

VILNIAUS UNIVERSITETAS

Andrius
DARANDA

Mašininiu mokymusi grindžiamas
laivybos eismo dalyvių elgsenos
prognozavimas bei nestandartinių
laivybos srauto situacijų atradimas

DAKTARO DISERTACIJA

Technologijos mokslai,
Informatikos inžinerija (T 007)

VILNIUS 2021

Disertacija rengta 2015 – 2020 metais Vilniaus universitete.

Mokslinis vadovas:

prof. habil. dr. Gintautas Dzemyda, (Vilniaus universitetas, technologijos mokslai, informatikos inžinerija – T 007).

Mokslinis konsultantas:

prof. dr. Arūnas Andziulis, Klaipėdos universitetas, technologijos mokslai, informatikos inžinerija – T 007).

VILNIUS UNIVERSITY

Andrius
DARANDA

Machine learning-based prediction of
the behavior of marine traffic
participants and discovering non-
standard marine traffic situations

DOCTORAL DISSERTATION

Technological Sciences,
Informatics Engineering (T 007)

VILNIUS 2021

This dissertation was written between 2015 and 2020 in the Vilnius University.

Academic supervisor:

Prof. Habil. Dr. Gintautas Dzemyda (Vilnius University, Technological Sciences, Informatics Engineering – T 007).

Academic consultant:

Prof. Dr. Arūnas Andziulis (Klaipėda University, Technological Sciences, Informatics Engineering T 007).

SANTRAUKA

Pastaraisiais dešimtmečiais laivybos intensyvumas stipriai išaugo. Tačiau dabar, kaip ir seniausiais laikais, kelionės laivu saugumas priklauso tik nuo atsakingo asmens, laivavedžio, patirties ir priimtų sprendimų manevruojant laivą. Net šiais modernių technologijų laikais technologijos negali visapusiškai analizuoti ir valdyti vykstančio laivų judėjimo. Laivavedys privalo nuolat stebėti ir analizuoti esamą situaciją bei laiku nustatyti galimą pavojų ar kitokį neįprastą stebimo laivo manevrą. Tai būtina siekiant numatyti ar prognozuoti stebimo laivo manevrus, suplanuoti savo manevrus bei priimti teisingą sprendimą laiku, išvengiant skaudžių avarių.

Disertacijos tyrimo objektas – mašininio mokymosi metodai laivų manevrams modeliuoti ir situacijai vertinti. Šio darbo tikslas – sukurti mašininio mokymosi algoritmais grindžiamą metodą, kuris leistų prognozuoti ir įvertinti stebimų laivų manevravimą, siekiant užtikrinti saugią laivybą.

Darbe susitelkiama į pastaruosiu metu ypač daugelyje sričių taikomus mašininio mokymosi metodus. Siekiama išplėsti jų taikymą moderniems laivybos sprendimams. Pasiūlyti ir eksperimentiškai ištirti algoritmai, skirti istoriniams navigacijos duomenims klasterizuoti. Disertacijoje klasterizavimas panaudotas istoriniams laivybos duomenims agreguoti ir agreguotiems duomenims panaudoti tolesniuose eksperimentuose su mašininio mokymosi algoritmais. Pasiūlyti ir eksperimentiškai ištirti du metodai, skirti prognozuoti būsimus artimiausius stebimo laivo posūkio taškus, kuriais remiantis galima būtų sudaryti net ir būsimą laivo maršrutą. Numačius laivo būsimo posūkio taško koordinatas, galima tinkamai suplanuoti manevrą, padedantį išvengti pavojingos situacijos. Pasiūlytas ir eksperimentiškai ištirtas metodas skirtas aptikti nukrypimą (anomaliją) nuo planuoto arba prognozuojamo maršruto.

Disertacijoje pateikiamas naujas kompleksinis metodas paremtas kontekstine informacija pagrįstu posūkio taško prognozavimu ir vertinimu. Ši prognozė vertinama siekiant įspėti apie neįprastą situaciją dar nesant jos požymių. Metodas skirtas darbui su realiojo laiko navigacijos duomenimis.

Pasiūlytų metodų analizė atlikta sprendžiant klasterizavimo ir klasifikavimo uždavinius su istoriniais jūriniais navigacijos duomenimis.

Raktiniai žodžiai: **saugi laivyba, posūkio taško prognozė, anomalija laivyboje, savivoka, grėsmės vertinimas, kontekstinės žinios.**

ABSTRACT

In recent decades, marine traffic dramatically increases. From ancient times till nowadays, vessel safety depends on the watch officer's experience and decisions in any maneuvering situation. Even in modern times, marine navigation technologies could not ensure the analysis and control of marine traffic. The watch officer must constantly supervise and analyze the marine traffic for dangerous situations or any unusual behavior to ensure safe navigation. It is essential to anticipate and predict the unusual behavior of the monitored vessel. It allows to make the right decision in time and plan actions to ensure safe marine navigation.

In this thesis, we investigate the possibility of applying machine learning methods for maneuver modeling and threat assessment of maneuvering situations to ensure safe navigation. This work aims to create machine learning methods for predicting and threat assessment of maneuvering situations to ensure safe navigation.

This thesis is based on methods of machine learning. The aim is to apply machine learning algorithms to modern marine solutions. The historical marine traffic data clustering method was proposed and investigated. The result of the clustering was applied to further experiments on machine learning algorithms. Two different methods were proposed and examined for the prediction of the next turning point and route of the vessel. Such prediction allows to plan and evaluate actions to ensure safe navigation. The method to detect anomalies in traffic flow was proposed and examined.

In this thesis, the novel method based on contextual knowledge was proposed. This method makes evaluation and threat assessment on the predictions of the turning point. The purpose of this prediction is to evaluate the unfamiliar maneuvering situation. The proposed method is designed to process real-time marine traffic data.

The analysis of the proposed algorithms was performed by solving the tasks of clustering and classification of the historical marine navigation data.

Keywords: safe marine traffic, turn point prediction, marine anomaly detection, self-awareness, threat assessment, contextual knowledge.

SANTRUMPOS

AIS (angl. *Automatic Identification System*) – laivų automatinė identifikavimo sistema;

COG (angl. *Course Over Ground*) – kursas virš grunto;

ECDIS (angl. *Electronic Chart Display and Information System*) – elektroninių jūrlapių vaizdavimo ir informacijos sistema;

GPS (angl. *Global Positioning System*) – globali pozicionavimo sistema;

IMO (angl. *International Maritime Organization number*) – tarptautinės jūrų organizacijos suteiktas unikalus numeris;

MMSI (angl. *Maritime Mobile Service Identity*) – laivo radijo stoties radijo šaukinys;

SOG (angl. *Speed Over Ground*) – greitis virš grunto;

SOLAS (angl. *Safety of Life at Sea*) – tarptautinė konvencija dėl žmogaus gyvybės apsaugos jūroje;

STCW (angl. *Standards of Training, Certification and Watchkeeping for Seafarers*) – konvencija, skirta jūrininkų rengimo, atestavimo ir budėjimo normatyvams;

VHF (angl. *Very High Frequency*) – labai aukštas radijo bangų dažnis;

VTC (angl. *Vessel Traffic Center*) – laivų stebėjimo tarnyba.

TURINYS

1. ĮVADAS.....	12
1.1. TYRIMŲ SRITIS IR PROBLEMOS AKTUALUMAS.....	12
1.2. TYRIMŲ OBJEKTAS	13
1.3. DARBO TIKSLAS IR UŽDAVINIAI	13
1.4. TYRIMŲ METODIKA	13
1.5. MOKSLINIS DARBO NAUJUMAS.....	14
1.6. PRAKTINĖ DARBO REIKŠMĖ	14
1.7. GINAMIEJI TEIGINIAI.....	15
1.8. DARBO REZULTATŲ APROBAVIMAS	15
1.9. DISERTACIJOS APIMTIS IR STRUKTŪRA.....	16
2. METODAI, SKIRTI UŽTIKRINTI SAUGIĄ LAIVYBĄ	18
2.1. LAIVYBOS SAUGUMAS IR GRĖSMĖS	18
2.2. TECHNOLOGIJOS SAUGIAI LAIVYBAI UŽTIKRINTI.....	20
2.3. AUTOMATINĖ LAIVŲ IDENTIFIKAVIMO SISTEMA.....	21
2.4. SPRENDIMŲ PRIĖMIMAS LAIVYBOJE	23
2.5. MARŠRUTO PAIEŠKOS IR SUSIDŪRIMO IŠVENGIMO ALGORITMAI ..	25
2.6. MARŠRUTO PLANAVIMO ALGORITMAI	26
2.7. SUSTIPRINTO MOKYMO SI ALGORITMAS	29
2.8. TYRIMAMS NAUDOJAMI DUOMENYS	37
2.9. SKYRIAUS APIBENDRINIMAS	40
3. LAIVYBOS MARŠRUTŲ PROGNOZAVIMO MODELIS.....	42
3.1. ANOMALIJŲ APTIKIMAS LAIVYBOJE	42
3.2. NAVIGACIJOS DUOMENŲ KLASTERIZAVIMAS.....	43
3.3. STEBIMO LAIVO MARŠRUTO PROGNOZAVIMO MODELIS.....	47
3.4. DNT PRITAIKYMAS STEBIMO LAIVO MARŠRUTUI PROGNOZUOTI ..	56
3.5. MARŠRUTO PROGNOZAVIMO MODELIO TAIKYMO TYRIMO REZULTATAS.....	59
3.6. ANOMALIJŲ APTIKIMAS LAIVYBOJE	62
3.7. SKYRIAUS APIBENDRINIMAS	68
4. KONTEKSTINE INFORMACIJA GRĮSTO PROGNOZAVIMO METODAS.....	70
4.1. KONTEKSTINE INFORMACIJA GRĮSTAS PROGNOZAVIMO METODAS	70
4.2. LAIVYBOS KONTEKSTAS.....	71
4.3. SAUGIOS LAIVYBOS UŽTIKRINIMO METODAS.....	74

4.4.	NAVIGACIJOS DUOMENŲ PARUOŠIMAS	78
4.5.	DUOMENŲ KLASIFIKAVIMAS SPRENDIMŲ MEDŽIU	80
4.6.	NEĮPRASTŲ SITUACIJŲ APTIKIMAS.....	82
4.7.	ALGORITMO APMOKYMAS IR REZULTATAI.....	84
4.8.	PASIŪLYTO METODO TAIKYMAS.....	89
4.9.	SKYRIAUS APIBENDRINIMAS	91
5.	APIBENDRINIMAS IR BENDROSIOS IŠVADOS	93
	LITERATŪROS SĄRAŠAS.....	96
	APROBAVIMAS.....	109

ILIUSTRACIJŲ SĄRAŠAS

1 pav. AIS veikimo principas.....	22
2 pav. Laivybos tankumas Šiaurės jūroje.....	23
3 pav. Principinė sprendimo priėmimo schema	24
4 pav. Sėkmingas dinaminio lango algoritmo pritaikymas	27
5 pav. Nesėkmingas dinaminio lango algoritmo pritaikymas	28
6 pav. Potencinio lauko algoritmo pritaikymas	29
7 pav. Sustiprinto mokymosi algoritmo mokymosi schema	30
8 pav. Gilaus sustiprinto mokymosi algoritmo schema	31
9 pav. Sustiprinto mokymosi aplinka.....	31
10 pav. Sustiprinto mokymosi progresas: a) 50 etapų; b) 100 etapų	32
11 pav. Apmokymo progresas iki 1500 etapų.....	33
12 pav. Sustiprinto mokymosi progresas su trimis kliūtimis: a) 50 etapų; b) 100 etapų	35
13 pav. Apmokymo progresas su kintančia tikslo taško padėtimi a) 50 etapų; b) 100 etapų	36
14 pav. Tekstiniu formatu AIS saugomų duomenų pavyzdys	38
15 pav. AIS duomenų struktūros diagrama.....	38
16 pav. Sugeneruotas AIS duomenų grafinis pavaizdavimas	40
17 pav. Skirtingo laivo judėjimo į tą patį uostą pavyzdys	43
18 pav. Posūkio taškų klasterizavimas.....	45
19 pav. DBSCAN algoritmo panaudojimas.....	46
20 pav. Laivybos srautai Baltijos jūroje.....	47
21 pav. Duomenų paruošimo ir maršruto prognozavimo modelio apmokymas	48
22 pav. Posūkio taškų klasteris su apskaičiuotu centru	49
23 pav. Skirtingi rezultatai pritaikius skirtingą ε parametą	49
24 pav. Posūkio taškų klasterizavimas, kai $\varepsilon = 0,001$	50
25 pav. Posūkio taškų klasterizavimas, kai $\varepsilon = 0,1$	51
26 pav. Posūkio taškų klasterizavimas, kai $\varepsilon = 0,05$	51
27 pav. Klasterių išsidėstymas laivybos kanale	52
28 pav. Klasterių skaičius pagal paskirties uostą.....	53
29 pav. Neuroninio tinklo schema	54
30 pav. Neuroninio tinklo apmokymo progresas	55
31 pav. Laivo maršruto pagal prognozuojamus klasterius.....	56
32 pav. Laivų maršruto prognozavimo modelio taikymo schema	58
33 pav. Klasterizuoti maršrutų taškai į Roterdamą, Olandija	59
34 pav. Prognozuoto ir faktinio maršruto palyginimas	60
35 pav. Prognozavimo tikslumas	61

36 pav. Prognozuotas maršrutas su didelėmis paklaidomis	62
37 pav. Anomalių laivyboje pavyzdžiai	63
38 pav. Suklasterizuotas laivybos srautas	64
39 pav. Anomalus laivų judėjimas srauto atžvilgiu	65
40 pav. Vidutinis atstumas tarp kaimynų laivybos sraute į tą patį uostą	66
41 pav. Vidutinis atstumas tarp laivybos srauto ir anomalių taškų	67
42 pav. Įvairūs faktoriai, turintys įtaką saugiai laivybai	72
43 pav. Posūkio taškų vizualizacija	76
44 pav. Manevavimo situacijų palyginimas	77
45 pav. OPTICS algoritmo klasterizavimo rezultatas	79
46 pav. Sprendimų medžio apmokymo duomenys	81
47 pav. a) normalus laivo judėjimas, b) neįprastas laivo judėjimas	83
48 pav. Duomenų pavyzdys	84
49 pav. Pasiūlyto algoritmo apmokymo procesas	86
50 pav. Sprendimo medžio tikslumas, pritaikant parametą <i>maxdepth</i>	87
51 pav. Aptiktos neįprastos situacijos pavyzdys	88
52 pav. Manevro vertinimas	89
53 pav. Sprendimų priėmimo proceso schema	90

1. ĮVADAS

1.1. Tyrimų sritis ir problemos aktualumas

Šiuolaikiniame pasaulyje laivyba yra ypač svarbi transporto rūšis. Didžioji pasaulyje transportuojamų krovinių dalis gabenama jūriniu transportu. Krovinių pristatymas laivais yra ekonomiškiausias iš esamų transportavimo būdų, taip pat yra saugesnis ir ekologiškesnis. Nepaisant to, kad krovinių gabenimas laivais yra saugesnis, gana dažnai pasitaiko su laivais susijusių nelaimingų atsitikimų ir avarijų. Šių nelaimių pasekmės būna žymiai skaudesnės ir tragiškesnės lyginant su kitų transporto priemonių avarijomis, nes:

1. Gali žūti nepalyginamai daugiau žmonių. Tai yra ypač aktualu keleiviniams / kruiziniams laivams.
2. Prarandamas kroviny, kuris laivais gabenamas dideliais kiekiais, todėl nuostoliai būna žymiai didesni.
3. Gali kilti ekologinė katastrofa.

Per pastaruosius 50 metų laivyba buvo reglamentuota įvairiais teisiniais aktais, kurių laikymasis turi užtikrinti saugią laivybą: konvencija dėl tarptautinių taisyklių, padedančių išvengti laivų susidūrimų jūroje (angl. *International Regulations for Preventing Collisions at Sea 1972*) [1], tarptautinė konvencija dėl žmogaus gyvybės apsaugos jūroje (angl. *Safety of Life at Sea*) [23], konvencija dėl jūrininkų rengimo, atestavimo ir budėjimo normatyvų (angl. *Standards of Training, Certification and Watchkeeping for Seafarers*) (STCW) ir t. t. Šiomis konvencijomis siekiama užtikrinti žmonių gyvybių saugumą jūroje, nustatant tam taikomus vienodus darbo principus, standartus bei taisykles laivuose.

Taip pat didelė pažanga įgyvendinta pritaikant technologijas laivams – Automatinę identifikacinę sistemą (AIS), elektroninių jūrlapių vaizdavimo ir informacijos sistemą (ECDIS), globalinę jūrų avarinio ryšio ir saugos sistemą (GMDSS) ir t. t. Šios technologijos gerina laivybos saugumą, tačiau niekaip negali pakeisti laivavedžio, kuris priima sprendimus ir yra atsakingas už galimas pasekmes. Laivavedys remiasi visa prieinama informacija apie esamą situaciją, analizuoja ir modeliuoja galimus sprendimus bei priima sprendimą, kaip elgtis konkrečioje situacijoje. Dėl didelių laivo gabaritų bei jo manevravimo savybių laivavedys turi iš anksto numatyti ir įvertinti kitų laivų manevrus. Laivavedys, įvertinęs riziką ir priimdamas sprendimą, prisiima visišką atsakomybę už galimas pasekmes. Todėl yra reikalingi dirbtinio intelekto metodai, pagrįsti mašininio mokymusi [2] ir skirti laivavedžio

sprendimų paramai. Tokie metodai turi gebėti mokytis ir gerinti prognozavimo tikslumą be papildomo žmogaus įsikišimo. Tai ypač svarbu modeliuojant manevravimo situacijas ir rekomenduojant galimus sprendimus, siekiant išvengti pavojingų situacijų.

1.2. Tyrimų objektas

Disertacijos tyrimo objektas – mašininio mokymosi algoritmų taikymas laivų manevrams modeliuoti ir situacijai vertinti.

1.3. Darbo tikslas ir uždaviniai

Tikslas:

- Sukurti mašininiais mokymosi algoritmais grindžiamą metodą, kuris leistų prognozuoti ir įvertinti stebimų laivų manevravimą, siekiant užtikrinti saugią laivybą.

Uždaviniai:

- Analitiškai apžvelgti laivyboje naudojamus metodus ir algoritmus, skirtus saugiai laivybai užtikrinti; eksperimentiškai įvertinti taikymo ribotumus.
- Ištirti galimybes pritaikyti mašininio mokymosi algoritmus stebimų laivų judėjimui bei galimam manevrui prognozuoti ir įvertinti: prognozuoti būsimus stebimo laivo posūkio taškus bei aptikti nukrypimus nuo bendro maršruto (anomalijas).
- Sukurti mašininio mokymosi grįstą kompleksinį metodą, skirtą prasilenkiančių laivų manevrų analizei, kai stebimo laivo manevras ne tik prognozuojamas pagal susidariusias aplinkybes, bet ir vertinamas remiantis kontekstinėmis žiniomis, gautomis iš istorinių laivybos duomenų.
- Siūlomiesiems metodams ir sprendimų efektyvumui pagrįsti, atlikti eksperimentinius tyrimus su didelės apimties laivybos istoriniais navigacijos duomenimis.

1.4. Tyrimų metodika

Šios disertacijos tyrimas pagrįstas šiais metodais:

1. Darbe naudojami analizės, lyginamosios analizės ir apibendrinimo metodai.
2. Darbo tikslui pasiekti ir uždaviniams spręsti analizuojami ir vertinami šiuo metu laivyboje taikomi metodai ir algoritmai, skirti saugiai

laivybai užtikrinti, taip pat algoritmai, skirti planuoti maršrutą bei išvengti esamų kliūčių.

3. Mašininis mokymasis iš didelių istorinių laivybos navigacijos duomenų.

1.5. Mokslinis darbo naujumas

Disertacija yra moksliskai reikšminga dėl šių priežasčių:

1. Pasiūlyti ir eksperimentiškai ištirti algoritmai, skirti istoriniams navigacijos duomenims klasterizuoti.
2. Pasiūlyti ir eksperimentiškai ištirti metodai, skirti prognozuoti stebimo laivo būsimus artimiausius posūkio taškus, kuriais remiantis galima numatyti būsimą laivo manevrą.
3. Pasiūlyti ir eksperimentiškai ištirti metodai, skirti aptikti nukrypimą (anomaliją) nuo planuoto arba prognozuojamo maršruto į tam tikrą uostą.
4. Disertacijoje pateikiamas naujas kompleksinis atraminiais vektoriais ir sprendimo medžiais grindžiamas mašininio mokymosi metodas, paremtas kontekstine informacija grindžiamu būsimo posūkio taško prognozavimu ir vertinimu. Ši prognozė vertinama siekiant įspėti apie neįprastą situaciją dar nesant jos požymių. Tai ypač svarbu norint užtikrinti saugią laivybą. Metodas skirtas darbui su realiojo laiko laivybos navigacijos duomenimis.

1.6. Praktinė darbo reikšmė

Šiuo metu informaciją, kuri reikalinga užtikrinti saugiai laivybai, turi apdoroti ir įvertinti už laivo saugumą atsakingas asmuo. Esamos kompiuterinės sistemos naudojamos tik palengvinti navigacinės informacijos keitimuisi tarp laivybos dalyvių ir (arba) užtikrinti navigacinės informacijos vizualizavimui. Esant tiesioginio susidūrimo pavojui, tokios kompiuterinės sistemos perspėja laivavedį, tačiau šis perspėjimas paremtas laivų judėjimo krypties vektorių apskaičiavimu. Gilesnė analizė apie situaciją nėra atliekama kompiuterinėmis sistemomis. Todėl saugiai laivybai užtikrinti sprendimus visada priima atsakingas asmuo. Vis dėlto žmogiškasis faktorius yra viena iš pagrindinių nelaimingų atsitikimų jūroje priežasčių. Esant šiuolaikiniam laivybos intensyvumui, nebepakanka vien esamų technologinių sprendimų, skirtų tik laivybos navigacijos informacijai vaizduoti. Pasiūlyti metodai kompleksiskai sprendžia saugios laivybos užtikrinimo problemą. Naudojant pasiūlytus metodus galima išspręsti navigacijos duomenų analizės ir

sprendimo priėmimo paramos uždavinius. Šie uždaviniai dėl autonominių laivų kūrimo poreikio tampa ypač aktualūs.

1.7. Ginamieji teiginiai

Disertacijos ginamieji teiginiai:

- Pasitelkus mašininio mokymosi algoritmais grįstus metodus, galima:
 - prognozuoti stebimo laivo būsimus artimiausius posūkio taškus;
 - modeliuoti visą laivo maršrutą į paskirties uostą;
 - įvertinti, ar yra neįprastai judančių laivų bendrame laivybos sraute ir tam tikrą paskirties uostą bei juos identifikuoti.
- Pasitelkus kontekstinę informaciją ir sujungus mašininio mokymosi grįstus metodus galima ne tik kompleksiskai prognozuoti stebimo laivo būsimą artimiausią posūkio tašką, bet ir įvertinti to laivo būsimą manevrą atsižvelgiant į kontekstinius duomenis, bei jį įvertinti įvairių laivybos dalyvių atžvilgiu.

1.8. Darbo rezultatų aprobavimas

Pagrindiniai tyrimo rezultatai pristatyti tarptautinėse bei respublikinėse konferencijose.

Pranešimai skaityti šiose tarptautinėse konferencijose:

1. Databases and Information Systems: 12th International Baltic Conference, DB&IS 2016, Riga, Latvia, July 4-6, 2016.
2. The 61TH international scientific conference of Riga technical university: IEEE Section of Information Technology and Management Science, Riga, Latvia, October 15-16, 2020.
3. WorldCist'21 - 9th World Conference on Information Systems and Technologies, in Terceira Island, Azores, Portugal, 30-31 March to 1-2 April 2021.

Straipsniai recenzuojamuose mokslo žurnaluose, referuojamuose „Web of Science Clarivate Analytics“ ir turinčiuose citavimo rodiklį:

4. Jakovlev, S., Andziulis, A., Daranda, A., Voznak, M., & Eglynas, T.: Research on ship autonomous steering control for short-sea shipping problems. *Transport*, 32, 2, 198–208, 2017. <https://doi.org/10.3846/16484142.2017.1286521>

5. Daranda A., Dzemyda G.: Navigation decision support: discover of vessel traffic anomaly according to the historic marine data. *International Journal of Computers Communications & Control*, 15, 3, 2020. ISSN 1841-9844.
<https://doi.org/10.15837/ijccc.2020.3.3864>.
6. Daranda A., Dzemyda G.: Novel machine learning approach for self-aware prediction based on the contextual knowledge. *International Journal of Computers Communications & Control*. 2021 (Accepted).

Straipsniai recenzuojamuose mokslo žurnaluose, referuojamuose „Web of Science Clarivate Analytics“:

7. Daranda A.: Neural network approach to predict marine traffic. *Baltic J. Modern Computing*, 4, 483–495, 2016.

Straipsniai recenzuojamuose tarptautinių konferencijų mokslo darbuose :

8. Daranda A., Dzemyda G: Artificial intelligence based strategy for vessel decision support system. In: *Proceedings of the WorldCist'21 - 9th World Conference on Information Systems and Technologies*, Terceira, pp. 49–58, 2021.
9. Jakovlev S., Daranda A., Voznak M., Lektuers A., Eglynas T., Jusis M.: Analysis of the possibility to detect fake vessels in the automatic identification system. In: *2020 61st International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS)*, IEEE, pp. 1–5, 2020.

Pranešimų santraukos konferencijų leidiniuose:

10. Daranda, Andrius; Dzemyda, Gintautas: A Marine Traffic Prediction using Recurrent Neural Networks, *9th International workshop on Data Analysis Methods for Software Systems (DAMSS)*, Druskininkai, Lithuania, November 30 - December 2, 2017. Vilnius: Vilniaus universitetas, 2017. ISBN 9789986680642. p. 14-15.

1.9. Disertacijos apimtis ir struktūra

Darbą sudaro įvadas, trys skyriai, išvados, literatūros sąrašas, autoriaus publikacijų disertacijos tema sąrašas.

Įvade pateikiami tyrimų sritis, objektas, darbo tikslas ir uždaviniai, tyrimų metodai, mokslinis darbo naujumas, praktinė darbo reikšmė, ginamieji teiginiai.

Pirmame skyriuje aptariamas pasirinktos temos aktualumas ir bendra problematika. Pateikiami laivyboje naudojamų metodų aprašymai ir algoritmai, skirti saugiai laivybai užtikrinti. Eksperimentiškai įvertinami tų algoritmų taikymo ribotumai.

Antrame skyriuje pateikiamas stebimo laivo būsimo artimiausio posūkio taško prognozavimo metodas, paremtas dirbtiniu neuroniniu tinklu, ir tiriamas jo taikymas modeliuojant laivo judėjimą. Taip pat pateikiamas metodas įvertinti, ar yra neįprastai judančių laivų bendrame laivybos sraute į tam tikrą paskirties uostą ir juos identifikuoti.

Trečiame skyriuje aprašomas mašininis mokymusi grindžiamas metodas, gebantis prognozuoti stebimo laivo būsimą artimiausią posūkio tašką ir įvertinti to laivo būsimą manevrą atsižvelgiant į kontekstinius duomenis.

Disertacijos apimtis: 116 puslapių, 1 lentelė, 53 iliustracija ir 1 priedas. Disertacijoje remtasi 138 literatūros šaltiniais.

2. METODAI, SKIRTI UŽTIKRINTI SAUGIĄ LAIVYBĄ

Šiame skyriuje pateikiama analitinė laivyboje naudojamų technologijų ir maršruto paieškos / planavimo algoritmų apžvalga. Šio skyriaus medžiagos dalis yra publikuota [3], [4].

2.1. Laivybos saugumas ir grėsmės

Laivyba vystoma nuo seniausių laikų. Saugiai laivybai užtikrinti naudojamos įvairios technologijos. Nepaisant šiuolaikinės kompiuterizacijos, viena iš patikimiausių ir seniausių technologijų yra vizualinės priemonės – orientavimasis naudojant plūdūrų ir šviesų sistemą. Vizualinės priemonės užtikrina aiškų ir patikimą informacijos pateikimą, informacijos perdavimą pagal bendras taisykles. Tačiau vizualinėms priemonėms apdoroti ir analizuoti nėra kuriamos kompiuterinės sistemos. Vizualinių ženklų apdorojimas – per daug sudėtingas uždavinys spręsti automatizuotais metodais, pavyzdžiui, reikia atskirti judančio laivo navigacijos šviesas ir įvertinti tų šviesų poslinkį kitų tokių pat šviesų fone, kaip, pavyzdžiui, apšviestas uostas. Tai atlikti gali tik laivavedys, turintis patirties ir atitinkamų žinių. Naujesnės technologijos, tokios kaip GPS (angl. *Global Positioning System*) ir AIS (angl. *Automatic Identification System*), perduoda skaitmeninę informaciją apie laivo padėtį, judėjimą ir papildomą informaciją [5], [6], [7]. Šie duomenys apdorojami ir gali būti atvaizduojami ECDIS – elektroninių jūrlapių vaizdavimo ir informacijos sistemoje (angl. *Electronic Chart Display and Information System*).

Tačiau laivyboje naudojamos technologijos yra riboto taikymo. Pagrindinės problemos:

1. Labai didelė stebima teritorija;
2. Didelis laivybos eismo dalyvių skaičius;
3. Triukšmingas, iškreiptas radijo signalas;
4. Geografiniai apribojimai perduodamo radijo signalo sklidimui.

Šioms problemoms spręsti pradėti naudoti palydovai [8], [9], [10]. Tačiau šią technologiją dažniausiai naudoja tik laivų stebėjimo tarnybos VTC (angl. *Vessel Traffic Center*).

Analizuoti laivybą saugumo aspektu svarbu ne tik dėl galimų susidūrimų, bet ir dėl piratų bei terorizmo pavojaus. Piratai nėra išnykęs reiškinys įvairiose pasaulio vietose ir šiais laikais. Piratai ypač išsiskynę ties Somalio krantais, Indijos vandenyne ir pietryčių Azijoje [11], [12], [13], [14].

Žinoma, laivyba taip pat plačiai naudojama ne tik piratų, bet ir kitokio pobūdžio neteisėtai veiklai: žvejybai, draudžiamoms medžiagoms gabenti ir

nelegaliai žmonių migracijai [15], [16], [17]. Laivybos stebėjimas, anomalijų arba neįprastos veiklos aptikimas ir neteisėtų veiklų užkardymas – labai svarbūs valstybių ekonomikai.

