

Kognitivni model zatvorene okoline mobilnoga robota temeljen na mjerenjima

Pavlic, Tomislav

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:320631>

Rights / Prava: [In copyright / Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-19**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)





Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Tomislav Pavlic

**KOGNITIVNI MODEL ZATVORENE
OKOLINE MOBILNOGA ROBOTA
TEMELJEN NA MJERENJIMA**

DOKTORSKI RAD

Zagreb, 2021.



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Tomislav Pavlic

**KOGNITIVNI MODEL ZATVORENE
OKOLINE MOBILNOGA ROBOTA
TEMELJEN NA MJERENJIMA**

DOKTORSKI RAD

Mentor:

prof. dr. sc. Mladen Crneković

Zagreb, 2021.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING AND
NAVAL ARCHITECTURE

Tomislav Pavlic

**COGNITIVE MODEL OF CLOSED
ENVIRONMENT OF MOBILE
ROBOT BASED ON
MEASUREMENTS**

DOCTORAL THESIS

Zagreb, 2021.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING
AND NAVAL ARCHITECTURE

Tomislav Pavlic

**COGNITIVE MODEL OF CLOSED
ENVIRONMENT OF MOBILE
ROBOT BASED ON
MEASUREMENTS**

DOCTORAL THESIS

Supervisor:

prof. dr. sc. Mladen Crneković

Zagreb, 2021.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK: 004.8

KLJUČNE RIJEČI: kognitivno ponašanje; strojno učenje; neuronska mreža; umjetna inteligencija; mobilni robot; percepcija okoline; kognitivni model zatvorenog okruženja.

ZNANSTVENO PODRUČJE: Tehničke znanosti

ZNANSTVENO POLJE: Strojarsstvo

INSTITUCIJA U KOJOJ JE RAD IZRAĐEN: Fakultet strojarstva i brodogradnje,
Sveučilište u Zagrebu

MENTOR RADA: dr. sc. Mladen Crneković, red. prof.

BROJ STRANICA: 117

BROJ SLIKA: 34

BROJ TABLICA: 2

BROJ KORIŠTENIH BIBLIOGRAFSKIH JEDINICA: 41

DATUM OBRANE: 07.10.2021.

POVJERENSTVO:

dr. sc. Bojan Jerbić, red. prof. – predsjednik
(Fakultet strojarstva i brodogradnje, Zagreb)

doc. dr. sc. Tomislav Stipančić, dipl. ing. – član
(Fakultet strojarstva i brodogradnje, Zagreb)

dr. sc. Zdenko Kovačić, red. prof. – član
(Fakultet elektrotehnike i računarstva, Zagreb)

INSTITUCIJA U KOJOJ JE RAD POHRANJEN: Fakultet strojarstva i brodogradnje,
Sveučilište u Zagrebu

PODACI O MENTORU

Prof. dr. sc. Mladen Crneković se u znanstvenom radu bavi automatikom, robotikom i primjenom mikrokontrolera. U organiziranom znanstveno-istraživačkom radu sudjeluje od 1987. godine i autor je više od 50 znanstvenih i stručnih radova. Vodio je dva znanstveno-istraživačkih projekta te četiri stručna projekta. Objavio je jedan udžbenik i održao preko 20 javnih predavanja. Doprinos osposobljavanju istraživača dao je kroz mentorstvo jednog magisterija i više od 120 završnih i diplomskih radova. Osim u nastavnim i istraživačkim aktivnostima sudjeluje u ostalim aktivnostima Fakulteta. Od 2004. do 2018. bio je voditelj smjera Mehatronika i robotika, a od 2013. član je Povjerenstva za studijski program. Izradio je elaborat za sveučilišni preddiplomski studij Mehatronika i robotika. Godine 2021. nagrađen je velikom medaljom Fakulteta strojarstva i brodogradnje, ima registriran jedan patent iz 2003. godine pod nazivom KeyBlock (P20030016A), član je znanstvenog odbora CIM-a, recenzent 7 knjiga te recenzent časopisa Transactions of the Institute of Measurement and Control.

Zahvaljujem se svom mentoru prof. dr. sc. Mladenu Crnekoviću na savjetima i pomoći tijekom istraživanja i pisanja rada.

Zahvaljujem članovima povjerenstva, prof. dr. sc. Bojanu Jerbiću, prof. dr. sc. Zdenku Kovačiću i doc. dr. sc. Tomislavu Stipančiću, za pronalaženje vremena za pregled ovog rada, te za sve komentare i primjedbe koje su poboljšale kvalitetu rada.

Zahvaljujem svim dragim prijateljima koji su mi bili spremni pomoći u brojnim malim i velikim stvarima te uvijek bili uz mene.

Na kraju, najveću zahvalnost dugujem svojoj obitelji na beskrajnoj podršci i razumijevanju.

Sažetak

Posljednjih je godina u području mobilne robotike težište na metodama kod kojih se fuzijom mjerenja s više sustava dolazi do modela okoline koji su vjerojatnosnog karaktera. U ovom radu razvijen je novi pristup rješavanju SLAM problema, koji je temeljen na kognitivnom modelu zatvorene okoline mobilnog robota. Kognitivni model okoline je manje precizan od egzaktnog matematičkog, ali je nezaobilazan u interakciji robota s čovjekom.

Predloženo istraživanje bavi se razvojem modela učenja i planiranja djelovanja robota pri istraživanju nepoznatog prostora, na način sličan kako to i čovjek radi. Proces učenja temelji se na virtualnome dinamičkom modelu mobilnog robota, istovjetnom stvarnome robotu. Kretanje robota uvjetovano je razvijenim neuronskim mrežama te genetskim algoritmima.

U ovom radu predložena je nova metoda stvarnog (Sim-To-Real; STR) prijenosa znanja koja uključuje stadij vježbanja, stadij simultanog zaključivanja i stadij primjene naučenog na stvarnome robotu. Korištenjem jezika osnovnih kognitivnih elemenata opisana je okolina robota i njegov odnos prema toj okolini te je na temelju tog opisa dobivena viša razina informacija o stanju okoline u kojoj se robot nalazi, fuzijom mjernih podataka dobivenih iz različitih uređaja.

Video prezentacija istraživanja i eksperimenata dostupna je na sljedećoj poveznici:

<https://youtu.be/KUxVIAe8hSM>

Extended summary

This thesis is organized in 8 sections, as follows:

Section 1: *Introduction*. The first, introductory section, presents the motivation of the research, the overview of the area and the research so far. The main goal of the study is set, followed by a hypothesis. The plan and methodology of research work are presented. The rest of paper is organized as follows.

Section 2: *Problem Description*. In section 2, the primary goal of the research is established. Research work plan and research methodology are presented. Furthermore, the definition of tasks and terms are established.

Section 3: *Mathematical Model of the Mobile Robot*. In section 3, a definition of robot motion with mathematical models of the mobile robot system is described.

Section 4: *Algorithms for Building a Cognitive Model of the eMIR Mobile Robot Environment*. The cognitive model of the closed environment (developed algorithms for a cognitive behaviour of the mobile robot) is thoroughly described in section 4.

Section 5: *Design of a Mechatronic System for Creating a Cognitive Model of Robot Space*. In section 5, the development process of a mechatronic system used in research is described.

Section 6: *Results*. In section 6, experimental validation of the developed control model and the obtained results are described in detail.

Section 7: *Discussion*. The results obtained on the developed real mobile robot system were compared with those obtained by simulations. The applicability of the developed algorithms on a real robot system has been confirmed. This outcome is described in section 7.

Section 8: *Conclusion*. In section 8, an evaluation of the obtained results is discussed, and a critical review is given.

Appendix 1, contains information on additional materials such as codes, images, CAD models, simulation models, etc., and a link to a video of a cross-section of the entire study.

Appendix 2, on the other hand, contains the most important algorithms developed for the successful implementation of this research.

Ključne riječi (Keywords)

Ključne riječi:

- kognitivno ponašanje
- strojno učenje
- neuronska mreža
- umjetna inteligencija
- mobilni robot
- percepcija okoline
- kognitivni model zatvorenog okruženja

Keywords:

- cognitive behaviour
- machine learning
- neural network
- artificial intelligence
- mobile robot
- environment perception
- cognitive model of closed environment

Sadržaj

Sažetak	8
Extended summary.....	9
Ključne riječi (Keywords).....	11
Sadržaj.....	12
Popis slika	15
Popis tablica	18
Popis algoritama.....	19
Popis oznaka i kratica	20
1. Uvod	22
1.1. Pregled dosadašnjih istraživanja	22
1.2. Cilj i hipoteza rada	27
1.3. Struktura rada	28
1.4. Metodologija i plan istraživanja	28
2. Opis problema	30
2.1. Kognitivna robotika i planiranje putanja robota	30
2.1.1. Strojno učenje u svojstvu gradnje kognitivnog modela prostora.....	31
2.2. Kognitivni model zatvorenog prostora mobilnog robota	32
2.3. Opis eksperimentalnog sustava za istraživanje nepoznatog prostora.....	35
3. Matematički model mobilnog robota	42
4. Algoritmi za izgradnju kognitivnog modela okoline	47
4.1. Inicijalizacija neuronskih mreža s nasumičnim težinskim koeficijentima.....	48
4.2. Simulacija i izračun rezultata neuronske mreže	56
4.3. Generiranje neuronske mreže	57

4.4.	Završetak nulte generacije pri generiranju neuronske mreže	58
4.5.	Proces križanja - <i>Crossover</i>	59
4.6.	Proces mutacije - <i>Mutation</i>	60
5.	Dizajn mehatroničkog sustava za izradu kognitivnog modela prostora robota....	63
5.1.	Mehanička struktura mobilnog robota	66
5.2.	Elektronička struktura mobilnog robota.....	68
5.2.1.	Glavni uređaj mobilnog robota	69
5.2.2.	Laserski senzor daljine za istraživanje prostora.....	70
5.2.3.	Pogonski sklop i napajanje.....	71
5.3.	Razvoj programske podrške sustava	72
5.3.1.	Dizajn i treniranje softvera neuronske mreže	73
5.3.2.	PC aplikacija za kontrolu i prikupljanje podataka za izgradnju kognitivnog modela prostora robota (GUI).....	77
5.3.3.	Upravljački softver mobilnog robota	78
5.3.4.	Vizijski sustav za provjeru puta	80
5.3.5.	Izrada kognitivnog modela prostora	82
5.4.	Sustav mreže računala	85
6.	Rezultati	88
6.1.	Usporedba putanja gibanja mobilnog robota u simulaciji i stvarnosti kod izgradnje kognitivnog modela zatvorene okoline	95
7.	Rasprava	97
8.	Zaključak.....	101
	Literatura.....	103
	Prilog 1.....	106
	Prilog 2.....	107
	Životopis	111

Popis objavljenih djela	112
Biography	117

Popis slika

Slika 1. Mobilni roboti: (a) starija generacija opremljena IR senzorima daljine; (b) novija generacija opremljena laserskim senzorom daljine (LiDAR).....	26
Slika 2. Glavni elementi u eksperimentu istraživanja: (a) virtualni poligon s mobilnim robotom (mjerilo 1:1); (b) primjer scene virtualnog poligona za istraživanje s mobilnim robotom, koji se koristi za izgradnju kognitivnog modela prostora.	33
Slika 3. Okruženje robota u poligonu: (a) stvarni poligon, identičan virtualnom, prikazanom na slici 2a, snimljen kamerom za nadzor, postavljenom iznad poligona; (b) realni poligon prilagođen prema virtualnom poligonu prikazanom na slici 2a koristeći proširenu stvarnost [32].	34
Slika 4. Razvoj mobilnog robota eMIR: (a) 3D CAD model eMIR; (b) dinamički model eMIR (CoppeliaSim programski alat za virtualnu stvarnost); (c) izrađeni stvarni mobilni robot eMIR.	37
Slika 5. Različite konfiguracije poligona: (a) 3D CAD modeli tri različite konfiguracije poligona za izgradnju kognitivnog modela ponašanja robota; (b) modeli tri različite konfiguracije poligona definiranih i parametriranih u CoppeliaSim, programskom alatu za virtualnu stvarnost; (c) tri različite konfiguracije poligona s četiri početne pozicije eMIR mobilnih robota korištenih u stadijima učenja, treniranja, simulacije i testiranja naučenih kognitivnih modela ponašanja mobilnog robota u realnim eksperimentima i zadacima istraživanja nepoznatog prostora.	38
Slika 6. CoppeliaSim poligoni virtualne stvarnosti: (a) 3D bočni prikaz konfiguracije poligona s mobilnim robotom u pokretu; (b) skup od tri različita poligona modelirana za učenje i treniranje kognitivnog modela ponašanja mobilnog robota; (c) model poligona u virtualnoj stvarnosti s 10 definiranih detekcijskih zraka laserskog senzora (LiDAR) za otkrivanje prepreka, na svakih 36°, identično konfiguriran kao realna konfiguracija poligona za eksperimentalnu validaciju simuliranih rezultata, prikazana na slici 3a.	40
Slika 7. Kinematički model mobilnog robota diferencijalne strukture.....	42
Slika 8. Inicijalizacija neuronske mreže pri nultoj generaciji.	48
Tablica 1. Eksperimentalno određene vrijednosti korištene u pokusima.	50

Slika 9. Težinski koeficijenti neuronske mreže popunjeni slučajnim brojevima.	51
Slika 10. Opis slojeva neuronske mreže.	52
Slika 11. Matematički opis modificirane Sigmoid aktivacijske funkcije.	53
Slika 12. Dijagram toka izračuna neuronskih mreža.	55
Slika 13. Dijagram procesa generiranja neuronske mreže.	58
Slika 14. Proces križanja težinskih koeficijenata kod generiranja nove neuronske mreže (Crossover).	59
Slika 15. Dijagram toka genetskog algoritma.	60
Slika 16. Proces mutacije (proces promjene šest nasumičnih vrijednosti težinskih koeficijenata).	61
Slika 17. Dijagram toka neuronskih mreža i genetskih algoritama (neuroevolucija).	62
Slika 18. Blok dijagram glavnih dijelova sustava: (a) stadij izrade, učenja i treniranja neuronske mreže; (b) stadij virtualnog testiranja; (c) stadij testiranja na stvarnom sustavu.	63
Slika 19. Blok dijagram cijelog mehatroničkog sustava razvijenog za potrebe istraživanja.	64
Slika 20. eMIR - mobilni robot diferencijalne kinematičke strukture: (a) kinematičke veličine; (b) izgled i raspored pogonskih motora i kotača; (c) položaj LiDAR-a na mobilnom robotu i smjer rotacije (točka C na slici 7).	67
Slika 21. Blok dijagram elektroničkog sustava mobilnog robota.	68
Slika 22. Raspberry Pi 4B SoC računalo.	69
Slika 23. LiDAR u sklopu mobilnog robota: (a) RPLiDAR A2 uređaj; (b) model LiDAR uređaja korišten u simulaciji (CoppeliaSim; jedna zraka svakih 36°); (c) RPLiDAR A2 uređaj instaliran na eMIR-u.	71
Slika 24. Funkcionalni blok dijagram razvijenih softvera korištenih u fazama učenja, simulacije i testiranja naučenih kognitivnih modela istraživanja robota u realnim eksperimentima.	72
Slika 25. PC aplikacija za kontrolu neuronske mreže i prikupljanje podataka.	77
Slika 26. Razvijeni vizijski sustav za provjeru ponašanja robota u naučenome kognitivnome modelu	

njegova prostora: (a) položaj kamere za kontrolu postavljene iznad poligona (shematski prikaz); (b) položaj i orijentacija apsolutnog koordinatnog sustava eksperimentalnog postava (shematski prikaz); (c) generirana putanja (iz video zapisa snimljenog kamerom sa slike 26a) gibanja mobilnog robota (iz samostalno naučenog kognitivnog modela prostora robota) koju je robot trebao proći da bi uspio pretražiti kompletni poligon LiDAR-om.	81
Slika 27. Kognitivni model i kognitivna karta prostora: (a) odabrana konfiguracija poligona; (b) kognitivna karta poligona dobivena simulacijom; (c) eksperiment na stvarnom poligonu s praćenjem putanje kretanja robota; (d) karta zatvorenog prostora dobivena fuzijom podataka dobivenih iz senzora robota, osnova za izgradnju kognitivne karte; (e) tumačenje dobivenih (sposobnošću mobilnog robota za kognitivno istraživanje) informacija na visokoj razini o prethodno nepoznatom okruženju.	84
Tablica 2. Odnosi površina koje se koriste za klasifikaciju otkrivenih objekata u eksperimentu. ...	85
Slika 28. Mreža računala za učenje i treniranje neuronskih mreža.	86
Slika 29. Korisničko sučelje programskog alata Veyon za upravljanje lokalnom mrežom računala.	87
Slika 30. Rezultat kroz generacije neuronske mreže (Linearni oblik).	90
Slika 31. Rezultat kroz generacije neuronske mreže (Sigmoid oblik).	91
Slika 32. Rezultati učenja neuronske mreže kroz generacije neuronske mreže: (a) rezultat istraživanja; (b) ocjena brzine (koeficijent brzine); (c) ocjena razlike (razlika u brzini); (d) ocjena petlji (broj iteracija); (e) ocjena udaljenosti (dosegnuta udaljenost); (f) rezultat kuta otklona (kut između eMIR-a i slobodnog okruženja).	94
Slika 33. Put kretanja mobilnog robota: (a) kognitivna karta modela s putanjom kretanja robota; (b) putanja kretanja pravog robota (pješčani trag); (c) putanja kretanja pravog robota (softverski iscertana u snimljenom video zapisu s kamere).	96
Slika 34. Matematički opis aktivacijskih funkcija korištenih kod neuronskih mreža za potrebe izgradnje kognitivnog modela prostora robota: (a) funkcija u obliku Sigmoida; (b) Funkcija linearnog oblika.	99

Popis tablica

Tablica 1. Eksperimentalno određene vrijednosti korištene u pokusima.50

Tablica 2. Odnosi površina koje se koriste za klasifikaciju otkrivenih objekata u eksperimentu. ...85

Popis algoritama

Algoritam 0-1 „mainwindow“	107
Algoritam 0-2 „thread_1“	107
Algoritam 0-3 „thread_2“	108
Algoritam 0-4 „neuralnetwork“	108
Algoritam 0-5 „geneticalgorithm“	108
Algoritam 0-6 „imageprocessing“	109
Algoritam 0-7 „explore“	109
Algoritam 0-8 „score“	110

Popis oznaka i kratica

Popis oznaka

Oznaka	Značenje	Mjerna jedinica
L	širina između pogonskih kotača robota	m
R	radijus pogonskih kotača robota	m
v	brzina	m/s
ω	kutna brzina	°/s
x_i, y_i	položaj u referentnom koordinatnom sustavu robota	m
θ	orijentacija u referentnom koordinatnom sustavu robota	rad
C	težište robota (ujedno i središte rotacije LiDAR-a)	-
P	središnja točka na osi pogonskih kotača robota	-
d	udaljenost između točaka P i C	m
$(0, X, Y)$	apsolutni koordinatni sustav robota	-
$(0, x, y)$	relativni koordinatni sustav robota	-
x, y	parametri kinematike robota	m
v_R	linearna brzina desnog pogonskog kotača robota	m/s
v_L	linearna brzina lijevog pogonskog kotača robota	m/s
ω_R	kutna brzina desnog pogonskog kotača robota	rad/s
ω_L	kutna brzina lijevog pogonskog kotača robota	rad/s
d_t	vremenska konstanta	ms

Popis kratica

AI	Artificial Intelligence
eMIR	educational Mobile Intelligent Researcher
IR	Infrared Radiation
SLAM	Simultaneous Localization And Mapping
DRL	Deep Reinforcement Learning
STR	Sim-To-Real
RPi	Raspberry Pi
CAD	Computer Aided Design
CAM	Computer Aided Manufacturing
CNC	Computer Numerical Control
NN	Neural Network
GA	Genetic Algorithm
AR	Augmented Reality
GUI	Graphic User Interface
GPIO	General Purpose Input Output
PWM	Pulse-Width Modulation
LiDAR	Light Detection and Ranging
SoC	System on Chip
IDE	Integrated Development Environment
IKP	Inverse Kinematic Problem
HMI	Human Machine Interface
ROI	Region of Interest

