

KLAIPĖDOS UNIVERSITETAS

Giedrius ŠILAS

LAIVŲ POVEIKIO UOSTO ORO TARŠAI VERTINIMO
MODELIS IR METODIKA

MOKSLO DAKTARO DISERTACIJA

TECHNOLOGIJOS MOKSLŲ SRITIS
TRANSPORTO INŽINERIJOS MOKSLO KRYPTIS (T 003)

Klaipėda, 2025

Disertacija rengta 2020–2025 metais Klaipėdos universitete.

Mokslinis vadovas

dr. Paulius RAPALIS (Klaipėdos universitetas, transporto inžinerija – T 003)

Disertacija ginama Klaipėdos universiteto Transporto inžinerijos mokslo krypties disertacijos gynimo taryboje:

Pirmininkas

prof. dr. Gintautas BUREIKA (Vilniaus Gedimino technikos universitetas, transporto inžinerija – T 003)

Nariai:

prof. dr. Edgar SOKOLOVSKIJ (Vilniaus Gedimino technikos universitetas, transporto inžinerija – T 003)

doc. dr. Artūras KERŠYS (Kauno technologijos universitetas, transporto inžinerija – T 003)

prof. habil. dr. Vytautas PAULAUSKAS (Klaipėdos universitetas, transporto inžinerija – T 003)

dr. Rodolfo TACCANI (Triesto universitetas, Italija, transporto inžinerija – T 003)

Disertacija ginama viešame Transporto inžinerijos mokslo krypties disertacijos gynimo tarybos posėdyje 2025 m. rugpjūčio 28 d., 13 val. Klaipėdos universiteto Aula Magna korpuso konferencijų salėje.

Adresas: Herkaus Manto g. 90-2, LT-92295 Klaipėda, Lietuva.

Tel.: +370 398 936; el. p.: mokslas@ku.lt

Pranešimai apie numatomą ginti disertaciją išsiųsti 2025 m. liepos 28 d.

Disertaciją galima peržiūrėti Klaipėdos universiteto talpykloje <http://ku.lt/mokslas/doktorantura> ir Vilniaus Gedimino technikos universiteto bibliotekoje (Saulėtekio al. 14, LT-10223 Vilnius, Lietuva), Klaipėdos universiteto (Herkaus Manto g. 84, LT-92294 Klaipėda, Lietuva), Vytauto Didžiojo universiteto (Studentų g. 11-146, Akademija, LT-53361 Kauno raj., Lietuva), Kauno technologijos universiteto (K. Donelaičio g. 20, LT-44239 Kaunas, Lietuva) bibliotekose.

© Giedrius Šilas, 2025

© Klaipėdos universiteto leidykla, 2025

KLAIPĖDA UNIVERSITY

Giedrius ŠILAS

A MODEL AND METHODOLOGY FOR ASSESSING
THE IMPACT OF SHIPS ON PORT AIR POLLUTION

DOCTORAL DISSERTATION

TECHNOLOGICAL SCIENCES,
FIELD OF TRANSPORT ENGINEERING (T 003)

Klaipėda, 2025

The dissertation was prepared at Klaipėda University from 2020 to 2025.

Scientific Supervisor

Dr. Paulius RAPALIS (Klaipėda University, Transport Engineering – T 003)

The dissertation is defended in the Dissertation Defense Council of the Transport Engineering scientific field at Klaipėda University:

Chairman

Prof. Dr. Gintautas BUREIKA (Vilnius Gediminas Technical University, Transport Engineering – T 003)

Members:

Prof. Dr. Edgar SOKOLOVSKIJ (Vilnius Gediminas Technical University, Transport Engineering – T 003)

Assoc. Prof. Dr. Artūras KERŠYS (Kaunas University of Technology, Transport Engineering – T 003)

Prof. Dr. Habil. Vytautas PAULAUSKAS (Klaipėda University, Transport Engineering – T 003)

Dr. Rodolfo TACCANI (University of Trieste, Italy, Transport Engineering – T 003)

The dissertation will be defended at a public meeting of the Transport Engineering scientific field Defense Council, which will take place on August 28, 2025, at 1 PM in the conference hall of the Aula Magna building at Klaipėda University.

Address: Herkaus Manto g. 90-2, LT-92295 Klaipėda, Lithuania.

Tel.: (0 46) 398 936; Email: mokslas@ku.lt

Notifications regarding the dissertation defense, specifying the website address where the dissertation is available, will be sent on July 28, 2025.

The dissertation can be reviewed on the website at <https://www.ku.lt/mokslas/doktorantura/> and in the libraries of Vilnius Gediminas Technical University (Saulėtekio al. 14, LT-10223 Vilnius, Lithuania), Klaipėda University (Herkaus Manto str. 84, LT-92294 Klaipėda, Lithuania), Vytautas Magnus University (Studentų str. 11-146, Akademija, LT-53361 Kaunas district, Lithuania), and Kaunas University of Technology (K. Donelaičio str. 20, LT-44239 Kaunas, Lithuania).

Reziumė

Disertaciniame darbe nagrinėjama uoste eksploatuojamų laivų oro taršos įvertinimo įrankių trūkumo problematika. Pagrindinis tyrimų objektas – uoste eksploatuojamų laivų išmetamų teršalų emisijos, jų pasiskirstymas uosto aplinkoje bei įtaka aplinkos oro užterštumui, atsižvelgiant į laivų eismo intensyvumą, aplinkos sąlygų kaitą ir laivų technines savybes. Šiuo metu naudojami taršos vertinimo modeliai remiasi statistiniais bei gamykliniais duomenimis, ir yra tinkamesni ilgų reisų jūra vertinimui. Tačiau vertinant uoste eksploatuojamus laivus, kurių varikliai veikia maža apkrova, papildomai apsunkina vertinimą, nes yra didesnė tikimybė nukrypti nuo nominalių parametrų, o faktinis jėgainės apkrovimas yra nežinomas. Todėl, kai atliekami vertinimai, iš esmės nei uostai, nei institucijos šiuo metu neturi patikimo įrankio uoste eksploatuojamų laivų emisijų ir taikomų taršos mažinimo priemonių efektyvumui vertinti.

Darbe sprendžiami šie uždaviniai:

1. Įvertinti uoste eksploatuojamų laivų išmetamų oro teršalų kiekio ir pasiskirstymo uosto teritorijoje vertinimo metodikų tinkamumą.
2. Remiantis eksperimentiniais emisijų nuotolinių matavimų duomenimis, skaitinio modeliavimo tyrimais ir statistiniais duomenimis suformuoti laivų emisijų ir šleifo įtakos vertinimo metodiką.
3. Sukurti laivų, eksploatuojamų uoste, emisijų vertinimo detalų matematinį modelį.
4. Parengti uoste eksploatuojamų laivų įtakos aplinkos oro užterštumui vertinimo metodiką.
5. Remiantis metodikos ir modelio rezultatais atlikti modelio verifikaciją ir pateikti rekomendacijas tolesniems tyrimams.

Disertaciją sudaro įvadas ir keturi skyriai, naudotos literatūros ir autoriaus publikacijų disertacijos tema sąrašai ir trylika priedų.

Įvadiniame skyriuje aptariama tiriamoji problema, darbo aktualumas, aprašomas tyrimų objektas, formuluojamas darbo tikslas bei uždaviniai, aprašoma tyrimų metodika, darbo mokslinis naujumas, darbo rezultatų praktinė reikšmė, ginamieji teiginiai. Įvado pabaigoje pristatomos disertacijos tema autoriaus paskelbtos publikacijos, pranešimai konferencijose ir disertacijos struktūra.

Pirmajame skyriuje pateikiama Lietuvoje ir užsienio šalyse atliktų mokslinių tyrimų disertacijos tema apžvalga, apžvelgiamos plačiausiai naudojamos taršos iš laivų vertinimo tyrimų ir modeliavimo metodikos. Skyriaus pabaigoje formuluojamos ir pateikiamos apibendrintos skyriaus išvados.

Antrajame skyriuje pateikiama laivų taršos įvertinimo bei laivų taršos poveikio uosto oro kokybei metodikų kūrimo principai. Aprašoma matematinio taršos vertinimo iš uoste eksploatuojamų laivų modelio kūrimas, naudojami parametrai. Nurodoma

tyrimų rezultatų apdorojimo metodika bei duomenų masyvų sinchronizavimo metodika. Taip pat pateikiamas detalus tolimojo oro teršalų perdavimo Europoje stebėjimo ir įvertinimo kooperatinės programos Europoje (EMEP) metodikos papildymo algoritmas. Nurodoma, kaip papildyta metodika gali būti panaudojama dinaminiam uoste eksploatuojamų laivų taršos vertinimui.

Trečiajame skyriuje pateikiami eksperimentinių tyrimų rezultatai: uoste eksploatuojamų laivų kietųjų dalelių šleifų pikų (piku laikomas koncentracijos padidėjimas 2–3 kartus nuo vidutinės koncentracijos ir trunka ne ilgiau nei 15 min., jeigu piko trukmė ilgesnė nei 15 min., vertinama, kad įvyko persidengimas arba atsirado kito taršos šaltinio, esančio kranto pusėje, poveikis) ir laivų intensyvumo uoste analizė; uostuose eksploatuojamų laivų oro taršos vertinimo dirbtinių neuroninių tinklų pagrindu sukurto modelio rezultatų analizė bei tinkamumas taršos iš uoste eksploatuojamų laivų įvertinimui; EMEP trečiojo lygmens metodikos papildymas AIS duomenimis ir pritaikymas uostuose eksploatuojamų laivų taršos (taršai) bei tiksliai (tiksliai) laivo pozicijos (pozicijai) įvertinimui (įvertinti). Skyriaus pabaigoje pateikiamos ir apibendrinamos gautų rezultatų išvados.

Disertacijos pabaigoje pateikiamos bendrosios išvados.

Abstract

The dissertation addresses the issues of assessing air pollution from ships operating in a port. The main objective of research is to evaluate the influence of ship traffic, environmental conditions, and technical characteristics of ships on exhaust gas emissions in ports. Currently, pollution assessment models rely on statistical/factory data and are more suitable for assessing long sea voyages, where operational characteristics are close to designed parameters. However, assessment in the port is complicated by the fact that engine loads are low, and port waters differ in layout and environmental conditions. As a result, neither port authorities nor government institutions currently have a reliable tool to accurately inventory emissions from ships operating in the port, pollutant dispersion, or the effectiveness of pollution reduction measures.

The study addresses the following tasks:

- Evaluate the applicability of ship emission assessment methodologies for quantifying and characterizing the spatial distribution of air pollutants emitted by vessels operating in port areas.
- Develop a methodology for the assessment of particulate matter emissions and exhaust plume impact from port-operating vessels, based on experimental remote emission measurements, numerical simulations, and statistical data.
- Create a detailed mathematical model for evaluating emissions from ships operating within the port environment.
- Develop a methodology for assessing the contribution of port-operating vessels to ambient air pollution.
- Based on the results of the methodology and model, perform model verification and provide recommendations for further research.

Santrumpos

AE – pagalbiniai varikliai;
AIS – automatinė identifikavimo sistema;
CFD – skysčių dinamika;
CNN – konvoliuciniai neuroniniai tinklai;
CO – anglies monoksidas;
CO₂ – anglies dioksidas;
DNN – gilieji neuroniniai tinklai;
DNT – dirbtiniai neuroniniai tinklai;
DWT – dedveito tonažas;
EMEP – tolimojo oro teršalų perdavimo Europoje stebėjimo ir įvertinimo kooperatinės programos Europoje;
EMSA – Europos jūrų saugumo agentūros;
FNN – tiesioginiai neuroniniai tinklai;
GT – bendrasis tonažas;
KD – kietosios dalelės;
LNG – suskystintos gamtinės dujos;
LOJ – lakieji organiniai junginiai;
LUVIS – laivybos uoste valdymo informacinė sistema;
ME – pagrindiniai varikliai;

MNA – maksimalios nuolatinės apkrovos;
MSE – vidutinė kvadratinė paklaida;
 NO_x – azoto oksidai;
NRMSE – normalizuota kvadratinės vidutinės paklaidos šaknis;
RMSE – kvadratinės vidutinės paklaidos šaknis;
RNN – pasikartojantys neuroniniai tinklai;
SECA – sieros emisijos kontrolės zona;
 SO_2 – sieros dioksidas;
 SO_x – sieros oksidai;
STEAM – laivų eismo išmetamųjų teršalų įvertinimo modelis;
TJO – tarptautinė jūrų organizacija;
VHF – labai aukšto dažnio radijo dažniai.

Formulių simboliai

- c – kampas Žemės centre tarp dviejų spindulių, rad;
 d – atstumas tarp dviejų taškų, km;
 e – variklio kategorija (pagrindinis, šalutinis);
 E_C – emisijos plaukimo jūroje eksploataciniu greičiu metu, t;
 E_{CO_2} – per visą reisą išmestas CO_2 kiekis (kg);
 E_H – emisijos laivui prisišvartavus prie krantinės, t;
 e_H – laivo stovėjimo prie krantinės metu laivų sunaudota energija;
 E_M – emisijos manevravimo metu, t;
 E_t – emisijos per visą laivo kelionę, t;
 E_{trip} – emisijos per visą laivo kelionę, g;
 EF – emisijos koeficientas, g/kWh;
 i – teršalas (SO_x , NO_x , KD);
 j – variklio tipas (mažo greičio dyzelinis, vidutinio greičio dyzelinis, didelio greičio dyzelinis, dujų turbina, garo turbina);
 LF – variklio apkrova, %;
 m – kuro tipas;
 P – variklių nominalioji galia, kW;
 p – skirtingas kelionės etapas (plaukimas jūroje eksploataciniu greičiu, stovėjimas prie krantinės, manevravimas);

R – Žemės spindulys, km;
SFOC – savitosios mazuto sąnaudos, kg/kWh;
T – laikas, h.

Turinys

IVADAS	17
Tiriamoji problema	17
Darbo aktualumas	18
Tyrimų objektas	19
Darbo tikslas	19
Darbo uždaviniai	19
Tyrimų metodika	20
Darbo mokslinis naujumas ir jo reikšmė	20
Praktinė reikšmė	21
Ginamieji teiginiai	21
Darbo rezultatų aprobavimas	22
Disertacijos struktūra	23
1. LAIVŲ TARŠOS ĮVERTINIMO BEI LAIVŲ TARŠOS POVEIKIO APLINKOS ORO KOKYBEI ĮVERTINIMO MOKSLINĖ ANALIZĖ	25
1.1. Vandens transporto sektoriaus analizė	25
1.2. Laivų emisijų nustatymo metodai	28
1.3. Atmosferos oro taršos sklaidos modeliai	32
1.4. Laivų automatinio identifikavimo sistema ir laivų stebėsena bei valdymas	33
1.5. Dirbtinių neuroninių tinklų modeliai	35
1.6. Pirmojo skyriaus apibendrinimas	38
2. KLAIPĖDOS UOSTE EKSPLOATUOJAMŲ LAIVŲ TARŠOS ĮVERTINIMO METODIKA	41
2.1. Dirbtinių neuroninių tinklų kūrimo ir panaudojimo metodika	43
2.1.1. AQM65 oro taršos matavimo stotis	44
2.1.2. Uoste eksploatuojamų laivų šleifo analizė	45
2.1.3. Dirbtinio neuroninio tinklo modelio neuronų skaičiaus parinkimas	46

2.1.4. Dirbtinio neuroninio tinklo modelio struktūra ir algoritmas	48
2.1.5. Dirbtinio neuroninio tinklo modelio parametrai Neural Designer programinėje įrangoje	51
2.2. AIS duomenų integravimas į EMEP metodiką	52
2.3. Antrojo skyriaus apibendrinimas	58
3. TYRIMŲ REZULTATAI	61
3.1. Klaipėdos uoste eksploatuojamų laivų kietųjų dalelių šleifų analizė	61
3.2. Neuroninių tinklų modelio rezultatų analizė	78
3.3. Dinaminis uosto akvatorijos taršos vertinimas panaudojant AIS duomenis ir EMEP metodiką	89
3.4. Trečiojo skyriaus išvados	95
BENDROSIOS IŠVADOS	97
REKOMENDACIJOS	99
LITERATŪRA IR ŠALTINIAI	101
GYVENIMO APRAŠYMAS	113
SUMMARY	115
PRIEDAI	143
A priedas. Microsoft Excel VBA pikų identifikavimo kodas	144
B priedas. RoRo tipo laivų greičio pasiskirstymo žemėlapis (HeatMap)	147
C priedas. Tanklaivių greičio pasiskirstymo žemėlapis (HeatMap)	148
D priedas. Konteinerinių laivų greičio pasiskirstymo žemėlapis (HeatMap)	149
E priedas. Sausakrūvių laivų greičio pasiskirstymo žemėlapis (HeatMap)	150
F priedas. Vilkikų greičio pasiskirstymo žemėlapis (HeatMap)	151
G priedas. Žvejybinių laivų greičio pasiskirstymo žemėlapis (HeatMap)	152
H priedas. KD2,5 realių duomenų ir neuroninių tinklų modelio prognozuojamų duomenų koreliacija	153
I priedas. KD10 realių duomenų ir neuroninių tinklų modelio prognozuojamų duomenų koreliacija	154
J priedas. Dirbtinių neuroninių tinklų modelio Python kodas	155
K priedas. Pradinių AIS duomenų failo fragmentas	161
L priedas. AQM65 taršos vertinimo stoties duomenų fragmentas	162
M priedas. Leidimas naudoti 9 paveikslą disertacijoje.	163

Contents

INTRODUCTION	17
Topicality of the thesis	17
Relevance	18
Research object	19
Objective	19
Tasks	19
Research methodology	20
Scientific novelty	20
Practical significance	21
Defended statements	21
Approval of Research Results	22
Dissertation structure	23
1. SCIENTIFIC ANALYSIS OF SHIP POLLUTION ASSESSMENT AND ITS IMPACT ON PORT AIR QUALITY	25
1.1. Analysis of the water transport sector	25
1.2. Methods for Determining Ship Emissions	28
1.3. Atmospheric Air Pollution Dispersion Models	32
1.4. Automatic Identification System of Ships and Vessel Monitoring and Management	33
1.5. Artificial Neural Network Models	35
1.6. Summary of Chapter One	38
2. METHODOLOGY FOR ASSESSING THE POLLUTION OF SHIPS OPERATING IN THE PORT OF KLAIPEDA	41
2.1. Methodology for Developing and Applying Artificial Neural Networks	43
2.1.1. AQM 65 Air Pollution Monitoring Station	44
2.1.2. Plume Analysis of Ships Operating in the Port	45

2.1.3. Selection the Number of Neurons in the Artificial Neural Network Model	46
2.1.4. Structure and Algorithm of the Artificial Neural Network Model	48
2.1.5. Artificial Neural Network Model Parameters in Neural Designer Software	51
2.2. Integration of AIS Data into the EMEP Methodology	52
2.3. Summary of Chapter Two	58
3. RESEARCH RESULTS	61
3.1. Analysis of Particulate Plumes of Ships Operating in the Port of Klaipėda	61
3.2. Analysis of the Results of the Neural Network Model	78
3.3. Dynamic Assessment of Port Water Area Pollution Using AIS Data and the EMEP Methodology	89
3.4. Conclusions of Chapter Three	95
GENERAL CONCLUSIONS	97
LITERATURE AND SOURCES	101
CV	113
SUMMARY	115
ANNEXES	143
Annex A. Microsoft Excel VBA Code for Peak Identification	144
Annex B. Speed Distribution Map (HeatMap) of Ro-Ro Type Ships	147
Annex C. Speed Distribution Map (HeatMap) of Tankers	148
Annex D. Speed Distribution Map (HeatMap) of Container Ships	149
Annex E. Speed Distribution Map (HeatMap) of Bulk Carriers	150
Annex F. Speed Distribution Map (HeatMap) of Tugboats	151
Annex G. Speed Distribution Map (HeatMap) of Fishing Vessels	152
Annex H. Correlation Between Real $KD_{2.5}$ Data and Neural Network Model Forecasts	153
Annex I. Correlation Between Real KD_{10} Data and Neural Network Model Forecasts...	154
Annex J. Python Code for the Artificial Neural Network Model	155
Annex K. Fragment of the Raw AIS Data File	161
Annex L. Fragment of Data from the AQM 65 Air Pollution Monitoring Station	162
Annex M. Permission to Use Figure 9 in the Dissertation.	163

Ivadas

Tiriamoji problema

Per pastarąjį dešimtmetį didėjanti oro tarša tapo rimta problema, daranti įtaką daugeliui teritorijų, ne išimtis ir uostai, taip pat juos supanti aplinka. Nors dėl „Covid-19“ pandemijos 2019–2020 metais pasaulinio laivybos srautai smarkiai sumažėjo (European Maritime Safety Agency, 2022; Gavalas et al., 2022; Millefiori et al., 2021; United Nations Conference on Trade and Development, 2021), bet naujausia statistika rodo, kad laivybos srautas grįžta į priešpandeminį lygį (UNCTAD, 2022). Remiantis Europos jūrų saugumo agentūros (EMSA) duomenimis 2019–2020 m. ir 2019–2021 m. eismo tendencijos buvo neigiamos: –15 % ir –1 %, atitinkamai, tačiau laivybos srautas 2019–2022 m. padidėjo 8 % (European Maritime Safety Agency, 2022).

Europos komisija skiria labai daug dėmesio klimato neutralumui. Dėl šios priežasties numatoma teisiškai reglamentuoti didesnę atsinaujinančių bei mažai anglies dioksido (CO₂) dujų generuojančių kuro šaltinių naudojimą. Be to, yra kuriamos žaliųjų uostų iniciatyvos, siekiant sumažinti oro taršą uostuose (European Commission, 2020). Taip pat Europos Sąjungoje yra priimtas „Fit for 55“ teisinių dokumentų paketas, kuriuo siekiama, kad šalyse narėse iki 2030 m. šiltnamio dujų emisijos būtų sumažintos 55 procentais (European Commission, 2023b). Svarbu suprasti ir valdyti laivų generuojamą taršą uostuose, todėl būtina turėti galimybę vertinti taršos sklaidą ir pasiskirstymą aplinkoje. Šiuolaikiniai sklaidos modeliai suteikia įvairių vertinimo

galimybių, tačiau jų naudojimas yra ribotas dėl reikalingo didelio kiekio pradinio duomenų tiksliam sklaidos modelio darbui, dėl šios priežasties modeliavimo procesas tampa per ilgas uosto veiklai, kadangi uosto aplinka yra dinamiška, kurioje situacija nuolat kinta, ir reikalauja vertinimo atsižvelgiant į esamas sąlygas (Aeroqual, 2024; AirSensEUR, 2019; Shen et al., 2022). Vertinimą uoste apsunkina ir tai, kad laivų jėgainės yra mažai apkrautos, o uostų akvatorijos skiriasi savo išdėstymu, taip pat aplinkos sąlygos uostuose yra skirtingos.

Darbo aktualumas

Laivyba techniniu požiūriu yra unikali: skiriasi laivuose naudojamo kuro kokybė, laivų jėginių techninė būklė, laivų amžius, emisijų mažinimo priemonių tipai, naudojimas ir net eksploatacijos kokybė. Didelė dalis šios informacijos nėra prieinama be tiesioginių kontaktų su laivą eksploatuojančia įmone.

Transporto sektorius yra vienas didžiausių energijos vartotojų rinkoje, jo sunaudojama energija sudaro daugiau nei 26,6 % viso energijos balanso pasaulyje ir net 33 % Europoje, todėl transportas yra vienas didžiausių oro teršėjų. Ypač tai aktualu uostamiesčiuose, kur aplinkos oro užterštumas yra visada didesnis, laivų išmetami teršalai vidaus vandenių regionuose ir uostamiesčiuose sudaro 2,7 % CO₂, 15 % NO₂ ir 4–9 % SO₂ visų antropogeninių emisijų (International Maritime Organization, 2021).

Dedama daug pastangų mažinti aplinkos taršą uostuose. Viena iš tokių priemonių yra žalių uostų (angl. green port) iniciatyva – tai tarptautinė strategija, kuria siekiama sumažinti jūrų uostų poveikį aplinkai ir skatinti tvarų jūrų transportą. Šios iniciatyvos tikslas – diegti aplinkai palankias technologijas ir praktikas, tokias kaip atsinaujinančios energijos naudojimas, oro ir vandens taršos mažinimas bei efektyvesnis išteklių valdymas. Žalieji uostai prisideda prie klimato kaitos mažinimo, skatindami atsakingą energijos vartojimą bei ekologines inovacijas jūrų transporto sektoriuje. Tinkamam šios iniciatyvos vykdymui reikalingi įrankiai, kuriuos taikant būtų galima įvertinti ne tik uosto veiklos, bet ir uoste eksploatuojamų laivų taršą.

Šiuo metu naudojami taršos vertinimo modeliai, tokie kaip EMEP ar STEAM, nors ir remiasi plačiomis statistinių duomenų gamomis, turi tik artimesnius gamykliniams parametrus duomenis, tokie duomenys yra tinkamesni ilgiems reisams jūra vertinti, kai laivas veikia pastoviai apkrova, ir jėgainės darbo charakteristika yra maksimaliai artima projektuotiems parametrų. Tačiau uoste eksploatuojamų laivų, kurių varikliai veikia mažomis apkrovomis, vertinimas tampa sudėtingesnis dėl dalinės apkrovos režimų duomenų neapibrėžtumo. Pavyzdžiui, EMEP metodikoje manevravimo režimų (20 % apkrova) emisijų vertinimo paklaidos yra dvigubai didesnės nei plaukimo jūra režimų (80 % apkrova), o faktinis jėgainės apkrovimas lieka nežinomas (European Environment Agency., 2019). Todėl, kai atliekami vertinimai, iš esmės nei

uostai, nei institucijos šiuo metu neturi patikimo įrankio uoste eksploatuojamų laivų emisijų ir taikomų taršos mažinimo priemonių efektyvumui vertinti. Be šio parametro nėra galimybės žinoti, kaip uosto taikomos ar laivuose esančios priemonės gali paveikti laivų emisijas uoste, o tai yra labai svarbu siekiant valdyti uosto veiklą.

Siūlomas tyrimas aktualus siekiant valdyti uosto įtaką aplinkos oro užterštumui.

Tyrimais siekiama atlikti analitinius uoste eksploatuojamo laivyno įtakos miesto aplinkos oro užterštumui vertinimą ir inventorizavimą.

