Model procjene rizika pomorskih nezgoda na putničkim brodovima u nelinijskoj obalnoj plovidbi

Vojković, Lea

Doctoral thesis / Disertacija

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Maritime Studies, Rijeka / Sveučilište u Rijeci, Pomorski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:187:270669

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-26**

Sveučilište u Rijeci, Pomorski fakultet
University of Rijeka, Faculty of Maritime Studies

Repository / Repozitorij:

Repository of the University of Rijeka, Faculty of Maritime Studies - FMSRI Repository

UNIRI DIGITALNA KNJIŽNICA

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U RIJECI

POMORSKI FAKULTET

Lea Vojković

MODEL PROCJENE RIZIKA POMORSKIH NEZGODA NA PUTNIČKIM BRODOVIMA U NELINIJSKOJ OBALNOJ PLOVIDBI

DOKTORSKA DISERTACIJA

Mentor: prof. dr. sc. Damir Zec

Komentor: izv. prof. dr. sc. Đani Mohović

Rijeka, 2019.

UNIVERSITY OF RIJEKA

FACULTY OF MARITIME STUDIES

Lea Vojković

MODEL OF RISK ASSESSMENT OF MARITIME ACCIDENTS ON PASSENGER VESSELS IN NON-LINEAR COASTAL NAVIGATION

DOCTORAL DISSERTATION

Rijeka, 2019

Mentor rada: prof. dr. sc. Damir Zec

Komentor: izv. prof. dr. sc. Đani Mohović

Doktorska disertacija obranjena je 17. siječnja 2019. na Pomorskom fakultetu u Rijeci, pred Povjerenstvom u sastavu:

1. dr. sc. Vlado Frančić, izvanredni profesor Pomorskog fakulteta u Rijeci, predsjednik
2. dr. sc. Toni Bielić, redoviti profesor Pomorskog odjela Sveučilišta u Zadru, član i
3. dr. sc. Lovro Maglić, docent Pomorskog fakulteta u Rijeci, član.

SADRŽAJ:

SAŽETAK i

SUMMARY ii

PREDGOVOR iii

1. UVOD 1

1.1 Tema doktorske disertacije 1

1.2 Problem, predmet, svrha i ciljevi 2

1.3 Prethodna istraživanja 4

1.4 Hipoteza 8

1.5 Znanstvene metode 8

2. POMORSKE NEZGODE 10

2.1 Pojam pomorskih nezgoda 11

2.2 Analiza pomorskih nezgoda u Rebublici Hrvatskoj 12

2.3 Pomorske nezgode u teritorijalnim morima i unutarnjim vodama EU zemalja 21

2.4 Opći model broda kao dinamičkog sustava 23

2.5 Modeliranje pomorskih nezgoda 28

3. BAYESOVE MREŽE 30

4. ČIMBENICI UTJECAJA NA POMORSKE NEZGODE 35

4.1 Izvori podataka 39

4.2 Vrijeme pojave pomorskih nezgoda 42

4.3 Hidrometeorološke prilike 51

4.4 Utjecaj gustoće prometa na nastajanje pomorskih nezgoda 62

4.5 Ljudski faktor 63

4.6 Tehničko-tehnološka obilježja brodova 71

4.7 Plovidba u plitkom području 80

4.8 Plovidba u području posebnog opreza 81

4.9 Greške i gubici kontrole ... 82
5. KVALITATIVNI MODEL PROCJENE POJAVE POMORSKIH NEZGODA ... 88
5.1 Kvalitativni model potonuća ... 90
5.2 Kvalitativni model udara ... 93
5.3 Kvalitativni model nasukavanja ... 96
5.4 Kvalitativni model sudara ... 101
5.5 Kvalitativni model požara i eksplozije ... 105
6. KVANTITATIVNI MODELI NASUKAVANJA I SUDARA BRODOVA ... 108
6.1 Kvantitativni model nasukavanja ... 109
6.2 Kvantitativni model sudara ... 119
6.3 Validacija modela ... 123
6.3.1. Kvalitativna provjera ... 123
6.3.2. Analiza osjetljivosti modela nasukavanja ... 127
6.3.3. Analiza osjetljivosti modela sudara ... 130
6.3.4. Usporedba rezultata modela sa stvarnim događajem ... 133
6.4 Analiza rezultata i prijedlozi mjera za poboljšanje ... 138
6.5 Moguća primjena i preporuke za daljnje istraživanje ... 144
7. ZAKLJUČAK ... 147
LITERATURA ... 149
PRILOZI ... 165
Prilog 1. Varijable modela pomorskih nezgoda ... 165
Prilog 2. Referenti podaci za tablicu ΔPg nasukavanja ... 168
Prilog 3. Referentni podaci za tablicu ΔPg sudara ... 170

SAŽETAK

U zadnjih se dvadeset godina broj putničkih brodova na Jadranu znatno povećao, a samim tim i mogućnost pojave pomorskih nezgoda. U ovoj doktorskoj disertaciji sustavno je napravljena analiza uzroka pojave pomorskih nezgoda malih putničkih brodova na temelju koje su izrađeni kvalitativni i kvantitativni modeli procjene rizika. Kvalitativni modeli izrađeni su za pomorske nezgode: potonuće, udar, nasukavanje, sudar te požar i eksplozija. Kvantitativni modeli izrađeni su za pomorske nezgode: sudar i udar. U svrhu proaktivnog djelovanja analizirani su čimbenici utjecaja na pomorske nezgode, odnosno kombinacije utjecajnih čimbenika koje mogu dovesti brod u neželjeno stanje. Kvalitativni i kvantitativni modeli napravljeni su korištenjem Bayesovih mreža čime je omogućena vizualizacija uvjetovane vjerojatnosti između različitih faktora utjecaja te finalnog ishoda. Kvantificiranje utjecajnih faktora izvršeno je kombiniranjem statističkih podataka i ekspertnog mišljenja. Kvantitativni modeli validirani su metodama: kvalitativna provjera, analiza osjetljivosti te usporedba rezultata sa stvarnim događajem.

Ovakvom analizom i izradom modela uz pomoć Bayesovih mreža moguće je proaktivno djelovati na sigurnost plovidbe promatranih brodova.

Temeljem dobivenih rezultata, nakon provedenih istraživanja, predložene su preventivne mjere.

Ključne riječi: mali putnički brodovi, Bayesove mreže, pomorske nezgode.

SUMMARY

Over the last twenty years, the number of passenger vessels in Adriatic has increased and, due to it, the number of possibilities of maritime accidents has risen as well. In this doctoral dissertation qualitative and quantitative models of risk assessment have been based on analysis of causes of maritime accidents on small passenger vessels. The qualitative models have been made for these types of accidents: sinking, impact, grounding, collision, fire and explosion. The quantitative models have been made for: collision and impact. Influencing factors of maritime accidents and possible combinations of initial factors that could lead vessel to undesirable condition have been analyzed in order to take proactive measures. Qualitative and quantitative models have been developed using Bayesian networks, enabling a visualization of conditional probability between different initial factors and final outcome. Quantification of the influencing factors has been made using statistical data and expert estimation. Quantitative models have been validated by: qualitative feature test, sensitivity analysis and comparison between results and accidental report.

By analyzing this and developing the model with the help of Bayesian networks, it is possible to proactively influence the safety of the observed vessels.

Based on the results obtained, following the researches, preventive measures have been proposed.

Key words: small passenger vessels, Bayesian network, maritime accidents.

PREDGOVOR

Struktura doktorske disertacije pod naslovom „Model procjene rizika pomorskih nezgoda na putničkim brodovima u nelinijskoj obalnoj plovidbi“ podijeljena je u sedam poglavlja koja čine jednu funkcionalnu cjelinu.

U prvom dijelu, uvodu, opisana je tema disertacije te problem istraživanja, postavljena je znanstvena hipoteza, opisana je svrha i ciljevi istraživanja, dan je pregled dosadašnjih istraživanja te su navedene korištene znanstvene metode.

U drugom dijelu objašnjeni su pojmovi vezani za pomorske nezgode, prikazana su stanja plovidbe u kojima se brod nalazi za vrijeme putovanja, odnosno, opći model broda kao dinamički sustav. Prikazana je metodologija izrade modela procjene rizika pomorskih nezgoda temeljena na Bayesovim mrežama te su opisana ograničenja modela. Analizirane su pomorske nezgode u Republici Hrvatskoj te je dan pregled pomorskih nezgoda prema Europskoj agenciji za pomorsku sigurnost.

U trećem dijelu opisane su Bayesove mreže.

U četvrtom dijelu opisani su čimbenici utjecaja na pomorske nezgode korišteni u modelima.

U petom dijelu izrađeni su kvalitativni modeli procjene rizika pomorskih nezgoda na putničkim brodovima u nelinijskoj plovidbi. Modeli su napravljeni za pomorske nezgode potonuća, nasukavanja, sudara, udara te požara i eksplozije.

U šestom dijelu izrađeni su kvantitativni modeli procjene pomorskih nezgoda na putničkim brodovima u nelinijskoj plovidbi za pomorske nezgode nasukavanja i sudara. Napravljena je validacija modela uz pomoć kvalitativne provjere, analize osjetljivosti te usporedbe rezultata sa stvarnim događajem. Zatim je izvršena obrada, analiza i verifikacija rezultata provedenih istraživanja. Poglavlje je završeno prikazom ključnih znanstvenih saznanja proizišlih iz provedenog istraživanja. Također, prezentirane su preporuke za daljnja istraživanja.

U posljednjem, sedmom dijelu, iznijet je zaključak u kojem su predstavljeni dokazi, na temelju kojih je prihvaćena postavljena hipoteza. Nakon iznesenog zaključka, popisane su sve korištene reference, slike, tablice te su navedeni prilozi.

1. UVOD

Putnički brodovi u nelinijskoj obalnoj plovidbi važan su segment turizma. Povećanjem njihovog broja povećava se mogućnost njihova sudjelovanja u pomorskim nezgodama. Posljedice pomorskih nezgoda mogu varirati od manjih ozljeda do smrti i/ili uništenja imovine i okoliša. Statistički podaci o pomorskim nezgodama na Jadranu, usprkos činjenici da pomorstvo tehnološki napreduje, ukazuju na povećanje broja pomorskih nezgoda. Pomorske nezgode rijetko su uzrokovane greškom jednog sustava ili namjernom ljudskom odlukom te se najčešće događaju zbog spleta okolnosti koje uključuju male, naočigled neznatne, događaje i ljudske pogreške. Da bi se pomorske nezgode uspješno izbjegle, potrebno je preventivno djelovati pri čemu je najvažnije identificirati najrizičnije situacije.

U ovom radu sustavno su istraženi uzroci pojave pomorskih nezgoda na putničkim brodovima u nelinijskoj obalnoj plovidbi.

1.1 Tema doktorske disertacije

Provedeno istraživanje usredotočeno je na male putničke brodove u nelinijskoj obalnoj plovidbi, odnosno na putničke brodove do 70 metara dužine (mogu biti manji od 12 metara u slučaju da prevoze više od 12 putnika) čija plovidba nije redovna ni učestala te ne predstavlja sistematski slijed. Promatrani brodovi mogu obavljati jednodnevne ili višednevne izlete koji većinom plove u ljetnoj sezoni. Maksimalan broj putnika im je 200 te plove u obalnim područjima i manjim zatvorenim morima. Posebni segment malih putničkih brodova u nelinijskoj obalnoj plovidbi su tradicionalni jedrenjaci za krstarenje i jednodnevne izlete. Izvorno su ti brodovi prevozili pijesak i slične terete na Jadranu te su prenamijenjeni za prijevoz putnika.

Poradi povećanja broja malih putničkih brodova u nelinijskoj obalnoj plovidbi javlja se potreba analize čimbenika koji utječu na mogućnost pojave pomorske nezgode jer prilikom neplaniranog događaja – pomorske nezgode – postoji veća vjerojatnost gubitka ljudskih života ili ozljeđivanja ljudi zbog broja putnika koje ti brodovi prevoze u odnosu na druga plovila nautičkog turizma.

Na temelju istraživanja i analize putničkih brodova u nelinijskoj obalnoj plovidbi, uzimajući u obzir sigurnosnu situaciju i razvojni trend, prevenciju rizika, sigurnosne regulative i druge

aspekte, zaključeno je da je u ovome trenutku od posebne važnosti bolje definirati čimbenike utjecaja na pomorske nezgode kako bi se smanjio njihov broj. Jednako tako na temelju rezultata istraživanja moguće je unaprijediti postojeće regulative i normative koje će uključivati različita tehnička i operativna pitanja.

1.2 Problem, predmet, svrha i ciljevi

Pri izrađivanju modela procjene rizika većinom se koriste statističke informacije. Različite države raspolažu različitim bazama podataka koje nisu standardizirane. Gotovo je nemoguće napraviti model koji se može rabiti svugdje u svijetu, ne samo zbog varijabli utjecaja koje su različite zbog područja promatranja nego i zbog različitih baza podataka. Nedostatak baza podataka očituje se u nedostatku informacija o tome što je prethodilo pomorskoj nezgodi i što je bio inicijalni faktor. Većina baza podataka temeljena je na posljedicama (Reason, 1990, 1997). S obzirom na to kako su baze podataka uređene i strukturirane, korisnije su za arhiviranje i prikupljanje statističkih analiza pomorskih nezgoda nego za donošenje zaključaka o pravim uzrocima koji su doveli do nastupanja pomorske nezgode. Ako prilikom prikupljanja podataka nije moguće doći do svih podataka neophodnih za izradu modela (često se i prilikom uporabe kategoriziranih baza podataka pojavljuju prazna polja na mjestima gdje bi trebao biti broj), tada se vjerojatnosti i odnosi parametara u modelu baziraju na mišljenju grupe eksperata.

Prema izvoru Bukša, Zec (2005) izrada prihvatljivog modela procjene zavisi o postojanju odgovarajućih podataka o prometu za područje koje je predmet procjene, zatim o zadovoljavajućim tehnološkim uvjetima koji stoje na raspolaganju te o pravilima i propisima koji reguliraju sigurnost plovidbe.

Pomorske nezgode, posebice nezgode putničkih brodova u nelinijskoj obalnoj plovidbi, su vrlo rijetki događaji. Na njihov nastanak utječu brojni utjecajni čimbenici čiju je veličinu i utjecaj vrlo teško odrediti. Stoga je temeljni problem ovog znanstvenog istraživanja razviti i ispitati druge metode kojima bi se procijenio njihov utjecaj, a s konačnim ciljem utvrđivanja mjera predostrožnosti kojima se umanjuje nepovoljno djelovanje najutjecajnijih čimbenika.

Da bi se postavljeni problem mogao primjereno riješiti, istraživanje je provedeno po sljedećim točkama:

- analiziranje i sistematiziranje dosadašnjih teorijskih i empirijskih istraživanja iz područja procjene rizika te određivanje pojma rizika
- određivanje pravila i ograničenja koje je moguće uzeti u obzir prilikom razvijanja metodologije procjene rizika te definiranje temeljnih pojmova, posebice pojma obalne plovidbe i pojma malih putničkih nelinijskih brodova
- određivanje mogućih opasnosti te neželjenih i željenih stanja plovidbe promatranih brodova
- istraživanje među sudionicima te programska implementacija dobivenih rezultata putem predloženog matematičkog modela primjenjujući i ostale numeričke i simulacijske metode istraživanja
- analiziranje i sistematiziranje dobivenih rezultata te razvijanje modela koji objedinjava razne prijetnje putničkim brodovima u nelinijskoj obalnoj plovidbi te izrada modela koji ima mogućnost kontinuiranog unaprjeđivanja uz mogućnost prilagodbe različitim lokalitetima i uvjetima.

Uobičajeni postupci koje se upotrebljavaju u slučajevima otežanog verificiranja varijabli su:

- model korištenja tehnika koje omogućuju validaciju mišljenja eksperata
- model korištenja mišljenja eksperata o vjerojatnosti nastupanja određenog događaja koji je definiran u modelu.

Predmet istraživanja je procjena rizika pojave pomorskih nezgoda na putničkim brodovima u nelinijskoj obalnoj plovidbi. Već je u 14. stoljeću postojala praksa pomorskog osiguranja koja je omogućila srednjovjekovnim trgovcima ocjenjivanje različitih čimbenika rizika koji se pojavljuju prilikom prekomorskog trgovanja (Očevčić, 2015). Važnost metoda za procjenu rizika pomorske plovidbe posljednjih je godina porasla do te mjere da pomorske međunarodne organizacije predlažu preporuke za izradu specifičnih analiza rizika.

Danas se više ne čeka da se nesretni događaj dogodi kako bi se djelovalo na preporuke o sigurnosti i uvodile nove pravne regulative (Haapasaari P. i ostali, 2015). Kultura proaktivnog pristupa raširena je u nuklearnoj i svemirskoj industriji te je u zadnje vrijeme prisutna i u svim aspektima pomorstva. Izradom metoda procjene rizika te pravilnom izradom ili izborom odgovarajućeg modela definiraju se visokorizični scenariji koji dovode do neželjenih situacija. Svrha rada je prevencija pomorskih nezgoda predlaganjem novih propisa ili preporuka ponašanja kojima je moguće smanjiti pojedine rizike nastupanja pomorske

nezgode. Nakon kvantificiranja informacije o riziku, informaciju je moguće rabiti u razvoju odgovarajućeg alata za kontrolu, pri određivanju odgovarajuće politike postupaka u incidentnim situacijama, kao i za lociranje izvora nezgode kako bi se umanjio njihov utjecaj.

Cilj rada je određivanje najvažnijih čimbenika i kombinacija najvažnijih čimbenika koji uzrokuju pomorske nezgode na promatranim brodovima. Kvalitativno su određeni važniji čimbenici utjecaja na pomorske nezgode potonuća, sudara, udara, nasukavanja te požara i eksplozije. Potom je valoriziranjem čimbenika ekspertnom procjenom i statističkim podacima te određivanjem težinskog faktora utjecaja izrađena kvantitativna procjena dviju vrsta pomorskih nezgoda (nasukavanje i sudar) na primjeru Splitsko-dalmatinske županije. Kvantitativne modele sudara i nasukavanja moguće je koristiti za druge županije promjenom podataka koji se odnose na varijable: „Plovidba u području posebnog opreza“ i „Gustoća prometa“.

1.3 Prethodna istraživanja

Korištenje izričito povijesnih statističkih podataka o pomorskim nezgodama prilikom izrade modela procjene rizika sadržava niz nedostataka što je prepoznato od strane Međunarodne pomorske organizacije (International Maritime Organization ─ IMO). Odbor za pomorsku sigurnost (MSC)[1] 2006. godine donio je Rezoluciju u kojoj su opisane tehnike procjene rizika, FSA[2] metodologija, primjena procjene rizika pomorskih nezgoda na brodovima, nezgoda u industriji iskorištavanja mora i podmorja te izvori podataka o nezgodama u pomorstvu.

Od znanstvene literature koja obrađuje modeliranje pomorskih nezgoda treba izdvojiti radove Marie Hanninen. U radu iz 2008. godine autorica je opisala postojeće metode modeliranja

[1] Odbor za pomorsku sigurnost (MSC – Maritime safety committee) najviše je tehničko tijelo Međunarodne pomorske organizacije. Sve države članice imaju svog člana u tom odboru. Osnovna je zadaća odbora da razmotri svako pitanje vezano za navigaciju, navigacijska pomagala, konstrukciju i opremu brodova, rukovanje sa stajališta sigurnosti, pravila o sprječavanju nezgoda (sudara) na moru, rukovanje opasnim teretima, hidrografske podatke, pomorske nezgode, spašavanje i pružanje pomoći na moru i svako drugo pitanje vezano za sigurnost na moru.

[2] FSA – Formal safety assesment, FSA je znanstvena metoda koja se upotrebljava za analizu pomorske sigurnosti. Upotrebom FSA pristupa, pomorska industrija prelazi s reaktivnog na proaktivni pristup. FSA je međunarodno poznata kao jedna od najboljih metoda za procjenu pomorskog rizika. Karakteriziraju je: racionalan i sistematičan proces za procjenu rizika vezanih za pomorsku sigurnost i prevenciju onečišćenja okoliša te mjerenje troškova ili dobrobiti; proaktivan pristup; sprječavanje nezgoda prije nego što se dogode; često se koristi kao sustav za provjeru i implementaciju novih mjera (pravilnici, zakoni, preporuke). FSA preporuke dozvoljavaju uporabu statističkih podataka, ali uz obveznu uporabu probabilističkog modela te modeliranja scenarija koji prethode pomorskoj nezgodi.

ljudskog faktora kao uzročnika pomorskih nezgoda. Rad je fokusiran na metode procjene rizika, posebice na upotrebu Bayesove metode. Osim Bayesove metode koja je detaljno predočena, autorica opisuje i *HRA* metodu, *THREP* metodu, *Swiss cheese* metodu, *Cream* metodu te opisuje ljudske faktore u domeni pomorstva.

U radu iz 2012. godine autori Maria Hanninen i Pentti Kujala [46] bavili su se istraživanjem najutjecajnijih varijabli na pomorsku nezgodu sudar u Finskom zaljevu koristeći Bayesove mreže. Bazirali su se na varijablama koje se odnose na ljudski faktor – statistički najvažniji uzrok sudara – te su analizirali sljedeće: reakcija OOW,[3] detekcija opasnosti, osobno stanje, nesposobnost, umor i itd. Također, autori su analizirali utjecaj varijabli koje se odnose na ometanje na mostu: izgled mosta, rutina na mostu i dr.

U radu iz 2013. godine skupina autora Haninnen i ostali [43] analizirala je utjecaj određenih varijabli na pomorsku nezgodu uz pomoć kvalitativnog i kvantitativnog modela. Model se odnosio na mogućnost smanjenja pomorskih nezgoda implementacijom novog sustava e-navigacije. Vrijednosti za varijable, kao i dobrobit uvođenja e-navigacije (*ENSI-service*), procijenjene su uz pomoć osam eksperata.

U radu iz 2014. godine autori Haninnen i Kujala [45] koristili su podatke lučkih kapetanija (*Port State Control)* u svrhu otkrivanja interakcija u pomorskim nezgodama i pomorskim incidentima.[4] Uz pomoć Bayesove mreže uspoređivali su međusobne povezanosti rezultata inspekcija finskih lučkih vlasti, statistiku pomorskih nezgoda na Baltiku te izvještaje o pomorskim nezgodama VTS centra kako bi doznali koje varijable i koja stanja varijabli imaju najveći utjecaj na mogućnost pojave pomorske nezgode.

---

[3] OOW – Officer on watch – časnik odgovoran za plovidbenu stražu na brodu.

[4] Pomorski incident definiran je kao pojava koja je povezana s radnjom broda, a koja nije pomorska nezgoda te ima ili može imati utjecaj na sigurnost broda (Faghih-Roohi i ostali, 2014). Prema IMO-u nezgoda *(Accident*) se definira kao nenamjeran događaj koji uključuje smrtnost, povrede ljudi, gubitak broda ili njegovo oštećenje, gubitak ili oštećenje druge imovine ili štete po okoliš. Termini „pomorska nezgoda“ te „pomorski incident“ označavaju neželjeni događaj vezan za brodske operacije (IMO, 1996). Autori Mullai, Paulsson (2011) pomorskim incidentom smatraju neželjen događaj koji je rezultirao štetnim posljedicama, primjerice povredom, gubitkom života, ekonomskim gubitkom, onečišćenjem okoliša te oštećenjem ili gubitkom imovine. Pomorsku nezgodu smatraju neočekivanom kombinacijom uvjeta ili događaja. Budući da se u većini literature najčešće koristi izraz „pomorska nezgoda“, bez obzira na razliku između nezgode i incidenta, takav pristup korišten je i u ovom radu.

Det Norske Veritas (DNV) je 2003. godine izradila studiju procjene rizika za putničke brodove koja se temelji na FSA preporukama. Studija se sastoji od modela koji služi za kvantificiranje vjerojatnosti sudara i nasukavanja. Model uključuje ljudski, tehnički i geografski faktor te druge vanjske utjecaje, izabrane s ciljem prikazivanja važnosti određenih faktora utjecaja na rizik u svrhu izračuna *Risk Control Options (RCO*[5]*).* Modeli su napravljeni na temelju Bayesovih mreža. U studiji su došli do rezultata kako nasukavanje koje se dogodi za vrijeme rada pogonskog stroja ima 40 % veću vjerojatnost gubitka ljudskih života nego sudar, a navedeni podatak proizlazi iz činjenice da su frekvencije nasukavanja veće nego frekvencije sudara. Ako se razmatra gubitak ljudskih života u odnosu na broj nasukavanja te gubitak ljudskih života u odnosu na broj sudara, dolazi se do zaključka da je pomorska nezgoda sudara devet puta opasnija za ljude na brodu nego pomorska nezgoda nasukavanja (DNV, 2003).

Wang i ostali (2004) [97] analizirali su različite pristupe modeliranja rizika. Promatrali su *Fuzzy* teoriju u sustavima nesigurnosti analize pomorskih nezgoda.

Liu i ostali 2005. godine [65] razmatrali su različite tehnike i opisivali njihovu mogućnost uporabe u analizama pomorskog rizika. Analizirali su tri teorije: Bayesovu, Demster-Shaferovu i *Fuzzy*. Komparacijom su iznijeli mane i prednosti svake od ovih teorija.

Kujala i ostali (2009) [60] i Goerlandt (2012) [38] modelirali su rizik nezgode koristeći podatke o gustoći pomorskog prometa, definirajući rizik kao uvjetovanu vjerojatnost.

Autori Li i ostali 2012. godine [64] bavili su se analizom postojećih modela rizika u pomorstvu. Zaključuju da nema jedinstvenog modela koji bi se mogao rabiti u svim pomorskim složenim sustavima za procjenjivanje rizika. Većina autora pri procjeni pomorskog rizika bavi se samo jednom vrstom pomorske nezgode.

Grupa autora Chang i ostali 2014. godine [31] izradila je skalu na temelju rangiranja faktora koristeći srednje vrijednosti i stohastičke metode dominacije te mapu rizika uz pomoć koje je identificirala razinu rizika.

[5] RCO – Kombinacija mjera za kontrolu rizika (FSA, 2003).

Grupa autora Montewka i ostali (2014) [76] izradila je model koristeći Bayesove mreže za procjenu sudara Ro-Ro putničkih brodova na otvorenom moru definirajući varijable modela, potom razvijajući kvalitativni i kvantitativni model te, na kraju, validirajući model.

Autori Akhtar i Utne 2014. Godine [22] izradili su model rizika temeljen na Bayesovoj mreži. U tom radu predočili su problem nemogućnosti generaliziranja modela bez kvantificiranja podataka kao što je, primjerice, vrsta broda. Metodologija koju su autori rabili za konstruiranje probabilističkog modela razrađena je u pet faza:

- definiranje sustava s njegovim karakteristikama i granicama
- prikupljanje potrebnih podataka
- razvijanje strukture modela
- parametriziranje modela
- validacija modela.

Autori Mazeheri, Montewka i Kujala u radu iz 2016. Godine [71] izradili su model nasukavanja temeljen na Bayesovim mrežama koristeći se pristupom temeljenim na stvarnim događajima. Podatke za kvantificiranje dobili su iz izvještaja pomorskih nezgoda nasukavanja nadopunjujući ih ekspertnim znanjem. Rezultat modela je vjerojatnost nasukavanja dana kroz apriori i posteriori vjerojatnosti utjecajnih čimbenika.

Autori Frančić i ostali 2009. Godine [37] analizirali su stanje flote, vrste pomorskih nezgoda te općenito sigurnost putničkih brodova čime su utvrđeni najčešći uzroci nezgoda. Na temelju rezultata autori su predložili preporuke u cilju unaprjeđenja sigurnosti plovidbe.

Autori Mohović, Barić i Itković 2013. [74] godine analizirali su vrste pomorskih nezgoda te njihove uzroke. Autori su se bavili korelacijama između pomorskih nezgoda i vremenskih uvjeta u Republici Hrvatskoj. Slijedom analize, autori su zaključili kako se u razdoblju od 2005. do 2011. godine najveći broj nezgoda plovila nautičkog turizma odnosio na nesposobnost manevriranja i nasukavanje. U razdoblju od 2005. do 2011. ispitivali su i uzroke pomorskih nezgoda te uočili nekorelaciju broja dana puhanja jakog i olujnog vjetra i broja nesreća u Dubrovačko-neretvanskoj županiji, navodeći kako bi taj fenomen trebalo dodatno ispitati. Kao razlog nekorelacije navode smjer vjetra. Naime, jugo kao vjetar koji najčešće puše u južnom dijelu Jadrana postupno jača pa su nautičari obično u prilici skloniti se u sigurnu luku.

Autori Lale i ostali u radu iz 2015. godine [61] obrazložili su potrebu analiziranja rizika u pomorstvu te su opisali Bayesove mreže i obrazložili postupak izrade i glavne značajke Bayesovog teorema. Nadalje, u radu analiziraju primjenu Bayesovog teorema na raznim primjerima u pomorstvu.

1.4 Hipoteza

Temeljna hipoteza ovoga rada jest: ograničenja općenitih metoda procjene rizika temeljenih na kvalitativnoj analizi i jednostavnoj obradi statističkih podataka mogu se poboljšati komplementarnim djelovanjem kvalitativne i kvantitativne analize podataka temeljene na Bayesovim mrežama, koje su parametarski prilagodljive području interesa.

Pri tome su glavni izazovi modeliranja rizika:

- koje faktore utjecaja na rizik uključiti u model i kako ih mjeriti
- kako sistematizirati i stupnjevati ekspertno znanje dostupno u obliku opisnih podataka i intervjua.

1.5 Znanstvene metode

Za potrebe znanstvenog istraživanja, analize i prezentacije rezultata istraživanja te provedbe istraživanja korištena je sva raspoloživa dokumentacija, bibliografija, baze podataka i drugi izvori. Primijenjena je kombinacija više istraživačkih metoda. Koristila se metoda kompilacije za pregled dosadašnjih istraživanja, metoda promatranja, uspoređivanja te statističke metode.

Da bi se izračunala vjerojatnost pojave pomorske nezgode na putničkim brodovima u nelinijskoj obalnoj plovidbi, korištene su procjene eksperata te podaci dobiveni od različitih službenih izvora u svrhu osiguranja čvrstih temelja za definiranje ovisnosti i figura koje su unesene u model. Među aktivnim zapovjednicima brodova provedena je metoda intervjuiranja nakon što su upoznati s osnovama uvjetovane vjerojatnosti koja se koristila u izradi modela. Osim aktivnih zapovjednika, intervjuirani su zaposlenici VTS centra te lučki kapetani lučkih ispostava s visokim brojem uplova i isplova promatranih brodova.

Bayesove mreže su izabrane kao metoda za izradu modela procjene neželjenih događaja zbog mogućnosti modeliranja ljudskih i organizacijskih faktora koji su neki od glavnih uzroka pomorskih nezgoda. Bayesove mreže mogu davati procjene i u uvjetima nekompletnih setova podataka te u procesu procjene mogu ravnopravno koristiti informacije dobivene analitičkim

putem iz podataka i/ili uz pomoć eksperata. Bayesove mreže koristile su se prilikom izrade modela procjene rizika pojave pomorskih nezgoda zbog mogućnosti prepoznavanja najvažnijih razloga koji dovode do pomorske nezgode te mogućnosti analiziranja veza koje djeluju između njih. Prilikom izrade Bayesovih mreža primijenjena je matematička logika u kombinaciji s ekspertnim mišljenjem. Bayesove mreže omogućuju inkorporaciju znanja stručnjaka koje je korišteno u izradi ovih modela. U slučajevima kada je bilo potrebno koristiti ekspertnu procjenu prilikom validiranja varijabli, Bayesove mreže bile su korisne zbog velikog broja nepotpunih podataka o utjecajnim čimbenicima.

2. POMORSKE NEZGODE

Pomorska plovidba izložena je mnogobrojnim opasnostima jer se brod prilikom plovidbe iz redovitih stanja može naći u izvanrednim stanjima koja su uzrokovana neželjenim događajima. Izvanredna stanja mogu se pretvoriti u pomorske nezgode, odnosno izvanredne događaje te u konačnici rezultirati gubitkom života, gubitkom imovine ili onečišćenjem okoliša. Pomorske nezgode karakterizira izvanrednost, a izvanredni događaji mogu se podijeliti na one koji su izazvali štetne posljedice, izravno ili neizravno, i na one koji nisu izazvali štetne posljedice, ali su ih mogli izazvati. Usprkos poduzetim mjerama u vezi sa sigurnošću plovidbe, mnoge studije dokazuju da su pomorske nezgode prisutne u velikom broju (Wang i ostali, 2011, 2013). Pomorske nezgode nemoguće je eliminirati, preostaje nam učiniti sve što je moguće kako bi ih bilo manje.

Rizik se može definirati ovisno o njegovoj svrsi pa tako postoji mnogo različitih definicija rizika. Počeci analize rizika sudara javljaju se još krajem pedesetih godina prošlog stoljeća kada je Minorski (1959) mjerio sudar bazirajući se na mehaničkom modelu. Prema Janešu i Čavraku (1999) rizik je mjerilo opasnosti kojom neki objekt ili djelatnost može utjecati na okolinu, a funkcija je učestalosti i veličine mogućih posljedica. Prema Vanem i ostali (2008) koncept rizika je definiran kao vjerojatnost posljedica neželjenog događaja u različitim scenarijima i pomorskim sustavima. Rizik se može definirati i kao kombinacija vjerojatnosti i stupnja moguće ljudske ozljede, štete imovine ili štete okoliša (Aven, 2010). Nadalje, rizik se može definirati kao vjerojatnost neželjenog događaja (Debath i Chin, 2010). Prema standardnoj definiciji, rizik je umnožak vjerojatnosti pojave događaja i posljedice:

$$R = P \cdot C \,, \tag{1}$$

gdje su R – rizik (*Risk*), P – vjerojatnost pojave događaja (*Probability*), a C – posljedica (*Consequence*).

Prema autoru Mohović (2011), svi događaji na brodu koji su neuobičajeni, započinju ispravnim stanjem sustava broda, a završavaju nezgodom. Isti autor navodi da je pri razmatranju pomorskih rizika, u ovom slučaju pomorske nezgode potrebno, osim određivanja prihvatljivog rizika odrediti i posljedicu nezgode.

Pomorske nezgode mogu izazvati posljedice na:

- pojedinca (prolazne ili trajne povrede, invalidnost ili gubitak života),

- društvo (isto kao i za pojedinca, samo što se uzima u obzir veća skupina ljudi, a često se podrazumijeva da ta skupina ne sudjeluje u tom procesu već je izvan njega),
- imovinu i prava (materijalne posljedice kao što je gubitak imovine, gubitak prihoda, troškovi za umanjenje posljedica onečišćenja i dr.),
- okoliš (prolazna ili trajna promjena šireg ili užeg okoliša).[6]

Određivanje prihvatljivog rizika promatranih brodova uključuje, osim sigurnosnih faktora, i razne druge faktore kao što su: ekonomski faktori, faktori utjecaja na okoliš, faktori u turizmu itd. Zbog širokog opsega faktora utjecaja na procjenu rizika pomorskih nezgoda te širokog opsega utjecajnih faktora na posljedice pomorskih nezgoda u ovom radu istražena je samo procjena pojave pomorskih nezgoda bez promatranja posljedica pomorskih nezgoda.

2.1 Pojam pomorskih nezgoda

U pomorstvu postoji veći broj podjela pomorskih nezgoda, sukladno potrebama autora ili institucijama koje njima bave. Međunarodna pomorska organizacija dijeli sve pomorske nezgode u 4 sljedeće grupe:

- nezgode koje su uzrokovale štetne posljedice vrlo velikih razmjera (*Very serious casualty*),
- nezgode koje su uzrokovale štetne posljedice velikih razmjera (*Serious casualty*),
- nezgode koje su uzrokovale štetne posljedice malih razmjera (*Less serious casualty*),
- ostale nezgode (*Marine incidents*).

Ministarstvo mora, prometa i infrastrukture prema izvješćima pomorske nezgode dijeli na: kvar, nasukavanje, naplavljivanje, oštećenje, požar, potonuće, ozljeda, sudar, udar, smrt te ostalo.

Iz znanstvene literature koja se bavi pomorskim nezgodama vrijedno je spomenuti definiciju prema Zec (2001) kako slijedi: „Pomorskim nezgodama nazivaju se izvanredni događaji koji su izazvali takve štetne posljedice da su neposredno ugroženi ljudski životi i imovina. Ako su zbog pomorske nezgode nastupile takve okolnosti da su ugroženi životi svih ljudi na brodu, pa je smanjena i sposobnost broda da se održava na površini mora, prijeko je potrebno napustiti brod i prijeći u plovila za preživljavanje."

[6] Mohović Đ., Upravljanje rizikom u pomorstvu – autorizirana predavanja, 2011.

S obzirom na okolnosti u kojima je potrebno napustiti brod autor dijeli pomorske nezgode na:

- potonuća
- požare i/ili eksplozije
- nasukanje broda
- sudare i udare broda i
- oštećenje trupa i strojeva.[7]

Mohović (2011) opasnost definira „kao događaj koji može štetno utjecati na život i zdravlje ljudi, kao i na okoliš te izazvati oštećenje ili uništenje imovine. Dakle, opasnost predstavlja događaj koji može imati štetne posljedice na neke ili više prije navedenih kategorija.“ Isti autor definira i izvanredni događaj: „Izvanredni događaj predstavlja događaj koji nije planiran od strane posade, a može rezultirati opasnošću po ljude, imovinu ili okoliš.“

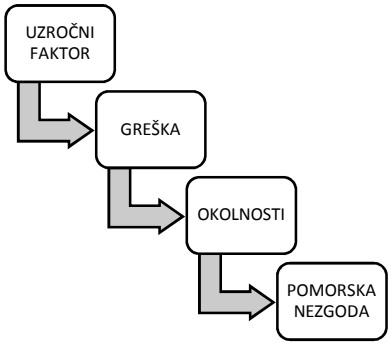

Slika 2-1: Nastanak pomorske nezgode

U ovom se radu zbog potrebe modela primjenjuje podjela pomorskih nezgoda na: potonuće, udar, nasukavanje, sudar te požar i eksplozije. Pored navedenih pomorskih nezgoda potrebno je spomenuti i izvanredne događaje koje karakterizira mala učestalost te povezanost s lokalitetom (prevare, ratne nezgode, piratstvo, namjerne nezgode i sl.).

2.2 Analiza pomorskih nezgoda u Republici Hrvatskoj

Analiza pomorskih nezgoda i analiza putničkih brodova u Republici Hrvatskoj napravljene su na temelju podataka Ministarstva pomorstva, prometa i infrastrukture te Hrvatskog registra brodova za razdoblje od 2011. do 2015. godine.

[7] Zec D. Sigurnost na moru, Rijeka 2001.

Prema nacionalnim propisima, putnički brod je definiran kao brod na mehanički pogon koji je ovlašten prevoziti više od 12 putnika, dok je putnik svaka osoba na pomorskom objektu osim djece ispod jedne godine života, te osoba zaposlenih na brodu u bilo kojem svojstvu.[8]

Putnički brodovi mogu se podijeliti prema:

- veličini broda,
- broju putnika koje prevoze,
- području plovidbe.

Postoji veliki broj podjela putničkih brodova prema veličini te će se zbog potrebe ovoga rada uzeti podjela na: velike putničke brodove (veće od 70 metara) i male putničke brodove (manje od 70 metara). Također, postoji mnogo podjela prema broju putnika koje prevoze, te će se za potrebe rada uzeti podjela na: brodovi za mali broj putnika (do 50), srednji broj putnika (50 do 200) te veliki broj putnika (preko 200).

Prema kategoriji plovidbe pomorskih brodova, putnički brodovi mogu ploviti:

- neograničenom plovidbom
- velikom obalnom plovidbom
- malom obalnom plovidbom
- obalnom plovidbom Jadranskim morem
- nacionalnom plovidbom
- nacionalnom obalnom plovidbom
- nacionalnom priobalnom plovidbom.[9]

Obalne putničke brodove promatrane u ovom radu karakterizira plovidba i prijevoz putnika u obalnim područjima te manjim zatvorenim morima.

Pomorsko putnički promet razlikuje dvije osnovne vrste brodarstva:

- linijsko putničko brodarstvo
- nelinijsko putničko brodarstvo.

[8] Pomorski zakonik, Narodne novine, br. 181/04, 76/07, 146/08, 61/11, 56/13 i 26/15.

[9] Pomorski zakonik, op. cit.

Linijska plovidba je: „prijevoz putnika, tereta i vozila u unutarnjim morskim vodama i teritorijalnom moru Republike Hrvatske koji se obavlja na unaprijed utvrđenim linijama prema javno objavljenim uvjetima reda plovidbe i cjenikom usluga.“[10]

Pojam nelinijske plovidbe moguće je objasniti kao putovanje brodom između dviju ili više luka bez objavljenog plovidbenog reda. Plovidba u nelinijskom brodarstvu nije redovna ni učestala te ne predstavlja sistematski slijed.

Putnički nelinijski promet dijeli se na domaći i strani. Promet stranih brodova je ponajprije promet velikih brodova za kružna putovanja, dok putnički nelinijski promet domaćih brodova ostvaruju manji brodovi za jednodnevna ili višednevna krstarenja.

Prema Pravilniku o vrstama i kategorijama plovnih objekata nautičkog turizma, putnički turistički brodovi dijele se na:

- plovne objekte za izlete (u trajanju do 24 sata)
- plovne objekte za krstarenja (u trajanju preko 24 sata).

Plovni objekt za izlete namijenjen je za turističke usluge prijevoza turista na izletima u trajanju do 24 sata u kojem se ne pruža usluga smještaja.[11] Brodove za izlete karakterizira plovidba u trajanju 2 – 3 sata u tijeku koje napuštaju matične luke ujutro, vode putnike na turističke destinacije te se vraćaju u matične luke istog dana. Kapacitet putnika i uobičajene rute ovih brodova nestalne su i ovisne o potrebama klijenata.

Plovni objekt za krstarenje namijenjen je za turističke usluge prijevoza turista na krstarenjima u trajanju preko 24 sata, a opremljen je za višednevni boravak turista.[12] Brodovi za višednevna krstarenja su brodovi s kapacitetom putnika od dvanaest do pedeset. Ukrcavaju putnike u svojim matičnim lukama svako sedam ili četrnaest dana. Dnevna plovidba im traje kao kod brodova za izlete, točnije samo nekoliko sati. Uglavnom noće u lukama ili na turističkim odredištima.[13] Brzine putničkih brodova za jednodnevna krstarenja i izlete te za višednevna krstarenja kreću se od 7 do 15 čvorova.

---

[10] Zakon o prijevozu u linijskom i povremenom obalnom prometu, Narodne novine, br. 33/06, 38/09, 87/09, 18/11, 80/13, 56/16.

[11] Pravilnik o vrstama i kategorijama plovnih objekata nautičkog turizma, Narodne novine, br. 69/08.

[12] Pravilnik o vrstama i kategorijama plovnih objekata nautičkog turizma, Narodne novine, br. 69/08.

[13] Prometno-plovidbena studija, Plovno područje Split, Ploče i Dubrovnik, 2014.

Prema direktivi 2009/45/EZ Europskog parlamenta i Vijeća o sigurnosnim pravilima i normama za putničke brodove koju je preuzeo i Hrvatski registar brodova (HRB), brodovi su razvrstani u sljedeće klase prema području plovidbe:

- Klasa A: putnički brod koji obavlja putovanja u nacionalnoj plovidbi osim putovanja obuhvaćenih klasama B, C i D;
- Klasa B: putnički brod koji obavlja putovanja u nacionalnoj plovidbi, pri čemu ni u jednom trenutku nije udaljen više od 20 milja od obalne crte kopna na koje se mogu iskrcati osobe koje pretrpe brodolom, uzimajući u obzir srednju visinu morskih mijena;
- Klasa C: putnički brod koji obavlja putovanja u nacionalnoj plovidbi u morskim područjima gdje je vjerojatnost premašivanja značajne visine vala od 2,5 m manja od 10 % na godišnjoj razini za brodove koji plove cijelu godinu ili na razini pojedinog ograničenog razdoblja za brodove koji plove isključivo u tom razdoblju (npr. plovidba u ljetnom razdoblju), pri čemu ni u jednom trenutku nije udaljen više od 15 milja od mjesta zakloništa ni više od 5 milja od obalne crte kopna na koje se mogu iskrcati brodolomci, uzimajući u obzir srednju visinu morskih mijena;
- Klasa D: putnički brod koji obavlja putovanja u nacionalnoj plovidbi u morskim područjima gdje je vjerojatnost premašivanja značajne visine vala od 1,5 m manja od 10 % na godišnjoj razini za brodove koji plove cijelu godinu ili na razini pojedinog ograničenog razdoblja za brodove koji plove isključivo u tom razdoblju (npr. plovidba u ljetnom razdoblju), pri čemu ni u jednom trenutku nije udaljen više od 6 milja od mjesta zakloništa ni više od 3 milje od obalne crte kopna na koje se mogu iskrcati osobe koje pretrpe brodolom, uzimajući u obzir srednju visinu morskih mijena.

Prema podacima Hrvatskog registra brodova za 2015. godinu broj putničkih brodova iznosio je ukupno 672, od toga je bilo 46 Ro-Ro putničkih brodova te 24 brza putnička broda. Prema Hrvatskom registru brodova većina brodova izgrađena je od drva, čak 59,5 %, slijede brodovi od čelika 27,7 % te stakloplastike 10,8 %. Neznatan broj brodova napravljen je od aluminija (1,7 %) ili betona.

Većina putničkih brodova je duljine od 10 do 20 metara (54 %). Slijede brodovi duljine od 20 do 30 metara (23,2 %), zatim brodovi duljine od 30 do 40 metara (14,3 %), putnički brodovi do 10 m[14], (2,5 %) te putnički brodovi veći od 50 metara (0,5 %).

81,4 % brodova ima kategoriju plovidbe nacionalne obalne plovidbe, 15,1 % brodova ima kategoriju nacionalne priobalne plovidbe. Ostale kategorije prisutne su u vrlo malim postotcima.

Podaci o starosti putničkih brodova u Hrvatskoj prikazani su na slici 2-2.

Iz slike 2-2 je vidljiv trend izgradnje novih brodova. 17,8 % brodova je mlađe od 10 godina, a 8,4 % brodova je starije od 100 godina.

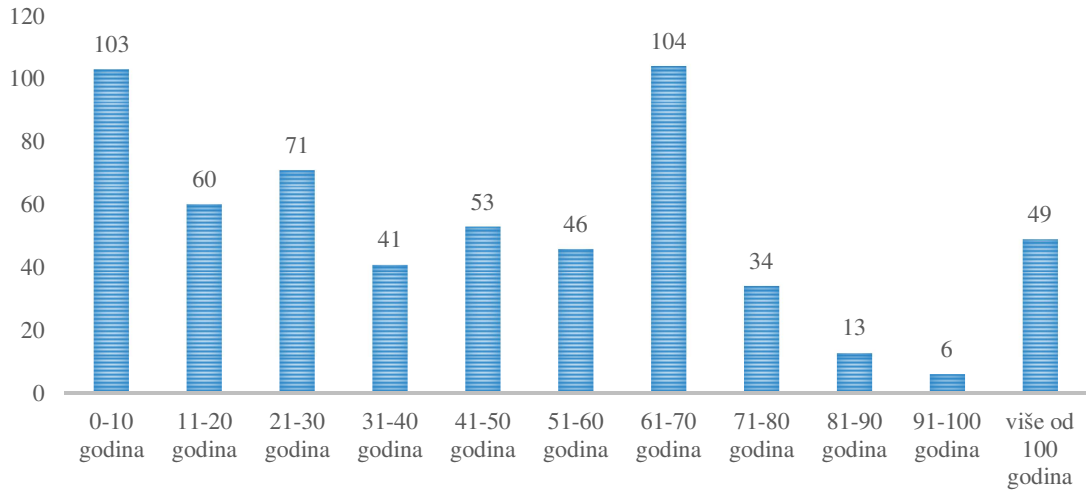

Slika 2-2: Starost putničkih brodova u Hrvatskoj

Izvor: Hrvatski registar brodova

Nadalje, statistički podaci pokazuju da su u razdoblju od 2011. do 2015. plovila za šport i razonodu sudjelovali u najvećem broju pomorskih nezgoda, njih 84,6 %, dok su putnički brodovi sudjelovali s 2,5 % (Slika 2-3).

[14] Putnički brod može biti veličinom manji od one kojom je definiran brod prema Pomorskom zakoniku što znači da brodica (duljina manja od 12 metara) registrirana za prijevoz putnika predstavlja putnički brod.

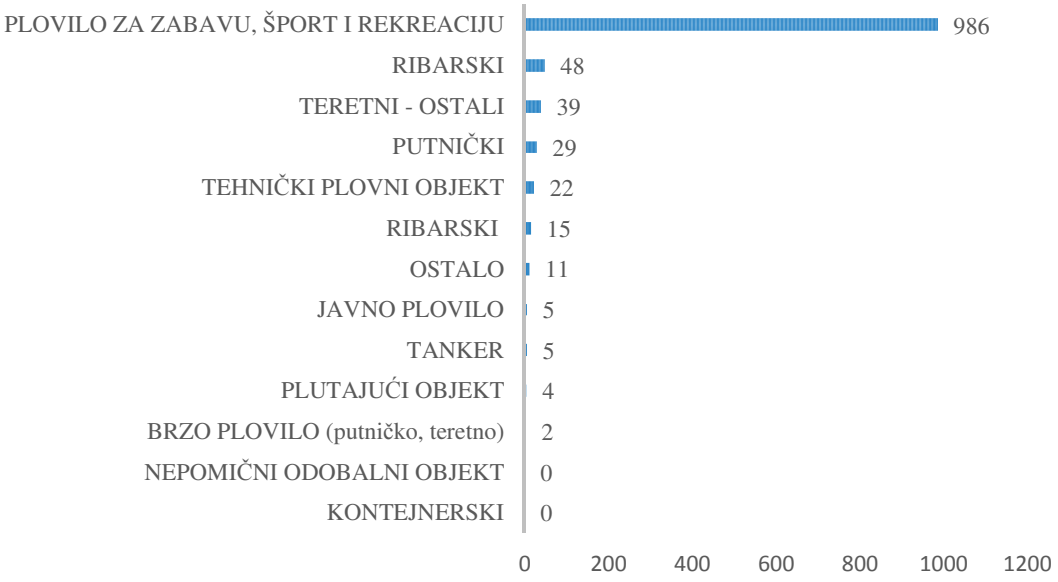

Slika 2-3: Broj pomorskih nezgoda prema vrsti plovnog objekta

Izvor: MMPI

U pomorskim nezgodama prema podacima MMPI-a u razdoblju od 2011. do 2015. godine 23,3 % plovila je bilo hrvatske zastave, slijede plovila talijanske zastave 17,6 %, zatim njemačke zastave 14,3 %, plovila slovenske zastave 10,6 %, plovila austrijske zastave 5,6 % te ostali u manjim postotcima.

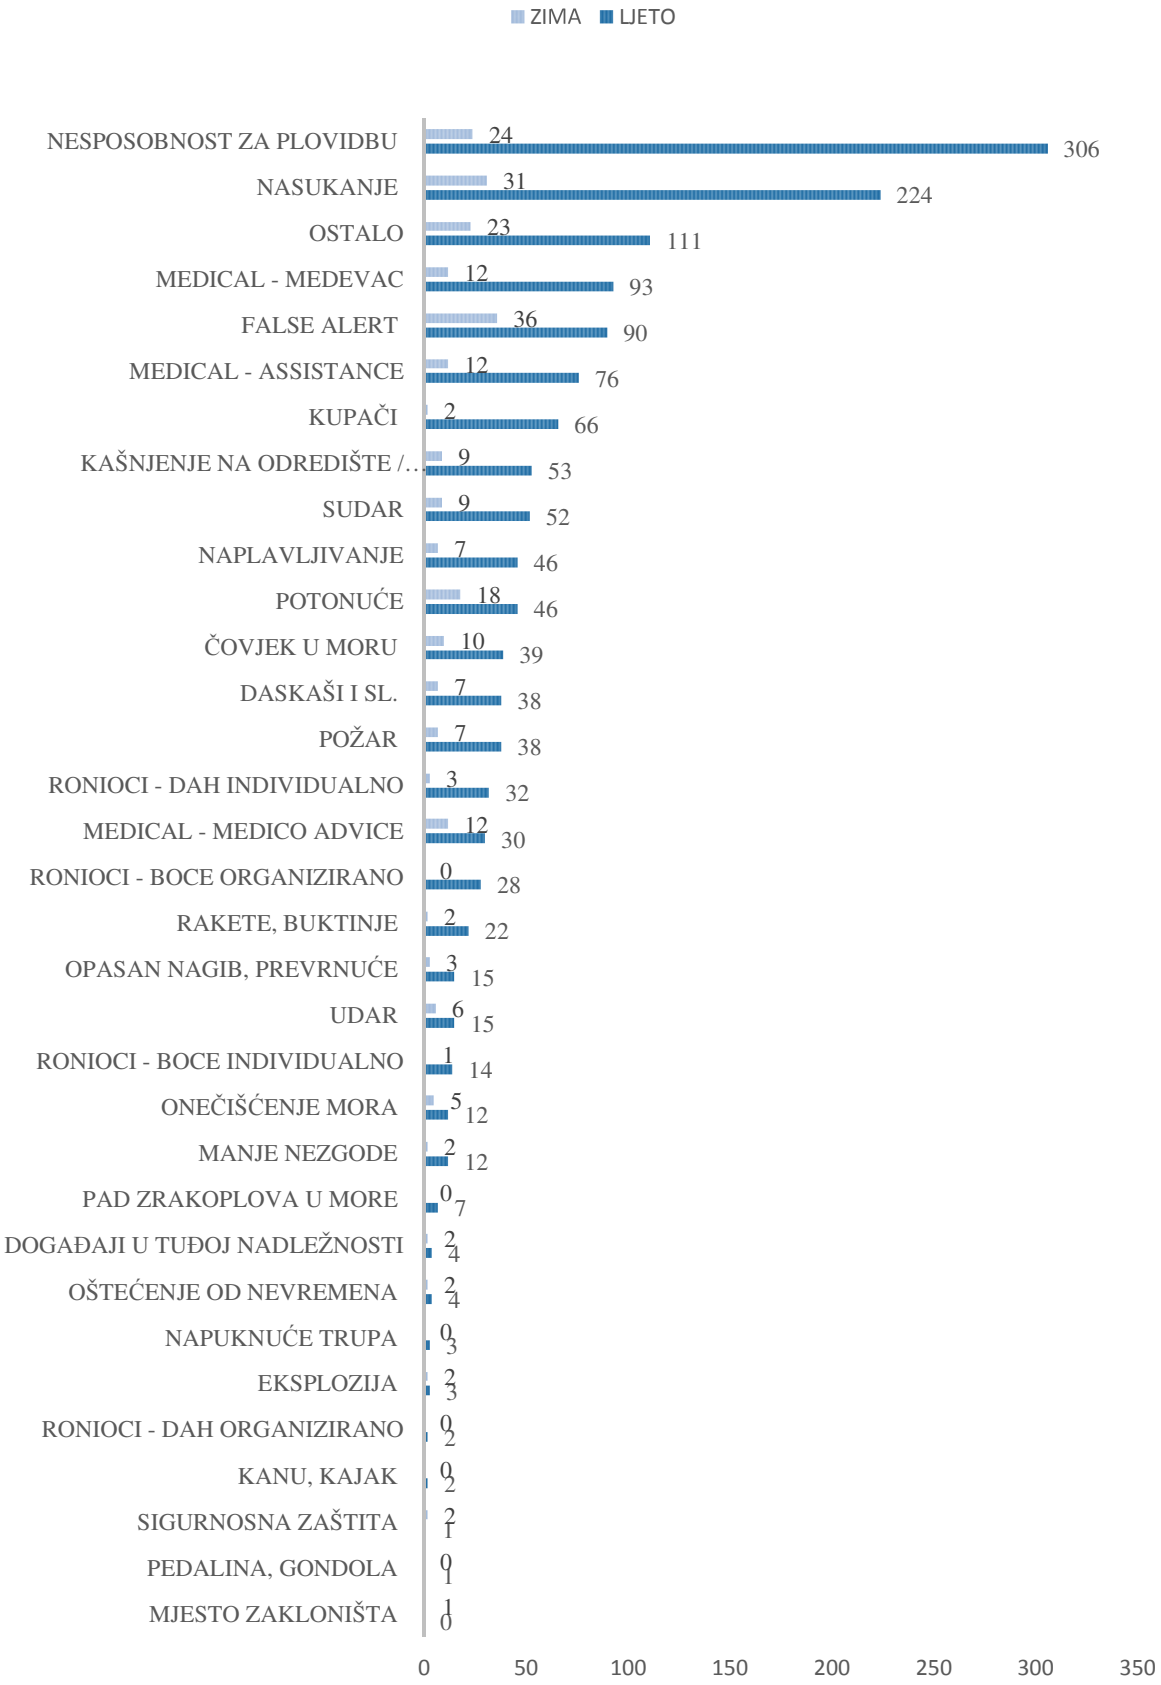

Slika 2-4: Pomorske nezgode na moru prema klasifikaciji MMPI-a od 2011. do 2015. godine

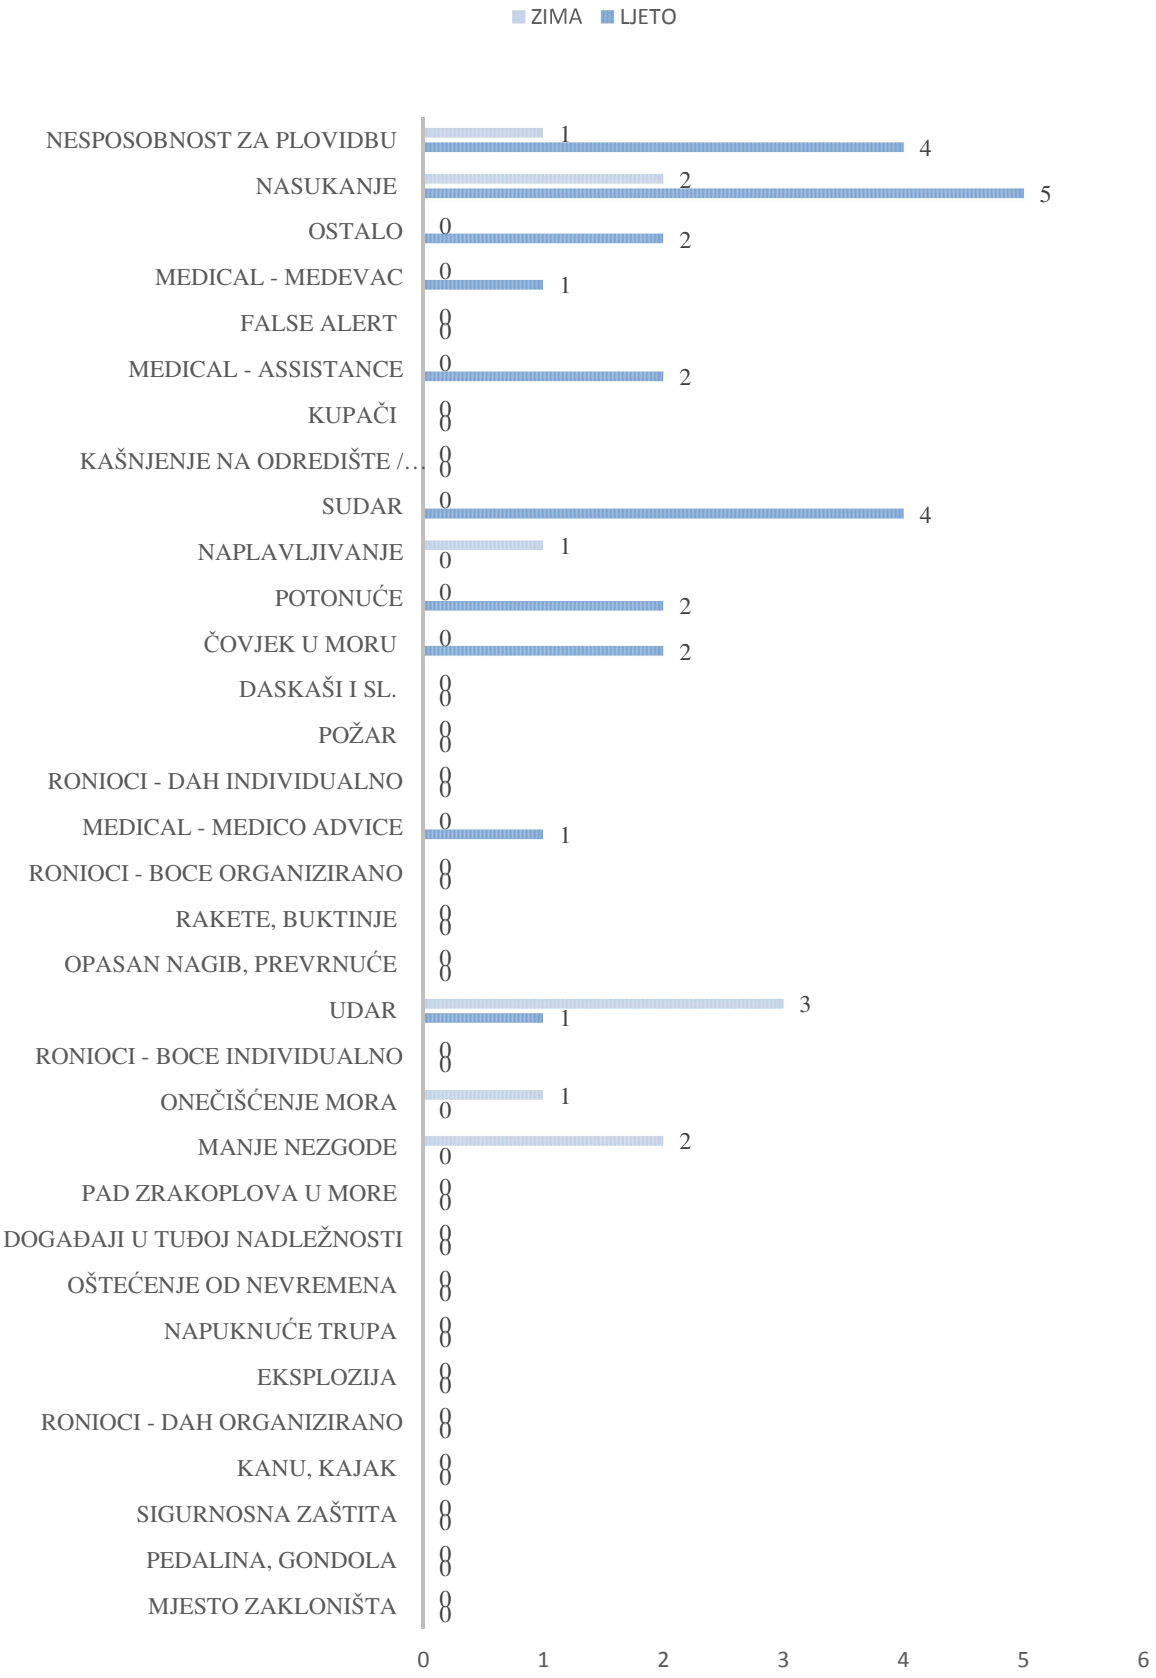

Slika 2-5: Pomorske nezgode putničkih brodova prema klasifikaciji MMPI-a od 2011. do 2015. godine

Prema podacima Ministarstva mora, prometa i infrastrukture, najzastupljenija vrsta pomorske nezgode putničkih brodova je nasukavanje u ljetnom periodu (Slika 2-5). Nakon sudara, slijedi pomorska nezgoda udara u zimskom razdoblju. Zabilježen je postotak od 8,3 % slučajeva traženja medicinske pomoći koje prema podjeli u ovome radu ne spada u pomorske nezgode, ali može biti uzrok zbog kojeg putnički brodovi prekidaju plovidbu i mijenjaju planirane rute.