Saugus laivų manevravimas – imperatyvus uždavinys. Tačiau nepaisant technologinės pažangos, didelę grėsmę kelia laivų susidūrimai [18]. Atlikus detalią įvykusių avarijų analizę išsiaiškinta, kad pagrindinė avarijų priežastis – žmogiškasis faktorius [19], [20], [21]. Ši problema sprendžiama dviem pagrindinėmis kryptimis:

1. Sistemų, skirtų laivavedžiui pagelbėti, kūrimas;
2. Eliminuojamas žmogiškasis faktorius.

Saugiai laivybai užtikrinti sukurti ir pritaikyti įvairūs metodai [22], [23], [24], [25], [26], tačiau pagrindinės technologijos išlieka tos pačios: radiolokacinės navigacijos sistema, radiolokacinio žymėjimo ir automatinio radiolokacinio žymėjimo sistema (ARPA – *Automatic Radar Plotting Aid*), elektroninių jūrlapių vaizdavimo ir informacijos sistema (ECDIS – *Electronic Chart Display and Information System*) ir t. t.

Žmogiškajam faktoriui eliminuoti yra kuriamos autonominės sistemos (angl. *Autonomous Surface Vehicle*), skirtos saugiam laivo valdymui [27], [28], [29]. Tokių sistemų kūrimas yra labai svarbus laivybos vystymuisi, nes padeda išspręsti daug šiuo metu aktualių problemų, kaip pavyzdžiui:

- Laivų įgulos komplektavimas;
- Maksimali laivų išplaukimo trukmė;
- Projektavimo ir eksploatavimo kaštų sumažinimas;
- Galimybė gauti didesnę krovinių kiekį, sumažinant gyvenamąsias patalpas.

Autonominis laivų valdymas galėtų išspręsti šiuo metu aktualias problemas, tačiau tokių sistemų kūrimas susiduria su teisiniu reglamentavimu [30] ir techninėmis problemomis [31]. Šiuo metu vystoma daug su autonominiu laivų valdymu susijusių projektų: įmonė „Rolls–Royce“ pristatė autonominės laivybos AWA koncepciją [32], „Yara Birkeland“ pristatė autonominį elektra varomą laivą [33], Europos Sąjungos „MUNIN“ projektas [34] ir „DIMECC“ konsorciumo projektas [35], kurio planuojama įgyvendinimo pabaiga – 2025 metais. Tačiau iki visiškai funkcionuojančio autonominio laivo sukūrimo dar toli.

Lietuvoje, taip pat kaip ir užsienyje, yra aktuali saugios laivybos tema. Lietuvoje įvairiomis kryptimis atliekami tyrimai, susiję su saugios laivybos klausimais. Ši tema yra svarbi, siekiant užtikrinti darnų laivų judėjimą Klaipėdos uoste ir Baltijos jūroje. Pastaruoju metu skiriamas vis didesnis dėmesys laivybos apimčių didėjimui, todėl ir saugios laivybos svarba tapo itin

reikšminga. Laivybos saugumas nagrinėjamas straipsniuose [36], [37]. Laivybos sraute esančių anomalijų aptikimas aprašomas straipsniuose [38], [39]. Jūros maršrutų aptikimas, nustatymas, planavimas tirtas straipsniuose [40], [41], o laivų įgulų pervargimas – [42], [43].

2.2. Technologijos saugiai laivybai užtikrinti

Sistemos, skirtos laivavedžiui pagelbėti valdant laivą, pagrįstos dviem pagrindiniais principais:

1. Radiolokacija – skirta nustatyti kitų laivų, objektų padėtį radijo siųstuvo atžvilgiu;
2. Globali pozicionavimo sistema (GPS) – skirta nustatyti savo padėtį žemės atžvilgiu.

Radiolokacinis metodas pagrįstas radijo bangų atspindėjimo savybėmis. Radaras siunčia radijo bangų signalą ir pagal atspindėtą nuo objekto signalą apskaičiuojamas atstumas bei kryptis iki objekto. Šis paprastas veikimo principas pritaikomas aptikti laivams ir bet kokioms kitoms kliūtims, pavyzdžiui, kranto linijai nustatyti. Radaro technologija yra paremta ir ARPA sistema (angl. *Automatic Radar Plotting Aid* – automatinio radiolokacinio žymėjimo sistema), kuri geba automatiškai pažymėti objektus, nuo kurių atspindėtas radijo signalas, apskaičiuoti to objekto judėjimo parametrus ir įspėti laivavedį apie galimą pavojingą situaciją.

Tačiau radaro technologija turi ir nemažai trūkumų:

1. Radaras yra pagrįstas analoginio signalo laiko skleidimo apskaičiavimu. Radijo signalas išspinduliuojamas ir atstumas iki objekto apskaičiuojamas pagal signalo sugrįžimo laiką.
2. Radaro technologija nėra skirta objekto tipui nustatyti. Taip yra dėl to, kad sugrįžęs signalas yra vienodas – atspindėtas tiek nuo laivo, tiek nuo bet kokio kito objekto. Todėl laivams identifikuoti, įvertinus sugrįžusį radiolokacinį signalą, kuris atvaizduojamas ekrane, reikalinga radiolokacinių sistemų naudojimo patirtis. Tai yra priežastis, lemianti tokio pobūdžio informacijos analizavimo kompiuterinėmis sistemomis sudėtingumą.
3. Tiksliam radaro darbui trukdo gamtos sąlygos. Pavyzdžiui, esant lietingam orui, radaras gali fiksuoti ir atvaizduoti debesis radaro ekrane, o laivavedžiui dėl to sunkiau analizuoti bendrą situaciją.

Kita svarbi technologija, skirta pagelbėti laivavedžiui saugiai valdyti laivą, yra vietos pozicionavimo sistemos. Pagrindinė vietos pozicionavimo sistemos paskirtis – nustatyti imtuvo koordinatas specialiais palydovais. Sistemos veikimas pagrįstas signalo sklaidimo nuo palydovų iki imtuvo laiko

skirtumų trianguliacijos būdu. Šios sistemos ištakos siekia 1960 m., kai ją sudarė 5 palydovai. Šiais laikais koordinacių nustatymo palydovinių sistemų yra ne viena. Tokiu pačiu principu veikia ir įvairios pozicionavimo sistemos:

1. GPS – JAV sukurta sistema;
2. BeiDou – Kinijos sukurta sistema;
3. Galileo – Europos Sąjungos sukurta sistema
4. Quasi-Zenith – Japonijos sukurta regioninė sistema;
5. GLONASS – Rusijos Federacijos sukurta sistema.

Šių sistemų veikimo principas yra vienodas. Palydovai siunčia radijo pranešimą (savo koordinates, tikslų laiką ir identifikavimo kodą) į žemę, o imtuvas pagal gautus duomenis apskaičiuoja esamą padėtį, aukštį virš jūros lygio, greitį ir judėjimo kryptį. Apskaičiuotą informaciją nesunku apdoroti kompiuteriu ir pateikti vizualinei analizei per ECDIS. Taip pat didelis GPS privalumas, lyginant su radiolokaciniu metodu, yra tas, kad GPS gali veikti bet kokiomis oro sąlygomis ir metų laikais.

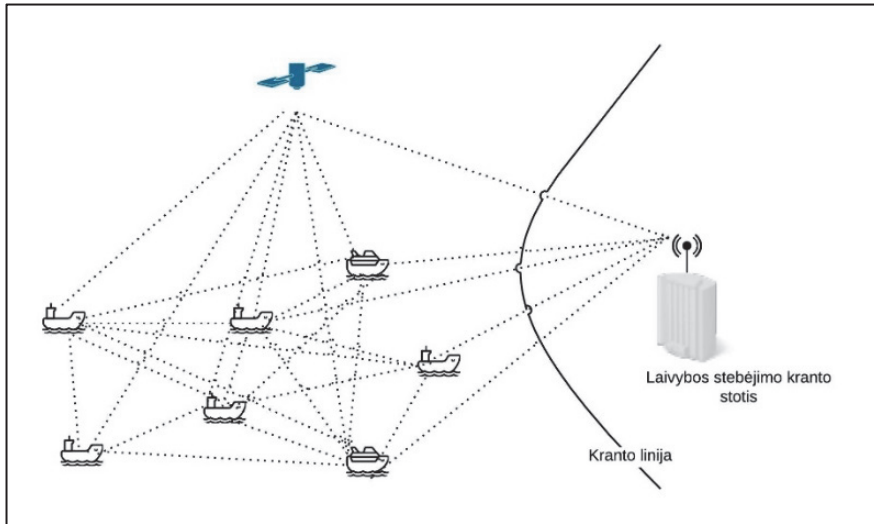
2.3. Automatinė laivų identifikavimo sistema

Viena iš šiuolaikiškiausių ir pagrindinių sistemų, skirtų laivavedžiui pagelbėti valdyti laivą, yra Automatinė identifikavimo sistema (angl. *Automatic Identification System*) (AIS). AIS pagrindinė paskirtis – užtikrinti saugią laivybą, vykdyti laivybos stebėjimą, padėti analizuoti ir stebėti laivų judėjimą uosto ir kitoms tarnyboms [44], [45], [46]. Pagrindiniai sistemos reikalavimai yra nurodyti Tarptautinėje konvencijoje dėl žmogaus gyvybės apsaugos jūroje (angl. *Safety of Life at Sea*). Ši sistema skirta išspręsti radiolokacinės technologijos trūkumus. AIS patikimesnė už radiolokacinę sistemą, kadangi:

1. Sistema autonominė, informacija automatiškai siunčiama (priimama) AIS imtuvo aprėpties zonoje;
2. Sistema skaitmeninė, lengvai pritaikoma duomenų vizualizavimui ir analizavimui;
3. Mažesnis oro sąlygų bei metų laikų poveikis signalo perdavimui bei jo kokybei;
4. Perduodami duomenys daug tikslesni, nes naudojama GPS technologija, taip pat papildomą informaciją įveda operatorius;
5. Yra galimybė perduoti papildomus duomenis, pavyzdžiui: paskirties uostą, krovinio tipą ir t. t.

AIS patikimumas užtikrinamas autonominiu ir pastoviu informacijos perdavimu radijo bangomis labai aukštų dažnių juostoje (angl. *Very High Frequency*) (VHF). Dėl šio proceso perduodama informacija ribojama


fizikinėmis radijo bangų savybėmis – signalo sklaidimo riba tarp 20–60 km, priklausomai nuo hidrometeorologinių ir geografinių vietovės sąlygų. Informacijai paskirstyti naudojama TDMA (angl. *Time Division Multiple Access*) technologija (1 pav.) [47]. AIS privalomai įdiegta ir naudojama daugiau kaip 400000 laivų pasaulyje.



1 pav. AIS veikimo principas

Tačiau AIS yra labai svarbi, nes geba priimti duomenis ir iš kitų laivo navigacijos prietaisų. Su AIS gali būti sujungti tokie prietaisai kaip GPS, girokompasas, vairo pasukimo kampo daviklis ir t. t. Šių prietaisų realiojo laiko informacija taip pat perduodama aprėpties zonoje esantiems laivams.

Laivybos stebėjimą naudojant AIS vykdo uosto ir pakrančių tarnybos. Laivai, esantys už radijo bangų sklaidimo ribos, gali būti stebimi nano palydovais [48], [49]. Laivybos tankumas Šiaurės jūroje pagal AIS pateiktas 2 pav. Įvairios pagalbinės sistemos, priemonės sukurtos remiantis AIS technologija [50], [44], [46].



2 pav. Laivybos tankumas Šiaurės jūroje

2 paveiksle spalvomis žymimas laivybos srautų intensyvumas. Intensyviausi laivybos srautai pažymėti raudona spalva, mažiau intensyvūs – žalia, o mėlyna spalva žymimi laivybos maršrutai, kuriais laivai plaukia retai. Pilka spalva – labai mažas laivų intensyvumas. Analizuojant raudonos ir žalios spalvos žymėjimus, galima išskirti laivų maršrutus į tam tikrus uostus.

2.4. Sprendimų priėmimas laivyboje

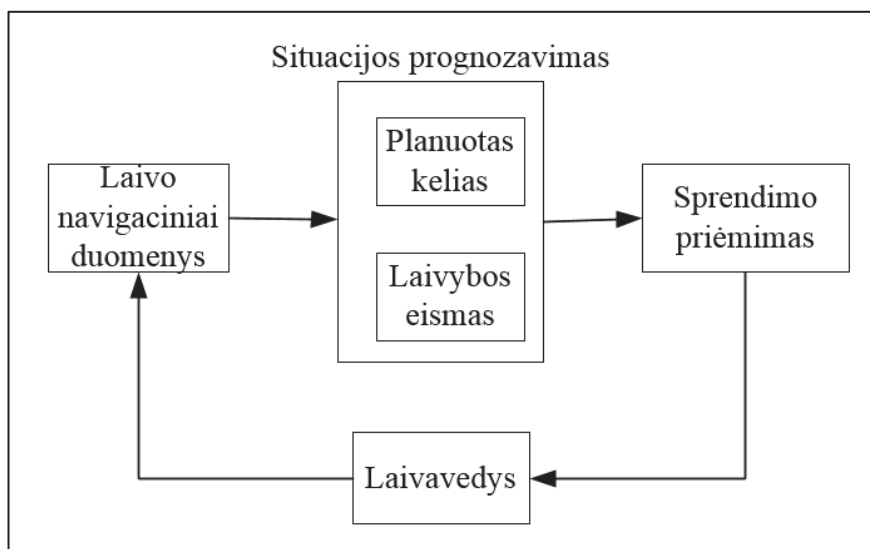
Nepriklausomai nuo turimos laivavedžio patirties, sprendimų priėmimas visada yra sudėtingas procesas, kuris vyksta tam tikra tvarka, pasirenkant tinkamiausią, optimaliausią ar kompromisinį sprendimo variantą. Laivui manevruojant, atsakingas už sprendimo priėmimą yra budintis laivavedys. Dinamiška laivybos aplinka bei kintantys veiksniai daro įtaką sprendimo priėmimui. Sprendimas vertinamas konkrečiu atveju ir negali būti pagrįstas prielaidomis, kad prieš tai buvę sprendimai yra tinkami ateities prognozėms. Todėl sprendimo priėmimas kiekvienu atveju parenkamas pagal konkrečią, visiškai išanalizuotą situaciją. Sprendimo priėmimo modeliai išanalizuoti [51], [52], [53], [54] straipsniuose. Atsižvelgiant į pasiūlytus sprendimo

priėmimo modelius galima teigti, kad laivavedys konkrečiu atveju gali taikyti skirtingą arba kombinuotą sprendimo priėmimo modelį:

1. Geriausios alternatyvos paieška – sprendimas pagrįstas racionaliū pasirinkimu tarp skirtingų alternatyvų;
2. Ekonomiškai naudingiausio sprendimo paieška – sprendimas grindžiamas sąnaudų skaičiavimu;
3. Algoritmiškai efektyvaus sprendimo paieška – sprendimas grindžiamas taikant iš anksto nustatytas taisykles efektyviam sprendimui rasti;
4. Riboto sprendimo paieška, atsižvelgiant / kontaktuojant su kitais laivybos dalyviais;
5. Alternatyva, skirta momentinės situacijos sprendimui;
6. Riboto sprendimo paieška, neatsižvelgiant į priežasties ir pasekmės ryšį.

Sprendimo priėmimo sudėtingumui įtakos turi ir ribotas laikas, skirtas sprendimui priimti. Kiekvienas priimtas sprendimas turi būti gerai pagrįstas, kadangi jo koregavimo galimybės ribotos. Svarią įtaką tam daro dideli laivų dydžiai ir fizinės jų savybės. Todėl labai svarbu, kad teisingas sprendimas būtų priimtas laiku ir nedelsiant. Svarbu ir tai, kad sprendimas kartais turi būti suderintas ir su kitais laivybos dalyviais, nes visi dalyviai sprendimus turi suprasti vienodai bei įgyvendinti koordinuotai.

Sprendimų priėmimo problematika ir teisingus sprendimus lemiantys faktoriai plačiai analizuojami įvairiuose darbuose. Yra parašyti tiriamieji darbai apie sprendimo priėmimo specifiką jūroje [55], [56], [57], [58].



3 pav. Principinė sprendimo priėmimo schema

Laivavedys, priimdamas optimalų sprendimą (3 pav.), privalo atsižvelgti į:

1. Koks yra suplanuotas kelias ir stengtis kuo mažiau nukrypti nuo suplanuoto kurso;
2. Laivybos situaciją, kiek prasilenkiama su kitais laivais ar objektais.

Optimalus sprendimas balansuoja tarp saugaus prasilenkimo ir kuo mažesnio nukrypimo nuo suplanuoto maršruto. Pasirinkus ne optimalų sprendimą, tiek nukrypstant nuo maršruto, tiek arti (nesaugiai) prasilenkiant su kitu laivu, pavyzdžiui, darant staigius posūkius, sugaištama laiko ir stipriai didėja laivo eksploataciniai kaštai.

Optimalaus sprendimo priėmimui didžiausią įtaką daro žmogiškasis faktorius. Laivavedžio priimtiems sprendimams itin svarbų poveikį turi jo įgyta (turima) patirtis, paros ar metų laikas, oro sąlygos ir pan. Dažnai laivo reisas gali trukti nuo kelių savaitių iki devynių mėnesių. Todėl priimant sprendimus įtaką ypač daro tokie veiksniai kaip nuovargis, išsiblaškymas, užsiėmimas pašaliniais reikalais ir t. t., kurie lemia neteisingus ir (ar) pavėluotus sprendimus.

2.5. Maršruto paieškos ir susidūrimo išvengimo algoritmai

Laivo maršruto planavimas yra sudėtingas uždavinys. Maršruto planavimas bendrai formuluojamas kaip trumpiausio atstumo tarp dviejų taškų radimas. Tačiau dažnai pasitaiko taip, kad trumpiausias atstumas nėra saugus ar tinkamiausias atsižvelgiant į įvairius faktorius. Todėl planuojant maršrutą, privaloma atsižvelgti į, pavyzdžiui, laivo ir krovinio tipą, pavojingas kliūtis, laivo manevrines savybes, orų prognozes ar netgi į karinius konfliktus plaukimo maršrute.

Saugaus laivo manevravimo problema aktuali ne tik laivams, bet ir laivų stebėjimo tarnyboms. Labai svarbu laiku numatyti arba užkardyti galimas avarines situacijas [59] ar avarijas uostų ribose [60], [61]. Įvykus avarijai jūrų uoste gali būti paralyžiuota viso uosto veikla, o tai lemtų labai didelius nuostolius. Šiuo metu ši problema sprendžiama locmanų tarnyba – uoste privaloma užsisakyti laivo įvedimo (išvedimo) paslaugą. Užsisakius šią paslaugą į laivą atvyksta locmanas – uosto atstovas (patyręs jūrininkas). Gerai pažįstantis uostą locmanas suteikia patarimų laivavedžiui, kaip užtikrinti saugią navigaciją iki pat švartavimosi krantinės arba iki kol laivas išplauks iš uosto ir atitols saugiu atstumu.

Maršruto paieška – grafų teorijos uždavinys. Šio tipo algoritmai skirstomi į du pagrindinius tipus: deterministiniai ir tikimybiniai. Optimalaus

maršruto paieška svarbi ne tik transporto sričiai, bet ir kitoms sritims: logistikos, robotikos, infrastruktūros bei mikroschemų projektavimo ir t. t.

Optimalaus maršruto paieškai sukurta daug įvairių algoritmų, kurie skirstomi į dvi pagrindines grupes:

1. Euristiciniai;
2. Tikimybiniai.

Visi šie algoritmai turi ir privalumų, ir esminių trūkumų. Pagrindinis šių algoritmų trūkumas yra tas, kad ieškoma ne optimalaus maršruto, o tokio, kuris būtų trumpiausias pagal atstumą ir laiką, arba tokio, kuriam reikėtų mažiausiai energijos išteklių. Šis apskaičiuotas maršrutas išreiškiamas konkrečių veiksmų seka, dėl kurių pasiekiamas galutinis taškas. Atsižvelgiant į pasirinktą algoritmą gali būti atliekami įvairūs tarpiniai skaičiavimai, siekiant išvengti maršrute esančių kliūčių.

Tačiau realybėje optimalaus maršruto paieška yra kur kas sudėtingesnis procesas. Vien apskaičiuoti galimą maršrutą, pasitelkus maršruto paieškos algoritmą, nepakanka. Būtina atsižvelgti ir į kitus faktorius, norint užtikrinti kompleksiskai saugų maršrutą. Pritaikius maršruto paieškos algoritmą maršrutui planuoti, būtina įvertinti tą aspektą, kad panaudojus pasirinktą maršruto paieškos algoritmą, bus ne tik išspręstas maršruto radimo uždavinys, bet ir pavyks nustatyti, ar algoritmo sudarytas maršrutas tinkamas praktiniam panaudojimui.

2.6. Maršruto planavimo algoritmai

Laivų maršrutui planuoti ir laivų susidūrimams išvengti yra taikomi įvairūs maršruto planavimo algoritmai: dinaminio žaidimo teorijos algoritmas (angl. *Dynamic Games Theory*) [62], dinaminio programavimo metodas (angl. *Dynamic Programming*) [63], labirinto kelio radimo algoritmas (angl. *Maze Routing Algorithm*) [64], greito žygiavimo metodas (angl. *Fast Marching Method*) [65], genetinis algoritmas (angl. *Genetic Algorithm*) [66] [67], kooperatyvus maršruto planavimo algoritmas (angl. *Cooperative Path Planning Algorithm*) [68], dirbtinių potencinių laukų algoritmas (angl. *Artificial Potential Field*) [69], neraiškiosios logikos algoritmas (angl. *Fuzzy Logic-Based*) [70], evoliuciniai algoritmai (angl. *Evolutionary Algorithms*) [71] ir skruzdžių kolonijos algoritmas (angl. *Ant Colony Optimization*) [72].


Vienas iš populiariausių algoritmų laivų maršrutams planuoti yra dinaminio lango algoritmas (angl. *Dynamic Window Approach*) [73]. Šis algoritmas išsiskiria tuo, kad geba planuoti maršrutą ir atnaujinti suplanuotą maršrutą siekiant išvengti susidūrimo su kitais laivais, esančiais tarp pradinės padėties ir tikslo taško [74], [75], [76]. Šis algoritmas taip pat plačiai taikomas

ir kitiems panašioms uždaviniais spręsti, pavyzdžiui, mobiliems robotams kurti ir eksperimentuoti su jais [77]. Skirtingai nei kiti maršruto planavimo algoritmai, šis algoritmas naudoja duomenis atsižvelgiant į dinaminį laivo ir kliūčių judėjimą. Dėl šių galimybių dinaminio lango algoritmas ypač tinkamas autonominių laivų valdymo sistemai kurti [78], [79], [27], [80], [81].

Dinaminio lango algoritmas susideda iš dviejų dalių:


1. Generuoja efektyvią paieškos erdvę;
2. Pasirenkamas optimalus sprendimas, atsižvelgiant į paieškos erdvę.

Paieškos erdvė yra apribota saugia apsisukimo erdve. Saugi erdvė – tai tokia erdvė, kuri yra artimiausia laivui per trumpą laiką ir yra saugi. Optimalaus sprendimo tikslas yra pasirinkti tokį judėjimą (kryptį ir greitį) į tikslą, kuris užtikrintų maksimalų atstumą nuo esamų kliūčių.



4 pav. Sėkmingas dinaminio lango algoritmo pritaikymas

4 paveiksle pavaizduota, kaip objektas startuoja iš pradinio taško, pažymėto raudona spalva ((a) dalis). Žaliais taškais pavaizduotas maršrutas, kuriuo judėjo objektas. Objekto tikslas – saugiai pasiekti tikslą, pažymėtą mėlynu simboliu \times . Naudojantis dinaminio lango algoritmu, suplanuojamas saugus maršrutas, kuris sudaromas atsižvelgiant į saugų atstumą nuo esamų kliūčių. Aplenkus kliūtis, esančias tarp pradinio taško ir tikslo (kliūtys pažymėtos juodais taškais), pasiekiamas tikslas – mėlynas simbolis \times , kaip pavaizduota 5 pav. b) dalyje. Eksperimentai su dinaminio lango algoritmu atlikti pritaikius biblioteką [82].




5 pav. Nesėkmingas dinaminio lango algoritmo pritaikymas

Tačiau esant sudėtingesnei situacijai – atsiradus papildomoms kliūtims (5 pav.), algoritmui sėkmingai nepavyksta suplanuoti maršruto ir objektas judėdamas nebesiekia kelionės tikslo, kuris yra pažymėtas raudonu simboliu \times . Objektui saugiai aplenkus esamas pavojingas kliūtis, dinaminio lango algoritmas priima sprendimą pasukti ne į tikslo tašką, o „kilti“ į viršų. Toks judėjimas vyksta priešinga kryptimi nei yra tikslo taškas \times , algoritmas nebekeičia judėjimo krypties link tikslo ir judėdamas toliau ta pačia kryptimi saugiai tolsta nuo esamų kliūčių. Šiuo atveju dinaminio lango algoritmas nebeišsprendžia maršruto planavimo, nes objektas tolsta nuo tikslo taško – optimizuojant didinamas atstumas iki esamų kliūčių.

Kitas nagrinėjamas maršruto paieškos algoritmas, kuris plačiai taikomas maršrutams planuoti bei autonominių laivų valdymo sistemoms kurti [83], [84], [85], [86] yra dirbtinio potencinio lauko algoritmas.

Dirbtinio potencinio lauko algoritmas užpildo erdvę dirbtiniu potenciniu lauku, pradinis ir tikslo taškas išreiškiamas priešingu elektros krūviu, o kliūtys – tuo pačiu elektros krūviu. Taip pat kaip ir su elektriniu lauku, objektai su priešingais krūviais traukia vienas kitą, o su vienodais – atstumia vienas kitą. Tokiu būdu objektas juda iš pradinio taško link priešingo krūvio – tikslo taško. Kliūtys yra aplenkiamos, nes turi tokį patį krūvį kaip ir iš pradinio taško pajudėjęs objektas.



6 pav. Potencinio lauko algoritmo pritaikymas

Pritaikius dirbtinio potencinio lauko algoritmą įrankiu *PythonRobotics* [82], 6 pav., a) dalies situacijai, objektas sėkmingai pasiekia tikslą, aplenkdamas kliūtis. Tačiau pasunkinus situaciją ir pridėjus papildomą kliūtį, dirbtinio potencinio lauko algoritmas „užstringa“ ir nebegali pasiekti tikslo taško, kaip pavaizduota 6 pav., b) dalyje. Šiuo atveju potencinio lauko algoritmas, kaip ir dinaminio lauko algoritmas, nebeišsprendžia maršruto planavimo uždavinio.

2.7. Sustiprinto mokymosi algoritmas

Pastaraisiais metais vis labiau populiarėja sustiprinto (skatinamojo) mokymosi algoritmai, kurie pagrįsti mašininio mokymosi [87]. Tokių sustiprinto mokymosi algoritmų paskirtis valdyti įvairius įrenginius ar objektus. Yra atlikta įvairių eksperimentų siekiant pritaikyti tokius algoritmus laivams valdyti, maršrutams planuoti ar laikytis jau suplanuoto maršruto [88], [89], [90]. Tačiau toliau aprašyti eksperimentai parodo šių algoritmų taikymo ribotumus.

Gilusis sustiprinto mokymosi algoritmas geba savaimė mokytis, t. y. be žmogaus pagalbos ir savarankiškai apsimoko ir pagal apsimokymą priima sprendimus. Tokio algoritmo pavyzdys yra Q -learning algoritmas [91]. Šis algoritmas mokosi iš gaunamos patirties – naudojamas klaidų ir skatinimų metodas. Algoritmas, pagrįstas veiksmo funkcija $Q(s, a)$, kuria apibūrinamas tolesnis veiksmas. Q -learning algoritmas moko Q funkciją pagal taisyklę:

$$Q(s, a) = (1 - \alpha) * Q(s, a) + \alpha * (r + \gamma * \max_{a'} Q(s', a')). \quad (1)$$

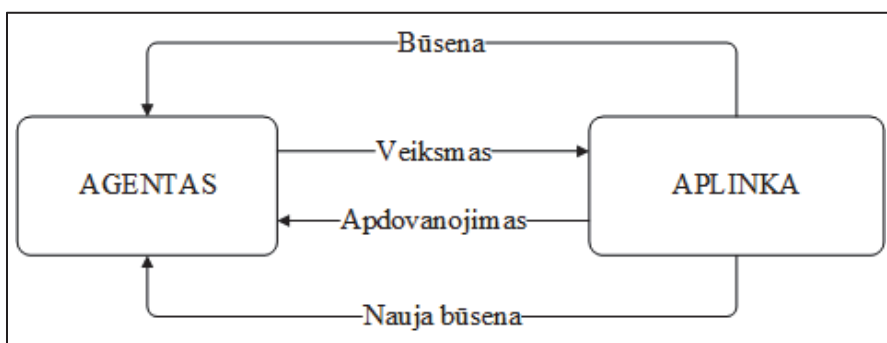
$Q(s, a)$ – funkcijos Q vertė;
 s – būseną;

a – veiksmas;
 α – mokymosi greičio koeficientas;
 γ – pasitikėjimo būsenos vertėmis koeficientas;
 s' – ateities būsena;
 a' – veiksmas būsenoje, turintis didžiausią Q reikšmę;
 r – paskatinimo vertė, kurios reikšmės priklauso nuo konkretaus iškelto uždavinio, gali būti tokios:

- a) 1 – sėkmingai pasiektas tikslas,
- b) 0 – nepasiektas tikslas, neužteko maksimalaus veiksmų skaičiaus,
- c) -1 – pasiektas tikslas, tačiau susidurta su kliūtimi.

Sprendžiant maršruto planavimo uždavinį, gilusis sustiprinto mokymosi algoritmas gali rinktis ir pritaikyti vieną iš šių veiksmų:


1. Į kairę;
2. Į dešinę;
3. Aukštyn;
4. Žemyn.



7 pav. Sustiprinto mokymosi algoritmo mokymosi schema


Q -learning algoritmas sustiprinto mokymosi metu sukuria aplinką, kurioje mokosi Q -learning algoritmo agentas (7 pav.). Mokymosi metu agentas priima sprendimus, remdamasis iš aplinkos gaunamais signalais – būsenomis. Eksperimento metu iš aplinkos gaunami atitinkami signalai, pagal kuriuos priimamas sprendimas numatytai strategijai įgyvendinti. Šiuo atveju būsena yra agento konkreti padėtis aplinkoje. Agentas kaupia būsenų sąrašą ir sprendimą, kurie atitinka veiksmą (į kairę, į dešinę, aukštyn ar žemyn), konkrečiai agento būsenai aplinkoje įvertinti. Pagal būsenos-veiksmo poras sukuriamas Q -lentelė, kuri yra skirta indeksuoti Q -reikšmę. Siekiant geresnių rezultatų, Q -lentelės duomenys panaudojami apmokant gilųjį neuroninį tinklą

(8 pav.) [87], [92]. Apmokymo metu agento būseną aplinkoje pateikiama neuroniniam tinklui. Neuroninis tinklas išveda Q -reikšmės veiksmo reikšmę.