1. Uvod

1.1. Pregled dosadašnjih istraživanja

Područje presjeka umjetne inteligencije (engl. *Artificial Intelligence*; AI) i robotike naziva se inteligentna robotika. Tradicionalne metode učenja temeljene na podacima daju dobre rezultate, ali nisu nimalo slične ponašanju čovjeka. Razvijeni pristupi dubokom učenju s pojačanjem (engl. *Deep Reinforcement Learning*; DRL) mogu se koristiti za osposobljavanje robota za postizanje upravljanja s dobrim performansama [1]. Korištenje neuronskih mreža i strojnog učenja ima sve veću primjenu u svim segmentima društva. Tako će i samo ponašanje mobilnih robota u simulacijama, kao i modeliranje virtualnih modela robota istovjetnih realnim robotima, u budućnosti igrati važnu ulogu. Ako pogledamo rješenja koja su postala uobičajena, a pričamo o simulacijama i primjeni dobivenih rezultata na realnim sustavima, možda je jedno od najvažnijih rješenja u CAD/CAM/CNC proizvodnom lancu [2]. Puno istraživanja ima fokus na problemima gdje roboti rješavaju radne scene i zadatke koji su složeni, nepredvidivi i nestrukturirani. U radu [3] se opisuje metoda uvježbavanja virtualnog agenta u simuliranom okruženju s ciljem dostizanja nasumičnog ciljnog položaja iz slučajnog početnog položaja, a zatim se slijed putanje virtualnog agenta dobiven simulacijskim treningom, pretvara u stvarne naredbe robota s transformacijom koordinata za kontrolu robota koji izvršava zadatke. Treba spomenuti da dosta istraživanja prikazuje simulacijske rezultate učenja bez testiranja istih na stvarnim sustavima. Jedno od rijetkih istraživanja prikazuje u [4] implementaciju eksperimentalnih rezultata u dva različita zadatka upravljanja robotom na stvarnim sustavima. Opis razvoja konvolucijske neuronske mreže za kontrolu kućnog robota za nadgledanje opisan je u istraživanju [5]. Mobilni robot diferencijalne strukture je opremljen računalom RaspberryPi za upravljanje kretanjem, a kamera se koristi kao davatelj ulaznih podataka za neuronsku mrežu. Kamerom, kao senzorom za prikupljanje ulaznih vrijednosti u neuronsku mrežu,

koristili su se i autori Wang i dr. u [6]. U istraživanju [6] fokus je na problemu kontrole robota na temelju podataka dobivenih iz vizijskog sustava s kamerom. Predloženi prilagodljivi kontroler zahtijeva isključivo podatke o slici s kalibrirane perspektivne kamere, postavljene u bilo kojem položaju i orijentaciji na robotu. Planiranje putanje mobilnog robota, temeljeno na oblaku točaka, prezentirano je u istraživanju [7]. Svakako treba ukazati na problem nedostatka procesorske snage i radne memorije kod osobnih računala. Kamera kao senzor za prikupljanje ulaznih podataka čini se najpogodnijom, ali to iziskuje obradu velike količine podataka koje treba pohraniti u stvarnom vremenu, bez gubitaka. U istraživanju [8] autori opisuju probleme koji se pojavljuju pri tom procesu. Problem opisa prostora mobilnog robota i traženja putanje između dviju točaka počeo se rješavati početkom 80-tih godina prošloga stoljeća. Prevladavale su metode: metoda konfiguracijskog prostora, metoda potencijalnih polja i metoda ekvidistantnih putanja. Metode su bile strogo determinističke i nisu bile slične načinu kako to radi čovjek, tj. nisu bile kognitivne, već temeljene na gruboj računalnoj snazi. U provedenim istraživanjima, opisanim u [9, 10, 11, 12, 13, 14], dan je opis kognitivnosti mobilnog robota koji je, uz modifikacije u dinamičkome smislu, sličan robotu korištenom u ovome istraživanju. U međuvremenu su se na tržištu pojavili senzori koji su mogli prikupiti veliku količinu podataka (kamere i senzori daljine), a obrada tih informacija postala je lokalna, na SoC računalima kao što je Raspberry Pi (engl. *System on Chip*; SoC). To je u mnogo čemu promijenilo pristup rješavanju problema. Više se nije polazilo od pretpostavke da su nam svi objekti u prostoru zadani i poznati već je zavladao ideja simultane i postupne gradnje modela prostora, tzv. SLAM (engl. *Simultaneous Localization And Mapping*) problem (simultana lokalizacija i mapiranje). Modeli dobiveni podacima s laserskih senzora daljine bili su u obliku oblaka točaka, što je opet vodilo u koordinatne sustave i numeričke oblike podataka. Takve oblike podataka i informacija čovjek teško interpretira ako nije upoznat s matematičkim definiranjem prostora. U proizvodnim procesima imamo visokokvalificirano osoblje (inženjere), koji mogu raditi s kompleksnim sustavima kao što su roboti (razumiju koordinatne sustave, kinematiku, upravljanje, programske jezike). Rad robota u kućanstvima mora biti prilagođen potpuno nestručnim rukovateljima koji ne vladaju nabrojenim pojmovima. To znači da bi u takvog mobilnog robota morale biti ugrađene kognitivne sposobnosti razumijevanja okoline u kojoj se nalazi, od kojih su neki kognitivni elementi: soba, stolica, čovjek, kretanje naprijed, prednost prolaska, osobina pristojnosti itd. To je veoma opsežan zadatak na kojemu će u budućnosti raditi mnogi istraživački timovi i tvrtke. Rješenje navedenih problema i dalje je aktualni izazovni problem. U ovom radu

predložena je nova metoda stvarnog (engl. *Sim-To-Real* - *STR*; dalje u tekstu *STR*) prijenosa naučenog znanja, koja uključuje stadij treniranja, stadij simultanog zaključivanja i stadij primjene naučenog na stvarnome robotu u stvarnoj okolini. U stadiju simulacijskog treninga, simulirano okruženje relevantno za zadatak izrađuje se na temelju semantičkih informacija iz stvarnog scenarija uz pomoć transformacije koordinata, a zatim se naučeno trenira *STR* metodom u izgrađenom simuliranom okruženju, korištenjem neuronskih mreža i genetskih algoritama. U stadiju simultanog zaključivanja naučeno se kognitivno ponašanje izravno primjenjuje za kontrolu robota u stvarnim scenarijima bez ikakvih predefiniраниh podataka iz stvarnog svijeta. Eksperimentalni rezultati u više različitih zadataka upravljanja robotom, pokazuju da predložena *STR* metoda može uvježbavati kognitivne sposobnosti s visokim generaliziranim performansama. Tijekom posljednjih godina, istraživači koriste neuronske mreže kod treninga i učenja ponašanja robota u raznim poljima, s očekivanjem da će rezultati dobiveni u simulacijama biti što primjenjiviji u realnim situacijama i zadacima. Prikupljanje podataka o prostoru u kojem se robot treba kretati, na kognitivan način kako to i čovjek radi, na stvarnim je robotima potencijalno nesigurno i dugotrajno. Metode učenja na stvarnim robotima mogu biti teško izvedive i zamorne. Jedna obećavajuća metoda je osposobljavanje virtualnih modela mobilnih robota u simuliranim okruženjima u kojima je generiranje podataka sigurno i kvalitetno u smislu prijenosa naučenih znanja u stvarni svijet. Međutim, veoma zahtjevno je stvarati simulirana okruženja slična svim eventualnim stvarnim scenarijima rada, posebno s velikom vjernošću. Slijedom toga, procedure osposobljene u simuliranim okruženjima obično ne mogu izravno dovoljno dobro funkcionirati u stvarnom svijetu, zbog jaza u stvarnosti (neslaganja između simuliranog i stvarnog okruženja) [4].

Ovaj rad je ograničen na mogućnost kognitivnog modela zatvorenog (ograničenog) prostora mobilnog robota, kako bi robot mogao komunicirati s čovjekom, tj. robot treba izvijestiti što „vidi“ oko sebe, čovjeku razumljivim „jezikom“. Npr. na pitanje čovjeka "Gdje su moji ključevi od auta?", uobičajeni odgovor bi bio: "Ključevi od auta su na koordinatama 578, 312, 105.", dok bi odgovor robota s kognitivnim sposobnostima bio: "Ključevi od auta su na komodi u dnevnoj sobi.". Ako se od robota dodatno zahtjeva donijeti ključeve, očekivali bismo da se pri tome ne zaleti u zid, stolicu, drugu osobu, da ne zapne za rub stola i ne sruši vazru, na primjer. Dakle, očekujemo uglađeno ljudsko kretanje po prostoru s ciljem izvršavanja željenog zadatka.

U literaturi te dosadašnjim istraživanjima moguće je pronaći razne pristupe rješavanju ovih problema. Većina tehnika kao glavni senzor za određivanje položaja objekta koji treba

presresti, izbjeći, zaobići itd., koristi kameru [15, 16]. Fuzija dobivenih informacija s više senzora korištena je u istraživanju [17]. Autori su se bavili lociranjem, navigacijom i planiranjem gibanja različitih tipova mobilnih robota, na različitim terenima [18]. Sve se više istraživanja okreće virtualnom modeliranju sustava koji su istovjetni stvarnim sustavima, koristeći programske alate za izradu virtualne stvarnosti [19, 20, 21]. Jedan od najpoznatijih simulacijskih programskih alata za izradu virtualne stvarnosti, potpuno besplatan za korištenje u istraživačke svrhe, opisan je u literaturi [22, 23]. Veliki broj autora koristi upravo taj programski alat za simuliranje leta raznih letjelica [24], dok drugi opet koriste isti za simuliranje industrijskih, podvodnih i sličnih robota [25, 26]. Sve veći broj autora [21, 27, 28] koristi simulacijsku platformu za izradu virtualne stvarnosti za simuliranje autonomnog ponašanja mobilnih robota.

Usporedba i mogućnosti programskih alata za simuliranje ponašanja modela mobilnih robota, povezanih sa senzorima okoline te integriranih u iste, virtualno definirane okoline, dana je u [29].

Za potrebe predloženog istraživanja razvijeno je virtualno okruženje za opremu djelomično opisanu u [11, 12, 13]. Na mobilnom robotu djelomično opisanom u [11] također je izvršena nadogradnja, u smislu preciznijih pogonskih motora, ugrađen je laserski senzor daljine te glavno upravljačko računalo novije generacije, s boljim računalnim performansama (slika 1).

Izvršena je prilagodba i implementacija stvarnih senzora unutarnjih i vanjskih stanja (enkoderi pogonskih motora i vrijednosti sa senzora daljine), koji se nalaze na mobilnom robotu u okruženju virtualne stvarnosti. Informacijski podaci iz vanjskog i unutarnjeg okruženja i enkoderi motora implementiraju se i oblikuju u odgovarajući oblik. Svi senzori postavljeni su na mobilnog robota smještenog u stvarnom okruženju - poligonu.

(a)



(b)



Slika 1. Mobilni roboti: (a) starija generacija opremljena IR senzorima daljine; (b) novija generacija opremljena laserskim senzorom daljine (LiDAR).

Navedeni su postignuti izvorni znanstveni doprinosi istraživanja. Dodatno su navedena ograničenja razvijenog modela i algoritama te su opisana moguća područja primjene. Dane su preporuke i smjernice za buduća istraživanja. U istraživanju je izgrađen kognitivni model zatvorenog prostora mobilnog robota. Model prostora je izgrađen fuzijom podataka o položaju i orijentaciji robota, provjere informacija o objektima koje vidi kamera iznad robota

i informacija s lidara, te uz pomoć informacija dobivenih enkoderom na pogonskim motorima mobilnog robota. Fuzijom tih informacija dobiva se nova informacija koja je više od jednostavnog zbroja dijelova manjih informacija. Nakon što je robot postavljen u njemu nepoznati zatvoreni prostor, nakon prihvatljivog vremenskog intervala istražio je cijeli prostor. Nakon toga robot je izvijestio da mu je okolina sada poznata te uz pomoć osnovnih kognitivnih elemenata opisao je gdje se nalazi i što vidi, tj. što je detektirao u procesu istraživanja. Korištenjem jezika osnovnih kognitivnih elemenata opisana je okolina robota i njegov odnos prema toj okolini. Na temelju tog opisa dobivena je viša razina informacija o stanju okoline u kojoj se robot nalazi.

1.2. Cilj i hipoteza rada

Cilj istraživanja:

Cilj istraživanja je izgradnja kognitivnog modela zatvorenog prostora mobilnog robota. Model prostora trebao bi biti izgrađen od podataka o položaju i orijentaciji robota, informaciji o boji objekata koje vidi kamera na robotu (samo u simulaciji) i informacija dobivenih laserskim senzorom daljine instaliranim na robotu. Fuzijom tih informacija dobila bi se nova generirana informacija koja je više od jednostavnog zbroja dijelova manjih informacija. Nakon što bi se robot pokrenuo u njemu nepoznati zatvoreni prostor, trebao bi nakon prihvatljivog vremenskog intervala izvijestiti da mu je okolina sada poznata te uz pomoć osnovnih kognitivnih elemenata opisati gdje se nalazi i što vidi, tj. što je detektirao u procesu istraživanja.

Na temelju iznesenog postavlja se sljedeća hipoteza:

Korištenjem jezika osnovnih kognitivnih elemenata moguće je opisati okolinu robota i njegov odnos prema toj okolini te je na temelju tog opisa moguće dobiti višu razinu informacije o stanju okoline u kojoj se robot nalazi, fuzijom mjernih podataka dobivenih iz različitih uređaja.

1.3. Struktura rada

- U prvom uvodnom poglavlju predstavljena je motivacija istraživanja, pregled područja i dosadašnjih istraživanja.
- U drugom poglavlju postavljen je osnovni cilj istraživanja, nakon kojeg slijedi uspostavljena hipoteza. Prikazan je plan i metodologija istraživačkog rada. Nadalje, utvrđuje se definicija zadataka i pojmova.
- U trećem je poglavlju opisan kinematički model robota, odnosno matematički model robotskog sustava.
- Algoritmi za gradnju kognitivnog modela okoline mobilnog robota eMIR opisani su u poglavlju 4.
- U poglavlju 5 opisan je razvojni proces mehatroničkog sustava koji se koristi u istraživanju.
- U poglavlju 6 opisana je eksperimentalna validacija razvijenog upravljačkog modela i dobiveni rezultati.
- U poglavlju 7, rezultati dobiveni na stvarnoj istraživačkoj opremi uspoređeni su s onima dobivenim u simulacijama te je potvrđena primjenjivost razvijenih algoritama na stvarnom robotskom sustavu.
- U poglavlju 8 nalazi se evaluacija postignutih rezultata te je dan kritički osvrt.
- Prilog 1 sadrži informacije o dodatnim materijalima kao što su kodovi, slike, CAD modeli, simulacijski modeli te poveznicu na video prezentaciju presjeka cjelokupnog istraživanja.
- Prilog 2 sadrži najvažnije algoritme razvijene za uspješnu provedbu ovog istraživanja.

1.4. Metodologija i plan istraživanja

Metodologija istraživanja u izradi doktorske disertacije:

Kako bi se navedena hipoteza potvrdila, metodologija istraživanja sadržavat će definiranje, analizu i postavljanje odgovarajućeg interaktivnog kognitivnog modela zatvorene okoline mobilnog robota. Validacija i verifikacija modela izvest će se nizom simulacija jednostavnijih problema. Oblikovanjem segmenata rada u cjelinu postupno će se definirati

cjelokupni model interakcije mobilnog robota i okruženja. Model prostora biti će izgrađen od podataka o položaju i orijentaciji robota, informaciji o objektima koje vidi kamera na robotu (u simulaciji) i informacija dobivenih s laserskog senzora daljine instaliranog na mobilnom robotu. Segmenti istraživanja implementirati će se na stvarnom sustavu koji sačinjavaju mobilni robot i poligon, opremljeni sensorima i vizijskim sustavima (kamera za nadzor odozgo). Fuzijom dobivenih informacija generirana će biti nova informacija koja će, nakon što bude pušten u njemu nepoznati zatvoreni prostor, robotu pomoći da nakon prihvatljivog vremenskog intervala izvijesti da mu je okolina sada poznata. Uz pomoć osnovnih kognitivnih elemenata, mobilni robot će opisati gdje se nalazi i što vidi, tj. što je pronašao prilikom istraživanja.

Plan istraživanja:

Kao konačni cilj istraživanja zadane su eksperimentalne provjere, korekcije i prilagodbe autonomnog ponašanja korištenog mobilnog robota na stvarnome poligonu i identično ponašanje modela robota u virtualnoj simulaciji. Svi algoritmi za prepoznavanje i vođenje robota biti će ispitani u programskome alatu za virtualnu stvarnost (CoppeliaSim) i na eMIR mobilnom robotu smještenom u odgovarajućem poligonu. Za ispitivanje sustava napisati će se potrebna programska podrška korištenjem C++ programskog jezika. Parametriranjem i usklađivanjem tih eksperimenata dati će se obrasci i smjernice za istraživanje, razvoj i testiranje algoritama za autonomno ponašanje modela mobilnih robota u okruženjima koja ne moraju biti visokog stupnja definiranosti, za puno širi krug korisnika, a sve zbog lakšeg prijenosa znanja. Kao glavna vodilja u predloženome istraživanju je razvoj modela ponašanja mobilnog robota, temeljenog na mjerenjima, potpuno identičnog stvarnome sustavu. U okviru ovoga rada riješiti će se istraživanje prostora mobilnim robotom u cilju gradnje modela prostora, praćenje linija, tj. samostalno planiranje gibanja robota u prostoru modela (simulacijskog i realnog), izbjegavanje prepreka na poligonu pomoću senzora daljine ugrađenih na mobilni robot, simultano odlučivanje o smjeru kretanja potaknuto vrijednostima sa senzora, praćenje statičkih, odnosno dinamičkih objekata vizijskim sustavima.

2. Opis problema

2.1. Kognitivna robotika i planiranje putanja robota

Važno je objasniti kako čovjek percipira prostor koji ga okružuje, kako u statičnom tako i u dinamičkom smislu. Važan pogled je i način donošenja odluke o planiranom kretanju. Umjesto preciznih numeričkih vrijednosti koje opisuju prostornu metriku, mentalni prostor se uspostavlja i opisuje s identifikacijskim svojstvima prepreka i njihovim odnosima. Aktiviraju se posebni agenti za pronalaženje specifičnih svojstava. Složena svojstva grade se od jednostavnijih. Pretpostavlja se da, ako imamo takav model i cilj istraživanja, moguće je donijeti odluku o planiranom kretanju. Na taj se način ostvaruje samo jedan korak kretanja, a može se planirati nekoliko koraka unaprijed. Težnja da se izgradi robot sličan čovjeku, ne samo svojim izgledom, već i ponašanjem, uveo je u robotiku nove discipline, nezamislive do tada. Idejno rješenje je simbioza digitalnog svijeta i čovjekovih kognitivnih sposobnosti percepcije prostora. Na primjer, koliko god je visoka razina čovjekovih kognitivnih sposobnosti, čovjek ne može zapamtiti točne pozicije u prostoru, dok robot ima tu mogućnost. Isto tako, čovjek ne može donositi odluke na razini mikrosekunda, dok robot ima tu mogućnost. S druge strane, robot ima značajnih problema pri percepciji i interpretaciji prostora koji ga okružuje. Jedna od vrlo važnih disciplina je psihologija, koja odgovara na pitanja o ljudskom ponašanju i sposobnostima koje ljudi posjeduju. Pregled područja može su vidjeti u [39]. Osim toga, uočeno je da pisanje algoritama na konvencionalan način nije prikladno za probleme složene prirode. Na temelju toga, razvijeni su dodatni alati za donošenje odluka, kao što su neizrazita logika (engl. *Fuzzy Logic*), umjetna inteligencija (engl. *Artificial Intelligence*), umjetne neuronske mreže (engl. *Artificial Neural Networks*), genetski algoritmi (engl. *Genetic Algorithms*), vizualno prepoznavanje (engl. *Machine Vision*), analiza glasa (engl. *Voice Recognition*), paralelno programiranje, sustav agenata, strojno učenje (engl. *Machine Learning*). Svi ovi alati donijeli su spoznajnu realizaciju o dostupnosti elemenata za izgradnju robotskih sustava sa svojstvima nalik ljudskom

ponašanju, prepoznatim po pripadajućim kognitivnim sposobnostima.

2.1.1. Strojno učenje u svojstvu gradnje kognitivnog modela prostora

Strojno učenje kao grana umjetne inteligencije je tehnika koja putem baze podataka uči obrasce ponašanja sustava u tijeku procesa treniranja. Brojna su područja primjene, a dobar se uvid u njih daje u [37]. Kod strojnog učenja, nakon procesa treniranja, prema već naučenim obrascima ponašanja, uz određenu točnost se predviđaju izlazne vrijednosti, ovisno o početnim ulaznim vrijednostima u projektiranom sustavu. Odnosno, prema ljudskom poimanju svijeta, proces strojnog učenja donosi odluke koje ovise o naučenom iskustvu i podražajima oko sebe. Umjesto da strojevi rade prema predefiniranim instrukcijama, strojno učenje im daje mogućnost da uče iz iskustva bez eksplicitnog programiranja. Sustav napreduje bez asistencije čovjeka, u svojstvu programera.

Strojno učenje se može podijeliti na 3 glavne grane:

- Nadzirano učenje (engl. *Supervised Learning*) – ulazni podaci koji se zadaju, već su poznati kojoj klasi pripadaju, odnosno za ulazne podatke poznati su izlazni podaci. Učenjem uz pomoć poznatih vrijednosti postavljamo sustav tako da definiranjem ulaznih vrijednosti kod kojih nisu poznati izlazni podaci, sustav može predvidjeti koja bi to vrijednost podataka bila.
- Nenadzirano učenje (engl. *Unsupervised Learning*) – za razliku od nadziranog, kod nenadziranog učenja nema spoznaje o mogućim vrijednostima izlaznih podataka. Algoritam nad ulaznim podacima traži smislen uzorak i pokušava sortirati ulazne podatke prema nekom uzorku.
- Pojačano učenje (engl. *Reinforcement Learning*) – algoritam uči kroz metodu pokušaja i pogrešaka (engl. *trial and error*). Kroz pogreške sustav uči da primijenjena metoda neće donijeti daljnje napredovanje u ponašanju sustava. Određeni pogrešno primijenjeni postupci se „kažnjavaju“ na način da se sustav vraća u ponovljeni ciklus učenja.

Duboko učenje (engl. *Deep Learning*) je metoda strojnog učenja koja koristi neuronske mreže za učenje obrazaca ponašanja iz podataka koji su najčešće nestrukturirani. Duboko


učenje podrazumijeva korištenje kompleksnijih neuronskih mreža pomoću kojih se želi oponašati način rada ljudskog mozga. Ta kompleksnost se očituje u broju slojeva neuronskih mreža koje se sastoje od ulaznih, izlaznih i skrivenih slojeva. Broj skrivenih slojeva može biti višestruk, npr. dva, tri ili više. Broj skrivenih slojeva određuje kompleksnost neuronske mreže, pa tako kompleksnija neuronska mreža može riješiti puno zahtjevniji zadatak.

Kod neuronskih mreža kao jednog dijela strojnog učenja, koristi se tehnika neuroevolucije koja uz pomoć genetskih algoritama za neuronske mreže, oponaša evoluciju ljudskog živčanog sustava iz prirode. Za razliku od drugih metoda učenja, neuroevolucija ima mogućnost učenja bez točno zadanog cilja [38]. Takav pristup se koristi u autonomnoj vožnji automobila, u video igrama i robotici. U ovom istraživanju se koristi u mobilnoj robotici, pri izgradnji kognitivnog modela zatvorene okoline mobilnog robota.

2.2. Kognitivni model zatvorenog prostora mobilnog robota

U istraživanju se želi odgovoriti na pitanje o minimalnom skupu topoloških oznaka i njihovim svojstvima koja su dovoljna za neovisna planiranja putanje robota od početne pozicije do cilja. Odgovor daje prostorni model klasificiran kao kognitivni prostorni model, jer podsjeća na ljudski model njegova okruženja opisan pojmovima dostupnim ljudskom sustavu opisivanju prostora njemu znanim kognitivnim terminima. Kognitivni prostorni model može se podijeliti na dijelove koji se nazivaju okruzi. U svakom trenutku mobilni robot može definirati što može detektirati iz trenutne pozicije (objekti, prepreke, granice). Čovjekova percepcija prostora u kojem je pozicioniran nije određena u smislu brojeva, tj. numeričke metrike. Čovjek opisuje udaljenosti, duljine i odnose u smislu omjera, u usporedbi na neku poznatu veličinu. Ti opisi nisu vrlo precizni i imaju više od jednog značenja, ali ipak odražavaju stvaran svijet vrlo dobro. Na primjer, da bi opisao položaj i orijentaciju, čovjek ne koristi koordinatne sustave kao element numeričkih opisa prostora. Položaj i orijentacija objekta opisani su odnosom čovjeka prema drugim objektima kojima je okružen te ovise o položaju i orijentaciji čovjeka koji proizvodi opis. Glavna prednost takvog pristupa je u tome što složeni navigacijski sustavi nisu potrebni, a takvi uređaji projektirani od strane bioloških sustava ne postoje do danas. Umjesto tako složenih navigacijskih sustava, razvijen je kognitivni model prostora. Iako kognitivni model prostora

nije tako precizan kao numerički pristup opisivanju prostornog okruženja, takav model može se realizirati na mnogo jednostavniji način i vrlo je učinkovit, kao što to i pokazuje ljudska evolucija. Za svrhu simulacije prikupljanja kognitivnih informacija o nekom prostoru, prostor u kojem se robot kreće ne mora biti poznat. Prepreka se definira kao poligon uz pomoć skupa točaka. Putanja kretanja robota uvijek započinje od nekog ugla, koji ima ulogu početnog položaja. Tu se nalazi središte koordinatnog sustava korištenog za simulaciju istraživanja. Smatra se da je poznat početni položaj robota. Prostorni objekti, tj. prepreke postavljaju se u datoteku prostorne konfiguracije. Za vrijeme simulacije putanje kretanja robota potrebno je provjeriti mogućnost kolizije robota s bilo kojom preprekom u poligonu. Takav se zadatak mora provesti prije izvršenja sljedećeg koraka. Virtualni poligon prikazan je na slici 2.




Slika 2. Glavni elementi u eksperimentu istraživanja: (a) virtualni poligon s mobilnim robotom (mjerilo 1:1); (b) primjer scene virtualnog poligona za istraživanje s mobilnim robotom, koji se koristi za izgradnju kognitivnog modela prostora.