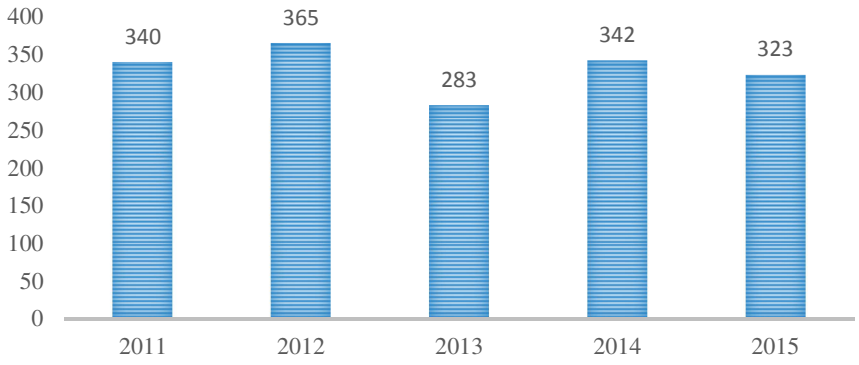

Slika 2-6: Broj pomorskih nezgoda od 2011. do 2015. godine

Izvor: MMPI

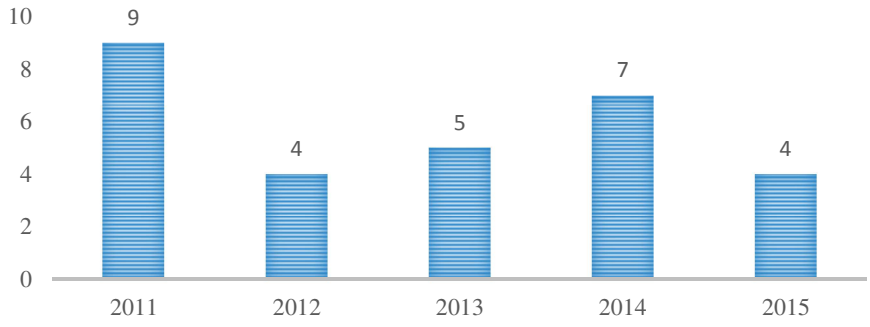

Slika 2-7: Broj pomorskih nezgoda za putničke brodove od 2011. do 2015. godine

Izvor: MMPI

Ukupni broj nezgoda u razdoblju od 2011. do 2015. te ukupni broj nezgoda u kojima su sudjelovali putnički brodovi prikazani su na slikama 2-6 i 2-7.

2.3 Pomorske nezgode u teritorijalnim morima i unutarnjim vodama EU zemalja

Da bi se usporedile pomorske nezgode na istočnoj strani Jadrana s podacima Europske agencije za pomorsku sigurnost (*European Maritime Safety Agency – EMSA*), potrebno je navesti EMSA-inu definiciju pomorske nezgode: „Pomorska nezgoda je definirana kao događaj koji je izravno povezan s operacijama broda koje su rezultirale bilo kojim od sljedećih scenarija:

- smrt, gubitak ili teške ozljede osobe
- gubitak, pretpostavljeni gubitak ili napuštanje broda
- materijalna šteta na brodu ili obalnoj infrastrukturi
- naplavljivanje ili onesposobljavanje broda ili sudjelovanje broda u sudaru
- teške ili potencijalne ozbiljne štete u okolišu, uzrokovane oštećenjem broda.

Prema EMSA-i pomorske nezgode dijele se i po kategorijama na:

- vrlo ozbiljne
- ozbiljne
- manje ozbiljne
- pomorski incident.

Termin „pomorski incident“ definiran je kao događaj ili niz događaja, osim pomorske nezgode, koji se dogodio izravno u vezi s operacijama broda koje su ugrožene ili, ako nisu ispravljene, ugrožavaju sigurnost broda, njegovih putnika ili bilo koje druge osobe ili okoliš. Zbog lakše analize podataka pomorskih nezgoda od strane EMSA-e korišten je izraz „događaj“ koji se odnosi na pomorski incident i na pomorsku nezgodu.

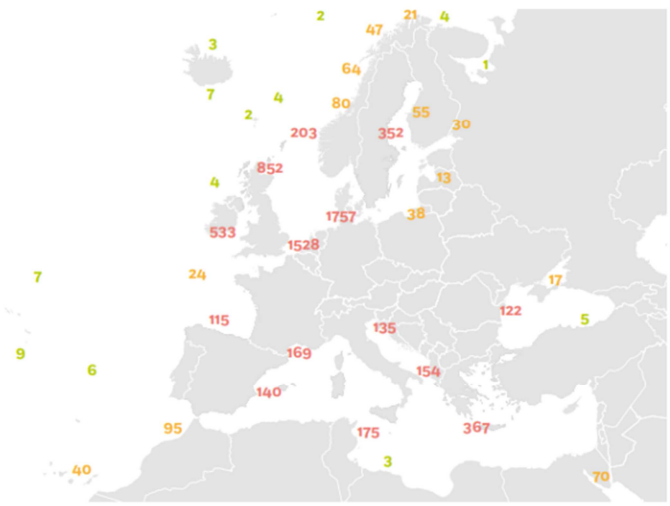

Slika 2-8: Distribucija pomorskih nezgoda teritorijalnog mora i unutarnjih voda EU zemalja za 2015. godinu

Slika preuzeta s www.emsa.europa.eu

Prema podacima EMSA-e od 2011. do 2015. prijavljeno je 9506 događaja (slika 2-10). U istom razdoblju dogodilo se 505 smrtnih slučajeva te je ozlijeđeno 4226 osoba. Kao uzroci smrtnih slučajeva navedeni su sljedeći događaji: gubitak kontrole, sudar, naplavljivanje, udar, oštećenje broda i opreme, prevrtanje, nasukavanje, požar/eksplozija te oštećenje trupa (slika 2-9). U razdoblju od 2011. do 2015. godine polovina pomorskih nezgoda bila je navigacijske prirode (sudar, nasukavanje, udar). Prema EMSA-inim podacima 67 % pomorskih nezgoda uzrokovano je ljudskom pogreškom.

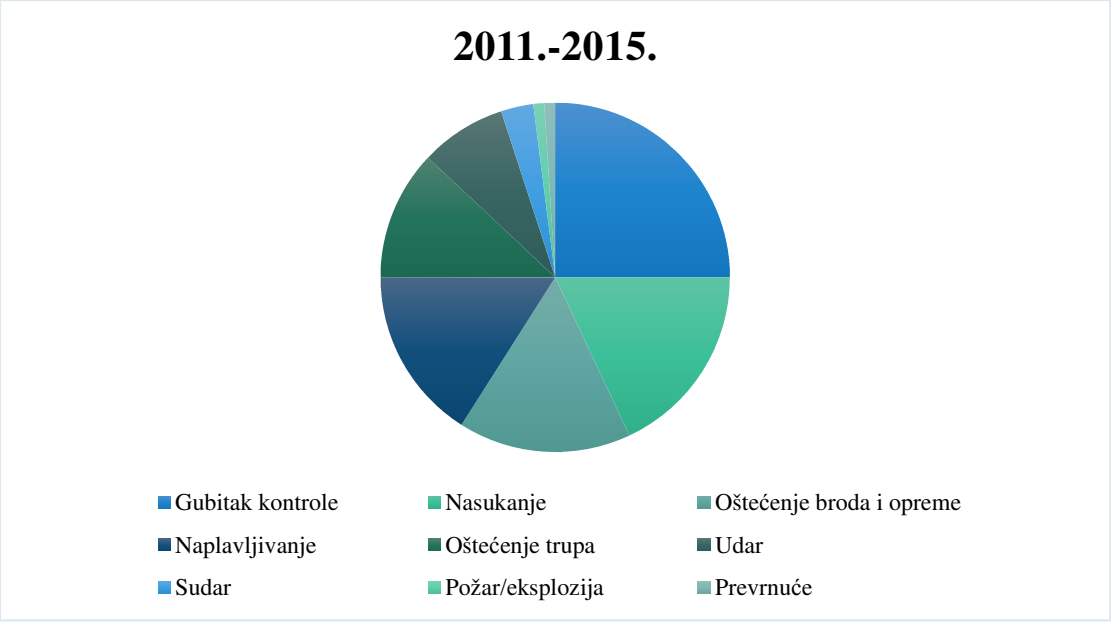

Slika 2-9: Vrste pomorskih nezgoda od 2011. – 2015. godine

Izvor: Izrađeno prema podacima www.emsa.europa.eu

EMSA navodi da je od 2011. do 2014. godine bilo 4 % vrlo ozbiljnih pomorskih nezgoda, ozbiljnih 21 %, manje ozbiljnih 59 % te pomorskih incidenata 16 %. U promatranom razdoblju nije bilo porasta broja vrlo ozbiljnih pomorskih nezgoda, ali se zato u ostalim kategorijama bilježi stalni porast pomorskih nezgoda. Najučestalije kategorije koje su uzrokovale pomorske nezgode su gubitak kontrole (296 slučajeva) te nasukavanje (291 slučaj). Od ukupnog broja 2383 putnička broda koja su imala pomorsku nezgodu od 2011. do 2014. godine većina ih je bila kategorije Ro-Ro putnički brod (683 slučajeva), a slijede brodovi kategorije putnički brod sa 412 slučajeva (EMSA).

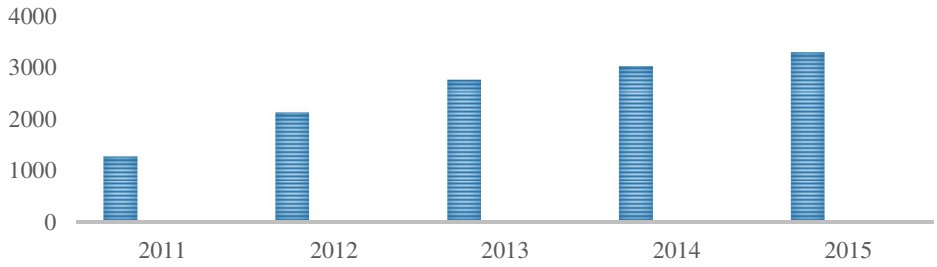

Slika 2-10: Događaji od 2011. do 2015.

Izvor: Izrađeno prema podacima www.emsa.europa.eu

U razdoblju od 2011. do 2014. godine brodovi koji su imali najviše „događaja“ su trgovački brodovi (44 %), slijede putnički brodovi (23 %), specijalni brodovi (15 %), ribarski brodovi (13 %) te ostali (5 %). Samo u 2015. godini zabilježeno je 3296 događaja, od čega 115 smrtnih slučajeva pri čemu je 976 osoba bilo ozlijeđeno, 573 broda imala su gubitak kontrole, 405 brodova imalo je udar, 348 brodova imalo je štetu na brodu ili opremi te 117 brodova požar/eksploziju.

2.4 Opći model broda kao dinamičkog sustava

Da bi se uspješno izradili modeli procjene pojave pomorskih nezgoda, potrebno je utvrditi stanja sustava koji se promatra. Kao cjelina brod se dijeli u više sustava. Jedna od cjelina je i dinamički sustav broda.

Struktura modela procjene rizika pomorskih nezgoda za različita stanja nije jednaka, a promatrati brod samo u jednom stanju bilo bi nepotpuno budući da brodovi u jednom danu koriste više stanja plovidbe, odnosno prelaze iz stanja u stanje. Stanja plovidbe mogu se podijeliti na željena stanja plovidbe i neželjena stanja (izvanredna stanja) koja mogu

rezultirati izvanrednim događajima sa štetnim posljedicama neposredne ugroze ljudskih života i imovine, odnosno pomorskim nezgodama.

Jedan od načina proučavanja sustava broda je korištenje metode za proučavanje složenih sustava s povratnim petljama – sistemske dinamike. Osnove ove metode postavio je Jay W. Forrester, 1960. godine. Sa stajališta sistemske dinamike sustav je skup elemenata kojima međusobni odnosi počivaju na određenim zakonima i načelima. Elementi sustava djeluju jedan na drugog s pomoću povratnih veza, tako da promjena jedne varijable utječe na promjene drugih, a one opet imaju utjecaj na promjenu izvorne varijable, itd. Sve promjene odvijaju se u vremenu.

Prema Zecu (2001) izvanredni događaji mogu se podijeliti na:

- događaje koji ne izazivaju štetne posljedice niti su ih mogli izazvati
- događaje koji nisu izazvali štetne posljedice, ali su ih mogli izazvati
- događaje koji su izravno ili neizravno izazvali štetne posljedice (gubitak ljudskih života, ugrožavanje zdravlja ljudi, materijalne štete na brodu, obali ili drugim objektima na moru ili kopnu, odnosno onečišćenje mora i priobalja bez obzira na trajanje i veličinu štete).

Zbog potrebe izrade modela procjene rizika pojave pomorskih nezgoda, stanja plovidbe podijeljena su na:

- stanja plovidbe (obalna plovidba, otvoreno more, plovidba kanalima i uskim prolazima te plovidba u luci)
- stanja mirovanja (vez u luci te boravak na sidrištu).

Podjela plovidbe[15] napravljena je po uzoru na DNV (2003) te je ista zajedno s ekspertnim mišljenjem o vremenu provedenom u svakom stanju, prikazana u tablici 2-1.

Ekspertno mišljenje je korišteno zbog manjkavosti podataka, odnosno nemogućnosti dobivanja podataka na temelju AIS praćenja. Vrijeme provedeno u željenim stanjima promjenjiva je veličina te je primjer prikazan u nastavku teksta napravljen na temelju srednje vrijednosti rezultata dobivenih ispitivanjem zapovjednika promatranih brodova na dan 1. kolovoza 2017. godine. Putnički brodovi u nelinijskoj plovidbi u 24-satnom periodu pola sata provedu u plovidbi u luci. Iz tog podatka dobiva se vrijednost: 1/24 = 0,041. Dalje, u plovidbi

[15] Podjela preuzeta od DNV studije za putničke brodove koji prevoze više od 2000 putnika.

provedu od 3 do 6 sati te se prema izračunu srednje vrijednosti dobiva: 4/24 = 0,16. Boravak na sidru jednak je 6/24 = 0,25, a vrijeme provedeno na vezu u luci iznosi 13/24 = 0,54.[16]

Tablica 2-1: Podjela plovidbe

OBALNA PLOVIDBA	OTVORENO MORE	PLOVIDBA KANALIMA I USKIM PROLAZIMA
ne postoje prepreke unutar 2 M u svim smjerovima	ne postoje prepreke unutar 5 M u svim smjerovima	ne postoje prepreke unutar 0,5 M u svim smjerovima
20 % ukupne dnevne plovidbe	60 % ukupne dnevne plovidbe	20 % ukupne dnevne plovidbe

Zec (2001) navodi kako je opće obilježje pomorskih nezgoda da nerijetko sadržavaju višestruke događaje, odnosno da jedna vrsta pomorske nezgode slijedi drugu pri čemu se u statističkim prikazima takvi događaji svrstavaju sukladno osnovnom događaju. Na slici 2-11 vidljiv je mogući slijed izvanrednog događaja „Nesposoban za manevriranje“. Brod se iz pojedinih neželjenih stanja može vratiti u željeno stanje, ali također postoji i mogućnost da se brod iz pojedinog neželjenog stanja prebaci u drugo neželjeno stanje. Tako je na slici 2-11 prikazana plovidba putničkog broda koji je prelazio iz željenog stanja „Vez u luci“ u željeno stanje „Plovidba kanalima i uskim prolazima“ te je iz željenog stanja prešao u neželjeno stanje „Nesposoban za manevriranje“ uslijed posljedice kvara na pogonskom stroju. Neželjeno stanje u prikazanom primjeru može izazvati dva posljedična stanja: u jednom će se nakon otklanjanja kvara stroja brod vratiti u željeno stanje „Plovidbe kanalima i uskim prolazima“, dok će u drugom prijeći u stanje pomorske nezgode nasukavanja. Valja naglasiti kako nije nužno da uslijed nemogućnosti otklona kvara stroja dođe do nasukavanja jer je, ovisno o okolnostima, moguće poduzeti određene radnje, primjerice: sidrenje broda, tegljenje od strane drugih brodova. Također, nasukavanje se ne mora dogoditi zbog određenih vremenskih uvjeta. Na slici 2-11 ranije navedene mogućnosti nisu prikazane, jer se pretpostavlja da poduzete radnje ili okolnosti nisu spriječile nasukanje broda.

[16] Navedeni podaci predstavljaju početne vrijednosti za modeliranje stanja plovidbe kod brodova koji noće vezani u luci.

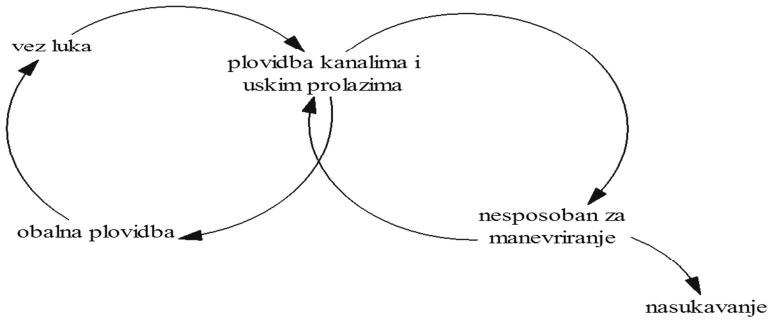

Slika 2-11: Primjer prelaska broda iz željenog u neželjeno stanje

Pomorska nezgoda promatranih brodova može se dogoditi dok je brod vezan u luci, dok je usidren te dok brod plovi.

Na slici 2-12 prikazani su mogući prelasci broda iz željenih u neželjena stanja, kao i prijelaz iz neželjenih stanja u pomorske nezgode ili neželjene događaje:

- kada je brod vezan u luci, moguća stanja prijelaza su: bolest putnika, čovjek u moru, požar i eksplozija te terorizam
- kada se brod nalazi na sidrištu, moguća stanja prijelaza su: bolest putnika, čovjek u moru, terorizam, nasukavanje, požar i eksplozija te udar
- kada brod plovi otvorenim morem, moguća stanja prijelaza su: bolest putnika, čovjek u moru, terorizam, požar i eksplozija, nesposoban za manevriranje, potonuće te sudar
- kada brod plovi uskim kanalima i prolazima, moguća stanja prijelaza su: bolest putnika, čovjek u moru, nesposoban za manevriranje, terorizam, nasukavanje, potonuće, požar i eksplozija, sudar te udar
- kada brod plovi obalnom plovidbom, moguća stanja prijelaza su: bolest putnika, čovjek u moru, terorizam, nesposoban za manevriranje, potonuće te sudar
- kada brod plovi u luci, moguća stanja prijelaza su: bolest putnika, čovjek u moru, terorizam, nesposoban za manevriranje, nasukavanje, požar i eksplozija, potonuće, sudar te udar.

Iz slike 2-12 je vidljivo da je najveći broj prijelaznih stanja moguć iz „Plovidbe u uskim kanalima i prolazima“ te „ Plovidba u luci“.

Iz stanja „Nesposoban za manevriranje“ moguće je vratiti se u svako početno željeno stanje, ali je moguće i prijeći u druga stanja. Stanja u koje se može prijeći su: nasukavanje, sudar i udar.

Iz stanja „Terorizam“, „Bolest putnika“ i „Čovjek u moru“ moguće se vratiti u svako početno željeno stanje. Iz stanja: „Požar i eksplozija“, „Nasukavanje“, „Sudar“ i „Udar“, koja su po definiciji pomorske nezgode, moguće je prijeći u stanje „Potonuća“.

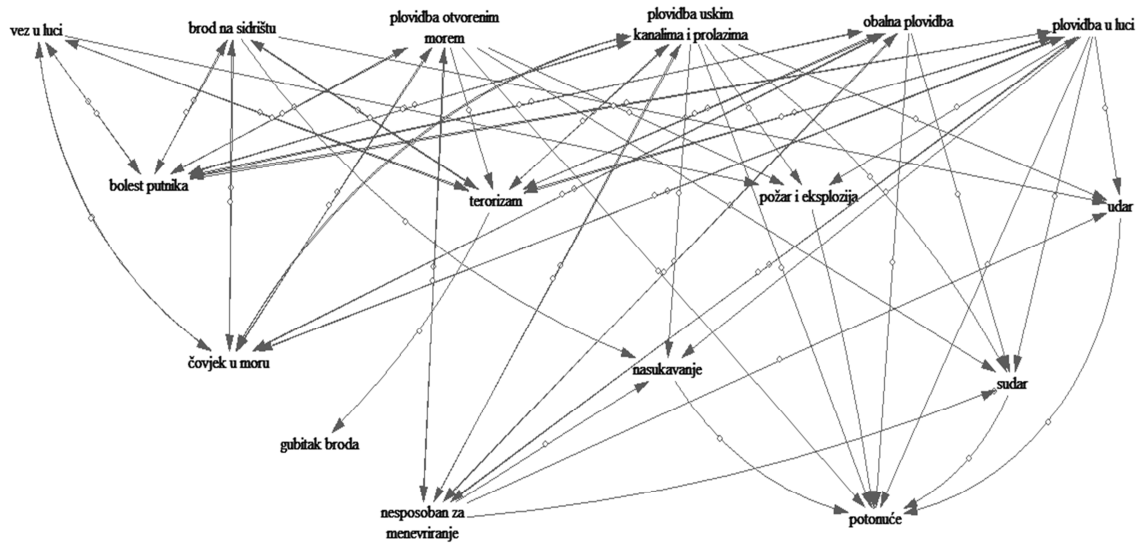

Slika 2-12: Moguća stanja plovidbe s prijelazima u neželjena stanja

Osim pomorskih nezgoda, odnosno neželjenih događaja, neželjena stanja koja se mogu dogoditi u stanjima plovidbe i stanjima mirovanja su: terorizam, bolest ili ozljeda. Navedena stanja su nepoželjna, ali ih ne zovemo pomorskim nezgodama budući da se brod nakon završetka neželjenih stanja može vratiti u željeno stanje.

2.5 Modeliranje pomorskih nezgoda

Model procjene rizika je sredstvo kojim se pretpostavlja slijed stvarnih događaja zbog donošenja odluka te učinkovitog utvrđivanja, analiziranja, planiranja, praćenja, upravljanja i opisa rizika (Peharda, 2004).

Prvi dio izrade modela procjene pojave pomorskih nezgoda: potonuća, udara, nasukavanja, sudar te požara i eksplozije baziran je na izboru samog scenarija. Za potrebe izrade navedenih modela neophodno je u prvoj fazi definirati generalne utjecajne čimbenike, primjerice gustoću i karakteristike pomorskog prometa na promatranom području, zatim hidrometeorološke prilike, karakteristike promatranih brodova te njihov način plovidbe. Autori Montewka i ostali (2014) također navode kako je za definiranje modela rizika neophodno definirati scenarij pomorske nezgode. Sukladno autorima, to je temeljna postavka o kojoj ovise svi ostali koraci u izradi. Navedeno pretpostavlja znanje o sustavu koji se promatra i ponašanju sustava u mogućim situacijama.

Za kvantitativno i kvalitativno modeliranje procjene rizika pomorskih nezgoda, izabrana je metoda bazirana na Bayesovom teoremu. Bayesova mreža je grafički model koji vizualizira uvjetovane odnose između različitih čimbenika te finalni ishod. Prikazuje fleksibilan pristup koji može biti kvalitativni i kvantitativni.

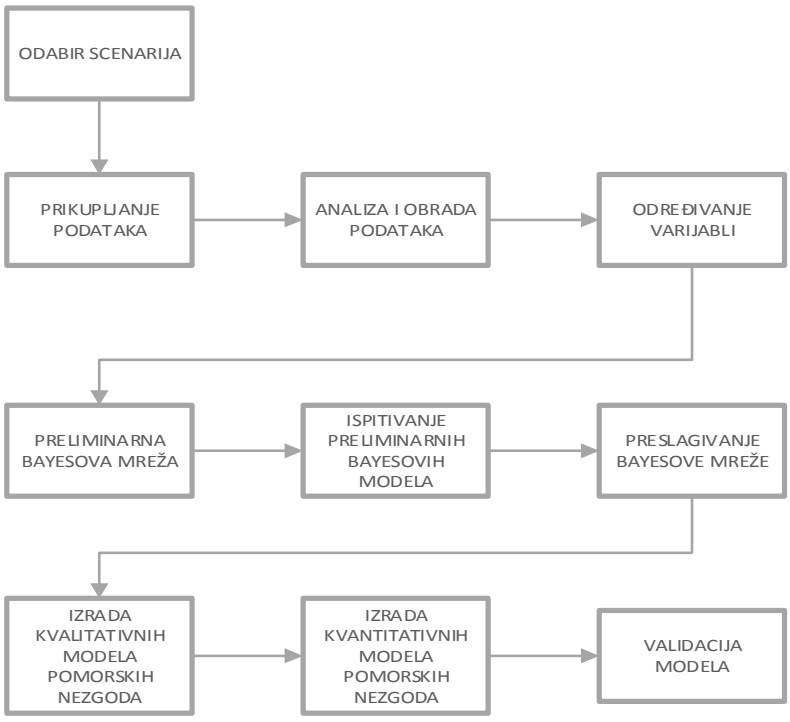

Slika 2-13: Metodologija izrade modela

Metodologija izrade modela korištena u ovom radu (Slika 2-13):

- Prvi korak je odabir scenarija modeliranja.
- Drugi korak u procesu izrade Bayesove mreže je prikupljanje podataka iz svih raspoloživih izvora: izvješća pomorskih nezgoda, baza podataka, statistički obrađenih podataka, simulacija, analitičkih modela itd.
- Treći korak je filtriranje, analiza i obrada prikupljenih podataka.
- Četvrti korak je određivanje i odabir utjecajnih čimbenika u modelima.
- Peti korak je stvaranje grafičke strukture preliminarne Bayesove mreže. Sukladno pravilima o izgradnji mreže, određuju se varijable u mreži (čvorovi), zatim se određuju mogući ishodi svih čvorova. Slijedi povezivanje čvorova te određivanje čvorova koje predstavljaju roditelje te čvorova koji su djeca. Određuju se veze između čvorova. Veze se stvaraju između čvorova utjecaja. Izabiru se korijenski čvorovi. Nadalje, određuju se združene vjerojatnosti ishoda u svakom pojedinom čvoru ovisno o njegovim roditeljima u mreži.
- Šesti korak predstavlja preslagivanje Bayesove mreže, odnosno suptilnije određivanje čimbenika utjecaja te preslagivanje strukture modela. Preslagivanje se vrši temeljem ekspertnog mišljenja i metodama testiranja. Ekspertima je prezentirana inicijalna struktura modela te je kasnije model prepravljen prema njihovim sugestijama. Nakon određivanja strukture modela, determiniran je kvantitativni dio modeliranja.
- Sedmi korak predstavlja izradu kvantitativnog modela za pomorske nezgode. Broj podataka potrebnih za kvantificiranje Bayesove mreže ovisi o strukturi mreže, broju varijabli i njihovih stanja. Tablice uvjetovanih vjerojatnosti za varijable izrađene su na temelju ekspertnog mišljenja i matematičkih pravila.
- Osmi korak predstavlja validaciju modela različitim tehnikama koje se koriste za testiranje Bayesovih modela (uspoređivanjem, analizom osjetljivosti, kvalitativnim testom modela, usporedbom rezultata modela sa stvarnim događajem).

3. BAYESOVE MREŽE

Bayesova mreža je naziv dobila po britanskom matematičaru Thomasu Bayesu *(1702.-1761.)* On je u svojem radu opisao matematičku formulu koja danas ima veliku važnost kod teorije vjerojatnosti. Iako je Thomas Bayes opisao formulu još u 18. stoljeću, formula je pravu primjenu doživjela tek u 20. stoljeću razvojem područja umjetne inteligencije (Perаić, 2012).

Bayes je pronašao zakone koji se ponešto razlikuju od klasičnog pristupa vjerojatnosti osmislivši matematičke postupke koji omogućuju mijenjanje vjerojatnosti nekog ishoda pod utjecajem novih informacija (Mršić, 2011).

Bayesove mreže su grafičke strukture za predstavljanje uvjetnih vjerojatnosti između velikog broja varijabli (atributa) te donošenje uvjetovanih zaključaka u vezi s navedenim varijablama (Pearl, 2000). Bayesova mreža je probabilistički grafički model koji predstavlja uvjetovane relacije između slučajnih varijabli i njihovih uvjetovanih ovisnosti (Finn and Thomas, 2007). Također, Bayesova mreža može se definirati kao usmjereni aciklički graf koji se sastoji od čvorova i bridova (Kjaerulff, Madsen, 2008). Svaki brid ima svoj početak i kraj (strelica). Čvorovi su slučajne varijable i prikazuju stanja, ali ne isključivo i događaj kao u primjerima stabala odlučivanja (Rausand, 2011) te predstavljaju faktore utjecaja na glavni problem. Bridovi predstavljaju direktni utjecaj (Rausand, 2011) i određuju neovisnu pretpostavku koja povezuje čvorove (Charniak, 1991).

Bayesove mreže mogu se koristiti za kvalitativnu i kvantitativnu analizu (Rausand, 2011).

Varijable u Bayesovim mrežama imaju diskretne vrijednosti koje odgovaraju vjerojatnostima (apriori ili uvjetnim).

Apriori vjerojatnost opisuje vjerojatnost nastanka događaja u slučaju nedostatka bilo koje druge informacije. Uvjetovana vjerojatnost opisuje vjerojatnost istinitosti u slučaju da su poznate dodatne informacije. Prije samog izračuna uvjetne i spojne vjerojatnosti, potrebno je utvrditi jesu li događaji zavisni, nezavisni ili su možda međusobno isključivi. Dva događaja su nezavisna ako bilo koji ishod jednog događaja ne utječe na vjerojatnost bilo kojeg drugog događaja. Spojna vjerojatnost nezavisnih događaja A i B jest produkt njihovih individualnih vjerojatnosti.

Čvor bez roditelja se zove korijenski čvor, prikazan čvorom A, dok je B dječji čvor (Slika 2-14).

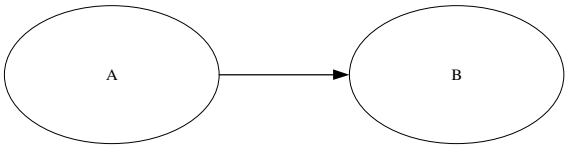

Slika 3-3-1: Roditeljski čvor A i dječji čvor B

Kao što je već navedeno, osnovni koncept Bayesovih mreža temelji se na pravilu vjerojatnosti događaja a i b koje glasi:

$$P(a\backslash b)P(b)=P(a,b). \quad (2)$$

Ako se događaji a i b promatraju u kontekstu događaja c, to se može izraziti kao:

$$P(a\backslash b,c)P(b\backslash c)=P(a,b\backslash c). \quad (3)$$

Na osnovi pravila uvjetovane vjerojatnosti proizlazi:

$$P(a\backslash b)P(b)=P(b\backslash a)P(a). \quad (4)$$

Iz čega proizlazi Bayesova formula:

$$P(b\backslash a)=\frac{P(a\backslash b)P(b)}{P(a)}. \quad (5)$$

Odnosno, ako se promatra događaj c slijedi:

$$P(b\backslash a,c)=\frac{P(a\backslash b,c)P(b\backslash c)}{P(a\backslash c)}. \quad (6)$$

Za izgradnju Bayesove mreže potrebno je definirati čvorove (varijable), moguće vrijednosti koje određeni čvor može poprimiti, veze između čvorova i vrijednosti uvjetnih vjerojatnosti u čvorovima. Odnosi između čvora roditelja i djeteta ukazuju da je za računanje distribucije vjerojatnosti djeteta potrebno poznavati određene vjerojatnosti roditelja. Svaki čvor u Bayesovoj mreži ima pripadajuću spojnu vjerojatnost, pa je stoga Bayesova mreža određena strukturom i vrijednostima (Grubišić, 2012).

Glavna obilježja Bayesove mreže:

- mogućnost da se do zaključka dođe inverznim putem, od kraja prema početku

- mogućnost da se u mrežu uključe nova opažanja
- vjerojatnosna semantika koja uključuje rad s podacima koji nedostaju ili su nepotpuni
- vizualno predočavanje izvornog slučaja i međusobnih efekata.

Broj vjerojatnosti potrebnih za probabilističku mrežu izravno ovisi o strukturi same mreže, točnije, što je mreža gušće povezana, to je potrebno više brojeva za kvantitativni račun. Reduciranje količine potrebnih podataka izvodi se promjenom grafičke strukture mreže ili korištenjem parametarske raspodjele vjerojatnosti.

Da bi se izgradila Bayesova mreža, potrebno je definirati čimbenike interesa (varijable) te odgovoriti na pitanja: koje varijable će biti stavljene u model, koje su njihove vrijednosti te u kojim stanjima se mogu naći. Prilikom izgradnje probabilističkog grafa, grafička struktura istoga je najvažnija jer prikazuje ovisnost i odnose između varijabli interesa. Struktura i topologija mreže mora sadržavati kvalitativne odnose između varijabli, odnosno dva čvora moraju direktno biti vezana ako jedan utječe na uvjetnost drugoga.

Mreža se sastoji od skupa čvorova koji prezentiraju slučajne varijable i od skupa veza koje spajaju te varijable (čvorove), prezentiranih u obliku strelica. Čvorovi su diskretne varijable, a veze prikazuju njihove odnose (Nielsen i ostali, 2007). Čvorovi u koje su uperene strelice zovu se djeca, a čvorovi od kojih strelice polaze zovu se roditelji. Za svaku varijablu A s roditeljem čvorom $B_{1.....,}B_n$ postoji veza od $B_{1....,}B_n$ prema A te za istu postoji tablica uvjetovane vjerojatnosti $P(A/B_{1....,}B_{n)}$ koja opisuje vjerojatnost svih kombinacija stanja A i B. Ako varijabla A nema roditelje, onda je bezuvjetno prikazana u tablici P(A). Ulazne vrijednosti tablice vjerojatnosti su parametri Bayesovog modela. Za svaki čvor potrebno je pregledati sve moguće kombinacije vrijednosti njegovih roditelja i napraviti tablicu uvjetovanih vjerojatnosti.

U svakom stupcu tablice uvjetovane vjerojatnosti vrijednosti vjerojatnosti se normaliziraju tako da budu u rasponu od 0 do 1. Zbog toga zbroj vjerojatnosti u svakom stupcu mora zadovoljavati broj jedan. Veličina uvjetovanih vjerojatnosti svake varijable eksponencijalno ovisi o veličini roditeljskih setova. Veličina tablice uvjetovane vjerojatnosti postaje velika ako joj je pridodano više čvorova što uzrokuje probleme s računanjem (Eleye-Datubo i ostali, 2006). Prema autorima Feng M. i ostali (2009) tablica uvjetovane vjerojatnosti čvora djeteta može postati neprihvatljivo velika te je informacije o utjecaju između varijabli za velike kompleksne modele teško opravdati.

Na slici 3-2 prikazan je primjer Bayesove mreže. Čvor X3 predstavlja korijensku varijablu. Tablica uvjetovane vjerojatnosti (Tablica 3-2) prikazuje kombinacije svih mogućih stanja korijenskih čvorova i djece umetanjem odgovarajuće vrijednosti vjerojatnosti p_i za svaku kombinaciju (Antão i ostali, 2009).

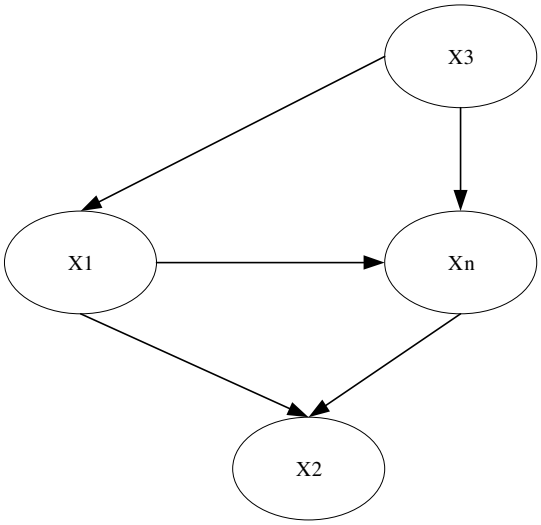

Slika 3-3-2: Primjer Bayesove mreže

(Antão i ostali, 2009)

Tablica 3-1: Primjer tablice uvjetovanje vjerojatnosti

(Antão i ostali, 2009)

				X1			
		DA				NE	
		X2				X2	
X3	DA		NE		DA		NE
DA	p1		p2		p3		p4
NE	1-p1		1-p2		1-p3		1-p4

Odnosi između čvora roditelja i djeteta ukazuju na to da je za računanje distribucije vjerojatnosti djeteta potrebno poznavati određene vjerojatnosti roditelja. Da bi model radio potrebno je:

- odrediti apriori vjerojatnosti za čvorove bez roditelja
- odrediti uvjetovane vjerojatnosti za sve čvorove s roditeljima, i to za sve moguće kombinacije i ishode roditelja.

Ako su roditelj i dijete međusobno nezavisne slučajne varijable, tada je moguće s lakoćom definirati vjerojatnost djeteta na temelju vjerojatnosti njegovih roditelja.

Korijenske varijable se postavljaju prve te se potom bridovima povezuju njihova djeca sve dok se ne dođe do krajnjih varijabli (tzv. varijabla list). Dva čvora trebala bi biti direktno povezana ako jedan utječe na uzrok drugoga, sa strelicom koja je uperena u smjeru utjecaja.

Nakon toga potrebno je definirati tablice uvjetovanih vjerojatnosti svake varijable. Veličina tablice uvjetovane vjerojatnosti ovisi o broju roditelja toga čvora.

4. ČIMBENICI UTJECAJA NA POMORSKE NEZGODE

Čimbenici utjecaja na pomorsku nezgodu mogu se definirati kao „događaji ili stanja sustava ili aktivnosti koji utječu na razinu rizika sustava ili aktivnosti“ (Øien, 2001).

Čimbenici utjecaja na pomorske nezgode mogu se podijeliti na: organizacijske, ljudske, vanjske i tehničke čimbenike te se uz pomoć Bayesove mreže može prikazati njihov međusobni utjecaj (Slika 4-1). Jedan čimbenik može utjecati na veći broj drugih čimbenika. Čimbenike utjecaja u Bayesovom modelu zovemo varijablama ili čvorovima. Pozicija varijabli te brojevi unutar mreže uneseni su prema subjektivnom mišljenju stručnjaka (Charniak) te sukladno tome može doći do razlika u zaključivanju.

Pomorstvo je složen socijalno-tehnički sustav koji je često pod utjecajem ekonomskih pritisaka. Čimbenici ljudskog faktora spadaju u znanstvenu disciplinu koja se bavi proučavanjem ljudskih mogućnosti (percepcije, psihičkog stanja itd.) te ograničenja istoga u odnosu na sustav (Koester, 2001). Pojam „ljudski faktor“ često se miješa s terminom „ljudska pogreška“. Prema Rausandu (2011) ljudska pogreška je netolerirana aktivnost ili devijacija od normalnog ponašanja čije su granice definirane sistemom te je kao takva direktan uzročnik pomorske nezgode. Prema Gordonu (1998) ljudski faktor je temeljni uzrok pomorske nezgode. Prema definiciji koju autorica koristi u svom radu, ljudski faktor sastoji se od organizacijskih, grupnih te individualnih čimbenika koji utječu na sigurnost. U ovom radu za neposredni uzrok pomorske nezgode uzrokovan ljudskim ponašanjem koristi se pojam „human error“ (ljudska pogreška).

U pomorstvu, nezgode uzrokovane ljudskom pogreškom su najzastupljenije. Dosadašnja istraživanja prikazuju kako je od 43 % do 96 % svih pomorskih nezgoda uzrokovano ljudskom greškom. Prema Kujala i ostali (2009) ljudski faktor uzrokuje 67,6 % pomorskih nezgoda nasukanja te 52,6 % pomorskih nezgoda sudara.

Hanninen (2008) objašnjava kako je kao uzročnik pomorskih nezgoda često zastupljen vanjski faktor. Pri tom ističe kako je stvaran uzrok pomorskih nezgoda nedovoljno dobra reakcija pomoraca naspram određenih loših vanjskih uvjeta.

Prema Hanninen (2008) tehnički su uređaji također konstruirani, napravljeni te održavani od strane ljudi pa se i oni trebaju smatrati ljudskom pogreškom.

Organizacijski čimbenici umanjuju rizik od pomorskih nezgoda budući da ljudi svojim iskustvom, znanjem te korištenjem sigurnosnih mjera mogu znatno umanjiti vjerojatnost za pojavu pomorskih nezgoda.

Prema Rausand (2011) tehnički čimbenici odnose se na opremu (*hardware, software*, konstrukcija broda). Općeprihvaćeno mišljenje je kako je 80 % pomorskih nezgoda uzrokovano ljudskim i organizacijskim faktorima dok je 20 % uzrokovano tehničkim faktorima (Shaluf i ostali, 2003).

Tehničke greške koje se odnose na gubitak pogona ili nemogućnost upravljanja brodom mogu direktno dovesti do pomorske nezgode nasukavanja ili sudara.

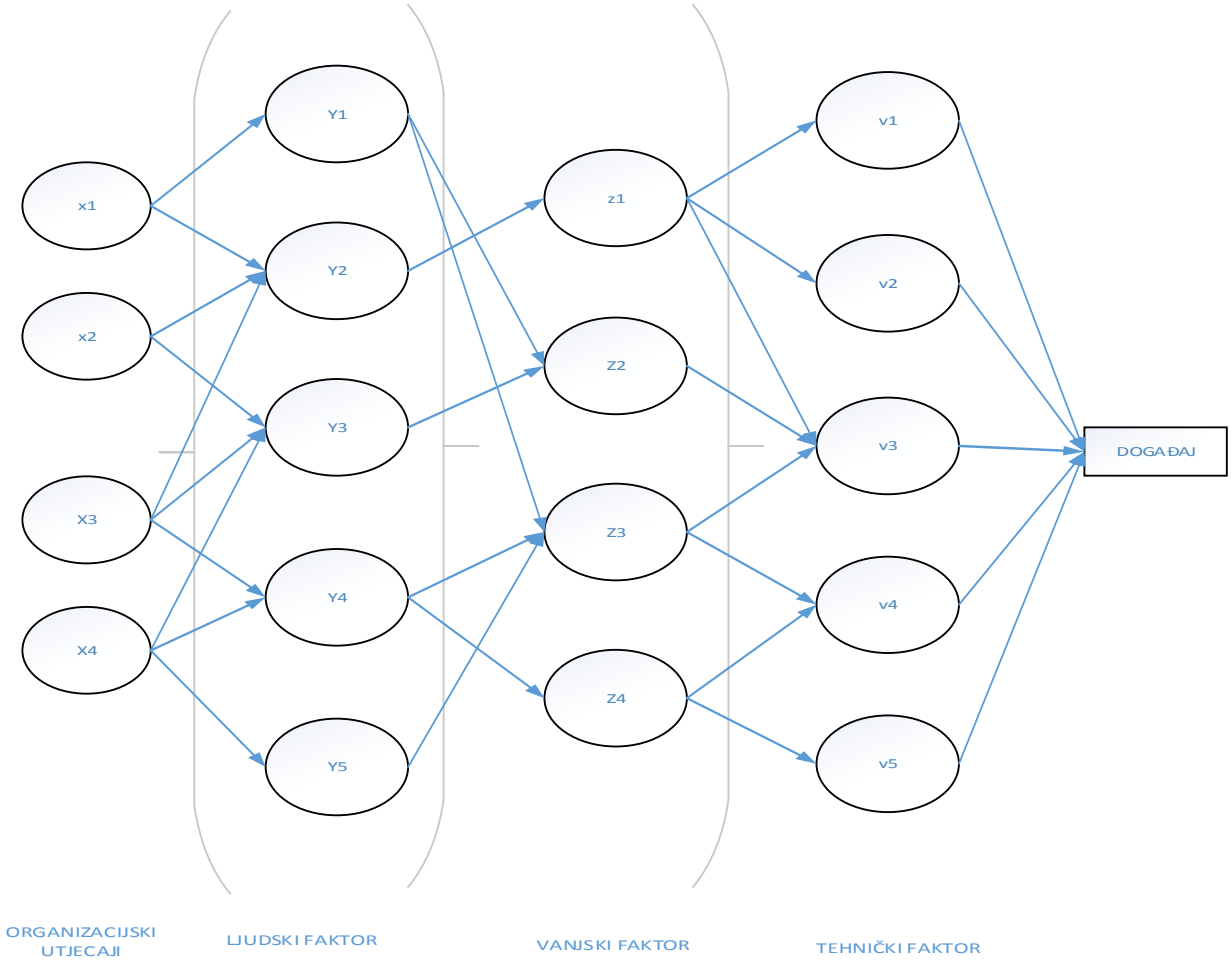

Slika 4-1: Osnovna podjela čimbenika utjecaja

Izrađeno prema Rausand (2011)

Nakon što se izaberu varijable utjecaja potrebno je odrediti stanja te vrijednosti koje varijable mogu poprimiti. Varijable (čvorovi u modelu) se prema stanjima koja mogu poprimiti dijele

na: *Boolean, Ordered i Integral. Boolean* čvorovi mogu poprimiti binarne vrijednosti (da, ne), *Ordered* čvorovi vrijednosti: nisko, srednje, visoko, dok *Integral* vrijednosti mogu poprimiti brojčane vrijednosti, primjerice, od 1 do 100.

Sukladno odabiru određene vrste varijabli već se u ranoj fazi izrade modela potonuća, udara, nasukavanja, sudara, požara i eksplozije odabiru i vrijednosti čvorova koje će imati veći utjecaj na rezultat modela. Primjerice, izborom vrijednosti varijable starost brodova 0 ─ 10, 11 ─ 20, 21 ─ 30, 31 ─ 40, 41 ─ 50 godina i 51 godina i više definiraju se vrijednosti koje su važne za model požara i eksplozije, skraćuje se tablica uvjetovanje vjerojatnosti, ali i dalje postoji dovoljno detalja koji su neophodni za odlučivanje.

Varijable u modelu možemo podijeliti prema pridodanim vrijednostima (Slika 4-2) na:

- varijable kojima su pridijeljene vrijednosti na temelju statističkih podataka
- varijable kojima nije moguće pridijeliti vrijednost na temelju statističkih podataka.

Tablica 4-1: Izabrane varijable utjecaja na pomorske nezgodu

Time	**Meteorology**	**Traffic distribution**	**Human factors**	**Vessel**	**Navigation in shallow waters**	**Spacial caution area**	**Error and Loss of control**
Day/night	Weather conditions	Nema posebnih podvarijabli utjecaja	Tired	Material	Nema posebnih podvarijabli utjecaja		Loss of control
Season	Weather		ISM Code	Age			Breakdown
Day	Sea state		Familiarization	Equipment			Human Error
Month	Wind force		Stress level	Navigation category			Navigational error
Hour	Wind direction		Incapacitated	Duration of cruising			Maintenance
	Visibility		Other distractions	Flag			Give away
	Fog		Non navigational tasks	Safety culture			Loss of control of other vessel

	Weather reports		Situational awareness	Visual detection			Passenger nonchalance
			Personal condition	Maintenance			Handling error
			Comunication with other vessel	AIS			Off course
				Radar			
				Vessel damage			
				Hull fractured			
				Flooding			
				Capsizing			
				Hull ruptured			
				Hull ruptured/construction demage			

Opaska: Izrazi u tablici namjerno su pisani engleskim jezikom jer je izvorni program koji se kasnije koristi u modelima na engleskom jeziku.

Tehnički, organizacijski, ljudski i vanjski čimbenici sadržavaju podvarijable. Pojedine podvarijable pojavljuju se u svim izrađenim modelima, pretežno su to podvarijable koje se odnose na ljudski faktor te na organizaciju. U tablici 4-1 prikazane su varijable korištene u modelima te njihove podvarijable.

Tehnički čimbenici odnose se na: materijal od kojeg je brod izgrađen, godinu izgradnje, opremu, kategoriju plovidbe, zastavu, vidljivost s mosta, AIS, radar, oštećenje broda, pukotine, naplavljivanje broda, proboj broda, prevrtanje, lom konstrukcije, tehničku grešku, gubitak kontrole drugog broda (može biti i ljudski čimbenik).

Organizacijske varijable odnose se na ISM pravilnik, familijarizaciju, druga ometanja, nenavigacijske zadatke, svjesnost o situaciji, komunikaciju s drugim brodom, održavanje broda.

Vanjski čimbenici sadržavaju varijable koje se odnose na meteorologiju, vrijeme, gustoću prometa, plovidbu u plitkom području te plovidbu u području posebnog opreza.

Ljudske varijable odnose se na gubitak kontrole, na ljudsku pogrešku, navigacijsku grešku, izbjegavanje (može biti i tehnički čimbenik), nemar putnika, pogrešku pri rukovanju, kada brod ne plovi po planiranom kursu (može biti i tehnički čimbenik), umor, ometanja osobe koja upravlja brodom, razine stresa, onesposobljenosti, svjesnost o situaciji, osobno stanje osobe koja upravlja brodom te sigurnosne kulture.

4.1 Izvori podataka

Prilikom izrade modela korišteni su podaci raznih izvora te mišljenja raznih eksperata kako bi se dobile vrijednosti i odnosi između varijabli.

Vrijednosti varijabli koje za izvor imaju statističke podatke pomorskih nezgoda putničkih brodova i pomorskih nezgoda svih brodova na hrvatskom dijelu Jadrana dobivene su na temelju analize podataka pomorskih nezgoda MMPI-a za razdoblje od 2011. do 2015. godine. Statistički podaci o pomorskim nezgodama prije navedenog razdoblja ne sadrže dovoljno potrebnih informacija te zbog toga nisu korišteni u radu. Zbog kratkog vremena promatranja te relativno malog broja određenih pomorskih nezgoda prilikom modeliranja u nekim su slučajevima korišteni podaci o pomorskim nezgodama svih vrsta brodova što je posebno napomenuto u opisima modela, dok su, kad god je to bilo moguće, korišteni statistički podaci pomorskih nezgoda putničkih brodova. Statistički podaci o putničkim brodovima u nelinijskoj obalnoj plovidbi nisu dostupni. Navedena kategorija brodova se u bazama podataka MMPI-a ne pojavljuje. Podaci o pomorskim nezgodama brodova koji nisu isključivo nelinijski putnički brodovi korišteni su tamo gdje je smatrano da se mogu primijeniti u modelu, a rezultati modela su dodatno validirani kako bi se provjerio utjecaj korištenih podataka na krajnji rezultat. Podaci koji se odnose na karakteristike putničkih nelinijskih brodova dobiveni su iz baze podataka Hrvatskog registra brodova. Izvori podataka za vrijednosti varijabli dobivenih iz hrvatskih baza podataka prikazani su na slici 4-2.