Tyrimų objektas

Darbo tyrimų objektas – uoste eksploatuojamų laivų išmetamų teršalų emisijos, jų pasiskirstymas uosto aplinkoje ir įtaka aplinkos oro užterštumui, atsižvelgiant į laivų eismo intensyvumą, aplinkos sąlygų kaitą ir laivų technines savybes.

Darbo tikslas

Sukurti ir pritaikyti uoste eksploatuojamų laivų išmetamų teršalų kiekio, jų pasiskirstymo uosto aplinkoje bei jų įtakos aplinkos oro užterštumui vertinimo tyrimų matematinį modelį ir metodiką.

Darbo uždaviniai

Darbo tikslui pasiekti iškelti uždaviniai:

1. įvertinti uoste eksploatuojamų laivų išmetamų oro teršalų kiekio ir pasiskirstymo uosto teritorijoje vertinimo metodikų tinkamumą;
2. remiantis eksperimentiniais emisijų nuotolinių matavimų duomenimis, skaitinio modeliavimo tyrimais ir statistiniais duomenimis suformuoti laivų emisijų ir šleifo įtakos vertinimo metodiką;
3. sukurti laivų, eksploatuojamų uoste, emisijų vertinimo detalų matematinį modelį;
4. parengti uoste eksploatuojamų laivų įtakos aplinkos oro užterštumui vertinimo metodiką;
5. remiantis metodikos ir modelio rezultatais atlikti modelio verifikaciją ir pateikti rekomendacijas tolesniems tyrimams.

Tyrimų metodika

Siekiant mokslinių sprendimų bei praktinių rezultatų, disertaciniame darbe taikomi kompleksiniai analitiniai, eksperimentiniai ir dirbtinių neuroninių tinklų modeliavimo metodai. Laivų taršos sklaidai vertinti yra reikalingi emisijų duomenys, kurių realiai gauti nėra galimybės. Tiesioginiai taršos matavimai fiziškai esant laivuose yra netikslingi, kai reikia didelio srauto laivų duomenų. Dėl šios priežasties disertaciniame darbe buvo pasirinkta naudoti nuotolinės matavimo stoties rezultatus ir mašininio mokymosi metodiką taršai iš uoste eksploatuojamų laivų įvertinti. Dirbtinių neuroninių tinklų (DNT) modelio kūrimui buvo naudojama programinė įranga NeuralDesigner. Buvo sudarytas bendras duomenų masyvas, kuris reikalingas modelio apmokymui. Masyvas sudarytas naudojant laivo techninius parametrus, meteorologinius duomenis, laivo pozicijos ir greičio duomenis. Laivų techniniai duomenys buvo susieti su laivų pozicijos ir greičio duomenimis pagal laivų identifikacinį numerį (MMSI). Toliau į duomenų masyvą buvo įtraukti meteorologiniai duomenys. Detali uosto aplinkos taršos vertinimo metodika sudaryta papildant Tolimojo oro teršalų perdavimo Europoje stebėjimo ir įvertinimo kooperatinės programos Europoje (EMEP) metodiką. Metodika buvo pildoma išsamiais AIS (automatinė identifikavimo sistema) duomenimis – laivo padėtis koordinatėmis, kursas, greitis virš žemės bei identifikavimo numeris (IMO ir MMSI).

AIS duomenys gauti iš Lietuvos transporto saugos administracijos. Laivų techninių parametrų duomenys paimti iš IHS Fairplay, BalticShipping bei Marine MAN Ltd duomenų bazių. Meteorologiniai parametrai gauti iš archyvinių duomenų bazės, laisvai prieinamų internetu (Freemeteo). Tiesioginiai uoste eksploatuojamų laivų taršos duomenys buvo gauti iš Klaipėdos uoste esančios AQM65 taršos matavimo stoties.

Dinaminio emisijų ir galios vertinimui naudoti AIS duomenys ir EMEP metodika. Dirbtinių neuroninių tinklų kūrimui naudota programinė įranga NeuralDesigner. Sukurto modelio tikslumui patikrinti naudotas papildomas duomenų masyvas bei tikrintos modeliavimo paklaidos.

Darbo mokslinis naujumas ir jo reikšmė

Nors neuroniniai tinklai yra gana gerai žinomas ir plačiai naudojamas įrankis, tačiau jų naudojimas laivyboje ypač suaktyvėjo 2021 metais. Tai paskatino pasirinkti neuroninius tinklus vertinant uosto taršos sklaidą ir poveikį aplinkai. Neuroniniai tinklai, kaip įrankis, leidžia įvertinti ryšius tarp didelio kiekio įvesties parametrų, todėl buvo pasirinkti naudoti disertaciniams tyrimams. Įprastai uosto taršai vertinti yra pasitelkiama EMEP metodika, kuri leidžia įvertinti sumines uosto emisijas per ilgą laiko tarpą, tačiau šioje metodikoje nėra vertinama laivo pozicija ir įprastai uostas vertina-

mas kaip vienas objektas. Darbe sukurta metodika leidžia uosto taršą vertinti dinamiškai, t. y. realiu laiku arba esant poreikiui vertinti specifinį laikotarpį. Taip pat buvo sukurta neuroninių tinklų modelis, kuris leidžia vertinti taršos uoste sklaidą, o tai leidžia vertinti taršos poveikį aplinkai. Disertacijoje parengtas modelis taikomas kietųjų dalelių koncentracijų vertinimui, tačiau modelis nesiremia fiziniais skaičiavimais, o tik ryšių tarp parametru įvertinimu, todėl yra tinkamas bet kokiam teršalui įvertinti. Rengiant disertaciją gauti transporto inžinerijos mokslo srities nauji rezultatai:

1. Sudaryta metodika, papildant EMEP metodiką AIS duomenimis, leidžia vertinti uostą ne kaip statiską, bet kaip dinaminį objektą, kai galima įvertinti laivų generuojamą taršą bet kurioje uosto dalyje, bet kuriuo momentu.
2. Sukurtas dirbtinių neuroninių tinklų modelis, leidžiantis realiu laiku prognozuoti realias laivų emisijas bet kurioje uosto vietoje.

Praktinė reikšmė

Sukurtas dirbtinių neuroninių tinklų modelis bei AIS duomenų integravimo į esamą taršos vertinimo metodiką suteikia galimybę:

- realiu laiku vertinti laivybos uoste įtaką aplinkos oro kokybei bei priimti sprendimus dėl atitinkamo laivybos veiklos koordinavimo;
- atlikti detalią laivų eismo ir išmetamųjų dujų šleifų uoste analizę ir nustatyti laivų eismo intensyvumą pagal laivo tipą; laivų išmetamųjų dujų šleifo įtaka aplinkos oro kokybei analizuojamoje vietoje ir laivo eksploatavimo uoste metu;
- įvertinti oro teršalų ir CO₂ emisijas bei energijos sunaudojimą krantinėje, pateikiant vertingas įžvalgas apie emisijų karštuosius taškus ir mažinimo potencialus;
- dirbtinių neuroninių tinklų modelį naudoti be apribojimų, kadangi modelis yra pateikiamas kaip Python programavimo kalbos kodas, kuris gali būti įdiegiamas į bet kokią esamą sistemą. Kodui nėra būtina pradinė, modeliui kurti naudota programinė įranga.

Ginamieji teiginiai

1. Detali uoste eksploatuojamų laivų įtakos aplinkos oro užterštumui vertinimo metodika leidžia vertinti uoste eksploatuojamų laivų eismo ir išmetamųjų dujų įtaką aplinkos oro užterštumui.
2. Neuroniniais tinklais paremtas laivybos įtakos aplinkos oro kokybei prognozavimo modelis leidžia tinkamai ir realiu laiku įvertinti uoste eksploatuojamų laivų taršą ir jos sklaidą.

3. Esamų laivybos taršos uoste įvertinimo modelių išplėtimas naudojant aukšto detalumo AIS duomenis kokybiškai pakeičia vertinimo rezultatų pritaikomumą, atskleidžiant oro teršalų ir energijos suvartojimo uoste kitimą ir teritorinį pasiskirstymo netolygumą.
4. Laivybos sukeltų intensyvių, trumpalaikių oro užterštumo padidėjimų uoste vertinimas leidžia atskleisti laivų eismo intensyvumo, laivo tipo ir kitų laivų techninių parametrų įtaką aplinkos oro užterštumo kitimui analizuojamoje uosto teritorijoje ir viso uosto mastu.

Darbo rezultatų apibavimas

Straipsniai Mokslinės informacijos instituto (ISI) pagrindinio sąrašo leidiniuose (ISI Web of Science, turinčiuose citavimo indeksą):

Rapalis, P.; Šilas, G.; Žaglinskis, J. Ship Air Pollution Estimation by AIS Data: Case Port of Klaipėda. J. Mar. Sci. Eng. 2022, 10, 1950. <https://doi.org/10.3390/jmse10121950>

Šilas, G.; Rapalis, P.; Lebedevas, S. Particulate Matter (PM₁, 2.5, 10) Concentration Prediction in Ship Exhaust Gas Plume through an Artificial Neural Network. J. Mar. Sci. Eng. 2023, 11, 150. <https://doi.org/10.3390/jmse11010150>

Straipsniai kituose Mokslinės informacijos instituto (ISI) duomenų bazėse referuojamuose leidiniuose [Proceedings ir kt.]:

Šilas, G.; Rapalis, P. 2021. Review of Methods and Models for Estimating Ship Emissions in Port. In Transport Means 2021, Proceedings of the 25th International Scientific Conference, Kaunas, Lithuania, 6–8 October 2021; Technologija: Kaunas, Lithuania, pp. 955–960.

Straipsniai tarptautinių duomenų bazių referuojamuose leidiniuose:

Rapalis, P., Šilas, G. 2023. Artificial Neural Network Model Use for Particulate Matter Evaluation from Ships in Klaipėda Port. In: Prentkovskis, O., Yatskiv (Jackiva), I., Skačkauskas, P., Maruschak, P., Karpenko, M. (eds) TRANSBALTICA XIII: Transportation Science and Technology. TRANSBALTICA 2022. Lecture Notes in Intelligent Transportation and Infrastructure. Springer, Cham. https://doi.org/10.1007/978-3-031-25863-3_7

Straipsniai kituose recenzuojamuose mokslo leidiniuose: konferencijų pranešimų medžiagoje.

Šilas, G.; Rapalis, P. Use of Artificial Neural Networks as a tool for port pollution control. 2024. 5th Baltic Earth Conference. New Challenges for Baltic Sea Earth System Research. Conference Proceedings. Jūrmala, Latvia: International Baltic Earth Secretariat. pp. 114–115.

Seminaras

Seminaras Lietuvos auštojoje jūreivystės mokykloje, 2024. Seminaro tema „Klaipėdos uoste operuojančių laivų įtakos vertinimo modelio uostamiesčio oro kokybei sukūrimas“.

Stażuotė

Stażuotė AB „Klaipėdos valstybinio jūrų uosto direkcija“ (J. Janonio g. 24-1, LT-92251 Klaipėda, Lietuva). Stažuotės laikotarpis: nuo 2023 m. liepos 1 d. iki 2023 m. rugpjūčio 30 d.

Disertacijos struktūra

Disertaciją sudaro įvadas, trys skyriai ir bendrosios išvados. Taip pat yra 13 priedų. Darbo apimtis yra 131 puslapis, neįskaitant priedų. Tekste panaudotos 6 formulės, 55 paveikslai ir 9 lentelės. Rašant disertaciją buvo panaudoti 132 mokslinės literatūros šaltiniai.


Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

1.1. Vandens transporto sektoriaus analizė

Jūrų transporto sektorius yra labai svarbi pasaulinės transporto sistemos sudedamoji dalis, palengvinanti prekių ir žmonių judėjimą per pasaulio vandenynus ir jūras. Per pastaruosius kelis dešimtmečius didėjant vandens transporto apimtims, išaugo laivybos emisijos, kurios prisideda prie sukeltų oro taršos ekologinių problemų, tokių kaip klimato kaita, ozono sluoksnio ardymas, rūgštieji lietūs (Eyring et al., 2010; Nunes et al., 2017; Saraçoğlu et al., 2013) concluding that it contributed to the global anthropogenic emissions through the emission of pollutants that have a strong impact on hu' health and also on climate change. Thus, this paper aimed to review published studies since 2010 that used activity-based methodology to estimate ship emissions, to provide a summary of the available input data. After exclusions, 26 articles were analysed and the main information were scanned and registered, namely technical information about ships, ships activity and movement information, engines, fuels, load and emission factors. The larger part of studies calculating in-port ship emissions concluded that the majority was emitted during hotelling and most of the authors allocating emissions by ship type concluded that containerships were the main pollutant emitters. To obtain technical information about ships the combined use of data from Lloyd's Register of Shipping database with other sources such as port authority's databases, engine manufactures and ship-owners seemed the best approach. The use

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

of AIS data has been growing in recent years and seems to be the best method to report activities and movements of ships. To predict ship powers the Hollenbach (1998). Jūrų transporto sektorius yra pasaulinės prekybos pagrindas, apimantis didžiąją dalį tarptautinės prekybos veiklos. Beveik 90 procentų visos tarptautinės prekybos vykdoma tarptautinės laivybos pramonės (Sheikh et al., 2023). Nors pasaulinės COVID-19 pandemijos metu (2019–2020 m.) laivybos mąstai sumažėjo (European Maritime Safety Agency, 2022; Gavalas et al., 2022; United Nations Conference on Trade and Development, 2021), tačiau nauja statistika rodo, kad laivybos sektorius sparčiai atsigauja ir grįžta į priešpandeminį lygį. Pagal Europos jūrų saugumo agentūros (EMSA) duomenis laivybos mąstai nuo 2019 iki 2022 metų išaugo 8 %, o laikotarpiu nuo 2019 iki 2020 metų sumažėjo 15 %, o nuo 2019 iki 2021 sumažėjo 1 % (European Maritime Safety Agency, 2022). Nors laivybos mąstai sumažėjo, tačiau krovos apimtys itin nekito (1 paveikslas).



1 pav. Tarptautinės jūrinės krovos kaita nuo 2000 iki 2021 metų, mln. tonų (duomenys gauti iš UNCTAD, 2022)




2 pav. Pasaulinės laivų flotilės išskirstymas pagal laivo tipą (Marine Flottenkommando, 2022)

Pandemijos metu labiausiai paveiktas sektorius buvo keleivių transportavimas keltais bei kruiziniais laivais. Tačiau keleiviniai laivai sudaro tik 9,22 % viso pasaulio prekybinio laivyno (2 paveikslas) (Kapitänleutnant Torsten Kowitz, 2022).


Jūrų pramonė yra svarbi pasaulio ekonomikos dalis, nes sukuriamos darbo vietos, generuojamos pajamos ir skatinama uostamiesčių ir jūrų regionų ekonominė plėtra. Tačiau tuo pat metu jūrų transportas prisideda prie pasaulinio išmetamųjų teršalų kiekio (Fuentes García et al., 2021; Li et al., 2022; Xiao et al., 2022). 3 paveiksle pateikiamas bendras transporto sektoriaus CO₂ išmetimų pasiskirstymas, vandens transporto sektorius sudaro 10 proc. visų išmetimų. Ketvirtajame paveiksle detalizuojama vandens transporto išmetamų šiltnamio efektą sukeliančių dujų pasiskirstymas pagal išmetamųjų teršalų rūšį. Didžiausia dalis, 91,32 proc., išmetimų sudaro anglies dioksidas, toliau seka suodžiai (6,85 proc.), metanas (1,35 proc.) bei diazoto oksidas (0,48 proc.). Uos-

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

tai vis daugiau dėmesio skiria tvariai praktikai, diegdami ekologiškas technologijas ir laikydamiesi aplinkosaugos taisyklių, kad sumažintų uosto veiklos ekologinį poveikį. Viena iš priemonių emisijoms mažinti, kurių imasi uostai, tarp jų ir Klaipėdos uostas, yra žaliojo uosto koncepcija (Bergqvist & Monios, 2019; Klaipėdos valstybinio jūrų uosto direkcija, 2022). Taip pat plačiai pradėtas uostų skaitmenizavimas, kai uostui valdyti pasitelkiami skaitmeniniai ištekliai siekiant padidinti uostų efektyvumą bei užtikrinti didesnę informacijos prieinamumą (Raza et al., 2023; Z. Zhang et al., 2023).



3 pav. Transporto sektoriaus CO₂ išmetimų paskirstymas 2022 m.
(modifikuota pagal (IEA, 2023))



4 pav. Išmetamųjų šiltnamio efektą sukeliančių dujų paskirstymas, kurį 2018 m. sudarė pasaulinė laivybos pramonė, pagal išmetamųjų teršalų rūšį
(European Commission, 2023a)

Uostai bei terminalai yra neatsiejamąs jūrų transporto sektoriaus sudedamosios dalys, atliekančios pagrindinį vaidmenį tarpusavyje susijusiame tarptautinės prekybos ir logistikos tinkle. Šių elementų veiksmingumas yra labai svarbus sklandžiam prekių ir keleivių judėjimui visame pasaulyje. Nuolatinės inovacijos, investicijos ir saugos bei aplinkosaugos standartų laikymasis yra labai svarbūs tvariam šio sektoriaus vystymuisi.

Pagrindiniai laivų, eksploatuojamų uoste ar pakeliui iš / į uostą, išmetami iš jėgainių teršalai yra azoto oksidai (NO_x), sieros oksidai (SO_x), anglies dvideginis (CO₂), lakieji organiniai junginiai (LOJ), anglies monoksidas (CO) bei kietosios dalelės (KD) (Alver et al., 2018; Cheng et al., 2019; Merico et al., 2016; Sorte et al., 2020). Šie teršalai taip pat turi įtakos visuomenės sveikatai. Manoma, kad dėl aplinkos oro taršos per metus miršta 4,2 mln. žmonių dėl insulto, širdies ligų, plaučių vėžio ir lėtinių kvėpavimo takų ligų (Jahangiri et al., 2018; Toscano et al., 2021; WHO, 2018). Pagal tarptautinės jūrų organizacijos (IMO) ketvirtąją šiltnamio dujų studiją, laivybos išmetamų šiltnamio efektą sukeliančių dujų (ŠESD) kiekis iki 2050 m. didės 90–130 % (International Maritime Organization, 2021).

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

Dedama daug pastangų siekiant sumažinti oro taršą iš laivų. Viena iš tarptautinės jūrų organizacijos (TJO) tarptautinės konvencijos dėl teršimo iš laivų prevencijos – MARPOL konvencija (International Maritime Organization, 1973). MARPOL konvencijos VI priede reglamentuojamas sieros oksidų, azoto oksidų ir kietųjų dalelių kiekis išmetamosiose dujose. Įsigaliojus šiam dokumentui, pasaulinis sieros kiekis jūriniame kure nuo 2012 m. neturėtų viršyti 3,5 proc. ir nuo 2020 m. sausio 1 d. ši suma buvo sumažinta iki 0,5 %. Tačiau sieros emisijos kontrolės zonose (SECA), pavyzdžiui, Baltijos jūroje arba Šiaurės jūroje, šie reikalavimai yra griežtesni. Nuo 2010 m. laivai turėjo naudoti degalus, turinčius ne daugiau kaip 1 % sieros, o nuo 2015 m. sausio mėn. – degalus, turinčius ne daugiau kaip 0,1 % sieros. Taip pat nuo 2022 m. įsigaliojusios MARPOL konvencijos VI priedo pataisoms (Resolution MEPC.328(76), 2022) naujiems laivams yra taikomas energijos efektyvumo projektavimo indeksas (EEDI) ir esamiems laivams taikomas energijos efektyvumo esamiems laivams indeksas (EEXI). EEDI ir EEXI indeksai įvesti siekiant sumažinti šiltnamio efektą sukeliančių dujų (ŠESD) išmetimus iš laivų. Ši sistema nustato reikalavimus laivo techninėms priemonėms, siekiant sumažinti anglies dioksido intensyvumą, atsižvelgiant į tokius veiksnius kaip laivo dizainas, variklio galia ir kuro sunaudojimas. Be to, Europos Sąjungos (ES) komisija priėmė sprendimą iki 2030 metų sumažinti CO₂ emisijas bent 55 %, o iki 2050 metų galo pasiekti visišką klimato neutralumą (European Commission, 2020).

MARPOL konvencijos VI priede nustatytos sieros oksidų ribinės vertės yra privalomos visam laivynui, tačiau azoto oksidų ribinės vertės taikomos tik naujiems laivams, atsižvelgiant į variklio sūkių dažnį ir įrengimo metus. Dėl šios priežasties TJO reglamentų poveikis NO_x yra ribotas (Nunes et al., 2017). Boersma et al. (2015) teigia, kad azoto oksidų emisijos iš laivybos Europoje ir toliau didėja. Laivyba daro ypač didelį poveikį oro taršai uostamiesčiuose, kur laivų eismas yra intensyvus, o daugelis laivų stovi prie krantinių su įjungtais pagalbiniais varikliais. Tačiau, nors laivyba jūrų uostuose yra svarbus taršos šaltinis, stebėti oro taršą iš laivų yra labai sunku. Kituose disertacinio darbo pirmo skyriaus poskyriuose analizuojamos uoste eksploatuojamų laivų taršos vertinimo priemonės.

1.2. Laivų emisijų nustatymo metodai

Iš laivų išmetamų teršalų įvertinimas yra gana sudėtingas uždavinys, tiek atliekant tiesioginius matavimus, tiek ir vertinant statistiniais metodais be tiesioginių matavimų. Pasak Chu-Van et al. (2018), yra trys pagrindiniai tiesioginiai laivų išmetamųjų dujų sudėties matavimų metodai – standai (angl. test-bed), laivų šleifų matavimai ir matavimai laivuose. Laivų šleifų emisijų matavimų metodai gali būti antžeminiai ir atliekami ore. Antžeminiai metodai yra tokie, kai laivui plaukiant pavėjui pastatyta

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

įranga matuoja išmetamųjų dujų šleifą (Beecken, 2015; Rapalis et al., 2018; Smailys et al., 2013, 2016). Wang ir kt. (2019) tyrimuose laivų oro taršai nustatyti buvo naudojama stacionari matavimo stotis su įmontuotais analizatoriais. Šiuo būdu galima gana tiksliai įvertinti tuo metu uoste eksploatuojamų laivų išmetamųjų dujų šleifus, tačiau šio metodo trūkumas tas, kad rezultatams įtakos gali turėti kita uoste vykdoma veikla, kas gali visiškai užmaskuoti laivybos veiklą (Smailys et al., 2016), metodas taip pat yra jautrus aplinkos sąlygų įtakai (vėjo kryptis, greitis, atmosferos slėgis, krituliai) (Rapalis et al., 2018; Smailys et al., 2013). Šios problemos galima išvengti naudojant mobilią įrangą, kuri prikabinama prie oro transporto (sraigtasparnio ar nepilotuojamų orlaivių). Smarkiai tobulėjant nepilotuojamų orlaivių bei mikrodaviklių technologijoms, jie gali būti plačiai panaudojami tiesioginiam laivų šleifų matavimui (Anand et al., 2020; Burgués & Marco, 2020; Shen et al., 2020; Yuan et al., 2020). Tačiau šie metodai taip pat nėra be trūkumų – reikia didesnių išlaidų davikliams bei patiems orlaiviams. Taip pat rezultatai priklausys ir nuo piloto ar žmogaus kontroliuojančio nepilotuojamą orlaivį sugebėjimų teisingai atlikti matavimus. Be paminėtų trūkumų, sunkumų nepilotuojamų orlaivių panaudojimui uostų teritorijoje sudaro ir papildomų leidimų gavimas, kad būtų galima orlaivį eksploatuoti (Explicit ApS, 2018; Ministry of Environment and Food of Denmark, 2018). Šleifo matavimas leidžia įvertinti, kaip kinta kenksmingų komponentų koncentracijos aplinkoje kintant laivo išmetamųjų dujų šleifui. Tai svarbus parametras siekiant įvertinti laivybos įtaką uostamiesčių gyventojams ir aplinkai laivo stovėjimo arba plaukimo uoste metu bei įvertinti kai kurias kuro savybes (pvz., sieros kiekį kure pagal SO_2/CO_2 santykį). Tačiau šleifo matavimas nesuteikia galimybės įvertinti emisiją – išmetamų teršalų kiekį masės vienetais per laiką (kg/h). Siekiant įvertinti emisijas remiantis tik šleifo duomenimis galima naudoti atvirkštinį Gauso šleifo skaičiavimą (Aliabadi et al., 2016). Turint tikslius aplinkos sąlygų duomenis bei daug matavimo taškų atliekamas atvirkštinis modeliavimas (Aliabadi et al., 2016; Ding et al., 2018; Kura & Jilla, 2019; Lushi & Stockie, 2010), tačiau laivų matavimo sąlygomis tai atlikti sudėtinga dėl laivo judėjimo, be to, nustatymo paklaida didėja tolstant nuo matuojamo objekto, kai išmetamosios dujos prasiskiedžia. Čia pasitarnauja matavimas orlaiviais, kai matavimas atliekamas netoli šleifo šaltinio ir naudojama įranga pasižymi dideliu matavimo dažniu (Aliabadi et al., 2016). Tačiau mokslo darbų, kuriuose būtų plačiai vystomi ir nagrinėjami tokie emisijų vertinimo metodai, yra labai mažai.

Kitas iš tiesioginių emisijų matavimo metodų būtų emisijų matavimas sumontuojant įrangą laive. Pastarojo metodo apribojimai yra teisiniai ir technologiniai. Teisiniai apribojimai – tarptautiniuose vandenyse į laivą patekti negalima, tam reikia kreiptis į šalį, su kurios vėliava plaukioja laivas (Balzani Lööv et al., 2014). Neretai šiuos emisijų nustatymo metodus apsunkina ir reikalingi gauti sutikimai iš uosto ar uoste dirbančių įmonių (College, 2016) bei laivo savininkų ir kapitono. Be to, laivai yra didelio pavojaus zona, ypač tanklaiviai, kuriuose taikomos specifinės darbo saugos

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

ir net naudojamos įrangos taisyklės. Technologiniai apribojimai – visų pirma reikalingi duomenys, tiesiogiai matuojant išmetamųjų dujų koncentracijas išmetamųjų dujų trakte ir norint įvertinti emisijas (kg/h) būtina išmatuoti ne tik išmetamųjų dujų koncentracijas bet ir išmetamųjų dujų srautą. Laivo sąlygomis išmatuoti išmetamųjų dujų srautą sudėtinga dėl daugelio faktorių: didelis srautas, aukšta temperatūra, pulsacija dėl variklio darbo, kieta suodžių frakcija sraute ir kt. Kitas sprendimas srautui įvertinti yra išmetamųjų dujų srauto apskaičiavimas iš kitų parametrų: variklyje sunaudoto kuro ir oro srauto. Verta atkreipti dėmesį, kad retai laivų varikliuose būna sunaudojamo oro apskaitos įranga, o kuro matavimo įrangos tikslumas būna prastas. Be to, šiam vertinimui būtina žinoti kuro elementinę sudėtį, o oro kiekis skaičiuojamas iš variklių techninių charakteristikų ir apkrovos, tai vėl komplikuoja matavimus (Makarevičiūtė et al., 2014; Mollenhauer & Tschöke, 2010). Taip pat šis metodas reikalauja didelių laiko ir žmogiškųjų resursų kiekvienam laivui įvertinti, todėl norint sukaupti reikšmingą duomenų bazę, metodas taptų nepriimtinas. Dėl prieš tai paminėtų priežasčių šie metodai taikomi rečiau.

