

Primjena metoda umjetne inteligencije za iskorištanje pomorskih podataka

Sablić, Filip

Master's thesis / Diplomski rad

2022

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/um:nbn:hr:187:149291>

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

Download date / Datum preuzimanja: **2024-05-28**



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

Repository / Repozitorij:

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



SVEUČILIŠTE U RIJECI

POMORSKI FAKULTET

FILIP SABLIĆ

**PRIMJENA METODA UMJETNE INTELIGENCIJE ZA
ISKORIŠTAVANJE POMORSKIH PODATAKA**

DIPLOMSKI RAD

Rijeka, 2022.

SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET

**PRIMJENA METODA UMJETNE INTELIGENCIJE ZA
ISKORIŠTAVANJE POMORSKIH PODATAKA**

**APPLICATION OF ARTIFICIAL INTELLIGENCE
METHODS FOR MARITIME DATA UTILIZATION**

DIPLOMSKI RAD

Kolegij: Optoelektronički sustavi

Mentor: izv. prof. dr. sc. Irena Jurdana

Komentor: dr. sc. Nikola Lopac, mag. ing. el.

Student: Filip Sablić

Studijski program: Elektroničke i informatičke tehnologije u pomorstvu

JMBAG: 0112065427

Rijeka, rujan 2022.

Student: Filip Sablić

Studijski program: Elektroničke i informatičke tehnologije u pomorstvu

JMBAG: 0112065427

IZJAVA O SAMOSTALNOJ IZRADI DIPLOMSKOG RADA

Kojom izjavljujem da sam diplomski rad s naslovom PRIMJENA METODA UMJETNE INTELIGENCIJE ZA ISKORIŠTAVANJE POMORSKIH PODATAKA izradio samostalno pod mentorstvom izv. prof. dr. sc. Irene Jurdane te komentorstvom dr. sc. Nikole Lopca, mag. ing. el.

U radu sam primijenio metodologiju izrade stručnog/znanstvenog rada i koristio literaturu koja je navedena na kraju diplomskog rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući naveo u diplomskom radu na uobičajen, standardan način citirao sam i povezao s fusnotama i korištenim bibliografskim jedinicama, te nijedan dio rada ne krši bilo čija autorska prava. Rad je pisan u duhu hrvatskoga jezika.

Student:

Filip Sablić
(potpis)

Student: Filip Sablić

Studijski program: Elektroničke i informatičke tehnologije u pomorstvu

JMBAG: 0112065427

IZJAVA STUDENTA – AUTORA
O JAVNOJ OBJAVI OBRANJENOG DIPLOMSKOG RADA

Izjavljujem da kao student – autor diplomskog rada dozvoljavam Pomorskom fakultetu Sveučilišta u Rijeci da ga trajno javno objavi i besplatno učini dostupnim javnosti u cjelovitom tekstu u mrežnom digitalnom repozitoriju Pomorskog fakulteta.

U svrhu podržavanja otvorenog pristupa diplomskim radovima trajno objavljenim u javno dostupnom digitalnom repozitoriju Pomorskog fakulteta, ovom izjavom dajem neisključivo imovinsko pravo iskorištavanja bez sadržajnog, vremenskog i prostornog ograničenja mog diplomskog rada kao autorskog djela pod uvjetima *Creative Commons* licencije CC BY Imenovanje, prema opisu dostupnom na <http://creativecommons.org/licenses/>

Student - autor

Filip Sablić

SAŽETAK

U radu su obrađeni pomorski podaci dobiveni Automatskim identifikacijskim sustavom te njihova primjena korištenjem strojnog učenja. Uz to obrađene su i metode umjetne inteligencije koje se uz pomoć podataka dobivenih putem AIS-a svakodnevno koriste u pomorstvu. Rad prikazuje i pojašnjava korištenje pomorskih podataka za otkrivanje pomorskih anomalija, za procjenu rizika od sudara, predviđanje putanje plovila, te za određivanje učinkovitosti plovila i luka. Također, u radu su prikazani novi i budući trendovi kao i nove tehnologije koje će ubrzo postati svakodnevna primjena.

Ključne riječi: Automatski identifikacijski sustav, pomorske anomalije, putanja plovila, učinkovitost, umjetna inteligencija, strojno učenje, sudar

SUMMARY

The paper deals with maritime data obtained by the Automatic Identification System and their application using machine learning. In addition, the methods of artificial intelligence, which are used daily in the maritime industry with the help of data obtained with AIS, are also covered. The paper presents and explains the use of maritime data to detect maritime anomalies, to assess the risk of collisions, to predict the trajectory of vessels, and to determine the efficiency of vessels and ports. Also, the paper presents new and future trends as well as new technologies that will soon become everyday applications.

Keywords: Automatic identification system, maritime anomaly, vessel trajectory, efficiency, artificial intelligence, machine learning, collision

SADRŽAJ

SAŽETAK	I
SUMMARY	I
SADRŽAJ	II
1. UVOD	1
1.1. PROBLEM, PREDMET I OBJEKTI ISTRAŽIVANJA	1
1.2. RADNA HIPOTEZA	1
1.3. SVRHA I CILJEVI ISTRAŽIVANJA.....	1
1.4. ZNANSTVENE METODE	2
1.5. STRUKTURA RADA.....	2
2. AUTOMATSKI IDENTIFIKACIJSKI SUSTAV (AIS)	3
2.1. OPĆENITO O AIS-U.....	3
2.2. PRINCIP RADA AIS-A.....	7
2.3. PRIMJENA AIS-A.....	8
3. PRIMJENA STROJNOG UČENJA ZA ANALIZU AIS PODATAKA	10
3.1. PRIMJENA STROJNOG UČENJA ZA OTKRIVANJE POMORSKIH ANOMALIJA.....	11
3.1.1. POTPORNI VEKTORSKI STROJEVI.....	11
3.1.2. NEURONSKE MREŽE	12
3.1.3. BAYESOVE MREŽE	13
3.1.4. GAUSSOVI PROCESI.....	14
3.1.5. POTENCIJALNI PROBLEMI	14
3.2. METODA ANALITIKE VELIKIH PODATAKA ZA PROCJENU RIZIKA OD SUDARA PLOVILA.....	15
3.2.1. METODA DIJELJENJA UDALJENOSTI (K-MEANS ALGORITHM).....	16
3.2.2. METODA GUSTOĆE (DB-SCAN ALGORITHM)	16
3.2.3. METODA ANALITIKE VELIKIH PODATAKA (BIG DATA ANALYTICS FRAMEWORK).....	17

3.2.4. PROCJENA RIZIKA	19
3.3. BAZA PODATAKA SUSTAVA AUTOMATSKE IDENTIFIKACIJE ZA PREDVIĐANJE POMORSKE PUTANJE I RUDARENJE PODATAKA	21
3.3.1. OBRADA NEOBRAĐENIH PODATAKA	21
3.3.2. ODABIR NEOBRAĐENIH PODATAKA.....	22
3.3.3. ČIŠĆENJE PODATAKA	23
3.3.4. INTERPOLACIJA PODATAKA KOJI NEDOSTAJU.....	25
3.4. MJERNI PODACI O UČINKOVITOSTI PLOVILA I LUKA PUTEM VALIDIRANIH AIS PODATAKA.....	26
3.4.1. KRETANJE PLOVILA U LUCI.....	26
3.4.2. VALIDACIJA AIS PODATAKA	27
3.4.3. PODJELA PUTOVANJA	29
3.4.4. MJERNI PODACI O UČINKOVITOSTI LUKA.....	29
3.5. DVOSTRUKI LINEARNI AUTOENKODER ZA PREDVIĐANJE PUTANJE PLOVILA POMOĆU POVIJESNIH AIS PODATAKA	30
3.5.1. SVIJEST O SITUACIJI NA MORU	30
3.5.2. PREDVIĐANJE PUTANJE PLOVILA	31
3.5.3. GENERATIVNI MODELI.....	31
3.5.4. GRUPIRANJE I KLASIFIKACIJA PUTANJA.....	32
3.5.4.1. GRUPIRANJE PUTANJE.....	34
3.5.4.2. KLASIFIKACIJA PUTANJE.....	34
3.5.5. DVOSTRUKI LINEARNI AUTOENKODER.....	36
3.5.5.1. PREDNJI LINEARNI AUTOENKODER	37
3.5.5.2. OBRNUTI LINEARNI AUTOENKODER	37
3.5.5.3. LATENTNA INTERPOLACIJA.....	37
3.6. SUMIRAJUĆA TABLICA KORIŠTENIH ZNANSTVENIH ČLANAKA	39
4. IZAZOVI I BUDUĆI TRENDLOVI.....	40
4.1. IZAZOVI U PRIMJENI	41
4.2. BUDUĆI TRENDLOVI	41

4.3. NOVE TEHNOLOGIJE I LJUDSKA POBOLJŠANJA.....	43
5. ZAKLJUČAK	46
LITERATURA.....	47
POPIS SLIKA	49
POPIS TABLICA.....	50

1. UVOD

1.1. PROBLEM, PREDMET I OBJEKTI ISTRAŽIVANJA

Umjetna inteligencija u današnjem svijetu kakav mi poznajemo, poprima sve veću važnost. Pomalo se uvodi u računalne sustave, kako bi ti sustavi rješavali probleme koji su ljudima komplikirani. Također, umjetna se inteligencija može koristiti u područjima gdje određeni roboti mogu zamijeniti ljude, prije svega iz sigurnosnih razloga, a zatim i zbog toga što može ubrzati određene procese.

Pomorski promet, kao ni brodove, umjetna inteligencija nije zaobišla. Danas uz sve modernije sustave na brodovima, metode umjetne inteligencije, odnosno njihovi algoritmi mogu se primijeniti radi iskorištavanja pomorskih podataka.

1.2. RADNA HIPOTEZA

Prema već gore navedenom problemu, predmetu i objektu istraživanja određuje se temeljna radna hipoteza, odnosno pretpostavka koju je potrebno dokazati: koliko su metode umjetne inteligencije pouzdane, te može li ih se primijeniti za iskorištavanje pomorskih podataka.

1.3. SVRHA I CILJEVI ISTRAŽIVANJA

Cilj ovog istraživanja je opisati umjetnu inteligenciju, njezinu granu koja se naziva strojno učenje, te prikazati kako se njezine metode mogu koristiti u pomorstvu. Uz to, istraživanje ima za cilj i dati usporedbu metoda te navesti njihove prednosti i nedostatke.

1.4. ZNANSTVENE METODE

Kod istraživanja, prikupljanja i izlaganja rezultata istraživanja korištene su u odgovarajućim kombinacijama sljedeće znanstvene metode: komparativna metoda, metoda deskripcije, metoda analize i sinteze te metoda dokazivanja i opovrgavanja.

1.5. STRUKTURA RADA

U uvodu diplomskog rada navedeni su problem i predmet istraživanja, radna hipoteza i pomoćne hipoteze, svrha i ciljevi istraživanja, znanstvene metode te je obrazložena i struktura rada.

U drugom poglavlju rada ukratko je opisana definicija automatskog identifikacijskog sustava (AIS-a), njegov princip rada te primjena u praksi.

Pojedinačni opis te primjena metoda umjetne inteligencije za iskorištavanje pomorskih podataka opisan je u trećem poglavlju rada.

Četvrti dio prikazuje izazove i buduće trendove koje donosi razvoj umjetne inteligencije, trenutne poteškoće, te prednosti i nedostatke u primjeni.

U posljednjem poglavlju, dana je sinteza istraživanja kojom je prikazana radna hipoteza.

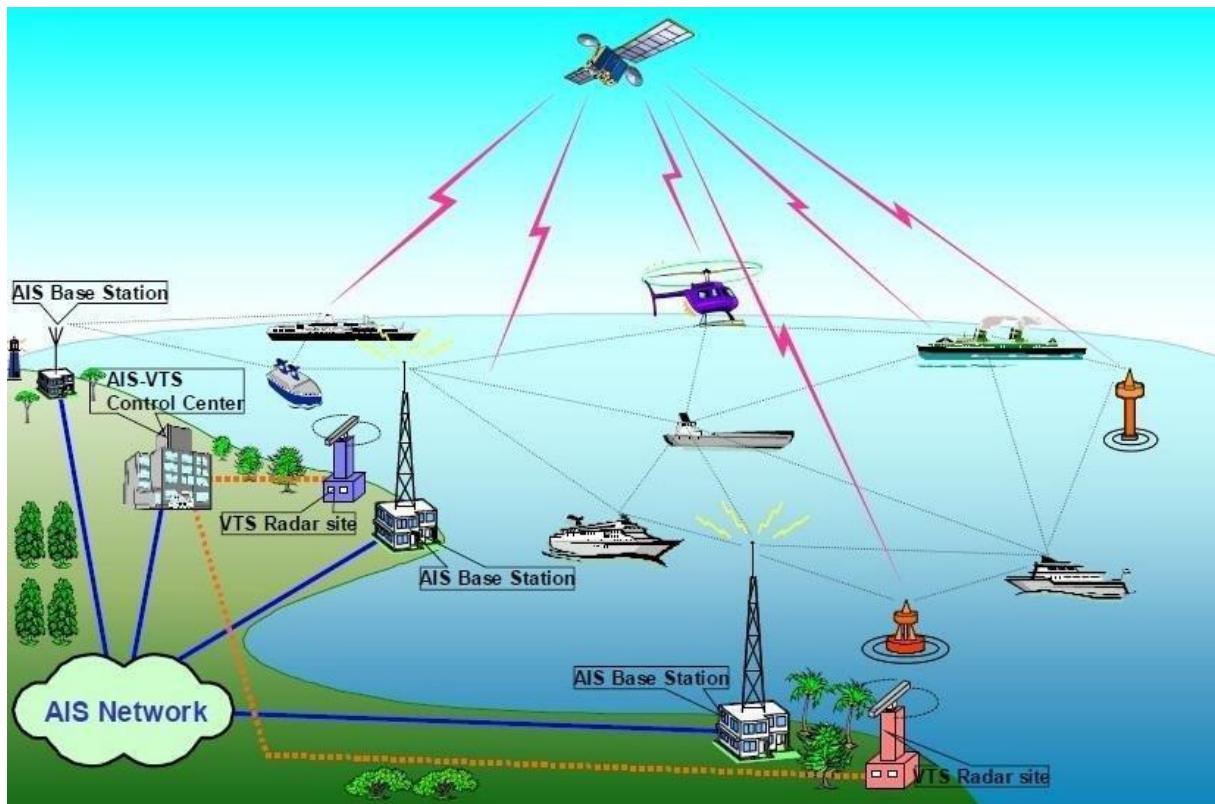
2. AUTOMATSKI IDENTIFIKA CIJSKI SUSTAV (AIS)

Temelj sigurnosti plovidbe je točna razmjena podataka pri čemu je najvažniji korak brza i točna identifikacija. Ukoliko poruku primi osoba kojoj nije upućena, ona postaje neupotrebljiva. Nebrojeno puta potrebno je identificirati objekt koji se pojavio na radaru ili nekom drugom navigacijskom uređaju, a osim njegovog odraza drugi identifikacijski parametri su nepoznanica. Kod takvih situacija dolazilo bi do puno zapreka i nejasnoća te bi postupak identifikacije trajao izuzetno dugo i ne bi bio potpuno pouzdan.

Upravo iz tog razloga razvijeni su satelitski sustavi koji pridonose poboljšanju sigurnosti ljudskih života na moru, a zatim i identifikaciji brodova i nadgledanju sveukupnog pomorskog prometa. Upotreba suvremenih sustava za prijenos informacija izvrstan je put za razvoj automatskog primopredajnog uređaja za sva plovila. Jedan od takvih sustava, čija je namjena predaja i prijam informacija je Automatski identifikacijski sustav (AIS).

2.1. OPĆENITO O AIS-U

AIS je pomorski tehnički standard koji je razvila Međunarodna pomorska organizacija (IMO). Koristi se kao brodski sustav za emitiranje koji djeluje poput transpondera, radi u VHF pomorskem pojasu, koji može obraditi više od 4500 izvještaja u minuti i ažurira se čak svake dvije sekunde. Koristi tehnologiju samoorganizirajućeg višestrukog pristupa vremenskim dijeljenjem (SOTDMA) kako bi zadovoljio ovu visoku stopu emitiranja i osigurao pouzdan rad brod-brod. [3].



