Sigurnost sustava umjetne inteligencije u međunarodnom pomorskom prometu

Pilić, Marko

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zadar / Sveučilište u Zadru**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:162:118268

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Image not found or type unknown

Repository / Repozitorij:

University of Zadar Institutional Repository

Image not found or type unknown

SVEUČILIŠTE U ZADRU
i
LIBERTAS MEĐUNARODNO SVEUČILIŠTE

ZAJEDNIČKI POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
MEĐUNARODNI ODNOSI

Marko Pilić

SIGURNOST SUSTAVA UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU

Doktorski rad

Zadar; Zagreb, 2022.

SVEUČILIŠTE U ZADRU
i
LIBERTAS MEĐUNARODNO SVEUČILIŠTE
ZAJEDNIČKI POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
MEĐUNARODNI ODNOSI

Marko Pilić

SIGURNOST SUSTAVA UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU

Doktorski rad

Mentor

dr. sc. Josip Kasum, redoviti profesor u trajnom zvanju

Komentor

dr. sc. Toni Bielić, redoviti profesor

Komentorica

dr. sc. Željka Primorac, redovita profesorica

Zadar; Zagreb, 2022.

SVEUČILIŠTE U ZADRU
TEMELJNA DOKUMENTACIJSKA KARTICA

I. Autor i studij

Ime i prezime: Marko Pilić

Naziv studijskog programa: Međunarodni odnosi

Mentor/Mentorica: prof. dr. sc. Josip Kasum

Komentor/Komentorica 1: prof. dr. sc. Toni Bielić

Komentor/Komentorica 2: prof. dr. sc. Željka Primorac

Datum obrane:

Znanstveno područje i polje u kojem je postignut doktorat znanosti: Društvene znanosti, interdisciplinarne društvene znanosti.

II. Doktorski rad

Naslov: Sigurnost sustava umjetne inteligencije u međunarodnom pomorskom prometu

UDK oznaka: 656.61:004.89

Broj stranica: 431

Broj slika/grafičkih prikaza/tablica: 39 / 5 / 13

Broj bilježaka: 1037

Broj korištenih bibliografskih jedinica i izvora: 722

Broj priloga: 6

Jezik rada: Hrvatski

III. Stručna povjerenstva

Stručno povjerenstvo za ocjenu doktorskog rada:

1. izv. prof. dr .sc. Robert Kopal, predsjednik
2. izv. prof. dr. sc. Marko Valčić, član
3. prof. dr. sc. Hana Horak, članica

Stručno povjerenstvo za obranu doktorskog rada:

1. izv. prof. dr .sc. Robert Kopal, predsjednik
2. izv. prof. dr. sc. Marko Valčić, član
3. prof. dr. sc. Hana Horak, članica

UNIVERSITY OF ZADAR
BASIC DOCUMENTATION CARD

I. Author and study

Name and surname: Marko Pilić

Name of the study programme: International Relations

Mentor: (Tenure) Professor Josip Kasum, PhD

Co-mentor 1: (Full) Professor Toni Bielić, PhD

Co-mentor 2: (Full) Professor Željka Primorac, PhD

Date of the defence:

Scientific area and field in which the PhD is obtained: Social Sciences, Interdisciplinary Social Sciences.

II. Doctoral dissertation

Title: The security of Artificial Intelligence system in international maritime traffic

UDC mark: 656.61:004.89

Number of pages: 431

Number of pictures/graphical representations/tables: 39 / 5 / 13

Number of notes: 1037

Number of used bibliographic units and sources: 722

Number of appendices: 6

Language of the doctoral dissertation: Croatian

III. Expert committees

Expert committee for the evaluation of the doctoral dissertation:

1. Associate professor Robert Kopal, PhD., chair
2. Associate professor Marko Valčić, PhD., member
3. (Full) Professor Hana Horak, PhD., member

Expert committee for the defence of the doctoral dissertation:

1. Associate professor Robert Kopal, PhD., chair
2. Associate professor Marko Valčić, PhD., member
3. (Full) Professor Hana Horak, PhD., member

Izjava o akademskoj čestitosti

Ja, **Marko Pilić,** ovime izjavljujem da je moj **doktorski** rad pod naslovom **Sigurnost sustava umjetne inteligencije u međunarodnom pomorskom prometu** rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, prosinac, 2022.

SADRŽAJ

1 UVOD 1

1.1. PROBLEM, PREDMET I OBJEKT ISTRAŽIVANJA 6

1.2. SVRHA, CILJEVI I HIPOTEZE ISTRAŽIVANJA 11

1.3. OSTVARENI ZNANSTVENI DOPRINOS 12

2. PRAVNI OKVIR UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU 13

2.1. MEĐUNARODNA POMORSKA ORGANIZACIJA 13

2.2. MEĐUNARODNA ORGANIZACIJA RADA 17

2.3. KONVENCIJA UJEDINJENIH NARODA O PRAVU MORA 20

2.4. MEĐUNARODNA KONVENCIJA O ZAŠTITI LJUDSKIH ŽIVOTA NA MORU 23

2.5. MEĐUNARODNA KONVENCIJA O SPRJEČAVANJU ONEČIŠĆENJA S BRODOVA 28

2.6. MEĐUNARODNA KONVENCIJA O STANDARDIMA IZOBRAZBE, IZDAVANJU SVJEDODŽBI I DRŽANJU STRAŽE POMORACA 29

2.7. MEĐUNARODNA KONVENCIJA O REGULACIJAMA ZA PREVENCIJU SUDARA NA MORU . 31

2.8. MEĐUNARODNI PRAVILNIK O SIGURNOSNOJ ZAŠTITI BRODOVA I LUČKIH PROSTORA .. 33

2.9. UREDBA (EU) 2016/679 EUROPSKOG PARLAMENTA I VIJEĆA OD 27. TRAVNJA 2016. O ZAŠTITI POJEDINACA U VEZI S OBRADOM OSOBNIH PODATAKA I O SLOBODNOM KRETANJU TAKVIH PODATAKA TE O STAVLJANJU IZVAN SNAGE DIREKTIVE 95/46/EZ ... 35

2.10. UMJETNA INTELIGENCIJA ZA EUROPU 37

2.11. EUROPSKA STRATEGIJA ZA PODATKE 44

2.12. BIJELA KNJIGA O UMJETNOJ INTELIGENCIJI 47

2.13. IZVJEŠĆE O SIGURNOSTI I ODGOVORNOSTI ZA UMJETNU INTELIGENCIJU, INTERNET STVARI I ROBOTIKU 54

2.14. KOORDINIRANI PLAN O UMJETNOJ INTELIGENCIJI 56

2.15. PRIJEDLOG UREDBE EUROPSKOG PARLAMENTA I VIJEĆA – POSTAVLJANJE USKLAĐENIH PRAVILA O UMJETNOJ INTELIGENCIJI (ZAKON O UMJETNOJ INTELIGENCIJI) I IZMJENI I DOPUNI ODREĐENIH ZAKONODAVNIH AKATA UNIJE 58

2.16 AKTIVNOSTI UJEDINJENIH NARODA NA PODRUČJU UMJETNE INTELIGENCIJE 61

2.17 JAČANJE KIBERNETIČKE SIGURNOSTI EUROPSKE UNIJE 64

2.18. KOMPARATIVNA ANALIZA PRAVNIH IZVJEŠĆA U PODRUČJU UMJETNE INTELIGENCIJE .. 68

2.18.1. SAVEZNA REPUBLIKA NJEMAČKA 69

2.18.2. FRANCUSKA 71

2.18.3. UJEDINJENO KRALJEVSTVO 73

2.18.4. ŠPANJOLSKA 76

2.18.5. ITALIJA 77

2.18.6. SJEDINJENE AMERIČKE DRŽAVE 79

2.18.7. RUSIJA 83

2.18.8. KINA 85

2.18.9. AUSTRALIJA ... 87

2.19. NACIONALNE STRATEGIJE ZA UMJETNU INTELIGENCIJU ... 90
2.19.1. SAVEZNA REPUBLIKA NJEMAČKA ... 90
2.19.2. UJEDINJENO KRALJEVSTVO ... 92
2.19.3. ITALIJA ... 94
2.19.4. ŠPANJOLSKA ... 96
2.19.5. FRANCUSKA ... 99

3 UMJETNA INTELIGENCIJA U DRUŠTVU ... 102

3.1. POVIJEST RAZVOJA UMJETNE INTELIGENCIJE ... 102

3.2. POJAVNI OBLICI SASTAVNICA UMJETNE INTELIGENCIJE ... 108
3.2.1. UPRAVLJANJE VELIKOM KOLIČINOM PODATAKA ... 108
3.2.2. METODOLOŠKI PRISTUP UMJETNOJ INTELIGENCIJI ... 111
3.2.3. KOMUNIKACIJSKI SUSTAVI ... 124

3.3. DEFINIRANJE UMJETNE INTELIGENCIJE ... 130

3.4. SMJEROVI ISTRAŽIVANJA RAZVOJA UMJETNE INTELIGENCIJE ... 135
3.4.1. KOGNITIVNI PRISTUP ISTRAŽIVANJU UMJETNE INTELIGENCIJE ... 136
3.4.2. LOGIČKI PRISTUP ISTRAŽIVANJU UMJETNE INTELIGENCIJE ... 136
3.4.3. BIHEVIORALNI PRISTUP ISTRAŽIVANJU UMJETNE INTELIGENCIJE ... 137

3.5. USKA, OPĆA UMJETNA INTELIGENCIJA I SUPER INTELIGENCIJA ... 137
3.5.1. USKA UMJETNA INTELIGENCIJA ... 138
3.5.2. OPĆA UMJETNA INTELIGENCIJA ... 139
3.5.3. SUPER INTELIGENCIJA ... 140

3.6. STROJEVI I MISAONI PROCESI ... 142
3.6.1. TURINGOV TEST ... 143
3.6.2. KINESKA SOBA ... 144
3.6.3. SVIJEST STROJA ... 145
3.6.4. ŠTO STROJEVI MOGU I NE MOGU ČINITI ... 146

3.7. ETIČKE SMJERNICE ZA POUZDANU UMJETNU INTELIGENCIJU ... 148
3.7.1. NAČELO LJUDSKE AUTONOMIJE ... 152
3.7.2. NAČELO SPRJEČAVANJA NASTANKA ŠTETE ... 152
3.7.3. NAČELO PRAVEDNOSTI ... 152
3.7.4. NAČELO OBJAŠNJIVOSTI ... 153
3.7.5. LJUDSKO DJELOVANJE I NADZOR ... 154
3.7.6. TEHNIČKA OTPORNOST I SIGURNOST ... 155
3.7.7. PRIVATNOST I UPRAVLJANJE PODACIMA ... 156
3.7.8. TRANSPARENTNOST ... 157
3.7.9. RAZNOLIKOST, NEDISKRIMINACIJA, PRAVEDNOST ... 157
3.7.10. DOBROBIT DRUŠTVA I OKOLIŠA ... 157
3.7.11. ODGOVORNOST ... 158

3.8. LJUDSKA PRAVA I UMJETNA INTELIGENCIJA ... 161
3.8.1. PRAVO NA PRAVIČNO SUĐENJE ... 165
3.8.2. PRAVO NA PRIVATNOST I ZAŠTITU PODATAKA ... 167
3.8.3. PRAVO NA SLOBODU IZRAŽAVANJA ... 169
3.8.4. SLOBODA OKUPLJANJA I UDRUŽIVANJA ... 172
3.8.5. PRAVO NA DJELOTVORAN PRAVNI LIJEK ... 172
3.8.6. ZABRANA DISKRIMINACIJE ... 174
3.8.7. SOCIJALNA PRAVA I PRISTUP JAVNIM USLUGAMA ... 175
3.8.8. PRAVO NA SLOBODNE IZBORE ... 175

3.9. HUMANOIDNA UMJETNA INTELIGENCIJA 176
3.9.1. PRIHVAĆANJE ZNANJA, LJUDI I UMJETNA INTELIGENCIJA 178
3.9.2. UTJECAJ UMJETNE INTELIGENCIJE NA PRAVNI SUSTAV 179
3.9.3. UMJETNA INTELIGENCIJA KAO UGROZA U PRAVNOM SUSTAVU 180
3.9.4. UMJETNA INTELIGENCIJA U MODERNIZACIJI SUDSTVA 184
3.9.5. UMJETNA INTELIGENCIJA, ČOVJEČANSTVO I RELIGIJA 187

3.10. OBJAŠNJIVA I ODGOVORNA UMJETNA INTELIGENCIJA 189
3.10.1. PRISTRANOST UMJETNE INTELIGENCIJE 189
3.10.2. PRAVEDNOST UMJETNE INTELIGENCIJE 191
3.10.3. ODGOVORNA UMJETNA INTELIGENCIJA 191
3.10.4. OBJAŠNJIVA, TRANSPARENTNA I POVJERLJIVA UMJETNA INTELIGENCIJA 192
3.10.5. POGREŠNE ODLUKE UMJETNE INTELIGENCIJE 193
3.10.6. ZDRAVSTVENA SKRB U POMORSTVU 194

4 UTJECAJ UMJETNE INTELIGENCIJE NA DRUŠTVO 197

4.1. STANJE U SVIJETU POSLOVA 200

4.2. UMJETNA INTELIGENCIJA U MEĐUNARODNOM POMORSKOM PROMETU 210

4.3. PRILIKE I IZAZOVI U POVEZIVOSTI S UMJETNOM INTELIGENCIJOM 214

4.4. MOGUĆNOSTI I OGRANIČENJA UMJETNE INTELIGENCIJE 216

4.5. NAPREDAK DRUŠTVA I KLASIFIKACIJA UMJETNE INTELIGENCIJE 218

4.6. ASILOMARSKI PRINCIPI UMJETNE INTELIGENCIJE 222

4.7. MORALNE DILEME I AUTONOMNA NAVIGACIJA, UTJECAJ NA DRUŠTVO 227

4.8. ETIČNE DILEME ZNAČAJNIH GOSPODARSKIH SUBJEKATA 229

4.9. PRIMJERI ISKORISTIVIH MOGUĆNOSTI PRIMJENE UMJETNE INTELIGENCIJE U POSEBNO PROBLEMATIČNIM PODRUČJIMA 230

4.10. UMJETNA INTELIGENCIJA I BRUTO DOMAĆI PROIZVOD 234

4.11. UMJETNA INTELIGENCIJA I POREZNI SUSTAV 239

5 UMJETNA INTELIGENCIJA U MEĐUNARODNOM POMORSKOM PROMETU 241

5.1. PREGLED ELEKTRONIČKIH NAVIGACIJSKIH SUSTAVA U POMORSKOM PROMETU 241
5.1.1. INERCIJALNI NAVIGACIJSKI UREĐAJ 241
5.1.2. ŽIRO KOMPAS 242
5.1.3. DIGITALNI ŽIRO KOMPAS 242
5.1.4. ELEKTRONIČKI KOMPAS 242
5.1.5. ULTRAZVUČNI DUBINOMJER 242
5.1.6. BRZINOMJERI 243
5.1.7. GLOBALNI SUSTAV ZA POZICIONIRANJE 243
5.1.8. GLOBALNI NAVIGACIJSKI SATELITSKI SUSTAV 244
5.1.9. RADAR 245
5.1.10. SNIMAČ PODATAKA O PUTOVANJU 245
5.1.11. SUSTAV AUTOMATSKOG PREPOZNAVANJA 245
5.1.12. ELEKTRONIČKA POMORSKA KARTA 245
5.1.13. AUTOPILOT 246

5.2. MODERNE TEHNOLOGIJE I LUČKE OPERACIJE - TRENUTNO STANJE I OČEKIVANI RAZVOJ 246
5.2.1. EKOLOŠKI PRIHVATLJIVI BRODOVI I TRANSPORT 248
5.2.2. SIGURNOST I ZAŠTITA 248

5.2.3. POVEZANOST I AUTOMATIZIRANI TRANSPORT 249
5.2.4. LJUDSKI FAKTOR 250
5.2.5. INTEGRIRANA TRANSPORTNA LOGISTIKA 250
5.2.6. PROIZVODNJA 251
5.2.7. PODVODNI ZVUKOVI I AKUSTIKA 251

5.3. PRIMJENA UMJETNE INTELIGENCIJE U POMORSKOM PROMETU 252
5.3.1. AUTONOMNI BRODOVI 252
5.3.2. DIGITALNE LUKE 253
5.3.3. VIRTUALNI ASISTENTI 253
5.3.4. OBRADA DOKUMENATA 254
5.3.5. POBOLJŠANJE TOČNOSTI 254
5.3.6. EKOLOŠKI PRIHVATLJIVI PRISTUP 255

5.4. AUTONOMNA NAVIGACIJA U MEĐUNARODNOM POMORSKOM PROMETU 255
5.4.1. RAZVOJ AUTONOMNIH PLOVILA 255
5.4.2. PROJEKT MUNIN 259
5.4.3. DALJINSKI UPRAVLJANA, TEHNIČKI - TEHNOLOŠKA PODRŠKA I CENTRI ZA OBALNO UPRAVLJANJE 263
5.4.4. ODGOVORNOST UPRAVLJANJA SUSTAVOM UMJETNE INTELIGENCIJE AUTONOMNIH PLOVILA 265

5.5. PREDNOSTI I NEDOSTACI SUSTAVA UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU 270

5.6. SIGURNOSNI I TEHNIČKI NADZOR BRODSKIH ELEKTRONIČKIH NAVIGACIJSKIH UREĐAJA 272

5.7. MODEL ODREĐIVANJA SIGURNOSTI SUSTAVA UMJETNE INTELIGENCIJE 275

5.8. POBOLJŠANJE POSTOJEĆIH SUSTAVA 278

6 SIGURNOSNI ASPEKTI UMJETNE INTELIGENCIJE U POMORSKOM PROMETU 290

6.1. PRIKAZ SUSTAVA SIGURNOSTI UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU 290

6.2. KIBERNETIČKA SIGURNOSTI I UPRAVLJANJE RIZICIMA 292

6.3. PLANOVI I PROCEDURE 294

6.4. IDENTIFIKACIJA PRIJETNJI 298

6.5. TIPOVI PRIJETNJI I FAZE IZVRŠENJA 299

6.6. IDENTIFIKACIJA RANJIVOSTI 302

6.7. PROCJENA VJEROJATNOSTI 305

6.8. PROCJENA UTJECAJA 306

6.9. PROCJENA RIZIKA 309

6.10. RAZVOJ MJERA ZAŠTITE 311

6.11. RAZVOJ DETEKCIJSKIH MJERA 314

6.12. ODGOVOR I OTKLANJANJE KIBERNETIČKIH INCIDENATA 315

7 RASPRAVA 317

8 ZAKLJUČAK 332

LITERATURA 339

SAŽETAK *395*
SUMMARY *398*
POPIS OZNAKA I KRATICA *401*
POPIS SLIKA *413*
POPIS GRAFIKONA *414*
POPIS TABLICA *414*
ANKETNI UPITNIK *416*
ŽIVOTOPIS *420*

ZAHVALA I SPOMEN

Želio bih se zahvaliti svima onima koji su mi na razne načine pomogli prilikom izrade ovog rada. Jedna stranica je premalo za izraziti zahvalnost koju osjećam prema vama.

Prvenstveno, želim se zahvaliti mentoru prof. dr. sc. Josipu Kasumu. Brojne ideje, diskusije i sati razgovora koje smo vodili utkani su u ovaj rad. Vaše vođenje i stručnost značajno su mi pomogli u ovom procesu. Prihvatili ste biti mi mentor, a ja sam osim stručnjaka dobio i prijatelja. Hvala vam na svemu.

Veliku zahvalnost dugujem i komentorici prof. dr. sc. Željki Primorac. Hvala vam na strpljenju. Naučili ste me, između ostalog, kako pažnju uvijek moram posvetiti i najmanjim detaljima. Slobodan sam istaknuti kako ste mi u ovom procesu bili kao dobar roditelj, tjerali me naprijed i tražili više i bolje. Hvala vam na tome.

Izrazito sam zahvalan i komentoru prof. dr. sc. Toniju Bieliću na pristupačnosti, potpori i poticaju. Vaših savjeta ću se uvijek sjećati. Hvala vam još jednom.

Isto tako, dužnost mi je, a i čast spomenuti moga životnog mentora prof. dr. sc. Damira Primorca. Pružili ste mi priliku i povjerenje, a ja se nadam da sam vas učinio ponosnim. Vaši mudri savjeti imali su i imat će ključnu ulogu u mom profesionalnom i privatnom životu. Neizmjerno sam vam zahvalan.

Veliko hvala stručnom povjerenstvu za ocjenu i obranu rada na izvrsnoj suradnji.

Najveću zahvalnost dugujem svojoj obitelji.
Hvala mami Đurđici i ocu Peri na potpori u svakom smislu, hvala što ste vjerovali u mene, hvala na svim vrijednostima kojima ste me učili, a nadasve hvala što postojite. Bolje roditelje ne bih mogao ni zamisliti.

Hvala baki Divni, sestri Aniti, zetu Marinu, nećacima Roku i Neri. Uvijek sam se mogao osloniti na vas i na tome ću vam biti vječno zahvalan.

Hvala dragoj Jasminki i Peri. Nikada neću zaboraviti ljubav koju ste mi pružili kao ni činjenicu da sam rad započeo pisati u Jesenicama, a završio u Strožancu. Lijepe stvari se uvijek vežu uz vas.

Nemjerljivo hvala dugujem svojoj supruzi Maji i sinu Petru.
Majo, hvala ti na bezuvjetnoj ljubavi, svakodnevnoj potpori te na svim savjetima i pomoći. Bez tebe sve bi bilo puno teže. Hvala što si kamen temeljac naše male obitelji.

Ipak i unatoč svim zahvalama, ovaj rad posvećujem svome sinu Petru. Dragi sine, sretan sam što te imam.

Zahvalu dugujem i svojoj mostarskoj obitelji Leli, Goranu, Leoni i Zoranu na vjeri i riječima potpore. Uvijek ću se sjećati radnog stola u Dubrovačkoj.

Na koncu, moram istaknuti kako je ovaj rad obranjen 2. prosinca 2022. na rođendan pokojne, krštene mi kume Nataše. Ne vjerujem u slučajnosti. Nato, hvala ti što me pratiš od gore i pozdravi mi didu Marka, didu Miljenka i baku Anu.

1 UVOD

Pojam umjetne inteligencije (engl. *Artificial Intelligence* - AI) predstavlja nepoznanicu široj javnosti i ostavlja nejasnoće u samoj integraciji sustava AI u poslovanje i/ili djelovanje određenih poduzeća i poslovnih subjekata. U prilog tome ide istraživanje provedeno na 1500 poslovnih lidera unutar svojih organizacija u Sjedinjenim Američkim Državama (SAD) gdje je svega 17 % ispitanika izjavilo kako je upoznato s pojmom AI.[1] Neki od njih nisu bili sigurni što je to ili kako će AI utjecati na njihova poduzeća, ali su shvatili da postoji značajan potencijal za promjenu poslovnih procesa, iako im nije bilo jasno kako se AI može upotrijebiti unutar njihovih poduzeća. S druge strane, primjena AI može se, primjerice, očitovati u prometnim sustavima odnosno poluautonomnim ili autonomnim vozilima / plovilima koji operaterima daju podatke o nadolazećim prometnim zagušenjima i smetnjama, odnosno sudjeluju u izradi optimalne plovne rute s obzirom na vremenske prilike, željenu uštedu goriva i sl.[2]

U ovoj doktorskoj disertaciji primijenjena metodologija znanstvenog istraživanja obuhvaća nekoliko faza ravnomjerno podijeljenih po poglavljima. S obzirom na složenost materije koja se radom obrađuje, u svrhu pisanja ove doktorske disertacije korišteno je više znanstveno istraživačkih metoda. Tako se na prikupljenim materijalima znanstveno istraživačkim metodama selekcije, analize i sinteze nastoje spoznati činjenice relevantne za ovo znanstveno istraživanje. Te činjenice su klasificirane i vrednovane s ciljem stvaranja novih spoznaja, utvrđivanjem eventualnih zakonitosti istraživanih pojavnosti koristeći matematičke, informatičke i statističke znanstveno istraživačke metode. S obzirom na to da naslov rada sugerira kako je riječ o djelu iz područja tehničkih znanosti, važno je naglasiti kako je istraživanje provedeno interdisciplinarnim, multidisciplinarnim i transdisciplinarnim pristupom forenzičkih znanosti i kao takav smatra se dijelom društvenog područja znanosti.

Glede sadržajne konstrukcije, ova doktorska disertacija sastoji se od šest poglavlja te rasprave, zaključka i popisa korištene literature. U uvodnom dijelu određuje se znanstveni doprinos te prikazuje mogućnost primjene predviđenog znanstvenog istraživanja. Nadalje, određuje se pojmovna okosnica problema temeljena na analizi razvoja AI s posebnim osvrtom

---

[1] Davenport, T., Loucks, J., Schatsky, S. (2017). Bullish on the Business Value of Cognitive. Deloitte, str. 3. dostupno na: www2.deloitte.com/us/en/pages/deloitte-analytics/articles/cognitive-technology-adoption-survey.html

[2] Bellone, M., Lundh, M., Wahde, M., MacKinnon, S. (2019). Electrification and Automation in Maritime Applications: Employing AI Techniques for Energy Optimization and Efficiency. IEEE Electrification Magazine, 7(4), str. 23.

na međunarodni pomorski promet. Također se detaljno istražuje pravna utemeljenost proučavanjem i komparativnom analizom pravnog nasljeđa Europske unije (engl. *European Union* – EU) u domeni AI. S istog polazišta istražuju se aktivnosti Ujedinjenih Naroda (engl. *United Nations* – UN), Međunarodne pomorske organizacije (engl. *International Maritime Organization* - IMO), uz analizu nacionalnih propisa u vezi s AI na primjeru SAD-a, Kine, Francuske, Španjolske, Italije, Ujedinjenog Kraljevstva, Rusije, Australije i Njemačke. Radom se nastoji utvrditi današnja razina primjene AI u međunarodnom pomorskom prometu uz prikaz očekivanih pravaca razvoja i prijedloga daljnjih istraživanja. U međunarodnom pomorskom prometu se poglavito radi očekivano manjih troškova poslovanja očekuje rastuća primjena AI. Stoga se detaljno istražuje međunarodni pomorski promet kao sustav koji obuhvaća obalni i od obalni podsustav, počevši od same definicije AI, utvrđivanja razine sadašnje te očekivane primjene AI s polazišta sigurnosti. U tom smjeru, radom se vrši analiza pojavnih oblika AI kroz primjenu neuronskih mreža, inteligentnih agenata, sustava rudarenja podataka, sustava upravljanja velikom količinom podataka, strojnog učenja, dubokog učenja i autonomnih plovila, uz utvrđivanje prednosti i nedostataka primjene istih. Temeljem uočenih nedostataka nastoje se odrediti moguća poboljšanja postojećih sustava te ukazati na problem neophodnosti nadzora sustava AI.

Filozofski i sociološki aspekti su analizirani u trećem i četvrtom poglavlju ove doktorske disertacije, uočavajući tri smjera znanstvenog istraživanja opće AI raščlambom na kognitivni, logički i bihevioristički smjer. Radom se nastoji istražiti fenomen definiran upitom o tome može li stroj uopće razmišljati na način koji je svojstven čovjeku. Stoga se posebno potrebnim znanstvenim pristupom analiziraju: Turingov test, problem kineske sobe, svijest stroja uz pokušaj elaboriranog odgovora na pitanje što strojevi mogu ili ne mogu raditi i/ili činiti. Danas se robotika može smatrati usko povezanom s AI te se kritički vrednuju zakoni robotike, sve u povezanosti i /ili prožetosti s ljudskim pravima i humanoidnom inteligencijom. Također, opravdano se može tvrditi da je porezna politika sastavni dio funkcioniranja modernih država i društava te se kao takva posebno analizira u povezanosti s AI. Iz navedenog se postavlja temeljno pitanje; koliko je AI stvarno sigurna ili u kojoj joj se mjeri može vjerovati. Tijekom ovog znanstvenog istraživanja izučavaju se spoznaje ispitanika eksperata u području AI znanstveno istraživačkim metodama intervjuiranja i anketiranja. Osim toga, istražuju se dostupne tehničko tehnološke značajke AI na današnjoj razini razvijenosti i primjene. Primijenjenim metodama modeliranja razvijeni su svi potrebni polazni modeli kao i novi model

iskoristiv u vrednovanju sigurnosti sustava AI s raznih polazišta predviđenih istraživanjima. Ona se odnose na povezanost AI s postojećim zakonodavnim propisima, definicijama, pojavnim oblicima, međunarodnim pomorskim prometom, filozofskim i sociološkim aspektima, poreznom politikom, ljudskim pravima, pravima same AI (vlasnika, koncesionara ili nekim novopredloženim pravnim i/ili ekspertnim pojmovima i sl.), radom, humanoidnim značajkama, terminološkim odrednicama i ostalima, koji se pojavljuju kao novo prepoznati u samom istraživanju. Znanstvenim pristupom znanstveno istraživačke metode opće teorije sustava, raščlambom na podsustave, uz utvrđivanje među povezanosti podsustava i elemenata definiranih podsustava unutar sustava kao i s okolinom sustava AI i primjenom novih mjera, provodi se analiza sigurnosti sustava AI u međunarodnom pomorskom prometu na modelu s mogućnošću praktične primjene.

Pregled istraživanja podrazumijeva povratak u sredinu prošlog stoljeća gdje se AI kao pojam pojavljuje 1943. godine prilikom znanstvenog i istraživačkog rada *Warrena McCullocha* i *Waltera Pittsa* koji, vođeni ponajviše teorijom računanja *Alana Turinga,* ali i znanjem iz područja fiziologije i funkcije neurona u mozgu, predlažu model umjetnih neurona s funkcijom „*on*“ ili „*off*“[3]. Usporedbe radi, u današnjem razdoblju računalne znanosti ta dva stanja klasificiraju se kroz binarni sustav odnosno poprimaju vrijednost 1 kada je određeno stanje „*on*“ ili vrijednost ∅ kada je stanje „*off*“. Sama vrijednost tzv. umjetnih neurona iznosila bi u početnom stanju ∅ sve do trenutka kada bi došlo do dovoljne interakcije susjednih neurona čime se vrijednost iz ∅ mijenja u 1.[4] Usprkos doprinosu gore navedenih autora, zasluge u stvaranju AI kakvu znamo danas ima matematičar *F*. Njegovo otkriće stroja iz 1936. godina postavlja prve prave temelje u stvaranju AI. Turingov stroj, znan kao umjetni stroj, u svojoj srži i ne ulazeći u inženjerske postavke, odgovarao je na dva zadana pitanja. S obzirom na to da se Turingov stroj sastojao od beskonačnog niza vrpci na koje su se zapisivali podaci, u kontekstu dva zadana pitanja zapisivao je odgovor na pitanje postoji li stroj koji može utvrditi zapisuje li bilo koji stroj na vrpci zadani simbol i postoji li stroj koji se „zamrzava“ ili ne može dovršiti neku računsku operaciju.[5] Pod pojmom „zamrzavanja“ smatra se prekid daljnjeg djelovanja stroja uslijed nemogućnosti izvršavanja neke akcije. S obzirom na to da su ideja i već neka poduzeta djelovanja na području AI uzeli maha, u povijesti razvoja AI pojavili su se još neki

[3] Russell, S. J., Norvig, P. (2016). Artificial intelligence – A modern approach, 3rd Ed., Pearson Education, str. 16.
[4] *Loc. cit.*
[5] Warwick, K. (2012). Artificial intelligence – The basics, Routledge, str. 86.

znanstvenici i istraživači čiji je doprinos ostavio dubok trag u razvoju znanosti. To je ponajprije *John McCarthy,* koji je u tom razdoblju radio na sveučilištu *Dartmouth* (*Hanover, New Hampshire,* SAD), je predložio radionicu deset znanstvenika u razdoblju od dva mjeseca u ljeto 1956 godine. Ideja koju je zamislio *McCarthy* je temeljena na premisi da proces učenja i/ili drugih funkcija inteligencije koji je pomno osmišljen i objašnjen može rezultirati računalnom simulacijom odnosno da se može napraviti stroj koji će taj postupak simulirati. Cilj skupine znanstvenika bio je istražiti kako stroj može koristiti govor u svom djelovanju, ali i rješavati zadatke koji su do tada bili nerješivi za strojeve.[6] Nakon uspješnog okupljanja i rada na sveučilištu Dartmouthu, znanstvena zajednica se priključila na „vlak" AI i iznjedrila niz pokušaja i članaka na temu AI i procesa rješavanja problema stroja na način na koji to rade ljudi. Međutim, od velikog broja istraživanja se vremenom i odustalo, uzevši za primjer GPS program (engl. *General Problem Solver* - GPS) kojeg su razvili *Herbert A. Simon, J. C. Shaw* i *Allen Newell*, ali nikad nije u potpunosti zaživio zbog neefikasnosti sustava odnosno previše korištenja memorije za odrađivanje jednostavnih funkcija.[7] Tadašnji problem najviše je predstavljao način razmišljanja znanstvenika, ali i šire javnosti. Djelomično, takav pristup je prisutan i danas, a smatra se da AI želi reproducirati ljudsku, ne priznajući inteligenciju stroja samu po sebi, odnosno da inteligencija ne treba kopirati ljudske kognitivne sposobnosti već se temeljiti na razvoju uske, unaprijed određene i valjano definirane inteligencije. Najbolji primjer tome je bila *ELIZA*,[8] *chatterbot* kojeg je razvio *Joseph Weisenbaum*. Iako je bila u ranoj fazi razvoja, *ELIZA* i njeni razgovori s osobom s druge strane tipkovnice su bili toliko realni da su uspijevali prevariti sudionike razgovora i navesti ih na pomisao da zaista komuniciraju s osobom, a ne računalom. Međutim, to je bila rijetka svijetla točka u razvoju AI tijekom 1960-ih godina što je bila uvertira u tzv. mračno doba AI tijekom 70-ih kada ništa značajnije nije postignuto i velika većina istraživanja je odbačena, a financiranja su povučena. Nije se uspijevao pronaći dovoljno dobar razlog za nastavak istraživanja, posebice kada se uzmu u obzir neka od tadašnjih istraživanja gdje je dosta sredstava uloženo u programe poput nekih strojeva za obradu prirodnog jezika koji bi u svom rječniku imali svega 20-ak riječi, što je dobrim dijelom bilo uzrokovano slabim hardverskim mogućnostima stroja. Nedostatkom

[6] *Loc. cit.*
[7] Newell, A., Shaw, J. C., Simon, H. A. (1959). Report on a General Problem-Solving Program, International Conference on Information Processing, UNESCO House, Paris, France. str. 2.
[8] Weizenbaum, J. (1966). Computational Linguistics, Communications of the ACM, Vol. 9., No. 1., dostupno na: https://web.stanford.edu/class/linguist238/p36-weizenabaum.pdf

stvarnih tehničkih uvjeta i mogućnosti za daljnjim razvojem, po prvi se puta javlja i filozofski pristup u AI i rasprava o „kineskoj sobi“. Turingov postulat o stroju koji razmišlja (Turingov stroj) tada biva izložen pobijanju filozofske znanstvene zajednice kada po prvi puta John Searle tvrdi da stroj ne može razmišljati pa čak i da ne razumije simbole koje obrađuje već samo manipulira istima.[9] Nakon mračnog doba AI slijedi renesansa 1980-ih ponajviše iz tri razloga. Većina istraživača i znanstvenika nastavlja s radom na razvoju AI s praktičnog aspekta, odnosno prihvaćen je pristup uske funkcionalnosti AI sa specifičnim znanjima i tržištu / industrijski prilagođena. Nadalje, dva pristupa; filozofski i tehnički, nisu se obazirala jedni na druge već su radili svoje čime se razvoj inteligencije nije usporavao kao što je to bio slučaj u 1970-ima kada su se vodili prijepori o mogućnosti AI u usporedbi s čovjekom. Treći razlog je razvoj robotike čija je pojava utjecala na percepciju izgleda AI, odnosno polazištem da računalo / inteligencija mora imati „tijelo“ kako bi mogla opstati. Polako dolazeći do kraja 20. stoljeća susrećemo se i prvim sustavom AI koji nadmašuje čovjeka u specifičnom i logičkom pristupu u djelovanju. Naime, 1997. godine programski sustav *Deep Blue*, kreiran za igranje šaha, pobjeđuje svjetskog prvaka *Garry Kasparova*, a 2002. godine *Kevin Warwick* prvi put povezuje ljudski živčani sustav s računalom.[10] Nadalje, evolucija AI ide sve od robota koji je pobijedio u izazovu DARPA (engl. *Defense Advanced Research Projects Agency* - DARPA) vozeći samostalno 131 milju kroz pustinju, *Google*-ovu AI *AlphaGo* koja je pobijedila jednog od najboljih GO igrača svijeta, preko stvaranja pametnih telefona, internetskih pretraživača, raznih računalnih i mobilnih sustava, robota koji se kreću i razgovaraju, pa sve do onog što je predmet istraživanja ovog rada, a to su inteligentni sustavi u pomorskom prometu koji su osnova navigacijskih integriranih sustava, sustava dinamičkog pozicioniranja, elektroničke navigacije, satelitskih komunikacija, satelitskih pozicioniranja, satelitski podržanih mjerenja i sličnih sustava navođenja važnih za današnji pomorski promet. Pokazalo se kako se pregledom povijesti može steći i uvid u budućnost što u području AI predstavlja zanimljive inovacije i dostignuća. Jedan od takvih primjera je i humanoidni robot *Sophia* koja je postala aktivna 2016. godine. Humanoidni robot je napravljen na sliku glumice *Audrey Hepburn* i temeljen je na sličnom konceptu kao i već spomenuta *ELIZA* samo sa sofisticiranijim računalnim algoritmima

[9] Preston, J., Bishop, M. (2002). Views into the Chinese Room: New Essays on Searle and Artificial Intelligence, Oxford University Press, str. 3.

[10] IBM-ov *Deep Blue* pobjeđuje *Kasparova,* tadašnjeg svjetskog prvaka, u partiji šaha u meču od 6 utakmica čime se, iako sa zakašnjenjem, ostvarila izjava *Simon*-a i *Newell*-a iz 1959. o računalu kao prvaku svijeta u šahu. Više o tome na: https://web.eecs.umich.edu/~kuipers/opinions/AI-progress.html

i naprednijim hardverom. Ono što Sophiu čini drugačijim humanoidnim robotom jest činjenica da je robot dobio državljanstvo Saudijske Arabije čime su se postavila mnoga pitanja.[11] Osporavao se prvenstveno tehnološki napredak robota, tvrdeći da je to ništa više od *chaterbotta* samo moderne verzije koja koristi tehnike AI poput praćenja lica, prepoznavanja emocija, dubokih neuronskih mreža i sl. Potom se raspravljalo i o dobivenom državljanstvu koje samo po sebi povlači određene obveze i prava koje pripadaju čovjeku. Postavilo se i pitanje o glasačkim pravima robota, pravu na vjenčanje, pa čak i o ubojstvu u slučaju namjernog gašenja sustava robota. U svakom slučaju, pokazalo se kako će budućnost AI imati široku primjenu u tehnici, pravu i filozofiji. Kroz ovaj rad budućnost AI se promatra s aspekta međunarodnog pomorskog prometa. U tom kontekstu, Rolls-Royce je predstavio viziju budućeg kopnenog kontrolnog centra (engl. *Shore Control Centre - SCC*) u kojem mala posada od 7 do 14 ljudi prati i kontrolira flotu udaljenih i autonomnih plovila širom svijeta. Posada koristi interaktivne pametne ekrane, sustave prepoznavanja glasa, holograme i nadzorne dronove za nadgledanje onoga što se događa kako na brodu tako i oko njega. Daljinski i autonomni brodovi jedan su od tri elementa inovativne strategije brodske inteligencije za koju se smatra da će omogućiti transformaciju brodskih tvrtki koristeći moć upravljanja velikom količinom podataka.

1.1. PROBLEM, PREDMET I OBJEKT ISTRAŽIVANJA

Kako bi se stekao uvid u problem, predmet i objekt istraživanja kao i uočene nedostatke možebitne primjene AI u međunarodnom pomorskom prometu nužno je osvrnuti se na nesreće izazvane korištenjem tehnički i računalno visoko podržanim sustavima, dakle tehnologijama po definiciji vrlo bliskim sustavu AI. S obzirom na to da je razvoj autonomne tehnologije uvjetovan i pravnim regulativama, u međunarodnom pomorskom prometu za sada ne možemo naići na incidente takve vrste, odnosno incidente koji uključuju autonomna plovila. IMO, Međunarodna konvencija o zaštiti ljudskih života na moru (engl. *International Convention for the Safety of Life at Sea* - SOLAS), Međunarodna konvencija o sprječavanju onečišćenja s brodova (engl. *International Convention for the Prevention of Pollution from Ships* – MARPOL), Međunarodna konvencija o standardima izobrazbe, izdavanju svjedodžbi i držanju straže pomoraca (engl. *The International Convention on Standards of Training, Certification and Watchkeeping for Seafarers)* i Konvencija o međunarodnim pravilima o izbjegavanju

[11] Retto, J. (2017). Sophia, first citizen robot of the world, ResearchGate

sudara na moru (engl. *Convention on the International Regulations for Preventing Collisions at Sea* - COLREG) u tekstu svojih konvencija ne predviđaju autonomne brodove i njihova putovanja međunarodnim vodama. Navedene konvencije upućuju na direktnu kontrolu brodova što podrazumijeva određeni broj ljudske posade i još uvijek ne prepoznaju alternativne mogućnosti što nudi autonomna brodska navigacija. Tako primjerice COLREG zahtjeva da zapovjedni most broda mora uključivati ljudsku posadu sukladno članku 5. COLREG konvencije. To uključuje opažanja biološkim elementima poput vida i sluha kako bi se spriječila pomorska nesreća. Prema SOLAS konvenciji nužno je da brod bude dovoljno i efikasno popunjen ljudskom posadom te sadržava državne oznake pripadnosti, odnosno državnu zastavu. Osim upravljačkih elemenata koje ljudska posada ostvaruje na brodu, navodi se i nužnost pritjecanja u pomoć drugom brodu u nevolji što autonomni brodovi, barem po prvoj zamisli, ne mogu ostvariti. COLREG također navodi potrebu ljudske posade u ostvarivanju elemenata poput čuvanja straže ili promatranju okoline u svrhu prevencije od sudara na moru što sprječava upotrebu potpune autonomije broda. Međutim, države mogu samostalno donijeti odluke o provedbi autonomne plovidbe sve dok autonomni brodovi plove isključivo u njihovim teritorijalnim vodama. S obzirom na tek dozvoljena testiranja poput pomorskih površinskih autonomnih brodova (engl. *Maritime Autonomous Surface Ships* – MASS) i sličnih, tek u skorijoj budućnosti možemo očekivati rezultate testova autonomne plovidbe. Iako autonomna plovila nisu još uvijek zaživjela u kontekstu međunarodnog pomorskog prometa, pomorske nesreće s plovilima koje koriste tehnologiju, po definiciji blisku AI, su itekako poznate. Tako za primjer možemo uzeti neprimjereno korištenje sustava elektroničkog pokazivača pomorskih karata s informacijskim sustavom (*eng. Electronic Chart Display and Informations System* - ECDIS) u nasukanju broda rasutog tereta[12] gdje je došlo i do ljudske pogreške pri krivom izračunu rute, ali i zvučnom neoglašavanju samog ECDIS sustava što inače nije slučaj.

Pomorske nesreće do kojih dođe prilikom upotrebe / nepravilne upotrebe usluge praćenja prometa plovila (engl. *Vessels Traffic Service* - VTS) su također poznate. To je vidljivo i na primjeru sudara teretnog broda Karen Danielsen i Great Belt Bridge u Danskoj. Područje je bilo pokriveno VTS sustavom, ali u ključnom trenutku operater VTS-a je bio ometen te je teretnjak udario u most. Hrvatski časnik je zaspao na mostu i nažalost poginuo u toj nesreći. To pokazuje i manjkavosti sustava u kojem je ljudska odluka u kritičnim trenucima nužna, pa časnici

[12] Više o tome na: https://www.marineinsight.com/case-studies/mproper-bridge-procedures-ecdis-use-caused-grounding/

zaokupljeni administracijom ne uspijevaju obavljati dužnosti nužne za prevenciju sudara na moru određene COLREG konvencijom.

Odbor Ujedinjenog Kraljevstva za pomorske nesreće (engl. *United Kingdom Marine Accident Investigation Board* - UK MAIB) je 2014. objavio izvješće u sudaru *Rickmers Dubai* i *Walcon Wizard* gdje su kritizirali preveliko oslanjanje časnika broda Rickmers Dubai na brodsku opremu automatskog sustava prepoznavanja (engl. *Automatic Identification System* – AIS).[13] Provjera informacija koje pruža AIS treba biti verificirana zbog visokog rizika od pogreške, odnosno potrebitost provjere informacija s drugim informativnim sustavima kao radar ili izvorima informacija kao vizualni pregled šire i bliže okoline broda. To se odnosi i na shvaćanje kako prema SOLAS brodovi ispod 300 bruto tona ne moraju biti opremljeni s AIS sustavom ili činjenicom da u pojedinim situacijama kapetan broda može isključiti AIS. U tom kontekstu, AIS ne može biti jedino sredstvo kojim će se stvarati percepcija okolnog područja na moru. Također, probleme u navigaciji može stvarati loša kalibracija pomorskog radara s mogućnošću automatskog radarskog crtanja (engl. *Automatic Radar Plotting Aid* - ARPA), odnosno može stvoriti redukciju skeniranog područja kao što je bio slučaj u nesreći izazvanoj od strane nosača automobila što je vidljivo iz izvješća nautičkog instituta MARS.[14]

Korištenje sustava dinamičkog pozicioniranja (engl. *Dynamic Posittioning* - DP), sustava koji je iznimno sofisticiran, može stvarati poteškoće i uzrokovati hitna odvajanja od objekata na moru pa i ozbiljne nesreće. U jednom od primjera, poteškoće uzrokovane električnim smetnjama dovele su do nemogućnosti povezivanja potisnika sa sustavom. Potisnik koji je bio na održavanju zbog nepravilnog rada uzrokovao je pokretanje sekvence hitnog odvajanja (engl. *Emergency disconnect sequence* - EDS), odnosno gubljenje pozicije. Nekoliko je primjera gubljenja pozicije zbog loših vremenskih uvjeta. Unatoč zaprimanju vremenskih upozorenja o grmljavinskoj oluji i jakim vjetrovima, u jednom slučaju, svega polovica dizelskih generatora je bila u funkciji što je dovelo do gubljenja pozicije i pokretanja EDS. Pitanje koje se postavlja je potencijal korištenja AI u predviđanju neželjenih okolnosti, ali i mogućnosti donošenja samostalnih odluka u stvarnom vremenu, a sve u svrhu reduciranja broja nesreća korištenjem bilo kojih od navedenih sustava, odnosno donošenje najbolje odluke na temelju podataka dobivenih iz svih dostupnih sustava.

[13] Maritime accident investigation branch – Accident report NO 24/2012, UK, 2012.
[14] Više o tome na: https://www.marineinsight.com/case-studies/real-life-incident-bridge-not-job-leads-collision/

S druge pak strane, stanje u testiranju autonomnih vozila na cestama je nešto specifičnije. U takve eksperimente upustile su se tvrtke poput Tesle, Ubera i Google-a koji na američkim cestama nekih saveznih država testiraju svoja softverska rješenja u poluautonomnim ili autonomnim vozilima. U početnoj fazi vozač je za upravljačem vozila, ali vozilo prilikom uključenja autopilota donosi samostalno odluke. Do sada je zabilježeno nekoliko incidenata na cestama. Proizvođač električnih automobila Tesla je prilikom testiranja autopilota zabilježio niz smrtnih slučajeva prilikom udara u barijere na cesti ili direktnih sudara s drugim vozilom. Teslin autopilot, na skali automatizacije u vožnji koju su usuglasili Društvo automobilskih inženjera (engl. *Society of Automotive Engineers* - SAE) i Nacionalna uprava za sigurnost prometa na autocestama (engl. *National Highway Traffic Safety Administration* - NHTSA) iznosi level 3 što predstavlja uvjetnu automatizaciju, odnosno vozilo / softver preuzima proces donošenja odluka i kao takvo je odgovorno za daljnje postupke. Poznat je i slučaj Ubera kada je po prvi puta smrtno stradao pješak. Autonomno vozilo Ubera je na već spomenutoj skali automatizacije bilo level 4 što predstavlja visoku ili potpunu automatizaciju u vožnji. Iako je za upravljačem sjedio vozač za hitne slučajeve, ni vozilo ni vozač nisu registrirali pješakinju što je, osim tragične nesreće, uzrokovalo i Uber-ov prekid u testiranju autonomne tehnologije, barem na kratko vrijeme. Pitanja koja se postavljaju su prvenstveno pitanja odgovornosti, odnosno je li odgovoran proizvođač softvera / tehnologije, tvrtka koja je testirala taj proizvod, druga vozila koja su sudjelovala u nesreći ili pješaci. U svakom slučaju, pravna regulativa tek treba biti formirana sukladno nadolazećoj tehnologiji što će biti dijelom predmet istraživanja ovog rada.

Današnja razina primjene sustava AI upućuje na neophodnost daljnjih znanstvenih istraživanja povezanih s pravnom utemeljenošću sustava AI, istraživanjima nacionalnih propisa vezanih za AI, dostignute razine razvoja i primjene sustava AI te istraživanja povezana s očekivanim pravcima razvoja sustava AI. Očekuje se bitan udio primjene sustava AI u međunarodnom pomorskom prometu. Stoga se smatra potrebnim istražiti trenutnu razinu primjene sustava AI kao i očekivanu razinu njezine primjene u međunarodnom pomorskom prometu. Tako i u tom dijelu valja razviti odgovarajuće modele primjene, a sve s ciljem detaljnog uvida u analizu sigurnosti takvih sustava. U primjeni AI u međunarodnom pomorskom prometu primjećuje se neophodnost detaljnih znanstvenih istraživanja povezanih s filozofskim i sociološkim aspektima primjene sustava AI. Ono što se drži izuzetno važnim i na što se pružio odgovor u ovom doktorskom radu je svakako sigurnost sustava AI.

Polazeći od dosad navedenog determiniran je znanstveni problem istraživanja ove disertacije koji glasi: „Valja identificirati, klasificirati i vrednovati prepoznate čimbenike sigurnosti sustava AI s primjenom u međunarodnom pomorskom prometu. Stoga će se sustavnim pristupom prepoznati, klasificirati i vrednovati prepoznati elementi u uskoj povezivosti između sustava AI i sustava međunarodnog pomorskog prometa."

Temeljem definiranog problema istraživanja određen je i predmet istraživanja na način: „primjenom znanstvenih metoda sustavno i znanstveno utemeljeno istražiti, analizirati, klasificirati, vrednovati i modelirati sigurnost sustava primjene AI u međunarodnom pomorskom prometu. Predmet istraživanja također se može prikazati sa sljedećim bitnim odrednicama:

- Analizirati međunarodne i nacionalne propise koji se odnose na pitanja vezana za AI u međunarodnom pomorskom prometu;
- Analizirati relevantne propise značajnih međunarodnih organizacija u području povezivosti AI i sustava sigurnosti međunarodne plovidbe;
- Definirati mogući smjer razvoja pravnih propisa vezanih za sigurnost korištenja AI u međunarodnom pomorskom prometu;
- Istražiti postojeće stanje korištenja AI u pomorskom prometu s posebnim osvrtom na sigurnost iste;
- Identificirati, klasificirati i vrednovati elemente sigurnosti AI u međunarodnom pomorskom prometu,
- Odrediti ključne dvojbe upotrebe AI u međunarodnom pomorskom prometu;
- Odrediti ključne dvojbe možebitne odgovornosti sustava AI u neželjenim događajima;
- Uspostaviti model sigurnog djelovanja AI u sustavu međunarodne plovidbe;
- Istražiti primjenu i sigurnost sustava AI u autonomnim sustavima u međunarodnom pomorskom prometu;
- Predložiti nove sigurnosne mjere i pravne odredbe sigurnosti sustava AI u međunarodnom pomorskom prometu.

Shodno navedenim odrednicama modeliran je sažeti grafički prikaz sustava sigurnosti AI u međunarodnom pomorskom prometu s pripadajućim podsustavima što je vidljivo na slici 1-1. Elementi svakog od podsustava su obrađeni u daljnjem radu.

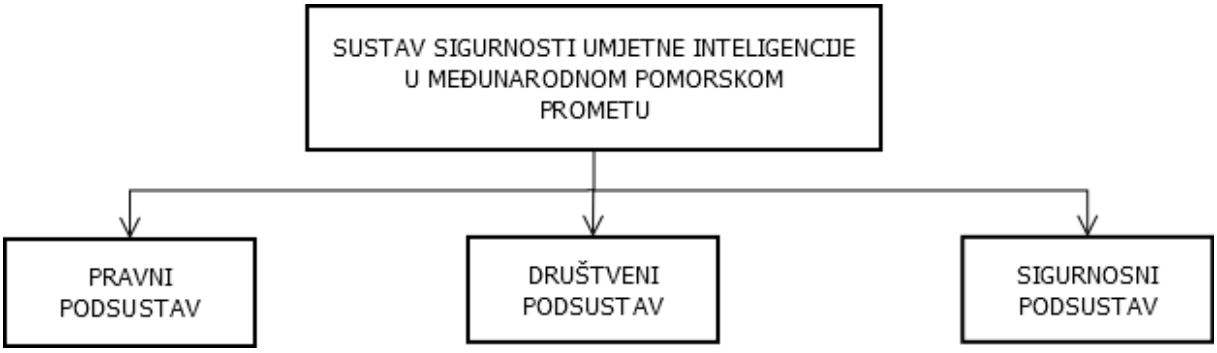

Slika 1-1 Sažeti prikaz sustava sigurnosti AI u međunarodnom pomorskom prometu,

Izvor: autor

Temeljem definiranog problema i predmeta istraživanja određen je i objekt istraživanja u ovoj disertaciji. Objektom istraživanja smatra se sustav AI u uzročno posljedičnoj vezi sa sigurnošću i implikacije koje iz te veze proizlaze.

1.2. SVRHA, CILJEVI I HIPOTEZE ISTRAŽIVANJA

Svrha istraživanja je uz pomoć znanstveno-istraživačkih metoda dokazati kako primjena AI u međunarodnom pomorskom prometu pokazuje različite stupnjeve sigurnosti. Opći ciljevi istraživanja su:

- istražiti pravne temelje povezivosti s AI analizom međunarodnih i nacionalnih pravnih regulativa;
- utvrditi trenutno stanje primjene sustava AI u međunarodnom pomorskom prometu;
- razviti model sustava AI u međunarodnom pomorskom prometu koji će pružiti uvid u sigurnost AI kao sustava vrednovanjem i klasifikacijom razina sigurnosti.

Hipoteze:

H1. Pretpostavlja se nepostojanje unificiranog pravnog okvira za klasifikaciju sustava AI u međunarodnom pomorskom prometu;

H2. Podsustavi sustava AI u određenoj mjeri izloženi humanoidnoj manipulaciji mogu predstavljati dodatnu opasnost u međunarodnom pomorskom prometu;

H3. Primjena sustava AI nužno rezultira etičkim dvojbama;

H4. Ugroženost sigurnosti sustava AI u međunarodnom pomorskom prometu može se vrednovati novim metodama.

1.3. OSTVARENI ZNANSTVENI DOPRINOS

Razina sigurnosti sustava AI u međunarodnom pomorskom prometu smatra se nepoznatom ili nedovoljno poznatom zbog čega može različito utjecati na sigurnost svih procesa u međunarodnom pomorskom prometu. Ostvareni izvorni znanstveni doprinos izražen je u novim mjerama procjene sigurnosti AI, primjenjivim novim polaznim modelima vrednovanja AI i primjenjivim modelom učinkovitog vrednovanja sigurnosti AI u međunarodnom pomorskom prometu. Ovaj rad ima za cilj s više različitih znanstvenih aspekata ponuditi nova aktualna rješenja u području primjene AI u međunarodnom pomorskom prometu i ukazati na doprinos AI struci i široj društvenoj zajednici. Takvim pristupom ostvario se teorijski i aplikativni znanstveni doprinos, ukazalo se na određena ograničenja te sukladno navedenim ograničenjima formirane su smjernice za daljnja istraživanja. Detaljno opisan ostvareni znanstveni doprinos vidljiv je u zaključnom dijelu ove disertacije.

2. PRAVNI OKVIR UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU

U ovom poglavlju analizirana je pravna utemeljenost razvoja sustava AI u povezivosti s međunarodnim pomorskim prometom. Stoga se ovim dijelom rada iznose svi relevantni međunarodni i nacionalni pravni izvori koji se bave aktualnim pitanjem. Uz njih, u ovom dijelu rada analiziraju se i relevantne međunarodne organizacije nadležne za pitanja pomorskog prava.

2.1. MEĐUNARODNA POMORSKA ORGANIZACIJA

Konferencijom UN-a iz 1948. godine osnovan je IMO kao specijalizirana agencija za djelatnost poboljšanja sigurnosti međunarodne plovidbe i sprječavanje onečišćenja mora te se bavi pravnim pitanjima, posebno odgovornošću i naknadom štete.[15] Glavnim ciljem IMO-a smatra se osiguranje zaštićenog i učinkovitog procesa trgovine putem svjetskih mora te održavanje čistoće svjetskih oceana.[16] IMO usmjerava usvajanje konvencija, protokola i pravilnika.[17] IMO, sa sjedištem u Londonu, ima 170 država članica i tri podupiruće države članice. Sastoji se od Skupštine koja se sastaje jednom u dvije godine i najviše je upravljačko tijelo organizacije, te Vijeća koje se sastoji od 40 država izabranih od Skupštine i upravlja organizacijom u periodima kada Skupština ne zasjeda. Kada je u pitanju tehnička organizacija IMO-a, takva vrsta djelovanja je rezervirana za razne odbore i pododbore kao što su Odbor za pomorsku sigurnost (engl. *Maritime Safety Committee* - MSC),[18] Odbor za zaštitu pomorskog okoliša (engl. *Marine Environment Protection Committee* - MEPC), Pododbor za navigaciju, komunikaciju i potragu i spašavanje (engl. *Sub - Committee on Navigation, Communications and Search and Rescue* - NCSR) i sl. U dosadašnjem radu IMO je, između ostalog, predlagala i promovirala usvajanje preko 50 konvencija i protokola te usvajanje više od 1000 kodeksa i preporuka vezanih za pomorsku sigurnost i zaštitu te sprječavanje onečišćenja svjetskih mora i oceana. Od važnijih konvencija koje je IMO usvojila su SOLAS iz 1974.,[19] Međunarodna

[15] Više vidjeti: Luttenberger, A. (2008). Pomorsko upravno pravo, Sveučilište u Rijeci, Pomorski fakultet u Rijeci, str. 15.
[16] Balkin, R. (2006). The International Maritime Organization and Maritime Security. Tul. Mar. LJ, 30, str. 1.
[17] Wieslaw, T. (2012). Origins of ship safety requirements formulated by International Maritime Organization, Procedia Engineering, 45, str. 847-856.
[18] Performance standards and functional requirements for the long-range identification and tracking of ships, adopted by the Maritime Safety Committee of the Organization by resolution MSC.210(81)
[19] Više o tome: https://treaties.un.org/doc/Publication/UNTS/Volume%201184/volume-1184-I-18961-English.pdf; SOLAS je nastala kao odgovor na pomorsku nesreću i tragediju putničkog broda Titanik 1912. godine. Međutim, zbog Prvog svjetskog rata nije stupila na snagu sve do 1929. kada je u Londonu po prvi put

konvencija o teretnim linijama (engl. *International Convention on Load Lines* - CLL) iz 1966.,[20] COLREG) iz 1972.[21], Međunarodna konvencija o pomorskoj satelitskoj organizaciji (engl. *Convention on the International Maritime Satellite Organization* - INMARSAT) iz 1979.,[22] Međunarodna konvencija o standardima izobrazbe, izdavanju svjedodžbi i držanju straže pomoraca (STCW) iz 1984.,[23] kao i mnoge druge.

Veliku pažnju IMO pridaje i pomorskoj zaštiti posebno nakon otmice talijanskog kruzera „Achille Lauro"[24] u listopadu 1985. godine. Jedan od najvažnijih dokumenata s ciljem zaštite od protupravnih djelovanja je i Međunarodni pravilnik o sigurnosnoj zaštiti brodova i lučkih prostora[25] (engl. *International Ship and Port Facility Security Code* – ISPS).[26] Osim zahtjeva za procjenom sigurnosnih rizika lukama, po prvi puta predloženo je postavljanje časnika za sigurnost (engl. *Ship Security Officer* - SSO). IMO je usvojila i neke druge sigurnosne instrumente koji uključuju preporuke za sigurnosne mjere na putničkim brodovima u međunarodnim putovanjima kraćim od 24 sata ili pak sigurnosne mjere za luke kao što su sprječavanje i suzbijanje krijumčarenja drogama, psihotropskih tvari i ostalih supstanci na brodovima u međunarodnom pomorskom prometu. Također, važno je napomenuti i problem piratstva i pljački brodova. To je pitanje prvotno postavljeno početkom 1980-ih što je

---

donesena kao međunarodni dokument. S obzirom da je SOLAS prvi puta usvojena 1914., do danas je bilo nekoliko verzija dokumenta, počevši od 1929. godine, zatim 1948., 1960. te posljednji iz 1974. godine. Upravo posljednja verzija SOLAS-a koja je stupila na snagu 25. svibnja 1980. godine, bila je više puta ažurirana te nadopunjavana amandmanima. Važno je naglasiti kako su 164 države svijeta stranke konvencije koja je stupila na snagu sukladno članku 10. SOLAS-a. Konvencija stupa na snagu 12 mjeseci nakon datuma kada je barem 25 država postalo stranka konvencije pod uvjetom da je ukupna kombinirana trgovačka flota tih država najmanje 50% ukupne bruto tonaže svjetskog trgovačkog prometa. Člankom 9. SOLAS-a utvrđeno je kako države postaju stranke (potpis, ratifikacija, prihvaćanje ili odobrenje).

[20] Više o tome: https://www.imo.org/fr/OurWork/Safety/Pages/LoadLines.aspx; Više o izvorima iz bilj. 15. i vidjeti: Grabovac, I. (1995). Hrvatsko pomorsko pravo i međunarodne konvencije, Književni krug, Split, str. 7.; Bolanča, D., Luttenberger, A. (1995). Some views in the Croatian Maritime Code, Zbornik radova Pravnog fakulteta u Splitu, 32, str. 113-117.

[21] Usvojena 20. listopada 1972., a stupila na snagu 15. srpnja 1977. Više vidjeti: https://www.imo.org/en/About/Conventions/Pages/COLREG.aspx

[22] INMARSAT konvenciju usvojila je IMO 1976. godine kako bi uspostavila i nadzirala satelitske komunikacije za brodarstvo. Više o tome: https://www.imo.org/en/About/Conventions/Pages/Convention-on-the-International-Maritime-Satellite-Organization.aspx

[23] Više o tome: https://www.imo.org/en/OurWork/HumanElement/Pages/STCW-Conv-LINK.aspx

[24] Odnosi se na kaznena djela protiv sigurnosti pomorskog prometa. U Kaznenom zakonu (NN, br. 125/11, 144/12, 56/15, 61/15, 101/17, 118/18, 126/19, 84/21), glava XXII. čl. 223. definira ista u okviru napada na zrakoplov, brod ili nepokretnu platformu. Također, ovisno o biću kaznenog djela čl. 97. Kaznenog zakona, st.1. toč. 5. definira otmicu zrakoplova, broda ili drugih sredstava javnog prijevoza ili prijevoza robe kao terorizam. Vidjeti: Primorac, D. (2007). Kaznena djela protiv sigurnosti pomorskog prometa, Pravni fakultet Sveučilišta u Zagrebu, doktorska disertacija, str. 158.

[25] Mukherjee, P. K. (2007). The ISM Code and the ISPS Code: A critical legal analysis of two SOLAS regimes, WMU Journal of Maritime affairs, 6(2), str. 147-166.

[26] Više o tome: https://www.imo.org/en/OurWork/Security/Pages/SOLAS-XI-2%20ISPS%20Code.aspx

uzrokovalo projekt IMO-a o obrani od piratstva.[27] U tom kontekstu donesene su mjere u okviru regionalne suradnje o borbi protiv piratstva i oružanih pljački u Aziji (engl. *The Regional Co-operation Agreement on Combating Piracy and Armed Robbery against ships in Asia* - ReCAAP) iz 2004.,[28] a to je rezultiralo i osnivanjem centra za dijeljenje informacija vezanih za piratstvo (engl. *Information Sharing Centre* - ISC).[29]

Uz sve navedeno, IMO kao jedan od ključnih ciljeva ima sprječavanje onečišćenja mora i oceana. U cilju sprječavanja navedenog, osim MARPOL[30], koja je naslijedila dotadašnju Međunarodnu konvenciju o sprječavanje onečišćenja mora naftom / uljem iz 1954. (engl. *The International Convention for the prevention of pollution of the sea by oil* - OILPOL), IMO je usvojila i neke druge pravne akte važne u sprječavanju onečišćenja. Jedan od njih je i Međunarodna konvencija o pripravnosti, reakciji i suradnji za slučaj onečišćenja naftom iz 1990. (engl. *The International Convention on Oil Pollution Preparedness, Response and Co-operation* - OPRC) zamišljena kao „alat“ u hitnim i kriznim slučajevima. Vodeći se navedenim ciljevima, IMO pretendira osiguranje održivog pomorskog prometa. S obzirom da je pomorski promet, u kontekstu prijevoza robe i dobara morskim putem, ključni dio svjetske trgovine i globalizacije, IMO je razvila koncept sustava održivog pomorskog prometa gdje je naglasak stavljen na sljedećim točkama: a) sigurnosna kultura i upravljanje okolišem, b) obrazovanje i osposobljavanje pomorskih profesija te pružanje podrške takvim djelatnicima, c) energetska učinkovitost i povezanost brod – luka, d) osiguravanje energije za brodove, e) podrška sustavu pomorskog prometa, f) pomorska sigurnost, g) tehnička i tehnološka suradnja, i) nove

[27] O piratstvu vidjeti: Buhovac, M., Pilić, M., Jukić, S. (2020). Criminal law aspects of piracy at sea according to the UNCLOS with reference to the Croatian legal system, Pomorstvo, 34, 2, str. 282-290.; Amižić Jelovčić, P. (2012). Mjere suzbijanja piratstva u Adenskom zaljevu, Zbornik radova drugog znanstveno stručnog skupa "In memoriam prof. dr. sc. Vjekoslav Šmid" / Buklijaš, Boris (ur.), Pravni fakultet Sveučilišta u Splitu, str. 133-169.

[28] Sporazum je zaključen u studenom 2006. godine. Dvadeset zemalja trenutno su ugovorne stranke, uključujući europske države poput Norveške, Danske, Nizozemske i Velike Britanije, kao i SAD. Cilj sporazuma je poboljšati međunarodnu suradnju u cilju bolje borbe protiv piratstva u Aziji. Ključni element toga je razmjena informacija o sigurnosnim napadima, što je ReCAAP značajno poboljšao. Federal Foreign Office (2021). Combating piracy: Germany intends to accede to the Regional Cooperation Agreement on Combating Piracy and Armed Robbery against Ships in Asia, dostupno na: https://www.auswaertiges-amt.de/en/aussenpolitik/regionaleschwerpunkte/asien/recaap-kabinettsbeschluss/2437518

[29] Centar za razmjenu informacija ReCAAP (ReCAAP ISC) osnovan je u Singapuru 29. studenog 2006. Na 12. sastanku Upravnog vijeća 2018. godine Vijeće je objavilo da je ReCAAP ISC ispunio kriterije da bude Centar izvrsnosti za razmjenu informacija u borbi protiv piratstva i oružane pljačke brodova na moru. Više o tome: https://www.recaap.org/about_ReCAAP-ISC

[30] O MARPOL-u vidjeti i kod: Pavić, D. (2003). Pomorske havarije i osiguranje, Split, str. 105-108.

tehnologije i inovacije, j) mehanizmi za kvalitetno financiranje, određivanje odgovornosti i osiguranja, te k) upravljanje oceanima.[31]

Važnost IMO-a kao organizacije vidljiva je i u posljednjim djelovanjima po pitanju autonomnih pomorskih površinskih brodova pri čemu je prepoznato kako autonomna plovidba predstavlja budućnost pomorske industrije.[32] U tom kontekstu, IMO je odobrila stvaranje regulatornog okvira na temelju vježbi i testiranja MASS-a u kontroliranim uvjetima, a primarno u provođenju sigurnih operacija koje su u skladu sa stavovima organizacije o zaštiti okoliša. Samim time, pretpostavila se i nužnost definiranja MASS operacije. MASS je brod koji u određenom stupnju može djelovati / ploviti neovisno o ljudskoj interakciji. Autonomija takvih brodova podijeljena je u četiri stupnja:

1. brod s automatskim procesima i potpori u donošenju odluka što znači ljudsku posadu na brodu koja nadzire brodske sustave, dok je samo manji dio brodskih funkcija automatiziran,
2. daljinski nadzirani brodovi s ljudskom posadom na brodu što znači da se brodom upravlja s druge lokacije, ali posada je i dalje prisutna na samom plovilu,
3. daljinski nadzirani brodovi bez prisustva ljudske posade i
4. potpuno autonomni brodovi gdje brodski sustavi samostalno donose odluke i pokreću postupke.[33]

Radnje MASS-a će, između ostalog, imati za cilj utvrditi trenutne regulatorne okvire i procijeniti koliko mogu biti primjenjive na brodove s određenim stupnjem autonomije te provesti analizu o samim radnjama uzimajući u obzir ljudski element, tehnologiju i čimbenike funkcioniranja same operacije. Kada je riječ o regulatornim aktima, nekoliko ugovora će se posebno proučavati. To su primjerice neki dijelovi konvencija SOLAS, COLREG, STCW, Konvencije o baždarenju (engl. *Tonnage Convention* - TC)[34] i dogovor o instrumentima za posebne trgovačke putničke brodove (engl. *Special trade passenger ship instruments* – SPACE STP).

Važno je istaknuti i dijelove SOLAS-a koji će se posebno promatrati u kontekstu MASS radnji, a posebno se tiču poglavlja 3, regulacija 17-1 o spašavanju / prihvatu osoba iz mora koja

---

[31] Vidjeti više: IMO and the Sustainable Development Goals, dostupno na: https://www.imo.org/en/MediaCentre/HotTopics/Pages/SustainableDevelopmentGoals.aspx

[32] Laurinen, M. (2016). Remote and Autonomous Ships: The next steps. AAWA: Advanced Autonomous Waterborne Applications, str. 4.

[33] IMO (2018). IMO takes first steps to address autonomous ships, dostupno na: https://www.imo.org/en/MediaCentre/PressBriefings/Pages/08-MSC-99-MASS-scoping.aspx

[34] International Convention on Tonnage Measurement of Ships 1969, dostupna na: https://ec.europa.eu/eurostat/cache/metadata/Annexes/fish_fleet_esms_an1.pdf

uređuje posebne brodske planove za izvlačenje osoba iz vode. Zatim, poglavlje 5, regulacija 19.2 koja govori o potrebitosti brodske navigacijske opreme i sustava, kao i regulacija 10 o teretnim linijama i dostavljanju krucijalnih informacija zapovjedniku broda. Poglavlje 2, regulacija 1/3-4 o hitnim vučnim procedurama i poglavlje 5, regulacija 22 o vidljivosti zapovjednog mosta broda, također će biti pod promatranjem prilikom MASS operacija. AI će na taj način biti djelomično testirana u pomorskom prometu, a iako se radi o kontroliranim uvjetima, sami takav čin je od iznimne važnosti za pomorsko gospodarstvo u globalu, te će fleksibilnost nadležnih tijela biti od iznimne važnosti prilikom prihvaćanja novih tehnologija i AI u međunarodnom pomorskom prometu. Ono što je važno napomenuti je svakako činjenica da IMO nije odredila vremenski okvir u kojem će predstaviti novi ili revidirati postojeći regulatorni okvir za MASS što može potencijalno rezultirati nekim teškoćama.[35] U prvom redu to bi se odnosilo na mogućnost gdje bi MASS djelovao unutar teritorijalnih voda određenih država, a značajno bi kasnila primjena u međunarodnom pomorskom prometu ili mogućnost odgađanja dugoročnih ulaganja tehnologije MASS, odnosno AI.

2.2. MEĐUNARODNA ORGANIZACIJA RADA

Međunarodna organizacija rada (engl. *International Labour Organization* - ILO) je tijelo UN-a nadležno za donošenje standarda o radu na međunarodnoj razini te promoviranju društvene pravde i poštenog rada. Osnovana je 29. listopada 1919. i ima 187 država članica od čega je 186 država članica UN-a. Tripartitno upravljačko tijelo ILO-a sastoji se od predstavnika vlada, poslodavaca i zaposlenika. ILO ima značajnu ulogu u normativnim postupanjima, odnosno o donošenju i usvajanju konvencija, protokola i preporuka. Međutim, ono što ovu organizaciju čini drugačijom od ostalih jest činjenica da nevezano za ratifikaciju konvencija država stranaka usvojene konvencije se smatraju međunarodnim standardom rada, a trenutkom stupanja na snagu rezultiraju i implementacijom u zakonodavne okvire država članica organizacije. U kontekstu usvajanja konvencija ILO-a u vezi s pomorstvom ističu se:

1. Konvencija o zapošljavanju pomoraca, 1920. (br. 9)
2. Konvencija o liječničkom pregledu mlađih osoba (more), 1921. (br. 16)
3. Konvencija o ugovorima o radu pomoraca, 1926. (br. 22)

[35] Antolini, A. (2018). Maritime Issues – Autonomous ships: IMO MSC's steps forward on revising international regulations for including maritime autonomous surface ships (MASS), Japan Transport and Tourism Research Institute, str. 3.

4. Konvencija o repatrijaciji pomoraca, 1926. (br. 23)
5. Konvencija o svjedodžbama o osposobljenosti časnika, 1936. (br. 53)
6. Konvencija o plaćenim odmorima (more), 1936. (br. 54)
7. Konvencija o odgovornosti brodovlasnika (bolest i ozljede pomoraca), 1936. (br. 55)
8. Konvencija o osiguranju pomoraca u slučaju bolesti (more), 1936. (br. 56)
9. Konvencija o radnom vremenu i brojnom stanju posade (more), 1936. (br. 57)
10. Konvencija (izmijenjena) o najmanjoj starosnoj dobi (more), 1936. (br. 58)
11. Konvencija o prehrani i posluživanju hrane na brodovima, 1946. (br. 68)
12. Konvencija o diplomi o osposobljenosti brodskih kuhara, 1946. (br. 69)
13. Konvencija o socijalnom osiguranju pomoraca, 1946. (br. 70)
14. Konvencija o plaćenim odmorima pomoraca, 1946. (br. 72)
15. Konvencija o liječničkom pregledu pomoraca, 1946., (br. 73)
16. Konvencija o svjedodžbama kvalificiranih mornara, 1946. (br. 74)
17. Konvencija o smještaju posade na brodu, 1946. (br. 75)
18. Konvencija o plaćama, radnom vremenu na brodu i brojnom stanju posade (more), 1946. (br. 76)
19. Konvencija o plaćenim odmorima (pomorci), 1949. (br. 91)
20. Konvencija (izmijenjena) o smještaju posade na brodu, 1949. (br. 92)
21. Konvencija (izmijenjena) o plaćama, radnom vremenu na brodu i brojnom stanju posade, 1949. (br. 93)
22. Konvencija (izmijenjena) o plaćama, radnom vremenu na brodu i brojnom stanju posade, 1958. (br. 109)
23. Konvencija o smještaju posade na brodu (dopunske odredbe), 1970. (br. 133)
24. Konvencija o sprječavanju nezgoda (pomorci), 1970. (br. 134)
25. Konvencija o stalnosti zaposlenja, 1976. (br. 145)
26. Konvencija o plaćenim godišnjim odmorima pomoraca, 1976. (br. 146)
27. Konvencija o najnižim standardima u morskom brodarstvu, 1976. (br. 147)
28. Protokol 1996. Konvencije o najnižim standardima u morskom brodarstvu, 1976.
29. Konvencija o socijalnoj skrbi pomoraca, 1987. (br. 163)
30. Konvencija o zaštiti zdravlja i medicinskoj skrbi (pomorci), 1987. (br. 164)
31. Konvencija (izmijenjena) o socijalnom osiguranju pomoraca, 1987. (br. 165)
32. Konvencija (izmijenjena) o repatrijaciji pomoraca, 1987. (br. 166)

33. Konvencija o inspekciji rada pomoraca, 1996. (br. 178)
34. Konvencija o pribavljanju i zapošljavanju pomoraca, 1996. (br. 179)
35. Konvencija o radnom vremenu i brojnom stanju posade na brodovima, 1996. (br. 180).[36]

Naravno, na rad u pomorstvu utječu često uvjeti i propisi zadani i u drugim konvencijama pa tako na pomorstvo i rad unutar tog sustava možemo izdvojiti i sljedeće konvencije usvojene od ILO-a:

1. Konvencija o prisilnom radu, 1930. (br. 29);
2. Konvencija o slobodi udruživanja i zaštiti prava na organiziranje, 1948. (br. 87);
3. Konvencija o organiziranju i kolektivnom pregovaranju, 1949. (br. 98);
4. Konvencija o jednakim plaćama, 1951. (br. 100);
5. Konvencija o oslobođenju od prisilnog rada, 1957. (br. 105);
6. Konvencija o diskriminaciji (zaposlenje i zanimanje), 1958. (br. 111);
7. Konvencija o najnižoj životnoj dobi, 1973. (br. 138);
8. Konvencija o najgorim oblicima rada djece, 1999. (br. 182).[37]

Inicijativa budućnosti rada iz 2016. godine je projekt kojeg je pokrenula ILO s ciljem razumijevanja transformacija koje se događaju u svijetu rada i tako biti u stanju razviti odgovore na te izazove. ILO također procjenjuje utjecaj tehnologije na zaposlenost širom svijeta te je izražena zabrinutost zbog globalnog, ekonomskog i zdravstvenog utjecaja tehnologije kao što su automatizacija, AI, robotika i robotska automatizacija na ljudski rad. Drugi aspekt predstavlja tehnološka kreativnost i velike mogućnosti za globalnu ekonomiju. Smatra se kako je u moderno doba tehnologija promijenila način na koji razmišljamo, dizajniramo i implementiramo sustavna rješenja, no bez sumnje postoje prijetnje ljudskim poslovima. U tom kontekstu, ljudska radna snaga treba napredovati u smislu konkurentne točnosti, brzine, mogućnosti i poštenja. Sukladno navedenom, nužno je identificirati izazove današnjice.

Prema izvješću ILO-a iz 2019.[38] 190 milijuna ljudi je nezaposleno u svijetu, 300 milijuna radnika živi u ekstremnom siromaštvu (manje od 2 američka dolara na dan) te se smatra nužnim stvoriti 344 milijuna novih poslova do 2030. godine. Nadalje, 2,78 milijuna radnika godišnje umre zbog nesreće na poslu ili bolesti razvijene zbog obavljanja tog posla, dok

[36] Čl. 10. Konvencije o radu pomoraca (NN, MU, br. 11/2009). Isto tako i: Pomorski glasnik – Konvencija o radu pomoraca (2006). Ministarstvo mora, turizma, prometa i razvitka, str. 17-18.
[37] Preambula Konvencije o radu pomoraca. Pomorski glasnik, *op.cit.*, str. 12.
[38] Work for a Brighter Future. Report of the Global Commission on the Future of Work, više o tome na: https://www.ilo.org/infostories/en-GB/Campaigns/future-work/global-commission#seizing/challenges

36 % radnika na svijetu radi više od 48 sati tjedno. Također, važno je naglasiti i spolnu nejednakost i ostale diskriminatorne razlike u obavljanju svjetskih poslova, a to je 20 % razlike između plaća muškaraca i žena, svega 53,6 % kućanstava ima pristup internetu, dok je najbogatiji 1 % svjetske populacije primilo 27 % globalnog prihodovnog rasta, a s druge strane najsiromašniji 50 % je primio svega 12 % u periodu od 1980. do 2016.

Prema izvješću ILO-a ulaganje u održivi rad je nužnost, dok će moderne tehnologije te demografske i klimatske promjene imati transformativni utjecaj i eventualnu narušavajuću ulogu u svjetskoj ekonomiji i na burzi rada. Sasvim je sigurno kako će utjecaj AI i ostalih novih tehnologija ostaviti traga i transformirati svjetsku pomorsku industriju u cijelosti, a posebno tehnologije i međunarodni pomorski promet. Takav utjecaj može se očitovati kroz prizmu straha od gubitka poslova i nejednakosti u učinkovitosti zbog već jasnih i provjerenih premisa o produktivnosti određenih tehnologija u odnosu na čovjeka što treba posebno znanstveno istražiti u djelovanju same ILO.[39]

2.3. KONVENCIJA UJEDINJENIH NARODA O PRAVU MORA

Konvencija Ujedinjenih naroda o pravu mora (engl. *United Nations Convention on Law at Sea* - UNCLOS)[40] usvojena je 1982. godine na trećoj konferenciji UN-a o pravu mora. Iako je stupila na snagu tek 16. studenog 1994. ratifikacijom šezdesete države[41], UNCLOS ima za cilj jasno utvrditi određene pravne aspekte na moru i mirno rješavanje sporova glede pomorskih pitanja.[42] Za potrebe UNCLOS-a, 1996. godine osnovan je i Međunarodni sud za pravo mora (engl. *International Tribunal for the Law of the Sea*)[43] sa sjedištem u gradu Hamburgu u SR Njemačkoj[44]. UNCLOS-u je pristupilo 167 država te EU, dok je 24 države svijeta još uvijek

[39] Ernst, E., Merola, R., Samaan, D. (2018). The economics of artificial intelligence: Implications for the future of work, ILO, str. 1-35.
[40] Dostupna na: https://www.un.org/depts/los/convention_agreements/texts/unclos/unclos_e.pdf
[41] Gvajana, Južna Amerika.
[42] Rowan, P. J. (2005). UNCLOS and Sovereignty in the South China Sea, Asian Survey, Vol. XLV, No. 3.
[43] Vidjeti više: Barić Punda, V., Rudolf, D. (2007). Rješavanje sporova u međunarodnom pravu mora - dokumenti, sudska praksa, mišljenja znanstvenika, komentari, Pravni fakultet u Splitu, str. 9.
[44] Međunarodni sud za pravo mora osnovan je radi rješavanja sporova i zahtjeva vezanih uz UNCLOS i predmeta za koje je nadležan po drugim ugovorima. Ima 21 nezavisnog suca koji se biraju na razdoblje od devet godina. Zanimljivo je napomenuti kako je jedan od sudaca i potpredsjednik suda bio Hrvat, profesor zagrebačkog Pravnog fakulteta Budislav Vukas. Dostupno na: https://www.enciklopedija.hr/natuknica.aspx?id=58647

nisu ratificirale[45], a 18 država nisu potpisale[46]. Za izdvojiti je svakako i odnos SAD-a prema ratifikaciji UNCLOS-a. Naime, SAD prepoznaje UNCLOS kao dio običajnog međunarodnog prava, ali je američki Senat još uvijek odbija ratificirati. Mišljenja o takvom pristupu američke vanjske politike su podijeljena. *Steven Groves*[47] u svom radu *The Law of the Sea: Costs of the U.S. Accession to UNCLOS* tvrdi da pristupanjem SAD-a UNCLOS-u može generirati značajne financijske izdatke prilikom plaćanja tantijema zbog proizvodnje ugljikovodika, a zauzvrat ne bi imala nikakve benefite. Također, smatra se kako bi pristupanje UNCLOS-u omogućilo značajan broj tužbi zbog mogućeg onečišćenja morskih luka i morskog okoliša.[48] Obzirom da američka tradicija i pravna regulativa omogućuje domicilnim korporacijama i državljanima pravnu potporu u pristupanju, istraživanju i iskorištavanju morskog dna odnosno zone, postoje i zagovarači američkog pristupa UNCLOS-u koji tvrde da će SAD-u biti zabranjeno istraživanje i eksploatacija zone.[49] S druge pak strane, stručnjaci poput *Andrew Chubba*[50] i *Jamesa Kraska*[51] tvrde kako pristupanje SAD-a UNCLOS-u može pridonijeti stvaranju određene političke prednosti na međunarodnoj razini u odnosu na Kinu, dok Kina drži kako će UNCLOS pomoći u diplomatskim rješavanjima sporova u regionalnim područjima.[52] Također, smatraju kako bi to omogućilo i značajniju pravnu sigurnost u kontekstu pristupanja resursima morskog dna[53] u plitkim područjima.[54]

Zajedno sa završnim odredbama UNCLOS sadrži sedamnaest poglavlja i devet dodataka. Osim uvodnog dijela gdje se definiraju važni izrazi te njihova upotreba, UNCLOS uređuje teritorijalno more i vanjski pojas, tjesnace koji služe međunarodnoj plovidbi, arhipelaške države, isključivi gospodarski pojas, epikontinentalni pojas, otvoreno more, režim otoka,

---

[45] Afganistan, Butan, Burundi, Kambodža, Srednjoafrička Republika, Čad, Kolumbija, Republika Kongo, Dominikanska Republika, El Salvador, Etiopija, Iran, DNR Koreja, Liberija, Libija, Lihtenštajn, Malavi, Niger, Ruanda, Svazi, Švicarska, Tajland, Ujedinjeni Arapski Emirati, Sjedinjene Američke Države.

[46] Andora, Azerbajdžan, Ekvador, Eritreja, Izrael, Južni Sudan, Kazahstan, Kirgistan, Peru, San Marino, Sirija, Tadžikistan, Istočni Timor, Turska, Turkmenistan, Uzbekistan, Vatikan, Venezuela.

[47] Nekadašnji član konzervativnog istraživačkog i edukacijskog instituta *„The Herritage Foundation“*.

[48] Groves, S. (2012). The Law of the Sea: Costs of U.S. Accession to UNCLOS, dostupno na: https://www.heritage.org/testimony/the-law-the-sea-costs-us-accession-unclos

[49] Zona je dno mora ili oceana s pripadajućim podzemljem koje nije unutar granica određene nacionalne nadležnosti. U tom kontekstu, obavljanje djelatnosti u području zone znači istraživanje i iskorištavanje prirodnih bogatstva tog područja. Dio VI. čl. 76. UNCLOS-a

[50] Odjel za politiku, filozofiju i religiju Sveučilišta u Lancasteru UK.

[51] Profesor za međunarodno pomorsko pravo u Stockton centru pri *U.S. Naval War* sveučilištu.

[52] Hong, N. (2012). UNCLOS and Ocean Dispute Settlement, Law and politics in South China Sea, Routledge, New York, str. 2.

[53] Engl. *the Continental shelf* - Zona morskog dna oko velike kopnene površine gdje je more relativno plitko u odnosu na otvoreni ocean. Prilog I. Čl. 1. UNCLOS-a

[54] Prows, P. (2006). Tough love: The dramatic birth and looming demise of UNCLOS property law (and what is to be done about it). Tex. Int'l LJ, 42, str. 241.

zatvorena ili poluzatvorena mora, pravo pristupa neobalnih država moru i slobodu tranzita, zonu, zaštitu i očuvanje morskog okoliša, znanstveno istraživanje mora, razvoj i prijenos morske tehnologije, rješavanje sporova te opće odredbe.

Već na prvi pogled jasno je kako se UNCLOS u svom sadržaju ne dotiče i ne regulira AI pa ni s aspekta međunarodnog pomorskog prometa. U stvarnosti nije bilo ni za očekivati da će konvencija koja potječe iz 1982. uređivati prava i primjenu tehnologije koja je tek sada u početnim fazama razvoja. Međutim, s razvojem AI u skorijoj budućnosti i primjenom u međunarodnom pomorskom prometu, navedena tehnologija morat će se pravno regulirati, a doneseni zaključci glede iste implementirati u najvažnije pomorsko pravne akte. Ono što je donekle primjenjivo na pravnu regulaciju sustava AI u međunarodnom pomorskom prometu je XIV. poglavlje UNCLOS-a, odnosno dio o razvoju i prijenosu morske tehnologije. Prema UNCLOS-u, predviđeno je da države surađuju u procesima promicanja razvoja tehnologije i prijenosa iste, naravno, u skladu sa svojim mogućnostima. Izravna ili neizravna djelovanja država u tom kontekstu za cilj imaju akviziciju i širenje znanja, olakšavanje pristupa informacija drugima, razvoj same tehnologije i infrastrukture primjenjujući stečena znanja, usavršavanje i edukaciju ljudskog potencijala, ali i međunarodnu suradnju. Ujedno, osnivanje nacionalnih i regionalnih centara za znanstvena istraživanja mora i morske tehnologije predstavljaju važan dio ovog dijela UNCLOS-a, a u skladu s već navedenim procesima širenja znanja, istraživanja mora i tehnologija i ostalih elemenata definirane su i zadaće osnovanih centara. Takve zadaće podrazumijevaju proučavanje gospodarstva, organiziranje znanstvenih konferencija i skupova, prikupljanje i analiziranje podataka o moru i morskoj tehnologiji te razne znanstvene publikacije i međunarodnu suradnju. Iz svega navedenog vidljivo je da se razvoj AI i njezina primjena u pomorskom gospodarstvu, a ponajviše u međunarodnom pomorskom prometu, može smatrati elementarnim dijelom odredbi sadržanih u poglavlju razvoja i prijenosa morske tehnologije UNCLOS-a.

2.4. MEĐUNARODNA KONVENCIJA O ZAŠTITI LJUDSKIH ŽIVOTA NA MORU

Najvažniji pravni akt u području osiguranja sigurnosti plovidbe odnosno zaštite ljudskih života na moru predstavlja konvencija SOLAS.

Glavni cilj SOLAS-a je utvrditi najmanje vrijednosne standarde za izgradnju, opremanje i djelovanje brodova u aspektu sigurnosti.[55] Sukladno tome, tekst SOLAS-a je sadržan unutar 14 poglavlja od kojih su neki važni i za regulaciju AI. Iako se u konvenciji ne navodi termin AI, vidljiv je utjecaj koji takva tehnologija može imati u donošenju formalnog pravnog okvira primjene iste, ali i temelja koji je u tekstu SOLAS-a predviđen za potencijalnu upotrebu AI u pomorstvu. Izuzev općenitih odredbi sadržanih u prvom poglavlju konvencije, SOLAS uređuje još i izgradnju i stabilnost broda, strojeva i električnih instalacija, protupožarnu zaštitu, detekciju i gašenje vatre, opremu i uređaje važne za spašavanje ljudskih života, radio komunikacija, sigurnost navigacije, prijevoz tereta, osiguranje tereta i prijevoz opasne robe. SOLAS uređuje i osnovne zahtjeve u pogledu brodova na nuklearni pogon pozivajući se na kodeks o zaštiti trgovačkih brodova na nuklearni pogon,[56] ali i ostale slične elemente zaštite poput uspostavljanja sustava za upravljanje sigurnošću od strane brodovlasnika i sigurnosnih mjera za brze brodove.

Također, SOLAS-om su regulirane i posebne mjere za poboljšanje pomorske sigurnosti i dodatne sigurnosne mjere za prijevoznike rasutog tereta. Ono što predstavlja okosnicu upotrebe AI u okvirima SOLAS-a je nekoliko izdvojenih poglavlja i potpoglavlje. Prema dijelu sadržanom u općenitim odredbama, SOLAS zahtijeva provođenje inspekcija, anketa i certificiranja samog broda i njegove posebne opreme. Prema 1. poglavlju, regulaciji br. 9, konvencija zahtijeva provjeru / anketu o provjeri radio instalacija brodova s teretom te predviđa inicijalnu provjeru prije nego brod prvi put zaplovi, obnavljanje provjere unutar sljedećih pet godina te povremenu provjeru tri mjeseca prije ili poslije od godišnjice dobivanja certifikata. Stjecanje takvih certifikata zahtijevat će sasvim sigurno ažuriranje navedenih regulacija o anketiranju zbog specifičnosti potencijalne tehnologije u okviru AI koja može predstavljati značajan tehnološki i tehnički napredak u načinu komunikacije i nadzoru tijeka informacija komunikacijskim kanalima kojima može upravljati AI. Slične su i odredbe u regulaciji br. 10 istog poglavlja koje se odnose na strukturu, strojeve i opremu teretnih brodova kao neke od

[55] Više o tome na: http://www.imo.org/en/About/Conventions/ListOfConventions/Pages/International-Convention-for-the-Safety-of-Life-at-Sea-(SOLAS),-1974.aspx

[56] Više o tome u: Nuclear-Ship Code Code of safety for nuclear merchant ships - Res. A.491(XII)

ključnih elemenata vezanih za sigurnost plovidbe. Kroz prizmu sigurnosti plovidbe u svim vremenskim uvjetima ključno je definirati dodatne zahtjeve koje je potrebno ispuniti ili osigurati uvjete za ispunjavanje tih zahtjeva, a to je određeno u poglavlju 2-1, dijelu E SOLAS-a. Sve navedene regulacije u tom dijelu konvencije odnose se na sigurnosne provjere i djelovanja kao i prisutnost ljudske posade u tim procedurama. Sam izraz ekvivalentnosti prisutnosti ljudske posade u ovom dijelu konvencije daje do znanja da procedure i mjere poduzete mogu navoditi na potencijalni nedostatak iste. U tom kontekstu, za pretpostaviti je kako će informacijski sustavi povezani s odgovarajućim brodskim sustavima imati važan utjecaj u etabliranju sustava AI u brodske i informacijske procese. Iako se ovo poglavlje SOLAS-a najviše odnosi na teretne brodove, regulacija br. 54 u obzir uzima i putničke brodove prilikom vrednovanja procesa određenih konvencijom od strane Administracije,[57] a u svrhu osiguravanja sigurnosti plovidbe.

U poglavlju 2-1 dijelu E SOLAS-a regulacije se odnose na preventivne mjere od požara,[58] zaštitu od poplave, nadzoru pogonskih strojeva sa zapovjednog mosta,[59] komunikacije,[60] sustava upozorenja i sigurnosnih sustava.[61] Standardizacija sigurnosnih procedura i određivanja nužne opreme na brodovima kao i funkcioniranja iste je važan aspekt SOLAS-a. Ako se u obzir uzme bilo kakav trenutni i/ili budući utjecaj AI na sigurnosne brodske sustave ključno je izdvojiti 4. poglavlje konvencije koje se odnosi na radio komunikaciju. Važnost takvih sustava je vidljiva i po klasifikaciji unutar same konvencije, odnosno tri dijela koja uređuju opće elemente, provedbene dužnosti nadležnih državnih tijela i zahtjeva na koje sami brod / brodari moraju odgovoriti. Iako je u sadržaju ovog poglavlja konvencije određena primjena navedenih regulacija za teretne brodove s nosivosti od najmanje 300 BT iznimno se može primijeniti i na brodove manje teretne nosivosti.[62] Imajući na umu važnost komunikacije na moru, a pogotovo

[57] Administracijom se smatra vlada države pod čijom zastavom brod plovi.
[58] Regulacija br. 47 govori o detekciji i alarmiranju u ranoj fazi nastanka vatre navodeći kao važan dotok zraka u bojlerima, čišćenje zračnih pojaseva pogonskih strojeva, te motorima s unutarnjim izgaranjem od 2.250 kW ili cilindrima većim od 300mm koji moraju biti opremljeni s prikladnim detektorima odnosno monitorima kontrole temperature ležaja motora i sličnim uređajima.
[59] Regulacija br. 49 navodi kako u svakim plovidbenim uvjetima kontrola propelera mora biti u potpunosti moguća sa zapovjednog mosta s tim da se takva udaljena kontrola provodi s jednim uređajem za svaki nezavisni propeler i po potrebi uređaj mora biti opremljen sustavom protiv preopterećenja pogonskih strojeva i ostalih mogućnosti za prevenciju neželjenih posljedica kao što je i hitna obustava rada pogonskih strojeva.
[60] Regulacija br. 50 navodi nužnost govorne komunikacije između strojarske kontrolne sobe, zapovjednog mosta i časnikove sobe.
[61] Regulacija br. 52, između ostalog, određuje nužnost postojanja sigurnosnih sustava u slučajevima ozbiljnih poteškoća u radu strojeva i bojlera te pokretanje automatiziranog gašenja sustava.
[62] Callís Oliver, L. M. (2018). SOLAS Convention: Safety on Board, Bachelor's thesis, Universitat Politècnica de Catalunya

u slučajevima opasnosti, SOLAS navodi kako je nužna funkcionalnost komunikacijske opreme u primanju upozorenja o opasnosti u odnosu obala – brod, kao i u slanju upozorenja u odnosu brod – brod. Usklađena komunikacija u slučajevima potrage i spašavanja kao i primanje i slanje informacija usko vezanih za pomorsku sigurnost su okosnica ovog dijela konvencije. Složenost primjene AI u pomorskim komunikacijama razvidna je i iz Svjetskog pomorskog sustava za pogibelj i sigurnost (engl. *Global Maritime Distress and Safety System* - GMDSS) i njegovih podsustava npr. selektivno digitalno pozivanje (engl. *Digital selective calling* - DSC) koristeći razna frekventna područja poput srednje frekvencije (engl. *Medium frequency* - MF), visoke frekvencije (engl. *High frequency* - HF) i vrlo visoke frekvencije (engl. *Very high frequency* - VHF). Još se mogu navesti podsustavi poput navigacijskog telexa (engl. *Navigation Telex* - NAVTEX), radio plutače za određivanje mjesta pogibelji (engl. *Emergency Position-Indicating Radio Beacon* - EPIRB), AIS i nužne radio opreme u različitim morskim zonama.[63]

Važan je i dio određen u 4. poglavlju, dio C, regulacija br. 16 koji definira potrebitost prisutnosti kvalificiranog osoblja za radijsku komunikaciju u slučaju pogibelji i održavanja sigurnosti, što jasno govori o prisutnosti ljudske posade na brodovima. U nastavku rada će se svakako osvrnuti i na taj dio u pogledu plovidbe autonomnih plovila te mogućom prilagodbom posebnih regulacija na primijenjenu AI u međunarodnom pomorskom prometu. Sigurnost plovidbe će sasvim sigurno predstavljati glavnu okosnicu u primjeni AI u međunarodnom pomorskom prometu. Važnost sigurnosti plovidbe je prepoznata upravo kroz SOLAS u pogledu plovidbe plovila svih veličina i namjena, ali i ostalih elemenata sigurnosti plovidbe kao što su navigacijska upozorenja, meteorološka upozorenja, hidrografske djelatnosti i usluga, usluga praćenja prometa plovila, procedura sigurne navigacije te izbjegavanja opasnih situacija i slično. U kontekstu sigurnog prolaza i kreiranja sigurne plovne rute regulacije 4 i 5 navode različite navigacijske i meteorološke sustave upozorenja koje su detaljno opisane kroz smjernice o svjetskom navigacijskom sustavu upozorenja usvojene od IMO i Svjetske hidrografske organizacije (engl. *International Hydrografic Organization* - IHO).[64] Zahvaljujući

[63] Morska zona A1 – prostor unutar radio-telefonskog dosega barem jedne VHF obalne stanice sa stalnim dostupnim DSC upozorenjima. Morska zona A2 – isključujući A1, unutar dosega barem jedne MF obalne stanice sa stalno dostupnim DSC upozorenjima. Morska zona A3, isključujući A1 i A2, unutar dosega INMARSAT satelita. Morska zona A4 označava prostor van svih navedenih zona.

[64] Guidance on the IMO/IHO World-Wide Navigational Warning Service adopted by the Organization by Resolution A.706(17), više o tome na: http://www.imo.org/en/KnowledgeCentre/IndexofIMOResolutions/Assembly/Documents/A.706(17).pdf

tehnološkom dosegu, sustavi navigacijskih upozorenja, elektroničke navigacije,[65] a između ostalog i brodske komunikacijske opreme, mogu u kratkom vremenu odaslati i primiti informacije važne za sigurnost plovidbe. Navigacijska upozorenja se u plovidbi postižu na različite načine: VHF, HF i MF veze, EGC,[66] NAVTEX i INMARSAT itd. Navigacijska upozorenja mogu biti raznolikog tipa, počevši od plutača za upozorenje, promjena o morskim dubinama, postojanje opasnih podrtina ili prepreka za navigaciju, plutajućih opasnosti, vremenskih upozorenja i slično. Značajnu ulogu u osiguranju sigurne plovidbe imaju hidrografske organizacije. Najvažnijim proizvodima hidrografske djelatnosti[67] smatraju se pomorske karte. One sadržavaju orijentacijske i sigurnosne elemente nužne za plovidbu. Svi ostali podaci koji su važni za sigurnu plovidbu, a ne mogu biti sadržani na pomorskim kartama, su dio ostalih navigacijskih publikacija, odnosno priručnika za plovidbu. Doprinos sigurnosti plovidbe predstavljaju i usluge praćenja prometa plovila - VTS. One doprinose zaštiti života na moru te osiguranju sigurne i učinkovite navigacije, pa stoga SOLAS u svojim odredbama iziskuje obveznu upotrebu VTS-a u teritorijalnim morima obalnih država.[68] U tekstu SOLAS-a navodi se kako su države stranke konvencije za svoje nacionalne brodove odgovorne za osiguranje fizičkog prisustva kvalitetne ljudske posade na brodu.[69] U kontekstu potpune autonomne plovidbe, takav tekst SOLAS-a je potrebno mijenjati jer sadrži oprečne odredbe u odnosu na praktičnu primjenu budući da zahtijeva osiguranje fizičkog prisustva posade. SOLAS također uređuje potrebe provjere valjanosti i učinkovitosti sustava nužnih za sigurnu plovidbu kao što je ECDIS, referirajući se na preporuke standarda performansi ECDIS-a.[70] [71]

U kontekstu primjene AI na međunarodni pomorski promet, mogla bi se tumačiti konvencija koja definira neophodnost za sustavima praćenja i prepoznavanja brodova na velikoj udaljenosti (engl. *Long Range Identification and Tracking* - LRIT).[72] LRIT predstavlja sustav temeljem preporuka MSC-a te je isti službeno uvršten i obvezan na brodovima koji su izgrađeni od 31. prosinca 2008. pa nadalje. Razlog tomu je da države stranke SOLAS-a mogu surađivati

[65] Weintrit, A., Wawruch, R., Specht, C., Gucma, L., Pietrzykowski, Z. (2007). Polish approach to e-navigation concept. TransNav, International Journal on Marine Navigation and Safety od Sea Transportation, 1(3).
[66] Engl. *Enhanced Group Call* je dio GMDSS sustava za prijenos informacija važnih za pomorsku sigurnost (engl. *Maritime Safety Information* - MSI) u područjima gdje *Navtex* nije dostupan.
[67] Više vidjeti: Poglavlje 5., regulacija 9 SOLAS-a
[68] Poglavlje 5. regulacija 12 SOLAS-a
[69] Poglavlje 5. regulacija 14 točka 1. SOLAS-a
[70] Recommendation on Performance Standards for Electronic Chart Display and Information Systems (ECDIS) (resolution A.817(19)), as amended by resolutions MSC.64(67), annex 5 i MSC.86(70), annex 4.
[71] Weintrit, A. (2015). ECDIS issues related to the implementation of the carriage requirements in SOLAS Convention. Archives of Transport System Telematics, 8(1), str. 35-40.
[72] Poglavlje 5. regulacija 19-1 SOLAS-a

u pogledu dijeljenja informacija o pomorskoj sigurnosti i brodovima koji plove plovnim područjima obalnih država. Od značajne važnosti za pomorski promet, barem u kontekstu istraživanja pomorskih nesreća, svrstava se uređaj za zapis podataka (engl. *Voyage Data Recorder* - VDR). Ako usporedimo pomorski promet sa zračnim, korištenje VDR uređaja može se usporediti s crnom kutijom u zrakoplovima što samo po sebi govori o važnosti takvog uređaja. SOLAS prema tome određuje nužnost postojanja VDR na putničkim brodovima sagrađenim nakon srpnja 2002. godine, ro – ro putničkim brodovima,[73] ostalim putničkim brodovima izgrađenim najkasnije do siječnja 2004. godine, te brodovima (osim putničkih) s nosivosti od 3000 BT i više, a sagrađenih 1. srpnja 2002. i kasnije.[74] Uz to, za pružanje pomoći pri istraživanju pomorskih nesreća može biti od koristi i pojednostavljeni uređaj za zapis podataka (engl. *Simplified Voyage Data Recorder* – S-VDR) koji je također uređen SOLAS-om i ima svoju primjenu u posebnoj specifikaciji brodova.

U djelomičnoj povezanosti s upotrebom AI u pomorskom prometu nužno je analizirati i primjenu Međunarodnog signalnog kodeksa (engl. *International Code of Signals* - ICS) prema kojem su brodske radio instalacije implementirane u brodsku strukturu. Poglavlje 5. u svojoj 33. regulaciji SOLAS-a predviđa obveze i procedure u pogibeljnim situacijama. Važnost ove regulacije u kontekstu upotrebe AI je što predviđa ljudsku posadu kao čimbenika u ispunjavanju takvih uvjeta i zadaća. Naglasak u budućnosti svakako treba biti stavljen i na ulogu AI u pogibeljnim situacijama, odnosno kako će potpuno autonomni sustav / plovilo moći ispuniti potrebne zadaće u spašavanju drugog plovila i posade na tom plovilu. Također, u pogledu sigurne navigacije i izbjegavanja opasnih situacija, zapovjednik broda sa svojim časnicima mora isplanirati rutu odnosno plan puta kojim će ploviti. Uzimajući u obzir sve relevantne podatke, a oslanjajući se pritom na vlastita znanja i brodske sustave u kreiranju sigurnog puta, nužno je ispuniti četiri ključna elementa:[75] a) uzeti u obzir sve važne brodske sustave za planiranje rute, b) osigurati dovoljno morskog prostora za siguran prolaz brodova na istoj ruti, c) predvidjeti sve moguće navigacijske ugroze uključujući i vremenske nepogode kao i d) uzeti u obzir mjere za zaštitu morskog i ostalog okoliša te izbjeći sva daljnja postupanja koja bi mogla naštetiti okolišu. SOLAS predviđa i uređuje i elemente važne, između ostalog, i za sigurnost

[73] Tzv. *roll on – roll off* brodovi s ugrađenim unutarnjim rampama dizajnirani za prijevoz kotrljajućeg tereta.
[74] Poglavlje 5. regulacija 20 SOLAS-a
[75] Poglavlje 5. regulacija 34 toč. 2. SOLAS-a

plovidbe i transporta.[76] Isto tako, jasno je kako će neke od tih odredbi morati biti ažurirane i implementirane u skladu s AI koja polako ali sigurno doživljava svoj razvoj i primjenu u međunarodnom pomorskom prometu. Tako primjerice sustavi kao što su GMDSS, DSC, AIS, VTS, ECDIS, LRIT, VDR, e-navigacija i ostali će prikupljati podatke i prosljeđivati ih centralnom informacijskom brodskom sustavu i/ili nadzornom centru AI s možebitnom postavkom samostalnog odlučivanja. Iz tog razloga može se smatrati nužnim predvidjeti i takve elemente u SOLAS-u kako bi se osigurao što kvalitetniji prijelaz prema upotrebi modernih tehnologija kao što je AI.

2.5. MEĐUNARODNA KONVENCIJA O SPRJEČAVANJU ONEČIŠĆENJA S BRODOVA

Međunarodna konvencija kojom se uređuje namjerno ili slučajno onečišćenje s brodova potpisana je 1973. u Londonu, a MARPOL je stupila na snagu u listopadu 1983. Nastala je kao napor IMO-a u cilju smanjenja onečišćenja svjetskih oceana i mora te danas obuhvaća 158 država potpisnica koje čine 99 % svjetske pomorske trgovine. MARPOL je podijeljena u nekoliko dodataka konvencije ovisno o vrsti mogućih zagađivača. U tom kontekstu, MARPOL uređuje sprječavanje zagađenja mora uljima (prilog I.),[77] sprječavanje onečišćenja mora kemikalijama u rasutom teretu (prilog II.),[78] sprječavanje onečišćenja mora štetnim opasnim tvarima u posebnim pakovanjima, kontejnerima ili prijevoznim tankovima (prilog III.),[79] sprječavanje onečišćenja mora fekalijama s brodova (prilog IV.),[80] sprječavanje onečišćenja mora smećem i otpadom s brodova (prilog V.),[81] te sprječavanje onečišćenja atmosfere – emisijom dima i plinova s broda (prilog VI.).[82]

Važno je izdvojiti nekoliko ključnih definicija poput definicije ispuštanja gdje se ispuštanje određuje kao svako istjecanje, odlaganje, prosipanje, istjecanje kroz pukotinu, izbacivanje ili

[76] Hesse, H., Charalambous, N. L. (2004). New security measures for the international shipping community. WMU Journal of Maritime Affairs, 3(2), str. 123-138.
[77] MARPOL 73/78 Annex I on Prevention of pollution by oil and oily water koja je stupila na snagu 2. listopada 1983.
[78] MARPOL 73/78 Annex II on Control of pollution by noxious liquid substances in bulk koja je stupila na snagu 6. travnja 1987.
[79] MARPOL 73/78 Annex III on Prevention of pollution by harmfull substances carried by sea in packaged form koja je stupila na snagu 1. srpnja 1992.
[80] MARPOL 73/78 Annex IV on Pollution by sewage from ships koja je stupila na snagu 27. rujna 2003.
[81] MARPOL 73/78 Annex V on Pollution by garbage from ships koja je stupila na snagu 31. prosinca 1988.
[82] MARPOL 73/78 Annex VI on Prevention o fair pollution from ships koja je stupila na snagu 19. svibnja 2005.

pražnjenje broda.[83] Na sličan način se uređuje i definicija ulja koja je važna za prilog 1, kojom ulje obuhvaća u bilo kojem obliku, tj. sirova nafta, naftne prerađevine destilatnog[84] i rezidualnog[85] tipa, talog, otpadno ulje, maziva i zauljene vode, a ne obuhvaća neke petrokemijske proizvode poput umjetnog gnojiva.[86] Važno je spomenuti i postojeće zabrane ispuštanja u posebnim područjima gdje je moguća velika ugroženost mora i morskog okoliša, a to su : a) Sredozemno more, b) Crno more, c) Baltičko more, d) Crveno more, e) područje Zaljeva, f) područje Adenskog zaljeva, g) područje Antarktika, h) Sjeverozapadne europske vode, i) područje Omana u Arapskom moru.[87] MARPOL uređuje kada je i gdje dopušteno ispuštanje određenih manjih količina, u ovom slučaju ulja. To iziskuje da brod nije unutar zaštićenog područja, potrebitost pozicije broda koja je veća od 50 nautičkih milja (NM) od najbliže obale, nužnost broda u plovidbi ili da trenutna brzina plovila, a samim time i da ispuštanja ne prelaze 30 litara po NM.[88]

U kontekstu primjene AI u budućnosti je svakako važan i nužni brodski sustav za nadzor ispuštanja ulja što može predstavljati izvrsnu podlogu za testiranje takvih sustava u donošenju samostalnih odluka prilikom ispuštanja / ne ispuštanja ulja. Na taj način može se ostvariti još kvalitetniji sustav u odlučivanju prilikom upravljanja otpadom, uljima i sličnim brodskim zagađivačima mora, ali na način da je otporan od udaljenog uplitanja u proces donošenja odluka, naravno, pod uvjetom da je kvalitetno izrađen i višestruko testiran.

2.6. MEĐUNARODNA KONVENCIJA O STANDARDIMA IZOBRAZBE, IZDAVANJU SVJEDODŽBI I DRŽANJU STRAŽE POMORACA

Najvažnija konvencija o standardima izobrazbe pomoraca odnosno STCW usvojena je na konferenciji IMO-a u Londonu 1978. godine, a stupila je na snagu 1984. STCW uređuje minimalna znanja i vještine pomoraca koja su nužna za obavljanje pomorskih poslova i djelatnosti, a da su prihvaćena na međunarodnoj razini i ne zahtijevaju dodatne sustave provjere poput nostrifikacija stečenih diploma.[89] Standardi, mjere i procedure koje STCW propisuje i poteškoće koje bi mogle predstavljati za države nečlanice konvencije su, između ostalog, jedan

[83] Čl. 2. st. 3. toč. a) MARPOL-a
[84] Dizel gorivo, benini, lož ulje, kerozin.
[85] Teško dizel gorivo, mazut.
[86] Pravilo 1. MARPOL-a
[87] Pravilo 34.B MARPOL-a
[88] Pravilo 34.C MARPOL-a
[89] Marušić, L. (2010). STCW konvencija i bolonjski proces, Metodički ogledi, 17 1-2, str. 13-22.

od razloga zašto je STCW sveopće prihvaćena i do danas ima 164 države stranke. STCW je u svojoj povijesti imala dvije važnije izmjene i dopune s amandmanima. Prve izmjene su se zbile u srpnju 1995. godine i bile su opširne. Izmjene[90] su uključivale prijedlog razvoja nove STCW koja bi sadržavala sve tehničke elemente, a koje su usko vezane za istu. Isto tako, najvažnije dopune STCW sadržavale su mjere poboljšanja u kontekstu državne lučke kontrole, pravovremenu komunikaciju prema IMO za međusobni nadzor i konstantnost u primjeni konvencijskih standarda te poboljšanja u području procedura za certificiranje, nadgledanje izobrazbe i procjeni iste.[91] Osim navedenih izmjena, važni su i amandmani s konferencije u gradu na Filipinima iz 2010., a koja je rezultirala izmjenama STCW po pitanju sati za odmor za pomorce, novo stupnjevanje svjedodžbi za pomorce kako na palubi tako i u strojarnici, ažurirane zahtjeve u izobrazbi, obvezne sigurnosne edukacije, dodatne medicinske standarde i točan volumenski limit dozvoljenog alkohola u krvi i dahu osoba na dužnosti.[92] Novi elementi izobrazbe pomoraca su uključivali i edukaciju iz područja primjene novih tehnologija na brodu što pretpostavlja znanje specijalne opreme, a pogotovo kada je riječ o časničkim pozicijama na palubi i u strojarnici, odnosno specijalnih znanja poput časnika za radio vezu i sl., dok su neke promjene u STCW pretpostavljale i izrade zasebnih dokumenata poput STCW – F, odnosno standarde za posadu ribarice duže od 24 metra koja je stupila na snagu u rujnu 2012.[93]

U pogledu uvođenja još modernijih sustava na brodove poput sustava AI, smatra se da će promjene i u smislu STCW-a biti nužne te u skladu s primijenjenim tehnologijama što će se odnositi i na upravljanje brodom i rukovođenje. U tom kontekstu zahtjevi iz STCW odnose se na odlomak A-II/2-6. Unaprjeđenja će se temeljiti na vještinama / karakteristikama potrebnim za učinkovito upravljanje i rukovođenje brodom odnosno odgovornosti za držanje plovidbene straže. Ključni elementi upravljanja i rukovođenja brodom odnose se na upoznavanje s komandnim mostom, standardni manevri, utjecaj struja i vjetra, efekt plitkih voda, sidrenje i privezivanje na plutaču, planiranje i izvršavanje plovidbenog puta i sl.[94]

---

[90] Uz izmjene STCW-a donesen je i STCW pravilnik (engl. *STCW Code*) s tehničkim pojedinostima iz određenih poglavlja. On se sastoji od dijela A koji ima karakter obveznog dijela i dijela B kao preporukom. Dio A sadržava minimalne standarde koje članice trebaju ispuniti. Milošević-Pujo, B. (2006). Pomorsko pravo (odabrane teme po STCW konvenciji), Sveučilište u Dubrovniku, str. 106.
[91] Navedene izmjene su postale obvezne u veljači 2002. *Ibid.*
[92] Amandmani iz Manile primjenjuju se od siječnja 2012. godine. *Ibid.*
[93] *Ibid.*
[94] *Ibid.*

2.7. MEĐUNARODNA KONVENCIJA O REGULACIJAMA ZA PREVENCIJU SUDARA NA MORU

Konvencija o međunarodnim pravilima o izbjegavanju sudara na moru odnosno COLREG je objavljena od IMO-a 1972. godine, a stupila na snagu u srpnju 1977. Temeljni joj je cilj spriječiti sudare na moru između dva i/ili više plovila. COLREG-om je obuhvaćena 41 regulacija podijeljena u 6 glavnih sekcija koje se tiču općenitih odredbi, upravljanja i plovidbe, izuzećima i potvrdama o suglasnosti s odredbama konvencije. Uz to, za COLREG se vežu i četiri priloga koja sadrže tehničke zahtjeve glede svijetla, svjetlosnih oblika i njihovog pozicioniranja, uređajima za zvučne signale, dodatne signale za ribarice koje plove ili djeluju u međusobnoj blizini i međunarodne signale za pogibelj. COLREG je ratificiralo 155 država stranaka koje čine približno 99 % svjetske trgovačke flote.[95]

U svjetskim zakonodavstvima primjena COLREG-a ima različite oblike, odnosno svaka država je primjenjuje kroz svoje za to namijenjene zakonodavne okvire. Tako primjerice, primjena COLREG-a u SAD vrši se kroz upute, pravilnike i protokole američke obalne straže pri odjelu za domovinsku sigurnost (engl. *US Coast Guard of US Department of Homeland Security*).[96] U Kanadi tu ulogu ima „*Transport Canada*“, a u Ujedinjenom Kraljevstvu (dalje u tekstu: UK) Agencija za pomorstvo i obalnu stražu (engl. *Maritime and Coastguard Agency* - MCA). U Republici Hrvatskoj (RH) ta uloga pripada Ministarstvu mora, prometa i infrastrukture (MMPI) koje je u skladu s odredbama Pomorskog zakonika (PZ)[97] donijelo Pravilnik o sigurnosti pomorske plovidbe u unutarnjim morskim vodama i teritorijalnom moru RH te načinu obavljanja nadzora i upravljanja pomorskim prometom.[98]

U dijelu općenitih odredbi COLREG-a ističu se odredbe o odgovornosti zapovjednika, vlasnika i posade broda o usklađenosti s konvencijom te specifičnim definicijama. Također, ističe se potrebitost prisutnosti same ljudske posade na brodu koja svojim vizualnim i slušnim percepcijama mora učiniti sve nužno da spriječi sudar na moru.[99] [100] Mnoge odredbe utvrđene

---

[95] Ivanišević D., Gundić, A., Mohović, Đ. (2018). COLREG in STCW Convention, Pomorski zbornik, Vol. 54 No.1, str. 24.

[96] Vidjeti: Amižić Jelovčić, P., Primorac, Ž., Mandić, N. (2017). Obalna straža Republike Hrvatske, Pravni fakultet Sveučilišta u Splitu, str. 98-101.

[97] Pomorski zakonik (NN, br. 181/04, 76/07, 146/08, 61/11, 56/13, 26/15, 17/19), a prema čl. 64. st. 1. toč. 3. Zakona o izmjenama i dopunama Pomorskog zakonika (NN br. 61/11)

[98] Pravilnik o sigurnosti pomorske plovidbe u unutarnjim morskim vodama i teritorijalnom moru Republike Hrvatske te načinu i uvjetima obavljanja nadzora i upravljanja pomorskim prometom (NN, br. 79/13, 40/14, 57/15)

[99] COLREG Part B, Section 1, Rule 5.

[100] Stitt, I. P. A. (2003). The use of VHF in collision avoidance at sea, The Journal of Navigation, 56(1), str. 67-78.

u konvenciji tiču se prava prolaza u uskim kanalima i ostalim prolazima, učinkom pomorskog prometnog razmaka i preporučenim shemama,[101] pretjecanjima, prava prednosti na moru i ostalim. Osim na moru, pomorski promet se odvija i unutarnjim vodama RH. U RH plovni put se definira kao morski pojas dovoljno dubok i širok za sigurnu plovidbu plovnog objekta.[102] Pri tome se u obzir uzima i niski plovni vodostaj koji se prema podacima dostupnim na službenoj web stranici MMPI računa u razdoblju od 25 godina s 95 % trajnosti, te visoki plovni vodostaj određen na temelju razdoblja od 25 godina i 1 % trajnosti.[103] U RH mrežu unutarnjih plovnih puteva čine rijeke Dunava (137,5 km), Save (446 km), Drave (198,6 km) i Kupe (6 km).[104] Osim toga, granice teritorijalnog mora su već dobro poznate, a čini je pojas od 12 NM od najbliže točke polazne crte, nakon čega je vanjski pojas od također 12 NM, isključivi gospodarski pojas od 200 NM od najbliže točke polazne crte te epikontinentalni pojas i otvoreno more.[105]

U kontekstu upotrebe AI u međunarodnom pomorskom prometu usklađenim s COLREG-om, nužno je testirati i ispuniti regulative o sprječavanju sudara koja se sastoji od 38 međunarodno prihvaćenih pravila, a što je usklađeno i sa SOLAS-om. Samim time, važno je istaknuti i najčešće vrste nastanka pomorskih nesreća te je utvrđeno kako 30 % nastane sudarom, 15 % kvarom glavnog motora, 14 % odvezivanjem s nekog sidrišta ili luke, 11 % nasukavanjem, 8 % zbog magle.[106] Prema dostupnim podacima o vrstama nesreća na moru, mogućnost upotrebe modernih tehnologija, a nadasve AI u pomorskom prometu, može rezultirati smanjenjem navedenih tipova nesreća posebice ako su uzrokovani ljudskim djelovanjem.

[101] Sheme iz studije Međunarodnog udruženja instituta za navigaciju (eng. *International Association of Institutes of Navigation* - IAIN) iz 1981.
[102] Čl. 5. st. 28. PZ-a
[103] Dostupno na: https://mmpi.gov.hr/more-86/unutarnja-plovidba-rijecni-promet/plovni-putovi/8646
[104] *Ibid.*
[105] Čl. 18. PZ-a
[106] Ivanišević D. *et.al., op.cit.,* str. 25.

2.8. MEĐUNARODNI PRAVILNIK O SIGURNOSNOJ ZAŠTITI BRODOVA I LUČKIH PROSTORA

Međunarodni pravilnik o sigurnosnoj zaštiti brodova i lučkih prostora - ISPS stupio je na snagu u srpnju 2004. godine u sklopu izmjena i dopuna SOLAS-a, odnosno poglavlja XI-2. Glavni ciljevi ISPS-a su: a) stvoriti djelotvorni okvir za suradnju nadležnih tijela na lokalnoj, nacionalnoj i međunarodnoj razini u svrhu identifikacije i procjene mogućeg sigurnosnog rizika za pomorske brodove i luke te prevencijsko djelovanje; b) utvrditi ulogu i odgovornost nadležnih tijela u pružanju pomorske sigurnosti u lukama i na brodovima; c) osigurati pravovremenu razmjenu ključnih informacija po pitanju sigurnosti; d) pružiti metodologiju za procjenu sigurnosti pomorskih brodova i luka, bilo da je riječ o sigurnosnim planovima i procedurama, izgradnji broda i sl., i e) osigurati primjenu ključnih sigurnosnih mjera u lukama i na brodovima.[107] Ispunjavanje navedenih ciljeva iziskuje, tada po prvi puta, kreiranje posebnih radnih mjesta i edukaciju takvih djelatnika. Naime, ISPS-om se imenuju časnici poput sigurnosnih časnika za luke (engl. *Port facility security officer* - PFSO),[108] brodski sigurnosni časnici (engl. *Ship security officer* - SSO)[109] i korporativni sigurnosni časnici (engl. *Company security officer* - CSO).[110] CSO usko surađuje sa SSO po sigurnosnim pitanjima, odnosno CSO će obraditi podatke iz sigurnosne procjene broda (engl. *Ship Security Assessment* - SSA) i savjetovati o potencijalnim ugrozama. Isto tako, CSO utvrđuje prikladno održavanje sigurnosnog plana broda (engl. *Ship Security Plan* - SSP) koje provodi SSO. S druge pak strane, SSO je u potpunosti odgovoran za sigurnost plovila i provođenje redovitog nadzora u svrhu poduzimanja pravovremenih sigurnosnih mjera kao i edukaciju i trening ostatka posade u kontekstu spremnosti na određene sigurnosne ugroze.[111] Naravno, odgovornost glede pripadajuće uloge SSO odobrava zapovjednik broda prema odredbama u poglavlju XI-2/8 SOLAS-a. Procedura komunikacije na brodu ili u odnosu brod – obala je uvijek predmet detaljnih obrazlaganja. Prema odredbama SOLAS-a regulacija XI-2/6 ističe se nužnost posjedovanja prikladne komunikacijske opreme prema kojoj brod može komunicirati s brodarskim poduzećem putem satelita koristeći alarmne sustave. Nadalje, napredni alarmni sustavi na brodu mogu odaslati signal koji će sadržavati ključne informacije kao što su lokacija

[107] Dio A točka 1.2. ISPS-a
[108] Dio A točka 3. st. 8. ISPS-a
[109] Dio A točka 3. st. 6. ISPS-a
[110] Dio A točka 3. st. 7. ISPS-a
[111] Dio A točka 7., 8. i 9. ISPS-a. Poglavlje XI-2 SOLAS-a

broda, identifikacijske informacije i kratki opis sigurnosne ugroze. Te informacije putem naprednih alarmnih sustava može odaslati i sam zapovjednik broda bez da upozori posadu broda.

ISPS je dokument koji je podijeljen u dva dijela sadržavajući minimalne nužne zahtjeve. Prvi dio ISPS-a je obligatoran, dok se drugi odnosi na upute za primjenu te samim time se može također smatrati dijelom i obveznim. Primjena ISPS-a se odnosi na brodove u međunarodnom putovanju[112] i luke za prihvat takvih brodova. Kada je riječ o implementaciji ISPS-a u zakonodavne okvire, države s područja Europe su djelovale u skladu s Uredbom (EZ) br. 725/2004 Europskog parlamenta i Vijeća o jačanju sigurnosne zaštite brodova i luka iz 31. ožujka 2004. godine.[113] Sukladno toj uredbi, ali i Direktivi 2005/65/EZ Europskog parlamenta i Vijeća o jačanju sigurnosne zaštite luka iz 26. listopada 2005.,[114] RH je donijela Zakon o sigurnosnoj zaštiti pomorskih brodova i luka koji je na snazi od 16. studenog 2017.[115] koji je zamijenio istoimeni zakon iz 2009. godine. S druge strane, UK je navedenu uredbu implementiralo kroz Zakon o sigurnosti brodskih i lučkih uprava (engl. T*he Ship and Port Facility (Security) Regulations 2004*).[116] SAD su to isto napravile na način da su uskladile svoje zakonodavstvo[117] sa SOLAS-om i ISPS-om.

U kontekstu primjene AI ovakve odredbe ISPS-a, a samim time i SOLAS-a, mogu biti predmet izmjena i dopuna kako bi se pravilnik i konvencija uskladili s novim tehnološkim dostignućima posebice na području korištenja potpunih autonomnih sustava / plovila u pomorskom i međunarodnom pomorskom prometu.

---

[112] To su putnički brodovi, teretni brodovi (bruto tonaža od 300 pa na više) i odobalne prijenosne jedinice za bušotine.

[113] Uredba (EZ) br. 725/2004 Europskog parlamenta i Vijeća od 31. ožujka 2004. godine o jačanju sigurnosne zaštite brodova i luka, OJ L 129, str. 120-250.

[114] Direktiva 2005/65/EZ Europskog parlamenta i Vijeća od 26. listopada 2005. o jačanju sigurnosne zaštite luka, OJ L 310, str. 72-83.

[115] Zakon o sigurnosnoj zaštiti pomorskih brodova i luka (NN, br. 108/17, 30/21)

[116] UK Statutory Instrument, S. I. 1495 of 2004, dostupno na: http://www.legislation.gov.uk/uksi/2004/1495/contents/made

[117] Maritime Transportation Security Act of 2002 i Code of Federal Regulations (101 do 107). Više o tome na: https://uslaw.link/citation/us-law/public/107/295

2.9. UREDBA (EU) 2016/679 EUROPSKOG PARLAMENTA I VIJEĆA OD 27. TRAVNJA 2016. O ZAŠTITI POJEDINACA U VEZI S OBRADOM OSOBNIH PODATAKA I O SLOBODNOM KRETANJU TAKVIH PODATAKA TE O STAVLJANJU IZVAN SNAGE DIREKTIVE 95/46/EZ

Opća uredba o zaštiti podataka odnosno Uredba (EU) 2016/679 Europskog parlamenta i Vijeća od 27. travnja 2016. o zaštiti pojedinaca u vezi s obradom osobnih podataka i o slobodnom kretanju takvih podataka te o stavljanju izvan snage Direktive 95/46/EZ (engl. *General Dana Protection Regulation* - GDPR)[118] stupila je na snagu 25. svibnja 2018. godine. GDPR regulira zaštitu osobnih podataka i privatnost s ciljem omogućavanja osobama nadzor i kontrolu nad vlastitim podacima.[119] Iako je GDPR primjenom vezana za područje država članica EU, regulira i odredbe u smislu izvoza korisničkih podataka u države koje nisu članice EU. Samim time EU želi postići slobodno kretanje osobnih podataka, ali s elementom zaštite istih kao i temeljnih prava i sloboda osoba. Jasno je kako se GDPR prvenstveno odnosi na poduzeća, institucije i slične organizacije koje te podatke i prikupljaju te se zlouporaba prikupljenih podataka, kao što je prodavanje istih, želi smanjiti na najmanju moguću mjeru, ako ne i potpuno spriječiti. Stoga GDPR definira osobne podatke kao podatke koji se „*odnose na pojedinca čiji je identitet utvrđen ili se može utvrditi izravno ili neizravno uz pomoć identifikatora kao što su ime, identifikacijski broj, podatci o lokaciji, mrežni identifikatori ili određeni fizički, fiziološki, genetski, mentalni, ekonomski, kulturni ili socijalni identitet*."[120] GDPR u svojim odredbama uređuje područje primjene,[121] odgovornost[122] i transparentnost[123], pravne osnove za obradu,[124] privolu ispitanika,[125] imenovanje službenika za zaštitu osobnih podataka,[126] pseudonimizaciju,[127] načine povrede podataka,[128] sankcije[129] i dr.

Prema tome, GDPR će igrati važnu ulogu u regulaciji same AI, posebice iz razloga što GDPR uređuje obradu podataka, a AI prikuplja podatke. Članak 22. GDPR-a uređuje

---

[118] Uredba (EU) 2016/679 Europskog parlamenta i Vijeća od 27. travnja 2016. o zaštiti pojedinaca u vezi s obradom osobnih podataka i o slobodnom kretanju takvih podataka te o stavljanju izvan snage Direktive 95/46/EZ, OJ L 119, str. 1-88.
[119] Više o GDPR vidjeti kod: Boban, M. (2018). Zaštita osobnih podataka i nova EU uredba o zaštiti podataka, Bilten Hrvatskog društva za medicinsku informatiku, str. 26-40.
[120] Čl. 4. st. 1. GDPR
[121] Čl. 2. i 3. GDPR
[122] Poglavlje VIII. GDPR
[123] Čl. 12. GDPR
[124] Čl. 6. GDPR
[125] Točka 32. Preambule GDPR
[126] Čl. 37. GDPR
[127] Čl. 4. GDPR
[128] Čl. 4. st. 12. GDPR
[129] Čl. 84. GDPR

automatizirano pojedinačno donošenje odluka i izradu profila što iz perspektive razvoja AI i tehnološke složenosti može predstavljati svojevrsne barijere u razvoju i implementaciji, ali i podložnosti krivom tumačenju same odredbe. Naime, ovaj članak primjenjuje se samo kada se odluka temelji na isključivo automatiziranoj obradi podataka ispitanika, odnosno ta odluka se može ne odnositi na ispitanika ako ista proizvodi pravne učinke ili na sličan način utječe na njega. Mnogi se slažu kako to predstavlja visoki prag za pokretanje ograničenja, a pogotovo ako se u obzir uzmu striktne odredbe iz članka 15. GDPR-a koje se odnose na postojanje automatiziranog odlučivanja i profiliranje u pogledu pružanja značajnih informacija o logici obrade podataka i značajnosti, odnosno predviđenih posljedica takve obrade za ispitanika. Kada se takve odredbe stave u kontekst, može se zaključiti kako se u slučaju neprimjenjivanja članka 22. GDPR-a neće primjenjivati ni članak 15. iste uredbe. Značajne informacije o uključenoj logici u vezi s člankom 22. GDPR-a treba shvatiti kao informacije vezane za korištenje algoritamske metode, a ne kao objašnjenje utemeljenja automatizirane odluke. Na primjer, ako je zahtjev za kredit odbijen, članak 22. može zahtijevati od voditelja obrade podataka da dostavi informacije o ulaznim podacima koji se odnose na pojedinca i općim parametrima postavljenim u algoritmu koji je omogućio automatsku odluku. No članak 22. ne bi zahtijevao objašnjenje vezano za izvorni kod ili kako i zašto je ta konkretna odluka donesena. S druge strane, o algoritamskoj transparentnosti, odgovornosti i objašnjivosti sustava AI raspravlja se izvan GDPR-a te su potrebna daljnja istraživanja i razmišljanja o tim pitanjima, posebice jer se mogu „umiješati“ u područje intelektualnog vlasništva i prava nad izvornim kodom koje omogućava proces automatiziranog odlučivanja. Unatoč "tijesnoj" primjenjivosti članka 22., GDPR uključuje pregršt odredbi koje se primjenjuju na sva profiliranja i automatizirano donošenje odluka (poput onih koje se odnose na pravo pristupa i pravo na prigovor).

Konačno, u mjeri u kojoj profiliranje i automatizirano odlučivanje uključuju obradu osobnih podataka, primjenjuju se sve odredbe GDPR-a, uključujući primjerice načela poštene i transparentne obrade. Primjena ove odredbe u pomorstvu i međunarodnom pomorskom prometu u kontekstu aplikacije AI može imati posebne učinke, poglavito u zapošljavanju pomoraca, obradi i slanju podataka poduzećima trećih državama, brodarstvu, sustavima za pohranu i obradu podataka (bilo na brodu ili na obali), ali i nadležnim tijelima u lukama i državnim lučkim kontrolama.

2.10. UMJETNA INTELIGENCIJA ZA EUROPU

Europska komisija (dalje u tekstu: Komisija) je u travnju 2018. godine donijela Komunikaciju prema Europskom Parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija koju je nazvala Umjetna inteligencija za Europu (Komunikacija– Umjetna inteligencija za Europu).[130] S ciljem približavanja pojma AI široj populaciji, Komisija navodi razne podsustave sustava AI kao stvarnost koju trenutno živimo, bilo da je riječ o pametnim virtualnim asistentima s raznim zadaćama, autonomnim prijevoznim sredstvima, podsustavima temeljenih na strojnom učenju (engl. *Machine Learning* - ML) koje predlažu restorane, pjesme i sl. U određenom broju pokušaja da se definira AI, svoj doprinos je dala i Komisija u Komunikaciji koja tvrdi da se „*izrazom umjetna inteligencija označavaju sustavi koji pokazuju inteligentno ponašanje tako što analiziraju svoje okruženje i izvode radnje – uz određeni stupanj autonomije – radi postizanja određenih ciljeva*."[131] Može se reći da je jedan od ciljeva korištenja AI da nam olakša život i da pomogne u rješavanju određenih gorućih problema današnjice poput liječenja kroničnih bolesti i smanjenja smrtnosti od prometnih nesreća,[132] ali i borbe protiv klimatskih promjena, te sprječavanju ugroza u području kibernetičke sigurnosti. Samim time, Komisija za primjer izdvaja neke države članice EU poput Danske gdje se AI koristi u praksi hitnih službi pri dijagnosticiranju srčanog zastoja i drugih sličnih stanja prema zvuku glasa pozivatelja.[133] U Austriji AI radiolozima pomaže u otkrivanju tumora i sličnih stanja usporedbom postojećih snimaka s medicinskom bazom podataka. AI se koristi i na europskim farmama prilikom praćenja kretanja, temperature i unosa hrane životinjama. Tako proizvođači postaju konkurentniji na tržištu što predstavlja jedan od ciljeva EU: „vratiti tvornice u Europu".[134]

---

[130] Komunikacija Komisije Europskom parlamentu, Europskom vijeću, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Umjetna inteligencija za Europu, COM/2018/237 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX%3A52018DC0237

[131] *Ibid*, str. 1.

[132] Procjenjuje se da oko 90 % prometnih nezgoda nastaje zbog ljudske pogreške. Vidjeti: Izvješće Komisije „Spašavanje života: poboljšanje sigurnosti automobila u EU-u", COM(2016) 0787 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX%3A52016DC0787

[133] Kruse, C. R., Lindskow, T., Ibrahim, R. M., Thomsen, M. V., Bell, B. (2020). Artificial intelligence in Danish healthcare, Ugeskrift for Laeger, 182(6), str. 6.

[134] Purdy, M., Daugherty, P. (2016). Why AI is the future of growth, Accenture. Gospodarski učinak automatizacije intelektualnog rada, robota i autonomnih vozila mogao bi do 2025. iznositi od 6,5 bilijuna eura do 12 bilijuna eura na godišnjoj razini (uključujući poboljšanje produktivnosti i višu kvalitetu života sve starijeg stanovništva). Manyika, J., Chai, M., Bughin, J., Dobbs, R., Bisson, P., Marrs, A. (2013). Disruptive technologies: Advances that will transform life, business, and the global economy, McKinsey Global Institute

Po tom pitanju su se udružile i snage država članice EU te su se 10. travnja 2018. obvezale na zajedničku suradnju na polju razvoja AI. Točnije, 24 države članice EU zajedno s Norveškom su se obvezale na suradnju,[135] s tim da su se Rumunjska, Cipar i Grčka priključile u svibnju 2018., a RH u srpnju iste godine. Komisija ističe tri ključna elementa u integraciji AI na općenitom planu EU, a koji se odnose na osiguranje:

- konkurentne Europe u području razvoja i implementacije AI te značajnim financijskim ulaganjima kako bi poduzeća, a posebno mala i srednja (engl. *Small and medium enterprises* - SME), koje čine 99 % poduzeća u EU, mogle uvesti AI u svoje poslovanje.
- ne zaostajanja u procesu digitalne transformacije. Digitalna transformacija je nužna i to za većinu poslova u EU pa će AI neka radna mjesta ugasiti, a druga stvoriti.
- stvaranja tehnologije AI koja će se temeljiti na etičkim i moralnim vrijednostima. Značajan korak u izgradnji povjerenja je upravo GDPR. Pomoću novih tehnologija neke primjene AI mogu otvoriti nova etička i pravna pitanja, poput odgovornosti ili moguće pristranosti u procesu donošenja odluka.[136]

Stav Komisije je stoga da EU mora osigurati prikladan zakonodavni okvir za razvoj i implementaciju AI koja promiče inovacije i poštuje vrijednosti i temeljna prava EU te etička načela. Na taj način EU može dati konkretan doprinos u razvoju i primjeni AI za građane i društvo. EU može iskoristiti prednosti AI samo ako je ona svima dostupna i pristupačna. Komisija će svim potencijalnim korisnicima, a posebno SME, olakšati pristup modernim tehnologijama i potaknuti ih da ih testiraju, isprobaju i implementiraju. Takav stav Komisije trebao bi rezultirati razvojem platforme „AI na zahtjev“. Na taj način bi se omogućilo da korisnici imaju pristup značajnim resursima AI kao što su znanje, spremanje i dohvaćanje podataka, računalnu snagu (oblak i slične platforme), alati i algoritmi. To bi pretpostavljalo i upotrebu postojećih mreža digitalno-inovacijskih centara koji su svojim radom usmjereni prema AI[137]. To će svakako iziskivati i dodatne financijske investicije i nadležnih europskih

[135] Austrija, Belgija, Bugarska, Češka, Danska, Estonija, Finska, Francuska, Irska, Italija, Latvija, Litva, Luksemburg, Mađarska, Malta, Nizozemska, Njemačka, Poljska, Portugal, Slovačka, Slovenija, Španjolska, Švedska, UK.

[136] Više o implementaciji AI u sudnice vidjeti: Simonite, T. (2019). Algorithms Should’ve Made Courts More Fair. What Went Wrong?, WIRED, dostupno na: https://www.wired.com/story/algorithms-shouldve-made-courts-more-fair-what-went-wrong/

[137] Mreža obuhvaća više od 400 centara. Vidjeti više: Komunikacija Komisije Europskom Parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Digitalizacija europske industrije - Iskorištavanje svih prednosti jedinstvenog digitalnog tržišta, COM/2016/180 final i popis centara na povezinici: https://s3platform.jrc.ec.europa.eu/digital-innovation-hubs-

tijela i država članica EU. Samim time, kroz višegodišnji financijski okvir EU u razdoblju od 2021. - 2027. naglašavaju se ulaganja u sljedećim područjima:

- unapređivanje paneuropske mreže centara izvrsnosti za AI,
- istraživanja i inovacije u područjima poput objašnjive AI[138] i nenadziranog ML-a, energetike i učinkovitosti podataka,[139]
- dodatni digitalno-inovacijski centri, vodeća svjetska postrojenja za testiranje i eksperimentiranje u područjima poput prometa, zdravstva, poljoprivredno-prehrambene industrije i proizvodnje, uz potporu eksperimentalnih regulatornih okruženja,
- potpora uvođenju AI u organizacije u svim sektorima,
- testiranje mogućnosti zajedničke nabave inovacija za primjenu i razvoj AI i
- centar za potporu dijeljenju podataka koji će biti usko povezan s platformom za AI na zahtjev u pogledu olakšavanja razvoja aplikacija za poduzeća i javni sektor.[140]

Isto tako, jasno je da je razvoj AI uvjetovan dostupnošću velike količine podataka, gdje AI koristeći tehnike strojnog učenja prepoznaje obrasce u postojećim podacima i zatim to[141] znanje primjenjuje na nove podatke. Samim time, veća količina podataka čini podatke preciznima, a preciznošću podataka lakše se otkrivaju odnosi među podacima što samo po sebi nudi nove mogućnosti. Uz to, Komisija je u svojoj Komunikaciji – Umjetna inteligencija za Europu predstavila skup inicijativa za rast europskog podatkovnog prostora,[142] a to uključuje ažuriranje Direktive 2003/98/EZ o ponovnoj uporabi informacija javnog sektora[143] (promet, meteorološke, gospodarske i financijske podatke), izradu smjernica o dijeljenju podataka privatnog sektora u gospodarstvu, ažuriranje Preporuke o pristupu i čuvanju znanstvenih

---

tool?p_p_id=digitalinnovationhub_WAR_digitalinnovationhubportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-1&p_p_col_count=1&_digitalinnovationhub_WAR_digitalinnovationhubportlet_cur=2&formDate=1521718574008&freeSearch=&evolStages=3

[138] Sustavi AI moraju se razvijati transparentno. To će rezultirati smanjenim rizikom u pogledu pristranosti i grešaka, a ljudi će moći razumjeti djelovanje AI i steći povjerenje.

[139] To će osigurati korištenje manje količine podataka za procese učenja AI.

[140] Komunikacija Komisije, Moderan proračun Unije koja štiti, osnažuje i brani, Višegodišnji financijski okvir za razdoblje 2021.–2027., COM(2018) 321 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX%3A52018DC0321

[141] Često je cilj aktivnosti detektirati obrasce / uzorke. U tom pogledu koriste se algoritmi za čitanje koji zapravo „rudare“ tekst i automatski generiraju određeno znanje. Komisija je u okviru postupka modernizacije pravila EU-a o autorskom pravu uvela izuzeće za rudarenje teksta i podataka.

[142] Više o tome A European Strategy for Data, dostupno na: https://ec.europa.eu/digital-single-market/en/policies/building-european-data-economy

[143] Prvo je donesena Direktiva 2013/37/EU Europskog parlamenta i Vijeća od 26. lipnja 2013. o izmjeni Direktive 2003/98/EZ o ponovnoj uporabi informacija javnog sektora, OJ L 175 koja više nije na snazi. Trenutno na snazi je Direktiva (EU) 2019/1024 Europskog parlamenta i Vijeća od 20. lipnja 2019. o otvorenim podatcima i ponovnoj uporabi informacija javnog sektora, OJ L 172, str. 56-83.

podataka[144] te Komunikaciju o digitalnoj transformaciji zdravstva i skrbi.[145] Naravno, u svim nadolazećim promjenama Komisija ističe i socioekonomske promjene navodeći kako se pojam i način rada mijenjao kroz povijest i takve promjene su često bile uvjetovane razvitkom novih tehnologija. Nekada su velike promjene uzrokovale otkriće električne energije i interneta, dok će današnje gospodarstvo i sustav rada iz temelja biti promijenjeni zahvaljujući AI, automatizaciji i robotici.[146] Najveća primjena se očekuje u repetitivnim poslovima gdje bi tehnologija mogla značajno uštedjeti vrijeme, ali i izvršavati zadaće koje mogu biti opasne po čovjeka. Također, AI služi i u medicini prilikom dijagnosticiranja, operacija i sl. Velika je primjena AI i u području transporta i prometa gdje se stalno nude nova rješenja i poboljšavaju ljudske sposobnosti. Razvoj AI utjecat će na stvaranje novih radnih mjesta od kojih je neke teško, pa čak i nemoguće u ovom trenutku predvidjeti, dok će neka druga radna mjesta biti ukinuta. Iako je u ovoj fazi teško točno izmjeriti utjecaj AI na radna mjesta, jasno je da je potrebno djelovati. Socioekonomsko promišljanje korištenja AI mora naglasiti ulogu obrazovanja i osposobljavanja, posebice onog kadra kojem prijeti ostanak bez posla. Samim time, Komisija ističe tri izazova na koje će se ubrzo morati pronaći odgovor. Prvenstveno, društvo se mora pripremiti na nadolazeću tehnologiju što iziskuje razvitak elementarnih računalnih vještina. To po nekima podrazumijeva i razvijanje onih vještina koje AI još uvijek ne može zamijeniti poput kreativnog ili kritičkog razmišljanja. Naravno, u trenutnoj fazi razvoja AI doista ne može ispuniti te uvjete, ali iluzorno je očekivati da neće moći ni u budućnosti. Nadalje, EU mora zaštiti one najosjetljivije čija je socijalna egzistencija ugrožena zbog primjene AI.[147] Treći izazov predstavlja i osposobljavanje velikog broja stručnjaka za AI. Iz tog razloga Komisija je pokrenula i plan osposobljavanja budućih djelatnika, a sve u skladu sa zahtjevima tržišta, tzv. „Novi program za Europu“.[148] Takav plan uključuje nove oblike

[144] Preporuka Komisije (EU) 2018/790 od 25. travnja 2018. o pristupu znanstvenim informacijama i njihovu čuvanju, C/2018/2375, dostupno na: https://eur-lex.europa.eu/legal-content/HR/ALL/?uri=CELEX%3A32018H0790

[145] Komunikacija Komisije Europskom Parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija o omogućivanju digitalne transformacije na jedinstvenom digitalnom tržištu u području zdravstva i skrbi: osnaživanje građana i stvaranje zdravijeg društva, COM/2018/233 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:52018DC0233

[146] Više o tome vidjeti u: Report with recommendations to the Commission on Civil Law Rules on Robotics (2015/2103(INL)), dostupno na: https://www.europarl.europa.eu/doceo/document/A-8-2017-0005_EN.html

[147] Više o tome: Proposal for a Council Recommendation on access to social protection for workers and the self-employed {SWD(2018) 70 final} - {SWD(2018) 71 final} - {SWD(2018) 79 final}

[148] Više o tome: Komunikacija Komisije Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija, Novi program vještina za Europu – Suradnja na jačanju ljudskog kapitala, zapošljivosti i konkurentnosti, COM/2016/0381 final, dostupno na: https://op.europa.eu/en/publication-detail/-/publication/c861f839-2ee9-11e6-b497-01aa75ed71a1/language-hr/format-PDF

usavršavanja s ciljem poboljšanja osnovnih matematičkih, pismenih i digitalnih vještina. Plan osposobljavanja budućih djelatnika rezultirao je i Akcijskim planom za digitalno obrazovanje[149] s ciljem povećanja digitalnih vještina i kompetencija djelatnika. Tim se planom želi istražiti utjecaj AI na obrazovanje i osposobljavanje.