8 pav. Gilaus sustiprinto mokymosi algoritmo schema

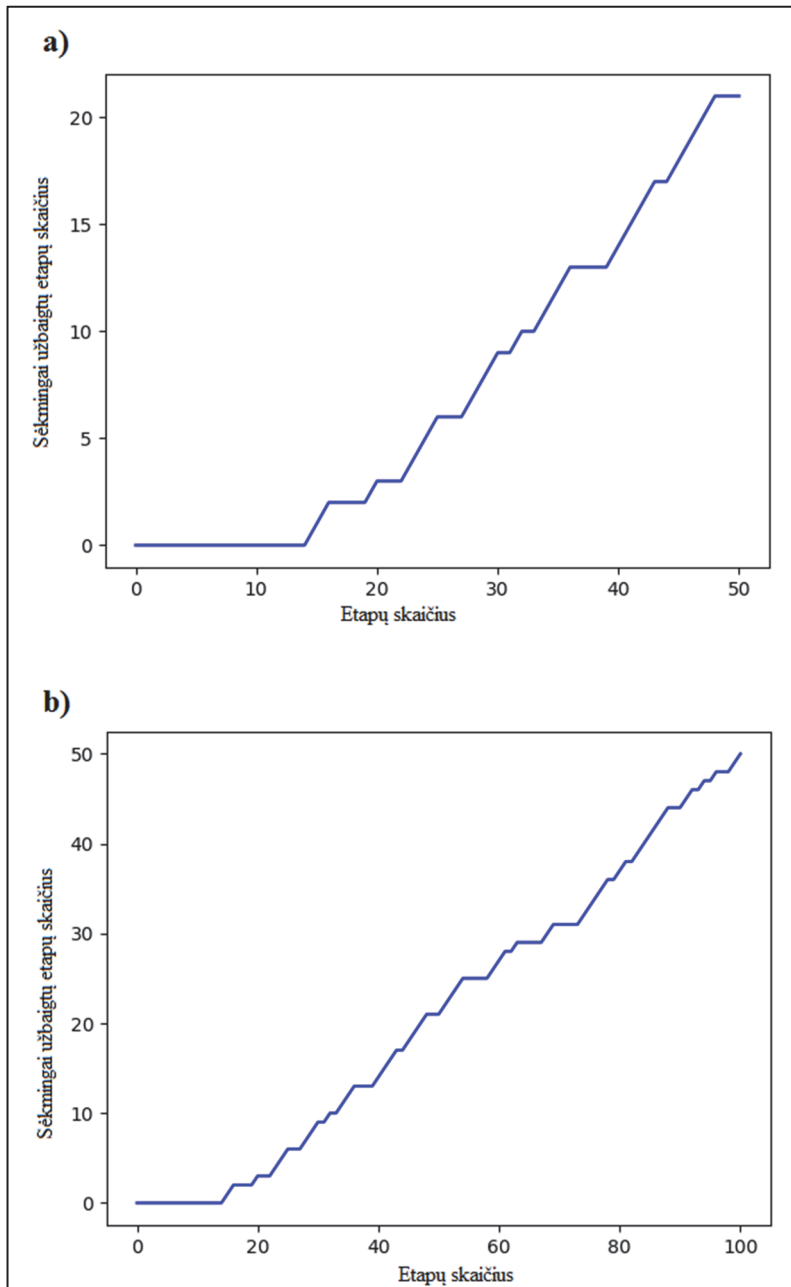
Eksperimentams su Q -learning algoritmu panaudotas *OpenAI* įrankis [93]. Sustiprinto mokymosi procesas susideda iš atskirų etapų. Kiekvienam etapui sukuriami laiku bėgant kintanti aplinka. Aplinkoje mokosi agentas, kuris atvaizduojamas mokymosi aplinkoje šešiakampiu. Pradinis taškas yra kairiajame viršutiniame kampe. Kliūtis (pažymėta rombu) padėtis aplinkoje ir judėjimo kryptis nustatoma atsitiktiniais parametrais ir stacionaria tikslo taško (kvadratas) padėtimi – apatinis dešinysis kampas (9 pav.).



9 pav. Sustiprinto mokymosi aplinka


Mokymosi proceso metu agento (rombas) tikslas – pasiekti tikslo tašką (kvadratas). Agentas privalo pasiekti tikslo tašką, nesusidurdamas su kliūtimi

(rombas). Siekiant išmokyti agentą pasiekti tikslo tašką, po susidūrimo mokymosi procesas nenutraukiamas, o tęsiamas tol, kol agentas pasiekia tikslo tašką arba yra viršijamas maksimalus galimų žingsnių skaičius – 25 žingsniai.



10 pav. Sustiprinto mokymosi progresas: a) 50 etapų; b) 100 etapų

10 pav. pavaizduotas sustiprinto mokymosi progresas. Sustiprinto mokymosi algoritmui besimokant, šis progresas vaizduoja sėkmingų etapų priklausomybę nuo bendro etapų skaičiaus. Pirmieji 15 etapų nėra sėkmingi, nes agentas visiškai nežino, kur yra tikslo taškas ir neturi duomenų apie esamą kliūtį. Po kelių etapų agentas randa tikslo tašką ir pradeda spartesnį optimizavimo / sustiprinto mokymosi procesą. Skaičiuojant mokymosi tikslumą, imamas sėkmingai užbaigtų etapų skaičius ir dalijamas iš viso etapų skaičiaus. Po 50 etapų agentas sėkmingai pasiekia tikslą 41,18 % atvejų, o po 100 etapų rezultatas tampa 49,5 %. Tai rodo, kad reikalingas didesnis etapų skaičius, kadangi nėra stebimas eksponentinis kitimas, kuris reikštų, kad sustiprinto mokymosi algoritmas perprato mokymosi aplinką ir dėl to reikšmingai didėja sėkmingų etapų skaičius.



11 pav. Apmokymo progresas iki 1500 etapų

Tešiant sustiprintą apmokymą iki 1500 etapų (11 pav.), agentas pasiekia tikslą 87,7 % atvejais skaičiuojant nuo visų etapų skaičiaus. Galima teigti, kad agentas sėkmingai išmoko pasiekti tikslo tašką ir išvengti kliūtis su sustiprinto mokymosi algoritmu.

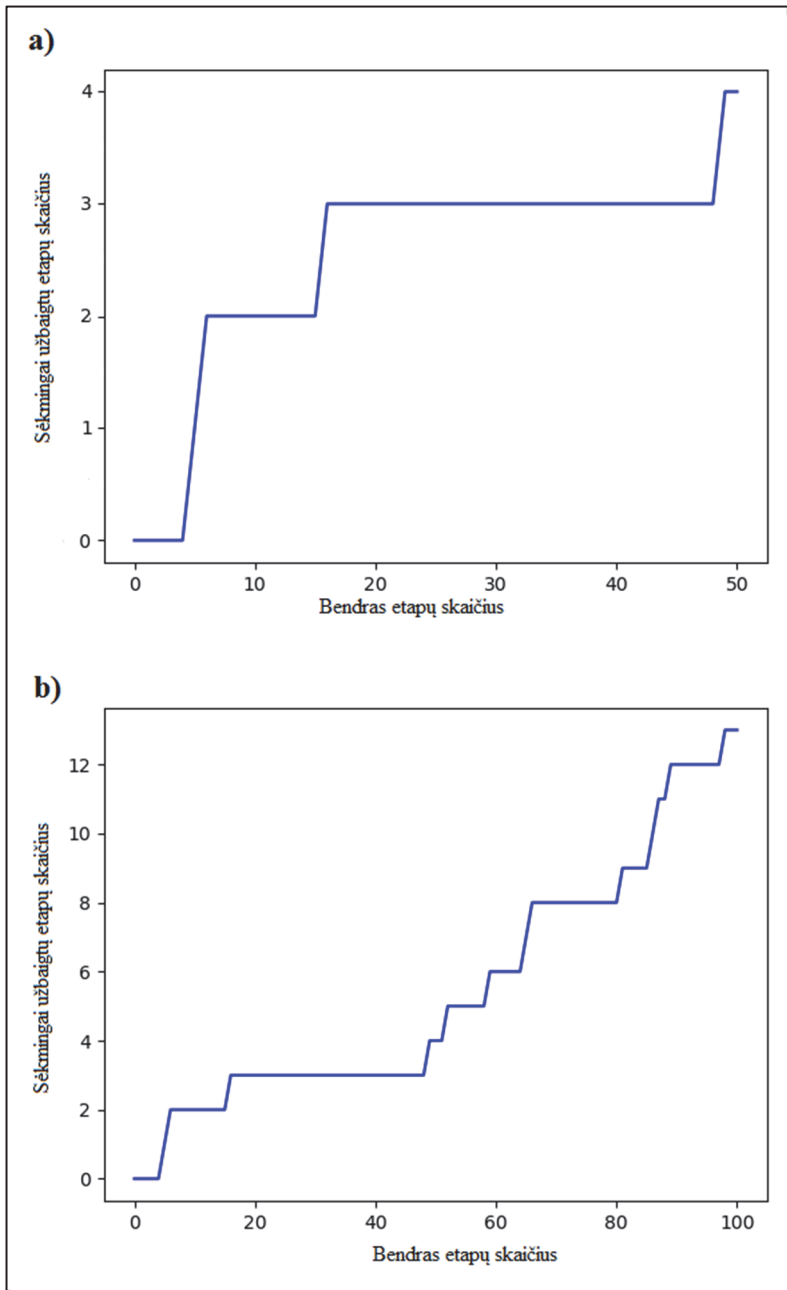
Tačiau šis pasiektas rezultatas turi ir kelis apribojimus:

1. Tikslo taškas buvo visada toje pačioje vietoje (stacionari padėtis);
2. Agentas turėjo išmokti judėti esant tik vienai dinaminei kliūčiai.

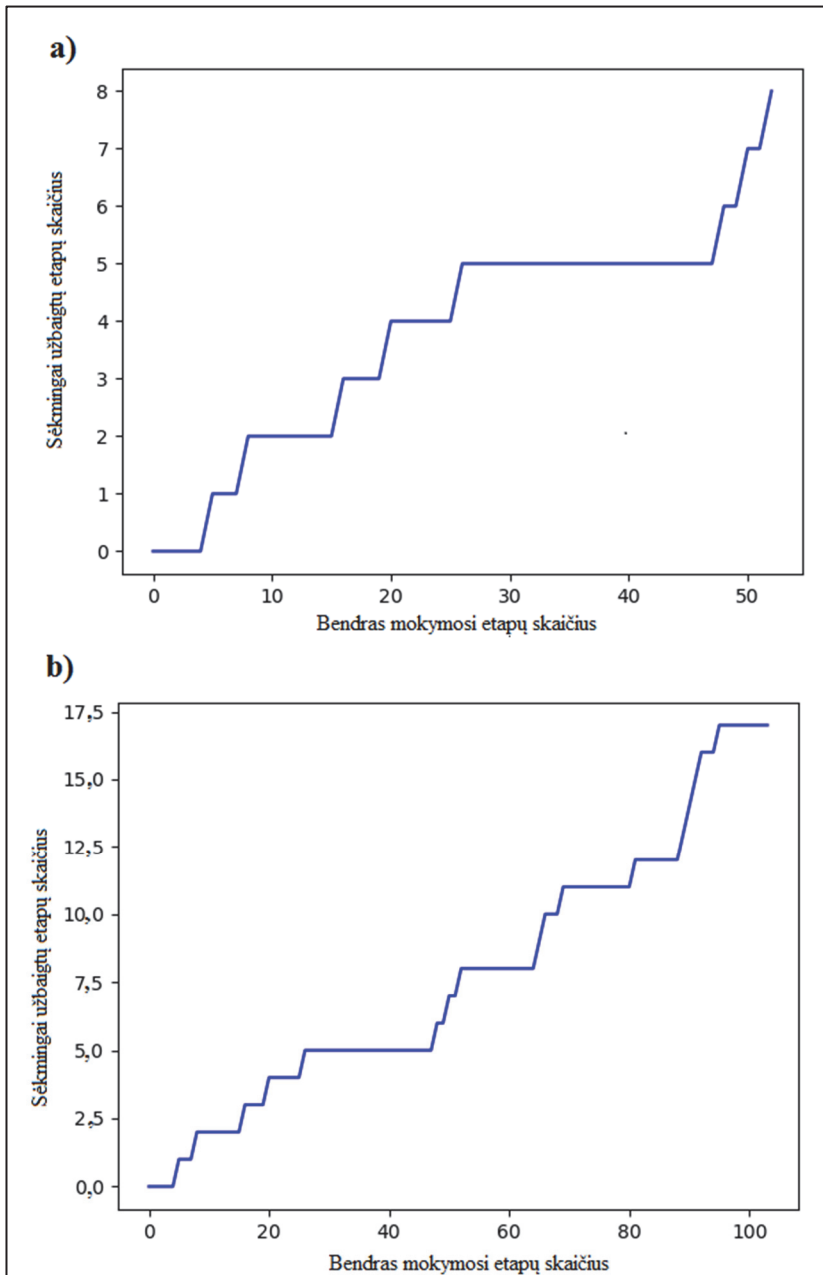
Atlikti papildomi tyrimai, siekiant įvertinti sustiprinto mokymosi algoritmo galimybę apsimokyti esant kelioms kliūtims. Kaip pavaizduota 12 paveiksle, jei uždavinys sudėtingesnis, sustiprinto mokymosi algoritmui sunkiau pasiekti sėkmingą rezultatą, t. y. tikslo tašką, aplenkiant tris kliūtis.

Agento mokymosi rezultatas su trimis kliūtimis po 50 etapų – tikslas pasiektas 7,8 % atvejais. Po 100 etapų agentas tikslą pasiekia 12,9 %. Lyginant agento mokymosi rezultata esant vienai kliūčiai, 87,7 % sėkmingai užbaigtų atvejų yra po 1500 etapų, tačiau esant trimis kliūtimis po 1500 etapų agentui sėkmingai pasiekti tikslą pavyksta tik 48,1 % atvejais. Siekiant įvertinti mokymosi galimybes, pratęstas agento apsimokymas iki 5000 etapų, tačiau pasiektas rezultatas skaičiuojant visus etapus siekia tik 60,92 %.

Papildomai atliktas eksperimentas su trimis kliūtimis ir kintančia tikslo taško padėtimi, žr. 13 pav.



12 pav. Sustiprinto mokymosi progresas su trimis kliūtimis: a) 50 etapų; b) 100 etapų



13 pav. Apmokymo progresas su kintančia tikslo taško padėtimi
a) 50 etapų; b) 100 etapų.

Lyginant agento mokymąsi su trimis kliūtėmis ir stacionaria tikslo taško padėtimi, pasiekti šiek tiek geresni rezultatai. Po 50 etapų agentas sėkmingai pasiekė tikslą 13,73 % atvejų, o po 100 etapų – 16,83 % atvejų. Tačiau lyginant su viena kliūtimi, apsimokius su 1500 etapų, agentas pasiekė tikslą 50,77 % atvejų. Tešiant mokymąsi iki 5000 etapų, pasiektas 64 % rezultatas.

Nors yra pasiūlyta nemažai įvairiems uždaviniams pritaikytų sustiprinto mokymosi modelių, skirtų laivybai [94], [95], [96], sustiprinto mokymosi procesas yra efektyvus naudojant tik supaprastintą modelį. Tačiau, kaip rodo papildomi tyrimai, agentui veikiant sudėtingesnėje aplinkoje sunku pasiekti gerų rezultatų. Taip pat tokie modeliai neatsižvelgia į laivų judėjimo taisykles, įvairias oro ir metų laikų sąlygas bei netikėtai atsiradusias kitas aplinkybes, o tai dar apsunkintų sprendžiamo uždavinio sprendimą.

2.8. Tyrimams naudojami duomenys

Visi disertacijoje panaudoti duomenys yra realūs navigacijos duomenys. Šiuos duomenis laivai siunčia LAD radijo bangomis visiems laivybos dalyviams, naudojant AIS [10]. Intensyvi laivyba generuoja didžiulius kiekius įvairių navigacijos duomenų. AIS duomenys eksperimentams gauti iš [97] – panaudoti 3 skyriaus eksperimentuose ir [98] – panaudoti 4 skyriaus eksperimentuose. Abiejose duomenų imtyse laivų duomenys yra tokios pačios struktūros, tačiau skiriasi duomenų kiekiai. Šiame darbe eksperimentams atlikti panaudoti skirtingi navigacijos duomenų rinkiniai. Atliekant pirmuosius eksperimentus, apsiribota mažesnės apimties AIS duomenimis, siekiant nustatyti galimybes tokius duomenis taikyti laivų maršrutams prognozuoti.

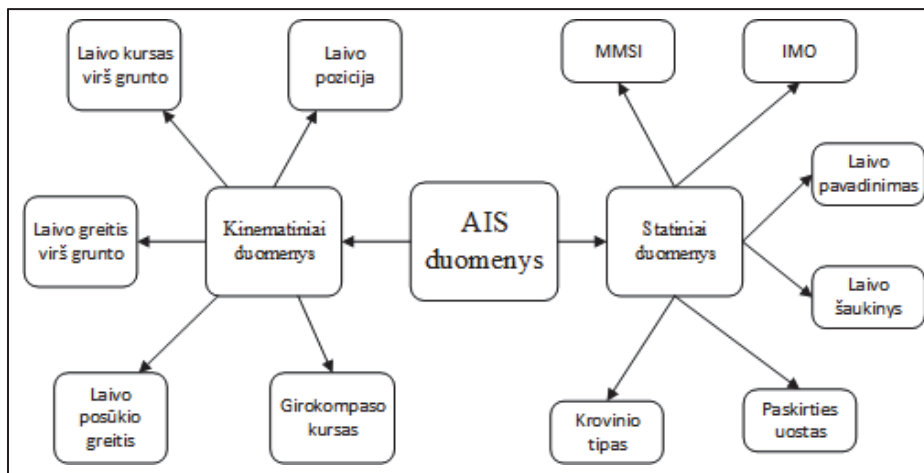
3 skyriuje eksperimentai atlikti su 3 mėnesių AIS duomenimis, gautais iš Šiaurės ir Baltijos jūrų laivybos dalyvių. Skaičiavimuose panaudotos laivų padėty, kuriose laivo kursas pasikeitė didesniu kaip 4° kampu. Tokius duomenis sudaro 1367251 laivų koordinatės. Šie duomenys panaudoti posūkio taškui prognozuoti, panaudojant dirbtinį neuroninį tinklą (DNT), ir anomalijoms aptikti – laivams, esantiems už laivybos srauto į tam tikrą uostą identifikuoti.

4 skyriuje panaudoti AIS duomenys apima Danijos krantus [98]. Kiekvieną dieną sukaupiama apie 2 GB duomenų. Susidaro dideli kiekiai (angl. *Big Data*) tokių duomenų, pavyzdžiui, AIS surinkti duomenys ties Danijos krantais užima apie 62 GB per mėnesį, o per metus susidaro apie 744 GB duomenų, žr. 14 pav.

MMSI	Ilguma	Platuma	Greitis	Kursas
258025000	58.01928	0.003056667	13.2	52
373864000	50.52565	0.007096667	12.2	254
308665000	54.14243	0.02045167	10.9	321
235102539	53.5735	0.03331167	14.2	144
305024000	54.39435	0.07314333	12.0	345
235090834	50.69424	0.07369667	8.2	279
212201000	54.26037	0.07741667	12.2	342
538005368	50.52254	0.08389	11.0	254
219252000	59.10472	0.09463666	13.6	101

14 pav. Tekstiniu formatu AIS saugomų duomenų pavyzdys

Perduodami ir gaunami AIS duomenys sudaro dvi pagrindines duomenų grupes: statiniai ir kinematiniai duomenys. Ši duomenų struktūra pavaizduota diagramoje (15 pav.).



15 pav. AIS duomenų struktūros diagrama

1. Statiniai duomenys:

- a) Laivo pavadinimas – tekstinė informacija, kurios modifikuoti naudotojas negali;

- b) MMSI (angl. *Maritime Mobile Service Identity*) – 9 skaičių tekstinė reikšmė, priskiriama konkrečiam laivui, naudojama norint susisiekti su konkrečiu laivu naudojantis radijo signalų pagalba;
- c) IMO (angl. *International Maritime Organization number*) – unikalus kiekvienam laivui identifikacinis skaičius;
- d) Šaukinys – unikalus kiekvienam laivui raidžių derinys, naudojamas susisiekti įvairiais būdais – radijo, vizualiniais ir t. t.;
- e) Krovinio tipas – rankiniu būdu pasirenkama reikšmė. Krovinio tipas apibūdinamas konkrečiu pasirinkimu iš sąrašo, atsižvelgiant į jo pavojingumą.
- f) Paskirties uostas – tekstinė reikšmė, įvedama rankiniu būdu kas kartą sudarant naują maršrutą į pasirinktą uostą.

2. Kinematiniai duomenys:

- a) Girokompaso kursas – duomenys realiuoju laiku atnaujinami pagal girokompasą.
- b) Laivo kursas virš grunto (angl. *Course Over Ground*) – duomenys gaunami iš globalios pozicionavimo sistemos (GPS) realiuoju laiku, skaičiuojami laipsniais;
- c) Laivo greitis virš grunto (angl. *Speed Over Ground*) – duomenys gaunami iš GPS realiuoju laiku, skaičiuojami mazgais;
- d) Posūkio greitis – duomenys realiuoju laiku atnaujinami pagal ROT (angl. *Rate Of Turn*) jutiklį, skaičiuojami laipsniais per sekunde;
- e) Koordinatės (platuma ir ilguma), kuriose šiuo metu yra laivas (GPS imtuvas). Taško, esančio ant žemės paviršiaus, nuotolis nuo pusiaujo išreiškiamas laipsniais.

Siekiant užtikrinti patikimus duomenis dažnai sensoriai yra dubliuojami, pavyzdžiui, AIS gauna informaciją iš GPS, tačiau turi ir vidinį GPS imtuvą, kuris naudojamas nesant informacijos iš pagrindinio GPS imtuvo. AIS duomenų grafinį pavaizdavimą elektroniniuose jūrlapiuose žr. 16 pav.



16 pav. Sugeneruotas AIS duomenų grafinis pavaizdavimas

AIS automatiškai siunčia duomenis apie laivo veiklos pobūdį konkrečiu metu (1 priedas, 1 lentelė) ir laivo tipą (1 priedas, 2 lentelė). Visa ši informacija skirta laivavedžiui palengvinti situacijos analizę ir pagelbėja priimant tinkamą sprendimą, užtikrinantį saugų laivų prasilenkimą.

2.9. Skyriaus apibendrinimas

Šiame skyriuje analizuojami įvairūs algoritmai, kurių paskirtis – suplanuoti saugų ir optimalų maršrutą. Išanalizuoti algoritmai nėra tinkami siekiant sukurti šiais algoritmais paremtą metodą, kuris leistų prognozuoti ir įvertinti stebimų laivų manevravimą, kadangi nagrinėtų algoritmų galimybės yra ribotos:

1. Analizės metu apžvelgtos laivyboje naudojamos technologijos, skirtos užtikrinti saugią laivybą. Patikimiausia technologija, užtikrinanti saugią laivybą, yra radaras, tačiau jis veikia analoginiu būdu ir reikalinga papildoma detali vaizdo analizė. Laivų stebėjimui palengvinti sukurta ir šiuo metu plačiai naudojama AIS technologija. Naudojant šią sistemą laivai keičiasi duomenimis realiuoju laiku su kitais laivybos dalyviais. Šiuo metu laivuose naudojamos technologijos skirtos tik palengvinti navigacijos informacijos

keitimąsi tarp laivybos dalyvių arba užtikrinti navigacijos informacijos vizualizavimą. Šios technologijos negali visapusiškai analizuoti ar valdyti vykstančio laivų judėjimo ir užtikrinti saugią laivybą.

2. Maršruto planavimo / kliūčių išvengimo algoritmų didžiausias trūkumas yra tas, kad ieškoma ne geriausio maršruto, o maršruto, kuris būtų optimalus tik pagal atstumą. Dažnai algoritmo pasiūlytas maršrutas nėra geriausias ar saugiausias, todėl būtina atsižvelgti į kitus lemiamus faktorius. Be to, maršruto planavimo algoritmai, esant tam tikroms aplinkybėms, negali iki galo išspręsti keliamo uždavinio – algoritmas gali užstrigti arba priimti kitą sprendimą, kuris nėra logiškas kelionės tikslo atžvilgiu.
3. Pritaikius gilau susitrinto mokymosi algoritmus, modeliuojant situacijas įmanoma apmokyti gilau susitrinto mokymosi agentą manevruoti ir pasiekti galutinį tašką. Tačiau toks algoritmo pritaikymas turi nemažai trūkumų:
 - a. Gilau susitrinto mokymosi algoritmas gana efektyvus esant vienai kliūčiai, tačiau esant sudėtingesniai uždaviniui, t. y. daugiau nei vienai kliūčiai, labai pailgėja mokymosi laikas ir nepasiekiamas didelis sprendimo priėmimo tikslumas.
 - b. Gilau susitrinto mokymosi algoritmas nėra tinkamas naudoti laivams manevruoti, nes pasiekus ir 99,9 % tikslumą, visada išliks gana didelė tikimybė, kad algoritmas priims neteisingą sprendimą, o tai turės galimai skaudžių padarinių. Teisingas sprendimas yra labai svarbus, todėl priimant sprendimą konkrečioje situacijoje, negalima suklysti arba savo veiksmais klaidinti kitų laivybos dalyvių.
 - c. Gilau susitrinto mokymosi metu nebuvo įtrauktos papildomos sąlygos, tokios kaip, pavyzdžiui, laivų prasilenkimo taisyklės, oro sąlygos ir pan. Tai darytų ypač neigiamą įtaką susitrinto mokymosi rezultatams.

3. LAIVYBOS MARŠRUTŲ PROGNOZAVIMO MODELIS

Šiame skyriuje pasiūlytas istorinių navigacijos duomenų klasterizavimo būdas, taikomas prognozuoti kitą laivo maršruto posūkio tašką. Taip pat pasiūlytas ir eksperimentiškai ištirtas metodas, skirtas aptikti neįprastai jundačius laivus bendrame laivybos sraute į tam tikrą paskirties uostą bei juos identifikuoti.

Šiame skyriuje pateikta medžiaga publikuota [99], [100] straipsniuose.

3.1. Anomalijų aptikimas laivyboje

AIS siunčiami navigacijos duomenys labai pagerina bendrą laivybos saugumą [101], [102], tačiau visada būtina šių duomenų analizė norint įvertinti esamą situaciją. Analizė visada atliekama laivavedžio turimomis priemonėmis, sudarant aplinkinių laivų atvaizdavimą popieriniuose arba elektroniniuose jūrlapiuose. Analizės metu skaičiuojamas prasilenkimas su kitais laivais ar kliūtimis, įvertinama laivų eismo situacija. Taip pat vertinant situaciją labai svarbu numatyti stebimo laivo manevrą ar kokiu maršrutu kitas laivas tęs savo kelionę. Atsižvelgiant į atliktą analizę ir įvertinus kitus įtaką darančius faktorius, tokius kaip aplinkiniai laivai, kliūtys, oro sąlygos ir t. t., koreguojamas savo laivo maršrutas. Tačiau neatlikus analizės, ją atlikus neišsamiai ar dėl dėmesingumo esamai situacijai stokos dažnai įvyksta nelaimių, kurių priežastis – žmogiškasis faktorius [103], [104], [105].


Laivybos dalyvių neįprastus manevrus arba anomalijas aptikti svarbu ne tik laivavedžiui, bet ir laivybą kontroliuojančioms tarnyboms, kurios yra suinteresuotos aptikti ir užkardyti įvairią nelegalią veiką, pavyzdžiui, nelegalią žvejybą, kriminalines veikas, aptikti naftos produktų išsiliejimą ir t. t. [106], [107], [108]. Anomalijų aptikimas padeda nustatyti / atskirti netikrus / padirbtus per AIS perduodamus duomenys [4], [17].

Anomalijų aptikimas – sudėtingas uždavinys. Nustatyti, kuris laivas juda neįprastai, yra sunku, nes:

1. Visi laivybos dalyviai elgiasi „teisingai“ iki tol, kol atsitinka nelaimė ir po jos atliekama detali įvykio analizė;
2. Kitų laivybos dalyvių vertinimas yra subjektyvus laivavedžio vertinimas;
3. Nežinant atlikto manevro priežasties sunku vertinti patį manevrą.

Sukurta įvairių metodų anomalijoms aptikti [109], [38], [110], tačiau šiuo metu praktiškiausias būdas laivavedžiui išsiaiškinti stebimo laivo manevravimo veiksmus – susisiekti tiesiogiai su kitais laivybos dalyviais per LAD radijo stoties specialų budintį kanalą. Kitas, praktiškesnis, būdas yra

įvertinti, koku maršrutu laivas juda, ir palyginti su AIS perduodama informacija – galutiniu uostu.



17 pav. Skirtingo laivo judėjimo į tą patį uostą pavyzdys

Suplanuotas maršrutas iš uosto A į uostą B visada gali šiek tiek skirtis (17 pav.), tai priklauso nuo:

1. Budinčio laivavedžio ir nuo to, kaip jis laikosi suplanuoto maršruto;
2. Oro sąlygų. Šis veiksnys ypač svarbus pučiant stipriam vėjui ir laivui kryptant į pavėjinę pusę;
3. Esamos laivybos situacijos. Prasilenkiant laivams galimas žymus nuokrypis nuo suplanuoto maršruto;
4. Mechaninių mazgų (pavyzdžiui, vairo plunksnos) būklės ir jų valdymo.

3.6 disertacijos skyriuje siūlomas laivybos anomalijoms aptikti skirtas metodas, paremtas prognozuojamu stebimo laivo maršrutu. Maršruto prognozavimo metodui yra reikalingas navigacijos duomenų klasterizavimas.

3.2. Navigacijos duomenų klasterizavimas

Per AIS gaunami navigacijos duomenys atnaujinami kas 2–6 sekundes, priklausomai nuo laivo judėjimo greičio ir duomenų tipo. Duomenis, gautus tokiu dažnumu, sujungus nuosekliai, gaunamas kelias, kuriuo laivas judėjo. Tačiau dirbti su tokiais duomenimis nėra paprasta, kadangi:

1. Atnaujinant duomenis kas 2–6 sekundes, o laivui judant pavyzdžiui 25 km/h, gaunami taškai, vienas nuo kito nutolę apie 14–42 metrus. O laivo ilgis neretai siekia 100 metrų ir daugiau.
2. Sunku išskirti posūkio taškus, nes jei laivo ilgis yra 100 metrų, posūkio spindulys (laivo cirkuliacija) gali siekti ir 400 metrų (4–7 laivo ilgiai), priklausomai nuo kurso pokyčio.
3. Planuotas maršrutas būna tiesios linijos tarp posūkio taškų, o atstumas tarp posūkio taškų siekia keletą / kelis šimtus kilometrų.
4. Dėl oro sąlygų, fizinių laivo savybių laivo padėtis kinta suplanuoto maršruto atžvilgiu.
5. Gaunami navigacijos duomenys sudaro didelį duomenų masyvą, todėl susiduriama su skaičiavimo išteklių apribojimais.