Dažniausiai laivų emisijos, ypač tai taikoma uostuose, nustatomos jas skaičiuojant. Čia skaičiavimai atliekami arba kuro pagrindu (angl. fuel-based) arba laivo veiklos pagrindu (angl. activity-based) (Alver et al., 2018; Bacalja et al., 2020; El-Taybany et al., 2019; Lonati et al., 2010)2020; El-Taybany et al., 2019; Lonati et al., 2010. Remiantis Europos aplinkos agentūros EMEP oro emisijų skaičiavimo vadovu (Carlo Trozzi & Contributing, 2019; EMEP, 2013) laivų emisijos apskaičiuojamos trimis pakopomis (Tier 1, Tier 2, Tier 3).

Kuro sąnaudomis paremti skaičiavimai (1 ir 2 pakopos skaičiavimai), kurie pagrįsti sunaudoto kuro kiekiu specifiniuose uostuose, neturi galimybės įvertinti, kiek kuro buvo sunaudota konkrečioje laivo judėjimo vietoje (Kwon et al., 2019). Dažnu atveju kuro sąnaudomis paremti skaičiavimai yra naudingi preliminaros vietinės taršos vertinimui, tačiau rezultatai turėtų būti patvirtinami atliekant laivų aktyvumo pagrindu paremtus skaičiavimus (Toscano & Murena, 2019). Laivų aktyvumo pagrindu paremti skaičiavimai yra sudėtingesni ir reikalauja daug daugiau informacijos nei pirmos ar antros pakopos skaičiavimai. Dažnai vieno šaltinio šiems skaičiavimams atlikti neužtenka ir reikia naudoti keletą, kad būtų galima surinkti kuo daugiau informacijos apie laivo poziciją, greitį, techninius parametrus (Chen et al., 2016; Huang et al., 2017; Merico et al., 2017; Progiou et al., 2020a). Laivų techniniai parametrai surenkami iš laivų registrų, o laivų judėjimo informacija – iš automatinės identifikavimo sistemos (AIS) duomenų bazės bei informacijos iš uosto institucijų (Port of LA, 2007; Zou et al., 2020). Taip pat naudojant tiek laivo veiklos pagrindu, tiek kuro sąnaudomis pagrįstus skaičiavimus reikia įvertinti kiekvieno vertinamo teršalo emisijos koeficientą. Šie koeficientai gali būti parinkti naudojantis duomenų bazėmis, moksliniais straipsniais bei skaičiuojami (Goldsworthy & Goldsworthy, 2015; Ng et al., 2013; Qiao et al., 2017; US ICF International, 2009; Y. Zhang et al., 2017). Skaičiavimuose,

paremtuose laivo aktyvumu, įvertinama ne tik pagrindinių variklių, bet ir pagalbinių variklių bei šildytuvų sukeliama tarša (Huang et al., 2018; Zhao et al., 2020). Emisijų skaičiavimai remiantis laivų statistiniais duomenimis patogūs naudoti, tačiau pasižymi didele paklaida nuo 10–25 % (priklausomai nuo vertinamo teršalo) iki 50 % manevruojant ir iki 40 % uoste (Carlo Trozzi & Contributing, 2019).

AIS duomenys, kaip pagrindas skaičiuojant emisijas, naudojami STEAM (Laivų eismo išmetamųjų teršalų įvertinimo modelis, angl. Ship Traffic Emission Assessment Model) modeliuose. Kaip ir EMEP skaičiavimuose čia yra reikalingi technologiniai laivų parametrai (Goldsworthy & Goldsworthy, 2015; Jalkanen et al., 2009; Tichavska et al., 2019). Modelis buvo kelis kartus modifikuotas. Pirmoji modifikacija STEAM 2 pateikta (Jalkanen et al., 2012) publikacijoje, kurioje teigiama, kad šiame modelyje naudojama modernesnė variklių atsparumo / pasipriešinimo ir balansavimo schema, kuri leidžia tiksliau įvertinti PM ir CO emisijas. Ši modelio modifikacija, palyginti su pirmąja, yra universalesnė apibūdinant laivo greičio ir judėjimo, variklio apkrovos ir kuro kiekio kitimo bei laivų eksploatacinių charakteristikų poveikį. STEAM 3 modifikacija pateikta 2017 m. Šioje STEAM modelio modifikacijoje buvo išspręsta trūkstamos informacijos apie dalies laivų technines specifikacijas ir kai kuriuose regionuose esančių palydovų duomenų trūkumo problema. Taip pat STEAM 3 modifikacijos leido modeliuoti tarptautines išmetamųjų teršalų kontrolės sritis, valymo įrenginių bei dviejų tipų kuro sistemas (Johansson et al., 2017). Panašus modelis (C-port) specialiai parengtas laivų emisijų uostuose preliminariam vertinimui ir sklaidos modeliavimui, modelyje yra kartu sujungti laivų emisijų faktoriai, paremti statistiniais rodikliais (EMEP ir pan.) ir integruotais sklaidos modeliais (Isakov et al., 2017). Toks modelis yra labai patogus preliminariam uostų vertinimui, tačiau jo tikslumas griežtai priklauso nuo turimos duomenų bazės – statistinių taršos rodiklių.

Kadangi laivų variklių apkrovos ir kuro sąnaudų vertinimas yra gana sudėtingas ir reikalauja daugelio parametrų lygiagretaus vertinimo, laivo kuro sąnaudoms, emisijoms vertinti ir optimizuoti pastaruoju metu pasirenkami dirbtinių neuroninių tinklų modeliai. Panašius tyrimus savo publikacijoje pateikė daug mokslininkų (Jurdana et al., 2020; Karagianidis et al., 2019; Kim & Jung, 2021; Moreira et al., 2021; Namgung & Kim, 2020; Schaub et al., 2020; Sun et al., 2019; Theodoropoulos et al., 2021). Atliktuose tyrimuose bandoma neuroninių tinklų algoritmais įvertinti ir prognozuoti laivą veikiančias jėgas (Namgung & Kim, 2020), variklių apkrovą (Theodoropoulos et al., 2021) bei kuro sunaudojimą (Kim & Jung, 2021; Moreira et al., 2021; Sun et al., 2019), planuoti maršrutus (Jurdana et al., 2020) ir modeliuoti emisijas (Schaub et al., 2020), pastarojo modelio apmokymui buvo panaudoti tiesioginių matavimų metu surinkti duomenys, o dirbtinių neuroninių tinklų modelio gauti rezultatai yra beveik identiški tiesioginių matavimų rezultatams. Naudojant neuroninius tinklus ir mašinų mokymosi technologijas gaunami rezultatai pasižymi tikslumu nenusileidžiančiu tradiciniais (Beecken et al., 2015), tačiau yra lengviau įdiegiami ir plečiami. Atsižvel-

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

giant į laivų technologinių skirtumų ir sąlygų kiekius laivuose, dirbtinių neuroninių tinklų algoritmų naudojimas ateityje gali tapti vienu pagrindiniu įrankiu ne tik planuojant laivų maršrutus, bet ir vertinant kuro sąnaudas bei emisijas.

Pagrindinis tokių metodų naudojimo trūkumas – reikalingi dideli laivų tiriamųjų parametrų duomenų masyvai, tačiau juos galima gauti iš laivuose esančių parametrų stebėjimo ir įspėjimo sistemų, kurių duomenys puikiai tinka neuroninių tinklų apmokymui (Kim & Jung, 2021).

1.3. Atmosferos oro taršos sklaidos modeliai

Atmosferos dispersijos modeliai yra svarbios priemonės, naudojamos aplinkos moksle ir meteorologijoje, siekiant numatyti ar įvertinti teršalų plitimą Žemės atmosferoje. Šie modeliai atsižvelgia į įvairius veiksnius, įskaitant išmetamųjų teršalų šaltinį, teršalų tipą, atmosferos sąlygas ir teritorijos geografiją, kad būtų galima prognozuoti teršalų sklaidą ir koncentraciją laikui bėgant (Ashworth et al., 2013). Šių modelių kūrimas ir naudojimas turi didelę reikšmę visuomenės sveikatai ir aplinkos apsaugai. Atsižvelgdami į įvairius fizinius ir cheminius procesus, kurie daro įtaką teršalams, kai jie sklinda oru, atmosferos sklaidos modeliai padeda suprasti ir valdyti oro kokybę, įvertinti poveikį aplinkai ir priimti pagrįstus sprendimus dėl visuomenės sveikatos ir saugos.

Atmosferos sklaidos modelių veikimas apima keletą pagrindinių žingsnių. Pirmiausia reikia apibūdinti išmetimo šaltinį. Tai apima šaltinio tipo nustatymą (sutelktasis šaltinis, pvz., kaminas; linijos šaltinis, pvz., kelias; vietovės šaltinis, pvz., žemės ūkio laukas), išmetimo greičio, išmetamų medžiagų temperatūros ir išleidimo aukščio. Toliau seka teršalų savybių įvertinimas – išleidžiamų teršalų fizikinės ir cheminės savybės. Šiame etape įvertinami teršalų reaktyvumas, tirpumas ir kietųjų dalelių dydis ir kiti parametrai. Šie veiksniai turi įtakos medžiagos savybėms patekus į atmosferą (Dodla et al., 2017; Vira et al., 2017).

Kad naudojantis atmosferos sklaidos modeliais būtų galima kuo tiksliau prognozuoti teršalų sklaidą, reikalingi išsamūs meteorologiniai duomenys: vėjo greitis ir kryptis, atmosferos stabilumas (kuris turi įtakos turbulencijai), temperatūra, drėgmė ir saulės spinduliuotė. Šie veiksniai turi įtakos teršalų judėjimo greičiui ir kryptčiai, taip pat procesams, tokiems kaip cheminės reakcijos ir nusėdimas. Teritorijos, esančios aplink taršos šaltinį, reljefas gali reikšmingai paveikti sklaidos modelius. Todėl be meteorologinių duomenų atmosferos sklaidos modeliams taip pat reikalingi duomenys apie reljefo aukštį, žemės panaudojimo paskirtį ir kliūtis (pastatų, medžių), galinčias pakeisti vėjo srautą ir turbulenciją (Martina & Trini Castelli, 2023).

Atmosferos sklaidos modelių pagrindas yra matematinės lygtys, apibūdinančios oro srautą ir teršalų pernašą, taip pat sklaidą oro sraute. Šios lygtys apima advek-

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

ciją (oro ir jo savybių kitimas dėl oro masių horizontaliosios pernašos), difuziją (teršalų plitimas dėl oro turbulencijos), chemines reakcijas ir pašalinimo procesus (nusodinimą ir skilimą). Šių lygčių sudėtingumas skiriasi priklausomai nuo skirtingų tipų modelių, nuo paprastų Gauso plunksnų modelių iki sudėtingų skysčių dinamikos (CFD) modelių (Stockie, 2011).

Modeliai pateikia rezultatus, kurie apima teršalų koncentracijas įvairiais atstumais ir kryptimis nuo šaltinio, laikui bėgant. Šie rezultatai gali būti naudojami vertinant atitiktį oro kokybės standartams, vertinant riziką sveikatai, planuojant skubų reagavimą į atsitiktinį teršalų išleidimą ir pateikiant informaciją miestų ir pramonės objektų planavimui (Leadbetter et al., 2020).

Apibendrinant galima pasakyti, kad atmosferos sklaidos modeliai yra sudėtingi įrankiai, integruojantys duomenis apie išmetamuosius teršalus, teršalų charakteristikas, meteorologines sąlygas ir reljefą, kad būtų galima prognozuoti teršalų sklaidą ir jų virsmus atmosferoje. Dėl šios priežasties jie atlieka svarbų vaidmenį aplinkos apsaugos, visuomenės sveikatos ir teisės aktų laikymosi srityse.


Tačiau šiems atmosferos sklaidos modeliams reikalingi dideli pradiniai duomenų masyvai bei išsamūs pradiniai duomenys – emisijos, išmetamųjų dujų temperatūra, teršalų cheminė sudėtis, teršalų išmetimo greitis ir kt. Todėl populiarūs sklaidos modeliai kaip CALPUFF, AERMOD ar GRALL (Exponent, Inc., 2022; GRAL, 2023; U.S. Environmental Protection Agency, 2023) nėra tinkami uoste eksploatuojamų laivų taršai vertinti.

1.4. Laivų automatinio identifikavimo sistema ir laivų stebėsena bei valdymas

Automatinė identifikavimo sistema (AIS) yra laivybos saugumo ir navigacijos priemonė, naudojama laivuose ir laivybos valdymo centruose. AIS leidžia laivams automatiškai keistis įvairia informacija, tokia kaip laivo identifikacija, tipas, pozicija, kursas, greitis ir kiti saugumui svarbūs duomenys. Ši sistema padeda sumažinti susidūrimų pavojų jūroje ir pagerina laivybos eismo stebėjimą (Garmin Ltd., 2017).


AIS naudoja labai aukšto dažnio (VHF) radijo dažnius siųsti ir gauti duomenis, kurie gali būti perduodami ne tik tarp laivų, bet ir tarp laivų bei kranto stotelių. Ši informacija gali būti rodoma įvairiose navigacijos sistemose, pvz., elektroninių žemėlapių rodymo ir informacijos sistema (ECDIS) arba atskiruose AIS prietaisuose (5 paveikslas).

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė



5 pav. AIS duomenų stotelė Klaipėdos universiteto Jūrų tyrimo institute (nuotrauka daryta autoriaus)

SOLAS V/19 reglamentas (International Maritime Organization, 2004) reikalauja, kad AIS duomenimis būtų keičiamasi tarp laivų ir laivų su kranto įrenginiais. AIS tikslas yra padėti atpažinti laivus, sekti taikinius, teikti pagalbą paieškos ir gelbėjimo operacijose, supaprastinti informacijos mainus (pvz., sumažinti privalomą žodinių laivo pranešimą) ir suteikti papildomą informaciją, padedančią suvokti situaciją. Apibendrinant galima teigti, kad per AIS gauta informacija pagerina prieinamos informacijos kokybę, nesvarbu, ar informacija gauta iš kranto stebėjimo stoties, ar laivo. Automatinio identifikavimo sistema yra naudingas papildomos informacijos šaltinis, nustatant laivų poziciją (6 paveikslas), todėl gali būti plačiai panaudojamas laivų eismo įvykių prevencijai ar tašinių emisijų vertinimui uostuose (Hensel et al., 2020).



6 pav. Laivybos intensyvumo Klaipėdos uoste pagal AIS sistemos duomenis žemėlapis (duomenys iš AIS stotelės Klaipėdos universitete, 2024)

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

AIS suteikia informaciją apie laivo greitį, kryptį, jo padėtį bei laivo identifikavimo numerius (IMO ir MMSI). Pasitelkiant automatinės identifikavimo sistemos informaciją galima įvertinti laivo poziciją uoste bet kuriuo laiko momentu, kai laivas yra eksploatuojamas uoste. Tokiu būdu laivo tarša įvertinama ne kaip statistinis vienetas bendroje uosto taršos sudėtyje, bet kaip atskiras objektas. Analizuojant kiekvieną uoste eksploatuojamą laivą pasirinktu laiko momentu galima įvertinti, kokį poveikį aplinkos orui turi laivų tarša konkrečiose uosto teritorijose arba vertinti kiekvieno laivo ar laivo tipo poveikį aplinkos orui atskirai.

Klaipėdos uoste naudojama valdymo, stebėsenos sistema yra LUVIS – Laivybos uoste valdymo informacinė sistema (Lietuvos Respublikos susisiekimo ministerija, 2020). Sistemoje integruota visa informacija iš visų uosto direkcijos skyrių informatyviems ir greitiems sprendimams priimti.

Laivai, kurie nori įplaukti į Klaipėdos uostą, iš anksto informuoja operatorius ir perduoda visus reikalingus dokumentus dispečeriams, kurie įvertina, ar dokumentai atitinka reikalavimus, kad laivas galėtų įplaukti į uostą. Jeigu dokumentai atitinka reikalavimus, dispečeriai suveda reikiamą informaciją į LUVIS sistemą. Laivui priartėjus prie uosto ir susisiekus su operatoriumi, laivui leidžiama įplaukti į uostą.

1.5. Dirbtinių neuroninių tinklų modeliai

Dirbtiniai neuroniniai tinklai (DNT) yra dinamiška ir besivystanti dirbtinio intelekto studijų sritis. DNT yra kompiuteriniai modeliai, sukurti žmogaus smegenų struktūros ir veikimo principu. Dėl jų sugebėjimo mokytis iš daugybės duomenų ir nustatyti ryšius tarp įvairių parametrų, jie tampa neįkainojamu įrankiu įvairiose srityse, įskaitant vaizdo ir garso atpažinimą, natūralios kalbos supratimą, automatinį vertimą, automatinį spėjimą ir daug kitų. DNT taip pat galima taikyti ten, kur yra daug rezultatui įtakos turinčių tarpusavyje susijusių veiksmų, kurių įtaką yra sudėtinga įvertinti. Dirbtinių neuroninių tinklų gebėjimas apdoroti ir mokytis iš didelių duomenų rinkinių naudingas kuriant programas, kurios galėtų suprasti sudėtingus modelius, daryti prognozes ar pateikti įžvalgas, kurios labai reikšmingos priimant sprendimus įvairiose pramonės šakose.

Pagrindinės DNT sudedamosios dalys yra dirbtiniai neuronai, kurie simbolizuoja biologinius neuronus. Šie dirbtiniai neuronai yra organizuoti į sluoksnius ir sujungti tarpusavyje svorio koeficientais. Pagrindinė DNT struktūra yra daugiasluoksnis perceptronas. Dirbtiniai neuroniniai tinklai gali turėti įvairias architektūras, priklausomai nuo taikymo srities ir užduoties sudėtingumo. Populiariausios architektūros yra:

- „Feedforward“ neuroniniai tinklai (angl. Feedforward Neural Networks, FNN): kiekvienas neuronas viename sluoksnyje yra sujungtas su kiekvienu

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

neuronu kitame sluoksnyje. Tai paprasčiausia forma, dažnai naudojama paprastoms užduotims spręsti (Adedeji & Kabir, 2023; Admon et al., 2024).


- Konvoliuciniai neuroniniai tinklai (angl. Convolutional Neural Networks, CNN): ypač efektyvūs apdorojant vaizdinę medžiagą, nes jų architektūra imituoja žmogaus regos veikimą. Tokiu būdu jie gali atpažinti formas, tekstūras ir kitus vaizdo elementus (Abdeljaber et al., 2017).
- Rekurentiniai (pasikartojantys) neuroniniai tinklai (angl. Recurrent Neural Networks, RNN) tinka teksto ar garso apdorojimui. Jie gali išsaugoti informaciją apie ankstesnius žingsnius, leidžiant modeliui analizuoti visą seką kontekste (Truong et al., 2022).
- Giliųjų neuroninių tinklų (angl. Deep Neural Networks, DNN) architektūros. Tai sudėtingesnės struktūros, kurios sudarytos iš daug sluoksnių ir yra naudojamos didelio kiekio duomenų apdorojimui. Šios architektūros modeliais galima atpažinti labai sudėtingus ryšius tarp įvairių duomenų (Zhu et al., 2024).

Bendrinė dirbtinių neuroninių tinklų struktūra (7 paveikslas) susideda iš 3 sluoksnių (Ibrahim et al., 2022):

- Įvesties sluoksnis. Įvestis yra pradžioje esantis duomenų sluoksnis, kuris gali būti paveikslėliai, tekstas, garso signalai, duomenų masyvas ir kt. Kiekvienam įvesties elementui priskiriama pradinė būseną (neuronų išvestis).
- Paslėptieji sluoksniai. Tarp įvesties ir išvesties sluoksnių yra vienas arba keli paslėptieji sluoksniai. Kiekvienam neuronui šiuose sluoksniuose yra priskiriami svorio koeficientai, kurie reguliuoja informacijos perdavimą tarp sluoksnių.
- Išvesties sluoksnis. Paskutinis sluoksnis, kuris duoda galutinį rezultatą ar prognozę. Išvesties reikšmės gali būti skaičiai, klasės tikimybės arba kita atitinkama informacija pagal užduotį.

Dirbtinių neuroninių tinklų veikimas pagrįstas jų gebėjimu mokytis iš pateiktų duomenų. DNT mokosi naudojant mokymo duomenis, kuriuose yra žinomi įvesties ir tikslo rezultatai. Tinklui yra keičiami svorio koeficientai taip, kad prognozė būtų kuo artimesnė tikram rezultatui. Šis procesas kartojamas su įvairiais duomenimis, kol tinklas pasiekia norimą tikslumą su mokymo masyvu. Po to rezultatai yra tikrinami su testavimo masyvu. Svorio koeficientams parinkti ir koreguoti yra naudojamos aktyvacijos funkcijos.

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė



7 pav. Principinė neuroninių tinklų struktūros schema:
1 – įvesties sluoksnis; 2 – paslėptieji (perceptrų) sluoksniai;
3 – išvesties sluoksnis (sudaryta autoriaus).

Kiekvienam dirbtiniam neuronui yra priskirta aktyvacijos funkcija, kuri nusako išėjimo reikšmę pagal įvesties reikšmes ir svorius. Aktyvacijos funkcijos padeda įvesties duomenis perduoti tinklui gilesniu lygmeniu, leidžiant jiems išmokti sudėtingesnes savybes ir modeliuoti ryšius tarp požymių. Tai leidžia dirbtiniams neuroniniams tinklams mokytis ir prisitaikyti prie įvairių užduočių. Dažniausiai naudojamos aktyvacijos funkcijos yra ReLU (Rectified Linear Unit), sigmoidinė, linijinė arba hiperbolinio tangento funkcijos (Artelnics, 2023).

Dirbtiniai neuroniniai tinklai gali būti naudojami oro taršai vertinti uostuose, modeliuojant sudėtingus ryšius tarp įvairių aplinkos, meteorologinių ir veiklos veiksnių. DNT tarpusavyje susieja tiesioginių teršalų koncentracijų matavimų, meteorologinių parametrų bei uosto veiklos duomenis. Dėl šios priežasties DNT suteikia galimybę vertinti taršą uostuose remiantis tik laivo techniniais duomenimis ir meteorologiniais parametrais realiu laiku (Cordova et al., 2021).

1.6. Pirmojo skyriaus apibendrinimas

Griežtėjant teisiniams reikalavimams, kuriais siekiama sumažinti neigiamą poveikį aplinkai, yra svarbu valdyti ir suprasti laivų generuojamą taršą uostuose, todėl būtina turėti galimybę vertinti taršos sklaidą ir pasiskirstymą aplinkoje. Išanalizavus įvairius pasauliniu mastu taikomus laivų taršos vertinimo metodus, galima teigti, kad dirbtinių neuroninių tinklų panaudojimas kuriant taršos vertinimo modelį yra racionalus sprendimas siekiant sukurti universalų įrankį uostuose eksploatuojamų laivų taršai įvertinti. Egzistuoja nemažai metodų laivų taršai vertinti, tačiau jų panaudojimas, būtent vertinant laivų eksploatuojamų uostuose taršą, įprastai yra ribotas dėl reikalingų duomenų. Paprastai oro taršos vertinimą galima išskirti į kelias grupes: tiesioginiai matavimai, statistiniai skaičiavimai bei atmosferinės sklaidos modeliavimas.

Tiesioginiai matavimai laivų taršai įvertinti dažniausiai netaikomi, kadangi tai reikalauja montuoti įrangą pačiuose laivuose. Egzistuoja metodų, kai tiesiogiai taršą galima matuoti ir be įrangos laivuose, tačiau tokiu atveju matavimų rezultatams įtakos turi aplinkinė veikla. Tai ypač svarbu uostuose, kur vykdoma krovos veikla. Statistiniams modeliams įprastai reikia duomenų, kuriuos gauti iš laivų yra arba sudėtinga, arba neįmanoma. Kitas tiesioginių matavimų būdas yra nepilotuojamų orlaivių (dronų) panaudojimas, prie jų pritaissant matavimo įrangą. Tačiau šie metodai susiduria su daug teisiųjų problemų, norint juos naudoti uostų teritorijose.

Pagrindinė emisijų skaičiavimo metodika yra laikoma EMEP metodika, kur pagrindiniai skaičiavimai atliekami kuro pagrindu (angl. fuel-based) – pirmas ir antras EMEP skaičiavimų lygmuo arba laivo veiklos pagrindu (angl. activity-based) – trečias EMEP skaičiavimų lygmuo. Pirmo ir antro EMEP lygmens skaičiavimų įprastai neužtenka ir reikia vykdyti trečio lygmens skaičiavimus. Bet net ir tada EMEP metodikos panaudojimo neužtenka norint gauti tinkamą rezultatų tikslumą. Šią problemą galima būtų koreguoti – į esamą trečio lygmens metodiką įtraukiant detales duomenis apie laivo poziciją, kryptį ir greitį.

Šiuolaikiniai sklaidos modeliai gali suteikti įvairių vertinimo galimybių, tačiau jų naudojimas yra ribotas dėl reikalingo didelio pradinio duomenų kiekio, kad būtų užtikrintas tinkamas sklaidos modelio veikimas. Taip pat sklaidos modeliavimo modeliams reikalinga informacija apie atmosferos sąlygas (pvz., turbulencija, kintantys vėjo profiliai). Ši informacija dažnai būna daug kompleksiškesnė nei modeliuojamos prielaidos leidžia atvaizduoti. Dėl to modeliai gali neatspindėti tikro proceso dinamikos, ypač lokaliajame masto analizėje. Dėl šios priežasties modelio skaičiavimo procesas tampa per ilgas uosto veiklai, kadangi uosto aplinka yra dinamiška ir reikalauja vertinimo atsižvelgiant į esamas sąlygas. Vertinimą uoste apsunkina ir tai, kad jėgainės yra mažai apkrautos, o uostų akvatorijos skiriasi išdėstymu ir aplinkos sąlygomis.