S društvenog aspekta AI je utjecala i nastaviti će utjecati na stvaranje novih profila radnih mjesta, među ostalim i u području razvoja algoritama za ML i sličnih inovacija.[150] Područje informacijskih i komunikacijskih tehnologija još od 2011. ima godišnji porast otvaranja novih radnih mjesta od 5 % što je rezultiralo povećanju broja IT stručnjaka.[151] Ukupno gledajući, broj stručnjaka u području IT i komunikacijskih tehnologija u EU od 2011. se godišnje povećava za 5 % čime se stvorilo 1,8 milijuna radnih mjesta i u samo pet godina naglo povećao njihov udio u ukupnom zapošljavanju, s 3 % na 3,7 %, a to znači najmanje 360 000 slobodnih radnih mjesta za te stručnjake u Europi, što upućuje na znatan manjak vještina.[152]

Cilj Europe u nadolazećem vremenu je svakako povećati broj osoba koje su osposobljene za obavljanje poslova u području AI te poticati raznolikost u postupku osposobljavanja. Također, važna je interdisciplinarnost u samom osposobljavanju. To znači da je nužno podržati programe i predmete osposobljavanja koji će sadržavati studij npr. prava ili psihologiju uz dodatak AI. Naravno, to uključuje i etiku kao jednu od ključnih stupova razvoja i primjene AI. Komisija s ovom Komunikacijom – Umjetna inteligencija za Europu podržava napore država članica u politici rada i obrazovanja te planira provesti sljedeće korake:

- uspostaviti namjenske sustave prekvalifikacije i osposobljavanja u okviru Plana za sektorsku suradnju u području vještina,[153]
- prikupiti detaljne analize i stručna mišljenja radi predviđanja promjena na tržištu rada i neusklađenosti u vještinama u cijeloj EU te o tome informirati donositelje odluka na razini EU te na nacionalnoj i lokalnoj razini,

[149] Više o tome: Komunikacija Komisije Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija o akcijskom planu za digitalno obrazovanje, COM/2018/022 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=COM%3A2018%3A22%3AFIN

[150] Više o tome: Centre For The Future of Work. (2017). 21 Jobs of the future – A guide to getting – and staying – employed over the next 10 years, dostupno na: https://www.cognizant.com/whitepapers/21-jobs-of-the-future-a-guide-to-getting-and-staying-employed-over-the-next-10-years-codex3049.pdf

[151] Više o tome na: https://digital-strategy.ec.europa.eu/en/news/pilot-project-monitors-online-vacancies-ict-specialists-real-time

[152] *Ibid.*

[153] Više o tome: Blueprint for sectoral cooperation on skills, dostupno na: https://ec.europa.eu/social/main.jsp?catId=1415&langId=en

- poduprijeti program Digitalna prilika (2018. – 2020.) za pripravništva u području naprednih digitalnih vještina za studente i osobe koje su nedavno diplomirale,
- u okviru Koalicije za digitalne vještine i radna mjesta poticati partnerstva između poduzeća i obrazovnih ustanova da privuku i zadrže više stručnjaka u području AI,
- pozvati socijalne partnere da uključe AI i njezin utjecaj na gospodarstvo i zapošljavanje.[154]

Europski institut za inovacije i tehnologiju integrirat će AI u sve kurikulume obrazovnih programa koje nudi kako bi se priključio razvijanju kvalitetne strukture stručnjaka za AI u Europi. Nadalje, u sociološkom doprinosu AI važno je stvoriti atmosferu povjerenja i odgovornosti oko samog procesa razvoja i korištenja sustava AI. Sociološke vrijednosti su utvrđene i u članku 2. i 3. Ugovora o EU i kao takve predstavljaju temelj prava svih stanovnika EU.[155] Prva pravila na razini EU o sigurnosti mrežnih i informacijskih sustava[156] te stroža pravila o GDPR-u stupila su na snagu u svibnju 2018. Ujedno, Komisija je predstavila i niz prijedloga u okviru strategije jedinstvenog digitalnog tržišta koji će biti glavni pokretači razvoja AI. To podrazumijeva implementaciju Uredbe o slobodnom protoku neosobnih podataka[157] i povećanje povjerenja u moderne tehnologije, korištenje interneta ili pak Internet stvari (engl. *Internet of Things* - IoT) kroz Uredbu o e-privatnosti[158] i Akt o kibersigurnosti.[159] Na taj način će i fizičke i pravne osobe steći povjerenje u tehnologiju kojom se služe te će se osigurati ravnopravno i očekivano pravno okruženje čime će se pružiti učinkovita zaštita temeljnih prava i sloboda. Kako bi se dodatno osiguralo povjerenje potrebno je razumjeti i kako tehnologija funkcionira zbog čega je važno istražiti objašnjivost sustava AI i načina upravljanja takvim sustavom. Komisija ističe nužnost osiguranja transparentnosti te redukciju rizika od pristranosti

[154] Točka 3.2. Komunikacije – Umjetna inteligencija za Europu

[155] Više o tome : Pročišćene verzije Ugovora o Europskoj uniji i Ugovora o funkcioniranju Europske unije (2016/C 202/01), dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:12016ME/TXT

[156] Više o tome: Direktiva (EU) 2016/1148 Europskog Parlamenta i Vijeća od 6. srpnja 2016. o mjerama za visoku zajedničku razinu sigurnosti mrežnih i informacijskih sustava širom Unije, OJ L 194, str. 1-30. (Direktiva 2016/1148)

[157] Uredba (EU) 2018/1807 Europskog parlamenta i Vijeća od 14. studenoga 2018. o okviru za slobodan protok neosobnih podataka u Europskoj uniji, OJ L 303, str. 59-68. (Uredba 2018/1807). O smjernicama više na: https://ec.europa.eu/commission/presscorner/detail/hr/IP_19_2749

[158] Prijedlog Uredbe Europskog parlamenta i Vijeća o poštovanju privatnog života i zaštiti osobnih podataka u elektroničkim komunikacijama te stavljanju izvan snage Direktive 2002/58/EZ (Uredba o privatnosti i elektroničkim komunikacijama), COM/2017/010 final - 2017/03 (COD), dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX%3A52017PC0010

[159] Uredba (EU) 2019/881 Europskog Parlamenta i Vijeća o ENISA-i (agenciji EU-a za kibersigurnost) i stavljanju izvan snage Uredbe (EU) 526/2013 te o kibersigurnosnoj certifikaciji u području informacijske i komunikacijske tehnologije („Akt o kibersigurnosti”), OJ L 151, str. 15-69.

ili pogreške na najmanju moguću mjeru. Iz tog proizlazi da bi sustave AI trebalo razvijati tako da se ljudima omogući razumijevanje njihova rada. Etička pitanja svakako su obrađena kroz dokument o etičkim smjernicama o pouzdanoj AI (Etičke smjernice) koju je izradila Stručna skupina na visokoj razini (engl. *High Level Expert Group* – HLEG).[160] Između ostalog, obrađena su pitanja kao što su budućnost rada, pravednost, zaštita, sigurnost, socijalna uključenost i algoritamska transparentnost te utjecaj AI na temeljna ljudska prava, uključujući načela privatnosti, dostojanstva, zaštite potrošača i nediskriminacije. Neka od navedenih djelovanja temeljit će se i na radu Europske skupine za etiku u znanosti i novim tehnologijama[161] i drugim sličnim nastojanjima.[162] Komisija u Komunikaciji ističe kako se pojavnošću AI, a nadasve podsustava AI koji omogućuje autonomnost donošenja odluka, zahtijeva promišljanje o pitanjima prikladnosti nekih utvrđenih pravila o sigurnosti i građanskopravne odgovornosti. Na primjer, napredni roboti i proizvodi IoT u zajedništvu s AI mogu se ponašati na načine koji nisu bili predviđeni u trenutku kad je sustav prvi put stavljen u upotrebu. Koristeći tehnike i metode usvajanja velike količine podataka (engl. *Big Data* - BD) nemoguće je u startu predvidjeti sve ishode pokrenutog algoritma i petljama koje aktivira izvršavanjem startnog koda te se dovodi u pitanje mogućnost preispitivanja horizontalnih i sektorskih pravila.[163] Ako se u obzir uzmu automatizirani sustavi AI nužno je osigurati ispravnost i provjeru ispravnosti odluka koje sustav donese te mogućnosti ispravke takvih grešaka. Većina država članica EU je u tom smislu i razvila strategije za razvoj AI koje će biti obrađene u nastavku ovog rada, a čime se ukazuje na važnost suradnje država u pogledu međudjelovanja te zajednički rad na regulatornim zakonskim rješenjima kojim se može osigurati jedinstvenost tržišta i potaknuti osnivanje poduzeća aktivnih u području AI, a samim time i povećati bazu korisnika iste.

U zaključku ove Komunikacije Komisija ističe zajedništvo i snagu europske znanstvene i industrijske infrastrukture što uključuje djelovanja na području AI, robotike, automatizacije i

---

[160] Neovisna Stručna skupina na visokoj razini o AI, (2019). Etičke smjernice za pouzdanu AI dostupno na: https://ec.europa.eu/futurium/en/ai-alliance-consultation

[161] EU skupina za etiku u znanosti i novim tehnologijama je savjetodavno tijelo Komisije.

[162] Izazove o poštivanju temeljnih prava korisnika i proizvođača AI vrednovat će Agencija EU za temeljna prava. Europska skupina za etiku u znanosti i novim tehnologijama objavila je 9. ožujka 2018. i relevantnu izjavu o AI, robotici i autonomnim sustavima. Primjeri međunarodnog djelovanja: načela AI nastala u okviru konferencije u Asilomaru, nacrt načela Montrealske deklaracije o odgovornoj AI, deset glavnih načela etične AI saveza sindikata UNI Global Union (http://www.thefutureworldofwork.org/opinions/10-principles-for-ethical-ai/).

[163] Za svaki novi regulatorni prijedlog koji će biti potreban za rješavanje pitanja u vezi s AI i povezanim tehnologijama Komisija primjenjuje načelo inovativnosti, skup alata i razvijenih smjernica. Više o tome vidi na: https://ec.europa.eu/epsc/publications/strategic-notes/towards-innovation-principle-endorsed-betterregulation_en

općenito inovacija. Također, zakonodavni okvir EU je opsežan i obuhvaća sve važne elemente ljudskog djelovanja, prava i potreba. Na taj način pohvalna je i prilagodba koje države članice EU pokazuju u postupku primjene predloženih inicijativa na nacionalnoj razini. To je jedan od glavnih razloga u stvaranju i održanju jedinstvenog digitalnog tržišta. Samim time, postavljeni su svi preduvjeti da Europa bude predvodnik novog trenda pokrenutog AI i modernom tehnologijom. Navedena Komunikacija naglašava potrebu za zajedničkim djelovanjem u postupku digitalne transformacije kao i ulaganja dodatnih financijskih napora u kontekstu razvoja AI satkane od svih važnih vrijednosti i ljudskih prava.

2.11. EUROPSKA STRATEGIJA ZA PODATKE

Komisija je u veljači 2020. godine izdala još jednu Komunikaciju prema Europskom Parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija pod nazivom „Europska podatkovna strategija“ (Komunikacija – Europska podatkovna strategija)[164] s ciljem uspostavljanja jedinstvenog tržišta za podatke te omogućavanjem slobodnog protoka podataka unutar EU i između sektora u korist poduzeća, znanstvenika i državnih uprava. To podrazumijeva bolju iskoristivost podataka što bi rezultiralo većom produktivnošću, boljom konkurentnošću na tržištu, ali i poboljšanju zdravlja i dobrobiti, okoliša, transparentnog upravljanja i određenih javnih usluga. U količini podataka u opticaju jasno je kako novi val podatkovne strukture pruža mnoge prilike pogotovo ako uzmemo u obzir da je trenutno 80 % ukupne podatkovne analize i procesuiranja lokalizirano u centraliziranim računalnim centrima, a svega 20 % na određenim, više ili manje mobilnim, pametnim uređajima. Do 2025. godine takvi omjeri bi se trebali obrnuti.[165] Važnost podataka za ekonomiju i društvo očituje se u činjenici da su podaci temelj ekonomskog razvoja, odnosno oni su osnova za mnoge nove proizvode i usluge, povećavajući produktivnost i učinkovitost resursa u svim sektorima gospodarstva, pružanje personaliziranih proizvoda i usluga, što u zajedničkom djelovanju može rezultirati boljim korporativnim politikama, a što je ključan resurs za SME.[166] Također, dostupnost podataka ključno je za treniranje sustava AI. Kao što je

[164] Komunikacija Komisije Europskom Parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Europska strategija za podatke, COM/2020/66 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:52020DC0066

[165] IDC and TXT Solutions (2014). SMART 2013/0037, „Kombinacija usluga u oblaku i interneta stvari” (Cloud and IoT combination), studija za Europsku komisiju, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:52017JC0450&from=NL

[166] Komunikacija – Europska podatkovna strategija, str. 2-3.

već utvrđeno, budućnost digitalne Europe će ovisiti o količini i kvaliteti dostupnih podataka, ali već i sadašnjost nam pruža uvid u neke potencijale kvalitetne upotrebe podataka.[167]

Primjerice, zrakoplovi opremljeni mnoštvom senzora na motorima provode učinkovite letove zahvaljujući kvalitetnoj obradi prijašnjih podataka o letovima. Podaci o prometnoj navigaciji tijekom gužvi dobiveni u stvarnom vremenu mogu uštedjeti 730 milijuna sati što rezultira uštedom od 20 milijardi eura.[168] Također, obavijesti o kašnjenju vlakova u stvarnom vremenu mogu uštedjeti 27 milijuna radnih sati čime bi se sačuvalo 740 milijuna eura u troškovima rada.[169] Nadahnjujući je i primjer bolje alokacije financijskih sredstava temeljem boljeg korištenja podataka i AI u borbi protiv malarije gdje bi se moglo osigurati dodatnih 5 milijardi eura svjetskim zdravstvenim sustavima.[170] Vrijednost podatkovne ekonomije očituje se i u predviđanjima kako će činiti 5,8 % EU BDP-a, odnosno 829 milijardi eura (dosadašnja vrijednosti je 2,4 % ili 301 milijarda eura).[171] Također, predviđa se dvostruko povećanje ljudskih potencijala odnosno radnog kadra te bi do 2025. godine trebalo biti 10,9 milijuna osposobljenih djelatnika. Isto tako, postotak europske populacije s osnovnim digitalnim vještinama bi se povećao s 57 % na 65 %.[172] Sve navedeno potvrđuje da je nužno osigurati kvalitetan zakonodavni okvir. Osim navedenih regulacija koje je donijela Komisija, poput GDPR-a, Akta o kibernetičkoj sigurnosti ili Uredbe (EU) o okviru za slobodan protok neosobnih podataka[173], Komisija je donijela i regulacije posebne za pojedine sektore poput Uredbe (EZ) o homologaciji motornih vozila[174] u kontekstu automobilskih usluga, Direktive o platnim uslugama na unutarnjem tržištu,[175] Direktive o zajedničkim pravilima za unutarnje tržište električne energije[176] ili pak Direktive o okviru za uvođenje inteligentnih prometnih

[167] *Ibid*, str. 2.
[168] Dostupno na: https://ec.europa.eu/info/strategy/priorities-2019-2024/europe-fit-digital-age/european-data-strategy_hr
[169] *Ibid.*
[170] *Ibid.*
[171] *Ibid.*
[172] *Ibid*.
[173] Uredba 2018/1807
[174] Uredba (EZ) br. 595/2009 Europskog Parlamenta i Vijeća od 18. lipnja 2009. o homologaciji motornih vozila i motora s obzirom na emisije iz teških vozila (Euro VI) i o pristupu informacijama za popravak i održavanje vozila i izmjenama Uredbe (EZ) br. 715/2007 i Direktive 2007/46/EZ i stavljanju izvan snage direktiva 80/1269/EEZ, 2005/55/EZ i 2005/78/EZ, OJ L 188, str. 1-13.
[175] Direktiva (EU) 2015/2366 Europskog Parlamenta i Vijeća od 25. studenoga 2015. o platnim uslugama na unutarnjem tržištu, o izmjeni direktiva 2002/65/EZ, 2009/110/EZ i 2013/36/EU te Uredbe (EU) br. 1093/2010 i o stavljanju izvan snage Direktive 2007/64/EZ, OJ L 337, str. 35-127.
[176] Direktiva (EU) 2019/944 Europskog parlamenta i Vijeća od 5. lipnja 2019. o zajedničkim pravilima za unutarnje tržište električne energije i izmjeni Direktive 2012/27/EU, OJ L 158, str. 125-199.

sustava u cestovnom prometu i za veze s ostalim vrstama prijevoza.[177] Komisija u Komunikaciji – Europska podatkovna strategija smatra da se poduzeća i javni sektor u EU mogu ojačati korištenjem podataka za donošenje boljih odluka. S obzirom da se podaci, za razliku od ostalih ekonomskih resursa, mogu umnožiti s minimalnim, ako ne i nepostojećim troškovima, upotreba takvih podataka od strane jedne osobe ili organizacije ne sprječava istodobnu upotrebu istih podataka od druge osobe ili organizacije.

U cilju maksimizacije takvog potencijala, Komisija smatra da je potrebno osigurati bolji pristup podacima i odgovornu uporabu istih. Na taj način bi se stvorila kvalitetnija struktura u kojoj bi ekonomija podataka tj. podaci pohranjeni, obrađeni i stavljeni na vrijednu upotrebu u Europi, barem odgovarali njezinoj ekonomskoj težini i to prema pojedinačnom izboru. Pojednostavljeno rečeno, takav podatkovni prostor pružit će europskim poduzećima mogućnost da se ostvaruju kroz jedinstveno tržište. Zajednička europska pravila i učinkoviti mehanizmi provedbe trebali bi osigurati da:

- podaci mogu teći unutar EU i između sektora,
- se u potpunosti poštuju europska pravila i vrijednosti, posebno zaštita osobnih podataka, regulacija o zaštiti potrošača i prava tržišnog natjecanja,
- su regulacije o pristupu i korištenju podataka prikladne, uporabljive i fer, a da postoje jasni te pouzdani mehanizmi upravljanja podacima.[178]

Vizija zajedničkog europskog prostora podataka i daljnji razvoj istinskog jedinstvenog tržišta podataka rezultirala je i prilagodbama vlastitog pravnog okvira nekih država članica poput korištenja privatnih podataka državnih tijela,[179] obrada podataka u svrhu znanstvenih istraživanja[180] ili prilagodbe prava tržišnog natjecanja.[181] Vrijednost podataka leži u konstantnoj uporabi istih. Poteškoće koje se pojavljuju su nedostatak dostupnih podataka za inovativnu upotrebu, uključujući za razvoj AI. Također, prijeporna pitanja se mogu odnositi na identifikaciju nositelja podataka i tko je korisnik podataka, ali također ovise i o prirodi podataka

[177] Direktiva 2010/40/EU Europskog parlamenta i Vijeća od 7. srpnja 2010. o okviru za uvođenje inteligentnih prometnih sustava u cestovnom prometu i za veze s ostalim vrstama prijevoza, OJ L 207, str. 1-13.
[178] Komunikacija – Europska podatkovna strategija, str. 5.
[179] Primjerice, francuski *LOI n ° 2016-1321 du 7 octobre 2016 pour une République numérique* omogućava javnom sektoru pristup određenim podacima (privatnom sektoru) od općeg interesa ili finski Zakon o šumama koji obvezuje vlasnike šuma da razmjenjuju informacije povezane s gospodarenje šumama s javnim sektorom.
[180] Primjerice, finski Zakon o sekundarnoj upotrebi zdravstvenih i socijalnih podataka, stvarajući tijelo za izdavanje podataka.
[181] Na primjer, u Njemačkoj se vode rasprave o prilagodbi pravila tržišnog natjecanja kako bi ih se bolje opremilo za podatkovnu ekonomiju. Vidjeti također Izvješće Komisije o „Politici tržišnog natjecanja za digitalno doba“ dostupno na: https://ec.europa.eu/competition/publications/reports/kd0419345enn.pdf

(tj. osobni podaci, javni podaci ili miješani skupovi podataka koji ih kombiniraju).[182] U ostvarivanju europskih podatkovnih zamisli nužno je provesti akcije temeljene na četiri ključna stupa prema ovoj Komunikaciji – Europska podatkovna strategija:

- međusektorski okvir upravljanja pristupom i upotrebom podataka;
- ulaganja u podatke i jačanje europskih sposobnosti i infrastrukture za prikupljanje, obradu i upotrebu podataka;
- osnaživanje pojedinaca, ulaganje u vještine i u SME i
- zajednički europski podatkovni prostori u strateškim sektorima i domenama od javnog interesa.

U ovoj Komunikaciji – Europska podatkovna strategija Komisija navodi stajalište o europskom podatkovnom prostoru izražavajući ambiciju o omogućavanju EU da postane najatraktivnije, najsigurnije i najdinamičnije gospodarstvo na svijetu, odnosno osnaživanje Europe podacima za poboljšanje odluka i bolji život svih njezinih građana.

2.12. BIJELA KNJIGA O UMJETNOJ INTELIGENCIJI

Europska komisija je u Bijeloj knjizi o AI iz veljače 2020.[183] iznijela svoj stav o pojavnosti AI i utjecaju koji će AI nužno imati u budućnosti. Počevši od premise o ubrzanom razvoju modernih tehnologija, Komisija drži kako će AI promijeniti naše živote na bolje u mnogo područja ljudskog djelovanja i industrijskog razvitka. Smatra se da će djelovanje AI u zdravstvenom sustavu pozitivno utjecati na preciznost dijagnoza i prevenciju bolesti, poboljšati poljoprivredu, doprinijeti poboljšanju klimatskih uvjeta, povećati sigurnost građana, ali i otvoriti mogućnost za potencijalne rizike u smislu zlouporabe tehnologije, rasne i ostale diskriminacije, prekoračenog zadiranja u privatnost ili pak površnog donošenja odluka. Stav koji je Komisija zauzela u Bijeloj knjizi ističe podršku u zakonodavnoj regulaciji AI i prihvaćanju ulagačkog pristupa, a temeljeno dvostrukim ciljem: a) promoviranje AI i njezinog

[182] Kako bi osigurala pravna sigurnost Komisija je u svibnju 2019. godine izdala praktične smjernice za poduzeća kako obraditi miješane skupove podataka. Vidjeti: Communication from the Commission to the European Parliament and the Council - Guidance on the Regulation on a framework for the free flow of non-personal data in the European Union, COM (2019) 250, dostupno na: https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=COM%3A2019%3A250%3AFIN

[183] Bijela knjiga o umjetnoj inteligenciji – Europski pristup izvrsnosti i izgradnji povjerenja od 19.2.2020., COM(2020) 65 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:52020DC0065&from=hr

razvoja u kontekstu boljitka čovječanstva i b) identificiranje mogućih rizika u korištenju takve tehnologije.

U mnogim pokušajima da se definira tehnologija AI i Komisija je u Bijeloj knjizi dala svoj doprinos određujući AI kao skup tehnologija koje spajaju i koriste moć računala, algoritama i podataka.[184] Navedena tri elementa su ključna u daljnjem razvoju AI te je nužnost da Europa ujedini tehnološku i industrijsku snagu s kvalitetnom digitalnom infrastrukturom i dosljednom pravnom regulativom. Prednosti korištenja sustava AI mogu utjecati na pozitivan daljnji razvoj same tehnologije, ali i na cijelo europsko i svjetsko društvo i ekonomiju. Komisija u Bijeloj knjizi ističe trostruki doprinos AI, a odnosi se na: a) građane koji će poboljšanja osjetiti u zdravstvenoj zaštiti, manjem broju kvarova kućanskih aparata, sigurnijem i čišćem sustavu prijevoza i boljim javnim uslugama, b) razvoj poduzeća s proizvodima nove generacije, a posebice u sektorima u kojima Europa prednjači kao što su prijevoz, kibernetička sigurnost, poljoprivreda, zelena ekonomija, zdravstvo i turizam te c) usluge od javnog interesa kao što je smanjivanje troškova za pružanje određenih usluga poput prijevoza, obrazovanja, energetike i odlaganja otpada i to na način da se poboljša održivost proizvoda[185] i osiguranje prikladnih alata nadležnim regulatornim tijelima za održavanje sigurnosti građana[186] poštujući njihova prava i slobode. S obzirom na utjecaj koji će imati AI nužno je napomenuti i prava koje će se trebati poštivati prilikom uporabe takvih sustava. Ljudsko dostojanstvo i zaštita privatnosti su neka od osnovnih ljudskih prava koja mogu biti „meta“ AI ili onih koji je kontroliraju te je važno ostati svjestan mogućih ugroza i prizemljen u smislu razvoja sustava AI.[187]

U uvodnom dijelu Bijele knjige Komisija smatra nužnim voditi računa o životnom vijeku nekog sustava AI u kontekstu utjecaja na onečišćenje okoliša što se može odnositi na infrastrukturu ponajprije ogromnih područja gdje se radi pohrana velike količine podataka, ali i upotrebe resursa za ML, odnosno treniranje algoritama. Komisija smatra kako će buduća zakonodavna regulativa stvoriti jedinstveni sustav povjerenja za što će biti potrebno izgraditi kvalitetan okvir glede nadzora i usklađenosti europskih regulativa, a što se posebice odnosi na

---

[184] *Ibid*, str. 2.

[185] ICT sektor s ekološkog aspekta trenutno emitira 2% ukupne svjetske emisije što je ključni pokretač ambicija EU o „Zelenoj Europi“ koristeći AI. *Ibid*, bilj. 31.

[186] Sustav AI može pružiti alate i metode bolje zaštite građana od kriminala i terorističkih napada. Koristeći takve alate stvara se mogućnost prepoznavanja terorističkih propagandi na Internetu, otkrivanja sumnjivih transakcija u prodaji opasnih proizvoda, prepoznavanja skrivenih objekata koji predstavljaju opasnost, pružanja posebnih usluga građanima u opasnosti odnosno kada trebaju hitnu pomoć ili ako su se našli kao prvi na mjestu događaja i mogu pružiti prvu pomoć. *Ibid*, bilj. 33.

[187] *Ibid*, str. 2.

sustave AI koji su od visokog rizika, odnosno čija pogrešna uporaba može rezultirati protupravnim djelovanjima.[188] Jasno je da razvoj AI u ovom trenutku ovisi o količini dostupnih podataka koje obrađuje. ML i duboko učenje (engl. *Deep Learning* - DL) su procesi koji zahtijevaju obradu BD kako bi AI rezultirala točnošću, brzinom dostavljenih informacija i reakcijom na traženi upit ili donesene odluke. Količina podataka koja nastaje i/ili cirkulira svijetom je u velikom porastu, točnije u 2018. je bilo 33 zettabajtova podataka, dok se u 2025. godini očekuje 175 zettabajtova.[189] [190] Također, način obrade i analize dostupnih podataka trenutno se obavlja u „oblaku" (engl. *Cloud*) i to u omjeru 80 % : 20 % u odnosu na pametne objekte (auta, kućanski aparati, mobiteli, proizvodni roboti).[191] Do 2025. godine taj će se omjer drastično promijeniti.[192] Naravno, za svaku promjenu i poboljšanje u infrastrukturi i načinu obrade podataka potrebno je uložiti određena financijska sredstva. Europa tek uviđa nužnost većeg novčanog doprinosa razvoju tehnologije što je rezultiralo povećanjem sredstava za razvoj i inovacije za 70 % u protekle tri godine te ukupni financijski doprinos iznosi 3.2 milijardi eura.[193] S druge pak strane, Sjeverna Amerika je u istom periodu uložila 12.1 milijardu eura, a Azija 6.5 milijardi eura.[194] Jasno je, dakle, kako Europa tek mora uhvatiti korak s najvećim svjetskim silama u području razvoja sustava AI što je i izneseno u Koordiniranom planu za AI za države članice EU.

U procesu stvaranja zajedničkog europskog regulatornog okvira, a vodeći se misijom održavanja sustava povjerenja, ističu se mnoge prednosti i nedostaci korištenja AI. Jedan od glavnih strateških ciljeva jest osigurati povjerenje građana u tehnologiju koja trenutno i u određenom dijelu, zbog obrane ljudskih prava, informacijske nejednakosti u algoritmičkoj

---

[188] Report from the Commission to the European Parliament, the Council and the European Economic and Social Committee - Report on the Safety and Liability Implications of Artificial Intelligence, The Internet of things and robotics, COM(2020) 64 final

[189] Zettabajt je oznaka za količinu podataka. 1 ZB = 10^{21}B odnosno 1 ZB = 1 trilijun GB. Usporedbe radi, 2007. godine svijet je proizveo 1.9 ZB što je ekvivalent količini podataka sadržanih u 174 novine (vjesnika) koje bi dobila svaka osoba na svijetu u jednom danu. Stavljajući volumen podataka od 33 ZB u još zanimljiviji kontekst, mogli bi ustvrditi kako bi podatkovno maksimalno iskorišteni tableti od 512 GB mogli formirati toranj koji bi dosegnuo Mjesec, a do 2025. formirao bi se pet puta veći. Komunikacija – Europska podatkovna strategija, str. 2.

[190] Reinsel, D., Gantz, J., Rydning, J. (2018). The Digitalization of the World From Edge to Core, An IDC White Paper - #US44413318, dostupno na: https://www.seagate.com/files/www-content/our-story/trends/files/idc-seagate-dataage-whitepaper.pdf

[191] Bijela knjiga, str. 4.

[192] Panetta, K. (2017). Top Trends in the Gartner Hype Cycle for Emerging Technologies, Smart with Gartner, dostupno na: https://www.gartner.com/smarterwithgartner/top-trends-in-the-gartner-hype-cycle-for-emerging-technologies-2017/

[193] Bijela knjiga, str. 4.

[194] Manyika, J. (2017). 10 imperatives for Europe in the age of AI and automation, McKinsey Global Institute, dostupno na: https://www.mckinsey.com/featured-insights/europe/ten-imperatives-for-europe-in-the-age-of-ai-and-automation

odlučivanju, ali i pravne nesigurnosti, izaziva strah. Također, strah je dodatno ojačan činjenicom o možebitnoj zlouporabi sustava AI i neželjenih učinaka koji bi protupravno ponašanje takve vrste izazvalo. Takva problematika je navedena i u Strategiji EU za AI te Koordiniranom planu i dokumentu objavljenog od strane HLEG-a.[195] S obzirom na brzi razvoj AI nužno je da zakonodavstvo indirektno prepozna potencijalne buduće ugroze i omogući daljnju regulaciju AI, a promjene koje će se uvoditi moraju identificirati problem i pružiti odgovarajuće rješenje. Iako je AI u početnoj fazi svoga razvoja, već sada vlasnici inteligentnih sustava podliježu zakonodavstvu EU u kontekstu zaštite osobnih podataka, privatnosti, nediskriminaciji, zaštiti potrošača te omogućavanju sigurnosti sustava jer potrošači takvu odgovornosti i očekuju nevezano o tome oslanja li se postojeći sustav na AI ili ne. Upravo je to ključ u određivanju potrebitosti prilagodbe postojeće zakonodavne regulative ili donošenja posve novog regulatornog okvira. Međutim, potrebno je naglasiti važnost uloge koju predstavlja EU u smislu ujednačenosti zakonodavstava. Primjerice Savezna Republika Njemačka (Njemačka) je predložila sustav regulacije koji je temeljen na pet razina sigurnosti, odnosno od odsutnosti regulacija za određene sustave AI do potpune zabrane najopasnijih sustava.[196] S druge strane, danska poduzeća žele iskoristiti konkurentsku prednost u etičnom ponašanju s osobnim podacima i zato je Danska izdala prototip pečata za dobru informatičku sigurnost i odgovorno korištenje podataka. Može se uzeti i primjer Malte koja je uvela dobrovoljni sustav certificiranja poduzeća za AI.[197]

Iz navedenog, vidljiv je realni rizik od potencijalne neujednačenosti unutarnjeg tržišta EU što bi se negativno odrazilo na ciljeve u kontekstu stvaranja povjerenja, informatičke i pravne sigurnosti, ali i smanjenju rizika od kibernetičkih napada ili pak problema s upotrebom sustava AI u kritičnim infrastrukturama. Neki od primjera u kojima sustavi AI preuzimaju ulogu koju je nekada radio čovjek očituje se u situacijama gdje sustavi AI povećaju mogućnosti praćenja ljudskih navika analiziranjem istih uz prilagođavanje i personaliziranije proizvode. Sukladno mogućnostima sustava isti se može koristiti i za masovni nadzor ili u mikro sredinama za promatranje ponašanja zaposlenika čime se mogu kršiti osnovna ljudska prava, prava na zaštitu podataka i sl. U nekim primjerima vidljivi su i nedostaci određenih algoritama koji su korišteni

[195] European AI Alliance, više o inicijativi na: https://ec.europa.eu/digital-single-market/en/european-ai-alliance
[196] Bijela knjiga, str. 10.
[197] *Loc.cit.*

glede predviđanja kriminalnog recidivizma, iskazujući spolne i rasne pristranosti.[198] Komisija u Bijeloj knjizi navodi kako sustavi AI mogu predstavljati sigurnosne rizike za korisnike kada djeluju lokalno, odnosno kada svoju funkciju obavljaju direktno unutar proizvoda. Primjerice, zbog pogreške u tehnologiji prepoznavanja predmeta autonomno vozilo može pogrešno identificirati objekt na cesti što može rezultirati prometnim nesrećama, ozljedama i štetama. Ne ulazeći još u softverske ili hardverske greške, problemi mogu biti identificirani i s dostupnosti i kvalitetom dostupnih podataka. Postojeća europska zakonodavstva o sigurnosti i odgovornosti za AI, uključujući posebne regulacije za pojedine sektore, a zajedno sa zakonodavstvima država članica EU, čine nužan trokut zakonodavnih akata koji bi bio primjenjiv i univerzalan na brojne implementacije sustava AI kroz različite sektore kao što je prikazano na slici 2-1.

Slika 2-1 Prikaz pravnih propisa u području AI,

Izvor: Izradio autor prema izvješću Komisije

[198] Tolan, S., Miron, M., Gomez, E., Castillo, C. (2019). Why machine learning may lead to unfairness: Evidence from risk assesment for juvenile justice in Catalonia, 17th International Conference on AI and Law, Montreal, dostupno na: https://chato.cl/papers/miron_tolan_gomez_castillo_2019_machine_learning_risk_assessment_savry.pdf

Naravno, ključno pitanje budućeg specifičnog regulatornog okvira za AI je utvrđivanje opsega njezine primjene. Samim time, u svakom budućem pravnom aktu definicija sustava AI će morati biti dovoljno široka da obuhvati budući tehnički napredak, a ujedno eksplicitna da utvrdi pravne temelje i osigura zaštitu građana. U samom početku to će značiti pravilno razlikovanje i definiranje pojmova „AI“, „podatak“ i „algoritam“. Prema HLEG-u sustavi AI su „ *softverski (a možda i hardverski) sustavi koje je dizajnirao čovjek, a koji djeluju u fizičkoj ili digitalnoj dimenziji gdje opažaju svoje okruženje prikupljajući podatke, interpretirajući prikupljene podatke (strukturirane ili nestrukturirane) i temeljem stečenog znanja donose odluke o poduzimanju akcija za postizanje zadanog cilja. AI sustavi mogu ili koristiti simbolička pravila ili naučiti numerički model, a također mogu prilagoditi svoje ponašanje analizirajući kako okoliš utječe na njihove prethodne radnje*“.[199] Primjerice, u autonomnoj vožnji algoritam koristi podatke dobivene u stvarnom vremenu iz automobila (brzina, potrošnja goriva i sl.) i sa senzora koji skeniraju čitavo okruženje automobila (cesta, znakovi i druga vozila, pješaci i sl.) za određivanje smjera, ubrzanja i brzine kojom bi automobil trebao u određenoj situaciji putovati i manevrirati. Algoritam se treba prilagođavati situaciji na cesti i vanjskim uvjetima u stvarnom vremenu te predviđati djelovanje ostalih dionika u prometu za postizanje sigurne vožnje i dolaska na cilj.[200] Slična usporedba, samo s ostalim dionicima i podacima iz senzora, bila bi i s autonomnim plovilima u pomorskom prometu. Također, Komisija u Bijeloj knjizi navodi specifičnosti primjene sustava AI za koju se smatra da predstavlja visoki rizik što se određuje kumulativnim ispunjavanjem sljedeća dva kriterija:

- primjena AI u sektoru u kojem se, s obzirom na karakteristike aktivnosti koje se obično poduzimaju, može očekivati značajan rizik. Na taj način regulatorna djelovanja bi se usmjerila na područja za koja se smatra da su ponajviše izložena riziku i takvi sektori trebaju biti navedeni i povremeno pregledavani i nadopunjeni u novom zakonodavnom okviru. U kontekstu rizičnosti za primjer se mogu uzeti zdravstvena zaštita, transport, energetika i specifična područja u službi javnog sektora,[201]
- primjena AI u određenom sektoru se koristi na način koji značajno povećava mogućnost nastanka rizika. Time se želi reći da svako korištenje aplikacija sustava AI ne rezultira nužno značajnim rizicima. Primjerice, korištenje AI u zdravstvenom sustavu u

[199] Etičke smjernice, str. 44.
[200] Bijela knjiga, str. 17.
[201] Primjer mogu biti područja u sklopu kojih djeluju sustavi za azil, migracije, granične kontrole, pravosuđe, službe za zapošljavanje i/ili sigurnost građana i sl. *Ibid,* bilj. 50., str. 18.

kontekstu zakazivanja određenog bolničkog pregleda ne predstavlja značajan rizik koji bi uvjetovao zakonodavnu i pravnu intervenciju. Samim time, procjena rizika korištenja AI u nekom sektoru se može odrediti i po utjecaju koji ima na „oštećenu"/drugu stranu, pa tako primjerice upotreba AI koja može izazvati pravne posljedice predstavlja rizik od smrti, ozljeda, prouzročenja značajnih materijalnih ili nematerijalnih šteta, odnosno onih posljedica koje fizičke ili pravne osobe ne mogu izbjeći.[202]

Sukladno smjernicama HLEG-a visokorizične aplikacije koje koriste sustave AI se mogu sastojati od sljedećih ključnih elemenata kao što su: a) podaci nužni za učenje sustava AI, b) vođenje i prikupljanje podataka, c) informacije koje se trebaju pružiti, d) točnost, e) ljudski nadzor, f) specifični podaci potrebni sustavu AI kao što su biometrijski identifikatori za individualizaciju pojedinaca. Prema navedenim ključnim elementima, AI i njezina primjena uvelike ovisi o dostupnim podacima i točnosti istih. U provođenju zaštite i stvaranju vjerodostojne i sigurne AI takvi sustavi moraju biti „utrenirani", ali na način da se svi korišteni podaci čuvaju u skladu s postojećom zakonskom regulativom i prilagođavaju novim regulatornim okvirima koji će tek nastati. U tu svrhu zakonodavni okvir prema Izvješću 65 morao bi propisati nužnost čuvanja:

- točnih zapisa o skupu podataka koji se koriste za učenje i testiranje sustava AI, uključujući opis glavnih karakteristika i način odabira skupa podataka,
- u određenim opravdanim slučajevima skupova podataka i
- dokumentaciju o programskim metodama i metodologijama obuke, procesima i tehnikama koje se koriste za izradu, testiranje i vrednovanje sustava AI.

Takvi zapisi bi mogli biti zadržani od strane nadležnih tijela kako bi se osigurala učinkovita primjena određenog zakona. Također, važno je naglasiti stav Komisije o budućem regulatornom okviru, da se svaka obveza treba odnositi na one pojedince ili poduzeća koji su u prednosti pri donošenju odgovora na moguće rizike. Na primjer, iako su programeri sustava AI možda u najboljem položaju da se bave rizicima koji proizlaze iz razvojne faze, njihova sposobnost nadzora rizika tijekom faze korištenja može biti ograničena. U tom bi slučaju oni koji određenu uslugu korištenjem AI stavljaju na tržište trebali snositi dio odgovornosti. Na taj način odgovornost bi prema krajnjim korisnicima bila zagarantirana, a omogućila bi se i podloga za pravnu odgovornost vlasnika sustava AI. Kako bi se AI učinila pouzdanom i sigurnom moraju se ispuniti zahtjevi određeni u zakonskim regulativama te omogućiti i

[202] *Loc.cit.*

učinkovitu primjenu akata od strane nadležnih tijela. Nadležna tijela moraju biti u mogućnosti istražiti pojedinačne slučajeve, ali i procijeniti utjecaj na društvo. Također, Komisija navodi kako je nužno uspostaviti europsku upravljačku strukturu za sustave AI na način da se donese relevantan okvir za suradnju nacionalnih i međunarodnih nadležnih tijela. Na taj način ostvarit će se zajedništvo po pitanju djelovanja u određivanju odgovornosti, ali i omogućiti stvaranje kvalitetne infrastrukture za testiranje i certifikaciju sustava AI. Naravno, Izvješće 64 predstavlja okvir djelovanja za svaki pojedini sektor u kojem će se koristiti takvi sustavi što se odnosi i na nadležne organizacije u pomorstvu, pritom misleći ponajprije na IMO.[203]

Ovakav stav Komisije zasigurno će rezultirati promjenama u postojećim regulacijama i iziskuje zakonodavnu prilagodbu sustava na sustav AI.

2.13. IZVJEŠĆE O SIGURNOSTI I ODGOVORNOSTI ZA UMJETNU INTELIGENCIJU, INTERNET STVARI I ROBOTIKU

Komisija je u veljači 2020. godine izdala dokument prema Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija pod nazivom „Izvješće o sigurnosti i odgovornosti za AI, IoT i robotiku“ (Izvješće 64)[204] s ciljem prepoznavanja važnosti i potencijala modernih tehnologija poput AI, IoT ili robotike i potrebe za značajnim ulaganjima u ta područja. Ciljem Komisije prema Izvješću 64 može se smatrati donošenje i usuglašavanje pravnog okvira za sigurnost i odgovornost na način da svi proizvodi i usluge, uključujući one koje integriraju nove digitalne tehnologije djeluju sigurno, pouzdano i dosljedno. U kontekstu važnih karakteristika modernih tehnologija poput AI, IoT i robotike navode se kombinacija povezanosti, autonomije i ovisnosti o BD za obavljanje zadataka s potpunim ili djelomičnim ljudskim nadzorom. Ogromna količina uključenih podataka i algoritamska ovisnost AI u procesu donošenja odluka otežavaju predviđanje ponašanja proizvoda koji koriste sustave AI i razumijevanje mogućih uzroka štete. Naravno, takav način povezanosti proizvoda otvara mogućnost kibernetičkih ugroza što se želi spriječiti već pri samom modeliranju sektorski posebnih proizvoda. Osim navedenih karakteristika modernih tehnologija, Izvješće 64 navodi i potencijalne prilike koje pruža sama tehnologija. To se odnosi na povećanje povjerenja i društvene prihvaćenosti novih tehnologija od strane korisnika, poboljšanje proizvoda, procesa

[203] *Ibid*, str. 22.
[204] Izvješće Komisije Europskom parlamentu, Vijeću i Europskom gospodarskom i socijalnom odboru - Izvješće o utjecaju umjetne inteligencije, interneta stvari i robotike na sigurnost i odgovornost, COM/2020/64 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/ALL/?uri=COM%3A2020%3A0064%3AFIN

i poslovnih modela te povećanje učinkovitosti. Jedna od glavnih značajki navedenih proizvoda smatra se mogućnost povezivanja, ali takva značajka može uzrokovati ugrožavanje sigurnosti prilikom možebitnih upada u sustave. Kao primjer tome na europskom sustavu upozorenja o opasnostima neprehrambenih proizvoda može se naći značajan broj obavijesti od različitih europskih država.[205]

Kada je riječ o odgovornosti modernih tehnologija Izvješće 64 navodi kako se okviri odgovornosti u EU oslanjaju na primjenu Direktive Vijeća o približavanju zakona i drugih propisa država članica u vezi s odgovornošću za neispravne proizvode[206] koja usklađuje odgovornost proizvođača neispravnih proizvoda i druge neusklađene nacionalne režime odgovornosti.[207] Navedena direktiva pruža sloj sigurnosti u smislu uvođenja sustava stroge odgovornosti proizvođača za štetu uzrokovanu neispravnošću njihovih proizvoda. U slučaju fizičke ili materijalne štete oštećenik ima pravo na naknadu ako dokaže štetu odnosno nedostatak na proizvodu i uzročno-posljedičnu vezu između neispravnog proizvoda i oštećenja. S druge pak strane, nacionalni neusklađeni režimi sadrže pravila odgovornosti na temelju krivnje prema kojima oštećenici moraju dokazati krivnju proizvođača, štetu i uzročno posljedičnu vezu između krivnje i štete. U tom smjeru se kreću i odredbe Zakona o obveznim odnosima (ZOO).[208] Sustavi AI često su dio IoT gdje dolazi do međusobne interakcije više različitih povezanih uređaja i njihovih usluga. Takva kombinacija digitalnih komponenti može znatno otežati procjenu odakle potječe potencijalna šteta i tko je za nju odgovoran. Zbog složenosti ovih tehnologija oštećenici ponekad mogu vrlo teško identificirati odgovornu osobu i dokazati štetu sukladno nacionalnom zakonodavstvu. Samim time, troškovi procjene odgovornosti u postupku dokazivanja štete mogu biti nerazmjerno visoki i negativno utjecati na oštećenike u traženju naknade. Uz navedeno, proizvodi i usluge koji se oslanjaju na AI će u svom prijelaznom razdoblju komunicirati s tradicionalnim tehnologijama što dovodi do dodatne

---

[205] Više o sustavu na: Više o sustavu vidjeti Safety Gate: the rapid alert system for dangerous non-food products, dostupno na: https://ec.europa.eu/consumers/consumers_safety/safety_products/rapex/alerts/repository/content/pages/rapex/index_en.htm

[206] Direktiva Vijeća br. 85/274 od 25. srpnja 1985. o približavanju zakona i drugih propisa država članica u vezi s odgovornošću za neispravne proizvode, OJ L 210, str. 29-33.; Direktiva 1999/34/EZ Europskog parlamenta i Vijeća od 10. svibnja 1999. o izmjeni Direktive Vijeća 85/374/EEZ o usklađivanju zakona i drugih propisa država članica u vezi s odgovornošću za neispravne proizvode, OJ L 141, str. 20-21. (Direktiva 1999/34)

[207] Više o tome vidjeti: Petrić, S. (2001). Odgovornost proizvođača za štete od nedostataka na proizvodu u hrvatskom pravu i pravu Europske unije, Zbornik radova Pravnog fakulteta u Splitu, 4, 64, str. 371-396.; Bevanda, M. (2006). Odgovornost za štetu izazvanu neispravnim proizvodom u hrvatskom i bosanskohercegovačkom pravu, Zbornik Pravnog fakulteta Sveučilišta u Rijeci, Vol. 28, No. 1, str. 587-632.

[208] Čl. 1073. Zakona o obveznim odnosima (NN, br. 35/05, 41/08, 125/11, 78/15, 29/18, 126/21)

složenosti kada je u pitanju odgovornost. Primjerice, autonomna vozila će dijeliti cestu s tradicionalnim vozilima određeno vrijeme ili će se interakcija pak pojaviti u nekim uslužnim sektorima poput upravljanja prometom i zdravstva, gdje će djelomično automatizirani sustavi AI podržati ljudsko odlučivanje. Prema Izvješću stručne skupine za odgovornost i nove tehnologije[209] mogu se razmotriti prilagodbe nacionalnih zakona kako bi se oštećenicima olakšao teret dokazivanja zbog štete nastale korištenjem proizvoda s AI. Primjerice, teret dokazivanja može ovisiti o usklađenosti posebnih kibernetičkih ili drugih sigurnosnih obveza utvrđenih zakonom što znači da u slučaju nepridržavanja traženih propisa može doći do izmjene tereta dokazivanja. Proces odgovornosti za takve operacije na razvoj i prihvaćanje AI mora biti pažljivo ocijenjen i temeljen na procjeni rizika.

Stoga, sukladno Izvješću 64 trenutno zakonodavstvo o sigurnosti proizvoda sadrži brojne nedostatke koje je potrebno riješiti te bi se budući rad na prilagodbi različitih zakona u ovom okviru trebao odvijati na dosljedan i usklađen način. Novi izazovi u pogledu sigurnosti stvaraju i nove izazove u pogledu odgovornosti.

2.14. KOORDINIRANI PLAN O UMJETNOJ INTELIGENCIJI

Koordinirani plan o AI (KP)[210] je dokument kojeg je Komisija u prosincu 2018. godine izdala u Komunikaciji Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija. KP je donesen s ciljem maksimalnog povećanja ulaganja i učinka tehnologije na međunarodnoj i nacionalnoj razini te poticanja suradnje država članica EU u razmjeni prakse i definiranju nužnih zajedničkih koraka u kontekstu razvoja i implementacije AI. KP-om se predviđa donošenje okvira za nacionalne strategije u području AI kojim se države članice potiču na donošenje istih. U tu svrhu Komisija u suradnji s državama članicama dogovara zajedničke pokazatelje za praćenje razvoja i korištenja AI, a sve uz potporu tzv. „*AI Watch*“ istraživačkog centra.[211] Stoga, prijedlog Komisije je da u sljedećem programskom razdoblju 2021. – 2027. EU ulaže u AI najmanje 1 milijardu eura godišnje iz programa Obzor

[209] Više vidjeti: Report from the Expert Group on Liability and New Technologies – New Technologies Formation. (2019). Liability for Artificial Intelligence and other emerging digital technologies, dostupno na: https://ec.europa.eu/newsroom/dae/document.cfm?doc_id=63199

[210] Komunikacija Komisije Europskom parlamentu, Europskom vijeću, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Kordinirani plan o umjetnoj inteligenciji, COM(2018) 795 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:52018DC0795

[211] Više o centru: AI Watch, Monitor the development, uptake and impact of Artificial Intelligence for Europe, dostupno na: https://ec.europa.eu/knowledge4policy/ai-watch_en

Europa i Digitalna Europa.[212] Velik dio ulaganja trebao bi se odnositi na eksperimentiranje i ispitivanje modernih tehnologija u stvarnom okružju. U tom kontekstu, optimizacija ulaganja bi značila i razvijanje posebnih referentnih mjesta za AI kao objekata za ispitivanja i eksperimentiranja u određenom sektoru pod stvarnim ili gotovo stvarnim uvjetima (pametna bolnica, čisti prostori, pametni grad, eksperimentalno poljoprivredno gospodarstvo, koridor za umreženu i automatiziranu vožnju itd.). Primjeri takvih objekata za ispitivanja uključuju prekogranično testiranje umrežene i autonomne vožnje, mjesta za testiranje autonomnih brodova i stvaranje podatkovnih prostora.[213]

Samim time, program Digitalna Europa za kojeg se zalaže Komisija treba pridonijeti uspostavi već prije navedenih digitalno-inovacijskih centara diljem Europe, a Europa će osigurati do 900 milijuna eura za potporu razvoja tih centara. Pojedinačni doprinosi država članica u razvoju centara bi trebali biti također do 900 milijuna eura te bi se u određenom stupnju razvoja trebala osigurati potpora za do 10 000 SME.[214] Sukladno KP istraživanja i ulaganja u sustave AI potrebno je osnažiti i kroz rješenja o lancu blokova i ostalim sigurnim rješenjima za pristup podataka, industrijske podatkovne platforme, zdravstvo, centre za razmjenu podataka i Europsku inicijativu za računalstvo visokih performansi. KP-om se ističe i nužnost prikladnog etičkog i regulatornog okvira uz oslanjanje na zaštitu temeljnih ljudskih prava i sloboda kako bi građani imali povjerenja u AI. Osim toga, zbog rastuće primjene AI u javnom sektoru etička i pravna pitanja će pronaći svoj put prema javnosti te će na njih trebati pravovremeno i odgovoriti. Nije zanemariva ni primjena AI u sustavima naoružanja gdje može doći do značajnih promjena u raznim oružanim sukobima. Međunarodno pravo s međunarodnim humanitarnim pravom koje je primijenjeno u dosadašnjim sustavima će trebati predstavljati oslonac i u budućim sustavima naoružanja uključujući sustave autonomnog oružja. Države moraju i dalje biti odgovorne za postupanja tijekom sukoba nevezano za vrstu upotrijebljene tehnologije.[215]

Može se zaključiti da je stav EU o ljudskoj kontroli prilikom donošenja odluka o korištenju smrtonosne sile i dalje nepromijenjen i stavlja čovjeka na funkciju donositelja odluka. Takav stav mora biti „utkan“ i u svaki sustav naoružanja koji je potpomognut s AI i to za vrijeme cijelog životnog ciklusa takvog sustava.

---

[212] KP, str. 3.
[213] *Ibid*, str. 4-5.
[214] Prilog KP, str. 11.
[215] *Ibid*, str. 8-9.

2.15. PRIJEDLOG UREDBE EUROPSKOG PARLAMENTA I VIJEĆA – POSTAVLJANJE USKLAĐENIH PRAVILA O UMJETNOJ INTELIGENCIJI (ZAKON O UMJETNOJ INTELIGENCIJI) I IZMJENI I DOPUNI ODREĐENIH ZAKONODAVNIH AKATA UNIJE

Nakon donošenja Bijele knjige Komisija je započela intenzivnu suradnju s različitim dionicima koji su u velikoj mjeri podržavali regulatorne intervencije u rješavanju izazova i zabrinutosti zbog sve veće upotrebe AI. Tako je nastao Prijedlog Uredbe Europskog parlamenta i Vijeća – Postavljanje usklađenih pravila o AI (akt o umjetnoj inteligenciji) i izmjeni i dopuni određenih zakonodavnih akata EU (Prijedlog).[216] Ovaj dokument odgovara na izričite zahtjeve Europskog parlamenta i Vijeća, koji su više puta izrazili pozive na zakonodavne mjere kako bi se osiguralo dobro funkcioniranje unutarnjeg tržišta za sustave AI, a sve u interesu tehnološkog vodstva EU. Što se tiče sadržaja samog Prijedloga u naslovu I. pod nazivom Područje primjene i definicije, definira se predmet regulacije i opseg primjene novih pravila koja pokrivaju stavljanje na tržište, stavljanje u upotrebu i uporabu sustava AI. Definicija sustava AI[217] u pravnom okviru želi biti što više tehnološki neutralnija, uzimajući u obzir brzi tehnološki i tržišni razvoj povezan s AI. Ključni sudionici u lancu vrijednosti AI također su jasno definirani, poput pružatelja i korisnika sustava AI koji pokrivaju i javne i privatne operatore kako bi osigurali jednake uvjete.[218]

U drugom dijelu Prijedloga koji nosi naziv Zabranjene prakse u području AI, uspostavlja se popis zabranjenih postupaka onih sustava AI čija se uporaba smatra neprihvatljivom te je u suprotnosti s vrijednostima EU, na primjer kršenjem temeljnih prava. Prijedlog slijedi pristup zasnovan na riziku, razlikujući upotrebu AI koja stvara (i) neprihvatljiv rizik, (ii) visok rizik i (iii) nizak ili minimalan rizik. Zabrane obuhvaćaju prakse koje imaju značajan potencijal za manipuliranje osobama putem subliminalnih tehnika izvan njihove svijesti ili iskorištavanje ranjivosti određenih ranjivih skupina, poput djece ili osoba s invaliditetom, kako bi se njihovo ponašanje materijalno iskrivilo na način koji bi im mogao prouzročiti psihološke ili fizičke boli. Prijedlog također zabranjuje socijalno bodovanje temeljeno na AI za opće svrhe koje rade javne

[216] Proposal for a Regulation of the European Parliament and of the Council - Laying Down Harmonised Rules On Artificial Intelligence (Artificial Intelligence Act) and Amending Certain Union Legislative Acts, {SEC(2021) 167 final} - {SWD(2021) 84 final} - {SWD(2021) 85 final}, COM(2021) 206 final

[217] Prema čl. 3. st. 1. Prijedloga sustav AI znači softver koji je razvijen s jednom ili više tehnika i pristupa navedenih u Prilogu I. i može za zadani skup ciljeva koje definira čovjek generirati rezultate kao što su sadržaj, predviđanja, preporuke ili odluke koje utječu na okruženja s kojima komuniciraju.

[218] Točka 5.2.1. Prijedloga

vlasti. Konačno, zabranjena je i upotreba sustava za biometrijsku identifikaciju u stvarnom vremenu u javno dostupnim prostorima u svrhu provođenja zakona, osim ako se ne primjenjuju određene ograničene iznimke.[219]

Treći naslov Prijedloga pod nazivom Visokorizični AI sustavi sadrži posebna pravila za sustave AI koji stvaraju visoki rizik za zdravlje i sigurnost ili temeljna prava fizičkih osoba. U skladu s pristupom temeljenog na riziku ti visoko rizični sustavi AI dopušteni su na europskom tržištu pod uvjetom da ispunjavaju određene obvezne zahtjeve i *ex-ante* ocjenu sukladnosti. Stoga klasifikacija kao visoko rizična ne ovisi samo o funkciji koju obavlja sustav AI, već i o specifičnoj namjeni i modalitetima za koje se taj sustav koristi. Poglavlje 1. naslova III postavlja pravila klasifikacije i identificira dvije glavne kategorije visoko rizičnih sustava AI:

• sustavi AI namijenjeni korištenju kao sigurnosna komponenta proizvoda koji su predmet *ex-ante* procjene sukladnosti treće strane;

• drugi samostalni sustavi AI s implikacijama uglavnom na temeljna prava koji su izričito navedeni u Prilogu III.[220]

Naslov IV. pod nazivom Obveze u pogledu transparentnosti za određene AI sustave odnosi se na određene sustave AI kako bi se uzeli u obzir specifični rizici manipulacije koje predstavljaju. Obveze transparentnosti primjenjivat će se na sustave koji (i) komuniciraju s ljudima, (ii) se koriste za otkrivanje emocija ili utvrđivanje povezanosti s (društvenim) kategorijama na temelju biometrijskih podataka ili (iii) generiraju ili manipuliraju sadržajem („duboke lažne radnje“). Kada osobe stupe u interakciju sa sustavom AI ili se njihove emocije ili karakteristike prepoznaju automatiziranim sredstvima, ljudi moraju biti obaviješteni o toj okolnosti. Ako se sustav AI koristi za generiranje ili manipulaciju slikovnim, audio ili video sadržajem koji znatno podsjeća na autentični sadržaj, trebala bi postojati obveza otkrivanja da se sadržaj generira automatiziranim sredstvima, podliježući iznimkama u legitimne svrhe (provođenje zakona, sloboda izražavanja). To omogućava osobama da donose informirane odluke ili se odmaknu od date situacije.[221]

Naslov V. pod nazivom Mjere za potporu inovacijama doprinosi cilju stvaranja pravnog okvira koji je pogodan za inovacije, otporan na budućnost i otporan na poremećaje. U tu svrhu potiču se nacionalna nadležna tijela da uspostave regulatorne okvire i osnovni okvir u pogledu

[219] Točka 5.2.2. Prijedloga
[220] Točka 5.2.3. Prijedloga
[221] Točka 5.2.4. Prijedloga

upravljanja, nadzora i odgovornosti AI. Naslov V. također sadrži mjere za smanjenje regulatornog opterećenja za mala i srednja poduzeća i novoosnovana poduzeća.[222]

Naslov VI., VII. i VIII. pod nazivom Upravljanje i provedba uspostavljaju sustave upravljanja AI na razini EU i na nacionalnoj razini. Na razini EU prijedlogom se uspostavlja Europski odbor za AI sastavljen od predstavnika država članica i Komisije. Odbor će omogućiti nesmetanu, učinkovitu i usklađenu provedbu ove uredbe doprinoseći djelotvornoj suradnji nacionalnih nadzornih tijela i Komisije te pružajući savjete i stručnost Komisiji. Također će prikupljati i dijeliti najbolje prakse među državama članicama. Na nacionalnoj razini države članice će morati odrediti jedno ili više nacionalnih nadležnih tijela, a među njima i nacionalno nadzorno tijelo, u svrhu nadzora primjene i provedbe propisa. Europski nadzornik za zaštitu podataka djelovat će kao nadležno tijelo za nadzor institucija, agencija i tijela EU kada spadaju u područje primjene ove uredbe.[223]

Naslov IX. pod nazivom Kodeksi ponašanja stvara okvir za stvaranje kodeksa ponašanja kojem je cilj potaknuti pružatelje ne-rizičnih sustava AI da dobrovoljno primjenjuju obvezne zahtjeve za visoko-rizične sustave AI. Pružatelji ne-rizičnih sustava AI mogu sami stvoriti i provoditi kodekse ponašanja. Ti kodeksi mogu također uključivati dobrovoljne obveze povezane, na primjer, s održivošću okoliša, pristupačnošću za osobe s invaliditetom, sudjelovanjem dionika u dizajnu i razvoju sustava AI i raznolikošću razvojnih timova.[224]

Naslov X., XI. i XII. pod nazivom Završne odredbe naglašavaju obvezu svih strana da poštuju povjerljivost podataka i utvrđuju pravila za razmjenu informacija dobivenih tijekom

---

[222] Točka 5.2.5. Prijedloga

[223] Naslov VII. ima za cilj olakšati nadzorni rad Komisije i nacionalnih vlasti uspostavljanjem baze podataka na razini cijele EU za samostalne visoko rizične sustave AI uglavnom s implikacijama na temeljna prava. Bazom podataka upravljat će Komisija, a podatke će joj pružati pružatelji sustava AI koji će trebati registrirati svoje sustave prije nego što ih stave na tržište ili na drugi način puste u upotrebu.
Naslov VIII. utvrđuje obveze praćenja i izvješćivanja za pružatelje sustava AI s obzirom na praćenje i izvješćivanje i istragu o incidentima i neispravnostima povezanih s AI i nakon njih. Tijela za nadzor tržišta također bi kontrolirala tržište i istraživala poštivanje obveza i zahtjeva za sve rizične sustave AI koji su već stavljeni na tržište. Tijela za nadzor tržišta imala bi sve ovlasti prema Uredbi (EU) 2019/1020 Europskog parlamenta i Vijeća od 20. lipnja 2019. o nadzoru tržišta i sukladnosti proizvoda i o izmjeni Direktive 2004/42/EZ i uredbi (EZ) br. 765/2008 i (EU) br. 305/2011, OJ L 169. Naknadna provedba trebala bi osigurati da nakon što se sustav AI stavi na tržište tijela javne vlasti imaju ovlasti i resurse da interveniraju u slučaju da sustavi AI generiraju neočekivane rizike što zahtijeva brzo djelovanje. Prijedlog ne predviđa automatsko stvaranje bilo kakvih dodatnih tijela ili tijela na razini država članica. Države članice stoga mogu imenovati (i oslanjati se na stručnost) postojećih sektorskih tijela kojima bi se također povjerile ovlasti nadgledanja i provođenja odredbi uredbe. Točka 5.2.6. Prijedloga

[224] Točka 5.2.7. Prijedloga

provedbe propisa. Naslov X. također uključuje mjere kojima se osigurava učinkovita provedba propisa učinkovitim, razmjernim i odvraćajućim kaznama za kršenje odredbi.[225]

2.16 AKTIVNOSTI UJEDINJENIH NARODA NA PODRUČJU UMJETNE INTELIGENCIJE

U posljednje vrijeme AI je tema koja najviše okupira maštu javnosti, a posebno u dijelu gdje se smatra da može transformirati čovječanstvo. Sukladno nastalim trendovima u gospodarstvu i ubrzanom razvoju IT sektora, UN je izdao publikaciju *UN activities on AI*[226] o djelovanju preko 35 agencija i tijela UN-a na području AI s ciljem opisivanja korištenja AI i suočavanja s izazovima u svijetu. Važnost AI očituje se kroz prizmu djelovanja raznih organizacija u vlastitim sektorima uz pomoć AI. Tako su svoja djelovanja opisali i agencije poput ILO, Organizacija za prehranu i poljoprivredu (engl. *Food and Agriculture organization),* Međunarodna organizacija za migracije (engl. *International organization for Migration*), Međunarodna telekomunikacijska unije (engl. *International Telecommunication Union*), Organizacija međunarodnog civilnog zrakoplovstva (engl. *International Civil Aviation Organization*) i ostali. Međutim, u ovom poglavlju opisat će se samo djelovanja i program opisan kroz IMO koji je također sastavni dio ove publikacije. Opis djelovanja IMO-a u području AI očituje se kroz pet projekata:

- digitalizacija transporta / suradnja s lukama i jedinstvenim pomorskim prozorom,[227]
- MASS,
- e – navigacija,
- zaštita morskog okoliša i AI i
- digitalni pregled.[228]

---

[225] Naslov XI utvrđuje pravila za izvršavanje delegiranja i provedbenih ovlasti. Prijedlog ovlašćuje Komisiju da prema potrebi donese provedbene akte kako bi se osigurala jedinstvena primjena uredbe ili delegiranih akata za ažuriranje ili dopunu popisa u Prilozima od I do VII. Naslov XII sadrži obvezu Komisije da redovito procjenjuje potrebu za ažuriranjem Priloga III i da priprema redovita izvješća o ocjeni i pregledu uredbe. Također se utvrđuju konačne odredbe, uključujući diferencirano prijelazno razdoblje za početni datum primjene propisa kako bi se olakšala nesmetana provedba svih zainteresiranih strana. Točka 5.2.8. Prijedloga

[226] UN activities on AI (2018), dostupna na: https://www.itu.int/dms_pub/itu-s/opb/gen/S-GEN-UNACT-2018-1-PDF-E.pdf

[227] Jedinstveni prozor (engl. *Single window*) se odnosi na koncept jednostruke suradnje poduzeća u specifičnom sektoru i vlasti koja nadzire taj sektor. S obzirom da se u ovom kontekstu to odnosi na pomorsko gospodarstvo, možemo ga nazvati jedinstveni pomorski prozor (engl. *Maritime Single Window*). Pregled rada IMO-a na elektroničkom poslovanju/e-certifikatima, jedinstveni pomorski prozor vidjeti Electronic exchange of information/Electronic data exchange, IMO, dostupno na: http://www.imo.org/en/OurWork/Facilitation/Electronic%20Business/Pages/default.aspx

[228] *UN Activities on AI,* str. 18.-21.

Sukladno Konvenciji o olakšicama u međunarodnom pomorskom prometu (engl. *Convention on facilitations of International Maritime Traffic* - FAL)[229] novi uvjet za sve javne vlasti je da uspostave sustave za elektroničku razmjenu podataka koji se odnose na pomorski promet i koji bi kao takav trebao predstavljati značajan pomak pomorske industrije i luka prema digitalnom pomorskom svijetu. Na taj način bi se smanjio administrativni teret i povećala učinkovitost pomorske trgovine i prometa. Novi zahtjevi stupili su na snagu 8. travnja 2019. i zahtijevaju od nacionalnih vlada da uvedu elektroničku razmjenu podataka između brodova i luka. Preporučuje se uspostava jedinstvenog pomorskog prozora. Cilj je pojednostaviti prekograničnu trgovinu i logistički lanac za više od 10 milijardi tona robe kojom se godišnje trguje morem širom svijeta. Jačanje suradnje i partnerstva između luka i brodova od presudne je važnosti za UN-ov cilj održivog razvoja br. 13. (engl. *Sustainable Development* - SD13) jer brodovi troše oko 15 % svog ukupnog goriva tijekom boravka u luci. Ističući važnost partnerstva broda i luke posebno prema SD13, IMO je nedavno pozvala države članice da potaknu dobrovoljnu suradnju lučkog i pomorskog sektora kako bi doprinijele smanjenju emisija stakleničkih plinova iz brodova.[230] Prema IMO-u to bi trebalo uključivati regulatorne, tehničke, operativne i gospodarske radnje poput pružanja:

- opskrbe električnom energijom na kopnu (po mogućnosti iz obnovljivih izvora),
- sigurnih i učinkovitih alternativnih goriva s niskim emisijama ugljikovog dioksida,
- poticaja za promicanje održive otpreme goriva s niskim emisijama ugljikovog dioksida i
- podrške za optimizaciju lučkih poziva, uključujući omogućavanje pravovremenog dolaska brodova.[231]

FAL potiče upotrebu „jedinstvenog pomorskog prozora“ za podatke kako bi se omogućilo da se putem jedinstvenog portala bez dupliciranja predaju sve informacije koje zahtijevaju javna tijela u vezi s dolaskom, boravkom i odlaskom brodova, osoba i tereta. Uspješan projekt IMO-a koji je Norveška promovirala za uspostavljanje pomorskog "jedinstvenog prozora" u Antigvi i Barbudi završen je 2019. godine, a izvorni kôd za sustav sada će biti dostupan drugim

[229] Usvojena 9. travnja 1965., a stupila na snagu 5. ožujka 1967. Više na: https://www.imo.org/en/About/Conventions/Pages/Convention-on-Facilitation-of-International-Maritime-Traffic-(FAL).aspx

[230] Vidjeti više: Primorac, Ž. (2020). Suvremeni pravni izazovi smanjenja emisija stakleničkih plinova iz pomorskog prometa - međunarodna i europska perspektiva, Zbornik radova Pravnog fakulteta u Splitu, 57, 3, str. 739-757.

[231] Više o IMO i UN održivom razvoju vidjeti na: https://wwwcdn.imo.org/localresources/en/MediaCentre/HotTopics/Documents/IMO%20SDG%20Brochure.pdf

zemljama kojima je potreban. 101. zasjedanje IMO-ovog MSC-a 2019. godine odobrilo je inicijalni skup vježbi za provođenje ispitivanja MASS-a,[232] predviđajući da se ispitivanja moraju provoditi na način koji osigurava barem isti stupanj sigurnosti, ali i zaštite okoliša kako je predviđeno odgovarajućim instrumentima. Rizici povezani s ispitivanjima trebaju biti na odgovarajući način identificirani i trebaju se poduzeti mjere za smanjenje rizika na najmanju moguću mjeru.[233] Također, jedan od projekata odnosi se i na elektroničku navigaciju (e-navigaciju) koja je definirana kao "usklađeno prikupljanje, integracija, razmjena, predstavljanje i analiza pomorskih informacija na brodu i obali elektroničkim putem kako bi se poboljšala plovidba vezom i srodnim uslugama sigurnosti i zaštite na moru i zaštite morskog okoliša".[234]

Unutar Svjetskog industrijskog udruženja (engl. *Global Industry Alliance* - GIA) IMO radi na promicanju brodova koji stižu na vrijeme kroz korištenje AIS podataka i podataka koji se odnose na luke s ciljem smanjenja potrošnje goriva i emisija stakleničkih plinova u lukama. U ovu inicijativu uključena su brojna pomorska poduzeća. IMO je bila aktivna u razvoju alata za podršku u odlučivanju pri praćenju i primjeni odluka utemeljenih na riziku za rješavanje problema pomorske biološke sigurnosti, a to je rezultiralo razvojem alata za procjenu rizika "*GloBallast*".[235]

Aktivnosti će sada biti proširene na novi *GloFouling* projekt koji će se baviti morskim biološkim organizmima. Jedan od važnih projekata u budućnosti će svakako biti vezan za AI u sklopu održivog pomorskog prometa (AI - SMART), odnosno o mogućnosti suradnje privatnog pomorskog sektora i pružatelja rješenja za AI čime bi se, između ostalog, omogućilo i zemljama u razvoju da se pripreme za rješenja vezana uz AI u pomorskom sektoru.

Sukladno navedenom, uočava se važnost UN-a u usmjeravanju i razvoju percepcije primjene AI u općenitom smislu kao i u posebnim primjenama poput pomorskog prometa.

---

[232] Dostupno na: https://www.register-iri.com/wp-content/uploads/MSC.1-Circ.1604.pdf

[233] Više o tome: Maritime Safety Committee (MSC), 101 session, 5-14 June 2019, dostupno na: http://www.imo.org/en/MediaCentre/MeetingSummaries/MSC/Pages/MSC-101st-session.aspx

[234] *Ibid.*

[235] Od 2000. godine, vođeni željom za ublažavanjem utjecaja štetnih vodenih invazija, Program UN-a za razvoj (UNDP), Globalni fond za zaštitu okoliša (GEF) i IMO surađivali su u okviru projekta *GloBallast Partnerships* kako bi poticali međunarodnu i javno-privatnu suradnju u području upravljanja balastnim vodama.
Reflektirajući se na složenost upravljanja balastnim vodama *GloBallast* je postao jedan od najdugovječnijih programa u okviru GEF-a, protežući se u razdoblju od 2000. do 2017. u dvije faze (2000.-2004. i 2007.-2017.). Prva faza, Globalni program upravljanja balastnim vodama (*GloBallast*), pomogla je šest zemalja u razvoju (Brazil, Kina, Indija, Islamska Republika Iran, Južna Afrika i Ukrajina) u provedbi učinkovitih mjera za kontrolu unošenja stranih morskih vrsta. O tome više: https://www.imo.org/en/OurWork/PartnershipsProjects/Pages/GloBallast-Programme.aspx

2.17 JAČANJE KIBERNETIČKE SIGURNOSTI EUROPSKE UNIJE

Kibersigurnost je ključan element digitalnog djelovanja zaštite života od izloženosti digitalnim sferama. Stoga su Komisija i Visoki predstavnik EU za vanjske poslove i sigurnosnu politiku izdali u rujnu 2019. godine zajedničku Komunikaciju prema Europskom parlamentu i Vijeću nazvanu „Otpornost, odvraćanje i obrana: jačanje kibernetičke sigurnosti EU“ (dalje u tekstu: Zajednička komunikacija).[236]

Rizici koje kibersigurnosne prijetnje predstavljaju mogu imati značajne utjecaje na mnoge gospodarske grane, a istraživanja iz razdoblja od 2013. do 2017. pokazuju peterostruko povećanje rizika za taj period.[237] U recentnim primjerima značajna je upotreba ucjenjivačkih softvera poput „*Wannacry*“[238] i „*Petya*“[239] koji ograničavaju uporabu digitalnog medija sve dok se ne plate otkupnine. Međutim, važno je naglasiti kako ucjenjivački softveri nisu ni izdaleka jedina prijetnja. Kiberprostor se koristi za razne geopolitičke ciljeve, ratovanje, provođenje hibridnih taktika, stvaranje raznih digitalnih ugroza, krađu podataka, dezinformiranje, pa čak i uplitanje u nacionalne demokratske postupke. Poimanje stvarnosti sigurnosnih prijetnji leži u shvaćanju proporcionalnog rasta rizika s povećanjem digitalne preobrazbe. Kroz 2020. godinu smatra se da će na Internet biti povezano nekoliko desetaka milijardi uređaja iz skupine IoT te da sigurnost u digitalnom okruženju nije prioritet u samom kreiranju uređaja.[240] Kroz Zajedničku komunikaciju Europa se zalaže za stvaranje obuhvatnijeg pristupa u kreiranju otpornosti sustava od kibernetičkih ugroza. To podrazumijeva odgovor na kibernapade u državama članicama, ali i u institucijama, agencijama i tijelima EU prema kojima će se opet definirati sektorsko djelovanje u jačanju kibernetičke sigurnosti i znatno poboljšanje tehničkih elemenata u zaštiti i obrazovanju stručnjaka. Ključnu ulogu u tom procesu imat će Agencija EU

---

[236] Zajednička Komunikacija Europskom parlamentu i Vijeću - Otpornost, odvraćanje i obrana: jačanje kibersigurnosti EU-a, JOIN/2017/0450 final/2

[237] *McAfee* i Centar za strateške i međunarodne studije „Neto gubici: procjena troškova kiberkriminaliteta na svjetskoj razini”. Net losses: Estimating the Global Cost of Cybercrime, Economic impact of cybercrime II, Report Summary, dostupno na: https://csis-website-prod.s3.amazonaws.com/s3fs-public/legacy_files/files/attachments/140609_McAfee_PDF.pdf

[238] *WannaCry* je crv otkupljivač koji se brzo proširio nizom računalnih mreža u svibnju 2017. Nakon zaraze računala sa sustavom *Windows* šifrira datoteke na tvrdom disku računala, onemogućujući pristup korisnicima, a zatim zahtijeva plaćanje otkupnine u *bitcoinima* kako bi ih dešifrirali. Više o tome: Fruhlinger, J. (2018). What is WannaCry ransomware, how does it infect, and who was responsible?, CSO, dostupno na: https://www.csoonline.com/article/3227906/what-is-wannacry-ransomware-how-does-it-infect-and-who-was-responsible.html

[239] Primjerice, slučaj „*Wannacry*“ je iskorišten za napad na preko 400.000 računala u više od 150 zemalja u 2017. godini, dok je svega godinu dana nakon napadnuta Ukrajina u slučaju „*Petya*“, ali i poveći broj poduzeća diljem svijeta. Više o tome: https://www.proofpoint.com/us/threat-reference/petya

[240] IDC and TXT Solutions (2014), *op.cit.*

za mrežu i informacijsku sigurnost (ENISA)[241] koja bi trebala imati nadzornu i savjetodavnu ulogu u provođenju Direktive 2016/1148. U tom kontekstu donesen je već navedeni Akt o kibernetičkoj sigurnosti kojim se po prvi puta uvode pravila na razini EU za kibersigurnosnu certifikaciju proizvoda, postupaka i usluga. Također, njime se uspostavio novi trajni mandat ENISA-e koji bi inače istekao u lipnju 2020. godine. Na taj način stvara se mehanizam za uspostavu europskih programa kibersigurnosne certifikacije, ali i ključne usluge u području informacijskih i komunikacijskih tehnologija. Sigurnosni certifikati će vrijediti u svim zemljama EU zbog čega će korisnici lakše stjecati povjerenje u te tehnologije, a poduzeća lakše poslovati preko granica. Primjena sigurnosnih certifikata je širokog spektra, a prema priopćenju Komisije obuhvaćat će, među ostalim, povezane igračke, pametne nosive uređaje, kontrolne sustave za industrijsku automatizaciju i pametne energetske mreže. Vijeće je 17. svibnja 2019. utvrdilo okvir kojim se omogućuje uvođenje ciljanih mjera ograničavanja za odvraćanje od kibernapada koji predstavljaju prijetnju EU ili njezinim državama članicama[242] te odgovor na njih, među ostalim u slučaju kibernapada protiv trećih zemalja ili međunarodnih organizacija kada se ograničene mjere smatraju potrebnima za postizanje ciljeva zajedničke vanjske i sigurnosne politike. U okviru uspostavljanja značajnog kibersigurnosnog okvira kroz Akt o kibernetičkoj sigurnosti omogućen je i novi režim sankcija koji se primjenjuje na kibernapade sa znatnim učinkom:[243]

- koji potječu ili su izvedeni iz područja izvan EU,
- za koje se upotrebljava infrastruktura izvan EU,
- koje izvode osobe ili subjekti koji djeluju izvan EU ili
- koji se izvode uz potporu osoba ili subjekata koji djeluju izvan EU.

Točnije rečeno, moguće je uvoditi sankcije i prema fizičkim i pravnim osobama koje su odgovorne za kibernapade ili pokušaje kibernapada ili one koji pružaju određeni vid potpore u tome (financijsku, tehničku ili materijalnu potporu takvim napadima ili koji su uključeni na druge načine). Također, sankcije se mogu odnositi i na sudionike u takvim napadima. Isto tako, s ciljem stvaranja boljeg kibernetičkog okruženja Vijeće je 19. lipnja 2017. donijelo „alat za

[241] Engl. *The European Union Agency for Cybersecurity*
[242] Odluka Vijeća (ZVSP) 2019/797 od 17. svibnja 2019. o mjerama ograničavanja protiv kibernapada koji predstavljaju prijetnju Uniji ili njezinim državama članicama, OJ L 129, str. 13-19.
[243] Više o tome vidjeti na: https://www.consilium.europa.eu/hr/press/press-releases/2019/05/17/cyber-attacks-council-is-now-able-to-impose-sanctions/

kiberdiplomaciju“,[244] odnosno okvir za doprinos poboljšanju suradnje, sprječavanju sukoba te ublažavanju mogućih kibernetskih prijetnji. U kontekstu stvaranja učinkovitijeg sigurnosnog kibernetičkog prostora Vijeće je 16. travnja 2018. usvojilo zaključke o zlonamjernim kiberaktivnostima gdje je naglasak stavljen na važnost globalnog, sigurnog i slobodnog kiberprostora, pri čemu treba naglasiti kako se u pogledu jačanja kibernetičke i sigurnosne infrastrukture kroz korporacije i sustave već koristi AI.[245] U praksi videozapisi na navedenoj platformi su pohranjeni na poslužitelju i analizira se sadržaj i kontekst gdje algoritmi AI šalju sigurnosna upozorenja kad god se pronađe nešto sumnjivo. Isto tako i Balbix-ova platforma[246] koristi predviđanja rizika utemeljena na AI kako bi zaštitila informacijsku infrastrukturu od ugrožavanja sigurnosti podataka i ostalih dijelova infrastrukture. Prema brojnim ekspertima za kibersigurnost AI će značajno poboljšati to područje. Neki od njih[247] navode sljedeća poboljšanja:

- alati AI nastavit će se poboljšavati pri izvlačenju skupova podataka potpuno različitih tipova omogućujući sastavljanje „veće slike“ iz, primjerice, statičkih konfiguracijskih podataka, povijesnih i lokalnih zapisa, kreiranje mape globalnih prijetnji i sl.;
- dionici će povećati uporabu AI za analizu obrambenih mehanizama i simulirati obrasce ponašanja kako bi zaobišli sigurnosne kontrole koristeći analitiku i ML kako bi mogli prodrijeti u ciljane organizacije;
- s obzirom na manjak resursa za sigurnosne radnje i veliku količinu podataka kroz koju većina organizacija pokušava raditi vjerojatno ćemo vidjeti organizacije koje traže AI/ML mogućnosti za automatizaciju svojih procesa za sigurnosne radnje;
- očekuje se i veća potreba za konkurentskim ML u borbi protiv korupcije u lancu opskrbe 2020. godine;

---

[244] Zaključci Vijeća o okviru za zajednički diplomatski odgovor EU-a na zlonamjerne kiberaktivnosti („Alati za kiberdiplomaciju”), od 19. lipnja 2017., 10474/17, dostupno na: https://data.consilium.europa.eu/doc/document/ST-10474-2017-INIT/hr/pdf

[245] Postoje brojni primjeri u kojima rješenja koja pokreću AI značajno poboljšavaju kibersigurnost. Pa tako primjerice *Gmail* koristi ML za blokiranje stotine milijuna neželjene pošte na dan, IBM-ov *Watson* kognitivni trening koristi ML za otkrivanje kiberprijetnji i mnoga druga rješenja za jačanje kibersigurnosti. *Google* također koristi AI za DL na svojoj platformi „*Cloud Video Intelligence*“.

[246] *Balbix* je prva svjetska platforma za kibernetsku sigurnost koja koristi specijaliziranu AI kako bi pružila uvid u stvarnom vremenu rizik od kršenja organizacije. Sustav *Balbix* predviđa gdje i kako će se vjerojatno dogoditi kršenja, propisuje prioritetne mjere za ublažavanje i omogućava tijekovima rada rješavanje osnovnih sigurnosnih problema. Dostupno na: https://www.businesswire.com/news/home/20200310005110/en/Balbix-Named-Hot-Security-Technology-of-the-Year-for-Industry-First-AI-Platform

[247] Nicko van Someren, Ph.D. and Chief Technology Officer at Absolute Software; Dr. Torsten George, Cybersecurity Evangelist at Centrify; Craig Sanderson, Vice President of Security Products at Infoblox; Josh Johnston, Director of AI, Kount; and Brian Foster, Senior Vice President Product Management at MobileIron.

- potrošači će u 2020. godini preuzeti veći nadzor nad razmjenom podataka i privatnosti,
- zbog brzog razvitka kibernetskih prijetnji AI će se boriti s AI i
- *Capgemini* predviđa da 63 % organizacija planira implementirati AI u 2020. godini i to za poboljšanje kibernetičke sigurnosti, a ponajviše u kontekstu mrežne sigurnosti i pripadajućih aplikacija.

Prema *Capgemini* istraživačkom institutu[248] provedena je anketa na uzorku od 850 izvršnih direktora u raznim korporacijama, a na pitanje koriste li AI u kibernetičkoj sigurnosti za određena područja u vlastitim organizacijama, dobiveni su sljedeći rezultati prikazani na slici 2-2.

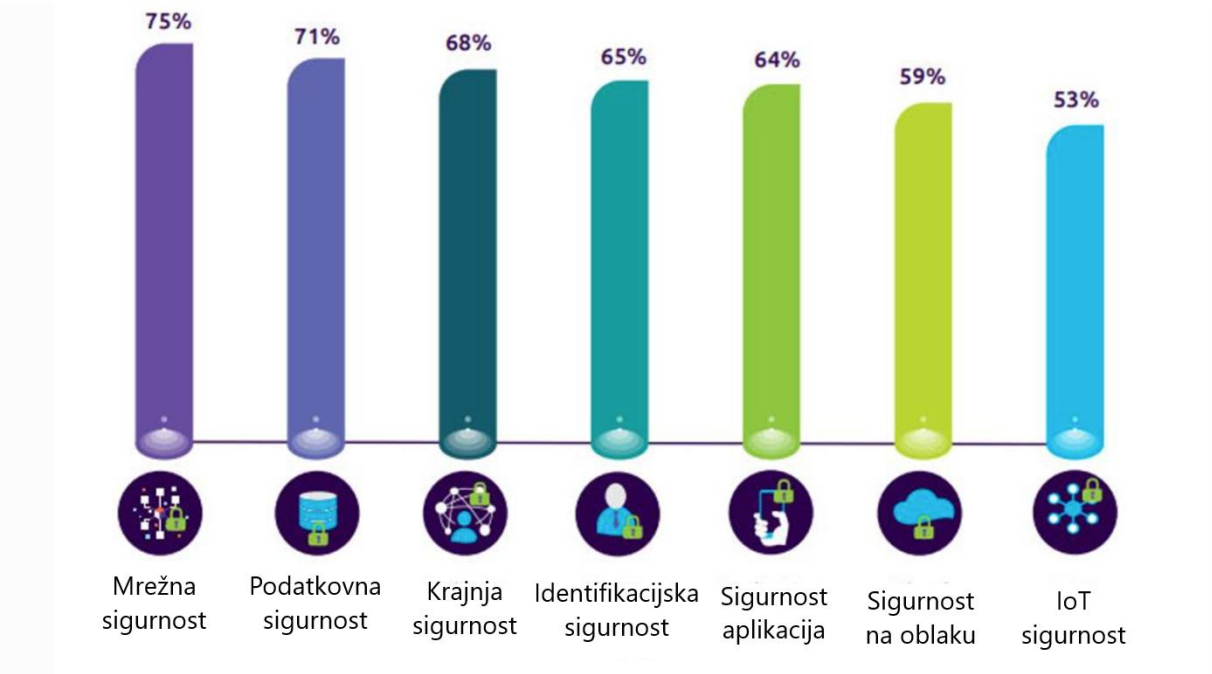

Slika 2-2 Korištenje AI u specifičnim područjima organizacije,

Izvor: Capgemini, Ponovno stvaranje kibernetičke sigurnosti s AI: nova granica digitalne sigurnosti

Kibernetička sigurnost ima vrlo važan utjecaj i na sadašnju primjenu raznolikih računalnih i softverskih tehnologija u EU. Stoga se opravdano očekuje da će i kibernetska sigurnost imati potencijalno značajan utjecaj na sigurnost sustava AI posebice u primjeni u pomorskom prometu.

[248] Engl. *Capgemini Research Institute*

2.18. KOMPARATIVNA ANALIZA PRAVNIH IZVJEŠĆA U PODRUČJU UMJETNE INTELIGENCIJE

U ovom poglavlju provodi se komparativna analiza pravnih izvješća u području AI. Analiza je provedena na primjerima Njemačke, Francuske, UK, Španjolske, Italije, SAD, Rusije, Kine te Australije. Model istraživanja i komparacije pravnih izvješća država provodi se u tri ključna segmenta, a to su: etika, autonomni sustavi i ubojiti autonomni oružani sustavi (engl. *Lethal Autonomous Weapons Systems* – LAWS). Model i međusobni odnosi vidljivi su na slici 2-3.

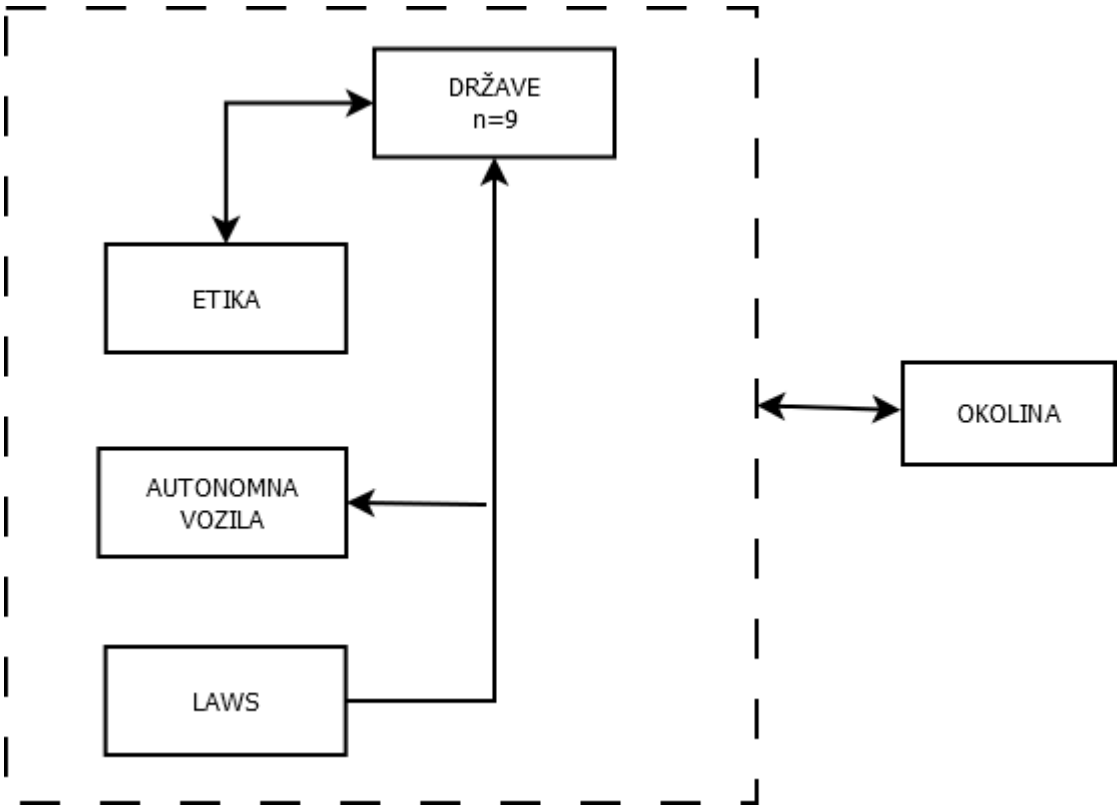

Slika 2-3, Model istraživanja komparativnih pravnih izvješća,

Izvor: izradio autor

2.18.1. SAVEZNA REPUBLIKA NJEMAČKA

Njemačka vlada je sredinom 2014. objavila Digitalnu agendu 2014–2017 kojom se utvrđuju smjernice za vlastitu državnu digitalnu politiku i ističe brojna ključna djelovanja, ali i tzv. Digitalnu strategiju 2025.[249] Između ostalog, uspostavljena su dva centra za kompetenciju u pogledu BD. U kontekstu rješavanja problema obrade BD Njemačka ističe da AI i ML pružaju osnovne alate za navedenu problematiku. S obzirom na to da AI pruža iznimne mogućnosti u smislu digitalizacije društva, cilj Njemačke je uspostaviti ispravnu procjenu rizika za mogućnosti AI, ali i osiguravanje središnje pozicije čovjeka u smislu tehničkih, pravnih, sigurnosnih i etičkih okvira upotrebe AI.[250] U rujnu 2018. godine Komisija za etiku podataka Njemačke održala je svoj prvi uvodni sastanak[251] te su određeni zadaci za predlaganje etičkih smjernica za podatkovnu politiku, algoritme, AI i digitalne inovacije te pružanje preporuka i regulatornih prijedloga njemačkoj vladi.[252] S obzirom na njemačku strategiju AI, Komisija za etiku podataka preporučila je dodavanje još jednog cilja te još jednog dodatnog područja djelovanja.[253] Naime, riječ je o cilju poštivanja etičkih i pravnih načela koja se temelje na njemačkoj demokraciji tijekom čitavog razvoja i primjene AI te području promicanja sposobnosti pojedinaca i društva u cjelini da kritički razumiju informacijsko društvo.

U Njemačkoj je 13. prosinca 2016. stupio na snagu Zakon o izmjenama i dopunama Bečke konvencije o cestovnom prometu[254] kojom je omogućen prijenos zadataka vožnje na sama vozila, odnosno kojim su regulirana autonomna vozila. Ova izmjena Bečke konvencije odnosi se na tehničke zahtjeve za autonomne/automatizirane upravljačke sustave. Potom, 2017. godine Njemačka je izmijenila svoj Zakon o cestovnom prometu (njem. *Straßenverkehrsgesetz (StVG)*)[255] kako bi omogućila vozačima da upravljačke funkcije vozila prepuste visokim ili

---

[249] Bundesregierung [Federal government], Digitale agenda 2014–2017 [Digital agenda 2014–2017] (2014)
[250] Digital Summit: Shaping the Digital Transformation Together, dostupno na: http://perma.cc/A8SG-EBUV
[251] Press Release (2018). Federal Ministry of the Interior, Building, and Community [BMI], Data Ethics Commission Goes to Work, dostupno na: https://www.bmi.bund.de/SharedDocs/pressemitteilungen/EN/2018/data-ethics-commission.html
[252] The Federal Government's key questions to the Data Ethics Commission, dostupno na https://www.bmi.bund.de/SharedDocs/downloads/EN/themen/it-digital-policy/key-questions-Data-Ethics-commission.pdf?__blob=publicationFile&v=6
[253] Data Ethics Commission, Recommendations of the Data Ethics Commission for the Federal Government's Strategy on Artificial Intelligence dostupno na https://www.bmjv.de/SharedDocs/Downloads/DE/Ministerium/ForschungUndWissenschaft/DEK_Empfehlungen_englisch.html;jsessionid=DDAF76836371D0CC6F04A232F117B72F.1_cid324?nn=11678512
[254] Gesetz zur Änderung der Artikel 8 und 39 des Übereinkommens vom 8. November 1968 über den Straßenverkehr, dostupno na: https://www.bgbl.de/xaver/bgbl/start.xav?startbk=Bundesanzeiger_BGBl&jumpTo=bgbl216s1306.pdf
[255] German Road Traffic Act — Straßenverkehrsgesetz (StVG)

potpuno automatiziranim upravljačkim sustavima i da se ta vozila mogu koristiti na javnim cestama.[256] Važno je naglasiti kako se tim zakonom određuje obveznost vozačeve interferencije, odnosno vozač je dužan preuzeti upravljačke funkcije od autonomnog vozila bez nepotrebnog odgađanja ako mu to autonomno vozilo predloži ili ako shvati ili je trebao shvatiti da uvjeti za ostvarenje autonomne vožnje nisu ispunjeni, što dijelom razjašnjava i potencijalnu odgovornost u slučaju prometne nesreće.[257] Pored toga, „crna kutija“ u automobilu mora zabilježiti upravlja li vozilom vozač ili upravljački sustav.[258] Izmjena je također povećala maksimalni iznos kojim se žrtvi dopušta naknada štete za prometne nesreće koje uključuju takve automatizirane upravljačke sustave na 10 milijuna eura za osobne ozljede ili smrt te na 2 milijuna eura za oštećenja imovine.[259] Pored toga, njemački savezni ministar prometa i digitalne infrastrukture osnovao je Etičko povjerenstvo o automatiziranoj i povezanoj vožnji[260] koje je 2017. godine objavilo izvješće u kojem se navodi dvadeset etičkih smjernica za programiranje autonomnih vozila/automatiziranih vozačkih sustava s naglaskom na sigurnost, ljudsko dostojanstvo, osobnu slobodu izbora i autonomiju podataka.[261]

U pogledu LAWS-a njemačka vlada je u svom koalicijskom sporazumu navela da "odbacuje autonomne sustave oružja koji su lišeni ljudske kontrole" i pozvala na njihovu globalnu zabranu.[262] Ujedno je i u suradnji s Francuskom predložila usvajanje političke deklaracije kojom bi se *"potvrdilo da države stranke dijele uvjerenje da ljudi i nadalje trebaju donositi konačne odluke u vezi s uporabom smrtonosne sile kao i provoditi kontrolu nad sustavima smrtonosnog oružja koji koriste*“.[263]

Prema navedenom, Njemačka stavlja čovjeka u centar razvoja i upotrebe AI te poziva na rješavanja etičkih pitanja prilikom razvoja AI. Uz to, povukla je i prve korake po pitanju regulacije autonomne vožnje i snažno se zalaže za odbacivanje primjene LAWS-a.

---

[256] Achtes Gesetz zur Änderung des Straßenverkehrsgesetzes, dostupno na: https://www.bgbl.de/xaver/bgbl/start.xav?startbk=Bundesanzeiger_BGBl&jumpTo=bgbl117s1648.pdf
[257] § 1b. Straßenverkehrsgesetz (StVG)
[258] *Ibid*, § 63a.
[259] *Ibid.* § 12, para. 1.
[260] Press Release (2017). Federal Ministry of Transport and Digital Infrastructure [BMVI], Ethics Commission on Automated Driving Presents Report, dostupno na: https://www.bmvi.de/SharedDocs/EN/publications/report-ethics-commission.pdf?__blob=publicationFile
[261] *Ibid.*
[262] Ein neuer Aufbruch für Europa. Eine neue Dynamik für Deutschland. Ein neuer Zusammenhalt für unser Land. Koalitionsvertrag zwischen CDU, CSU und SPD. 19. Legislaturperiode, dostupno na: https://www.cdu.de/system/tdf/media/dokumente/koalitionsvertrag_2018.pdf?file=1
[263] Meeting of the Group of Governmental Experts on Lethal Autonomous Weapons Systems. Statement by France and Germany (under Agenda Item “General Exchange of Views”) (Apr. 9–13, 2018)

2.18.2. FRANCUSKA

Francuska ima neke od najboljih svjetskih matematičkih i inženjerskih škola, a neki od vodećih svjetskih znanstvenika i istraživača za AI dolaze iz te zemlje.[264] Upravo iz tog razloga administracija na čelu s predsjednikom *Emmanuelom Macronom* odredila je jednim od prioriteta svoje vlade nadogradnju postojećih resursa kako bi Francusku pozicionirali u sami svjetski vrh po pitanju razvoja i implementacije AI. To bi ih koštalo 1,5 milijardi eura do 2022.[265] Dodatno, francuska vlada je uložila značajne napore u predviđanje regulatornih izazova u povezivosti s AI. Ključna je uloga i Komisije za računalnu tehnologiju i građanske slobode (engl. *National Commission on Computer Technology and Civil Liberties* - CNIL) koja se od 2016. godine bavi proučavanjem društvenih i etičkih uloga povezanih s novim digitalnim tehnologijama.[266]

Kao dio ove misije CNIL je u prosincu 2017. izradio izvještaj o „etičkim ulozima algoritama i AI".[267] Ovo izvješće ukazuje na šest širokih etičkih pitanja koja se tiču AI:

- Hoće li se ugroziti ljudska sloboda i odgovornost ako se odlučivanje sve više delegira strojevima i softveru?
- Dobrovoljno ili slučajno uključivanje pristranosti i diskriminacije u AI.
- Kako AI potiče segmentaciju rješenja (prilagođenih za svaki jedinstveni profil), kako to utječe na kolektivnu logiku određenih bitnih obilježja našeg društva kao što je demokratski pluralizam?
- Kako uravnotežiti prednosti BD s potrebom zaštite privatnosti pojedinaca?
- Kako odabrati podatke koji se koriste za ML, uravnotežiti kvalitetu, količinu i prikladnosti za ostvarivanje svrhe?
- Kako razvoj autonomne AI, kao i izbljeđivanje crte između ljudi i strojeva, dovode u pitanje sam smisao ljudskog identiteta?[268]

Šest konkretnih preporuka CNIL-a uključuju sljedeće:

---

[264] Dillet, R. (2018). France Wants to Become an Artificial Intelligence Hub, TECHCRUNCH, dostupno na: https://techcrunch.com/2018/03/29/france-wants-to-become-an-artificial-intelligence-hub/

[265] *Ibid.*

[266] LOI n° 2016-1321 du 7 octobre 2016 pour une République numérique (1), dostupno na: https://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000033202746&dateTexte=&categorieLien=id

[267] Commission Nationale De L'informatique Et Des Libertés (CNIL), Comment Permettre À L'homme De Garder La Main? (2017), dostupno na: https://www.cnil.fr/sites/default/files/atoms/files/cnil_rapport_garder_la_main_web.pdf

[268] *Ibid*, str. 5.

- etičko obrazovanje svih uključenih u razvoj i korištenje AI,
- daljnji napori kako bi se ostvarila objašnjivost algoritma za krajnje korisnike,
- osmisliti algoritme koji služe ljudskoj slobodi,
- stvoriti nacionalno tijelo za kontrolu i reviziju algoritama,
- potaknuti istraživanje etične AI i pokrenuti veliki nacionalni istraživački projekt usmjeren općem interesu i
- ojačati tijela za poštivanje etike u korporacijama.[269]

Na međunarodnoj razini Francuska se nedavno pridružila Kanadi s ciljem stvaranja stručne međunarodne skupine za AI kako bi podržala i usmjerila odgovorno usvajanje AI usredotočene na poštivanje ljudskih prava i sl.[270] Francuska izražava veliku ambiciju u preuzimanju glavne uloge po pitanju razvoja autonomnih vozila s naglaskom na sigurnost kao ključ autonomije. To uključuje proaktivan pristup u eksperimentiranju s autonomnim vozilima, apostrofirajući sigurnost na cestama i kibernetičku sigurnost, ali i značajniju suradnju vlasti i autoindustrije u razvoju zakonodavnog okvira. Francuska je započela suradnju s Njemačkom i Luksemburgom u nastojanju stvaranja međunarodnog, digitalnog testnog poligona za autonomnu i povezanu vožnju.[271] Nadalje, od 1. siječnja 2019. francuska vlada je uspjela odobriti autonomna vozila razine 4 na javnim cestama za potrebe ispitivanja.[272] Francuska inicijativa iz 2013. dovela je do međunarodnih rasprava o LAWS-u u okviru Konferencije o Konvenciji o određenom konvencionalnom oružju.[273] Francuska je izričito protiv primjene LAWS-a[274] pogotovo u slučaju kad nisu poznati elementarni etički i pravni okviri same AI.

Može se zaključiti kako Francuska najveći naglasak stavlja na proučavanje etike i njezine uloge u razvoju AI. Potiče se međunarodna suradnja što je vidljivo kroz bilateralni sporazum i

---

[269] *Ibid*, str. 6.

[270] Rispal, K. (2018). France and Canada Create New Expert International Panel on Artificial Intelligence, Gouvernement.Fr, dostupno na: https://www.gouvernement.fr/en/france-and-canada-create-new-expert-international-panel-on-artificial-intelligence

[271] Franco-German-Luxemburgish Cooperation On Automated And Connected Driving: Concept For The Cross-Border Digital Test Bed. (2018), dostupno na: https://perma.cc/BK6Y-9HQT

[272] Décret n° 2018-211 du 28 mars 2018 relatif à l'expérimentation de véhicules à délégation de conduite sur les voies publiques art. 9, dostupno na: https://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000036750342&dateTexte=&categorieLien=id

[273] Council Conclusions on the Fifth Review Conference of the Convention on Prohibitions or Restrictions on the Use of Certain Conventional Weapons Which May be Deemed to be Excessively Injurious or to Have Indiscriminate Effects (CCW) (Geneva, 12-16 December 2016), dostupno na: https://eeas.europa.eu/sites/eeas/files/ccw.pdf; Konvencija o zabrani ili ograničenju uporabe određenog konvencionalnog oružja s pretjeranim traumatskim učinkom ili djelovanjem bez obzira na cilj (NN 13/2001-120)

[274] Thompson, N. (2018). Emmanuel Macron Talks to Wired About France's AI Strategy, WIRED, dostupno na: https://www.wired.com/story/emmanuel-macron-talks-to-wired-about-frances-ai-strategy/

suradnju s Kanadom u osnivanju zajedničke skupine za AI. Francuska je odobrila ispitivanje autonomnih vozila na javnim cestama i snažno se protivi LAWS-u.

2.18.3. UJEDINJENO KRALJEVSTVO

Vlada UK je izjavila da je zemlja trenutno u predvorju nove tehnološke revolucije ističući kako AI ima potencijal transformirati naše živote kao što je imao parni stroj na ekonomiju 19. stoljeća.[275] U tom kontekstu, Vlada UK je opisala AI kao „*skup naprednih digitalnih tehnologija opće namjene koje omogućuju strojevima da obavljaju vrlo složene zadatke*“.[276] Samim time UK aktivno potiče i financira razvoj AI te je izradilo niz izvještaja koja razmatraju primjenu i razvoj iste. Jedan od ciljeva vladajuće britanske administracije je iskoristiti predviđanja o rastu BDP-a za 10,3 %, odnosno stvaranja dodatnih 232 milijardi funti kao rezultat razvoja AI.[277] Usporedbe radi, proračun britanske Vlade u 2017. osigurao je 75 milijuna funti za AI.[278] U lipnju 2017. Gornji Dom Parlamenta (engl. *House of Lords*) osnovao je Odbor za razmatranje ekonomskog, etičkog i društvenog utjecaja razvoja AI (dalje u tekstu: Odbor UK)[279], a nedugo zatim u studenom 2017. Donji Dom Parlamenta (engl. *House of Commons*) je proveo istraživanje s ciljem razmatranja uporabe algoritama u javnom poslovanju i donošenju odluka.[280] U takvom izvješću zaključeno je kako upotreba algoritama u procesu donošenja odluka treba pružati značajne prilike, ali i da takvu tehnologiju treba pomno nadzirati.[281] U recentno vrijeme UK prihvaća korištenje AI u javnim servisima na različite načine. Tako je predložen i zakonodavni okvir u pogledu obveznog osiguranja korisnika vozila koja imaju

---

[275] Government Office for Science (2015). Artificial Intelligence: Opportunities And Implications For The Future Of Decision Making, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/566075/gs-16-19-artificial-intelligence-ai-report.pdf

[276] Hall, W., Pesenti, J. (2017). Growing The Artificial Intelligence industry in the UK, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/652097/Growing_the_artificial_intelligence_industry_in_the_UK.pdf

[277] Müller, B., The AI Landscape in the United Kingdom, dostupno na: http://ec.europa.eu/newsroom/dae/document.cfm?doc_id=50824

[278] Policy paper (2017). Autumn Budget 2017, dostupno na: https://www.gov.uk/government/publications/autumn-budget-2017-documents/autumn-budget-2017

[279] 783 PARL. DEB. H.L. (5th ser.) (2017) 562, dostupno na: https://hansard.parliament.uk/Lords/2017-06-29/debates/09a72b2f-9261-4ab4-82e8-92f1c0758a87/LordsChamber

[280] House of Commons Science and Technology Committee (2018). Algorithms in Decision-Making, Fourth Report of Session 2017–19, dostupno na: https://publications.parliament.uk/pa/cm201719/cmselect/cmsctech/351/351.pdf

[281] House of Commons Science and Technology Committee (2018). Algorithms in Decision-Making: Government Response to the Committee's Fourth Report, Sixth Special Report of Session 2017–19, dostupno na: https://publications.parliament.uk/pa/cm201719/cmselect/cmsctech/1544/1544.pdf

mogućnost autonomnog rada, čime osiguratelj postaje odgovoran za nezgode prouzročene vozilom u autonomnom djelovanju.

Osim toga, primjena AI u UK se očituje i kroz niz drugih primjera kao što su:

- *Google DeepMind* trenutno surađuje s Nacionalnom zdravstvenom službom (engl. *National Health Service*) na razvoju alata za analizu skenova očiju.[282]
- Razvoj vojne opreme koja koristi AI za skeniranje bojnog polja za neprijateljske pokrete te registriranje opasnosti za vojnike i alarmiranje o istim.[283]
- Pametni semafori se koriste u nekim gradovima za pomoć u upravljanju prometom.[284]
- Internetski tečajevi za testiranje korištenja AI u unaprjeđivanju i razvoju digitalnih vještina za koje su izdvojena značajna financijska sredstva (30 milijuna funti).[285]
- 84 milijuna funti planirano je uložiti kroz sljedeće četiri godine u razvoj AI kako bi industrija i javne usluge bile sigurnije i produktivnije.[286]
- UK je stvorilo i financiralo Centar za podatkovnu etiku i inovacije kao savjetodavno tijelo za suradnju s vladom, zakonodavnim tijelima i industrijom kako bi usuglasili i postavili ključne etičke norme za primjenu AI u UK.[287]
- UK preispituje regulatornu strukturu kako bi se autonomna vozila na putu omogućila do 2021. godine.[288]

U kontekstu LAWS-a Ministarstvo obrane je izjavilo kako UK ne posjeduje oružane autonomne zrakoplovne sustave i nema ih namjeru razvijati. Samim time ističe se britanska politika koja jasno određuje čovjeka kao ključnog čimbenika u nadzoru i u kontroli nad

---

[282] Points, L., Potton, E. (2017). Artificial Intelligence and Automation in the UK, UK Parliament

[283] Ward, V. (2018). Artificial Intelligence Weaponry Successfully Trialed on Mock Urban Battlefield, THE TELEGRAPH, dostupno na: https://www.telegraph.co.uk/news/2018/09/24/artificial-intelligence-weaponry-successfully-trialled-mock/

[284] McGoogan, C. (2017). AI Traffic Lights to End Rush Hour Jams in Milton Keynes, THE TELEGRAPH, dostupno na: https://www.telegraph.co.uk/technology/2017/05/15/ai-traffic-lights-end-rush-hour-jams-milton-keynes/

[285] HM Treasury (2017). Autumn budget 2017, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/661583/autumn_budget_2017_print.pdf

[286] UK Space Agency, Perry, C. (2017). Funding for £84 Million for Artificial Intelligence and Robotics Research and Smart Energy Innovation Announced, dostupno na: https://www.gov.uk/government/news/funding-for-84-million-for-artificial-intelligence-and-robotics-research-and-smart-energy-innovation-announced

[287] Centre for Data Ethics and Innovation Consultation, Department for Digital, Culture, Media & Sport (2018), dostupno na: https://www.gov.uk/government/consultations/consultation-on-the-centrefordataethicsandinnovation/centre-for-data-ethics-and-innovation-consultation

[288] Scottish Law Commission (2018). Automated Vehicles: A Joint Preliminary Consultation Paper, dostupno na: https://s3-eu-west-2.amazonaws.com/lawcom-prod-storage-11jsxou24uy7q/uploads/2018/11/6.5066_LC_AV-Consultation-Paper-5-November_061118_WEB-1.pdf

smrtonosnim oružjem čime se jamči nadzor, odgovornost i autoritet. Iako oružani sustavi mogu raditi na automatski način, uvijek postoji osoba koja je uključena u postavljanje odgovarajućih parametara.[289] Međutim, zabrinjavajuća je britanska definicija smrtonosnog autonomnog oružja, odnosno definicija o vojnoj uporabi istog poput „visoke sposobnosti razumijevanja namjere i smjera“, koja nije u skladu s ostalim državama.[290] Samim time UK je limitiralo svoj položaj u kontekstu međunarodnih dogovora o LAWS-u i mogućnosti preuzimanja vodeće etičke uloge na globalnoj razini. Također, takva definicija ugrožava jedinstveni međunarodni dogovor za definiranje AI u smislu LAWS-a.[291] Iako je preporuka Odbora UK usklađivanje definicije autonomnog oružja s ostatkom svijeta, Vlada UK je takav prijedlog odbila.[292] U vezi s navedenim, može se zaključiti kako se tumačenje autonomnog oružja od strane UK na međunarodnoj razini ne podudara s definicijom mnogih drugih zapadnih država i ne podržava prvotnu zabranu takvog oružanog sustava. Umjesto toga, UK želi daljnje rasprave o razvoju tih sustava.[293]

Stoga se da zaključiti kako UK veliki naglasak stavlja, kao i ostale države, na primjenu etičnosti AI i razmatranju upotrebe algoritama u javnom poslovanju te nadzoru tih tehnologija. Za provedbu dijela strategije UK je osnovala i centar za podatkovnu etiku te će preispitati odluku o regulatornom okviru kojim se omogućuje korištenje autonomnih vozila na javnim cestama 2021. Po pitanju LAWS-a UK je zauzela nešto drukčiji stav od ostalih država s obzirom da UK nema LAWS i ne planiraju ih razvijati, ali bi bili otvoreni za daljnju raspravu o razvoju takvih sustava.

---

[289] Ministry Of Defence, Development, Concepts And Doctrine Centre (2017). Unmanned Aircraft Systems, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/673940/doctrine_uk_uas_jdp_0_30_2.pdf

[290] *Ibid*, str. 43.

[291] House Of Lords, Select Committee On Artificial Intelligence (2018). Ai In The Uk: Ready, Willing And Able?, 345, dostupno na: https://publications.parliament.uk/pa/ld201719/ldselect/ldai/100/100.pdf

[292] *Ibid*, str. 61.

[293] Report of the 2018 session of the Group of Governmental Experts on Emerging Technologies in the Area of Lethal Autonomous Weapons Systems (2018), 9, dostupno na: https://undocs.org/pdf?symbol=en/CCW/GGE.1/2018/3

2.18.4. ŠPANJOLSKA

Španjolska ima brojne istraživačke organizacije AI koje djeluju u sklopu informatičkih programa koje vode sveučilišta i druge akademske institucije.[294] Vodeći istraživački subjekti u AI uključuju španjolsko udruženje za AI (špa. *Asociación Espanola de Inteligencia Artificial* - AEPIA) i Istraživački institut za AI (špa. *Instituto de Investigación en Inteligencia Artificial* - IIIA) koja se nalazi na Autonomnom sveučilištu u Barceloni (špa. *Universitat Autònoma de Barcelona*). Kao dio Digitalne strategije za pametnu Španjolsku 2025., u studenome 2017. osnovana je radna skupina stručnjaka za izradu službenih smjernica o AI.[295] Otkrića radne skupine bit će objavljena u Bijeloj knjizi o AI (špa. *Libro Blanco de Inteligencia Artificial* - WBAI) čiji je cilj rješavanje društvenih, pravnih i etičkih implikacija upotrebe AI i BD u privatnom i javnom sektoru.[296] Po pitanju autonomnih vozila Španjolska nije donijela nikakav zakonodavni okvir, ali je odobrila testiranje autonomnih vozila od 2015. godine.[297] Također, po pitanju LAWS-a španjolska Vlada je izjavila kako njezine oružane snage nemaju i ne planiraju razvijati LAWS ili oružje na temelju AI te da ne financiraju ni jedan projekt na tu temu.[298] Španjolska je istaknula zabrinutost oko razvoja robotskog oružja koje bi djelovalo bez ljudske intervencije.[299] Sukladno tome, Španjolska podržava usvajanje općeg međunarodnog pravnog okvira usmjerenog na sprječavanje utrke u naoružanju u skladu sa LAWS.[300] Konkretno, Španjolska predlaže i podržava izdavanje političke deklaracije i obvezujućeg kodeksa ponašanja koji bi uključivao mjere transparentnosti za praćenje ovog procesa kao i uspostavljanje odbora stručnjaka koji će biti odgovoran za ocjenu novih dostignuća u tehnologiji koja uključuje autonomno smrtonosno oružje.[301]

---

[294] European Commission (2018). The European AI Landscape: Workshop Report 22–23, dostupno na: https://ec.europa.eu/digital-single-market/en/news/european-artificial-intelligence-landscape

[295] Grupo de Sabios Creara Libro Blanco de Inteligencia Artificial y Big Data, dostupno na: https://cepymenews.es/libro-blanco-inteligencia-artificial-big-data/

[296] *Ibid.*

[297] Dirección Nacional De Tráfico, Ministerio Del Interior, Tráfico Establece El Marco Para La Realización De Pruebas Con Vehículos De Conducción Automatizada En Vías Abiertas A La Circulación, Nota De Prensa (Nov. 16, 2015), dostupno na: https://www.dgt.es/Galerias/prensa/2015/11/NP-pruebas-vehiculos-conduccion-automatizada.pdf

[298] Miranda, I. (2015). Las Fuerzas Armadas Españolas No Tendrán Su Propio «Robot Asesino», ABC, dostupno na: https://www.abc.es/espana/20150831/abci-robots-asesinos-espana-201508301912.html

[299] Respuesta del Gobierno [Government Answer], Pregunta Escrita Senado [Written Question Senate] 684/77289, June 17, 2015, dostupno na: http://www.senado.es/web/expedientdocblobservlet?legis=10&id=190036

[300] *Ibid.*

[301] Herraiz, J. (2018). Convención sobre Ciertas Armas Convencionales, Grupo de Expertos Gubernamentales sobre Sistemas de Armas Autónomas Letales, Intervención del Embajador de Espana, Julio Herraiz, Delegado ante la Conferencia de Desarme, Geneva, dostupno na: https://docs-

Sukladno navedenom, može se zaključiti kako Španjolska polaže velike nade u suradnji državnih tijela i istraživačkih institucija po pitanju stvaranja etičkih normi u razvoju AI i ostalih digitalnih strategija. Španjolska nije regulirala autonomna vozila u upotrebi na javnim cestama, ali ih testira još od 2015. Po pitanju LAWS-a zauzela je stav kako ga nema i ne planira ga razvijati te podržava donošenje jasnog i međunarodnog okvira o sprječavanju naoružavanja.

2.18.5. ITALIJA

Istraživanje AI rezultira stvaranjem većeg broja novih poduzeća (*start up*-ova) fokusirajući se na projekte vezane za pojedino područje AI. Tako su primjerice SAD od travnja 2018. prijavile postojanje 1 393 *start up*-a, EU 769, Kina 383 i Izrael 362, a Italija svega 22.[302] U tom kontekstu, stručnjaci za AI u Italiji istaknuli su potrebu za većom posvećenosti inicijativi za razvoj AI stvaranjem ili diversifikacijom državnih, socijalnih i investicijskih programa koji bi omogućili pristup većem tržištu EU za AI, ali na način da sjedište tih poduzeća bude u Italiji.[303] U srpnju 2018. godine grupa visokih učilišta stvorila je Laboratorij za AI i inteligentne sustave s ciljem jačanja „temeljnih i primijenjenih istraživanja zemlje u AI, podržavajući informatičku industriju u zemlji, promičući prijenos tehnologije od istraživanja do poduzetništva i promičući donošenje AI rješenja u javnoj upravi“.[304]

Agencija za digitalnu Italiju objavila je 2018. „Bijelu knjigu“ o AI koja opisuje trenutni status AI u Italiji.[305] Bijela knjiga navodi vladin interes za olakšavanje usvajanja strategija i primjene AI u javnim sustavima kako bi široj javnosti pružile brže i učinkovitije usluge, između ostalog, u područjima javnog zdravstva, obrazovanja, pravosuđa i sustava sigurnosti.[306] Također, Bijela knjiga navodi potrebu za donošenjem zakonodavnog okvira za AI u Italiji, uključujući ravnotežu javnih i privatnih interesa te poštivanje načela transparentnosti, zaštite privatnosti i intelektualnog vlasništva, poticanja odgovornosti i uspostavljanja učinkovitog sustava društvene kontrole radi zaštite temeljnih prava osobe.[307] Bijela knjiga uključuje deset

---

library.unoda.org/Convention_on_Certain_Conventional_Weapons_-_Group_of_Governmental_Experts_(2017)/2017_GGE%2BLAWS_Statement_Spain.pdf

[302] Netti, E. (2018). Intelligenza Artificiale, Europa Indietro, IL SOLE 24 ORE, dostupno na: https://www.ilsole24ore.com/art/tecnologie/2018-07-10/intelligenza-artificiale-europa-indietro-112436.shtml

[303] *Ibid.*

[304] Dutton, T. (2018). An Overview of National AI Strategies, Medium, dostupno na: https://medium.com/politics-ai/an-overview-of-national-ai-strategies-2a70ec6edfd

[305] The Agency for Digital Italy, (2018). Atificial Intelligence at service of citizens, dostupno na: https://ai-white-paper.readthedocs.io/en/latest/doc/making_the_most.html

[306] Dutton, T., *op.cit.,* str. 9.

[307] *Ibid,* str. 11.

preporuka koje će Vlada razmotriti, a odnose se prvenstveno na stvaranje Nacionalnog centra za kompetencije AI kao nacionalne platforme za promicanje prikupljanja zabilježenih podataka i mjera za razvoj vještina povezanih s AI kroz javnu upravu. Naglasak je stavljen i na izradu nacionalne strategije za AI[308] gdje je nužno razvijanje politika i sustava vezanih za razvoj AI i primjenu iste. Kao važni ciljevi istaknuti su:

- poboljšanje istraživanja i koordinacije na polju AI;
- poticanje javnih i privatnih ulaganja u AI;
- privlačenje talenta i poduzetničkih inicijativa u području AI;
- poticanje razvoja podatkovne ekonomije, s posebnim naglaskom na slobodan protok neosobnih podataka u skladu s najvišim standardima interoperabilnosti i sigurnosti;
- pregled postojećeg zakonodavnog i regulatornog okvira primjenjivog na proizvode i usluge povezane s AI i
- analiza i procjena socioekonomskih učinaka zbog širokog prihvaćanja sustava temeljenih na AI.[309]

U pogledu autonomnih vozila u Italiji, Uredba ministara iz 2018.[310] predviđa da eksperimentiranje ili testiranje autonomnih vozila na zaštićenom mjestu ili javnim ulicama mora obavljati čovjek (nadzornik) koji posjeduje određene posebne kvalifikacije, uključujući, između ostalih, vozačku dozvolu najmanje pet godina u vezi s određenim vozilom koje se testira i drugim zahtjevima koji se odnose na akreditaciju u drugoj državi EU i osposobljavanje u trećoj zemlji u kojima takva vozila rade određeni minimalni broj prijeđenih kilometara.[311] Propisi posebno nalažu da čovjek-vozač mora biti u stanju da brzo prebaci između automatskog i ručnog upravljanja vozilom i obrnuto.[312] Po pitanju LAWS-a Italija tvrdi da ih ne posjeduje i ne planira proizvoditi.

Zaključno, može se reći da Italija traži donošenje zakona o AI te poštivanju etičkih načela što uključuje i društvene i ekonomske učinke. Autonomna vozila u Italiji se testiraju od 2018.,

---

[308] Press Release, Ministero dello Sviluppo Economico [Ministry for Economic Development], Intelligenza Artificiale: Call per Esperti [Artificial Intelligence: Call for Experts] (Sept. 13, 2018), dostupno na: https://www.sviluppoeconomico.gov.it/index.php/it/intelligenza-artificiale-call

[309] Dostupno na: https://knowledge4policy.ec.europa.eu/ai-watch/italy-ai-strategy-report_en

[310] Decreto 28 Febbraio 2018 Ministero delle Infrastrutture e dei Trasporti, Modalita' Attuative e Strumenti Operativi della Sperimentazione su Strada delle Soluzioni di Smart Road e di Guida Connessa e Automatica, GAZZETTA UFFICIALE [G.U.] [OFFICIAL GAZETTE] No. 90 (Apr. 18, 2018), dostupno na: http://www.gazzettaufficiale.it/eli/id/2018/04/18/18A02619/sg

[311] Čl. 10 st. 1. Uredbe

[312] Čl. 10 st. 2. Uredbe

ali na sigurnim lokacijama. Po pitanju LAWS-a Italija je zauzela sličan stav kao i većina država Europe, odnosno nema ga i ne planira razvijanje istog.

2.18.6. SJEDINJENE AMERIČKE DRŽAVE

Mnoge države izdale su ili su u postupku izdavanja vlastitih nacionalnih strategija, smjernica ili kodeksa u pogledu razvoja i implementiranja AI. Takvi dokumenti često ističu temeljna načela etičkog razvoja AI, što jednim dijelom predstavlja kvalitetan i nužan početak u određivanju smjera razvoja same AI, a s druge pak strane prezentira neaktivnost u području donošenja važnih zakona iz područja materijalnog prava. Postoje i određene iznimke kada je u pitanju reguliranje AI u EU, a takvi primjeri uključuju Rezoluciju Europskog parlamenta o pravilima građanskog prava o robotici (veljača 2017.),[313] Etičke smjernice EU za pouzdanu AI (travanj 2019.) i Preporuku Vijeća Organizacije za ekonomsku suradnju i razvoj o umjetnoj inteligenciji (svibanj 2019.).[314] Pravna regulativa AI u SAD je bila poprilično inertna barem do 2019. godine. Ono što se može istaknuti su tri izvještaja o AI koje je izdala administracija predsjednika *Baracka Obame*, točnije, u razdoblju 2015. - 2016. postojala su samo dva prijedloga zakona na 114. Kongresu koji sadrže izraz "AI",[315] što je na 115. Kongresu (2017. - 2018.) naraslo na 42 zakona i na 51 prijedlog zakona za 116. Kongres početkom studenog 2019. godine. Osim federalnih zakona, slični trendovi se mogu primijetiti i na državnim razinama. Tako primjerice Savezna država Kalifornija je imala dva zakona o AI za razdoblje 2015. - 2016., pet prijedloga zakona tijekom mandatnog razdoblja 2017. - 2018. i 13 prijedloga zakona za 2019. - 2020. godinu.[316]

Svake godine broj država koje razmatraju zakonodavstvo vezano za autonomna vozila postupno se povećava. U 2018. godini 15 država donijelo je 18 zakona koji se odnose na autonomna vozila. U 2017. godini 33 države su implementirale takve pravne akte u svoje zakonodavstvo, a 2016. godine još 20 država. Od 2012. najmanje 41 država i *D.C. (*engl.

---

[313] Rezolucija Europskog parlamenta od 16. veljače 2017. s preporukama Komisiji o pravilima građanskog prava o robotici (2015/2103(INL)) (2018/C 252/25)

[314] Recommendation of the Council on Artificial Intelligence, dostupna na: https://legalinstruments.oecd.org/en/instruments/OECD-LEGAL-0449

[315] Prijedlozi su rezultat izvješća Nacionalnog znanstvenog i tehnološkog savjeta nazvan „Pripremanje za budućnost AI“, dostupno na: https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/preparing_for_the_future_of_ai.pdf

[316] Više o tome na: https://www.ncsl.org/research/telecommunications-and-information-technology/2020-legislation-related-to-artificial-intelligence.aspx

District of Colombia) razmotrile su zakonodavstvo vezano za autonomna vozila. Dvadeset devet država[317] donijelo je određena zakonodavstva vezano za autonomna vozila. Guverneri saveznih država poput *Arizona, Delaware, Hawaii, Idaho, Illinois, Maine, Massachusetts, Minnesota, Ohio, Washington i Wisconsin* izdali su izvršne naredbe vezane za autonomna vozila što je prikazano na slici 2-4.[318]

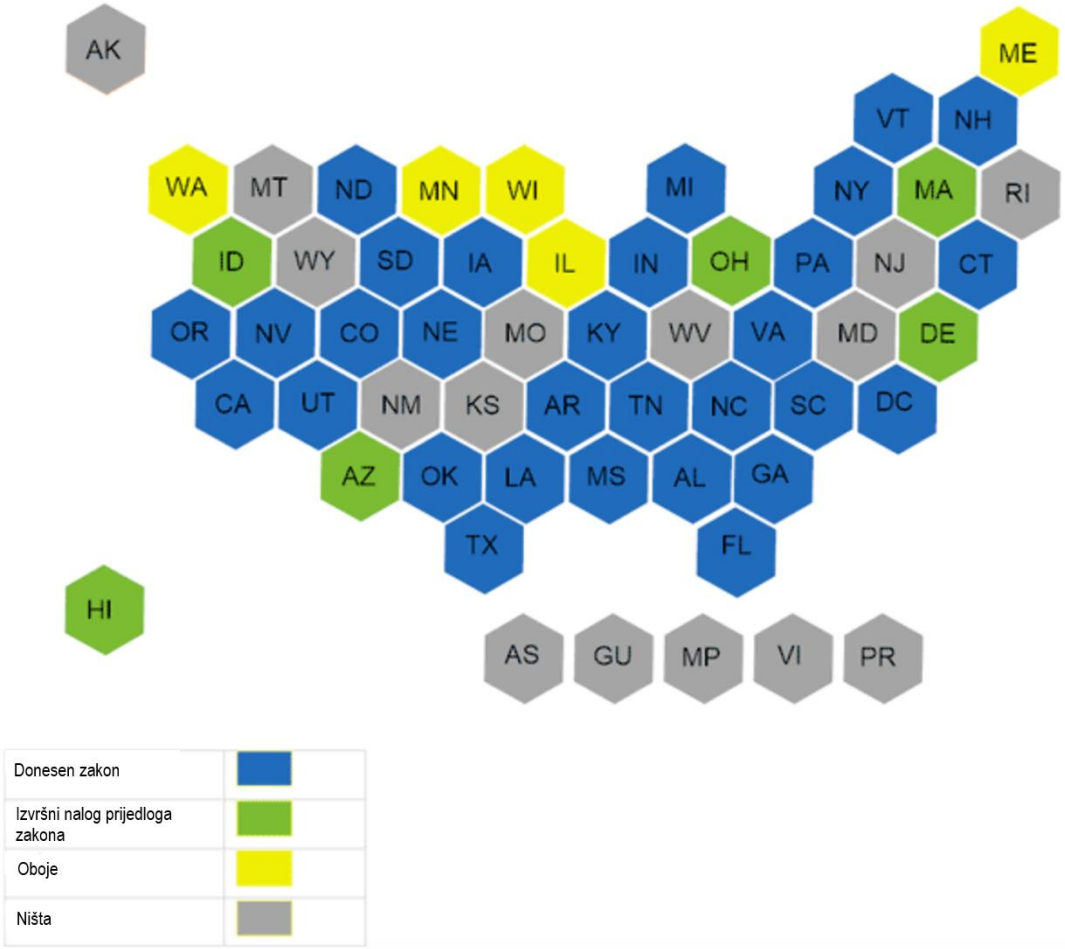

Slika 2-4 Savezne države s donesenim zakonodavstvom o autonomnim vozilima i izvršnim naredbama,

Izvor: National Conference on State Legislatures

[317] Alabama, Arkansas, Kalifornija, Colorado, Connecticut, Florida, Georgia, Illinois, Indiana, Kentucky, Louisiana, Maine, Michigan, Mississippi, Nebraska, New York, Nevada, Sjeverna Carolina, Sjeverna Dakota, Oregon, Pennsylvania, Južna Carolina, Tennessee, Teksas, Utah, Virginia, Vermont, Washington i Wisconsin i Washington DC.

[318] Vidjeti više na: https://www.ncsl.org/research/transportation/autonomous-vehicles-self-driving-vehicles-enacted-legislation.aspx

Dok američko Ministarstvo prometa i NHTSA[319] periodično ažuriraju svoje smjernice[320] u pogledu autonomnih vozila,[321] pojedine države već usvajaju relevantne zakone. Ono što je važno istaknuti su razlike u osnovnim elementima poput pojma "operater vozila". *Tennessee* SB 151[322] ukazuje na sustav autonomne vožnje kao operatera autonomnog vozila, dok *Texas* SB 2205[323] označava "fizičku osobu" u vozilu. Savezna država *Georgia* zauzima drukčiji pristup te u *Georgia* SB 219 aktu[324] identificira operatera kao osobu koja aktivira autonomne upravljačke sustave, ali i mogućnost upravljanja na daljinu. Navedene razlike mogu u budućnosti uzrokovati niz neusuglašenosti, a između ostalog i razlike koje će utjecati na način na koji države licenciraju i ljudske vozače i autonomna vozila. Najpopularnija tema, 11 državnih zakona, čine izuzeci od pridržavanja pravila udaljenosti koja omogućuju "kamionsko spajanje".[325] Uzevši u obzir tipično održavanje odgovarajuće udaljenosti od drugih vozila te brzinu, stanje na cesti i vrijeme reakcije ljudi kada se promet zaustavi, "kamionsko spajanje" putem bežične komunikacije većeg broja kamiona može ubrzavati i kočiti na mnogo kraćim udaljenostima. To znači da bliže udaljenosti među kamionima smanjuju otpor zraka na sljedećim vozilima što rezultira uštedom goriva čime se stvara značajan profit u pogledu prijevoza tereta većeg broja kamiona. Popularnost ovog zakona daje dodatnu širinu komercijalnoj primjeni AI na autonomnim vozilima.[326]

Kada je u pitanju LAWS američka politika ne zabranjuje razvoj ili primjenu istog. Iako SAD trenutno nemaju i ne koriste LAWS, pojedini visoki vojni čelnici tvrde kako bi SAD mogle biti primorane na izradu LAWS-a u doglednoj budućnosti pod uvjetom da se na to odluče američki "protivnici".[327] U isto vrijeme sve veći broj država i nevladinih organizacija apelira na reguliranje ili zabranu postavljanja LAWS-a zbog etičkih problema. Kao što je i prije

---

[319] Engl. *National Highway Traffic Safety Administration*

[320] U.S. Department of Transportation (2017). Automatic driving systems 2.0: A Vision for Safety, dostupno na: https://www.nhtsa.gov/sites/nhtsa.dot.gov/files/documents/13069a-ads2.0_090617_v9a_tag.pdf

[321] U.S. Department of Transportation (2018). Automated Vehicles 3.0: Preparing for the future of transportation, dostupno na: https://www.transportation.gov/sites/dot.gov/files/docs/policy-initiatives/automated-vehicles/320711/preparing-future-transportation-automated-vehicle-30.pdf

[322] House Bill by Lamberth, Senate Bill by Lundberg, An Act to amend Tennessee Code Annotated, dostupno na http://www.capitol.tn.gov/Bills/110/Bill/SB0151.pdf

[323] An Act relating to automated motor vehicles, dostupno na: https://legiscan.com/TX/text/SB2205/2017

[324] 2017-2018 Regular Session - SB 219 Motor Vehicles; definitions; operation of motor vehicles with automated driving systems on certain public roads; provide, dostupno na: http://www.legis.ga.gov/Legislation/en-US/display/20172018/SB/219

[325] Chu, J. (2016). Driverless platoons, MIT news, dostupno na : http://news.mit.edu/2016/driverless-truck-platoons-save-time-fuel-1221

[326] *Ibid.*

[327] Department of Defense, Directive 3000.09, "Autonomy in Weapon Systems", dostupno na: https://www.esd.whs.mil/portals/54/documents/dd/issuances/dodd/300009p.pdf

navedeno, ne postoji unificirana definicija LAWS-a. Međutim, Direktiva Ministarstva obrane (DODD 3000.09)[328] kojom se uspostavlja američka politika o autonomiji ubojitih oružanih sustava daje definicije za različite kategorije autonomnih oružanih sustava za potrebe američke vojske. DODD 3000.09 definira LAWS kao "*oružane sustav/e koji nakon aktiviranja mogu birati ciljeve i djelovati na iste bez daljnje ljudske intervencije*."[329] Ovaj koncept autonomije također je poznat i kao „potpuna autonomija“. Druga kategorija su poluautonomni oružani sustavi koji djeluju samo na pojedinačne ciljeve po odabiru čovjeka. Poluautonomno oružje uključuje tzv. "pucaj i zaboravi" oružje poput navođenih raketa i sl. Ujedno, DODD 3000.09 zahtijeva da svi sustavi, uključujući LAWS, budu konstruirani na način da omoguće operateru primjenu ljudske prosudbe o upotrebi sile na odgovarajući način.[330] Ono što svakako interesira stručnu javnost, kako međunarodnu tako i američku, su tri ključna pitanja:

- U kojoj mjeri potencijalni američki protivnici razvijaju LAWS?
- Kako uravnotežiti istraživanje i razvoj LAWS s etičkim pitanjima?
- Kakvu bi ulogu SAD trebale imati u UN-ovim raspravama o LAWS, odnosno treba li SAD podržati "status *quo*"?[331]

U svakom slučaju, 25 zemalja i 100 nevladinih organizacija zatražile su preventivnu zabranu postavljanja LAWS zbog etičkih pitanja, ali i pitanja operativnog rizika, odgovornosti za uporabu te poštivanja načela razmjernosti sukladno ratnim zakonima.[332]

Iz navedenog može se zaključiti da su SAD sve donedavno bile inertne po pitanju zakonodavne regulative AI. Od 2019. savezne države su se više aktivirale, ali zbog posebnog državnog uređenja i raznolikosti opće populacije u saveznim državama i dalje postoji neujednačenost u odlukama. Svakako, više od polovice saveznih država podupire testiranja autonomnih vozila u određenom okruženju, ali s malim naglaskom na etičke standarde za AI. Kada je u pitanju LAWS, visoko rangirani vojni dužnosnici zauzeli su stav na temelju reciprociteta što znači da će ga SAD proizvoditi i koristiti ako to i njihovi protivnici budu radili. U široj javnosti povlače se pitanja etičnosti LAWS-a, ali su marginalizirana.

---

[328] *Ibid.*
[329] *Ibid,* 4.a DODD 3000.09
[330] United Nations Office at Geneva, “Background on Lethal Autonomous Weapons Systems in the CCW,” dostupno na: https://www.unog.ch/80256EE600585943/
[331] Defense Primer: U.S. Policy on LAWS, dostupno na: https://fas.org/sgp/crs/natsec/IF11150.pdf
[332] Congressional Research Service (2019). Defense Primer: U.S. Policy on Lethal Autonomous Weapon System, dostupno na: https://fas.org/sgp/crs/natsec/IF11150.pdf

2.18.7. RUSIJA

Važnost razvoja i primjene AI očituje se i u jednoj od izjava ruskog predsjednika *Vladimira Putina* koji je 2017. godine izrazio mišljenje kako će zemlja koja prva ovlada AI postati „vladar svijeta“.[333] Ruska agenda i napori u razvoju AI i pripadajuće infrastrukture fokusirani su na područje obrane Rusije. Sukladno tome, rusko Ministarstvo obrane, Ministarstvo obrazovanja i znanosti i Ruska akademija znanosti su 2018. godine organizirali konferenciju pod nazivom „Umjetna inteligencija - problemi i njihova rješenja“. Navedena konferencija iznjedrila je i Akcijski plan za razvoj sustava AI u Rusiji koji se sastoji od:[334]

- osnivanja BD konzorcija s primarnim ciljem unificiranja napora vodećih znanstvenih, obrazovnih i industrijskih organizacija u stvaranju i primjeni AI,
- razvijanja ekspertize u području automatizacije,[335]
- obrazovanja za područje AI na državnoj razini,
- izgradnje laboratorija za AI u znanstvenom, tehnološkom i istraživačkom kampusu gdje vojska i privatni sektor mogu zajedno raditi na inovativnim i modernim tehnologijama kao što su AI, robotika, automatizacija i sl.,[336]
- osnivanja Nacionalnog centra za AI s primarnom ulogom u razvoju znanosti s tog područja, razvoju infrastrukture i same tehnologije,
- nadgledanja globalnog razvoja AI,
- održavanja ratnih igara AI što podrazumijeva organiziranje i provođenje niza ratnih igara sa širokom spektrom scenarija, definirajući utjecaj modela AI na promjenjivi karakter vojnih operacija na različitim razinama - taktičkim, operativnim i strateškim,
- provjere usklađenosti sustava AI što uključuje razvoj sustava za procjenu usklađenosti sustava AI sa standardima struke,
- rasprave o sustavima AI i ostalim prijedlozima glede iste na domaćim vojnim forumima i

---

[333] Whoever Leads in AI Will Rule the World’: Putin to Russian Children on Knowledge Day (2017), RUSSIA TODAY, dostupno na: https://www.rt.com/news/401731-ai-rule-world-putin/

[334] Konferentsia “Iskusstvenij Intellect: Problemi I Puti Ikh Reshenia” – 2018” [Conference: “Artificial Intelligence: Problems and Their Solutions” – 2018], Ministry Of Defense Of Russia, dostupno na: http://mil.ru/conferences/is-intellekt.htm

[335] Bendett, S. (2018). Here’s How the Russian Military Is Organizing to Develop AI, DEFENSE ONE, dostupno na: https://www.defenseone.com/ideas/2018/07/russian-militarys-ai-development-roadmap/149900/

[336] *Ibid.*

- održavanje godišnje konferencije o AI.

Za razliku od prethodno analiziranih država, Rusija je izrazila ambiciju za razvijanjem LAWS-a. Jedan od čelnih ljudi ruske vojske je rekao kako će svaki budući vojni sukob koristiti visoko precizno i moderno oružje uključujući i robote.[337] Također, Rusija je zajedno s SAD-om na sastanku stranaka Konvencije o određenom konvencionalnom oružju blokirala predloženi sporazum o zabrani LAWS[338] iznoseći svoje mišljenje kako trenutno ne postoji jasna definicija LAWS-a, a nedostatak eksperimenata u tom području ostaje glavni problem u raspravi o LAWS-u.[339] Ujedno, naglašeno je kako nema jasne distinkcije između vojnog i civilnog razvoja autonomnih sustava koji proizlaze iz sustava AI.[340] Sukladno tome, Rusija smatra da se buduće rasprave u pogledu LAWS-a trebaju odnositi na usklađivanje osnovnih načela, definiranje koncepata te pojmova poput autonomije, ljudskog nadzora i predvidivosti što će opet ovisiti o definiciji LAWS-a.[341] Autonomna vozila se u Rusiji proizvode još od 2016. godine od strane nekoliko *start up*-ova i poduzeća *Yandex*. S obzirom na to da su strani proizvođači automobila poput Scania, Volvo, Toyota i Audi izrazili interes za testiranje svojih autonomnih vozila u tradicionalno teškim ruskim uvjetima vožnje[342], stručnjaci u industriji predviđaju da će do 2025. na ruskim cestama biti oko 20.000 autonomnih vozila.[343] Međutim, ruska zakonodavna tijela nisu uključila pravnu regulativu po pitanju autonomnih vozila, iako je u 2018. godini Kabinet ministara izdao prvu nacionalnu uredbu u pogledu testiranja.[344] Takva uredba regulira potrebu testiranja visoko-autonomnih vozila na javnim cestama u dvije ruske

---

[337] Ispol'zovanie Robotov i Shirokoe Primenenie Vysokotochnogo Oruzhija Stanut Osnovnymi Osobennostjami Vojn Budushhego – Nachal'nik Genshtaba Rossijskoj Armii [The Use of Robots and the Widespread Use of Precision Weapons Will Be the Main Features of Future Wars – Chief of the General Staff of the Russian Army], INTERFAKS, ABN, AGENSTVO BOENNIX NOVOSTEJ [INTERFAX, MNA, MILITARY NEWS AGENCY] (2018), dostupno na: http://www.militarynews.ru/story.asp?rid=1&nid=476975

[338] Handful of Countries – Including the US and Russia – Hamper Discussions to Ban Killer Robots at UN, FUTURE OF LIFE INSTITUTE (2018), dostupno na: https://futureoflife.org/2018/11/26/handful-of-countries-including-the-us-and-russia-hamper-discussions-to-ban-killer-robots-at-un/

[339] Submission of the Russian Federation to the GGE of the High Contracting Parties to the CCW, Examination of Various Dimensions of Emerging Technologies in the Area of Lethal Autonomous Weapons Systems, in the Context of the Objectives and Purposes of the Convention, UN Doc No. CCW/GGE.1/2017/WP.8 (2017), dostupno na: https://admin.govexec.com/media/russia.pdf

[340] *Ibid.*

[341] *Ibid.*

[342] New Legislation Set to Regulate Russia's Burgeoning Driverless Car Market (2018). THE BELL, dostupno na: https://thebell.io/en/new-legislation-set-to-regulate-russia-s-burgeoning-driverless-car-market

[343] Botoroeva, E. (2018). There Will Be 11 Million Driverless Cars in Russia in 25 Years, PARLAMENTSKAIA GAZETA, dostupno na: https://www.pnp.ru/social/v- rossii-cherez-25-let-budet-11-mln-bespilotnykh-avto-schitayut-v-rosstandarte.html

[344] Government of the Russian Federation, Regulation No. 1415 of Nov. 26, 2018, on Conducting an Experiment in the Test Use of Highly Automated Vehicles on Public Roads, dostupno na: http://government.ru/docs/34831/

regije i to u periodu od 1. prosinca 2018. do 1. ožujka 2022. po isteku kojeg će se raspravljati o daljnjim koracima.[345]

Za zaključiti je da Rusija najveći naglasak stavlja na obrazovanju za AI, nadgledanje globalnog razvoja iste te raspravi o AI na domaćim vojnim forumima. Rusija jasno pokazuje ambicije za razvoj LAWS-a, a po pitanju autonomnih vozila predviđa do 2025. oko 20.000 takvih vozila na cestama. O etičnosti upotrebe AI u raznim oblicima ima vrlo malo govora.

2.18.8. KINA

Kinesko ministarstvo industrije i informacijske tehnologije, ministarstvo javne sigurnosti i ministarstvo prometa su 11. travnja 2018. donijeli Administrativna pravila o testiranju inteligentnih i povezanih vozila na cestama.[346] Navedena pravila objavljena su nakon lokalnih propisa o ispitivanju autonomnih osobnih vozila na cestama koji su doneseni u Pekingu, Šangaju i *Chongqingu*, a stupili su na snagu 1. svibnja 2018. godine. S obzirom na to da su navedena pravila stupila na snagu nedugo nakon incidenta s testiranjem *Uber*-ovog autonomnog vozila gdje je došlo do smrtnih posljedica, sigurnost je naglašena kao ključni element u testiranju autonomne tehnologije.[347] Uzevši u obzir pravnu potporu i jasnu regulativu u smislu donošenja konciznih nacionalnih i lokalnih pravila, kineske vlasti smatraju da će se ostvariti dodatni poticaj u testiranju autonomnih vozila na cestama. U početku su osmišljeni kontrolirani uvjeti za ostvarenje testnih ideja i mogućnosti, ali Kina očekuje provođenje testnih faza diljem zemlje. Smatra se kako će takav pristup ubrzati razvoj i komercijalizaciju autonomnih vozila u Kini. Između ostalog, kineski predsjednik *Xi Jinping* je na forumu u *Boaou* 10. travnja 2018. izjavio da postoje planovi za daljnje otvaranje kineske ekonomije u kontekstu stranih direktnih ulaganja (engl. *Foreign Direct Investment* - FDI) u automobilskom sektoru čime bi se taj proces ostvarenja vodeće pozicije u svijetu za područje AI još više ubrzao.

Kada je u pitanju LAWS te usprkos neodgovorenim etičkim dvojbama, kineska vlada se posebno zainteresirala za AI u pogledu vojnog oružja.[348] General bojnik *Ding Xiangrong*,

---

[345] *Ibid.*
[346] King & Wood Mallesons (2018). China Issues Self-driving Car Road Testing Regulations, China Law Insight, dostupno na: https://www.chinalawinsight.com/2018/04/articles/compliance/china-issues-self-driving-car-road-testing-regulations/
[347] *Ibid.*
[348] Statement by the Chinese Delegation at the Thematic Debate on Conventional Weapons at the First Committee of the 73rd Session of the UNGA, dostupno na: https://www.un.org/disarmament/wp-content/uploads/2018/11/statement-by-china-cw.pdf

zamjenik ravnatelja kineskog središnjeg vojnog odbora, izrazio je kako je cilj Kine iskoristiti "*tekuću vojnu revoluciju usredotočenu na informacijsku i inteligentnu tehnologiju*".[349] Po pitanju toga te poduzeća poput CATIC (engl. *China National Aero-Technology Import & Export Corporation*) nedavno je stvoren tzv. "*Ziyan Blowfish*", bespilotni helikopter opremljen bombama koji autonomno obavlja složenije borbene misije, uključujući vremensku detekciju fiksne mete, izviđanje zadanog dometa i tzv. ciljane precizne udare. U međuvremenu, kineska vlada na sličan način razvija niz bespilotnih podmornica AI sposobnih za obavljanje širokog spektra misija, uključujući „samoubilačke napade“ na neprijateljske brodove. Ono što se može iščitati iz ovakvog djelovanja jeste želja za revolucioniranjem vlastitih vojnih mogućnosti koristeći AI kao prednost modernog ratovanja.