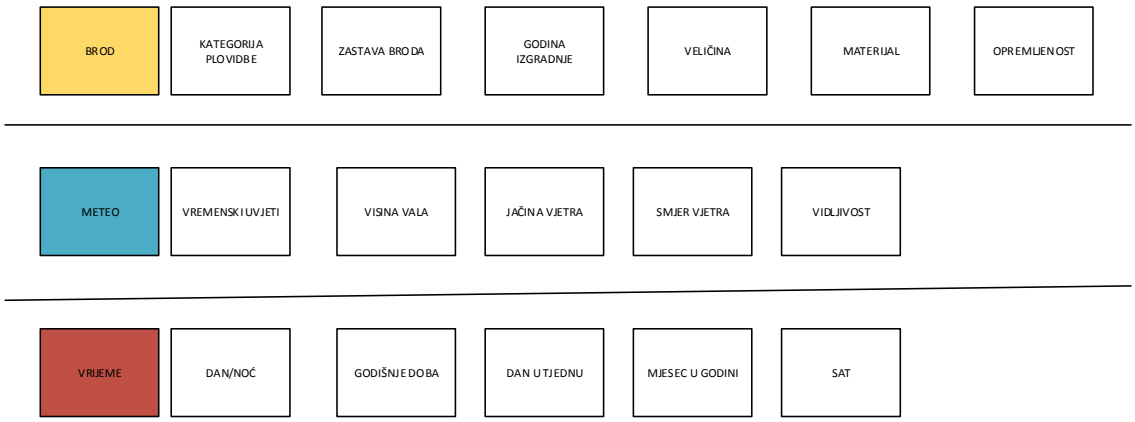

Slika 4-2: Varijable čije su vrijednosti dobivene statističkom obradom

Statistički podaci pomorskih nezgoda te izvještaja pomorskih nezgoda su korišteni kada je to bilo moguće. U nedostatku istih korišteni su statistički podaci sličnih brodova u situacijama kada se njihov način plovidbe poklapao s načinom plovidbe promatranih brodova. U situacijama kada su statistički podaci nedostupni, koristilo se mišljenje eksperata koji su metodom intervjua određenim varijablama dodjeljivali vrijednosti. Neki su od eksperata bili izravno uključeni u proces provjere modela kako bi se vršila kontrola strukture Bayesove mreže da bi se, osim logičkih pravila, kontrolirali i utjecajni čimbenici koji se odnose na plovidbu promatranih brodova. Eksperti su bili izravno uključeni i u proces izrade tablica uvjetovanih vjerojatnosti.

U izvještajima o pomorskim nezgodama postoji velik broj podataka koji su međusobno povezani, no unatoč tomu gotovo ih je nemoguće izravno implementirati u probabilističku mrežu. Stoga je potrebno znanje i iskustvo stručnih ljudi za procjenu vjerojatnosti, ali i za usklađivanje vjerojatnosti dobivenih iz drugih izvora koje je potrebno prilagoditi specifičnom području ili situaciji. S druge strane, problem procjene eksperata može biti njihova pristranost i nemogućnost da se njihovi podaci savršeno kalibriraju.

Uzroci pojave pomorskih nezgoda u ovome radu obrađeni su kvalitativno i kvantitativno koristeći ekspertno znanje intervjuiranjem ili direktnom komunikacijom s ekspertima u procesima izrade Bayesovih mreža.

Ekspertima su objašnjeni osnovni pojmovi uvjetovane vjerojatnosti te principi izrade Bayesovih mreža. Objašnjena su im pripremljena pitanja te razlozi njihova postavljanja kao i razlozi važnosti njihovih odgovora. Eksperti su u radu sudjelovali dobrovoljno i anonimno u svrhu prikupljanja što vjerodostojnijih informacija. Jedanaest eksperata je sudjelovalo u ovome radu, muških osoba starosti od 24 do 59 godina. Svi eksperti su imali iskustva u

pomorskom prometu od 3 do 30 godina. Dva eksperta imaju iskustvo rada kao VTS operatori, četiri eksperta su aktivni zapovjednici promatranih brodova, tri eksperta su kapetani lučkih ispostava u lukama koje koriste promatrani brodovi te je jedan ekspert inspektor sigurnosti plovidbe. Jedan ekspert je znanstvenik u polju tehnologije prometa i transporta, te je vrlo dobro upoznat s konceptom vjerojatnosti i Bayesovim mrežama, dok su ostali sudionici imali prema vlastitim iskazima malo znanja u uvjetovanoj vjerojatnosti i probabilističkim mrežama. Svi eksperti su hrvatski državljani, a zapovjednici brodova su u trenutku sudjelovanja u radu bili zaposleni na putničkim brodovima u nelinijskoj obalnoj plovidbi.

Eksperti su sudjelovali u:

- izradi Bayesove mreže
- preslagivanju Bayesove mreže kao i u dodjeljivanju vrijednosti tablicama uvjetovane vjerojatnosti
- dodjeljivanju vrijednosti nekih korijenskih varijabli
- analizi osjetljivosti modela.

Statistički podaci dobiveni su od Ministarstva mora, prometa i infrastrukture, Državnog zavoda za statistiku, Hrvatskog registra brodova, Državnog hidrometeorološkog zavoda te Hrvatskog hidrografskog instituta.

Varijable koje se odnose na ljudski faktor i dio organizacijskih varijabli koje su općenite, preuzete su iz drugih izvora (DNV, 2003., Mazaheri, Montewka, Kujala, 2016.).

Podaci koji se odnose na vremenske čimbenike (dan/noć, godišnje doba, dan u tjednu, sat nastupanja pomorske nezgode) dobiveni su statističkom obradom podataka MMPI-a. Podaci se odnose na vrijeme pojavljivanja pomorskih nezgoda putničkih brodova od 2011. do 2015. godine.

Podaci koji se odnose na hidrometeorološke čimbenike (vremenski uvjeti, pojava, stanje mora, smjer vjetra, vidljivost i magla) dobiveni su statističkom obradom podataka MMPI-a. Podaci se odnose na hidrometeorološke uvjete koji su prethodili pomorskim nezgodama putničkih brodova od 2011. do 2015. godine. Varijabla „Praćenje meteoroloških upozorenja“ dobivena je ekspertnim mišljenjem, intervjuiranjem zapovjednika putničkih brodova u nelinijskoj plovidbi koji plove u promatranom području s iskustvom plovidbe na promatranim brodovima, osoba zaposlenih u lučkim kapetanijama koje obavljaju poslove vezane za sigurnost prometa i VTS službenika koji vrše nadzor promatranog područja.

Podaci koji se odnose na gustoću prometa preuzeti su iz Prometno-plovidbene studije Pomorskog fakulteta u Rijeci iz 2014. godine.

Podaci koji se odnose na čimbenike ljudskog faktora koji utječu na pomorske nezgode većinom su preuzeti iz drugih studija i znanstvenih istraživanja (umor, familijarizacija, razina stresa, onesposobljenost, druga ometanja, nenavigacijski zadaci, svjesnost o situaciji, osobno stanje, komunikacija s drugim brodom) osim varijable „ISM pravilnik“ čije su vrijednosti dobivene od eksperata.

Podaci koji se odnose na varijable tehničko-tehnoloških obilježja promatranih brodova dobiveni su:

- statističkom analizom baze podataka putničkih brodova Hrvatskog registra brodova (materijal od kojeg je brod izgrađen, godina izgradnje, opremljenost, kategorija plovidbe) te dijelom statističkom analizom podataka o pomorskim nezgodama MMPI-a (zastava)
- dijelom iz radova drugih autora i studija (vidljivost s mosta)
- dijelom od eksperata (trajanje plovidbe putničkih brodova, sigurnosna kultura, održavanje broda, AIS, radar, oštećenje broda, pukotine, naplavljivanje, lom konstrukcije, proboj trupa).

Podaci koji se odnose na plovidbu u plitkom području i području posebnog opreza dobiveni su intervjuiranjem zapovjednika promatranih brodova.

Podaci koji se odnose na varijable pogrešaka i gubitaka kontrole temelje se na mišljenju eksperata (gubitak kontrole, tehnička pogreška, ljudska pogreška, navigacijska pogreška, izbjegavanje, gubitak kontrole drugog broda, greška drugog broda, nemar putnika, pogreška u rukovanju). Neke su varijable slične drugima, no te su namjerno izabrane kako bi se postigla veća osjetljivost modela i kvalitetniji rezultat. Zbog potrebe modela u ovom radu neke su pomorske nezgode prikazane kao varijable.

4.2 Vrijeme pojave pomorskih nezgoda

Statističkom analizom te ekspertnom procjenom utvrđena je povezanost pomorskih nezgoda i vremena. Dnevna ili noćna navigacija, godišnje doba, mjesec u godini i određen dan u tjednu te sat u danu povećavaju ili smanjuju mogućnost pojave pomorske nezgode. U tablici 4-2

prikazani su nazivi čvorova, vrste čvorova, broj stanja koja čvorovi mogu poprimiti te skraćeni nazivi čvorova.

Tablica 4-2: Preliminarne vrijednosti čimbenika vremena

Ime čvora	Vrsta	Vrijednosti	Naziv
Day/night	Boolean	2	V1
Season	Boolean	2	V2
Day	Integral	7	V3
Month	Integral	12	V4
Hour	Integral	24	V5

Dan/noć

Varijabla naziva „Dan/noć“ *(Day/night)* označava vrijeme događaja pomorske nezgode.
Stanja koja može poprimiti varijabla „Dan/noć“ su:

- dan
- noć.

Statističkom obradom dobiven je broj pomorskih nezgoda za vrijeme dana ili noći. Kod putničkih turističkih brodova rizik pojave pomorske nezgode veći je za vrijeme dana, budući da su promatrani brodovi aktivniji po danu. Unatoč boljoj vidljivosti dnevne sate karakterizira: veća aktivnost na moru, povećana gustoća plovidbe, više brodova u područjima posebnog opreza, više brodova na sidrištima te više brodova koje vrše aktivnosti priveza i odveza u lukama.

Noćna navigacija je zahtjevnija, pogotovo u područjima jako razvijene obale, ali noćnu navigaciju karakterizira znatno manji broj brodova na uobičajenim rutama i znatno manji broj brodova u područjima opasnijim za navigaciju, a kretanje u lukama umanjeno je u odnosu na dnevne aktivnosti brodova.

Vrijednosti za varijablu „Dan/noć“ dobivene su računanjem broja sati dnevne svjetlosti u odnosu na 24 sata.

Budući da se mogućnost pojave pomorske nezgode promatra tijekom cijele godine, određen je broj sati dnevnog svjetla za 4 godišnja doba i to: 15. siječnja, 15. travnja, 15. lipnja te 15. listopada – prema uzoru na referencu (Hanninen, Kujala 2012).

Na slici 4-4 prikazane su pomorske nezgode putničkih brodova za vrijeme dana i noći.

Tablica 4-3: Podjela dana i noći prema godišnjim dobima

Izvor: http://astrogeo.geoinfo.geof.hr/online_efemeride/sunrise_sunset/

15. siječnja	15. travnja	15. lipnja	15. listopada
Izlazak: 07:24	Izlazak: 06:12	Izlazak: 05:28	Izlazak: 07:08
Zalazak: 16:44	Zalazak: 19:38	Zalazak: 20:32	Zalazak: 18:10
Trajanje dana: 09:20	Trajanje dana: 13:24	Trajanje dana: 15:03	Trajanje dana: 11:03

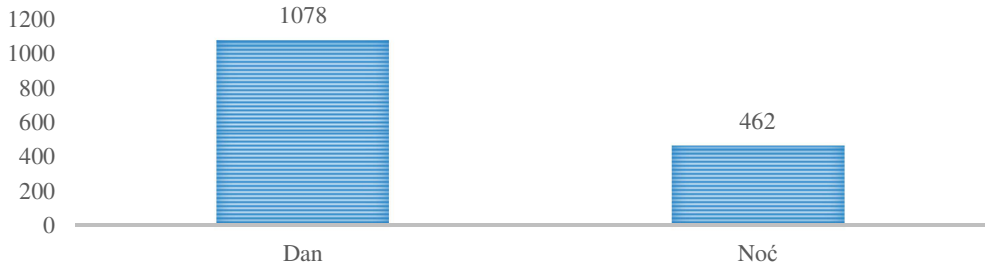

Slika 4-3: Prikaz broja pomorskih nezgoda svih brodova ovisno o dobu dana od 2011. do 2015. godine

Izvor: Izrađeno prema podacima MMPI-a

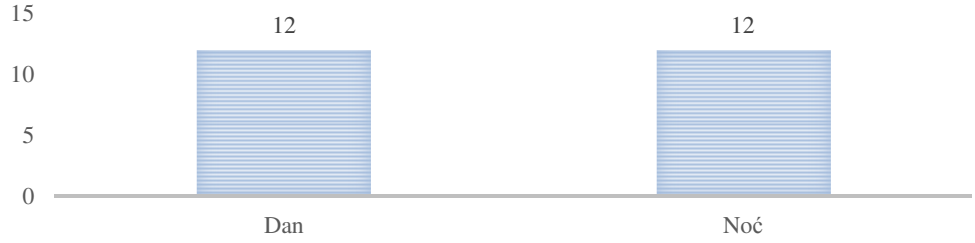

Slika 4-4: Prikaz broja nezgoda putničkih brodova u vrijeme dana i noći od 2011. do 2015. godine

Izvor: Izrađeno prema podacima MMPI-a

Podijelivši dan i noć prema tablici 4-3 dobivene su vrijednosti za varijablu „Dan/noć“ za sve pomorske nezgode u razdoblju od 2010. do 2015. godine[17] (Slika 3-3), te za pomorske nezgode putničkih brodova[18] (Slika 4-4).

Godišnje doba

Varijabla naziva „Godišnje doba“ (*Season*) prikazuje je li se pomorska nezgoda dogodila u ljetnom ili zimskom razdoblju. Ljetnim razdobljem smatra se razdoblje od 1. travnja do 31. listopada.

Stanja koja može poprimiti varijabla „Godišnja doba“ su:

- ljeto
- zima.

Ljetni period karakteriziraju bolji vremenski uvjeti, ali i povećana gustoća prometa, dok zimski period obilježavaju znatno lošiji vremenski uvjeti i smanjena gustoća pomorskog prometa.

[17] 113 pomorskih nezgoda nije uvršteno u analizu zbog manjka podataka o vremenu nastupanja pomorske nezgode.

[18] 5 pomorskih nezgoda nije uvršteno u analizu zbog manjka podataka o vremenu nastupanja pomorske nezgode.

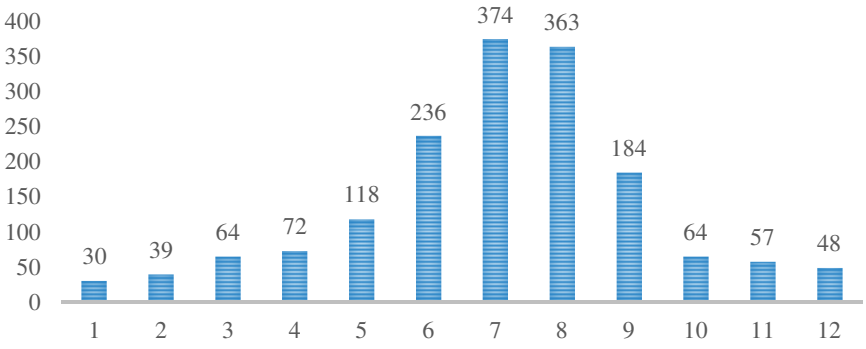

Slika 4-5: Broj pomorskih nezgoda za sve brodove od 2011. do 2015. godine

Izvor: Prema podacima MMPI-a

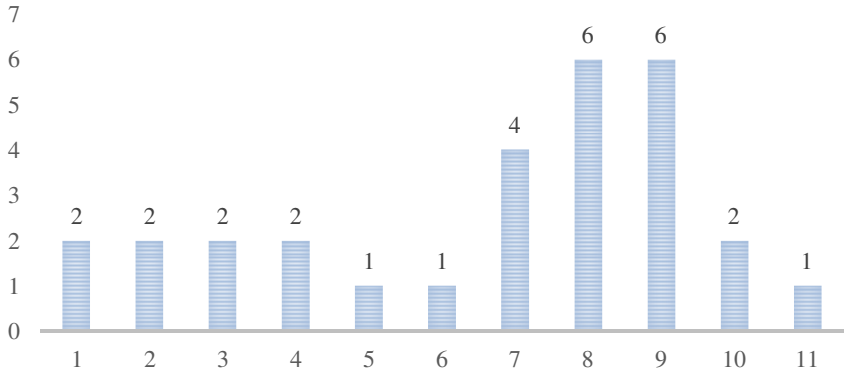

Slika 4-6: Broj pomorskih nezgoda putničkih brodova od 2011. do 2015. godine

Izvor: Izrađeno prema podacima MMPI-a

Varijabla godišnje doba u modelima procjene rizika pomorskih nezgoda prikazanim u ovom radu utječe na gustoću prometa.

Mali putnički brodovi ploveći u zimskom razdoblju nerijetko su izloženi nepovoljnim vremenskim prilikama te se zimska plovidba smatra opasnijom (Slika 4-6). Usporedivši omjer broja malih putničkih brodova i pomorskih nezgoda zimi i ljeti, uočeno je kako su zimi pomorske nezgode učestalije.

Varijabla „Godišnje doba“ korijenska je varijabla. Vrijednosti za varijablu dobivene su analizom statističkih podataka MMPI-a.. Zimsko vrijeme mogu karakterizirati i povoljni hidrometeorološki uvjeti, stoga je u kvantitativnim modelima sudara i nasukavanja varijabla „Godišnje doba“ postavljena kao roditelj varijabli „Gustoća prometa“, a ne varijabli „Vremenski uvjeti“.

Dan u tjednu

Varijabla naziva „Dan u tjednu“ *(Day)* odnosi se na povezanost vjerojatnosti pojave pomorske nezgode i dana u tjednu. Dan u tjednu utječe na veću gustoću prometa u određenim područjima.

Stanja koja može poprimiti varijabla su:

- ponedjeljak (1)
- utorak (2)
- srijeda (3)
- četvrtak (4)
- petak (5)
- subota (6)
- nedjelja (7).

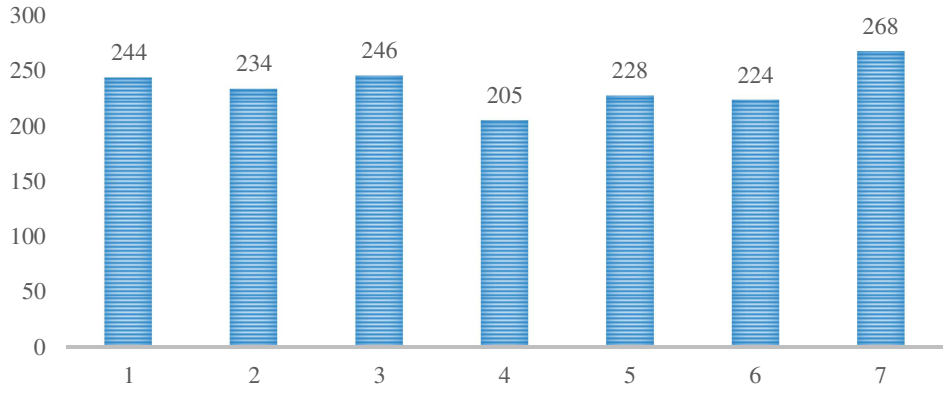

Slika 4-7: Broj pomorskih nezgoda u ovisnosti o danu u tjednu kroz cijelu godinu od 2011.do 2015. godine

Izvor: Izrađeno prema podacima MMPI-a

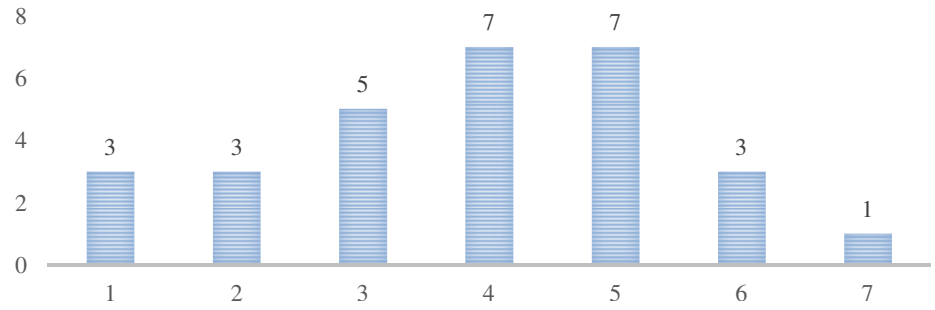

Slika 4-8: Broj pomorskih nezgoda putničkih brodova u ovisnosti o danu u tjednu kroz cijelu godinu od 2011. do 2015. godine

Izvor: Izrađeno prema podacima MMPI-a

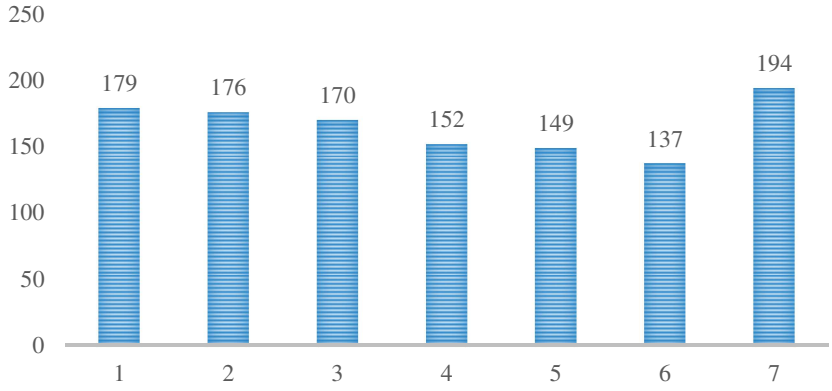

Slika 4-9: Broj pomorskih nezgoda u ovisnosti o danu u tjednu u ljetnom razdoblju za sve vrste brodova od 2011. do 2015. godine

Izvor: Izrađeno prema podacima MMPI-a

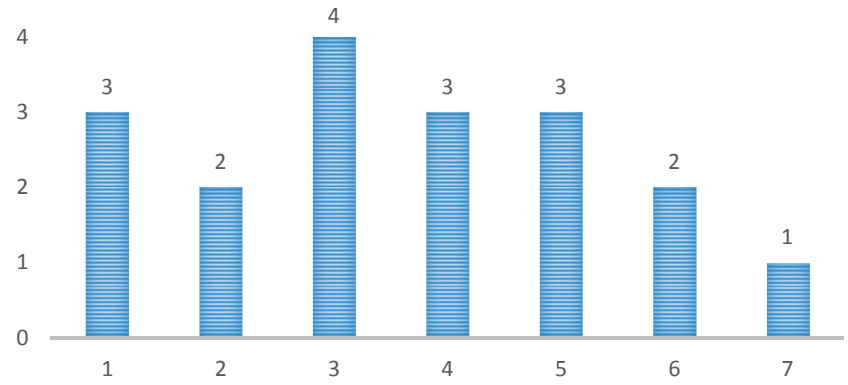

Slika 4-10: Broj pomorskih nezgoda u ovisnosti o danu u tjednu u ljetnom razdoblju za putničke brodove od 2011. do 2015. godine

Izvor: Izrađeno prema podacima MMPI-a

Promatrajući pomorske nezgode u ljetnom razdoblju vidljivo je da se kod putničkih brodova najveći broj pomorskih nezgoda događa početkom i sredinom tjedna, a najmanji broj nedjeljom.

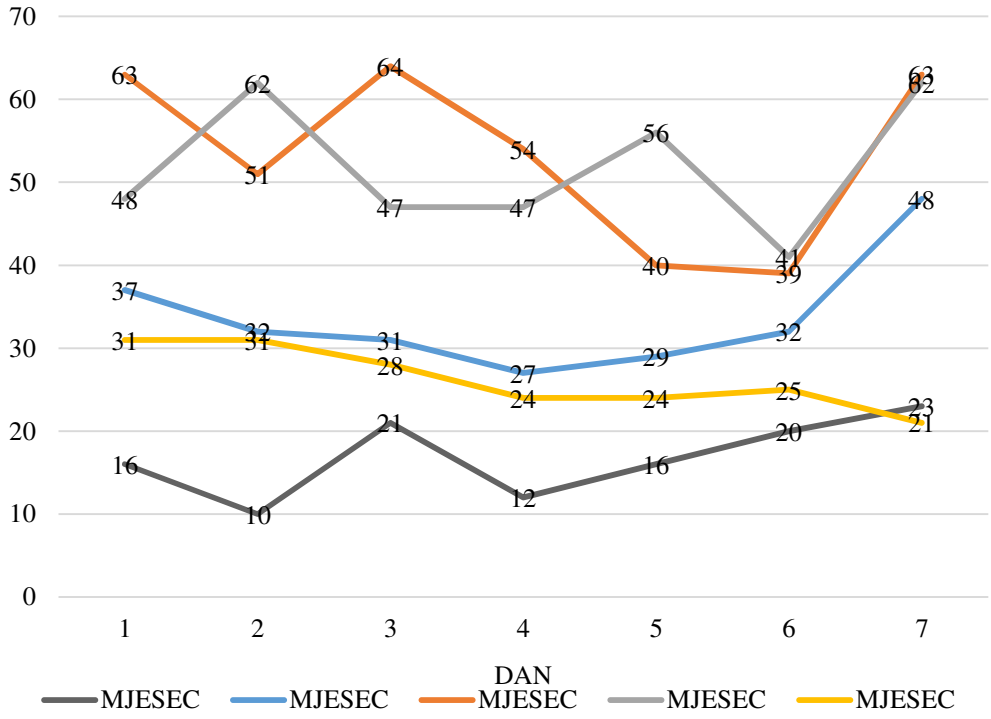

Slika 4-11: Prikaz pomorskih nezgoda svih brodova od 5. do 9. mjeseca prema danima u tjednu

Izvor: Izrađeno prema podacima MMPI-a

Varijabla „Dan u tjednu“ u modelima pomorskih nezgoda prikazanim u ovom radu utječe na gustoću prometa. Nerijetko se događa da promatrani brodovi imaju slične plovidbene rute te da pojedine luke imaju velike oscilacije opterećenosti. Dan u tjednu utječe i na gustoću prometa u područjima posebne opasnosti (Splitska vrata, prilaz Gradskoj luci, itd.).

Vrijednosti za varijablu „Dan u tjednu” dobiveni su statističkom obradom podataka MMPI-a.

Sat nastupanja pomorske nezgode

Varijabla naziva sat „Sat nastupanja pomorske nezgode“ (*Time of accident)* prikazuje doba dana kada je mogućnost za pojavu pomorske nezgode najveća.

Stanja koja može poprimiti varijabla „Sat nastupanja pomorske nezgode“ su:

- 00:00 - 00:59
- 01:00 - 01:59
- 02:00 - 02:59
- 03:00 - 03:59
- 04:00 - 04:59
- 05:00 - 05:59
- 06:00 - 06:59
- 07:00 - 07:59
- 08:00 - 08:59
- 09:00 - 09:59
- 10:00 - 10:59
- 11:00 - 11:59

- 12:00 - 12:59
- 13:00 - 13-59
- 14:00 - 14:59
- 15:00 - 15:59
- 16:00 - 16:59
- 17:00 - 17:59
- 18:00 - 18:59
- 19:00 - 19:59
- 20:00 - 20:59
- 21:00 - 21:29
- 22:00 - 22:59
- 23:00 - 23:59

U statističkim podacima MMPI-a ne navodi se vrijeme pomorske nezgode, već vrijeme kada je započela akcija spašavanja tako da je je prilikom modeliranja vrijeme početka akcije uzeto kao približno vrijeme nastupanja pomorske nezgode. Analizom podataka dobiveno je vrijeme u kojem se događa najveći broj pomorskih nezgoda putničkih brodova, a to je između 11:00 i 12:00 sati te između 17:00 i 18:00 sati (Slika 4-13).

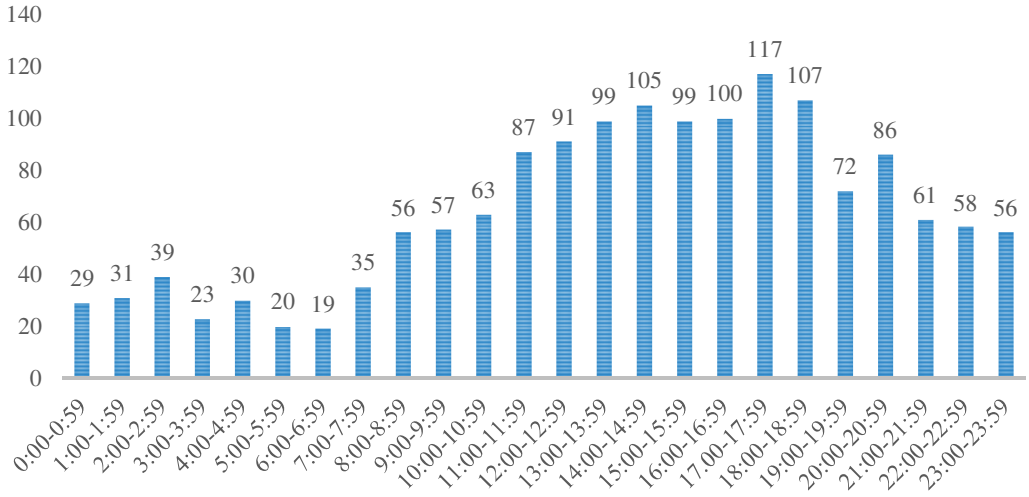

Slika 4-12: Vrijeme početka akcije spašavanja za sve kategorije brodova na Jadranu od 2010. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

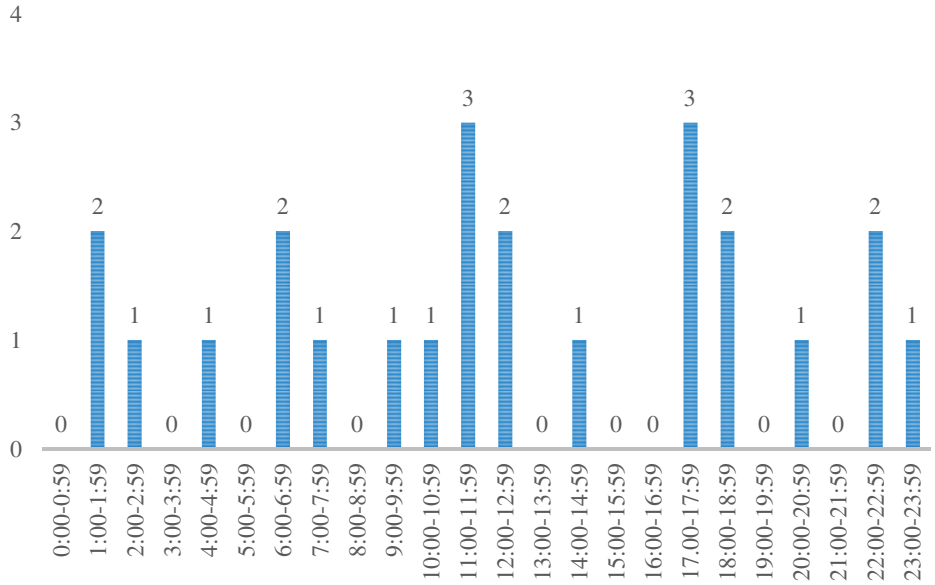

Slika 4-13: Vrijeme početka akcije spašavanja za putničke brodove na Jadranu od 2010. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

Napomena: u statističkim podacima MMPI-a putnički brodovi u nelinijskoj obalnoj plovidbi nisu posebno obrađeni te se za izračun početka akcije putničkih turističkih brodova uzima vrijeme početka akcije svih putničkih brodova.

Mali putnički brodovi namijenjeni za višednevna putovanja najčešće noće u lukama, u jutarnjim satima kreću prema sljedećoj luci, sa zaustavljanjima tijekom dana, odnosno sidrenjem ili pristajanjem na nekom turističkom lokalitetu (plaža, prirodna znamenitost itd.).

Zbog mnogobrojnih stanja koja ima varijabla „Sat nastupanja pomorske nezgode“ te utjecaja na veličinu tablice uvjetovane vjerojatnosti, ova varijabla nije korištena u modelima procjene pojave pomorskih nezgoda.

Vrijednosti za varijablu „Sat nastupanja pomorske nezgode“ dobiveni su od MMPI-a.

4.3 Hidrometeorološke prilike

Čimbenici hidrometeoroloških utjecaja prikazuju ovisnost vremenskih prilika i pojave pomorske nezgode kod malih putničkih brodova.

Promatrani brodovi najčešće plove od travnja do listopada. U razdoblju koje na Jadranu karakteriziraju uglavnom dobre vremenske prilike, no za Jadran su karakteristične česte

promjene vremena s obzirom na klimatska obilježja i orografske karakteristike jadranskog otočja i priobalja. Nagle promjene vremena u vidu naglog pogoršanja, tzv. nevere, predstavljaju mogući rizik za pojavu pomorske nezgode. Za vrijeme olujnog nevremena koje se događa i u ljetnim mjesecima, pri ljetnim depresijama tlaka dolazi do velikog rizika i za brodove koji su na sidru. Karakteristike olujnog nevremena su iznenadne i brze promjene meteoroloških elemenata: smjera i brzine vjetra, visine vala, tlaka zraka, temperature zraka, naoblake i vlage. Često dolazi do grmljavine, tuče i pijavice.

Statistička obrada podataka pokazuje da se većina pomorskih nezgoda na Jadranu dogodila za vrijeme vedrog dana pri mirnom moru te pri odličnoj vidljivosti. Važno je napomenuti kako je u slučajevima kada se pomorska nezgoda dogodila za vrijeme puhanja vjetra to bio vjetar iz NE smjera.

Vrijednosti za varijablu meteorologije dobivene su iz statističke obrade uvjeta za vrijeme pomorskih nezgoda od 2011. do 2015. godine

Tablica 4-4: Preliminarne vrijednosti meteoroloških čimbenika utjecaja

Ime čvora	Vrsta	Vrijednosti	Ime
Weather conditions	Boolean	2	M1
Weather	Integral	4	M2
Sea state	Integral	5	M3
Wind force	Integral	6	M4
Wind direction	Integral	3	M5
Visibility	Integral	5	M6
Fog	Boolean	2	M7
Weather reports	Boolean	2	M8

Vremenski uvjeti

Varijabla naziva „Vremenski uvjeti“ (*Weather conditions)* opisuje meteorološka stanja za promatranu skupinu brodova koji povećavaju rizik od pojave pomorske nezgode ovisno o veličini broda i konstrukciji za promatrano područje.

Stanja koja može poprimiti varijabla su:

- da (dobro vrijeme, dobra vidljivost bez kritične brzine vjetra i kritične visine vala u odnosu na karakteristike broda)
- ne (nevrijeme, kiša, magla, jaki vjetrovi, srednje dobra do loša vidljivost, kritična visina vala u odnosu na karakteristike broda).

Vrijednosti za varijablu naziva „Vremenski uvjeti“ dobiveni su obradom statističkih podataka MMPI-a.

Pojava

Varijabla naziva „Pojava“ (*Weather)* opisuje meteorološku pojavu za vrijeme pomorske nezgode. U kvantitativnim modelima sudara i nasukavanja varijabla je postavljena kao korijenska i njene vrijednosti su podaci o pojavi na moru u vremenu nastupanja pomorske nezgode malih putničkih brodova.

Stanja koja može poprimiti varijabla „Pojava“ su:

- vedro
- djelomično oblačno
- oblačno
- kiša.

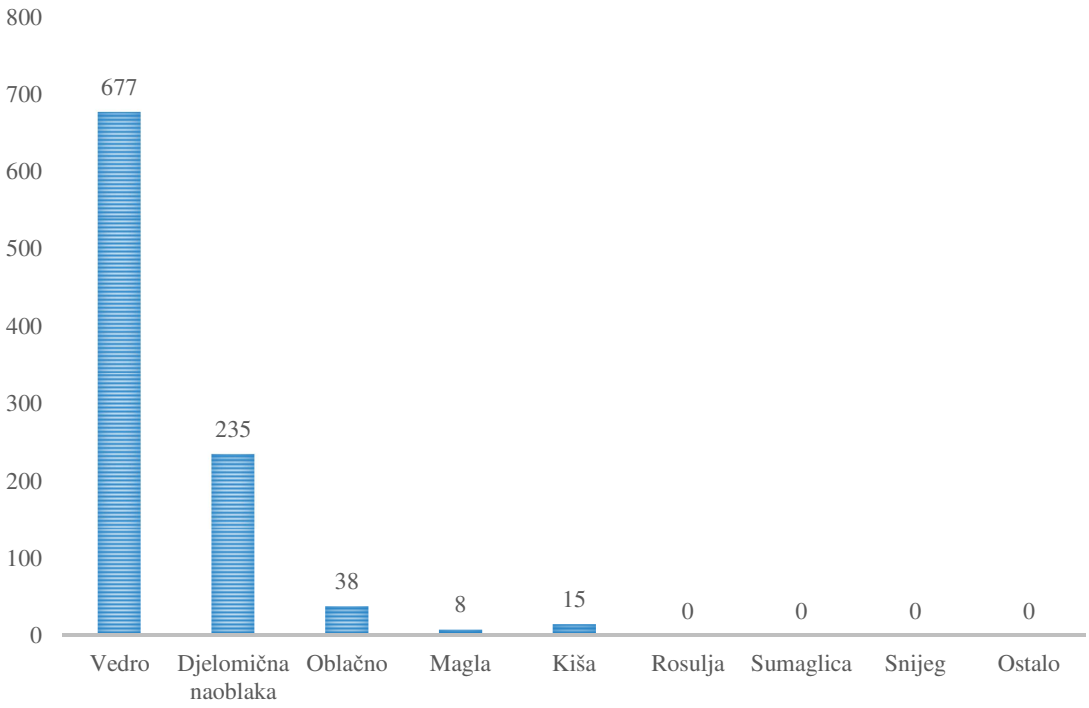

Slika 4-14: Pojava za vrijeme pomorske nezgode svih brodova od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

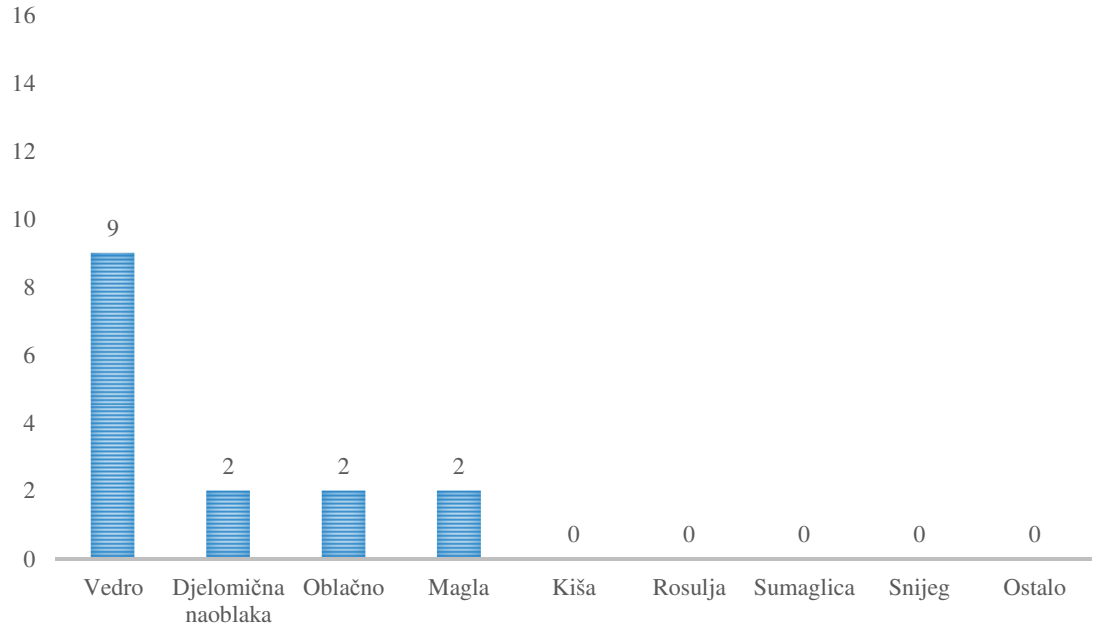

Slika 4-15: Pojava za vrijeme pomorske nezgode putničkih brodova od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

Stanje mora

Varijabla naziva „Stanje mora“ odnosi se na stanje mora za vrijeme pomorske nezgode.

Stanja koje može poprimiti varijabla „Stanje mora“ su:

- mirno
- umjereno valovito
- valovito
- uzburkano
- teško.

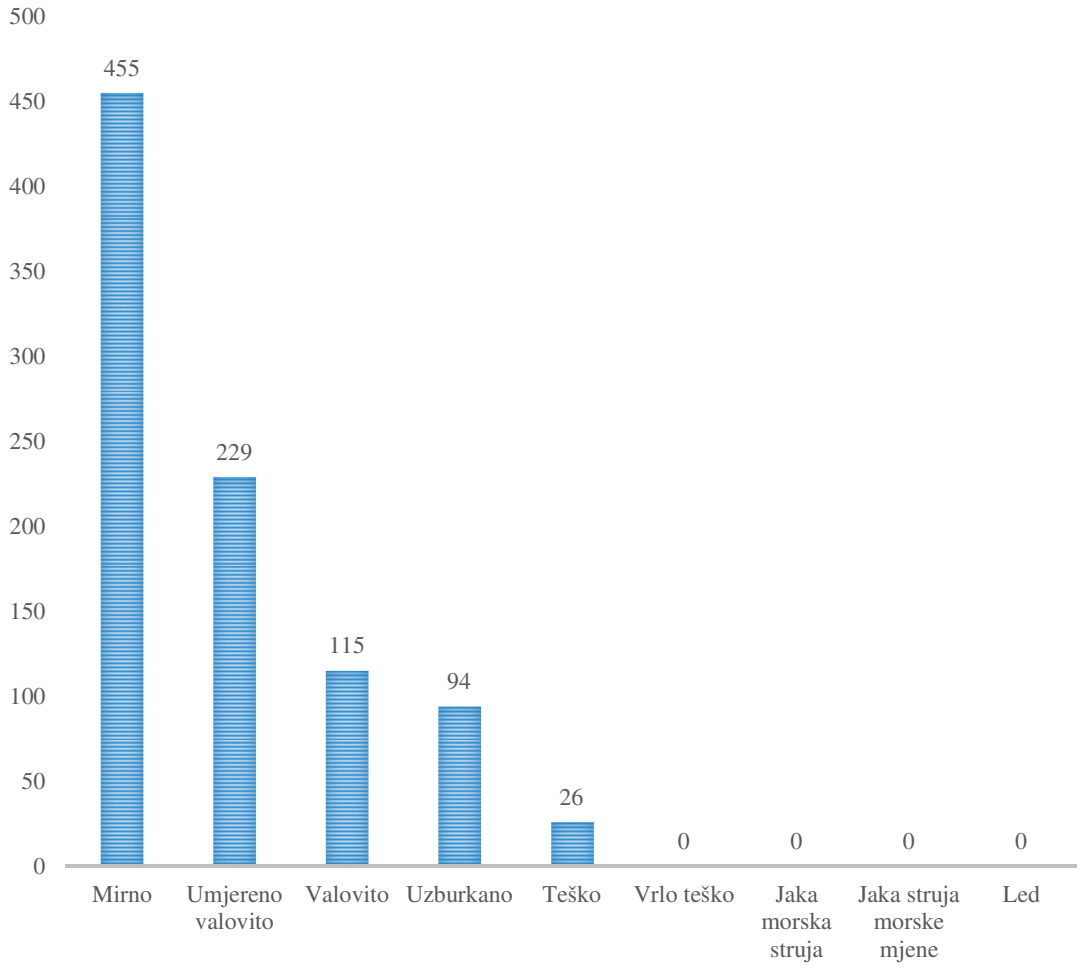

Slika 4-16: Stanje mora za vrijeme pomorskih nezgoda svih brodova od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

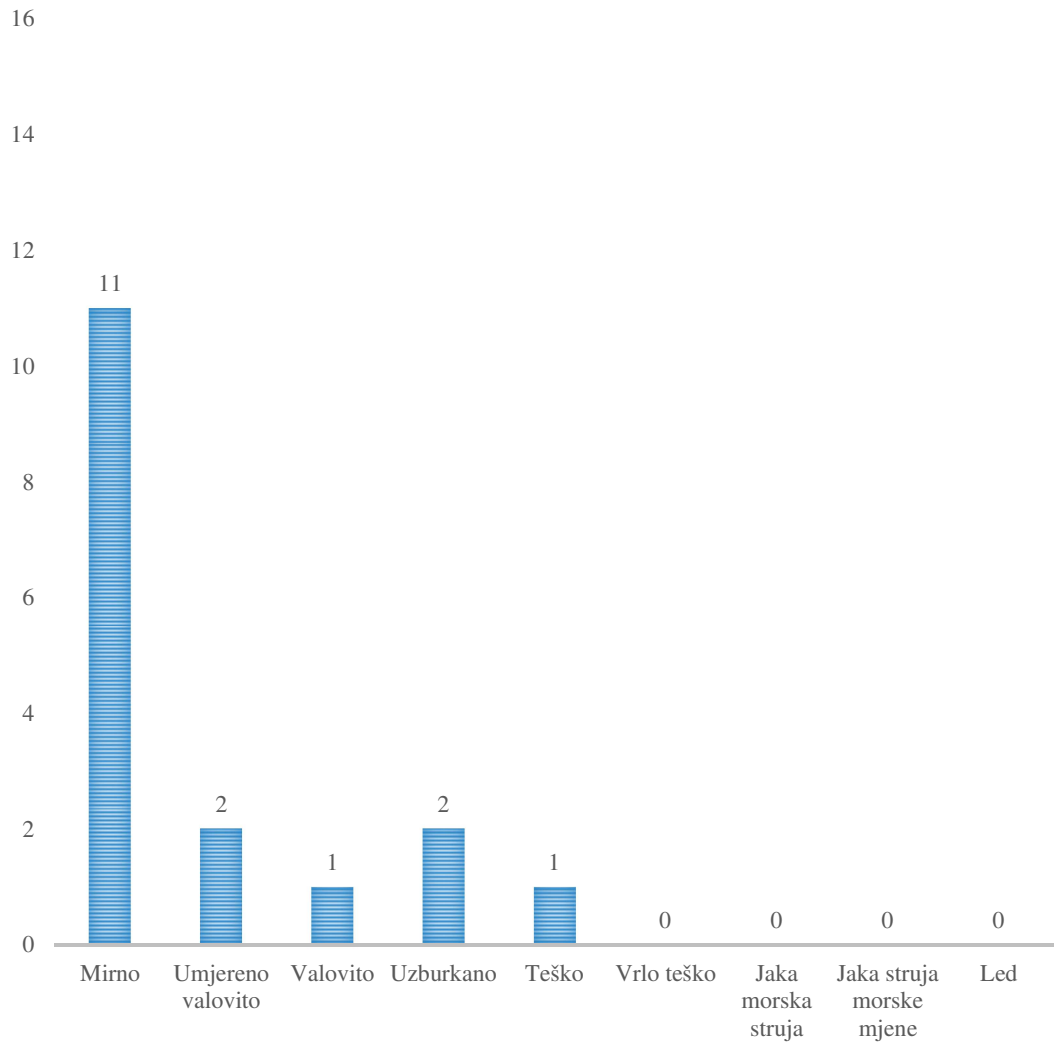

Slika 4-17: Stanje mora za vrijeme pomorskih nezgoda putničkih brodova od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

Vrijednosti za varijablu „Stanje mora“ dobiveni su statističkom obradom podataka MMPI-a.

Snaga vjetra

Varijabla naziva „Snaga vjetra“ (*Wind force)* odnosi se na snagu vjetra za vrijeme pomorske nezgode. U kvantitativnim modelima nasukavanja i sudara varijabla je postavljena na način da ima utjecaj na oštećenje broda, primjerice, na oštećenje jarbola ili kormila zbog sila uzrokovanim jedrenjem.

Stanja koja može poprimiti varijabla „ Snaga vjetra“ su:

- tiho
- povjetarac

- umjereni vjetar
- jaki vjetar
- olujni vjetar
- orkanski vjetar.

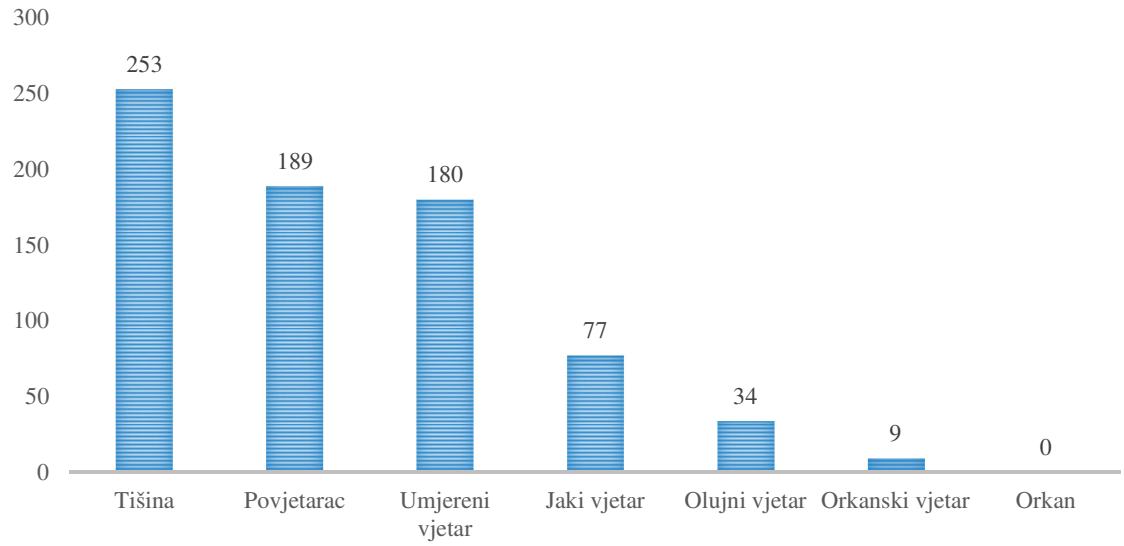

Slika 4-18: Snaga xvjetra za vrijeme pomorskih nezgoda svih brodova na Jadranu od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

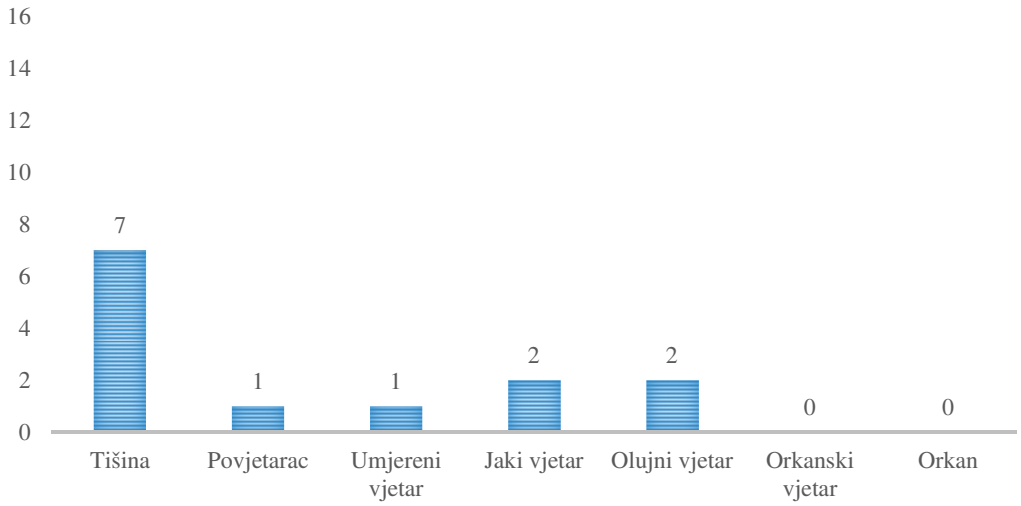

Slika 4-19: Snaga vjetra za vrijeme pomorskih nezgoda putničkih brodova na Jadranu od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

Vrijednosti za varijablu „Snaga vjetra“ dobiveni statističkom obradom podataka MMPI-a.

Smjer vjetra

Varijabla naziva „Smjer vjetra“ *(Wind direction)* odnosi se na smjer vjetra za vrijeme pomorske nezgode. Prema statističkoj analizi pomorskih nezgoda najviše se nezgoda dogodilo za mirnoga vremena. U slučaju puhanja vjetra, najviše ih se dogodilo za vrijeme puhanja vjetra iz NE smjera.

U modelu pomorske nezgode udara, varijabla „Smjer vjetra“ postavljena je na način da ima direktni utjecaj na tablicu uvjetovane vjerojatnosti varijable „Biti van kursa“. Prilikom puhanja jakog vjetra iz određenog smjera u nekim lukama otežan je manevar prilaza vezu i vez broda. Kvalitativni model udara izrađen je prema scenariju udara prilikom manevriranja u luci.

U kvantitativnim modelima sudara i nasukavanja, varijabla „Smjer vjetra“ utječe na oštećenje broda. Prema ekspertnom mišljenju zapovjednika brodova intervjuiranih za potrebe ovog rada, valovi izazvani puhanjem vjetra iz NE i N smjera, zbog karakteristične strmine, mogu dovesti do oštećenja broda. Kako se varijabla „Visina vala“ odnosi samo na visinu, a ne i na ostale karakteristike vala, u modelima pomorskih nezgoda prikazanim u ovom radu varijabla „Smjer vjetra“ se odnosi na karakteristiku površinskih valova uzrokovanu vjetrom iz određenog smjera.

U modelu požara i eksplozije, varijabla „Smjer vjetra“ roditelj je varijabli „Oštećenje broda“ koja može dovesti do požara i eksplozije. Razlog postavljanja varijable na ovaj način je povećana mogućnost iskrenja radi trenja dotrajalih materijala i valjanja na starim brodovima.

Prema podacima Hrvatskog hidrografskog instituta iz Splita najfrekventnije površinske valove na Jadranu uzrokuju bura i jugo u zimskom razdoblju, te NW vjetar u ljetnom razdoblju. Značajke površinskih valova uzrokovanim vjetrom zavise od smjera, brzine i trajanja prevladavajućih vjetrova, veličine područja nad kojim ti vjetrovi pušu (privjetrišta) i topografije morskog dna (dubine mora), što na području Jadranskog mora uzrokuje znatno veće visine valova juga nego bure pri istoj brzini i trajanju vjetra. (Peljar I., Jadransko more − istočna obala, 5 izd., 2012.)

Prema podacima iz Pomorsko-plovidbene studije plovnog područja Primorsko-goranske, Ličko-senjske, Zadarske i Šibensko-kninske županije (2015), obilježje valova izazvanih olujnim vjetrovima je njihova znatna strmina ($H/\lambda=1/10$) odnosno srednji period od 4,6 s, zbog čega se pri približnoj jednakoj visini vala plovidba, posebice manjih brodova, na Jadranu smatra opasnijom nego na oceanima.

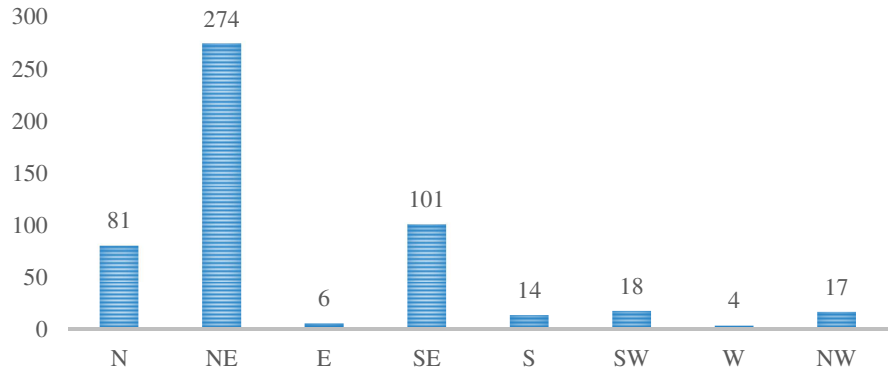

Slika 4-20: Smjer vjetra za vrijeme pomorskih nezgoda svih brodova na Jadranu od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

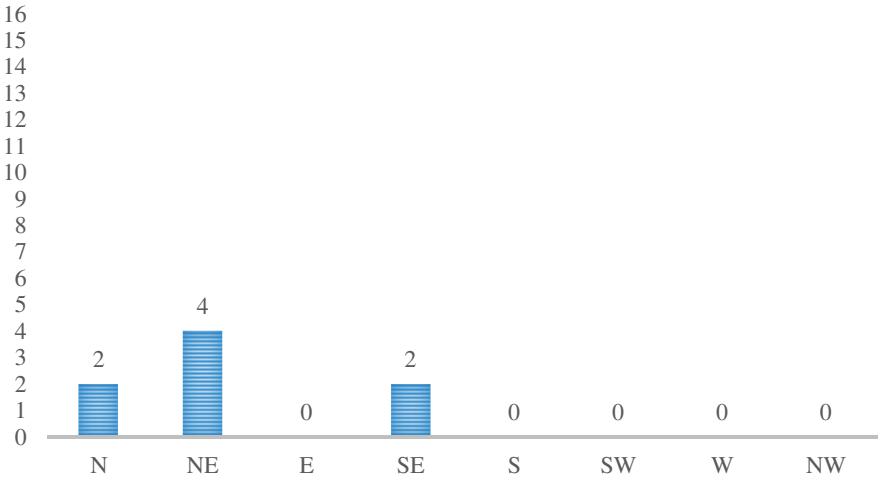

Slika 4-21: Smjer vjetra za vrijeme pomorskih nezgoda putničkih brodova na Jadranu od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

Stanja koja varijabla „Smjer vjetra“ kod putničkih brodova može poprimiti su:

- N
- NE
- SE.