Slika 1. AIS sustav

Izvor: <https://shipping.nato.int/nsc>

Podaci AIS-a predstavljaju bogat izvor informacija o pomorskom prometu. To mogu biti jednostavne razmjene podataka o osnovnim informacijama između pojedinih plovila ili razmjene podataka između obale i uređaja koji se nalaze na splavima. Osnovna podjela podataka dobivenih putem AIS sustava dijele se na statičke i dinamičke podatke, podatke o plovidbi te sigurnosne podatke [20].

Statički podaci su podaci koji se ručno unose u AIS uređaj, dok su dinamički podaci automatski uneseni ili generirani od strane samog sustava. Takve informacije emitira AIS jedinica klase A svakih 6 minuta. Koriste ga samo AIS postaje na brodovima i SAR zrakoplovima klase A pri izvješćivanju o statičkim podacima ili podacima povezanim s putovanjem.

STATIČKI PODACI	
MMSI broj	Ubačen pri ugradnji. Izmjena podataka broda pri promijeni vlasnika
Pozivni znak i ime broja	Ubačen pri ugradnji. Izmjena podataka broda pri promijeni vlasnika
IMO broj	Ubačen pri ugradnji. Unikatni podatak koji prati brod kroz cijeli vijek.
Dužina i širina	Ubačen pri ugradnji. Mjenja se ukoliko dođe do promjena.
Vrsta broda	Ubačen pri ugradnji. Mjenja se ukoliko dođe do promjena.
Položaj antene	Ubačen pri ugradnji. Mjenja se ukoliko dođe do promjena.
DINAMIČKI PODACI	
Položaj broda s pokazivanjem točnosti	Automatsko ažuriranje preko senzora spojenog na AIS. Točnost iznosi ± 10 metara
Vrijeme u UT	Automatsko ažuriranje preko DGPS senzora spojenog na AIS.
Kurs preko dna	Automatsko ažuriranje preko DGPS senzora spojenog na AIS, ukoliko uređaj daje taj podatak. Podatak može biti nedostupan.
Brzina preko dna	Automatsko ažuriranje preko DGPS senzora spojenog na AIS, ukoliko uređaj daje taj podatak. Podatak može biti nedostupan.

Kurs kroz vodu	Automatsko osvježavanje podataka preko senzora spojenog s kompasom.
Navigacijski status	Ručni unos podataka. Mogućnost izmjene po potrebi.
Kutna brzina	Automatsko osvježavanje podataka preko senzora kutne brzine ili žiro kompasa. Mogućnost nedostupnosti podatka.
Kut nagiba	Automatsko osvježavanje podataka preko senzora inklinometra. Mogućnost nedostupnosti podatka.

Tablica 1. Statički i dinamički podaci broda

Izvor: <https://hrcak.srce.hr/file/83093>

Podaci o plovidbi unose se ručno i uključuju gaz pramca i krme, odredište, ETA (*engl. Estimated Time of Arrival*). Sigurni podaci su podaci poslani u obliku poruke koja može sadržavati do 158 znakova, smanjenjem broja znakova poruka može brže doći do primatelja [21].

PODACI O PLOVIDBI	
Gaz broda	Ručni unos na početku putovanja, mijenja se ukoliko dođe do promjena.
Opasan teret	Ručni unos na početku putovanja prema vrsti opasnog tereta. Mogućnost izostavljanja podataka o količini.
Luka odredišta i ETA	Ručni unos na početku putovanja. Mogućnost osvježavanja po potrebi.

SIGURNOSNI PODACI	
	Kratke poruke slobodnog sadržaja. Mogu biti poslane točno određenom AIS prijemniku, svim brodovima i obalnim stanicama unutar dometa.

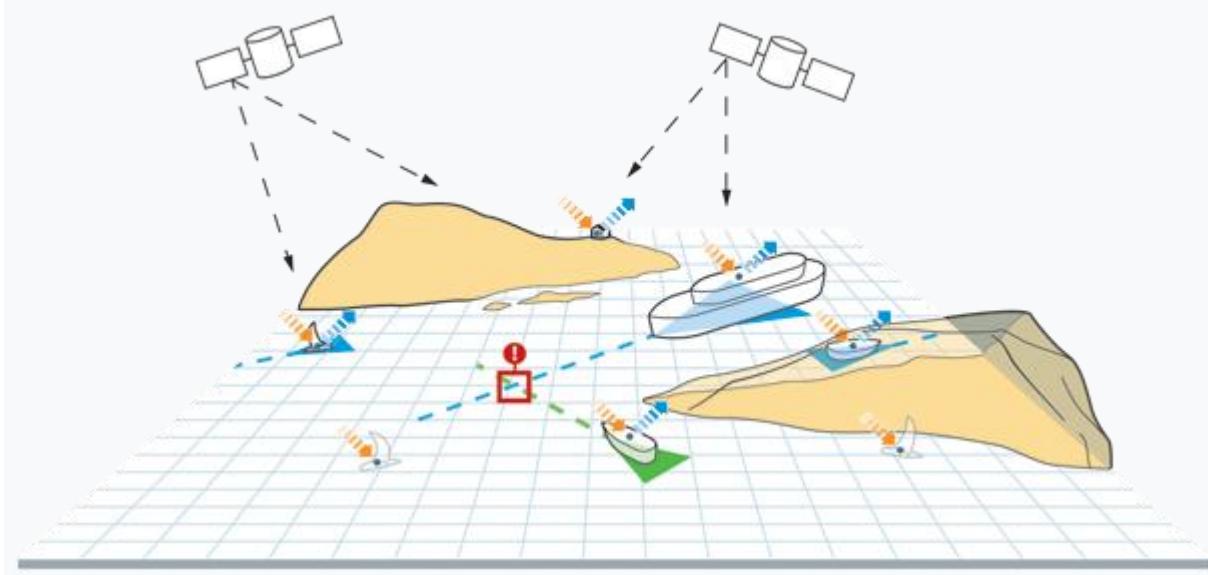
Tablica 2. Podaci o plovidbi i sigurnosni podaci

Izvor: <https://hrcak.srce.hr/file/83093>

2.2. PRINCIP RADA AIS-A

Prednost AIS-a u odnosu na druge tehnologije je u tome što prenosi podatke na organiziran, interoperabilan način; spaja statičke i dinamičke podatke zajedno.

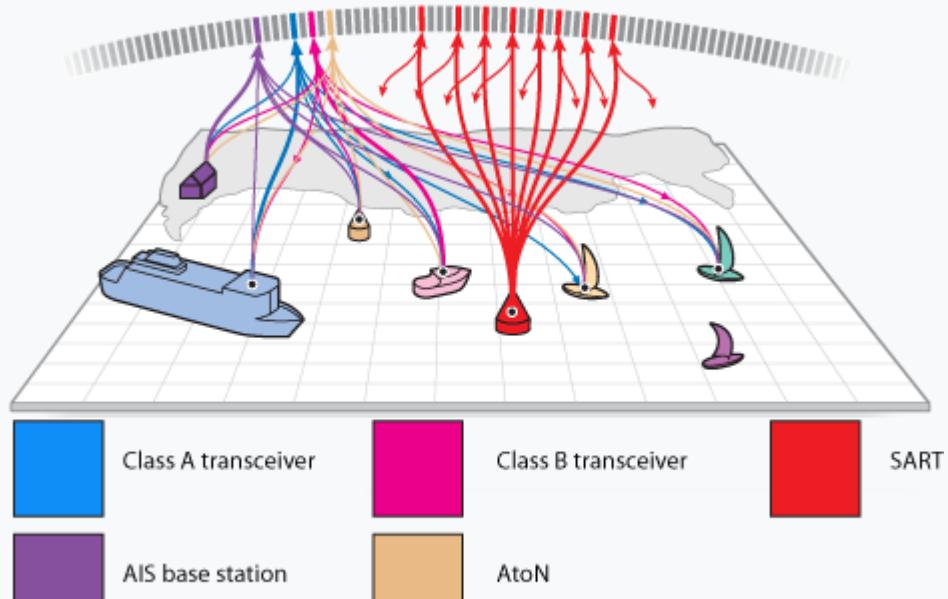
GPS dijeli dinamičke podatke koji uključuju kurs, brzinu i poziciju plovila, a koji su spojeni sa statičkim podacima pod koje spadaju MMSI broj plovila, njegovu veličinu i odredište kako bi se dobio sveobuhvatan navigacijski sustav.



Slika 2. Primjer rada AIS-a

Izvor: <http://www.allaboutais.com/index.php/en/>

Podaci se emitiraju na zajedničkoj međunarodnoj VHF frekvenciji - AIS 1 i 2 (161,975 MHz i 162,025 MHz), čime se osigurava mogućnost da uređaji mogu vidjeti jedni druge i međusobno funkcionirati, te razmjenjivati informacije. Emitirani signali primaju se putem AIS transpondera kojima su opremljeni brodovi ili kopneni VTS sustavi. Primljeni podaci prikazuju se na zaslonu radara, ECDIS-a, elektroničkih karata.



Slika 3. Prikaz razmjene podataka

Izvor: <http://www.allaboutais.com/index.php/en/>

2.3. PRIMJENA AIS-A

Zbog neograničenosti dometa, satelitski AIS sustav se najčešće koristi u praksi. Primjenjuje u mnogim poljima, koristi se kao pomoć pri izbjegavanju sudara, za identifikaciju plovila, za pretragu pomorskog dobra te praćenje okoliša.

Uz sve to, njime se koriste i skupine korisnika koje ga primjenjuju za:

- Sigurnosne operacije, nadzor plovidbenog prostora
- Borbe protiv piratstva, ilegalni ribolov
- Traganje i spašavanje

- Granična kontrola, sprječavanje krijumčarenja
- Praćenje opasnih tereta
- Sprječavanje onečišćenja

AIS sustav također primjenjuju i brodske kompanije, odnosno sami vlasnici brodova koji satelitskim putem prate svoje brodove.

3. PRIMJENA STROJNOG UČENJA ZA ANALIZU AIS PODATAKA

Strojno učenje (*eng. Machine Learning*) jedno je od najperspektivnijih i najaktivnijih grana umjetne inteligencije (AI). Cilj strojnog učenja je omogućiti računalu da napravi određeni model skupa podataka kako bi to isto računalo predvidjelo kamo smjestit nove podatke.

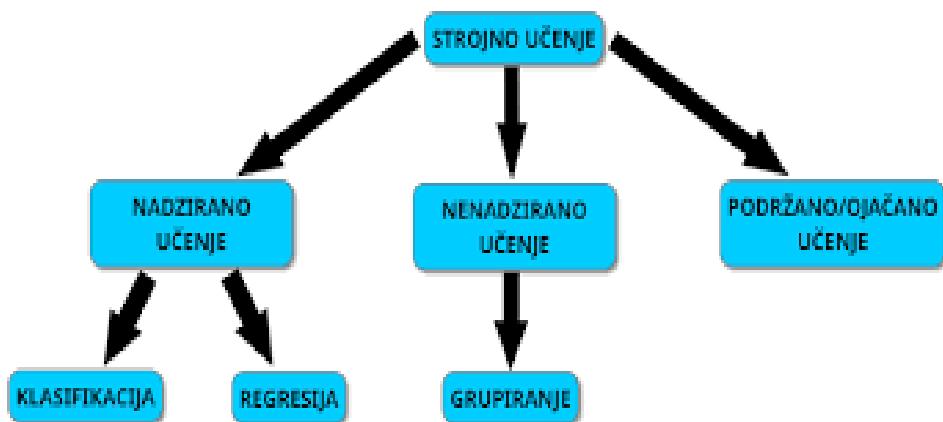
Svakodnevnim rastom podataka koji se povećavaju i šire svijetom, strojno učenje je postalo veoma važno na više područja : računalstvo, proizvodnja energije, industrijska proizvodnja te u prometu.

Strojno učenje može se podijeliti na dva glavna dijela:

- Nadzirano učenje
- Nenadzirano učenje

Kod nadziranog učenja (*engl. supervised learning*) modeli se uvježbavaju, odnosno grade primjenom skupa ulaznih i izlaznih podataka prikupljenih eksperimentom ili akvizicijom tako da mogu predviđati buduće izlaze na temelju dostupnih ulaza.

Zadatak nenadziranog učenja (*engl. unsupervised learning*) je pronaći skrivene uzorke i inherentne strukture u ulaznim podatcima bez poznavanja izlaza [2].



Slika 4. Podjela strojnog učenja

Izvor: http://www.zemris.fer.hr/~ajovic/mentorstva/Marko_Josipovic_zavrsni_final.pdf

3.1. PRIMJENA STROJNOG UČENJA ZA OTKRIVANJE POMORSKIH ANOMALIJA

Glavni temelj za otkrivanje anomalija su podaci, stoga je logično označiti postavljanje podataka kao početak procesa. Anomalije se otkrivaju iz svih prikupljenih podataka zbog čega je od velike važnosti da su točni. Pomorski sustav koji se koristi kao izvor podataka je AIS.

Otkrivanje anomalija je važan problem koji se istražuje unutar mnogo različitih područja od kojih je jedno i pomorstvo. U pravilu, odnosi se na problem pronalaska obrazaca među podacima koji nisu u skladu s očekivanim, odnosno nisu kakvi bi trebali biti. Pronalazak anomalija je od velike važnosti jer se one često pretvaraju u mnogo značajnije i kritične informacije.

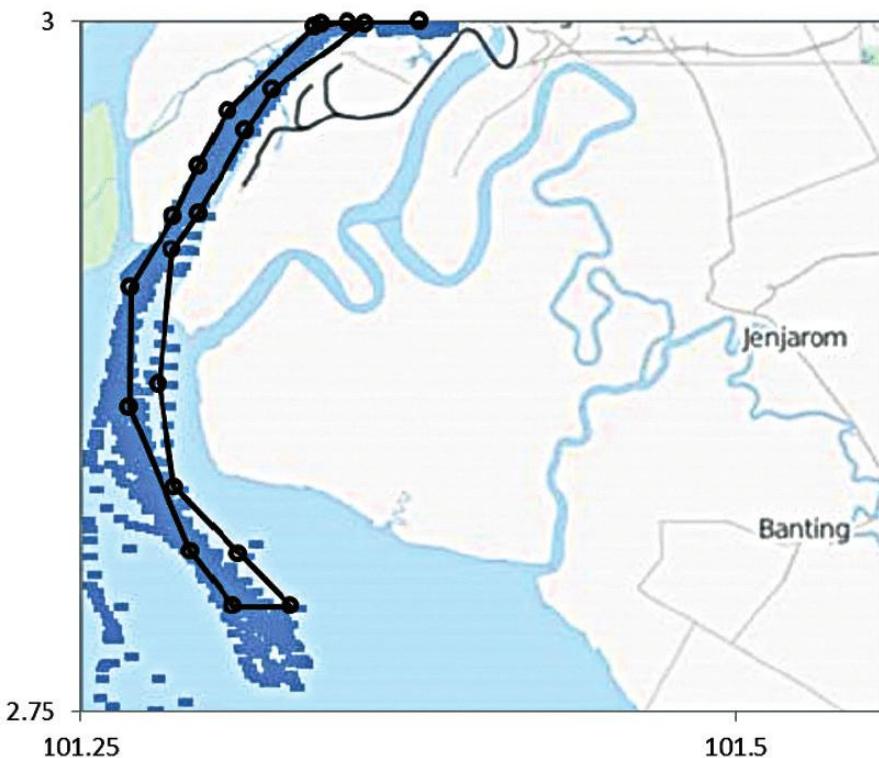
Za otkrivanje pomorskih anomalija koristi se nekoliko tehnika strojnog učenja:

- Potporni vektorski strojevi
- Neuronske mreže
- Bayesove mreže
- Gaussovi procesi

3.1.1. POTPORNI VEKTORSKI STROJEVI

Potporni vektorski strojevi su skup nadziranih metoda kojima je potrebno prethodno znanje prije klasifikacije. Metoda je implementirana kao tehnika klasifikacije uzoraka koja uspoređuje sličnost između ulaznih podataka i podataka pohranjenih u bazi. Sustav za otkrivanje anomalija sastoji se od dvije faze: faze treniranja gdje postoje već razvijeni modeli AIS podataka, te faze testiranja, koja je proces procjene performansi sustava.

. Na slici 5. prikazana je anomalija u slučaju polukružne rute. Plavom bojom prikazana je normalna ruta dok je crnim krugovima označena anomalija.