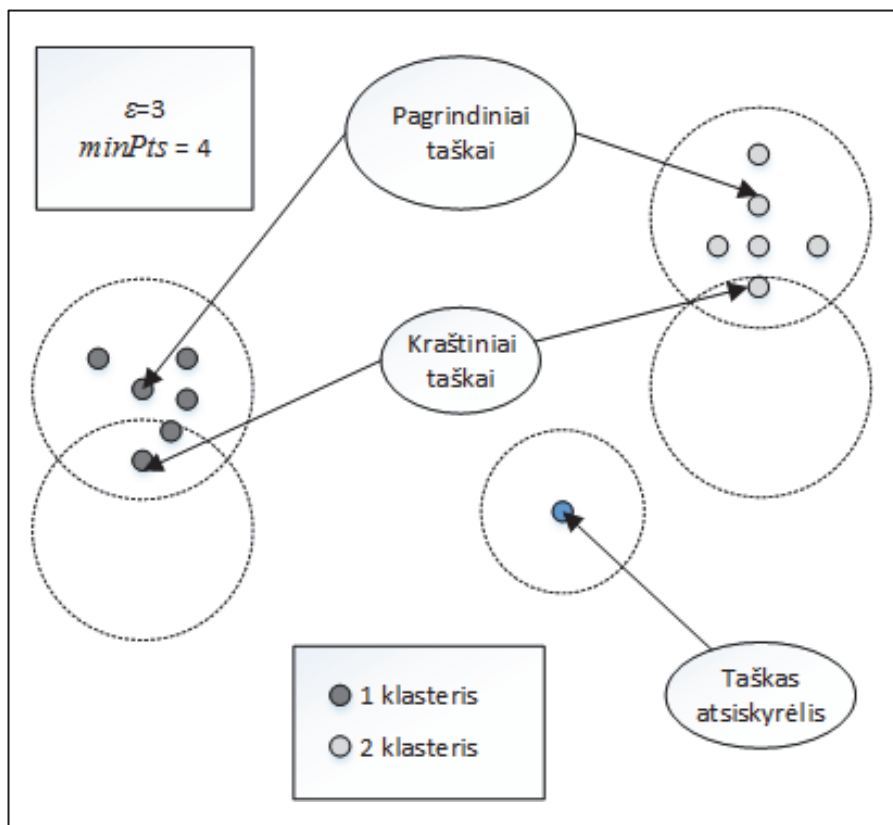
Siekiant išspręsti išvardytas problemas, panaudotas DBSCAN (angl. *Density-Based Spatial Clustering of Applications with Noise*) klasterizavimo algoritmas [111], sukurtas darbui su dideliais [112] geografinių duomenų (angl. *geo-spatial data*) kiekiais [113], [114], [115]. Šis algoritmas pagrįstas duomenų tankio klasterizavimu, grupuojant duomenis pagal išdėstytų geografinių taškų tankį, o ne tik pagal atstumą. Taip pat DBSCAN privalumas yra tas, kad nereikia nurodyti pradinio klasterio skaičiaus.

DBSCAN algoritmas naudoja du parametrus:

1. ϵ – spindulys, kuris apibrėžia objekto q kaimynystės dydį;
2. $minPts$ – klasterį sudarantis minimalus elementų kiekis.

DBSCAN algoritmas klasifikuoja duomenis pagal tris grupes, kaip pavaizduota 18 paveiksle:

1. Pagrindiniai taškai (angl. *core point*).
2. Pasiekiami taškai (angl. *reachable points*).
3. Taškai atsiskyrėliai (angl. *noise, outliers*).



18 pav. Posūkio taškų klasterizavimas


p taškas yra pagrindinis, jeigu aplink jį nustatytu atstumu (ϵ) susidaro numatytas minimalus taškų skaičius ($minPts$), įskaitant ir jį patį. q tašką tiesiogiai pasiekia p taškas, jeigu q taškas yra ϵ atstumu nuo pagrindinio taško p . Visi klasterį sudarantys taškai turi būti tiesiogiai pasiekiami. q taškas pasiekiamas iš taško p , jeigu tarp taškų p_1, \dots, p_n yra tiesioginis kelias, kai $p_1 = p$ ir $p_n = q$, kur kiekvienas p_{i+1} yra tiesiogiai pasiekiamas iš taško p_i . Taškai, kurių pagrindinis taškas nepasiekia, vadinami taškais atsiskyrėliais (angl. *outliers, noise points*). Kraštiniais taškais vadinami tokie taškai, kuriuos pasiekia keli pagrindiniai taškai. Kiekvieną klasterį turi sudaryti mažiausiai vienas pagrindinis taškas.

DBSCAN algoritmas duomenis klasterizuoja tokia seka:

1. Išanalizuojami visi taškai (objektai), jie nėra priskiriami jokiam klasteriui;
2. Duomenų aibėje parenkamas objektas q ;
3. Objektas tampa pagrindiniu, jeigu atitinka sąlygas: randami su objektu siejami taškai, atsižvelgiant į $minPts$ ir ϵ parametrus;

4. Jeigu objektas neatitinka pagrindinio objekto parinktų parametų ($minPts$ ir ϵ), jis tampa tašku atsiskyrėliu;
5. Algoritmas stabdomas priskyrus visus taškus prie klasterių arba taškų atsiskyrėlių.

DBSCAN algoritmui buvo pateiktos laivų padėties (platuma ir ilguma). Šios padėties išfiltruotos pagal laivo kurso pokytį – imami tokie taškai, kuriuose pasikeitė kursas daugiau kaip 4° . Filtravimas reikalingas atskirti atsiktinius taškus – maži nukrypimai nuo suplanuoto maršruto, atsirandantys dėl laivo siūbavimo, vėjo ar povandeninių srovių. Skirtingų laivų posūkio taškai į tą patį uostą gali skirtis, todėl gaunama daug posūkio taškų. Faktiškai yra tam tikri posūkio regionai, kurios reikia lokalizuoti atliekant klasterizavimą.



19 pav. DBSCAN algoritmo panaudojimas

Suklasterizavus posūkio taškus, gaunami posūkio taškų klasteriai. Imant atskirai kiekvieną klasterį, gaunama geografinė sritis, kurioje laivai keičia kursą keliaujant laivui iš uosto A į B. Tad bendroju atveju maršrutas susideda iš klasterių (19 pav.), o klasteriai susideda iš daugelio laivų posūkio taškų. Taip suklastertizuoti navigacijos duomenys vėliau gali būti geriau panaudojami dėl kelių privalumų:

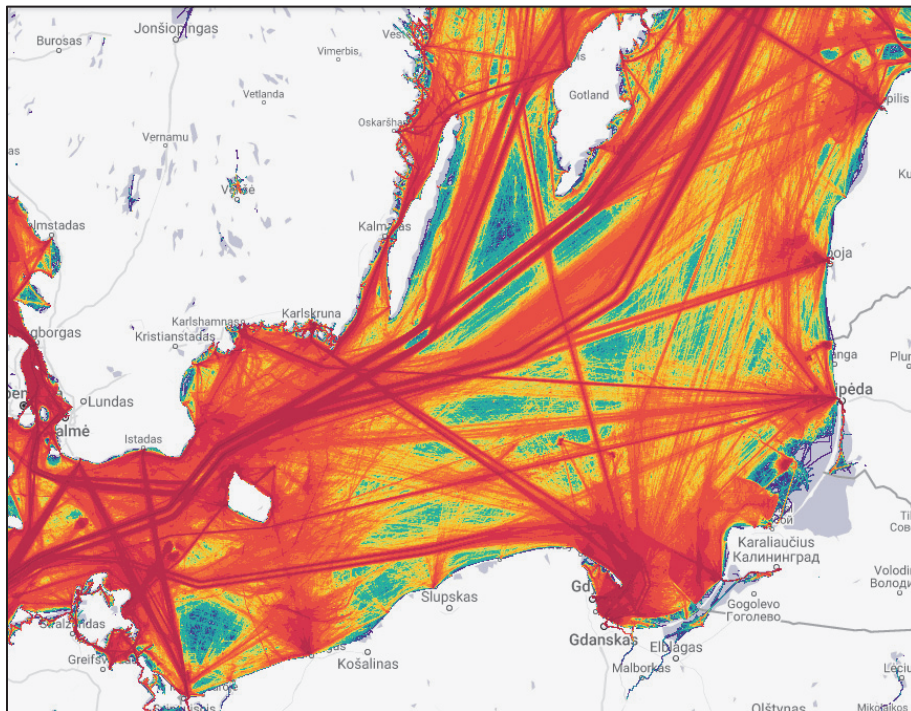
1. Išryškėja posūkio taškai keliaujant iš uosto A į uostą B;

2. Sumažėja duomenų apimtis. Lieka tik svarbiausi posūkio taškai;
3. Atmetami atsitiktiniai taškai – blogai įvestas paskirties uostas, nukrypimai dėl prasilenkimų ir t. t.

DBSCAN algoritmas taip pat padeda surinkti ir laivų, judančių kitais maršrutais, bet į tą patį paskirties uostą, posūkio taškus. Pradiniai posūkio taškai gali būti unikalūs, tačiau vėlesni gali sutapti su stebimo laivo maršruto posūkio taškais, kai laivas juda iš A uosto į B, su maršruto iš C į B, iš D į B ir t. t. Tai svarbu, nes labai padidina duomenų apimtį nagrinėjant konkretų paskirties uostą. Duomenys bus naudojami dirbtiniams neuroniniams tinklams mokytį.

3.3. Stebimo laivo maršruto prognozavimo modelis

Dažniausiai laivo maršrutas yra sudarytas iš daugelio posūkio taškų. Šių taškų padėtys (koordinatės) priklauso nuo to, kaip buvo suplanuotas maršrutas. Maršrutą asmeniškai planuoja kiekvienas laivavedys, tačiau keliaujant į konkretų uostą A vis tiek išlieka bendros tendencijos. Tai ypač gerai atsiskleidžia vizualiai panagrinėjus laivybos srautus Baltijos jūroje (20 pav.).

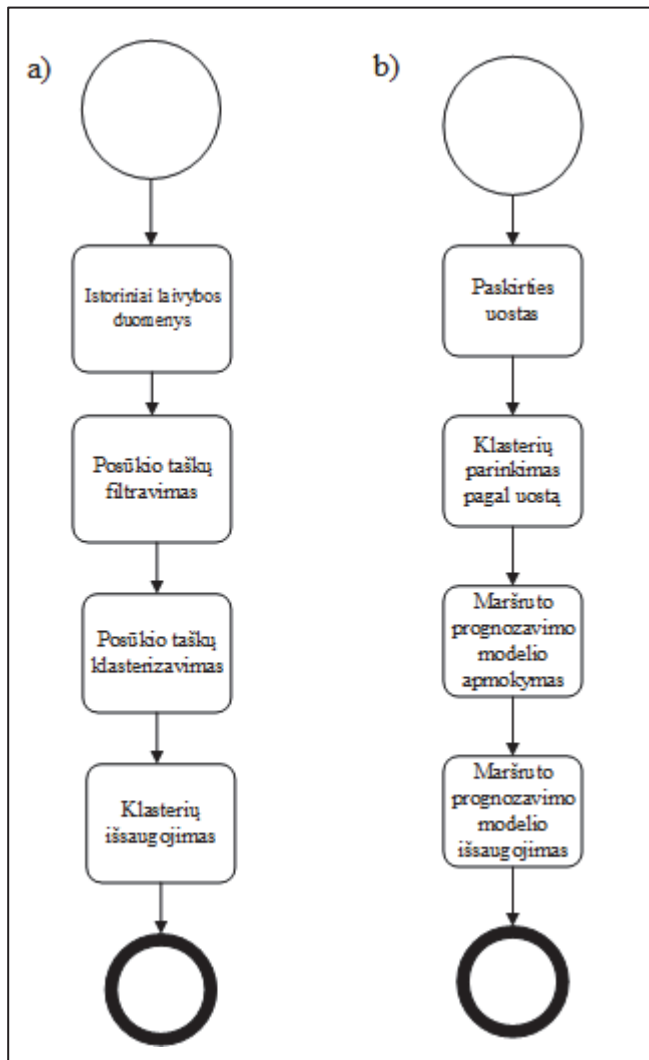


20 pav. Laivybos srautai Baltijos jūroje

Maršruto posūkio taškai apibūdinami koordinatėmis – platumu ir ilguma. Tačiau planuojant didelio laivo maršrutą svarbu, koku kursu ir greičiu pasiekiamas posūkio taškas. Taip yra todėl, kad norint laikytis suplanuoto maršruto esant didesniai laivo greičiui ar norint atlikti didesnę kurso pakeitimą reikia atsižvelgti į laivo manevrines savybes, t. y. laivo inerciją.


Disertacijoje pasiūlytas stebimo laivo maršruto prognozavimo modelis (21 pav.) susideda iš dviejų pagrindinių dalių:

1. Duomenų paruošimas – posūkio taškų klasterizavimas ir klasterių centrų apskaičiavimas;
2. DNT apmokymas pagal paruoštus (klasterizuotus) duomenis.




21 pav. Duomenų paruošimo ir maršruto prognozavimo modelio apmokymas

Duomenų paruošimas – posūkio taškų klasterizavimas ir klasterių centrų apskaičiavimas. Navigacijos duomenų klasterizavimą atliekant DBSCAN algoritmu, klasteriai sujungia posūkio taškus tam tikroje zonoje. Kitas etapas – apskaičiuoti šių klasterių centrų koordinates (ilguma ir platumą), žr. 22 pav.



22 pav. Posūkio taškų klasteris su apskaičiuotu centru

Aplink apskaičiuoto klasterio centrą laivai vykdo posūkį. Klasteriai gali būti vienas nuo kito nedaug nutolę, o tai gali atspindėti priklausomybę nuo laivo tipo, dydžio ar krovinio tipo. Tačiau išdėstant klasterius nuosekliai sudaromas konkretus maršrutas iš uosto A į uostą B. Iš posūkio taško (klasterio) laivo judėjimo kryptis keičiama link kito posūkio taško (klasterio). Klasterizuojant navigacijos duomenis labai svarbu atsižvelgti į DBSCAN algoritmo ϵ parametą.



23 pav. Skirtingi rezultatai pritaikius skirtingą ϵ parametą

Parametras ϵ turi didelę įtaką klasterių apskaičiavimui (23 pav.). 23 pav. a) paveiksle parinkta didesnė ϵ parametro reikšmė, o 23 pav. b) – mažesnė

reikšmė. Taikant DBSCAN algoritmą posūkio taškams klasterizuoti, parametras ε parenkamas pagal tai, kur yra nagrinėjami posūkio taškai:


1. Parametro ε didesnė skaitinė reikšmė reikalinga klasterizuojant posūkio taškus atviroje jūroje, nes:
 - a. Sujungiamas didesnis posūkio taškų skaičius;
 - b. Lieka mažiau taškų atsiskyrėlių.
2. Parametro ε mažesnė skaitinė reikšmė reikalinga klasterizuojant posūkio taškus uostuose, kanaluose ar siaurumose, nes:
 - a. Posūkio taškai sujungiami daug tiksliau;
 - b. Gaunamas detalesnis maršrutas.

Tad labai svarbu kiekvienu konkrečiu atveju klasterizuojant posūkio taškus parinkti tinkamą ε parametą. Detalesnis skirtingų parametro ε reikšmių pritaikymo DBSCAN algoritmui rezultatas pavaizduotas 24 pav., 25 pav. ir 26 pav.




24 pav. Posūkio taškų klasterizavimas, kai $\varepsilon = 0,001$

24 pav. pateikiamas rezultatas, gautas posūkio taškus suklasterezavus pagal parametro reikšmę $\varepsilon=0,001$. Gauti klasteriai nėra tinkami tolesniems eksperimentams, nes posūkio taškų klasteriai nėra pakankamai tankiai išdėstyti, kad sudarytų maršrutus į Antverpeno uostą.




25 pav. Posūkio taškų klasterizavimas, kai $\varepsilon = 0,1$

25 pav. pateikiamas rezultatas, gautas posūkio taškus suklasterezavus pagal parametro reikšmę $\varepsilon = 0,1$. Gauti klasteriai išdėstyti nesistemiškai, todėl negalima sudaryti maršruto į Antverpeno uostą. Geriausias rezultatas gautas pagal $\varepsilon = 0,05$.




26 pav. Posūkio taškų klasterizavimas, kai $\varepsilon = 0,05$

Atviroje jūroje reikia naudoti didesnę ε parametro reikšmę, tačiau bet kuriuo atveju ji turi būti žymiai mažesnė už kanalo plotį uoste ar jūroje (žr. 27 paveikslą).



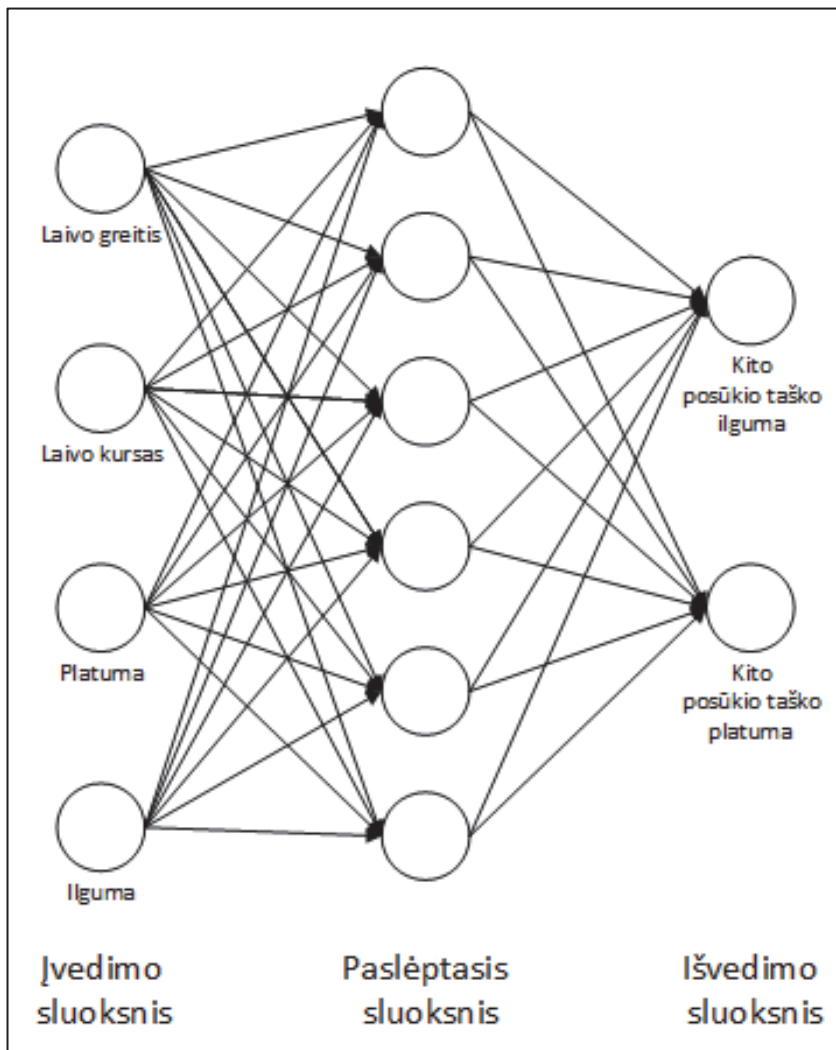
27 pav. Klasterių išsidėstymas laivybos kanale

Klasterizavimui iliustruoti pasitelkti Baltijos ir Šiaurės jūrų 3 mėnesių istoriniai navigacijos duomenys. Iš viso klasterizavimui pateiktas 1367251 išfiltruotas posūkio taškas (šiuose taškuose kursas keitėsi didesniu kaip 4° kampu). Klasterių skaičius maršrute yra labai skirtingas. Kuo populiarnesnis uostas – tuo daugiau laivų į jį keliauja skirtingais maršrutais (žr. 28 paveikslą).



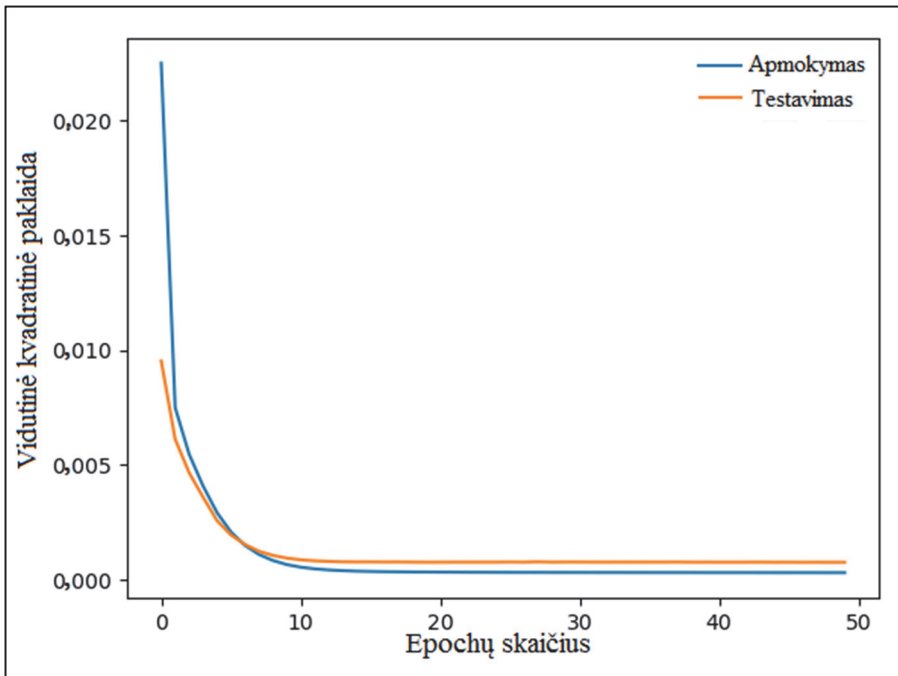
28 pav. Klasterių skaičius pagal paskirties uostą

Pasiūlyto stebimo laivo maršruto prognozavimo modelio antroji sudėtinė dalis yra DNT apmokymas pagal paruoštus (klasterizuotus) duomenis. Kaip minėta, plaukiant suplanuotu maršrutu, reikia atsižvelgti į pagrindinius parametrus: laivo greitį, judėjimo kryptį ir esamas koordinatas (ilgumą ir platumą). Šie parametrai lemia, kokios bus kito posūkio taško koordinatės (platumą ir ilgumą). Remiantis šiais duomenimis ir buvo apmokytas daugiasluoksnis DNT, kaip pavaizduota 29 paveiksle.



29 pav. Neuroninio tinklo schema

DNT įvedimo sluoksnyje įvedama dabartinė laivo padėtis (platuma ir ilguma), greitis ir judėjimo kryptis. Išvedimo sluoksnyje – prognozuojamo klasterio centro (posūkio taško) koordinatės. Eksperimentuose įvedami duomenys normalizuoti intervale [min, max]. 80 % duomenų pateikti mokymuisi, o likusi dalis – testavimui. Panaudota ReLU aktyvavimo funkcija. Apmokyta tiek atskirų DNT, kiek yra ir su DBSCAN apskaičiuotų klasterių, t. y. kiekvienas maršruto posūkio taškas (klasteris) turi atskirą, apmokytą DNT. Konkretaus posūkio taško apmokymo progreso rezultatas pateikiamas 30 paveiksle. Šiam DNT apmokyti pateikti 36360 posūkio taškų ir pasiektas 97,53 % tikslumas.



30 pav. Neuroninio tinklo apmokymo progresas

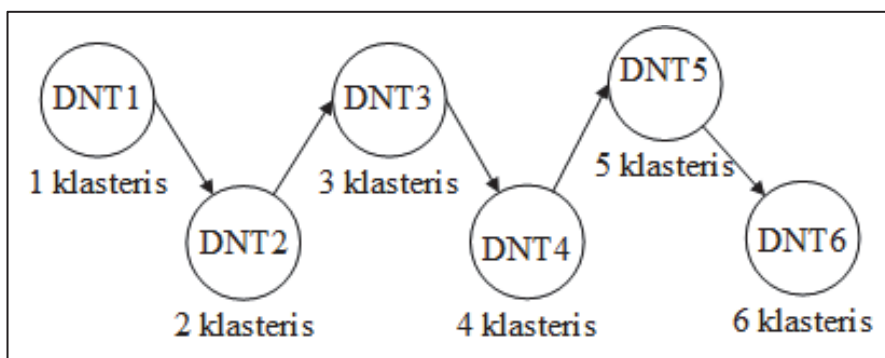
Konkreto posūkio taško apmokymas yra didelis viso maršruto pranašumas prieš vieną DNT, nes suteikia galimybę tiksliau prognozuoti būsimą stebimo laivo posūkio tašką bei aptikti laivų judėjimo anomalijas.

Atsižvelgus į kitus mokslinius tyrimus su LSTM (angl. *Long Short-Term Memory*) [116] ir RNN (angl. *Recurrent Neural Network*) [117], [118] tinklais, atlikti ir papildomi eksperimentai, kurie neįtraukti į disertaciją. Papildomai atlikti eksperimentai, pritaikant gilius neuroninius tinklus LSTM ir RNN posūkio taškams prognozuoti. Šių tinklų apmokymo rezultatas labai panašus į DNT, reikšmingo pagerėjimo nenustatyta, o dėl šios priežasties tolesni eksperimentai apsiribojo klasikiniiais metodais.

Pasiūlytas metodas dar nėra išbandytas realioje aplinkoje, tačiau praktinis tikslumas turi būti panašus į nustatytąjį modeliuojant. Realioje aplinkoje navigacijos duomenys atitinka duomenis, kuriais remiantis atlikti eksperimentai. Taip pat pažymėtina, kad kiti autoriai siūlo panašiai prognozuoti laivų maršrutus [117], [119], [120], tačiau disertacijoje pateiktas metodas yra pasiūlytas ir publikuotas prieš kelerius metus [99].

3.4. DNT pritaikymas stebimo laivo maršrutui prognozuoti

DNT tiesiogiai prognozuoti maršruto negali. DNT, kaip minėta pirmiau, atsižvelgiant į stebimo laivo padėtį, kursą ir greitį, prognozuoja būsimas stebimo laivo posūkio taško koordinatas. Didžiausias tokio prognozavimo privalumas yra tas, kad DNT kas kartą perskaičiuoja prognozę pagal atnaujintus duomenis. Taip nuosekliai prognozuojant tikėtinus posūkio taškus, galima sudaryti hipotetinį stebimo laivo maršrutą (31 pav.), jei tinklui mokyti naudojami duomenys apie laivų judėjimą į tą patį paskirties uostą. Visais atvejais rekomenduojama DNT prognozavimą naudoti keliems tolesniems žingsniams, o gavus atnaujintus navigacijos duomenis – perskaičiuoti prognozavimą.



31 pav. Laivo maršruto pagal prognozuojamus klasterius

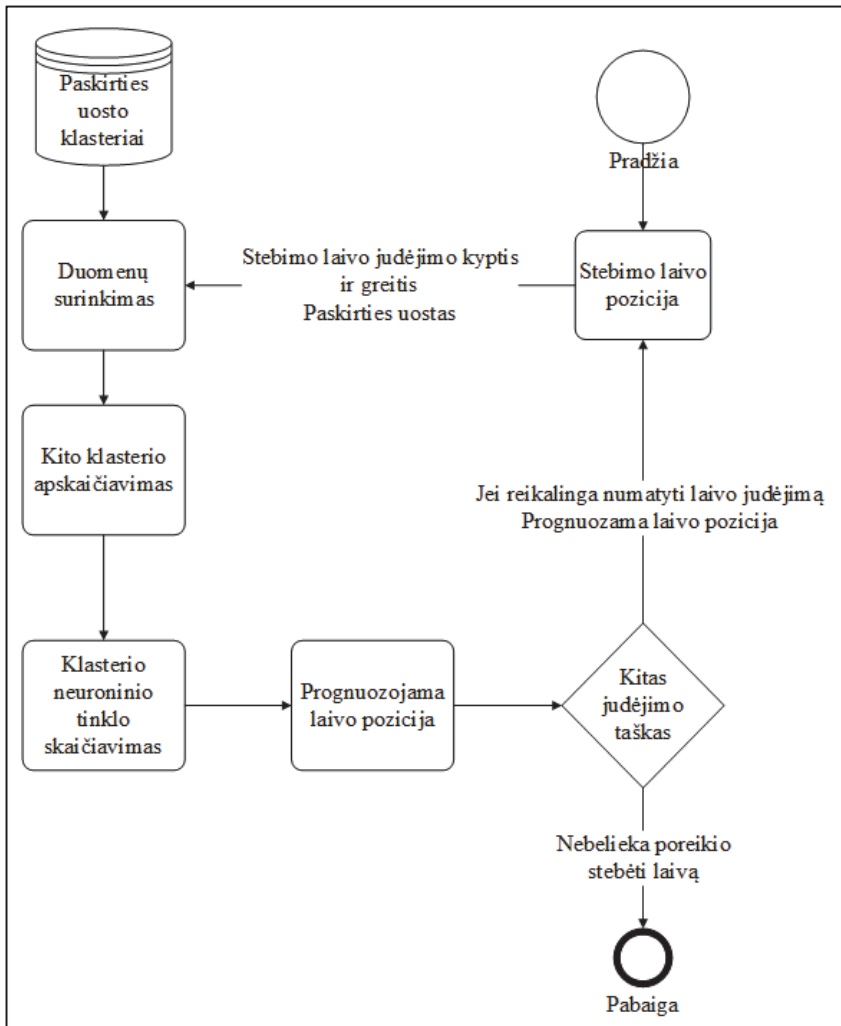
Klasterių eiliškumas nebūtinai yra nuoseklus, tačiau gavus prognozavimo rezultatą, t. y. būsimą posūkio taško koordinatas, galima pagal prognozuojamas koordinatas atlikti naują prognozavimą, siekiant nustatyti būsimą posūkio tašką. Tačiau taikant tokį DNT maršruto prognozavimo modelį yra papildomų sąlygų:

1. Laivo greitis turi būti pastovus. Ši sąlyga tinka atviroje jūroje, tačiau siaurumose, kanaluose ir uostuose greitis gali keistis priklausomai nuo situacijos;
2. Laivo kursas apskaičiuojamas atsižvelgiant į tai, koks bus kitas posūkio taškų klasteris;
3. Pakitus navigacijos duomenims, prognozė turi būti perskaičiuojama.

Tokia seka prognozuojant stebimo laivo posūkio taškus, galima nuosekliai pasiekti paskutinį maršruto posūkio tašką. Kadangi pagal kiekvieną klasterį yra apmokytas atskiras DNT, tai leidžia gana tiksliai prognozuoti būsimą stebimo laivo posūkio tašką. Viso maršruto prognozavimo tikslas yra ne kuo tiksliau atkartoti būsimą maršrutą (prognozuojamo maršruto

palyginimas pateikiamas 34 pav.), o numatyti, kokie yra galimi stebimo laivo manevrai. Atitinkamai įvertinus galimus stebimo laivo veiksmus, reikia planuoti savo laivo manevravimą, siekiant išvengti laivų susidūrimo ar pavojingų situacijų. Kitas svarbus dalykas yra tas, kad pasiūlytas modelis gali būti taikomas realiuoju laiku ir su nuolat kintančiais kitų laivų navigacijos duomenimis. Tai yra labai svarbu, nes tikslinant duomenis gali nutikti taip, kad paskirties uostas nebus prognozuojamame maršrute. Toks nesutapimas gali atsirasti dėl įvairių priežasčių, pavyzdžiui, pasikeitus laivo maršrutui, laivavedys pamiršo AIS siųstuvo nustatymuose pakeisti ir paskirties uostą, t. y. įvyko žmogiškoji klaida. Esant nesutapimui tarp laivo tikrojo judėjimo ir prognozuojamo maršruto, laivavedys privalo atkreipti dėmesį į tokią situaciją ir ją vertinti kaip pavojingą. Todėl toks modelio veikimas ir pritaikymas taip pat pagerina laivybos saugumą.