Dodatna provjera kolizije obavlja se nad preprekama koje pripadaju okruhu u kojem je robot trenutno pozicioniran, zbog nadolazećeg prijelaza robota iz jednog okruha u drugi. Slika 3 prikazuje uobičajenu scenu u prostoru gdje robot istražuje. Nakon svakog koraka robota, okolina se detektira skeniranjem laserskim senzorom daljine. Proširena stvarnost (engl. *Augmented Reality*) korištena je u eksperimentalnoj provjeri konfiguracije stvarnog poligona, kako bi se objekti mogli postaviti izravno i precizno na poligon, istovjetno planiranom položaju objekata u simulaciji, bez potrebe za dodatnim mjerenjem i definiranjem poligona. U istraživanju i eksperimentu je proširena stvarnost korištena kao pomoć u postavljanju pravog poligona prema 3D CAD modelu poligona, koji je prvo modeliran, a zatim korišten u simulaciji.



(a)



(b)

Slika 3. Okruženje robota u poligonu: (a) stvarni poligon, identičan virtualnom, prikazanom na slici 2a, snimljen kamerom za nadzor, postavljenom iznad poligona; (b) realni poligon prilagođen prema virtualnom poligonu prikazanom na slici 2a koristeći proširenu stvarnost [32].

Skeniranje u simulaciji je zamjena za sustav na stvarnom mobilnom robotu. Proces skeniranja je definiran na način da se robot ne smije približiti nijednom objektu na udaljenost manju od 15 cm. Točnost procjene udaljenosti ovisi o stvarnoj udaljenosti. Ako je neka prepreka bliža, procjena udaljenosti je bolja i obratno. Na istovjetan način čovjek procjenjuje udaljenost.

2.3. Opis eksperimentalnog sustava za istraživanje nepoznatog prostora

Kao konačni cilj istraživanja, zadane su eksperimentalne provjere, korekcije i prilagodbe autonomnog ponašanja korištenog mobilnog robota na stvarnome poligonu i identično ponašanje modela mobilnog robota u simulaciji [30]. Svi algoritmi za prepoznavanje i vođenje robota ispitani su u programskome alatu za virtualnu stvarnost CoppeliaSim [31], u kojem je implementiran virtualni dinamički model eMIR mobilnog robota (slika 4b) uz odgovarajuću konfiguraciju poligona (slika 5). Za ispitivanje sustava napisana je potrebna programska podrška korištenjem C++ i Lua programskog jezika (slika 24). Parametriranjem i usklađivanjem tih eksperimenata dani su obrasci i smjernice za istraživanje, razvoj i testiranje algoritama za autonomno ponašanje modela mobilnih robota u okruženjima koja ne moraju biti visokog stupnja definiranosti, za puno širi krug korisnika, a sve zbog lakšeg prijenosa znanja [4].

Kao glavna vodilja u predloženome istraživanju je razvoj modela ponašanja mobilnog robota, temeljenog na mjerenjima, potpuno identičnog realnome sustavu. U okviru ovoga rada riješena su istraživanja prostora mobilnim robotom u cilju gradnje njegovog modela, izbjegavanje prepreka na poligonu pomoću senzora daljine ugrađenog na mobilnom robotu. Jedna od važnih tema u proučavanju robotske spoznaje jest omogućiti robotu da opaža, planira i reagira na situacije u stvarnom okruženju. Predloženo učenje neuroevolucijom (slika 21), predstavlja kognitivni navigacijski model koji integrira sposobnost kognitivne izrade modela i sposobnost pohrane prikupljenih informacija, kako bi robot mogao izvršiti svestranije zadatke uz pomoć svojih novih kognitivnih sposobnosti.

Modelirane su tri neuronske mreže (slika 16) za izgradnju kognitivnog modela prostora (slika 27). Modelirane neuronske mreže sadrže 10 ulaza koji predstavljaju detekcijske zrake laserskog senzora daljine (po jedna na svakih 36°). U svoja dva skrivena sloja, neuronske

mreže sadrže po 5, 10 ili 15 neurona, uključujući pripadajuće vrijednosti odstupanja (engl. *Bias*). Neuronske mreže sadrže dva izlaza koji predstavljaju brzine lijevog i desnog kotača mobilnog robota, opisanog u poglavlju 3.


Razvijen je sustav za prikupljanje i pohranu informacija povezanih sa zadacima. Informacije između kognitivne karte i prikupljenih podataka razmjenjuju se kroz odgovarajuće procese kodiranja i dekodiranja. Naučeni bodovi testiraju se u simulacijskom okruženju, koje je također razvijeno za ovo istraživanje. Za dobivanje kognitivnog modela prostora, koristi se kognitivni sustav (neuroevolucija neuronskih mreža) primjenjen na mobilnom robotu pomoću kojeg se istražuje prostor (engl. *Exploring*), provodi se lokalizacija (fuzijom podataka sa LiDAR-a i vrijednosti enkodera motora) i navigacija robota (slika 27). Eksperimenti, uz pomoć kognitivnih sposobnosti ponašanja mobilnog robota dokazanih u simulaciji, u završnoj, eksperimentalnoj validaciji pokazuju učinkovitost predloženog projektiranog sustava.

Navedena hipoteza je potvrđena, a metodologija istraživanja sadrži definiranje, analizu i postavljanje odgovarajućeg interaktivnog kognitivnog modela zatvorene okoline mobilnog robota. Validacija i verifikacija modela izvedena je nizom simulacija jednostavnijih problema. Oblikovanjem segmenata rada u cjelinu postupno je definiran cjelokupni model interakcije mobilnog robota i okruženja. Model prostora je građen fuzijom podataka o položaju i orijentaciji robota, informaciji o objektima koje laserski senzor daljine, smješten na robotu detektira i informacija s enkodera pogonskih motora na mobilnom robotu. Segmenti istraživanja implementirani su na realnom sustavu kojeg čine mobilni robot i poligon, opremljeni senzorima i vizijskim sustavima. Interakcijom dobivenih informacija dobivena je nova informacija koja, nakon što je smješten u njemu dotad nepoznati zatvoreni prostor, robotu pomaže da nakon prihvatljivog vremenskog intervala izvijesti da mu je okolina poznata, te uz pomoć osnovnih kognitivnih opisa elemenata, generira informacije gdje se nalazi i što je detektirao.

Predloženo istraživanje koristi sljedeće materijale i opremu:


- eMIR mobilni robot diferencijalne strukture - (eng. *educational Mobile Intelligent Robot*) je edukacijski mobilni robot projektiran i izrađen na Fakultetu strojarstva i brodogradnje u Zagrebu. Opremljen je autonomnim izvorom energije, komunikacijskim sučeljima, kamerom, daljinomjerima i programskom podrškom za rad (slika 1a). Moguća je povezivost s bilo kojim uređajem koji može ostvariti Bluetooth

komunikaciju. Izrađena su tri takva robota, a identifikacija svakog robota je njegova boja (crveni, plavi, žuti). Za potrebe ovog istraživanja izrađen je i dodatni mobilni robot eMiR (bijeli, slika 4c), nakon što je zaključena (nakon dobivenih rezultata provedenih istraživanja i testiranja na postojećim robotima) potreba za smanjivanjem prijenosnih omjera reduktora pogonskih motora robota, kako bi se postigli što manje strmi odzivi robota na zahtjeve za promjenom putanje kretanja (slika 1b).



Slika 4. Razvoj mobilnog robota eMIR: (a) 3D CAD model eMIR; (b) dinamički model eMIR (CoppeliaSim programski alat za virtualnu stvarnost); (c) izrađeni stvarni mobilni robot eMIR.


- Poligon dimenzija 2x4 m – zatvoreni prostor u kojem eMIR mobilni roboti izvršavaju neki zadatak. Prostor je bijele boje kako bi se olakšao rad vizijskim sustavima za nadzor, a moguće ga je dodatnim pregradama konfigurirati prema potrebi.



(a)



(b)




(c)

Slika 5. Različite konfiguracije poligona: (a) 3D CAD modeli tri različite konfiguracije poligona za izgradnju kognitivnog modela ponašanja robota; (b) modeli tri različite konfiguracije poligona definiranih i parametriranih u Coppeliasim, programskom alatu za virtualnu stvarnost; (c) tri različite konfiguracije poligona s četiri početne pozicije eMIR mobilnih robota korištenih u stadijima učenja, treniranja, simulacije i testiranja naučenih kognitivnih modela ponašanja mobilnog robota u realnim eksperimentima i zadacima istraživanja nepoznatog prostora.


- Kamera iznad poligona – snima poligon i može detektirati položaj i orijentaciju mobilnog robota. Dinamika sustava za praćenje objekata je oko 10 izračuna u jednoj sekundi, što je obzirom na cilj rada sasvim dovoljno. Kamera može prepoznati dodatne pregrade jer su im rubovi crne boje. Postavljena kamera nije niti na koji način uključena u upravljačku petlju koja upravlja gibanjem robota na poligonu (niti u simulaciji niti u stvarnom okruženju). Međutim, slika, tj. video dobiven uz pomoć te kamere je temelj za rad vizijskog programskog alata OpenCV, koji je korišten za generiranje putanje kretanja mobilnog robota pri pretraživanju poligona. Spomenuta generirana putanja je vidljiva na slici 33c. Potrebno je spomenuti da je generirana (kontrolna) putanja identična generiranoj putanji u razvijenom simulacijskom kognitivnom modelu, vidljiva na slici 33a.

- Kamera na robotu – može snimati prostor ispred robota u prvom licu (engl. *FPV*; *First Person View*). Kamera ima vidni kut od 55° i prepoznaje objekte prema bojama (u simulacijskom dijelu eksperimenta). Vidni kut od 55° stupnjeva ima stvarna kamera na mobilnom robotu, dok u simulaciji kamera ima vidni kut od 120° . Zasebni programski alat, aplikacija obrađuje sliku, a informacije o prepoznavanju prosljeđuje drugoj aplikaciji kroz virtualni komunikacijski kanal. Razvojem upravljačkih algoritama realiziranih u ovome istraživanju, ova je kamera isključena iz upravljačke petlje mobilnog robota. Razvijene neuronske mreže, potpomognute razvijenim genetskim algoritmima, dovoljno dobro rješavaju vođenje mobilnog robota u stadiju učenja, testiranja kao i u stadiju istraživanja otprije nepoznatog prostora mobilnom robotu. Naravno, ukoliko bi se radilo o industrijskim aplikacijama, kameru bi svakako trebalo uključiti u upravljačku petlju, zbog sigurnosnih zahtjeva takvih mjesta aplikacija, potrebno je imati senzore na više razina, u slučaju ispada pojedine razine iz rada.
- Laserski senzor daljine instaliran na robotu (LiDAR) – u simulacijskom okruženju u stadiju učenja i testiranja je definirano, aproksimacijski, da senzor koristi po jednu detekcijsku lasersku zraku na svakih 36° kružnog, horizontalnog intervala, rezultirajući s ukupno 10 laserskih detekcijskih zraka, što je i prikazano na slici 6a. Tijekom eksperimenta na stvarnom laboratorijskom postavu, laserski senzor daljine radi na istim principima, kao što je to modelirano u simulaciji, u sklopu ovog istraživanja (slika 6b).


(a)



(b)



(c)



Slika 6. CoppeliaSim poligoni virtualne stvarnosti: (a) 3D bočni prikaz konfiguracije poligona s mobilnim robotom u pokretu; (b) skup od tri različita poligona modelirana za učenje i treniranje kognitivnog modela ponašanja mobilnog robota; (c) model poligona u virtualnoj stvarnosti s 10 definiranih detekcijskih zraka laserskog senzora (LiDAR) za otkrivanje prepreka, na svakih 36° , identično konfiguriran kao realna konfiguracija poligona za eksperimentalnu validaciju simuliranih rezultata, prikazana na slici 3a.


- CoppeliaSim simulator (V-Rep) – je virtualni robotski simulator s integriranom razvojnom okolinom, temelji se na distribuiranoj upravljačkoj arhitekturi: svaki objekt/model može se pojedinačno kontrolirati pomoću ugrađene skripte ili prilagođenog rješenja. To čini korišteni simulator vrlo svestranim i idealnim za multi-robotske aplikacije. Kontroleri mogu biti napisani u programskim jezicima kao što su C/C++, Python, Java, Lua, Matlab, Octave ili Urbi. Može se koristiti kao samostalna aplikacija ili se lako može ugraditi u glavnu aplikaciju, kao što je to učinjeno u ovome

istraživanju. Korišten je kao virtualna simulacijska platforma u stadiju učenja i testiranja. Veoma jednostavno implementiranje različitih 3D CAD modela poligona iz bilo kojeg CAD programskog alata, uvelike olakšava postizanje istovjetnosti modela i konfiguracija prostora u stadiju učenja, testiranja i eksperimentalne validacije na realnim poligonima. Od velike koristi kod izrade realnih modela je i proširena stvarnost koja je također korištena u ovome istraživanju.

- Qt Creator (C++) – integrirano razvojno okruženje (engl. *Integrated Development Environment*), dostupno na više platformi. Radi na Windows, Linux, Android, BlackBerry i MacOS operativnim sustavima te omogućuje projektiranje aplikacija na radnim površinama, mobilnim i ugrađenim platformama. Programski alat sadrži i razvijena programska rješenja za provedeno istraživanje, kao i korisnička strojna sučelja (engl. *Human Machine Interface*) i korisnička grafička sučelja (engl. *Graphics User Interface*).

3. Matematički model mobilnog robota

Matematički model neholonomskog diferencijalnog pogona robota s dva pogonska kotača opisan je u ovom poglavlju. Analiza sadrži kinematičku interpretaciju cijelog sustava. U kinematici se proučava kretanje robota bez uplitanja vanjskih sila u gibanje mobilnog robota.



Slika 7. Kinematički model mobilnog robota diferencijalne strukture.

Model kinematike diferencijalnog pogona mobilnog robota koji se sastoji od dva kotača prikazan je na slici 7, gdje je:

-
- L [m] je širina između pogonskih kotača robota;
 - R [m] je promjer kotača;
 - C je težište robota (ujedno i središte rotacije LiDAR-a);
 - P je središnja točka na osi pogonskih kotača robota;
 - d [m] je udaljenost između točaka P i C ;
 - $(0, X, Y)$ je apsolutni koordinatni sustav robota;
 - $(0, x, y)$ je relativni koordinatni sustav robota;
 - θ [rad] je orijentacija robota u odnosu na X -os;
 - x [m], y [m], θ [rad] su parametri kinematike robota;
 - v_R [m/s], v_L [m/s] su linearne brzine desnog, odnosno lijevog pogonskog kotača robota;
 - ω_R [rad/s], ω_L [rad/s] su kutne brzine desnog, odnosno lijevog pogonskog kotača robota.

Neholonomska struktura podrazumijeva da robot nema sposobnost kretanja bočno, a kretanje se temelji na principu kutnog zakreta (rotacije) pogonskih kotača [33]. Pogonski sklop robota sastoji se od dva pogonska kotača za vožnju sa strane i jednog kotača za potporu konstrukciji robota sprijeda. Dva odvojena motora koriste se za pomicanje kotača i upravljanje orijentacijom robota razlikama brzine kotača (princip diferencijalnog pogona). Pretpostavlja se da je robot izrađen od krutog okvira i kreće se u horizontalnoj ravnini. Širinu staze, puta robota, označavaju L , R i C na slici 7, kao i promjer kotača i središte mase mobilnog robota. Točka P nalazi se u sredini osi pogonskih kotača. Točka d je udaljenost između točaka P i C . Koordinatni sustav (O, X, Y) prikazuje (definira) okruženje na poligonu, a koordinatni sustav (O, x, y) predstavlja pokretnu os (poziciju i orijentaciju) mobilnog robota. Orijentacija robota definirana je sa θ , što predstavlja orijentaciju robota u odnosu na X -os. Tri parametra (x, y, θ) definiraju početno stanje mobilnog robota, koje je predstavljeno jednadžbom q :

$$q = [x, y, \theta]^T \quad (1)$$

U ovom slučaju razlog neholonomnosti se može izraziti jednostavno tako da imamo dvije upravljane koordinate (brzinu lijevog i desnog kotača; v_L i v_R), a tri vanjske koordinate (x, y, θ).

To znači da imamo neizmjereno veliki broj načina kako doći u neku točku (x, y, θ) .

Neholonomsko ograničenje predstavljeno je sljedećom jednađžbom:

$$\dot{y}\cos\theta - \dot{x}\sin\theta = 0 \quad (2)$$

Sljedeće jednađžbe definiraju korelaciju između linearne brzine i kutne brzine kotača:

$$v = \omega \cdot R \quad (3)$$

$$v_R = \omega_R \cdot R \quad (4)$$

$$v_L = \omega_L \cdot R \quad (5)$$

$$\omega = \frac{v_R - v_L}{L} \quad (6)$$

$$v = \frac{v_R + v_L}{2} \quad (7)$$

Jednađžbe (6) i (7) mogu se ponovno zapisati na sljedeći način:

$$\begin{bmatrix} v \\ \omega \end{bmatrix} = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} \\ \frac{1}{L} & -\frac{1}{L} \end{bmatrix} \begin{bmatrix} v_R \\ v_L \end{bmatrix} \quad (8)$$

Sljedeća jednađžba određuje brzine pokretnih osi mobilnog robota (x, y) i njegov kut rotacije (orijentacija) u nekom malom vremenu (dt):

$$\frac{dx}{dt} = \dot{x} = v \cdot \cos\theta \quad (9)$$

$$\frac{dy}{dt} = \dot{y} = v \cdot \sin\theta \quad (10)$$

$$\frac{d\theta}{dt} = \dot{\theta} = \omega \quad (11)$$

Kinematika mobilnog robota na dva kotača definirana je sljedećim jednađžbama (inverzni kinematički problem; IKP):

$$\dot{q} = \begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} \cos\theta & 0 \\ \sin\theta & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} v \\ \omega \end{bmatrix} \quad (12)$$

Jednadžbe (9), (10) i (11) s (6) i (7) definiraju nadalje sljedeće jednadžbe :

$$\dot{x} = \frac{R}{2} (\omega_R + \omega_L) \cdot \cos\theta \quad (13)$$

$$\dot{y} = \frac{R}{2} (\omega_R + \omega_L) \cdot \sin\theta \quad (14)$$

$$\dot{\theta} = \frac{R}{L} (\omega_R - \omega_L) \quad (15)$$

Kinematički model mobilnog robota definiran je jednadžbama (13), (14) i (15) u obliku matrice, kako slijedi:

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} \frac{R}{2} \cos\theta & \frac{R}{2} \cos\theta \\ \frac{R}{2} \sin\theta & \frac{R}{2} \sin\theta \\ \frac{R}{L} & -\frac{R}{L} \end{bmatrix} \begin{bmatrix} \omega_R \\ \omega_L \end{bmatrix} \quad (16)$$

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} \frac{\cos\theta}{2} & \frac{\cos\theta}{2} \\ \frac{\sin\theta}{2} & \frac{\sin\theta}{2} \\ \frac{1}{L} & -\frac{1}{L} \end{bmatrix} \begin{bmatrix} v_R \\ v_L \end{bmatrix} \quad (17)$$

Kinematički model opisan prethodnim jednadžbama može se naći u literaturi o mobilnoj robotici, kao što je [34]. Na temelju definiranog kinematičkog modela (IKP) mobilnog robota moguće je konstruirati algoritam za izgradnju kognitivnog modela zatvorene okoline mobilnog robota. Glavni dio tog algoritma definiran je u nastavku.

Algoritam izgradnje kognitivne karte

1. $wL[i] = wl[i];$
 2. $wR[i] = wr[i];$
 3. $Fi = Fi + fi;$
-

-
4. $x = 0.02f * (w_r[i] + w_l[i]) * \cos(-F_i) * 0.05f$;
 5. $y = 0.02f * (w_r[i] + w_l[i]) * \sin(-F_i) * 0.05f$;
 6. $f_i = (0.04f/0.24f) * (w_r[i] - w_l[i]) * 0.05f$;
 7. $X[i+1] = X[i] + x$;
 8. $Y[i+1] = Y[i] + y$;
 9. $X_p = \text{round}(X[i] * 400.0f)$;
 10. $Y_p = \text{round}(Y[i] * 400.0f)$;
-

gdje je:

- w_l je ω_L ;
- w_r je ω_R ;
- F_i je θ ;
- f_i je $\dot{\theta}$;
- 0,02 je $R/2$ [m];
- 0,04 je R [m];
- 0,24 je L [m];
- 0,05 je d_t [ms];


Definirani algoritam koristi se za konstruiranje kognitivnog modela nepoznate okoline (slika 27) u koju je robot (slika 7) smješten za istraživanje u poligonima za testiranje (slika 2b). U algoritmu za izgradnju kognitivne karte nalaze se brojčane veličine koje su opisane prije, a odnose se na polumjer/promjer pogonskih kotača robota, razmak između pogonskih kotača, vremensku konstantu d_t , te konstantu 400, potrebnu da se može prikazati na ekranu generiranje karte (GUI), vidljivo na 1:35 u [40]. Definiran je dinamički model mobilnog robota (slika 4b), a ponašanje dinamičkog modela vidljivo je na 0:30 u [40]. Detaljan opis postupka izrade kognitivne karte prikazan je u poglavlju 6. Fuzijom podataka prikupljenih s laserskog senzora daljine (LiDAR) i integracijom dobivenih podataka upravljačkog signala motora, dobivaju se elementi korišteni za izradu kognitivne karte, kao što je i prikazano na slici 27, i objašnjeno u poglavlju 6.

4. Algoritmi za izgradnju kognitivnog modela okoline

Jedna od primjenjivih tehnika učenja u kognitivnoj robotici je učenje stjecanjem znanja, tj. iskustva. Učenje stjecanjem znanja jedna je od najsloženijih tehnika učenja koja se koristi za istraživanje nepoznatog prostora robota. U ovom radu, neuronska mreža se koristi za usmjeravanje robota kroz neistraženi prostor zbog svoje sposobnosti stjecanja znanja (iskustva). Proces učenja neuronske mreže pomoću simuliranog okruženja stvara znanje potrebno za istraživanje nepoznatih prostora određene topologije. Umjetna neuronska mreža također ima mogućnost da fuzijom podataka dobivenih laserskim senzorom daljine daje, kao izlaz kutne brzine motora robota. Kada predmeti, u prostoru koji se istražuje, promijene položaj, nestanu/dodaju se na scenu, razvijeni simulacijski model će robota navoditi da istražuje prostor i dalje, tj. izbjegavati će eventualne smetnje, vidljivo na [41]. Neuronske mreže su korištene, kako bi mobilni robot istaživajući nepoznati prostor, mogao opisati ljudskim riječnikom što se nalazi oko njega, tj. za gradnju kognitivnog modela okoline robota. Na temelju kinematičkog modela mobilnog robota predstavljenog u poglavlju 3, moguće je fuzijom različitih podataka (prikupljenih pomoću mjernih senzora), i, projektiranim algoritmima, konstruirati kognitivni model prostornog okruženja u kojem se nalazi mobilni robot. Podatci o okolišu, dobiveni „čitanjem kognitivne karte“, osnova su za planiranje optimalne putanje kretanja mobilnog robota tijekom planiranog istraživanja. Dobivenom kognitivnom kartom utvrđuje se visoka razina informacija o prostornom okruženju, bliska informacijama generiranim uz pomoć sposobnosti ljudske percepcije prostora. Proces učenja, tj. generiranja znanja robota potrebnog za izgradnju kognitivnog modela prikazan je od 1:06 do 3:09 u [40]. Kako bi se objasnio ključni element gradnje kognitivnog modela zatvorenog prostora robota, u ovome je poglavlju objašnjen proces projektiranja i učenja neuronskih mreža, koje moraju “simulirati” ponašanje robota slično ponašanju čovjeka.