Vrijednosti za varijablu „Smjer vjetra“ dobiveni su statističkom obradom podataka MMPI-a.

Vidljivost

Varijabla naziva „Vidljivost“ *(Visibility)* odnosi se na vidljivost za vrijeme pomorske nezgode.

Stanja koja može poprimiti varijabla „Vidljivost“ su:

- odlična (preko 50 000 metara)
- dobra (do 10 000 metara)
- srednja (do 4000 metara
- slaba (do 2000 metara)
- vrlo slaba (do 1000 metara).

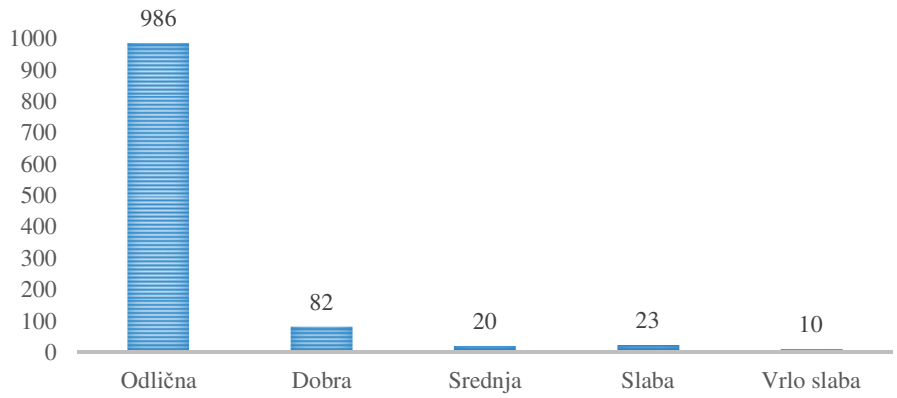

Slika 4-22: Vidljivost za vrijeme pomorskih nezgoda svih brodova na Jadranu od 2011. do 2015.

Izvor: izrađeno prema podacima MMPI-a

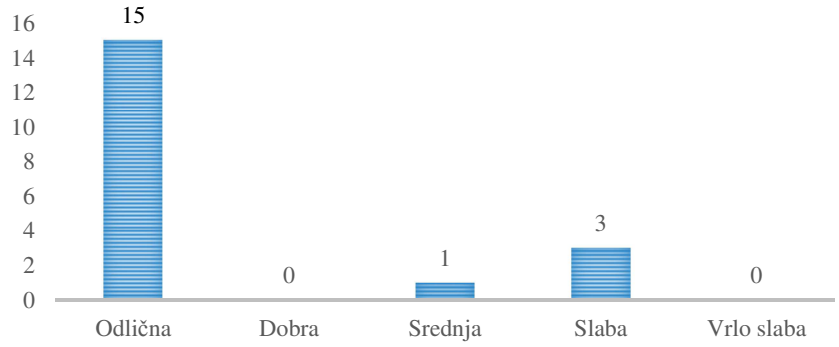

Slika 4-23: Vidljivost za vrijeme pomorskih nezgoda putničkih brodova na Jadranu od 2011. do 2015.

Izvor: Izrađeno prema podacima MMPI-a

Vrijednosti za varijablu „Vidljivost“ dobiveni su statističkom obradom podataka MMPI-a. Hidrometeorološki podaci koji su prethodili pomorskim nezgodama prema službenim izvještajima o pomorskim nezgodama MMPI-a dobivaju se od Hidrometeorološkog zavoda.

Magla

Varijabla naziva „Magla“ (*Fog)* odnosi se na pojavu magle za vrijeme pomorske nezgode.

Stanja koja može poprimiti varijabla „Magla“ su:

- da (na moru je prisutna: slaba magla, umjerena magla, gusta magla ili vrlo gusta magla)
- ne (na moru nema magle).

Prema Prometno-plovidbenoj studiji plovnog područja Split, Ploče i Dubrovnik utjecaj magle na sigurnost plovidbe je gotovo zanemariv zbog njene čestine te zbog jasnih odraza obalnih i otočnih objekata na radarskom zaslonu. Vjerojatnost magle na moru prikazana je u kvantitativnim modelima sudara i nasukavanja kroz vrijednosti stanja varijable „Pojava“. Magla se na Jadranu javlja većinom u zimskom razdoblju (prosinac – veljača) i to u prosjeku 5 dana godišnje (Peljar I., 2012).

Vrijednosti za varijablu „Magla“ prikazani su na slici 4-15 i dobiveni su statističkom obradom podataka MMPI-a.

Praćenje meteoroloških upozorenja

Varijabla naziva „Praćenje meteoroloških upozorenja“ (*Weather reports)* odnosi se na obvezu redovitog praćenja pomorskih sigurnosnih informacija (*Maritime Safety Information – MSI*) i vremenskih izvješća. Vremenska izvješća obuhvaćaju: upozorenja o nevremenu, sinoptičke podatke i prognozu vremena za pomorce. Praćenje meteoroloških upozorenja važan je čimbenik u smanjenu vjerojatnosti pojave pomorskih nezgoda promatranih brodova. Prema podacima HRB, 54 % malih putničkih brodova u 2015. godini bilo je duljine između 10 i 20 metara zbog čega su izloženiji meteorološkim neprilikama. Praćenjem meteoroloških upozorenja moguće je umanjiti rizik pojave pomorske nezgode uzrokovane meteorološkim čimbenicima u cijelosti, odgađanjem putovanja ili korištenjem sigurnih ruta zaklonjenih strana otoka i sl.

Stanja koja može poprimiti varijabla „Praćenje meteoroloških upozorenja“ su:

- da (osoba koja upravlja brodom prati službena meteorološka upozorenja, dobar je poznavatelj pomorske meteorologije te meteoroloških utjecaja na brod)
- ne (osoba koja upravlja brodom ne prati službena meteorološka upozorenja ili nije dobar poznavatelj pomorske meteorologije te meteoroloških utjecaja na brod).

Podaci za vrijednosti varijable „Praćenje meteoroloških upozorenja“ dobiveni su ekspertnom procjenom.

4.4 Utjecaj gustoće prometa na nastajanje pomorskih nezgoda

Varijabla naziva „Gustoća prometa“ je „omjer ukupnog broja plovnih jedinica i površine promatranog područja, gdje se pod pojmom plovne jedinice smatraju brodovi, jahte i brodice“[19]

Stanja koja može poprimiti varijabla „Gustoća prometa“ su:
- niska
- visoka.

Vrijednosti za varijablu „Gustoća prometa“ preuzeti su iz Prometno-plovidbene studije Pomorskog fakulteta u Rijeci iz 2014. godine.

Tablica 4-5: Preliminarne vrijednosti čimbenika gustoće prometa

Ime čvora	Vrsta	Vrijednosti	Naziv
Traffic distribution	Integral	2	G1

Prema podacima Prometno-plovidbene studije Pomorskog fakulteta u Rijeci iz 2014. godine, u 2013. godini iz luka Splitsko-dalmatinske županije isplovilo je otprilike 53.000 brodova, od toga se 92 % odnosi na promet prema domaćim lukama. Isti postotak ima i udio putničkih brodova u ukupnom broju isplovljenja. Pomorski promet Splitsko-dalmatinske županije čine primarno manja putnička plovila, prosječne dužine 40 do 50 m, a promet je pojačan u 6.,7.,8. i 9. mjesecu.[20] Nadalje, prema Prometno-plovidbenoj studiji „posebnu podskupinu predstavljaju lokalni plovni putovi koje koriste brodovi nautičkog turizma, odnosno jahte. Ovi

[19] Prometno- plovidbena studija, 2014.

[20] Prometno-plovidbena studija, 2014.

plovni putovi povezuju nautičke centre (domaće ili inozemne) s najatraktivnijim turističkim odredištima na Jadranu (gradovi uz obalu, nacionalni parkovi, otoci, uvale...). Iako se većinom protežu u blizini obale i nisu ustaljeni (više su raspršeni u odnosu na putove koji koriste trgovački brodovi), plovni putovi nautičkog turizma mogu imati obilježja prekomorskog plovidbenog puta, npr. prijelaz s istočne na zapadnu obalu Jadrana i obratno, ili obilježje uobičajene plovidbe između većih luka, odnosno odredišta istočne obale Jadrana. U tim slučajevima plovni putovi nautičkog turizma preklapaju se s glavnim plovnim putovima Jadrana. Osnovni lokalni plovni putovi su oni koji spajaju Split s važnijim lukama na otocima (Supetar, Hvar, Stari Grad, Rogač, Vis, Vela Luka, Korčula, Ubli) te oni koji spajaju veća obalna mjesta s otocima i otoke međusobno (Trogir − Drvenik V/M, Makarska − Sućuraj, Vela Luka − Ubli, Komiža − Biševo, itd.). Najopterećeniji dio je područje Splitskog kanala i područje koje zatvaraju spojnice Splitska vrata, Vis i zapadna obala Hvara. U ovim dvama područjima, skupa s prilaznim kanalima je i najveće preklapanje glavnih i lokalnih plovnih putova. Posebno ipak treba izdvojiti Splitska vrata, kao prometno najopterećenije područje jer se unutar malog prostora spaja većina plovnih putova koja ide prema Splitu.“

4.5 Ljudski faktor

U procesima procjene rizika u kojima je uključen ljudski faktor najčešće se javlja problem nedovoljnih informacija te raspolaganja s informacijama koje je teško izmjeriti. U takvim slučajevima najčešće se koristi procjena stručnjaka.

Tablica 4-6: Preliminarne vrijednosti varijable ljudski faktor

Ime čvora	Vrsta	Vrijednosti	Naziv
Tired	Boolean	2	LJ1
ISM Code	Boolean	2	LJ2
Familiarization	Integral	3	LJ3
Stress level	Integral	2	LJ4
Incapacitated	Integral	2	LJ5

Other distractions	Integral	2	LJ6
Non navigational tasks	Boolean	2	LJ7
Situational awareness	Boolean	2	LJ8
Personal condition	Integral	2	LJ9
Comunication with other vessel	Integral	2	LJ10
Safety culture	Integral	2	LJ11

Umor

Varijabla naziva „Umor“ (*Tired)* odnosi se na stanje osobe koja upravlja brodom. Umor je bitan element propusta izazvanih ljudskim faktorom, a koji uzrokuju 75-95 % pomorskih nezgoda (Bielić, Zec, 2004). U novijoj literaturi koristi se izraz zamor (*Fatigue*, a očituje se smanjenjem kognitivnih sposobnosti, spriječenošću izvođenja zadaća, slabim pamćenjem te smanjenom mogućnošću za adekvatno upravljanje brodom (Jones i ostali, 2005)). Zamor se smatra jednim od najznačajnijih faktora koji uzrokuju pomorske nezgode (Akhtar, Utne 2014, a neki od uzroka zamora su: vibracije, monotonija posla, izloženost vremenskim uvjetima, odvojenost od obitelji, slaba odvojenost rada i odmora itd.). Jedna od definicija zamora glasi: Zamor je najčešće opisan kao stanje „osjećaja umora, klonulosti, ili pospanosti koje proizlazi iz dugotrajnog mentalnog i fizičkog obavljanja rada, izloženosti teškim uvjetima, ili izostanku sna koje vodi pogoršanju izvođenja rada i smanjenju budnosti“ (Lapa, Xhelilaj, 2010).

Prilikom modeliranja pomorskih nezgoda u ovom radu koristi se izraz umor kao širi pojam od pojma zamor. Umor je moguć kod osoba koje upravljaju promatranim brodovima zbog specifičnog načina plovidbe. Najčešće samo jedna osoba upravlja brodom te promatrani brodovi u tijeku jednog dana zbog obilaska turističkih destinacija više puta sidre te imaju nekoliko manevara prilaza vezu i vezivanja broda. Osobe koje upravljaju brodom najčešće obavljaju i druge poslove na brodu te rade pod utjecajem atmosferskih prilika (sunce, vrućine). Osobe koje upravljaju promatranim brodovima najčešće su ukrcane bez prekida za vrijeme cijele godišnje eksploatacije broda.

Stanja koja može poprimiti varijabla naziva „Umor“ su:

- da (osoba koja upravlja brodom se osjeća umorno i pokazuje znakove umora)
- ne (osoba koja upravlja brodom se ne osjeća umorno niti pokazuje znakove umora).

Varijabla „Umor“ je u kvantitativnim modelima postavljena kao roditeljska varijabla te su vrijednosti za stanja varijable „Umor“ preuzeti su iz studije DNV, 2006.

ISM pravilnik

Varijabla naziva „ISM pravilnik“ (*ISM Code)* odnosi se na primjenu Međunarodnog kodeksa upravljanja sigurnošću, u nastavku Kodeks. Kodeks podrazumijeva zapovjednika kvalificiranog za upravljanje i poduzimanje svih mjera vezanih za sigurnost uz neophodnu podršku, kako bi mogao svoju dužnost obavljati u skladu sa sustavom sigurnosti te posadu koja je sposobna sigurno obavljati sve poslove vezane za svakodnevni rad, potrebne vježbe i rad u izvanrednim okolnostima propisane Pravilnikom.

Krajnji cilj Kodeksa je smanjenje broja nezgoda (Frančić, 2009).[21]

Primjena ISM pravilnika utječe na povećanje sigurnosne kulture na brodu.

Stanja za varijablu „ISM pravilnik“ su:

- da (Kodeks se primjenjuje u praksi sukladno preporukama, bez iznimaka)
- ne (Kodeks se primjenjuje u umanjenom obimu).

Vrijednosti za varijablu „ISM pravilnik“ dobiveni su ekspertnom procjenom.

[21] Prema Pravilima za statutarnu certifikaciju putničkih brodova u nacionalnoj plovidbi, Split, Hrvatski registar brodova, 2008. Obveza uvođenja ISM pravilnika na putničkim brodovima u nacionalnoj plovidbi odnosi se na:

- Ro-Ro putničke brodove
- vrlo brze putničke brodove
- putničke linijske brodove koji prevoze 100 ili više putnika, a koji pretežito ili isključivo plove unutarnjim morskim vodama i teritorijalnim morem Republike Hrvatske
- putničke brodove građene od drva ili ojačane stakloplastike bruto-tonaže ne veće od 250 BT namijenjene za jednodnevne turističke izlete s ne više od 250 putnika ili turistička krstarenja s prekonoćnim boravkom s ne više od 36 putnika koji plove u razdoblju od 1. travnja do 31. listopada u području plovidbe 6 do 8 nautičkih milja od obale.

Familijarizacija

Varijabla naziva „Familijarizacija“ *(Familiarization)* odnosi se na iskustvo osobe koja upravlja brodom u plovidbi određenim područjem.

Familijarizacija je posebno naglašena u modelu kao varijabla sa utjecajem na razinu stresa. Smatra se da osoba koja nije familijarizirana ima višu razinu stresa od prosječne te da neposredno može uvelike povećati rizik pojave pomorske nezgode.

Na temelju ekspertne procjene utvrđeno je da je većina osoba koja upravlja promatranim brodovima dobro upoznata i s brodom kojim upravlja i s područjem kojim plovi. Familijarizacija uvelike povećava sigurnost na brodovima i umanjuje rizik pojave pomorskih nezgoda zbog specifične plovidbe promatranih brodova (plovidbe u plitkom području, sidrenja u blizini obale, manevriranja u opterećenim lukama). Namjernim naglašavanjem varijable „Familijarizacija“ u modelu se postiže značajan utjecaj na krajnji rezultat modela u slučaju da osoba nije familijarizirana. Familijarizacija je u kvantitativnim modelima postavljena kao korijenska varijabla, stanja i vrijednosti za istu su zbog nedostatka podataka preuzeti iz studije DNV, 2003. U kvantitativnim modelima sudara i nasukavanja navedena varijabla je roditelj varijabli „ Razina stresa“.

Pojam familijarizacije u modelu (stanje varijable: da) podrazumijeva da je osoba dobro upoznata i s novim uređajima na brodu.

Stanja koje može poprimiti varijabla „ Familijarizacija“ su:

- da (osoba koja upravlja brodom upoznata je s brodom i plovnim područjem te je na istom brodu zaposlena duže od tri mjeseca i plovi promatranim područjem duže od tri mjeseca)
- srednje (osoba koja upravlja brodom zaposlena je na istom brodu kraće od tri mjeseca i plovi promatranim područjem kraće od tri mjeseca, ali je dobro upoznata s brodom i s područjem)
- ne (osoba koja upravlja brodom zaposlena je na istom brodu kraće od tri mjeseca i plovi promatranim područjem kraće od tri mjeseca te nije dobro upoznata ni sa brodom ni s promatranim područjem).

Vrijednosti za varijablu „Familijarizacija“ preuzeti su iz studije DNV, 2003.

Razina stresa

Varijabla naziva „Razina stresa“ *(Stress level)* prikazuje koliko je osoba koja upravlja brodom izložena stresnim utjecajima. Dijelom je taj stres uzrokovan familijarizacijom, odnosno iskustvom plovidbe i vještinom plovidbe u određenom području, a dijelom je uzrokovan brojnim drugim ometanjima koja joj zaokupljaju pažnju.

U kvantitativnim modelima sudara i nasukavanja varijabla „Razina stresa“ dijete je varijable „Familijarizacija“ i roditelj varijable „Osobno stanje“.

Stanja koja može poprimiti varijabla naziva „Razina stresa“ su:

- visok (osoba koja upravlja brodom nije familijarizirana te je pod utjecajem stresa (loši vremenski uvjeti, osobni problemi, problemi s posadom itd.)
- standardan (osoba koja upravlja brodom je familijarizirana te nije pod utjecajem stresa).

Onesposobljenost

Varijabla naziva „Onesposobljenost“ *(Incapacitaded)* odnosi se na psihičku sposobnost osobe koja upravlja brodom. Onesposobljenost može nastupiti zbog utjecaja alkohola, bolesti, zloupotrebe droga ili nekih lijekova. Osoba je onesposobljena i kada spava te kada nije prisutna na mostu.

Varijabla „Onesposobljenost“ korijenska je varijabla čije su vrijednosti zbog nedostatka podataka preuzete od autora Mazaheri, Montewka, Kujala, 2016. Varijabla „Onesposobljenost“ utječe na uvjetovanu vjerojatnost varijable „Osobno stanje“.

Stanja koja može poprimiti varijabla „Onesposobljenost“ su:

- da (osoba koja upravlja brodom je u neadekvatnom psihičkom stanju za upravljanje brodom)
- ne (osoba koja upravlja brodom je psihički sposobna za upravljanje brodom).

Druga ometanja

Varijabla naziva „Druga ometanja“ *(Other distractions)* odnosi se na izloženost osobe koja upravlja brodom drugim ometanjima, kao što su mobilni uređaji, prisutnost drugih osoba na mostu, problematične situacije na brodu koje joj mogu odvući pažnju od navigacijskih zadaća.

Stanja koje može poprimiti varijabla „Druga ometanja“ su:

- nekoliko (ometanja nema toliko da utječu na odvlačenje pažnje osobi koja upravlja brodom)
- mnogo (ometanja ima u tolikoj mjeri da odvlače pažnju osobi koja upravlja brodom).

Nenavigacijski zadaci

Varijabla naziva „Nenavigacijski zadaci“ *(Non navigational tasks)* opisuje količinu nenavigacijskih zadaća koje mogu odvući pozornost osobi koja upravlja brodom.

Stanja koja može poprimiti varijabla „Nenavigacijski zadaci“ su:

- nekoliko (nenavigacijskih zadataka u tijeku plovidbe ima toliko da ne utječu na upravljanje brodom)
- mnogo (nenavigacijskih zadataka u tijeku plovidbe ima toliko da utječu na upravljanje brodom).

Svjesnost o situaciji

Varijabla „Svjesnost o situaciji“ (S*ituational awareness)* odnosi se na sposobnost osobe da konstruira mentalni model sadašnjosti i da procijeni kako će se sadašnji trenutak razvijati (Hetherington i ostali, 2006). Postoje istraživanja temeljena na izvješćima pomorskih nezgoda koja govore da je 71 % ljudskih pogrešaka uvjetovano problemima nastalima zbog nesvjesnosti situacije (Grech i ostali, 2002).

Stanja koja može poprimiti varijabla „Svjesnost o situaciji“ su:

- da (osoba je svjesna sadašnjeg trenutka i ima sposobnost procjene kako će se sadašnji trenutak razviti)
- ne (osoba nije svjesna sadašnjeg trenutka te nema sposobnost procjene kako će se sadašnji trenutak razviti, ili osoba je svjesna sadašnjeg trenutka, ali nema sposobnost procjene kako će se sadašnji trenutak razviti).

Osobno stanje

Varijabla „Osobno stanje“ *(Personal condition)* odnosi se na psihičko i fizičko stanje osobe koja upravlja brodom. U kvantitativnim modelima sudara i nasukavanja, na osobno stanje onog koji upravlja brodom mogu utjecati: umor, razina stresa i onesposobljenost. Varijabla „Osobno stanje“ u kvantitativnom modelu sudara utječe na ljudsku pogrešku, a u kvantitativnom modelu nasukavanja na svjesnost o situaciji i na ljudsku pogrešku.

Stanja koja može poprimiti varijabla „Osobno stanje“ su:

- dobro (osoba koja upravlja brodom sposobna je obavljati zadatke vezane za upravljanje brodom i sigurnu plovidbu, što znači da nije umorna, nije pod visokim utjecajem stresa te nije onesposobljena)
- loše (osoba koja upravlja brodom nije sposobna obavljati zadatke vezane za upravljanje brodom i sigurnu plovidbu, odnosno osoba je, ili umorna ili pod visokim utjecajem stresa, ili onesposobljena).

Komunikacija s drugim brodom

Varijabla „Komunikacija s drugim brodom“ *(Comunication with other vessel)* odnosi se na uspješnu komunikaciju s drugim brodom u slučajevima sudarnih kursova ili tijekom plovidbe uskim kanalima radi dogovora oko izbjegavanja neželjenih navigacijskih postupaka drugog broda. Varijabla „Komunikacija s drugim brodom“ koristi se u modelu sudara. Roditeljska je varijabla krajnjoj varijabli „Sudar“, a na njenu uvjetovanu vjerojatnost utječe svjesnost o situaciji osobe koja upravlja brodom.

Vrijednosti koje može poprimiti varijabla „Komunikacija s drugim brodom“ su:

- dobra (uspostavljena je uspješna komunikacija brodova sudarnih kursova te su osobama koje upravljaju brodovima sudarnih kursova jasne namjere drugog broda)
- loša (nije uspostavljena komunikacija između brodova sudarnih kursova; uspostavljena je nejasna komunikacija između osoba koje upravljaju brodovima sudarnih kursova).

Sigurnosna kultura

Varijabla naziva „Sigurnosna kultura“ *(Safety culture)* roditeljska je varijabla čije su vrijednosti preuzete iz studije DNV, 2003. U kvantitativnim modelima prikazanim u ovome radu varijabla „Sigurnosna kultura“ utječe na tablice uvjetovane vjerojatnosti varijabli: „Druga ometanja“ i „Održavanje broda“.

Postoje mnogobrojne definicije sigurnosne kulture, u ovom radu korištena je definicija dana od strane *Advisory Committee on the Safety of Nuclear Installations (ACSNI, 1993):* „Sigurnosna kultura organizacije skup je osobnih i grupnih vrijednosti, stavova, načina ponašanja, znanja i vještina koji uvjetuju način rada i učinkovitost menadžmenta zaštite i sigurnosti.“

Varijabla „Sigurnosna kultura“ obuhvaća:

- mogući manjak posade i ljudskog resursa na brodu, lošu financijsku situaciju kompanije koja je vlasnik broda, česte promjene posade zbog nezadovoljstva radnim uvjetima
- radno vrijeme, odnosno mogućnost da pomorci rade u smjenama koje mogu rezultirati povećanim umorom i umanjenom kvalitetom zdravlja (Philips i Sagberg, 2010). Radno vrijeme utječe na umor, vezano je za vrijeme spavanja te je dokazano da služba 6/6 povećava vjerojatnost umora više od drugih kombinacija (Hanninen, 2015)
- nepoštivanje sigurnosnih protokola, lošu osviještenost posade o pomorskoj sigurnosti.

Varijabla naziva „Sigurnosna kultura“ može poprimiti stanja:

- visoka (visoka razina primjene sigurnosnih regulativa, sigurnosnih obveza te sigurnosne prakse na brodu)
- standardna (standardna primjena sigurnosnih regulativa, sigurnosnih obveza te sigurnosne prakse na brodu)
- loša (primjena sigurnosnih preporuka je na granici standarda za putničke brodove).

Podaci za varijablu „Sigurnosna kultura“ preuzeti su od DNV, 2003.

4.6 Tehničko-tehnološka obilježja brodova

Čimbenici brodskog sustava odnose se na čimbenike broda, odnosno karakteristike broda, načine navigacije, sustave sigurnosti koji su na brodu itd.

Tablica 4-7: Preliminarne vrijednosti čimbenika brodskog sustava

Ime čvora	Vrsta	Vrijednosti	Naziv
Material	Integral	6	B1
Age	Integral	6	B2
Equipment	Integral	3	B3
Navigation category	Integral	6	B4
Duration of cruising	Integral	3	B5
Flag	Integral	2	B6
Bridge visibility	Integral	2	B8
Maintenance	Integral	2	B9
AIS	Boolean	2	B10
Radar	Boolean	2	B11
Vessel damage	Boolean	2	B12
Hull fractured	Boolean	2	B13
Hull ruptured	Boolean	2	B14
Flooding	Boolean	2	B15
Capsizing	Boolean	2	B16
Hull ruptured	Boolean	2	B17

Materijal od kojeg je brod izgrađen

Varijabla naziva „Materijal od kojeg je brod izgrađen“ *(Material)* odnosi se na vrstu materijala korištenu pri gradnji ili zadnjoj rekonstrukciji broda. Većina promatranih brodova su drvene konstrukcije.

Stanja koja može poprimiti varijabla „Materijal od kojeg je brod izgrađen“ su:

- drvo
- čelik
- stakloplastika
- aluminij
- beton
- aluminij-čelik.

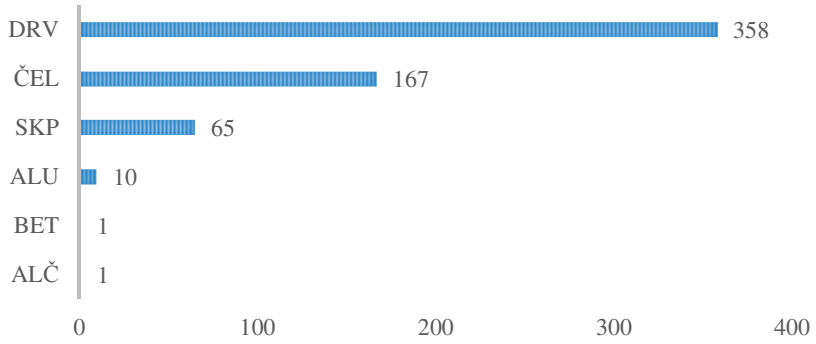

Slika 4-24: Materijal od kojeg je brod izgrađen prema HRB za 2015. godinu

Vrijednosti za varijablu „Materijal od kojeg je brod izgrađen“ dobivene su od Hrvatskog registra brodova i odnose se na putničke nelinijske brodove u 2015. godini.

Godina izgradnje

Varijabla naziva „Godina izgradnje“ *(Age)* odnosi se na starost broda. Statistički podaci o starosti broda koji su imali pomorsku nezgodu nisu dostupni te se prilikom modeliranja rizika pomorskih nezgoda putničkih nelinijskih brodova koristi podatak o starosti putničkih nelinijskih brodova za 2015. godinu. Prema Analizi sigurnosti putničkih brodova iz 2009 godine autora Frančić i dr., gotovo sve nezgode putničkih brodova dogodile su se kod brodova starijih od 25 godina. Podaci za razdoblje od 2011. do 2015. autorici nisi poznati te je varijabla postavljena u kvalitativan model požara i eksplozije.

Stanja koja može poprimiti varijabla “Godina izgradnje“ su:

- 0 − 10 godina
- 11 − 20 godina
- 21 − 30 godina
- 31 − 40 godina
- 41 − 50 godina
- 51 i više godina.

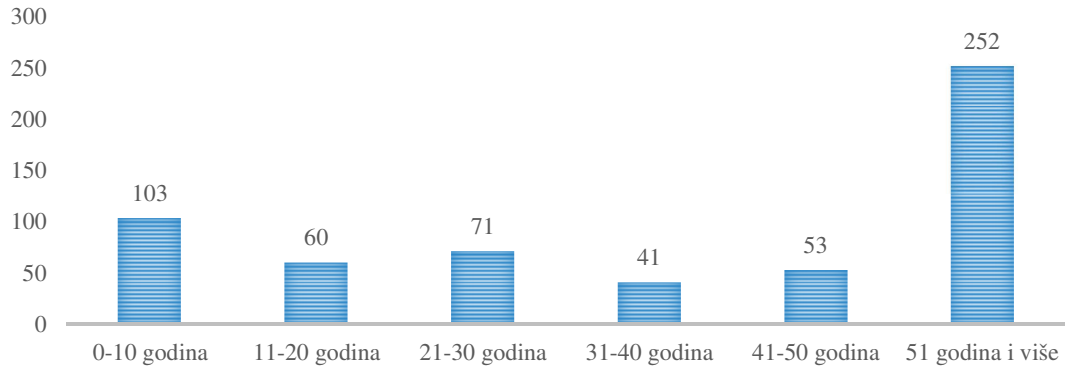

Slika 4-25: Starost putničkih brodova u nelinijskoj plovidbi

Vrijednosti za varijablu „Godina izgradnje“ dobiveni su od Hrvatskog registra brodova i odnose se na starost brodova u 2015. godinu bez obzira na sudjelovanje u pomorskim nezgodama.

Opremljenost

Varijabla naziva „Opremljenost“ *(Equipment*) odnosi se na opremljenost broda sustavima sigurnosti te pomagalima za navigaciju.

Stanja koja može poprimiti varijabla „Opremljenost“ su:

- dobra (opremljenost broda prema kategoriji plovidbe 1-4)
- srednja (opremljenost broda prema kategoriji plovidbe 5-6)
- loša (opremljenost broda prema kategoriji plovidbe 7-8).

Vrijednosti za varijablu „Opremljenost“ dobiveni od Hrvatskog registra brodova. Vrijednosti se odnose na opremljenost putničkih brodova bez obzira na sudjelovanje u pomorskim nezgodama.

Kategorija plovidbe putničkih brodova

Varijabla naziva „Kategorija plovidbe“ *(Navigation category)* odnosi se na kategoriju plovidbe putničkih brodova registriranih od strane Hrvatskog registra brodova za 2015. godinu.

Stanja koja može poprimiti varijabla „Kategorija plovidbe“ su:

- nacionalna obalna plovidba
- nacionalna priobalna plovidba
- nacionalna plovidba
- lokalna plovidba
- obalna plovidba Jadranskim morem
- neograničena plovidba.

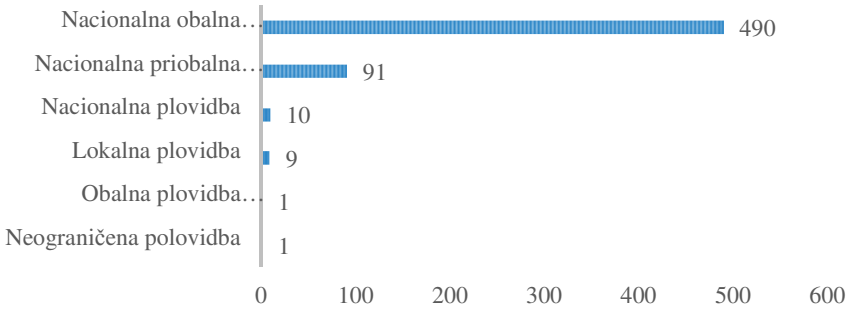

Slika 4-26: Kategorije plovidbe nelinijskih putničkih brodova 2015. godine

Vrijednosti za varijablu „Kategorija plovidbe“ putničkih brodova dobiveni su od Hrvatskog registra brodova i odnose se na podjelu putničkih nelinijskih brodova prema kategoriji plovidbe za 2015. godinu bez obzira na sudjelovanje u pomorskim nezgodama.

Trajanje plovidbe putničkih brodova

Varijabla naziva „Trajanje plovidbe“ *(Duration of cruising)* odnosi se na trajanje putovanja promatranih brodova. Promatrani brodovi najčešće plove u dnevnom ili sedmodnevnom periodu, a rjeđe u četrnaestodnevnom periodu. Varijabla trajanje plovidbe ima utjecaj na broj putnika na brodu. Varijabla “Trajanje plovidbe” utječe na opterećenje pojedinih luka.

Stanja koja može poprimiti varijabla “Trajanje plovidbe” su:

- jednodnevna putovanja

- sedmodnevna putovanja
- četrnaestodnevna putovanja.

Statistički podaci o trajanju plovidbe brodova koji su imali pomorsku nezgodu nisu poznati. Zbog nedovoljno podataka o trajanju plovidbe promatranih brodova, varijabla nije korištena u modeliranju pomorskih nezgoda u ovome radu.

Zastava

Varijabla naziva „Zastava“ *(Flag)* odnosi se na državnu pripadnost promatranog broda koji je sudjelovao u pomorskoj nezgodi. Nedostatak iskustva stranog zapovjednika utječe na vjerojatnost pojave pomorske nezgode.

Stanja koja može poprimiti varijabla „Zastava“ su:

- hrvatska
- strana.

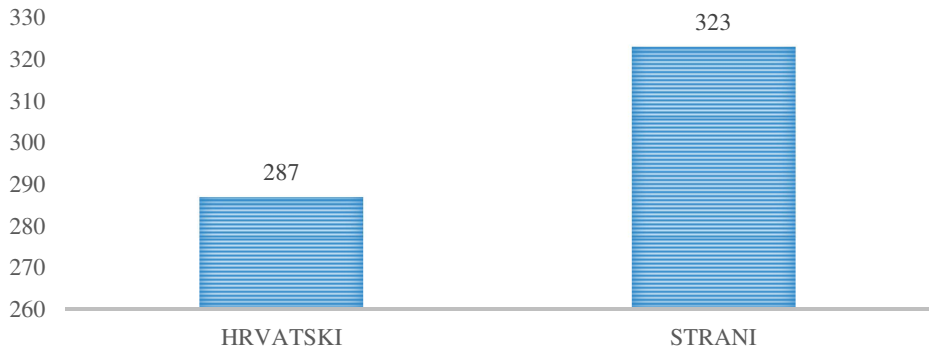

Slika 4-27: Zastava svih brodova koji su sudjelovali u pomorskim nezgodama od 2011. do 2015.

Izvor: Prema dostupnim podacima MMPI-a

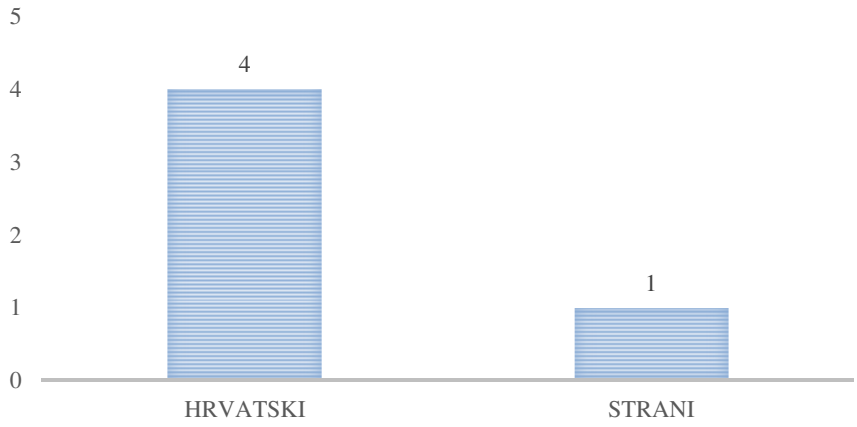

Slika 4-28: Zastava putničkih brodova koji su sudjelovali u pomorskim nezgodama od 2011. do 2015.

Izvor: Prema dostupnim podacima MMPI-a

Podaci za varijablu „Zastava“ dobiveni su statističkom obradom podataka MMPI-a. U promatranom razdoblju ukupno je bilo 29 pomorskih nezgoda putničkih brodova, ali je samo za pet brodova bila navedena zastava broda. Zbog nedostatka kvalitetnih statističkih podataka ova varijabla nije korištena u modelima.

Vidljivost s mosta

Varijabla naziva „Vidljivost s mosta“ *(Visual detection)* odnosi se na vidljivost s mosta koja je uvjetovana dizajnom i razmještajem prozora na mostu, brisača na prozorima, soli na prozorima itd. Varijabla se odnosi i na vidljivost uvjetovanu jačinom Sunčeve svjetlosti.

Stanja koja može poprimiti varijabla „Vidljivost s mosta“ su:

- dobra (nema zapreka vidljivosti)
- standardna (postoje zapreke vidljivosti, uvjetovane dizajnom i razmještajem prozora na mostu, brisača na prozorima, soli na prozorima itd, jačini Sunčeve svjetlosti).

Održavanje broda

Varijabla naziva „Održavanje broda“ *(Maintenance)* odnosi se na održavanje tehničkih sustava, brodske oplate te generalno brodskih sustava.

Stanja koja može poprimiti varijabla „Održavanje broda“ su:

- da (provođenje adekvatnog održavanja brodskih sustava)
- ne (neprovođenje adekvatnog održavanja brodskih sustava).

AIS

Varijabla naziva „AIS“ *(AIS)* odnosi se na primjenu sustava za automatsku identifikaciju na brodu *(Automatic Identification System − AIS)*.

Stanja koja može poprimiti varijabla „AIS“ su:

- da (brod ima AIS uređaj, AIS uređaj je u funkciji)
- ne (brod nema AIS uređaj, AIS uređaj nije u funkciji).

Varijabla „AIS“ je roditeljska varijabla. Vrijednosti za varijablu „AIS“ dobivene su ekspertnim mišljenjem zbog nedostatka statističkih podataka. Razlog postavljanja stanja varijable na 50 % je mogućnost praćenja utjecaja varijable „AIS“ na krajnji rezultat modela u slučaju da ga brod posjeduje ili ne, u cilju eventualnih preporuka o implementaciji ovog sustava na sve male putničke brodove. Varijabla „AIS“ u kvantitativnim modelima prikazanim u ovome radu roditelj je varijabli „Svjesnost o situaciji“.

Radar

Varijabla naziva „Radar“ *(Radar)* odnosi se na primjenu radara na brodu.

Stanja koja može poprimiti varijabla „Radar“ su:

- da (brod ima radar te ga osoba koja upravlja brodom pravilno koristi)
- ne (brod nema radar uređaj, osoba koja upravlja brodom nepravilno rukuje radarom).

Radar kao pomagalo pri navigaciji nije obvezan na svim malim putničkim brodovima u nelinijskoj obalnoj plovidbi, stoga se smatra potrebnim implementirati ga u model kako bi se ustanovio utjecaj radara na vjerojatnost pojave pomorske nezgode. Varijabla „Radar“ roditeljska je varijabla i njene vrijednost dobivene su ekspertnim mišljenjem zbog nedostatka statističkih podataka. Varijabla „Radar“ u kvantitativnim modelima prikazanim u ovome radu roditelj je varijabli „ Svjesnost o situaciji“.

Oštećenje broda

Varijabla naziva „Oštećenje broda“ *(Vessel damage)* odnosi se na sva oštećenja broda bez obzira na uzrok i posljedice.

Varijabla „Oštećenje broda“ u kvantitativnom modelu sudara, roditelj je varijabli „Izbjegavanje“. Na uvjetovanu vjerojatnost varijable „Oštećenje broda“ u modelu sudara utječu varijable koje se odnose na hidrometeorološke prilike.

U kvantitativnom modelu nasukavanja, varijabla „Oštećenje broda“ utječe na varijablu „Kada brod ne plovi po planiranom kursu“. Na uvjetovanu vjerojatnost varijable „Oštećenje broda“ utječu varijable hidrometeoroloških prilika.

Varijabla se u pojedinim modelima može odnositi na lom konstrukcije *(Hull ruptured)*, oštećenja trupa broda *(Hull fractured)* ili na probijanje trupa broda *(Hull ruptured)* ovisno o uzroku.

Stanja koja može poprimiti varijabla „Oštećenje broda“ su:

- da (brod ima lom konstrukcije, pukotinu ili otvor u trupu)
- ne (brod nema lom konstrukcije, pukotinu ili otvor u trupu).

Pukotina

Varijabla naziva „Pukotine“ *(Hull fractured)* odnosi se na manja oštećenja trupa.

Stanja koja može poprimiti varijabla su:

- da (brod ima pukotine na trupu, ali pukotine ne mogu uzrokovati potonuće za sat vremena)
- ne (brod nema pukotine na trupu).

Varijabla „Pukotina“ postavljenja je u kvalitativnom modelu „Potonuća“ kao roditeljska varijabla „Naplavljivanju“ te kao dijete varijablama: „Sudar“, „Vremenski uvjeti“, „Udar“, „Požar i eksplozija“ i „Nasukavanje“.

U kvantitativnom modelu potonuća pojedine pomorske nezgode imaju ulogu utjecajnih varijabli.

Proboj trupa

Varijabla naziva „Proboj trupa“ *(Hull ruptured)* odnosi se na veća oštećenja trupa.

Stanja koja može poprimiti varijabla su:

- da (brod ima proboj trupa koji može uzrokovati potonuće za sat vremena)
- ne (brod nema proboj trupa).

Varijabla „Proboj broda“ korištena je u kvalitativnom modelu potonuća kao dijete varijablama „Sudar“, „Požar i eksplozija“ i „Nasukavanje“ te kao roditelj varijabli „Naplavljivanje“.

Naplavljivanje broda

Varijabla naziva „Naplavljivanje“ *(Flooding)* odnosi se na prodor vode u brod bez obzira na uzrok i posljedice.

Stanja koja može poprimiti varijabla su:

- da (u brod prodire voda)
- ne (u brod ne prodire voda).

Varijabla „Naplavljivanje“ korištena je u kvantitativnom modelu potonuća kao roditeljska varijabla krajnjoj varijabli. Varijabla „Naplavljivanje“ dijete je varijablama: „Pukotina“, „Sudar“, „Udar“, „Nasukavanje“ i „Proboj trupa“.

Prevrtanje

Varijabla naziva „Prevrtanje“ *(Capsizing)* odnosi se na prevrtanje broda brez obzira na uzrok.

Stanja koja može poprimiti varijabla su:

- da (brod se nalazi u kritičnom kutu nagiba koji dovodi do prevrtanja)
- ne (brod se ne nalazi u kritičnom kutu nagiba koji dovodi do prevtanja).

Varijabla „ Prevrtanje“ korištena je u kvalitativnom modelu potonuća kao roditeljska varijabla krajnjoj varijabli. Varijabla „Prevrtanje“ dijete je varijablama: „ Naplavljivanje“, „Pukotina“, „Sudar“, „Udar“ i „Nasukavanje“.

Lom konstrukcije

Varijabla naziva „Lom konstrukcije“ *(Hull ruptured)* odnosi se na veća oštećenja trupa bez obzira na uzrok. Lom konstrukcije odnosi se na lomove strukturnih dijelova do kojih dolazi zbog zamora konstrukcije i umora materijala izloženog dinamičkim opterećenjima i visokim naprezanjima.

Stanja koja može poprimiti varijabla su:

- da (brod ima lom konstrukcije uslijed čega može doći do potonuća za sat vremena)
- ne (brod nema lom konstrukcije).

Zbog rijetkosti loma konstrukcije na malim putničkim brodovima u nelinijskoj obalnoj plovidbi varijabla „Lom konstrukcije“ nije korištena u modelima procjene rizika pojave pomorskih nezgoda u ovom radu.

4.7 Plovidba u plitkom području

Varijabla naziva „Plovidba u plitkom području“ *(Navigation in shallow waters)* odnosi se na plovidbu, sidrenje ili zadržavanje u plitkom području zbog turističkih atrakcija.

Stanja koja može poprimiti varijabla „Plovidba u plitkom području“ su:

- da (brod se nalazi u plitkom području)
- ne (brod se ne nalazi u plitkom području).

Promatrani brodovi zbog atraktivnog ambijenta određenih laguna i sličnih plitkih područja na Jadranu često sidre ili plove na plitkom području čime povećavaju rizik od nasukavanja.

Tablica 4-8: Preliminarne vrijednosti varijable plovidba u plitkom području

Ime čvora	Vrsta	Vrijednosti	Ime
Navigation in shallow waters	Boolean	2	P1

Podaci za varijablu „Plovidba u plitkom području“ dobiveni su ekspertnom procjenom.

4.8 Plovidba u području posebnog opreza

Varijabla naziva „Područje posebnog opreza“ *(Special caution area)* odnosi se na područja posebne opasnosti specifična za područje promatranja. Područja posebnog opreza definirana prema Pomorsko-plovidbenoj studiji plovnog područja Split, Ploče i Dubrovnik (Slika 4-29) su: Splitska vrata, Drvenički kanal, Viški kanal, Šoltanski kanal, Pakleni otoci i Pakleni kanal, Prilaz Gradskoj luci, područja plovidbe hidroaviona, područja vanjskih rubova otoka.

Stanja koja može poprimiti varijabla „Područje posebnog opreza“ su:

- da (brod se nalazi u području posebnog opreza)
- ne (brod se ne nalazi u području posebnog opreza).

Tablica 4-9: Preliminarne vrijednosti čimbenika područja posebnog opreza

Ime čvora	Vrsta	Vrijednosti	Ime
Special caution area	Boolean	2	P2

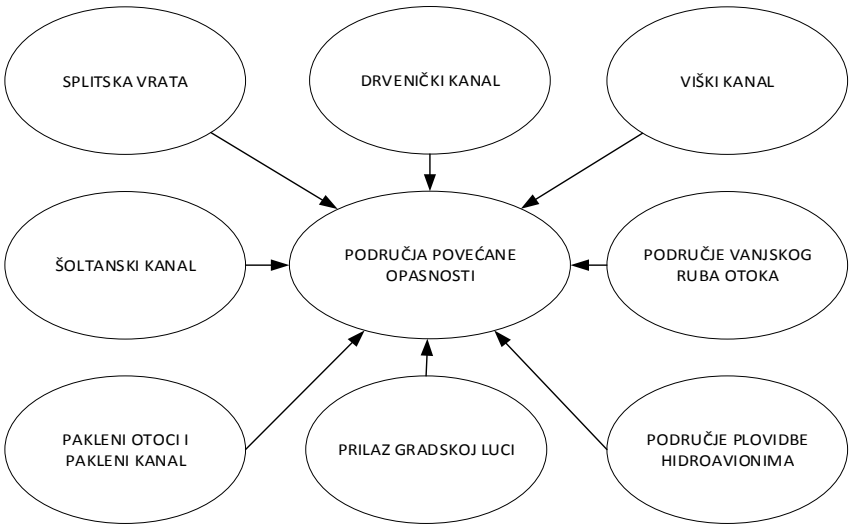

Slika 4-29: Područja posebnog opreza u Splitsko-dalmatinskoj županiji

Izvor: Izrađeno prema podacima Pomorsko-plovidbene studije plovnog područja Split, Ploče, Dubrovnik

Varijabla „Područje posebnog opreza“ korijenska je varijabla koja u kvantitativnom modelu sudara utječe na varijablu „Izbjegavanje“, a u kvantitativnom modelu nasukavanja utječe

direktno na krajnju varijablu. Vrijednosti za varijablu „Područje posebnog opreza“ dobivene su ekspertnim mišljenjem.

4.9 Greške i gubici kontrole

Varijable grešaka, gubitka kontrole i nemara odnose se na generalne pojmove grešaka koji su korišteni u modelima.

Tablica 4-10: Preliminarne vrijednosti čimbenika grešaka i gubitka kontrole

Ime čvora	Vrsta	Vrijednosti	Naziv
Loss of control	Boolean	2	O1
Breakdown	Boolean	2	O2
Human error	Boolean	2	O3
Navigational error	Boolean	2	O4
Give away	Boolean	2	O5
Loss of controll of other vessel	Boolean	2	O6
Other vessel error	Boolean	2	O7
Passenger nonchalance	Boolean	2	O8
Handling error	Boolean	2	O9
Off course	Boolean	2	O10

Gubitak kontrole

Varijabla naziva „Gubitak kontrole“ *(Loss of control)* odnosi se na gubitak kontrole nad brodom zbog tehničkog kvara ili zbog ljudske pogreške prilikom čega ništa ne može zaustaviti brod u kretanju prema opasnosti (DNV, 2003).

Stanja koja može poprimiti varijabla „Gubitak kontrole“ su:

- da (brod iz željenog stanja ide u neželjeno stanje)
- ne (brod se zadržava u željenom stanju).

U kvantitativnom modelu nasukavanja, varijabla „Gubitak kontrole“ dijete je varijablama: „Tehnička greška“, „Druga ometanja“, „Ljudska pogreška“, i „Svjesnost o situaciji“. U kvantitativnom modelu „Sudara“, varijabla „Gubitak kontrole“ dijete je varijablama: „Tehnička greška“, „Ljudska pogreška“ i „Druga ometanja“. Varijabla „Gubitak kontrole“ u kvantitativnim modelima sudara i nasukavanja roditelj je varijabli „Kada brod ne plovi po planiranom kursu“.

Tehnička greška

Varijabla naziva „Tehnička greška“ *(Breakdown)* odnosi se na tehnički kvar na brodu, bez obzira na uzrok i posljedice kvara.
Stanja koja može poprimiti varijabla „Tehnička greška“ su:

- da (brod ima tehnički kvar)
- ne (brod nema tehnički kvar).

Varijabla „Tehnička greška“ u kvantitativnim modelima sudara i nasukavanja dijete je varijable „Održavanje broda“ i roditelj varijabli „Gubitak kontrole“.

Ljudska pogreška

Varijabla naziva „Ljudska pogreška“ *(Human error)* odnosi se na netoleriranu aktivnost ili devijaciju od normalnog ponašanja čije su granice definirane sustavom (Rausand, 2001).

Varijabla naziva „Ljudska pogreška“ odnosi se na sve pogreške uzrokovane ljudskim faktorom u:

- plovidbi (planiranje putovanja, izvršenje putovanja i izbjegavanje sudara)
- pogonu (odgovornost za cjelovito funkcioniranje brodskog pogonskog sustava i njegovih pomoćnih sredstava)
- održavanju broda i brodske opreme
- upravljanju brodom (radni zadaci, kontrola i nadzor, itd).

Stanja koja može poprimiti varijabla „Ljudska pogreška“ su:

- da (ljudska pogreška uzrok je prijelaza broda iz željenog u neželjeno stanje)
- ne (ljudska pogreška nije uzrok prijelaza broda iz željenog u neželjeno stanje).

U kvantitativnim modelima sudara i nasukavanja prikazanim u ovom radu varijabla „Osobno stanje“ roditelj je varijabli „Ljudska pogreška“ koja je pak roditelj varijabli „Gubitak kontrole“.

Navigacijska pogreška

Varijabla naziva „Navigacijska pogreška“ *(Navigational error)* odnosi se na pogreške prilikom snalaženja na moru, odnosno prilikom određivanja položaja broda, upravljanja i nadzora njegova kretanja.

Stanja koja može poprimiti varijabla „Navigacijska pogreška“ su:

- da (pozicija broda kojom raspolaže osoba koja upravlja brodom odstupa toliko od stvarne pozicije broda da može dovesti brod u opasnost)
- ne (pozicija broda kojom raspolaže osoba koja upravlja brodom ne odstupa toliko od stvarne pozicije broda da može dovesti brod u opasnost).

U kvantitativnim modelima nasukavanja i sudara prikazanim u ovom radu varijabla „Svjesnost o situaciji“ roditelj je varijabli „Navigacijska pogreška“. Varijabla „Navigacijska pogreška“ roditelj je varijabli „Kada brod ne plovi po planiranom kursu“. U kvalitativnom modelu sudara varijabla „Navigacijska pogreška“ roditelj je varijabli „Izbjegavanje“.

Izbjegavanje sudara

Varijabla naziva „Izbjegavanje“ *(Give away)* odnosi se na poduzimanje pravilnih i djelotvornih radnji za izbjegavanje sudara sukladno „Pravilniku o sigurnosti pomorske plovidbe u unutarnjim morskim vodama i teritorijalnom moru Republike Hrvatske te načinu i uvjetima obavljanja nadzora i upravljanja pomorskim prometom.“[22] Iako fraza *Give away* nije potpuno ispravna, ona se koristi za ovu varijablu zbog ograničenja programa (modela).

[22]Narodne novine, br. 79/2013.

Ispravna fraza za ovu varijablu bila bi *Collision avoiding action* što predstavlja radnju za izbjegavanje sudara.

Stanja koja može poprimiti varijabla „Izbjegavanje“ su:

- da (osoba koja upravlja brodom poduzela je sve potrebne radnje sukladno plovidbenoj praksi i pravilima o izbjegavanju sudara na moru)
- ne (osoba koja upravlja brodom nije poduzela sve potrebne radnje sukladno plovidbenoj praksi i pravilima o izbjegavanju sudara na moru ili je poduzela radnje koju su nejasne drugom brodu).

Varijabla „Izbjegavanje“ koristi se u kvantitativnom modelu „Sudara“ kao roditeljska varijabla krajnjoj varijabli modela. Varijabli „Izbjegavanje“, roditeljske varijable u modelu sudara su: „Navigacijska pogreška“, „Gubitak kontrole“ i „Kada brod ne plovi po planiranom kursu“.

Gubitak kontrole drugog broda

Varijabla naziva „Gubitak kontrole drugog broda“ *(Loss of control of other vessel)* odnosi se na gubitak kontrole drugog broda zbog tehničke ili ljudske pogreške, ili utjecaja vanjskih faktora.

Stanja koja može poprimiti varijabla „Gubitak kontrole drugog broda“ su:

- da (osoba koja upravlja drugim brodom izgubila je kontrolu uravljanja zbog tehničkog kvara ili ljudske pogreške čime predstavlja opasnost za ostale brodove u okolini)
- ne (osoba koja upravlja drugim brodom ima kontrolu upravljanja).

Varijabla „Gubitak kontrole drugog broda“ utječe na krajnju varijablu modela sudara.
Varijabli „Pogreška drugog broda“ roditelj je varijabla „Gubik kontrole drugog broda“.

Pogreška drugog broda

Varijabla naziva „Pogreška drugog broda“ *(Other vessel error)* odnosi se na ljudske greške na drugom brodu (navigacijske pogreške, pogreške prilikom rukovanja itd.)

Stanja koje može poprimiti varijabla „Pogreška drugog broda“ su:

- da (na drugom brodu je napravljena ljudska pogreška koja može dovesti do gubitka kontrole broda),
- ne (na drugom brodu nije napravljena ljudska pogreška).

Varijabla „Pogreška drugog broda“ korijenska je varijabla u modelu sudara te su njene vrijednosti dobivene ekspertnim mišljenjem. Varijabla „Pogreška drugog broda“ roditelj je varijabli „Gubitak kontrole drugog broda“.

Nemar putnika

Varijabla „Nemar putnika*“ (Passenger nonchalance)* odnosi se na nemar putnika zbog nepoštivanja općih pravila prilikom boravka na brodu (pušenje na nedozvoljenom mjestu, nošenje neadekvatne obuće, ignoriranje uputa posade itd.).

Stanja koja može poprimiti varijabla „Nemar putnika“ su:

- da (putnici ne poštuju brodska pravila te se ne pridržavaju uputa posade)
- ne (putnici poštuju brodska pravila i pridržavaju se uputa posade).

Varijabla „Nemar putnika“ prikazana je u kvalitativnom modelu sudara i eksplozije kao korijenska varijabla s direktnim utjecajem na krajnju varijablu modela.

Pogreška pri rukovanju

Varijabla naziva „Pogreška pri rukovanju“ *(Handling error)* odnosi se na skupinu uzroka koji dovode do ljudske greške pri radu, a ona uključuje pogrešne ili nepotpune radne postupke, radno preopterećenje, nedostatak znanja i vještina i sl.
Stanja koja može poprimiti varijabla „Pogreška pri rukovanju“ su:

- da (osoba ne poznaje sustav ili uređaj kojim rukuje te izaziva štetu na sustavu ili uređaju s posljedicama na brod, posadu i putnike, ili bez njih)
- ne (osoba pravilno upravlja uređajem ili sustavom i njeni postupci ne uzrokuju štetu sustava ili uređaja).

Varijabla „Pogreška pri rukovanju“ se nije zasebno koristila u modelu zbog nedostatka podataka.

Kada brod ne plovi po planiranom kursu

Varijabla naziva „Kada brod ne plovi po planiranom kursu“ *(Off course)* odnosi se na skupinu uzroka koji dovode do toga da brod nije u mogućnosti ploviti po planiranom kursu.

Stanja koja može poprimiti varijabla „Kada brod ne plovi po planiranom kursu“ su:

- da (brod ne plovi po planiranom kursu)
- ne (bod plovi po planiranom kursu).

