

Model nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina

Vorkapić, Aleksandar

Doctoral thesis / Disertacija

2020

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:187:407109>

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

Download date / Datum preuzimanja: **2024-06-29**

Repository / Repozitorij:



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

[Repository of the University of Rijeka, Faculty of
Maritime Studies - FMSRI Repository](#)



SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET

ALEKSANDAR VORKAPIĆ

**MODEL NADZORA I PREDVIĐANJA ENERGETSKE
UČINKOVITOSTI I ISPUŠTANJA UGLJIKOVA
DIOKSIDA NA PRIMJERU BRODA ZA PRIJEVOZ
UKAPLJENOGA NAFTNOG PLINA**

DOKTORSKA DISERTACIJA

RIJEKA, 2020.

SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET

Aleksandar Vorkapić

MODEL NADZORA I PREDVIĐANJA ENERGETSKE UČINKOVITOSTI I
ISPUŠTANJA UGLJIKOVA DIOKSIDA NA PRIMJERU BRODA ZA
PRIJEVOZ UKAPLJENOGA NAFTNOG PLINA

DOKTORSKA DISERTACIJA

Mentor: doc. dr. sc. Radoslav Radonja

Komentorica: prof. dr. sc. Sanda Martinčić-Ipšić

RIJEKA, 2020.

UNIVERSITY OF RIJEKA
FACULTY OF MARITIME STUDIES

ALEKSANDAR VORKAPIĆ

A MODEL OF MONITORING AND PREDICTION OF ENERGY
EFFICIENCY AND CARBON DIOXIDE EMISSION IN CASE OF
LIQUEFIED PETROLEUM GAS CARRIER

DOCTORAL THESIS

RIJEKA, 2020

Doktorska disertacija pod naslovom:

**,,Model nadzora i predviđanja energetske učinkovitosti i
ispuštanja ugljikova dioksida na primjeru broda za prijevoz
ukapljenoga naftnog plina”,**

pod mentorstvom dr. sc. Radoslav Radonja, docent Pomorskog fakulteta, Sveučilišta u Rijeci i komentorstvom dr. sc. Sanda Martinčić-Ipšić, redovite profesorice Odjela za informatiku , Sveučilišta u Rijeci, obranjena je u Rijeci, dana 07. veljače 2020. pred povjerenstvom za obranu u sastavu:

1. Dr. sc. Goran Vukelić, izvanredni profesor Pomorskog fakulteta, Sveučilišta u Rijeci, predsjednik,
2. Dr. sc. Dean Bernečić, izvanredni profesor Pomorskog fakulteta, Sveučilišta u Rijeci, član i
3. Dr. sc. Ivan Štajduhar, izvanredni profesor Tehničkog fakulteta, Sveučilišta u Rijeci, član.

Predgovor

Ova doktorska disertacija završni je dio poslijediplomskog sveučilišnog studija „Pomorstvo“, studijskog smjera „Pomorski energetski i strojni sustavi“ Pomorskog fakulteta, Sveučilišta u Rijeci.

Istraživanje pod mentorstvom koje je prethodilo disertaciji odvijalo se u razdoblju od veljače 2018. godine do lipnja 2018. godine u sklopu istoimenog kolegija pod mentorstvom docenta Radoslava Radonje s Pomorskog fakulteta u Rijeci, Sveučilišta u Rijeci i komentorstvom profesorice Sande Martinčić-Ipšić s Odjela za informatiku, Sveučilišta u Rijeci, koja me uvela u svijet strojnog učenja i pružila nebrojene savjete i smjernice iz kojih je ova disertacija proizašla.

Ovim im putem upućujem izraze zahvalnosti na doprinosima i podršci tijekom izrade ovog rada.

Izraze zahvalnosti upućujem Karlu Babiću i Josipu Drobnjaku koji su mi pružili podršku prilikom obrade prikupljenih podataka te Nataliji Vitali koja mi je pomogla kod rekonstruiranja vremenskih uvjeta i stanja mora iz vanjskih izvora.

Posebnu zahvalnost iskazujem svojoj obitelji, a osobito supruzi Snježani na pruženoj podršci, strpljenju i odričanjima tijekom proteklih godina.

Sažetak

U ovom istraživanju predstavljen je model nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida temeljen na senzorskim podacima preuzetim s broda za prijevoz ukapljenoga naftnog plina te meteorološkim i oceanografskim podacima sukladnim geografskom položaju i vremenu plovidbe. Za gradnju modela korištene su metode strojnog učenja u sinergiji s općom teorijom sustava. Model upotrebljava klasifikacijske i regresijske postupke strojnog učenja: naivni Bayes, višeslojni perceptron, strojeve potpornih vektora, stabla odluke, nasumične šume te multinomijalnu logističku i linearu regresiju. Nakon verifikacije postupaka pripreme podataka, učenja klasifikacijskih i regresijskih modela i analize rezultata kako bi se poboljšala točnost predviđanja energetske učinkovitosti, na temelju standardnih mjera vrednovanja (točnost predviđanja, mjera F_1 i ostale) odabran je najbolji algoritam za učenje modela. Eksperimentalni rezultati pokazuju da, uz potrošnju goriva kao izlaznu varijablu predviđanja te odgovarajuću kombinaciju i obradu relevantnih podataka senzora, nasumične šume postižu najbolji rezultat od 97,40% točno klasificiranih slučajeva i koeficijent korelacije od 0,9992 kod regresije. Uz to, svojom fleksibilnošću i jednostavnosću upotrebe te uz minimalna podešavanja potrebnih parametara, predstavlja najbolji izbor za uključivanje u model nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida. Opća teorija sustava rabljena je u prepoznavanju i tranzicijama komponenti predloženog modela nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina, sustavnom istraživanju unutarnjeg i vanjskog okruženja te definiranju informacijskih tokova između pojedinih komponenti. Pritom su vanjske mogućnosti i prijetnje s kojima se suočava sustav suprotstavljene unutarnjim snagama i slabostima da bi se kao rezultat formulirale strategije u kojima su slabosti i prijetnje sustava neutralizirane postojećim snagama i mogućnostima. Slijedom vrednovanja odabranih postupaka strojnog učenja, te rezultata SWOT i TOWS analize, moguće je zaključiti da je postavljeni model nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina ostvariv te široko primjenjiv u pomorskoj industriji. U doktorskoj disertaciji pokazano je da se obradom senzorskih podataka preuzetih u plovidbi s uključenim podacima o vanjskim utjecajima može postaviti model koji opisuje, predviđa i omogućuje prilagodbu relevantnih operacijskih parametara broda za energetski učinkovitiji prijevoz ukapljenoga naftnog plina.

Ključne riječi: *operacijska učinkovitost broda, energetska učinkovitost plovidbe, smanjenje emisija ugljikova dioksida s brodova, strojno učenje, klasifikacija, regresija, senzorski podaci*

Summary

In this study, a model of monitoring and prediction of energy efficiency and carbon dioxide emissions based on the sensor data taken from the liquefied petroleum gas carrier and meteorological and oceanographic data in accordance with the geographic position and time of navigation was presented. Machine learning methods in synergy with the general system theory were used to construct the model. The model utilises various classification and regression machine learning techniques based on naive Bayes, multilayer perceptron, support vector machines, decision trees, random forests and multinominal logistic and linear regression. Upon verification of data preparation methods, classification and regression model learning and analysis of results, in order to improve the accuracy of predicting energy efficiency, the best algorithm was selected based on standard measures (prediction accuracy, F₁ measures, etc.). Experimental results show that, with fuel consumption as the predicting variable, and the corresponding combination and processing of relevant sensor data, random forests achieve the best result of 97.40% correctly classified cases and regression correlation coefficient of 0.9992. In addition, with its flexibility and ease of use, and with minimal intervention in parameter settings, it is the preferred choice. The general system theory was used during the identification and transition of components of the proposed model of monitoring and prediction of energy efficiency and carbon dioxide emission in case of liquefied gas carrier, a systematic investigation of the internal and external environment and the definition of information flow between the individual components. Then, the external opportunities and threats that the system faces were opposed to internal forces and weaknesses in order to formulate strategies in which weaknesses and threats of the system are suppressed by existing forces and capabilities. After assessing the selected machine learning methods and the results of the SWOT and TOWS analysis, it can be concluded that the set model of monitoring and prediction of energy efficiency and carbon dioxide emission in case of liquefied gas carrier is feasible and widely applicable in the maritime industry. The doctoral dissertation showed that by processing sensor data in navigation with the inclusion of environmental data it is possible to set up a model that describes, forecasts and allows for the adjustment of relevant ship's working parameters for more efficient transportation of liquefied petroleum gas.

Keywords: *ship operational performance, energy efficient navigation, ships' carbon dioxide emission reduction, machine learning, classification, regression, sensor data*

Sadržaj

Predgovor.....	ii
Sažetak.....	iii
Summary.....	v
Sadržaj	1
1. Uvod	3
1.1. Predmet doktorske disertacije	3
1.2. Svrha i ciljevi istraživanja	4
1.3. Definiranje problema istraživanja, glavna hipoteza i pomoćne hipoteze.....	6
1.4. Pregled dosadašnjih istraživanja	7
1.5. Znanstvene metode.....	10
1.6. Struktura rada	11
2. Utjecaj, zakonska regulativa i mogućnosti smanjenja ispuštanja ugljikova dioksida s pomorskih brodova	13
2.1. Emisije ispušnih plinova u morskom graničnom sloju atmosfere i njihov utjecaj na ljudsko zdravlje i okoliš.....	13
2.1.1. Krute čestice i neizgoreni ugljikovodici	15
2.1.2. Dušikovi oksidi	17
2.1.3. Sumporni oksidi.....	18
2.1.4. Ugljikov dioksid.....	19
2.2. Usvojena međunarodna pravna regulativa prema povećanju energetske učinkovitosti pomorskih brodova i smanjenju ispuštanja ugljikova dioksida	22
2.3. Brodski plan upravljanja energetskom učinkovitosti i projektni indeks energetske učinkovitosti	24
2.4. Tehnološka rješenja i postupci unaprjeđenja energetske učinkovitosti i smanjenja emisije ugljikova dioksida s postojećih brodova.....	29
2.4.1. Optimizacija putovanja	30
2.4.2. Upravljanje potrošnjom energije.....	32
2.4.3. Održavanje trupa, vijka i postrojenja	32
2.4.4. Konstrukcijske preinake na postojećim brodovima	33
2.4.5. Upotreba alternativnih vrsta goriva	34
2.4.6. Ekološka prihvatljivost broda i prepreke široj implementaciji mjera smanjenja emisija ugljikova dioksida.....	37
3. Metode procjene relevantnih operacijskih parametara	41
3.1. Metode temeljene na fizičkim zakonitostima.....	44
3.1.1. Tradicionalne i metode obrade serija.....	44
3.1.2. Metode regresije.....	47
3.1.3. Izravni testovi modela.....	49

3.1.4. Metode računalne dinamike fluida.....	51
3.2. Metode rudarenja podataka	53
3.2.1. Klasifikacijske metode.....	56
3.2.2. Metode regresijske analize.....	69
3.3. Metodologija vrednovanja rezultata rudarenja podataka	70
4. Prijedlog metode nadzora i predviđanja operacijskih parametara.....	77
4.1. Prikupljanje i priprema podataka	77
4.2. Izgradnja i testiranje metode za predviđanja operacijskih parametara.....	85
4.2.1. Diskretizacija podataka u razrede	85
4.3. Vrednovanje metoda rudarenja podataka.....	88
4.3.1. Usporedba rezultata dobivenih upotrebom različitih metoda rudarenja podataka i odabir najprimijerenije.....	88
4.3.2. Izbor i analiza različitih kombinacija ulaznih varijabli.....	97
4.3.3. Izbor i analiza različitih izlaznih varijabli uvažavajući specifične uvjete primjene	100
5. Prijedlog modela nadzora i predviđanja energetske učinkovitosti i ispuštenog ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina	111
5.1. Osnovna obilježja sustava	111
5.2. Opis postojećeg stanja.....	115
5.3. Prijedlog strukture novog sustava	116
5.4. Analiza i rasprava o dobivenim rezultatima.....	123
6. Znanstveni doprinos doktorske disertacije	128
6.1. Primjena rezultata znanstvenog istraživanja	128
6.2. Prijedlog za nastavak znanstveno-istraživačkog rada	129
7. Zaključak i preporuke	130
Prilozi	133
Prilog A: Pregled ulaznih varijabli	133
Prilog B: Prikaz plovidbe na zemljopisnoj karti	138
Prilog C: Tablice korelacije	142
Prilog D: Matrice zabune	144
Popis slika	146
Popis tablica	147
Popis oznaka i kratica	149
Literatura	154
Životopis s opisom znanstvenog i stručnog rada	165

1. UVOD

Pomorski je promet jedan od najbrže rastućih vrsta prometa u pogledu onečišćenja atmosfere ugljikovim dioksidom i Međunarodna pomorska organizacija (engl. *International Maritime Organization, IMO*) preuzeila je vodeću ulogu prema smanjenju ispuštanja provodeći brzu akciju donošenjem različitih mjera. S obzirom na to da je jedan od glavnih načina smanjenja emisije ugljikova dioksida smanjenje potrošnje ugljika iz goriva, odnosno smanjenje potrošnje goriva (koje se troši za propulziju, proizvodnju električne energije i proizvodnju vodene pare), posljedično učinkovitije iskorištavanje energije izravno smanjuje štetnu emisiju ugljikova dioksida.

1.1. Predmet doktorske disertacije

Predmet ovog istraživanja je prikupljanje operacijskih podataka s broda, njihova obrada i analiza, te prijedlog modela za unaprjeđenje energetske učinkovitosti i smanjenje emisije ugljikova dioksida u stvarnim uvjetima operacije broda za prijevoz ukapljenoga naftnog plina. IMO u 2016. godini usvaja obvezujuće zahteve prema brodovima bruto tonaže 5000 ili više, a koji se odnose na prikupljanje podataka s brodova za svaku vrstu goriva koju rabe, te dalnjih podataka vezanih uz prijevoz tereta. Tako prikupljeni podaci, koji opisuju uzroke za oko 85% svih ispuštanja ugljikova dioksida s pomorskih brodova bit će upotrebljavani prilikom odlučivanja o budućim ograničenjima za ispuštanje ugljikova dioksida.

Pomanjkanje pouzdanih izvora podataka o stvarnoj uštedi energije primjenom tehničkih i operacijskih rješenja prema povećanju energetske učinkovitosti i smanjenju ispuštanja ugljikova dioksida značajna je barijera pri širem uvođenju takvih rješenja. Tako su procjene uštede energije, odnosno smanjenja ispuštanja ugljikova dioksida s pomorskih brodova, nerijetko precijenjene, optimistične i međusobno djelomično ili u potpunosti isključive [1]. Proizvođači opreme ili rješenja ističu vrijednosti koje im odgovaraju, nerijetko dobivene teorijski na ispitnome stolu ili računalnom simulacijom te potom projicirane na stacionarne uvjete broda [2]. U dostupnoj se literaturi pojedine mjere primjenjuju na uvjete za koje nisu predviđene – primjerice, povećanje brzine kontejnerskog broda nije automatski primjenjivo na brod za prijevoz sirove nafte – ili pak predviđaju cijenu goriva koja je višestruko uvećana [3]. Pri procjeni učinkovitosti pojedinih mjera za smanjenje potrošnje goriva neophodno je uzeti u obzir stvarni operacijski profil broda, količinu prevoženog tereta ili balasta te vanjske uvjete, poput morskih struja, vjetra i valova.

Danas, suvremeni brodovi imaju nekoliko puta veći broj senzorskih signala prema sustavima za nadzor postrojenja koji se obrađuju, no ne pohranjuju ih i ne rabe s ciljem smanjenja utroška energije i emisije štetnih plinova. Nadalje, moderni sustavi nadzora motora s unutarnjim izgaranjem obrađuju velik broj senzorskih podataka, no ne pohranjuju ih, što onemogućava mogućnost praćenja rada motora i broda kroz dulje razdoblje.

Potaknuto nedostatkom obrade senzorskih podataka brodskih sustava u relevantnoj literaturi, ovo istraživanje usmjeren je na analizu mogućnosti i primjenu računalnih rješenja za unaprjeđenje energetske učinkovitosti i smanjenje emisije ugljikova dioksida. Izvorni podaci mogu se grupirati u skupinu propulzije, vanjskih uvjeta, operacijskih postupaka, proizvodnje električne energije te podataka vezanih uz teret broda za prijevoz ukapljenoga naftnog plina. Brod za prijevoz ukapljenoga naftnog plina odabran je zbog dostupnosti podataka te ugrađenog sustava ukapljivanja tereta, čime je predloženi model primjenjiv na sve brodove sa sustavima ukapljivanja tereta.

1.2. Svrha i ciljevi istraživanja

Osnovna je svrha ovog istraživanja, u okvirima predložene teme doktorske disertacije te izravno i u najužoj vezi s problemom, predmetom istraživanja i postavljenom hipotezom, upotreboom znanstvenih metoda, doći do relevantnih spoznaja i saznanja koja bi se upotrebljavala prilikom:

- planiranja putovanja i operacije brodskih sustava, gdje su troškovna učinkovitost i ekološka prihvatljivost glavni prioriteti,
- izravne usporedbe stanja „prije i poslije”, primjerice, nakon dokovanja ili nadogradnje te usporedbe s referentnim procesima,
- unaprjeđenja projektnog indeksa energetske učinkovitosti (engl. *Energy efficiency design index, EEDI*) i optimizacije brodskog plana upravljanja energetskom učinkovitosti (engl. *Ship energy efficiency management plan, SEEMP*),
- prilagodbe poslovne politike i razvoja brodara prema načelu ekološke održivosti uspostavljanjem ravnoteže između poslovanja i odgovornosti prema cjelovitosti ekosustava

i u tom kontekstu znanstveno utemeljeno usmjeriti i formulirati rezultate istraživanja u izradu modela koji opisuje brodski sustav i predviđa relevantne operacijske parametre, te potom interpretirati dobivene rezultate kako bi se ostvario cilj istraživanja.

Cilj je istraživanja postaviti model koji metodama analize i rudarenja podataka opisuje i predviđa relevantne operacijske parametre vezane uz količinu ispuštenog ugljikova dioksida s broda za prijevoz ukapljenoga naftnog plina. Podaci koji će se obrađivati raspoloživi su senzorski podaci brodskog sustava nadzora postrojenja i prostora za skladištenje tereta, brodska podnevna izvješća te javno dostupni meteorološki i oceanografski podaci. Da bi se postavio model koji s prihvatljivom točnošću opisuje operacijski proces broda, potrebno je prikupiti i analizirati podatke te odabratи metodu rudarenja podataka (engl. *data mining*) klasifikacijskim ili regresijskim algoritmima koja daje najbolje rezultate predviđanja relevantnih operacijskih parametara broda.

Izračun potrošnje goriva broda uobičajeno se procjenjuje prema podacima prikupljenim u probnoj vožnji. Probna vožnja ne izvodi se sa stvarnom količinom tereta, već u teškom balastu¹ (engl. *heavy ballast*). Snaga porivnog stroja i potrošnja goriva broda u punom teretu izračunavaju se na temelju očekivanog otpora trupa, dakle, to su teorijski dobivene vrijednosti. Starenjem broda te vrijednosti mogu značajno odstupati od stvarnih. Nadalje, brodovi ispuštaju znatne količine ugljikova dioksida izgaranjem goriva u pogonskim motorima s unutarnjim izgaranjem i generatorima električne energije, posebice pri prijevozu ukapljenoga plina s ugrađenim sustavom ukapljivanja tereta. Instalirana snaga takvih sustava generatora električne energije nerijetko prelazi instaliranu propulzijsku snagu jednog Panamax² tankera te ne može biti zanemarena prilikom procjene ukupnog utroška goriva. Primjerice, kod brodova za prijevoz ukapljenoga naftnog plina količina goriva potrebna za ukapljivanje tereta kreće se u vrijednostima koje su više od 10% količine potrebne za propulziju³. Brodski planovi upravljanja energetskom učinkovitošću uvjetuju potrebu za procjenom utroška energije broda kao cjeline, a ne samo utroška goriva vezanog uz propulziju. Procjena emisije ispuštenog ugljikova dioksida postaje sve važnija brodovlasnicima jer i zakonodavstvo regulira globalno smanjenje emisije te mjere uštede energije na pomorskim brodovima. Iako su pojedine zakonske regulative na snazi, načini ocjene pomaka u emisiji i uštedi su nepotpuni i neprecizni. Transparentnije praćenje emisija ugljikova dioksida te implementacije mjera za smanjenje poticaj su proizvođačima opreme i brodovlasnicima na intenzivniji razvoj, ugradnju i primjenu

¹ Stanje nepotpune natovarenosti broda s brodskim balastnim tankovima napunjениm do punog kapaciteta.

² Panamax brodovi izmjerama su prilagođeni prolasku kroz Panamski kanal.

³ Podatak preuzet s broda za prijevoz ukapljenog prirodног plina (216000m³, GTT MarkIII, membrane type) sa ugrađenim sustavom za ukapljivanje kao osnovne metode održavanja tlaka u tankovima tereta (5600kgBOG/hr)

takvih sustava, stoga su proizvođači u mogućnosti jasnije predstaviti prednosti ugradnje takvih rješenja, dok brodari jednostavnije pronalaze teret za brodove koji dokazano troše manju količinu goriva i ostavljaju manji otisak na okoliš. Ekološki prihvativljivo upravljanje brodom ne samo da pomaže brodovlasniku održati odgovoran odnos prema okruženju već omogućava i stvarne uštede u poslovanju.

Pažljivim odabirom podataka koje brodari (u sklopu brodskih sustava nadzora i podnevnih izvješća) imaju na raspolaganju može se postaviti model koji praćenjem operacijskih parametara daje precizan opis sustava omogućujući bolje razumijevanje odnosa između unutarnjih i vanjskih čimbenika. Takav se model može rabiti prilikom procjene i predviđanja relevantnih operacijskih parametara, čime bi se omogućila energetski učinkovitija plovidba broda za prijevoz ukapljenoga naftnog plina sa smanjenom emisijom ugljikova dioksida. Očekivane su osnovne prednosti dobivenog modela jednostavnost uporabe, dostupnost te niski troškovi primjene.

1.3. Definiranje problema istraživanja, glavna hipoteza i pomoćne hipoteze

Polazeći od prethodno definirane svrhe istraživanja u okvirima predložene teme doktorske disertacije te nakon definiranja radnih hipoteza, jasno se tumači nekoliko smjerova istraživanja, pri čemu dokazivanje hipoteze postaje znanstveni problem koji se rješava primjenom znanstvenih metoda. Ključni je problem istraživanja postavljanje modela kojim bi se opisao proces praćenja potrošnje goriva i omogućilo predviđanje relevantnih operacijskih parametara broda te rezultiralo uvidima koji pridonose unaprjeđenju energetske učinkovitosti i smanjenju emisije ugljikova dioksida broda za prijevoz ukapljenoga naftnog plina.

Glavna hipoteza: Obradom podataka preuzetih sa senzora u plovidbi i uključivanjem podataka o vanjskim utjecajima moguće je postaviti model koji opisuje, predviđa i omogućuje prilagodbu relevantnih operacijskih parametara broda koji vode k energetski učinkovitijem prijevozu ukapljenoga naftnog plina.

Pomoćna hipoteza 1: Primjenom modela koji s visokom točnošću opisuje i predviđa relevantne operacijske parametre moguće je utjecati na korekciju postojećeg brodskog plana upravljanja energetskom učinkovitošću.

Pomoćna hipoteza 2: Definirane utjecajne koeficijente proizašle iz modela moguće je rabiti za unaprjeđenje energetskog sustava i projektnog indeksa energetske učinkovitosti.

Pomoćna hipoteza 3: Primjenom modela može se utjecati na prilagodbu poslovne politike brodara prema većoj ekološkoj prihvativljivosti broda na međunarodnom pomorskom tržištu.

1.4. Pregled dosadašnjih istraživanja

Znanstveni izvori o mjerama uštete energije i smanjenja emisije ugljikova dioksida u pomorskoj industriji mogu se podijeliti u dvije osnovne skupine: oni izvori koji prepoznaju i uspoređuju potencijal raspoloživih mjera [1, 2, 4-10], te izvori u kojima se detaljnije istražuje jedna ili manja skupina mjera s detaljnim procjenama o učinkovitosti i primjeni. Primjeri druge skupine napredni su premazi podvodnih dijelova trupa [11], optimizacija uzdužnog nagiba broda [12] i plovidba prema preporukama vremenskih prognostičara [13], dok se učinkovitost plovidbe pri lošim vremenskim uvjetima analizira u više radova [14-17].

Ekonomski aspekti raščlane problematike povrata ulaganja sredstava u energetski učinkovitiju operaciju brodom obrađuju autori Delitala, Gallino, Villa, Lagouvardos i Drago [18].

Metode procjene otpora trupa te dodatnog otpora mogu se podijeliti u četiri osnovne skupine [19]: tradicionalne i standardne metode s nizom [20-22], regresijske metode [23, 24], izravni testovi modela [22, 25, 26] te računalna dinamika fluida (engl. *computational fluid dynamics, CFD*) [27, 28].

Uobičajeno se metode izračuna operacijskih parametara dijele na one temeljene na fizičkim zakonitostima te metode koje upotrebljavaju pristup statističke obrade podataka. Za razliku od modela temeljenih na fizičkim zakonitostima, statistički je pristup znatno rjeđe zastavljen u literaturi te se svega nekoliko objavljenih znanstvenih radova bavi primjenom metoda strojnog učenja i rudarenja podataka na operacijskim i senzorskim podacima broda.

Lajic i dr. [29] postavili su model podrške pri odlučivanju o promjeni smjera vožnje ili brzine plovidbe u kritičnim situacijama identifikacijom predstojećih događaja (poput promjene smjera i veličine valova i vjetra) redizajnom postojećeg matematičkog modela u sklopu sustava *SeaSense*. Prema predloženom sustavu koji obrađuje i pogrešne signale (engl. *fault tolerant system*) s dijagnostikom pogreške (engl. *fault diagnosis*) i metodom vrednovanja i izbora najprikladnije kombinacije podataka (engl. *sensor fusion quality test, SFQ test*), odnosno mogućnošću nastavka predviđanja, i u slučaju pogreške pri mjerenu različitim stanju mora, valova i sl., podaci koji se obrađuju prikupljeni su s postojećih sustava SeaSense instaliranih na nekoliko kontejnerskih i brodova danske ratne mornarice. SFQ se može uspješno upotrebljavati za povećanje preciznosti mjerjenja stanja mora, te se time povećava pouzdanost predviđanja odziva broda pri promjeni brzine i smjera plovidbe.

Petersen i dr. [30] predstavljaju model učinkovitosti plovidbe trajekta u obalnoj plovidbi razvijen pomoću umjetne neuronske mreže (engl. *artificial neural network, ANN*) i Gaussovim

procesom (GP) temeljenim na senzorskim podacima s putovanja u periodu od 1 sata i 55 minuta. Rezultati dobiveni umjetnim neuronskim mrežama bolji su od onih dobivenih Gaussovim procesom. Relativna je pogreška snage propulzije 1,65%, dok je 1,50% pogreška pri predviđanju utroška goriva.

Nielsen i Jelsen [31] opisuju sustav podrške pri odlučivanju o promjeni brzine broda i promjeni smjera plovidbe u lošijim vremenskim uvjetima u stvarnome vremenu upotrebom modela za predviđanje uz procjenu utjecaja valova. Predloženi model procjenjuje valni spektar kombinacijom hidrodinamičkog modeliranja te statističkom obradom preuzetih podataka. Autori se služe linearnom spektralnom analizom pri statističkoj obradi normalne raspodjele (Gaussova krivulja), dok se Monte Carlo simulacijom (MCS) i metodom pouzdanosti prvog reda (engl. *first order reliability method, FORM*) obrađuju podaci koji prate diskretne funkcije. Model je temeljen na podacima prikupljenim s osam senzora instaliranih na palubi pokusnog broda. Mjereni su podaci ubrzanje, visina valova, podaci senzora prelijevanja mora preko izložene pramčane palube (engl. *green water sensor*) te podaci preuzeti sa senzora naprezanja. Sustav daje obećavajuće rezultate, no potrebna je daleko veća količina podataka kako bi ga se u potpunosti potvrdilo.

Hansen [32] u sklopu doktorskog rada predstavlja model predviđanja operacijskih parametara i potrebe za čišćenjem brodskog trupa i vijka kontejnerskog broda upotrebom „Bond Graph” metode i regresijskim analizama. Rabi podatke s brodskih senzora, i to podatke senzora pokreta instaliranog na pramcu te podatke iz dnevnih izvješća u vremenskom razdoblju od 380 dana. Podaci koji se šalju s broda putem dnevnih izvješća nedovoljni su kako bi se primijetila potreba za čišćenjem trupa, dok je takva potreba razlučiva obradom senzorskih podataka. Unatoč tome što autor ne raspolaze potpunim podacima o vanjskim utjecajima, filtriranjem ulaznih podataka autor uspješno određuje početno stanje (engl. *steady state condition*) za mjerjenje stupnja obraštanja trupa i vijka.

Ruihua Lu i dr. [33] u svom istraživanju postavljaju model podrške pri odlučivanju o odabiru prikladnog smjera plovidbe s uključenim praćenjem obraštanja trupa i vijka te degradacije učinka glavnog porivnog stroja upotrebom modificirane metode [34] za predviđanje dodatnog otpora. Modifikacija koju autori predlažu sastoji se od dodanih podnevnih izvješća s dva broda

(*Suezmax*⁴ i *Aframax*⁵) u trajanju od pet godina te podataka s probne vožnje. Predstavljeni su rezultati unutar pogreške od 5,12% (*Suezmax*), odnosno 7,15% (*Aframax*).

Pedersen [35] u svome doktorskom radu predstavlja model predviđanja utroška goriva i trenda učinka propulzije korištenjem umjetne neuronske mreže (ANN) i Gaussovog procesa regresije (GPR). Model obrađuje operacijske podatke broda za prijevoz naftnih produkata. Autor u radu navodi ograničenja za upotrebu predloženog modela za procjenu učinka održavanja trupa prije i nakon dokovanja, odnosno ocjenu postupaka koji utječu na smanjenje utroška goriva.

Zhao i dr. [36] predstavljaju model predviđanja specifičnog utroška goriva, snage propulzijskog motora te brzine broda za prijevoz kontejnera upotrebom numeričkih modela koji opisuju uzdužno i rotacijsko gibanje broda u šest stupnjeva slobode u kombinaciji s modelom cikličke srednje vrijednosti (engl. *cycle mean value – CMV*) propulzijskog dvotaktnog motora u Matlab/Simulink okruženju. Model je temeljen na senzorskim podacima s *Type-2 Fuzzy* kontrolera instaliranog na brodu, podacima proizvođača, te meteorološkim podacima. Rezultati su unutar 2% pogreške za specifičnu potrošnju goriva u ovisnosti o broju okretaja motora, te su lošiji pri nižim okretajima motora.

Trodden i dr. [37] predstavljaju model planiranja utroška goriva i emisije ispušnih plinova remorkera te analizu početnog stanja, koji se potom mogu upotrijebiti za procjenu degradacije učinkovitosti tijekom vremena eksploracije programskim algoritmom upotrebe filtera kako bi se eliminirala sva stanja koja ne odgovaraju početnom. Model obrađuje 43143 primjerka mjerena brzine i utroška goriva remorkera u trajanju od 30 dana u različitim režimima rada. Autori pokazuju da se upotrebom ekološki učinkovite brzine (engl. *eco speed*) porivnog stroja smanjuje potrošnja goriva za oko 20% te je predstavljeni model uveden u upotrebu na remorkerima na kojima su istraživanja i provedena.

Bialystocki [38] predstavlja računalni model procjene utroška goriva obradom dnevnih (podnevnih) izvješća broda za prijevoz automobila (*Pure Car and Truck Carrier, PCTC*) tijekom 418 dana plovidbe s točnošću predviđanja u granicama od 2,76%.

⁴ *Suezmax* brodovi izmjerama su prilagođeni plovidbi Sueskim kanalom u stanju pod teretom. Termin se gotovo isključivo rabi za tankere.

⁵ *Aframax* je naziv za tanker za prijevoz nafte i naftnih derivata i zasniva se na sustavu rangiranja tankera koji je uvela kompanija Shell Oil (engl. *Average Freight Rate Assessment, AFRA*) radi standardiziranja trgovinskih ugovora u brodarstvu.

Perera [39] u svome radu obrađuje tematiku obrade senzorskih podataka s naglaskom na okvir njihova prikupljanja, prijenosa i obrade. Podaci su preuzeti s broda za prijevoz rasutog tereta i obrađuju se grupiranjem (engl. *clustering*) nenadziranim algoritmom Gauss-ovog modela mješavine (engl. *Gaussian mixture models, GMM*) s maksimizacijom očekivanja (engl. *expectation maximization, EM*) te se odgovarajući skupovi podataka prikazuju grafički pomoću dijagrama. Rezultati su grupiranja obećavajući, dok je okvir prikupljanja detaljno obrađen.

Na osnovi do sada prikupljenih i obrađenih bibliografskih jedinica, razvidno je da objavljeni radovi i metodologije procjene i izračuna dodatnog otpora i utroška goriva na temelju statističke obrade operacijskih podataka raspolažu s ograničenim podacima ili su usko vezani za područje plovidbe, vrstu broda, odnosno obradu podataka vezanih isključivo uz propulziju. Otklanjanje tih ograničenja bila je važna odrednica pri izboru istraživanja u ovome doktorskome radu. Uvažavajući prethodna istraživanja, ustanovljeno je da područje nije u dovoljnoj mjeri istraženo te postoji teorijsko i praktično opravdanje za ovo istraživanje.

1.5. Znanstvene metode

U znanstvenom istraživanju, formuliranju i prezentaciji rezultata istraživanja upotrebljavat će se induktivna i deduktivna metoda, metoda analize i sinteze, metoda apstrakcije i konkretizacije, metoda generalizacije i specijalizacije, metoda dokazivanja i opovrgavanja, komparativna metoda, statistička i matematička metoda, empirijska metoda, metode rudarenja podataka i opća teorija sustava, pomoću kojih će se istražiti problem, dobiti model te dokazati postavljene hipoteze. Za rudarenje podataka isprobat će se naivni Bayes, logistička regresija, multinomijalna logistička regresija, linearna regresija, višeslojni perceptron (umjetne neuronske mreže), strojevi potpornih vektora (engl. *support vector machines*), stabla odluke (engl. *decision trees*), nasumične šume (engl. *random forests*), te će se upotrebljavati njihova implementacija u programskom paketu Weka⁶ [40].

⁶ Weka je skup alata otvorenog pristupa napisan u programskom jeziku Java, razvijen na Sveučilištu Waikato na Novom Zelandu. Namijenjen je rješavanju zadataka iz područja rudarenja podataka uporabom integriranih alata za pripremu, klasifikaciju, regresiju, grupiranje, otkrivanje asocijacija i vizualizaciju podataka.

1.6. Struktura rada

Tematika je ove doktorske disertacije obrađena u sedam međusobno nadopunjajućih cjelina. U uvodnome dijelu obrazložena je tema doktorske disertacije, definiran je problem istraživanja, predstavljena glavna hipoteza i pomoćne hipoteze, određena svrha i ciljevi istraživanja, ocijenjena dosadašnja istraživanja, navedene najvažnije znanstvene metode rabljene u znanstvenom istraživanju i prezentiranju dobivenih rezultata te je obrazložena struktura disertacije.

U drugom dijelu, „*Utjecaj, zakonska regulativa i mogućnosti smanjenja ispuštanja ugljikova dioksida s pomorskih brodova*”, primjerena pozornost posvećena je utjecaju ispušnih plinova na kretanja zraka u morskom graničnom sloju atmosfere, a potom i na zdravlje čovjeka, okoliš i klimu, kao i procjeni budućih utjecaja i odnosa. Posebno je obrađena međunarodna pravna regulativa prema povećanju energetske učinkovitosti pomorskih brodova i smanjenju ispuštanja ugljikova dioksida, projektni indeks energetske učinkovitosti i brodska plan upravljanja energetskom učinkovitošću te implementacija tehnoloških rješenja i postupaka unaprjeđenja energetske učinkovitosti i smanjenja ispuštanja ugljikova dioksida s postojećih brodova.

U trećem dijelu, „*Metode procjene relevantnih operacijskih parametara*”, predstavljene su najčešće upotrebljavane metode predviđanja brodskih operacijskih parametara s naglaskom na metodama rudarenja podataka te je potom opisana metodologija procjene uspješnosti modela. Nakon znanstveno utemeljenih postavki predstavljenih u prethodnim dijelovima disertacije, slijedi četvrti dio, „*Prijedlog metode nadzora i predviđanja operacijskih parametara*”, u kojem je opisan proces prikupljanja i pripreme podataka, odabir različitih ulaznih i izlaznih varijabli, uvažavajući specifične uvjete primjene, te su predstavljene najprimjerenije metode za predviđanje relevantnih operacijskih parametara broda za prijevoz ukapljenoga naftnog plina. Uvažavajući specifične uvjete primjene izvršena je analiza ulaznih i izlaznih varijabli.

U petom dijelu, „*Prijedlog modela nadzora i predviđanja energetske učinkovitosti i ispuštenog ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina*”, opisano je postojeće stanje te sintezom prethodnih rezultata metoda rudarenja podataka predložena struktura modela nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida. U potpoglavlju „*Analiza i rasprava o dobivenim rezultatima*” analizom primjene modela uz pomoć opće teorije sustava bit će potvrđene glavna i pomoćne hipoteze.

U šestom dijelu, „*Znanstveni doprinos doktorske disertacije*”, predstavljen je znanstveni doprinos disertacije, izvršena je procjena primjenjivosti modela i mogućnosti implementacije

u okvirima trenutnog stanja te predložene smjernice za nastavak znanstveno-istraživačkog rada i buduća istraživanja.

U zaključnom dijelu, sustavno su predstavljeni najvažniji rezultati znanstvenog istraživanja, koji su opširnije elaborirani u disertaciji, a kojima je dokazana postavljena glavna i pomoćne hipoteze.

2. UTJECAJ, ZAKONSKA REGULATIVA I MOGUĆNOSTI SMANJENJA ISPUŠTANJA UGLJKOVA DIOKSIDA S POMORSKIH BRODOVA

Pomorski prijevoz u velikoj je mjeri ovisan o uporabi teških goriva (engl. *heavy fuel oil, HFO*) koja se još uvijek rabe u energetskim postrojenjima u velikoj većini (70 – 80%) brodova. HFO je viskozni produkt koji ostaje na kraju procesa rafiniranja sirove nafte te sadrži povišen udio različitih nečistoća, kao što su oksidi, sumpor i voda, a koje je nužno ukloniti npr. centrifugiranjem ili filtracijom. Pritom je važno da se viskoznost goriva reducira predgrijavanjem kako bi se omogućilo njegovo izgaranje. Bez obzira na navedeno, riječ je o popularno rabljenom, dostupnom i relativno jeftinom rafinerijskom nusproizvodu, dobro prilagođenom za uporabu u sadašnjim velikim brodskim motorima [41].

No upotreba navedenih goriva u pomorskom prometu ima i značajne, dugo zanemarivane negativne strane, što se posebice odnosi na emisiju štetnih plinova, produkata izgaranja HFO, u atmosferu. Od produkata i nusprodukata navedenog procesa izgaranja, u atmosferu se dominantno otpuštaju ugljikov dioksid (CO_2), vodena para (H_2O), dušikovi oksidi (NO_x), sumporovi oksidi (SO_x), fine čestice (engl. *particulate matters, PM*), hlapljivi organski spojevi (engl. *volatile organic compounds, VOCs*), crni/elementarni ugljik (engl. *black/elemental carbon, BC/EC*) te organski ugljik (engl. *organic carbon, OC*) [42, 43].

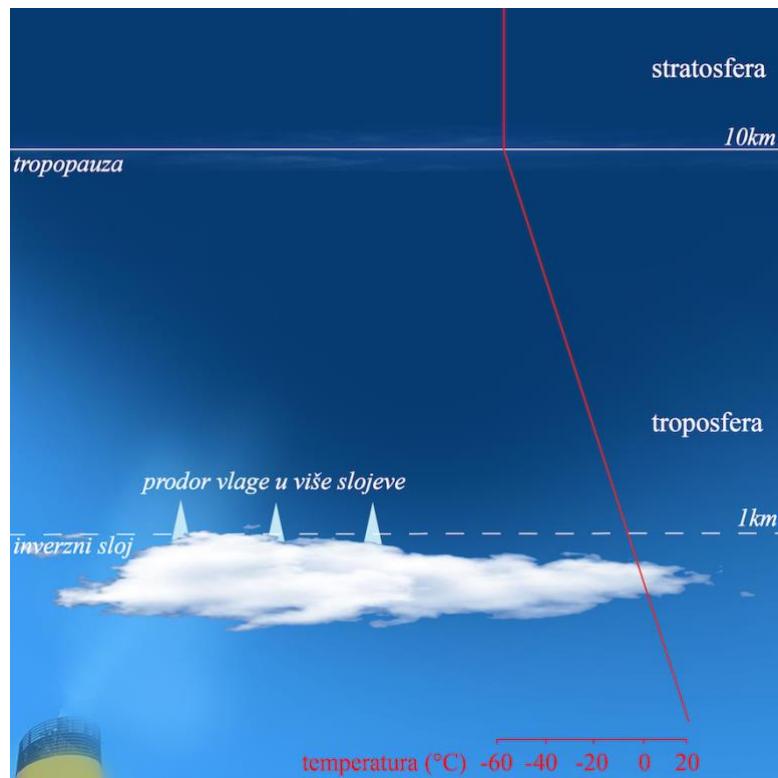
Emisije plinova s brodova čine mali dio, točnije 2,2% ukupnih globalnih emisija [7], no zabrinjavajuća je činjenica da se udio emisija s brodova povećava znatno brže u odnosu na druge izvore. IMO tako procjenjuje da je moguće povećanje ispuštanja stakleničkih plinova ili GHG-a (engl. *greenhouse gases, GHG*) s brodova čak za 50 – 250% do 2050. godine u odnosu na razine iz 2012. godine [7]. Također je zabilježen značajan porast ispuštanja metana (CH_4) i didušikovog oksida (N_2O).

2.1. Emisije ispušnih plinova u morskom graničnom sloju atmosfere i njihov utjecaj na ljudsko zdravlje i okoliš

Ispušni plinovi predstavljaju linijski izvor onečišćenja koji se izlaskom iz brodskih dimnjaka u obliku dimne struje, prateći smjer kretanja broda tijekom plovidbe u neposrednom području ispuštanja i doticaju s okolnim zrakom, kemijski mijenja te dolazi do stvaranja različitih sekundarnih spojeva. Kemijske reakcije u morskom graničnom sloju atmosfere, kao i u ostalim

dijelovima troposfere, ovisne su o primarnim emisijama tvari i njihovim naknadnim reakcijama. Neke su od najvažnijih kemijskih reakcija, koje se odvijaju u morskom graničnom sloju atmosfere, nastanak ozona uz katalitičko djelovanje dušičnih oksida, plinovita i vlažna oksidacija sumpornih oksida u sulfatne aerosole, raspad metana pomoću hidroksilnih radikala, te halogeno-katalitički raspad ozona [43].

Ekspanzija dimne struje ispušnih plinova s pomorskih brodova odvija se u smjeru okomitom na glavnu os, a vertikalna ekspanzija obično je ograničena inverznim slojem. Na disperziju i difuziju ispušnih plinova iz brodskog dimnjaka utječe veliki broj čimbenika kao što su brzina strujanja i temperatura ispušnih plinova, razina turbulencije, brzina i smjer vjetra, geometrija brodske konstrukcije itd. Morski granični sloj nerijetko se percipira kao dobro izmiješani sloj troposfere (s gornje strane ograničen inverznim slojem), u kojem pri vrhu dolazi do stvaranja naoblake, kumulusa, koji latentnom toplinom kondenzacije prodiru kroz inverzni sloj i omogućavaju prijelaz vlage u više slojeve, zbog čega njegova visina može biti od nekoliko stotina pa do preko tisuću metara (Slika 1.).



Slika 1. Širenje brodskih ispušnih plinova kroz slojeve atmosfere

Varijacija je uzrokovana upravo razmjenom između donje i gornje troposfere. Miješanje i kretanje zraka u morskom graničnom sloju atmosfere značajno se razlikuje od onog na kopnu i najveći dio emisija iz brodskih ispušnih sustava zadržava se upravo u tom sloju. Zbog velikog toplinskog kapaciteta mora i učinkovitosti njegovog miješanja, morski granični sloj atmosfere na otvorenom moru posjeduje veću temperaturnu ujednačenost zbog razlike između temperature mora i zraka koja je manja od one u obalnome području. Kada je temperatura zraka znatno niža od površinske temperature mora, doći će do uzburkane konvekcije, koja će uzrokovati nestabilne površinske uvjete, dok će strujanje toplog zraka iznad hladnije morske površine rezultirati stabilnijim uvjetima. Tijekom dana, uslijed zagrijavanja kratkovalnim zračenjem, morski granični sloj dijeli se od stratokumulusne naoblake, da bi u poslijepodnevnim satima došlo do ponovnog miješanja. Proces je naročito izražen kod guste naoblake i utječe na razmjenu plinova između mora i atmosfere te disperziju onečišćivača u određenom području [44].

Procesi miješanja i kemijskih reakcija ovise o primarnim koncentracijama sastojaka u dimnoj struji, prethodno zatečenim koncentracijama u okolišnoj atmosferi, trenutnim meteorološkim prilikama (npr. visini i stabilnosti morskog graničnog sloja atmosfere, smjeru i jačini vjetra ili naoblaci) i ostalim čimbenicima koji uključuju insolaciju, a u ovisnosti su o geografskoj širini, godišnjem dobu i vremenu [45].

Iako se sastojci nastali kao produkti izgaranja pojavljuju u relativno visokim koncentracijama u odnosu na prethodno zatečene koncentracije u atmosferi, oni uslijed mokre ili suhe depozicije uglavnom djelomično ili potpuno nestaju iz atmosfere. Ukoliko su ispuštanja veća (primjerice u područjima s većim pomorskim prometom), utoliko, s ekološkog gledišta, može doći do značajnijih negativnih utjecaja na okoliš, cjelokupnu biocenazu i čovjekova dobra i djelatnosti [46].

2.1.1. Krute čestice i neizgoreni ugljikovodici

Krute čestice (engl. *particulate matters, PM*) mješavina su krutih čestica i kapljica koje se ispuštaju u atmosferu, ponajviše iz brodskih sustava ispuha motora s unutarnjim izgaranjem i parnih kotlova. Neke čestice, kao što su prašina, prljavština, čađa ili dim, dovoljno su velike ili tamne da ih se može vidjeti golim okom, dok su druge vidljive samo pomoću elektronskog mikroskopa. Onečišćenje krutim česticama uključuje PM₁₀ čestice promjera između 2,5 µm i 10 µm, PM_{2,5} fine čestice promjera do 2,5 µm te podskupine ultrafinih čestica (engl. *ultrafine particles, UFP*) promjera manjeg od 0,1 µm [47].

Istraživanje Američkog udruženja srca (engl. *American Heart Association, AHA*), pod nazivom „Onečišćenje zraka i kardiovaskularna oboljenja” (engl. *Air Pollution and Cardiovascular Disease*), zaključuje da izlaganje zraku onečišćenom krutim česticama doprinosi kardiovaskularnim oboljenjima i smrtnosti. Novo AHA istraživanje [48] zaključuje da izlaganje PM_{2.5} tijekom nekoliko sati do nekoliko tjedana može izazvati smrtnost i nefatalne događaje povezane s kardiovaskularnim bolestima; dugotrajnija izloženost (npr. nekoliko godina) povećava rizik od kardiovaskularne smrtnosti u još većoj mjeri od izloženosti tijekom nekoliko dana, te smanjuje očekivano trajanje života unutar više izloženih segmenata stanovništva za nekoliko mjeseci do nekoliko godina; smanjena razina PM povezana je sa smanjenjem smrtnosti od kardiovaskularnih bolesti u vremenskom okviru kraćem od nekoliko godina; razjašnjeni su mnogi vjerodostojni patološki mehanizmi koji potvrđuju biološku vjerodostojnost tih nalaza.

Modelom testa poplitealnih limfnih čvorova (engl. *popliteal lymph node assay, PLNA*) i metodom enzimski vezanog imunosorbentnog testa (engl. *enzyme-linked immunosorbent assay, ELISA*) za određivanje specifičnih imonoglobulin E (IgE) protutijela utvrđeno je da krute čestice (PM), bez obzira na veličinu i geografsko podrijetlo, dovode do povećanog stvaranja specifičnih IgE-protutijela, odnosno alergijskih reakcija te da manje čestice pri tome imaju veći učinak nego krupnije čestice [49].

Neizgoreni ugljikovodici (engl. *black carbon, BC*) proizvod su nepotpunog izgaranja organskih goriva. Kao takav, BC nije isto što i elementarni ugljik (engl. *elementary carbon, EC*), koji se obično prati toplinsko-optičkim metodama. Postojeće metode mjerjenja BC-a i EC-a moraju biti standardizirane kako bi se olakšala usporedba rezultata različitih studija. Iako nema dovoljno kliničkih ili toksikoloških studija koje bi omogućile procjenu kvalitativnih razlika između zdravstvenih učinaka izloženosti BC-u ili PM-u [50], relevantni se izvori slažu da su posredni i neposredni učinci značajni [51]. BC-i (osobito aromatski ugljikovodici) snažan su čimbenik klimatskih promjena jer sudjeluju u tvorbi fotokemijskog smoga [52].

Smatra se da međunarodno pomorsko brodarstvo sudjeluje s oko 1 do 2% u ukupnom onečišćenju česticama BC-a [53]. Kod motora s unutarnjim izgaranjem pri punom opterećenju, količina ispuštenog BC-a razmjerna je utrošku goriva [54]. Brodovi emitiraju više čestica PM-a i BC-a po jedinici potrošenog goriva u odnosu na druge izvore izgaranja fosilnih goriva zbog lošije kvalitete upotrebljavanog goriva [50].

Povećanjem intenziteta pomorskog prometa u arktičkom području očekuje se daljnje topljenje ledene mase, a promjene će se odraziti i na obrazac dalekosežnog transporta onečišćivača

atmosfere. Nedavni radovi pokazuju da ispuštanje BC-a i izvan Arktika može doprinijeti zagrijavanju Arktika [55].

Osim toga, depozicija neizgorenih crnih ugljičnih čestica iz ispušnih plinova brodskih energetskih sustava na svjetlom ledenom pokrivaču može dodatno pojačati učinak globalnog zagrijavanja i promjene klime. Kao posljedica nepotpunog izgaranja goriva i ulja za podmazivanje iz brodskih energetskih sustava dolazi i do emisija neizgorenih ugljikovodika, ali i različitih drugih konfiguracija organskih spojeva i krutih čestica [56, 57].

2.1.2. Dušikovi oksidi

Dušikovi oksidi (NO_x), kao što su dušikov monoksid (NO) i dušikov dioksid (NO_2), važni su plinovi prisutni u tragovima u atmosferi koji imaju značajnu ulogu prilikom stvaranja ozona kao i u drugim oksidativnim procesima u atmosferi [58]. Proizvodi su reakcije plinova dušika i kisika tijekom procesa izgaranja, posebno pri visokim temperaturama. NO_x plinovi formiraju se svaki put kada dođe do izgaranja u prisutnosti dušika, npr. u motorima s unutarnjim izgaranjem, ali mogu se također prirodno proizvesti, npr. djelovanjem munja, a mogu nastati i kao produkt procesa u mikroorganizmima [59]. U područjima u kojima je prisutan znatan promet motornih vozila, poput velikih gradova, dušikovi oksidi emitirani u atmosferu mogu biti vrlo značajan izvor onečišćenja zraka. Procjenjuje se da se godišnje u svijetu proizvede NO_x u rasponu 23 – 81 TgN⁷, od čega se približno pola stvara zbog izgaranja fosilnih goriva [60], a od čega su brodovi odgovorni za količine koje se nalaze u rasponu od 3,6 do 6,9 TgN/godišnje [45, 61] [61].

Što se tiče izravnih utjecaja NO_x na ljudsko zdravlje, ti spojevi uglavnom utječu na respiratorični sustav te mogu uzrokovati upalu dišnih putova, naročito kad su prisutni u visokim razinama [59]. Dugotrajna izloženost NO_x može smanjiti funkciju pluća, povećati rizik od respiratoričnih problema i povećati odgovor na alergene. NO_x također pridonose stvaranju PM-a i prizemnog ozona, pri čemu su oba navedena spoja povezana sa štetnim učincima na zdravlje.

U ekosustavu visoke razine NO_x mogu djelovati negativno na vegetaciju, uzrokujući oštećenje listova i smanjenje rasta biljaka, što rezultira povećanom osjetljivošću vegetacije na oštećenja, bolesti i smrzavanje. NO_x također reagiraju s drugim onečišćivačima te se u prisutnosti sunčeve

⁷ 1 teragram (Tg) of nitrogen (N) = 10^9 kilograms (kg) of nitrogen

svjetlosti stvara prizemni ozon koji, pri visokim koncentracijama, može izravno oštetiti vegetaciju [62].

Istraživanja su pokazala da je pomorski promet odgovoran za 18 – 30% stvorenih NO_x u svijetu [63]. Štoviše, iako su poduzete različite mjere kako bi se smanjila emisija NO_x s brodova, još uvijek smo daleko od trenutka kad će se emisija tih spojeva smanjiti na nulu ili na prihvatljivu razinu.

Kada je riječ o stvaranju NO_x tijekom rada brodskih motora, gorivo u tim motorima spaljuje se unutar komora za izgaranje tako da se miješa ispravna smjesa goriva i zraka u prisutnosti topline ili izvora zapaljenja. Budući da mješavina zraka sadrži 21% kisika i 78% dušika, dušik reagira s kisikom u određenim radnim uvjetima motora pri čemu se stvaraju dušikovi oksidi [64].

Na povećano stvaranje NO_x u brodskim motorima utječu različiti čimbenici, kao što su visoka temperatura i tlak tijekom procesa izgaranja, opterećenje motora, neodgovarajući omjer goriva i zraka, visoka temperatura ispirnog zraka i loša kvaliteta goriva.

2.1.3. Sumporni oksidi

Sumporni oksidi (SO_x) spojevi su sumpora i molekula kisika. Prevladavajući je oblik SO_x sumporni dioksid (SO₂) koji se ponajviše nalazi u nižoj atmosferi, odnosno troposferi [65]. Riječ je o bezbojnem plinu, prepoznatljivog okusa i mirisa, koji se može detektirati pri koncentracijama u rasponu od 1000 do 3000 µg/m³, a pri koncentracijama od 10 000 µg/m³ i više ima opor, neugodan miris. SO₂ se lako otapa u vodi pri čemu se stvara sumporasta kiselina (H₂SO₃). Oko 30% SO₂ u atmosferi pretvara se u kiseli sulfatni aerosol. Sumporni trioksid (SO₃), drugi oksid sumpora, otpušta se ili izravno u atmosferu ili nastaje iz sumpornog dioksida, a potom se, u reakciji s molekulama vode, brzo pretvara u sumpornu kiselinu (H₂SO₄). Glavni su izvori SO₂ izgaranje goriva koja sadrže sumpor ili prženje metalnih sulfidnih ruda, iako postoje i prirodni izvori koji čine 35 – 65% ukupnog emitiranog SO₂, kao što su vulkani. Termoelektrane koje rabe ugljen ili ulja s visokim udjelom sumpora glavni su izvori antropogenog stvorenog SO₂ diljem svijeta, a slijede ih industrijski kotlovi i nehrđajući metalni taljevci. Emisije iz izgaranja ugljena u domaćinstvima i iz vozila također mogu pridonijeti visokim lokalnim koncentracijama SO₂.

Periodično visoke koncentracije SO₂ smatraju se odgovornima za većinu zdravstvenih i ekoloških oštećenja povezanih uz emisiju sumporovih spojeva. Vjetar, temperatura, vlažnost i

topografija glavni su čimbenici koji utječu na koncentriranje SO₂ u nižim razine atmosfere, tj. blizu površine tla.

Izlaganje višim koncentracijama SO₂ u prostoru povezano je sa smanjenjem plućne funkcije, povećanom incidencijom simptoma respiratornih oboljenja, iritacijom očiju, nosa i grla, kao i s većom stopom mortaliteta [66]. Poseban rizik prisutan je ne samo u osoba koje već pate od oboljenja respiratornog sustava nego i kod djece i starijih osoba. Čini se da su navedeni učinci na zdravlje pojedinaca posebno povezani s kratkotrajnim, akutnim (do 10 minuta) izlaganjima koncentracijama SO₂ većim od 1000 µg/m³ [65].

U okolišu SO_x prvenstveno djeluju na vegetaciju, što uključuje šume i usjeve. Pod utjecajem povišenih koncentracija SO₂ biljke mogu izgubiti svoje lišće, postati manje produktivne ili prerano uvenuti [67]. Utjecaj na šumske ekosustave uvelike varira ovisno o vrsti tla, biljnim vrstama, atmosferskim uvjetima, populacijama insekata i drugim čimbenicima koji još nisu dovoljno razjašnjeni. Uzgoj poljoprivrednih kultura također može biti ugrožen zbog odlaganja spojeva koji sadrže sumpor. Čini se, ipak, da oštećenja listova moraju biti velika prije nego što izloženost počne utjecati na prinose većine usjeva. No moguće je da dugoročan unos sumpora u tlo značajno utječe na prinose [68].

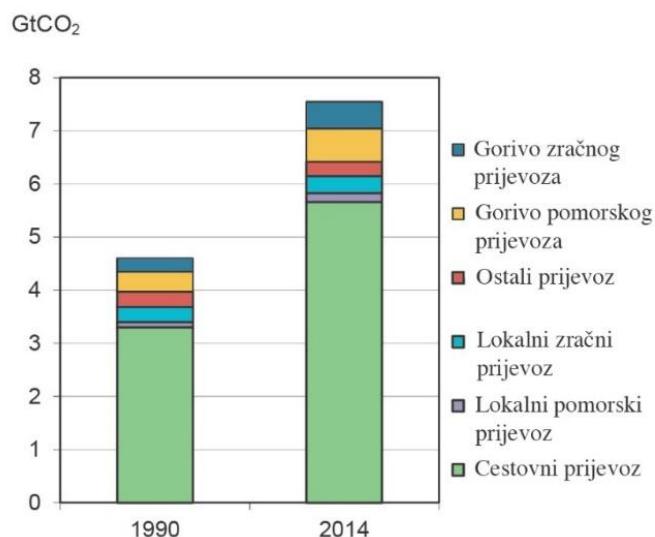
Taloženje kiselina nastalih otapanjem SO_x u vodi može oštetiti ekosustave slatkovodnih jezera i potoka snižavanjem pH vode [69]. Jezera s niskim kapacitetom puferiranja, tj. neutralizacije učinaka kiselih kiša, posebno su izložena tom riziku. Malo ribljih vrsta može preživjeti velike promjene u pH, a zahvaćena jezera mogu ostati u potpunosti bez ribljeg života. Zakiseljavanje također smanjuje raznolikost vrsta, kao i obilje ostalog životinjskog i biljnog svijeta.