Dirbtiniai neuroniniai tinklai (DNT) gali būti itin naudingi vertinant laivų teršalų emisijas, nes jie leidžia efektyviai apdoroti didelius ir įvairius duomenų kiekius bei

1. Laivų taršos įvertinimo bei laivų taršos poveikio aplinkos oro kokybei įvertinimo mokslinė analizė

nustatyti sudėtingus ryšius tarp įvairių veiksnių. Dirbtinių neuroninių tinklų modeliai taip pat leidžia vertinti esamą situaciją uoste realiu laiku. Mokydamiesi iš istorinių duomenų, neuroniniai tinklai sukuria modelius, leidžiančius prognozuoti teršalų emisijų pokyčius priklausomai nuo laivo veiklos (pvz., greičio, apkrovos ar pasirinkto maršruto). Tai leidžia operatoriams imtis prevencinių priemonių dar prieš atsirandant dideliems taršos lygio svyravimams. Naudojant prognozes ir realaus laiko analizę, laivų operatoriai gali koreguoti veiklos strategijas – pavyzdžiui, optimizuoti maršrutus ar variklių darbo režimus – siekiant sumažinti teršalų kiekį ir pagerinti energijos vartojimo efektyvumą.


Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika

Pagal atliktus tyrimus buvo parengtos dvi metodikos (8 paveikslas):

1. AIS duomenų įterpimas į Tolimojo oro teršalų perdavimo Europoje stebėjimo ir įvertinimo kooperatinės programos Europoje (angl. The co-operative programme for monitoring and evaluation of the long-range transmission of air pollutants in Europe – EMEP) trečio lygmens metodiką. Modifikuota EMEP metodika leidžia vertinti uostą ne kaip vieną objektą, o analizuoti emisijas prie kiekvienos uosto krantinės ir bet kuriuo momentu. Tyrimui buvo panaudoti techniniai laivų duomenys, laivo pozicijos bei greičio duomenys (AIS) ir integruoti į esamą EMEP metodiką, kuri leidžia įvertinti sumines uosto emisijas.
2. Dirbtinių neuroninių tinklų modelio kūrimo ir panaudojimo uoste eksploatuojamų laivų taršos įvertinimui metodika. Tyrimui panaudoti detalūs AIS ir laivų techniniai duomenys bei oro užterštumo matavimo stotelės duomenys. Tyrimo metu kietų dalelių koncentracijos aplinkos ore pokyčiai buvo susieti su laivų judėjimu ir jų techninėmis charakteristikomis bei meteorologinėmis sąlygomis pasirinktu momentu. Sąsajai nustatyti buvo panaudoti dirbtiniai neuroniniai tinklai, galintys nustatyti ryšius tarp didelio skaičiaus skirtingų parametrų. Parengtas modelis gali prognozuoti, kaip keisis skirtingų frakcijų kietų dalelių koncentracijos aplinkoje priklausomai nuo laivo pozicijos, jo techninių parametrų, greičio ir meteorologinių sąlygų. Tyrimai buvo apriboti laivų tarša. Tar-

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika

ša iš miesto ar terminalų vertinama nebuvo. Skirtingai nuo kitų modelių, šiam variantui nereikia pradinio duomenų apie emisijas, išmetamųjų dujų temperatūrą, cheminę sudėtį, išmetimo greitį ir kt., kurių neįmanoma gauti be tiesioginių matavimų laivuose. Modelio rezultatas yra Python programavimo kalbos kodas, kuris gali būti įdiegiamas į esamas sistemas. Python kodas pasirinktas todėl, kad šiam programavimo kalbos paketui nereikalinga licencija, tai yra atviro kodo licencija prieinama visiems.



8 pav. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika

AIS duomenimis papildyta EMEP metodika leidžia vertinti laivų emisijas tiek jiems manevruojant uosto akvatorijoje, tiek stovint krantinėse. DNT modelis leidžia vertinti teršalų koncentracijas ir jų pokytį laiko atžvilgiu. AIS duomenų įterpimas į EMEP metodiką leidžia vertinti uostą ne kaip vieną objektą, o analizuoti emisijas prie kiekvienos uosto krantinės ir bet kuriuo momentu. Tyrimui buvo panaudoti techniniai laivų duomenys, laivo pozicijos bei greičio duomenys (AIS) ir integruoti į esamą

EMEP metodiką, kuri leidžia įvertinti sumines uosto emisijas. Dirbtinių neuroninių tinklų modeliui sukurti panaudoti detalūs AIS ir laivų techniniai duomenys bei oro užterštumo matavimo stotelės duomenys. Tyrimo metu kietųjų dalelių koncentracijos aplinkos ore pokyčiai susieti su laivų judėjimu ir jų techninėmis charakteristikomis bei meteorologinėmis sąlygomis pasirinktu momentu.

Kietųjų dalelių koncentracijos, modelio apmokymui ir rezultatams gauti, pasirinktos dėl kelių priežasčių:


- laivyboje trūksta kietųjų dalelių reglamentavimo, dėl to sunkiau vykdoma šių teršalų stebėseną;
- kietųjų dalelių sklaidos modeliavimas yra sudėtingesnis nei dujinių teršalų – kietosios dalelės yra heterogeninės sistemos, sudarytos iš įvairių medžiagų (organinės medžiagos, metalai, druskos, biologiniai komponentai) (Seinfeld, 2016); priešingai nei dujiniai teršalai, kurie atmosferoje pasiskirsto tolygiai, kietosios dalelės kaupiasi nevienodai, priklausomai nuo vėjo parametrų ir reljefo; dujinių teršalų sklaidai vertinti įprastai naudojami Gauso modeliai, kurie dažnu atveju neįvertina papildomų komponentų, tokių kaip kietųjų dalelių sedimentacija, nusėdimo reiškinyje ar atmosferos cheminė sudėtis (European Environment Agency, 2019);
- kietosios dalelės, ypač smulkios (KD2,5 ir KD1), turi labai didelę įtaką žmonių sveikatai, nes gali patekti giliai į kvėpavimo takus ir net į kraujotaką (WHO Global Air Quality Guidelines, 2021).

Sąsajai tarp įvesties parametrų nustatyti buvo panaudoti dirbtiniai neuroniniai tinklai, galintys nustatyti ryšius tarp didelio skaičiaus skirtingų parametrų. Parengtas modelis gali prognozuoti, kaip keisis skirtingų frakcijų (1 μm , 2,5 μm ir 10 μm) kietųjų dalelių koncentracijos dėl laivo išmetamųjų dujų šleifo priklausomai nuo laivo pozicijos, jo techninių parametrų, greičio ir meteorologinių sąlygų. Tyrimai buvo apriboti laivų tarša. Tarša iš miesto ar terminalų vertinama nebuvo.

2.1. Dirbtinių neuroninių tinklų kūrimo ir panaudojimo metodika

Tyrimai grindžiami laivų AIS pozicijų naudojimu ir išmetamųjų dujų šleifo analize. Dėl Klaipėdos uosto geografinės padėties laivai juda siauru kanalu Kuršių mariose, palei Klaipėdos miestą. Pučiant vakariniam vėjui, išmetamųjų dujų šleifas pučiamas į uostą ir miestą, jį gali registruoti uoste esanti oro taršos analizės įranga. Laivo judėjimo metu išmetamųjų dujų šleifas juda lygiagrečiai laivui, kai šleifas juda per matavimo stotį, registruojami duomenys apie horizontalios šleifo dalies koncentracijas (9 paveikslas).

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika



9 pav. Laivo judėjimo metu išmetamųjų dujų šleifo fiksavimo schema


Tyrimui panaudoti detalūs AIS ir laivų techniniai duomenys, taip pat oro užterštumo matavimo stotelės duomenys. Tyrimo metu kietųjų dalelių koncentracijos aplinkos ore pokyčiai buvo susieti su laivų judėjimu ir jų techninėmis charakteristikomis bei meteorologinėmis sąlygomis pasirinktu momentu. Sąsajai nustatyti buvo panaudoti dirbtiniai neuroniniai tinklai, galintys nustatyti ryšius tarp didelio skaičiaus skirtingų parametrų. Tyrimų rezultatas – parengtas modelis gali prognozuoti, kaip keisis skirtingų frakcijų kietųjų dalelių koncentracijos aplinkoje priklausomai nuo laivo pozicijos, jo techninių parametrų, greičio ir meteorologinių sąlygų.

Pakeičiant pradinių duomenų masyvą modelis taip pat gali būti apmokytas dujinių teršalų (NO_x , SO_x) koncentracijoms nustatyti. Tai yra, jeigu modelio apmokymui bus pateikiamos kitų teršalų tiesioginių matavimų reikšmės, modelis gali būti parengtas tų teršalų vertinimui (parinktų teršalų koncentracijoms vertinti). Modelio kūrimui (Kuriant modelį) buvo panaudoti duomenys iš tiesioginės matavimų stoties Klaipėdos uosto teritorijoje.

2.1.1. AQM65 oro taršos matavimo stotis

Išmetamųjų dujų pliūpsnio matavimai buvo atlikti AQM 65 matavimo stotyje, kuri tyrimo atlikimo metu buvo pastatyta Klaipėdos uosto teritorijoje (55.705542; 21.121891) (10 paveikslas). AQM65 matavimo stoties parametrai pateikti 1 lentelėje.

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika



10 pav. AQM65 matavimo stotis ir jos pozicija Klaipėdos uoste (Aeroqual, 2024)

1 lentelė. AQM65 matavimo stotelės parametrai (Aeroqual, 2024)


Parametras	Matavimo zondo aukštis	Tikslumas	Matavimų apimtis (range)	Rezoliucija
Optinis dalelių skaitiklis	10 m	$<\pm 5 \mu\text{g}/\text{m}^3$ + 15% nuo matavimų	KD_1 200 $\mu\text{g}/\text{m}^3$	0,1 $\mu\text{g}/\text{m}^3$
			$\text{KD}_{2,5}$ 2000 $\mu\text{g}/\text{m}^3$	
			KD_{10} 5000 $\mu\text{g}/\text{m}^3$	

Iš AQM65 stoties buvo gautos 1 mikrono (KD_1), 2,5 mikrono ($\text{KD}_{2,5}$) ir 10 mikronų (KD_{10}) kietųjų dalelių koncentracijos ($\mu\text{g}/\text{m}^3$). Kietųjų dalelių koncentracijos buvo fiksuojamos 1 min. intervalu 10 m aukštyje. Tyrimams buvo naudojami vienerių metų laikotarpio (nuo 2020 m. iki 2021 m.) duomenys. Pagal gautus duomenis buvo apmokytas vienas modelis, gebantis lygiagrečiai vertinti visų trijų kietųjų dalelių frakcijų (KD_1 , $\text{KD}_{2,5}$ ir KD_{10}) koncentracijas.

2.1.2. Uoste eksploatuojamų laivų šleifo analizė

Tinkamai uoste eksploatuojamų laivų išmetamųjų teršalų (KD_1 , $\text{KD}_{2,5}$ ir KD_{10}) šleifo pikų (piku laikomas koncentracijos padidėjimas 2–3 kartus nuo vidutinės koncentracijos ir trunka ne ilgiau nei 15 min., jeigu piko trukmė ilgesnė nei 15 min. vertinama, kad įvyko persidengimas arba atsirado kito taršos šaltinio, esančio kranto pusėje, poveikis) analizei buvo parašytas Microsoft Excel VBA kodas (A priedas). Šleifų pikų indentifikavimo schema pateikiama 11 paveiksle.

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika




11 pav. Šleifų pikų identifikavimo schema

Pikų analizei paimti duomenys pirmiausia buvo filtruojami pagal laivo atstumą iki matavimo stoties. Duomenys buvo apriboti 1 km spinduliu nuo matavimo stoties. Išfiltruotiems duomenims buvo pritaikytas parašytas Microsoft Excel VBA kodas. Kode buvo nurodytos sąlygos, kad laivų šleifo koncentracijų pikai būtų sudaryti ne mažiau kaip iš trijų taškų. Piku priimta laikyti koncentracijos padidėjimą daugiau nei 3 kartus nuo vidutinės reikšmės. Taip pat piko trukmė turi būti ne didesnė nei 15 min. Šis laiko intervalas pasirinktas kaip vidutinis rodiklis, parodantis, kiek laiko laivui trunka nuplaukti 1 km atstumą, nuo piko pradžios iki piko pabaigos. Kode taip pat įdėta sąlyga, kad būtų fiksuojami pavieniai pikai, o ne keli pikai iš karto (dvigubi ar trigubi pikai fiksuojami kaip vienas).

2.1.3. Dirbtinio neuroninio tinklo modelio neuronų skaičiaus parinkimas

Dirbtinių neuroninių tinklų modelio neuronų skaičius buvo parinktas eksperimentiniu būdu. Didinant neuroninių tinklų modelio bendrą neuronų skaičių visuose perceptronų sluoksniuose buvo tikrinama, kaip keičiasi standartinis nuokrypis kiekvienoje modelio veikimo fazėje – mokymo, validavimo ir testavimo (12 paveikslas).

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika




12 pav. Neuroninių tinklų modelio fazių standartinio nuokrypio priklausomybė nuo neuronų skaičiaus

Rezultatai parodė, kad optimalus neuronų skaičius perceptronų sluoksniuose yra 424. Toliau didinant neuronų skaičių modelyje standartinio nuokrypis mažėja, tačiau patikrinus modelio rezultatus pateikiant naują duomenų masyvą, nustatyta, kad susiduriama su permokymo problema (statistiniai rodikliai rodo, kad modelis tiksliai nustatinėja kietųjų dalelių koncentracijas, tačiau modeliui pateikus realius duomenis, paklaidos siekia iki 80 proc.). Statistiškai, pagal vidutinio kvadratinio nuokrypio reikšmes, tikslinga būtų naudoti modelio architektūrą su didesniu perceptronų skaičiumi. Tačiau modeliui pateikus naujus duomenis, kietųjų dalelių įvertinimo paklaidos labai išauga. Dėl šios priežasties, net ir esant mažesnėms vidutinio kvadratinio nuokrypio reikšmėms, modelio architektūra su didesniu perceptronų skaičiumi yra vertinama neigiamai.

Tokias pat tendencijas parodė ir naujų duomenų įvedimas į modelį rezultatams gauti (13 paveikslas). Neuronų skaičiui esant intervale nuo 474 iki 574 modelio prognozuojamos vertės yra mažiau išsibarsčiusios nei esant mažesniai neuronų skaičiui, o nuo 624 reikšmių išsibarstymas pradeda didėti, tai rodo, kad nuo šios vertės modelio stabilumas mažėja ir gauti rezultatai yra mažiau patikimi. Tačiau analizuojant realių ir prognozuojamų duomenų vertes, nustatyta, kad naudoti daugiau nei 424 neuronus yra netikslinga, kadangi ryšys tarp realių ir prognozuojamų duomenų prastėja. Toliau tyrimams naudoto neuroninių tinklų modelio architektūra pateikta kito (2.1.4.) poskyrio trečioje lentelėje.

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika



13 pav. Neuroninių tinklų modelio rezultatų standartinis nuokrypis pagal neuronų skaičių

2.1.4. Dirbtinio neuroninio tinklo modelio struktūra ir algoritmas

Kiekvieno laivo padėtis (koordinatės ir padėtis uosto pabaigos atžvilgiu), greitis virš žemės ir oro parametrai registruojami laiku t_x 1 min. intervalu. Laivų techniniai duomenys pridedami iš IHS Fairplay duomenų bazės pagal IMO numerį.

Teršalai buvo matuojami (KD_1 , $KD_{2,5}$, KD_{10}) nenutrūkstantai (24/7), duomenys fiksuojami kas 1 min. Modeliui kurti panaudoti 2020–2021 m. duomenys. Kiekvieno laivo padėties laiko intervalai, greitis virš žemės, taip pat oro parametrai ir teršalų matavimai buvo sinchronizuoti pagal AIS duomenis, naudojant tiesinę interpoliaciją, galutiniam duomenų masyvui gauti.

Laivo techniniai ir geometriniai duomenys buvo paimti iš IHS Fairplay pasaulio laivybos enciklopedijos. Techninių duomenų suderinimas su laivais buvo pagrįstas IMO numeriu AIS sistemoje ir IHS Fairplay duomenų bazėje. IHS Fairplay duomenų bazėje pateikiami šie parametrai: laivo pavadinimas, greitis, tipas, DWT, pastatymo data, GT, ilgis, plotis, grimzlė, gylis, variklio modelis, variklio gamintojas, variklio galia, variklio išdėstymas, variklio apskos, variklio tipas, variklių skaičius, informacija apie variklio cilindrus bei laivo identifikaciniai numeriai (IMO ir MMSI). Metodikai buvo parinkti kiekvieno tipo laivų techniniai duomenys, kurie buvo prieinami laivų techninių duomenų bazėje. Jeigu parametras buvo prieinamas tik daliai laivų, tada tie parametrai į metodiką nebuvo įtraukti. Geometriniai laivo parametrai įtraukti į modelį tam, kad modelis surastų ryšį tarp išmetamųjų teršalų koncentracijos ir laivo dydžio.

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika

Meteorologiniai duomenys buvo gauti iš dviejų šaltinių – matuojami tiesiogiai stoties jutikliais ir iš turimų archyvų internete. Duomenys buvo fiksuojami 30 min. intervalu (Freemeteo, 2020). Gauti duomenys iš archyvo buvo sinchronizuojami pagal laiką kiekvienai minutei, linijinės interpoliacijos būdu naudojant MS Excel index, match bei forecast formules.


2 lentelė. Neuroninių tinklų modelio įvesties parametrai

Parametras	Matavimo vienetai	Šaltinis
Laivo techniniai ir geometriniai duomenys		
DWT	-	IHS Fairplay duomenų bazė (ACML, 2024) Kitos laivų duomenų bazės: BalticShipping, 2024 Marine MAN Ltd, 2021
GT	t	
Laivo ilgis	m	
Laivo plotis	m	
Laivo gylis (depth)	m	
Bendra laivo variklių galia	kW	
Laivo grimzlė	m	
Meteorologiniai duomenys		
Vėjo greitis	km/h	(Freemeteo, 2020) inter- netinis duomenų archyvas
Vėjo kryptis	°	
Slėgis	mb	
Santykinis drėgnumas	%	
Laivo pozicijos duomenys		
Laivo greitis	km/h	AIS duomenys (Lietuvos transporto saugos admin- istracija)
Laivo kursas virš žemės	Laipsniai (°)	
Tiksli kryptis	°	
Ilguma	°	
Platuma	°	
Atstumas iki uosto pabaigos	m	

AIS duomenis pateikė Lietuvos transporto saugos administracija. AIS duomenys buvo filtruojami pagal koordinates, apribojant duomenis tik Klaipėdos uosto vandenyse plaukiojančiais laivais. Buvo naudojami laivo identifikavimo parametrai, taip pat padėties, judėjimo greičio ir krypties apibrėžimas laiko momentu t .

Neuroninio tinklo mokymui buvo naudojama duomenų ir mašininio mokymosi programinė įranga Neural Designer (5.9.8 versija) (Explainable AI Platform | Neural Designer, n. d.).

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika



14 pav. Duomenų masyvo naudoto neuroninių tinklų modelio kūrimui algoritmas

Buvo naudojamas aproksimacijos tinklas, kurį sudarė 17 įvesties duomenų (2 lentelė) ir 3 tiksliniai kintamieji, sudaryti iš KD_1 ; $KD_{2.5}$; KD_{10} koncentracijų ($\mu\text{g}/\text{m}^3$), išmatuotų AQM 65 stotyje. Įvesties parametrai parinkti taip, kad charakterizuotų laivo dydį ir tipą, kad neuroninių tinklų modelis gebėtų atskirti laivo gabaritą. Duomenų masyvas buvo sudarytas pagal algoritmą, pateiktą 14 paveiksle. Buvo naudojamas duomenų filtras, kai vėjo kryptis apribota nuo 180 iki 360 laipsnių. Vėjo krypties apribojimo filtras buvo parinktas taip, kad AQM65 stoties duomenyse neliktų tų duomenų, kuriems įtakos gali turėti miesto ar uosto veikla.


3 lentelė. Dirbtinių neuroninių tinklų modelio parametrai

Pavadinimas	Neuronų skaičius	Aktyvacijos funkcija
Perseptron layer 1	20	Hyperbolinis tangentas (tahn)
Perseptron layer 2	100	Hyperbolinis tangentas (tahn)
Perseptron layer 3	150	Hyperbolinis tangentas (tahn)
Perseptron layer 4	150	Hyperbolinis tangentas (tahn)
Perseptron layer 5	4	Linijinė
Bounding layer	-	Duomenų diapazonas

Dirbtinių neuroninių tinklų modelio apmokymui buvo naudotas standartinis duomenų pasiskirstymas: 60 % duomenų – modelio apmokymui, 20 % duomenų – modelio validavimui ir 20 % duomenų testavimui. Pasirinktas 5 sluoksnių neuroninis tinklas su 4 hiperbolinio tangento (tanh) aktyvinimo funkcijomis (3 lentelė).

2.1.5. Dirbtinio neuroninio tinklo modelio parametrai Neural Designer programinėje įrangoje

Neural Designer programinė įranga leidžia apmokyti dirbtinių neuroninių tinklų modelį. Tam, kad tai būtų galima įgyvendinti, programinėje įrangoje yra išskirtos keturios modelio sekcijos – duomenų masyvas, neuroninio tinklo architektūra, apmokymo strategija ir modelio parinkimas (15 paveikslas).



15 pav. Neural Designer programinės įrangos valdymo langas

Duomenų masyvo valdymo bloke programinė įranga leidžia įkelti reikiamą duomenų masyvą. Duomenų masyvo dydis nėra ribojamas, tačiau programa priima tik tekstinius (.txt), duomenų (.dat), kableliais atskirtų duomenų (.csv) bei MS Excel (.xlsx) failų formatus. Įkėlus duomenų masyvą, programinė įranga leidžia parinkti įvesties ir išvesties duomenis, taip pat, kokių santykiu naudoti duomenis modelio apmokymui, validavimui ir testavimui.

Modelio neuroninio tinklo architektūros valdymo bloke, programinės įrangos vartotojas turi galimybę sudaryti reikiamą modelio architektūrą, nurodant reikiamą paslėptųjų sluoksnių skaičių ir neuronų skaičių kiekviename sluoksnyje.

Apmokymo valdymo blokas leidžia reguliuoti modelio apmokymo procesą. Šis reguliavimas atliekamas keičiant modelio apmokymo stabdymo kriterijus (modelio apmokymui skirtą laiką, maksimalų iteracijų skaičių, minimalią modelio prognozės paklaidos reikšmę), apmokymui naudojamų duomenų imties dydį, apmokymo algoritmą. Šiame bloke programos vartotojas taip pat turi galimybę parinkti permokymo (angl. overfitting) sumažinimo metodiką.

Modelio parinkimo valdymo blokas suteikia galimybę programinei įrangai parinkti neuronų skaičių pasirinktai neuroninio tinklo architektūrai.

2.2. AIS duomenų integravimas į EMEP metodiką

Modifikuota trečio lygmens EEA/EMEP metodika buvo panaudota laivų taršai įvertinti Klaipėdos uosto teritorijoje (16 paveikslas).




16 pav. Klaipėdos uosto ortofotografinis vaizdas (Google Maps)

Naudojant statistinius oro kokybės vertinimo modelius, uostuose dažnai priimama nemažai supaprastinimų, dažnai naudojamas ilgesnio laikotarpio vertinimas, kuriame teršalų išmetimai įvertinami kaip suma tam tikram laikotarpiui (Nguyen et al., 2022; Progiou et al., 2020b), dažnai tokie vertinimai taip pat pateikiami rengiant veiklos strategijas bei vertinant aplinkos oro kokybę (Klaipėdos Miesto Savivaldybės Aplinkos Oro Kokybės Valdymo Programa 2020 –2023 m., 2020; Klaipėdos Valstybinio Jūrų Uosto Žaliojo Uosto koncepcija, 2021). Detalūs Mujal-Colilles et al. (2022), Toscano et al. (2021), Yang et al. (2021) vertinimai leidžia atskleisti svarbias įžvalgas apie emisijų lokalizaciją, pokyčius laiko atžvilgiu bei energijos sunaudojimą uoste (Colarossi et al., 2022). Toscano ir kt. (2021) bei Yang ir kt. (2021) savo tyrimuose taip pat panaudojo AIS duomenis EMEP ir CALPUFF metodikose. Tačiau šių tyrimų metu mokslininkai apsiribojo AIS duomenų panaudojimu laivo eksploataciniais veiksmais identifikuoti (manevravimas, laivas stovi prie krantinės), laivui identifikuoti pagal MMSI numerį bei duomenims filtruoti (duomenims atmesti pagal tyrimo vietą). Disertaciniame darbe modifikuotoje EMEP trečiojo lygmens metodikoje be kitų mokslininkų naudotų AIS duomenų taip pat panaudojami ir laivo geolokaciniai duomenys jo pozicijos uoste ir atstumui nuo uosto galo ir matavimo vietai identifikuoti.

Naudota EMEP/EEA oro taršos trečiojo lygmens vertinimo metodika (European Environment Agency, 2019). Emisijos buvo vertinamos atsižvelgiant į laivo techninius parametrus bei judėjimą (atliekamą operaciją) pagal sudarytą algoritmą (17 paveikslas). Variklio tipui nustatyti ir kitiems techniniams parametrams įvertinti naudotas IHS Fairplay registras. Laivo operacija įvertinta naudojant laivo greičio skaitinę vertę, kuri buvo gauta iš AIS duomenų. Atlikti tiek pagrindinių, tiek pagalbinių vari-

klių skaičiavimai laivui vykdant tas pačias operacijas. Pagrindinių ir pagalbinių variklių apkrovos koeficientai (angl. Load factor (LF) parinkti pagal EMEP metodiką kiekvienai operacijai atskirai.

Algoritmas naudoja tris duomenų rinkinius – IHS Fairplay, AIS ir EMEP duomenis (17 paveikslas). AIS duomenys buvo surūšiuoti taip, kad apimtų tik uosto akvatorijoje esančius laivus ir įtrauktų laivo padėties koordinates, greitį ir IMO numerį identifikavimui. IHS Fairplay duomenų blokas – laivo techninės informacijos duomenų bazė: laivo tipas, bendroji talpa (GT), pagrindinio variklio tipas, variklių skaičius ir variklio galia.