Varijabla „Kada brod ne plovi po planiranom kursu“ prikazana je u kvantitativnim modelima sudara i nasukavanja. U modelu sudara, na varijablu „Kada brod ne plovi po planiranom kursu“ direktno utječu varijable „Oštećenje broda“ i „Gubitak kontrole“. Varijabla „Kada brod ne plovi po planiranom kursu“ u istom modelu utječe na varijablu „Izbjegavanje“. U modelu nasukavanja, na varijablu „Kada brod ne plovi po planiranom kursu“ direktno utječu varijable „Navigacijska pogreška“, „Gustoća prometa“, „Gubitak kontrole“ i varijabla „Oštećenje broda“. Varijabla „Kada brod ne plovi po planiranom kursu“ roditeljska je varijabla krajnjoj varijabli u kvantitativnom modelu nasukavanja.

5. KVALITATIVNI MODEL PROCJENE POJAVE POMORSKIH NEZGODA

Pristupanje rizicima može se izvršiti na kvalitativni i kvantitativni način. Kvalitativni pristup koristi način uspoređivanja u svrhu definiranja, ima li jedna aktivnost veći utjecaj od druge, dok se kvantitativnim pristupom evaluiraju utjecaji parametara na rizik.

Kvalitativnim modelom rizika odabiru se relevantni parametri modela, te se određuju njihove međusobne veze, čime se prikazuju odnosi čimbenika koji dovode do pomorske nezgode. Navedeno pretpostavlja znanje o sustavu koji se promatra i ponašanje sustava u mogućim situacijama. Varijable kvalitativnog modela mogu biti povezane na različite načine. Kvalitativni odnos između dviju varijabli prikazuje kako jedna varijabla utječe na ponašanje druge varijable.

Kvalitativni modeli procjene rizika pomorskih nezgoda nužno su vezani za područje promatranja, načine plovidbe te vrstu, odnosno karakteristike promatranih brodova. Autori Montewka i ostali (2014) navode kako je za izradu modela rizika neophodno odrediti scenarij pomorske nezgode.

Prema autoru Mohović (2011): „Scenarijem nezgode smatra se razumno mogući, nepovoljan razvoj događaja, u pretpostavljenim okolnostima, koji u konačnici rezultira pomorskom nezgodom s određenim posljedicama.“ Nadalje, isti autor navodi da je scenarij moguće izraditi za sve vrste pomorskih nezgoda ovisno o cilju procjene rizika, odnosno željenoj posljedici analize.

Kvalitativni modeli u ovom radu razmatraju scenarije u plovnom području Splitsko-dalmatinske županije, i to primarno za male putničke brodove u nelinijskoj obalnoj plovidbi, ali ostavljaju mogućnost promjene i prilagodbe ovih čimbenika, čime se dopušta primjena modela i na druga područja i slične vrste brodova. Još od zlatnog doba Dubrovačke Republike, područje Jadrana bilo je poznato po kvalitetnim pomorcima i brodograditeljima brodova od drva. Stari trabakuli koji su u prošlosti služili za prijevoz pijeska prenamijenjeni su i rekonstruirani za prijevoz putnika u vidu tradicionalnih jedrenjaka. Ovakvi brodovi koriste se kao brodovi za manja kružna putovanja ili kao brodovi za jednodnevne izlete. Njihova intenzivna eksploatacija događa se u zadnjih dvadeset godina, posebice u Splitsko-dalmatinskoj županiji.

Vrste tradicionalnih brodova koje se koriste u nautičkom turizmu su: trabakul, karak, šoner, bark i loger (Kozličić, 1993). Smatra se da su sadašnji tradicionalni brodovi koji se koriste u turizmu 4. generacija prvobitno rekonstruiranih starih jedrenjaka iz 60-ih godina prošlog stoljeća, te se radi o obnovljenim ili sasvim novim jedrenjacima kojima su nadograđivane palube za postizanje većeg komoditeta putnika. Osim tradicionalnih brodova u radu se modeliraju pomorske nezgode i ostalih malih putničkih brodova koji plove u obalnoj plovidbi.

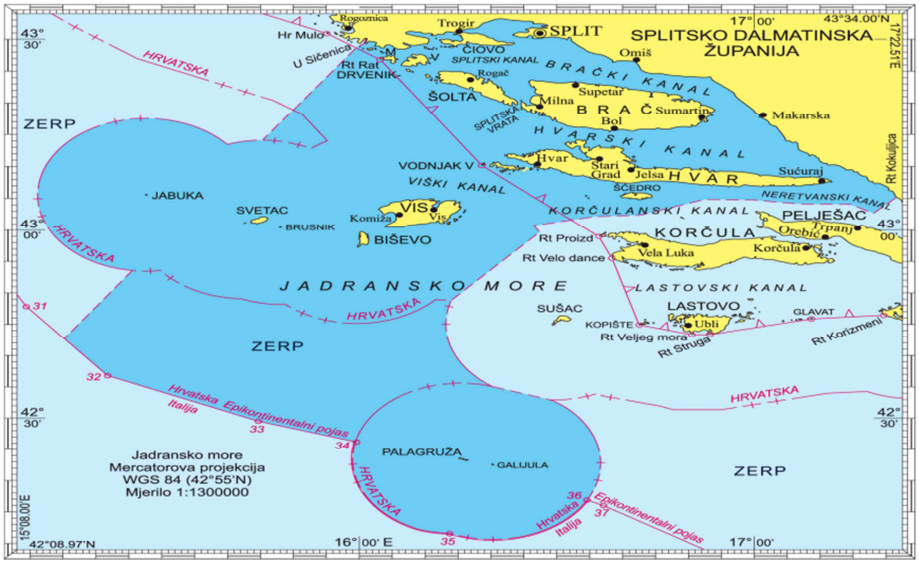

Slika 5-1: Splitsko-dalmatinska županija

Izvor: Hrvatski hidrografski institut

U nastavku ove doktorske disertacije prikazani su modeli procjene rizika pojave pomorskih nezgoda za definiranu grupu brodova i područja plovidbe. Pri modeliranju procjene rizika pojave pomorskih nezgoda uzeti su u obzir različiti lokalni čimbenici utjecaja koji se odnose na Splitsko-dalmatinsku županiju (Slika 5-1). Uključivanjem vrijednosti lokalnog karaktera te vrijednosti koje se odnose na specifičan način plovidbe promatranih brodova dobivene su lokalizirane vrijednosti uvjetovane vjerojatnosti. Smatra se da je upotrebom lokalnih vrijednosti dobivena preciznija vrijednost uvjetovane vjerojatnosti. Vrijednosti koje se odnose na lokaciju dobiveni su intervjuiranjem zapovjednika s iskustvom plovidbe navedenim promatranim područjem, predstavnika lučkih kapetanija koji obavljaju dužnosti u promatranom području, te VTS službenika čiji nadzor pokriva promatrano područje. Također, uzeti su u obzir meteorološki podaci područja, pojasa posebnog opreza, hidrografski podaci te gustoća prometa. Obilježja promatranog područja karakterizira izrazito razvedena obala te gust promet u ljetnim mjesecima.

Pri modeliranju uključeni su svi važni čimbenici utjecaja na pomorsku nezgodu koji se odnose na promatrane vrste brodova. Temelj za odabir početnog scenarija baziran je na izvještajima pomorskih nezgoda promatrane vrste broda u Splitsko-dalmatinskoj županiji.

Napravljeni su sljedeći modeli procjene pojave pomorskih nezgoda:

- potonuće (model sadržava 18 čvorova)
- udar (model sadržava 25 čvorova)
- nasukavanje (model sadržava 28 čvorova)
- sudar (model sadržava 33 čvora)
- požar i eksplozija (model sadržava 13 čvorova).

5.1 Kvalitativni model potonuća

Do potonuća broda u Jadranskom moru dolazi vrlo rijetko. Često se ova vrsta pomorske nezgode ne uvrštava u procjenu rizika zbog rijetkosti događaja na području istočnog dijela Jadranskog mora (Mohović i ostali, 2013). Razlog potonuća broda je gubitak uzgona, stabilnosti ili čvrstoće trupa. Do gubitka uzgona broda dolazi zbog naplavljivanja, a ono može biti uzrokovano prodorom vode kroz otvore broda ili kroz pukotine na trupu broda (Zec, 2001). Mali putnički brodovi su zbog niskog nadvođa najčešće izloženi naplavljivanju kroz otvore pri plovidbi po nemirnome moru. Također, postoji mogućnost pucanja trupa zbog dotrajalosti konstrukcije, a moguće je i pucanje trupa broda zbog inercijalnih sila koje nastaju uslijed posrtanja, zaošijanja i valjanja (Zec, 2001). Većina putničkih brodova u nelinijskoj plovidbi stariji su od 50 godina.

Probabilistički model pojave pomorske nezgode potonuća baziran na uvjetovanoj vjerojatnosti:

$$P\ (\text{potonuća}) = \sum_{j=1}^{k} P(\text{potonuće}|\text{situacija}_j)\ P(\text{situacija}_j), \qquad (7)$$

situacija − označava moguću kombinaciju varijabli

za j =1,…,k, gdje k odgovara broju mogućih situacija.

$P\ (\text{potonuće}|\text{situacija}_j)$ − vjerojatnost da će se nezgoda dogoditi u definiranoj situaciji

određuje se iz statističkih podataka o nezgodi ili na temelju ekspertne procjene.

$P\ (\text{situacija}_j)$ − vjerojatnost da će se određena kombinacija varijabli dogoditi u sustavu

određuje se na temelju ekspertne procjene ili simulacija.

Tablica 5-1: Tablica korijenskih čvorova za model potonuća

Korijenski čvorovi	**Djeca**
Special caution area	Collision, Impact, Fire and explosion, Grounding
Breakdown	Collision, Impact, Fire and explosion, Grounding
Traffic distribution	Collision, Impact, Grounding, Navigational error, Human error
Weather conditions	Collision, Impact, Grounding, Navigational error, Human error
AIS	Collision, Grounding, Navigational error, Human error
Radar	Collision, Grounding, Navigational error, Human error
Navigation in shallow waters	Collision, Impact, Grounding

Kvalitativni pojednostavljeni model potonuća sastoji se od 17 varijabli utjecaja te varijable potonuća.

Model nasukavanja prikazan na slici 5-2 skraćeni je oblik modela potonuća. Originalan model sadržava više od sto varijabli. Kvalitativni modeli sudara, udara, požara i eksplozije te nasukavanja prikazani su kao varijable „Sudar“, „Udar“, „Požar i eksplozija“ te „Nasukavanje“.

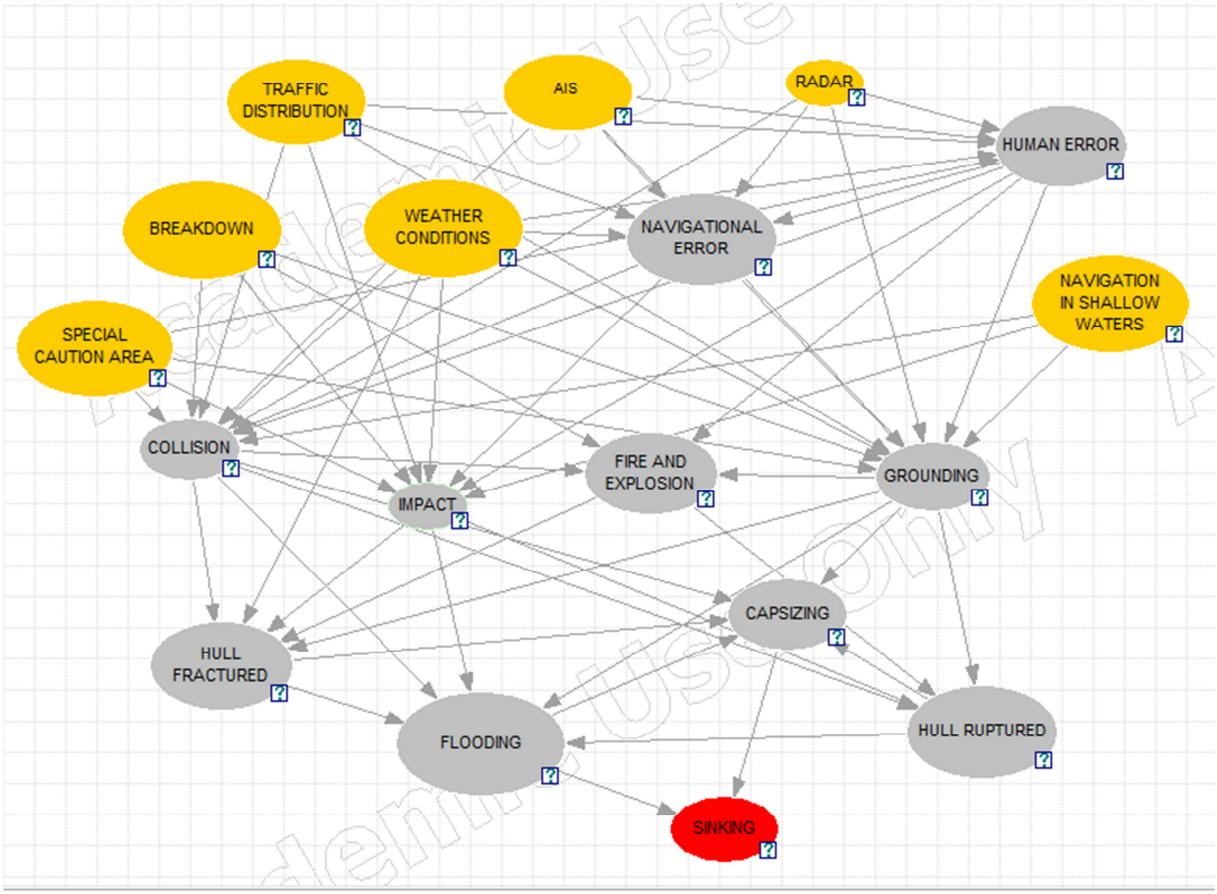

Slika 5-2: Skraćeni kvalitativni model potonuća

Korijenske varijable modela potonuća su: „Navigacija u području posebne opasnosti“, „Tehnička greška“, „Gustoća prometa“, „Vremenski uvjeti“, „AIS“, „Radar“ te „Navigacija u plitkom području“ (korijenske varijable prikazane su žutom bojom). Korijenske varijable imaju utjecaj na većinu varijabli u modelu. Varijable „Tehnička greška“, „Navigacijska pogreška“ te „Ljudska pogreška“ utječu na uvjetovane vjerojatnosti za „Sudar“, „Udar“, „Požar i eksplozija“ te „Nasukavanje“. Varijabla „Navigacija u plitkom području“ utječe na uvjetovanu vjerojatnost varijabli „Nasukavanja“ i „Sudara“ i „Udara“. Varijabla „Navigacija u području posebne opasnosti“ utječe na varijable „Sudara“, „Udar“ i „Nasukavanje“.

Varijabla „AIS“ utječe na uvjetovane vjerojatnosti varijablama „Sudar“, i „Nasukavanje“ kao roditeljska varijabla i na uvjetovane vjerojatnosti varijablama „Navigacijska pogreška“ i „Ljudska pogreška“. Varijabla „Radar“[23] utječe na varijable „Sudar“, i „Nasukavanje“, kao

[23]Prema Pravilima za statutarnu certifikaciju pomorskih brodova, Pomagala za navigaciju Narodne novine, br. 97/2015. „određivanje i prikaz udaljenosti i smjera radarskih transpondera kao i drugih plovila, zapreka, plutača, obrisa obale i navigacijskih oznaka za pomoć u plovidbi i izbjegavanju sudara“ obvezan je za kategorije

roditeljska varijabla. Nadalje, kao i varijabla „AIS“, utječe na uvjetovane vjerojatnosti varijabli „Ljudska pogreška“ i „Navigacijska pogreška“.

Zbog atraktivnosti turističkih sadržaja promatrani brodovi ponekad plove u plitkim područjima. Varijabla koja se odnosi na plovidbu u plitkom području uvrštena je u model kao varijabla koja utječe na uvjetovanu vjerojatnost varijable „Nasukavanje“, a time i na nastajanje pukotina ili proboja trupa.

Roditeljske varijable „Potonuća“ su: varijabla „Naplavljivanja broda“, i „Prevrtanja“ koje su opisane u uvodnom dijelu odlomka kao uzroci potonuća. U modelu potonuća, varijabla „Sudar“ utječe na uvjetovanu vjerojatnost varijabla: „Pukotine“, „Naplavljivanje broda“, „Proboj trupa“ te „Prevrtanje“. Varijabla „Udar“ utječe na uvjetovanu vjerojatnost varijabla: „Pukotina“, „Naplavljivanje broda“ te „Proboj trupa“. Varijabla „Požar i eksplozija“ je roditeljska varijabla varijablama „Pukotina“ te „Proboj trupa“.

5.2 Kvalitativni model udara

Udar broda je sraz broda s objektom koji nije brod. Kod pomorske nezgode udara, smatra se da je brod udario u neki fiksni objekt. Udar se može dogoditi u plovidbi, na sidrištu ili kad je brod privezan. Učestalost sudara je do dva puta manja od učestalosti udara na određenom području (Zec, 2001). Do udara dolazi uglavnom u lučkim područjima, najčešće prilikom plovidbe malim brzinama, zbog pogrešnog izvođenja manevra pristajanja ili odveza broda, a rjeđe se događa kao posljedica oranja sidra u blizini luke. Bitno je obilježje udara da u mnogo manjem broju slučaja dolazi do oštećenja broda koja dovode do potpunog gubitka broda (Zec, 2001). Putnički turistički brodovi manevriraju u lukama čiji su kapaciteti popunjeni. Većina brodova dolazi na privez u popodnevnim satima te ih napuštaju sljedećeg jutra. Zbog prostornog ograničenja ovi brodovi se ponekad vezuju na privezima koji nisu primjereni njihovim veličinama ili se vezuju jedan na drugoga. Navedeni načini plovidbe povećavaju mogućnost od udara.

Probabilistički model pojave pomorske nezgode udara baziran na uvjetovanoj vjerojatnosti:

---

plovidbe od 1 do 6, uz napomenu da ga za kategoriju 5 i 6 moraju imati putnički brodovi duljine preko svega ≥30m ili GT ≥ 150 te svi teretni brodovi GT≥300.

$$P(\text{udar}) = \sum_{j=1}^{k} P(\text{udar}|\text{situacija}_j)P(\text{situacija}_j), \quad (8)$$

situacija − označava moguću kombinaciju vrijednosnih varijabli

za j =1,…,k, gdje k odgovara broju mogućih situacija

$P(\text{udar}|\text{situacija}_j)$ ─ vjerojatnost da će se nezgoda dogoditi u definiranoj situaciji

određuje se iz statističkih podataka o nezgodi ili na temelju ekspertne procjene

$P(\text{situacija}_j)$ − vjerojatnost da će se određena kombinacija varijabli dogoditi u sustavu

određuje se na temelju ekspertne procjene ili simulacija.

Tablica 5-2: Tablica korijenskih čvorova za model udara

Korijenski čvorovi	**Djeca**
Tired	Personal conditions
Incapacitated	Personal conditions
Familiarization	Stress level
Weather conditions	Visibility
Season	Traffic distribution
Day/night	Visual detection, Traffic distribution
Day	Traffic distribution
Safety culture	Other distractions, Maintenance
Sea state	Loss of control, Off course
Wind force	Loss of control, Off course
Wind direction	Loss of control, Off course

Radar	Situational awareness
AIS	Situational awareness

Kvalitativni model udara sastoji se od 25 čvorova zajedno s čvorom udar. Model se formira s početnom pretpostavkom plovidbe broda u luci i odnosi se na udar prilikom manevriranja.

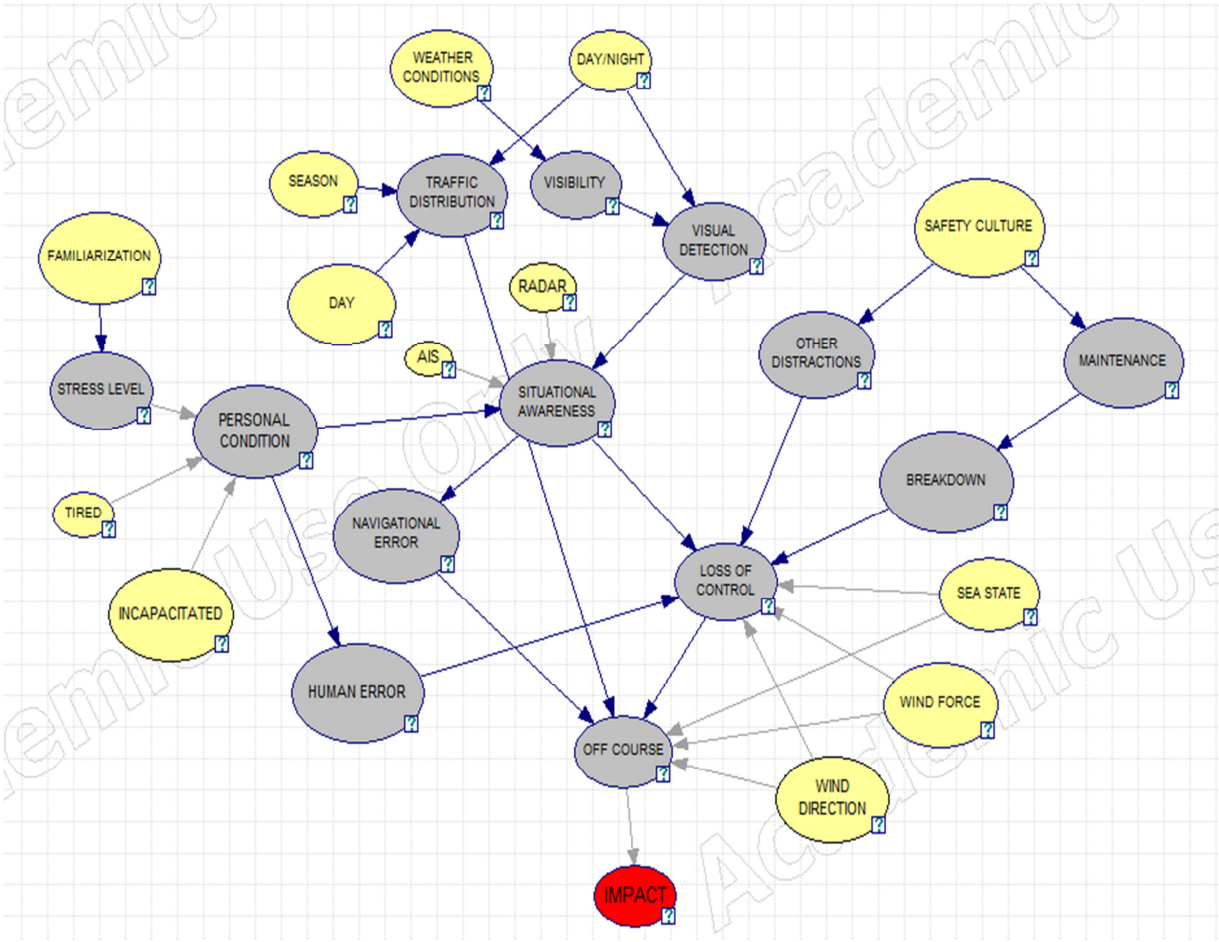

Slika 5-2: Kvalitativni model udara

Od varijabli koje se odnose na ljudski faktor, apriori vjerojatnosti su „Onesposobljenost“ te „Umor“. Te dvije varijable direktno utječu na stanje osobe koja upravlja brodom. „Osobno stanje“ utječe na vjerojatnost pojave „Ljudske pogreške“ te na „Svjesnost o situaciji“. Na „Osobno stanje“ utječe i „Familijarizacija“ kroz varijablu „Razina stresa“.

Apriori varijabla je „Vremenski uvjeti“ koja utječe na „Vidljivost“. „Vidljivost“ utječe na „Vizualnu detekciju“ koja dalje utječe na „Svjesnost o situaciji“ osobe koja upravlja brodom. „Svjesnost o situaciji“ utječe na „Navigacijsku pogrešku“ i „Gubitak kontrole“ .

Apriori varijable „Godišnje doba“, „Dan/noć“ te „Dan u tjednu“ utječu na „Gustoću prometa“ u luci. Primjerice, luka Split ima manju gustoću u noćnim satima, od ponedjeljka do četvrtka čak i u ljetnim mjesecima. Tako se, ovisno o danu u tjednu, smanjuje mogućnost udara zbog lakšeg priveza broda.

„Sigurnosna kultura“ na brodu utječe na „Druga ometanja“ te na „Održavanje broda“. Što je „Sigurnosna kultura“ veća, to je manja vjerojatnost da će osoba koja upravlja brodom za vrijeme pristajanja imati druga ometanja. Osim toga, veća „Sigurnosna kultura“ znači da se brod bolje održava za vrijeme eksploatacije te u vremenu pripreme. Time se direktno utječe na smanjenje tehničke greške koja dovodi do gubitka kontrole i udara.

Hidrometeorološki uvjeti utječu na stanje u luci te povećavaju vjerojatnost od udara. Neke luke su izloženije određenim smjerovima vjetra, u nekima se stvara štiga uslijed određene visine i smjera vala, a u nekima snaga vjetra povećava rizik od udara.

U modelu udara pri manevriranju u luci, varijable „AIS“ i „Radar“ nemaju veliki utjecaj na smanjenje vjerojatnosti udara, ali su uvrštene u model zbog mogućnosti promjene scenarija udara u luci pri manevriranju za neki drugi scenarij udara.

5.3 Kvalitativni model nasukavanja

Nasukavanje je položaj broda u mirovanju, u kojemu brod dira morsko dno u mjeri koja ne dopušta daljnju plovidbu vlastitim strojevima ili opremom, a da se pritom ne ošteti trup, strojevi ili oprema broda (Zec, 2001).

Nasukavanje se može promatrati kroz dva scenarija:

- nasukavanje koje se dogodi dok pogonski stroj radi (događaj koji je uslijedio kada je brod nastavio ploviti nesigurnom rutom zbog ljudske ili tehničke greške)
- nasukavanje koje se dogodi dok pogonski stroj ne radi (događaj koji je uslijedio jer brod nije mogao slijediti sigurnu rutu zbog mehaničke greške, štetnih utjecaja okoliša, problema sa sidrom ili pogreške pri asistenciji (DNV, 2003)).

Mali putnički turistički brodovi u tijeku jednog dana, ovisno o načinu plovidbe i kategoriji plovidbe, najčešće prođu kroz sva stanja plovidbe. Pri nasukavanju promatrana vrsta brodova se može nalaziti u plovidbi, plovidbi u luci ili na sidrištu.

Model prikazan na slici 5-5, odnosi se na model nasukavanja u stanju plovidbe. Pomorska nezgoda nasukavanja prilikom plutanja nije prikazana u ovome modelu.

Preliminarni model nasukavanja sastoji se od 28 varijabli uključujući i varijablu nasukavanje.

Prema izvještajima pomorskih nezgoda glavni uzročnik pomorske nezgode je ljudski faktor te su sukladno tome čvorovi koji se odnose na ljudsku pogrešku i organizacijske segmente namjerno naglašeni u modelu.

Svi korijenski vrhovi te njihova djeca prikazani su u tablici 5-3.

Probabilistički model pojave pomorske nezgode nasukavanja baziran na uvjetovanoj vjerojatnosti:

$$P\,(\text{nasukavanja}) = \sum_{j=1}^{k} P(\text{nasukavanja}_j|\text{situacija}_j)P\,(\text{situacija}_j), \qquad (9)$$

situacija − označava moguću kombinaciju vrijednosnih varijabli

za j =1,…,k, a k odgovara broju mogućih situacija.

$P\,(\text{udar}|\text{situacija}_j)$ − vjerojatnost da će se nezgoda dogoditi u definiranoj situaciji

određuje se iz statističkih podataka o nezgodi ili na temelju ekspertne procjene.

$P\,(\text{situacija}_j)$ − vjerojatnost da će se određena kombinacija varijabli dogoditi u sustavu

određuje se na temelju ekspertne procjene ili simulacija

Tablica 5-3 Tablica korijenskih vrhova za kvalitativni model nasukavanja

Korijenski čvorovi	**Djeca**
Tired	Personal condition
Incapacitated	Personal condition
Familiarization	Stress level
AIS	Situational awareness
Weather	Visibility

Season	Traffic distribution
Day/night	Visual detection
Day	Traffic condition
Safety culture	Other distractions, Maintenance
Sea state	Vessel damage
Wind force	Vessel damage
Wind direction	Vessel damage
Special caution area	Grounding
Navigation in shallow waters	Navigational error
Radar	Situational awareness

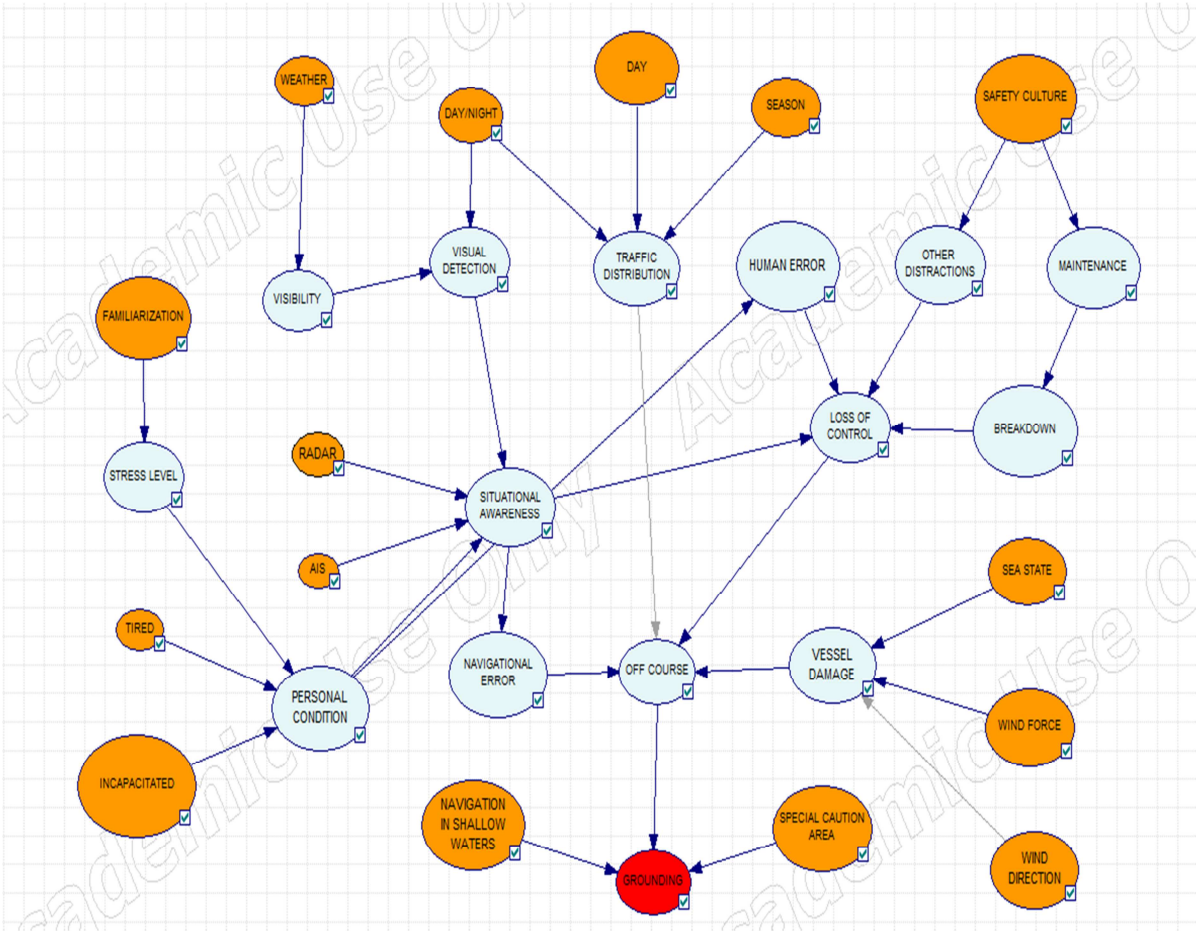

Slika 5-3: Kvalitativni model nasukavanja

„Onesposobljenost“ i „Umor“ utječu na „Osobno stanje“ osobe koja upravlja brodom. Varijabla „Onesposobljenost“, odnosno utjecaj bolesti, alkohola, lijekova, opijata i sl., znatno može utjecati na mogućnost pomorske nezgode. Varijabla „Umor“ odnosi se na posljedicu opterećenost, nedovoljno odmaranje, opterećenost drugim poslovima na brodu itd. Smatra se jednim od najznačajnijih čimbenika koji uzrokuju pomorske nezgode.

„Familijarizacija“ utječe na „Razinu stresa“ osobe koja upravlja brodom. Osoba koja je familijarizirana s brodom i s područjem plovidbe, imat će znatno manju razinu stresa od osobe koja to nije.

VTS monitoring i korištenje AIS uređaja utječu na „Svjesnost o situaciji“. VTS operatori imaju važnu ulogu u službi sigurnosti prometa zbog detekcije mogućih pogubnih situacija.

„Hidrometeorološki utjecaji“ koji povećavaju rizik od pomorske nezgode prikazani su varijablom „Pojava“. Odnose se na hidrometeorološku pojavu koja utječe na vidljivost. Stanja

za čvor pojava su: vedro, djelomično oblačno, oblačno, magla i kiša. Navedena stanja čvora preuzeta su iz izvješća o pomorskim nezgodama MMPI-a.

Nagle promjene vremena u vidu naglog pogoršanja, tzv. nevere, predstavljaju moguć rizik za pojavu pomorske nezgode. Za vrijeme olujnog nevremena koje se događa i u ljetnim mjesecima pri ljetnim depresijama tlaka, dolazi do velikog rizika i za brodove koji su na sidrištu. Karakteristike olujnog nevrijemena su iznenadne i brze promjene meteoroloških elemenata: smjera i brzine vjetra, tlaka zraka, temperature zraka, naoblake i vlage. Često dolazi do grmljavine, tuče i pijavice. U takvim meteorološkim uvjetima zbiva se stanje izrazito smanjene vidljivosti te brodovi bez ugrađenog radara nisu u mogućnosti obavljati sigurnu navigaciju. Ovisno o poziciji na kojoj se brod tada zatekne, za posljedicu može imati pomorsku nezgodu nasukavanja.

„Gustoća prometa“ u ljetnom razdoblju, periodu većeg pomorskog prometa, uvelike ovisi o vremenskim uvjetima. Tako u danima lošeg vremena, gustoća prometa naglo opada jer tada većina brodova čeka u sigurnim marinama i lukama stabilizaciju vremena.

Na gustoću prometa utječu visina vala te smjer vjetra, ali varijable „Visina vala“ i „Smjer vjetra“ nisu povezane s varijablom „Gustoća“ u modelu jer bi tablica uvjetovane vjerojatnosti za čvor gustoća bila neprihvatljivo velika.

„Dan/noć“, „Godišnje doba“ i „Dan u tjednu“ utječu na „Gustoću prometa“. Plovidba promatranih brodova je „sezonska“, većina ih plovi od 1.04. do 31.10. Gustoća prometa u promatranom području u ljetnom razdoblju ovisi o danu u tjednu. Većina brodova kreće na sedmodnevna putovanja petkom ili subotom i sukladno tome planira rutu putovanja, te ukrcaj i iskrcaj putnika obavlja u luci Split. Jedan dio promatranih brodova ukrcaj i iskrcaj putnika obavlja u luci Makarska. Vikendima je znatno smanjena gustoća prometa u lukama pučinskih otoka. Mali putnički brodovi se u vrijeme vikenda nalaze u lukama koje su bliže lukama ukrcaja ili iskrcaja putnika.

Varijabla „Dan/noć“ utječe na vizualnu detekciju. Kod putničkih turističkih brodova polazi se od pretpostavke da je vjerojatnost pojave pomorske nezgode veća za vrijeme dana. Razlog je tome to što se, statistički gledano, većina pomorskih nezgoda dogodila za vrijeme dnevnog svjetla. Dnevnu navigaciju karakterizira i veća aktivnost na moru, odnosno povećana gustoća plovidbe. Noćna navigacija je zahtjevnija, pogotovo u područjima jako razvijene obale, ali noćnu navigaciju karakterizira manja gustoća plovidbe.

Varijabla „Sigurnosna kultura“ ima utjecaj na uvjetovanu vjerojatnost varijable „Održavanje broda“ i „Druga ometanja“.

„Radar“ utječe na uvjetovanu vjerojatnost varijable „Svjesnost o situaciji“ i njegova upotreba može umanjiti vjerojatnost pojave pomorske nezgode.

Varijable „Smjer vjetra“, „Snaga vjetra“ i „Visina vala“ utječu na varijablu „Oštećenje broda“.

Smjer vjetra i snaga vjetra ne utječu direktno na oštećenje broda jer oni prvotno uzrokuju određeno stanje mora (valovi), koje onda može uzrokovati oštećenje broda. Kako se u ovom radu razmatraju i putnički brodovi koji radi atraktivnosti mogu koristiti i snagu vjetra kao pogon, navedene varijable namjerno su direktno vezane na oštećenje broda.

S obzirom na veličinu i karakteristike brodova, stanje mora 4, 5 i 6 s visinom vala od 1,25m do 6 metara može ugroziti sigurnost putnika i broda. More stanja 6 je rijetko na Jadranu u ljetnim mjesecima, ali je moguće, stoga je pri analizi pomorskih nezgoda zabilježeno kao stanje u kojem su se neki brodovi zatekli pri pomorskoj nezgodi te je stavljeno u model. Promatrani brodovi se razlikuju po veličini i konstrukciji, a da bi se generaliziralo stanje varijable utjecaja stanja mora, pretpostavljeno je da stanje mora 4 može imati utjecaj na sigurnost plovidbe.

Prema statističkim podacima smjer vjetra koji je uzročnik najviše pomorskih nezgoda je NE (bura), stoga što dolazi naglo i puše na mahove te često iznenadi nautičare (Mohović i ostali, 2013). Ekspertnom procjenom dobiveni su podaci da je smjer koji najviše ometa plovidbu u ljetnim mjesecima NNW (tramontana) zbog specifičnih strmih valova koje taj vjetar proizvodi.

Varijabla „Plovidba u području posebne opasnosti“ u direktnoj je vezi s varijablom „Nasukavanje“ kako bi se povećao njezin utjecaj na tablicu uvjetovane vjerojatnosti varijable nasukavanje.

5.4 Kvalitativni model sudara

Sudar broda je sraz broda s drugim brodom u plovidbi, na sidrištu ili kada je brod privezan, s oštećenjem trupa ili bez oštećenja trupa jednog ili obaju brodova (Zec, 2001).

Nadalje, prema Zecu, do sudara brodova dolazi isključivo krivnjom časnika jednog ili, što je češće, obaju brodova koji su sudjelovali u sudaru.

Pri sudaru dvaju brodova na moru oni mogu, ali i ne moraju potonuti. Brod koji udara u drugi brod neće imati toliko velike šanse potonuti jer je udarac primio u pramčanom dijelu broda. Brod koji je primio udarac u bok ima veću šansu da izgubiti stabilitet i doći u opasnost od potonuća.

Prema DNV (2003) sudar će se dogoditi ako brodovi ne promjene sudarne kursove u 20 % slučajeva. Ako oba broda promijene kursove, postoji vjerojatnost od 1E-05 da će ta situacija rezultirati sudarom. Sudar za vrijeme plovidbe može se razviti u požar i eksploziju, potonuće te onečišćenje (Slika 5-4).

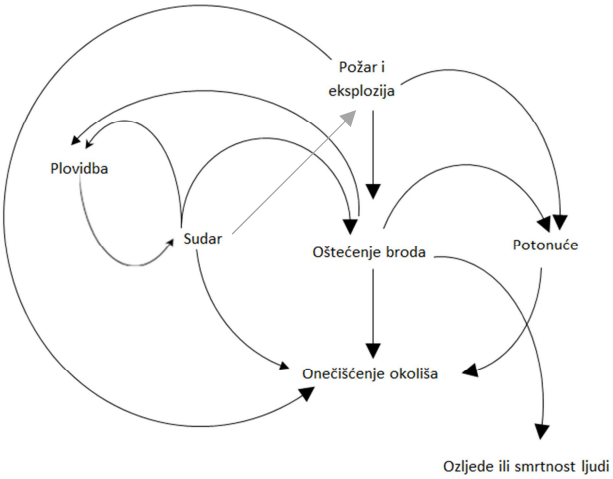

Slika 5-4: Moguće posljedice sudara za vrijeme plovidbe

Vjerojatnost sudara na određenom području u nekom vremenu definirana je dvijema neovisnim vjerojatnostima

$$P = P_a \cdot P_b , \tag{10}$$

P_a – broj sudarnih kandidata

P_b – uvjetovana vjerojatnost sudara u slučaju nepoduzimanja manevra izbjegavanja (Macduff, 1974).

Razlog nepoduzimanja mjera za izbjegavanje sudara dok se brod nalazi u sudarnom kursu može biti rezultat tehničke greške, ljudske pogreške ili vanjskih faktora (Hanninen, Kujala, 2009).

Geometrijska vjerojatnost ovisi o geometrijskim parametrima morskog područja, veličini broda, količini prometa, brzini broda, kursu broda i uvjetovanoj vjerojatnosti vještine osobe koja upravlja brodom. Uvjetovana vjerojatnost može biti procijenjena na temelju podataka o povijesnim događajima prikupljenim na različitim lokacijama, potom implementiranih u područje interesa. Uvjetovana vjerojatnost za različite scenarije sudara nije ista.

Probabilistički model pojave pomorske nezgode sudara baziran na uvjetovanoj vjerojatnosti:

$$P(\text{sudar}) = \sum_{j=1}^{k} P(\text{sudara}|\text{situacija}_j)P(\text{situacija}_j) \qquad (11)$$

situacija − označava moguću kombinaciju vrijednosnih varijabli

za j =1,…,k, gdje k odgovara broju mogućih situacija.

$P(\text{sudar}|\text{situacija}_j)$ − vjerojatnost da će se nezgoda dogoditi u definiranoj situaciji

(određuje se iz statističkih podataka o nezgodi ili na temelju ekspertne procjene).

$P(\text{situacija}_j)$ − vjerojatnost da će se određena kombinacija varijabli dogoditi u sustavu

(određuje se na temelju ekspertne procjene ili simulacija).

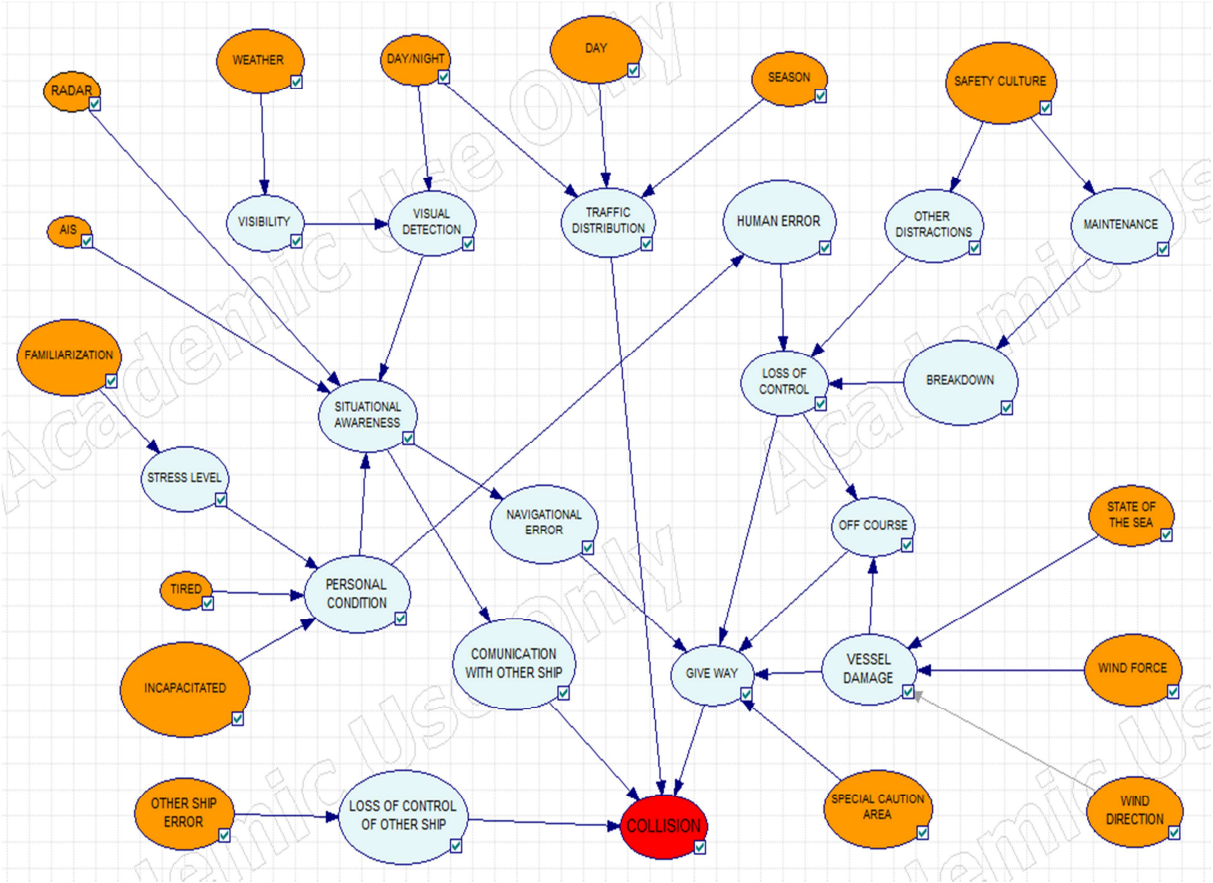

Slika 5-5: Kvalitativni model sudara

Kvalitativni model sudara sadržava 35 varijabli uključujući varijablu sudara, sličan je modelu nasukavanja (Slika 5-7). Varijable koje se odnose na organizacijske i ljudske čimbenike su jednake.

Model sudara sadržava varijablu korijenskog vrha „Pogreška drugog broda“ čije je dijete varijabla „Gubitak kontrole drugog broda“. Podrazumijeva se da korijenska varijabla „Pogreška drugog broda“ sadržava sve varijable koje utječu na uvjetovanu vjerojatnost varijable „Pogreška prvog broda“ te je određena ekspertnom procjenom. Varijabla „Izbjegavanja“ odnosi se na plovidbu ili davanje prednosti drugom brodu sukladno pravilima o izbjegavanju sudara. Varijable koje utječu na tablicu uvjetovane vjerojatnosti varijable „Izbjegavanja“ su: „Plovidba u području posebnog opreza“, „Oštećenje broda“, „Kada brod ne plovi po planiranom kursu“, „Gubitak kontrole“ te „Navigacijska pogreška“. Korijenski čvoroviza model sudara prikazani su u tablici 5-4.

Tablica 5-4: Tablica korijenskih čvorova za kvalitativni model sudara

Korijenski čvorovi	**Djeca**
Tired	Personal condition
Incapacitated	Personal condition
Familiarization	Stress level
AIS	Situational awareness
Weather	Visibility
Season	Traffic distribution
Day/night	Visual detection, Traffic distribution
Day	Traffic distribution
Safety culture	Other distraction, Maintenance
Sea state	Vessel damage
Wind force	Vessel damage
Wind direction	Vessel damage
Special caution area	Give way

Other vessel error	Loss of control of other vessel
Radar	Situational awareness

5.5 Kvalitativni model požara i eksplozije

Požar na brodu je nekontrolirano gorenje cijelog broda ili njegovih dijelova, dok je eksplozija trenutačno izgaranje zapaljivih plinova ili goriva broda (Zec, 2001). Požar i eksplozija mogu se dogoditi u plovidbi, na sidrištu i u luci na vezu.

10 % svih nezgoda otpada na eksplozije (Zec, 2001). Uzroci mogu biti razni, od neprikladnih radnih postupaka posade broda do nemara putnika. Na slici 5-6 prikazan je pojednostavljen model požara i eksplozije koji sadržava 13 varijabli, uključujući varijablu požara i eksplozije. Cjeloviti model obuhvaća modele sudara i udara koji su u skraćenom modelu prikazani kao varijable budući da pomorske nezgode sudara i udara mogu dovesti do požara i eksplozije.

Probabilistički model pojave pomorske nezgode požara i eksplozije baziran na uvjetovanoj vjerojatnosti:

$$P(\text{požar i eksplozija}) = \sum_{j=1}^{k} P(\text{požar i eksplozija}_j|\text{situacija}_j)P(\text{situacija}_j) \qquad (12)$$

situacija − označava moguću kombinaciju vrijednosnih varijabli

za j =1,…,k, gdje k odgovara broju mogućih situacija.

$P(\text{sudar}|\text{situacija}_j)$ − vjerojatnost da će se nezgoda dogoditi u definiranoj situaciji

(određuje se iz statističkih podataka o nezgodi ili na temelju ekspertne procjene).

$P(\text{situacija}_j)$ − vjerojatnost da će se određena kombinacija varijabli dogoditi u sustavu

(određuje se na temelju ekspertne procjene ili simulacija).

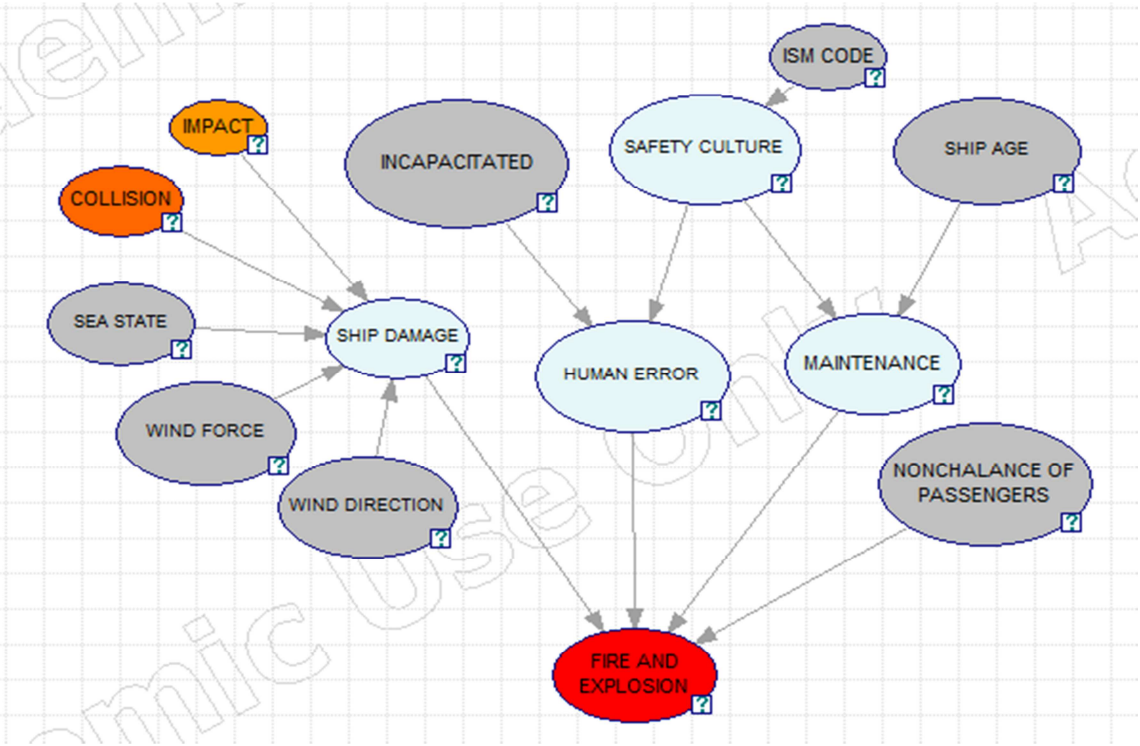

Slika 5-6: Skraćeni kvalitativni model požara i eksplozije

U tablici 5-5 prikazani su korijenski vrhovi te djeca kvalitativnog modela požara i eksplozije. Varijable: „Smjer vjetra“, „Snaga vjetra“, „Visina vala“, „Sudar“ i „Udar“ utječu na uvjetovanu vjerojatnost varijable „Oštećenje broda“. Varijabla „Onesposobljenost“ utječe na varijablu „Ljudska pogreška“. Varijabla „ISM pravilnik“ utječe na varijablu „Sigurnosna kultura“. Varijabla „Starost broda“ utječe na varijablu „Održavanje broda“. „Nemar putnika“ kao varijabla koja se do sada nije koristila direktno utječe na mogućnost pojave požara i eksplozije. „Nemar putnika“ može direktno izazvati požar na brodu neprimjerenom upotrebom vatre, kuhala, neprimjerenim bacanjem opušaka od cigareta itd. Neprikladni radni postupci posade su u modelu požar i eksplozija prikazani pod varijablom „Ljudska pogreška“.

Varijabla „Sigurnosna kultura“ utječe na uvjetovanu vjerojatnost varijable „Održavanje broda“. Star i loše održavan brod ima veću vjerojatnost pojave pomorske nezgode požara ili eksplozije.

Onesposobljenost člana posade direktno utječe na varijablu „Ljudska pogreška“ te mogućnost požara.

Požar i eksplozija mogu nastati kao posljedica oštećenja broda uslijed loših hidrometeoroloških utjecaja što je prikazano kroz varijable: „Visina vala“ , „Smjer vjetra“ i „Snaga vjetra“.

Tablica 5-5: Tablica korijenskih vrhova za skraćeni model požara i eksplozije

Korijenski čvorovi	**Djeca**
Wind force	Vessel damage
Sea state	Vessel damage
Wind direction	Vessel damage
Collision	Vessel damage
Impact	Vessel damage
Incapacitated	Human error
ISM Code	Safety culture
Age	Maintenance
Passenger nonchalance	Fire and explosion

6. KVANTITATIVNI MODELI NASUKAVANJA I SUDARA BRODOVA

Nakon konstruiranja kvalitativnih modela slijedi kvantificiranje modela. Kvantificiranje modela je unošenje apriori te aposteriori vjerojatnosti čvorova. Cilj izrade kvantitativnog modela je računanje vjerojatnosti događaja pomorskih nezgoda za izabrane scenarije sudara i nasukavanja brodova. Kvantificiranje čvorova te izrada tablica uvjetovanih vjerojatnosti moguća je na dva načina:

- korištenjem tehnika na temelju mišljenja eksperata o vjerojatnosti pojave scenarija koji je prezentiran u modelu (DNV, 2003; Hanninen i ostali, 2004)
- korištenjem statističkih podataka za svaki scenarij u modelu.

Autori A. Mazaheri i ostali u radu iz 2016. godine navode kako korištenje isključivo statističkih podataka doprinosi nesigurnosti samog modela. Kao jedan od razloga za takvo razmišljanje spominju brojne nezgode koje se ne prijavljuju i kao takve ne ulaze u statističku obradu. Drugi razlog je veliki broj nezgoda koje nisu istražene. Treći razlog je tvrdnja da je svaki lanac događaja koji je doveo do pomorske nezgode drugačiji te da zamjenjivost događaja koja je preduvjet za procjenu vjerojatnosti nije valjana. Zbog gore navedenih ograničenja u ovom su radu za kvantificiranje modela korišteni statistički podaci, ali i procjena eksperata. Statistički podaci su korišteni za određivanje apriori vrijednosti podacima koji se odnose na utjecaje vremenskih čimbenika, hidrometeoroloških čimbenika te nekih brodskih čimbenika. Sve ostale vrijednosti u modelu kao i tablice uvjetovanih vjerojatnosti temelje se na procjeni eksperata.

Ekspertno mišljenje se uvelike koristi pri modeliranju ljudskih i organizacijskih faktora zbog manjka podataka potrebnih za kvantificiranje varijabli. Kvantificiranje modela izvršeno je intervjuiranjem eksperata te direktnim sudjelovanjem samih eksperata u izradi modela.

Prilikom izrade mreže, eksperti su u njoj sudjelovali tako što su odgovarali na jednostavna pitanja, primjerice: „Što uzrokuje stres na mostu?“, „Koji su uzroci neizbjegavanja drugog broda?“, „Koji su uzroci gubitka kontrole?“, „Što utječe na loše psihičko i fizičko stanje osobe koja upravlja brodom?“, „Koji su najutjecajniji čimbenici, uzročnici nasukavanja?" Pri dodjeljivanju vrijednosti za tablicu uvjetovane vjerojatnosti, ekspertima su ponuđene jedna ili dvije važne uvjetovane vjerojatnosti čvora o kojoj su diskutirali. Eksperti su zaokruživali

vrijednosti koje smatraju adekvatnima za pojedine situacije. Pritom je korištena tehnika autora Van der Gaag kojom je moguće na brz i jednostavan način dodijeliti vrijednosti nekoliko stotina ili tisuća uvjetovanih vjerojatnosti ekspertnog mišljenja.

Metoda korištena za dodjeljivanje vrijednosti je „Probabilistička skala“ prikazana na slici 6-1. Probabilistička skala je vodoravna ili okomita linija sa numeričkim vrijednostima. Vrijednosti ponuđene ekspertima su: (0,1, 0,25, 0,5, 0,75, 0,9). U tablice uvjetovane vjerojatnosti unesena je dominantna vrijednost eksperata (modus).

Opis skale za dodjeljivanje vrijednosti:

0,10 – vrlo malo vjerojatno (gotovo nemoguće)

0,25 – malo vjerojatno

0,5 – pola-pola

0,75 – vrlo vjerojatno

0,90 – vrlo visoka vjerojatnost (gotovo sigurno)

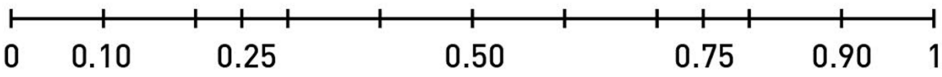

Slika 6-1: Probabilistička skala korištena za dodjeljivanje vrijednosti uvjetovanih vjerojatnosti

Kao alat za izradu Bayesovih mreža te njihovo kvantificiranje korišten je *GeNie Software (Graphical Network Inteface)* koji pruža grafičko korisničko sučelje za jednostavnu izgradnju Bayesovih mreža.