2.1.4. Ugljikov dioksid

Ugljikov dioksid (CO₂) bezbojni je plin bez mirisa koji biljke iskorištavaju u procesu fotosinteze, a čiji je rezultat nastanak kisika, plina bez kojeg je život na Zemlji nemoguć. Sukladno tome, može se reći da je CO₂ gotovo jednako važan za opstanak ljudskog života kao i O₂. U prirodi, CO₂ cirkulira između atmosfere, oceana, te biotičkih čimbenika iz zemlje i voda, kao i mineralnih rezervoara [70]. Pritom se dominatno izmjena CO₂ odvija između atmosfere i zemaljskih biotičkih čimbenika, odnosno atmosfere i površine oceana. U koncentracijama u kojima je trenutno prisutan u atmosferi (0,041% ili 410 milijuntih volumnih dijelova (engl. *parts per million by volume*, ppmv)), CO₂ ne djeluje štetno na zdravlje [71]. No koncentracije se CO₂ konstantno povećavaju, razmjerno s povećanjem ljudske populacije i razvojem industrije. Procjenjuje se da se koncentracija CO₂ u atmosferi povećala od oko 280

dijelova po milijunu obujma u predindustrijskom dobu do gore navedenih trenutnih razina, a što čini 46%-tno povećanje koncentracije tog stakleničkog plina. Sukladno podacima koje je objavila Međunarodna agencija za energetiku (engl. *International Energy Agency, IEA*), tijekom 2016. godine zanstvenici su uočili da se koncentracija ugljikovog dioksida (CO_2) u atmosferi značajno povećala u zadnjem stoljeću. Prema izvješću Međuvladinog panela o klimatskim promjenama (engl. *Intergovernmental Panel on Climate Change, IPCC*), glavni su izvor stvaranja CO_2 postrojenja za proizvodnju energije (oko 35%), potom slijede emisije iz transporta (oko 24%) te ostali različiti sektori (industrija, stambeni i komercijalni izvori, itd.) [72].

Ukupna emisija CO_2 kao posljedica ljudske aktivnosti u 2014. godini iznosila je 32,4 Gt, 0,8% više od ukupne emisije tijekom 2013. godine. Transport roba i putnika tu zauzima 7,452 Gt ili 23%. Na složenom stupčastom grafikonu (Slika 2.) prikazano je da pri onečišćenju atmosfere CO_2 transportnim aktivnostima najveći postotak generira cestovni promet sa 71% udjela (od 1990. godine) [3].



Slika 2. Onečišćenje atmosfere ispuštanjem CO_2 prijevoznim aktivnostima

Izvor: International Energy Agency: *CO₂ emissions from fuel combustion highlights, 2016.* [3]

Rast onečišćenja CO_2 transportnim aktivnostima između 1990. i 2015. godine dosegnuo je 1% na godišnjoj razini [73].

Pomorski promet tu zauzima manji dio, no unatoč naporima prema smanjenju, pomorski promet (rast 1990. – 2014. od 69%), uz zračni promet (rast 1990. – 2014. od 95%), najbrže je rastući izvor onečišćenja CO_2 , brži i od cestovnog prometa [3].

IMO je dosad u tri navrata, 2000., 2009. te 2014. godine, izradila studije razine ispuštanja GHG-a od strane brodova, a posljednji nalazi upućuju na to da pomorski promet proizvodi oko milijardu metričkih tona CO₂ godišnje, od čega je međunarodni pomorski promet odgovoran za 900 milijuna metričkih tona. U međuvremenu, IMO-ov Odbor za zaštitu morskog okoliša (engl. *Marine Environment Protection Committee, MEPC*)⁸ na svom redovnom zasjedanju MEPC73 pokreće rad na četvrtoj GHG studiji potaknut inicijativom Baltičkog i međunarodnog pomorskog vijeća (engl. *The Baltic and International Maritime Council, BIMCO*)⁹ prema stvarnim projekcijama ispuštanja GHG s brodova. Oni, naime, smatraju da su trenutne procjene 50 – 250% povećanog ispuštanja GHG do 2050. godine pretjerane i ne uzimaju u obzir stvarnu projekciju porasta svjetske ekonomije i bruto domaćeg proizvoda (BDP) kao osnove za procjenu buduće potrebe za pomorskim prijevozom [74].

Trajno povećanje koncentracija atmosferskog CO₂ ima dugotrajne učinke na ljudsko zdravlje. Ljudski organizam reagira tako da nadomješće visoke razine CO₂ kombinacijom povećanog disanja, puferiranjem pH krvi, adaptacijom funkcije bubrega i kostiju, a ovisno o duljini kontinuiranog izlaganja, sve do trenutka kada više nije moguće nastaviti disanje, tj. do trenutka kad je razina CO₂ prevelika [75]. Također, povećane razine CO₂ imaju značajan izravan negativan utjecaj na kognitivne funkcije, što je dokazano u studiji u kojoj su subjekti istraživanja bili ispitanici koji su boravili u zatvorenim prostorima [76].

Osim navedenih izravnih učinaka, puno su važniji neizravni učinci povećanja razina CO₂ na ljudsko zdravlje, a koji su posredovani učinkom staklenika tog plina. Naime, upravo se CO₂ smatra odgovornim za povećanje temperatura na Zemlji koje se bilježi posljednjih nekoliko stoljeća. Mogući je razlog tome zadržavanje CO₂ u atmosferi znatno duže od ostalih plinova koji imaju sposobnost zadržavanja topline. Procjenjuje se da se oko 40% otpuštenog CO₂ u atmosferi zadržava 100 i više godina, 20% i do 1000 godina, a čak je 10 000 godina potrebno da se 10% od početne količine CO₂ razgradi. Za usporedbu, metan (CH₄) se u potpunosti razgradi u roku od 10 godina, a za isto je N₂O potrebno 100 godina [77].

U 20.-om stoljeću, svijest o očuvanju okoliša povećana je, kako kod pojedinca, tako i u profesionalnim aktivnostima te industrijskoj proizvodnji. Što se tiče pokušaja smanjivanja

⁸MEPC je više tehničko tijelo IMO-a koje se bavi pomorskim onečišćenjem i povezanim pitanjima. Neki od pododbora IMO-a pomažu MEPC-u, posebice Podobor za prevenciju onečišćenja i odziv (engl. *Pollution Prevention and Response Sub-Committee, PPR*).

⁹BIMCO je najveća međunarodna neprofitna pomorska udruga, s oko 2000 članova u više od 120 zemalja, što predstavlja 56% svjetske tonaže. Članstvo uključuje brodovlasnike, operatere, menadžere, posrednike i agente.

emisije CO₂ proizведенog transportom, najučinkovitiji je način redukcija potrošnje fosilnih goriva. Učinkovit način smanjenja onečišćenja okoliša jest poboljšanje energetske učinkovitosti u svakom aspektu života: potrošnji energije kućanstva, potrošnji energije u industriji i potrošnji energije u transportu tereta i putnika. S obzirom na to da energija najčešće potječe od izgaranja izvora koji sadrže ugljik (gorivo, ugljen, plinovi), a izgaranje ugljika uvjetuje onečišćenje zraka ugljikovim oksidima, počeo se rabiti izraz „otisak ugljika“ (engl. *carbon footprint*) [78]. Uzimajući u obzir prethodne podatke o onečišćenju zraka uslijed emisije CO₂ te pomorski promet kao jedan od najbrže rastućih u pogledu onečišćenja atmosfere, međunarodne pomorske organizacije izrazile su zabrinutost, što je rezultiralo određenim međunarodnim propisima o sprječavanju onečišćenja zraka s pomorskih brodova. Međunarodna pomorska organizacija preuzela je vodeću ulogu provodeći brzu akciju za smanjenje emisije. S obzirom na to da je jedan od glavnih načina smanjenja emisija stakleničkih plinova smanjenje potrošnje ugljika iz goriva, odnosno smanjenje potrošnje goriva (koje se troši za propulziju i proizvodnju električne energije), posljedično učinkovitija upotreba energije smanjuje štetnu emisiju CO₂.

IMO, 2016. godine usvaja obvezujuće zahtjeve prema brodovima od 5000 bruto registarskih tona ili većima, a koji se odnose na prikupljanje podataka s brodova za svaku vrstu goriva koju upotrebljavaju te dalnjih podataka vezanih za prijevoz tereta. Tako prikupljeni podaci opisuju uzroke za oko 85% svih ispuštanja CO₂ s pomorskih brodova i rabit će se za odluke o budućim ograničenjima.

2.2. Usvojena međunarodna pravna regulativa prema povećanju energetske učinkovitosti pomorskih brodova i smanjenju ispuštanja ugljikova dioksida

IMO je objavio Rezoluciju MEPC 203(62), usvojenu 15. srpnja 2011., „Izmjena dodatka Protokola iz 1997. za izmjenu Međunarodne konvencije za sprečavanje onečišćenja s brodova iz 1973. godine, izmijenjenog Protokolom iz 1978. godine na koji se odnosi“ (engl. *Amended to the Annex of the Protocol of 1997 to amend the International convention for the prevention of pollution from ships, 1973, as modified by the protocol of 1978 relating thereto*), te je ta rezolucija konačno pridodana Poglavlju 4, Priloga VI, Međunarodne konvencije o sprječavanju onečišćenja s brodova, 1973., izmijenjene Protokolom iz 1978. (MARPOL 73/78) (engl. *The International Convention for the Prevention of Pollution from Ships, 1973 as modified by the*

*Protocol of 1978) nazvanog „Pravilnik o energetskoj učinkovitosti brodova“ (engl. *Regulations on Energy Efficiency for Ships*).*

Rezolucija MEPC-a 203(62) donijela je nekoliko zahtjeva prema novim i postojećim brodovima:

- međunarodnu svjedodžbu energetske učinkovitosti (engl. *International Energy Efficiency Certificate*)
- brodski plan upravljanja energetskom učinkovitosti, SEEMP
- projektni indeks energetske učinkovitosti, EEDI

Zahtjevi koji se odnose na postojeće brodove u određenoj su mjeri blaži te za njih implementacija EEDI nije obvezna. Rezolucija utvrđuje vremenski okvir za prilagodbu postojećih plovila ili njihove opreme.

Svaki brod mora imati svoj SEEMP, koji može biti dio brodskog sustava upravljanja sigurnošću (engl. *Safety Management System, SMS*). SEEMP mora biti u skladu s preporukama IMO-a [80], koje, nakon što su unesene u Prilog VI¹⁰, MARPOL 73/78, postaju prvi obvezujući akt nakon Protokola iz Kyota¹¹, a IMO prva organizacija koja je usvojila mjere za učinkovitije upravljanje energijom koje su obvezujuće za pomorsku industriju i primjenjive na sve obalne države. Postojeći brodovi moraju osigurati u svome SEEMP planu poboljšani plan putovanja, adekvatno čišćenje podvodnih dijelova brodskog trupa i čišćenje i poliranje vijka, te usvojiti tehničke mjere, poput uređaja za iskorištavanje otpadne topline (kotlovi na ispušne plinove, generatori slatke vode, i sl.) ili se odlučiti na ugradnju energetski učinkovitijeg brodskog vijka [79].

Od 1. siječnja 2019. SEEMP je podijeljen u dva dijela. Dio I pruža održiv pristup praćenju učinkovitosti broda i flote tijekom vremena te opcije koje je potrebno uzeti u obzir pri optimizaciji učinkovitosti broda, dok Dio II sadrži metodologije koje upotrebljavaju brodovi od 5000 i više bruto tona pri prikupljanju podataka potrebnih sukladno članku 22A, Poglavlje 4, Priloga VI, MARPOL-a 73/78.

¹⁰Izmjene MARPOL 73/78 Konvencije, Prilog VI vezane uz Energetsku učinkovitost stupile su na snagu 1.1.2013. Propisi o EEDI obvezujući su za nove brodove (brodovi za koje je ugovor o gradnji potpisani ili kobilica položena na datum ili nakon datuma izmjena Konvencije, ili isporuka izvršena 1.7.2015. ili nakon tog datuma), a oni vezani uz SEEMP za sve brodove [80].

¹¹Protokol iz Kyota stupio je na snagu 16.2.2015., a potписан je s ciljem smanjenja ispuštanja ugljikovog dioksida i ostalih stakleničkih plinova u atmosferu.

Brodovi su obvezni prikupljati podatke o utrošku goriva kako je navedeno u Dodatku IX, Priloga VI, MARPOL-a 73/78, te za 2019. godinu i svaku sljedeću kalendarsku godinu ili njezin dio u skladu s propisanim uvjetima. Na kraju svake kalendarske godine, brodar objedinjuje podatke prikupljene u toj kalendarskoj godini ili jednom njezinom dijelu, te u roku od tri mjeseca nakon isteka svake kalendarske godine izvješćuje Administraciju, odnosno opunomoćenu organizaciju (klasifikacijski zavod), o zbirnoj vrijednosti za protekli period, sukladno dodatku IX, Priloga VI, MARPOL-a 73/78, putem elektroničke komunikacije i upotrebom standardiziranog formata, opisanim u Rezoluciji IMO-a MEPC.282(70) 2016. Smjernice za izradu brodskog plana upravljanja energetskom učinkovitosti (SEEMP) nalaze se u preliminarnoj okružnici MEPC.70/18/Add.1/Corr.1. (engl. *IMO Resolution MEPC.282(70) 2016 Guidelines for The Development of a Ship Energy Efficiency Management Plan (SEEMP) as amended by MEPC.70/18/Add.1/Corr.1*) [81].

Uredbom o praćenju, izvješćivanju i provjeri (engl. *Monitoring, Reporting and Verification regulation, MRV*) Europska unija (EU) od brodara zahtjeva godišnje praćenje, izvješćivanje i provjeru emisija CO₂ za brodove veće od 5000 bruto tona (GT) koji posjećuju bilo koju EU ili luku EFTA-e (Norveška i Island) prema odobrenom Planu praćenja, izvješćivanja i provjere emisija CO₂ (engl. *Monitoring, Reporting and Verification of CO₂ Emissions Plan*) [82-85]. Prikupljanje podataka odvija se za svako putovanje i započinje s 1. siječnja 2018. godine. Prijavljene emisije CO₂, zajedno s dodatnim podacima, potvrđuju neovisna opunomoćena tijela, kao što su klasifikacijski zavodi, a šalju se u središnju bazu podataka kojom upravlja Europska agencija za pomorsku sigurnost (engl. *European Maritime Safety Agency, EMSA*), koja ih i objavljuje svake godine.

2.3. Brodski plan upravljanja energetskom učinkovitosti i projektni indeks energetske učinkovitosti

Brodski plan upravljanja energetskom učinkovitosti sadrži skup mjera čiji je cilj uspostava ekonomski prihvatljivih mehanizama za unaprjeđenje energetske učinkovitosti broda. Plan također omogućuje brodskim tvrtkama upravljanje energetskom učinkovitošću broda i flote, primjerice preko Operacijskog pokazatelja energetske učinkovitosti (engl. *Energy Efficiency Operational Indicator, EEOI*), koji nije obvezatan.

Projektni indeks energetske učinkovitosti, EEDI, značajna je tehnička mjera, čiji je cilj promocija energetski učinkovitijih, a time i ekološki prihvatljivijih brodova. EEDI za različite

vrste brodova zahtjeva najmanju moguću potrošnju energije po kapacitivnoj nautičkoj milji (engl. *tonne mile*). Nakon dvije godine usuglašavanja oko nultih vrijednosti, od 1. siječnja 2013. godine svi novi brodovi trebaju imati energetsku učinkovitost u skladu s referentnim EEDI za svoj tip broda. Vrijednost EEDI postrožavat će se svakih pet godina stimulirajući inovacije i razvoj rješenja prema odgovornijem korištenju energetskih izvora. U 2025. godini novi brodovi, u usporedbi s onima izgrađenim 2014., bit će 30% energetski učinkovitiji [79]. U cilju standardizacije izračuna EEDI, MEPC objavljuje uputstvo za izračun i odobrenje u svojoj preliminarnoj okružnici MEPC.1/Circ.682, potom u MEPC.212(63), MEPC.224(64) te naposljetku MEPC.245(66).

Projektni indeks energetske učinkovitosti definira se kao omjer između utjecaja broda na okoliš i koristi koju šira zajednica ima od prijevoza [86]:

$$EEDI = \frac{\text{količina ispuštenog } CO_2 \text{ u atmosferu}}{\text{transportni rad}}. \quad (1)$$

Količina CO₂ ispuštenog u atmosferu izračunava se iz utroška goriva uzimajući u obzir količinu ugljika u upotrijebljenom gorivu. Potrošnja goriva zasnovana je na snazi potrebnoj za propulziju i pomoćne uređaje, a mjerena preko unaprijed zadanih uvjeta. Transportni se rad procjenjuje preko kapaciteta broda pomnoženim s brzinom pri najvećoj ljetnoj uronjenosti broda i 75% instalirane snage.

Naposljetku se EEDI prema MEPC.245(66) izračunava kako slijedi [87]:

$$EEDI = \frac{\text{upotrijebljena snaga} \times \text{specifični utrošak goriva} \times CO_2 \text{ koeficijent}}{\text{kapacitet} \times \text{brzina broda}}, \quad (2)$$

iz čega se daljnjom raščlanom dobiva konačni izraz:

$$EEDI = \frac{(\prod_{j=1}^n f_j) (\sum_{i=1}^{nME} P_{ME(i)} \times C_{FME(i)} \times SFC_{ME(i)})}{f_i \times f_c \times f_l \times \text{capacity} \times f_w \times V_{ref}} + \\ \frac{(P_{AE} \times C_{FAE} \times SFC_{AE})}{f_i \times f_c \times f_l \times \text{capacity} \times f_w \times V_{ref}} + \quad (3)$$

$$\frac{\left[\left(\prod_{j=1}^n f_j \times \sum_{i=1}^{nPTI} P_{PTIi} - \sum_{i=1}^{neff} f_{eff(i)} \times P_{AEeff(i)} \right) C_{FAE} \times SFC_{AE} \right]}{f_i \times f_c \times f_l \times capacity \times f_w \times V_{ref}} -$$

$$\frac{\left(\sum_{i=1}^{neff} f_{eff(i)} \times P_{eff(i)} \times C_{FME} \times SFC_{ME} \right)}{f_i \times f_c \times f_l \times capacity \times f_w \times V_{ref}}$$

Prethodni izraz (3) podijeljen je na četiri međusobno zbrojena ili oduzeta reda kako slijedi:

1. Količina ispuštenog CO₂ uslijed propulzije broda, P_{ME} + P_{PPI}
2. Količina ispuštenog CO₂ uslijed rada pomoćnih strojeva¹², P_{AE}
3. Smanjenje ispuštanja CO₂ primjenom različitih tehnoloških postupaka ka smanjenju potrošnje električne energije za rad pomoćnih strojeva u vrijeme plovidbe broda P_{AEEff} (primjerice, iskorištavanje otpadne topline)
4. Smanjenje ispuštanja CO₂ primjenom različitih tehnoloških postupaka za smanjenje potrošnje električne energije potrebne za propulziju

Dio u nazivniku sastoji se od kapaciteta broda i referentne brzine, koji zajedno predstavljaju transportni rad broda.

Sljedeći su simboli rabljeni pri izračunu:

- C_f – bezdimenzionalni koeficijent za pretvorbu potrošnje goriva u gramima u količinu ispuštenog CO₂, također u gramima, ovisan o vrsti goriva. Oznake ME(i) i AE(i) odnose se na glavni pogonski stroj, odnosno pomoćne motore (engl. *ME – Main Engine, AE – Auxiliary Engines*). Vrijednost koeficijenta C_f određuje se prema Tablici 1.:

Tablica 1. Vrijednost koeficijenta C_f za različita goriva u brodskoj upotrebi [87]

VRSTA GORIVA	REFERENCA	UDIO UGLJIKA	C _f (T- CO ₂ / T- GORIVO)
DIESEL/ PLINSKO GORIVO	ISO 8217 DMX-DMB	0,8744	3,206
LAKO GORIVO	ISO 8217 RMA-RMD	0,8594	3,151
TEŠKO GORIVO	ISO 8217 RME-RMK	0,8493	3,114
UKAPLJENI NAFTNI PLIN	PROPAN	0,8182	3,000
	BUTAN	0,8264	3,030
UKAPLJENI PRIRODNI PLIN		0,7500	2,750
METANOL		0,3750	1,375
ETANOL		0,5217	1,913

¹²Pod pomoćnim strojevima podrazumijevaju se pogonski motori generatora za proizvodnju električne energije.

- SFC (engl. *Specific Fuel Consumption*) omjer je masenog protoka goriva i raspoložive snage, mjerena u g/kWh; nalazi se u NO_x Tehničkoj knjizi¹³ (engl. *NO_x Technical file*), kako je određeno člankom 1.3.15 NO_x Tehničkog koda¹⁴ (engl. *NO_x Technical Code 2008*). SFC je potrebno prilagoditi na vrijednosti koje odgovaraju standardima ISO 15550:2016¹⁵ i ISO 3046- 1:2002¹⁶ pri upotrebi goriva s donjom ogrjevnom vrijednošću od 42 700kJ/kg. Za glavni pogonski motor usklađen s E2 ili E3 NO_x Tehničkim kodom specifična se potrošnja SFC_{ME(i)} uzima pri 75% maksimalne trajne snage (engl. *maximum continuous rating, MCR*), dok se kod pomoćnih strojeva usklađenim prema D2 ili C1 istog koda potrošnja SFC_{AE(i)} uzima pri 50% MCR [87] [88].
- V_{ref} – brzina broda mjerena u nautičkim miljama na sat (čvor)
- Kapacitet – za brodove za prijevoz rasutog tereta, ukapljenoga plina, RO-RO, generalnog tereta, rashlađenog tereta i one koji prevoze teret u kombinaciji navedenih prijevoza kao kapacitet se uzima nosivost¹⁷ (engl. *Deadweight, DWT*). Za ostale vrste brodova kapacitet se izračunava prema članku 3. MEPC 66/21, Annex 5, page 6 [87].
- P – snaga glavnog pogonskog stroja (engl. *main engine, ME*), odnosno pomoćnih motora (engl. *auxiliary engine, AEs*) te osovinskog generatora (engl. *PTI – power take-in*), a mjeri se u kW.
- i-ti element u zbroju odnosi se na svaki pojedinačni ugrađeni strojni uređaj (ako ih je više) s ukupnim konačnim brojem n.

Za izračun se upotrebljava 75% nazivne snage glavnoga stroja ili 75% MCR (engl. *maximum continuous rating*).

¹³NO_x Tehnička knjiga definirana je člankom 2.3.4. Tehničkog koda te je obvezna za sve brodove na koje je kod primjenjiv.

¹⁴NO_x Tehnički kod definiran je Rezolucijom MEPC.177(58) izmijenjenom i nadopunjrenom s MEPC.251.(66).

¹⁵ISO 15550:2016 standard određuje temeljna stanja i metode izračuna snage, potrošnje goriva i potrošnje ulja za podmazivanje te metode testiranja komercijalnih motora s unutarnjim izgaranjem tekućih i plinovitih goriva.

¹⁶ISO 3046-1:2002 dodatak je na ISO 15550:2016 i definira specifične zahtjeve i uvjete.

¹⁷Nosivost broda – DWT zbroj je plaćenog tereta (engl. *payload*) i mase goriva, vode, maziva, namirnice, rezervnih dijelova i posade. DWT jednaka je Δ istisnini broda do ljetne teretne vodne linije (gornji rub središnje crte marke nadvođa) umanjenoj za vlastitu težinu broda (engl. *lightweight ship – LS*), odnosno $DWT = \Delta - LS$ [165].

Kod brodova koji snagu glavnog propulzijskog stroja upotrebljavaju isključivo za pogon vijka snaga se izračunava prema sljedećem izrazu [86]:

$$P_{ME(i)} = 0,75 \times MCR_{ME(i)}, \quad (4)$$

gdje je:

- $P_{\text{eff}(i)}$ – izlazna snaga dobivena primjenom inovativnih rješenja pri snazi od 75% MCR-a
- $P_{AE\text{eff}(i)}$ – smanjena snaga pomoćnih strojeva upotrebom inovativnih energetskih rješenja mjerenih pri $P_{ME(i)}$
- PAE – potrebna snaga pomoćnih strojeva kod normalnog opterećenja broda pri plovidbi, uključujući energiju potrebnu za propulziju (pumpe glavnog propulzijskog stroja), navigacijske sustave te uređaje potrebne boravku posade (klimatizacija, priprema i čuvanje prehrambenih namirnica, itd.)

Za brodove čija ukupna propulzijska snaga prelazi 10 000 kW potrebna snaga pogonskih strojeva izračunava se po [87]:

$$P_{AE(\sum MCR_{ME(i)} \geq 10,000 \text{ kW})} = \left[0,025 \times \left(\sum_{i=1}^{nME} MCR_{ME(i)} + \frac{\sum_{i=1}^{nPTI} P_{PTI(i)}}{0,75} \right) \right] + 250, \quad (5)$$

gdje su:

- f_j – koeficijent koji uzima u obzir specifičnosti kao što su klasa broda za plovidbu u zaledenim morima i zalihost propulzije
- $f_{\text{eff}(i)}$ – koeficijent raspoloživosti svake pojedinačne inovativne tehnologije usmjerene energetskoj učinkovitosti; $f_{\text{eff}(i)}$ za sustav iskorištavanja otpadne topline trebao bi biti 1,0
- f_i – korekcijski koeficijent za svako ograničenje nosivosti broda; ako nema ograničenja, koeficijent se uzima kao 1,0

- f_c – koeficijent korekcije kapaciteta broda za pojedine vrste brodova koji imaju nepovoljan DWT/GT, omjer između ukupne nosivosti (DWT) i ukupne zapremine broda¹⁸ (engl. *Gross tonnage, GT*)
- f_l – koeficijent predviđen za brodove opremljene dizalicama i ostalim teretnim uređajima kako bi se nadomjestio gubitak ukupne nosivosti
- f_w – bezdimenzionalni koeficijent smanjenja brzine broda pri zadanim uvjetima plovidbe (visina vala, frekvencija vala, brzina vjetra) u nepovoljnim vremenskim uvjetima

Značajan je broj čimbenika koji utječu na energetsku učinkovitost, a mogu se prema Ozturku podijeliti u dvije osnovne skupine: one koji utječu na učinkovitost trupa te one koji su vezani za snagu i propulziju [89].

Energetska se učinkovitost može podijeliti prema IMO na sljedeće: tehničke preduvjete koji su ocijenjeni preko EEDI te operacijske postupke kojima se temeljni uvjeti mogu unaprijediti, kao i postići dodatne uštede mjerljem i praćenjem potrošnje goriva preko SEEMP plana.

2.4. Tehnološka rješenja i postupci unaprjeđenja energetske učinkovitosti i smanjenja emisije ugljikova dioksida s postojećih brodova

Trenutno je u pomorskoj industriji i relevantnim publikacijama ponuđeno preko 50 postupaka za smanjenje emisije CO₂ [90]. IMO preko svoga višeg tehničkog tijela MEPC izdaje priručnik u cilju razvoja najprikladnijih, učinkovitih i izvedivih planova. U priručniku se opisuje zatećeno stanje te predstavljaju mogućnosti uštede energije na postojećim brodovima.

IMO naglašava da je postavljanje ciljeva uštede energije dobrovoljno te da ni poduzeće niti brod nisu podložni vanjskom nadzoru ciljeva. Postavljanje ostvarivih ciljeva stvara poticaj i povećava predanost sudionika u procesu ka poboljšanju energetske učinkovitosti. Bez obzira na cilj, on mora biti mjerljiv i lako razumljiv [81].

U nastavku su opisane metode uštede energije najčešće korištene na postojećim brodovima.

¹⁸Ukupna je zapremina broda volumen svih zatvorenih prostora broda prema odredbama IMO konvencije o baždarenju brodova (1969).

2.4.1. Optimizacija putovanja

Optimizacija i planiranje putovanja ubuhvaća plovidbu prema preporuci vremenskih prognostičara (engl. *weather routing*)¹⁹, određivanje virtualnog vremena dolaska, plovidbu smanjenom brzinom (engl. *slow steaming, super slow steaming*), planiranje grijanja ili hlađenja tereta u ovisnosti o vanjskoj temperaturi tijekom trajanja putovanja, itd. Plovidba prema preporuci vremenskih prognostičara ima veliki potencijal unaprjeđenja učinkovitosti plovidbe na određenim rutama, ali vrijeme preusmjeravanja također može povećati potrošnju goriva na određenom putovanju [81].

Virtualni dolazak proces je koji uključuje sporazum o smanjenju brzine plovidbe na putovanju kako bi se zadovoljilo revidirano vrijeme dolaska, kada postoji poznato kašnjenje u iskrcajnoj luci. Smanjenje brzine rezultirat će smanjenom potrošnjom goriva, čime se smanjuje emisija stakleničkih plinova (GHG) i drugih ispušnih plinova [91].

Smanjena brzina donosi uštedu u potrošnji goriva te je mnoge pomorske tvrtke, posebice kada je brod u balastu, odabiru kao sastavni dio operacije. Kako dugoročna upotreba motora s unutarnjim izgaranjem pri niskim opterećenjima stvara i povećanu potrebu za održavanjem, preporučuje se pridržavati uputstava proizvođača. Omjer između brzine i utroška snage eksponencijalno raste s porastom brzine te kod manjih brzina, karakterističnih za tankere i brodove za prijevoz rasutog tereta, snaga se povećava s trećom potencijom brzine ili

$$P_B = c \cdot n^3$$
 gdje je P_B snaga na osovini, c konstanta koja predstavlja ukupni otpor, a n brzina motora [92]. Pri tome treba uzeti u obzir da se krivulja SFC ne mijenja sa snagom, te pri smanjenju snage može biti veća specifična potrošnja. Kada se brod nalazi u izrazito teškim vremenskim uvjetima plovidbe, preostaju dvije mjere koje je moguće poduzeti kako bi se smanjio utjecaj valjanja broda i smanjila mogućnost oštećenja brodske konstrukcije. To su promjena smjera plovidbe, odnosno kursa, te smanjenje brzine plovidbe [15].

Razlozi zbog kojih se pribjegava smanjenju brzine broda jesu oni koji pripadaju skupini prirodnih (otpor vjetra, valova i morskih struja, akvatorija...), tehničkih (velike amplitude kretanja, ubrzavanje ili usporavanje broda, opterećenje na listu kormila, preopterećenje glavnog porivnog stroja, stanje trupa broda) te ekonomskih (ušteda goriva).

¹⁹Plovidba prema preporuci vremenskih prognostičara osigurava optimalnu rutu koja je zasnovana na vremenskim uvjetima, stanju mora te karakteristikama broda za koje se ruta izrađuje. Tradicionalno je planiranje putovanja po najkraćoj ruti, dok plovidba prema preporuci vremenskih prognostičara omogućuje uštedu vremena i utroška goriva [13].

Oni mogu ovisiti o vrsti tereta, prosječnoj uronjenosti i uzdužnom nagibu broda, snazi i tehničkom stanju konstrukcija, glavnom motoru, sustavu itd. [16]

Za izračun gubitka brzine broda neophodno je uzeti u obzir vjetar, utjecaj valova, iskoristivost glavnog propulzijskog stroja i vijka u uvjetima stvarnog stanja mora, kao i inerciju mase broda [17].

Autori Ochi i Motter promatraju dobrovoljno smanjenje brzine broda u lošim vremenskim uvjetima, bez uzimanja u obzir mogućnost promjene kursa. Njihov se model temelji na kritičnim vrijednostima gibanja i ubrzanja broda [14].

Soares razrađuje teorijski model dobrovoljnog smanjenja brzine dodavanjem kursa broda, koji potom dorađuje i kalibrira na temelju iskustava zapovjednika brodova i rezultata simulacije [15].

Natjecanje među brodograđevnim projektantskim uredima potaknulo je napore prema što točnjim ocjenama učinkovitosti plovidbe broda. Brodski časnici žele sigurnost, brzinu i učinkovitost u stvarnim uvjetima plovidbe, dok su brodari okrenuti najvećoj mogućoj dobiti u zadanim uvjetima. Vodeći se navedenim, točnost izračuna brzine broda u uvjetima lošeg vremena iznimno je značajna s ekonomskog gledišta i gledišta očuvanja okoliša. Pouzdan izračun gubitka brzine broda omogućuje predviđanje povećanja snage i potrošnje goriva, kao i onečišćenja okoliša emisijom ispušnih plinova s pomorskih brodova [17].

Poznato je da što je veća masa broda, veća je istisnina, te raste otpor, veća je snaga potrebna za propulziju, kao i potrošnja goriva, stoga je preporučljivo svesti dodatnu težinu goriva, vode i maziva na minimum. Pravilnim rasporedom tereta te ukrcajem i rasporedom balasta moguće je smanjiti ukupni otpor broda. Brodovi koji ne krcaju balast (engl. *ballast free ships*) pojavljivali su se kao ideja, no potrošnja se goriva uslijed povećane širine broda kod njih ne smanjuje.

Optimizacija uzdužnog nagiba broda ili trima²⁰ jedna je od najjednostavnijih metoda optimizacije utroška energije, odnosno smanjenja utroška goriva. Ona se izvodi balastiranjem broda ili pravilnim rasporedom tereta u brodskim skladištima kako bi se brod doveo do optimalnog trima, pri kojem je potrošnja goriva najmanja u trenutnim uvjetima gaza. Reichel opisuje sustav odlučivanja (engl. *decision support system, DSS*) koji na temelju gaza na pramcu i krmi te potrebne brzine preporučuje optimalni trim [12]. Brodar ili operater mogu izvršiti

²⁰Trim ili uzdužni nagib broda izračunava se kao razlika uronjenosti trupa na pramcu i na krmi.

testiranje broda te mjerenjem potrošnje pri različitim vrijednostima trima izabrati najekonomičniju opciju.

Bouman daje pregled više od 150 studija s ciljem sveobuhvatnog pregleda raspoloživih metoda smanjenja emisije stakleničkih plinova za pomorski promet. Rezultati ukazuju na to da pojedinačna mjera nije dovoljna za postizanje značajnijeg smanjenja emisije stakleničkih plinova iako pojedine mjere bilježe zamjetne rezultate (primjerice, upotreba biogoriva ili optimizacija brzine plovidbe). Zaključuje da se značajno smanjenje emisija može postići usvajanjem i kombinacijom većeg broja međusobno ovisnih i neovisnih mjer [10].

2.4.2. Upravljanje potrošnjom energije

Boljim upravljanjem energijom unaprjeđenjem operacijskih postupaka mogu se u skladu sa SEEMP planom postići značajne uštede energije. Smanjenjem snage glavnog i pomoćnih strojeva smanjuje se potrošnja goriva, a time i emisija CO₂ u atmosferu. Mogućnosti uštede ovise o projektu broda i ugrađenoj opremi. Primjer je uštede u upotrebi sustava kontrole broja okretaja pumpi, čime je opterećenje u skladu s trenutnom potrebom [93]. Kada je temperatura mora niža te kod manje potrebe za hlađenjem, pumpe mora automatski smanjuju broj okretaja te time štete energiju. Isto vrijedi i za sustave klimatizacije nadgrađa, gdje se može uštedjeti značajna količina energije nadzorom opterećenja sustava i odgovarajućim miješanjem s vanjskim zrakom.

2.4.3. Održavanje trupa, vijka i postrojenja

Primjerenum održavanjem postrojenja prema uputstvima proizvođača te redovitim pregledom i čišćenjem trupa i vijka postižu se značajne uštede energije. Brodovi kojima je trup potpuno obrastao i hrapav mogu trošiti i dvostruko više energije [90]. Moderni visoko- učinkoviti premazi trupa (engl. *low surface energy coatings, LSE*), poput floropolimera – FFR (engl. *flouropolymer foul release*) kod kojeg se organizmi odvajaju pod utjecajem hidrodinamičkih sila pri brzini većoj od 10 čvorova, mogu uštedjeti do 5% energije, odnosno u istome postotku smanjiti emisiju CO₂ [11].

2.4.4. Konstrukcijske preinake na postojećim brodovima

Optimizacijom oblika bulba te na krmi boljim usmjeravanjem mora prema vijku, većim promjerom vijka ili, primjerice, CLT²¹ (engl. *contracted and loaded tip propeller*) dizajnom vijka kod kojih su lopatice savijene oštro prema naprijed postiže se bolja energetska učinkovitost te smanjuje potrošnja goriva.

Prikladno oblikovani bulb pomaže smanjenju otpora valova, stvarajući vlastiti sustav vala izvan faze s pramčanim valom iz trupa te smanjuje viskoznu otpornost zaglađivanjem tijeka pramčanog dijela broda. Bulbovi projektirani za samo jedno stanje brzine i uronjenosti trupa nisu učinkoviti u drugim radnim uvjetima te uvjetuju dodatno stvaranje valova i smanjenje učinkovitosti, posebice pri brzinama nižim od projektiranih, stoga čimbenici koji se uzimaju u obzir kod optimizacije bulba uključuju brzinu broda i stanje uronjenosti. Brodovlasnik Maersk Lines izvješćuje o uštedama goriva prilagodbom bulba preko 5% [94]. Razmatranjem svojstvenih radnih uvjeta u procesu projektiranja bulba moguće je optimizirati izvedbu ne samo za pojedinačne brzine i uvjete uronjenosti već i za pojedinačni radni profil svakog plovila. Rezultat može biti neznatno smanjeni učinak na izvornoj vršnoj točki, ali znatno poboljšani učinak pramca na preostalim točkama, što dovodi do značajne prosječne uštede goriva.

Uređaji za predvrtloženje hidrodinamički su dodaci trupu koji tvore rotaciju suprotnu onoj vijka, čime se poboljšava kut nagiba protoka na lopaticama vijka preko cijelog diska. Također, predvrtloženje poništava rotaciju fluida inducirano vijkom. Kao rezultat toga, protok koji napušta disk vijka sadrži minimalni moment te time zahtijeva manje kinetičke energije za proizvodnju potiska.

Uloga postvrtložnih uređaja jest nadzor strujanja na stražnjem kraju vijka, odnosno pretvorba rotacijske komponente protoka u korisni aksijalni tok. U nekim izvedbi cilj je smanjenje štetnih karakteristika protoka (kao što je vortex glavine vijka), odnosno preusmjerenje toka radi poboljšanja učinkovitosti kormila.

Općenito, vijci većeg promjera s manjim brojem lopatica, koji rade na nižem broju okretaja, učinkovitiji su od manjih. Međutim, to opće načelo uravnoteženo je potrebom za razumnim dosjedom vijka i potrebom za usklađivanjem najboljih rezultata vijka i motora.

²¹CLT vijak ugrađen na brodu „Goliath” donio je uštedu od 14% usporedno s konvencionalnim vijkom. CLT vijci raspoloživi su za snage od 75 do 26 500 kW [45].

2.4.5. Upotreba alternativnih vrsta goriva

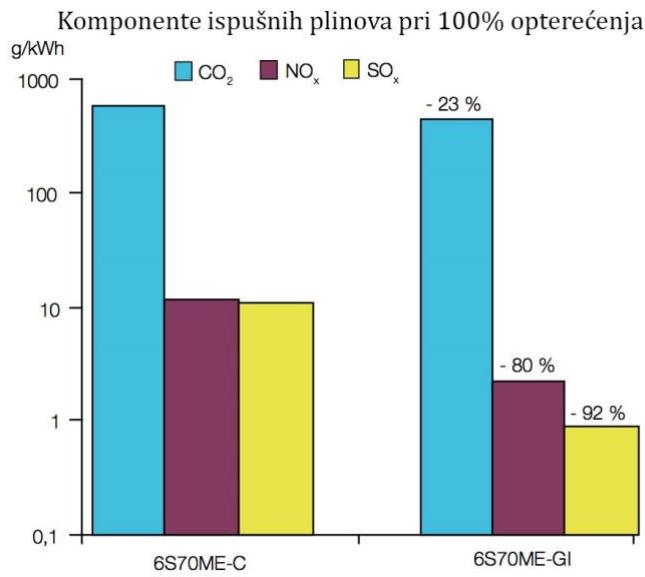
Količina ugljikovog dioksida ispuštenog u atmosferu pri izgaranju goriva proporcionalna je sadržaju ugljika u gorivu. Količina topline ili energije proizvedene pri izgaranju određuje se sadržajem ugljika (C) i vodika (H).

Prirodni plin je ponajviše metan (CH_4), koji ima veći sadržaj energije u odnosu na ostala goriva i time ispušta manje ugljikovog dioksida prilikom izgaranja. Uvođenjem strožih propisa o okolišu koji se odnose na emisiju štetnih sastojaka u atmosferu i povećanje cijena teških goriva, uporaba ukapljenoga prirodnog plina (engl. *liquefied natural gas, LNG*), kod kojeg se usporedno s konvencionalnim gorivima ispušta 20 – 25% manje CO_2 , kao goriva za izgaranje u diesel motorima s dvojnim gorivom (engl. *dual fuel*), nameće se kao prihvatljiva opcija s očekivanim rastom budućih narudžbi [95].

Prednost korištenja LNG-a kao goriva dugogodišnje je iskustvo tijekom kojeg su brodovi sigurno pogonjeni prirodnim plinom.

U početku se LNG rabio za proizvodnju vodene pare na tankerima za prijevoz LNG-a pogonjenih parnom turbinom izgarajući prirodno ispareni LNG (engl. *boil-off gas, BOG*) u tankovima tereta, te time održavajući tlak i temperaturu u tankovima. Sustav se, unatoč visokoj pouzdanosti, nije pokazao kao učinkovit te se prelazi na motore s unutarnjim izgaranjem s mogućnošću izgaranja BOG-a u dvije izvedbe: dvotaktnih sporohodnih diesel propulzijskih motora i četverotaktnih srednjeokretnih diesel generatora [96].

U početku se takvi motori ugrađuju isključivo na tankere za prijevoz LNG-a, no s pooštrenjem zakonodavnih okvira oko onečišćenja atmosfere, takva rješenja prelaze na ostale vrste brodova. Sustav za izgaranje prirodnog plina u motorima s unutarnjim izgaranjem nije uskladiv s ugrađenim motorima koji izgaraju tekuća goriva na postojećim brodovima, te prebacivanje na prirodni plin zahtijeva značajne konstrukcijske izmjene, kao i druge promjene u sustavu dobave goriva, kako bi se zadovoljili propisani standardi.



Slika 3. Usporedba sastava ispušnih plinova motora 76S0ME tvrtke MAN Diesel & Turbo pogonjenog konvencionalnim gorivima (C) i prirodnim plinom (GI).

Zbog toga se najčešće ugrađuju na novogradnje. Na stupčastom grafikonu (Slika 3.) prikazana je usporedba sastava ispušnih plinova dvotaktnog motora tvrtke MAN pogonjenog konvencionalnim gorivima i prirodnim plinom (GI). U posljednje vrijeme pojavljuju se ciljana rješenja poput MHI (Mitsubishi Heavy Industries) STaGE (engl. *steam turbine and gas engines*) hibridnog pogona LNG tankera (prvog isporučenog 2018. godine), a sastavljenog od parnoturbinskog i diesel električnog pogona, oba pogonjena dvojnim gorivom (LNG i diesel/teško gorivo) s neprekinutim pokrovom iznad nove generacije MOSS spremnika, pri čemu je gornja polukružnica spremnika tereta veća od donje. Brod ispušta otprilike 40% manje CO_2 po jedinici tereta u usporedbi s konvencionalnim LNG tankerima koje pokreće konvencionalna parna turbina [97].

Ukapljeni naftni plin (engl. *liquified petroleum gas, LPG*), kao gorivo na LPG brodovima i ostalim trgovackim brodovima, definitivna je mogućnost. Visokotlačni sustav za ubrizgavanje prirodnog plina koji rabi ME-GI motor tvrtke MAN ima prednost što nije osjetljiv na vrstu niti varijacije u sastavu smjese plinova. Poznato je da motor može izgorjeti siromašnije mješavine, kao i plin koji sadrži veće količine ugljikovodika. LPG se obično sastoji od većih molekula ugljikovodika, poput propana i butana, te se stoga mogu rabiti kao gorivo bez promjene izvedbe motora u smislu brzine, toplinske učinkovitosti i izlazne snage, istovremeno održavajući istu razinu učinkovitosti kao pri upotrebi teškog goriva. Kod LPG-a nisu potrebne kriogene tehnologije pri izradi sustava dobave goriva prema motoru, što LPG sustave goriva čini

jeftinijim od LNG-a. Povećana proizvodnja LNG-a očekivana u budućnosti također će stimulirati povećanje proizvodnje LPG-a, što bi trebalo utjecati na cijenu naftnog plina i učiniti ga konkurentnijim tradicionalnim dizelskim (engl. *marine diesel oil, MDO*) i plinskim (engl. *marine gas oil, MGO*) gorivima u upotrebi u pomorstvu [98].

Biogoriva su sljedeća opcija postizanja smanjene emisije štetnih plinova s pomorskih brodova uz izgaranje koje je u brodskim diesel motorima vrlo učinkovito. Goriva su raspoloživa na globalnoj razini, a globalni proizvođači brodskih motora MAN i Wartsila nude opciju takvih motora s unutarnjim izgaranjem. Najčešće su upotrebljavana biogoriva biodizel (iz ulja koja sadrže poljoprivredni usjevi) i bioetanol (iz šećera ili škroba koje sadrže poljoprivredni usjevi). Emisija CO₂ biogoriva gotovo je ekvivalentna (na osnovi energetskog sadržaja) konvencionalnim gorivima, iako se emisija CO₂ biogoriva smatra ugljično neutralnim, a to je kratko-ciklički CO₂ nasuprot dugo-cikličkom fosilnom CO₂. Proizvodnja negorivih sastojaka i uljnih taloga u slučaju uporabe biogoriva niža je zbog smanjenog udjela mulja. To rezultira uštedama u usporedbi s upotrebom MDO-a, a još više u usporedbi s HFO-om [99]. Upotreba biogoriva zanimljiva je opcija s primarnim ciljem smanjenja onečišćenja zraka sumpornim oksidima i alternativa je prirodnom plinu jer nije uvjetovana značajnim konstrukcijskim izmjenama postojećih sustava. Ipak, zasjenjena ograničenom dostupnošću i neatraktivnim cijenama, vjerojatno se neće naći u značajnijoj upotrebi u bliskoj budućnosti.

U Tablici 2. izložene su projekcije temeljene na IMO studiji stakleničkih plinova iz 2009. godine. Prikazani su potencijali smanjenja ispuštanja CO₂ učinjenih za različite tipove plovila, veličinu i dob. Ta studija temeljena je na projiciranoj cijeni goriva iz bunkera (HFO) iz 2007. godine.

Tablica 2. Sažetak globalnog potencijala smanjenja ugljikova dioksida (MT)

Izvor: *Maddox Consulting: Analysis of market barriers to cost effective GHG emission reductions in the maritime transport sector, 2012.* [100]

	2020		2030	
	V	M	V	M
PLOVIDBA SMANJENOM BRZINOM	225,6 MT	440,0 MT	383,7 MT	752,1 MT
PLOVIDBA PREMA PREPORUCI VREMENSKIH PROGNOSTIČARA	12,0 MT	47,9 MT	18,3 MT	73,1 MT
UNAPRJEĐENJE RADA AUTOPILOTA	12,7 MT	19,2 MT	20,3 MT	30,1 MT
OPTIMIZACIJA TRIMA I RASPOREDA BALASTA	13,1 MT	44,6 MT	19,7 MT	70,8 MT
POLIRANJE BRODSKOG VIJKA	13,1 MT	39,3 MT	19,7 MT	59 MT
ČIŠĆENJE PODVODNOG DIJELA TRUPA	13,1 MT	65,5 MT	19,7 MT	98,4 MT
NAPREDNI PREMAZI TRUPA	44,5 MT	26,2 MT	65,5 MT	39,4 MT
UNAPRJEĐENJE RADA BRODSKOG VIJKA I KORMILA	40,9 MT	52,9 MT	63,9 MT	82,2 MT

PODEŠENJE RADA GL. PROPULZIJSKOG STROJA, PRELAZAK NA MOTORE BEZ RAZVODNE OSOVINE	13,1 MT	39,3 MT	19,7 MT	59,0 MT
ISKORIŠTAVANJE OTPADNE TOPLINE	22,5 MT	74,8 MT	36,4 MT	121,5 MT
KONTROLA BRZINE VRTNJE PUMPI I VENTILATORA	2,6 MT	13,1 MT	3,9 MT	19,7 MT
RAZLIČITE METODE UŠTEDE ENERGIJE (PRELAZAK NA ŠTEDLJIVA RASVJETNA TIJELA I SL.)	0,1 MT	0,3 MT	0,1 MT	0,4 MT

V – vrlo vjerojatno, M – najviše moguće

2.4.6. Ekološka prihvatljivost broda i prepreke široj implementaciji mjera smanjenja emisija ugljikova dioksida

Do 2005. godine brodovlasnici i brodari pridavali su mali značaj mjerama za smanjenje potrošnje goriva jer je cijena goriva bila niska. U međuvremenu, cijene goriva prošle su kroz dramatične promjene samo u zadnjem desetljeću, čime se kontinuirano mijenja ekonomija primjene GHG rješenja iz neprihvatljive u isplative.

Emisije CO₂ iz pomorskog prijevoza znatno su se povećale u posljednjem desetljeću, a uz rastući utjecaj azijskih zemalja i povećanu trgovinsku razmjenu, uzlazni će se trend vjerojatno nastaviti. S obzirom na ograničene dostupne opcije dekarbonizacije, povećanje energetske učinkovitosti vrijedan je doprinos smanjenju emisija u sektoru brodarstva. Ukoliko energetska učinkovitost nije adekvatno nagrađena, utoliko se može uvesti samo regulativno. S druge strane, ako bi energetski učinkoviti brodovi mogli naplatiti premiju na tržištu, vlasnici bi imali poticaj za ulaganje u smanjenje potrošnje goriva. U potonjem slučaju, tržište će pomoći postizanju smanjenja emisije ugljika zahvaljujući nagrađivanju ekološki prihvatljivog ponašanja.

Nesigurnost u odnosu na regulatorne zahtjeve kako bi se zadovoljile količine emisije SOx može dovesti do promjene vrste goriva, što može udvostručiti cijenu u odnosu na goriva koja su danas najzastupljenija (HFO). S druge strane, propisi o emisiji SOx-a koji stupaju na snagu, mogu imati za posljedicu unaprjeđenje učinkovitosti pročistača ispušnih plinova do te mjeru da će teška goriva i dalje biti isplativa.

Troškovi gradnje energetski učinkovitog i ekološki prihvatljivog broda veći su od konvencionalnog, no povrat dodatnog ulaganja, unatoč tome što troškovi energije zauzimaju 60 – 70% ukupnih troškova te su samim time mogućnosti uštede velike, nije proporcionalan. U tipičnom ugovornom odnosu o prijevozu tereta zakupoprimatelj ima izravnu materijalnu korist od smanjene potrošnje goriva, dok brodovlasniku ostaje nesigurnost (engl. *split incentives*) oko toga hoće li dobiti povrat uloženih sredstava. To se ponajprije događa kada se brodovi, osobito za prijevoz rasutih tereta, te tankeri i kontejnerski brodovi, uzimaju u najam

na temelju ugovora na određeno vrijeme (engl. *time charter*) te prilikom predaje zakupoprimatelu broda i opreme bez posade (engl. *bare boat charter*). U takvim slučajevima, zakupoprimatelj plaća gorivo, a vlasnik broda ostaje odgovoran za ulaganja u opremu energetske učinkovitosti.

Brodaru je otežano jamčiti i predvidjeti smanjenu potrošnju goriva, pa stoga najmoprimatelj vjerojatno ne želi platiti premiju bez jamstva za uštedu.

Brodovlasnici su u pravilu konzervativni te nevoljko prihvaćaju nova tehnološka rješenja koja se nisu provjerila u praksi.

Brodogradilišta nerijetko tehnologije za smanjenje potrošnje smatraju rizičnim i značajnim odstupanjem od temeljnog projekta te ih ne nude ili naplaćuju daleko iznad stvarne vrijednosti. Zbog rizika ugradnje novih tehnologija, teško je pronaći vanjske izvore financiranja.

Vlasnik broda ne može dobiti uloženo na tržištu rabljenih brodova jer ono ne uzima u obzir energetsku učinkovitost i ekološku prihvatljivost broda pri određivanju cijene.

Svi sektori pomorske industrije prolaze kroz cikluse porasta i pada. U vrijeme porasta brodovlasnici u pravilu raspolažu sredstvima koja mogu usmjeriti u ugradnju prema tehnologijama za uštedu energije dok je tijekom pada, kada je dobit niska, ulaganje svedeno na minimum.

Pojam „prepreka u učinkovitosti“ (engl. *efficiency gap*) odnosi se na razliku između stvarne razine ulaganja u energetsku učinkovitost i višu razinu koja bi bila od veće koristi krajnjem korisniku ili ulagaču. Postojanje te prepreke dokumentirano je u studijama gdje su nove tehnologije bile superiornije od postojećih i gdje nije bilo moguće identificirati primjenjive „skrivene troškove“, no unatoč tome nije došlo do ugradnje učinkovitijih tehnologija [101].

Prepreke u učinkovitosti moguće je predstaviti kao razliku između idealne provedbe (modeliranje) i provedbe u izvedbi (realizirani potencijal):

$$\text{Prepreka u učinkovitosti} = \text{Idealna provedba} - \text{Realizirani potencijal} \quad (6)$$

Neke od prepreka u energetskoj učinkovitosti objasnjuje su racionalnim odzivom na tržišne barijere koje tehnološko-ekonomski analiza nije prepoznala, dok su druge vezane za nedostatak informacija o mogućnostima primjene i ostvarljivim uštedama. Na temelju istraživanja [1] zaključuje se da brodovlasnici koji ulažu u mjere za smanjenje emisije štetnih plinova s pomorskih brodova ne mogu izravno nadoknaditi svoja ulaganja, osim ako ne trguju

svojim brodovima ili imaju dugoročne ugovore s najamnicima, no brodovi manje starosti češći su izbor najamnika u usporedbi s 25 godina starim.

Primjerice, ušteda u potrošnji goriva od oko 5% tankera od 441 585 DWT²² s modernim floropolimerskim (FP) samočistećim premazom s prosječnom hrapavošću površine (engl. *average hull roughness, AHR*) od 70μ nije upitna, no za cijenu pripreme površina, nanošenja te nabave premaza koja prelazi 1,2 milijuna USD, vlasnik broda očekuje povrat takvih sredstava u razumnome roku. Nadalje, paluba i gornji dio trupa broda premazani bijelom zaštitnom bojom znatno smanjuju isparavanje lakših ugljikovodika iz tankova tereta. Takav premaz zahtijeva češće održavanje, no ušteda u smanjenoj količini visokovrijedne isparene komponente trebala bi nadoknaditi uložena sredstva. U praksi je takvu uštedu nemoguće dokazati vlasniku tereta, stoga se bijeli premaz rijetko primjenjuje u praksi.



Slika 4. 440 000 DWT supertanker nakon nanošenja FP zaštitnog premaza

Izvor: fotografija autora snimljena 8.2.2008. u DDWD remontnom brodogradilištu, suhi dok

3

²²441 585 DWT supertanker, izgrađeni 2002. u južnokorejskom brodogradilištu Daewoo za grčkog naručitelja Hellenpont Shipping Corporation i prepoznatljivi po svojoj bijeloj boji, trenutno su nosivošću i ukupnom zapreminom najveći brodovi na svijetu. Klasa se sastoji od četiri broda od kojih su dva prepravljena u FSO tankere (engl. floating storage and offloading), zaposlene za skladištenje sirove nafte na polju Al Shaheed u Katru, dok su druga dva zaposlena kao skladišni brodovi u Omanu i Maleziji.

Krivulje graničnog smanjenja troškova (engl. *marginal abatement cost curves, MACC*) uobičajene su za prikaz tehnoloških rješenja i njihove učinkovitosti, no uvjetovane su najvećim dijelom pretpostavljenom budućom cijenom goriva, čime nisu u potpunosti pouzdane. Iz pojedinih MACC-ova razvidna su rješenja s negativnim troškom nakon implementacije, što znači da su opcije profitabilne jer pokazuju pozitivnu neto sadašnju vrijednost, a što bi u konačnici značilo da će opcija uštedjeti novac kroz smanjenje troškova goriva iznad investicijskog horizonta koji se pretpostavlja u modeliranju. To bi moglo biti zato što je većina tih mjera operacijska te zahtijeva manje kapitalnih izdataka u usporedbi s tehničkim rješenjima [8]. Primjerice, smanjenje brzine broda između 10 i 20% pokazuje značajne uštede kod većine tipova i veličina brodova [2].

Agnolucci, Smith i Rehmatulla [18] daju procjenu stupnja do kojeg su energetski učinkoviti brodovi nagrađeni na tržištu Panamax²³ najma brodova za prijevoz suhih tereta. Potvrđujući prethodna istraživanja, autori ističu 40% uštede proizašle iz ulaganja u energetsku učinkovitost koja na kraju pripada brodovlasnicima. S pozicije zaštite prirodnog okoliša, to je obeshrabrujuće jer vlasnici brodova neće ulagati u energetsku učinkovitost onoliko koliko bi ulagali u slučaju da mogu zadržati veći udio. Vjerojatno i zbog nedostatka informacija te poteškoća pri provjeri stvarne uštede goriva, autori smatraju da svaka politika koja olakšava protok informacija o energetskoj učinkovitosti između zakupoprimatelja i vlasnika, potiče razinu ulaganja u energetsku učinkovitost u pomorstvu i time smanjuje emisiju štetnog CO₂. Svaki instrument koji olakšava protok informacija o stvarnoj energetskoj učinkovitosti pomoći će povećanju najvećeg iznosa koji su vlasnici tereta spremni odvojiti za povećanu energetsku učinkovitost i time potaknuti energetski učinkovita ulaganja vlasnika brodova [101].

²³Panamax flota brodova za prijevoz suhih tereta s maksimalnom nosivošću od oko 60 000 do 100 000 tona sudjeluje s oko 50MT ili 5% ukupne količine ispuštenog CO₂ u pomorskom transportu u 2007. godini.

3. METODE PROCJENE RELEVANTNIH OPERACIJSKIH PARAMETARA

Razvoj brodogradnje sve do 19. stoljeća tekao je relativno sporo uz pomorski promet koji se odvijao malim brzinama plovidbe. Karakteristike brodova utvrđivale su se na probnim vožnjama, odnosno tijekom plovidbe, a brodske su se forme usavršavale iskustveno. Tijekom 19. stoljeća, nekoliko je čimbenika utjecalo na dramatične promjene u konstruiranju i izgradnji brodova, a to su primjena parnog stroja u brodskim uvjetima, upotreba čelika u brodogradnji, te sve veći zahtjevi za povećanjem brzine plovidbe i veličine plovnih objekata. Postalo je neophodno da su već u fazi pretpredmeta projektant i brodograditelj u mogućnosti predvidjeti potrošnju goriva, odnosno ukupni otpor novog plovnog objekta, snagu ugradbenog propulzijskog stroja, kao i brzinu kojom će se budući brod kretati u plovidbi. Tada je potrebno odabrati formu koja će za traženi tip broda osigurati najmanji mogući otpor i najmanju snagu potrebnu za poriv. Utjecaj stvarnih uvjeta plovidbe uobičajeno se osigurava dodatnom ugrađenom porivnom snagom iznad porivne snage potrebne za plovidbu u mirnoj vodi; takva dodatna snaga ovisi o tipu broda i vrsti plovidbe za koju je brod projektiran. Proračun dodatne snage temeljen je na prikupljenim podacima o uvjetima plovidbe sličnih brodova na sličnim putovanjima.