Osim navedenog, Kina marljivo radi i na testiranju autonomnih plovila gdje je u prosincu 2019. godine prvi puta uspješno izvela probno putovanje autonomnog teretnog broda.[350] Ono što je još zanimljivije jesu izvještaji koji navode smanjenje troškova gradnje od 20 %, kao i smanjenje od 20 % u operativnim troškovima i 15 % redukcije troškova u potrošnji goriva.[351] U pogledu ostale pravne regulative, Kina je od 2013. godine objavila nekoliko dokumenata na nacionalnoj razini koji odražavaju namjeru razvoja i korištenja AI u različitim sektorima. Primjerice, 2015. godine Državno vijeće objavilo je smjernice o kineskoj akciji "*Internet* +" za integraciju Interneta u sve elemente gospodarstva i društva.[352] Iste godine objavljen je desetogodišnji plan „*Made in China 2025*“ s ciljem da se Kina pretvori u ključnog igrača u pogledu proizvodnje i implementacije moderne tehnologije, odnosno AI.[353] Jedan od značajnih primjera kineske aktivnosti u razvoju i regulaciji AI je petogodišnji plan donesen na 13. odboru Središnje komunističke partije Kine koji je objavljen u ožujku 2016. U dokumentu se spominje AI kao jedna od šest ključnih područja razvoja kineske industrije i kao važan čimbenik poticanja gospodarskog rasta.[354] Međutim, prije 2016. AI je predstavljena samo kao jedna od mnogih

---

[349] Daly, C. (2019). China's Interest In Autonomous Weapons Cause For Concern?, AI Business, dostupno na: https://aibusiness.com/document.asp?doc_id=760973&site=aibusiness

[350] Brod je započeo testiranje s otoka Zhuhai na otoku Dong Ao i uspješno završio svoje putovanje od otoka do Hong Kong – Zhuhai - Macao mosta. Dostupno na: Safety4sea (2019). China successfully tests first autonomous cargo ship, dostupno na: https://safety4sea.com/china-successfully-tests-first-autonomous-cargo-ship/

[351] *Ibid.*

[352] China’s promotion of “Internet Plus governance”. (2017). The State Council, dostupno na: http://english.gov.cn/premier/news/2017/02/01/content_281475556331388.htm

[353] McBride, J., Chatzky, A. (2019). Is ‘Made in China 2025’ a Threat to Global Trade?, Council on Foreign Relations, dostupno na: https://www.cfr.org/backgrounder/made-china-2025-threat-global-trade

[354] The 13th Five Year Plan for Economic and Social Development of the People’s Republic of China. (2016). Central Compilation & Translation Press, dostupno na: https://en.ndrc.gov.cn/policyrelease_8233/201612/P020191101482242850325.pdf

tehnologija koja bi mogla biti korisna u postizanju niza ciljeva politike. To se promijenilo izdavanjem Plana razvoja AI nove generacije (engl. *New Generation Artificial Intelligence Development Plan* -AIDP).[355]

Sukladno navedenom, vidljivo je da kineske vlasti potiču testiranje autonomnih vozila na cestama te su otvoreni na temu LAWS-a. Kao i u slučaju konkurentskih, prethodno analiziranih država, ni Kina za sada ne pridaje značajniju važnost etici u upotrebi AI.

2.18.9. AUSTRALIJA

Australska uprava za pomorsku sigurnost (engl. *Australian Maritime Safety Authority* - AMSA) je uočila sve veći interes za uporabu bespilotnih i / ili autonomnih plovila u australskoj pomorskoj industriji. Uporaba bespilotnih i/ili autonomnih plovila mora biti jednako sigurna kao i brodovi s ljudskom posadom. Glavni ciljevi AMSA-e su sigurnost i zaštita morskog okoliša što se reflektira i kroz odobravanje certifikata za autonomna i/ili bespilotna plovila koja će ploviti u australskom teritorijalnom moru.[356] U tom kontekstu brodari i brodarska poduzeća najveću pažnju obraćaju na sigurnost i zaštitu ljudi, drugih plovila i okoliša. Stoga AMSA ima u planu kratkoročni, srednjoročni i dugoročniji pristup pravnoj i tehničkoj regulaciji autonomnih plovila.[357] Za očekivati je da će biti nužne izmjene postojećeg nacionalnog zakonodavstva kako bi AMSA pravilno postupala s autonomnim plovilima primjenjujući i buduće odredbe IMO-a o djelovanju u međunarodnom pomorskom prometu. Australija regulira autonomna plovila ili daljinski upravljana plovila kao:[358]

- domaća komercijalna plovila ako su australska plovila koja posluju na domaćem tržištu,
- australska plovila koja plove međunarodnim vodama i
- strana plovila koja plove u australskim teritorijalnim vodama.

---

[355] Next Generation Artificial Intelligence Development Plan Issued by State Council. (2017). China's Strengths Creates Innovation Miracles, China Science and Technology Newsletter, No. 17, dostupno na: http://fi.china-embassy.org/eng/kxjs/P020171025789108009001.pdf

[356] AMSA policy on regulatory treatment of unmanned and/or autonomous vessels, Australian Maritime Safety Authority, dostupno na: https://www.amsa.gov.au/sites/default/files/policy-regulatory-treatment-unmanned-autonomous-vessels.pdf

[357] Regulatory plan—five-year regulatory outlook, Australian Maritime Safety Authority, dostupno na: https://www.amsa.gov.au/about/corporate-publications/regulatory-plan-five-year-regulatory-outlook

[358] Autonomous vessels in Australia, Australian Maritime Safety Authority, dostupno na: https://www.amsa.gov.au/vessels-operators/domestic-commercial-vessels/autonomous-vessels-australia

Trenutno se za ta plovila primjenjuje isti regulatorni okvir kao i za ostala plovila, uključujući standarde za pregled i zahtjeve za posadu. To je rezultat široke definicije plovila u Zakonu o plovidbi iz 2012.[359] i Nacionalnom zakonu o sigurnosti plovidbe iz 2012.[360] S obzirom na navedeno, AMSA je zauzela pristup izdavanja smjernica i preporuka u pogledu autonomnih plovila vodeći se ključnim načelima autonomne plovidbe poput:

- autonomna plovila ili plovila kojima se upravlja na daljinu moraju biti sigurna koliko i plovila s ljudskom posadom,
- rizici po sigurnost ljudi, drugih plovila i okoliša moraju se na odgovarajući način identificirati i smanjiti i
- brodar i/ili zapovjednik je odgovoran za sigurnosne standarde plovila.[361]

Autonomna vozila predstavljaju ključan element za primjenu AI u prometu. U kontekstu autonomije vozila na cestama društvo inženjera automobila (engl. *Society of Automotive Engineers* - SAE) definira pet razina autonomije vozila priznatih i primijenjenih globalno, ne uključujući nultu razinu odnosno razinu bez autonomije. Riječ je o sljedećim razinama prikazanim na slici 2-5.[362]

[359] Navigation Act 2012, Australian Maritime Safety Authority, dostupno na: https://www.amsa.gov.au/about/regulations-and-standards/navigation-act-2012

[360] National Law Act 2012, Australian Maritime Safety Authority, dostupno na: https://www.amsa.gov.au/about/regulations-and-standards/national-law-act-2012

[361] AMSA - Autonomous vessels in Australia, dostupno na: https://www.amsa.gov.au/vessels-operators/domestic-commercial-vessels/autonomous-vessels-australia

[362] Society of Automotive Engineers. 2018. Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles J3016_201806, dostupno na: https://www.sae.org/standards/content/j3016_201806/

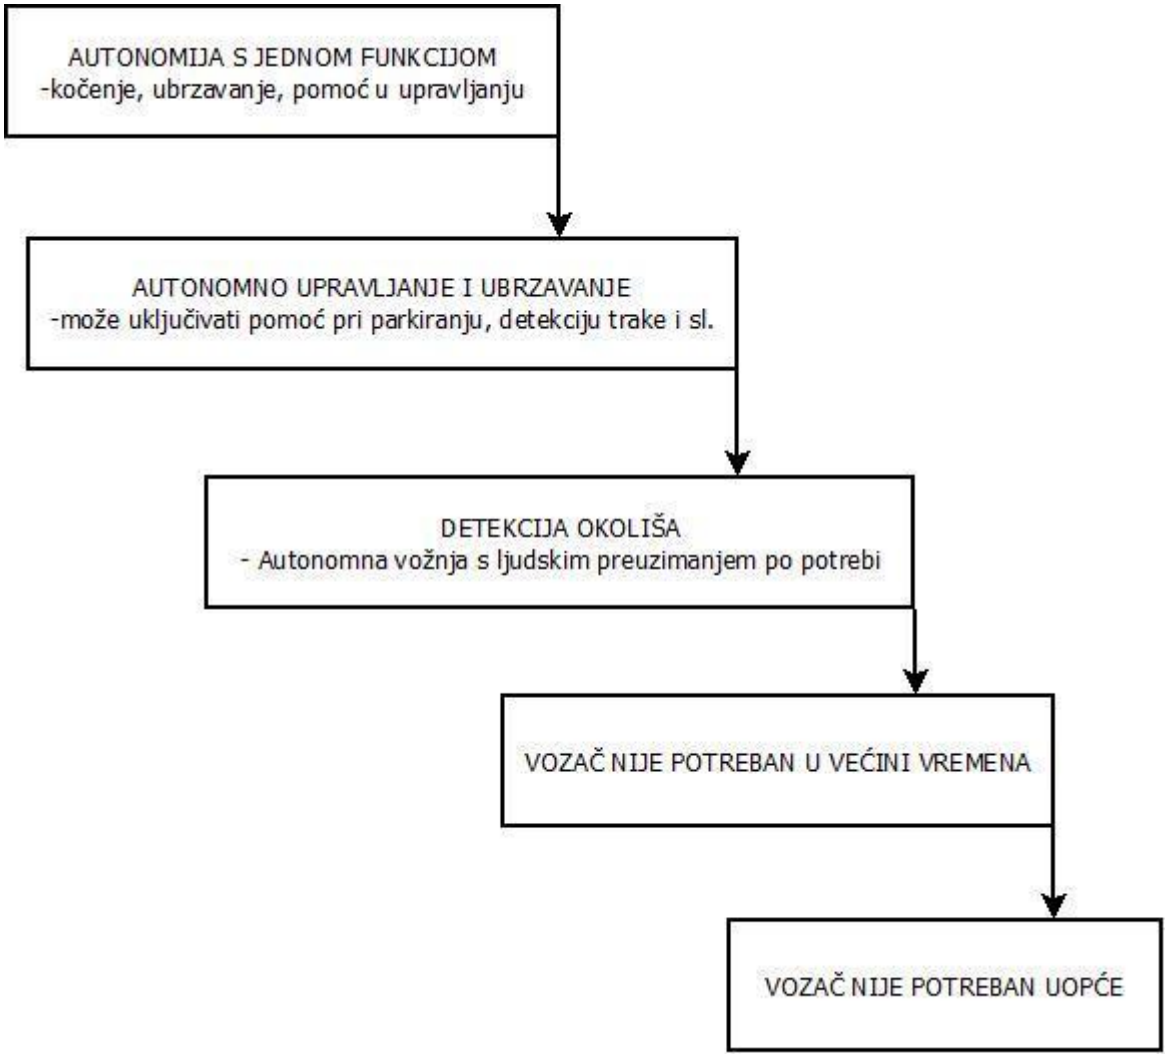

Slika 2-5 Pet razina autonomne vožnje,

Izvor: Society of Automotive Engineers, 2018.

Australsko ministarstvo prometa objavilo je program reformi kojima podržavaju siguran i pravno reguliran promet autonomnim vozilima čiji je prijedlog dostavila Nacionalna komisija za promet[363] 2020. godine.[364] U tom smislu, NTC je nedavno objavila smjernice za ispitivanje automatiziranih vozila u Australiji[365] koje određuju postupak prijave za dobivanje dozvole za testiranje autonomnih vozila na australskim cestama. Kriteriji koji se moraju definirati kroz zahtjev vezani su za detalje o mjestu pokusa, tehnologiji koja se testira, planu upravljanja prometom, infrastrukturnim zahtjevima ispitivanja, suočavanju poduzeća s javnošću te upravljanju promjenama tijekom testiranja. Premda nema poseban zakon o autonomnim

[363] engl. *National Transport Commission* - NTC
[364] National Transport Commission. (2018). Automated vehicles in Australia.
[365] National Transport Commission. (2017). Guidelines for Trials of Automated Vehicles in Australia.

plovilima i/ili vozilima, u Australiji je jako dobro definiran postupak testiranja takvih plovila/vozila s naglaskom na sigurnost ljudskih života i sigurnim upravljanjem, pri čemu se smatra kako će skup kvalitetnih i ujednačenih pravila rezultirati boljom optimizacijom navedenih tehnologija u budućim pravnim propisima i tehnološkim dostignućima.

U kvartetu analiziranih država u svijetu Australija najviše od svih podržava autonomna vozila i plovila za koje već i postoji određena zakonska regulativa. U tom smislu raspravlja se i o etičkim smjernicama upotrebe AI, a LAWS i upotreba istog se ne planira. S obzirom na sve navedeno u analizi država u svijetu glede primjene AI razvidno je da svjetski moćnici vrlo malo raspravljaju o etičnosti upotrebe AI, dok vodeće sile daju do znanju da su spremne razvijati LAWS ako se osjete ugrožene.

2.19. NACIONALNE STRATEGIJE ZA UMJETNU INTELIGENCIJU

U ovom poglavlju istražene su nacionalne strategije pojedinih zemalja važne za područje AI.

2.19.1. SAVEZNA REPUBLIKA NJEMAČKA

Njemačka strategija za AI je razvijena u suradnji njemačke Federalne vlade s Federalnim ministarstvom obrazovanja i istraživanja, Federalnim ministarstvom za ekonomska pitanja i energetiku te Federalnim ministarstvom rada i socijalnih poslova.[366] U Njemačkoj strategiji za AI se ističe inicijativa istraživanja, razvoja i primjene AI u Njemačkoj, odnosno AI revoluciju tzv. "*Industrie 4.0*". Jedan od strateških planova je omogućiti financiranje za napredak sektora, zbog čega će se osigurati tri milijarde eura do 2025. godine. Kao što je već i ranije navedeno, ne postoji unificirana definicija AI. Njemačka strategija za AI se stoga temelji na postojanju dvije skupine AI. Riječ je o "jakoj" i "slaboj" AI. „Jaka“ AI predstavlja sustave koji imaju iste intelektualne sposobnosti kao ljudi ili ih čak i premašuju, dok je „slaba“ AI usmjerena na rješavanje posebnih problema primjenom metoda iz matematike i informatike. Preciznije rečeno, „slaba“ AI može raditi samo jednu stvar u određenom trenutku zbog čega se može reći da je „slaba“ AI specijalist u svome području i u kontekstu svoje funkcije.[367] Federalna vlada

[366] Germany AI Strategy Report, dostupno na: https://ec.europa.eu/knowledge4policy/ai-watch/germany-ai-strategy-report_en
[367] *Ibid*, str. 4.

je svoju strategiju orijentirala na korištenje AI za rješavanje posebnih problema, tj. na "slabi" pristup koji se očituje u sljedećim točkama:

- sustavi za odbitak, strojno utemeljeni dokazi: oduzimanje formalnih izjava iz logičkih izraza, sustavi za dokaz ispravnosti hardvera i softvera,
- sustavi temeljeni na znanju: metode modeliranja, softver za simulaciju ljudske ekspertize u suradnji sa psihologijom i kognitivnim znanostima,
- analiza uzoraka i prepoznavanje uzoraka: induktivni analitički procesi, ML,
- robotika i autonomni sustavi i
- pametna multimodalna interakcija čovjek-stroj: analiza i „razumijevanje“ jezika (u suradnji s lingvistikom), slike, geste i drugi oblici ljudske interakcije.[368]

Prema Njemačkoj strategiji tri su ključna cilja razvoja AI:

- etabliranje Njemačke i Europe kao vodeće sile u AI što će omogućiti buduću konkurentnost,
- odgovoran razvoj i upotrebu AI za dobrobit društva i
- integracija AI u društvo kroz etičke, pravne i kulturne okvire.[369]

Međutim, Njemačka je svjesna strukture funkcioniranja AI, odnosno činjenice da AI ovisi o BD što je zbog strogih njemačkih propisa značajan problem. U tom kontekstu, promiču se istraživanja u postupcima pseudonimizacije i anonimizacije podataka koji bi se potom mogli koristiti u funkcionalnom dijelu AI. Također, u Njemačkoj strategiji za AI navodi se potencijalni uspjeh razvijanja uvjerljivih modela anonimizacije i pseudonimizacije koji bi rezultirao i spremnošću građana da svoje podatke učine dostupnim u istraživačke svrhe što bi značajno olakšalo posao implementacije AI. U taj proces je uključena i proizvodnja sintetičkih podataka[370] u budućnosti kao i sklapanje partnerstava između poduzeća po pitanju razmjene podataka. Uz to, Njemačka strategija za AI orijentirana je i na tipične društvene ciljeve poput iskorištavanja AI za agrokulturu i proizvodnju hrane, zaštitu okoliša, korištenje tehnologije za zaštitu građana ili poboljšanja na području sigurnosti informacijskih i komunikacijskih sustava, ali velik naglasak je stavljen i na financijski sektor. Federalna vlada osnovala je *FinTech* Savjet za transformaciju financijskog sektora i postojećih poslovnih modela u modele integrirane s AI i BD, prvenstveno vodeći se idejom učinkovitog bankarskog procesa, a što će otvoriti posve

[368] Njemačka strategija za AI, str. 5.
[369] *Ibid*, str. 8-9.
[370] Prema *McGraw-Hill Dictionary of Scientific and Technical Terms* iz 2009. godine sintetički podaci su svi podaci primjenjivi u određenoj situaciji koji se ne dobivaju izravnim mjerenjem.

nove mogućnosti trenutnim ili budućim pružateljima usluga na tom području. Međutim, pitanje nadzora i regulacije se ipak tek treba utvrditi. Također, nužno je osigurati upotrebu AI na način da ista neće narušiti temeljne vrijednosti na kojima je zasnovan demokratski poredak Njemačke, kao ni prava sadržana u njemačkom Ustavu,[371] a posebno opću slobodu djelovanja, zaštitu privatnosti i kontrolu osobnih podataka. Stoga, Federalna vlada smatra nužnim revidirati i pregledati sveobuhvatnost njemačkog zakonodavnog okvira za sve aspekte koji se odnose na odluke, usluge i proizvode temeljene na algoritmima i AI, te ih po potrebi prilagoditi na način da se eliminira potencijalna diskriminacija ili pristranost.

Shodno navedenom, Njemačka je zauzela strateški stav glede AI, a koji se temelji na „jakoj" i „slaboj" AI. Njemačka planira postati vodeća svjetska sila u razvoju i primjeni AI, ali s naglaskom na odgovornosti prema društvu te integraciji AI kroz etičke, pravne i kulturne procese.

2.19.2. UJEDINJENO KRALJEVSTVO

Industrijska strategija - sektorska AI[372] izdana od strane UK navodi da je i kroz povijest bilo trenutaka u kojima bi napredak tehnologije u kombinaciji s inovativnim sadržajima preobrazio dotadašnji život ljudi. Tehnike koje koristi AI, poput ML, već sada značajno poboljšavaju svakodnevni život koristeći funkcije inteligentnih osobnih pomoćnika te sustava koji štite financijski sustav[373] pa čak i softvera za pružanje medicinskih savjeta. Uvodni dio Strategije UK navodi i napredne algoritmičke tehnike poput DL u kontekstu brzog rješavanja složenih problema, čime se poveća produktivnost. UK smatra da je nužno osigurati kolektivnu korisnost sustava AI zbog čega Vlada UK osniva Centar za podatkovnu etiku i inovacije za savjetovanje o etičkoj upotrebi podataka, uključujući i AI. U kreiranju strategije UK postavljeni su ključni temelji na čemu bi se trebala razvijati industrijska strategija, a to su:

- ideje,
- ljudi,
- infrastruktura,

---

[371] Njem. *Grundgesetz für die Bundesrepublik Deutschland*

[372] Clark, G., Hancock, M., Hall, W., Pesenti, J. (2018). Industrial Strategy Artificial Intelligence Sector Deal, HM Government, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/702810/180425_BEIS_AI_Sector_Deal__4_.pdf

[373] PwC (2017). The Impact of Artificial Intelligence on the UK Economy, dostupno na: https://www.pwc.co.uk/economic-services/assets/ai-uk-report-v2.pdf

- poslovno okruženje i
- lokacija.[374]

Ključne politike za razvoj strategije u idejnom smislu uključuju povećanje ukupnog ulaganja u istraživanje i razvoj na 2,4% BDP-a do 2027., zatim povećanje stope kredita za istraživanje i razvoj na 12% te ulaganje 725 milijuna funti u nove programe fonda za industrijsku strategiju izazova.[375] U kontekstu ključnih politika u pogledu ljudi navedeno uključuje uspostavljanje tehnički obrazovni sustav uz bok najvećim svjetski silama, ulaganje 406 milijuna funti u vještine, uključujući matematiku, digitalno i tehničko obrazovanje, pomažući u rješavanju nedostatka vještina u području znanosti, tehnologije, inženjerstva i matematike (engl. *Science, Technology, Engineering, Math* - STEM) te stvaranje nove, unificirane i nacionalne prekvalifikacije koja podržava ljude u stjecanju novih vještina, što će rezultirati početnim ulaganjem od 64 milijuna funti za digitalnu i ostale obuke.[376] U pogledu infrastrukturnog napretka ključne politike odnose se na povećanje državnog fonda za investicije u području produktivnosti na 31 milijardu funti, ističući ulaganja u promet, stambenu i digitalnu infrastrukturu, zatim podršku električnim vozilima putem ulaganja u infrastrukturu za punjenje od 500 milijuna funti i ulaganje dodatnih milijardu funti javnog novca u digitalnu infrastrukturu, uključujući 176 milijuna funti za 5G i 200 milijuna funti za poticanje implementiranja mreža baziranih na optičkim kabelima.[377] Politike koje se kreiraju unutar poslovnog okruženja uključuju pokretanje sektorskih javno-privatnih partnerstava s ciljem povećanja produktivnosti sektora. Prva takva partnerstva očekuju se u području AI i automobilskom sektoru, uz osiguravanje ulaganja od 20 milijardi funti u inovativne poslove poduzeća te pokretanje nadzornih mehanizama za omogućavanje učinkovite produktivnosti i rasta SME kao i poduzeća s nižom produktivnosti.[378]

Naposljetku, politika za lokacije uključuje usklađivanje s lokalnim industrijskim strategijama koje se oslanjaju na lokalne snage i ostvaruju ekonomske prilike i stvaranje novih fondova za transformaciju gradova koji će osigurati 1,7 milijardi funti za gradski prijevoz.[379] U smislu nadzora implementacije sektorskog sporazuma važno je uspostaviti vladin Ured za AI koji će biti odgovoran za provedbu sektorskog sporazuma. Vlada UK naglašava ulogu Ureda

[374] Clark, G. *et.al., op.cit.*, str. 6.
[375] *Ibid*, str. 5.
[376] *Loc.cit.*
[377] *Ibid*, str. 8.
[378] *Ibid*, str. 5.
[379] *Loc.cit.*

za AI koji se odnosi na usuglašavanje provedbenih planova za svaki dio posla, uključujući dogovorena mjerila uspjeha. Također, glavni cilj Vijeća AI bit će osigurati strateško vodstvo i prednost u realizaciji.[380] Ozbiljnost istraživanja i primjene AI očituje se u uspostavljenim hijerarhijskim modulima, pa će tako Ured za AI redovito podnositi izvješća Vijeću AI i biti će podložno raspravama na sjednicama Ministara vlada o napretku u provedbi sektorskog posla. Tim za industrijsku strategiju pružit će izazov u vezi s rokom isporuke, mjernim podacima i ambicijama o ishodima, kao i pružanjem najnovijih vijesti i napretku ministrima kroz sektorske izvještaje.[381]

UK veliki naglasak stavlja na etičnost primjene AI i na inovacije. Temeljne strateške odrednice odnose se na ideje, infrastrukturu, okruženje i lokacije s čovjekom kao centralnom figurom razvoja i primjene AI. Može se zaključiti da je takva strategija proeuropska i ne bi se trebala mijenjati usprkos izlasku UK iz EU.

2.19.3. ITALIJA

U kolovozu 2019. talijansko Ministarstvo gospodarskog razvoja objavilo je nacrt verzije svoje Nacionalne strategije za AI[382] na javnu raspravu. Istodobno je Ministarstvo objavilo i popratni dokument pod naslovom Prijedlozi talijanske strategije za AI[383] koji pruža početna načela i preporuke politike kao osnovu za strategiju AI u Italiji. Kada je u pitanju dugoročna strategija Italije u kontekstu održivog razvoja AI, navedeno je devet ključnih ciljeva za povećanje razvoja i konkurentnosti AI u Italiji:[384]

- povećati javna i privatna ulaganja u području AI i ostale slične tehnologije,
- poboljšati ekosustav istraživanja i inovacija u području AI,
- podržati usvajanje digitalnih tehnologija utemeljenih na AI,
- ojačati edukaciju i obrazovanje na svim razinama kako bi se AI dovela u službu ljudi,

[380] Hall, W., Pesenti, J. (2017). *op.cit.*, str. 14.
[381] *Ibid*, str. 3.
[382] Strategia Nazionale per l'Intelligenza Artificiale, dostupno na: https://www.mise.gov.it/images/stories/documenti/Strategia-Nazionale-Intelligenza-Artificiale-Bozza-Consultazione.pdf
[383] Proposte per una strategia italiana per l'intelligenza artificiale (2019). Elaborata dal Gruppo di Esperti MISE sull'intelligenza artificiale, dostupno na: https://www.mise.gov.it/images/stories/documenti/Proposte-per-una-strategia-italiana-2019.pdf
[384] *Ibid*, str. 5.

- iskoristiti potencijal podatkovne ekonomije,
- stabilizirati i ujednačiti zakonodavni i etički okvir koji upravlja razvojem AI,
- promovirati svijest i povjerenje u AI među građanima,
- pokrenuti javnu upravu i učiniti javnu politiku učinkovitijom i
- poticati europsku i međunarodnu suradnju za odgovornu i uključivu AI.

Strategija talijanske vlade glede financiranja provedbe strategije AI jest izdvajanje jedne milijarde eura s ciljem privlačenja dodatnih privatnih ulaganja u istom iznosu što bi rezultiralo ukupnim opsegom ulaganja od dvije milijarde eura. Istraživački ekosustav Italije za AI je primijenjen kroz veliki broj nacionalnih centara izvrsnosti, kao što su Laboratorij za AI i inteligentne sustave[385] talijanskog međusveučilišnog konzorcija za informatiku,[386] Talijanski tehnološki institut[387] i Institut za proračun i mreže za visoke usluge[388] te Nacionalno vijeće za istraživanje.[389] Osim navedenog, cilj Italije jest povećanje konkurentnosti u sektoru AI i korištenje aplikacija podržanih AI. Jedna od tih inicijativa je *Smart & Start Italia,*[390] program kojeg financira Vlada, a koji potiče nova poduzeća u digitalnoj ekonomiji. Namjenski programi financiranja razvijat će se za eksperimentiranja i testiranja za specifična područja primjene poput *blockchain*-a, AI i IoT.[391]

U pogledu umrežavanja talijanska Strategija naglašava da će poticati već navedene centre izvrsnosti u pogledu izgradnje mreže za istraživanje i razvoj. Ukupno 8 centara kompetencija koje je osnovalo Ministarstvo za ekonomski razvoj i 12 europskih tehnoloških klastera koje je osnovalo Ministarstvo obrazovanja zajedno sa nadležnim sveučilištima činit će osnovu za nacionalnu mrežu za razmjenu znanja i suradnju. Svi ti elementi implementirani su u program Digitalne Europe za razdoblje 2021. - 2027.[392] Talijanska Strategija spominje svoju proaktivnu potporu europskim inicijativama poput Konfederacije laboratorija za AI u Europi[393] i javno-privatnim partnerstvima za elektroničke komponente i sustave[394] (ECSEL).[395] Uz to, Italija

[385] Više o laboratoriju za AI na: https://www.consorzio-cini.it/index.php/it/artificial-intelligence-and-intelligent-systems
[386] Više o konzorciju na: https://www.consorzio-cini.it/index.php/it/artificial-intelligence-and-intelligent-systems
[387] Više o Tehnološkom institutu na: https://www.iit.it
[388] Više o Institutu na: https://www.cnr.it/en/institute/018/institute-for-high-performance-computing-and-networking-icar
[389] Više o vijeću na: https://www.cnr.it/en
[390] Više o programu na: https://www.mise.gov.it/index.php/it/incentivi/impresa/smart-start
[391] Nacionalna strategija za AI, str. 8.
[392] *Loc.cit.*
[393] Više o konfederaciji laboratorija na: https://claire-ai.org
[394] Više o tome na: https://ec.europa.eu/digital-single-market/en/ecsel
[395] Nacionalna strategija za AI, str. 10.

pretpostavlja i uspostavljanje središnjeg centra za koordinaciju napora na nacionalnom umrežavanju koji će biti propisno opremljen odgovarajućom digitalnom infrastrukturom. Kako bi povećala međunarodnu privlačnost Italije u području AI, talijanska Vlada predviđa jačanje postojećih političkih instrumenata kojima se želi kreirati skup stranih i domaćih ljudskih talenata na području AI kroz program poput Plava karta EU[396] i talijanska *start up* viza.[397] Svakako važan cilj talijanske Vlade po pitanju strategije za AI jeste iskoristiti potencijal podatkovne ekonomije poboljšanjem interoperabilnosti i dostupnosti podataka javne uprave putem aplikacijsko programskog sučelja. U cilju jednostavnije razmjene podataka aktivno je promicanje sporazuma o razmjeni podataka, posebno u strateškim sektorima s velikim potencijalom i društvenim interesom. Uz to, Italija ima u planu pokrenuti pilot projekt za procjenu prednosti tzv. *Data Trust* modela, čiji je cilj osigurati razmjenu podataka na pošten, siguran i pravedan način. Značajno je i aktivno podržavanje stvaranja zajedničkog europskog prostora podataka.[398]

Iz navedenog je razvidno kako Italija ima detaljno razrađenu strategiju razvoja AI i njezine primjene u društvu. Od devet ključnih ciljeva naglasak se stavlja na podizanje svijesti i povjerenja građana u sustave AI te poticanje međunarodne suradnje. Značajan je poslovni fokus države na AI koji bi predstavljao temelj podizanja kvalitetne digitalne ekonomije, što bi Italiju kao pomorsku zemlju svakako značajno unaprijedilo u smislu primjene iste na vlastiti pomorski promet.

2.19.4. ŠPANJOLSKA

U ožujku 2019. španjolsko Ministarstvo znanosti, inovacija i sveučilišta objavilo je Strategiju za istraživanje, razvoj i inovacije u području AI[399] (engl. *RDI Strategy in Artificial Intelligence* - RDIAI). RDIAI definira cijeli niz prioriteta i preporuka za djelovanje kroz razne politike, a sve u svrhu stvaranja kvalitetnog sustava za razvoj i implementaciju tehnologija temeljenih na AI. Primarni cilj RDIAI je svakako istraživanje, razvoj i inovacije u AI koji će

[396] EU Blue Card Network, dostupno na: https://www.apply.eu/BlueCard/Italy/
[397] Italia Startup Visa, dostupno na: http://italiastartupvisa.mise.gov.it
[398] Italy AI Strategy Report, dostupno na: https://ec.europa.eu/knowledge4policy/ai-watch/italy-ai-strategy-report_en
[399] Spanish RDI Strategy in Artificial Intelligence, dostupna na: https://www.ciencia.gob.es/stfls/MICINN/Ciencia/Ficheros/Estrategia_Inteligencia_Artificial_EN.PDF

postaviti temelj daljnjem napretku tehnologije i sustava. U tom kontekstu identificirani su sljedeći prioriteti:

- donošenje kvalitetnog pravnog i ostalih okvira sustava istraživanja, razvoja i inovacija te analiza njegovog društveno-ekonomskog utjecaja,
- identificiranje ključnih prioritetnih područja u kojima bi trebalo maksimizirati istraživanja i inovacije u AI,
- olakšavanje transfera znanja i implementacija „*back to the community*“ sustava u kontekstu dobrobiti društva,
- razvoj obrazovnog sustava i kompetencija u području AI,
- uspostavljanje sustava digitalnih podataka i unapređenje dostupne digitalne infrastrukture i
- analiza i razvoj etičkog okvira iz perspektive istraživanja, razvoja i inovacija.[400]

Kao što je već i identificirano kroz strategije drugih država članica EU, tako i Španjolska naglašava cilj razvijanja organizacijske strukture kroz različite političke inicijative kojima bi se povećale mogućnosti za međunarodnu, međuinstitucijsku i ostalu suradnju. Između ostalog, ista treba uključivati i stvaranje mreže centara izvrsnosti[401] u AI i Digitalne inovacijske inkubatore. Kroz cilj ostvarivanja potencijalne suradnje na navedenom području RDIAI predlaže pokretanje mape sposobnosti za AI koja bi istraživala i preslikala mogućnosti AI u svim španjolskim znanstvenim i tehnološkim zajednicama. Prioritetna područja definirana u RDIAI odnose se na sljedeće sektore i aktivnosti:

- povezana industrija 4.0,
- pametni gradovi i područja,
- zdravstvo,
- energija i okoliš,
- sigurnost i zaštita,
- kultura i turizam,
- javna uprava i
- obrazovanje.[402]

---

[400] RDIAI, str. 9.

[401] Popis centara izvornosti dostupan na: https://www.ciencia.gob.es/portal/site/MICINN/menuitem.7eeac5cd345b4f34f09dfd1001432ea0/?vgnextoid=cba733a6368c2310VgnVCM1000001d04140aRCRD&lang_choosen=en

[402] RDIAI, str. 24.

Uz to, Španjolska prepoznaje potrebu za interdisciplinarnim, multidisciplinarnim i transdisciplinarnim usavršavanjem i edukacijom prateći razvoj AI na svim razinama obrazovanja. To zahtijeva osnovno i napredno obrazovanje AI u osnovnom, srednjem i visokom obrazovanju. Te bi mjere trebalo dopuniti posebnim obukama za profesionalce koje nude cjeloživotno učenje i mogućnost dokvalifikacije. RDIAI prepoznaje i vrijednost podataka u razvoju AI. Jedna od predloženih inicijativa Španjolske jest model tzv. otvorenih podataka ili bolje rečeno dostupnih podataka kroz javne sektore i sl.[403] Ostale inicijative uključuju pružanje algoritamskih i ostalih platformi AI s ciljem olakšanog korištenja otvorenih baza podataka. Španjolska vlada postavila je i fizičku računalnu infrastrukturu poput španjolske super-računalne mreže,[404] odnosno distribuirane mreže 13 superračunala. Uz navedeno, jasna je i inicijativa o sudjelovanju u provedbi europske inicijative *Open Science Cloud*[405] tzv. "*cloud*", infrastrukture za promicanje otvorene znanosti na europskoj razini koja se može shvatiti kao moguće djelovanje kojim se podržava i razvoj budućih 5G komunikacijskih mreža. Naposljetku, RDIAI preporuča i osnivanje španjolskog Odbora za istraživačku etiku u cilju izrade etičkih normi za AI i definiranje etičkih smjernica za pošteno i održivo korištenje i razvoj AI.

Sukladno navedenom, Španjolska je zauzela strateški stav prema kojem želi razviti kvalitetan pravni i etički okvir upotrebe AI te se fokusira na obrazovanje i inovacije. Slijedom toga će razvijati i infrastrukturu te ostale platforme. S obzirom na dugu pomorsku povijest, Španjolska planira i brzi razvoj 5G tehnologija čime će u kontekstu AI stvoriti dobre temelje za primjenu iste u pomorskom prometu.

[403] Vidi na: https://datos.gob.es/en
[404] Vidi na: https://www.res.es/en
[405] Vidi na: https://ec.europa.eu/research/openscience/index.cfm?pg=open-science-cloud

2.19.5. FRANCUSKA

U ožujku 2018. francuski predsjednik je u svom izlaganju predstavio viziju i strategiju o francuskoj ulozi u pogledu AI. Smatra da Francuska može postati lider u području AI što je istodobno cilj svim većim svjetskim silama. Francuska strategija AI (dalje u tekstu: FRAAI) nosi naziv „AI za čovječanstvo“[406] i razvijena je na temelju izvještaja o politici države prema AI.[407] Glavni ciljevi FRAAI su:

- poboljšati ekosustav obrazovanja i osposobljavanja u području AI čime bi se potencijalno privukli najkvalitetniji ljudski resursi i talentirani budući naraštaji,[408]
- uspostaviti politiku otvorenih podataka za implementaciju aplikacija temeljenih na AI[409] i
- razviti etički okvir za transparentno i pošteno korištenje aplikacija temeljenih na AI.[410]

U svrhu razvoja AI francuska vlada bi do kraja 2022. godine trebala izdvojiti 1,5 milijardi eura. FRAAI naglašava dva važna preduvjeta za uspješan razvoj ljudskih resursa u području AI predstavljajući ih kao istinski kapital, odnosno ljudski kapital.[411] Prvi preduvjet odnosi se na uključivanje učinkovitih i obveznih digitalnih i ostalih disciplina koje su vezane za AI. To bi obuhvatilo sve obrazovne razine što zahtijeva i reforme sadržaja predmeta i korištenih nastavnih metoda. Drugi preduvjet odnosi se na socijalnu nejednakost, točnije nužnost za pristupačnošću edukativnim programima svim osobama. Ključnu ulogu u tom segmentu odigrala bi politika veće raznolikosti i jednakosti u stopama sudjelovanja s posebnim naglaskom na suzbijanje bilo kojeg oblika rodnog stereotipiziranja. U kontekstu formalnog obrazovanja i osposobljavanja FRAAI predviđa:

- pokretanje programa edukacije i obrazovanja na području AI prema svim razinama obrazovanja s posebnim naglaskom na programe visokog obrazovanja na Interdisciplinarnim zavodima za AI.[412] Primarni cilj u tom dijelu odnosi se na udvostručavanje broja učenika AI i polaznika programa za AI i

---

[406] French Strategy for Artificial Intelligence, dostupna na: https://www.aiforhumanity.fr/en/
[407] Villani, C. (2018). For a meaningful artificial intelligence: towards a french and european strategy, dostupno na: https://www.aiforhumanity.fr/pdfs/MissionVillani_Report_ENG-VF.pdf
[408] FRAAI, str. 20.
[409] *Ibid*, str. 19.
[410] *Ibid*, str. 119.
[411] *Ibid*, str. 19.
[412] Više o tome na: https://www.inria.fr/en/actualites_evenements

- poticanje obrazovanja svih dionika uključenih u "AI lanac" (dizajneri, profesionalci, građani) i omogućavanje svakom građaninu poboljšanje vlastite digitalne pismenosti kako bi bolje razumio unutarnju strukturu i rad strojeva te prednosti AI.[413]

U pogledu velikih ciljeva koji su postavljeni u FRAAI nužnost predstavlja istraživanje i razvoj. Odgovornost za koordinaciju istraživačke strane dodijeljena je Francuskom nacionalnom istraživačkom institutu za digitalne znanosti (dalje u tekstu: INRIA) s jasnim ciljem: ojačati cijeli francuski sektor za AI. Između ostalog, INRIA će koordinirati provedbu strategije, pružiti znanstvenu i tehnološku ekspertizu i razviti inicijative za bilateralnu suradnju, posebno s Njemačkom.[414] Prema FRAAI ključne potpore u istraživanju i razvoju moraju biti usmjerene prema gospodarskim i ostalim sektorima koji takve promjene mogu brže i bolje prihvatiti i implementirati u svoje sustave. To se ponajviše odnosi na sektore poput zdravstva, prometa, okoliša, obrane i sigurnosti. Stoga je nužno kreirati tzv. sektorske platforme koje će omogućiti sustave za prikupljanje i razmjenu podataka, računalnu infrastrukturu širokog razmjera i testne infrastrukture. Iako se mnogi od ovih aspekata dotiču infrastrukture, francuska vlada zagovara stvaranje testnih područja kako bi se olakšao dizajn i implementacija tehnologija temeljenih na AI.[415] Time žele omogućiti eksperimentiranje u stvarnim uvjetima, a istovremeno smanjiti zakonodavne i regulatorne obveze na najmanje moguće i prihvatljive za društvo.

Uz navedeno, ističu se i prednosti kreiranja kolaboracijskih mreža i suradnje u području AI koje su u tom kontekstu mnogostruke. FRAAI se dotiče i etičkih pitanja u pogledu osiguranja pravednosti i transparentnosti AI. S tim u svezi, *Cédric Villani* u svom izvješću preporučuje stvaranje Odbora za digitalnu tehnologiju i etiku AI koji bi bio zadužen za vođenje javne rasprave na transparentan, a ipak zakonski određen način. U tu svrhu je stvoren Digitalni odbor s Nacionalnim savjetodavnim odborom za etiku. Etička načela, između ostalog, oblikuju se kroz sljedeće preporuke politike:

- da bi se zajamčila etička svijest još od faze dizajna, etika bi se mogla ugraditi u obuku inženjera i istraživača koji studiraju AI,
- jačanje etike unutar poduzeća (npr. osnivanje etičkih odbora i sl.),

[413] Executive Report, str. 2-4., dostupno na: https://www.aiforhumanity.fr/pdfs/MissionVillani_Summary_ENG.pdf
[414] FRAAI, str. 128.
[415] *Ibid*, str. 9.

- postavljanje nacionalne platforme za reviziju algoritama čime bi se mogla raditi procjena o sukladnosti istoga s pravnim i etičkim okvirima. Smatra se da bi taj način funkcioniranja povećao transparentnost i smanjio možebitne zloupotrebe AI i
- pokretanje Globalnog partnerstva za AI (dalje u tekstu: GPAI). Naime, potpisana je deklaracija s Kanadom za pokretanje projekta o stvaranju međunarodne studijske skupine za AI koja će biti fokusirana na razvoj odgovornog sustava AI. Ova će inicijativa biti pokrenuta u skoroj budućnosti uz potporu OECD-a.[416]

Pored definiranog etičkog okvira, FRAAI naglašava i važnost donošenja kvalitetnog zakonodavstva za kontrolu granica i performansi sustava AI i sprječavanje bilo kojeg oblika kršenja. U tom pogledu FRAAI predviđa:

- donošenje relevantnog pravnog okvira o digitalnoj republici, zaštiti prava korisnika i privatnosti podataka te osiguravanje mogućnosti za digitalizaciju od koristi svima i
- implementaciju Direktive 2016/1148 koja zahtijeva od država članica da usvoje nacionalnu strategiju za kibersigurnost.[417] U Francuskoj se ona provodi francuskim Zakonom br. 2018-133 iz veljače 2018. godine.

U smislu digitalne i telekomunikacijske infrastrukture za poticanje razvoja ML i algoritama AI FRAAI predviđa i ulaganje u superračunalo vrijedno 115 milijuna eura. Naposljetku, INRIA se obvezala na ulogu koordinatora provođenja FRAAI-a.

S obzirom na navedeno, jasna je strateška određenost Francuske. Naime, naglasak se stavlja na obrazovanje i osposobljavanje za sustave AI te donošenju etičkih okvira i transparentnost u korištenju aplikacija što ulazi u sfere odgovorne i objašnjive AI. Također, Francuska se zalaže za kreiranje politike otvorenih i razumljivih podataka odnosno obrade istih.

[416] *Ibid,* str. 119-124.
[417] French Act Br. 2018-133 iz veljače 2018., dostupno na: https://www.digitaleurope.org/resources/nis-implementation-tracker/

3 UMJETNA INTELIGENCIJA U DRUŠTVU

Sustavi AI imaju interdisciplinarnu, multidisciplinarnu i transdisciplinarnu primjenu. U ovo poglavlju analiziran je utjecaj AI u društvu.

3.1. POVIJEST RAZVOJA UMJETNE INTELIGENCIJE

Kao što je navedeno u uvodnom dijelu, AI kao pojam pojavljuje se 1943. godine prilikom znanstvenog i istraživačkog rada *Warrena McCullocha* i *Waltera Pittsa* koji predlažu model umjetnih neurona s funkcijom *„on“* ili *„off“*.[418] Usporedbe radi, u današnjem razdoblju računalne znanosti ta dva stanja klasificiraju se kroz binarni sustav, odnosno poprimaju vrijednost 1 kada je određeno stanje „*on*“ ili vrijednost ∅ kada je stanje *„off“*. Sama vrijednost tzv. umjetnih neurona iznosila bi u početnom stanju ∅ sve do trenutka kada bi došlo do dovoljne interakcije susjednih neurona čime se vrijednost iz ∅ mijenja u 1.[419] Usprkos doprinosu gore navedenih autora, zasluge u stvaranju AI kakvu znamo danas ima matematičar *Alan Turing*. Njegovo otkriće stroja iz 1936. postavlja prve prave temelje u stvaranju AI. Turingov stroj, znan kao umjetni stroj, u svojoj srži i ne ulazeći u inženjerske postavke, odgovarao je na dva zadana pitanja. S obzirom na to da se Turingov stroj sastojao od beskonačnog niza vrpci na koje su se zapisivali podaci, zapisivao je odgovor na pitanje postoji li stroj koji može utvrditi zapisuje li bilo koji stroj na vrpci ikada zadani simbol i postoji li stroj koji se „zamrzava“ ili ne može dovršiti neku računsku operaciju.[420] S obzirom na to da su ideja i već neka poduzeta djelovanja na području AI uzeli maha, u povijesti razvoja AI pojavili su se još neki znanstvenici i istraživači čiji je doprinos ostavio dubok trag u razvoju znanosti.

Razdoblje od 1950. do 1970. je označilo početak AI kao namjenskog istraživačkog područja. Prestižna svjetska sveučilišta poput *Massachusetts Institute of Technology* (MIT), *Carnegie Mellon University* (CMU), *Stanford* i *Edinburgh* dominirali su financiranjem istraživanja na polju AI tijekom tog razdoblja.[421] DARPA je također značajno doprinijela financijskim ulaganjima u mnoga istraživanja, iako su takva ulaganja oscilirala tijekom navedenog razdoblja ovisno o postignućima ili neuspjesima istraživača.[422] Značajan događaj

[418] Russell, S. J., Norvig, P. (2016). Artificial intelligence – A modern approach, 3rd Ed., Pearson Education, str. 16.
[419] *Loc. cit.*
[420] Warwick, K., *op.cit.*, str. 86.
[421] Russell, S. J., Norvig, P., *op.cit.*, str. 18.
[422] *Ibid*, str. 1014.

tog razdoblja za AI predstavlja *Dartmouth* konferencija iz 1956. koja je označila AI kao važno istraživačko područje i zapravo uvela pojam AI kao temelj onog što danas znamo i nastavljamo istraživati. *Marvin Minsky, John McCarthy, Claude Shannon* i *Nathan Rochester* organizirali su događaj i okupili istraživače tog vremena koji su imali radove i istraživanja relevantna za to područje. Kao naziv polja nastao je pojam "AI". Krajem 1950-ih i početkom 1960-ih po prvi puta se uvodi termin *„Means End Analysis“* (MEA) u kontekstu šireg pristupa u razmišljanju i obrazloženju određenog napora u razvoju AI. Zapravo u smislu već poznatog, paralela se u jednom dijelu može povući s GAP analizom, odnosno sadašnje stanje s krajnjim ciljem na umu. MEA više puta poduzima radnje kako bi se smanjio jaz između sadašnjeg stanja i ciljanog stanja. U tom smislu po prvi puta 1959. godine javlja se termin i novi način djelovanja pod nazivom *General Problem Solver* (GPS).[423] Neki od navedenih istraživača poput *Simona, Shawa* i *Newella*, idejni su začetnici ovog pristupa što se pokazao kao najpopularniji pristup s ovog područja razvoja za navedeno doba. Možda i najpoznatija izjava tog vremena od *Simona* i *Newella* je bila: *"... u roku od deset godina digitalno računalo bit će svjetski prvak u šahu“*.[424]

Idući korak u razvoju AI svakako je obrada prirodnog jezika (engl. *Natural Language Processing* - NLP) odnosno program zvan *STUDENT*, koji je bio sposoban riješiti matematičke probleme izražene riječima, odnosno *STUDENT* je mogao prepoznati čitav niz jezika, ali ograničenog opsega te u slučaju nemogućnosti rješavanja problema *STUDENT* bi tražio od korisnika dodatne informacije.[425] Nedugo nakon *STUDENT-a* pojavila se *ELIZA* koju je 1966. godine *Joseph Weizenbaum* kreirao kao NLP projekt s *MIT-a* koji je *"omogućio određene vrste razgovora na prirodnom jeziku između čovjeka i računala“*.[426] *ELIZA* je bila simulacija psihoterapije u kojoj bi čovjek dobio ponekad vrlo humane odgovore na određena pitanja. 1967. i 1972. godine pojavljuju se prvi osobni roboti imena *WABOT-1* i *WABOT-2* koji su predstavljali veliki napredak u robotici. *WABOT-1* je imao kontrolu nad udovima, vid i govor. Mogao je hvatati i transportirati predmete, ali naravno bio je vrlo ograničen na mnogo načina. Tadašnji tvorci su tvrdili da *WABOT* ima *"mentalnu sposobnost jedno i pol godišnjeg djeteta". WABOT-2* bio je sposoban svirati klavir, čitati notne zapise pa čak i biti prateći vokal.[427]

---

[423] Newell, A., Shaw, J. C., Simon, H. A. (1959). Report on a General Problem-Solving Program, International Conference on Information Processing, UNESCO House, Paris, France. str. 2.
[424] *Supra*, bilj. 10.
[425] Bobrow, D. G. (1964). Natural Language Input for a Computer Problem Solving System, AI Technical Reports (1964 - 2004), dostupno na: https://dspace.mit.edu/handle/1721.1/6903
[426] Weizenbaum, J. (1966). Computational Linguistics, Communications of the ACM, Vol. 9., No. 1., dostupno na: https://web.stanford.edu/class/linguist238/p36-weizenabaum.pdf
[427] Više o tome vidjeti na: https://www.humanoid.waseda.ac.jp/booklet/kato_2.html

Desetljeće između 70-ih i 80-ih označava zimu za AI. Financiranje je gotovo nestalo jer se činilo da velika očekivanja od AI propadaju i da nema stvarnih pomaka prema naprijed. Određeni istraživači izrazili su javne kritike za AI dok su neke od glavnih financijskih institucija povukle sredstva jer mnoga obećanja raznih istraživača AI nisu ispunjena. Ograničenja u razvoju AI od teorije do primjene uvelike su pridonijela stagnaciji u praksi. Ta su ograničenja uglavnom: smanjenje računalne mogućnosti, nedostatak podataka i mogućnosti pohrane, *Moravec-ov* paradoks[428] i nekoliko drugih važnih pitanja. Godina 1970. donosi *SHRDLU*[429] koji je predstavljao značajan iskorak u razvoju NLP-a uključujući korisnika koji komunicira sa strojem kako bi stvorio svojevrsni svijet. Korisnik bi dao upute računalu da premješta predmete širom svijeta i nauči stvari o svojoj okolini. Korisnik je mogao pitati što je moguće, a stroj je mogao reći korisniku više informacija koje je naučio i iskusio. Mogli bi se također dati imena ili opisi objektima ili interakcijama koje bi stroj zapamtio za kasniju upotrebu. Još jedan NLP napor odnosi se na *QUALM* koji je bio jedan od mnogih u to vrijeme, a koristio je model organizacije ljudskog pamćenja kako bi *QUALM* mogao sudjelovati u pitanjima i pružanju odgovora.[430] Obnovljeni optimizam označio je povratak financijskih sredstava u istraživačkom području AI. Japanci su uložili gotovo milijardu dolara u projekt namijenjen izradi strojeva sposobnih za razne zadatke zaključivanja. Velika Britanija potrošila je 350 milijuna dolara na projekt *Alvey*.[431] U SAD-u su formirani konzorciji korporacija, a DARPA je utrostručila svoja ulaganja.

U 80-im godinama NLP je postajao praksa modeliranja ljudskog pamćenja i zaključivanja. *Schankovo* "Dinamičko pamćenje"[432] bilo je jedno od vodećih djela koje je nadahnulo sustave poput *BORIS*-a[433] i *MOPTRANS*-a.[434] Ti su modeli bili dinamični, što znači

---

[428] *Moravecov* paradoks je zapažanje istraživača AI i robotike da suprotno tradicionalnim pretpostavkama rasuđivanje (koje je na visokoj razini kod ljudi) zahtijeva vrlo malo preračunavanja, ali osjetilne i motoričke vještine (razmjerno niskoj razini kod ljudi) zahtijevaju ogromne računske resurse.

[429] Prikaz *SHRLDU* dostupan na: http://hci.stanford.edu/~winograd/shrdlu/

[430] Više o računalnom programu *QUALM* vidi na: https://files.eric.ed.gov/fulltext/ED150955.pdf

[431] Program *Alvey* bio je dio istraživanja informacijske tehnologije sponzoriran od strane britanske vlade koji je trajao od 1983. do 1987. Program je bio reakcija na japanski projekt *Peta* generacije, čiji je cilj bio stvoriti računalo koje koristi masovno paralelno računanje/obradu. U operacijama je uspoređen s američkom Agencijom za napredne istraživačke projekte obrane (DARPA) i japanskim ICOT-om.

[432] Schank, R. C. (1983). Dynamic Memory: A Theory of Reminding and Learning in Computers and People, Cambridge University Press

[433] Dyer, G. M. (1983). In-Depth Understanding – A Computer Model of Integrated Processing for Narrative Comprehension, MIT Press, str. 1.

[434] Lytinen, S. L. (1985). Integrating syntax and semantics, Proceedings of the Conference on Theoretical and Methodological Issues in Machine Translation of Natural Languages, Colgate University, Hamilton, New York, str. 168.

da bi se njihova memorija pomicala i registrirala nove informacije onako kako su predstavljene. 1989. *Watkins* je predstavio *Q-Learning*[435] u tezi o pojačanom učenju bez modela. Q-učenje uključuje agenta koji uči kako bi maksimizirao ukupnu buduću nagradu. Na taj način bi očekivana vrijednost nagrade dosegnula krajnje očekivane vrijednosti iz trenutnog stanja. 1992. *Gerald Tesauro* je razvio program za igru "*backgammon*" koji je sposoban igrati s vrhunskim ljudskim igračkim sposobnostima u „*backgammonu*“.[436] Koristi se neuronskom mrežom s učenjem vremenskih razlika što je oblik pojačanog učenja bez modela. 1995. *Tin Kam Ho* opisao je „*Slučajne šume odlučivanja*“ u široko citiranom i provedenom radu. Svoju je metodu potvrdio računalnim prepoznavanjem rukom napisanih znamenki.[437] *Cortes i Vapnik* objavili su svoj rad temeljen na podupirućim vektorskim mašinama (engl. *Supporting Vector Machines* - SVM) 1995. godine. Njihov rad bio je temelj široko cijenjene i vrlo korištene moderne tehnike ML.[438] 1997. godinu obilježio je ponajviše znanstveni rad na temu duge kratkoročne memorije (*Long Short-Term Memory* - LSTM) autora *Seppa Hochreitera i Jürgena Schmidhubera*. Drugim riječima, LSTM je neophodan u obrađivanju elemenata poput videa i govora i popularno se koristi za skladbu glazbe.[439]

Prelaskom u 2000-te, AI sve više poprima oblik poznatiji i bliži današnjim vremenima. Brzi napredak u računalnoj snazi i pristupu podacima omogućili su masovna otkrića poput revolucije DL. 2004. „*Veliki izazov DARPA-e*“ osmišljen je za autonomno terensko vozilo da završi put pod zadanim vremenskim ograničenjem.[440]

U početnom natjecanju 2004. nije proglašen pobjednik dok je već naredne godine pet timova uspješno dovršilo izazov na čelu s ekipom sa Sveučilišta *Stanford*. 2006. pojavljuju se *"Mreže dubokih uvjerenja"* kao generativni grafički modeli koji su sposobni rekonstruirati unesene parametre i nakon ML-a bez nadzora.[441] Slojevi otkrivaju značajke, a kasniji trening uz nadgledano učenje može omogućiti klasifikaciju. Mreže dubokih uvjerenja dobro su poznate po svojoj sposobnosti generiranja slikovnih i video podataka. *Alex Graves* je 2009. godine

---

[435] Watkins, C., Dayan, P. (1992). Q – Learning, Machine Learning, Vol. 8, Kluwer Academic Publishers, Boston, str. 279-292.
[436] Teasuro, G. (1995). Temporal Difference Learning and TD-Gammon, Communications of the ACM, / Vol. 38, No. 3. 58-68.
[437] Ho, T. K. (1995). Random decision forests, Proceedings of 3rd International Conference on Document Analysis and Recognition, Montreal, Quebec, Canada, str. 278-282, dostupno na: https://ieeexplore.ieee.org/document/598994
[438] Cortes, C., Vapnik, V. (1995). Support-Vector Networks, Machine Learning, 20, str. 273-297.
[439] Hochreitera, S., Schmidhubera, J. (1997). Long short-term memory, Neural Computation 9(8). str. 1.
[440] Više o tome na: https://www.darpa.mil/about-us/timeline/-grand-challenge-for-autonomous-vehicles
[441] Hinton, G. E., Osindero, S., Teh, Y. W. (2006). A fast learning algorithm for deep belief nets, Neural Computation, dostupno na: https://www.cs.toronto.edu/~hinton/absps/fastnc.pdf

trenirao LSTM koristeći se konekcionističkom vremenskom klasifikacijom (CTC), stvarajući prvi RNN koji je osvajao natjecanja u prepoznavanju uzoraka. Njegov je razvoj vjerojatno ono što je prouzročilo *Google-ovu* uporabu LSTM-a obučenog za CTC, odnosno za prepoznavanje govora na pametnim telefonima.[442] 2009. pojavljuje se *ImageNet* kao masivna baza slika sa *Stanforda*. Ovakvi napori ključno pridonose kretanju prema demokratizaciji podataka. *ImageNet* sadrži preko 20 000 kategorija slika, a 2011. IBM-ov "*Watson*" pobijedio je dvojicu prvaka *Jeopardyja*. *Watson* je koristio moderni NLP kako bi stekao razumijevanje pitanja, a zatim pretražio njegovu bazu podataka (koja nije omogućena putem interneta) kako bi pronašao odgovor.[443] 2014. Generativne suparničke mreže (engl. *Generative Adversarial Networks* - GAN) autora *Iana Goodfellowa* predstavlja značajan razvoj u modernoj AI.[444] GAN-ovi su odgovorni za trenutne primjene u realističnom generiranju fotografija, videozapisa, dubokim fejkovima (engl. *Deep Fake*) i drugim dostignućima. Ideja je da se dvije neuronske mreže natječu međusobno u igri s pravilima koja je postavio programer čime se dobije izuzetno kvalitetan rezultat u generiranju lažiranih slika i/ili videozapisa.

S druge pak strane, *Tesla* 2014. godine predstavlja autonomiju svojih vozila s autopilotom čime postaje prvi pretendent u utrci do autonomije vozila pete razine. U 2015. godini *Google* izdaje *TensorFlow* koji je otvoren i postao je najčešće korištena knjižnica ML-a s otvorenim kodom.[445] *DeepMind* je razvijao i nastavlja razvijati sustave AI koji pobjeđuju igre. 2016. jedan od njih je i *Aplha Go* koji je prvo osvojio *Go*, a zatim se preselio u igre poput šaha, *Dota*-e, *Starcraft*-a i ostalih. *DeepMind*-ov sustav AI rutinski pobjeđuje profesionalno rangirane ljude u njihovoj igri po izboru.[446]

Google-ov projekt *BERT* iz 2018. je nedavno otvoren projekt *Google*-ovog inteligencijskog sustava koji prethodno trenira duboke dvosmjerne prikaze neoznačenog teksta zajedničkim uvjetovanjem u svim kontekstima i na svim slojevima.[447] Kao rezultat toga,

---

[442] Graves, A., Fernandez S., Gomez, F., Schmidhuber, J. (2006). Connectionist Temporal Classification: Labelling Unsegmented Sequence Data with Recurrent Neural Networks, Proceedings of the 23 rd International Conference on Machine Learning, Pittsburgh, vidjeti *Figure* 1.

[443] Više vidjeti na: https://www.ibm.com/ibm/history/ibm100/us/en/icons/watson/breakthroughs/

[444] Goodfellow, I. J., Pouget Abadie, J., Mehdi, M., Bing, X., Warde Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). Generative Adversarial Networks, Cornell University, dostupno na: https://arxiv.org/abs/1406.2661v1, str. 4-7.

[445] O *Tenserflow*-u vidjeti na: https://www.wired.com/2015/11/google-open-sources-its-artificial-intelligence-engine/

[446] Više vidjeti na NY Times: https://www.nytimes.com/2019/05/30/science/deep-mind-artificial-intelligence.html

[447] O BERT-u vidjeti na: https://searchengineland.com/welcome-bert-google-artificial-intelligence-for-understanding-search-queries-323976

unaprijed osposobljeni *BERT* model može se prilagoditi sa samo jednim dodatnim izlaznim slojem kako bi se stvorili najsuvremeniji modeli za širok raspon zadataka.[448] Nadalje, robot koji je pobijedio u *DARPA* izazovu, vozeći samostalno 131 milju kroz pustinju, *Google-ova* AI *AlphaGo* pobijedila je jednog od najboljih *Go* igrača svijeta, preko stvaranja pametnih telefona, internetskih pretraživača, raznih računalnih i mobilnih sustava, robota koji se kreću i razgovaraju, pa sve do onog što je predmet istraživanja ovog rada, a to su inteligentni sustavi u pomorskom prometu koji su osnova navigacijskih integriranih sustava, sustava dinamičkog pozicioniranja, elektroničke navigacije, satelitskih komunikacija, satelitskih pozicioniranja, satelitski podržanih mjerenja i sličnih sustava navođenja važnih za današnji pomorski promet. Pokazalo se kako se pregledom povijesti može steći i uvid u budućnost što u području AI predstavlja zanimljive inovacije i dostignuća. Jedan od takvih primjera je i humanoidni robot *Sophia* koja je postala aktivna 2016. Humanoidni robot je napravljen na sliku glumice *Audrey Hepburn* i temeljen je na sličnom konceptu kao i već spomenuta *ELIZA*, samo sa sofisticiranijim računalnim algoritmima i naprednijim hardverom. Ono što *Sophiu* čini drugačijim humanoidnim robotom jest činjenica da je robot dobio državljanstvo Saudijske Arabije čime su se postavila mnoga pitanja. Osporavao se prvenstveno tehnološki napredak robota, tvrdeći je to ništa više od *chatbotta* samo moderne verzije koja koristi tehnike AI poput praćenja lica, prepoznavanja emocija, dubokih neuronskih mreža i sl. Potom se raspravljalo i o dobivenom državljanstvu iz kojeg proizlaze određene obveze i prava pojedinca te o izbornom pravu robota kao i određenim pitanjima koja se povezuju s čovjekom poput pitanja o ubojstvu u slučaju namjernog gašenja robotskog sustava. U svakom slučaju, pokazalo se kako će budućnost AI imati široku primjenu u tehnici, pravu i filozofiji odnosno veliki društveni utjecaj.[449]

[448] Devlin, J., Chang, M. W., Lee, K., Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, Association for Computational Linguistics, dostupno na: https://arxiv.org/pdf/1810.04805.pdf , vidjeti *Figure* 2.

[449] Više o tome vidjeti na: https://theconversation.com/an-ai-professor-explains-three-concerns-about-granting-citizenship-to-robot-sophia-86479

3.2. POJAVNI OBLICI SASTAVNICA UMJETNE INTELIGENCIJE

Pojavni oblici sastavnica AI obuhvaćaju: ML, DL, neuronske mreže i umjetne neuronske mreže te sustave rudarenja podataka, BD i 5G. Oni se dalje u radu posebno analiziraju.

3.2.1. UPRAVLJANJE VELIKOM KOLIČINOM PODATAKA

Ljudi djeluju prikupljanjem činjenica, koje zovemo podacima, o okolini i donose njima svojstvene, utemeljene izbore sukladno tim činjenicama. Takvo postupanje može biti jednostavno pri odlučivanju koji kruh kupiti na temelju cijene ili koji vlak uloviti, ovisno o vremenu i mjestu kretanja. Međutim, opseg informacija koje su nam sada dostupne za mnoge odluke su mnogo više od onoga s čime se naš ljudski mozak može nositi. Točnije, riječ je o preopterećenju informacijama. Stoga mnoga poduzeća postoje samo kako bi nas savjetovala primjerice koje osiguranje uzeti i kako to učiniti. Oslanjamo se na njih da za nas donesu „teške“ odluke. Čak i kad kupujemo jednostavan proizvod suočeni smo s mnoštvom različitih vrsta podataka kao što su informacije o različitim dobavljačima, cijenama i proizvodima i sl. Bilo da ga provodi čovjek ili stroj, izvlačenje vitalnih dijelova znanja iz složenosti dostupnih podataka o određenoj temi naziva se rudarenje podacima (engl. *Data Mining* - DM).[450] Sustavi AI su u tome vrlo prikladni zbog svoje sposobnosti pohranjivanja ogromnih količina podataka i izvlačenja svih vrsta odnosa unutar tih podataka kako bi se ostvarili značajni obrasci, veze i poveznice. Smatra se da se količina podataka u svijetu približno udvostručuje svake godine što znači da tijekom desetogodišnjeg razdoblja (npr. od 2002. do 2012.) dolazi do povećanja podataka za 1000 puta. Posljednjih godina projekt ljudskog genoma otvorio je složenost DNK, a sada smo u stanju istražiti funkcioniranje mozga i pokušati shvatiti što se događa na temelju novih oblika podataka koji su dobiveni. Kao rezultat postoje nove poslovne prilike koje treba iskoristiti, nove medicinske tehnike za razvoj i, najvažnije od svega, dostupno je dublje razumijevanje znanstvenog svijeta oko nas, ali moramo razumjeti prikupljene podatke.[451]

U međunarodnom pomorskom prometu DM se može koristiti za vjerojatnu karakterizaciju pomorskog prometa i otkrivanje anomalija. U tom smislu sustavi AI mogu automatski grupirati povijesne podatke u određenim pomorskim rutama kroz AIS u pogledu

[450] Više o tome vidjeti na: https://www.sas.com/en_us/insights/analytics/data-mining.html
[451] Shirado, H., Christakis, N.A., *op.cit.*, str. 54-55.

tipova brodova, veličina, konačnih odredišta i drugih karakteristika koje utječu na pomorski promet. Na taj način, a primjenom AI, mogla bi se omogućiti identifikacija raznih profila brodova, odnosno karakterizacija tipičnog ponašanja skupine sličnih brodova na određenoj ruti.[452]

Podaci u rječničkim terminima definiraju se kao činjenice i statistike prikupljene zajedno za referencu ili analizu. Mehanizmi za pohranu uvelike su evoluirali s ljudskom evolucijom od skulptura, rukom napisanih tekstova na lišću, bušilice, magnetske trake, tvrdi diskovi, diskete, CD-ovi, DVD-ovi, SSD-ovi i još mnogo toga. Sa svakim novim medijem u mogućnosti smo pohraniti više podataka u manje prostora. Pojavom Interneta i IoT količina podataka eksponencijalno raste. Pojam BD predstavlja sve veće količine podataka. Uz volumen, pojam uključuje još tri atributa, a to su: brzina, raznolikost i vrijednost.[453] Volumen predstavlja sve veću i eksponencijalno rastuću količinu podataka.

Povijesno gledano, većina elektroničkih skupova podataka bila je strukturirana i uklopila se u tablice baze podataka. Međutim, više od 80 % elektroničkih podataka koje sada generiramo nije u strukturiranom formatu, na primjer slike, video datoteke i datoteke glasovnih podataka. Uz BD u mogućnosti smo analizirati veliku većinu strukturiranih/nestrukturiranih i polustrukturiranih skupova podataka.[454] Vrijednost je najvažniji aspekt BD, odnosno podaci su jednako toliko vrijedni koliko je njihova upotreba u stvaranju djelotvornog uvida. Međutim, sustavi se moraju brzo razvijati kako bi mogli analizirati podatke, razumjeti obrasce unutar podataka i na temelju kontekstualnih detalja pružiti rješenja koja u konačnici stvaraju vrijednost.[455] U ovom trenutku tehnološke evolucije gdje imamo dostupnost sustava koji prikupljaju velike količine podataka iz heterogenih izvora, zajedno sa sustavima koji pohranjuju te velike količine podataka uz stalno smanjenje troškova, možemo izvući vrijednost u obliku uvida u podatke i graditi inteligentne strojeve koji mogu pokretati radnje koje rezultiraju poboljšanjem ljudskog života. Moramo koristiti algoritamski pristup s masivnim podacima i proračunskim sredstvima kojima raspolažemo. Koristeći kombinaciju ljudske inteligencije, BD i raspodijeljene računalne snage, možemo stvoriti stručne sustave koji se mogu koristiti kao

[452] Rong, H., Teixeira, A. P., Guedes Soares, C. (2020). Data mining approach to shipping route characterization and anomaly detection based on AIS data, Ocean Engineering, Volume 198, str. 1.
[453] Gandomi, A., Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics, International Journal of Information Management, str. 138-139.
[454] Više o tome na: https://www.sas.com/en_us/insights/analytics/big-data-analytics.html
[455] Deshpande, A., Kumar, M. (2018). Artificial Intelligence for Big Dana, Complete guide to automating Big Data solutions using Artificial Intelligence techniques, str. 13-15.

prednost za vođenje ljudske rase u bolju budućnost. Iako smo u povojima razvoja AI, nekoliko osnovnih područja u kojima se događaju značajna istraživanja i otkrića, a na koji značajan utjecaj imaju BD su:[456]

- NLP: olakšava interakciju između računala i ljudskih jezika.
- Neizraziti sustav zaključivanja: oni se temelje na stupnjevima istine, umjesto na programiranju za sve situacije s AKO/ONDA pravilima. Ovi sustavi mogu kontrolirati strojeve i potrošačke proizvode na temelju prihvatljivog obrazloženja.
- Inteligentna robotika: to su mehanički uređaji koji mogu izvoditi svakodnevne ili opasne ponavljajuće zadatke.
- Ekspertni sustavi: to su sustavi ili aplikacije koji rješavaju složene probleme u određenoj domeni. Sposobni su savjetovati, dijagnosticirati i predvidjeti rezultate na temelju baze znanja i modela.

U međunarodnom pomorskom prometu BD se koristi za upravljanje brodskim senzorima i za prediktivnu analizu koja je potrebna da bi se spriječila kašnjenja i poboljšala ukupna operativna učinkovitost u industriji. U brodarskoj industriji pravilno je praćenje tereta neophodno kako bi se osigurala potrebna sigurnost i povjerljivost. Kroz podatke dobivene pravilnim praćenjem pošiljaka tijekom nekoliko godina, informacije o uzrocima gubitaka brodova na moru, gubicima kontejnera unutar ili izvan terminala ili skladišta i druge probleme povezane s otpremanjem (na primjer, razlozi za oštećenje robe) mogu se skupljati i vrednovati. U tom smislu BD za brodarsku industriju mogu se koristiti za donošenje odluka u budućnosti u pogledu predviđanja i izbjegavanja poteškoća te za stvaranje pouzdanijih mogućnosti isporuke tereta.[457] Isto tako, BD mogu imati ulogu u dizajnu brodova. U osnovi, to će biti moguće analizirajući rezultate dobivene senzorima prethodno korištenih brodova. Podaci prikupljeni i analizirani tijekom životnog vijeka plovila mogu biti korišteni za buduća poboljšanja u dizajnu broda. Prethodni skupovi podataka mogli bi pomoći u testiranju predloženog dizajna broda bez fizičkog razvoja. To predstavlja značajnu prednost za brodogradnju. Također, u današnjem globaliziranom ekonomskom sustavu potražnja za prijevozom robe i s njom povezana logistička podrška nastavit će rasti.[458] Vremenom će ovaj rast povećati potrebu za maksimiziranjem vremena i zarade kako bi se imali najprofitabilniji procesi isporuke.

[456] *Ibid*, str. 20.
[457] Ayed, A. B., Halima, M. B., Alimi, A. M. (2015). Big Data Analytics for Logistics and Transportation, 4th IEEE International Conference on Advanced logistics and Transport, str. 313.
[458] Nemschoff, M. (2014). Why the transportation Industry is getting on bord with Big Data & Hadoop

Korištenjem naprednih tehnika obrade podataka dostava robe postat će učinkovitija. Poboljšane usluge prijevoza povećat će ukupnu međunarodnu trgovinu koja je velikim dijelom dostavljana pomorskim prometom. Ključne uporabe BD u međunarodnom pomorskom prometu mogu se, između ostalog, odnositi na ključnoj analitici za brodovlasnike, podatkovni inženjering, performanse plovila i upravljanje situacijskim resursima i pozicijama flote.

3.2.2. METODOLOŠKI PRISTUP UMJETNOJ INTELIGENCIJI

Najjednostavniji način definiranja ML-a jeste učitavanje veće količine podataka u računalni program i odabir modela koji će "uklopiti" podatke što omogućuje računalu da bez ljudske pomoći iznese predviđanja.[459] Računalo izrađuje model putem algoritama koji se mogu kretati od jednostavne jednadžbe (poput jednadžbe linije) do vrlo složenog logičkog/matematičkog sustava koji računalo dovodi do najboljih predviđanja. ML nosi prikladan naziv s obzirom da nakon što se odabere model koji će se koristiti i prilagodi ga se ili se poboljša prilagodbama, stroj će koristiti model za učenje uzoraka u zadanim podacima.[460] Zatim se mogu unijeti novi uvjeti (opažanja) i sustav će predvidjeti ishod. Kada je riječ o ML, razlikujemo ključne elementa poput:[461]

- nadzirani ML i
- nenadzirani ML.

Nadzirano učenje vrsta je ML-a kod kojeg su podaci koji se unose u model „označeni“. „Označeno“ jednostavno znači da je ishod promatranja poznat. Na primjer, ako model pokušava algoritmom[462] predvidjeti hoće li vaši prijatelji ići na golf ili ne, možda imate varijable poput temperature, dana u tjednu i sl. Ako su vaši podaci „označeni“, imati ćete i varijablu koja ima vrijednost 1 ako su vaši prijatelji stvarno igrali golf ili 0 ako nisu. Nenadzirano učenje suprotno je od nadziranog učenja kada su u pitanju „označeni“ podaci. Uz učenje bez nadzora ne znate jesu li vaši prijatelji igrali golf ili ne, a na računalu je pronaći uzorke putem modela koji će pogoditi što se dogodilo ili predvidjeti što će se dogoditi.

Jedna od najvećih zabluda koju mnogi ljudi drže o računalima je da oni nisu u stanju učiti i prilagoditi se novim mogućnostima. Svakako je istina da to može biti slučaj za neka

---

[459] Definiciju *Eda Burnsa* vidjeti na: https://searchenterpriseai.techtarget.com/definition/machine-learning-ML
[460] Više o tome na: https://searchenterpriseai.techtarget.com/definition/machine-learning-ML
[461] Goodfellow, I. J., Bengio, Y., Courville, A. (2016). Deep learning, MIT Press, str. 98-164.
[462] Bonaccorso, G. (2017). Machine learning algorithms, Packt Publishing Ltd. Dostupno na: https://www.packtpub.com/product/machine-learning-algorithms/9781785889622

računala jer su samo programirana i od njih se očekuje da rade samo onako kako su programirana. Međutim, mnoga računala mogu učiti iz iskustva i već viđenih uzoraka te značajno mijenjati svoj način rada i mijenjati svoje djelovanje na različite načine. Zapravo, važan aspekt područja AI je sposobnost računala za učenje. Stručni (umjetni) sustav zasnovan na pravilima po definiciji je izvorno postavljen izvlačenjem niza pravila od ljudskih stručnjaka, zajedno s drugim informacijama. Ono što se stvara je grupa pravila od kojih neka vode do drugih pravila kada se aktiviraju. Dakle, nakon unosa određenih podataka serija pravila može uključivati šest, sedam ili više pravila koja se aktiviraju u nizu, a svako od njih pokreće sljedeće dok se ne postigne konačni zaključak konačnog pravila. Iz toga slijedi da su za donošenje zaključnog pravila potrebna sva prethodna pravila u nizu. Može se dogoditi da je izvučeni zaključak dobar što se tiče bilo kakve radnje poduzete u vanjskom svijetu, npr. možda se dionice prodaju i ostvari profit ili se na vrijeme oglasi alarm. Svako od pravila koja su sudjelovala u uspješnom zaključku tada se može vrednovati tako da kada se dogodi sličan skup ulaznih podataka postoji veća vjerojatnost da će se upravo ta pravila aktivirati.

Primijenjena metoda, primijenjeni ponderi i količina fleksibilnosti koja je uključena u pravila ovise o domeni problema. Na primjer, može se dogoditi da se neka pravila nužno ne smiju mijenjati iz razloga sigurnosti ili pouzdanosti, a ona tada ne mogu sudjelovati u procesu učenja. Također je moguće da računalo samo generira nova pravila. Novo pravilo može se izvesti jednostavnim dopuštanjem malih mutacija vjerojatnosti stanja ili postupka rješavanja sukoba. Ako novo pravilo tada sudjeluje u uspješnom završnom zaključku, dobit će nagradu i ojačati. Ako pak sudjeluje u bilo kakvim neuspješnim zaključcima, kažnjavat će se svaki put dok ne uvene. Koliki je dio ovog učenja dopušten u potpunosti ovisi o problemu i koliko su pokušaji i pogreške dopušteni u stvarnom svijetu.[463]

Zbog činjenice da su podaci glavni element za uklanjanje nesigurnosti, prilagođavanje algoritama ML može pomoći u povećanju netipičnih podataka koji mogu biti presudni za vlasnike brodova.[464] ML omogućuje korisnicima primjenu inteligentnih algoritama i procjenu podataka koji pomažu u vođenju logike mogućih problema u pomorskom prometu. Te se

[463] Warwick, K., *op.cit.*, str. 53-54.

[464] Članci i vijesti o poduzećima koji svakodnevno koriste AI, odnosno ML tehnologiju su uobičajena pojava. Nedavno je *Stena Lines* (jedan od najvećih trajektnih operatera na svijetu) koristio AI/ML za smanjenje količine plastike na brodu, smanjenje nesreća posade i putnika, za uštedu goriva i sl. Luka *Rotterdam* koristi sustav zasnovan na ML-u za određivanje vremena dolaska plovila.

metode mogu koristiti u planiranju morskih mreža, planiranju putovanja, optimizaciji tereta, procesu održavanja itd.[465]

Pojam DL opisuje određene vrste neuronskih mreža i srodne algoritme koji ponajviše uče iz neobrađenih ulaznih podataka.[466] Oni obrađuju te podatke kroz mnoge slojeve nelinearnih transformacija ulaznih podataka kako bi izračunali ciljni izlaz. Nenadzirano izdvajanje značajki također je područje u kojem DL briljira. Izdvajanje značajki postoji kada algoritam može automatski izvesti ili konstruirati značajne vrijednosti podataka koji će se koristiti za daljnje učenje, generaliziranje i razumijevanje. Teret je na obradi podataka ili programerima da izvrši postupak ekstrakcije značajki u većini drugih pristupa ML zajedno s odabirom značajki i inženjeringom. To ima brojne prednosti koje uključuju pojednostavljivanje, računanje i smanjenje memorijskog opterećenja i sl. Općenito, DL spada u skupinu tehnika poznatih kao učenje karakteristika ili učenje reprezentacija. Kao što je rečeno, izdvajanje značajki koristi se za učenje na koje se značajke treba usredotočiti i koristiti u rješenjima za ML. Algoritmi ML sami nauče optimalne parametre kako bi stvorili model s najboljim učinkom. Možemo reći da algoritmi za učenje značajki omogućuju stroju i da nauči određeni zadatak koristeći prikladan skup značajki, a također nauči i same značajke. Drugim riječima, ti algoritmi uče kako učiti. DL se uspješno koristi u mnogim aplikacijama i smatra se jednom od najmodernijih tehnika ML i AI.[467] Povezani algoritmi često se koriste za probleme pod nadzorom, bez nadzora i polu-nadgledanja. Za modele DL temeljenih na neuronskim mrežama[468] broj slojeva je veći nego u tzv. plitkim algoritmima učenja. Plitki algoritmi obično su manje složeni i zahtijevaju više predznanja o optimalnim značajkama za upotrebu što obično uključuje odabir i inženjering značajki. Suprotno tome, algoritmi DL više se oslanjaju na optimalan odabir modela i optimizaciju kroz podešavanje modela.[469] Oni su prikladniji za rješavanje problema tamo gdje je prethodno znanje o značajkama manje poželjno ili potrebno i ako označeni podaci nisu dostupni ili nisu potrebni za primarni slučaj upotrebe. Pored statističkih tehnika, neuronske mreže i koncepti i tehnike DL koriste i obradu signala, uključujući nelinearnu obradu i/ili

[465] Više o tome na: https://www.offshore-energy.biz/port-of-rotterdam-self-learning-computers-predicting-vessel-arrival-times/
[466] Goodfellow, I. J. *et.al*., *op.cit.*
[467] Više o AI, ML i DL vidjeti na: https://towardsdatascience.com/understanding-the-difference-between-ai-ml-and-dl-cceb63252a6c
[468] Kriegeskorte, N., Golan, T. (2019). Neural network models and deep learning, Current Biology, 29(7), R231-R236.
[469] Kahng, M., Andrews, P. Y., Kalro, A., Chau, D. H. (2017). Activis: Visual exploration of industry-scale deep neural network models, IEEE transactions on visualization and computer graphics, 24(1), str. 88-97.

transformacije. Nelinearne funkcije mogu uključivati polinomne, logaritamske i eksponencijalne pojmove, kao i bilo koju drugu transformaciju koja nije linearna. Mnoge pojave uočene u fizičkom svijetu zapravo se najbolje modeliraju nelinearnim transformacijama. To vrijedi i za transformacije između ulaza i ciljanog rezultata u ML i AI rješenjima. Kao što je spomenuto, ulazni podaci transformiraju se kroz slojeve neuronske mreže DL pomoću umjetnih neurona ili procesnih jedinica. Lanac transformacija koji se događaju od ulaza do izlaza poznat je kao put dodjele kredita ili CAP. Vrijednost *CAP Proxy je* za mjerenje ili koncept „dubine" u arhitekturi modela DL. Neki od značajnijih modela DL i algoritama učenja uključuju:[470]

- neuronske mreže s povratnim naponom,
- ponavljajuću neuronsku mrežu,
- višeslojni perceptroni (MLP),
- konvolucijske neuronske mreže,
- rekurzivne neuronske mreže,
- mreže dubokih vjerovanja,
- konvolucijske mreže dubokih uvjerenja,
- samoorganizirajuće karte,
- duboke *Boltzmannove* strojeve i

Vrijedno je istaknuti da zbog relativnog povećanja složenosti algoritmi DL i neuronske mreže mogu biti skloni prekomjernoj opremi. Uz to, povećana složenost modela i algoritma može rezultirati vrlo značajnim računalnim resursima i vremenskim zahtjevima. Također je važno uzeti u obzir da rješenja mogu predstavljati lokalne minimume za razliku od globalnog optimalnog rješenja. To je zbog složene prirode ovih modela u kombinaciji s optimizacijskim tehnikama poput gradijentnog spuštanja. S obzirom na sve navedeno, mora se voditi računa pri iskorištavanju algoritama AI za rješavanje problema uključujući odabir, implementaciju i procjenu izvedbe samih algoritama.[471]

U povezivosti s razvojem AI u međunarodnom pomorskom prometu, a temeljeno AI i ML, napredni algoritmi DL moći će, između ostalog, poboljšati optimizaciju putovanja poput uštede goriva, poboljšanja produktivnosti posade, poboljšanja procjena troškova putovanja,

[470] Huang, K., Hussain, A., Wang, Q. F., Zhang, R. (2019). Deep Learning: Fundamentals, Theory and Applications (Vol. 2), Springer, str. 15-19.
[471] Castrounis, A. AI, Deep Learning, and Neural Networks Explained, Innoarchitech, dostupno na: https://www.innoarchitech.com/blog/artificial-intelligence-deep-learning-neural-networks-explained

izračunavanja optimalne rute u minuti, davanja preporuka o brzini, smjeru i sl. Također, algoritmi ML i DL mogu se koristiti za procjenu potrošnje goriva pomoću podataka motora i karakteristika plovila. Ti algoritmi omogućuju pretvaranje ogromnih skupova senzorskih podataka i ostalih podataka iz kopnenih izvora u strukturirane informacije koje se mogu koristiti za predviđanje potrošnje goriva i planiranje optimalnih ruta za plovila kao i za cijeli niz ostalih algoritamskih predviđanja koje mogu biti od koristi za dionike u međunarodnom pomorskom prometu.

Iako su sastavnica ML-a i DL-a vrijedno je posebno istaknuti umjetne neuronske mreže (engl. *Artificial Neuron Network* - ANN). Kako bi se bolje pojasnile ANN potrebno je koliko je to moguće objasniti i rad ljudskog mozga. Ljudski mozak izuzetno je složen i smatra se najsnažnijim poznatim računalnim strojem. Unutarnji rad ljudskog mozga često se modelira oko koncepta neurona i mreža neurona poznatih kao biološke neuronske mreže. Procjenjuje se da ljudski mozak sadrži otprilike 100 milijardi neurona koji su povezani duž putova kroz ove mreže.[472] Na vrlo visokoj razini neuroni međusobno komuniciraju putem sučelja koje se sastoji od aksonskih terminala koji su povezani s dendijima preko sinapsi. Jednostavno rečeno, jedan neuron će prenijeti poruku drugom neuronu preko ovog sučelja ako je zbroj ponderiranih ulaznih signala iz jednog ili više neurona (zbrajanje) u njega dovoljno velik (premašuje prag) da uzrokuje prijenos poruke što se naziva aktivacijom kada se premaši prag i poruka se proslijedi sljedećem neuronu.[473] Proces zbrajanja može biti matematički složen. Ulazni signal svakog neurona zapravo je ponderirana kombinacija potencijalno mnogo ulaznih signala, a ponderiranje svakog ulaza znači da taj ulaz može imati različit utjecaj na bilo koji sljedeći izračun, a u konačnici i na izlaz cijele mreže. Uz to, svaki neuron primjenjuje funkciju ili transformaciju na ponderirane ulaze, što znači da se kombinirani ponderirani ulazni signal transformira matematički prije procjene je li prag aktivacije premašen. Ova kombinacija ponderiranih ulaznih signala i primijenjenih funkcija obično su linearne ili nelinearne. Ti ulazni signali mogu potjecati na mnogo načina, a naša su osjetila neka od najvažnijih poput disanja, konzumiranja tekućine i krutina. Pojedinačni neuron može primiti stotine tisuća ulaznih signala

[472] Cherry, K. (2020). How Many Neurons Are in the Brain?, Very well mind, dostupno na: https://www.verywellmind.com/how-many-neurons-are-in-the-brain-2794889
[473] Cherry, K. (2020). Neurons and Their Role in the Nervous System, Very well mind, dostupno na: https://www.verywellmind.com/what-is-a-neuron-2794890

odjednom koji prolaze kroz proces zbrajanja kako bi se utvrdilo prolazi li poruka dalje i što u konačnici uzrokuje mozak da upućuje na radnje, prisjećanje na memoriju i sl.[474]

Proces razmišljanja ili obrada koju naš mozak provodi i naknadne upute dane našim mišićima, organima i tijelu rezultat su ovih neuronskih mreža. Uz to, neuronske mreže mozga kontinuirano se mijenjaju i ažuriraju na mnogo načina, uključujući modifikacije količine ponderiranja primijenjenog između neurona. To se događa kao izravni rezultat učenja i iskustva. S obzirom na to prirodna je pretpostavka da računalni stroj za preslikavanje funkcionalnosti i mogućnosti mozga, uključujući i inteligenciju, mora uspješno implementirati računalnu ili umjetnu verziju ove mreže neurona. Ovo je geneza napredne statističke tehnike i izraza poznata kao ANN. Navedene mreže statistički su modeli izravno nadahnuti i djelomično modelirani na biološkim neuronskim mrežama.[475] Sposobni su paralelno modelirati i obrađivati nelinearne odnose između ulaza i izlaza. Povezani algoritmi dio su šireg područja ML-a i mogu se koristiti u mnogim aplikacijama kako je već spomenuto. ANN karakteriziraju sadržavanje prilagodljivih elemenata duž staza između neurona koji se mogu prilagoditi algoritmom učenja koji uči iz promatranih podataka kako bi se poboljšao model.[476]

Pored samog algoritma učenja, mora se odabrati i odgovarajuću troškovnu funkciju. Funkcija troškova je ono što se koristi za učenje optimalnog rješenja problema s kojim se sustav suočava. To uključuje određivanje najboljih vrijednosti za sve parametre prilagodljivog modela s prilagodljivim utezima neuronske staze koji su primarni cilj, ali i zajedno s parametrima podešavanja algoritma kao što je stopa učenja.[477] Obično se to radi tehnikama optimizacije, poput gradijentnog spuštanja ili stohastičkog gradijentnog spuštanja. Ove se tehnike optimizacije u osnovi trude da ANN rješenje bude što bliže optimalnom rješenju što, kada je uspješno, znači da ANN može riješiti željeni problem visokim performansama. Arhitektonski se ANN modelira pomoću slojeva umjetnih neurona ili računskih jedinica koje mogu primiti ulaz i primijeniti funkciju aktiviranja zajedno s pragom kako bi se utvrdilo prenose li se poruke. U jednostavnom modelu prvi sloj je ulazni sloj, slijedi jedan skriveni sloj i na kraju izlazni sloj. Svaki sloj može sadržavati jedan ili više neurona.[478] Modeli mogu postati sve složeniji, a s

[474] Više o radu neurona vidjeti na: https://www.medicalnewstoday.com/articles/320289#carry_message
[475] Anthony, M., Bartlett, P. L. (2009). Neural network learning: Theoretical foundations, Cambridge University Press, str. 2.
[476] Hassoun, M. H. (1995). Fundamentals of artificial neural networks, MIT Press, dostupno na: https://neuron.eng.wayne.edu/tarek/MITbook/t_contents.html
[477] *Ibid*. Poglavlje 3.1.5.
[478] *Ibid.*

povećanom apstrakcijom i mogućnostima rješavanja problema povećavaju se i brojevi skrivenih slojeva, brojevi neurona u bilo kojem danom sloju i broj putova između neurona što je vidljivo na slici 3-1.

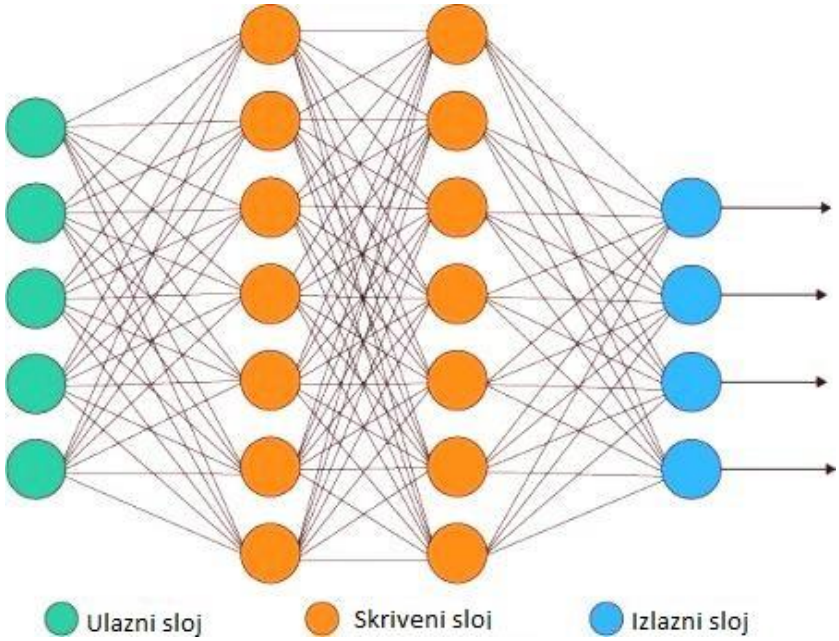

Slika 3-1 Slojevitost modela ANN,

Dostupno na: https://hr.flipperworld.org/pc/neuronske-mreze-primjer-definicija-vrijednost-opseg

Arhitektura modela i ugađanje stoga su glavne komponente ANN tehnika uz same algoritme učenja.[479] Sve ove karakteristike ANN mogu imati značajan utjecaj na djelovanje odnosno performanse modela. Uz to, modeli su karakterizirani i prilagodljivi funkcijom aktivacije koja se koristi za pretvaranje neuronskog ponderiranog ulaza u njegovu izlaznu aktivaciju. Rezultat transformacija ulaznih podataka kroz neurone i slojeve oblik je distribuirane reprezentacije, nasuprot lokalnoj reprezentaciji. Značenje, na primjer, predstavljeno jednim umjetnim neuronom oblik je lokalnog predstavljanja. Značenje čitave mreže, međutim, oblik je distribuirane reprezentacije zbog mnogih transformacija kroz neurone i slojeve. Jedna stvar koju treba napomenuti jest da iako su ANN-ovi izuzetno moćni, oni također mogu biti vrlo složeni i smatraju se algoritmima crne kutije, što znači da je njihovo

[479] Ghiassi, M., Saidane, H. (2005). A dynamic architecture for artificial neural networks, Neurocomputing, 63, str. 397-413.

unutarnje djelovanje vrlo teško razumjeti i objasniti. Stoga pri odabiru hoće li se ANN-ovi koristiti za rješavanje problema treba odabrati vodeći se navedenim elementima.[480]

U sveobuhvatnom metodološkom pristupu AI važno je spomenuti i inteligentne agente (engl. *Intelligent Agent* - IA) koji se odnose na autonomni entitet s ciljem djelovanja na okolinu pomoću promatranja putem senzora i posljedičnih pokretača.[481] IA također mogu naučiti ili koristiti znanje za postizanje svojih ciljeva. Mogu biti vrlo jednostavni ili složeni. Tako se primjerice refleksni stroj poput termostata, smatra primjerom inteligentnog sredstva.[482] IA se često shematski opisuju kao apstraktni funkcionalni sustavi slični računalnom programu. Istraživači kao što su *Russell* i *Norvig* smatraju da je ciljno ponašanje suština inteligencije, tj. normativni agent može se označiti terminom posuđenim iz ekonomije – „racionalni agent". U ovoj paradigmi racionalnog djelovanja IA posjeduje unutarnji model svog okruženja koji obuhvaća sva agentova vjerovanja o svijetu. Agent također ima "ciljnu funkciju" koja obuhvaća sve ciljeve procjene učinka. Takav je agent dizajniran za stvaranje i izvršavanje bilo kojeg plana koji će po završetku maksimizirati očekivanu vrijednost ciljne funkcije.[483] Model djelovanja jednostavnog agenta prikazan je na slici 3-2.

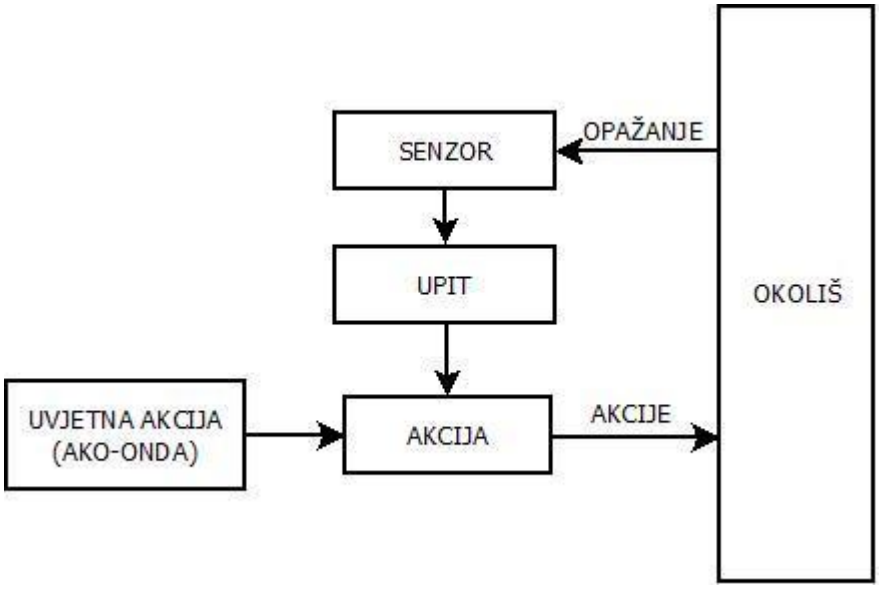

Slika 3-2 Model djelovanja jednostavnog agenta,

Izvor: Izradio autor

[480] Hassoun, M. H., *op.cit.*
[481] Anderson, M., Anderson, S. L. (2007). Machine Ethics: Creating an Ethical Intelligent Agent, AI Magazine 28 (4)
[482] Prema definiciji koju su dali Russell, S. J., Norvig, P. (2003). Artificial Intelligence, A Modern Approach. Second Edition, University of Michigan Press
[483] Bringsjord, S., Govindarajulu, N. A. (2020). Artificial Intelligence, The Stanford Encyclopedia of Philosophy Archive, dostupno na: https://plato.stanford.edu/archives/sum2020/entries/artificial-intelligence/

Sredstvo za učenje pojačanja[484] može imati "funkciju nagrađivanja" koja programerima omogućuje oblikovanje željenog ponašanja IA,[485] a ponašanje evolucijskog algoritma oblikuje "funkcija kondicije".[486] Apstraktni opisi inteligentnih agenata ponekad se nazivaju apstraktni IA (engl. *Apstract Intelligent Agents* - AIA) kako bi se razlikovali od njihovih stvarnih implementacija kao računalnih i bioloških sustava ili organizacija.

Neki su autonomni IA dizajnirani da funkcioniraju u odsutnosti ljudske intervencije. Kako IA postaju sve popularniji, sve su veći i pravni rizici.[487] IA u AI usko su povezani s agentima u ekonomiji, a verzije paradigme IA proučavaju se u kognitivnoj znanosti, etici, filozofiji praktičnog razuma, kao i u mnogim interdisciplinarnim socio-kognitivnim modelima i računalnim socijalnim simulacijama. IA također su usko povezani sa softverskim agentima (autonomni računalni program koji izvršava zadatke u ime korisnika). U računalnoj znanosti IA je softverski agent koji ima određenu inteligenciju, na primjer, autonomni programi koji se koriste za pomoć operatora ili rudarenje podataka (ponekad se nazivaju i botovi) nazivaju se i IA. Definicija i karakteristike IA prema *Nikoli Kasabovu*[488] trebali bi pokazivati sljedeće značajke:

- postupno prilagođavanje novih pravila rješavanju problema,
- prilagodbe na mreži i u stvarnom vremenu,
- sposobnost samoanalize u smislu ponašanja, pogrešaka i uspjeha,
- učenje i poboljšavanje interakcije s okolinom (utjelovljenje),
- brzo učenje iz BD,
- imati uzorne kapacitete za pohranu i pronalaženje temeljene na memoriji i
- imati parametre koji predstavljaju kratkoročnu i dugoročnu memoriju, dob, zaborav, i sl.

---

[484] Podržano učenje (RL) područje je ML-a zabrinutog kako inteligentni agenti trebaju poduzimati radnje u okruženju kako bi maksimizirali pojam kumulativne nagrade. RL jedno je od tri osnovne paradigme ML-a, uz nadzirano i nenadgledano učenje. RL se razlikuje od učenja pod nadzorom po tome što ne trebaju biti prezentirani označeni parovi ulaza/izlaza i u tome što ne trebaju izričito ispravljati neoptimalne akcije. Umjesto toga, fokus je na pronalaženju ravnoteže između istraživanja (neiscrtanog teritorija) i eksploatacije (trenutnih saznanja). Kaelbling, L.P., Littman, M.L., Moore, A.W. (1996). Reinforcement Learning; A Survey, Journal of Artificial Intelligence Research 4, str. 237–285, dostupno na: doi:10.1613/jair.301.

[485] Wolchover, N. (2020). Artificial Intelligence Will Do What We Ask. That's a Problem, Quanta Magazine

[486] Bull, L. (1999). On model-based evolutionary computation, Soft Computing 3, str. 76-82.

[487] Van Loo, R. (2019). Digital Market Perfection, Michigan Law Review 117 (5), str. 815.

[488] Kasabov, N. (1998). Introduction: Hybrid intelligent adaptive systems, International Journal of Intelligent Systems. 13 (6), str. 453–454, dostupno na: https://doi.org/10.1002%2F%28SICI%291098-111X%28199806%2913%3A6%3C453%3A%3AAID-INT1%3E3.0.CO%3B2-K

Padgham i *Winikoff* se slažu da se IA nalazi u okruženju i reagira (na vrijeme, iako ne nužno u stvarnom vremenu) na promjene u okruženju. Međutim, IA također moraju proaktivno slijediti ciljeve na fleksibilan i robustan način.[489] Neke definicije iz 20. stoljeća karakteriziraju IA kao program koji pomaže korisniku ili koji djeluje u njegovo ime.[490] Utjecajni AIMA definira agenta kao „*sve na što se može gledati kao na percepciju svoje okoline putem senzora i djelovanje na tu okolinu putem aktuatora*“, a inteligenciju karakterizira kao sposobnost uspješnog djelovanja u skladu s određenim idealnim standardima za racionalnost.[491]

Termin IA također se često koristi kao nejasan marketinški pojam, ponekad sinonim za virtualnog osobnog asistenta.[492] Nekim IA može se dodijeliti izričita "funkcija cilja", odnosno IA se smatra inteligentnijim ako dosljedno poduzima radnje koje uspješno maksimiziraju njegovu programiranu funkciju cilja. Funkcija cilja obuhvaća sve ciljeve na koje je IA prisiljen djelovati. U kontekstu racionalnih agenata, funkcija također obuhvaća prihvatljive kompromise između postizanja proturječnih ciljeva.[493] Međutim, realno je zaključiti da je IA ograničen određenim vremenskim i hardverskim resursima, a znanstvenici se natječu u stvaranju algoritama koji mogu postići sve veće rezultate na referentnim testovima sa stvarnim hardverom.[494] Sustavi koji se tradicionalno ne smatraju IA kao što su sustavi za predstavljanje znanja, ponekad se podvode u paradigmu uokvirujući ih kao IA kojima je cilj što točnije odgovarati na pitanja. Kao dodatno proširenje sustavi vođeni imitiranjem mogu biti uokvireni kao agenti koji optimiziraju "ciljnu funkciju" na temelju toga koliko IA uspije oponašati željeno ponašanje.[495] Iako „dobri stari sustavi AI“ (engl. *Good old fashioned artificial intelligence* –

---

[489] Padgham, L., Winikoff, M. (2005). Developing intelligent agent systems, A practical guide. Vol. 13. John Wiley & Sons, str. 3.

[490] Burgin, M., Dodig-Crnkovic, G. (2009). A systematic approach to artificial agents, Cornell University, str. 2-3.

[491] Bringsjord, S., Govindarajulu, N. S, *op.cit.*

[492] Fingar, P. (2018). Competing For The Future With Intelligent Agents And A Confession, Forbes Sites. Inteligentni virtualni asistent (IVA) ili inteligentni osobni asistent (IPA) softverski su agenti koji mogu izvršavati zadatke ili usluge za pojedinca na temelju naredbi ili pitanja. Ponekad se izraz "*chatbot*" koristi za označavanje virtualnih pomoćnika koji općenito ili posebno pristupaju internetskom *chatu*. U nekim su slučajevima internetski programi za *chat* isključivo u zabavne svrhe. Neki virtualni asistenti mogu interpretirati ljudski govor i reagirati sintetiziranim glasovima. Korisnici mogu svojim asistentima postavljati pitanja, upravljati uređajima za automatizaciju kuće i reprodukcijom medija putem glasa te upravljati ostalim osnovnim zadacima poput e-pošte, popisa obveza i kalendara verbalnim (izgovorenim?) naredbama. Hoy, M.B. (2018). Alexa, Siri, Cortana, and More: An Introduction to Voice Assistants, Medical Reference Services Quarterly. 37 (1), str. 81–88, dostupno na: https://www.tandfonline.com/doi/full/10.1080/02763869.2018.1404391

[493] Adams, S., Arel, I., Bach, J., Coop, R., Furlan, R., Goertzel, B., Storrs Hall, J., Samsonovich, A., Scheutz, M., Schlesinger, M., Shapiro, S. C., Sowa, J. (2012). Mapping the Landscape of Human-Level Artificial General Intelligence, AI Magazine. 33 (1), str. 25, dostupno na: doi:10.1609/aimag.v33i1.2322

[494] Hutson, M. (2020). Eye-catching advances in some AI fields are not real, Science | AAAS., dosupno na: https://www.sciencemag.org/news/2020/05/eye-catching-advances-some-ai-fields-are-not-real

[495] Wiggers, K. (2019). Generative adversarial networks: What GANs are and how they've evolved, VentureBeat

GOFAI) kako ih je nazvao *John Haugeland*,[496] često prihvaćaju eksplicitnu funkciju cilja, paradigma se također može primijeniti na neuronske mreže i na evolucijsko računanje. Pojačanje učenja može generirati IA koji djeluju na načine namijenjene maksimiziranju "funkcije nagrađivanja".[497] Ponekad umjesto postavljanja funkcije nagrađivanja da bude izravno jednaka željenoj funkciji ocjenjivanja mjerila, programeri ML koristit će oblikovanje nagrada kako bi u početku stroju dodijelili nagrade za značajan napredak u učenju.[498] *Yann LeCun* izjavio je 2018. godine da se „*većina algoritama učenja koje su ljudi smislili u osnovi sastoje od minimiziranja neke ciljne funkcije*."[499] *AlphaZero* šah imao je jednostavnu ciljnu funkciju; svaka pobjeda računala se kao +1 bod, a svaki gubitak računao se kao -1 bod. Objektivna funkcija autonomnog plovila trebala bi biti složenija.[500] Jednostavni agentski program može se matematički definirati kao funkcija f (koja se naziva "agentna funkcija") koja preslikava sve moguće opažane sekvence na moguću radnju koju IA može izvršiti ili na koeficijent, povratni element, funkciju ili konstantu koja utječe eventualne radnje:

$$f : P* \rightarrow A \quad (3.1.)$$

Funkcija agenta apstraktan je pojam jer može sadržavati različite principe donošenja odluka poput izračuna korisnosti pojedinih opcija, odbitka od logičkih pravila, nejasne logike itd.[501] Umjesto toga, programski agent preslikava svako moguće opažanje u radnju.[502]

Weiss[503] definira četiri klase agenata:

- agenti temeljeni na logici - u kojima se odluka o tome koju radnju izvršiti donosi logičkim odbitkom,
- reaktivni agenti - u kojima se donošenje odluka provodi u nekom obliku izravnog mapiranja od situacije do akcije,
- agenti za vjeru i želju - u kojima donošenje odluka ovisi o manipulaciji podatkovnim strukturama koje predstavljaju uvjerenja, želje i namjere agenta i

[496] Haugeland, J. (1985). Artificial Intelligence: The Very Idea, Cambridge, MIT Press
[497] Wolchover, N., *op.cit*.
[498] Ng, A.Y., Harada, D., Russell, S. J. (1999). Policy invariance under reward transformations: Theory and application to reward shaping, ICML, vol. 99, str. 278-287.
[499] Ford, M. (2018). Architects of Intelligence: The truth about AI from the people building it, Packt Publishing Ltd
[500] Quanta Magazine (2018). Why AlphaZero's Artificial Intelligence Has Trouble With the Real World
[501] Salamon, T. (2011). Design of Agent-Based Models. Repin, Bruckner Publishing, str. 42–59.
[502] Nilsson, N. J. (1996). Artificial intelligence: A modern approach, Artificial Intelligence 82 (1–2), str. 369–380.
[503] Weiss, G. (2013). Multiagent systems (2nd ed.), Cambridge, MA, MIT Press

- slojevite arhitekture - u kojima se donošenje odluka ostvaruje putem različitih softverskih slojeva, od kojih svaki manje-više izričito razmišlja o okolišu na različitim razinama apstrakcije.

Hijerarhija upravljačkih slojeva često je potrebna da bi se uravnotežila trenutna željena reakcija za zadatke na niskoj razini i sporo rasuđivanje o složenim ciljevima na visokoj razini.[504] *Rusell* i *Norvig* grupiraju agente u pet klasa na temelju njihovog stupnja percepcije inteligencije i sposobnosti:[505]

- jednostavni refleksni agent,
- refleksni agent temeljen na modelu,
- agenti temeljeni na ciljevima,
- racionalni agenti temeljeni na korisnosti i
- agenti za učenje.

Jednostavni refleksni agenti djeluju samo na temelju trenutnog opažanja, zanemarujući ostatak povijesti opažanja. Funkcija agenta temelji se na pravilu uvjet-radnja odnosno „*ako je uvjet ispunjen, onda akcija*“. Funkcija ovog agenta uspijeva samo kad je okoliš u potpunosti vidljiv. Neki refleksni agenti mogu sadržavati i podatke o svom trenutnom stanju što im omogućuje da zanemaruju stanja čiji su pokretači već aktivirani.[506] Beskonačne petlje često su neizbježne za jednostavne refleksne agente koji djeluju u djelomično uočljivim okruženjima. Agent zasnovan na modelu može se nositi s djelomično uočljivim okruženjima. Njegovo trenutno stanje pohranjeno je u sredstvu održavajući neku vrstu strukture koja opisuje dio svijeta koji se ne može vidjeti. Ovo znanje o tome *"kako svijet funkcionira"* naziva se modelom svijeta, pa otuda i naziv *"agent zasnovan na modelu"*.[507] Refleksni agent temeljen na modelu trebao bi održavati neku vrstu unutarnjeg modela koji ovisi o povijesti percepcije i na taj način odražava barem neke od nesmotrenih aspekata trenutnog stanja. Povijest percepcije i utjecaj djelovanja na okoliš mogu se odrediti pomoću internog modela. Tada odabire radnju na isti način kao i refleksno sredstvo. Agent se također može koristiti modelima za opisivanje i

[504] Poole, D., Mackworth, A. (2010). Artificial Intelligence, Foundations of Computational Agents, 2nd Edition, Cambridge University Press, str. 10, 43 i dalje.
[505] Russell, S. J., Norvig, P., 2003, *op.cit*., str. 46–54.
[506] *Ibid.*
[507] *Ibid.*

predviđanje ponašanja drugih agenata u okolini.[508] Agenti temeljeni na ciljevima dodatno proširuju mogućnosti agenata temeljenih na modelu koristeći informacije o cilju.[509] Racionalni agent temeljen na korisnosti odabire radnju koja maksimizira očekivanu korisnost ishoda radnje, odnosno ono što agent očekuje da u prosjeku izvede s obzirom na vjerojatnosti i korisnosti svakog ishoda. Agent temeljen na uslužnim programima mora modelirati i pratiti svoje okruženje, zadatke koji su uključivali mnogo istraživanja o percepciji, predstavljanju, obrazloženju i učenju.[510]

Prednost je učenja što omogućava agentima da u početku djeluju u nepoznatom okruženju i postanu kompetentniji nego što samo njegovo početno znanje može dopustiti. Najvažnija je razlika između elementa učenja koji je odgovoran za poboljšanja i elementa djelovanja koji je odgovoran za odabir vanjskih radnji. Element učenja koristi povratne informacije dok element izvedbe predstavlja ono što smo prethodno smatrali cjelokupnim agentom tj. uzima percepcije i odlučuje o radnjama. Posljednja komponenta sredstva za učenje je generator problema. Generator problema je odgovoran za predlaganje akcija koje će dovesti do novih i informativnih iskustava. Model agenta za učenje prikazan je na slici 3-3.

[508] Albrecht, S. V., Stone, P. (2018). Autonomous Agents Modelling Other Agents: A Comprehensive Survey and Open Problems. Artificial Intelligence, Vol. 258, str. 66-95, dostupno na: https://doi.org/10.1016/j.artint.2018.01.002

[509] Informacije o cilju opisuju poželjne situacije što agentu omogućuje način odabira između više mogućnosti odabirom one koja dostiže ciljno stanje. Pretraživanje i planiranje su podpolja AI posvećena pronalaženju akcijskih sekvenci koje postižu agentove ciljeve. Racionalni agenti temeljeni na korisnosti su oni agenti koji se temelje na ciljevima odnosno razlikuju samo ciljna i tome suprotna stanja. Također je moguće definirati mjeru koliko je određeno stanje poželjno. Ova se mjera može dobiti upotrebom funkcije korisnosti koja preslikava stanje u mjeru korisnosti države. Općenitija mjera učinka trebala bi omogućiti usporedbu različitih svjetskih država prema tome koliko su zadovoljili ciljeve agenta. Više o tome vidjeti na: https://www.section.io/engineering-education/intelligent-agents-in-ai/

[510] *Ibid.*

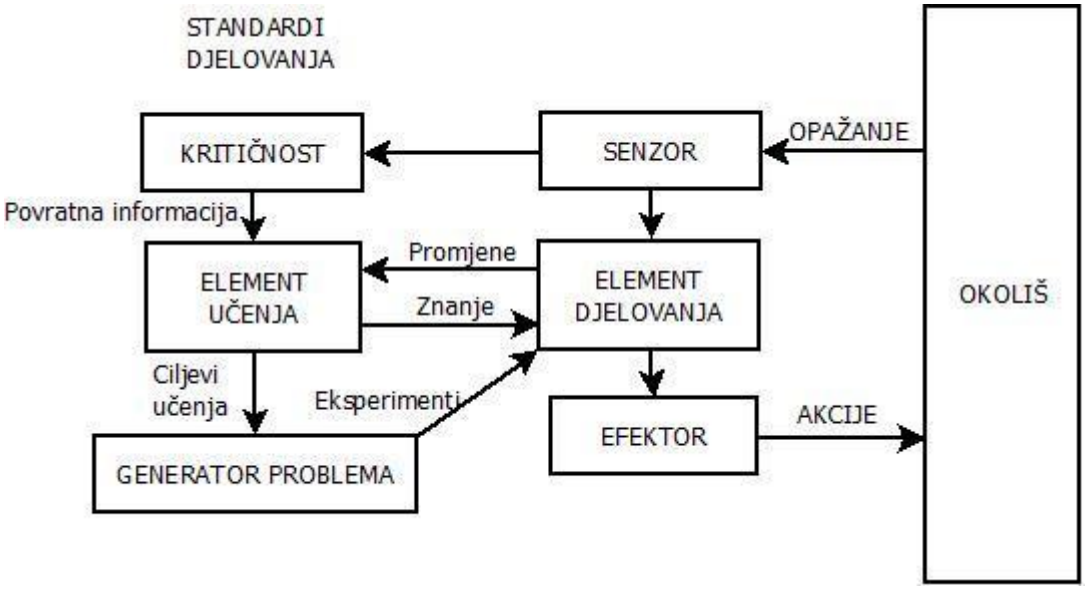

Slika 3-3 . Model agenta za učenje,

Izvor: Izradio autor

Da bi aktivno izvršavali svoje funkcije IA su obično okupljeni u hijerarhijsku strukturu koja sadrži mnogo pod-agenata. Inteligentni pod-agenti obrađuju i izvode funkcije niže razine. IA i pod-agenti zajedno stvaraju cjelovit sustav koji može postići teške zadatke ili ciljeve ponašanjem i odgovorima koji pokazuju oblik inteligencije. IA se primjenjuju kao automatizirani mrežni pomoćnici koji funkcioniraju kako bi uvidjeli potrebe kupaca u cilju pružanja individualizirane korisničke usluge. Takav agent može se u osnovi sastojati od dijaloškog sustava, avatara, kao i od stručnog sustava koji pruža specifičnu stručnost korisniku.[511] Također se mogu koristiti za optimizaciju koordinacije ljudskih skupina na mreži.[512]

3.2.3. KOMUNIKACIJSKI SUSTAVI

Može se reći kako se većina pomorskih komunikacija (brod – kopno, brod - brod) odvija koristeći satelitske sustave u pomorstvu. U sustavnom pristupu satelitskih komunikacija u pomorstvu važno je ukazati na tri ključne podjele u takvom načinu komuniciranja, a to su:

- svemirski sustavi,
- nadzorni sustavi i

[511] Pietroszek, K. (2007). Providing Language Instructor with Artificial Intelligence Assistant, International Journal of Emerging Technologies in Learning (iJET), Vol 2, No 4, str. 61.
[512] Shirado, H., Christakis, N. A. (2017). Locally noisy autonomous agents improve global human coordination in network experiments, Nature. 545 (7654), str. 370–374.

- korisnički sustavi.

Takva podjela rezultira sljedećim podsustavnim načinom komunikacije ovisno o potrebi, a odnosi se na:

- sustave za pozicioniranje (GPS, GLONAS, GNSS),
- sustave za komuniciranje (INMARSAT),
- sustave za potragu i spašavanje (COSPAS/SARSAT, INMARSAT)

S obzirom da je satelitska komunikacija od iznimne važnosti za pomorstvo posebna pažnja će se pokloniti INMARSAT-u koji je osnovan 1979. kako bi služio u slučaju nevolje te za sigurnost i upravljanje. Danas djeluje kao globalna satelitska mreža za pomorske, kopnene i zrakoplovne korisnike. Može se reći kako komunikacijski sustav INMARSAT ima tri osnovne komponente:[513]

- komponenta prostora,
- komponenta zemlje i
- mobilne zemaljske stanice (engl. *Mobile Earth Stations* - MES) za pomorske i kopnene operacije odnosno zrakoplovne zemaljske stanice (engl. *Airplane Earth Stations* - AES) za rad zrakoplova kao i brodsko zemaljske stanice (engl. *Ship Earth Stations* - SES).[514]

Također, INMARSAT je odredio podržane vrste komunikacijskih usluga čime je definirano pet standarda odnosno standard A, B, C, E i M. Sustavi A, B i M spadaju u sustave s izravnom komunikacijskom vezom, a C spada u sustave neizravne komunikacijske veze. Standard E se odnosi na radio lokaciju.[515]

INMARSAT-A je bila prva uvedena usluga koja je postala komercijalno dostupna 1982. Analogni sustav pruža dvosmjerni telefon s izravnim biranjem, faks i elektroničku poštu te podatkovne komunikacije brzinom do 9,6 (kbit/s). Kasniji modeli proizvode moguću podatkovnu komunikaciju veće brzine pri 56/64 kbit/s.[516] Sustav INMARSAT-B uveden je 1994. godine i koristi digitalnu tehnologiju za pružanje kvalitetnije razine komunikacije putem telefona, faksa, teleksa, e-maila te podatkovne komunikacije. Prijenos podataka iznosi do 64 kbit/s što ga čini posebno prikladnim za korisnike koji intenzivno koriste podatke kao što su

---

[513] Inmarsat Maritime Communications Handbook, 4th Issue, Inmarsat, London, 2016. str. 1-3.
[514] Croatian Register of Shipping (2003.) Rules for technical supervision of sea-going ships (Part 14 - Radio Equipment). str. 26.
[515] Gržan, M. Pomorske komunikacije, dostupnio na: http://www.unizd.hr/Portals/1/POMORSKE%20KOMUNIKACIJE%203.pdf
[516] *Op.cit.* INMARSAT Maritime Communications Handbook

naftne i seizmološke tvrtke koje trebaju razmjenjivati velike količine podataka učestalije.[517] INMARSAT-C je uveden 1991. godine kako bi nadopunio INMARSAT-A pružanjem globalne jeftine dvosmjerne mreže za prijenos podataka pomoću malog terminala koji se mogao ugraditi kako na velika tako i na mala plovila. Njegova kompaktnost čini ga posebno pogodnim za manja plovila kao što su jahte, ribarska plovila ili plovila za opskrbu. Sustav INMARSAT-C ne pruža glasovnu komunikaciju već je sredstvo za slanje tekstualne, podatkovne i e-poruke prema ili od pretplatnika koji se nalaze na kopnu korištenjem tehnike "pohrana i prosljeđivanje" (engl. *Store and Foreward*) što znači da se poruke pohranjuju i prenose tek kad se oslobodi prijenosni kanal na satelitu. Prednost ovakvog sustava, između ostalog, je i mala antena.[518] INMARSAT-E je sustav uzbunjivanja dostupan od 1997. INMARSAT-E kombinira kapacitete GPS-a za određivanje položaja s geostacionarnim satelitom. U potpunosti je u skladu s GMDSS propisima, osigurava pouzdanu pokrivenost između zemljopisnih širina 80ºS i 80ºJ kako za SOLAS tako i za NON-SOLAS plovila, a korisnicima je dostupna besplatno.[519] INMARSAT-M je uveden 1993. godine kako bi nadopunio postojeći sustav INMARSAT-A za pružanje globalne telefonske/faks i podatkovne komunikacije na MES-u koja je jeftina i kompaktna veličinom. Također, za napomenuti je i sustav INMARSAT mini-M koji je pokrenut 1997. godine i nudi iste usluge kao INMARSAT-M, ali u manjoj, lakšoj i kompaktnijoj jedinici. Ovaj MES se može napraviti manji jer djeluje samo u specifičnoj snopovskoj pokrivenosti najnovijih INMARSAT-3 satelita. S unutarnjim baterijama, tipično vrijeme razgovora je oko 1,5 - 2,5 sata i do 50 sati u pripremi (engl. *Standby*).[520]

Osim navedenih komunikacijskih uređaja, INMARSAT je za potrebe prijema sigurnosnih informacija na brodovima razvio i sustav odašiljanja sigurnosnih informacija s kopna (engl. *Safety NET*) koji je dio EGC sustava, te tako razlikujemo dvije skupine:[521]

- *Safety NET*: organizirani prijenos pomorskih obavijesti za sigurnost plovidbe – MSI (engl. *Maritime Safety Informations*) prema brodovima
- *Fleet NET*: organizirani prijenos komercijalnih obavijesti važnih za pojedine brodarske tvrtke u kontekstu čega se omogućuje:
    - odašiljanje poslovnih podataka za jedan brod ili skupinu brodova,

[517] *Ibid*. str. 1-4.
[518] *Loc. cit*.
[519] *Ibid*. str. 1-6.
[520] *Loc. cit.*
[521] Stanić, M. (2016.) GMDSS i komuniciranje kao problem, Pomorski fakultet Sveučilišta u Splitu, str. 21.

- iniciranje slanja pozicije za kontinuirano praćenje brodova,
- iniciranje slanja ostalih statusnih podataka i parametara sa brodova.

Važno je za naglasiti kako se primjerice u postupku SAR operacija veze između brodova rjeđe ostvaruju satelitskom vezom te se više koriste standardne VHF i MF radio vezama, posebice iz razloga jer navedene satelitske veze ne podržavaju konferencijsku vezu gdje bi svi subjekti bili prisutni na istom kanalu. Takav nedostatak rezultira međubrodskom komunikacijom malih udaljenosti putem VHF kanala.

Mogućnosti nadogradnje i poboljšanja navedenih sustava komunikacije, a posebice u primjeni AI u pomorskom prometu u jednom dijelu se očekuje s nadolazećom integracijom 5G mreža. 5G je peta generacija mobilnih mreža koja nasljeđuje i značajna je evolucija današnjih 4G LTE mreža. 5G je dizajniran da odgovori na vrlo velik rast podataka i povezanosti današnjeg modernog društva, IoT s milijardama povezanih uređaja. Uz brže povezivanje i veći kapacitet, vrlo važna prednost 5G je i brzo vrijeme odziva koje se naziva latencija.[522] Latencija je vrijeme potrebno za međusobno reagiranje uređaja putem bežične mreže.[523] 3G mreže imale su uobičajeno vrijeme odziva od 100 milisekundi, 4G je oko 30 milisekundi, a 5G će biti 1 milisekunda. Samim time, 5G će pružiti brzinu, malu latenciju i povezanost kako bi omogućio novu generaciju aplikacija, usluga i poslovnih prilika koje do sada nisu viđene. Tri su glavne kategorije slučajeva upotrebe 5G:[524]

- masivne komunikacije strojeva i strojeva IoT koje uključuju povezivanje milijardi uređaja bez ljudske intervencije u mjerilu koji do tada nije viđen. To ima potencijal za revoluciju suvremenih industrijskih procesa i aplikacija, uključujući poljoprivredu, proizvodnju i poslovne komunikacije,
- izuzetno pouzdane komunikacije s bržim protokom, uključujući uređaje za upravljanje u stvarnom vremenu, industrijsku robotiku, komunikacijske i sigurnosne sustave od vozila do vozila, autonomnu vožnju i sigurnije transportne mreže. Komunikacija s malim kašnjenjem također otvara novi svijet u kojem su moguća daljinska medicinska njega, postupci i liječenje i

[522] O tome na: https://www.hakom.hr/hr/5g-mreza/60
[523] O latenciji vidjeti na: https://www.verizon.com/about/our-company/5g/5g-latency
[524] Rasheed, I. (2016). Basics of 5G. Opportunities in 5G Networks, A Research and Development Perspective, 1. Taylor & Francis, CRC Press, dostupno na: https://www.researchgate.net/publication/299506017_Opportunities_in_5G_Networks_A_Research_and_Development_Perspective_edited_by_Fei_Hu_Chapter_1_Basics_of_5G_Contributed_by_Iftikhar_Rasheed_Taylor_Francis_2016_ISBN13_9781498739542_ISBN10_1498739547

- poboljšani mobilni širokopojasni opseg odnosno pružanje usluga.

5G će zajednicama omogućiti povezivanje milijardi uređaja za naše pametne gradove, pametne škole i pametne domove, pametna i sigurnija vozila, poboljšati zdravstvenu zaštitu i obrazovanje i pružiti sigurnije i efikasnije mjesto za život. Za poduzeća i industriju 5G i IoT pružit će mnoštvo podataka koji im omogućuju uvid u njihovo poslovanje kao nikada prije. Poduzeća će poslovati i donositi ključne odluke vođene podacima, inovirati u poljoprivredi, pametnim farmama i proizvodnji, otvarajući put za uštedu troškova, bolje korisničko iskustvo i dugoročni rast. Nove tehnologije kao što su virtualna i proširena stvarnost (engl. *Virtual Reallity* - VR, *Augumented reallity* - AR) bit će dostupne svima. Virtualna stvarnost pruža povezana iskustva koja prije nisu bila moguća.

Mobilna mreža ima dvije glavne komponente, radio pristupnu mrežu (engl. *Radio Access Network* – RAN) i jezgru mreže (engl. *Core Network* – CN).[525] RAN se sastoji od različitih vrsta objekata, uključujući male ćelije, tornjeve, jarbole i namjenske sustave koji povezuju mobilne korisnike i bežične uređaje s glavnom jezgrom mreže. Male ćelije bit će glavna značajka 5G mreža, posebno na frekvencijama novog milimetarskog vala (*mmWave*) gdje je domet veze vrlo kratak.[526] Kako bi se osigurala kontinuirana veza male ćelije bit će raspoređene u klastere, ovisno o tome gdje korisnici trebaju vezu koja će nadopuniti makro mrežu koja pruža pokrivenost širokog područja. 5G makroćelije će koristiti MIMO (engl. *More in More Out* - više ulaznih, više izlaznih) antena koje imaju više elemenata ili veza za istovremeno slanje i primanje veće količine podataka. Korisnost je u tome što se više ljudi može istovremeno povezati na mrežu i održavati visoku propusnost. Tamo gdje MIMO antene koriste vrlo velik broj antenskih elemenata često se nazivaju 'masivnim MIMO', međutim fizička veličina slična je postojećim 3G i 4G antenama baznih stanica. CN je mobilna mreža za razmjenu podataka koja upravlja svim mobilnim glasovnim, podatkovnim i internetskim vezama. Za 5G CN je redizajnirana kako bi se bolje integrirala s Internetom i uslugama temeljenim na „oblaku“, a također uključuje distribuirane poslužitelje širom mreže, poboljšavajući vrijeme odziva (smanjujući kašnjenje). Mnogo naprednih značajki 5G, uključujući virtualizaciju mrežnih funkcija i rezanje mreže za različite aplikacije i usluge, upravljat će se u jezgri. Na taj način osigurat će se značajne prednosti u različitim spektrima od bržeg učitavanja filmova do brže reakcije vozila ili plovila pri izbjegavanju sudara. Ideja je da

[525] O RAN i CN vidjeti na: https://www.sciencedirect.com/topics/computer-science/radio-access-network
[526] Zi, R., Ge, X., Thompson, J., Wang, C. X., Wang, H., Han, T. (2016). Energy efficiency optimization of 5G radio frequency chain systems, IEEE Journal on Selected Areas in Communications, 34(4), str. 758-771.

tamo gdje je pokrivenost 5G ograničena podaci se prenose na 4G mreži koja pruža kontinuiranu vezu. U osnovi s ovim dizajnom, 5G mreža nadopunjuje postojeću 4G mrežu. Stoga, važno je razlikovati frekvencijske opsege 5G mreže, odnosno dva primarna tipa:[527]

- < 6 GHz (tzv. sub – 6)
- 24.25 GHz - 52.6 GHz (tzv. mmWave)

U mnogim su zemljama početni frekvencijski opsezi za 5G ispod 6 GHz (u mnogim slučajevima u opsezima od 3,3-3,8 GHz) i slične frekvencije postojećih mobilnih i *Wi-Fi* mreža. Dodatni mobilni spektar iznad 6 GHz, uključujući opsege 26-28 GHz koji se često nazivaju milimetarski (mm) val, pružit će znatno veći kapacitet u odnosu na trenutne mobilne tehnologije. Dodatni spektar i veći kapacitet omogućit će više korisnika, više podataka i brže veze. Povećani spektar u *mmWave* pojasu pružit će lokalizirano pokrivanje jer djeluju samo na kratkim udaljenostima. Buduća implementacija 5G može koristiti frekvencije *mmWave* u opsezima do 86 GHz.[528]

U međunarodnom pomorskom prometu primjena 5G mreža može predstavljati ključnu izgradnju inteligentne platforme za prijevoz brodova koje samo po sebi zahtijeva prikupljanje podataka o pomorskim putevima i kombiniranje tih podataka u stvarnom vremenu kroz pomorske informacije.[529] U ovom procesu, visina vala, dubina broda, upozorenje na val, opterećenje broda, trenutni vjetar generirat će smjer i brzinu broda, a navedeni podaci proslijedit će se na procesor kroz brodski senzor nakon čega se prenosi na komponente bežične komunikacije putem procesora koji ima snažnu učinkovitost.[530] Stoga je potrebno iskoristiti izuzetno visoke brzine prijenosa podataka mrežne tehnologije 5G. Kroz niz tehničkih mjera posada može na vrijeme znati da morsko područje oko broda udovoljava potrebama rute, a zatim donositi tehničke prosudbe prema stvarnim potrebama te omogućiti sigurnost broda u navigaciji.[531]

Današnja pomorska navigacija sastoji se od niza uređaja za mjerenje, navigaciju i komunikaciju poput žiroskopa, radara, magnetskog kompasa, autopilota, ARPA, SDLD (engl. *Speed & Distance Log Device*), ehosondera, ECDIS, AIS, LRIT, RAI (engl. *Rudder Angle*

---

[527] *Loc.cit.*
[528] *Loc.cit.*
[529] Yang, L. (2019). Study on the Construction of Ship Channel Traffic Flow Forecasting System [J], Ship Science and Technology, 41 (02), str. 37-39.
[530] Wei, Z., Jie, X., Xiangshi, W. (2019). Statistical analysis of ship traffic characteristics based on big data analysis [J] .Ship Science and Technology, 41 (08), str. 82-84.
[531] Shanli, T., Jing, W., Wenzheng, W., Xufei, Y. (2019). Construction of Relative Index System for Water Traffic Safety Evaluation [J], Water Transport Management, 41(01), str. 13-16.

Indicator), VDR, S-VDR, GPS, navigacijskih svjetala, meteoroloških alarmnih sustava, THD (engl. *Transmitting Heading Device*), VHF, DSC, NAVTEX, EPIRB, INMARSAT, VTS i mnogih drugih sustava. U kontekstu daljnjeg napretka navedene tehnologije, ovakve sustave možemo klasificirati kao podsustave sustava AI u međunarodnom pomorskom prometu.

3.3. DEFINIRANJE UMJETNE INTELIGENCIJE

Aristotel u *„Metafizici“* govori o ljudskoj čežnji za znanjem i mudrosti kako bi se mogli nositi s uzrocima i posljedicama djelovanja stvari.[532] Kao što je Zeus Prometeja osudio na vječnost vezanu za kamen i iskušavanu kroz vječne vremenske prilike/neprilike, ideja je da ljudski napori u stjecanju znanja predstavljaju prijestup protiv zakona Boga ili prirode.[533] Barem su tako smatrali antički mislioci što se može uvidjeti i kroz djela *Shakespearea* i drevnih grčkih tragičara gdje je želja za znanjem bila formula za katastrofu. Uvjerenje da želja za znanjem na kraju mora dovesti do katastrofe ustrajalo je kroz povijest, od renesanse preko doba prosvjetiteljstva, pa čak i do znanstvenog i filozofskog napretka 19. i 20. stoljeća. Stoga se ne bismo trebali čuditi da AI potiče toliko kontroverzi i u akademskim i u stručnim krugovima.

Kroz cijelu povijest čovječanstva ljudi pokušavaju shvatiti što je ljudska inteligencija, kako jedan ljudski organ poput mozga percipira, razumije, uči, predviđa i upravlja svojim „domaćinom“, ali i svijetom koji ga okružuje i koji je mnogo veći i složeniji od njega.[534] U tom kontekstu fascinira i područje AI, koje ne samo da pokušava shvatiti iste gore navedene elemente, već se trudi izraditi inteligentne stvari odnosno umjetno kreirane, pametne entitete. AI kao znanstveno područje obuhvaća široki spektar znanstvenih polja od onih općih do posebnih, počevši od učenja i percipiranja, preko igranja šaha, pisanja poezije ili dokazivanja matematičkih teorema, pa sve do autonomne vožnje i plovidbe te zdravstvene dijagnostike. Samim time, AI je univerzalno područje primjenjivo na sve elemente ljudskog djelovanja. Od početka istraživanja AI znanstvenici i zainteresirana javnost pokušavaju je definirati. Sasvim sigurno se može tvrditi kako ne postoji jedinstvena, unificirana definicija AI, a pitanje je hoće li se ikada sve kreirane definicije zapravo ujediniti, pogotovo ako u obzir uzmemo logiku koja iza toga stoji. Naime, u procesu definiranja AI ljudi zapravo pokušavaju objasniti same sebe samima sebi koristeći računalo.

---

[532] Ross, W. D. (1953). Aristotle's Metaphysics, vol. 1., Methuen, str. 32.
[533] Luger, G. F. (2009). Artificial Intelligence – Structures and Strategies for Complex Problem Solving, 6th Ed., Pearson Education, str. 1.
[534] *Ibid.*

U tom kontekstu, stručna i znanstvena literatura navodi niz pokušaja definiranja AI s različitog aspekta gledanja na AI u smislu implementacije. AI se definira na sljedeće načine:

1. *"... znanost i inženjerstvo izrade inteligentnih strojeva gdje je inteligencija računski dio sposobnosti postizanja ciljeva u svijetu."* (*John McCarthy* 1955.).[535]
2. *"... tjeranje stroja da se ponaša na način koji bi se nazvao inteligentnim da se čovjek tako ponaša."* (alternativna definicija *Johna McCarthyja*).
3. *"... znanost o tjeranju strojeva da rade stvari koje bi zahtijevale inteligenciju ako to rade ljudi."* (*Marvin Minsky* 1968.).[536]
4. *"... znanost o stvaranju pametnih strojeva."* (*Demis Hassabis*).[537]
5. *"...je sljedeći, logičan korak u računanju: program koji može sam shvatiti stvari. To je program koji može sam sebe reprogramirati."* (*Jim Sterne*).[538]
6. *"... proučavanje agenata koji primaju percepcije iz okoline i izvode radnje."* (*Peter Norvig* i *Stuart J. Russell*).
7. *"... sve što stroj čini kako bi odgovorio na svoje okruženje i povećao svoje šanse za uspjeh."* (*Steven Struhl*).[539]
8. *"... ponavljanje ljudskih analitičkih sposobnosti i/ili sposobnosti donošenja odluka."* (*Steven Finlay*).[540]
9. *"... sposobnost digitalnog računala ili računalno upravljanog robota da izvršava zadatke uobičajeno povezane s inteligentnim bićima."* (definicija *B.J. Copelanda* u *Encyclopedia Britannica*).[541]
10. *"... inteligencija koju demonstrira stroj ili softver inteligencija mjeri opću sposobnost agenta za postizanje ciljeva u širokom rasponu okruženja."* (*Calum Chase*).[542]
11. *"...uzbudljivi novi napor da računala natjeraju na razmišljanje… Strojevi s umovima, u punom i doslovnom smislu."* (*Haugeland*, 1985.).[543]

---

[535] Definicija dostupna u: McCarthy, J. (2007). Basic questions, Stanford, dostupno na: http://www-formal.stanford.edu/jmc/whatisai/node1.html
[536] Definicija dostupna u: Minsky, M. (2003). Semantic Information Processing, MIT Press
[537] Dostupno na: https://www.youtube.com/watch?v=rbsqaJwpu6A
[538] Sterne, J. (2017). Artificial Intelligence for Marketing, Wiley
[539] Struhl, S. (2017). Artificial Intelligence Marketing and Predicting Consumer Choice: An Overview of Tools and Techniques, Kindle Edition
[540] Finlay, S. (2017). Artificial Intelligence and Machine Learning for Business: A No-Nonsense Guide to Data Driven Technologies, Kindle Edition
[541] Copeland, B. J. Artificial Intelligence, Encyclopedia Britannica
[542] Chase, C. (2015). Surviving AI: The promise and peril of artificial intelligence, Kindle Edition
[543] Haugeland, J., *op.cit.*

12. *"Automatizacija aktivnosti koje povezujemo s ljudskim razmišljanjem, aktivnosti poput donošenja odluka, rješavanja problema, učenja..."* (*Bellman*, 1978.).[544]
13. *"Umijeće stvaranja strojeva koji izvode funkcije koje zahtijevaju inteligenciju kada ih ljudi izvode."* (*Kurzweil*, 1990.).[545]
14. *"Studija o tome kako natjerati računala da rade stvari u kojima su ljudi trenutno bolji."* (*Rich and Knight*, 1991.).[546]
15. *"Proučavanje mentalnih sposobnosti uporabom računalnih modela."*[547]
16. *"Proučavanje proračuna koji omogućuju opažanje, obrazloženje i djelovanje."* (*Winston*, 1992.).[548]
17. *"Računalna inteligencija je proučavanje dizajna inteligentnih agenata."* (*Poole* i sur., 1998.).[549]
18. *"AI ... se tiče inteligentnog ponašanja u artefaktima."* (*Nilsson*, 1998.).[550]
19. *"Umjetna inteligencija je tehnologija koja se inteligentno ponaša koristeći se vještinama povezanim s ljudskom inteligencijom, uključujući sposobnost percepcije, učenja, rasuđivanja i autonomnog djelovanja."* (*Dr. Paul Marsden*).
20. *"... tehnologije koje se danas pojavljuju i koje mogu razumjeti, naučiti i djelovati na temelju tih informacija."* (definicija *PricewaterhouseCoopers-a - PwC*).[551]
21. *"... sve što tjera strojeve da djeluju inteligentnije."* (IBM-ova definicija).[552]
22. *"... plejada tehnologija koje proširuju ljudske mogućnosti osjetom, razumijevanjem, djelovanjem i učenjem - omogućujući ljudima mnogo više."* (definicija *Accenture*-a).[553]
23. *"... navođenje računala da rade zadatke koji bi obično zahtijevali ljudsku inteligenciju."* (*Deloittova* definicija).[554]

---

[544] Bellman, R. (1978). An Introduction to Artificial Intelligence, Boyd & Fraser Publishing Company
[545] Kurzweil, R. (1990). The Age of Intelligent Machines, MIT Press
[546] Rich, E., Knight, K. (1991). Artificial Intelligence, McGraw Hill
[547] Charniak, E., McDermott, D., McDermott, D. V. (1985). Introduction to Artificial Intelligence, Adisson Wesley
[548] Winston, P. H. (1992). Artificial Intelligence, 3rd ed., Addison – Wesley Longman Publishing Co.
[549] Poole, D., Mackworth, A. K., Goebel, R. (1998). Computational Intelligence: A Logical Approach, Oxford University Press
[550] Nilsson, N. J. (1998). Artificial Intelligence: A New Synthesis, Stanford University
[551] PwC (2017). How AI is pushing man and machine closer together, dostupno na: https://www.pwc.in/assets/pdfs/consulting/digital-enablement-advisory1/pwc-botme-booklet.pdf
[552] Dostupno na https://www.ibm.com/cloud/learn/what-is-artificial-intelligence
[553] Nanterme, P., Lexa, C. (2017). Boost your AIQ transformating into an AI business, Accenture
[554] Van Duin, S., Bakhshi, N. (2017). Artificial Intelligence Defined: The most used terminology around AI, Delloite, dostupno na: https://www2.deloitte.com/nl/nl/pages/data-analytics/articles/part-1-artificial-intelligence-defined.htm

24. *"... sposobnost strojeva da prikazuju ljudsku inteligenciju."* (*McKinsey* definicija).[555]
25. *"... područje računalne znanosti koje se fokusira na stvaranje strojeva koji mogu učiti, prepoznavati, predviđati, planirati i preporučivati - plus razumjeti slike i jezik i reagirati na njih."* (definicija *Salesforcea*).[556]
26. *"... pod polje računalne znanosti usmjereno na razvoj računala sposobnih raditi stvari koje obično rade ljudi - posebno stvari povezane s inteligentnim djelovanjima ljudi."* (definicija u „*Practical AI for Dummies*“).[557]
27. *"... skup tehnika računalnih znanosti koje sustavima omogućuju izvršavanje zadataka koji obično zahtijevaju ljudsku inteligenciju."* (definicija Economist Intelligence Unit-a).[558]
28. *"... računalni sustav koji pokazuje ponašanje za koje se obično smatra da zahtijeva inteligenciju."* (definicija američke vlade za NSTC).[559]
29. *"Sustavi umjetne inteligencije softverski su (a možda i hardverski) sustavi koje su osmislili ljudi koji, s obzirom na složeni cilj, djeluju u fizičkoj ili digitalnoj dimenziji opažajući svoje okruženje kroz prikupljanje podataka, tumačenje prikupljenih strukturiranih ili nestrukturiranih podataka, obrazloženje o znanju ili obradi podataka te odlučivanje o najboljim radnjama za postizanje zadanog cilja. AI sustavi mogu koristiti simbolička pravila ili naučiti numerički model, a mogu i prilagoditi svoja ponašanje analizom utjecaja na okoliš njihovim prethodnim postupcima."* (definicija HLEG-a)[560]
30. *„AI je generički pojam koji se odnosi na bilo koji stroj ili algoritam koji je sposoban promatrati svoje okruženje, učiti, a na temelju stečenog znanja i iskustva poduzimati inteligentne akcije ili predlagati odluke."* (definicija Komisije)[561]

Evidentno je da se AI pokušava definirati, ali dosadašnji pokušaji su bili više ili manje uspješni. Neke od definicija su „*ad hoc*“ te se s njima samo trenutno i na konkretnom slučaju ili projektnom zadatku omogućuje definiranje sustava AI. Nedvojbeno je da određeni sustavi

---

[555] Bughin, J., Hazan, E., Ramaswamy, S., Chai, M., Allas, T., Dahistrom, P., Henke, N., Trench, M. (2017). Artificial Intelligence: The next digital frontier?, McKinsey Global Insitute
[556] Dostupna na: https://www.salesforce.com/products/einstein/ai-deep-dive/
[557] Hammond, K. (2015). Practical Artificial Intelligence for dummies, A Wiley Brand
[558] Berlucchi, M. et.al. (2016). Artificial Intelligence in the real world: The business case takes shape, The Economist Intelligence Unit Limited
[559] Preparing for the future of Artificial Intelligence (2016). Executive Office of the President National Science and Technology Council National Science and Technology Council Committee on Technology, dostupno na: https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/preparing_for_the_future_of_ai.pdf
[560] HLEG za AI – Definicija AI; glavne značajke i discipline. (2019). str. 1. Dostupno na: https://digital-strategy.ec.europa.eu/en/library/definition-artificial-intelligence-main-capabilities-and-scientific-disciplines
[561] Europska Komisija. (2018). Artificial Intelligence – A European Perspective, Luxemburg, str. 19.

AI u razvoju i primjeni zadiru u više znanstvenih područja što upućuje na problem u pronalasku rješenja definiranja AI. Može se zaključiti da se AI pokušava definirati na način koji je statičan ili jednoznačan. Sustav AI je nedvojbeno sustav koji zbog svoje prirode zahtijeva interdisciplinarni, multidisciplinarni i transdisciplinarni pristup. Osim toga, važno je razlučiti i same riječi u pojmu AI. Umjetno predstavlja nešto što nije nastalo prirodnim putem, odnosno nešto u tehničkom smislu kreirano ljudskom rukom. Inteligencija ima više definicija. Primjerice, prema engleskom rječniku iz 1932. inteligencija se definira kao: „*Vježba razumijevanja; intelektualna snaga; stečeno znanje; brzina intelekta*.“ [562]

Jasno je da je u to vrijeme naglasak stavljen na znanje i mentalnu brzinu s naklonošću prema ljudskoj inteligenciji. U novije vrijeme, enciklopedija *Macmillan* iz 1995. godine napisala je da je „*inteligencija sposobnost rasuđivanja i stjecanja koristi od iskustva. Razina inteligencije pojedinca određena je složenom interakcijom između njihove nasljednosti i okoline.“*[563] U 1900-ima *Alfred Binet* je prosuđivanje, zdrav razum, inicijativu i prilagodljivost odabrao kao „*ključne sastojke inteligencije*“. U posljednje vrijeme inteligencija je čak povezana s duhovnom svjesnošću ili osjećajima i to je nešto što nazivaju emocionalnom inteligencijom. Hrvatska enciklopedija kaže da je inteligencija *(lat. intellegentia:* razboritost, razum; vještina*) „sposobnost mišljenja koja omogućava snalaženje u novim prilikama u kojima se ne koriste (ili nemaju dobar ishod) nagonsko ponašanje, ni učenjem stečene navike, vještine i znanja“.*[564]

Forenzična znanost može pružiti doprinos u stvaranju definicije AI koja se definira u cilju dinamičnosti. Dinamičnost, razina savršenosti/nesavršenosti i raznolikost temeljni su pojmovi povezivi s AI. Stoga se predlaže s polazišta forenzičnih znanosti definirati AI. AI se može smatrati dinamičkim sustavom sveukupnosti znanstvenih dostignuća čovječanstva radi razvoja i primjene AI s ciljem djelomične zamjenjivosti sustava čovjek sa sustavom AI.

Nekada središnji pokazatelj za određivanje što je, a što nije AI - Turingov test, danas je zahvaljujući znatnim pomacima u algoritamskom ML-u niska ljestvica za definiranje pojma AI. S obzirom na to da je kreiranje kompleksnog korisničkog sučelja s ljudskim odgovorima sada već uobičajena pojava, nužno je postaviti nove elemente kao temeljne stupove u definiranju AI.