Pasiūlytas modelis lengvai gali būti pritaikomas pagal laivų dydį, tipą, krovinio tipą ir pan. Norint pritaikyti modelį, užtektų išfiltruoti atitinkamus navigacijos duomenis pagal reikalingą kriterijų ir tokiu pat būdu apmokyti DNT. Tai atlikus labai pagerėtų prognozių tikslumas, nes, pavyzdžiui, 300 metrų ilgio tanklaivis, gabenantis 500 000 tonų naftos, neplauks tais pačiais posūkio taškais kaip 20 metrų ilgio žvejų laivas.



32 pav. Laivų maršruto prognozavimo modelio taikymo schema

Modelio veikimo schema pavaizduota 32 paveiksle. Kiekvienas maršrutas į konkretų uostą sudarytas iš skirtingo posūkio taškų skaičiaus. Tai lemia ir galutinį klasterių (apmokytų DNT modelių) skaičių konkrečiame maršrute. Kaip minėta anksčiau, galima sujungti duomenis iš kelių skirtingų maršrutų, bet atvykimas planuojamas į tą patį paskirties uostą. Pavyzdžiui, maršrutas iš Klaipėdos į Roterdamą (Olandija), gali būti vykdomas per Kylio kanalą arba keliaujant Skagerako ir Kategato sąsiauriais. Šiuo atveju maršrutai turi bendrą dalį Baltijos jūroje ir Šiaurės jūroje (žr. 33 paveikslą).



33 pav. Klasterizuoti maršrutų taškai į Roterdamą, Olandija

Klasterizuojant navigacijos duomenis, imami visi galimi maršrutai į atvykimo uostą, tačiau apmokomas konkretus klasteris. Apmokius DNT, atsiranda galimybė stebėti ir prognozuoti laivų judėjimą. Iš pradžių per AIS gaunama dominančio laivo padėtis, judėjimo parametrai ir paskirties uostas. Pagal paskirties uostą atrenkami DNT išsaugoti modeliai, pagal laivo judėjimo kryptį parenkamas apmokytas DNT būsimam posūkio taškui prognozuoti. Pritaikius DNT, gaunamas būsimas posūkio taškas. Galima kartoti tol, kol pasiekiamas galutinis posūkio taškas.

3.5. Maršruto prognozavimo modelio taikymo tyrimo rezultatas

DNT prognozuoja stebimo laivo būsimo posūkio taško padėtį, kuri turi sutapti su laivo judėjimo kryptimi. Atstumas d tarp prognozuoto taško koordinatės (λ_1, φ_1) ir tikrojo posūkio taško koordinatės (λ_2, φ_2) apskaičiuojamas formulėmis:

$$a = \sin^2\left(\frac{\Delta\varphi}{2}\right) + \cos(\varphi_1)\cos(\varphi_2)\sin^2\left(\frac{\Delta\lambda}{2}\right); \quad (5)$$

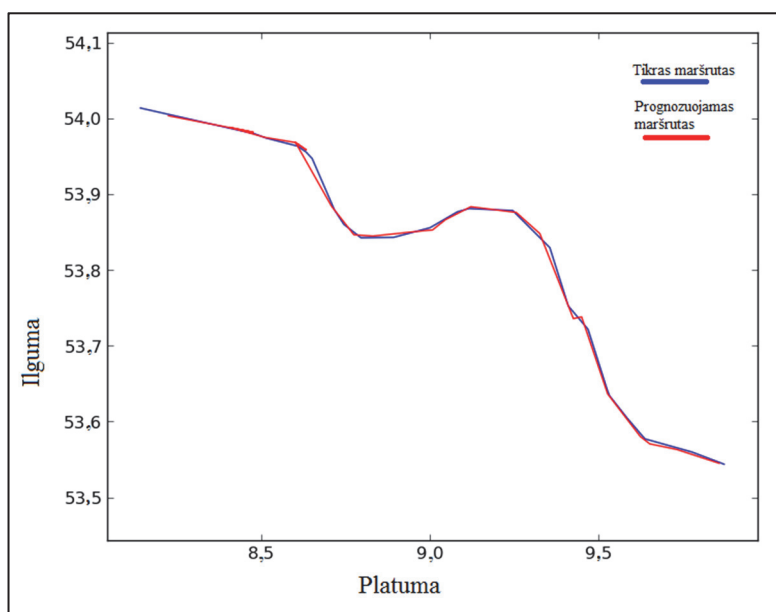
$$c = 2 * \operatorname{atan2}(\sqrt{a}, \sqrt{(1-a)}); \quad (6)$$

$$d = Rc \quad (7)$$

Formulėse naudojami žymėjimai:

- φ – platumas radianais;
- λ – ilguma radianais;
- $\Delta\varphi = (\varphi_2 - \varphi_1)$ – skirtumas tarp dviejų platumų;
- $\Delta\lambda = (\lambda_2 - \lambda_1)$ – skirtumas tarp dviejų ilgumų;
- R – žemės spindulys (skaičiavimams naudotas žemės vidutinis spindulys 6371 km).

Taip pat svarbi geros prognozės sąlyga yra ta, kad prognozuojami posūkio taškai turi nuosekliai susijungti į maršrutą, kaip pavaizduota 34 pav.




34 pav. Prognozuoto ir faktinio maršruto palyginimas

Laivo maršrutas susideda iš daugelio posūkio taškų. Kiekvienas posūkio taškas nukreipia laivo judėjimą į kitą, ūsimą posūkio tašką. Tokia seka vykdomas plaukimas iš uosto A į uostą B. Tokia pačia seka sudaromas maršrutas, prognozuojant kiekvieną stebimo laivo maršruto posūkio tašką. Toks prognozavimas gali būti pritaikomas ir laivui esant pusiaukelėje arba kas kartą atnaujinus navigacijos duomenis. Tai įmanoma atlikti, nes posūkio taškai, kurie buvo klasterizuojami, priklausė maršrutams į tą patį paskirties uostą.

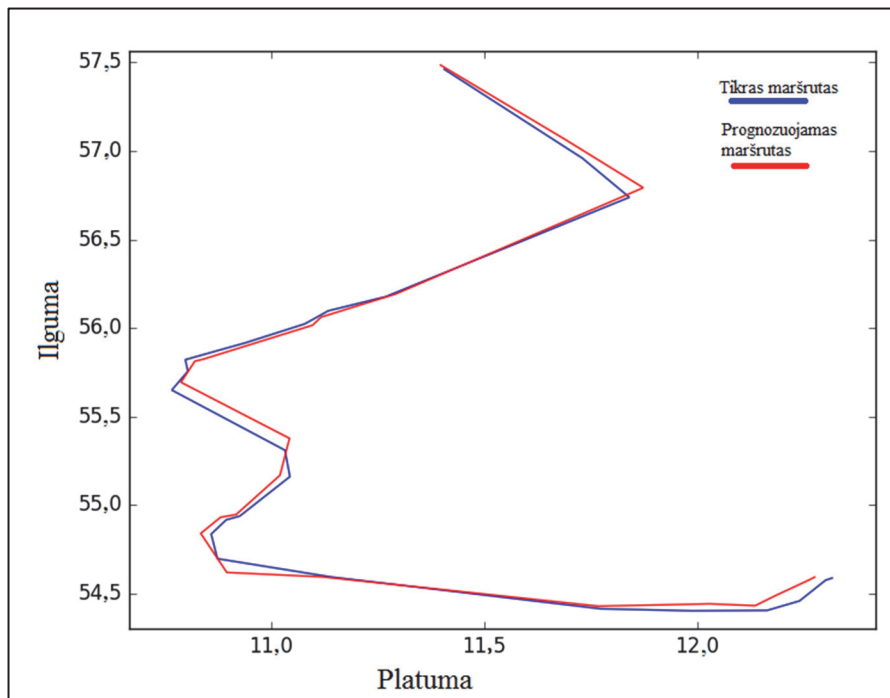
Prognozavimo tikslumo įvertinimas pateiktas 35 paveiksle. Stulpelio aukštis nurodo atstumo nesutapimą tarp prognozuojamo ir faktinio posūkio

taško. Laivo posūkio taškai nėra prognozuojami labai tiksliai, nes naudoja klasterizuotus daugelio posūkių duomenis. Prognozavimo tikslumas labai priklauso nuo panaudoto DBSCAN ϵ parametro. Neįmanoma tinkamai pritaikyti DBSCAN ϵ parametro skirtingoms geografinėms vietovėms. Parenkant parametras, būtina atsižvelgti į tai, kokio pločio yra galimas laivybos kanalas, pavyzdžiui, uostas, siaurumos, atvira jūra ar vandenynas. Dėl šios priežasties atsiranda didelių paklaidų prognozavimo rezultatuose. Šiai problemai išspręsti vėlesniuose tyrimuose pritaikytas OPTICS algoritmu paremtas klasterizavimas, aprašytas 4.4 skyriuje.



35 pav. Prognozavimo tikslumas


Tačiau pasiūlyto prognozavimo tikslas yra ne kuo tiksliau atkartoti visą maršrutą (žr. 36 paveikslą). Pagrindinis prognozavimo uždavinys – numatyti, kokie yra galimi stebimo laivo manevrai. Numatant, kuriose vietose laivas keis kursą, galima planuoti saugų prasilenkimą. Prognozuojant posūkio taškus, didelėmis paklaidomis galima laikyti tokias reikšmes, kai numatomas taškas nesutapo su faktiniu, didesniu už laivo ilgį, atstumu. Tokia paklaida yra reikšminga, nes iškreipia prognozuojamą maršrutą.



36 pav. Prognozuotas maršrutas su didelėmis paklaidomis

3.6. Anomalijų aptikimas laivyboje

DBSCAN algoritmu agreguojant navigacijos duomenis, taškai atsiskyrėliai (anomalijos) yra atmetami. Taškai atsiskyrėliai tolesniam DNT mokymui nėra naudojami. Tačiau šie taškai atsiskyrėliai reiškia dalyvius laivyboje, kurie keliauja į tą patį paskirties uostą nelegišku arba net priešingu bendram laivybos srautui maršrutu. Atsižvelgiant į tai, kad navigacijos duomenys yra filtruojami pagal paskirties uostą, anomalinių taškų priežastys gali būti labai įvairios: nepakeistas paskirties uostas AIS siųstuvo nustatymuose, dėl techninių problemų iš suplanuoto maršruto išklydęs laivas, neteisingai nustatytame paskirties uoste slepiama nelegali veikla (pavyzdžiui, nelegali žvejyba ar žmonių gabenimas) ir t. t. Kaip pavaizduota 37 pav., anomaliniai taškai (pažymėti raudonais stačiakampiais) vizualiai išsiskiria iš bendro laivybos srauto.




37 pav. Anomalijų laivyboje pavyzdžiai

Anomaliniai taškai, esantys už bendro laivybos srauto, nedaro įtakos stebimo laivo maršruto prognozavimui 3.4 skyriuje pasiūlytu metodu. Tačiau juos įvertinti labai svarbu, siekiant užtikrinti saugią laivybą. Anomalinis laivų judėjimas kelia pavojų saugiai laivybai, nes:

1. Laivai, esantys už srauto ir ketinantys pasiekti tą patį paskirties uostą, anksčiau ar vėliau privalės įsilieti į bendrą laivybos srautą. Tačiau tai gali įvykti ne pačiu saugiausiu būdu;
2. Sudėtinga prognozuoti tokių laivų veiksmus, nes nėra aiškus tokių manevrų tikslas;
3. Reikia nuolat stebėti, kaip keičiasi situacija, atsižvelgiant į laivybos dalyvius, kurie nėra bendrame laivybos sraute;
4. Dėl sunkiai prognozuojamų stebimų laivų veiksmų algoritmais paremto (kompiuteriu) saugaus prasilenkimo tarp laivų skaičiavimas radaru arba elektroniniuose jūrlapiuose gali klaidinti.


Pasiūlytas stebimo laivo maršruto prognozavimo modelis yra skirtas prognozuoti laivo judėjimą bendrame laivų sraute, judančiame į tam tikrą uostą. Laivui esant už tokio srauto, būsimą posūkio tašką taip pat galima prognozuoti, tačiau su didesne paklaida. Tai įmanoma, jeigu stebimo laivo judėjimo kryptis nukreipta į bendrą laivybos srautą ir sraute sutampa su posūkio tašku, pagal kurį apmokytas DNT. Esant paklaidai, sudėtinga nustatyti, ar laivas juda link bendro laivybos srauto, ar vis tik tokio laivo kelionės tikslas yra kitas uostas. Šiuo atveju anomalija yra situacija, kai laivas nėra bendrame laivybos sraute į tam tikrą uostą, tačiau pagal AIS perduodamus duomenis turi keliauti į tą (konkretų) uostą. Šiai anomalijai nustatyti toliau pasiūlytas būdas, pagrįstas atstumo tarp artimiausių kaimyninių taškų vertinimu.

Nustatant anomalijas, imamas konkretus laivybos srautas į tam tikrą uostą. Tokio srauto pavyzdys pateiktas 38 paveiksle. Taškais yra pažymėti posūkio taškų klasterių centrai. Pasirinkti atsitiktiniai taškai laivybos sraute, jie sunumeruoti ir pažymėti × simboliu.




38 pav. Suklasterizuotas laivybos srautas

Kaip minėta, esant anomaliai laivų judėjimui, jų padėtys nepatenka į bendrą laivybos srautą. Toks judėjimas gali vykti bet kuria kryptimi srauto atžvilgiu. Anomalius keturių laivų judėjimas parodytas 39 paveiksle.



39 pav. Anomalus laivų judėjimas srauto atžvilgiu

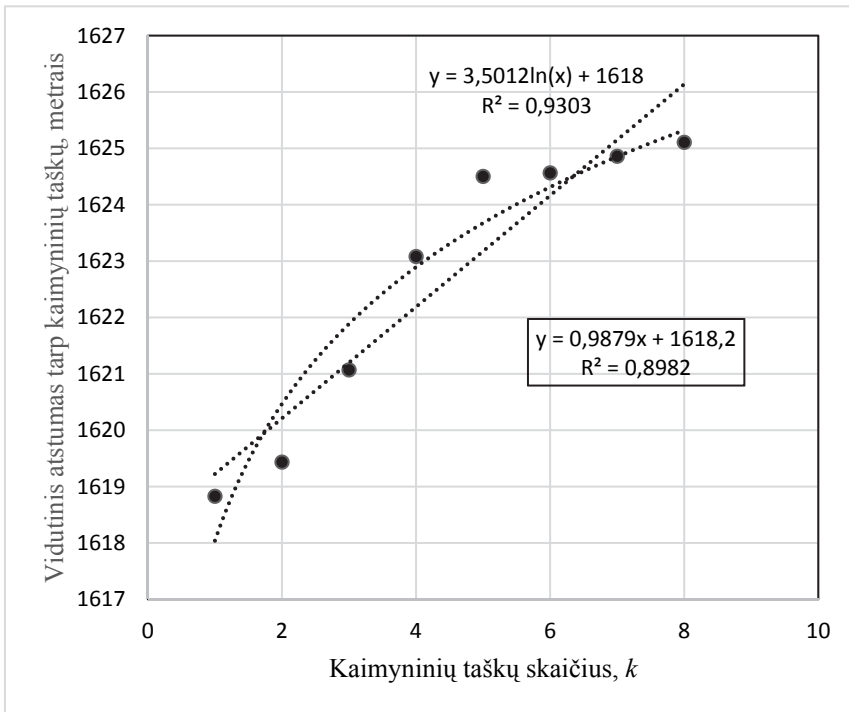
Pagrindinis šių anomalinių taškų (laivų) išskirtinumas yra jų atstumas iki bendro laivybos srauto. Atstumas leidžia vizualiai įvertinti, kad šie taškai yra anomalūs, tačiau reikia tai apskaičiuoti. Apskaičiavimui atlikti pritaikytas k -artimiausių kaimynų metodas. Suskaičiuotus atstumų vidurkius tarp k -artimiausių kaimyninių taškų visame laivybos sraute galima palyginti ir apskaičiuoti atstumo priklausomybę nuo nagrinėjamų kaimyninių laivų skaičiaus. Nagrinėjame atvejus, kai $k=1, \dots, 8$. 40 pav. rezultatai gauti atvejui, kai nėra anomalijų taškų. Vidutinis atstumas didėja priklausomai nuo kaimyninių taškų skaičiaus. Priklausomybę aproksimuojame naudodami regresiją: tiesinę, kvadratinę ir logaritminę. Visais atvejais stebimas determinacijos koeficiento R kvadratas – jis yra artimas 1, o tiesinis arba kvadratinis modelis ypač gerai aprašo duomenis.



40 pav. Vidutinis atstumas tarp kaimynų laivybos sraute į tą patį uostą

Taip pat apskaičiuotas vidutinis atstumas įtraukus 4 anomalius taškus. Artimiausių kaimynų skaičius toks pat – $k=1, \dots, 8$. Rezultatas labai skiriasi nuo normalaus laivybos srauto, pavaizduoto 41 paveiksle. Šiuo atveju tiesinis modelis prasčiau aproksimuoja taškus už logaritminį.

Įvertinus rezultatus, pateiktus 41 ir 42 paveiksluose, galima teigti, kad tarp (a) k kaimyninių taškų vidutinio atstumo ir (b) to, ar laivai yra tik bendrame sraute, ar jų yra ir už bendro laivybos srauto, yra priklausomybė. Navigacijos duomenyse esant laivų, kurie yra už bendro laivybos srauto, k kaimyninių taškų vidutinio atstumo priklausomybė nuo k pakinta iš tiesinės į netiesinę (logaritminę).



41 pav. Vidutinis atstumas tarp laivybos srauto ir anomalinių taškų

Kitas eksperimentas atliktas vertinant galimybę aptikti, ar konkretus laivas yra už laivybos srauto. Tokiam laivui aptikti buvo vertinama atstumu tarp pasirinkto laivo ir jo $k=8$ artimiausių kaimynų dispersija, t. y. kiekviena dispersija apskaičiuojama pasirinkus aštuonis taškus, kurie yra laivybos sraute. Tyrimai parodė (1 lentelė), kad laivui už laivybos srauto apskaičiuota dispersija yra daug mažesnė už apskaičiuotąją laivui, kuris yra bendrame laivybos sraute. 1 lentelėje kaip visas laivybos srautas suprantami posūkio klasterių taškai.

Remiantis gautais rezultatais (40 pav., 41 pav. ir 1 lentelė), galima įvertinti ir nustatyti laivą, esantį už bendro laivybos srauto, pagal šiuos požymius:

- 1) Vidutinis atstumas tarp bendrame laivybos sraute nesančio laivo ir laivybos sraute esančių kelių artimiausių kaimyninių laivų yra daug didesnis už vidutinį atstumą, apskaičiuotą bendrame laivybos sraute esantiems laivams;

- 2) Vidutinė atstumo tarp pasirinkto laivo ir kelių artimiausių kaimyninių laivų dispersija yra daug didesnė laivams, pasirinktiems iš bendro laivybos srauto, nei laivams, kurie yra už bendro laivybos srauto; ši dispersija mažėja didėjant atstumui tarp laivo ir bendro laivybos srauto.

1 lentelė. Taškų dispersijos palyginimas

Taškai		Dispersija (metrais)
Vidutinis atstumas tarp laivų, esančių laivybos sraute		53,92
Taškai laivybos sraute (žr. 35 pav.)	1	72,71
	2	52,83
	3	25,49
	4	52,51
	5	38,72
	6	28,09
	7	139,36
	8	22,72
	9	70,82
	10	84,57
Taškai už laivybos srauto (žr. 36 pav.)	1	15,65
	2	10,16
	3	8,00
	4	5,70

3.7. Skyriaus apibendrinimas

Atlikus laivybos maršrutų prognozavimo ir anomalijų aptikimo metodų analizę, galima daryti šias išvadas:

1. Papildomas duomenų agregavimas yra būtinas, kadangi istorinių laivybos duomenų kiekiai yra didžiuliai. Atlikus duomenų agregavimą DBSCAN algoritmu ir išskiriant klasterizuotus posūkio taškų centrus labai palengvinamas maršruto prognozavimas.
2. Naudojant DNT galima prognozuoti kitą stebimo laivo maršruto posūkio tašką bei modeliuoti visą laivo maršrutą į paskirties uostą. Maršrutas / posūkio taškas prognozuojamas su paklaidomis, tačiau prognozavimo tikslas yra ne kuo tiksliau atkartoti visą stebimo laivo maršrutą, o numatyti, kokie gali būti stebimo laivo veiksmai.

Atsižvelgiant į prognozes, galima planuoti manevravimą, siekiant išvengti susidūrimų arba pavojingų situacijų.

3. Anomalijų laivybos sraute aptikimas yra labai svarbus, siekiant išvengti pavojingų situacijų bei numatant stebimo eismo dalyvio veiksmus. Duomenų analizei panaudojus informaciją apie k artimiausius kaimynus (vidutiniškai visame sraute arba konkrečiam laivui), galima įvertinti, ar bendrame laivybos sraute yra neįprastai judančių laivų ir tam tikrą paskirties uostą ir juos identifikuoti. Navigacijos duomenyse esant laivų, kurie yra už bendro laivybos srauto, vidutinio atstumo tarp k kaimyninių taškų priklausomybė nuo k pakinta iš tiesinės į netiesinę (logaritminę).
4. Laivo maršrutų posūkio taškų / maršrutų prognozavimas bei anomalijų aptikimas yra labai svarbus, siekiant užtikrinant bendrą laivybos saugumą. Pasiūlyti metodai gali būti plačiai pritaikomi tiek laivyboje, tiek laivybos eismo stebėjimo tarnyboms stebint laivus realiuoju laiku pagal nuolat kintančius didelius duomenų kiekius.

4. KONTEKSTINE INFORMACIJA GRĮSTO PROGNOZAVIMO METODAS

Šiame skyriuje pateikiamas kompleksinis metodas, paremtas kontekstine informacija pagrįstu posūkio taško prognozavimu ir vertinimu. Ši prognozė vertinama siekiant išpėti apie galimą neįprastą situaciją dar nesant akivaizdiems jos požymiams.

Šio skyriaus medžiagos dalis publikuota [138] straipsnyje.

4.1. Kontekstine informacija grįstas prognozavimo metodas

Norint priimti teisingą sprendimą, labai svarbu įvertinti ir atsižvelgti į esamą kontekstą. Kontekstinė informacija, kuria remiantis priimamas sprendimas, vadinama kontekstinėmis žiniomis [121]. Kontekstinės žinios nėra susijusios su siekiamu tikslu arba uždaviniu. Tačiau siekiant užsibrėžto tikslo, kontekstinės žinios naudojamos sprendimams priimti [122], t. y. sprendimams priimti naudojamas procedūrizuotas kontekstas. Labai svarbu į tai atsižvelgti, nes tokioje pačioje situacijoje tas pats sprendimas gali lemti skirtingą rezultatą. Kontekstinės žinios gali paaiškinti, kodėl, kas ir kaip vyksta konkrečioje situacijoje. Dėl dalyvių skirtingai suvokiamo konteksto ta pati situacija gali būti labai skirtingai interpretuojama – situacijos suvokimas priklauso nuo dalyvių pasaulio suvokimo ir turimos patirties.

Priimant sprendimus labai svarbų vaidmenį atlieka patirtis. Patirtis įgyjama mokantis ir gebant taikyti įgytas žinias praktiškai konkrečiose situacijose bei darant atitinkamas išvadas. Šios išvados taip pat labai svarbios, nes yra pritaikomos ateityje. Todėl žmogus, numatydamas ateitį, remiasi turimais duomenimis, tačiau ne mažiau svarbūs faktoriai yra kontekstas ir įgyta patirtis.

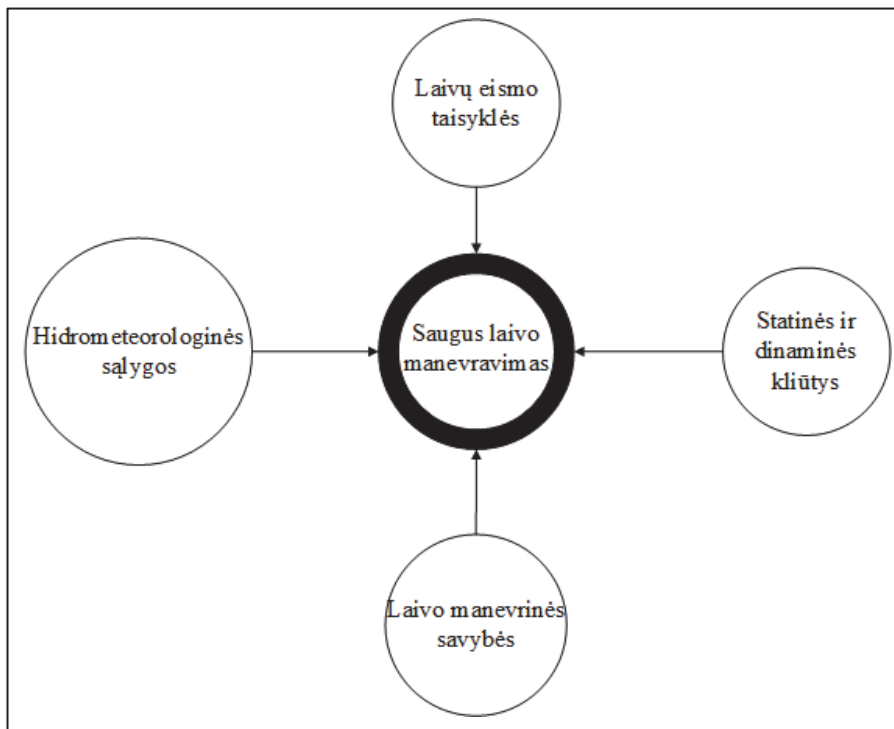
Pagrindinis kompiuterio ir žmogaus informacijos apdorojimo skirtumas yra kontekstinės informacijos suvokimas ir pritaikymas konkrečiai situacijai. Kitaip nei kompiuteris, žmogus lengvai gali pasidalyti kontekstinėmis žiniomis, kurios yra labai naudingos priimant optimalų sprendimą, su kitais asmenimis. Siekiant mašininio mokymosi algoritmui perteikti kontekstinę informaciją, ją reikia papildomai susisteminti, paruošti ir pateikti kaip statistinius duomenis. Tad kontekstinių duomenų paruošimo procesas labai reikalauja žmogiškojo darbo. Tačiau šis papildomas duomenų paruošimas neužtikrina, kad bus pasiektas toks pats rezultatas, kaip ir sprendimą priimant žmogui.

Turintis patirties žmogus, pagal kontekstą vertindamas pateiktus duomenis, gauna suvokimą apie esamą situaciją ir jį panaudoja priimdamas sprendimus. Šis suvokimas nurodo į savivoką, t. y. padeda suvokti paties žmogaus padėtį konkrečioje situacijoje ne tik išorės, bet ir kitų situacijos dalyvių patirties bei galimų situacijos sprendimų priėmimo atžvilgiu. Savivoka suteikia galimybę veikti tikslingai ir įgyti patirties kaupiant žinias. Lygindamas kitų žmonių veiksmus ir įvertindamas galimus motyvus, žmogus susidaro tam tikrą savo paties vaizdinį. Šis vaizdinys padeda kognityvinėmis funkcijomis mokytis iš savo patirties – klaidų, įvertinti savo reikšmingumą situacijoje bei siekti tolesnio tobulėjimo. Toks kognityvinis vertinimas suteikia galimybę atskirti tinkamą (normalų) elgesį nuo pavojingo (nenormalaus) elgesio. Taip pat labai svarbu yra tai, kad kognityvinis vertinimas leidžia įvertinti ir prognozuoti kitų asmenų veiksmus ir poelgius.

Savivoka suteikia galimybę priimti teisingus sprendimus tam tikroje situacijoje, kitaip nei tradiciniai mašininio mokymosi algoritmai. Mašininio mokymosi algoritmai negeba vertinti konteksto ir neturi kognityvinio vertinimo funkcijos.

4.2. Laivybos kontekstas

Saugaus laivo plaukimo užtikrinimas – sudėtingas kompleksinis uždavinys. Bendras laivybos saugumas priklauso nuo įvairių faktorių, kurie įvairiose situacijose turi skirtingą įtaką. Taip pat jų tarpusavio poveikis gali būti skirtingas. Šiuos faktorius privalo įvertinti laivavedys, kuris ir priima sprendimą konkrečioje situacijoje. Laivavedys, vertindamas įvairius faktorius, pirmiausia remiasi turimomis žiniomis ir savo patirtimi. Faktoriai daro skirtingą įtaką sprendimui, todėl sunku nuspręsti, kuris faktorius yra pagrindinis ir lemia konkretų sprendimą, žr. 42 pav.



42 pav. Įvairūs faktoriai, turintys įtaką saugiai laivybai

Pirmiausia laivavedys privalo laikytis tarptautinės konvencijos dėl tarptautinių taisyklių, padedančių išvengti laivų susidūrimų jūroje [1]. Šios taisyklės yra paprastos ir lengvai įgyvendinamos, tačiau dažniausiai nelaimės įvyksta todėl, kad laivavedžiai nepriima teisingo sprendimo laiku arba tikisi, kad sprendimą priims stebimo laivo atsakingas asmuo. Tad dažnai pasitaiko, kad abu susidūrusių laivų laivavedžiai yra kalti dėl avarijos.

Kitas labai svarbus faktorius, darantis įtaką saugiai laivybai, yra įvairios kliūtys. Tai gali būti dinaminės (įvairūs nekonvenciniai laivai ar laivai, užsiimantys tam tikra veikla – žvejybiniai, kabelių klojimo ir pan.) ir statinės – geografinės kliūtys (seklumos, rifai, uolos) ar kiti objektai, netyčia atsidūrę vandenyje, pavyzdžiui, konteineriai. Dažniausiai sunku tokias kliūtis pastebėti, todėl labai sumažėja laikas, per kurį turi būti priimtas optimalus sprendimas dėl manevravimo. Dar vienas svarbus dalykas yra tas, kad privalu aplenkėti tokias kliūtis, nesudarant avarinių situacijų su kitais laivais.