Brod u plovidbi predstavlja složen hidrodinamički sustav koji se uobičajeno svodi na pretvorbu energije goriva u korisni potisak (engl. *thrust*) koji je suprotstavljen ukupnom otporu broda (engl. *resistance*), a koji brod mora savladati da bi postigao zadaniu brzinu plovidbe (engl. *speed*). Ukupni je otpor broda time jedan od temeljnih operacijskih parametara rabljenih prilikom proračuna učinkovitosti plovidbe; što je otpor manji, to je brod ekonomičniji i potrebno je manje goriva kako bi se postigla zadana brzina. Ukupni otpor broda u mirnoj vodi raščlanjuje se na sljedeće komponente [102]:

- otpor trenja (engl. *frictional resistance*) – nastaje kao posljedica prolaska brodskog trupa kroz viskoznu tekućinu. Ispitivanjima je ustanovljeno da kod novih brodova manjih brzina i glatkih površina trupa otpor trenja iznosi od 80 do 85 % ukupnog otpora, dok kod brodova većih brzina otpor trenja može iznositi do oko 50 % ukupnog otpora. Svaka neravnina na podvodnom dijelu oplate trupa povećat će otpor trenja značajno iznad otpora trenja zaglađene površine. Zbog toga na otpor trenja najviše djeluje kvaliteta premaza podvodnog dijela trupa, obraštanje trupa i

napredovanje korozije. Povećanjem otpora trenja mijenjaju se također osobine sustrujanja (engl. *wake*) i propulzije. Apscisa krivulje ukupnog otpora jest Froudeov²⁴ broj F_n , koji se određuje:

$$F_n = \frac{v}{\sqrt{L \cdot g}}, \quad (7)$$

gdje su: F_n – Froudov broj; v – brzina broda (m/s); L – duljina broda (m); g – ubrzanje sile teže (m/s²).

Prema Froudeovom broju plovni se objekti dijele na deplasmanske – $Fr < 1$, poludeplasmanske – $1 < Fr < 3$ i glisirajuće – $Fr > 3$.

- otpor valova (engl. *wave-making resistance*) – nastaje uslijed oblikovanja valova na površini mirne vode, koji su posljedica promjena hidrodinamičkog tlaka uzduž brodskog trupa. Pri manjim brzinama, valovi koje formira brod mali su tako da je udio otpora valova naspram otpora trenja zanemariv. Što je manja energija koja se kontinuirano predaje vodi u obliku valova, to je manji i otpor valova. Energija vala ovisna je o valnoj visini:

$$\bar{E} = \frac{\rho \cdot g \cdot x \cdot \zeta^2}{2}, \quad (8)$$

gdje su: \bar{E} – energija vala (kJ); ζ – amplituda vala (m); ρ – gustoća medija (kg/m³); g – ubrzanje sile teže (m/s²).

- otpor vrtloženja (engl. *eddy resistance*) – nastaje stvaranjem vrtloga na trupu broda i njegovim privjescima. Lokalno vrtloženje pojavljuje se iza privjesaka (engl. *appendages*), kao što su nogavice (engl. *bossings*), osovine (engl. *shafts*) i skrokovi (engl. *shaft struts*). Lokalno se vrtloženje također pojavljuje na krmenom dijelu trupa ili kormilu ako na tim mjestima nije omogućeno dobro opstrujavanje trupa (engl. *streamline*). Također, ako je krmeno zaoštrenje premalo, voda neće moći pratiti zakrivljenje na krmenom dijelu broda, što će rezultirati stvaranjem vrtloga te povećavanjem otpora uslijed odvajanja graničnoga sloja [103].

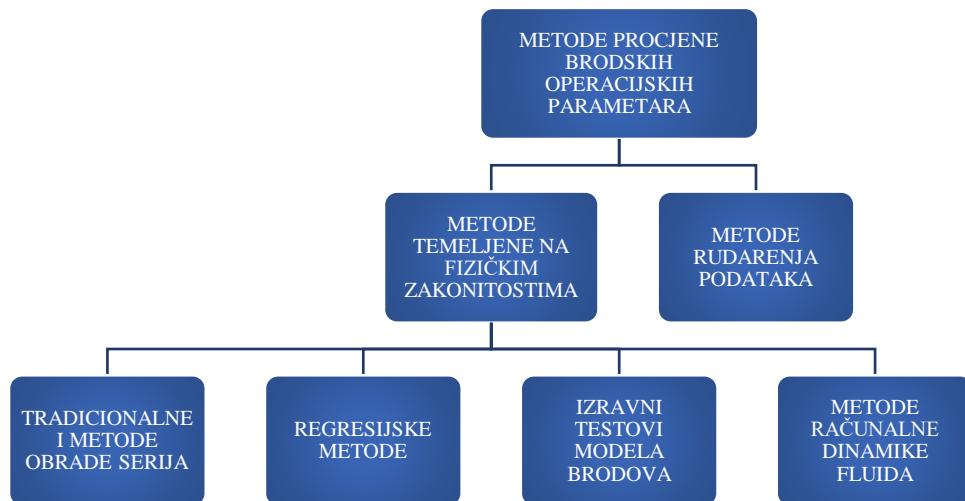
- otpor zraka – nastaje kretanjem nadvodnog dijela broda zrakom. Taj otpor može predstavljati znatan dio ukupnog otpora, pogotovo ako je riječ o brodovima koji se kreću većom brzinom i

²⁴ William Froude (28. studenoga 1810., Devon – 4. svibnja 1879., Simonstown, Južna Afrika), engleski inženjer, hidrodinamičar i brodograditelj, začetnik formulacije pouzdanih zakona otpora i propulzije plovnih objekata

koji imaju veće nadgrađe. Kada brod primi nedovoljnu količinu balasta, zbog povećanja površine trupa iznad vode, otpor zraka obično postaje prevelik, što ima za posljedicu smanjenje upravljačkih svojstava broda.

Otpor valova i vrtloženja uobičajeno se nazivaju preostalim otporom (engl. *residuary resistance*).

U dostupnoj literaturi postoje različite podjele metoda izračuna otpora i ostalih relevantnih parametara, a u ovom radu upotrijebljena je Mollandova nadograđena podjela prikazana na organizacijskoj shemi (Slika 5.).



Slika 5. Metode procjene brodskih operacijskih parametara

Izvor: Molland, A: *The Maritime Engineering Reference Handbook*, 2008. [19]

Osnovna podjela metoda procjene brodskih operacijskih parametara je u dvije skupine: metode temeljene na fizičkim zakonitostima i metode rudarenja podataka. Procjena brodskih operacijskih parametara započinje još u projektnoj fazi kako bi brod ispunjavao ugovorene zahtjeve nosivosti, brzine plovidbe, troškova izgradnje i sigurnosti [104]. U toj fazi još uvijek nema dostupnih senzorskih podataka te su metode temeljene na fizičkim zakonitostima jedini način procjene budućih operacijskih parametara broda. Situacija se mijenja u trenutku kada brod započinje s operacijom i kada je znatna raspoloživost senzorskih podataka. Tada količina prikupljenih podataka omogućuje novi temelj ocjene učinkovitosti broda u stvarnim uvjetima plovidbe. Nedostatak metoda temeljenih na fizičkim zakonitostima je što neizvjesnost povezana s fizičkim modelom uključuju u točnost konačnih rezultata [105].

Za prevladavanje nedostataka, modeli koji koriste teorijske principe i fizičke zakonitosti nerijetko se nadopunjaju stvarnim izmjer enim podacima obrađenim nekom od metoda rudarenja podataka [106, 107, 108].

U ovome radu prednost je dana metodama rudarenja zbog jednostavnosti modeliranja i implementacije u postojeće brodske sustave i postupke te mogućnosti praćenja starenja trupa i postrojenja.

3.1. Metode temeljene na fizičkim zakonitostima

Iskustvene hidrodinamičke metode uobičajeno se oslanjaju na skup parametara koji opisuju brodski trup i Froudeov broj te mogu uspješno procijeniti utrošak energije potreban za propulziju plovног objekta usporediv s potrošenom energijom u stvarnim uvjetima plovidbe. Takve metode nerijetko odstupaju od stvarnih vrijednosti ako nisu korigirane usporedbom sa specifičnim podacima vezanim za stvarnu plovidbu. Promjenom uvjeta plovidbe ili starenja broda takva su odstupanja u pravilu veća.

3.1.1. Tradicionalne i metode obrade serija

Tradicionalne i iskustvene metode sastoje se od teorijskih metoda zasnovanih na grafikonima i opažanjima koja se temelje na eksperimentima koje su proveli različiti znanstvenici i stručnjaci iz područja brodogradnje:

*Admiral Taylor*²⁵ objavio je 1910. godine rezultate testova modela na nizu različitih oblika broda „Leviathan“. Osnovna forma imala je najveći presjek na polovici duljine i 3% bulb na pramcu, te krstašku krmu s dva porivna vijka. Modeli su ispitivani sve do 1933. godine te objavljeni u Taylorovoј knjizi „The Speed and Power of Ships“ iz 1933. godine [20]. Njegov rad proširen je 1943. godine kako bi obuhvatio Froudeov broj od 0,3 do 2,0. Serija se sastojala od 80 brodskih modela u kojima su rezultati objavljeni za omjere širine (engl. *beam*) i uronjenosti broda (engl. *draft*), odnosno B/T od 2,25, 3,0 i 3,75 za pet omjera duljina prema istisninama. Upotrijebljeno je osam prizmatičnih koeficijenata u intervalu od 0,48 do 0,8, što čini seriju korisnom za brže i lakše plovne objekte. Postupak je usredotočen na izračunavanje koeficijenata preostalog otpora na temelju podataka za svaku B/T vrijednost koja odgovara vrijednostima prizmatičnih i Froudeovih brojeva. Preostala komponenta otpora C_R izračunava se interpolacijom iz triju B/T vrijednosti koje odgovaraju vrijednostima v/\sqrt{L} (engl. *velocity/waterline length ratio*), odnosno omjeru brzine i korijena duljine broda na vodenoj liniji.

²⁵David Watson Taylor (4. ožujka 1864., okrug Louisa, Virginia, SAD – 28. srpnja 1940., Washington, DC), američki brodograditelj koji je sagradio prvu ustanovu za testiranje brodova u SAD-u u Washingtonu DC, Navy Yard i formulirao temeljna načela brodskog dizajna

Komponenta otpora trenja izračunava se na temelju Reynoldsovog broja i oplakane površine zajedno s dozvoljenom hrapavosti trupa [19].

Rezultat tog izračuna dodaje se interpoliranim koeficijentu rezidualnog otpora kako bi se formirao koeficijent ukupnog otpora C_T , iz kojeg se proračunava efektivna snaga za svaku od odabranih Froudeovih vrijednosti iz odnosa:

$$P_E = A \times C_T \times v_S^3, \quad (9)$$

gdje su: P_E – efektivna snaga (KS); A – oplakana površina broda (m^2); C_T – koeficijent ukupnog otpora; v_S – brzina broda (m/s)

Taylor prikazuje dobivene rezultate u obliku krivulja:

$$\frac{R_R}{\Delta} = f \left(C_P, \frac{\Delta}{\left(\frac{L_{WL}}{100}\right)^3} \right), \quad (10)$$

gdje su: R_R – preostali otpor; C_P – prizmatični koeficijent trupa na vodenoj liniji; Δ - istinsna (t); L_{WL} – duljina na vodenoj liniji (m) za pojedine vrijednosti B/T i v/\sqrt{L} .

Morton Gertler preračunava Taylorove krivulje u funkcije:

$$C_R = f \left(\frac{v}{\sqrt{g \times L_{WL}}}, \frac{\nabla}{L_{WL}^3} \right), \quad (11)$$

gdje su: C_R – koeficijent preostalog otpora; v – brzina (čv); ∇ - odnosna dimenzija volumena broda; L_{WL} – duljina na vodenoj liniji (m), za pojedinačne vrijednosti C_P i B/T [21].

*Amos Ayre*²⁶ 1927. je godine razvio metodu na temelju podataka testova modela, rabeći niz oblika trupa broda za prijevoz ugljena²⁷. U svom pristupu, koji je u ranijim godinama postigao široku primjenu, metoda se usredotočuje na izračun koeficijenta C_2 :

$$P_E = \frac{\Delta^{0.64} x v_S^3}{C_2}, \quad (12)$$

gdje su: P_E – efektivna snaga (KS); v_S – brzina broda (m/s); C_2 – koeficijent omjera v/\sqrt{L} .

Taj odnos podrazumijeva da se u slučaju pune veličine plovila identičnih oblika i proporcija, P_E pri odgovarajućim brzinama mijenja razmjerno ($\Delta^{0.64} x v_S^3$), tako da je C_2 konstantna kod danih vrijednosti v/\sqrt{L} . Upotrebom $\Delta^{0.64}$ nije potrebno odvojeno tretirati otpore trenja i preostale otpore za plovne objekte oko 30 m.

Vrijednost C_2 procjenjuje se za standardni koeficijent bloka. Zatim se vrše prilagodbe kako bi se standardni koeficijent bloka približio stvarnoj vrijednosti zadovoljavanjem varijacija u omjeru B/T , položaju uzdužnog težišta istisnine i ukupnoj duljini, ako se razlikuje od standardne vrijednosti rabljene u izvedbi metode.

Sustavna obrada podataka otpora brodova s ciljem predviđanja ukupnog otpora broda i izbora odgovarajućeg oblika trupa te snage poriva slijedi dva osnovna smjera [22]:

1. Obradu izmјerenih podataka obrade broda – modela, tzv. sustavnih serija. Forme trupa takvih serija sustavno se mijenjaju varijacijom proporcija glavnih karakteristika zadane forme, koja može biti odabrana iskustveno ili optimizacijom forme postojećeg trupa s ciljem minimalnog otpora.
2. Sustavna obrada izmјerenih podataka modela i brodova u stvarnoj veličini istoga trupa. Takvi se podaci primjenjuju na proračun otpora brodova iste namjene i vrste. Obradeni modeli ili brodovi nisu u potpunosti jednaki, već imaju iste omjere glavnih dimenzija, koeficijente trupa i plove pri jednakim odnosnim brzinama.

²⁶Sir Amos Lowrey Ayre (23. srpnja 1885., South Shields, UK – 13. siječnja 1952.), britanski brodograditelj i suosnivač brodogradilišta Burntisland 1918. godine

²⁷Riječ je o relativno neuobičajenom dizajnu broda za prijevoz rasutog tereta s krmenom strojarnicom i kormilarnicom u sredini broda. Brodovi su uglavnom bili namijenjeni opskrbi ratnih brodova s ugrađenim parnim kotlovima loženim ugljenom.

Danas su dostupne velike količine podataka koji se odnose na standardne oblike trupa u kojima geometrijske varijable oblika variraju na sustavan način te se standardiziraju predvođene Međunarodnom konferencijom vučnih tankova (engl. *International Towing Tank Conference, ITTC*). Konferencija je dragovoljna udružica svjetskih organizacija odgovornih za predviđanje hidrodinamičkih osobina brodova i brodskih instalacija na temelju rezultata fizičkog i numeričkog modeliranja s primarnim ciljem poticanja napretka u rješavanju tehničkih problema, pružanju savjeta i informacija u vezi s relevantnim brodskim parametrima, poticanja istraživanja u svim područjima u kojima je potrebno bolje poznavanje hidrodinamike brodova i brodskih instalacija, kako bi se poboljšale metode modelnih eksperimenata, numeričko modeliranje i mjerjenja u punoj veličini, preporuke postupaka za opću uporabu u provođenju eksperimenata fizičkih modela i numeričkog modeliranja brodova i brodskih instalacija te potvrđivanje točnosti takvih potpunih predviđanja i mjerjenja za osiguranje kvalitete, formuliranje zajedničke politike o interesnim pitanjima i pružanje učinkovite platforme za razmjenu informacija o tim pitanjima.

ITTC Odbor za otpore na 16. je sastanku izradio prijedlog udruženog eksperimentalnog istraživačkog programa za otpor brodova i protok oko trupa kako bi se izradila standardna baza podataka. U Japanu su četiri organizacije provele pokuse na Wigleyjevom paraboličnom modelu kako bi istražile utjecaj razmjera otpora broda pomoću geosimskih modela duljine 6 m, 4 m, 2,5 m i 2 m.

Takvi se podaci obrađuju regresijskim analizama radi dobivanja algebarskih funkcija ugrađenih u programe koji se koriste pri projektiranju plovnih objekata.

3.1.2. Metode regresije

Predviđanje otpora broda na temelju statističkih regresijskih metoda definiraju u nekoliko radova Holtrop i Mennen [23, 24]. Regresijsku metodu temelje na raščlani ukupnog otpora kako slijedi:

$$R_T = (1 + k_1)R_F + R_W + R_B + R_{TR} + R_{APP} + R_A, \quad (13)$$

gdje su: R_T – ukupni otpor broda; R_F – otpor trenja; R_W – otpor valova golog trupa; R_B – otpor valova pramca s bulbom; R_{TR} – dodatni otpor uronjenog dijela krmenog zrcala; R_{APP} – otpor privjesaka; R_A – dopuštena korelacija za ekstrapolaciju modela na brod; $(1 + k_1)$ – koeficijent oblika golog trupa.

U prethodnom izrazu otpor trenja R_F izračunava se prema formulaciji ITTC-a iz 1957. godine, a faktor oblika trupa ($1 + k_1$) temelji se na regresijskoj jednadžbi:

$$(1 + k_1) = f \left(\frac{L}{B}, \frac{L}{T}, LCB, \frac{\nabla}{L^3}, C_p \right), \quad (14)$$

dok se otpor vala predstavlja sljedećom regresijskom jednakošću:

$$\frac{R_W}{\nabla \times \rho \times g} = f \left(F_n, C_M, \frac{\nabla}{L^3}, \frac{L}{B}, \frac{B}{T}, \frac{A_{BT}}{BT}, \frac{A_T}{BT}, T_f, h_b, c_p \right), \quad (15)$$

gdje su: L – duljina fluktuacije (m); B – širina broda (m); T – uronjenost (m); LCB – uzdužni položaj centra trupa (m); ∇ – istisnina (m^3); C_p – prizmatični koeficijent trupa na vodenoj liniji; R_W – otpor vala; F_n – Froudeov broj; C_M – koeficijent srednje sekcije; A_{BT} – poprečni presjek bulba (m^2); A_T – poprečni presjek krmenog zrcala u mirovanju (m^2); T_f – okomita udaljenost od središta bulba do linije kobilice (m); h_b – uronjenost pramčanog dijela broda (m); c_p – prizmatički koeficijent trupa.

Regresijski izraz za izračun oplakane površine brodskog trupa (S):

$$S = f(L, B, T, C_M, C_B, C_{WP}, A_{BT}) \text{ (m}^2\text{)}, \quad (16)$$

gdje su: C_{WP} – koeficijent finoće fluktuacije i C_B – koeficijent bloka, odnosno odnos podvodnog volumena broda prema volumenu oplakivanja bloka i izračunava se prema:

$$C_B = \frac{\nabla}{L \times B \times d}. \quad (17)$$

Utjecaj dodatnog otpora privjesaka izračunava se izrazom:

$$R_{APP} = \frac{1}{2} \rho \times v^2 \times S_{APP} (1 + k_2) \times C_F, \quad (18)$$

gdje su: v – brzina broda (m/s); S_{APP} – oplakivana površina privjesaka (m^2); $1 + k_2$ – koeficijent forme privjesaka; C_F – koeficijent otpora trenja broda.

Dodatni otpor korelacije pri ekstrapolaciji s modela na brod izračunava se prema izrazu:

$$R_A = \frac{1}{2} \rho x v^2 x S x C_A, \quad (19)$$

gdje je C_A koeficijent dozvoljene korelacijske.

Poboljšanja u odnosu na standardne metode procjene otpora vidljiva su u tome što je faktor forme ovisan o brzini broda, unaprijeđen je izračun otpora vala te uveden otpor zraka i korekcija za plovidbu u plitkoj vodi.

Predstavljena raščlana otpora nije jedina i različiti autori razvijaju različite pristupe kako bi odgovorili na izazove oko što preciznijeg izračuna. U svakome slučaju, otpor valova prevladavajuća je komponenta preostalog otpora u većini scenarija [26].

Holtrop i Mennen predlažu koristan alat procjene otpora plovнog objekta. Međutim, kao i mnogi drugi postupci analize, u velikoj mjeri oslanjaju na tradicionalne arhitektonske parametre pomorske industrije. Kako ti parametri ne mogu u potpunosti djelovati kao osnova za prikazivanje zakrivljenosti trupa i utjecaj na tok oko plovila, postoji prirodno ograničenje točnosti pristupa bez uporabe složenijih parametara definicije trupa. Trenutno se u tom smjeru odvijaju istraživanja kako bi se proširila održivost metode predviđanja otpora [19].

3.1.3. Izravni testovi modela

Modelske ispitivanje broda u fazi projektiranja važan je dio procesa, posebice nakon Drugoga svjetskog rata, kada se naglo razvija znanstveno-istraživački rad u području brodske hidrodinamike. Bitno je naglasiti da su ovi modeli, za razliku od modela opisanih u poglavljju 3.1.1. gdje se koriste modeli stvarne veličine trupa, nekoliko puta manji od stvarnih plovnih jedinica. Bazeni za tegljenje brodskih modela u pravilu su izgrađeni od armiranog betona u obliku dugačkih kanala, većinom pravokutnog presjeka, napunjeni slatkom vodom (Slika 6.). U njima se ispituju modeli brodova u mirnoj vodi, no jednako tako obavljaju i ostala hidrodinamička ispitivanja ako su bazeni opremljeni dodatnim uređajima, poput generatora valova [22].



Slika 6. Modelsко испитivanje broda u bazenu

Izvor: fotografiju ustupio Brodarski institut u Zagrebu

Prilikom испитivanja otpora, model broda se vuče pomoću kolica za tegljenje postavljenim na tračnicama uzduž bazena, a ukupna uzdužna sila koja djeluje na model mjeri se za različite brzine vuče. Širina i dubina bazena određuju veličinu modela koji se može испитivati. Model se postavlja ispod kolica i vuče na način da je slobodan za podizanje i uron, kako bi se mogao simulirati potreban gaz. Provodi se po cijeloj dužini bazena u određenim vremenskim intervalima, a vrijednosti otpora bilježe se pomoću dinamometra postavljenog unutar modela. Model je uobičajeno izrađen od parafinskog voska, drva ili plastike ojačane stakлом, mora biti izrađen do visokog stupnja finoće, sa simulatorima turbulencije smještenim na pramcu kako bi se potaknuo prijelaz iz laminarnog u turbulentno strujanje u graničnom sloju preko trupa. Primjena izazivača turbulencije nije idealno rješenje jer izaziva dodatni otpor, a ispred njih još uvijek ostaje dio pramca na kojem se može razviti laminarno strujanje. Upravo taj predio pramca na kojem je laminarni sloj najtanji važan je za utjecaj trenja. Općenito, postoje dvije vrste testova otpornosti: испитivanje trupa i test dodatnog otpora [25].

Izmjerene sile otpora modela pri konstantnoj brzini tegljenja proračunavaju se u otpor trenja modela, viskozni otpor modela, te preostali otpor modela. Određivanje otpora trenja modela i broda započeo je Froude, no uslijed dokazanog nesklada postavki trenja i fizičkih zakona optjecanja viskozne tekućine, zamijenile su ih naprednije metode. Danas se prema preporuci ITTC-a u pravilu upotrebljava koreacijska linija ITTC-1957, ali različiti bazeni paralelno

obrađuju podatke primjenom ranijih metoda, poput Lap-Trostove [109] ili Hughesove [110], jer su one korištene prilikom skupljanja podataka o modelima. Potom se izračunava otpor trenja stvarnog plovnog objekta, odnosno njegov viskozni otpor, metodom sličnosti koja je odabrana za model te, zbrajanjem pojedinačnih otpora, ukupni otpor stvarnog plovnog objekta. Sličnost modela i stvarnog plovnog objekta uvjetovana je geometrijskom, kinematičkom i dinamičkom sličnošću.

Geometrijsku sličnost trupa u pravilu nije teško zadovoljiti, međutim, time nije u potpunosti zadovoljena sličnost modela i stvarnog objekta. Poteškoće uglavnom proizlaze iz ispitivanja modela u slatkoj vodi, hrapavosti oplakivane površine broda koja ovisi o vrsti premaza, obraštanju oplate i slično. Ograničenja dimenzija bazena (najvažnije su dubina i širina) također je potrebno uključiti prilikom preslikavanja. Kod kinematičke sličnosti modela i stvarnog objekta, ona je postignuta kada se bilo koja brzina čestice fluida (voda) pri optjecanju stvarnog objekta može odrediti množenjem brzine odgovarajuće čestice pri optjecanju modela uvijek istim koeficijentom kinematičke sličnosti. Kod dinamičke sličnosti takav je odnos sila što djeluju na česticu tekućine pri optjecanju stvarnog objekta koje se moraju dobiti množenjem sila pri optjecanju modela s koeficijentom dinamičke sličnosti.

Pri uporabi metoda ekstrapolacije izmjerениh vrijednosti modela na stvarnom plovnom objektu od iznimnog je značenja točnost i preciznost izmjerениh podataka pri ispitivanju u bazenu. Također, veličina modela određuje točnost, a ograničena je, kako je navedeno, dimenzijama bazena.

Potrebno je naglasiti da na otpor trupa utječe i rad vijka, a proračun tog utjecaja uračunava se u proračun propulzije broda i procjenjuje tijekom ispitivanja modela. Time standardna ispitivanja uključuju ispitivanje otpora, ispitivanje vijka (engl. *open water test*), ispitivanje propulzije i test vizualizacije protoka.

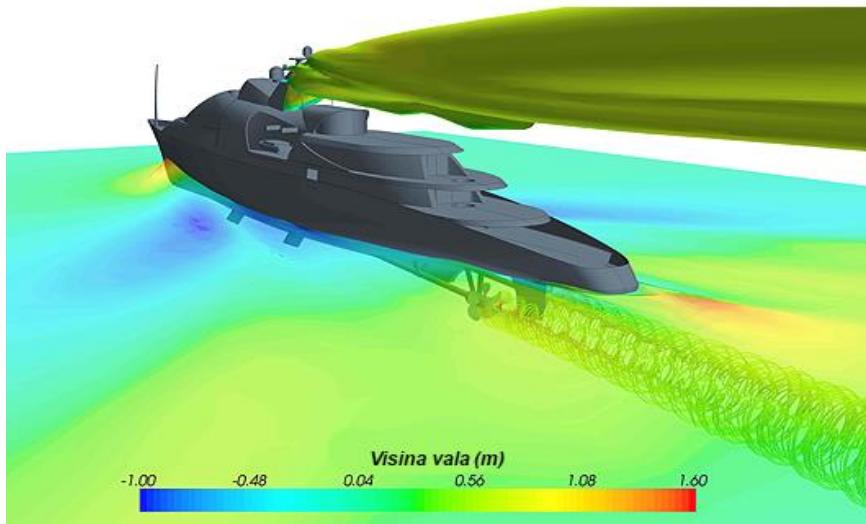
3.1.4. Metode računalne dinamike fluida

Računalna dinamika fluida (engl. *computational fluid dynamics, CFD*) dio je mehanike fluida koji rabi numeričke metode i algoritme pri rješavanju i analizi problema koji uključuju protok nekog fluida. Računala se upotrebljavaju za izračune potrebne kod simulacije interakcije fluida s područjem određenim rubnim uvjetima (Slika 7.). Temelj gotovo svih CFD programa jest Navier-Stokesova jednadžba, koja karakterizira tokove viskoznih fluida u jednoj fazi:

$$\bar{F} - \frac{1}{\rho} \times \nabla p + \frac{\eta}{\rho} \Delta \bar{v} + \frac{v}{3} \nabla(\nabla \bar{v}), \quad (20)$$

gdje su: \bar{F} – jedinstvena masena sila; \bar{v} – brzina; p – tlak; ρ – gustoća; η – dinamički viskozitet; v – kinematički viskozitet.

Pomorska računalna dinamika fluida uglavnom se bavi problemima u hidrodinamici. U većini slučajeva izračunavaju se globalni tlakovi i komponente brzine fluida u trodimenzionalnom prostoru koji okružuje potopljeni dio brodskog trupa.



Slika 7. Ispitivanje broda u plovidbi korištenjem CFD simulatora

Izvor: AITAC [111]

Na taj način moguće je dalje izračunati sile i momente koji djeluju na trup, bilo da su postojani ili nestabilni. Uobičajeno je da se radni fluid, u ovom slučaju voda, smatra nestlačivim i izotermalnim. Nadalje, pretpostavlja se da je tekućina Newtonovska i da je laminarna viskoznost konstantna tijekom cijelog toka. Međutim, moguće je postaviti i daljnje pretpostavke o ponašanju toka, ovisno o prirodi problema [28]. S obzirom na to da je otpor valova komponenta ukupnog otpora, pod uvjetom da se zanemaruju viskozni učinci, potencijalni se protok može definirati nametanjem graničnih uvjeta na trupu i slobodnoj površini. Uvjeti trupa uzimaju se u obzir stavljanjem raspodjele izvornih panela preko njegove površine. Problem je u zadovoljavanju slobodnih površina / graničnih uvjeta, koji se moraju primijeniti na stvarnoj slobodnoj površini, što je, naravno, nepoznato na početku izračuna. Otpor valova može se izračunati iz energije u spektru slobodnih valova ili integracijom stalnih

pritisaka na površini trupa. U pristupu koji je predložio Dawson [112] ukupni potencijal podijeljen je na potencijal dvostrukog tijela i potencijal perturbacije. Budući da je potencijal perturbacije malen, potencijal dvostrukog tijela odgovara ograničavajućem rješenju jer Froudeov broj pada na nulu.

Danas, kada se razmatraju propulzijski aspekti dizajna broda, preporučuje se kombinacija testiranja modela i analize CFD-om u kombinaciji s ostalim metodama. Bez obzira na napredak koji je postignut s procesima matematičkog modeliranja, oni u ovom trenutku ne bi trebali zamijeniti konvencionalne i u teoriji i praksi potvrđene postupke testiranja modela za koje postoji velik broj podataka o korelaciji; radije ih treba iskoristiti kao dopunu pristupu dizajna omogućujući projektantu stjecanje uvida u dinamiku protoka i razvoj rješenja prije izgradnje trupa.

3.2. Metode rudarenja podataka

U današnje vrijeme, u gotovo svakoj djelatnosti, prikupljaju se velike količine podataka iz kojih je bez pomoći računalne obrade teško izdvojiti važno te na temelju toga donositi kvalitetne odluke. Primjerice, podaci prikupljeni na brodovima u obliku podnevnih izvješća često pružaju više informacija nego što se može razumjeti samo gledajući ih, posebice ako se promatra dulje vremensko razdoblje.

Podatak je činjenica predočena u formaliziranom obliku koja je pogodna za daljnju obradu, interpretaciju ili komunikaciju među ljudima, među uređajima ili između ljudi i uređaja. Podatak u brodskim uvjetima može biti senzorski podatak o temperaturi ili tlaku, odnosno podatak o brzini vjetra ili stanju mora. Informacija je značenje koje je pripisano podatku, odnosno, rezultat obrade, manipulacije i organizacije podataka tako da primatelj podatka dobije i značenje, relevantnost ili znanje [113]. Ukratko, kada se podatak iskoristi u neku korisnu svrhu, onda je to informacija. Informacija može biti vremenska prognoza ili potrošnja goriva. Moderni brodovi prikupljaju veliku količinu podataka u obliku senzorskih signala s ciljem nadziranja i upravljanja brodskim sustavima. Senzorski podaci predstavljaju niz numeričkih vrijednosti, služe za trenutno nadziranje sustava i rijetko se pohranjuju ili upotrebljavaju za daljnju obradu, organizaciju ili usporedbu s početnim stanjem, odnosno ne prelaze u informacije. Pregledavanjem takvih podataka teško je doći do kvalitetnih informacija ili znanja. Stoga proizvođači opreme nadzora i upravljanja nerijetko nude opciju grupiranja i vizualizacije s ciljem boljeg uočavanja promjena koje izlaze iz okvira predviđljivog ili

uobičajenog ponašanja sustava, no u tom se slučaju podaci ne pohranjuju kroz dulje vremensko razdoblje niti se računalno obrađuju s ciljem izvlačenja novih uzoraka ili uvida u sustav.

Osnovna je razlika između tradicionalne podatkovne analitike i metoda rudarenja u tome što se rudarenjem automatskim, statističkim postupkom izvlači informacija i otkriva model koji sadrži znanje o promatranom sustavu [114]. Rudarenje podataka naziva se još i dubinska analiza podataka i temeljeno je na postupcima strojnog učenja, gdje algoritam iz podataka uči model koji služi dalnjem zaključivanju o podacima, dakle sadrži znanje.

Rudarenje podataka služi kako bi se iz velikog skupa potencijalno nepotpunih i neprovjerenih podataka, uz pomoć raznih algoritama, grupirale, organizirale i izdvojile implicitne informacije, obrasci, asocijacije, promjene i anomalije, statistički značajne strukture i događaji te otkrila potencijalno korisna znanja iz podataka (engl. *knowledge discovery in databases*, *KDD*) koja ljudi prethodno nisu znali ili vidjeli [115, 113].

Nadalje, uz pomoć algoritama strojnog učenja, korisnik može dobiti dodatne uzorke i znanja i kad je količina podataka prevelika za razumijevanje odnosa ili kada odnosi među podacima nisu razumljivi. Strojno učenje definira se kao automatizirani proces analize uzoraka i stvaranja informacija iz skupine podataka koje nadopunjuje i zamjenjuje inženjerstvo znanja [116].

Zadaće rudarenja podataka ovise o vrsti podataka i ciljevima, a mogu se podijeliti u nekoliko osnovnih skupina [117]:

- *Asocijacijska pravila*, odnosno otkrivanje pravila među podacima (ulaznim varijablama) s ciljem uočavanja poveznica među podacima, kao i zajedničkog nastupanja u promatranim događajima (npr. istovremenoj kupovini proizvoda u potrošačkoj košarici),
- *Grupiranje* (engl. *clustering*) je postupak organiziranja podataka u skupove ili grupe podataka koji su međusobno slični, ali različiti od podataka u drugim skupovima. Grupiranje se najčešće upotrebljava kada točan raspored podataka u skupove nije poznat i tada je riječ o nenadziranom učenju. Rezultirajući klasteri ili grupe mogu se rabiti kao dodatni ulazni atributi²⁸ u dalnjim postupcima rudarenja podataka,
- *Klasifikacija* razvrstava ulazni skup podataka u odnosu na vrijednost izlazne varijable koja opisuje razred. Raspored u razred ili skup unaprijed je poznat te je u tom slučaju riječ o nadziranom učenju,

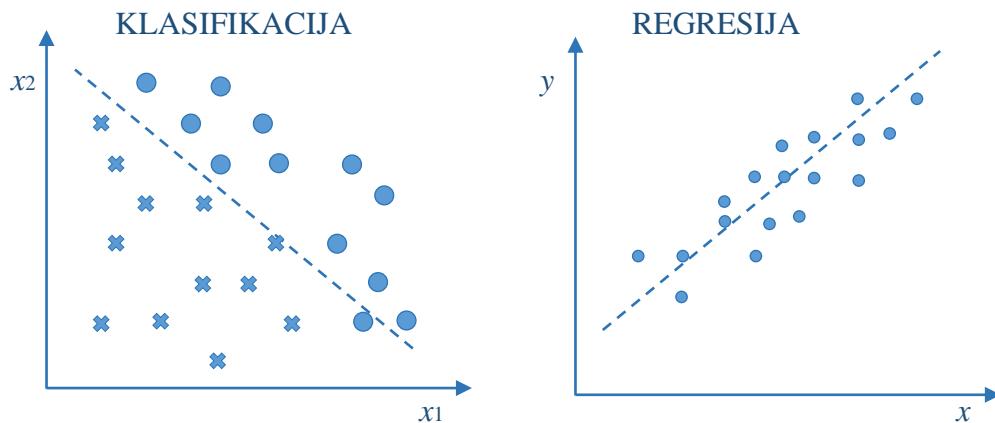
²⁸ Atribut je veličina pojedine varijable.

- Regresija je slična klasifikaciji, osim što regresija predviđa isključivo numeričku vrijednost izlazne varijable, dok kod klasifikacije vrijednost može biti i kategorička,
- Prediktivno modeliranje postupak je u kojem se gradi model za predviđanje vrijednosti odabrane (izlazne) varijable iz poznatih vrijednosti drugih (ulaznih) varijabli, te upotrebljava algoritme regresije i klasifikacije.

Metode rudarenja podataka mogu se podijeliti u dvije osnovne skupine:

Nadzirane metode (engl. *supervised methods*) i *nenadzirane metode* (engl. *unsupervised methods*). Nadzirane metode rudarenja, rabljene u ovom istraživanju, one su metode u kojima se za izgradnju modela upotrebljavaju podaci za koje su unaprijed poznati pripadajući razredi, a zatim se na temelju izgrađenog modela predviđa razred kojemu će pripadati novi podaci za koje je razred nepoznat. Toj skupini pripadaju metode klasifikacije. Za razliku od nadziranih, nenadzirane metode na temelju zadanih podataka formiraju grupe podataka, bez prethodnog saznanja o tome kojemu bi razredu podaci mogli pripadati. Kod tih metoda ne postoji razlika između atributa, tj. nije definiran ciljni atribut kao kod nadziranih metoda učenja. Toj skupini pripadaju metode grupiranja i metode asocijativnih pravila.

Osnovni cilj nadziranog rudarenja podacima jest taj da za ulazni skup primjera nauči funkciju $h: X \rightarrow Y$, gdje su: X – skup ulaznih varijabli; x – ulazna varijabla; Y – skup izlaznih varijabli; y – izlazna varijabla, tako da $h(x)$ bude prediktor odgovarajuće vrijednost y .



Slika 8. Vizualni prikaz postupaka klasifikacije i regresije

Među navedenim algoritmima postoje inherentne razlike prema formatu izlazne varijable; ukoliko je izlazna varijabla y kontinuirana iz skupa realnih brojeva $y \in \mathbb{R}$, utoliko se rabe *regresijski algoritmi*, dok se *klasifikacija* upotrebljava ako je izlazna varijabla kategorička i poprima diskretne vrijednosti, primjerice za binarni slučaj $y \in \{p, n\}$, gdje su p i n diskretne

vrijednosti razreda. U osnovi, regresija se odnosi na predviđanje količine (engl. *quantity*), a klasifikacija na predviđanje oznake (engl. *label*) (Slika 8.).

3.2.1. Klasifikacijske metode

U ovom radu upotrebljavane su nadzirane metode učenja, što znači da podaci koji se upotrebljavaju za učenje moraju biti označeni. Osim atributa koji opisuju podatke, označeni podaci moraju sadržavati i oznaku razreda kojem pripadaju. U radu su ispitani sljedeći algoritmi klasifikacije:

- naivni Bayes,
- multinomijalna logistička regresija,
- višeslojni perceptron umjetne neuronske mreže,
- strojevi potpornih vektora,
- stabla odluke,
- nasumične šume.

Za učenje svih modela upotrijebljen je programski paket Weka (ver. 3.8.2) sa standardnom implementacijom i postavkama parametara algoritama, osim u kasnije navedenom slučaju višeslojnog perceptrona. U nastavku su opisana osnovna obilježja algoritama, s iznimkom nasumičnih šuma, koje su obrađene detaljnije jer su postigle najbolje rezultate [40].

Naivni Bayes (engl. *naive Bayes*, *NB*) jednostavna je metoda temeljena na Bayesovom²⁹ teoremu. Služeći se Bayesovim teoremom, može se pronaći vjerojatnost da će se događaj A dogoditi, uz uvjet da je događaj B nastao:

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)}. \quad (21)$$

Ovdje je B dokaz, a A hipoteza, te se pretpostavlja da su prediktorska varijabla i ulazne varijable (atributi) neovisne. To znači da prisutnost jedne varijable ne utječe na drugu.

²⁹Thomas Bayes (1701. – 7. travnja 1761.) bio je engleski statističar, filozof i prezbiterijanski svećenik koji je poznat po formuliranju teorema koji nosi njegovo ime. Bayes nikada nije objavio ono što će postati njegovo najpoznatije postignuće; njegove je bilješke Richard Price uredio i objavio nakon njegove smrti.

Prepostavlja se i da ne postoji skriveni ili latentni atribut koji utječe na proces predviđanja te se zato naziva naivnim [118, 119, 120].

Prepostavi li se da je y varijabla razreda, a X parametar dobiven iz vrijednosti ulazne varijable, uz gornji uvjet neovisnosti, teorem se može napisati kao:

$$P(y|X) = \frac{P(X|y) P(y)}{P(X)}, \quad (22)$$

gdje je parametar $X = (x_1, x_2, x_3, \dots, x_n)$.

Atributi x_1, x_2, \dots, x_n mogu se preslikati u temperaturu, tlakove ili potrošnju goriva. Zamjenom za X iz prethodnog izraza i proširenjem pomoću lančanog pravila dobiva se:

$$P(y|x_1, \dots, x_n) = \frac{P(x_1|y) P(x_2|y) \dots P(x_n|y) P(y)}{P(x_1)P(x_2) \dots P(x_n)}. \quad (23)$$

Za različite primjerke iz skupa podataka nazivnik se ne mijenja, odnosno ostaje stalan. Stoga se nazivnik može ukloniti te ostaje brojnik:

$$P(y|x_1, \dots, x_n) \propto P(y) \prod_{i=1}^n P(x_i | y). \quad (24)$$

Za klasifikaciju se mora odrediti ciljna varijabla s najvećom mogućom vjerojatnošću, pomoću argmax funkcije [121]:

$$\hat{y} = \underset{y}{\operatorname{argmax}} P(y) \prod_{i=1}^n p(x_i | y), \quad (25)$$

u kojoj je \hat{y} predviđanje vrijednosti varijable, y je zabilježena vrijednost, x_i je vrijednost obilježja u i -tom elementu ulaznog podatka.

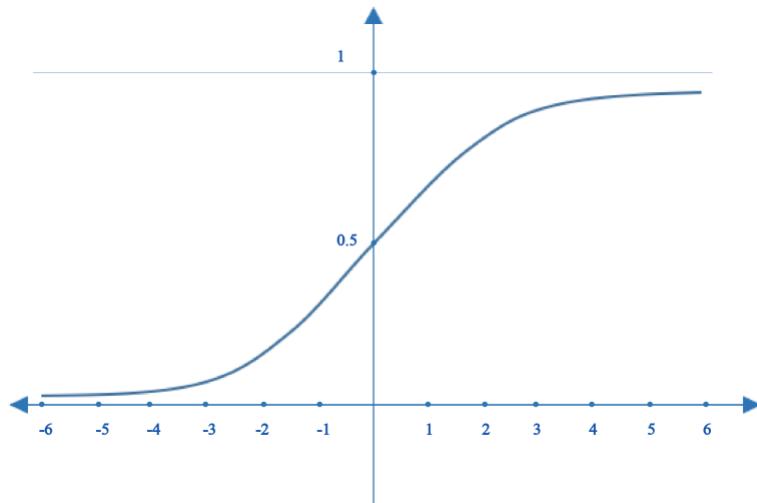
Prodot $P(y)$ i $P(x_i|y)$ predstavlja vjerojatnost da primjerak pripada razredu y . Funkcija argmax određuje najvišu vrijednost y , odnosno najvjerojatniji razred [118].

Logistička regresija (engl. *logistic regression, LR*) je binarni klasifikator koji uči obitelj funkcija h iz \mathbb{R}^d u intervalu $[0, 1]$, gdje je \mathbb{R}^d skup d-dimenzionalnih vektora iz skupa realnih brojeva \mathbb{R} . Za probleme klasifikacije funkcija $h(x)$ može se tumačiti kao vjerojatnost da x pripada određenom razredu. Funkcija h linearna je kombinacija težinskih faktora i atributa (vrijednosti varijabli), a rezultat je kombinacija sigmoidne funkcije $\phi_{sig}: \mathbb{R} \rightarrow [0,1]$, koja poprima vrijednost iz intervala $[0, 1]$ [121].

U logističkoj regresiji sigmoidna je funkcija logistička funkcija, definirana kao:

$$\phi_{sig}(x) = \frac{1}{1 + e^{-x}}, \quad (26)$$

gdje je ϕ_{sig} izlazna varijabla, x je ulazna varijabla, a e baza prirodnog logaritma. Naziv „sigmoidan” znači blagog „S-oblika” (Slika 9.).



Slika 9. Krivulja sigmoidne funkcije

Stoga je funkcija razreda (zbog pojednostavljenja koristi se homogena linearna funkcija L_d) definirana kako slijedi:

$$\hat{y} = \phi_{sig} x L_d = \{x \rightarrow \phi_{sig}(\langle w, x \rangle) : w \in \mathbb{R}^d\}. \quad (27)$$

gdje je \hat{y} funkcija razreda, ϕ_{sig} izlazna varijabla, x je ulazna varijabla, a w pripadajuća težina ulazne varijable.

Kada je $\langle w, x \rangle$ vrlo velik, tada je $\phi_{sig}(\langle w, x \rangle)$ blizu 1. Analogno, kada je $\langle w, x \rangle$ malen, tada je $\phi_{sig}(\langle w, x \rangle)$ blizu 0, odnosno kada je $|\langle w, x \rangle|$ blizu nule, imamo $\phi_{sig}(\langle w, x \rangle) \approx \frac{1}{2}$ [121].

LR upotrebljava metodu maksimalne izglednosti pri procjeni parametara i time se oslanja na aproksimacije većeg broja primjeraka, pa dobra prilagođenost modela proizlazi iz dovoljno velike količine podataka [122].

Multinomijalna logistička regresija (engl. *multinomial logistic regression, MLR*) generalizira logističku regresiju kako bi se podaci rasporedili u više razreda jer je logistička regresija binarni klasifikator. Kao i kod linearne regresije jedne varijable, preporučljivo je dodati postupke regularizacije u svrhu dobivanja stabilnijih procjena parametara za model logističke regresije. Postupcu regularizacije sažimaju parametre tako što „kažnjavaju“ vrijednosti parametara, efektivno ih umanjujući po apsolutnoj vrijednosti.

U MLR algoritmu upotrijebljenom u ovom radu koristi se sljedeća inačica:

Ako postoji k razreda za n primjeraka (x_i) s m atributa, matrica parametara B bit će matrica $m \times (k - 1)$. Vjerojatnost razreda P_j je vjerojatnost razreda j , s izuzetkom posljednjeg razreda:

$$P_j(x_i) = \frac{e^{x_i B_j}}{\sum_{j=1}^{(k-1)} e^{x_i B_j} + 1}. \quad (28)$$

Tada posljednji razred k ima vjerojatnost:

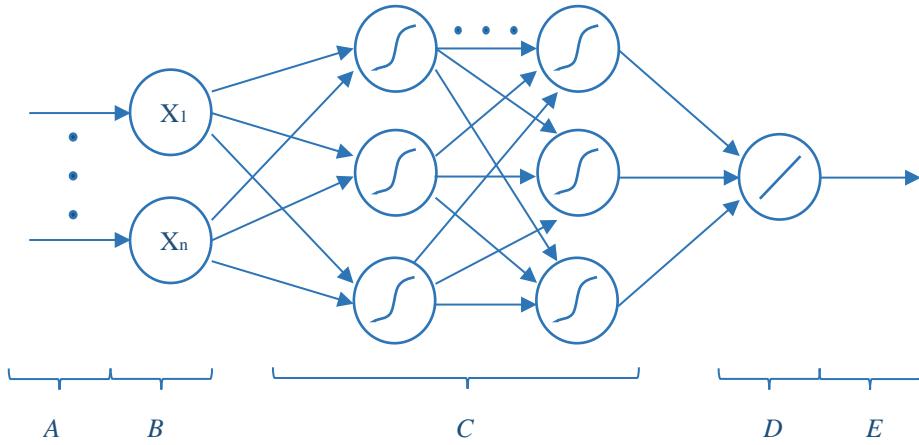
$$P_k(x_i) = 1 - \sum_{j=1}^{(k-1)} P_j(x_i) = \frac{1}{\sum_{j=1}^{(k-1)} e^{x_i B_j} + 1}. \quad (29)$$

Tada je negativna multinomijalna logaritamska vjerojatnost L s dodatnom regularizacijom R i matricom B :

$$L = - \sum_{i=1}^n \left\{ \sum_{j=1}^{(k-1)} Y_{ij} \ln(P_j(X_j)) + (1 - \sum_{j=1}^{(k-1)} Y_{ij}) \ln \left(1 - \sum_{j=1}^{(k-1)} P_j(X_i) \right) \right\} + R \cdot B. \quad (30)$$

Kako bi se pronašla matrica B za koju je N minimizirana, upotrebljava se quasi-Newtonova metoda za traženje optimalne vrijednosti $m \times (k - 1)$ varijabli. Prije upotrebe optimizacijskog postupka potrebno je preslikati matricu B u vektor $m \times (k - 1)$.

Višeslojni perceptron (engl. *multilayer perceptron, MLP*) je umjetna neuronska mreža (engl. *artificial neural network, ANN*) inspirirana strukturom bioloških neurona ljudskog mozga, koja se služi mrežom umjetnih neurona s najmanje tri sloja neurona [123].



A – ulazne varijable; B – ulazni sloj; C – jedan ili više skrivenih slojeva s nelinearnom aktivacijskom funkcijom; D – izlazni sloj s funkcijom identiteta, E – izlazna, ciljna varijabla

Slika 10. Arhitektura višeslojne perceptronske neuronske mreže

Izvor: Buhmann, MD: *Radial Basis Functions: Theory and Implementations*, 2009 [123].

U tipičnoj višeslojnoj perceptronskoj arhitekturi (Slika 10.) svaki neuron, osim onog u prvom sloju, ima nelinearnu aktivacijsku funkciju (npr. sigmoidna (logistička) funkcija). Prvi je sloj ulazni sloj (*B*) i sadrži onoliko neurona koliko ima atributa, ulaznih varijabli u podacima (primjercima) učenja. Slojevi su potpuno povezani, što znači da je svaki neuron u jednom sloju povezan sa svakim nevronom u sljedećem sloju. Tijekom učenja ulazni signali putuju kroz neuronske veze od ulaznog sloja, množeći se težinama veza (sinapsi) prije ulaska u sljedeći nevron. Izračunana se vrijednost zatim prosljeđuje aktivacijskoj funkciji. Za učenje neuronske mreže upotrebljava se algoritam s povratnom propagacijom pogreške (engl. *backpropagation*) koji, uzimajući u obzir gradijent funkcije gubitka, prilagođava faktore težine kako bi se postigla optimalna prediktivna svojstva. Višeslojne mreže imaju osim ulaznog (*B*) i izlaznog sloja (*D*) i jedan ili više (na slici su prikazana dva) skrivenih slojeva (engl. *hidden layers*) neurona (*C*). Korištena je prijenosna funkcija skrivenih slojeva sigmoidna (logistička) funkcija. Neuronska mreža uči kroz iterativni proces prilagođavanja sinaptičkih težina i pragova. Učenje je proces

kojim se slobodni parametri neuronske mreže prilagođavaju kroz kontinuirani proces učenja iz ulaznih podataka [124].

MLP mreže upotrebljavaju se za rješavanje širokog spektra problema (npr. raspoznavanje uzorka, analiza signala, analiza slike i govora, optimizacija, nelinearno upravljanje, prognoza vremenskih serija, itd.) gdje se nadzirano učenje odvija pomoću algoritma s povratnom propagacijom pogreške, generalizacijom algoritma najmanjih srednjih kvadrata (engl. *least mean squares algorithm, LMS*) u linearном perceptronu. Pogreška na izlazu neurona j u n -tom koraku jednaka je razlici između željenog d_j i dobivenog odziva y_j :

$$e_j(n) = d_j(n) - y_j(n), \quad (31)$$

Trenutna (u koraku n) kvadratna pogreška na izlazu mreže jednaka je:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n), \quad (32)$$

gdje je C skup izlaznih neurona mreže. Tada je prosječna kvadratna pogreška za sve primjerke jednaka:

$$E_{SR} = \frac{1}{2} \sum_{n=1}^N E(n), \quad (33)$$

gdje je N broj primjeraka u skupu za učenje, a E_{SR} srednja kvadratna pogreška i predstavlja ocjenu kvalitete učenja mreže.

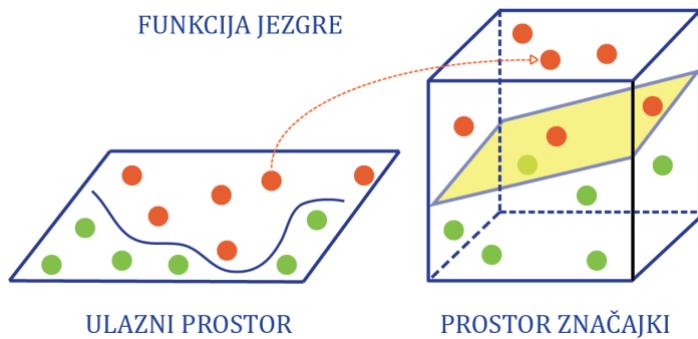
Cilj je učenja odrediti težine na vezama kako bi se smanjila srednja pogreška E_{SR} . Korekcija težine $\Delta w_{ji}(n)$ definira se delta pravilom, odnosno metodom gradijentnog spusta (engl. *gradient descent*):

$$\forall n, 1 \leq n \leq N; \Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)}, \quad (34)$$

gdje η parametar brzine učenja algoritma propagacije greške unatrag.

Strojevi potpornih vektora (engl. *support vector machines*, SVM) modeli su koji se oslanjaju na vektore potpore za dobivanje optimalnih granica između razreda. S obzirom na skup podataka $(x_1, y_1), \dots, (x_n, y_n)$, gdje je $x \in \mathbb{R}^d$ (d-dimenzionalni ulazni prostor) i $y \in \mathbb{R}$, u osnovi, SVM pokušava pronaći ravninu koja najbolje razdvaja dva razreda podataka, odnosno maksimizira marginu razdvajanja [125] [121].

Dakle, SVM klasifikator uči linearni prediktor koji odvaja n-dimenzionalni prostor u razrede. Što je margina šira, bolje su razdvojene, odnosno definirane razrede. U n-dimenzionalnom prostoru margina razdvajanja je n-dimenzionalna hiper-ravnina. U primjeru na skici (Slika 11.), nakon transformacije prostora, razredi se mogu odvojiti linearom marginom.



Slika 11. Transformacija pomoću jezgrene funkcije u strojevima potpornih vektora (SVM)

Weka u inicijalnim postavkama rabi normaliziranu polinomijalnu jezgrenu funkciju (kernel) [126]:

$$K(x, y) = \frac{\langle x, y \rangle}{\sqrt{\langle x, x \rangle \langle y, y \rangle}}, \quad (35)$$

U usporedbi s uobičajenim funkcijama jezgre, upotreba Pearsonovog univerzalnog kernela (Puk) ima nekoliko prednosti: ne zahtijeva odabir funkcija jezgre (što pojednostavljuje proces izgradnje modela), smanjuje vrijeme učenja te ima jaču moć preslikavanja pomoću koje se može ispravno nositi s velikim brojem problema mapiranja [126]. Univerzalna funkcija jezgre (Puk) postiže bolje rezultate te se (Pearson VII funkcija) upotrebljava u ovom istraživanju, dok normalizirani polinomijalni kernel ostaje kao referentna vektorska funkcija.

Osnovni oblik funkcije Pearson VII prikazan je sljedećim izrazom [126]:

$$f(x) = \frac{H}{\left[1 + \left(\frac{2(x - x_0)\sqrt{2^{\frac{1}{\omega}} - 1}}{\sigma} \right)^2 \right]^{\omega}}, \quad (36)$$

gdje je H visina vrha u središtu x_0 , a x predstavlja neovisnu varijablu. Parametri σ i ω kontroliraju poluširinu, koja se naziva i Pearsonovom širinom (engl. *Pearson width*), i repni faktor vrha. Glavni razlog upotrebe funkcije Pearson VII za usklađivanje (engl. *fit*) krivulja njezina je fleksibilnost za promjenu. Promjenom parametra ω , Pearson VII funkcija od Gaussovog oblika ($\omega = \infty$) se pomiče prema Lorentzian-ovom obliku ($\omega=1$), čime se pojednostavljuje gradnja SVM i odabir jezgrene funkcije, te smanjuje vrijeme učenja.

Stabla odluke J48 (engl. *decision trees*, *DT-J48*) neparametarska su metoda klasifikacije primjenjiva na širokom spektru problema, posebice pri rješavanju prediktivnih problema nadziranog učenja. Osnovna je prednost te metode razumljivost, jednostavnost i brzina učenja. Algoritam iz ulaznih varijabli gradi stablo, čime se daje mogućnost jednostavne analize i tumačenja predviđanja.

Svaki čvor u stablu dijeli ulaznu varijablu u „čvorove-djecu” (engl. *child nodes*) za svaku moguću vrijednost ulazne varijable u „roditeljskom čvoru” (engl. *parent node*). U skupu realnih brojeva uspoređuju se podjele kod svake vrijednosti koja se pojavljuje u toj varijabli, odnosno intervala vrijednosti, dok se kod diskretnih vrijednosti uspoređuju podjele svih mogućih kombinacija bez ponavljanja. Svaki list stabla predstavlja vrijednost ciljne (izlazne) varijable ako su zadane vrijednosti ulaznih varijabli (primjeraka) predstavljene putem od korijena do lista. Stablo raste učenjem iz podataka, tako da se podijeli izvorni skup podataka u podskupine na temelju testiranja vrijednosti varijabli. Proces podjele ponavlja se na svakoj izvedenoj podskupini rekurzivnim particioniranjem (engl. *recursive partitioning*). Particioniranje je dovršeno kada podskup određenog čvora ima sve iste vrijednosti izlazne varijable ili kada daljnje grananje više ne pridonosi kvaliteti rezultata. Moguće je da se, pomoću ulaznih atributa koji su na raspolaganju, ne postigne potpuna čistoća u listu [40].

Za odabir najbolje funkcije grananja postoje različiti kriteriji, poput entropije (H) ili informacijske dobiti (engl. *information gain*, IG) [127, 128], Gini kriterija izbora [127, 129],

omjera dobiti [130], Lopez de Mantrasove funkcije udaljenosti [131], mjere ortogonalnosti (engl. *orthogonality measure, ORT*) [132], te *chi₂* (CHAID)³⁰ metode [130,133,134].

Složenost izgrađenog stabla moguće je smanjiti podrezivanjem (engl. *tree pruning*) [40].