6.1 Kvantitativni model nasukavanja

Model nasukavanja sadržava 15 korijenskih varijabli. Korijenske varijable u modelu nasukavanja prikazane su narančastom bojom radi lakšeg uočavanja.

Pri izradi modela čvorovi za koje postoje statističke vrijednosti stavljene su u ulogu roditelja kada je to bilo moguće, vrijednosti stanja čvorova koji se odnose na ljudske čimbenike i dio organizacijskih čimbenika preuzete su iz drugih izvora (DNV, 2003; Hanninen i ostali 2014, Mazahari i ostali 2016). Vrijednosti stanja čvorova koje se odnose na promatrano područje te promatrane brodove, a nisu statistički obrađene u bazama podataka niti u literaturi, dobivene su ekspertnom procjenom.

Korijenski vrhovi „Godišnje doba“, „Pojava“, „Doba dana“, „Dan“, „Visina vala“, „Snaga vjetra“, „Smjer vjetra“ te njihove apriori vrijednosti napravljene su na temelju statističke obrade 1653 pomorske nezgode koje su se dogodile u razdoblju od 2010. do 2015. godine. Podaci o pomorskim nezgodama prikupljeni su iz baze podataka MMPI-a. Korijenski vrhovi „Familijarizacija“, „Plovidba u području posebne opasnosti“ i „Plovidba u plitkom području“ određeni su na temelju ekspertne procjene. Korijenski vrhovi čije su vrijednosti preuzete iz drugih izvora su: „Umor“, „Onesposobljenost“ i „Sigurnosna kultura“. Vrijednosti za tablice uvjetovane vjerojatnosti napravljene su na temelju logičkog odlučivanja te ekspertne procjene.

Apriori vrijednosti čvora „Familijarizacija“ prikazano je na slici 6-2. Stanja koja može poprimiti čvor „Familijarizacija“ su: familijariziran, srednje familijariziran te nefamilijariziran. Familijarizacija po definiciji utječe na razinu stresa kod osobe koja upravlja brodom te je u modelu prikazana kao roditelj čvoru „Razina stresa“. Vrijednosti za čvor „Familijarizacija“ preuzete su iz studije DNV (2003) te potvrđene ekspertnom procjenom. Smatra se da većina osoba koje upravljaju promatranim brodovima vrlo dobro upoznata s područjem plovidbe te brodom kojim upravlja. Tablica uvjetovane vjerojatnosti za razinu stresa prikazana je na slici 6-3. Moguće vrijednosti za čvor „Razina stresa“ su: visok i standardan. Tablica prikazuje sve moguće kombinacije događaja, u ovom slučaju 6 mogućih kombinacija za čvor „Razina stresa“. Moguće vrijednosti koje može poprimiti čvor „Razina stresa“ kreću se od najmanje 10 %, kada osoba koja upravlja brodom familijarizirana, do 75 %, kada je osoba koja upravlja brodom nije familijarizirana. Prilikom dodjeljivanja vrijednosti u tablici uvjetovane vjerojatnosti za „Razinu stresa“ uzeti su u obzir i svi ostali čimbenici koji mogu dovesti do povećane razine stresa kod osobe koja upravlja brodom te su stoga stanja koje može poprimiti čvor „Razina stresa“: visok i standardan.

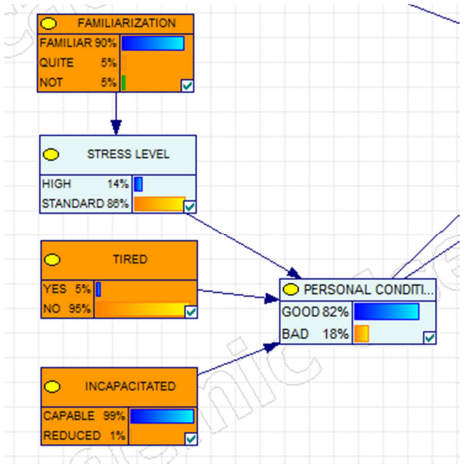

Slika 6-2: Dio kvantitativnog modela nasukavanja koji se odnosi na osobno stanje osobe koja upravlja brodom

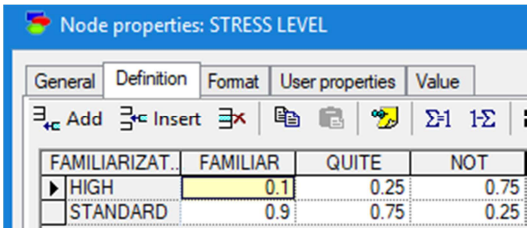

Slika 6-3: Uvjetovana vjerojatnost za čvor „Razina stresa“

Na osobno stanje osobe koja upravlja brodom utječe razina stresa, umor ili nesposobnost. Apriori vrijednosti za čvor „Umor“ preuzete su iz DNV (2003) te su potvrđene ekspertnim mišljenjem. Smatra se da većina promatranih brodova noći u lukama te da osoba koja upravlja brodom ima dovoljno vremena za odmor. Vrijednosti koje imaju stanja čvora umor su: 0,05 umoran, 0,95 osoba koja upravlja brodom nije umorna. Vrijednosti za varijablu onesposobljenost iznose: 0,01 i 0,99 što su stanja preuzeta od Mazaheri (2016), potvrđena ekspertnom procjenom. Smatra se da su stanja onesposobljenosti rijetkost kod osoba koje upravljaju brodom. Tablica uvjetovane vjerojatnosti za čvor „Osobno stanje“ prikazana je na slici 6-4.

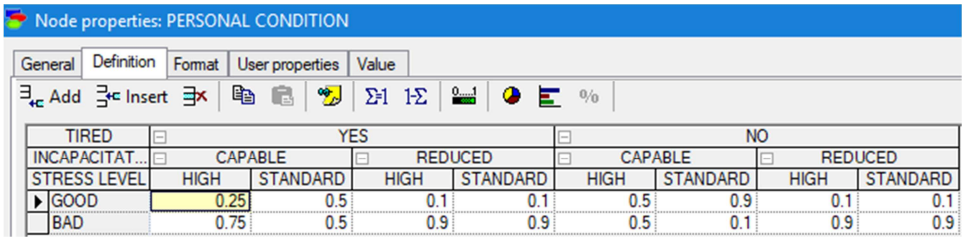

Slika 6-4: Uvjetovana vjerojatnost za čvor „Osobno stanje“

U primjeru na slici 6-5. prikazana je situacija kada su vrijednosti stanja čvorova „Razina stresa“ i „Umor“ postavljene na 100 %, tada vrijednosti za čvor „Osobno stanje“ padaju s 82 % na 25 %.

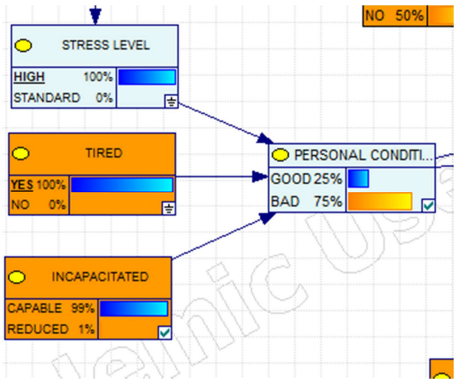

Slika 6-5: Prikaz vrijednosti čvora „Osobno stanje“ nakon što su vrijednosti čvorova „Umor“ i „Razina stresa“ postavljene na 100 %

Na čvor „Vizualna detekcija“ u modelu nasukavanja utječu tri čvora: „Vrijeme“, „Vidljivost“ te čvor „Dan/noć“. Vrijednosti za apriori čvor „Pojava“ dobivene su iz statističkih podataka o hidrometeorološkim uvjetima za vrijeme pomorskih nezgoda te je na temelju njih napravljena tablica uvjetovane vjerojatnosti za čvor „Vidljivost“. Stanja koja može poprimiti čvor „Vidljivost“ su: odlična, dobra, srednja, slaba i vrlo loša.

Struktura mreže za vizualnu detekciju prikazana je na slici 6-6., dok su vrijednosti za tablicu uvjetovane vjerojatnosti dobivene ekspertnom procjenom prikazane na slici 6-7.

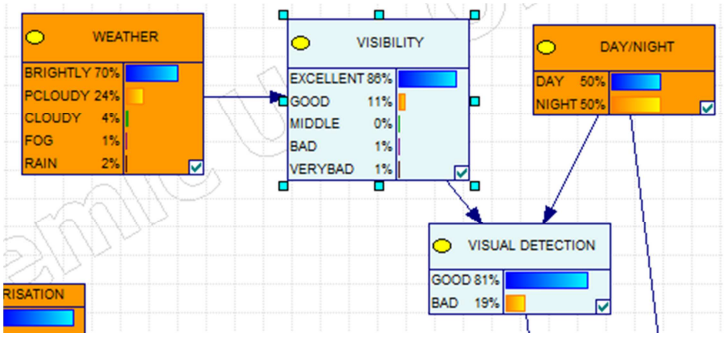

Slika 6-6: Dio kvantitativnog modela nasukavanja koji se odnosi na vizualnu detekciju osobe koja upravlja brodom

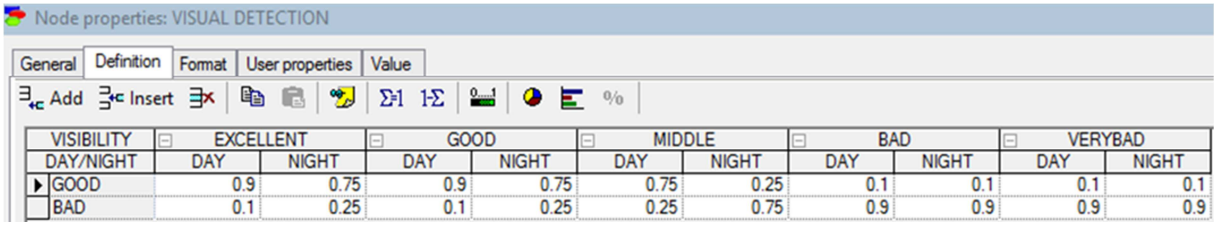

VISIBILITY	EXCELLENT		GOOD		MIDDLE		BAD		VERYBAD	
DAY/NIGHT	DAY	NIGHT	DAY	NIGHT	DAY	NIGHT	DAY	NIGHT	DAY	NIGHT
GOOD	0.9	0.75	0.9	0.75	0.75	0.25	0.1	0.1	0.1	0.1
BAD	0.1	0.25	0.1	0.25	0.25	0.75	0.9	0.9	0.9	0.9

Slika 6-7: Uvjetovane vjerojatnost za čvor „Vizualna detekcija“

Čvor „Gustoća prometa“ može poprimiti stanja: velika i mala zbog sezonskog načina plovidbe u promatranom području. Tablica uvjetovane vjerojatnosti za čvor „Gustoća prometa“ prikazuje utjecaj doba dana, dana i noći te godišnjeg doba na gustoću prometa, a odnos navedenih varijabli prikazan je na slici 6-8. Vrijednosti za apriori čvorove „Dan/noć“, „Godišnje doba“ i „Doba dana“ dobivene su iz statističkih podataka koji se odnose na sve putničke brodove. Korišteni su statistički podaci MMPI-a. Prilikom statističke analize promatrani su podaci za razdoblje od 2010. do 2015. Podaci prije 2010. godine nemaju odvojene vrijednosti za putničke brodove. Vrijednosti za pojavu pomorske nezgode u ljetnom periodu za sve brodove iznosi 85,7 %, dok vrijednost za putničke brodove iznosi 75,8 %. Ljeto se u ovom slučaju računa od 1. travnja do 31. listopada (prema datumu proširenja kategorije nacionalne obalne plovidbe) kojom plovi 15,1 % promatranih brodova. Pri statističkoj obradi podataka posebno su računane vrijednosti za putničke brodove te za sve

vrste brodova. Zbog nedovoljnog broja podataka za određene vrijednosti stanja čvorova, korišteni su podaci o svim vrstama brodova, što je posebno napomenuto.

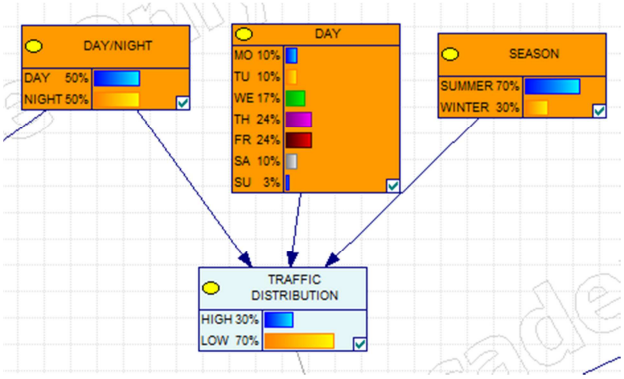

Slika 6-8: Dio kvantitativnog modela nasukavanja koji se odnosi na gustoću prometa

Čvor „Svjesnost o situaciji“ može poprimiti stanja: da i ne. Na čvor „Svjesnost o situaciji“ utječu roditeljski čvorovi: „Radar“, „AIS“, „Osobno stanje“ i „Vizualna detekcija“. Pri izradi tablice uvjetovane vjerojatnosti naglašen je utjecaj radara i AIS uređaja na svjesnost o situaciji. Na slici 6-9. prikazan je dio Bayesove mreže koji se odnosi na svjesnost o situaciji u kojem početne vrijednosti za čvor „Radar“ i „AIS“ iznose 50 %. Budući da korištenje radara[24] i AIS uređaja[25] nije obvezno za sve putničke brodove, početne vrijednosti su stavljene na 50 %.

Na slici 6-10 prikazana su stanja svjesnosti situacije nakon promjene stanja radara i AIS-a na 100 %. Prema modelu, korištenjem radara i AIS uređaja, svjesnost o situaciji osobe koja upravlja brodom povećava se za 10 %.

[24] Prema Pravilima za statutarnu certifikaciju pomorskih brodova, Pomagala za navigaciju, Narodne novine, br. 97/2015., korištenje radara je obvezno u kategorijama plovidbe od 1 do 6 te za sve brodove veće od 300 BT uz napomenu da je za „određivanje i prikaz udaljenosti i smjera radarskih transpondera kao i drugih plovila, zapreka, plutača, obrisa obale za pomoć u plovidbi i izbjegavanje sudara za područje plovidbe 5 i 6 radar obvezan na putničkim brodovima duljine preko svega ≥30 ili GT ≥150“.

[25] Prema Pravilima za statutarnu certifikaciju pomorskih brodova, Pomagala za navigaciju, Narodne novine, br. 97/2015., AIS uređaj obvezan je u svim kategorijama plovidbe uz napomenu da je na putničkim brodovima GT≥150 obvezan u područjima plovidbe 1-4, a za putničke brodove GT≥300 obvezan je i u područjima plovidbe 5 - 8.

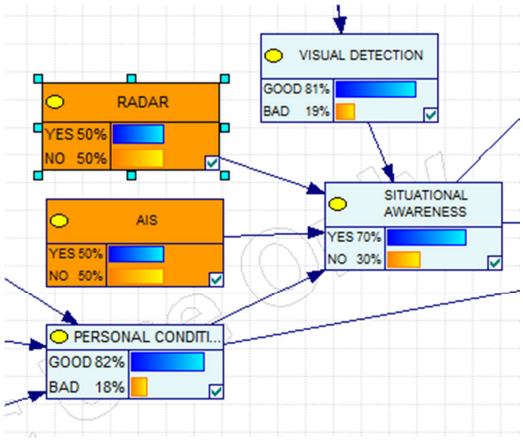

Slika 6-9: Dio kvantitativnog modela nasukavanja koji se odnosi na svjesnost o situaciji

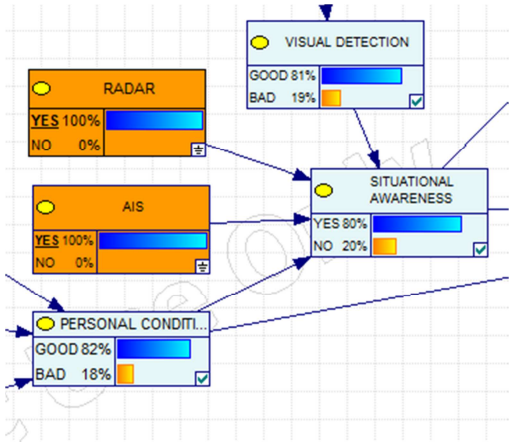

Slika 6-10: Primjer čvora „Svjesnost o situaciji“ kada su vrijednosti čvorova „Radar“ i „AIS“ postavljene na 100 %

Čvor „Sigurnosna kultura“ može poprimiti tri stanja: odlično, standardno te slabo. Čvor „Sigurnosna kultura“ utječe na čvor „Održavanje broda“ i čvor „Druga ometanja“. Tablice uvjetovane vjerojatnosti za ta dva čvora prikazane su na slikama 6-11. i 6-12.

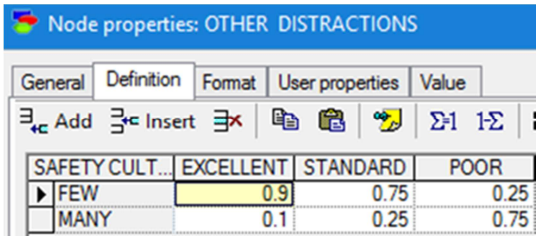

Slika 6-11: Uvjetovana vjerojatnost za čvor „Druga ometanja“

Čvor „Navigacija u plitkom području“ postavljen je u Bayesovoj mreži na način da ima veliki utjecaj na tablicu uvjetovanje vjerojatnosti čvora „Nasukavanje“.

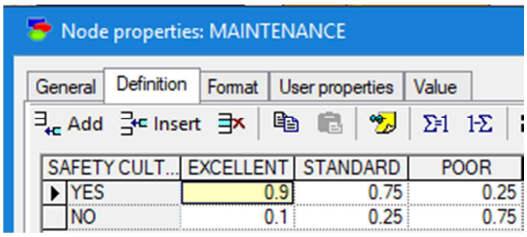

Slika 6-12: Uvjetovana vjerojatnost za čvor „Održavanje“

Čvor „Ljudska pogreška“ može poprimiti stanja: da i ne. Na ljudsku pogrešku utječe osobno stanje osobe koja upravlja brodom. Tablica uvjetovane vjerojatnosti napravljena je na temelju ekspertne procjene i prikazana je na slici 6-13.

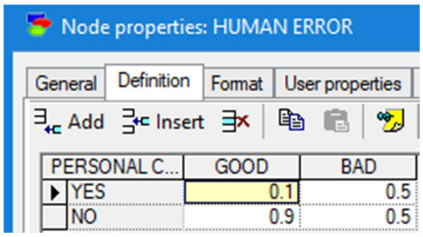

Slika 6-13: Uvjetovana vjerojatnost za čvor „Ljudska pogreška“

Utjecaj održavanja broda na tehničku grešku prikazan je u tablici uvjetovane vjerojatnosti na slici 6-14. Vrijednosti za navedenu tablicu dobivene su ekspertnom procjenom.

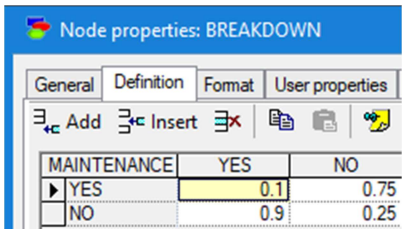

Slika 6-14: Uvjetovana vjerojatnost za čvor „Tehnička greška“

Na čvor „Gubitak kontrole“ utječu četiri čvora: „Ljudska pogreška“, „Svjesnost o situaciji“, „Druga ometanja“ te „Tehnička greška“. Dio modela nasukavanja koji se odnosi na gubitak kontrole prikazan je na slici 6-15. Tablica uvjetovane vjerojatnosti za čvor „Gubitak kontrole“ dobivena je ekspertnom procjenom i prikazana je na slici 6-16.

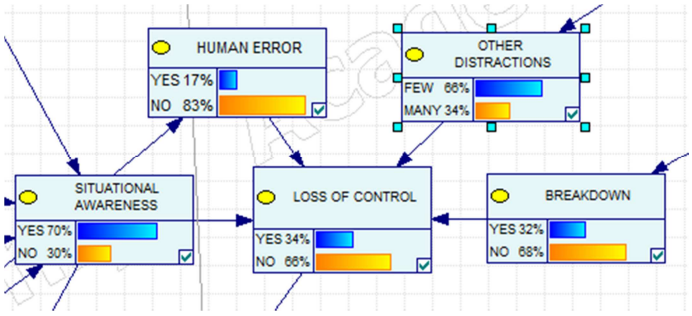

Slika 6-15: Dio kvantitativnog modela nasukavanja koji se odnosi na gubitak kontrole

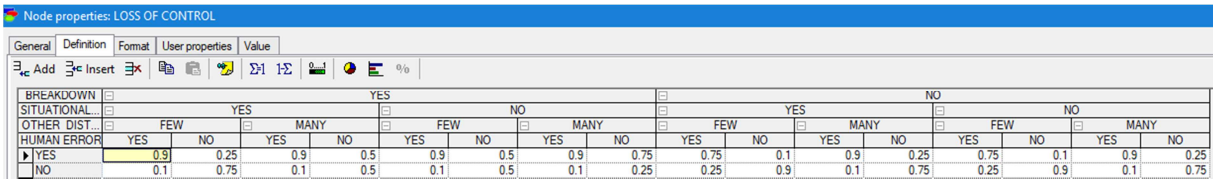

Slika 6-16: Uvjetovana vjerojatnosti za čvor „Gubitak kontrole“

Na čvor „Oštećenje broda“ utječu čvorovi: „Snaga vjetra“, „Stanje mora“ te „Smjer vjetra“. Podaci za navedene tri korijenske varijable dobivene su statističkom obradom baze podataka MMPI-a za stanje mora, smjer vjetra te visine vala za vrijeme pomorskih nezgoda putničkih brodova. Stanja koja može poprimiti čvor „Stanje mora“ preuzeta su iz izvješća pomorskih nezgoda: mirno, umjereno, valovito, uzburkano i teško.

Stanja koja može poprimiti čvor „Snaga vjetra“ su: tišina, povjetarac, umjereni vjetar, jaki vjetar te olujni vjetar. Stanja koja može poprimiti čvor „Smjer vjetra“ su: sjeverni, sjeveroistočni te južni vjetar. Stanja koja može poprimiti čvor „Stanje mora“ su: mirno, umjereno valovito, valovito, uzburkano i teško.

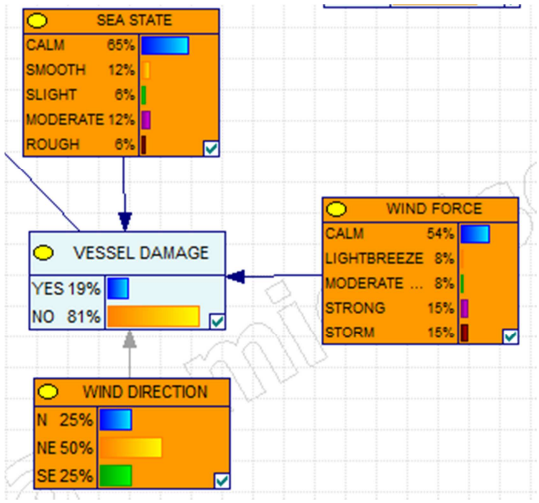

Slika 6-17: Dio kvantitativnog modela nasukavanja koji se odnosi na oštećenje broda

„Navigacijska pogreška“ je dijete čvora „Svjesnost o situaciji“. Tablica uvjetovane vjerojatnosti za čvor „Navigacijska pogreška“ prikazana je na slici 6-18. Tablica uvjetovane vjerojatnosti za navigacijsku pogrešku napravljena je na temelju ekspertnog mišljenja.

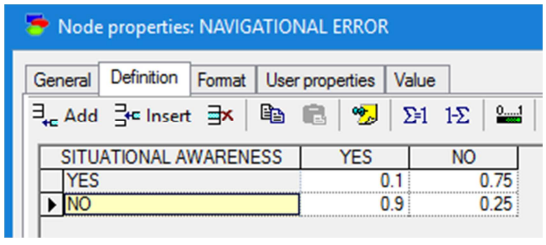

Slika 6-18: Uvjetovana vjerojatnost za čvor „Navigacijska pogreška“

Na čvor „Kada brod ne plovi po planiranom kursu“ utječu čvorovi: „Navigacijska pogreška“, „Gustoća prometa“, „Gubitak kontrole“ te „Oštećenje broda“ (Slika 6-19). Tablica uvjetovane vjerojatnosti za čvor „Kada brod ne plovi po planiranom kursu“ napravljena je na temelju podataka dobivenih ekspertnom procjenom te je prikazana na slici 6-20.

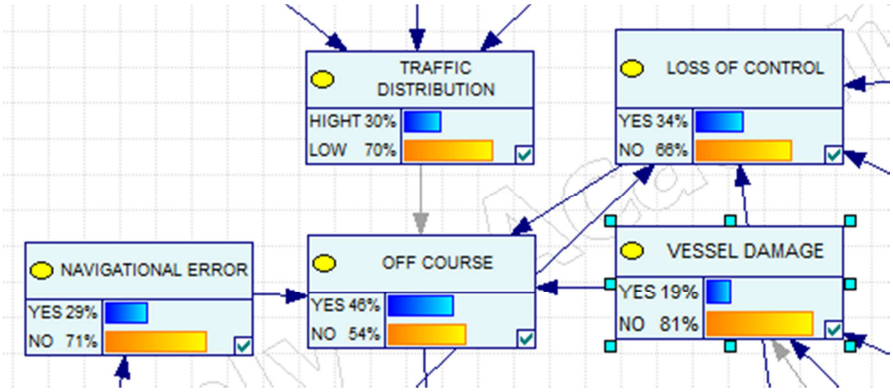

Slika 6-19: Dio kvantitativnog modela nasukavanja kada brod ne plovi po planiranom kursu

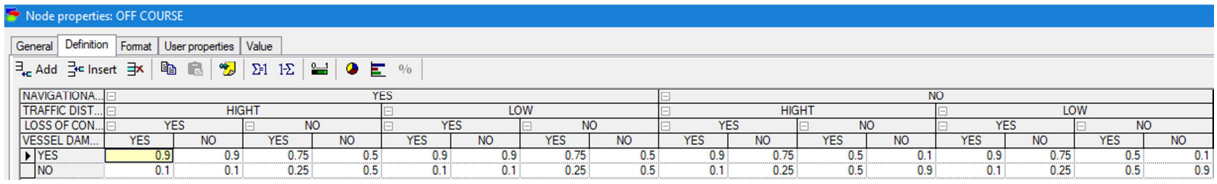

Slika 6-20: Uvjetovana vjerojatnost za čvor „Kada brod ne plovi po planiranom kursu“

Na čvor „Nasukavanje“ u modelu utječu čvorovi: „Navigacija u plitkom području“, „Kada brod ne plovi po planiranom kursu“ te „Plovidba u području posebnog opreza“.

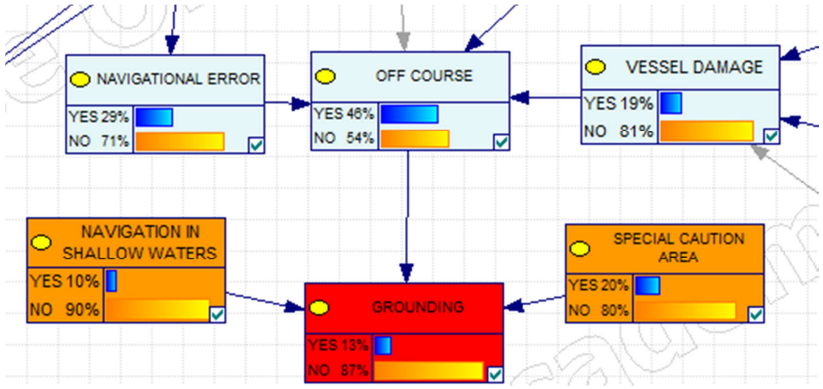

Slika 6-21: Dio kvantitativnog modela nasukavanja koji se odnosi na plovidbu u plitkom području

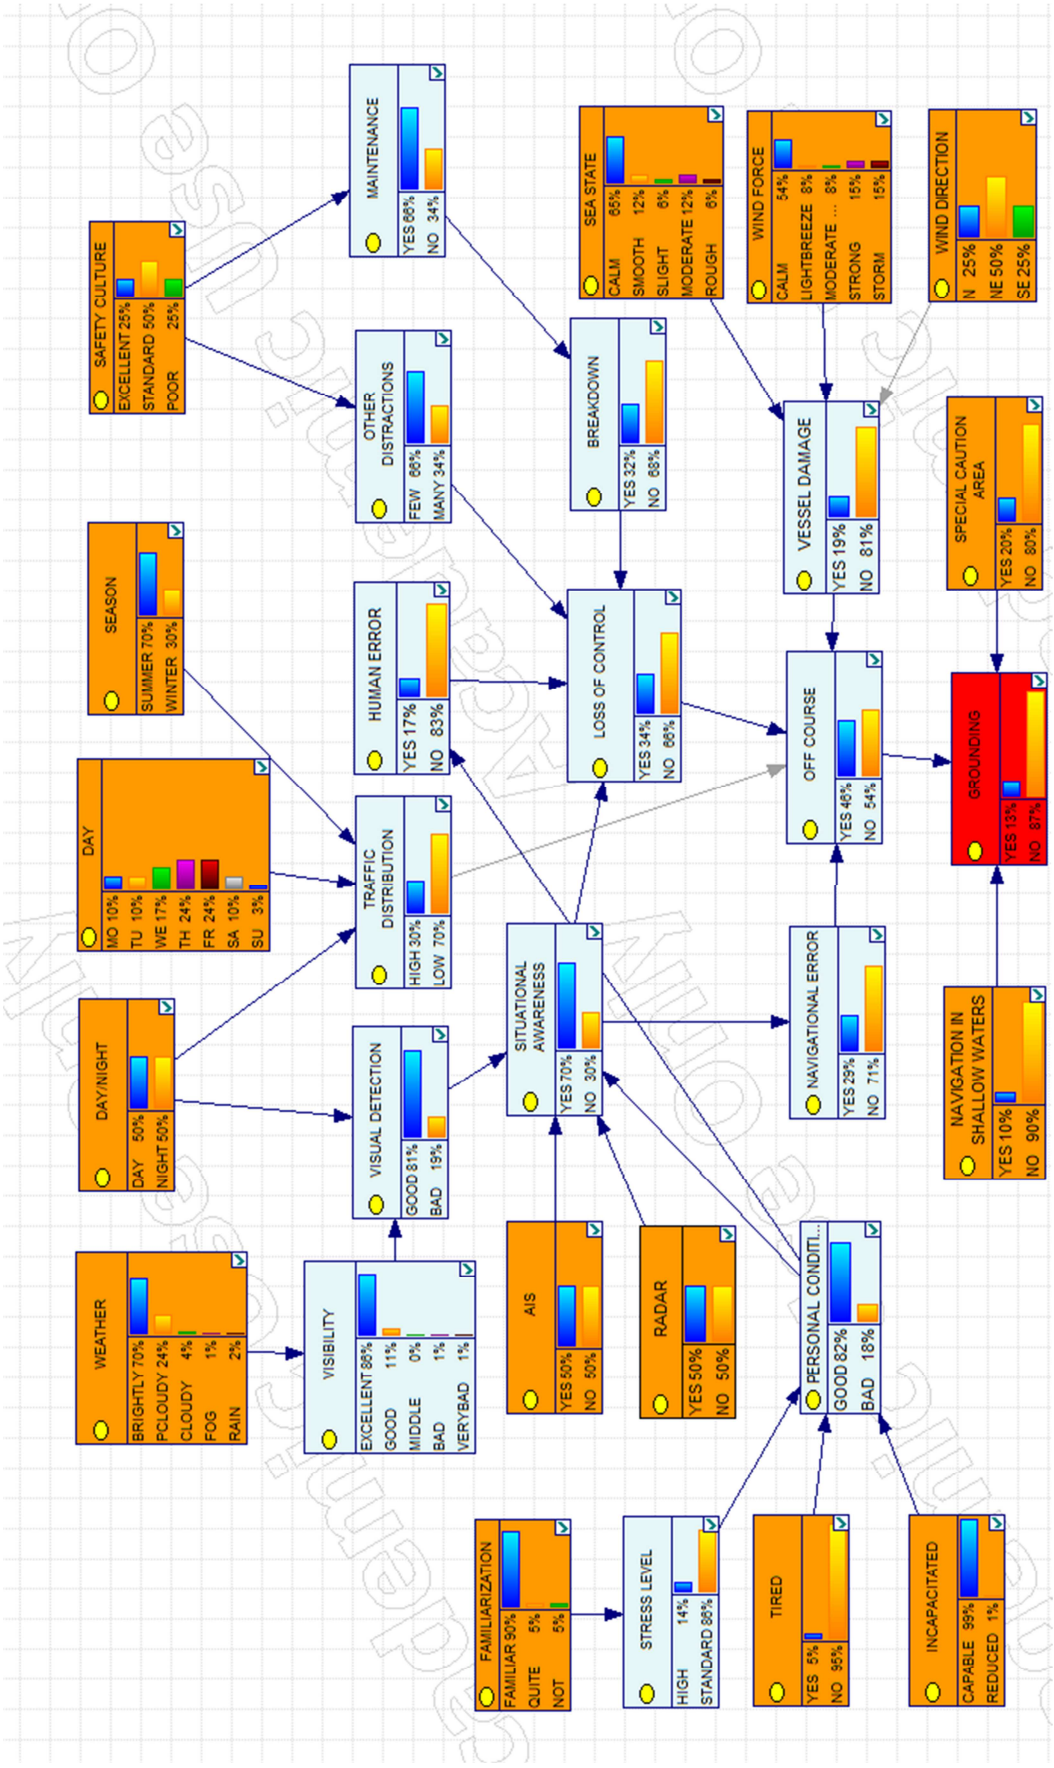

Slika 6-22: Kvantitativni model nasukavanja za putničke nelinijske brodove

6.2 Kvantitativni model sudara

Čimbenici ljudskih i organizacijskih faktora slični su za različite modele pomorskih nezgoda. Sukladno tome, kvalitativni model sudara sličan je kvalitativnom modelu nasukavanja. Kvalitativni model sudara se sastoji od 15 korijenskih varijabli. Karakteristične varijable za model sudara su: „Greška drugog broda“, „Gubitak kontrole drugog broda“, „Komunikacija s drugim brodom“ te „Izbjegavanje“.

Budući da su vrijednosti i veze koje se ponavljaju iz modela nasukavanja identične vrijednostima i vezama u modelu sudara, one neće biti ponovno opisane (vidi dio 6.1).

U daljnjem tekstu opisani su novi čvorovi, odnosi između čvorova te njihov utjecaj na vjerojatnost sudara. Cjeloviti kvalitativni model sudara malih putničkih brodova u nelinijskoj obalnoj plovidbi prikazan je na slici 6-28.

U modelu sudara čvor „Svjesnost o situaciji“, osim na čvor „Navigacijska pogreška“, utječe i na čvor „Komunikacija s drugim brodom“, što je u konačnici čvor koji utječe na tablicu uvjetovane vjerojatnosti čvora „Sudar“ (Slika 6-23). U pomorskoj se praksi, naročito nakon uvođenja AIS-a, povećala komunikacija između brodova i moguće dogovaranje o načinu izbjegavanja sudara. Komunikacija između brodova kojima prijeti rizik sudara svakako može biti dodatna mjera sigurnosti, ali valja naglasiti da eventualni načini izbjegavanja sudara moraju biti u skladu s Pravilima za izbjegavanje sudara na moru. Tablica uvjetovane vjerojatnosti za čvor „Komunikacija s drugim brodom“ prikazana je na slici 6-24.

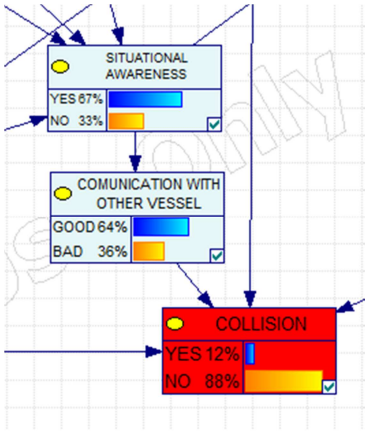

Slika 6-23: Dio kvalitativnog modela sudara koji se odnosi na svjesnost o situaciji i komunikaciju s drugim brodom

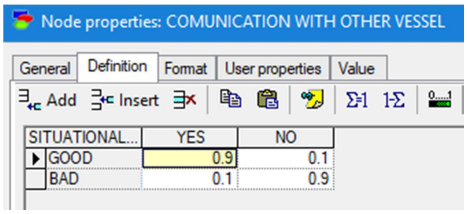

Slika 6-24: Uvjetovane vjerojatnost za čvor „Komunikacija s drugim brodom“

Čvor „Izbjegavanje“ ima petero roditelja: „Navigacijska pogreška“, „Gubitak kontrole“, „Kada brod ne plovi po planiranom kursu“, „Oštećenje broda“ te „Plovidba u području posebnog opreza“ i njegova tablica uvjetovane vjerojatnosti prikazana je na slici 6-25. Na slici 6-26. prikazan je primjer kada su stanja čvorova „Navigacijska pogreška“, „Gubitak kontrole“, „Oštećenje broda“ te „Plovidba u području posebnog opreza“ postavljene na 100 %. Uočava se da u takvoj situaciji vrijednost stanja „ne“ čvora „Izbjegavanje“ iznosi 90 % .

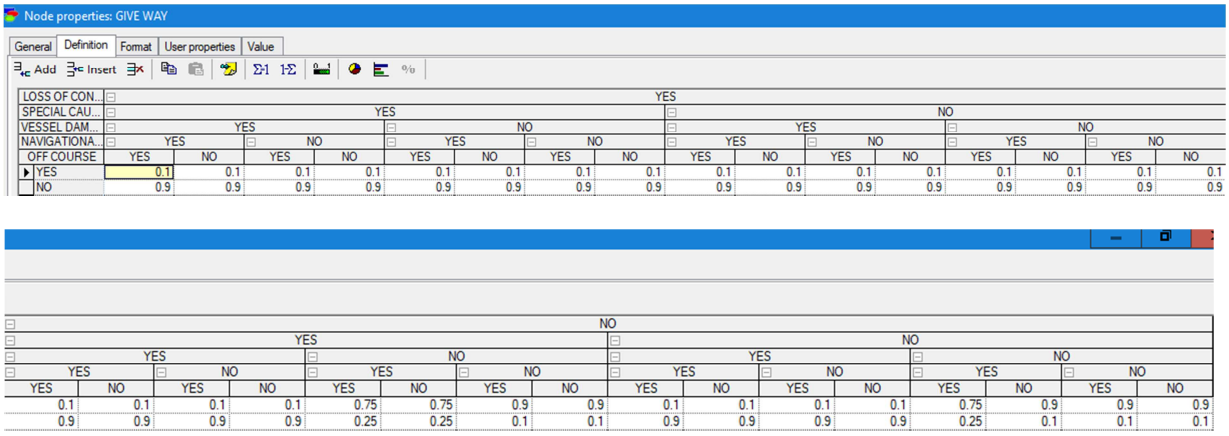

Slika 6-25: Uvjetovana vjerojatnost za čvor „Izbjegavanje“

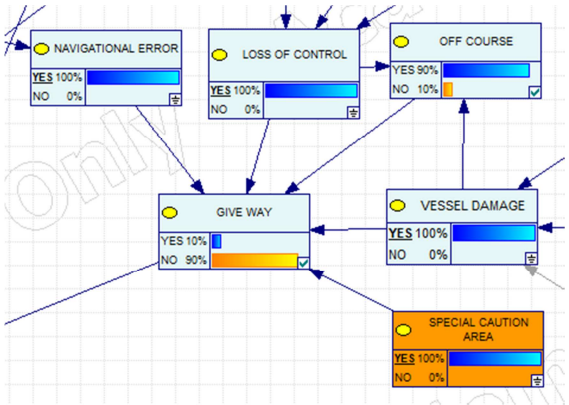

Slika 6-26: Prikaz vrijednosti čvora „Izbjegavanje“ nakon što su vrijednosti za čvor „Navigacijska pogreška“, „Gubitak kontrole“, „Oštećenje broda“ te „Navigacija u području posebne opasnosti“ postavljene na 100 %

Čvor „Greška drugog broda“ roditelj je čvoru „Gubitak kontrole drugog broda“. Čvor „Gubitak kontrole drugog broda“ u modelu je postavljen na način da ima direktan utjecaj na čvor „Sudar“ (Slika 6-27).

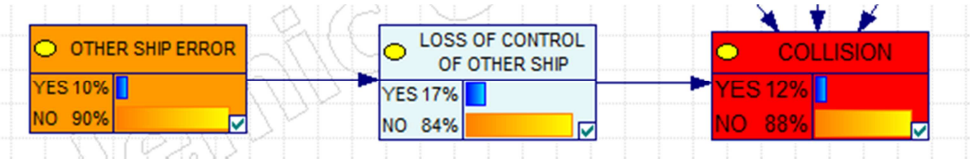

Slika 6-27: Dio kvantitativnog modela sudara koji se odnosi na čvor „Gubitak kontrole drugog broda“

Na čvor „Sudar“ utječu čvorovi: „Gubitak kontrole drugog broda“, „Komunikacija s drugim brodom“, „Izbjegavanje“ i „Gustoća prometa“.

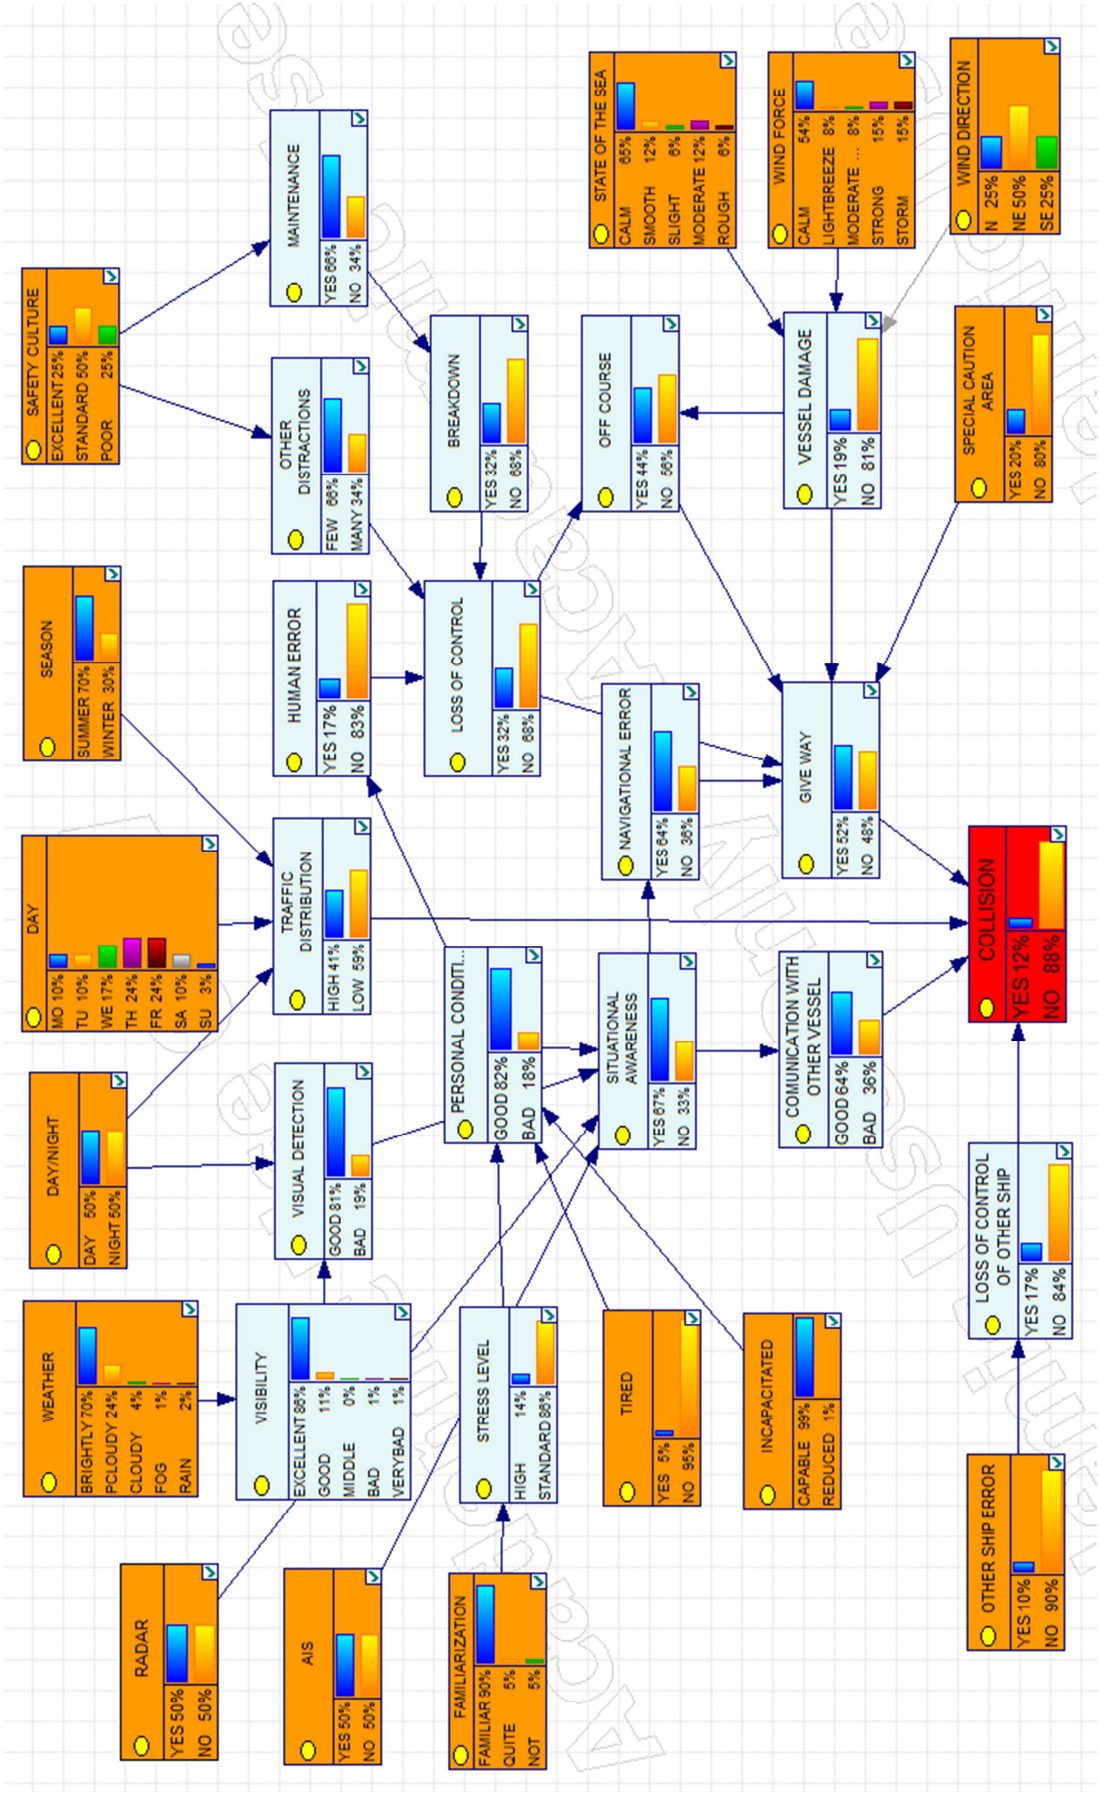

Slika 6-28: Kvantitativni model sudara za putničke nelinijske brodove

6.3 Validacija modela

Procesom validacije modela provjerava se ili ocjenjuje koliko valjano model specificira sustav kojeg reprezentira (Marwedel, 2011). Validacijski testovi ne dokazuju točnost rezultata modela, već pokazuju je li model vjerodostojna reprezentacija objekta ispitivanja. Prema autorima Goerlandt i Montewka (2015) te Zhang i ostali (2015) model bi trebao biti dovoljno vjerodostojan te služiti kao temelj za buduća istraživanja.

Različiti testovi se mogu izraditi na modelu u cilju evaluacije. U radu su napravljena tri testa:

- kvalitativni test modela
- analiza osjetljivosti modela
- usporedba rezultata modela sa stvarnim događajem.

6.3.1. Kvalitativna provjera

Kvalitativni test procjenjuje model na nizu testnih uvjeta kako bi usporedio odzive modela sa stvarnim ponašanjem sustava u tim uvjetima (Mazahery i ostali, 2016). Kvalitativni test modela za cilj ima identifikaciju varijabli koje imaju najveći utjecaj na rezultat modela primjenom principa razlike uvjetovane vjerojatnosti pri ekstremnim vrijednostima parametara svake varijable. Vrijednosti uvjetovane vjerojatnosti unutar modela ispitane su promatranjem svakog stanja pojedinog čvora. Drugim riječima, za svaki je čvor po jedno stanje postavljano na vrijednost 1, dok su istovremeno ostala stanja istog čvora postavljana na vrijednost 0 ovim postupkom moguće je uočiti promjene konačnih vrijednosti uvjetovanih vjerojatnosti modela za sve one varijable čiji se utjecaj može smatrati značajnim (Hanninen, Kujala, 2012; Mazaheri i ostali, 2015).
Razlika uvjetovane vjerojatnosti za stanja koja proizvode najveću uvjetovanu vjerojatnost i stanja koja proizvode najmanju promatrana je za svaku varijablu (Tablice 6-1 i 6-2). Testiranje je napravljeno koristeći se *GeNie softwareom.*

Razlika (ΔP_G) je informacija o ponašanju modela koja nam pomaže evaluirati najutjecajnije varijable koristeći se formulom prikazanom u radu A. Mazaheri i ostali (2016):

$$\Delta P_G = \max P(\text{nasukavanje=da} \mid X=x_i) - \min P(\text{nasukavanja=da} \mid X=x_j) \qquad (13)$$

$$\Delta P_G = \max P(\text{sudara=da} \mid X=x_i) - \min P(\text{sudara=da} \mid X=x_j), \quad (14)$$

gdje su x_i i x_j stanja varijable X koja imaju najveću i najmanju vjerojatnost. Razlika opisuje maksimum promjene koju varijabla X može uzrokovati na rezultate modela.

Rezultati analize (Tablica 6-1) prikazuju dva čvora koja imaju najveći utjecaj na rezultat modela nasukavanja kada su im stanja postavljena na bilo koju vrijednost u modelu nasukavanja. To su čvorovi: „Navigacija u plitkom području“ i „Sigurnosna kultura“. Slijedi čvor „Kada brod ne plovi po planiranom kursu“ te čvor „Gubitak kontrole“. Navedene varijable logički zadovoljavaju očekivana ponašanja sustava te se poklapaju s rezultatima sličnih modela, vidi primjere (Hanninen, Kujala (2012), Hanninen i ostali (2012, 2014)).

U analizi modela sudara (Tablica 6-2) čvor s najvećim utjecajem na krajnji rezultat modela je čvor „Komunikacija s drugim brodom“, slijedi čvor „Svjesnost o situaciji“ te čvor „Izbjegavanje“. Dobivene vrijednosti su sukladne očekivanjima modela sudara.

Tablica 6-1: Razlika najboljeg i najgoreg stanja za svaki čvor u modelu nasukavanja

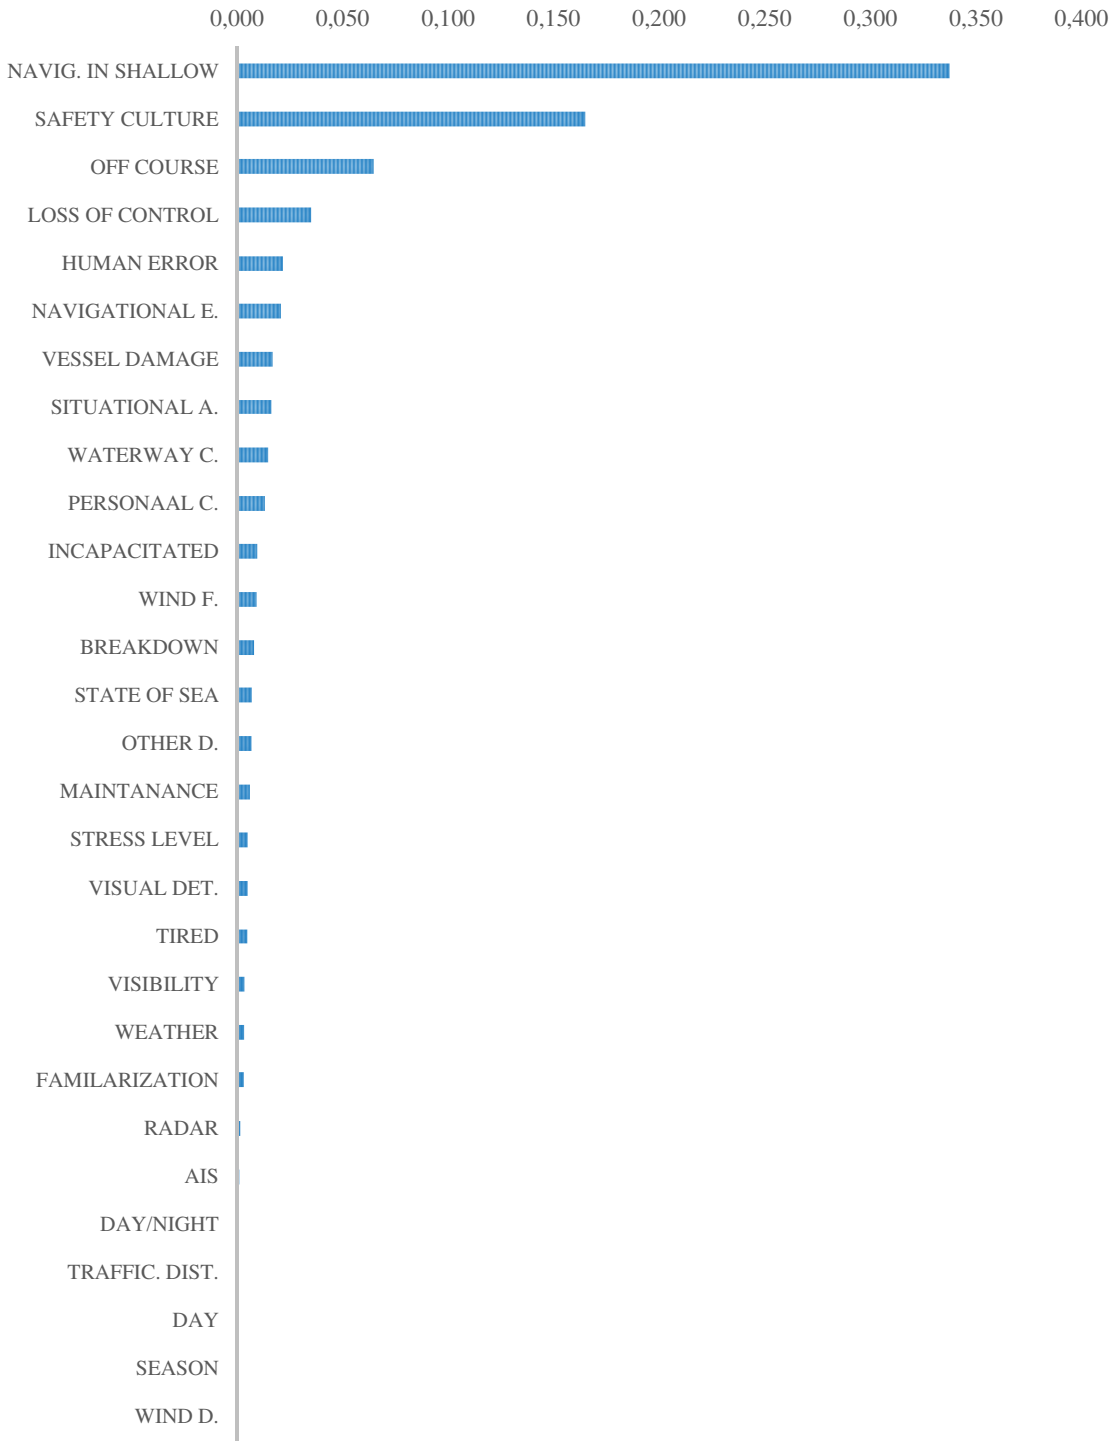

Tablica 6-2: Razlika najboljeg i najgoreg stanja za svaki čvor u modelu sudara

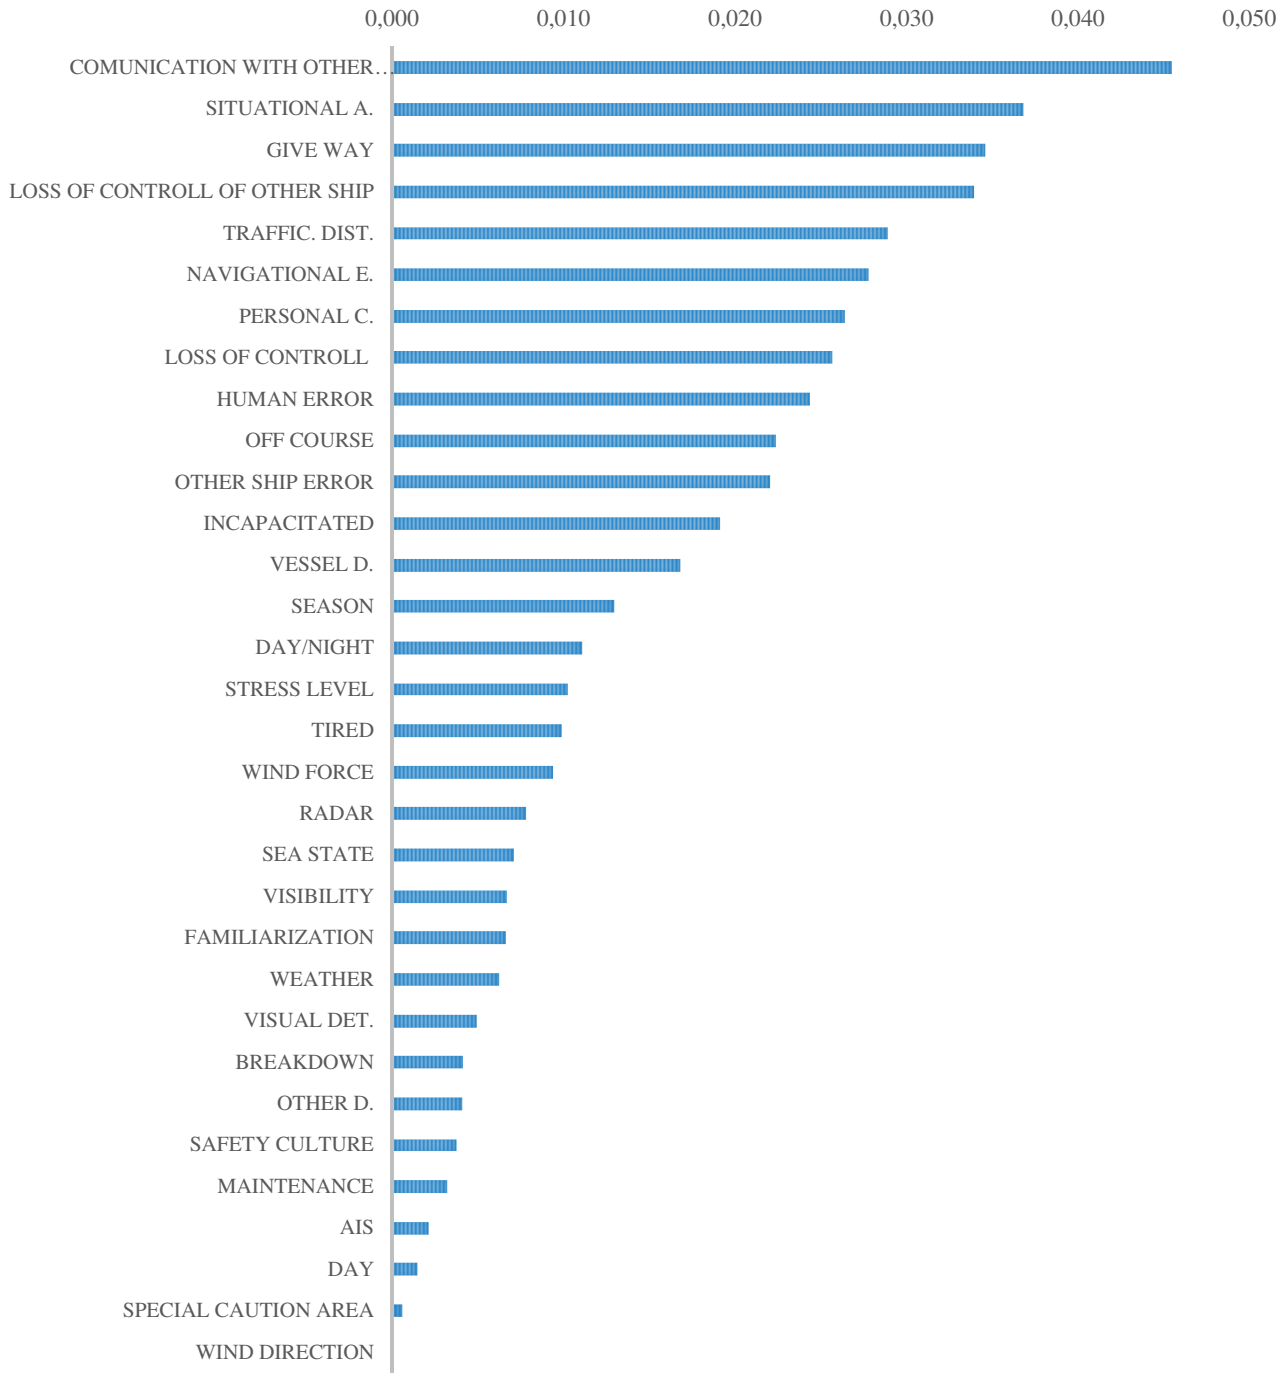

6.3.2. Analiza osjetljivosti modela nasukavanja

Analiza osjetljivosti je tehnika uz pomoć koje se vrši validacija parametara vjerojatnosti Bayesove mreže (Castillo i ostali, 1997). Validacija se vrši istraživanjem utjecaja malih promjena na brojčane vrijednosti (parametre vjerojatnosti), posteriornih vjerojatnosti ili izlaznih parametara. Vrlo osjetljivi parametri će imati značajniji utjecaj na izlazne rezultate. Identificiranje vrlo osjetljivih parametara omogućava usmjerenu raspodjelu parametara kako bi se dobili točniji rezultati modeliranja.
Kao posljedica nepotpunih podataka i djelomičnog znanja o sustavu, dobivene procjene su neizbježno netočne.