Laivo dinaminės savybės labai svarbios saugiai laivybai. Visada privaloma įvertinti savo ir stebimo laivo manevrines savybes prieš atliekant manevrą. Šis aspektas labai svarbus, kadangi dėl didelių laivo gabaritų ir laivo inercijos, pradėjus manevro veiksmą (pasukus vairo plunksną), laivas tik po kurio laiko pradeda į tai reaguoti. Atsižvelgiant į šią aplinkybę, visas manevras

gali užtrukti net keliolika minučių, o laivo stabdymo atstumas gali siekti ir kilometrą.

Ypač svarbus faktorius yra hidrometeorologinės sąlygos. Didelę įtaką laivo judėjimui daro bangos, vėjas ir povandeninės srovės. Vėjo ir povandeninių srovių poveikis kiekvienam laivui yra individualus, pavyzdžiui, kuo didesnis laivo paviršiaus plotas virš vandens, tuo didesnę poveikį daro vėjas. Atitinkamai povandeninės srovės veikia laivo povandeninę dalį. Vertinant bendrai, laivą veikia vėjo ir srovės jėgų vektorinė suma, tad ypač svarbu į ją atsižvelgti laivui keičiant judėjimo kryptį. Dėl šių jėgų poveikio keičiant judėjimo kryptį pagal suplanuotą kelią, laivas neplanuotai gali nukrypti į šoną net kelis šimtus metrų, taip sukeldamas pavojų sau ir kitiems laivybos dalyviams.

Sunku išskirti lemiančius ar pagrindinius faktorius, kurie daro įtaką priimant sprendimą. Konkrečią situaciją reikia vertinti ir bandyti suprasti, kodėl priimtas tam tikras sprendimas. Kaip minėta ankstesniame skyriuje, kontekstinė informacija tampa kontekstinėmis žiniomis tik tada, kai ja remiantis priimamas konkretus sprendimas. Šiame darbe kontekstinės žinios paremtos tik istoriniais laivų maršrutais ir iš duomenų gauta manevravimo informacija. Šios kontekstinės žinios neapima visų minėtų faktorių, galinčių daryti įtaką priimant sprendimą, tačiau yra tiesiogiai susijusios su saugios laivybos užtikrinimu – plaukimas tam tikru suplanuotu laivybos maršrutu yra susijęs su atliekamais manevrais. Yra ir atvirkštinė sąsaja, t. y. atliekami manevrai priklauso nuo pasirinkto maršruto. Esant tokiam sąryšiui, lengva išskirti neįprastą situaciją pagal konkrečius požymius:

- manevras, atliekamas ne pagal suplanuotą maršrutą;
- plaukimas ne pagal suplanuotą maršrutą.

Disertacijoje neįprastoms situacijoms aptikti pagal šiuos požymius panaudoti iš istorinių laivybos duomenų (duomenys aprašyti 2.6 skyriuje) gautos kontekstinės žinios – laivybos maršrutai ir laivų manevrai. Kontekstinių žinių pritaikymas užtikrina galimybę numatyti ir iš anksto įvertinti galimus stebimo laivo veiksmus. Galimų stebimo laivo veiksmų prognozavimas yra labai svarbus užtikrinant saugią laivybą, nes:

1. Įspėja apie galimą pavojų ir poreikį atidžiai stebėti konkretaus laivo manevrus;
2. Suteikia galimybę iš anksto planuoti manevravimą, siekiant išvengti pavojingo prasilenkimo;
3. Prognozės nesutapimas su stebimo laivo manevrais taip pat signalizuoja apie neįprastą situaciją, o tai reikalauja atidesnio stebėjimo.

Sukurta įvairių technologijų saugiai laivybai užtikrinti, tačiau nė viena šiuolaikinė technologija neįspėja laivavedžio apie prognozuojamą neįprastą situaciją. Tokios technologijos, kaip minėta ankstesniuose skyriuose, skirtos informuoti ir perspėti tik apie dabartinę situaciją. Tad išsiaiškinti galimus stebimo laivo veiksmus įmanoma tik tiesiogiai komunikuojant ir klausiant laivų radijo ryšiu.

Nepaisant technologinės pažangos, sudėtinga prognozuoti ir vertinti galimus stebimo laivo manevrus. Labai sudėtinga užduotis yra esamos laivybos situacijos (konteksto) vertinimas, išskiriant kontekstines žinias, bei kito laivavedžio veiksmų prognozavimas ir maršruto pokyčių numatymas. Dėl šių priežasčių visus sprendimus priima laivavedys.

4.3. Saugios laivybos užtikrinimo metodas

Disertacijoje pasiūlytas saugios laivybos užtikrinimo metodas remiasi priežastinių ir pasekminių ryšių nustatymu. Šiems ryšiams įtaką daro esamos aplinkybės, sąlygos / apribojimai ir kiti įtaką saugiam manevravimui konkrečioje situacijoje darantys faktoriai. Priežastiniam ir pasekminiam ryšiui nustatyti naudojamas kontekstinėmis žiniomis grįstas būsimos situacijos vertinimas pagal neįprastos situacijos požymius:

1. Manepravimas ne pagal suplanuotą / prognozuojamą stebimo laivo maršrutą;
2. Laivo plaukimas ne pagal suplanuotą maršrutą.

Šis vertinimas atitinkamai paremtas dviem skirtingais mašininio mokymosi metodais, naudojamais skirtingiems uždaviniams spręsti. Būsimos situacijos vertinimas yra vykdomas realiuoju laiku ir nereikia laukti papildomų / būsimų duomenų, tačiau kas kartą atsinaujinus navigacijos duomenims, patikslintas situacijos vertinimas gali būti atliekamas iš naujo.

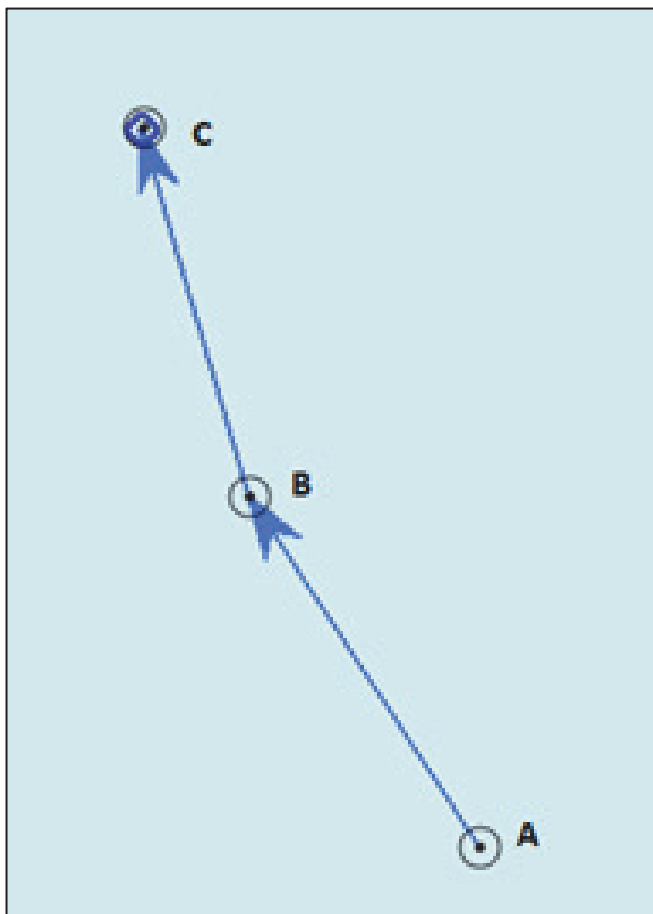
Įprastai manevravimo situacija susideda iš bent dviejų ar daugiau laivų. Norint užtikrinti saugų laivų prasilenkimą, būtina numatyti ir įvertinti stebimo galimą laivo maršruto pasikeitimą. Šį veiksma būtinyje atlikti iš anksto, nes reikia turėti laiko manevrui atlikti bei įvertinti būsimo manevro saugumą kitų dalyvių atžvilgiu. Šis sprendimas ypač svarbus, nes manevras ar būsima situacija po atlikto manevro neturi kelti pavojaus kitiems laivybos dalyviams. Be to, būsimo manevro atlikimo tikslas turi būti aiškiai suformuluotas, suprantamas ir kitiems laivybos dalyviams. Dėl šios priežasties laivybos taisyklėse pateikiamas šis reikalavimas: jei prasilenkimo metu reikia keisti kursą, jo keitimas turi būti ne mažesnis kaip 30°, kad kiti laivybos dalyviai pamatytų ir suprastų atliekamą manevrą.

Siūlomas situacijos vertinimo metodas atlieka vertinimą tokia žingsnių seka:

1. Prognozuoja stebimo laivo būsimą posūkio tašką;
2. Įvertina prognozuojamą stebimo laivo manevrą, ar jis yra įprastas, ar neįprastas ir ar gali sukelti pavojų;
3. Įvertinus prognozuojamą laivo manevrą kaip potencialiai pavojingą, galimi šie veiksmai:
 - a. Jeigu yra saugus atstumas iki potencialiai pavojingo laivo, kartojami 1 ir 2 žingsniai su atnaujintais navigacijos duomenimis;
 - b. Jei atstumas iki potencialiai pavojingo laivo tampa nesaugus, laivavedys priima sprendimą dėl manevravimo vadovaudamasis laivybos taisyklėmis.

Pasiūlytas metodas grindžiamas per AIS gaunamais navigacijos duomenimis. Navigacijos duomenis transliuoja visi laivyboje dalyvaujantys laivai. Taip užtikrinamas navigacinių duomenų atnaujinimas laiku. Tačiau dėl duomenų atnaujinimo kyla ir duomenų apdorojimo problema, nes reikia apdoroti didelius duomenų kiekius. Todėl kad pasiūlytas metodas funkcionuotų, būtinas duomenų agregavimas, detaliau išnagrinėtas 4.4 skyriuje. Duomenų agregavimas skirtas posūkio taškams klasterizuoti. Taip pat, kaip minėta 3.2 skyriuje, klasterizavimas sujungia posūkio taškus, per kuriuos laivai keliauja panašiais maršrutais iš uosto A į B. Duomenų agregavimas stipriai sumažina bendrą navigacijos duomenų kiekį – pradinis duomenų kiekis yra 19 GB, o po klasterizavimo liko 237 MB duomenų. Agregavimas palieka išskirtus reikšmingus posūkio taškus. Gauti klasterių geografiniai centrai naudojami tolesniems skaičiavimams.

Pasiūlytas metodas naudoja esamą laivo padėtį ir du maršruto posūkio taškus. Kaip pavaizduota 43 pav., taškas A yra dabartinė stebimo laivo padėtis, o taškas B – kitas maršruto posūkio taškas. Posūkio taškas B yra apskaičiuotas klasterio centras, nustatomas pagal laivo judėjimo kryptį, t. y. keliamą prielaidą, kad laivas tam tikra kryptimi juda link kito savo posūkio taško. Posūkio taškas C yra būsimas posūkio taškas – po to, kai laivas, judėdamas tam tikru maršrutu, pakeis kursą B posūkio taške. Posūkio taškas C taip pat yra apskaičiuotas tam tikro kito klasterio centras.



43 pav. Posūkio taškų vizualizacija


Posūkio taškas C yra svarbus, norint numatyti bei įvertinti laivo tolesnį judėjimą. Todėl pirmuoju žingsniu prognozuojama stebimo laivo posūkio taško C padėtis (koordinatės). Numačius posūkio taško C padėtį, galima įvertinti prognozuojamą maršrutą. Nedidelis posūkis (bukas kampas tarp ABC taškų – 43 pav.) reiškia, kad viskas vyksta pagal suplanuotą maršrutą, o staigus posūkis (smailus kampas tarp ABC taškų – 43 paveikslas) reiškia neįprastą situaciją, nes atliekamas staigus manevras.

Būsimam posūkio taškui (posūkio taškas C) prognozuoti tinkamas klasifikatorius yra sprendimo medžio tipo. Sprendimų medis parenka tinkamą sprendimą pagal tam tikrus požymius ir sąlygas. Šis klasifikatorius yra apmokomas agreguotais istoriniais navigacijos duomenimis, o jo rezultatas yra būsimos posūkio taško koordinatės. Turint būsimos posūkio taško koordinatės, reikia būsimos situacijos vertinimo – ar ji įprasta, ar ne. Prognozuojamai situacijai vertinti tinka dviejų klasių klasifikatorius [123].

Tačiau neįprastų taškų paprastai būna nedaug, todėl galima naudotis ir vienos klasės klasifikatoriumi, tokiu kaip atraminių vektorių vienos klasės klasifikatorius (angl. *One-Class SVM*) [124].

Neįprasta situacija nebūtinai turi būti pavojinga. Neįprastus posūkius gali atlikti žvejyba užsiimantis laivas, pavėjui plaukiantis būrinis laivas ir t. t., tačiau planuojant tolesnius manevrus būtina atkreipti dėmesį į tokius laivybos dalyvius.

Neįprastus manevrus išskirti iš visų duomenų yra sudėtinga. Tokio tipo manevrai neturi nusistovėjusių bendrų bruožų, tad nelengva nustatyti, kuri konkreti situacija buvo pavojinga, o kuri – įprasta. Būtina atsižvelgti į konkrečias aplinkybes. 44 paveiksle pavaizduota panaši situacija, tik b) dalyje ji yra a) dalies apverstas vaizdas, t. y. apversta 180°. Nepaisant to, kad situacijos panašios, pagal laivybos taisykles laivai, kurie privalo imtis veiksmų, smarkiai keičiasi. Panašių situacijų gali būti pačių įvairiausių, besiskiriančių kitokiais minimaliais pokyčiais. Todėl manevravimo situacijų lyginimas yra sudėtingas, o neįprastų situacijų aptikimas tampa neįgyvendinamas, jei yra lyginamos tik manevravimo situacijos.



44 pav. Manevravimo situacijų palyginimas

Pasiūlytas mašininio mokymosi metodas, sujungiantis du mašininio mokymosi algoritmus, padeda aptikti neįprastus manevrus. Tai atliekama įvertinus kontekstines žinias, įgyjamas iš istorinių navigacijos duomenų. Dviem skirtingais metodais įgyjamos dviejų tipų kontekstinės žinios:

- apie laivybos maršrutus;
- apie neįprastas laivybos situacijas.

Vertinimo procesui sujungti naudojami du metodai papildo vienas kitą. Naudojant tik sprendimų medį, galima prognozuoti tik galimą būsimą posūkio tašką. Naudojant *One-Class SVM* galima įvertinti situaciją, tačiau negalima prognozuoti. Tad sujungus abu metodus galima įvertinti prognozuojamą būsimą posūkio tašką, sudarant dalį galimo maršruto. Sprendimo medžiu prognozuojant būsimą posūkio tašką (C taškas), *One-Class SVM* algoritmu galima įvertinti prognozavimą prieš laivui pasiekiant kitą posūkio tašką (B

taškas). Atnaujinant prognozavimo vertinimą ir kaskart atsinaujinant navigacijos duomenims, užtikrinamas nuolatinis manevravimo situacijos vertinimas ir stebėjimas visų laivybos dalyvių atžvilgiu.

4.4. Navigacijos duomenų paruošimas

Laivų judėjimas generuoja didelius navigacijos duomenų kiekius. Navigacijos duomenys siunčiami per AIS sistemą kas kelias sekundes visiems laivybos dalyviams, tačiau iš šių duomenų sudėtinga nustatyti neįprastas manevravimo situacijas, tokias kaip pavojingas laivų prasilenkimas. Neįprastos manevravimo situacijos neišsiskiria iš bendro navigacijos duomenų srauto, nes kiekvienas atsakingas asmuo situaciją vertina individualiai konkrečiu metu. Todėl net tą pačią manevravimo situaciją gali nevienodai ar subjektyviai įvertinti skirtingi asmenys.

Didelius navigacijos duomenų kiekius reikia agreguoti. Agregavimas palengvina duomenų apdorojimą, sumažina duomenų kiekį ir išgrynina svarbią informaciją. Duomenims agreguoti sukurta įvairių algoritmų, tačiau navigacijos duomenims apdoroti patogiausia naudoti tankiu grindžiamus klasterizavimo algoritmus (detaliau žr. 3.2 skyriuje), kaip, pavyzdžiui, DBSCAN [111] ar OPTICS (angl. *Ordering Points to Identify the Clustering Structure*) [125]. Šie algoritmai grupuoja duomenis ne tik pagal atstumą tarp objektų, tačiau atsižvelgia ir į kaimyninių objektų išsidėstymo tankį (tankio funkcija). Detaliau DBSCAN algoritmas aprašytas 3.2 skyriuje.


Naudojant DBSCAN algoritmą labai svarbus yra ε – skersmens parametras. Kaip aprašyta 3.2 skyriuje, šis parametras nustatomas empiriniu būdu, tačiau nustatyti visai duomenų apimčiai tinkamą parametą yra sudėtinga ir nepraktiška. Šiai problemai spręsti naudojamas OPTICS algoritmas. OPTICS algoritmui, taip pat kaip ir DBSCAN, reikalingi parametrai: ε ir *MinPts*. Be to, OPTICS algoritmas naudoja du papildomus parametrus: *atstumas* nuo pagrindinio taško (angl. *Core Distance*) ir *pasiekiamumo* (angl. *Reachability Distance*) atstumas. Kiekvienas duomenų imties taškas (o , q) aprašomas atstumu nuo *pagrindinio* taško p , ir tai yra atstumas iki *MinPts*-tojo artimiausio taško. Taško o *pasiekiamumo* atstumas yra atstumas tarp taškų o ir q , arba atstumas nuo *pagrindinio* taško iki q , priklausomai nuo to, kuris didesnis.

Navigacijos duomenų agregavimas OPTICS algoritmu vykdomas apdorojant laivų posūkio taškus. Laivo posūkio taškas yra padėtys (ilguma ir platumas), kurios išfiltruotos pagal laivo kurso pokytį. Atrenkamos tokios padėtys, kuriose kursas pasikeitė daugiau kaip 4° . Šis filtravimas reikalingas

atskirti atsitiktinius taškus, tokius kaip dėl laivo siūbavimo, vėjo ar povandeninių srovių atsirandantys nedideli kurso pasikeitimai.

OPTICS generuoja surūšiuotą posūkio taškų sąrašą. Posūkio taškai susiejami pagal *pasiekiamumo* parametą. OPTICS algoritmas apdorojimo metu mažina kiekvieno posūkio taško *pasiekiamumo* atstumą. Kiekvienas neapdorotas posūkio taškas yra naujas klasteris. Naujojo klasterio kaimyniniai taškai pridedami į apdorojimo eilę ir surūšiuojami pagal mažiausią *pasiekiamumo* parametą. OPTICS algoritmas sugeneruoja rezultato sąrašą, kuriame posūkio taškai išrūšiuojami pagal *pasiekiamumo* parametą. Klasteriai identifikuojami pagal staigius *pasiekiamumo* parametro pokyčius. Jeigu nurodytas parametras ϵ , jis naudojamas klasterizavimui. Jeigu parametras nėra nurodytas – algoritmas pats apskaičiuoja klasterius.

Kitas duomenų agregavimo žingsnis – klasterių geografinių centrų apskaičiavimas. Atsižvelgiant į tai, kad laivas niekada netaiko atlikti manevro tiksliai į tą patį posūkio tašką, skaičiavimai pakankamai tikslūs, kai posūkio tašku nustatomas klasterio geografinis centras.



45 pav. OPTICS algoritmo klasterizavimo rezultatas

Agreguotus duomenis sudaro posūkio taškų klasteriai. Šiuose klasteriuose laivai keičia kursą į kitą posūkio taškų klasterį. Iš klasterių

sudaryta seka atspindi laivų maršrutą iš uosto A į uostą B (45 paveikslas). Iš klasterių sudarytas maršrutas yra laivų judėjimo kontekstinės žinios. Šiuo atveju kontekstinės žinios apibendrina tarp uostų keliaujančių jūrinių patirtį.

Šiame eksperimente panaudoti 6 mėnesių duomenys. Šie duomenys buvo filtruojami pagal tai, ar galima sudaryti nuoseklų laivo paros judėjimo maršrutą. Po filtravimo navigacijos duomenys sudaro 19 GB. Paskui šie duomenys išfiltruoti pagal tai, kuriuose taškuose kursas pasikeitė daugiau kaip 4° , ir duomenų apimtis sumažėjo iki 4 GB. 4 GB duomenų buvo suklastertizuoti OPTICS algoritmu, o galiausiai gauta 237 MB duomenų imtis. Šie duomenys apima informaciją apie laivų judėjimą pagal klasterius. OPTICS algoritmo taikymas yra svarbus dėl kelių priežasčių:

1. Posūkio taškų klasterizavimas padeda išskirti sritis, kuriose laivai reikšmingai keičia kursą. Šios sritys dažniausiai sutampa su tam tikru maršrutu;
2. Pritaikant pasiūlytą metodą darbui realiomis sąlygomis, reikia kuo didesnės navigacijos duomenų imties. Kaip minėta 2.2 skyriuje, per metus susidaro apie 744 GB navigacijos duomenų vien tik prie Danijos krantų. Panaudojus, pvz., 10-ties metų navigacijos duomenis, pasiūlytas duomenų klasterizavimas labai palengvina darbą su tokiais duomenimis, nes leidžia juos agreguoti.

4.5. Duomenų klasifikavimas sprendimų medžiu


Sprendimų medžio algoritmas yra mašininio mokymosi metodas, skirtas klasifikavimo uždaviniams spręsti. Sprendimų medžio algoritmas priklauso prižiūrimo mokymo (angl. *Supervised Learning*) [126] [127] [128] kategorijai. Klasifikuojant duomenis sprendimų medžio algoritmas siekia padalyti ir paskirstyti duomenis į iš anksto žinomas klases. Duomenų klasifikavimas vyksta dalijant duomenis pagal tam tikrus požymius, siekiant sumažinti entropiją. Sprendimo medžio algoritmo rezultatas – į medį panaši „žinių“, sprendimų struktūra, skirta rezultatui prognozuoti. Ši struktūra aprašo taisykles, pagal kurias įvedami duomenys yra klasifikuojami.

Sprendimų medis pasirinktas, nes yra spartus ir lengvai interpretuojamas. Tai labai svarbu prognozuojant būsimą stebimo laivo posūkio tašką. Sprendimų medžio algoritmas apmokomas laivo judėjimo duomenimis (judėjimo kryptis ir greitis) ir duomenimis, gautais pritaikius OPTICS algoritmą:

1. Esama laivo padėtis – taškas A (ilguma, platumas);

2. Būsims posūkio taškas (B) – ilguma, platuma, apskaičiuojama pagal laivo kursą į artimiausią posūkio taškų klasterį;
3. Būsims posūkio taškas C (ilguma ir platuma);
4. Laivo judėjimo kryptis ir greitis.

Duomenys, kuriais remiantis sprendimo medžio algoritmas prognozuoja C tašką, vizualiai pavaizduoti elektroninio jūrlapio dalyje (46 pav.). Problema yra ta, kad C taškas gali būti bet kuris posūkio taškas iš visų netoliese išsidėsčiusių posūkio taškų.



46 pav. Sprendimų medžio apmokymo duomenys

Sprendimų medis apmokomas klasifikuoti navigacijos duomenis, t. y. apmokomas laivybos kontekstinėmis žiniomis. Tačiau apmokytas modelis veikia tik konkrečioje geografinėje vietovėje, kuri priklauso nuo pateiktų duomenų apmokymo metu. Norint praplėsti šį geografinį apribojimą, reikėtų papildomais navigacijos duomenimis apmokyti sprendimo medžio algoritmą ir taip sprendinys galėtų atlikti didesnės teritorijos prognozes.

Didžiausią įtaką sprendimų medžio algoritmo apmokymo rezultatui daro didžiausio gylio (*maxdepth*) parametras. *maxdepth* parametras nurodo maksimalų sprendimo medžio algoritmo naudojamų šakų skaičių. Eksperimentuose panaudotas sprendimų medžio algoritmas, kuris yra realizuotas *scikit-learn* įrankiu [129]. Panaudotas sprendimų medžio metodas naudoja optimizuotą CART (klasifikavimo ir regresijos medžio) algoritmą. Algoritmo tikslas – rasti logines duomenų atskyrimo taisykles [130]. Sprendimo medžiui mokytį naudoti 462499 duomenų pavyzdžiai, iš šios duomenų imties 15 % panaudota testavimui. Naudota vidutinė kvadratinė prognozės paklaida (*mse*) duomenims dalyti. Sprendimo medis apmokytas agreguotais OPTICS algoritmo duomenimis, kad prognozuotų kitą būsimą posūkio tašką C. Apmokymui pateikti tokie duomenys: esamos laivo koordinatės (x_1, x_2) – taškas A, kito posūkio koordinatės (x_3, x_4) – taškas B, laivo kinematiniai duomenys – greitis (SOG) ir kursas (COG).

4.6. Neįprastų situacijų aptikimas

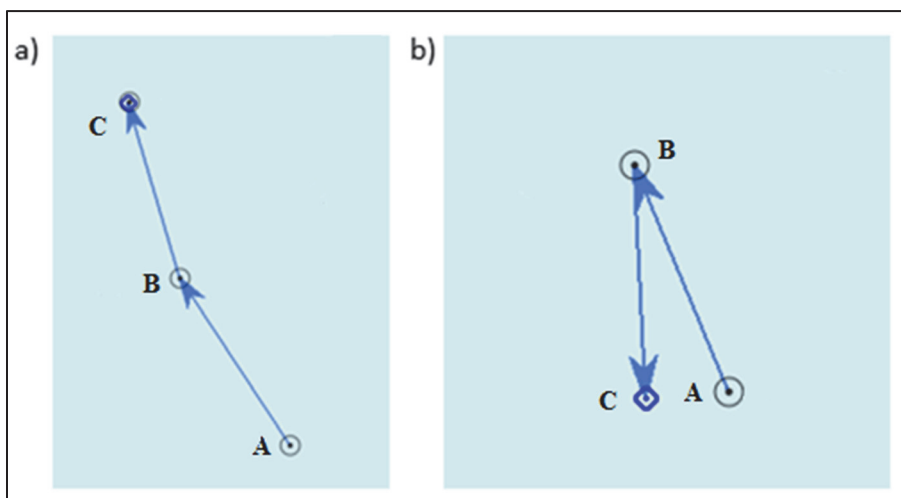
Laivyboje neįprastų situacijų gali susidaryti dėl įvairių priežasčių. Tokio pobūdžio situacijos gali būti tiek pavojingos, tiek nepavojingos laivybos dalyviams. Neįprasta situacija reikalauja papildomos analizės, norint suprasti priežastis bei galimas pasekmes. Todėl svarbu laiku aptikti tokias situacijas ir laiku pradėti analizuoti gaunamus navigacijos duomenis. Laivyboje neįprasta situacija gali susidaryti tada, kai laivas pernelyg arti prasilenkia su kitu laivu. Tad vengdamas galimos avarijos, laivas priverstas atlikti staigų išvengimo manevrą. Staigus posūkio atlikimas nėra įprastas, nes dėl didelių laivų matmenų toks veiksmas sukelia visą eilę problemų: susidaro papildomų kuro sąnaudų manevrui atlikti, reikia papildomai suplanuoti laivo grįžimą į numatytą maršrutą, prarandama laiko manevrui atlikti, manevro metu gali kilti pavojus susidurti su kitais laivais ir t. t. Dėl šių priežasčių neplanuotų manevrų vengiama, tikintis, kad kitas laivas pakeis judėjimo kryptį pagal nusistovėjusią gerąją jūrinę praktiką. Tačiau dažnai tokia strategija lemia laivų susidūrimą, nes nesiryžtama imtis veiksmų nedelsiant, o tikimasi, kad pavojinga situacija išsispręs.

Neįprastų situacijų aptikimas iš istorinių duomenų yra labai sudėtingas [131], [132], [133], nes tokias situacijas išskirti pagal kokius nors kriterijus nelengva. Vienintelis būdas yra analizuoti pavojingus laivų prasilenkimus ar įvykusias avarijas, tačiau tokia analizė yra labai ribota ir apima tik konkrečias, žinomas pavojingo manevravimo situacijas. Neįprastą situaciją yra sudėtinga nustatyti, nes remiamasi subjektyviu požiūriu į konkrečią situaciją. Tai reiškia, kad kiekvienas laivavedys turi savo asmeninę patirtį ir ja paremtą

požiūrį. Tai, kas vienam asmeniui atrodo normali situacija, kitam asmeniui gali atrodyti labai pavojinga ar neatitinkanti nusistovėjusios gerosios jūrinės praktikos.

Neįprastą situaciją išskirti yra sudėtinga. Šiame darbe iširtos galimybės pritaikyti naujovių aptikimo (angl. *Novelty Detection*) metodiką. Šią metodiką 1950 metais sukūrė neuropsichologas E. Sokolovas [134], [135] ir [136]. Naujovių aptikimas skirtas identifikuoti naujus arba visiškai nežinomus duomenų požymius, išskiriant anomalijas kaip atskiras, nežinomas duomenų grupes. Išskirtos anomalijos neatitinka bendros duomenų aibės charakteristikų. Anomalijos duomenų aibėje pasitaiko gana retai, tačiau gali lemti didelius duomenų aibės pokyčius.

Algoritmas *One-Class SVM* [137] panaudotas siekiant aptikti neįprastas situacijas iš istorinių laivybos duomenų. Šiame darbe neįprasta manevravimo situacija galėtų būti charakterizuojama kaip staigus manevras – t. y. smailus kampas $\angle ABC$ (47 paveikslo b dalis) lyginant su normaliu laivo judėjimu (47 paveikslo a dalis).



47 pav. a) normalus laivo judėjimas, b) neįprastas laivo judėjimas

Neįprasto judėjimo priežastys gali būti labai įvairios, tokios kaip pavyzdžiui, bandymas išvengti susidūrimo su kliūtimi (kitas laivas, plūduriuojantis objektas ir t. t.). Tačiau toks judėjimas gali būti ir normalus jachtos plaukimas, kuriam įtaką daro vėjo kryptis. Svarbu pažymėti, kad, neatsižvelgiant į galimas priežastis, būtina sutelkti dėmesį į tokį manevrą ir įvertinti, ar yra galimas susidūrimo pavojus.

Kaip aprašyta 4.5 skyriuje, sprendimų medis buvo apmokytas istoriniais navigacijos duomenimis. Algoritmas *One-Class SVM* apmokytas papildomai agreguojant OPTICS klasterizavimo duomenis:

1. *dist1* – atstumas tarp A ir B posūkio taškų metrais;
2. *dist2* – atstumas tarp B ir C taškų metrais;
3. *angle* – $\angle ABC$ laipsniais.

Tokių duomenų pateikimas apmokymui pagrįstas posūkio taško pasirinkimo priklausomybe nuo laivo greičio. Tiksliau tariant, esant gana dideliame laivo greičiui, sudėtinga atlikti staigius manevrus dėl laivo dydžio ir svorio (inercijos poveikis), tad tokiam staigiam manevrui atlikti turi būti labai sviri priežastis. Pateiktų apmokymui duomenų pavyzdys pateiktas 48 paveiksle.