Za izgradnju stabla u ovom radu upotrijebljen je C4.5 algoritam s J48³¹ implementacijom gradnje stabala. C4.5 algoritam unaprijeđena je verzija algoritma ID3 koji počinje s izvornim skupom S kao korijenskim čvorom. U svakoj iteraciji algoritma ponavljaju se svi neiskorišteni atributi skupa S i izračunava entropija (H). Zatim se odabire atribut koji ima najmanju vrijednost entropije (H), odnosno najveću informacijsku dobit (IG):

$$IG(S, A) = H(S) - \sum_{t \in T} p(t)H(t) = H(S) - H(S|A), \quad (37)$$

gdje su: $H(S)$ – entropija skupa S ; T – podskup nastao podjelom skupa S po vrijednosti atributa A ; $p(t)$ – udio broja elemenata u t na broj elemenata u skupu S ; $H(t)$ – entropija podskupa t . Informacijska dobit IG mjera je razlike u entropiji prije i nakon podjele skupa S po atributu A .

Skup S zatim se razdijeli odabranim vrijednostima atributa A da bi se proizveli podskupovi podataka u pretpostavljenom binarnom prostoru. Neki skup S sadrži pozitivne i negativne primjere pa je entropija:

$$H(S) = -p_+ \log_2 p_+ - p_- \log_2 p_-, \quad (38)$$

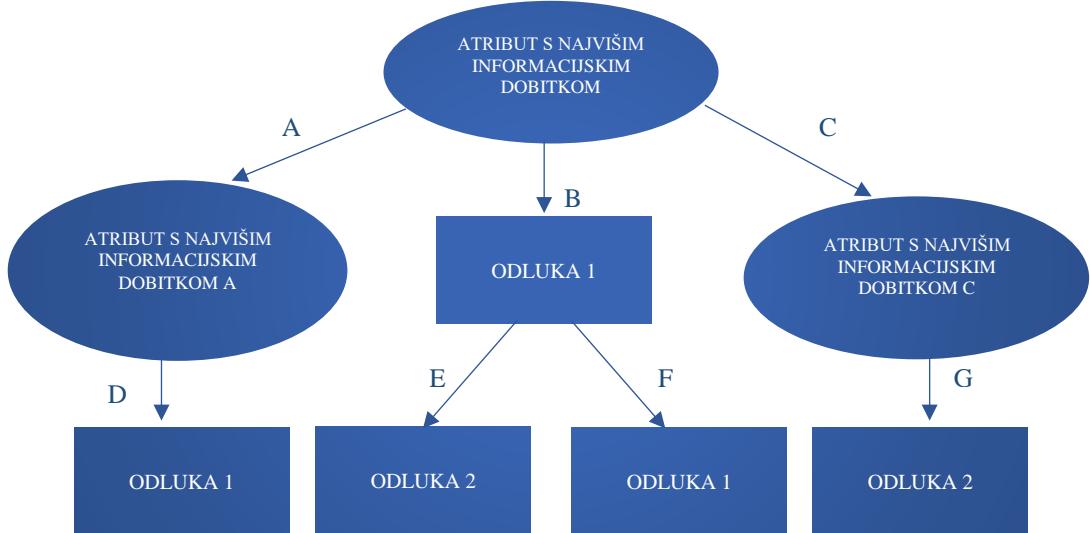
gdje su: p_+ – udio pozitivnih primjera u skupu S i p_- – udio negativnih primjera u skupu S . Entropija je minimalni broj bitova potrebnih za kodiranje proizvoljnih članova skupa S te u slučaju prelaska iz binarnog na c razreda iznosi:

$$H(S) = \sum_{i=1}^c -p_i \log_2 p_i. \quad (39)$$

³⁰Prednost je CHAID metode u tome što je izlaz vrlo vizualan i jednostavan za interpretaciju. Budući da prema zadanim postavkama upotrebljava višestruke podjele, za učinkovito funkcioniranje treba prilično velike veličine primjeraka.

³¹J48 otvorena je Java implementacija C4.5 algoritma u Weka sučelju.

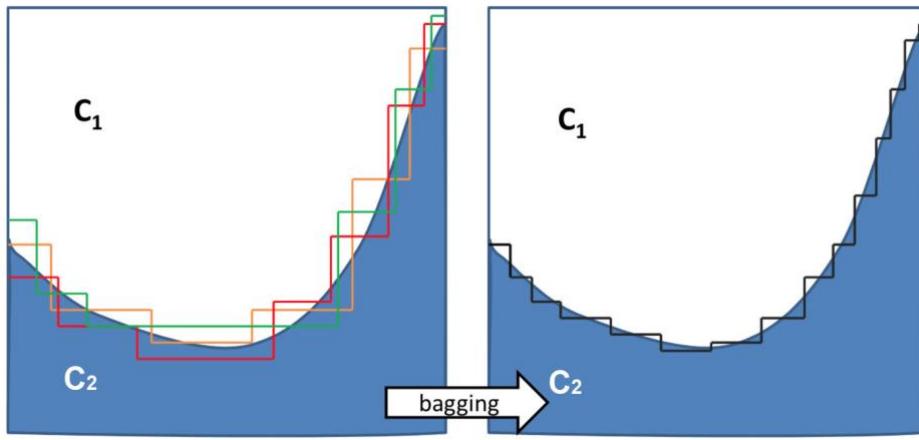
Algoritam se ponavlja na svakom podskupu, uzimajući u obzir samo preostale atribute, dakle one koji još nisu odabrani za podjelu. Proces se rekursivno izvodi sve dok skup u danom podstablu nije homogen (sadrži objekte koji pripadaju istoj kategoriji, razredu ili klasi) (Slika 12.) [128].



Slika 12. Stablo potencijalnih ID3 generiranih odluka s atributima raspoređenima u čvorove i vrijednosti atributa predstavljenih granama

Metoda C4.5, za razliku od ID3, obrađuje kontinuirane i diskretne varijable, u mogućnosti je procesirati nepotpune podatke, rješava problem prenaučenosti modela (engl. *overfitting*) tehnikom podrezivanja stabla [128].

Leo Breiman predlaže slučajan odabir atributa (engl. *bagging, bootstrap aggregating*) za unaprjeđenje klasifikacije tako da se klasifikacijska stabla grade iz nasumično uzorkovanih skupova podataka za učenje (Slika 13.). Pri tome nasumičan može biti odabir atributa i primjeraka koje se upotrebljavaju za izgradnju pojedinačnog stabla odluke. Uzorkovanje iz izvornog skupa podataka za učenje određuje podatak za učenje u pojedinom koraku, pri čemu se pojedini primjerak može ponoviti više puta, dok drugog primjerka možda uopće nema. Primjeri koje se više puta pojavljuju tretiraju se kao primjeri s većim težinama, dok se primjeri kojih više nema tretiraju kao one s manjim težinama, jer se ne uzimaju u obzir prilikom izgradnje stabla. Svaki dobiveni osnovni model je stablo i ima isti značaj u glasovanju za odluku o rezultatu klasifikacije [135, 136].

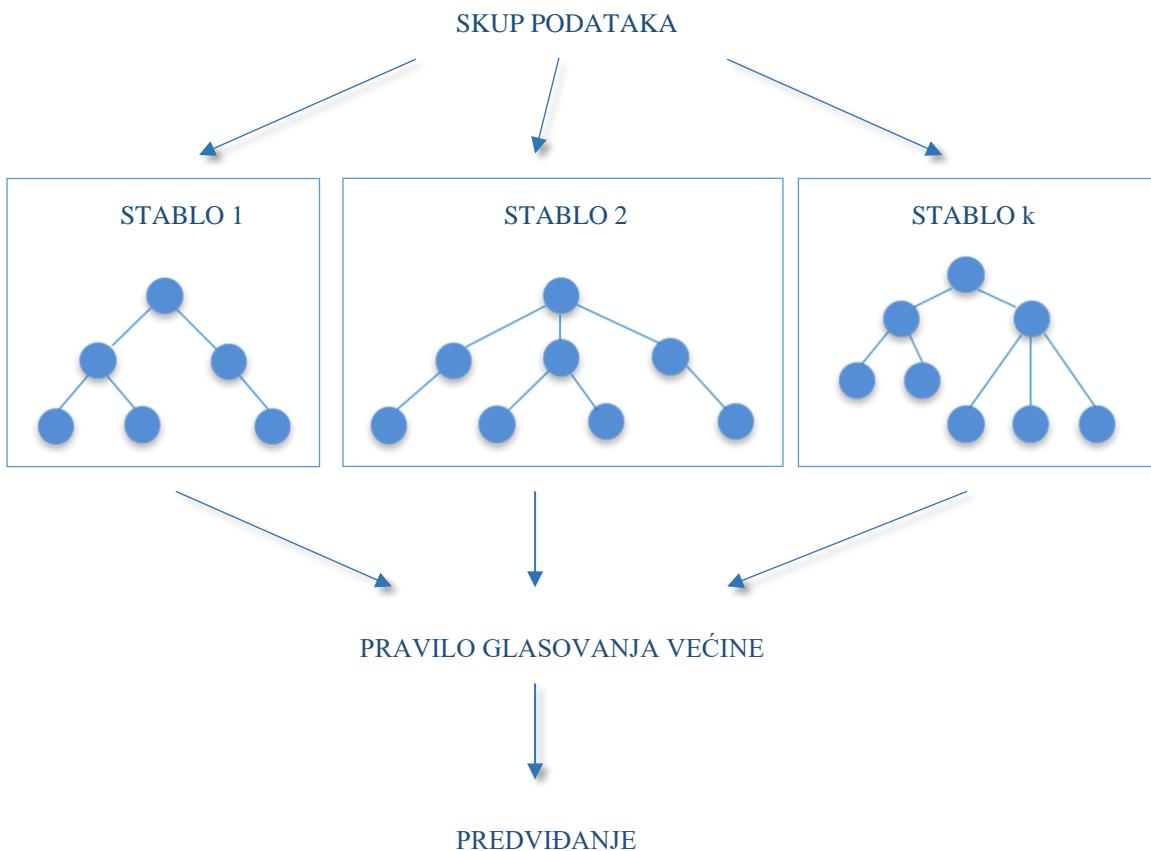


Slika 13. Primjer određivanja dva razreda C1 i C2 u slučaju primjene većeg broja stabala odlučivanja (lijevo) te ansabla dobivenim „baggingom” (desno)

Izvor: Šmuc, T: *Strojno učenje: B&V; Ansambls*, 2011. [137]

Nasumične šume (engl. *random forests*, *RF*) temelje se na izmjenjenoj verziji ansambla „bagging” sa slučajnim odabirom atributa iz cijelog skupa atributa, te primjerke iz cijelog skupa primjeraka [138]. RF je klasifikator koji se sastoji od skupa stabala odlučivanja, gdje se svako stablo konstruira primjenom algoritma za gradnju stabla na skupu za učenje S i dodatnim slučajnim vektorom θ , gdje je θ neovisan i jednako razdijeljen (engl. *independent and identically distributed*) iz skupa primjeraka. Algoritam za izgradnju nasumičnih šuma gradi veći broj različitih stabala odlučivanja koja glasuju o rezultatu klasifikacije prema pravilu većine (engl. *majority vote*), kao što je prikazano na dijagramu toka (Slika 14.), ili pronalaze srednju vrijednost kod regresije. Iz skupa za učenje uzorkovanjem dobiva se novi uzorak, koji je po veličini jednak originalnom [40, 121, 139].

Nasumična šuma je klasifikator koji se sastoji od zbirke strukturiranih klasifikacijskih stabala $\{h(x, \Theta_k), k = 1, \dots\}$, gdje su $\{\Theta_k\}$ neovisni identično raspodijeljeni slučajni vektori i svako stablo glasa za najpopularniji razred za klasifikaciju ulaznog primjerka x [140].



Slika 14. Pojednostavljen prikaz predviđanja algoritma nasumičnih šuma

Za zadalu zbirku klasifikatora $h_1(x), h_2(x), \dots, h_k(x)$ i sa skupom učenja slučajno izvučenim iz raspodjele slučajnog vektora Y, X marginalna funkcija definira se kao:

$$mg(\mathbf{X}, Y) = av_k I(h_k(\mathbf{X}) = Y) - \max_{j \neq y} av_k I(h_k(\mathbf{X}) = j), \quad (40)$$

gdje je $I(h_k(\mathbf{X}))$ indikatorska funkcija. Margina (mg) mjeri stupanj do kojeg prosječan broj glasova za X, Y za ispravan razred premašuje prosječni glas za bilo koji drugi razred. Što je veća margina, to je bolje razvrstavanje. Greška generalizacije daje se pomoću:

$$PE^* = P_{\mathbf{X}, Y}(mg(\mathbf{X}, Y) < 0), \quad (41)$$

gdje indeksne vrijednosti \mathbf{X}, Y pokazuju da je vjerojatnost dobivena iz \mathbf{X}, Y prostora.

Za veliki broj stabala, iz zakona velikih brojeva³² (engl. *strong law of large numbers*) i strukture stabla, slijedi da s povećanjem broja stabala gotovo sigurno sve sekvence Θ_1, \dots, PE^* konvergiraju u:

$$P_{X,Y}(P_\Theta(h(\mathbf{X}, \Theta) = Y) - \max_{j \neq Y} P_\Theta(h(\mathbf{X}, \Theta) = j) < 0). \quad (42)$$

To objašnjava zašto se nasumične šume s dodavanjem stabala ne prilagođavaju vrijednostima podataka (engl. *overfitting*), već proizvode ograničavajuću vrijednost pogreške generalizacije [140].

Pri svakom uzorkovanju jedan dio izvornih podataka, koji se nazivaju skup OOB (engl. *out-of-bag*), ostaje neiskorišten. Pomoću OOB provodi se unakrsno vrednovanje svakog stabla. Takvo unakrsno vrednovanje provodi se paralelno s izgradnjom stabla i dobra je procjena pogreške te čvrstoće i korelacije nasumične šume [139]. Time RF tijekom uzorkovanja i izgradnje stabala prolazi kroz dvostruku provjeru slučajnom permutacijom vrijednosti atributa iz OOB skupa kako bi se utvrdili značajni atributi te k-strukom tehnikom unakrsne validacije. Važna je osobina Breimanove metode određivanje značaja atributa. Značaj se određuje analizom atributa obzirom na predviđanje točnog razvrstavanja metodom slučajnih stabala. Algoritam najprije izračunava točan broj, broj ispravne klasifikacije pomoću podataka u testnom skupu. Vrijednosti se atributa zatim slučajno permutiraju u primjerima. Novi se skup podataka zatim testira na ispravnu klasifikaciju. Tada se značaj atributa računa prema izrazu [141]:

$$\text{značaj atributa}_{\text{variable } (m)} = \frac{\text{netaknut broj} - \text{broj varijabli}_m}{\text{broj stabala odlučivanja}}, \quad (43)$$

gdje je *broj varijabli_m* broj glasova za ispravan razred u promjenjivim-m-permutiranim podacima OOB, a *netaknut broj* broj glasova za točan razred u netaknutim podacima OOB.

³²Pretpostavimo da je prvi moment $\mathbb{E}|X$ od X konačan. Tada \bar{X}_n gotovo sigurno konvergira u $\mathbb{E}X$, tako da $\mathbb{P}(\lim_{n \rightarrow \infty} \bar{X}_n = \mathbb{E}X) = 1$.

3.2.2. Metode regresijske analize

Odabir algoritama predviđanja prati metode opisane kod klasifikacije:

- linearna regresija,
- višeslojni perceptron umjetne neuronske mreže,
- strojevi potpornih vektora i
- nasumične šume,

s razlikom što se naivni Bayes, logistička regresija i J48 stabla ne upotrebljavaju kao regresijska metoda, pa su izuzete. U nastavku je, stoga, dodatno uvedena linearna regresija kao uobičajeni regresijski algoritam.

Linearna regresija (engl. *linear regression or generalized linear model, GLM*) metoda je numeričkog predviđanja koja djeluje tako što procjenjuje koeficijente za pravac ili ravninu koji najbolje odgovaraju podacima za učenje. To je vrlo jednostavan regresijski algoritam, brz za izgradnju, a može postići dobre rezultate predviđanja, posebno u slučaju kada je izlazna varijabla linearna kombinacija ulaznih varijabli. Ukoliko podaci pokazuju da nemaju linearnu ovisnost, utoliko će postupak pronaći najbolji linearni pravac tako da se kao najbolji rezultat tumači najmanja srednja kvadratna pogreška (engl. *root mean square error, RMSE*). Linearni modeli, unatoč tome što modeliraju jednostavne linearnosti, služe kao blokovi ili polazne točke za složenije metode učenja. U Weki se algoritam linearne regresije služi Akaike kriterijem odabira najboljeg modela. Akaike informacijski kriterij (engl. *Akaike information criterion, AIC*) procjenitelj je relativne kvalitete statističkih modela za određeni skup podataka. S obzirom na skup modela za podatke, AIC procjenjuje kvalitetu svakog modela u odnosu na svaki drugi model. Prema tome, AIC osigurava sredstva za odabir modela, a izračunava se prema izrazu:

$$AIC_{rezultat} = -LL + K, \quad (44)$$

gdje je K broj parametara, a LL logaritam vjerojatnosti događaja s negativnim predznakom [40].

Strojevi potpornih vektora koriste se i kao metoda regresije. Regresija strojeva potpornih vektora koristi iste principe kao i SVM za klasifikaciju, no s obzirom na to da je izlaz numerička vrijednost granica tolerancije postavlja se u približavanju SVM-u [142]. Algoritam

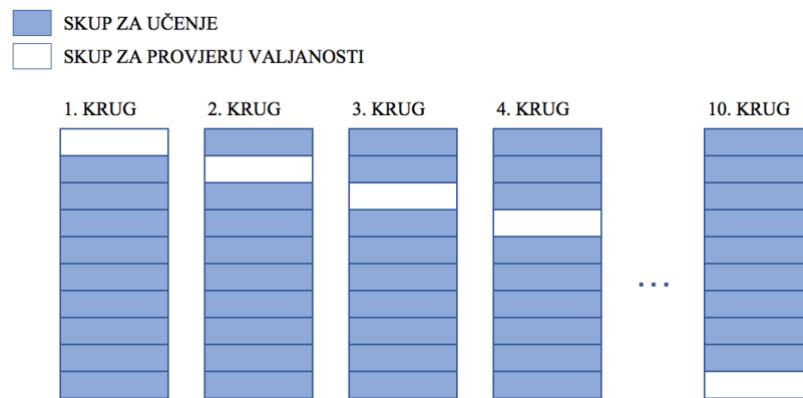
regresije je složeniji, međutim, glavna ideja je uvijek ista: minimizirati pogrešku, individualizirati hiper-ravninu koja maksimizira marginu, vodeći računa da se dio pogreške tolerira. SVM koji se upotrebljava u Weki za potrebe numeričkog predviđanja označuju se skraćenicom se SMOreg [142, 143].

3.3. Metodologija vrednovanja rezultata rudarenja podataka

Postoje različite metode koje se rabe za vrednovanje učinkovitosti algoritama prilikom strojnog učenja. Kako bi se ocijenilo odabrane algoritme, najprije je bilježeno vrijeme potrebno za njihovo učenje, odnosno vrijeme izvršenja algoritama implementiranih na računalu s instaliranim Weka paketom i ugrađenim procesorom od 1,4 GHz i 4 GB 1600 Mhz DDR3 radne memorije.

Za procjenu naučenih metoda u svim scenarijima klasifikacije i regresije, upotrijebljena je tehnika deseterostrukе unakrsne provjere (validacije) (engl. *10-fold cross validation technique*) [116] jer prilikom učenja algoritama strojnog učenja (osim višeslojnog perceptronu) nije bilo potrebno određivati vrijednosti parametara.

Standardno, tehnika deseterostrukе unakrsne provjere dijeli izvorni skup podataka na 10 podskupova i sustavno ih rotira. Za učenje modela uzme 9, dok preostale podskupove upotrebljava za provjeru (validaciju).



Slika 15. Prikaz deseterostrukе tehnike unakrsne validacije

Svaki od 10 podskupova programski paket Weka odredi slučajno te sadrži otprilike iste omjere oznaka razreda (distribuciju razreda u originalnim podacima), a sustavno se primjenjuju za skupinu učenja i testiranja modela (Slika 15.). Slijedi kratak pregled upotrijebljenih mjera ocjenjivanja učinkovitosti algoritama.

Mjere učinkovitosti modeliranja klasifikacijskim algoritmima

Točnost klasifikacije (engl. *accuracy*) je udio točno klasificiranih primjeraka u skupu svih primjeraka.

Stvarna pozitivna stopa (engl. *true positive rate*, *TPR*) naziva se još i osjetljivost (engl. *sensitivity*), odziv (engl. *recall*) i vjerojatnost detekcije (engl. *probability of detection*), te predstavlja pozitivno stanje, odnosno jednaka je omjeru broja točno klasificiranih slučajeva (engl. *true positive*, *TP*) i ukupnog broja pozitivnih vrijednosti (*P*):

$$TPR = \frac{TP}{P}. \quad (45)$$

Broj ukupnih pozitivnih vrijednosti (*P*) jednak je zbroju točno klasificiranih i pogrešno negativnih vrijednosti (engl. *false negative*, *FN*):

$$P = TP + FN. \quad (46)$$

Netočna pozitivna stopa (engl. *false positive rate*, *FPR*), koja se naziva i ispadanje (engl. *fall-out*), predstavlja negativno stanje kada je ishod pogrešno predviđen, a jednaka je omjeru netočno pozitivnog broja klasificiranih slučajeva (engl. *false positive*, *FP*) i ukupnog broja negativnih vrijednosti (*N*):

$$FPR = \frac{FP}{N}. \quad (47)$$

Ukupan broj negativnih vrijednosti (*N*) jednak je zbroju netočno pozitivnih klasifikacija (*FP*) i točno klasificiranih vrijednosti kao negativnih (engl. *true negatives*, *TN*):

$$N = FP + TN. \quad (48)$$

Osnovne mjere ocjenjivanja uobičajeno se prikazuju u matrici zabune (engl. *confusion matrix*). Matrica zabune se upotrebljava za opisivanje učinkovitosti klasifikatora – kada je poznata stvarna vrijednost podatka koji se procjenjuje. Rezultati se često prikazuju u obliku

dvodimenzionalne matrice zabune (Tablica 3.). Pozitivna / negativna oznaka odnose se na predviđeni ishod eksperimenta, dok se istina / neistina odnose na stvarni ishod. Pozitivni rezultati odgovaraju brojevima na glavnoj dijagonali, a negativni su rezultati u nedijagonalnim čelijama, i imaju po mogućnosti niske, idealno, nulte vrijednosti.

Tablica 3. Standardna matrica zabune

ISHOD	STVARNI (ISTINA / NEISTINA)	
	ISTINITO POZITIVAN (TP)	NEISTINITO POZITIVAN (FP)
	NEISTINITO NEGATIVAN (FN)	ISTINITO NEGATIVAN (TN)

Preciznost (engl. *precision or positive predictive value, PPV*) udio je točno klasificiranih slučajeva među dohvaćenim slučajevima, dok je odziv u Weka programskom paketu jednak stvarnoj pozitivnoj stopi³³. I preciznost i odziv računaju se iz matrice zabune ishoda kako slijedi:

$$PPV = \frac{TP}{TP + FP}, \quad (49)$$

$$TPR = \frac{TP}{TP + FN}. \quad (50)$$

Mjera F_1 (engl. *F1 score*)

Yutaka Sasaki definira TF mjeru kao harmonijsku sredinu preciznosti (PPV) i stvarne pozitivne stope (TPR) (odziva), a izračunava se [144]:

$$TF = \frac{2 \times PPV \times TPR}{PPV + TPR}. \quad (51)$$

Harmonijska sredina intuitivnija je od aritmetičke sredine kada se izračunava srednja vrijednost omjera. Mjera F_1 se definira kao poseban slučaj opće F_β mjere koja glasi [145]:

³³Weka sučelje rabi dva termina (*TPR* i *recall*) u tablici učinka klasifikacije, unatoč tome što su to jednaki kriteriji. U daljem tekstu i prezentiranju rezultata klasifikacije, zbog jasnoće i nedvosmislenosti, kriterij odziva neće se više upotrebljavati, a pripadajući rezultati bit će prikazani kao TPR.

$$F_{\beta} = \frac{(\beta^2 + 1)PPV \times TPR}{\beta^2 PPV + TPR} \quad \text{za } (0 \leq \beta \leq \infty), \quad (52)$$

gdje β parametar kontrolira ravnotežu između PPV i TPR . Kada je $\beta = 1$, $F_{\beta}=F_1$ i odgovara harmonijskoj sredini PPV i TPR . Ako je $\beta > 1$, F_{β} postaje osjetljiviji na TPR , a ako je $\beta < 1$, postaje osjetljiviji na preciznost, npr. $F_0 = PPV$.

Uobičajeno upotrebljavana oznaka F_1 znači $F_{\beta} = 1$ [144].

Mjera F_1 , PPV i TPR standardne su mjere za vrednovanje algoritama strojnog učenja koje zanemaruju klasifikaciju negativnih primjera, a odražavaju značaj pozitivnih primjera u klasifikaciji podataka [146].

Mathewsov koeficijent korelacije (MCC) upotrebljava se kao mjera kvalitete binarnih klasifikacija. MCC uzima u obzir stvarne i lažno pozitivne i negativne rezultate i općenito se smatra uravnoteženom mjerom koja se može upotrebljavati čak i ako su razredi različite brojnosti (engl. *unbalanced*). MCC je koeficijent korelacije između promatranih i predviđenih binarnih klasifikacija i vraća vrijednost između -1 i 1 . Koeficijent 1 označava savršeno predviđanje, 0 prosječno slučajno predviđanje, a -1 inverzno predviđanje [147]. MCC se može izračunati izravno iz matrice zabune pomoću formule:

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (53)$$

Krivulja radnog svojstva prijemnika (engl. *receiver operating characteristics, ROC*) oblikuje se bilježenjem stvarne pozitivne stope (engl. *true positive rate*) prema brzini neistinite pozitivne stope (engl. *false positive rate*) pri različitim postavkama praga (engl. *threshold setting*). Područje ispod ROC krivulje obično se upotrebljava za usporedbu rezultata klasifikacije i označava se kao AUROC (engl. *area under receiver operating curve*). Slično tome, površina ispod krivulje preciznosti odziva označena je kao AUPRC (engl. *area under precision-recall curve*) [148].

Za izračunavanje ukupnih rezultata, *ponderirani prosjek* (engl. *weighted average*, WA) izračunava se kao omjer zbroja svih stopa mjere po razredu pomnoženim s brojem slučajeva prema razvrstanim razredima i ukupnim brojem primjeraka:

$$WA = \frac{\sum_{razred=1}^n \text{mjera} * \text{broj slučajeva prema razvrstanim razredima}}{\text{ukupan broj primjeraka}}, \quad (54)$$

gdje je n - ukupan broj razreda.

Srednja kvadratna pogreška (RMSE) ili standardna devijacija mjera je disperzije pojedinačnih vrijednosti \hat{y}_i od srednje vrijednosti \bar{y} . RMSE rezultate klasifikacije računa po relaciji:

$$RMSE = \sqrt{\frac{(\hat{y}_1 - y_1)^2 + \dots + (\hat{y}_n - y_n)^2}{n}}, \quad (55)$$

gdje je \hat{y} predviđeni razred, y stvarni razred i n - ukupan broj razreda.

Budući da se pogreške kvadriraju prije usrednjavanja, RMSE daje relativno veliki značaj velikim pogreškama. To znači da je RMSE najkorisniji kada su velike pogreške posebno nepoželjne.

Mjere učinkovitosti modeliranja regresijskim algoritmima

Koeficijent korelacije (engl. *correlation coefficient*, C_c) mjeri statističku korelaciju između svih predviđenih numeričkih vrijednosti $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n$ u odnosu na stvarne vrijednosti y_1, y_2, \dots, y_n . Koeficijent korelacije kreće se od 1, za savršeno korelirane rezultate, do 0, kada nema korelacije, te -1, kada su rezultati savršeno negativno korelirani. Naravno, negativne vrijednosti ne smiju se pojaviti u slučaju razumnih metoda predviđanja. Korelacija se neznatno razlikuje od ostalih mjeri jer je u ovisnosti o skali u sljedećem smislu: ako se uzme određeni skup predviđanja, pogreška ostaje nepromijenjena ako se sva predviđanja množe s konstantnim faktorom, a stvarne vrijednosti ostaju nepromijenjene. Taj se faktor pojavljuje u svakom izrazu $S_{\hat{y}y}$ u brojniku i u svakom izrazu $S_{\hat{y}}$ u nazivniku, čime se poništava. Koeficijent korelacije izračunava se prema sljedećem izrazu:

$$C_c = \frac{S_{\hat{y}y}}{\sqrt{S_{\hat{y}}S_y}}, \quad (56)$$

gdje su

$$S_{\hat{y}y} = \frac{\sum(\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{n - 1}, \quad (57)$$

$$S_{\hat{y}} = \frac{\sum(\hat{y}_i - \bar{\hat{y}})}{n - 1}, \quad (58)$$

$$S_y = \frac{\sum(y_i - \bar{y})}{n - 1}, \quad (59)$$

i gdje \bar{y} predstavlja srednju vrijednost izlazne varijable, a $\bar{\hat{y}}$ srednju predviđenu vrijednost.

Srednja kvadratna pogreška (RMSE) ili standardna devijacija izračunava se istovjetno kao kod klasifikacije.

Srednja apsolutna pogreška (engl. *mean absolute error*, MAE) je alternativa koja koristi prosječne veličine pojedinih grešaka bez uzimanja u obzir njihovog predznaka, a izračunava se kako slijedi:

$$MAE = \frac{|\hat{y}_1 - y_1| + \dots + |\hat{y}_n - y_n|}{n}. \quad (60)$$

Relativna apsolutna pogreška kvadrata (engl. *relative absolute error*, RAE), koristi se u slučajevima kada su važne relativne vrijednosti, a ne apsolutne pogreške:

$$RAE = \frac{|\hat{y}_1 - y_1| + \dots + |\hat{y}_n - y_n|}{|\bar{y} - y_1| + \dots + |y - y_n|}. \quad (61)$$

Korijenska kvadratna pogreška kvadrata (engl. *root relative squared error, RRSE*) izračunava se na sljedeći način:

$$RRSE = \sqrt{\frac{(\hat{y}_1 - y_1)^2 + \dots + (\hat{y}_n - y_n)^2}{(\bar{y} - y_1) + \dots + (\bar{y} - y_n)}}. \quad (62)$$

Vizualizacija rezultata je alat koji omogućuje pregled regresijskog modeliranja odabirom stvarnih vrijednosti y_1, y_2, \dots, y_n na x osi, te predviđenih vrijednosti $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n$ na y osi.

4. PRIJEDLOG METODE NADZORA I PREDVIĐANJA OPERACIJSKIH PARAMETARA

4.1. Prikupljanje i priprema podataka

Metode strojnog učenja upotrebljavane u ovom istraživanju temelje se na podacima, odnosno metode iz eksperimentalnih podataka uče i vrednuju rezultate predviđanja. U ovome se radu za učenje i testiranje upotrebljavaju podaci s broda za prijevoz ukaplijenoga naftnog plina sličnog nedavnoj seriji južnokorejskog brodograditelja kapaciteta 54 340 DWT, duljine 225 m i širine 37 m. Vrsta i veličina broda odabrana je na temelju činjenice da je njegova veličina sukladna prosječnoj veličini brodova koji se uobičajeno koriste na plovidbi oceanima i da se rezultati mogu primijeniti na bilo kojem brodu sličnih karakteristika. Glavni je motor dvotaktni brodski dizelski motor s jednim turbopunjačem. Najveća je izlazna snaga 12 400 kW s 15% margine mora i 10% margine obraslosti trupa i teških vremenskih uvjeta, a kako bi se zadovoljila zajamčena brzina od 16,8 čvorova po projektnim podacima. Specifikacija motora navedena je u Tablici 4.:

Tablica 4. Specifikacija ugrađenog glavnog pogonskog stroja

MODEL MOTORA:	HYUNDAI-MAN B&W 6G60ME-C9.2		
TIP MOTORA:	ELEKTRONIČKI UPRAVLJAN, DVOTAKTNI, DIREKTNO PREKRETNI, S KRIŽNOM GLAVOM DIESEL MOTOR S KONSTANTNIM TLAKOM TURBO PUNJENJA, SUKLADAN IMO TIER II ZAHTJEVIMA		
PROVRT CILINDRA:	600	mm	
DULJINA KORAKA:	2790	mm	
BROJ CILINDARA:	6		
MCR	IZLAZNA SNAGA	12400	kW
	BROJ OKRETAJA	92,2	min ⁻¹
	PROSJEČNI EF. TLAK	17,0	kg/cm ²
	P _{MAX}	185	kg/cm ²
	PROSJEČNA BRZINA STAPA	8,6	m/s
	POTROŠNJA GORIVA (42700KJ/KG):	161,3	g/kWh
NCR	IZLAZNA SNAGA	11160	kW
	BROJ OKRETAJA	89	min ⁻¹
	PROSJEČNI EF. TLAK	15,9	kg/cm ²
TURBOPUHALO, MODEL I TIP:		HYUNDAI-ABB A175 X 1 SET	

Četverokrilni propulzijski vijak s fiksnim korakom (Tablica 5.) izravno je spojen na glavni motor preko osovinskog voda.

Tablica 5. Specifikacija brodskog vijka

MODEL I TIP:	HHI KEYLESS, FPP	
PROMJER:	7400	mm
BROJ LOPATICA:	4	
PROSJEČAN USPON:	5971,06	mm

U ovome se radu upotrebljavaju četiri skupine podataka grupirane prema izvoru:

1. senzorski podaci preuzeti s integriranog sustava nadzora i upravljanja K-Chief 600³⁴ kao primarni izvor,
2. podaci preuzeti s brodskog ECDIS³⁵ sustava kao sekundarni izvor
3. podaci iz brodskih podnevnih izvješća³⁶ i
4. dostupni meteorološki i oceanografski podaci sukladni geografskom položaju i vremenu plovidbe predmetnog broda.

Podaci su prikupljeni u vremenskom razdoblju od ukupno 12 mjeseci, međutim, snimanja nisu trajala kontinuirano i senzorski podaci za vrijeme boravka u lukama, na sidru ili tijekom plutanja nisu obrađivani. Konačno vrijeme snimanja 95 senzorskih izvora sustava nadzora i upravljanja brodskim postrojenjem (Prilog A, Tablica 31.) trajalo je ukupno 5042 sata na putovanjima između koordinata (Tablica 6.), te vizualiziranih na zemljopisnim kartama u Prilogu B. (Slika 31., Slika 32., Slika 33., Slika 34., Slika 35., Slika 36., Slika 37.). Eksperimenti su provedeni pri zadanim okretnim brzinama motora od 89 min⁻¹ (normalna kontinuirana brzina) (engl. *normal continuous rating, NCR*), 85 min⁻¹ (traženo podešenje tijekom plovidbe od strane čartera) i 75 min⁻¹ (ekonomska brzina iznad tlaka uključivanja

³⁴K-Chief 600, proizvođača Kongsberg, brodski je automatizacijski sustav modularno dizajniran te omogućuje konfiguraciju od alarma do visoko integriranih sustava nadzora uz naprednu kontrolu procesa i upravljanja energijom. Sustav objedinjuje nadzor nad senzorima i sklopnicima, energetskim postrojenjem (engl. power management system), sustavom za ukapljivanje tereta, te nadzor nad operacijom bunkera i balastiranja broda.

³⁵ECDIS (engl. electronic chart display and information system) geografski je informacijski sustav koji se kao zamjena ili dodatak tradicionalnim papirnatim kartama upotrebljava pri nautičkoj plovidbi u skladu s propisima Međunarodne pomorske organizacije. Sustav prikazuje informacije iz elektroničkih navigacijskih karata (engl. electronic navigational charts, ENC) ili digitalnih navigacijskih karata (engl. digital navigational charts, DNC) i integrira informacije o položaju, kretanju i brzini preko povezanih sustava i uređaja.

³⁶Podnevna izvješća s brodova dio su dnevne rutine gdje se relevantni podaci o brzini broda, zemljopisnoj poziciji, potrošnji goriva, vremenskim uvjetima i slično šalju u ured. Podaci se unose najčešće ručno kao prosječne vrijednosti unutar protekla 24 sata, odnosno od prethodnog dana u podne do dana u kojem se šalje izvješće u podne. Pri prolasku broda kroz različite vremenske zone broj sati može biti 25 ili 23, ovisno o smjeru kretanja broda. Postoje dvije vrste podataka: oni koji se mijere mjernim instrumentima (temperature, tlakovi, brzine i sl.) i unose se kao trenutne, prosječne ili ukupne vrijednosti te oni koji su opservacijski i najčešće sadrže prosječne vrijednosti u tijeku promatranog vremenskog razdoblja (visina vala, stanje mora, i sl.). Kod opservacijskih unosa moguća je pogreška jer ovise o subjektivnoj procjeni i iskustvu promatrača.

pomoćnih puhalo), pri različitim opterećenjima glavnog propulzijskog stroja, što je rezultiralo s približno 54 milijuna preuzetih podataka iz primarnog izvora. Kako bi se osigurala ponovljivost i usporedivost mjerena, temperatura rashladne vode glavnog propulzijskog stroja automatski je kontrolirana pomoću regulatora temperature na 89°C, dok je temperatura ulja za podmazivanje automatski kontrolirana pomoću temperaturnog regulatora između 45 i 47° C. S obzirom na to da je pohranjene podatke iz K-Chief 600 baze moguće izvesti jedino u .pdf formatu zapisa u obliku dijagrama, u prvom redu, zbog broja podataka, bilo je neophodno razviti programski alat koji bi podatke prebacivao iz grafičkog u numerički oblik. Program za ovu namjenu napisan je u programskome jeziku Java s elementima C++ te se služi alatima s otvorenim pristupom iz knjižnice „openCV” (engl. *open source computer vision library*): Google guava, Apache PDFbox, Apache poi i ControlsFX. Za pokretanje je upotrijebljen JDK (engl. *Java SE development kit*).

Pri razvoju programskog alata najprije je definiran izlaz i tijek podataka, potom razvijena logika transformacije, da bi se napisao postupak pripreme podataka:

1. Program pretvara svaku pojedinu sliku iz .pdf formata (svaka stranica sadrži tri grafa) u grafove.
2. Svaki pojedinačni graf prikazuje se korisniku, potom korisnik ručno unosi granične vrijednosti x i y osi. Taj je korak neophodan kako bi se zadržala kontrola nad očitavanjem grafova.
3. Grafovi se potom pretvaraju u crno-bijeli nekomprimirani .bmp format.
4. Određuje se granica tolerancije za svjetlige tonove, čime se filtrira graf i ostaju samo linije grafa.
5. Izvršava se dilatacija i erozija linije da bi se pronašle lokalne minimalne i maksimalne točke.
6. Dobivena numerička očitanja točaka šalju se u tablični preglednik.
7. Na završetku se pohranjuje tablični dokument s nazivom koji određuje korisnik.

Pohranjeni numerički podaci uspoređeni su s podacima iz K-Chief 600 sustava te su podudarni s prosječnom pogreškom od 0,15%, što je prihvatljivo za potrebe ovog istraživanja i u granicama tolerancije pogreške rabljenih instrumenata mjerjenja.

Tablica 6. Serije preuzimanja i snimanja podataka

BR.	PROSJEČAN ZADANI BROJ OKRETAJA (min. ⁻¹)	POČETAK SNIMANJA		KRAJ SNIMANJA	
		ŠIRINA	DUŽINA	ŠIRINA	DUŽINA
1	87	9° 30' 59,19"	311° 30' 27,36"	-2° 15' 47"	72° 7' 4,76"
2	82	19° 21' 15,06"	252° 59' 6,36"	29° 26' 3,25"	264° 56' 7,43"
3	86	29° 26' 3,25"	264° 56' 3,45"	23° 21' 27,48"	180° 40' 20,4"
4	79	23° 36' 35,64"	179° 48' 55,26"	35° 9' 43,68"	129° 28' 12"
5	77	34° 30' 24,24"	129° 3' 44,46"	23° 35' 16,14"	179° 50' 17,58"
6	73	23° 24' 39"	180° 33' 23,88"	12° 1' 51,9"	237° 55' 41,1"
7	86	21° 54' 55,5"	113° 12' 43,02"	-4° 49' 34,44"	325° 16' 18,24"

Preuzetom skupu senzorskih podataka pridruženo je šest podataka s brodskog sustava elektronskih karata (Prilog A, Tablica 32.) te 30 podataka iz brodskih podnevnih izvješća (Prilog A, Tablica 33.). Zemljopisne koordinate i datum / vrijeme morali su se izdvajiti te su upotrijebljeni za dobivanje 10 trenutnih meteoroloških i oceanografskih podataka prema izvađenim koordinatama i datumu / vremenu (Prilog A, Tablica 34.). Ukupno je preuzet 141 različit podatak iz nabrojenih izvora.

Atribut pojedine varijable je sastavni dio opažanja i može biti ulaz ili izlaz iz modela. U ovome istraživanju svaka varijabla ima samo jedan atribut koji je ujedno i izmjerena, odnosno opservacijska vrijednost varijable. Atribut je predstavljen jednim stupcem u skupu podataka, a primjerak je skup vremenski usklađenih atributa te predstavlja jedan red u skupu podataka. Više primjeraka naziva se uzorkom.

S obzirom na to da određeni broj preuzetih ulaznih varijabli nema utjecaj na ciljane izlazne varijable, a neke su od njih i istovrsne u različitim izvorima (primjerice, brzina vjetra koja se pojavljuje kao senzorski podatak u skupini preuzetoj s K-Chief sustava te iz ECDIS-a), izvršen je ekspertni odabir koji je rezultirao s 23 senzorske varijable iz primarnog izvora te 15 iz sekundarnih izvora (Prilog A, Tablica 35.). Prikupljanje podataka iz većeg broja izvora zahtijeva sinkronizaciju vremena očitanja između izvora te spajanje podataka u jedinstven zapis očitanja svih vrijednosti varijabli (primjerak koji ulazi u postupak strojnog učenja). Nadalje, budući da su se mjerena bilježila u različitim vremenskim rasponima, a s ciljem smanjenja broja zapisa, pojedinačne su varijable u nekim slučajevima imale veći broj očitanja. Za potrebe usklađivanja pohranila se njihova prosječna vrijednost. Do tog problema dolazi iz različitih frekvencija očitanja između senzora, a daljnji postupci zahtijevaju jedinstven zapis. U slučaju kada očitanje pojedinačne vrijednosti senzora nije bilo moguće, nedostajući su podaci interpolirani stepenastom funkcijom, odnosno ponovljena je posljednja poznata

vrijednost očitanja do sljedećeg očitanja te varijable. Pokazalo se da je ta jednostavna interpolacija dosta na to da je broj nepostojećih podataka bio mali u odnosu na ukupan broj prikupljenih podataka.

Za bolje razumijevanje međusobne povezanosti između podataka sastavljena je Pearsonova korelacija (Prilog C, Tablica 36. i Tablica 37.) prema izrazu:

$$r = \frac{n(\sum xy) - (\sum x)(\sum Y)}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \quad (63)$$

Na temelju vrijednosti Pearsonove korelacije među varijablama uklonjena je jedna od varijabli koja je imala korelaciju iznad 0,85 s drugom varijablom. Smanjenje broja varijabli, u ovome slučaju, preporučljivo je uvesti iz dva razloga: pojedine varijable posjeduju poznate direktno - ovisne odnose te, još važnije, da se smanji broj varijabli u konačnom modelu kako bi se postigla bolja razumljivost u praktičnoj primjeni. Odluka o zadržavanju varijable donesena je iskustvenim ekspertnim načelom uvažavajući i varijable koje nisu imale dovoljno podataka o odabranim serijama snimanja. Nakon tog postupka, od inicijalnih 38, preostalo je 25 varijabli s mjeranjima u vremenskim intervalima od 5 minuta, i to: 1, 3, 4, 6, 8, 9, 15, 16, 17, 19, 22, 23, 24, 25, 26, 27, 28, 29, 30, 33, 34, 35, 36, 37, 38 (Prilog A, Tablica 35.). Upravo su ti podaci zadržani u konačnom popisu varijabli (Tablica 7.).

Preostalih 25 ulaznih varijabli predstavljeno je s 18499 primjeraka podataka koji su upotrijebljeni za učenje i evaluaciju. Pri tome je od značenja napomenuti da su varijable 2, 3, 4, 6, 9 i 25 izlazne (Tablica 7.), odnosno one koje primjenom algoritama strojnog učenja predviđamo.

Tablica 7. Konačan popis varijabli preostalih nakon korelacije

BR.	IZVORNA OZNAKA SENZORA/ VARIJABLE	DODATNE INFORMACIJE	MJERNA JEDINICA
1	PICKUP11	BROJ OKRETAJA GLAVNOG POGONSKOG STROJA	°/min
2	FUEL_EFF	UČINKOVITOST UTROŠKA GORIVA GL. POG. STROJA	g/kWh
3	ME_TOT_FL	POTROŠNJA GORIVA GL. POGONSKOG STROJA (CORIOLIS)	kg
4	NAV_02	BRZINA BRODA PREKO DNA (GPS VTG)	nm/h
5	NAV_04	BRZINA VJETRA (ANEMOMETAR)	m/s
6	MSB0-TOT-LOD	DJELATNA SNAGA IZMJERENA NA GL. RAZVODNOJ PLOČI	kW
7	MS114	TEMPERATURA ZRAKA	°C
8	MW014	TEMPERATURA MORA	°C

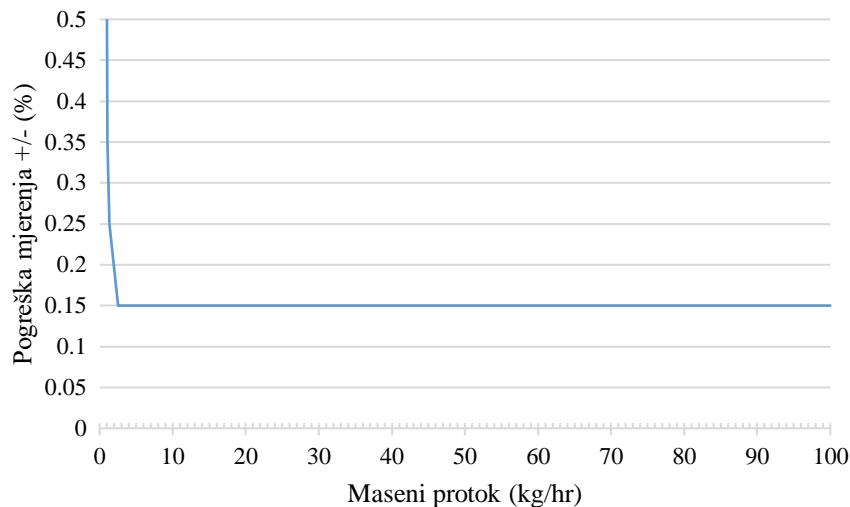
BR.	IZVORNA OZNAKA SENZORA/ VARIJABLE	DODATNE INFORMACIJE	MJERNA JEDINICA
9	TRIM IN METERS	UZDUŽNI NAGIB BRODA (- PRAMAC, + KRMA)	m
10	LIST	POPREČNI NAGIB BRODA	°
11	DRAFT_P/S	SREDNJA URONJENOST BRODA PO SREDINI	m
12	COG/ DEGT	BRODSKI KURS PREKO DNA (ECDIS)	°
13	UWIND	U KOMPONENTA VJETRA	m/s
14	VWIND	V KOMPONENTA VJETRA	m/s
15	GUST	UDAR VJETRA	m/s
16	SIGNIFICANT WAVE	ZNAČAJNA VISINA VALA	m
17	WAVE DIRECTION	SMJER VALA	°
18	WAVE PERIOD	PERIODA VALA	s
19	SEA DIRECTION	SMJER MORA	°
20	SEA CURRENT SPEED	BRZINA MORSKE STRUJE	m/s
21	SEA	OPSERVACIJA VISINE VALA IZ PODNEVNOG IZVJEŠĆA	Bft ³⁷
22	SWELL	OPSERVACIJA MRTVOG MORA IZ PODNEVNOG IZVJEŠĆA	DSS ³⁸
23	WIND	OPSERVACIJA SNAGE VJETRA IZ PODNEVNOG IZVJEŠĆA	DSS
24	WIND DIRECTION	SMJER VJETRA	°
25	PROP_SLIP	SKLIZ VIJKA	%

Potrošnja goriva glavnog pogonskog stroja mjerena je Coriolisovim³⁹ mjeračem masenog protoka, proizvođača Endress i Hauser, model Proline Promass 80, prema standardu ISO-DIN 11631, s ukupnom pogreškom od 0,15%.

³⁷Beaufortova ljestvica služi za ocjenjivanje jačine vjetra prema njegovim učincima. Ljestvica je izražena od 0 do 12 stupnjeva.

³⁸Douglasova skala (engl. Douglas sea scale, DSS) mjerilo je visine valova i stanja mrtvog mora. Ljestvica je vrlo jednostavna za praćenje i izražena je od 0 do 9 stupnjeva.

³⁹Coriolisov mjerač protoka temelji se na principima mehanike gibanja. Kako se fluid kreće kroz vibrirajuću cijev, ona je prisiljena ubrzati dok se kreće prema točki vibracija vršne amplitude. Obrnuto, usporavajući fluid udaljava se od točke vršne amplitude dok izlazi iz cijevi. Rezultat je toga reakcija uvijanja protočne cijevi tijekom protočnih uvjeta, koja prelazi svaki ciklus vibracija. Maseni protok proporcionalan je razlici faza između dva senzora ugrađena na mjerne tubi, koja registrira pomak faza oscilacije, gustoća medija proporcionalna je frekvenciji rezonancije mjerne tube, a temperatura medija izravno je mjerena integriranim temperaturnim senzorom.



Slika 16. Primjer ovisnosti pogreške mjerjenja o protoku medija te najveća izmjerena vrijednost pogreške mjerene u %.

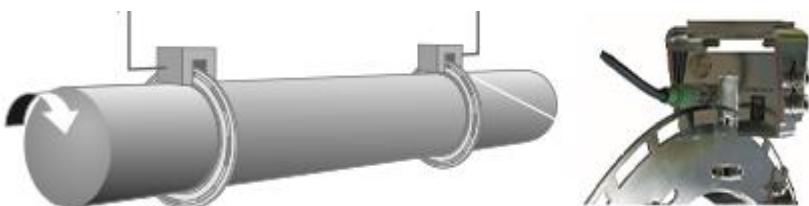
Izvor: Endress i Hauser: *Operating Instructions: Proline Promass 80, Coriolis Mass Flow Measuring System, 2006.* [149].

Sukladno dijagramu (Slika 16.), pogreška je veća kod manjih protoka te se s povećanjem protoka smanjuje na spomenutu vrijednost. S obzirom na to da je potrošnja goriva daleko veća od deklariranih 2,5 kg na sat, pogreška je mjerena utroška unutar 0,15% [149]. Instalirana su dva mjerila protoka istog tipa, jedan na ulazu u glavni pogonski stroj, drugi na izlazu, a razlika između očitanja predstavlja potrošnju goriva.

U prvoj seriji preuzimanja senzorskih podataka (Tablica 6.) rabljeno je teško gorivo visokog sadržaja sumpora, sukladno standardu ISO 8217, čije su glavne osobine sljedeće: gustoća @15°C (ISO 12185) 985,2 kg/m³, viskozitet @50°C (ASTM D7042) 341,6 mm²/s, sumpor (ISO 8754) 2,56% m/m te specifična energija (ISO 8217) 40,32 MJ/kg. U drugoj seriji preuzimanja senzorskih podataka rabljeno je gorivo visokog sadržaja sumpora, sukladno standardu ISO 8217, čije su glavne osobine sljedeće: gustoća @15°C (ISO 12185) 989,5 kg/m³, viskozitet @50°C (ASTM D7042) 348,1 mm²/s, sumpor (ISO 8754) 2,34% m/m te specifična energija (ISO 8217) 40,35 MJ/kg. Od 3. do 6. serije preuzimanja senzorskih podataka rabljeno je gorivo visokog sadržaja sumpora, sukladno standardu ISO 8217, čije su glavne osobine sljedeće: gustoća @15°C (ISO 12185) 985,5 kg/m³, viskozitet @50°C (ASTM D7042) 346,2 mm²/s, sumpor (ISO 8754) 2,42% m/m te specifična energija (ISO 8217) 40,33 MJ/kg, dok je u posljednjoj seriji gorivo imalo gustoću @15°C (ISO 12185) 985,3 kg/m³, viskoznost @ 50@ (ASTM D7042) 345,2 mm²/s, sumpor (ISO 8754) 2,41% m/m i specifičnu energiju (ISO 8217)

40,33 MJ/kg. Budući da uporabljena goriva imaju slične karakteristike⁴⁰, nije bilo potrebe za prilagodbom.

Zakretni moment, snaga na osovinskom vodu, te broj okretaja osovinskog voda mjereni su mjeračem zakretnog momenta MetaPower, proizvođača Kongsberg.



Slika 17. Mjerač zakretnog momenta osovinskog voda MetaPower

Izvor: *Kongsberg Maritime: Shaft power meter, Torque and power measurement system for rotating shaft, 2017.* [150]

MetaPower sustav integriran je u arhitekturu sustava nadzora brodskog postrojenja K-Chief 600, a sastoji se od dva diska s prorezima kroz koje se emitira svjetlećih dioda. Svjetlosni se signal pretvara u digitalni te šalje u procesorsku jedinicu, koja proračunava zakretni moment. Sustav nema mehaničkih dijelova koji se troše te je dugotrajan, točan i pouzdan [150].

Brzina i smjer vjetra mjereni su AT-200 anemometrom i anemoskopom proizvođača Heriana Co. Ltd. Brzina vjetra mjerena je generatorom pulsa s vijkom do najviše 60 m/s (0 – 115 čvorova), a smjer vjetra sinkronim motorom za vjetar za veličine veće od 1 m/s pri kutu od 90° [151].

Brzina broda u odnosu na dno (engl. *Speed over ground – SOG*) izmjerena je GP-150 dual GPS uređajem proizvođača Furuno. Greška je mjerena brzine unutar 0,2 čvora za brzinu manju od 10 čvorova te 2% za brzinu veću od 10 čvorova. Točnost je mjerena smjera plovidbe +/- 3% za brzinu 1 – 17 čvorova i 1% iznad 17 čvorova [152].

Smjer kretanja broda mjerjen je TG 8500 Gyro kompasom proizvođača Tokyo Keiki Inc. [153] Točnost gyro kompasa redovito se provjerava te se servisira jednom godišnje.

⁴⁰Brod je uzimao bunker uvijek u istoj (ukrcajnoj) luci od istog dobavljača – Aegean Marine Petroleum.

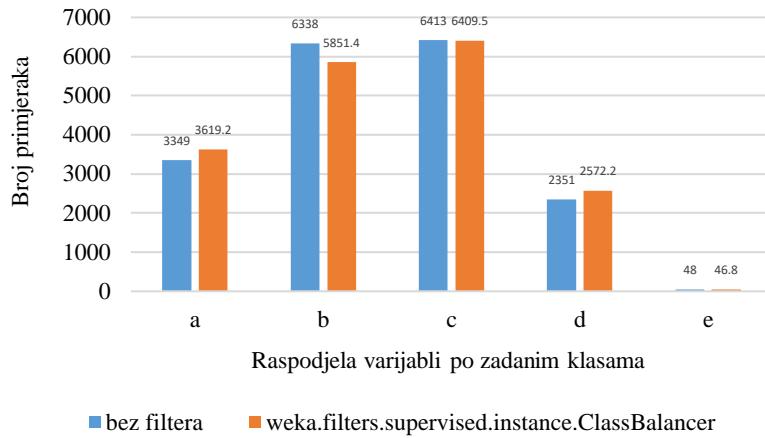
4.2. Izgradnja i testiranje metode za predviđanje operacijskih parametara

Kao osnovna izlazna varijabla, tj. ona čija će se vrijednost predvidjeti, odabrana je potrošnja goriva glavnog propulzijskog stroja. Glavni propulzijski stroj najveći je pojedinačni potrošač energije kod kojeg je unaprjeđenjem operacijskih postupaka moguće postići najveće uštede u potrošnji goriva te najveće smanjenje emisije ugljikova dioksida u atmosferu, što je u skladu sa zahtjevima sadržanim u SEEMP planu (dio 1 i 2), opisu EEDI te zahtjevima Europske unije prema Uredbi o praćenju, izyješćivanju i provjeri, odnosno brodskom MRV planu.

4.2.1. Diskretizacija podataka u razrede

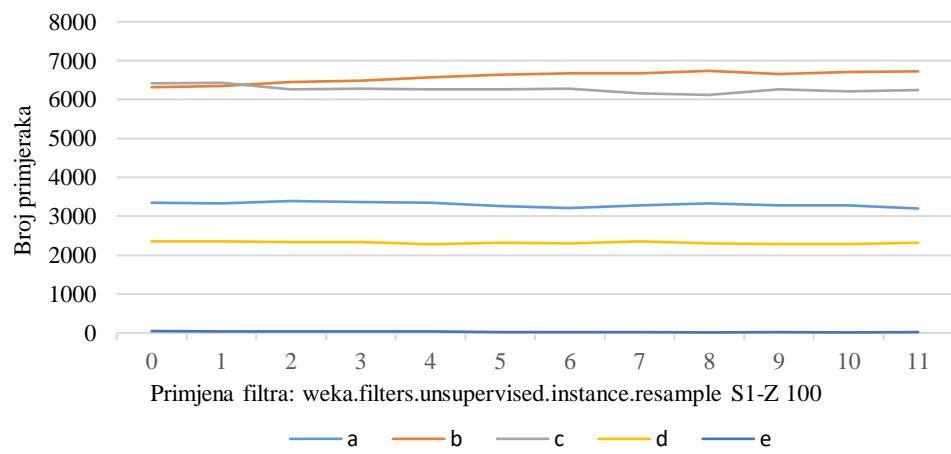
Potrošnja goriva mjerena u kg/sat podijeljena je za potrebe klasifikacije u pet klasa ili razreda i odgovara graničnoj potrošnji prema ugovoru o prijevozu tereta: razred a <1333 , $1333 \leq b <1583$, $1583 \leq c <1770$, $1770 \leq d \leq 1916$ i e: >1916 . Razredi su potvrđeni od strane stručnjaka (glavnog brodskog inženjera) uzimajući u obzir izmjerene vrijednosti potrošnje goriva u tri skupine postavki brzine u različitim uvjetima plovidbe, s ciljem ravnomjerne raspodjele u onoliko razreda koliko je razumno. Intervali i broj razreda mogu se optimizirati ovisno o potrebi za usporedbom rezultata, kao što je usporedba s ciljanom potrošnjom goriva iz SEEMP-a, vrijednostima izmjerenima tijekom probne vožnje ili s ispitnog stola.