4.1. Inicijalizacija neuronskih mreža s nasumičnim težinskim koeficijentima

Inicijalizacija neuronskih mreža popunjavanjem težinskim koeficijentima, pri prvom učenju, odnosno kod nulte generacije, opisana je na slici 8. Na ulazu imamo 10 ulaznih veličina koje su vrijednosti udaljenosti prepreka, tj. objekata unutar poligona i centra težišta mobilnog robota eMiR u koje je postavljen laserski senzor daljine. Na slici 8 je prikazana neuronska mreža dimenzija 4x3 neurona. Nadalje u radu je opisano kako se definira veličina neuronske mreže. Neuronska mreža manje dimenzije je korištena samo radi bolje preglednosti i pojašnjenja pojedinih elemenata neuronske mreže. Kasnije u radu i u samom pokusu, koriste se složenije neuronske mreže većih dimenzija.



Slika 8. Inicijalizacija neuronske mreže pri nultoj generaciji.


Unutar nulte generacije, koja se sastoji od npr. 100 pripadnika populacije, postoji 100 neuronskih mreža s pripadajućim težinskim koeficijentima. Za svakog člana populacije, generira se nova neuronska mreža s drugačijim težinskim koeficijentima, koji su odabrani

nasumično (zeleni kvadratići na slici 9). Primjerom je prikazana jedna od neuronskih mreža nulte generacije, na slici 10. Ovakva inicijalizacija se koristi samo unutar nulte generacije. Mreža je popunjavana s nasumičnim brojevima u intervalu od -0,999 do 0,999. Testirani su i manji intervali nasumičnih brojeva, ali se pokazalo da robot uči puno sporije i lošije u tom slučaju. Rezultat korištenja ograničenja užih intervala bilo je sporije učenje robota, tj. računanje neuronske mreže, što je na kraju rezultiralo niskom ocjenom naučenosti neuronske mreže (rezultati su prikazani u poglavlju 7). Dobivene vrijednosti učenja neuronske mreže (težinski koeficijenti) za vođenje robota kroz poligon dobivene su metodom pokušaja i promašaja. Optimizirane su do optimalnog intervala kada se promjenom ulaza, prilikom različitih neuronskih mreža, dobiva velika razlika izlaza. Ili, promjenom ulaza (po mogućnosti malom promjenom), dobiva se promjena (po mogućnosti velika) izlaza. Ovaj slučaj bi vrijedio kada su ulazi jako niski i promjenom ulaza dobiva se mala promjena izlaza, ili nikakva, kao i cijele neuronske mreže. Ulazi moraju biti u određenom intervalu jer može doći i do zasićenja (slučaj kada su vrijednosti prevelike), odnosno iako postoji promjena ulaza koja može biti i velika, izlazi će stalno biti u jednoj maksimalnoj vrijednosti. Naravno sve je u korelaciji sa aktivacijskim funkcijama unutar samih skrivenih slojeva.

Tablica 1. Eksperimentalno određene vrijednosti korištene u pokusima.


Neuronska mreža	Broj populacije	Ulazna akt. funkcija	Aktivacijska funkcija	Konstante bodovanja	Mutacija	Prolaz	Pokus br.
[5][5]	200	Leky Relu if(ulaz > 0) ulaz*5 else ulaz=5	Leky Relu n/5	Speed * 50 Dif * 50 (1.000488, Explore) Distance / 4 Loop / 4 Angle / 4	7	Ne	1
[5][5]	200	Leky Relu if(ulaz > 0) ulaz*5 else ulaz=5	Leky Relu n/10	Speed * 50 Dif * 50 (1.000488, Explore) Distance / 2 Loop / 2 Angle / 2	7	Ne	2
[5][5]	200	Leky Relu if(ulaz > 0) ulaz*10 else ulaz=10	Leky Relu n/5	Speed * 50 Dif * 50 (1.000488, Explore) Distance / 2 Loop / 2 Angle / 2	6	Ne	3
[5][5]	200	Leky Relu if(ulaz > 0) ulaz*10 else ulaz=10	Leky Relu n/10	Speed * 50 Dif * 50 (1.000488, Explore) Distance / 2 Loop / 2 Angle / 2	6	Ne	4
[5][5]	200	Leky Relu if(ulaz > 0) ulaz*7 else ulaz=7	Leky Relu n/5	Speed * 50 Dif * 50 (1.000488, Explore) Distance / 2 Loop / 2 Angle / 2	8	Da	5
[5][5]	200	Leky Relu if(ulaz > 0) ulaz*7 else ulaz=7	Leky Relu n/10	Speed * 50 Dif * 50 (1.000488, Explore) Distance / 2 Loop / 2 Angle / 2	8	Ne	6

Tablicom 1 je prikazan provedeni predpokus, kako bi se došlo bliže vrijednostima koji će se koristiti u pokusu, kao npr. koju vrstu aktivacijskih funkcija koristiti. Sve to je bilo potrebno napraviti zbog nedostatka takvih podataka iz literature, sa kojima se može uspoređivati, kako bi se vidjelo od kojih vrijednosti krenuti. Predpokusne radnje za ispitavanje odabira korištenja parametara neuroevolucije prikazane su tablicom 1. Prikazan je jedan dio parametara sa neuronskom mrežom [5][5], jer se pretpostavlja da će njome biti moguće postići određeni broj bodova u najkraćem vremenu. Također je prikazano samo testiranje linearnom ulaznom aktivacijskom funkcijom. Broj provedenih pokusa je puno veći nego što je to prikazano tablicom. Svaki pokus je proveden u roku od 6 sati i pritom mora sakupiti barem 2000 bodova. Unutar 6 sati dovoljno je vremena da neuroevolucija provede 2 generacije. Tablicom su prikazani samo rezultati koji su poslužili definiranju parametara neuroevolucije, broj pokusa je puno veći sa različitim varijantama parametara.




Slika 9. Težinski koeficijenti neuronske mreže popunjeni slučajnim brojevima.

Pokazalo se da robot u tim slučajevima ne može naučiti neke kompleksnije kretnje, npr. savladavanja zavoja, tj. skretanja. Navedeno je i očekivano jer je manji broj mogućih kombinacija, stoga će izlaz iz neuronske mreže biti repetitivniji (puno manje mogućih varijacija).



Slika 10. Opis slojeva neuronske mreže.

Na slici 10 detaljno su opisani dijelovi neuronske mreže, odnosno slojevi neuronske mreže. U ulaznome neuronskom sloju je 10 vrijednosti udaljenosti dobivenih laserskim senzorom daljine (brojčane vrijednosti u zelenome okviru). Tih 10 vrijednosti predstavlja očitavanja udaljenosti laserskog senzora daljine, smještenog na robotu, od prepreka koje ga okružuju. Također u tome sloju, unutar plavog okvira, označene su neuronske točke plavom bojom, u kojima se odvija ulazna aktivacijska funkcija prikazana na slici 11.



Slika 11. Matematički opis modificirane Sigmoid aktivacijske funkcije.

Algoritam aktivacijskih funkcija

```


1.    float NeuralNetwork::Sigmoid(float num)
2.    {
3.        // Scaled Sigmoid function
4.        return (1 / (1 + pow(2.718281828459,-num))) * 10;
5.    }
6.
7.    float NeuralNetwork::ReLu(float num)
8.    {
9.        // Modified Leaky ReLu function
10.     if(num > 0)
11.         return num * 1;
12.     else
13.         return num / 5;
14. }
```

U radu se veličine matrica opisuju kao 5x5, što znači da se neuronska mreža sastoji od dva sloja (tzv. skrivena sloja). Svaki sloj je veličine 5 neurona. Isto tako, svaki sloj ima isti pripadajući sloj *bias*-a. Korištene matrice uvijek se sastoje od istog broja neurona u prvom i drugom neuronskom sloju. U radu se najčešće spominje upravo neuronska mreža dimenzija 5x5 neurona, jer je najjednostavnija od spomenute tri neuronske mreže korištene u pokusima. Također, ta je mreža ujedno i najpogodnija za demonstraciju rada sustava.

Ono najbitnije što definira sposobnost kognitivnog ponašanja robota, je broj težinskih koeficijenta u neuronskoj mreži, što direktno utječe na kvalitetu izgrađenog kognitivnog modela prostora. To je prikazano u poglavlju 6, gdje se vidi utjecaj veličine neuronske mreže na sposobnost robota da riješi određeni zadatak. U neuronskoj mreži dimenzija 5x5 neurona, nalazi se ukupno 97 težinskih koeficijenata. Kod druge korištene neuronske mreže dimenzija 10x10 neurona, nalaze se 242 težinska koeficijenta te u mreži dimenzija 15x15 neurona, nalaze se 452 težinska koeficijenta. Kod planiranja pokusa, javlja se paradoks vezano uz veličinu neuronskih mreža i njihov utjecaj na kompleksnost kretanja i brzinu učenja robota. Paradoks je vezan za pretpostavku da će veća neuronska mreža najvjerojatnije rezultirati preciznijom putanjom robota, odnosno da će sakupiti više bodova, što i je objašnjeno detaljnije u poglavlju 7. Ali veća neuronska mreža bi mogla rezultirati puno duljim vremenom učenja, jer postoji puno više mogućih kombinacija težinskih koeficijenata koji se tijekom neuroevolucije moraju postaviti, kako bi se robot kretao dovoljno dobro. Ako se krene od najmanje mreže, ona ima puno manje kombinacija i pretpostavka je da će putanja biti lošija te da će robot puno brže učiti.

Pokusima je pokazano da veća neuronska mreža brži uči nego manja, što je pokazatelj da iako ima više mogućih kombinacija mreže, također postoji i više mogućih kombinacija koje su one prave i rezultiraju dovoljno dobrim ponašanjem robota.

U prvom neuronskom sloju, koji je dimenzija 5 neurona (plave točke na slici 10), prvi izlazni sloj dobiva se računanjem matrica ulaznih vrijednosti u neuronskoj mreži (vrijednosti sa LiDAR-a) i prve matrice težinskih koeficijenata sa pripadajućim *bias*-ima. Drugi neuronski sloj, koji također ima 5 neurona (plave točke), dobiva se računanjem matrica prvog neuronskog sloja i druge matrice težinskih koeficijenata s pripadajućim *bias*-ima. Na kraju, izlazni neuronski sloj, koji se sastoji od dva neurona, dobiva se računanjem drugog neuronskog sloja s izlaznom matricom težinskih koeficijenata sa pripadajućim *bias*-ima. Izlazni neuronski sloj ujedno je i izlaz iz neuronske mreže.



Slika 12. Dijagram toka izračuna neuronskih mreža.

Testiranje eMIR-a na poligonu, s ugrađenom neuronskom mrežom, odvija se na način da se eMIR kreće kroz prostor koristeći podatke s LiDAR-a kao ulaze u neuronsku mrežu. Algoritam neuronske mreže eMIR-a koristi vrijednosti udaljenosti od prepreka koje je LiDAR detektirao, kao ulaz u neuronsku mrežu. Njegov tok je dijagramom prikazan na slici 12, računajući neuronsku mrežu u svakom prolazu kroz petlju. Kao rezultat tog računanja dobivaju se brzine lijevog i desnog motora eMIR-a. Bitno je naglasiti da unutar jedne simulacije, odnosno jedne neuronske mreže, težinski koeficijenti ostaju isti, računaju se samo neuroni i izlazi iz neuronske mreže. Istraživanje mobilnog robota, u simuliranom okruženju (CoppeliaSim), prikazano je na slici 6b. Neuronska mreža se računa s lijeva na desno, svaki sloj zasebno. Aktivacijska funkcija prikazana na slici 11, nalazi se na izlazu neuronske mreže pri svakom od dva neurona. Tako modificirana funkcija, odnosno uvećana 10 puta, idealno odgovara skaliranju izlaza, tj. brzina vrijednosti od 0 do 10, što ujedno predstavlja brzine kotača mobilnog robota. U ostalim neuronima koristi se aktivacijska funkcija ReLu, koja je obična linearna funkcija koja u pozitivnoj domeni propušta ulazne vrijednosti, a u negativnoj ih prigušuje, odnosno smanjuje. Uobičajeni koeficijent takvog prigušenja je 10, a u ovom istraživanju korišten je koeficijent 5. Koeficijent prigušenja 5 dijeli sve negativne ulaze s brojem 5. Odabrane aktivacijske funkcije, kao i njihove modifikacije dobivene su eksperimentalno. Dobivene aktivacijske funkcije uspješno se koriste u ovom opisu problematike, tj. kretanja robota. U malo istraživanja gdje autori prezentiraju svoje rezultate, rijetko se spominju svi potrebni detalji, kada su u pitanju neuronske mreže kod mobilne robotike. Npr., to se odnosi na dimenzije neuronske mreže, konstrukciju i raspored mreže, aktivacijske funkcije, skaliranje ulaza/izlaza itd. To uvelike otežava masovnije, jednostavnije i brže korištenje spomenutih tehnika.

4.2. Simulacija i izračun rezultata neuronske mreže

Simulacija se zaustavlja ako eMIR udari u neki od objekata unutar poligona, ako prođe određeni broj iteracija (u ovom slučaju 1000 iteracija) te ako prođe veću od postavljene dozvoljene udaljenosti. Nakon zaustavljanja, eMIR se ponovo pozicionira na početnu poziciju. Uvjeti zaustavljanja tijekom simulacije prethode ponovnom pozicioniranju robota na početnu poziciju i generiranje nove populacije ili generacije. Nakon naučenih neuronskih mreža, i pokretanja robota u neistražen prostor, simulacijski i stvarno, uvjeti zaustavljanja prekidaju istraživanje.

Korištena neuronska mreža za upravljanje gibanjem eMIR-a boduje se na način zbrajanja nekoliko parametara kojima se dodjeljuje određeni koeficijent (određeni utjecaj pojedinih bodova na ukupan bodovni rezultat): a) istraženost prostora; b) brzina kotača; c) razlika u brzini lijevog i desnog kotača; d) broj petlji simulacije; e) prijeđena udaljenost; f) kut između eMIR-a i slobodnog prostora. Sljedeći rezultat određene neuronske mreže izračunava se pomoću jednadžbe:


$$Score = A\bar{V}_l + B\bar{\omega} + C\bar{ex} + \frac{1000-\bar{n}}{2} + \frac{1000-\bar{d}_l}{2} + D\bar{\alpha}, \quad (18)$$

gdje su A, B, C, D eksperimentalno određene konstante ($A=50; B=50; C=1,000488; D=1$), $\bar{V}_l$ je brzina kotača, $\bar{\omega}$ je razlika u brzini lijevog i desnog kotača, $\bar{ex}$ je istraženost prostora, $\bar{n}$ je broj petlji simulacije, $\bar{d}_l$ je prijeđena udaljenost, $\bar{\alpha}$ je kut između eMIR-a i slobodnog prostora. Provedena je analiza i uzeti su ovi iznosi, koji su se pokazali najboljima. Na slici 32a, koja prikazuje istraženost prostora, vidi se da istraženost prostora ima najveći utjecaj na ukupni rezultat, koji se vidi iz sličnosti sa grafom prikazanim slikom 31, gdje je prikazan ukupni rezultat. Kut između eMIR-a i slobodnog prostora, $\bar{\alpha}$, je kut koji je zapravo "prikaz" vrludanja robota lijevo-desno. Što je manji to je bolje, i pokazuje da se robot "kvalitetnije" ponaša. Koordinatni sustav (O, X, Y) prikazuje (definira) okruženje na poligonu, a koordinatni sustav (O, x, y) predstavlja pokretnu os (poziciju i orijentaciju) mobilnog robota, vidljivo na slici 7.

4.3. Generiranje neuronske mreže

Nakon prvog člana populacije slijedi generiranje drugog člana populacije (nove neuronske mreže). Slijedeći član populacije nije nužno nova generacija. Nakon generiranja predodređenog broja članova populacije, slijedi generiranje nove generacije s prvim članom koji pripada toj novoj generaciji. Nova neuronska mreža popunjava se novim težinskim koeficijentima, a ciklus se ponavlja, kao što je to prikazano na slici 13. Cijela prva generacija neuronskih mreža sastavljena je od nasumično odabranih težinskih koeficijenata. Vrijednosti težinskih koeficijenata su nepoznate, iz toga razloga se počinje s nasumično odabranim težinskim koeficijentima. Kasnije u radu opisan bazen od 30 računala, na kojima se simultano izvodi treniranje i učenje neuronskih mreža, znatno doprinosi bržoj spoznaji koji su težinski koeficijenti otprilike najbolji, tj. s kojim težinskim koeficijentima koja neuronska mreža daje

najbolje rezultate.



Slika 13. Dijagram procesa generiranja neuronske mreže.


4.4. Završetak nulte generacije pri generiranju neuronske mreže

Svih npr. 100 pripadnika populacije je generirano i simulirano. Time završava nulta generacija. Svakoj neuronskoj mreži, od njih npr. 100, je dodijeljen određeni broj bodova. Iz cijele generacije se odabire najbolja neuronska mreža i druga najbolja neuronska mreža, u kojoj se nalaze težinski koeficijenti. Slijedi generiranje nove generacije križanjem (engl. *Crossover*) i mutacijom (engl. *Mutation*). Križanje i mutacija simuliraju genetsku evoluciju, gdje se dva gena

roditelja križaju i prilikom tog križanja nastaju mutacije, zbog kojih se potomak bitno može razlikovati od svojih roditelja. U simuliranom okruženju, parametri križanja i mutacije mogu biti promijenjeni na način da se može odrediti koliko će novo nastala mreža u novoj generaciji, kopirati težinskih koeficijenta od roditelja A, odnosno roditelja B. To je pokazatelj koliko će biti mutirana novonastala mreža.


4.5. Proces križanja - *Crossover*

Prvi korak prema generiranju nove generacije, odnosno, prvog člana populacije unutar prve generacije je križanje neuronskih mreža. Neuronska mreža iz prethodne generacije, prva i druga najbolja neuronska mreža se križaju (slika 14). Točnije, križaju se težinski koeficijenti u omjeru koliko je prva neuronska mreža bolja od druge, na način da se težinski koeficijenti iz obje neuronske mreže kopiraju u novu praznu neuronsku mrežu. Kada je križanje završeno, stvorena je nova neuronska mreža.




Slika 14. Proces križanja težinskih koeficijenata kod generiranja nove neuronske mreže (*Crossover*).

4.6. Proces mutacije - *Mutation*




Slika 15. Dijagram toka genetskog algoritma.

Nad novo nastalom neuronskom mrežom provodi se mutacija (slika 15). Izabiru se nasumični težinski koeficijenti kojima se vrijednost prepisuje novim nasumično odabranim vrijednostima. Broj težinskih koeficijenata kojima će vrijednost biti promijenjena, ovisi o postotku mutacije. Križanje i mutacija su osnovne operacije kod genetskih algoritama, koji u jednom dijelu simuliraju Darwinovu teoriju evolucije. Mutirana neuronska mreža se ugrađuje u simulaciju u koraku opisanome u poglavlju 4.1. Slijede koraci opisani u poglavljima 4.1 do 4.3, gdje se korak opisan u poglavlju 4.3 (generiranje nove neuronske mreže), sada zamjenjuje neuronskom mrežom koja je dobivena kao produkt križanja i mutacije, kao i poglavlje 4.4 (završetak nulte generacije), gdje se sada definira završetak svake sljedeće generacije. Na ovaj način se stvara nova neuronska mreža, za svakog člana populacije (slika 16).



Slika 16. Proces mutacije (proces promjene šest nasumičnih vrijednosti težinskih koeficijenata).


U sljedećoj generaciji se uzima najbolja i sljedeća najbolja neuronska mreža te se ciklus ponavlja. Generacijama najbolja neuronska mreža ima sve veći broj bodova, što znači da je eMIR sve pametniji i bolje rješava poligon (slika 17). Takvo kognitivno učenje rješavanja poligona zaustavljamo proizvoljno nakon zadovoljavajućeg ponašanja eMIR-a, tj. kada se vidi stagnacija u učenju (pokazatelji naučenosti, tj. bodovi se ne mijenjaju ili se mijenjaju zanemarivo).



Slika 17. Dijagram toka neuronskih mreža i genetskih algoritama (neuroevolucija).


5. Dizajn mehatroničkog sustava za izradu kognitivnog modela prostora robota

S obzirom da je razvijeni eksperimentalni sustav rezultirao korisnim informacijama u simulacijskom dijelu, izrađen je i stvarni mehatronički sustav, istovjetan modelu korištenom u simulacijskom dijelu. U ovome poglavlju je opisano projektiranje cjelokupnog mehatroničkog sustava, koji se sastoji od mehaničkog i elektroničkog dijela s pripadajućim komponentama, razvijene programske podrške, vizijskog i senzorskog sustava te na kraju mreže računala za učenje i treniranje neuronskih mreža. Cijeli mehatronički sustav se može podijeliti na tri glavne cjeline, topološki i kronološki poredane kao što je i prikazano na slici 18. Koraci se odnose na stadij učenja, simulaciju na virtualnom sustavu i testiranje na realnom sustavu.



Slika 18. Blok dijagram glavnih dijelova sustava: (a) stadij izrade, učenja i treniranja neuronske mreže; (b) stadij virtualnog testiranja; (c) stadij testiranja na stvarnom sustavu.

Na slici 19 prikazana je topologija cjelokupnog mehatroničkog sustava za izradu kognitivnog modela prostora uz pomoć naučenog kognitivnog ponašanja mobilnog robota. U početku razvoja cijelog procesa učenja kognitivnih sposobnosti eMIR-a, pokušano je proces učenja i treniranja neuronske mreže uspostaviti na jednom računalu, koje je nazvano “PC-NN”. Zbog zahtjevnosti zadatka učenja i treniranja, velik je zahtjev za vremenom izvršavanja istog. Potrebno je bilo ubrzati cijeli proces nekoliko desetaka puta što je bilo neizvedivo jer su već u prethodnom koraku bile poduzete sve mjere najbržeg mogućeg izvršavanja. Komunikacija je dio programske podrške koji zauzima najduži vremenski interval, i to onaj dio između Qt razvojnog okruženja gdje je neuronska mreža ostvarena i pokrenuta te CoppeliaSim programskog alata za virtualnu stvarnost. Iz tog razloga je razvijen simultani proces učenja na mreži više računala.




Slika 19. Blok dijagram cijelog mehatroničkog sustava razvijenog za potrebe istraživanja.