<i>dist₁</i>	<i>dist₂</i>	$\angle ABC$
6174,521716	1287,871001	151,207152
671,350733	121,825336	129,923692
1526,956203	1590,687044	57,443675
1024,278923	24,308594	82,418407
46029,972439	44602,396607	163,378400
...
2500,948001	310,076441	100,690438
2762,535835	1864,934067	144,600721
28158,883863	24575,099968	172,394118
24293,263539	20709,932847	172,257642
5300,631150	4825,688549	160,690769

48 pav. Duomenų pavyzdys

Ekperimentuose naudotas *One-Class SVM* algoritmas, kuris yra realizuotas *scikit-learn* įrankiu [129].

4.7. Algoritmo apmokymas ir rezultatai

Kaip aprašyta ankstesniuose skyriuose, pasiūlytas mašininio mokymosi metodas yra kompleksiškas dviejų skirtingų mašininio mokymosi algoritmų veikimo rezultatas. Šie algoritmai yra mokomi skirtingai agreguotais duomenimis, gautais iš istorinių navigacijos duomenų.

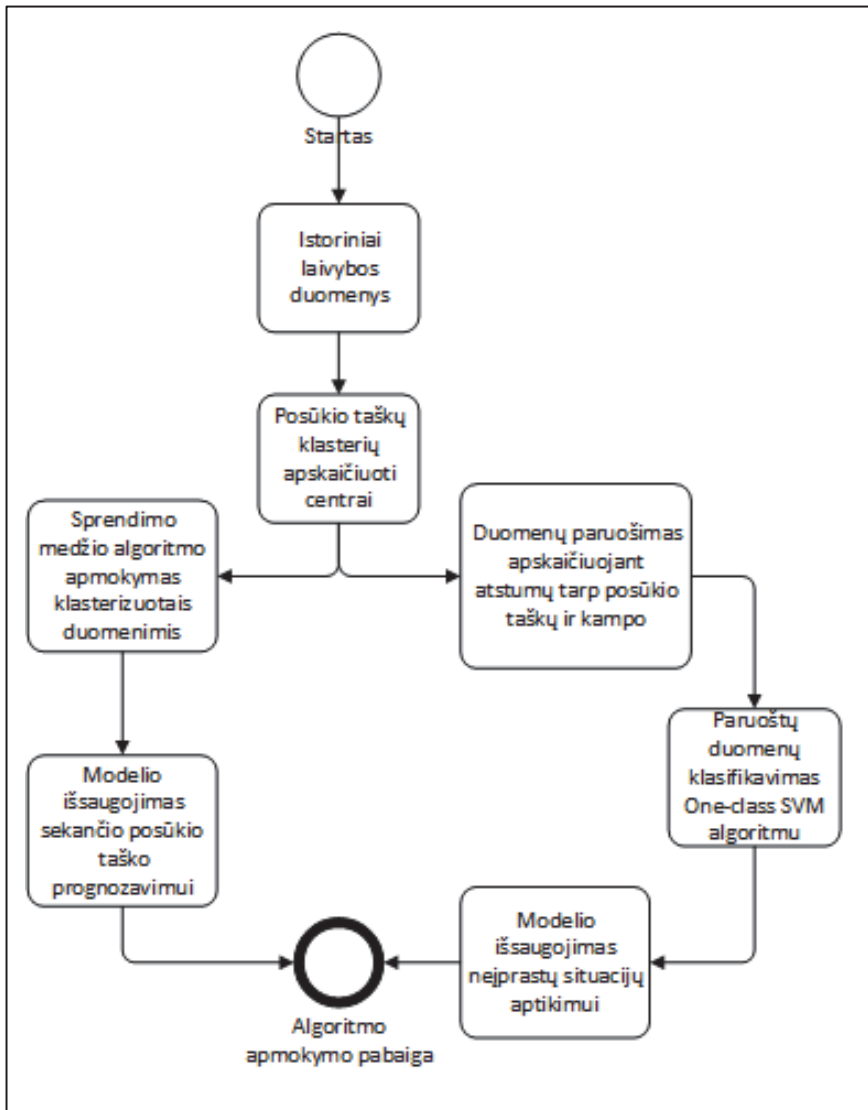
Pirmiausia istoriniai navigacijos duomenys paruošiami OPTICS algoritmu. Šiame etape analizuojami istoriniai navigacijos duomenys visa apimtimi, rezultatas – posūkio taškų klasterių apskaičiuoti centrai. Šie duomenys naudojami tolesniuose žingsniuose, kurie dalijami į atskiras grupes:

1. Sprendimo medžio algoritmo apmokymas kitam būsimam stebimo laivo posūkio taškui prognozuoti;
2. Neįprastos situacijos aptikimas *One-Class SVM* klasifikatoriumi.

Tačiau prieš pateikiant duomenis *One-Class SVM* klasifikatoriui, reikalingi papildomi skaičiavimai:

- a. Apskaičiuojami atstumai tarp posūkio taškų (A, B) ir (B, C);
 - b. Apskaičiuojamas $\angle ABC$.
3. Apmokyti modeliai išsaugojami tolesniam panaudojimui.

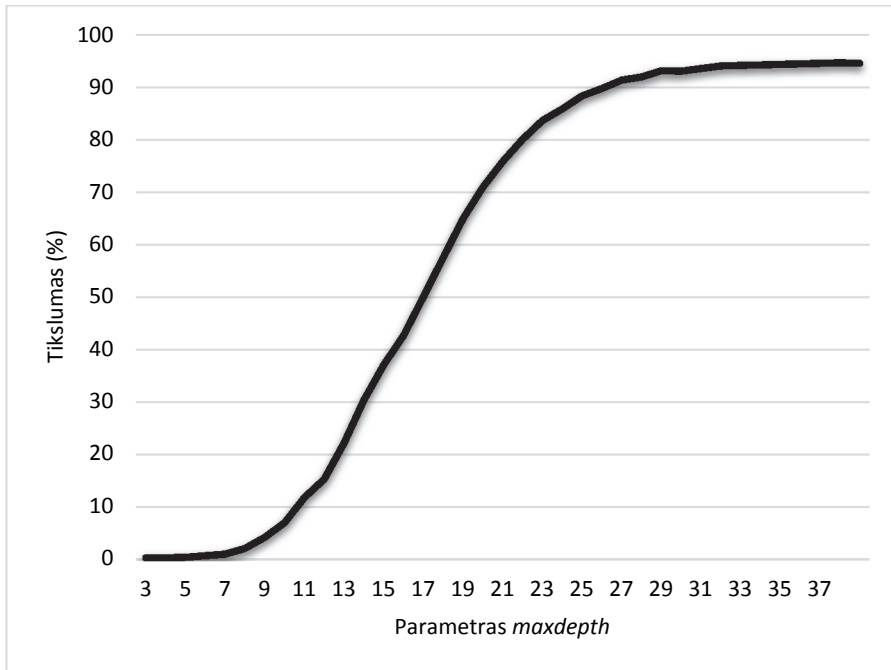
Apmokymo procesas grafiškai pavaizduotas 49 paveiksle.



49 pav. Pasiūlyto algoritmo apmokymo procesas


Apmokymo proceso metu sprendimo medžio algoritmas apmokomas tam tikros geografinės teritorijos laivybos maršrutų. Numatyti būsimą posūkių tašką – sudėtingas uždavinys, nes yra priklausomybė nuo esamos laivo padėties (ilguma ir platumas), laivo kurso ir greičio bei kito posūkių taško.

Atlikti eksperimentai, siekiant įvertinti sprendimo medžio parametro *maxdepth* įtaką prognozavimo tikslumui. *maxdepth* parametras buvo keičiamas nuo 3 iki 37. Rezultatas pavaizduotas 50 paveiksle. *maxdepth* parametro reikšmei esant 26 – pasiekiamas 90 % tikslumas. Gautas maksimalus tikslumas – 94 %, *maxdepth* parametro reikšmei esant 37.



50 pav. Sprendimo medžio tikslumas, pritaikant parametą *maxdepth*

One-Class SVM algoritmo apmokymo metu pateiktos 462499 situacijos. Algoritmas iš šių situacijų išrinko anomalijas / neįprastas situacijas. Gautas rezultatas – 27125 neįprastos situacijos, kurios sudaro 5,86 % visų situacijų. Automatinį patikrinimą atlikti sudėtinga, nes neįprastos situacijos neturi bendrų bruožų, pagal kuriuos būtų jas galima išskirti. Tačiau tokios neįprastos situacijos išskiriamos iš turimų duomenų naudojant *One-Class SVM* algoritmą.



51 pav. Aptiktos neišprasos situacijos pavyzdys

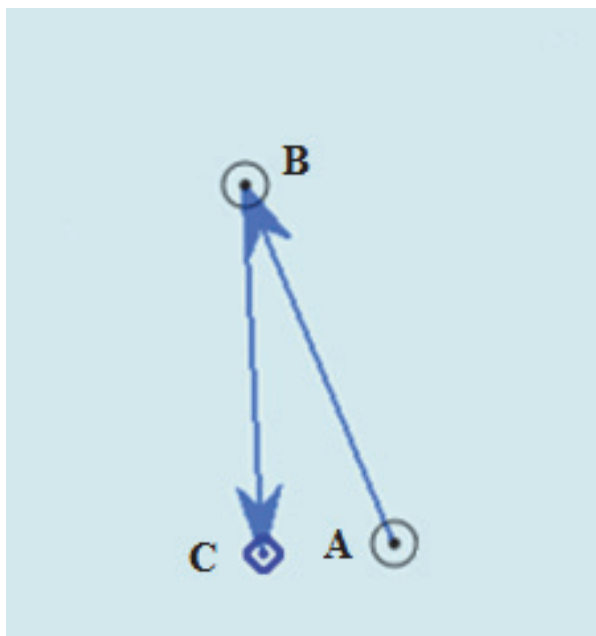
Neišprasos situacijos pavyzdys pateikiamas 51 paveiksle. Šis situacija yra aptikta *One-Class SVM* algoritmu. Šioje situacijoje laivas plaukė iš taško A į B ir toliau į C (laivo judėjimo kryptis pažymėta rodyklėmis). Kampas tarp šių posūkio taškų smailus, todėl ši situacija atitinka neišprasos situacijos aprašymą. Tokio manevravimo priežastis nėra aiški, tačiau judėjimą būtina stebėti, nes laivas atlieka staigius manevrus ir beveik grįžta į pradinį (A) tašką.

4.8. Pasiūlyto metodo taikymas

Pasiūlytas metodas paremtas kontekstinių žinių taikymu, siekiant įvertinti konkrečią manevravimo situaciją. Šis vertinimas imituoja pagrindinius kognityvinio mąstymo procesus:

1. Žinojimą ir atmintį – sprendimų medžio algoritmas yra apmokomas ir „žino“, kokiais maršrutais laivai plaukioja konkrečioje geografinėje zonoje;
2. Vertinimą – *One-Class SVM* algoritmu vertinama sprendimų medžio prognozė, identifikuojant situacijas, kurios gali tapti pavojingos dar nesant požymių;
3. Problemos sprendimą – taikant pasiūlytą metodą, galima įvertinti planuojamą sprendimą, kaip saugiau atlikti avarinės situacijos išvengimo manevrą. Planuojamas manevras turi būti saugus ir kitų laivybos dalyvių atžvilgiu, tad pasiūlytas sprendimas yra tinkamas planuojamam manevrui vertinti visų laivybos dalyvių atžvilgiu.

Galimai pavojingo būsimo laivo manevro ir tikėtino manevro, skirto išvengti pavojingos situacijos, vertinimas atliekamas dar prieš pavojų keliančio laivo atvykimą į B posūkio tašką (52 pav.).



52 pav. Manevro vertinimas

Saugią laivybą užtikrinančios tarnybos tokiu pačiu principu gali taikyti pasiūlytą metodą. Neįprasti laivų manevrai ne tik sukelia pavojų laivybos

dalyviams, tačiau gali būti ir bandymas nuslėpti nelegalią veiklą. Dėl intensyvaus laivų eismo zonose ir uostuose, reikalinga ne tik nuolatinė laivybos srauto stebėjimo sistema, bet ir pavojų numatanti bei užkardyti galimą avariją galinti sprendimų priėmimo sistema. Ši sprendimų priėmimo sistema turėtų gebėti savarankiškai aptikti būsimą pavojingą situaciją ir informuoti laivybos dalyvius arba kitus atsakingus asmenis apie neįprastą veiklą. Tai yra svarbu, nes dėl laivų matmenų bei manevravimo savybių išankstinis įspėjimas padėtų susiplanuoti atitinkamus manevrus, siekiant išvengti galimos avarijos.



53 pav. Sprendimų priėmimo proceso schema

Sprendimų priėmimo sistema turi užtikrinti nuolatinę situacijos vertinimo procesą (žr. 53 paveikslą). Pasiūlytas metodas taikomas didžiajai sprendimo priėmimo proceso etapų daliai:

1. Problemos identifikavimas. Šiame etape pritaikomas metodas identifikuoja galimą pavojingą situaciją;

2. Informacijos surinkimas – metodas pritaikomas kaskart atnaujinus duomenis, siekiant įsitikinti, ar tikrai yra pavojaus grėsmė;
3. Alternatyvų identifikavimas – prasilenkimo scenarijų sudarymas, atsižvelgiant į laivybos taisykles, aplink esančias kliūtis, laivo manevrines savybes ir t. t.;
4. Alternatyvų įvertinimas – pasiūlytas metodas pritaikomas prasilenkimo scenarijams įvertinti. Prasilenkimo manevras privalo būti saugus visų kitų laivybos dalyvių atžvilgiu, tad metodas taikomas ir savo planuojamiems manevrams vertinti kitų laivybos dalyvių atžvilgiu;
5. Alternatyvos pasirinkimas – pasirenkamas saugiausias ir optimalus manevras visų laivybos dalyvių atžvilgiu;
6. Veiksmo atlikimas – konkretaus pasirinkto prasilenkimo scenarijaus įvykdymas;
7. Rezultato įvertinimas – atlikus manevrą įvertinamos naujos manevravimo situacijos tiek savo atžvilgiu, tiek aplinkinių laivų atžvilgiu.

Sprendimo priėmimo procesas yra nuolatinis ir privalo būti atliekamas nuolat. Pasiūlytas metodas pritaikomas įvairiuose sprendimo priėmimo etapuose.

4.9. Skyriaus apibendrinimas

Atlikus laivų manevrų vertinimo metodo, pagrįsto kontekstinių žinių taikymu, analizę, apibendrinant galima daryti tokios išvadas:

1. Laivybos duomenų agregavimas yra būtinas, norint gauti informaciją apie laivybos maršrutus ir juos panaudoti tolesniuose skaičiavimuose. Dėl posūkio taškų išsidėstymo specifikos duomenims agreguoti geriau taikyti OPTICS algoritmą nei DBSCAN. Duomenų agregavimo rezultatas – posūkio taškų klasteriai, skirti būsimam stebimo laivo posūkio taškui prognozuoti.
2. Pasiūlytas metodas, paremtas kontekstinių žinių taikymu, kuriuo siekiama įvertinti konkrečią manevravimo situaciją. Mašininio mokymosi metodas sujungia du skirtingus mašininio mokymosi algoritmus. Sprendimų medžio algoritmas prognozuoja būsimą stebimo laivo posūkio tašką. Būsimo posūkio taško prognozavimas yra labai svarbus, siekiant numatyti būsimus stebimo laivo manevrus. *One-Class SVM* algoritmo taikymas, vertinant sprendimo medžio prognozavimo rezultata, suteikia galimybę numatyti neįprastus stebimo laivo manevrus. Pasiūlyto metodo išskirtinumas yra tas, kad

jis skirtas būsimo laivo manevrui įvertinti pagal kontekstines žinias prieš jam įvykstant.

3. Atsižvelgiant į skyriuje aprašytus gautus rezultatus, disertacijoje pasiūlytą metodą galima taikyti vertinti ne tik būsimiems stebimo laivo manevrams, bet ir būsimam, tikėtinam savo laivo manevrui. Šis metodas suteikia galimybę planuoti tinkamus manevers ne tik pagal tam tikrus faktorius (pavyzdžiui, laivybos taisyklės, hidrometeorologinė situacija ir t. t.), bet ir pagal savo laivo vertinimą kitų laivų atžvilgiu.

Pasiūlytas metodas universalus, tačiau šiame darbe pritaikytas konkrečiam laivybos stebėjimo ir vertinimo uždaviniui. Jis užtikrina interaktyvų situacijos vertinimą, atsižvelgiant į kintančius navigacijos duomenis.

5. APIBENDRINIMAS IR BENDROSIOS IŠVADOS

Disertacijoje išnagrinėti ir pasiūlyti metodai, skirti spręsti saugios laivybos užtikrinimo uždavinius. Šiems uždaviniams spręsti disertacijoje pasiūlyti įvairūs metodai, leidžiantys prognozuoti būsimą stebimo laivo posūkio tašką arba maršrutą ir įvertinti laivo manevrus kitų laivų atžvilgiu. Šie metodai paremti mašininio mokymosi metodais.

Pagrindiniai rezultatai:

- Analitiškai apžvelgtos laivyboje naudojamos technologijos, metodai ir maršrutų planavimo algoritmai, skirti užtikrinti saugią laivybą bei maršrutų planavimą. Šiuo metu laivybos saugumas užtikrinamas nedideliu skaičiumi technologijų, skirtų laivybai stebėti. Laivyboje išmaniosios technologijos sprendimams priimti netaikomos dėl sudėtingos veikimo aplinkos. Pasirenkamas paprasčiausias būdas, t. y. susitelkiama į laivavedžio, kuris turi priimti sprendimus, informavimą. Tačiau pastebimas didelis poreikis taikyti išmaniausias technologijas laivyboje, o ateityje šis poreikis tik didės. Saugiai laivybai užtikrinti maršruto planavimo / kliūčių išvengimo algoritmų taikymas yra sudėtingas, nes algoritmai neplanuoja geriausio maršruto, o apskaičiuoja trumpiausią. Tačiau tai nėra gerai, nes toks planavimas neįtraukia kitų faktorių, lemiančių saugią laivybą.
- Laivo posūkio taško ar maršruto prognozavimas yra svarbus uždavinys, siekiant užtikrinti saugią laivybą. Žinant būsimą stebimo laivo posūkio tašką arba maršrutą, įmanoma numatyti būsimą pavojingą situaciją. Atsiranda galimybė iš anksto planuoti manevrą ir priimti sprendimą, kaip saugiai išvengti susidūrimo ar pavojingos situacijos susidarymo. Kiekvienas laivavedys privalo vertinti ir priimti sprendimus savarankiškai. Sprendimo priėmimui palengvinti sukurti metodai, skirti prognozuoti būsimus artimiausius stebimo laivo posūkio taškus. Taip pat sukurtas metodas, leidžiantis aptikti anomaliją bendrame laivybos sraute. Šio metodo taikymas padeda įvertinti esamą situaciją realiu laiku bei prognozuoti kitų dalyvių veiksmus. O tai yra svarbiausia sąlyga, siekiant užtikrinti saugią laivybą.
- Saugiai laivybai užtikrinti nepakanka vien tik numatyti būsimus stebimo laivo manevrus. Šiuos būsimus manevrus būtina įvertinti. Įprastai įvertinti atliekamą manevrą yra sudėtinga, nes nelengva nustatyti ir susieti priežastinius ir pasekminius atliekamo manevro ryšius. Tokie ryšiai paaiškintų, kodėl yra atliekamas manevras ir

kokie galimi kiti manevrai toje situacijoje. Disertacijoje pasiūlytas metodas skirtas būsimam laivo manevrui įvertinti prieš jam įvykstant. Jis paremtas kontekstinių žinių taikymu, kuriuo siekiama įvertinti konkrečią būsimą manevravimo situaciją. Mašininio mokymosi metodas sujungia du skirtingus mašininio mokymosi metodus. Pasiūlyto metodo išskirtinumas yra tas, kad jis yra skirtas būsimam laivo manevrui įvertinti prieš jam įvykstant, remiantis kontekstinėmis žiniomis. Panašių metodų į pasiūlytą kontekstinėmis žiniomis paremtą metodą mokslinėje literatūroje identifikuoti nepavyko, todėl sudėtinga atlikti palyginimą. Nežiūrint to, atlikti eksperimentai įrodė pasiūlyto metodo taikymo galimybes.

Atlikus eksperimentinius tyrimus, suformuluotos šios išvados:

- Atlikti eksperimentai, skirti patikrinti maršruto planavimo, kliūčių išvengimo arba gilaus sustiprinto mokymosi algoritmų efektyvumą, parodė, kad tie algoritmai neužtikrina saugaus maršruto planavimo, kadangi negali atsižvelgti į daugelį laivybai įtaką darančių faktorių. Tų algoritmų rezultatus laivavedžiui reikia vertinti kritiškai, nes gali būti pasiūlytas net ir nelogiškas maršrutas kelionės tikslo atžvilgiu.
- Atliekant eksperimentus su giliuoju sustiprintu mokymosi algoritmu, agentas pasiekia pakankamai gerą 87,7 % maršruto planavimo tikslumą. Apsunkinus šiam algoritmui uždavinį, t. y. pridėjus: a) papildomų kliūčių ir b) pradėjus keisti gauto taško padėtį kiekviename etape, atitinkamai pasiektas tik: a) 48,1 % ir b) 50,77 % tikslumas. Šie eksperimentai parodė, kad esant sudėtingesnėms sąlygoms, giliojo sustiprinto mokymosi algoritmas netinka saugiam manevravimui planuoti ir atlikti.
- Prognozuojant stebimų laivų posūkio taškus ir maršrutus naudojantis DNT, pasiekiamas 97,53 % prognozavimo tikslumas, todėl pasiūlytas metodas yra tinkamas praktiniam panaudojimui. Šiuo metodu prognozuoti stebimo laivo posūkio taškai, o remiantis prognozėmis, galima net sudaryti preliminarinius stebimų laivų maršrutus. Tokio prognozavimo tikslas yra ne kuo tiksliau sudaryti galimą maršrutą, o numatyti, kokie bus artimiausi stebimo laivo manevrai.
- Atrasta priklausomybė tarp vidutinio k kaimyninių laivų atstumo ir to, ar laivai yra tik bendrame sraute, ar jų yra ir už bendro laivybos srauto. Navigacijos duomenyse esant laivų, kurie yra už bendro laivybos srauto, kinta vidutinio atstumo tarp k kaimyninių laivų

priklausomybė nuo k iš tiesinės į netiesinę (logaritminę). Šią priklausomybę galima pritaikyti vykdant laivybos stebėjimą realiuoju laiku.

- Vykdant automatinį laivybos srautų stebėjimą, svarbu algoritmiškai užtikrinti neįprastai judančių laivų aptikimą. Laivą, esantį už bendro laivybos srauto, galima aptikti pagal šiuos požymius:
 - Vidutinis atstumas tarp laivybos sraute nesančio laivo ir kelių artimiausių laivybos sraute esančių kaimyninių laivų yra daug didesnis už tokį vidutinį atstumą, apskaičiuotą laivams, esantiems bendrame laivybos sraute;
 - Vidutinė atstumo tarp pasirinkto laivo ir kelių artimiausių kaimyninių laivų dispersija yra daug didesnė iš laivybos srauto pasirinktiems laivams nei laivams, kurie yra už bendro laivybos srauto. Ši dispersija mažėja didėjant atstumui tarp laivo ir bendro laivybos srauto.
- Pritaikius duomenų filtravimą ir klasterizavimą OPTICS algoritmu, sumažinta duomenų imtis tolesniems eksperimentams. Pradinė duomenų imtis buvo 19 GB, po klasterizavimo gauta 237 MB duomenų imtis. Atlikti eksperimentai parodė, kad OPTICS algoritmas yra tinkamesnis darbui su geografiniais laivybos duomenimis nei DBSCAN. Taip pat siekiant tikslesnių prognozių, tikslinga naudoti kuo didesnes navigacijos duomenų imtis, jas filtruojant pagal poreikį, pavyzdžiui, laivų tipą, maršrutą, metų laikus. Filtravimas pagerina klasterizavimą ir prognozavimą.
- Atlikus eksperimentus nustatyta, kad sprendimų medžio algoritmas yra tinkamas prognozuoti stebimo laivo būsimą posūkio tašką. Atlikti eksperimentai, siekiant įvertinti sprendimo medžio parametro *maxdepth* įtaką prognozavimo tikslumui. Keičiant parametro *maxdepth* įvertį nuo 3 iki 37 pasiektas maksimalus 94 % prognozavimo tikslumas.
- Pritaikius *One-Class SVM* algoritmą neįprastoms situacijoms aptikti tarp 462499 situacijų, aptiktos net 27125 neįprastos situacijos, kurios sudarė 5,86 % visų tirtų situacijų.

LITERATŪROS SĄRAŠAS

- [1] International Maritime Organization: *The International Regulations for Preventing Collisions at Sea 1972 (COLREGS)*. London, International Maritime Organization. (1972).
- [2] Machine Learning. Available at: <https://www.ibm.com/cloud/learn/machine-learning/> [Date accessed: February 7, 2021]
- [3] Daranda A. Dzemyda G: Artificial Intelligence Based Strategy for Vessel Decision Support System. *WorldCist'21 - 9th World Conference on Information Systems and Technologies*, Terceira, 49–58, 2021.
- [4] Jakovlev S., Daranda A., Voznak M., Lektauers A., Eglynas T., Juisis M.: Analysis of the Possibility to Detect Fake Vessels in the Automatic Identification System. *2020 61st International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS)*, IEEE, 1–5, 2020.
- [5] Stitt I.: AIS and collision avoidance - A sense of Déjà Vu. *Journal of Navigation* 57, 2, 167–80, 2004. Doi: 10.1017/S0373463304002760
- [6] Wiley D. N., Thompson M., Pace R. M., Levenson J.: Modeling speed restrictions to mitigate lethal collisions between ships and whales in the Stellwagen Bank National Marine Sanctuary, USA. *Biological Conservation* 144, 9, 2377–81, 2011. Doi: 10.1016/j.biocon.2011.05.007
- [7] McBratney A., Mendonça S. M., Minasny B.: On digital soil mapping. *Geoderma* 117, 1–2, 3–52, 2003. Doi: 10.1016/S0016-7061(03)00223-4
- [8] Bruschi S., Lehner S., Fritz T., Soccorsi M., Soloviev A., Van Schie B.: Ship surveillance with TerraSAR-X. *IEEE Transactions on Geoscience and Remote Sensing* 49, 3, 1092–103, 2011. Doi: 10.1109/TGRS.2010.2071879
- [9] Greidanus H., Alvarez M., Eriksen T., Gammieri V.: Completeness and Accuracy of a Wide-Area Maritime Situational Picture based on Automatic Ship Reporting Systems. *Journal of Navigation* 69, 1, 156–68, 2016. Doi: 10.1017/S0373463315000582
- [10] Fournier M., Casey H. R., Rezaee S., Pelot R.: Past, present, and future of the satellite-based automatic identification system: areas of applications (2004–2016). *WMU Journal of Maritime Affairs* 17, 3, 311–45, 2018. Doi: 10.1007/s13437-018-0151-6

- [11] Guha B., Guha A. S.: Pirates and traders: Some economics of pirate-infested seas. *Economics Letters* 111, 2, 147–50, 2011. Doi: 10.1016/j.econlet.2011.01.030
- [12] Kraska J., Wilson B.: Fighting pirates: The pen and the sword. *World Policy Journal* 25, 4, 41–52, 2008. Doi: 10.1162/wopj.2009.25.4.41
- [13] Mejia M. Q., Cariou P., Wolff F. C.: Is maritime piracy random? *Applied Economics Letters* 16, 9, 891–5, 2009. Doi: 10.1080/13504850701222186
- [14] Daxecker U. E., Prins B. C.: The new barbary wars: Forecasting maritime piracy. *Foreign Policy Analysis* 11, 1, 23–44, 2015. Doi: 10.1111/fpa.12014
- [15] Petrossian G. A.: Preventing illegal, unreported and unregulated (IUU) fishing: A situational approach. *Biological Conservation* 189, 39–48, 2014. Doi: 10.1016/j.biocon.2014.09.005
- [16] Maimun A., et al.: Using AIS data for navigational risk assessment in restricted waters. *Transportation Systems and Engineering: Concepts, Methodologies, Tools, and Applications* 3–3, 1154–63, 2015. Doi: 10.4018/978-1-4666-8473-7.ch059
- [17] Longépé N., et al.: Completing fishing monitoring with spaceborne Vessel Detection System (VDS) and Automatic Identification System (AIS) to assess illegal fishing in Indonesia. *Marine Pollution Bulletin* 131, 33–9, 2018. Doi: 10.1016/j.marpolbul.2017.10.016
- [18] Baldauf M., Benedict K., Fischer S., Motz F., Schröder-Hinrichs J.: Collision avoidance systems in air and maritime traffic. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability* 225, 3, 333–43, 2011. Doi: 10.1177/1748006X11408973
- [19] Chen S. T., Wall A., Davies P., Yang Z., Wang J., Chou Y. H.: A Human and Organisational Factors (HOFs) analysis method for marine casualties using HFACS-Maritime Accidents (HFACS-MA). *Safety Science* 60, 105–14, 2013. Doi: 10.1016/j.ssci.2013.06.009
- [20] Batalden B. M., Sydnes A. K.: Maritime safety and the ISM code: A study of investigated casualties and incidents. *WMU Journal of Maritime Affairs* 13, 1, 3–25, 2014. Doi: 10.1007/s13437-013-0051-8
- [21] Schröder-Hinrichs J. U., Baldauf M., Ghirxi K. T.: Accident investigation reporting deficiencies related to organizational factors in machinery space fires and explosions. *Accident Analysis and Prevention* 43, 3, 1187–96, 2011. Doi: 10.1016/j.aap.2010.12.033
- [22] Tam C. K., Bucknall R., Greig A.: Review of collision avoidance and path planning methods for ships in close range encounters. *Journal of*