Budući da je riječ o pet razreda (za ciljanu primjenu algoritma moguć je veći ili manji broj), kako bi se dodatno riješili problemi neravnoteže razreda (različitog broja mjerena u svakom razredu), ispitane su primjene dvije vrste filtara: nadziranog filtra balansiranja razreda (weka.filters.supervised.instance.ClassBalancer), čija je primjena balansiranja razreda na primjeru klasificiranih podataka prema potrošnji goriva prikazana na grafikonu (Slika 18.) i nenadziranog filtra ponovnog uzorkovanja S1-Z 100 (weka.filters.unsupervised.instance.resample, S1-Z100), čija je primjena na istom primjeru klasificiranih podataka prema potrošnji goriva prikazana na dijagramu (Slika 19.) Oba su filtra standardno implementirana u programske pakete Weka. Posebnost filtera balansiranja razreda je u tome da se ne temelji na naduzorkovanju manjinskih razreda ili poduzorkovanju većinskih razreda već se primjenjuje težinska raspodjela, gdje se primjercima u svakom razredu dodjeljuju težine na način da je ukupni zbroj težina u svim razredima jednak dok nenadzirani filter ponovnog uzorkovanja izrađuje nasumični podskup skupova podataka pomoću uzorkovanja sa zamjenom ili bez zamjene elemenata skupa [40].



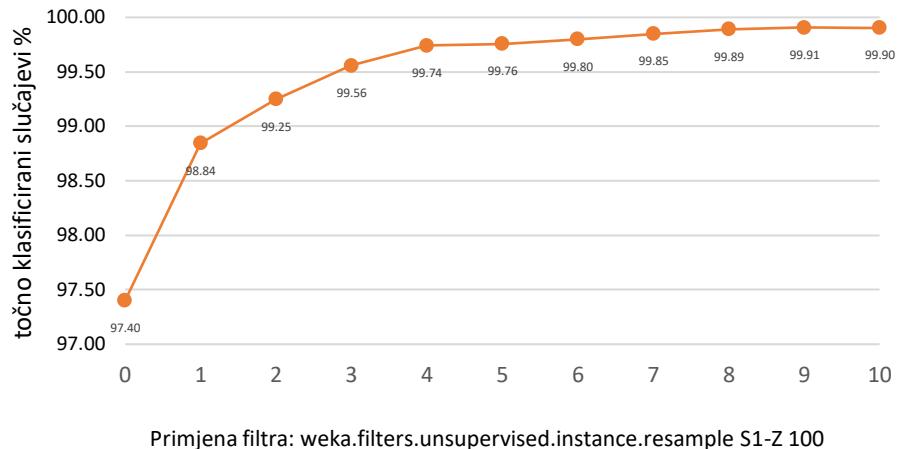
Slika 18. Primjena nadziranog filtra balansiranja razreda na primjeru klasificiranih podataka prema potrošnji goriva

Originalne postavke broja intervala diskretizacije (*Number of discretization intervals = 10*) pokazale su najbolje rezultate tehnikom desetorostrukе unakrsne provjere na svim ispitanim algoritmima strojnog učenja te prilikom različitog odabira izlaznih varijabli (što je i očekivano jer je skup podataka zajednički).



Slika 19. Primjena nenadziranog filtra S1-Z 100 na primjeru klasificiranih podataka prema potrošnji goriva

Originalne postavke (*random seed = 1*) parametara ponovnog uzorkovanja postavljene na S1-Z 100 pokazale su najbolje rezultate na svim ispitanim algoritmima strojnog učenja te prilikom različitog odabira izlaznih varijabli.



Slika 20. Primjena nenadziranog filtra S1-Z 100 na primjeru učenja algoritma nasumičnih šuma prema klasifikaciji potrošnje goriva

Unatoč izvrsnim, unakrsno provjerenim rezultatima učenja prikazanima na primjeru na dijagramu (Slika 20.), nenadzirani filtri generalno nisu preporučljivi za primjenu na prethodno klasificiranim skupovima podataka (što je ovdje slučaj), stoga su nadzirani filtri koji uzimaju u obzir raspodjelu razreda i nadziru diskretiziranje razbijanjem atributa u ladice koje pružaju najviše informacija o razredu bolji izbor [40]. Diskretizacija je izvršena zbog lakše primjenjivosti u praksi gdje je važno pravovremeno predvidjeti razred potrošnje goriva kao potporu prilikom donošenja odluka vezanih za operaciju brodom.

4.3. Vrednovanje metoda rudarenja podataka

U nastavku su prikazani rezultati učenja različitih algoritama strojnog učenja.

4.3.1. Usporedba rezultata dobivenih upotrebom različitih metoda rudarenja podataka i odabir najprimjerenije

Rezultati su podijeljeni u dvije skupine algoritama – oni koji se služe klasifikacijom te algoritmi s regresijskim pristupom.

4.3.1.1. Rezultati učenja primjenom algoritama klasifikacije

Naivni Bayes (weka/bayes/NaiveBayes)⁴¹ klasifikacijski algoritam naučio je model za 0,05 sekundi s 12 644 od 18 499 ili 68,35% točno klasificiranih slučajeva i RMSE od 0,3186. Uključivanje opcije nadziranog balansiranja razreda s originalnim postavkama (broj je intervala diskretizacije 10) te nadzirane diskretizacije (useSupervisedDiscretization) prilikom učenja, predviđanje je poboljšano na 17 121 od 18 499 ili 92,55% točno klasificiranih slučajeva uz RMSE 0,1668 i vrijeme potrebno za učenje modela od 0,28 sekundi. Više informacija o rezultatima klasifikacije može se vidjeti u prikazu (Tablica 8.) i odgovarajućoj matrici zabune (Prilog D, Tablica 38.).

Tablica 8. Vrednovanje klasifikacije pomoću naivnog Bayesa

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,965	0,017	0,968	0,967	0,949	0,998	0,995
b	0,941	0,026	0,898	0,919	0,900	0,991	0,970
c	0,874	0,026	0,940	0,906	0,866	0,987	0,974
d	0,927	0,022	0,872	0,898	0,882	0,992	0,964
e	0,682	0,006	0,219	0,331	0,384	0,952	0,335
WA	0,926	0,022	0,926	0,927	0,902	0,992	0,978

Multinomijalna logistička regresija (weka/functions/Logistic) klasifikacijski algoritam naučio je model za 6,1 sekundu s 15 521 od 18 499 ili 83,90% točno klasificiranih slučajeva i RMSE od 0,2213. Filter nadziranog balansiranja razreda nije upotrijebljen jer pogoršava rezultat. Rezultati MLR bolji su u usporedbi s naivnim Bayesom jer je temeljni NB generativni

⁴¹ Naziv u zagradi predstavlja odabrani algoritam u Weka izborniku.

model (uči zajedničku vjerojatnost $p(x,y)$), dok je logistička regresija diskriminativni model (uči uvjetnu vjerojatnost $p(y/x)$) [154]. Posljedično, uvođenjem nadzirane diskretizacije, NB postiže bolji rezultat u svim kategorijama ocjenjivanja uspješnosti. Više informacija o rezultatima klasifikacije može se vidjeti u sljedećem prikazu (Tablica 9.) i matrici zabune (Prilog D, Tablica 39.).

Tablica 9. Vrednovanje multinomijalne logističke regresije

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,949	0,028	0,947	0,948	0,921	0,986	0,975
b	0,617	0,044	0,756	0,679	0,621	0,938	0,765
c	0,837	0,136	0,762	0,798	0,687	0,913	0,841
d	0,876	0,019	0,871	0,874	0,855	0,986	0,933
e	0,083	0,001	0,222	0,121	0,135	0,972	0,157
WA	0,839	0,067	0,838	0,836	0,776	0,952	0,884

Višeslojni perceptron (weka/functions/MultilayerPerceptron) klasifikacijski algoritam naučio je model za 29,21 sekundu s 17 081 od 18 499 ili 92,33% točno klasificiranih slučajeva i RMSE od 0,1608 služeći se jednim skrivenim slojem s 5 čvorova uz 500 epoha, momentom od 0,2 i početnom postavkom stupnja učenja algoritma povratne propagacije od $L = 0,3$. Postavljanjem broja sigmoidnih čvorova u skrivenom sloju na 10 povećava se točnost na 94,36%, dok 15 čvorova povećava točnost na 94,53% (najbolji rezultat klasifikacije s jednim skrivenim slojem). Povećanje broja skrivenih slojeva na 2 poboljšava model jer dodavanje slojeva omogućuje modeliranje nelinearne složenosti: model s dva skrivena sloja i 15 čvorova postiže najbolji rezultat s 94,79% točno klasificiranih primjeraka. Konačni rezultat sa 17 586 od 18 499 ili 95,06% točno klasificiranih slučajeva i RMSE od 0,1287 postignut je sa 2 skrivena sloja, svaki s 15 čvorova, 2000 epoha, momentom od 0,1 i postavkom stupnja učenja algoritma povratne propagacije od $L = 0,2$. Međutim, vrijeme potrebno za izgradnju modela značajno je povećano na 914 sekundi. Filter nadziranog balansiranja razreda nije upotrijebljen jer je promjena prognostičkog rezultata točno klasificiranih slučajeva neznatna. Više informacija o rezultatima klasifikacije može se vidjeti u sljedećem prikazu (Tablica 10.) i matrici zabune (Prilog D, Tablica 40.).

Tablica 10. Vrednovanje višeslojnog perceptronra

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,996	0,015	0,972	0,984	0,975	0,993	0,978
b	0,936	0,012	0,945	0,940	0,927	0,989	0,964
c	0,932	0,031	0,940	0,936	0,903	0,974	0,962
d	0,912	0,010	0,933	0,922	0,911	0,987	0,951
e	0,188	0,001	0,474	0,269	0,297	0,720	0,120
WA	0,951	0,019	0,950	0,950	0,932	0,984	0,965

Strojevi potpornih vektora (weka/functions/SMO) klasifikacijski algoritam naučio je model za 16,54 sekunde s 15 083 od 18 499 ili 81,53% točno klasificiranih slučajeva i RMSE od 0,3291. Budući da se najbolji rezultat postiže primjenom odgovarajuće funkcije jezgre, inicijalne postavke normaliziranog polinominalnog kernel klasifikatora (weka.NormalizedPolyKernel) promijenjene su u Pearsonovu univerzalnu funkciju jezgre (weka.Puk), s točnošću klasifikacije od 94,37% ili 17 458 od 18 499 točno klasificiranih primjeraka uz pomoć 135 potpornih vektora za vrijeme učenja od 170 sekundi, s RMSE od 0,3206. Strojevi potpornih vektora postižu 1,82% više točno klasificiranih slučajeva u usporedbi s NB.

Više informacija o rezultatima klasifikacije može se vidjeti u sljedećem prikazu (Tablica 11.) i matrici zabune (Prilog D, Tablica 41.).

Tablica 11. Vrednovanje strojeva potpornih vektora

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,994	0,08	0,985	0,990	0,984	0,995	0,984
b	0,913	0,018	0,918	0,916	0,897	0,960	0,864
c	0,927	0,037	0,928	0,928	0,890	0,955	0,892
d	0,909	0,013	0,910	0,909	0,896	0,979	0,866
e	0,146	0,000	0,875	0,250	0,357	0,925	0,209
WA	0,944	0,021	0,943	0,943	0,923	0,973	0,914

Stabla odluke (weka/trees/J48) klasifikacijski algoritam naučio je model za 1,27 sekundi sa 17 850 od 18 499 ili 96,49% točno klasificiranih slučajeva i RMSE od 0,1132. Više informacija o rezultatima klasifikacije može se vidjeti u prikazu (Tablica 12.) i odgovarajućoj matrici zabune (Prilog D, Tablica 42.).

Tablica 12. Vrednovanje stabla odluke

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,996	0,004	0,993	0,995	0,992	0,997	0,992
b	0,950	0,011	0,949	0,949	0,938	0,977	0,927
c	0,955	0,023	0,956	0,956	0,933	0,972	0,948
d	0,937	0,009	0,941	0,939	0,930	0,977	0,910
e	0,500	0,001	0,615	0,552	0,554	0,833	0,452
WA	0,965	0,012	0,965	0,965	0,953	0,982	0,954

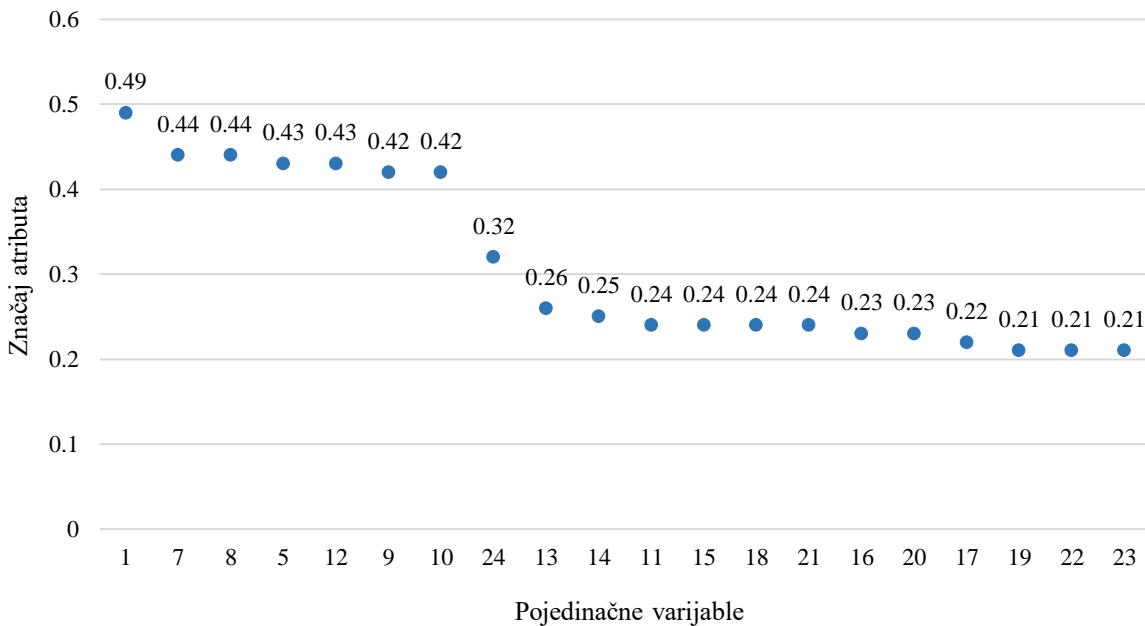
Nasumične šume (weka/trees/RandomForest) klasifikacijski algoritam naučio je model za 5,31 sekundu s 18 018 od 18 499 ili 97,40% točno klasificiranih slučajeva i RMSE od 0,0895. Filter nadziranog balansiranja razreda nije upotrebljavan jer je promjena prognostičkog rezultata točno klasificiranih slučajeva neznatna, a i nepotrebna, jer algoritam uključuje slučajni odabir primjeraka i atributa. U usporedbi s ostalim algoritmima, nasumične šume postižu najbolji rezultat po svim načinima vrednovanja. Više informacija o rezultatima klasifikacije može se vidjeti u sljedećem prikazu (Tablica 13.) i matrici zabune (Prilog D, Tablica 43.).

Tablica 13. Vrednovanje metode nasumičnih šuma

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,998	0,003	0,995	0,996	0,994	1,000	1,000
b	0,963	0,008	0,965	0,964	0,956	0,997	0,991
c	0,969	0,018	0,965	0,967	0,950	0,997	0,993
d	0,946	0,006	0,957	0,951	0,944	0,996	0,987
e	0,604	0,000	0,853	0,707	0,717	0,999	0,800
WA	0,974	0,009	0,974	0,974	0,965	0,998	0,994

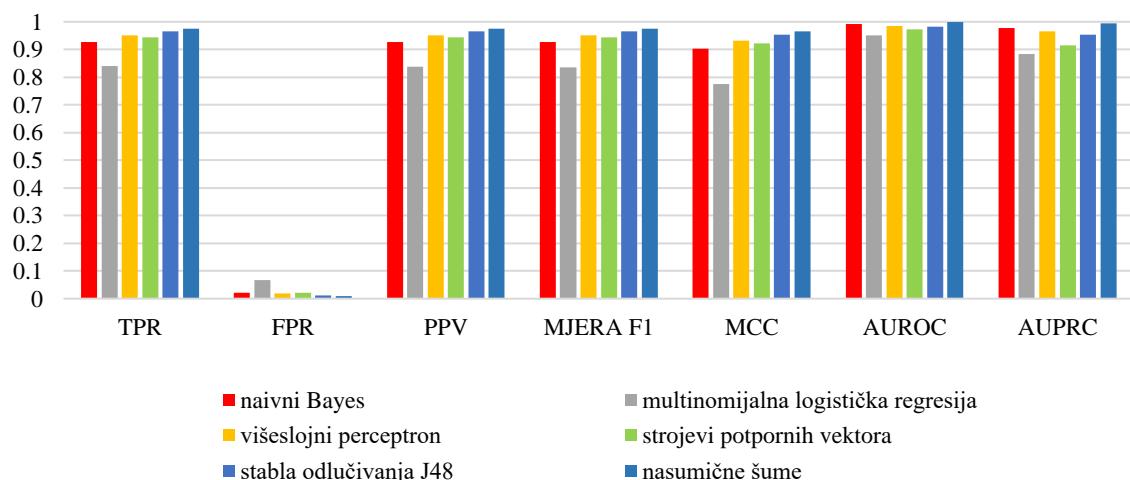
Značaj pojedinačnih atributa u gradnji stabla temeljen na prosječnom smanjenju nečistoća (i broja čvorova koji rabe taj atribut) može se vidjeti u grafičkom prikazu (Slika 21.).

Nizak rezultat značaja, odnosno onaj blizu nule, ukazuje na to da atribut ne doprinosi konačnoj klasifikaciji, te se može razmotriti gradnja modela koji sadrži isključivo varijable visokog značaja s prednošću u jednostavnosti i lakšoj praktičnoj primjeni modela s manje varijabli.



Slika 21. Značaj pojedinačnih atributa u gradnji modela nasumičnih šuma

Pozitivna ocjena pokazuje da je zadana varijabla važna za ispravnu klasifikaciju. Najveći značaj pri gradnji stabla ima varijabla 1, potom prema značaju slijede 7, 8, 5, 12, 9, 10, 24, 13, 14, 11, 15, 18, 21, 16, 20, 17, 19, 22 i 23 (Slika 21.).



Slika 22. Usporedba rezultata klasifikacije šest algoritama strojnog učenja prema standardnim mjerama učinkovitosti modeliranja klasifikacijskih algoritama

Nakon verifikacije okvira modeliranja i analize rezultata kako bi se poboljšala točnost predviđanja, najbolji klasifikacijski model bira se na temelju standardnih mjera vrednovanja usporedno prikazanih na grafikonu (Slika 22.). Podjela podataka u pet razreda – a: <1333, b:

<1583, c: <1770, d: <1916 i e: >1916 – prema operacijskim zahtjevima, rezultirala je neuravnoteženošću razreda, što je posebno vidljivo u posljednjem razredu *e*, u kojoj je broj primjeraka relativno malen (48), a opisuje iznimno visoku potrošnju goriva. Te probleme moguće je riješiti nadziranim balansiranjem među razredima, čime se rezultat predviđanja poboljšava za 0,2 – 0,5%, a nenadziranom upotrebom filtra ponovnog uzorkovanja S1-Z 100 moguće je postići gotovo apsolutan broj točno klasificiranih slučajeva (Slika 20.). S obzirom na to da je intervencija u rasporedu primjeraka po razredima kod S1-Z 100 filtra prevelika, u ovom istraživanju rezultati su prezentirani bez uključene nenadzirane filtracije spomenutim algoritmom. Eksperimentalni rezultati te usporedba pokazatelja vrednovanja algoritama pokazuju da algoritam MLR postiže skromne rezultate, dok NB, MLP, SVM, J48 i RF postižu visoke i usporedive rezultate klasifikacije. Vrijeme izvođenja algoritama je standardno prikazano u Weki te je uključeno u razmatranje koja će se metoda primijeniti u konačnom modelu.

Najbolji rezultati klasifikacija su dobiveni algoritmom nasumičnih šuma (RF), te s obzirom na točnost predviđanja, postižu najbolji rezultat od 97,40% točno klasificiranih slučajeva unutar prihvatljivog vremena učenja modela. Konačno, možemo zaključiti da su nasumične šume najbolja opcija rudarenja na eksperimentalnm podacima.

4.3.1.2. Rezultati učenja primjenom algoritama regresije

Linearna regresija (weka/functions/LinearRegression) algoritam regresijskog predviđanja naučio je model za 0,46 sekundi s rezultatima prikazanim u sljedećoj tablici:

Tablica 14. Rezultati algoritma linearne regresije

Cc	RMSE	MAE	RAE	RRSE
0,8762	205,5833	125,179	36,8504%	48,1958%

Rezultati vrednovanja učinkovitosti linearne regresije prikazani u prethodnoj tablici (Tablica 14.) pokazuju da je učinak osnovne regresijske metode motivirajuć za prelazak na složenije algoritme.

Višeslojni perceptron (weka/functions/MultilayerPerceptron) algoritam regresijskog predviđanja naučio je model za 120,53 sekunde s Cc od 0,9907 i RMSE 58,3507 rabeći jedan

skriveni sloj s 20 čvorova uz 1000 epoha, moment 0,1 i vrijeme učenja 0,2. Četverostrukom upotrebom dvostrukog nenadziranog filtra S1-Z 100 na ulaznim varijablama, algoritam je uz iste postavke naučio model za 121,74 sekunde te unaprijedio rezultat kako je prikazano u sljedećoj tablici:

Tablica 15. Rezultati predviđanja regresijskog algoritma višeslojnog perceptronra

Cc	RMSE	MAE	RAE	RRSE
0,9954	40,2773	23,4637	7,0284%	9,6109%

Strojevi potpornih vektora (weka/functions/SMOreg) algoritam regresijskog predviđanja naučio je model za 2012,82 sekunde s Cc od 0,963 i RMSE 115,3915 uporabom inicijalnih postavki normaliziranog polinominalnog kernela. Promjenom kernela u Puk, učinak je regresije Cc od 0,9939 i RMSE 47,0969. Četverostrukom upotrebom nenadziranog filtra S1-Z 100 na ulaznim varijablama, algoritam je naučio model za 6924,76 sekundi te unaprijedio rezultate kako je prikazano u sljedećoj tablici:

Tablica 16. Rezultati predviđanja regresijskog algoritma strojeva potpornih vektora

Cc	RMSE	MAE	RAE	RRSE
0,9971	31,6349	7,5572	2,2637%	7,5486%

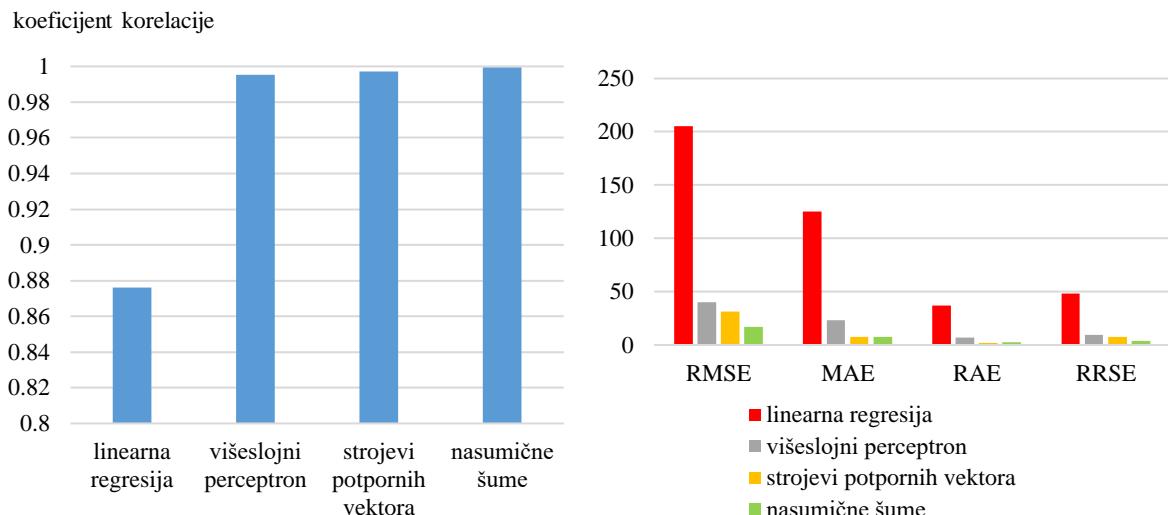
Nasumične šume (weka/trees/RandomForest) algoritam regresijskog predviđanja naučio je model za 8,43 sekunde s Cc od 0,9955 i RMSE 40,486. Četverostrukom upotrebom nenadziranog filtra S1-Z 100 na ulaznim varijablama, algoritam je naučio model za 6,03 sekunde te unaprijedio rezultate kako je prikazano u sljedećoj tablici:

Tablica 17. Rezultati predviđanja regresijskog algoritma višeslojnog perceptronra

Cc	RMSE	MAE	RAE	RRSE

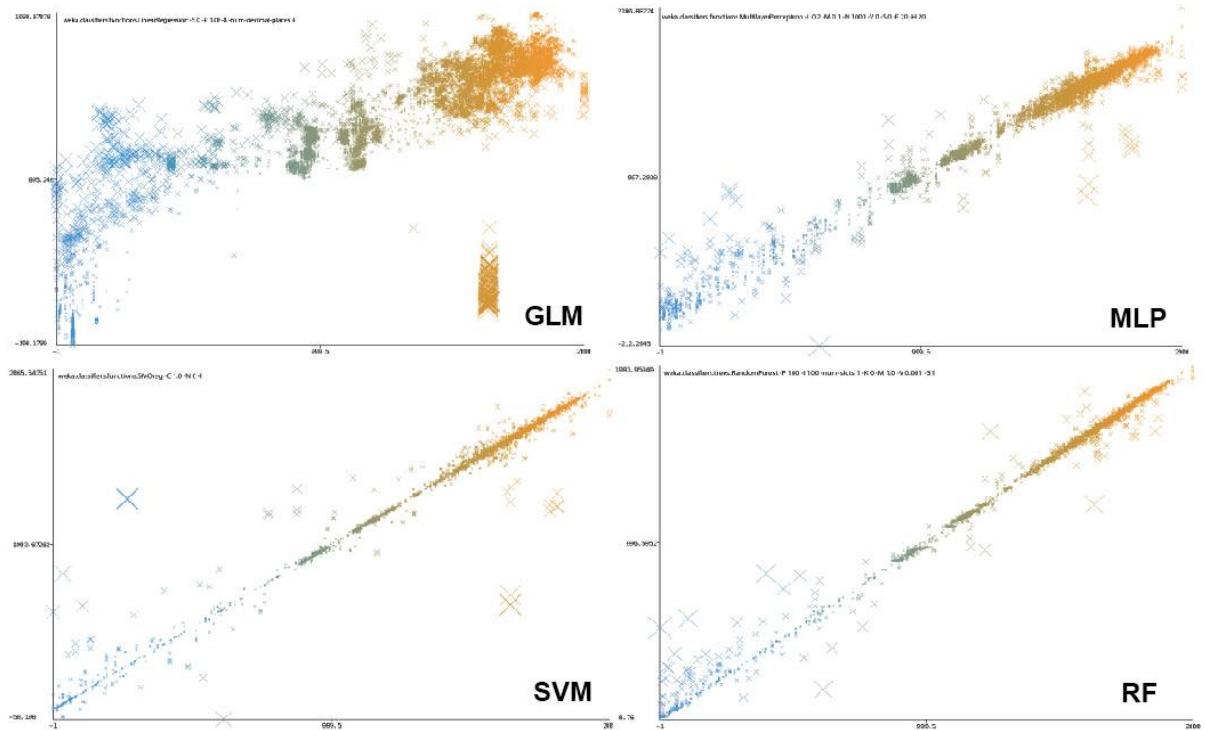
0,9992	17,2632	7,6748	2,304%	4,1287%
--------	---------	--------	--------	---------

Nakon analize rezultata predviđanja četiriju regresijskih modela, najuspješniji algoritam izabran je na temelju standardnih mjera učinkovitosti modeliranja regresijskim algoritmima usporedno prikazanih stupčastim grafikonima (Slika 23.).



Slika 23. Usporedba rezultata regresije četiriju algoritama strojnog učenja prema standardnim mjerama učinkovitosti modeliranja regresijskih algoritama

Primjena nenadziranog filtra S1-Z 100 na ulaznim varijablama rezultirala je poboljšanjem indeksa Cc za 0,003 i RMSE za 15,462. Eksperimentalni rezultati te usporedba pokazatelja vrednovanja algoritama pokazuju da GLM postiže najlošije rezultate, dok MLP, a posebice SVM i RF postižu usporedive rezultate regresije. Vizualizacija rezultata regresijskog modeliranja (Slika 24.) potvrđuje i rezultate numeričke validacije:



Slika 24. Vizualizacija rezultata algoritama regresijskog modeliranja

RF, odgovarajućom kombinacijom i obradom relevantnih varijabli, s obzirom na točnost predviđanja i najmanje raspršivanje, postiže najbolji rezultat regresije s C_c od 0,9992 i RMSE 17,2632 unutar prihvatljivog vremena učenja i s najmanjom intervencijom prilikom učenja modela te se konačno može zaključiti da se nasumične šume čine kao najbolja opcija za praktičnu primjenu [155].

4.3.1.3. Rasprava o rezultatima učenja

Rezultati predstavljenih klasifikacijskih i regresijskih metoda pokazuju da je primjenom odgovarajućeg algoritma moguće s visokom točnošću predvidjeti potrošnju goriva unutar prethodno postavljenih granica (klasifikacija) ili kao točnu brojčanu vrijednost (regresija). Unatoč tome što metode J48, MLP, SVM i NB kod klasifikacije te MLP i SVM kod regresije postižu izvrsne rezultate, RF svojom fleksibilnošću i jednostavnosću uporabe u oba predstavljenja slučaja primjene (klasifikacija i regresija) daje najbolje rezultate predviđanja u vrlo kratkom vremenu učenja te naspram potrebnih parametara za podešavanje. Kod višeslojnog perceptronu, koji se rezultatima predviđanja približavaju RF, prisutan je zahtjevan postupak pronalaska optimalnih parametara za gradnju uspješnog modela. Stoga je vrijeme potrebno za izgradnju RF-a puno kraće te je preporučljiva uporaba nasumičnih šuma upravo

za ovakve slučajeve koji su analizirani u ovome radu. Jedna od osnovnih poteškoća strojnog učenja problem je prenaučenosti modela. Kod RF to se rješava s dovoljno pojedinačnih stabala odlučivanja koja tehnikom podrezivanja odozdo prema gore i različitim težinama primjenjuju atributе koje sadrže podatke o učenju. Daljnje smanjenje broja ulaznih varijabli moguće je na temelju značaja pojedinačnih atributa u gradnji modela nasumičnih šuma (Slika 21.). S obzirom na to da se ansambli nasumičnih šuma djelomično ponašaju kao crne kutije sastavljene od velikog broja osnovnih modela, nije u potpunosti razumljivo koje točno varijable pridonose preciznosti algoritma. U sljedećem poglavlju izvršena je interpretacija utjecaja odabira različitih ulaznih varijabli (senzorskih signala) na točnost predviđanja. U ovome radu, na temelju nabrojenih prednosti u odnosu na ostale ispitane metode, bit će upotrijebljena metoda slučajnih stabala. Odabir metode slučajnih stabala ne isključuje mogućnost primjene ostalih uspješnih algoritama pri rješavanju specifičnih problema te kada je to osobinama koje takvi algoritmi posjeduju poželjno.

4.3.2. Izbor i analiza različitih kombinacija ulaznih varijabli

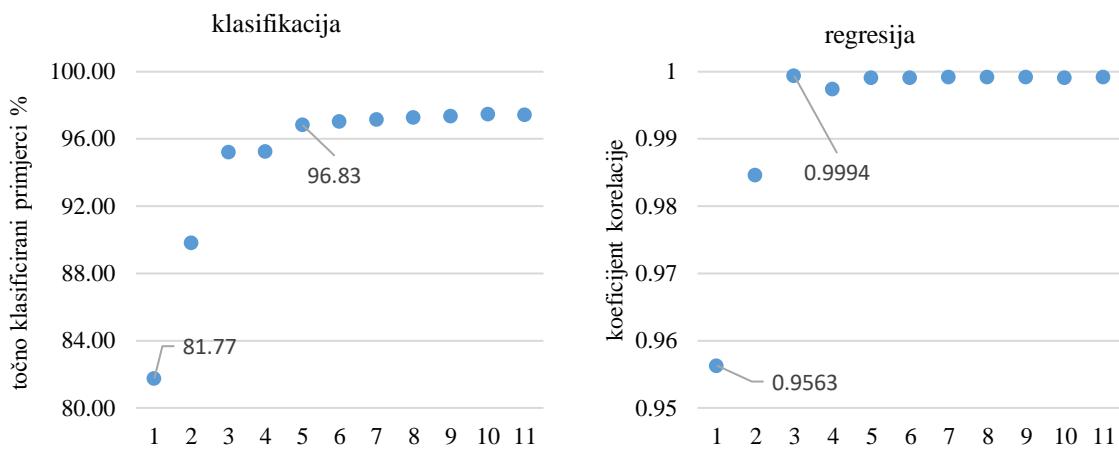
Algoritam nasumičnih šuma uči model pomoću svih ulaznih varijabli i generalno vrijedi pravilo da RF nema potrebe za odabirom varijabli. U primjeni, selekcija je ipak neophodna jer se vrijeme predviđanja, pri uporabi neograničenog broja, može značajno povećati kod stvarnih modela. Nadalje, sa skupovima složenih podataka potrebno je više od točnog predviđanja, odnosno potrebne su kvalitetne informacije o odnosu između ulaznih i izlaznih varijabli detaljnim pogledom u crnu kutiju te priprema podataka za učenje modela [156]. Nakon što je u prethodnim poglavlјima pronađena najuspješnija kombinacija parametara i najuspješniji algoritam rudarenja podacima, dodatno se analizira utjecaj pojedinih ulaznih varijabli ili skupine varijabli na izlazni rezultat, kao i provjera kvalitete rezultata. Utjecaj ulaznih varijabli na rezultat predviđanja razmjeran je značaju pojedinačnih atributa u gradnji modela nasumičnih šuma, međutim, metodom OOB ne može se sa sigurnošću spoznati kako bi se ponašali atributi ako bi se neki uklonili jer bi u tom slučaju stablo bilo izgrađeno na drugačiji način. Jednako tako, ne može se znati jesu li pokriveni svi scenariji vanjskih uvjeta plovidbe, odnosno je li prikupljen dovoljan broj podataka i je li model prenaučen. Stoga je potrebna ekspertna interpretacija rezultata s obzirom na različite kombinacije ulaznih varijabli.

Tablica 18. daje pregled 11 odabranih skupina relevantnih operacijskih parametara koje ulaze u model.

Tablica 18. Pregled različitih kombinacija ulaznih varijabli

BR.	OPIS VARIJABLE	M.J.	1	2	3	4	5	6	7	8	9	10	11
1	BROJ OKRETAJA GLAVNOG POGONSKOG STROJA	%/min	x	x	x	x	x	x	x	x	x	x	x
5	BRZINA VJETRA (ANEMOMETAR)	m/s					x	x	x	x	x	x	x
7	TEMPERATURA ZRAKA	°C							x	x	x	x	x
8	TEMPERATURA MORA	°C							x	x	x	x	x
9	UZDUŽNI NAGIB BRODA (- PRAMAC, + KRMA)	m								x	x	x	x
10	POPREČNI NAGIB BRODA	°									x	x	
11	SREDNJA URONJENOST BRODA PO SREDINI	m											x
12	BRODSKI KURS PREKO DNA (ECDIS)	°						x	x	x	x	x	x
13	U KOMPONENTA VJETRA	m/s			x	x	x	x	x	x	x	x	x
14	V KOMPONENTA VJETRA	m/s			x	x	x	x	x	x	x	x	x
15	UDAR VJETRA	m/s			x	x	x	x	x	x	x	x	x
16	ZNAČAJNA VISINA VALA	m			x	x	x	x	x	x	x	x	x
17	SMJER VALA	°			x	x	x	x	x	x	x	x	x
18	PERIODA VALA	s			x	x	x	x	x	x	x	x	x
19	SMJER MORA	°			x	x	x	x	x	x	x	x	x
20	BRZINA MORSKE STRUJE	m/s			x	x	x	x	x	x	x	x	x
21	OPSERVACIJA VISINE VALA IZ PODNEVNOG	Bft	x		x	x	x	x	x	x	x	x	x
22	OPSERVACIJA MRTVOG MORA IZ PODNEVNOG	DSS	x		x	x	x	x	x	x	x	x	x
23	OPSERVACIJA SNAGE VJETRA IZ PODNEVNOG	DSS	x		x	x	x	x	x	x	x	x	x
24	SMJER VJETRA	°				x	x	x	x	x	x	x	x
BROJAČ ULAZNIH VARIJABLI			1	4	9	12	14	15	16	17	18	19	20

Grafički prikaz (Slika 25.) točno klasificiranih slučajeva (klasifikacija / lijevo) i koeficijenata korelacije (regresija / desno) u različitim kombinacijama ulaznih signala prema skupinama opisanim u gornjoj tablici daje pregled utjecaja pojedinih ulaznih varijabli na rezultat klasifikacije ili regresije.



Slika 25. Grafički prikaz točno klasificiranih primjeraka i koeficijenata korelacijske

Dijagram je podjednak u slučaju klasifikacije i regresije, te se može reći da je utjecaj ulaznih varijabli na predviđanje sličan. To je i očekivano, s obzirom na to da su oba modela učena na istim podacima s istim ulaznim signalima, jedino je izlazna varijabla drugačije zapisana – jednom kao razred za klasifikaciju, a drugi put kao numerička vrijednost za regresiju. Također, može se zaključiti da utjecaj pojedinih varijabli prati značaj pojedinačnih atributa u gradnji modela nasumičnih šuma (Slika 21.). Model sa samo jednom ulaznom varijablom – broj okretaja glavnog pogonskog stroja (skupina 1, Tablica 18.) – u stanju je predvidjeti potrošnju goriva s 81,77% točnošću klasifikacije, odnosno 0,9563 koeficijenta korelacijske kod regresije. Podaci iz brodskih podnevnih izvješća (skupina 2) postižu slabiji rezultat nego prikupljeni javno dostupni meteorološki i oceanografski podaci (skupina 3), koji više doprinose gradnji modela. Uključivanjem svih vanjskih čimbenika gradi se model koji s prihvratljivom točnošću od 95,23% klasifikacije, odnosno 0,9974 koeficijenta korelacijske kod regresije može predvidjeti potrošnju goriva (skupina 4). Razlog slabijih rezultata vanjskih utjecaja iz brodskih izvješća može biti veći vremenski interval i manji ukupni broj varijabli, kao i ljudski čimbenik koji ne očitava s potpunom točnošću. Čovjek je potencijalno pouzdan mjerni instrument za mjerjenje niza veličina, kako konkretnih, tako i onih apstraktnih. Sasvim je drugo pitanje koliko će to njegovo mjerjenje biti metrijski precizno i upotrebljivo. Utjecaj smjera i brzine vjetra s brodskog anemometra korigira prije spomenute vanjske utjecaje te poboljšava predviđanje. Ta se informacija može u budućim istraživanjima rabiti kao mjerilo ocjene prikupljenih javno dostupnih oceanografskih i meteoroloških podataka o vjetru (skupina 5). Sljedeća je ulazna varijabla zadani smjer plovidbe (skupina 6), čiji je značaj u određivanju susretnog kuta vanjskih

čimbenika prema smjeru kretanja broda (ulazna je varijabla stvarnog smjera plovidbe izuzeta jer je takav podatak nemoguće znati u budućnosti). Temperatura zraka (skupina 7) i temperatura mora (skupina 8) imaju podjednak značaj. Uzdužni nagib broda (skupina 9) pridonosi točnosti predviđanja, dok varijabla o poprečnom nagibu (skupina 10), unatoč značaju atributa u gradnji modela nasumičnih šuma koji je jednak onome uzdužnog nagiba broda, ipak ne doprinosi kvaliteti predviđanja u jednakoj mjeri. Razlog je vjerojatno u činjenici da posada održava brod poprečno izravnanim postupkom balastiranja te je on minimalan, dok uzdužni nagib ovisi o stanju tereta, a u isto vrijeme i više doprinosi potrošnji goriva. Uronjenost broda po sredini (skupina 11) umjерeno doprinosi kvaliteti predviđanja. Algoritam nasumičnih šuma u stanju je kroz broj okretaja glavnog propulzijskog stroja i vanjske parametre (skupina 5) uspješno naučiti model u slučaju klasifikacije s 96,83% točno klasificiranih slučajeva, dok kod regresije, kombinacijom broja okretaja glavnog propulzijskog stroja i javno dostupnih meteoroloških i oceanografskih podataka (skupina 3), može predvidjeti potrošnju goriva s 0,9994 koeficijentom korelacije. Takav se rezultat tumači činjenicom da je brod u vrijeme prikupljanja podataka bio u plovidbi stalnom putnom brzinom te je potrošnja uz vremenske uvjete najviše ovisna o broju okretaja glavnog propulzijskog stroja. Ostale varijable doprinose kvaliteti predviđanja u promjenjivim uvjetima plovidbe.

U slučaju modela nasumičnih šuma, gdje je brzina predviđanja podataka ključna, moguće je isključiti jednu ili više varijabli na temelju grafički prikazanih rezultata (Slika 25.) te raspravljenih utjecaja različitih kombinacija ulaznih varijabli iz prethodnog teksta. U slučaju potrebe za visokom preciznošću kao i spremnošću modela na vanjske uvjete koji se uvelike razlikuju od obrađenih, te kada vrijeme izgradnje modela nije presudno, preporučuje se uporaba svih ulaznih varijabli izlistanih u Tablici 18.

4.3.3. Izbor i analiza različitih izlaznih varijabli uvažavajući specifične uvjete primjene

Odabir izlaznih varijabli pratio je čimbenike koji su vezani za učinkovitost propulzije i trupa preko EEDI, SEEMP plana (dio 1 i 2) [157, 158] te operacijskih postupaka kojima se mogu unaprijediti temeljni uvjeti, kao i postići dodatne uštede mjeranjem i praćenjem potrošnje goriva. Eksperimentalno preuzimanje podataka bilo je ograničeno raspoloživošću senzorskih podataka i trajanjem preuzimanja te su odabrani oni pokazatelji koji su na raspolaganju, a povezani su s prethodno navedenim kriterijima odabira:

- potrošnja goriva glavnog propulzijskog stroja,
- specifična potrošnja goriva glavnog propulzijskog stroja,
- brodski skliz (slip),
- brzina broda (preko dna),
- uzdužni nagib broda (trim),
- potreba za ukapljivanjem tereta.

Potrošnja goriva glavnog propulzijskog stroja odabrana je kao glavna izlazna varijabla jer je praćenjem i mjeranjem potrošnje goriva glavnog propulzijskog stroja kao najvećeg pojedinačnog potrošača energije moguće postići najveće uštede potrošnje goriva i najveće smanjenje emisije ugljikova dioksida u atmosferu, što u potpunosti odgovara zahtjevima sadržanim u SEEMP planu (dio 1 i 2) i opisu EEDI. Rezultati rudarenja podataka s potrošnjom goriva glavnog propulzijskog stroja kao izlaznom varijablu predstavljeni su u prethodnim poglavljima. Brodski operacijski pokazatelj energetske učinkovitosti EEOI uobičajen je pokazatelj energetske učinkovitosti unutar zadatog vremenskog perioda, a izračunava se u skladu s metodologijom opisanom u Smjernicama IMO-a za dragovoljnu uporabu operacijskog indikatora energetske učinkovitosti brodova (engl. *IMO Guidelines for voluntary use of the Ship Energy Efficiency Operational Indicator – EEOI*) (Ref. MEPC.1/Circ.684/17 August 2009). EEOI pruža informaciju o emisiji ugljikova dioksida proizvedenog za rad koji obavlja plovilo, odnosno količinu prevezenog tereta na ukupnoj prijeđenoj udaljenosti:

$$EEOI = \frac{M_{CO_2}}{M_c \times d}, \quad (64)$$

gdje je M_{CO_2} masa ispuštenog ugljikova dioksida (t), M_c masa prevezenog tereta (t) i d ukupna udaljenost koju je brod prešao (nm).

Iz gornje formule proizlazi da EEOI ovisi o sljedećem:

1. potrošnji goriva (brzini, optimizaciji konstrukcije broda / motora),
2. količini tereta,
3. duljini putovanja,
4. dijelu putovanja provedenog u balastu i

5. vremenu provedenom izvan najma, na sidrištu, kašnjenju u luci, popravcima ili drugim neaktivnim uvjetima.

Iz navedenog, EEOI je moguće izračunati pomoću izlazne varijable potrošnje goriva, C_f bezdimenzionalnog koeficijenta za pretvorbu potrošnje u količinu ispuštenog CO_2 iz Tablice 1., informacije o masi tereta i predviđenom prijeđenom putu. Predviđeni prijeđeni put može se izračunati iz predviđene brzine broda:

$$EEOI = \frac{24 \times Fc \times C_f}{M_c \times 24 \times v}, \quad (65)$$

gdje je Fc potrošnja goriva (t/hr), C_f bezdimenzionalni koeficijent za pretvorbu potrošnje u količinu ispuštenog CO_2 , M_c masa prevezenog tereta (t) i v brzina broda (čvor).

U cilju praćenja i mjerjenja energetske učinkovitosti rabe se različiti pokazatelji energetske učinkovitosti (engl. *Energy Performance Indicator, EnPI*) ugrađeni u SEEMP, a koji mogu biti jednostavnii parametri, poput spomenutih do složenijih izraza, za koje se smatra da adekvatno predstavljaju energetsku učinkovitost broda, odnosno potrošača. *EnPI* se za slučaj potrošnje goriva uobičajeno izračunava prema sljedećem izrazu:

$$EnPI_{FC} = \frac{FC - FC_B}{FC_B}, \quad (66)$$

gdje je FC potrošnja goriva (t), a FC_B početna ili usporedna potrošnja goriva. *EnPI* predstavlja razliku (%) u potrošnji goriva prema unaprijed određenoj osnovnoj potrošnji.

Specifična potrošnja goriva (engl. *specific fuel oil consumption, SFC*) *glavnog propulzijskog stroja* upotrebljava se prilikom izračuna EEDI te unatoč visokoj korelativnosti s potrošnjom goriva glavnog propulzijskog stroja pruža korisnu informaciju pri provjeri točnog trošenja goriva stroja prema opterećenju i u skladu sa zadanim vrijednostima proizvođača. SFC se izračunava u g/kW kao omjer utroška goriva i snage predane osovinskom vodu, a predstavlja djelotvornost pretvaranja kemijske energije goriva u koristan rad. Vrijednost SFC-a ukazuje ne samo na učinkovitost procesa izgaranja motora nego i na ekonomičnost potrošnje goriva. Specifična potrošnja goriva za potrebe je klasifikacija podijeljena u četiri klase ili razreda koje

odgovaraju graničnoj potrošnji prema rezultatima iz probne vožnje: $a < 161$, $161 \leq b < 175$, $175 \leq c \leq 189$, $d > 189$. Intervali i broj razreda mogu se optimizirati ovisno o potrebi za usporedbom rezultata, kao što je usporedba s ciljanom potrošnjom goriva iz SEEMP-a, vrijednosti izmjerениh na ispitnom stolu i slično. Klasifikacijski algoritam metode RF s prethodnim postavkama bez filtriranja naučio je model za 5,55 sekundi sa 17 962 od 18 499 ili 97,1% točno klasificiranih slučajeva i RMSE od 0,103. Više informacija o rezultatima klasifikacije može se vidjeti u sljedećem prikazu (Tablica 19.) i odgovarajućoj matrici zabune (Prilog D, Tablica 44.).

Tablica 19. Vrednovanje klasifikacijske RF metode sa SFC kao izlaznim parametrom

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,948	0,008	0,941	0,945	0,937	0,997	0,986
b	0,890	0,012	0,907	0,899	0,885	0,994	0,968
c	0,991	0,035	0,988	0,989	0,958	0,998	0,999
d	0,859	0,002	0,881	0,870	0,867	0,996	0,933
WA	0,971	0,028	0,971	0,971	0,945	0,998	0,993

Algoritam regresijskog predviđanja RF naučio je model s upotrebom nenadziranog filtra ponovnog uzorkovanja S1-Z 100 za 5,87 sekundi s Cc od 0,9887 i RMSE 12,0096. Dodatne informacije o rezultatima regresije prikazane su u sljedećoj tablici.

Tablica 20. Rezultati predviđanja regresijske RF metode sa SFC kao izlaznim parametrom

Cc	RMSE	MAE	RAE	RRSE
0,9887	12,0096	1,7503	9,4625%	15,0868%

Brodska skliz (engl. *slip*) predstavlja odnos teorijskog gibanja brodskog vijka i brzine strujanja vode, odnosno omjer stvarne brzine broda i uložene brzine brodskog vijka. Budući da se vijak nalazi u fluidu (moru), njegov stvarni aksijalni pomak nikad nije jednak njegovom usponu, kao što je slučaj s klasičnim vijkom u čvrstom materijalu [103]. Skliz je razlika između teorijskog i stvarnog pomaka, odnosno uspona vijka i stvarnog pomaka plovног objekta, ili gubitak uspona. On je, štoviše, neophodan da bi lopatice vijka pokrenule gibanje mora.

U svakodnevnoj pomorskoj praksi upotrebljava se prividni omjer klizanja (engl. *apparent slip ratio*):

$$s_A = \frac{D_{vijka} - D_{broda}}{D_{vijka}} * 100\% = 1 - \frac{D_{broda}}{D_{vijka}} * 100\%, \quad (67)$$

gdje se teorijska brzina vijka izračunava prema sljedećem izrazu:

$$D_{vijka} = \frac{rpm * h}{1852,16}. \quad (68)$$

Objašnjenje simbola rabljenih u gornjim izrazima jest kako slijedi: s_A – prividni omjer klizanja (%); D_{vijka} – udaljenost koju je prešao vijak ili ukupni uspon (nm); D_{broda} – udaljenost koju je prešao brod (nm); n – broj okretaja vijka (min⁻¹); h – uspon vijka ili udaljenost koju je vijak prešao tijekom jednog okretaja (m).

Prividni omjer klizanja obično se izračunava u podne za prethodna 24 sata, a sastavni je dio brodskih podnevnih izvješća. Također se jednostavno može izračunati za kraća vremenska razdoblja rabeći izraz 68, međutim, da bi vrijednosti bile međusobno usporedive, potrebno je u obzir uzeti jednakе vremenske intervale.

U konkretnom slučaju, udaljenost koju je vijak prešao jednaka je umnošku broja okretaja vijka i uspona vijka od 5971,06 mm prema podacima iz Tablice 5., dok je stvarna prijeđena udaljenost senzorski podatak brzine broda preko dna. Ako je proklizavanje nepromijenjeno, tada je udaljenost koju je vijak prešao proporcionalna razmaku koji je brod prešao. Klizanje je najveće pri pokretanju pogonskog stroja, dok je brod još uvijek u mirovanju, a iznosi 100%. Kako se brzina broda povećava, klizanje se smanjuje i nalazi se na najnižoj vrijednosti pri optimalnoj brzini, stabilnim vremenskim uvjetima, optimalnom uronu trupa, obrastanju trupa i vijka. Prividni omjer klizanja za potrebe je klasifikacije podijeljen u četiri klase ili razreda koje odgovaraju graničnim vrijednostima prema eksperimentalnim podacima: $a < 0$, $0 \leq b < 5$, $5 \leq c \leq 10$, $d: > 10$. Intervali i broj razreda mogu se optimizirati ovisno o potrebi za usporedbom rezultata. Klasifikacijski algoritam metode RF s prethodnim postavkama bez filtriranja naučio je model za 7,34 sekunde sa 16 933 od 18 499 ili 91,53% točno klasificiranih slučajeva i RMSE od 0,1856. Više informacija o rezultatima klasifikacije može se vidjeti u sljedećem prikazu (Tablica 21.) i matrici zabune (Prilog D, Tablica 45.).

Tablica 21. Vrednovanje klasifikacijske RF metode sa sklizom kao izlaznim parametrom

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,851	0,015	0,885	0,868	0,850	0,985	0,930
b	0,930	0,051	0,918	0,924	0,877	0,981	0,966
c	0,924	0,045	0,911	0,918	0,876	0,981	0,955
d	0,910	0,012	0,939	0,925	0,910	0,990	0,964
WA	0,915	0,038	0,915	0,915	0,879	0,983	0,958

Algoritam regresijskog predviđanja RF naučio je model s upotrebom nenadziranog filtra ponovnog uzorkovanja S1-Z 100 za 9,52 sekunde s Cc od 0,995 i RMSE 1,593. Dodatne informacije o rezultatima regresije prikazane su u sljedećoj tablici:

Tablica 22. Rezultati predviđanja regresijske RF metode sa sklizom kao izlaznim parametrom

Cc	RMSE	MAE	RAE	RRSE
0,995	1,593	0,407	5,857%	10,0403%

Brzina broda (preko dna) odabrana je kao izlazna predikcijska varijabla zbog svog operacijskog značenja prilikom odabira najpovoljnije rute prema uvjetima mora i vremena. S obzirom na to da klasifikacija nema previše temelja u praktičnoj upotrebi, rabljena je analiza regresijskim algoritmom nasumičnih šuma. RF algoritam naučio je model s upotrebom nenadziranog filtra ponovnog uzorkovanja S1-Z 100 za 8,73 sekundi s Cc od 0,9989 i RMSE 0,1542. Dodatne informacije o rezultatima regresije prikazane su u sljedećoj tablici:

Tablica 23. Rezultati predviđanja regresijske RF metode s brzinom broda kao izlaznim parametrom

Cc	RMSE	MAE	RAE	RRSE
0,9989	0,1542	0,0644	3,1917%	4,6623%

Uzdužni nagib broda ili trim rabi se pri optimizaciji utroška energije odnosno smanjenja potrošnje goriva, posebice kod većih plovnih objekata, gdje su uštede značajnije. Mijenja se balastiranjem broda, odnosno pravilnim rasporedom tereta u brodskim skladištima kako bi se brod doveo do uzdužnog nagiba pri kojem je potrošnja goriva najmanja za zadane uvjete

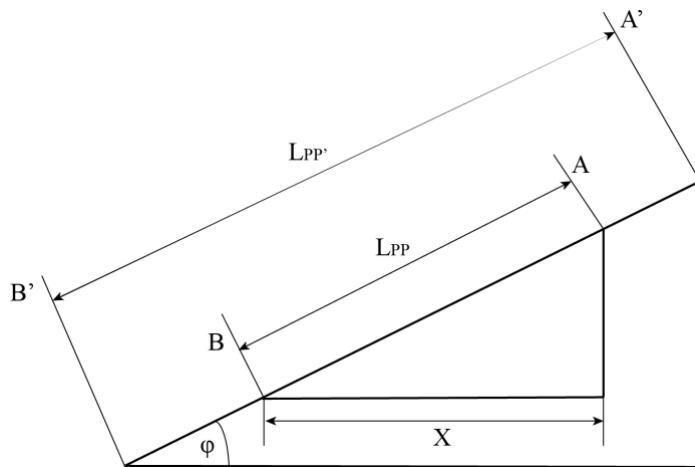
uronjenosti trupa, odnosno stanja tereta. Trim se izračunava kao razlika uronjenosti trupa između pramčane i krmene okomice (perpendikulara). S obzirom na to da uzdužni položaj senzora za mjerjenje uronjenosti ne odgovara položaju pramčane i krmene okomice, potrebna je korekcija prema sljedećim izrazima:

$$Trim = B' - A' = L_{pp'} \times \sin \varphi, \quad (69)$$

$$\varphi = \frac{\tan^{-1}(B - A)}{X}, \quad (70)$$

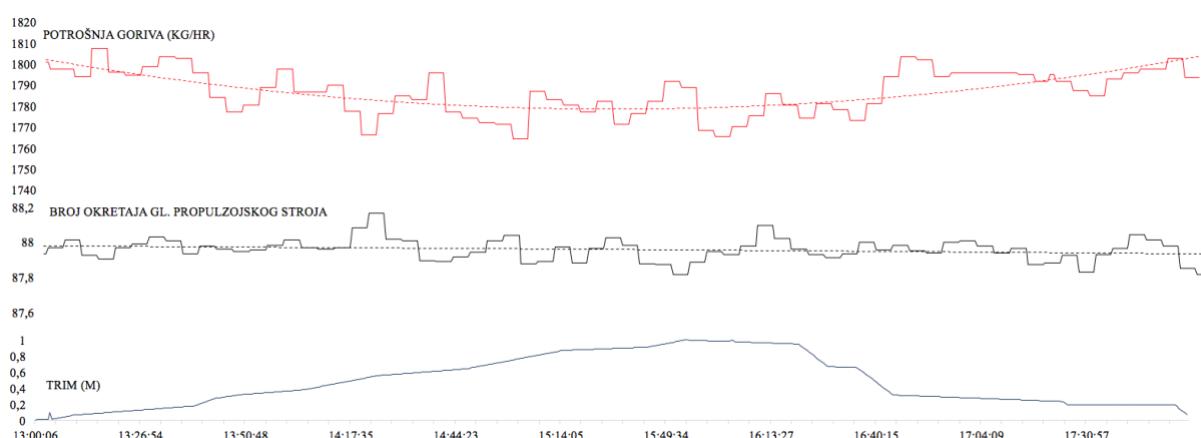
$$X = \sqrt{L_{pp}^2 - (B - A)^2}, \quad (71)$$

gdje su A i B točke centralne uzdužne linije na kojima su smješteni senzori očitanja uronjenosti, A' i B' točke centralne uzdužne linije na kojima su smještene pramčana i krmena okomica, L_{pp} duljina između točaka na kojima su smješteni senzori očitanja uronjenosti i $L_{pp'}$ duljina između pramčane i krmene okomice. Za pozitivne vrijednosti trima, brod je nagnut u smjeru krme, dok je za negativne brod nagnut u smjeru pramca.



Slika 26. Grafički prikaz osnovnih parametara za izračun uzdužnog nagiba broda

Ta varijabla može pomoći posadi broda prilikom odabira najpovoljnijeg uzdužnog nagiba s ciljem smanjenja potrošnje goriva i ispuštanja štetnog ugljikova dioksida u atmosferu, kao što je prikazano na dijagramu (Slika 27.), gdje srednja vrijednost potrošnje goriva jasno prati promjenu trima. U vremenskom razdoblju od 5 sati brodski je trim balastiranjem promijenjen s početnih 0 m na 1 m uronjenosti pramcem te natrag na 0 m. Brod je natovaren s 48394,6 MT tereta, vremenske prilike i stanje mora nisu se promijenile, a upravljačka je ručica postavljena na 88° min⁻¹ i mijenjala se unutar 1° min⁻¹. Iz priloženog se može zaključiti da predmetni brod u stanju punog tereta ima manju potrošnju goriva za propulziju ako je mu je uzdužni nagib postavljen tako da je uronjen pramcem 1 m više nego krmom.



Slika 27. Odnos trima i potrošnje goriva

Uzdužni nagib broda za potrebe je klasifikacije podijeljen u pet klasa ili razreda, koje odgovaraju graničnim vrijednostima prema realnim parametrima: $a < -1$, $-1 \leq b < 0$, $0 \leq c < 1$, $1 \leq d \leq 2$, $e > 2$. Kako u skupini od -1 m (brod uzdužno nagnut prema pramcu preko 1 m) nije bilo zabilježenih mjerjenja, skupina je izostavljena iz tablice vrednovanja klasifikacije. Intervali i broj razreda mogu se optimizirati ovisno o potrebi za usporedbom rezultata. Klasifikacijski algoritam metode RF s prethodnim postavkama bez filtriranja naučio je model za 4,09 sekundi s 18 116 od 18 499 ili 97,93% točno klasificiranih slučajeva i RMSE od 0,0879. Više informacija o rezultatima klasifikacije može se vidjeti u sljedećem prikazu (Tablica 24.) i odgovarajućoj matrici zabune (Prilog D, Tablica 46.).