17 pav. Emisijų skaičiavimo metodika papildant EMEP/EEA Tier 3 metodiką AIS duomenimis

AIS duomenų bloke pateikta informacija apie laivo veiklą. EMEP duomenų blokas, kurį sudarė apkrovos koeficientų, pagrindinių ir pagalbinių variklių santykio, išmetamųjų teršalų faktoriaus ir SFOC verčių duomenys, buvo naudojamas išmetamųjų teršalų faktoriams ir pagrindinio bei pagalbinių variklio santykiui gauti. AIS duomenų bloke laivo greitis buvo naudojamas laivo eksploatacijai (manevravimas, stovėjimas krantinėje) nustatyti ir tinkamiems variklio apkrovos koeficientams parinkti. Pagalbinis ir pagrindinis variklio santykis, gautas iš EMEP duomenų bloko, buvo naudojamas pagrindinių ir pagalbinių variklių galiai nustatyti. Išmetamųjų teršalų skaičiavimams buvo naudojami EMEP duomenų bloko išmetamųjų teršalų faktoriai, AIS duomenų bloko laiko ir apkrovos koeficientas bei pagrindinių ir pagalbinių variklių galia iš IHS Fairplay duomenų bloko.

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika

Parenkant išmetamųjų teršalų faktorius, buvo įvertintas variklio tipas (dujų turbina, didelės spartos variklis, vidutinio greičio variklis, lėto greičio variklis, garo turbina) ir naudojami degalai. IMO numeris buvo naudojamas laivo techniniams parametrams nustatyti iš IHS Fairplay duomenų bazės. Laivo padėtis uoste ir jo greitis buvo nustatyti naudojant AIS sistemos duomenis. Laivo eksploatacija (manevravimas, stovėjimas krantinėje) vertinama pagal laivo greitį – kai laivo greitis yra >0 m/s, tai laikoma manevravimo operacija, jei greitis lygus 0 – laivas stovi krantinėje. Skaičiavimai buvo atlikti tiek pagalbiniais, tiek pagrindiniais varikliais, įvertinant tas pačias operacijas. Įplaukimas į uosto teritoriją priskiriamas prie manevravimo, kadangi Klaipėdos uoste maksimalus laivų greitis yra 8 mazgai ($\sim 4,12$ m/s) (Lietuvos transporto saugos administracija, 2023), o vidutinis kruizinis (angl. cruising) laivo greitis siekia apie 20 mazgų ($\sim 10,29$ m/s). Siekiant geresnio tikslumo, buvo vertinami tik tie laivai, kurių duomenys buvo pastovūs. Buvo naudojamas duomenų filtras, kuris pašalina duomenis, jei skirtumas tarp duomenų eilučių AIS duomenų masyve buvo didesnis nei 4 min. 15 sek.

Pagrindinių (ME) ir pagalbinių variklių (AE) apkrovos koeficiento (LF) parametras parenkamas pagal EMEP metodiką kiekvienai operacijai atskirai (4 lentelė).

4 lentelė. Maksimalios nuolatinės apkrovos (MNA) koeficientas pagrindiniams ir pagalbiniais varikliais, įvairioms laivų operacijoms

Laivo kelionės fazė	MNA koeficientas pagrindiniam varikliui, %	Visų pagrindinių variklių veikimo laikas, %	MNA koeficientas pagalbiniam varikliui, %
Kruizas	80	100	30
Manevravimas	20	100	50
Stovėjimas prie krantinės (visi laivai, išskyrus tanklaivius)	20	5	40
Stovėjimas prie krantinės (tanklaiviai)	20	100	60

Laivų emisijos uoste buvo įvertinamos panaudojant EMEP trečiojo lygmens skaičiavimo metodiką (1–2 formulės).

Pirmoje formulėje pateikiamas bendras emisijų skaičiavimo būdas visai laivo kelionei pagal EMEP trečiojo lygmens metodiką:

$$E_t = E_H + E_M + E_C \quad (1)$$

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika

Čia: E_t – emisijos per visą laivo kelionę, t

E_H – emisijos laivui prisišvartavus prie krantinės, t

E_M – emisijos manevravimo metu, t

E_C – emisijos plaukimo jūroje eksploataciniu greičiu metu, t

Antroje formulėje pateikiamas emisijų skaičiavimas laivo kelionės metu, kai nėra žinomos kuro sąnaudos:

$$E_{Trip,i,j,m} = \sum_p \left[T_p \cdot \sum_e (P_e \cdot LF_e \cdot EF_{e,i,j,m,p}) \right] \quad (2)$$

Čia: E_{trip} – emisijos per visą laivo kelionę, g

EF – emisijos koeficientas, g/kWh

LF – variklio apkrova, %

P – variklių nominalioji galia, kW

T – laikas, h

e – variklio kategorija (pagrindinis, šalutinis),

i – teršalas,

j – variklio tipas (mažo greičio dyzelinis, vidutinio greičio dyzelinis, didelio greičio dyzelinis, dujų turbina, garo turbina),

m – kuro tipas,

p – kelionės fazė (plaukimas jūroje eksploataciniu greičiu, stovėjimas prie krantinės, manevravimas).

Remiantis modifikuotomis EMEP lygtimis, buvo įvertintos prie krantinės prisišvartavusių laivų energijos sąnaudos, kuro ir CO₂ emisijos. Kuro apskaičiavimas taip pat buvo atliktas remiantis EMEP III pakopos specifinėmis degalų sąnaudų vertėmis ir pritaikytas kiekvienam uoste esančiam laivui. CO₂ buvo apskaičiuotas įvertinant sunaudotą kurą, remiantis EMEP specifinėmis kuro sąnaudų vertėmis, tada taikant tipinį 87 % kuro anglies kiekį ir įvertinant išmetamą CO₂ kiekį darant prielaidą, kad visa anglis sudeginama iki CO₂. Modifikuota EMEP lygtis.

Energijos skaičiavimai prisišvartavus:

$$e_H = T \cdot (P_e \times LF_e) \quad (3)$$

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika

Čia: e_H – laivo stovėjimo prie krantinės metu laivų sunaudota energija;
LF – variklio apkrovos koeficientas (%);
P – variklio vardinė galia (kW);
T – laikas (valandomis);
e – variklio kategorija (pagrindinis, pagalbinis).

Išmetamam CO₂ kiekiui:


$$E_{CO_2} = \sum_p T_p \sum \left(P_e \times LF_e \times SFOC_{e,j,p} \times \frac{44}{12} \times 0.87 \right) \quad (4)$$

Čia: E_{CO_2} – per visą reisą išmestas CO₂ kiekis (kg);
SFOC – savitosios mazuto sąnaudos, kg/kWh;
LF – variklio apkrovos koeficientas (%);
P – variklio vardinė galia (kW);
T – laikas (valandomis);
e – variklio kategorija (pagrindinis, pagalbinis);
j – variklio tipas (lėto, vidutinio ir didelio greičio dyzelinis, dujų ir garo turbinos);
p – skirtingas kelionės etapas (plaukimas jūroje eksploataciniu greičiu, stovėjimas prie krantinės, manevravimas).

Remiantis laivų AIS duomenimis, išmetamųjų teršalų kiekis buvo vertinamas kiekvienai laivo padėčiai visame uoste. Taip pat kas valandą buvo skaičiuojami suminiai teršalų kiekiai kiekvienai uosto krantinei, susumuojant prie krantinės stovinčių ir krantinę praplaukiančių laivų išmetamus teršalus.

Atstumas tarp laivo ir matavimo vietos bei uosto pabaigos buvo įvertinamas naudojantis sferinę kosinusų teorema (18 paveikslas ir 5,6 formulės). Sferinę kosinusų teorema naudojama sferinėje trigonometrijoje, ypač taikoma nustatant didžiausią atstumą tarp dviejų taškų ant sferos paviršiaus, žinant jų ilgumą ir platumą. Ji yra ypač naudinga navigacijoje ir geodezijoje, kad būtų galima apskaičiuoti trumpiausią atstumą per Žemės paviršių.

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika



18 pav. Sferinės kosinusų teoremos pritaikymas atstumui tarp dviejų taškų su duotomis koordinatėmis vertinimui (sudaryta autoriaus).

18 paveiksle pateiktas supaprastintos sferinės kosinusų teoremos pritaikymas skaičiuojant atstumą tarp dviejų taškų su duotomis koordinatėmis. Norint apskaičiuoti atstumą tarp dviejų taškų (d) reikia įvertinti ir Žemės spindulį R (vidutiniškai 6371 km):

$$d = R \cdot c \quad (5)$$

Parametras c ($\Delta\sigma$) reiškia kampą Žemės centre (O) tarp dviejų spindulių OA ir OB ir yra matuojamas radianais. Centrinis kampas apskaičiuojamas panaudojant sferinę kosinusų teoremą:

$$\cos(d) = \cos(\varphi_1) \cos(\varphi_2) + \sin(\varphi_1) \sin(\varphi_2) \cos(\Delta\lambda) \quad (6)$$

Čia: d yra atstumas tarp dviejų taškų;

φ_1 ir φ_2 yra dviejų taškų platumas (radianais);

$\Delta\lambda$ yra dviejų taškų ilgumų skirtumas (radianais).

Teorema plačiai naudojama visuotinei navigacijai, kadangi tai yra geriausias kompromisas tarp tikslumo ir sudėtingumo. Trumpiems atstumams įvertinti dažnai naudojama Haversino formulė, o didžiausiam tikslumui pasiekti naudojama Vincenty

formulė (ji įtraukia Žemės elipsės formos įtaką skaičiavimams). Tačiau abi formulės nėra be trūkumų. Haversino formulė kartais kenčia nuo apvalinimo klaidų, kai kampai labai maži. Vincenty formulė yra sudėtingesnė nei kiti metodai, nes naudoja elipsoidinius skaičiavimus, iteracijas ir daug trigonometrinių funkcijų. Jos pagrindinis trūkumas yra lėtumas ir galimi problematiški antipodiniai taškai.

Sferinė kosinusų teorema yra stabilesnė nei Haversino teorema ir tinka įvertinti tiek trumpus, tiek ilgus atstumus tarp dviejų taškų. Teorema yra tiesioginė ir turi aiškų geometrinį interpretavimą, todėl ji yra vertinga priemonė įvairiose taikymo srityse, be navigacijos, pavyzdžiui, astronomijos, fizikos ar inžinerijos srityse, kai reikia spręsti su sferiniais atstumais susijusias problemas.

Praktiniuose taikymuose ši teorema gali būti naudojama programavime ir geografinėse informacijos sistemose, kad būtų galima apskaičiuoti atstumą tarp geografinių koordinacių, padedant planuoti maršrutus, nustatyti buvimo vietą ir kurti žemėlapius.

2.3. Antrojo skyriaus apibendrinimas

Antrajame skyriuje sudarytos metodikos skirtos uoste eksploatuojamų laivų taršai vertinti. Pirmoji parengta metodika skirta dirbtinių neuroninių tinklų (DNT) modelio kūrimui. DNT modelio veikimas pagrįstas sudėtingų ryšių tarp laivo geometrinių, techninių bei padėties ir meteorologinių parametrų identifikavimu. Šiam tikslui buvo sudarytas duomenų masyvas apmokyti dirbtinius neuroninius tinklus. Masyvas buvo sudarytas naudojant duomenis iš kelių skirtingų duomenų bazių (IHS Fairplay, BalticShipping, Marine MAN, Freemeteo, Lietuvos transporto saugos administracija). Laivo techniniai ir geometriniai duomenys buvo integruojami į AIS duomenis pagal laivo identifikavimo numerį. Integruoti duomenys buvo filtruojami, kad modelio apmokymui būtų pateikiami tik tie duomenys, kurie suteikia informaciją apie uoste eksploatuojamus laivus. Atlikus duomenų filtravimą, prie duomenų buvo pridėti meteorologiniai parametrai (vėjo greitis ir kryptis, slėgis, drėgmė). Meteorologiniai duomenys į masyvą buvo integruoti linijinės interpoliacijos būdu pagal laiką, panaudojant MS Excel programą. Sudarius modelio apmokymo masyvą, buvo identifikuojama modelio permokymo riba, kai modelio rezultatų patikimumas pradeda mažėti. Buvo nustatyta, kad modelis efektyviai veikia naudojant 424 neuronų architektūrą, toliau didinant neuronų skaičių modelio efektyvumas mažėja. Dirbtinių neuroninių tinklų modelio apmokymui buvo naudotas standartinis duomenų pasiskirstymas: 60 % duomenų – modelio apmokymui, 20 % duomenų – modelio validavimui ir 20 % duomenų testavimui. Pasirinktas 5 sluoksnių neuroninis tinklas su 4 hiperbolinio tangento (tanh) aktyvinimo funkcijomis. Dirbtinių neuroninių tinklų modelio apmokymas buvo vykdomas naudojant NeuralDesigner programinę įrangą.

2. Klaipėdos uoste eksploatuojamų laivų taršos įvertinimo metodika


Antroji metodika skirta esamos EMEP trečiojo lygmens emisijų skaičiavimo metodikai papildyti. Į esamą metodiką buvo įtraukti AIS duomenys, tiksliau, laivų pozicijos duomenys. Šiame skyriuje pateiktos EMEP metodikos lygtys įprastai naudojamos laivų emisijoms vertinti viso reiso metu arba per tam tikrą laiko tarpą (dažnu atveju mėnesio ar metų laikotarpio). Disertaciniame darbe naudojama modifikuota EMEP metodika remiasi tomis pačiomis formulėmis, tačiau į metodiką buvo integruoti AIS duomenys, siekiant sukurti detalią emisijų vertinimo sistemą, suteikiančią didesnę įžvalgumą apie jų pasiskirstymą uosto teritorijoje ir padedančią geriau suprasti poveikį aplinkinėms gyvenamosioms teritorijoms. Tą pačią metodiką galima pritaikyti ir dyzelinių generatorių naudojamai galiai prie krantinių įvertinti bei nustatyti galimus CO₂ ir kitų teršalų emisijų mažinimo tikslus. Metodika leidžia detaliai įvertinti oro teršalų ir CO₂ emisijas bei energijos naudojimą prie krantinių, suteikdama vertingų įžvalgų apie emisijų židinius ir mažinimo galimybes. Tačiau ši metodika turi tuos pačius apribojimus kaip ir EMEP/EEA metodika, susijusius su apkrovos koeficiento ir pagalbinio variklio galios įvertinimu. Dėl šios priežasties taip pat buvo kuriamas ir dirbtinių neuroninių tinklų modelis.

Tyrimų rezultatai

3.1. Klaipėdos uoste eksploatuojamų laivų kietųjų dalelių šleifų analizė

Klaipėdos uoste eksploatuojamų laivų taršos analizei buvo panaudoti 9 mėn. (nuo 2021-01-01 iki 2021-09-31) AQM65 oro taršos matavimo stoties duomenys. Duomenys buvo išfiltruoti, kad galutiniame duomenų masyve patektų tik 1 km diapazone aplink matavimo stotį buvę laivai. Šis atstumas parinktas atsižvelgiant į vidutinį Klaipėdos uoste eksploatuojamų laivų greitį ir faktą, kad kuo toliau laivas yra nuo matavimų stoties, tuo daugiau teršalų šleifas praskiedžiamas oru ir yra didesnė tikimybė, kad teršalų koncentracija susilygins su fonine uosto taršos koncentracija.


3. Tyrimų rezultatai



19 pav. Vidutinės pikų koncentracijos pagal laivo tipą

Išanalizavus vertinamų teršalų – 1, 2,5 ir 10 µm frakcijos kietosios dalelės (toliau KD1, KD2,5 ir KD10), koncentracijų pikus buvo nustatyta, kad vidutinės visų trijų frakcijų kietųjų dalelių koncentracijų reikšmės yra žemiausios konteinerinių laivų tipui, o aukščiausios – burių krovinių (19 paveikslas). Visų laivų tipų, išskyrus tanklaivius, atveju didžiausios koncentracijų reikšmės yra 10 µm kietųjų dalelių frakcijos. Tanklaivių atveju didžiausia koncentracija buvo fiksuota 2,5 µm kietųjų dalelių frakcijos. Vertinant teršalų šleifų vidutinės pikų koncentracijos pagal laivo tipą vertes nustatytas sistemingas koncentracijos didėjimas, didėjant kietųjų dalelių dydžiui. Taip yra todėl, kad į KD10 frakciją įeina visų trijų kietųjų dalelių frakcijos (KD1, KD2,5 ir KD10), o KD2,5 apima KD1 ir KD2,5 frakcijas. Todėl galima teigti, kad gautos vidutinės šleifų pikų koncentracijos atitinka teršalų vertinimo realijas, kai matuojant KD10 ar KD2,5 frakcijų koncentracijas, į jų reikšmes taip pat įtraukiamos ir žemesnių frakcijų koncentracijos.


3. Tyrimų rezultatai



20 pav. KD1 šleifų pikai pagal laivo tipą

Vertinant kiekvienos kietųjų dalelių frakcijos laivų išmetimų šleifus nustatyta, kad galima nesudėtingai identifikuoti $1\ \mu\text{m}$ kietųjų dalelių frakcijos šleifų pikus (20 paveikslas). $2,5\ \mu\text{m}$ kietųjų dalelių frakcijos šleifų pikai taip pat identifikuojami nesudėtingai. Vienintelė išimtis identifikuojant KD2,5 pikus nustatyta vertinant RoRo tipo laivus. Šiuo atveju ne visais atvejais pavyksta tinkamai įvertinti pikų koncentracijas, tą parodo 21 paveikslas, kuriame matoma, kad vietomis užfiksuojami dvigubi pikai ar didesni koncentracijų šuoliai pikuose.

3. Tyrimų rezultatai




21 pav. RoRo tipo laivų KD2,5 pikai

Šiam reiškiniui įtakos gali turėti RoRo tipo laivų aukštis, kai teršalų šleifas gali sklirti aukščiau matavimo stoties ir pikinės teršalų šleifo vertės įvertinamos neteisingai. Taip pat RoRo tipo laivuose gali būti išmetamųjų dujų valymo įranga („skruberiai“), kas taip pat gali turėti įtakos šleifo vertinimui. 10 µm kietųjų dalelių frakcijos šleifo pikai identifikuojami sudėtingai (22 ir 23 paveikslai). Taip yra todėl, kad didėjant kietųjų dalelių dydžiui artėjama prie foninę koncentraciją sudarančių teršalų dalelių dydžio ir šleifo pikų identifikavimas tampa sudėtingesnis.




Pastebėta, kad KD2,5 šleifų pikų identifikavimas skiriasi pagal laivo tipą. Didesnių laivų, tokių kaip tanklaiviai, konteineriniai laivai ar sausakrūviai laivai, pikai identifikuojami nesudėtingai, tačiau vilkikų, žvejybinių laivų ir RoRo tipo laivų atveju pikų identifikavimas yra sudėtingesnis. Mažesnių laivų variklių apkrovos dažnu atveju yra nepastovios, o RoRo tipo laivų pikų identifikavimą apsunkina jau minėta jų aukščio problema.

3. Tyrimų rezultatai




22 pav. Žvejybinių laivų, tanklaivių ir RoRo tipo laivų KD10 šleifų pikai

3. Tyrimų rezultatai



3. Tyrimų rezultatai

Atlikta kietųjų dalelių iš laivų šleifų pikų analizė leidžia įvertinti, kurio laivo tipo pikų koncentracijos yra aukščiausios. Remiantis 10 metrų aukštyje užfiksuotais duomenimis, didžiausia KD1 frakcijos pikinė koncentracija ($66,16 \mu\text{g}/\text{m}^3$) nustatyta sausakrūvių laivų. Šių laivų atveju taip pat fiksuota mažiausia koncentracija ($5,14 \mu\text{g}/\text{m}^3$), palyginti su kitų laivų rodikliais. 24 paveiksle pateikiamos minimalios ir maksimalios $1 \mu\text{m}$ kietųjų dalelių frakcijos šleifų pikų koncentracijos. Didesniam KD1 šleifo pikų koncentracijų pasiskirstymui sausakrūviuose laivuose įtakos gali turėti nesandarumai laivuose, kai dalis sauso krovinio gali patekti į atmosferą.




24 pav. KD1 pikų koncentracijos pasiskirstymas pagal laivo tipą


Vertinant KD2,5 frakcijos šleifų pikų koncentracijas, pastebėti panašūs dėsningumai kaip ir KD1 frakcijos atveju (25 paveikslas). Didžiausia kietųjų dalelių šleifo piko koncentracija – $67,58 \mu\text{g}/\text{m}^3$ – nustatyta sausakrūvių laivų tipui būdingame šleife. Mažiausia koncentracija ($5,63 \mu\text{g}/\text{m}^3$) užfiksuota konteinerinių laivų tipo atveju. Pikų koncentracijų pasiskirstymo intervalas buvo plačiausias sausakrūvių laivų tipo atveju.

Nagrinėjant $10 \mu\text{m}$ kietųjų dalelių frakciją, nustatyta, kad didžiausia ($155,98 \mu\text{g}/\text{m}^3$) ir mažiausia ($4,36 \mu\text{g}/\text{m}^3$) šleifų pikų koncentracijų reikšmės buvo užfiksuotos žvejybinių laivų tipo emisijų metu (26 pav.). Didžiausias šių reikšmių pasiskirstymo intervalas taip pat fiksuotas šiam laivų tipui.

3. Tyrimų rezultatai



25 pav. KD2,5 pikų koncentracijos pasiskirstymas pagal laivo tipą




26 pav. KD10 pikų koncentracijos pasiskirstymas pagal laivo tipą

Nustatyta, kad 2,5 μm kietųjų dalelių frakcijos šleifų pikų minimalios ir maksimalios koncentracijos yra didesnės nei 1 μm frakcijos kietųjų dalelių, tačiau maksimali šleifų pikų KD2,5 koncentracija yra mažesnė nei 10 μm frakcijos. Iš visų trijų nagrinėtų kietųjų dalelių frakcijų, tiek mažiausia, tiek didžiausia šleifo piko koncentracijos reikšmė užfiksuota 10 μm kietųjų dalelių frakcijai. Visų trijų frakcijų analizė parodė,

3. Tyrimų rezultatai

kad mažiausias šleifų pikų koncentracijų pasiskirstymo intervalas būdingas tanklaivių tipo laivų šleifams. Didžiausias pasiskirstymas nustatytas skirtingų laivų tipų atvejais: KD1 ir KD2,5 frakcijoms – sausakrūvių, o KD10 frakcijai – žvejybinių laivų tipo.




27 pav. Vidutinė kietųjų dalelių šleifo pikų trukmė pagal laivo tipą

Be pikų koncentracijų reikšmių, buvo vertinamos ir minimalios, maksimalios bei vidutinės visų trijų kietųjų dalelių frakcijų (KD1, KD2,5 ir KD10) šleifų pikų trukmės vertės. Nustatyta, kad trumpiausia vidutinė šleifo piko trukmė būdinga sausakrūvių tipo laivų šleifams (27 pav.): KD1 frakcijos vidutinė trukmė – 6,48 min., KD2,5 – 6,4 min., KD10 – 6,14 min. Ilgiausiai atmosferoje išsilaikantys kietųjų dalelių šleifų pikai nustatyti tanklaivių (KD1 frakcija, vidutinė trukmė – 11,26 min.) ir konteinerinių laivų (KD2,5 ir KD10 frakcijos, vidutinė trukmė – atitinkamai 9,6 ir 11,2 min.) šleifuose.


Vertinant kietųjų dalelių šleifų pikų trukmę pagal laivų tipus taip pat nustatytos minimalios ir maksimalios trukmės reikšmės (28–30 pav.).

Analizuojant KD1 frakcijos šleifo pikus (28 paveikslas) pagal laivo tipą, buvo nustatyta, kad ilgiausiai maksimali kietųjų dalelių koncentracija atmosferoje išsilaiko tanklaivių šleifuose – 16 min. Trumpiausiai 1 μm kietųjų dalelių maksimali koncentracija išsilaiko sausakrūvių laivų šleifuose – 2,4 min. Teršalų koncentracijos išmatuotos 10 metrų aukštyje.

3. Tyrimų rezultatai




28 pav. KD1 frakcijos šleifo pikų trukmė pagal laivo tipą



29 pav. KD2,5 frakcijos šleifo pikų trukmė pagal laivo tipą

KD2,5 frakcijos atveju (29 paveikslas), ilgiausiai ir trumpiausiai maksimalios koncentracijos atmosferoje išsilaiko sausakrūvių laivų šleifuose – 15,9 ir 2,12 min. atitinkamai. Tuo tarpu KD10 frakcijai didžiausia maksimalios koncentracijos šleife trukmė užfiksuota RoRo tipo laivų ir konteinerinių laivų šleifuose – 12 min. Trumpiausiai išliekanti maksimali KD10 koncentracija užfiksuota RoRo tipo laivuose – 3,02 min. (30 paveikslas).

3. Tyrimų rezultatai



30 pav. KD10 frakcijos šleifo pikų trukmė pagal laivo tipą


Vertinant maksimalios kietųjų dalelių koncentracijos išsilaikymą šleifuose, nustatyta, kad vidutiniškai visų tipų laivų šleifuose maksimalios koncentracijos išsilaikymo atmosferoje trukmė yra ~8 min., nepriklausomai nuo vertinamos kietųjų dalelių frakcijos (KD1 – 7,73 min.; KD2,5 – 7,82 min.; KD10 – 8,12 min.).

Nagrinėjant uoste eksploatuojamų laivų šleifų pikų koncentracijas, buvo įvertintas ir laivų greitis tiek analizuojamame plote 1 km aplink matavimo stotį (31 paveikslas), tiek ir visame uoste (32 paveikslas).

Nustatyta, kad analizuojamame plote didžiausią maksimalų greitį tarp uoste eksploatuojamų laivų pasiekė vilkikai – 24,26 km/h, o mažiausią – RoRo tipo laivai (17,22 km/h). Vertinant vidutinį greitį, didžiausia reikšmė nustatyta tanklaivių (9,68 km/h), o mažiausia – žvejybinių laivų (0,29 km/h) tipui.


31 ir 32 paveiksle pateikti duomenys rodo, kad atlikta uoste eksploatuojamų laivų išmetimų šleifo pikų analizė 1 km spinduliu aplink matavimo stotį gali būti pritaikyta ir visame uoste, kadangi laivų judėjimo tendencijos visame uoste išlieka panašios.