Slika 5. Anomalija u ponašanju plovila u polukružnoj ruti

Izvor:https://www.researchgate.net/publication/288458284_Machine_learning_approaches_to_maritime_anomaly_detection

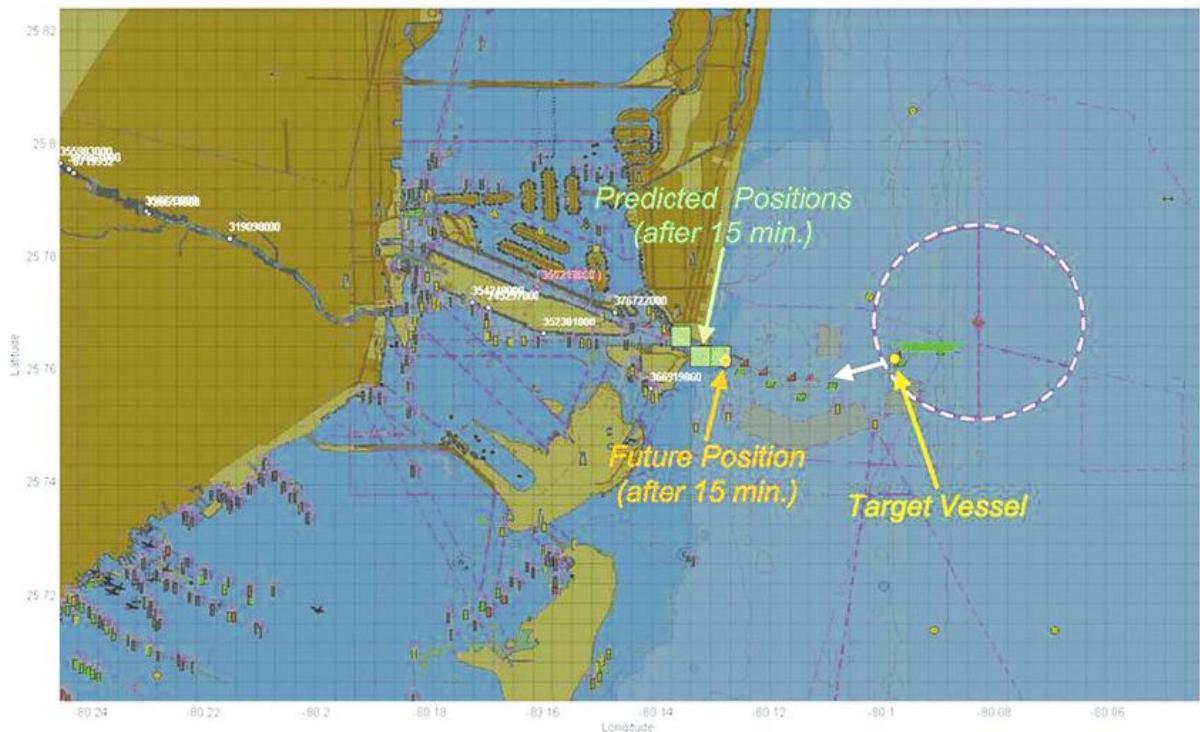
3.1.2. NEURONSKE MREŽE

Neuronske mreže također se mogu koristiti za otkrivanje pomorskih anomalija. Osim AIS sustava kod neuronskih mreža koristi se i modificiran klasifikator ARTMAP. Neuronske mreže koriste se za određivanje buduće pozicije plovila temeljene na AIS podacima.

Za otkrivanje anomalija sustav prvo mora naučiti niz zapažanja za koja se zna da su rutinska. Nakon toga, sustav može razlikovati normalna zapažanja, te neobična zapažanja za koja je u mogućnosti izdati upozorenje u obliku alarma.

Sustav radi na principu povezivanja različitih geografskih mreža koja odgovara položaju plovila u vremenskim intervalima. Implementacijom sustava postavlja se kvadratna mreža (rešetke) preko područja interesa za diskretizaciju mjesta plovila. Za otkrivanje anomalije, otkrivanje nepravilnog položaja plovila, sustav uvijek koristi prethodni položaj unutar kvadratne mreže. Ukoliko plovilo nije stiglo na položaj, odnosno rešetku, koju je

sustav predvidio, javlja se alarm. Slika 6. prikazuje predviđanje budućeg položaja plovila preko tehnike neuronskih mreža.



Slika 6. Predviđanje budućeg položaja plovila

Izvor:https://www.researchgate.net/publication/288458284_Machine_learning_approaches_to_maritime_anomaly_detection

3.1.3. BAYESOVE MREŽE

Sljedeća tehnika strojnog učenja koja se koristi za otkrivanje pomorskih anomalija na temelju AIS podataka su Bayesove mreže. U odnosu na prije navedene tehnike, Bayesove mreže imaju dvije velike prednosti: mogućnost jednostavnog uključivanja stručnih znanja u model, te mogućnost jednostavnog razumijevanja samog modela.

Bayesove mreže koriste se za otkrivanje nepravilnog ponašanja u pomorskom prometu. Ponašanja koja se mogu pratiti putem AIS-a su: odstupanje od standardne rute, neočekivana AIS aktivnost, neočekivani dolazak u luku, bliski pristup i ulazak u zonu. Za svako od tih ponašanja opisan je proces za određivanje da je ono normalno. Pojedinačne vjerojatnosti kombiniraju se sa Bayesovim mrežama kako bi se izračunao postotak vjerojatnosti prijetnje,

Proizvedene su mreže na dvije vremenske skale u obliku vremenske serije i u obliku modela tragova. Mreže su proizvedene pomoću stroja za učenje CaMMI koristeći AIS podatke u kombinaciji sa stvarnim podacima kao što su vrijeme, prognoza vremena i interakcija između plovila. Modeli mreža pokazali su različite rezultate u identificiranju anomalija, što je dovelo do zaključka da je najbolja kombinacija oba modela [11].

3.1.4. GAUSSOVI PROCESI

Prednost kod Gaussovih procesa je ta što model nije parametarski pa u njega nije potrebno ubacivati značajke anomalijskog ponašanja. Model koristi aktivno učenje paradigmu (*eng. Active Learning paradigm*) koje omogućuje izbor optimalnog uzorka iz AIS podataka koji predstavljaju cijeli skup. Model omogućuje izračun mjere normalnosti za svaki novo slanje podataka prema njemu s obzirom na zemljopisnu širinu i dužinu. Koristeći mjeru normalnosti brodovi se mogu identificirati kao potencijalno anomaljni [4].

3.1.5. POTENCIJALNI PROBLEMI

Uz sve prednosti koje nude tehnike strojnog učenja za otkrivanje pomorskih anomalija postoji i nekoliko nedostataka, tj. mana:

- Nedostatak podataka
- Krivotvoreni AIS podaci
- Lažne uzbune
- Nepotpuna objašnjenja

3.2. METODA ANALITIKE VELIKIH PODATAKA ZA PROCJENU RIZIKA OD SUDARA PLOVILA

Sudari brodova jedni su od najčešćih nesreća koje se događaju na moru. Često rezultiraju neželjenim i razornim posljedicama kao što su ispuštanje nafte, poplavljivanje brodova i gubitak ljudskih života. Kako bi se smanjili takvi rizici na minimum, razvijeni su alati koji se bave procjenom rizika. Do danas, istraživanje o upravljanju rizikom od sudara usredotočeno je na dva modela: poluempijski i probabilistički. Oni ne predlažu pouzdane mјere za smanjenje zato što je izazovno pružiti uvjerljivo opravdanje za opcije kontrole rizika (RCO) u složenoj prometnoj situaciji [12].

Istraživanje analize rizika može pomoći sa rješavanjem problema ukoliko je promet kompleksan korištenjem dostupnih velikih podataka kao što su AIS i GEBCO (*eng. Gridded Bathymetry dana*). Ipak, slično empirijskim metodama, mogu dovesti do podcenjivanja indeksa rizika jer ne uzimaju u obzir uvjete okoliša. Nadalje, kako bi se detaljnije istražio rizik od sudara potrebno je grupirati putanje brodova. To se ponajviše odnosi na statičke i dinamičke podatke brodova. Metoda strojnog učenja, odnosno algoritam grupiranja koristi se za automatsko prikupljanje potrebnih podataka. Algoritam grupiranja može se klasificirati u tri skupine:

- Metode dijeljenja udaljenosti (algoritam k – srednjih vrijednosti)
- Hijerarhijske metode (BIRCH algoritam)
- Metode gustoće (DB-SCAN)

Metode dijeljenja udaljenosti opće su prihvaćene zbog svoje visoke učinkovitosti. Uz njih se također koriste i metode gustoće koje vrlo reprezentativne. Hijerarhijske metode pate zbog činjenice da kad jednom dođe do grupiranja ili razdvajanja podataka, one nisu reverzibilne.

Unatoč svim svojim prednostima, ne koriste se u ograničenim područjima gdje su za razliku od otvorenih mora, prometni putovi mnogo složeniji te je mnogo komplikiranije pratiti putanje svih brodova čiji su podaci isporučeni putem AIS-a. Upravo iz tog razloga razvijena je metoda analitike velikih podataka (*eng. Big data analytics framework*) koja radi na temelju AIS podataka, prometnih podataka te hidrometeoroloških uvjeta [13].

3.2.1. METODA DIJELJENJA UDALJENOSTI (K-MEANS ALGORITHM)

K – means algoritam je algoritam grupiranja koji dijeli podatkovne točke u skupine na temelju euklidskih udaljenosti. Lako ga je razumjeti, implementirati i može se nositi s velikim skupovima podataka. Zahtijeva jasnu specifikaciju želenog broja prikupljenih podataka, što je lako odrediti na temelju statičkih podataka putovanja (točke polaska i odredišta, duljina putovanja). Može biti osjetljiv ako je u pitanju veliki broj podataka za grupiranje ili ako se radi o pojavi određenog šuma.

Kod metode dijeljenja udaljenosti, dvije brodske putanje (*eng. Ship trajectory*) su slične ako su im tri glavna parametra slična: polazište, odredište i dužina putovanja. Međutim, ukoliko se uz statičke podatke u obzir uzmu i dinamički podaci algoritam neće dobro raditi zbog prevelikog broja informacija.

3.2.2. METODA GUSTOĆE (DB-SCAN ALGORITHM)

DB-SCAN algoritam pomaže u formiranju grupe podataka na temelju pravilne i nepravilne gustoće podataka. Za razliku od K-means algoritma, ovaj algoritam dobro radi kada se koriste dinamički podaci, dok sa statičkim podacima neće dobro raditi. Upravo iz tog razloga, u praksi se koristi kombinacija oba algoritma koji daju odlične rezultate.

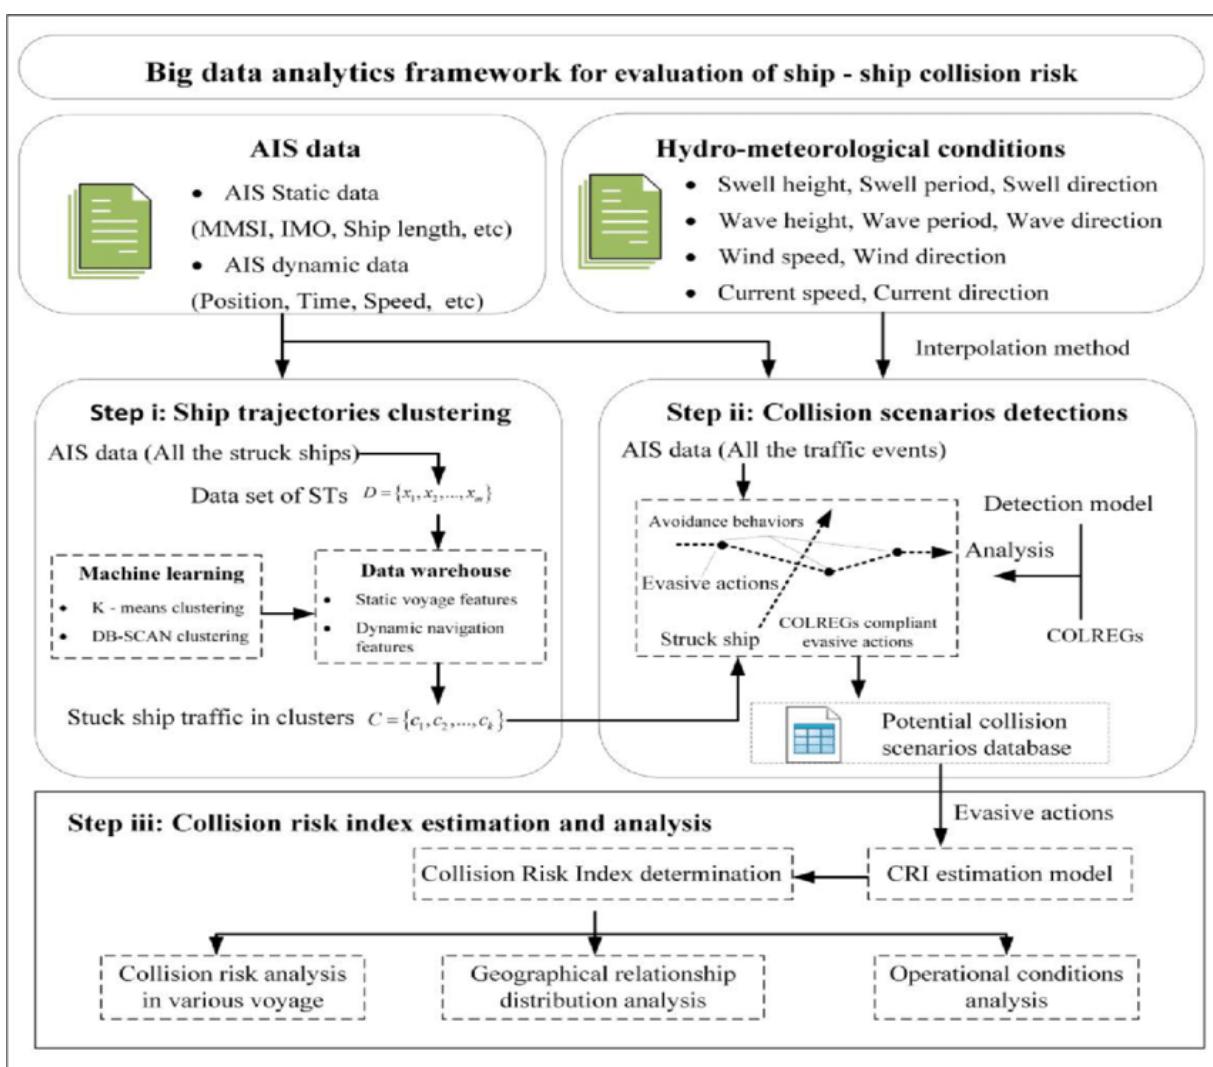
U procesu grupiranja kod DB-SCAN algoritma podaci su podijeljeni u tri kategorije: na jezgru, granicu i šum. Također, algoritam ne zahtijeva jasnu specifikaciju želenog broja prikupljenih podataka.

Brodske putanje su slične ukoliko njihove značajke putovanja, navigacija i prostorna udaljenost imaju sličnu gustoću podataka.