Tablica 24. Vrednovanje klasifikacijske RF metode s trimom kao izlaznim parametrom

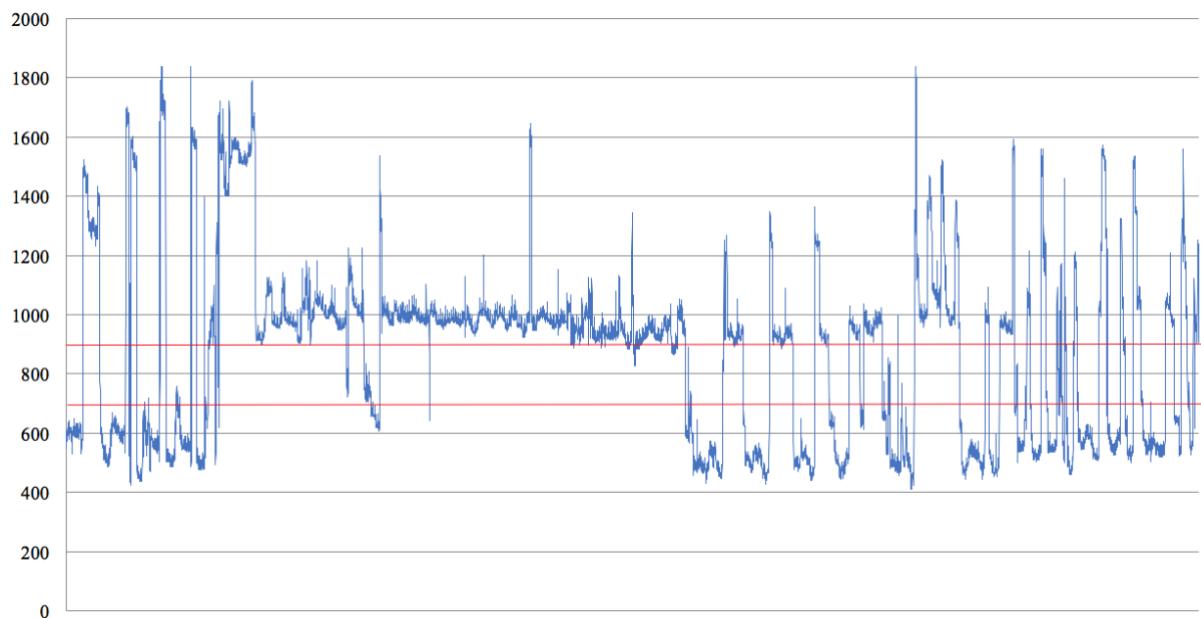
RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
b	0,912	0,001	0,932	0,922	0,921	0,993	0,960
c	0,984	0,009	0,980	0,982	0,974	0,999	0,996
d	0,911	0,011	0,903	0,907	0,897	0,993	0,953
e	0,990	0,009	0,993	0,992	0,980	0,999	0,999
WA	0,979	0,009	0,979	0,979	0,969	0,998	0,993

Algoritam regresijskog predviđanja RF naučio je model s upotrebom nenadziranog filtra ponovnog uzorkovanja S1-Z 100 za 7,00 sekundi s Cc od 0,9992 i RMSE 0,0499. Dodatne informacije o rezultatima regresije prikazane su u sljedećoj tablici:

Tablica 25. Rezultati predviđanja regresijske RF metode s trimom kao izlaznim parametrom

Cc	RMSE	MAE	RAE	RRSE
0,9992	0,0499	0,0261	2,2963%	3,9653%

Potreba za ukapljivanjem tereta na primjeru broda za prijevoz ukapljenoga naftog plina predstavljena je veličinom ukupne djelatne snage glavne razvodne ploče električne energije. Djelatna snaga električne energije potrebna za ukapljivanje tereta veća je od bilo koje druge operacije na brodu za prijevoz ukapljenoga naftnog plina koji se rabi kao primjer u ovom istraživanju te se snaga na ploči može uzeti kao parametar za praćenje ukapljivanja u ovisnosti o ostalim parametrima. Veličina ukupne djelatne snage preuzete u sedam vremenskih intervala preuzimanja podataka (Tablica 6.) na glavnoj razvodnoj ploči za potrebe je klasifikacije podijeljena u tri klase ili razreda, koje odgovaraju graničnim vrijednostima prema realnim parametrima opterećenja brodske električne mreže: $a < 700$, $700 \leq b \leq 900$, $d > 900$ (Slika 28.).



Slika 28. Snaga na glavnoj razvodnoj ploči (kW)

Sve tri vrijednosti predstavljaju potrošnju za vrijeme plovidbe tako da prva predstavlja opterećenje mreže sa smanjenom potrošnjom, druga normalnu potrošnju, a treća potrošnju s radom postrojenja za ukapljivanje tereta. Intervali su preuzeti iz brodskog nacrtta analize električnog opterećenja (engl. *electrical load analyses drawing*). Kao što je već navedeno kod drugih izlaznih varijabli, intervali i broj razreda mogu se optimizirati ovisno o potrebi za usporedbom rezultata. Klasifikacijski algoritam metode RF s prethodnim postavkama bez filtriranja naučio je model za 5,34 sekunde s 18 145 od 18 499 ili 98,09% točno klasificiranih slučajeva i RMSE od 0,103. Više informacija o rezultatima klasifikacije može se vidjeti u sljedećem prikazu (Tablica 26.) i odgovarajućoj matrici zabune (Prilog D, Tablica 47.).

Tablica 26. Vrednovanje klasifikacijske RF metode s potrebom za ukapljivanjem tereta kao izlaznim parametrom

RAZRED	TPR	FPR	PPV	MJERA F ₁	MCC	AUROC	AUPRC
a	0,992	0,009	0,984	0,988	0,981	0,999	0,999
b	0,752	0,005	0,867	0,805	0,799	0,973	0,864
c	0,991	0,021	0,986	0,988	0,971	0,999	0,999
WA	0,981	0,016	0,980	0,980	0,967	0,998	0,993

Algoritam regresijskog predviđanja RF naučio je model s upotrebom nenadziranog filtra ponovnog uzorkovanja S1-Z 100 za 7,91 sekundu s Cc od 0,9946 i RMSE 30,5164. Dodatne informacije o rezultatima regresije prikazane su u sljedećoj tablici:

Tablica 27. Rezultati predviđanja regresijske RF metode s potrebotom za ukapljivanjem tereta

Cc	RMSE	MAE	RAE	RRSE
0,9946	10,4066	8,9974	3,8113%	10,4066%

5. PRIJEDLOG MODELA NADZORA I PREDVIĐANJA ENERGETSKE UČINKOVITOSTI I ISPUŠTENOG UGLJIKOVA DIOKSIDA NA PRIMJERU BRODA ZA PRIJEVOZ UKAPLJENOGA NAFTNOG PLINA

Za potrebe definiranja modela nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina rabljena je opća teorija sustava [159]. Opća teorija sustava u najširem smislu odnosi se na zbirku općih koncepata, principa, alata, problema, metoda i tehnika u izravnoj vezi sa sustavima. Iako naziv „sustav” može imati različita značenja u različitim okolnostima, on uobičajeno označava raspored određenih, međusobno povezanih komponenti, tako da međusobno tvore cjelinu [160] [161]. Opća teorija sustava upućuje na razlikovanje otvorenih i zatvorenih sustava. Na otvorenost sustava upućuje jedan od tvoraca opće teorije sustava, Ludwig von Bertalanffy, koji smatra da je dinamična interakcija komponenti modela otvorenog sustava njegova temeljna oznaka. Ako bi sustav bio zatvoren i ne bi s okolinom razmjjenjivao materiju, energiju i informacije, okolina ne bi bila u stanju prepoznati takav sustav [159].

5.1. Osnovna obilježja sustava

U definiranju sustava polazi se od temeljnog određenja po kojemu se sustav mora pojmiti krajnje formalno kao skupina identiteta koji se održavaju u kompleksnoj i promjenjivoj okolini stabiliziranjem razlike između unutrašnjosti i vanjštine. Sustav se stvara iz nepromijenjenih i na okolinu usmjerenih smislenih struktura čija je zadaća smanjenje složenosti [162]. Organizacija sustava jest skup svih svojstava sustava koja uzrokuju ponašanje sustava, dok je struktura onaj dio organizacije koji ostaje nepromijenjen, utvrđen ili konstantan i čini osnovu za permanentno ili relativno permanentno ponašanje. Luhmannova definicija osobito je važna za razumijevanje problema složenosti sustava te polazi od stajališta da je zadaća sustava redukcija kompleksnosti okoline. U tu svrhu na raspolaganju su četiri mogućnosti:

1. objektivna situacija zamjenjuje se subjektivnom, tj. djelovanje sustava nije određeno zbiljom, nego je usmjereno sustavnom predodžbom
2. okolina se sustava u određenoj mjeri pojednostavljuje i imobilizira tako da se institucionaliziraju određeni oblici obrade doživljaja

3. strategija diferenciranja okoline sastoji se u tome da sustav stvara posebne granice za svaki pojedini isječak okoline te na tim granicama stabilizira odnose i temelji svoju autonomiju i svoju sposobnost za indiferentnost spram promjena okoline upravo na diferenciranju
4. u mjeri neodređenosti strukture sustava, što je sustav sebi može priuštiti, a da ne izgubi svoj potencijal selekcije, iz čega proizlazi daljnja sistemska strategija

Dio strukture sustava koji je osnova za permanentno ponašanje, a naziva se i realnom strukturom, jest upravo onaj dio koji u stvarnosti nije moguće u potpunosti prepoznati u sustavu koji se promatra, dok je dio strukture koji predstavlja osnovu za relativno permanentno ponašanje dokučiv i naziva se hipotetička struktura. Proučavanjem sustava kao cjeline razvidno je da se svaki sustav može rastaviti na elemente od kojih svaki predstavlja zasebni sustav s ponašanjem prema zakonitostima tog sustava. Dakle, svaki je sustav podsustav nekoga višeg sustava, koji se obično označuje njegovom okolinom, a s kojim razmjenjuje tvari (materiju), energiju i informacije. Luhmann konstatira da je pripadnošću nekom sustavu i njegovim podsustavima zajamčena okolina manje nesigurnosti i kompleksnosti, i to ih osposobljava da ispunjavanjem svojih podsvrha dalje smanjuju postojeću kompleksnost [162]. Okolina sustava predstavlja onaj element koji može proizvesti značajne promjene unutar sustava, bez obzira na tip sustava o kojemu je riječ. U empirijskoj se znanosti sve ono što nije pod izravnim razmatranjem smatra okolinom sustava. Osim naznačenih momenata okoline koji dovode u pitanje opstojnost sustava kao skladne i povezane cjeline, nesumnjivo je da i unutarsustavski razlozi i nesklad među objektima i njihovim atributima (vrijednosti atributa mogu biti numeričke i nenumeričke prirode) mogu stimulirati promjene u sustavu ili prema njegovoj okolini. Entropija je pojam suprotan organiziranosti i informaciji te predstavlja mjeru pomanjkanja informacije, nefunkcionalnosti i neorganiziranosti pojedinog sustava, odnosno mjeru neodređenosti sustava. Kako bi entropija bila što manja, sustav se mora potruditi da u interakciji s okolinom djeluje neentropski, odnosno mora smanjivati dezintegrativne učinke okoline. Informacije koje su suprotnog djelovanja od entropije mogu poništiti entropiju u procesu upravljanja. Sastav komponenti sustava jest supstancialna, sadržajna strana cjelovitog sustava, osnova njegove strukture. Mijenjanje jednog od dijelova sustava povlači za sobom i promjenu drugih dijelova, a nerijetko i čitavog sustava. Mjerenjem ili promatranjem vrijednosti atributa pojedinog objekta u obzir se uzima prostorno-vremenska odrednica (specifikacija vrijeme-prostor). Točnosti i učestalost (frekvencija) bilježenja izabralih veličina predstavlja razinu prostorno-vremenske rezolucije ili razinu razlučivanja. Za neke veličine vremenska i/ili

prostorna specifikacija potpuno su nevažne, tj. u potpunosti je moguće da aktivnost sustava nije izravna posljedica mjerena ili promatranja, primjerice, ako su izabrane veličine statističke prirode, aktivnost se može odnositi na obradu podataka. Ako su veličine izabrane i ako je svakoj dodijeljena razina razlučivanja, tada je njihova vrijednost matrica, tj. varijacija vrijednosti veličine u vremenu (počevši od $t = 0$), koja se naziva matricom aktivnosti sustava. Stoga je aktivnost sustava kontinuirani prikaz varijacija od kojih se uzimaju uzorci, gdje se rezolucijom određuje broj mjerjenih točaka, a iz rezultata se određuju vremenski nepromjenjivi odnosi tih veličina. Promatranjem aktivnosti sustava pokušavaju se zapravo odrediti oni odnosi između promatranih veličina koji su zadovoljeni tijekom čitavog vremenskog intervala. Ti su odnosi, dakle, vremenski nepromjenjivi ili vremenski invarijantni, a promatranjem se nastoje utvrditi svojstva koja ih određuju i način na koji su sastavljeni od jednostavnijih odnosa. Pritom treba razlikovati tri moguća ponašanja sustava [160]:

1. *permanentno ili realno ponašanje sustava* koje je zasnovano na absolutnim odnosima (relacijama) koji su definirani u cijelom vremenskom intervalu aktivnosti,
2. *relativno permanentno ili poznato ponašanje sustava* koje je definirano relativnim odnosima koji su zadovoljeni svugdje unutar određenih aktivnosti, odnosno: kada je aktivnost definirana, odnos unutar nje mora biti sadržan, te je upravo to ponašanje ono od izravnog zanimanja (interesa) istraživanja i
3. *povremeno ili lokalno ponašanje sustava* predstavlja odnose koji su zadovoljeni unutar jednog dijela određene aktivnosti, a sastavni je dio relativno permanentnog ponašanja sustava.

Pritom je važno naglasiti da je svakom konkretnom sustavu svojstvena njegova specifična organizacija, pri čemu se složenošću sustava povećavaju stupnjevi njegove diferencijacije, što povećava složenost same strukture. Granice diferencijacije i integracije sustava moraju biti vrlo elastične kako ne bi došlo do narušavanja ravnoteže. Kako je logično da svaki sustav teži uspostavi ravnoteže među ovim suprotstavljenim načelima, dolazi do pojave u kojoj se svaki sustav samim svojim postojanjem i konzistencijom svoje ravnoteže opire promjenama [163]. Sustav se jednoznačno može odrediti na osnovi dvije skupine podataka: cjeline svih elemenata i njihovih međusobnih veza (UC struktura) i strukture stanja i prijelaza između stanja (ST struktura) [160, 46]. Razmatranjem UC strukture uočljivo je da veze između dva elementa predstavljaju skup svih zajedničkih atributa između tih elemenata, odnosno njihov presjek, dok se ST strukturu definiraju sva moguća stanja i svi mogući prijelazi između elemenata, te, ako

je moguće, vjerojatnosti tih prijelaza, ili se sustav vodi iz jednog stanja u drugo onda kada prijelazi nisu stohastički. Pritom veze između elemenata predstavljaju zapravo informacijske tokove. Programi su onaj dio organizacije koji je promjenjiv i koji u svakom trenutku predstavlja relevantno stanje sustava, skup nekih drugih stanja i skup prijelaza iz trenutnog stanja u stanja koja se razmatraju u vremenu, te se mogu razlikovati tri vrste programa:

1. *kompletni programi* – obuhvaćaju sva stanja i prijelaze između njih,
2. *potprogrami* – obuhvaćaju trenutno stanje i jedan podskup svih mogućih prijelaza i
3. *trenutni programi* – obuhvaćaju trenutno stanje zajedno sa svim prijelazima iz tog stanja.

Promjene u sustavu nastaju uslijed postojanja zavisnih i nezavisnih veličina u samom sustavu. Pritom se nezavisne veličine mijenjaju neovisno o promatranom sustavu, a mijenjanje je posljedica promjena u okolini (okruženju) sustava. Iz toga je vidljivo da se sustav može kontrolirati izvana tako da se kontroliraju nezavisne varijable i u tom slučaju postaje kontrolirani sustav. Analogno navedenom, veličine ovisne samo o promatranom sustavu ne mogu se kontrolirati iz okruženja, te je sustav neutralan s obzirom na promjene izvana, što ukazuje na važnost određivanja granica promatranog sustava. Dio ulaznih veličina transformira se u izlazne (korisne) veličine kojima se ostvaruje cilj sustava, a dio se troši na funkcioniranje samoga sustava, tj. transformira se u nekorisne (neiskoristive) izlazne veličine. Kako bi sustav mogao ostvarivati postavljene ciljeve, njime se mora upravljati. Sustav bez upravljanja teži stanju potpune entropije. Upravljanje sustavom, tj. njegovo održavanje u željenom stanju, svodi se na dodavanje novih informacija u sustav, čime se smanjuje neodređenost sustava. Za ostvarivanje ciljeva sustava, odnosno povećanje njegove učinkovitosti, ključne su specijalizacije i integracije. Sustav može biti kompleksan, odnosno teško raščlanjiv, s velikim brojem elemenata i veza među tim elementima. Kompleksnost sustava uobičajeno se rješava metodom agregacije, odnosno združivanjem elemenata sustava u podsustave na temelju slučajnog ponašanja ili prostornog rasporeda, ili metodom apstrakcije pogodne u slučajevima nedostatne određenosti kada se smanjuje rezolucija upotrebom intervala umjesto pojedinačnih vrijednosti. Za jasno definiranje sustava potrebno je utvrditi objekt istraživanja, odrediti gledište te definirati veličine i razinu razlučivosti na kojoj će se te veličine promatrati. Stoga se sustav definira četirima osnovnim svojstvima: promatrani skup veličina, razina razlučivanja, vremenski invarijantni odnosi među promatranim veličinama, te karakteristike koje određuju ti odnosi, iz čega je moguće razlučiti kakvo će biti njegovo ponašanje s određenog točno

utvrđenog gledišta. U nastavku je primijenjen model sustava za modeliranje brodskog sustava nadzora i predviđanja energetske učinkovitosti.

5.2. Opis postojećeg stanja

Postojeće stanje na brodu obuhvaća postupke i mjere učinkovitije uporabe energetskih izvora i kontrole emisija ugljikova dioksida, a koje su preuzete iz obvezujuće pravne regulative i relevantnih standarda upravljanja. Brodar u svome sustavu upravljanja sigurnošću, definira i dokumentira izvore, uloge, odgovornosti i ovlaštenja svih osoba ili odjela koji upravljaju, izvode i provjeravaju postupke i utjecajne faktore u svezi s provedbom i upravljanjem komponentama zaštite okoliša kako bi se ostvarila učinkovita kontrola. Sukladno odredbama brodskog sustava upravljanja, zapovjednik broda odgovoran je za provedbu i održavanje svih elemenata sustava upravljanja energetskim izvorima i zaštite okoliša te je dužan osigurati provedbu obvezujućih zahtjeva vezanih za zaštitu okoliša. Upravitelj stroja odgovoran je za praćenje učinka, održavanje postrojenja te provedbu svih korektivnih postupaka nakon procjene vrijednosti potrošnje u skladu sa zahtjevima SEEMP-a. Brodar uspostavlja formalni proces identifikacije potrošača energije i varijabli koje utječu na potrošnju u svim uvjetima operacije brodom. Proces uključuje studiju izvodljivosti mjera za poboljšanje energetske učinkovitosti uporabom tehničkih ili operativnih sredstava. Razina uspješnosti takvih mjera ocjenjuje se upotrebom pokazatelja energetske učinkovitosti u odnosu na definirane ciljeve. Energetskim planiranjem upravlja odjel za upravljanje energijom i provodi se uz pomoć raspoloživih izvora. Posljedica je toga akcijski plan provedbe energetskih ušteda, što dovodi do specifičnih ciljeva. Plan je sastavljen od mjera jednostavne energetske učinkovitosti do tehničkih mjera i modernizacije postojeće opreme ili promjena u postojećim postupcima tvrtke i može se sažeti u šest skupina djelovanja:

1. uspostavljanje i održavanje dokumentiranih postupaka za stanja u kojima može doći do odstupanja od politike i ciljeva brodara,
2. utvrđivanje operativnih kriterija u postupcima,
3. uspostava i održavanje postupaka vezanih uz utvrđivanje značajnih aspekata okoliša za robu i usluge od strane brodara i priopćavanje ugovaratelja i dobavljača relevantnih postupaka i zahtjeva,
4. izbjegavanje ili minimiziranje rizika za okoliš,
5. uspostavljanje procedure ili formalno (kroz energetsko planiranje i akcijske planove) ili u obliku jednostavnih instrukcija za učinkovito rukovanje opremom, upravljanje energijom na brodu, navigacija plovila (uvjetovanje) i modifikacija postojeće opreme i

6. osiguravanje usklađenosti sa zakonskim zahtjevima i drugim zahtjevima kojima se brodar obvezuje.

Za planiranje putovanja i optimizaciju navigacijskih postupaka rabi se vanjska usluga vremenskih prognostičara. Senzorski se podaci iz brodskog sustava nadzora i upravljanja postrojenjem te navigacijskog sustava obrađuju, no ne pohranjuju se i ne rabe s ciljem otkrivanja novih informacija, odnosno otkrivanja skrivenih obrazaca ponašanja. Podaci vezani uz nadzor potrošnje energije i količinu ispuštenog ugljikova dioksida ručno se unose u obrasce koje propisuje brodar. Na predmetnome brodu ugrađen je vanjski (brodski) komunikacijski sustav koji omogućuje prijenos i primanje uputa, naredbi, naloga, izvješća, kao i komuniciranje i izmjenu podataka s uredom i ostalim sudionicima u pomorskom pothvatu.

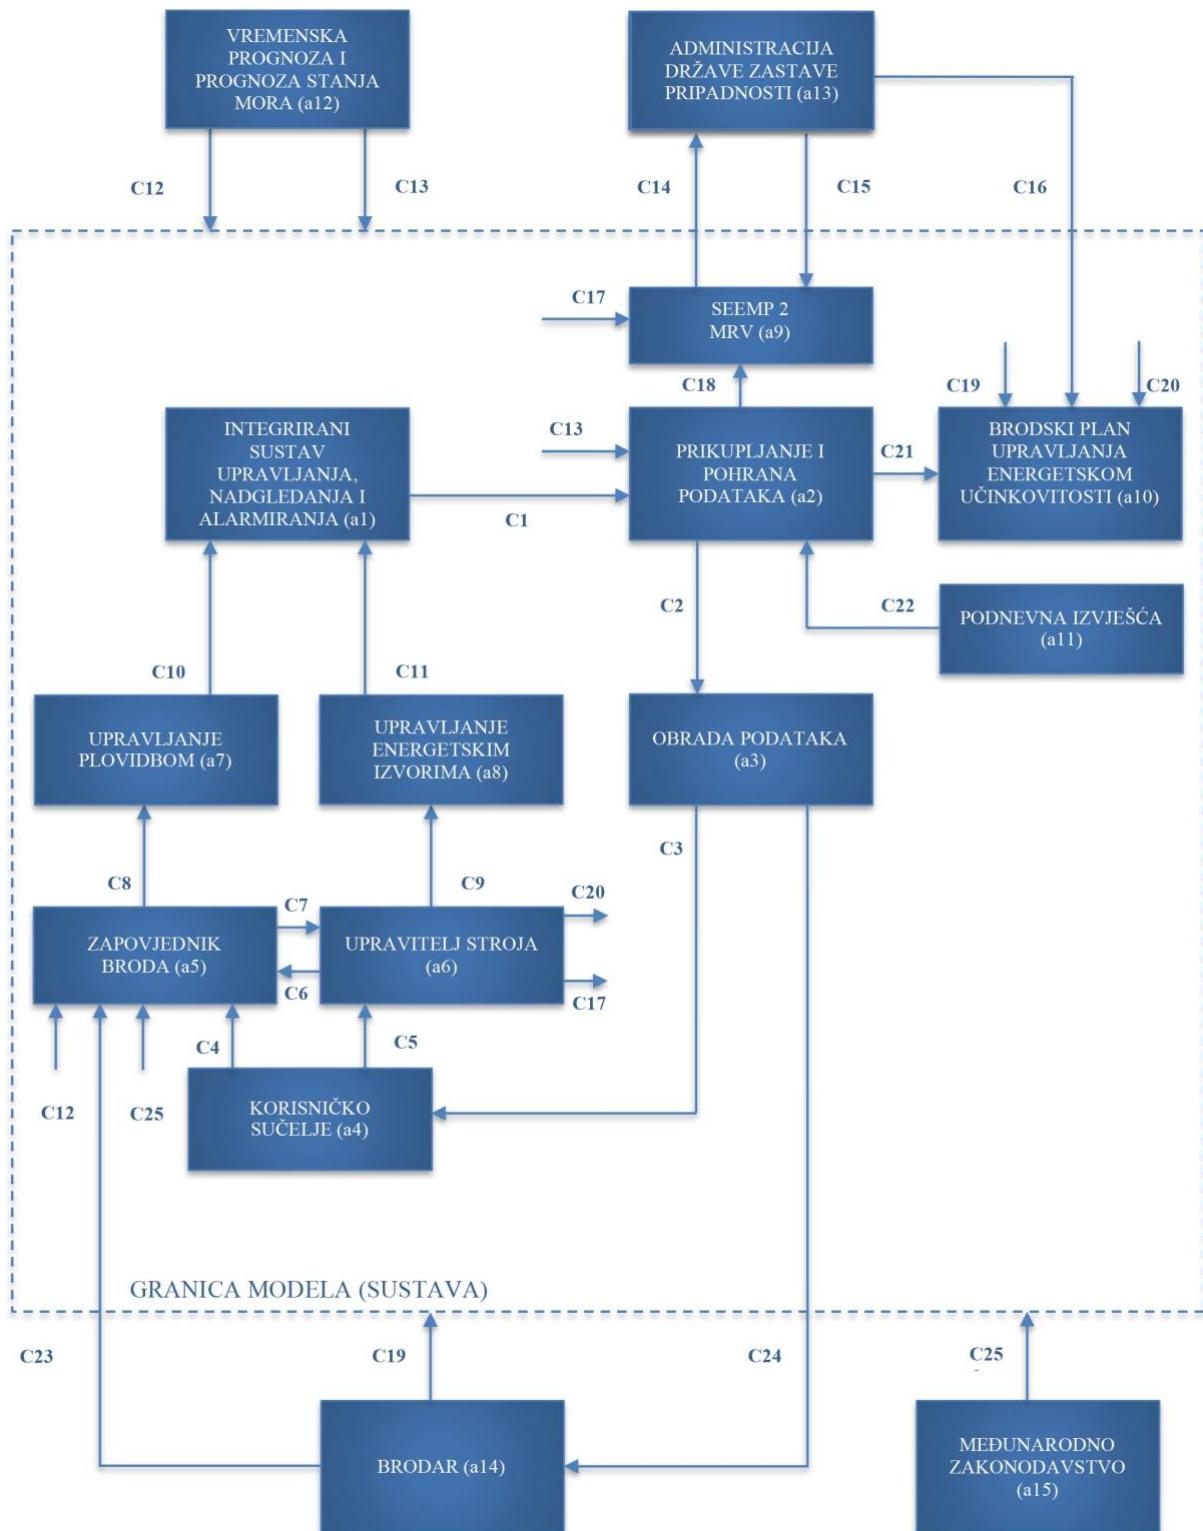
Odjel upravljanja energijom brodara sastaje se u vremenskim razdobljima ne duljim od jedne (1) godine. Međutim, ako je razdoblje za postizanje cilja za određenu mjeru definirano za kraće vremensko razdoblje (npr. tromjesečno), tada se procjena provodi na kraju razdoblja koje se podudara s cilnjim okvirom.

5.3. Prijedlog strukture novog sustava

Uočavajući nedostatke postojećeg sustava u kojem se ulazne varijable korigiraju s vremenskim odmakom (vezanim za vrijeme postizanja postavljenog cilja) te služeći se podacima koji se ručno unose u sustav, uvažavajući statutarne promjene oko izvješćivanja vezanih za potrošnju energije i ispuštanje ugljikova dioksida, kao i nedostatnu obradu raspoloživih senzorskih podataka, predložen je model nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina koji je definiran UC (engl. *universe of discourse and couplings*) (Slika 29.) i ST (engl. *state transition*) strukturom (Slika 30.) modela. U predloženom modelu uvedena je dinamička interakcija među komponentama sustava, koja je omogućena povratnim djelovanjem na ulazne varijable kao što su, primjerice, broj okretaja glavnog pogonskog stroja, smjer plovidbe, uzdužni nagib broda (trim) i potreba za ukapljivanjem tereta, čijom je promjenom moguće utjecati na potrošnju goriva i količinu ispuštenog ugljikova dioksida. Povratna se veza ostvaruje primjenom algoritama strojnog učenja na podatke koji se pretvaraju u informacije (C4) i čije je izlazne predikcijske vrijednosti moguće usporediti s trenutnim stanjem te izvršiti neophodnu korekciju ulaznih vrijednosti (Slika 29.). Informacije o učinkovitijem upravljanju brodom i brodskim sustavima dostupne su u uredu brodara (C24) te se mogu rabiti prilikom korigiranja postojećeg brodskog plana energetske učinkovitosti (C19), sklapanja ugovora o prijevozu tereta i kreiranja

poslovne politike. Uvođenjem novih informacija u sustav smanjuje se neodređenost, što je temeljna osobina predloženog modela. Organiziranjem informacija one postaju znanje o postupcima i mjerama uštede energije koje je moguće upotrijebiti pri optimizaciji potrošnje goriva, pri uvođenju novih sustava na projektnoj razini, kao i za unaprjeđenje energetskog sustava i koeficijenta energetske učinkovitosti prilikom gradnje brodova. Daljnja osobina predloženog modela jest redukcija kompleksnosti okoline koja se postiže automatiziranim ispunjavanjem SEEMP i MRV izvješća. Kontrola unošenja podataka i dalje je prepuštena upravitelju stroja, no može biti izostavljena nakon potvrde u praksi.

Važno je napomenuti da su na UC strukturi modela (Slika 29.) prikazani ključni elementi sustava (komponente) koji dijele zajedničke atributte na jednakoj razini razlučivosti te razmjenjuju informacije koje su vezane za predloženi sustav (model). Predloženi se model služi postojećim zakonodavnim i institucijskim pretpostavkama kao i operativnim tijelima nužnim za njihovo provođenje te postojećim tehnološkim preduvjetima. Nove su fizičke komponente predloženog modela sustav prikupljanja i pohrane podataka (a2), računalna obrada podataka (a3) i korisničko sučelje vizualizacije (engl. *graphical user interface, GUI*) preko kojeg je informacija dostupna krajnjem korisniku u obliku znakova, slika i dijagrama (a4). Za izvođenje zadanog procesa i adekvatnu izmjenu informacija s ostalim komponentama sustava potrebna je (namjenska) programska podrška. Takva programska podrška uključuje metode i modele strojnog učenja te se povezuje s ostalim dijelovima sustava pomoću ulaznih i izlaznih varijabli. Elementi upravljanja plovidbom (a7) i energetskim sustavima (a8) preuzeti su iz postojećeg sustava jer prikladno agregiraju postupke na višu razinu razlučivosti.



Slika 29. UC – struktura modela

Značenje pojedinih elemenata sustava:

a1 – integrirani sustav upravljanja, nadgledanja i alarmiranja (engl. *integrated automation system, IAS*),

a2 – prikupljanje i pohrana podataka, $x_{1-n}(t)$ preuzima podatke s IAS sustava, brodskog navigacijskog sustava, podatke iz brodskih podnevnih izvješća te meteorološke i oceanografske podatke iz vanjskih izvora,

a3 – obrada podataka postupcima strojnog učenja koja objedinjuje odabir relevantnih ulaznih parametara, vremensko ujednačenje, smanjenje broja potrebnih primjeraka i povrat izgubljenih ili nepotpunih podataka te primjenu odgovarajućeg algoritma strojnog učenja na zadane parametre, učenje i vrednovanje modela, predviđanje, odnosno izvođenje postupaka otkrivanja znanja iz podataka,

a4 – korisničko sučelje za vizualizaciju i podršku pri odlučivanju (DSS) prikazuje rezultate predviđanja izlaznih varijabli $y_{1-n}(t)$ (potrošnja goriva glavnog propulzijskog stroja, EEOI, EnPI, specifična potrošnja goriva glavnog propulzijskog stroja, brodska sklis (slip), brzina broda (preko dna), uzdužni nagib broda (trim) i potreba za ukapljivanjem tereta) usporedno sa zadanim vrijednostima (SEEMP, probna vožnja, ugovor o prijevozu i sl.), čime je omogućena usmjerena korektivna akcija,

a5 – zapovjednik broda najviši je i odlučujući autoritet vezan za sigurnost plovidbe, zaštitu okoliša, prijevoz tereta, obavljanje putovanja, izvješćivanje i provedbu politike tvrtke te kontrolu troškova; u obavljanju navedenih dužnosti pomaže mu prije svega upravitelj stroja i prvi časnik palube te ostali članovi posade,

a6 – upravitelj stroja zadužen je za održavanje postrojenja na palubi i u strojarnici, nadzor nad transferom i bunkerom goriva, upravljanje manevrom iz strojarnice (po potrebi), kontrolu i narudžbu rezervnih dijelova te provedbu SEEMP plana,

a7 – upravljanje plovidbom sadrži organizacijske i tehničke elemente upravljanja i izvješćivanja te relevantne postupke s ciljem osiguranja sigurnosti plovidbe sadržane u brodskom sustavu sigurnog upravljanja; u slučajevima kada je ugrožena sigurnost posade, broda i tereta, zapovjedniku broda dana je mogućnost nadvladavanja postupaka i donošenja konačne odluke,

a8 – upravljanje energetskim izvorima sadrži organizacijske i tehničke elemente upravljanja i izvješćivanja prema smjernicama za optimalnu uporabu energetskih izvora (sadržane u brodskom sustavu sigurnog upravljanja),

- a9 – SEEMP (2) i MRV brodski plan izvješćivanja,
- a10 – brodski plan upravljanja energetskom učinkovitosti (SEEMP),
- a11 – podnevna izvješća,
- a12 – vremenska prognoza i prognoza stanja mora,
- a13 – Administracija države zastave pripadnosti, odnosno priznata organizacija (engl. *Recognized Organization, RA*),
- a14 – brodar sa sustavom upravljanja brodom i energetskom učinkovitosti te poslovnom politikom,
- a14 – međunarodno zakonodavstvo i njegovi izvršni elementi,
- C1 – prikupljeni senzorski podaci $x_{1-n}(t)$ s integriranog sustava upravljanja, nadgledanja i alarmiranja te brodskog navigacijskog sustava: broj okretaja glavnog pogonskog stroja (1), brzina (6) i smjer vjetra (26) s anemometra, temperatura zraka (9), temperatura mora (10), uzdužni nagib broda (11), poprečni nagib broda (12), srednja uronjenost broda po sredini (13) i brodski kurs preko dna (14),
- C2 – prikupljeni podaci C1 prema obradi podataka,
- C3 – skup izlaznih podataka $y_{1-n}(t)$ nakon algoritama strojnog učenja prema korisničkom sučelju: potrošnja goriva glavnog propulzijskog stroja (3), EEOI, EnPI, specifična potrošnja goriva glavnog propulzijskog stroja (2), brodski skliz (slip) (27), brzina broda (preko dna) (4), uzdužni nagib broda (trim) (11) i potreba za ukapljivanjem tereta (8),
- C4 – grafički prikaz izlaznih vrijednosti prema zapovjedniku broda,
- C5 – grafički prikaz izlaznih vrijednosti prema upravitelju stroja,
- C6 – sugestija upravitelja stroja prema zapovjedniku vezana za unaprjeđenje energetske učinkovitosti,
- C7 – odluka zapovjednika prema upravitelju stroja vezana za optimizaciju upravljanja energetskim izvorima (broj okretaja glavnog propulzijskog stroja, smjer kretanja broda, potreba za ukapljivanjem tereta),
- C8 – odluka zapovjednika prema sustavu upravljanja i odlučivanja o plovidbi,
- C9 – odluka upravitelja stroja o sustavu upravljanja energetskim izvorima (broj generatora na mreži, broj rashladnih pumpi u radu, i sl.),
- C10 – izlazne veličine iz sustava navigacijskog upravljanja i odlučivanja,
- C11 – izlazne veličine iz sustava upravljanja energetskim izvorima,
- C12 – meteorološki i oceanografski podaci prema zapovjedniku broda,

C13 – meteorološki i oceanografski podaci prema sustavu prikupljanja i pohrane podataka: u komponenta vjetra (15) i v komponenta vjetra (16), udar vjetra (17), značajna visina vala (18), smjer vala (19), perioda vala (29), smjer mora (21) i brzina morske struje (22),

C14 – podaci iz SEEMP (2) i MRV prema Administraciji države zastave pripadnosti, odnosno priznatoj organizaciji,

C15 – odobrenje, periodični pregled i izmjene u regulativi SEEMP (2) i MRV plana od strane Administracije države zastave pripadnosti, odnosno priznate organizacije,

C16 – odobrenje, periodični pregled i izmjene regulative SEEMP (1) plana od strane Administracije države zastave pripadnosti, odnosno priznate organizacije,

C17 – kontrola i korekcija podataka unesenih u SEEMP (2) i MRV izvješća od strane upravitelja stroja,

C18 – podaci prema brodskom SEEMP (2) i MRV iz sustava prikupljanja i pohrane podataka,

C19 – postavljanje ciljeva i nadgledanje provođenja mjera ušteda energije od strane odjela upravljanja energijom brodara,

C20 – kontrola i korekcija podataka unesenih u izvješća SEEMP-a od strane upravitelja stroja

C21 – podaci iz sustava prikupljanja i pohrane podataka prema SEEMP-u,

C22 – opservacijski podaci iz brodskih podnevnih izvješća prema sustavu prikupljanja i pohrane podataka: visina vala (23), mrtvo more (24) i snaga vjetra (25),

C23 – putni nalog i ostali operacijski postupci,

C24 – skup izlaznih varijabli $y_{1-n}(t)$ prema sustavu upravljanja energetskom učinkovitosti brodara i sustavu upravljanja brodom nakon algoritama strojnog učenja: potrošnja goriva glavnog propulzijskog stroja (3), EEOI, EnPIFC, specifična potrošnja goriva glavnog propulzijskog stroja (2), brodski skliz (slip) (27), brzina broda (preko dna) (4), uzdužni nagib broda (trim) (11) i potreba za ukapljivanjem tereta (8), usporedno sa zadanim vrijednostima (SEEMP, probna vožnja, ugovor o prijevozu i sl.),

C25 – zahtjevi međunarodnog zakonodavstva i različitih izvršnih tijela koja ih provode prema zapovjedniku broda.

Utjecaji na sustav mogu se podijeliti u dvije osnovne skupine:

- utjecaji unutar granica modela, odnosno ulazna vrijednost broja okretaja glavnog propulzijskog stroja, smjer kretanja broda, nalog za ukapljivanjem tereta, odluka o broju generatora spojenih na brodsku električnu mrežu, broj rashladnih pumpi u radu, i sl.,

- utjecaji izvan granica modela (sustava), kao što su vremenski uvjeti i stanje mora, putni nalog (engl. *voyage order*), obvezujuće odredbe međunarodnog zakonodavstva.

Neprekinuta obrada većeg broja⁴² senzorskih podataka uvjetovala je računalnu obradu na brodu, dok je internet stvari (engl. *internet of things, IoT*), preuvjet daljinskog upravljanja brodom, odnosno autonomne plovidbe, preostao kao opcija u budućnosti, kada širokopojasna izmjena podataka s mogućnošću upravljanja u realnom vremenu bude potvrđena u praksi.

Tablica 28. daje prikaz mogućih stanja sustava (modela) i prijelaza između stanja gdje su stanja sustava kako slijedi:

S0 – nepostojanje modela niti baze podataka (sadašnje stanje),

S1 – postavljen je model koji omogućuje prikupljanje relevantnih operacijskih podataka,

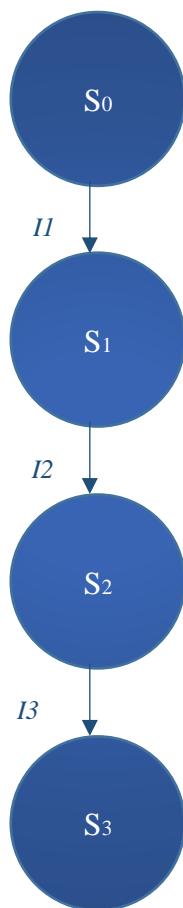
S2 – utvrđeno je početno (nulto stanje), čime model postiže punu funkcionalnost predviđanja i potpore pri donošenju odluka o optimizaciji potrošnje energije i smanjenju ispuštanja ugljikova dioksida u atmosferu,

S3 – kontinuirani nadzor i održavanje modela.

Tablica 28. Prijelazi između stanja

STANJE	PRIJELAZ	IZLAZ
S0 – nepostojanje modela	I1 – postavljanje znanstveno prihvaćenog modela koji opisuje, predviđa i omogućuje prilagodbu relevantnih operacijskih parametara broda	S1 – postavljeni i prihvaćen model
S1 – prihvaćeni model	I2 – prikupljanje podataka	S2 – utvrđeno početno (nulto) stanje
S2 – utvrđeno početno (nulto) stanje	I3 – kontinuirani nadzor i održavanje modela	S3 – potpuna funkcionalnost modela

⁴² Podatkovni promet IoT platforme tvrtke Inmarsat (Fleet Xpress) neograničenog broja varijabli dostupan je od polovice 2019. godine (Inmarsat, 2019).



Slika 30. ST – struktura modela

5.4. Analiza i rasprava o dobivenim rezultatima

Prema predstavljenom modelu nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina vidljivo je da će kontinuirani nadzor nad relevantnim operacijskim parametrima, mogućnost predviđanja istih, te povratno djelovanje na ulazne vrijednosti pridonijeti učinkovitijem upravljanju energetskim izvorima i smanjenju onečišćenja atmosfere ugljikovim dioksidom i omogućiti uvid u stvarno stanje, kao i moguće mjere smanjenja potrošnje goriva i sprječavanja onečišćenja, od čega će svi čimbenici u pomorskom pothvatu imati višestruku korist. Uz kontinuirane promjene vanjskih uvjeta izazov je odgovarajuća struktura koja dezintegrativne učinke okoline smanjuje na najmanju moguću vrijednost. Pomanjkanje informacija povećava entropiju sustava te je slijedom navedenog primjeroeno procjenu primjenjivosti modela promotriti kroz analizu njegovih snaga, slabosti, mogućnosti i prijetnji (engl. *strengths, weaknesses, opportunities and threats, SWOT*). Snage i slabosti predstavljaju unutarnje karakteristike sustava (modela), dok mogućnosti i prijetnje dolaze iz okruženja. Zbog svoje integrirajuće i obuhvatne uloge često se

označava kao unutarnje-vanjska analiza, dok se SWOT matrica naziva i matrica unutarnjih i vanjskih čimbenika [164]. Postupak je izgradnje SWOT analize sljedeći [165]:

1. identifikacija snaga, slabosti, mogućnosti i prijetnji
2. određivanje važnosti i vjerojatnosti pojavljivanja
3. analiza odnosa mogućnosti sa snagama i slabostima te prijetnji sa snagama i slabostima
4. identifikacija strateških alternativa

Tablica 29. Tablica identifikacija SWOT elemenata modela

SNAGE (S)	SLABOSTI (W)	MOGUĆNOSTI (O)	PRIJETNJE (T)
S1. Predviđanje relevantnih operacijskih parametara i neprekinuto praćenje stanja	W1. Vrijeme početnog učenja na podacima onemogućuje predviđanje u ranoj fazi implementacije sustava	O1. Integracija broda i ureda u zajednički informatički sustav praćenja i donošenja odluka	T1. Predloženi model nije prepoznat kao koristan alat praćenja operacijskih parametara i donošenja odluka
S2. Utjecaj na korekciju postojećeg SEEMP-a	W2. Za potrebe kvalitetnog predviđanja neophodno je pokriti sve scenarije vanjskih uvjeta i operacijskih postupaka	O2. Predloženi je model priprema daljinskog ili automatiziranog upravljanja brodom	T2. Promjena vanjskih čimbenika, poput relevantnih propisa, smjernica i standarda
S3. Unaprjeđenje energetskog sustava i EEDI na projektnoj razini	W3. Dio podataka preuzetih iz brodskih podnevnih izvješća zasnovan je na subjektivnoj percepciji	O3. Prijedlog novog pristupa upravljanja brodom i unaprjeđenja plovidbe prema vremenskim prognostičarima	T3. SWOT identifikacija elemenata može biti zastarjela u promijenjenim uvjetima primjene (okoline)
S4. Prilagodba poslovne politike brodar prema većoj ekološkoj prihvatljivosti broda	W4. Interpretacija predviđanja i rezultirajući postupci ovise o ljudskom čimbeniku	O4. Prikupljene podatke i rezultate obrade brodar može rabiti prilikom sklapanja ugovora o prijevozu tereta	
S5. Određivanje početnog (nultog) stanja		O5. Prikupljene podatke i rezultate obrade brodar može rabiti za prijedlog novog metodološkog pristupa prema IMO-u i njegovim odborima	
S6. Uporaba postojeće infrastrukture s minimalnim intervencijama		O6. Rezultati modela mogu se rabiti u sustavu planskog održavanja postrojenja	
S7. Usklađenost s relevantnim propisima, smjernicama i standardima		O7. Prikupljeni podaci i rezultati obrade mogu se rabiti u budućim istraživanjima	
S8. Uspostavljanje automatiziranog sustava praćenja i predviđanja potrošnje goriva i emisije CO ₂		O8. Daljnja uporaba vanjske usluge vremenskih prognostičara	
		O9. Prikupljene podatke moguće je primijeniti na brodove iz iste serije	

U svrhu identifikacije strategija koje će na najbolji mogući način naglasiti snage i minimizirati slabosti te kapitalizirati mogućnosti i neutralizirati prijetnje, izvršena je analiza odnosa mogućnosti sa snagama i slabostima te prijetnji sa snagama i slabostima te sastavljena TOWS⁴³ matrica sustava (modela). TOWS matrica pomaže pri identifikaciji veza između snaga (S), slabosti (W), prilika (O) i prijetnji (T) te daje osnovu formuliranja strategija na tim odnosima. Ona pokazuje kako vanjske mogućnosti i prijetnje s kojima se suočava određen sustav mogu biti suprotstavljenе unutarnjim snagama i slabostima da bi se kao rezultat dobila četiri skupa alternativnih strateških preporuka [166]:

1. S-O strategija: maksimiziranje snaga da bi se maksimizirale mogućnosti u okolini (engl. *maxi-maxi*),
2. S-T strategija: maksimiziranje snaga da bi se minimizirale prijetnje (engl. *maxi-mini*),
3. W-O strategija: minimiziranje slabosti u mogućnostima bogatom okruženju (engl. *mini-maxi*),
4. W-T strategija: minimiziranje slabosti i prijetnji (engl. *mini-mini*).

Da bi se TOWS matrica kvalitetno izvela, potrebno je sustavno istražiti unutarnje i vanjsko okruženje te definirati informacijske tokove koji su rabljeni u analizi i prepoznavanju ključnih odnosa između unutarnjih i varijabli okruženja. Izuzete su kombinacije s ponavljanjem ili bez jasno identificirane strategije.

Tablica 30. TOWS matrica

		UNUTARNJI ČIMBENICI	
		SNAGE (S)	SLABOSTI (W)
VANJSKI ČIMBENICI	MOGUĆNOSTI (O)		
		S1O1 Integracija sustava moguća je nakon ispunjenja tehnoloških preduvjeta vezanih za brzinu podatkovnog prometa. S1O2 Proširenjem broja ulaznih i izlaznih varijabli moguće je stvoriti temelje za daljinsko ili autonomno upravljanje brodom. S1O3 Suradnja s vremenskim prognostičarima na unaprjeđenju usluge.	W1O8 Postojeći sustav podrške pri navigaciji nastavlja se rabiti dok model ne skupi dovoljan broj podataka. W1O9 Vrijeme prikupljanja, početnog broja podataka moguće je minimizirati ako je riječ o drugom ili n-tom broju iz iste serije. W2O8 Postojeći sustav podrške pri navigaciji nastavlja se rabiti dok se ne pokriju svi scenariji vanjskih uvjeta i operacijskih postupaka .

⁴³TOWS je akronim od riječi prijetnje, mogućnosti, slabosti i snage (engl. threats, opportunities, weaknesses and strengths)

	<p>S1O4 Moguće su korekcije tipiziranih ugovora o prijevozu uključivanjem izmjerениh operacijskih parametara.</p> <p>S2O5 Moguća je inicijativa prema IMO-u i ostalim zainteresiranim skupinama kako bi se promjenio metodološki pristup izvješćivanju o potrošnji goriva i emisijama ugljikova dioksida.</p> <p>S1O6 Izlazne podatke predviđanja i nadgledanja moguće je rabiti kao usporedne veličine s podacima proizvođača, a s ciljem ranog otkrivanja kvarova ili potreba za održavanjem (čišćenje trupa, poliranje vijka, i sl.).</p> <p>S1O7 Predstavljeni rezultati mogu omogućiti daljnja znanstvena istraživanja i unaprijeđenja.</p> <p>S5O6 Početno stanje operacijskih parametara može se usporediti s podacima proizvođača kao ulaz u sustav planskog održavanja.</p> <p>S6O2 Razvoj programske podrške i infrastrukture prema budućem sustavu daljinskog ili autonomnog upravljanja.</p> <p>S7O5 Sudjelovanje u razvoju zakonodavstva i smjernica relevantnih institucija.</p>	<p>W2O9 Vrijeme prikupljanja početnog broja podataka moguće je minimizirati ako je riječ o drugom ili n-tom broju iz iste serije.</p> <p>W3O2 U razvoju modela i budućim istraživanjima, podaci zasnovani na subjektivnoj percepciji bit će isključeni.</p> <p>W4O1 Integracijom sustava brod – ured moguća su unaprjeđenja programske podrške u različitim scenarijima vanjskih uvjeta i operacijskih postupaka. Sustav donošenja odluka i dalje funkcioniра prema postojećem stanju.</p>
PRIJETNJE (T)	<p>S1T1 Predviđanje relevantnih operacijskih parametara nova je informacija u postojećem sustavu donošenja odluka, ona kao takva može biti prihvaćena ili odbijena.</p> <p>S2T1 Postojeći SEEMP moguće je korigirati u kraćem vremenskom intervalu od postojećeg.</p> <p>S3T1 Prikupljena saznanja moguće je rabiti prilikom unaprjeđivanja energetskog sustava i EEDI na projektnoj razini.</p> <p>S4T1 Poslovna politika brodara prema većoj ekološkoj osjetljivosti prepoznata je od strane svih zainteresiranih skupina u pomorskom pothvatu.</p> <p>S5T1 Početno stanje rabi se za buduće usporedbe, zatećeni model s početnim stanjem iz probne vožnje ili ispitnog stola može biti nerealan.</p> <p>S6T1 Implementacija novog sustava ne zahtijeva značajna sredstva.</p> <p>S7T1 Predloženi sustav uskladen je s postojećim propisima, smjernicama i standardima. Ishodovanje tipskog odobrenja zatražit će se nakon završetka procesa razvoja programskog sustava te odabira fizičkih komponenti sustava.</p> <p>S7T3 SWOT i TOWS analizu potrebno je periodično ponoviti u ključnim razvojnim stupnjevima modela.</p>	<p>W1T1 Uporaba predloženog modela neobvezujuća; model je nadgradnja i podrška u postojećem sustavu donošenja oduka s nepromijenjenim odgovornostima i izmjenama informacija.</p> <p>W1T2 Nije vjerojatno da će promjena propisa, smjernica i standarda ograničiti podršku pri odlučivanju o učinkovitoj uporabi energetskih izvora ili vezano za učinkovitu plovidbu, ako mjerodavna tijela donešu standarde primjene takvih sustava, sustav se može modificirati kako bi bio u sukladnosti sa zahtjevima. Takva je nadogradnja relativno jednostavna jer je predloženi model u potpunosti uklapljen u postojeće zakonske regulative i postojeću infrastrukturu.</p> <p>W2T1 Predloženi model predviđen je za uporabu na tankerima te svim ostalim brodovima kod kojih se operacijski postupci ponavljaju unutar razumnog vremenskog razdoblja. Uporaba na brodovima za, primjerice, prijevoz teških tereta, zahtijevala bi dulje vremensko razdoblje preuzimanja i učenja na podacima.</p> <p>W3T1 Problem se može prevladati usporednim praćenjem istih veličina različitim očitanjima kako</p>

		S8T1 Automatizacija postojećeg sustava, ljudski element i dalje može biti uključen.	bi se smanjilo unošenje nerealnih vrijednosti. W4T1 Problem je moguće prevladati razvojem adekvatnog programskog sučelja te edukacijom krajnjih korisnika.
--	--	---	---

Slijedom SWOT identifikacije unutarnjih i vanjskih čimbenika sustava te TOWS matrice strategija smanjenja neodređenosti, moguće je zaključiti da je postavljeni model primjenjiv i uvažava specifične uvjete okruženja. Pretpostavljene snage i mogućnosti predstavljaju prednosti i donose korist, kako smanjenju potrošnje energije i sprječavanju onečišćenja ispuštanjem ugljikova dioksida, tako i održivom razvoju unutar ekoloških parametara, s minimumom iscrpljivanja izvora i onečišćenja prirodnog okoliša. Slabosti i prijetnje sustava neutralizirane su postojećim snagama i mogućnostima. S obzirom na to da TOWS mehanizam strukturiranja obrađuje trenutačno stanje te da iz njega ne proizlaze nove ideje ili uvidi, tijekom razvoja modela potrebno je ponoviti analizu kako bi se razmotrili mogući promijenjeni odnosi te korigirala početna strategija razvoja. Time je potvrđen model koji sinergijom metoda strojnog učenja i općom teorijom sustava obrađuje podatke preuzete sa senzora u plovidbi i podatke o vanjskim utjecajima te opisuje, predviđa i omogućuje prilagodbu relevantnih operacijskih parametara broda na primjeru tankera za prijevoz ukapljenoga naftnog plina s ciljem smanjenja potrošnje energije i emisije štetnog ugljikova dioksida. Uvođenjem novih informacija o učinkovitijem upravljanju brodom i brodskim sustavima omogućena je energetski učinkovitija plovidba i upravljanje brodskim procesima, kao i korekcija postojećeg brodskog plana energetske učinkovitosti. Prikupljena znanja moguće je primijeniti prilikom sklapanja ugovora o prijevozu tereta te kreiranja poslovne politike brodara prema većoj ekološkoj prihvatljivosti broda na međunarodnom pomorskom tržištu. Time su dokazane glavna i pomoćne hipoteze doktorskog istraživanja.

6. ZNANSTVENI DOPRINOS DOKTORSKE DISERTACIJE

Gradnjom modela nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida temeljenim na senzorskim podacima preuzetim s broda za prijevoz ukapljenoga naftnog plina te meteorološkim i oceanografskim podacima sukladnim geografskom položaju i vremenu plovidbe, kao i odabirom učinkovitih metoda strojnog učenja u sinergiji s općom teorijom sustava, postignuti su znanstveni doprinosi ovog doktorskog istraživanja:

1. identifikacija parametara koji utječu na energetsku učinkovitost i ispuštanje ugljikova dioksida na brodu za prijevoz ukapljenoga naftnog plina,
2. utvrđivanje njihovog utjecaja,
3. razvoj novog metodološkog pristupa za nadzor i predviđanje emisija na predmetnoj vrsti brodova te
4. prijedlog modela nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida na brodu za prijevoz ukapljenoga naftnog plina.

6.1. Primjena rezultata znanstvenog istraživanja

Rezultati ovog istraživanja mogu se primijeniti u sljedećem:

1. moguća je korekcija i optimizacija postojećeg brodskog plana upravljanja energetskom učinkovitošću s ciljem uštede energije i smanjenja ispuštanja ugljikova dioksida,
2. moguća je korekcija pokazatelja energetske učinkovitosti (EnPI) proizašlog iz koeficijenta energetske učinkovitosti (EEDI) te je rezultate moguće rabiti prilikom odabira vrste preinake, odabira uređaja i broja senzora,
3. predloženi model moguće je rabiti za praćenje, predviđanje i planiranje ekološki prihvatljivijeg putovanja i upravljanja brodom te unaprjeđenje plovidbe po uputama vremenskih prognostičara,
4. rezultati mogu koristiti brodaru i operateru za uspostavljanje sustava praćenja i predviđanja utroška goriva i emisije ugljikova dioksida u svezi s obvezujućim zahtjevima Međunarodne pomorske organizacije prema brodovima od 2019. godine,
5. primjenom modela moguće je utjecati na poslovnu politiku brodara prema većoj ekološkoj prihvatljivosti broda,
6. rezultati se mogu upotrebljavati kao pomoć pri donošenju odluka prilikom sklapanja ugovora o prijevozu tereta,
7. rezultati se mogu upotrebljavati u sustavima upravljanja i nadzora potpuno automatiziranih i tzv. „dron” brodova i

8. rezultati istraživanja mogu se upotrebjavati u budućim istraživanjima koja kao cilj imaju nadzor plovidbe zasnovan na inteligentnoj analizi podataka i simulaciji operacije broda.

6.2. Prijedlog za nastavak znanstveno-istraživačkog rada

U nastavku ovog istraživanja moguće je proširiti prikupljanje podataka na senzore ugrađenih propulzijskih strojeva i pogonskih strojeva generatora električne energije pri različitim opterećenjima, identifikaciju senzorskih signala koji najviše utječu na energetsku učinkovitost te odabir izlaznih varijabli i primjerenog algoritma strojnog učenja. Buduća istraživanja mogu biti usmjerena prema području tehnologija koje će isključiti subjektivnu percepciju u procesu prikupljanja podataka i primjene postupaka usmjerениh prema smanjenju potrošnje goriva i onečišćenja atmosfere ugljikovim dioksidom. Također, buduća istraživanja mogu uključivati prikupljanje senzorskih podataka vezanih uz sustav upravljanja plinom na brodovima za prijevoz ukaplenoga plina s posebnim naglaskom na ukapljeni prirodni plin, zbog sve češće upotrebe kao alternativnog goriva. Rezultate početnog stanja moguće je rabiti za proširenje predloženog modela iz ovog istraživanja sa spomenutim funkcionalnostima te pri usporedbi s postojećim stanjem spomenutih sustava i odlučivanju o održavanju. Isto tako, daljnja istraživanja mogu biti usmjerena razvoju programske podrške za optimizaciju potrošnje energije te smanjenja ispuštanja ugljikova dioksida, a u skladu s potrebama krajnjeg korisnika. Nadalje, moguća je izrada prototipa programske opreme kojom će se u potpunosti realizirati predloženi model te izvesti njegovo praćenje u realnim operacijskim uvjetima, čime se omogućava izravan uvid u stvarne vrijednosti poboljšane energetske učinovitosti broda.