Korišteno je 30 uobičajenih računala po zahtjevima procesorske snage potrebne za izvršavanje zadataka učenja i treniranja neuronskih mreža. U prvom koraku na svih 30 računala pokrenuta je izrada inicijalnih neuronskih mreža. Prvi korak u procesu učenja i treniranja neuronskih mreža pomoću mreže računala bila je inicijalizacija neuronskih mreža na svim računalima pomoću početnih parametara. Izrađeno je 30 neuronskih mreža, s tim da je mreža koja je postigla najveći stadij naučenosti prema dostignutim bodovima uzeta za daljnje iteracije treniranja. Svaka sljedeća iteracija učenja i treniranja pokreće se od polazne točke koja je definirana upravo tom prethodno najbolje naučenom, istreniranom i mutiranom neuronskom mrežom. Na svakom od 30 računala generiraju se neuronske mreže tijekom prve generacije. Nakon završetka prve generacije odabire se najbolja neuronska mreža, koja je ostvarila najviše bodova. Takva mreža se dijeli na ostala računala, uključujući potrebne informacije i parametre, upravo vezane za naučenu mrežu, kako bi se postupak treniranja nastavio pravilno. Na svakom računalu u sljedećoj generaciji počinje miješanje i mutacija odabranih najboljih mreža. Ovaj proces se ponavlja iz generacije u generaciju. Tim postupcima i umrežavanjem, dobivena je velika raznolikost generiranih neuronskih mreža, što uvelike doprinosi brzini i kvaliteti rješavanja problema. Od spomenutih 30 neuronskih mreža, za konačni pokus korištena je najbolja neuronska mreža i prva sljedeća najbolja (s najboljim bodovima učenja). Promatrajući pokazatelje naučenosti neuronske mreže (bodove), zaključuje se koja je mreža najbolje naučena. Iz najbolje naučene mreže preuzimaju se podaci u obliku tekstualne datoteke s broječanim vrijednostima. Inačica neuronske mreže je prilagođena mobilnom robotu te je isprogramirana na glavnom računalu (engl. *Master Device*), koje se nalazi na samom mobilnom robotu. Podaci o prostoru dobivaju se integracijom više podataka iz različitih izvora. Fuzijom tih podataka, informacija s enkodera motora i podataka s laserskog sensora LiDAR-a, dobiva se podatak koji se prosljeđuje na osobno računalo nazvano “PC – Map” (slika 19), čija je namjena konstrukcija i iscrtavanje kognitivne karte prostora, koja je ujedno i temelj mogućnosti konstrukcije kognitivnog modela nepoznatog prostora, uz pomoć mobilnog robota koji ima kognitivne sposobnosti. Navedeno računalo ima i zadaću preuzimati video zapis s topografske kamere, koji ujedno služi za grafički prikaz putanje mobilnog robota te verifikaciju podataka koji opisuju tu putanju numerički, tj. o njegovom kognitivnom ponašanju ili gibanju u njemu nepoznatom prostoru. Tijekom tog kognitivnog ponašanja uslijed gibanja u nepoznatom prostoru, robot istražuje i evidentira podatke o nepoznatom prostoru koji sadrže i informacije o različitim oblicima eventualnih prepreka u tom istom prostoru. Komunikacija je ostvarena pomoću lokalne bežične mreže između računala i glavnog uređaja na mobilnom robotu, koji je

potpuno autonoman upravo zbog takve izvedbe komunikacije.

5.1. Mehanička struktura mobilnog robota


Mehaničke karakteristike mobilnog robota diferencijalne strukture koji je korišten u istraživanju i eksperimentu opisane su sljedećim parametrima. Vanjske dimenzije robota su 300x250 mm. Masa robota s pripadajućim senzorima i napajanjima iznosi 3,15 kg. Promjer pogonskih kotača je $D = 80$ mm. Razmak između centra pogonskih kotača je $L = 240$ mm. Prijenosni omjer reduktora motora i pogonskih kotača je $i = 71$. Na prethodnim inačicama robota omjer reduktora je bio $i = 27$, što je bilo neprihvatljivo za potrebe ovog istraživanja. Robot s takvim prijenosnim omjerom bio je brži za isti broj okretaja motora, ali su odzivi na kontrolne vrijednosti za gibanje dobivene iz neuronskih mreža bili pregrubi, tj. gibanje robota bilo je popraćeno naglim promjenama ubrzanja i smjera. Najveća rotacijska brzina kotača pri najvećem nazivnom naponu 12 V, iznosi približno $\omega = 0,733$ okr/s, tj. 4,61 rad/s. Kod prethodnih inačica motora s reduktorima koji imaju manji prijenosni omjer reduktora, brzina je iznosila $\omega = 2$ okr/s, tj. 12 rad/s. Kod ostvarene navedene brzine na izlazu enkodera generira se 364 impulsa u sekundi. Najveća translacijska brzina robota je $v_{max} = 185$ mm/s (kod starih reduktora $v_{max} = 500$ mm/s). Najveća rotacijska brzina robota je $\omega_{max} = 90$ °/s (kod starih reduktora $\omega_{max} = 240$ °/s).



(b)




(c)



Slika 20. eMIR - mobilni robot diferencijalne kinematičke strukture: (a) kinematičke veličine; (b) izgled i raspored pogonskih motora i kotača; (c) položaj LiDAR-a na mobilnom robotu i smjer rotacije (točka C na slici 7).

Elementi stvarnog poligona za eksperimente prikazani su na slici 4, koja se nalazi u poglavlju 2. Poligon je dimenzija 4x2 m, visina svih elemenata je 200 mm, a dimenzije pojedinih prepreka nisu veće od 500x500 mm. Prikaz odnosa veličina mobilnog robota i poligona unutar CAD modela u mjerilu $M = 1:1$ prikazan je na slici 2a.

5.2. Elektronička struktura mobilnog robota



Slika 21. Blok dijagram elektroničkog sustava mobilnog robota.

Na slici 21 prikazan je blok dijagram elektroničkog dijela sustava mobilnog robota, koji je upravljački dio sustava za kognitivno istraživanje nepoznate okoline i generiranje podataka potrebnih za izradu konačnog kognitivnog modela nepoznatog prostora. Glavni upravljački uređaj (engl. *Master Device*) je računalo u obliku kartice (engl. *System on Chip*), temeljeno na Linux operativnom sustavu. Model korištenog računala je *Raspberry Pi 4B*. Informacije o nepoznatoj okolini i preprekama generirane su pomoću senzora daljine (engl. *Range Sensor*). Korišteni senzor daljine radi uz pomoć laserskih zraka te je korišten model *LiDAR*, *RPLIDAR A2*. Mobilni robot pokretan je pomoću dva istosmjerna motora koji rade u diferencijalnom načinu. Izlazni moment električnih motora uvećan je neposrednim reduktorima ugrađenim na kućište motora. Upravljački signal za električne motore generiran je pomoću upravljačkih sklopova (engl. *Drivers*), koji imaju ulogu H-mosta (engl. *H-bridge*; *LMD18200T*). Svaki motor ima pripadajući zasebni upravljački sklop. Upravljački signal za kontrolu upravljačkih sklopova za električne motore generiran je izravnim standardnim izlazom (engl. *General Purpose Input Output*; *GPIO*), iz glavnog uređaja (engl. *Master Device*) i pulsno širinski je moduliran kvadratni signal (engl. *Pulse Width Modulated*; *PWM*). Cijeli sustav napajan je s dva neovisna baterijska izvora sa zajedničkim nultim potencijalom (engl. *Common Ground*). Prvo

napajanje je baterijskog tipa (engl. *Power Bank*) te je korišteno za glavni uređaj i LiDAR kako bi se osigurala stabilnost napajanja potrebna za elektroničke komponente TTL naponske razine. Pogonski dio, motori i upravljački sklopovi za motore napajani su zasebnim akumulatorskim napajanjem većeg kapaciteta koje može podnijeti veće struje opterećenja, s ciljem dulje autonomije mobilnog robota. Blok dijagram elektroničkog sustava prikazan je na slici 21.

5.2.1. Glavni uređaj mobilnog robota


Na slici 22 prikazano je računalo u obliku kartice i s jednim mikroprocesorom koji sadrži sve glavne komponente jednog računala, što je upravo i glavna karakteristika računala na jednom mikroprocesoru (engl. *System On Chip*). Korišteno je računalo Raspberry Pi 4B. Takvo računalo odlikuje se malim dimenzijama zbog spomenute tehnologije, što je korisno zbog potrebe za mobilnosti robota i njegovog neovisnog rada zbog potrebe istraživanja nepoznatih prostora s nepredviđenim rasporedom eventualnih prepreka. Računalo ima i relativno veliku procesorsku snagu koja je potrebna za brzo izračunavanje upravljačkih parametara za gibanje mobilnog robota pomoću neuronskih mreža i obrade velikog broja podataka o prostoru koji su generirani pomoću LiDAR senzora daljine.



Slika 22. Raspberry Pi 4B SoC računalo.

5.2.2. Laserski senzor daljine za istraživanje prostora

Na slici 23 prikazan je dvodimenzijski laserski senzor daljine s kutom detekcije od 360° . Broj uzoraka u sekundi (engl. *Number of Samples*) je do 8000 uzoraka, što rezultira vremenom uzorkovanja (engl. *Time Sampling*), iznosa $125\ \mu\text{s}$. Toliko veliki broj uzoraka u jednoj sekundi moguć je zbog velike brzine rotacije laserskog odašiljača i primatelja. LiDAR korišten u ovom sustavu može skenirati prostor u dvije dimenzije tj. planarno, uključujući i prepreke u prostoru od 360° s najvećom mogućom udaljenosti detekcije od 12 metara. Moguće je postići i veće udaljenosti detekcije, npr. 18 m uz prilagodbu upravljačke programske podrške. Generirani podaci tj. točke s dvodimenzijskim koordinatama, koriste se u istraživanju nepoznatog prostora i za modeliranje kognitivnog modela okoline u kojoj se robot giba u svrhu istraživanja. Senzor daljine priključen je na komunikacijsko sučelje preko kojeg odašilje podatke o detektiranim točkama koje opisuju prostor. Nazivna frekvencija skeniranja laserskog senzora daljine, model RPLIDAR A2, iznosi 10 Hz, što odgovara 600 o/min. Stvarna frekvencija skeniranja može se prema želji korisnika prilagoditi u intervalu od 5 do 15 Hz. Laserski senzor daljine koristi metodu laserske triangulacije. Takav senzor daljine pokazuje iznimne detekcijske mogućnosti u različitim unutarnjim i vanjskim okruženjima, bez utjecaja vanjskih pojava kao što je sunčeva svjetlost na njegovu sposobnost detekcije prepreka.



(c)



Slika 23. LiDAR u sklopu mobilnog robota: (a) RPLiDAR A2 uređaj; (b) model LiDAR uređaja korišten u simulaciji (CoppeliaSim; jedna zraka svakih 36°); (c) RPLiDAR A2 uređaj instaliran na eMIR-u..


5.2.3. Pogonski sklop i napajanje

Za napajanje glavnog uređaja i LiDAR-a korištena je baterija kapaciteta 10 000 mAh, napona prikladnog TTL logici uređaja iznosa 5 V. Za napajanje pogonskog dijela mobilnog robota kojeg čine istosmjerni motori i upravljački uređaji, korištena je baterija kapaciteta 2000 mAh, nazivnog napona 12 V. Sustav na upravljačkoj tiskanoj pločici sadrži i pretvarač napona na dolje (engl. *Step Down*), što omogućava svesti cijelu konfiguraciju robota na jedan izvor napajanja. Korišteni su istosmjerni električni motori s četkicama (model IG320071X0014), nazivnog napona iznosa 24 V. Najveća nazivna brzina električnih motora je iznosa od 0,733 okr/s, pri kojoj je struja (engl. *Draw Current*) iznosa 200 mA. Na kućištu motora se nalazi enkoder, koji se koristi za detekciju pomaka izlazne osovine motora, posljedično i pogonskog kotača. Na izlaznoj osovini motora pričvršćen je reduktor koja ima prijenosni omjer $i = 71$, u svrhu povećanja okretnog momenta na pogonskom kotaču mobilnog robota koji je izravno pričvršćen na izlaznu osovinu reduktora. Za generiranje upravljačkog signala korištenog za upravljanje električnim motorima korišteni su upravljački sklopovi, model LMD18200T. Najveća moguća izlazna nazivna struja upravljačkih sklopova iznosi 3 A, što je upravo i karakteristika bitna za odabir upravnog tog modela upravljačkih sklopova, kako bi odgovarali izabranim električnim motorima. Upravljački signal za upravljačke sklopove je pulsno širinski moduliran signal, frekvencije 330 kHz. Brzinom vrtnje motora upravlja se pomoću pulsno širinske modulacije signala, tj. promjene intervala trajanja visoke razine signala (engl. *Duty Cycle*). Eksperimentalnom metodom utvrđeno je da motori imaju nedovoljan iznos izlaznog okretnog momenta na osovini reduktora, ukoliko je promjena signala (engl. *Duty Cycle*), manja od 30% visoke razine signala. Stoga, brzina vrtnje motora upravljanja je

modulacijom promjene signala od 30% do 100%. Upravljački signal generiran je na glavnom računalu pomoću hardverskih generatora pulsno-širinskog signala (engl. *PWM*), spojenim na standardni izlaz glavnog računala (engl. *GPIO*). Potrebno je upravljati i smjerom vrtnje motora, što ovi upravljački sklopovi za električne motore također podržavaju. Uz korištenje standardnih izlaza glavnog uređaja i upravljačkim signalom koji može biti 3,3V ili 0V, upravljan je smjer vrtnje motora, posredno preko upravljačkih sklopova.

5.3. Razvoj programske podrške sustava

Na slici 24 prikazan je kronološki blok dijagram softverskih dijelova koji čine postupak izrade konačnog kognitivnog modela nepoznatog prostora. U nastavku je detaljnije opisan svaki od segmenata.



Slika 24. Funkcionalni blok dijagram razvijenih softvera korištenih u fazama učenja, simulacije i testiranja naučenih kognitivnih modela istraživanja robota u realnim eksperimentima.

5.3.1. Dizajn i treniranje softvera neuronske mreže

Neuronske mreže kao i genetski algoritmi pisani su u programskom jeziku C++, u razvojnom okruženju paketa Qt Creator IDE, iz početka što znači da nisu korištene biblioteke poput TensorFlow [35] ili Keras [36]. Spomenute biblioteke su najčešće korištene u području umjetne inteligencije. U ovom su istraživanju razvijeni "od nule" zbog uvida u svaki segment same neuronske mreže i mogućnosti prilagođavanja svakog segmenta neuronske mreže zbog konkretne problematike koju korištena umjetna inteligencija mora riješiti u predloženoj hipotezi. Već spomenuti manjak parametara neuronske mreže i genetskih algoritama dovodi do toga da je potrebno pronaći bar okvirne vrijednosti sa kojima bi se provodio pokus. Bitno je naglasiti kako postoji beskonačan broj različitih parametara i njihovih kombinacija koje se mogu koristiti, tako da se neke pretpostavke za početak provođenja pokusa moraju uzeti u obzir (tablica 1). Opisati će se glavni parametri neuronskih mreža i genetskih algoritama, korišteni u eksperimentima kojima se potvrdilo postavljenu hipotezu, a sve u svrhu izgradnje kognitivnog modela zatvorene okoline mobilnog robota:

Veličina neuronske mreže – veličina mreže svakako ima veliki utjecaj na gibanje robota, brzinu učenja, kompleksnost putanje itd. Kao veličina se uzima jedna ili dvije neuronske mreže na kojima se mijenjaju ostale kombinacije parametara. Veličine neuronske mreže su uzete sa pretpostavkom da će manja (5x5) biti na granici da se uspješno koristi za istraživanje poligona. Tako da će ostale dvije neuronske mreže (10x10 i 15x15) biti sigurno dovoljne za kvalitetno istraživanje poligona.

Broj populacija – veličina koja je u korelaciji sa raznolikosti neuronske mreže unutar jedne generacije. Što je broj veći, veća je mogućnost dobiti raznolikost unutar jedne generacije. Broj je odabran kao neka optimalna vrijednost između vremena trajanja jedne generacije i dovoljne raznolikosti da bi u evoluciji imali dovoljno različitih neuronskih mreža za napredak. Već spominjana raznolikost neuronske mreže najbolje se opisuje primjerom da imamo samo nekoliko populacija, npr. dvije populacije u jednoj generaciji. To znači da imamo samo dva križanja i mutacije neuronskih mreža iz prethodne generacije. Očekivano je da će se unutar te generacije neuronska mreža neznatno promijeniti, i kao takva je kandidat za sljedeću koja će se također jako malo promijeniti. Iz toga se zaključuje da će evolucija vrlo sporo, ili čak neznatno napredovati. Većim brojem populacija dobiva se više raznolikosti, što znači više onih neuronskih mreža koje su potencijalno lošije od prethodne generacije, ali i onih koje su bolje

od predhodne generacije. Još veći utjecaj ima početna nulta generacije gdje su svi težinski koeficijenti generirani nasumično, pa tako više populacija znači puno više mogućih kombinacija težinskih koeficijenata koji definiraju neuronsku mrežu. Takve neuronske mreže imaju potencijal postati najbolje, tj. one na kojima će se dalje graditi neuroevolucija.

Ulazna aktivacijska funkcija – vrijednosti ulaza neuronske mreže ponekad nisu pogodne jer nedovoljno pobuđuju neuronsku mrežu, odnosno, ulaznim promjenama nedovoljno se mijenjaju izlazi. Velika promjena ulaza rezultira malom ili nikakvom promjenom izlaza. Takvo ponašanje je nedopustivo jer neuronska mreža gubi svoju sposobnost „odlučivanja“. Možda je zornije objašnjeno običnom linearnom funkcijom $f(x) = 0 \cdot x$. Za bilo koji x , $f(x)$ će uvijek biti 0. Takva funkcija jednostavno nema smisla. Korištene ulazne aktivacijske funkcije odabrane su iz standardnih aktivacijskih funkcija koje se koriste kod neuronskih mreža, a to su Sigmoid i ReLU, koje su detaljnije objašnjene u poglavlju 4.1. Ove vrste aktivacijskih funkcija su odabrane jer se podudaraju sa već spomenutim, najčešće korištenima u nekom modificiranom obliku. Ideja je provjeriti ponašanje neuronske mreže prilikom linearne pobude i pobude opisane sigmoidom odnosno asimptotskom pobudom kao sastavnim članom sigmoid funkcije. Standardne funkcije su modificirane u vidu povećanja ili smanjenja njihovih amplituda djelovanja, to se odnosi na povećanje izlaznih vrijednosti kod modificirane sigmoid funkcije. Njihove amplitude djelovanja unutar nekog intervala provjerene su da osiguravaju dovoljnu raznolikost ulaznih vrijednosti što je jedna od zadaća ulazne aktivacijske funkcije. I drugo, kako će se ponašati neuronska mreža prilikom neke nelinearne funkcije kao sigmoid. Više informacija o samoj prirodi intervala unutar neuronske mreže biti će u sljedećem odlomku. Samo na primjeru ulazne aktivacijske funkcije vidi se mogućnost izbora i primjene različitih funkcija i njihovih modifikacija. Sve to je uzrok vrlo teškom, ili skoro nemogućem dobivanju matematičkim putem, informacije koja funkcija je najpogodnija.

Aktivacijska funkcija – odnosi se na aktivacijske funkcije skrivenih slojeva unutar neuronske mreže. Za rješavanje skrivenih slojeva neuronskih mreža odabrana je ReLU aktivacijska funkcija koja se sastoji od propuštanja vrijednosti u pozitivnom dijelu i prigušenja (smanjenja) vrijednosti u negativnom dijelu. To je jedna od standardnih funkcija koja se koristi uz Sigmoid, kod neuronskih mreža. Sigmoid je neprimjeren za korištenje jer se njegove vrijednosti kreću od 0-1. Moguće je i proširiti ovaj interval, modifikacijama, ali će uvijek ostati određeni interval unutar kojeg će se vrijednosti kretati. Takva pojava nije optimalna kod ovakve vrste problematike i više se koristi kod neuronskih mreža gdje kod izlaza očekujemo neko bitovno odlučivanje, gdje je izlaz 0 ili 1, što ovdje nije slučaj. Još jedna karakteristika Sigmoida je zasićenje. Zasićenje se očituje kada je ulaz u Sigmoid prevelika vrijednost. Na slici 11 se vidi,

u pozitivnom dijelu koordinatnog sustava, da, ako ulazna vrijednost (na osi x) prijeđe vrijednost 5, izlazna vrijednost će biti jako blizu 1, da će se daljnjim povećanjem ulazne vrijednosti izlaz mijenjati zanemarivo malo, do mjere kada se više uopće ne mijenja. Tako da može postojati različiti interval pobude na ulazu, a da na izlazu vrijednost ostaje 1. Isto to se događa i u negativom dijelu samo se izlaz u tom slučaju asimptotski približava vrijednosti 0. Takvo ponašanje je u nekim slučajevima poželjno, kao što će biti objašnjeno u nastavku.

Korištenje funkcije Sigmoid kod računanja unutarnjih slojeva, npr. ako su ulazne veličine u neuronsku mrežu u mjernim jedinicama milimetrima, daje za rezultat da bi interval takvih vrijednosti bio od par stotina do nekoliko tisuća, ovisno o poziciji robota na poligonu. Takav interval, kao ulaz u Sigmoid bi rezultirao konstantnom izlaznom vrijednosti iz Sigmoida koja bi bila 1.

Zato se koristi ReLU funkcija koja nema ograničenja izlaza u odnosu na ulaze i moguće je s njom dobiti puno veće raznolikosti. Moguće je samo skalirati veličine izlaza u odnosu na ulaz. Bez obzira na prije spomenuto, još uvijek ulazne i izlazne veličine neuronske mreže moraju biti u određenoj korelaciji, što će jednim dijelom biti opisano u nastavku.

Odabrana aktivacijska funkcija, koja se koristi na izlaznom sloju neuronske mreže, jest Sigmoid. Ona ostaje nepromijenjena kroz cijeli pokus, tako da nije dio tablice 1. Sigmoidom se jako dobro opisuju izlazne vrijednosti koje se nakon skaliranja provode u intervalu 0-10, što se koristi kao brzina prilikom simulacije, te još u modificiranom obliku i u realnom robotu. Iz razloga što se koristi Sigmoid, ulazne vrijednosti moraju se nalaziti u određenom intervalu kako ne bi došlo do zasićenja. Pravilnim izborom ulazne funkcije, kao i funkcije unutar neuronske mreže, ulazne vrijednosti moraju biti podešene tako da na ulazu izlaznog sloja neuronske mreže Sigmoida ne dolazi do zasićenja. Ovaj proces je teško matematički opisati. Mogu se izračunati eventualno minimumi i maksimumi koji se opet svode na aproksimacije.

Parametri bodovanja odnose se na način računanja i vrednovanja pojedinačnih bodova. Svakom pojedinačnom bodu se pridodaje određeni koeficijent koji određuje sa kojim udjelom on sudjeluje u ukupnom broju bodova. Koeficijenti koji su korišteni određeni su eksperimentalno sa određenim prepostavkama. Koeficijent koji ima najviše utjecaja na bodove se odnosi na istraživanje, tako da se robota prisiljava na istraživanje prostora.

Primjerom će biti opisan način bodovanja u slučaju kada bi najviši koeficijent bio pridodan npr. bodovima razlike brzine kotača, koji definira da se robot giba što ravnije uz manje mijenjanje kuta zakreta. U tom slučaju prilikom neuroevolucije, robot bi išao samo ravno po poligonu, bez ikakvih kutnih pomaka. Ako bi robot u nekoj od generacija i skrenuo, ta neuronska mreža bi dobila puno manje bodova vezanih za promjenu brzina, a kako ti bodovi imaju najveći utjecaj


(recimo 100x u odnosu na druge) takva neuronska mreža ne bi sudjelovala u formiranju sljedeće generacije. Tako bi se odmah sankcioniralo bilo kakvo skretanje, odnosno promjena u razlici brzine kotača. Primjerom se pokušalo pokazati koliko utječu različiti utjecaji pojedinih bodova na ishod, a sve u vidu što optimalnijeg ponašanja robota i prisile robota da se ponaša u zadanim okvirima. Način bodovanja provjeren je u samim pretpokusnim radnjama. Jednom odabran, tijekom različitih pokusa se ne mijenja, kako bi se rezultati mogli uspoređivati prema broju bodova.

Mutacija – već objašnjen parametar koji određuje koliko će se mijenjati svaka sljedeća generacija u odnosu na prethodnu. Veličina je određena pretpostavkama da prevelika mutacija previše mijenja neuronsku mrežu kroz neuroevoluciju, pa tako iz neuronske mreže koja ostvaruje puno bodova može postati najgora moguća. Nema postupnog napredovanja nego skokovitog, teoretski se može postići veliki broj bodova već u prvoj generaciji, ali se on najčešće drastično smanji već u nekoliko sljedećih generacija.