3. Tyrimų rezultatai



31 pav. Laivų analizuojamame plote (1 km aplink matavimo stotį) vidutiniai ir maksimalūs greičiai (km/h) pagal laivo tipą


Analizuojant visame uoste eksploatuojamų laivų duomenis, nustatytos panašios tendencijos kaip ir laivuose 1 km spinduliu aplink matavimo stotį. Mažiausias maksimalus ir vidutinis greičiai užfiksuoti žvejybinių laivų – 17,78 ir 0,56 km/h atitinkamai. Tačiau didžiausios reikšmės maksimalaus ir vidutinio greičių išsiskyrė.



32 pav. Visame uoste eksploatuojamų laivų vidutiniai ir maksimalūs greičiai (km/h) pagal laivo tipą

Didžiausias maksimalus greitis (24,26 km/h) užfiksuotas vilkikų, o didžiausias vidutinis greitis (5,07 km/h) užfiksuotas RoRo tipo laivų. Kuo mažesnis laivo greitis, tuo ilgiau laivas užtrunka plaukti iki krantinės ir tuo ilgiau išsilaiko jo šleifo piko koncentracija. Atskirų laivų tipų greičio pasiskirstymas uoste pateiktas B–G prieduose, o bendras visų uoste eksploatuojamų laivų greičio pasiskirstymas pateiktas 33 paveiksle.


3. Tyrimų rezultatai



33 pav. Uoste eksploatuojamų laivų greičio pasiskirstymo žemėlapis (HeatMap)

Atlikta uoste eksploatuojamų laivų šleifo pikų koncentracijų ir laiko analizė leidžia įvertinti, kiek laiko per parą atmosferoje išsilaiko laivų šleifų pikų koncentracijos. Nustatyta, kad sausakrūvių laivų šleifų pikų koncentracijos išsilaiko ilgiausiai, o trumpiausiai – žvejybinių laivų (34 paveikslas). Didžiausia nustatyta vidutinė šleifo piko koncentracijos išsilaikymo trukmė atmosferoje per parą $1\ \mu\text{m}$ kietosioms dalelėms yra 71,3 min., KD2,5 – 70,41 min., KD10 – 67,49 min. Mažiausia fiksuota vidutinė šleifo piko koncentracijos trukmė yra: KD1 – 14 min., KD2,5 – 14,86 min., KD10 – 14,23 min.

3. Tyrimų rezultatai



34 pav. Vidutinė laivų šleifo piko koncentracijos trukmė pagal laivų tipą

Panaši tendencija nustatyta ir vertinant laivų šleifų piko koncentracijas. Didžiausia maksimali koncentracija buvo užfiksuota sausakrūvių laivų (KD1 – 66,16 $\mu\text{g}/\text{m}^3$; KD2,5 – 67,58 $\mu\text{g}/\text{m}^3$) ir žvejybinių laivų (KD10 – 155,98 $\mu\text{g}/\text{m}^3$) pikuose. Didžiausia minimali koncentracija visų kietųjų dalelių frakcijų atveju užfiksuota tanklaivių pikuose: KD1 – 19,87 $\mu\text{g}/\text{m}^3$; KD2,5 – 20,41 $\mu\text{g}/\text{m}^3$; KD10 – 21,34 $\mu\text{g}/\text{m}^3$. Visų laivų šleifo piko maksimalios ir minimalios koncentracijų vertės pateiktos 4 lentelėje.

4 lentelė. Laivų šleifo piko koncentracijos reikšmės per parą pagal laivo tipą

	Maksimali laivų šleifo piko koncentracija, $\mu\text{g}/\text{m}^3$			Minimali laivų šleifo piko koncentracija, $\mu\text{g}/\text{m}^3$		
	KD1	KD2,5	KD10	KD1	KD2,5	KD10
RoRo	22,03	22,25	88,62	8,53	7,58	17,56
Tanklaiviai	22,19	25,50	25,79	19,87	20,41	21,34
Konteineriniai laivai	15,80	12,76	32,26	5,88	5,63	8,45
Sausakrūviai laivai	66,16	67,58	89,16	5,14	16,91	4,37
Vilkikai	42,65	39,56	88,80	14,53	14,79	4,37
Žvejybiniai laivai	59,07	60,12	155,98	14,55	16,25	4,36

Tiek laivų šleifo piko trukmės, tiek piko koncentracijos atveju didžiausios reikšmės užfiksuotos sausakrūvių laivų, kadangi analizuojamu laikotarpiu vidutiniškai per parą uoste eksploatuojamų laivų didžioji dalis buvo, būtent sausakrūviai laivai (5 lentelė).

3. Tyrimų rezultatai

5 lentelė. Laivų skaičius uoste per parą pagal laivo tipą

	Vidutinis laivų skaičius	Maksimalus laivų skaičius	Minimalus laivų skaičius
RoRo	3	6	1
Tanklaiviai	5	10	1
Konteineriniai laivai	4	8	1
Sausakrūviai laivai	11	20	1
Vilkikai	6	8	4
Žvejybiniai laivai	2	6	1

Analizuojant ryšį tarp laivų šleifo vidutinių pikų koncentracijų ir laiko trukmės, pastebėta tiesioginė priklausomybė tarp piko trukmės ir vidutinės piko koncentracijos – didėjant piko trukmei didėja ir vidutinė piko koncentracija (35 paveikslas).

Grafike matyti, kad didėjant ar mažėjant piko trukmei, analogiškai kinta ir vidutinė piko koncentracija. Išskirtinis atvejis yra žvejybiniai laivai, kadangi šių laivų šleifų koncentracijos įprastai yra didelės, o piko laikas – trumpas. Todėl grafike matomas neatitikimas tarp anksčiau minėtos priklausomybės.




Tačiau vertinant žvejybinių laivų pikų trukmę ir vidutinę pikų koncentraciją (36 paveikslas) matoma ta pati tendencija, kad didėjant piko trukmei didėja ir vidutinė piko koncentracijos reikšmė.

Laivų emisijos dydis priklauso nuo daugelio veiksnių, tarp kurių pagrindiniai yra variklių galia, apkrova ir naudojamas kuras. Tačiau jų įtaka aplinkos oro užterštumui taip pat priklauso nuo laivo dydžio, tipo ir meteorologinių sąlygų. Šleifų pikų tyrimų rezultatai rodo, kad laivo konstrukciniai parametrai gali lemti didelius skirtumus, turinčius įtakos tiek oro taršos lygiui, tiek žmonių sveikatai laivo plaukimo zonoje.

Vertinant aplinkos oro užterštumą ir jo poveikį žmonių sveikatai, svarbiausias parametras yra teršalų koncentracija, o ne jų emisija. Dabartinė mokslinė literatūra patvirtina, kad teršalų koncentracija turi tiesioginį poveikį žmonių sveikatai. Fuller et al. (2022) teigia, kad teršalų koncentracijos lygis tiesiogiai koreliuoja su sveikatos problemų dažnumu, o ne pats išmetamųjų teršalų kiekis. Jie taip pat pabrėžia, kad meteorologinės sąlygos ir geografinė padėtis lemia tai, kaip teršalai pasklinda ir pasiekia gyventojus, todėl teršalų koncentracijos matavimas yra esminis vertinant riziką žmonių sveikatai (Fuller et al., 2022). Tuo tarpu, Wang ir kt. (2023) išanalizavo ilgalaikį teršalų koncentracijos poveikį žmonių sveikatai ir nustatė, kad net mažos koncentracijos teršalai gali turėti rimtą poveikį ilgalaikėje perspektyvoje. Jie taip pat pabrėžia, kad didesnės koncentracijos teršalų didina širdies ir kraujagyslių ligų, plaučių ligų ir net ankstyvos mirties riziką (R. Wang et al., 2023). Koncentracija atspindi tikrąją oro kokybę, kuria kvėpuoja gyventojai, o tai, kaip teršalai sklaidosi ir kaip ilgai jie išlieka esant didelėms koncentracijoms, yra svarbu įvertinant sveikatos riziką. Nors emisija


3. Tyrimų rezultatai

rodo, kiek teršalų patenka į aplinką, galutinė rizika sveikatai priklauso nuo to, kaip tie teršalai pasiekia žmones ir kokia yra jų koncentracija ore (So et al., 2022).



35 pav. Priklausomybė tarp laivų šleifo piko trukmės ir vidutinės piko koncentracijos

3. Tyrimų rezultatai



36 pav. Priklausomybė tarp žvejybinių laivų šleifo pikų trukmės ir vidutinės pikų koncentracijos


Pikų analizės rezultatai parodė, kad norint tiksliai įvertinti uosto aplinkos oro užterštumą, reikia ne tik analizuoti teršalų emisijas, bet ir nustatyti vietas, kuriose oro kokybė yra labiausiai paveikta. Tam būtinas aplinkos oro užterštumo rodiklis, kuris padėtų identifikuoti kiekvieno uoste esančio laivo poveikį oro taršai. Laivų įtakos aplinkos oro užterštumui vertinimas yra sudėtingas dėl daugybės kintamųjų, todėl šiam uždaviniui spręsti tikslinga naudoti neuroninių tinklų modelius. Jie gali būti apmokyti analizuoti laivybos, oro užterštumo ir kitus susijusius duomenis, leidžiant tiksliau įvertinti taršos poveikį.

DNT modelio taikymas kartu su EMEP metodika leistų ne tik įvertinti tiesiogines laivų emisijas, bet ir nustatyti didžiausio poveikio zonas. Tai suteiktų galimybę taikyti tikslingas priemones taršai mažinti planuojant uosto veiklą.

Papildant EMEP metodiką neuroninių tinklų (DNT) modeliu, būtų galima ne tik vertinti bendrus išmetimus, bet ir lygiagrečiai nustatyti kiekvieno laivo poveikio oro užterštumui lygį. Šie duomenys galėtų būti panaudoti uosto valdymui siekiant išvengti didelio užterštumo zonų susidarymo, taip pat planuojant uosto terminalų veiklą ir kitas susijusias operacijas. Todėl rekomenduojama naudoti neuroninių tinklų modelį laivų poveikio aplinkos oro užterštumui reitingui sudaryti. Tai padėtų tiksliau įvertinti, ar išmetamų teršalų kiekis tiesiogiai koreliuoja su taršos poveikiu, ir leistų priimti efektyvesnius aplinkosaugos sprendimus.


3.2. Neuroninių tinklų modelio rezultatų analizė

DNT modeliui kurti naudota programinė įranga NeuralDesigner leidžia įvertinti modelio efektyvumą ir sugeneruoti paklaidų ir duomenų koreliacijos ataskaitas. Vertinant modelio mokymosi rezultatus ir testavimui skirtų duomenų koreliaciją buvo nustatyta, kad KD1 determinacijos koeficientas yra 0,8952, KD2,5 – 0,8889, o KD10 – 0,77 (37–39 paveikslai).




37 pav. 1 μm kietųjų dalelių realių ir testavimo masyvo prognozuojamų duomenų koreliacija

3. Tyrimų rezultatai




38 pav. 2,5 μm kietųjų dalelių realių ir testavimo masyvo prognozuojamų duomenų koreliacija



39 pav. 10 μm kietųjų dalelių realių ir testavimo masyvo prognozuojamų duomenų koreliacija

3. Tyrimų rezultatai

Nors gauti dirbtinių neuroninių tinklų (DNT) modelio rezultatai rodo, kad modelio prognozuojamos kietųjų dalelių taršos vertės yra artimos realiems duomenims, norint tinkamai įvertinti modelį reikia papildomos analizės su kitų duomenų masyvu. 1 μm kietųjų dalelių realių ir neuroninių tinklų modelio prognozuojamų duomenų koreliacija su naujų duomenų masyvu (modelio apmokymui nenaudoti duomenys) pateikiami 40 paveiksle.




40 pav. KD1 realių duomenų ir neuroninių tinklų modelio prognozuojamų duomenų koreliacija

2,5 μm ir 10 μm kietųjų dalelių paveikslai pateikti H ir I prieduose. Paveiksluose laikas pateikiamas kaip laikas praėjęs nuo matavimo pradžios minutėmis. Ta pati tendencija tarp realių ir neuroninių tinklų prognozuojamų duomenų koreliacijos pastebima analogiškai ir 2,5 μm bei 10 μm kietųjų dalelių frakcijoms.

41 paveiksle pateiktas fragmentas, kai modelio prognozuojamos vertės ypač skiriasi nuo realių. Panašų vaizdą galima pastebėti analizuojant kiekvienos kietųjų dalelių frakcijos paklaidų reikšmes.

Nustatyta, kad netikslumai tarp realių duomenų ir modelio prognozuojamų duomenų atsiranda dėl didelio kietųjų dalelių koncentracijų kontrasto. Modeliui apmokyti pateiktame duomenų masyve yra tiek žemų koncentracijų (daugiausiai foninė koncentracija, kai taršos rezultatams laivai neturi įtakos), tiek didelių koncentracijų, kai fiksuojama praplaukiančių pro matavimo stotį laivų tarša. Dėl šios priežasties modelis labiausiai klysta vertindamas foninę taršą tose situacijose, kai neįtraukiama laivų taršos įtaka. Šiai problemai spręsti ateityje būtų galima kurti du atskirus modelius, vienas būtų naudojamas žemoms koncentracijoms vertinti, kitas aukštomis. Taip pat būtų reikalingas algoritmas, galintis nustatyti, kuris modelis turėtų būti naudojamas.

3. Tyrimų rezultatai



41 pav. KD1 realių ir prognozuojamų duomenų koreliacijos grafiko fragmentas

Nors gauti rezultatai rodo, kad bendra koreliacija tarp realių ir DNT prognozuojamų duomenų yra nebloga, vidutinė KD_{2,5} koncentracijos paklaida parengtame modelyje šiuo metu yra 23 %, t. y. pakankamai artima pasaulyje naudojamiems modeliams. AERMOD azoto dioksido (NO₂) koncentracijos vidutinė paklaida miestuose buvo 24 %. AERMOD vidutinė KD_{2,5} koncentracijos vidutinė paklaida mieste buvo 31 %. CALPUFF vidutinė KD_{2,5} koncentracijos paklaida kaimo vietovėje yra 14 %.

6 ir 7 lentelėse pateikiamos modelio paklaidų vertės. DNT modelio apmokymo metu paklaidos kiekvieno apmokymo etapui pateikiamos šeštoje lentelėje. Nustatyta, kad gautos normalizuotos kvadratinės vidutinės paklaidos šaknies reikšmės (NRMSE) yra per didelės. Modelio apmokymo programinė įranga naudoja minimalių ir maksimalių reikšmių (min-max) normalizacijos metodą. Modelio apmokymui naudotame masyve esančios kietųjų dalelių koncentracijos turi ekstremumų, kurie padidina NRMSE vertes. Dėl šios priežasties papildomai vertinama RMSE vertė. Buvo nustatyta, kad visų modelio apmokymo etapų metu kvadratinės vidutinės paklaidos šaknies (RMSE) vertė neviršija 10–20 % vidutinės kietųjų dalelių koncentracijos vertės (KD₁ nuo 0,49 iki 0,98 µg/m³; KD_{2,5} nuo 0,57 iki 1,14 µg/m³; KD₁₀ nuo 1,067 iki 2,135 µg/m³). Esant tokioms reikšmėms modelis yra laikomas priimtinu.

3. Tyrimų rezultatai

6 lentelė. DNT modelio apmokymo paklaidos

Paklaidos vertinimo rodiklis	Modelio apmokymo etapas		
	Apmokymas	Validacija	Testavimas
Vidutinė kvadratinė paklaida (MSE)	0,031	0,054	0,065
Šaknis iš vidutinės kvadratinės paklaidos (RMSE)	0,175	0,231	0,233
Normalizuota šaknis iš vidutinės kvadratinės paklaidos (NRMSE)	0,375	0,387	0,382

Kaip vienas pagrindinių modelio tikslumo vertinimo rodiklių buvo taikoma šakninė vidutinė kvadratinė paklaida (angl. Root Mean Square Error, RMSE), apskaičiuojama kaip kvadratinų paklaidų vidurkio kvadratinė šaknis. Ši metrika parodo vidutinį modelio prognozuojamų reikšmių nuokrypį nuo faktinių reikšmių, išreikštą ta pačia matavimo skale kaip ir prognozuojamas kintamasis. RMSE yra glaudžiai susijusi su dispersija – jos kvadratas atitinka paklaidų dispersiją, tačiau ji nėra tapatinama su standartine paklaida, kuri įprastai taikoma inferencinėje statistikoje.

Šiame tyrime RMSE, taip pat ir MSE bei NRMSE, buvo naudojamos kaip aprašomosios statistinės metrikos, skirtos bendram modelio prognozių tikslumui įvertinti. Kadangi analizėje nebuvo taikomos inferencinės procedūros – neformuluoti pasikliautinumo intervalai ir netaikytas reikšmingumo lygmuo – statistinio reikšmingumo lygio (pvz., $\alpha = 0,05$) taikymas nebuvo aktualus. RMSE reikšmės buvo interpretuojamos kaip praktinis modelio tikslumo rodiklis, neturintis inferencinio statistinio pagrindo.

Septintoje lentelėje pateikiamos paklaidos, kai modeliui pateikiamas naujas duomenų masyvas, siekiant patikrinti modelio rezultatų tikslumą. Visų trijų kietųjų dalelių frakcijų maksimali procentinė paklaida siekia 63–71 proc., tačiau vidutinė procentinė paklaida neviršija 3 proc. Vertinant modelio apmokymo ir testavimo funkcijas nustatyta, kad apmokymo metu šaknis iš vidutinės kvadratinės paklaidos sudaro 0,175 apmokymo duomenims ir 0,233 testavimo duomenims.

Neural Designer programinė įranga taip pat suteikia galimybę patikrinti modelio testavimo paklaidų pasiskirstymą. Jeigu modelis veikia tinkamai, santykinės paklaidos reikšmės turėtų pasiskirstyti pagal normalųjį (Gauso) pasiskirstymo modelį. Sukurto DNT modelio santykinų paklaidų histogramos (42 paveikslas) rodo, kad paklaidos pasiskirsto pagal Gauso modelį.

3. Tyrimų rezultatai

7 lentelė. Kiekvienos kietųjų dalelių frakcijos Testavimo duomenų paklaidų vertės

	Minimali paklaidos reikšmė	Maksimali paklaidos reikšmė	Vidutinė paklaidos reikšmė
	KD1		
Absoliuti paklaida	0	53,3825	1,56361
Santykinė paklaida	0	0,64489	0,0188893
Procentinė paklaida	0	64,489	1,88893
	KD2,5		
Absoliuti paklaida	0	53,2732	1,75063
Santykinė paklaida	0	0,633621	0,0208216
Procentinė paklaida	0	63,3621	2,08216
	KD10		
Absoliuti paklaida	0,000001144	154,566	3,23794
Santykinė paklaida	0,000000053	0,714507	0,0149679
Procentinė paklaida	0,000000529	71,4507	1,49679




Modelio rezultatų paklaidų histogramos leidžia įvertinti, kaip plačiai pasiskirsto išskirtinai aukštos ar žemos santykinės paklaidos. Pagal gautus rezultatus matoma, kad didžioji testavimo duomenų dalis papuola į nedidelį santykinės paklaidos intervalą (0–12,02 KD1 ir KD2,5 atveju ir 0–9,83 KD10 atveju). Visų trijų kietųjų dalelių frakcijų atveju šis paklaidų intervalas sudaro ~49 proc. visų paklaidų. Didžiosios paklaidos (>40 proc.) sudaro sąlyginai nedidelį paklaidų kiekį – nuo 0 iki 0,01, priklausomai nuo kietųjų dalelių frakcijos.

Formaliai normalumas įvertintas Jarque–Bera (JB) testu, taikytu visai paklaidų aibei, gauti šie rezultatai:

- KD₁: asimetrija $S = -0,98$, smailumas $K = 1,26$, JB reikšmė ≈ 176754 ;
- KD_{2,5}: asimetrija $S = -0,83$, smailumas $K = 2,17$, JB reikšmė ≈ 46903 ;
- KD₁₀: asimetrija $S = -1,37$, smailumas $K = 16,30$, JB reikšmė ≈ 2489014 .

Papildomai buvo atliktas Shapiro–Wilk testas, taikytas 5000 atsitiktinai atrinktų paklaidų imčiai. Šiuo atveju taip pat gauta p reikšmė ≈ 0 , kas statistškai rodo reikšmingą nukrypimą nuo normalumo. Tačiau būtina pabrėžti, kad esant labai didelei imčiai net ir nedideli nukrypimai nuo teorinės normalumo prielaidos (pvz., smailumo sumažėjimas ar lengva asimetrija) statistškai išryškėja kaip reikšmingi. Simetriška, be reikšmingų šuolių histogramų forma, žemos vidutinių paklaidų vertės (absoliuti paklaida: 1,56–3,23; santykinė paklaida: 0,015–0,02; procentinė: 1,5–2,1 %) bei aukšta koreliacija tarp prognozuotų ir stebėtų verčių (R^2 : 0,78–0,89) rodo, kad praktiniu požiūriu paklaidų pasiskirstymas yra pakankamai artimas normaliam. Todėl modelio paklaidų pasiskirstymas vertinamas kaip tinkamas praktiniam modeliavimo rezultatų taikymui.

3. Tyrimų rezultatai




42 pav. Dirbtinių neuroninių tinklų modelio santykinų paklaidų histogramos pagal kietųjų dalelių frakciją

3. Tyrimų rezultatai

Analizuojant modelio architektūrą buvo tikrinama, koks neuronų skaičius būtų efektyviausias modeliui kurti. Pagal standartinio nuokrypio reikšmes buvo įvertinta, kad efektyviausiai modelis turėtų veikti naudojant 524 neuronų architektūrą. Tačiau atliekant rezultatų analizę pastebėta, jog naudojant 524 neuronus susiduriama su permokymo (angl. overfitting) reiškiniu. Šis reiškinys pasireiškia, kai mokymuisi ir testavimui skirti duomenys rodo puikius rezultatus, tačiau modeliui pateikus naują duomenų masę ir palyginus prognozuojamus rezultatus su realiais duomenimis, pastebima, jog modelis prognozę atlieka labai prastai.

Sukurtas dirbtinių neuroninių tinklų (DNT) modelis leidžia prognozuoti bet kio tipo laivų šleifo koncentracijas realiu laiku bet kurioje uosto vietoje. Skirtingai nuo kitų modelių šiam modeliui nereikia pradinių duomenų apie emisijas, išmetamųjų dujų temperatūrą, cheminę sudėtį, išmetimo greitį ir kt., kurių laivuose gauti neįmanoma be tiesioginių matavimų.

Be paklaidų vertinimo, rezultatų analizė leidžia įvertinti parametų ir rezultatų tarpusavio ryšį. Analizuojant rezultatus nustatyta išvesties ir įvesties parametų tarpusavio priklausomybė. Modeliui sukurti buvo naudojami 17 įvesties parametrai, kurie, vertinant jų įtaką modelio rezultatams, buvo suskirstyti į keturias grupes: laivo geometriją nusakantys parametrai, laivo padėtį nusakantys parametrai, laivo jėgainės apkrovą nusakantys parametrai, aplinkos sąlygas nusakantys parametrai (43 paveikslas).




43 pav. Modelio įvesties parametų suskirstymo į grupes schema

Parametų įtakos modelio rezultatams svarbumas vertintas skalėje nuo 0 iki 1. Kuo rezultatas arčiau 0, tuo didesnė tikimybė, kad to parametro reikšmė rezultatams įtakos turi labai mažai arba neturi visai. Kuo reikšmės artimesnės 1, tuo parametro įtaka rezultatams yra didesnė. 44 paveiksle pateikta visų 17 įvesties parametų svarbumo

3. Tyrimų rezultatai


modelio rezultatams reikšmė. Iš paveikslėlio matyti, kad visų kietųjų dalelių frakcijų prognozavimo rezultatai labiausiai priklauso nuo meteorologinių parametrų – vėjo krypties, vėjo greičio, santykinio drėgnumo ir slėgio.



44 pav. Modelio įvesties parametrų svarbumo rezultatams reikšmė


Taip pat įvertinta kiekvieno modelio įvesties parametrų, suskirstytų į grupes, svarbos reikšmės, siekiant išskirti svarbiausią parametą kiekvienoje grupėje. Tam atlikti kiekvienos parametrų grupės svarbumo reikšmių suma buvo prilyginta vienetui ir išskaičiuota kiekvieno įvesties parametro svarbumo reikšmė intervale nuo 0 iki 1. Kiekvienos grupės įvesties parametrų svarbumo reikšmių vertės pateikiamos 44–47 paveiksluose. Nustatyta, kad didžiausią įtaką rezultatams laivo geometriją nusakančių parametrų grupėje daro bendrasis tonažas (GT) ir dedveito tonažas (DWT) (45 paveikslas). O mažiausiai įtakos rezultatams turi laivo grimzlės parametras.

3. Tyrimų rezultatai



45 pav. Laivo geometriją nusakančių parametų svarbumo rezultatams reikšmė


Meteorologinių parametų grupėje didžiausią įtaką rezultatams turi vėjo parametrai – kryptis ir greitis. Mažiausiai rezultatams įtakos turi slėgio reikšmės (46 paveikslas).



46 pav. Meteorologines sąlygas nusakančių parametų svarbumo rezultatams reikšmė


3. Tyrimų rezultatai

Tarp laivo jėgainės apkrovą nusakančių parametų didžiausią įtaką rezultatams daro laivo variklių galia (47 paveikslas). Tačiau šioje grupėje esančių parametų rezultatų skirtumas, palyginti su kitų įvesties parametų grupių rezultatais, nėra toks didelis.



47 pav. Laivo jėgainės apkrovą nusakančių parametų svarbumo rezultatams reikšmė

Lyginant didžiausios ir mažiausios įtakos turinčių įvesties parametų svarbos reikšmių santykį kiekvienoje grupėje, nustatyta, kad laivo jėgainės apkrovą nusakančių įvesties parametų grupėje šis santykis yra ~ 2 , o kitose grupėse šis santykis yra nuo 10 iki 25. Rezultatams pagrindinę įtaką daro laivo poziciją nusakančių parametų grupės elementai – ilguma, platumas ir laivo kursas. Mažiausiai rezultatams įtakos turi laivo kurso virš žemės reikšmės (48 paveikslas).




48 pav. Laivo poziciją nusakančių parametų svarbumo rezultatams reikšmė

3. Tyrimų rezultatai

Įvesties parametų išskyrimas į keturias grupes, leidžia įvertinti laivų techninių parametų, geometrinių parametų bei meteorologinių sąlygų įvesties parametų įtaką modelio rezultatams. Nustatyta, kad didžiausią įtaką modelio rezultatams turi meteorologiniai parametrai.