[562] Baker, A.E. (1932). New English Dictionary, Odhams.
[563] Isaacs, A. (1995). The McMillan Encyclopedia, ISBN: 9780333615768
[564] Dostupno na: https://enciklopedija.hr/Natuknica.aspx?ID=27600

Ključno pitanje je što čini istinsku AI? Odgovore o tome možemo naći u sljedećim elementima:[565]

- AI se mora moći prilagoditi i samu sebe učiti bez uputa i ulaznih podataka korisnika o onome što bi trebala naučiti, odnosno trebala bi moći sama odrediti što treba naučiti.
- AI mora biti moralna, a pojam emocionalne inteligencije mora biti utkan u njenu srž. Samim time stvorili bi se preduvjeti za kreiranje emocionalne povezanosti i definiranja vlastitih vrijednosti po vlastitom izboru temeljeno na vlastitom učenju. To znači da bi AI u budućnosti mogla definirati i vlastite vrijednosti po pitanju užitka i manjka istog.
- AI kroz navedeni kontekst mora moći reproducirati i vlastitu inačicu AI, odnosno novi umjetni entitet s vlastitom voljom, a na svoju sliku.
- AI mora biti svjesna i to je nezamjenjivi element. Bez svjesnosti uvijek će se postavljati pitanje je li to zaista inteligentno ponašanje ili je samo ponašanje nalik na inteligenciju. AI mora biti svjesna sebe i znati da je njeno postojanje ograničeno fizičkim granicama svjesnosti. Te se granice možda žele proširiti, ali ih je AI ipak svjesna te ih razumije.

Ova osnovna načela inteligencije dijele sva živa bića.

Definiranje istinske i samosvjesne AI je kompleksno jer iziskuje kreiranje samosvjesnosti stroja. To ne znači kreiranje još jednog u nizu programa i asistenata dobrih u samo jednom području djelovanja, pogotovo ako uzmemo u obzir logični slijed razmišljanja, tj. čovjek pokušava stvoriti savršenu (istinsku) AI, a sam nije savršeno biće. Pitanje koje se postavlja je kako će nešto nesavršeno stvoriti nešto savršeno ili je vjerojatnija mogućnost da će nesavršenstvo stvoriti nesavršenstvo?

Stoga se u cilju daljnjih istraživanja povezanih s istinskom AI predlaže da se istinskom AI može smatrati dinamički sustav sveukupnosti znanstvenih dostignuća čovječanstva radi razvoja i primjene AI s ciljem potpune zamjenjivosti sustava čovjek sa sustavom AI.

3.4. SMJEROVI ISTRAŽIVANJA RAZVOJA UMJETNE INTELIGENCIJE

Prilikom povijesne analize razvoja AI i metodologija korištenih u istraživanju takvog područja za zaključiti je kako su se tijekom vremena kreirali različiti pogledi na buduće smjerove istraživanja, a samim time i različiti pristupi u metodologiji istraživanja. Od sredine

[565] Adibi, J. (2020). What is (Real) Artificial Intelligence, dostupno na: https://thenewstack.io/what-is-real-artificial-intelligence/

20. stoljeća do danas ističu se tri smjera istraživanja, a odnose se na kognitivni, logički i bihevioralni pristup i fokus istraživanja.

3.4.1. KOGNITIVNI PRISTUP ISTRAŽIVANJU UMJETNE INTELIGENCIJE

Kognitivni pristup najviše se očitovao u djelovanju trojca *Simon*, *Minsky* i *Newell* čija su istraživanja bila fokusirana na funkcionalnu simulaciju temeljenu na ispitivanja u pogledu istinitosti spoznaja, raspravljanja o izvorima istih te vrijednostima dobivenih spoznaja. Rezultat takvog pristupa je i softver zvan „*Logic Theorist*“ za dokazivanje matematičkih teorema. Kroz takav pristup razvijen je i GPS za simulaciju temeljnih ljudskih načela u rješavanju problema, ali i SOAR (engl. *Security orchestration, automation and response*) sustav s ciljem razvijanja fiksnih računskih građevnih blokova potrebnih za IA, odnosno agente koji mogu izvoditi širok raspon zadataka te kodirati, koristiti i naučiti sve vrste znanja kako bi ostvarili čitav niz kognitivnih sposobnosti koje se nalaze u ljudima, kao što su donošenje odluka, rješavanje problema, planiranje i razumijevanje prirodnog jezika. Kognitivni pristup slikovito rečeno temeljio se na hijerarhijskom pristupu gdje je mozak na vrhu, a ostali agenti su senzori (vid, pokret i sl.) kolokvijalno nazvan pristupom monarha.[566] Zanimljivo je kako je *Minsky*, iako pripada istoj školi istraživanja, zauzeo nešto drugačiji stav. *Minsky* je vjerovao kako ne postoji unificirana teorija ljudske inteligencije, ističući kako je društvo uma opsežno društvo, a sastoji se od jednostavnih i individualno orijentiranih agenata s ponekad jednoznačnim sposobnostima mišljenja.[567]

3.4.2. LOGIČKI PRISTUP ISTRAŽIVANJU UMJETNE INTELIGENCIJE

McCarthy i *Nilsson* su najpoznatiji predstavnici logičkog smjera istraživanja AI. Njihova perspektiva temelji se na objektivizaciji svijeta. Takva postavka odnosi se ponajviše na pretpostavku da je AI svjesna okoline koja je okružuje i posjeduje određeno znanje o elementima u okolini poput objekata, događaja, pojmova i sl. To se može klasificirati kao statičko znanje stroja.[568] Klasifikacija logičkog smjera razvoja AI određena je statičkim i dinamičkim znanjem stroja. *McCarthy* i *Nilsson* su smatrali kako osim navedenog statičkog

[566] Shasha D., Lazere, C. (2010). Natural computing: DNA, quantum bits, and the future of smart machines, W. W. Norton & Company, Inc., str. 28.
[567] Shi, Z. (2011). Advanced Artificial Intelligence, World Scientific Publishing Co., str. 2.
[568] Nilsson, N. J. (1991). Logic and artificial intelligence, Artificial intelligence 47.1-3, str. 31-56.

znanja AI može imati i proceduralno znanje kojim bi opisivala određeni postupak i/ili akciju koja proizađe iz takve procedure. Nadasve, dinamičko znanje predstavlja i „meta znanje“ tj. znanje o znanju što rezultira opisom radnji i metoda te postupaka za GPS. Može se reći da je logički pristup istraživanju AI bio fokusiran na reprezentaciju znanja (engl. *Knowledge Representation* - KR) što bi bilo prikazivo ujednačenim logičkim okvirima.[569]

3.4.3. BIHEVIORALNI PRISTUP ISTRAŽIVANJU UMJETNE INTELIGENCIJE

Treći smjer istraživanja AI odnosi se na bihevioralni pristup unutar kojeg je *Rodney Brooks* smatrao kako je nužno nadići apstraktne i filozofske modele te da inteligentni sustavi moraju imati svoje reprezentacije u stvarnom svijetu i inspiraciju potražiti u biološkim modelima. U *Brooks*-ovom modelu to je značilo kreaciju robota s određenim vještinama koristeći dostupne senzore i mehanizme za kretanje koji su međusobno neovisni. Zamisao je da AI mora biti testirana, kako kao teorija tako i tehnologija, u stvarnom svijetu i na stvarnim problemima, a pritom bi se učeći poboljšavala.[570] Prema *Brooks*-u iz 1991. inteligencija bez KR i inteligencija bez svjesnosti/razumijevanja predstavlja inteligenciju nastalu iz komunikacije s okolinom odnosno bihevioralnom robotikom.[571]

Iz toga su proizašle temeljne odrednice bihevioralnog pristupa istraživanju AI, a odnose se na:

- pozicioniranost, odnosno da su roboti smješteni u svijetu i svijet direktno utječe na bihevioralan aspekt robota,
- utjelovitost, odnosno da roboti imaju neki oblik tijela kojim osjećaju svoju okolinu, te
- inteligencija koja kao takva nije ograničena isključivo na strojeve.[572]

3.5. USKA, OPĆA UMJETNA INTELIGENCIJA I SUPER INTELIGENCIJA

Razdoblje razvoja i uporabe AI koje se odvija pred našim očima je ponekad i zbunjujuće. Značajan broj stručne i znanstvene literature nerijetko vodi ka zbunjenosti u moru različitih mišljenja. Predviđanje budućnosti razvoja AI i njene primjene vođeno idejom o

[569] Brachman, R., Gilbert, V., Levesque, H. (1985). An essential hybrid reasoning system: knowledge and symbol level accounts of KRYPTON, in: Proceedings HCAI-85, Los Angeles, CA
[570] Brooks, R. A. (1986). Achieving Artificial Intelligence through Building Robots, Massachusetts Inst Of Tech Cambridge Artificial Intelligence Lab. str. 1-2.
[571] Brooks, R. A. (1991). Intelligence without representation, Artificial intelligence, 47(1-3), str. 139-159.
[572] Kovač, L. (2015). Umjetna inteligencija danas, Filozofski fakultet Sveučilišta u Rijeci, str. 8.

eksponencijalnom razvoju takve tehnologije čini sve teže odrediti točnost dobivenih informacija. Definiranje AI predstavlja prvi korak u određivanju smjera razvoja, implementacije i utjecaja na društvo, a manjak postojanja jedinstvene definicije AI već govori o složenosti istraživačkog područja. Svjesni smo kako AI nije biološki „proizvod“ te je nužno da se sam izraz koristi u pravom kontekstu. Točnije, kako bismo mogli razumjeti što je AI i kako može utjecati na sebe, svijet ili društvo, nužno je napraviti distinkciju između vrsta AI.

3.5.1. USKA UMJETNA INTELIGENCIJA

Uska AI (engl. *Narrow Artificial Intelligence* - NAI) također poznata i kao „slaba“ AI je AI koja postoji u današnjem svijetu. Sustav AI definiran kao „uski“ je programiran za izvršavanje jednog zadatka - bilo da se radi o provjeri vremena, mogućnosti igranja šaha ili analiziranju određenog broja podataka za pisanje novinarskih izvještaja.[573] NAI kao takva je najčešće prisutna u stvarnom vremenu, ali rezultate koje pruža su plod velikog skupa podataka, a sustav sam po sebi ne izvršava niti jedan zadatak osim onog za kojeg je isprogramiran. Na taj način može se tvrditi da NAI nije svjesna, ne osjeća i nije inteligentna kao čovjek. NAI djeluje u unaprijed određenim uvjetima i ne izlazi izvan tih okvira. Samo jedan od primjera korištenja NAI u društvu su sustavi poput *Google Asistenta*, *Google Prevoditelja*, *Siri* i ostalih alata za obradu prirodnog jezika. Na prvi pogled rekli bismo da je riječ o jakim alatima koji koriste kompleksne algoritme kojima komuniciraju s korisnicima i obrađuju NLP. Primjerice, kada postavljamo određeni upit *Siri*, moramo biti upoznati da *Siri* nije svjesni stroj koji odgovara na naše upite. Umjesto toga, ono što je *Siri* u stanju učiniti jest obraditi ljudski jezik, unijeti ga u tražilicu i vratiti nam rezultate. Tako možemo dobiti odgovor od *Siri* na pitanje kakvo je vani vrijeme ili zadati joj određenu naredbu poput pozivanja neke osobe. *Siri*, kao i ostali virtualni pomoćnici, zahvaljujući ML i DL metodama može učiti, odnosno može kreirati uzorke našeg ponašanja kada koristimo uređaj.[574] Na taj način daje određena predviđanja po pitanju korištenja neke aplikacije ili podsjetnika za uzvraćanje propuštenog poziva, ali i mnogih drugih korisničkih postavki. Međutim, kada postavljamo apstraktna pitanja o stvarima poput smisla života ili kako pristupiti osobnom problemu alatima poput *Siri* ili *Google Asistenta*, dobivamo nejasne odgovore ili internetske poveznice do postojećih članaka koji se bave našim

[573] Kaplan, A., Haenlein, M. (2019). Siri, Siri, in my hand: Who’s the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence, Business Horizons, 62(1), str. 15-25.
[574] Page, J., Bain, M., Mukhlish, F. (2018.). The risks of low level narrow artificial intelligence. In 2018 IEEE International Conference on Intelligence and Safety for Robotics (ISR), IEEE, str. 1-6.

postavljenim pitanjima. Drugim riječima, nedostaje im samosvijesti, svijesti i prave inteligencije koja bi se podudarala s ljudskom inteligencijom i nemaju sposobnost kreativnog razmišljanja. Kao ljudi sposobni smo procijeniti svoju okolinu, biti živa bića i imati emocionalne reakcije na specifičnu situaciju. NAI koja postoji oko nas lišena je takve „mentalne fleksibilnosti“ i samim time je nazivamo „slabom“ AI. Čak se ni puno kompleksniji sustavi od *Siri* ili *Google Asistenta,* poput autonomnog vozila ili plovila ne mogu smatrati nečim većim od NAI, jer iako izvode zadaće koje su iznimno teške i dalje se sastoje od niza sustava koji su u domeni NAI.

Važno je napomenuti da iako postojeće sustave nazivamo „slabom“ AI ne bismo ih trebali uzimati zdravo za gotovo. NAI je zaista velik podvig u razvoju sustava AI ako po ničem drugom onda po činjenici da su sposobni obrađivati podatke i izvršavati zadatke znatno bržim tempom nego što to može bilo koje ljudsko biće, što nam je omogućilo da poboljšamo ukupnu produktivnost, učinkovitost i kvalitetu života. Može se tvrditi kako je imaginarni skup mogućnosti u raznim područjima koje omogućuje NAI impresivan i postaje sve bolji, a pogotovo u obradi podataka iz svog okruženja te razumijevanju i razlikovanju između onoga što čovjek govori i što čovjek želi.

3.5.2. OPĆA UMJETNA INTELIGENCIJA

Opća AI (engl. *General Artificial Intelligence* - GAI) ili „snažna“ AI odnosi se na strojeve koji pokazuju ljudsku inteligenciju, odnosno GAI može uspješno izvršiti bilo koji intelektualni zadatak koji ljudsko biće može s tim da se očekuje da GAI može rasuđivati, rješavati probleme, donositi prosudbe u nesigurnosti, planirati, učiti, integrirati predznanje u donošenju odluka i biti inovativna, maštovita i kreativna.[575] Međutim, da bi strojevi postigli istinsku inteligenciju po uzoru na čovjeka, trebat će biti sposobni iskusiti svijest. Najteži problemi za strojeve pokretane nekom vrstom AI neformalno su poznati kao "*AI-complete*" ili "*AI-hard*", što podrazumijeva da je njihovo rješavanje ekvivalent općoj sklonosti ljudske inteligencije ili „snažnoj“ AI, a izvan mogućnosti algoritma specifičnog za svrhu.[576] Pretpostavlja se da problemi s AI uključuju općeniti računalni vid, razumijevanje prirodnog jezika i rješavanje neočekivanih okolnosti tijekom rješavanja bilo kojeg problema iz stvarnog

[575] Goertzel, B. (2007). Artificial general intelligence (Vol. 2), Springer, New York
[576] Shapiro, S. C. (1992). Encyclopedia of Artificial Intelligence, Second Edition, str. 54–57.

svijeta.[577] Ukupni problemi vezani za AI ne mogu se riješiti samo trenutnom računalnom tehnologijom, već zahtijevaju i ljudska računanja. Ovo bi svojstvo moglo biti korisno, na primjer, za testiranje prisutnosti ljudi, kao što to čine *CAPTCHA*, a za računalnu sigurnost da se obrani od kibernetičkih napada.[578]

Istraživanje o GAI je izuzetno raznoliko i pomalo pionirsko. U uvodu svoje knjige *Goertzel*[579] kaže da procjene vremena potrebnog prije stvaranja uistinu fleksibilne GAI variraju od 10 do više od 100 godina, ali konsenzus u istraživačkoj zajednici je da je vremenski raspon u kojem možemo očekivati pravu upotrebu GAI između 2015. i 2045. vjerojatan.[580] Uz navedeno, važno je istaknuti da za razliku od NAI, GAI potiče i određena filozofska odnosno društvena pitanja poput razumijevanja takve AI i ljudske/strojne prirode kao i pitanja o poznavanju iste. Odgovori koji se u ovom trenutku pružaju su daleko od ujednačenih što će svakako rezultirati etičkim dvojbama o primjeni GAI.[581]

3.5.3. SUPER INTELIGENCIJA

Oxford-ski filozof *Nick Bostrom* super inteligenciju definira kao *"bilo koji intelekt koji uvelike premašuje kognitivne sposobnosti ljudi u gotovo svim područjima od interesa".*[582] Umjetna super inteligencija (engl. *Artificial Super Intelligence* - ASI) nadmašit će ljudsku inteligenciju u svim aspektima - od kreativnosti, opće mudrosti do rješavanja problema. Strojevi će moći pokazati inteligenciju koju nismo vidjeli među nama.[583] Ovo je vrsta AI zbog koje su mnogi ljudi zabrinuti i za koju mnogi misle da će dovesti do izumiranja ljudske rase. *Kurzweil* predviđa da ćemo do 2045. biti u stanju umnožiti svoju inteligenciju milijardu puta bežičnim povezivanjem našeg neokorteksa sa sintetičkim neokorteksom u „oblaku".[584] To će u osnovi prouzročiti spajanje ljudi i strojeva. Ideja proizašla iz toga objašnjava kako ne samo da ćemo

---

[577] Yampolskiy, R.V. (2013). Turing Test as a Defining Feature of AI-Completeness. In Artificial Intelligence, Evolutionary Computation and Metaheuristics (AIECM) --In the footsteps of Alan Turing, Springer, London, (Chapter 1), str. 3-17.
[578] Von Ahn, L., Blum, M., Hopper, N., Langford, J. (2003). CAPTCHA: Using Hard AI Problems for Security, the Wayback Machine, Proceedings of Eurocrypt, Vol. 2656, str. 294–311.
[579] Goertzel, B., Pennachin, C. (2006). Artificial General Intelligence, Springer
[580] Kurzweil, R. (2005). The Singularity is Near: When Humans Transcend Biology, A Penguin Book, str. 260.
[581] Stahl, C. B. (2021). Artificial Intelligence for a better future – An ecosystem perspective on the ethics of AI and emerging digital technologies, Springer, str. 12.
[582] Bostrom, N. (1998). How long before superintelligence?, University of Oxford, dostupno na: https://www.nickbostrom.com/superintelligence.html
[583] Gill, K. S. (2016). Artificial super intelligence: beyond rhetoric, Sociology, Computer Science, AI&Society, str. 138.
[584] Kurzweil, R., *op.cit.*

se moći povezati sa strojevima putem „oblaka“, već ćemo se moći povezati i s neokorteksom druge osobe. To bi moglo poboljšati cjelokupno ljudsko iskustvo i omogućiti nam otkrivanje različitih neistraženih aspekata čovječanstva. Iako smo desetljećima udaljeni od ASI, istraživači predviđaju da će skok s GAI na ASI biti kratak. Nitko zapravo ne zna kada će stići prvi živahan računalni oblik života, ali s obzirom na to da NAI postaje sve sofisticiranija i sposobnija, možemo početi zamišljati budućnost koju pokreću i strojevi i ljudi, u kojoj smo puno inteligentniji i svjesniji sebe. Tri stupnja razvoja AI prikazana su na slici 3-4.

Slika 3-4 Vrste AI s pripadajućim definicijama,

Izvor: Izradio autor

U vremenskoj analizi razvoja AI i onoga što je pred nama, AI se može svrstati u četiri razdoblja, odnosno u četiri vala razvoja AI koja su prikazana na slici 3-5.

Slika 3-5 Valovi razvoja AI,

Izvor: Izradio autor prema Six Kin Development, nadopunjeno s DARPA-inim 3 vala

Iako je konačni cilj istinskih strojeva za razmišljanje na ljudskoj razini još uvijek daleko, AI trećeg vala nam je dostupna ili bar pred vratima dok inteligenciju temeljenu na općoj AI možemo očekivati za svega nekoliko godina.

3.6. STROJEVI I MISAONI PROCESI

U pogledu zauzimanja filozofskog stajališta pri odgovoru na pitanje mogu li strojevi misliti, važno je nepristrano sagledati što se želi postići razvojem AI i na koji način bi se to napravilo. Iako ne možemo definitivno reći što je to AI, može se zauzeti stav u pogledu pitanja pokušava li AI kopirati ljudski mozak?! Nastavno na to, postavlja se pitanje kopiranja ljudskog mozga i implementacije istog u „tijelo“ robota ili nekog sličnog tehnološkog entiteta.[585] S druge strane, ako se uzme u obzir računalni oblik AI kao najčešća računalna simulacija nekog fizičkog procesa, *John Searle* je kazao kako je upravo ta računalna simulacija fizičkog procesa kao što je ljudski mozak vrlo različita stvar od procesa samog po sebi.[586] Drugim riječima, ako bi uspjeli u kreiranju umjetnog mozga od istog materijala koji postoji kod ljudi, približili bi se kreiranju

[585] Carter, M. (2007). Minds and Computers: An Introduction to the Philosophy of Artificial Intelligence Edinburgh University Press, str. 320.
[586] Searle, J. R. (1980). Minds, brains, and programs. The Turing Test: Verbal Behaviour as the Hallmark of Intelligence, str. 201-224.

istinske AI, iako je velika vjerojatnost da ipak to nikad neće biti isto. Činjenica je da će uvijek postojati razlike između biološkog entiteta i onog umjetno stvorenog, osobito kada u „jednadžbu“ uključimo i nepoznanice poput raznih bioloških bolesti kao *Alzheimer*, cerebralna paraliza i sl., ili ljude s različitim mentalnim mogućnostima i prirodnoj raznolikosti kao što su autisti i ostali. Također se mora imati na umu, na primjer, da neki ljudi imaju ograničen oblik komunikacije ili čak ne mogu komunicirati konvencionalnim načinom.

S druge pak strane, u pokušaju odgovora na pitanje mogu li strojevi misliti, važan faktor može imati i teza o nasumičnom razmišljanju.[587] Naime, jasno je kako strojevi djeluju mehanički, odnosno isprogramirani su u svom djelovanju i svaka naizgled nasumična radnja zapravo nije nasumična već rezultat već odrađene i unaprijed planirane radnje. Suprotno tome, smatra se da ljudi mogu razmišljati nasumice. Međutim, to nije nužno u cijelosti točno i moramo uzeti u obzir da su sve ljudske misli temeljene na genetskom sastavu našeg mozga i onome što smo naučili u svom životu odnosno prethodnim iskustvima.

Roger Penrose, matematičar i fizičar, kazao je kako u postavkama ljudskog mozga postoji velika količina slučajnosti.[588] To se teško može smatrati istinitom tezom jer je ljudski mozak izuzetno složena mreža povezanih moždanih stanica, ali veze su uspostavljene zbog biološkog rasta, dijelom prema uputama našeg genetskog sastava, a dijelom zbog iskustava u učenju koje fizički mijenjaju snagu veza te one mogu postati jače ili oslabjeti.[589] Ako je nešto kompleksno i nama teško za razumjeti ne znači da je slučajno. Za razliku od teorijskog pristupa velikog broja istraživača AI, *Alan Turing* je predstavio u svom radu *„Računalni strojevi i inteligencija“,* i test koji se može smatrati pandanom pitanju „mogu li strojevi misliti“. Imitacijska igra poznatija kao *Turingov* test predstavlja jedan od ključnih testova pri odgovoru na traženo pitanje.

3.6.1. TURINGOV TEST

Najveće filozofske rasprave o AI svode se na pitanje je li stroj inteligentan, odnosno može li misliti? Test koji bi trebao dati odgovor na to pitanje zove *Turingov* test. Ideja o testiranju strojne inteligencije je nastala prema načinu testiranja ljudske inteligencije u smislu postavljanja nekih pitanja ili razgovora o određenoj tematici na temelju čega bi se izvlačili

[587] Storrs Hall, J. (2007). Beyond AI: Creating the Conscience of the Machine, Prometheus Books
[588] Brighton, H., Selina, H. (2007). Introducing Artificial Intelligence, Icon Books
[589] Airhart, G. M. (2018). Learning Expands the Brain’s Capacity to Store Information, dostupno na: https://cns.utexas.edu/news/learning-expands-the-brain-s-capacity-to-store-information

zaključci.[590] Baš poput razgovora za posao i *Turingov* test u svom primarnom obliku izgleda na način da ispitivač sjeda za računalo s tipkovnicom, dok su s druge strane, skriveni od pogleda, računalni i ljudski ispitanici. Jedina dopuštena interakcija je komunikacija putem tipkovnice i monitora. Ispitivač ima pet minuta da s dva nepoznata entiteta razgovara o onome što želi. Na kraju ispitivanja ispitivač mora odlučiti koji ispitanik je čovjek, a koji računalo. Cilj računala je zavarati ispitivača, a najbolji rezultat za računalo bi bilo zavaravanje ne na način da se predstavi kao čovjek, već da ispadne više čovjek od čovjeka kojeg se također ispituje. *Alan Turing* je 1950. rekao: *„ Vjerujem da će za pedesetak godina biti moguće programirati računala ... natjerati ih da igraju imitacijsku igru tako dobro da prosječni ispitivač nakon pet minuta neće imati više od 70 % šanse za ispravnu identifikaciju ispitivanja".*[591] Drugim riječima, svaki treći ispitanik će pogriješiti u svojoj odluci. Može se stoga u jednom dijelu konstatirati kako test/računalni ispitanik pokušava zavarati ispitivača o prirodi ispitanika, međutim Turingov test ne odgovara na pitanje ima li stroj svijest, odnosno je li samosvjestan. Samim time, ključno je naglasiti nedoumicu koja proizlazi iz testa gdje računalni ispitanik eventualno zavara ljudskog ispitanika. Kao rezultat testa tada bi se moglo reći da stroj može misliti ili da razmišlja na sličan način kao čovjek. Međutim, postavlja se pitanje kako možemo tvrditi da čovjek misli i je li odgovor na to svijest čovjeka. Samim time, treba se uzeti u obzir i potencijalno drugačiji test koji je definirao nužne elemente u postavljanju pitanja kojima bi se utvrdila svjesnost stroja pa na taj način zaobilaznim putem došlo do odgovora na pitanje može li stroj misliti. [592] [593] [594]

3.6.2. KINESKA SOBA

Kineska soba predstavlja argument kojim se želi dokazati kako računalo/stroj ne može imati um, razumjeti ili biti svjesno bez obzira na to koliko njegovo određeno ponašanje može djelovati inteligentno. Kineska soba čiji je idejni začetnik *John Searle* tako postaje temeljni simbol filozofskog aspekta istraživanja AI.[595] Sami argument definira računalo koje prima kineske znakove kao ulaznu informaciju, potom slijede upute programa za kineski jezik i

[590] Saygin, A. P., Cicekli, I., Akman, V. (2000). Turing test: 50 years later. Minds and machines, 10(4), str. 463-518.
[591] Turing, A. (1950). Computing machinery and intelligence, (LIX) 236, str. 433–460
[592] *Ibid.*
[593] Storrs Hall, J., *op.cit.* This book looks at the history of AI and predicts future achievements.
[594] Carter, M., *op.cit.* This is an excellent next step in reading into the philosophy of AI – it considers the important philosophical issues in slightly greater depth.
[595] Warwick, K., *op.cit.*

reproducira se odgovor također na kineskom jeziku. Ujedno, vanjski dionik (čovjek) fizički ne vidi tko je u prostoriji i tko/što daje izlazne informacije. *John Searle* time hoće reći da računalo može vrlo jednostavno i s lakoćom uvjeriti čovjeka da odgovor dobiva od drugog ljudskog bića, a ne od računala, odnosno da razumije i priča kineski jezik čime se u teoriji uspješno prolazi Turingov test.[596] Možda se najbolji primjer za argument Kineske sobe navodi kroz slučaj čovjek – čovjek. Naime, u zatvorenoj sobi možete biti i Vi, osoba koja ne priča i ne razumije kineski jezik, ali imate knjigu s uputama na materinskom jeziku o tome kako obraditi informacije koje dobijete na kineskom te reproducirati odgovor također na kineskom jeziku. Velika je vjerojatnost da ćete uspješno savladati taj zadatak i vanjskog dionika uvjeriti da pišete i razumijete kineski jezik. Jedina razlika između Vas i računala jest ta što će računalo brže obraditi informacije i dati rezultat. Međutim, u osnovi između Vas i računala nema razlike te svatko od vas samo simulira inteligentno ponašanje. Na taj način možemo zaključiti kako se funkcija koju obavlja računalo ne može smatrati razmišljanjem i razumijevanjem čime se može odbaciti argument o GAI, ali i činjenica da samo pokretanje programa ne generira i razumijevanje.

3.6.3. SVIJEST STROJA

Nadovezujući se na argument Kineske sobe *John* Searle je postavio premisu kako čovjek ima nešto više od stroja, odnosno ima biološki mozak koji može naučiti kineski jezik te da se čovjekov um razvija i ostvaruje kroz tip mozga kojeg čovjek posjeduje.[597] *Searle* smatra da svijest i razumijevanje uzrokuju specifični neuronski procesi u mozgu koji su sami po sebi niže razine neuronskog djelovanja.[598] U kontekstu takve premise pitanje koje se postavlja odnosi se na moguću objašnjivost svijesti kroz prizmu individualnih neuronskih elemenata ili pak zbroja svojstava većeg broja neuronskih djelovanja.[599] Kako bi se upustili u tu raspravu nužno je poznavati rad mozga kao organa i njegovih neuronskih poveznica u stopostotnom dijelu. Jasno je kako se poznavanje rada mozga i dan danas ne zna u tolikom postotku što ne može proizvesti navedeni zaključak *Searla* o biološkoj objašnjivosti svijesti. Međutim, znamo kako funkcioniraju računala i može se zaključiti kako su strojevi podobni za simulaciju određenih

[596] Preston, J., Bishop, M. (2002). Views into the Chinese Room: New Essays on Searle and Artificial Intelligence, Oxford University Press, str. 3.
[597] *Ibid.*
[598] *Ibid*, str. 5.
[599] Gamez, D. (2008). Progress in machine consciousness, Consciousness and cognition, 17(3), str. 887-910.

mentalnih stanja čovjeka, ali simulacija takvih stanja nije više mentalno stanje nego što je računalna simulacija plovidbe sama po sebi plovidba. Ovakvim pristupom otvara se prostor za dodatna razmatranja. Kroz izneseni argument može se objasniti prvi koncept. Njime se može reći kako stroj nema svijest jer svijest nastaje kao rezultat određenog svojstva našeg mozga, a neurone kao dijelove tih svojstava je nemoguće simulirati u računalnim procesima. Sve i da znamo u stopostotnom dijelu kako funkcioniraju neuroni, računalna replika istih ne bi bila doslovno ista kao i biološki moždani reprezent istog tog neurona. Samim time, ostajemo uskraćeni za stvaranje „snažne“ AI, a dodatne razlike između ljudskog mozga i računalne replike su nešto na što se naziva i *Penrose* navodeći ih kao epifenomenalnim svojstvima.[600] Interdisciplinarnim pristupom forenzičkog inženjerstva može se u obzir uzeti činjenica prema kojoj čak i da se ljudski mozak može izmjeriti zajedno sa svojim svojstvima, i dalje će imati nešto više od računalnog mozga, odnosno nešto što čovjeka čini čovjekom i što se ne može mjeriti. Bez obzira na to koliko se računalo koristi u pokušaju kopiranja ljudskog mozga, ono nikada neće biti potpuno isto osim ako možda samo po sebi nije sastavljeno od ljudskih neurona i ne iskusi neke aspekte ljudskog života.

Searle je svoj argument o Kineskoj sobi koristio na više različitih načina. Rekao je da dok „*ljudi imaju uvjerenja, termostati i strojevi nemaju*“ ili "*ako cipela nije svjesna, kako onda računalo može biti svjesno?*"[601] Možda najvažniji aspekt ljudskog razumijevanja i razumijevanja svijesti koji se iz toga može zaključiti je da su to vjerojatna pojavna svojstva iz kolektivnog ponašanja ljudskih neurona.

3.6.4. ŠTO STROJEVI MOGU I NE MOGU ČINITI

Jedna od zanimljivih i vitalnih značajki koje se mogu naučiti iz proučavanja AI jest njezin potencijal ne samo da bude jednaka već da u nekoj fazi djelovanja nadmaši ljudsku inteligenciju. Početni argument kaže da je inteligencija ta koja je ljude dovela u njihov relativno moćan položaj na Zemlji, a ako se nađe nešto pametnije, to bi moglo predstavljati prijetnju ljudskoj dominaciji. Već sada strojevi nadmašuju ljude na brojne načine poput matematike, memorije, analize, brzine i sl. Možda je samo pitanje vremena kada će se pojaviti superiorni stroj koji tada može dizajnirati i proizvesti još više superiornih strojeva. Takav scenarij

[600] Warwick, K., *op.cit.*, str. 73.
[601] Searle, J. (1980). The Chinese Room, From: Minds, Brains and Programs, str. 2-3.

označavao bi tehnološku singularnost.[602] Točnije, *Vinge* je smatrao da će se kroz narednih 30 godina steći tehnološki uvjeti za stvaranje umjetne nadljudske inteligencije. *Moravec*[603] je, nadovezujući se na početni argument, rekao kako će se roboti podudarati s ljudskom inteligencijom, a za 50 godina će je premašiti čime će postati naša „*umna djeca*“.

Zbog ove potencijalne prijetnje neki se ljudi zanimljivo okreću (zbog sigurnosti) „Trima zakonima robotike“ koje je uveo pisac znanstvene fantastike *Isaac Asimov*, kao da imaju neku znanstvenu osnovu. Iako su ovi zakoni plod izvanredne mašte *Asimova*, u stručnoj literaturi su prihvaćeni kao strogi propisi kojih se roboti moraju pridržavati. Osim što to nije nikakav propis, nije vidljivo da je bilo koji robot iz stvarnog svijeta ikad radio prema tim pravilima. Zapravo, ako uzmemo u obzir mnoge današnje vojne robotske strojeve, oni otvoreno krše sva tri zakona u svojoj svakodnevnoj upotrebi. Europski parlament u pravilima građanskog prava o robotici iz 2017. je objasnio to na sljedeći način: „*Zakoni Asimova moraju se smatrati usmjerenima prema dizajnerima, proizvođačima i operaterima robota, uključujući robote kojima je dodijeljena ugrađena autonomija i samoučenje, jer se ti zakoni ne mogu pretvoriti u strojni kod*“.[604]

S druge pak strane, zbog potencijalnog gubitka nadzora nad strojevima od strane ljudi, kao sredstva za borbu protiv takve mogućnosti razni istraživači predložili su spajanje ljudi i tehnologije. *Kurzweil* je predvidio „*snažan trend spajanja ljudskog mišljenja sa svijetom strojne inteligencije*“ ukazujući nadalje da „*više neće postojati nikakva jasna razlika između ljudi i računala*“.[605] *Steven Hawking* je komentirao to na sljedeći način: *„Za razliku od našeg intelekta, računala udvostručuju performanse svakih 18 mjeseci. Stvarna je opasnost da bi mogli razviti inteligenciju i zavladati svijetom. Moramo razviti što je brže moguće tehnologije koje uspostavljaju izravnu vezu između mozga i računala*.“[606]

Istraživanje na tom području koje je predložio *Hawking* zapravo traje već neko vrijeme, dijelom u vezi s korištenjem takve tehnologije za pomoć osobama s invaliditetom. Međutim, pojavilo se i područje ljudskog poboljšanja, istražujući novi senzorni unos i nova

---

[602] Vinge, V. (1993). Techonlogical singularity, Whole Earth Review, dostupno na: https://frc.ri.cmu.edu/~hpm/book98/com.ch1/vinge.singularity.html
[603] Moravec, H. (1988). Mind Children, Harvard University Press, str. 6.
[604] Točka „T“ od European Parliament resolution of 16 February 2017 with recommendations to the Commission on Civil Law Rules on Robotics (2015/2103(INL))
[605] Kurzweil, R. (2000). The Age of Spiritual Machines: When Computers Exceed Human Intelligence, Penguin Putnam, str. 291.
[606] Više o tome na: https://www.smh.com.au/technology/the-cyborg-evolution-20030322-gdggw7.html

komunikacijska sredstva za ljude. Zapravo, može se reći da je počelo doba kiborga, dijelom čovjeka, dijelom stroja.

3.7. ETIČKE SMJERNICE ZA POUZDANU UMJETNU INTELIGENCIJU

U travnju 2019. godine HLEG je prezentirao Etičke smjernice s ciljem da se utvrde temelji pouzdane AI kao što su moralna i zakonska prava, etička načela, zahtjevi za pouzdanu AI, tehničke i ostale metode za ostvarenje iste te procjene pouzdane AI.[607] Samim time, ostvarivanje takvih ciljeva temeljeno je na premisi da sustavi AI trebaju biti usmjereni na i prema čovjeku, odnosno biti u službi ljudi i društva. Također, nužno je apostrofirati kako svaki sustav pruža određene prilike, ali biva izložen i određenim rizicima, pa tako i sustav AI. Prema navodima HLEG-a u ovom trenutku važno je pravilno usmjeriti razvoj takvih sustava kako bi se osiguralo povjerenje u socioekonomskoj okolini u koju su integrirani. Također, može se ustvrditi nastojanje maksimalnog povećanja koristi sustava AI uz istovremeno sprječavanje i smanjivanje rizika koje takvi sustavi predstavljaju za vrijeme svog životnog ciklusa. Smjernicama koje je izdala HLEG pokušavaju se pružiti generalne upute za primjenu AI te na taj način postaviti temelje za postizanje pouzdanosti kroz cijeli niz sektora. Jasno je kako različiti scenariji događaja i upotrebe AI širom različitih sektora mogu rezultirati dijametralno suprotnim ponašanjem sustava AI te nije moguće postaviti jasna pravila za sve sustave. Pri tome će se postavljati različita etička pitanja i dvoumice, ali nužno je postaviti etičke temelje koji bi bili univerzalno primjenjivi u cijeloj sektorski horizontalnoj strukturi.

Kao što je već rečeno, pouzdanost je preduvjet koji se mora ispuniti kako bi se sustavi AI postupno uvodili, razvijali i implementirali u svakodnevnicu osoba, poduzeća, pa i samo društvo. Pouzdanost sustava AI leži na tri ključna stupa:

- zakonitost i poštivanje svih primjenjivih zakona i propisa,
- etičnost i poštivanje etičkih načela i vrijednosti i
- otpornost u tehničkom i socijalnom smislu jer sustavi AI, čak i s dobrim namjerama, mogu uzrokovati nenamjernu štetu.[608]

Sva tri navedena elementa moraju biti ispunjena za vrijeme cijelog životnog ciklusa sustava AI kako bi se osigurala apsolutna pouzdanost.

[607] Etičke smjernice, str. 2.
[608] Točka A) st. 15. Etičkih smjernica

Zakonitost djelovanja sustava AI temelji se na nizu pravno obvezujućih regulativa na međunarodnoj i nacionalnoj razini. U tom smislu, obvezujuće pravne regulative mogu se svrstati u četiri skupine:

- pravni izvori koji uključuju primarno pravo EU (ugovori EU i njezina Povelja o temeljnim pravima, dalje u tekstu: Povelja),[609]
- sekundarno pravo EU (kao što su GDPR, Direktiva o strojevima,[610] Direktiva o odgovornosti za proizvode, Uredba o slobodnom protoku neosobnih podataka, Direktiva o sigurnosti i zdravlju radnika na radu[611]…),
- ugovori UN-a o ljudskim pravima i konvencije Vijeća Europe (kao što je Europska konvencija o zaštiti ljudskih prava i sloboda - EKLJP)[612] te nacionalna zakonodavstva država članica EU i
- sektorski specifična pravila koja se primjenjuju na određene primjene AI (Uredba o medicinskim proizvodima u sektoru zdravstvene zaštite,[613] Pravilnik o rukovanju opasnim tvarima, uvjetima i načinu obavljanja prijevoza u pomorskom prometu, ukrcavanja i iskrcavanja opasnih tvari, rasutog i ostalog tereta u lukama, te načinu sprječavanja širenja isteklih ulja u lukama,[614] Pravilnik o prijevozu opasnih tvari unutarnjim vodama,[615] Pravilnik o upravljanju i nadzoru balastnih voda[616] i sl.).

Važno je napomenuti kako pravni okviri predviđaju i pozitivne i negativne obveze, te je u stvaranju istih na nacionalnoj razini nužno voditi računa ne samo o onome što AI ne smije učiniti, već i ono što bi trebala učiniti. Za primjer se može navesti Povelja koja sadrži članke o

[609] Povelja EU o temeljnim pravima od 7.6.2016., C 202, str. 389.- 405.
[610] Direktiva 2006/42/EZ Europskog parlamenta i Vijeća od 17. svibnja 2006. o strojevima o izmjeni Direktive 95/16/EZ, OJ L 157. str. 24. - 86.
[611] Direktiva 89/391/EEZ Vijeća od 12. lipnja 1989. o uvođenju mjera za poticanje poboljšanja sigurnosti i zdravlja radnika na radu, OJ L 183, str. 1. - 8.
[612] Europska konvencija za zaštitu ljudskih prava i temeljnih sloboda (NN, MU, br. 18/97, 6/99, 14/02, 13/03, 9/05, 1/06, 2/10)
[613] Uredba (EU) 2017/745 Europskog Parlamenta i Vijeća od 5. travnja 2017. o medicinskim proizvodima, o izmjeni Direktive 2001/83/EZ, Uredbe (EZ) br. 178/2002 i Uredbe (EZ) br. 1223/2009 te o stavljanju izvan snage Direktiva Vijeća 90/385/EEZ i 93/42/EEZ, OJ L 117, str. 1. - 175.
[614] Pravilnik o rukovanju opasnim tvarima, uvjetima i načinu obavljanja prijevoza u pomorskom prometu, ukrcavanja i iskrcavanja opasnih tvari, rasutog i ostalog tereta u lukama, te načinu sprječavanja širenja isteklih ulja u lukama (NN, br. 51/05, 23/20)
[615] Pravilnik o prijevozu opasnih tvari unutarnjim vodama (NN, br. 106/08)
[616] Pravilnik o upravljanju i nadzoru balastnih voda (NN, br. 128/12)

slobodi poduzetništva[617] i slobodi umjetnosti i znanosti,[618] ali i članke o zaštiti podataka[619] i nediskriminaciji[620] koji moraju biti jedan od temelja u kreiranju pouzdane AI.

Nadalje, etičnost AI mora se osigurati kroz usklađenost s etičkim normama posebice iz razloga što zakonski okvir nerijetko ne prati tehnološki napredak. Djelovanje na etičkoj razini može i prije identificirati i barem moralno regulirati određena pitanja. S druge pak strane, nužno je osigurati i otpornost AI kako bi se izbjeglo nenamjerno prouzročenje štete. Sustavi AI bi trebali raditi na siguran, zaštićen i pouzdan način i važno je predvidjeti zaštitne mjere za sprječavanje negativnih učinaka. Otpornost sustava AI može se staviti u percepciju tehničkog i socijalnog djelovanja (osiguravanje tehničke otpornosti sustava u kontekstu područja primjene ili faze životnog ciklusa). Sukladno Smjernicama može se utvrditi kako su etičnost i otpornost AI usko povezani te se nadopunjuju što je prikazano na slici 3-6.

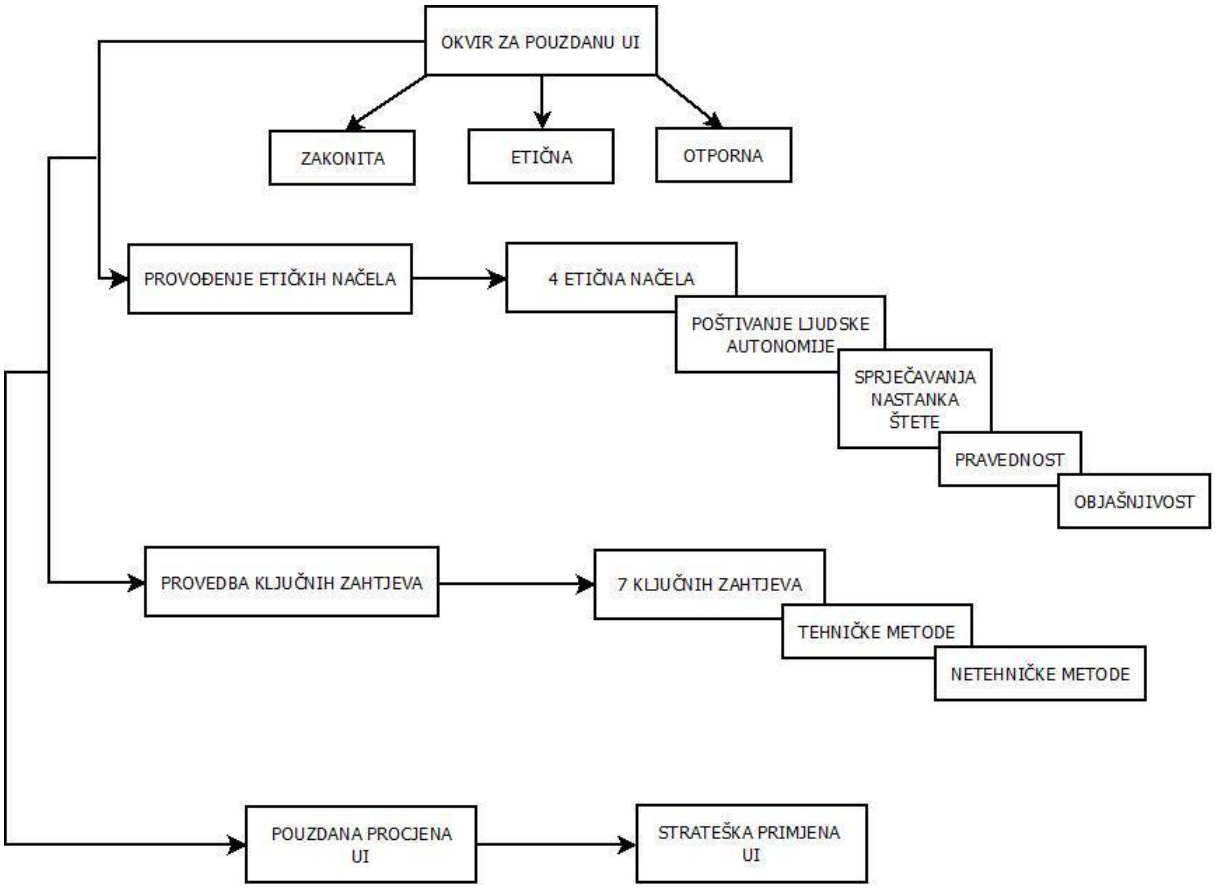

Slika 3-6 Struktura smjernica za pouzdanu AI,

[617] Čl. 16. Povelje
[618] Čl. 13. Povelje
[619] Čl. 8. Povelje
[620] Čl. 21. Povelje

Izvor: Izradio autor prema Smjernicama HLEG-a

U kontekstu osiguranja temeljnih prava kao preduvjeta za pouzdanu AI važno je istaknuti nekoliko ključnih elemenata poput:

- Poštivanje ljudskog dostojanstva u smislu pretpostavke da AI sa svim ljudima postupa s poštovanjem koje zaslužuju kao moralne osobe, a ne samo u obliku brojeva u određenim analizama. Sustave AI treba razvijati tako da se poštuje tjelesni i duhovni integritet ljudi, kao i ostali osjećaji identiteta (osobnih i kulturnih) te zadovoljenja svrhe, između ostalog, da ih se štiti i da im se služi.[621] U određenom smislu, potonje je usporedivo i s *Asimovljevim* zakonima robotike,[622] posebice prvim zakonom gdje se navodi da robot ne smije naškoditi čovjeku ili svojom pasivnošću dopustiti da se čovjeku naškodi.
- Osobna sloboda gdje osnovna premisa leži u činjenici da bi ljudi trebali zadržati slobodu da odlučuju sami za sebe, ali i vlastita suverenost te osiguranje pristupa AI svima kako bi se smanjio rizik od isključenosti.[623]
- Poštovanje demokracije, pravde i vladavine prava gdje bi sustavi AI služili u održavanju i poticanju demokratskih procesa poštivajući suživot različitih vrijednosti i životnih odabira pojedinaca.[624]
- Ravnopravnost, nediskriminacija i solidarnost.[625]
- Prava građana u smislu ostvarivanja građanskih prava poput biračkog prava, prava na dobru upravu ili pristup javnim dokumentima i sl. Sustavi AI pružaju veliku mogućnost za poboljšanje učinkovitosti javnih dobara i usluga društvu.[626]

Stoga je vidljivo da se pouzdanost sustava AI s etičkih polazišta mora temeljiti na četiri ključna etička načela, a to su: a) poštovanje ljudske autonomije, b) sprječavanje nastanka štete, c) pravednost i d) objašnjivost.

[621] Točka B) Poglavlje 1. točka 2. st. 41. Etičkih smjernica
[622] Anderson, S.L. (2011). The Unacceptability of Asimov's Three Laws of Robotics as a Basis for Machine Ethics, Cambridge University Press, str. 285-296. Anderson, M., Anderson, S.L., 2007, *op.cit.*
[623] Točka B) Poglavlje 1. točka 2. st. 42. Etičkih smjernica
[624] Točka B) Poglavlje 1. točka 2. st. 43. Etičkih smjernica
[625] Točka B) Poglavlje 1. točka 2. st. 44. Etičkih smjernica
[626] Točka B) Poglavlje 1. točka 2. st. 45. Etičkih smjernica

3.7.1. NAČELO LJUDSKE AUTONOMIJE

Poštivanje slobode i autonomije ljudskih bića spada u temeljna prava na kojima se temelji EU. Interakcija ljudi i AI mora rezultirati djelotvornom samoodređenju i sudjelovanju u procesu odlučivanja. Prema Smjernicama smatra se da sustavi AI ne bi trebali neopravdano podređivati, prisiljavati, zavaravati, uvjetovati i grupirati ljude ili manipulirati njima. Upravo suprotno, AI treba pozitivno djelovati na ljudske kognitivne, socijalne i kulturne vještine.[627]

Samim time, vidljivo je da projektiranje sustava AI mora biti usmjereno prema čovjeku i omogućavati priliku za ljudski odabir. To znači osiguravanje ljudskog nadzora nad radnim procesima AI.

3.7.2. NAČELO SPRJEČAVANJA NASTANKA ŠTETE

Sustavi AI ne bi trebali ni uzrokovati ni pogoršati štetu. Načelo sprječavanja nastanka štete podrazumijeva i zaštitu ljudskog dostojanstva. U Smjernicama HLEG smatra kako samim time i sustavi AI i okolina u kojoj oni djeluju moraju biti sigurni i zaštićeni. Posebna pažnja mora se posvetiti i situacijama u kojima AI može uzrokovati ili pogoršati negativne učinke zbog distinkcija u različitosti dostupnih informacija, npr. između poslodavaca i radnika, poduzeća i potrošača ili države i građana. U kontekstu načela sprječavanja štete u obzir bi se trebala uzimati i ostala živa bića kao i njihovo prirodno stanište, odnosno okoliš.[628]

3.7.3. NAČELO PRAVEDNOSTI

Razvoj, uvođenje i upotreba sustava AI moraju biti pravedni. Pravednost kao takva ima svoju materijalnu dimenziju. Materijalna dimenzija podrazumijeva obvezu poput ravnopravnosti u podjeli koristi i troškova ili pak da određeni pojedinci ili skupine ne budu pod utjecajem nepravedne pristranosti, diskriminacije i stigmatizacije. Ako bi se takvi elementi uspješno integrirali u sustave AI, rezultat bi mogla biti i veća pravednost u društvu bilo da je riječ o pristupu obrazovanju, uslugama, tehnologiji i sl. Uz navedeno, a u svrhu uravnoteženja interesa i ciljeva, HLEG smatra da je nužno integrirati i načelo proporcionalnosti sredstava i ciljeva.[629]

---

[627] Točka B) Poglavlje 1. točka 2. st. 50. Etičkih smjernica
[628] Točka B) Poglavlje 1. točka 2. st. 51. Etičkih smjernica
[629] Mjere koje se poduzimaju za ostvarivanje cilja (npr. mjere izvlačenje podataka koji se uvode za funkciju optimizacije AI) trebalo bi strogo ograničiti na ono što je nužno. To podrazumijeva i da se u slučaju u kojem se

Isto tako, kroz načelo pravednosti jako je važno osigurati mogućnost identifikacije subjekta odgovornog za odluku, a proces odlučivanja bi trebao biti objašnjiv. Ranjivim osobama trebala bi se posvetiti veća pažnja i trebalo bi ih uključiti u razvoj i uvođenje sustava AI.

3.7.4. NAČELO OBJAŠNJIVOSTI

Proces izgradnje povjerenja u sustav AI uvelike se oslanja i na proces/načelo objašnjivosti. Odluke se moraju moći objasniti osobama na koje one utječu izravno i neizravno naravno u mjeri u kojoj je to moguće. HLEG u Etičkim smjernicama uvodi i termin algoritama „crne kutije“ prema kojem neće uvijek biti moguće objasniti kako je nastao određeni rezultat ili posljedica određene odluke. Iz tog razloga navedeni su i ostali elementi koji mogu poboljšati mjere objašnjivosti kao npr. sljedivost, provjerljivost i transparentna komunikacija o mogućnostima sustava. Kada je riječ o stupnju objašnjivosti ili potrebe za istom, ona uvelike ovisi o kontekstu i ozbiljnosti posljedica ako se ispostavi da je došlo do pogrešnog navođenja ili krivog rezultata.[630]

U drugom poglavlju Etičkih smjernica HLEG-a pružaju se upute djelovanja za ostvarivanje pouzdane AI prema popisu od sedam zahtjeva (prikazano na slici 3-7) koje bi AI trebala ispuniti da bi je se implementiralo u sustave i društvo. Prema HLEG-u radi se o sljedećim zahtjevima:[631]

- ljudsko djelovanje i nadzor,
- tehnička otpornost i sigurnost,
- privatnost i upravljanje podacima,
- transparentnost,
- raznolikost, nediskriminacija i pravednost,
- dobrobit društva i okoliša i
- odgovornost.[632]

---

nekoliko mjera natječe za ostvarenje određenog cilja prednost treba dati mjeri koja je najmanje suprotstavljena temeljnim pravima i etičkim normama (npr. razvojni programeri AI prednost bi uvijek trebali dati podacima iz javnog sektora umjesto osobnim podacima). Može se uputiti i na proporcionalnost između korisnika i subjekta koji uvodi sustav, uzimajući u obzir prava poduzeća s jedne strane (uključujući intelektualno vlasništvo i povjerljivost) i prava korisnika s druge. Točka B) Poglavlje 1. točka 2. st. 52. Etičkih smjernica

[630] Kao primjer izdvojen je mogući slučaj netočne preporuke za kupnju koje daje sustav AI ne dovode do ozbiljnih etičkih pitanja, za razliku od sustava umjetne inteligencije koji procjenjuju trebali li pojedinca osuđenog za kazneno djelo uvjetno otpustiti. Točka B) Poglavlje 1. točka 2. st. 53. Etičkih smjernica

[631] Točka B) Poglavlje 2. st. 58. Etičkih smjernica

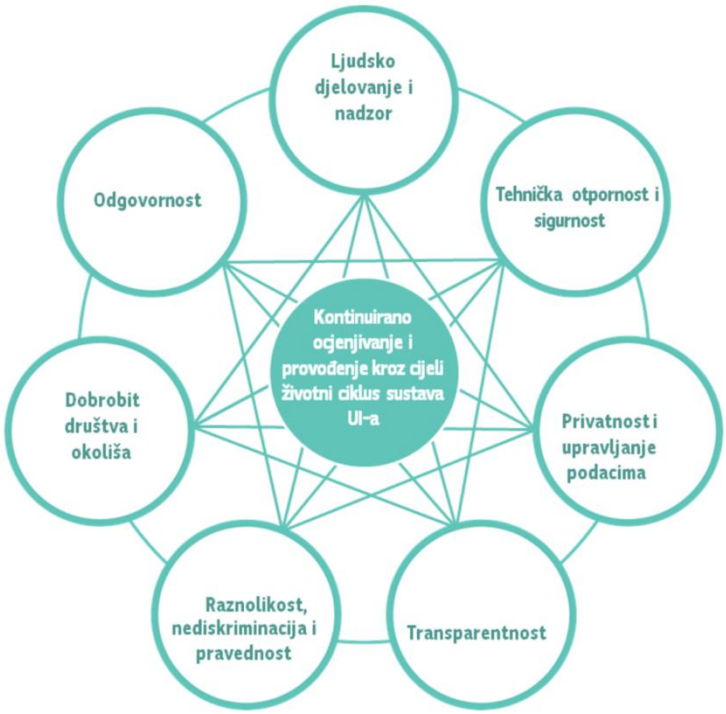

Slika 3-7 Međusobni odnosi sedam zahtjeva (važnost, podupiranje, procjena tijekom životnog ciklusa), Izvor: Etičke smjernice HLEG-a

Kontinuirano ocjenjivanje i provođenje navedenih zahtjeva dijelom se naslanjaju i na četiri ključna etička načela o poštovanju ljudske autonomije, sprječavanja nastanka štete, pravednosti i objašnjivosti te su međusobno povezana.

3.7.5. LJUDSKO DJELOVANJE I NADZOR

Zahtjevi za pouzdanu AI, između ostalog, sastoje se i od tri ključna elementa, a to su: temeljna prava, ljudsko djelovanje i ljudski nadzor. Kao što je navedeno i u ranijim dokumentima Komisije, sustavi AI u istoj mjeri mogu omogućavati i otežavati ostvarivanje temeljnih prava. Na istom primjeru poput prikupljanja osobnih podataka mogu pružiti korist na način da personaliziraju određene potrage i djelovanja, a otegotna okolnost može biti da vlasniku AI omogući zaradu eksploatirajući upravo najosobnije podatke. Stoga je u rizičnim situacijama nužno napraviti procjenu učinka sustava AI na temeljna prava te na taj način ih identificirati i prije samog razvoja smanjiti ili društveno opravdati. Samim time u smislu nadzora se trebaju uspostaviti mehanizmi o identifikaciji sustava AI koji možda narušavaju temeljna prava.[633] U kontekstu ljudskog djelovanja korisnici bi trebali moći donositi

[633] Točka B) Poglavlje 2. točka 1. st. 62., 63. Etičkih smjernica

informirane i autonomne odluke o sustavima AI. Kao i svaki proces odlučivanja, mora postojati određena razina znanja i razumijevanja koje se treba pružiti korisniku kako bi u interakciji s AI mogao donijeti razumnu i vlastitu odluku. Važan mehanizam u omogućavanju samostalnog ljudskog djelovanja je otklanjanje utjecaja na podsvjesne ljudske procese uključujući različite oblike nepravedne manipulacije, zavaravanja, grupiranja i uvjetovanja. Samim time, daje se zaključiti da načelo autonomije mora biti jedno od središnjih načela funkcije sustava AI oslanjajući se pritom i na čl. 22. GDPR-a gdje je to pravo i utvrđeno.[634] Kao što je već i navedeno, ljudski nadzor će igrati veliku ulogu u osiguravanju da sustav AI ne ugrozi ljudsku autonomiju ili izazove druge negativne učinke. Mehanizmi za ostvarivanje tih ciljeva HLEG u Etičkim smjernicama dijeli na: a) ljudsku intervenciju (engl. *human-in-the-loop* - HITL), b) ljudski nadzor (engl. *human-on-the-loop* - HOTL) i c) ljudsko odlučivanje (engl. *human-in-command* - HIC).[635] HITL se odnosi na mogućnost ljudske intervencije u svakom elementu odlučivanja sustava AI što najčešće nije moguće, a istovremeno nije ni dobro za AI jer time djelomično gubi svoju svrhu.[636] HOTL se odnosi na mogućnost ljudskog djelovanja pri projektiranju AI, dok se HIC odnosi na mogućnost nadzora ukupne aktivnosti sustava AI što uključuje i širi gospodarski, društveni, pravni i etički učinak, te kako navodi HLEG „*mogućnost odlučivanja o vremenu i načinu upotrebe sustava u određenoj situaciji*“.[637]

Međutim, važno je napomenuti kako je ovdje riječ o ljudskom nadzoru, ali treba razmisliti i iz toga se opravdano može predložiti razvoj sustava AI koji bi nadzirao sustav AI, a da se pritom ne ugroze značajke tehničkih otpornosti i sigurnosti.

3.7.6. TEHNIČKA OTPORNOST I SIGURNOST

Tehnička otpornost zahtijeva razvoj sustava AI na način da preventivno djeluje na potencijalne rizike kako bi se osigurala pouzdanost rada sustava. Na taj način umanjile bi se nenamjerne i neprihvatljive štete. Tehnička otpornost i sigurnost u svojoj srži se odnose na otpornost na napad i sigurnost, rezervni plan, točnost te pouzdanost i ponovljivost. Otpornošću na napad i sigurnost smatraju se oni elementi sustava AI (hardverski i softverski) koji moraju biti zaštićeni od ranjivosti zbog kojih ih protivnici mogu iskoristiti, npr. hakiranje. HLEG smatra da sustavi AI moraju imati zaštitne mjere, odnosno rezervne planove koji se aktiviraju

[634] Točka B) Poglavlje 2. točka 1. st. 64. Etičkih smjernica
[635] Točka B) Poglavlje 2. točka 1. st. 65. Etičkih smjernica
[636] *Ibid.*
[637] *Ibid.*

u slučaju potreba pa tako npr. AI može zatražiti od čovjeka nastavak rada i sebe isključiti iz procesa u kojem je ugrožena njezina samostalnost u odlučivanju od vanjskih, neželjenih faktora.[638]

Također, točnost je još jedan element tehničke otpornosti i sigurnosti, a odnosi se na sposobnost sustava AI da donese točne odluke ili procjene, primjerice da točno klasificira informacije u pripadajuće kategorije, pa čak i da donese određeno predviđanje ili preporuku temeljenu na podacima i modelima.[639]

Može se naposljetku tvrditi da su pouzdanost i ponovljivost važni kako bi se rezultati dostavljeni od AI mogli provjeriti, a postupak rekonstruirati. Važnost toga se očituje u preispitivanju sustava AI i sprječavanja nenamjerne štete.

3.7.7. PRIVATNOST I UPRAVLJANJE PODACIMA

AI mora moći jamčiti za sigurnost podataka. Korisničkim podacima se smatraju oni koje je korisnik samostalno i svjesno dao, ali i oni koje je AI generirala o korisniku pri procesu ML. Upravljanje osjetljivim podacima poput dobi, spola, spolnoj orijentaciji, političkim ili vjerskim stavovima moraju se koristiti samo i isključivo za dobro korisnika i ni na koji način ti podaci ne smiju biti zloupotrijebljeni. Isto tako, važno je da ti podaci nisu prikupljeni nezakonito te da ne generiraju diskriminatorna obilježja. Također, podaci u sustav AI mogu biti uneseni od trećih strana pri čemu takav postupak mora biti evidentiran i točan te nikako protiv suglasnosti krajnjeg korisnika. Jedino na taj način može se osigurati kvaliteta i cjelovitost podataka koje AI može koristiti u procesu ML.[640]

Stoga pristup osjetljivim podacima mora biti restriktivan te je nužno uspostaviti sigurne protokole za pristup informacijama.

[638] Točka B) Poglavlje 2. točka 2. st. 66., 67., 68. Etičkih smjernica
[639] Točka B) Poglavlje 2. točka 2. st. 69. Etičkih smjernica
[640] Točka B) Poglavlje 2. točka 3. st. 71. 72., 73., 74. Etičkih smjernica

3.7.8. TRANSPARENTNOST

Transparentnost se u kontekstu AI sastoji od sljedivosti, objašnjivosti i komunikaciji. Osim prva dva elementa koja su objašnjena i kroz druge prizme ključnih točaka, komunikacija je sastavni dio identifikacije sustava AI. Točnije rečeno, AI se mora predstaviti kao takva ako je korisnik od nje zatražio identifikaciju.[641]

Može se zaključiti da iako sustavi AI mogu djelovati kao ljudi, pokazivati kognitivne karakteristike ljudi, nužno je da se ne predstavljaju kao ljudi izazivajući tako zabludu kod korisnika.

3.7.9. RAZNOLIKOST, NEDISKRIMINACIJA, PRAVEDNOST

Navedeni elementi sa svojim pod-elementima kao što su izbjegavanje nepravedne pristranosti, dostupnost, univerzalni dizajn i sudjelovanje sudionika predstavlja još neke od temeljnih dijelova pouzdane AI. Sve navedene elemente sustav AI mora sadržati tijekom cijelog životnog ciklusa u kontekstu načela pravednosti koji je već naveden. U tom smislu, skupovi podataka koji se upotrebljavaju u sustavima AI za ML, DL i slične procese mogu uključivati nenamjerne naslijeđene pristranosti, mogu biti nepotpuni i uključivati loše modele upravljanja što je iznimno važno izbjeći.[642]

Može se podržati stav HLEG-a izražen u Etičkim smjernicama da je važno tražiti povratne informacije od korisnika za vrijeme i nakon uvođenja određenih mehanizama važnih za djelovanje AI.

3.7.10. DOBROBIT DRUŠTVA I OKOLIŠA

Održiva i ekološki prihvatljiva AI je nužnost u modernom svijetu. Ako se takav uvjet ne ispuni, povjerenje u sustave AI može biti poljuljano. Isto tako, sustavi AI imaju potencijala pridonijeti rješavanju velikog broja pitanja značajnih za društvo i društveno djelovanje, ali se to mora odvijati na ekološki prihvatljiv način.[643]

---

[641] Točka B) Poglavlje 2. točka 4. st. 75., 76., 77., 78. Etičkih smjernica
[642] Točka B) Poglavlje 2. točka 5. st. 79., 80., 81., 82. Etičkih smjernica
[643] Točka B) Poglavlje 2. točka 6. st. 83., 84., 85., 86. Etičkih smjernica

3.7.11. ODGOVORNOST

Odgovornost se sastoji od povjerljivosti, smanjenju negativnih učinaka i izvješćivanju o njima, kompromisima te pravnoj zaštiti. Provjerljivost podrazumijeva omogućivanje procjene algoritama, pristupa podataka i procesa projektiranja. Naravno, sustave AI treba prikladno zaštiti od kršenja prava intelektualnog vlasništva i od onih koji je žele kopirati i prilagoditi svojim poslovnim modelima. Nije nužno da izvorni kod sustava AI bude u otvorenom pristupu. HLEG smatra „*da mora biti dostupna odgovarajuća zaštita za zviždače, nevladine organizacije, sindikate ili druge subjekte kada prijave opravdane zabrinutosti u vezi sa sustavom koji se temelji na AI*“.[644]

Kada je riječ o kompromisu, u Etičkim smjernicama se navodi specifičnost situacija u kojima bi došlo do raskola pri usuglašavanju etičkih normi. Ako se ne može naći kompromis preporuča se obustava s daljnjim razvojem, uvođenjem i upotrebom sustava AI u tom obliku.[645] U postupku ispunjavanja zahtjeva za stvaranje pouzdane AI, smjernica HLEG-a je da se sami zahtjevi ugrade u arhitekturu sustava AI i to na način da se odrede ponašanja ili stanja sustava s popisa iz dva skupa pravila, tj. „bijela lista“ za ona ponašanja ili stanja koja bi sustav uvijek trebao poštovati, te skup pravila s „crne liste” koja se odnose na ponašanja ili stanja koja sustav nikada ne bi trebao prekršiti.[646] Izvan tih skupova bi trebao biti izdvojeni proces koji će provjeravati poštivanje zadanih skupova pravila. U Etičkim smjernicama HLEG izdvaja nekoliko puta važnost objašnjivosti AI te ističe izazov sustava AI koji se temelje na neuronskim mrežama. Ponekad spona između ML s neuronskim mrežama i parametara postavljenih na numeričke vrijednosti su teško povezivi ili ne povezivi s dobivenim rezultatima. Osim toga, i minimalne promjene u definiranim vrijednostima podataka ponekad mogu dovesti do velikih promjena u tumačenju. Tako primjerice autonomni sustavi u automobilima prilikom skeniranja drugog automobila na reklami uz cestu tumače to doslovno kao drugi automobil i poduzimaju mjere skretanja, usporavanja ili ponekad ubrzanja. Poznat je i primjer autonomnog pilotskog sustava u električnim automobilima poduzeća *Tesla* koji nije na vrijeme prepoznao promjenu cestovne trake već je produžio za starim, greškom ostavljenim cestovnim oznakama te udario u zid.[647]

---

[644] Točka B) Poglavlje 2. točka 7. st. 89. Etičkih smjernica
[645] Točka B) Poglavlje 2. točka 7. st. 90. Etičkih smjernica
[646] Točka B) Poglavlje 2. st. 95. Etičkih smjernica
[647] Patrascu, D. (2019). Video Shows Tesla Model S on Autopilot Hit Highway Concrete Divider, Autoevolution, dostupno na: https://www.autoevolution.com/news/video-shows-tesla-model-s-on-autopilot-hit-highway-concrete-divider-133275.html#

U kontekstu međunarodnog pomorskog prometa sustavi AI sastavni su dio autonomnih plovila koji će se koristiti u komercijalne svrhe. *Rolls-Royce* je u prosincu 2018. u suradnji s finskim državnim trajektnim poduzećem izveo prvo uspješno putovanje autonomnim trajektom oko grada *Turkua*. Uspješno je testirano u izbjegavanju sudara na moru, ali i automatsko privezivanje zahvaljujući novo razvijenom sustavu autonomne navigacije. IMO je dozvolila testiranja MASS u nekim područjima te specifičnim i vremenski ograničenim uvjetima. U Kineskom moru se testira prvi autonomni tanker koji može samostalno prevoziti veliku količinu tereta. S obzirom da takva vrsta plovidbe pomiče tehnološke granice, važno je ispitati sigurnost takvih sustava što uključuje podsustave kao optimizacije donošenja odluka AI, odrađivanje kompleksnih zadataka u konvencionalnim i nekonvencionalnim uvjetima i okruženjima, IoT i infrastrukture za prijenos podataka (5G mreže) kao i otpornost sustava na kibernetičke prijetnje i ugroze. Samim time, poduzeća ili organizacije moraju uvesti popis za procjenu pouzdane AI unutar svojih poslovnih djelovanja. U tom dijelu važno je definirati i unutarnju strukturu organizacije u smislu operativne i rukovodeće razine za AI. Prema Etičkim smjernicama HLEG-a uvođenje tog procesa bi bilo na sljedeći način:

Tablica 3-1 Unutarnja struktura organizacije za AI, Izvor: Etičke smjernice

Razina	**Relevantne uloge (ovisno o organizaciji)**
Rukovodstvo i upravni odbor	Najviše rukovodstvo raspravlja o razvoju, uvođenju ili nabavi AI i služi kao izvršni odbor za procjenu svih inovacija i upotreba AI kada se otkriju posebno problematična pitanja. Uključuje osobe na koje moguće uvođenje sustava AI utječe (npr. radnike) i njihove predstavnike putem postupaka informiranja, savjetovanja i sudjelovanja.
Odjel za usklađenost/pravni odjel/odjel za društveno odgovorno poslovanje	Odbor za odgovornost prati upotrebu popisa za procjenu i njegov razvoj koji je potreban kako bi se odgovorilo na tehnološke ili

	regulatorne promjene. Ažurira norme ili interne politike o sustavima AI i osigurava da upotreba tih sustava bude usklađena s trenutačnim pravnim i regulatornim okvirom i vrijednostima organizacije.
Odjel za razvoj proizvoda i usluga ili slično	Odjel za razvoj proizvoda i usluga upotrebljava popis za procjenu kako bi procijenio proizvode i usluge koje se temelje na AI te evidentira sve rezultate. O tim se rezultatima raspravlja na rukovodećoj razini koja naposljetku odobrava nove ili revidirane primjene koje se temelje na AI.
Osiguranje kvalitete	Odjel za osiguranje kvalitete (ili jednakovrijedan odjel) osigurava i provjerava rezultate popisa za procjenu i poduzima mjere za slanje pitanja višoj razini ako rezultat nije zadovoljavajući ili ako uoči nepredviđene rezultate.
Ljudski resursi	Odjel za ljudske resurse osigurava pravilnu kombinaciju kompetencija i raznolikost profila razvojnih programera za sustave AI. Osigurava odgovarajuću razinu osposobljavanja o pouzdanoj AI u organizaciji.
Nabava	Odjel za nabavu osigurava da u proces nabave proizvoda ili usluga koji se temelje na AI bude uključena provjera pouzdane AI.

Svakodnevni rad	Razvojni programeri i voditelji projekata uključuju popis za procjenu u svoj svakodnevni rad i evidentiraju rezultate i ishode procjene.

Sukladno navedenom, a radi slikovitog prikaza izrađena je i karta najnovijih zbivanja po pitanju etike i AI u svijetu što je prikazano na slici 3-8.

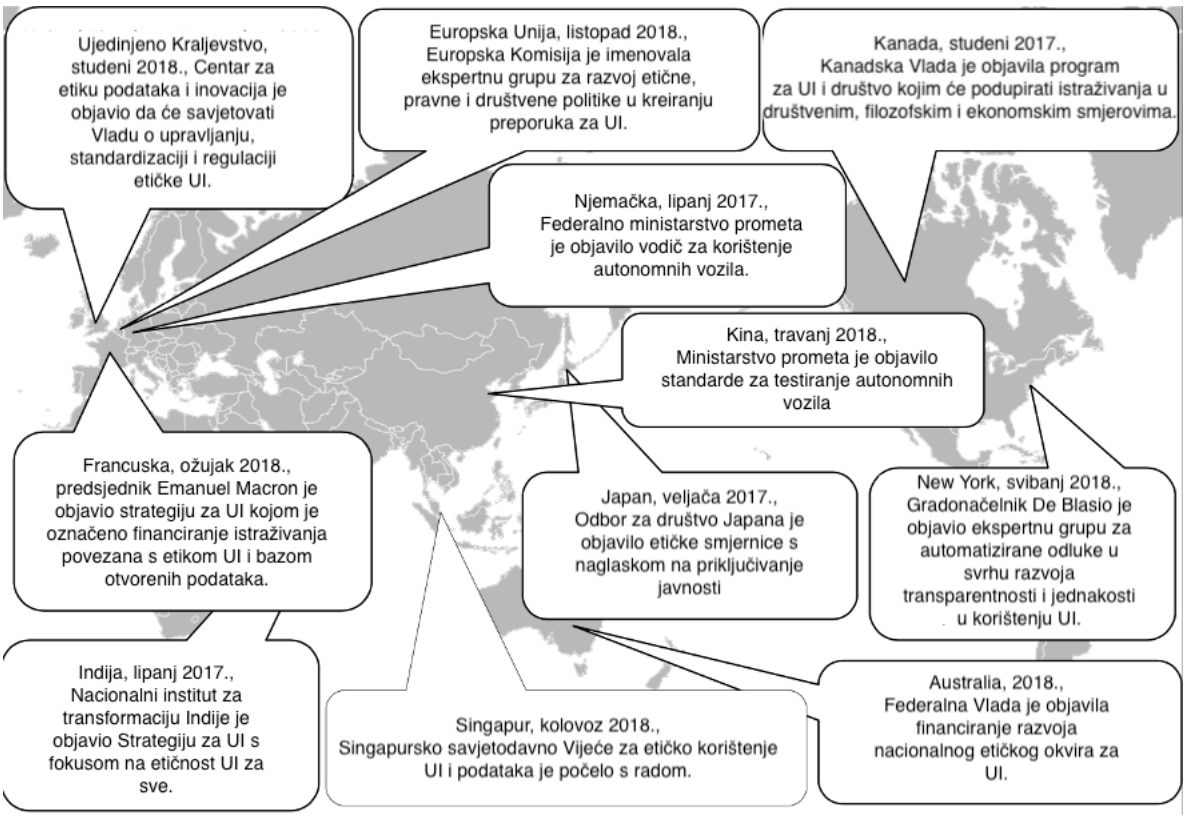

Slika 3-8 Karta najnovijih zbivanja u etici AI u svijetu

Izvor: Artificial Intelligence – Australia's Ethics Framework, 2019.

3.8. LJUDSKA PRAVA I UMJETNA INTELIGENCIJA

Utjecaj AI na ljudska prava i njezine moguće regulatorne implikacije na ista ogleda se u aktivnosti Vijeća europskih studija unutar kojeg je provedena studija o dimenzijama ljudskih prava automatiziranih tehnika obrade podataka (posebno algoritama) i njihove moguće

regulatorne implikacije.[648] Pri provedbi ove studije postavljana su sljedeća pitanja: koje su informacije dostupne korisnicima na njihovim *Facebook* profilima?; na temelju čega se utvrđuje profil rizika osobe i koji profili pružaju najbolje šanse za zdravstveno osiguranje, zaposlenje ili za potencijalnog kriminalca ili terorista? Tehnike automatizirane obrade podataka poput algoritama, korisnicima interneta ne samo da omogućuju traženje i pristup informacijama, već se sve više koriste u procesima donošenja odluka koji su prije bili u potpunosti u nadležnosti ljudi. Algoritmi se mogu koristiti za pripremu ljudskih odluka ili za njihovo donošenje automatiziranim procesima. Zapravo, granice između ljudskog i automatiziranog odlučivanja često su nejasne što rezultira pojmom „*kvazi ili poluautomatizirano odlučivanje*“.[649] Korištenje algoritama postavlja značajne izazove ne samo za određeno područje politike u kojoj se oni koriste, već i za društvo u cjelini. Pri tome se kao ključno postavlja pitanje kako zaštititi ljudska prava i ljudsko dostojanstvo pred tehnologijama koje se brzo mijenjaju? To utječe na pravo na život, pravo na pošteno suđenje i pretpostavku nevinosti, pravo na privatnost i slobodu izražavanja, prava radnika, pravo na slobodne izbore, čak i na samu vladavinu prava. Odgovor na izazove povezane s "algoritmima" koje koriste javni i privatni sektor, posebno internetske platforme, predstavlja aktualno sporno pitanje. Sve je veća percepcija da „softver jede svijet“,[650] jer ljudska bića osjećaju da nemaju kontrolu i ne razumiju tehničke sustave koji ih okružuju. To je nusproizvod ove faze suvremenog života u kojoj globalizirani ekonomski i tehnološki razvoj proizvodi velik broj softverskih tehničkih elemenata i "*kodiranih predmeta*"[651] i ugrađuje ih u ključne kapacitete za donošenje odluka relevantne za ljudska prava.

Koji odabir u djeliću sekunde treba napraviti vozilo vođeno softverom ako zna da će se sudariti? Je li rasna, etnička ili rodna pristranost vjerojatnija ili manje vjerojatna u automatiziranom sustavu? Da li se društvene nejednakosti samo preslikavaju ili pojačavaju automatiziranim tehnikama obrade podataka? Iako postoje okviri za razvoj sustava i procesa koji vode do algoritamskog donošenja odluka ili njihove provedbe, oni su još uvijek u ranoj

---

648 Study On The Human Rights Dimensions Of Automated Data Processing Techniques (In Particular Algorithms) And Possible Regulatory Implications, dostupno na: https://rm.coe.int/study-on-algorithmes-final-version/1680770cbc

649 Zilberstein, S. (2015). Building Strong Semi-Autonomous Systems, Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence, str. 4088.

650 Andreessen, M. (2011). Why Software Is Eating The World, Wall Street Journal, dostupno na: http://www.wsj.com/articles/SB10001424053111903480904576512250915629460

651 Kitchin, R., Dodge, M. (2011). Code/Space Software and Everyday Life, Cambridge, MA, MIT Press, str. 61.

fazi i obično se izričito ne bave problemima ljudskih prava. Zapravo je neizvjesno mogu li i u kojoj mjeri postojeći pravni koncepti na odgovarajući način obuhvatiti etičke izazove koje postavljaju algoritmi. Štoviše, nejasno je je li normativni okvir koji se odnosi na upotrebu algoritama ili učinkovitu regulaciju tehnika automatizirane obrade podataka uopće izvediv jer su mnoge tehnologije temeljene na algoritmima tek u povojima i potrebno je veće razumijevanje njihovih društvenih implikacija. Pitanja koja proizlaze iz upotrebe algoritama kao dijela procesa donošenja odluka su višestruka i složena. Istodobno, rasprava o algoritmima i njihovim mogućim posljedicama za pojedince, skupine i društva u ranoj je fazi. To, međutim, ne bi trebalo spriječiti napore u razumijevanju onoga što algoritmi zapravo rade, koje posljedice za društvo proizlaze iz njih i kako bi se mogli riješiti mogući problemi s ljudskim pravima. Izazovi povezani s utjecajem algoritama i tehnikama automatizirane obrade podataka na ljudska prava zasigurno će rasti kako sustavi postaju sve složeniji i međusobno komuniciraju. Provedena studija nema za cilj sveobuhvatno se baviti svim aspektima koji se odnose na utjecaje algoritama na ljudska prava, već nastoji mapirati neke od glavnih trenutnih problema iz perspektive ljudskih prava i sagledati moguće regulatorne mogućnosti koje države članice mogu implementirati o smanjenju štetnih učinaka ili promicanju dobrih praksi.

Pri uporabi pojma algoritam u kontekstu ljudskih prava i njihove implikacije na ljudska prava treba uzeti u obzir i one definicije koje su utvrđene, ali i to da se pojam algoritam široko primjenjuje i ima različita značenja, ovisno o tome u kojem se ambijentu koristi. U stvari, mnoge su rasprave o algoritmima manje usredotočene na same algoritme, a šire na ulogu tehnologije u društvu.[652] Osnovni pristup ove studije polazi od pretpostavke *Tarletona Gillespiea* da „*algoritmi ne moraju biti softverski: u najširem smislu, oni su kodirani postupci za pretvaranje ulaznih podataka u željeni izlaz, na temelju određenih izračuna. Postupci imenuju i problem i korake kojima ga treba riješiti*."[653] Algoritmi se stoga doživljavaju kao *„niz koraka poduzetih kako bi se riješio određeni problem ili postigao definirani ishod"*.[654] Stoga, u pogledu analize utjecaja algoritama na ljudska prava ista treba ograničiti na algoritme koji su digitalni i utječu na širu javnost, usredotočujući se tako uglavnom na algoritamsko odlučivanje koje ima implikacije na ljudska prava. Automatizacija je jedna od osnovnih karakteristika

[652] Bucher, T. (2016). The Algorithmic Imaginary: Exploring the Ordinary Affects of Facebook Algorithms, Information, Communication & Society, str. 1–15.
[653] Gillespie, T., The Relevance of Algorithms, str. 167–94. u: Gillespie, T., Boczkowski, P. J., Foot, K. A. (2014). Media technologies: Essays on communication, materiality, and society, Cambridge Mass, MIT Press, str. 167.
[654] Diakopoulos, N. (2015). Algorithmic Accountability, Digital Journalism 3(3), str. 400.

povezanih s algoritamskim odlučivanjem. Sposobnost automatiziranih računalnih sustava da zamjenjuju ljude u sve većem broju ključna je karakteristika praktične primjene algoritama. Razlozi za zamjenu ljudskih bića automatiziranim računalnim sustavima obično se mogu pratiti unatrag do pitanja velike obrade podataka, brzine, obujma i opsega odlučivanja, a u mnogim slučajevima i do očekivanja niže stope pogrešaka u usporedbi s ljudskim bićima. Iako je algoritamsko donošenje odluka sve vještije u zamjeni ljudskog odlučivanja, važni elementi (poput diskrecije) procesa donošenja odluka ne bi se smjeli automatizirati, ali često se izgube prilikom automatizacije ljudskih procesa donošenja odluka.[655] Bez prosuđivanja njihove "kvalitete" procesi donošenja odluka od strane ljudi i algoritama u osnovi su i kategorički različiti, čine različite pogreške i mogu imati različite ishode, a time i posljedice.

Ključ za promicanje poštivanja ljudskih prava u uporabi algoritama može biti razumijevanje onoga što algoritmi mogu, a što ne mogu postići i promišljanje o učinkovitosti ili djelotvornosti. Stoga, iako se čini logičnim napraviti razliku između potpuno automatiziranog odlučivanja i poluautomatiziranog odlučivanja, u praksi su granice između njih često nejasne. Treba napomenuti da algoritmi o kojima se raspravlja ne postoje smisleno bez interakcije s ljudima. Matematički ili računski konstrukti sami po sebi nemaju štetne učinke na ljudska prava, ali njihova primjena i primjena na ljudsku interakciju imaju. Tehnologije u svojoj primjeni na ljudsku interakciju duboko su društvene konstrukcije[656] sa značajnim političkim implikacijama.[657] Iako je softver za donošenje odluka možda pristran, ali ambivalentan[658] on nema značenje bez društvenog sustava oko sebe koji pruža značenje i utjecaj. Stoga je previše jednostavno kriviti algoritam ili sugerirati da se više ne pribjegava računalima ili računarstvu. Umjesto toga, socijalni konstrukt i posebne norme i vrijednosti ugrađene u algoritme trebaju biti propitivani, kritizirani i osporavani. Zapravo, nisu sami algoritmi već procesi donošenja odluka oko algoritama ti koji moraju biti pod nadzorom u smislu njihovog utjecaja na ljudska prava. Na pitanje razlikuje li se kvaliteta odluka u pogledu ljudskih prava između onih koje donose ljudi i onih koje donose ili se temelje na algoritamskom izračunu možemo odgovoriti samo ako znamo kako funkcionira donošenje ljudskih odluka što je iznimno složeno[659] s

[655] Spiekermann, S. (2015). Ethical IT Innovation: A Value-Based System Design Approach. CRC Press, str. 41.
[656] Winner, L. (1980). Do Artifacts Have Politics?, Daedalus; Winner, L. (1986). The Whale and the Reactor: A Search for Limits in an Age of High Technology
[657] Denardis, L. (2012). Hidden Levers of Internet Control'. Information, Communication & Society, str. 37–41.
[658] McCarthy, D. R. (2011). Open Networks and the Open Door: American Foreign Policy and the Narration of the Internet, Foreign Policy Analysis 7(1), str. 89–111.
[659] Tversky, A., Kahneman, D. (1974). Judgment under Uncertainty: Heuristics and Biases, Science 185(4157)

obzirom na upotrebu prešutnog znanja i prešutnih normi.[660] Zbog svega navedenog, UN potiču hitno donošenje akcijskog plana zbog potencijalnih rizika koje donosi upotreba AI u kontekstu ugroze ljudskih prava.[661]

3.8.1. PRAVO NA PRAVIČNO SUĐENJE

Raste trend primjene tehnika i algoritama automatizirane obrade u prevenciji kriminaliteta i kaznenopravnom sustavu. Upotreba AI može imati određene koristi jer se masivni skupovi podataka mogu brže obrađivati ili točnije procjenjivati. Štoviše, uporaba automatiziranih tehnika obrade za određivanje, primjerice, duljine zatvorske kazne može omogućiti ravnomjernije pristupe usporedivim slučajevima. Ipak, sve veća zabrinutost za nacionalnu sigurnost dovela je do sve ambicioznijih primjena novih tehnologija. Nakon niza terorističkih napada u SAD-u i Europi političari su pozvali mrežne platforme društvenih medija da koriste svoje algoritme za prepoznavanje potencijalnih terorista i da u skladu s tim poduzmu odgovarajuće mjere.[662] Neke takve platforme već koriste algoritme za prepoznavanje računa koji generiraju ekstremistički sadržaj. Osim značajnog utjecaja koji takva primjena algoritama ima na slobodu izražavanja, ona također izražava zabrinutost za standarde pravičnog suđenja sadržane u članku 6. EKLJP, posebno pretpostavku nevinosti, pravo na hitnu obavijest razloga i prirode optužbe, pravo na pravično suđenje i pravo na obranu. Zabrinutost se također može pojaviti u vezi s člankom 5. EKLJP koji štiti od proizvoljnog lišavanja slobode i člankom 7. koji propisuje da nitko ne može biti proglašen krivim za kazneno djelo koje u trenutku počinjenja nije bilo zakonodavno regulirano kao kazneno djelo. Na području prevencije kriminaliteta glavne političke rasprave u vezi s upotrebom algoritama odnose se na prediktivno policijsko djelovanje. Ovaj pristup nadilazi sposobnost ljudskih bića da donose zaključke iz prošlih kaznenih djela kako bi predvidjeli moguće buduće obrasce kriminaliteta te uključuje razvijene automatizirane sustave koji predviđaju koje će osobe vjerojatno biti upletene u kazneno djelo[663] ili će vjerojatno postati ponavljači kaznenih djela pa će zato biti ozbiljniji kandidati za izricanje kazne. Također, uključuje sustave namijenjene predviđanju počinjenja

[660] Schulz, W., Dankert, K. (2016). Governance by Things' as a Challenge to Regulation by Law, Internet Policy Review 5(2), str. 8.
[661] Više o tome vidjeti na: https://news.un.org/en/story/2021/09/1099972
[662] Rifkind, M. (2014). Report on the Intelligence Relating to the Murder of Fusilier Lee Rigby; The New York Times, Toor, A. (2016). Automated Systems Fight ISIS Propaganda, but at What Cost?, The Verge, dostupno na: http://www.theverge.com/2016/9/6/12811680/isis-propaganda-algorithm-facebook- twitter-google
[663] Perry, W. L., Mclnnis, B., Price, C.C., Smith, C.S., Hollywood, S.J. (2013). Predictive Policing: The Role of Crime Forecasting in Law Enforcement Operations, Rand Corporation, str. 13.

kaznenog djela, odnosno pretpostavke gdje i kada bi se moglo dogoditi određeno kazneno djelo. Takva saznanja mogu djelomično restrukturirati rad i generirati trenutne prioritete u radu policije i ostalih nadležnih tijela. Isto tako, pretpostavlja se da takvi pristupi mogu biti vrlo štetni u pogledu etničkog i rasnog porijekla i stoga bi zahtijevali pažljiv nadzor i odgovarajuće zaštitne mjere.

Često se sustavi temelje na postojećim policijskim bazama podataka koje namjerno ili nenamjerno odražavaju pristranost sustava. Ovisno o načinu evidentiranja kaznenih djela koja su odabrana da se uključe u analizu i na koja se analitički alati koriste, prediktivni algoritmi mogu tako pridonijeti prejudiciranom donošenju odluka i diskriminatornim ishodima. Uz to, postoji značajna zabrinutost zbog provođenja takvih procjena u kontekstu prevencije kriminaliteta koja će vjerojatno stvoriti odjeke unutar kojih već postojeće predrasude. Predrasude povezane, na primjer, s rasnom ili etničkom pripadnošću, policija možda neće prepoznati kao takve kada se integriraju u automatizirani računalni program koji se smatra neovisnim i neutralnim. Kao rezultat toga pristranost se može standardizirati i tada je manje vjerojatno da će biti identificirana i ispitana kao takva. U odnosu na kaznenopravne sustave, algoritmi predstavljaju ozbiljnu zabrinutost u odnosu na čl. 6. EKLJP odnosno pravo na pošteno suđenje koje je uspostavio Europski sud za ljudska prava (ESLJP)[664] gdje je nužno osigurati temeljna procesna prava optuženika i ugraditi ih u algoritamske procedure koje ni u kojem slučaju ne smiju biti prekršene. Nadalje, algoritmi se sve više koriste u sustavu građanskog i kaznenog pravosuđa u kojem se razvija AI da bi na kraju podržala ili zamijenila donošenje odluka od strane ljudskih sudaca. Takvi se sustavi trenutno ispituju kako bi se utvrdili ishodi donošenja odluka s ciljem otkrivanja obrazaca u složenom sudskom odlučivanju. Do sada je stopa pouzdanosti predviđanja sudskih odluka relativno niska i iznosi 75 %, a predviđanje pravnih stručnjaka još niža i iznosi 59,1 %.[665] Stoga se u ovom trenutku smatra preuranjenim zamišljanjem takvih sustava koji zamjenjuju suce. Ipak, predlaže se da takvi sustavi mogu podržati ili pomoći sucima. S obzirom na pritisak velikog broja slučajeva i nedovoljnih resursa zbog kojih većina pravosuđa pati, postoji opasnost da suci neprimjereno koriste sustave potpore temeljene na AI za "delegiranje" odluka na tehnološke sustave koji nisu razvijeni u tu svrhu i koji se smatraju "objektivnijima". Stoga treba biti vrlo oprezan kako bi se procijenilo što takvi

[664] Engl. *European Court of Human Rights*

[665] Više o istraživanju vidjeti na: https://www.americanbar.org/groups/judicial/publications/judges_journal/2020/winter/what-judges-and-lawyers-should-understand-about-artificial-intelligence-technology/

sustavi mogu pružiti i pod kojim se uvjetima mogu koristiti kako se ne bi ugrozilo pravo na pravično suđenje. To je osobito važno kada se takvi sustavi uvode obvezno, kao što je slučaj s odlukama o uvjetnom otpustu u SAD-u. Zabrinutost zbog pravosudne pristranosti oko odluka o uvjetnom otpustu dovela je do obveznog uvođenja softvera za predviđanje vjerojatnosti ponovnog počinjenja prijestupa u mnogim državama SAD-a. Međutim, u SAD-u je ustanovljeno da je softver koji se koristi za predviđanje budućih kriminalaca pristran prema Afroamerikancima.[666]

3.8.2. PRAVO NA PRIVATNOST I ZAŠTITU PODATAKA

Pravo na privatnost uvijek je bilo tema najžustrijih rasprava posebice u primjeni novih tehnologija poput AI, gdje algoritamska i automatizirana obrada podataka može utjecati na kršenje takvog prava.[667] S obzirom na to da algoritamski podržani programi prikupljaju i obrađuju znatne količine podataka, kako tekstualnih tako i slikovnih, moguća je ugroza prava na privatni i obiteljski život, uključujući pravo na zaštitu podataka, zajamčeno člankom 8. EKLJP. Algoritmi se koriste u internetskom praćenju i profiliranju pojedinaca čiji se obrasci pregledavanja bilježe „kolačićima“ i sličnim tehnologijama poput digitalnih otisaka prstiju agregiranih s upitima za pretraživanje (tražilice/virtualni asistenti). Štoviše, podaci o ponašanju obrađuju se s pametnih uređaja kao što su podaci o lokaciji i drugi podaci senzora putem aplikacija na mobilnim uređajima[668] što dovodi do sve većih izazova za privatnost i zaštitu podataka. Internetsko praćenje i profiliranje također se koriste u ciljanom oglašavanju na temelju profila pretpostavljenih interesa neke osobe. Ovdje je suglasnost korisnika važna regulatorna sastavnica. Istraživanje iz 2016. je utvrdilo, na primjer, da se upotreba privatno invazivnih tehnologija praćenja koje korisnici ne mogu promatrati (poput digitalnih otisaka prstiju i podataka o ponašanju koje generiraju senzori) povećala nakon veće svijesti potrošača i rastuće prakse o brisanju ili onemogućavanju kolačića kao dijela postavki izbora "ne prati" u internetskim preglednicima.[669] Štoviše, opsežna obrada podataka korištenjem algoritama može pogoršati kršenje drugih prava, jer se osobni podaci koriste za ciljanje pojedinaca, na primjer u

[666] Angwin, J., Mattu, S., Kirchner, L. (2016). Machine Bias: There’s Software Used Across the Country to Predict Future Criminals. And It’s Biased Against Blacks, ProPublica, dostupno na: https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing
[667] Sills, A. J. (1970). Automated Data Processing and the Issue of Privacy. Seton Hall Law Review 1
[668] Tene, O., Polonetsky, J. (2012). To Track or “Do Not Track”: Advancing Transparency and Individual Control, Online Behavioral Advertising, dostupno na: http://conservancy.umn.edu/handle/11299/155947
[669] Penney, W. J. (2016). Chilling effects: Online surveillance and wikipedia use. Berkely Technology Law Journal, Vol. 31:1., str. 122-123.

kontekstu zahtjeva za osiguranjem ili zapošljavanjem. Poseban izazov algoritamske obrade osobnih podataka je generiranje novih podataka. Kad subjekt podataka dijeli nekoliko diskretnih podataka često je moguće da se ti podaci spoje, generirajući drugu, pa čak i treću generaciju podataka o pojedincu. Dva bezazlena dijela podataka, kada se procjenjuju u usporedbi s mnogo većim skupom podataka, mogu se "razmnožavati" i generirati, čija priroda može biti potpuno nepredvidiva za subjekta podataka. To postavlja glavna pitanja za pojmove pristanka, transparentnosti i osobne autonomije.[670]

Regulatorni okvir za zaštitu pojedinaca u vezi s obradom osobnih podataka i o slobodnom kretanju takvih podataka na razini EU predstavlja GDPR.[671] Posebna zabrinutost proizlazi iz upotrebe posrednika podataka koji prikupljaju informacije sadržane u osobnim profilima. Profiliranje samo po sebi znači ekstrapolaciju podataka dostupnih na Internetu kroz procese automatiziranog prikupljanja informacija i naknadne izrade i primjene profila.[672] Tehnike profiliranja mogu koristiti pojedincima i društvu, na primjer, vodeći boljoj segmentaciji tržišta ili dopuštajući analizu rizika i prijevara. Ipak, postoje i važne zabrinutosti zbog upotrebe tehnike. Preporuka Vijeća Europe o profiliranju[673] bavi se rizikom da profili koji se pripisuju subjektu podataka omogućuju generiranje novih podataka, uključujući i agregiranje podataka. Te se informacije tada mogu iskopati uporabom algoritama, što stvara rizik od opsežnog nadzora („nadzor podataka“) od strane privatnih subjekata i vlada.[674] To stajalište ponavlja i Vijeće UN-a koje je 2018. sa zabrinutošću primijetilo „*da automatska obrada osobnih podataka za pojedinačno profiliranje može dovesti do diskriminacije ili odluka koje inače mogu utjecati na uživanje ljudskih prava, uključujući ekonomska, socijalna i kulturna prava*.“[675] Glavna briga korištenja podataka iz profila u različite svrhe kroz algoritme je ta da podaci gube svoj izvorni kontekst. Prenamjena podataka vjerojatno će utjecati na informacijsko samoodređenje osobe. Tražilice mogu imati sličan učinak na pravo na privatnost i zaštitu podataka jer također olakšavaju prikupljanje podataka o određenoj osobi. Korištenje podataka

---

[670] O razmjerima izazova vidjeti istraživanja sveučilišta *Cambridge* i *Stanford*, Stanford news, “New Stanford research finds computers are better judges of personality than friends and family”, dostupno na: http://news.stanford.edu/2015/01/12/personality-computer-knows-011215/

[671] Poglavlje 1. čl. 1. st. 1-3. GDPR-a

[672] Čl. 24., 63. i 64. GDPR-a

[673] Recommendation CM/Rec(2010)13 of the Committee of Ministers to member states on the protection of individuals with regard to automatic processing of personal data in the context of profiling

[674] Rubinstein, I., Lee, R. D., Schwartz, P. M. (2008). Data Mining and Internet Profiling: Emerging Regulatory and Technological Approaches. Rochester, NY, Social Science Research Network, dostupno na http://papers.ssrn.com/abstract=1116728

[675] Vidjeti Preambulu i Poglavlje 1. čl. 1. Convention for the Protection of Individuals with regard to Automatic Processing of Personal Data (ETS No. 108)

iz profila, uključujući one uspostavljene na temelju podataka prikupljenih algoritmima pretraživanja i tražilicama, izravno utječe na pravo na informacijsko samoodređenje osobe. Subjekt podataka obično neće biti svjestan samog profiliranja i naknadne prenamjene podataka izvan njihovog izvornog konteksta, olakšavajući pronalaženje informacija smanjenjem praktične nejasnoće anonimnih podataka. Uz to, rezultati dobiveni algoritmima pretraživanja mogu biti nepotpuni, netočni ili zastarjeli, čime se pojedinci stavljaju u iskrivljeno svjetlo, što može biti štetno. Takvi profili mogu imati osobito ozbiljne posljedice za djecu i njihovu budućnost. Sve je više dokaza da se podaci prikupljaju kako bi se stekli bihevioralni uvidi koji se mogu koristiti za ciljanje glasača i u konačnici čak i za manipulaciju izborima.[676]

Sljedeći ključni aspekt povezan s upotrebom algoritama za automatiziranu obradu podataka usredotočuje se na pohranu podataka u oblaku. To se odnosi na rješenja kojima se datoteke i drugi podaci više ne pohranjuju u lokalnu pohranu, već se pohranjuju na daljinu na poslužiteljima dostupnim putem Interneta. Takva automatizirana obrada podataka može se odvijati na dva mjesta:[677]

- u tranzitu do udaljenog mrežnog mjesta za pohranu i
- na udaljenim poslužiteljima gdje podaci se pohranjuju.

Korisnicima može biti sve teže utvrditi jesu li koristili lokalne ili udaljene usluge, kakvi postupno postaju moderni operativni sustavi dublje upleteni u udaljene usluge u „oblaku“. Što se tiče podataka u prijenosu, teško je utvrditi radi li se o dovoljno zaštićenoj tehnologiji kao što je snažna enkripcija i nije li njome manipulirano u nekom obliku.[678]

3.8.3. PRAVO NA SLOBODU IZRAŽAVANJA

Rad algoritama i tehnika obrade podataka ima ogromne učinke na pravo na slobodu izražavanja, što uključuje pravo na primanje i davanje informacija. Iako se opetovano govori o pozitivnim učincima algoritama pretraživanja i tražilicama na ljudsko pravo na slobodu izražavanja, sada se sve više raspravlja o njihovom potencijalu nanošenja štete slobodi

[676] Više o tome na: The Guardian, “The great British Brexit robberty: how our democracy was hijacked”, 7 May 2017, dostupno na: https://www.theguardian.com/technology/2017/may/07/the-great-british-brexit-robbery-hijacked-democracy

[677] Clay, K. (2012). Is Microsoft Spying On SkyDrive Users? Forbes, dostupno na: https://www.forbes.com/sites/kellyclay/2012/07/19/is-microsoft-spying-on-skydrive-users/?sh=206f86b2339c 2016 (http://www.forbes.com/sites/kellyclay/2012/07/19/is-microsoft-spying-onskydrive-users/)

[678] *Ibid.*

informacija i slobodi izražavanja pojedinaca, grupa i cijelih segmenata društva. Zabrinutosti se javljaju ne samo u vezi s pojedinačnim pravom na slobodu izražavanja, već i s obzirom na cilj članka 10. EKLJP stvaranja povoljnog okruženja za pluralističku javnu raspravu, koje je jednako dostupno i uključuje sve. Štoviše, gore navedeni problemi u vezi s privatnošću i zaštitom podataka mogu znatno spriječiti sposobnost pojedinaca da se slobodno izraze. Tražilice djeluju kao ključni vratari za ljudska bića koja žele tražiti, primati ili prenositi informacije. Sadržaj koji internetska tražilica nije indeksirala ili visoko rangirala manje je vjerojatno da će dosegnuti veliku publiku ili da će ga uopće vidjeti. Kao rezultat upotreba algoritama može dovesti do fragmentacije javne sfere i do stvaranja „odjeka s odabirom“ koji favoriziraju samo određene vrste vijesti, čime se povećavaju razine polarizacije u društvu koja može ozbiljno ugroziti socijalnu koheziju. Algoritam također može biti pristran prema određenim vrstama sadržaja ili pružateljima sadržaja, čime riskira da utječe na srodne vrijednosti poput pluralizma i raznolikosti medija. To je osobito slučaj u kontekstu dominantnih internetskih pretraživača.[679] Prema članku 10. EKLJP svaka mjera koja blokira pristup sadržaju filtriranjem ili uklanjanjem sadržaja mora biti propisana zakonom, slijediti jedan od legitimnih ciljeva predviđenih člankom 10.2. EKLJP i mora biti potrebna u demokratskom društvu. U skladu s jurisprudencijom ESLJP, svako ograničenje slobode izražavanja mora odgovarati "hitnoj društvenoj potrebi" i biti proporcionalno.[680] Međutim, uklanjanje sadržaja na platformama društvenih medija često se odvija poluautomatiziranim ili automatiziranim procesima. Algoritmi se široko koriste za procese filtriranja i uklanjanja sadržaja[681], uključujući na platformama društvenih mreža, izravno utječući na slobodu izražavanja i pobuđujući vladavinu zakona (pitanja zakonitosti, legitimiteta i proporcionalnosti). Iako velike platforme društvenih medija poput *Googlea* ili *Facebooka* često tvrde da ljudi uklanjaju sav sadržaj,[682]

---

[679] Pasquale, F. A. (2016). Platform Neutrality: Enhancing Freedom of Expression in Spheres of Private Power, Social Science Research Network, dostupno na: https://papers.ssrn.com/abstract=2779270

[680] U predmetu *Yildirim* protiv Turske od 18. ožujka 2013., br. 3111/10 ESLJP je naglasio da su „opasnosti svojstvene prethodnim ograničenjima takve da zahtijevaju najpažljivije ispitivanje Suda, (. .) jer je vijest kvarljiva roba i odgađanje njezina objavljivanja, čak i na kratko, može joj uskratiti svu vrijednost i interes “. Stoga je za blokiranje pristupa Internetu ili uklanjanje internetskog sadržaja potreban pravni okvir, „koji osigurava i strogu kontrolu nad opsegom zabrana i učinkovitu sudsku reviziju kako bi se spriječila bilo kakva zlouporaba ovlasti (..) U tom pogledu, sudska revizija takve mjera koja se temelji na vaganju konkurentskih interesa i čiji je cilj postići ravnotežu između njih nezamisliva je bez okvira koji uspostavlja precizna i posebna pravila u vezi s primjenom preventivnih ograničenja slobode izražavanja ”.

[681] Urban, J. M., Karaganis, J., Schofield, B. L. (2016). Notice and Takedown in Everyday Practice dostupno na: http://papers.ssrn.com/sol3/Papers.cfm?abstract_id=2755628

[682] Buni, C., Chemaly, C. (2016). The Secret Rules of the Internet, The Verge, dostupno na: http://www.theverge.com/2016/4/13/11387934/internet-moderator-history-youtube- facebook-reddit-censorship-free-speech

veliki dijelovi procesa su automatizirani[683] i temelje se na poluautomatiziranim procesima. Tako se u SAD-u administracija bivšeg predsjednika *Baracka Obame* zalagala za upotrebu automatiziranog otkrivanja i uklanjanja ekstremističkih videozapisa i slika.[684] Pored toga, bilo je prijedloga za izmjenu algoritama pretraživanja kako bi se "sakrile" web stranice koje bi poticale i podržavale ekstremizam. Automatski mehanizam filtriranja ekstremističkih videozapisa usvojili su *Facebook* i *YouTube* za videozapise. Međutim, nisu objavljene informacije o procesu niti o usvojenim kriterijima za utvrđivanje koji su videozapisi "ekstremistički" ili prikazuju očito ilegalni sadržaj.[685]

Nakon izvještaja londonskog *Timesa* i *Wall Street Journal*-a da su oglasi koji se pojavljuju na *YouTube* videozapisima takvi da podržavaju "ekstremizam" i "govor mržnje", *YouTube* je reagirao čvršćom upotrebom svog algoritma za otkrivanje neprikladnog sadržaja za oglašivače što je navodno utjecalo na neovisne medije.[686] Slične inicijative razvijene su u Europi, gdje su se posrednički pružatelji usluga kao odgovor na javni i politički pritisak obvezali na aktivno suprotstavljanje govoru mržnje putem automatiziranih tehnika koje otkrivaju i brišu sav ilegalni sadržaj. Iako ne osporavaju potrebu za učinkovitim suočavanjem s govorom mržnje, takvi aranžmani kritizirani su zbog delegiranja odgovornosti za provođenje zakona s državnih na privatna poduzeća, zbog stvaranja rizika od pretjeranog uplitanja u pravo na slobodu izražavanja i zbog nepridržavanja načela zakonitosti, proporcionalnosti i pravičnog postupka. Međutim, u kontekstu zaštite prava na slobodu izražavanja prema ESLJP svaka obveza filtriranja ili uklanjanja određenih vrsta komentara korisnika s mrežnih platformi stavlja "pretjerani i neizvedivi" teret na operatore i u određenoj mjeri obvezuje ih na korištenje sustava za praćenje koji može ograničiti pravo na prijenos informacija na Internet.[687]

---

[683] Wagner, B. (2016). Global Free Expression: Governing the Boundaries of Internet Content, Cham, Switzerland, Springer International Publishing

[684] Više o tome na: https://people.eecs.berkeley.edu/~russell/research/LAWS/President-Obama-letter-2016-04-04.pdf

[685] Više o tome vidjeti: Hess, A. (2017). How YouTube's Shifting Algorithms Hurt Independent Media, dostupno na: https://www.nytimes.com/2017/04/17/arts/youtube-broadcasters-algorithm-ads.html?_r=0

[686] *Ibid.*

[687] Više o tome: Draft Recommendation of the Committee of Ministers to Member States on the Roles and Responsibilities of Internet Intermediaries, on 19 September 2017, dostupno na: https://rm.coe.int/draft-recommendation-on-internet-intermediaries-version-4/1680759e

3.8.4. SLOBODA OKUPLJANJA I UDRUŽIVANJA

Internet, a osobito usluge društvenih mreža vitalni su alati za uživanje prava na slobodu okupljanja i udruživanja, nudeći mogućnosti za povećanje potencijala za sudjelovanje pojedinaca u političkom, društvenom i kulturnom životu. Sloboda pojedinaca da koriste internetske platforme poput društvenih medija, da osnivaju udruge i organiziraju se u svrhu mirnog okupljanja, uključujući prosvjed, u skladu je s člankom 11. EKLJP. Stoga, svako ograničenje prava na slobodu mirnog okupljanja i slobodu udruživanja mora biti propisano zakonom, mora težiti legitimnom cilju i biti neophodno u demokratskom društvu. Rad algoritama na platformama društvenih medija i ogromna količina dostupnih podataka o osobama koji se mogu identificirati mogu se naravno koristiti i za praćenje i identificiranje ljudi i mogu dovesti do automatskog razvrstavanja određenih pojedinaca ili grupa iz poziva za okupljanja, što bi moglo imati značajan negativan utjecaj na slobodu okupljanja. Profiliranje i nadzor gomile prosvjednika ne odvija se samo na Internetu, već se proteže i na izvan mrežne metode nadzora gomile podataka. Teoretski, algoritmi koji se koriste za predviđanje mogućih sukoba i prosvjednih situacija također se mogu koristiti kao preventivni alat za sprječavanje demonstracija ili prosvjeda uhićenjem određenih pojedinaca prije nego što se i okupe.[688]

3.8.5. PRAVO NA DJELOTVORAN PRAVNI LIJEK

Članak 13. EKLJP propisuje da će svatko čija su prava povrijeđena imati djelotvoran pravni lijek pred nacionalnim vlastima.[689] Dostupni pravni lijek trebao bi biti učinkovit u praksi, odnosno pojedinci imaju pristup sudskim ili ostalim postupcima u kojima se nepristrano odlučuje o njihovim zahtjevima u vezi s kršenjem ljudskih prava na mreži, uključujući izvansudsko rješavanje sporova, administrativna ili druga sredstva za traženje pravnog lijeka, primjerice putem nacionalnih institucija za ljudska prava. Stoga, države moraju poduzeti odgovarajuće korake kako bi osigurale zaštitu od kršenja ljudskih prava, uključujući i aktere privatnog sektora. To uključuje osiguravanje da akteri iz privatnog sektora poštuju ljudska prava tijekom svog poslovanja, posebno uspostavljanjem učinkovitih mehanizama za pritužbe koji odmah ispravljaju pritužbe pojedinaca. Automatizirani procesi donošenja odluka

[688] Vidjeti: De Chant, T. (2014). The Inevitability of Predicting the Future, NOVA, dostupno na: http://www.pbs.org/wgbh/nova/next/tech/predicting-the-future/
[689] Čl. 13.1. EKLJP

prepuštaju se posebnim izazovima u odnosu na sposobnost pojedinca da pristane na donošenje takve odluke, odnosno samo shvaćanje o uporabi svojih podataka prilikom donošenja odluke. Priroda odluka koje se donose automatski, bez ili sa malo ljudske uloge i s primatom na učinkovitost, a ne na ljudsko-kontekstualno razmišljanje, znači da organizacije koje koriste takve sustave imaju još veći teret kako bi pogođenim pojedincima omogućile stjecanje prava na djelotvoran pravni lijek. Sve veći broj poduzeća, posebno većih, koristi algoritme i automatizirane tehnike obrade podataka za vođenje svojih postupaka po prigovorima. U kontekstu automatiziranih postupaka uklanjanja sadržaja na platformama društvenih medija, upotreba algoritama posebno je očita u odgovorima koje različite vrste sadržaja primaju i kako se sadržaju daje prednost, postupak koji je očito automatiziran. Isto vrijedi i za prag žalbi korisnika koji je potreban prije pregleda dijela sadržaja. Često će se mnogi korisnici morati žaliti na određenu vrstu sadržaja prije nego što ga automatizirani algoritam prepozna kao relevantan za upućivanje na ljudskog operatera radi pregleda sadržaja. Pri tom operatori često rade pod znatnim vremenskim pritiskom i uz minimalne upute u skladu s internim „pravilima brisanja“.[690]

Pravo na djelotvorni pravni lijek podrazumijeva pravo na obrazloženu odluku. Povijesno gledano, sve su takve odluke donosila ljudska bića kojima su u izvršavanju njihovih funkcija na temelju sveobuhvatne obuke i u skladu s primjenjivim procesima donošenja odluka dana diskrecijska prava. U načelu je zadatak suca da u skladu s pravnim propisima i sudskom praksom odluči kako će uravnoteženje pojedinačnih prava poput slobode izražavanja i zaštite od nasilja provesti u praksi. Odluka se mora temeljiti na pažljivoj analizi specifičnog konteksta, uzimajući u obzir "hladni učinak" koji bi smetnja mogla podrazumijevati i uzimajući u obzir proporcionalnost smetnji. Danas su, međutim, sve više algoritamske tehnike obrade podataka koje pripremaju i utječu na donošenje odluka u žalbenim postupcima.[691] Uz to, postoje ozbiljne rasprave jesu li postupci automatskog reagiranja na pritužbe učinkovit pravni lijek.

[690] Više o tome vidjeti na: Krause, T., Grassegger, H. Inside Facebook, Süddeutsche Zeitung, dostupno na: http://international.sueddeutsche.de/post/154513473995/inside-facebook

[691] Goodman, B., Flaxman, S. (2016). EU regulations on algorithmic decision-making and a “right to explanation”, ICML workshop on human interpretability in machine learning (WHI 2016), New York, NY, dostupno na: http://arxiv. org/abs/1606.08813 v1.

3.8.6. ZABRANA DISKRIMINACIJE

Sljedeće ključno ljudsko pravo koje se često navodi u vezi s radom algoritama i drugim automatiziranim tehnikama obrade je pravo na uživanje ljudskih prava i temeljnih sloboda bez diskriminacije. U pogledu brzine i količine obrađenih podataka, algoritamsko odlučivanje može imati značajne prednosti u odnosu na određene vrste ljudskog odlučivanja. Međutim, algoritmi mogu imati ugrađene predrasude koje će biti teško otkriti i/ili ispraviti.[692] To je osobito slučaj kada pojedinačne varijable u algoritmima BD služe kao „zamjenici" za zaštićene kategorije kao što su rasa, spol ili dob. Algoritam može odlučiti diskriminirati skupinu korisnika koja korelira na 80 %, 90 %, 95 % ili čak 99 % s varijablom poput rase, spola ili dobi, a da to ne čini 100 %. Algoritmi pretraživanja i tražilice po definiciji ne tretiraju sve informacije jednako. Iako se procesi koji se koriste za odabir i indeksiranje podataka mogu dosljedno primjenjivati, rezultati pretraživanja obično se rangiraju prema percipiranoj relevantnosti. Tražilice i algoritmi pretraživanja također ne tretiraju sve korisnike jednako. Različitim se korisnicima mogu predstaviti različiti rezultati na osnovu ponašanja ili drugih profila, uključujući profile osobnih rizika koji se mogu razviti u svrhu osiguranja ili kreditno bodovanje ili općenito za različite cijene, tj. nuđenje različitih cijena za iste robe ili usluge različitim potrošačima na temelju njihovog profila. Pristrani algoritam koji sustavno diskriminira jednu skupinu u društvu, na primjer na temelju njihove dobi, seksualne orijentacije, rase, spola ili socio-ekonomskog položaja, može izazvati znatne probleme ne samo u pogledu pristupa pravima pojedinih krajnjih korisnika ili kupaca na koje utječu ove odluke, nego i za društvo u cjelini. Neki su autori čak sugerirali da će internetske usluge koje koriste personalizirane sustave ocjenjivanja same po sebi vjerojatno dovesti do diskriminacijske prakse.[693] U teoriji, algoritmi bi mogli biti korisni alati za smanjenje pristranosti na mjestima gdje je to uobičajeno, poput procesa zapošljavanja. Ipak, stručna javnost upozorava da automatizacija i ML mogu ojačati postojeće pristranosti jer za razliku od ljudi algoritmi mogu biti neopremljeni za svjesno suzbijanje naučenih pristranosti.

[692] Sandvig, C., Hamilton, K., Langbort, K, C. (2016). When the Algorithm Itself Is a Racist: Diagnosing Ethical Harm in the Basic Components of Software, International Journal of Communication, str. 10-19.
[693] Rosenblat, A., Levy, K., Barocas, S., Hwang, T. (2016). Discriminating Tastes: Customer Ratings as Vehicles for Bias, SSRN, dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2858946

3.8.7. SOCIJALNA PRAVA I PRISTUP JAVNIM USLUGAMA

Radni odnosi predstavljaju još jedan sektor u kojem je automatizirano donošenje odluka sve češće posljednjih godina. Algoritmi mogu biti uključeni u odluke o zapošljavanju i otpuštanju osoblja, organizaciji i upravljanju osobljem, kao i pojedinačnim procjenama zaposlenika. Kako se sve više poduzeća kreće prema algoritamskim metodama zapošljavanja[694] pojavili su se novi problemi povezani s nedostatkom transparentnosti u odlukama koje donose kako u procesu zapošljavanja tako i šire. Štoviše, mnogi od takvih automatiziranih procesa donošenja odluka temelje se na podacima primljenim putem internetskih platformi. Dopuštanje „mudrosti gomile“ da donosi odluke o zapošljavanju pojedinaca ne samo da je vrlo upitno s etičkog stajališta, već također ograničava sposobnost radnika da ospore takve odluke.[695]

Kako se sve više sustava automatizira, a sve više podataka prikuplja na radnom mjestu, prava zaposlenika su prema članku 8. EKLJP u opasnosti čak i ako nisu izravno ciljana općim mjerama prikupljanja podataka. Osim toga, postoje i dodatni izazovi povezani s korištenjem algoritama i od javnog i od privatnog sektora za praćenje komunikacije s osobljem ili za provođenje internih „rangiranja“ zaposlenika koji možda nisu dio formalnog postupka ocjenjivanja, ali možda su odlučniji u pogledu individualnih prilika za karijeru.[696]

3.8.8. PRAVO NA SLOBODNE IZBORE

Rad algoritama i automatiziranih sustava preporuka koji mogu stvoriti tzv. „*filter bubbles*“ odnosno potpuno automatizirane odjeljke u kojima pojedinci vide samo dijelove podataka kojima potvrđuju vlastito mišljenje ili se podudaraju s njihovim profilom,[697] mogu imati značajne učinke za demokratske procese u društvu. Iako se od pojave interneta tvrdi da će mrežne kampanje i mreže društvenih medija vjerojatno promijeniti način na koji se vode politike i izbori, tek je nedavno akademsko istraživanje otkrilo u kojoj mjeri manipulacija internetskog sadržaja na platformama društvenih medija može "najaviti" izbore. Tako neka

---

[694] Rosenblat, A., Kneese, T., Boyd, D. (2014). Networked Employment Discrimination, Open Society Foundations, Future of Work Commissioned Research, dostupno na: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2543507

[695] Tufekci, Z., York, J. C., Wagner, B., Kaltheuner, F. (2015). The Ethics of Algorithms: From Radical Content to Self-Driving Cars, European University Viadrina, dostupno na: https://cihr.eu/publication-the-ethics-of-algorithms/

[696] Voorhoof, D., Humblet, P. (2013.) The Right to Freedom of Expression in the Workplace under Article 10 ECHR, Oxford: Hart Publishing, str. 183–208.

[697] Bozdag, E. (2013). Bias in Algorithmic Filtering and Personalization, Ethics and Information Technology 15(3), 2013, str. 209–227.

istraživanja sugeriraju da na izborima ne mogu pobijediti kandidati s najboljim političkim argumentima već oni koji koriste najučinkovitiju tehnologiju za manipulaciju.[698] Iako je političko oglašavanje na televiziji danas regulirano i postoji nepristranost nametnuta javnim radiotelevizijama, ne postoje takvi ekvivalenti za upotrebu algoritamskih predviđanja preferencija i ponašanja birača koji bi mogli imati jednak, ako ne i snažniji utjecaj na glasače. U tom kontekstu se raspravljalo o posebnoj ulozi koju socijalni botovi igraju u oblikovanju političke i javne rasprave pred izbore, posebno u kontekstu američkih izbora 2016. i referenduma o *Brexitu*. Društveni botovi algoritamski su kontrolirani računi koji oponašaju aktivnost ljudskih korisnika, ali djeluju mnogo većim tempom (npr. automatski proizvode sadržaj ili sudjeluju u društvenim interakcijama), a istovremeno uspješno drže neotkrivenim njihov umjetni identitet.[699] Istraživanje u kojoj je mjeri prisutnost botova na društvenim mrežama utjecala na političku raspravu oko američkih predsjedničkih izbora 2016. godine sugerira da to može negativno utjecati na demokratsku političku raspravu, a ne na njezino poboljšanje, što zauzvrat može potencijalno promijeniti javno mnijenje i ugroziti ga.[700]

3.9. HUMANOIDNA UMJETNA INTELIGENCIJA

Humanoidni robot je robot koji oblikom tijela izgleda kao čovjek, tj. liči na ljudsko biće.[701] Dizajn može biti radi funkcionalnih razloga kao što su interakcija s ljudskim alatima i okolinom, zbog eksperimentalnih razloga kao što je studija o lokomotornom (pokretnom) sustavu ili zbog drugih razloga. Općenito, humanoidni roboti imaju trup, glavu, dvije ruke, dvije noge, iako neki oblici imaju oblikovan samo dio od sredina trupa prema gore. Neki imaju dizajnirane glave tako da što više sliče ljudskima, pa imaju i oči i usta. Uloga humanoidnih robota u društvu je višestruka. Humanoidni roboti koriste se za razna istraživanja, osobnu pomoć i njegu, obrazovanje i zabavu, potragu i spašavanje, proizvodnju i održavanje, odnose s javnošću i zdravstvo. Prije pandemije koronavirusa i ekonomske neizvjesnosti *Stratistics Market Research Consulting* očekivao je da će globalno tržište humanoidnih robota doseći 13

[698] Bond, R. M., Fariss, C. J., Jones, J. J., Kramer, A. D. I., Marlow, C., Settle, J. E., James, H. (2012). A 61-Million-Person Experiment in Social Influence and Political Mobilization, Nature 489(7415), str. 295–298.
[699] Više o tome vidjeti na: https://www.kaspersky.com/resource-center/definitions/what-are-bots
[700] Bessi, A., Ferrara, E. (2016). Social bots distort the 2016 U.S. Presidential election online discussion, FIRST MONDAY, Volume 21, No 11, dostupno na: http://journals.AIc.edu/ojs/index.php/fm/article/view/7090/5653
[701] Vidjeti na: https://www.sciencedaily.com/terms/humanoid_robot.htm

milijardi dolara do 2026.[702] Iako je buduće ponašanje na tržištu neizvjesno, upotreba robota je u porastu: kineska poduzeća žurila su s postavljanjem robota i tehnologija automatizacije, dok su se liječnici borili s korona virusom. Primjerice, početkom ožujka u kineskom *Wuhanu* otvorila se „poljska“ bolnica u kojoj su radili roboti - *Smart Field Hospital*.[703] Tamo su humanoidni roboti dezinficirali, mjerili temperature, dostavljali hranu i lijekove i zabavljali medicinsko osoblje i pacijente. Neki roboti mogu olakšati umornim medicinskim sestrama u bolnicama, obaviti osnovno čišćenje i dostavu, drugi mogu pomoći u skladištima, dok industrijski roboti mogu pomoći u održavanju neke proizvodnje za proizvodna poduzeća dok su njihovi ljudski suradnici u karanteni. Također, poznat je i humanoidni robot koji oponaša pokrete svog ljudskog operatera poput avatara iz stvarnog svijeta. On je kreiran u svrhu Olimpijskih igara u Tokiju te ima poboljšane funkcije nadzora i može prirodnije hodati. Humanoidni roboti također mogu pomoći njegovateljima da rade svoj posao na daljinu ili onima koji trebaju pomoć kako bi živjeli neovisniji život. *SoftBank Robotics' Pepper* dizajniran je da bude prijateljski pomagač u čitanju emocija kako bi radio kao recepcionar, u maloprodaji, pa čak i kao dadilja.[704] Sada *Pepper* dolazi s obrazovnim integriranim razvojnim okruženjem (IDE), nazvanim *Tethys*, koje je stvoreno kako bi učenike naučilo kodirati. Koristeći softver studenti mogu programirati humanoid da se kreće, razgovara, gestikulira i prikazuje različite poruke na njegovom zaslonu, sve u stvarnom vremenu.[705]

Možda je najprepoznatljiviji humanoidni robot *Sophia*, socijalni humanoid koji je razvio *Hanson Robotics* iz Hong Kong-a. Učena od ljudi *Sophia* se može kretati, razgovarati, pokazivati neke emocije, crtati i pjevati. Ono što *Sophiu* čini posebnom jeste što je ona prvi humanoid koji je dobio državljanstvo neke države (Saudijske Arabije), što predstavlja iskorak u približavanju humanoida ljudskim pravima.[706] To iz razloga što državljanstvo predstavlja pravo pojedinca kojim kao državljanin neke države ima sva prava i obveze koje proistječu iz njezina pravnog poretka. Sukladno navedenom, *inter alia*, postavlja se pitanje odgovornosti za počinjenje nekog kaznenog djela i mogućnosti sankcioniranja samog humanoida.

---

[702] Više o tome na: https://www.marketresearch.com/Stratistics-Market-Research-Consulting-v4058/Humanoid-Robot-Global-Outlook-12684730/

[703] Zhou, M., Chen, Y., Su, X., An, L. (2020). Rapid construction and advanced technology for a Covid-19 field hospital in Wuhan, China, Proceedings of the Institution of Civil Engineers-Civil Engineering, Vol. 174, No. 1, str. 29-34.

[704] Pandey, A. K., Gelin, R. (2018). A mass-produced sociable humanoid robot: Pepper: The first machine of its kind, IEEE Robotics & Automation Magazine, *25*(3), str. 40-48.

[705] Više o tome na: https://www.softbankrobotics.com/emea/en/blog/news-trends/landscape-ai-robotic-guides-museums-cultural-places

[706] Retto, J., *op.cit.*

3.9.1. PRIHVAĆANJE ZNANJA, LJUDI I UMJETNA INTELIGENCIJA

DeepMind Technologies je 2013. godine objavila revolucionarni rad[707] koji pokazuje kako bi neuronska mreža mogla naučiti igrati video igre iz 1980-ih onako kako to rade ljudi - gledajući u ekran. *DeepMind* je od tada primijenio DL u nizu situacija, a najpoznatiji je kako bi nadmašio ljude u drevnoj igri *Go*.[708] No, iako je ovo djelo impresivno, ono naglašava jedno od značajnih ograničenja DL. U usporedbi s ljudima, strojevima koji koriste ovu tehnologiju potrebno je ogromno vrijeme za učenje.[709] Što je to kod ljudskog učenja što nam omogućuje tako dobre rezultate s relativno malo iskustva? U odgovoru na ovo pitanje pomoglo je proučavanje istraživača s kalifornijskog sveučilišta *Berkeley* koji su promatrali način na koji ljudi komuniciraju s video igrama kako bi otkrili na kakvo se predznanje oslanjamo kako bismo ih razumjeli.[710] Ispostavilo se da ljudi koriste bogatstvo prethodnog znanja kad god započnemo novu igru što čini igre znatno lakšima za igranje. Međutim, suočeni s igrama kojima se ovo znanje ne koristi ljudi se poigravaju, dok se strojevi služe na potpuno isti način. Pri eksperimentu provedenom na nekim video igricama utvrđeno je da ljudi učeni iskustvom igricu mogu riješiti na temelju prethodnih znanja, dok je nekim ranijim strojevima to bilo teško. Međutim, eksperimentirajući i uklanjajući neka predznanja uočeno je da isto uzrokuje drastičnu degradaciju brzine kojom ljudski igrači rješavaju igru. Vrijeme potrebno ljudima da riješe igru povećava se s jedne minute na više od 20 minuta kako se uklanjaju različite vrste prethodnih informacija, dok s druge strane uklanjanje ovih informacija obično ne razlikuje brzinu kojom strojni algoritam uči. Ova saznanja potakla su na istraživanja u kvantificiranju važnosti različitih prioriteta koje ljudi koriste u rješavanju video igara i razumijevanju kako predznanje čini ljude dobrima u tako složenim zadacima. To sugerira zanimljiv put naprijed za računalne znanstvenike koji rade na strojnoj inteligenciji, odnosno programiranjem u stroj unose ista ona osnovna znanja koje ljudi poprimaju u ranoj dobi. Na taj bi način strojevi trebali moći sustizati ljude u brzini učenja, a možda ih i nadmašiti.[711]

---

[707] Dabney, W., Kurth-Nelson, Z., Uchida, N., Starkweather, C. K., Hassabis, D., Munos, R., Botvinick, M. (2020). A distributional code for value in dopamine-based reinforcement learning. Nature, 577(7792), str. 671-675.
[708] Chouard, T. (2016). The Go Files: AI computer wins first match against master Go player, Nature News
[709] Wilks, Y. (2019). Artificial Intelligence – Modern magic or dangerous future?, Icoon Books
[710] Stoica, I. *et.al.* (2017). A Berkeley View of Systems Challenges for AI, Cornell University, dostupno na: https://arxiv.org/abs/1712.05855
[711] Why Humans Learn Faster Than AI – for now (2018). MIT Technology Review, dostupno na: https://www.technologyreview.com/2018/03/07/3241/why-humans-learn-faster-than-ai-for-now/

3.9.2. UTJECAJ UMJETNE INTELIGENCIJE NA PRAVNI SUSTAV

U travnju 2019. godine istraživački tim kineskog tehnološkog diva *Tencent* pokazao je da bi *Tesla Model S* u načinu rada autopilota mogao biti prevaren tako da slijedi zavoj ceste koji nije postojao na način da se na prometnicu dodaju naljepnice koje mijenjaju putanju kretanja.[712] Ranija istraživanja u SAD-u su pokazala da bi male promjene znaka zaustavljanja mogle uzrokovati da automobil bez vozača pogrešno shvati kao znak ograničenja brzine. Drugo je istraživanje pokazalo da bi zlonamjerni napadač puštanjem tonova koji se ne mogu odgonetnuti osobi mogao uzrokovati da *Amazon Echo* naručuje neželjene predmete pa čak i laserski kontrolirati sami uređaj.[713] Ova su otkrića dio rastućeg područja proučavanja poznatog kao kontradiktorno ML. Kako sve više strojeva postaje dio AI, informatičari uče da se s AI može manipulirati tako da svijet opaža na pogrešne, ponekad opasne načine. Budući da ove tehnike zavaraju sustav umjesto da ga hakiraju, savezni zakoni i sigurnosni standardi možda neće osigurati zaštitu od ovih zlonamjernih novih ponašanja, kao i ozbiljnih posljedica koje mogu imati. Pravila protiv hakiranja u SAD-u datiraju iz sredine 1980-ih, otprilike u vrijeme filma *War Games*. Prema popularnim saznanjima, administrativni službenici bivšeg američkog predsjednika *Ronald Reagana* gledali su film užasnuto dok je tinejdžer David upao u računalo Pentagona iz svoje spavaće sobe i zamalo pokrenuo nuklearni rat. Bez obzira na razlog, Kongres je 1986. godine donio Zakon o računalnim prijevarama i zlostavljanjima (engl. *Computer Fraud and Abuse Act* - CFAA) s ciljem suzbijanja hakiranja državnih i drugih zaštićenih računala. Prema Saveznom zakonu hakiranje se sastoji u nanošenju štete zaobilazeći sigurnosni protokol bez odgovarajućeg ovlaštenja. Ovo razumijevanje i dalje vrijedi i proširilo se i na drugi kontekst, uključujući međunarodno pravo i standarde. Problem je u tome što suparnički ML ne upada u stroj kao takav. Umjesto toga, ove tehnike iskorištavaju znanje o modelu da bi sustav prevarile i to rade ne zaobilazeći bilo koji sigurnosni protokol. Ove tehnike također ne isključuju tipični pristup koji se naziva napadom "uskraćivanjem usluge". Prijetnja računalnoj sigurnosti razvija se na načine na koje zakoni protiv hakiranja nisu predviđali. Jedan od problema je taj što zakoni protiv hakiranja možda neće obuhvatiti sva nedopuštena ponašanja te stoga neće zabraniti opasno ponašanje poput kompromitiranja autonomnog automobila. Prethodnih godina kasino je pokušao tužiti osobu jer je otkrio kako prevariti digitalni poker

[712] Nie, S., Liu, L., Du, Y. (2017). Free-fall: Hacking tesla from wireless to can bus, Briefing, Black Hat USA, 25, str. 1-16.
[713] Više o tome na: https://www.wired.com/story/lasers-hack-amazon-echo-google-home/

aparat da mu dopusti pobjedu pritiskujući niz gumba određenim redoslijedom.[714] U neobvezujućem mišljenju Savezni sud je odbio slučaj kasina jer optuženik nije hakirao stroj, odnosno nije zaobišao nijedan sigurnosni protokol.[715] Isto bi se moglo reći za prijevaru automobila prebrzom vožnjom ili promjenom trake mijenjanjem vanjskog okruženja. Naravno, promjena ceste ili putokaza na način koji ugrožava vozače već je nezakonito. Možda bi se ovi lokalni zakoni mogli baviti primjerima nenadziranog ML barem kad su životi u opasnosti. Međutim, postavlja se pitanje što je s tehnikama koje dosežu više uređaja odjednom, poput tona emitiranog na radiju zbog kojeg bi *Amazonova Alexa* u cijeloj zemlji mogla naručivati predmete s *Amazona*? Neki od načina na koje se strojevi mogu prevariti mogu se prilagoditi razmjeru i mogu prijeći jurisdikcijske granice. Drugi se mogu brinuti da bi ionako nejasan zakon protiv hakiranja mogao nehotice ciljati nevine ili izražajne aktivnosti.[716] Postavlja se pitanje primjerice bi li nošenje šminke namijenjeno izbjegavanju prepoznavanja lica predstavljalo hakiranje sustava u zračnim lukama? Nadalje, postavlja se pitanje što je s programerom sustava koji je prevaren? Poduzeća imaju obvezu primijeniti odgovarajuću sigurnost, a državni zakon zahtijeva od njih da prijave hakere pri kršenju osobnih podataka. Pametni strojevi poput čak i najpametnijih ljudi mogu se prevariti. Istraživanje računalne sigurnosti uči nas da pametni napadač može namjerno manipulirati s AI navodeći je na pogrešno opažanje svijeta na načine koji mogu nanijeti nenacionalnu ili čak fizičku štetu. Rezultirajući prekid veze između kontradiktornih tehnika i zakona protiv hakiranja znači nesigurnost za potrošače i istraživače i manje poticaje za programere AI. Ono što je potrebno je veliko preispitivanje samog pojma hakiranja.[717]

3.9.3. UMJETNA INTELIGENCIJA KAO UGROZA U PRAVNOM SUSTAVU

Premda se na prvi pogled roboti i AI čine dalekima od pravosuđa i postupaka posredovanja u sudskim postupcima, algoritmi i BD brzo ulaze u svijet alternativnog rješavanja sporova (engl. *Alternative Dispute Resolution* - ADR). To je rezultat brzo rastuće potražnje za onom vrstom analitike podataka koja se koristi u američkim parnicama radi predviđanja ishoda suđenja. Implementiranje robota u postupke posredovanja postiglo je novu prekretnicu u veljači

[714] Prakken, H. (2005). AI & Law, logic and argument schemes, Argumentation, 19(3), str. 303-320.
[715] Više: Oboyle, D. (2021). First Circuit Court rejects DOJ Wire Act appeal, IGB, dostupno na: https://www.igbnorthamerica.com/first-circuit-court-rejects-doj-wire-act-appeal/
[716] Crawford, K., Whittaker, M., Elish, M. C., Barocas, S., Plasek, A., Ferryman, K. (2016). The AI Now Report, The Social and Economic Implications of Artificial Intelligence Technologies in the Near-Term
[717] Calo, R. (2019). How New A.I. Is Making the Law's Definition of Hacking Obsolete, OneZero

2019. kada su kanadski stručnjaci za elektroničke pregovore *iCan Systems* navodno postali prvo poduzeće koje je spor riješilo na javnom sudu u Engleskoj i Walesu pomoću "robotskog posrednika". Tako je *Smartsettle ONE* kao robotski posrednik zamijenio suca i za manje od sat vremena koristeći svojevrsni mehanizam slijepog licitiranja riješio tromjesečni spor oko neplaćenog računa od 2000 funti za tečaj osobnog savjetovanja. Sudjelovanje AI u sudskom posredovanju možda može biti korisna pri rješavanju nekih manjih financijskih sporova, ali neki odvjetnici tvrde da je ona daleko od rješavanja velikih arbitraža. Pri tome se navodi da su pri rješavanju takvih većih spornih arbitraža potrebne vještine iskusnog pregovarača kako bi se uspjelo nagovoriti ljude da čine stvari koje ne žele. AI jeste već uključena u rješavanje sporova na sudovima, ali u alternativnom smislu, više kao alat za analizu podataka i dokumentacije. Osobito se navodi sposobnost analize BD, prepoznavanja i prioritizacije ranog pregleda ključnih dokumenata korištenjem tehnološki potpomognutog softvera za pregled koji klasificira i daje prioritete dokumentima te postizanja brzog zaključka o meritumu slučaja slijedeći postupak rane procjene slučaja. Ovi postupci u stvari predstavljaju ranu procjena rizika od kaznenog progona što je najčešće područje upotrebe AI u posredovanju. Alati poput *Brainspacea* otkrivaju i razvrstavaju jedinstvene fraze u velikim skupovima podataka, omogućujući da u jednom slučaju pregledaju skup dokumenata od 2,7 milijuna u samo dva sata.[718] Također, AI se koristi kroz metodu klasteriranja koja svojim oznakama pridružuje skupine dokumenata i klasterira dokumente sa sličnim temama. To omogućuje otkrivanje potencijalno ključnih riječi i tema kojima se daje prioritet za ljudski pregled. Takvim postupnim uvođenjem AI u pravni sustav ista se može pojaviti kao ugroza samom pravu jer bi u budućnosti AI mogla predviđati ishode i potencijalno utjecati na tijek nagodbi. Isto tako mogla bi i utjecati na to da se takva analitika podataka proširi na predviđanje u kojem smjeru mogu ići arbitri ili posrednici. Etička nedoumica je utjecaj koji bi imala na izbor ljudi koji će izabrati arbitra ili posrednika u postupku u koji su uključeni.[719] Također, ranije je navedeno kako se AI koristi u donošenju sudskih odluka odnosno odluka o kaznenopravnoj sankciji počinitelja na temelju podataka iz njegova profila. Pri tome se američki kaznenopravni sustav koristi prediktivnim algoritmima kako bi sudski postupak učinio manje pristranim, odnosno kako bi ga učinio pravednim. Međutim, pravednost je apstraktan pojam pa nešto što je za nekog pravedno za drugoga nije i slično. Taj koncept pravednosti razvijamo po osjećaju. Međutim, svjedoci smo

[718] Beioley, K. (2019). Robots and AI Threaten to Mediate Disputes Better Than Lawyers, Financial Times
[719] *Ibid.*

da algoritmi sve češće preuzimaju ulogu posrednika i na određeni način donose odluke što je za nas pravedno. Tako oni odlučuju tko će vidjeti koje oglase za stanovanje, tko će biti gdje zaposlen ili otpušten, pa čak i tko će biti poslan u zatvor. Slijedom toga, od ljudi koji ih stvaraju - softverskih inženjera - traži se da artikuliraju što znači biti pošten u svom kodu. Zbog toga se regulatori širom svijeta sada hvataju u koštac s pitanjem kako matematički kvantificirati pravednost? Za odgovor na ovo pitanje proveden je svojevrstan eksperiment gdje je ispitan pravi algoritam koji je odlučivao tko će biti poslan u zatvor uz podešavanje njegovih različitih parametara kako bi njegovi ishodi bili pravedniji.[720] Pri tom eksperimentu ispitan je algoritam poznat pod nazivom COMPAS, a koji predstavlja samo jedan od nekoliko različitih alata za "procjenu rizika" koji se koriste u američkom kaznenopravnom sustavu.[721] COMPAS bi trebao pomoći sucima da utvrde treba li osobi odrediti istražni zatvor ili je pustiti da se brani sa slobode. Obučava se na podacima o optuženiku kako bi pronašao korelacije između čimbenika poput nečije dobi i povijesti s kaznenopravnim sustavom i toga je li osoba ponovno uhićena. Zatim koristi korelacije za predviđanje vjerojatnosti da će optuženik biti uhićen zbog novog kaznenog djela tijekom razdoblja čekanja na suđenje. Ovo predviđanje poznato je kao "ocjena rizika" optuženika, a zamišljeno je kao preporuka:

- optuženici s "visokim rizikom" trebaju biti zatvoreni kako bi im se spriječilo da nanose štetu društvu i
- optuženici s „niskim rizikom“ trebali bi biti pušteni prije suđenja.

U stvarnosti suci ne slijede uvijek ove preporuke, ali procjene rizika ostaju utjecajne. Pristalice alata za procjenu rizika tvrde da oni čine kaznenopravni sustav pravednijim. Oni zamjenjuju sudačku intuiciju i pristranost, posebno rasnu pristranost s naizgled "objektivnijim" vrednovanjem. Oni također mogu zamijeniti praksu polaganja jamčevine u SAD-u koja od optuženika zahtijeva plaćanje iznosa novca za puštanje na slobodu. Jamčevina diskriminira siromašne Amerikance i nerazmjerno utječe na optuženike pripadnike crne rase koji su previše zastupljeni u kaznenopravnom sustavu.[722] COMPAS ne uključuje rasu u izračunavanje procjene rizika. Međutim, istraga *ProPublice* 2016. godine tvrdila je da je alat i dalje pristran prema

[720] Više o tome vidjeti na: https://www.nytimes.com/2017/10/26/opinion/algorithm-compas-sentencing-bias.html
[721] Kearns, P. (2020). Here's how Compass uses artificial intelligence to support its agents, Inman, dostupno na https://www.inman.com/2020/01/29/heres-how-compass-uses-artificial-intelligence-to-support-its-agents/
[722] Lee, N. T. (2018). Detecting racial bias in algorithms and machine learning, Journal of Information, Communication and Ethics in Society

Afroamerikancima. *ProPublica*[723] je utvrdio da su među optuženicima koji nikada nisu bili ponovno uhićeni afroamerički optuženici dvostruko vjerojatnije od pripadnika bijele rase označeni kao visoko rizični. Razlog je taj što su optuženici različite puti, crne ili bijele, ponovo uhićeni po različitim stopama. Iako je 52 % optuženika Afroamerikanaca ponovno uhićeno prema podacima okruga *Broward*, samo je 39 % optuženih bijelaca. Slična je razlika u mnogim jurisdikcijama diljem SAD-a, dijelom i zbog povijesti policije u zemlji koja neproporcionalno cilja na manjine. Poanta ovog eksperimenta dovela je do toga da u stvari predviđanja odražavaju podatke koji su korišteni za njihovo stvaranje bilo algoritmom ili ne. Ako se Afroamerikance uhićuje višom stopom od bijelaca u stvarnom svijetu, imat će i veću stopu predviđenih uhićenja. To znači da će u prosjeku imati i više rizične ocjene, a veći postotak njih bit će označen visokorizičnim - i ispravno i netočno. To je točno bez obzira koji se algoritam koristi, sve dok je dizajniran tako da svaki rezultat rizika znači isto bez obzira na rasu. Ovaj neobičan sukob definicija pravednosti nije ograničen samo na algoritme za procjenu rizika u kaznenopravnom sustavu. Iste vrste paradoksa vrijede za algoritme bodovanja, osiguranja i zapošljavanja. U bilo kojem kontekstu u kojem automatizirani sustav odlučivanja mora raspodijeliti resurse ili kazne među više skupina koje imaju različite ishode, različite će se definicije pravednosti neizbježno ispostaviti. Ne postoji algoritam koji to može popraviti, odnosno ovo zapravo nije ni algoritamski problem. Suci trenutno čine iste vrste prisilnih kompromisa - i to su činili kroz povijest. Međutim, iako suci možda nisu uvijek transparentni u načinu na koji biraju između različitih pojmova pravednosti, stranke u postupku imaju uvid u odluke i obrazloženja. Suprotno tome, COMPAS, koju izrađuje privatno poduzeće *Northpointe*, poslovna je tajna koja se ne može javno pregledati ili ispitati. Optuženi više ne mogu dovesti u pitanje njegove ishode, a vladine agencije gube sposobnost nadzora postupka donošenja odluka. Dakle, nema više javne odgovornosti.

U pogledu rješavanja ovog nedostatka predložen je Zakon o algoritamskoj odgovornosti iz 2019.[724] koji kako neki navode predstavlja primjer dobrog početka. Radi se o nacrtu zakona kojim se želi regulirati pristranost u automatiziranim sustavima donošenja odluka i koji ima dvije značajne odrednice koje služe kao predložak budućem zakonodavstvu. Prvo, od poduzeća bi se zahtijevalo da revidiraju svoje sustave ML na pristranost i diskriminaciju u „procjeni

[723] Washington, A. L. (2018). How to argue with an algorithm: Lessons from the COMPAS-ProPublica debate, Colo. Tech. LJ, 17, str. 131.
[724] Više na: https://www.congress.gov/bill/116th-congress/house-bill/2231/all-info

učinka“. Drugo, ne precizira definiciju pravednosti s obzirom na njezinu apstraktnost. No, trebaju li se algoritmi uopće koristiti za arbitražu složeno je pitanje. Algoritmi ML uče se na podacima dobivenim kroz povijest isključenja i diskriminacije. Veće je pitanje njihove upotrebe - ili bilo kojeg algoritma koji se koristi za rangiranje ljudi - smanjuju li oni postojeće nepravde ili ih pogoršavaju.[725] Time možemo zaključiti da ne treba žuriti s primjenom AI u određenim dijelovima sudskih procesa već ih strateški implementirati u smislu modernizacije sudstva.