Premala mutacija jako malo mijenja neuronsku mrežu pa tako iz generacije u generaciju nema skoro nikakvih promjena ili su one jako male. Najčešće je prirast broja bodova iz generacije u generaciju jako mali. Neuroevolucija napreduje ali malim, postepenim trendom. To znači da je potrebno puno generacija i puno vremena da se dođe do željenog učinka.

Bitno je naglasiti da svi odabrani parametri sigurno nisu najbolji za odabranu problematiku. Kompleksnost i sama priroda neuroevolucije i manjak informacija oko odabira istih, daje veliku širinu odabira. Svakako da su korišteni parametri i više nego dovoljni za daljnje proučavanje iste problematike. Treba dati do znanja da postoji neograničen broj mogućnosti korištenja parametara i njihovih kombinacija koje se mogu koristiti, a u ovome su istraživanju odabrani prema pretpostavkama iz eksperimentalnog proučavanja neuronskih mreža.

5.3.2. PC aplikacija za kontrolu i prikupljanje podataka za izgradnju kognitivnog modela prostora robota (GUI)



Slika 25. PC aplikacija za kontrolu neuronske mreže i prikupljanje podataka.

GUI se sastoji od tri moda rada (tipke se nalaze u gornjem lijevom kutu prozora), prikazano na slici 25: *New* – mod rada kod kojeg započinje učenje iz nule, što znači da učenje započinje generiranjem nasumičnih težinskih koeficijenata; *Continue* - mod rada kod kojeg se nastavlja učenje već prethodno naučene neuronske mreže. Ovaj mod započinje generiranje težinskih koeficijenata u sustavu; *One run* – mod koji služi za validaciju rezultata odnosno kretanje eMIR-a u nekom nepoznatom okruženju nakon već naučene neuronske mreže. Ovaj mod predstavlja puštanje u rad u stvarnom svijetu. Dakako tu je i tipka za spajanje sa CoppeliaSim simulacijskim okruženjem. Dalje u samom središtu GUI prozora nalazi se dio zadužen za prikazivanje istraženog prostora koji je eMIR pretražio i koji se sastoji od mape veličine 200 x 100 piksela odnosno skalirani prostor poligona veličine 400 x 200 cm, što znači da cijeli sustav mapira prostor u rezoluciji od 2 cm. U gornjem desnom kutu nalaze se podaci o vremenskim intervalima. Prikazuje se vrijeme potrebno aplikaciji i simulaciji da proračuna jedan korak simulacije. Tu se nalazi i razlika te dvije brzine s obzirom da je vrijeme proračuna jednog koraka CoppeliaSim-a uvijek veće, i razvijeni program čeka CoppeliaSim da vrati izračunate vrijednosti prema programu. U donjem lijevom kutu ispisuju se trenutna generacija, broj sakupljenih bodova sakupljenih u prethodnom članu populacije, kao i najbolji broj bodova prikupljen u generaciji. U tom dijelu nalaze se tipke za prikaz prozora za ispis grafova. Grafovi se generiraju nakon svake generacije gdje ispisuju sve pojedinačne bodove i ukupan broj bodova najbolje neuronske mreže u generaciji. Sljedeća tipka prikazuje cijelu neuronsku mrežu u realnom vremenu. Prikazuju se ulazi i izlazi neuronske mreže. Također se prikazuju i sve težinske funkcije kao i vrijednost neurona za svaki sloj neuronske mreže.

5.3.3. Upravljački softver mobilnog robota


Unutar *Raspberry Pi* mini računala koji upravlja eMIR-om u stvarnom svijetu nalaze se algoritmi neuronske mreže odnosno onaj dio koji se odnosi na *feedforward* računanje izlaza iz neuronske mreže. Kada se pokrene način za pretraživanje prostora odnosno kada se eMIR počne kretati, iz tekstualnih datoteka težinski koeficijenti se učitaju u samu aplikaciju. Težinski koeficijenti su rezultat učenja eMIR-a na poligonima unutar simulacije i nakon zadovoljavajućeg ponašanja i sakupljenog određenog broja bodova prebačeni su na *Raspberry Pi*. Nakon učitavanja težinskih koeficijenata počinje računanje neuronske mreže prikazano slikom 12. Isti algoritam koristi se i u simulaciji samo se u ovom slučaju koriste kao ulazi u neuronsku mrežu stvarne udaljenosti izmjerene LiDAR-om. Bitno je napomenuti da su te vrijednosti identične, izražene u metrima, samo dolaze iz drugog izvora. Isto tako i kod izlaza



se pretvaraju u PWM, tako da se vrijednosti u rasponu od 0 do 10, moraju skalirati na vrijednosti od 0 – 1023 što je raspon 10-bitnog PWM-a koji je korišten. Izlaz neuronske mreže koristi samo skaliranje vrijednosti i ne koristi nikakvu drugu upravljačku logiku. Dio sa ulaznim i izlaznim varijablama, koji se jedino razlikuje od onog iz simulacije prikazan slikom 12, nalazi se sa desne strane gornjeg i donjeg dijela slike. Uzimamo u obzir da robot istražuje nepoznat prostor, sa nama poznatim elementima (ne i robotu), i, preprekama koje se sastoje od ograde kojom je prostor ograden. Eventualno promijenjene pozicije i orijentacije nama poznatih objekata, tj. elemenata, robotu također, na neki način, predstavljaju prepreke. Robot kreira mapu prostora i prepoznate, nama poznate predmete (ne i njemu poznate) semantički opisuje (plav, trokut, položaj, orijentacija itd.). Ostali nepoznati objekti su prepreke. Nakon toga se kreira virtualni model, tako mapiranog prostora, i planira se kretanje. Zaključak je da se u ovom istraživanju radi s nama poznatim prostorom i elementima u njemu, na način da se prvo stvori simulacijski model ponašanja robota u njemu nepoznatom okolišu, a onda se kopira razmještaj objekata na realnom poligonu i provjerava koliko je simulacija dobra. Dobiveni rezultati pokazuju da je ponašanje u simulaciji i u realnom sustavu gotovo identično, skoro 100%. To je svakako vidljivo u [40, 41]. Isto tako direktnim prebacivanjem težinskih koeficijenata iz simulacijskog dijela u stvarni, eMIR se ponaša “identično” kao i u simulaciji sa minimalnim preinakama u već spomenutom ulaznom i izlaznom dijelu neuronske mreže. Mobilni robot eMIR se može „naučiti“ u kratkom vremenskom intervalu jer je potreban samo korak za napraviti prijenos već spomenutih "naučenih" težinskih koeficijenata i izvršiti zahtjev za istraživanjem nepoznatog prostora koje će se obaviti kao što je učinjeno u simulaciji. To znači da je razlika simuliranog i stvarnog minimalna i put od simuliranog do stvarnog ponašanja eMIR-a je vrlo kratak s obzirom da je potrebno samo poslati već spomenute “naučene” težinske koeficijente i pokrenuti sustav koji će kao takav raditi. Ovakvim pristupom se mogu provoditi razna ispitivanja kao i učenja puno kompleksnijih zadataka što je logičan nastavak ovog rada i očekivati “iste” rezultate kao i kod realnog robota. Sličan je princip rada već ranije spomenutog CAD/CAM/CNC lanca gdje se nakon modeliranja i stvaranja virtualne obrade modeliranog komada generira G-kod. Takav G-kod se prebacuje na CNC stroj i najčešće su potrebne preinake takvog koda zbog razlike između same virtualne upravljačke jedinice prema kojoj je generiran kod i stvarne koja je različita i ne može pročitati takav kod. Očigledno je da se takav sustav ponaša deterministički što znači da je već unaprijed sve zadano i poznato i nema puno veze sa načinom ponašanja eMIR-a koji je jedan nedeterministički sustav gdje se samo ponašanje robota mora provjeriti u nekoj okolini koja mu nije poznata. Okolina mu postaje poznata nakon učenja ponašanja u nepoznatom prostoru. To je svrha dokazanog kognitivnog ponašanja. Bez obzira na različita

ponašanja prije spomenutih sustava, dobra je paralelna usporedba kognitivnog ponašanja mobilnog robota eMIR sa nekim "svakodnevnim" industrijskim sustavom, kao što je to već danas slučaj sa npr. CAD/CAM/CNC lancom. Iako je ponašanje robota djelomično nedeterminističko (kaotično), blisko je čovjeku koji također djeluje svojim ponašanjem nepredvidivo, zbog ljudske prirode kao takve i percipiranju svijeta oko sebe na nedovoljno precizan način.

5.3.4. Vizijski sustav za provjeru puta

Iznad poligona postavljena je web kamera C920 proizvođača Logitech (slika 26). Kamera služi za snimanje video zapisa gibanja robota u istraživanju dotad nepoznatog prostora, u ovom slučaju poligona. U CoppeliaSim simulatoru kamera je postavljena iz razloga da bi se pratilo gibanje virtualnog robota u virtualnome okruženju, dok je na stvarnome sustavu postavljena zbog provjere točnosti kognitivnog modela ponašanja realnog gibanja, u odnosu na gibanje dobiveno simulacijom. U početnoj fazi eksperimentalne validacije dobivenih simulacijskih rezultata, na mobilnome je robotu bila pričvršćena vrećica sa pijeskom, koji je ostavljao vidljiv trag na podlozi što je i vidljivo na slici 33b. S obzirom da korištenje pijeska nije praktično rješenje, razvijen je softverski dio koji je u stanju prikazati kretanje robota u obliku kretanja geometrijskog težišta mobilnog robota u ravnini (slika 26c). U ovome slučaju je težište mobilnog robota upravo laserski senzor smješten na robotu.







Slika 26. Razvijeni vizijski sustav za provjeru ponašanja robota u naučenome kognitivnome modelu njegova prostora: (a) položaj kamere za kontrolu postavljene iznad poligona (shematski prikaz); (b) položaj i orijentacija apsolutnog koordinatnog sustava eksperimentalnog postava (shematski prikaz); (c) generirana putanja (iz video zapisa snimljenog kamerom sa slike 26a) gibanja mobilnog robota (iz samostalno naučenog kognitivnog modela prostora robota) koju je robot trebao proći da bi uspio pretražiti kompletni poligon LiDAR-om.

5.3.5. Izrada kognitivnog modela prostora


Na temelju kinematičkog modela mobilnog robota predstavljenog u poglavlju 3, moguće je fuzijom različitih podataka (prikupljenih pomoću mjernih senzora), i, projektiranim algoritmom, konstruirati kognitivni model prostornog okruženja u kojem se nalazi mobilni robot. Kognitivna karta je temeljni dio cjelokupnog kognitivnog modela zatvorenog okruženja. Podaci o okolišu dobiveni čitanjem kognitivne karte, osnova su za planiranje optimalne putanje kretanja mobilnog robota tijekom planiranog istraživanja. Na kraju postupka istraživanja mobilnog robota, uspostavlja se popis kognitivnih informacija o okruženju u kojem se robot nalazi. Konfiguracija okruženja, tj. poligona dobiva se pomoću popisa prikupljenih podataka. Informacije o prostoru, tj. prikupljeni podaci sastoje se od ulaza u sobu (što se smatra početnom točkom poligona) pa sve do relativne točke u kojoj je robot postigao dovoljno dobar rezultat istraživanja. Fuzija podataka prikupljenih s laserskog senzora daljine (LiDAR) i integracijom upravljačkog signala motora dobivenih podataka, dobiveni su elementi korišteni za izradu kognitivne karte, kao što je i prikazano na slici 27.




(b)




(c)



(d)





(e)

Slika 27. Kognitivni model i kognitivna karta prostora: (a) odabrana konfiguracija poligona; (b) kognitivna karta poligona dobivena simulacijom; (c) eksperiment na stvarnom poligonu s praćenjem putanje kretanja robota; (d) karta zatvorenog prostora dobivena fuzijom podataka dobivenih iz senzora robota, osnova za izgradnju kognitivne karte; (e) tumačenje dobivenih (sposobnošću mobilnog robota za kognitivno istraživanje) informacija na visokoj razini o prethodno nepoznatom okruženju.

Okruženje je robotu nepoznato, jer je robot u simulacijskom okruženju učio na nekoliko varijanti poligona, a, pušten je u poligon koji je drastično izmijenjen, u odnosu na one poligone na kojima je učio. Korištenjem funkcija programskog alata za vizijske sustave OpenCV, na posrednim rezultatima sa slike 27d stvaraju se granični okviri (engl. *Region of Interest*), koji stavljaju u područje interesa otkriveni objekt nad kojim se izračunava i površina tog objekta. Klasifikacija se postiže usporedbom površine graničnog okvira Abb i površine objekta $Aobj$. Tipove objekata mi znamo, no, robot ih ne zna. Mora postojati baza iz koje radi usporedbe, jer, kao i kod npr. djeteta, s čim će dijete usporediti, i, reći da je nešto npr. lopta, ako je prije nije vidio, i, memorirao, tj. vizualizirao je, i, zapamtio. Omjer površina ograničavajućih okvira i predmeta za svaki objekt korišten u eksperimentu prikazan je u tablici 2:

Tablica 2. Odnosi površina koje se koriste za klasifikaciju otkrivenih objekata u eksperimentu.


Objekt	Trokut	Krug	Kvadrat	L poligon	Zaobljeni poligon
Abb/Aobj	2	$4/\pi$	1	9/5	$18/(14-\pi)$
Raspon omjera	1,9–2,1	1,15–1,4	0,9–1,1	1,7–1,85	1,5–1,67

Treniranje robota u simulaciji se odvija na tri poligona simultano. Primjer učenja na takvim poligonima se može vidjeti na 1:53 do 2:08 u [40]. Rezultati s tri poligona, i šest generacija (3:07 u [40]), zapisani u datoteku, spremni su za gradnju kognitivnog modela, koji izgleda kao na 4:13 u [40], kada govorimo o simulaciji. Da bi se to učenje ubrzalo, točnije 30 puta, osmišljen je sustav mreže računala koji je opisan u nastavku.

5.4. Sustav mreže računala


Topologija sustava mreže računala za učenje i treniranje neuronskih mreža prikazana je blok dijagramom na slici 28. Računala su umrežena u lokalnu mrežu pomoću mrežnog preklopnika (engl. *Switch*), koji je preko servera povezan na Internet. Na glavno (engl. *Master Computer*) računalo je instaliran programski alat *TeamViewer* za udaljeni pristup, čime je dobivena prednost udaljenog pristupa mreži računala. Takav sustav može se nadzirati iz bilo koje lokacije u stvarnom vremenu, što omogućuje provjeru procesa učenja i treniranja neuronskih mreža te nadziranje trenutne vrijednosti pokazatelja naučenosti neuronske mreže (engl. *Score*). Nadzirući vrijednost pokazatelja naučenosti neuronske mreže, donosi se zaključak da li proces učenja napreduje prema očekivanom trendu. Uz upotrebu eventualno dostupnog super računala koje ima veliku procesorsku snagu za računanje neuronskih mreža, ovakav sustav postao bi

redundantan, no, u nedostatku istog, ovakav sustav je omogućio dovoljnu brzinu računanja neuronskih mreža, kako bi eksperiment bio izveden u praktičnom vremenskom intervalu.



Slika 28. Mreža računala za učenje i treniranje neuronskih mreža.

Lokalno upravljanje umreženim računalima obavlja se preko glavnog dijela sustava, koje je nazvano glavno računalo (engl. *Master Computer*). Na tom računalu je instaliran *Veyon Master* programski alat, dok je na svih ostalih 30 računala instaliran isti programski alat u inačici klijent alata *Veyon Slave*. Korisničko sučelje programskog alata *Veyon* u radu je prikazano na slici 29. U narednim stadijima istraživanja svakako se planira izrada algoritma koji će automatizirati iteracije učenja i treniranja neuronskih mreža. Ideja je uzimati s 30 računala naučene vrijednosti upravo s onog računala na kojemu je neuronska mreža postigla najveći pokazatelj učenja u prethodnoj iteraciji i time dala najbolje rezultate. Ovakvim automatizacijskim algoritmom automatizirala bi se podjela te neuronske mreže preostalim 29 računala, kako bi dalje trenirali neuronske mreže s najboljim rezultatima prethodne iteracije. Nakon odrađenog željenog cilja, vremenskog ili u obliku postignute željene vrijednosti pokazatelja naučenosti neuronske mreže, glavno računalo bi prosljedilo podatke u smislu naučene, tj. istrenirane neuronske mreže na udaljeno računalo preko Interneta.



Slika 29. Korisničko sučelje programskog alata Veyon za upravljanje lokalnom mrežom računala.

6. Rezultati

Ideja gradnje kognitivnog modela je bila temeljena na pretraživanju prostora na sličan način kako to i čovjek radi. Zamislamo da čovjek uđe u potpuno mračnu, nepoznatu prostoriju u kojoj prije nije bio. U prostoriji se nalazi 5 objekata opisanih u tablici 2, tj. prostorija izgleda kao poligon sa slike 2a, samo dimenzija 20x40 metara (prosječan je čovjek 10 puta veći, otprilike, od mobilnog robota eMIR). Pozicija gdje čovjek uđe u takvu prostoriju je točno na mjestu gdje je i pozicija robota na slici 27a. Rukama, i, nogama bi dodirivao zidove koji omeđuju prostoriju, odnosno predmete koji su u prostoriji smješteni. U slučaju da se zaleti u neku od prepreka, vidljivo na 1:37 u [40], vratio bi se nekoliko koraka unatrag, te bi krenuo ponovno dalje, vodeći računa o mjestu, tj. prepreci u koju je udario, da pokuša tu situaciju izbjeći (u novoj „iteraciji“ pretraživanja). Uzastopnim ponavljanjem tih radnji, čovjek bi bio sve sposobniji proći cijelu prostoriju, u sve kraćem vremenu, sa što manje udaranja u prepreke, i, sa što manjim brojem koraka, tj. put koji bi prolazio u tom zadatku bi bio sve kraći. „Fuzijom podataka“, tako prikupljenih, čovjek bi dobio „elemente“ za izradu kognitivnog modela, kao što je i prikazano na slici 27d. Mogli bismo reći da bi crna linija (slika 27d) bila putanja kojom bi se čovjek kretao (po toj bi liniji hodao), a crvene točkice bismo mogli nazvati „točkama koje je čovjek opipao rukama“. Veoma je važno napomenuti ključnu razliku između pretraživanja nepoznatog prostora čovjeka i mobilnog robota (korištenog u ovome istraživanju), a ta je da korišteni LiDAR ima domet od 12 metara, dok čovjek može dosegnuti rukom, u prosjeku, prepreke na udaljenosti od oko jednog metra. To bi značilo, da bi se čovjek morao „prošetati“ i između objekata u prostoriji kako bi mogao „dodirnuti“ sve crvene točkice rukama (slika 27d). Robot to ne mora učiniti (prolaziti između objekata) jer su algoritmi pretraživanja projektirani na način da pretraži cijeli prostor, a da pri tome napravi što kraći put, i, da sve to napravi u što kraćem konačnome vremenu. Robot se može kretati i između predmeta u poligonu, ali nema potrebe, s obzirom na dobre karakteristike korištenog LiDAR-a. Svrha istraživanja nije bila unaprijedno planiranje putanje gibanja robota, već je putanja kojom se robot kretao generirana nakon što je pretražio cijeli prostor i obavijestio gdje se što nalazi, a to se reprezentira u formi kognitivnog


modela zatvorenog prostora. Podaci o okolišu, dobiveni čitanjem kognitivne karte, bili su osnova za planiranje optimalne putanje kretanja mobilnog robota tijekom provedenog istraživanja. Dokazana je hipoteza o glavnim doprinosima predloženog istraživanja. Na kraju postupka istraživanja mobilnog robota, uspostavlja se popis kognitivnih informacija o okruženju u kojem se robot nalazi (4:02 do 4:31 u [40]). Dobivenom kognitivnom kartom utvrđuje se visoka razina informacija o prostornom okruženju, bliska informacijama generiranim uz pomoć sposobnosti ljudske percepcije prostora. Kognitivna karta nepoznatog prostora izrađena je bez ikakvih unaprijed definiranih podataka iz stvarnog svijeta, tj. robot prethodno nije poznao raspored objekata i okruženje u kojem se kreće. Poznata mu je samo "memorija" predstavljena u tablici 2, kako bi mogao raspoznati o kojem se obliku radi. Kao i kod ljudi, da bi mogli raspoznati radi li se o npr. autu, autobusu, tenku itd., moraju imati iskustvo od prije, da imaju na temelju čega donijeti odluku/zaključak. Kognitivna karta prostora izgrađena je fuzijom rezultata prikazanih na slici 27b i slici 27d. Ovi posredni rezultati dobiveni su fuzijom očitavanja laserskog senzora daljine instaliranog na robotu i odometrije robota. Ti podaci prosljeđuju se drugom algoritmu koji služi za pretraživanja uzoraka i pronalaženje predmeta s njihovim pripadajućim projekcijama položaja. Projekcije položaja se zatim klasificiraju prema područjima kao što je to prikazano na slici 27e. Otkriveni predmeti moraju se klasificirati prema njihovim geometrijskim značajkama. Za ovu klasifikaciju projektiran je jednostavan algoritam. Zbog smetnji prilikom mjerenja uz pomoć senzora, objekti su klasificirani pomoću prikazanih intervala vrijednosti, tj. omjera (prikazano u tablici 2). Ako je detektirana vrijednost izvan određenog intervala, tada je objekt klasificiran kao nepoznat. To, da je neki objekt klasificiran kao nepoznat, nije se dogodilo niti jednom u procesu istraživanja, što samo govori da se radi o izrazito kvalitetnom razvijenome procesu koji se sastoji od istraživanja, učenja i zaključivanja. Nakon klasifikacije izrađuje se kognitivna karta zatvorenog prostora. Kognitivna karta predstavljena je doslovnim objašnjenjem položaja objekata u istraženom prostoru (informacijom visoke razine kognitivnosti), npr. „plavi trokut jugozapadno“ ili „zeleni krug južno od središta“. Rezultati su prikazani na slici 27e.

Kako je i opisano u poglavlju 4 (gradnja kognitivnog modela okoline mobilnog robota), nakon zaustavljanja eMIR-a, eMIR se resetira na početnu poziciju. Korištena neuronska mreža za vožnju eMIR-a se boduje kao zbroj nekoliko parametara, vidljivih i opisanih u 18:


- istraženost prostora;
- brzina kotača;
- razlika u brzini lijevog i desnog kotača;
- broj iteracija simulacije;

- prijeđena udaljenost;
- kut između eMIR-a i slobodnog prostora.

Rezultati su dobiveni korištenjem 3 različite neuronske mreže 5x5, 10x10, 15x15. Svaka neuronska mreža testirana je sa dvije osnovne ulazne funkcije, modificirani Sigmoid i modificirani ReLU. Ukupna ocjena postignuta tijekom procesa učenja različitih neuronskih mreža s različitim ulaznim funkcijama prikazana je na slici 30 (linearni oblik) i slici 31 (sigmoid oblik). Na slici 30, prikazane su tri krivulje trenda učenja, gdje je korištena linearna funkcija, prikazana na slici 34b, dok su na slici 31 također prikazane tri krivulje trenda učenja, sa korištenom sigmoid funkcijom, prikazanom na slici 34a. Prikupljanje podataka zaustavlja se kada nema vidljivog napretka u procesu učenja neuronske mreže. Stagnacija u procesu učenja može se vidjeti iz trendova u kojima se rastući trend izravna do vodoravne linije ili u nekim slučajevima linija dobiva trend smanjenja, odnosno rezultat se počinje smanjivati. Očekivani broj bodova je približno 16000, što također predstavlja maksimalnu ocjenu. Ovaj broj je teško odrediti upravo zbog same prirode učenja neuronske evolucije.