Dirbtinių neuroninių tinklų (DNT) modelis leidžia nustatyti laivų taršos koncentracijas esant vienodiems meteorologiniams ir laivo pozicijos parametrams. 49 paveiksle pateiktos DNT modelio prognozuojamos kietųjų dalelių (KD1, KD2,5 ir KD10) koncentracijos, kai kinta tik laivo jėgainės ir geometriniai parametrai.



49 pav. Kietųjų dalelių (KD1, KD2,5 ir KD10) koncentracijos pagal laivo tipą esant toms pačioms meteorologinėms sąlygoms bei laivo pozicijos parametrams


Tai patvirtina 3.1 poskyryje iškeltą hipotezę, jog priklausomai nuo laivo tipo ir jo dydžio kietųjų dalelių koncentracija yra skirtinga. Šio modelio rezultatų pagrindu galima formuoti aplinkos oro užterštumo reitingą, kuris padėtų identifikuoti kiekvieno uoste esančio laivo poveikį oro taršai.

3.3. Dinaminis uosto akvatorijos taršos vertinimas panaudojant AIS duomenis ir EMEP metodiką

DNT modelis leidžia vertinti aplinkos taršą iš laivų, vertinant teršalų koncentracijas ir jų pokytį. Tačiau ne visada reikia vertinti teršalų koncentracijas. Norint įvertinti teršalų emisijas DNT modelis tampa netinkamas. Šiai problemai spręsti disertaciniame darbe buvo sukurta metodika, leidžianti į esamą trečiojo lygmens EMEP metodiką įterpti AIS duomenis siekiant tikslesnio teršalų emisijų vertinimo.

3. Tyrimų rezultatai

Klaipėdos uostą sudaro 22 skirtingi terminalai, įvairios įmonės veikia uosto teritorijoje. Dėl šių priežasčių į Klaipėdos uostą atvykstančių laivų įvairovė yra gana didelė. Padalijus laivus į 11 grupių (50 paveikslas), didžiausi išmetamųjų teršalų kiekiai pagal azoto oksidus (NO_x) sugeneruojami trijų laivų tipų: „Ro-Ro“ (26 %), konteinerinių laivų (24 %) ir sausakrūvių laivų (21 %).



50 pav. Į Klaipėdos uostą įplaukiančių laivų emisijos (%) pagal laivo tipą

Po trijų didžiausias emisijas išmetančių laivų grupių seka kitų laivų kategorija (8 %), kuri sudaryta iš įvairių pagalbinių, remonto ir kitos paskirties laivų. Tanklaivių ir generalinių krovinių laivų išmetimų emisijos yra panašios ir siekia 7,28 bei 7,17 proc. atitinkamai. Vilkikų procentinė NO_x emisija siekia 4 proc. Likusi emisijų dalis pasiskirsto tarp LNG tanklaivių, šaldomų krovinių laivų bei žvejybinių laivų. Detalus emisijų duomenys pagal laivo tipą pateikiami 8 lentelėje.

Emisijų dydis uoste priklauso nuo laivybos intensyvumo ir, jei nėra reikšmingų veiklos skirtumų uoste, rezultatas bus gana reprezentatyvus, vertinant emisijas per metus. Tačiau uostuose, turinčiuose daug skirtingų terminalų ir nenuoseklų veiklos intensyvumą, vidutinis emisijų ir energijos suvartojimo vertinimas gali nepakankamai atspindėti poveikį oro kokybei.

3. Tyrimų rezultatai

8 lentelė. Vidutinės teršalų emisijos pagal laivo tipą

Laivo tipas	NO _x , t/d	CO, t/d	Ne metano lakieji or- ganiniai junginiai (NMLOJ), t/d	Suspen- duotos kietosios dalelės (SKD), t/d	Anglis, t/d	CO ₂ *, t/d	Ener- gija*, kWh
LNG tanklaiviai	0,57	0,06	0,02	0,01	0,0008	18,73	30264
Žemsiurbės	0,96	0,13	0,08	0,03	0,001	61,33	85823
Žvejybiniai laivai	1,97	0,19	0,08	0,04	0,002	108,09	171889
Šaldomų krovinių laivai	3,54	0,33	0,15	0,07	0,004	170,31	272263
Vilkikai	9,66	1,66	0,85	0,27	0,019	372,97	524570
Generalinių krovinių laivai	17,42	1,90	0,92	0,40	0,023	898,33	1375904
Tanklaiviai	17,67	1,63	0,67	0,35	0,019	884,38	1424448
Kiti	20,25	2,26	1,23	0,48	0,026	1307,66	1933306
Sausakrūviai laivai	51,38	4,21	1,81	0,97	0,054	2321,38	3747557
Konteineriniai laivai	57,18	5,12	2,09	1,11	0,067	2284,59	3691608
Ro-Ro	62,22	6,39	2,49	1,30	0,081	2374,02	3836118

* – Energijos ir CO₂ emisijos skaičiuotos tik stovintiems laivams.

Išvertinus vidutines emisijas per dieną Klaipėdos uoste nuo 2020-11-25 iki 2021-01-09, pagal turimus duomenis, gautas rezultatas – 5,28 tonos NO_x. Gautas rezultatas, palyginti su ankstesniais tyrimais, yra labai artimas 2020 m. Klaipėdos miesto savivaldybės atliktiems tyrimams (Klaipėdos miesto savivaldybės aplinkos oro kokybės valdymo programa 2020–2023 m., 2020) ir daug didesnis nei 2014 m. Abrutytės ir kt. tyrime. Skirtumas tarp Abrutytės ir kt. tyrimų gali būti paaiškintas daug senesniais duomenimis su mažesniu laivų srautu. Taip pat Abrutytės ir kt. tyrimuose buvo naudojama antrojo lygmens EMEP metodika, kurioje emisijos vertinamos pagal kuro sąnaudas. Vidutiniai ir maksimalūs visų emisijų dydžiai pateikti 9 lentelėje.

3. Tyrimų rezultatai


9 lentelė. Vidutinės ir maksimalios emisijos Klaipėdos uoste

Teršalas	Vidutinė emisija	Maksimali emisija	Minimali emisija	Vidutinė emisija*	Vidutinė emisija**
Azoto oksidai (NO_x), t/d	5,28	7,64	2,74	2,59	5,06
Suspenduotos kietosios dalelės (SKD), t/d	0,52	0,74	0,29	-	0,3
Ne metano lakieji organiniai junginiai (NMLOJ), t/d	0,22	0,32	0,12	-	0,311
Juodoji anglis, t/d	0,064	0,0095	0,0033	-	-
Anglies dioksidas (CO_2), t/d	235	341	125	-	-
Energija, kWh	371603	545076	197517	-	-

* – Abrutytė ir kt. tyrime

** – Klaipėdos miesto savivaldybės tyrime


Laivų generatorių energija ir jos paskirstymas uoste laikotarpiu nuo 2020-11-25 iki 2021-01-09 yra tolygūs. Esant minimaliam energijos kiekiui 197 518 kWh, maksimali suvartojimo vertė buvo 545 076 kWh energijos per dieną ir atitinkamai 340 t CO_2 per dieną (51 paveikslas).




51 pav. Laivų generatorių pagaminamas energijos kiekis, CO_2 emisija ir jų pasiskirstymas laiko atžvilgiu

Vertinant poveikį aplinkos oro kokybei, dienos rodikliai yra ne mažiau svarbūs nei ilgo laikotarpio vidutinės ar bendros emisijos. Emisijų pokyčių grafikai pateikti 52 ir 53 paveiksluose.

3. Tyrimų rezultatai




52 pav. Suminė CO, NMLOJ ir SKD paros emisija




53 pav. Suminė juodosios anglies (BC) ir NO_x paros emisija

Emisijų sklaida taip pat priklauso nuo emisijų intensyvumo pasiskirstymo uosto terminaluose. Paskirsčius emisijas Klaipėdos uosto krantinėse, nustatyta, kad 1; 54–57; 127 ir 128 krantinėse, kur buvo kraunami / iškraunami tanklaiviai (krantinė 1), bendrieji krovininiai (krantinės 54–57) bei Ro-Ro laivai (krantinės 127–128), emisijos buvo didesnės. Emisijų pasiskirstymas laiko atžvilgiu krantinėse, kuriose emisijos linkusios būti didžiausios, siekė atitinkamai iki 1,24 ir 1,07 tonų per dieną. Lyginant šiuos skaičius su vidutinėmis NO_x emisijomis uoste (5,28 t NO_x per dieną), matoma, kad 20 % teršalų emisijų atskiromis dienomis gali būti išmetama vienoje vietoje (54 ir 55 paveikslai).

3. Tyrimų rezultatai




54 pav. Emisijų pasiskirstymas 1–90 uosto krantinėse



55 pav. Emisijų pasiskirstymas 91–142 uosto krantinėse

Maksimalios emisijos krantinėse 127–128 (55.658357; 21.155559) buvo 1,24 t/d., o krantinėje Nr. 1 (55.726619; 21.093111) - 1,18 t/d. NO_x (56 pav.). Pažymėtina, kad nors vidutinė laivų emisija uoste buvo ~ 5,28 t/d., esant tinkamoms sąlygoms, 20 % visų emisijų iš laivų gali būti sutelkta vienoje ar kitoje uosto krantinėje. Tai yra labai svarbu vertinant uosto poveikį ir emisijų sklaidą bei planuojant oro teršalų stebėjimo stotis.

3. Tyrimų rezultatai



56 pav. NO_x paros emisijų pasiskirstymas pirmoje ir 127–128 uosto krantinėse

Disertaciniame darbe buvo nagrinėjamas laivybos emisijų pasiskirstymas ir emisijų trukmė Klaipėdos uoste, taip pat CO₂ emisijos ir suvartota energija krantinėje. Su augančiu poreikiu uostams tapti žaliais ir tvariais, būtina pasiekti sudėtingus tikslus, siekiant užtikrinti CO₂ neutralumą ir švorių oro standartų laikymąsi. Vis dėlto pažymima, kad trūksta vertinimų, kurie būtų skirti teršalų emisijoms, energijos suvartojimui ir CO₂ emisijoms toje pačioje studijoje, pateikiant aiškų potencialaus teršalų ir CO₂ emisijų mažinimo vaizdą. Naudojant Klaipėdos uostą kaip pavyzdį, buvo nustatytos trys vietos uoste, kuriose dėl intensyvesnio laivų srauto ir techninių laivų charakteristikų emisijos buvo žymiai didesnės. Nustatyta, kad nors vidutinė laivų emisija uoste buvo ~ 5,28 t/d., esant tinkamoms sąlygoms, 20 % visų laivų emisijų gali būti sutelkta vienoje krantinėje. Tokio tipo pikinės emisijos, nors ir laikinos, gali būti reikšmingas taršos šaltinis aplinkinėse gyvenamosiose vietovėse. Norint išvengti teršalų ribų viršijimo, vietos, kuriose gali atsirasti tokios pikinės emisijos, turėtų būti pirminis stebėjimo ir emisijų mažinimo priemonių, tokių kaip kranto energijos naudojimas, taikymo tikslas. Vidutinis dienos energijos suvartojimas ir CO₂ emisijos krantinėje, nagrinėtu laikotarpiu, svyravo nuo 500 iki 5000 kWh ir nuo 120 iki 350 tonų CO₂ atitinkamai vienai krantinei. Nors šis vertinimas turi ribotumą dėl tikslų pagalbinių variklių galios ir apkrovos duomenų trūkumo, jis suteikia gerą supratimą apie galimą energijos suvartojimą ir galimų CO₂ sumažinimo galimybių įvertinimą visam uostui ar atskirų krantinių pagrindu.

3.4. Trečiojo skyriaus išvados

1. Atlikta detali laivų eismo ir išmetamųjų dujų šleifų uoste analizė. Nustatytas vidutinis laivų eismo intensyvumas pagal laivo tipą, atsižvelgiant į laivų skai-

3. Tyrimų rezultatai

čių ir vidutinį plaukimo greitį. Taip pat įvertinta laivų išmetamųjų dujų šleifo įtaka aplinkai analizuojamoje vietoje ir laivo eksploatacijos metu uoste. Tyrimo rezultatai parodė, kad vidutinis laivo greitis sudarė nuo 0,2 iki 25 km/h. Laivų išmetamųjų dujų šleifo pikinės koncentracijos sudarė nuo 5,2 iki 43,84 $\mu\text{g}/\text{m}^3$, o poveikis analizuojamoje vietoje truko nuo 6,14 iki 11,26 min. Pikų analizė parodė, kad norint tiksliai įvertinti uosto aplinkos oro užterštumą, reikia ne tik analizuoti teršalų emisijas, bet ir nustatyti, kuriose vietose oro kokybė yra labiausiai paveikta. Tam būtinas aplinkos oro užterštumo rodiklis, kuris padėtų identifikuoti didžiausią poveikį turinčias uosto zonas. Dirbtinių neuroninių tinklų (DNT) modelis suteikia galimybę suformuoti tokį reitingą ir naudoti jį kartu su EMEP metodika. DNT modelio taikymas kartu su EMEP metodika leistų ne tik įvertinti tiesiogines laivų emisijas, bet ir nustatyti didžiausio poveikio zonas. Tai suteiktų galimybę taikyti tikslingas priemones taršai mažinti planuojant uosto veiklą.

2. Vertinant modelio mokymosi rezultatus ir testavimui skirtų duomenų paklaidas buvo nustatyta, kad KD1 determinacijos koeficientas yra 0,8952, KD2,5 – 0,8889, o KD10 – 0,77. Testavimo paklaidas puikiai atspindi Gauso pasiskirstymo modelis. Visų trijų frakcijų kietųjų dalelių maksimali procentinė paklaida siekia 63–71 proc., tačiau vidutinė procentinė paklaida neviršija 3 proc.
3. Atliktų tyrimų rezultatai atskleidė uosto veiklos įtakos aplinkos oro užterštumui dinamiškumą, parodant, kad išmetamas oro teršalų kiekis yra nepastovus tiek laiko, tiek geolokacijos prasmėmis. Laivybos įtakos zonos dinamiškai kinta ir gali sukurti laikinas padidintų emisijų išmetimų vietas.
 - 3.1. Atlikus AIS duomenų integraciją į EMEP metodiką, sukurta detali emisijų įvertinimo sistema, leidžianti geriau suprasti jų pasiskirstymą uosto teritorijose ir poveikį kaimyninėms gyvenamosioms vietovėms. Klaipėdos uoste buvo įvertintos vidutinės emisijos: NO_x – 5,28 t/d., SKD – 0,52 t/d., NMLOJ – 0,22 t/d., BC – 0,064 t/d., CO_2 – 235 t/d. Skirtumas tarp maksimalių ir vidutinių emisijų buvo 37,8 %.
 - 3.2. Gautos vidutinės laivų emisijos uoste yra artimos kitų tyrėjų rezultatams, kai uostas buvo vertinamas kaip vienas šaltinis, tačiau vertinant detaliai nustatyta, kad emisijų išmetimo vietos nėra tolygios. Pritaikant tą pačią metodiką dyzelinių generatorių energijos suvartojimo krantinėse įvertinimui, buvo pateikta įžvalga apie krantines, kuriose sunaudojama daugiausia energijos, taip pat apie vidutinį ir maksimalų laivų energijos suvartojimą uoste, nustatant galimus tikslus CO_2 ir kitiems teršalams mažinti.
 - 3.3. Pasiūlyta metodika leidžia detaliai įvertinti oro teršalus ir CO_2 emisijas bei energijos sunaudojimą krantinėje, daryti vertingas įžvalgas apie emisijų karštuosius taškus ir mažinimo potencialus.

Bendrosios išvados

Disertacijoje analizuojama plati mokslinių darbų tematika, vertinant laivybos veiklos įtaką aplinkos oro užterštumui. Pateikiama taikomų tyrimų metodologijų, technologijų, analizės ir modeliavimo metodų bei rezultatų vertinimo apžvalga. Identifikuoti pagrindiniai aspektai ir trūkumai, kurių pagrindu suformuluoti tyrimo tikslai ir uždaviniai. Sukurti ir išsamiai aprašyti metodologiniai sprendimai, pritaikyti tyrimo objektui – Klaipėdos valstybiniam jūrų uostui, atskleidžiant pagrindines uosto laivybos, kaip dinaminio taršos objekto, savybes bei sukuriant jų prognozavimo įrankius.

1. Sukurta kompleksinė metodika leidžia įvertinti dinaminių laivybos procesų poveikį oro taršos pasiskirstymui uosto aplinkoje, integruojant:
 - a) išsamų laivų eismo ir jų išmetamųjų teršalų įtakos oro taršai vertinimą;
 - b) detalų laivų energijos vartojimo ir emisijų kiekio palyginamąjį vertinimą, leidžiantį nustatyti efektyvumo skirtumus tarp skirtingų laivų tipų;
 - c) neuroniniais tinklais paremtą prognozavimo modelį, leidžiantį numatyti teršalų koncentracijų kitimą priklausomai nuo laivybos intensyvumo.

Ši metodika sudaro prielaidas detalesniam ir dinamiškam laivybos įtakos oro taršai vertinimui uostų teritorijose ir gali būti taikoma planuojant taršos mažinimo priemones.

Ši metodika sudaro galimybes detaliau vertinti dinamišką laivybos įtaką oro taršai uosto teritorijose ir gali būti taikoma planuojant taršos mažinimo priemones.

2. Atlikta detali laivų eismo ir išmetamųjų dujų šleifų uoste analizė. Įvertinta laivų išmetamųjų dujų šleifo įtaka aplinkos oro kokybei analizuojamoje vietoje ir per laivo plaukimą uoste. Vidutinis laivo greitis uoste siekė nuo 0,2 iki 25 km/h. Laivo išmetamųjų dujų poveikio viename tyrimų taške trukmę sudaro iki 11,26 min., o kietųjų dalelių koncentracija išmetamųjų dujų šleife sudaro nuo 5,2 iki 43,84 $\mu\text{g}/\text{m}^3$, priklausomai nuo laivo tipo.
3. Neuroniniais tinklais paremto oro taršos iš uoste plaukiančių laivų prognozavimo modelio rezultatai prilygsta stacionarių taršos objektų tyrimuose taikomų sklaidos modelių tikslumui ir yra tinkami praktiniam naudojimui. Visų kietųjų dalelių frakcijų prognozavimo rezultatai iš esmės priklauso nuo meteorologinių parametrų – vėjo krypties, vėjo greičio, santykinio drėgnumo ir slėgio. Rezultatams iš laivo techninių parametrų pagrindinę įtaką daro laivo dydį nusakantys parametrai (GT, DWT, ilgis plotis ir kt.).
4. Didžiausios kietųjų dalelių koncentracijos tyrimo metu buvo nustatytos sausakrūvių laivų šleifuose. Tai būtų galima susieti su galima šių laivų dydžio įtaka. Nustatyta, kad didžiausią poveikį kietųjų dalelių (KD) koncentracijoms ore laivyba daro, kai šleifuose vyrauja smulkesnės frakcijos – KD1 ir KD2,5 dydžio dalelės (KD1 $R^2 = 0,8952$; KD2,5 $R^2 = 0,8889$). Analizuojant stambesnių dalelių frakcijas, nustatyta, kad koreliacija tarp koncentracijų ir laivybos šleifų silpnėja (KD10 $R^2 = 0,7586$; SKD $R^2 = 0,5626$).
5. Atlikus AIS duomenų integraciją į EMEP metodiką, sukurta detali emisijų įvertinimo sistema, leidžianti geriau suprasti jų pasiskirstymą uosto teritorijose ir poveikį kaimyninėms gyvenamosioms vietovėms. Galima įvertinti uosto aplinkos taršos kitimą laike ir detaliai įvertinti skirtingus uosto teritorijos segmentus. Taršos kitimo laiko atžvilgiu vertinimas leidžia nustatyti, ar susidariusi tarša susijusi su krovos darbais, ar su laivų eismo intensyvumu. Emisijų laivybos uoste skirtumai tarp atskirų krantinių gali skirtis iki 20 kartų, o suminės paros teršalų emisijų dydis iš laivų gali skirtis iki 20 %.
6. Siekiant efektyviau valdyti laivų taršos poveikį, rekomenduojama derinti EMEP metodiką su neuroninių tinklų modeliais, kurie gali tiksliau įvertinti taršos pasiskirstymą ir identifikuoti labiausiai paveiktas zonas. Tokiu būdu galima priimti tikslingesnius aplinkosaugos sprendimus, mažinti oro taršą uostuose bei gerinti vietos gyventojų sveikatos apsaugą. Neuroninių tinklų modelių taikymas leistų ne tik sudaryti kiekvieno laivo taršos poveikio reitingą, bet ir optimizuoti uosto veiklą, siekiant sumažinti didelės taršos zonas ir jų neigiamą poveikį aplinkai bei žmonėms.

Rekomendacijos

Remiantis disertacinio darbo rezultatais, pateikiamos rekomendacijos tolesniems taršos iš uoste eksploatuojamų laivų vertinimo tyrimams vykdyti bei metodikai tobulinti:

- Laivyboje naudojamų variklių taktiškumas turi didelę įtaką teršalų išmetimams (pavyzdžiui, dvitakčių ir keturtakčių variklio išmetimai reikšmingai skiriasi). Duomenys apie variklių taktiškumą ne visada prieinami, todėl šis parametras kuriant ir apmokant modelį nebuvo panaudotas. Parametrą įtraukti į modelio kūrimo ir apmokymo procesą galima, tačiau tai susiaurintų modelio panaudojimo galimybes. Ateityje galima būtų formuoti kelių modelių kompleksą, kuris kistų priklausomai nuo prieinamų duomenų pasirinktu momentu.
- Disertaciniame darbe yra vertinama uoste eksploatuojamų laivų tarša tik horizontalioje plokštumoje. Tačiau taršos rezultatams gali turėti ir vertikalios plokštumos parametrai, tokie kaip laivo kamino (išmetimo šaltinio) aukštis. Tolesniuose tyrimuose bei modelio tobulinimo procese rekomenduojama įvertinti laivų kamino aukštį ir teršalų pasiskirstymą vertikalioje plokštumoje.
- Tolesniuose tyrimuose rekomenduojama papildomai įvertinti ir aplinkosauginius parametrus skirtingais metų laikotarpiais.

Literatūra ir šaltiniai

- Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M., & Inman, D. J. (2017). Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks. *Journal of Sound and Vibration*, 388, 154–170. <https://doi.org/10.1016/j.jsv.2016.10.043>
- Abrutytė, E., Žukauskaitė, A., Mickevičienė, R., Zabukas, V., & Paulauskienė, T. (2014). Evaluation of NOx emission and dispersion from marine ships in Klaipėda sea port. *Journal of Environmental Engineering and Landscape Management*, 10. <http://dx.doi.org/10.3846/16486897.2014.892009>
- ACML. (2024). *IHS Fairplay*. <https://www.acml-egypt.com/Fairplay.html>
- Adedeji, B. P., & Kabir, G. (2023). A feedforward deep neural network for predicting the state-of-charge of lithium-ion battery in electric vehicles. *Decision Analytics Journal*, 8, 100255. <https://doi.org/10.1016/j.dajour.2023.100255>
- Admon, M. R., Senu, N., Ahmadian, A., Majid, Z. A., & Salahshour, S. (2024). A new modern scheme for solving fractal–fractional differential equations based on deep feedforward neural network with multiple hidden layer. *Mathematics and Computers in Simulation*, 218, 311–333. <https://doi.org/10.1016/j.matcom.2023.11.002>
- Aeroqual. (2024). *AQM 65 Ambient Air Monitoring Station*. <https://www.aeroqual.com/products/aqm-stations/aqm-65-air-quality-monitoring-station#specifications>

- AirSensEUR. (2019). *Air Quality Monitoring Open Framework*. AirSensEUR — Open Framework for Air Quality Monitoring. <https://airsenseur.org/website/airsenseur-air-quality-monitoring-open-framework/>
- Aliabadi, A. A., Thomas, J. L., Herber, A. B., Staebler, R. M., Leaitch, W. R., Schulz, H., Law, K. S., Marelle, L., Burkart, J., Willis, M. D., Bozem, H., Hoor, P. M., Köllner, F., Schneider, J., Levasseur, M., & Abbatt, J. P. D. (2016). Ship emissions measurement in the Arctic by plume intercepts of the Canadian Coast Guard ice-breaker Amundsen from the Polar 6 aircraft platform. *Atmospheric Chemistry and Physics*, 16(12), 7899–7916. <https://doi.org/10.5194/acp-16-7899-2016>
- Alver, F., Saraç, B. A., & Alver Şahin, Ü. (2018). Estimating of shipping emissions in the Samsun Port from 2010 to 2015. *Atmospheric Pollution Research*, 9(5), 822–828. <https://doi.org/10.1016/j.apr.2018.02.003>
- Anand, A., Wei, P., Gali, N. K., Sun, L., Yang, F., Westerdahl, D., Zhang, Q., Deng, Z., Wang, Y., Liu, D., Shen, Y., Fu, Q., Liu, J., Zhang, C., Ho, A. M. H., Louie, P., Lau, B. L., & Ning, Z. (2020). Protocol development for real-time ship fuel sulfur content determination using drone based plume sniffing microsensor system. *Science of the Total Environment*, 744, 140885. <https://doi.org/10.1016/j.scitotenv.2020.140885>
- Artelnics. (2023, August 31). Machine learning tutorial: Neural network. *Neural Designer*. <https://www.neuraldesigner.com/learning/tutorials/neural-network/>
- Ashworth, D. C., Fuller, G. W., Toledano, M. B., Font, A., Elliott, P., Hansell, A. L., & De Hoogh, K. (2013). Comparative Assessment of Particulate Air Pollution Exposure from Municipal Solid Waste Incinerator Emissions. *Journal of Environmental and Public Health*, 2013, 1–13. <https://doi.org/10.1155/2013/560342>
- Bacalja, B., Krčum, M., & Slišković, M. (2020). A line ship emissions while manoeuvring and hotelling—A case study of port split. *Journal of Marine Science and Engineering*, 8(11), 1–18. <https://doi.org/10.3390/jmse8110953>
- BalticShipping. (2024). *Ship database | Find vessed details by name or IMO number | BalticShipping.com*. <https://www.balticshipping.com/vessels>
- Balzani Lööv, J. M., Alfoldy, B., Gast, L. F. L., Hjorth, J., Lagler, F., Mellqvist, J., Beecken, J., Berg, N., Duyzer, J., Westrate, H., Swart, D. P. J., Berkhout, A. J. C., Jalkanen, J. P., Prata, A. J., Van Der Hoff, G. R., & Borowiak, A. (2014). Field test of available methods to measure remotely SO_x and NO_x emissions from ships. *Atmospheric Measurement Techniques*, 7(8), 2597–2613. <https://doi.org/10.5194/amt-7-2597-2014>
- Beecken, J. (2015). *Remote Measurements of Gas and Particulate Matter Emissions from Individual Ships*.
- Beecken, J., Mellqvist, J., Salo, K., Ekholm, J., Jalkanen, J. P., Johansson, L., Litvinenko, V., Volodin, K., & Frank-Kamenetsky, D. A. (2015). Emission factors of SO₂, NO_x and particles from ships in Neva Bay from ground-based and helicopter-borne measurements and AIS-based modeling. *Atmospheric Chemistry and Physics*, 15(9), 5229–5241. <https://doi.org/10.5194/acp-15-5229-2015>