3.2.3. METODA ANALITIKE VELIKIH PODATAKA (BIG DATA ANALYTICS FRAMEWORK)

Okvir za procjenu rizika od sudara sastoji se od tri koraka:

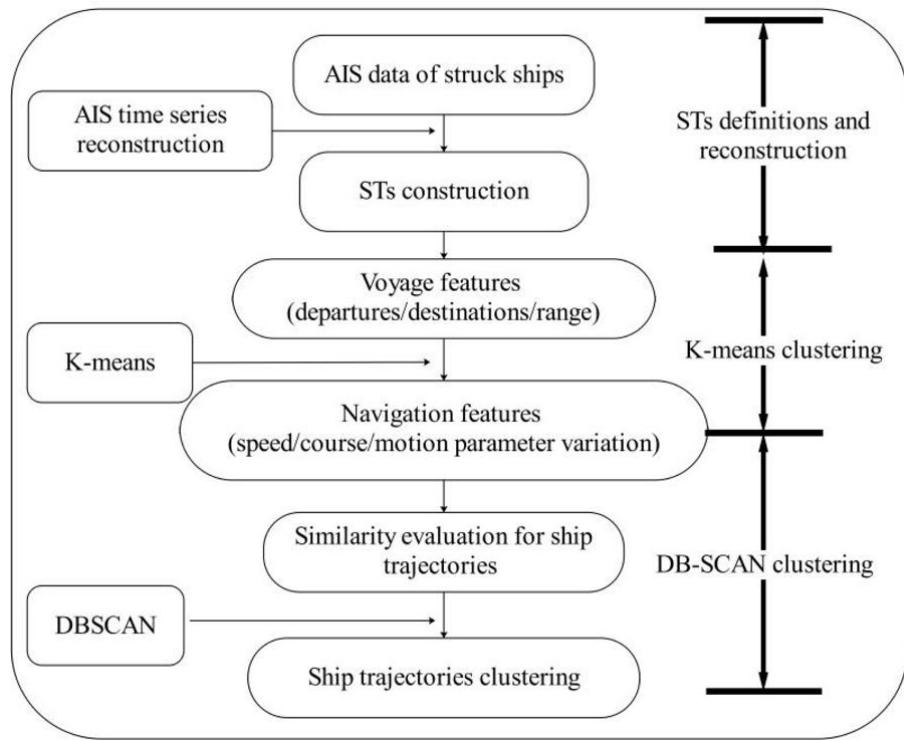
- KORAK 1: brodske se putanje rekonstruiraju na temelju AIS podataka koji sadrže statičke podatke i dinamičku navigaciju (K-means za statičke podatke, DB-SCAN za dinamičke podatke); fokusirano je samo na sudaru između brodova
- KORAK 2: detekcija scenarija sudara brod - brod
- KORAK 3: poduzimanje radnji za izbjegavanje sudara



Slika 7. Okvir za procjenu rizika od sudara

Izvor: <https://www.sciencedirect.com/science/article/pii/S095183202100212X>

Dijagram toka grupiranja putanja pomoću K-means i DB-SCAN algoritama prikazan je na slici 8. On se sastoji od tri dijela: rekonstrukcije brodskih putanja, grupiranja statičkih podataka i grupiranja dinamičkih podataka [6].

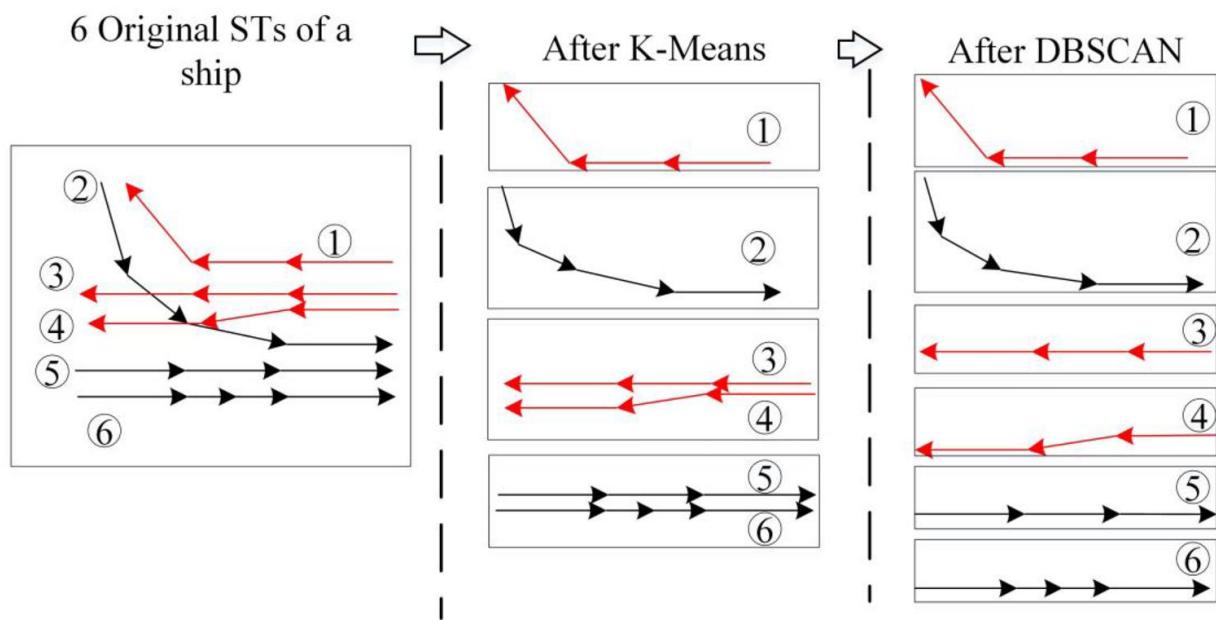


Slika 8. Dijagram toka grupiranja putanja

Izvor: <https://www.sciencedirect.com/science/article/pii/S095183202100212X>

Korištenjem predložene metode strojnog učenja na temelju dva navedena i opisana algoritma, složeni prometni scenariji mogu se detaljnije istražiti.

Primjer jednog takvog scenarija prikazan je na slici 9. Na slici je prikazan brod sa šest različitih putanja. Putanje ST1, ST3 i ST4 idu u jednom smjeru dok putanje ST2, ST5 i ST6 idu u suprotnom. Iako je smjer putanja ST3 i ST4 isti, kao i putanja ST5 i ST6, njihova brzina je drugačija.



Slika 9. Proces grupiranja putanja

Izvor: <https://www.sciencedirect.com/science/article/pii/S095183202100212X>

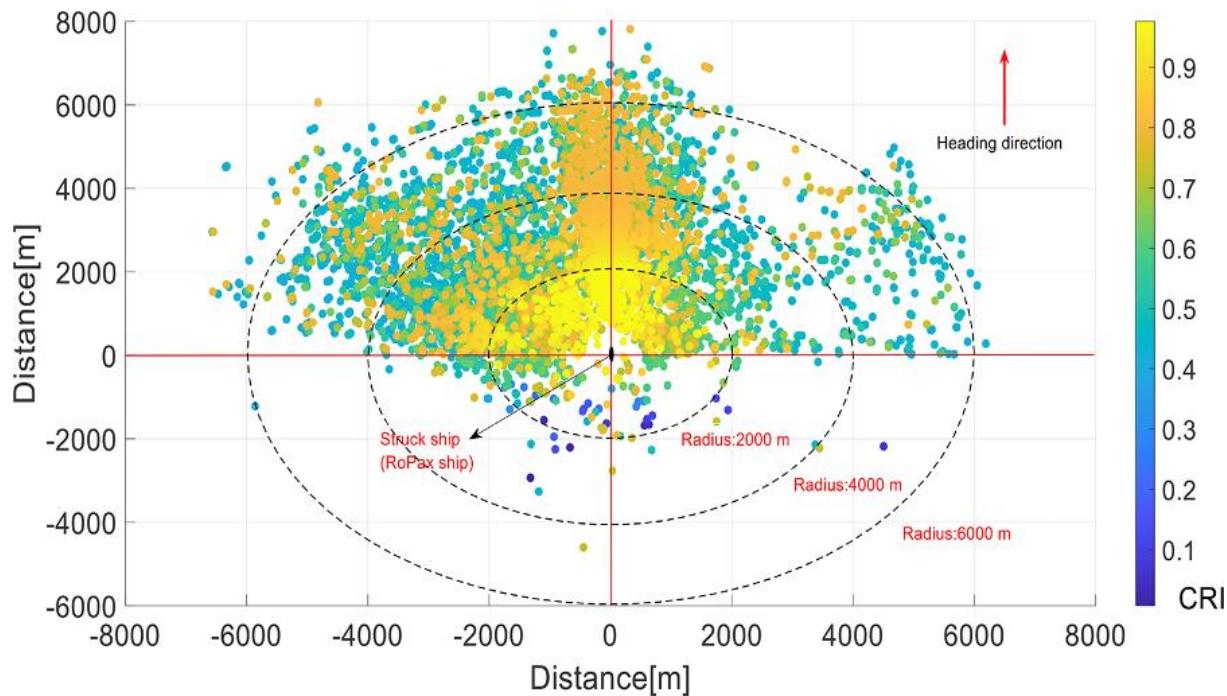
Razdvajanje pojedinih putanja kao i istraživanje rizika od sudara postiže se na sljedeći način:

- Algoritam K-means na temelju statičkih podataka klasificira brodske putanje u grupacije (ST1, ST2, ST3 i 4, te ST5 i 6 trebaju biti smješteni u različite grupe)
- Algoritam DB-SCAN na temelju dinamičkih podataka klasificira brodske putanje u podgrupe (ST3 i ST4, kao i ST5 i ST6 trebaju biti smještene u različite podgrupe)

3.2.4. PROCJENA RIZIKA

Procjena rizika od sudara dijeli se na dvije grupe:

- Analiza indeksa rizika od sudara tijekom aktivirane akcije izbjegavanja



Slika 10. Indeks gustoće rizika od sudara tijekom akcije izbjegavanja

Izvor: <https://www.sciencedirect.com/science/article/pii/S095183202100212X>

- Analiza indeksa rizika od sudara među hidrometeorološkim uvjetima

VARIJABLE HIDROMETEOROLOŠKIH UVJETA			
Visina vala	Brzina	Brzina vjetra	Prihvaćena hipoteza
Od -0.0479 do 0.6892	Od 0.0644 do 0.6725	Od -0.0292 do 0.6946	($\alpha=0.05$)

Tablica 3. Korelacija između rizika od sudara i hidrometeoroloških uvjeta

Izvor: Pripremio autor

3.3. BAZA PODATAKA SUSTAVA AUTOMATSKE IDENTIFIKACIJE ZA PREDVIĐANJE POMORSKE PUTANJE I RUDARENJE PODATAKA

AIS tehnologija emitira informacije o brodu i putovanju u redovitim vremenskim intervalima. Informacije se mogu primiti putem primopredajnika na brodu i zemaljske i/ili satelitske bazne stanice. Najvažniji atributi AIS baze podataka za predviđanje putanje su: zemljopisna širina i dužina, brzina, kurs (COG), brzina kretanja (SOG) te identitet plovila [10].

AIS baza podataka koja se koristi za predviđanje putanje izrađuje se pomoću alata za obradu podataka čiji se proces sastoji od četiri dijela:

- Obrada neobrađenih podataka (*eng. raw data pre-processing*)
- Odabir neobrađenih podataka (*eng. raw data selecting*)
- Čišćenje podataka (*eng. candidate data cleaning*)
- Interpolacija podataka koji nedostaju (*eng. missing data interpolating*)

3.3.1. OBRADA NEOBRAĐENIH PODATAKA

Prvi korak u izradi AIS baze podataka je odabir područja interesa. Najčešće je to zona sa velikom količinom plovila jer takva područja sadrže veliku količinu AIS podataka za obradu. Kako bi se obradili AIS podaci i odabrali korisni, potreban je alat koji ima mogućnost prebacivanja datoteka iz jednog formata u drugi. Format koji se koristi je uglavnom csv (*eng. comma-separated values*) zbog toga tabličnog zapisa kojim se on koristi što je mnogo jednostavnije za rukovanje.

Arcmap je najčešće korišteni softver geografskog informacijskog sustava (GIS) koji se koristi za pregledavanje, uređivanje i analizu geoprostornih podataka. Njegov alat pod nazivom „izvoz značajke atributa u ASCII“ koristi se za izvoz koordinata klase obilježja i vrijednosti atributa u ASCII tekstualnu datoteku.

XCoord	YCoord	SOG	COG	ROT	BASEDATETIME	MMSI
-120.003717	34.242683	20	285	0	200902012013	235844000
-120.0102	34.244133	20	285	0	200902012014	235844000
-120.016783	34.245633	20	285	0	200902012015	235844000

Slika 11. Primjer csv datoteke

Izvor: https://link.springer.com/chapter/10.1007/978-3-319-57421-9_20

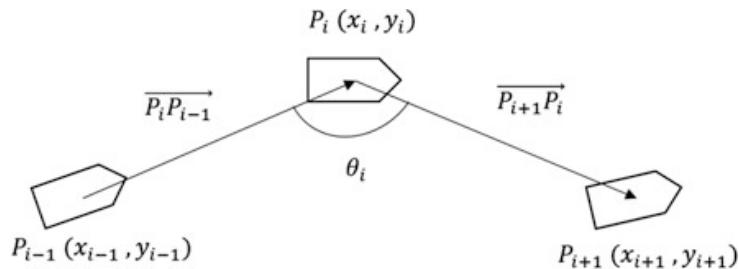
3.3.2. ODABIR NEOBRAĐENIH PODATAKA

Nakon obrade neobrađenih podataka potrebno ih je odabrat. Odabir podataka sastoji se od dva koraka. Prvo se svi neobrađeni podaci sortiraju povećavajući vremenski redoslijed, a zatim se ponovno sortiraju prema MMSI-u. Na ovaj način se može prikazati trag svakog plovila kronološkim redom, te je jednostavniji za obradu. Drugi korak je izračun složenosti rute ta dužina trajanja plovidbe.

Ako SOG (*eng. Speed Over Ground*) zadovoljava uvjet $SOG \neq 0$, smatra se da je plovilo u navigacijskom stanju. Trajanje navigacije definirano je kao najduži kontinuirani SOG niz AIS poruka koji je različit od nule u navigacijskom stanju. Svaka pojedinačna ruta trebala bi sadržavati sve važne informacije, kako bi AIS baza podataka mogla predvidjeti putanju i rudariti podatke. Kratke rute ne sadrže dovoljan broj podataka, pa stoga ni algoritmi ne mogu izvršiti svoj zadatok predikcije.

Složenost rute izračunava se preko $\cos \theta$, a definira se kao srednja vrijednost $\cos \theta$. Jednadžba za izračun složenosti rute:

$$\cos \theta = \frac{P_i P_i - 1 * P_i + 1 P_i}{|P_i P_i - 1||P_i + 1 P_i|}$$



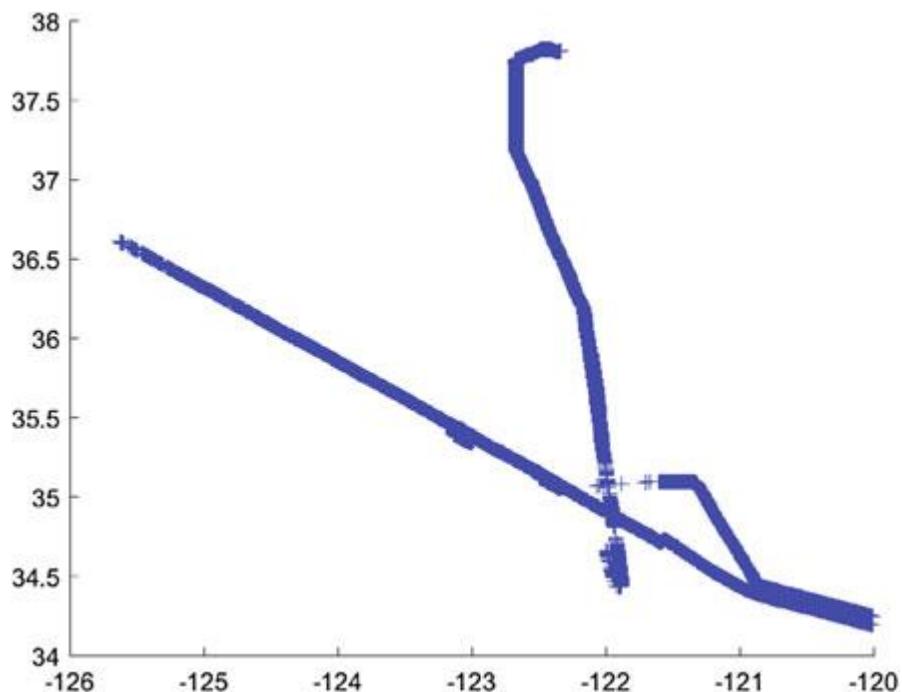
Slika 12. Primjer složenosti rute

Izvor: https://link.springer.com/chapter/10.1007/978-3-319-57421-9_20

3.3.3. ČIŠĆENJE PODATAKA

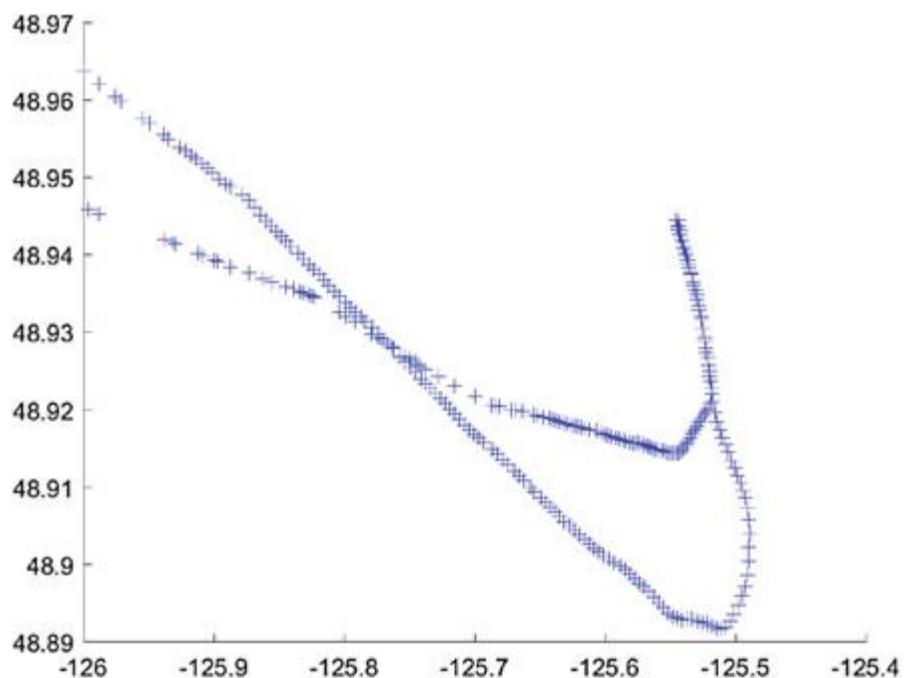
Nakon završetka obrade podataka potreban je daljnja selekcija istih na temelju putanja. Putanje se iscrtaju u alatu MATLAB-u. Na slikama ispod prikazane su tri vrste „šumovitih“ pomorskih putanja:

- Diskontinuirana putanja (slika 13.)
- Opuštena putanja (slika 14.)
- Isprepletena putanja (slika 15.)