Slika 30. Rezultat kroz generacije neuronske mreže (Linearni oblik).




Slika 31. Rezultat kroz generacije neuronske mreže (Sigmoid oblik).

Iz grafa sa slike 31 je vidljivo da korištenjem modificirane Sigmoid aktivacijske funkcije (engl. *Sigmoid like*), učenje postiže bolje rezultate. Krivulja učenja (dostignut broj bodova), je strmija i broj generacija je manji u odnosu na ostale. To dokazuje da je robotu za njegovo percipiranje svijeta bitno da poznaje cijelu svoju okolinu, bez obzira na udaljenost. Ovom aktivacijskom funkcijom, koja je detaljnije opisana u poglavlju 7, robotu asimptotski raste utjecaj te udaljenosti kako se približava prepreci, dok je druga aktivacijska funkcija puno lošija te ona opisuje udaljenost linearno i isključivo u lokalnom prostoru robota.


Nadalje, vidljivo je u slučaju korištenja obje funkcije u odnosu na korištenu veličinu neuronske mreže, postizanje boljih rezultata koje postiže ona neuronska mreža koja je većih dimenzija s više neurona. Ne samo da postiže veći broj bodova, nego i te bodove postiže puno brže, u manjem broju generacija. Oba ova segmenta učenja pokazuju da robot brže uči s kompleksnijom mrežom, kao i s ulaznom funkcijom koja uzima u obzir potpunu udaljenost. Takvo ponašanje je i očekivano, s obzirom da će veća neuronska mreža biti u mogućnosti riješiti zahtjevniji zadatak, tj. prikupiti više bodova u manje vremena, jer unutar veće neuronske mreže moguć je puno veći broj kombinacija pa tako ulaznom pobudom i veći broj mogućih izlaza neuronske mreže. Na početku je pretpostavljeno da će veća neuronska mreža trebati više vremena za učenje zbog većeg broja mogućih kombinacija do kojih treba doći mutacijom. Pokusom je pokazano upravo suprotno, iako ima više težinskih koeficijenata, a time bi trebalo više mutacija odnosno generacija da se dođe do odgovarajuće ili skupa odgovarajućih težinskih koeficijenata za zadovoljavajući rad. Utvrđeno je da veća neuronska mreža uključuje mnogo prihvatljivije kombinacije po mnogo bržoj stopi učenja.

Ovaj dio istraživanja pokazao je minimalne dimenzije neuronske mreže dovoljne za prihvatljivo


rješavanje neke scene ili zadatka. Rezultatima prikazanim na slikama 30 i 31 pokazano je i dokazano da se korištenjem veće neuronske mreže, bitno skraćuje vrijeme učenja. Također, moguće je postići više bodova. Daljnjim grafovima prikazanim na slici 32, prikazani su trendovi pojedinačnih ostvarenih bodova za različite veličine neuronske mreže, ali samo za slučaj ulazne funkcije modificiranog Sigmoida, jer su u tom slučaju rezultati nešto bolji i trendovi grafova su konzistentniji, a time su i zanimljiviji za proučavanje. Na slici 32a, koja prikazuje istraženost prostora, vidi se da istraženost prostora ima najveći utjecaj na ukupni rezultat, koji se vidi iz sličnosti sa grafom prikazanim slikom 31, gdje je prikazan ukupni rezultat.




(a)




(b)




(c)



(d)



(e)




(f)

Slika 32. Rezultati učenja neuronske mreže kroz generacije neuronske mreže: (a) rezultat istraživanja; (b) ocjena brzine (koeficijent brzine); (c) ocjena razlike (razlika u brzini); (d) ocjena petlji (broj iteracija); (e) ocjena udaljenosti (dosegnuta udaljenost); (f) rezultat kuta otklona (kut između eMIR-a i slobodnog okruženja).

Grafovi prikazani slikom 32 vezani su samo za pojedinačne bodove učenja funkcijom oblika Sigmoid. Zbog preglednosti na grafovima, odabrana je samo funkcija Sigmoid jer se pokazala puno uspješnija za učenje. Bodovi u grafovima, kako slikom 31 tako i slikom 32, prikazuju samo najbolje bodove iz jedne generacije. Prikazivanje ostalih bodova možda bi dalo jasniji uvid kako se cijela generacija ponaša, ali unošenjem tako velikog broja podataka unijela bi se velika zbrka u grafu.

6.1. Usporedba putanja gibanja mobilnog robota u simulaciji i stvarnosti kod izgradnje kognitivnog modela zatvorene okoline


Ponašanje mobilnog robota tijekom istraživanja okoliša, i njegove putanje kretanja, opisane su u ovom poglavlju. Usporedba putanje kretanja pravog robota i putanje kretanja modela robota u simulaciji pokazala je da je pravi mobilni robot uspio u pokušaju da istraži okruženje kao što je to učinio u simulaciji. Putanje kretanja bile su približno iste, što je također dokaz potvrde postavljene hipoteze. Rezultat, odnosno usporedba simulacijskog i stvarnog sustava prikazana je na 3:10 u [40]. Predloženo istraživanje, koje se bavilo planiranjem djelovanja robota pri istraživanju nepoznatog prostora i simultanom izgradnjom kognitivnog modela prostora, na način sličan kako to i čovjek radi, opravdalo je postavljenu hipotezu koja glasi: *„Korištenjem jezika osnovnih kognitivnih elemenata moguće je opisati okolinu robota i njegov odnos prema toj okolini te je na temelju tog opisa moguće dobiti višu razinu informacije o stanju okoline u kojoj se robot nalazi, fuzijom mjernih podataka dobivenih iz različitih uređaja“*. Dokaz tome je vidljiv na 4:14 na [40]. Proces učenja, koji se temeljio na virtualnome dinamičkom modelu mobilnog robota, istovjetnom stvarnome robotu, pokazao je da predložena, nova metoda stvarnog (*Sim-To-Real*; STR) prijenosa znanja koja uključuje stadij vježbanja, stadij simultanog zaključivanja i stadij primjene naučenog na stvarnome robotu, funkcionira u vidu izgradnje kognitivnog modela prostora. Robusnost nove predložene metode (*Sim-To-Real*; STR), najbolje se očituje u detaljima putanje robota između realnog i stvarnog pokusa. Jedan od takvih detalja koji opisuje istovjetnost putanja, može se najbolje vidjeti prolaskom robota pokraj istog objekta u simulaciji i u stvarnosti, npr. zelenog valjka (slika 33), fokusirajući se na putanju gibanja robota pored istog objekta, gdje se vidi da se robot paralelno odmiče od valjka (slike 33a/b/c).



(a)



(b)



(c)

Slika 33. Put kretanja mobilnog robota: (a) kognitivna karta modela s putanjom kretanja robota; (b) putanja kretanja pravog robota (pješčani trag); (c) putanja kretanja pravog robota (softverski iscrtana u snimljenom video zapisu s kamere).

7. Rasprava

Konstruirana kognitivna mapa unapređuje sposobnosti mobilnog robota na razinu kognitivnih informacija višestruko prikladnijih razini na kojoj čovjek interpretira svojstva okoliša u kojem se nalazi, a vidi se na 4:02 do 4:31 u [40]. Razmjena kognitivnih informacija dobivenih putem mobilnog robota eMIR prikazana je na slici 27e. Ako su podaci o prostoru prikupljeni uz pomoć unaprijed definirane baze podataka u kojoj je definiran izgled prostora i razmještaj elemenata u njemu, tada mobilni robot ne bi bio kognitivan, tj. njegove bi sposobnosti bile umanjene jer ne bi mogao istraživati u neopisanim okruženjima koja nisu uključena u bazu podataka. U procesu istraživanja, mobilni robot mora pridobiti znanje, podatke o okolini, prostoru u koji je smješten. U tom procesu, mobilni robot mora pridobiti za čovjeka razumljive, informacije o prostoru oko sebe. Jedan scenarij iz stvarnoga svijeta je kada čovjek uđe u nepoznatu sobu ili prostor (npr. na poligon na slici 27a, dimenzija 40x20 m). Jedino znanje koje je u tom trenutku dostupno čovjeku su pređeni koraci, proteklo vrijeme istraživanja, približni položaji i orijentacije objekata te prepreka postavljenih u tom okruženju, korelacija između predmeta, prepreka i zidova (dimenzije poligona ili prostorije) te zadnje korelacija između samih predmeta. Moglo bi se reći da obično dok se čovjek kreće i istražuje, recimo hotelsku sobu, u koju je ušao uopće ne broji korake već prepoznaje predmete, boju, veličinu, udaljenosti, itd. No, što u slučaju ako je u sobi mrak? Tada ova prethodna tvrdnja ne stoji. Primjerom korištene ulazne aktivacijske funkcije koja na ulazu (x-os na slici 34) ima vrijednosti udaljenosti robota od nekog objekta, a na izlazu (y-os na slici 34) ima vrijednosti ulaza u neuronsku mrežu (faktori pobude neuronske mreže), valja se detaljnije pozabaviti. Tu se može vidjeti kognitivno ponašanje mobilnog robota (kod gradnje kognitivnog modela) korištenog u eksperimentu, slično ljudskome ponašanju u istim, ili sličnim situacijama. Ako npr. uzmemo situaciju kada čovjek dolazi pred vrata stana, nekoliko metara prije vrata nije mu bitno gdje je točna pozicija kvake, brave itd. Približavanjem vratima na sve manju udaljenost, npr. 20 cm, “aktiviraju se agenti” koji “uključuju” sve precizniju navigaciju npr. ključa pri ulasku u bravu. Prilikom pregleda radova koji se bave neuroevolucijom u mobilnoj robotici nigdje se ne spominju egzaktni parametri neuronskih mreža i genetskih algoritama. Pod time se misli na korištene aktivacijske funkcije, način


bodovanja neuronske mreže, broj populacija unutar jedne generacije, postotak mutacije. U ovom radu je prikazano kako povećanje, ili smanjivanje neuronske mreže utječe na brzinu i kvalitetu učenja, tj. brzinu gradnje kognitivnog modela. Istraživanje je pokazalo da mobilni robot kojim upravlja neuronska mreža dimenzija 5x5 neurona, ima nedovoljne generirane vrijednosti za upravljanje kretanjem robota, jer teži linearnom opisu putanje kretanja mobilnog robota (slika 32). Stadij učenja i treniranja u simulaciji pokazao je da mobilni robot teži kružnim putanjama prilikom kretanja, potaknut pretpostavkom da će manja neuronska mreža imati linearniju putanju kretanja. Nadalje, empirijski su izvedene aktivacijske funkcije za neuronske mreže koje su poboljšale performanse kretanja mobilnog robota te one glase:

Aktivacijske funkcije

$$f(x) = \frac{16}{1 + e^{0.55-8x}} \quad (19)$$

$$f(x) = \begin{cases} 7x, & 0 < x < 1 \\ 7, & 1 < x < 7 \end{cases} \quad (20)$$

gdje x predstavlja udaljenost robota od prepreke izvrsno su polazište za nastavak istraživanja. Aktivacijska funkcija (slika 34a) je puno agresivnija na udaljenostima do 2 m, što znači da je derivacija (ili promjena) vrlo velika što je bliža 0, dok je na udaljenostima od 2 m na više, funkcija jako blaga i asimptotski se približava vrijednosti 8 (na y-osi grafa). Aktivacijska funkcija (slika 34b) je linearna funkcija koja ulaz množi sa koeficijentom 7 do udaljenosti jednog metra, a sve veće udaljenosti od jednog metra postavlja na vrijednost 7.



Slika 34. Matematički opis aktivacijskih funkcija korištenih kod neuronskih mreža za potrebe izgradnje kognitivnog modela prostora robota: (a) funkcija u obliku Sigmoida; (b) Funkcija linearnog oblika.

Funkcija dolazi u zasićenje u slučajevima udaljenosti iznad jednog metra. Funkcijom se opisuje lokalni prostor oko mobilnog robota u radijusu od jednog metra gdje se htjelo provjeriti ponašanje robota u odnosu na njegov lokalni prostor, tj. prostor neposredne blizine robota. Robot (neuronska mreža) neće reagirati na vrijednosti veće od jednog metra (ljudskim riječnikom rečeno, pažnju usmjerava na bitnije informacije, tj. bliže objekte. Različite korištene neuronske mreže dobro pokazuju svoje karakteristike i kod dinamičkih, pokretnih prepreka, u istome poligonu. Rezultati se mogu vidjeti na [41].

Prije opisivanja pravca budućih istraživanja, valja najprije spomenuti da je istraživanje provedeno u smislu smanjivanja jaza između simulacija i realnih gibanja mobilnih robota u nepoznatim okruženjima. Pri tome se je vodilo mišlju da se sve simulacije, učenja i testiranja u realnim situacijama provode na opremi koju prosječni korisnik može osigurati [40]. Vođeni tim ograničenjima, predlaže se povećanje poligona za eksperimentalne provedbe pokusa, samim time i kompleksnijim okruženjima sličnijima okruženjima koja okružuju čovjeka. To dalje vodi do korištenja naprednijih senzora koji su u stanju detektirati, klasificirati i “razumijeti” i kompleksnije prostore. Naravno, kada spominjemo senzore, pri tome mislimo na informacije koje isti trebaju pružiti razvijenim neuronskim mrežama, tj. robotima. Također bi svakako napore trebalo usmjeriti i u probleme kognitivnog modela zatvorenog prostora mobilnog robota, s dinamičkim preprekama, kao što je inicijalno i testirano u [41]. Za takve provedbe eksperimenata potrebna su naprednija računala za fazu učenja, simuliranja, a, isto tako i

interpretaciju naučenog znanja na realnim robotima. Ipak treba napomenuti da je korišteno računalo *Raspberry Pi 4* (4 GB RAM-a), koje ima ograničenja kod kompleksnijih zahtjeva.

8. Zaključak

Tema, tj. hipoteza rada je kognitivni model zatvorenog prostora mobilnog robota temeljen na mjerenjima, dobiven fuzijom mjerenih podataka i korištenjem kombinacije neuronskih mreža i genetskih algoritama. Ponašanje robota, naučeno je neuronskom evolucijom u simulaciji koja predstavlja stvarne uvjete, i, predstavlja puno veće mogućnosti i brže učenje nego na stvarnom robotu. Mogućnost povećanja vremenske konstatne je također moguć, pa ubrzavanjem simulacije i učenje je puno brže. Ovakva vrsta učenja na realnom robotu bi bila skoro nemoguća jer bi učenje trajalo jako dugo. Ako se postavi pitanje na način da robot po definiciji ulazi u nepoznat prostor, kako odraditi off-line učenje za nepoznat prostor i raspored predmeta u njemu? Odgovor bi mogao biti: simulacijom prvo, pa prijenosom na realni sustav. Povećanje broja računskih mjesta dovodi do znatnog ubrzavanja učenja, tj. do bržeg generiranja kognitivnog modela prostora robota. Tako dobiven kognitivni model prostora, korištenjem neuronskih mreža, prebačen je na realnog robota i pokazana je primjenljivost u realnom svijetu.

Metodologija istraživanja sadrži definiranje, analizu i postavljanje odgovarajućeg interaktivnog kognitivnog modela zatvorene okoline mobilnog robota. Validacija i verifikacija modela izvedena je nizom simulacija jednostavnijih problema, koji vode do kompleksnog kognitivnog modela. Oblikovanjem segmenata rada u cjelinu postupno je definiran cjelokupni model interakcije mobilnog robota i okruženja.

Kognitivni model prostora je građen od podataka o položaju i orijentaciji robota, informaciji o objektima koje vidi LiDAR smješten na robotu i informacija s enkodera na pogonskim motorima na robotu, tj, kognitivne mape.

Istraživačka hipoteza i izjave implementirane su na realnom sustavu kojeg sačinjavaju mobilni robot i poligon, opremljeni senzorima (LiDAR s 10 vrijednosti očitavanja i odometrijske veličine, tj. brzine pogonskih kotača robota) i vizijskim sustavima (kamera na robotu i kamera iznad poligona u simulaciji, te kamera iznad poligona u stvarnom postavu). Interakcijom dobivenih informacija dobivena je nova informacija koja koristi robotu, nakon što je pušten u njemu nepoznati zatvoreni prostor, da nakon prihvatljivog vremenskog intervala izvijestiti da

mu je okolina poznata, te uz pomoć osnovnih kognitivnih elemenata opiše gdje se nalazi i što vidi. Ovo je istina, jer je robot pušten u njemu nepoznati prostor, s obzirom da su poznati elementi unutar tog prostora drugačije razmiješteni. Trenirao je i učio u drugačijim prostorima, a, kognitivno ponašanje robota je testirano u novom prostoru, njemu nepoznatom od ranije. Nije prepoznao nepoznate predmete, već predmete koji su mu poznati, prema tablici 2. Razmještaj istih je njemu nepoznat. Nakon završetka početnog zahtjeva za istraživanje nepoznatog okruženja, mobilni robot koristi ove novo dobivene informacije kako bi opisao sada poznato okruženje. Opis se sastoji od osnovnih kognitivnih jezičnih elemenata (oblik prepreke, približna veličina, položaj i orijentacija prepreka u poligonu, boja i sl.), bez precizno definiranih mjernih elemenata poput udaljenosti ili položaja u koordinatnom sustavu u okolišu. Kognitivni model prostora robota, opisan, slično kako bi prostor opisao i čovjek. Opis je usmjeren na lokaciju elemenata u okolišu i njihov izgled, prema naučenim podacima.

Ukratko, glavni znanstveni doprinosi koji su potvrđeni u ovome istraživanju, navedeni su sljedećim redom:

- (1) Spajanjem različitih vrsta podataka iz različitih izvora, kako bi se konstruirale složenije informacije prikladne za izgradnju kognitivnog modela zatvorenog okruženja mobilnog robota, uspostavljen je pouzdan simulacijsko-realni model (STR).
- (2) Definiran je izbor informacija i metoda za izradu modela okruženja koji se koristi za primjene u stvarnom vremenu.
- (3) Konstruiran je kognitivni model zatvorenog okruženja mobilnog robota koji je izravno primjenjiv u stvarnim scenarijima bez unaprijed definiranih podataka iz stvarnog svijeta. To ne znači da postojeći elementi u simuliranom poligonu imaju univerzalna svojstva da pokrivaju sve što će eMIR sresti po prostorijama jedne bolnice, škole, kuće, tvornice, itd. Radi se o scenarijima koji su izrađeni, testirani i dokazana im je primjenjivost u ovome radu. Na tri je scenarija trenirao i učio, i to je znanje primijenio na četvrtom, nepoznatom okolišu od prije, i, uspješno ga je savladao.
- (4) Eksperimentalna provjera i validacija konstruiranog kognitivnog modela zatvorenog okruženja mobilnog robota uspostavljena je u pravom poligonu s pravim mobilnim robotskim sustavom, a uspješna je u punom opsegu hipoteze.

Literatura

- [1] Liu, N.; Lu, T.; Cai, Y.; Wang, S. A Review of Robot Manipulation Skills Learning Methods. *Acta Autom. Sin.* 2019, 45, 458–470.
- [2] Karkalos, N.E.; Efkolidis, N.; Kyratsis, P.; Markopoulos, A.P. A Comparative Study between Regression and Neural Networks for Modeling Al6082-T6 Alloy Drilling. *Machines* 2019, 7, 13.
- [3] Liu, N.; Lu, T.; Cai, Y.; Wang, R.; Wang, S. Real-world Robot Reaching Skill Learning Based on Deep Reinforcement Learning. In *Proceedings of the Chinese Control and Decision Conference (CCDC)*, Hefei, China, 22–24 August 2020.
- [4] Liu, N.; Cai, Y.; Lu, T.; Wang, R.; Wang, S. Real–Sim–Real Transfer for Real-World Robot Control Policy Learning with Deep Reinforcement Learning. *Appl. Sci.* 2020, 10, 1555.
- [5] Thomas, A.; Hedley, J. FumeBot: A Deep Convolutional Neural Network Controlled Robot. *Robotics* 2019, 8, 62.
- [6] Wang, H.; Guo, D.; Liang, X. Adaptive vision-based leader-follower formation control of mobile robots. *IEEE Trans. Industr. Elect.* 2017, 64, 2893–2902.
- [7] Liu, M. Robotic online path planning on point cloud. *IEEE Trans. Cyber.* 2016, 46, 1217–1228.
- [8] Szegedy, C.; Liu, W.; Jia, Y.; Sermanet, P.; Reed, S.; Anguelov, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A. Going deeper with convolutions. In *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, Massachusetts, USA, 7–12 June 2015; pp. 1–9.
- [9] Crneković, M.; Sučević, M.; Brezak, D.; Kasać, J. Cognitive robotics and robot path planning. In *Proceedings of the CIM05- International Scientific Conference on Production Engineering*, Lumbarda, Korčula, Croatia, 15–17 June 2005.
- [10] Crneković, M.; Zorc, D.; Sučević, M. Cognitive Model of Mobile Robot Workspace. In *Proceedings of the CIM07—Computer Integrated Manufacturing and High Speed Machining*, Biograd, Croatia, 13–17 June 2007; pp. 95–102.
- [11] Crneković, M.; Zorc, D.; Kunica, Z. Research of mobile robot behavior with eMIR. In *Proceedings of the International Conference on Innovative Technologies*, Rijeka, Croatia, 26–28 September 2012.
- [12] Crneković, M.; Zorc, D.; Kunica, Z. Mobile Robot Vision System for Object Color Tracking. In *Proceedings of the CIM2013 - Computer Integrated Manufacturing and High Speed Machining*, Biograd, Croatia, 19–22 June 2013; pp. 93–98.
- [13] Crneković, M.; Pavlic, T.; Lukas, M. Programming language for the eMIR mobile robot. In *Proceedings of the 15th International Scientific Conference on Production Engineering*, Vodice, Hrvatska, 10–13 June 2015; pp. 81–89.