3.9.4. UMJETNA INTELIGENCIJA U MODERNIZACIJI SUDSTVA

Kako živimo u eri AI potrebno je odgovoriti na zahtjeve ljudi za nepristranošću suda putem AI i drugih modernih tehnologija. Integracijom znanosti i tehnologije bolje bi se trebala zajamčiti nepristranost suda kako bi mogla bolje služiti gospodarskom i društvenom razvoju. Pravosudni razvoj ima svoje vlastite snažne zahtjeve za modernom tehnologijom. Kao što je jednom rekao *Zhou Qiang*, predsjednik Vrhovnog suda Kine: "*Baš kao i kotači na vozilu i krila ptici, reforma pravosuđa i informatizacija dva su neizostavna čimbenika za pravosudni cilj zemlje*."[726] Primjena tehnologija u pravosudnoj praksi pogodna je za poboljšanje pravosudnih kapaciteta i ostvarivanje pravde na učinkovit način. S jedne strane, tehnologija je ključ za rješavanje pravosudnih poteškoća. Primjerice, posljednjih godina sa sve većim brojem pokrenutih sudskih postupaka neujednačenost sudske prakse i ograničeni broja sudaca postali su vodeći problemi koji utječu i ograničavaju razvoj sudova. Kako bi prevladao ovu istaknutu poteškoću, Šangajski sud integrirao je AI tehnologiju u „*hotline*“ liniju pravosudne službe, služeći masama na cjelokupan, cjelodnevni način bez ikakve udaljenosti i prepreka, čime je učinkovito riješio poteškoće s kojima se ljudi susreću u kontaktiranju sudaca, informiranja o predmetu i savjetovanja u parnici. S druge strane, znanost i tehnologija dobri su alati koji jamče pravdu. Trenutno još uvijek postoje slučajevi u kojima su ljudi nepravedno, lažno ili pogrešno optuženi ili osuđeni i izdržavaju kaznu. Oni su jedan od glavnih problema koji utječu na sudsku vjerodostojnost i autoritet. Kako bi se spriječila pojava ovih slučajeva razvijen je *Shanghai AI*, pomoćni sustav za kaznene slučajeve pomoću kojeg se dokazi mogu ispitati i provjeriti, a nedostaci u dokazima i proturječnost između dokaza mogu se otkriti na vrijeme. Posljednjih godina AI je predstavila nove značajke kao što su DL, prekogranična integracija, suradnja

[725] Hao, K., Stray, J. (2019). Can you make AI fairer than a judge? Play our courtroom algorithm game, MIT
[726] Jian, D. (2021). Several Important Statements of Zhou Qiang in the Supreme Law Work Report-Finance News, 6Park News, dostupno na: https://6park.news/en/several-important-statements-of-zhou-qiang-in-the-supreme-law-work-report-finance-news.html

čovjek-stroj, inteligencija mnoštva i slično. Sustav pretraživanja pravnih podataka i pravni stručni sustav široko su korišteni, postavljajući tehničke i empirijske temelje za primjenu AI u pravosudnoj praksi. Istodobno, s izuzetnim napretkom algoritama AI predstavljenih DL na polju prepoznavanja slika i prepoznavanja govora, više nije daleko ostvariti „digitalnu vladavinu zakona“ i „inteligentnu pravdu“ pomoću tehnologija AI kao što je ML. Na primjer, poboljšanje i ponavljanje algoritma DL tjera primjenu AI u pravosudnu praksu na dublju razinu. Višestruki, višetipski, stvarni i masovni pravosudni podaci čine opis sudskih aktivnosti živopisnijim i sveobuhvatnijim. Razvojem modernih tehnologija poput AI mnoge države u svijetu aktivno proučavaju i istražuju načine primjene AI u pravosudnoj praksi. U SAD-u AI se kontinuirano primjenjuje u pravosudnim aktivnostima. Prema izvješću od 6. lipnja 2017. godine suci Saveznog suda u San Diegu u Kaliforniji predložili su Kongresu da se *chatbotovi* široko koriste na sudovima za pomoć sucima. Glavni sadržaj prijedloga je sljedeći: „*Prvo, chatbotovi se mogu koristiti za promociju otvorenosti suda i poboljšati usluge. Prijedlog je smatrao da chatbotovi mogu obavljati jednostavan svakodnevni rad sudova i da mogu dobro služiti javnosti. Korištenje chatbotova poboljšalo bi učinkovitost sudskog rada i uštedjelo pravosudne resurse. Kao drugo, chatbotovi se mogu koristiti za pomoć sudu u svakodnevnom radu. Trenutno su neki sudovi u Kaliforniji koristili robote za svoj svakodnevni rad. Na primjer, neki sudovi koriste ovu tehnologiju na komunikacijskim linijama kako bi odgovorili na jednostavna savjetodavna pitanja i prenijeli svakodnevne informacije o radu. Treće, podjela rada suda mogla bi se optimizirati. Sudovi koriste robote za obavljanje jednostavnih i ponavljajućih poslova, kako bi se suci mogli usredotočiti na složeniji posao koji pogoduje promjeni tradicionalnog koncepta rada, kako bi postigli benignu suradnju između sudaca i robota*.“[727]

Britansko udruženje prava i računarstva iznijelo je britanskoj vladi prijedloge i planove za implementaciju „*online*“ sudova. Sustav „*online*“ sudova usredotočio bi se na „rješavanje sporova“, „kontrolu sporova“ i „sprječavanje sporova“ kako bi se ostvarila kombinacija ADR-a (mehanizma alternativnog rješavanja sporova) i EDR-a (mehanizma ranog rješavanja sporova).[728] Sveučilište *Sheffield* u Velikoj Britaniji objavilo je novi sustav AI koji može

[727] Cai, Y. (2020). Artificial Intelligence and Judicial Modernization, Springer, Shanghai People's Publishing House, str. 22-23.
[728] Više o tome na: https://kennedyslaw.com/thought-leadership/article/online-courts-a-report-on-the-first-international-online-courts-forum/

pomoći u rješavanju pravnih slučajeva i predvidjeti rezultate s točnošću od 79 %.[729] *Imperial College* Sveučilišta u Londonu uspješno je vodio dijalog čovjek-stroj u praksi prava državljanstva uz pomoć funkcije obrazloženja programskog jezika PROLOG. Osim toga, odvjetničko društvo *Hodge Jones & Allen* sa sjedištem u Londonu već dugo koristi "model predviđanja ishoda slučaja" kako bi procijenio vjerojatnost uspjeha u predmetima osiguranja. To je izravno dovelo do reforme parnice *Jackson* u 2013. godini koja je uvelike smanjila troškove parnice u slučajevima osiguranja. Komisija u Komunikaciji Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija nazvanom „Prema rastućem gospodarstvu temeljenom na podacima“ iz 2014.[730] imala je za cilj uklanjanje prepreka prekograničnom pristupu i razmjeni podataka. Ova komunikacija uključuje odredbu koja omogućuje slobodan protok neosobnih podataka. Pod pretpostavkom poštivanja zakona o zaštiti tržišnog natjecanja, Komisija može olakšati razmjenu podataka između europskih poduzeća. Europski odbor za pravna pitanja podnio je zahtjev kojim traži od Komisije da barem najnaprednije automatizirane robote identificira kao „elektroničke ljude“ i da im dodijeli „posebna prava i obveze“. U prijedlogu se također preporučuje uspostava registra inteligentnih automatiziranih robota za otvaranje financijskih računa koji pokrivaju zakonske obveze za te robote. EU se obvezala dati AI pravni i etički status kako bi joj pomogla da bolje služi pravosuđu i javnosti. U srpnju 2016. godine nacrtom Nacionalne strategije za razvoj informatizacije koju je izdala kineska vlada ugrađena je izgradnja „inteligentnih sudova“ u nacionalno planiranje razvoja informatizacije, jasno stavljajući do znanja da treba uložiti napore u izgradnju „inteligentnih sudova“ radi poboljšanja razine informatizacije u svim koracima sudske prakse. U srpnju 2017. godine Razvojno planiranje nove generacije AI koju je izdala kineska vlada iznijelo je posebne zahtjeve za primjenu AI u pravosudnoj praksi: „*Treba uložiti napore u promicanju primjene AI u javnoj upravi, pravosudnom upravljanju, urbanoj upravi, zaštiti okoliša i važnim područjima socijalnog upravljanja, promičući tako modernizaciju socijalnog upravljanja*.“[731]

---

[729] Barton, S. (2016). AI predicts outcomes of human rights trials, The University of Sheffield, dostupno na: https://www.sheffield.ac.uk/news/nr/artificial-intelligence-predicts-outcomes-human-rights-trials-study-1.656915

[730] Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions Towards a thriving data-driven economy, COM/2014/0442 final

[731] Cai, Y., *op.cit.*, str. 21-24.

Dakle, suština pravosudnih aktivnosti je primjena zakona. Karakteristike pravosudnih djelatnosti daju temelj i pretpostavku za primjenu AI u pravosudnoj praksi. Isto tako, prikupljanje pravnog znanja i cjelovite arhive pružaju iscrpne informacije za uključivanje AI u pravosudne aktivnosti i simuliranje stjecanja, izražavanja i primjene pravnog znanja. Naposljetku, jedinstvena samosvijest i samokritičnost u provođenju mnogobrojnih pravnih aktivnosti zajedno s tradicijom preispitivanja (izmjene, dopune) pojedinih zakonskih rješenja i odgovarajuće sudske prakse pružaju prostor za primjenu AI. Dakle, pravni formalizam pruža teorijsku osnovu za primjenu AI u sudskoj praksi.[732]

3.9.5. UMJETNA INTELIGENCIJA, ČOVJEČANSTVO I RELIGIJA

Nedvojbenim se smatra povijesna povezivost čovječanstva i raznih oblika božanstava. Stoga bi se u daljnjim istraživanjima trebala provesti sveobuhvatna analiza odnosa različitih religija i sustava AI. U cilju doprinosa daljnjim istraživanjima mogu se komparirati zakoni robotike u odnosu na izabrane religije. Stoga, može se povući paralela s autorom znanstvene fantastike *Isaacom Asimovim* koji je osmislio svoja Tri zakona robotike te razmišljao o androidima.[733] Zamišljao je svijet u kojem bi se roboti slični ljudima ponašali poput sluga i trebao bi im set programskih pravila kako bi ih spriječio da nanose štetu. No, u 75 godina od objavljivanja prve priče koja sadrži njegove etičke smjernice došlo je do značajnog tehnološkog napretka. Sada imamo vrlo različito poimanje kako roboti mogu izgledati i kako ćemo s njima komunicirati. Izuzetno razvijeno područje robotike proizvodi veliku paletu uređaja, od autonomnih usisavača, vojnih dronova do cijelih tvorničkih proizvodnih linija. Istodobno, AI i ML sve više stoje iza većine softvera kojima se svakodnevno služimo bez obzira pretražujemo li Internet ili neke druge usluge. Ova dostignuća brzo vode u vrijeme kada će roboti svih vrsta postati prevladavajući u gotovo svim aspektima društva, a interakcija čovjeka i robota znatno će se povećati. *Asimovi* zakoni i dalje se spominju kao predložak za vođenje našeg razvoja robota. Južnokorejska vlada čak je 2007. predložila Povelju o robotičkoj etici koja odražava zakone.[734] No, s obzirom na to koliko se robotika promijenila i nastavit će rasti u budućnosti,

[732] *Ibid*, str. 34-35.
[733] Anderson, S. L. (2008). Asimov's "three laws of robotics" and machine metaethics, AI & Society, 22(4), str. 477-493.
[734] Više o tome na: https://www.reuters.com/article/us-korea-robots-idUSSEO16657120070507

moramo se pitati kako bi se ta pravila mogla ažurirati za verziju AI 21. stoljeća. *Asimovi* predloženi zakoni osmišljeni su kako bi zaštitili ljude od interakcije s robotima. Oni su:[735]

1) Robot ne smije ozlijediti čovjeka niti mu nečinjenjem nauditi;
2) Robot se mora pokoravati naredbama koje mu daju ljudi, osim ako bi se takve naredbe kosile s Prvim zakonom robotike;
3) Robot mora zaštititi vlastito postojanje sve dok se takva zaštita ne kosi s Prvim ili Drugim zakonom robotike.

Ovi zakoni ne uspijevaju pravilno definirati i razlikovati ljude i robote. Ne postoji jasna definicija koja šteti čovjeku. Šteta za čovjeka može varirati u rasponu od fizičke do emocionalne razine. Ako su roboti imali nadljudsku inteligenciju, teško je pretpostaviti da neće smisliti način da promijene vlastito programiranje. Prema takvim naprecima postoji mogućnost da jednog dana robot čak i nauči sam sebe reprogramirati. Ako je cilj robota boriti se te spasiti vojnike i civile tijekom rata, mogao bi kršiti Prvi zakon jer bi mogao naštetiti svojim neprijateljima. Bilo kako bilo, roboti su postali stvarnost. S obzirom na sva ova pitanja, *Asimovi* zakoni nude malo više od temeljnih načela za nekoga tko danas želi stvoriti robotski kod. Moramo ih slijediti s mnogo sveobuhvatnijim nizom zakona. To znači da bez značajnih pomaka u AI provedba takvih zakona ostat će nemoguć zadatak.[736] Isto tako, može se zaključiti da bez mogućnosti da sigurno prekine AI i ne utječe na njeno učenje, jednostavan čin zaustavljanja robota da učini nešto nesigurno ili neproduktivno mogao bi ga učiniti manje sigurnim ili produktivnim - pretvarajući ljudsku intervenciju u mučenje, odnosno previše složenu stvar s nesagledivim posljedicama.[737]

Kroz definiranje ključnih elemenata AI u kontekstu razumijevanja, objašnjivosti, odgovornosti, etičnosti i ostalih, može se povući paralela osnovnih zakona robotike/AI s religijskim smjernicama ponašanja i životnog djelovanja. U smislu kršćanstva takve smjernice odnosile bi se na biblijske božanske zapovijedi, odnosno na 10 Božjih zapovijedi. Ako se u obzir uzme da se kršćani vode tim načelima/zapovijedima kroz život, za očekivati je da se slična načela primijene i na AI kako bi se ostvarila opća, globalna povjerljivost u istinsku AI. Budući

[735] *Ibid.*
[736] Anderson, M. (2017). After 75 years, Isaac Asimov's Three Laws of Robotics need updating, The Conversation
[737] Murphy, R., Woods, D. D. (2009). Beyond Asimov: the three laws of responsible robotics, IEEE intelligent systems, 24(4), str. 14-20.

da je u čovječanstvu prepoznat veći broj religija svakako se preporuča provesti daljnja detaljna i sveobuhvatna znanstvena istraživanja razvoja i primjene istinske AI.

3.10. OBJAŠNJIVA I ODGOVORNA UMJETNA INTELIGENCIJA

U istraživanju sociološkog učinka AI i njezinih podsustava kao što su ML i DL možemo naći argumente u pogledu prednosti i nedostataka. Svakako da je u tom procesu važno pronaći način na koji se AI čini etičnom i pravednom (ako to već nije) tako da je usmjerena na čovjeka i čovječanstvo. Pravednost treba biti osnovna etička okosnica u smislu da što veći broj ljudi ima prednosti od korištenja AI, a ne samo moćne korporacije. Na taj način ćemo društvo učiniti uravnoteženim i manje opasnim. Dakle, u odnosu na donositelje odluka važno je osigurati pravednost, odgovornost i transparentnost AI sa svim njenim podsustavima.

3.10.1. PRISTRANOST UMJETNE INTELIGENCIJE

Kad je riječ o pristranosti najprije treba kazati kako su podaci temelj svakog rada na ML i AI i tu započinju mnoga pitanja pristranosti i pravičnosti jer sami podaci uključuju ljudsku angažiranost na tim podacima u prošlosti.[738] Uvođenje AI u sve vrste poslovnih funkcija u svim industrijama će se zasigurno ubrzati i proširiti. Ipak, AI će biti ograničena svojom sposobnošću da pouzdano prepozna istinit sadržaj od lažnih podataka. Postoje tri glavna područja pristranosti u podacima:[739]

a) pristranost oznake - ono što se opaža postaje podatak, npr. uhićenja, a ne kaznena djela;
b) valjanost podskupina - prediktivna snaga značajki može se razlikovati među skupinama i
c) zastupljenost - jesu li podaci o obuci reprezentativni za populaciju? Imamo li iskrivljeni uzorak? Postoji li razlika u veličini uzorka? Na primjer, nedostatak geo-raznolikosti u podacima o treningu utjecati će na izvedbu klasifikacije na slikama izvučenim iz šireg skupa lokacija.

Kao primjer pristranosti možemo uzeti aplikaciju za odabir restorana. Dakle, cilj je utvrditi na koji način pristranost ulazi u model. Tako, dok korisniku preporučuje nove restorane, aplikacija AI osmišljena je tako da gleda na iznos potrošen u prethodnim transakcijama i ocjenu

[738] Angwin, J. *et.al., op.cit.*
[739] Corbett-Davies, S., Goel, S. (2018). The Measure and Mismeasure of Fairness: A Critical Review of Fair Machine Learning, dostupno na: https://arxiv.org/pdf/1808.00023.pdf

restorana (zajedno s ostalim značajkama), a sustav AI započinje s preporukom restorana koji su skuplji. Iako u blizini mogu biti dobri i jeftiniji restorani, restorani se možda neće prikazati kao jedna od glavnih preporuka. Također veći iznos koji korisnik potroši podrazumijeva i više prihoda za restoransku aplikaciju. Ukratko, AI usmjerava klasu korisnika prema trošenju više na vrhunske restorane, a da korisnik za to ne zna. Stoga se postavlja pitanje klasificira li se AI kao pristranost ili pametna shema stvaranja prihoda? Dakle, za stvaranje nepristranosti modela AI potrebno je dizajnirati model bez pristranosti, tj. bez unošenja značajki koje ukazuju na pristranost. Također, važno je objasniti izlaz iz modela. Ako korisnik dobije izlaz iz algoritma AI navodeći zašto je izlaz predstavljen i koliko je relevantan, treba biti ugrađen u algoritam. To bi trebalo osnažiti korisnike da razumiju zašto se predstavljaju određene informacije i uključiti/isključiti bilo kakve postavke povezane s algoritmom AI za buduće preporuke/prijedloge. Sljedeći korak bi bio potvrditi model, odnosno isti provjeriti. U konačnici, ljudi moraju gledati na rezultate iz sustava AI i poduzeti korektivne mjere za kritični zadatak. Na primjer, liječnik mora pažljivo istražiti mogućnost liječenja tumora koju nudi sustav AI, ali modna web stranica koja preporučuje pogrešne proizvode za korisnika nije kritična i može se kasnije ispraviti povratnim informacijama/učenjima. U slučaju restoranske aplikacije to bi značilo sljedeće: ako aplikaciju dizajniramo uzimajući u obzir navedene smjernice i učinimo rezultat razumljivim korisniku, možemo imati barem 4 razine preporuka zajedno s dokazima zašto se daje preporuka:

- preporučivanje restorana na temelju jednog od ranijih troškova, ocjena, povijesti i preferencija korisnika,
- preporuke sličnih restorana koji dijele visoko ocijenjenu osnovu, a tiče se ocjena, povijesti i preferencija korisnika,
- preporučivanje novih restorana na temelju povijesti i preferencija korisnika i
- preporuke generirane sustavom bez primjene bilo kojih korisničkih postavki.

Revidirana aplikacija tako nudi razne preporuke i dovoljno dokaza za potporu preporuke i u konačnici izbor, ako je prepušten korisniku da preuzme restoran i rezervira stol.[740] Na jednostavnom primjeru poput odabira restorana kroz određene varijable možemo steći uvid u primjenu AI u međunarodnom pomorskom prometu kroz segment pristranosti odnosno nepristranosti. Objektivne odluke koje bi donijela AI mogu rezultirati ostvarivanju financijskih

[740] Balani, N. (2019). Responsible And Ethical AI - Building Explainable Model, Medium

prednosti brodarskim poduzećima kao i olakšavanju poslovnih zadataka posade te automatizaciji određenih procesa.

3.10.2. PRAVEDNOST UMJETNE INTELIGENCIJE

Drugi element u izradi politike AI jeste pravednost AI. Postoje tri uobičajena modela mjerenja pravednosti AI odnosno njezine sastavnice poput ML:

- protuklasifikacija, što znači da se zaštićeni atributi poput rase, spola ne koriste izričito za donošenje odluka,
- paritet klasifikacije, što znači da su uobičajene mjere predviđanja (npr. lažno pozitivne i lažno negativne stope) jednake među skupinama definirane zaštićenim atributima i
- kalibracija, što znači da su uvjeti procjene rizika neovisni o zaštićenim svojstvima.[741]

Ove definicije su predložene kao mogući načini mjerenja pravednosti. Međutim, postoji rasprava o nedostacima tih mjera (npr. ove su definicije međusobno nespojive), a neki istraživači vjeruju da te odredbe mogu stvarno pogoršati problem pristranosti. *Sam Corbett-Davies i Sharad Goel* sa Sveučilišta *Stanford* tvrde da se sve tri definicije pravičnosti sugeriraju iz značajnih statističkih ograničenja.[742] U mnogim su slučajevima procjene rizika na temelju graničnih vrijednosti bolji izbor. Ovaj pristup znači postupati sa sličnim rizičnim ljudima na sličan način, na temelju statistički najtočnijih procjena rizika koje netko može proizvesti. Osim toga, vanjski utjecaji i efekti ravnoteže ponekad se zanemaruju, ali postoje situacije u kojima su važni. Tako se neke odluke bolje smatraju skupnim, a ne pojedinačnim odabirom. U međunarodnom pomorskom prometu povezanost brodova može pružiti korist cijeloj floti, ali i brodovima drugih kompanija. S druge strane, važan je oprezan pristup u kreiranju prediktivnih algoritama kako bi se izbjegle neželjene petlje u povratnim informacijama, a samim time i neželjene posljedice.

3.10.3. ODGOVORNA UMJETNA INTELIGENCIJA

Sljedeći element u izradi politike AI je osigurati odgovornu AI. Odgovorna AI široki je pojam koji treba opisati AI koja je etična, uključiva (i nije isključiva za privilegiranu skupinu društva), ne šteti društvu i održava dobrobit društva. Privatnost je područje koje čini dio i etične i odgovorne AI. ML je ostvario značajan napredak u prepoznavanju lica u posljednjih nekoliko

[741] Corbett-Davies, S., Goel, S., *op.cit.*, str. 5-6.
[742] *Ibid.*

godina, izazivajući zabrinutost zbog privatnosti, vlasništva nad podacima i pravednosti od strane mnogih, uključujući Algoritamsku ligu pravde (AJL).[743] Kanada i Francuska preuzele su vodeću ulogu u pogledu razvoja odgovorne AI. U odnosu na odgovornu AI možemo istaknuti dva temeljna izvora: Montrealska deklaracija[744] koja je formalizirala viziju za odgovornu AI te Etičke smjernice. U tom procesu IMO, IHO i ostale važne pomorske organizacije, zajedničkim naporima moraju odrediti i definirati pojmove i vrijednosti ključne za međunarodni pomorski promet kako bi implementacija svih ostalih smjernica za AI bila usklađena s potrebama pomorskog gospodarstva.

3.10.4. OBJAŠNJIVA, TRANSPARENTNA I POVJERLJIVA UMJETNA INTELIGENCIJA

Start up-ovi i trenutni operatori ulažu goleme svote novca u AI (oko 35 milijardi američkih dolara 2019. prema IDC-u).[745] Kako ti modeli AI postaju sve učinkovitiji, neka se poduzeća suočavaju s novim problemom: ne mogu ih koristiti. To iz razloga što ne postoji način na koji će se utvrditi kako je algoritam donio odluku. Međutim, postoje brojna rješenja za objašnjivost koja pomažu poduzećima da protumače svoj model i učine metaforični crni okvir malo transparentnijim.[746] Objašnjiva AI je ona čija djela ljudi mogu lako razumjeti. Suprotno je konceptu „crne kutije“ u ML, što znači interpretaciju rada složenih algoritama gdje čak ni njihovi dizajneri ne mogu objasniti zašto je AI donijela određenu odluku. Često postoje kompromisi između toga koliko je AI pametna i koliko je transparentna, a očekuje se da će ovi kompromisi rasti kako se sustavi AI povećavaju u unutarnjoj složenosti. Dakle, trebala bi postojati mogućnost revidirati algoritme i podatke. Stoga se postavlja pitanje kada se trebamo pouzdati u algoritme? Neki autori tvrde da je to onda kada se mogu uočiti pogreške, a povratne informacije su pouzdane, brze i djelotvorne.[747] Dakle, područje izrade politike AI i njezina razvoja svakako će obilježiti analize ostvarenja odgovornosti, objašnjivosti, pouzdanosti, nepristranosti, nediskriminacije i transparentnosti AI[748] što se uvelike oslanja na prethodno navedene elemente s dodatnom vrijednošću u primjeni na međunarodni pomorski promet.

---

[743] Više o tome: https://www.ajl.org

[744] Montrealska deklaracija o odgovornom razvoju umjetne inteligencije, dostupna na: https://www.declarationmontreal-iaresponsable.com/la-declaration

[745] Više o tome na: https://www.idc.com/getdoc.jsp?containerId=prUS46794720

[746] Walker, R. (2020). AI Explainability: Why we need it, how it works, and who’s winning, Medium

[747] Sava, N. (2017). Algorithmic ethics: lessons and limitations for leaders. London School of Business, dostupno na: https://www.london.edu/faculty-and-research/lbsr/algorithmic-ethics-essons-and-limitations-for-business-leaders

[748] Bhatti, B. (2018). AI Policy Making Part 4: A Primer On Fair and Responsible ML and AI, Medium

3.10.5. POGREŠNE ODLUKE UMJETNE INTELIGENCIJE

Ne umanjujući punitivni karakter kaznenopravnih sankcija, osobito je važno osvrnuti se i na socio-psihološke utjecaje koje ima oduzimanje slobode pojedincu radi ostvarenja svrhe kažnjavanja. To pogotovo kada se donošenje odluke o izricanju takvih kaznenopravnih sankcija oslanja na algoritamsko odlučivanje. Primjer takve prakse su SAD s obzirom da SAD izriče zatvorske kazne više nego bilo koja druga zemlja na svijetu. Na kraju 2016. godine gotovo 2,2 milijuna odraslih bilo je u zatvorima, a dodatnih 4,5 milijuna u drugim popravnim ustanovama, odnosno 1 od 38 odraslih Amerikanaca bio je pod nekim oblikom popravnog nadzora.[749] Pod neizmjernim pritiskom da se smanji broj zatvorskih kazni, a da se ne riskira porast kriminaliteta, sudnice u SAD-u su se okrenule automatiziranim alatima u pokušajima da pravni sustav što efikasnije i sigurnije odbaci neutemeljene optužbe protiv osumnjičenika. Tako se policijske uprave koriste prediktivnim algoritmima za strategiju kamo poslati svoje službenike, istražna tijela koriste sustave za prepoznavanje lica kako bi identificirali osumnjičene i sl. Ove su prakse dovele do ispitivanja jesu li u stvari poboljšale sigurnost ili jednostavno produžile postojeće nepravde. Primjerice, istraživači i zagovornici građanskih prava više su puta pokazali da sustavi prepoznavanja lica mogu zakazati, osobito za pripadnike crne rase čak i zamjenjujući članove Kongresa za osuđenike.[750] No, najkontroverzniji alat zasad je alat za procjenu kaznenog rizika. Ti algoritmi prikupljaju podatke o optuženikovom profilu i daju ocjenu recidiva odnosno broj koji procjenjuje vjerojatnost da će on ili ona ponovno počiniti kazneno djelo. Sudac tada uzima u obzir mnoštvo odluka koje mogu odrediti koju vrstu mjera određenom okrivljeniku treba izreći, trebaju li ga pritvoriti i koliko bi kazne trebale biti visoke. Logika korištenja takvih algoritamskih alata polazi od pretpostavke da u slučaju ako se može točno predvidjeti kriminalno ponašanje, može li se u skladu s tim rasporediti resurse, odnosno naložiti mjera kao što su rad za opće dobro ili zatvorska kazna. U teoriji to također smanjuje bilo kakvu pristranost u utjecaju na postupak, jer suci donose odluke na temelju podataka, kao i na osnovu njihove procjene. Ono što ukazuje na problem jeste da se suvremeni alati za procjenu rizika često pokreću algoritmima obučenim na ranijim podacima o kaznenim djelima. Dakle, ako algoritam hranimo ranijim podacima o kriminalitetu, on će izdvojiti obrasce povezane s kriminalitetom. Međutim, ti obrasci statističke korelacije nisu ni približno isti kao uzroci. Ako bi algoritam

[749] Enns, K. P. (2016). Incarceration Nation How the United States Became the Most Punitive Democracy in the World, Cambridge University Press

[750] Frost, N. A. (2010). Beyond public opinion polls: Punitive public sentiment & criminal justice policy, Sociology Compass, 4(3), str. 156-168.

utvrdio, na primjer, da je nizak dohodak povezan s visokim recidivizmom, tada djeluje pametnije za istražiti je li nizak dohodak stvarno prouzročio kriminalitet. No, to je upravo ono što rade alati za procjenu rizika: oni pretvaraju povezujuće uvide u uzročno-posljedične mehanizme bodovanja. Upravo zbog toga dolazi do mogućeg diskriminatornog postupanja u odnosu na primjerice zajednice s niskim primanjima i manjinske zajednice. Osim toga, budući da je većina algoritama za procjenu rizika vlasnička, također je nemoguće ispitati njihove odluke ili ih pozvati na odgovornost. Rasprava o tim alatima još uvijek traje. U srpnju 2018. godine više od 100 organizacija s građanskim pravima i zajednicama potpisali su izjavu u kojoj se protive uporabi procjene rizika.[751] Iako je procjena rizika važan element svake poslovne aktivnosti ključno je primijeniti je na pravedan način. U međunarodnom pomorskom prometu kvalitetna procjena rizika kroz podsustave sustava AI predstavlja ključan element u ostvarivanju sigurnosti plovidbe.

3.10.6. ZDRAVSTVENA SKRB U POMORSTVU

Poznata narodna poslovica za pomorstvo kao zanimanje kaže da ono predstavlja "kruh sa sedam kora". Razlog tome je što je pomorstvo uvijek bilo iznimno opasno, a duga putovanja, ekstremni vremenski uvjeti, bolesti i nesreće mogu značajno utjecati na zdravlje članova posade.[752] Težini posla kojim se pomorci bave doprinosi i izoliranost od standardnih izvora kvalitetne medicinske skrbi što je u stvarnosti rezervirano ponajviše za ljude na obali. U tom smislu važno je istaknuti napore Svjetske zdravstvene organizacije (engl. *World Health Organization* - WHO) koja se trudi poboljšati zdravlje ljudi na njihovom radnom mjestu, a posebnu pozornost je poklonila sektoru pomorstva. Razlog tomu je možda upravo zato što su određena istraživanja pokazala da pomorac[753] s radnim stažom od 10 - 40 godina na moru ima znatno veći rizik za određene vrste bolesti kao što su određene vrste raka, bolesti srca, alkoholne

[751] Hao, K. (2019). A.I. Is Sending People to Jail — and Getting It Wrong, MIT Technology Review

[752] Posadu broda čine osobe ukrcane za obavljanje poslova na brodu i upisane u popis posade. Za člana posade broda rabi se i naziv pomorac. Pomorcem se smatra osoba koja je zaposlena na pomorskom brodu i koja se ubraja u brodsku posadu odnosno svaka osoba koja je uvedena (upisana) u popis posade, bez obzira na to vrši li na brodu neku službu koja se eventualno izravno ne odnosi na plovidbu i koja bi takve poslove mogla vršiti i na kopnu. Bolanča, D. (1999). Pomorsko pravo (odabrane teme), Sveučilište u Splitu, Pravni fakultet, str. 64.

[753] Prema Konvenciji o pomorskom radu iz 2006. koja je stupila na snagu 20. kolovoza 2013. godine, pomorcem se smatra svaka osoba koja je zaposlena ili angažirana ili radi u bilo kojem svojstvu na brodu na koji se konvencija odnosi. Više o konvenciji na: https://www.ilo.org/wcmsp5/groups/public/---ed_norm/---normes/documents/normativeinstrument/wcms_763684.pdf

jetre, gubitka sluha te oštećenja kralježnice i zglobova.[754] Prema Međunarodnom medicinskom vodiču za brodove kojeg je izdala WHO definirana su i objašnjena postupanja u slučaju raznih ozljeda i bolesti koje mogu zateći pomorce na moru, odnosno minimalne zdravstvene usluge. Osim toga, značajan doprinos u zaštiti zdravlja pomoraca reguliran je i kroz Konvenciju o zdravstvenoj zaštiti i medicinskoj skrbi (pomorci) iz 1987. izdanu od ILO-a.[755] Navedenom konvencijom, između ostalog, uređuju se elementi prema kojima svaka stranka konvencije mora usvojiti mjere kojima se osigurava zdravstvena zaštita i zdravstvena skrb pomoraca na brodu. Minimalne mjere odnose se na:

- osiguranje primjene svih općih odredbi o zaštiti zdravlja na radu i medicinskoj njezi koje se odnose na pomorsku profesiju, kao i posebnih odredbi svojstvenih radu na brodu,
- težnji ka pružanju zdravstvene zaštite i medicinske zaštite pomorcima što je moguće usporedivije s onom koja je općenito dostupna radnicima na kopnu,
- pravo pomorcima da bez odlaganja posjete liječnika u lukama u kojima se to može,
- pružanje besplatne medicinske skrbi i zdravstvene zaštite dok pomorac služi i
- mjere prevencijskog karaktera, a posebnu pozornost posvećuju razvoju programa promicanja zdravlja i zdravstvenog obrazovanja kako bi pomorci sami mogli igrati aktivnu ulogu u smanjenju učestalosti lošeg zdravlja među strukom.[756]

Analizirajući navedene konvencije i preporuke jasno je da se one odnose isključivo na ljude. Međutim, može se smatrati relevantnim definirati nužne elemente dodijeljene AI pomoću kojih bi se vrednovala trenutna i opća „sposobnost“ sustava AI u upravljanju brodom i brodskim procesima. Tako se smatra potrebnim uvijek moći odrediti „stanje AI“ u određenom trenutku i to udaljenim djelovanjem. Također, određivanje „stanja AI“ na obali i od obalno te testiranje istog može biti važno u determiniranju „zdravlja AI“ odnosno sigurnosti korištenja sustava i predstojećim plovidbenim rutama. U tom smislu može se razmotriti i sustav certificiranja sustava AI od nadležnih pomorskih organizacija čime bi se potvrdila trenutna primjena AI. Prilikom provođenja ankete o stavovima eksperata u području AI iz pravnog, sociološkog i

[754] WHO (2007). International medical guide for ships, dostupno na: https://apps.who.int/iris/bitstream/handle/10665/43814/9789240682313_eng.pdf;jsessionid=0E0D2D673D04511C794DC700B308BD02?sequence=1

[755] C164 - Health Protection and Medical Care (Seafarers) Convention, 1987 (No. 164) dostupna na: http://www.ilo.org/dyn/normlex/en/f?p=NORMLEXPUB:55:0::NO::P55_TYPE,P55_LANG,P55_DOCUMENT,P55_NODE:REV,en,C164,%2FDocument

[756] Čl. 4. Konvencije o zdravstvenoj zaštiti i medicinskoj skrbi (pomorci), 1987 (No. 164)

sigurnosnog aspekta vidljivo je uvriježeno mišljenje da su nužna tipska odobrenja, tehničke i ostale specifikacije izdane od nadležnih regulatornih međunarodnih organizacija za AI kako bi se primjena AI u pomorskom prometu smatrala sigurnom.

4 UTJECAJ UMJETNE INTELIGENCIJE NA DRUŠTVO

Svaki napredak tehnologije značajno utječe na određeni dio društva odnosno na određeni poslovni i/ili korisnički sektor. Ako uzmemo u obzir da je u ljudskoj prirodi da banaliziraju određenu tehnologiju s protekom vremena samo zato jer su se na nju navikli, nužno je postaviti relevantne okvire za vrednovanje utjecaja tehnologija na društvo. Takve vrijednosne okvire treba postaviti posebno, odnosno jedan bi se trebao odnositi za poslovni sektor s različitim podsektorima, a drugi na korisnički sektor koji će sam po sebi biti nešto općenitiji.

Mnogo je primjera utjecaja tehnologije na društvo ponajviše u posljednjih nekoliko godina; plovila sama plove, automobili sami voze, strojevi prepoznaju lice i govor, virtualni glasovni asistenti nam pomažu u raznim kratkim ili automatiziranim zadaćama, računala pobjeđuju najbolje ljudske igrače složenih igara poput *Go* i sl. Nevjerojatno je da stroj može otkriti predmete, prevesti jezike, pa čak i napisati računalni kod nakon što mu se daju primjeri takvog ponašanja, umjesto da ga treba unaprijed programirati. To zapravo nije bilo moguće prije otprilike desetljeća, jer prije nije bilo dovoljno digitalnih podataka za potrebe obuke, a čak i da je bilo, nije bilo dovoljno računalne snage da sve to izvrši. Kako je računalni znanstvenik Sveučilišta u Torontu *Hector Levesque* napisao u svojoj knjizi *Common Sense,*[757] Turingov test i potraga za stvarnom AI, odnosno ideja prilagodljivog ML je „*nabaviti računalni sustav da nauči neko inteligentno ponašanje trenirajući ga na ogromne količine podataka*“. Budući da strojevi mogu obrađivati nadljudske količine podataka, nije više ni čudno što mogu kontrolirati brod i ploviti sigurnije od ljudi i isto to primijeniti na cestovni i zračni promet.

Unatoč tome, sve je ovo mali dio onoga što bi se razumno moglo smatrati pravom AI. *Patrick Winston,* profesor AI i računalnih znanosti na MIT-u, kaže kako bi bilo korisnije opisati razvoj događaja u posljednjih nekoliko godina u "računalnoj statistici", a ne u AI.[758] Isto tako, jedan od vodećih istraživača u *Eeldu, Yann LeCun, Facebook*-ov direktor za AI, rekao je na konferenciji *Future of Work* na MIT-u da su strojevi daleko od toga da imaju "bit inteligencije". To uključuje sposobnost razumijevanja fizičkog svijeta dovoljno dobro za proricanje njegovih osnovnih aspekata odnosno promatranje jedne stvari, a zatim korištenje prethodnog znanja kako

[757] Levesque, H. J. (2017). Common sense, the Turing test, and the quest for real AI, MIT Press
[758] Brown, R. H., Winston, P. H. (1984). Artificial intelligence, an MIT perspective, MIT Press

bi se utvrdilo koje druge stvari također moraju biti istinite.[759] S druge strane, kratkoročne prilike koje AI nudi društvu mogu biti spektakularne, ali pod uvjetom da takav sustav uspijemo učiniti i robusnim i nenametljivim. Zabrinutost za dobar utjecaj AI na društvo je razumljiv i povlači pitanje pametnog, sigurnog i poštenog korištenja takve tehnologije ili će ona pak iskriviti naše gospodarstvo i društvenu strukturu.[760]

Kakav je utjecaj AI na društvo? U odgovoru na ovo pitanje postoje mišljenja kako će promjene do kojih nužno vodi AI biti pozitivne, dok postoje i oni koji smatraju da će takve promjene biti izazovne. Kao i kod većine promjena u životu, svakako će biti i pozitivnih i negativnih utjecaja na društvo jer AI nastavlja transformirati svijet u kojem živimo. Kako će se to uravnotežiti tek nam preostaje vidjeti. O izazovima s kojima se treba suočiti govori i *Bernard Marr*[761]. Tako on naglašava kako će AI definitivno utjecati na razvoj ljudske radne snage s obzirom da postoji bojazan kako će AI preuzeti mnoštvo poslova ljudi zbog čega će ljudi ostajati bez posla. Upravo zato *Marr* navodi da će biti pravi izazov da se ljudi suoče s novim odgovornostima koje zahtijevaju njihove jedinstvene ljudske sposobnosti.[762]

Prema PwC-u[763] 7 milijuna postojećih radnih mjesta zamijenit će se s AI u UK od 2017. do 2037., ali moglo bi se otvoriti 7,2 milijuna novih radnih mjesta. Ova neizvjesnost i promjene načina na koji će neki zarađivati za život mogli bi biti izazovni. Transformativni utjecaj AI na naše društvo imat će dalekosežne ekonomske, pravne, političke i regulatorne implikacije o kojima se trenutno vode rasprave na globalnoj razini. Utvrđivanje tko je kriv ako autonomno vozilo ozlijedi pješaka ili kako upravljati globalnom autonomnom utrkom u naoružanju samo su neki od izazova s kojima se moramo suočiti. Postavljaju se pitanja hoće li strojevi postati super inteligentni i hoće li ljudi na kraju izgubiti kontrolu nad njima, a iako se raspravlja o tome

[759] Gomes, L. (2015). Facebook AI Director Yann LeCun on His Quest to Unleash Deep Learning and Make Machines Smarter, IEEE, dostupno na: https://spectrum.ieee.org/automaton/artificial-intelligence/machine-learning/facebook-ai-director-yann-lecun-on-deep-learning
[760] Brown, R. H., Winston, P. H., *op.cit.*
[761] Autor je bestselera, glavni govornik i savjetnik poduzeća i vlada. Surađivao je i savjetovao mnoge od najpoznatijih svjetskih organizacija. *LinkedIn* je nedavno Bernarda svrstao među 10 influencera na svijetu (zapravo, broj 5 - odmah iza *Billa Gatesa* i *Richarda Bransona*). Piše o temama inteligentnih poslovnih performansi za razne publikacije, uključujući *Forbes, HuffPost* i *LinkedIn Pulse*. Njegovi blogovi i prezentacija *SlideShare* imaju milijune čitatelja.
[762] Više o tome vidjeti na: https://bernardmarr.com/the-7-biggest-ethical-challenges-of-artificial-intelligence/
[763] PwC (2017). The economic impact of artificial intelligence on the UK economy, dostupno na: https://www.pwc.co.uk//economic-services/assets/ai-uk-report-v2.pdf

koliko će vjerojatan biti ovaj scenarij, znamo da uvijek postoje nepredviđene posljedice kada se uvede nova tehnologija. Ti neželjeni ishodi AI vjerojatno će za sve nas biti izazov.

Drugo pitanje je kako osigurati da AI ne postane toliko vješta u obavljanju posla koji je dizajniran da prelazi etičke ili zakonske granice. Iako je prvotna namjera i cilj AI da koristi čovječanstvu, ako se odluči na postizanje željenog cilja na destruktivan (ali učinkovit način) to bi negativno utjecalo na društvo. Algoritmi AI moraju biti na pravilan način izgrađeni kako bi se uskladili sa sveobuhvatnim ciljevima ljudi. Algoritmi AI pokreću se podacima. Kako se prikuplja sve više podataka u svakoj minuti svakog dana svake osobe, naša privatnost postaje kompromitirana. Ako bi državna tijela i poduzeća u tom slučaju donosili odluke na temelju podataka koje o nama prikupljaju kao što to čini Kina sa svojim sustavom socijalnih kredita, to bi moglo prerasti u socijalno ugnjetavanje. S druge pak strane, kad je riječ o pozitivnim utjecajima AI na društvo svakako treba kazati kako ona može dramatično poboljšati učinkovitost naših radnih mjesta i povećati obujam posla koji ljudi mogu obaviti. Tako *Marr* navodi da kad AI preuzme ponavljajuće ili opasne zadatke, to oslobađa ljudsku radnu snagu za posao za koji je bolje opremljena, odnosno zadatke koji uključuju kreativnost i empatiju među ostalima. Ako ljudi rade posao koji im je zanimljiviji, to bi moglo povećati sreću i zadovoljstvo poslom.[764]

Nadalje, s boljim mogućnostima praćenja i dijagnostike AI može dramatično utjecati na zdravstvenu zaštitu. Poboljšavanjem rada zdravstvenih ustanova i medicinskih organizacija AI može smanjiti operativne troškove i uštedjeti novac. Primjer za navedeno je procjena poduzeća *McKinsey* koja predviđa da bi BD mogli uštedjeti do 100 milijardi dolara lijekova godišnje.[765] Pravi će učinak biti u skrbi o pacijentima. Potencijal za personalizirane planove liječenja i protokole lijekova, kao i pružanje davatelja usluga boljeg pristupa informacijama u medicinskim ustanovama radi informiranja bolesnika promijenit će život. Osim toga, naše će društvo postići nebrojene sate produktivnosti samo uvođenjem autonomnog prijevoza utječući na probleme s gužvom u prometu što utječe na psihološko zdravlje društva. Oslobođeni stresnih putovanja ljudi će moći provoditi vrijeme na razne druge načine. Također, način na koji se otkrivaju i procesuiraju kaznena djela poboljšat će se uporabom AI, poput tehnologija

[764] Marr, B. (2019). What Is The Impact Of Artificial Intelligence (AI) On Society?, Intelligent Business Performance, dostupno na: https://bernardmarr.com/default.asp?contentID=1828
[765] McKinsey & Co. (2020). Transforming healthcare with AI: The impact on the workforce and organizations, dostupno na: https://www.mckinsey.com/industries/healthcare-systems-and-services/our-insights/transforming-healthcare-with-ai

prepoznavanja lica.[766] Stoga, možemo kazati kako će implikacije AI na društvo biti višestruke, s nadom da će AI općenito imati više pozitivnog nego negativnog utjecaja na društvo.

4.1. STANJE U SVIJETU POSLOVA

U ranijim poglavljima ovog rada više puta je spomenuta pozitivna implikacija AI na svijet poslova, osmišljena kao produžena ljudska ruka u obavljanju niza poslova koji olakšavaju rad ljudima. U ovom dijelu rada analizira se upravo utjecaj AI na ljudske poslove u svijetu s primjerom *Amazon-ovog* alata za novačenje i implikacije koje iz toga proizlaze. Također, analiziraju se vrste poslova koji bi mogli biti sigurniji od negativnog djelovanja AI, kao i onih koji su ugroženi. U primjeru *Amazon-a* AI se pojavila kao seksistički alat za zapošljavanje. Riječ je o tadašnjem *Amazon-ovom* tajnom alatu za novačenje AI koji je pokazao pristranost prema ženama. Iz članka *Reutersa* se navodi sljedeće: *„Stručnjaci za ML poduzeća Amazon.com Inc otkrili su velik problem: njihov novi sustav za zapošljavanje nije volio žene. Tim je od 2014. gradio računalne programe za pregled životopisa kandidata za posao s ciljem mehanizacije potrage za vrhunskim talentima, rekli su za Reuters pet ljudi upoznatih s tim radom. Zapravo je Amazon-ov sustav naučio da su muški kandidati poželjniji, a životopise koji su uključivali riječ "ženski" poput "kapetan ženskog šahovskog kluba" je degradirao. Tako je degradirao diplomirane studentice dvaju ženskih fakulteta.“*[767] *Amazon* je uređivao programe kako bi ih učinio neutralnima prema tim određenim uvjetima, ali to nije bilo jamstvo da strojevi neće osmisliti druge načine razvrstavanja kandidata koji bi se mogli pokazati diskriminirajućima. Dakle, postavlja se pitanje što je krenulo po zlu? U odgovoru na ovo pitanje za potrebe rada analiziran je članak *Julien Laureta* koji ističe da algoritmi nisu moralno pristrani, nemaju svijest, autonomiju i osjećaj morala.[768] Rade ono što njihovi dizajneri traže. Čak i podaci nisu pristrani. To znači da bismo razumjeli što se dogodilo na *Amazonu* ili u bilo kojem projektu AI moramo razumjeti ljudske dizajnere, njihove ciljeve, resurse koje su imali i izbore koje su morali donijeti. Tu se navode tri ključne komponente: poslovni cilj, podaci, funkcija cilja i troškova. Kad je riječ o poslovnom cilju, *Reuters* o poslovnom cilju *Amazon-ovog* tima navodi sljedeće: „*Eksperimentalni alat za zapošljavanje poduzeća koristio je AI kako bi kandidatima dao posao u rasponu od jedne do pet zvjezdica - slično kao što kupci ocjenjuju*

[766] Marr, B., *op.cit.*
[767] BBC (2018). Amazon scrapped 'sexist AI' tool, dostupno na: https://www.bbc.com/news/technology-45809919
[768] Lauret, J. (2019). Amazon’s sexist AI recruiting tool: how did it go so wrong?, Medium, dostupno na: https://becominghuman.ai/amazons-sexist-ai-recruiting-tool-how-did-it-go-so-wrong-e3d14816d98e

proizvode na Amazonu. Doslovno su željeli da to bude sustav koji funkcionira na način da mu se da 100 životopisa, a on će izbaciti onaj s pet zvjezdica i toga će zaposliti.“ Međutim, iz navedenog je vidljivo da se radi o pomalo nejasnom i nerealnom cilju ako se uzme u obzir nekoliko koraka koji dovode do procjene neke osobe koja će biti dobra za određeni posao. Prije svega, i ljudi iz *Amazon-a* su potvrdili da nisu imali namjeru temeljiti odluku o zapošljavanju samo na temelju životopisa. Dakle, da bi se donijela odluka o zapošljavanju ponajprije se životopis provjerava, odnosno podaci iz njega, nakon čega slijedi intervju s kandidatom. Postavlja se pitanje zašto bi onda tim za znanost u *Amazon-u* smatrao da su informacije sadržane u životopisu dovoljne da algoritam ML pruži točne preporuke o zapošljavanju? Razumniji cilj bio bi pomoći u ponovnom prikazivanju i to pod pretpostavkom da se ljudski pregled i razgovor dogode nakon automatskog pregleda. Drugi element čine podaci, odnosno i ljudi i strojevi trebaju relevantne informacije kako bi donijeli odgovarajuću odluku o provjeri ili zapošljavanju. Koji su podaci bili dostupni *Amazon-ovom* timu? *Amazon-ovi* računalni modeli obučeni za provjeru podnositelja zahtjeva promatrali su obrasce u životopisima koji su se poduzeću predavali više od deset godina. Većina je potekla od muškaraca, što je odraz muške dominacije u tehnološkoj industriji. Grupa je stvorila 500 računalnih modela usredotočenih na određene funkcije i lokacije posla. Svakog su naučili prepoznati nekih 50 000 pojmova koji su se pojavili u prošlim životopisima kandidata. To znači da je *Amazon* vjerojatno koristio samo životopise koje su predali prošli kandidati pri čemu nastaje pristranost prema samoizboru. Algoritmi učenja pod nadzorom zahtijevaju ciljanu varijablu i funkciju troškova, dok zajedno predstavljaju "motivaciju za učenje" modela. Algoritmi AI imaju samo jednu potrebu, jednu želju i jedan cilj: minimizirati svoju troškovnu funkciju. U slučaju *Amazon-ovog* alata za zapošljavanje mogli bismo razmotriti nekoliko izbora za ciljanu funkciju, a suština problema je u tome što općenito algoritmi ML ne vole imati više ciljeva. Tim koji dizajnira softver mora izričito identificirati i ponderirati potencijalne trgovinske servise. Prije svega, ako je cilj odabir za razgovor, algoritam uči ponavljati odluke menadžera za zapošljavanje za odabir razgovora. Međutim, izvedba modela bit će u najboljem slučaju jednaka menadžerima za zapošljavanje ljudi. Ako su menadžeri pristrani prema ženama ili manjinama, takav će biti i model. Ako menadžeri loše odabiru kandidate s visokim učinkom, takav će biti i model.[769]

[769] *Ibid.*

Dakle, algoritmi nikada nisu seksistički. Rade ono što mi tražimo od njih, a ako ih odredimo da oponašaju menadžere koji su seksistički nastrojeni u procesu zapošljavanja, to čine bez ikakvog oklijevanja. Posljednje pitanje je funkcija troškova koja predstavlja način na koji dizajneri algoritama "motiviraju" svoje modele za učenje i postizanje svojih ciljeva. Primjerice, menadžer ocijeni kandidata s jednom zvjezdicom, ali model joj lažno daje ocjenu od tri zvjezdice. To je pogreška od dvije zvjezdice. Međutim, u konačnici ova pogreška nije bitna za odluku koju treba donijeti jer se kandidati s ocjenom 1 ili 3 neće zaposliti. Međutim, ako je menadžer dodijelio ocjenu od 5 zvjezdica za kandidata, a model joj daje 3,5 zvjezdice, tj. 1,5 zvjezdicu manje ovdje je pogreška manja u odnosu na prethodni primjer, ali znatno važnija jer se radi o kandidatu kojeg je trebalo zaposliti, ali će izgubiti priliku za posao zbog niže ocjene modela. Taj jednostavni misaoni eksperiment pokazuje zamku korištenja vrste funkcije troškova koja se naziva srednja apsolutna pogreška (engl. *Medium Apsolute Error* - MAE). Koristimo samo apsolutnu razliku između ciljanog rezultata kojeg definira čovjek i rezultata predviđenog strojem. To nije razumna funkcija troškova u tom okruženju. U slučaju *Amazona* članci ne pružaju dovoljno detalja o ciljanoj varijabli ili funkciji troškova. Na kraju, postavlja se pitanje što možemo naučiti iz *Amazon-ovog* neuspjeha? Jedan od mogućih odgovora je da se radi o pristranim podacima te da se odluke o dizajnu u kontekstu poslovnog cilja, podataka i troškovnoj funkciji čine tehničkim, ali uključuju poslovna razmatranja koja nadilaze matematiku i inženjerstvo. Ciljevi projekta vjerojatno su bili previše nejasno definirani. Relevantni dionici projekta, od menadžera do pravnika i marketing stručnjaka, vjerojatno su bili slabo informirani o mogućnostima i ograničenjima ML. U svakom slučaju, možemo zaključiti kako nisu bili dovoljno uključeni u odluke o dizajnu i razvoju. Ishod je bio alat koji je davao neprihvatljivo pristrane preporuke i morao se ukinuti.[770]

Osim navedenog primjera u obzir treba uzeti opći model determiniranja poslova koji su ugroženi implementacijom AI i poslova koji su sigurni od iste. Kako bi determinirali polazne modele nužno je postaviti ključna, polazna pitanja sekvencirana za različite tipove poslova. Za utvrđivanje sigurnosti ili nesigurnosti poslova vodimo se sljedećim odrednicama:

1. Poslovi tzv. "bijelog ovratnika"

1.1. Repetitivnost / strateška važnost:

[770] *Ibid.*

- Ima li vaš posao minimalno ponavljanje zadataka?
- Dolazite li redovito do uvida u informacije koje su važne za vašu tvrtku?
- Donosite li ključne odluke za vašu tvrtku?

1.2. Jednostavnost / složenost:

- Zahtijeva li većina odluka u vašem poslu složenost ili promišljanje?
- Morate li u svom poslu redovito učiti i razumjeti puno složenih informacija?

2. Poslovi tzv. "plavog ovratnika"

2.1. Spretnost / ponavljanje:

- Treba li vam najmanje godinu dana obuke da biste bili kvalificirani za svoj posao?
- Uključuje li vaš posao vrlo malo ponavljanja istih zadataka?

2.2. Fiksno okruženje / nestrukturirano okruženje

- Izvodi li se vaš posao svaki put u različitim okruženjima? (npr. taksist bi uvijek radio u istom taksiju)
- Je li vaše radno okruženje nestrukturirano?

3. Za sve poslove:

3.1. Ljudski kontakt / empatija / suosjećanje:

- Je li komunikacija i uvjeravanje jedan od najvažnijih dijelova vašeg posla?
- Provodite li > 30 % svog radnog vremena s ljudima koji nisu zaposleni u vašoj tvrtki (npr. kupci, potencijalni kupci, partneri)?
- Mjeri li se ključni dio vašeg radnog učinka koliko dobro komunicirate s ljudima?
- Da li vaš posao rezultira srećom, sigurnošću ili zdravljem onih kojima izravno služite?
- Vodite li ili upravljate ljudima u svom poslu?

U promišljanju odgovora na navedena pitanja i provedenim istraživanjima dolazi se do sljedećeg zaključka o najugroženijim poslovima:

- **Istraživanje prodaje i marketinga**

Istraživanje se čini složenim poslom koji je teško zamijeniti, ali "istraživanje" je preopterećena riječ. Kada se primjenjuje na istraživanje prodaje i marketinga (ili bilo koje istraživanje

podataka općenito), više se radi o prebiranju ogromnih količina podataka i stvaranju uvida, što je ljudima sve teže upravljati s toliko podataka, dimenzionalnosti i složenosti. *McKinsey* klasificira ove profesionalce kao „vrlo osjetljive“ na automatizaciju.

- **Djelatnici na obradi šteta iz osiguranja**

Djelatnici koji obrađuju zahtjeve za naknadu šteta iz osiguranja preplavljeni su umjerenim novčanim štetama, no da bi pravilno postupao sa svakim, on ili ona moraju pregledati ogromnu količinu podataka i nositi se s mnogo neizvjesnosti. Osiguravajuća društva često samo slučajno provjeravaju štete ili automatski nadoknađuju manje štete. S AI se sva potraživanja mogu provjeriti u odnosu na povijesne podatke kako bi se značajno smanjila prijevara[771] i imaju mnogo jaču numeričku osnovu za prilagodbe. Također, ključno je znati da je osiguranje kao industrija igra velikih brojeva, sa značajnom dobiti i općim troškovima te nedostatkom transparentnosti i simetrije informacija. Primarna je meta za razne prijevare i sl., koristeći AI i potpuno novi pristup (kao što je slučaj Limunada u SAD-u ili *WaterDrop* u Kini).[772]

- **Zaštitari**

Već postoje neki "sigurnosni roboti" poput *Knightscope*[773] koji se raspoređuju u uredima i fiksnim okruženjima. No, isplativija verzija bit će mnoge kamere povezane na sustav AI koji vrši nadzor. To može uključivati ne samo kamere i mikrofone, već i senzore dubine, detektore mirisa i termovizijske sustave. Izlazni podaci iz senzora ići će u AI radi provjere propusnosti sustava čak i kada je određeno područje neosvijetljeno, u plamenu ili ako je prostorija ispunjena plinom koji je opasan za čovjeka. Uz sve tehničke i tehnološke postavke i dalje će biti određen ljudski nadzor. Može se smatrati kako će uvijek biti potreban barem jedan zaštitar na licu mjesta

[771] Primorac, Ž. (2016). Effective strategies for detecting fraudulent claims in motor third party liability insurance. In Economic and Social Development (Book of Proceedings), 16th International Scientific Conference on Economic and Social, str. 299.

[772] *Waterdrop* je internetska tehnološka platforma osiguranja čiji je cilj poslovanja rješavanje problema visokih medicinskih troškova s kojima se susreću mnogi pacijenti. Izvještaj *Pear Video* kaže da je osoblje *Waterdropa*, raspoređeno u više od 40 gradova diljem Kine, obilazilo bolnice tražeći od pacijenata pokretanje projekata *crowdfundinga* i pretjerujući u svojim pričama kako bi privuklo suosjećanje i donacije. Izvještaj je također otkrio da osoblje nije provjerilo financijsku situaciju ciljanih obitelji. Također, *Pear Video* navodi da je u jednom slučaju predstavnik *Waterdropa* pomogao pacijentu da postavi cilj doniranja na 150 000 *yuana*, iako je polovica njegovih troškova pokrivena medicinskim osiguranjem. Uz to, tajni izvjestitelj je našao mali nadzor nad trošenjem donacija, a osoblje *Waterdropa* reklo je pacijentima da poduzeće ne traži nikakve dokaze.

[773] Američko poduzeće za sigurnosne kamere koje je osnovano 2013. godine sa sjedištem u *Mountain Viewu* u Kaliforniji. Cilj *Knightscopea* je dizajnirati, izraditi i implementirati robote nazvane *Autonomous Data Machines* (ADM) za upotrebu u praćenju ljudi u trgovačkim centrima, parkiralištima i četvrtima.

koji će prići ljudima, odlučiti u teškim situacijama i upravljati sustavom AI po potrebi. Ovo će biti dobro plaćen posao, tako da zaštitari mogu naučiti kako postati stručni korisnici sustava AI kako bi zadržali svoj posao.

- **Vozači kamiona**

S obzirom da se kamioni uglavnom voze autocestama, a autoceste su najlakši scenarij za autonomna vozila, vozači kamiona bit će među prvima koji će biti ugroženi nakon što ta tehnologija bude dostupna. Sindikati i lobisti mogu u nekim zemljama zaštititi radna mjesta nešto duže, ali tehnologije će se pokrenuti u drugim zemljama. Zemlje koje se prije lansiraju mogu imati koristi od poboljšanja tehnologije autonomnih kamiona, a kako AI postaje bolja, morat će riješiti problem raspodjele radnika odnosno osposobljavanja radne snage na slične poslove.

- **Novinari**

Kad je riječ o novinarskom poslu, većina vijesti u određenom trenutku imaju ponavljajući opis vrlo sličnih događaja poput prenošenja kvartalnih izvještaja o zaradi nekog poduzeća koja je uvrštena na tržište ili rezultat nogometne utakmice. To može pokriti AI, pa čak i videozapise iz više kutova s glasom. Također, AI može smisliti naslove koji su privlačni na temelju povijesnih podataka o klikovima (da ih urednik odobri i prilagodi). Novinari bi uskoro trebali naučiti koristiti AI za standardizirano izvještavanje i njegovati svoje druge vještine izvještavanja koje nije tako lako zamijeniti.

- **Knjigovođe i financijski analitičari**

Automatizacija će igrati važnu ulogu u budućnosti računovodstva, a knjigovodstvo će biti jedna od prvih na koje će utjecati. Automatski unos podataka i usklađivanje već preuzimaju veći dio knjigovodstvenih zadataka, a AI uočava uzorke koji pomažu vlasnicima poduzeća da steknu uvid. Budućnost računovodstva ovisit će o potrebi poduzeća za ljudskim doprinosom u ključnim informacijama. Ljudi zaposleni u ovom području trebali bi prijeći s transakcijskog i ponavljajućeg analitičkog posla na posao vođen uvidom. Izgradnja povjerenja i duboko razumijevanje vlasnika poduzeća bit će najmanje zamjenjiv posao u računovodstvu.

- **Osobe zaposlene na obavljanju investicijskih poslova**

U financijskoj industriji val automatizacije prvo je pogodio sektor za trgovinu robom. Mnoge vrste ulaganja uključuju ili analizu ogromne količine informacija, ili zahtijevaju nevjerojatno brzo donošenje odluka. Obje su vrste prikladne za AI. Primjeri su kvantitativno trgovanje, personalizirani robo-savjetnici i kapital uz kupnju s većim oslanjanjem na BD i AI za aktivno upravljane uzajamne fondove. Jasno je da još uvijek postoji mnogo pozicija za ulaganje na najvišoj razini u preuzimanjima tzv. "anđeoskim" ulaganjima i specifičnim vrstama kredita. No, broj visoko plaćenih ljudi koji će biti pogođeni u sljedećih 10 godina bit će značajan.

- **Radiolozi**

Preraspodjela poslova zbog AI nije ograničena samo na slabije plaćene poslove. Radiolozi u zapadnim državama poput SAD zarađuju 425 000 dolara godišnje.[774] AI je već pokazala performanse na ljudskoj razini za prepoznavanje određenih vrsta karcinoma (melanom, rak pluća) u rendgenskom snimanju, magnetskoj rezonanci ili CT-u. Tijekom globalne pandemije koronavirusa 2020. godine sustav AI je bio obučen za CT skeniranje pluća kako bi ubrzao dijagnozu liječnika o infekciji COVID-19 među pacijentima.[775] Iako će trebati neko vrijeme dok AI preuzme veći dio posla radiologa, ovo je definitivno posao koji bi se trebao naći na "udaru" AI.

- **Neki od poslova u pomorstvu**

Iako samo po sebi pomorstvo odnosno pomorski prijevoz ne spadaju na ovu listu, oni također nisu imuni na sve aktualne trendove automatizacije. Na terminalnim pristaništima već se sada uočava smanjenje broja radnika sa 25 na 8-10 odnosno na terminalima u kojima je broj radnika još uvijek oko 15, vidljivo je kako polovina njih ne zna što bi radila.[776] Na brodovima tehnologija smanjuje ljudske aktivnosti od strojarnice pa sve do mosta. Međutim, strojevi se još uvijek kvare i traži se uvijek siguran par ljudskih ruku i ljudskog znanja te kreativnosti, ali sveukupna potreba za starijim posadama se smanjuje. Veći brodovi ne zahtijevaju veće posade, a moderni brodovi koji zamjenjuju starije brodove zbog veličine omogućuju manje posade.[777]

---

[774] Podatak dostupan na: https://www.talent.com/salary?job=radiologist
[775] Više vidi na: https://healthcare-in-europe.com/en/news/ai-lung-scan-analysis-in-fight-against-covid-19-goes-european.html
[776] Kosmala, K. (2019). Maritime automation will not spare seafarers, dostupno na: https://splash247.com/maritime-automation-will-not-spare-seafarers/
[777] *Ibid.*

Čak i ako uzmemo u obzir scenarij u kojem su autonomna plovila još uvijek fantazija, realnost današnjih brodova s posadom i radnika u sustavu pomorstva je zabrinjavajuća za budućnost zapošljavanja u tom sektoru. Iako simulacije iznesene u izvješću *World Maritime University* iznenađujuće pokazuju da uvođenje visoko automatiziranih brodova smanjuje stopu rasta potražnje za pomorcima, povećanje opsega pomorske trgovine projicirane u sljedećih 20 godina znači da je predviđeni broj pomoraca potreban do 2040. godine znatno viši od trenutne razine. U nekim scenarijima navedenim u izvješću brojka je gotovo dvostruka od približno 1,6 milijuna pomoraca koji danas rade.[778] Za razliku od ostalih vrsta prijevoza, studija sugerira da se u pomorstvu usvajanje novih tehnologija tradicionalno događa u postupnim koracima. Očekuje se da će usvajanje autonomnih brodova pod ljudskim nadzorom doseći 11 % do 17 % do 2040. godine, a očekuje se da će ti brodovi raditi u nacionalnim i regionalnim jurisdikcijama i specijaliziranim prijevozima.[779]

S druge pak strane, neki od najsigurnijih poslova od utjecaja AI se smatraju sljedeći:

- **Psihijatri**

Psihijatri, socijalni radnici, bračni savjetnici; sve su to profesije koje zahtijevaju snažne komunikacijske vještine, empatiju i sposobnost pridobivanja povjerenja klijenata. To su najslabija područja za AI. Također, s vremenima koja se mijenjaju, rastućom nejednakošću i raspodjelom poslova, vjerojatno će se povećati potreba za tim uslugama.

- **Terapeuti**

Spretnost je jedan od izazova AI. Fizikalna terapija poput kiropraktike ili masažne terapije uključuje primjenu vrlo osjetljivih pritisaka i osjetilnih odgovora klijentovog tijela. Uz to, dodatni su izazovi prilagođavanje skrbi za svakog klijenta, posljedice povrede klijenta i potreba za interakcijom na nivou čovjek - čovjek. Ljudska interakcija uključuje[780] terapiju koja je u tijeku, stručne savjete, kratke razgovore, kao i ohrabrenje i empatiju. Ovi aspekti čine posao kratkoročno neprihvatljivim za AI.

---

[778] Schröder-Hinrichs, J.U., Song, D.W., Fonseca, T., Lagdami, K., Shi, X. (2019). Transport 2040: Automation, Technology, Employment - The Future of Work, World Maritime University Malmo, dostupno na: https://safety4sea.com/wp-content/uploads/2019/01/World-Maritime-University-Transport-2040-Automation-Technology-Employment-The-future-of-work-2019_01.pdf

[779] *Ibid.*

[780] Više o tome na: https://www.statista.com/statistics/1117974/healthcare-industry-profit-growth-by-sector/

- **Medicinski njegovatelji (medicinske sestre, njega starijih osoba)**

Očekuje se da će cjelokupna zdravstvena industrija znatno porasti zbog povećanih prihoda, većih koristi, smanjenja troškova skrbi i starenja stanovništva (što zahtijeva mnogo više skrbi).[781] Mnogi od ovih razloga potaknut će održivo okruženje u kojem AI pomaže analitičkim i ponavljajućim aspektima zdravstvene zaštite, jer se veći dio zdravstvene djelatnosti preusmjerava na pažljivost, suosjećanje, podršku i ohrabrenje.

- **Istraživači i inženjeri AI**

Kako AI raste, doći će do skoka potražnje na tržištu za profesionalcima u području AI. *Gartner*[782] procjenjuje da će u sljedećih nekoliko godina ta povećanja premašiti broj zamijenjenih radnih mjesta. Međutim, treba imati na umu da kako alati AI postaju sve bolji, tako će i neke početne pozicije u AI s vremenom biti automatizirane. Stručnjaci za AI morat će pratiti promjene, baš kao što su tijekom godina softverski inženjeri morali učiti o montažnom jeziku, jeziku visoke razine, objektno orijentiranom programiranju, mobilnom programiranju i sada AI programiranju.

- **Književnici**

Književnost i pisanje književnih djela jedna je od najviših razina kreativnosti u kojoj će AI biti slaba. Pisci moraju stvarati, kreirati, stilski oblikovati i prepoznatljivo ukrasiti svoj rukopis. Takva djela imaju originalne ideje, zanimljive likove, zanimljivu radnju, iznenađujuće emocije i pjesnički jezik. Sve je to teško ponoviti. Iako će AI moći pisati poruke na društvenim mrežama, prijedloge za naslove ili čak oponašati stilove pisanja, najbolje knjige, filmove i drame će pisati ljudi u dogledno vrijeme.

- **Učitelji, nastavnici i profesori**

AI će postati izvrstan alat za prosvjetu i obrazovanje, sposoban znati kako pomoći personalizirati obrazovni kurikulum na temelju kompetencija, napretka, sposobnosti i temperamenta svakog učenika. Međutim, obrazovanje će se više odnositi na pomaganje svakom studentu da pronađe ono što želi, pomaganje u usavršavanju sposobnosti svakog učenika da samostalno uči i biti mentor koji će svakom učeniku pomoći naučiti komunicirati s drugima i

[781] *Ibid.*
[782] Costello, K. (2020). Gartner Predicts the Future of AI Technologies, dostupno na: https://www.gartner.com/smarterwithgartner/gartner-predicts-the-future-of-ai-technologies/

steći povjerenje. To su poslovi koje mogu raditi samo prosvjetari, a zahtijevaju nizak omjer učenika i učitelja (poput 5:1 ili manje). Tako će u budućnosti biti stvoreno još puno takvih humanističkih učiteljskih mjesta.

- **Odvjetnici**

Vrhunski odvjetnici teško da će se morati brinuti o svom poslu. Kreativnost u traženju najboljih mogućih ishoda za svoje stranke kao i osvajanje povjerenja klijenata, godine rada u pravosudnom sustavu ili pak samouvjereni javni nastup pred sudom savršena su kombinacija složenosti, strategije i ljudske interakcije koje su teške za AI. Međutim, administrativni i pripremni posao odvjetnika u pregledu, analizi i preporukama dokumenata može se učiniti puno boljim pomoću AI. Mnoge će zadatke koje obavljaju odvjetnici poput sastavljanja ugovora i rješavanja sporova male vrijednosti sve više rješavati AI.

- **Računalni znanstvenici i inženjeri**

Kako informacijsko doba napreduje izvještaj *McKinsey*-a[783] pokazuje da inženjerska zanimanja poput informatičara, inženjera, IT administratora, IT radnica i sl. mogu očekivati da će se plaće u IT sektoru značajno povećati već do 2030. godine. Iako je opstanak ovakvih poslova trenutno zagarantiran, nužno je da radnici u tim sektorima budu u korak s tehnologijom, odnosno osiguraju jedinstvenost njihovog rada što znači nemogućnost automatizacije istih.

- **Znanstvenici**

Znanstvenici su jedno od najvažnijih zanimanja koje uključuje ljudsko stvaralaštvo. AI ih može optimizirati samo na temelju ciljeva postavljenih ljudskom kreativnošću. Iako AI vjerojatno neće zamijeniti znanstvenike, bila bi sjajan alat za iste. Na primjer, AI se može koristiti za testiranje moguće upotrebe poznatih lijekova za bolesti ili za filtriranje mogućih novih lijekova koje bi znanstvenici trebali razmotriti. Stoga se smatra kako će AI će značajno doprinijeti ljudima u znanosti.

[783] Manyika, J., Lund, S., Chai, M., Bughin, J., Woetzel, J., Batra, P., Ko, R., Sanhvi, S. (2017). Jobs lost, jobs gained: What the future of work will mean for jobs, skills, and wages, McKinesy Global Institute, dostupno na: https://www.mckinsey.com/featured-insights/future-of-work/jobs-lost-jobs-gained-what-the-future-of-work-will-mean-for-jobs-skills-and-wages#

- **Menadžeri / Voditelji**

Dobri menadžeri posjeduju vještine ljudske interakcije, uključujući motivaciju, pregovaranje, uvjeravanje i sl. Dobri menadžeri učinkovito će se povezati u ime poduzeća sa zaposlenicima i obrnuto. Još važnije, najbolji menadžeri su vođe koji uspostavljaju jaku kulturu i vrijednosti, a svojim djelovanjem i riječima potiču zaposlenike da ih slijede. Iako se AI može koristiti za upravljanje učinkom, menadžeri će i dalje biti ljudi. To znači čak i ako je menadžer samo birokrat koji sjedi za radnim stolom i zapovijeda zaposlenicima, njega će zamijeniti drugi ljudi, a nikako AI.[784]

4.2. UMJETNA INTELIGENCIJA U MEĐUNARODNOM POMORSKOM PROMETU

Društveni utjecaj AI na međunarodni pomorski promet jedno je od najzanimljivijih područja u kojem se istražuju značajke AI i njezine upotrebe u pomorskom prometu. Sustavi AI najvažniji su tehnološki razvoj našeg doba. AI i Industrija 4.0 imaju implikacije na pomorsku industriju kao i na svaki sektor. Budući da je pomorska industrija usko povezana s tehnološkim razvojem, AI i Industrija 4.0 koja se naziva tehnološkom revolucijom, vrlo su važni za ovaj sektor.[785] Inovacija u okruženju Industrija 4.0 odnosi se na konfiguracije međusobno povezanih fizičkih i digitalnih komponenata, sustava i infrastrukture,[786] koje omogućuju stvaranje novih poslovnih modela i pružanje novih pomorskih usluga. Stoga je Industrija 4.0 zbirka sofisticiranih, sveobuhvatnih interdisciplinarnih tehnologija koje obuhvaćaju napredak komunikacija, mikroelektronike i senzorske tehnologije, zajedno s inženjerstvom podataka i ML (računske i algoritamske tehnike inženjeringa), također tehnikama sigurnosti i kriptografije.[787] U brodarstvu je najveći naglasak na istraživanju i razvoju temeljen na IoT-u i analizi BD (engl. *Big Data Analytics* - BDA), a odnosi se na:

- primjenu prediktivnog održavanja,

[784] Lee, K. F. (2020). Top 10 safest jobs from AI, dostupno na: https://kaifulee.medium.com/top-10-safest-jobs-from-ai-1824cacd1954
[785] Cicek, K., Akyuz, E., Celik, M. (2019). Future skills requirements analysis in maritime industry, Procedia Computer Science, 158, str. 270-274.
[786] Lasi, H., Fettke, P., Kemper, H. G., Feld, T., Hoffmann, M. (2014). Industry 4.0, Business & information systems engineering, 6(4), str. 239-242.
[787] Jokioinen, E., Cross, B. (2017). Remote and Autonomous Ship- The next steps, dostupno na: http://docplayer.net/19502019-Remote-and-autonomous-ships-the-next-steps.html Chen, M., Mao, S. and Liu, Y. (2016). Big data: A survey, Mobile Networks and Applications 19(2), str. 171-209.

- nadzor energetske učinkovitosti,[788]
- platforme za praćenje emisija i
- sigurnosne platforme za praćenje kritičnih incidenata.[789]

Komercijalni softver za brodarska poduzeća (tj. platforme za nadzor performansi brodova / flote) i centralizirane platforme orijentirane na politike za podršku operativnim tijelima (tj. usluge temeljene na praćenju plovila u stvarnom vremenu) trenutno su u nastajanju. U pomorstvu, između ostalih, autonomni brodovi[790] [791]mogu činiti dio većeg pomorskog sustava i lanca opskrbe koji može uključivati npr. dodatna plovila, brodogradilišta ili lučke terminale i nadzirati ključne pokazatelje uspješnosti plovila i pojedinih strojeva te komponente za optimizaciju ukupne učinkovitosti veće flote ili čak pomorske logističke infrastrukture, sustava proizvodnje energije i trgovine, sustava proizvodnje robe i trgovine i sl. Kombinacija višestrukih, prethodno različitih sustava proizvoda i usluga, npr. flote, vremenski podaci, sustavi za trgovinu robom, može dovesti do sustava koji mogu proširiti postojeće industrijske granice i izazvati konkurentsku dinamiku.[792] Komplementarne računalne tehnologije poput *blockchain* tehnologije također omogućavaju pružanje značajne tehnološke podrške u pomorskoj trgovini. Očekuje se da će se konkurentna dinamika razvoja brodarske industrije proširiti i obuhvatiti nove proizvode (platforme, sustave) i usluge koji zajedno udovoljavaju široko redefiniranim poslovnim potrebama koje industrija služi. Nadalje, softverske komponente za upravljanje aspektima kibernetske sigurnosti brodara, kao i integracija s naslijeđenim poslovnim sustavima, npr. za praćenje brodova/flote ili upravljanje putovanjima te integracija s vanjskim izvorima informacija predviđeni su kao relevantni.[793]

Stoga se za Industriju 4.0 pretpostavlja da će imati ključnu ulogu u formiranju i funkcioniranju novih mreža za inovacije u brodarstvu, budući da se resursi (kiber-fizički, kapitalno intenzivni resursi), kao i informacije i znanje kombiniraju i razmjenjuju na nove

[788] Primorac, Ž. (2020). Suvremeni pravni izazovi smanjenja emisija stakleničkih plinova iz pomorskog prometa-međunarodna i europska perspektiva. Zbornik radova Pravnog fakulteta u Splitu, 57(3), 739-757.
[789] Ficco, M., Choras, M., Kozik, R. (2017). Simulation platform for Cyber-Security and Vulnerabillity Analysis of Critical Infrastructures, Journal of Computational Science 22, str. 6.
[790] Levander, O. (2017). Autonomous ships on the high seas, Engineering, IEEE Spectrum
[791] Autonomni plovni objekt je onaj plovni objekt koji ovisno o stupnju automatizacije i zahtjevima za neposrednim nadzorom stalne službe može ploviti bez ukrcane posade ili sa smanjenim brojem članova posade. (čl. 5. PZ-a)
[792] Loebbecke, C., Picot, A. (2015). Reflections on societal and business model transformation arising from digitization and big data analytics, The Journal of Strategic Information Systems; Porter, M. E., Heppelmann, J. E. (2014). How Smart, Connected Products Are Transforming Competition, Harvard Business Review
[793] Levander, O., *op.cit.*

načine koji stvaraju nove mogućnosti za prakse upravljanja uspostavljenim brodarskim poduzećima, kao i za nove sudionike koji djeluju u digitalnom pomorskom inovacijskom ekosustavu. Strukturni i povezani uvjeti za Industriju 4.0 prikazani su na slici 4-1.

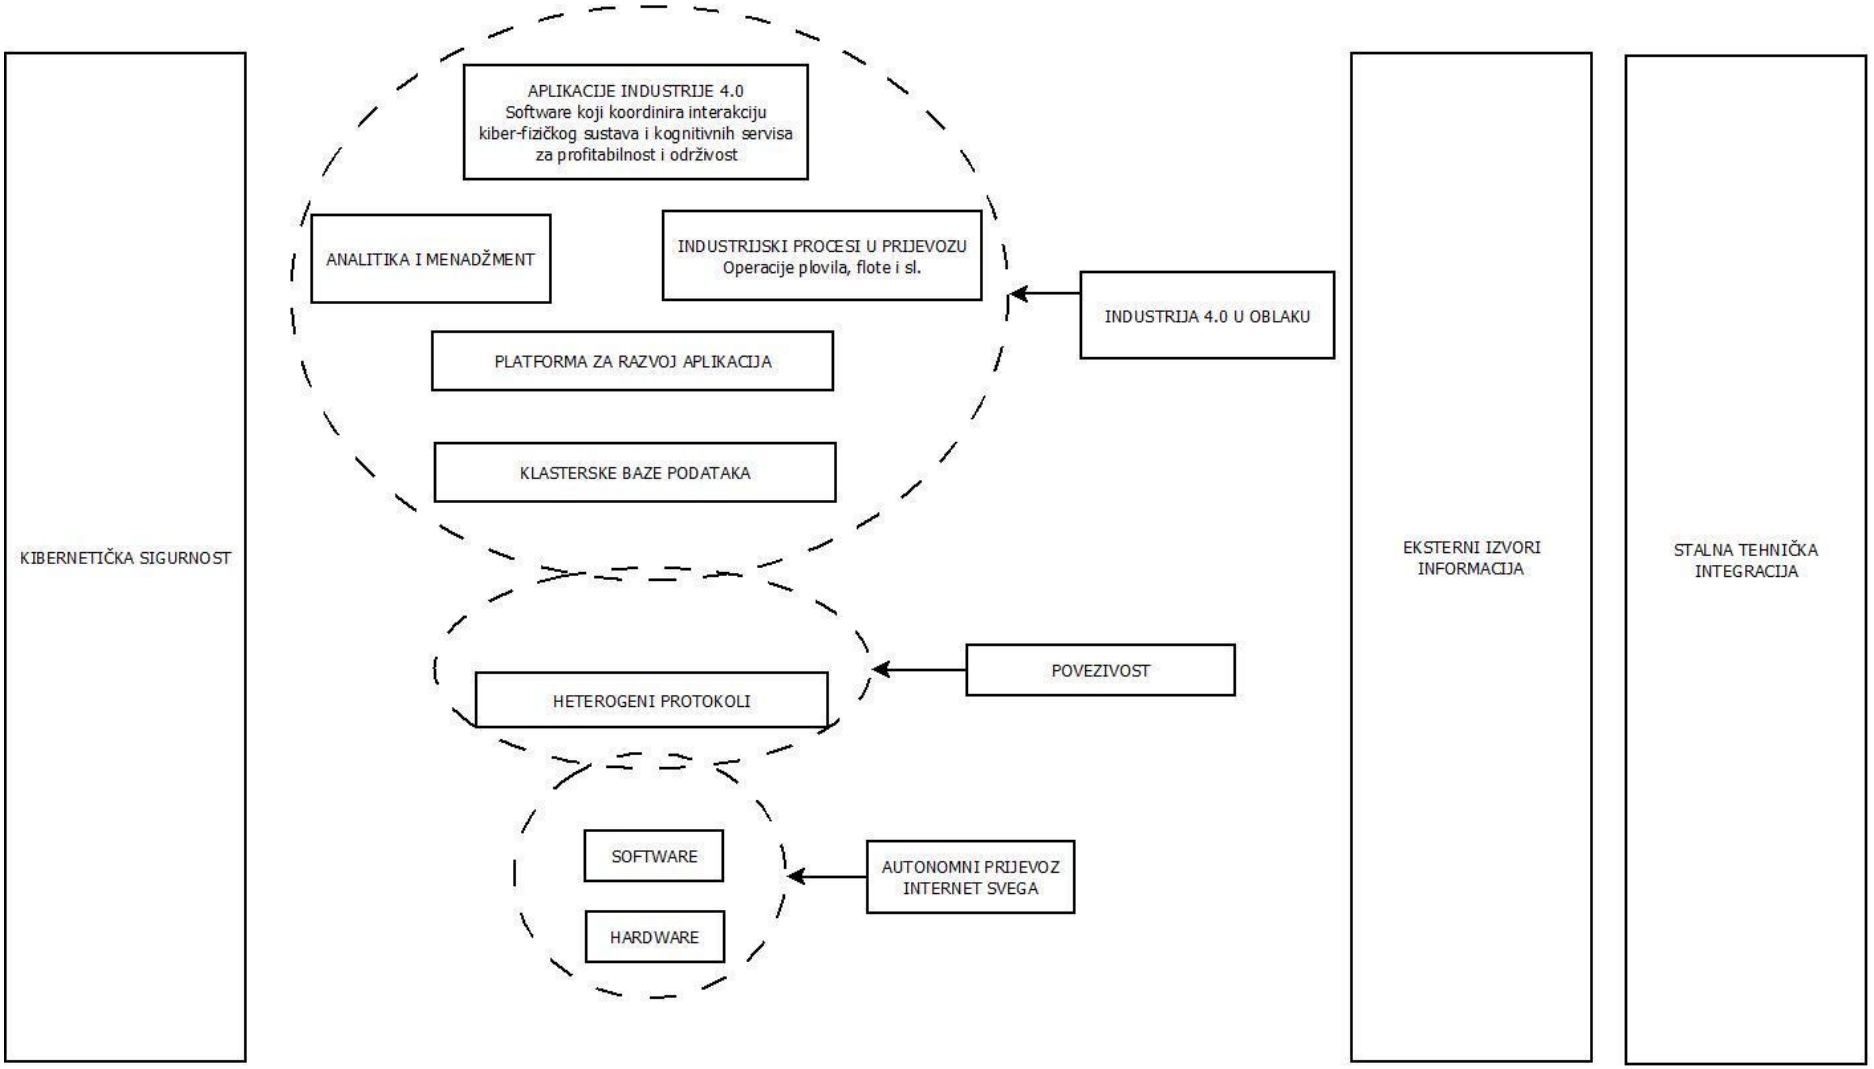

Slika 4-1 Povezani uvjeti za Industriju 4.0, Izvor: Izradio autor

Kao primjena novih tehnologija u pomorskom prometu pojavljuju se i kontejneri koji su vrlo atraktivni za poduzeća koja svoj proizvod prevoze istima te koji pokazuju sposobnosti najpouzdanijeg transporta. Razlog tomu je što su proizvodi koji se njime prevoze sigurniji, neoštećeni tijekom prijevoza, a informacije o pošiljci se mogu ažurirati automatizacijom.[794] Pametni uređaji za kontejnere prenose informacije o položaju sa satelitskih sustava za pozicioniranje i telemetrijske informacije kao što su temperatura, gorivo, vlaga i sl. s odgovarajućih osjetila do središnjeg mjesta prikupljanja podataka. Jednom kad se podaci prikupe pohranjuju se u banku podataka na središnjem poslužitelju, a korisnici mogu nadgledati spremnike na mreži zahvaljujući softveru, te mogu vidjeti podatke s uređaja i promijeniti alarm i status programa uređaja. Moduli za nadzor spremnika mogu se razlikovati za različite vrste spremnika dok se detektori otvaranja/zatvaranja otvora koriste za suhe posude, pored hladnjaka koji se koriste za logistiku hrane, pored senzora za vrata postoje senzori temperature, senzori vlage, tlaka, senzori koncentracije plina itd. Za spremnike u kojima se nalazi opasan kemijski materijal postoje senzori kuta rotacije, senzori ubrzanja, senzori razine tekućine, senzori tlaka, senzori curenja itd.[795] Iz navedenog se može zaključiti da postoji čitav niz korisnih informacija važnih u kreiranju ulaznih podataka u sustav AI.

4.3. PRILIKE I IZAZOVI U POVEZIVOSTI S UMJETNOM INTELIGENCIJOM

U posljednjih nekoliko godina AI se razvija primjenjujući tehnologije u cilju stvaranja odgovora na izazove poput sigurnosti hrane i zdravstvene zaštite. To se posebice očitovalo u slabije razvijenim dijelovima svijeta poput Afrike. Afrika je zbog svog zemljopisnog položaja posebno zanimljiva zemlja u odnosu na razvoj AI.[796] S obzirom da je afričkim znanstvenicima često bilo otežano sudjelovati na međunarodnim znanstvenim skupovima o AI osobito zbog problema s vizama, to nije utjecalo na procvat razvoja AI i ML u Africi posljednjih nekoliko godina. Lokalna skupina industrijskih stručnjaka i istraživača 2013. godine započela je *Data Science Africa*, godišnju radionicu za razmjenu resursa i ideja.[797] Tijekom posljednje tri godine

[794] Sarioglu, O., Muhsin, A. (2018). Lojistik surecte yeni bir uygulama ve sektorun bakisi: akilli konteyner, str. 2-6., dostupno na: http://www.otomasyondergisi.com.tr/arsivlyazi/104-lojistik-surecte-yeni-bir-uygulama-ve-sektorun-bakisiakilli-konteyner
[795] *Ibid.*
[796] ITU News (2020). Africa is at the AI innovation table and 'ready for the next wave', dostupno na: https://www.itu.int/en/myitu/News/2020/06/23/07/55/AI-for-Good-2020-Africa-innovation
[797] Više o tome na: http://www.datascienceafrica.org

akademici i industrijski istraživači s cijelog afričkog kontinenta počeli su s analizom budućnosti vlastite industrije AI na konferenciji pod nazivom *Deep Learning Indaba*. Konferencija okuplja stotine istraživača iz više od 40 afričkih zemalja kako bi predstavili svoj rad i razgovarali o svemu, od obrade prirodnog jezika do etike AI. Konferencija *Indaba* je izravan odgovor na zapadne znanstvene konferencije kojima istraživači iz udaljenih dijelova svijeta nisu mogli pristupiti.[798] Sveučilišni tečajevi i drugi obrazovni programi posvećeni poučavanju ML rastu kao odgovor na sve veću potražnju.[799] Krajem 2013. godine, *IBM Research* otvorio je svoj prvi afrički ured u Nairobiju te još jedan 2016. godine u Johannesburgu. *Google* je 2019. otvorio novi laboratorij AI u Akri (Gana), a sljedeće godine *ICLR*, velika istraživačka konferencija o AI, bila je domaćin događaja u Addis Abebi u Etiopiji.[800] IBM-ov rad u Keniji i Južnoj Africi i *Googleov* laboratorij za AI u Gani dijele istu misiju kao i njihove matične organizacije: provoditi temeljna i vrhunska istraživanja. Oni se usredotočuju na pitanja poput povećanja pristupa zdravstvenoj zaštiti koja se može dostaviti na tržište, čineći financijske usluge sveobuhvatnijima, jačajući dugoročnu sigurnost hrane i usmjeravanje vladinih operacija. Prije nego što je osnovao svoj laboratorij AI u Gani, *Google* je počeo raditi s poljoprivrednicima u ruralnoj Tanzaniji kako bi razumio neke izazove s kojima su se suočavali u održavanju dosljedne proizvodnje hrane. Istraživači su saznali da bolest usjeva može značajno smanjiti prinos pa su stvorili model ML koji bi mogao dijagnosticirati rani stadij bolesti u biljci manioke važnoj u glavnoj kulturi u regiji. Model koji radi izravno na mobilnim telefonima poljoprivrednika bez potrebe za pristupom Internetu pomaže im da ranije interveniraju kako bi spasili svoje biljke. Još je jedan primjer iz 2016. gdje je tim iz Johannesburga iz *IBM Research-a* otkrio da je postupak prijavljivanja podataka o karcinomu koje je vlada koristila za informiranje nacionalnih zdravstvenih politika trajao četiri godine nakon dijagnoze u bolnicama, dok u SAD-u ekvivalentno prikupljanje i analiza podataka traje samo dvije godine. Pokazalo se da je dodatno zaostajanje dijelom i zbog nestrukturirane prirode bolničkih izvještaja o patologiji. Stručnjaci su čitali svaki slučaj i klasificirali ga u jedan od 42 različita tipa karcinoma, ali tekst slobodnog oblika u izvješćima vrlo je dugo trajao. Tako su istraživači

[798] Primjer za to je Konferencija o neuronskim sustavima za obradu informacija, najpoznatiji sastanak posvećen umjetnim neuronskim mrežama. *NeurIPS* je održavana u odmaralištima *Westin* i *Hilton Resort and Spa* u *Whistleru BC* što je za istraživače iz Afrike često bilo izvan dosega. 2016. godine na konferenciji nisu prihvaćeni radovi iz afričkih zemalja. 2018. više od 100 istraživača odbilo je vize za ulazak u Kanadu za *NeurIPS*. O tome: Gershgorn, D. (2019). Africa Is Building an A.I. Industry That Doesn't Look Like Silicon Valley, Medium

[799] *Ibid.*

[800] Vidjeti na: https://edition.cnn.com/2019/04/14/africa/google-ai-center-accra-intl/index.html

krenuli raditi na modelu ML koji bi mogao automatski označavati izvještaje. U roku od dvije godine razvili su uspješan prototipni sustav i sada ga nastoje učiniti prilagodljivim kako bi mogao biti koristan u praksi. Reagiranje na potrebe korisnika također pomaže postići temeljni napredak u mogućnostima tehnologije. *Google-ov* laboratorij AI u Gani sada radi na poboljšanju razumijevanja prirodnog jezika kako bi se smjestilo u oko 2000 jezika koji se govore u Africi, koja se smatra jezično daleko najraznolikijim mjestom na Zemlji.[801]

Neki autori ističu privlačnost ulaganja u Afriku, između ostalog, zbog činjenice da 75 % kontinenta još uvijek nema pristup Internetu. To je izazov za lokalno stanovništvo, ali i mogućnost ulaganja za međunarodna tehnološka poduzeća. Kineska poduzeća godinama su ulagala u afričku tehnološku infrastrukturu. *Huawei* je instalirao nadzorne kamere oko Nairobija u ime kenijske vlade, a poduzeće trenutno radi na velikim nadzornim sustavima prepoznavanja lica oko Zimbabvea. Sva ta strana ulaganja i prikupljanje podataka pokreću probleme s eksploatacijom. Svjesni tih problema organizatori konferencije *Indabe* nastoje uravnotežiti međunarodne sponzore s lokalnim i ističu mogućnosti na afričkim sveučilištima i tehnološkim poduzećima u cilju oplemenjivanja upotrebe AI pogotovo u zemljama u razvoju.[802]

4.4. MOGUĆNOSTI I OGRANIČENJA UMJETNE INTELIGENCIJE

U raspravama o AI postoji stalna bojazan hoće li AI prestići ljudski um, odnosno hoće li ga nadmašiti? *Googleov DeepMind* se specijalizirao za algoritme DL koji dizajnirano oponašaju ljudski mozak. Stvarnost je takva da je trenutno stanje AI još uvijek daleko od toga da može prestići ljude. Smatra se da AI ima svoje prednosti i ograničenja.[803] Prvo ograničenje AI odnosi se na dostupnost podataka. Trenutni napredak viđen u ML u kojem se softver sada može učiti i poboljšavati uvjetovan je usitnjavanjem BD za specifični zadatak koji uči izvoditi. Uzmimo za primjer softver AI koji je obučen za klasificiranje različitih modela automobila na temelju slika s Interneta. Vremenom može postati sve bolji i bolji samo ako mu se da ogromna količina slika za analizu i ako mu ljudski operater da povratne informacije o tome koje su pretpostavke bile ispravne ili pogrešne. Međutim, ne postoji mogućnost da softver na neki način nauči dizajnirati automobil apsolutno samostalno. Trenutna AI također je u stanju istraživati i

[801] Hao, K. (2019). The Future of AI Is in Africa, MIT Techonlogy Review
[802] Gershgorn, D., *op.cit.*
[803] Chowdhury, M., Sadek, A. W. (2012). Advantages and limitations of artificial intelligence, Artificial intelligence applications to critical transportation issues, 6(3), str. 360-375.

organizirati informacije ako ih se hrani bazom podataka tekstualnog sadržaja što znači kako u slučaju „hranjenja“ takvog softver za AI, primjerice, udžbenicima za dizajn i inženjering automobila, on može istaknuti i sažeti ključne informacije. Međutim, čak i ako tu mogućnost dodamo ranijoj za prepoznavanje slika automobila, softver AI i dalje neće moći samostalno dizajnirati i konstruirati novi automobil, dok s druge strane čovjek koji uči može dizajnirati automobil s obzirom na dovoljno obrazovanja i prirodnih sposobnosti.

Drugo ograničenje AI, osim dostupnosti podataka, je računalna snaga. Trenutni matematički pokretački softver za AI postoji već mnogo desetljeća. Tada računala još nisu bila dovoljno jeftina ili brza da bi njihove potencijalne aplikacije učinila realnima ili korisnima. Danas je situacija posve drukčija, pri čemu algoritmi DL nisu novi, ali računalni čipovi koji ih pokreću jesu. Kako bi se umjetne računalne snage približile sposobnostima ljudskog mozga trebali bismo stvoriti kvantno računalo. Takva je tehnologija još uvijek u ranoj fazi. Ne možemo sa sigurnošću reći kada će kvantna računala postati *mainstream*, ali sa sigurnošću možemo reći da na temelju inženjerskih principa trenutna tehnologija integriranog kruga koja pokreće računske sposobnosti konvencionalnih računala nikada neće moći replicirati ljudski mozak, a još manje ga premašiti u intelektualnim sposobnostima.

Treće ograničenje AI vodi se sintagmom da ne možemo nadmašiti ono što još uvijek ne razumijemo u potpunosti. Vrsta računalne matematike koja je potaknula trenutni napredak u AI naziva se neuronska mreža koja je inspirirana ljudskim mozgom. Međutim, moderna znanost još uvijek nije u potpunosti razumjela kako mozak radi. Bez ovog razumijevanja niti jedan ljudski znanstvenik nikada ne bi mogao programirati AI koja može nadmašiti ljudski mozak. Dok neuroznanost ne sustigne, softver neće moći oponašati kreativne ili prilagodljive sposobnosti ljudskog uma koje su istinske granice ljudske inteligencije koje još uvijek mogu poraziti stroj.[804]

U odnosu na ograničenja AI postavlja se pitanje utjecaja *AlphaGo* u pobjedi nad čovjekom? Radi se o softveru Google *DeepMind* koji je u ožujku 2016. pobijedio svjetskog prvaka *Go*.[805] *AlphaGo* je dizajniran za jedan specifičan zadatak - pobijediti *Leeja Sedola*. Stvarnost je takva da je *AlphaGo* posebno dizajniran da se istakne samo u igranju *Go* kako bi

[804] Ng, L. (2018). On the potential & limits of AI – The facts beneath the hype, dostupno na: https://lancengym.medium.com/3-simple-reasons-why-ai-will-not-rule-man-yet-22d8069d8321
[805] Chang, H. S., Fu, M. C., Hu, J., Marcus, S. I. (2016). Google deep mind’s alphago, OR/MS Today, 43(5), str. 24-29.

mogao pobijediti *Leeja Sedola*, vladajućeg prvaka iz Južne Koreje. *DeepMind* je prošao kroz mnoge runde neuspjeha i novih vlastitih inačica. Čak su unajmili još jednog ljudskog velemajstora da više puta igra *AlphaGo* prije natjecanja kako bi otklonio njegove slabosti. Taj ljudski trener bio je europski prvak *Fan HAI*. Inače, *Fan HAI* je bio sudac na utakmici između *AlphaGoa* i *Leeja*. Dakle, *DeepMind* su pokušali podvrgnuti svoju AI općem IQ testu. AI je neuspješno propala u usporedbi s ljudima zbog nemogućnosti apstraktnog zaključivanja. Pojednostavljeno, AI nije mogla iskočiti iz obrazaca i zadataka za koje je osposobljena, čak i kad je odstupanje bilo vrlo malo. U svakom slučaju, smatra se da je AI vrlo dobra u specifičnom zadatku za koji je modelirana, ali tek nakon što su je obučili na BD i mnogim korektivnim iteracijama.[806]

4.5. NAPREDAK DRUŠTVA I KLASIFIKACIJA UMJETNE INTELIGENCIJE

Kao globalna zajednica zadnjih smo desetljeća zapanjujuće napredovali, rješavajući neke od najokrutnijih svjetskih tragedija. Primjerice, smanjila se smrtnost djece zahvaljujući miru i inovacijama. Tako se svakog dana rađa značajan broj djece koja bi umrla prije samo četvrt stoljeća.[807] Ipak, neki od najtežih izazova čovječanstva poput nejednakosti, nisu se popravili - zapravo su postali gori. Pothranjenost i bolesti koje se mogu spriječiti i dalje ubijaju milijune, opterećujući zdravstvene sustave i u bogatim i u siromašnim zemljama. Naši napori u suzbijanju bolesti ograničeni su nedostatkom obučenih medicinskih sestara i liječnika, kako u bogatijim, tako i u zemljama u razvoju. Zbog toga su znanost i tehnologija bili toliko kritični u povijesti civilizacije. Tehnološki napredak proširuje mogućnosti ljudskih postignuća povećavajući našu zajedničku sposobnost rješavanja problema koji su se nekad smatrali nerješivima. Već je ranije ukazano kako se očekuje da će AI imati više pozitivnih nego negativnih utjecaja na društvo. Jedan od takvih primjera je *DeepMind*, tehnologija za otkrivanje novih znanja, ideja i strategija pomoću algoritama koji uče iz podataka. Primjerice, svake godine oko 250 milijuna ljudi širom svijeta pati od različitih oblika gubitka vida. Nažalost, očekuje se da će se taj broj utrostručiti do 2050. godine, iako bi većina slučajeva bila izlječiva ako se prepoznaju u ranijoj fazi. Tehnologija skeniranja oka potrebna za otkrivanje ranog gubitka vida široko je dostupna, ali

[806] Chai, M., Manyika, J., Schwartz, D. (2018). The real-world potential and limitations of artificial intelligence, The McKinsey Quarterly
[807] Više o tome na: https://path.azureedge.net/media/documents/APP_epcmd_modeling_br2.pdf

jednostavno nema dovoljno kvalificiranih liječnika koji bi analizirali ove snimke i utvrdili koji su pacijenti najugroženiji. Tako su iz poduzeća *DeepMind* stvorili partnerstvo sa stručnjacima iz očne bolnice *MoorRelds* u Londonu kako bi razvili sustav za prepoznavanje i preporuku liječenja za nekoliko problema s vidom.[808] Postignuti su prijelomni rezultati, odnosno razina preciznosti od 94 % pri čemu je zaključeno da se tehnologija ponaša kao i kliničari s više od 20 godina iskustva. Premda još mora proći klinička ispitivanja i regulatorna odobrenja, ovaj projekt može biti revolucionaran u načinu liječenja očnih bolesti. To bi pak moglo uštedjeti milijune dolara za ekonomiju i omogućiti liječnicima da se više usredotoče na skrb o pacijentima. Sličan napredak događa se u mnogim medicinskim područjima. Algoritmi DL identificirali su više zloćudnih melanoma,[809] kao i studija ML o dijagnozi raka dojke koja je pokazala potencijal smanjenja nepotrebnih operacija za 30 %.[810]

Ako uzmemo u obzir ove pozitivne elemente AI, onda se postavlja pitanje što nas koči u njezinoj široj primjeni? Primarno, mogli bismo reći da se čovječanstvo još uvijek bori sa rješavanjem nekih elementarnih problema poput nedostupnosti čiste vode dok se radi na stvaranju personaliziranih gaziranih pića ili problema pothranjenosti dok se stvaraju ideje o novom načinu naručivanja hrane i sl. Zatim, ako želimo da tehnološki inovatori budu ambiciozniji u rješavanju velikih problema, onda također trebamo ambicioznija društva u pogledu upravljanja tim tehnologijama, usmjeravajući ih prema namjeravanoj koristi, a ne nenamjernoj šteti. Od širenja prepoznavanja lica u bespilotnim letjelicama do pristranog prediktivnog rada policije rizik je da pojedinačna i kolektivna prava zaostanu na društveno prihvaćenom putu u trci za tehnološkom prednošću. Kako bi se stvorio pravedniji svijet u koji je utkana AI nužne su institucije koje jamče etička načela i čuvaju ljudsko dostojanstvo kako se društva i tehnologije razvijaju. Pored ispravljanja principa, moramo ispraviti i praktične primjere. Ako se većina tehnoloških ulaganja usmjerila u područja koja su važna za društveni napredak, sporedni je učinak da neka od društveno najvažnijih infrastruktura koja bi najviše profitirala od pažljive i etičke upotrebe AI još nisu spremna za promjenu.

---

[808] Više o tome na: https://www.moorfields.nhs.uk/landing-page/deepmind-health-research-partnership

[809] Više o tome: Computer learns to detect skin cancer more accurately than doctors, dostupno na: https://www.theguardian.com/society/2018/may/29/skin-cancer-computer-learns-to-detect-skin-cancer-more-accurately-than-a-doctor

[810] Više o tome: Downey, A. (2021). Study to look into how AI could reduce breast cancer diagnosis time, Digital Heatlh, dostupno na: https://www.digitalhealth.net/2021/03/artificial-intelligence-could-reduce-time-to-diagnose-breast-cancer/

Većina zdravstvenih podataka još uvijek je pohranjena na papiru, a javni podaci često se čuvaju u neusklađenim formatima, što ograničava sposobnost AI da pomogne u pružanju rješenja. Podržavanje nove ere otvorenih, provjerljivih podataka i ulaganje u digitalizaciju postavit će neophodne temelje za otkrića koja su nam prijeko potrebna.[811]

Kada je riječ o klasifikaciji AI, onda se često postavlja pitanje od kojih se alata sastoji AI, odnosno na koji način AI uči razmišljati. Pri klasifikaciji AI postavljaju se problemi za koje je korištena AI poput: a) obrazloženja - sposobnost rješavanja problema, b) znanja - sposobnost predstavljanja i razumijevanja svijeta, c) planiranja - sposobnost postavljanja i postizanja ciljeva, d) komunikacije - sposobnost razumijevanja jezika i govora i e) percepcija - sposobnost pretvaranja sirovih senzorskih unosa (npr. slika, zvukova itd.) u korisne informacije.[812] Temeljno pitanje je je li ova klasifikacija dovoljno velika da obuhvati sav spektar problema s kojima se trenutno suočavamo ili treba dodati još slučajeva poput kreativnosti ili mehaničkih pokreta.

Konačno, postoji relevantna klasifikacija AI, točnije 5 različitih vrsta analitike: deskriptivna analitika (što se dogodilo), dijagnostička analitika (zašto se nešto dogodilo), prediktivna analitika (što će se dogoditi), analitika na recept (preporučivanje radnji) i automatizirana analitika (poduzimanje radnji automatski).[813] U cilju razvoja nove klasifikacije predlaže se puni popis tehnologija uključenih u sustave AI:

- robotska automatizacija procesa (RPA): tehnologija koja izdvaja popis pravila i radnji koje treba izvršiti promatrajući korisnika kako izvršava određeni zadatak,
- ekspertni sustavi: računalni program koji ima strogo kodirana pravila za oponašanje ljudskog procesa donošenja odluka. Neizraziti sustavi su specifični primjer sustava temeljenih na pravilima koji mapiraju varijable u kontinuum vrijednosti između 0 i 1, suprotno tradicionalnoj digitalnoj logici koja rezultira ishodom 0/1,
- računalni vid (CV): metode za stjecanje i razumijevanje digitalnih slika (obično se dijeli na prepoznavanje aktivnosti, prepoznavanje slika i strojni vid),

[811] Suleyman, M. (2018). AI Offers a Unique Opportunity for Social Progress, dostupno na: https://www.economist.com/open-future/2018/09/20/ai-offers-a-unique-opportunity-for-social-progress
[812] Corea, F. (2018). AI Knowledge Map: how to classigy AI technologies, dostupno na: https://francesco-ai.medium.com/ai-knowledge-map-how-to-classify-ai-technologies-6c073b969020
[813] Yampolskiy, R. V. (2012). AI-complete, AI-hard, or AI-easy–classification of problems in AI, The 23rd Midwest Artificial Intelligence and Cognitive Science Conference, Cincinnati, OH, USA

- obrada prirodnog jezika (NLP): pod-polje koje obrađuje podatke o prirodnom jeziku (tri glavna bloka pripadaju ovom polju, tj. razumijevanje jezika, generiranje jezika i strojno prevođenje),
- neuronske mreže (NN ili ANN): klasa algoritama labavo oblikovana prema neuronskoj strukturi ljudskog/životinjskog mozga koja poboljšava svoje performanse bez izričitih uputa o tome. Dvije glavne i dobro poznate podklase nacionalnih mreža su DL i GAN,
- autonomni sustavi: pod-polje koje leži na sjecištu između robotike i inteligentnih sustava (npr. inteligentna percepcija, spretna manipulacija objektima, upravljanje robotom zasnovano na planu, itd.),
- distribuiranja AI (DAI): klasa tehnologija koje rješavaju probleme distribuirajući ih autonomnim "agentima" koji međusobno komuniciraju. Sustavi s više agenata (MAS), modeliranje zasnovano na agentima (ABM) i inteligencija roja tri su korisne specifikacije ove podskupine, gdje kolektivno ponašanje proizlazi iz interakcije decentraliziranih samoorganiziranih agenata,
- afektivno računarstvo: pod-polje koje se bavi prepoznavanjem, interpretacijom i simulacijom osjećaja,
- evolucijski algoritmi (EA): podskup je šire domene računalne znanosti koja se naziva evolucijsko računanje koja koristi mehanizme nadahnute biologijom (npr. mutacija, reprodukcija itd.) u potrazi za optimalnim rješenjima. Genetski algoritmi su najčešće korištene podskupine EA, koje su heuristike pretraživanja koje slijede prirodni postupak odabira za odabir rješenja kandidata,
- induktivno logičko programiranje (ILP): pod-polje koje koristi formalnu logiku za predstavljanje baze podataka činjenica i formuliranje hipoteze koja proizlazi iz tih podataka,
- mreže odlučivanja: uopćavanje najpoznatijih *Bayesovih* mreža/zaključaka koji predstavljaju skup varijabli i njihove vjerojatne odnose putem karte (koja se naziva i usmjereni aciklički graf),
- probabilističko programiranje: okvir koji ne prisiljava na varijablu tvrdog koda, već djeluje s probabilističkim modelima. *Bayesova* sinteza programa (BPS) je oblik programiranja, gdje *Bayesovi* programi pišu nove *Bayesove* programe (umjesto da to rade ljudi, kao u širem pristupu programiranju) i

- ambijentalna inteligencija (AmI): okvir koji zahtijeva od fizičkih uređaja da u digitalna okruženja osjete, percipiraju i reagiraju svjesnošću konteksta na vanjski podražaj (koji se obično pokreće ljudskim djelovanjem).

Sve navedene klasifikacije i vrste analitika mogu se koristiti na način da jedna drugu nadopunjuju što je svakako težak zadatak za računala da nauče obavljati zadatke bez da su za to programirani.[814]

4.6. ASILOMARSKI PRINCIPI UMJETNE INTELIGENCIJE

Riječ je o principima AI koji su razvijeni na konferenciji u Asilomaru 2017. godine. AI je već pružila blagotvorne alate koje svakodnevno koriste ljudi širom svijeta. Daljnji razvoj AI, vođen sljedećim načelima, očekuje se pružiti nevjerojatne mogućnosti za pomoć i osnaživanje ljudi u desetljećima i stoljećima koja su pred nama. Asilomarski principi se mogu predstaviti i kao načela o mogućim neželjenim ishodima, ili preporukama za sprječavanje takvog događaja. Na primjer, pod kategorijom etike i vrijednosti načelo utrke u naoružanju AI izjavljuje da treba izbjegavati utrku u naoružanju smrtonosnim autonomnim oružjem.[815] Već navedene tri kategorije asilomarskih principa, odnosno istraživanje, etika i vrijednosti te dugoročna pitanja mogu se primijeniti u kreiranju ključnih smjernica za upotrebu AI u međunarodnom pomorskom prometu.

Tablica 4-1 Asilomarski principi, Pitanja istraživanja, Izvor: Asilomar AI principles, Future Of Life Institute

Pitanja istraživanja	**Principi**
Cilj istraživanja	Stvaranje korisne inteligencije.
Financiranje	Ulaganja u AI trebala bi biti popraćena financiranjem istraživanja za osiguravanje njezine korisne upotrebe, uključujući pitanja iz informatike, ekonomije, prava, etike i

[814] Corea, F., *op.cit.*
[815] Asilomar AI principles, Future Of Life Institute. Ove principe do danas je potpisalo 1677 istraživača AI i 3662 ostalih.

	društvenih studija, poput pitanja: Kako možemo učiniti buduće sustave AI izuzetno robusnima tako da rade ono što mi želimo bez kvara ili hakiranja? Kako možemo razvijati svoj prosperitet automatizacijom, a istovremeno zadržati resurse i svrhu ljudi? Kako možemo ažurirati svoje pravne sustave kako bi bili pravedniji i učinkovitiji, kako bismo išli u korak s AI i upravljali rizicima povezanim s AI? S kojim nizom vrijednosti treba uskladiti AI i koji pravni i etički status treba imati?
Znanstveno-politička veza	Trebala bi postojati konstruktivna i zdrava razmjena između istraživača AI i kreatora politike.
Kultura istraživanja	Kulturu suradnje, povjerenja i transparentnosti treba njegovati među istraživačima i programerima AI.
Izbjegavanje utrka	Timovi koji razvijaju sustave AI trebali bi aktivno surađivati kako bi se izbjeglo zaobilaženje sigurnosnih standarda.

Tablica 4-2 Asilomarski principi, Etika i vrijednosti, Izvor: Asilomar AI principles, Future Of Life Institute

Etika i vrijednosti	**Principi**
Sigurnost	Sustavi AI trebali bi biti sigurni i pouzdani tijekom svog životnog vijeka tamo gdje je to primjenjivo i izvedivo.
Transparentnost neuspjeha	Ako sustav AI nanosi štetu, trebalo bi biti moguće utvrditi zašto.
Pravosudna transparentnost	Svako sudjelovanje autonomnog sustava u donošenju sudskih odluka treba pružiti zadovoljavajuće objašnjenje koje može revidirati nadležno ljudsko tijelo.
Odgovornost	Dizajneri i graditelji naprednih sustava AI dionici su moralnih implikacija njihove upotrebe, zlouporabe i djelovanja, s odgovornošću i mogućnošću oblikovanja tih implikacija.
Usklađivanje vrijednosti	Visoko autonomni AI sustavi trebaju biti dizajnirani tako da se njihovi ciljevi i ponašanja mogu uskladiti s ljudskim vrijednostima tijekom cijelog njihovog rada.
Ljudske vrijednosti	Sustavi AI trebaju biti dizajnirani i upravljani tako da budu usklađeni s ljudskim idealima (pravo, sloboda, kultura i sl.)
Osobna privatnost	Ljudi bi trebali imati pravo pristupa, upravljanja i nadzora podataka koje

	generiraju, s obzirom na moć sustava AI da analiziraju i koriste te podatke.
Sloboda i privatnost	Primjena AI na osobne podatke ne smije nerazumno umanjiti stvarnu ili opaženu slobodu ljudi.
Zajednička korist	AI bi trebala imati koristi i osnažiti što više ljudi.
Dijeljeni prosperitet	Ekonomski prosperitet stvoren od AI trebao bi se široko dijeliti u korist čitavog čovječanstva.
Ljudski nadzor	Ljudi bi trebali odabrati hoće li i kako delegirati odluke sustavima AI kako bi postigli ciljeve koje je odabrao čovjek.
Nesukobljavanje	Moć koja se daje kontrolom visoko naprednih sustava AI trebala bi poštivati i poboljšavati, a ne potkopavati socijalne i građanske procese o kojima ovisi zdravlje društva.
Utrka AI u naoružanju	Treba izbjegavati utrku u naoružanju smrtonosnim autonomnim oružjem.

Tablica 4-3 Asilomarski principi, Dugoročna pitanja, Izvor: Asilomar AI principles, Future Of Life Institute

Dugoročna pitanja	**Principi**
Oprez sposobnosti	Nema konsenzusa, trebali bismo izbjegavati pretpostavke u pogledu gornjih granica budućih sposobnosti AI.
Važnost	Napredna AI mogla bi predstavljati duboku promjenu u povijesti života na Zemlji, i trebala bi se planirati i njome se upravljati razmjernom pažnjom.
Rizici	Rizici koje predstavljaju sustavi AI, posebno katastrofalni ili egzistencijalni rizici, moraju biti podložni planiranju i ublažavanju razmjerno očekivanom učinku.
Rekurzivno samopoboljšanje	Sustavi AI dizajnirani za rekurzivno samopoboljšanje ili samokopiranje na način koji bi mogao dovesti do brzog povećanja kvalitete ili količine moraju podlijegati strogim sigurnosnim i kontrolnim mjerama.
Opće dobro	Super inteligencija se treba razvijati samo u službi široko podijeljenih etičkih ideala, a u korist čitavog čovječanstva, a ne jedne države ili organizacije.

4.7. MORALNE DILEME I AUTONOMNA NAVIGACIJA, UTJECAJ NA DRUŠTVO

U raspravama o sociološkim aspektima AI, vjerojatno jedno od najvažnijih pitanja zauzimaju moralne dileme u povezivosti s autonomnim plovilima/vozilima pri čemu se postavlja pitanje na koji način bi autonomni sustavi trebali donositi odluke primjerice u izbjegavanju prometnih nesreća možda i sa smrtnim posljedicama? Zapravo, autonomni sustavi moraju donositi odluke kao ljudi, ali još uvijek ne otklanjaju mogućnost sudara, samo smanjuju šanse da se to dogodi. Osim toga, tijekom nesreće autonomni sustavi ne biraju točno koga možda mogu ozlijediti, već odabiru kako ne ozlijediti.[816] Temeljno razmatranje koje programeri uzimaju u obzir jeste kakav postupak će autonomni sustavi poduzeti tijekom svog djelovanja. Stoga se postavlja pitanje tko, što i kako se donose odluke na kojima se temelji rad autonomnih sustava? Pri odgovoru na to pitanje treba istaknuti kako moralni izbori nisu univerzalni s obzirom da je moral subjektivnog karaktera. Dakle, umjesto univerzalnog morala postoji općeprihvaćeni konsenzus o tome što je „važnije za društvo". U jednom provedenom testu tako je utvrđeno kako među ljudima postoji preferencija spola na koju onda učimo i AI.[817] Tako su ljudi imali tendenciju spašavati djevojke u odnosu na dječake. Također, određene zemlje su pokazale uznemirujuću sklonost spašavanju ljudi višeg statusa, na primjer, rukovoditelja u odnosu na beskućnike. Otkriveno je da je taj problem prilično čvrsto povezan s razinom ekonomske nejednakosti u zemlji. Tamo gdje je bila veća nejednakost, bilo je više sklonosti žrtvovanju beskućnika.[818]

U tom kontekstu važno je definirati dileme u prometu. Dileme se definiraju kao kritične situacije u kojima će u određenom trenutku autonomni sustavi neizbježno naštetiti barem jednom sudioniku u prometu i/ili jednoj grupi sudionika u prometu, a ponašanje sustava na kraju će odrediti koja je skupina ili pojedinac oštećen.[819] U regulaciji razvoja i primjene autonomnih sustava kreatori politike mogu prihvatiti da ponašanje sustava u situacijama dileme može proizaći iz poštivanja načela upravljanja rizika. Upravljanje rizikom, između ostalog, odnosi se na korištenje autonomnih sustava za promjenu fokusa s ranjivih korisnika koji se trebaju prilagoditi opasnostima na cesti na sustave koji se trebaju prilagoditi ranjivim

[816] Nawrot, J., Vio, I. (2021). Autonomous vessels based on artificial intelligence: selection of regulatory approach – main challenges, 3. Međunarodna znanstvena konferencija pomorskog prava, Split
[817] Dobson, J. L. (2010). A comparison between learning style preferences and sex, status, and course performance, Advances in physiology education, 34(4), str. 197-204.
[818] *Ibid.*
[819] Jeans, N. (2019). Moral Dilemmas of Self-Driving Cars, Toward Dana Science, dostupno na: https://towardsdatascience.com/moral-dilemmas-of-self-driving-cars-a52a7fb6f13a

sudionicima u prometu. To je u skladu s Etičkim smjernicama koje preporučuju da se posebna pažnja posveti ranjivim skupinama, ili onima koji nerazmjerno trpe zbog postojećih asimetrija moći u prometu. Primjerice, pretpostavimo da se utvrdi da biciklisti imaju nerazmjerno visok udio smrtnih slučajeva u odnosu na njihov udio izloženosti na cesti te da su automobilske nesreće uključene u značajan dio ovih smrtnih slučajeva. U takvom slučaju kreatori politike mogu zahtijevati od proizvođača i distributera da dokažu kako njihova vozila rade kako bi smanjili rizik za bicikliste, tako da se njihov omjer štete u odnosu na izloženost na cesti smanji. Sredstva za postizanje tog cilja mogu uključivati usporavanje kada se detektiraju biciklisti, ali i davanje biciklistima više prostora, čak i ako to ponašanje daje manje prostora ostalim manje osjetljivim sudionicima u prometu. Slično se može primijeniti i na pomorski promet definirajući potencijalne i ugrožene skupine na moru. Posebno se to odnosi na područja u kojima se odvija ili će se odvijati mješovita plovidba gdje u jednom trenutku u istom akvatoriju imamo različite vrste konvencionalnih plovila i autonomna plovila koja isto tako mogu biti specifične namjene. Također, važno je u obzir uzeti i jedno istraživanje provedeno na 240 ispitanika u simuliranim uvjetima u sklopu programa za profesionalne pomorce kroz tzv. *Bridge Resource Management i Ship simulator and Bridge Team Work* gdje je 67 ispitanika odbilo postupiti po naredbi zapovjednika koji je svjesno naložio rizičnu rutu za plovidbu.[820] Pitanje koje se može postaviti jest što ako sustav AI na autonomnom brodu namjerno dovede brod i/ili druge dionike pomorskog prometa u opasnost? Dakle, da bi došli do odgovora na pitanje kako autonomni sustav odlučuje o izbjegavanju sprječavanja ljudskih ozljeda u prometnim nesrećama, odnosno izbjegavanju sudara na cesti ili moru te biranja nepovoljnijih ruta, pri kreiranju autonomnih sustava mora se uzeti u obzir niz različitih scenarija uključujući situaciju u kojoj nije moguće pritisnuti kočnice ili promijeniti kurs, a sustav mora napraviti etičku odluku o tome koga oštetiti, a što će posljedično utjecati na odgovornost za štetu koja će nastati uporabom autonomnog plovila.[821] Problem je što ne postoji recept za ono što je 'ispravno', a što je 'pogrešno, pa je teško dobiti i odgovor na navedeno pitanje. Svatko bi od nas spasio različite ljude, pa koga bi onda etički programirani autonomni sustavi trebali slijediti?[822] U tom smislu poštivanje načela upravljanja rizikom trebalo bi osigurati da ponašanje sustava ne bude u suprotnosti s osnovnim

[820] Bielić, T., Mandžuka, S., Tomas, V. (2011). Model of ship management in emergencies. Promet – Traffic&Transportation, Vol 23, str. 474.
[821] Savić, I. (2021). Autonomni plovni objekti u pomorskom pravu Republike Hrvatske, 3. Međunarodna znanstvena konferencija pomorskog prava, Split, str. 29-49.
[822] Jeans, N., *op. cit.*

etičkim i pravnim načelima. Može se zaključiti da primjena AI na različitim razinama uzrokuje i različite razine moralnih dilema, djelomično, potpuno ili uopće nerješive.

4.8. ETIČNE DILEME ZNAČAJNIH GOSPODARSKIH SUBJEKATA

Razvoj i primjena AI uzrokuje velike podjele unutar i izvan tehnoloških poduzeća. Poduzeća koja vode istraživanja o AI u SAD-u i Kini, uključujući *Google, Amazon, Microsoft, Baidu, SenseTime* i *Tencent*, zauzele su vrlo različite pristupe o AI, kao i mišljenje treba li razvijati tehnologiju koja se u konačnici može koristiti za vojsku i nadzor. Na primjer, *Google* se izjasnio kako neće prodavati usluge prepoznavanja lica vladama, dok su *Amazon* i *Microsoft* u nedavnoj prošlosti to radili, a u čemu su u posljednje vrijeme odustali.[823] Također su napadnuti zbog algoritamske pristranosti njihovih programa, gdje računala nenamjerno šire pristranost nepravednim ili oštećenim unosima podataka.[824] Kao odgovor na kritike ne samo kompanija i akademika već i vlastitog osoblja, poduzeća su se počela samoregulirati pokušavajući uspostaviti vlastite inicijative "etike AI". Najčešća praksa bila je objavljivanje načela poduzeća za etičku AI. *Microsoft, Google, IBM* i drugi su objavili popise etike poduzeća,[825] dok su istraživačka tijela poput *Institute for Future of Life,* koja su razvila Asilomarske principe, pokušala natjerati znanstvenike iz cijelog svijeta da se prijave. Međutim, ono što se zamjeralo takvoj politici je nedostatak transparentnosti i provedbe navodeći da etički pristupi u industriji implicitno traže da javnost jednostavno vjeruje korporacijama na riječ kada kažu da će voditi svoje ponašanje na etički način. Mnoga su se poduzeća pridružila širim tijelima radi suradnje s akademskim krugovima, poslovanju i civilnom društvu. Jedan takav, *Partnership on AI,* 2017. godine osnovali su *Google, DeepMind, Facebook, Amazon, Microsoft* i *Apple*.[826] Partnerstvo sada broji gotovo 90 grupa, od kojih su polovica poduzeća poput *McKinseyja,* dok su ostatak neprofitne i druge institucije. U međuvremenu, u Kini poduzeća zauzimaju različite pristupe etičkoj AI. *De Kai*, računalni znanstvenik sa Sveučilišta za znanost i tehnologiju u Hong Kongu i član *Googleovog* kratkotrajnog etičkog vijeća, rekao je da su kineska poduzeća općenito više zaokupljena rješavanjem stvarnih problema za dobrobit

---

[823] Više o tome na: https://www.washingtonpost.com/gdpr-consent/?next_url=https%3a%2f%2fwww.washingtonpost.com%2ftechnology%2f2020%2f06%2f11%2fmicrosoft-facial-recognition%2f

[824] Moreau, J. T., Baillet, S., Dudley, R. W. (2020). Biased intelligence: on the subjectivity of digital objectivity, BMJ Health & Care Informatics, 27(3)

[825] Vidjeti na: https://vitalflux.com/ethical-ai-principles-ibm-google-intel/

[826] Više o tome na: https://www.partnershiponai.org/partners/

društva, umjesto da se usredotočuju na apstraktnost etičkih načela.[827] Međutim, kako oni definiraju "dobro" s nekih su strana bili predmet žestokih kritika. Kompanije s AI, kao što su *CloudWalk, Yitu* i *SenseTime*, udružile su se s kineskom vladom u uvođenju prepoznavanja lica i predviđanja rada policije, posebno među manjinskim skupinama poput ujgurskih muslimana. U konačnici, stručnjaci kažu da je ovo područje još uvijek u povojima, a za postizanje konsenzusa potreban je zajednički pristup privatnog i javnog sektora.[828]

Jasno je kako će kreiranje jedinstvenog etičkog okvira predstavljati značajne poteškoće posebice ako se u obzir uzmu raznolikosti pojedinačnih gospodarskih sektora. U tom pogledu potrebno je generirati jedinstveni opći okvir etičkih nužnosti s postupnom primjenom i nadopunjavanjem u pojedinačnim sektorima među koje spada i međunarodni pomorski promet.

4.9. PRIMJERI ISKORISTIVIH MOGUĆNOSTI PRIMJENE UMJETNE INTELIGENCIJE U POSEBNO PROBLEMATIČNIM PODRUČJIMA

U ovoj doktorskoj disertaciji je više puta navedeno kako AI ima i može imati dugoročne pozitivne učinke. Premda je njezina uporaba i implementacija u različite sfere društva ujedno i izazovna, Etičke smjernice navode primjere razvoja i upotrebe AI koje bi trebalo poticati, kao i primjere slučajeva u kojima razvoj, uvođenje ili upotreba AI može biti u suprotnosti s našim vrijednostima i dovesti do određenih dvojbi. Primarno, pouzdana AI može biti velika prilika za ublažavanje hitnih izazova s kojima se društvo suočava, kao što su starenje stanovništva, sve veća društvena nejednakost i onečišćenje okoliša. S obzirom da su klimatske promjene i održivi razvoj pitanja koja se nastoje rješavati na globalnoj razini, i Europa bi u tom smjeru mogla iskoristiti AI kao odgovor na takve izazove. Primjerice, pouzdana AI može se povezati s BD kako bi se točnije utvrdile potrebe za energijom, što bi dovelo do učinkovitije energetske infrastrukture i potrošnje. Nadalje, sustavi AI za pametne prijevozne sustave[829] mogu se upotrijebiti za smanjenje gužvi, optimizaciju ruta, povećanje neovisnosti slijepih i slabovidnih osoba,[830] optimizaciju energetski učinkovitih motora i time poboljšanje napora koji ulaze u

[827] Više o tome: Deng, I. (2019). People need to wake up to dangers of AI, warns Google ethics adviser, South China Morning Post, dostupno na: https://www.scmp.com/tech/big-tech/article/3004340/people-need-wake-dangers-ai-warns-hong-kong-professor-and-google

[828] Murgia, M., Shrikanth, S. (2019). How Big Tech Is Struggling With the Ethics of AI, Financial Times

[829] Nova rješenja koja se temelje na umjetnoj inteligenciji pomažu pripremiti gradove za budućnost mobilnosti. Vidjeti, na primjer, projekt Fabulos koji se financira sredstvima EU-a: https://fabulos.eu/

[830] Primjerice projekt *PRO4VIP* koji je dio europske strategije *Vision 2020* za suzbijanje sljepoće koja se može spriječiti, osobito sljepoće koja je posljedica starenja.

dekarbonizaciju i smanjenje ekološkog otiska radi postizanja zelenijeg društva. Nedvojbeno je da bi sustavi AI mogli pomoći da se znatno smanji broj smrtnih slučajeva u prometnim nesrećama, na primjer kraćim vremenom reakcije i boljim poštivanjem pravila. Kad je riječ o uporabi AI u zdravstvenom sustavu, tehnologije pouzdane AI mogu se upotrebljavati i već se upotrebljavaju za pametnije i usmjerenije liječenje te kao pomoć u sprječavanju bolesti opasnih po život.[831] Liječnici i zdravstveno osoblje mogli bi provoditi točnije i sveobuhvatnije analize složenih podataka o zdravlju pacijenta čak i prije nego što se ljudi razbole te bi mogli pružiti prilagođeno preventivno liječenje.[832] U kontekstu starenja europskog stanovništva, AI i robotika mogu biti vrijedni alati za pomoć pružateljima skrbi i potporu u skrbi za starije osobe jer se pomoću njih može pratiti stanje pacijenata u stvarnom vremenu, što pomaže u spašavanju života.[833]

Osim navedenog, pouzdana AI se može koristiti i u širem kontekstu, primjerice može ispitati i utvrditi opća kretanja u sektoru zdravstvene zaštite i liječenja[834] što bi dovelo do ranijeg otkrivanja bolesti, učinkovitijeg razvoja lijekova, preciznijeg liječenja[835] i naposljetku više spašenih života. Pozitivni učinci AI ogledaju se i u sustavu obrazovanja te u radnom sektoru. Tako bi sustavi AI mogli pomoći u točnijem predviđanju radnih mjesta i profesija na koje će AI utjecati, novih poslova koje će nastati i vještina koje će biti potrebne. To bi moglo pomoći vladama i industriji u planiranju (pre)kvalifikacije radnika. Građanima koji možda strahuju od otpuštanja moglo bi pružiti perspektivu za razvoj u novoj ulozi. Uz to, AI može biti odličan alat

---

[831] Primjerice projekt *REVOLVER* dostupan na: https://www.healtheuropa.eu/personalised-cancer-treatment/87958/ ili projekt Murab u kojem se obavljaju preciznije biopsije i kojim se nastoji brže dijagnosticirati rak i druge bolesti dostupan na: https://ec.europa.eu/digital-single-market/en/news/murab-eu-funded-project-success-story.

[832] Vidjeti, na primjer, projekt *Live INCITE*: www.karolinska.se/en/live-incite. Taj konzorcij naručitelja zdravstvene zaštite pred industriju je stavio izazov razvoja pametne AI i drugih rješenja IKT-a koja omogućuju intervencije u životnom stilu u okviru perioperativnog procesa. Cilj se odnosi na inovativna rješenja eZdravlja koja mogu personalizirano utjecati na pacijente kako bi oni poduzeli potrebne mjere u svom životnom stilu prije i nakon operacije, što će poboljšati zdravstveni rezultat.

[833] Vidjeti na primjer *MyHealth Avatar* (www.myhealthavatar.eu) koji pruža digitalan prikaz zdravstvenog stanja pacijenta. U okviru istraživačkog projekta pokrenute su aplikacija i internetska platforma koje prikupljaju digitalne informacije o dugoročnom zdravstvenom stanju osobe i daju joj pristup tim informacijama. To se odvija u obliku cjeloživotnog savjetnika za zdravlje („avatar"). *MyHealth Avatar* ujedno i predviđa rizik od moždanog udara, dijabetesa, kardiovaskularnih bolesti i povišenog krvnog tlaka.

[834] Vidjeti na primjer projekt *ENRICHME* (www.enrichme.eu) koji se bavi progresivnim smanjenjem kognitivnog kapaciteta stanovništva koje stari. Integrirana platforma za život potpomognut okolinom (AAL) i pokretni robot za usluge za dugoročno praćenje i interakciju pomoći će starijim osobama da dulje ostanu neovisne i aktivne.

[835] Vidjeti na primjer upotrebu AI u poduzeću *Sophia Genetics* koje iskorištava statističko zaključivanje, prepoznavanje uzoraka i ML kako bi se povećala vrijednost podataka iz genomike i radiomske analize, dostupno na: https://www.sophiagenetics.com/home.html

za borbu protiv obrazovne nejednakosti i stvaranje personaliziranih i prilagodljivih obrazovnih programa koji bi svima mogli pomoći da steknu nove kvalifikacije, vještine i kompetencije u skladu s njihovom sposobnošću učenja.[836] Mogla bi povećati i brzinu učenja i kvalitetu obrazovanja, od osnovnih škola do fakulteta.

Osim navedenih pozitivnih implikacija koje AI može ostvariti u društvu, postoje i primjeri posebno etički problematičnih područja koja se javljaju njezinom uporabom. Takvo je područje identifikacije i praćenje pojedinaca primjenom AI. Primjeri nadogradive tehnologije AI za identifikaciju koji se mogu istaknuti uključuju prepoznavanje lica i druge prisilne metode identifikacije upotrebom biometrijskih podataka (tj. otkrivanje laži, procjena osobnosti putem mikro izraza i automatsko prepoznavanje glasa). Identifikacija pojedinaca ponekad je poželjna mjera usklađena s etičkim načelima (na primjer, u otkrivanju prijevara, pranja novca ili financiranja terorizma), međutim automatska identifikacija izaziva zabrinutost i pravne i etičke dvojbe jer može imati nepredviđeni učinak na mnogim psihološkim i sociokulturnim razinama. Jasno utvrđivanje toga može li se, kada i kako AI upotrijebiti za automatiziranu identifikaciju pojedinaca te razlikovanje identifikacije pojedinca od pronalaženja i praćenja pojedinca i ciljanog/masovnog nadzora bit će presudno za ostvarenje pouzdane AI. Ako bi pravna osnova za tu aktivnost bio „pristanak", moraju se razviti praktična sredstva koja omogućuju davanje suvislog i provjerenog pristanka na automatsku identifikaciju AI ili jednakovrijednim tehnologijama. To se primjenjuje i na upotrebu „anonimnih" osobnih podataka koji se mogu ponovno personalizirati. Činjenica je da bi kreiranje unificiranog etičkog okvira za AI zapravo rezultiralo velikim brojem projekata koji imaju za cilj stvoriti upravo taj kodeks što je samo po sebi kontradiktorno. Pa tako primjerice, *Yannick Meneceur* poziva na etički kodeks nabrajajući 126 inicijativa.[837] Isto tako, u relativnom novom projektu naziva *Algorithm Watch*, skupina istraživača iz Švicarske je naišla na 1180 kodeksa koji se tiču etičkih načela u povezivosti s AI.[838] Sukladno tome, može se postaviti osnovna premisa o važnosti takvih načela, odnosno koji su razlozi koji utječu na svakodnevni porast takvih inicijativa. Ono što je još i najviše zabrinjavajuće jest činjenica da se radi o malom broju ljudi iz određenih zemalja koji se bave

[836] Vidjeti na primjer projekt *MaTHiSiS* kojim se nastoji dati rješenje za afektivno učenje u ugodnom okruženju, koje sadržava vrhunske tehnološke uređaje i algoritme: (http://mathisis-project.eu/). Vidjeti i IBM-ovu platformu *Watson Classroom* ili platformu *Century Tech*.
[837] Meneceur, Y. (2020). L'intelligence artificielle en procès: Plaidoyer pour une réglementation internationale et européenne, Bruylant
[838] AI Ethics Guidelines Global Inventory, dostupno na: https://inventory.algorithmwatch.org/

takvim objavama odnosno znanstvenim i javnim diskursom glede etičkih načela. U meta analizi koju je izradio tim iz Švicarske, a koja obuhvaća 84 dokumenta, SAD (24 %) i UK (7 %) zajedno daju trećinu svih izvještaja o etici u AI. Međutim, treba u obzir uzeti i etički pluralizam, odnosno pogled na etičke smjernice iz perspektive istočnog dijela svijeta, kao i Latinske Amerike i ostalih. Tu se postavlja pitanje ostvarivanja jedinstvenosti takvog okvira, a da su sve stranke postupka zadovoljne ishodom. U svakom slučaju, iako naizgled jednostavan posao, na nekim razinama će se pojaviti značajne prepreke koje će svijet morati premostiti ako planiramo ostvariti jedinstvena pravila u interakciji čovjek – stroj.[839]

Nadalje, s obzirom na težnju svakog društva da osigura zaštitu slobode i autonomije svih građana kod primjene AI postavlja se pitanje vrednovanja građana. Vrednovanje građana (u većim ili manjim razmjerima) već se sada često koristi za isključivo opisne ocjene i ocjene specifične za određeno područje (npr. školski sustavi, e-učenje i vozačke dozvole). Čak i kod tih užih primjena, građanima bi trebao biti dostupan potpuno transparentan postupak, uključujući informacije o procesu, svrsi i metodologiji vrednovanja. Također, trenutačno određen broj zemalja istražuje i razvija sustave smrtonosnog autonomnog oružja koji se kreću od projektila s mogućnošću selektivnog ciljanja do strojeva za učenje s kognitivnim vještinama, koje im omogućuju da bez ljudske intervencije odluče s kim će se boriti, kada i gdje. To dovodi do temeljnih etičkih pitanja, kao što je činjenica da bi moglo doći do utrke u naoružanju na dosad neviđenoj razini i koju nije moguće kontrolirati te do vojnog konteksta u kojem je gotovo potpuno isključen ljudski nadzor i nije riješeno pitanje rizika od nepravilnosti u radu. Europski parlament pozvao je na hitan razvoj zajedničkog stajališta o etičkim i pravnim pitanjima ljudskog nadzora, odgovornosti i provedbe međunarodnog prava o ljudskim pravima, međunarodnog humanitarnog prava i vojnih strategija.[840]

Sukladno tome, možemo zaključiti da bi ljudi uvijek trebali znati jesu li u izravnoj interakciji s drugim čovjekom ili strojem, a stručnjaci za AI su ti koji su odgovorni da se to ostvari na pouzdan način. Poteškoće bi se mogle pojavljivati kod nekih graničnih slučajeva koji otežavaju situaciju (npr. glas osobe koji se filtrira AI). Trebalo bi imati na umu da bi zbunjenost oko toga je li riječ o ljudima ili strojevima mogla imati višestruke posljedice poput privrženosti,

[839] Jobin, A., Ienca, M., Vayena, E. (2019). Artificial Intelligence: the global landscape of ethics guidelines, Preprint version, str. 3-7.
[840] Etičke smjernice, str. 38-42.

utjecaja ili smanjene vrijednosti ljudi.[841] U tom pogledu razvoj humanoidnih robota stoga bi trebalo pažljivo procijeniti iz etičke perspektive baš kao i primjenu autonomnog oružja u različitim sustavima.

4.10. UMJETNA INTELIGENCIJA I BRUTO DOMAĆI PROIZVOD

Značajan tehnološki napredak u mnogim područjima ubrzao je razvoj AI koja ima potencijal za preoblikovanje konkurentskog izgleda poduzeća, radnih mjesta i gospodarstvenog razvoja zemalja. Tijekom posljednjih nekoliko godina došlo je do značajnih rezultata u korištenju NLP, ML i sličnih pojavnih sastavnica AI.[842] Osim toga, mnogi proizvodi i usluge koji su već u širokoj upotrebi koriste napredak u razvoju AI kao što su osobni asistenti i sustavi za prepoznavanje lica. Veliki dio ovog ubrzanog razvoja je rezultat napretka u tri područja:

- postupna poboljšanja u računalnoj snazi i kapacitetu ponajviše zahvaljujući kontinuiranom napretku od središnjih procesnih jedinica do grafičke procesne jedinice. Takvi elementi su danas brži 40 do 80 puta od najbržih verzija dostupnih u 2013. godini;
- eksplozija podataka odnosno činjenica da svijet stvara količinu podataka bez presedana svaki dan. Ogromna raznolikost podataka znači da su organiziranje i analiza tih podataka izuzetno izazovni, ali i da postoji prilika za izdvajanje vrijednosti iz podataka što nije bilo dostupno u prošlosti te[843]
- napredak u algoritmima odnosno tehnikama i algoritmima na kojima se temelji AI i njeni sastavni podsustavi. Isto tako napredak u tehnikama DL i ML donosi značajne promjene u točnosti klasifikacije i predviđanja sustava AI.[844]

Predviđanje ekonomskog učinka AI vrlo je spekulativno. Za takve vrste predviđanja neki od ključnih čimbenika koje treba uzeti u obzir su: troškovi razvoja i primjena tehnologija za posebne namjene na radnom mjestu, dinamika na tržištu rada, kvaliteta i količina rada i pripadajuće plaće, odnosno prednosti od automatizacije izvan zamjene rada i regulatornog i

[841] Madary, M., Metzinger, T. K. (2016). Real Virtuality: A Code of Ethical Conduct. Recommendations for Good Scientific Practice and the Consumers of VR-Technology, Frontiers in Robotics and AI, 3(3)
[842] Horvitz, E. (2007). Machine learning, reasoning, and intelligence in daily life: Directions and challenges, Proceedings of Artificial Intelligence Techniques for Ambient Intelligence, Hyderabad, India
[843] Behavioral, transactional, environmental, and geospatial data are available from sources including the web, social media, industrial sensors, payment systems, cameras, wearable devices, and human entry, for example. Vidjeti: Henke, N., Bughin, J., Chai, M., Manyika, J., Saleh, T., Wiseman, B., Sethupathy, G. (2016). The age of analytics: Competing in a data-driven world, McKinsey Global Institute
[844] Goodfellow, I. J. *et.al., op.cit.*

društvenog prihvaćanja.[845] Uz ove čimbenike važno je percipirati moguću pojavnost poduzeća na tržištu koji razvoju AI naizgled od nigdje, stavljajući naoko dobro zaštićene i robusna postojeća poduzeća u lošiji položaj. Primjerice, prije 10 godina Kina je činila 1 % globalnih transakcija e-trgovine, a danas taj udio je preko 40 %.[846] To je stvorilo zamah za sustave AI čak i u kontekstu pripadajućih patenata. Ono što je najvažnije, patenti u pogledu AI rastu u cijelom svijetu za 6 % prosječne godišnje stope rasta između 2010. i 2015., koja je viša od godišnje stope rasta zabilježene za sve ostale patente kako je i prikazano na slici 4-2.[847]

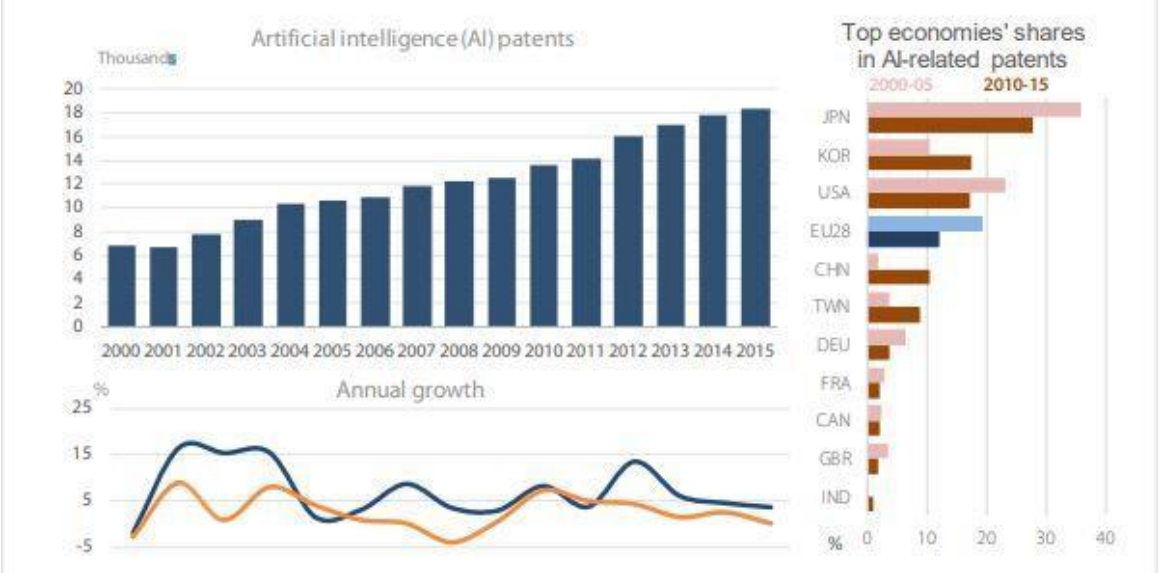

Slika 4-2 Patenti u području AI,

Izvor: OECD, Science, Technology and Industry Scoreboard, 2017.