Kada su prilikom inicijalne procjene mreže sa stvarnim vrijednostima izlazne vrijednosti drugačije od onih koje su očekivane, tada se uz pomoć analize osjetljivosti može identificirati parametre koje je potrebno korigirati u svrhu dobivanja očekivanih rezultata. Dakle, analiza osjetljivosti potvrđuje pretpostavlja li model ispravno ponašanje sustava koji se modelira, odnosno provjeravanjem osjetljivosti modela prikazuje se da je model osjetljiv na parametre i scenarije na koje bi promatrani sustav trebao biti osjetljiv (Mazehery i ostali, 2016).

U ovome je radu korištena analiza osjetljivosti *Software GeNie* koju su opisali Castillo i ostali (1997) te autor Kjaerulff i van der Gaag (2013). Nakon što se odaberu određeni čvorovi nazvani „ciljani čvorovi“, algoritam efektivno izračunava kompletne setove derivacije distribucije posteriorne vjerojatnosti odabranih čvorova preko svih numeričkih parametara Bayesove mreže. Ako je derivacija velika za parametar *p*, tada mala derivacija *p* dovodi do velike razlike svih posteriornih vrijednosti za odabrane čvorove. Ako je derivacija mala, tada i velike promjene u parametrima rade male razlike u posteriornim vrijednostima (priručnik *GeNie Modeler*, 2017).

Analiza osjetljivosti modela nasukavanja napravljena je na dvama primjerima:

- analiza osjetljivosti modela nasukavanja kada su „ciljani čvorovi“ izabrani ekspertnom procjenom
- analiza osjetljivosti modela nasukavanja kada su „ciljani čvorovi“ varijable s najvećim ΔP_G iz kvalitativnog testa.

Primjer analize osjetljivosti prikazan je na slici 6-29. „Ciljani čvorovi“ su: „Navigacijska pogreška“ i „Oštećenje broda“.

Nakon provođenja testa analize osjetljivosti evidentna je osjetljivost modela na čimbenike ljudskog faktora i čimbenike meteoroloških utjecaja. Čvorovi visoke osjetljivosti su: „Navigacijska pogreška“, „Stanje mora“ i „Snaga vjetra“. Visoko osjetljivi čimbenici su: „Onesposobljen“, „Osobno stanje“ te „Pojava“. Osjetljivi čvorovi su: „Vizualna detekcija“, „Svjesnost o situaciji“, „Radar“, „AIS“, „Familijarizacija“, „Razina stresa“, „Umor“, „Dan/noć“ i „Oštećenje broda“.

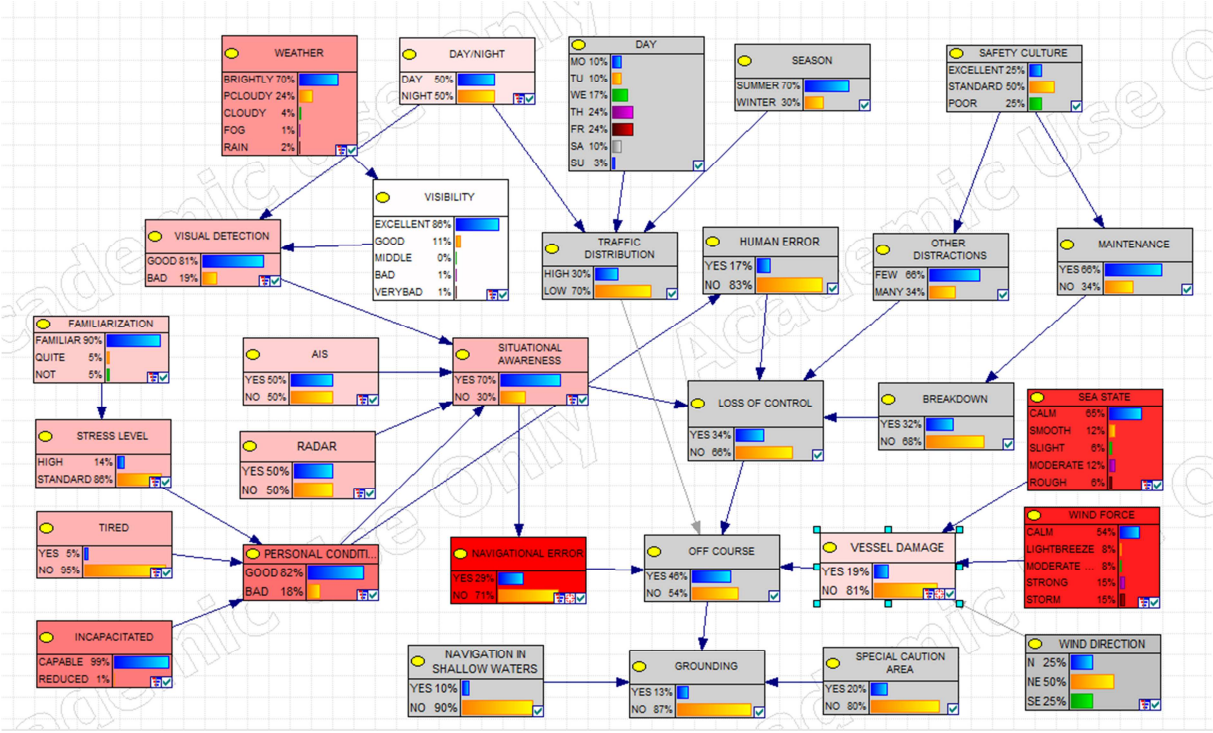

Slika 6-29: Analiza osjetljivosti modela nasukavanja kada su „ciljani čvorovi“: „Navigacijska pogreška“ i „Oštećenje broda“

Dijagram osjetljivosti prikazuje najosjetljivije parametre za selektirana stanja izabranog čvora, poredan od najosjetljivijeg do najmanje osjetljivog. Uz pomoć razdjelnika moguće je odrediti postotak promjene u svim parametrima. Horizontalna os prikazuje apsolutnu promjenu u posteriornoj vjerojatnosti kada su svi parametri promijenjeni za određeni postotak (Slika 6-30). Crveno-zeleno prikazane su vrijednosti pozitivne derivacije, a zeleno-crveno prikazane su negativne derivacije. Ovakav prikaz omogućuje brzu identifikaciju stanja „ciljanih čvorova“ koja će povećati ili smanjiti njihov posterior kada se poveća vrijednost parametra za koji je napravljen test osjetljivosti.

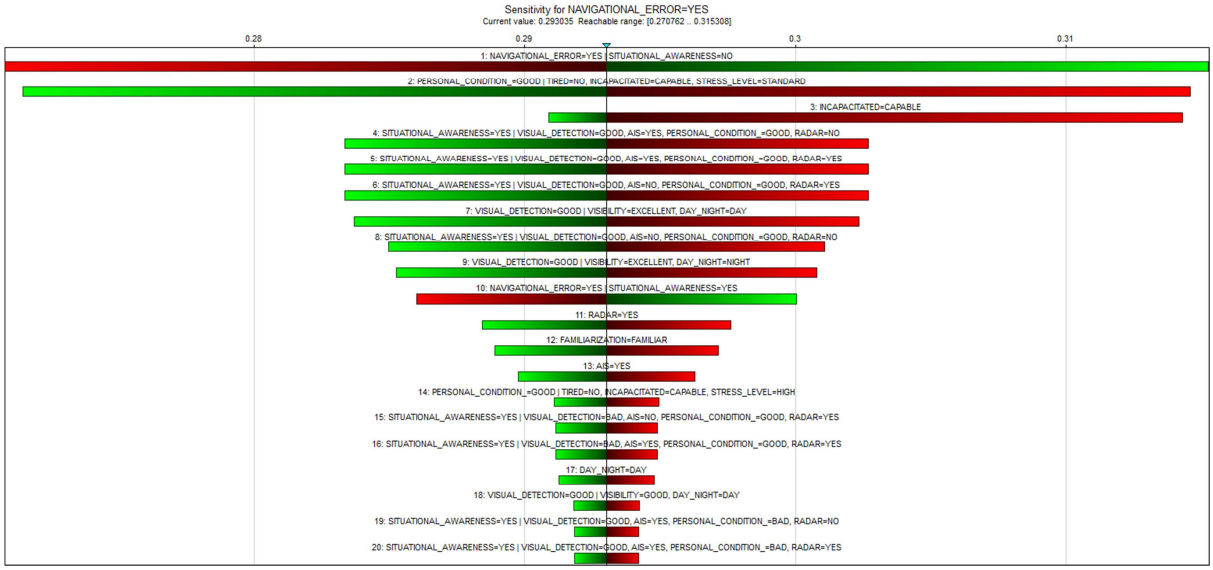

Slika 6-30: Dijagram osjetljivosti za čvor „Navigacijska pogreška“

Sljedeći primjer analize osjetljivosti za model nasukavanja napravljen je postavljanjem „ciljanih čvorova“ prema vrijednostima dobivenim kvalitativnim testom modela. U modelu nasukavanja za „ciljane čvorove“ postavljane su vrijednosti: „Navigacija u plitkom području“, „Sigurnosna kultura“ te čvor „Kada brod ne plovi po planiranom kursu“. Nakon testiranja osjetljivosti (Slika 6-31) uočeno je da čvorovi „Navigacija u plitkom području“ i „Sigurnosna kultura“ imaju najveću osjetljivost te da visoku osjetljivost pokazuju čvorovi: „Onesposobljenost“, „Osobno stanje“, „Navigacijska pogreška“, „Ljudska pogreška“, „Gubitak kontrole“ te čvor „Kada brod ne plovi po planiranom kursu“. Visoku osjetljivost pokazuju i čvorovi: „Familijarizacija“, „Razina stresa“ te „Umor“, ali i čvorovi koji se odnose na vanjske utjecaje: „Stanje mora“ i „Snaga vjetra“.

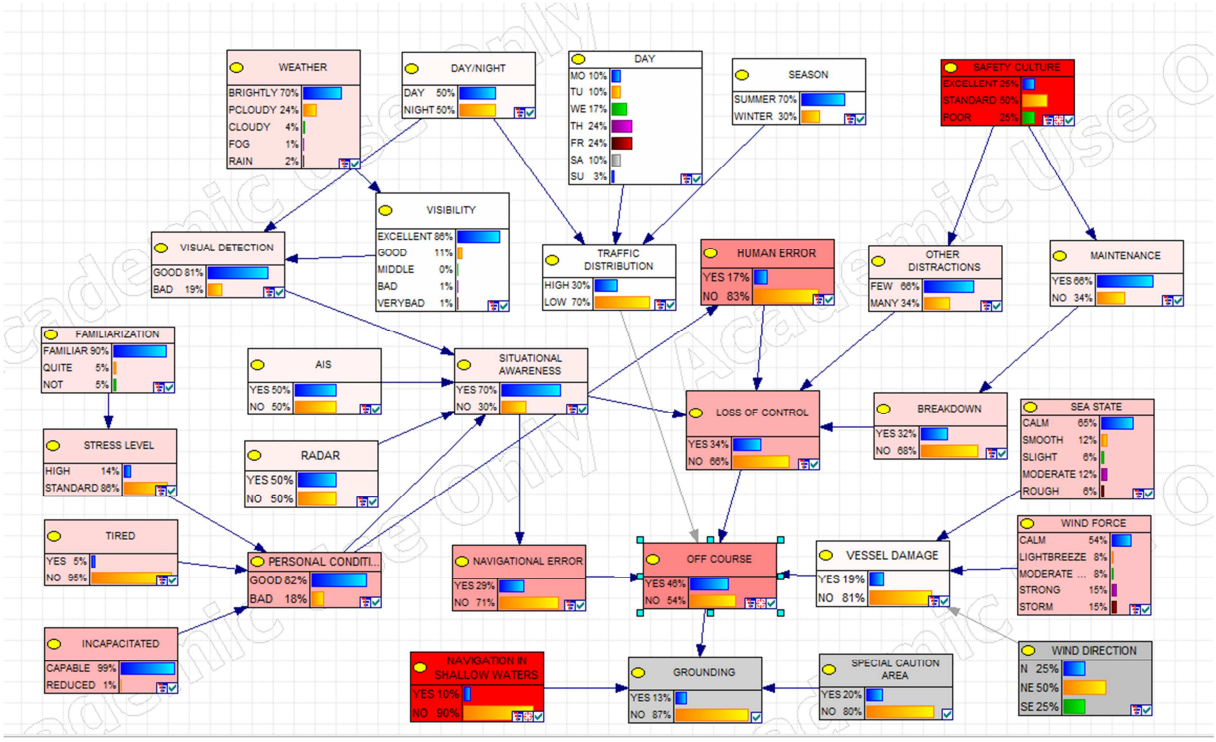

Slika 6-31: Analiza osjetljivosti modela nasukavanja kada su „ciljani čvorovi“: „Navigacija u plitkom području“, „Sigurnosna kultura“ i „Kada brod ne plovi po planiranom kursu“

Ocjenjivanje rezultata provedene analize osjetljivosti na model nasukavanja prikazuje osjetljivost modela na različite parametre modela te na različite kombinacije stanja parametara te iste odgovaraju očekivanjima modeliranog sustava.

6.3.3. Analiza osjetljivosti modela sudara

Analiza osjetljivosti modela sudara napravljena je na dvama primjerima:

- analiza osjetljivosti modela sudara kada su „ciljani čvorovi“ čvorovi izabrani prema procjeni eksperata: „Vizualna detekcija“, „Gustoća prometa“, „Gubitak kontrole drugog broda“ te „Gubitak kontrole“ (Slika 6-32)
- analiza osjetljivosti modela sudara kada su „ciljani čvorovi“ čvorovi s najvećim ΔP_G iz kvalitativnog testa modela: „Komunikacija s drugim brodom“, „Svjesnost o situaciji“ te „Izbjegavanje“ (Slika 6-33).

Na prvom primjeru prikazana je osjetljivost čvorova koji se odnose na čimbenike vremena, čimbenike broda, čimbenike ljudskog faktora, meteorološke čimbenike te čimbenike pogrešaka i gubitka kontrole. Čimbenici vremena koji imaju visoku osjetljivost u modelu su:

doba dana i doba godine, odnosno čimbenici koje utječu na gustoću prometa u promatranom području te matematički umanjuju ili povećavaju vjerojatnost pojave pomorske nezgode sudara. Čvor „Dan u tjednu“ je manje osjetljiv od ostalih čimbenika vremena što odgovara stvarnoj situaciji. Čvor „Pojava“ prikazuje visoku osjetljivost na pomorsku nezgodu sudara zbog mogućih stanja kiše i magle, važnih utjecajnih faktora za umanjenje vizualne detekcije, pogotovo kod brodova bez radara. Čvor „Vizualna detekcija“ prikazuje visoku osjetljivost kao važan faktor utjecaja na pomorsku nezgodu sudara. Sljedeći vrlo osjetljiv čvor je „Ljudska pogreška“, roditeljska varijabla čvoru „Gubitka kontrole“ te čvorovi „Pogreška drugog broda“ te „Gubitak kontrole drugog broda“ kao visoko osjetljivi čvorovi koji mogu dovesti do pomorske nezgode sudara, ali na koje ne možemo utjecati. Visoku osjetljivost pokazuju i čvorovi vezani za sigurnosnu kulturu koja utječe na opću sigurnosnu atmosferu na brodu, odnosno na ponašanje na mostu, količinu ometanja na mostu, održavanje broda, tehničku ispravnost svih uređaja na brodu itd. Od čimbenika ljudskog faktora visoku osjetljivost pokazuju čvorovi „Onesposobljenost“ i „Osobno stanje“ osobe koja upravlja brodom. Osjetljivost pokazuju i čvorovi: „Familijarizacija“, „Razina stresa“ te „Umor“.

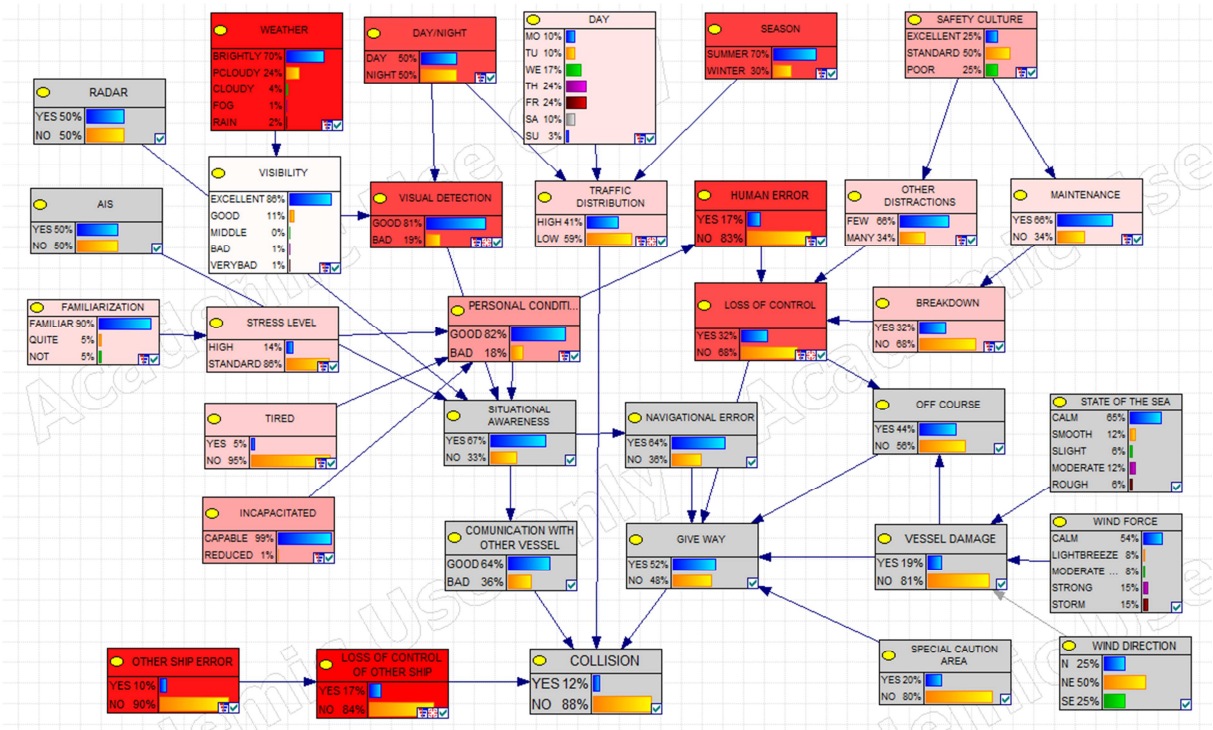

Slika 6-32: Analiza osjetljivosti za model sudara kada su „ciljani čvorovi“: „Vizualna detekcija“, „Gustoća prometa“, „Gubitak kontrole drugog broda“ i „Gubitak kontrole“

Drugi primjer analize osjetljivosti za model sudara napravljen je postavljanjem „ciljanih čvorova“ prema vrijednostima dobivenim kvalitativnim testom modela. „Ciljani čvorovi“ su čvorovi: „Izbjegavanje“, „Komunikacija s drugim brodom“ te „Svjesnost o situaciji“. Uočeno je da su u ovom primjeru visoko osjetljivi čimbenici koji se odnose na ljudski faktor, odnosno čvorovi „Onesposobljenost“ i „Osobno stanje“ te da visoku osjetljivost pokazuju čvorovi „Umor“, „Stres“ i „Familijarizacija“. Sljedeći visoko osjetljiv čvor je čvor „Komunikacija s drugim brodom“. U ovom primjeru kao visoko osjetljivi čvorovi pojavljuju se: „AIS“ i „Radar“ što nije bio slučaj u prvom primjeru. Čvor „Radar“ pokazuje veću osjetljivost od čvora „AIS“, što odgovara realnim očekivanjima modela. Visoku osjetljivost predstavljaju čvorovi „Izbjegavanje“, „Navigacijska pogreška“ te „Navigacija u području posebnog opreza“ što odgovara realnim očekivanjima modela. Osjetljivost pokazuju čvorovi „Stanje mora“ i „Snaga vjetra“ što do sada nije bio slučaj.

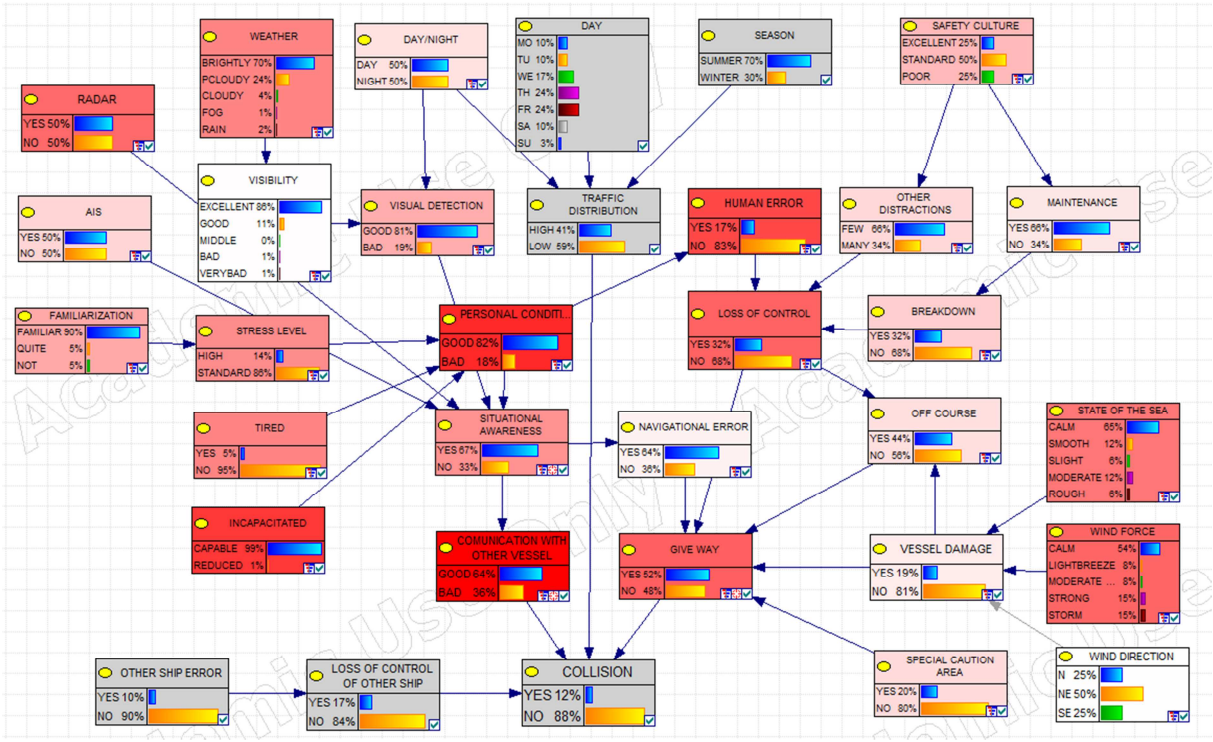

Slika 6-33: Analiza osjetljivosti za model sudara kada su „ciljani čvorovi“: „Izbjegavanje“, „Komunikacija s drugim brodom“ i „Svjesnost o situaciji“

Razvidno je da drugi primjer sadržava veći broj visoko osjetljivih čvorova u odnosu na prvi primjer.

6.3.4. Usporedba rezultata modela sa stvarnim događajem

Primjer 1. Nasukavanje putničkog nelinijskog broda „Zlatni žal“

Za uspoređivanje rezultata modela sa stvarnim događajem uzet je primjer nasukavanja turističkog broda „Zlatni žal“ (Slika 6-35). Radi se o čeličnom putničkom brodu, područja plovidbe 6 (nacionalna obalna plovidba) izgrađenom 1979. godine u Baku. Brod pokreću dva dieselska motora ukupne snage 492 kW, dug je 33,5 metara, širine 5,3 metara, gaza 1582 mm te 109 GT. Brod posjeduje radar, ali je pri plovidbi je doživio pomorsku nezgodu nasukavanja na otok Šćedro.

Prema izvješću pomorske nezgode nasukavanja navedenom u daljnjem tekstu, napravljena je usporedba rezultata s pravim događajem (Slika 6-34).

Izvješće pomorske nezgode nasukavanja broda „Zlatni Žal“ od 1.travnja 2017. godine:

„Na poziciji nasukavanja pronađen je motorni putnički brod naziva „Zlatni žal“, hrvatske zastave s tri člana posade (uključno sa zapovjednikom), svi hrvatski državljani, od kojih nitko nije ozlijeđen. Očevidom na poziciji nezgode utvrđeno je da se putnički brod duljine 33 metra, čelične konstrukcije, pogonjen dvama pogonskim strojevima ukupne porivne snage 492 kW pramčanim dijelom nasukao na otočne hridi. Trup broda pretrpio je oštećenja uslijed udara u obalu, no nije ustanovljen prodor mora u potpalublje. U trenutku nasukavanja na moru su vladali povoljni vremenski uvjeti i odlična vidljivost te je kao uzrok nezgode utvrđena nesmotrenost zapovjednika broda. Na poziciji nasukavanja nije uočeno onečišćenje mora, nema prodora mora. Lučka kapetanija Split izdala je nalog zapovjedniku broda za organiziranje komercijalnog odsukavanja broda koji je u vlasništvu pravne osobe registrirane u Republici Hrvatskoj.“ Izvor: http://www.mppi.hr/default.aspx?id=32703.

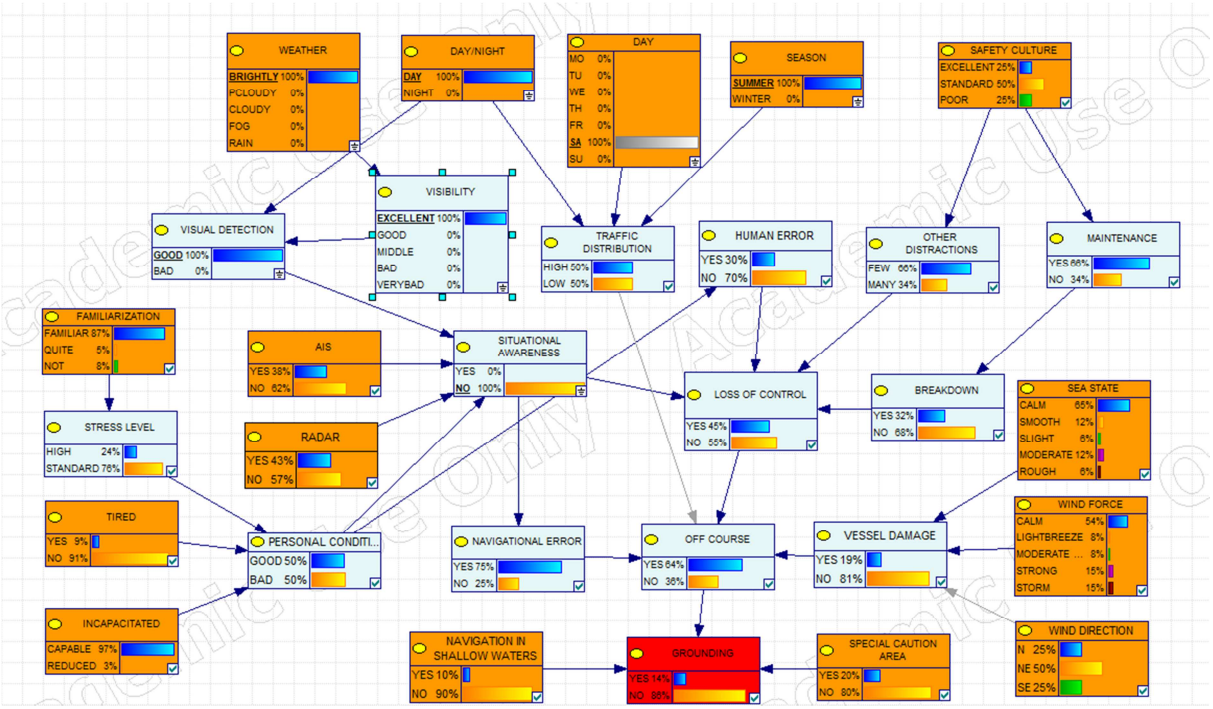

Slika 6-34: Model nasukavanja putničkog broda prema izvješću o pomorskoj nezgodi nasukavanja putničkog broda „Zlatni žal“

Slika 6-35: Putnički brod „Zlatni žal“ nasukan na otoku Šćedru

Izvor: Ministarstvo mora, prometa i infrastrukture

Korijenskim čvorovima dodijeljene su vrijednosti navedene u izvješću pomorske nezgode nasukavanja broda „Zlatni žal“. Vrijednosti čvorova: „Vrijeme“, „Doba dana“, „Dan u tjednu“ te „Godišnje doba“ promijenjeni su u odnosu na izvorni model nasukavanja. Čvor „Vrijeme“ postavljen je na vedro, vrijednost za dan na 100 %, dan je subota, sezona spada u ljetnu prema definiranoj podjeli u prvom dijelu rada. Čvor „Vidljivost“ postavljen je na odličnu, „Vizualna detekcija“ na dobra te „Svjesnost o situaciji“ na negativna 100 %.

Nakon promjene stanja varijabli prema podacima iz izvješća o pomorskoj nezgodi te pokretanja modela, uočava se promjena vjerojatnosti pomorske nezgoda nasukavanja za 1 % .

Primjer 2. Nasukavanje putničkog linijskog broda „Lumbrikata“

Uspoređivanje rezultata modela sa stvarnim događajem na primjeru nasukavanja broda „Lumbrikata“ koji je plovio na liniji Vrgada − Pakoštane napravljeno je u svrhu testiranja modela u Zadarskoj županiji. Brod „Lumbrikata“ uzet je za primjer zbog tehničko-tehnoloških sličnosti s malim putničkim brodovima u nelinijskoj obalnoj plovidbi za jednodnevne izlete koji su temadisertacije. M/b „Lumbrikata“ izgrađen je 1974., kapaciteta je 80 putnika, dužine 16,60 metara te brzine broda 10 čv.

Prema izvještaju o pomorskoj nezgodi preuzetoj sa stranica MMPI-a vidljivo je da je brod plovio po nepovoljnim vremenskim uvjetima, odnosno po magli. Ostali mogući uzroci pomorske nezgode nisu navedeni u izvješću te su se sukladno tome formirala stanja modela. Varijabla „Pojava“ postavljena na magla, varijabla „Dan u tjednu“ je postavljena na srijeda, varijabla „Godišnje doba“ je postavljena na zima, varijabla „Dan/noć“ na dan, a varijabla „Vidljivost“ na vrlo slaba (Slika 6-36).

Nakon promjena vrijednosti stanja varijabli prema izvješću o pomorskoj nezgodi, vidljiv je rast krajnje varijable modela nasukavanja za 1%.

Prema izvješću o pomorskoj nezgodi MMPI-a navedenom u daljnjem tekstu, napravljena je usporedba modela s pravim događajem.

„Djelatnici Lučke kapetanije Zadar izvijestili su danas Ministarstvo pomorstva, prometa i infrastrukture i Nacionalnu središnjicu za usklađivanje traganja i spašavanja na moru (MRCC Rijeka) o pomorskoj nesreći nasukavanja putničkoga broda na obalu otočića kod Pakoštana.

Dojavu o pomorskoj nesreći Lučkoj kapetaniji Zadar uputio je zapovjednik putničkoga motornoga broda naziva „Lumbrikata“ koji je plovio na redovnoj liniji Vrgada – Pakoštane –

Biograd kada se jutros, 11. studenoga nešto prije 06:30 sati nasukao na sjevernu obalu otočića Sveta Juština, nasuprot mjesta Pakoštane.

U trenutku nesreće na brodu se nalazilo 22 putnika od kojih nitko srećom nije ozlijeđen te su nedugo nakon nasukavanja prekrcani na zamjenski brod kojim su dalje sigurno prevezeni do luke odredišta.

Obavljenim očevidom na poziciji nasukavanja djelatnici zadarske Lučke kapetanije nisu ustanovili onečišćenje mora i morskog okoliša te je u okviru istrage o uzrocima nasukavanja u obzir uzeta činjenica da tijekom plovidbe na navedenoj liniji na moru nisu vladali povoljni vremenski uvjeti, odnosno plovilo se po izrazito gustoj magli.

Iz Lučke kapetanije Zadar vlasniku nasukanoga broda naloženo je komercijalno odsukavanje te izvanredni pregled broda od strane djelatnika Hrvatskoga registra brodova radi utvrđivanja sposobnosti broda za daljnju plovidbu.“

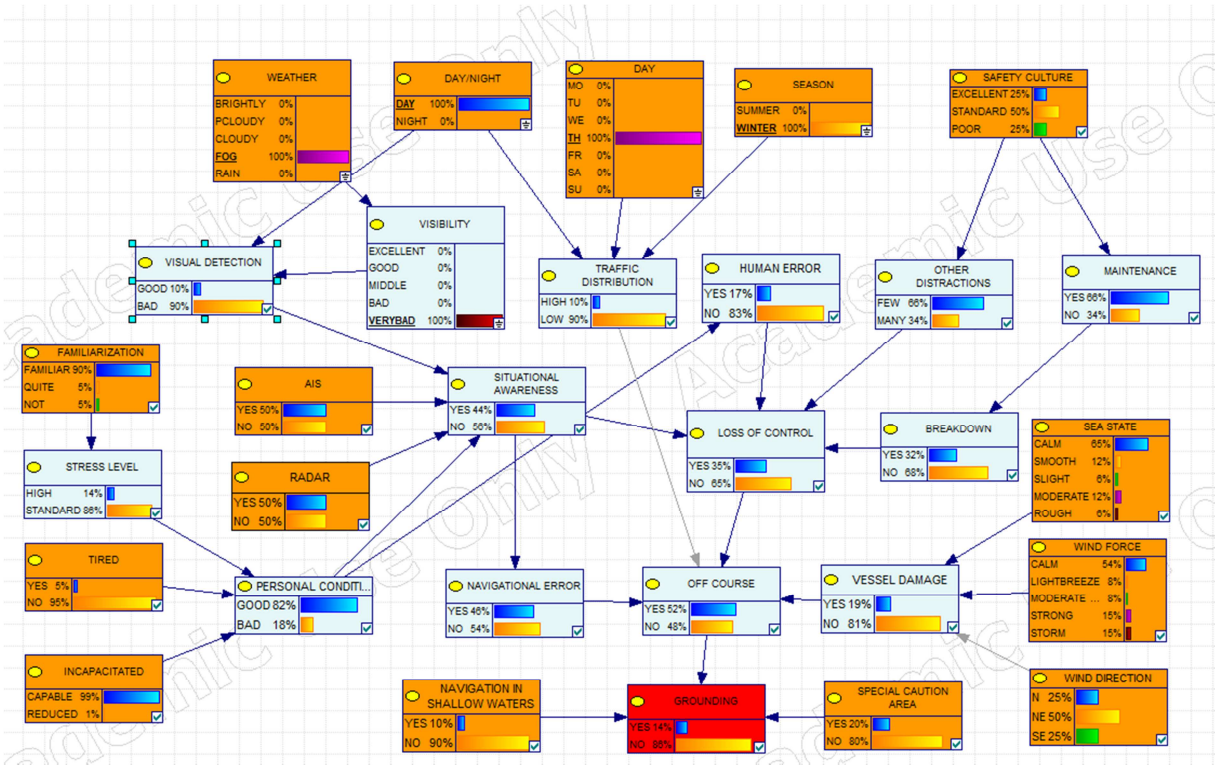

Slika 6-36: Model nasukavanja linijskog putničkog broda prema izvješću o pomorskoj nezgodi nasukavanja putničkog broda „Lubrikata“

Prema uputama za plovidbu iz Peljara za male brodove, Drugi dio (2003) Hrvatskog hidrografskog instituta, u luku Pakoštane se može uploviti samo s jugoistoka, istočno od otočića Sv. Justina tako da zidana oznaka sa željeznom bitvom na pličini pri uplovljavanju ostaje lijevo. U istoj publikaciji dano je i upozorenje zbog pličina na koje valja paziti pri uplovljavanju u luku Pakoštane. Na slici 6-37. prikazan je primjer modela nasukavanja broda

„Lubrikata“ kada je varijabla „Plovidba u plitkom području“ postavljena na maksimalnih 100 %. Varijabla „Plovidba u području posebnog opreza“ postavljena je na negativno 100 % jer se koristi model prilagođen za Splitsko-dalmatinsku županiju te se na ovaj način umanjuje njen utjecaj.

Krajnji rezultat modela se u tom slučaju povećava za 30 %. Ovakvi rezultati modela dokazuju njegovu primjenu i na slične brodove u drugim županijama na Jadranu.

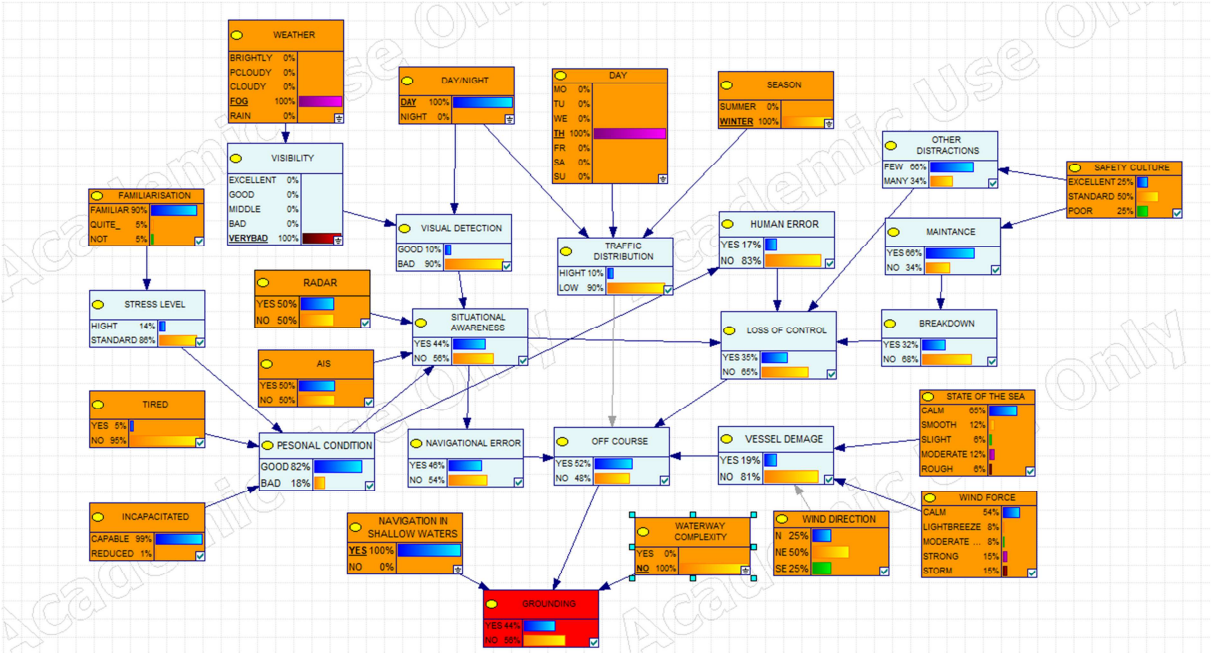

Slika 6-37: Model nasukavanja linijskog putničkog broda prema izvješću o pomorskoj nezgodi putničkog broda „Lubrikata“ uzimajući u obzir plovidbu u plitkom području

Slika 6-38: Linijski mali putnički brod „ Lubrikata“

6.4 Analiza rezultata i prijedlozi mjera za poboljšanje

Pomorske nezgode predstavljaju složen problem za analizu i modeliranje zbog različitih scenarija te kombinacije događaja. Promatrani brodovi nemaju ustaljene rute plovidbe niti ustaljen način plovidbe što dodatno otežava izbor scenarija prema kojemu se vrši modeliranje. Nadalje, promatrani brodovi nisu jednako opremljeni, stoga je otežano izraditi opći model koji ima primjenu na sve male putničke brodove u nelinijskoj obalnoj plovidbi. Zbog složenosti problematike, u ovoj disertaciji odabran je pristup analizi pomorskih nezgoda modeliranjem uz pomoć Bayesovih mreža, budući da Bayesovo modeliranje omogućuje prilagodbu različitim scenarijima promjenom utjecajnih čimbenika ili njihovim preslagivanjem u modelu. Također, uz pomoć Bayesovih mreža moguće je ustanoviti utjecaj određenog faktora na krajnji rezultat modela.

U doktorskoj disertaciji analizirane su pomorske nezgode: potonuće, udar, nasukavanje, sudar, požar i eksplozija, pri čemu su posebno analizirane pomorske nezgode nasukavanje i sudar.

Korištenje statističkih podataka u ovome radu bazirano je na relativno malom broju pomorskih nezgoda što je rezultiralo manjim odmacima pojedinih rezultata od očekivanih vrijednosti. Nadalje, tvrdnja (Mazahery, 2015) da su podaci za modeliranje pomorskih nezgoda često neadekvatni, nepotpuni ili nepostojeći potvrđena je analiziranjem izvora korištenih u ovome radu. Uočen je nedostatak podataka točnih pozicija na kojima se dogodila pomorska nezgoda, nedostatak informacija o vremenima nastupanja pomorskih nezgoda za pojedine pomorske nezgode te generaliziranje vrsta putničkih brodova. Svrstavanje velikih putničkih brodova zajedno s malima, kao i linijske plovidbe zajedno s nelinijskom, neadekvatno je zbog razmjerno velikih razlika u plovidbi, načinu eksploatacije, održavanju, provođenju sigurnosnih mjera, itd.

Analiza statističkih podataka Hrvatskog registra brodova pokazuje da su 2015. godine evidentirana 602 putnička broda, izuzevši Ro-Ro putničke brodove i brze putničke brodove, te da 43,4 % od ukupnog broja putničkih brodova otpada na brodove starije od 50 godina koji su dijelom i rekonstruirani. Brodova od 10 do 20 metara ima 54,0 %, 23,2 % su brodovi od 20 do 30 metara te 14,3 % brodovi od 30 do 40 metara.

Rezultati statističke obrade podataka za istočnu obalu Jadrana i promatrane brodove govore da ukupan broj malih putničkih brodova koji su sudjelovali u različitim pomorskim nezgodama od 2011. do 2015. godine iznosi 29. Za isto razdoblje ukupan broj brodova koji

su sudjelovali u pomorskim nezgodama iznosi 1653. Zabilježen je trend pada broja pomorskih nezgoda u promatranom razdoblju za putničke brodove, ali s obzirom na relativno mali broj pomorskih nezgoda taj je podatak nepouzdan.

Analizom statističke obrade podataka Ministarstva pomorstva, prometa i infrastrukture prema vrsti pomorskih nezgoda putničkih brodova, najbrojnija pomorska nezgoda je nasukavanje, slijedi nesposoban za plovidbu, sudar te udar. Prema podacima autora Frančić i ostali (2009) 80 % nasukavanja je bilo od strane hrvatskog broda i to s najvećim udjelom drvenih brodova. Autori navode da su drveni brodovi najzastupljeniji i u pomorskoj nezgodi nesposobnosti broda za plovidbu.

Broj pomorskih nezgoda koje su se dogodile za vrijeme dana, jednak je broju nezgoda koje su se dogodile za vrijeme noći te ih se većina dogodila u 7., 8. i 9. mjesecu. Dani u kojima je zabilježen najveći broj pomorskih nezgoda promatrajući cjelogodišnje razdoblje su: četvrtak i petak. Dan s najvećim brojem pomorskih nezgoda u ljetnom razdoblju (6.,7. i 8.) za putničke brodove je ponedjeljak, dok je nedjelja dan u kojem je zabilježeno najviše pomorskih nezgoda za sve brodove promatrajući cjelogodišnje te posebno ljetno razdoblje.

Doba dana kada je zabilježen najveći broj pomorskih nezgoda za putničke brodove je vrijeme od 11:00 do 12:00 sati te vrijeme od 17:00 do 18:00 sati, a doba dana kada je zabilježen najveći broj pomorskih nezgoda za sve brodove je vrijeme od 17:00 do 18:00 sati.

Najveći broj pomorskih nezgoda zabilježen je za vrijeme vedrog vremena pri odličnoj vidljivosti pri mirnom moru bez vjetra. Promatrajući broj nezgoda za vrijeme vjetra, najviše ih je zabilježeno za vrijeme puhanja vjetra iz NE smjera.

Sukladno rezultatima statističke analize pomorskih nezgoda vidljivo je da pomorske nezgode malih putničkih brodova više ovise o ljudskim, organizacijskim te tehničko-tehnološkim čimbenicima, nego o vanjskim, odnosno hidrometeorološkim uvjetima. Manji broj pomorskih nezgoda uvjetovanih hidrometeorološkim čimbenicima može se objasniti i učestalim praćenjem meteoroloških upozorenja te dobrim poznavanjem mjesta zakloništa u području plovidbe što je potvrđeno intervjuiranjem eksperata.

U radu su detaljnije analizirane pomorske nezgode nasukavanje i sudar zbog mogućih ozbiljnijih posljedica na putnike, posadu, brod i okoliš te zbog njihove brojnosti. Za pomorske nezgode nasukavanja i sudara koje su kvantitativno obrađene napravljena su testiranja modela. Testiranja modela su izvršena uz pomoć kvalitativnog testa modela, analize osjetljivosti te usporedbe rezultata sa stvarnim događajem. Testiranja su izvršena korištenjem

GeNie softwarea, alata namijenjenog modeliranju i učenju Bayesovih mreža. Varijable koje pokazuju najveću razliku uvjetovanih vjerojatnosti prikazane su u tablicama 6-1. i 6-2. Detaljni podaci o varijablama s najvećim ekstremnim vrijednostima prikazani su u Prilozima 2. i 3., na temelju čega se mogu izdvojiti sljedeći zaključci za model nasukavanja i model sudara.

Za model nasukavanja varijable s najvećim ekstremnim vrijednostima su: „Navigacija u plitkom području“, „Sigurnosna kultura“, „Kada brod ne plovi po planiranom kursu“ te „ Gubitak kontrole“. Za model sudara varijable s najvećim ekstremnim vrijednostima su: „Komunikacija s drugim brodom“, „Svjesnost o situaciji“, Izbjegavanje“ te „Gubitak kontrole drugog broda“. Najveći utjecaj na uvjetovanu vjerojatnost nasukavanja pokazuje varijabla „Navigacija u plitkom području“, koja se odnosi na namjernu plovidbu u područjima gdje su opasnosti za navigaciju vrlo blizu broda. U tom slučaju uvjetovana vjerojatnost nasukavanja iznosi 0,43725463, a u slučaju da brod ne plovi plitkim područjem uvjetovana vjerojatnost je 0,1. Varijabla „Sigurnosna kultura“ (manjak posade, neprimjenjivanje sigurnosnih preporuka i normativa na brodu) pri postavljanju na najbolje maksimalno stanje daje vrijednost krajnje varijable od 0,3022418, dok je pri postavljanju na najgore stanje ta vrijednost 0,1372442. Varijabla „Kada brod ne plovi po planiranom kursu“ pri postavljanju na najbolju maksimalnu vrijednost daje vrijednost krajnjoj varijabli od 0,103 dok je pri postavljanju na najgoru moguću vrijednost, vrijednost krajnje varijable 0,168. Varijabla „Gubitak kontrole“ pri postavljanju na najbolju maksimalnu vrijednost daje vrijednost krajnjoj varijabli od 0,12123953 a pri postavljanju na najgore moguće stanje ta vrijednost je 0,1565659.

Za model sudara varijabla koja ima najveću razliku između maksimalne i minimalne vrijednosti stanja je varijabla „Komunikacija s drugim brodom“ s vrijednošću 0.1 za maksimalno dobru komunikaciju te s vrijednošću od 0,1454337 za lošu komunikaciju s drugim brodom. Slijedi varijabla „Svjesnost o situaciji“ s utjecajem od 0,10440206 za maksimalno dobro stanje te od 0,14118093 za najgore stanje. Varijabla „Izbjegavanje“ ima maksimalnu vrijednost utjecaja na krajnju varijablu od 0,1, a minimalnu vrijednost utjecaja na krajnju varijablu od 0,12894959.

Rezultati testiranja modela nasukavanja prikazuju da je povećanje sigurnosti moguće korištenjem uređaja za pomoć pri navigaciji: radara i AIS uređaja. U modelu, korištenje radara pokazuje veće povećanje sigurnost nego korištenje AIS uređaja. Njihova zajednička primjena u modelu nasukavanja pokazuje utjecaj na povećanje svjesnosti osobe koja upravlja brodom za 10 %. Nadalje, provođenjem određenih mjera kojima bi se smanjio negativni

utjecaj faktora "Navigacija u plitkom području" te „Sigurnosna kultura" smanjila bi se vjerojatnost pojave nasukavanja na malim putničkim brodovima. Na spomenute varijable moguće je utjecati povećanjem svjesnosti situacije osobe koja upravlja brodom prilikom plovidbe rizičnim područjem na način da se utječe na njeno osobno stanje (kontrola radnih sati, odnosno radnog opterećenja, dovoljan broj sati za odmor posade, poboljšanje opreme za pomoć pri navigaciji, svjesnost o mogućim redovitijim provođenjima ispitivane količine alkohola u krvi, smanjivanje dozvoljene količine alkohola u krvi osobama koje upravljaju brodovima s 0,5g/kg alkohola u krvi na 0,0g/kg)[26] te podizanje opće razine sigurnosti na brodu.

Osim prijedloga za korištenje radara kojim se povećava „Svjesnost o situaciji", predlaže se i uvođenje obveze ugradnje i primjene sustava za automatsku identifikaciju na sve kategorije putničkih brodova u svrhu povećanja sigurnosti plovidbe. Uvođenje obveze ugradnje i primjene sustava za automatsku identifikaciju na sva plovila omogućavalo bi učinkovitu identifikaciju svih plovila na Jadranu (AIS klase A i AIS klase B), efikasnije nadziranje prometa, lakše analiziranje gustoće prometa, lakše pružanje pomoći na moru, mogućnost upozoravanja brodova kojima prijeti rizik sudara ili nasukavanja od strane VTS službe te kvalitetniju analizu pomorskih nezgoda ako do njih dođe i sl.

Za pomorsku nezgodu sudar napravljen je test utjecaja na uvjetovanu vjerojatnost čvora „Izbjegavanje" kada su njegovi roditeljski čvorovi postavljeni na najgori mogući scenarij. Čvorovi: „Navigacijska pogreška", „Gubitak kontrole", „Oštećenje broda" te „Plovidba u području posebnog opreza" postavljeni su na najveće negativne vrijednosti te je prikazan rezultat takvog scenarija: uvjetovana vjerojatnost čvora koji se odnosi na nemogućnost izbjegavanja drugog broda je porasla na 90 %.

Kvalitativnim testom modela vjerodostojnije se prikazuje osjetljivost određenih parametara na pomorsku nezgodu u modelu nasukavanja, a manje vjerodostojno u modelu sudara. Jedan od razloga zašto su u modelu sudara za čvor „Dan/noć" te „Gustoća prometa" dobivene manje realno očekivane vrijednosti jest mali broj promatranih pomorskih nezgoda koje su korištene za određivanje apriori vjerojatnosti. Ovakve su anomalije u modelu bile očekivane. U radu M. Hanninen, P. Kujala iz 2012. godine, male vrijednosti osjetljivosti određenih varijabli, primjerice gustoće prometa, mogu se objasniti općenitim malim numeričkim vrijednostima

[26] Prema Pomorskom zakoniku Članka 134. Zapovjednik, član posade broda, jahte ili brodice ne smije tijekom obavljanja dužnosti na brodu, brodici ili jahti imati više od 0,5g/kg alkohola u krvi.

osjetljivosti svih utjecajnih varijabli. Ako je broj sudarnih kandidata visok, kao što je to slučaj u uskim prolazima i područjima velike gustoće prometa, tada sasvim malo povećanje uvjetovane vjerojatnosti može rezultirati značajno visokom vjerojatnošću sudara te se sukladno navedenom varijable s malim vrijednostima osjetljivosti ne smiju automatski smatrati neutjecajnima.

Potrebno je napomenuti da su rezultati modeliranja ovisni i o strukturi Bayesove mreže. Utjecaj jedne varijable na drugu u Bayesovoj mreži smanjuje se kada se put između njih povećava, dok srednje varijable doprinose nesigurnosti modela (M. Hanninen, P. Kujala, 2012).