7. ZAKLJUČAK I PREPORUKE

U ovom istraživanju postavljen je model koji opisuje, predviđa i omogućuje prilagodbu relevantnih operacijskih parametara broda na primjeru tankera za prijevoz ukapljenoga naftnog plina s ciljem smanjenja potrošnje energije i emisije štetnog ugljikova dioksida. Pri postavljanju modela upotrebljavane su metode strojnog učenja u kombinaciji s općom teorijom sustava. Ispitani su klasifikacijski i regresijski algoritmi strojnog učenja temeljeni na naivnom Bayesu, multinomijalnoj logističkoj regresiji, višeslojnom perceptronu, strojevima potpornih vektora, stablima odluke, nasumičnim šumama i linearnej regresiji. Za potrebe učenja modela preuzeti su senzorski podaci sa sustava nadzora i upravljanja brodskim postrojenjem (kao primarni izvor), sekundarni podaci s brodskog navigacijskog sustava, brodska podnevna izvješća te dostupni meteorološki i oceanografski podaci sukladni geografskom položaju i vremenu plovidbe. Nakon određivanja Pearsonove korelacije, uz pomoć ekspertnog odabira, te mogućnosti predviđanja vrijednosti u budućnosti, konačan broj varijabli smanjen je sa 141 na 25. Standardne mjere učinkovitosti rabljene pri vrednovanju algoritama klasifikacije jesu vrijeme potrebno za učenje, udio točno klasificiranih primjeraka, RMSE, TP i FP stopa, preciznost, mjera F_1 , MCC, AUROC i AUPRC, dok je kod regresije upotrebljavanje vrijeme potrebno za učenje, koeficijent korelacije (C_c), RMSE, MAE, RAE i RRSE. Za procjenu naučenih metoda u svim scenarijima klasifikacije i regresije rabljena je deseterostruka tehnika unakrsne provjere (validacije). Rezultati predstavljenih metoda pokazuju da je primjenom odgovarajućeg algoritma strojnog učenja moguće, unutar prethodno postavljenih granica razreda (klasifikacija), predvidjeti razred potrošnje goriva, odnosno previdjeti brojčanu vrijednost (regresija), i to oboje s visokom točnošću predviđanja. Unatoč tome što metode stabala odlučivanja, višeslojnog perceptrona, strojeva potpornih vektora i naivnog Bayesa kod klasifikacije te višeslojnog perceptrona i strojeva potpornih vektora kod regresije postižu izvrsne rezultate, nasumične šume svojom fleksibilnošću i jednostavnosću uporabe u oba predstavljena slučaja primjene (klasifikacija i regresija) daju najbolje rezultate predviđanja potrošnje goriva glavnog propulzijskog stroja u kratkom vremenu učenja uz mali broj potrebnih parametara za podešavanje. Na temelju dobivenih rezultata vrednovanja preporuča se uporaba nasumičnih šuma upravo za slične slučajeve strojnog učenja. Rezultati vrednovanja pokazuju da RF, odgovarajućom kombinacijom i obradom relevantnih varijabli, s obzirom na točnost predviđanja, postiže najbolje rezultate od 97,40% točno klasificiranih primjeraka unutar prihvatljivog vremena učenja, dok kod regresije postiže C_c od 0,9992 unutar prihvatljivog

vremena učenja i s najmanjom intervencijom prilikom učenja modela. U doktorskome istraživanju se zatim pristupilo modeliranju dodatnih izlaznih varijabli (na istom skupu ulaznih varijabli) vezanih uz učinkovitost propulzije i trupa preko EEDI, SEEMP plana (dio 1 i 2) te operacijskih postupaka kojima se mogu unaprijediti osnovni uvjeti kao i optimizirati uporaba energetskih izvora te smanjiti količina ispuštenog ugljikova dioksida. Uz početnu varijablu potrošnje goriva ispitane su specifična potrošnja glavnog propulzijskog stroja (97,09% točno klasificiranih primjeraka te Cc 0,9887 numeričkog predviđanja), EEOI (izvedena varijabla iz potrošnje goriva), $EnPI_{FC}$ (izvedena varijabla iz potrošnje goriva), brodski skliz (91,53% točno klasificiranih primjeraka te Cc 0,995 numeričkog predviđanja), brzina broda (0,9989 numeričkog predviđanja), uzdužni nagib broda (97,93% točno klasificiranih primjeraka te Cc 0,9992 numeričkog predviđanja) te potrebe za ukapljivanjem tereta (98,09% točno klasificiranih primjeraka te Cc 0,9946 numeričkog predviđanja). Rezultati potvrđuju da se metode rudarenja podataka mogu uspješno rabiti prilikom ocjenjivanja operativnog stanja broda u stvarnim operacijskim uvjetima, stoga se u drugom dijelu istraživanja pristupilo izradi modela nadzora i predviđanja energetske učinkovitosti i ispuštanja ugljikova dioksida na primjeru broda za prijevoz ukapljenoga naftnog plina. Za opis sustava rabljene su UC struktura, kojom su određene komponente sustava i njihove međusobne veze, te ST struktura, kojom su prepoznata stanja i opisani prijelazi između pojedinih stanja. Za provjeru i identifikaciju strategija koje će na najbolji mogući način prepoznati snage i minimizirati slabosti rabljene su SWOT identifikacija i TOWS analiza snaga, slabosti, mogućnosti i prijetnji sustava. Slijedom spomenutih analiza moguće je zaključiti da je postavljeni model primjenjiv te da je potvrđena glavna hipoteza ove disertacije koja tvrdi da je obradom podataka preuzetih sa senzora u plovidbi i uključivanjem podataka o vanjskim utjecajima moguće postaviti model koji opisuje, predviđa i omogućuje prilagodbu relevantnih operacijskih parametara broda koji vode k energetski učinkovitijem prijevozu ukapljenoga naftnog plina.

Informacije o upravljanju brodom i brodskim sustavima, kao i postupcima proizašlim iz modela, dostupne su u uredu brodara te ih je moguće rabiti prilikom postavljanja novih i procjene provođenja i korekcije postojećih ciljeva, sadržanih u brodskom planu upravljanja energetskom učinkovitošću, poput poboljšanog plana putovanja i smanjene potrošnje goriva glavnog i pomoćnih strojeva. Praćenjem relevantnih operacijskih parametara kod tankera za prijevoz ukapljenoga plina s ugrađenim sustavom ukapljivanja, optimizacijom je moguće postići značajne uštede električne energije. Jednako tako, nova znanja moguće je upotrijebiti u procesu donošenja odluka o planiranom održavanju, poput čišćenja podvodnih dijelova

brodskog trupa ili čišćenja i poliranja brodskog vijka. Prilikom usvajanja tehničkih mjera prema unaprjeđenju energetske učinkovitosti omogućena je usporedba s prethodnim stanjem te kvalitetna valorizacija novougrađenog sustava. Model omogućuje i automatizirano prikupljanje podataka prema SEEMP i MRV izvješćima, čime se utječe na pojednostavljenje brodskog sustava izvješćivanja.

S vremenom, prikupljeni podaci o relevantnim operacijskim parametrima te preporuke i postupci za smanjenje potrošnje energije i ispuštenog ugljikova dioksida postaju znanje koje je moguće uključiti kod ugradnje tehnoloških rješenja i razvoja postupaka unaprjeđenja energetske učinkovitosti i smanjenja emisije ugljikova dioksida na postojećim brodovima. Predviđanjem specifične potrošnje goriva omogućena je usporedba s početnim i trenutnim stanjem te pružena korisna informacija o učinkovitosti procesa izgaranja u skladu sa zadanim vrijednostima proizvođača. Usvojena tehnička i operativna rješenja mogu se ugrađivati u novogradnje brodova, čime se lakše postiže zahtijevana razina energetske učinkovitosti.

Smanjena brzina donosi značajnu uštedu u potrošnji goriva te je mnoge pomorske tvrtke, posebice kada je brod u balastu, odabiru kao sastavni dio politike upravljanja. Ukoliko je energetska učinkovitost adekvatno nagrađena, a preduvjet je mogućnost prezentacije ušteda, utoliko brodari imaju poticaj za ulaganje u smanjenje potrošnje goriva. Posljedično može doći do korekcije tržišta, koje tada pomaže postizanju smanjenja emisije ugljika zahvaljujući nagrađivanju ekološki prihvatljivog ponašanja.

Predloženi sustav (model) moguće je preporučiti kao zamjenu ili nadogradnju postojećim modelima temeljenim na fizikalnim zakonitostima tijekom gradnje broda, ispitivanjima na probnom stolu ili u moru, pri određivanju potrošnje goriva, ili utvrđivanju čimbenika koji utječu na učinkovitost plovidbe i optimizaciju uporabe energetskih izvora.

Prilozi

Prilog A: Pregled ulaznih varijabli

Tablica 31. Prikupljeni senzorski podaci sa sustava nadzora i upravljanja brodskim postrojenjem

BR.	OPIS	OZNAKA	MJERNA JEDINICA
1.	BROJ OKRETAJA GLAVNOG POGONSKOG STROJA	PICKUP11	°/min
2.	UČINKOVITOST TRUPA	HULL_EFF	kg/nm
3.	UČINKOVITOST UTROŠKA GORIVA GL. POG. STROJA	FUEL_EFF	g/kWh
4.	POTROŠNJA GORIVA GL. POGONSKOG STROJA (CORIOLIS)	ME_TOT_FL	kg
5.	BRZINA BRODA KROZ VODU (SPEED LOG-DOPPLER)	NAV_01	nm/h
6.	BRZINA BRODA PREKO DNA (GPS VTG)	NAV_02	nm/h
7.	SMJER PLOVIDBE S GYRO KOMPASA	NAV_03	°
8.	BRZINA VJETRA	NAV_04	m/s
9.	SKLIZ VIJKA	PROP_SLIP	%
10.	INDEKS RUČICE GORIVA GL. POG. STROJA	FUEL INDEX	%
11.	SNAGA NA GLAVNOJ OSOVINI (METAPOWER)	POWER_SHAFT1	kW
12.	MOMENT NA GLAVNOJ OSOVINI (METAPOWER)	TORQUE_SH1	kNm
13.	BROJ OKRETAJA TURBOPUHALA GL. POGONSKOG STROJA	MC004	°/min
14.	TLAK U KOLEKTORU ISPIRNOG ZRAKA GL. POG. STROJA	MA016	kg/cm ²
15.	DJELATNA SNAGA IZMJERENA NA GL. RAZVODNOJ PLOČI	MSB0-TOT-LOD	kW
16.	ZEMLJOPISNA DUŽINA	LATDEGMIN	°
17.	ZEMLJOPISNA ŠIRINA	LONDEGMIN	°
18.	TEMPERATURA ZRAKA	MS114	°C
19.	TEMPERATURA MORA	MW014	°C
20.	PROSJEČNA TEMPERATURA ISPUŠNIH PLINOVA GL. POG. STROJA	MEEXHMEAN	°C
21.	UZDUŽNI NAGIB BRODA	TRIM	m
22.	STUPANJ PROMJENE KURSA (ENGL. RATE OF TURN-ROT)	NAV15	°/min
23.	KUT OTKLONA KORMILA	NAV07	°
24.	POPREČNI NAGIB BRODA	LIST	°
25.	TEMPERATURA ISPUŠNIH PLINOVA 1. CIL. GL. POG. STROJA	MA007	°C
26.	TEMPERATURA ISPUŠNIH PLINOVA 2. CIL. GL. POG. STROJA	MA008	°C
27.	TEMPERATURA ISPUŠNIH PLINOVA 3. CIL. GL. POG. STROJA	MA009	°C
28.	TEMPERATURA ISPUŠNIH PLINOVA 4. CIL. GL. POG. STROJA	MA010	°C
29.	TEMPERATURA ISPUŠNIH PLINOVA 5. CIL. GL. POG. STROJA	MA011	°C
30.	TEMPERATURA ISPUŠNIH PLINOVA 6. CIL. GL. POG. STROJA	MA012	°C
31.	POVRATNI INV. SIGNAL POZICIJE REG. VENTILA CENTR. SUSTAVA RASHLADNE VODE	MW019.2_INV	%
32.	IZLAZNA TEMPERATURA RASHL. VODE IZ RASHLADNIKA GL. POGONSKOG STROJA	MW009	°C
33.	KONTROLNI SIGNAL PREMA AUT. VENTILU V.T. RASHLADNE VODE GL. POG. STR.	MW017.1	%
34.	POVRATNI SIGNAL S AUT. VENTILA V.T. RASHLADNE VODE	MW017.2	%
35.	TEMPERATURA V.T RASHLADNE RASHLADNE VODE GL. POG. STR.	MW017.3	°C
36.	KONTROLNI SIGNAL PREMA AUT. VENTILU N.T. RASHLADNE VODE	MW019.1	%
37.	POVRATNI SIGNAL S AUT. VENTILA N.T. RASHLADNE VODE	MW019.2	%

38.	TEMPERATURA N.T RASHLADNE VODE	MW019.3	°C
39.	KOREKCIJA UCINKA UTROŠKA GORIVA GL. POG. STROJA	FUEL_EFF_C	g/kWh
40.	TEMP. ISPIRNOG ZRAKA 1. CIL. GL. POG. STROJA	MA001	°C
41.	TEMP. ISPIRNOG ZRAKA 2. CIL. GL. POG. STROJA	MA002	°C
42.	TEMP. ISPIRNOG ZRAKA 3. CIL. GL. POG. STROJA	MA003	°C
43.	TEMP. ISPIRNOG ZRAKA 4. CIL. GL. POG. STROJA	MA004	°C
44.	TEMP. ISPIRNOG ZRAKA 5. CIL. GL. POG. STROJA	MA005	°C
45.	TEMP. ISPIRNOG ZRAKA 6. CIL. GL. POG. STROJA	MA006	°C
46.	ULAZNA TEMP. ISPUŠNIH PLINOVA IZ TURBOPUHALA GL. POG. STROJA	MA013	°C
47.	ULAZNA TEMP. ISPUŠNIH PLINOVA U TURBOPUHALO GL. POG. STROJA	MA014	°C
48.	IZLAZNA TEMP. ISPUŠNIH PLINOVA IZ KOTLA NA ISPUŠNE PLINOVE	AB018	°C
49.	PROSJEČNA TEMPERATURA ISPUŠNIH PLINOVA IZ GENERATORA BR.1	GE1_MEAN	°C
50.	DEVIJACIJA TEMPERATURE ISPUŠNIH PLINOVA IZ CILINDRA BR. 1 U ODNOSU NA PROSJEČNU IZ GENERATORA BR.1	GE1_A	°C
51.	TEMPERATURA ISPIRNOG ZRAKA GENERATORA BR.1	ITI21	°C
52.	TLAK ISPIRNOG ZRAKA GENERATORA BR.1	IPI21	kg/cm ²
53.	BROJ OKRETAJA TURBOPUHALA GENERATORA BR.1 (X10)	ISE42	%/min
54.	TEMPERATURA ISPUŠNIH PLINOVA 1. CILINDRA GENERATORA BR.1	ITE25-1GE1.1	°C
55.	ULAZNA TEMP. ISPUŠNIH PLINOVA U TURBOPUHALO GEN. BR.1	ITE26-BGE1.1	°C
56.	TEMPERATURA N.T. RASHLADNE VODE U GEN. BR.1	ITI71 GE1	°C
57.	TEMPERATURA N.T. RASHLADNE VODE IZ GEN. BR.1	ITI72 GE1	°C
58.	TEMPERATURA V.T. RASHLADNE VODE U GEN. BR.1	ITI75 GE1	°C
59.	TEMPERATURA V.T. RASHLADNE VODE IZ GEN. BR.1	ITI76 GE1	°C
60.	PROSJEČNA TEMPERATURA ISPUŠNIH PLINOVA IZ GENERATORA BR.2	GE2_MEAN	°C
61.	DEVIJACIJA TEMPERATURE ISPUŠNIH PLINOVA IC CILINDRA BR.1 U ODNOSU NA PROSJEČNU IZ GEN. BR.2	GE2_A	°C
62.	TEMPERATURA ISPIRNOG ZRAKA GENERATORA BR.2	ITI21 GE2.1	°C
63.	TLAK ISPIRNOG ZRAKA GENERATORA BR.2	IPI21 GE2.1	kg/cm ²
64.	BROJ OKRETAJA TURBOPUHALA GENERATORA BR.2 (X10)	ISE42 GE2.1	%/min
65.	TEMPERATURA ISPUŠNIH PLINOVA 1. CILINDRA GENERATORA BR.2	ITE25-1GE2.1	°C
66.	ULAZNA TEMP. ISPUŠNIH PLINOVA U TURBOPUHALO GEN. BR.2	ITE26-BGE2.1	°C
67.	TEMPERATURA N.T. RASHLADNE VODE U GENERATOR BR.2	ITI71 GE2	°C
68.	TEMPERATURA N.T. RASHLADNE VODE IZ GENERATORA BR.2	ITI72 GE2	°C
69.	TEMPERATURA V.T. RASHLADNE VODE U GENERATOR BR.2	ITI75 GE2	°C
70.	TEMPERATURA V.T. RASHLADNE VODE IZ GENERATORA BR.2	ITI76 GE2	°C
71.	PROSJEČNA TEMPERATURA ISPUŠNIH PLINOVA IZ GENERATORA BR.2	GE3_MEAN	°C
72.	DEVIJACIJA TEMPERATURE ISPUŠNIH PLINOVA IC CILINDRA BR. 1 U ODNOSU NA PROSJEČNU IZ GEN. BR.2	GE3_A	°C
73.	TEMPERATURA ISPIRNOG ZRAKA GENERATORA BR.2	ITI21 GE32.1	°C
74.	TLAK ISPIRNOG ZRAKA GENERATORA BR.2	IPI21 GE3.1	KG/CM ₂
75.	BROJ OKRETAJA TURBOPUHALA GENERATORA BR.2 (X10)	ISE42 GE3.1	%/MIN
76.	TEMPERATURA ISPUŠNIH PLINOVA 1. CILINDRA GENERATORA BR.2	ITE25-1GE3.1	°C

77.	ULAZNA TEMP. ISPUŠNIH PLINOVA U TURBOPUHALO GENERATORA BR.2	ITE26-BGE3.1	°C
78.	TEMPERATURA N.T. RASHLADNE VODE U GEN. BR.2	ITI71 GE3	°C
79.	TEMPERATURA N.T. RASHLADNE VODE IZ GEN. BR.2	ITI72 GE3	°C
80.	TEMPERATURA V.T. RASHLADNE VODE U GEN. BR.2	ITI75 GE3	°C
81.	TEMPERATURA V.T. RASHLADNE VODE IZ GEN. BR.2	ITI76 GE3	°C
82.	SNAGA GENERATORA BR.1	DG1-LOAD	KW
83.	SNAGA GENERATORA BR.2	DG2-LOAD	KW
84.	SNAGA GENERATORA BR.3	DG3-LOAD	KW
88.	BROJ OKRETAJA GLAVNOG POGONSKOG STROJA	PICKUP11	°/MIN
89.	BROJ OKRETAJA GLAVNOG POG. STROJA (METAPOWER)	RPM_SHAFT1	°/MIN
90.	SNAGA PO NAUTIČKOJ MILJI	POWER_CURVE	KW/NM
91.	TEMPERATURA RASHLADNOG ULJA IZ STAPA 1. CILINDRA GLAVNOG POGONSKOG STROJA	ML001	°C
92.	TEMPERATURA IZLAZA RASHLADNE V.T. VODE 1. CILINDRA GLAVNOG POGONSKOG STROJA	MW001	°C
93.	UKUPNA SNAGA GLAVNOG POGONSKOG STROJA	ME_TOT_POW	KW
94.	URONJENOST BRODA SREDINA/ DESNO	DRAFT_STBD	m
95.	URONJENOST BRODA SREDINA/ LIJEVO	DRAFT_PORT	m

Tablica 32. Prikupljeni podaci sustava elektronskih karata (ECDIS)

BR.	OPIS	MJERNA JEDINICA
1.	ZEMLJOPISNA DUŽINA	°
2.	ZEMLJOPISNA ŠIRINA	°
3.	BRZINA PREKO DNA	čvorovi
4.	SMJER PLOVIDBE	°
5.	BRODSKI KURS PREKO DNA	°
6.	BRZINA VJETRA	m/s

Tablica 33. Prikupljeni podaci iz brodskih podnevnih izvješća

BR.	OPIS	MJERNA JEDINICA
1.	DNEVNO STANJE GORIVA	MT
2.	DNEVNA UKUPNA POTROŠNJA GORIVA	MT
3.	PROCIJENJENO VRIJEME DOLASKA	Dan i sat
4.	UDALJENOST ZA PRELAZAK	Nm
5.	PROSJEČNA DNEVNA BRZINA	čvor
6.	BRZINA PREMA CHARTERU	čvor
7.	BRZINA GL. PROPULZIJSKOG STROJA	čvor
8.	RADNI SATI GL. PROPULZIJSKOG STROJA	sat
9.	RADNI SATI GENERATOR #1	sat
10.	RADNI SATI GENERATOR #2	sat
11.	RADNI SATI GENERATOR #3	sat
12.	PRAMČANA URONJENOST BRODA	
13.	KRMENA URONJENOST BRODA	
14.	URONJENOST PO SREDINI BRODA	
15.	SMJER PLOVIDBE	°
16.	NOSIVOST	t
17.	ISTISNINA	t
18.	TEMPERATURA ZRAKA	°C

19.	TLAK ZRAKA	mbar
20.	STANJE MORA PO BEAUFORT LJESTVICI	
21.	STANJE VALA PO BEAUFORT LJESTVICI	
22.	SNAGA VJETRA PO BEAUFORT LJESTVICI	
23.	SMJER MORA	°
24.	SMJER MRTVOG MORA	°
25.	SMJER VJETRA	°
26.	SMJER MORSKE STRUJE	°
27.	VISINA VALA	m
28.	VISINA MRTVOG MORA	m
29.	DNEVNA POTROŠNJA GORIVA GL. PROPULZIJSKOG STROJA	MT
30.	DNEVNA POTROŠNJA GORIVA GENERATORA	MT

Tablica 34. Prikupljeni javno dostupni meteorološki i oceanografski podaci

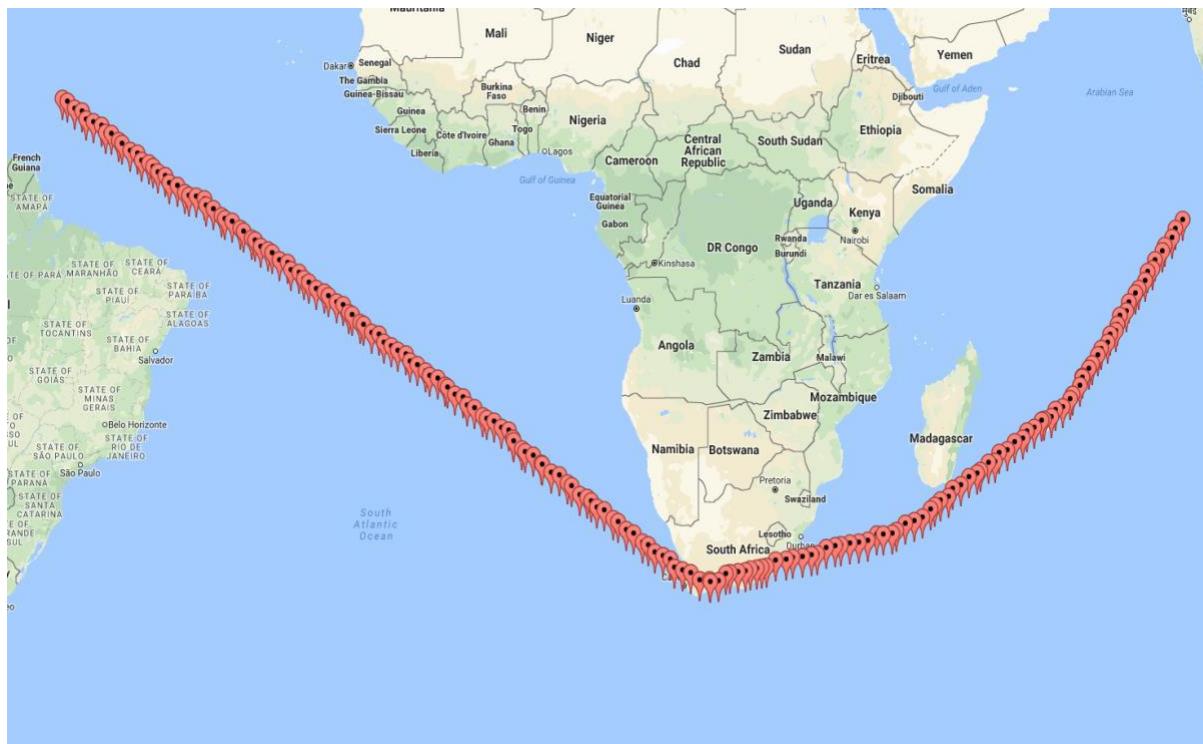
BR.	OPIS	MJERNA JEDINICA
1.	U-VJETAR	m/s
2.	V-VJETAR	m/s
3.	UDAR VJETRA	m/s
4.	ZNAČAJNA VISINA VALA	m
5.	SMJER VALA	°
6.	PERIODA VALA	s
7.	MORSKA STRUJA SMJER X	°
8.	MORSKA STRUJA SMJER Y	°
9.	SMJER MORA	°
10.	BRZINA MORSKE STRUJE	m/s

Tablica 35. Popis izabranih varijabli preuzetih iz snimljenog skupa podataka

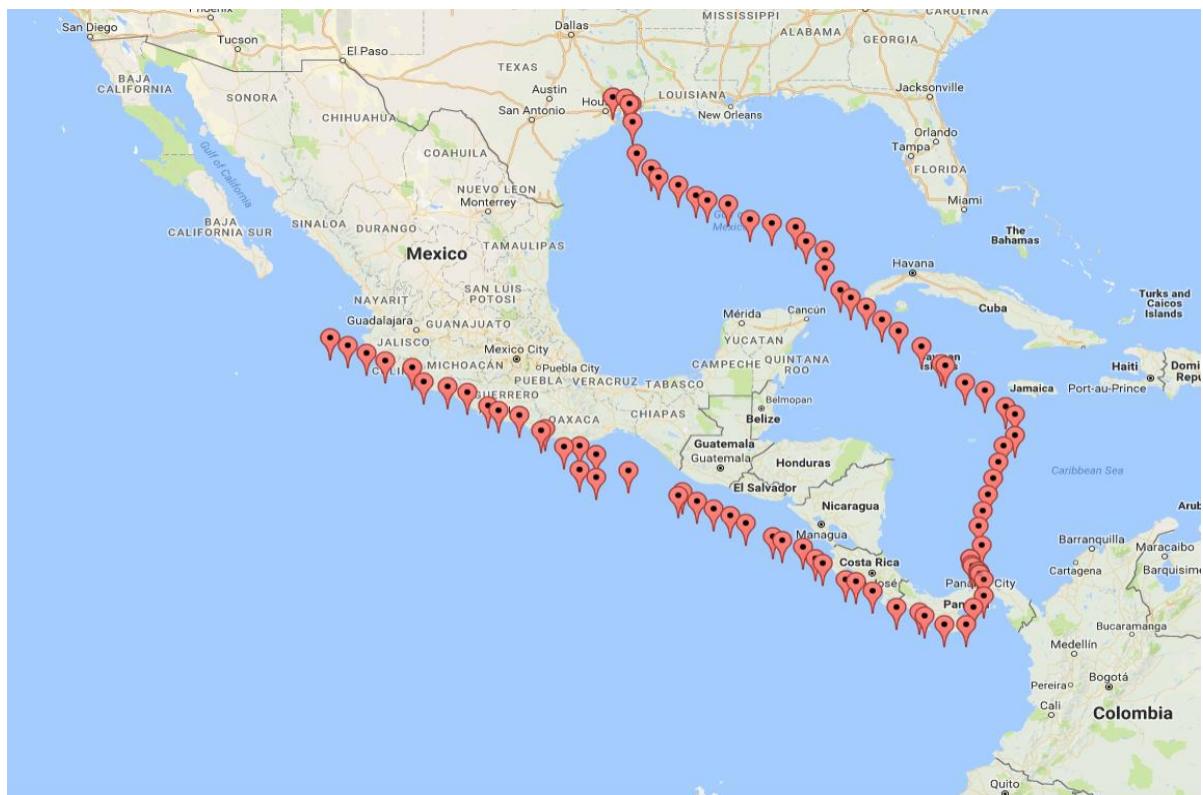
BR.	IZVORNA OZNAKA SENZORA/ VARIABLE	DODATNE INFORMACIJE	MJERNA JEDINICA
1	PICKUP11	BROJ OKRETAJA GLAVNOG POGONSKOG STROJA	°/min
2	HULL_EFF	UČINKOVITOST BRODSKOG TRUPA	kg/nm
3	FUEL_EFF	UČINKOVITOST UTROŠKA GORIVA GL. POG. STROJA	g/kWh
4	ME_TOT_FL	POTROŠNJA GORIVA GL. POGONSKOG STROJA (CORIOLIS)	kg
5	NAV_01	BRZINA BRODA KROZ VODU (SPEED LOG-DOPPLER)	nm/h
6	NAV_02	BRZINA BRODA PREKO DNA (GPS VTG)	nm/h
7	NAV_03	SMJER PLOVIDBE (GYRO KOMPAS)	°
8	NAV_04	BRZINA VJETRA (ANEMOMETAR)	m/s
9	PROP_SLIP	SKLIZ VIJKA	%
10	FUEL INDEX	INDEKS RUČICE GORIVA GL. POG. STROJA	%
11	POWER_SHAFT1	SNAGA NA GLAVNOJ OSOVINI (METAPOWER)	kW
12	TORQUE_SH1	MOMENT NA GLAVNOJ OSOVINI (METAPOWER)	kNm
13	MC004	BROJ OKRETAJA TURBOPUHALA GL. POG. STROJA	°/min
14	MA016	TLAK U KOLEKTORU ISPIRNOG ZRAKA GL. POG. STROJA	kg/cm ²
15	MSB0-TOT-LOD	DJELATNA SNAGA IZMJERENA NA GL. RAZVODNOJ PLOČI	kW

BR.	IZVORNA OZNAKA SENZORA/ VARIJABLE	DODATNE INFORMACIJE	MJERNA JEDINICA
16	MS114	TEMPERATURA STROJARNICE	°C
17	MW014	TEMPERATURA MORA	°C
18	MEEHXMEAN	PROSJEČNA TEMP. ISPUŠNIH PLINOVA GL. POG. STROJA	°C
19	TRIM IN METERS	UZDUŽNI NAGIB BRODA (- PRAMAC, + KRMA)	m
20	NAV15	STUPANJ PROMJENE KURSA (ENGL. RATE OF TURN-ROT)	°/min
21	NAV07	KUT OTKLONA KORMILA	°
22	LIST	POPREČNI NAGIB BRODA	°
23	DRAFT_P/S	SREDNJA URONJENOST BRODA PO SREDINI	m
24	COG/ DEGT	BRODSKI KURS PREKO DNA (ECDIS)	°
25	UWIND	U KOMPONENTA VJETRA	m/s
26	VWIND	V KOMPONENTA VJETRA	m/s
27	GUST	UDAR VJETRA	m/s
28	SIGNIFICANT WAVE	ZNAČAJNA VISINA VALA	m
29	WAVE DIRECTION	SMJER VALA	°
30	WAVE PERIOD	PERIODA VALA	s
31	SEA CURRENT_X	MORSKA STRUJA OS X	m/s
32	SEA CURRENT_Y	MORSKA STRUJA OS Y	m/s
33	SEA DIRECTION	SMJER MORA	°
34	SEA CURRENT SPEED	BRZINA MORSKE STRUJE	m/s
35	SEA	OPSERVACIJA VISINE VALA IZ PODNEVNOG IZVJEŠĆA	Bft
36	SWELL	OPSERVACIJA MRTVOG MORA IZ PODNEVNOG IZVJEŠĆA	Dss
37	WIND	OPSERVACIJA SNAGE VJETRA IZ PODNEVNOG IZVJEŠĆA	Dss
38	WIND DIRECTION	SMJER VJETRA	°

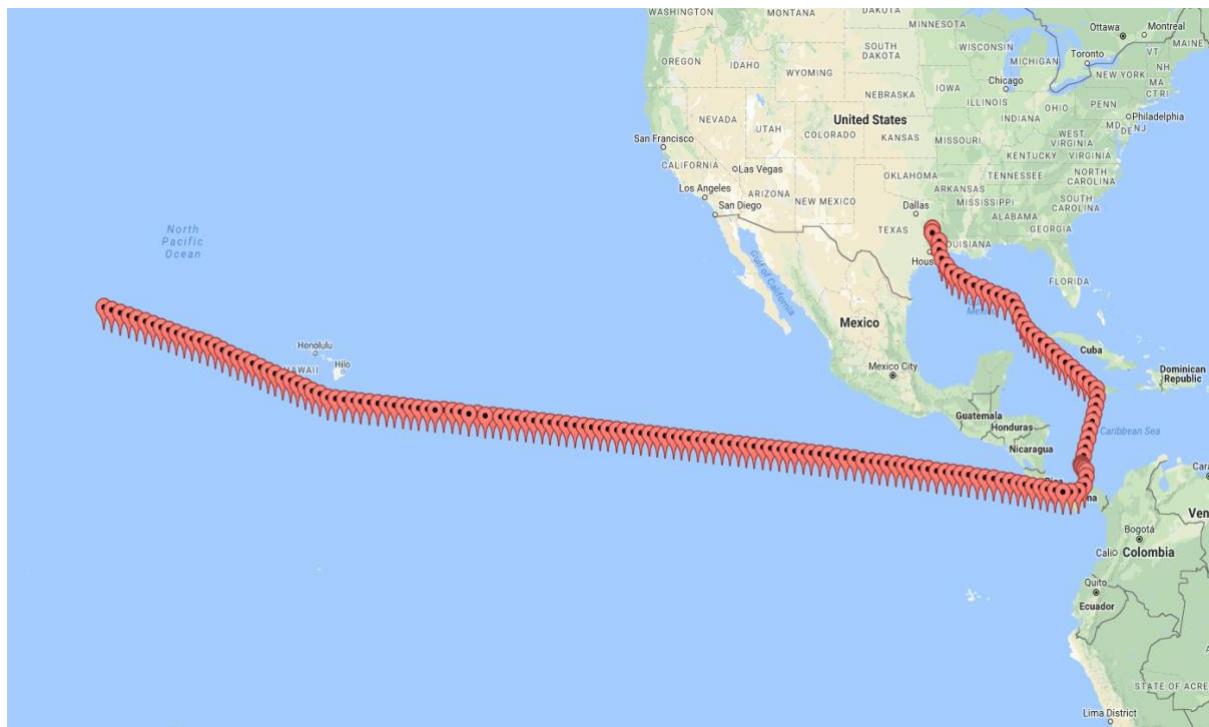
Prilog B: Prikaz plovidbe na zemljopisnoj karti



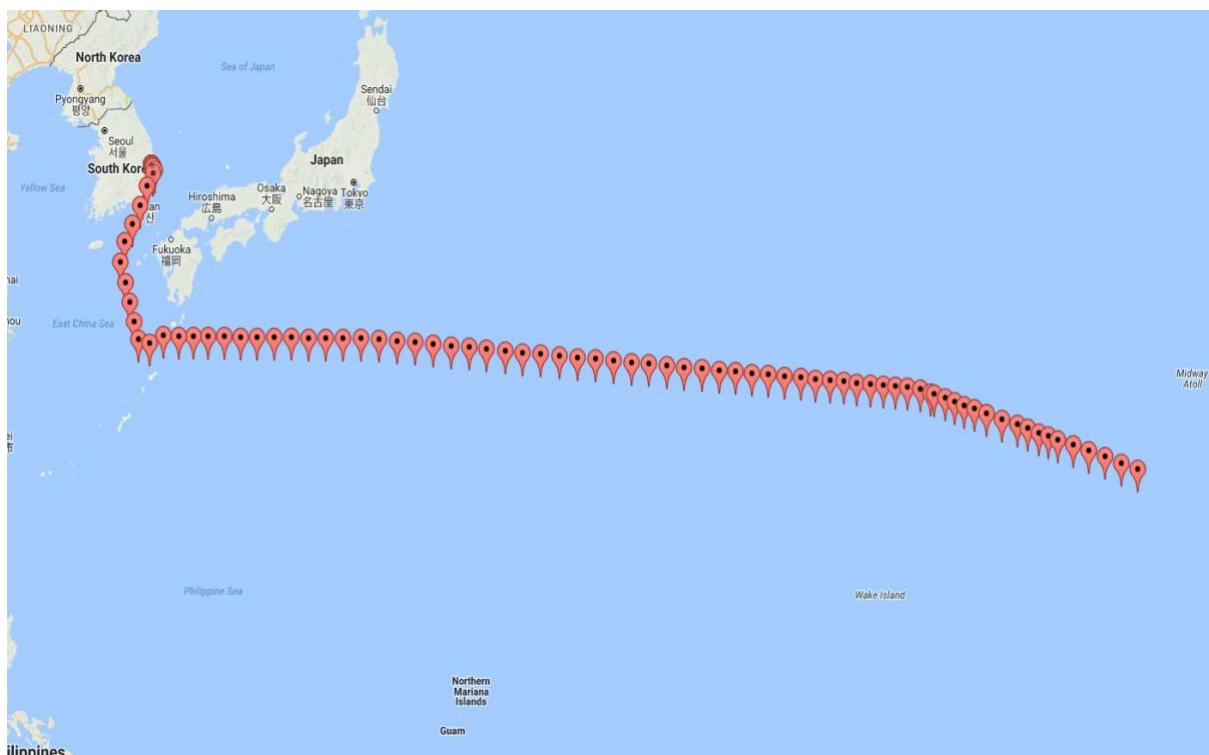
Slika 31. Putovanje br.1: $9^{\circ}30'59.19''/ 311^{\circ}30'27.36'' \rightarrow -2^{\circ}15'47''/ 72^{\circ}7'4.76''$



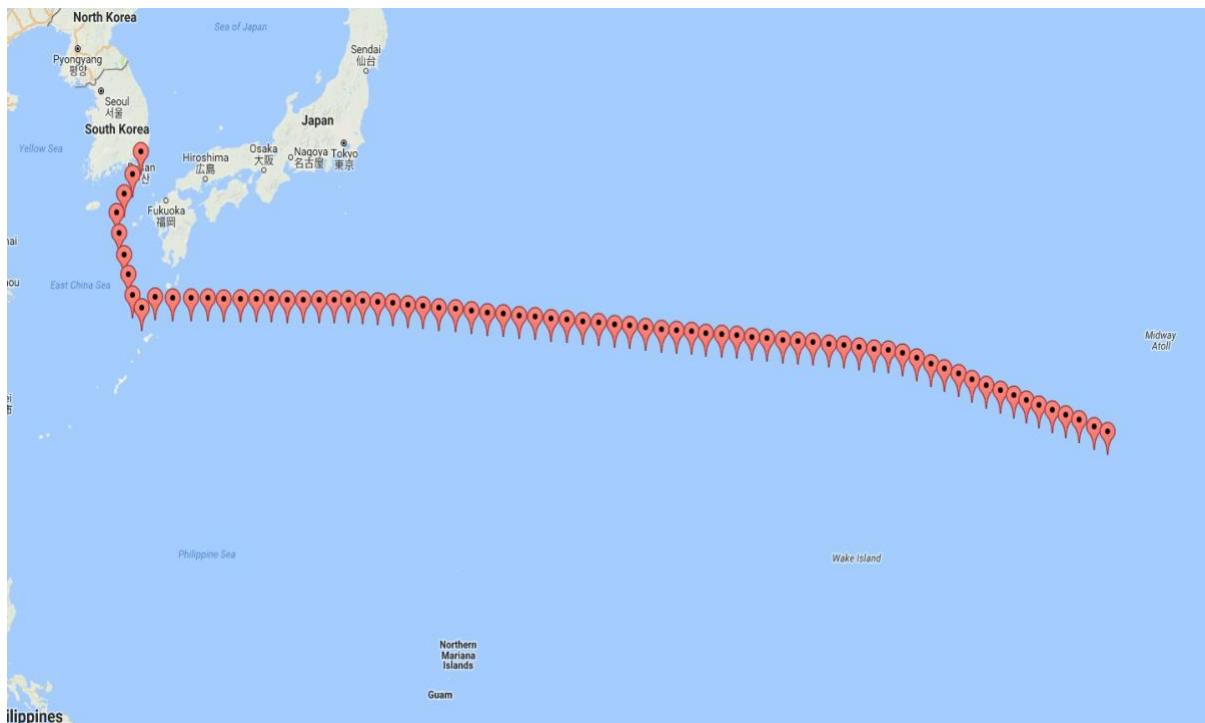
Slika 32. Putovanje br.2: $19^{\circ}21'15.06''/ 252^{\circ}59'6.36'' \rightarrow 29^{\circ}26'3.25''/ 264^{\circ}56'7.43''$



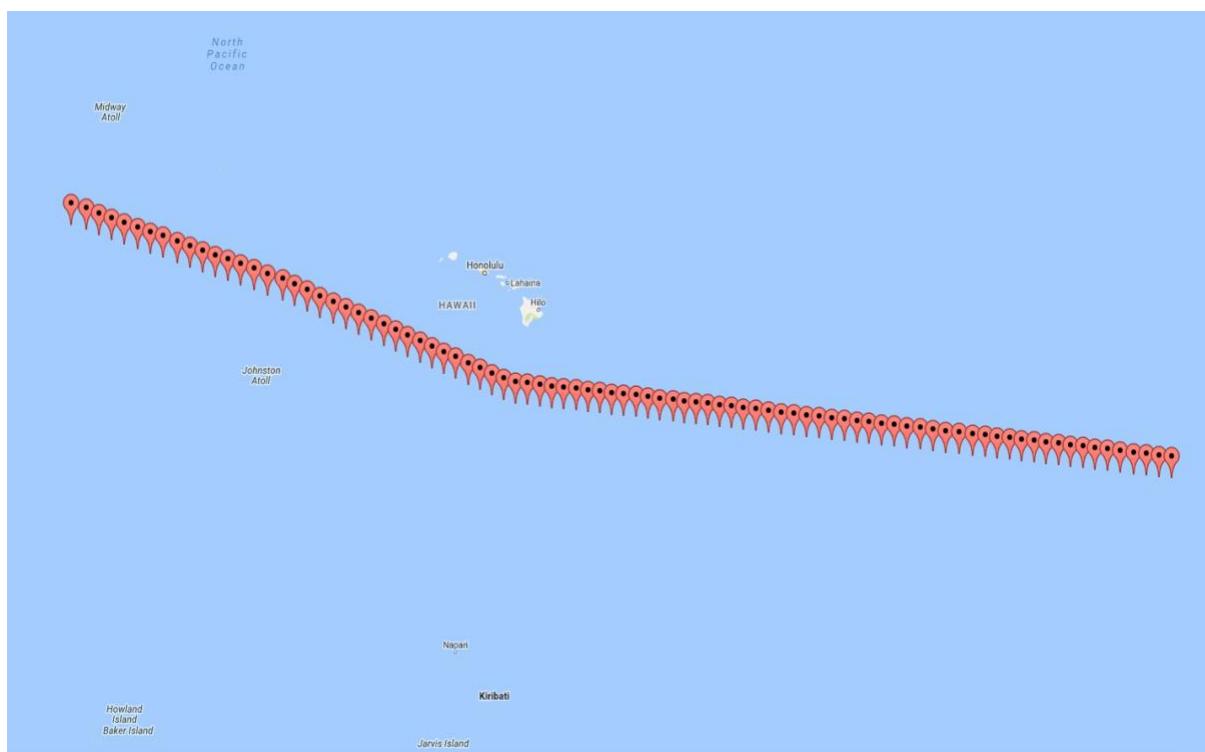
Slika 33. Putovanje br.3: $29^{\circ}26'3.25''/ 264^{\circ}56'3.45'' \rightarrow 23^{\circ}21'27.48''/ 180^{\circ}40'20.4''$



Slika 34. Putovanje br.4: $23^{\circ}36'35.64''/ 179^{\circ}48'55.26'' \rightarrow 35^{\circ}9'43.68''/ 129^{\circ}28'12''$



Slika 35. Putovanje br.5: $34^{\circ}30'24.24''/ 129^{\circ}3'44.46'' \rightarrow 23^{\circ}35'16.14''/ 179^{\circ}50'17.58''$



Slika 36. Putovanje br.6: $23^{\circ}24'39''/ 180^{\circ}33'23.88'' \rightarrow 12^{\circ}1'51.9''/ 237^{\circ}55'41.1''$



Slika 37. Putovanje br.7: $21^{\circ}54'55.5''/ 113^{\circ}12'43.02'' \rightarrow -4^{\circ}49'34.44''/ 325^{\circ}16'18.24''$

Prilog C: Tablice korelacije

Tablica 36. Tablica korelacija varijabli 1 – 19

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
1	1,00	0,74	0,13	0,80	0,07	0,93	0,25	0,29	0,86	0,82	0,83	0,88	0,84	-0,03	0,05	-0,00	0,95	-0,02	0,08
2	0,74	1,00	0,01	0,90	0,05	0,68	0,30	0,41	0,87	0,87	0,87	0,86	0,82	-0,04	0,10	-0,00	0,75	0,01	0,06
3	0,13	0,01	1,00	-0,01	-0,01	0,10	0,07	0,03	0,10	0,04	0,06	0,07	0,02	-0,01	0,01	0,00	0,15	0,08	0,03
4	0,80	0,90	-0,01	1,00	-0,01	0,76	0,38	0,39	0,95	0,97	0,94	0,95	0,92	-0,00	0,08	-0,03	0,78	-0,09	0,06
5	0,07	0,05	-0,01	-0,01	1,00	0,11	-0,48	-0,43	-0,06	-0,09	0,01	-0,01	-0,13	-0,40	0,03	0,10	0,11	0,87	-0,10
6	0,93	0,68	0,10	0,76	0,11	1,00	0,23	0,22	0,79	0,76	0,77	0,82	0,78	-0,08	0,05	0,01	0,88	-0,01	0,06
7	0,25	0,30	0,07	0,38	-0,48	0,23	1,00	0,29	0,43	0,44	0,38	0,37	0,45	0,07	0,03	-0,07	0,26	-0,44	0,07
8	0,29	0,41	0,03	0,39	-0,43	0,22	0,29	1,00	0,41	0,41	0,39	0,37	0,41	0,22	0,10	0,01	0,34	-0,34	0,07
9	0,86	0,87	0,10	0,95	-0,06	0,79	0,43	0,41	1,00	0,97	0,96	0,99	0,92	0,01	0,05	-0,04	0,85	-0,10	0,07
10	0,82	0,87	0,04	0,97	-0,09	0,76	0,44	0,41	0,97	1,00	0,96	0,96	0,96	0,02	0,04	-0,06	0,80	-0,12	0,07
11	0,83	0,87	0,06	0,94	0,01	0,77	0,38	0,39	0,96	0,96	1,00	0,96	0,91	-0,03	0,04	-0,04	0,82	-0,02	0,07
12	0,88	0,86	0,07	0,95	-0,01	0,82	0,37	0,37	0,99	0,96	0,96	1,00	0,90	-0,01	0,04	-0,04	0,85	-0,08	0,08
13	0,84	0,82	0,02	0,92	-0,13	0,78	0,45	0,41	0,92	0,96	0,91	0,90	1,00	0,04	0,03	-0,07	0,80	-0,16	0,06
14	-0,03	-0,04	-0,01	-0,00	-0,40	-0,08	0,07	0,22	0,01	0,02	-0,03	-0,01	0,04	1,00	0,02	-0,07	-0,04	-0,38	0,03
15	0,05	0,10	0,01	0,08	0,03	0,05	0,03	0,10	0,05	0,04	0,04	0,04	0,03	0,02	1,00	0,63	0,10	0,03	-0,03
16	-0,00	-0,00	0,00	-0,03	0,10	0,01	-0,07	0,01	-0,04	-0,06	-0,04	-0,04	-0,07	-0,07	0,63	1,00	0,04	0,09	-0,01
17	0,95	0,75	0,15	0,78	0,11	0,88	0,26	0,34	0,85	0,80	0,82	0,85	0,80	-0,04	0,10	0,04	1,00	0,04	0,09
18	-0,02	0,01	0,08	-0,09	0,87	-0,01	-0,44	-0,34	-0,10	-0,12	-0,02	-0,08	-0,16	-0,38	0,03	0,09	0,04	1,00	-0,08
19	0,08	0,06	0,03	0,06	-0,10	0,06	0,07	0,07	0,07	0,07	0,08	0,06	0,03	-0,03	-0,01	0,09	-0,08	1,00	
20	0,20	0,12	0,06	0,14	0,21	0,21	-0,04	-0,07	0,18	0,12	0,15	0,18	0,09	0,00	0,04	0,01	0,20	0,11	-0,10
21	-0,10	-0,20	0,05	-0,22	-0,22	-0,09	0,04	0,10	-0,14	-0,17	-0,15	-0,14	-0,16	0,02	-0,07	-0,04	-0,11	-0,17	0,02
22	-0,22	-0,21	-0,08	-0,28	0,86	-0,20	-0,54	-0,45	-0,34	-0,35	-0,27	-0,30	-0,38	-0,28	0,05	0,11	-0,17	0,79	-0,09
23	0,15	0,16	0,03	0,26	-0,50	0,12	0,92	0,22	0,29	0,33	0,25	0,23	0,38	0,11	0,01	-0,09	0,15	-0,46	0,05
24	-0,04	-0,08	0,10	-0,09	-0,12	-0,05	0,11	-0,18	0,01	0,00	-0,00	-0,02	0,02	-0,05	-0,13	-0,03	-0,06	-0,03	0,01
25	0,09	0,10	0,06	0,07	0,32	0,08	-0,12	-0,15	0,05	0,04	0,07	0,05	0,03	-0,01	0,08	0,11	0,14	0,36	0,06
26	0,16	0,09	0,04	0,08	-0,23	0,10	0,17	0,09	0,18	0,17	0,17	0,17	0,17	0,09	-0,08	-0,15	0,17	-0,26	0,05
27	0,15	-0,01	0,14	-0,03	-0,10	0,13	0,03	0,10	0,07	0,03	0,07	0,08	0,03	-0,01	-0,12	-0,04	0,14	0,10	0,15
28	-0,07	-0,09	0,13	-0,12	0,18	-0,06	-0,07	-0,29	-0,07	-0,09	-0,07	-0,09	-0,09	-0,16	-0,09	0,09	-0,03	0,31	0,02
29	0,08	-0,09	0,16	-0,13	-0,08	0,07	-0,05	-0,09	-0,03	-0,07	-0,02	-0,02	-0,06	0,02	-0,04	0,08	0,05	0,16	0,09
30	-0,09	-0,11	0,06	-0,09	0,15	-0,09	-0,02	-0,38	-0,04	-0,05	-0,05	-0,06	-0,01	-0,13	-0,16	-0,23	-0,13	0,16	-0,12
31	0,02	0,20	-0,03	0,22	0,13	-0,03	0,28	0,07	0,17	0,23	0,19	0,12	0,24	-0,01	0,15	-0,03	0,06	0,15	-0,16
32	0,02	0,14	-0,00	0,16	0,32	0,00	0,08	-0,34	0,12	0,16	0,15	0,08	0,18	-0,12	0,03	-0,06	0,04	0,33	-0,12
33	-0,10	-0,21	0,05	-0,27	0,27	-0,07	-0,32	-0,20	-0,23	-0,28	-0,22	-0,19	-0,29	-0,07	-0,09	0,08	-0,08	0,32	0,06
34	0,46	0,50	0,12	0,42	0,26	0,42	0,16	0,14	0,41	0,42	0,44	0,41	0,42	-0,14	0,12	0,00	0,53	0,28	0,16
35	0,38	0,40	0,08	0,33	0,20	0,32	0,18	0,14	0,34	0,35	0,37	0,33	0,34	-0,11	0,14	0,13	0,46	0,24	0,19
36	0,43	0,45	0,04	0,39	0,08	0,40	0,04	0,22	0,38	0,37	0,39	0,39	0,36	-0,07	0,07	0,06	0,47	0,03	0,19
37	-0,14	-0,07	0,06	-0,13	0,16	-0,14	-0,10	-0,32	-0,11	-0,13	-0,12	-0,12	-0,15	-0,15	-0,10	-0,02	-0,13	0,19	0,05
38	-0,31	-0,10	-0,00	-0,17	-0,22	-0,47	0,05	0,03	-0,14	-0,18	-0,24	-0,19	-0,21	0,19	-0,00	-0,04	-0,26	-0,21	0,01

Tablica 37. Korelacijska tablica varijabli 20 – 38

	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38
1	0,20	-0,10	-0,22	0,15	-0,04	0,09	0,16	0,15	-0,07	0,08	-0,09	0,02	0,02	-0,10	0,46	0,38	0,43	-0,14	-0,31
2	0,12	-0,20	-0,21	0,16	-0,08	0,10	0,09	-0,01	-0,09	-0,09	-0,11	0,20	0,14	-0,21	0,50	0,40	0,45	-0,07	-0,10
3	0,06	0,05	-0,08	0,03	0,10	0,06	0,04	0,14	0,13	0,16	0,06	-0,03	-0,00	0,05	0,12	0,08	0,04	0,06	-0,00
4	0,14	-0,22	-0,28	0,26	-0,09	0,07	0,08	-0,03	-0,12	-0,13	-0,09	0,22	0,16	-0,27	0,42	0,33	0,39	-0,13	-0,17
5	0,21	-0,22	0,86	-0,50	-0,12	0,32	-0,23	-0,10	0,18	-0,08	0,15	0,13	0,32	0,27	0,26	0,20	0,08	0,16	-0,22
6	0,21	-0,09	-0,20	0,12	-0,05	0,08	0,10	0,13	-0,06	0,07	-0,09	-0,03	0,00	-0,07	0,42	0,32	0,40	-0,14	-0,47

	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38
7	-0,04	0,04	-0,54	0,92	0,11	-0,12	0,17	0,03	-0,07	-0,05	-0,02	0,28	0,08	-0,32	0,16	0,18	0,04	-0,10	0,05
8	-0,07	0,10	-0,45	0,22	-0,18	-0,15	0,09	0,10	-0,29	-0,09	-0,38	0,07	-0,34	-0,20	0,14	0,14	0,22	-0,32	0,03
9	0,18	-0,14	-0,34	0,29	0,01	0,05	0,18	0,07	-0,07	-0,03	-0,04	0,17	0,12	-0,23	0,41	0,34	0,38	-0,11	-0,14
10	0,12	-0,17	-0,35	0,33	0,00	0,04	0,17	0,03	-0,09	-0,07	-0,05	0,23	0,16	-0,28	0,42	0,35	0,37	-0,13	-0,18
11	0,15	-0,15	-0,27	0,25	-0,00	0,07	0,17	0,07	-0,07	-0,02	-0,05	0,19	0,15	-0,22	0,44	0,37	0,39	-0,12	-0,24
12	0,18	-0,14	-0,30	0,23	-0,02	0,05	0,17	0,08	-0,09	-0,02	-0,06	0,12	0,08	-0,19	0,41	0,33	0,39	-0,12	-0,19
13	0,09	-0,16	-0,38	0,38	0,02	0,03	0,17	0,03	-0,09	-0,06	-0,01	0,24	0,18	-0,29	0,42	0,34	0,36	-0,15	-0,21
14	0,00	0,02	-0,28	0,11	-0,05	-0,01	0,09	-0,01	-0,16	0,02	-0,13	-0,01	-0,12	-0,07	-0,14	-0,11	-0,07	-0,15	0,19
15	0,04	-0,07	0,05	0,01	-0,13	0,08	-0,08	-0,12	-0,09	-0,04	-0,16	0,15	0,03	-0,09	0,12	0,14	0,07	-0,10	-0,00
16	0,01	-0,04	0,11	-0,09	-0,03	0,11	-0,15	-0,04	0,09	0,08	-0,23	-0,03	-0,06	0,08	0,00	0,13	0,06	-0,02	-0,04
17	0,20	-0,11	-0,17	0,15	-0,06	0,14	0,17	0,14	-0,03	0,05	-0,13	0,06	0,04	-0,08	0,53	0,46	0,47	-0,13	-0,26
18	0,11	-0,17	0,79	-0,46	-0,03	0,36	-0,26	0,10	0,31	0,16	0,16	0,15	0,33	0,32	0,28	0,24	0,03	0,19	-0,21
19	-0,10	0,02	-0,09	0,05	0,01	0,06	0,05	0,15	0,02	0,09	-0,12	-0,16	-0,12	0,06	0,16	0,19	0,19	0,05	0,01
20	1,00	-0,09	0,09	-0,08	-0,03	-0,02	-0,04	-0,13	-0,04	-0,10	0,11	0,14	0,11	-0,06	-0,09	-0,16	-0,14	-0,07	-0,07
21	-0,09	1,00	-0,17	0,05	0,03	-0,20	0,21	0,32	-0,18	0,19	0,04	-0,26	-0,30	-0,09	-0,05	-0,06	0,09	-0,24	-0,04
22	0,09	-0,17	1,00	-0,48	-0,19	0,29	-0,25	-0,16	0,12	-0,10	0,11	0,13	0,29	0,29	0,14	0,13	-0,03	0,09	-0,07
23	-0,08	0,05	-0,48	1,00	0,08	-0,13	0,15	-0,02	-0,09	-0,09	0,03	0,33	0,12	-0,33	0,08	0,11	-0,05	-0,16	0,08
24	-0,03	0,03	-0,19	0,08	1,00	0,15	0,10	0,12	0,46	0,17	0,53	-0,12	0,13	0,00	-0,03	0,04	-0,04	0,51	0,04
25	-0,02	-0,20	0,29	-0,13	0,15	1,00	-0,20	0,18	0,37	0,06	0,19	-0,09	0,24	0,32	0,41	0,42	0,25	0,30	-0,07
26	-0,04	0,21	-0,25	0,15	0,10	-0,20	1,00	0,23	-0,18	0,19	-0,00	-0,02	-0,01	0,03	0,13	0,21	0,13	-0,09	0,02
27	-0,13	0,32	-0,16	-0,02	0,12	0,18	0,23	1,00	0,08	0,78	0,04	-0,41	-0,32	0,44	0,23	0,25	0,18	0,05	-0,12
28	-0,04	-0,18	0,12	-0,09	0,46	0,37	-0,18	0,08	1,00	0,14	0,35	-0,21	0,21	0,30	0,05	0,12	0,00	0,53	-0,05
29	-0,10	0,19	-0,10	-0,09	0,17	0,06	0,19	0,78	0,14	1,00	-0,03	-0,29	-0,21	0,42	0,10	0,19	0,04	0,06	-0,16
30	0,11	0,04	0,11	0,03	0,53	0,19	-0,00	0,04	0,35	-0,03	1,00	0,12	0,40	-0,10	-0,00	-0,16	-0,14	0,41	-0,04
31	0,14	-0,26	0,13	0,33	-0,12	-0,09	-0,02	-0,41	-0,21	-0,29	0,12	1,00	0,63	-0,47	0,14	0,06	-0,14	-0,09	0,05
32	0,11	-0,30	0,29	0,12	0,13	0,24	-0,01	-0,32	0,21	-0,21	0,40	0,63	1,00	-0,21	0,23	0,18	-0,05	0,23	-0,03
33	-0,06	-0,09	0,29	-0,33	0,00	0,32	0,03	0,44	0,30	0,42	-0,10	-0,47	-0,21	1,00	-0,08	0,11	-0,07	0,18	-0,05
34	-0,09	-0,05	0,14	0,08	-0,03	0,41	0,13	0,23	0,05	0,10	-0,00	0,14	0,23	-0,08	1,00	0,86	0,78	0,07	-0,18
35	-0,16	-0,06	0,13	0,11	0,04	0,42	0,21	0,25	0,12	0,19	-0,16	0,06	0,18	0,11	0,86	1,00	0,73	0,08	-0,13
36	-0,14	0,09	-0,03	-0,05	-0,04	0,25	0,13	0,18	0,00	0,04	-0,14	-0,14	-0,05	-0,07	0,78	0,73	1,00	0,00	-0,17
37	-0,07	-0,24	0,09	-0,16	0,51	0,30	-0,09	0,05	0,53	0,06	0,41	-0,09	0,23	0,18	0,07	0,08	0,00	1,00	0,12
38	-0,07	-0,04	-0,07	0,08	0,04	-0,07	0,02	-0,12	-0,05	-0,16	-0,04	0,05	-0,03	-0,05	-0,18	-0,13	-0,17	0,12	1,00