- Navigation* 62, 3, 455–76, 2009. Doi: 10.1017/S0373463308005134
- [23] Mehdi R., Gluch M., Fischer S., Baldauf M.: A perfect warning to avoid collisions at sea? *Zeszyty Naukowe Akademii Morskiej w Szczecinie* 53–64, 2017. Doi: 10.17402/245
- [24] Chen P., Huang Y., Mou J., van G. P.: Ship collision candidate detection method: A velocity obstacle approach. *Ocean Engineering* 170, 186–98, 2018. Doi: 10.1016/j.oceaneng.2018.10.023
- [25] Huang Y., Chen L., Chen P., Negenborn R. R., van G. P.: Ship collision avoidance methods: State-of-the-art. *Safety Science* 121, 451–73, 2020. Doi: 10.1016/j.ssci.2019.09.018
- [26] Du L., Banda O. V., Kujala P.: An intelligent method for real-time ship collision risk assessment and visualization. *Developments in the Collision and Grounding of Ships and Offshore Structures - Proceedings of the 8th International Conference on Collision and Grounding of Ships and Offshore Structures, ICCGS 2019*, CRC Press/Balkema, 293–300, 2020.
- [27] Statheros T., Howells G., McDonald-Maier K.: Autonomous ship collision avoidance navigation concepts, technologies and techniques. *Journal of Navigation* 61, 1, 129–42, 2008. Doi: 10.1017/S037346330700447X
- [28] Johansen T. A., Perez T., Cristofaro A.: Ship collision avoidance and COLREGS compliance using simulation-based control behavior selection with predictive hazard assessment. *IEEE Transactions on Intelligent Transportation Systems* 17, 12, 3407–22, 2016. Doi: 10.1109/TITS.2016.2551780
- [29] Wróbel K., Montewka J., Kujala P.: Towards the assessment of potential impact of unmanned vessels on maritime transportation safety. *Reliability Engineering and System Safety* 165, 155–69, 2017. Doi: 10.1016/j.ress.2017.03.029
- [30] Karlis T.: Maritime law issues related to the operation of unmanned autonomous cargo ships. *WMU Journal of Maritime Affairs* 17, 1, 119–28, 2018. Doi: 10.1007/s13437-018-0135-6
- [31] Kobylński L.: Smart ships – autonomous or remote controlled? *Zeszyty Naukowe Akademii Morskiej w Szczecinie* 53, 125, 28–34, 2018. Doi: 10.17402/262
- [32] Laurinen M.: Remote and Autonomous Ships: The next steps. *AAWA: Advanced Autonomous Waterborne Applications* 88, 2016.
- [33] Skredderberget Asle: Yara Birkeland, The first zero emission, autonomous ship, Yara International. Webpage. Available at:

- <https://www.yara.com/knowledge-grows/game-changer-for-the-environment/> [Date accessed: October 12, 2020]
- [34] MUNIN: About, MUNIN. Available at: <http://www.unmanned-ship.org/munin/about/> [Date accessed: October 12, 2020]
- [35] Haikkola P.: One Sea Roadmap towards commercial autonomous shipping in 2025. Available at: https://www.oneseaecosystem.net/wp-content/uploads/sites/2/2017/08/onesea_roadmaps-august-2017_paivi-haikkola_rev.pdf [Date accessed: October 22, 2019]
- [36] Dubra V.: Remarks on the safe navigation conditions in the port of Klaipėda. *Transport Means 2020 Sustainability: Research and Solutions: Proceedings of the 24th International Scientific Conference: September 30 - October 02, 2020, Online Conference, Kaunas, Lithuania*, 233–7, 2020.
- [37] Paulauskas V., et al.: The influence of port tugs on improving the navigational safety of the port. *Journal of Marine Science and Engineering* 9, 3:342, 1–20, 2021. Doi: 10.3390/jmse9030342
- [38] Venskus J., et al.: Real-time maritime traffic anomaly detection based on sensors and history data embedding. *Sensors* 19, 17, 3782, 2019. Doi: 10.3390/s19173782
- [39] Venskus J., et al.: Integration of a self-organizing map and a virtual pheromone for real-time abnormal movement detection in marine traffic. *Informatica* 28, 2, 359–74, 2017. Doi: 10.15388/Informatica.2017.133
- [40] Urbahs A., et al.: Analysis of an unmanned aerial vehicle monitoring system for resurveying of shipping routes. *Transport and Aerospace Engineering* 3, 102–11, 2016. Doi: 10.1515/tae-2016-0012
- [41] Paulauskas V., Paulauskas D.: Accuracy evaluation of Ro-Ro and Ro-Pax ships arrival to the ports. *TransNav: The International Journal on Marine Navigation and Safety of Sea Transportation* 14, 2, 397–401, 2020. Doi: 10.12716/1001.14.02.17
- [42] Andruškienė J., Barsevičienė Š., Varoneckas G.: Poor sleep, anxiety, depression and other occupational health risks in seafaring population. *TransNav: The International Journal on Marine Navigation and Safety of Sea Transportation* 10, 1, 19–25, 2016. Doi: 10.12716/1001.10.01.01
- [43] Varoneckas G., et al.: Monitoring system for evaluation of operator functional status on sea ships. *TransNav: The International Journal on Marine Navigation and Safety of Sea Transportation* 10, 2, 309–13, 2016. Doi: 10.12716/1001.10.02.13

- [44] Zhang W., Goerlandt F., Kujala P., Wang Y.: An advanced method for detecting possible near miss ship collisions from AIS data. *Ocean Engineering* 124, 141–56, 2016. Doi: 10.1016/j.oceaneng.2016.07.059
- [45] Bošnjak R., Šimunović L., Kavran Z.: Automatic Identification System in Maritime Traffic and Error Analysis. *Transactions on Maritime Science* 1, 2, 77–84, 2012. Doi: 10.7225/toms.v01.n02.002
- [46] Zhang W., Kopca C., Tang J., Ma D., Wang Y.: A Systematic Approach for Collision Risk Analysis based on AIS Data. *Journal of Navigation* 70, 5, 1117–32, 2017. Doi: 10.1017/S0373463317000212
- [47] Gaugel T., et al.: In-depth analysis and evaluation of Self-organizing TDMA. *2013 IEEE Vehicular Networking Conference*, Boston: VNC, 79–86, 2013.
- [48] Yao L., Liu Y., He Y.: A novel ship-tracking method for GF-4 satellite sequential images. *Sensors* 18, 7, 2018. Doi: 10.3390/s18072007
- [49] De Souza E. N., Boerder K., Matwin S., Worm B.: Improving fishing pattern detection from satellite AIS using data mining and machine learning. *PLoS ONE* 11, 7, 2016. Doi: 10.1371/journal.pone.0158248
- [50] Karthick K.: Analysis of marine accidents and design an enhanced method of collision avoidance using AIS. *Journal of Engineering and Applied Sciences* 13, 12 SI, 9357–60, 2018. Doi: 10.3923/jeasci.2018.9357.9360
- [51] Lindblom C. E.: The Science of “Muddling Through.” *Public Administration Review* 19, 2, 79–88, 1959.
- [52] Etzioni A.: Mixed-Scanning: A “Third” Approach to Decision-Making. *Public Administration Review* 27, 5, 385, 1967. Doi: 10.2307/973394
- [53] Cohen M. D., March J. G., Olsen J. P.: A Garbage Can Model of Organizational Choice. *Administrative Science Quarterly* 17, 1, 1, 1972. Doi: 10.2307/2392088
- [54] Simon H. A., Simon H.: Rational Decision Making in Business Organizations. *American Economic Review* 69, 4, 493–513, 1979.
- [55] Hu S., Fang Q., Xia H., Xi Y.: Formal safety assessment based on relative risks model in ship navigation. *Reliability Engineering and System Safety* 92, 3, 369–77, 2007. Doi: 10.1016/j.res.2006.04.011
- [56] Hu S., Fang Q., Cai C.: Formal risk assessment of vessel traffic at coastal waters. *NCM 2009 - 5th International Joint Conference on INC, IMS, and IDC*, 363–8, 2009.
- [57] Chauvin C., Lardjane S.: Decision making and strategies in an

- interaction situation: Collision avoidance at sea. *Transportation Research Part F: Traffic Psychology and Behaviour* 11, 4, 259–69, 2008. Doi: 10.1016/j.trf.2008.01.001
- [58] Du L., et al.: Improving stand-on ship's situational awareness by estimating the intention of the give-way ship. *Ocean Engineering* 201, 2020. Doi: 10.1016/j.oceaneng.2020.107110
- [59] Bukhari A. C., Tusseyeva I., Lee B. G., Kim Y. G.: An intelligent real-time multi-vessel collision risk assessment system from VTS view point based on fuzzy inference system. *Expert Systems with Applications* 40, 4, 1220–30, 2013. Doi: 10.1016/j.eswa.2012.08.016
- [60] Kim J. S.: Vessel target prediction method and Dead Reckoning Position based on SVR seaway model. *International Journal of Fuzzy Logic and Intelligent Systems* 17, 4, 279–88, 2017. Doi: 10.5391/IJFIS.2017.17.4.279
- [61] Kim J. S., Jeong J. S.: Extraction of reference seaway through machine learning of ship navigational data and trajectory. *International Journal of Fuzzy Logic and Intelligent Systems* 17, 2, 82–90, 2017. Doi: 10.5391/IJFIS.2017.17.2.82
- [62] Lisowski J.: Comparison of dynamic games in application to safe ship control. *Polish Maritime Research* 21, 3, 3–12, 2014. Doi: 10.2478/pomr-2014-0024
- [63] Lisowski J.: Computational intelligence methods of a safe ship control. *Procedia Computer Science* 35, C, 634–43, 2014. Doi: 10.1016/j.procs.2014.08.145
- [64] Szlupczynski R.: A new method of ship routing on raster grids, with turn penalties and collision avoidance. *Journal of Navigation* 59, 1, 27–42, 2006. Doi: 10.1017/S0373463305003528
- [65] Liu Y., Bucknall R.: Path planning algorithm for unmanned surface vehicle formations in a practical maritime environment. *Ocean Engineering* 97, 126–44, 2015. Doi: 10.1016/j.oceaneng.2015.01.008
- [66] Kuczkowski Ł., Śmierzchalski R.: Comparison of single and multi-population evolutionary algorithm for path planning in navigation situation. *Solid State Phenomena* 210, 166–77, 2014. Doi: 10.4028/www.scientific.net/SSP.210.166
- [67] Szlupczynski R., Szlupczynska J.: Customized crossover in evolutionary sets of safe ship trajectories. *International Journal of Applied Mathematics and Computer Science* 22, 4, 999–1009, 2012. Doi: 10.2478/v10006-012-0074-x
- [68] Tam C., Bucknall R.: Cooperative path planning algorithm for marine

- surface vessels. *Ocean Engineering* 57, 25–33, 2013. Doi: 10.1016/j.oceaneng.2012.09.003
- [69] Xue Y., Clelland D., Lee B., Han D.: Automatic simulation of ship navigation. *Ocean Engineering* 38, 17–18, 2290–305, 2011. Doi: 10.1016/j.oceaneng.2011.10.011
- [70] Perera L., Carvalho J., Soares C. G.: Bayesian network based sequential collision avoidance action execution for an ocean navigational system. *IFAC Proceedings Volumes (IFAC-PapersOnline)* 43, 20, 266–71, 2010. Doi: 10.3182/20100915-3-DE-3008.00046
- [71] Tam C., Bucknall R.: Path-planning algorithm for ships in close-range encounters. *Journal of Marine Science and Technology* 15, 4, 395–407, 2010. Doi: 10.1007/s00773-010-0094-x
- [72] Lazarowska A.: Ship’s trajectory planning for collision avoidance at sea based on Ant Colony Optimisation. *Journal of Navigation* 68, 2, 291–307, 2015. Doi: 10.1017/S0373463314000708
- [73] Fox D., Burgard W., Thrun S.: The dynamic window approach to collision avoidance. *IEEE Robotics and Automation Magazine* 4, 1, 23–33, 1997. Doi: 10.1109/100.580977
- [74] Kim H., et al.: Improved Dynamic Window Approach With Path-Following for Unmanned Surface Vehicle. *IEMEK Journal of Embedded Systems and Applications* 12, 5, 295–301, 2017. Doi: 10.14372/IEMEK.2017.12.5.295
- [75] Geng X., Wang Y., Wang P., Zhang B.: Motion plan of maritime autonomous surface ships by dynamic programming for collision avoidance and speed optimization. *Sensors* 19, 2, 434, 2019. Doi: 10.3390/s19020434
- [76] Eriksen B. O. H., et al.: Radar-based maritime collision avoidance using dynamic window. *IEEE Aerospace Conference Proceedings*, 2018- March, IEEE Computer Society, 1–9, 2018.
- [77] Seder M., Petrović I.: Dynamic window based approach to mobile robot motion control in the presence of moving obstacles. *Proceedings - IEEE International Conference on Robotics and Automation*, 1986–91, 2007. Doi: 10.1109/ROBOT.2007.363613
- [78] Serigstad E., Eriksen B., Olav H., Breivik M.: Hybrid Collision Avoidance for Autonomous Surface Vehicles. *IFAC-PapersOnLine* 51, 29, 1–7, 2018. Doi: 10.1016/j.ifacol.2018.09.460
- [79] Tusseyeva I., Kim S., Kim Y.: 3D Global Dynamic Window Approach for Navigation of Autonomous Underwater Vehicles. *International*

Journal of Fuzzy Logic and Intelligent Systems 13, 2, 91–9, 2013. Doi: 10.5391/ijfis.2013.13.2.91

- [80] Lin X., Fu Y.: Research of USV obstacle avoidance strategy based on dynamic window. *2017 IEEE International Conference on Mechatronics and Automation, ICMA 2017*, Institute of Electrical and Electronics Engineers Inc., 1410–5, 2017.
- [81] Campbell S., Naeem W., Irwin G.: A review on improving the autonomy of unmanned surface vehicles through intelligent collision avoidance manoeuvres. *Annual Reviews in Control* 36, 2, 267–83, 2012. Doi: 10.1016/j.arcontrol.2012.09.008
- [82] Sakai A., et al.: PythonRobotics: a Python code collection of robotics algorithms. *arXiv:1808.10703*, 2018.
- [83] Lyu H., Yin Y.: COLREGS-Constrained Real-Time Path Planning for Autonomous Ships Using Modified Artificial Potential Fields. *Journal of Navigation* 72, 3, 588–608, 2019. Doi: 10.1017/S0373463318000796
- [84] Pêtrès C., Romero-Ramirez M., Plumet F.: A potential field approach for reactive navigation of autonomous sailboats. *Robotics and Autonomous Systems* 60, 12, 1520–7, 2012. Doi: 10.1016/j.robot.2012.08.004
- [85] Shi C., Zhang M., Peng J.: Harmonic potential field method for autonomous ship navigation. *ITST 2007 - 7th International Conference on Intelligent Transport Systems Telecommunications, Proceedings*, 471–6, 2007.
- [86] Lazarowska A.: A New Potential Field Inspired Path Planning Algorithm for Ships. *2018 23rd International Conference on Methods and Models in Automation and Robotics, MMAR 2018*, Institute of Electrical and Electronics Engineers Inc., 166–70, 2018.
- [87] Liu Q., et al.: A Survey on Deep Reinforcement Learning. *Jisuanji Xuebao/Chinese Journal of Computers*, 1–27, 2018. Doi: 10.11897/SP.J.1016.2018.00001
- [88] Etemad M., et al.: Using Deep Reinforcement Learning Methods for Autonomous Vessels in 2D Environments. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12109 LNAI, Springer, 220–31, 2020.
- [89] Guo S., Zhang X., Zheng Y., Du Y.: An autonomous path planning model for unmanned ships based on deep reinforcement learning. *Sensors* 20, 2, 2020. Doi: 10.3390/s20020426

- [90] Martinsen A. B., Lekkas A. M.: Straight-Path Following for Underactuated Marine Vessels using Deep Reinforcement Learning. *IFAC-PapersOnLine* 51, 29, 329–34, 2018. Doi: 10.1016/j.ifacol.2018.09.502
- [91] Watkins C. J., Dayan P.: Technical Note: Q-Learning. *Machine Learning* 8, 3, 279–92, 1992. Doi: 10.1023/A:1022676722315
- [92] Cheng Y., Zhang W.: Concise deep reinforcement learning obstacle avoidance for underactuated unmanned marine vessels. *Neurocomputing*, 272, 63–73, 2018. Doi: 10.1016/j.neucom.2017.06.066
- [93] Brockman G., et al.: OpenAI Gym. *arXiv:1606.01540*, 2016.
- [94] Shen H., et al.: Automatic collision avoidance of multiple ships based on deep Q-learning. *Applied Ocean Research* 86, April 2018, 268–88, 2019. Doi: 10.1016/j.apor.2019.02.020
- [95] Zhang X., Wang C., Liu Y., Chen X.: Decision-making for the autonomous navigation of maritime autonomous surface ships based on scene division and deep reinforcement learning. *Sensors* 19, 18, 2019. Doi: 10.3390/s19184055
- [96] Panov A. I., Yakovlev K. S., Suvorov R.: Grid path planning with deep reinforcement learning: Preliminary results. *Procedia Computer Science*, 123, Elsevier B.V., 347–53, 2018.
- [97] MarineTraffic: Global Ship Tracking Intelligence, AIS Marine Traffic. Available at: <https://www.marinetraffic.com/en/ais/home/> [Date accessed: March 20, 2020]
- [98] AIS data. Available at: <https://www.dma.dk/SikkerhedTilSoes/Sejladsinformation/AIS/Sider/default.aspx> [Date accessed: March 20, 2021]
- [99] Daranda A.: Neural Network Approach to Predict Marine Traffic. *Baltic J. Modern Computing*, 4, 483–95, 2016.
- [100] Daranda A., Dzemyda G.: Navigation decision support: Discover of vessel traffic anomaly according to the historic marine data. *International Journal of Computers, Communications and Control* 15, 3, 15, 2020. Doi: 10.15837/IJCCC.2020.3.3864
- [101] Tsou M. C.: Online analysis process on Automatic Identification System data warehouse for application in vessel traffic service. *Proceedings of the Institution of Mechanical Engineers Part M: Journal of Engineering for the Maritime Environment* 230, 1, 199–215, 2016. Doi: 10.1177/1475090214541426
- [102] Eriksen T., Høye G., Narheim B., Meland B. J.: Maritime traffic

- monitoring using a space-based AIS receiver. *International Astronautical Federation - 55th International Astronautical Congress 2004*, 8, 5276–89, 2004.
- [103] Fujii Y., Shiobara R.: The analysis of traffic accidents. *Journal of Navigation* 24, 4, 534–43, 1971. Doi: 10.1017/S0373463300022372
- [104] Celik M., Cebi S.: Analytical HFACS for investigating human errors in shipping accidents. *Accident Analysis and Prevention* 41, 1, 66–75, 2009. Doi: 10.1016/j.aap.2008.09.004
- [105] Mazaheri A., Montewka J., Kujala P.: Correlation between the ship grounding accident and the ship traffic – A case study based on the statistics of the Gulf of Finland. *TransNav, the International Journal on Marine Navigation and Safety of Sea Transportation* 7, 2, 119–24, 2013. Doi: 10.12716/1001.07.01.16
- [106] Eide M. S., Endresen Ø., Brett P. O., Ervik J. L., Røang K.: Intelligent ship traffic monitoring for oil spill prevention: Risk based decision support building on AIS. *Marine Pollution Bulletin* 54, 2, 145–8, 2007. Doi: 10.1016/j.marpolbul.2006.11.004
- [107] Jin M., Shi W., Lin K., Li K. X.: Marine piracy prediction and prevention: Policy implications. *Marine Policy* 108, 2019. Doi: 10.1016/j.marpol.2019.103528
- [108] Prabowo A. R., Bae D. M.: Environmental risk of maritime territory subjected to accidental phenomena: Correlation of oil spill and ship grounding in the Exxon Valdez’s case. *Results in Engineering* 4, 100035, 2019. Doi: 10.1016/j.rineng.2019.100035
- [109] Hodge V. J., Austin J.: A survey of outlier detection methodologies. *Artificial Intelligence Review* 22, 2, 85–126, 2004. Doi: 10.1007/s10462-004-4304-y
- [110] Wang Y., Han L., Liu W., Yang S., Gao Y.: Study on wavelet neural network based anomaly detection in ocean observing data series. *Ocean Engineering* 186, 2019. Doi: 10.1016/j.oceaneng.2019.106129
- [111] Ester M., Kriegel H., Sander J., Xu X.: A density-based algorithm for discovering clusters in large spatial databases with noise. *Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining*, 226–31, 1996.
- [112] Heidari S., Alborzi M., Radfar R., Afsharkazemi M. A., Rajabzadeh G. A.: Big data clustering with varied density based on MapReduce. *Journal of Big Data* 6, 1, 77, 2019. Doi: 10.1186/s40537-019-0236-x
- [113] Tang J., Liu F., Wang Y., Wang H.: Uncovering urban human mobility from large scale taxi GPS data. *Physica A: Statistical Mechanics and*

- Its Applications* 438, 140–53, 2015. Doi: 10.1016/j.physa.2015.06.032
- [114] Zhou A.: Approaches for scaling DBSCAN algorithm to large spatial databases. *Journal of Computer Science and Technology* 15, 6, 509–26, 2000. Doi: 10.1007/BF02948834
- [115] Daszykowski M., Walczak B., Massart D.: Looking for natural patterns in data. Part 1. Density-based approach. *Chemometrics and Intelligent Laboratory Systems* 56, 2, 83–92, 2001. Doi: 10.1016/S0169-7439(01)00111-3
- [116] Tu E. Z. G., Mao S., Rachmawati L., Huang G.: Modeling Historical AIS Data For Vessel Path Prediction: A Comprehensive Treatment. *arXiv:2001.01592*, 2020.
- [117] Suo Y., Chen W., Claramunt C., Yang S.: A ship trajectory prediction framework based on a recurrent neural network. *Sensors* 20, 18, 1–21, 2020. Doi: 10.3390/s20185133
- [118] Yang S., Xinya P., Zexuan D., Jiansen Z.: An Approach to Ship Behavior Prediction Based on AIS and RNN Optimization Model. *International Journal of Transportation Engineering and Technology* 6, 1, 16, 2020. Doi: 10.11648/j.ijtet.20200601.13
- [119] Li H., Liu J., Wu K., Yang Z., Liu R. W., Xiong N.: Spatio-temporal vessel trajectory clustering based on data mapping and density. *IEEE Access* 6, 58939–54, 2018. Doi: 10.1109/ACCESS.2018.2866364
- [120] Zhao L., Shi G.: Maritime Anomaly Detection using Density-based Clustering and Recurrent Neural Network. *Journal of Navigation* 72, 4, 894–916, 2019. Doi: 10.1017/S0373463319000031
- [121] Rosenfield I., Clancey W. J.: Book Review The Invention of Memory: A New View of the Brain. *Artificial Intelligence* 50, 241–84, 1991.
- [122] Brezillon P., Pomerol J. C.: Contextual Knowledge and Proceduralized Context. *AAAI Workshop on Modeling Context in AI Applications*, 16–20, 1999.
- [123] Nathalie J., Nathalie J., Catherine M., Mark A. G.: A Novelty Detection Approach to Classification, *IJCAI*, 518–523, 1995 (modified: 16 Jul 2019).
- [124] Scholkopf Bernhard, Williamson Robert, Smola Alex, Shawe-Taylor John, Platt John, Holloway Royal: *Support Vector Method for Novelty Detection*. In: *Proceedings of the 12th International Conference on Neural Information Processing Systems (NIPS'99)*, 582–588, MIT Press, Cambridge, MA, USA. 1999.
- [125] Ankerst M., Breunig M. M., Kriegel H. P., Sander J.: OPTICS: Ordering Points to Identify the Clustering Structure. *SIGMOD Record*

- (ACM Special Interest Group on Management of Data) 28, 2, 49–60, 1999. Doi: 10.1145/304181.304187
- [126] Quinlan J.: Induction of decision trees. *Machine Learning* 1, 1, 81–106, 1986. Doi: 10.1007/bf00116251
- [127] Wang X., Chen B., Qian G., Ye F.: On the optimization of fuzzy decision trees. *Fuzzy Sets and Systems* 112, 1, 117–25, 2000. Doi: 10.1016/S0165-0114(97)00386-2
- [128] Murthy S., Kasif S., Salzberg S.: A System for Induction of Oblique Decision Trees. *Journal of Artificial Intelligence Research* 2, 1–32, 1994. Doi: 10.1613/jair.63
- [129] Pedregosa Fabian., et al.: Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research* 12, 2825–30, 2011.
- [130] Breiman L., Friedman J., Olshen R., Stone C.: *Classification and regression trees*. Monterey, CA: Wadsworth & Brooks/Cole Advanced Books & Software
- [131] Beghi A., Cecchinato L., Corazzol C., Rampazzo M., Simmini F., Susto G.: A one-class SVM based tool for machine learning novelty detection in HVAC chiller systems. *IFAC Proceedings Volumes (IFAC-PapersOnline)*, 19, IFAC Secretariat, 1953–8, 2014.
- [132] Sadooghi M. S., Esmailzadeh K. S.: Improving one class support vector machine novelty detection scheme using nonlinear features. *Pattern Recognition* 83, 14–33, 2018. Doi: 10.1016/j.patcog.2018.05.002
- [133] Lauer M.: A mixture approach to novelty detection using training data with outliers. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2167, Springer Verlag, 300–11, 2001.
- [134] Sokolov E.: Neuronal models and the orienting reflex. In: Mary A.B. Brazier, editor. *The Central Nervous System and Behavior*, New York: Macey, 187–276, 1960.
- [135] Markou M., Singh S.: Novelty detection: A review - Part 1: Statistical approaches. *Signal Processing* 83, 12, 2481–97, 2003. Doi: 10.1016/j.sigpro.2003.07.018
- [136] Markou M., Singh S.: Novelty detection: A review - Part 2: Neural network based approaches. *Signal Processing* 83, 12, 2499–521, 2003. Doi: 10.1016/j.sigpro.2003.07.019
- [137] Schölkopf B., Platt J. C., Shawe-Taylor J., Smola A. J., Williamson R. C.: Estimating the support of a high-dimensional distribution. *Neural Computation* 13, 7, 1443–71, 2001. Doi:

10.1162/089976601750264965

- [138] Daranda A., Dzemyda G.: Novel machine learning approach for self-aware prediction based on the contextual knowledge. *International Journal of Computers Communications & Control*. 2021 (Accepted).

APROBAVIMAS

Pagrindiniai tyrimo rezultatai pristatyti tarptautinėse ir respublikinėse konferencijose.

Pranešimai skaityti šiose tarptautinėse konferencijose:

1. Databases and Information Systems: 12th International Baltic Conference, DB&IS 2016, Riga, Latvia, July 4-6, 2016.
2. The 61TH international scientific conference of Riga technical university: IEEE Section of Information Technology and Management Science, Riga, Latvia, October 15-16, 2020.
3. WorldCist'21 – 9th World Conference on Information Systems and Technologies, in Terceira Island, Azores, Portugal, 30-31 March to 1-2 April 2021.

Straipsniai recenzuojamuose mokslo žurnaluose, referuojamuose „Web of Science Clarivate Analytics“ ir turinčiuose citavimo rodikli:

1. Jakovlev, S., Andziulis, A., Daranda, A., Voznak, M., & Eglynas, T.: Research on ship autonomous steering control for short-sea shipping problems. *Transport*, 32, 2, 198–208, 2017. <https://doi.org/10.3846/16484142.2017.1286521>
2. Daranda A., Dzemyda G.: Navigation decision support: discover of vessel traffic anomaly according to the historic marine data. *International Journal of Computers Communications & Control*, 15, 3, 2020. ISSN 1841-9844. <https://doi.org/10.15837/ijccc.2020.3.3864>.
3. Daranda A., Dzemyda G.: Novel machine learning approach for self-aware prediction based on the contextual knowledge. *International Journal of Computers Communications & Control*. 2021 (Accepted).

Straipsniai recenzuojamuose mokslo žurnaluose, referuojamuose „Web of Science Clarivate Analytics“:

4. Daranda A.: Neural network approach to predict marine traffic. *Baltic J. Modern Computing*, 4, 483–495, 2016.

Straipsniai recenzuojamuose tarptautinių konferencijų mokslo darbuose :

5. Daranda A., Dzemyda G: Artificial intelligence based strategy for vessel decision support system. In: *Proceedings of the WorldCist'21 – 9th World Conference on Information Systems and Technologies*, Terceira, pp. 49–58, 2021.
6. Jakovlev S., Daranda A., Voznak M., Lektuers A., Eglynas T., Jusis M.: Analysis of the possibility to detect fake vessels in the automatic identification system. In: *2020 61st International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS)*, IEEE, pp. 1–5, 2020.

Pranešimų santraukos konferencijų leidiniuose:

7. Daranda, Andrius; Dzemyda, Gintautas: A Marine Traffic Prediction using Recurrent Neural Networks, *9th International workshop on Data Analysis Methods for Software Systems (DAMSS)*, Druskininkai, Lithuania, November 30–December 2, 2017. Vilnius: Vilniaus universitetas, 2017. ISBN 9789986680642. p. 14-15.

1 PRIEDAS

1 lentelē Laivo veiklos pobūdis

Eil. Nr.	Laivo veiklos pobūdis
1	Laivas eigoje
2	Laivas ant inkaro
3	Nevaldomas laivas
4	Riboto manevringumo laivas
5	Apribotas dēl grimzlēs
6	Prišvartuotas
7	Ant seklumos
8	Žvejoja
9	Būriuoja
10	Rezervuota
11	Rezervuota
12	Rezervuota
13	Rezervuota
14	Rezervuota
15	Rezervuota
16	Rezervuota

2 lentelė Laivų tipai

Eil. Nr.	Laivo tipas
1	Nežinomas
2	Rezervuota
3	Laivas ant povandeninių sparnų
4	Žvejys
5	Laivas velka objektą
6	Žemkasė / žemsiurbė
7	Laivas, vykdamas darbus su narais
8	Karinis laivas
9	Būrinis laivas
10	Pramoginis
11	Rezervuota
12	Greitaeigis
13	Locmanas
14	Paieškos ir gelbėjimo laivas
15	Vilkikas
16	Uosto pagalbinis laivas
17	Užterštumo likvidavimo laivas
18	Teisėsaugos laivas
19	Papildomas, naudojamas vietinėms reikmėms
20	Medicinos transportas
20	Nekovinis
21	Keleivinis laivas
22	Krovininis laivas
23	Tanklaivis
24	Kitas laivų tipas

PADĖKA

Esu labai dėkingas savo moksliniam vadovui prof. habil. dr. Gintautui Dzemydai už vertingas mokslines konsultacijas, svarbias ir konstruktyvias pastabas, nuoseklų vadovavimą, visokeriopą pagalbą bei didelę kantrybę, rengiant šią disertaciją. Dėkoju už visapusišką supratimą, motyvavimą ir pasitikėjimą manimi.

Taip pat esu dėkingas disertacijos recenzentams prof. dr. Aisčiui Raudžiui ir dr. Viktor Medvedev, skyrusiems laiko mano disertacijai perskaityti ir pateikusiems labai vertingų patarimų bei konstruktyvių pastabų.

Nuoširdžiai dėkoju savo šeimai, kuri besąlygiškai mane palaikė, motyvavo bei skatino judėti pirmyn.

Taip pat dėkoju visiems, kurie tiesiogiai ar netiesiogiai prisidėjo prie šio darbo naudingomis pastabomis bei pasiūlymais.

Andrius Daranda

UŽRAŠAMS

UŽRAŠAMS

Andrius Daranda

MAŠININIŲ MOKYMŲSI GRINDŽIAMAS LAIVYBOS EISMO
DALYVIŲ ELGSENOS PROGNOZAVIMAS BEI
NESTANDARTINIŲ LAIVYBOS SRAUTO SITUACIJŲ
ATRADIMAS

Daktaro disertacija
Technologijos mokslai
Informatikos inžinerija (T 007)

Redaktorė Jorūnė Rimeisytė-Nekrašienė

Vilniaus universiteto leidykla
Saulėtekio al. 9, III rūmai, LT-10222 Vilnius
El. p.: info@leidykla.vu.lt, www.leidykla.vu.lt
Tiražas 20 egz.