Analiza osjetljivosti modela napravljena je za modele nasukavanja te sudara na dva načina: u prvom, testiranje je izvršeno uz pomoć ekspertnog znanja, a u drugom uz pomoć matematičkih rezultata kvalitativnih vrijednosti varijabli u modelu, tj. prvo testiranje je napravljeno na temelju izbora „ciljanih čvorova“ prema ekspertnom mišljenju, a drugo na temelju izbora „ciljanih čvorova“ prema rezultatima kvalitativnog testa modela.

Rezultati testova osjetljivosti provedeni na dva načina za modele nasukavanja i sudara, pokazuju različite osjetljivosti varijabla u modelu pa je rezultatima analize modela dokazana tvrdnja da se procjena eksperata, koja se uvelike koristi u modeliranju Bayesovim mrežama, može bazirati na subjektivnom mišljenju te u nekim slučajevima umanjiti vjerodostojnost modela. Stoga je, nakon modeliranja neophodno izvršiti testiranja modela.

Rezultati testa osjetljivosti napravljeni na temelju procjene eksperata za model nasukavanja prikazuju najosjetljivije varijable: „Navigacijska pogreška“, „Stanje mora“ te „Snaga vjetra“.

Rezultati testa osjetljivosti napravljeni na temelju rezultata kvalitativnog testa za model nasukavanja prikazuju najosjetljivije varijable: „Navigacija u plitkom području“ te „Sigurnosna kultura“.

Rezultati testa osjetljivosti napravljeni na temelju procjene eksperata za model sudara prikazuju najosjetljivije varijable: „Pojava“, „Doba dana“, „Vizualna detekcija“, „Ljudska pogreška“, „Doba godine“, „Gubitak kontrole drugog broda“ te „Pogreška drugog broda“.

Rezultati testa osjetljivosti napravljenog na temelju rezultata kvalitativnog testa za model sudara prikazuje osjetljive varijable: „Onesposobljenost“, „Osobno stanje“, Izbjegavanje“, „Plovidba u području posebnog opreza“, „Radar“, „Komunikacija s drugim brodom“ te „Pojava“.

Analiza testova osjetljivosti za model sudara izrađena uz pomoć kvalitativnog testa i procjene eksperata ukazuje na to da su najvažnije varijable utjecaja na sudar varijable na koje ne možemo utjecati, a odnose se na meteorološke čimbenike i vidljivost. Prema testu osjetljivosti napravljenom uz pomoć kvalitativnog testa najveći utjecaj imaju ljudski čimbenici. Prema rezultatima testa osjetljivosti mjere za unaprjeđenje sigurnosti odnosile bi se na uvođenje radara te AIS uređaja radi povećavanja svjesnosti situacije tijekom upravljanja brodom.

Model nasukavanja testiran je unošenjem vrijednosti varijabli iz izvješća o pomorskoj nezgodi nasukavanja putničkog broda „Zlatni žal“. Vjerojatnost za pomorsku nezgodu nasukavanja ovim se povećala za 1 % što se može smatrati potvrdom ispravnosti modela. Vrijednosti koje se odnose na uvjete u kojima se dogodila pomorska nezgoda, a koji su preuzeti iz izvještaja o pomorskoj nezgodi te uneseni kao ulazni podaci u model su zapravo vrijednosti koje potencijalno nisu preduvjet za pomorsku nezgodu, osim čvora „Svjesnost o situaciji“ koji je postavljen na negativnu vrijednost. Povećanje vjerojatnosti za nasukavanje za 1 % pod navedenim uvjetima u modelu kod kojeg nema velikih odstupanja u postocima vjerojatnosti pokazuje da model radi ispravno jer je dokazana osjetljivost modela na određene parametre.

Prema analizama podataka Ministarstva pomorstva, prometa i infrastrukture, pomorska nezgoda „Nesposoban za plovidbu“ druga je po zastupljenosti pomorskih nezgoda te je autori Frančić i ostali, (2009) povezuju s starošću promatranih brodova. Autori navode podatak da su drveni brodovi najzastupljeniji u pomorskim nezgodama „Nesposoban za plovidbu“. Ovaj neželjeni događaj, koji prema podjeli nadležnog Ministarstva spada u pomorsku nezgodu, nije detaljno opisan u radu zbog mogućnosti prijelaza iz navedenog neželjenog stanja u željeno, bez posljedica za posadu, brod i okoliš. Nadalje, podaci iz navedenog rada ne mogu se direktno koristiti u ovoj disertaciji jer je u zadnjih devet godina velik broj brodova izgrađen od čelika.

Jedan od razloga relativno velike brojnosti pomorske nezgode „Udar“ je plovidba te privez u lukama s nedovoljnim brojem priveznih mjesta za ovu vrstu brodova. Smatra se da se veliki broj pomorskih nezgoda udara ne prijavljuje zbog posljedica zadržavanja broda u luci prilikom istraživanja pomorske nezgode, a sama pomorska nezgoda udara u većini slučajeva nije opasna za putnike (podaci dobiveni ekspertnim mišljenjem). Kao smjernica za poboljšanje sigurnosti plovidbe predlaže se traženje adekvatnih rješenja za boravak promatranih brodova u njihovim lukama ticanja.

Osim navedenih faktora utjecaja analiziranih kroz Bayesove modele koji uzrokuju pomorske nezgode, neophodno je spomenuti neželjeno stanje u kojem se putnički brodovi često nalaze − bolest ili ozljeda putnika (analiza podataka MMPI-a). Stanje bolesti ili ozljede putnika spada u česta stanja promatranih brodova te bi se navedeno stanje trebalo detaljnije analizirati i napraviti preporuke novih mjera, odnosno istražiti adekvatna rješenja za pružanje medicinske pomoći na moru. Jedna od preporuka je uvođenje dodatne obuke članova posade za pružanje medicinske pomoći putnicima na moru.

Prema istraživanju analize sigurnosti putničkih brodova autora Frančić i ostali (2009) čak 66 % posade svih putničkih brodova isključeni su iz obveze obuke članova posade glede pružanja pomoći putnicima u izvanrednim okolnostima te se i u ovome radu predlaže uvođenje dodatnih obuka zapovjednika i svih članova posade na svim putničkim brodovima.

Eksperti koji su sudjelovali u radu napomenuli su da u ljetnom periodu velike gustoće prometa primjećuju generalno loše poznavanje „Pravila o izbjegavanju sudara na moru“ i ostalih propisa sigurnosti plovidbe te loše poznavanje plovidbene prakse od strane osoba koje upravljaju brodicama i jahtama. Stoga je preporuka za povećanje sigurnosti prometa uvođenje većeg broja brodova i brodica lučkih kapetanija na moru u cilju preventivnog nadzora i povećanih kontrola.

Nadalje, eksperti kao potencijalno opasnu radnju za putnike spominju vezivanje više brodova bočno jedan na drugi. Moguće posljedice ovakvog načina vezivanja, čiji je uzrok manjak slobodnih vezova mogu biti: ozljeđivanje putnika ili pad u more te moguće nagnječenje između dvaju brodova pri prelasku s jednog broda na drugi, pomorske nezgode u slučaju promjene hidrometeoroloških uvjeta te posljedice u slučaju požara ili eksplozije na jednom od vezanih brodova. Kako bi se povećala sigurnost plovidbe, predlaže se za postojeće i nove luke u kojima promatrani brodovi pristaju izrada „Maritimne studije“ u kojoj će biti definiran najveći broj brodova koji se mogu privezati jedan na drugi, način rasporeda priveznih konopa kao i hidrometeorološki uvjeti kada se to može smatrati sigurnim.

6.5 Moguća primjena i preporuke za daljnje istraživanje

Cilj analiziranja pomorskih nezgoda te izrade procjene vjerojatnosti pojave pomorskih nezgoda je utvrđivanje uzroka i odlučujućih utjecajnih faktora kako bi se spriječile buduće pomorske nezgode. Modeli procjene rizika pomorskih nezgoda prikazani uz pomoć Bayesovih mreža u ovome radu mogu biti primijenjeni u analiziranju sigurnosti plovidbe

promatranih brodova. Na temelju dobivenih rezultata, analiza i zaključaka, moguće je predložiti sigurnosne preporuke koje se mogu odnositi na unaprjeđenje radnih postupaka na brodu, izmjene propisa, načine provođenja inspekcijskog nadzora, upravljanje brodom, uvježbavanje posade, načine popravka i održavanja brodova, postupke pomoći s kopna i sl.

Uz pomoć prikazanih modela moguće je uočiti najznačajnije negativne čimbenike utjecaja na pomorske nezgode u određenim scenarijima te razmatrati načine smanjenja njihovih utjecaja na krajnje rezultate modela. Modele je moguće nadopunjavati novim varijablama sukladno potrebama, stoga su korisni za analiziranje učinkovitosti određenih mjera u svrhu sigurnosti plovidbe. Prikazani modeli korisni su i za analizu implementacije novih pomagala u navigaciji, načina praćenja brodova te novih načina plovidbe.

Kao što je već opisano u radu, modeliranje temeljeno na Bayesovim mrežama moguće je poboljšati na više načina:

- unošenjem preciznijih, odnosno točnijih podataka
- uključivanjem većeg broja eksperata u izradu modela, kao i u procese izrade tablica uvjetovane vjerojatnosti
- preslagivanjem čvorova unutar modela te uvođenjem novih veza unutar modela i uvođenjem novih čvorova na temelju novih informacija
- testiranjem modela s više slučajeva stvarnih događaja.

Jedan od temeljnih problema modeliranja je nedostatak podataka ili u ovome slučaju relativno mali broj pomorskih nezgoda na kojima je izvršena statistička analiza. U svrhu poboljšavanja modela trebalo bi ponovno analizirati podatke i implementirati ih u model 2020. godine. Tako bi se promatrano razdoblje proširilo na deset godina što bi poboljšalo kvalitetu modela izrađenih u ovoj disertaciji. Također je moguće prilikom unošenja podataka u tablice uvjetovanih vjerojatnosti koristiti manje decimalne brojeve u svrhu dobivanja većih osjetljivosti pojedinih čvorova. Model je moguće poboljšati i ispitivanjem većeg broja eksperata. Nadalje, prikazane modele u ovoj disertaciji moguće je nadograditi te u njih implementirati nove čvorove ili više stanja pojedinih čvorova na temelju novih podataka čime bi se povećala kvaliteta modela. Modeli napravljeni u ovoj disertaciji mogu služiti kao baza za detaljnije analize pojedinih segmenata unutar modela i kao primjeren alat za ispitivanje utjecaja novih regulativa vezanih za sigurnost plovidbe.

Mali broj pojedinih pomorskih nezgoda onemogućava ispravnu validaciju modeliranja sa stvarnim događajem te je preporuka da se nakon određenog broja pomorskih nezgoda ponovi validiranje temeljeno na scenariju pomorske nezgode „slijed ishoda najveće vjerojatnosti.“[27]

[27] Mohović Đ., 2011.

7. ZAKLJUČAK

Putnički nelinijski brodovi u obalnoj plovidbi su brodovi s trendom povećanja kapaciteta putnika i veličine brodova. Njihova brojnost zahtijeva provođenje analize sigurnosti plovidbe bazirajući se na mogućim neželjenim situacijama koje za rezultat mogu imati pomorsku nezgodu. Mali broj nezgoda ukazuje na njihovu relativnu sigurnost, ali usprkos tome eventualne pomorske nezgode nelinijskih brodova predstavljaju potencijalnu prijetnju. Istraživanje pomorskih nezgoda ima za cilj unaprjeđenje sigurnosti prometa, odnosno utvrđivanje uzroka pomorskih nezgoda kako bi se umanjila vjerojatnost pojave pomorskih nezgoda, stoga su u radu predložene mjere za preventivno djelovanje.

Pomorske nezgode rezultat su kombinacije događaja različitih utjecajnih čimbenika koji su svaki put drugačiji. Stoga se metoda koja je izabrana za izradu procjene pomorskih nezgoda temelji na Bayesovim mrežama koje su prikladne za modeliranje sustava čije ponašanje ovisi o velikom broju varijabli s nepoznatim ovisnostima. U ovoj doktorskoj disertaciji su za analizu vjerojatnosti pomorskih nezgoda na Jadranu korištene Bayesove mreže koje podrazumijevaju korisničku procjenu vjerojatnosti da će se određeni događaj dogoditi pod određenim uvjetima.

Izrađeni modeli i naknadni zaključci omogućuju šire razumijevanje utjecajnih čimbenika pomorskih nezgoda. Razumijevanje utjecajnih čimbenika od velike je važnosti zbog mogućeg smanjenja negativnih posljedica na ljudske živote i imovinu. Također, uz pomoć Bayesovih mreža, prilikom modeliranja pomorskih nezgoda lako je uočljiv utjecaj promjena određenih parametara na rezultat modela što omogućuje olakšano odlučivanje pri donošenju određenih mjera u svrhu povećavanja sigurnosti promatranih brodova.

U procesu modeliranja pomorske nezgode Bayesovom mrežom korištene su dvije metode prikupljanja podataka za izradu modela. Prva metoda izrade modela koristi Bayesove mreže uz korištenje statističkih podataka. Druga metoda koristi procjene eksperata o vjerojatnosti i nastupanju određenog događaja. U ovoj disertaciji korištene su obje metode kako bi se što vjernije prikazali odnosi čimbenika utjecaja na pomorske nezgode.

Rezultati modela testirani kvalitativnim testom, testom osjetljivosti te usporedbom rezultata modela sa stvarnim događajem potvrdili su zadovoljavajuću kvalitetu razvijenih modela.

Rezultate modela moguće je koristiti za istraživanje odnosa brojčanih vrijednosti različitih tipova nedostataka, prikupljenih od različitih izvora. Također, ovakav način modeliranja

omogućuje razumijevanje odnosa uvjetovanih vjerojatnosti i ovisnosti čimbenika uz pomoć preglednog grafičkog prikaza u kojem se lako uočavaju čimbenici na koje se može utjecati te njihova međuovisnost, kao i ovisnost o drugim čimbenicima.

Provedenim istraživanjem dokazana je temeljna hipoteza da se procjena rizika pojave pomorskih nezgoda može poboljšati komplementarnim djelovanjem kvalitativne i kvantitativne analize podataka temeljene na Bayesovim mrežama, koje su parametarski prilagodljive području interesa.

LITERATURA

Knjige

1. L. R. Guidance notes for collision analysis. Lloyd's register, London, 2014.
2. Favro S., Kovačić M., Nautički turizam i luke nautičkog turizma, Split, 2010.
3. Finn V. Jensen, Thomas D. Nielsen, Bayesian Networks and Decision Graphs, 2007.
4. Gluhonja I, Brodovi na jedra, Izdavačko poduzeće „Pomorstvo", Rijeka 1951.
5. IALA, IALA recommendation 0-134 on the IALA risk management tool for ports and restricted waterways, International Association of Marine Aids to Navigation and Lighthouse Authorities; May, 2009.
6. IMO, Degree of risk evaluation. SN.1/Circ.296. International Maritime Organization; Dec, 2010.
7. Janeš, V., Čavrak B., Procjena opasnosti za opasne tvari, Zagreb, Zavod za istraživanje i razvoj sigurnosti, 1999.
8. Jensen, F. i ostali, Bayesian Networks and Decision Graphs, Information Science and Statistics, 2007.
9. Kevin, B., Nicholson, A. E., Bayesian Artificial Intelligence, 2nd ed., 2016.
10. Kozličić, M., Hrvatsko brodovlje, Zagreb 1991.
11. Luković i ostali, Nautički turizam Hrvatske, Split 2015.
12. Luković, T., Gržetić, Z., Nautičko turističko tržište u teoriji i praksi Hrvatske i europskog dijela Mediterana, Hrvatski hidrografski institut, Split, 2007.
13. Luković, T., Šamanović J., Menanžment i ekonomika nautičkog turizma, Hrvatski hidrografski institut, Split, 2007.
14. Peljar I. Jadransko more – istočna obala, Split 2012.
15. Peljar za male brodove – drugi dio, Hrvatski hidrografski institut, Split, 2003.
16. Rausand, M., Risk Assessment – Theory, Methods, and Applications. John Wilwy & Sons, Inc., Hoboken, New Jersey, 2011.
17. Reason, J., Human Error, Cambridge University Press, Cambridge, 1990.
18. Vidučić, V., Pomorski turizam – prometne, razvojne i ekološke dileme, Split 2017.

19. Zec, D., Sigurnost na moru, Pomorski fakultet, Rijeka 2001.

20. Zelenika, R., Metodologija i tehnologija izrade znanstvenog i stručnog djela, Ekonomski fakultet Sveučilišta u Rijeci, Rijeka, 2000.

Radovi u stručnim i znanstvenim časopisima te zbornicima

21. Akhatar, M. J., Fatigue at Sea a Manning Problem, Journal of maritime research, Vol XI, No III, 27-42, 2014.

22. Akhtar, M. J., Utne I. B., Modelling the impact of human fatigue on the risk of shipping accidents, Transport Research Arena, Paris, 2014.

23. Antão, P. i ostali,Analysis of maritimr accident dana with BBN models. Safety, reliability and risk analysis: theory, methods and applications, London, 2009.

24. Aven, T., On how to define, understand and describe risk, Reliab. Eng. Syst. Saf. 95 (6), 623-631, 2010.

25. Bayes, T., An essay towards solving a problem in the dovtrine of chances, Philosophical Transactions of the Royal Society of London, 53, 370-418, 1763.

26. Bielić, T., Zec D., Ujecaj brodske tehnologije i organizacije rada na umor; Pomorski zbornik 42, 2004.

27. Božikov, J., Modeliranje i simulacija, U: Kern J. urednica. Medicinskoinformatičke metode. Priručnik doktorskog studija. Zagreb: Medicinska naklada, 69-84, 2006.

28. Bukša, J., Zec, D., Model procjene pomorskog rizika u ograničenom plovnom području, Pomorstvo, Scientific Journal of Maritime Research, Rijeka, 2005.

29. Bukša, J., Zec, D., Poslovno-tehnološki rizici u obalnom linijskom kontejnerskom brodarstvu, Pomorstvo, 25/1, 125-144, 2011.

30. Castillo, E., Gutierrez, J.M., Hadi, A.S., Sensitivity analysis in discrete Bayesian Networks. IEEE Trans. Syst. Man Cybern. Part A Syst. Hum. 27 (4), 412–423, 1997.

31. Chang, C-H., Xu, J., Song, D.-P., An analysis of safety and security risks in container shipping operations: a case study of Taiwan, Saf. Sci., 63,168-178, 2014.

32. Charniak, E., Bayesian networks without tears, AI magazine, 12(4):50, 1991.

33. Christos, A. K., Harilaos N.P.: Formal Safety Assessment: A Critical Review; Marine Tehnology, Vol 46, 45-49. January 2009.

34. Debnath, A.K., Chin, H.C. Navigational Traffic Conflict Technique, A Proactive Approach to Quantitative Measurement of Collision Risks in Port Waters. Journal of Navigation, 63(01), 137-152, 2010.

35. Delaš, N., Čulin, J.,Gundić, A., Bielić, T., Ljudski faktor kao uzrok pomorske nezgode, Suvremeni promet: časopis za pitaja teorije i prakse prometa 37 (2017)

36. Faghih-Roohi, S., Xie M., and Ng KM., Accident risk assessment in marine transportation via Markov modelling and Markov Chain Monte Carlo simulation, Ocean Eng , 91, 363–70, 2014.

37. Frančić, V., Njegovan M., Maglić L., Analiza sigurnosti putničkih brodova u nacionalnoj plovidbi, Pomorstvo 23, 2, 539-555, 2009.

38. Goerlandt, F., Ståhlberg K, Kujala P.,Influence of impact scenario models on collision riskanalysis, OceanEng, 47, 74–87, 2012.

39. Goerlandt, F., Montewka J., Maritime transportation risk analysis: Review and analysis in light of some foundational issuses; Reliability Engineering System Safety 138, 115-134, 2015.

40. Goerlandt, F., Montewka J., A framework for risk anaysis of maritime transportation systems: a case study for oil spill from tankers in a ship-ship collision, Safety Science 76, 42–66, 2015.

41. Gordon, R. P., The contribution of human factors to accidents in the offshore oil industry, Reliability Engineering & System Safety, 61 (1-2), 95-108, Offshore safety,1998.

42. Grech, M. R, Horberry T., Smith A**.,** Human error in maritime operations: analyses of accident reports using the leximancer tool, Proc. Human Factors Ergonom. Soc. Ann. Meet., 46, 1718-1721, 2002.

43. Hanninen, M. i ostali, Expert elicitation of a navigation service implementation effects on ship groundings and collisions in the Gulf of Finland, Journal of Risk and reliability, 2013.

44. Hanninen, M., Kujala P., The Effects of Causation Probability on the Ship Collision Statistics in Gulf of Finland, Helsinki University of Technology, Finland, 2009.

45. Hanninen, M., Kujala P., Bayesian network modeling of Port State Control inspection findings and ship accident involvement, Expert Systems with Applications 41, 1632–1646, 2014.

46. Hanninen, M., Kujala P., Influences of variables on ship collision probability in a Bayesian belif network model, Reability Engineering and System Safety 102, 27-40, 2012.

47. Hanninen, M., Analysis of Human and organizational factors in marine traffic risk modeling, Helsinki, 2008.

48. Haapasaari P. i ostali, A proactive approach for maritime safety policy making for the Gulf of Finland: Seeking best practices, Marine Policy Volume 60, 107-118, 2015.

49. Hetherington C., Flin R., Meaarns K.,Safety in shipping: the human element, Journal of safety research, 37(4), 40,1-11, 2006

50. Hess, M., Kos, S., Njegovan M.; Procjena i kontrola operativnih rizika na brodu u skladu s ISM pravilnikom, Pomorstvo, god. 25, 2/ 405-416, 2011.

51. Hollnagel, E., Risk + barries = safety? Safety science 46, 221-229, 2008.

52. Jason, R. W., Merrick, J., Rene van Dorp, Speaking the truth in Maritime Risk Assessment, Port and Harbour Risk Assessment and Safety Management Systems in New Zeland, Maritime Safety Authority 2004.

53. Jean-Francois Balmamt i ostali, A decision-making system to maritime risk assessment; Ocean Engineering 38, 171-176, 2011.

54. Jones, C. i ostali, Working hours regulation and fatigue in transportation: A comparative analysis, Safety science, 43, 225-252, 2005.

55. Khaled, M. E, Kawamura Y., Collision Risk Analysis of Chittagong Port in Bangladesh by Using Collision Frequency Calculation Models with Modified BBN Model, International Society of Offshore and Polar Engineers, Hawaii, 2015.

56. Kjaerulff, U. B. and Madsen, A. L., Bayesian networks and influence diagrams, Springer science + Business Media, 200:114, 2008.

57. Koester, T., Human factors and everyday routine in the maritime work domain. In Human Factors in Transportation, Communication, Helth and the Workplace, Human Factor and Ergonomis Society Europe Chapter Annual Meeting. Citeseer, 2001.

58. Konovessis i ostali, Risk evaluation for RoPax vessels, Proceedings of the Institution of Mechanical Engineers, Part M, Journal of Engineering for the Maritime Environment 2008.

59. Kovačić, M., Favro S., Gržetić, Z: Traditional sailing ships for day-trips and cruises in croatia: Currnt issues and development opportunities, University of Maribor, Faculty of Organizational Sciences, 355-361, 2014.

60. Kujala,P., Hänninen M., Arola T., Ylitalo J., Analysis of the marine traffic safety in the Gulf of Finland, Reliability Engineering & System Safety 94 (8), 1349-1357, 172, 2009.

61. Lale, S. i ostali, Primjena Bayesove mreže u analizama rizika u pomorstvu, Naše more 62 (1), 16-25, 2015.

62. Langseth, H., Portinale L., Bayesian networks in reliability, Reliability Engineering & System Safety, Volume 92, 92-108, January 2007.

63. Lapa K., Xhelilaj, E.,'The role of human fatigue factor towards maritime casualtie', Maritime transport & Navigation Journal Vol. 13, 2010., 23- 29.

64. Li S, Meng Q, Qu X., An overview of maritime waterway quantitative risk assessment models, Risk Anal., 32 (3), 496-512, 2012.

65. Liu i ostali, Engineering system safety analysis and synthesis using the fuzzy rule-based evidential reasoning approach, Quality and Reliability Engineering International, 25, 387-411, 2005.

66. Macduff, T., The probability of vessel collisions, Ocean industry 9,9, 144-148, 1974.

67. Marwedel, P., Evalution and validation, Embedded System Design, Embedded Systems Foundations of Cyber-Physical Systems, 203-234, 2011.

68. Mascaro, S. i ostali, Learning Abnormal Vessel Behaviour from AIS Data with Bayesian Networks at Two Time Scales, Clayton School Of Information Technology, Monash Univeresity; August 2010.

69. Mazaheri, A., Probabilistic Modeling of Ship Grounding - A review of the literature, Helsinki University of Technology, 2009.

70. Mazaheri, A, Montewka J., Nisula J., Kujala P., Usability of accident reports for evidence-based risk modeling – A case study in ship grounding reports, Safety Science Volume 76, 202-214, July 2015.

71. Mazaheri, A., Montewka J., Kujala P., Towards an evidence-based probabilistic risk model for ship-grounding, Safety Science, 195-210, 2016.

72. Merrick, J.R., van Dorp R., Speaking the truth in mariime risk assessment, Risk Analysis 26 (1); 223-37, 2006.

73. Minorski, VU., An analysis of Ship Collisions with Reference to Protection of Nucler Power plants, Journal of Ship Reasrch,3 (2), 1-4, 1959.

74. Mohović, Đ., Barić M., Itković H., Prijedlog unaprjeđenju sigurnosti plovidbe plovila nautičkog turizma, (117-130), Pomorstvo, 2013.

75. Mohović, Đ., Upravljanje rizikom u pomorstvu, autorizirana predavanja, Rijeka, 2011.

76. Montewka J. i ostali, A framework for risk assessment for maritime transportation systems – A case study for open sea collisions involving RoPAx vessels; Reability Engineering and System Safety 124, 142-157, 2014.

77. Montewka, J. i ostali, A risk frame work for maritime transportation systems, International Ship Stability workshop, Brest, 2013.

78. Montewka, J. i ostali, On a systematic perspective on risk for formal safety assessment (FSA), Reability Engineering and System Safety 127, 77-85, 2014.

79. Mullai, A., Paulsson U., A Grounded theory for analysis of marine accidents, Accident Analysis and Prevention 43, 1590-1603, 2011.

80. Murphy, K., A Brief Introduction to Graphical Models and Bayesian Networks, 1998.

81. Øien, K., Risk indicators as a tool for risk control, Reliability Engineering & system Safety, 74(2), 129-145, 2001.

82. Pearl, J., Causality Models Reasoning and Inference, Cambridge University Press New York, 2000.

83. Peraić, I., Bayesove mreže u modeliranju učenika, dipolomski rad, Prirodoslovo-matematički fakultet, Split 2012.

84. Philips, O., Sagberg R., Managing driver fatigue in occupational settings, Institute of transport economics, Oslo 2010.

85. Reason, J. T., Managing the risk of organizational accidents, volume 6, Ashgate Aldershot, 1997.

86. Reason, J., Human error, Cambridge University Press, New York, 302, 1990.

87. Shaluf, I. M., Ahmadum, F.-R., and Shariff, A R., Trchnologiacl disasters factors, Journal of Loss Prevention in the Process Industries, 16(6):513-521, 2003.

88. Shenping, H., Jinpeng Z., Risk Assessment of Marine Traffic Safety at Coastal Water, Procedia Engineering 45, 31-37, 2012.

89. Shenping, H., Quangen Fang, Haibo Xia, Yongtao Xi, Formal safety assessment based on relative risks model in ship navigation, Reliabillity Engineering and System Safety 92, 369-377, 2007.

90. Suyi, Li, Qiang, Meng and Xiabo, Qu; An Overview of Maritime Waterway Quantitative Risk Assessment Models, Risk Analysis Vol 32, No 3, 2012.

91. Ugurlu, Umut Yidirim, Ersan Basar, Analysis of grounding accidents caused by human error, Journal of Marine Science and Technology, Vol. 23, No. 5, pp. 748-760, 2015.

92. Uluscu, S. O. i ostali, Risk Analysis of the Vessel Traffic in the the Sreait of Istanbul, Risk Analyis, 2009.

93. Van der Gaag, L.C., Renooij, S., Witteman, C.L.M., B.M.P. and Taal, B. G. Probabilities for a probabilistic network: a case study in oesophageal cancer, Artificial Intelligence in Medicine 25, 123–148, 2002.

94. Vanem, E., Skjong R., Collision and Grounding of Passenger Ships – Risk assessment and Emergency Evacuations, DNV Reasech, 2004.

95. Vanem, E., Skjong R., Desifning for safety in passenger ships utilizing advanced evacuation analyses – a risk based approach, Safety science 44, 111-135., 2006.

96. Vanem, E, Antao.P., Ostvik. I. de Comas. F.D., Analysing the risk of LNG carrier operations. Reliab. Eng. syst.saf. 93(9), 1328-1344, 2008.

97. Wang i ostali, Investigations of Human and Organizational Factors in hazardous vapor accidents, Journal of Hazardous Materials, Volume 191, Issues 1–3, 15 Pages 69-82, July 2011.
98. Wang, Y. F., Xie, M., Chin, K.-S., Fu, X.J., Accident analysis model based on Bayesian Network and evidential reasoning approach, J. Loss Prevent. Proc. 26, 2013.
99. Yuan, Z. i ostali, Risk-based optimal safety measure allocation for dust explosions; Safety Science 74, 79-92, 2015.
100. Zhang, D. i ostali, Incorportation of formal safety assessment and Bayesian network in navigational risk estimation of the Yangze River, REliability Engineering and System Safety 118, 93-105, 2013.
101. Zhang, W. i ostali, a method for detecting possible near-miss ship collision from AIS dana, Ocean Eng. 107, 60-69, 2015.

Studije, elaborati i propisi

102. Accident Investigation Board of Finland Annual Report 2007, Helsinki 2008.
103. Det Norske Varitas, Formal safety assessment – large passenger ships, technical report, DNV, 2003.
104. Det Norske Veritas, Formal safety assessment of Electronic Chart Display and Information System (ECDIS), Technical report, DNV, 2006.
105. Direktiva 2009/45/EZ Europskog parlamenta i Vijeća od 6. svibnja 2009. o sigurnosnim pravilima i normama za putničke brodove
106. Europska pomorska sigurnosna agencija – EMSA - www.emsa.europa.eu, 2016.
107. FSA for use in the IMO rule-making process, London, IMO, 2007.
108. Guidelines for Formal Safety Assessment (FSA) for use in the IMO rule making proces – IMO Formal Safety Assessment, FSA-RoPax ships, IMO, July 2008.
109. Guidelines for Port and Harbour Risk Assessment and Safety Management Systems in New Zeland, Maritime Safety Authority, 2014.
110. IMO (International Maritime Organisation), Code of the Investigation of Marine Causalities and Incidents, FSI 5/10/2, 1996.

111. IMO (International Maritime Organisation), Guidelines for Formal Safety (FSA) for use in IMO Rule –Making process. The MSC/Circ. 1023, MEPC/Circ.392, 2002.

112. Marine risk assessment, Det Norske Veritas for the Health and Safety Executive, Offshore technology report, 2001.

113. MSC 83/INF.2, Consolidated text of the guidelines for formal safety assessment

114. MSC/83, Formal Safety Assessment – Consolidated text of the Guidelines for Formal

115. Pravila za statutarnu certifikaciju putničkih brodova u nacionalnoj plovidbi 2013 – Hrvatski registar brodova

116. Prometno-plovidbena studija ─ Plovno područje Split, Ploče i Dubrovnik, voditelj: dr. sc. Damir Zec, naručitelj: Ministarstvo pomorstva, prometa i infrastrukture, Pomorski fakultet u Rijeci, studeni 2014.

117. Pomorsko-plovidbene studija plovnog područja Primorsko-goranske, Ličko-senjske, Zadarske i Šibensko-kninske županije, naručitelj: Ministarstvo pomorstva, prometa i infrastrukture, Pomorski fakultet u Rijeci, 2015.

Ostali izvori (enciklopedije, doktorski radovi, internet i drugi izvori)

118. Hanninen, M., Bayesian network modeling of potential patterns in maritime safety performance, Aalto University, School of Engineering, Helsinki 2015.

119. GeNIe Modeler, priručnik, 2017., http://support.bayesfusion.com/docs/genie.pdf

120. Grubišić, A., Model prilagodljivoga stjecanja znanja učenika u sustavima e-učenja, Doktorska disertacija, Zagreb 2012.

121. https://www.iaea.org/

122. Mohović, R., Model manevriranja brodom, Doktorska disertacija, Rijeka, 2002.

123. Mršić, L., Prijedlog izgradnje modela za podršku odlučivanju u trgovini korištenjem metode transformacije vremenske serije (REFII) i Bayesove logike, Doktorska disertacija, Zagreb 2011.

124. Ovčević, H., Model procjene vjerojatnosti neželjenih događaja u informacijskom sustavu upotrebom Bayesovog teorema, Doktorska disertacija, Zagreb 2015.

125. Peharda, N.: Upravljanje rizicima, [www.npeharda.html.] 2004.

126. Pomorski zakonik, N.N. 181/04, 76/07, 146/08, 61/11, 56/13 i 26/15.

127. Pravilnik o istraživanju pomorskih nesreća, N.N. 181/04.

128. Prometno-plovidbena studija - Plovno područje Split, Ploče i Dubrovnik, voditelj: dr. sc. Damir Zec, naručitelj: Ministarstvo pomorstva, prometa i infrastrukture, Pomorski fakultet u Rijeci, studeni 2014.

129. Risk Level and Acceptance Criteria for Passenger Ships, First interim report, part 2: Risk Acceptance Criteria European Maritime Safety Agency EMSA/OP/10/2013.

130. Safety Assessment (FSA) for use in the IMO rule-making process, London, IMO.

131. Yin, Jingbo, Quantitative risk assessment for maritime safety menagement, The Hong Kong Polytehnic University, 2011.

Popis slika

Slika 2-1: Nastanak pomorske nezgode 12

Slika 2-2: Starost putničkih brodova u Hrvatskoj 16

Slika 2-3: Broj pomorskih nezgoda prema vrsti plovnog objekta 17

Slika 2-4: Pomorske nezgode na moru prema klasifikaciji MMPI-a od 2011. do 2015. godine 18

Slika 2-5: Pomorske nezgode putničkih brodova prema klasifikaciji MMPI-a od 2011. do 2015. godine 19

Slika 2-6: Broj pomorskih nezgoda od 2011. do 2015. godine 20

Slika 2-7: Broj pomorskih nezgoda za putničke brodove od 2011. do 2015. godine 20

Slika 2-8: Distribucija pomorskih nezgoda teritorijalnog mora i unutarnjih voda EU zemalja za 2015. godinu 22

Slika 2-9: Vrste pomorskih nezgoda od 2011. − 2015. godine 22

Slika 2-10: Događaji od 2011. do 2015 23

Slika 2-11: Primjer prelaska broda iz željenog u neželjeno stanje 26

Slika 2-12: Moguća stanja plovidbe s prijelazima u neželjena stanja 27

Slika 2-13: Metodologija izrade modela 28

Slika 3-3-1: Roditeljski čvor A i dječji čvor B 31

Slika 3-3-2: Primjer Bayesove mreže 33

Slika 4-1: Osnovna podjela čimbenika utjecaja 36

Slika 4-2: Varijable čije su vrijednosti dobivene statističkom obradom 40

Slika 4-3: Prikaz broja pomorskih nezgoda svih brodova ovisno o dobu dana od 2011. do 2015. godine 44

Slika 4-4: Prikaz broja nezgoda putničkih brodova u vrijeme dana i noći od 2011. do 2015. godine 45

Slika 4-5: Broj pomorskih nezgoda za sve brodove od 2011. do 2015. godine 46

Slika 4-6: Broj pomorskih nezgoda putničkih brodova od 2011. do 2015. godine 46

Slika 4-7: Broj pomorskih nezgoda u ovisnosti o danu u tjednu kroz cijelu godinu od 2011.do 2015. godine 47

Slika 4-8: Broj pomorskih nezgoda putničkih brodova u ovisnosti o danu u tjednu kroz cijelu godinu od 2011. do 2015. godine 47

Slika 4-9: Broj pomorskih nezgoda u ovisnosti o danu u tjednu u ljetnom razdoblju za sve vrste brodova od 2011. do 2015. godine 48

Slika 4-10: Broj pomorskih nezgoda u ovisnosti o danu u tjednu u ljetnom razdoblju za putničke brodove od 2011. do 2015. godine 48

Slika 4-11: Prikaz pomorskih nezgoda svih brodova od 5. do 9. mjeseca prema danima u tjednu 49

Slika 4-12: Vrijeme početka akcije spašavanja za sve kategorije brodova na Jadranu od 2010. do 2015. 50

Slika 4-13: Vrijeme početka akcije spašavanja za putničke brodove na Jadranu od 2010. do 2015. 51

Slika 4-14: Pojava za vrijeme pomorske nezgode svih brodova od 2011. do 2015. 54

Slika 4-15: Pojava za vrijeme pomorske nezgode putničkih brodova od 2011. do 2015. 54

Slika 4-16: Stanje mora za vrijeme pomorskih nezgoda svih brodova od 2011. do 2015. 55

Slika 4-17: Stanje mora za vrijeme pomorskih nezgoda putničkih brodova od 2011. do 2015. 56

Slika 4-18: Snaga vjetra za vrijeme pomorskih nezgoda svih brodova na Jadranu od 2011. do 2015. 57

Slika 4-19: Snaga vjetra za vrijeme pomorskih nezgoda putničkih brodova na Jadranu od 2011. do 2015. 57

Slika 4-20: Smjer vjetra za vrijeme pomorskih nezgoda svih brodova na Jadranu od 2011. do 2015. 59

Slika 4-21: Smjer vjetra za vrijeme pomorskih nezgoda putničkih brodova na Jadranu od 2011. do 2015. 59

Slika 4-22: Vidljivost za vrijeme pomorskih nezgoda svih brodova na Jadranu od 2011. do 2015. 60

Slika 4-23: Vidljivost za vrijeme pomorskih nezgoda putničkih brodova na Jadranu od 2011. do 2015. 60

Slika 4-24: Materijal od kojeg je brod izgrađen prema HRB za 2015. godinu 72

Slika 4-25: Starost putničkih brodova u nelinijskoj plovidbi 73

Slika 4-26: Kategorije plovidbe nelinijskih putničkih brodova 2015. godine 74

Slika 4-27: Zastava svih brodova koji su sudjelovali u pomorskim nezgodama od 2011. do 2015. 75

Slika 4-28: Zastava putničkih brodova koji su sudjelovali u pomorskim nezgodama od 2011. do 2015. 76

Slika 4-29: Područja posebnog opreza u Splitsko-dalmatinskoj županiji 81

Slika 5-1: Splitsko-dalmatinska županija 89

Slika 5-2: Kvalitativni model udara 95

Slika 5-3: Kvalitativni model nasukavanja 99

Slika 5-4: Moguće posljedice sudara za vrijeme plovidbe 102

Slika 5-5: Kvalitativni model sudara 103

Slika 5-6: Skraćeni kvalitativni model požara i eksplozije 106

Slika 6-1: Probabilistička skala korištena za dodjeljivanje vrijednosti uvjetovanih vjerojatnosti 109

Slika 6-2: Dio kvantitativnog modela nasukavanja koji se odnosi na osobno stanje osobe koja upravlja brodom 110

Slika 6-3: Uvjetovana vjerojatnost za čvor „Razina stresa“ 111

Slika 6-4: Uvjetovana vjerojatnost za čvor „Osobno stanje“ 111

Slika 6-5: Prikaz vrijednosti čvora „Osobno stanje“ nakon što su vrijednosti čvorova „Umor“ i „Razina stresa“ postavljene na 100 % 111

Slika 6-6: Dio kvantitativnog modela nasukavanja koji se odnosi na vizualnu detekciju osobe koja upravlja brodom 112

Slika 6-7: Uvjetovane vjerojatnost za čvor „Vizualna detekcija“ 112

Slika 6-8: Dio kvantitativnog modela nasukavanja koji se odnosi na gustoću prometa 113

Slika 6-9: Dio kvantitativnog modela nasukavanja koji se odnosi na svjesnost o situaciji ... 114

Slika 6-10: Primjer čvora „Svjesnost o situaciji“ kada su vrijednosti čvorova „Radar“ i „AIS“ postavljene na 100 %..... 114

Slika 6-11: Uvjetovana vjerojatnost za čvor „Druga ometanja“ 114

Slika 6-12: Uvjetovana vjerojatnost za čvor „Održavanje“ 115

Slika 6-13: Uvjetovana vjerojatnost za čvor „Ljudska pogreška“ 115

Slika 6-14: Uvjetovana vjerojatnost za čvor „Tehnička greška“ 115

Slika 6-15: Dio kvantitativnog modela nasukavanja koji se odnosi na gubitak kontrole 115

Slika 6-16: Uvjetovana vjerojatnosti za čvor „Gubitak kontrole“ 116

Slika 6-17: Dio kvantitativnog modela nasukavanja koji se odnosi na oštećenje broda..... 116

Slika 6-18: Uvjetovana vjerojatnost za čvor „Navigacijska pogreška“ 116

Slika 6-19: Dio kvantitativnog modela nasukavanja kada brod ne plovi po planiranom kursu 117

Slika 6-20: Uvjetovana vjerojatnost za čvor „Kada brod ne plovi po planiranom kursu“..... 117

Slika 6-21: Dio kvantitativnog modela nasukavanja koji se odnosi na plovidbu u plitkom području..... 117

Slika 6-22: Kvantitativni model nasukavanja za putničke nelinijske brodove 118

Slika 6-23: Dio kvalitativnog modela sudara koji se odnosi na svjesnost o situaciji i komunikaciju s drugim brodom 119

Slika 6-24: Uvjetovane vjerojatnost za čvor „Komunikacija s drugim brodom“ 120

Slika 6-25: Uvjetovana vjerojatnost za čvor „Izbjegavanje“ 120

Slika 6-26: Prikaz vrijednosti čvora „Izbjegavanje“ nakon što su vrijednosti za čvor „Navigacijska pogreška“, „Gubitak kontrole“, „Oštećenje broda“ te „Navigacija u području posebne opasnosti“ postavljene na 100 % 120

Slika 6-27: Dio kvantitativnog modela sudara koji se odnosi na čvor „Gubitak kontrole drugog broda“..... 121

Slika 6-28: Kvantitativni model sudara za putničke nelinijske brodove..... 122

Slika 6-29: Analiza osjetljivosti modela nasukavanja kada su „ciljani čvorovi“: „Navigacijska pogreška“ i „Oštećenje broda“ 128

Slika 6-30: Dijagram osjetljivosti za čvor „Navigacijska pogreška“ 129

Slika 6-31: Analiza osjetljivosti modela nasukavanja kada su „ciljani čvorovi“: „Navigacija u plitkom području“, „Sigurnosna kultura“ i „Kada brod ne plovi po planiranom kursu“130

Slika 6-32: Analiza osjetljivosti za model sudara kada su „ciljani čvorovi“: „Vizualna detekcija“, „Gustoća prometa“, „Gubitak kontrole drugog broda“ i „Gubitak kontrole“ 131

Slika 6-33: Analiza osjetljivosti za model sudara kada su „ciljani čvorovi“: „Izbjegavanje“, „Komunikacija s drugim brodom“ i „Svjesnost o situaciji“ 132

Slika 6-34: Model nasukavanja putničkog broda prema izvješću o pomorskoj nezgodi nasukavanja putničkog broda „Zlatni žal“ 134

Slika 6-35: Putnički brod „Zlatni žal“ nasukan na otoku Šćedru..... 134

Slika 6-36: Model nasukavanja linijskog putničkog broda prema izvješću o pomorskoj nezgodi nasukavanja putničkog broda „Lubrikata“ 136

Slika 6-37: Model nasukavanja linijskog putničkog broda prema izvješću o pomorskoj nezgodi putničkog broda „Lubrikata“ uzimajući u obzir plovidbu u plitkom području 137

Slika 6-38: Linijski mali putnički brod „ Lubrikata“ 137

Popis tablica

Tablica 2-1: Podjela plovidbe 25

Tablica 3-1: Primjer tablice uvjetovanje vjerojatnosti 33

Tablica 4-1: Izabrane varijable utjecaja na pomorske nezgodu 37

Tablica 4-2: Preliminarne vrijednosti čimbenika vremena 43

Tablica 4-3: Podjela dana i noći prema godišnjim dobima 44

Tablica 4-4: Preliminarne vrijednosti meteoroloških čimbenika utjecaja 52

Tablica 4-5: Preliminarne vrijednosti čimbenika gustoće prometa 62

Tablica 4-6: Preliminarne vrijednosti varijable ljudski faktor 63

Tablica 4-7: Preliminarne vrijednosti čimbenika brodskog sustava 71

Tablica 4-8: Preliminarne vrijednosti varijable plovidba u plitkom području 80

Tablica 4-9: Preliminarne vrijednosti čimbenika područja posebnog opreza 81

Tablica 4-10: Preliminarne vrijednosti čimbenika grešaka i gubitka kontrole 82

Tablica 5-1: Tablica korijenskih čvorova za model potonuća 91

Tablica 5-2: Tablica korijenskih čvorova za model udara 94

Tablica 5-3 Tablica korijenskih vrhova za kvalitativni model nasukavanja 97

Tablica 5-4: Tablica korijenskih čvorova za kvalitativni model sudara 104

Tablica 5-5: Tablica korijenskih vrhova za skraćeni model požara i eksplozije 107

PRILOZI

Prilog 1. Varijable modela pomorskih nezgoda

VARIJABLA	*IME*	*STANJA*	*IZVOR*	*RODITELJI*
dan/noć	*V1*	*da/ne*	*MMPI/statistika*	*-*
godišnje doba	*V2*	*D4*	*MMPI/statistika*	*-*
dan u tjednu	*V3*	*7*	*MMPI/statistika*	*-*
mjesec u godini	*V4*	*12*	*MMPI/statistika*	*-*
sat	*V5*	*24*	*MMPI/statistika*	*-*
vremenski uvjeti	*M1*	*dobri/loši*	*MMPI/statistika*	*mjesec u godini, godišnje doba*
pojava	*M2*	*5*	*MMPI/statistika*	*-*
visina vala	*M3*	*5*	*MMPI/statistika*	*-*
jačina vjetra	*M4*	*5*	*MMPI/statistika*	*-*
smjer vjetra	*M5*	*3*	*MMPI/statistika*	*-*
vidljivost	*M6*	*5*	*MMPI/statistika*	*pojava*
magla	*M7*	*da/ne*	*MMPI/statistika*	*-*
praćenje meteo izvještaja	*M8*	*da/ne*	*ekspert*	*sigurnosna kultura*
gustoća prometa	*G1*	*velika/mala*	*studija*[28]	*dan/noć, dan u tjednu, godišnje doba*
umor	*LJ1*	*da/ne*	*DNV,ekspert*	*-*
ISM code	*LJ2*	*da/ne*	*expert*	*sigurnosna kultura*
familijarizacija	*LJ3*	*da/ne*	*DNV*	*-*
razina stresa	*LJ4*	*da/ne*	*DNV*	
onesposobljenost	*LJ5*	*da/ne*	*Mazaheri, Montewka, Kujal, 2016*	*-*
druga ometanja	*LJ6*	*da/ne*	*DNV*	*sigurnosna kultura*
nenavigacijski zadaci	*LJ7*	*da/ne*	*DNV, ekspert*	*sigurnosna kultura*
svjesnost o situaciji	*LJ8*	*da/ne*	*DNV, ekspert*	*vizualna detekcija, AIS, osobno stanje*
osobno stanje	*LJ9*	*dobro/loše*	*DNV*	*umor, onesposobljenost, razina stresa*
komunikacija s drugim brodom	*LJ10*	*dobra/loša*	*ekspert*	*svjesnost o situaciji*

[28] Prometno-plovidbena studija plovno područje Split, Ploče i Dubrovnik.

sigurnosna kultura	*LJ11*	*dobra/loša*	*DNV*	*-*
materijal broda	*B1*	*6*	*HRB*	*-*
godina izgradnje	*B2*	*6*	*HRB*	*-*
opremljenost	*B3*	*dobra/srednja/loša*	*HRB*	*kategorija plovidbe*
kategorija plovidbe	*B4*	*6*	*HRB*	*-*
duljina putovanja	*B5*	*dnevni/sedmodnevni/četrnaestodnevni*	*ekspert*	*-*
zastava	*B6*	*hrvatska/strana*	*MMPI/statistika*	*-*
vidljivost sa mosta	*B8*	*dobra /standardna*	*ekspert*	*vidljivost*
održavanje broda	*B9*	*dobro/loše*	*ekspert*	*sigurnosna kultura*
AIS	*B10*	*da/ne*	*ekspert*	*-*
radar	*B11*	*da/ne*	*ekspert*	*-*
oštećenje broda	*B12*	*da/ne*	*ekspert*	*sudar, udar, požar i eksplozija, nasukavanje, hidrometeorološki čimbenici*
pukotina	*B13*	*da/ne*	*ekspert*	*sudar, udar, hidrometeorološki utjecaj, požar i eksplozija, nasukavanje*
proboj trupa	*B 14*	*da/ne*	*ekspert*	*sudar, udar, nasukavanje, požar i eksplozija*
naplavljivanje broda	*B15*	*da/ne*	*ekspert*	*sudar, udar, nasukavanje*
prevrtanje	*B16*	*da/ne*	*ekspert*	*sudar, nasukavanje*
lom konstrukcije	*B17*	*da/ne*	*ekspert*	*sudar, udar, požar i eksplozija, nasukavanje*
plovidba u plitkom području	*P1*	*da/ne*	*ekspert*	*-*
područje posebnog opreza	*P2*	*da/ne*	*ekspert*	*-*
gubitak kontrole	*O1*	*da/ne*	*DNV*	*tehnička greška, druga ometanja, svjesnost o situaciji, ljudska pogreška*
tehnička greška	*O2*	*da /ne*	*DNV*	*održavanje broda*
ljudska greška	*03*	*da/ne*	*DNV*	*osobno stanje*
navigacijska greška	*04*	*da /ne*	*DNV*	*svjesnost o situaciji*

izbjegavanje	*O5*	*da/ne*	*DNV*	*oštećenje broda, plovidba u području posebnog opreza, kada brod ne plovi po planiranom kursu, gubitak kontrole, navigacijska pogreška*
gubitak kontrole drugog broda	*O6*	*da/ne*	*ekspert*	*pogreška drugog broda*
greška drugog broda	*O7*	*da/ne*	*ekspert*	*-*
nemar putnika	*O8*	*da /ne*	*expert*	*-*
pogreška pri rukovanju	*O9*	*da /ne*	*ekspert*	*ISM code, ljudska pogreška, familijarizacija*
kada brod ne plovi po planiranom kursu	*O10*	*da /ne*	*ekspert*	*gubitak kontrole*

Prilog 2. Referenti podaci za tablicu ΔPg nasukavanja

PARAMETAR	BEST	P -best	WORST	P-worst	ΔPg	ΔPg
WEATHER	BRIGHTLY	0,13265539	FOG	0,1363025	0,0036471	0,00364715
DAY/NIGHT	DAY	0,13234608	NIGHT	0,1331325	0,0007864	0,0007864
DAY	SUNDAY	0,13313248	FRIDAY	0,1331325	0	0
SEASON	WINTER	0,13313248	SUMMER	0,1331325	0	0
VISIBILITY	EXCELLENT	0,13265539	VERY BAD	0,1365155	0,0038601	0,00386012
VISUAL DET.	GOOD	0,13172364	BAD	0,1370479	0,0053243	0,0053243
TRAFFIC. DIST.	LOW	0,13284968	MEDIUM	0,1324783	-0,0003713	0,00037135
HUMAN ERROR	NO	0,12899423	YES	0,1510265	0,0220323	0,0220323
OTHER D.	FEW	0,13030398	MANY	0,1375197	0,0072157	0,0072157
MAINTENANCE	YES	0,13056473	NO	0,1370078	0,0064431	0,00644311
FAMILIARIZATION	FAMIL.	0,13252573	NOT	0,1359959	0,0034701	0,00347012
STRESS LEVEL	STANDARD	0,13199187	HIGH	0,1373305	0,0053386	0,00533864
TIRED	NO	0,13248153	YES	0,1376366	0,005155	0,00515502
INCAPACITATED	CAPABLE	0,13273928	REDUCED	0,1426012	0,0098619	0,00986187
RADAR	YES	0,13276216	NO	0,1346888	0,0019266	0,0019266
AIS	YES	0,1330083	NO	0,1344426	0,0014343	0,00143432
PERSONAL C.	GOOD	0,13035967	BAD	0,1439613	0,0136016	0,01360164
SITUATIONAL A.	YES	0,12832813	NO	0,1448456	0,0165174	0,01651744

NAVIGATIONAL E.	NO	0,12710953	YES	0,1482875	0,0211779	0,02117792
NAVIG. IN SHALLOW	NO	0,1	YES	0,4372546	0,3372546	0,33725463
OFF COURSE	NO	0,103	YES	0,168	0,065	0,065
LOSS OF CONTROL	NO	0,12123953	YES	0,1565659	0,0353264	0,03532635
VESSEL DAMAGE	NO	0,1304116	YES	0,1476222	0,0172106	0,01721063
BREAKDOWN	NO	0,13104499	YES	0,1394379	0,0083929	0,00839288
STATE OF SEA	CALM	0,13306204	ROUGH	0,1403421	0,0072801	0,0072801
WIND F.	CALM	0,13091881	STORM	0,1405385	0,0096197	0,00961973
WIND D.	SE	0,13372546	NE	0,1337255	0	0
WATERWAY C.	NO	0,13072546	YES	0,1457255	0,015	0,015
SAFETY CULTURE	EXCELLENT	0,3022418	POOR	0,1372442	-0,1649976	0,16499762

Prilog 3. Referentni podaci za tablicu ΔPg sudara

PARAMETAR	**BEST**	**P -best**	**WORST**	**P-worst**	***ΔPg***	***ΔPg***
WEATHER	BRIGHTLY	0,11629255	FOG	0,12255537	0,00626282	0,00626282
DAY/NIGHT	DAY	0,12198273	NIGHT	0,11089046	-0,01109227	0,01109227
DAY	SUNDAY	0,11695212	FRIDAY	0,115458	-0,00149412	0,00149412
SEASON	WINTER	0,10736673	SUMMER	0,12032368	0,01295695	0,01295695
SAFETY CULTURE	EXCELLENT	0,11507678	POOR	0,11885468	0,0037779	0,00377790
VISIBILITY	EXCELLENT	0,11629255	VERY BAD	0,12299418	0,00670163	0,00670163
VISUAL DET.	GOOD	0,11549161	BAD	0,12044556	0,00495395	0,00495395
TRAFFIC. DIST.	LOW	0,10446608	HIGH	0,13335347	0,02888739	0,02888739
HUMAN ERROR	NO	0,11222708	YES	0,13657642	0,02434934	0,02434934
OTHER D.	FEW	0,11504707	MANY	0,11916419	0,00411712	0,00411712
MAINTENANCE	YES	0,11534265	NO	0,11858397	0,00324132	0,00324132
FAMILIARIZATION	FAMIL.	0,1160266	NOT	0,1226891	0,0066625	0,00666250
STRESS LEVEL	STANDARD	0,1150016	HIGH	0,1252516	0,01025	0,01025000
TIRED	NO	0,11594172	YES	0,12583918	0,00989746	0,00989746
INCAPACITATED	CAPABLE	0,11624534	REDUCED	0,13537104	0,0191257	0,01912570
RADAR	YES	0,11251679	NO	0,1203564	0,00783961	0,00783961
AIS	YES	0,11535594	NO	0,11751726	0,00216132	0,00216132
PERSONAL C.	GOOD	0,11163043	BAD	0,13800888	0,02637845	0,02637845

SITUATIONAL A.	YES	0,10440206	NO	0,14118093	0,03677887	0,03677887
NAVIGATIONAL E.	NO	0,13416123	YES	0,10638966	-0,02777157	0,02777157
OTHER SHIP ERROR	NO	0,11423194	YES	0,13627852	0,02204658	0,02204658
LOSS OF CONTROL OF OTHER SHIP	NO	0,11084016	YES	0,14475798	0,03391782	0,03391782
COMUNICATION WITH OTHER VESSEL	GOOD	0,1	BAD	0,14543374	0,04543374	0,04543374
LOSS OF CONTROL	NO	0,10824442	YES	0,13390467	0,02566025	0,02566025
OFF COURSE	NO	0,10658085	YES	0,12894959	0,02236874	0,02236874
VESSEL D.	NO	0,11319806	YES	0,13001749	0,01681943	0,01681943
BREAKDOWN	NO	0,1151099	YES	0,11926394	0,00415404	0,00415404
GIVE WAY	YES	0,1	NO	0,1345677	0,0345677	0,03456770
SPECIAL CAUTION AREA	NO	0,11631138	YES	0,11693746	0,00062608	0,00062608
SEA STATE	CALM	0,11578825	ROUGH	0,12290287	0,00711462	0,00711462
WIND FORCE	CALM	0,11369374	STORM	0,12309481	0,00940107	0,00940107
WIND DIRECTION	SE	0,1164366	NE	0,1164366	0	0,00000000