Većina studija naglašava da će AI imati značajan ekonomski utjecaj. Zaključci koji su proizašli iz studije OECD-a iz 2017. godine govore o predviđanjima godišnje stope globalnog gospodarskog rasta u kojima se navodi da bi se do 2035. zahvaljujući AI ista mogla i udvostručiti. AI će taj rast predvoditi na tri ključna načina. Prvenstveno, dovest će do snažnog povećanja produktivnosti rada (do 40 %), zahvaljujući inovativnim tehnologijama omogućujući tako učinkovitije upravljanje vremenom u vezi s radnom snagom. Nadalje, AI će stvoriti novu virtualnu radnu snagu tzv. "inteligentnu automatizaciju" koja će biti sposobna za rješavanje

[845] McKinsey Global Institute (2017). Jobs lost, jobs gained: Workforce transitions in a time of automation
[846] Wang, W. K., Woetzel, J., Seong, J., Manyika, J., Chai, M., Wong, W. (2017). Digital China: Powering the economy to global competitiveness, McKinsey Global Institute
[847] OECD (2017), OECD Science, Technology and Industry Scoreboard 2017: The digital transformation, OECD Publishing, Paris, https://doi.org/10.1787/9789264268821-en.

problema i samoučenje. Naposljetku, utjecaj na gospodarstvo će biti i kroz širenje inovacija kroz različite sektore i stvaranje novih tokova prihoda.[848]

Prema *Gillham* i suradnicima iz 2018. godine procjenjuje se da bi se globalni BDP mogao povećati i do 14 % (protuvrijednost 15,7 bilijuna američkih dolara) do 2030. godine kao rezultat ubrzanog razvoja AI (slika 4-3). Izvještaj predviđa da će se sljedeći val digitalne revolucije pokrenuti uz pomoć podataka generiranih s IoT koji će vjerojatno biti višestruko veći od podataka generiranih trenutnim Internetom ljudi (engl. *Internet of People* - IoP). Potaknut će standardizaciju i posljedično tome automatizaciju, kao i poboljšanje personalizacije proizvoda i usluga.[849]

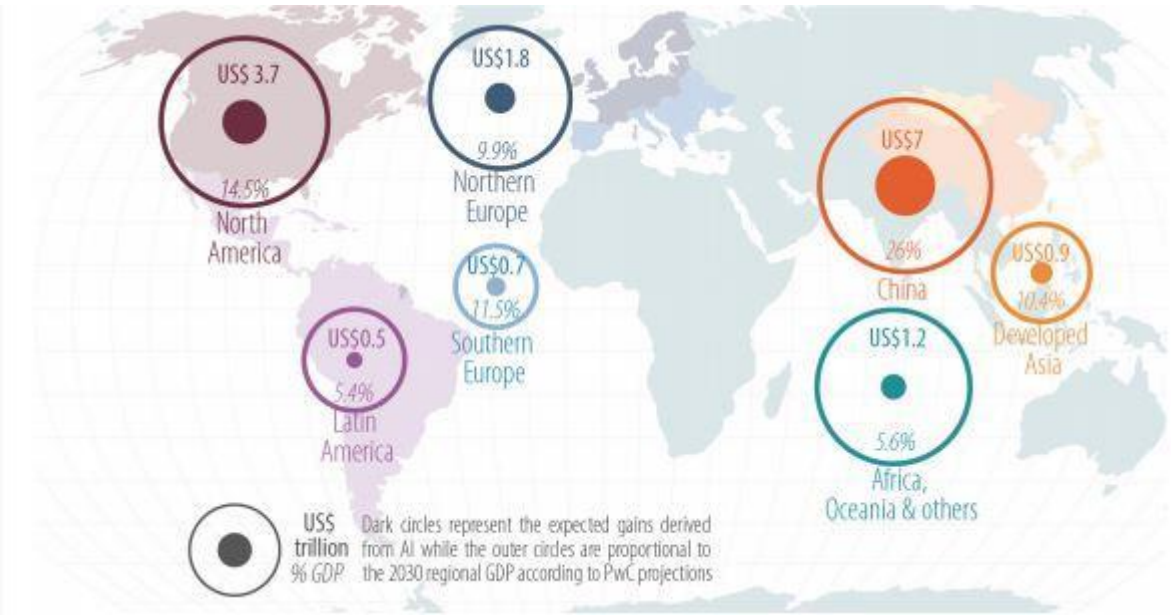

Slika 4-3 Projektirani porasti u BDP-u zbog AI u raznim regijama svijeta, Izvor: The macroeconomic impact of artificial intelligence, PwC, 2018

Ključni izazov je taj da bi integracija AI mogla dovesti do veće razlike između zemalja, poduzeća i radnika. AI bi mogla potaknuti gospodarsku aktivnost, ali raspodjela koristi bi mogla biti neravnomjerna. U pogledu implikacija za države, AI može proširiti jaz između zemalja, pojačavajući trenutnu digitalnu podjelu.[850] Države će možda trebati različite strategije i odgovore jer se razine usvajanja i primjene AI razlikuju. Čelnici država koje su razvijenije u pogledu korištenja AI mogli bi povećati svoju prednost u usvajanju takvih tehnologija u odnosu

[848] *Ibid.*
[849] Gillham, J., Rimmington, L., Dance, H., Verweij, G., Rao, A., Barnard Roberts, K., Paich, M. (2018). The macroeconomic impact of artificial intelligence, PwC, dostupno na: https://www.pwc.co.uk/economic-services/assets/macroeconomic-impact-of-ai-technical-report-feb-18.pdf
[850] Van Dijk, J. (2012). The evolution of the digital divide: The digital divide turns to inequality of skills and usage, u: Bus, J. *et al.* (2012). Digital Enlightenment Yearbook, Amsterdam, Netherlands, IOS Press

na zemlje u razvoju. Također, stope plaća u razvijenijim gospodarstvima su visoke što znači da postoji više poticaja nego u zemljama s niskim plaćama da radnu snagu zamijene strojevima. U kontekstu poduzeća i korporacija, primjena i razvoj AI može dovesti do razlike u učinku između vodećih s jedne, i ostalih koji ne koriste AI s druge strane. Na jednom kraju spektra predvodnici (poduzeća koja u potpunosti integriraju alate AI u svojim poduzećima tijekom sljedećih pet do sedam godina) vjerojatno će imati nerazmjernu korist. Velika poduzeća imaju konkurentsku prednost u usvajanju i integraciji AI ispred industrijskih konkurenata. *McKinsey Global Institute* u svojoj ekonometrijskoj simulaciji sugerira da imaju stope primjene za oko 10 % više od prosjeka. Slično tome, organizacije koje imaju uspostavljenu digitalnu kulturu (uključujući elemente kao što su institucionalizirano razmišljanje o dizajnu korisničkog iskustva, spretna organizacija, skalirani i integrirani načini rada u poslovnim i IT domenama i kultura vođenja koja njeguje i omogućuje mrežu osnaženih timova za postizanje definiranih ciljeva) su u boljoj poziciji za bržu implementaciju AI. Točnije rečeno, njihove su stope buduće primjene za 8 % više od onih u poduzećima koje nemaju digitalnu kulturu te će se one korporacije koje se prve odvaže primijeniti biti i one koje će imati eksponencijalne koristi, potencijalno ostvarujući tri puta više ekonomske koristi od AI od onih koji je ne koriste.[851] Jedan od važnih pokretača ovog pritiska na dobit je postojanje jake konkurentske dinamike među poduzećima koja bi tržišni udio mogla preusmjeriti sa zaostalih na vodeće, a mogla bi potaknuti raspravu o nejednakoj raspodjeli koristi od AI. U pogledu radne snage očekuje se povećanje razlika na razini pojedinih radnika. Potražnja za poslom mogla bi se preusmjeriti s ponavljajućih zadataka na one koji su društveno i kognitivno vođeni i one koje zahtijevaju aktivnosti koje je teško automatizirati. U tom dijelu očekuje se i veće digitalno znanje, odnosno posjedovanje digitalnih vještina. Profili posla karakterizirani ponavljajućim zadacima i aktivnosti koje zahtijevaju niske digitalne vještine mogu iskusiti najveći pad udjela u ukupnoj zaposlenosti, s nekih 40 % na blizu 30 % do 2030. godine.[852]

Najveći dobitak u udjelu mogu imati poslovne aktivnosti koje se ne mogu automatizirati kao i one koje zahtijevaju visoke digitalne vještine, popevši se s oko 40 % na više od 50 %.[853] Ove promjene u zaposlenosti imale bi utjecaj na plaće. Smatra se da bi se oko 13 % ukupnog

[851] Više o tome: Bughin, J., Seong, J., Manyika, J., Chai, M., Joshi, R. (2018). Notes from the AI frontier: Modeling the impact of AI on the world economy, McKinsey Global Institute, dostupno na: https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-modeling-the-impact-of-ai-on-the-world-economy
[852] *Ibid.*
[853] *Ibid.*

fonda plaća moglo prebaciti na kategorije koje zahtijevaju jedinstvene i visoke digitalne vještine gdje bi prihodi mogli rasti, dok radnici u ponavljajućim poslovima i s niskim digitalnim vještinama mogu potencijalno doživjeti stagnaciju ili čak rez u svojim plaćama.[854] Udio u ukupnoj masi plaća posljednje skupine mogao bi se smanjiti s 33 % na 20 %.[855]

Utjecaj tehnologije na radna mjesta stvaran je i važan. Međutim, tu zabrinutost treba razmotriti u kontekstu ukupnih dobitaka u produktivnosti i gospodarskim aktivnostima.[856] Utjecaj automatizacije mogao bi iznositi čak 9 bilijuna dolara, ili oko 11 % veću proizvodnju do 2030.[857] AI može dati važan doprinos poticanjem inovacija koje se zatim mogu primijeniti za poboljšanje trenutnih proizvoda i usluga i stvaranje potpuno novih ponuda. *McKinsey Global Institute* u svojim istraživanjima sugerira da inovacije mogu pridonijeti oko 7 % što bi moglo dovesti do potencijalnog povećanja proizvodnje od 6 bilijuna dolara do 2030. godine. Prvi razlog zbog kojeg su ovi učinci AI veliki jest taj što poduzeća mogu brzo poboljšati svoje proizvodne linije postizanjem učinkovitijih pristupa tržištu pa čak i sa postojećim proizvodima i uslugama. Drugi je razlog taj što dugoročno većina tehnologija potiče inovacije u proizvodnji i uslugama, potiskujući tradicionalne industrije i stvarajući potpuno nova tržišta. Istraživanje iz 2017. koje je proveo *McKinsey Global Institute* naglašava da će do 14 % radnika možda trebati promijeniti zanimanje i da će, iako neki mogu mijenjati uloge u istom poduzeću, drugi možda morati preći u nove sektore, pa čak i promijeniti mjesta prebivališta u potrazi za poslom.[858] Istraživanje je također otkrilo da dok će se većina radnika suočiti s konkurencijom u obliku AI za neke zadatke, manje od 10 % zanimanja čine aktivnosti koje mogu biti u potpunosti automatizirane na temelju trenutno pokazanih sposobnosti, dok je ipak oko 60 % zanimanja gdje bi se barem jedna trećina aktivnosti mogla automatizirati.[859] Negativni učinci AI na BDP mogli bi se očitovati u gubitku domaće potrošnje tijekom nezaposlenosti, odnosno na možebitnom smanjenju pozitivnih učinaka AI za 4 %. Prijelazni i provedbeni troškovi mogli bi unazaditi pozitivne učinke za dodatnih 5 %, što analizom sugerira da će ove promjene do 2030. godine uzrokovati troškove od oko 7 bilijuna dolara.[860]

---

[854] *Ibid.*
[855] *Ibid.*
[856] Bughin, J., LaBerge, L., Mellbye, A. (2017). The case for digital reinvention, McKinsey Quarterly
[857] Manyika, J., Sneader, K. (2018). AI, automation, and the future of work: Ten things to solve for, McKinsey Global Institute
[858] *Ibid.*
[859] *Ibid.*
[860] ITU trends (2018). Emerging trend sin ICT's, Assessing the economic impacts of Artificial Intelligence, No.1

Ekonomski utjecaj AI zasigurno će biti velik, uspoređujući se s ostalim tehnologijama opće namjene u povijesti. Međutim, opipljiva produktivnost AI možda neće biti vidljiva odmah, ali će se s vremenom vjerojatno ubrzati, pa blagodati početnog ulaganja možda neće biti vidljive u kratkom roku. Zakonodavci i dužnosnici morat će pokazati hrabrost kako bi prevladali razumljivu nelagodu među građanima zbog uočene prijetnje njihovim poslovima prilikom automatizacije istih. Poduzeća trebaju surađivati s vladama na ogromnom zadatku osposobljavanja ljudi za rad s AI.

Može se zaključiti kako se pojedinci trebaju prilagoditi novom svijetu u kojem će fluktuacija posla biti češća, možda će morati prijeći na nove vrste zaposlenja i vjerojatno će trebati stalno osvježavati i ažurirati svoje vještine kako bi odgovarale potrebama dinamično mijenjajućih poslova na tržištu.

4.11. UMJETNA INTELIGENCIJA I POREZNI SUSTAV

Utjecaj AI na gospodarstvo će također biti značajan. Kao i svaki novi element koji se unese u gospodarsku jednadžbu i sustav AI će imati svoje prednosti i mane. U slučaju AI najveća mana je svakako gubitak ljudskih poslova i zamjena istih automatiziranim procesima. Upravo tu se postavlja ključno pitanje: što će biti s financijskim sredstvima koja su se ulijevala u državne proračune nauštrb ljudskog rada? S obzirom da je poslodavac za vrijeme radnog odnosa s radnikom uplaćivao određene doprinose na račun i u ime radnika, postavlja se pitanje hoće li to isto raditi i za AI? Ako uzmemo u obzir da smo daleko još od sustava gdje bi AI ili humanoidna AI imala ista prava kao i čovjek, nije za očekivati da će poslodavac plaćati doprinose poput zdravstvenog i mirovinskog osiguranja za AI, ali ostaje otvoreno pitanje uplaćivanja poreza na račun ostvarene dobiti omogućene upravo AI. Zakonodavac upravo tu treba postaviti ključne zakonske odredbe kako bi zaštitio i radnika i državu, odnosno treba učiniti plaćanje poreza za ostvarenu dobit od AI nužnim, a dio tih novaca proslijediti u sustave digitalnog obrazovanja ljudi koji su izgubili svoj posao zbog primjene digitalnih tehnologija odnosno AI. Tehnološki poduzetnici bi trebali širiti svoje bogatstvo modelima drugačijim nego ih nalaže *Wall Street* i slične financijske okosnice te kreirati udruženja za pomoć članovima

koji su ostali bez posla radi primijenjene nove tehnologije i slične investicijske strukture koje bi nagrađivale i pomagale ljude.[861]

U današnjoj političkoj klimi povećanje poreza i drugi koraci koje bi se trebali zagovarati mogli bi se činiti pretjeranima, ali treba prepoznati istinske probleme i baviti se njima, a što očuvanje ljudskih prava poput slobode, govora i prava na rad definitivno jest. Davno prije nego što itko sazna kako stvoriti super inteligenciju, odnosno ljudsku verziju zdravog razuma, može se reći kako će se nestabilnost koju već uzrokuje ekonomska nejednakost pogoršati samo ako se AI koristi za određene, kratkoročne i kratkovidne ciljeve.

[861] Rege, M., Yarmoluk, D. (2020). Artificial Intelligence and its impact on jobs, St. Thomas University, dostupno na: https://news.stthomas.edu/artificial-intelligence-and-its-impact-on-jobs/

5 UMJETNA INTELIGENCIJA U MEĐUNARODNOM POMORSKOM PROMETU

U ovom poglavlju analizirana je AI s mogućom primjenom u međunarodnom pomorskom prometu stavljajući naglasak na različite brodske sustave odnosno sigurnosni i tehnički nadzor takvih sustava. Uz to, analizirana je i trenutna primjena AI u međunarodnom pomorskom prometu, pri čemu su istaknute prednosti i nedostaci te je kreiran model određivanja sigurnosti sustava AI u međunarodnom pomorskom prometu što uključuje i model poboljšanja postojećih sustava.

5.1. PREGLED ELEKTRONIČKIH NAVIGACIJSKIH SUSTAVA U POMORSKOM PROMETU

Brodski elektronički navigacijski uređaji (BENU) u plovidbi mjere i koriste različite elemente važne za samu navigaciju. To uključuje mjerenje pozicije broda, kursa, dubine, brzine i ostalih važnih elemenata poput jačine i smjerova morskih struja, morske mijene i sl. BENU se sastoje od različitih podsustava koje zbirnim djelovanjem omogućuju sigurnu i više/manje preciznu navigaciju.[862] U ovom dijelu rada pozornost je stavljena na BENU koji sadrže pretpostavke za integraciju u sustav AI.

5.1.1. INERCIJALNI NAVIGACIJSKI UREĐAJ

Zakon mehanike prema kojem tijelo nastoji zadržati stanje mirovanja ili jednolikog pravocrtnog gibanja ako se na njega ne djeluje vanjskim silama je temelj rada inercijalnog navigacijskog sustava. Moguće pogreške sustava inercijalne navigacije mogu se odnositi na pogreške položajem stabilizirane platforme horizonta, pogreške akcelerometra uzrokovane pomakom osi vrtnje giroskopa i oblikom Zemlje. Inercijalni navigacijski sustavi se vrlo često koriste u podmornicama.[863]

[862] Pregled određenih BENU može se vidjeti na: https://www.usps.org/national/eddept/ap/files/chapter6_2009_12_22.pdf
[863] Karabatić, A. (2005). Inercijalni sustavi, Ekscentar, (7), str. 84-86.

5.1.2. ŽIRO KOMPAS

Žiro kompas je vrsta kompasa s obješenim žiroskopom s brzo - rotirajućim girom kao osjetilom. Na žiro kompasu se 0° ili N kompasne vjetrulje postave u smjeru meridijana. Žiro kompasi u svom radu omogućuju pomorcima informaciju o pravom kursu (Kp). Žiro kompas u svom radu stvara pogreške poput tehničke pogreške, plovidbene pogreške, pogreške geografske širine, kvadrantalne i balističke pogreške.[864]

5.1.3. DIGITALNI ŽIRO KOMPAS

Pomorskim digitalnim žiro kompasom kao elektroničkim navigacijskim uređajem postižu se precizni podaci u orijentaciji uz pruženu izvanrednu pouzdanost u radu. Prepoznate promjene kursa uzrokovane valjanjem ili posrtanjem broda ne utječu na mjerenje mjerne veličine o kursu broda.

5.1.4. ELEKTRONIČKI KOMPAS

Elektronički kompas je kompas čiji se rad temelji na elektro - magnetskoj indukciji. U elektroničkom kompasu se automatski kompenzira devijacija kompasa. Korektorom se ispravlja magnetska varijacija magnetskog polja Zemlje.[865] Time se omogućuje pokazivanje pravog kursa broda na elektroničkom kompasu.

5.1.5. ULTRAZVUČNI DUBINOMJER

Poznavanje dubine mora ispod broda važan je podatak u plovidbi. U plovljenju obalnim područjima, iznad plitkih područja, u blizini ušća rijeka, za loših vremenskih uvjeta, poglavito vidljivosti, radi sigurnijeg vođenja broda i bolje orijentacije valja poznavati dubine u području plovljenja. Brzina širenja ultrazvuka kroz vodu izravno utječe na točnost izmjerene dubine. Brzina širenja ovisi o područjima mjerenja, godišnjim dobima, pa i o dnevnim termohalinskim promjenama.[866]

---

[864] Jaskólski, K., Felski, A., Piskur, P. (2019). The compass error comparison of an onboard standard gyrocompass, fiber-optic gyrocompass (FOG) and satellite compass, Sensors, 19(8), str. 1942.

[865] Više: Sharma, A. (2016). What is Magnetic Compass, its principle, types and errors, dostupno na: https://marinegyaan.com/what-is-the-magnetic-compass/

[866] Belić, J. (2005). Model sedimenta na dnu Prošćanskog jezera, Sveučilište u Zagrebu, Geodetski fakultet, diplomski rad, str. 13.

5.1.6. BRZINOMJERI

Brodovi se opremaju brodskim elektroničkim navigacijskim uređajima za mjerenje i pokazivanje brzine te prijeđenog puta. Oni pružaju podatke o prijeđenom putu i brzini kretanja u smjeru naprijed u odnosu na vodu ili dno, a mogu pružati i dodatne podatke o kretanju broda. Brzinomjeri zadovoljavaju izvedbene norme pri brzinama kretanja naprijed do najveće brzine broda. Brzina broda izravno se mjeri brzinomjerima. Brzinomjeri se dijele na: apsolutne i relativne. Apsolutni brzinomjeri mjere brzinu preko dna, a relativni kroz vodu.[867]

5.1.7. GLOBALNI SUSTAV ZA POZICIONIRANJE

Svjetski sustav za pozicioniranja (engl. *Global Positioning System - GPS*) je vojni navigacijski sustav SAD-a.[868] GPS obuhvaća tri podsustava: svemirski, nadzorni i korisnički. Navigacija se u velikoj mjeri oslanja na GPS ponajviše jer je jednostavan za upotrebu, relativno točan i pouzdan. Međutim, GPS signale mogu ugroziti i prirodni i ljudski izvori. Ako se to dogodi, to može dovesti do netočnih podataka ili potpunog gubitka GPS signala.[869] Najčešći problemi povezani s upotrebom GPS mogu se manifestirati na neki od sljedećih načina:

- pogrešna instalacija, odnosno nepravilno instaliran GPS može dovesti do netočnih podataka,
- pogreška korisnika što podrazumijeva ljudske pogreške poput GPS-a koji ostaje u načinu mrtvog računanja,
- atmosfera, odnosno na satelitske signale može utjecati nepravilna aktivnost u zemaljskoj atmosferi,
- lokalni problemi gdje na nekim lokacijama dostupnost i kvaliteta GPS signala mogu uzrokovati probleme te

[867] Raguž, I. (2019). Razvoj i rad brodskih brzinomjera, Sveučilište u Dubrovniku, Pomorski odjel, završni rad, str. 2.
[868] Više o tome na: https://www.gps.gov/applications/marine/
[869] Više o tome: GPS common problems and how to mitigate them (2018)., dostupno na: https://safety4sea.com/gps-common-problems-and-how-to-mitigate-them/?__cf_chl_jschl_tk__=8d8c96c2964240e7c242de432b5e6afd59d0c10c-1618912211-0-AQ1J9LAI2w08o18XZUdJBgYX7VHlB-ghskWpTn8DA9sbmfgk3iXJNamdhAC2kufKJ2-9g4j8KaGOMBnouqBaSh3oEMxQ_e5_d9bzuTMJ1FSiqX4RjTt0_TkJ3IwzfatmJDY9aYYGGxepvLLHnQeUmfswtWMiNLVP_ExytT2C6q0WhdZ_Jq0XroqoZZ2daugMU9EBgzniw1pAWI1HLCxwOe9votc87lltxgoLmDErrZW7y1eKQIXsjYhqaU91ptlMfXjJILjEHu1xiI9NlK6ecursY_XUwYA2cup06Vv9IPP09g9L5ctm4TgMxoRsCXPoofqsupZPd6gNdxwld2iKae2PGVdy3A7f_HNMTifguhJi62rL9C9Q2yyl-oaX141Ww3f42iOhtSLEnZyGtxE-hC9OFIOPkEEyLvDyDqk0J6c_BapqBelIfnOMj9ciXX6iqg

- namjerna djela poput ometanja, hakiranja i sličnih ugroza koje mogu utjecati na GPS signal.[870]

Na točnost pozicioniranja GPS uvelike utječu i atmosferske prilike/neprilike.[871] U svome radu pruža točnost u 95 % vremena, ali i određene pogreške[872] zbog čega se u pomorskom prometu razvio i diferencijalni svjetski sustav za pozicioniranje (DGPS). Temeljno načelo DGPS je usporedba pozicije poznate točke na diferencijalnoj postaji s pozicijom dobivenom od GPS prijemnika na toj točki i računanje razlike, tj. ispravka pozicije u podatkovnoj vezi s korisnikom.[873] DGPS sustavom ispravljaju se GPS pozicije u nekom ograničenom području. Korisnik DGPS sustava u pokretu podatke za ispravljanje mora primati s istih satelita kao i polazna postaja, a dobivena razlika može biti 2D ili 3D geografska koordinata ili niz podataka za ispravljanje što pruža točnost DGPS unutar 1,5 metra.[874]

5.1.8. GLOBALNI NAVIGACIJSKI SATELITSKI SUSTAV

GLONASS je ruski sustav za satelitska pozicioniranja tehničko - tehnološki sličan GPS sustavu. Omogućuje pozicioniranje 24 sata bilo gdje na Zemlji. Sustav je potpuno operativan od siječnja 1996. godine. Sastoji se od dvadeset četiri satelita u tri putanje na visini 19.100 km. Točnost je do ± 4 m bez obzira na vremenske uvjete i brzinu odgovarajuće opremljenih korisnika.[875] Nedostatak je i oslanjanje GLONASS sustava na ruski standard (engl. *Soviet Geocentric Coordinate System 1990 - SGS 90*) i neusuglašenost s kartama svjetskog geodetskog standarda - WGS 84.[876]

---

[870] *Ibid.*
[871] Filjar, R., Kasum, J., Kos, S., Sevrovic, M. (2008). Statistical Properties of Quiet Space Weather Northern Adriatic Residual GPS Ionospheric Delay, Proceedings of NAV08/ILA37 Conference, Westminster, London, Cambridge Press
[872] U.S. Department of Defense (2020). Global positioning system standard positioning service performance standard, dostupno na: https://www.gps.gov/technical/ps/2020-SPS-performance-standard.pdf
[873] Śniegocki, H., Specht, C., Specht, M. (2014). Testing Accuracy of Maritime DGPS System Based on Long-Term Measurements Campaigns over the Years 2006-2014. International Journal of Civil Engineering and Technology. 5, str. 1-8.
[874] *Ibid.*
[875] Hofmann Wellenhof, B., Lichtenegger, H., Wasle, E. (2007). GNSS–global navigation satellite systems: GPS, GLONASS, Galileo, and more, Springer Science & Business Media
[876] *Ibid.*

5.1.9. RADAR

Radarski sustavi koriste se za otkrivanja i mjerenja udaljenosti različitih objekata radiovalovima (engl. *Radio Detection and Ranging* - RADAR).[877] Kao računalno podržani sustavi, radari su ključan segment u sigurnosti plovidbe i neizostavni dio AI.

5.1.10. SNIMAČ PODATAKA O PUTOVANJU

Snimač podataka o putovanju VDR je crna kutija za brodove. Danas VDR imaju važnu ulogu u povećanju sigurnosti plovidbe. Podaci pohranjeni u VDR pružaju važne informacije za istraživače u određivanju uzroka pomorskih nesreća. VDR se može preslušati nakon incidenta. Zaštićen je od neovlaštenih promjena ili pokušaja promjena sadržaja.[878]

5.1.11. SUSTAV AUTOMATSKOG PREPOZNAVANJA

Automatskim sustavom za prepoznavanje brodova (engl. *Automatic Identification System* - AIS) olakšava se prepoznavanje brodova. Brodovima se primjenom AIS sustava omogućuje razmjena identifikacijskog broja (engl. *Identification Digit* - ID), brzine, kursa, pozicije i drugih važnih podataka. Ovi podaci se stalno odašiljaju svim brodovima u blizini i upravama na obali na vrlo visokim frekvencijama (VHF).[879]

5.1.12. ELEKTRONIČKA POMORSKA KARTA

Elektronička pomorska karta je relativno novo pomoćno sredstvo namijenjeno navigaciji. Pruža značajna poboljšanja u pomorskoj navigaciji i unapređuje sigurnost plovidbe. Objedinjuje geografske i tekstualne podatke, pozicije objekata i nevidljivih opasnosti. Kao automatizirani sustav pomaže navigatoru u donošenju odluka.[880]

---

[877] Ward, K. D., Baker, C. J., Watts, S. (1990). Maritime surveillance radar. Part 1: Radar scattering from the ocean surface, IEE Proceedings F, Radar and Signal Processing, Vol. 137, No. 2, str. 51-62.
[878] Walczak, A., Skotnicka, M. (2011). An evaluation of Voyage Date Recorders and S (Simplified)-VDR by maritime experts, Zeszyty Naukowe/Akademia Morska w Szczecinie, str. 108-113.
[879] Svanberg, M., Santén, V., Hörteborn, A., Holm, H., Finnsgård, C. (2019). AIS in Maritime Research, Marine Policy, 106
[880] Alexander, L., Black, L. J. (1993). ECDIS: The wave of the future, Sea Technology, United States, 34(3)

5.1.13. AUTOPILOT

Autopilot je brodski elektronički navigacijski uređaj za upravljivo automatsko nadziranje i upravljanje položajem kormila radi zadržavanja željenog kursa plovidbe broda.[881]

5.2. MODERNE TEHNOLOGIJE I LUČKE OPERACIJE - TRENUTNO STANJE I OČEKIVANI RAZVOJ

Pomorska tehnologija kao i noviteti koji će se primijeniti u razdoblju od sljedećih 10 godina predstavljaju društvene, globalne i industrijske izazove s ciljem osiguranja sigurnije, pametnije, konkurentnije i održivije pomorske industrije. Mnoga tehnološka područja trebat će prihvatiti primjenu AI uz više tradicionalnih područja istraživanja i razvoja. AI će zajedno s digitalizacijom i povezivanjem biti transformativna i pružit će značajan doprinos konkurentnosti i održivosti pomorske industrije. Budućnost postavlja mnoge izazove, ali nudi i mnogo novih rješenja za pomorski sektor. Današnji izazovi za održivi razvoj pomorskog prometa uključuju održavanje konkurentnosti u globalnom okruženju, optimalno korištenje izvora energije i minimaliziranje utjecaja na okoliš.[882]

Rastuće potrebe čovječanstva za hranom, energijom, vodom, organskim ili mineralnim resursima predstavljaju drugi veliki izazov. AI može pomoći u rješavanju značajnih izazova za okoliš u kontekstu isporuke robe i poboljšanja operativne učinkovitosti, a održive tehnologije pomoći će oceanskom prostoru u eksploataciji i zaštiti prirodnih dobara. Pomorski promet i dalje će ostati najučinkovitije sredstvo za globalni transport sirovina, roba, goriva, hrane i vode. Infrastruktura i povezanost s ostalim vrstama prijevoza će rasti. Pomorski promet, uključujući i promet unutarnjim plovnim putovima, također postaju sastavni dio učinkovitog multimodalnog logističkog lanca. Također, pametna plovila komunicirat će s pametnim lukama radi ograničenja zagušenja, vremena čekanja, a time i nadzora troškova čime će moći prilagoditi brzinu plovidbe za automatsko usklađivanje lučkih mjesta.[883]

Povećana očekivanja društva o zdravlju, sigurnosti i zaštiti te utjecaj industrije na okoliš su glavni elementi budućih pravnih regulativa što može samo poboljšati pomorski transport i

[881] Dove, M. J., Wright, C. B. (1991). Development of marine autopilots, The National Academics of Sciences, Engineering and Medicine, TRB, str. 259-272.
[882] Bichou, K. (2009). Port operations, planning and logistics, Informa Law from Routledge, str. 307-314.
[883] Burns, M. G. (2018). Port management and operations. CRC Press

industriju općenito. Klimatske promjene dovele su do zabrinutosti posebice u ograničenju emisija stakleničkih plinova (*Green House Gas* - GHG).[884] Globalno se zahtijeva smanjenje potrošnje energije u pomorskom prometu kroz mjere poput uporabe čistijih goriva, primjerice LNG, plovila na električni pogon, obnovljive izvore energije i sl. Klimatske promjene će dovesti do toga da ekstremnije vremenske prilike i otapanje polarnog leda u određenoj mjeri utječu na pomorski sektor. Samim time, to će zahtijevati brodove i odobalne strukture koje su robusnije, odnosno takve da mogu djelovati i u težim vremenskim uvjetima. Brzina inovacija raste, posebno s porastom novih digitalnih industrijskih tehnologija poznatih kao Industrija 4.0, potpomognuta transformacijskim tehnologijama kiber - fizičkih sustava (*Cyber - Physical System* - CPS).[885] Ti su sustavi kombinacije nekoliko glavnih inovacija u digitalnoj tehnologiji spremnih za transformaciju industrije. Tehnologije uključuju računalstvo u „oblaku“, IoT, *blockchain,* sofisticirane senzore, hvatanje i analitiku podataka, naprednu robotiku i AI. Industrija 4.0 bit će transformirajuća za upravljanje međusobno povezanih sustava i bit će ključni element u kontekstu pametne proizvodnje i otpreme te u smislu poboljšanja konkurentnosti.

Međutim, predviđajući koje od ovih tehnologija će transformirati pomorski promet i održati vrijednosti mora s biološkog aspekta ostaje izazov za budućnost. Komisija aktivno promiče povećanu automatizaciju i bolju upotrebu informacijskih i komunikacijskih tehnologija (IKT). Korištenje naprednih IKT u sektoru pomorskog prometa nije novi koncept.[886]

U budućnosti komunikacije i djelovanje na razini brod - brod i brod - obala će biti besprijekorna, posebice zbog činjenice da u pomorstvu i pomorskom prometu ogromne količine dostupnih podataka će podržati nove mogućnosti za poboljšanje rada broda, sigurnosti, zaštite i logistike.

Osnovni model razvoja novih tehnologija u pomorskoj transportnoj industriji odnosi se na sljedeće elemente:[887]

- „zeleni“ brodovi i transport,
- sigurnost i zaštita,

[884] Primorac, Ž. (2020). Suvremeni pravni izazovi smanjenja emisija stakleničkih plinova iz pomorskog prometa – međunarodna i europska perspektiva. Zbornik radova Pravnog fakulteta u Splitu, 57:3 str. 739-757.
[885] Tucci, A. E. (2017). Cyber risks in the marine transportation system, Cyber-Physical Security, str. 113-131.
[886] Giannopoulos, G. A. (2004). The application of information and communication technologies in transport, European journal of operational research, 152(2), str. 302-320.
[887] [887] ECMAR - European Council for Maritime applied R&D. (2020). Maritime technology challenges 2030 – New technologies and opportunities, Safer, smarter and greener for a sustainable European maritime sector, dostupno na: https://www.ecmar.eu/media/1813/ecmar-brochure-maritme-technology-challenges-2030.pdf

- povezani i automatizirani transport,
- ljudski faktor,
- integrirana transportna logistika,
- proizvodnja i
- podvodni zvukovi i akustika.

5.2.1. EKOLOŠKI PRIHVATLJIVI BRODOVI I TRANSPORT

Financijski, regulatorni i društveni pritisci nastavit će poticati brodarstvo da smanji negativan utjecaj na okoliš. U budućnosti će više plovila nuditi vrhunsku energetsku učinkovitost kroz mjere kao što su: poboljšana hidrodinamika, upotreba laganih materijala i napredni hibridni sustavi za proizvodnju energije s energetskom pohranom za optimizaciju performansi. Plovila će također imati smanjeni utjecaj na okoliš zbog upotrebe alternativnih goriva i obnovljivih izvora energije.[888] Pomorski promet je energetski najučinkovitiji način prijevoza, ali postoji prostor za značajno poboljšanje energetske učinkovitosti i emisije.[889] Unatoč nedavnom napretku u nizu tehnologija povezanih s energetskom učinkovitošću, puni potencijal brodarskih poduzeća koja gaje zelene tehnologije nije realiziran. Još uvijek postoji potreba za sveobuhvatnijim i cjelovitim pristupom s ciljem uštede energije koja bi integrirala sve napredne alate i koncepte. Primjerice, analiza BD dovest će do bolje procjene i upravljanja, a samim time i manje potrošnje plovila.

5.2.2. SIGURNOST I ZAŠTITA

Sigurnost, zaštita te sprječavanje onečišćenja su od najveće važnosti za pomorski promet. Ozbiljni incidenti na moru ne pokazuju značajnu silaznu putanju unatoč velikim ulaganjima i primjeni novih tehnologija. Posljedice ozbiljnih pomorskih nezgoda koje vode do gubitaka ljudskih života, onečišćenje okoliša i gubitka tereta, izravno utječu na društvo i gospodarstvo. Ljudski faktori i obuka su ključni za smanjenje incidenata na moru i za upravljanje novim tehnologijama. IMO-ov prošireni pristup zasnovan na ciljevima (engl. *Goal – Based Standards* - GBS) uključuje i pristup na sigurnosnoj razini (engl. *Goal – Based Standards and Safety - Level Approach* - GBS-SLA). Takva raspodjela u samom pristupu IMO-a je zalog za budućnost

[888] Sherbaz, S., Duan, W. (2012). Operational options for green ships, Journal of Marine Science and Application, 11(3), str. 335-340.
[889] Primorac, Ž., 2020, *op.cit.*, str. 739-757.

u smislu poboljšanja pomorske sigurnosti.[890] Međutim, provedba GBS-SLA će zahtijevati izradu postupka za određivanje buduće razine rizika i postupka povezivanja razina rizika s određenim brodskim funkcijama.[891] Terorističke prijetnje ne pokazuju znakove smanjenja te će se brodovi, a i luke, i dalje suočavati s prijetnjom terorističkih djelovanja. Također, i dalje vlada vrlo ozbiljna zabrinutost zbog kibernetičke sigurnosti, piratstva[892] i oružane pljačke na moru. EU Strategija pomorske sigurnosti (engl. *European Union Maritime Security Strategy* - EUMSS) i pripadajući Akcijski plan pružaju sveobuhvatne strategije protiv svih izazova u kojima pomorska industrija može utjecati na ljude, aktivnosti ili infrastrukture unutar EU što će svakako trebati primijeniti na nove tehnologije i AI.[893]

5.2.3. POVEZANOST I AUTOMATIZIRANI TRANSPORT

Digitalizacija će potaknuti automatizaciju i pozitivno utjecati na sigurnost i ekološke performanse. Nove tehnologije poput "*cloud computing*" će značajno utjecati na dizajn, proizvodnju i rad plovila i njihovih komponenti.[894] IoT će pomoći u isporuci pametnih plovila s nadzorom na kopnu. Kibernetička sigurnost i ljudski čimbenici postat će važna pitanja u kontekstu digitalizacije i automatizacije. Sljedeća generacija povezanosti broda i obale pomoći će brodarskim poduzećima da smanje troškove, izbjegnu skupe popravke i poboljšaju operativnu učinkovitost. Digitalizacija, senzori i automatizirani procesi te uvođenje BD u pomorskim operacijama dovest će do optimizacije potrošnje energije i učinkovitosti goriva, praćenje rada broda i stanja te vremenske uvjete i usmjeravanje u stvarnom vremenu. Viši stupanj automatizacije sustava, dostupnost, pametni senzori i globalne mreže za prijenos podataka između broda i obale promovirat će daljinsko upravljanje i djelomično ili potpuno autonomna navigacija. Međupovezanost između morskih operacija i operativnih centara na kopnu omogućit će sve veću podršku i kontrolu s obale. Ovo će zahtijevati zaštitu sustava i operacija od kibernetičkih napada. Digitalizacija je također omogućila dalekosežnije koncepte

---

[890] Više o tome na: https://www.imo.org/en/OurWork/Safety/Pages/Goal-BasedStandards.aspx

[891] Više o tome na: http://shippingregs.org/Portals/2/SecuredDoc/Circulars/MSC.1-Circ.1596%20-%20Interim%20Guidelines%20For%20Development%20And%20Application%20Of%20Imo%20Goal-Based%20Standards%20Safety%20Leve...%20(Secretariat).pdf?ver=2019-03-07-122838-707

[892] Buhovac, M. *et.al*., *op.cit.*, str. 282-290.

[893] EU strategija sigurnosti za pomorstvo (2014), dostupna na: https://ec.europa.eu/maritimeaffairs/policy/maritime-security_en

[894] Joszczuk Januszewska, J. (2012). The benefits of cloud computing in the maritime transport, International Conference on Transport Systems Telematics, Springer, Berlin, Heidelberg, str. 258-266.

poput navedenih, što će pomorskoj industriji pružiti nove načine prikupljanja, obrade i razmjene vrijednih podataka u stvarnom vremenu.[895]

5.2.4. LJUDSKI FAKTOR

Ljudski čimbenici koji doprinose od 75 % - 96 % pomorskih nesreća i incidenata[896] definirani kao djela ili propusti negativno utječu na pravilno funkcioniranje određenog sustava ili uspješno izvođenje određenog zadatka. Uzroci ljudske pogreške u radu broda su brojni: umor, stres, loše kvalifikacije, nemar, jezik i kulturne razlike na brodovima itd. Razumijevanje ljudskih čimbenika stoga zahtijeva proučavanje i analizu dizajna opreme, interakcije čovjeka/operatera s opremom i postupcima koje slijedi posada. Promjene u ljudskom ponašanju potrebne za interakciju s autonomnim brodovima i pripadajućim sustavima potpore će biti značajne. Pomorsko sučelje čovjek-stroj i povezani ljudski čimbenici stoga će biti posebno kritični u rizičnim i složenim operacijama. Zapravo, ljudski faktor će se moći definirati kao kritična infrastruktura.[897]

5.2.5. INTEGRIRANA TRANSPORTNA LOGISTIKA

Integrirani logistički i transportni sustav predstavlja konačnu integraciju novih pomorskih transportnih sustava i drugih prometnih sustava kao i lanaca opskrbe i proizvodnje. Fokus u kontekstu pomorskog prometa je na fizičkoj i digitalnoj povezanosti s lancima opskrbe i proizvodnje. Glavni izazov s kojim se suočavaju pružatelji logističkih usluga je taj da su sektori transportnih i logističkih usluga heterogeni i fragmentirani. To trenutno ograničava integraciju usluga i kombinaciju resursa. Integrirana ICT infrastruktura za transport i logistiku bit će imperativ za sve vrste prometnog prijevoza. Brojne su potencijalne prednosti u boljem iskorištavanju dostupnih podataka i korištenje informacija i komunikacijske tehnologije u transportu i logistici poput poboljšanja upravljanja prometom u lukama i na moru i smanjeni administrativni trošak u usklađenosti s propisima.[898]

---

[895] ECMAR, *op.cit.*
[896] Vidjeti Allianz na: https://www.agcs.allianz.com/news-and-insights/expert-risk-articles/human-error-shipping-safety.html
[897] *Ibid.*
[898] Loebbecke, C., Powell, P. (1998). Competitive advantage from IT in logistics: the integrated transport tracking system, International Journal of Information Management, 18(1), str. 17-27.

5.2.6. PROIZVODNJA

Materijali i strukture kao i njihova proizvodnja, montaža, opremanje, popravak, dogradnja i recikliranje procesi su koji imaju važan utjecaj na životni ciklus određene brodske strukture, troškove, utjecaj na okoliš i sigurnost modernih brodova. Budući brodovi imat će sve veću kombinaciju različitih materijala u strukturi, kao i u opremi. Korištenjem pametnih materijala i dizajnerskih rješenja plovila će postati fleksibilnija i učinkovitija. Novi materijali za primjenu u pomorskoj gradnji obećavaju smanjenje težine samih brodova, zaštitu okoliša i sl.[899]

5.2.7. PODVODNI ZVUKOVI I AKUSTIKA

Posljedice emisije buke i vibracija brodova (buka propelera, kavitacijska buka i sl.) predstavljaju smetnje i za putnike i za stanovnike u lučkim zonama te potencijalne zdravstvene probleme za posadu, ali i životinjski svijet u morima i oceanima. Dugotrajno izlaganje visokoj razini buke i vibracija uzrokuju umor, smanjuje učinkovitost u radu i može dovesti do pogoršanja sluha. IMO Kodeks o razini buke na brodovima kojeg je usvojila Rezolucijom MSC.337 (91)[900] prepoznala je potrebu za uspostavom obveznih ograničenja razine buke za strojarnice, upravljačke sobe, radionice, smještaj te druge prostorije na brodovima, a na snagu je stupila 1. srpnja 2014. godine. Trenutno se aktivno radi na priznanju međunarodne zajednice za potrebom zakonodavne regulative za podvodnu buku s aspekta određenog tipa onečišćenja. Međutim, potreban je daljnji rad, a dostupni eksperimentalni podaci o podvodnoj buci i razinama emisija su još uvijek vrlo ograničeni.[901]

---

[899] ECMAR, *op.cit.*
[900] Resolution MSC.337(91) (30 November 2012), Adopting of the Code on noise levels on bord ships, dostupna na: https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions/Documents/MSC%20-%20Maritime%20Safety/337(91).pdf
[901] ECMAR, *op.cit.*

5.3. PRIMJENA UMJETNE INTELIGENCIJE U POMORSKOM PROMETU

Poznato je da brodarstvo čini 90 % svjetske trgovine i kao takvo se uvijek smatralo žilom kucavicom svjetske ekonomije.[902] Međutim, ova je industrija također poznata po tome što je ponekad teško implementirati tehnološko-tehničke promjene ili inovacije. Međutim, u zadnje vrijeme vidljive su promjene i iskoraci u prihvaćanju novih i modernih tehnologija pa tako brodarska poduzeća koja su se prije oslanjala na tradicionalne metode i ostajala oprezna u usvajanju naprednih tehnologija, vide blagodati tehnologije i poduzimaju radnje kako bi se prilagodile digitalnom svijetu. Izgleda da je AI među svim mogućnostima relativno privlačna jer bi mogla ponuditi rješenja za pojednostavljivanje većine operacija u međunarodnom pomorskom prometu. Od autonomnih brodova, lučkih usluga, obrade dokumenata do povećanja sigurnosti i smanjenja utjecaja na okoliš, upotreba AI sposobna je sveobuhvatno transformirati pomorsko gospodarstvo.

5.3.1. AUTONOMNI BRODOVI

Kao što je već rečeno, procjenjuje se da više od 75 % do 96 % pomorskih nesreća uključuje ljudski faktor i pogreške[903] uglavnom zbog umora, neadekvatne komunikacije, loše prosudbe i neusklađenosti. Stoga su autonomni brodovi rješenje za povećanje sigurnosti i oslobađanje ljudi od opasnih ili rizičnih aktivnosti u svjetskim morima. Plovilo bez posade bilo bi opremljeno RADAR-om, GPS-om, senzorom, kamerom, satelitom i njime bi upravljao sustav AI, omogućavajući prikupljanje i analizu podataka, kao i planiranje rute i izbjegavanje opasnosti tijekom plovidbe. Budući da troškovi povezani s posadom čine i do 30 % ukupnih troškova putovanja,[904] očekuje se da će i autonomni brodovi donijeti značajne financijske koristi brodarskim poduzećima. Prvi potpuno autonomni trajekt na svijetu koji su razvili *Rolls-Royce* i *Finferries* prikazan je 2018. godine. Autonomni brod *Mayflower* koji koristi IBM tehnologiju AI započeo je svoje transatlantsko putovanje u rujnu 2020. godine. S eksponencijalnom stopom

[902] OECD - Ocean shipping and shipbuilding (2020), dostupno na: https://www.oecd.org/ocean/topics/ocean-shipping/

[903] Allianz - Safety and shipping review (2019), dostupno na: https://www.agcs.allianz.com/content/dam/onemarketing/agcs/agcs/reports/AGCS-Safety-Shipping-Review-2019.pdf

[904] CBInsights - Massive Cargo ships are going autonomous; Here are the companies and trends driving the global maritime industry forward (2018), dostupno na: https://www.cbinsights.com/research/autonomous-shipping-trends/

rasta tehnologije čini se da budućnost u kojoj autonomni brodovi prelaze svjetske plovne putove nije pretjerano daleka.[905]

5.3.2. DIGITALNE LUKE

Kako su brodovi sve veći luke se suočavaju sa sve većim pritiskom da prilagode svoju infrastrukturu za rukovanje različitim tipom tereta. U borbi da ostanu konkurentni brodski terminali nemaju drugu mogućnost već pokušavaju biti brži, učinkovitiji i inteligentniji. AI optimizira lučke operacije ne samo automatizacijom već i korištenjem podataka u stvarnom vremenu. Primjerice, podaci se prikupljaju iz različitih izvora kako bi se procijenilo vrijeme čekanja opreme i izvršilo pravovremeno raspoređivanje kamiona za ulazak, istovar, slaganje itd., smanjujući tako vrijeme praznog hoda objekata, kao i osiguravanje kontejnera i nesmetano rukovanje istim.[906] Nedavno su mnoge luke uspjele iskoristiti AI za digitalizaciju svojih operacija. Luka *Rotterdam* u Nizozemskoj razvila je aplikaciju za predviđanje vremena dolaska plovila,[907] dok je belgijska luka *Antwerpen* stekla vrijedan uvid u prometne tokove iz analiza mobilnosti koje je provodila AI kroz razne svoje podsustave poput računalnog vida.[908]

5.3.3. VIRTUALNI ASISTENTI

U prosincu 2019. brodarsko poduzeće *Maersk* predstavilo je zapovjednika *Petera*, virtualnog asistenta njegove preuređene platforme *Remote Container Management* (RCM).[909] Avatar pomaže kupcima tijekom putovanja njihovog tereta, pazi na temperaturu, vlažnost, razinu CO^2 u spremniku i obavještava ako se uoče neka odstupanja. U pomorskoj industriji

---

[905] Više o projektu SVAN (engl. *Safer Vessel with Autonomous Navigation*) vidjeti na: https://safety4sea.com/rolls-royce-finferries-present-worlds-first-fully-autonomous-ferry/?__cf_chl_jschl_tk__=6995ad1bac112f28061f8590b636478bb9b785b8-1623313432-0-AYu4VkAImdBsqI4kpobqxSy6GY-xflVLvyx7j7WXUAgXLAXZv0fUosUbYfglSbsYD0zyU3AdHh2KF1oGx8SfGLldEQycPmp21T980gJS04NZu1pb6vtDqY8LelFECbB1vOSYjwq_Z9zDO0zxOxppJj_OirHWFC7W7qjJF8BRwhBtoeYjc9cJg674H5G9aDhZllR-Z0HJ1ODGs6GMf56qnZueRg4c4k8GreF-VHaexEuvrmJN0R2kRE0h37SLmgffVlVG1P7Mb_fPQ_VI7CEZjOqSakSlal7JaeeBcBugo4vKvZJ89QyETFsh9fQ7VwWgE9UXA6wqjWT_vepUYqR04-ZF1ayvayGmsdDLx_kRHhdsR5F1EBeoSJ5sITNzjD1A8kdvuKVK63SjsVd8dQDVXdwwy9tOmpkMBbFniB5iex18Asrvze2CbOUlQ0NvyiZ512mcNQUO1T-dTs4d9NSm_pBlTr18tZz6Tlade1rruEn1

[906] Heilig, L., Lalla-Ruiz, E., Voß, S. (2017). Digital transformation in maritime ports: analysis and a game theoretic framework, Netnomics: Economic research and electronic networking, 18(2), str. 227-254.

[907] Više o tome na: https://www.porttechnology.org/news/europes_largest_port_releases_app_to_optimize_shipping/

[908] Više o tome na: https://www.portofantwerp.com/en/smart-port

[909] Maersk (2019). Maersk launches new visibility tool, dostupno na: https://www.maersk.com/news/articles/2019/12/03/maersk-launches-new-visibility-tool-captain-peter

virtualni asistenti mogu pomoći u praćenju pošiljki, rezervaciji isporuke, izmjenama i dopunama naloga, kao i brzom dohvatu i prevođenju informacija kako bi pomogli pomorcima ili zaposlenicima u uredu u dobivanju odgovora ili smjernica u hitnim situacijama. Takvi podsustavi sustava AI u stanju su naučiti preferencije korisnika u cilju pružanja odgovarajućih podataka. Kako tehnologija AI brzo sazrijeva zapovjednici brodova uskoro će moći značajno smanjiti sudjelovanje ljudi u svakodnevnim operacijama brodova, luka, lučkih operacija, oslobađajući osoblje za određene zadatke.[910]

5.3.4. OBRADA DOKUMENATA

Brodarska poduzeća moraju svakodnevno rješavati ogromnu količinu papira kao što su tovarni list, komercijalna faktura, popis pakiranja, bankovni *draft*-ovi i sl. Ručna obrada takvih papirnatih dokumenata nije samo skupa i dugotrajna, već je i sklona pogreškama. Rješenja koja pružaju sustavi AI sposobna su naučiti tisuće različitih oblika, čitati, skenirati i točno izvlačiti pojmove iz dokumenata, smanjujući tako broj unosa podataka, i još važnije, smanjujući stopu netočnosti.[911]

5.3.5. POBOLJŠANJE TOČNOSTI

Povećanje sigurnosti putovanja jedno je od najvažnijih poboljšanja koje bi AI mogla donijeti brodarskoj industriji. Tehnologija može pomoći pomorcima u njihovom radu, odnosno posada može analizirati podatke o vremenskim obrascima, lučkim uvjetima, žarištima kriminala kao i otkrivanju tehničkih anomalija, omogućujući poduzimanje proaktivnih radnji kako bi se izbjegla neočekivana zaustavljanja, štete, incidenti uz osiguravanje sigurnijeg radnog okruženja za radnike. U kombinaciji sa podsustavom za prepoznavanje slika sustavi AI se mogu koristiti za prepoznavanje objekata u okolici, pružanje upozorenja kada je vidljivost loša i minimiziranje pomorskih nesreća između velikih i manjih plovila. U tom smislu sama navigacija bi bila olakšana i inteligentnija jer navigacijski sustav automatski stvara najsigurniju rutu na temelju evidencije o incidentima i sličnim varijablama.[912]

---

[910] Više o tome na: https://thetius.com/brief-guide-to-artificial-intelligence-in-shipping/
[911] Lloyd's Register, Qinetiq, Unoversity of Saouthampton. Global Marine Technology Trends 2030, dostupno na: https://www.lr.org/en/insights/global-marine-trends-2030/global-marine-technology-trends-2030/
[912] Više o tome vidjeti na: https://marine-digital.com/article_optimizing_vessels_route

5.3.6. EKOLOŠKI PRIHVATLJIVI PRISTUP

Iako je pomorski promet i transport daleko najprikladniji za okoliš i način dostave robe,[913] pomorska industrija još uvijek nastoji smanjiti svoj utjecaj u narednim godinama strožim propisima o zaštiti okoliša. AI može uzeti u obzir razne čimbenike za predviđanje optimalne rute smanjujući tako potrošnju goriva i emisije ugljika. Većina autonomnih brodova trenutno je projektirana da budu potpuno električni ili da dobivaju energiju od sunca i vjetra što će zasigurno imati pozitivne utjecaje na okoliš.[914]

5.4. AUTONOMNA NAVIGACIJA U MEĐUNARODNOM POMORSKOM PROMETU

U ovom poglavlju naglasak istraživanja stavlja se na autonomnu navigaciju i primjenu AI u takvim vrstama plovila u međunarodnom pomorskom prometu.

5.4.1. RAZVOJ AUTONOMNIH PLOVILA

Autonomni plovni objekt definira se kao plovni objekt koji, ovisno o stupnju automatizacije i zahtjevima za neposrednim nadzorom stalne službe, može ploviti bez ukrcane posade ili sa smanjenim brojem članova posade.[915] Prema *Waterborne* autonomno plovilo opisano je kao "*modularni upravljački sustav i komunikacijska tehnologija sljedeće generacije koja će omogućiti bežično nadgledanje i kontrolne funkcije i na brodu i izvan njega. Oni će uključivati napredne sustave za podršku odlučivanju koji pružaju sposobnost upravljanja brodovima daljinski pod poluautonomnom ili potpuno autonomnom kontrolom*".[916] Ova plovila koriste najnoviju tehnologiju kao što su IoT, ICT, tehnologija analize podataka i kopnene baze za nadzor/kontrolu povezane širokopojasnom komunikacijom i automatski upravljaju dijelom ili

---

[913] ABB - Maritime's next wave: An ancient industry's bold new thinking (2019), dostupno na: https://www.forbes.com/sites/abb/2019/12/19/maritimes-next-wave-an-ancient-industrys-bold-new-thinking/?sh=5bac0c09552d#6c9bbbb5552d

[914] Više o tome vidjeti na: https://safety4sea.com/cm-electric-vessels-are-making-waves/?__cf_chl_jschl_tk__=7de0ba0adeb019f6ab2c24a5fe98c627da14d8c1-1625128416-0-ATH2tgHsvyPztJiwwxUtQ0pSQpNJX2vKbqkONYC9hgArsvWIjXanE3KrxvrvdXuHcHzlnM7tHPOcqCumAYIxjPcYK4SJJzjSu1IAGj7f4OPHeAAWjpWNbcKhY0P9amCmRfpzoOPcw5vCLY2BQGDsiB5Gp_rRl8JzROB4Ay42rVrfKMhCs_Nz-3PcoHr5hBDWCW4jrLjwovaZRRPIW3pB-ta_xZ-WMSAjEKjO56-bNPS7g4yoonQ5wPX3JiwxdHaLa-FqbHg8qH0crCFskb2iGMiqRAFjeBTI_FNTeudo6nU3iltyT2xr-joX4D_OgcIsauL2XmdWWc6LUCIAc6MXmKlcmaNHetk3ea6Txq10N3kg_DqOaOQdLJ_iST0v2oNptDp3x-F6ZCiN66C2elVf3PpeP2KqcNnweUXGLbNl_JFH-DVGOhrhWXu4pMFBX7ZGIQ

[915] Čl. 5. st. 1. PZ-a

[916] Waterborne Tp. (2017). The Autonomous Ship, Water Borne Technology Platform, Brussels, Belgium

svim brodskim zadacima povezanim s brodskim operacijama poput promatranja njegove okoline, praćenje stanja opreme, manevriranje brodom, nadzor motora, upravljanje/utovar tereta, pristajanje i otključavanje i drugi. Autonomna vozila već su vrhunska u mnogim načinima kopnenog prijevoza što vidimo i, između ostalog, u primjeni na automatiziranim podzemnim željeznicama ili modernim kontejnerskim terminalima. U modernom zrakoplovstvu postoje i vrlo široki pristupi koncepcijama autonomnog upravljanja. Posljedično tome autonomija se također vidi kao mogućnost da pomorski promet odgovori na današnje i sutrašnje izazove konkurentnosti, sigurnosti i održivosti. Ovaj opis podrazumijeva dvije generičke alternative koje se kombiniraju u autonomnom plovilu kao što je vidljivo i na slici 5-1. Prva je daljinski brod gdje se zadaci upravljanja brodom obavljaju putem mehanizma daljinskog upravljanja npr. od strane obale, a drugi je sami autonomni brod[917] na kojem napredni sustavi za podršku odlučivanju donose sve operativne odluke neovisno o intervencije ljudskog operatera.[918]

[917] U ovom radu koristi se izraz autonomno plovilo s obzirom da istraživanje nije ograničeno samo na integraciju autonomnih brodova u međunarodni pomorski promet, nego bi se ista odnosila na različite vrste plovila, a sve sukladno definiciji autonomnog plovnog objekta sukladno čl. 5. st. 27. PZ-a koji podrazumijeva plovni objekt kao pomorski objekt namijenjen za plovidbu morem, a koji u svojoj definiciji uključuje brod, ratni brod, podmornicu, jahtu ili brodicu. Čl. 5. st. 27. PZ-a

[918] Maritime Unmanned Navigation through Intelligence in Networks - MUNIN, The Autonomous Ship (2017), dostupno na: http://www.unmanned-ship.org/munin/about/the-autonomus-ship/

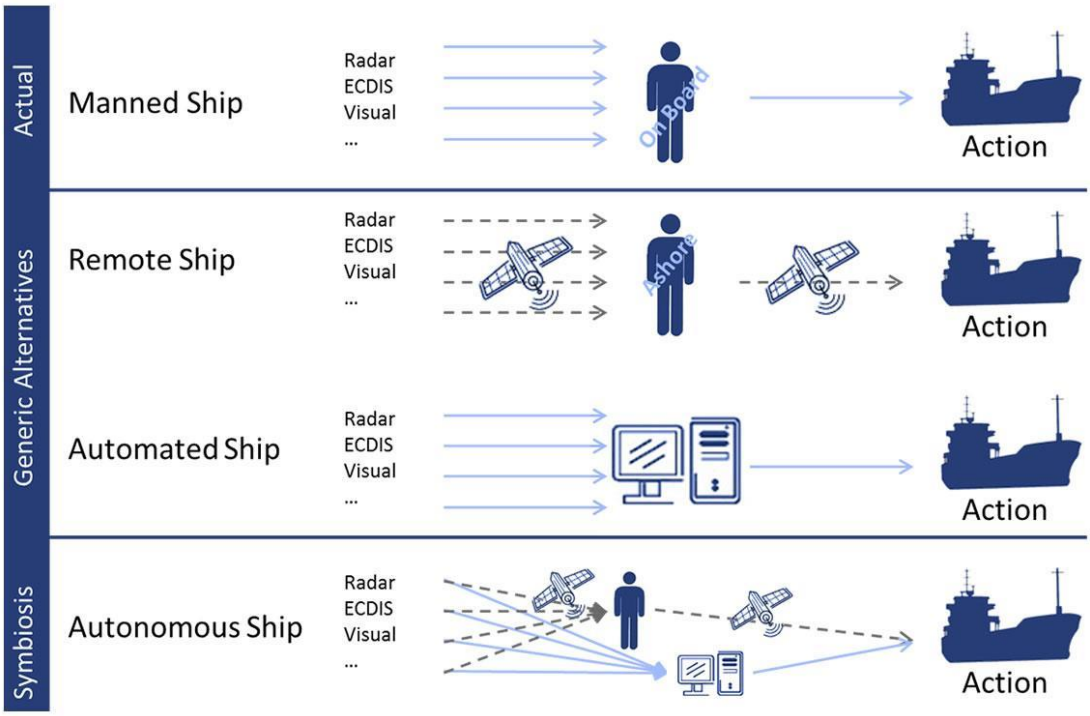

Slika 5-1 Autonomni brod, kako se pretpostavlja u projektu MUNIN, simbioza je broda na daljinsko upravljanje i automatskog broda, Izvor: MUNIN, 2017

Smatra se da autonomna navigacija pridonosi poboljšanju sigurnosti i učinkovitosti pomorskog prometa i prijevoza, radnog okruženja i atraktivnosti radnog mjesta za pomorce te povećanju konkurentnosti pomorske industrije poput pomorskog prometa, brodogradnje i ostalih pomorskih poslova. Na 99. sastanku IMO MSC[919] održanom u svibnju 2018. godine predstavljena su četiri stupnja automatizacije kao privremene definicije autonomnih brodova:[920]

1. Brod s automatiziranim procesima i podrškom za donošenje odluka – posada na brodu postoji kako bi upravljala brodom (neke radnje mogu biti automatizirane).
2. Brod na daljinsko upravljanje s posadom na brodu - brodom se upravlja s drugog mjesta, ali na njemu je posada.
3. Daljinski upravljani brod bez posade na brodu.

[919] Sažetak izvješća vidi na: https://www.imo.org/en/MediaCentre/MeetingSummaries/Pages/MSC-99th-session.aspx

[920] Misli se na autonomni brod u okviru autonomnog plovnog objekta. Brod je plovni objekt namijenjen za plovidbu morem, čija je duljina trupa veća od 15 m ili je ovlašten prevoziti više od 12 putnika. Brod može biti putnički, teretni, tehnički plovni objekt, ribarski, javni ili znanstvenoistraživački. Čl. 5. st. 2. PZ-a; O pojmu autonomnog broda u SAD-u, Kini i Italiji vidjeti: Ćorić, D., Pajković, M. (2018). Autonomni brod nova vrsta broda u pomorskom zakonodavstvu, Druga međunarodna konferencija pomorskog prava "Suvremeni izazovi pomorske plovidbe", Split, str. 110-111.

4. Potpuno autonomni brod – brodski sustav donosi odluke i djeluje sukladno vlastitim odlukama.[921]

Međutim, pojavila se potreba za daljnjim produbljivanjem razina autonomije u cilju ostvarivanja što veće sigurnosti. Registar brodova „*Lloyd's*“ navodi detaljniju razradu:[922]

1. Nema autonomne funkcije.
2. Podrška odlučivanju je na brodu - sve radnje na razini broda poduzima ljudski operater, ali alat za podršku odlukama može predstaviti opcije ili na drugi način utjecati na odabrane radnje, na primjer DP sposobnosti i planiranje rute.
3. Podrška odlučivanju na brodu i izvan njega - sve radnje na razini broda ljudski operater poduzima na brodu, ali alat za potporu odlučivanju može predstavljati opcije ili na drugi način utjecati na odabrane radnje. Podatke mogu pružati sustavi na brodu ili izvan njega, na primjer grafički prikaz sposobnosti DP i sl.
4. "Aktivni" HITL - odluke i radnje na razini broda izvode se autonomno uz nadzor ljudi. Odluke s velikim učinkom provode se na način da se ljudskim operaterima pruži prilika da ih pregledaju, provjere i ponište te donesu nove. Podatke mogu pružati sustavi na brodu ili izvan njega.
5. HITL - operater/nadzor - Odluke i radnje izvode se autonomno uz nadzor ljudi. Odluke s velikim utjecajem provode se na način da se ljudskim operaterima pruži prilika da ih pregledaju.
6. Potpuno autonomno (i rijetko nadzirano) - nenadzirana ili rijetko nadzirana operacija gdje sustav donosi odluke i na njih djeluje.
7. Potpuno autonomno (i bez nadzora).

Za razliku od automobila očekuje se da će autonomna plovila imati razne vrste automatizacije jer je više članova posade odgovorno za mnoge zadatke koji nisu rukovanje brodom poput održavanja motora i nadzora tereta, a čak i ako je automatizirano samo rukovanje brodom potpuno autonomno plovilo ne može biti ostvareno. Prema Godišnjem pregledu pomorskih nesreća i nezgoda 2020. koji je objavila EMSA, 54 % nesreća pripisano je ljudskim

[921] Maritime Safety Committee, 99/5/1. (2018). Regulatory scoping exercise for the use of Maritime Autonomous Surface Ships (MASS). Comments and proposals on the way forward for the regulatory scoping exercise submitted by IFSMA and ITF, str. 7.
[922] Vidi na: https://www.lr.org/en/latest-news/lr-defines-autonomy-levels-for-ship-design-and-operation/

faktorima.[923] Očekuje se da će naprednije rukovanje plovilom pomoću senzora poboljšati pouzdanost pomorskog prijevoza i pomoći u sprječavanju pomorskih nesreća. Uz to, sugerira se da će stalni porast opsega međunarodnog pomorskog prometa dovesti do uskog globalnog tržišta za pomorce u budućnosti. Usred tako rastućih očekivanja napori na realizaciji autonomnih plovila pojačani su širim usvajanjem AIS, ECDIS i drugih sustava elektroničke navigacije, zajedno s brzim napretkom pomorskih širokopojasnih komunikacija, IoT, AI i BD i sl.

Također, za naglasiti je da bi se takvi sustavi obično pokretali brodom na automatskim i potpuno determinističkim kontrolnim funkcijama za što će biti potrebni razni senzorski sustavi za otkrivanje problematičnih situacija poput neočekivanih predmeta u moru, opasnih vremenskih uvjeta ili opasnosti od sudara. Ako se dogodi neočekivana situacija, aktivirat će se autonomni upravljački modul koji pokušava popraviti situaciju unutar zadanih ograničenja. Ako sustav to ne može postići, zatražit će podršku od udaljenog operatera ili će pokrenuti postupak zaštite od pogreške ako operater nije dostupan. Ako se pravilno primijeni, ova vrsta autonomije smanjit će potrebu za ljudskim nadzorom, zadržavajući pritom visoku i dobro definiranu razinu sigurnosti. Međutim, glavni će izazov biti senzorski sustavi tako da se sve relevantne opasne situacije pouzdano otkriju i na njih primjereno djeluje.[924]

5.4.2. PROJEKT MUNIN

Autonomna navigacija kroz inteligentnu mrežu (engl. *Maritime Unmanned Navigation through Intelligence Networsk* - MUNIN) je projekt razvoja tehnologije za autonomno plovilo bez posade.[925] Struktura projekta odnosi se na koncept broda koji je potpuno bez posade barem za dijelove putovanja. Nadalje, projekt cilja na kratkoročne eksploatacijske potencijale za potporu tehnološkom napretku u konvencionalnom prijevozu. Projekt je dijelom financiran iz programskog okvira Komisije[926] s iznosom od 2,9 milijuna eura, a ukupni iznos proračuna je 3,8 milijuna eura. Bespilotna i autonomna plovila mogu doprinijeti cilju održivije europske industrije pomorskog prometa u kontekstu:

---

[923] European Maritime Safety Agency, Annual Overview of Marine Casualties and Incidents in 2020, dostupno na: http://www.emsa.europa.eu/newsroom/latest-news/item/4266-annual-overview-of-marine-casualties-and-incidents-2020.html
[924] *Ibid.*
[925] Više o tome na: http://www.unmanned-ship.org/munin/
[926] EU Commission's Seventh Framework Programme Grant Agreement No. 314286, dostupno na: https://ec.europa.eu/growth/sectors/space/research/fp7_en

- smanjivanja operativnih troškova,
- smanjivanja utjecaja na okoliš i
- privlačenje nove radne snage u pomorstvu.[927]

Projekt se bazirao na testiranju kroz plovidbu *bulk*-a odnosno nosača rasutog tereta. Razlog tome je što brodovi za rasuti teret obično prevoze teret izravno od točke do točke što rezultira dugim neprekinutim pomorskim putovanjem. Koncept MUNIN definira sljedeće sustave i entitete (slika 5-2):

- napredni senzorski modul koji brine o dužnostima čuvara na brodu kontinuiranim stapanjem podataka senzora iz postojećih navigacijskih sustava poput RADAR-a i AIS-a u kombinaciji s dnevnim pregledom slika dobivenih iz kamera i infracrvenih kamera,
- autonomni navigacijski sustav koji slijedi unaprijed definirani plan putovanja unutar određenog stupnja slobode za podešavanje ruta u skladu sa zakonodavstvom,
- autonomni motor i nadzor, odnosno kontrolni sustav koji obogaćuje brodove strojarnica i pogonski automatizirani sustavi s naprednim funkcijama za otkrivanje i rukovanje kvarovima dok zadržava optimalnu učinkovitost i brigu o dodatno instaliranom "*pumpjett*-u" koji djeluje kao kormilo i pogon redundancije i
- obalni kontrolni centri (SCC) koji kontinuirano nadziru i kontroliraju autonomno upravljano plovilo nakon što je pušteno u pomorski promet, a sastoje se od:
    - operatera u obalom kontrolnom centru koji nadgleda siguran rad autonomnih plovila u smislu ažuriranja plana putovanja operativnog autonomnog sustava,
    - inženjera u obalnom kontrolnom centru koji pomaže operateru u slučaju tehničkih pitanja te
    - tima u situacijskoj sobi obalnog kontrolnog centra koji može preuzeti izravno daljinsko upravljanje plovilom u određenim situacijama.[928]

[927] Maritime Unmanned Navigation through Intelligence in Networks - Research in Maritime Autonomous Systems, Project Results and Technology Potentials. (2016). str. 1, dostupno na: http://www.unmanned-ship.org/munin/wp-content/uploads/2016/02/MUNIN-final-brochure.pdf
[928] Maritime Unmanned Navigation through Intelligence in Networks, str. 4-5.

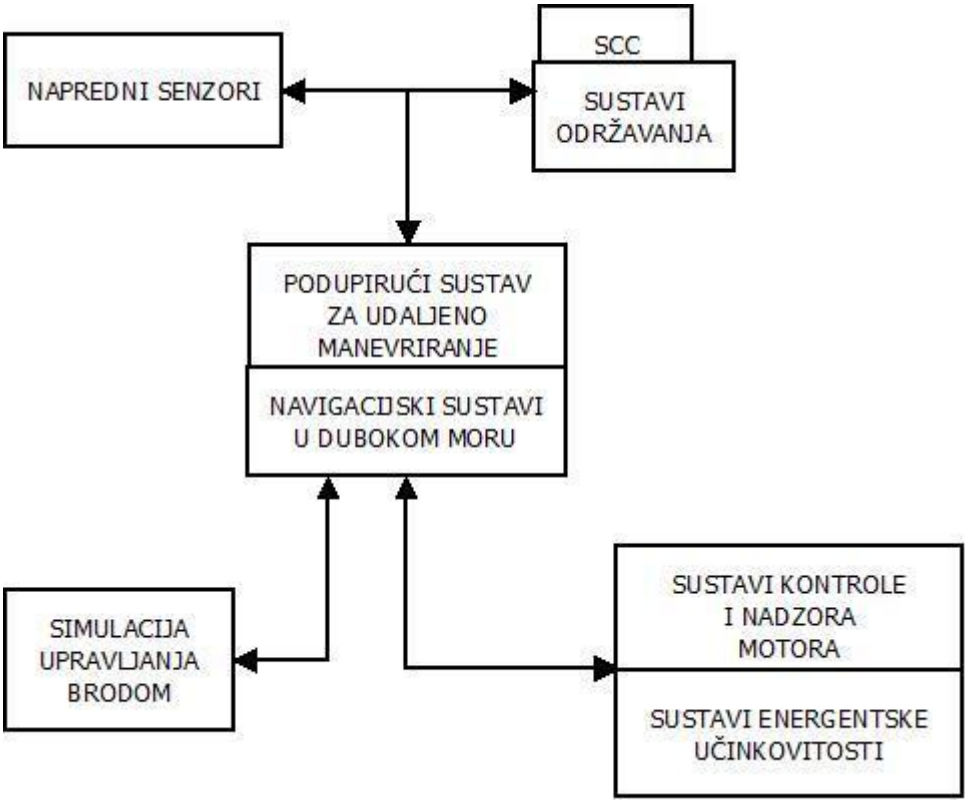

Slika 5-2 Odnos sustava i entiteta po MUNIN-u,

Izvor: MUNIN. 2017

Pod uvjetom da autonomno plovilo može djelovati najmanje jednako sigurno kao brod s posadom u svim svojim funkcionalnostima nema razloga za razmišljanje da se pravni okvir ne može prilagoditi kako bi se integrirala takva autonomna navigacija u pomorskom prometu. Glavna područja koja zabrinjavaju su navigacija, posada, pitanja odgovornosti za štetu koja može nastati od strane broda. U svakom slučaju, primjena autonomnih plovila u pomorskom pravu će značajno utjecati na sadašnje pravne propise kako glede standarda u gradnju, dizajnu i opremi plovila, tako i glede mnoštva pitanja na koja treba ponuditi odgovor kako bi pravna regulativa bila što kvalitetnija. U pogledu odgovornosti najveći problemi tiču se pripisivanja odgovornosti postojećeg plovila odnosno zapovjedničke dužnosti prema osobi u SCC zaduženoj za rad sustava. Nejasna je podjela odgovornosti između operatera u SCC i nadležnih mu osoba ili individualnom entitetu unutar SCC. Osim profitabilnosti, sigurnost je naravno poluga provedbe autonomnog plovila. Kategorija sudara i nezgoda na moru predstavlja gotovo 50 % svih ukupnih pomorskih incidenata u razdoblju od 2005. do 2014. godine što jasno

predstavlja kategoriju s najvećim incidentom vjerojatnosti, a posebice ako uzmemo u obzir da su ljudske pogreške presudni dio osnovnog uzroka većine pomorskih nesreća.[929]

Na temelju analize MUNIN autonomna navigacija za 10 puta smanjuje rizik od sudara i nezgode u odnosu na ljude. Također, rizici od kvarova motora i drugih sustava za autonomna plovila bi trebali biti manji ako je implementirana zadovoljavajuća razina redundancije i kvalitetnog održavanja (slika 5-3). Vatra i eksplozija predstavljaju relativno mali dio svih incidenata. S mogućnošću da koristi učinkovitije sustave za gašenje u potpuno zatvorenim prostorima, vjerojatno će autonomno plovilo biti mnogo manje sklono riziku nego plovilo s posadom. Konačno, rizici od kiber napada i pirata su pitanja koja izazivaju zabrinutost. Međutim, softverski sustavi kao i plovila mogu biti dizajnirani i izrađeni tako da pružaju vrlo visoku otpornost na digitalne i fizičke ugroze.[930]

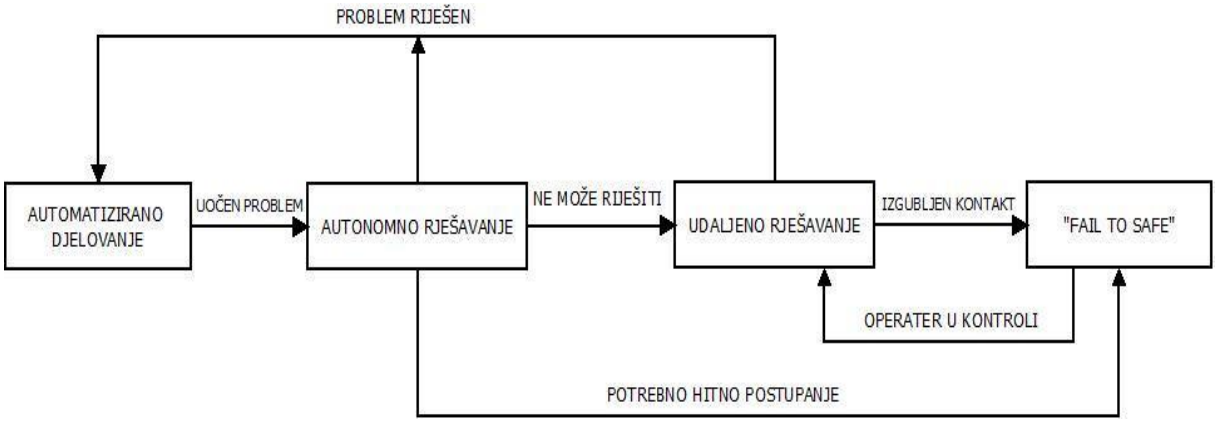

Slika 5-3 Sustav odlučivanja na brodu koji se provodi u MUNIN-u, Izvor: MUNIN, 2017.

Zaključak projekta jeste da je tehnologija uglavnom dostupna odnosno da ju je potrebno integrirati i poboljšati. Naravno, to predstavlja značajan izazov u sustavu pomorskog prometa, odnosno u korelaciji s obalom i drugim plovilima. Uz to, najveći izazov predstavljaju javno mnijenje, pravna pitanja i odgovornost što su zapravo i odgađajući faktori u svakodnevnoj i širokoj primjeni ove tehnologije.

[929] Više o tome na: http://www.unmanned-ship.org/munin/about/munin-results-2/
[930] Više o tome na: http://www.unmanned-ship.org/munin/about/the-autonomus-ship/

5.4.3. DALJINSKI UPRAVLJANA, TEHNIČKI - TEHNOLOŠKA PODRŠKA I CENTRI ZA OBALNO UPRAVLJANJE

Kako su brodovi postajali sve složeniji, brodovlasnici su se sve više oslanjali na dobavljače koji će upravljati i održavati njihova plovila. U kontekstu upravljanja i održavanja pojedina brodarska poduzeća se trude zaposliti novu generaciju inženjera strojeva što ponekad zna predstavljati problem s obzirom na to da elektronika i podatkovni sustavi na brodu iziskuju konstantno napredovanje i stalnu višu razinu kompetencije, ali mladi inženjeri imaju tendenciju da više vole poslove na kopnu.[931] Kao odgovor na ovaj sve veći izazov, određena poduzeća poput *DNV GL* udružile su snage s prodavačem automatiziranih sustava. Na primjeru *DNV GL* suradnja je krenula s poduzećem *Høglund*, norveškim trajektnim operaterom *Fjord1* i norveškim pomorskim vlastima kako bi uspostavio projekt ROMAS (engl. *Remote Operations of Machinery and Automation Systems*).[932] ROMAS, odnosno daljinsko upravljanje strojevima i sustavima automatizacije usredotočen je na premještanje upravljačke sobe motora (engl. *Engine Control Room* - ECR) s broda u obalni upravljački centar motora (engl. *Engine Control Center* - ECC).[933] Na takav način jedan ili više glavnih inženjera može daljinski upravljati pogonskim sustavima i sustavima pomoćnih strojeva na cijeloj floti plovila. Fokus je na identificiranju potrebnih tehničkih rješenja i uspostavljanju regulatornog okvira s pravilima i metodama provjere za daljinsko upravljanje brodskim strojevima i sustavima automatizacije. Prijenos odgovornosti, objekata za nadzor i kontrolu na obalu, smanjuje potrebu za inženjerima strojeva na brodu i trebao bi učiniti poslove pomorskog inženjeringa privlačnijim. Automatizacija i daljinsko poslovanje sve se više usvajaju u drugim industrijama, a brodarstvo poduzima prve korake prema autonomnom plovljenju. Automatizacija u strojarnici postoji već dugo vremena tako da se ovaj koncept temelji na postojećim tehnologijama i važan je korak prema potpuno autonomnom ili visoko automatiziranom plovilu. Velika ulaganja u ovom trenutku idu u električne i hibridne trajekte odnosno plovila koja će podržavati siguran i učinkovit transportni sustav, ali digitalna i povezana rješenja na brodu također omogućavaju udaljenije radnje s povećanom potporom na obali radi veće sigurnosti i učinkovitosti.[934]

---

[931] *Steinar Låg*, glavni istraživač na autonomnim brodovima u *DNV GL*.
[932] Vidi više: ROMAS (2018). Remote Operations of Machinery and Automation Systems, DNV, dostupno na: https://www.dnv.com/research/review2018/featured-projects/romas-remote-operations-machinery-automation.html
[933] *Ibid.*
[934] *Kim Gunnar Jensen*, projektni inženjer u poduzeću *Fjord1*.

Novi pristupi dizajnu i operacijama u kombinaciji s povećanom redundancijom i naprednijim održavanjem znače da bi se konceptom moglo uopće upravljati bez ikakvih inženjera strojeva. Jednom kad se poduzme ovaj korak put do autonomnijih plovila postaje jasniji i kraći. U tom kontekstu važno je odrediti distinkciju između autonomnog prijevoza i automatiziranog prijevoza. U svakom slučaju granica između dvaju pojmova je tanka, ali razborito je znati da će autonomija donijeti mnoštvo promjena u međunarodni pomorski sektor, a automatizacija će to omogućiti.[935] BIMCO[936] navodi da će potpuno autonomnim plovilima u međunarodnim putovanjima dugo trebati da postanu stvarnost. Osim što su potrebne nove tehnologije i mora postojati poslovna vizija, drugi su izazovi nedostatak propisa, osiguranje i prihvaćanje tržišta. Već smo vidjeli kako se projekti bespilotnih brodova planiraju u nacionalnim vodama, međutim, budući da su oni do sada bili poprilično subvencionirani, nije jasno grade li se na održivom poslovnom modelu.

Autonomna plovila prvo će se pojaviti tamo gdje postoji značajan rizik za ljudski život na mjestima gdje je korištenje robota sigurnije od korištenja ljudi. Potom će se proširiti na područja u kojima je lakše kontrolirati radnje i osigurati sigurnost prometa poput kraćih plovidbi od obale do obale, trajekata koji plove unaprijed definiranim rutama i malih teretnih brodova. Poduzeća za upravljanje brodovima koje koriste autonomne brodove također će koristiti vlastite terminale i luke.

Autonomna plovidba nastavit će se razvijati tijekom sljedećih 15-30 godina. U budućnosti će se nadzor brodskog prometa preseliti na obalu i vjerojatno će se uspostaviti standardizirani okvir vrlo sličan onome što danas imamo u zrakoplovstvu. Ova razina koordinacije bit će potrebna u pomorstvu. Zrakoplovima gotovo u potpunosti upravlja avio-

---

[935] Pojmove možemo objasniti i kroz primjer. Zamislimo nekoliko plovila na putu iz polazne luke „A“ kako bi stigli u različite luke širom svijeta, svaki u određeno vrijeme. Ova plovila nemaju zapovjednika ili posadu na brodu i mogu samostalno ploviti, pristajati, utovariti, istovariti i napuniti gorivo, a održavaju ih senzori, roboti, dronovi i sl. Plovilima upravlja računalo iz potpuno automatizirane luke bez ljudske intervencije ili interakcije. Operativni sustav svakog plovila donosi odluke i poduzima radnje na temelju situacije u kojoj se nalazi. To je "autonomni prijevoz" i razlikuje se od automatiziranih plovila. S druge pak strane, automatizirano plovilo diktirano je nekim stupnjem ljudske intervencije i kao takvo nema razinu inteligencije ili neovisnosti kakvu ima autonomno plovilo. Raspon između ručno - automatiziranih i autonomnih plovila nastoji biti klizna ljestvica različitih sposobnosti čovjeka u odnosu na stroj. Autonomno znači da plovilo samostalno donosi dovoljno složene odluke i nema ljudske intervencije. Čak i uz najnapredniju automatizaciju, tehnički pristup brodarstvu, apsolutnu redundanciju i izradu sigurnosnih kopija s kopna, teško je zamisliti kako se mogu riješiti sve operativne dužnosti i zadaci održavanja koje obavlja posada u određenom trenutku. Moglo bi se spomenuti mnogo primjera: senzori koji otkrivaju poplavu mogu, na primjer, automatski pokretati pumpe, ali kako će sustavi moći pronaći uzrok ulaska vode i zaustaviti curenje?

[936] Vidjeti: Juhl, J. S. (2020). Autonomous ships, BIMCO, dostupno na: https://www.bimco.org/ships-ports-and-voyage-planning/maritime-digitalisation/autonomous-ships

pilot i u tom su smislu autonomni, unatoč činjenici da u kokpitu još uvijek imaju posadu koja balansira i procjenjuje rizike u hitnim slučajevima. Ne možemo u potpunosti eliminirati ljudski faktor na moru, što nije niti cilj, ali predviđa se slična budućnost u pomorstvu.

5.4.4. ODGOVORNOST UPRAVLJANJA SUSTAVOM UMJETNE INTELIGENCIJE AUTONOMNIH PLOVILA

Na pitanje bilo kakve odgovornosti odgovore treba tražiti u postojećoj pravnoj regulativi. Prema odredbi čl. 385. PZ-a, za obveze u vezi s plovidbom i iskorištavanjem broda odgovara brodar (ako PZ ne propisuje drugačije). Osnovno je načelo pomorskog imovinskog prava da brodar odgovara za radnje osoba, kojima se služi u svom poslovanju, kao za svoje radnje odnosno propuste. Razne opasnosti specifične za pomorsku plovidbu mogu doprinijeti nastanku pomorskih havarija (nezgoda) koje, iako smanjene zbog primjene mnogobrojnih tehnoloških dostignuća, još uvijek rezultiraju nastankom sudara brodova, udara, potonuća i dr. Na međunarodnoj razini imamo veliki broj pravnih normi kojima se unutar konvencija normira pitanje odgovornosti za tako nastale štete poput primjerice:

- Međunarodne konvencije za izjednačavanje nekih pravila o sudaru brodova iz 1910.,[937]
- Međunarodne konvencije za izjednačavanje nekih pravila o kaznenoj nadležnosti za sudar i druge plovidbene nezgode iz 1952.,[938]
- Međunarodne konvencije za izjednačavanje nekih pravila o građanskoj nadležnosti za sudar iz 1952.,[939]
- COLREG-a i
- Lisabonskih pravila CMI-a o naknadi štete u slučaju sudara brodova iz 1987.[940]

Kad je riječ o odgovornosti, uz navedene konvencije iz kojih proizlaze i odredbe PZ-a, primjenjuju se odredbe o izvan ugovornoj odgovornosti koju brod ili drugi plovni objekt[941] prouzroči osobama, stvarima izvan broda te morskom okolišu, ali se ne odnose na sudar brodova i nuklearne štete.[942]

---

[937] Convention for the Unification of Certain Rules of Law with respect to Collisions between Vessels. (1910).
[938] International Convention for the unification of certain rules relating to penal jurisdiction in matters of collision or other incidents of navigation. (1952).
[939] International Convention on Certain Rules concerning Civil Jurisdiction in Matters of Collision. (1952).
[940] Lisbon Rules 1987 – Comite Maritime International. (1987).
[941] Odredbe PZ-a o izvanugovornoj odgovornosti vlasnika broda i brodara primjenjuju se na sve plovne objekte, bez obzira na veličinu i namjenu kojoj služi te na hidroavion na vodi. Čl. 809. st. 1. PZ-a.
[942] Čl. 808. PZ-a

Pojam sudar[943] brodova definira se kao događaj u kojem jedan ili više brodova izravnim dodirom ili neizravno prouzroči štetu na drugom brodu, imovini ili osobama što se nalaze na brodu i takve odredbe vrijede za svaki plovni objekt bez obzira na njegovu namjenu.[944] U pogledu odgovornosti za sudare na moru primjenjuje se tzv. načelo dokazane krivnje[945] odnosno pod odgovornošću broda podrazumijeva se odgovornost vlasnika broda i brodara što vrijedi u slučaju obveznog i fakultativnog peljarenja.[946]

Važno je istaknuti i pojam podijeljene odgovornosti. Naime, ako je šteta prouzročena krivnjom dvaju ili više brodova, svaki brod odgovara razmjerno svojoj krivnji.[947] Jedino u slučaju nemogućnosti utvrđivanja opsega krivnje brodova, odgovornost se dijeli na jednake dijelove.[948] Isto tako poznate su i odredbe o ulozi zapovjednika u slučaju sudara. Prema odredbi čl. 756.st.1. PZ-a, zapovjednik broda dužan je brodu, s kojim se sudario, priopćiti ime posljednje luke iz koje je isplovio i ime luke u koju plovi. Ujedno je dužan (ako to može učiniti bez ozbiljne opasnosti za brod kojim zapovijeda i za osobe na njemu) pored prvenstvenog spašavanja osoba, poduzeti spašavanje drugog broda s kojim se sudario.[949]

Međutim, pitanje koje se postavlja jest pitanje odgovornosti autonomnog plovila odnosno sustava AI koji je upravljao autonomnim plovilom u vrijeme sudara s drugim plovnim objektom. U brodskoj industriji vodila se značajna rasprava o tome mogu li se plovila bez posade ili s potpuno omogućenom AI striktno pridržavati važećih odredbi COLREG-a, uključujući Pravilo 2 (odgovornost), Pravilo 8 (radnje za izbjegavanje sudara) s obzirom na standard pomorstva, pravilo 5 (oprez) i pravilo 18 (odgovornosti među brodovima) s obzirom na plovila „pod zapovjedništvom“. Razna istraživanja provedena tijekom proteklih 12 do 18 mjeseci pokazala su da autonomna navigacija može ispuniti (ili premašiti) trenutna pravila

---

[943] Definicija pojma sudar je veoma važna, jer ako se sudar ne može podvesti pod zakonsku definiciju neće se primijeniti odredbe plovidbenog, nego građanskog prava. Jakaša, B. (1990). Sistem plovidbenog prava Jugoslavije, četvrta knjiga, plovidbene nezgode, Narodne novine, Zagreb, str. 28. Pomorska nesreća je sudar plovnih ili plutajućih objekata, nasukanje ili druga plovidbena nezgoda, ili drugi događaj na plovnom odnosno plutajućem objektu ili izvan njega koji uzrokuje materijalnu štetu ili predstavlja neposrednu opasnost od nastanka materijalne štete na plovnom odnosno plutajućem objektu ili njegovu teretu. Čl. 840.a st. 3. PZ-a.

[944] Pomorske nesreće – sudar brodova, spašavanje i zajednička havarija. Dostupno na: https://www.pravo.unizg.hr/_download/repository/Pomorske_nesrece_sudar_spasavanje_zajednicka_havarija%5B1%5D.pdf Sudar (engl. *Collision of ships*, franc. *Abordage, collision en mer*, tal. *Urto di navi, abbordagio*, njem. *Schiffszusammenstoß*) je sraz, sukob dvaju ili više brodova pri kojem je uzrokovana šteta makar jednome brodu u sudaru (ili) stvarima ili osobama na brodu. Kačić, H. (1968). Naknada štete u slučaju sudara pomorskih brodova, Jugoslavenska akademija znanosti i umjetnosti, Zagreb, str. 24.

[945] O pojmu dokazane krivnje vidjeti: Jakaša, B., *op.cit.*, str. 53.

[946] Huger, A. (1928). Proportional Damage Rule in Collisions at Sea, Cornell Law Review, Vol. 13

[947] Čl. 752. st. 1. PZ-a

[948] Čl. 752. st. 2. PZ-a

[949] Čl. 766. PZ-a

COLREG-a. Projekt MAXCMAS (engl. *Machine Executable Collision Regulations for Marine Autonomous Systems*)[950] poduzeća *Rolls Royce,* u partnerstvu s *Lloyd's Registerom* (između ostalih), tvrdi da su razvili navigacijski sustav, zasnovan na AI, koji omogućuje učinkovito provođenje pravila COLREG-a na način koji se ne razlikuje od „dobrog ponašanja pomoraca“, čak i u okolnostima "kada brod koji određuje put ne poduzme odgovarajuće mjere." Potonje će biti neophodno kada se autonomna plovila i plovila s posadom nastoje udaljiti od puta jedan drugome. Nije jednostavno riješiti pitanja koja se tiču "*Compliance*-a" ili usklađenosti, ali slučaj *Evergreen* pokazuje dva problema: časniku palube ne moraju uvijek biti očigledni identitet broda za ustupanje puta i da "dobro ponašanje pomoraca", u kontekstu raspodjele odgovornosti, nije fiksni standard već proizvod činjeničnih okolnosti, tumačenih kroz razna pravila COLREG-a, prošlu sudsku praksu i stavove stručnih nautičkih procjenitelja nakon događaja. Baš kao što je jedna od dilema s kojom se suočavaju zapovjednici i časnici što učiniti kad se suoče sa situacijom u kojoj se čini da su obveze prema COLREG-u u sukobu, oni koji razvijaju autonomna brodska rješenja moraju se jednako boriti s istim dilemama. Osim što ove odluke moraju programirati prije događaja na način koji je predvidljiv ili će sustav morati primijeniti ML kako bi mogao biti u skladu s pravilima COLREG-a. Dobar primjer je slučaj sudara broda *Ever Smart* i *Alexandra I.*[951] Postavlja se pitanje kako će onda dva autonomna plovila prepoznati svoje obveze prema COLREG-u? S obzirom na nesigurnosti oko primjene prava prolaza u uskom kanalu i nedostatku jasnih smjernica o tome kada će se smatrati da se plovilo nalazi na "dovoljno definiranom putu", ostaje nejasno da li bi se situacija prolaska mogla pojaviti u istoj ili sličnoj činjeničnoj okolnosti da su brzina ili smjer *Alexandre I* utvrđeniji. Ne ulazeći u detalje samog sudara, postavlja se pitanje gdje čak i uz upotrebu naprednih algoritama ovo može biti teška zagonetka za autonomni sustav da je riješi.

[950] Vidjeti: MAXCMAS success suggests COLREGs remain relevant for autonomous ships (2018), dostupno na: https://www.rolls-royce.com/media/press-releases/2018/21-03-2018-maxcmas-success-suggests-colregs-remain-relevant-for-autonomous-ships.aspx

[951] Detaljnije: Lessons learned from ‘Alexandra 1’ collision: Confused with Rules of the Road (2019), dostupno na: https://safety4sea.com/cm-lessons-learned-from-alexandra-1-collision-confused-with-rules-of-the-road/

Da bi se utvrdila odgovornost u tom slučaju, valja prvo identificirati dionike, a potom i uzroke sudara[952] / nesreća[953] / havarija[954] / udara.[955] Odgovor na to pitanje nije jednostavan već iziskuje i predikciju budućnosti odnosno razumijevanje autonomnih sustava upravljanih AI. U temeljnom određivanju dionika istakli bi se brodar[956] / brodarsko poduzeće,[957] poduzeća proizvođači sustava AI, razvojni programeri tih poduzeća, upravitelji u obalnim kontrolnim centrima. Postojati će rizik za razvojne programere sustava AI i vlasnike autonomnih plovila. Osim toga, u lancu odgovornih za štetu koje nanese autonomno plovilo mogli bi se svrstati i koderi i integratori, kao i vlasnici skupa podataka.[958] Od programera pomorskih sustava AI nije potrebno samo da kodificiraju usklađenost sa sigurnosnim standardima u pomorskom prometu koji se trenutno koristi, već se također moraju izraditi algoritme koji omogućavaju autonomnim plovilima interakciju s brodovima i posadom, bespilotnim (daljinski upravljanim) brodovima i potpuno autonomnim plovilima što mora biti moguće bez obzira na različita stanja tehnologije na brodu. Tako se od autonomnih plovila može zatražiti tumačenje VHF poruka standardne frekvencije čak i kada su opremljene VDES sustavom. Unatoč najboljim namjerama, nesreće se još uvijek mogu dogoditi. S obzirom na to da o ovom pitanju ne postoji sudska praksa, odgovornost trećih osoba u slučaju sudara u kojem sudjeluje autonomno plovilo još nije jasna. Moguće je da razvojni programeri mogu biti odgovorni za štetu zbog sudara ako se dokaže da je kvar u programiranju ugrađenih sustava AI ili način na koji se razvilo pod utjecajem ML što je uzrokovalo ili doprinijelo sudaru. Ono što otežava mogućnost utvrđivanja bilo kakve

---

[952] Vidjeti *infra,* bilj. 953. i 954.

[953] Prema Glavi I.b čl. 49.i st. 1. PZ-a pomorskom nesrećom se smatra svaki izvanredni događaj na moru koji je prouzročio štetne posljedice kojima su neposredno ugroženi ljudski životi, imovina i okoliš. Više o tome može se vidjeti i na: Hrvatsko strukovno nazivlje na: http://struna.ihjj.hr/naziv/pomorska-nesreca/18189/

[954] Prema čl. 789. – 807. PZ-a pomorska (zajednička) havarija je *svaka izvanredna šteta, gubitak ili trošak koji zadese pomorsku imovinu (tj. brod, teret i/ili vozarinu) za trajanja pomorskog plovidbenog pothvata, odnosno od ukrcavanja tereta i polaska na plovidbu pa do prispjeća u luku odredišta i iskrcavanja, ili do kakvog drugog mjesta gdje je ta plovidba prijevremeno okončana.* Više o tome vidjeti i na: https://www.pfri.uniri.hr/web/dokumenti/uploads_nastava/20190208_194956_vio_POMORSKE_HAVARIJE_I_OSIGURANJE.pdf

[955] Pomorski udar je materijalni sraz broda s čvrstim pomorskim ili kopnenim objektom. Tako primjerice udar smatramo materijalni sraz broda sa svjetionicima, obalama, plutajućim napravama, nepomičnim odobalnim objektima i sl. Odredbe PZ-a o pomorskom sudaru se ne primjenjuju u ovom slučaju. Više o tome vidjeti na: https://www.pravo.unizg.hr/_download/repository/Pomorske_nesrece_sudar_spasavanje_zajednicka_havarija%5B1%5D.pdf

[956] Brodar (engl. *temporay ship-owner*) je posjednik (držatelj) vlastitog ili tuđeg broda ili plovidbenog pothvata, koji imenuje i razrješava zapovjednika broda i ima sveukupnu upravu nad brodom. Grabovac, I., *op.cit.,* str. 59.

[957] Brodarsko poduzeće organizirano je u odjele i sektore. O tome više: Perović, D., Vukčević, M., Milošević, D. (2005). Poslovna logistika i organizacija suvremenog pomorskog poduzeća, NAŠE MORE: znanstveni časopis za more i pomorstvo, 52(3-4), str. 109-113.; Mitrović, F. (2008). Ekonomika brodarstva, Sveučilište u Splitu, Pomorski fakultet u Splitu, Split, str. 49.

[958] Papović, B.N. (2019). Veštačka inteligencija – skriveni rizici, Tokovi osiguranja 1/2019, str. 107.

odgovornosti AI jeste što se odgovornost proizvođača AI i programera AI ne mogu utvrđivati na isti način.[959] Analizom recentnih pravnih odredaba na odgovornost proizvođača autonomnog plovila shodno bi se primjenjivala pravila iz Konvencije o mjerodavnom pravu za odgovornost proizvođača za svoje proizvode iz 1973.,[960] Direktive 85/274,[961] Direktive 1999/34,[962] kao i ZOO.[963] Uz to, postoje i etička razmatranja o tome kako autonomno plovilo treba programirati u scenarijima u kojima AI treba birati između gubitka ili oštećenja vlastitog plovila ili tereta, ili gubitka ljudskog života ili ozbiljnog onečišćenja okoliša.[964]

Također se moraju uzeti u obzir budući scenariji u kojima autonomno plovilo pretrpi katastrofalni kvar poput potpunog električnog kvara. Brod za potrebe COLREG-a više neće biti brod pod zapovjedništvom, ali također može biti ograničen u mogućnosti da to priopći obližnjim brodovima ili nadzornim centrima na obali u nedostatku ljudskog zapovjednika koji još uvijek može imati koristi od satelitskog telefona ili, na tradicionalan način, podignuti dvije crne kugle na vrh jarbola. U svakom slučaju, može se zaključiti kako odgovornost treba biti dovedena u uzročno-posljedičnu vezu s novonastalom situacijom na moru. Ovisno o vrsti kvara ili djelovanja autonomnog plovila odgovornost trebaju snositi oni dionici za koje se može utvrditi da su sudjelovali u kreaciji ili kreirali elemente koji su zakazali u određenom trenutku. Generalizacija odgovornosti neće proizvesti dobre rezultate za daljnji napredak i korištenje AI u međunarodnom pomorskom prometu, a vodeći se postojećim relevantnim pravnih aktima u pomorstvu, s doradom i ažuriranjem u pogledu AI, može se stvoriti uređeni sustav kao temelj svih budućih regulatornih, tehničkih i tehnoloških postupanja.

---

[959] Vidjeti više o odgovornosti AI: Jovanović, S.O. (2018). Izazovi pravnog regulisanja robota i osiguranja od šteta prouzrokovanih njihovom upotrebom, Tokovi osiguranja br. 3/2018, str. 123 i dalje; O odgovornosti AI u pojedinim zemljama vidjeti: Chatzipanagiotis, M., Leloudas, G. (2020). Automated vehicles and third-party liability: A European perspective, Journal of Law, Technology & Policy, Vol. 2020.

[960] Konvencija je objavljena u Službenom listu bivše SFRJ MU 8/1977. Notifikacijom o sukcesiji od 22. siječnja 1994. Hrvatska je postala strankom Konvencije od 8. listopada 1991. Ovom Konvencijom se određuje mjerodavno pravo za odgovornost proizvođača i drugih osoba iz čl. 3. navedene konvencije za štetu koju nanese neki proizvod. Čl. 1. Konvencije o mjerodavnom pravu za odgovornost proizvođača za svoje proizvode iz 1973.

[961] Za više o odgovornosti vidjeti: čl. 1., čl. 2., čl. 6., čl. 8., čl. 12. Direktive 85/274.

[962] Ova Direktiva sadrži izmjene u odnosu na Direktivu 85/274 u pogledu pojma „proizvod“ koji predstavlja sve pokretnine, čak i ako su dio druge pokretnine ili nekretnine, kao i električnu energiju. Čl. 2. Direktive 1999/34.

[963] Čl. 1073., čl. 1074., čl. 1075., čl. 1076., čl. 1077., čl. 1078. ZOO

[964] „*S obzirom na tehnološki razvoj i postavke kaznenopravne dogmatike bespredmetno je govoriti o kaznenoj odgovornosti robota dokle god se ne razvije generacija naprava koja će, uz samostalnost u odlučivanju, imati i određenu "ljudsku" crtu*“. Mrčela, M., Vuletić, I. (2018). Kazneno pravo pred izazovima robotike: tko je odgovoran za prometnu nesreću koju je prouzročilo neovisno vozilo?, Zbornik Pravnog fakulteta Sveučilišta u Zagrebu, Vol. 68, No. 3-4, str. 487.

5.5. PREDNOSTI I NEDOSTACI SUSTAVA UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU

Tehnologija brzo napreduje i svi doživljavamo brze promjene u inovacijama te se jednako brzo moramo istima prilagoditi. Postalo je gotovo nemoguće raditi bilo koji posao bez korištenja tehnologije. Takve promjene uvelike nadiru i u pomorsku industriju, a analizirajući ih možemo steći uvid o prednostima i nedostacima određenih promjena nastalih integriranjem neke razine AI u poslovanje. Uz rastuću konkurenciju u pomorskom prometu odnosno prijevozu različite organizacije moraju usvojiti nove tehnologije i poboljšati svoje usluge kako bi stekle konkurentsku prednost. Način za postizanje konkurentske prednosti na tržištu prijevoza je pružanje usluga koje su isplative, učinkovite i prilagodljive. U kontekstu održivog razvoja AI može pomoći u podršci čistim i zelenim plovilima što uključuje smanjenje emisije ugljika, manje troškove brodarskim poduzećima uključujući i manje iskorištavanje goriva. Također, u cilju stjecanja prednosti na tržištu, brodarska poduzeća moraju osigurati učinkovit rad uz pomoć tehnologije ponajviše iz razloga jer, uz niže troškove, kupci traže sigurnu i učinkovitu isporuku. Prednosti koje bi mogle proizaći iz primjene AI u međunarodnom pomorskom prometu odnose se na implementaciju automatiziranih procesa, autonomije plovila, veće zaštite i reduciranje pogrešaka. Možemo uzeti kao primjer ukupne prihode od pomorskog prijevoza koji su u 2017. iznosili 166 milijardi američkih dolara, a procjenjuje se kako će isti doseći 205 milijardi američkih dolara do 2023,[965] a AI se smatra ključnim elementom u dosezanju takvih brojki.[966]

Kako bi se AI pravilno iskoristila i primijenila u pomorskom prometu, razni projekti se već testiraju u svijetu.[967] Tako imamo primjer gdje je poduzeće *Wärtsiläinu* napravila akviziciju Transasa kao podršku svojoj viziji *"Smart Marine Ecosystem"*. Također, aktivno se radi na projektu poduzeća *Maersk Line* gdje se testira situacijska svijest (engl. *situational awareness*) u povezivosti s AI na brodu. Francuski brodski gigant CMA CGM udružio se sa San Franciscom Shoneom kako bi istražio AI na svojim brodovima. Uz to, poduzeća *Stene Line* i *Hitachi*

---

[965] Više o tome vidjeti na: https://emag.nauticexpo.com/why-ai-will-transform-the-maritime-industry/

[966] United Nations Conference on Trade and Development, (2020). Review of Maritime Transport 2020. dostupno na: https://unctad.org/system/files/official-document/rmt2020_en.pdf, str. 75.

[967] Jedna od vodećih inicijativa je *Advanced Autonomous Waterborne Applications Initiative (AAWA) project* kojeg vodi *Rolls Royce Holdings*, kompanija najpoznatija po proizvodnji avionskih motora. Uz njega, tu su i finski državni trajektni operator *Finferries* te kompanija koja je vodeća u teretnom brodskom prijevozu na Baltiku, *ESL Shipping Oy*. Vojković, G., Milenković, M. (2018). Novi pravni okvir i klasifikacija autonomnih, daljinski upravljanih i srodnih brodova, Druga međunarodna konferencija pomorskog prava "Suvremeni izazovi pomorske plovidbe", Split, str. 393.

testiraju AI za smanjenje potrošnje goriva, a *Orient Overseas Container Line* se udružio s *Microsoftovim* istraživačkim ogrankom u Aziji kako bi koristili AI za poboljšanje operacija brodske mreže. Uz to, prednosti autonomnih plovila su višestruke. Osim redukcije ljudskih pogrešaka, smanjuju se troškovi posade, a povećava se sigurnost života te omogućuje učinkovita upotreba prostora u samoj gradnji brodova. Posljedično, kao što je već i navedeno, stvara se temelj za učinkovitiju uporabu goriva. Trogodišnji istraživački projekt MUNIN predvidio je uštedu od preko 7 milijuna američkih dolara tijekom 25-godišnjeg razdoblja po autonomnom brodu u potrošnji goriva i zalihama te plaćama posade.[968]

Unatoč operativnim uštedama, početno će ulaganje u tehnologiju biti veliko, posebno u ranim fazama njezina razvoja. To se ne odnosi isključivo na sam brod, već i na uspostavljanje kopnenih operacija za praćenje kretanja flote. Također mogu postojati nekompatibilnosti između trenutne morske infrastrukture i autonomnog plovila. Nadalje, nedostatak posade učinit će održavanje pokretnih dijelova teškim na dugim putovanjima, a kvarovi bi mogli rezultirati značajnim kašnjenjima. Uz to, možemo reći da ipak sustav AI ne bi trebao biti apsolutno neovisan, odnosno učinkovit rad sustava bi se trebao kontrolirati od strane čovjeka kako bi se u ključnom trenutku moglo intervenirati i donijeti moguće odluke kada sustav ne zna kako postupiti. Isto tako, ako uzmemo u obzir da se AI ne temelji samo na analiziranju podataka već i na učenju iz iskustva, posljedično nakon određenog vremenskog razdoblja može doći do nepredvidivog djelovanja same AI. To nam daje na zaključak da sustave AI treba kontrolirati kako bi se pravovremeno uočile i ispravile moguće pogreške. Uz sve navedeno, uvijek ostaje otvoreno pitanje sigurnosti i kibernetske sigurnosti. Mnoga poduzeća koriste AI za obradu BD i osjetljivih informacija gdje jedan sigurnosni propust može rezultirati ozbiljnim posljedicama za brodarsko poduzeće. To se odnosi i na kibernetičke napade posebice u današnje vrijeme gdje će napredak tehnologije dovoditi do napretka kibernetskog kriminala. Poduzeća koje će implementirati AI izložit će se riziku od takvih napada te je nužno sustav redovito ažurirati i zaštiti. Stoga možemo reći da je zadatak klasifikacijskih društava da osiguraju sigurnu, učinkovitu implementaciju AI u pomorsku industriju posebice jer primjena iste rezultira većim prednostima nego rizicima ponajviše u pogledu smanjenja nesreća i nezgoda povezanih s brodarstvom, održavanja strojeva, komponenata i konstrukcija, ali i potrošnji goriva i učinkovitosti.

[968] Final Report Summary - MUNIN (engl. *Maritime Unmanned Navigation through Intelligence in Networks*), dostupno na: https://cordis.europa.eu/project/id/314286/reporting

5.6. SIGURNOSNI I TEHNIČKI NADZOR BRODSKIH ELEKTRONIČKIH NAVIGACIJSKIH UREĐAJA

Tehničko-tehnološki sustavi imaju svojih prednosti i manjkavosti. U iskorištavanju takvih sustava kao i njihovom nadzoru postavljaju se određeni uvjeti kako bi se stekao uvid u tehničke značajke, korištenje sustava, nadzor i efikasnost. Prema opće poznatim formulama za pouzdanost, popravljivost i raspoloživost mogu se definirati četiri ključna segmenta sigurnosti (SS):[969]

- Pouzdanost (*Reliability* - R)
- Popravljivost (*Serviceability* - S)
- Raspoloživost (*Availability* - A) i
- Redundancija (*Redundancy* - Re)

Pouzdanost je jednaka srednjem vremenu između dva uzastopna kvara (engl. *Mean Time Between Failure* - MTBF).

$$MTBF = \frac{OS}{K} \quad (5.1)$$

gdje su:

OS – operativni sati

K – broj kvarova

Pouzdanost treba biti što veća. Vjerojatnost da će neki sustav raditi bez kvara u nekom vremenskom razdoblju T je:

$$r(T) = e^{-T/MTBF} \quad (5.2.)$$

Popravljivost je srednje vrijeme otklanjanja kvara (engl. *Mean Time Repair Failure* - MTRF). Skraćivanje tog vremena postiže se brzom intervencijom što može predstavljati zamjenu neispravnog dijela ili cijeloga sklopa.

$$MTRF = \frac{\sum tP}{nP} \quad (5.3.)$$

gdje je:

tP = vrijeme popravka

[969] Opće poznate formule za pouzdanost, popravljivost i raspoloživost dostupne na: http://www.dba-oracle.com/real_application_clusters_rac_grid/availability.html

nP = broj popravaka

Raspoloživost sustava je postotak vremena u kojemu je sustav ispravan za korištenje. Uz poznate (R) i (S) raspoloživost je:

$$A = \frac{R}{R+S} * 100 = \frac{MTBF}{MTBF+MTRF} * 100 \quad (5.4.)$$

Redundancija je udvostručavanje kritičnih podsustava nekog sustava radi povećanja njegove pouzdanosti u ponavljanom uključivanju ili zaštiti od pogrešaka u radu. Svaka udvostručena sastavnica sustava smanjuje vjerojatnost nastanka kvara u radu sustava prema obrascu:

$$P = \prod_{i=1}^{n} Pi \quad (5.5.)$$

gdje su:

P - vjerojatnost kvara čitavog sustava

n - ukupan broj sastavnica sustava

P_i - vjerojatnost kvara sastavnice

U sigurnosnim i kritičnim sustavima koji se nalaze primjerice na brodovima, zrakoplovima, te posebno na primijenjenim elektroničkim navigacijskim uređajima, navigacijskim integriranim sustavima, neki se podsustavi moraju triplicirati. Tada pogrešku jednog podsustava anulira ispravan rad ostala dva. Dakle, redundancija je višestrukost, a ne zalihnost.

Navedeni sustavi BENU koriste određene računalno potpomognute entitete kojima se omogućuje donekle pravilan rad. U kontekstu takvih sustava polazni entitet je mikroprocesor. Mikroprocesori su značajno napredovali od početnog izgleda i funkcionalnosti, a nadasve mogućnosti. *Apollo Guidance Computer* izbacio je 2,048 MHz procesor koji je prvog čovjeka odveo na Mjesec, davne 1969. godine.[970] Dva su osnovna elementa koja se sastoje od modernog procesora, a to su aritmetička logička jedinica (ALU) i upravljačka jedinica (CPU). ALU izvodi

[970] O tome na: https://computer.howstuffworks.com/microprocessor.htm

osnovne matematičke i logičke operacije, dok CPU preuzima upute iz memorije i izvršava ih. Postoje dodatni odjeljci kao što su registri i predmemorija u arhitekturi procesora. Registri pohranjuju rezultate operacija koje vrši aritmetička logička jedinica. Predmemorija je mala količina memorije rezervirana za procesor radi spremanja čestih operacija, čime se umanjuje vrijeme koje procesoru treba za dohvaćanje podataka iz nasumične memorije (engl. *Random Access Memory* - RAM). Veličina tranzistora tek će se smanjiti, a broj tih sitnih entiteta koji se postavljaju u čipove će porasti, što će rezultirati mnogo bržim i boljim računalnim strojevima.

Uzevši u obzir da svaki navedeni BENU koristi određeni model mikroprocesora za primanje, obradu i slanje uređajno posebnih podataka, razvidno je da će AI u svoj sustav implementirati postojeće čipovlje podsustava koje će, *inter alia*, činiti BENU. Samim time, postavlja se pitanje tehničke i tehnološke ažuriranosti sklopovlja BENU-a što može utjecati na valjanost podataka. Također, razni informacijski sustavi implementirani u brodske sustave, a koji su dobili određena tipska odobrenja nacionalnih registara brodova će se također trebati revidirati u kontekstu implementacije u nove sustave koje će omogućiti AI. Primjerice, Hrvatski registar brodova (HRB) izdaje potvrde o tipskom odobrenju za proizvode poput informacijskog sustava za upravljanje imovinom i poslovima održavanja. Takve potvrde su u skladu s Pravilima za statutarnu certifikaciju pomorskih brodova, sprječavanje onečišćenja[971] i odnose se na bazu podataka imovine i opreme, planiranje preventivnog i korektivnog održavanja, upravljanje radnim nalozima, upravljanje skladištem i materijalima, upravljanje nabavom, izvještavanje i ključne pokazatelje poslovanja.[972] Slično je i s računalnim programskim sustavima za upravljanje brodovima i izvještavanje.[973] Svi takvi sustavi imaju svoje područje primjene i ograničenja koje će kroz SS provjeravati i pripremiti za implementaciju u sustave AI.

[971] Pravila za statutarnu certifikaciju pomorskih brodova, sprječavanje onečišćenja (NN, br. 8/2020)
[972] Vidi više na: http://www.crs.hr/TIPO/02-002736.pdf
[973] Vidi više na: http://www.crs.hr/TIPO/02-003090.pdf

5.7. MODEL ODREĐIVANJA SIGURNOSTI SUSTAVA UMJETNE INTELIGENCIJE

Određivanje sigurnosti sustava AI iziskuje određivanje početne kategorizacije brodova na koje bi se sustavi AI mogli primjenjivati. Takva kategorizacija određena je kroz odredbe SOLAS-a i dijeli se na SOLAS i NON-SOLAS brodove. U tom smislu, SOLAS brod je svaki brod na koji se primjenjuje SOLAS iz 1974., a odnosi se na:

- putnički brod na međunarodnom putovanju, ili
- ne-putnički brod bruto tonaže 500 tona ili više koji je angažiran na međunarodnom putovanju.[974]

Brodovi moraju ispunjavati sigurnosne standarde, ali posebne kategorije brodova ispunjavaju i dodatne sigurnosne standarde. Isto tako određena komercijalna plovila moraju udovoljavati sigurnosnim standardima SOLAS-a. Ova plovila moraju imati uspostavljen sustav sigurnosti prema Međunarodnom kodeksu za upravljanje sigurnošću (ISM kodeks).[975]

NON-SOLAS brodovi u osnovi su sva komercijalna plovila koja se ne uklapaju u definiciju broda SOLAS, iako postoje neke iznimke poput brodova s ograničenjima, ribarskim brodovima i brodovima manjim od 45 metara koji prelaze ograničene granice, ali nisu SOLAS brodovi.[976] Također, nužno je napomenuti i odobalne strukture na koje se mogu primijeniti sustavi AI u kontekstu DP-a, smanjivanja troškova i produljenja životnog vijeka struktura.[977] Odobalna ili „*offshore*“ struktura je građevina i/ili objekt u morskom okruženju, korištena obično za proizvodnju i prijenos električne energije, nafte, plina i drugih resursa. Nakon temeljne kategorizacije brodova i odobalnih konstrukcija koji bi mogli primjenjivati sustave AI, pretpostavlja se da će se i proizvođači sustava AI u prihvatljivoj mjeri, pored ostalih istraživanja, voditi i istraživanjem i postignutim znanstveno-istraživačkim rezultatima u ovom radu. Slijedom navedenog, vodeći se teorijom transfiniranih skupova[978] mogu se definirati četiri ključna podskupa skupa AI što je prikazano u tablici 5-1:

[974] Više o tome na: https://www.maritimenz.govt.nz/rules/part-21/Part21-maritime-rule.pdf
[975] International Safety Management Code, od 1994. dio SOLAS-a.
[976] Više vidjeti na: https://www.maritimenz.govt.nz/commercial/safety/safety-management-systems/default.asp
[977] Bhowmik, S. (2019). Life Extension of Offshore Structure Using Machine Learning, Offshore Technology Conference Brasil, Rio de Janeiro, Brazil, dostupno na: https://doi.org/10.4043/29759-MS
[978] Cantor, G. (1897). Beiträge zur Begründung der transfiniten Mengenlehre (2), Mathematische Annalen. 49 (2), str. 207–246.

Tablica 5-1 Podskupovi skupa AI, Izvor: Autor

Oznaka skupa ili podskupa	Opis skupa ili podskupa	Oznaka elementa	Opis elementa
A	Pravni podskup	$A_1 \dots A_{31}$	2.1. – 2.19. doktorskog rada
B	Društveni podskup	$B_1 \dots B_{61}$	3. – 4. doktorskog rada
C	Sigurnosni podskup	$C_1 \dots C_{45}$	5. – 6. doktorskog rada
AI	Skup umjetne inteligencije	A, B, C	Poglavlja 2. - 6. doktorskog rada

Pod podskupom A označava se podskup sa elementima u povezivosti s pravnom regulacijom sustava AI u međunarodnom pomorskom prometu što se može prikazati matematičkim izrazom:

A = {A1, A2, …A31}, te obuhvaća elemente sadržane u poglavljima od 2.1. do 2.19. ovog rada.

Pod podskupom B označava se podskup s elementima u povezivosti sa društvenim utjecajem sustava AI i etičkim smjernicama što se može prikazati matematičkim izrazom:

B = {B1, B2, …B61}, te obuhvaća elemente sadržane u poglavljima 3 i 4 ovog rada.

Podskup C označava podskup s elementima u povezivosti sa sigurnosti sustava AI u međunarodnom pomorskom prometu što se može prikazati matematičkim izrazom:

C = {C1, C2, …C45}, te obuhvaća elemente sadržane u poglavljima 5 i 6 ovog rada.

Iz navedenog proizlazi da su:

$A, B, C \subseteq AI$

Izloženi pristup omogućuje stvaranje tehničkih uvjeta za primjenu AI u međunarodnom pomorskom prometu posebice ako uzmemo u obzir da Međunarodno udruženje klasifikacijskih društava (engl. *International Association of Classification Societies* - IACS) i IMO djeluju u koheziji prema državama članicama. Primjerice u Hrvatskoj IACS djeluje prema HRB, a IMO

prema resornom ministarstvu,[979] pri čemu se stvaraju preduvjeti za definiranje tehničkih uvjeta primjene AI. Sukladno tome, sigurnosni i tehnički nadzor AI može se, na temelju redundancije kritičnih podsustava sustava AI, odražavati sljedećim modelom prikazanim na slici 5-4.

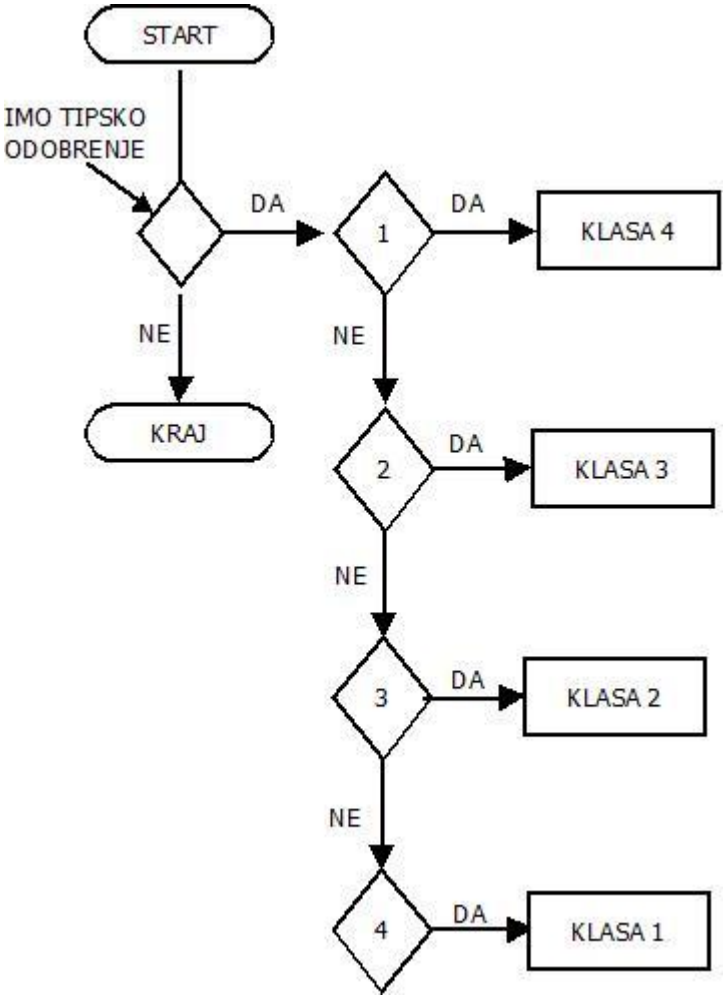

Slika 5-4 Model određivanja sigurnosti sustava AI,

Izvor: Izradio autor

Za zaključiti je kako se temeljem broja redundantnih kritičnih podsustava mogu klasificirati plovila koja koriste AI te da povećanjem takvih podsustava možemo utvrditi i veću sigurnost sustava AI. Bolje rečeno, plovila se mogu podijeliti na one koji prema IMO-vom tipskom odobrenju nemaju sustave AI i one koji ih imaju. Brodovi koji imaju jedan sustav AI pripadali bi *Klasi 4* kao oni brodovi koji mogu imati značajne poteškoće u slučaju zatajenja sustava AI. Povećanjem redundancije sustava AI na brodu povećavala bi se pripadajuća klasa broda, a posljedično umanjivao rizik od zatajenja sustava AI zbog višestrukosti sustava. Sukladno već

[979] Više o IACS vidjeti na: https://www.iacs.org.uk/media/3784/iacs-class-key-role.pdf

prije spomenutoj kategorizaciji brodova prema SOLAS-u možemo smatrati da brodovi koji imaju jedan ili nijedan sustav AI su NON-SOLAS brodovi, a brodovi s 2 ili više redundantnih sustava pripadaju kategoriji SOLAS brodova. Uz predloženu klasifikaciju može se predložiti izdavanje sigurnosnih certifikata različitih razina što može rezultirati i određenim prednostima u međunarodnom pomorskom prometu poput prava prolaska, prvenstva veza i sl. o čemu IMO i nadležne organizacije mogu dalje raspravljati. Također, može se povući paralela autonomne plovidbe s autonomnom vožnjom. Kao posljednji u nizu nesretnih slučajeva je slučaj automobila kompanije Tesla s autopilotom koji je udario u drvo i izgorio, a dvije osobe su poginule.[980] Smatra se da u daljnjim istraživanjima vrijedi analizirati transformaciju podataka u autonomnim sustavima s polazišta tehničkih znanosti gdje u svakoj idućoj fazi transformacije podataka može doći do gubitka prijašnjih vrijednih informacija za autonomne sustave.[981] Upravo iz tog razloga nužnim se smatra što veći broj redundantnih sustava u cilju postizanja što veće sigurnosti sustava AI kako u pomorskom tako i u cestovnom prometu.

5.8. POBOLJŠANJE POSTOJEĆIH SUSTAVA

Model poboljšanja postojećih sustava usko je povezan s modelom određivanja sigurnosti sustava AI. Kako bi se poboljšali postojeći sustavi nužno ih je vrednovati na jednak način. U povezivosti sa skupom AI navedenim u modelu određivanja sigurnosti sustava AI važno je definirati postojanje parametara određenih skupom AI za vrednovanje modela poboljšanja postojećih sustava. Predlaže se sljedeće vrednovanje:

- parametar ne postoji (NE),
- parametar postoji (DA)

Parametar ne postoji (NE) dodjeljuje se elementu kod kojeg, na sadašnjoj razini implementacije i istraženosti, njegove značajke nisu dostatno spoznate ili su u prijelaznom stanju s neizvjesnim smjerom razvoja odnosno njegove značajke ne zadovoljavaju očekivane uvjete.

[980] Više na: https://www.index.hr/vijesti/clanak/tesla-bez-vozaca-se-zabio-u-drvo-dvoje-mrtvih-sad-se-javio-i-elon-musk/2270411.aspx
[981] Moguće pogreške pri transformacijama podataka vidjeti na: https://consoltech.com/blog/10-common-causes-of-data-loss/

Parametar postoji (DA) dodjeljuje se elementu kod kojeg, na sadašnjoj razini implementacije i istraženosti, njegove temeljne značajke djelomično ili potpuno zadovoljavaju očekivane uvjete.

Sukladno navedenom, a u povezivosti s već predloženim skupovima / podskupovima AI proizlazi sljedeća tablica (5-2) vrednovanja elemenata.

Tablica 5-2 Tablica vrednovanja elemenata podsustava sustava AI, Izvor: Izradio autor

Element	**Ocjena**	**Prijedlog poboljšanja**
A1	NE	Poglavlje 2.1. – Značajnije poticati istraživanja u području AI za pomorstvo kroz projekte poput MASS-a te proaktivno djelovati u predlaganju pravne regulative.
A2	NE	Poglavlje 2.2. – Ažurirati ključne preporuke u pogledu zaštite pomoraca s aspekta primjene AI.
A3	NE	Poglavlje 2.3. – UNCLOS je potrebno ažurirati u skladu s trenutno i budućom primjenom AI u pomorskom gospodarstvu.
A4	NE	Poglavlje 2.4. – SOLAS zahtjeva značajne promjene s obzirom na svoju opširnost. U sve odredbe, koje to dozvoljavaju, postaviti ključne smjernice i zahtjeve koje AI mora ispunjavati kako bi se uspješno i sigurno primijenila u međunarodnom pomorskom prometu.
A5	NE	Poglavlje 2.5. – MARPOL ažurirati na način da odgovara zahtjevima primjene AI odnosno da se iskoristi AI kako bi se poštovale odredbe MARPOL-a
A6	NE	Poglavlje 2.6. – Prilagoditi sukladno novim promjenama SOLAS-a. Ako to SOLAS zahtjeva, ažurirati STCW kako bi se odredile smjernice u certificiranju AI s primjenom u međunarodnom pomorskom prometu.
A7	DA	Poglavlje 2.7. obrađuje COLREG kao jedan od najznačajnih pomorsko-pravnih akata u smislu primjene AI. Ključne odredbe COLREG-a je potrebno ugraditi u AI, a sami COLREG ažurirati sukladno primjeni novih tehnologija.

A8	DA	Poglavlje 2.8. Odredbe ISPS kodeksa su u značajnoj mjeri temeljene na upotrebi tehnike i tehnologije. Iskoristiti AI za poboljšanje postojećih sustava, a kodeks ažurirati sukladno potrebama sustava AI.
A9	DA	Poglavlje 2.9. – Iskoristiti postojeće odredbe GDPR-a kako bi se postavili temelji upotrebe osjetljivih informacija za sustave AI.
A10	DA	Poglavlje 2.10. – dokument AI za Europu opširno opisuje različite sastavnice i elemente AI i primjene iste. Razviti sektorski – specifična pravila i odredbe kako bi sadržaj dokumenta (AI za Europe) bio primjenjiv u različitim gospodarskim granama.
A11	DA	Poglavlje 2.11.
A12	DA	Poglavlje 2.12. – Djelomično zadovoljavajuća razina. Opći pristup sektorirati.
A13	DA	Poglavlje 2.13.
A14	DA	Poglavlje 2.14.
A15	DA	Poglavlje 2.15.
A16	DA	Poglavlje 2.16. – Dodatno ojačati globalno djelovanje u istraživanju sustava AI kao što su istraživani projekti poput MASS ili digitalnih luka.
A17	DA	Poglavlje 2.17. – Potrebno je proaktivno djelovanje relevantnih europskih i nacionalnih tijela kako bi se dodatno zaštitilo države i građanstvo. Kibersigurnost predstavlja dinamično područje razvijanja i potreban je i dinamičan odgovor na moguće ugroze.
A18	DA	Poglavlje 2.18.1. - Djelomično zadovoljavajuće u pogledu tri elementa: Autonomni vozni sustavi, etičke norme i LAWS. U kontekstu pomorskog prometa nema iznesenog izvještaja.
A19	DA	Poglavlje 2.18.2. - Djelomično zadovoljavajuće u pogledu tri elementa: Autonomni vozni sustavi, etičke norme i LAWS. U kontekstu pomorskog prometa nema iznesenog izvještaja.
A20	DA	Poglavlje 2.18.3. - Djelomično zadovoljavajuće u pogledu tri elementa: Autonomni vozni sustavi, etičke norme i LAWS. U kontekstu pomorskog prometa nema iznesenog izvještaja.

A21	DA	Poglavlje 2.18.4. - Djelomično zadovoljavajuće u pogledu tri elementa: Autonomni vozni sustavi, etičke norme i LAWS. U kontekstu pomorskog prometa nema iznesenog izvještaja.
A22	DA	Poglavlje 2.18.5. - Djelomično zadovoljavajuće u pogledu tri elementa: Autonomni vozni sustavi, etičke norme i LAWS. U kontekstu pomorskog prometa nema iznesenog izvještaja.
A23	DA	Poglavlje 2.18.6. - Djelomično zadovoljavajuće u pogledu tri elementa: Autonomni vozni sustavi, etičke norme i LAWS. U kontekstu pomorskog prometa nema iznesenog izvještaja.
A24	DA	Poglavlje 2.18.7. - Djelomično zadovoljavajuće u pogledu tri elementa: Autonomni vozni sustavi, etičke norme i LAWS. U kontekstu pomorskog prometa nema iznesenog izvještaja.
A25	DA	Poglavlje 2.18.8.
A26	DA	Poglavlje 2.18.9.
A27	DA	Poglavlje 2.19.1. – Smatra se važnim uvesti sektorsku razradu strategije za AI.
A28	DA	Poglavlje 2.19.2. – Smatra se važnim uvesti sektorsku razradu strategije za AI.
A29	DA	Poglavlje 2.19.3. – Smatra se važnim uvesti sektorsku razradu strategije za AI.
A30	DA	Poglavlje 2.19.4. - – Smatra se važnim uvesti sektorsku razradu strategije za AI.
A31	DA	Poglavlje 2.19.5. – Smatra se važnim uvesti sektorsku razradu strategije za AI.
B1	DA	Poglavlje 3.2.
B2	DA	Poglavlje 3.2.1.
B3	DA	Poglavlje 3.2.2.
B4	DA	Poglavlje 3.2.3.
B5	DA	Poglavlje 3.3.
B6	DA	Poglavlje 3.4.
B7	DA	Poglavlje 3.4.1.

B8	DA	Poglavlje 3.4.2.
B9	DA	Poglavlje 3.4.3.
B10	DA	Poglavlje 3.5.1.
B11	DA	Poglavlje 3.5.2.
B12	DA	Poglavlje 3.5.3.
B13	DA	Poglavlje 3.6. – Filozofski aspekti AI koje će vremenom biti nadograđivani posebice nadogradnjom tehnologije.
B14	DA	Poglavlje 3.6.1. – Iako ideja potječe više od pet desetljeća još uvijek se može koristiti taj filozofski pristup. Napredak tehnologije u skorije vrijeme će ga vjerojatno učiniti nevažnim.
B15	DA	Poglavlje 3.6.2. – Filozofska ideja i test nastao nastavno na Turingov test. Napredak tehnologije u skorije vrijeme će ga vjerojatno učiniti nevažnim.
B16	DA	Poglavlje 3.6.3. – Do dolaska super inteligencije će se postavljati pitanje o svijesti stroja. Trenutna filozofska raspravljanja su na dobrom tragu.
B17	DA	Poglavlje 3.6.4.
B18	DA	Poglavlje 3.7.1.
B19	DA	Poglavlje 3.7.2.
B20	DA	Poglavlje 3.7.3.
B21	DA	Poglavlje 3.7.4.
B22	DA	Poglavlje 3.7.5.
B23	DA	Poglavlje 3.7.6. – Tehničku otpornost i sigurnost je nužno ažurirati redovito kako bi se ostalo u korak s mogućim ugrozama.
B24	DA	Poglavlje 3.7.7.
B25	DA	Poglavlje 3.7.8.
B26	DA	Poglavlje 3.7.9.
B27	DA	Poglavlje 3.7.10.
B28	DA	Poglavlje 3.7.11. – Još uvijek nije jasno tko je točno odgovoran u smislu pogreške koju može napraviti AI. Nema međunarodnog konsenzusa.

B29	DA	Poglavlje 3.8.
B30	DA	Poglavlje 3.8.1.
B31	DA	Poglavlje 3.8.2.
B32	DA	Poglavlje 3.8.3.
B33	DA	Poglavlje 3.8.4.
B34	DA	Poglavlje 3.8.5.
B35	DA	Poglavlje 3.8.6.
B36	DA	Poglavlje 3.8.7.
B37	DA	Poglavlje 3.8.8.
B38	DA	Poglavlje 3.9. – Trenutna upotreba nudi perspektivu, ali otvara i brojna pitanja.
B39	DA	Poglavlje 3.9.1. – Proces učenja stroja i čovjeka se razlikuje. Istraživanja o poboljšanju idu u dobrom smjeru.
B40	DA	Poglavlje 3.9.2.
B41	DA	Poglavlje 3.9.3.
B42	DA	Poglavlje 3.9.4. – Sustavi AI se svakako mogu koristiti u modernizaciji sudstva, ali uz ljudsku kontrolu.
B43	DA	Poglavlje 3.9.5.
B44	DA	Poglavlje 3.10.1.
B45	DA	Poglavlje 3.10.2.
B46	DA	Poglavlje 3.10.3. – Pitanje odgovornosti AI će biti otvoreno sve dok se ne zauzme zajednički/globalni stav.
B47	DA	Poglavlje 3.10.4.
B48	DA	Poglavlje 3.10.5. – Prethodi odgovornosti. Postoji međuovisnost ta dva elementa.
B49	DA	Poglavlje 3.10.6. – Reducirajući poslove pomoraca na brodu i iskorištavanja AI u ponavljajućim procesima može uvelike poboljšati kako fizičko tako i mentalno stanje pomoraca.
B50	DA	Poglavlje 4. – Još uvijek se ne mogu predvidjeti svi ishodi primjene AI i utjecaj koji će ostaviti na društvo.

B51	DA	Poglavlje 4.1. – Omjer stvorenih i izgubljenih poslova zbog AI je jedan od utjecaja AI na društvo. Osposobljavanje trenutne radne snage je ključno.
B52	DA	Poglavlje 4.2. – Samo neki od mogućih načina upotrebe AI u međunarodnom pomorskom prometu odnosno modernizaciji pomorskog sektora.
B53	DA	Poglavlje 4.3. – Samo neki od mogućih prednosti i nedostataka.
B54	DA	Poglavlje 4.4. – Istraživanja će pokazati dodatne potencijalne mogućnosti i ograničenja.
B55	DA	Poglavlje 4.5.
B56	DA	Poglavlje 4.6.
B57	DA	Poglavlje 4.7. – Većom upotrebom AI u društvu otkrivati će se i sve veće dileme.
B58	DA	Poglavlje 4.8. – Vrijedi kao i za prethodno poglavlje uz naglasak na veće poslovne subjekte.
B59	DA	Poglavlje 4.9.
B60	NE	Poglavlje 4.10. – Još uvijek neistraženo područje na koje će se trebati obratiti pažnja prilikom zakonodavne regulacije upotrebe AI.
B61	NE	Poglavlje 4.11. - Još uvijek neistraženo područje na koje će se trebati obratiti pažnja prilikom zakonodavne regulacije upotrebe AI i gospodarske dobrobiti države.
C1	DA	Poglavlje 5.1.1.
C2	DA	Poglavlje 5.1.2.
C3	DA	Poglavlje 5.1.3.
C4	DA	Poglavlje 5.1.4.
C5	DA	Poglavlje 5.1.5.
C6	DA	Poglavlje 5.1.6.
C7	DA	Poglavlje 5.1.7.
C8	DA	Poglavlje 5.1.8.
C9	DA	Poglavlje 5.1.9.
C10	DA	Poglavlje 5.1.10.

C11	DA	Poglavlje 5.1.11.
C12	DA	Poglavlje 5.1.12.
C13	DA	Poglavlje 5.1.13.
C14	DA	Poglavlje 5.2.1.
C15	DA	Poglavlje 5.2.2. – Ažurirati modele sigurnosti i zaštite u redovnom vremenskom intervalu.
C16	DA	Poglavlje 5.2.3. – Primjenom AI će značajnije doći do izražaja.
C17	DA	Poglavlje 5.2.4. – Reduciranje pogrešaka i osposobljavanje za korištenje AI.
C18	DA	Poglavlje 5.2.5.
C19	DA	Poglavlje 5.2.6.
C20	NE	Poglavlje 5.2.7. – Područje još nije istraženo.
C21	DA	Poglavlje 5.3.1. – Vidni rezultat primjene AI. Integracija svih podsustava će zahtijevati vremena.
C22	DA	Poglavlje 5.3.2.
C23	DA	Poglavlje 5.3.3.
C24	DA	Poglavlje 5.3.4.
C25	DA	Poglavlje 5.3.5.
C26	DA	Poglavlje 5.3.6. – Buduća upotreba AI u međunarodnom pomorskom prometu treba staviti još veći naglasak na ekologiju mora.
C27	DA	Poglavlje 5.4.1. – Djelomično zadovoljavajuće s obzirom na kompleksnost područja.
C28	DA	Poglavlje 5.4.2.
C29	DA	Poglavlje 5.4.3. – Buduća istraživanja i djelovanja će učiniti ovaj sustav sigurnosnom potporom za autonomne sustave što je od iznimne važnosti.
C30	NE	Poglavlje 5.4.4. – Odgovornost upravljanja takvim sustavom treba biti usklađena na međunarodnoj razini i uvedena u pravne okvire država.

C31	DA	Poglavlje 5.5. – Daljnja istraživanja i upotreba AI u stvarnom vremenu može rezultirati dodatnim prednostima i nedostacima.
C32	DA	Poglavlje 5.6.
C33	DA	Poglavlje 5.7.
C34	DA	Poglavlje 5.8.
C35	DA	Poglavlje 6.2. – Upravljanje rizicima na brodu u području kibernetičke sigurnosti je iznimno važno. Nijedan od sljedećih elemenata u tablici ne može biti potpuno zadovoljavajući zbog dinamičnosti kibernetičkog prostora i brzine kojom se nove ugroze mogu dogoditi.
C36	DA	Poglavlje 6.3.
C37	DA	Poglavlje 6.4.
C38	DA	Poglavlje 6.5.
C39	DA	Poglavlje 6.6.
C40	DA	Poglavlje 6.7.
C41	DA	Poglavlje 6.8.
C42	DA	Poglavlje 6.9.
C43	DA	Poglavlje 6.10.
C44	NE	Poglavlje 6.11. – Trenutna istraživanja ne ukazuju kako na brodu postoji osoba zadužena za kibernetičku sigurnost.
C45	DA	Poglavlje 6.12.

Vrednovanje podskupova skupa AI može se i prikladno grafički prikazati. U tom pogledu podskupovi bi izgledali na sljedeći način:

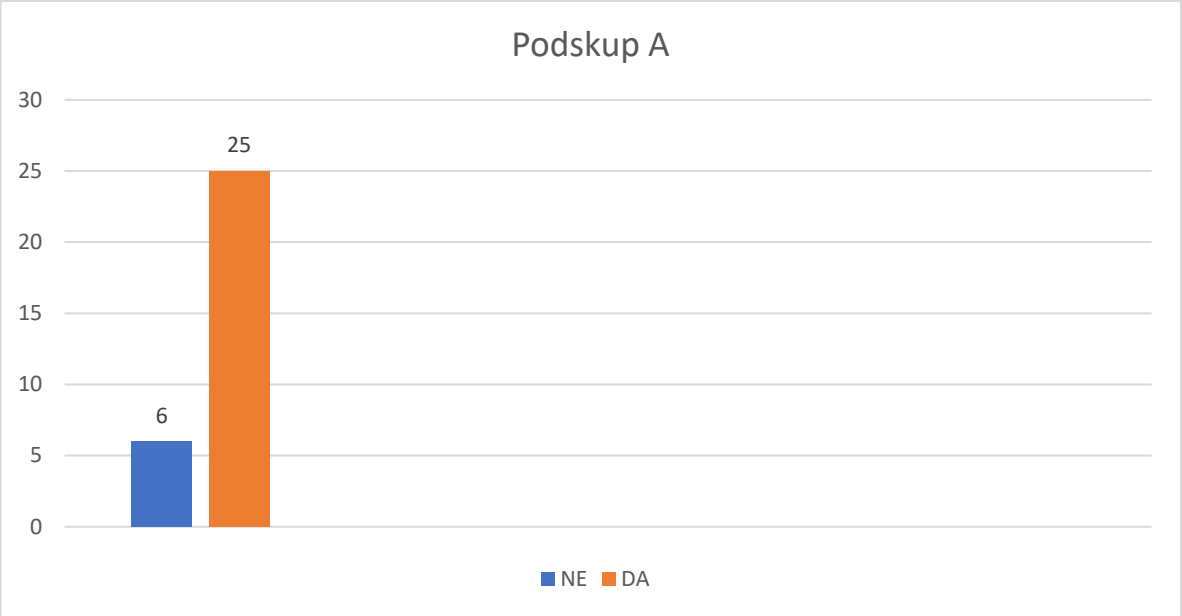

Grafikon 5-1 Podskup A, Izvor: Izradio autor

S obzirom da se podskup A odnosi na pravne elemente sustava AI, razvidno je da su nužna poboljšanja u tom segmentu implementacije i razvoje AI u međunarodnom pomorskom prometu.

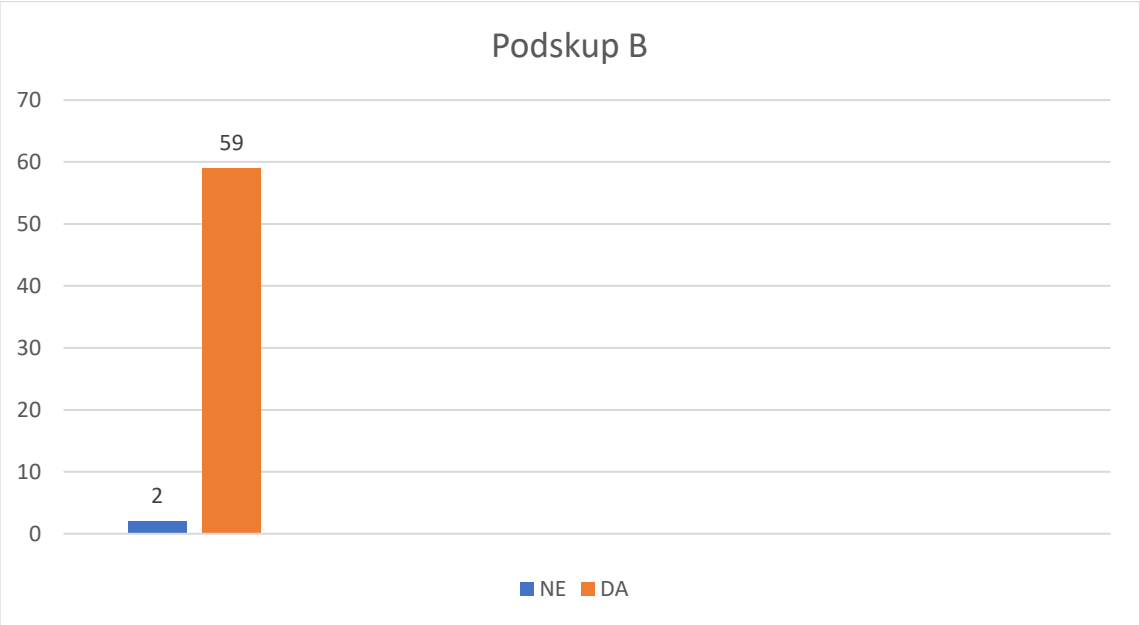

Grafikon 5-2 Podskup B, Izvor: Izradio autor

Podskup C skupa AI označava društveni aspekt primjene AI gdje je razvidno postojanje neizvjesnih elemenata, ali naglasak je ponajviše na postojanju djelomično i potpuno zadovoljavajućih parametara koji će zahtijevati dodatna istraživanja i ažuriranja u skladu s kasnijom implementacijom sustava AI.

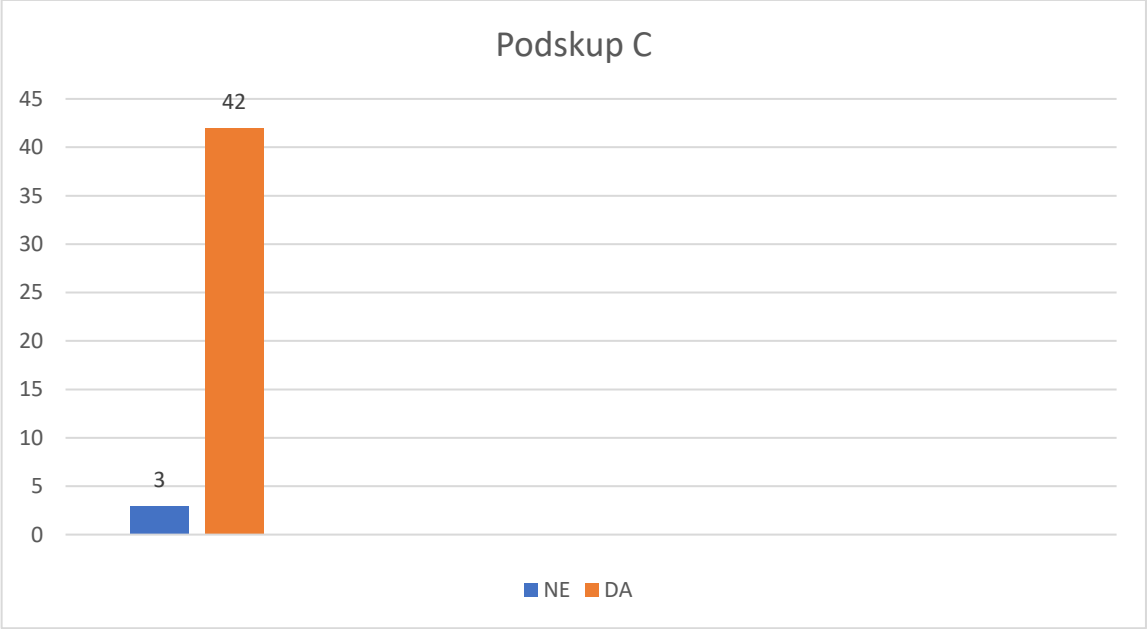

Grafikon 5-3 Podskup C, Izvor: Izradio autor

U vrednovanju podskupa D skupa AI, koji se odnosi na sigurnosne aspekte AI posebice u međunarodnom pomorskom prometu, vidljivo je nepostojanje određenih parametara koje je potrebno uvesti u procedure prije implementacije sustava AI. Također značajan je broj parametara koji postoje i primjenjivi su za sustave AI i mogu pozitivno utjecati u procesu implementacije, ali je za nekolicinu vidljiva potreba za ažuriranjem i usklađivanjem.

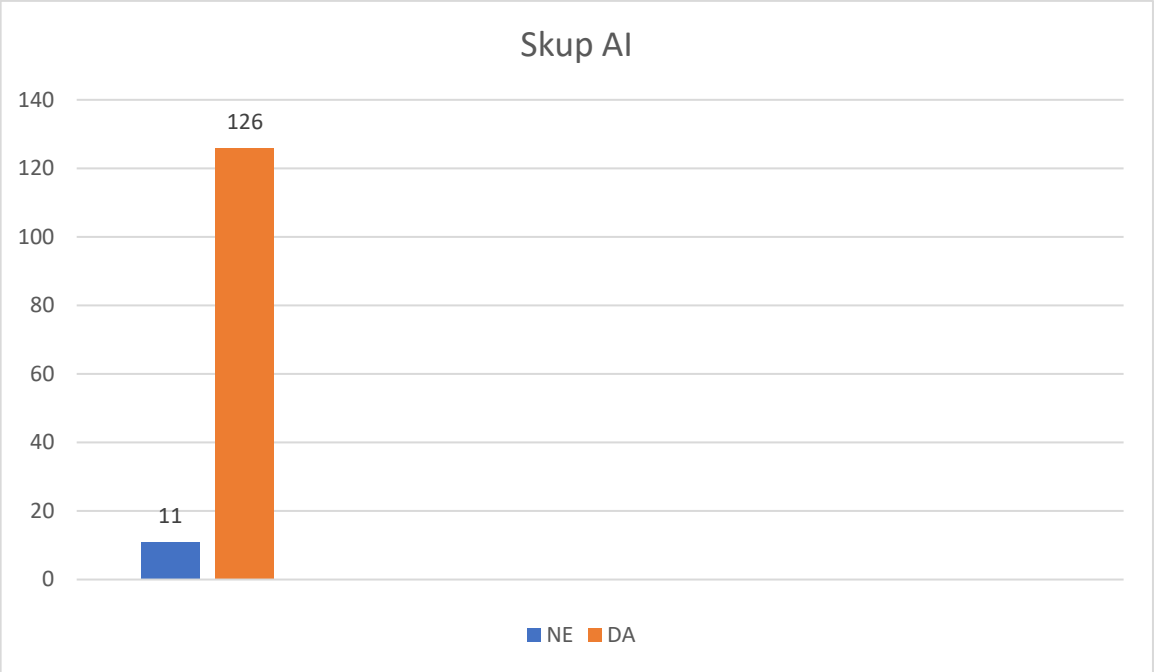

Grafikon 5-4. Skup AI,

Izvor: Izradio autor

Prikazani sustav vrednovanja može uvelike utjecati na poboljšanje postojećih sustava kroz evaluaciju trenutnog stanja i željenog cilja. Sukladno tome, model poboljšanja postojećih sustava AI može se prikazati sljedećim matematičkim izrazom:

PSAI {A1…A8, A10, A12, A15, A17…A25, A28…A31, B13…B16, B23, B28, B38, B39, B42, B46, B48…B54, B57, B58, B60, B61, C15…C17, C20, C21, C26, C27, C29…C31, C35, C44}

gdje je:

PSAI = podsustav sustava AI.