-
- [14] Pavlic, T.; Lukas, M.; Crneković, M. Design and control of robotic arm for educational mobile robot. In Proceedings of the 15th International Scientific Conference on Production Engineering, Vodice, Hrvatska, 10–13 June 2015; pp. 207–211.
- [15] Malayjerdi, E.; Yaghoobi, M.; Kardan, M. Mobile robot navigation based on Fuzzy Cognitive Map optimized with Grey Wolf Optimization Algorithm used in Augmented Reality. In Proceedings of the 2017 5th RSI International Conference on Robotics and Mechatronics (ICRoM), Tehran, Iran, 25–27 October 2017.
- [16] Richter, C.; Roy, N. Safe Visual Navigation via Deep Learning and Novelty Detection. Robotics, Science and Systems, July 2017. DOI: 10.15607/RSS.2017.XIII.064
- [17] Stückler, J.; Schwarz, M.; Behnke, S. Mobile Manipulation, Tool Use, and Intuitive Interaction for Cognitive Service Robot Co- sero. *Front. Robot. Ai* 2016, 3, 58.
- [18] Bijou, S.; Pinhas, B.T. Physics Based Path Planning for Autonomous Tracked Vehicle in Challenging Terrain. *J. Intell. Robot. Syst.* 2018, 95, 511–526.
- [19] Armesto, P.; Fuentes-Dur'a, P.; Perry, D. Low-cost Printable Robots in Education. *J. Intell. Robot. Syst.* 2015, 81, 5–24.
- [20] Farías, G.; Fabregas, E.; Peralta, E.; Torres, E.; Dormido, S. A Khepera IV library for robotic control education using V-REP. *Ifac- Pap.* 2017, 50, 9150–9155.
- [21] Tai, L.; Giuseppe, P.; Liu, M. Virtual-to-real Deep Reinforcement Learning: Continuous Control of Mobile Robots for Mapless Navigation. In Proceedings of the 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Vancouver, Canada, 24–28 September 2017.
- [22] Becker, T.; Alberto Fabro, J.; Schneider de Oliveira, A.; Reis, L.P. Adding Conscious Aspects in Virtual Robot Navigation through Baars-Franklin's Cognitive Architecture. In Proceedings of the 2015 IEEE International Conference on Autonomous Robot Systems and Competitions, Vila Real, Portugal, 8–10 April 2015.
- [23] Jiménez, A.C.; García-Díaz, V.; Bolaños, S. A Decentralized Framework for Multi-Agent Robotic Systems. *Sensors* 2018, 18, 417.
- [24] Heng, L.; Gotovos, A.; Krause, A.; Pollefeys, M. Efficient visual exploration and coverage with a micro aerial vehicle in unknown environments. In Proceedings of the 2015 IEEE International Conference on Robotics and Automation (ICRA), Seattle, WA, USA, 26–30 May 2015.
- [25] Båberg, F.; Wang, Y.; Caccamo, S.; Ögren, P. Adaptive object centered teleoperation control of a mobile manipulator. In Proceedings of the 2016 IEEE International Conference on Robotics and Automation (ICRA), Stockholm, Sweden, 16–21 May 2016; pp. 455–461.
- [26] Hossein Ghaffari, N.; Peixoto, N. Assessment of Evolutionary Processes Experiments on Self-Organizing Behavior of E-pucks. In Proceedings of the 2016 IEEE Symposium Series on Computational Intelligence (SSCI), Athens, Greece, 6–9 December 2016.
- [27] Ciszewski, M.; Mitka, Ł.; Buratowski, T.; Giergiel, M. Modeling and simulation of a tracked mobile inspection robot in MATLAB and V-REP software. *J. Autom. Mob. Robot. Intell. Syst.* 2017, 11, 5–11.
-

-
- [28] Nagy, Á.; Csorvási, G.; Kiss, D. Path planning and control of differential and car-like robots in narrow environments. In Proceedings of the 2015 IEEE 13th International Symposium on Applied Machine Intelligence and Informatics (SAMi), Herl'any, Slovakia, 22–24 January 2015.
- [29] Ivaldi, S.; Padois, V.; Nori, F. Tools for dynamics simulation of robots: A survey based on user feedback. arXiv 2014, arXiv:1402.7050.
- [30] Cognitive Model of the Closed Environment of a Mobile Robot Based on Measurements. Available online: <https://www.youtube.com/watch?v=KUxVIAe8hSM> (accessed on 14 February 2021).
- [31] Cognitive Mobile Robot Design. Available online: <https://youtu.be/x7lF3olP7Kw?t=21> (accessed on 14 February 2021).
- [32] Stengel, R.F. Robotics and Intelligent Systems—A Virtual Reference Book. Princeton University, Princeton, NJ, USA, 2017. Available online: <http://www.stengel.mycpanel.princeton.edu/RISVirText.html> (accessed on 14 February 2021).
- [33] Lucas, G.W. A Tutorial and Elementary Trajectory Model for the Differential Steering System of Robot Wheel Actuators. Available online: <http://rosum.sourceforge.net/papers/DiffSteer/> (accessed on 14 February 2021).
- [34] Siegwart, R.; Nourbakhsh, I.R. Introduction to Autonomous Mobile Robots, 2nd ed.; MIT Press, Massachusetts, USA, February 2011.
- [35] TensorFlow. Available online: <https://www.tensorflow.org/> (accessed on 14 February 2021).
- [36] Keras: The Python Deep Learning API. Available online: <https://keras.io/> (accessed on 14 February 2021).
- [37] Machine learning: the power and promise of computers that learn by example, Issued: April 2017 DES4702, ISBN: 978-1-78252-259-1, 2017., The Royal Society 6 – 9 Carlton House Terrace, London SW1Y 5AG
- [38] Galvan, E.; Mooney, P. Neuroevolution in Deep Neural Networks: Current Trends and Future Challenges, arXiv:2006.05415, 2020
- [39] Brain-inspired intelligent robotics: The intersection of robotics and neuroscience, Institute of Automation, Chinese Academy of Sciences, Laboratory of Research and Application for Robotic Intelligence of „Hand-Eye-Brain“ Interaction, Science, Vol. 354, Issue 6318, December 2016.
- [40] Cognitive Model of the Closed Environment of a Mobile Robot Based on Measurements – Collision. Available online: <https://youtu.be/KUxVIAe8hSM?t=96> (accessed on 14 February 2021).
- [41] Dynamical Test - Cognitive Model of a Mobile Robot eMIR. Available online: <https://youtu.be/MD8M4jepGuI> (accessed on 14 February 2021).
-

Prilog 1

Ovaj prilog sadržava video materijale validacije upravljačkog modela i sve materijale korištene u istraživanju. Svi isječci snimljeni su u Laboratoriju za inteligentne proizvodne sustave Fakulteta strojarstva i brodogradnje pri Sveučilištu u Zagrebu.

- Implementacija i validacija algoritma planiranja robotskog istraživanja prostora:

<https://youtu.be/KUxVIAe8hSM>

- Materijali nastali tijekom provedbe istraživanja:

<https://drive.google.com/drive/folders/1Td0qQYwubNo5B3O35yM-nev2KvcnmCWm?usp=sharing>

Prilog 2

Ovaj prilog sadrži algoritme. Kompletni algoritmi dostupni su na linku „Materijali nastali tijekom provedbe istraživanja“:

<https://drive.google.com/drive/folders/1Td0qQYwubNo5B3O35yM-nev2KvcnmCWm?usp=sharing>

Algoritam 0-1 “mainwindow”

```
1. MainWindow::MainWindow(QWidget *parent)
2.     : QMainWindow(parent)
3.     , ui(new Ui::MainWindow)
4. {
5.     ui->setupUi(this);
6.
7.     connect(&thread_1, &Thread_1::ScoreResults, this,
8.             &MainWindow::ReceiveScore);
9.     connect(&thread_1, &Thread_1::BestScoreResults, this,
10.            &MainWindow::ReceiveBestScore, Qt::BlockingQueuedConnection);
11.     connect(&thread_1, &Thread_1::SendStatus, this,
12.            &MainWindow::ReceiveStatus);
13.     connect(&thread_1, &Thread_1::SendMap, this,
14.
15.     ...
```

Algoritam 0-2 „thread_1”

```
1. Thread_1::Thread_1(QObject *parent)
2.     :QThread(parent)
3. {
4.     loop_break = false;
5.     next_iteration = false;
6.     generation_number = 0;
7.
8.     direction[0] = 0.0f;
9.     direction[1] = 0.0f;
10.
```

...

Algoritam 0-3 „thread_2“

```
1. Thread_2::Thread_2(QObject *parent)
2.     : QThread(parent)
3. {
4. }
5.
6. void Thread_2::InicIALIZation(int ID, bool cam)
7. {
8.     camera_use = cam;
9.     clientID = ID;
10.
```

...

Algoritam 0-4 „neuralnetwork“

```
1. NeuralNetwork::NeuralNetwork()
2. {
3.
4. }
5.
6. float NeuralNetwork::RandDec()
7. {
8.     int rand = QRandomGenerator::global()->generate();
9.     return (rand % 1000)/1000.0f;
10. }
```

...

Algoritam 0-5 „geneticalgorithm“

```
1. GeneticAlgorithm::GeneticAlgorithm()
2. {
3.     int k=0;
4.     for(int j=0; j<100; j++)
5.     {
6.         vector <int> temp;
```

```
7.         for(int i=0; i<200; i++)
8.         {
9.             if((k+i)%2 == 0){
10.                temp.push_back(1);
...

```

Algoritam 0-6 „imageprocessing“

```
1. ImageProcessing::ImageProcessing()
2. {
3.     for(int i=0; i<98304; i++)
4.         {image_array[i] = 0;}
5.
6.     int k=0;
7.     for(int j=0; j<100; j++){
8.         for(int i=0; i<200; i++){
9.             if((k+i)%2 == 0){
10.                object_position[j][i] = 1;
...

```

Algoritam 0-7 „explore“

```
1. Explore::Explore()
2. {
3.     // inicialazing space-matrix with 1 -> white
4.     //                                     2 -> grey
5.     // this is used for background
6.     int k=0;
7.     for(int j=0; j<100; j++){
8.         for(int i=0; i<200; i++){
9.             if((k+i)%2 == 0){
10.                space_map[j][i] = 1;
...

```

Algoritam 0-8 „score“

```
1. Score::Score()  
2. {  
3. }  
4.  
5. void Score::Score_reset()  
6. {  
7.     sum_speed = 0;  
8.     dif_speed = 0;  
9.     angle = 0;  
10.
```

...

Životopis

Tomislav Pavlic rođen je 28.11.1984. godine u Koprivnici. Srednju školu „Tehnička škola Ruđera Boškovića“ u Zagrebu, smjer Tehničar za elektroniku, završio je 2003. godine nakon čega upisuje Fakultet strojarstva i brodogradnje, Sveučilišta u Zagrebu. Godine 2008. završava diplomski studij, smjer Mehatronika i robotika. Prvi puta se zapošljava u tvrtki TROHA-DIL d.o.o., a radi na sljedećim mjestima: održavanje CNC strojeva i automatskih linija; priprema proizvodnje; voditelj proizvodnje; direktor razvoja novih proizvoda. Na Veleučilištu u Bjelovaru zapošljava se 2011. godine, na mjestu asistenta, za znanstveno područje tehničke znanosti, polje strojarstvo, grana proizvodno strojarstvo. Doktorski studij upisuje 2011. godine na Fakultetu strojarstva i brodogradnje, Sveučilišta u Zagrebu. Zvanje predavača za znanstveno područje tehničke znanosti, polje strojarstvo, grana proizvodno strojarstvo ostvario je 2012. godine, a zvanje višeg predavača za znanstveno područje tehničke znanosti, polje strojarstvo, grana proizvodno strojarstvo ostvario je 2015. godine. Funkciju voditelja Studentskog poduzetničko-tehnološkog inkubatora Bjelovar na Veleučilištu u Bjelovaru obavlja od 2015. godine, a osvojio je, u svojstvu voditelja i mentora studenata, više od desetak nagrada na inozemnim i domaćim izložbama inovacija. Od 2015. godine obavlja i funkciju voditelja Laboratorija za proizvodno strojarstvo i robotiku, na Veleučilištu u Bjelovaru. Od 2017. godine kao vanjski suradnik održava nastavu iz nekoliko kolegija na Sveučilištu Sjever u Varaždinu, te Tehničkom veleučilištu Zagreb. Javni razgovor o očekivanim znanstvenim doprinosima doktorske disertacije održao je 2018. godine. Aktivan je na nekoliko projekata, autor i koautor je 26 znanstvenih i stručnih radova, jedne knjige, brojnih nastavnih materijala, te je do sada bio mentor ukupno 67 studenata na završnim radovima i izložbama inovacija.

Popis objavljenih djela

Znanstveni radovi u časopisima

1. Pavlic, Tomislav; Kušec, Krunoslav; Radočaj, Danijel; Britvić, Alen; Lukas, Marin; Milić, Vladimir; Crneković, Mladen Cognitive Model of the Closed Environment of a Mobile Robot Based on Measurements. // Applied Sciences-Basel, 11 (2021), 6; 2786, 33 doi:10.3390/app11062786 (međunarodna recenzija, članak, znanstveni)
2. Petrović, Igor; Pavlic, Tomislav; Čikić, Ante The Approach to Stability Determination of Single Axis Positioning Regulation for the Model of TTT Manipulator. // Tehnički vjesnik, 21 (2014), 5; 1041-1046 (međunarodna recenzija, izvorni znanstveni članak, znanstveni)
3. Pavlic, Tomislav; Čikić, Ante; Golubić, Stjepan Analysis of the influence of 3D printing on hardness of parts. // Tehnički vjesnik, 23 (2016), 3; 843-847 (međunarodna recenzija, izvorni znanstveni članak, znanstveni)
4. Radočaj, Danijel; Jurica, Maja; Kos, Sebastijan; Pavlic, Tomislav Programiranje industrijskih robota za potrebe robotiziranog zavarivanja. // Zavarivanje, 59 (2016), 1/2; 5-11 (međunarodna recenzija, članak, znanstveni)

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom

1. Crneković, Mladen; Pavlic, Tomislav; Lukas, Marin Programming Language for the eMIR Mobile Robot. // Proceedings of the CIM 2015-15th International Scientific Conference on Production Engineering / Abele, Eberhard ; Udiljak, Toma ; Ciglar, Damir (ur.). Zagreb: Croatian Association of Production Engineering, 2015. str. 81-89 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
2. Pavlic, Tomislav; Lukas, Marin; Crneković, Mladen Design and Control of Robotic Arm for Educational Mobile Robot. // Proceedings of the CIM 2015-15th International Scientific Conference on Production Engineering / Abele, Eberhard ; Udiljak, Toma ; Ciglar, Damir (ur.). Zagreb: Croatian Association of Production Engineering, 2015. str. 207-211 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

-
3. Pavlic, Tomislav; Jurković, Ivana; Jusić, Elvis A MULTIDISCIPLINARY APPROACH TO TEACHING COGNITIVE ROBOTICS AND ENGLISH TERMINOLOGY BY INVOLVING THE INTERNATIONAL ASPECTS IN HIGHER EDUCATION. // VII International scientific conference FUTURE TRENDS, ORGANIZATIONAL FORMS AND EFFECTIVENESS OF COOPERATION DEVELOPMENT BETWEEN RUSSIAN AND FOREIGN UNIVERSITIES Russia, 2019. str. 650-662. (<https://www.bib.irb.hr/1029808>) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
 4. Pavlic, Tomislav; Jurković, Ivana; Kraljić, Luka AN INTEGRATED APPROACH TO CONNECTING UNIVERSITY RESEARCH AND MANUFACTURING COMPANIES IN THE FIELD OF COGNITIVE ROBOTICS AND ENGLISH FOR SPECIFIC PURPOSES. // VII International scientific conference FUTURE TRENDS, ORGANIZATIONAL FORMS AND EFFECTIVENESS OF COOPERATION DEVELOPMENT BETWEEN RUSSIAN AND FOREIGN UNIVERSITIES Russia, 2019. str. 662-675. (<https://www.bib.irb.hr/1029794>) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
 5. Kušec, Krunoslav; Pavlic, Tomislav; Boščić, Drago; Švegović, Mario; Golubić, Stjepan; Britvić, Alen Rapid Prototyping of Rifle for Underwater Fishing by the Application of the Reverse Engineering. // Proceedings of the CIM 2017-16th International Scientific Conference on Production Engineering / Abele, Eberhard ; Udiljak, Toma ; Ciglar, Damir (ur.). Zagreb: Croatian Association of Production Engineering, 2017. str. 171-176 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
 6. Vrhovski, Zoran; Markov, Mateo; Pavlic, Tomislav; Obrovac, Karlo; Mutka, Alan; Nižetić, Josip Design of a Mechanical Assembly for the Dynamic Evaluation of Human Body Posture. // 16th INTERNATIONAL SCIENTIFIC CONFERENCE ON PRODUCTION ENGINEERING –CIM2017 / Abele, Eberhard ; Udiljak, Toma ; Ciglar, Damir (ur.). Zagreb: Croatian Association of Production Engineering, 2017. str. 237-242 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
 7. Pavlic, Tomislav; Golubić, Stjepan; Čikić, Ante; Radočaj, Danijel Simulacija zavarivanja pomoću ABB robotske ruke u programskom alatu RobotStudio. // 8. MEĐUNARODNO ZNANSTVENO-STRUČNO SAVJETOVANJE SBZ 2015 - PROJEKTIRANJE, IZRADA I ODRŽAVANJE ZAVARENIH KONSTRUKCIJA I
-

-
- PROIZVODA Slavonski Brod, Hrvatska, 2015. str. 1-7 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
8. Radočaj, Danijel; Jurica, Maja; Kos, Sebastijan; Pavlic, Tomislav Programiranje industrijskih robota za potrebe robotiziranog zavarivanja. // Projektiranje, izrada i održavanje zavarenih konstrukcija i proizvoda, SBZ 2015 / Samardžić, Ivan ; Despotović, Božo (ur.). Slavonski Brod: Strojarski fakultet u Slavonskom Brodu, 2015. str. 238-249 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
 9. Bošić, Drago; Kos, Sebastijan; Pavlic, Tomislav The Approach to Stronger Connection Between Machining Oriented Manufacturing Companies and Education Sector-Joint Cooperation. // Proceedings of the CIM 2015-15th International Scientific Conference on Production Engineering / Abele, Eberhard ; Udiljak, Toma ; Ciglar, Damir (ur.). Zagreb: Croatian Association of Production Engineering, 2015. str. 65-70 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
 10. Čikić, Ante; Petrović, Igor; Pavlic, Tomislav The Influence of Solar Insolation and Oxygen Content in Water on the Efficiency of Intensive Hydroponic Salad Growing in Greenhouses. // Industrial, Systems and Design, Engineering, Technology & Engineering and Foresight Abstracts / Gregor T. Papanikos (ur.). Athens: Greece by the Athens Institute for Education and Research, 2015. str. 58-58 (predavanje, međunarodna recenzija, sažetak, znanstveni)
 11. Radočaj, Danijel; Jurica, Maja; Kos, Sebastijan; Pavlic, Tomislav Programiranje industrijskih robota za potrebe robotiziranog zavarivanja. // 8. MEĐUNARODNO ZNANSTVENO-STRUČNO SAVJETOVANJE SBZ 2015 - PROJEKTIRANJE, IZRADA I ODRŽAVANJE ZAVARENIH KONSTRUKCIJA I PROIZVODA Slavonski Brod, Hrvatska, 2015. str. 1-7 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
 12. Pavlic, Tomislav; Miletić, Marko; Hršak, Božidar; Badrov, Tatjana; Golubić, Stjepan; Vaško, Tajana; Šegrt, Ivana; Jolić, Robert; Aleksić, Dejan Animation Design in the Process of Developing a New Mechatronic Product. // Proceedings of TEAM 2015 7th International Scientific and Expert Conference of the International TEAM Society / Aleksandar Sedmak, Zoran Radakovic, Simon Sedmak, Snezana Kirin (ur.). Belgrade: Faculty of Mechanical Engineering, University of Belgrade, 2015. str. 332-335 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
 13. Pavlic, Tomislav; Golubić, Stjepan; Lukas, Marin Development of Electromechanical
-

Engineering Students Entrepreneur-technological Incubator at Bjelovar. // Proceedings of the CIM 2013 / Abele, Eberhard ; Udiljak, Toma ; Ciglar, Damir (ur.). Zagreb: Croatian Association of Production Engineering, 2013. str. 11-18. (<https://www.bib.irb.hr/773664>) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

14. Mihoci, Kristijan; Pavlic, Tomislav Razvoj i testiranje pet-osnog postprocesora. // Proceedings of the CIM 2009-12th International Scientific Conference on Production Engineering / Abele, Eberhard ; Udiljak, Toma ; Ciglar, Damir (ur.). Zagreb: Croatian Association of Production Engineering, 2009. str. 1-6. (<https://www.bib.irb.hr/773650>) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

Stručni radovi u časopisima

1. Boras, Igor; Pavlic, Tomislav Mogućnosti korištenja CAD alata na primjeru tvrtke Iveta d.o.o. prozori i vrata. // Tehnički glasnik, 8 (2014), 4; 457-460 (podatak o recenziji nije dostupan, članak, stručni)
2. Pavlic, Tomislav; Jurković, Ivana; Subota, Tomislav Aditivni postupci u procesu razvoja novih proizvoda s osvrtom na terminološka pitanja. // Tehnički glasnik, 10 (2016), 1-2; 38-44 (domaća recenzija, članak, stručni)
3. Jolić, Robert; Kukec, Đuro; Pavlic, Tomislav Usage and advantages of CAD/CAM technology for industry. // Tehnički glasnik, 8 (2014), 4; 332-338 (podatak o recenziji nije dostupan, članak, stručni)
4. Hršak, Božidar; Pavlic, Tomislav; Radić, Antonio Rekonstrukcija i izrada 3D modela dvo-osne konvencionalne tokarilice Hobbyamat MD65. // Tehnički glasnik, 8 (2014), 1; 114-117 (podatak o recenziji nije dostupan, članak, stručni)
5. Pavlic, Tomislav; Novosel, Ivan; Trojko, Domagoj Izrada projektne dokumentacije laktofriza TIP RBV - 300. // Tehnički glasnik, 8 (2014), 3; 295-302 (podatak o recenziji nije dostupan, članak, stručni)
6. Pavlic, Tomislav; Hršak, Božidar; Šabić, Renato Prilagodba CAD/CAM sustava za 2.5D I 3D glodanje na 4-osnoj CNC glodalici HAAS VF6. // Tehnički glasnik, 8 (2014), 2; 123-128 (recenziran, članak, stručni)
7. Badrov, Tatjana; Pavlic, Tomislav; Hršak, Božidar Student entrepreneurial-technological incubator in Bjelovar. // Tehnički glasnik, 7 (2013), 4; 414-418 (podatak

o recenziji nije dostupan, članak, znanstveni)

8. Badrov, Tatjana; Pavlic, Tomislav; Hršak, Božidar Studentski poduzetničko-tehnološki inkubator u Bjelovaru. // Tehnički glasnik, 7 (2013), 4; 414-418 (pregledni rad, znanstveni)

Autorstvo udžbenika

1. Pavlic, Tomislav Virtualno oblikovanje mehatroničkih sustava: podloge za rad u programskom okruženju SolidWorks., Bjelovar: Veleučilište u Bjelovaru, 2020 (priručnik). (<https://www.bib.irb.hr/1117063>)

Biography

Tomislav Pavlic, born on November 28th, 1984 in Koprivnica, Croatia. Formal education he started with "Ruđer Bošković Technical School" in Zagreb, majoring in Electronics Technician, graduated in 2003, after which he enrolled the Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb. In 2008 he completed his graduate studies in Mechatronics and Robotics. The first employment has been in the company TROHA-DIL d.o.o., where he worked in the following areas: maintenance of CNC machines and automated production lines; production preparation; production manager; new product development director. He started working at the Bjelovar University of Applied Sciences in 2011, as an assistant, for the scientific field of technical sciences, in the fields of mechanical engineering, a branch of production mechanical engineering. He enrolled in doctoral studies in 2011 at the Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb. The title of lecturer for the scientific field of technical sciences, field of mechanical engineering, branch of production mechanical engineering he earned in 2012, and the title of senior lecturer for the scientific field of technical sciences, field of mechanical engineering, branch of production mechanical engineering he earned in 2015. He is in the position of the head of the Student Entrepreneurship and Technology Incubator in Bjelovar at the Bjelovar University of Applied Sciences since 2015. He has won, as a leader and mentor of students, more than a dozen awards at foreign and domestic innovation exhibitions. Since 2015, he has also been the head of the Laboratory for Production Mechanical Engineering and Robotics at the Bjelovar University of Applied Sciences. Since 2017, as an external associate, he has been teaching several courses at the University North in Varaždin and the Zagreb University of Applied Sciences. He held a public discussion on the expected scientific contributions to a doctoral dissertation in 2018. He is active in several projects, author and co-author of 26 scientific and professional papers, one book, numerous teaching materials, and has so far mentored a total of 67 students in final thesis and innovation exhibitions.