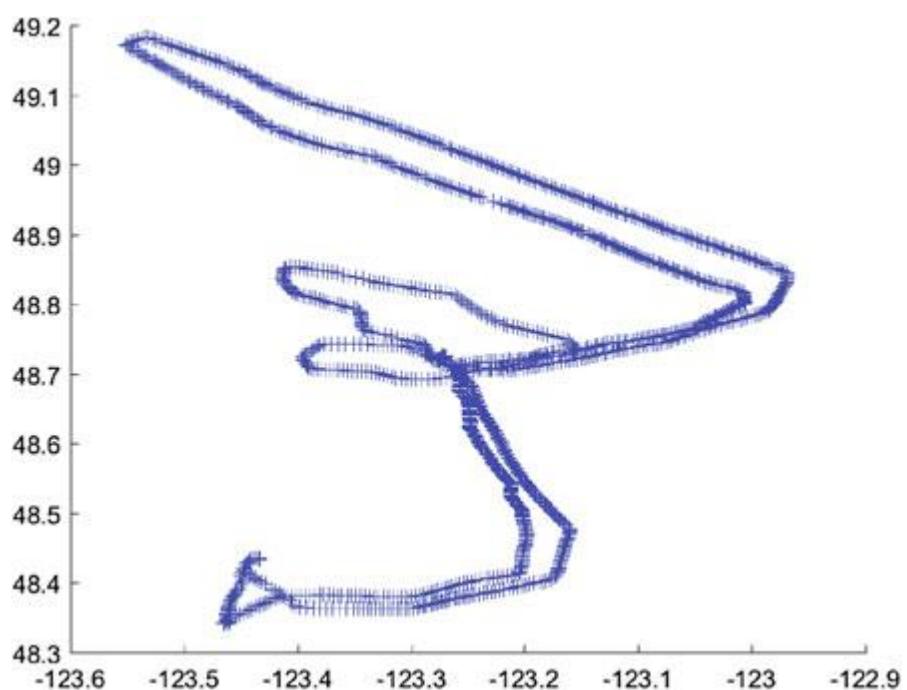
Slika 13. Diskontinuirana putanja

Izvor: https://link.springer.com/chapter/10.1007/978-3-319-57421-9_20



Slika 14. Opuštena putanja

Izvor: https://link.springer.com/chapter/10.1007/978-3-319-57421-9_20



Slika 15. Isprepletena putanja

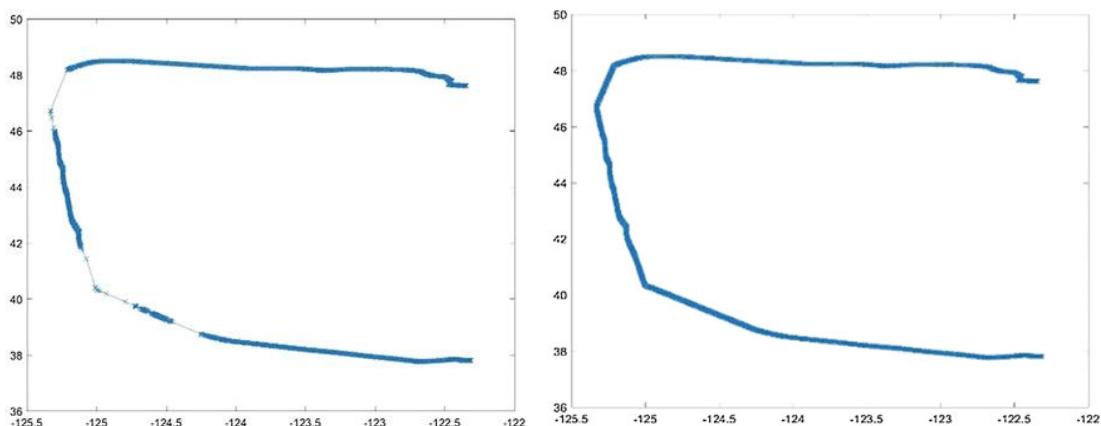
Izvor: https://link.springer.com/chapter/10.1007/978-3-319-57421-9_20

Sve ove putanje imaju neke inherentne nedostatke i zbog toga nisu korisne. Algoritmi za predviđanje putanja i rudarenje podataka ne mogu naučiti rute napamet. Upravo iz tog razloga, potrebno je ukloniti sve putanje sa nedostacima, kako bi ostale na raspolaganju korisne pitanje koje se koriste za izradu AIS baze podataka. Potpuna izrađena standardna AIS baza podataka u praksi se može iskoristiti za predviđanje putanje bilo kojeg plovila na moru.

3.3.4. INTERPOLACIJA PODATAKA KOJI NEDOSTAJU

Nedostatak podataka može utjecati na izvedbu algoritma i kvalitetu rudarenja podataka u bazi podataka. Također, prije izvođenja interpolacije potrebno je ukloniti i pogrešne podatke. Detekcija pogreške temelji se na usporedbi dva SOG-a, prethodnog i trenutnog. Ako je razlika između njih veća od one koja je unaprijed izračunata, dolazi do nove provjere koristeći najnoviji SOG. Testira se je li udaljenost u skladu sa stvarnom udaljenošću između poruka. Ukoliko to nije tako, SOG se smatra pogrešnim i vraća se na prethodni.

Izvršavanje interpolacije primjenjuje se u tri koraka: otkrivaju se podaci koji nedostaju, procjenjuje se da li je interpolacija uopće potrebna, te izrada linearne interpolacije. Do nedostatka podataka dolazi ukoliko je vremenski interval između dvije uzastopne poruke veći od jednog odabranog intervala (najčešće se odabire interval između 30 i 45 sekundi). Načelo linearne interpolacije je pretpostavka da je brod u ravnomjernom linearном gibanju tijekom vremenskog razdoblja koje nedostaje, a brzina se smatra SOG-om prethodne pozicije [5].



Slika 16. Prikaz putanje prije i nakon interpolacije

Izvor: https://link.springer.com/chapter/10.1007/978-3-319-57421-9_20

3.4. MJERNI PODACI O UČINKOVITOSTI PLOVILA I LUKA PUTEM VALIDIRANIH AIS PODATAKA

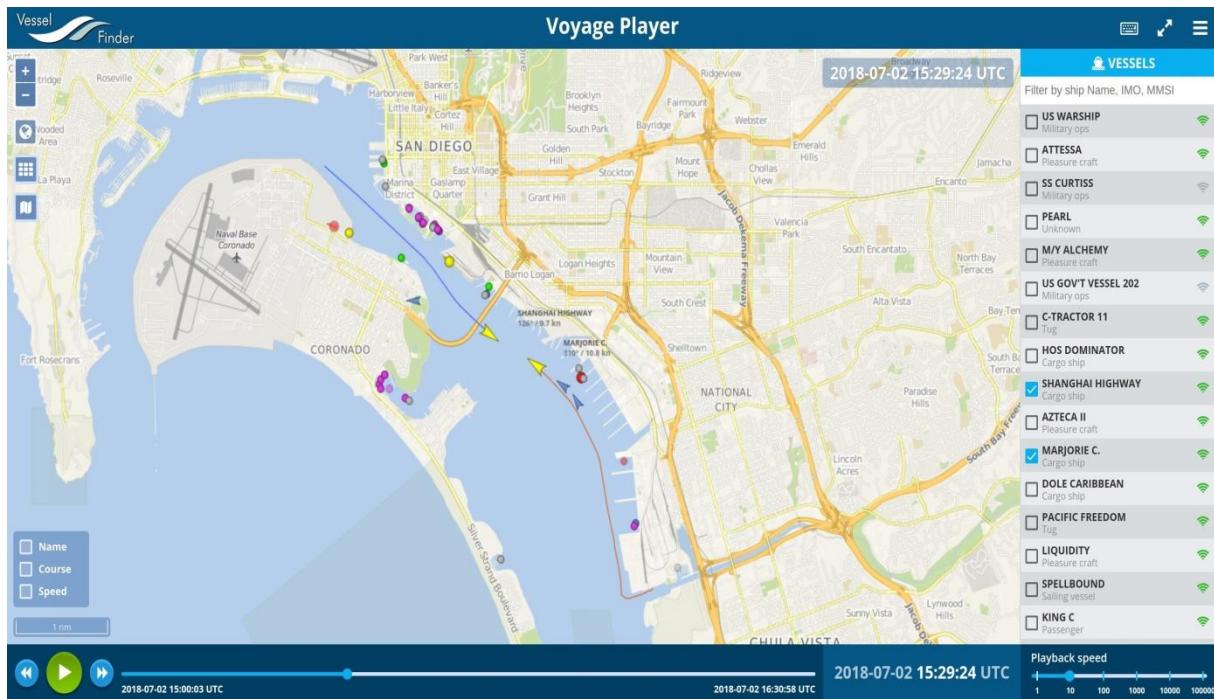
AIS podaci predstavljaju bogat izvor informacija i nude veliki potencijal pri pronalasku rješenja za probleme analize podataka i prediktivnog modeliranja. Kako bi to bilo moguće, potrebno se koristiti metodama koje se temelje na strojnom učenju, čiji je cilj povećati validiranost AIS podataka, a smanjiti broj pogrešnih podataka. Validirani podaci mogu se koristiti na plovilima i u lukama kako bi se izrazila poslovna i ekološka učinkovitost [22].

Validirani podaci, odnosni podaci koji su potvrđeni kao točni i koji su spremni za korištenje, mogu poslužiti kao alat za određivanje navigacijskog statusa, te alat za mjerjenje poslovanja luke. Također, koriste se za praćenje putovanja plovila u unaprijed definiranom području, te za procjenu ulaska u luku kao i vremena provedenog u njoj.

3.4.1. KRETANJE PLOVILA U LUCI

PARES (*eng. Port Area Vessel Movements*) predstavlja alat koji prati kretanje plovila u luci koristeći AIS podatke. Alat može obrađivati i koristiti prethodne ili trenutne podatke koje pruža AIS. Proces praćenja plovila sastoji se od tri koraka. PARES prvo odabire podatke na temelju odabranog vremenskog razdoblja, lokacije i vrste plovila. Zatim model potvrđuje podatke i izdvaja dodatne značajke, koje se zatim koriste pri čišćenju podataka i grupiranju AIS poruka.

Putovanje se u kontekstu PARES-a definira kao sva kretanja koje plovilo napravi pri jednom dolasku unutar lučkog područja. To uključuje sam dolazak u luku, odlazak do terminala, zaustavljanje na sidrištu, te odlazak iz luke nakon iskrcaja ili ukrcaja tereta. Model obrađuje podatke o vremenu provedenom na sidrištu, vremenu obrade tereta, trajanju vremena provedenog u luci te prosječnoj brzini kretanja unutar nje.



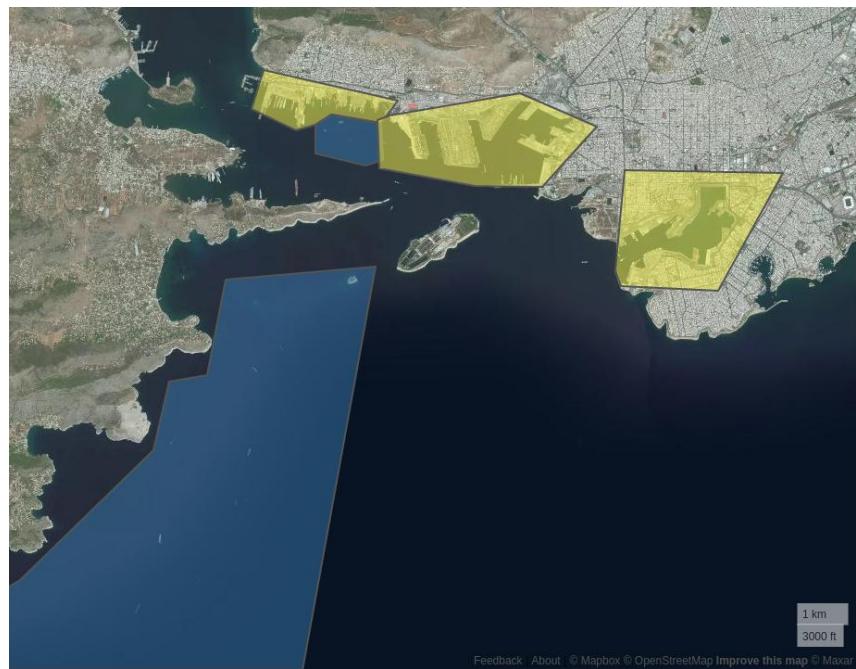
Slika 17. Primjer PARES-a

Izvor: <https://www.semanticscholar.org/paper/Vessel-and-Port-Efficiency-Metrics-through-AIS-data-Martincic-%C5%A0tepec/f3e67d6a04a261828b059d0d90616b0d93792b70#extracted>

3.4.2. VALIDACIJA AIS PODATAKA

Jedna od najvažnijih značajki unutar AIS poruka, je navigacijski status plovila. Poznavanje navigacijskog statusa je ključna informacija za odvajanje putovanja u dijelove. Za određivanje navigacijskog statusa alat (PARES) koristi tri različita pristupa: kada plovilo koristi motor, kada se nalazi na sidrištu i kada je usidren.

U prvom pristupu navigacijski status se određuje na temelju položaja plovila i brzine. Lokacija se promatra na način da li je plovilo unutar unaprijed definiranih poligona koji predstavljaju područja sidrišta i terminala. Glavni problem kod ovog pristupa je što se poligoni određuju ručno, zbog čega bi PARES ukoliko se plovilo usidri na rub poligona mogao lažno javiti promjene navigacijskog položaja.



Slika 18. Ručno određeni poligoni unutar luke

Izvor: <https://www.semanticscholar.org/paper/Vessel-and-Port-Efficiency-Metrics-through-AIS-data-Martincic-%C5%A0tepec/f3e67d6a04a261828b059d0d90616b0d93792b70#extracted>

Kod drugog pristupa promatralju se brzina plovila i brzina rotacije. Rotacija plovila događa se kod plovila koja su na sidrištu, dok kod usidrenih plovila rotacije nema. Plovila koja su na sidrištu najčešće se rotiraju zbog vjetra ili vodenih tokova. Ova metoda je vrlo pouzdana ukoliko se radi o dužim zaustavljanjima. Problem je kod kratkih zaustavljanja jer ne dolazi do dovoljne rotacije plovila.