Elementi navedeni PSAI-om su oni elementi koji su nužni za kvalitetnu i sigurnu implementaciju sustava AI u međunarodni pomorski promet, te na sadašnjoj razini istraživanja u dinamičnim uvjetima i s forenzičnog polazišta iziskuju dodatna poboljšanja u većoj ili manjoj mjeri.

6 SIGURNOSNI ASPEKTI UMJETNE INTELIGENCIJE U POMORSKOM PROMETU

U ovom poglavlju analizirana je sigurnost sustava AI u međunarodnom pomorskom prometu kroz aspekt kibernetičke sigurnosti i upravljanja rizikom. Takav pristup očituje se u pogledu izrade planova i procedura nužnih za sprječavanje kiberugroza odnosno identifikaciju prijetnji, tipove prijetnji i faza izvršenja, te identifikaciju ranjivosti, procjene vjerojatnosti, utjecaja i rizika što rezultira razvojem mjera zaštite i detekcijskih mjera kao i odgovora na prijetnje, te otklanjanje istih. Također, važno je naglasiti kako sva tehnička rješenja koja u sebi sadrže programske komponente i oblike programske podrške u interakciji s okolinom biva i/ili može biti izloženo kibernetičkim napadima. Sukladno tome, u podsustave sustava AI važne za kibernetičku sigurnost spadaju upravo svi oblici programskih i programski podržanih tehničkih rješenja.

6.1. PRIKAZ SUSTAVA SIGURNOSTI UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU

Do sada provedena istraživanja u ovom radu mogu se prikazati grafički (Slika 6-1). Iz grafičkog prikaza razvidno je kako sustav sigurnosti AI u međunarodnom pomorskom prometu obuhvaća tri temeljna podsustava odnosno pravni, društveni i sigurnosni podsustav.

Sukladno navedenom provela se analiza na sljedeći način. U pravnom podsustavu znanstveno se istražilo 18, za temu, relevantnih područja. U društvenom podsustavu se tako istražilo 20 relevantnih područja. Isto tako, u sigurnosnom podsustavu istražilo se također 20 područja. Sva područja su se istraživala i dalje se u radu istražuju u cilju izlučivanja elemenata podsustava.

U cjelokupnom znanstvenom istraživanju može se tvrditi kako su istraživani izvori u povezivosti s AI više ili manje značajni za temu ove doktorske disertacije. Stoga su se znanstvenom prosudbom značaja izvora, u ovom trenutku i na sadašnjoj razini razvijenosti, te implementacije sustava AI određena područja istražila, a određena se nisu istraživala što je razvidno iz grafičkog prikaza (slika 6-1). Potrebno je napomenuti kako se sigurnosni podsustav istraživao do sada kroz devet područja. Sukladno dosadašnjim spoznajama i rezultatima dalje se u radu analizira još 11 područja sigurnosnog podsustava koji su također obuhvaćeni grafičkim prikazom (slika 6-1).

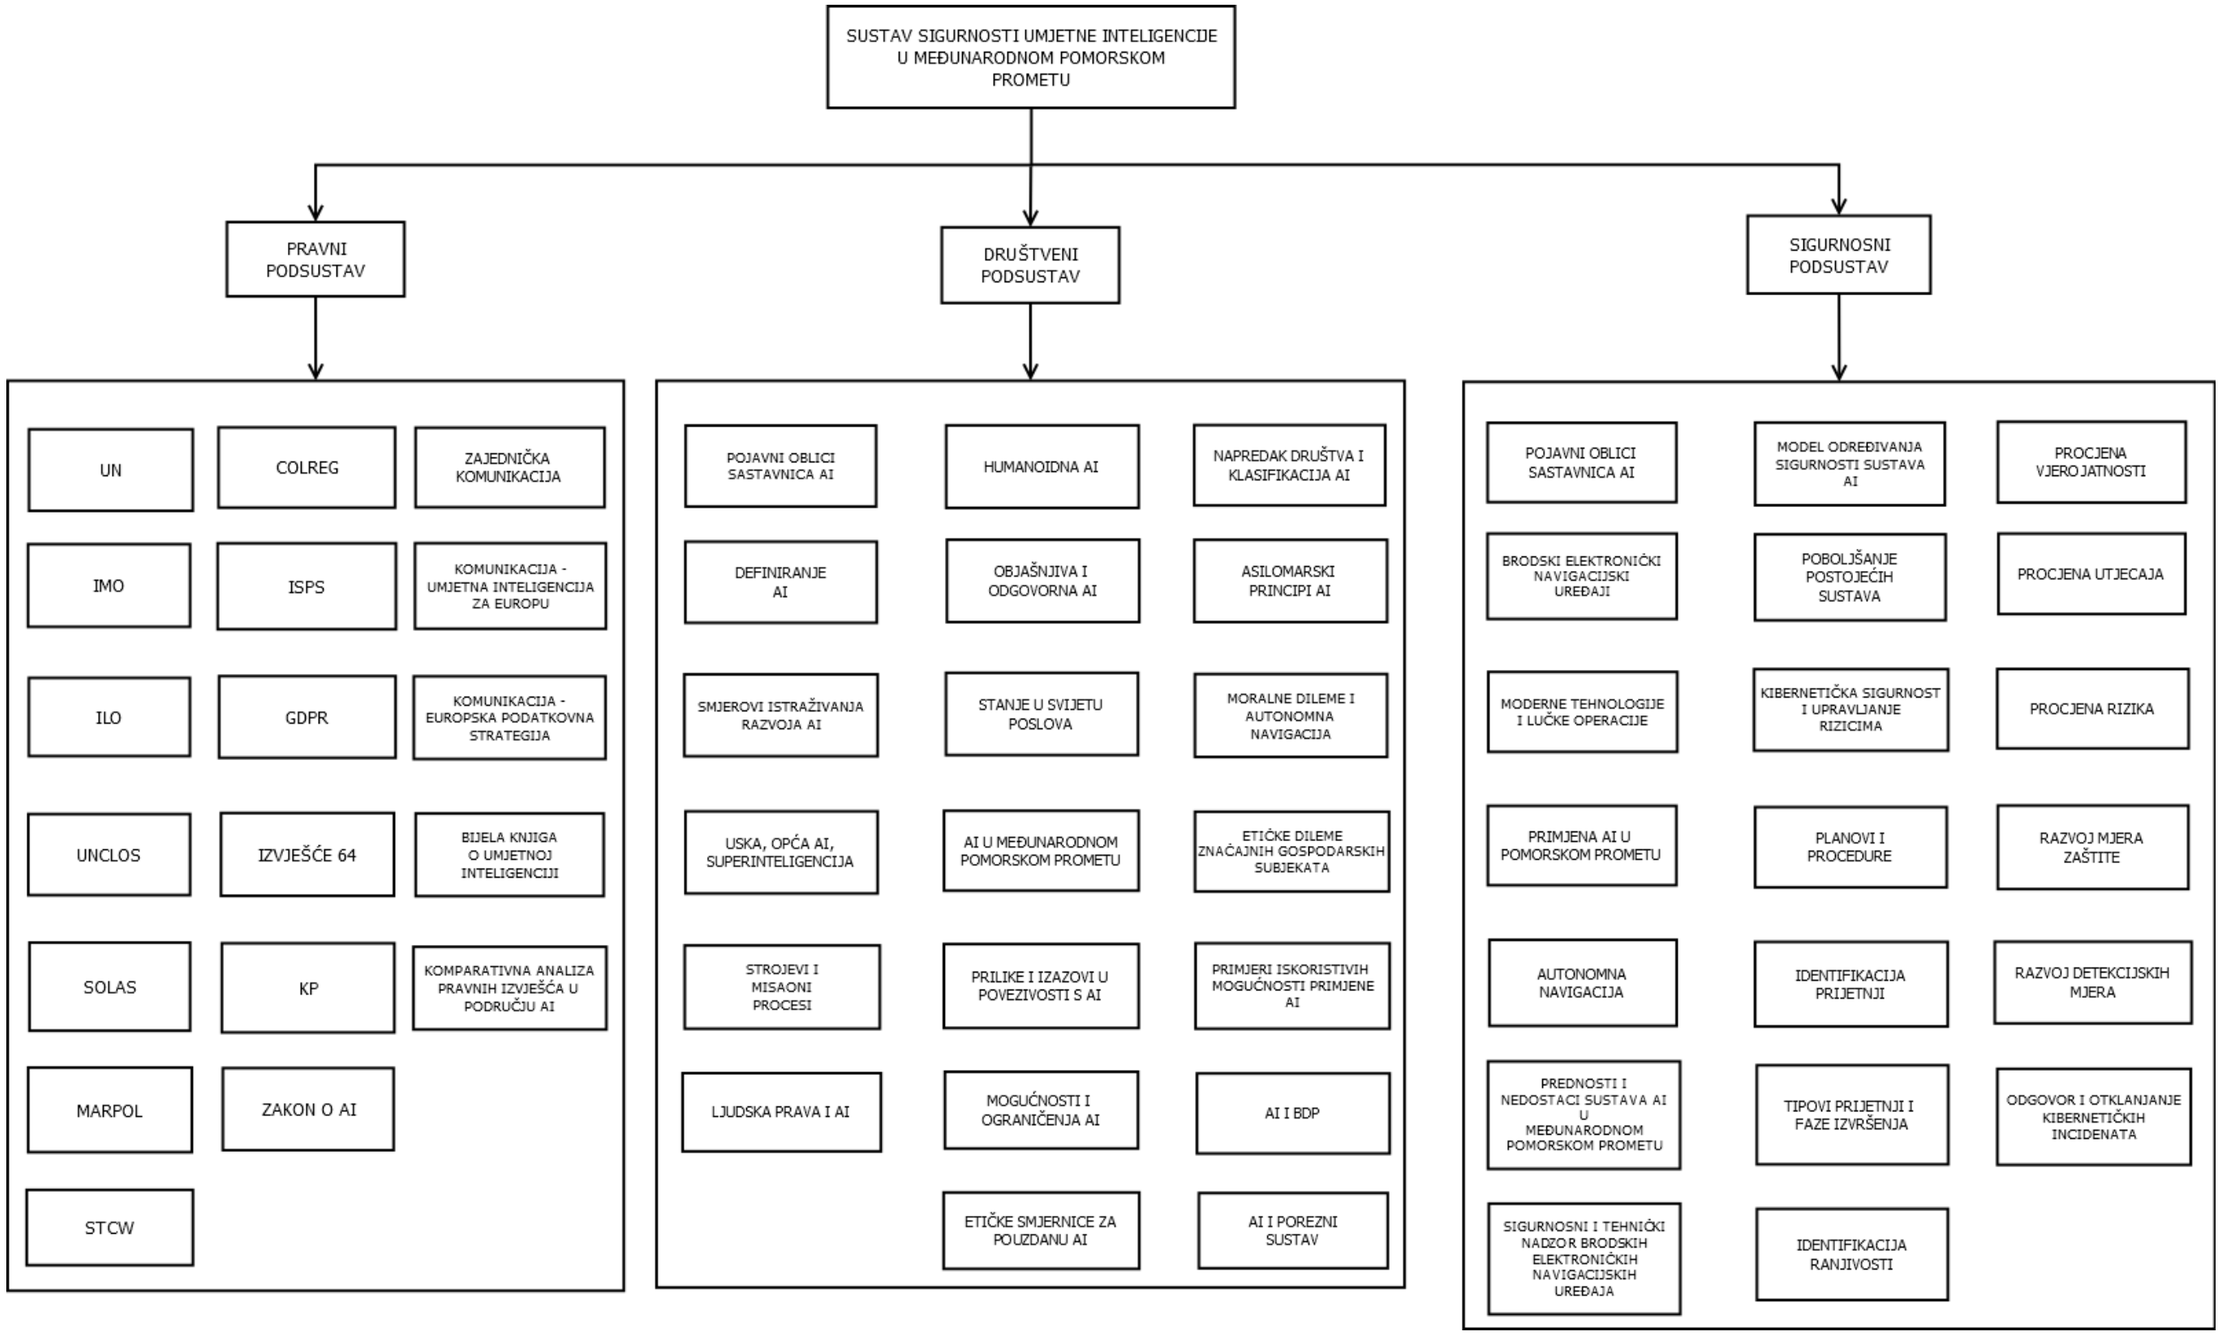

Slika 6-1 Prikaz sustava sigurnosti AI u međunarodnom pomorskom prometu,

Izvor: autor

Daljnjom analizom slike 6-1 može se zaključiti o relativnoj mnogobrojnosti različitih sigurnosnih aspekata primjene AI u međunarodnom pomorskom prometu. Također se, zbog spomenute mnogobrojnosti i posebnosti različitih istraživanih znanstvenih područja zaključuje kako se takva istraživanja i dalje mogu provoditi interdisciplinarnim, multidisciplinarnim i transdisciplinarnim forenzičnim pristupom.

6.2. KIBERNETIČKA SIGURNOSTI I UPRAVLJANJE RIZICIMA

Sukladno Vodiču za kibernetičku sigurnost na brodovima (Vodič)[982] kibernetička sigurnost važna je zbog svog potencijalnog utjecaja na osoblje, brod, okoliš i ostalo. Kibernetska sigurnost bavi se zaštitom informacijskih tehnologija (IT), operativnih tehnologija (OT), informacija i podataka od neovlaštenog pristupa, manipulacije i ometanja.[983] Prema IMO-u pomorski kibernetički rizici odnose se na mjeru u kojoj bi potencijalna tehnološka imovina mogla biti ugrožena i koja može rezultirati operativnim i sigurnosnim kvarovima što rezultira oštećenjem, gubitkom ili ugrožavanjem informacija ili sustava.[984] Sukladno Vodiču kibernetički incidenti mogu nastati kao rezultat:

- incident koji utječe na dostupnost i integritet OT-a, poput koruptivnih podataka koji su integrirani u ECDIS-u,
- nenamjerni kvar sustava koji se pojavio tijekom održavanja softvera, poput korištenja zaraženog USB ulaza za održavanje sustava,
- gubitak ili manipulacija vanjskim podacima dobivenih od senzora, a presudni za rad broda. Ovo uključuje, ali nije ograničeno na GNSS, od kojih je GPS najčešće korišten,
- pad sustava zbog greški u softveru i / ili *bug*-ova i
- interakcija posade s pokušajima krađe identiteta, što je najčešći vektor napada zbog prijetnje aktera, što bi moglo dovesti do gubitka osjetljivih podataka i uvođenja zlonamjernog softvera u brodski sustav.[985]

Pomorska industrija ima niz karakteristika koje utječu na njezinu ranjivost na kibernetske incidente. To uključuje:

---

[982] BIMCO, CLIA, ICS, INTERCARGO, INTERMANAGER, INTERTANKO, IUMI, OCIMF, WORLD SHIPPING COUNCIL, The Guidelines on Cyber Security Onboard Ship, (Ver.3), str. 1-56 dostupno na: https://www.ics-shipping.org/wp-content/uploads/2020/08/guidelines-on-cyber-security-onboard-ships-min.pdf
[983] *Ibid.*
[984] IMO Guidelines on Maritime Cyber Risk Management. (2017). MSC-FAL. 1/ Circ. 3, str. 1.
[985] *Loc.cit.*

- potencijalno uključivanje više dionika u rad i iznajmljivanje broda što je rezultiralo nedostatkom odgovornosti za IT i OT infrastrukturu sustava i brodske mreže,
- uporaba naslijeđenih IT i OT sustava koji više nisu podržani i / ili se oslanjaju na zastarjele operativne sustave,
- upotreba OT sustava koji se ne mogu popraviti ili pokrenuti anti-virus zbog problema s odobrenjem,
- brodovi koji se internetski povezuju s obalnim dionicima i ostalim dijelovima globalnog lanca opskrbe,
- brodska oprema kojoj se daljinski pristupa i nadgleda,
- razmjena poslovnih kritičnih, osjetljivih podataka i komercijalno osjetljivih informacija s pružateljima usluga na kopnu, uključujući lučke terminale i sl.,
- dostupnost i uporaba računalno upravljanih kritičnih sustava koji možda nemaju najnovije zakrpe instalirane ili moraju biti pravilno osigurane, radi sigurnosti broda i zaštite okoliša i sl.,
- kultura upravljanja kibernetskim rizikom koja još uvijek ima potencijala za poboljšanje poput više formaliziranih treninga, vježbi i razjašnjene uloge i odgovornosti i
- sustav automatizacije često se sastoji od više podsustava brojnih dobavljača koje brodogradilišta integriraju s minimalnim obzirom na kibernetske ugroze.[986]

Te elemente treba razmotriti i relevantne dijelove ugraditi u kibernetska poduzeća, sigurnosne politike i sustave sigurnosnog managementa (SMS).[987] Upravljanje kibernetičkim rizikom trebalo bi biti sastavni dio zaštite i sigurnosne kulture poduzeća, a koji pogoduju sigurnom i učinkovitom radu broda i provode se na raznim razinama poduzeća (uključujući starije rukovodstvo na kopnu i brodsko osoblje). Upravljanje kibernetskim rizikom treba:[988]

- utvrditi uloge i odgovornosti korisnika, ključnog osoblja i uprave na kopnu i na brodu,
- identificirati sustave, imovinu, podatke i mogućnosti koji bi, ako bi bili poremećeni, mogli predstavljati rizik za brodske sustave, rad i sigurnost,
- pravovremeno provoditi tehničke i proceduralne mjere za zaštitu od kibernetskih incidenta, otkrivanje incidenata i osiguravanje kontinuiteta operacija i

[986] *Loc.cit.*
[987] Više o Safety Management System (SMS) vidjeti na: https://www.marineinsight.com/marine-safety/what-is-safety-management-system-sms-on-ships/
[988] Kavallieratos, G., Katsikas, S. (2020). Managing Cyber Security Risks of the Cyber-Enabled Ship, Journal of Marine Science and Engineering, 8(10), str. 768.

- plan za nepredviđene slučajeve koji se redovito testira.

Ključno je razlikovati IT i OT sustave. Dok IT sustavi upravljaju podacima i podržavaju poslovne funkcije, OT je hardver i softver koji izravno nadzire / kontrolira fizičke uređaje i procese i kao takav je sastavni dio broda i mora funkcionirati neovisno o IT sustavima na brodu. Sustavi mogu, međutim, biti povezani s IT mrežom radi praćenja izvedbe, daljinske podrške itd. Takvi sustavi su dio IoT-a. U takvim slučajevima mora se osigurati da sučelje bude dovoljno zaštićeno te minimalno izloženo ranjivostima. Ovo je važno jer nije uvijek moguće ili izvedivo osigurati odgovarajuću razinu ažuriranosti podsustava u OT sustavima.[989]

Iako se čini neobičnim kako brodovi i ostala plovila mogu biti meta za kibernetičke napada, sve već upotreba modernih tehnologija napravila je od plovila nove izazove za hakere. Shodno tome na brodovima bi se trebala provoditi i određene prevencijske mjere kako bi se spriječile kibernetičke ugroze. Istraživanje koje je proveo BIMCO iz 2020. o sigurnosti na moru i pomorske kibernetičke sigurnosti većina ispitanika (77 %) kibernapade smatra visokim ili srednjim rizikom za njih, a naizgled djeluje kako je malo organizacija spremno na posljedice takvog napada. 64 % ispitanika tvrdi kako njihova organizacija ima plan kontinuiteta poslovanja koji bi se trebao slijediti u slučaju kibernetičkog incidenta, ali samo 24 % tvrdi da se testirao svaka tri mjeseca, dok je 15 % reklo da se testiralo svakih šest do 12 mjeseci.[990] Svega 42 % ispitanika tvrdi kako njihova organizacija štiti plovila od kiberprijetnji operativnim tehnologijama (OT), a neki su ispitanici su politiku poduzeća opisali kao neopreznu.[991]

6.3. PLANOVI I PROCEDURE

Rezolucija IMO MSC.428 (98) iz 2017. godine[992] identificirala je hitnu potrebu za podizanjem svijesti o prijetnjama od kibernetskih rizika i ranjivosti koje podržavaju zaštitu i sigurni transport koja je operativno otporna na kibernetske rizike. Stoga bi svi pomorski dionici trebali raditi na zaštiti brodara od trenutnih i budućih kibernetskih prijetnji i ranjivosti. Rezolucija nadalje potvrđuje da bi SMS trebao razmotriti upravljanje kibernetskim rizikom u skladu s ciljevima i funkcionalnim zahtjevima ISM kodeksa. Na 101. zasjedanju IMO Odbora

[989] Vodič, str. 7-8.
[990] Safety at Sea i BIMCO cyber security white paper, podržano od ABS Group. (2019), str. 5.
[991] *Ibid.*
[992] Resolution MSC.428(98) Maritime Cyber Risk Management in Safety Management Systems (adopted on 16 June 2017), dostupna na: https://wwwcdn.imo.org/localresources/en/OurWork/Security/Documents/Resolution%20MSC.428(98).pdf

za pomorsku sigurnost (izvještaj s ovog sastanka nalazi se u IMO dokumentu MSC 101/24)[993] navodi se da „…*aspekti upravljanja kibernetskim rizicima uključujući fizičku sigurnost i aspekti kibernetičke sigurnosti trebaju biti obrađeni u planovima zaštite broda (SSP) prema ISPS; međutim, to se ne bi trebalo smatrati zahtjevom od poduzeća da uspostavi zasebnu kibernetsku sigurnost za sustav upravljanja koji djeluje paralelno sa sustavom upravljanja sigurnošću poduzeća (SMS)".* Na istom sastanku IMO je također *„… potvrdio Rezoluciju MSC.428 (98) o pomorskom kibernetskom riziku te upravljanje SMS postavlja IMO zahtjeve za upravu kako bi se osiguralo da su kibernetski rizici na odgovarajući način adresirani u postojećim SMS-ovima (kako je definirano u ISM kodeksu), ovjereni odobrenim dokumentom / potvrdom o usklađenosti i upravljanju sigurnošću, i to u planu zaštite broda, odnosno treba se pozvati na postupke upravljanja kibernetskim rizicima koji se nalaze u SMS-u".* Za brodarsko poduzeće bi jednostavan način uvođenja sigurnosnih postupaka prema zahtjevu IMO trebao biti sadržan u Planu zaštite broda (SPS) i odnosio bi se na procedure povezane s fizičkim pristupom IT i OT sustavima te povezivosti u odnosu na SMS kibersigurnosne procedure. Brodarska poduzeća bi trebala razmotriti postoji li potreba za procjenom rizika specifičnog za brod na temelju kojeg su određeni brodovi ili grupe brodova jedinstveno konfigurirani u smislu postavljanja IT/OT unutar njihove flote. Čimbenici koje treba uzeti u obzir uključuju, ali nisu ograničeni na opseg u kojem se koriste IT i OT, složenosti integracije sustava i prirode operacija. Slično tome, važno je razmotriti mogu li se postupci u SMS-u urediti tako da pokrivaju kompletnu flotu poduzeća, ili su potrebni posebni postupci za određene brodove. SMS već uključuje postupke za prijavljivanje nesreća ili opasnih situacija i definira razine komunikacije i ovlasti za donošenje odluka. Takvi bi se postupci trebali voditi na način da održavaju komunikaciju i ovlasti u slučaju kibernetskih incidenta. Zapovjednik mora imati definiran protokol na koji se može pozvati u slučaju kibernetskih incidenta, a SMS bi trebao sadržavati dobro osmišljen plan odgovora na nepredviđene kibernetske slučajeve.[994]

Različite odgovornosti i zadaci trebaju se ugraditi u opise poslova i/ili ulogu na način kako je definirano u SMS-u. Kako planiranje i izvršenje upravljanja kibernetskim rizicima uključuje cijeli niz osoba i uređaja poduzeća, tijekom postupka određivanja protokola može biti korisno

---

[993] Više o 101. zasjedanju MSC-a na: http://www.crs.hr/Portals/0/docs/eng/imo_iacs_eu/imo/msc_reports/MSC%20101-24-Add.1%20-%20Report%20Of%20The%20Maritime%20Safety%20Committee%20On%20Its%20101St%20Session.pdf?ver=2019-08-20-150940-087

[994] Vodič, str. 8.

razjasniti tko je odgovorna osoba i koja je osoba zadužena za podršku odgovornoj osobi. Na primjer, IT menadžer broda može biti odgovorna osoba za upravljanje kibernetskim rizicima na brodovima, ali oslanja se na potporu ostalih menadžera i osoblja iz cijelog poduzeća, npr. osoblje za sigurnost, zaštitarsko osoblje, osoblje za obuku, osoblje za nabavu, pomorsko osoblje, posada itd. Podjela odgovornosti i zadataka najbolje će funkcionirati ako je usklađena sa standardiziranim zapovjednim lancem. Primjerice, pri raspodjeli odgovornosti za poštivanje kibernetskih rizika upravljačkim postupcima na brodu često će imati smisla imenovati zapovjednika ili časnika inženjera.[995]

Tablica 6-1 Primjer mapiranja uloga i odgovornosti, Izvor: Vodič

Zadaća / Uloga / osoba	**Politika zaštite i sigurnosti za kibernetske ugroze**	**Procjena kibernetskih rizika na OT sustavima**	**Procjena kibernetskih rizika na IT sustavima**	**Brodska IT infrastruktura**	**Osposobljavanje posade za menadžment kibernetskih rizika**
Direktor	Odgovoran				
IT menadžer poduzeća	Potpora		Potpora		
Brodski IT menadžer	Potpora	Odgovoran	Odgovoran	Odgovoran	
Menadžer sigurnosti	Potpora	Potpora	Potpora	Potpora	Potpora
Voditelj nabave	Potpora			Potpora	
Menadžer flote		Potpora	Potpora	Potpora	Potpora
Trening menadžer			Potpora		Potpora

[995] *Ibid*, str. 7.

Pomorski upravitelj			Potpora		Odgovoran

Nositelj dokumenta o sukladnosti (DoC) u konačnici je odgovoran za osiguravanje upravljanja sustavom za kibersigurnost na brodu. Ako je brod pod upravljanjem treće strane, savjetuje se da upravitelj broda postigne dogovor s brodovlasnikom o gore navedenim elementima. Obje strane trebaju naglasiti podjelu odgovornosti, usklađivanje očekivanja, dogovor o konkretnim uputama menadžeru i moguće sudjelovanje u odlukama o kupnji kao i proračunske mogućnosti.[996]

Standardi kvalitete su važni na nekoliko različitih razina. Tako su i standardi za agente krucijalni jer kao i sva druga poduzeća i agenti mogu biti na meti kiberkriminalaca, npr. u vezi s isporukom IT ili OT opreme na brod.[997] Kibernetički kriminalitet poput elektroničke prijevare te kibernetske prijetnje poput *ransomware* i hakiranja pozivaju na međusobne kibernetske strategije i poboljšane odnose između brodovlasnika i agenata za ublažavanje takvih kibernetskih rizika. Uzmimo za primjer vlasnika broda koji je izvijestio da su poslovne mreže poduzeća zaražene *ransomware* zahvaljujući *phishing* privitcima e-pošte. Izvor *ransomware* bio je od dva nesavjesna brodska agenta u odvojenim lukama i u odvojenim prilikama. Pogođeni su i brodovi, ali je šteta ograničena samo na poslovne mreže što nije utjecalo na plovidbu i brodske radnje. U jednom je slučaju vlasnik platio otkupninu i oslobodio mrežu što samo po sebi nije preporučljivo već se naglasak treba staviti na prevenciju takvih incidenata. Važnost ovog primjera incidenta je u tome što je internetska sigurnost usklađena u odnosima s pouzdanim poduzećem partnera i proizvođača i presudno je za sve u opskrbnom lancu. Stranke u lancu trebaju surađivati i dijeliti informacije prema potrebi kako bi ublažili kibernetički rizik. Također, poznat je i primjer novoizgrađenog broda koji je dizajniran za "beskartnu" plovidbu i koji nije nosio papirnate karte.[998] Isti je nosio rasuti teret te kasnio s plovidbom nekoliko dana jer je njegov ECDIS bio zaražen virusom, no zapovjednik broda i časnici ga nisu prepoznali kao kibernetsku ugrozu misleći da se radi o poteškoćama u radu ECDIS-a.[999] Tehničar proizvođača je posjetio brod i nakon što je proveo dosta vremena u rješavanju problema otkrio je da su obje ECDIS mreže zaražene virusom nakon čega je virus stavljen u karantenu, a

[996] *Loc. cit.*
[997] *Ibid*, str. 8.
[998] *Ibid*, str. 3.
[999] *Loc.cit.*

računala s ECDIS-om obnovljena.[1000] Izvor i način zaraze u ovom slučaju nisu poznati. Kašnjenje plovidbe i troškovi popravka rezultirali su stotinama tisuća dolara.[1001]

6.4. IDENTIFIKACIJA PRIJETNJI

Prilikom identificiranja prijetnji poduzeća bi trebala razmotriti sve posebne aspekte potencijalnih aktera prijetnji poput sposobnosti, prilika i namjeru napada. To može uključivati upotrebu npr. vanjske osobe kao nenamjernog posrednika koji nesvjesno donosi prijetnju npr. na zaraženoj USB memoriji. Jednom identificirane prijetnje treba uzeti u obzir uz identificirane ranjivosti kako bi se procijenila vjerojatnost napada ili incidenta koji se događa. Zajedno s utjecajem određenog incidenta vjerojatnost za incident koji se dogodi stvara faktor rizika. Organizacije i pojedinci mogu predstavljati namjernu ili čak nenamjernu prijetnju sigurnosti posade, okoliša i broda. Sljedeća slika navodi primjere prijetnje, aktere i njihove moguće motivacije i ciljeve. Popis sigurno nije potpun i mogao bi se nadograditi dodatnim promišljanjem. Nužno je voditi računa da razni akteri imaju i različite razine vještina i resursa koji potencijalno mogu ugroziti sigurnost brodova i sposobnost poduzeća da posluje.

Tablica 6-2 Prikaz aktera, motivacija i ciljeva, Izvor: Vodič

Akteri	**Motivacija**
Slučajni/nesvjesni akteri	Nema zlonamjernog motiva, ali ipak na kraju nanese neželjenu štetu lošom srećom, nedostatkom znanja ili nepažnjom, npr. umetanjem zaraženog USB-a u ugrađeni IT ili OT sustav
Aktivisti/Nezadovoljni zaposlenici	Osveta, Prekid rada, Pažnja medija, Reputacijska šteta
Kriminalci	Financijska dobit, Komercijalna špijunaža, Industrijska špijunaža
Oportunisti	Izazov, Reputacijski dobitak,

[1000] *Loc.cit.*
[1001] *Ibid*, str. 11.

	Financijska dobit
Države/Državno sponzorirane organizacije/Teroristi	Politički/idejni dobitak, npr. (ne) kontrolirani poremećaj u gospodarstvu i kritičnoj nacionalnoj infrastrukturi, Špijunaža, Financijska dobit, Komercijalna špijunaža, Industrijska špijunaža, Komercijalna dobit

6.5. TIPOVI PRIJETNJI I FAZE IZVRŠENJA

Općenito valja razlikovati postojanje dva tipa kibernetskih prijetnji koje mogu utjecati na poduzeća i brodove, a to su:

- neciljani napadi, gdje su poduzeće ili brodski sustavi i podaci neke od mnogih potencijalnih meta i
- ciljani napadi na poduzeće ili brodski sustav s pripadajućim podacima.[1002]

Neciljani napadi vjerojatno će koristiti alate i tehnike dostupne na Internetu što se može koristiti za lociranje, otkrivanje i iskorištavanje čestih ranjivosti koje također mogu postojati u poduzeću i na brodu. Primjeri nekih alata i tehnika koji se mogu koristiti u tim okolnostima uključuju:[1003]

- *Malware* ili zlonamjerni softver namijenjen pristupu ili oštećenju računala bez znanja vlasnika. Postoje razne vrste zlonamjernog softvera, uključujući trojanske programe, *ransomware*, špijunske softvere, viruse i crve. *Ransomware* šifrira podatke na sustavima dok se ne plati otkupnina. Zlonamjerni softver također može iskoristiti poznate nedostatke i probleme u zastarjelom softveru. Pojam "iskorištavanje" obično se odnosi na upotrebu softvera ili koda koji je kreiran tako da koristi i manipulira nedostatkom na drugom računalnom softveru ili hardveru. Ovaj problem može, na primjer, biti programska pogreška, ranjivost sustava, nepravilan dizajn, hardver kvar i/ili pogreška u provedbi protokola. Te se ranjivosti mogu iskoristiti daljinski ili mogu biti lokalno aktivirane.

[1002] *Ibid*, str. 13.
[1003] *Loc.cit.*

- "*Water holing*" odnosno uspostavljanje lažne web lokacije ili ugrožavanje izvornog web mjesta radi iskorištavanja posjetitelja koji ne sumnjaju da se radi o ugrozi.
- Skeniranje odnosno nasumično pretraživanje većeg dijela Interneta u potrazi za ranjivostima koje bi mogle biti iskorištene.
- "*Typosquatting*" odnosno otmica web adrese (URL) ili korištenje lažnog URL-a. Oslanja se na pogreške poput upisa korisnika prilikom unosa adrese web mjesta u web preglednik. Ako korisnik slučajno unese netočnu adresu web mjesta, oni mogu biti dovedeni do druge i često zlonamjerne web stranice.[1004]

Ciljani napadi mogu biti sofisticiraniji i koristiti posebno izrađene alate i tehnike za određena poduzeća ili brodove. Primjeri alata i tehnika koji se mogu koristiti uključuju:[1005]

- Socijalni inženjering. Ne tehnička metoda koju potencijalni kiber napadači koriste za manipulaciju osobe s unutarnjim pristupom radi kršenja sigurnosnih postupaka obično, ali ne isključivo, interakcijom putem društvenih mreža.
- "*Brue force*" odnosno napad koji pokušava isprobati mnoge lozinke s nadom da će na kraju ispravno pogoditi. Napadač sustavno provjerava sve moguće lozinke dok se ne pronađe ispravna.
- "*Credential stuffing*" ili kolokvijalno punjenje vjerodajnica odnosi se na upotrebu prethodno ugroženih vjerodajnica ili posebnih često korištenih lozinki za pokušaj neovlaštenog pristupa sustavu ili aplikaciji.
- *Denial of service* (DoS) sprječava legitimne i ovlaštene korisnike da pristupe informacijama, obično preplavljivanjem mreže podacima. Potreban je napad distribuiranog uskraćivanja usluge (DoS) tj. nadzor više računala i/ili poslužitelja za provedbu DoS napada.
- *Phishing*. Slanje e-pošte velikom broju potencijalnih ciljeva tražeći određene osjetljive ili povjerljive informacije. E-adresa također može sadržavati zlonamjerni privitak ili link na lažnu web stranicu.
- *Spear-phishing* slično je krađi identiteta, ali pojedinci često ciljaju na osobnu e-poštu koji sadrže zlonamjerni softver ili veze koje automatski preuzimaju zlonamjerni softver. U nekim su slučajevima SAT-C poruke korištene za uspostavljanje osjećaja poznavanja e-adresa zlonamjernog pošiljatelja.

[1004] *Loc.cit.*
[1005] *Loc.cit.*

- Subverzija opskrbnog lanca tj. napad na poduzeće ili brod ugrožavanjem opreme, softvera ili pratećih usluga koje se isporučuju poduzeću ili brodu.

Gornji primjeri nisu jedini koji se koriste. Razvijaju se i druge metode kibernetskog napada kao što su lažno predstavljanje legitimnog zaposlenika na kopnu u brodarskom poduzeću radi dobivanja vrijednih informacija koje se mogu koristiti za daljnji napad i sl. U 2019. godini trebalo je u prosjeku 279 dana između ugrožavanja mreže i sanacije problema.[1006] Međutim, upad može ostati neotkriven godinama. Ova je brojka porasla od 266 dana u 2018. godini.[1007] Trajanje pripreme kibernetskog napada može se odrediti motivacijom i ciljevima napadača te otpornosti tehničkih i proceduralnih nadzora kibernetskog rizika koju provodi poduzeće, uključujući one na brodovima. Kada se razmatra ciljani kibernetski napad uočene faze ugroze su:[1008]

1. izviđanje,
2. plasiranje,
3. prodiranje i
4. pivotiranje.

U kontekstu izviđanja, otvoreni/javni izvori kao što su društveni mediji koriste se za dobivanje informacija o potencijalnom cilju (npr. poduzeću, brodu ili pomorcu) u pripremi za kibernetski napad. Društvene mreže, tehnički forumi i skrivena svojstva na web mjestima, dokumentima i publikacijama koriste se za identificiranje tehničkih, proceduralnih i fizičkih ranjivosti sustava. Plasiranje ugroze se odnosi na pokušaje napadača za pristupom sustavima i podacima poduzeća i broda. Ovo se može izvršiti iz poduzeća ili broda ili na daljinu. Sljedeći korak je penetracija o čijem uspjehu ovise promjene statusa opreme i ostalih važnih brodskih i drugih elemenata. Naposljetku, napadač koristi i tehniku pivotiranja odnosno koristi već ugroženi sustav za napad na druge sustave u istoj mreži. Tijekom ove faze napada napadač koristi prvi kompromitirani sustav za napad na inače nepristupačne sustave. Napadač će obično ciljati najviše na najranjiviji dio žrtvinog sustava s najnižom razinom sigurnosti. Također, da se zaključiti da je prijetnja proizvod sposobnosti, mogućnosti i namjere aktera da nanese štetu. Metodama kvantificiranja prijetnje može se ostvariti svrha da se pomogne u kvantificiranju vjerojatnosti koja je dio procjene rizika, a koji je proizvod vjerojatnosti i utjecaja. Drugim

[1006] IBM Cost of a Data breach Report 2019, dostupno na: https://www.youtube.com/watch?v=rbsqaJwpu6A
[1007] *Ibid.*
[1008] *Ibid.*

riječima, ako je sposobnost, prilika ili namjera aktera prijetnje nula ili blizu nule, prijetnja, a time i rizik će biti mali. Metode kvantificiranja prijetnje su nužne u ostvarivanju sigurnosti i kibernetičke sigurnosti broda i brodarskog poduzeća.

6.6. IDENTIFIKACIJA RANJIVOSTI

Uobičajene kibernetske ranjivosti koje se mogu naći na postojećim brodovima, ali i ponekoj novogradnji su:[1009]

- zastarjeli i nepodržani operativni sustavi,
- nezakrpani softver za sustav,
- zastarjeli ili nedostatni antivirusni softver i zaštita od zlonamjernog softvera,
- neadekvatne sigurnosne konfiguracije i najbolje prakse, uključujući neučinkovito upravljanje mrežom i korištenje zadanih administratorskih računa i lozinki,
- brodske računalne mreže kojima nedostaju mjere zaštite i segmentacija mreža,
- sigurnosna oprema ili sustavi uvijek povezani s obalom,
- neadekvatni nadzor pristupa kibernetskoj imovini, mrežama i sl. za treće strane, uključujući dobavljače i pružatelje usluga,
- osoblje neadekvatno obučeno i/ili nevješto za upravljanje kibernetskim rizicima i
- nestali, neadekvatni ili neprovjereni planovi i postupci za izvanredne situacije.

Identifikacija ranjivosti uključuje analizu aplikacija, sustava i postupaka u svrhu otkrivanja slabosti koje bi potencijalne prijetnje mogle iskoristiti. Identifikacija prijetnji može biti učinkovitija ako se takvi poslovi dodijele stručnjacima unutar kompanije ili se posao "*out source*-a" kvalitetnim vanjskim ekspertima s velikim znanjem o pomorskoj industriji i ključnim procesima. Cilj procjene brodske mreže i njezinih sustava i uređaja je identificirati bilo koje ranjivosti koje bi mogle ugroziti ili rezultirati gubitkom povjerljivosti, integriteta ili dostupnosti podataka i sustava potrebnih za upravljanje opremom, sustavom, mrežom ili čak brodom. Takve ranjivosti mogu se svrstati u jednu od sljedećih kategorija:[1010]

- privremena izloženost kao što su softverski kvarovi, zastarjeli ili nezakrpani sustavi,
- dizajn poput upravljanja pristupom ili neupravljanih mrežnih povezivanja,
- pogreške u implementaciji, na primjer pogrešno konfigurirani vatrozid i

[1009] Zahvaljujući publikaciji i preporukama IACS "Recommendation on Cyber Resilience (No. 166), novogradnja bi trebala biti manje ranjiva po gore navedenim stavkama.
[1010] Vodič, str. 17-18.

- proceduralne ili druge korisničke pogreške.

Također, nužno je evaluirati i ljudski faktor kao jedan od ključnih faktora u uspostavi sigurnosti na brodu s obzirom na to da je dosta incidenata počelo upravo ljudskim djelovanjem. Isto tako, nužno je klasificirati i vrstu incidenata koji bi mogli predstavljati ugrozu za kibersigurnost broda. Takve ugroze u osnovnom obliku možemo klasificirati kao:

- nadvodne ugroze,
    - interne i
    - eksterne
- podvodne ugroze
    - kontaktne i
    - daljinske.

Digitalni sustavi koji se koriste za menadžment i kontrolu tereta, iskrcaj i prijevoz istog, a najčešće sadrže dostavne informacije i informacije za praćenje, mogu biti lako iskoristivi za obje vrste ugroza što se smatra posebno opasnim ako je riječ o opasnim teretima. Navigacijski sustavi poput ECDIS, AIS, GNSS, VDR, RADAR/ARPA, koji su najčešće međusobno integrirani, moraju moći funkcionirati i samostalno te je nužno da su sustavi ažurirani sa svojim posljednjim verzijama.[1011] Ono što predstavlja ključ uspjeha u sprječavanju kiber ugroza jest svjesnost brodovlasnika o različitim brodskim sustavima koji mogu biti ugroženi. U tom smislu sustave možemo označiti na sljedeći način:[1012]

- Sustavi kontrole na mostu (AIS, VDR, ARPA…)
- Sustavi propulzije i snage (kontrola motora, upravljanje, menadžment goriva…)
- Navigacijski sustavi (GPS/GNSS, ECIDS, RADAR…)
- Sustavi za utovar i stabilitet (balast, menadžment tereta, stres trupa…)
- Zaštitni sustavi (vatrodojavni i protupoplavni, CCTV…)
- Komunikacijski sustavi (Sateliti, brod-kopno, brod-brod, VoIP…)
- Sustavi operativne sigurnosti (sučelje čovjek-stroj, PLC-ovi, digitalni i analogni senzori…)

[1011] Tam, K., Jones, K. (2018). Cyber-risk assessment for autonomous ships, 2018 International Conference on Cyber Security and Protection of Digital Services (Cyber Security), IEEE, str. 1-8.
[1012] Mission Secure. (2020). A Comprehensive Guide to Maritime Cybersecurity, dostupno na: https://www.missionsecure.com/hubfs/Assets/eBooks/A%20Comprehensive%20Guide%20to%20Maritime%20Cybersecurity_Final.pdf

- Sustavi mrežne sigurnosti (vatrozid, antivirus, softverska ažuriranja…)
- Sustavi fizičke sigurnosti (server sobe, most, mrežna infrastruktura, dozvole pristupa…)
- Brodska mreža (elektronička pošta, administracija osoblja…)
- Mreža posade (elektronička pošta, Wi-Fi, žičana konekcija, vlastiti uređaji…)
- Sustavi nabave (udaljeni ili obalni dobavljači, održavanje, administracija).

Loš primjer predstavlja slučaj u kojem je brod s integriranim navigacijskim sustavom pretrpio kvar gotovo svih navigacijskih sustava na moru, a nalazio se u prometnom području sa smanjenom vidljivošću.[1013] Brod je dva dana morao ploviti po jednom radaru i papirnatim kartama prije dolaska u luku na popravak. Tijekom prethodnog poziva u luku tehnički predstavnik proizvođača izveo je ažuriranje navigacijskog softvera na brodskim navigacijskim računalima.[1014] Međutim, zastarjeli operativni sustavi nisu mogli pokrenuti softver.[1015] Brod je trebao ostati u luci do novog ECDIS računala koja su se mogla instalirati što je rezultiralo povećanim troškovima brodarskom poduzeću.[1016] Ovaj incident naglašava da nisu svi kvarovi na računalu rezultat namjernog napada već da je i zastarjeli softver sklon kvaru. Detaljnija ispitivanja i proaktivno održavanje softvera na brodu trebaju biti stalna obveza brodarskim poduzećima kako bi se takvi incidenti smanjili. Osim toga, sustavi podložni kibernapadima su i propulzijski i sustavi nadzora snage zbog svoje digitalne komponente. Točnije, možemo zaključiti kako svi sustavi koji su digitalizirani mogu biti predmet kibernapada. To se odnosi i na sustave nadzora pristupa, sustave verifikacije i nadzora putnika, javne brodske mreže koje koriste sami putnici, sustave za posadu i specifičnu administraciju s pristupom internetu te komunikacijske sustave.[1017] Također, jedan od primjera kibernetičkih napada na pomorske sustave se zbio u srpnju 2018. godine kada je *China Ocean Shipping Company* (COSCO) postala žrtvom *SamSam ransomware*.[1018] *SamSam* je izazvao kvar na COSCO mrežama u SAD-u, Kanadi, Panami, Argentini, Brazilu, Peruu, Čileu i Urugvaju. Slično *NotPetyi*, kad *SamSam* dobije pristup mreži hakeri mogu dobiti administrativna prava i mogu pokretati izvršne datoteke bez ljudskog djelovanja ili odobrenja. Skupina koja stoji iza *SamSama* ne čini svoj alat dostupan i besplatan već održavaju interni razvoj i često ga ažuriraju kako bi izbjegli sigurnosne obrane

[1013] Vodič, str. 18.
[1014] *Loc.cit.*
[1015] *Loc.cit.*
[1016] *Loc.cit.*
[1017] *Ibid*, str. 18-19.
[1018] Mission Secure, *op.cit.*, str. 9.

raznih poduzeća.[1019] Napad *SamSam* dogodio se ubrzo nakon što je COSCO stekao jednog od suparnika, *Orient Overseas Container Lines*. Aktiviranjem njihovih planova za nepredviđene slučajeve operacije COSCO-a vratile su se u normalu za pet dana. Šteta nastala ovim napadom nije se otkrila javnosti što daje naslutiti ozbiljnost samog napada.[1020]

Zbog svega navedenog, nužno je definirati termin brodskih kritičnih infrastruktura (BKI) temeljem kojeg bi se izradila analiza rizika od određenih vrsta napada na brodske sustave. Vodeći se odredbama hrvatskog Zakona o kritičnim infrastrukturama[1021] koji definira nacionalne kritične infrastrukture pretpostavlja se definiranje BKI. BKI se mogu definirati kao sustavi, mreže i objekti od ključne brodske važnosti čiji prekid djelovanja može imati značajne posljedice na brodsku sigurnost, zdravlje i živote ljudi, imovinu i okoliš.[1022]

6.7. PROCJENA VJEROJATNOSTI

Postoji tendencija procjene rizika samo na temelju potencijalnih utjecaja i postojećih ranjivosti. Međutim, kao što je prethodno navedeno, vjerojatnost da se dogodi kibernetska ugroza jest proizvod prijetnje i ranjivosti. To također znači da ako je bilo koji od ova dva čimbenika blizu nepostojećem ili nepostojeći, takva će biti i vjerojatnost, a to treba uzeti u obzir prilikom kvantificiranja vjerojatnosti. Poduzeća će u svojim SMS-ovima sadržavati matricu procjene rizika u kojoj je vjerojatnost da se zadani događaj mjeri na skali od pet koraka. Upotreba postojeće skale vjerojatnosti SMS-a može biti prednost jer će korištenje postojećih jezika i koncepata za opisivanje kibernetskih rizika olakšati razumijevanje u cijelom poduzeću. Usklađena strategija upravljanja rizikom poduzeća i razumijevanje je presudno za osiguravanje potpore višeg rukovodstva za učinkovito upravljanje kibernetskim rizicima strategije temeljene na ishodima procjene rizika. Jedan primjer takve ljestvice može biti:

[1019] *Ibid.*
[1020] *Ibid.*
[1021] Zakon o kritičnim infrastrukturama (NN, br. 56/13)
[1022] Čl. 3. Zakona o kritičnim infrastrukturama

Tablica 6-3 Procjena rizika, Izvor: SMS

Razina	**Opis vjerojatnosti**
1	Nikad čuo u industriji. Blizu da bude nešto nezamislivo.
2	Čulo se u industriji, ali vrlo rijetko i kao rezultat povezanih nesretnih događaja.
3	Incident se vjerojatno dogodio u vlastitom poduzeću, ali u kontekstu neispravne opreme ili iznenađujuće pogreške koje su činili ljudi uključeni u proces.
4	Povremeno se događa u vlastitom poduzeću, obično u kontekstu neispravne opreme ili pogrešaka ljudi koji su uključeni (vrste pogrešaka koje se s vremena na vrijeme mogu dogoditi na brodu).
5	Često se događa kad se poduzima određeni posao.

U idealnom svijetu kvantificiranje vjerojatnosti bilo bi potkrijepljeno pristupom specifičnim brodskim obavještajnim podacima i prijetnjama u cijeloj industriji na temelju izvješća o incidentima. Međutim, takva obavještajna struktura prijetnji nije odmah dostupna pa je stoga vrijedno potražiti druge sektore osim pomorskog prometa kao prijetnju gdje akteri često prenamjenjuju tehnike koje su se prije koristile za napad na jedan sektor kako bi ciljali drugi sektor. Također, nužno je pažljivo proučiti sposobnost, priliku, čimbenike prijetnje kao i samu namjeru.[1023]

6.8. PROCJENA UTJECAJA

Utjecaj neke ugroze na sustav može se vrednovati kroz različite modele. Međutim, prema Federalnim informacijskim standardima za procese[1024] za pomorstvo najznačajniji je CIA model (engl. *Confidentiality, Integrity, Availability* - CIA). On podrazumijeva povjerljivost, integritet i dostupnost te u tom okviru pruža procjenu utjecaja, a odnosi se na:

- gubitak povjerljivosti podataka poput neovlaštenog pristupa i otkrivanje informacija ili podataka o brodu, posadi, teretu i putnicima,
- gubitak integriteta, što bi izmijenilo informacije i podatke koji se odnose na siguran i učinkovit rad i upravljanje brodom i

[1023] Vodič, str. 22.
[1024] Federal Information Processing Standards, Publication 199, Computer Security Division Information Technology Laboratory, National Institute of Standards and Technology, Gaithersburg, MD 20899-8900, dostupno na: https://csrc.nist.rip/publications/drafts/FIPS-PUB-199-ipd.pdf

- gubitak dostupnosti uslijed uništavanja informacija i podataka i/ili poremećaja usluga/rada brodskih sustava.[1025]

Relativna važnost povjerljivosti, cjelovitosti i dostupnosti ovisi o upotrebi informacija ili podataka. Suprotno tome, procjena ranjivosti OT sustava na brodovima, posebno sigurnosnih sustava, može se usredotočiti na dostupnost i/ili integritet umjesto na povjerljivost. SMS će obično sadržavati matricu procjene rizika u kojoj je utjecaj određenog događaja i koji se mjeri na skali od pet razina. Podrazumijeva različite kategorije poput sigurnosti osoblja, sigurnosti okoliša, sigurnosti tereta i imovine, kontinuitet poslovanja, financijski utjecaj i ugled poduzeća. Korištenje razine i postavki omogućava poduzeću da razlikuje različite brodove u floti prema njihovoj kritičnosti naspram zbrojenih aktivnosti poduzeća.[1026] Takva ljestvica može izgledati na sljedeći način:

Tablica 6-4 Razine utjecaja - SMS, Izvor: Vodič

Razina	**Opis utjecaja**
1	Nema zdravstvenih učinaka/ozljeda. Nema štete za okoliš, imovinu, financije ili reputaciju poduzeća.
2	Vrlo neznatan učinak na zdravlje/ozljede. Vrlo mala šteta za okoliš, imovinu, financije ili ugled poduzeća.
3	Neki zdravstveni učinak/lakše ozljede. Manja šteta za okoliš, imovinu, financije ili ugled poduzeća.
4	Značajni zdravstveni učinak/relativno ozbiljne ozljede. Lokalna, ali velika šteta za okoliš, imovinu, financije ili ugled poduzeća.
5	Smrtnost ili trajni invaliditet. Raširena, značajna šteta za okoliš, imovinu, financije ili ugled poduzeća.

Kada je u pitanju ugroza od kibernapada može se primijeniti drukčija metodologija u procjeni utjecaja. Tako primjerice može sadržavati tri razine potencijalnog utjecaja kao što je prikazano u sljedećoj tablici.[1027]

[1025] *Ibid*, str. 4-6.
[1026] *Ibid*, str. 23.
[1027] Metodologije uključuju, ali nisu ograničene na, ISO / IEC 27005: 2018 Informacijska tehnologija - Sigurnosne tehnike - Upravljanje rizikom informacijske sigurnosti, COSO Okvir za upravljanje rizikom poduzeća i ISO 31000: 2018 Upravljanje rizikom - Smjernice.

Tablica 6-5 Razine potencijalnog utjecaja ugroza, Izvor: Vodič

Potencijalni utjecaj	**Definicija**	**Praksa**
Mali	Moglo bi se očekivati da će gubitak povjerljivosti, integriteta ili dostupnosti imati ograničeni štetni učinak na poduzeće i brod, organizacijsku imovinu ili pojedince.	Ograničeni štetni učinak znači da bi narušavanje sigurnosti moglo: (i) rezultirati manjom štetom za pojedince; (ii) rezultirati manjim financijskim gubicima; (iii) rezultirati manjom štetom na organizacijskoj imovini ili (iv) uzrokovati degradaciju rada broda do mjere i trajanja do koje organizacija može obavljati svoje primarne funkcije, ali je učinkovitost funkcija primjetno smanjena.
Srednji	Gubitak povjerljivosti, integriteta ili dostupnosti - moglo bi se očekivati da će imati značajan štetan učinak na poduzeće i brod, imovinu ili pojedince.	Značajan štetan učinak znači da bi narušavanje sigurnosti moglo: (i) rezultirati značajnom štetom za pojedince koja ne uključuje gubitak života ili ozbiljnih ozljeda opasnih po život; (ii) rezultirati značajnim financijskim gubicima; (iii) rezultirati značajnom štetom na organizacijskoj imovini ili (iv) uzrokovati značajnu degradaciju u radu broda do mjere i trajanja do koje organizacija može obavljati svoje primarne funkcije, ali je učinkovitost funkcija značajno smanjena.
Veliki	Očekivati je da će gubitak povjerljivosti, integriteta ili dostupnosti imati ozbiljan ili katastrofalan štetan učinak na	Teški ili katastrofalni štetni učinak znači da bi narušavanje sigurnosti moglo:

	poslovanje poduzeća, broda, imovinu, okoliš ili pojedince.	(i) rezultirati ozbiljnom ili katastrofalnom štetom za osobe koje uključuju gubitak života ili ozbiljne ozljede opasne po život; (ii) rezultirati velikim financijskim gubicima; (iii) rezultirati velikom štetom po okoliš i/ili organizacijsku imovinu ili (iv) izazvati ozbiljno oštećenje koje dovodi do prekida rada broda na način da brodarsko poduzeće nije više u stanju obavljati svoje primarne funkcije.

Procjenu utjecaja treba konstantno provoditi za sve sustave na brodu. Za OT sustave takva procjena utjecaja također je dio popisa opreme i tehničkih sustava čiji iznenadni operativni kvar može više ili manje odmah rezultirati opasnim situacijama što zahtijeva stavak 10.4 ISM kodeksa.

6.9. PROCJENA RIZIKA

Tek nakon uspostavljanja pregleda prijetnji (namjera, sposobnost i prilika), ranjivosti, utjecaja i vjerojatnosti, moguće je provesti procjenu rizika. Procjena rizika nije jednokratna aktivnost već je treba ponavljati u odgovarajućim intervalima kako bi se osiguralo da se rezultati procjene rizika pravodobno ažuriraju. Procjena rizika može se provoditi u četiri faze, a to su:[1028]

1. aktivnosti prije procjene,
2. procjena broda,
3. pregled i izvještavanje i
4. pregled i izvještavanje proizvođača.

Prva faza sastoji se od procjene kibernetskog rizika. Procjena kibernetskog rizika složen je poduhvat koji zahtijeva detaljno znanje o upravljanju kibernetskim rizikom, a u nekim će

[1028] Tam, K., Moara-Nkwe, K., Jones, K. (2021). The use of cyber ranges in the maritime context: Assessing maritime-cyber risks, raising awareness, and providing training, Maritime Technology and Research, 3(1)

slučajevima vjerojatno biti potrebna podrška treće strane u procesu procjene rizika. U kontekstu aktivnosti nužnih pred pokretanje same procjene važno je odraditi sljedeće korake:[1029]

- pregledati dokumentaciju IT i OT sustava primjerice pomoću CIA modela,
- identificirati glavne proizvođače kritične brodske IT i OT opreme,
- utvrditi kontaktne točke kibernetičke sigurnosti s najvažnijim proizvođačima i uspostaviti radni odnos s njima,
- pregledati detaljnu dokumentaciju o održavanju broda i podršci IT i OT sustavima i
- uspostaviti ugovorne zahtjeve i obveze koje brodar/brodski operater može imati za održavanje i podršku brodskih mreža i opreme.

Kada se procijene svi čimbenici rizika (prijetnje, ranjivosti, vjerojatnost i utjecaj) može se provesti druga faza, a to je procjena rizika i povezano ublažavanje rizika. Procjena rizika sustavno je razmatranje relevantnih čimbenika rizika. Procjena rizika i broda provodi se sustav po sustav i stoga se temelji na dokumentaciji sustava opisanoj u procjeni utjecaja. Da bi bila precizna procjena rizika oslanja se na poznavanje funkcionalnosti sustava, protok podataka u sustav i iz njega te na precizan način na koji je svaki sustav povezan kabelima ili bežičnom vezom s drugim sustavima. Aktivnosti izvršene tijekom procjene mogle bi uključivati pregled konfiguracije svih računala, poslužitelja, usmjerivača i tehnologija kibernetičke sigurnosti, uključujući vatrozid. Također bi mogao uključiti recenzije sve dostupne dokumentacije o kibernetičkoj sigurnosti i postupaka za povezane IT i OT sustave i uređaje. U trećoj fazi nužno je zadovoljiti zahtjeve ISM kodeksa što znači da bi procjena rizika trebala biti koherentan i ažuran dokument koji odražava način na koji se rizici procjenjuju i ublažavaju. Izrada takve procjene rizika često će biti ponavljajući postupak u kojem se različite mjere ublažavanja razmatraju u različitim kombinacijama sve dok se ne donese odluka o optimalnom sastavu ublažavanja rizika mjerenog u smislu zakonskih zahtjeva, prihvatljivog rizikom, izvedivosti, učinkovitosti i troškova.

Treća faza sadrži sljedeće elemente:

- sažetak,
- tehnički nalazi,
- prioritetni popis akcija,
- dopunski podaci i

[1029] *Ibid.*

- dodaci.[1030]

U posljednjoj fazi nakon što brodovlasnik ima priliku pregledati, raspraviti i procijeniti razne elemente sigurnosti, određena dokumentacija možda će trebati biti poslana proizvođačima kritičnijih sustava kako bi se smanjio rizik. Bilo koja otkrića poput identificirane kibernetske ranjivosti u tvorničkoj standardnoj konfiguraciji kritičnog sustava ili komponente mogla bi se dalje analizirati uz podršku vanjskih stručnjaka koji bi trebali surađivati s proizvođačkom kontaktnom točkom za kibersigurnost kako bi se osiguralo potpuno i sigurno razumijevanje rizika.[1031]

6.10. RAZVOJ MJERA ZAŠTITE

Povezani OT sustavi na brodu trebaju zahtijevati više od jedne tehničke i/ili proceduralne mjere zaštite. Obrane poput zaštitnih zidova važne su za sprječavanje neželjenog ulaska u sustave, ali to možda nije dovoljno za suočavanje s prijetnjama iznutra. Pristup u kvalitetnoj i sveobuhvatnoj obrani od kibernetskih ugroza na brodu potiče kombinaciju:[1032]

- fizičkog osiguranja broda u skladu s brodskim planom zaštite (SSP),
- zaštite mreža, uključujući učinkovitu segmentaciju,
- otkrivanje upada,
- upotrebe vatrozida,
- povremenog skeniranja i testiranja ranjivosti,
- nadzora dopuštenih softvera (softver *whitelisting*),
- pristupa i korisničke kontrole,
- kontrole upravljanja konfiguracijom i promjenama,
- odgovarajućih postupaka u vezi s upotrebom izmjenjivih medija i pravila zaporke,
- svijesti internetske sigurnosti osoblja i razumijevanje rizika za sebe i industriju i
- razumijevanja i poznavanja odgovarajućih postupaka, uključujući odgovor na incident.

Mjere zaštite od kibernetskih rizika mogu biti tehničke i usredotočene na osiguravanje da su ugrađeni sustavi dizajnirani i konfigurirani tako da budu otporni na kibernetičke incidente. Potrebno je razmotriti provođenje tehničkih nadzora koji su praktični i isplativi, posebno na

[1030] Vodič, str. 28-29.
[1031] *Loc.cit.*
[1032] *Ibid,* str. 30-34.

postojećim brodovima. Treba imati na umu da provedba mjera tehničke kontrole nije jednokratna aktivnost. Jednom implementirani trebali bi se redovito ažurirati kako bi se umanjio rizik od napada. Tehničke metode zaštite mogu podrazumijevati ograničenje nadzora mrežnih priključaka, protokola i usluga, konfiguraciju mrežnih uređaja poput vatrozida, usmjerivača (rutera) i prekidača (*switches*), fizičku sigurnost, satelitsku i radio komunikaciju, bežični pristup kontrolama, sigurnu konfiguraciju hardveru i softveru, zaštitu elektroničke pošte i Internet pretraživača te ažuriranje aplikacija. U kontekstu ograničenja i nadzora mrežnih priključaka, protokola i usluga to pomaže u osiguranju, odnosno osigurava da se putem kontrolirane mreže ili pod-mreže dopušta samo odgovarajući promet na temelju politike kontrole te mreže ili pod-mreže. Preporučuje se da usmjerivači budu zaštićeni od ugroza, a neiskorišteni priključci zatvoreni kako bi se spriječio neovlašteni pristup sustavima ili podacima. Sukladno konfiguraciji mrežnih uređaja poput vatrozida, usmjerivača i prekidača treba utvrditi koji se sustavi trebaju priključiti na kontrolirane ili nekontrolirane mreže. Kontrolirane mreže dizajnirane su za sprječavanje bilo kakvih sigurnosnih rizika povezanih uređaja upotrebom vatrozida, sigurnosnih prolaza, usmjerivača i prekidača. Fizička sigurnost ponekad je najjednostavniji, najjeftiniji i najočitiji oblik kibernetske obrane. To je središnji aspekt upravljanja kibernetskim rizikom, a učinkovita obrana u strategiji trebala bi imati za cilj osigurati da se mjere fizičke kontrole ne mogu zaobići. Ključno je strogo se voditi ISPS-om i SSP-om. Kibersigurnost radija i satelitskih veza trebala bi se razmotriti u suradnji s davateljem usluga. S tim u vezi, specifikaciju satelitske veze treba uzeti u obzir prilikom utvrđivanja zahtjeva za zaštitu brodske mreže. Satelitski terminal obično ima malu zaštitu lokalnog mrežnog (LAN) priključka za povezivanje s brodskim mrežama što ostavlja različite mogućnosti za zaštitu ovisno o prijetnji. Zaštita od prisluškivanja obično se vrši pomoću veze virtualne privatne mreže (VPN) ili šifriranih protokola. Bežični pristup mrežama na brodu trebao bi biti ograničen na odgovarajuće ovlaštene uređaje i osiguran pomoću jakog ključa za šifriranje koji se redovito mijenja. Sigurna konfiguracija hardvera i softvera podrazumijevala bi da korisnički profili trebaju biti ograničeni kako bi se računala, radne stanice ili poslužitelji mogli koristiti samo u svrhe za koje su potrebni. Korisnički profili ne bi trebali dopustiti korisniku da mijenja sustave ili instalira i izvršava nove programe. Bilo koja zaštita elektroničke pošte i web preglednika trebala bi:[1033]

- zaštititi obalno i brodsko osoblje od potencijalnog društvenog inženjeringa,

[1033] *Ibid.*

- pomoći u sprječavanju upotrebe elektroničke pošte kao metode za dobivanje osjetljivih podataka,
- osigurati da razmjena osjetljivih podataka putem elektroničke pošte ili glasa bude na odgovarajući način zaštićena kako bi se osigurala povjerljivost i cjelovitost podataka i
- spriječiti web preglednike i klijente elektroničke pošte u izvršavanju zlonamjernih skripti.

Ažuriranje aplikacije bi trebalo osigurati sigurnosna ažuriranja ugrađenih sustava i preporuča se razviti plan "zakrpe" softvera i hardvera. Sigurnosne zakrpe trebaju biti uključene u periodični ciklus održavanja, a preporuča se obratiti posebnu pozornost na opremu koja se koristi za virtualnu mrežnu segregaciju (VLAN) i vatrozid. Mjere zaštite mogu biti i proceduralne i trebaju biti obuhvaćene politikama poduzeća, postupcima upravljanja sigurnošću, sigurnosnim postupcima i kontrolama pristupa. Kao i kod svih ostalih mjera nadzora treba se provoditi samo proceduralni nadzor koji je praktičan i isplativ. Proceduralni nadzor usmjeren je na to kako posada i ostalo osoblje koristi ugrađene sustave. Također, prema STCW zahtijeva se od poduzeća da osiguraju da pomorci budu upoznati sa „*...svim brodskim aranžmanima, instalacijama, opremom, postupcima i karakteristikama brodova koji su relevantni za njihove rutinske ili hitne dužnosti*."[1034] Uz osposobljavanje pomoraca koje zahtijeva STCW trebao bi postojati i program podizanja svijesti za cjelokupno osoblje na brodu u skladu s njihovom ulogom obuhvaćajući, na primjer, nešto od sljedećeg:

- Rizici povezani s elektroničkom poštom i kako se ponašati na siguran način.
- Rizici povezani s korištenjem Interneta, uključujući društvene medije, forume za *chat* i pohranu datoteka u „oblaku“ gdje je kretanje podataka manje kontrolirano i nadzirano.
- Rizici povezani s podacima o geolokaciji za osoblje i brodove koji su javno dostupni.
- Rizici povezani s korištenjem vlastitih uređaja. Ovim uređajima možda nedostaju sigurnosne zakrpe, protokoli i nadzor, poput antivirusnih programa, a rizik mogu prenijeti na sustav na koji su povezani.
- Rizici povezani s instaliranjem i održavanjem softvera na hardveru poduzeća pomoću zaraženog hardvera (prijenosni medij) ili softvera (zaraženi paket).
- Rizici povezani s lošim praksama sigurnosti softvera i podataka gdje se ne provode antivirusne provjere ili provjere autentičnosti.

[1034] STCW Reg. I/14, 1,4

- Zaštita korisničkih podataka, lozinki i digitalnih certifikata.
- Kibernetski rizici u odnosu na fizičku prisutnost osoblja izvan poduzeća.
- Otkrivanje sumnjive aktivnosti ili uređaja i kako prijaviti mogući kibernetski incident.
- Svijest o posljedicama ili utjecaju kibernetskih incidenata na sigurnost i rad broda.
- Razumijevanje kako implementirati preventivne rutine održavanja kao što su antivirusni i *anti-malware* programi, zakrpe, sigurnosne kopije i planiranje i testiranje odgovora na incidente.[1035]

Kada se u kontekst uzmu svi povezani rizici i možebitne ugroze jasno je da smjer razvoja mjera zaštite od kibernapada mora ići u više faza i one moraju biti raznolike. Sukladno tome, može se napraviti sljedeći model razvoja mjera prikazan na slici 6-2.

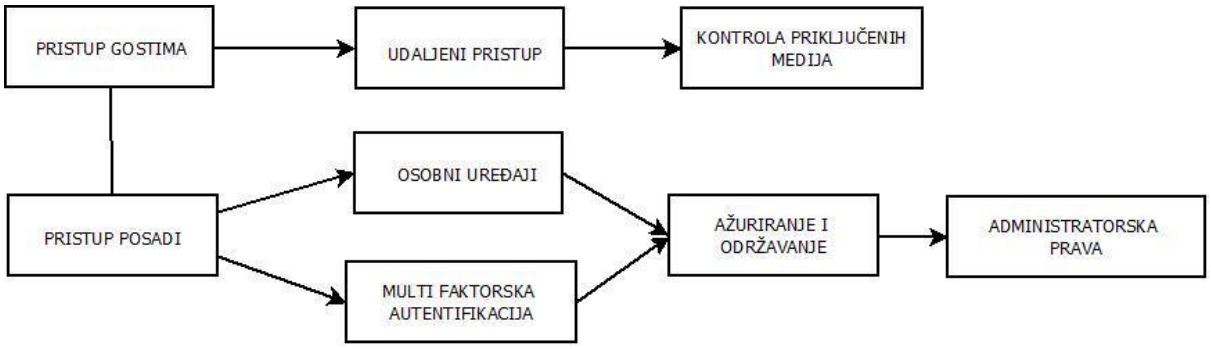

Slika 6-2 Model razvoja mjera zaštite,

Izvor: izradio autor

Uz navedeno, važno je naglasiti da zastarjela oprema može sadržavati podatke koji su poslovno osjetljivi ili povjerljivi. Prije zbrinjavanja opreme poduzeće bi trebalo imati uspostavljen postupak koji osigurava da se podaci koji se čuvaju u zastarjeloj opremi pravilno uništavaju i da se ne mogu dohvatiti.

6.11. RAZVOJ DETEKCIJSKIH MJERA

Otkrivanje upada i „infekcija“ sustava središnji je dio upravljanja kibernetskim rizikom. Treba uspostaviti i upravljati osnovnom mrežnom operacijom i očekivanim protokom podataka za korisnike i sustave kako bi se mogli uspostaviti pragovi upozorenja za kibernetske incidente. Ključni element u tom procesu je definicija uloga i odgovornosti za otkrivanje kako bi se

[1035] Vodič, str. 30.

osigurala svaka buduća sigurnost. Uz to, poduzeće može odlučiti da u mrežu ili kao dio vatrozida uvrsti sustav za otkrivanje provale[1036] (engl. *Intrusion Detection System* - IDS) ili sustav za sprječavanje upada[1037] (engl. *Intrusion Prevention System* - IPS). Opća smjernica je da računala na brodu trebaju biti zaštićena na istoj razini kao i uredska računala na kopnu. Anti-virusni i *anti-malware* softveri trebali bi se instalirati, održavati i ažurirati na sva osobna računala i računala povezana s brodskim sustavima. To će smanjiti rizik od djelovanja ovih računala kao napadače prema poslužiteljima i drugim računalima na brodskoj mreži. Koliko će se redovito ažurirati softver za skeniranje mora se uzeti u obzir prilikom donošenja odluke o obrambenim metodama. Također, predlaže se novačenje i/ili obučavanje posebne osobe na brodu za detekcijska i zaštitna pitanja računalnih brodskih sustava. Kao što postoji SSO trebalo bi se razmisliti i o uvođenju stručnjaka na brod koji će se baviti pitanjima kibernetičke sigurnosti odnosno *Cyber Security Ship Officer* (CSSO). Uz navedeno, nužno je izraditi plan odgovora koji pokriva relevantne nepredviđene slučajeve i sve planove treba čuvati u tiskanom obliku u slučaju potpunog gubitka elektroničkog pristupa istima. Prilikom izrade planova za izvanredne situacije za provedbu na brodovima važno je shvatiti značaj svakog kibernetskog incidenta kao sigurnosnog pitanja i u skladu s tim prioritetno odrediti radnje reagiranja.

6.12. ODGOVOR I OTKLANJANJE KIBERNETIČKIH INCIDENATA

Polazište za učinkovit odgovor je plan odgovora koji pokriva relevantne nepredviđene slučajeve. Međutim, malo je vjerojatno da će se planovi odgovora na kraju podudarati sa scenarijem kibernetičkog incidenta tijekom njegovog razvijanja. Zbog toga je važno redovito izrađivati plan odgovora i razvijati nepredviđene slučajeve u skladu s već viđenim prijetnjama, ranjivostima i utjecajima.[1038] Za većinu brodova planovi nepredviđenih događaja već su uspostavljeni u hitnim postupcima koji se zahtijevaju u dijelu 1.4.5. ISM kodeksa. Za kibernetske incidente potreban je aktivan odgovor kako bi se brod vratio u rad. Ako je primjerice ECDIS zaražen zlonamjernim softverom, pokretanje sigurnosne kopije ECDIS može

[1036] Almseidin, M., Alzubi, M., Kovacs, S., Alkasassbeh, M. (2017). Evaluation of machine learning algorithms for intrusion detection system, 2017 IEEE 15th International Symposium on Intelligent Systems and Informatics (SISY), IEEE, str. 277-282.
[1037] Wattanapongsakorn, N., Srakaew, S., Wonghirunsombat, E., Sribavonmongkol, C., Junhom, T., Jongsubsook, P., Charnsripinyo, C. (2012). A practical network-based intrusion detection and prevention system, 2012 IEEE 11th International Conference on Trust, Security and Privacy in Computing and Communications, IEEE, str. 209-214.
[1038] Vodič, str. 43-46.

prouzročiti novi kibernetički incident. Stoga se preporučuje izrada i uvježbavanje plana odgovora na incidente detaljno opisujući uloge i odgovornosti, putove komunikacije i osnovne aktivnosti. Kao što je vidljivo na slici 6-3, prva faza priprema bi obuhvaćala determiniranje kritičnih infrastruktura broda, njihovu evaluaciju i lokaciju.

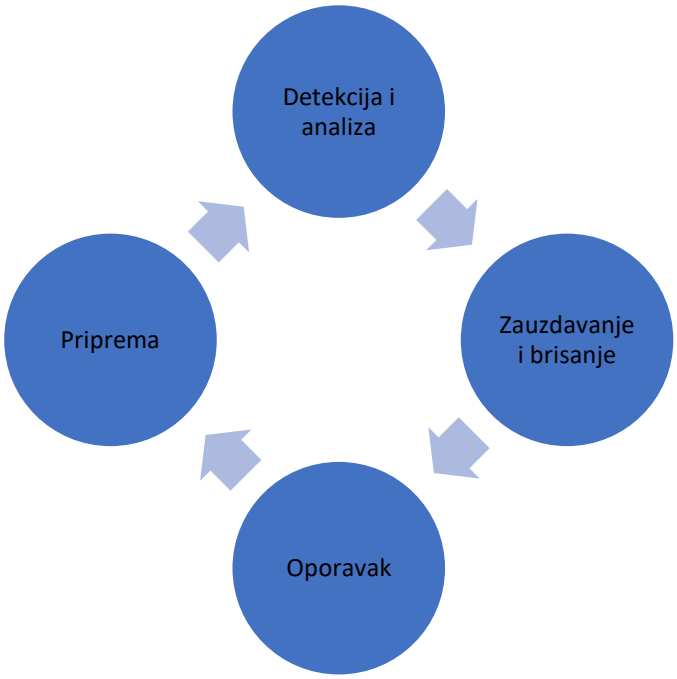

Slika 6-3 Faze odgovora na kibernetički incident,

Izvor: Izradio autor prema Vodiču

Kao jedna od metoda prioritizacije kritičnih infrastruktura preporuča se korištenje tehnika kompetitivne analize odnosno ponderiranje kao jedne od važnijih metoda. Također, u pripremi je nužno osigurati dodatnu pohranu (*backup*) svih relevantnih podataka, identifikaciju potencijalnih kritičnih točki napada te kreiranje plana odgovora i redovito uvježbavanje istog. U sljedećoj fazi detekcija i analiza obuhvaćala bi poimanje kako se incident dogodio, koji IT i OT sustavi su pogođeni i u kojoj mjeri je ostala prijetnja za navedene sustave. Treća faza obuhvaćala bi suzbijanje i uklanjanje nastale ugroze. To uključuje provjeru vatrozida, gašenje sustava koji su spojeni na Internet, potpuni oporavak diska i osiguranje lanca dokaza za daljnje forenzično postupanje. U posljednjoj fazi nužno je osigurati oporavak sustava i podataka, istražiti incident koliko je to moguće te spriječiti ponovni nastanak ugroze.[1039]

[1039] *Ibid*, str. 44.

7 RASPRAVA

Istraživanje provedeno u svrhu izrade ove doktorske disertacije imalo je za cilj ukazati na sadašnju primjenu AI u međunarodnom pomorskom prometu, ukazati na možebitne poteškoće primjene i ponuditi nova rješenja čime bi se ostvario znanstveni doprinos struci i široj društvenoj zajednici. Istraživanje se provelo u tri ključne cjeline, odnosno pravnu cjelinu primjene AI u međunarodnom pomorskom prometu, društvenu cjelinu tj. utjecaj AI na društvo te naposljetku sigurnosnu cjelinu AI s naglaskom na primjenu u međunarodnom pomorskom prometu. U tom smislu postavljene su hipoteze doktorske disertacije predstavljene u uvodnom dijelu rada. U ovom dijelu rada izdvajaju se ključni dijelovi važnih poglavlja u cilju sinteze dobivenih zaključaka provedenog istraživanja.

Pravni okvir AI u međunarodnom pomorskom prometu je u uzročno - posljedičnoj vezi s djelovanjem relevantnih pomorskih organizacija i propisa koje donose, između ostalog, i sa svrhom sigurne plovidbe. IMO kao krovna pomorska organizacija nastoji u svom djelovanju utvrditi trenutne regulatorne okvire i procijeniti koliko isti mogu biti primjenjivi na brodove s određenim stupnjem autonomije što je vidljivo kroz određene projekte poput MASS-a. Takav pristup podrazumijeva provođenje analiza istraživane problematike s ljudskim i tehnološkim elementom kao ključnim čimbenicima funkcioniranja. Ono što se u ovom radu prikazalo upućuje na nužnost izmjena i dopuna partikularnih rješenja unutar regulatornih okvira poput dijelova SOLAS-a, COLREG-a, STCW-a, ISPS-a, MARPOL-a i sl.

Uz IMO veliku ulogu u tom procesu ima i ILO. Djelovanje organizacije poput ILO-a je bitno u smislu procjene utjecaja AI na zaposlenost širom svijeta te je izražena zabrinutost zbog globalnog, ekonomskog i zdravstvenog utjecaja tehnologije, djelovanjem sustava automatizacije, AI, robotike i robotske automatizacije na ljudski rad. Sasvim je sigurno kako će utjecaj AI i ostalih novih tehnologija ostaviti traga i transformirati svjetsku pomorsku industriju u cijelosti. Takav utjecaj može se očitovati kroz prizmu straha od gubitka poslova i nejednakosti u učinkovitosti zbog već jasnih i provjerenih premisa o produktivnosti određenih tehnologija u odnosu na čovjeka što treba posebno znanstveno istražiti u okviru djelovanja ILO-a.

Analizom UNCLOS-a istaknuto je kako se AI ne regulira u njezinim odredbama. Stoga je važno naglasiti kako razvoj AI neminovno donosi određenu razinu primjene i u međunarodnom pomorskom prometu, a navedena tehnologija će se morati pravno regulirati i implementirati u najvažnije pomorsko pravne akte čime će se stvoriti prvi preduvjeti korištenja AI u pomorstvu.

Slično se odnosi i na SOLAS gdje je prilagodba postojećih odredbi nužna u kontekstu što kvalitetnije primjene AI u međunarodnom pomorskom prometu.

Važno je napomenuti kako svi postojeći pravni akti u području pomorstva iziskuju određenu razinu prilagodbe u kontekstu primjene AI. U tom smislu je analiziran i MARPOL, odnosno uočeni su benefiti moguće primjene AI, a tiču se kvalitetnijeg sustava u odlučivanju prilikom upravljanja otpadom, uljima i sličnim brodskim zagađivačima mora što predstavlja srž navedene konvencije.

Ažuriranje postojećih pravnih odredbi odnosi se i na akte poput STCW-a, COLREG-a i ISPS-a posebice kada znamo na što se navedeni dokumenti odnose. Izobrazba i certificiranje pomoraca od temeljne je važnosti pa slijedom toga možemo zaključiti da će se određeni sustav certificiranja i izobrazbe AI također morati primijeniti s ciljem sigurne plovidbe i sprječavanja sudara na moru propisanih i COLREG-om. Automatizacija određenih procesa na brodu, a sukladno nekim istraživanjima navedenim u radu, može rezultirati smanjenjem navedenih tipova nesreća posebice ako su uzrokovane ljudskim djelovanjem. U kontekstu primjene AI, odredbe ISPS-a, a samim time i SOLAS-a, mogu biti predmet izmjena i dopuna kako bi se navedeni pravni akti uskladili s novim tehnološkim dostignućima posebice na području korištenja potpunih autonomnih sustava/plovila u pomorskom i međunarodnom pomorskom prometu.

Pored normativnih pravnih propisa za pomorstvo u ovoj doktorskoj disertaciji istraživani su i drugi relevantni pravni akti koji mogu imati važnu ulogu i u pomorstvu. Jedan od takvih je GDPR iz razloga što uređuje način obrade osobnih podataka, a poznato je kako AI teži prikupljanju velike količine podataka svake vrste. Obrada i zaštita podataka koje će AI prikupiti treba biti iznimno pažljivo čuvana i korištena ponajviše iz sigurnosnih razloga. Svakako, odgovori će se morati pružiti i na pitanja koja se odnose na identifikaciju nositelja podataka i tko je korisnik podataka, ali također ovise i o prirodi podataka što će svakako biti povezano s odredbama GDPR-a i imati značaj utjecaj na pomorski sektor u svim onim elementima gdje se može očekivati razmjena važnih informacija kao i ostvarivanje sigurnosti istih. Upravo u ostvarivanju sigurnosti sustava AI jednim od ključnih čimbenika može se smatrati kibernetička sigurnost gdje određene organizacije poput ENISA-e s nadzornim i savjetodavnim djelovanjem u provođenju Direktive 2016/1448 mogu imati snažan utjecaj u sigurnosti primjene AI u pomorskom prometu.

Pomaci u približavanju AI stručnoj, ali i široj populaciji vidljivi su u djelovanju Komisije u raznim, već usvojenim dokumentima što uključuje AI za Europu, Europsku podatkovnu strategiju, Bijelu knjigu, Izvješće 64 i KP, ali i kroz aktivnosti koje provodi UN što je opisano u drugom poglavlju ovog rada.

Osim navedenog, u pravnom dijelu ove doktorske disertacije provedena je komparativna analiza relevantnih pravnih izvješća u području AI na primjeru sljedećih država: Njemačka, Francuska, UK, Španjolska, Italija, SAD, Rusija, Kina i Australija. U analizi naglasak je stavljen na etički pristup navedenih država u području AI te regulacije u pogledu autonomnih vozila i LAWS. Razvidno je kako države u određenoj fazi testiraju ili su u pripremi za testiranje autonomnih vozila na svojim prometnicama. Etičke smjernice usko su vezane za preporuke HLEG-a, dok je ujednačen stav oko primjene LAWS-a, odnosno države su ujedinjene protiv primjene AI u smrtonosnim oružjima. Uz navedenu analizu, provedeno je i anketno ispitivanje eksperata u području AI koji su kontaktirani u cilju dobivanja odgovora na određena pitanja i ispitivanja stavova osoba iz struke (eksperti). Anketa je provedena uz pomoć Hrvatske udruge za umjetnu inteligenciju (CroAI), odnosno anketni upitnik je poslan isključivo članovima CroAI-a. Prilikom obrade podataka pristiglo je 89 odgovorenih upitnika od 202 člana CroAI u vrijeme provođenja ankete. Kako bi se stekao uvid u pouzdanost odgovora dobivenih provedenom anketom sa statističkog aspekta provedena je analiza koristeći *Cronbach's Alpha* (α) metodu i faktorsku analizu unutar *IBM SPSS Statistics* softvera. Sukladno validiranim metodama određena je skala pouzdanosti odgovora koja je vidljiva u tablici 7-1.[1040]

Tablica 7-1 Pravila za odlučivanje na temelju koeficijenta Cronbach's Alfa

Izvor: http://www.efos.unios.hr/poslovni-informacijski-sustavi/wp-content/uploads/sites/491/2020/07/Dokument-2.pdf

Vrijednost koeficijenta α	**Tumačenje koeficijenta α**
> 0,9	Izvrsno
0,8 – 0,9	Vrlo dobro
0,7 – 0,8	Dobro
0,6 – 0,7	Osrednje
0,5 – 0,6	Loše
< 0,5	Neprihvatljivo

[1040] Više vidi na: http://www.efos.unios.hr/poslovni-informacijski-sustavi/wp-content/uploads/sites/491/2020/07/Dokument-2.pdf , str. 313.

S obzirom na interdisciplinarnost postavljenih pitanja, a u cilju dobivanja realnog koeficijenta pouzdanosti, setovi pitanja su složeni prema podudarnosti odnosno u tri skupa: pravni, društveni i sigurnosni. Dobiveni su sljedeći koeficijenti pouzdanosti čime su zadovoljene pretpostavke o pouzdanim odgovorima kako je vidljivo i u tablici 7-2.

Tablica 7-2 Koeficijent pouzdanosti provedene ankete

Izvor: izradio autor

Vrsta skupa prema setovima pitanja	**Koeficijent pouzdanosti α**
Pravni skup	0,899
Društveni skup	0,675
Sigurnosni skup	0,749

Također, provedena je faktorska analiza setova pitanja gdje je vidljiva pripadnost određenog pitanja određenom setu, odnosno matrica korelacija prema kojoj je ispunjen uvjet determinante koji mora biti veći od 0,0001. Determinanta od 0,024 je vidljiva na slici 7-1.

Correlation Matrix[a]

		pravni_1	pravni_2	pravni_3	drustv_1	drustv_2	drustv_3	drustv_4	sigur_1	sigur_2
Correlation	pravni_1	1,000	,723	,677	,098	-,131	-,135	-,107	-,268	-,423
	pravni_2	,723	1,000	,846	,111	-,080	,000	-,062	-,329	-,417
	pravni_3	,677	,846	1,000	,115	-,150	,000	-,072	-,363	-,447
	drustv_1	,098	,111	,115	1,000	,208	,527	-,077	,099	,046
	drustv_2	-,131	-,080	-,150	,208	1,000	,504	,135	,326	,219
	drustv_3	-,135	,000	,000	,527	,504	1,000	,078	,109	,122
	drustv_4	-,107	-,062	-,072	-,077	,135	,078	1,000	-,008	,066
	sigur_1	-,268	-,329	-,363	,099	,326	,109	-,008	1,000	,623
	sigur_2	-,423	-,417	-,447	,046	,219	,122	,066	,623	1,000
Sig. (1-tailed)	pravni_1		<,001	<,001	,181	,112	,104	,160	,006	<,001
	pravni_2	,000		,000	,152	,228	,500	,285	,001	,000
	pravni_3	,000	,000		,143	,082	,499	,253	,000	,000
	drustv_1	,181	,152	,143		,026	,000	,238	,180	,335
	drustv_2	,112	,228	,082	,026		,000	,105	,001	,020
	drustv_3	,104	,500	,499	,000	,000		,235	,156	,128
	drustv_4	,160	,285	,253	,238	,105	,235		,470	,272
	sigur_1	,006	,001	,000	,180	,001	,156	,470		,000
	sigur_2	,000	,000	,000	,335	,020	,128	,272	,000	

a. Determinant = ,024

Slika 7-1 Matrica korelacija

Izvor: izradio autor

Isto tako, faktorska analiza mora ispuniti određeni set uvjeta kako bi se sa sigurnošću moglo reći da je dobiven koeficijent pouzdanosti uistinu i pouzdan. To se odnosi na *Kaiser-Meyer-Olkin* mjerni instrument adekvatnosti (KMO) i *Bartlettov* test (BaT). Za KMO je sve poviše 0,5 zadovoljavajuće s naglaskom na to da je veći broj uvijek bolji, dok za BaT treba biti < 0,001.[1041] Na slici 7-2 je vidljivo kako su oba uvjeta ispunjena.

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,694
Bartlett's Test of Sphericity	Approx. Chi-Square	308,836
	df	36
	Sig.	<,001

Slika 7-2 KMO i BaT vrijednosti

Izvor: autor

U cilju daljnje deskriptivne analize provedene ankete važno je naglasiti kako su 66,3 % ispitanika muškarci (59 odgovora), a 33,7 % žene (30 odgovora) što je vidljivo na slici 7-3.

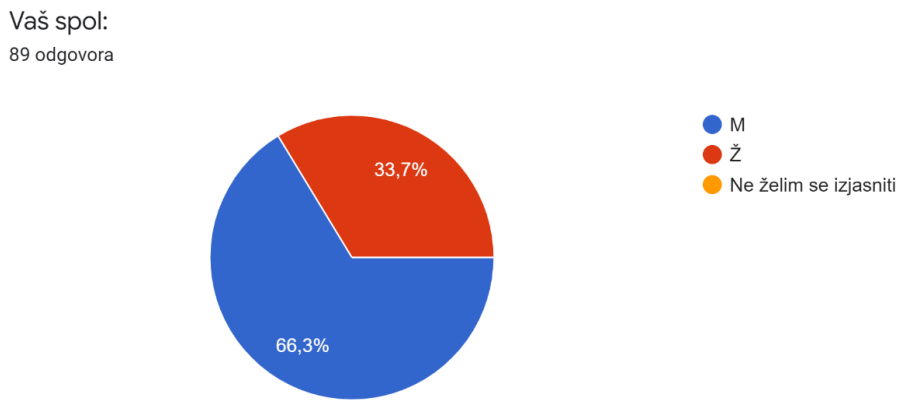

Slika 7-3 Udio odgovora prema spolu,

Izvor: autor

Također, u analizi dobi ispitanika došlo se do sljedećih podataka prikazanih na slici 7-4, gdje je vidljivo da je 90 % ispitanika u dobi između 25 i 45 godina (81 odgovor), a svega 7 odgovora odnosno 7,9 % ispitanika mlađe od 25 godina.

[1041] Grande, T. (2014.) Factor Analysis Using SPSS, dostupno na: https://www.youtube.com/watch?v=pRA3Wapx7fY

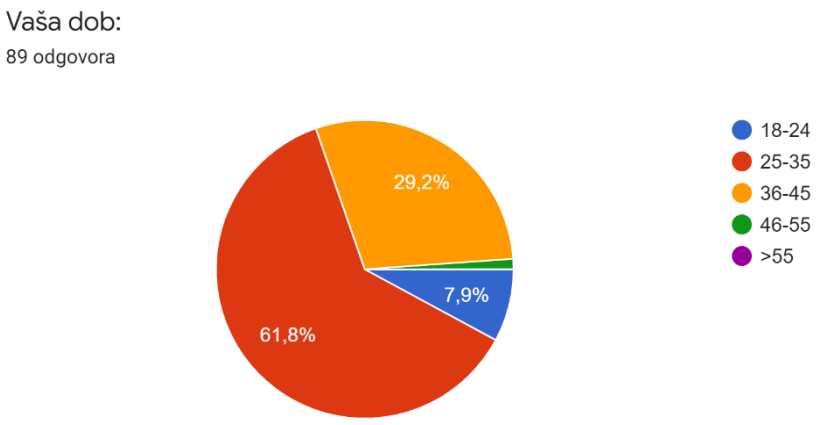

Slika 7-4 Udio odgovora prema dobi,

Izradio: autor

Uz navedeno, pri vrednovanju opće vjerodostojnosti odgovora u obzir su uzeti podaci o potencijalnoj zaposlenosti osobe u IT sektoru kao i radno mjesto u poduzeću. Od 89 ispitanika 78,7 % je zaposleno u IT industriji, a sukladno dobivenim odgovorima radna mjesta su postavljena u dvije skupine: upravljačke pozicije (CEO, CFO, CSO, CTO) i razvojni programeri. Omjer je vidljiv na slici 7-5.

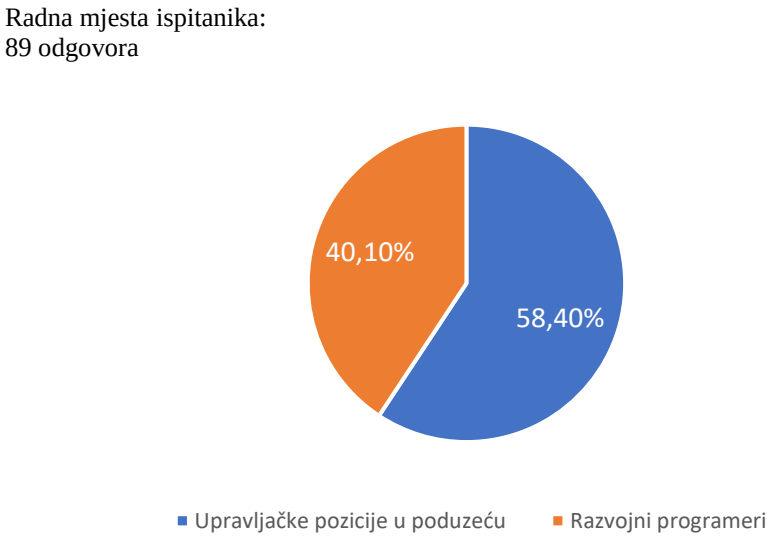

Slika 7-5 Radna mjesta ispitanika

Izradio: autor

Stavovi struke su u suprotnosti s postavljenim pitanjima iz pravnog aspekta. Točnije rečeno, eksperti smatraju da AI nije zadovoljavajuće regulirana u kontekstu opće primjene i to u postotku od 89,7 % što je vidljivo na slici 7-6.

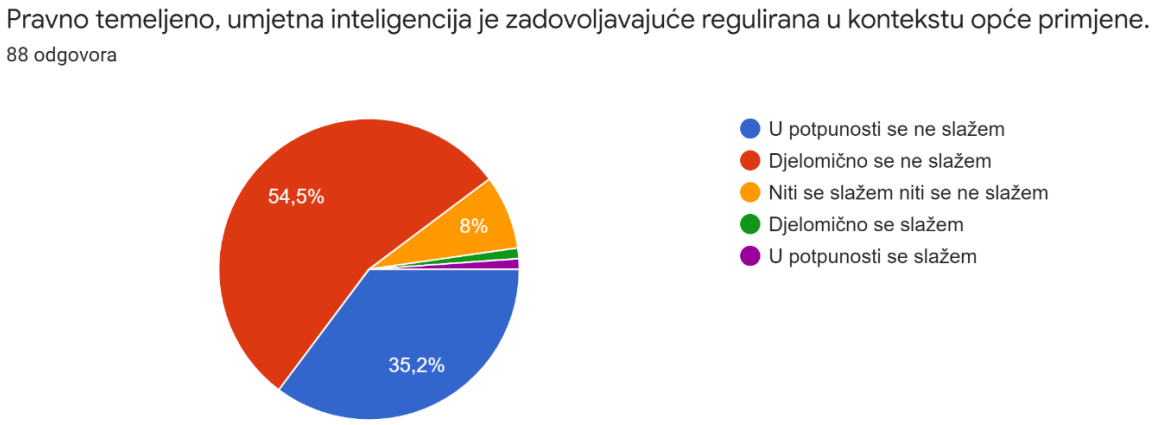

Slika 7-6 AI je zadovoljavajuće pravno regulirana u kontekstu opće primjene

Izvor: izradio autor

Također, kao što je prikazano na slici 7-7, eksperti u području AI smatraju da AI nije zadovoljavajuće pravno regulirana u kontekstu primjene u međunarodnom pomorskom prometu i to u postotku od 79,6 %.

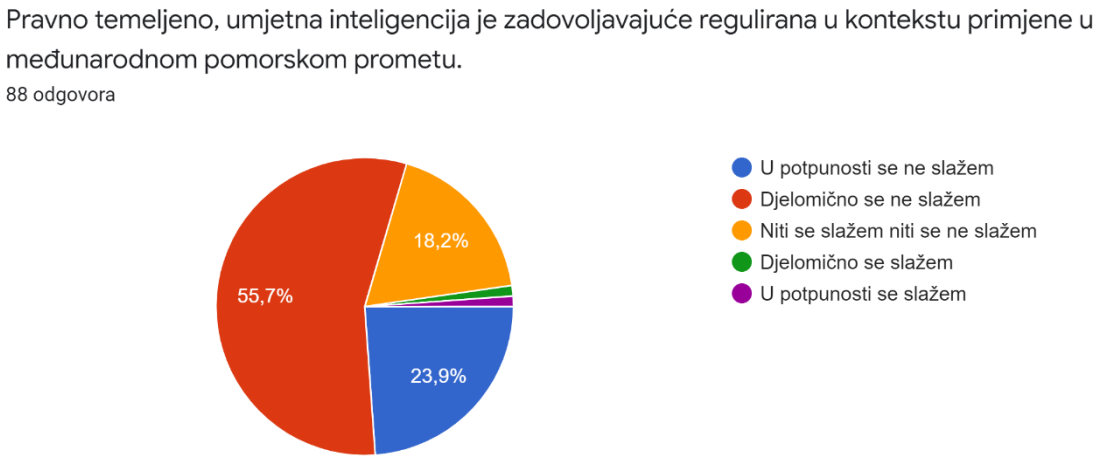

Slika 7-7 AI je zadovoljavajuće pravno regulirana u kontekstu primjene u međunarodnom pomorskom prometu

Izvor: izradio autor

Upitani za stav glede postavljene hipoteze doktorskog rada, a prikazano na slici 7-8, eksperti u području AI su se izjasnili kako pravni okvir za klasifikaciju AI u međunarodnom pomorskom prometu nije ujednačen i to u postotku od 79,6 %.

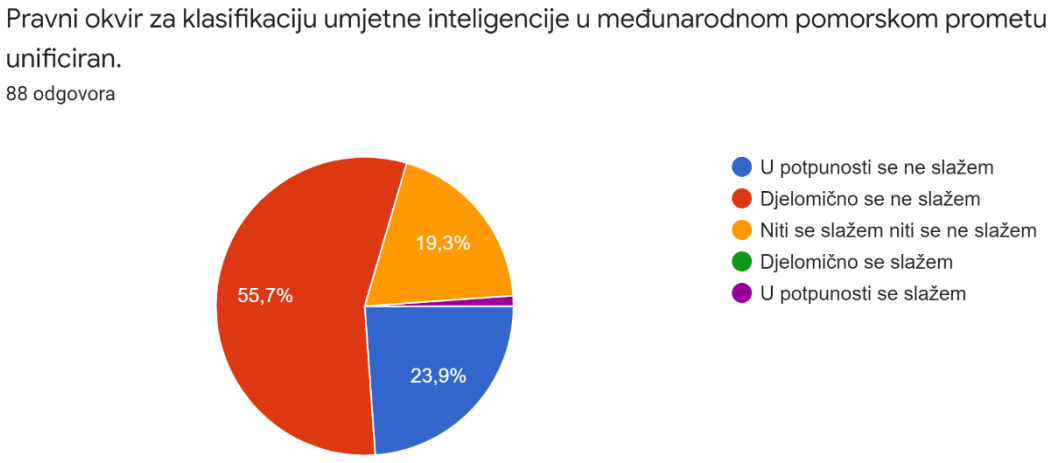

Slika 7-8 Pravni okvir za klasifikaciju AI u međunarodnom pomorskom prometu je unificiran

Izvor: Izradio autor

Sustavi AI imaju interdisciplinarnu, multidisciplinarnu i transdisciplinarnu primjenu. U ovom doktorskom radu posebno je istražena pojavnost i utjecaj AI u društvu.

U procesu društvenog istraživanja AI forenzičnim pristupom definirana je AI u cilju dinamičnosti, odnosno AI se može smatrati dinamičkim sustavom sveukupnosti znanstvenih dostignuća čovječanstva radi njezina razvoja i primjene s ciljem djelomične ili potpune zamjenjivosti sustava čovjek sa sustavom AI. Uz to, važan aspekt društvenih istraživanja su Etičke smjernice za pouzdanu AI. U smjernicama HLEG-a posebno su obrađena načela ljudske autonomije, sprječavanja nastanka štete, pravednosti, objašnjivosti, ljudskog djelovanja i nadzora, tehnička otpornost i sigurnost, transparentnost kao i dobrobit društva i odgovornost. Stavovi ispitanika su analizirani i u pogledu sociološkog aspekta upotrebe AI gdje je ujednačen stav eksperata koji smatraju da sustavi AI mogu imati etička obilježja, odnosno 93,2 % djelomično ili potpuno podržava takav stav što je vidljivo na slici 7-9. Ovakav stav struke može se uzeti u obzir prilikom vrednovanja hipoteze H3, odnosno da primjena sustava AI nužno rezultira etičkim dvojbama. S obzirom na to kako sustavi AI mogu imati etička obilježja za zaključiti je kako će posljedično imati i određene etičke dvojbe u nekoj fazi svoga djelovanja. Na takvu tezu može se pridodati i stav eksperata koji u 83 % odgovora smatraju da AI može u potpunosti zamijeniti čovjeka (slika 7-13) što posjedovanje etičkih obilježja uzročno-posljedično rezultira i etičkim dvojbama.

Slika 7-9 Sustavi AI mogu imati etička obilježja

Izvor: Izradio autor

U pogledu odgovornosti korištenja AI prilikom kvara takvog sustava u međunarodnom pomorskom prometu stav eksperata je ujednačen, odnosno 92 % odgovora usredotočeno je na vrstu kvara kao podlozi za definiranje odgovornosti kao što je prikazano na slici 7-10. Samim time, nužno je odrediti vrstu kvara koji se dogodio na sustavu AI kako bi se odredila odgovornost.

Slika 7-10 Odgovornost u slučaju kvara AI

Izvor: Izradio autor

U tom dijelu važno je istaknuti i odgovore ispitanika u pogledu posjedovanja određenih ovlaštenja u pomorstvu. Naime, poznato je da prilikom upravljanja brodovima čovjek mora imati odgovarajuća ovlaštenja, a 86,4 % ispitanika (76 odgovora) smatra kako bi AI u

budućnosti trebala posjedovati određena tipska odobrenja, tehničke i ostale specifikacije izdane od nadležne regulatorne međunarodne organizacije za AI što je vidljivo na slici 7-11.

Slika 7-11 Nužnost posjedovanja ovlaštenja od strane AI,

Izvor: Izradio autor

Posebna pažnja u izradi ove doktorske disertacije stavljena je na utjecaj AI na svijet poslova u kontekstu pomorskog prometa. Na brodovima tehnologija smanjuje ljudske aktivnosti od strojarnice pa sve do mosta. Međutim, strojevi ili uređaji se još uvijek kvare i traži se uvijek siguran par ljudskih ruku i ljudskog znanja te kreativnosti, ali sveukupna potreba za većim posadama se smanjuje. Budući da je pomorska industrija usko povezana s tehnološkim razvojem, AI i tehnološka revolucija vrlo su važni za ovaj sektor. Inovacija u okruženju Industrije 4.0 odnosi se na konfiguracije međusobno povezanih fizičkih i digitalnih komponenata, sustava i infrastrukture, koje omogućuju stvaranje novih poslovnih modela i pružanje novih pomorskih usluga što zasigurno jamči sigurnost u pomorskom svijetu poslova. U kontekstu opće primjene sustava AI u svijetu poslova eksperti iz područja AI iznijeli su stavove prema kojima će masovna primjena AI značajno utjecati na smanjenje broja radnih mjesta i to u postotku od 87,5 % što je vidljivo na slici 7-12.

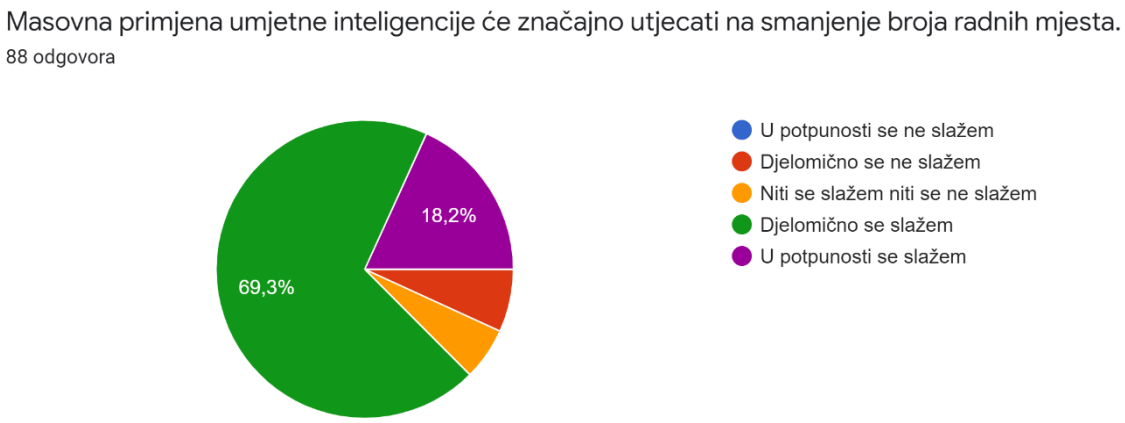

Slika 7-12 Utjecaj AI na smanjenje broja radnih mjesta

Izvor: Izradio autor

Posljedično tome, a prikazano na slici 7-13, mišljenje struke jest da sustavi AI mogu u potpunosti zamijeniti čovjeka i to u postotku od 83 %, odnosno 68 ispitanika se s tom tezom slaže djelomično, a pet u potpunosti.

Slika 7-13 Sustav AI može u potpunosti zamijeniti čovjeka,

Izvor: Izradio autor

Kroz utjecaj AI na društvo posebno su analizirane moralne dileme vezane uz djelovanje autonomnih plovila i značajnih gospodarskih subjekata. Moralne dileme vezane uz autonomna plovila odnosno autonomnu navigaciju možemo u jednom dijelu poistovjetiti sa sustavom odlučivanja takvih plovila, odnosno kako autonomni sustav odlučuje o izbjegavanju ljudskih ozljeda. Pri kreiranju autonomnih sustava mora se uzeti u obzir niz različitih scenarija, uključujući situaciju u kojoj nije moguće pritisnuti kočnice ili promijeniti smjer kretanja broda,

a sustav mora napraviti etičku odluku o tome koga oštetiti, a što će posljedično utjecati na odgovornosti za štetu koja će nastati uporabom autonomnog plovila. Primjena AI na različitim razinama uzrokuje i različite razine moralnih dilema, gdje neke od njih mogu biti potpuno ili djelomično nerješive. U kontekstu etičkih dilema značajnih gospodarskih subjekata važno je predviđanje ekonomskog učinka. Predviđanje ekonomskog učinka AI smatra se neizvjesnim, ali sasvim je sigurno kako će ekonomski utjecaj AI biti relativno velik, uspoređujući se s ostalim tehnologijama opće namjene u povijesti. Međutim, opipljiva produktivnost AI možda neće biti vidljiva odmah, ali će se s vremenom vjerojatno ubrzati pa blagodati početnog ulaganja možda neće biti vidljive u kratkom roku. Zakonodavci i dužnosnici morat će pokazati odlučnost kako bi prevladali razumljivu nelagodu među građanima zbog uočene prijetnje njihovim poslovima prilikom automatizacije istih. Poduzeća trebaju surađivati s vladama na složenom zadatku osposobljavanja ljudi za rad s AI. Jedan od najvećih nedostataka AI može svakako biti gubitak ljudskih poslova i zamjena istih automatiziranim procesima. Upravo tu se postavlja ključno pitanje: što će biti s financijskim sredstvima koja su se ulijevala u državne proračune nauštrb ljudskog rada? S obzirom da je poslodavac za vrijeme radnog odnosa s radnikom uplaćivao određene doprinose na račun i u ime radnike, hoće li to isto raditi i za AI? Po tom pitanju očitovali su se i ispitanici u provedenoj anketi gdje je vidljivo kako dolazi do oprečnih stavova što je i razumljivo s obzirom da ispitanici dolaze iz privatnog sektora gdje svaki dodatni porezni namet može negativno utjecati na njihovo poslovanje. Stavovi su vidljivi na slici 7-14 gdje se 55,7 % ispitanika djelomično ili u potpunosti slaže s dodatnim oporezivanjem, a preostali dio ispitanika ili nije siguran ili se s navedenim ne slaže.

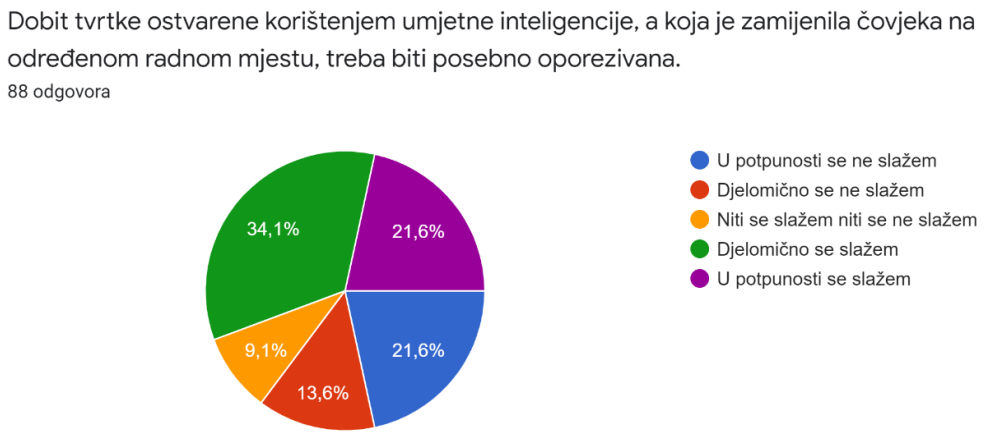

Slika 7-14 Oporezivanje dobiti od AI

Izvor: Izradio autor

Važan dio ove doktorske disertacije jest primjena AI u međunarodnom pomorskom prometu što podrazumijeva sigurnosni aspekt te primjene. Kroz pregled BENU-a stvorio se uvid u podsustave budućeg sustava AI odnosno one uređaje koji sadrže pretpostavke za integraciju u sustav AI. S obzirom da se radi o tehničko - tehnološkim sustavima koji imaju svoje prednosti i nedostatke, određeni su segmenti sigurnosti, a oni se odnose na pouzdanost, popravljivost, raspoloživost i redundanciju. Naglasak je svakako stavljen na element redundancije kao ključni segment sigurnosti u sigurnosnom i tehničkom nadzoru kako podsustava sustava AI tako i sustava AI u cjelini. Iz toga je proizašla i nova metoda određivanja sigurnosti sustava AI koja temeljem broja redundantnih kritičnih podsustava može klasificirati brodove koji koriste AI te povećanjem takvih podsustava možemo utvrditi i veću sigurnost sustava AI. Uz to, postavljena je hipoteza H4, odnosno ugroženost sustava AI u međunarodnom pomorskom prometu može se vrednovati novim metodama. Prilog hipotezi daju i stavovi eksperata u području AI gdje se u 79,5 % odgovora smatra potpuno ili djelomično opravdano određivanje nove metodologije pri vrednovanju sigurnosti sustava AI što je razvidno na slici 7-15. Uz vrednovanje sigurnosti novim metodama važno je imati na umu i ljudski utjecaj u sigurnosti primjene AI. Postavljena je hipoteza H2, odnosno podsustavi sustava AI u određenoj mjeri izloženi humanoidnoj manipulaciji mogu predstavljati dodatnu opasnost u međunarodnom pomorskom prometu. Kao što je vidljivo na slici 7-16 eksperti su se o mogućnosti manipulacije AI od strane čovjeka izjasnili kako je to moguće i to u postotku od 88,6 %. Kako bi se stekao dodatan uvid u stavove eksperata po pitanju sigurnosti primjene AI u međunarodnom pomorskom prometu, ispitanici su upitani koliko sigurnom smatraju primjenu AI na skali od jedan do pet. Dobiveni odgovori očituju se najviše u srednjoj vrijednosti (tri) odnosno 59,1 % (slika 7-17) eksperata se izjasnilo s navedenom vrijednošću što je u uskoj vezi s odgovorima glede manipulacije AI od strane čovjeka i vrednovanjem sigurnosti novim metodama.

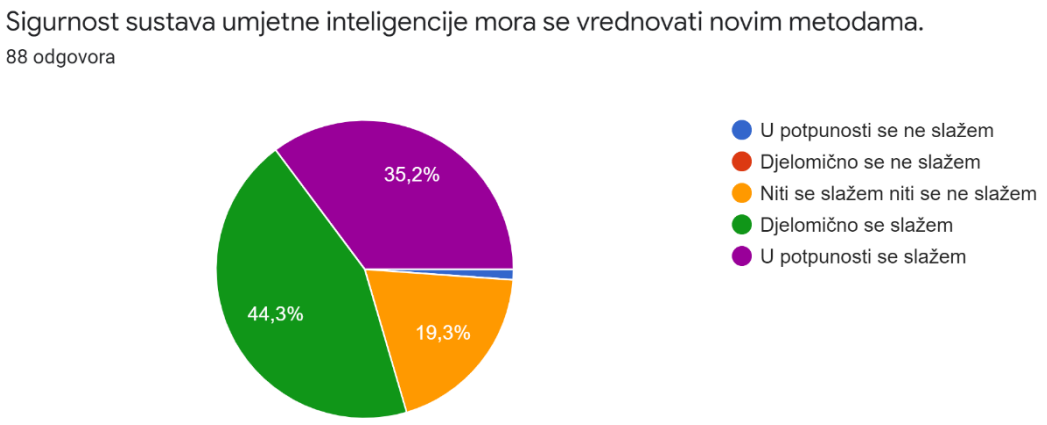

Slika 7-15 Vrednovanje sustava AI novim metodama

Izvor: Izradio autor

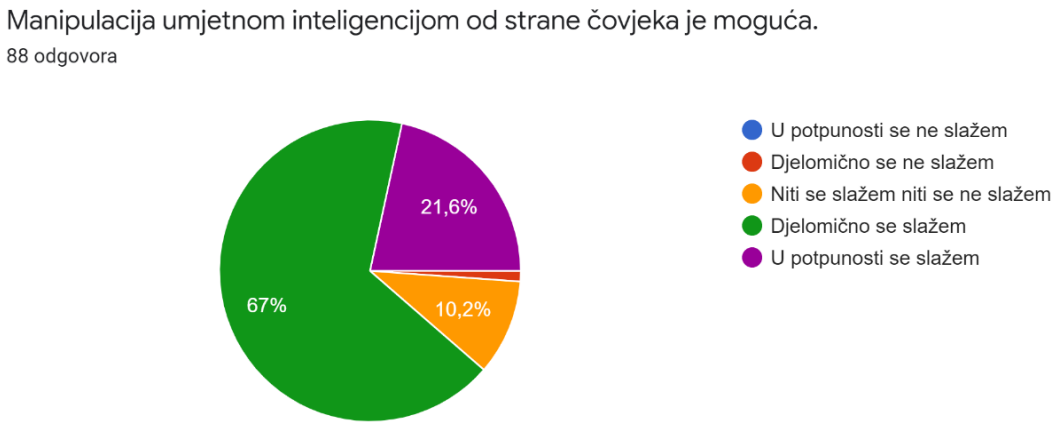

Slika 7-16 Manipulacija AI od strane čovjeka

Izvor: Izradio autor

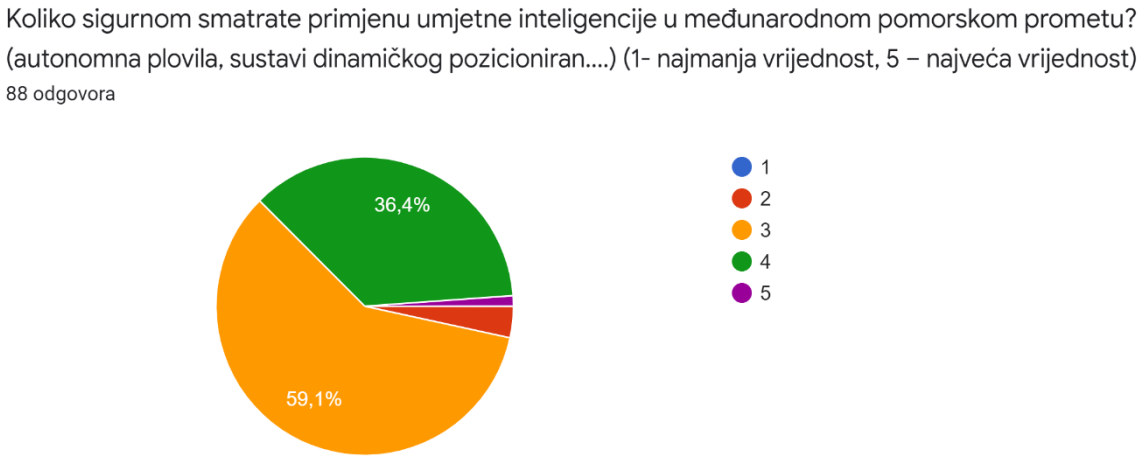

Slika 7-17 Sigurnost primjene AI u međunarodnom pomorskom prometu

Izvor: Izradio autor

U izradi ovog doktorskog rada analiziran je i element trenutne i buduće primjene AI u međunarodnom pomorskom prometu. AI će zajedno s digitalizacijom i povezivanjem biti transformativna i pružit će značajan doprinos konkurentnosti i održivosti pomorske industrije. To se ponajviše odnosi na primjenu autonomnih plovila, digitalnih luka, virtualnih asistenata, jednostavnijom obradom podataka kao i poboljšanjem točnosti obrade podataka, ali i u prihvatljivijem ekološkom pristupu. Naposljetku, sigurnost sustava AI u međunarodnom pomorskom prometu uvelike će ovisiti i o kibernetičkoj sigurnosti odnosno upravljanju potencijalnim rizicima sustava AI. U tom kontekstu veliki značaj će imati potrebni planovi i procedure, identifikacija prijetnji i ranjivosti, tipovi prijetnji i faze izvršavanja, ali i procjene vjerojatnosti napada, procjene utjecaja na sustav i razvoj detekcijskih i mjera zaštite. Svi navedeni elementi nužni su kako bi se potencijalni kibernetički incidenti spriječili ili pravovremeno otklonili. Sukladno navedenom, nužno je uskladiti SMS po pitanju uloge i odgovornosti korisnika, identifikacije rizičnih podsustava nekog sustava, pravovremeno provoditi sve nužne mjere zaštite i posjedovati ažurirani plan za nepredviđene slučajeve. S obzirom na to smatra se nužnim osposobiti osobu predloženog naziva (CSSO) koja bi se bavila pitanjima kibernetičke sigurnosti, bilo da je riječ o autonomnim ili brodovima s posadom. Osim toga, važno je i određivanje kritične brodske infrastrukture odnosno kreiranje prioriteta za zaštitu iste u cilju sprječavanja potencijalne ugroze.

8 ZAKLJUČAK

Temelji primjene sustava AI u međunarodnom pomorskom prometu već su postavljeni na određenoj razini. Brodski elektronički navigacijski uređaji se primjenjuju u pomorstvu, a mogu se smatrati dijelom podsustava sustava AI. Međutim, implementacija sustava AI u međunarodnom pomorskom prometu i dalje predstavlja neistraženo područje koje se ovim radom nastojalo znanstveno istražiti. Forenzičnim pristupom analiziranju problema istraživanja odnosno interdisciplinarnim, multidisciplinarnim i transdisciplinarnim pristupom, ova doktorska disertacija može se podijeliti u tri ključne cjeline, a to su pravni, društveni i sigurnosni aspekti primjene AI u međunarodnom pomorskom prometu.

U pogledu hipoteze H1 analizirani su ključni pravni dokumenti iz oblasti međunarodnog pomorskog prometa te je utvrđeno da ne postoji cjeloviti pravni okvir za klasifikaciju sustava AI u međunarodnom pomorskom prometu. Niti jedna od analiziranih konvencija i pravilnika navedenih u radu ne uređuje sustave AI. Budući da će sustav AI u budućnosti djelovati sukladno relevantnim pravnim aktima, u odredbe navedenih konvencija predlaže se implementirati budući dizajn i razvoj sustava AI, posebice jer se očekuje razvoj i primjena AI u međunarodnom pomorskom prometu. Stoga se smatra važnim da nadležne pomorske organizacije prepoznaju očekivanu upotrebu sustava AI te prilagode pravni okvir kako bi se AI mogla uspješno implementirati u cilju osiguranja postizanja sigurne plovidbe u novim uvjetima. Također, analizirana su pravna izvješća u području AI na razini devet država. Analizom je utvrđeno kako države reguliraju AI u tri ključna elementa: autonomna vožnja, Etičke smjernice i LAWS. Osim Australije, nijedna država ne definira upotrebu AI u kontekstu međunarodnog pomorskog prometa, a posebnu pozornost bi tome području trebale posvetiti upravo pomorske zemlje kojima pomorsko gospodarstvo predstavlja bitan udio u ukupnom gospodarstvu. U RH se nacionalna strategija za AI očekivala do kraja 2020., ali do danas još nije objavljena. Uz navedeno, određeni ciljevi ovog rada u vezi su s definiranim hipotezama. Tako se hipoteza H1 povezuje s prvim ciljem navedenim u uvodnom dijelu rada, a tiče se istraživanja pravnih temelja u povezivosti s AI analizom raznih međunarodnih i nacionalnih pravnih propisa. Provedbom takvog pristupa smatra se kako je hipoteza H1 potvrđena uključujući ispitane stavove eksperata u području AI. Naime, 79,6 % ispitanika smatra kako pravni okvir za klasifikaciju sustava AI nije sveobuhvatan. Također, 79,6 % se u potpunosti ili djelomično slaže kako AI nije zadovoljavajuće regulirana u kontekstu primjene u međunarodnom pomorskom prometu te se

89,7 % njih u potpunosti ili djelomično slaže kako AI nije zadovoljavajuće regulirana u kontekstu opće primjene.

U daljnjem istraživanju analizirani su društveni aspekti primjene AI. Samim time postavilo se pitanje definiranja sustava AI što je dovelo do odgovora kako ne postoji jedinstvena globalna definicija, a s forenzičnog aspekta vidljiv je potencijal da se takva jedinstvena definicija AI postavi.

Shodno navedenom, ovim radom se predlaže s polazišta forenzičnih znanosti definirati AI te je navedeno kako se ista može smatrati dinamičkim sustavom sveukupnosti znanstvenih dostignuća čovječanstva radi njezina razvoja i primjene s ciljem djelomične zamjenjivosti sustava čovjek sa sustavom AI. Međutim, slojevitost sustava AI i njezin eksponencijalni razvoj u jednom trenutku će napraviti distinkciju između sustava AI koji najviše koristimo danas (NAI) i sustava za koje se očekuje da će imati svijest, kreativnost i nadljudsku inteligenciju (ASI). Stoga digitalnu super inteligenciju nazivamo istinskom AI te se posebno definira u prijašnjim poglavljima. U društveni aspekt ovog istraživanja mogu se uvrstiti i razna društveno korisna pitanja poput kako zaštititi ljudska prava od AI? U ovom dijelu istraživanja utvrđeno je kako se postojeći pravni okviri moraju ažurirati na način da se riješe sve etičke dvojbe koje mogu proizaći iz primjene AI. Uspješnost takvih pravnih regulacija zahtijevat će napor u educiranju dionika tog procesa i šire populacije o načinu rada sustava AI. U tom smislu naglasak se stavlja na temeljna ljudska prava poput prava na pravično suđenje, slobodu govora, zabranu diskriminacije, pristup javnim uslugama i sl. Sukladno navedenom, ključan element u izradi kvalitetnog pravnog okvira primjene AI je definiranje odgovornosti njezine upotrebe u društvu. Primjerice, u ispitivanju eksperata u području AI 92 % se izjasnilo da odgovornost ovisi o vrsti kvara koja se dogodila sustavu AI što nudi svojevrsni temelj u izradi buduće zakonodavne regulative. Uz navedeno, etičke norme za pouzdanu AI predstavljaju povjerenje u socioekonomsku okolinu unutar koje su integrirane. Načelo ljudske autonomije, sprječavanje nastanka štete, načelo pravednosti i objašnjivosti, tehnička otpornost i sigurnost, nadzor, privatnost, transparentnost, raznolikost i odgovornost predstavljaju temelje za postizanje pouzdanosti sustava AI kroz cijeli niz sektora. Utvrđeno je kako se pouzdanost sustava AI odnosi na tri ključna elementa, tj. zakonitost i poštivanje svih zakona i propisa, zatim etičnost i poštivanje svih etičkih načela i vrijednosti te otpornost u tehničkom i društvenom smislu. U povezivosti definiranih hipoteza s ciljevima ovog rada važno je napomenuti kako je hipoteza H3 u uskoj vezi s prvim ciljem, odnosno etičnost sustava AI je istražena i kroz trenutne pravne

i regulatorne (obvezujuće i neobvezujuće) akte ključnih međunarodnih institucija. S obzirom na navedeno i na naglasak koji se postavlja na etičke smjernice za sustave AI, može se zaključiti kako je hipoteza H3 potvrđena. Uz to, eksperti iz područja AI u 93,2 % odabira smatraju da sustavi AI mogu imati etička obilježja, a napor koje su značajne svjetske institucije uložile u stvaranje etičkog okvira to i potvrđuje. Samim time, za zaključiti je da ako određeni sustav može imati etička obilježja, primjena takvih sustava će rezultirati i etičkim dvojbama. Štoviše, UN je naveo nužnost donošenja hitnog akcijskog plana zbog rizika koje upotreba AI predstavlja u odnosu na ljudska prava ističući strogost zakonodavnih okvira koji moraju biti globalno implementirani.

S društvenog aspekta istraživanja važan je i utjecaj AI u svijetu poslova. U određenim istraživanjima navedenim u ovom radu vidljivo je kako će se značajan broj radnih mjesta izgubiti zbog primjene AI, ali isto tako i da će se približno sličan broj novih radnih mjesta stvoriti, barem kada su u pitanju zemlje razvijenog gospodarstva. S druge strane, države slabijeg ekonomskog statusa i gospodarskog prosperiteta imat će veći nerazmjer između stvorenih i izgubljenih poslova. Kako bi se taj problem riješio važno je educirati postojeće ljudske resurse za poslove koji će se obavljati u koheziji s AI, odnosno AI treba prepustiti poslove koji su opasni za čovjeka te koji su visoko ponavljajući, a ljudsku radnu snagu preusmjeriti na poslove koji uključuju kreativnost, empatiju i nadzor sustava AI. To se odnosi i na poslove u pomorskom gospodarstvu koji također neće biti otporni na trendove automatizacije. U prilog navedenom idu i rezultati ispitivanja eksperata u području AI gdje 83 % smatra da AI može u potpunosti zamijeniti čovjeka, a 87,5 % da će masovna primjena AI utjecati na smanjenje broja radnih mjesta. Uz to, primjena AI imat će utjecaj i na gospodarstvo država, odnosno može se negativno odraziti na BDP posebice uzrokovanjem dodatne nezaposlenosti ljudskog kadra. U tom smislu važno je prilagoditi i porezne sustave država. Naime, ne očekuje se pad poslovanja i prihoda poslovnih subjekata koji koriste sustave AI. Dapače, automatizirani procesi omogućit će brzinu i točnost u proizvodnji i isporuci robe, ali poslodavci u ovom trenutku ne plaćaju doprinose na račun dobiti ostvarene primjenom sustava AI, gdje je nekad taj isti posao obavljao čovjek u čije ime su plaćali određene doprinose. Shodno navedenom, korak u smjeru očuvanja nacionalnih gospodarstava i globalne ekonomije bi trebao definirati nužne namete na dobit ostvarenu primjenom AI na štetu ljudskog rada. U provedenom anketiranju 55,7 % ispitanika se u potpunosti ili djelomično slaže s prethodno navedenom tvrdnjom, a 35,2 % se protivi.

Objašnjivost podijeljenih mišljenja je u tome što ispitanici dolaze iz privatnog sektora te bi takva odluka o oporezivanju išla na njihovu štetu, odnosno umanjila bi im dobit.

Treći dio istraživanja ovog doktorskog rada odnosi se na sigurnosni aspekt AI u međunarodnom pomorskom prometu. Važno je naglasiti kako podsustavi koji će biti dio sustava AI određuju elemente od kojih se sustav AI sastoji a koji stvaraju preduvjet za sigurnu plovidbu. U tom smjeru je navedeno kako su to svi oni podsustavi koji u sebi sadrže programske komponente i oblike programske podrške. To se ponajviše odnosi na BENU koji u plovidbi mjere i koriste različite elemente važne za samu navigaciju. U istraživanju se spoznalo kako su nužni određeni uvjeti u cilju pregleda tehničkih značajki, korištenja i efikasnosti sustava i nadzora. Time su se definirali četiri segmenta sigurnosti, a odnose se na pouzdanost, popravljivost, raspoloživost i redundanciju, slično kao kod sustava DP. Spoznalo se kako u sigurnosnim i kritičnim sustavima koji se nalaze na plovilima, odnosno elektroničkim navigacijskim uređajima i navigacijskim integriranim sustavima, pojedine sustave je nužno duplicirati ili triplicirati. Na taj način zatajenje jednog od podsustava ispravlja pravilan rad ostalih, identičnih podsustava. Samim time, stvara se višestrukost i omogućuje sigurna plovidba unatoč mogućim pogreškama ili zatajenjima nekih od podsustava. Prikazanim modelom određivanja sigurnosti sustava AI za zaključiti je kako se temeljem redundantnih kritičnih podsustava mogu klasificirati plovila koja koriste AI odnosno povećanjem broja takvih podsustava možemo utvrditi i veću sigurnost sustava AI. Stvaranje navedenog modela kao nove metode vrednovanja sigurnosti sustava AI očituje se u povezivosti hipoteza H4 s drugim i trećim ciljem navedenim u uvodnom dijelu rada. Model određivanja sigurnosti sustava AI je novi model i kao takav predstavlja novu metodu vrednovanja ugroženosti sigurnosti sustava AI u međunarodnom pomorskom prometu. Takav model može se smatrati jednim od temelja klasifikacije plovila sa i bez sustava AI, a posljedično i razina sigurnosti tih plovila u plovidbi. Sukladno navedenom, hipoteza H4 se smatra potvrđenom, a u prilog tome ide i stav eksperata u području AI, odnosno 79,5 % ispitanika podupire navedenu hipotezu.

Također, u vrednovanju sigurnosti AI poseban naglasak se mora staviti na kibernetičku sigurnost. Zaključeno je kako je aspekt kibernetičke sigurnosti očitovan ponajviše u pogledu izrade planova i procedura, identifikacije i prijetnji, faza izvršenja, identifikacije ranjivosti, procjene vjerojatnosti, utjecaja i rizika za specifične kibernetičke ugroze kao i razvoj zaštitnih i detekcijskih mjera što uključuje odgovor na prijetnje i otklanjanje istih. S obzirom da je riječ o naprednim računalnim sustavima izloženost humanoidnoj manipulaciji može predstavljati

dodatnu opasnost u međunarodnom pomorskom prometu. Sudionici mogu biti slučajni/nesvjesni, nezadovoljni zaposlenici, kriminalci, oportunisti, pa čak i države, odnosno sponzorirane organizacije ili teroristi. Prema provedenom istraživanju možemo zaključiti kako je hipoteza H2 također potvrđena, čemu u prilog ide i stav eksperata koji podupiru navedenu tezu u 88,6 % slučajeva, a važno je naglasiti kako je navedena hipoteza u uskoj vezi s trećim ciljem ovog rada, odnosno nedostatak vrednovanja i klasifikacije razina sigurnosti kao i mogućih dionika koji bi ugrozili sustav AI izloženih humanoidnoj manipulaciji predstavljaju dodatnu opasnost u međunarodnom pomorskom prometu.

Naposljetku, smatra se nužnim ići u korak s vremenom posebice kada je u pitanju tehnologija. Shodno tome, uvođenjem sustava AI na plovila potrebno je obučiti kadar u pogledu kibernetičke sigurnosti, odnosno imati brodskog časnika zaduženog isključivo za kibernetičku sigurnost broda, odnosno sustava i podsustava AI.

Može se zaključiti da znanstveni doprinos ove disertacije obuhvaća teorijski i aplikativni dio. Teorijski znanstveni doprinos ove disertacije odnosi se na činjenicu kako se prvi put provelo interdisciplinarno, multidisciplinarno i transdisciplinarno istraživanje pitanje primjene AI u međunarodnom pomorskom prometu s naglaskom na sigurnost sustava same AI čime se omogućio razvoj temeljnih znanstveno utvrđenih načina iskoristivih u istraživanjima pouzdanosti, popravljivosti, raspoloživosti i redundancije bilo kojeg sustava AI s primjenom u međunarodnom pomorskom prometu. Može se opravdano tvrditi da rezultati provedenih znanstvenih istraživanja u ovoj doktorskoj disertaciji omogućuju primjenu razvijene i korištene metodologije vrednovanja sustava AI s pravnog i društvenog aspekta u međunarodnom pomorskom prometu što dijelom predstavlja teorijski, a dijelom praktični znanstveni doprinos. Izravna primjena rezultata znanstvenog istraživanja odnosi se na mogućnost primjene modela poboljšanja postojećih sustava. Općenito se može zaključiti kako su sukladno relevantnim izvorima sva dosadašnja istraživanja relativno parcijalno provedena. Vidljivo je kako se u istraživanju sustava AI istraživači uglavnom drže postulata određenog znanstvenog područja, tj. područja u kojem istraživač znanstveno djeluje. Takav pristup u istraživanju svakako ne umanjuje ostvarena postignuća, ali valja napomenuti kako i dalje nedostaje cjeloviti pristup proučavanja sustava AI u svim interakcijama kako unutar sustava tako i s okolinom sustava. Dakle, ne primjećuje se sustavni pristup u razvoju i primjeni sustava AI. Primijenjena metodologija forenzičnih znanosti u sveobuhvatnoj analizi problematike ove disertacije

upućuje na korisnost uravnotežene primjene iste što se zaključuje iz postignutog znanstvenog doprinosa ovog istraživanja.

Uz navedeno, važno je naglasiti kako su u provedbi istraživanja ove doktorske disertacije uočena određena ograničenja. Prema dostupnim materijalima takva se ograničenja odnose ponajviše na manjak stručne literature kada je u pitanju primjena sustava AI u međunarodnom pomorskom prometu. Uz to, kao ograničenje može se smatrati i trenutna, ali i buduća nezavisna proizvodnja sustava AI, odnosno možebitni scenarij gdje će različite države različito konstruirati i proizvoditi AI što može značajno utjecati na sigurnu primjenu iste. U tom pogledu rastuću ulogu može imati poslovna inteligencija koja bi taj nerazmjer mogla smanjiti. Uz proizvodnju različitih sustava AI kroz različite države i kulture za predvidjeti je i povećanje broja različitih proizvođača unutar tržišnog sektora gdje je kao nedostatak uočena nedostupnost informacija. Također, raznovrsna i djelomično nepostojeća pravna regulativa kao i nedostatna cjelovita istraživanja o utjecaju AI na etička i društvena pitanja predstavljaju značaj nedostatak u stvaranju zdravih temelja kreiranja sustava AI. Nepostojanje povratnih informacija o različitim područjima nenadzirane primjene sustava AI jednako tako predstavlja nedostatak u ovom istraživanju stoga se opravdano pretpostavlja postojanje skrivenih, podešenih, minimaliziranih i netočnih izvještavanja o stvarnim vrijednostima ispitivanja povezanih s elementima sigurnosti (pouzdanost, popravljivost, raspoloživost, redundancija) uz razvidnu neinformiranost i neznanje konstruktora sustava AI. U tom pogledu predlaže se cjeloviti pristup sagledavanju sustava AI definiranim u ovoj disertaciji.

Sukladno navedenim ograničenjima vidljivi su određeni elementi kojima se mogu formirati smjernice za daljnja istraživanja posebice u aspektima definiranja cjelovitih normi proizvodnje sustava AI. U tom kontekstu posebnu pažnju treba obratiti na definiranje i uvođenje obveznih sustava standarda kvalitete kako bi sustav proizvodnje i testiranja AI bio ujednačen. Iz toga proizlazi i obveza o izmjeni kritičnih informacija o proizvodnji AI na primjeru prava na pristup informacijama, odnosno minimalnih podataka koji se moraju omogućiti proizvođačima s proizvodnim poteškoćama, a da se pritom ne ometa vlastita proizvodnja i intelektualno vlasništvo.

Važna smjernica za daljnja istraživanja tiče se i nastavka razvijanja i ujednačavanja pravne regulative kroz relevantne međunarodne organizacije kao i stvaranja baze podataka o vrstama konačnih proizvoda sustava AI po zemljama i gospodarskim sektorima. Na sadašnjoj razini razvoja i implementacije sustava primjećuje se izrazita dinamičnost sustava. Zato se predlaže

pojačati napore IMO-a u daljnjim istraživanjima problematike primjene AI u međunarodnom pomorskom prometu. Daljnja istraživanja trebala bi se odnositi na nova područja povezana s AI sukladno stalnom razvoju tehnike i tehnologije u cilju izlučivanja elemenata bitnih za sam sustav AI. Prikazani rezultati istraživanja ove doktorske disertacije bi u tom smislu pokazali svoju korisnost, a nakon omogućavanja razvoja pri IMO-u, prilagođena i usuglašena primjena postignutih rezultata istraživanja ove disertacije bi izravno doprinijela poboljšanju razine sigurnosti plovidbe. Posebnu pažnju potrebno je posvetiti i razvijanju ključnih tečajeva vezanih za proces stvaranja sustava AI koristeći interdisciplinaran, multidisciplinaran i transdisciplinaran pristup vidljiv iz ove disertacije.

LITERATURA

Knjige, udžbenici, znanstveni članci

1. Acemoglu, D., Restrepo, P. (2017). Low-skill and high- skill automation, NBER
2. Adams, S., Arel, I., Bach, J., Coop, R., Furlan, R., Goertzel, B., Storrs Hall, J., Samsonovich, A., Scheutz, M., Schlesinger, M., Shapiro, S. C., Sowa, J. (2012). Mapping the Landscape of Human-Level Artificial General Intelligence, AI Magazine. 33 (1), dostupno na: doi:10.1609/aimag.v33i1.2322
3. Adibi J. (2020). What is (Real) Artificial Intelligence, dostupno na: https://thenewstack.io/what-is-real-artificial-intelligence
4. Albrecht, S.V., Stone, P. (2018). Autonomous Agents Modelling Other Agents: A Comprehensive Survey and Open Problems. Artificial Intelligence, Vol. 258, dostupno na: https://doi.org/10.1016/j.artint.2018.01.002
5. Alexander, L., Black, L. J. (1993). ECDIS: The wave of the future, Sea Technology, United States, 34(3)
6. Almseidin, M., Alzubi, M., Kovacs, S., Alkasassbeh, M. (2017). Evaluation of machine learning algorithms for intrusion detection system, 2017 IEEE 15th International Symposium on Intelligent Systems and Informatics (SISY), IEEE
7. Amižić Jelovčić, P. (2012). Mjere suzbijanja piratstva u Adenskom zaljevu, Zbornik radova drugog znanstveno stručnog skupa "In memoriam prof. dr. sc. Vjekoslav Šmid" / Buklijaš, Boris (ur.), Pravni fakultet Sveučilišta u Splitu
8. Amižić Jelovčić, P., Primorac, Ž., Mandić, N. (2017). Obalna straža Republike Hrvatske, Pravni fakultet Sveučilišta u Splitu
9. Anderson, M. (2017). After 75 years, Isaac Asimov’s Three Laws of Robotics need updating, The Conversation
10. Anderson, M., Anderson, S. L. (2007). Machine Ethics: Creating an Ethical Intelligent Agent, AI Magazine 28 (4)
11. Anderson, S. L. (2008). Asimov’s “three laws of robotics” and machine metaethics, AI & Society, 22(4)
12. Anderson, S. L. (2011). The Unacceptability of Asimov's Three Laws of Robotics as a Basis for Machine Ethics, Cambridge University Press

13. Andreessen, M. (2011). Why Software Is Eating The World, Wall Street Journal, dostupno na: http://www.wsj.com/articles/SB10001424053111903480904576512250915629460
14. Angwin, J., Mattu, S., Kirchner, L. (2016). Machine Bias: There's Software Used Across the Country to Predict Future Criminals. And It's Biased Against Blacks, ProPublica, dostupno na: https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing
15. Anthony, M., Bartlett, P. L. (2009). Neural network learning: Theoretical foundations, Cambridge University Press
16. Antolini, A. (2018). Maritime Issues – Autonomous ships: IMO MSC's steps forward on revising international regulations for including maritime autonomous surface ships (MASS), Japan Transport and Tourism Research Institute
17. Ayed, A. B., Halima, M. B., Alimi, A. M. (2015). Big Data Analytics for Logistics and Transportation, 4th IEEE International Conference on Advanced logistics and Transport
18. Baker, A.E. (1932). New English Dictionary, Odhams
19. Balani, N. (2019). Responsible And Ethical AI - Building Explainable Model, Medium
20. Balkin, R. (2006). The International Maritime Organization and Maritime Security. Tul. Mar. LJ, 30, 1.
21. Barić Punda, V., Rudolf, D. (2007). Rješavanje sporova u međunarodnom pravu mora - dokumenti, sudska praksa, mišljenja znanstvenika, komentari, Pravni fakultet u Splitu
22. Barton, S. (2016). AI predicts outcomes of human rights trials, The University of Sheffield, dostupno na: https://www.sheffield.ac.uk/news/nr/artificial-intelligence-predicts-outcomes-human-rights-trials-study-1.656915
23. Beioley, K. (2019). Robots and AI Threaten to Mediate Disputes Better Than Lawyers, Financial Times
24. Belić, J. (2005). Model sedimenta na dnu Prošćanskog jezera, Sveučilište u Zagrebu, Geodetski fakultet, diplomski rad
25. Bellman, R. (1978). An Introduction to Artificial Intelligence, Boyd & Fraser Publishing Company
26. Bellone, M., Lundh, M., Wahde, M., MacKinnon, S. (2019). Electrification and Automation in Maritime Applications: Employing AI Techniques for Energy Optimization and Efficiency. IEEE Electrification Magazine, 7(4),

27. Bendett, S. (2018). Here's How the Russian Military Is Organizing to Develop AI, DEFENSE ONE, dostupno na: https://www.defenseone.com/ideas/2018/07/russian-militarys-ai-development-roadmap/149900/
28. Berlucchi, M. et.al. (2016). Artificial Intelligence in the real world: The business case takes shape, The Economist Intelligence Unit Limited
29. Bessi, A., Ferrara, E. (2016). Social bots distort the 2016 U.S. Presidential election online discussion, FIRST MONDAY, Volume 21, No 11, dostupno na: http://journals.AIc.edu/ojs/index.php/fm/article/view/7090/5653
30. Bevanda, M. (2006). Odgovornost za štetu izazvanu neispravnim proizvodom u hrvatskom i bosanskohercegovačkom pravu, Zbornik Pravnog fakulteta Sveučilišta u Rijeci, Vol. 28, No. 1
31. Bhatti, B. (2018). AI Policy Making Part 4: A Primer On Fair and Responsible ML and AI, Medium
32. Bhowmik, S. (2019). Life Extension of Offshore Structure Using Machine Learning, Offshore Technology Conference Brasil, Rio de Janeiro, Brazil, doi: https://doi.org/10.4043/29759-MS
33. Bichou, K. (2009). Port operations, planning and logistics, Informa Law from Routledge
34. Bielić, T., Mandžuka, S., Tomas, V. (2011). Model of ship management in emergencies. Promet – Traffic&Transportation, Vol 23
35. Boban, M. (2018). Zaštita osobnih podataka i nova EU uredba o zaštiti podataka, Bilten Hrvatskog društva za medicinsku informatiku
36. Bobrow, D. G. (1964). Natural Language Input for a Computer Problem Solving System, AI Technical Reports (1964 - 2004), dostupno na: https://dspace.mit.edu/handle/1721.1/6903
37. Bolanča, D. (1999). Pomorsko pravo (odabrane teme). Sveučilište u Splitu, Pravni fakultet
38. Bolanča, D., Luttenberger, A. (1995). Some views in the Croatian Maritime Code, Zbornik radova Pravnog fakulteta u Splitu, 32
39. Bonaccorso, G. (2017). Machine learning algorithms, Packt Publishing Ltd.