Prilog D: Matrice zabune

Tablica 38. Matrica zabune metode naivnog Bayesa

Klasificirano kao	a	b	c	d	e
a=b	3407	112	78	8	14
b=c	317	5111	101	299	23
c=a	58	77	6188	30	57
d=d	10	135	24	2384	20
e=e	0	0	1	14	32

Tablica 39. Matrica zabune metode multinomijalne logističke regresije

Klasificirano kao	a	b	c	d	e
a=b	2065	1157	111	12	4
b=c	537	5303	219	273	6
c=a	112	209	6089	1	2
d=d	7	275	7	2060	2
e=e	11	12	2	19	4

Tablica 40. Matrica zabune metode višeslojnog perceptronu

Klasificirano kao	a	b	c	d	e
a=b	3136	172	35	2	4
b=c	162	5908	136	131	1
c=a	19	5	6389	0	0
d=d	2	192	8	2144	5
e=e	1	9	7	22	9

Tablica 41. Matrica zabune metode strojeva potpornih vektora

Klasificirano kao	a	b	c	d	e
a=b	3059	274	60	5	1
b=c	255	5878	21	184	0
c=a	15	17	6377	4	0
d=d	1	205	8	2137	0
e=e	3	10	9	19	7

Tablica 42. Matrica zabune metode stabala odluke

Klasificirano kao	a	b	c	d	e
a=b	3182	138	27	1	1
b=c	146	6054	11	120	7
c=a	19	4	6388	2	0
d=d	2	134	6	2202	7
e=e	5	2	1	16	24

Tablica 43. Matrica zabune metode nasumičnih šuma

Klasificirano kao	a	b	c	d	e
a=b	3225	99	23	1	1
b=c	104	6142	6	85	1
c=a	12	3	6398	0	0
d=d	0	120	4	2224	3
e=e	2	1	2	14	29

Tablica 44. Matrica zabune RF metode sa SFC kao izlaznim parametrom

Klasificirano kao	a	b	c	d
a=c	13611	103	20	7
b=b	130	1968	5	107
c=d	29	7	310	15
d=a	6	91	17	2073

Tablica 45. Matrica zabune RF metode sa sklizom kao izlaznim parametrom

Klasificirano kao	a	b	c	d
a=b	6548	192	293	9
b=a	286	1868	20	21
c=c	288	29	5708	151
d=d	11	22	244	2809

Tablica 46. Matrica zabune RF metode s trimom kao izlaznim parametrom

Klasificirano kao	a	b	c	d
a=e	10583	107	0	0
b=d	73	1696	0	92
c=b	0	0	207	20
d=c	0	76	15	5630

Tablica 47. Matrica zabune RF metode s potrebom za ukapljivanjem tereta kao izlaznim parametrom

Klasificirano kao	a	b	c
a=a	6503	17	38
b=b	80	600	118
c=c	26	75	11042

Popis slika

Slika 1. Širenje brodskih ispušnih plinova kroz slojeve atmosfere	14
Slika 2. Onečišćenje atmosfere ispuštanjem CO ₂ prijevoznim aktivnostima	20
Slika 3. Usporedba sastava ispušnih plinova motora 76S0ME tvrtke MAN Diesel & Turbo pogonjenog konvencionalnim gorivima (C) i prirodnim plinom (GI).....	35
Slika 4. 440 000 DWT supertanker nakon nanošenja FP zaštitnog premaza	39
Slika 5. Metode procjene brodskih operacijskih parametara.....	43
Slika 6. Modelsко испитivanje брода у базену	50
Slika 7. Ispitivanje брода у плавидби коришћењем CFD симулатора	52
Slika 8. Визуелни приказ поступака класификације и регресије.....	55
Slika 9. Krivulja sigmoidne funkcije	58
Slika 10. Arhitektura višeslojne perceptronske neuronske mreže	60
Slika 11. Transformacija помоћу језгрове функције у струјевима потпорних вектора (SVM)	62
Slika 12. Stablo potencijalnih ID3 generiranih odluka s atributima raspoređenima u чворове i vrijednosti atributa predstavljenih granama.....	65
Slika 13. Primjer određivanja dva razreda C1 i C2 u slučaju primjene većeg broja stabala odlučivanja (lijevo) te ansabla dobivenim „baggingom” (desno)	66
Slika 14. Pojednostavljen prikaz predviđanja algoritma nasumičnih šuma.....	67
Slika 15. Prikaz deseterostrukte tehnike unakrsne validacije	70
Slika 16. Primjer ovisnosti pogreške mjerena o protoku medija te najveća izmjerena vrijednost pogreške mjerene u %.....	83
Slika 17. Mjerač zakretnog momenta osovinskog voda MetaPower.....	84
Slika 18. Primjena nadziranog filtra balansiranja razreda na primjeru klasificiranih podataka prema potrošnji goriva	86
Slika 19. Primjena nenadziranog filtra S1-Z 100 na primjeru klasificiranih podataka prema potrošnji goriva	86
Slika 20. Primjena nenadziranog filtra S1-Z 100 na primjeru učenja algoritma nasumičnih šuma prema klasifikaciji potrošnje goriva	87
Slika 21. Značaj pojedinačnih atributa u gradnji modela nasumičnih šuma	92
Slika 22. Usporedba rezultata klasifikacije šest algoritama strojnog učenja prema standardnim mjerama učinkovitosti modeliranja klasifikacijskih algoritama.....	92
Slika 23. Usporedba rezultata regresije četiriju algoritama strojnog učenja prema standardnim mjerama učinkovitosti modeliranja regresijskih algoritama.....	95
Slika 24. Vizualizacija rezultata algoritama regresijskog modeliranja.....	96
Slika 25. Grafički prikaz točno klasificiranih primjeraka i koeficijenata korelacije	99
Slika 26. Grafički prikaz osnovnih parametara za izračun uzdužnog nagiba брода	106
Slika 27. Odnos trima i potrošnje goriva	107
Slika 28. Snaga na главној разводној плочи (kW)	109
Slika 29. UC – struktura modela.....	118
Slika 30. ST – struktura modela	123
Slika 31. Putovanje br.1: 9°30'59.19"/ 311°30'27.36" → -2°15'47"/ 72°7'4.76"	138
Slika 32. Putovanje br.2: 19°21'15.06"/ 252°59'6.36" → 29°26'3.25"/ 264°56'7.43"	138
Slika 33. Putovanje br.3: 29°26'3.25"/ 264°56'3.45" → 23°21'27.48"/ 180°40'20.4"	139
Slika 34. Putovanje br.4: 23°36'35.64"/ 179°48'55.26" → 35°9'43.68"/ 129°28'12"	139
Slika 35. Putovanje br.5: 34°30'24.24"/ 129°3'44.46" → 23°35'16.14"/ 179°50'17.58"	140
Slika 36. Putovanje br.6: 23°24'39"/ 180°33'23.88" → 12°1'51.9"/ 237°55'41.1"	140
Slika 37. Putovanje br.7: 21°54'55.5"/ 113°12'43.02" → -4°49'34.44"/ 325°16'18.24"	141

Popis tablica

Tablica 1. Vrijednost koeficijenta C_f za različita goriva u brodskoj upotrebi [87]	26
Tablica 2. Sažetak globalnog potencijala smanjenja ugljikova dioksida (MT)	36
Tablica 3. Standardna matrica zabune	72
Tablica 4. Specifikacija ugrađenog glavnog pogonskog stroja	77
Tablica 5. Specifikacija brodskog vijka	78
Tablica 6. Serije preuzimanja i snimanja podataka	80
Tablica 7. Konačan popis varijabli preostalih nakon korelacije	81
Tablica 8. Vrednovanje klasifikacije pomoću naivnog Bayesa	88
Tablica 9. Vrednovanje multinomijalne logističke regresije	89
Tablica 10. Vrednovanje višeslojnog perceptronra	90
Tablica 11. Vrednovanje strojeva potpornih vektora	90
Tablica 12. Vrednovanje stabla odluke	91
Tablica 13. Vrednovanje metode nasumičnih šuma	91
Tablica 14. Rezultati algoritma linearne regresije	93
Tablica 15. Rezultati predviđanja regresijskog algoritma višeslojnog perceptronra	94
Tablica 16. Rezultati predviđanja regresijskog algoritma strojeva potpornih vektora	94
Tablica 17. Rezultati predviđanja regresijskog algoritma višeslojnog perceptronra	94
Tablica 18. Pregled različitih kombinacija ulaznih varijabli	98
Tablica 19. Vrednovanje klasifikacijske RF metode sa SFC kao izlaznim parametrom	103
Tablica 20. Rezultati predviđanja regresijske RF metode sa SFC kao izlaznim parametrom	103
Tablica 21. Vrednovanje klasifikacijske RF metode sa sklizom kao izlaznim parametrom	105
Tablica 22. Rezultati predviđanja regresijske RF metode sa sklizom kao izlaznim parametrom	105
Tablica 23. Rezultati predviđanja regresijske RF metode s brzinom broda kao izlaznim parametrom	105
Tablica 24. Vrednovanje klasifikacijske RF metode s trimom kao izlaznim parametrom	108
Tablica 25. Rezultati predviđanja regresijske RF metode s trimom kao izlaznim parametrom	108
Tablica 26. Vrednovanje klasifikacijske RF metode s potrebom za ukapljivanjem tereta kao izlaznim parametrom	109
Tablica 27. Rezultati predviđanja regresijske RF metode s potrebom za ukapljivanjem tereta	110
Tablica 28. Prijelazi između stanja	122
Tablica 29. Tablica identifikacija SWOT elemenata modela	124
Tablica 30. TOWS matrica	125
Tablica 31. Prikupljeni senzorski podaci sa sustava nadzora i upravljanja brodskim postrojenjem ..	133
Tablica 32. Prikupljeni podaci sustava elektronskih karata (ECDIS)	135
Tablica 33. Prikupljeni podaci iz brodskih podnevnih izvješća	135
Tablica 34. Prikupljeni javno dostupni meteorološki i oceanografski podaci	136
Tablica 35. Popis izabranih varijabli preuzetih iz snimljenog skupa podataka	136
Tablica 36. Tablica korelacije varijabli 1 – 19	142
Tablica 37. Korelacijska tablica varijabli 20 – 38	142
Tablica 38. Matrica zabune metode naivnog Bayesa	144
Tablica 39. Matrica zabune metode multinomijalne logističke regresije	144
Tablica 40. Matrica zabune metode višeslojnog perceptronra	144
Tablica 41. Matrica zabune metode strojeva potpornih vektora	144
Tablica 42. Matrica zabune metode stabala odluke	144
Tablica 43. Matrica zabune metode nasumičnih šuma	145
Tablica 44. Matrica zabune RF metode sa SFC kao izlaznim parametrom	145
Tablica 45. Matrica zabune RF metode sa sklizom kao izlaznim parametrom	145
Tablica 46. Matrica zabune RF metode s trimom kao izlaznim parametrom	145

Tablica 47. Matrica zabune RF metode s potrebom za ukapljivanjem tereta kao izlaznim parametrom 145

Popis oznaka i kratica

ABS	Američki klasifikacijski zavod (engl. <i>American Bureau of Shipping</i>)
AHA	Američko udruženje srca (engl. <i>American Heart Association</i>)
AHR	prosječna hravavost površine (engl. <i>average hull roughness</i>)
AIC	Akaike informacijski kriterij
ANN	umjetne neuronske mreže (engl. <i>artificial neural network</i>)
ASTM	Američko društvo za testiranje i materijale (engl. <i>American Society for Testing and Materials</i>)
AUPRC	površina ispod krivulje preciznog povlačenja (engl. <i>area under precision-recall curve</i>)
AUROC	površina ispod ROC (engl. <i>area under receiver operating curve</i>)
BC/EC	crni/elementarni ugljik (engl. <i>black/elemental carbon</i>)
BIMCO	Baltičko i međunarodno pomorsko vijeće (engl. <i>The Baltic and International Maritime Council</i>)
BOG	ispareni plin iz tekućeg stanja, uobičajeno se rabi kod prirodnog ukapljenoga plina kao mjera isparavanja – gubitka tereta pri brodskom transportu (engl. <i>boil-off gas</i>)
C	kemijski simbol za ugljik
C4.5	ekstenzija ID3 algoritma stabala odluke
C _c	koeficijent korelacije
CH ₄	kemijska (empirijska) oznaka molekule metana
CFD	računalna dinamika fluida (engl. <i>computational fluid dynamics</i>)
CHAID	Alat za otkrivanje odnosa među varijablama (engl. <i>Chi-square Automatic Interaction Detector</i>)
CLT	skraćeni i opterećeni vrh vijka (engl. <i>contracted and loaded tip propeller</i>)
CMV	kružna srednja vrijednost (engl. <i>cycle mean value</i>)
CO ₂	kemijska (empirijska) oznaka molekule ugljikova dioksida ili ugljik (IV) oksida
CRISP-DM	Standardni otvoreni procesni model rudarenja podataka (engl. <i>Cross Industry Standard Process for Data Mining</i>)
DDWD	skraćenica tvrtke za suho dokovanje i remont brodova u Dubaiju, Ujedinjeni Arapski Emirati (engl. <i>Drydocks World Dubai</i>)
DNC	digitalne pomorske karte (engl. <i>digital navigational charts</i>)
DSS	Douglasova ljestvica stanja mora (engl. <i>Douglas sea scale, DSS</i>)
DSS	sustav podrške pri odlučivanju (engl. <i>decision support system</i>)
DT-J48	stabla odluke upotrebom C4.5 algoritma s J48 java implementacijom
DWT	mjera nosivosti broda (engl. <i>deadweight</i>)

ECDIS	informacijski sustav s prikazom elektroničkih pomorskih karata (engl. <i>electronic chart display and information system</i>)
EEDI	projektni indeks energetske učinkovitosti (engl. <i>energy efficiency design index</i>)
EEOI	Brodski operacijski pokazatelj energetske učinkovitosti (engl. <i>Energy Efficiency Operational Indicator</i>)
ELISA	enzimski povezani imunosorbentni test (engl. <i>enzyme-linked immunosorbent assay</i>)
EM	maksimizacija očekivanja (engl. <i>expectation maximization</i>)
ENC	elektroničke pomorske karte (engl. <i>electronic navigational charts</i>)
EnPI	Pokazatelj energetske učinkovitosti (engl. <i>Energy Performance Indicator</i>)
EPA	Američka agencija za zaštitu okoliša (engl. <i>U.S. Environmental Protection Agency</i>)
F ₁	harmonijska sredina preciznosti i stvarne pozitivne stope
FC	potrošnja goriva (engl. <i>fuel consumption</i>)
FFR	floropolimerski premaz s čišćenjem obraštanja (engl. <i>flouropolymer foul release</i>)
FORM	metoda pouzdanosti prvog reda (engl. <i>first order reliability method</i>)
FP	fine čestice (engl. <i>fine particles</i>)
FP	floropolimerski premaz
FPP	vijak s fiksnim krilima (engl. <i>fixed pitch propeller</i>)
FPR	netočna pozitivna stopa (engl. <i>false positive rate</i>)
FSO	tanker za skladištenje i iskrcavanje (engl. <i>floating storage and offloading tanker</i>)
GHG	staklenički plin (engl. <i>greenhouse gas</i>)
GLM	linearna regresija (engl. <i>linear regression or generalized linear model</i>)
GMM	Gaussovi miješani modeli (engl. <i>Gaussian mixture models</i>)
GP	Gaussov proces
GPR	Gaussov proces regresije
GPS	Sustav globalnog pozicioniranja (engl. <i>Global Positioning System</i>)
GT	ukupna zapremina broda (engl. <i>gross tonnage</i>)
GUI	korisničko sučelje vizualizacije (engl. <i>graphical user interface</i>)
H	kemijski simbol za vodik
H	oznaka entropije
HFO	mazut (engl. <i>heavy fuel oil</i>)
IACS	Međunarodna udružba klasifikacijskih društava (engl. <i>The International Association of Classification Societies</i>)
IAS	sustav integriranog upravljanja, nadzora i alarmiranja (engl. <i>integrated automation system</i>)
ID3	J. Ross Quinlanov algoritam stabla odluke

IEA	Međunarodna agencija za energetiku (engl. <i>International Energy Agency</i>)
IG	informacijska dobit (engl. <i>information gain</i>)
IgE	specifični imonoglobulin E
IMO	Međunarodna pomorska organizacija (engl. <i>International Maritime Organization</i>)
IoT	internet stvari (engl. <i>Internet of Things</i>)
IPCC	Međuvladin panel o klimatskim promjenama (engl. <i>Intergovernmental Panel on Climate Change</i>)
ISO	Međunarodna organizacija za standardizaciju (engl. <i>International Organization for Standardization</i>)
ITTC	Međunarodna konferencija vučnih tankova (engl. <i>International Towing Tank Conference</i>)
JDK	Java SE razvojni paket (engl. <i>Java SE development kit</i>)
K-Chief	integrirani sustav upravljanja, nadgledanja i alarmiranja proizvođača Kongsberg Maritime
KDD	otkrivanje korisnih znanja iz podataka (engl. <i>knowledge discovery in databases</i>)
LNG	ukapljeni prirodni plin (engl. <i>liquefied natural gas</i>)
LPG	ukapljeni naftni plin (engl. <i>liquefied petroleum gas</i>)
LR	logistička regresija
LSE	premazi niske površinske energije (engl. <i>low surface energy coatings</i>)
MACC	krivulja graničnog smanjenja troškova (engl. <i>marginal abatement cost curves</i>)
MAE	srednja apsolutna pogreška (engl. <i>mean absolute error</i>)
MARPOL 73-78	Međunarodna konvencija o sprječavanju onečišćenja s brodova, 1973., izmijenjena Protokolom iz 1978. godine (engl. <i>The International Convention for the Prevention of Pollution from Ships, 1973 as modified by the Protocol of 1978</i>)
MCC	Mathewsov koeficijent korelaciјe
MCR	maksimalna trajna snaga (engl. <i>maximum continuous rating</i>)
MCS	Monte Carlo simulacija
ME-GI	oznaka elektronički upravljanog dvotaktnog motora na teško gorivo i prirodni plin tvrtke MAN Diesel&Turbo
MEPC	Odbor za zaštitu morskog okoliša (engl. <i>Marine Environment Protection Committee</i>)
MDO	brodsko dizelsko ulje (engl. <i>marine diesel oil</i>)
MGO	brodsko plinsko ulje (engl. <i>marine gas oil</i>)
MLP	višeslojni perceptron (engl. <i>multilayer perceptron</i>)
MLR	multinomijalna logistička regresija

MRV	Plan praćenja, izvješćivanja i provjere emisija CO ₂ (engl. <i>Monitoring, Reporting and Verification of CO₂ Emissions Plan</i>)
MSE	pogreška srednjeg kvadrata (engl. <i>mean squared error</i>)
MT	metrička tona jednaka je 1000 kilograma (engl. <i>metric ton</i>)
NB	naivni Bayes
NCR	normalni kontinuirani broj okretaja (engl. <i>normal continuous rating</i>)
NO	kemijska (empirijska) oznaka molekule dušikovog monoksida
NO _x	kemijska (empirijska) oznaka dušikovih oksida
OCIMF	Međunarodni pomorski forum naftnih tvrtki (engl. <i>Oil Companies International Marine Forum</i>)
OOB	podaci izvan skupa za učenje (engl. <i>out-of-bag</i>)
ORT	mjera ortogonalnosti (engl. <i>orthogonality measure</i>)
pH	mjera kiselosti ili aciditeta (lat. <i>potentia hydrogenii</i>)
PM	fine čestice (engl. <i>particulate matters</i>)
PCTC	brod za prijevoz cestovnih motornih vozila (engl. <i>Pure Car and Truck Carrier</i>)
PLNA	test poplitealnih limfnih čvorova (engl. <i>popliteal lymph node assay</i>)
ppmv	milijunti volumni dijelovi (engl. <i>parts per million by volume</i>)
PPR	Pododbor za prevenciju onečišćenja i odziv (engl. <i>Pollution Prevention and Response Sub-Committee</i>)
PPV	preciznost (engl. <i>precision or positive predictive value</i>)
PTI	osovinski generator kao dodatni izvor el. energije (engl. <i>power take-in</i>)
Puk	Pearsonov univerzalni kernel
RAE	relativna apsolutna pogreška kvadrata (engl. <i>relative absolute error</i>)
RF	nasumične šume (engl. <i>random forests</i>)
RMSE	srednja kvadratna pogreška (engl. <i>root mean square error</i>)
RO-RO	brodovi za prijevoz kotrljajućeg tereta (engl. <i>roll on – roll off</i>)
ROC	krivulja radnog svojstva prijemnika (engl. <i>receiver operating characteristics</i>)
RRSE	korijenska kvadratna pogreška kvadrata (engl. <i>root relative squared error</i>)
SEEMP	Brodska plan upravljanja energetskom učinkovitosti (engl. <i>Ship energy efficiency management plan</i>)
SFC	specifična potrošnja goriva (engl. <i>Specific Fuel Consumption</i>)
SFQ	metoda vrednovanja najprikladnijeg senzorskog signala (engl. <i>sensor fusion quality</i>)
SMO	Weka implementacija strojeva potpornih vektora za klasifikaciju
SMOreg	Weka implementacija strojeva potpornih vektora za regresiju

SMS	Sustav upravljanja sigurnošću (engl. <i>Safety Management System</i>)
SNAME	Međunarodno udruženje inženjera brodogradnje i pomorskih inženjera (engl. <i>The Society of Naval Architects and Marine Engineers</i>)
SO ₂	kemijska (empirijska) oznaka sumpornog dioksida
SO _x	kemijska (empirijska) oznaka sumpornih oksida
SOG	brzina preko dna (engl. <i>speed over ground</i>)
ST	tranzicija stanja (engl. <i>state transition</i>)
STaGE	hibridni pogon broda kombinacijom parne turbine i električne propulzije, oboje izgaranjem prirodnog plina kao goriva (engl. <i>steam turbine and gas engines</i>)
SVM	strojevi potpornih vektora (engl. <i>support vector machines</i>)
SWOT	akronim od riječi snage, slabosti mogućosti i prijetnje (engl. <i>strengths, weaknesses, opportunities and threats</i>)
TPR	stvarna pozitivna stopa (engl. <i>true positive rate</i>)
TgN	teragram dušika
TOWS	akronim od riječi prijetnje, mogućnosti, slabosti i snage (engl. <i>threats, opportunities, weaknesses and strengths</i>)
UC	komponente i međusobna stanja (engl. <i>universe of discourse and couplings</i>)
UCS	Američka udruga zabrinutih znanstvenika (engl. <i>Union of Concerned Scientists</i>)
UFP	ultrafine čestice (engl. <i>ultrafine particles</i>)
USD	američka nacionalna valuta, dolar (engl. <i>US dollar</i>)
VOC	isparivi organski spojevi (engl. <i>volatile organic compounds</i>)
VTG	vektorski trag i brzina preko dna (engl. <i>vector track and speed over the ground</i>)
WA	ponderirani prosjek (engl. <i>weighted average</i>)
WHO	Svjetska zdravstvena organizacija (engl. <i>World Health Organization</i>)

Literatura

- [1] J. Faber, B. Behrends i D. Nelissen, Analysis of GHG Marginal Abatement Cost Curves, CE Delft, Delft, 2011.
- [2] B. Russell, D. Amand, J. Faber, D. Nelissen i H. Wang, Summary of the Report Submitted to the International Maritime Organization (IMO): Marginal Abatement Costs and Cost Effectiveness of Energy-Efficiency Measures, SNAME, 2010.
- [3] International Energy Agency, CO₂ emissions from fuel combustion highlights, International Energy Agency, Paris, 2016.
- [4] J. Faber, A. Markowska, D. Nelissen, M. Davidson, V. Eyring, I. Cionni i E. Selstad, Technical support for European action to reducing Greenhouse Gas Emissions from international maritime transport, Delft, 2009.
- [5] S. Alvik, M. Eide, Ø. Endresen, P. Hoffmann i T. Longva, Pathways to low carbon shipping. Abatement potential towards 2030., DNV, Høvik, 2010.
- [6] P. Gilbert, A. Bows-Larkin, S. Mander i C. Walsh, Technologies for the high seas: meeting the climate challenge, Carbon Management, svez. 5:4, pp. 447-461, 2014.
- [7] T. Smith, J. Jalkanen, B. Anderson, J. Corbett, J. Faber, S. Hanayama, E. O'Keeffe, S. Parker, L. Johansson, L. Aldous, C. Raucci, M. Traut, S. Ettinger, D. Nelissen, D. Lee, S. Ng, A. Agrawal, J. Winebrake, M. Hoen, S. Chesworth i A. Pandey, Third IMO GHG Study 2014 Executive Summary and Final Report, IMO, London, 2015.
- [8] N. Rehmatulla i T. Smith, Barriers to energy efficient and low carbon shipping, Ocean Engineering, svez. 110, p. 102–112, 10 2015.
- [9] H. Lindstad, R. Verbeek, M. Blok, S. Zyl, A. Hübscher, H. Kramer, J. Purwanto, O. Ivanova i H. Boonman, GHG emission reduction potential of EU-related maritime transport and on its impacts, TNO, Delft, 2015.
- [10] E. Bouman, E. Lindstad, A. Rialland i A. Strømman, State-of-the-art technologies, measures, and potential for reducing GHG emissions from shipping – A review, Transportation Research, svez. Part D 52, p. 408–421, 2017.
- [11] J. Corbett, J. Winebrake, B. Comer i E. Green, Energy and GHG Emissions Savings Analyses of Fluoropolymer Foul Release Hull Coating, Energy and Environmental Research Associates, LLC, 2011.
- [12] M. Reichel, A. Minchev i N. Larsen, Trim Optimisation - Theory and Practice, TransNav- the International Journal on Marine Navigation and Safety of Sea Transportation, svez. 8, pp. 387-392, 2014.
- [13] A. Delitala, S. Gallino, L. Villa, K. Lagouvardos i A. Drago, Weather routing in long- distance Mediterranean routes, Theoretical and Applied Climatology, pp. 125-137, 2010.
- [14] M. Ochi i L. Motter, Prediction of Extreme Ship Responses in Rough Seas of the North Atlantic, The Dynamics of Marine Vehicles and Structures in Waves, pp. 199-209, 1974.

- [15] C. G. Soares, Effect of Heavy Weather Maneuvering. on the Wave-Induced Vertical Bending Moments in Ship Structures, *Journal of Ship Research*, pp. Vol. 34, No. 1, pp. 60-68, 1990.
- [16] V. Dubrovskiy, Complex Comparison of Seakeeping: Method and Example, *Marine Technology*, Vol. 37, No. 4, pp. 223-229, 2000.
- [17] J. Prpić-Oršić, O. M. Faltinsen i J. Parunov, Influence of operability criteria limiting values on ship speed, *Brodogradnja/Shipbuilding*, Sves. %1 od %2Volume 67 Number 3, 2016, 2016.
- [18] P. Agnolucci, T. Smith i N. Rehmatulla, Energy efficiency and time charter rates: Energy efficiency savings recovered by ship owners in the Panamax market, *Transportation Research*, svez. Part A 66, p. 173–184, 2014.
- [19] A. Molland, *The maritime engineering reference handbook*, Oxford: Butter- worth- Heinemann, 2008.
- [20] D. Taylor, *The Speed and Power of Ships*, Ransdell Incorporated, Washington, D.C., 1933.
- [21] M. Gertler, A reanalysis of the original test data for the Taylor standard series, U.S. Government Printing Office, Washington, 1954.
- [22] A. Vučinić, *Hidrodinamika plovnih objekata*, Rijeka: Sveuciliste u Rijeci, 1997, p. 353.
- [23] J. Holtrop, A statistical re-analysis of resistance and propulsion data, *International Shipbuilding Progress*, svez. 28 (363), pp. 272-276, 1 11 1984.
- [24] J. Holtrop i G. Mennen, An approximate power prediction method, *International Shipbuilding Progress*, svez. 29 (335), pp. 166-170, 07 1982.
- [25] D. Phillips-Birt, *Ship Model Testing*, Leonard-Hill, 1970.
- [26] V. Bertram, *Practical Ship Hydrodynamics*, 2nd ur., Butterworth-Heinemann, 2011, p. 390.
- [27] V. Ruggiero, V. Filardi i F. Cucinotta, Mesh size influence in a CFD code on resistance evaluation of a motor yacht, *COMPIT07—computer and IT applications in the maritime industries*, p. 458–466, 2007.
- [28] R. Marcer, C. Berhault, L. Eca i L. Broberg, *Best Practice Guidelines for the application of Computational Fluid Dynamics in Marine Hydrodynamics*, VIRTUE – The Virtual Tank Utility in Europe, 2009.
- [29] Z. Lajic, U. Nielsen, J. Jensen i M. Blanke, *Fault-Tolerant Onboard Monitoring and Decision Support Systems*, 2010. [Mrežno]. Poveznica: <http://orbit.dtu.dk/files/5294221/S121%20Zoran%20Lajic.pdf>. [Pokušaj pristupa 15 06 2018].
- [30] J. Petersen, D. Jacobsen i O. Winther, Statistical modelling for ship propulsion efficiency, *Journal of Marine Science and Technology*, svez. 17, p. 30–39, December 2011.
- [31] U. Nielsen i J. Jensen, A novel approach for navigational guidance of ships using onboard monitoring systems, *Ocean Engineering*, svez. 38, pp. 444-455, 2011.

- [32] S. Hansen, J. Petersen, J. Jensen i M. Lützen, Performance Monitoring of Ships, 2012. [Mrežno]. Povezница: http://orbit.dtu.dk/files/77836530/Soren_V_Hansen_PhD_thesis_.PDF. [Pokušaj pristupa 15 06 2018].
- [33] R. Lu, O. Turan, E. Boulogouris, C. Banks i A. Incezik, A semi-empirical ship operational performance prediction model for voyage optimization towards energy efficient shipping, Ocean Engineering, br. 110, p. 8–28, 2015.
- [34] Y. Kwon, Speed loss due to added resistance in wind and waves, Naval Architect, svez. 3, pp. 14-16, 2008.
- [35] B. P. Pedersen, Data-driven Vessel Performance Monitoring, DTU Mechanical Engineering, Kongens Lyngby, 2014.
- [36] F. Zhao, W. Yang, W. Tan, S. Chou i W. Yu, An Overall Ship Propulsion Model for Fuel Efficiency Study, Energy Procedia, svez. 75, p. 813 – 818, 2015.
- [37] D. Trodden, A. Murphy, K. Pazouki i J. Sargeant, Fuel usage data analysis for efficient shipping operations, Ocean Engineering, svez. 110, p. 75–84, 2015.
- [38] N. Bialystocki i D. Konovessis, On the estimation of ship's fuel consumption and speed curve: A statistical approach, Journal of Ocean Engineering and Science, svez. 1, br. 2, pp. 157-166, April 2016.
- [39] L. Perera i B. Mo, Digitalization of Seagoing Vessels Under High Dimensional Data Driven Models, u the 36th International Conference on Ocean, Offshore and Arctic Engineering (OMAE 2017), 2017.
- [40] I. Witten, E. Frank, M. Hall i C. Pal, Data Mining Practical Machine Learning Tools and Techniques, Fourth Edition, 4th ur., C. Kent, Ur., Cambridge: Elsevier- Todd Green, 2017.
- [41] H. Wang, The end of the era of heavy fuel oil in maritime shipping, 07 2014. [Mrežno]. Povezница: <http://www.theicct.org/blogs/staff/end-era-heavy-fuel-oil-maritime-shipping>. [Pokušaj pristupa 09 10 2017].
- [42] L. Espenes, Emissions to air - Norwegian Maritime Authority, Norwegian Maritime Authority, 26 09 2016. [Mrežno]. Povezница: <https://www.sjofartsdir.no/en/shipping/vessels/environment/prevention-of-pollution-from-ships/emissions-to-air/>. [Pokušaj pristupa 09 10 2017].
- [43] V. Eyring, H. Köhler, J. van Aardenne i A. Lauer, Emissions from international shipping: 1. The last 50 years, Journal of Geophysical Research, svez. 110, br. D17305, 2005.
- [44] J. Wilson, Carriage of goods by sea, 5th ur., Harlow: Pearson Longman, 2004.
- [45] Ø. Endersen, E. Sørgård, J. Sundet, S. Dalsøren, I. Isaksen, T. Berglen i G. Gravir, Emission from international sea transportation and environmental impact, Journal of Geophysical Research, svez. 108, 2003.
- [46] R. Radonja, Model regista emisija ispušnih plinova u pomorskom prometu na područje hrvatskoga dijela Jadrana, Rijeka, 2013.

- [47] Y. Du, X. Xu, M. Chu i Y. Guo, Air particulate matter and cardiovascular disease: the epidemiological, biomedical and clinical evidence, *Journal of Thoracic Disease*, pp. E8-E19, 2016.
- [48] R. Brook, S. Rajagopalan, C. Popelli i J. Brook, Particulate Matter Air Pollution and Cardiovascular Disease, An Update to the Scientific Statement From the American Heart Association, American Heart Association, 2010.
- [49] E. Dybing, T. Løvdal, R. Hetland i M. Løvik, Respiratory allergy adjuvant and inflammatory affects of urban ambient particles, *Toxicology*, pp. 198:307-14, 2004.
- [50] N. Janssen, M. Gerlofs-Nijland i T. Lanki, Health effects of black carbon, Bonn, 2012.
- [51] K. Smith, M. Jerrett, H. Anderson i R. Burnett, Public Health Benefits of Strategies to Reduce Greenhouse-Gas Emissions: Health Implications of Short-Lived Greenhouse Pollutants, *The Lancet*, svez. 374, br. 9707, pp. 2091-2103, 2009.
- [52] K. Kuiken, Diesel Engines for ship propulsion and power plants, Target Global Energy Training, Onnen, 2018.
- [53] D. Lack, B. Lerner, C. Granier i E. Williams, Light Absorbing Carbon Emissions from Commercial Shipping, *Geophysical Research Letters*, svez. 35, br. L13815, 07 2008.
- [54] D. Lack i J. Corbett, Black Carbon from Ships: A Review of the Effects of Ship Speed, Fuel Quality and Exhaust Gas Scrubbing, *Atmospheric Chemistry and Physics*, svez. 12, br. 9, pp. 3985-4000, 2012.
- [55] IMO, Emissions inventory and analysis of impacts of short-lived climate forcing aerosols from international shipping activity in the Arctic, 2010.
- [56] K. Capalado, J. Corbett, P. Kasibhatla i P. Fishbeck, Effects of ship emissions on sulphur cycling and radiative climate forcing over the ocean, u *Nature*, 1999.
- [57] IMO, Investigation of appropriate control measures (abatement technologies) to reduce Black Carbon emissions from international shipping, International maritime organization, London, 2015.
- [58] S. Beirle, U. Platt, R. von Glasow, M. Wenig i T. Wagner, Estimate of nitrogen oxide emissions from shipping by satellite remote sensing, *Geophysical Research Letters*, svez. 31, br. L18102, 17 09 2004.
- [59] Z. Lu, D. Streets, B. de Foy, L. Lamsal, B. Duncan i J. Xing, Emissions of nitrogen oxides from US urban areas: estimation from Ozone Monitoring Instrument retrievals for 2005–2014, *Atmos Chemistry and Physics*, svez. 15, br. 18, p. 10367–83, 21 09 2015.
- [60] D. Lee, I. Köhler, E. Grobler, F. Rohrer, R. Sausen i L. Gallardo-Klenner, Estimations of global no_x emissions and their uncertainties, *Atmospheric Environment*, svez. 31, br. 12, p. 1735– 49, 1 06 1997.
- [61] K. H. Corbett JJ, Updated emissions from ocean shipping, *Journal of Geophysical Research*, svez. 108, br. D20, 29 10 2003.

- [62] US EPA, Overview of Greenhouse Gases, 2015. [Mrežno]. Poveznica: <https://www.epa.gov/ghgemissions/overview-greenhouse-gases>. [Pokušaj pristupa 10 10 2017].
- [63] Marine Insight, The Urgent Need to Reduce Nitrogen Oxide (NOx) Emissions from Ships, 2012. [Mrežno]. Poveznica: <https://www.marineinsight.com/environment/the-urgent-need-to-reduce-nitrogen-oxide-nox-emissions-from-ships/>. [Pokušaj pristupa 10 10 2017].
- [64] L. Goldsworthy, Design of ship engines for reduced emissions of oxides of nitrogen, Flame Marine Diagnostic, 2002.
- [65] WB&IFC, Pollution Prevention and Abatement Handbook, 04 1999. [Mrežno]. Poveznica: http://www.ifc.org/wps/wcm/connect/topics_ext_content/ifc_external_corporate_site/sustainability-at-ifc/publications/publications_handbook_ppah_wci_1319577543003. [Pokušaj pristupa 10 10 2017].
- [66] S. Bernard, A. Grambsch, K. Ebi i I. Romieu, The potential impacts of climate variability and change on air pollution-related health effects in the United States, Environ Health Perspect, svez. 109(Suppl 2), p. 199–209, 05 2001.
- [67] WHO, Air Quality Guidelines for Europe Second Edition, 2000. [Mrežno]. Poveznica: http://www.euro.who.int/__data/assets/pdf_file/0005/74732/E71922.pdf. [Pokušaj pristupa 10 10 2017].
- [68] R. Barnes, G. Parkinson i A. Smith, Costs and Benefits of Sulfur Oxide Control, J. Air Pollut. Control Assoc.; (United States), svez. 33, br. 8, 1 08 1983.
- [69] EPA, What is Acid Rain?, 2016. [Mrežno]. Poveznica: <https://www.epa.gov/acidrain/what-acid-rain>. [Pokušaj pristupa 10 10 2017].
- [70] M. Gillenwater, What are greenhouse gases?, 15 6 2010. [Mrežno]. Poveznica: <http://ghginstitute.org/2010/06/15/what-are-greenhouse-gases/>. [Pokušaj pristupa 10 10 2017].
- [71] Daily CO₂, [Mrežno]. Poveznica: <https://www.co2.earth/daily-co2>. [Pokušaj pristupa 9 10 2017].
- [72] B. Metz, O. Davidson, H. Coninck, M. de Loos i L. Meyer, IPCC special report on carbon dioxide capture and storage, Cambridge University Press, Cambridge, 2005.
- [73] International Energy Agency, Energy and CO₂ emissions in the OECD With detailed data up to 2015, International Energy Agency, Paris, 2017.
- [74] M. K. Fraende, BIMCO demands 4th IMO GHG study based on realistic economic growth, 13 02 2019. [Mrežno]. Poveznica: <https://www.bimco.org/news/priority-news/20190213-fourth-imo-ghg-study>. [Pokušaj pristupa 30 04 2019].
- [75] D. Robertson, Health effects of increase in concentration of carbon dioxide in the atmosphere, Current Science, svez. 90, br. 12, pp. 1607-9, 25 06 2006.
- [76] J. Allen, P. MacNaughton, U. Satish, S. Santanam, J. Vallarino i J. Spengler, Associations of Cognitive Function Scores with Carbon Dioxide, Ventilation, and Volatile Organic Compound Exposures in Office Workers: A Controlled Exposure Study of Green and

Conventional Office Environments, Environ Health Perspect, svez. 124, br. 6, pp. 805-12, 06 2016.

- [77] UCS, Why does CO₂ get most of the attention when there are so many other heat-trapping gases?, 3 8 2017. [Mrežno]. Poveznica: http://www.ucsusa.org/global_warming/science_and_impacts/science/CO2-and-global-warming-faq.html#.WdyfnEyB1cA. [Pokušaj pristupa 10 10 2017].
- [78] L. Gómez i M. García, Energy Efficiency: an opportunity for Research and Improvement, Ships science and technology, Vol 8, No 15, 2014.
- [79] IMO International Maritime Organization, In Focus, 07 07 2017. [Mrežno]. Poveznica: [http://imo.com/English/MediaCentre/In Focus/Air pollution and energy efficiency](http://imo.com/English/MediaCentre/In%20Focus/Air%20pollution%20and%20energy%20efficiency).
- [80] IMO/ MEPC, RESOLUTION MEPC.203(62) AMENDMENTS TO THE ANNEX OF THE PROTOCOL OF 1997 TO AMEND THE INTERNATIONAL CONVENTION FOR THE PREVENTION OF POLLUTION FROM SHIPS, 1973, AS MODIFIED BY THE PROTOCOL OF 1978 RELATING THERETO, IMO/ MEPC, London, 2011.
- [81] IMO/ MEPC, RESOLUTION MEPC.282(70) 2016 GUIDELINES FOR THE DEVELOPMENT OF A SHIP ENERGY EFFICIENCY MANAGEMENT PLAN (SEEMP), IMO/ MEPC, London, 2016.
- [82] P. O. EU, 2015/757, 29 04 2015. [Mrežno]. Poveznica: <https://publications.europa.eu/>. [Pokušaj pristupa 02 05 2019].
- [83] P. O. EU, 2016/1927, 04 11 2016. [Mrežno]. Poveznica: <https://publications.europa.eu/>. [Pokušaj pristupa 02 05 2019].
- [84] P. O. EU, 2016/1928, 4 11 2016. [Mrežno]. Poveznica: <https://publications.europa.eu/>. [Pokušaj pristupa 02 05 2019].
- [85] P. O. EU, 2016/2072, 04 11 2016. [Mrežno]. Poveznica: <https://publications.europa.eu/>. [Pokušaj pristupa 02 05 2019].
- [86] IACS- the International Association os Classification Societies, No 38. Procedure for calculation and verification of the Energy Efficiency Design Index (EEDI), IACS- the International Association os Classification Societies, London, 2013.
- [87] IMO/ MEPC, RESOLUTION MEPC.245(66) 2014 GUIDELINES ON THE METHOD OF CALCULATION OF THE ATTAINED ENERGY EFFICIENCY DESIGN INDEX (EEDI) FOR NEW SHIPS, IMO/ MEPC, London, 2014.
- [88] IMO/ MEPC, RESOLUTION MEPC.177(58) AMENDMENTS TO THE TECHNICAL CODE ON CONTROL OF EMISSION OF NITROGEN OXIDES FROM MARINE DIESEL ENGINES (NO_x Technical Code 2008), IMO/ MEPC, London, 2008.
- [89] E. Ozturk, Operational Measures For Energy Efficiency In Shipping, Journal of ETA Maritime Science, Vol. 1, No. 2, pp. 65-72, 2013.
- [90] OCIMF, GHG Emissions- Mitigating Measures for Oil Tankers, OCIMF Oil Companies International Maine Forum, London, 2011.

- [91] OCIMF, Virtual Arrival Optimising Voyage Management and Reducing Vessel Emissions - an Emissions Management Framework, Oil Companies International Marine Forum, London, 2010.
- [92] MAN Diesel & Turbo, Basic Principles of Ship Propulsion, Copenhagen: MAN Diesel & Turbo, 2011.
- [93] K. Hochkirch i V. Bertram, Options for Fuel Saving for Ships, Berlin, 2010.
- [94] ABS, Ship Energy Efficiency Measures- Status and Guidance, American Bureau of Shipping, 2013.
- [95] P. Sames, N. Clausen i M. Andersen, Costs and Benefits of LNG as Ship Fuel for Container Vessels, MAN Diesel & Turbo, Copenhagen, 2013.
- [96] A. Vorkapic, P. Kralj i D. Bernečić, Ship systems for natural gas liquefaction, Multidisciplinary Scientific Journal of Maritime Research, svez. 30, pp. 105-112, 2016.
- [97] Ship Technology, Sayaringo STaGE LNG Carriers, Verdict Media Limited., 27 02 2018. [Mrežno]. Povezница: <https://www.ship-technology.com/projects/sayaringo-stage-lng-carriers/>. [Pokušaj pristupa 02 05 2019].
- [98] K. Aabo, Dual-fuel engine using LPG, Ship & Offshore, svez. 3, 2010.
- [99] A. Florentinus, C. Hamelinck i A. Bos, Potential of biofuels for shipping, European Maritime Safety Agency (EMSA), Lisbon, 2012.
- [100] Maddox Consulting, Analysis of market barriers to cost effective GHG emission reductions in the maritime transport sector, Maddox Consulting, London, 2012.
- [101] M. A. Brown, Market failures and barriers as a basis for clean energy policies, Energy Policy, svez. 29, p. 1197–1207, 2001.
- [102] SNAME, Principles of Naval Architecture Second Revision: Resistance, Propulsion and Vibration, Society of Naval Architects and Marine Engineers, Jersey City, 1988.
- [103] D. Radan, Uvod u hidrodinamiku broda, Dubrovnik: Sveučilište u Dubrovniku, 2004.
- [104] K. Logan, Using a Ship's Propeller for Hull Condition Monitoring, u ASNE Intelligent Ships Symp. IX, Philadelphia, 2011.
- [105] N. Bose i S. Malloy, Reliability and Accuracy of Ship Powering Performance Extrapolation, u 1st Int. Symp. on Marine Propulsors (SMP), Trondheim, 2009.
- [106] L. Ljung, Black-box Models from Inputs-output Measurements, u 18th IEEE Instrumentation and Measurements Technology Conf., Budapest, 2001.
- [107] L. Leifsson, H. Saevarsdottir, S. Sigurdsson i A. Vesteinsson, Grey-box modeling of an ocean vessel for operational optimization, Simulation Modelling Practice and Theory, svez. 16, br. 8, pp. 923-932, 09 2008.
- [108] M. Haranen, P. Pakkanen, R. Kariranta i J. Salo, White, Grey and Black-Box Modelling in Ship Performance Evaluation, u Hull Performance and Insight Conference , Castello di Pavone, 2016.

- [109] A. Lap i L. Troost, Frictional drag and ship forms, svez. 8, 1953.
- [110] G. Hughes, Friction and Form Resistance in Turbulent Flow and a Proposed Formulation for Use in Model and Ship Correlation, Trans. RINA, svez. 96, pp. 314-376, 1954.
- [111] AITAC, News, [Mrežno]. Poveznica: <http://aitac.nl/news/aitac-integrates-now-full-cfd-expertise-for-yacht-engineering>. [Pokušaj pristupa 12 01 2020].
- [112] C. Dawson, A practical computer method for solving ship–wave problems, u 2nd Int. Conf. on Numerical Ship Hydrodynamics, Berkley, 1977.
- [113] V. Srića, Poslovni informacijski sustavi: Otkrivanje znanja iz podataka, 2018. [Mrežno]. Poveznica: <https://www.scribd.com/document/378101618/05-Otkrivanje-Znanja-Iz-Podataka>. [Pokušaj pristupa 31 01 2019].
- [114] M. Chen, J. Han i P. Yu, Data mining: An overview from a database perspective, Transactions on Knowledge and Data Engineering, svez. 8, br. 6, pp. 866-883, 12 1996.
- [115] G. Linoff i M. Berry, Data mining tehniques, For marketing, sales, and customer relationship managment, 3 ur., Indiana: Wiley Publishing Inc, 2011.
- [116] J. Keleher, B. Namee i A. D'Arcy, Machine learning for predictive data analyses, Algorithms, worked examples, and case studies, Cambridge: Massachusetts Institute of Technology, 2015.
- [117] D. T. Larose, Discovering knowledge in data, An introduction to data mining, A JOHN WILEY & SONS, INC., PUBLICATION, 2005.
- [118] G. John i P. Langley, Estimating Continous Distributions in Bayesian Classifiers, u In Proceeding of the Eleventh Conference on Uncertainty in Artificial Intelligence, San Mateo, 1995.
- [119] K. Murphy, Naive Bayes classifiers, University of British Columbia, 2006.
- [120] N. Harzevili i S. Alizadeh, Mixture of latent multinomial naive Bayes classifier, Applied Soft Computing, svez. 69, pp. 516-527, 2018.
- [121] S. Shalev-Shwartz i S. Ben-David, Understanding Machine Learning: From Theory to Algorithms, Cambridge University Press, 2014.
- [122] D. Hosmer, S. Lemeshow i X. Rodney, Applied Logistic Regression, 3rd ur., Hoboken: John Wiley & Sons Inc., 2013.
- [123] M. Buhmann, Radial Basis Functions: Theory and Implementations, Cambridge: Cambridge University Press, 2009.
- [124] S. Haykin, Neural Networks and Learning Machines, 3rd ur., svez. 1999, Upper Saddle River: Pearson Education, 2009.
- [125] S. Gunn, Support Vector Machines for Classification and Regression, Image Speech and Intelligent Systems Group, Southampton, 1997.
- [126] B. Ustun, W. Melssen i L. Buydens, Facilitating the application of Support Vector Regression by using a universal Pearson VII function based kernel, Chemometrics and Intelligent Laboratory Systems, svez. 81, p. 29 – 40, 7 09 2006.

- [127] J. Morgan i R. Messenger, THAID: A sequential analysis program for the analysis of nominal scale dependent variables, Ann Arbor, Michigan: The University of Michigan, 1973.
- [128] J. R. Quinlan, C4.5: programs for machine learning, San Mateo, California: Morgan Kaufmann, 1993.
- [129] L. Breiman, J. Friedman, R. Olshen i C. Stone, Classification and Regression Trees, New York: Classification and Regression Trees, 1984.
- [130] J. Quinlan, Induction of Decision Trees, Machine learning, svez. 1, pp. 81-106, 1986.
- [131] R. L. deMantaras, A Distance-Based Attribute Selection Measure for Decision Tree Induction, Machine learning, svez. 6, br. 1, pp. 81-92, 01 1991.
- [132] U. Fayyad i K. Irani, The attribute selection problem in decision tree generation, u AAAI-92, San Jose, 1992.
- [133] G. Kass, An exploratory technique for investigating large quantities of categorical data., Applied Statistics, svez. 29, pp. 119-127, 1980.
- [134] D. Biggs, B. deVille i E. Suen, A method of choosing multiway partitions for classification and decision trees, Journal of Applied Statistics , svez. 18, br. 1, pp. 49-62, 1991.
- [135] L. Breiman, Bagging Predictors, Department of Statistics University of California, Berkeley, 1994.
- [136] S. Ben-David i S. Shalev-Shwartz, Understanding Machine Learning: From Theory to Algorithms, Cambridge: Cambridge University Press, 2014.
- [137] T. Šmuc, Strojno učenje: B&V; Ansambli, 2011. [Mrežno]. Poveznica:
https://web.math.pmf.unizg.hr/nastava/su/index.php/download_file/-/view/188/.
[Pokušaj pristupa 4 Izvor: 02 2019].
- [138] T. Dietrich, An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, and Randomization, Machine Learning, svez. 40, br. 2, pp. 139-157, 2000.
- [139] T. Hastie, R. Tibshirani i J. Friedman, The Elements of Statistical Learning: Data Mining, Inference, and Prediction, 2nd ur., Springer, 2009.
- [140] L. Breiman, Random Forests, Machine learning, svez. 45, pp. 5-32, 2001.
- [141] L. Breiman i A. Cutler, Random forests - classification description, 2004. [Mrežno].
Poveznica:
https://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm#varimp.
[Pokušaj pristupa 12 02 2019].
- [142] S. Shevade, S. Keerthi, C. Bhattacharyya i K. Murthy, Improvements to the SMO Algorithm for SVM Regression, IEEE Transactions on Neural Networks, 1999.
- [143] A. Smola i B. Schoelkopf, A tutorial on support vector regression, Statistics and Computing, p. 199–222, 2004.
- [144] Y. Sasaki, The truth of the F-measure, Toyota Technological Institute, 2007.

- [145] N. Chinchor, MUC-4 Evaluation Metrics, u Fourth Message Understanding Conference, 1992.
- [146] M. Sokolova i G. Lapalme, A systematic analysis of performance measures for classification tasks, Information Processing and Management, svez. 45, p. 427–437, 2009.
- [147] S. Ranganathan, K. Nakai i C. Schonbach, Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics, Elsevier, 2018.
- [148] J. Davis i M. Goadrich, The relationship between Precision-Recall and ROC curves, u Proceedings of the 23rd international conference on Machine learning, 2006.
- [149] Endress + Hauser, Operating Instructions: Proline Promass 80, Coriolis Mass Flow Measuring System, Reinach: Endress + Hauser, 2006.
- [150] Kongsberg, Shaft power meter, Torque and power measurement system for rotating shaft, 19 07 2017. [Mrežno]. Poveznica:
<https://www.k.kongsberg.com/ks/web/nokbg0240.nsf?AllWeb/ECC998CE82FE3801C125758300448E97?Open Document>.
- [151] Heriana, Instruction manual: Product : Anemometer & Anemoscope, Gangseo-Gu: Heriana Co.,Ltd., 2014.
- [152] Furuno, Operator's manual: GP-150-dual, Nishinomiya: Furuno Electric Co., Ltd., 2010.
- [153] Tokyo Keiki, Gyro Compass TG- 8000-8500 Operators manual (E101076-C), Tokyo: Tokyo Keiki Inc., 2008.
- [154] A. Ng i M. Jordan, On Discriminative vs. Generative classifiers: A comparisson of logistic regression and naive Bayes, 2001. [Mrežno]. Poveznica:
<http://ai.stanford.edu/~ang/papers/nips01-discriminativegenerative.pdf>. [Pokušaj pristupa 24 08 2018].
- [155] R. Piltaver, M. Luštrek, M. Gams i S. Martinčić-Ipčić, What makes classification trees comprehensible, Expert systems with applications, svez. 16, 2016.
- [156] L. Breiman, Wald Lecture II: Looking inside the black box, UCB Statistics, 2002. [Mrežno]. Poveznica: <https://www.stat.berkeley.edu/~breiman/wald2002-2.pdf>. [Pokušaj pristupa 17 02 2019].
- [157] IMO/MEPC, 2016 GUIDELINES FOR THE DEVELOPMENT OF A SHIP ENERGY EFFICIENCY MANAGEMENT PLAN (SEEMP), London, 2016.
- [158] IMO/ MEPC, RESOLUTION MEPC.292(71) 2017 GUIDELINES FOR ADMINISTRATION VERIFICATION OF SHIP FUEL OIL CONSUMPTION DATA, 2017.
- [159] L. von Bertalanffy, General System Theory, NYC: George Braziller, Inc., 1968.
- [160] G. Klir, Trends in General Systems Theory, New York: John Wiley& Sons Inc., 1972.
- [161] G. Klir, Applied General Systems Reasearch, Recent Developments and trends, svez. 1, NYC: Springer, 1977.
- [162] N. Luhmann, Teorija sistema : svrhovitost i racionalnost, Zagreb: Globus, 1981.
- [163] S. Petković, Društveno djelovanje i modaliteti njegova značenja,, VUŠ, svez. 3, 1966.

- [164] P. Sikavica, F. Bahtijarević-Šiber i N. Pološki Vokić, Temelji menadžmenta, Zagreb, 2008.
- [165] R. Stacey, Strateški menadžment i organizacijska dinamika, Zagreb: MATE, 2008.
- [166] H. Weihrich i H. Koontz, Menedžment, Zagreb: Mate, 1998.
- [167] I. Belamaric, Nosivost, vlastita masa broda i entropija/ Deadweight, Light ship Weight and Entropy, Nase more, pp. 131-133, 2013.

Životopis s opisom znanstvenog i stručnog rada

Ime i prezime: Aleksandar Vorkapić

Datum i mjesto rođenja: 27.7.1970. godine u Rijeci

Stručni naziv: Diplomirani inženjer za pomorski promet brodostrojarskog smjera, Sveučilišta u Rijeci, Pomorskog fakulteta u Rijeci

Strani jezici: engleski (C2); njemački, talijanski (A1/A2)

RADNO ISKUSTVO:

studeni 2014. – izvanredni student doktorskog studija „Pomorstvo” s dijelom radnog vremena

ožujak 2014. – upravitelj stroja (STCW III/2) na brodovima za prijevoz ukapljenoga plina različitih međunarodnih tvrtki

srpanj 2011. – ožujak 2014. – voditelj tehničkog odjela tvrtke Gulf Marine Management (Deutschland) GmbH & Co. KG.

veljača 2011. – srpanj 2011. – tehnički inspektor tvrtke Gulf Marine Management (Deutschland) GmbH & Co. KG. (NMM(D)/Stena)

siječanj 2008. – veljača 2011. – voditelj projektnog tima tvrtke OSG Ship Management (US)

lipanj 2006. – siječanj 2008. – tehnički inspektor tvrtke OSG Ship Management (UK)

travanj 2004. – lipanj 2006. – upravitelj stroja (STCW III/2) na brodovima za prijevoz sirove nafte i nafnih produkata tvrtke OSG Ship Management (UK)

lipanj 1998. – ožujak 2004. – član plovidbene straže u strojarnici i drugi časnik stroja na brodovima za prijevoz sirove nafte, nafnih produkata i ukapljenoga plina različitih međunarodnih tvrtki

listopad 1995. – travanj 1997. – vježbenik stroja na brodu za prijevoz kontejnera tvrtke Croatia Line

POPIS OBJAVLJENIH RADOVA:

- Vorkapic, A., Radonja R., & Zec, D. (2018). Cost Efficiency of Ballast Water Treatment Systems Based on Ultraviolet Irradiation and Electrochlorination. *Promet- Traffic & Transportation*, Vo. 30, No3, 343.–348.
- Vorkapic, A., Kralj, P., & Martinovic, D. (2017). The analysis of the maintenance systems of a LPG carrier's liquefaction system main components. *Multidisciplinary Scientific Journal of Maritime Research*, 31(1), 3.–9.

- Vorkapic, A., Kralj, P., & Bernebic, D. (2016). Ship systems for natural gas liquefaction. *Multidisciplinary Scientific Journal of Maritime Research*, 30, 105.–112.
- Vorkapic, A., Komar, I., & Jelic-Mrcelic, G. (2016). Shipboard Ballast Water Treatment Systems on Seagoing Ships. *Transactions on Maritime Science*, 01, 19.–28.