Treći pristup je najbolji pristup zbog toga što koristi više metoda strojnog učenja od jednom, od kojih svaka metoda ima jedan zadatak. Kombinacija metode gustoće (DB-SCAN) i metode najbližih susjeda (KNN) pokazala se najboljom. Grupirani podaci usidrenih plovila, i plovila na sidrištu dobiveni su algoritmom DB-SCAN, zaustavljena plovila preko AIS poruka, na temelju njihove lokacije i navigacijskog statusa. Zbog svoje mogućnosti uzimanja velikog broja plovila, algoritam KNN je prikupio preostale važne značajke potrebne za točniju klasifikaciju. Problem koji se javlja kod ovog pristupa je nedostatak AIS poruka. Ukoliko AIS podaci nisu validirani može nastati problem. To se može dogoditi iz više razloga kao što su kvar AIS odašiljača, problem sa zemaljskim prijemnikom ili u pružatelju usluga.

3.4.3. PODJELA PUTOVANJA

Kao što je već prije navedeno, putovanje predstavlja kretanje plovila u lučkom području. Validirani podaci grupirani su na temelju identifikacije plovila i na vremenu između dvije uzastopne AIS poruke u području luke.

Za podjelu putovanja izrađen je poseban podatkovni okvir od AIS poruka unutar područja luke. Svaki redak predstavlja jednu AIS poruku, a svaki stupac polje AIS poruke. Redovi su sortirani po identifikacijskom broju i po vremenu. Kako bi podjela putovanja mogla biti moguća, napravljen je poseban skup uvjeta koji uspoređuju dva uzastopna redaka. Ukoliko je razlika između poruka manja od 24 sata, to se smatra kao jedno putovanje. Ako je razmak između poruka veći od 5 sati, i ako se plovilo pomaknulo za više od 100 metara u tom periodu, AIS poruka će to protumačiti kao dva različita putovanja.

3.4.4. MJERNI PODACI O UČINKOVITOSTI LUKA

PARES može pružiti različita mjerila za opis stanja plovila u lukama te njegovim okolnim područjima. Vrijeme obrade jedan je od ključnih pokazatelja stanja i kvalitete luke. Što je ukrcaj i iskrcaj tereta sa plovila brži, to je luka bolja. PARES može automatski izdvojit ove informacije iz AIS podataka.

Također, preko alata je moguće identificirati plovila koja su se kretala u dvije ili više luka. Kod ovakve situacije nedostatak je što nije moguće pristupiti informacijama o teretu. Koristeći ovaj alat moguće je uočiti nenormalan raspored dolazaka i odlazaka redovnih pomorskih linija [7].

3.5. DVOSTRUKI LINEARNI AUTOENKODER ZA PREDVIĐANJE PUTANJE PLOVILA POMOĆU POVIJESNIH AIS PODATAKA

Kako se sve naprednije tehnike uvode u transportne sustave, povećava se i njihova sigurnost. Računalna raširenost u kombinaciji sa svakodnevnim napretkom umjetne inteligencije omogućuje implementaciju novih metoda u raznim sektorima. Pod taj sektor spada i pomorstvo. Iako je pomorstvo grana koja se oslanja na starije, ali provjerene sustave, u kombinaciji sa novim sustavima temeljenim na strojnom učenju pun su pogodak.

3.5.1. SVIJEST O SITUACIJI NA MORU

Povećanjem broja modernih sustava na plovilima, povećava se i sigurnost pomorskog prometa. Glavni temelj održavanja sigurnosti na moru je poznavanje putanja plovila. Svijest o situaciji na moru podijeljena je u tri stupnja:

- Percepcija elemenata u trenutnoj situaciji
- Shvaćanje trenutne situacije
- Projekcija budućeg statusa

Svijest o situaciji na moru uvelike se odnosi na otkrivanje prepreka i predviđanje situacija susreta. Prepreke će prvenstveno biti druga plovila koja se u situaciji susreta nazivaju ciljanim plovilima. Stoga je veoma bitno da osoba koja upravlja plovilom ima odgovarajući stupanj svijesti o situaciji kako bi mogao učinkovito izbjegavati druga plovila na moru.

Trenutno je usvojen širok raspon tehnologija koji služe za pružanje svijesti o situaciji na moru. To se prvenstveno odnosi na rada i ECDIS, koji su ključni za određivanje rizika od sudara. Buduće stanje ciljanog plovila procjenjuje se izračunom vrijednosti kursa i brzine. Na temelju tih parametara moguće je odrediti rizik od sudara.

3.5.2. PREDVIĐANJE PUTANJE PLOVILA

Previđanje putanje broda može biti od velike pomoći pri odlučivanju izvođenja manevra za izbjegavanje sudara. Napredne metode strojnog učenja predviđaju putanje plovila u rasponu od nekoliko sekundi, pa do nekoliko minuta. Metode mogu raditi na lokalnoj i globalnoj razini. Lokalnom razinom se smatra pomoć kod kratkoročnih predviđanja putanja kako bi manevrima pokušao izbjegići sudar, iako se on smatra neizbjježnim. Kod globalnih razina, predviđanje putanje za cilj ima spriječiti neposredni susret plovila na moru.

Jedna od metoda za predviđanje putanje plovila na globalnoj razini je korištenje povijesnih AIS podataka. Korištenjem tih podataka moguće je na uvid dobit prijašnje ponašanje broda, odnosno njegovo kretanje. Nedostatak kod ove metode je što su se putanje brodova značajno promijenile, pa se stoga ova metoda smatra metodom ograničene upotrebe.

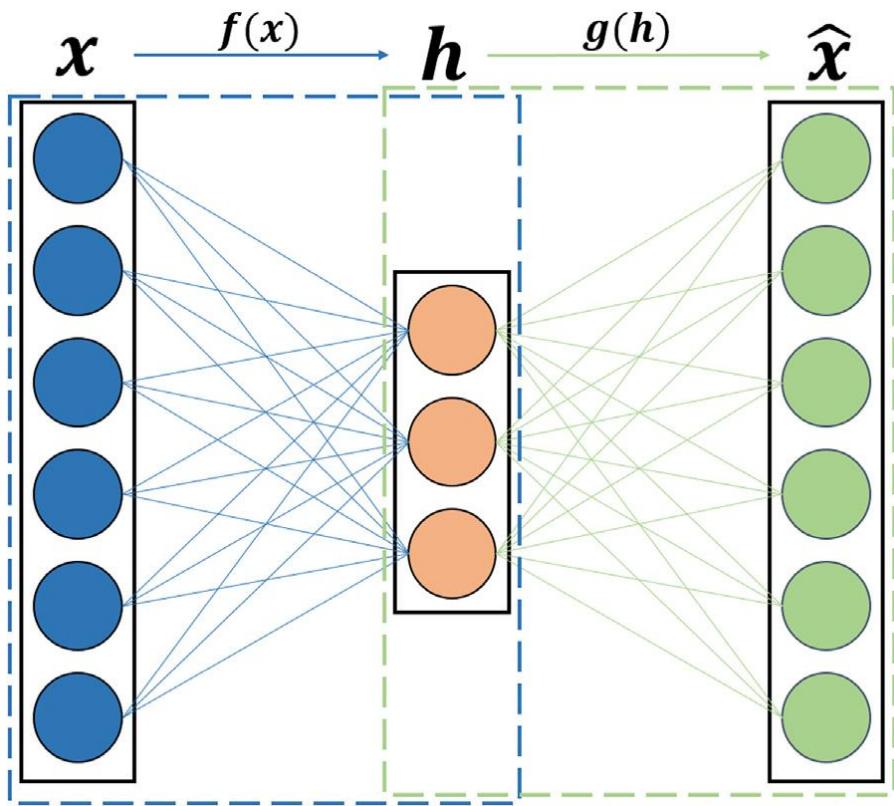
Modernija metoda koja je nastala na grupiranju povijesnih AIS podataka za identifikaciju putanja, te naknadnom klasificiraju djeleži, novih putanja zove se TREAD (*eng. Traffic Route Extraction and Anomaly Detection*). Također, razvijene su i neke metode koje se temelje na kombinaciji AIS povijesnih podataka sa metodama za otkrivanje anomalija kao što su Bayesove mreže ili Gaussovi procesi [8].

3.5.3. GENERATIVNI MODELI

Koriste se i modeli koji imaju alternativni pristup, a koji su bazirani na polju dubokog učenja, te se oni zovu generativni modeli. Danas su takvi modeli stekli visok stupanj popularnosti u području strojnog učenja. Jedan od takvih modela je autoenkoder, čiji je cilj rekonstruirati podatke koji se unose u njega, kopirajući njegov ulaz u njegov izlaz.

Još uvijek se te tehnike u pomorstvu ne primjenjuju u velikoj mjeri. Autoenkoderi su predloženi kao alat za komprimiranje podataka kao bi se omogućio učinkovitiji prijenos pomorskih podataka.

Autoenkoder se sastoji od dva dijela koji su prikazani na slici 19. Prvi dio predstavlja funkcija kodera $f(x)$, koja proizvodi kod h , dok drugi dio predstavlja funkciju dekodera $g(x)$ koja rekonstruira podatke koda h .



Slika 19. Primjer autoenkodera

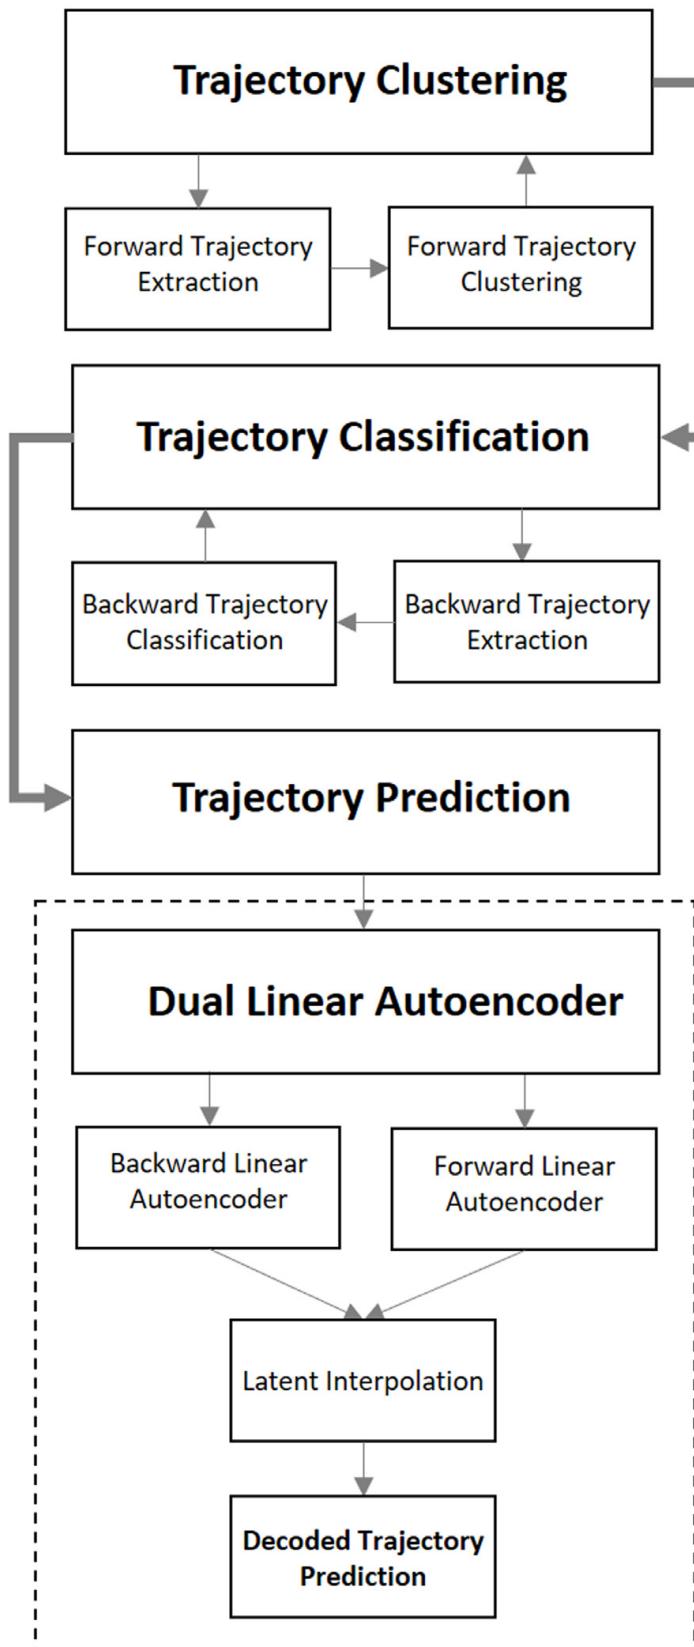
Izvor: <https://www.sciencedirect.com/science/article/pii/S0029801820304959>

3.5.4. GRUPIRANJE I KLASIFIKACIJA PUTANJA

Kako bi se izvršila predikcija putanje plovila, od velikog je značaja identificirati slične putanje i ponašanje u pomorskom prometu. Nakon što se identifikacija izvrši moguće je određeno plovilo smjestiti u određenu skupinu. To se izvršava radnjama grupacije i klasifikacije plovila.

Na taj način, predviđanje putanje može se provesti na određenom skupu podataka, pri čemu će podaci korišteni za predikciju putanje vjerojatno imati visok stupanj sličnosti s onima sa odabranog plovila. Ovakav oblik predprocesiranja AIS podataka smatra se vrlo naprednim s vrlo visokim postotkom točnosti.

Slika 20. prikazuje strukturu predviđanja putanje na temelju grupacije i klasifikacije podataka u kombinaciji sa dvostrukim linearnim autoenkoderom.



Slika 20. Struktura predviđanja putanje

Izvor: <https://www.sciencedirect.com/science/article/pii/S0029801820304959>

3.5.4.1. GRUPIRANJE PUTANJE

Jedan od ciljeva izdvajanja prednjih putanja je osigurati skup podataka na temelju kojeg je moguće identificirati buduće rute koje plovilo može slijediti. Stoga je poželjno grupirati putanje tako a se svaka pojedina ruta može zasebno ocijeniti, budući da može biti mnogo ruta koje pojedino plovilo može slijediti. Taj proces se provodi na način da se generiraju značajke za svaku putanju izravnavajući podatke o položaju dane u UTM koordinatama.

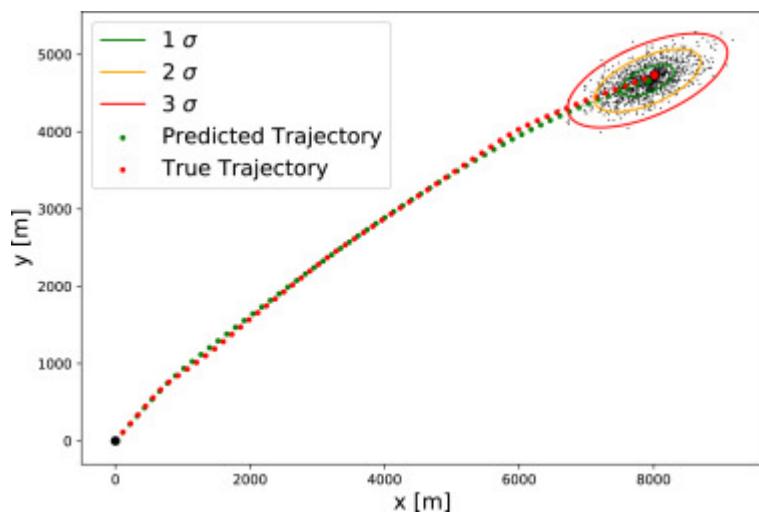
Grupiranje je tehnika koja grupira podatkovne točke na temelju nekih mjera sličnosti, odnosno, podatkovne točke koje su blizu jedna drugoj smatrati će se dijelom iste grupe. Međutim, ako je prostor velik, algoritam grupiranja može imati problema zbog toga što se u velikom prostoru određene točke gube zbog velike udaljenosti između njih.

3.5.4.2. KLASIFIKACIJA PUTANJE

Nakon što su putanje grupirane, potrebno je svrstati svako pojedinačno plovilo u jednu od grupe. Svrstavanje plovila u pojedine grupe na temelju AIS podataka izvršava se tehnikom klasifikacije.