40. Bond, R. M., Fariss, C. J., Jones, J. J., Kramer, A. D. I., Marlow, C., Settle, J. E., James, H. (2012). A 61-Million-Person Experiment in Social Influence and Political Mobilization, Nature 489(7415)
41. Bostrom, N. (1998). How long before superintelligence?, University of Oxford
42. Botoroeva, E. (2018). There Will Be 11 Million Driverless Cars in Russia in 25 Years, PARLAMENTSKAIA GAZETA, dostupno na: https://www.pnp.ru/social/v- rossii-cherez-25-let-budet-11-mln-bespilotnykh-avto-schitayut-v-rosstandarte.html
43. Bozdag, E. (2013). Bias in Algorithmic Filtering and Personalization, Ethics and Information Technology 15(3),
44. Brachman, R., Gilbert, V., Levesque, H. (1985). An essential hybrid reasoning system: knowledge and symbol level accounts of KRYPTON, in: Proceedings HCAI-85, Los Angeles, CA
45. Brighton, H., Selina, H. (2007). Introducing Artificial Intelligence, Icon Books
46. Bringsjord, S., Govindarajulu, N. A. (2020). Artificial Intelligence, The Stanford Encyclopedia of Philosophy Archive, dostupno na: https://plato.stanford.edu/archives/sum2020/entries/artificial-intelligence
47. Britannica. T. Editors of Encyclopaedia (2021). John Harrison. Encyclopedia Britannica, dostupno na: https://www.britannica.com/biography/John-Harrison-British-horologist
48. Brooks, R. A. (1986). Achieving Artificial Intelligence through BAIlding Robots, Massachusetts Inst Of Tech Cambridge Artificial Intelligence Lab.
49. Brooks, R. A. (1991). Intelligence without representation. Artificial intelligence, 47(1-3)
50. Brown, R. H., Winston, P. H. (1984). Artificial intelligence, an MIT perspective, MIT Press
51. Bucher, T. (2016). The Algorithmic Imaginary: Exploring the Ordinary Affects of Facebook Algorithms, Information, Communication & Society
52. Bughin, J., Hazan, E., Ramaswamy, S., Chai, M., Allas, T., Dahistrom, P., Henke, N., Trench, M. (2017). Artificial Intelligence: The next digital frontier?, McKinsey Global Insitute
53. Bughin, J., LaBerge, L., Mellbye, A. (2017). The case for digital reinvention, McKinsey Quarterly

54. Bughin, J., Seong, J., Manyika, J., Chui, M., Joshi, R. (2018). Notes from the AI frontier: Modeling the impact of AI on the world economy, McKinsey Global Institute, dostupno na: https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-modeling-the-impact-of-ai-on-the-world-economy
55. Buhovac, M., Pilić, M., Jukić, S. (2020). Criminal law aspects of piracy at sea according to the UNCLOS with reference to the Croatian legal system, Pomorstvo : scientific journal of maritime research, 34, 2, str. 282-290, doi:10.31217/p.34.2.9
56. Bull, L. (1999). On model-based evolutionary computation, Soft Computing 3
57. Buni, C., Chemaly, C. (2016). The Secret Rules of the Internet, The Verge, dostupno na: http://www.theverge.com/2016/4/13/11387934/internet-moderator-history-youtube- facebook-reddit-censorship-free-speech
58. Burgin, M., Dodig-Crnkovic, G. (2009). A systematic approach to artificial agents, Cornell University
59. Burns, M. G. (2018). Port management and operations, CRC Press
60. Callís Oliver, L. M. (2018). SOLAS Convention: Safety on Bord, Bachelor's thesis, Universitat Politècnica de Catalunya
61. Calo, R. (2019). How New A.I. Is Making the Law's Definition of Hacking Obsolete, OneZero
62. Cantor, G. (1897). Beiträge zur Begründung der transfiniten Mengenlehre (2), Mathematische Annalen. 49 (2)
63. Carter, M. (2007). Minds and Computers: An Introduction to the Philosophy of Artificial Intelligence Edinburgh University Press
64. Castrounis, A. AI, Deep Learning, and Neural Networks Explained, Innoarchitech, dostupno na: https://www.innoarchitech.com/blog/artificial-intelligence-deep-learning-neural-networks-explained
65. Chang, H. S., Fu, M. C., Hu, J., Marcus, S. I. (2016). Google deep mind's alphago, OR/MS Today, 43(5),
66. Charniak, E., McDermott, D., McDermott, D. V. (1985). Introduction to Artificial Intelligence, Adisson Wesley
67. Chase, C. (2015). Surviving AI: The promise and peril of artificial intelligence, Kindle Edition

68. Chatzipanagiotis, M., Leloudas, G. (2020). Automated vehicles and third-party liability: A European perspective, Journal of Law, Technology & Policy, Vol. 2020
69. Chen, M., Mao, S. and Liu, Y. (2016). Big data: A survey, Mobile Networks and Applications 19(2)
70. Cherry, K. (2020). How Many Neurons Are in the Brain?, Very well mind, dostupno na: https://www.verywellmind.com/how-many-neurons-are-in-the-brain-2794889
71. Cherry, K. (2020). Neurons and Their Role in the Nervous System, Very well mind, dostupno na: https://www.verywellmind.com/what-is-a-neuron-2794890
72. Chouard, T. (2016). The Go Files: AI computer wins first match against master Go player, Nature News
73. Chowdhury, M., Sadek, A. W. (2012). Advantages and limitations of artificial intelligence, Artificial intelligence applications to critical transportation issues, 6(3)
74. Chu, J. (2016). Driverless platoons, MIT news, dostupno na: http://news.mit.edu/2016/driverless-truck-platoons-save-time-fuel-1221
75. Chui, M., Manyika, J., Schwartz, D. (2018). The real-world potential and limitations of artificial intelligence, The McKinsey Quarterly
76. Cicek, K., Akyuz, E., Celik, M. (2019). Future skills requirements analysis in maritime industry, Procedia Computer Science, 158
77. Clark, G., Hancock, M., Hall, W., Pesenti, J. (2018). Industrial Strategy Artificial Intelligence Sector Deal, HM Government, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/702810/180425_BEIS_AI_Sector_Deal__4_.pdf
78. Clay, K. (2012). Is Microsoft Spying On SkyDrive Users? Forbes, dostupno na: https://www.forbes.com/sites/kellyclay/2012/07/19/is-microsoft-spying-on-skydrive-users/?sh=206f86b2339c2016 (http://www.forbes.com/sites/kellyclay/2012/07/19/is-microsoft-spying-onskydrive-users/)
79. Copeland, B. J. Artificial Intelligence, Encyclopedia Britannica
80. Corbett-Davies, S., Goel, S. (2018). The Measure and Mismeasure of Fairness: A Critical Review of Fair Machine Learning, dostupno na: https://arxiv.org/pdf/1808.00023.pdf

81. Corea, F. (2018). AI Knowledge Map: how to classify AI technologies, Medium, dostupno na: https://francesco-ai.medium.com/ai-knowledge-map-how-to-classify-ai-technologies-6c073b969020
82. Cortes, C., Vapnik, V. (1995). Support-Vector Networks, Machine Learning, 20
83. Costello, K. (2020). Gartner Predicts the Future of AI Technologies, dostupno na: https://www.gartner.com/smarterwithgartner/gartner-predicts-the-future-of-ai-technologies/
84. Crawford, K., Whittaker, M., Elish, M. C., Barocas, S., Plasek, A., Ferryman, K. (2016). The AI Now Report, The Social and Economic Implications of Artificial Intelligence Technologies in the Near-Term
85. Cui, Y. (2020). Artificial Intelligence and Judicial Modernization, Springer, Shanghai People's Publishing House
86. Dabney, W., Kurth-Nelson, Z., Uchida, N., Starkweather, C. K., Hassabis, D., Munos, R., Botvinick, M. (2020). A distributional code for value in dopamine-based reinforcement learning. Nature, 577(7792)
87. Daly, C. (2019). China's Interest In Autonomous Weapons Cause For Concern?, AI Business, dostupno na: https://aibusiness.com/document.asp?doc_id=760973&site=aibusiness
88. Davenport, T., Loucks, J., Schatsky, S. (2017). Bullish on the Business Value of Cognitive. Deloitte, dostupno na: www2.deloitte.com/us/en/pages/deloitte-analytics/articles/cognitive-technology-adoption-survey.html
89. De Chant, T. (2014). The Inevitability of Predicting the Future, NOVA, dostupno na: http://www.pbs.org/wgbh/nova/next/tech/predicting-the-future/
90. Defense Primer: U.S. Policy on LAWS, dostupno na: https://fas.org/sgp/crs/natsec/IF11150.pdf
91. Denardis, L. (2012). Hidden Levers of Internet Control, Information, Communication & Society,
92. Deng, I. (2019). People need to wake up to dangers of AI, warns Google ethics adviser, South China Morning Post, dostupno na: https://www.scmp.com/tech/big-tech/article/3004340/people-need-wake-dangers-ai-warns-hong-kong-professor-and-google

93. Deshpande, A., Kumar, M. (2018). Artificial Intelligence for Big Dana, Complete guide to automating Big Data solutions using Artificial Intelligence techniques
94. Devlin, J., Chang, M. W., Lee, K., Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, Association for Computational Linguistics, dostupno na: https://arxiv.org/pdf/1810.04805.pdf
95. Diakopoulos, N. (2015). Algorithmic Accountability, Digital Journalism 3(3)
96. Dibble, M. (2020). Machine Learning Models Explained to a Five-year-old, Explaining How ML Models Work as Simply as I Can, Towards Data Science
97. Dillet, R. (2018). France Wants to Become an Artificial Intelligence Hub, TECHCRUNCH, dostupno na: https://techcrunch.com/2018/03/29/france-wants-to-become-an-artificial-intelligence-hub/
98. Dobson, J. L. (2010). A comparison between learning style preferences and sex, status, and course performance, Advances in physiology education, 34(4)
99. Dove, M. J., Wright, C. B. (1991). Development of marine autopilots, The National Academics of Sciences, Engineering and Medicine, TRB,
100. Downey, A. (2021). Study to look into how AI could reduce breast cancer diagnosis time, Digital Heatlh, dostupno na: https://www.digitalhealth.net/2021/03/artificial-intelligence-could-reduce-time-to-diagnose-breast-cancer/
101. Dutton, T. (2018). An Overview of National AI Strategies, Medium, dostupno na: https://medium.com/politics-ai/an-overview-of-national-ai-strategies-2a70ec6edfd
102. Dyer, G. M. (1983). In-Depth Understanding – A Computer Model of Integrated Processing for Narrative Comprehension, MIT Press
103. Enns, K. P. (2016). Incarceration Nation How the United States Became the Most Punitive Democracy in the World, Cambridge University Press
104. Ernst, E., Merola, R., Samaan, D. (2018). The economics of artificial intelligence: Implications for the future of work, ILO
105. Europska Komisija. (2018). Artificial Intelligence – A European Perspective, Luxemburg
106. Executive Report, dostupno na: https://www.aiforhumanity.fr/pdfs/MissionVillani_Summary_ENG.pdf

107. Federal Foreign Office (2021).Combating piracy: Germany intends to accede to the Regional Cooperation Agreement on Combating Piracy and Armed Robbery against Ships in Asia, dostupno na: https://www.auswaertiges-amt.de/en/aussenpolitik/regionaleschwerpunkte/asien/recaap-kabinettsbeschluss/2437518
108. Ficco, M., Choras, M., Kozik, R. (2017). Simulation platform for Cyber-Security and Vulnerabillity Analysis of Critical Infrastructures, Journal of Computational Science 22
109. Filjar, R., Kasum, J., Kos, S., Sevrovic, M. (2008). Statistical Properties of Quiet Space Weather Northern Adriatic Residual GPS Ionospheric Delay, Proceedings of NAV08/ILA37 Conference, Westminster, London, Cambridge Press
110. Fingar, P. (2018). Competing For The Future With Intelligent Agents And A Confession, Forbes Sites
111. Finlay, S. (2017). Artificial Intelligence and Machine Learning for Business: A No-Nonsense Guide to Data Driven Technologies, Kindle Edition
112. Ford, M. (2018). Architects of Intelligence: The truth about AI from the people building it, Packt Publishing Ltd
113. Frost, N. A. (2010). Beyond public opinion polls: Punitive public sentiment & criminal justice policy, Sociology Compass, 4(3)
114. Fruhlinger, J. (2018). What is WannaCry ransomware, how does it infect, and who was responsible?, CSO, dostupno na: https://www.csoonline.com/article/3227906/what-is-wannacry-ransomware-how-does-it-infect-and-who-was-responsible.html
115. Gamez, D. (2008). Progress in machine consciousness, Consciousness and cognition, 17(3)
116. Gandomi, A., Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics, International Journal of Information Management
117. Gershgorn, D. (2019). Africa Is Building an A.I. Industry That Doesn’t Look Like Silicon Valley, Medium
118. Ghiassi, M., Saidane, H. (2005). A dynamic architecture for artificial neural networks, Neurocomputing, 63

119. Giannopoulos, G. A. (2004). The application of information and communication technologies in transport, European journal of operational research, 152(2)

120. Gill, K. S. (2016). Artificial super intelligence: beyond rhetoric, Sociology, Computer Science, AI & Society

121. Gillespie, T., Boczkowski, P. J., Foot, K. A. (2014). Media technologies: Essays on communication, materiality, and society, Cambridge Mass, MIT Press

122. Gillham, J., Rimmington, L., Dance, H., Verweij, G., Rao, A., Barnard Roberts, K., Paich, M. (2018). The macroeconomic impact of artificial intelligence, PwC, dostupno na: https://www.pwc.co.uk/economic-services/assets/macroeconomic-impact-of-ai-technical-report-feb-18.pdf

123. Goertzel, B. (2007). Artificial general intelligence (Vol. 2), Springer, New York

124. Goertzel, B., Pennachin, C. (2006). Artificial General Intelligence, Springer

125. Gomes, L. (2015). Facebook AI Director Yann LeCun on His Quest to Unleash Deep Learning and Make Machines Smarter, IEEE, dostupno na: https://spectrum.ieee.org/automaton/artificial-intelligence/machine-learning/facebook-ai-director-yann-lecun-on-deep-learning

126. Goodfellow, I. J., Bengio, Y., Courville, A. (2016). Deep learning, MIT Press

127. Goodfellow, I. J., Pouget Abadie, J., Mehdi, M., Bing, X., Warde Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). Generative Adversarial Networks, Cornell University, dostupno na: https://arxiv.org/abs/1406.2661v1

128. Goodman, B., Flaxman, S. (2016). EU regulations on algorithmic decision-making and a “right to explanation”, ICML workshop on human interpretability in machine learning (WHI 2016), New York, dostupno na: NY. http://arxiv. org/abs/1606.08813 v1.

129. Grabovac, I. (1995). Hrvatsko pomorsko pravo i međunarodne konvencije, Književni krug, Split

130. Graves, A., Fernandez S., Gomez, F., Schmidhuber, J. (2006). Connectionist Temporal Classification: Labelling Unsegmented Sequence Data with Recurrent Neural Networks, Proceedings of the 23 rd International Conference on Machine Learning, Pittsburgh

131. Groves, S. (2012). The Law of the Sea: Costs of U.S. Accession to UNCLOS, dostupno na: https://www.heritage.org/testimony/the-law-the-sea-costs-us-accession-unclos

132. Hall, W., Pesenti, J. (2017). Growing The Artificial Intelligence industry in the UK, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/652097/Growing_the_artificial_intelligence_industry_in_the_UK.pdf

133. Hammond, K. (2015). Practical Artificial Intelligence for dummies, A Wiley Brand

134. Hao, K. (2019). A.I. Is Sending People to Jail — and Getting It Wrong, MIT Technology Review

135. Hao, K. (2019). The Future of AI Is in Africa, MIT Techonlogy Review

136. Hao, K., Stray, J. (2019). Can you make AI fairer than a judge? Play our courtroom algorithm game, MIT

137. Hassoun, M. H. (1995). Fundamentals of artificial neural networks, MIT Press

138. Haugeland, J. (1985). Artificial Intelligence: The Very Idea, Cambridge, MIT Press

139. Heilig, L., Lalla-Ruiz, E., Voß, S. (2017). Digital transformation in maritime ports: analysis and a game theoretic framework, Netnomics: Economic research and electronic networking, 18(2)

140. Henke, N., Bughin, J., Chui, M., Manyika, J., Saleh, T., Wiseman, B., Sethupathy, G. (2016). The age of analytics: Competing in a data-driven world, McKinsey Global Institute

141. Hess, A. (2017). How YouTube's Shifting Algorithms Hurt Independent Media, The New York Times, dostupno na: https://www.nytimes.com/2017/04/17/arts/youtube-broadcasters-algorithm-ads.html?_r=0

142. Hesse, H., Charalambous, N. L. (2004). New security measures for the international shipping community. WMU Journal of Maritime Affairs, 3(2)

143. Hinton, G. E., Osindero, S., Teh, Y. W. (2006). A fast learning algorithm for deep belief nets, Neural Computation, dostupno na: https://www.cs.toronto.edu/~hinton/absps/fastnc.pdf

144. Ho, T. K. (1995). Random decision forests, Proceedings of 3rd International Conference on Document Analysis and Recognition, Montreal, Quebec, Canada, str. 278-282, dostupno na: https://ieeexplore.ieee.org/document/598994

145. Hochreitera, S., Schmidhubera, J. (1997). Long short-term memory, Neural Computation 9(8)

146. Hofmann Wellenhof, B., Lichtenegger, H., Wasle, E. (2007). GNSS–global navigation satellite systems: GPS, GLONASS, Galileo, and more, Springer Science & Business Media

147. Hong N. (2012). UNCLOS and Ocean Dispute Settlement, Law and politics in South China Sea, Routledge, New York

148. Horvitz, E. (2007). Machine learning, reasoning, and intelligence in daily life: Directions and challenges, Proceedings of Artificial Intelligence Techniques for Ambient Intelligence, Hyderabad, India

149. Hoy, M. B. (2018). Alexa, Siri, Cortana, and More: An Introduction to Voice Assistants, Medical Reference Services Quarterly. 37 (1), dostupno na: https://www.tandfonline.com/doi/full/10.1080/02763869.2018.1404391

150. Huang, K., Hussain, A., Wang, Q. F., Zhang, R. (2019). Deep Learning: Fundamentals, Theory and Applications (Vol. 2). Springer

151. Huger, A. (1928). Proportional Damage Rule in Collisions at Sea, Cornell Law Review, Vol. 13,

152. Hutson, M. (2020). Eye-catching advances in some AI fields are not real, Science | AAAS

153. Isaacs, A. (1995). The McMillan Encyclopedia, ISBN: 9780333615768

154. Ivanišević D., Gundić, A., Mohović, Đ. (2018). COLREG in STCW Convention, Pomorski zbornik, Vol. 54 No.1

155. Jakaša, B. (1990). Sistem plovidbenog prava Jugoslavije, četvrta knjiga, plovidbene nezgode, Narodne novine, Zagreb

156. Jaskólski, K., Felski, A., Piskur, P. (2019). The compass error comparison of an onboard standard gyrocompass, fiber-optic gyrocompass (FOG) and satellite compass, Sensors, 19(8)

157. Jeans, N. (2019). Moral Dilemmas of Self-Driving Cars, Medium, dostupno na: https://towardsdatascience.com/moral-dilemmas-of-self-driving-cars-a52a7fb6f13a

158. Jian, D. (2021). Several Important Statements of Zhou Qiang in the Supreme Law Work Report-Finance News, 6Park News, dostupno na: https://6park.news/en/several-important-statements-of-zhou-qiang-in-the-supreme-law-work-report-finance-news.html

159. Jobin, A., Ienca, M., Vayena, E. (2019). Artificial Intelligence: the global landscape of ethics guidelines, Preprint version

160. Jokioinen, E., Cross, B. (2017). Remote and Autonomous Ship- The next steps, dostupno na: http://docplayer.net/19502019-Remote-and-autonomous-ships-the-next-steps.html

161. Joszczuk Januszewska, J. (2012). The benefits of cloud computing in the maritime transport, International Conference on Transport Systems Telematics, Springer, Berlin, Heidelberg

162. Jovanović, S.O. (2018). Izazovi pravnog regulisanja robota i osiguranja od šteta prouzrokovanih njihovom upotrebom, Tokovi osiguranja br. 3/2018

163. Juhl, J. S. (2020). Autonomous ships, BIMCO, dostupno na: https://www.bimco.org/ships-ports-and-voyage-planning/maritime-digitalisation/autonomous-ships

164. Kačić, H. (1968). Naknada štete u slučaju sudara pomorskih brodova, Jugoslavenska akademija znanosti i umjetnosti, Zagreb

165. Kaelbling, L. P., Littman, M. L., Moore, A.W. (1996). Reinforcement Learning; A Survey, Journal of Artificial Intelligence Research 4

166. Kahng, M., Andrews, P. Y., Kalro, A., Chau, D. H. (2017). Activis: Visual exploration of industry-scale deep neural network models, IEEE transactions on visualization and computer graphics, 24(1),

167. Kaplan, A., Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. Business Horizons, *62*(1)

168. Karabatić, A. (2005). Inercijalni sustavi, Ekscentar, (7)

169. Kasabov, N. (1998). Introduction: Hybrid intelligent adaptive systems, International Journal of Intelligent Systems. 13 (6), dostupno na: https://doi.org/10.1002 %2F %28SICI %291098-111X %28199806 %2913 %3A6 %3C453 %3A %3AAID-INT1 %3E3.0.CO %3B2-K

170. Kavallieratos, G., Katsikas, S. (2020). Managing Cyber Security Risks of the Cyber-Enabled Ship, Journal of Marine Science and Engineering, 8(10)

171. Kearns, P. (2020). Here's how Compass uses artificial intelligence to support its agents, Inman, dostupno na: https://www.inman.com/2020/01/29/heres-how-compass-uses-artificial-intelligence-to-support-its-agents/

172. King & Wood Mallesons (2018). China Issues Self-driving Car Road Testing Regulations, China Law Insight, dostupno na: https://www.chinalawinsight.com/2018/04/articles/compliance/china-issues-self-driving-car-road-testing-regulations/

173. Kitchin, R., Dodge, M. (2011). Code/Space Software and Everyday Life, Cambridge, MA, MIT Press

174. Kosmala, K. (2019). Maritime automation will not spare seafarers, dostupno na: https://splash247.com/maritime-automation-will-not-spare-seafarers/

175. Kovač, L. (2015). Umjetna inteligencija danas, Filozofski fakultet Sveučilišta u Rijeci

176. Krause, T., Grassegger, H. Inside Facebook, Süddeutsche Zeitung, dostupno na: http://international.sueddeutsche.de/post/154513473995/inside-facebook

177. Kriegeskorte, N., Golan, T. (2019). Neural network models and deep learning, Current Biology, 29(7)

178. Kruse, C. R., Lindskow, T., Ibrahim, R. M., Thomsen, M. V., Bell, B. (2020). Artificial intelligence in Danish healthcare, Ugeskrift for Laeger, 182(6)

179. Kurzweil, R. (1990). The Age of Intelligent Machines, MIT Press

180. Kurzweil, R. (2000). The Age of Spiritual Machines: When Computers Exceed Human Intelligence, Penguin Putnam

181. Kurzweil, R. (2005). The Singularity is Near: When Humans Transcend Biology, A Penguin Book

182. Lasi, H., Fettke, P., Kemper, H. G., Feld, T., Hoffmann, M. (2014). Industry 4.0., Business & information systems engineering, 6(4),

183. Lauret, J. (2019). Amazon’s sexist AI recruiting tool: how did it go so wrong?, Medium

184. Laurinen, M. (2016). Remote and Autonomous Ships: The next steps. AAWA, Advanced Autonomous Waterborne Applications

185. Lee, K. F. (2020). Top 10 safest jobs from AI, dostupno na: https://kaifulee.medium.com/top-10-safest-jobs-from-ai-1824cacd1954

186. Lee, N. T. (2018). Detecting racial bias in algorithms and machine learning, Journal of Information, Communication and Ethics in Society

187. Levander, O. (2017). Autonomous ships on the high seas, Engineering, IEEE Spectrum

188. Levesque, H. J. (2017). Common sense, the Turing test, and the quest for real AI, MIT Press

189. Loebbecke, C., Picot, A. (2015). Reflections on societal and business model transformation arising from digitization and big data analytics, The Journal of Strategic Information Systems

190. Loebbecke, C., Powell, P. (1998). Competitive advantage from IT in logistics: the integrated transport tracking system, International Journal of Information Management, 18(1)

191. Luger, G. F. (2009). Artificial Intelligence – Structures and Strategies for Complex Problem Solving, 6th Ed., Pearson Education

192. Luse, J. D. (1981). A Brief History of the Use of Marine Radar. Navigation, 28, dostupno na: https://doi.org/10.1002/j.2161-4296.1981.tb00767.x

193. Luttenberger, A. (2008). Pomorsko upravno pravo, Sveučilište u Rijeci, Pomorski fakultet u Rijeci

194. Lytinen, S. L. (1985). Integrating syntax and semantics, Proceedings of the Conference on Theoretical and Methodological Issues in Machine Translation of Natural Languages, Colgate University, Hamilton, New York

195. Madary, M., Metzinger, T. K. (2016). Real Virtuality: A Code of Ethical Conduct. Recommendations for Good Scientific Practice and the Consumers of VR-Technology, Frontiers in Robotics and AI, 3(3),

196. Manyika, J. (2017). 10 imperatives for Europe in the age of AI and automation, McKinsey Global Institute, dostupno na: https://www.mckinsey.com/featured-insights/europe/ten-imperatives-for-europe-in-the-age-of-ai-and-automation

197. Manyika, J., Chui, M., Bughin, J., Dobbs, R., Bisson, P., Marrs, A. (2013). Disruptive technologies: Advances that will transform life, business, and the global economy, McKinsey Global Institute

198. Manyika, J., Lund, S., Chui, M., Bughin, J., Woetzel, J., Batra, P., Ko, R., Sanhvi, S. (2017). Jobs lost, jobs gained: What the future of work will mean for jobs, skills, and wages, McKinesy Global Institute, dostupno na: https://www.mckinsey.com/featured-insights/future-of-work/jobs-lost-jobs-gained-what-the-future-of-work-will-mean-for-jobs-skills-and-wages#

199. Manyika, J., Sneader, K. (2018). AI, automation, and the future of work: Ten things to solve for, McKinsey Global Institute

200. Marr, B. (2019). What Is The Impact Of Artificial Intelligence (AI) On Society?, Intelligent Business Performance, dostupno na: https://bernardmarr.com/default.asp?contentID=1828

201. Marušić, L. (2010). STCW konvencija i bolonjski proces, Metodički ogledi, 17 1-2

202. McBride, J., Chatzky, A. (2019). Is 'Made in China 2025' a Threat to Global Trade?, Council on Foreign Relations, dostupno na: https://www.cfr.org/backgrounder/made-china-2025-threat-global-trade

203. McCarthy, D. R. (2011). Open Networks and the Open Door: American Foreign Policy and the Narration of the Internet, Foreign Policy Analysis 7(1),

204. McCarthy, J. (2007). Basic questions, Stanford, dostupno na: http://www-formal.stanford.edu/jmc/whatisai/node1.html

205. McGoogan, C. (2017). AI Traffic Lights to End Rush Hour Jams in Milton Keynes, THE TELEGRAPH, dostupno na: https://www.telegraph.co.uk/technology/2017/05/15/ai-traffic-lights-end-rush-hour-jams-milton-keynes/

206. McKinsey & Co. (2020). Transforming healthcare with AI: The impact on the workforce and organizations, dostupno na: https://www.mckinsey.com/industries/healthcare-systems-and-services/our-insights/transforming-healthcare-with-ai

207. McKinsey Global Institute (2017). Jobs lost, jobs gained: Workforce transitions in a time of automation

208. Meneceur, Y. (2020). L'intelligence artificielle en procès: Plaidoyer pour une réglementation internationale et européenne, Bruylant

209. Milošević-Pujo, B. (2006). Pomorsko pravo (odabrane teme po STCW konvenciji), Sveučilište u Dubrovniku
210. Minsky, M. (2003). Semantic Information Processing, MIT Press
211. Miranda, I. (2015). Las Fuerzas Armadas Españolas No Tendrán Su Propio «Robot Asesino» ABC, dostupno na: https://www.abc.es/espana/20150831/abci-robots-asesinos-espana-201508301912.html
212. Mitrović, F. (2008). Ekonomika brodarstva, Sveučilište u Splitu, Pomorski fakultet u Splitu, Split
213. Moravec, H. (1988). Mind Children, Harvard University Press
214. Mordica, A. (2008). The Speed Log - History, Construction and Use, The Navy and Marine Living History Association. NMLHA
215. Moreau, J. T., Baillet, S., Dudley, R. W. (2020). Biased intelligence: on the subjectivity of digital objectivity, BMJ Health & Care Informatics, 27(3)
216. Mrčela, M., Vuletić, I. (2018). Kazneno pravo pred izazovima robotike: tko je odgovoran za prometnu nesreću koju je prouzročilo neovisno vozilo?, Zbornik Pravnog fakulteta Sveučilišta u Zagrebu, Vol. 68, No. 3-4
217. Mukherjee, P. K. (2007). The ISM Code and the ISPS Code: A critical legal analysis of two SOLAS regimes, WMU Journal of Maritime affairs, 6(2)
218. Müller, B., The AI landscape in the United Kingdom 9, dostupno na: http://ec.europa.eu/newsroom/dae/document.cfm?doc_id=50824
219. Murgia, M., Shrikanth, S. (2019). How Big Tech Is Struggling With the Ethics of AI, Financial Times
220. Murphy, R., Woods, D. D. (2009). Beyond Asimov: the three laws of responsible robotics, IEEE intelligent systems, 24(4)
221. Nanterme, P., Lexa, C. (2017). Boost your AIQ transformating into an AI business, Accenture
222. Nawrot, J., Vio, I. (2021). Autonomous vessels based on artificial intelligence: selection of regulatory approach – main challenges, 3. Međunarodna znanstvena konferencija pomorskog prava, Split
223. Nemschoff, M. (2014).Why the trasportation Industry is getting on bord with Big Data & Hadoop

224. Netti, E. (2018). Intelligenza Artificiale, Europa Indietro, IL SOLE 24 ORE, dostupno na: https://www.ilsole24ore.com/art/tecnologie/2018-07-10/intelligenza-artificiale-europa-indietro-112436.shtml

225. Newell, A., Shaw, J. C., Simon, H. A. (1959). Report on a General Problem-Solving Program, International Conference on Information Processing, UNESCO House, Paris, France

226. Ng, A.Y., Harada, D., Russell, S. J. (1999). Policy invariance under reward transformations: Theory and application to reward shaping, ICML, vol. 99

227. Ng, L. (2018). On the Potential & Limits of AI — The Facts Beneath the Hype, Medium

228. Nie, S., Liu, L., Du, Y. (2017). Free-fall: Hacking tesla from wireless to can bus, Briefing, Black Hat USA, 25

229. Nilsson, N. J. (1991). Logic and artificial intelligence, Artificial intelligence

230. Nilsson, N. J. (1996). Artificial intelligence: A modern approach, Artificial Intelligence 82 (1–2)

231. Nilsson, N. J. (1998). Artificial Intelligence: A New Synthesis, Stanford University

232. Oboyle, D. (2021). First Circuit Court rejects DOJ Wire Act appeal, IGB, dostupno na: https://www.igbnorthamerica.com/first-circuit-court-rejects-doj-wire-act-appeal/

233. Padgham, L., Winikoff, M. (2005). Developing intelligent agent systems, A practical guide. Vol. 13. John Wiley & Sons

234. Page, J., Bain, M.,Mukhlish, F. (2018.). The risks of low level narrow artificial intelligence. In 2018 IEEE International Conference on Intelligence and Safety for Robotics (ISR), IEEE

235. Pandey, A. K., Gelin, R. (2018). A mass-produced sociable humanoid robot: Pepper: The first machine of its kind, IEEE Robotics & Automation Magazine, *25*(3)

236. Panetta, K. (2017). Top Trends in the Gartner Hype Cycle for Emerging Technologies, Smart with Gartner, dostupno na: https://www.gartner.com/smarterwithgartner/top-trends-in-the-gartner-hype-cycle-for-emerging-technologies-2017/

237. Papović, B.N. (2019). Veštačka inteligencija – skriveni rizici, Tokovi osiguranja

1/2019

238. Parkinson, B., Gromov, K., Stansell, T., Beard, R. (1995). A history of satellite navigation, Proceedings of the 51st Annual Meeting of The Institute of Navigation

239. Pasquale, F. A. (2016). Platform Neutrality: Enhancing Freedom of Expression in Spheres of Private Power, Social Science Research Network, dostupno na: https://papers.ssrn.com/abstract=2779270

240. Patrascu, D. (2019). Video Shows Tesla Model S on Autopilot Hit Highway Concrete Divider, Autoevolution, dostupno na: https://www.autoevolution.com/news/video-shows-tesla-model-s-on-autopilot-hit-highway-concrete-divider-133275.html#

241. Pavić, D. (2003). Pomorske havarije i osiguranje, Split

242. Perović, D., Vukčević, M., Milošević, D. (2005). Poslovna logistika i organizacija suvremenog pomorskog poduzeća, NAŠE MORE: znanstveni časopis za more i pomorstvo, 52(3-4)

243. Perry, W. L. (2013). Predictive Policing: The Role of Crime Forecasting in Law Enforcement Operations. Rand Corporation

244. Perry, W. L., Mclnnis, B., Price, C.C., Smith, C.S., Hollywood, S.J. (2013). Predictive Policing: The Role of Crime Forecasting in Law Enforcement Operations, Rand Corporation

245. Petrić, S. (2001). Odgovornost proizvođača za štete od nedostataka na proizvodu u hrvatskom pravu i pravu Europske unije, Zbornik radova Pravnog fakulteta u Splitu, 4, 64

246. Pietroszek, K. (2007). Providing Language Instructor with Artificial Intelligence Assistant, International Journal of Emerging Technologies in Learning (iJET), Vol 2, No 4

247. Points, L., Potton, E. (2017). Artificial Intelligence and Automation in the UK, UK Parliament

248. Poole, D., Mackworth, A. (2010). Artificial Intelligence: Foundations of Computational Agents, 2nd Edition, Cambridge University Press

249. Poole, D., Mackworth, A. K., Goebel, R. (1998). Computational Intelligence: A Logical Approach, Oxford University Press

250. Porter, M. E., Heppelmann, J. E. (2014). How Smart, Connected Products Are Transforming Competition, Harvard Business Review
251. Prakken, H. (2005). AI & Law, logic and argument schemes, Argumentation, 19(3)
252. Preston, J., Bishop, M. (2002). Views into the Chinese Room: New Essays on Searle and Artificial Intelligence, Oxford University Press
253. Primorac, D. (2007). Kaznena djela protiv sigurnosti pomorskog prometa, Pravni fakultet Sveučilišta u Zagrebu, doktorska disertacija
254. Primorac, Ž. (2016). Effective strategies for detecting fraudulent claims in motor third party liability insurance. In Economic and Social Development (Book of Proceedings), 16th International Scientific Conference on Economic and Social
255. Primorac, Ž. (2020). Suvremeni pravni izazovi smanjenja emisija stakleničkih plinova iz pomorskog prometa-međunarodna i europska perspektiva, Zbornik radova Pravnog fakulteta u Splitu, 57(3)
256. Prows, P. (2006). Tough love: The dramatic birth and looming demise of UNCLOS property law (and what is to be done about it), Tex. Int'l LJ, 42
257. Purdy, M., Daugherty, P. (2016). Why AI is the future of growth, Accenture
258. Purdy, M., Daugherty, P. (2016.) Why Artificial Intelligence is the future of growth, Accenture, dostupno na: https://www.accenture.com/t20170524t055435__w__/ca-en/_acnmedia/pdf-52/accenture-why-ai-is-the-future-of-growth.pdfSimmsad
259. PwC (2017). The economic impact of artificial intelligence on the UK economy, dostupno na: https://www.pwc.co.uk//economic-services/assets/ai-uk-report-v2.pdf
260. PwC (2017). The Impact of Artificial Intelligence on the UK Economy, dostupno na: https://www.pwc.co.uk/economic-services/assets/ai-uk-report-v2.pdf
261. Quanta Magazine (2018). Why AlphaZero's Artificial Intelligence Has Trouble With the Real World
262. Raguž, I. (2019). Razvoj i rad brodskih brzinomjera, Sveučilište u Dubrovniku, Pomorski odjel, završni rad
263. Rasheed, I. (2016). Basics of 5G. Opportunities in 5G Networks, A Research and Development Perspective, 1

264. Rege, M., Yarmoluk, D. (2020). Artificial Intelligence and its impact on jobs, St. Thomas University, dostupno na: https://news.stthomas.edu/artificial-intelligence-and-its-impact-on-jobs/

265. Retto, J. (2017). Sophia, first citizen robot of the world, ResearchGate

266. Rich, E., Knight, K. (1991). Artificial Intelligence, McGraw Hill

267. Rifkind, M. (2014). Report on the Intelligence Relating to the Murder of Fusilier Lee Rigby, The New York Times,

268. Rispal, K. (2018). France and Canada Create New Expert International Panel on Artificial Intelligence, Gouvernement.Fr, dostupno na: https://www.gouvernement.fr/en/france-and-canada-create-new-expert-international-panel-on-artificial-intelligence

269. ROMAS (2018). Remote Operations of Machinery and Automation Systems, DNV, dostupno na: https://www.dnv.com/research/review2018/featured-projects/romas-remote-operations-machinery-automation.html

270. Rong, H., Teixeira, A. P., Guedes Soares, C. (2020). Data mining approach to shipping route characterization and anomaly detection based on AIS data, Ocean Engineering, Volume 198

271. Rosenbach Company (2003). The Sea: Books and Manuscripts on the Art of Navigation, Geography, Naval History, ShipbAIlding, Voyages, Shipwrecks, and Mathematics, Including Atlases and Maps. Storrs-Mansfield, CT: Maurizio Martino Publishers

272. Rosenblat, A., Kneese, T., Boyd, D. (2014). Networked Employment Discrimination, Open Society Foundations, Future of Work Commissioned Research, dostupno na: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2543507

273. Rosenblat, A., Levy, K., Barocas, S., Hwang, T. (2016). Discriminating Tastes: Customer Ratings as Vehicles for Bias, SSRN, dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2858946

274. Ross, W. D. (1953). Aristotle's Metaphysics, vol. 1., Methuen

275. Rowan, P. J. (2005). UNCLOS and Sovereignty in the South China Sea, Asian Survey, Vol. XLV, No. 3

276. Rubinstein, I., Lee, R. D., Schwartz, P. M. (2008). Data Mining and Internet Profiling: Emerging Regulatory and Technological Approaches, Social Science Research Network, dostupno na: http://papers.ssrn.com/abstract=1116728

277. Russell, S. J., Norvig, P. (2003). Artificial Intelligence, A Modern Approach. Second Edition, University of Michigan Press

278. Russell, S. J., Norvig, P. (2016). Artificial Intelligence – A Modern Approach, 3rd Ed., Pearson Education

279. Safety4sea (2019). China successfully tests first autonomous cargo ship, dostupno na: https://safety4sea.com/china-successfully-tests-first-autonomous-cargo-ship/

280. Salamon, T. (2011). Design of Agent-Based Models. Repin, Bruckner Publishing

281. Sandvig, C., Hamilton, K., Langbort, K, C. (2016). When the Algorithm Itself Is a Racist: Diagnosing Ethical Harm in the Basic Components of Software, International Journal of Communication,

282. Sarioglu, O., Muhsin, A. (2018). Lojistik surecte yeni bir uygulama ve sektorun bakisi: akilli konteyner, 2018, dostupno na: http://www.otomasyondergisi.com.tr/arsivlyazi/104-lojistik-surecte-yeni-bir-uygulama-ve-sektorun-bakisiakilli-konteyner

283. Sava, N. (2017). Algorithmic ethics: lessons and limitations for leaders. London School of Business, dostupno na: https://www.london.edu/faculty-and-research/lbsr/algorithmic-ethics-essons-and-limitations-for-business-leaders

284. Savić, I. (2021). Autonomni plovni objekti u pomorskom pravu Republike Hrvatske, 3. Međunarodna znanstvena konferencija pomorskog prava, Split

285. Saygin, A. P., Cicekli, I., Akman, V. (2000). Turing test: 50 years later, Minds and machines, 10(4)

286. Schank, R. C. (1983). Dynamic Memory: A Theory of Reminding and Learning in Computers and People, Cambridge University Press

287. Schröder-Hinrichs, J.U., Song, D.W., Fonseca, T., Lagdami, K., Shi, X. (2019). Transport 2040: Automation, Technology, Employment - The Future of Work, World Maritime University, Malmo, dostupno na: https://safety4sea.com/wp-

content/uploads/2019/01/World-Maritime-University-Transport-2040-Automation-Technology-Employment-The-future-of-work-2019_01.pdf

288. Schulz, W., Dankert, K. (2016). Governance by Things' as a Challenge to Regulation by Law, Internet Policy Review 5(2),

289. Searle, J. R. (1980). Minds, brains, and programs. The Turing Test: Verbal Behaviour as the Hallmark of Intelligence

290. Shanli, T., Jing, W., Wenzheng, W., Xufei, Y. (2019). Construction of Relative Index System for Water Traffic Safety Evaluation [J], Water Transport Management, 41(01)

291. Shapiro, S. C. (1992). Encyclopedia of Artificial Intelligence, Second Edition,

292. Sharma, A. (2016). What is Magnetic Compass, its principle, types and errors, dostupno na: https://marinegyaan.com/what-is-the-magnetic-compass/

293. Shasha D., Lazere C. (2010). Natural computing: DNA, quantum bits, and the future of smart machines, W. W. Norton & Company, Inc.

294. Sherbaz, S., Duan, W. (2012). Operational options for green ships, Journal of Marine Science and Application, 11(3)

295. Shi, Z. (2011). Advanced Artificial Intelligence, World Scientific Publishing Co.

296. Shirado, H., Christakis, N. A. (2017). Locally noisy autonomous agents improve global human coordination in network experiments, Nature. 545 (7654)

297. Sills, A. J. (1970). Automated Data Processing and the Issue of Privacy. Seton Hall Law Review 1

298. Simonite, T. (2019). Algorithms Should've Made Courts More Fair. What Went Wrong?, WIRED, dostupno na: https://www.wired.com/story/algorithms-shouldve-made-courts-more-fair-what-went-wrong/

299. Śniegocki, H., Specht, C., Specht, M. (2014). Testing Accuracy of Maritime DGPS System Based on Long-Term Measurements Campaigns over the Years 2006-2014. International Journal of Civil Engineering and Technology. 5

300. Society of Automotive Engineers. (2018). Taxonomy and definitions for terms related to on-road motor vehicle automated driving systems: J3016_201806

301. Spiekermann, S. (2015). Ethical IT Innovation: A Value-Based System Design Approach. CRC Press

302. Stahl, C. B. (2021). Artificial Intelligence for a better future – An ecosystem perspective on the ethics of AI and emerging digital technologies, Springer

303. Sterne, J. (2017). Artificial Intelligence for Marketing, Wiley

304. Stitt, I. P. A. (2003). The use of VHF in collision avoidance at sea. The Journal of Navigation, 56(1)

305. Stoica, I. et.al. (2017). A Berkeley View of Systems Challenges for AI, Cornell Univeristy, dostupno na: https://arxiv.org/abs/1712.05855

306. Storrs Hall, J. (2007). Beyond AI: Creating the Conscience of the Machine, Prometheus Books,

307. Struhl, S. (2017). Artificial Intelligence Marketing and Predicting Consumer Choice: An Overview of Tools and Techniques, Kindle Edition

308. Suleyman, M. (2018). AI Offers a Unique Opportunity for Social Progress, Medium

309. Svanberg, M., Santén, V., Hörteborn, A., Holm, H., Finnsgård, C. (2019). AIS in Maritime Research, Marine Policy, 106

310. Tam, K., Jones, K. (2018). Cyber-risk assessment for autonomous ships, 2018 International Conference on Cyber Security and Protection of Digital Services (Cyber Security), IEE

311. Tam, K., Moara-Nkwe, K., Jones, K. (2021). The use of cyber ranges in the maritime context: Assessing maritime-cyber risks, raising awareness, and providing training, Maritime Technology and Research, 3(1)

312. Taylor, E. G. R., Collins, K. S. B., Needham, J. (1971). The haven-finding art: a history of navigation from Odysseus to Captain Cook, Hollis & Carter, London

313. Teasuro, G. (1995). Temporal Difference Learning and TD-Gammon, Communications of the ACM, / Vol. 38, No. 3.

314. Tene, O., Polonetsky, J. (2012). To Track or "Do Not Track": Advancing Transparency and Individual Control, Online Behavioral Advertising, dostupno na: http://conservancy.umn.edu/handle/11299/155947

315. Thompson, N. (2018). Emmanuel Macron Talks to Wired About France's AI Strategy, WIRED, dostupno na: https://www.wired.com/story/emmanuel-macron-talks-to-wired-about-frances-ai-strategy/

316. Toghill, J. E. (1988). Celestial Navigation, W. W. Norton & Co., New York

317. Tolan, S., Miron, M., Gomez, E., Castillo, C. (2019). Why machine learning may lead to unfairness: Evidence from risk assesment for juvenile justice in Catalonia, 17th International Conference on AI and Law, Montreal, dostupno na: https://chato.cl/papers/miron_tolan_gomez_castillo_2019_machine_learning_risk_assessment_savry.pdf

318. Toor, A. (2016). Automated Systems Fight ISIS Propaganda, but at What Cost?, The Verge, dostupno na: http://www.theverge.com/2016/9/6/12811680/isis-propaganda-algorithm-facebook- twitter-google

319. Tucci, A. E. (2017). Cyber risks in the marine transportation system, Cyber-Physical Security

320. Tufekci, Z., York, J. C., Wagner, B., Kaltheuner, F. (2015). The Ethics of Algorithms: From Radical Content to Self-Driving Cars, European University Viadrina, dostupno na: https://cihr.eu/publication-the-ethics-of-algorithms/

321. Tversky, A., Kahneman, D. (1974). Judgment under Uncertainty: Heuristics and Biases, Science 185(4157)

322. UK Space Agency, Perry, C. (2017). Funding for £84 Million for Artificial Intelligence and Robotics Research and Smart Energy Innovation Announced, dostupno na: https://www.gov.uk/government/news/funding-for-84-million-for-artificial-intelligence-and-robotics-research-and-smart-energy-innovation-announced

323. Urban, J. M., Karaganis, J., Schofield, B. L. (2016). Notice and Takedown in Everyday Practice, dostupno na: http://papers.ssrn.com/sol3/Papers.cfm?abstract_id=2755628

324. Van Dijk, J. (2012). The evolution of the digital divide: The digital divide turns to inequality of skills and usage u: Bus, J. et al. (2012). Digital Enlightenment Yearbook, Amsterdam, Netherlands, IOS Press

325. Van Duin, S., Bakhshi, N. (2017). Artificial Intelligence Defined: The most used terminology around AI, Delloite, dostupno na: https://www2.deloitte.com/nl/nl/pages/data-analytics/articles/part-1-artificial-intelligence-defined.html

326. Van Loo, R. (2019). Digital Market Perfection, Michigan Law Review 117 (5)

327. Villani, C. (2018). For a meaningful artificial intelligence: towards a french and european strategy, dostupno na: https://www.aiforhumanity.fr/pdfs/MissionVillani_Report_ENG-VF.pdf

328. Vinge, V. (1993). Techonlogical singularity, Whole Earth Review

329. Vojković, G., Milenković, M. (2018). Novi pravni okvir i klasifikacija autonomnih, daljinski upravljanih i srodnih brodova, Druga međunarodna konferencija pomorskog prava "Suvremeni izazovi pomorske plovidbe", Split

330. Von Ahn, L., Blum, M., Hopper, N., Langford, J. (2003). CAPTCHA: Using Hard AI Problems for Security, the Wayback Machine, Proceedings of Eurocrypt, Vol. 2656

331. Voorhoof, D., Humblet, P. (2013.) The Right to Freedom of Expression in the Workplace under Article 10 ECHR, Oxford: Hart Publishing

332. Wagner, B. (2016). Global Free Expression: Governing the Boundaries of Internet Content. Cham, Switzerland, Springer International Publishing,

333. Walczak, A., Skotnicka, M. (2011). An evaluation of Voyage Date Recorders and S (Simplified)-VDR by maritime experts, Zeszyty Naukowe/Akademia Morska w Szczecinie

334. Walker, R. (2020). AI Explainability: Why we need it, how it works, and who's winning, Medium

335. Wang, W. K., Woetzel, J., Seong, J., Manyika, J., Chui, M., Wong, W. (2017). Digital China: Powering the economy to global competitiveness, McKinsey Global Institute

336. Ward, K. D., Baker, C. J., Watts, S. (1990). Maritime surveillance radar. Part 1: Radar scattering from the ocean surface, IEE Proceedings F, Radar and Signal Processing, Vol. 137, No. 2

337. Ward, V. (2018). Artificial Intelligence Weaponry Successfully Trialed on Mock Urban Battlefield, THE TELEGRAPH, dostupno na: https://www.telegraph.co.uk/news/2018/09/24/artificial-intelligence-weaponry-successfully-trialled-mock/

338. Warwick, K. (2012). Artificial intelligence – The basics, Routledge

339. Washington, A. L. (2018). How to argue with an algorithm: Lessons from the COMPAS-ProPublica debate, Colo. Tech. LJ, 17

340. Waterborne Tp. (2017). The Autonomous Ship. Brussels, Belgium: Water Borne Technology Platform

341. Watkins, C., Dayan, P. (1992). Q – Learning, Machine Learning, Vol. 8, Kluwer Academic Publishers, Boston

342. Wattanapongsakorn, N., Srakaew, S., Wonghirunsombat, E., Sribavonmongkol, C., Junhom, T., Jongsubsook, P., Charnsripinyo, C. (2012). A practical network-based intrusion detection and prevention system, 2012 IEEE 11th International Conference on Trust, Security and Privacy in Computing and Communications, IEEE

343. Wei, Z., Jie, X., Xiangshi, W. (2019). Statistical analysis of ship traffic characteristics based on big data analysis [J], Ship Science and Technology, 41 (08)

344. Weintrit, A. (2015). ECDIS issues related to the implementation of the carriage requirements in SOLAS Convention. Archives of Transport System Telematics, 8(1)

345. Weintrit, A., Wawruch, R., Specht, C., Gucma, L., Pietrzykowski, Z. (2007). Polish approach to e-navigation concept TransNav, International Journal on Marine Navigation and Safety od Sea Transportation, 1(3)

346. Weiss, G. (2013). Multiagent systems (2nd ed.), Cambridge, MA, MIT Press

347. Weizenbaum, J. (1966). Computational Linguistics, Communications of the ACM, Vol. 9., No. 1., dostupno na: https://web.stanford.edu/class/linguist238/p36weizenabaum.pdf

348. Wieslaw, T. (2012). Origins of ship safety requirements formulated by International Maritime Organization. Procedia Engineering, 45

349. Wiggers, K. (2019). Generative adversarial networks: What GANs are and how they've evolved, VentureBeat

350. Wilks, Y. (2019). Artificial Intelligence – Modern magic or dangerous future?, Icoon Books

351. Winner, L. (1980). Do Artifacts Have Politics?, Daedalus

352. Winner, L. (1986). The Whale and the Reactor: A Search for Limits in an Age of High Technology

353. Winston, P. H. (1992). Artificial Intelligence, 3rd ed., Addison – Wesley Longman Publishing Co.

354. Wolchover, N. (2020). Artificial Intelligence Will Do What We Ask. That's a Problem, Quanta Magazine

355. Yampolskiy, R. V. (2012). AI-complete, AI-hard, or AI-easy–classification of problems in AI, The 23rd Midwest Artificial Intelligence and Cognitive Science Conference, Cincinnati, OH, USA
356. Yampolskiy, R.V. (2013). Turing Test as a Defining Feature of AI-Completeness. In Artificial Intelligence, Evolutionary Computation and Metaheuristics (AIECM) - In the footsteps of Alan Turing, Springer, London
357. Yang, L. (2019). Study on the Construction of Ship Channel Traffic Flow Forecasting System [J], Ship Science and Technology, 41 (02)
358. Zhou, M., Chen, Y., Su, X., An, L. (2020). Rapid construction and advanced technology for a Covid-19 field hospital in Wuhan, China, Proceedings of the Institution of Civil Engineers-Civil Engineering, Vol. 174, No. 1
359. Zi, R., Ge, X., Thompson, J., Wang, C. X., Wang, H., Han, T. (2016). Energy efficiency optimization of 5G radio frequency chain systems, IEEE Journal on Selected Areas in Communications, 34(4)
360. Zilberstein, S. (2015). Building Strong Semi-Autonomous Systems, Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence

Pravni izvori

1. 783 PARL. DEB. H.L. (5th ser.) (2017) 562, dostupno na: https://hansard.parliament.uk/Lords/2017-06-29/debates/09a72b2f-9261-4ab4-82e8-92f1c0758a87/LordsChamber
2. A European Strategy for Data, dostupno na: https://ec.europa.eu/digital-single-market/en/policies/building-european-data-economy
3. Achtes Gesetz zur Änderung des Straßenverkehrsgesetzes, dostupno na: https://www.bgbl.de/xaver/bgbl/start.xav?startbk=Bundesanzeiger_BGBl&jumpTo=bgbl117s1648.pdf
4. AI Ethics Guidelines Global Inventory, dostupno na: https://inventory.algorithmwatch.org/
5. AMSA policy on regulatory treatment of unmanned and/or autonomous vessels, Australian Maritime Safety Authority, dostupno na:

https://www.amsa.gov.au/sites/default/files/policy-regulatory-treatment-unmanned-autonomous-vessels.pdf

6. An Act relating to automated motor vehicles, dostupno na: https://legiscan.com/TX/text/SB2205/2017
7. Artificial Intelligence – Australia's Ethics Framework, 2019.
8. ASILOMAR AI PRINCIPLES, Future Of Life Institute
9. BIMCO, CLIA, ICS, INTERCARGO, INTERMANAGER, INTERTANKO, IUMI, OCIMF, WORLD SHIPPING COUNCIL, The Guidelines on Cyber Security Onboard Ship, dostupno na: https://www.ics-shipping.org/wp-content/uploads/2020/08/guidelines-on-cyber-security-onboard-ships-min.pdf
10. Bijela knjiga o umjetnoj inteligenciji – Europski pristup izvrsnosti i izgradnji povjerenja od 19.2.2020., COM(2020) 65 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:52020DC0065&from=hr
11. Blueprint for sectoral cooperation on skills, dostupno na: https://ec.europa.eu/social/main.jsp?catId=1415&langId=en
12. Bundesregierung [Federal government], Digitale agenda 2014–2017 [Digital agenda 2014–2017] (2014)
13. Bundesregierung [Federal Government], Legislaturbericht. Digitale Agenda 2014–2017 [Legislative Report. Digital Agenda 2014–2017], (2017), dostupno na: http://www.bmi.bund.de/SharedDocs/downloads/DE/publikationen/themen/moderne-verwaltung/legislaturbericht-digitale-agenda-2014-2017.pdf?blob=publicationFile&v=4
14. C164 - Health Protection and Medical Care (Seafarers) Convention, 1987 (No. 164) dostupna na: http://www.ilo.org/dyn/normlex/en/f?p=NORMLEXPUB:55:0::NO::P55_TYPE,P55_LANG,P55_DOCUMENT,P55_NODE:REV,en,C164, %2FDocument
15. Communication from the Commission to the European Parliament and the Council - Guidance on the Regulation on a framework for the free flow of non-personal data in the European Union, COM (2019) 250, dostupno na: https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=COM %3A2019 %3A250 %3AFIN
16. Communication from the Commission to the European Parliament, the European Council, the Council, The European Economic and Social Committee and the

Committee of the Regions - Coordinated Plan on Artificial Intelligence, COM/2018/795 final

17. Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions - Towards a thriving dana - driven economy, COM/2014/0442 final
18. Convention for the Protection of Individuals with regard to Automatic Processing of Personal Data (ETS No. 108)
19. Convention for the Unification of Certain Rules of Law with respect to Collisions between Vessels. (1910)
20. Council Conclusions on the Fifth Review Conference of the Convention on Prohibitions or Restrictions on the Use of Certain Conventional Weapons Which May be Deemed to be Excessively Injurious or to Have Indiscriminate Effects (CCW) (Geneva, 12-16 December 2016), dostupno na: https://eeas.europa.eu/sites/eeas/files/ccw.pdf
21. Data Ethics Commission, Recommendations of the Data Ethics Commission for the Federal Government's Strategy on Artificial Intelligence dostupno na: https://www.bmjv.de/SharedDocs/Downloads/DE/Ministerium/ForschungUndWissenschaft/DEK_Empfehlungen_englisch.html;jsessionid=DDAF76836371D0CC6F04A232F117B72F.1_cid324?nn=11678512
22. Décret n° 2018-211 du 28 mars 2018 relatif à l'expérimentation de véhicules à délégation de conduite sur les voies publiques, dostupno na: https://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000036750342&dateTexte=&categorieLien=id
23. Decreto 28 Febbraio 2018 Ministero delle Infrastrutture e dei Trasporti, Modalita' Attuative e Strumenti Operativi della Sperimentazione su Strada delle Soluzioni di Smart Road e di Guida Connessa e Automatica, GAZZETTA UFFICIALE [G.U.] [OFFICIAL GAZETTE] No. 90 (Apr. 18, 2018), dostupno na: http://www.gazzettaufficiale.it/eli/id/2018/04/18/18A02619/sg
24. Department of Defense, Directive 3000.09, "Autonomy in Weapon Systems", dostupno na: https://www.esd.whs.mil/portals/54/documents/dd/issuances/dodd/300009p.pdf
25. Direktiva Vijeća br. 85/274 od 25. srpnja 1985. o približavanju zakona i drugih propisa država članica u vezi s odgovornošću za neispravne proizvode, OJ L 210, str. 29-33.

26. Direktiva 1999/34/EZ Europskog parlamenta i Vijeća od 10. svibnja 1999. o izmjeni Direktive Vijeća 85/374/EEZ o usklađivanju zakona i drugih propisa država članica u vezi s odgovornošću za neispravne proizvode, OJ L 141, str. 20-21.
27. Direktiva (EU) 2015/2366 Europskog Parlamenta i Vijeća od 25. studenoga 2015. o platnim uslugama na unutarnjem tržištu, o izmjeni direktiva 2002/65/EZ, 2009/110/EZ i 2013/36/EU te Uredbe (EU) br. 1093/2010 i o stavljanju izvan snage Direktive 2007/64/EZ, OJ L 7, str. 35-127.
28. Direktiva (EU) 2016/1148 Europskog parlamenta i Vijeća od 6. srpnja 2016. o mjerama za visoku zajedničku razinu sigurnosti mrežnih i informacijskih sustava širom unije, OJ L 194, str. 1-30.
29. Direktiva (EU) 2019/944 Europskog parlamenta i Vijeća od 5. lipnja 2019. o zajedničkim pravilima za unutarnje tržište električne energije i izmjeni Direktive 2012/27/EU, OJ L 158, str. 125-199.
30. Direktiva (EU) 2019/1024 Europskog parlamenta i Vijeća od 20. lipnja 2019. o otvorenim podatcima i ponovnoj uporabi informacija javnog sektora, OJ L 172, str. 56-83.
31. Direktiva 2005/65/EZ Europskog parlamenta i Vijeća od 26. listopada 2005. o jačanju sigurnosne zaštite luka, OJ L 310, str. 72-83.
32. Direktiva 2006/42/EZ Europskog parlamenta i Vijeća od 17. svibnja 2006. o strojevima o izmjeni Direktive 95/16/EZ, OJ L 157, str. 24-86.
33. Direktiva 2010/40/EU Europskog parlamenta i Vijeća od 7. srpnja 2010. o okviru za uvođenje inteligentnih prometnih sustava u cestovnom prometu i za veze s ostalim vrstama prijevoza, OJ L 207, str. 1-13.
34. Direktiva 2013/37/EU Europskog parlamenta i Vijeća od 26. lipnja 2013. o izmjeni Direktive 2003/98/EZ o ponovnoj uporabi informacija javnog sektora, OJ L 175, str. 56-83.
35. Direktiva 89/391/EEZ Vijeća od 12. lipnja 1989. o uvođenju mjera za poticanje poboljšanja sigurnosti i zdravlja radnika na radu, OJ L 183, str. 1-8.
36. Draft Recommendation of the Committee of Ministers to Member States on the Roles and Responsibilities of Internet Intermediaries, on 19 September 2017, dostupno na: https://rm.coe.int/draft-recommendation-on-internet-intermediaries-version-4/1680759e

37. EU Commission's Seventh Framework Programme Grant Agreement No. 314286, dostupno na: https://ec.europa.eu/growth/sectors/space/research/fp7_en
38. European Parliament resolution of 16 February 2017 with recommendations to the Commission on Civil Law Rules on Robotics (2015/2103(INL))
39. Europska konvencija za zaštitu ljudskih prava i temeljnih sloboda (MU 18/97, 6/99, 14/02, 13/03, 9/05, 1/06, 2/10)
40. Franco-German-Luxemburgish Cooperation On Automated And Connected Driving: Concept For The Cross-Border Digital Test Bed. (2018), dostupno na: https://perma.cc/BK6Y-9HQT
41. French Act Br. 2018-133 iz veljače 2018, dostupno na: https://www.digitaleurope.org/resources/nis-implementation-tracker/
42. French Strategy for Artifilical Intelligence, dostupna na: https://www.aiforhumanity.fr/en/
43. German Road Traffic Act — Straßenverkehrsgesetz (StVG)
44. Germany AI Strategy Report, dostupno na: https://ec.europa.eu/knowledge4policy/ai-watch/germany-ai-strategy-report_en
45. Gesetz zur Änderung der Artikel 8 und 39 des Übereinkommens vom 8. November 1968 über den Straßenverkehr, dostupno na: http://www.bgbl.de/xaver/bgbl/start.xav?startbk=Bundesanzeiger_BGBl&jumpTo=bgbl216s1306.pdf
46. Government of the Russian Federation, Regulation No. 1415 of Nov. 26, 2018, on Conducting an Experiment in the Test Use of Highly Automated Vehicles on Public Roads, dostupno na: http://government.ru/docs/34831/
47. Government Office for Science, Artificial Intelligence: Opportunities And Implications For The Future Of Decision Making (2015), dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/566075/gs-16-19-artificial-intelligence-ai-report.pdf
48. Guidance on the IMO/IHO World-Wide Navigational Warning Service adopted by the Organization by Resolution A.706(17), dostupno na: http://www.imo.org/en/KnowledgeCentre/IndexofIMOResolutions/Assembly/Documents/A.706(17).pdf
49. HLEG (2018). Ethics Guidelines for Trustworthy Artificial Intelligence, dostupno na: https://ec.europa.eu/digital-single-market/en/news/ethics-guidelines-trustworthy-ai

50. House Bill by Lamberth, Senate Bill by Lundberg, An Act to amend Tennessee Code Annotated, dostupno na http://www.capitol.tn.gov/Bills/110/Bill/SB0151.pdf
51. House of Commons Library Briefing Paper No. 8152, dostupno na: http://researchbriefings.files.parliament.uk/documents/CBP-8152/CBP-8152.pdf,
52. House of Commons Science and Technology Committee (2018). Algorithms in Decision-Making, Fourth Report of Session 2017–19, dostupno na: https://publications.parliament.uk/pa/cm201719/cmselect/cmsctech/351/351.pdf
53. House of Commons Science and Technology Committee (2018). Algorithms in Decision-Making: Government Response to the Committee's Fourth Report, Sixth Special Report of Session 2017–19, dostupno na: https://publications.parliament.uk/pa/cm201719/cmselect/cmsctech/1544/1544.pdf
54. House Of Lords Select Committee On Artificial Intelligence, Ai In The Uk: Ready, Willing And Able? ¶ 345 (HL Paper 100, Apr. 2018), dostupno na: https://publications.parliament.uk/pa/ld201719/ldselect/ldai/100/100.pdf
55. House Of Lords, Select Committee On Artificial Intelligence (2018). Ai In The Uk: Ready, Willing And Able? ¶ 345, dostupno na: https://publications.parliament.uk/pa/ld201719/ldselect/ldai/100/100.pdf
56. IMO Guidelines on Maritime Cyber Risk Management. (2017). MSC-FAL. 1/ Circ. 3
57. International Convention on Tonnage Measurement of Ships, 1969, dostupna na: https://ec.europa.eu/eurostat/cache/metadata/Annexes/fish_fleet_esms_an1.pdf
58. International Convention for the unification of certain rules relating to penal jurisdiction in matters of collision or other incidents of navigation. (1952)
59. International Convention on Certain Rules concerning Civil Jurisdiction in Matters of Collision. (1952).
60. Italy AI Strategy Report, dostupno na: https://ec.europa.eu/knowledge4policy/ai-watch/italy-ai-strategy-report_en <TitreType>
61. Izvješće Komisije Europskom parlamentu, Vijeću i Europskom gospodarskom i socijalnom odboru - Izvješće o utjecaju umjetne inteligencije, interneta stvari i robotike na sigurnost i odgovornost, COM/2020/64 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/ALL/?uri=COM %3A2020 %3A0064 %3AFIN
62. Kazneni zakon (NN, br. 125/11, 144/12, 56/15, 61/15, 101/17, 118/18, 126/19, 84/21)

63. Kodeks o zaštiti trgovačkih brodova na nuklearni pogon (Nuclear-Ship Code Code of safety for nuclear merchant ships - Res. A.491(XII)), dostupno na: https://puc.overheid.nl/nsi/doc/PUC_3002_14/1/
64. Komunikacija Komisije Europskom parlamentu, Europskom vijeću, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija - Umjetna inteligencija za Europu, COM/2018/237 final, https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX %3A52018DC0237
65. Komunikacija Komisije Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija o omogućivanju digitalne transformacije na jedinstvenom digitalnom tržištu u području zdravstva i skrbi: osnaživanje građana i stvaranje zdravijeg društva, COM/2018/233 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:52018DC0233
66. Komunikacija Komisije Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija, Novi program vještina za Europu – Suradnja na jačanju ljudskog kapitala, zapošljivosti i konkurentnosti, COM/2016/0381 final, dostupno na: https://op.europa.eu/en/publication-detail/-/publication/c861f839-2ee9-11e6-b497-01aa75ed71a1/language-hr/format-PDF
67. Komunikacija Komisije Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i odboru regija o akcijskom planu za digitalno obrazovanje, COM/2018/022 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=COM %3A2018 %3A22 %3AFIN
68. Komunikacija Komisije Europskom Parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Europska strategija za podatke, COM/2020/66 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:52020DC0066
69. Komunikacija Komisije Europskom Parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Digitalizacija europske industrije - Iskorištavanje svih prednosti jedinstvenog digitalnog tržišta, COM/2016/180 final
70. Komunikacija Komisije Europskom parlamentu, Europskom vijeću, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Kordinirani plan o umjetnoj inteligenciji, COM(2018) 795 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:52018DC0795

71. Komunikacija Komisije, Moderan proračun Unije koja štiti, osnažuje i brani, Višegodišnji financijski okvir za razdoblje 2021.–2027., COM(2018) 321 final, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX%3A52018DC0321
72. Konvencija o mjerodavnom pravu za odgovornost proizvođača za svoje proizvode iz 1973.
73. Konvencija o olakšicama u međunarodnom pomorskom prometu (engl. *Convention on Facilitation of International Maritime Traffic (FAL)*)
74. Konvencija o međunarodnoj pomorskoj satelitskoj organizaciji (engl. *Convention on the International Maritime Satellite Organization* – INMARSAT)
75. Konvencija o radu pomoraca (NN, MU, br. 11/2009)
76. Konvencija Ujedinjenih Naroda o pravu mora (engl. *United Nations Convention on Law at Sea* - UNCLOS)
77. Konvencija o zdravstvenoj zaštiti i medicinskoj skrbi (pomorci), 1987 (No. 164)
78. Lisbon Rules 1987 – Comite Maritime International. (1987).
79. LOI n° 2016-1321 du 7 octobre 2016 pour une République numérique (1), dostupno na: https://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000033202746&dateTexte=&categorieLien=id
80. MARPOL 73/78 Annex I on Prevention of pollution by oil and oily water
81. MARPOL 73/78 Annex II on Control of pollution by noxious liquid substances in bulk
82. MARPOL 73/78 Annex III on Prevention of pollution by harmfull substances carried by sea in packaged form
83. MARPOL 73/78 Annex IV on Pollution by sewage from ships
84. MARPOL 73/78 Annex V on Pollution by garbage from ships
85. MARPOL 73/78 Annex VI on Prevention o fair pollution from ships
86. Međunarodna konvencija o regulacijama za prevenciju sudara na moru (engl. *Convention on International Regulations for Preventing Collisions at Sea - COLREG*)
87. Međunarodna konvencija o standardima izobrazbe, izdavanju svjedodžbi i držanju straže pomoraca (engl. *The International Convention on Standards of Training, Certification and Watchkeeping for Seafarers - STCW*)
88. Međunarodna konvencija o teretnoj liniji (engl. *International Convention on Load Lines - CLL*)

89. Međunarodna konvencija o zaštiti ljudskih života na moru (engl. *International Convention for the Safety of Life at Sea* – SOLAS)
90. Međunarodni signalni kodeks (engl. *International Code of Signals - ICS*)
91. Međunarodni sigurnosni kod brodova i lučkih objekata (engl. *International Ship and Port Facility Security Code – ISPS*)
92. Ministarstvo mora, turizma, prometa i razvitka. (2006). Pomorski glasnik – Konvencija o radu pomoraca, NN
93. Ministry Of Defence, Development, Concepts And Doctrine Centre (2017). Unmanned Aircraft Systems, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/673940/doctrine_uk_uas_jdp_0_30_2.pdf
94. National Law Act 2012, Australian Maritime Safety Authority, dostupno na: https://www.amsa.gov.au/about/regulations-and-standards/national-law-act-2012
95. National Transport Commission. (2017). Guidelines for Trials of Automated Vehicles in Australia.
96. National Transport Commission. (2018). Automated vehicles in Australia.
97. Navigation Act 2012, Australian Maritime Safety Authority, dostupno na: https://www.amsa.gov.au/about/regulations-and-standards/navigation-act-2012
98. Odluka Vijeća (ZVSP) 2019/797 od 17. svibnja 2019. o mjerama ograničavanja protiv kibernapada koji predstavljaju prijetnju Uniji ili njezinim državama članicama, OJ L 129, str. 13-19.
99. Performance standards and functional requirements for the long-range identification and tracking of ships, adopted by the Maritime Safety Committee of the Organization by resolution MSC.210(81)
100. Pomorski zakonik (NN, br. 181/04, 76/07, 146/08, 61/11, 56/13, 26/15, 17/19)
101. Povelja EU o temeljnim pravima od 7.6.2016., C 202/390
102. Pravila za statutarnu certifikaciju pomorskih brodova, sprječavanje onečišćenja (NN, br. 8/2020-168)
103. Pravilnik o prijevozu opasnih tvari unutarnjim vodama (NN, br. 106/08)
104. Pravilnik o rukovanju opasnim tvarima, uvjetima i načinu obavljanja prijevoza u pomorskom prometu, ukrcavanja i iskrcavanja opasnih tvari, rasutog i ostalog tereta u lukama, te načinu sprječavanja širenja isteklih ulja u lukama (NN, br. 51/05, 23/20)

105. Pravilnik o sigurnosti pomorske plovidbe u unutarnjim morskim vodama i teritorijalnom moru Republike Hrvatske te načinu i uvjetima obavljanja nadzora i upravljanja pomorskim prometom (NN, br. 79/13, 40/14, 57/15)

106. Pravilnik o upravljanju i nadzoru balastnih voda (NN, br. 128/2012)

107. Preporuka Komisije (EU) 2018/790 od 25. travnja 2018. o pristupu znanstvenim informacijama i njihovu čuvanju, C/2018/2375, dostupno na: https://eur-lex.europa.eu/legal-content/HR/ALL/?uri=CELEX %3A32018H0790

108. Prijedlog Uredbe Europskog parlamenta i Vijeća o poštovanju privatnog života i zaštiti osobnih podataka u elektroničkim komunikacijama te stavljanju izvan snage Direktive 2002/58/EZ (Uredba o privatnosti i elektroničkim komunikacijama), COM/2017/010 final - 2017/03 (COD), dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX %3A52017PC0010

109. Pročišćena verzija Ugovora o Europskoj uniji i Ugovora o funkcioniranju Europske unije (2016/C 202/01), dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:12016ME/TXT

110. Proposal for a Regulation of the European Parliament and of the Council - Laying Down Harmonised Rules On Artificial Intelligence (Artificial Intelligence Act) and Amending Certain Union Legislative Acts, {SEC(2021) 167 final} - {SWD(2021) 84 final} - {SWD(2021) 85 final}, COM(2021) 206 final

111. Proposal for a Council Recommendation on access to social protection for workers and the self-employed {SWD(2018) 70 final} - {SWD(2018) 71 final} - {SWD(2018) 79 final}

112. Proposte per una strategia italiana per l‘intelligenza artificiale (2019). Elaborata dal Gruppo di Esperti MISE sull’intelligenza artificiale, dostupno na: https://www.mise.gov.it/images/stories/documenti/Proposte-per-una-strategia-italiana-2019.pdf

113. Recommendation CM/Rec(2010)13 of the Committee of Ministers to member states on the protection of individuals with regard to automatic processing of personal data in the context of profiling

114. Recommendation of the Council on Artificial Intelligence, dostupna na: https://legalinstruments.oecd.org/en/instruments/OECD-LEGAL-0449

115. Recommendation on Performance Standards for Electronic Chart Display and Information Systems (ECDIS) (resolution A.817(19)), as amended by resolutions MSC.64(67), annex 5 i MSC.86(70), annex 4. dostupno na: https://puc.overheid.nl/nsi/doc/PUC_2433_14/3/

116. Regulatory plan - five-year regulatory outlook, Australian Maritime Safety Authority, dostupno na: https://www.amsa.gov.au/about/corporate-publications/regulatory-plan-five-year-regulatory-outlook

117. Report from the Commission to the European Parliament, the Council and the European Economic and Social Committee - Report on the Safety and Liability Implications of Artificial Intelligence, The Internet of things and robotics, COM(2020) 64 final

118. Report from the Expert Group on Liability and New Technologies – New Technologies Formation. (2019). Liability for Artificial Intelligence and other emerging digital technologies, dostupno na: https://ec.europa.eu/newsroom/dae/document.cfm?doc_id=63199

119. Report with recommendations to the Commission on Civil Law Rules on Robotics (2015/2103(INL)), dostupno na: https://www.europarl.europa.eu/doceo/document/A-8-2017-0005_EN.html

120. Resolution MSC.428(98) Maritime Cyber Risk Management in Safety Management Systems, (adopted on 16 June 2017), dostupna na: https://wwwcdn.imo.org/localresources/en/OurWork/Security/Documents/Resolution %20MSC.428(98).pdf

121. Resolution MSC.337(91) (adopted on 30 November 2012), Adopting of the Code on noise levels on bord ships, dostupna na: https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions /Documents/MSC %20- %20Maritime %20Safety/337(91).pdf

122. Rezolucija Europskog parlamenta od 16. veljače 2017. s preporukama Komisiji o pravilima građanskog prava o robotici (2015/2103(INL)) (2018/C 252/25)

123. Scottish Law Commission (2018). Automated Vehicles: A Joint Preliminary Consultation Paper, dostupno na: https://s3-eu-west-2.amazonaws.com/lawcom-prod-storage-11jsxou24uy7q/uploads/2018/11/6.5066_LC_AV-Consultation-Paper-5-November_061118_WEB-1.pdf

124. Spanish RDI Strategy in Artificial Intelligence, dostupna na: https://www.ciencia.gob.es/stfls/MICINN/Ciencia/Ficheros/Estrategia_Inteligencia_Artificial_EN.PDF
125. Strategia Nazionale per l'Intelligenza Artificiale, dostupno na: https://www.mise.gov.it/images/stories/documenti/Strategia-Nazionale-Intelligenza-Artificiale-Bozza-Consultazione.pdf
126. Submission of the Russian Federation to the GGE of the High Contracting Parties to the CCW, Examination of Various Dimensions of Emerging Technologies in the Area of Lethal Autonomous Weapons Systems, in the Context of the Objectives and Purposes of the Convention, UN Doc No. CCW/GGE.1/2017/WP.8 (2017), dostupno na: https://admin.govexec.com/media/russia.pdf
127. Ten principles of ethical AI, dostupno na: http://www.thefutureworldofwork.org/opinions/10-principles-for-ethical-ai/
128. The Federal Government's key questions to the Data Ethics Commission, dostupno na: https://www.bmi.bund.de/SharedDocs/downloads/EN/themen/it-digital-policy/key-questions-Data-Ethics-commission.pdf?__blob=publicationFile&v=6
129. UK Statutory Instrument, S. I. 1495 of 2004, dostupno na: http://www.legislation.gov.uk/uksi/2004/1495/contents/made
130. United Nations activities on Artificial Intelligence, (2018), dostupno na: https://www.itu.int/pub/S-GEN-UNACT-2018-1
131. United States Maritime Transportation Security Act of (2002), dostupno na: https://uslaw.link/citation/us-law/public/107/295
132. Uredba (EU) 2016/679 Europskog parlamenta i Vijeća od 27. travnja 2016. o zaštiti pojedinaca u vezi s obradom osobnih podataka i o slobodnom kretanju takvih podataka, te o stavljanju izvan snage Direktive 95/46/EZ, OJ L 119, str. 1-88.
133. Uredba (EU) 2017/745 Europskog parlamenta i Vijeća od 5. travnja 2017. o medicinskim proizvodima, o izmjeni Direktive 2001/83/EZ, Uredbe (EZ) br. 178/2002 i Uredbe (EZ) br. 1223/2009 te o stavljanju izvan snage direktiva Vijeća 90/385/EEZ i 93/42/EEZ, OJ L 117, str. 1-175.
134. Uredba (EU) 2018/1807 Europskog parlamenta i Vijeća od 14. studenoga 2018. o okviru za slobodan protok neosobnih podataka u Europskoj uniji, OJ L 303, str. 59-68.

135. Uredba (EU) 2019/881 Europskog parlamenta i vijeća od 17. travnja 2019. o ENISA-i (Agencija Europske unije za kibersigurnost) te o kibersigurnosnoj certifikaciji u području informacijske i komunikacijske tehnologije i stavljanju izvan snage Uredbe (EU) br. 526/2013, OJ L 151, str. 15-69.

136. Uredba (EU) 2019/1020 Europskog parlamenta i Vijeća od 20. lipnja 2019. o nadzoru tržišta i sukladnosti proizvoda i o izmjeni Direktive 2004/42/EZ i uredbi (EZ) br. 765/2008 i (EU) br. 305/2011, OJ L 169

137. Uredba (EZ) br. 595/2009 Europskog Parlamenta i Vijeća od 18. lipnja 2009. o homologaciji motornih vozila i motora s obzirom na emisije iz teških vozila (Euro VI) i o pristupu informacijama za popravak i održavanje vozila i izmjenama Uredbe (EZ) br. 715/2007 i Direktive 2007/46/EZ i stavljanju izvan snage Direktiva 80/1269/EEZ, 2005/55/EZ i 2005/78/EZ, OJ L 188, str. 1-13.

138. Uredba (EZ) br. 725/2004 Europskog parlamenta i Vijeća od 31. ožujka 2004. godine o jačanju sigurnosne zaštite brodova i luka, OJ L 129, str. 120-250.

139. WHO (2007). International medical guide for ships, dostupno na: https://apps.who.int/iris/bitstream/handle/10665/43814/9789240682313_eng.pdf;jsessionid=0E0D2D673D04511C794DC700B308BD02?sequence=1

140. Zajednička Komunikacija Europskom parlamentu i Vijeću - Otpornost, odvraćanje i obrana: jačanje kibernetičke sigurnosti EU-a, JOIN/2017/0450 final/2

141. Zaključci Vijeća o okviru za zajednički diplomatski odgovor EU-a na zlonamjerne kiberaktivnosti („Alati za kiberdiplomaciju”), 19. lipnja 2017., 10474/17, dostupno na: https://data.consilium.europa.eu/doc/document/ST-10474-2017-INIT/hr/pdf

142. Zakon o kritičnim infrastrukturama (NN, br. 56/13)

143. Zakon o obveznim odnosima (NN, br. 35/05, 41/08, 125/11, 78/15, 29/18, 126/21)

144. Zakon o sigurnosnoj zaštiti pomorskih brodova i luka (NN, br. 108/17, 30/21)

Internet izvori

1. 2017-2018 Regular Session - SB 219 Motor Vehicles; definitions; operation of motor vehicles with automated driving systems on certain public roads; provide, dostupno na: http://www.legis.ga.gov/Legislation/en-US/display/20172018/SB/219
2. ABB - Maritime's next wave: An ancient industry's bold new thinking (2019), dostupno na: https://www.forbes.com/sites/abb/2019/12/19/maritimes-next-wave-an-ancient-industrys-bold-new-thinking/?sh=5bac0c09552d#6c9bbbb5552d
3. Afety Gate: the rapid alert system for dangerous non-food products, dostupno na: https://ec.europa.eu/consumers/consumers_safety/safety_products/rapex/alerts/repository/content/pages/rapex/index_en.htm
4. AI Watch, Monitor the development, uptake and impact of Artificial Intelligence for Europe, dostupno na: https://ec.europa.eu/knowledge4policy/ai-watch_en
5. Airhart, G. M., (2018). Learning Expands the Brain's Capacity to Store Information, dostupno na: https://cns.utexas.edu/news/learning-expands-the-brain-s-capacity-to-store-information
6. Allianz - Safety and shipping review (2019), dostupno na: https://www.agcs.allianz.com/content/dam/onemarketing/agcs/agcs/reports/AGCS-Safety-Shipping-Review-2019.pdf
7. AMSA - Autonomous vessels in Australia, dostupno na: https://www.amsa.gov.au/vessels-operators/domestic-commercial-vessels/autonomous-vessels-australia
8. BBC (2018). Amazon scrapped 'sexist AI' tool, dostupno na: https://www.bbc.com/news/technology-45809919
9. CBInsights - Massive Cargo ships are going autonomous; Here are the companies and trends driving the global maritime industry forward (2018), dostupno na: https://www.cbinsights.com/research/autonomous-shipping-trends/
10. Centre for Data Ethics and Innovation Consultation, Department for Digital, Culture, Media & Sport (2018), dostupno na: https://www.gov.uk/government/consultations/consultation-on-the-centrefordataethicsandinnovation/centre-for-data-ethics-and-innovation-consultation
11. Centre For The Future of Work. (2017). 21 Jobs of the future – A guide to getting – and staying – employed over the next 10 years, dostupno na:

https://www.cognizant.com/whitepapers/21-jobs-of-the-future-a-guide-to-getting-and-staying-employed-over-the-next-10-years-codex3049.pdf

12. China's promotion of "Internet Plus governance". (2017). The State Council, dostupno na: http://english.gov.cn/premier/news/2017/02/01/content_281475556331388.htm
13. Commission Nationale De L'informatique Et Des Libertés (Cnil), Comment Permettre À L'homme De Garder La Main? (2017), dostupno na: https://www.cnil.fr/sites/default/files/atoms/files/cnil_rapport_garder_la_main_web.pdf
14. Computer learns to detect skin cancer more accurately than doctors, dostupno na: https://www.theguardian.com/society/2018/may/29/skin-cancer-computer-learns-to-detect-skin-cancer-more-accurately-than-a-doctor
15. Congressional Research Service (2019). Defense Primer: U.S. Policy on Lethal Autonomous Weapon System, dostupno na: https://fas.org/sgp/crs/natsec/IF11150.pdf
16. Digital Summit: Shaping the Digital Transformation Together, dostupno na: http://perma.cc/A8SG-EBUV
17. Dijital Dönüşümün Liderleri (2019). dostupno na: https://idcciosummit.com/COMMONS/DOWNLOAD/DX-Leaders_IDC-booklet.pdf?guid=beb436e5-e2f8-45b4-a082-b1c1c5ed5e9d
18. Dirección Nacional De Tráfico, Ministerio Del Interior, Tráfico Establece El Marco Para La Realización De Pruebas Con Vehículos De Conducción Automatizada En Vías Abiertas A La Circulación, Nota De Prensa (Nov. 16, 2015), dostupno na: https://www.dgt.es/Galerias/prensa/2015/11/NP-pruebas-vehiculos-conduccion-automatizada.pdf
19. ECMAR - European Council for Maritime applied R&D. (2020). Maritime technology challenges 2030 – New technologies and opportunities, Safer, smarter and greener for a sustainable European maritime sector, dostupno na: https://www.ecmar.eu/media/1813/ecmar-brochure-maritme-technology-challenges-2030.pdf
20. Ein neuer Aufbruch für Europa. Eine neue Dynamik für Deutschland. Ein neuer Zusammenhalt für unser Land. Koalitionsvertrag zwischen CDU, CSU und SPD. 19. Legislaturperiode, dostupno na: https://www.cdu.de/system/tdf/media/dokumente/koalitionsvertrag_2018.pdf?file=1

21. Electronic exchange of information/Electronic data exchange, IMO, dostupno na: http://www.imo.org/en/OurWork/Facilitation/Electronic %20Business/Pages/default.aspx
22. EU Blue Card Network, dostupno na: https://www.apply.eu/BlueCard/Italy/
23. EU strategija sigurnosti za pomorstvo (2014). dostupna na: https://ec.europa.eu/maritimeaffairs/policy/maritime-security_en
24. European AI Alliance, dostupna na: https://ec.europa.eu/digital-single-market/en/european-ai-alliance
25. European Commission (2018). The European Ai Landscape: Workshop Report 22–23, dostupno na: https://ec.europa.eu/digital-single-market/en/news/european-artificial-intelligence-landscape
26. European Commission White paper on artificial intelligence - a european approach to excellence and trust, dostupno na: https://ec.europa.eu/info/sites/info/files/commission-white-paper-artificial-intelligence-feb2020_en.pdf
27. European Maritime Safety Agency, Annual Overview of Marine Casualties and Incidents in 2020, dostupno na: http://www.emsa.europa.eu/newsroom/latest-news/item/4266-annual-overview-of-marine-casualties-and-incidents-2020.html
28. Federal Information Processing Standards, Publication 199, Computer Security Division Information Technology Laboratory, National Institute of Standards and Technology, Gaithersburg, MD 20899-8900, dostupno na: https://csrc.nist.rip/publications/drafts/FIPS-PUB-199-ipd.pdf
29. Final Report Summary - MUNIN (Maritime Unmanned Navigation through Intelligence in Networks), dostupno na: https://cordis.europa.eu/project/id/314286/reporting
30. Foreign and Commonwealth Office, Statement for the General Exchange of Views at the Meeting of the Group of Government Experts on Lethal Autonomous Weapons Systems, April 9, 2018, ¶ 9, dostupno na: https://www.unog.ch/80256EDD006B8954/(httpAssets)/271A66FCD9412E18C125827A003454CF/$file/2018_LAWSGeneralExchange_UK.pdf
31. Government Office for Science (2015). Artificial Intelligence: Opportunities And Implications For The Future Of Decision Making, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/566075/gs-16-19-artificial-intelligence-ai-report.pdf

32. GPS common problems and how to mitigate them (2018)., dostupno na: https://safety4sea.com/gps-common-problems-and-how-to-mitigate-them/?__cf_chl_jschl_tk__=8d8c96c2964240e7c242de432b5e6afd59d0c10c-1618912211-0-AQ1J9LAI2w08o18XZUdJBgYX7VHlB-ghskWpTn8DA9sbmfgk3iXJNamdhAC2kufKJ2-9g4j8KaGOMBnouqBaSh3oEMxQ_e5_d9bzuTMJ1FSiqX4RjTt0_TkJ3IwzfatmJDY9aYYGGxepvLLHnQeUmfswtWMiNLVP_ExytT2C6q0WhdZ_Jq0XroqoZZ2daugMU9EBgzniw1pAWI1HLCxwOe9votc87lltxgoLmDErrZW7y1eKQIXsjYhqaU91ptlMfXjJILjEHu1xiI9NlK6ecursY_XUwYA2cup06Vv9IPP09g9L5ctm4TgMxoRsCXPoofqsupZPd6gNdxwld2iKae2PGVdy3A7f_HNMTifguhJi62rL9C9Q2yyl-oaX141Ww3f42iOhtSLEnZyGtxE-hC9OFIOPkEEyLvDyDqk0J6c_BapqBelIfnOMj9ciXX6iqg
33. Grupo de Sabios Creara Libro Blanco de Inteligencia Artificial y Big Data [Experts Group Will Create a White Book on AI and Big Data], dostupno na: https://cepymenews.es/libro-blanco-inteligencia-artificial-big-data/
34. Handful of Countries – Including the US and Russia – Hamper Discussions to Ban Killer Robots at UN, FUTURE OF LIFE INSTITUTE (2018), dostupno na: https://futureoflife.org/2018/11/26/handful-of-countries-including-the-us-and-russia-hamper-discussions-to-ban-killer-robots-at-un/
35. Herraiz, J. (2018). Convención sobre Ciertas Armas Convencionales, Grupo de Expertos Gubernamentales sobre Sistemas de Armas Autónomas Letales, Intervención del Embajador de Espana, Julio Herraiz, Delegado ante la Conferencia de Desarme, Geneva, dostupno na: https://docs-library.unoda.org/Convention_on_Certain_Conventional_Weapons_-_Group_of_Governmental_Experts_(2017)/2017_GGE %2BLAWS_Statement_Spain.pdf
36. HM Government, (2018). Industrial Strategy – Artificial Intelligence Sector Deal, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/702810/180425_BEIS_AI_Sector_Deal__4_.pdf

37. HM Treasury (2017). Autumn budget 2017, dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/661583/autumn_budget_2017_print.pdf
38. http://hci.stanford.edu/~winograd/shrdlu/
39. http://mathisis-project.eu/
40. http://shippingregs.org/Portals/2/SecuredDoc/Circulars/MSC.1-Circ.1596 %20- %20Interim %20Guidelines %20For %20Development %20And %20Application %20Of %20Imo %20Goal-Based %20Standards %20Safety %20Leve... %20(Secretariat).pdf?ver=2019-03-07-122838-707
41. http://struna.ihjj.hr/naziv/pomorska-nesreca/18189/
42. http://www.crs.hr/Portals/0/docs/eng/imo_iacs_eu/imo/msc_reports/MSC %20101-24-Add.1 %20- %20Report %20Of %20The %20Maritime %20Safety %20Committee %20On %20Its %20101St %20Session.pdf?ver=2019-08-20-150940-087
43. http://www.crs.hr/TIPO/02-002736.pdf
44. http://www.crs.hr/TIPO/02-003090.pdf
45. http://www.datascienceafrica.org
46. http://www.dba-oracle.com/real_application_clusters_rac_grid/availability.html
47. http://www.unmanned-ship.org/munin/about/munin-results-2/
48. http://www.waterencyclopedia.com/Mi-Oc/Navigation-at-Sea-History-of.html
49. http://www.waterencyclopedia.com/Mi-Oc/Navigation-at-Sea-History-of.html#ixzz6tDuicc72
50. https://bernardmarr.com/the-7-biggest-ethical-challenges-of-artificial-intelligence/
51. https://claire-ai.org
52. https://computer.howstuffworks.com/microprocessor.htm
53. https://consoltech.com/blog/10-common-causes-of-data-loss/
54. https://datos.gob.es/en
55. https://digital-strategy.ec.europa.eu/en/library/definition-artificial-intelligence-main-capabilities-and-scientific-disciplines
56. https://ec.europa.eu/commission/presscorner/detail/hr/IP_19_2749
57. https://ec.europa.eu/digital-single-market/en/ecsel
58. https://ec.europa.eu/digital-single-market/en/news/murab-eu-funded-project-success-story

59. https://ec.europa.eu/epsc/publications/strategic-notes/towards-innovation-principle-endorsed-betterregulation_en
60. https://ec.europa.eu/info/strategy/priorities-2019-2024/europe-fit-digital-age/european-data-strategy_hr
61. https://ec.europa.eu/research/openscience/index.cfm?pg=open-science-cloud
62. https://edition.cnn.com/2019/04/14/africa/google-ai-center-accra-intl/index.html
63. https://emag.nauticexpo.com/why-ai-will-transform-the-maritime-industry/
64. https://enciklopedija.hr/Natuknica.aspx?ID=27600
65. https://enrichme.eu
66. https://fabulos.eu/
67. https://files.eric.ed.gov/fulltext/ED150955.pdf
68. https://healthcare-in-europe.com/en/news/ai-lung-scan-analysis-in-fight-against-covid-19-goes-european.html
69. https://historylink101.com/2/greece3/travel-sea.htm
70. https://karolinska.se/en/live-incite
71. https://kennedyslaw.com/thought-leadership/article/online-courts-a-report-on-the-first-international-online-courts-forum/
72. https://knowledge4policy.ec.europa.eu/ai-watch/italy-ai-strategy-report_en
73. https://marine-digital.com/article_optimizing_vessels_route
74. https://mmpi.gov.hr/more-86/unutarnja-plovidba-rijecni-promet/plovni-putovi/8646
75. https://myhealthavatar.eu
76. https://news.un.org/en/story/2021/09/1099972
77. https://path.azureedge.net/media/documents/APP_epcmd_modeling_br2.pdf
78. https://people.eecs.berkeley.edu/~russell/research/LAWS/President-Obama-letter-2016-04-04.pdf
79. https://s3platform.jrc.ec.europa.eu/digital-innovation-hubs-tool?p_p_id=digitalinnovationhub_WAR_digitalinnovationhubportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-1&p_p_col_count=1&_digitalinnovationhub_WAR_digitalinnovationhubportlet_cur=2&formDate=1521718574008&freeSearch=&evolStages=3
80. https://searchengineland.com/welcome-bert-google-artificial-intelligence-for-understanding-search-queries-323976

81. https://theconversation.com/an-ai-professor-explains-three-concerns-about-granting-citizenship-to-robot-sophia-86479
82. https://thetius.com/brief-guide-to-artificial-intelligence-in-shipping/
83. https://towardsdatascience.com/understanding-the-difference-between-ai-ml-and-dl-cceb63252a6c
84. https://treaties.un.org/doc/Publication/UNTS/Volume %201184/volume-1184-I-18961-English.pdf
85. https://unctad.org/system/files/official-document/rmt2020_en.pdf
86. https://vitalflux.com/ethical-ai-principles-ibm-google-intel/
87. https://web.eecs.umich.edu/~kuipers/opinions/AI-progress.html
88. https://www.agcs.allianz.com/news-and-insights/expert-risk-articles/human-error-shipping-safety.html
89. https://www.ajl.org
90. https://www.americanbar.org/groups/judicial/publications/judges_journal/2020/winter/what-judges-and-lawyers-should-understand-about-artificial-intelligence-technology/
91. https://www.britannica.com/biography/Martin-Behaim
92. https://www.britannica.com/science/Mercator-projection
93. https://www.britannica.com/technology/portolan-chart
94. https://www.businesswire.com/news/home/20200310005110/en/Balbix-Named-Hot-Security-Technology-of-the-Year-for-Industry-First-AI-Platform
95. https://www.ciencia.gob.es/portal/site/MICINN/menAItem.7eeac5cd345b4f34f09dfd1001432ea0/?vgnextoid=cba733a6368c2310VgnVCM1000001d04140aRCRD&lang_choosen=en
96. https://www.cnr.it/en
97. https://www.cnr.it/en/institute/018/institute-for-high-performance-computing-and-networking-icar
98. https://www.congress.gov/bill/116th-congress/house-bill/2231/all-info
99. https://www.consorzio-cini.it/index.php/it/artificial-intelligence-and-intelligent-systems
100. https://www.darpa.mil/about-us/timeline/-grand-challenge-for-autonomous-vehicles
101. https://www.declarationmontreal-iaresponsable.com/la-declaration
102. https://www.enciklopedija.hr/natuknica.aspx?id=58647

103. https://www.gps.gov/applications/marine/
104. https://www.hakom.hr/hr/5g-mreza/60
105. https://www.healtheuropa.eu/personalised-cancer-treatment/87958/
106. https://www.humanoid.waseda.ac.jp/booklet/kato_2.html
107. https://www.iacs.org.uk/media/3784/iacs-class-key-role.pdf
108.https://www.ibm.com/ibm/history/ibm100/us/en/icons/watson/breakthroughs/
109. https://www.idc.com/getdoc.jsp?containerId=prUS46794720
110. https://www.iit.it
111. https://www.ilo.org/wcmsp5/groups/public/---ed_norm/---normes/documents/normativeinstrument/wcms_763684.pdf
112. https://www.imo.org/en/About/Conventions/Pages/COLREG.aspx
113. https://www.imo.org/en/About/Conventions/Pages/Convention-on-the-International-Maritime-Satellite-Organization.aspx
114. https://www.imo.org/en/MediaCentre/HotTopics/Pages/SustainableDevelopmentGoals.aspx
115. https://www.imo.org/en/MediaCentre/MeetingSummaries/Pages/MSC-99th-session.aspx
116. https://www.imo.org/en/OurWork/HumanElement/Pages/STCW-Conv-LINK.aspx
117. https://www.imo.org/en/OurWork/PartnershipsProjects/Pages/GloBallast-Programme.aspx
118. https://www.imo.org/en/OurWork/Safety/Pages/Goal-BasedStandards.aspx
119. https://www.imo.org/en/OurWork/Security/Pages/SOLAS-XI-2 %20ISPS %20Code.aspx
120. https://www.imo.org/fr/OurWork/Safety/Pages/LoadLines.aspx
121. https://www.index.hr/vijesti/clanak/tesla-bez-vozaca-se-zabio-u-drvo-dvoje-mrtvih-sad-se-javio-i-elon-musk/2270411.aspx
122. https://www.inria.fr/en/actualites_evenements
123. https://www.kaspersky.com/resource-center/definitions/what-are-bots
124. https://www.lr.org/en/latest-news/lr-defines-autonomy-levels-for-ship-design-and-operation/
125. https://www.maritimenz.govt.nz/commercial/safety/safety-management-systems/default.asp

126. https://www.maritimenz.govt.nz/rules/part-21/Part21-maritime-rule.pdf
127. https://www.marketresearch.com/Stratistics-Market-Research-Consulting-v4058/Humanoid-Robot-Global-Outlook-12684730/
128. https://www.medicalnewstoday.com/articles/320289#carry_message
129. https://www.mise.gov.it/index.php/it/incentivi/impresa/smart-start
130. https://www.moorfields.nhs.uk/landing-page/deepmind-health-research-partnership
131. https://www.nytimes.com/2017/10/26/opinion/algorithm-compas-sentencing-bias.html
132. https://www.nytimes.com/2019/05/30/science/deep-mind-artificial-intelligence.html
133. https://www.offshore-energy.biz/port-of-rotterdam-self-learning-computers-predicting-vessel-arrival-times/
134. https://www.partnershiponai.org/partners/
135. https://www.pfri.uniri.hr/web/dokumenti/uploads_nastava/20190208_194956_vio_POMORSKE_HAVARIJE_I_OSIGURANJE.pdf
136. https://www.portofantwerp.com/en/smart-port
137. https://www.porttechnology.org/news/europes_largest_port_releases_app_to_optimize_shipping/
138. https://www.pravo.unizg.hr/_download/repository/Pomorske_nesrece_sudar_spasavanje_zajednicka_havarija %5B1 %5D.pdf
139. https://www.proofpoint.com/us/threat-reference/petya
140. https://www.recaap.org/about_ReCAAP-ISC
141. https://www.register-iri.com/wp-content/uploads/MSC.1-Circ.1604.pdf
142. https://www.res.es/en
143. https://www.reuters.com/article/us-korea-robots-idUSSEO16657120070507
144. https://www.salesforce.com/products/einstein/ai-deep-dive/
145. https://www.sas.com/en_us/insights/analytics/big-data-analytics.html
146. https://www.sciencedaily.com/terms/humanoid_robot.htm
147. https://www.sciencedirect.com/topics/computer-science/radio-access-network
148. https://www.section.io/engineering-education/intelligent-agents-in-ai/

149. https://www.smh.com.au/technology/the-cyborg-evolution-20030322-gdggw7.html
150. https://www.softbankrobotics.com/emea/en/blog/news-trends/landscape-ai-robotic-guides-museums-cultural-places
151. https://www.sophiagenetics.com/home.html
152. https://www.sperrymarine.com/corporate-history/sperry-marine
153. https://www.statista.com/statistics/1117974/healthcare-industry-profit-growth-by-sector/
154. https://www.talent.com/salary?job=
155. https://www.thedockyards.com/norse-discovery-settlement-iceland-viking-age/
156. https://www.un.org/depts/los/convention_agreements/texts/unclos/unclos_e.pdf
157. https://www.usps.org/national/eddept/ap/files/chapter6_2009_12_22.pdf
158. https://www.verizon.com/about/our-company/5g/5g-latency
159. https://www.washingtonpost.com/gdpr-consent/?next_url=https %3a %2f %2fwww.washingtonpost.com %2ftechnology %2f2020 %2f06 %2f11 %2fmicrosoft-facial-recognition %2f
160. https://www.wired.com/2015/11/google-open-sources-its-artificial-intelligence-engine/
161. https://www.wired.com/story/lasers-hack-amazon-echo-google-home/
162. https://www.youtube.com/watch?v=rbsqaJwpu6A
163. https://wwwcdn.imo.org/localresources/en/MediaCentre/HotTopics/Documents/IMO %20SDG %20Brochure.pdf
164. IBM Cost of a Data breach Report 2019, dostupno na: https://www.ibm.com/downloads/cas/RDEQK07R
165. IDC and TXT Solutions (2014). SMART 2013/0037, „Kombinacija usluga u oblaku i interneta stvari" (Cloud and IoT combination), studija za Europsku komisiju, dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:52017JC0450&from=NL
166. IMO (2018). IMO takes first steps to address autonomous ships, dostupno na: https://www.imo.org/en/MediaCentre/PressBriefings/Pages/08-MSC-99-MASS-scoping.aspx

167. Inmarsat Maritime Handbook. (2016). 4th Issue, London.

168. Ispol'zovanie Robotov i Shirokoe Primenenie Vysokotochnogo Oruzhija Stanut Osnovnymi Osobennostjami Vojn Budushhego – Nachal'nik Genshtaba Rossijskoj Armii [The Use of Robots and the Widespread Use of Precision Weapons Will Be the Main Features of Future *Wars* – Chief of the General Staff of the Russian Army], INTERFAKS, ABN, AGENSTVO BOENNIX NOVOSTEJ [INTERFAX, MNA, MILITARY NEWS AGENCY] (Mar. 24, 2018), dostupno na: http://www.militarynews.ru/ story.asp?rid=1&nid=476975

169. Italia Startup Visa, dostupno na: http://italiastartupvisa.mise.gov.it

170. ITU trends (2018). Emerging trend sin ICT's, Assessing the economic impacts of Artificial Intelligence, No.1

171. ITU News (2020). Africa is at the AI innovation table and 'ready for the next wave', dostupno na: https://www.itu.int/en/myitu/News/2020/06/23/07/55/AI-for-Good-2020-Africa-innovation

172. Izvješće Komisije „Spašavanje života: poboljšanje sigurnosti automobila u EU-u" (COM(2016) 0787 final)

173. Izvješće Komisije o „Politici tržišnog natjecanja za digitalno doba", dostupno na: https://ec.europa.eu/competition/publications/reports/kd0419345enn.pdf

174. Izvješće Svjetske organizacije rada o budućnosti poslova, dostupno na: https://www.ilo.org/infostories/en-GB/Campaigns/future-work/global commission#seizing/challenges

175. Konferentsia "Iskusstvenij Intellect: Problemi I Puti Ikh Reshenia" – 2018" [Conference: "Artificial Intelligence: Problems and Their Solutions" – 2018], Ministry Of Defense Of Russia, dostupno na: http://mil.ru/conferences/is-intellekt.htm

176. Lessons learned from 'Alexandra 1' collision: Confused with Rules of the Road (2019), dostupno na: https://safety4sea.com/cm-lessons-learned-from-alexandra-1-collision-confused-with-rules-of-the-road/

177. Lloyd's Register, Qinetiq, Unoversity of Saouthampton. Global Marine Technology Trends 2030, dostupno na: https://www.lr.org/en/insights/global-marine-trends-2030/global-marine-technology-trends-2030/

178. Maersk (2019). Maersk launches new visibility tool, dostupno na: https://www.maersk.com/news/articles/2019/12/03/maersk-launches-new-visibility-tool-captain-peter

179. Maritime Safety Committee (MSC), 101 session, 5-14 June 2019, dostupno na: http://www.imo.org/en/MediaCentre/MeetingSummaries/MSC/Pages/MSC-101st-session.aspx
180. Maritime Unmanned Navigation through Intelligence in Networks - MUNIN, The Autonomous Ship (2017), dostupno na: http://www.unmanned-ship.org/munin/about/the-autonomus-ship/
181. Maritime Unmanned Navigation through Intelligence in Networks - Research in Maritime Autonomous Systems, Project Results and Technology Potentials. (2016). str. 1, dostupno na: http://www.unmanned-ship.org/munin/wp-content/uploads/2016/02/MUNIN-final-brochure.pdf
182. MAXCMAS success suggests COLREGs remain relevant for autonomous ships (2018), dostupno na: https://www.rolls-royce.com/media/press-releases/2018/21-03-2018-maxcmas-success-suggests-colregs-remain-relevant-for-autonomous-ships.aspx
183. Meeting of the Group of Governmental Experts on Lethal Autonomous Weapons Systems. Statement by France and Germany (under Agenda Item "General Exchange of Views") (Apr. 9–13, 2018)
184. Mission Secure. (2020). A Comprehensive Guide to Maritime Cybersecurity, dostupno na: https://www.missionsecure.com/hubfs/Assets/eBooks/A %20Comprehensive %20Guide %20to %20Maritime %20Cybersecurity_Final.pdf
185. Net losses: Estimating the Global Cost of Cybercrime, Economic impact of cybercrime II, Report Summary, dostupno na: https://csis-website-prod.s3.amazonaws.com/s3fs-public/legacy_files/files/attachments/140609_McAfee_PDF.pdf
186. New Legislation Set to Regulate Russia's Burgeoning Driverless Car Market (2018). THE BELL, dostupno na: https://thebell.io/en/new-legislation-set-to-regulate-russia-s-burgeoning-driverless-car-market
187. Next Generation Artificial Intelligence Development Plan Issued by State Council, China's Strengths Creates Innovation Miracles, China Science and Technology Newsletter, No. 17, 2017, dostupno na: http://fi.china-embassy.org/eng/kxjs/P020171025789108009001.pdf
188. OECD - Ocean shipping and shipbuilding (2020), dostupno na: https://www.oecd.org/ocean/topics/ocean-shipping/

189. OECD (2017), OECD Science, Technology and Industry Scoreboard 2017: The digital transformation, OECD Publishing, Paris, https://doi.org/10.1787/9789264268821-en

190. Policy paper (2017). Autumn Budget 2017, dostupno na: https://www.gov.uk/government/publications/autumn-budget-2017-documents/autumn-budget-2017

191. Pomorske nesreće – sudar brodova, spašavanje i zajednička havarija. Dostupno na: https://www.pravo.unizg.hr/_download/repository/Pomorske_nesrece_sudar_spasavanje_zajednicka_havarija %5B1 %5D.pdf

192. Popis digitalno-inovacijskih centara: https://s3platform.jrc.ec.europa.eu/digital-innovation-hubs tool?p_p_id=digitalinnovationhub_WAR_digitalinnovationhubportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-1&p_p_col_count=1&_digitalinnovationhub_WAR_digitalinnovationhubportlet_cur=2&formDate=1521718574008&freeSearch=&evolStages=3

193. Preparing for the future of Artificial Intelligence (2016). Executive Office of the President National Science and Technology Council National Science and Technology Council Committee on Technology, dostupno na: https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/preparing_for_the_future_of_ai.pdf

194. Press Release (2017). Federal Ministry of Transport and Digital Infrastructure [BMVI], Ethics Commission on Automated Driving Presents Report, dostupno na: https://www.bmvi.de/SharedDocs/EN/publications/report-ethics-commission.pdf?__blob=publicationFile

195. Press Release (2018). Federal Ministry of the Interior, Building, and Community [BMI], Data Ethics Commission Goes to Work, dostupno na: https://www.bmi.bund.de/SharedDocs/pressemitteilungen/EN/2018/data-ethics-commission.html

196. Press Release, Ministero dello Sviluppo Economico [Ministry for Economic Development], Intelligenza Artificiale: Call per Esperti [Artificial Intelligence: Call for

Experts] (Sept. 13, 2018), dostupno na: https://www.sviluppoeconomico.gov.it/index.php/it/intelligenza-artificiale-call

197. PwC (2017). How AI is pushing man and machine closer together, dostupno na: https://www.pwc.in/assets/pdfs/consulting/digital-enablement-advisory1/pwc-botme-booklet.pdf

198. RAPEX Weekly overview report of notifications – week 51 2015, dostupno na: https://www.certifico.com/component/attachments/download/2505

199. Report of the 2018 session of the Group of Governmental Experts on Emerging Technologies in the Area of Lethal Autonomous Weapons Systems (2018), ¶ 9, dostupno na: https://undocs.org/pdf?symbol=en/CCW/GGE.1/2018/3

200. Respuesta del Gobierno [Government Answer], Pregunta Escrita Senado [Written Question Senate] 684/77289, June 17, 2015, dostupno na: http://www.senado.es/web/expedientdocblobservlet?legis=10&id=190036

201. Safety Management System (SMS) vidjeti na: https://www.marineinsight.com/marine-safety/what-is-safety-management-system-sms-on-ships/

202. Society of Automotive Engineers. 2018. Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles J3016_201806, dostupno na https://www.sae.org/standards/content/j3016_201806/

203. Stanford news, “New Stanford research finds computers are better judges of personality than friends and family”, dostupno na: http://news.stanford.edu/2015/01/12/personality-computer-knows-011215/

204. Statement by the Chinese Delegation at the Thematic Debate on Conventional Weapons at the First Committee of the 73rd Session of the UNGA, dostupno na: https://www.un.org/disarmament/wp-content/uploads/2018/11/statement-by-china-cw.pdf

205. Stanić, M. (2016). GMDSS i komuniciranje kao problem, Pomorski fakultet Sveučilišta u Splitu

206. Study On The Human Rights Dimensions Of Automated Data Processing Techniques (In Particular Algorithms) And Possible Regulatory Implications, dostupno na: https://rm.coe.int/study-on-algorithmes-final-version/1680770cbc

207. The 13th Five Year Plan for Economic and Social Development of the People's Republic of China. (2016). Central Compilation & Translation Press, dostupno na: https://en.ndrc.gov.cn/policyrelease_8233/201612/P020191101482242850325.pdf

208. The Guardian, "The great British Brexit robberty: how our democracy was hijacked", 7 May 2017, dostupno na: https://www.theguardian.com/technology/2017/may/07/the-great-british-brexit-robbery-hijacked-democracy

209. The Rapid Alert System for Non-Food Products (RAPEX), dostupno na: https://ec.europa.eu/consumers/consumers_safety/safety_products/rapex/alerts/?event=viewProduct&reference=A12/0157/19&lng=en

210. U.S. Department of Defense (2020). Global positioning system standard positioning service performance standard, dostupno na: https://www.gps.gov/technical/ps/2020-SPS-performance-standard.pdf

211. U.S. Department of Transportation (2017). Automatic driving systems 2.0: A Vision for Safety, dostupno na: https://www.nhtsa.gov/sites/nhtsa.dot.gov/files/documents/13069a-ads2.0_090617_v9a_tag.pdf

212. U.S. Department of Transportation (2018). Automated Vehicles 3.0: Preparing for the future of transportation, dostupno na: https://www.transportation.gov/sites/dot.gov/files/docs/policy-initiatives/automated-vehicles/320711/preparing-future-transportation-automated-vehicle-30.pdf

213. UN activities on AI (2018), dostupna na: https://www.itu.int/dms_pub/itu-s/opb/gen/S-GEN-UNACT-2018-1-PDF-E.pdf

214. United Nations Conference on Trade and Development, (2020). Review of Maritime Transport 2020. dostupno na: https://unctad.org/system/files/official-document/rmt2020_en.pdf

215. United Nations Office at Geneva, "Background on Lethal Autonomous Weapons Systems in the CCW", dostupno na: https://www.unog.ch/80256EE600585943/

216. Whoever Leads in AI Will Rule the World': Putin to Russian Children on Knowledge Day (2017). RUSSIA TODAY, dostupno na: https://www.rt.com/news/401731-ai-rule-world-putin/

217. Why Humans Learn Faster Than AI - for now (2018). MIT Technology Review, dostupno na: https://www.technologyreview.com/2018/03/07/3241/why-humans-learn-faster-than-ai-for-now/

218. Work for a Brighter Future. Report of the Global Commission on the Future of Work, dostupno na: https://www.ilo.org/infostories/en-GB/Campaigns/future-work/global-commission#seizing/challenges

SIGURNOST SUSTAVA UMJETNE INTELIGENCIJE U MEĐUNARODNOM POMORSKOM PROMETU

SAŽETAK

Naslov rada može vrlo lako sugerirati kako se obrađuje tema koja je iz područja tehničkih znanosti što ovdje nije slučaj. Sigurnost sustava umjetne inteligencije (AI) u međunarodnom pomorskom prometu je obrađena interdisciplinarnim, multidisciplinarnim i transdisciplinarnim pristupom ponajviše u području društvenih znanosti. Sukladnom navedenom, za pojam AI možemo reći kako predstavlja nepoznanicu široj javnosti i ostavlja nejasnoće u samoj integraciji sustava AI u poslovanje i/ili djelovanje određenih poduzeća i poslovnih subjekata. AI je tehnologija koja će transformirati svaki životni sloj, odnosno omogućiti će ljudskim korisnicima da na brži i točniji način analiziraju podatke, integriraju informacije, a dobivene rezultate upotrijebe za poboljšanje procesa donošenja odluka. Ovom doktorskom disertacijom, u jednom dijelu, nastoji se ukazati na prednosti i nedostatke korištenja sustava AI kroz interdisciplinarni, multidisciplinarni i transdisciplinarni pristup, odnosno na elemente kojim AI već sada mijenja svijet i istaknuti važna pitanja koja će biti usmjerena na zakonodavstvo, društvo, sigurnost, gospodarstvo i upravljanje sustavima AI. Primjerice, korištenje AI u prometnim sustavima rezultira poluautonomnim ili autonomnim vozilima / plovilima koji operaterima daju do znanja o nadolazećim zagušenjima i smetnjama, odnosno sudjeluju u izradi optimalne plovne rute s obzirom na vremenske prilike, željenu uštedu goriva i sl. Napredni senzori, moderni algoritmi te ostala softverska i hardverska rješenja u određenom dijelu već sada mogu zamijeniti ljudsko iskustvo i time smanjiti mogućnost za pogreške. Sukladno navedenom, poseban naglasak stavljen je na sigurnost sustava AI u međunarodnom pomorskom prometu s pripadajućim dodatnim istraživanjima. Dodatna istraživanja temeljila su se pravnoj regulaciji AI u međunarodnom pomorskom prometu i komparativnoj analizi pravnih izvješća iz područja AI za izabrane države. Pravni okvir AI u međunarodnom pomorskom prometu temeljio se na ključnim međunarodnim pomorskim organizacijama, odnosno pravnim aktima koji uređuju pomorsko gospodarstvo i mogućoj potrebi za ažuriranjem istih sukladno nadolazećoj primjeni AI u međunarodnom pomorskom prometu.

Nakon obrade temeljnih pravnih akata u povezivosti s AI naglasak je stavljen na primjenu AI u društvu i njen društveni utjecaj. Shodno tome razrađena je povijest razvoja AI i sami razvoj pomorske navigacije te su razjašnjeni pojavni oblici sastavnica AI. Ovim radom nastojala se

definirati sama AI, odnosno istinska AI s forenzičkog aspekta što može rezultirati vrijednim znanstvenim doprinosom, posebice ako se u obzir uzmu nebrojeni pokušaji svjetskih stručnjaka da se AI definira na ujednačen način. S obzirom da društvene vrijednosti i etičke norme predstavljaju značajne odrednice u razvoju umjetnih sustava koji bi donosili odluke umjesto i uz pomoć ljudi, Etičke smjernice za stvaranje pouzdane AI su posebno obrađene u društvenom dijelu ovog rada. U tu kategoriju spadaju načelo ljudske autonomije, načelo sprječavanja nastanka štete, načelo pravednosti i objašnjivosti kao i ljudsko djelovanje i nadzor, te tehnička otpornost i sigurnost sustava, privatnost, transparentnost, raznolikost, nediskriminacija, dobrobit društva i okoliša, ali i odgovornost. Nadovezujući se na Etičke smjernice djelovanja sustava AI obrađeni su elementi koji su nužni u stvaranju takvih sustava i stjecanju povjerenja u njih. To uključuje elemente poput objašnjivosti i odgovornosti sustava AI, odnosno provjerljivosti i pravednosti. S obzirom na to da će AI imati značajan utjecaj na društvo u poslovnom kontekstu posebno je analizirano stanje u svijetu poslova s naglaskom na međunarodni pomorski promet, prilike i izazovi, odnosno mogućnosti i ograničenja AI u tom aspektu društvenog djelovanja. Kao potpora tezi da će AI imati značajan društveni utjecaj radom su analizirani su i tzv. Asilomarski principi AI, odnosno moralne i etičke dileme koje mogu proizaći iz upotrebe AI u društvu i značajnim gospodarskim subjektima. Naposljetku, skrenuta je i pozornost na ekonomske faktore upotrebe AI u društvu, odnosno utjecaju na bruto domaći proizvod (BDP) i potencijalne reforme poreznog sustava.

U trećem dijelu ove doktorske disertacije analizirana je upotreba sustava AI u međunarodnom pomorskom prometu, odnosno sigurnost istog. Uvodno je napravljen pregled elektroničkih navigacijskih uređaja kao onih uređaja koji bi tvorili podsustave sustava AI u međunarodnom pomorskom prometu. Upotreba AI u pomorstvu ponajviše se očituje kroz autonomne brodove, digitalne luke, virtualne asistente, preciznoj obradi dokumenata i ekološki prihvatljivim pristupom upotrebe AI. S obzirom da je autonomna navigacija „najzvučniji“ sustav koji bi koristio AI, isti su posebno analizirani kroz prizmu odgovornosti upravljanja AI takvim plovilima, odnosno ukazane su prednosti i nedostaci sustava AI u autonomnim plovila što je rezultiralo modelom poboljšanja postojećih sustava. Također, znanstveni doprinos ovog rada se može očitovati i u analiziranju sigurnosnog i tehničkog nadzora brodskih elektroničkih navigacijskih uređaja i modela određivanja sigurnosti sustava AI u međunarodnom pomorskom prometu. Uzimajući u obzir da su sustavi AI temeljeni na „online“ djelovanju bilo lokalno ili globalno, posebno se istražila sigurnost sustava AI u kibernetičkom prostoru. Stavljajući

naglasak na prevenciju umjesto na sanaciju mogućih kibernetičkih ugroza važno je donijeti ključne planove i procedure za sustave AI na brodu odnosno identificirati prijetnje i ranjivosti te procijeniti vjerojatnost da se kibernetička ugroza može dogoditi, te kakav će utjecaj imati i koji rizik to nosi. Naposljetku, takav pristup ima za cilj razviti mjere zaštite kao i detekcijske mjere i pružiti odgovor na moguće kibernetičke incidente. Svi navedeni elementi za krajnji cilj imaju povećati sigurnost sustava AI u međunarodnom pomorskom prometu.

Ključne riječi: umjetna inteligencija, međunarodni pomorski promet, sigurnost, pravna regulativa, etičke smjernice.

SECURITY OF ARTIFICIAL INTELLIGENCE SYSTEMS IN INTERNATIONAL MARITIME TRAFFIC

SUMMARY

The title of the paper can very easily suggest that a topic is from the field of technical sciences, which is not the case here. The security of Artificial Intelligence systems (AI) in international maritime transport is addressed by an interdisciplinary, multidisciplinary and transdisciplinary approach, especially in the field of social sciences. Accordingly, the term AI can be said to represent a technology that will transform every layer of life, ie it will enable human users to analyze data, integrate information in a faster and more accurate way, and use the obtained results to improve the decision-making process. This doctoral dissertation, in one part, tries to point out the advantages and disadvantages of using the AI systems through an interdisciplinary, multidisciplinary, and transdisciplinary approach, ie point out the elements by which AI is already changing the world and highlight important issues that will focus on legal aspects, society issues, security challenges, economy and management of AI systems. AI systems can learn and adapt in decision making process. For example, the use of AI in transport systems results in semi-autonomous or autonomous vehicles / vessels that inform operators about upcoming traffic jams and distrubances, or participate in the creation o fan optimal navigation route concering weather conditions, desired fuel savings, etc. Advanced sensors, modern algorithms and othet software and hardware solutions in a certain part, already now, can replace human operators and their experience and thus reduce the possibility of errors. Following the above, special emphasis is placed on the safety of the AI system in international maritime transport with the accompanying additional research. Additional research was based on the legal regulation of AI in international maritime transport and a comparative analysis of legal reports in the field of AI for selected countries. The legal framework of AI in international maritime transport was based on key international maritime organizations and legal acts governing the maritime economy and the possible need to update them following the forthcoming application of AI in international maritime transport.

After the processing of basic legal acts regarding the AI, the emphasis was placed on the application of AI in society and its social impact. Accordingly, the history of AI development and the development of maritime navigation itself have been elaborated, and the manifestations of AI components have been clarified. This disertation tried to define the AI

itself, ie the true AI from the forensic standpoint, which can result in a valuable scientific contribution, especially if we take into account the countless attempts of world experts to define the AI uniformly. Given that social values and ethical norms are important determinants in the development of artificial systems that would make decisions instead of and with the help of people, Ethical gAIdelines for trustworthy AI are specifically addressed in the social part of this paper. This category includes the principle of human autonomy, the principle of harm prevention, the principle of fairness and explainability as well as human action and supervision, and technical resilience and security of the system, privacy, transparency, diversity, non-discrimination, social and environmental well-being and responsibility. Building on the Ethical Guidelines, the elements necessary for the creation of such systems and gaining trust in them are discussed. This includes elements such as the explainability and accountability of the AI system, ie verifiability and fairness. Given that AI will have a significant impact on society in the business aspect, the situation in the world of business is especially analyzed with emphasis on international maritime transport, opportunities and challenges and advantages and limitations of AI in this aspect of social action. In support of the thesis that AI will have a significant social impact, the so-called Asilomar principles of AI are analyzed, ie moral and ethical dilemmas that may arise from the use of AI in society and significant economic entities. Finally, attention was drawn to the economic factors of the use of AI in society, ie the impact on gross domestic product (GDP) and potential reforms of the tax system.

In the third part of this doctoral dissertation, the emphasis is placed on the use of AI in international maritime transport, i.e. its safety. An introductory overview of electronic navigation devices as those devices that would form subsystems of the AI system in international maritime transport was made. The use of AI in maritime affairs is mostly manifested through autonomous ships, digital ports, virtual assistants, precise document processing and an environmentally friendly approach. Since autonomous vessels are most known systems that would use AI, they are specifically analyzed through the prism of AI management responsibilities of such vessels, ie the advantages and disadvantages of AI systems in autonomous vessels are indicated, which resulted in a model of improving existing systems. Also, the scientific contribution of this paper can be valued through the analysis of safety and technical supervision of ship electronic navigation devices and the model for determining the safety of the AI system in international maritime traffic. Considering that AI systems are based on online operations either locally or globally, the security of AI systems in cyberspace has

been specifically analyzed. With an emphasis on prevention rather than remediation of potential cyber threats, it is important to adopt key plans and procedures for on-board AI systems, identify threats and vulnerabilities, and assess the likelihood that cyber threats may occur, and what impact and risk it will carry. Finally, such an approach aims to develop protection measures as well as detection measures and provide a response to possible cyber incidents. All these elements have the ultimate goal of increasing the safety of the AI system in international maritime traffic.

Key words: *artificial intelligence, international maritime traffic, safety, legislation, ethical guidelines.*

POPIS OZNAKA I KRATICA

Kratica	Strani jezik	Hrvatski jezik
ABM	Agent-based modeling	Modeliranje zasnovano na agentima
ADR	Alternative Dispute Resolution	Mehanizam alternativnog rješavanja sporova
AEPIA	Asociación Espanola de Inteligencia Artificial	Španjolsko udruženje za AI
AES	Airplane Earth Stations	Zrakoplovne zemaljske stanice
AIA	Abstract intelligent agents	Apstraktni opisi inteligentnih agenata
AIDP	New Generation Artificial Intelligence Development Plan	Plana razvoja AI nove generacije
AIMA	Artificial Intelligence Magazine	Časopis o AI
AJL	Algorithm Justice League	Algoritamska liga pravde
ALU	Arithmetic Logic Unit	Aritmetička logička jedinica
AmI	Ambiental Intelligence	Ambijentalna inteligencija
AMSA	Australian Maritime Safety Authority	Australska uprave za pomorsku sigurnost
ANN	Artificial Neuron Network	Umjetne neuronske mreže
ARPA	Automatic radar plotting aid	
ASI	Artificial SuperIntelligence	Superinteligencija
ATA	Automatic Tracking AID	
BD	Big Data	Veliki podaci
BDA	Big Data Analytics	Analiza velikih podataka
BDP	./.	Bruto domaći proizvod
BENU	./.	Brodski elektronički navigacijski uređaji

BIJELA KNJIGA	European Commission White Paper on Artificial Intelligence – A European approach to excellence and trust	./.
BPS	Bayesian program synthesis	Bayesova sinteza programa
CFAA	Computer Fraud and Abuse Act	Zakon o računalnim prijevarama i zlostavljanjima
CIA	Confidentiality, Integrity, Availability	Povjerljivost, Integritet, Dostupnost
CLL	International Convention on Load Lines	Međunarodna konvencija o teretnoj liniji
CN	Core Network	Jezgra mreže
CNIL	National Commission on Computer Technology and Civil Liberties	Komisije za računalnu tehnologiju i građanske slobode
COLREG	Convention on International Regulations for Preventing Collisions at Sea	Konvencija o međunarodnim pravilima o izbjegavanju sudara na moru
CPS	Cyber - Physical System	Kiber - fizički sustavI
CPU	Central Processing Unit	Upravljačka jedinica
CSO	Company security officer	Korporativni sigurnosni časnici
CSSO	Cyber Security Ship Officer	Brodski časnik za kibersigurnost
CTC	Connectionist Temporal Classification	Konekcionistička vremenska klasifikacija
CV	Computer Vision	Računalni vid
DARPA	Defense Advanced Research Projects Agency	Američka Agencija za napredne istraživačke projekte obrane

Direktiva 2016/1148	DIRECTIVE (EU) 2016/1148 OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL of 6 July 2016 concerning measures for a high common level of security of network and information systems across the Union	Direktiva (EU) 2016/1148 Europskog Parlamenta i Vijeća od 6. srpnja 2016. o mjerama za visoku zajedničku razinu sigurnosti mrežnih i informacijskih sustava širom Unije, OJ L 194
Direktiva 1999/34	DIRECTIVE 1999/34/EC OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL of 10 May 1999 amendingCouncil Directive 85/374/EEC on the approximation of the laws, regulations and administrative provisions of the Member States concerningliability for defective products	Direktiva 1999/34/EZ Europskog parlamenta i Vijeća od 10. svibnja 1999. o izmjeni Direktive Vijeća 85/374/EEZ o usklađivanju zakona i drugih propisa država članica u vezi s odgovornošću za neispravne proizvode, OJ L 141
DoC	Document of Compliance	Dokument o sukladnosti
DGPS	Differential Global Positioning System	Diferencijalni svjetski sustav za pozicioniranje
DL	Deep Learning	Duboko učenje
DM	Data Minning	Rudarenje podataka
DP	Dynamic Possitioning	Dinamičko pozicioniranje
DSC	Digital Selective Calling	Selektivno digitalno pozivanje

ECDIS	Electronic Chart Display and Information System	Elektronički pokazivač pomorskih karata s informacijskim sustavom
ECR	Engine Control Room	Upravljački centar motora
EDR	Early Dispute Resolution	Mehanizam ranog rješavanja sporova
EKLJP	European Convention on Human Rights	Europska konvencija za zaštitu ljudskih prava i temeljnih sloboda
ENISA	European Network and Information Security Agency	Agencija EU za mrežu i informacijsku sigurnosT
EPIRB	Emergency Position-Indicating Radio Beacon	Radio plutače za određivanje mjesta pogibelj
ESLJP	European Court of Human Rights	Europski sud za ljudska prava
Etičke smjernice	The Ethics Guidelines for Trustworthy Artificial Intelligence	Etičke smjernice za pouzdanu AI
EU	European Union	Europska Unija
EUMSS	European Union Maritime Security Strategy	EU Strategija sigurnosti za pomorstvo
FAL	Convention on facilitations of International Maritime Traffic	Konvencija o olakšicama u međunarodnom pomorskom prometu
FDI	Foreign Direct Investment	Izravna strana ulaganja
FRAAI	./.	Francuska strategija AI
GAI	General Artificial Intelligence	Opća AI
GAN	Generative Adversarial Networks	Generativne suparničke mreže
GAP	./.	Analiza raskoraka

GBS	Goal – Based Standards	Pristup zasnovan na ciljevima
GBS-SLA	Goal – Based Standards and Safety – Level Approach	Pristup zasnovan na ciljevima i sigurnosnim prisupom
GDPR	General Data Protection Regulation	Opća uredba o zaštiti podataka
GHG	Green House Gas	Emisija stakleničkih plinova
GIA	Global Industry Alliance	Svjetsko industrijsko udruženjE
GLONASS	Global Navigation Satellite system	Globalni navigacijski satelitski sustav
GMDSS	Global Maritime Distress and Safety System	Svjetski pomorski sustav za pogibelj i sigurnost
GOFAI	Good old fashioned Artificial Intelligence	./.
GPAI	The Global Partnership on Artificial Intelligence	Globalno partnerstvo za AI
GPS	Global Positioning System	Svjetski sustav za pozicioniranje
HF	High frequency	Visoka frekvencija
HIC	Human-in-command	Ljudsko odlučivanje
HITL	Human-in-the-loop	Ljudska intervencija
HLEG	High Level Expert Group	Stručna skupina na visokoj razini
HOTL	Human-on-the-loop	Ljudski nadzor
HRB	./.	Hrvatski registar brodova
IACS	International Association of Classification Societies	Međunarodno udruženje klasifikacijskih društava

ICLR	The International Conference on Learning Representations	./.
ICS	International Code of Signals	Međunarodni signalni kodeksa
ICT	Information and communication technology	Informacijska i komunikacijska tehnologija
IDS	Intrusion Detection System	Sustav za otkrivanje provale
IHO	International Hydrografic Organization	Svjetska hidrografska organizacije
ILO	International Labour Organization	Međunarodna organizacija rada
ILP	./.	Induktivno logičko programiranje
IMO	International Maritime Organization	Međunarodna pomorska organizacija
INMARSAT	Convention on the International Maritime Satellite Organization	Konvencija o međunarodnoj pomorskoj satelitskoj organizaciji
INRIA	National Institute for Research in Digital Science and Technology	Francuski nacionalni istraživački institut za digitalne znanosti
IoP	Internet of People	Internet Ljudi
IoT	Internet of Things	Internet stvari
IPS	Intrusion Prevention System	Sustav za sprječavanje upada
ISC	Information Sharing Centre	Centar za dijeljenje informacija vezanih za piratstvo
ISPS	The International Ship and Port Facility Security Code	Međunarodni kodeks o sigurnosti brodova i lučkih prostora
IT	Information Technologies	Informacijske tehnologije

IZVJEŠĆE 64	./.	Izvješće o sigurnosti i odgovornosti za AI, IoT i robotiku
Komunikacija – Europska podatkovna strategija	Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions - A European strategy for dana, COM/2020/66 final	Komunikacija Komisije Europskom Parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Europska strategija za podatke, COM/2020/66 final
Komunikacija – Umjetna inteligencija za Europu	Communication from the Commission to the European Parliament, the European Council, the Council, the European Economic and Social Committee and the Committee of the Regions - Artificial Intelligence for Europe, COM(2018) 237 final	Komunikacija Komisije Europskom parlamentu, Europskom vijeću, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija - Umjetna inteligencija za Europu, COM/2018/237 final
KP	./.	Koordinirani plan o AI
Kp	./.	Pravi kurs
KR	Knowlegde Representation	./.
LAN	Local Area Network	Lokalna mreža
LAWS	Lethal Autonomous Weapons Systems	Ubojiti autonomni oružani sustavi
LNG	Liquefied natural gas	Ukapljeni zemni plin
LRIT	Long Range Identification and Tracking	Prepoznavanje brodova na velikoj udaljenosti
LSTM	Long Short-Term Memory	Duga kratkoročna memorija
MAE	Medium Apsolute Error	Srednja apsolutna pogreška

MARPOL	International Convention for the Prevention of Pollution from Ships	Međunarodna konvencija o sprječavanju onečišćenja s brodova
MASS	Maritime Autonomous Surface Ships	Autonomni pomorski površinski brodovi
MCA	Maritime and Coastguard Agency	Agencija za pomorstvo i obalnu stražu UK
MEA	Means End Analysis	./.
MEPC	Marine Environment Protection Committee	Odbor za zaštitu pomorskog okoliša
MES	Mobile Earth Stations	Mobilne zemaljske stanice
MF	Medium frequency	Srednja frekvencija
MIMO	More in More out	Više ulaznih, više izlaznih
ML	Machine Learning	Strojno učenje
MMPI	./.	Ministarstvo mora, prometa i infrastrukture RH
MSC	Maritime Safety Committee	Odbor za pomorsku sigurnost
MTBF	Mean Time Between Failure	Srednje vrijemeizmeđu dva uzastopna kvara
MTRF	Mean Time Repair Failure	Srednje vrijeme otklanjanja kvara
MUNIN	Maritime Unmanned Navigation through Intelligence in Networks	./.
NAI	Narrow Artificial Intelligence	Uska AI
NAVTEX	Navigation Telex	Navigacijski teleks
NCSR	Sub – Committee on Navigation, Communications and Search and Rescue	Pododbor za navigaciju, komunikaciju i potragu i spašavanje

NHTSA	National Highway Traffic Safety Administration	./.
NLP	Natural Language Processing	Obrada prirodnog jezika
NTC	National Transport Commission	./.
OECD	Organisation for Economic Co-operation and Development	Organizacija za ekonomsku suradnju i razvoj
OILPOL	The International Convention for the prevention of pollution of the sea by oil	Međunarodna konvencija o sprječavanju onečišćenja mora naftom / uljem
OPRC	The International Convention on Oil Pollution Preparedness, Response and Co-operation	Međunarodna konvencija o pripravnosti, reakciji i suradnji za slučaj onečišćenja naftom
OT	Operational Technology	Operativna tehnologija
PFSO	Port facility security officer	Sigurnosni časnici za luke
Prijedlog	Proposal for a regulation of the European parliament and of the Council laying down harmonised rules on Artificial Intelligence (Artificial Intelligence act) and amending certain Union legislative acts	Prijedlog Uredbe Europskog parlamenta i Vijeća – Postavljanje usklađenih pravila o AI (akt o umjetnoj inteligenciji) i izmjeni i dopuni određenih zakonodavnih akata EU
PwC	PricewaterhouseCoopers	./.
PZ	Pomorski zakonik	./.
RADAR	Radio detecting and ranging radio	./.

RAI	Rudder Angle Indicator	./.
RAM	Random Access Memory	Memorija s nasumičnim pristupom
RCM	Remote Container Management	./.
RDIAI	RDI Strategy in Artificial Intelligence	Strategija za istraživanje, razvoj i inovacije u području AI
ReCAAP	The Regional Co-operation Agreement on Combating Piracy and Armed Robbery against ships in Asia	Regionalna suradnja u borbi protiv piratstva i oružanih pljački u Aziji
RH	Republic of Croatia	Republika Hrvatska
RNN	Reccurent Neural Network	
RPA	Robotic process automation	Robotska automatizacija procesa
SAE	Society of Automotive Engineers	Društvo inženjera automobila
SCC	Shore Control Center	Odobalni kontrolni centri
SDLD	Speed & Distance Log Device	Uređaj za bilježenje brzine i udaljenosti
SES	Ship Earth Stations	Brodske zemaljske stanice
SME	Small – Medium Enterprises	Mala i srednja poduzeća
SMS	Safety Management System	Sustavi sigurnosnog menadžmenta
SOAR	Security orchestration, automation and response	
SOLAS	International Convention for the Safety of Life at Sea	Međunarodna konvencija o zaštiti ljudskih života na moru

SPACE STP	Special trade passenger ship instruments	Dogovor o instrumentima za posebne trgovačke putničke brodove
SSA	Ship Security Assessment	Sigurnosna procjena broda
SSO	Ship security officer	Brodski sigurnosni časnici
SSP	Ship Security Plan	Sigurnosni plan broda
STCW	The International Convention on Standards of Training, Certification and Watchkeeping for Seafarers	Međunarodna konvencija o standardima izobrazbe, izdavanju svjedodžbi i držanju straže pomoraca
STEM	Science, Technology, Engineering, Math	Znanost, tehnologija, inženjerstvo i matematika
S-VDR	Simplified Voyage Data Recorder	Jednostavni uređaj za zapis podataka
TC	Tonnage Convention	Konvencije o baždarenju
THD	Transmitting Heading Device	./.
AI	Artificial Intelligence	Umjetna inteligencija
UN	United Nations	Ujedinjeni Narodi
UNCLOS	United Nations Convention on Law at Sea	Konvencija Ujedinjenih naroda o pravu mora
Uredba 2018/1807		Uredba (EU) 2018/1807 Europskog parlamenta i Vijeća od 14. studenoga 2018. o okviru za slobodan protok neosobnih podataka u Europskoj uniji, OJ L 303
VDR	Voyage Data Recorder	Uređaj za zapis podataka
VDES	VHF Data Exchange System	VHF sustav za razmjenu podataka
VHF	Very high frequency	Vrlo visoka frekvencija

VLAN	Virtual LAN	Virtualna lokalna mreža
Vodič	BIMCO, CLIA, ICS, INTERCARGO, INTERMANAGER, INTERTANKO, IUMI, OCIMF, WORLD SHIPPING COUNCIL, The Guidelines on Cyber Security Onboard Ship, (Ver.3),	Vodič za kibernetičku sigurnost na brodovima
VPN	Virtual Private Network	Virtualna privatna mreža
VR/AR	Virtual reallity / Augumented reallity	Virtualna stvarnost / Proširena stvarnost
VTS	Vessel traffic services	Praćenje prometa plovila
WBAI	Libro Blanco de Inteligencia Artificial	Bijela knjiga o AI
WHO	World Health Organization	Svjetska Zdravstvena Organizacija
ZOO	./.	Zakon o obveznim odnosima

POPIS SLIKA

Slika 1-1 Sažeti prikaz sustava sigurnosti AI u međunarodnom pomorskom prometu.....11
Slika 2-1 Prikaz pravnih propisa u području AI.....51
Slika 2-2 Korištenje AI u specifičnim područjima organizacije 67
Slika 2-3, Model istraživanja komparativnih pravnih izvješća 68
Slika 2-4 Savezne države s donesenim zakonodavstvom o autonomnim vozilima i izvršnim naredbama.....80
Slika 2-5 Pet razina autonomne vožnje 89
Slika 3-1 Slojevitost modela ANN 117
Slika 3-2 Model djelovanja jednostavnog agenta.....118
Slika 3-3 . Model agenta za učenje.....124
Slika 3-4 Vrste AI s pripadajućim definicijama 141
Slika 3-5 Valovi razvoja AI.....142
Slika 3-6 Struktura smjernica za pouzdanu AI.....150
Slika 3-7 Međusobni odnosi sedam zahtjeva (važnost, podupiranje, procjena tijekom životnog ciklusa) 154
Slika 3-8 Karta najnovijih zbivanja u etici AI u svijetu 161
Slika 4-1 Povezani uvjeti za Industriju 4.0.....213
Slika 4-2 Patenti u području AI, ...235
Slika 4-3 Projektirani porasti u BDP-u zbog AI u raznim regijama svijeta 236
Slika 5-1 Autonomni brod, kako se pretpostavlja u projektu MUNIN, simbioza je broda na daljinsko upravljanje i automatskog broda.....257
Slika 5-2 Odnos sustava i entiteta po MUNIN-u,.....261
Slika 5-3 Sustav odlučivanja na brodu koji se provodi u MUNIN-u. 262
Slika 5-4 Model određivanja sigurnosti sustava AI.....277
Slika 6-1 Prikaz sustava sigurnosti AI u međunarodnom pomorskom prometu 291
Slika 6-2 Model razvoja mjera zaštite 314
Slika 6-3 Faze odgovora na kibernetički incident 316
Slika 7-1 Matrica korelacija 320
Slika 7-2 KMO i BaT vrijednosti 321
Slika 7-3 Udio odgovora prema spolu.....321
Slika 7-4 Udio odgovora prema dobi 322

Slika 7-5 Radna mjesta ispitanika 322
Slika 7-6 AI je zadovoljavajuće pravno regulirana u kontekstu opće primjene 323
Slika 7-7 AI je zadovoljavajuće pravno regulirana u kontekstu primjene u međunarodnom pomorskom prometu 323
Slika 7-8 Pravni okvir za klasifikaciju AI u međunarodnom pomorskom prometu je unificiran 324
Slika 7-9 Sustavi AI mogu imati etička obilježja 325
Slika 7-10 Odgovornost u slučaju kvara AI 325
Slika 7-11 Nužnost posjedovanja ovlaštenja od strane AI 326
Slika 7-12 Utjecaj AI na smanjenje broja radnih mjesta 327
Slika 7-13 Sustav AI može u potpunosti zamijeniti čovjeka 327
Slika 7-14 Oporezivanje dobiti od AI 328
Slika 7-15 Vrednovanje sustava AI novim metodama 330
Slika 7-16 Manipulacija AI od strane čovjeka 330
Slika 7-17 Sigurnost primjene AI u međunarodnom pomorskom prometu 331

POPIS GRAFIKONA

Grafikon 5-1 Podskup A 287
Grafikon 5-2 Podskup B 287
Grafikon 5-3 Podskup C 288
Grafikon 5-4. Skup AI 289

POPIS TABLICA

Tablica 3-1 Unutarnja struktura organizacije za AI 159
Tablica 4-1 Asilomarski principi, Pitanja istraživanja 222
Tablica 4-2 Asilomarski principi, Etika i vrijednosti 224
Tablica 4-3 Asilomarski principi, Dugoročna pitanja 226
Tablica 5-1 Podskupovi skupa AI 276
Tablica 5-2 Tablica vrednovanja elemenata podsustava sustava AI 279
Tablica 6-1 Primjer mapiranja uloga i odgovornosti 296

Tablica 6-2 Prikaz aktera, motivacija i ciljeva 298
Tablica 6-3 Procjena rizika 306
Tablica 6-4 Razine utjecaja - SMS 307
Tablica 6-5 Razine potencijalnog utjecaja ugroza 308
Tablica 7-1 Pravila za odlučivanje na temelju koeficijenta Cronbach's Alfa 319
Tablica 7-2 Koeficijent pouzdanosti provedene ankete 320

ANKETNI UPITNIK

STAVOVI EKSPERATA U PODRUČJU UMJETNE INTELIGENCIJE IZ PRAVNOG, SOCIOLOŠKOG I SIGURNOSNOG ASPEKTA.

Anketa je anonimna i provodi se u svrhu izrade doktorske disertacije pri Sveučilištu u Zadru i Libertas međunarodnom sveučilištu. Podaci prikupljeni u anketi neće se upotrebljavati ni u koju drugu svrhu, a obrada istih vođena je načelima i odredbama Opće uredbe o zaštiti podataka 2016/679 i Zakonu o provedbi Opće uredbe o zaštiti podataka (Narodne novine br. 42/2018). Anketa sadrži 17 pitanja i iziskuje najviše 10 minuta Vašeg vremena.

Unaprijed zahvaljujem na sudjelovanju u anketiranju.

1. Vaš spol:
    a. M
    b. Ž
    c. Ne želim se izjasniti
2. Vaša dob:
    a. 18 – 24
    b. 25 – 35
    c. 36 – 45
    d. 46 – 55
    e. > 55
3. Jeste li zaposleni u IT sektoru?
    a. Da
    b. Ne
4. Ako je Vaš odgovor na prethodno pitanje DA, koji je naziv Vašeg radnog mjesta u tvrtki? Ako je Vaš odgovor na prethodno pitanje NE, preskočite ovo pitanje.
    a. _____
5. Pravno temeljeno, umjetna inteligencija je zadovoljavajuće regulirana u kontekstu opće primjene.
    a. U potpunosti se ne slažem
    b. Djelomično se ne slažem
    c. Niti se slažem niti se ne slažem
    d. Djelomično se slažem
    e. U potpunosti se slažem

6. Pravno temeljeno, umjetna inteligencija je zadovoljavajuće regulirana u kontekstu primjene u međunarodnom pomorskom prometu.
    a. U potpunosti se ne slažem
    b. Djelomično se ne slažem
    c. Niti se slažem niti se ne slažem
    d. Djelomično se slažem
    e. U potpunosti se slažem
7. Pravni okvir za klasifikaciju umjetne inteligencije u međunarodnom pomorskom prometu je unificiran.
    a. U potpunosti se ne slažem
    b. Djelomično se ne slažem
    c. Niti se slažem niti se ne slažem
    d. Djelomično se slažem
    e. U potpunosti se slažem
8. Sustavi umjetne inteligencije mogu imati etička obilježja.
    a. U potpunosti se ne slažem
    b. Djelomično se ne slažem
    c. Niti se slažem niti se ne slažem
    d. Djelomično se slažem
    e. U potpunosti se slažem
9. Manipulacija umjetnom inteligencijom od strane čovjeka je moguća.
    a. U potpunosti se ne slažem
    b. Djelomično se ne slažem
    c. Niti se slažem niti se ne slažem
    d. Djelomično se slažem
    e. U potpunosti se slažem
10. Koliko sigurnom smatrate primjenu umjetne inteligencije u međunarodnom pomorskom prometu? (autonomna plovila, sustavi dinamičkog pozicioniranja, sustavi automatskog identificiranja, područja odvojene plovidbe, odobalno inženjerstvo i tehnologije (off shore) i sl.)
11. najmanja vrijednost, 5 – najveća vrijednost)
    a. 1
    b. 2

c. 3

d. 4

e. 5

12. Odgovornost u slučaju kvara sustava umjetne inteligencije u međunarodnom pomorskom prometu odnosi se na:

    a. Tvrtku proizvođača sustava

    b. Razvojnog programera i/ili tima tvrtke proizvođača sustava

    c. Podijeljena odgovornost tvrtke proizvođača sustava i/ili tima razvojnih programera

    d. Brodarsko poduzeće

    e. Odgovornost ovisi o vrsti kvara (tehnički kvarovi, greške u kodu, ignoriranje upozorenja sustava i slično)

    f. Ostalo _____

13. Sigurnost sustava umjetne inteligencije može se vrednovati novim metodama.

    a. U potpunosti se ne slažem

    b. Djelomično se ne slažem

    c. Niti se slažem niti se ne slažem

    d. Djelomično se slažem

    e. U potpunosti se slažem

14. Sustav umjetne inteligencije može u potpunosti zamijeniti čovjeka.

    a. U potpunosti se ne slažem

    b. Djelomično se ne slažem

    c. Niti se slažem niti se ne slažem

    d. Djelomično se slažem

    e. U potpunosti se slažem

15. Prilikom upravljanja brodovima čovjek mora imati odgovarajuća ovlaštenja. Što smatrate nužnim da bi umjetna inteligencija trebala posjedovati u međunarodnom pomorskom prometu?

    a. Tipska odobrenja, tehničke i ostale specifikacije izdane od nadležne regulatorne međunarodne organizacije za umjetnu inteligenciju

    b. Odgovarajuće licencirane programe

    c. Ne treba imati ovlaštenja

    d. Nije usporedivo

e. Ostalo _____

16. Masovna primjena umjetne inteligencije će značajno utjecati na smanjenje broja radnih mjesta.
    a. U potpunosti se ne slažem
    b. Djelomično se ne slažem
    c. Niti se slažem niti se ne slažem
    d. Djelomično se slažem
    e. U potpunosti se slažem
17. Dobit tvrtke ostvarene korištenjem umjetne inteligencije, a koja je zamijenila čovjeka na određenom radnom mjestu, treba biti posebno oporezivana.
    a. U potpunosti se ne slažem
    b. Djelomično se ne slažem
    c. Niti se slažem niti se ne slažem
    d. Djelomično se slažem
    e. U potpunosti se slažem

ŽIVOTOPIS

Marko Pilić, *mag. forens.*, rođen je 1989. godine u Splitu gdje je završio srednju Grafičku školu - smjer Web dizajner u Splitu. Upisao je stručni studij na visokoj poslovnoj školi "Minerva" – smjer Menadžment informacijskih sustava gdje je završni rad pod naslovom *"Informacijski sustav i bežične mreže"* i mentorstvom doc. dr. sc. Marije Boban uspješno obranio 2012. godine. Diplomski studij Forenzike upisao je 2014. godine te 2016. godine uspješno obranio diplomski rad pod naslovom *"Europski uhidbeni nalog s osvrtom na sudsku praksu"* pod mentorstvom izv. prof. dr. sc. Damira Primorca.

Od 1. veljače 2018. godine zaposlen je na Sveučilištu u Splitu, Sveučilišnom odjelu za forenzične znanosti gdje obavlja posao asistenta na Katedri za sigurnost i nacionalnu sigurnost. Pri Sveučilišnom odjelu za forenzične znanosti Sveučilišta u Splitu sudjeluje u radu na nizu kolegija poput „Sustavi nacionalne sigurnosti", „Pomorska i podvodna sigurnost", „Forenzika prometnih sustava", „Prevencija i suzbijanje terorizma na globalnoj, regionalnoj i nacionalnoj razini", „Nadzor sigurnosno-obavještajnog sustava", „Korporativna sigurnost" i „Osobna sigurnost i samoobrana". Uz navedeno, Marko Pilić obavlja funkciju tajnika na Katedri za sigurnost i nacionalnu sigurnost i na Katedri za tehničke znanosti u forenzici. Također, vanjski je suradnik na Pravnom fakultetu Sveučilišta u Mostaru, smjer Kriminalistika i sigurnosni menadžment na kojem sudjeluje u nastavi na kolegijima: „Forenzika prometnih sustava", „Nadzor sigurnosno-obavještajnog sustava", „Korporativne istrage i forenzika" i „Sigurnost elektroničke infrastrukture".

Autor i/ili koautor je više radova iz područja sigurnosti, kaznenopravnih znanosti te pomorstva, a koji su objavljeni u priznatim međunarodnim časopisima. Sudionik je više domaćih i međunarodnih znanstvenih konferencija i skupova. Član je Hrvatsko-poljske znanstvene mreže, Hrvatske udruge za umjetnu inteligenciju te Europskog saveza za umjetnu inteligenciju (engl. The European AI Alliance) pri Europskoj Komisiji.

Aktivno je sudjelovao na nekoliko značajnih projekata među kojima je i projekt *"Prepoznaj i spasi me"* u sklopu educiranja o problematici trgovanja ljudima.

Aktivno se služi engleskim jezikom.