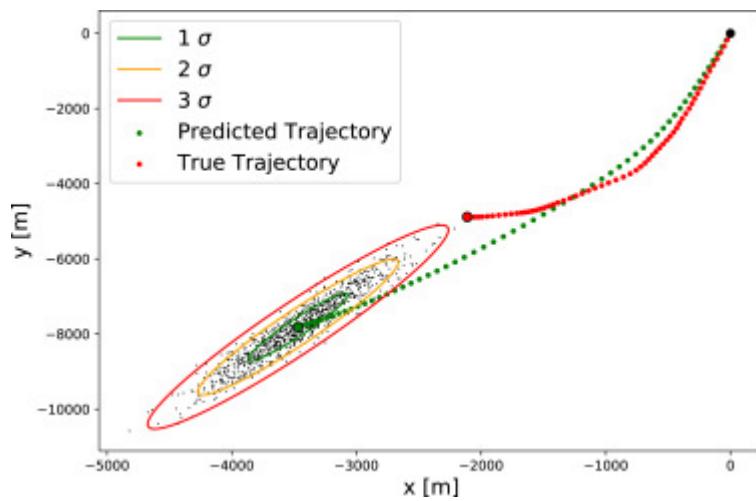
Kod tehnike klasificiranja, putanje se raspoređuju u određene klase nakon čega se putanje određenih plovila svrstavaju u pojedine klase na temelju AIS podataka. Kako bi klasifikacija bila što učinkovitija potrebno je generirati optimalne značajke putanja. Povratnim putanjama dodjeljuju se klase njihovih prednjih putanja otkrivenih navedenom tehnikom.

Predviđanje putanje može se podijeliti na točnu i na netočnu klasifikaciju. Slike 21. 22. prikazuju predviđanje putanje plovila na temelju skupa podataka. Prva slika je primjer točne klasifikacije, a druga slika primjer netočne klasifikacije. Crvena linija predstavlja pravu putanju plovila, dok zelena linija predviđenu putanju plovila.



Slika 21. Predviđanje putanje točnom klasifikacijom

Izvor: <https://www.sciencedirect.com/science/article/pii/S0029801820304959>



Slika 22. Predviđanje putanje netočnom klasifikacijom

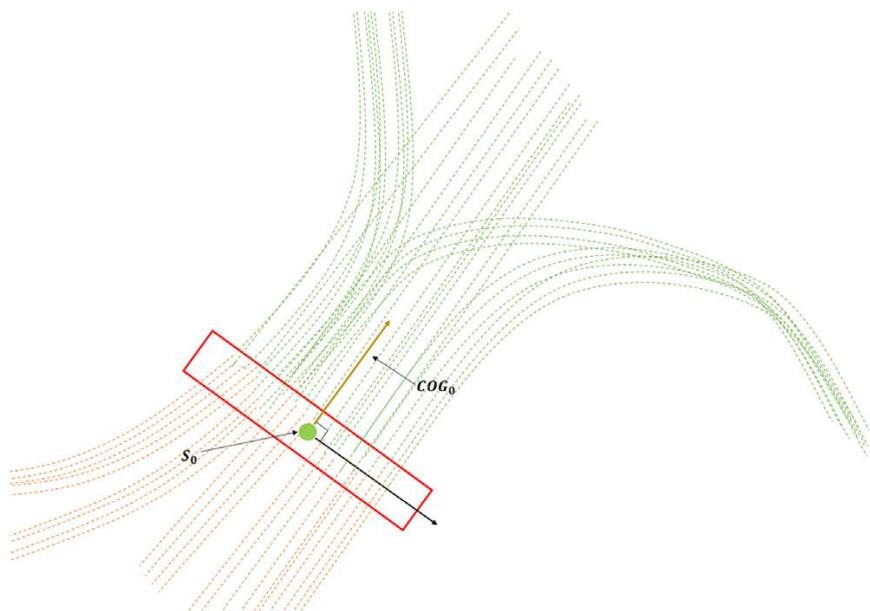
Izvor: <https://www.sciencedirect.com/science/article/pii/S0029801820304959>

3.5.5. DVOSTRUKI LINEARNI AUTOENKODER

Nova metoda koja se koristi za određivanje buduće putanje plovila pomoću dvostrukog linearog autoenkodera još uvijek u pomorstvu nije u širokoj primjeni. Međutim, kao i sve moderne metode i tehnologije pomalo se uvodi u primjenu.

Ukoliko postoji mogućnost stvaranja latentne distribucije između budućih putanja, tada je moguće vršiti interpolaciju između postojećih putanja u latentnom prostoru i generirati nove putanje koje odgovaraju pojedinom plovilu.

Metoda se temelji na treniranju dva linearna autoenkodera. Sve prednje putanje plovila koje pripadaju određenoj klasi unose se u prednji linearни autoencoder. U latentnom prikazu (kodnom prostoru) može se vršiti interpolacija između postojećih podatkovnih točaka i na taj način predvidjeti buduća putanja plovila. Ako se zatim pokrene „prilazak naprijed“ kroz dekoder, dobiti će se potpuno predviđanje putanje. Zatim dolazi do vizualizacije temeljne distribucije budućih putanja plovila gdje dolazi do najvećih varijacija između putanja. Interpolacija ovisi o mjeri sličnosti povratnih putanja koja je omogućena zahvaljujući obrnutom linearном autoenkoderu.



Slika 23. Prikaz prednjih (zelene) i povratnih putanja (narandžaste) plovila

Izvor: <https://www.sciencedirect.com/science/article/pii/S0029801820304959>

3.5.5.1. PREDNJI LINEARNI AUTOENKODER

Cilj prednjeg linearog autoenkodera je stvoriti smisleni latentni prikaz ekstrahiranih prednjih putanja. Međutim, treniranje autoenkodera na svim prednjim putanjama dati će latentnu prezentaciju koja opisuje najveće varijacije u podacima između svih grupa putanja plovila. To može biti predikcija gdje je podatkovna točka interpolirana između grupa, a zapravo predstavlja nerealnu podatkovnu točku koja nije dio distribucije.

Ako se u obzir uzme samo skup putanja pema kojima je odabранo plovilo grupirano, javlja se podskup putanja koje su međusobno vrlo slične, i gdje bi interpolacija između točaka trebala imati smisla. Kao takvo, treniranje autoenkodera na podskupu podataka omogućit će mu da zapamti latentnu prezentaciju koja opisuje svaku pojedinu grupu putanja. Dekodiranje podatkovne točke iz latentne prezentacije će omogućiti predviđanje putanje sa većim postotkom vjerojatnosti.

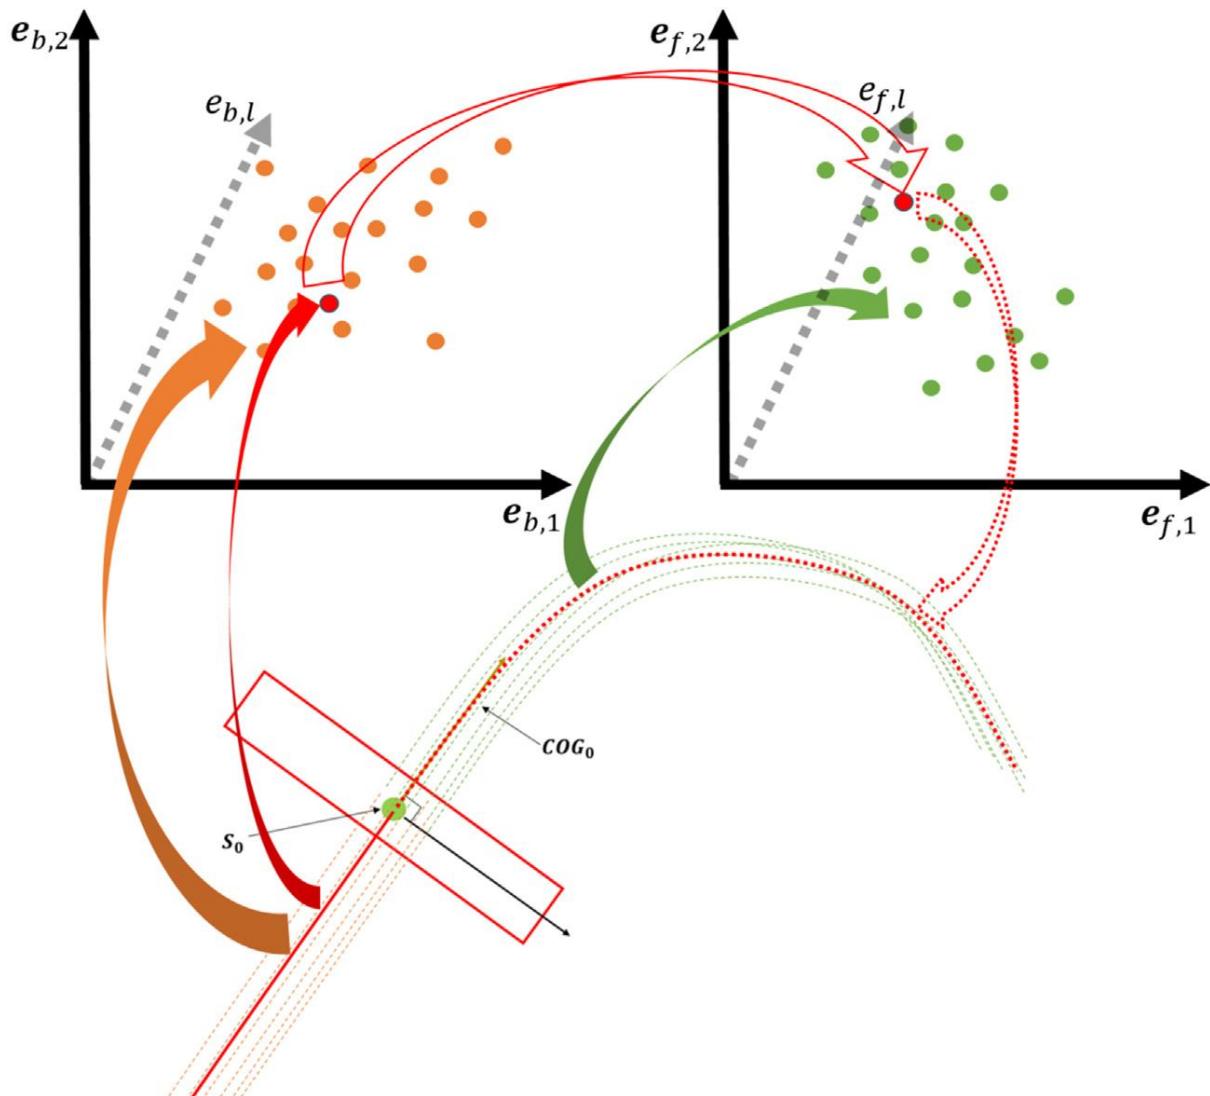
3.5.5.2. OBRNUTI LINEARNI AUTOENKODER

Uspjeh metode predviđanja putanje oslanja se na interpolaciju u latentnom prostoru prednjeg linearog autoenkodera. S obzirom na to da je buduća putanja nepoznanica, mora se zaključiti latentna prezentacija određenog plovila u prednjem latentnom prikazu.

Stoga je predložena usporedba povratnih putanja klasificiranih u grupe, sa povratnim putanjom određenog plovila. Identificiranjem stupnja sličnosti između svih povratnih putanja u grupi, sa određenom povratnom putanjom, u latentnom prostoru moguće je odrediti putanju.

3.5.5.3. LATENTNA INTERPOLACIJA

Budući da ne postoji funkcija eksplicitnog preslikavanja iz latentnog prostora obrnutog linearog autoenkodera u latentni prostor prednjeg linearog autoenkodera, predložen je pristup preslikavanja na temelju sličnosti. Slika 24. prikazuje strukturu predloženog pristupa.



Slika 24. Prikaz latentne interpolacije u dvostrukom linearnom autoenkoderu

Izvor: <https://www.sciencedirect.com/science/article/pii/S0029801820304959>

Slika prikazuje grupiranje putanja u latentni prikaz, povratnih putanja plovila, koje su označene narančastom bojom, te prednjih putanja plovila koje su označene zelenom bojom. Koordinatni sustavi predstavljaju latentni prostor. Povratna putanja plovila prikazana je kao puna crvena linija i predstavlja informacije o ponašanju plovila u prošlosti. Te informacije se zatim kodiraju, što za cilj ima grupiranje podatkovne točke u latentni prostor.

Funkcija preslikavanja može se smatrati interpolacijom između podatkovne točke kodiranih prednjih putanja. Sličnost između kodiranih povratnih putanja i kodiranih povratnih putanja određenog plovila izračunava se kao euklidska udaljenost [8].

3.6. SUMIRAJUĆA TABLICA KORIŠTENIH ZNANSTVENIH ČLANAKA

AUTOR	PRIMJENA STROJNOG UČENJA	REZULTAT
[Obradović2014]	Otkrivanje pomorskih anomalija	Često korišten u praksi, na temelju AIS podataka pokazuje veliku pouzdanost i učinkovitost
[Mao2017]	Procjena rizika od sudara plovila	Koristi pouzdane algoritme, mogućnost korištenja u praksi
[Zhang2021]	Predviđanje pomorske putanje i rudarenje podataka	Dosta komplikiran, puno koraka za točno predviđanje putanje, mogućnost pogreške
[Martinčić2020]	Učinkovitost plovila i luka	Često korišten u praksi, ali dosta komplikiran
[Murray2020]	Predviđanje pomorske putanje	Nova metoda koja nije u širokoj primjeni, u kombinaciji sa provjerenim sustavima može biti od velike koristi

Tablica 4. Prikaz korištenih znanstvenih članaka u radu

Izvor: Pripremio autor

4. IZAZOVI I BUDUĆI TRENDYOVI

Svakodnevni razvitak i sve češća primjena umjetne inteligencije u mnogim sektorima vezanim za ljudske živote donosi sa sobom različite izazove i trendove. Sredinom prošlog stoljeća, prije svega zahvaljujući napretku računalne znanosti, umjetna inteligencija izlazi iz koncipiranih okvira.

Istraživanja umjetne inteligencije danas se uvelike pragmatično orijentirana, a dijele se na grane kao što su procesiranje prirodnog jezika, reprezentacija znanja, automatizirano zaključivanje, strojno učenje, duboko učenje, računalni vid i robotika.

U svim granama postignuti su značajni rezultati koji su omogućili stvaranje izuzetno učinkovitih i inteligentnih sustava za izvršavanje zadataka. Međutim, većina stručnjaka i dalje vjeruje da smo daleko od stvaranja takozvane opće, široke ili moćne umjetne inteligencije. Umjetna inteligencija ima sličnu općenitost i široku primjenu kao ljudska i nije specijalizirana za jedan zadatak ili vrlo ograničen raspon zadataka.

Drugim riječima, ako sustav umjetne inteligencije može izvršiti zadatak na ograničenom području, nadmašujući ljudsku inteligenciju, još uvijek ne može parirati ljudskoj inteligenciji u obavljanju mnogih drugih različitih zadataka.

4.1. IZAZOVI U PRIMJENI

Konkretna primjena umjetne inteligencije, kao i njezine grane strojnog učenja pojavljuje se u mnogim područjima ljudskog života, koje iz dana u dan donose, te proširuju svoje ideje.

Dobra vijest za pomorstvo je da nisu nužni uvijek strojevi koji mogu prikazati teoriju uma ili da su svjesni sebe kako bi transformirali industriju. Postoji niz uzbudljivih aplikacija na kojima već rade startupi, brodovlasnici i pružatelji logistike. Očigledna primjena umjetne inteligencije u pomorstvu su autonomni brodovi, no u stvarnosti se razvijaju mnogo zanimljiviji računalni programi za optimizaciju poslovnih procesa, planiranje putovanja i održavanje plovila i njihovih putanja.

Jedan od glavnih izazova, ali također i najzanimljivijih koji se spominje su autonomna vozila. Ključni razlog za to je praktične naravi: brojne svjetske tvrtke ubrzano rade na razvijanju i testiranju takvih vozila, te bi ona ubrzo mogla postati prometna stvarnost. Očekuje se da će uvođenje takvih vozila (brodovi, auti...) smanjiti broj nesreća, povećati optimizaciju prometa, smanjiti potrošnju goriva te sačuvati okoliš.

4.2. BUDUĆI TRENDLOVI

Bostonski startup Sea Machines Robotics gradi autonomne sustave upravljanja i daljinskog upravljanja kako bi nadogradio rad komercijalnih brodova. Već su lansirali sustav radnih čamaca koji se može naknadno ugraditi na postojeća plovila ili instalirati u nove građevine za manje od 100 000 USD. To je prvi put da će se računalni vid, LiDAR [23] i softver za percepciju koristiti na brodu pod naponom kako bi se povećao i nadogradio rad plovila. Sea Machines vjeruju da njihova tehnologija može pomoći operaterima brodova da smanje operativne troškove za 40% i povećaju produktivnost plovila za 200%.



Slika 25. Sea Machines Robotics autonomno pilotsko plovilo

Izvor: <https://sea-machines.com/>

Prvi teretni brod na svijetu bez posade i bez emisija isplovit će u Norveškoj. Norveška tvrtka stvorila je, kako kaže, prvi autonomni teretni brod na svijetu s nula emisija. Ako sve bude išlo po planu, brod će prije kraja godine krenuti na svoje prvo putovanje između dva norveška grada, sa smanjenom posadom na brodu kako bi testirao autonomne sustave. Na kraju će se sva kretanja pratiti iz tri centra za kontrolu podataka na kopnu.

To nije prvi autonomni brod - autonomni trajekt lansiran u Finskoj 2018. godine - ali je prvi potpuno električni kontejnerski brod. Prvi put koncipiran 2017. godine, brod je nastao u partnerstvu s tehnološkom tvrtkom Kongsberg Maritime i brodograditeljem Vardom. Sposoban je nositi 103 kontejnera i s najvećom brzinom od 13 čvorova. Osim što pruža prihvatljiviju opciju u usporedbi s konvencionalnim teretnim brodovima, brod će biti bez posade što znači da će biti jednostavnije raditi. U početku će utovar i istovar broda zahtijevati ljude, ali sve operacije utovara, pražnjenja i privezivanja, uključujući vez plovila, također će

na kraju raditi pomoću autonomne tehnologije. To će uključivati razvoj autonomnih dizalica i nosača - vozila koja postavljaju kontejnere na brodove.



Slika 26. Prvi autonomni potpuno električni brod

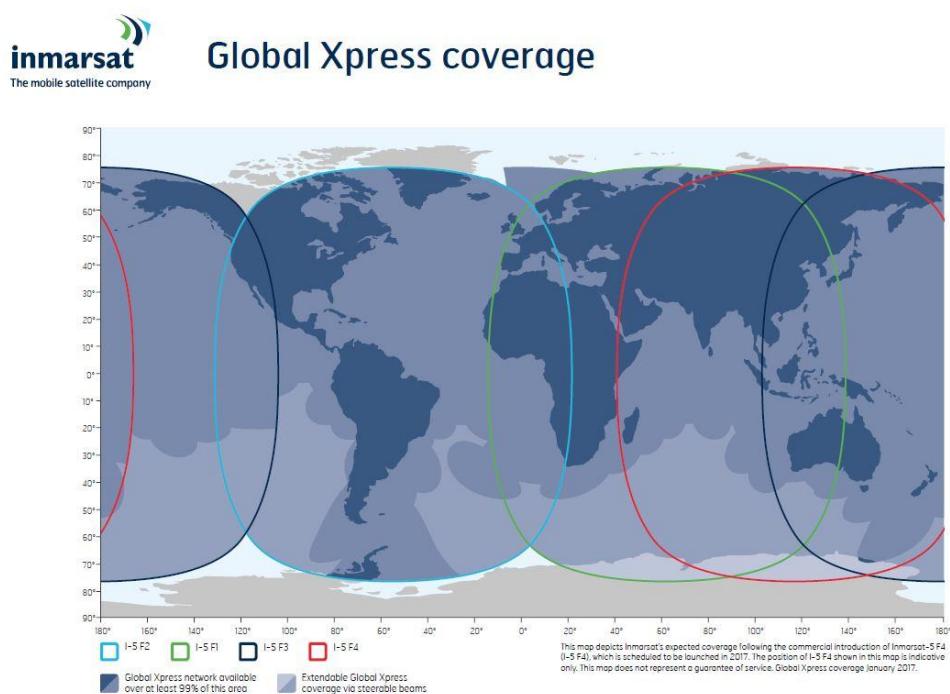
Izvor: <https://www.bug.hr/transport/prvi-elektricni-autonomni-teretni-brod-zaplovit-ce-do-kraja-godine-22971>

4.3. NOVE TEHNOLOGIJE I LJUDSKA POBOLJŠANJA

Uvriježeno je mišljenje da će umjetna inteligencija i njezini ogranci imati dva učinka na tržište rada. Prvi je da će neki poslovi biti izgubljeni jer će zadaće tih poslova biti bolje i jeftinije za obavljanje pametnim strojevima. Drugi je da će se zahvaljujući novim tehnologijama otvoriti nova radna mjesta koja do sada nisu postojala ili nisu bila potrebna. Naravno, sve to ima posljedice. Pitanje je kakav je dugoročni odnos između ova dva učinka, a koje su posljedice nezaposlenosti. Ovo su samo neka od postavljenih pitanja na koja je teško odgovoriti jer pretpostavljaju predviđanja dugoročnih gospodarskih kretanja, kao i dugoročnih tehnoloških kretanja, koja su vrlo složena i neizvjesna.

Nove tehnologije u pomorstvu koriste se za poboljšavanje brodske povezanosti, napredak kod kibernetičko-fizičkih sustava, digitalizaciju koja će preuzeti dominaciju u pomorstvu u nadolazećim desetljećima te će brodovi sve više podsjećati na plutajuća računala. Neke od novih tehnologija koje se pomalo uvode u pomorstvo su: digitalni blizanci, Fleet Xpress, Cyber Physical sustavi...

Povezanost brodova omogućiće razvoj novih pomorskih aplikacija i sustava. Budući da se ove nove aplikacije prvenstveno oslanjaju na komunikaciju, važnost komunikacijskih uređaja jasno će rasti. Ova povećana kritičnost zauzvrat će zahtijevati strože zahtjeve za dostupnošću i pouzdanošću komunikacijskih sustava za nove aplikacije. Inmarsatova najnovija komunikacijska usluga, Fleet Xpress, podiže pomorsku komunikaciju na potpuno novu razinu, nudeći velike brzine prijenosa podataka.



Slika 27. Pokrivenost Fleet Xpressa

Izvor: <https://www.polaris-as.dk/>

Digitalni blizanci digitalne su replike fizičkih sredstava, procesa i sustava koji se mogu koristiti u različite svrhe. Digitalni blizanci kombiniraju umjetnu inteligenciju, strojno učenje i softversku analitiku s podacima za stvaranje živih digitalnih simulacijskih modela koji se

ažuriraju i mijenjaju kako se mijenja stanje fizičkih komponenti sustava. U raznim industrijskim područjima twinning se koristi za optimizaciju rada i održavanja fizikalnih sustava i proizvodnih procesa. Oni predstavljaju tehnologiju, gdje fizički objekti mogu živjeti i virtualno komunicirati s drugim strojevima i ljudima.



Slika 28. Koncept digitalnih blizanaca

Izvor: <https://www.cadcam-group.eu/hr/>

Cyber-Physical System ili CPS je izraz za integrirano računalo i fizičke mogućnosti kao što su senzori, komunikacije i akcije na fizički svijet. U primjeni naprednih koncepata kao što su Industrija 4.0 i kibernetičko-fizički sustavi, samo postojanje veza između strojeva i senzora nije dovoljno. Da bi ove napredne tehnologije radile zajedno, prave informacije moraju biti dostupne za pravu svrhu u pravo vrijeme [14].

5. ZAKLJUČAK

Cilj ovog rada bio je istražiti i prikazati kako se umjetna inteligencija, odnosno strojno učenje u kombinaciji sa automatskim identifikacijskim sustavom (AIS) može primijeniti za iskorištavanje pomorskih podataka.

U radu su definirani ključni elementi, te opisani načini primjene umjetne inteligencije u pojedinim područjima pomorstva, sa posebnim osvrtom na strojno učenje i AIS. Metode strojno učenja primijenjene su na sustavima za otkrivanje pomorskih anomalija, za predviđanje putanje plovila, za procjenu rizika od sudara plovila i za određivanje učinkovitosti plovila i luka.

Na temelju primjene svih metoda može se zaključiti da umjetna inteligencija ima veliki i značajan utjecaj, ponajprije zbog toga što povećava sigurnost i pouzdanost pomorskog prometa, povećava i njegovu efikasnost te smanjuje negativni utjecaj na okoliš.

Umjetna inteligencija svakim danom je sve prisutnija. Primjena umjetne inteligencije je neograničena u različitim područjima, od jednostavnijih stvari do vrlo kompleksnih zadataka. Ona postaje sve važnija ne samo u poslu, nego i u drugim sferama života suvremenog čovjeka. Sustavi umjetne inteligencije bave se onime što je ljudima dosta komplikirani i teško.

Neuronske mreže i tehnologije umjetne inteligencije dubokog učenja brzo se razvijaju, prvenstveno zato što umjetna inteligencija puno brže obrađuje velike količine podataka i predviđa točnije nego što je to ljudski moguće.

Dok bi ogromna količina podataka koja se stvara na dnevnoj bazi otežala posao čovjeku, aplikacije umjetne inteligencije koje koriste strojno učenje mogu uzeti te podatke i brzo ih pretvoriti u korisne informacije. Primarni nedostatak korištenja umjetne inteligencije je taj što je skupo obraditi velike količine podataka koje zahtijeva programiranje umjetne inteligencije.

Iako je već prisutna u našim svakodnevnim životima, nismo ni svjesni kakve će goleme promijene umjetna inteligencija donijeti u budućnosti.

LITERATURA

- [1] Wikipedia: https://hr.wikipedia.org/wiki/Umjetna_inteligencija
- [2] Wikipedia: https://en.wikipedia.org/wiki/Machine_learning
- [3] Badurina Egon, Automatski identifikacijski sustav, 2004.
- [4] Obradović I., Miličević M., 2014., Machine Learning Approaches to Maritime Anomaly Detection, online: <https://hrcak.srce.hr/file/192572>
- [5] Mao, S. 2018., “An automatic identification system (AIS) database for maritime trajectory prediction and data mining,” in Proceedings in Adaptation, Learning and Optimization. Cham: Springer International Publishing, pp. 241–257.
- [6] Zhang, M., 2021., “A big data analytics method for the evaluation of ship - ship collision risk reflecting hydrometeorological conditions,” Reliability Engineering & System Safety, 213(107674), p. 107674. doi: 10.1016/j.ress.2021.107674.
- [7] Martinčić, T., 2020., “Vessel and Port Efficiency Metrics through Validated AIS data,” in Global Oceans 2020: Singapore – U.S. Gulf Coast. IEEE.
- [8] Murray, B., Perera, L. P., 2020. , “A dual linear autoencoder approach for vessel trajectory prediction using historical AIS data,” Ocean engineering, 209(107478), p. 107478. doi: 10.1016/j.oceaneng.2020.107478.
- [9] Nishizaki, C., 2018., “Development of navigation support system to predict new course of ship,”, 2018 World Automation Congress (WAC). IEEE, pp. 1–5.
- [10] Schöller, F., 2021., “Trajectory prediction for marine vessels using historical AIS heatmaps and long short-term memory networks,” IFAC-PapersOnLine, 54(16), pp. 83–89. doi: 10.1016/j.ifacol.2021.10.077.
- [11] Mascaro, S., Nicholso, A. E. and Korb, K. B., 2014., “Anomaly detection in vessel tracks using Bayesian networks,” International journal of approximate reasoning: official publication of the North American Fuzzy Information Processing Society, 55(1), pp. 84–98. doi: 10.1016/j.ijar.2013.03.012.
- [12] Munim, Z. H., 2020., “Big data and artificial intelligence in the maritime industry: a bibliometric review and future research directions,” Maritime policy & management, 47(5), pp. 577–597. doi: 10.1080/03088839.2020.1788731.
- [13] Murray, B. and Perera, L. P., 2021., “Proactive collision avoidance for autonomous ships: Leveraging machine learning to emulate situation awareness,” IFAC-PapersOnLine, 54(16), pp. 16–23. doi: 10.1016/j.ifacol.2021.10.067.

- [14] Sidibé, A. and Shu, G., 2017., “Study of automatic anomalous behaviour detection techniques for maritime vessels,” *Journal of navigation*, 70(4), pp. 847–858. doi: 10.1017/s0373463317000066.
- [15] Snapir, B., Waine, T. and Biermann, L., 2019., “Maritime vessel classification to monitor fisheries with SAR: Demonstration in the North Sea,” *Remote sensing*, 11(3), p. 353. doi: 10.3390/rs11030353.
- [16] Song, J. and Kim, D.-J., 2020., “Fine acquisition of vessel training data for machine learning from sentinel-1 SAR images accompanied by AIS imformation,” in *IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, pp. 1624–1627.
- [17] Song, J., Kim, D.-J. and Kang, K.-M., 2020., “Automated procurement of training data for machine learning algorithm on ship detection using AIS information,” *Remote sensing*, 12(9), p. 1443. doi: 10.3390/rs12091443.
- [18] de Souza, E. N., 2016., “Improving fishing pattern detection from satellite AIS using Data Mining and machine learning,” *PloSOne*, 11(7), doi: 10.1371/journal.pone.0158248.
- [19] Yan, R. and Wang, S., 2019., “Study of data-driven methods for vessel anomaly detection based on AIS data,” in *Smart Innovation, Systems and Technologies*. Singapore: Springer Singapore, pp. 29–37.
- [20] Jurdana Irena, Lopac Nikola, Liu Hongze, Shipboard Data Compression Method for Sustainable Real-Time Maritime Communication in Remote Voyage Monitoring of Autonomous Ships. // *Sustainability*, 13 (2021), 15; 8264,22
- [21] Jurdana Irena, Lopac Nikola, Liu Hongze, BlueNavi: A Microservices Architecture-Styled Platform Providing Maritime Information // *Sustainability*, 14 (2022), 4; 2173
- [22] Lopac Nikola, Wakabayashi Nobukazu, Application of Advanced Digital Technologies for AIS Data Utilization, 15th Baška GNSS Conference: Technologies, Techniques and Applications Across PNT and The 2nd Workshop on Smart, Blue and Green Maritime Technologies, Baška, Hrvatska, 2022.
- [23] Jurdana Irena, Lopac Nikola, Brnelić Adrian, Krljan Tomislav, Application of Laser Systems for Detection and Ranging in the Modern Road Transportation and Maritime Sector, MDPI-Sensors – 22, 2022, <https://www.mdpi.com/1424-8220/22/16/5946>

POPIS SLIKA

Slika 1. AIS sustav	4
Slika 2. Primjer rada AIS-a	7
Slika 3. Prikaz razmjene podataka.....	8
Slika 4. Podjela strojnog učenja	10
Slika 5. Anomalija u ponašanju plovila u polukružnoj ruti.....	12
Slika 6. Predviđanje budućeg položaja plovila	13
Slika 7. Okvir za procjenu rizika od sudara	17
Slika 8. Dijagram toka grupiranja putanja	18
Slika 9. Proces grupiranja putanja	19
Slika 10. Indeks gustoće rizika od sudara tijekom akcije izbjegavanja.....	20
Slika 11. Primjer csv datoteke	22
Slika 12. Primjer složenosti rute	22
Slika 13. Diskontinuirana putanja	23
Slika 14. Opuštena putanja.....	24
Slika 15. Isprepletena putanja.....	24
Slika 16. Prikaz putanje prije i nakon interpolacije	25
Slika 17. Primjer PARES-a	27
Slika 18. Ručno određeni poligoni unutar luke	28
Slika 19. Primjer autoenkodera	32
Slika 20. Struktura predviđanja putanje.....	33
Slika 21. Predviđanje putanje točnom klasifikacijom	35
Slika 22. Predviđanje putanje netočnom klasifikacijom	35
Slika 23. Prikaz prednjih (zelene) i povratnih putanja (narancaste) plovila.....	36
Slika 24. Prikaz latentne interpolacije u dvostrukom linearном autoenkoderu	38
Slika 25. Sea Machines Robotics autonomno pilotsko plovilo	42
Slika 26. Prvi autonomni potpuno električni brod	43
Slika 27. Pokrivenost Fleet Xpressa	44
Slika 28. Koncept digitalnih blizanaca	45

POPIS TABLICA

Tablica 1. Statički i dinamički podaci broda	6
Tablica 2. Podaci o plovidbi i sigurnosni podaci	7
Tablica 3. Korelacija između rizika od sudara i hidrometeoroloških uvjeta	20
Tablica 4. Prikaz korištenih znanstvenih članaka u radu	39