- Bergqvist, R., & Monios, J. (2019). Green Ports in Theory and Practice. In *Green Ports* (pp. 1–17). Elsevier. <https://doi.org/10.1016/B978-0-12-814054-3.00001-3>
- Boersma, K. F., Vinken, G. C. M., & Tournadre, J. (2015). Ships going slow in reducing their NO_x emissions: Changes in 2005–2012 ship exhaust inferred from satellite measurements over Europe. *Environmental Research Letters*, 10(7). <https://doi.org/10.1088/1748-9326/10/7/074007>
- Burgués, J., & Marco, S. (2020). Environmental chemical sensing using small drones: A review. *Science of the Total Environment*, 748, 141172. <https://doi.org/10.1016/j.scitotenv.2020.141172>
- Carlo Trozzi, R. D. L., & Contributing. (2019). *EMEP/EEA International maritime*. I.A.3(01), 1–42.
- Chen, D., Zhao, Y., Nelson, P., Li, Y., Wang, X., Zhou, Y., Lang, J., & Guo, X. (2016). Estimating ship emissions based on AIS data for port of Tianjin, China. *Atmospheric Environment*, 145, 10–18. <https://doi.org/10.1016/j.atmosenv.2016.08.086>
- Cheng, Y., Wang, S., Zhu, J., Guo, Y., Zhang, R., Liu, Y., Zhang, Y., Yu, Q., Ma, W., & Zhou, B. (2019). Surveillance of SO₂ and NO₂ from ship emissions by MAX-DOAS measurements and the implications regarding fuel sulfur content compliance. *Atmospheric Chemistry and Physics*, 19(21), 13611–13626. <https://doi.org/10.5194/acp-19-13611-2019>
- Chu-Van, T., Ristovski, Z., Pourkhesalian, A. M., Rainey, T., Garaniya, V., Abbassi, R., Jahangiri, S., Enshaei, H., Kam, U. S., Kimball, R., Yang, L., Zare, A., Bartlett, H., & Brown, R. J. (2018). On-board measurements of particle and gaseous emissions from a large cargo vessel at different operating conditions. *Environmental Pollution*, 237, 832–841. <https://doi.org/10.1016/j.envpol.2017.11.008>
- Colarossi, D., Lelow, G., & Principi, P. (2022). Local energy production scenarios for emissions reduction of pollutants in small-medium ports. *Transportation Research Interdisciplinary Perspectives*, 13, 100554. <https://doi.org/10.1016/j.trip.2022.100554>
- College, A. M. (2016). *Development of a Methodology to Measure and Assess Ship Emissions Theme*.
- Cordova, C. H., Portocarrero, M. N. L., Salas, R., Torres, R., Rodrigues, P. C., & López-Gonzales, J. L. (2021). Air quality assessment and pollution forecasting using artificial neural networks in Metropolitan Lima-Peru. *Scientific Reports*, 11(1), 24232. <https://doi.org/10.1038/s41598-021-03650-9>
- Dėl Lietuvos Respublikos susisiekimo ministro 2008 m. rugšėjo 10 d. įsakymo Nr. 3-327 „Dėl Klaipėdos valstybinio jūrų uosto laivybos taisyklių patvirtinimo“ pakeitimo, Nr. 3-708 (2020). <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/935bcc922dcbb1eb8c97e01ffe050e1c>
- Ding, J., van der A, R. J., Mijling, B., Jalkanen, J. P., Johansson, L., & Levelt, P. F. (2018). Maritime NO_x Emissions Over Chinese Seas Derived From Satellite

- te Observations. *Geophysical Research Letters*, 45(4), 2031–2037. <https://doi.org/10.1002/2017GL076788>
- Dodla, V. B. R., Gubbala, C. S., & Desamsetti, S. (2017). Atmospheric Dispersion of PM_{2.5} Precursor Gases from Two Major Thermal Power Plants in Andhra Pradesh, India. *Aerosol and Air Quality Research*, 17(2), 381–393. <https://doi.org/10.4209/aaqr.2016.07.0294>
- El-Taybany, A., Moustafa, M. M., Mansour, M., & Tawfik, A. A. (2019). Quantification of the exhaust emissions from seagoing ships in Suez Canal waterway. *Alexandria Engineering Journal*, 58(1), 19–25. <https://doi.org/10.1016/j.aej.2018.11.016>
- EMEP. (2013). EMEP/EEA air pollutant emission inventory guidebook 2013: Technical guidance to prepare national emission inventories. *EEA Technical Report*, 12/2013, 23.
- European Commission. (2020). *Amended proposal for a REGULATION OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL on establishing the framework for achieving climate neutrality and amending Regulation (EU) 2018/1999 (European Climate Law)*. COM(2020) 563 final. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52020PC0563>
- European Commission. (2023a). *Fourth Annual Report from the European Commission on CO₂ Emissions from Maritime Transport (period 2018-2021)* (Full-Length Report {C(2023) 1585 final}; Report from the Commission, p. 74). European Commission. https://climate.ec.europa.eu/system/files/2023-03/swd_2023_54_en.pdf
- European Commission. (2023b, October 9). Commission welcomes completion of key ‘Fit for 55’ legislation, putting EU on track to exceed 2030 targets. *European Commission - Press Release*, 3.
- European Environment Agency. (2019). *EMEP/EEA air pollutant emission inventory guidebook 2019: Technical guidance to prepare national emission inventories*. Publications Office. <https://data.europa.eu/doi/10.2800/293657>
- European Maritime Safety Agency. (2022). *COVID-19 – impact on shipping* (p. 23) [Report]. EMSA. <https://emsa.europa.eu/newsroom/covid19-impact/item/4795-july-2022-covid-19-impact-on-shipping-report.html>
- Explainable AI Platform | Neural Designer*. (n.d.). Retrieved June 10, 2022, from <https://www.neuraldesigner.com/>
- Explicit ApS. (2018). *Airborne Monitoring of Sulphur Emissions from Ships in Danish Waters. 2001*, 1–30.
- Exponent, Inc. (2022). *Official CALPUFF Modeling System*. CALPUFF Modeling System. <https://www.src.com/>
- Eyring, V., Isaksen, I. S. A., Berntsen, T., Collins, W. J., Corbett, J. J., Endresen, O., Grainger, R. G., Moldanova, J., Schlager, H., & Stevenson, D. S. (2010). Transport impacts on atmosphere and climate: Shipping. *Atmospheric Environment*, 44(37), 4735–4771. <https://doi.org/10.1016/j.atmosenv.2009.04.059>

- Fuentes García, G., Sosa Echeverría, R., Baldasano Recio, J. M., W. Kahl, J. D., Granados Hernández, E., Alarcón Jiménez, A. L., & Antonio Durán, R. E. (2021). Atmospheric Emissions in Ports Due to Maritime Traffic in Mexico. *Journal of Marine Science and Engineering*, 9(11), 1186. <https://doi.org/10.3390/jmse9111186>
- Fuller, R., Landrigan, P. J., Balakrishnan, K., Bathan, G., Bose-O'Reilly, S., Brauer, M., Caravanos, J., Chiles, T., Cohen, A., Corra, L., Cropper, M., Ferraro, G., Hanna, J., Hanrahan, D., Hu, H., Hunter, D., Janata, G., Kupka, R., Lanphear, B., ... Yan, C. (2022). Pollution and health: A progress update. *The Lancet Planetary Health*, 6(6), e535–e547. [https://doi.org/10.1016/S2542-5196\(22\)00090-0](https://doi.org/10.1016/S2542-5196(22)00090-0)
- Garmin Ltd. (2017). *ECHOMAP™ Plus Naudotojo vadovas*.
- Gavalas, D., Syriopoulos, T., & Tsatsaronis, M. (2022). COVID–19 impact on the shipping industry: An event study approach. *Transport Policy*, 116, 157–164. <https://doi.org/10.1016/j.tranpol.2021.11.016>
- Goldsworthy, L., & Goldsworthy, B. (2015). Modelling of ship engine exhaust emissions in ports and extensive coastal waters based on terrestrial AIS data—An Australian case study. *Environmental Modelling and Software*, 63, 45–60. <https://doi.org/10.1016/j.envsoft.2014.09.009>
- GRAL, R. (2023, March 15). *Graz Lagrangian Model*. <https://gral.tugraz.at/>
- Hensel, T., Ugé, C., & Jahn, C. (2020). Green shipping: Using AIS data to assess global emissions. *Sustainability Management Forum | NachhaltigkeitsManagement-Forum*, 28(1–2), 39–47. <https://doi.org/10.1007/s00550-020-00498-x>
- Huang, L., Wen, Y., Geng, X., Zhou, C., & Xiao, C. (2018). Integrating multi-source maritime information to estimate ship exhaust emissions under wind, wave and current conditions. *Transportation Research Part D: Transport and Environment*, 59(January), 148–159. <https://doi.org/10.1016/j.trd.2017.12.012>
- Huang, L., Wen, Y., Geng, X., Zhou, C., Xiao, C., & Zhang, F. (2017). Estimation and spatio-temporal analysis of ship exhaust emission in a port area. *Ocean Engineering*, 140(October 2016), 401–411. <https://doi.org/10.1016/j.oceaneng.2017.06.015>
- Ibrahim, R. A., Elsheikh, A. H., Elasyed Abd Elaziz, M., & Al-qaness, M. A. A. (2022). Basics of artificial neural networks. In *Artificial Neural Networks for Renewable Energy Systems and Real-World Applications* (pp. 1–10). Elsevier. <https://doi.org/10.1016/B978-0-12-820793-2.00002-1>
- IEA. (2023). *Distribution of carbon dioxide emissions produced by the transportation sector worldwide in 2022, by sub sector [Graph]*. In Statista. Statista. <https://www.statista.com/statistics/1185535/transport-carbon-dioxide-emissions-breakdown/>
- International Maritime Organization. (1973). *International Convention for the Prevention of Pollution from Ships (MARPOL)*. [https://www.imo.org/en/About/Conventions/Pages/International-Convention-for-the-Prevention-of-Pollution-from-Ships-\(MARPOL\).aspx](https://www.imo.org/en/About/Conventions/Pages/International-Convention-for-the-Prevention-of-Pollution-from-Ships-(MARPOL).aspx)

- International Maritime Organization. (2004). *SOLAS, Consolidated Edition, 2004: Consolidated Text of the International Convention for the Safety of Life at Sea, 1974, and Its Protocol of 1988: Articles, Annexes and Certificates* (4th ed.). International Maritime Organization. <https://books.google.lt/books?id=qJsTAAAYAAJ>
- International Maritime Organization. (2021). *Fourth IMO Greenhouse Gas Study*. International Maritime Organization. <https://www.wcdn.imo.org/localresources/en/OurWork/Environment/Documents/Fourth%20IMO%20GHG%20Study%202020%20-%20Full%20report%20and%20annexes.pdf>
- Isakov, V., Barzyk, T., Arunachalam, S., Naess, B., Seppanen, C., Monteiro, A., & Sorte, S. (2017). Web-based air quality screening tool for near-port assessments: Example of application in porto, portugal. *HARMO 2017 - 18th International Conference on Harmonisation within Atmospheric Dispersion Modelling for Regulatory Purposes, Proceedings, 2017-October(x)*, 258–262. <https://doi.org/10.1016/j.envsoft.2017.09.004>
- Jahangiri, S., Nikolova, N., & Tenekedjiev, K. (2018). An improved emission inventory method for estimating engine exhaust emissions from ships. *Sustainable Environment Research*, 28(6), 374–381. <https://doi.org/10.1016/j.serj.2018.08.005>
- Jalkanen, J. P., Brink, A., Kalli, J., Pettersson, H., Kukkonen, J., & Stipa, T. (2009). A modelling system for the exhaust emissions of marine traffic and its application in the Baltic Sea area. *Atmospheric Chemistry and Physics*, 9(23), 9209–9223. <https://doi.org/10.5194/acp-9-9209-2009>
- Jalkanen, J. P., Johansson, L., Kukkonen, J., Brink, A., Kalli, J., & Stipa, T. (2012). Extension of an assessment model of ship traffic exhaust emissions for particulate matter and carbon monoxide. *Atmospheric Chemistry and Physics*, 12(5), 2641–2659. <https://doi.org/10.5194/acp-12-2641-2012>
- Johansson, L., Jalkanen, J. P., Kalli, J., & Kukkonen, J. (2013). The evolution of shipping emissions and the costs of regulation changes in the northern EU area. *Atmospheric Chemistry and Physics*, 13(22), 11375–11389. <https://doi.org/10.5194/acp-13-11375-2013>
- Johansson, L., Jalkanen, J. P., & Kukkonen, J. (2017). Global assessment of shipping emissions in 2015 on a high spatial and temporal resolution. *Atmospheric Environment*, 167(January), 403–415. <https://doi.org/10.1016/j.atmosenv.2017.08.042>
- Jurdana, I., Krylov, A., & Yamnenko, J. (2020). Use of artificial intelligence as a problem solution for maritime transport. *Journal of Marine Science and Engineering*, 8(3). <https://doi.org/10.3390/jmse8030201>
- Kapitänleutnant Torsten Kowitz. (2022). *Marinekommando Jahresbericht 2022. Fakten und Zahlen zur maritimen Abhängigkeit der Bundesrepublik Deutschland* (p. 194) [Annual report]. Marine Flottenkommando. <https://www.bundeswehr.de/resource/blob/5522472/ab53f3a657a4a5174151c3fe03295545/jahresbericht-2022-data.pdf>

- Karagianidis, P., Themelis, N., Zaraphonitis, G., Spandonidis, C., & Giordamlis, C. (2019). Ship Fuel Consumption Prediction using Artificial Neural Networks. *13th Conf. Hellenic Institute of Marine Technology*, November, 70–78.
- Kim, Y., & Jung, M. (2021). *Development of a Fuel Consumption Prediction Model Based on Machine Learning Using Ship In-Service Data*.
- Klaipėdos miesto savivaldybės Aplinkos oro kokybės valdymo programa 2020–2023 m. (2020).
- Klaipėdos valstybinio jūrų uosto direkcija. (2022). *Klaipėdos valstybinio jūrų uosto Žaliojo uosto koncepcija* [Report].
- Klaipėdos valstybinio jūrų uosto Žaliojo uosto koncepcija. (2021).
- Kura, B., & Jilla, A. (2019). Feasibility of the inverse-dispersion model for quantifying drydock emissions. *Atmosphere*, 10(6), 1–15. <https://doi.org/10.3390/atmos10060328>
- Kwon, Y., Lim, H., Lim, Y., & Lee, H. (2019). Implication of activity-based vessel emission to improve regional air inventory in a port area. *Atmospheric Environment*, 203(June), 262–270. <https://doi.org/10.1016/j.atmosenv.2019.01.036>
- Leadbetter, S. J., Andronopoulos, S., Bedwell, P., Chevalier-Jabet, K., Geertsema, G., Gering, F., Hamburger, T., Jones, A. R., Klein, H., Korsakissok, I., Mathieu, A., Pázmándi, T., Périllat, R., Rudas, Cs., Sogachev, A., Szántó, P., Tomas, J. M., Twenhöfel, C., De Vries, H., & Wellings, J. (2020). Ranking uncertainties in atmospheric dispersion modelling following the accidental release of radioactive material. *Radioprotection*, 55, S51–S55. <https://doi.org/10.1051/radiopro/2020012>
- Li, Y., Zhang, Y., Cheng, J., Zheng, C., Li, M., Xu, H., Wang, R., Chen, D., Wang, X., Fu, X., Zhao, Y., Wu, R., Yang, X., & Shi, L. (2022). Comparative Analysis, Use Recommendations, and Application Cases of Methods for Develop Ship Emission Inventories. *Atmosphere*, 13(8), 1224. <https://doi.org/10.3390/atmos13081224>
- Lietuvos transporto saugos administracija. (2023, December 4). *Plaukiojimas uosto teritorijoje ir jūroje—Lietuvos transporto saugos administracija*. <https://ltsa.lrv.lt/lt/veiklos-sritys/eismo-sauga/vandens-transportas-1/plaukiojimas-uosto-teritorijoje-ir-juroje/>
- Lonati, G., Cernuschi, S., & Sidi, S. (2010). Air quality impact assessment of at-berth ship emissions: Case-study for the project of a new freight port. *Science of the Total Environment*, 409(1), 192–200. <https://doi.org/10.1016/j.scitotenv.2010.08.029>
- Lushi, E., & Stockie, J. M. (2010). An inverse Gaussian plume approach for estimating atmospheric pollutant emissions from multiple point sources. *Atmospheric Environment*, 44(8), 1097–1107. <https://doi.org/10.1016/j.atmosenv.2009.11.039>
- Makarevičiene, V., Lebedevas, S., Rapalis, P., Gumbyte, M., Skorupskaite, V., & Žaglinskis, J. (2014). Performance and emission characteristics of diesel fuel containing microalgae oil methyl esters. *Fuel*, 120. <https://doi.org/10.1016/j.fuel.2013.11.049>

- Marine Flottenkommando. (2022, November 8). *Number of ships in the world merchant fleet as of January 1, 2022, by type [Graph]*. In Statista. Statista. <https://www.statista.com/statistics/264024/number-of-merchant-ships-worldwide-by-type/>
- Marine MAN Ltd. (2021). *Marine MAN Ltd*® – Crewing Services Provider. <https://ships.jobmarineman.com>
- Martina, M., & Trini Castelli, S. (2023). Modelling the Potential Long-Range Dispersion of Atmospheric Microplastics Reaching a Remote Site. *Atmospheric Environment*, 312, 120044. <https://doi.org/10.1016/j.atmosenv.2023.120044>
- Merico, E., Donato, A., Gambaro, A., Cesari, D., Gregoris, E., Barbaro, E., Dinoi, A., Giovanelli, G., Masieri, S., & Contini, D. (2016). Influence of in-port ships emissions to gaseous atmospheric pollutants and to particulate matter of different sizes in a Mediterranean harbour in Italy. *Atmospheric Environment*, 139, 1–10. <https://doi.org/10.1016/j.atmosenv.2016.05.024>
- Merico, E., Gambaro, A., Argiriou, A., Alebic-Juretic, A., Barbaro, E., Cesari, D., Chasapidis, L., Dimopoulos, S., Dinoi, A., Donato, A., Giannaros, C., Gregoris, E., Karagiannidis, A., Konstandopoulos, A. G., Ivošević, T., Liora, N., Melas, D., Mifka, B., Orlić, I., ... Contini, D. (2017). Atmospheric impact of ship traffic in four Adriatic-Ionian port-cities: Comparison and harmonization of different approaches. *Transportation Research Part D: Transport and Environment*, 50, 431–445. <https://doi.org/10.1016/j.trd.2016.11.016>
- Millefiori, L. M., Braca, P., Zissis, D., Spiliopoulos, G., Marano, S., Willett, P. K., & Carniel, S. (2021). COVID-19 impact on global maritime mobility. *Scientific Reports*, 11(1), 18039. <https://doi.org/10.1038/s41598-021-97461-7>
- Ministry of Environment and Food of Denmark. (2018). *Remote sensing of sulphur and particle pollution from ships – from a cost-efficient approach* (Issue 2031).
- Mollenhauer, K., & Tschöke, H. (Eds.). (2010). *Handbook of Diesel Engines*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-540-89083-6>
- Moreira, L., Vettor, R., & Soares, C. G. (2021). *Neural Network Approach for Predicting Ship Speed and Fuel Consumption*.
- Mujal-Colilles, A., Guarasa, J. N., Fonollosa, J., Llull, T., & Castells-Sanabra, M. (2022). COVID-19 impact on maritime traffic and corresponding pollutant emissions. The case of the Port of Barcelona. *Journal of Environmental Management*, 310(February), 114787. <https://doi.org/10.1016/j.jenvman.2022.114787>
- Namgung, H., & Kim, J. S. (2020). Vessel trajectory analysis in designated harbor route considering the influence of external forces. *Journal of Marine Science and Engineering*, 8(11), 1–12. <https://doi.org/10.3390/jmse8110860>
- Ng, S. K. W., Loh, C., Lin, C., Booth, V., Chan, J. W. M., Yip, A. C. K., Li, Y., & Lau, A. K. H. (2013). Policy change driven by an AIS-assisted marine emission inventory in Hong Kong and the Pearl River Delta. *Atmospheric Environment*, 76, 102–112. <https://doi.org/10.1016/j.atmosenv.2012.07.070>

- Nguyen, P.-N., Woo, S.-H., & Kim, H. (2022). Ship emissions in hotelling phase and loading/unloading in Southeast Asia ports. *Transportation Research Part D: Transport and Environment*, 105(February), 103223. <https://doi.org/10.1016/j.trd.2022.103223>
- Nunes, R. A. O., Alvim-Ferraz, M. C. M., Martins, F. G., & Sousa, S. I. V. (2017). The activity-based methodology to assess ship emissions—A review. *Environmental Pollution*, 231(x), 87–103. <https://doi.org/10.1016/j.envpol.2017.07.099>
- Orai Klaipėda – Ankstesnė orų informacija, pateikiama kiekvieną dieną|freemeteo.lt. (2020). <https://freemeteo.lt/orai/klaipeda/istorija/kiekvienos-dienos-ankstesni-duomenys/?gid=598098&station=6334&date=2022-11-27&language=lithuanian&country=lithuania>
- Port of LA. (2007). *Port of Los Angeles Inventory of Air Emissions*.
- Progiou, A. G., Bakeas, E., Evangelidou, E., Kontogiorgi, C., Lagkadinou, E., & Sebos, I. (2020a). Air pollutant emissions from Piraeus port: External costs and air quality levels. *Transportation Research Part D: Transport and Environment*, x, 102586. <https://doi.org/10.1016/j.trd.2020.102586>
- Progiou, A. G., Bakeas, E., Evangelidou, E., Kontogiorgi, C., Lagkadinou, E., & Sebos, I. (2020b). Air pollutant emissions from Piraeus port: External costs and air quality levels. *Transportation Research Part D: Transport and Environment*, x, 102586. <https://doi.org/10.1016/j.trd.2020.102586>
- Qiao, B., He, W., Tian, Y., Liu, Y., Cai, O., & Li, Y. (2017). Ship emission reduction effect evaluation of air pollution control countermeasures. *Transportation Research Procedia*, 25, 3606–3618. <https://doi.org/10.1016/j.trpro.2017.05.325>
- Rapalis, P., Žemgulis, M., & Jonika, L. (2018). Emisijų iš laivų Klaipėdos uoste nustatymo nuotoliniu būdu galimybių apžvalga. *II-Oji Nacionalinė Jūros Mokslų Ir Technologijų Konferencija JŪROS IR KRANTŲ TYRIMAI 2018, January*, 97–100.
- Raza, Z., Woxenius, J., Vural, C. A., & Lind, M. (2023). Digital transformation of maritime logistics: Exploring trends in the liner shipping segment. *Computers in Industry*, 145, 103811. <https://doi.org/10.1016/j.compind.2022.103811>
- Resolution MEPC.328(76), Pub. L. No. MEPC.328(76), MEPC 76/15/Add.1 88 (2022). [https://wwwcdn.imo.org/localresources/en/OurWork/Environment/Documents/Air%20pollution/MEPC.328\(76\).pdf](https://wwwcdn.imo.org/localresources/en/OurWork/Environment/Documents/Air%20pollution/MEPC.328(76).pdf)
- Saraçoğlu, H., Deniz, C., & Kılıç, A. (2013). An Investigation on the Effects of Ship Sourced Emissions in Izmir Port, Turkey. *The Scientific World Journal*, 2013, 218324. <https://doi.org/10.1155/2013/218324>
- Schaub, M., Baldauf, M., & Hassel, E. (2020). *Prediction of PM emissions during transient operation of marine diesel engines using artificial neural networks*. 167–174. <https://doi.org/10.11128/arep.59.a59023>
- Seinfeld, J. H. (2016). *Atmospheric Chemistry and Physics: From Air Pollution to Climate Change* (1st ed). John Wiley & Sons, Incorporated.

- Sheikh, W., Chowdhury, M. M. H., & Mahmud, K. K. (2023). A comprehensive performance measurement model for maritime Logistics: *Sustainability and policy approach. Case Studies on Transport Policy*, 14, 101097. <https://doi.org/10.1016/j.cstp.2023.101097>
- Shen, L., Hou, Y., Yang, Q., Lv, M., Dong, J.-X., Yang, Z., & Li, D. (2022). Synergistic path planning for ship-deployed multiple UAVs to monitor vessel pollution in ports. *Transportation Research Part D: Transport and Environment*, 110, 103415. <https://doi.org/10.1016/j.trd.2022.103415>
- Shen, L., Wang, Y., Liu, K., Yang, Z., Shi, X., Yang, X., & Jing, K. (2020). Synergistic path planning of multi-UAVs for air pollution detection of ships in ports. *Transportation Research Part E: Logistics and Transportation Review*, 144(March), 102128. <https://doi.org/10.1016/j.tre.2020.102128>
- Smailys, V., Rapalis, P., Strazdauskiene, R., & Ešmantaitė, V. (2013). Air pollution by NOx from ships passing Klaipėda port channel. *Transport Means - Proceedings of the International Conference*.
- Smailys, V., Strazdauskiene, R., & Bereisiene, K. (2016). *Evaluation of a Possibility to Identify Port Pollutants Trace in Klaipėda City Air Pollution Monitoring Stations*. 4(4), 66–75.
- So, R., Andersen, Z. J., Chen, J., Stafoggia, M., De Hoogh, K., Katsouyanni, K., Vienneau, D., Rodopoulou, S., Samoli, E., Lim, Y.-H., Jørgensen, J. T., Amini, H., Cole-Hunter, T., Mahmood Taghavi Shahri, S., Maric, M., Bergmann, M., Liu, S., Azam, S., Loft, S., ... Mehta, A. J. (2022). Long-term exposure to air pollution and mortality in a Danish nationwide administrative cohort study: Beyond mortality from cardiopulmonary disease and lung cancer. *Environment International*, 164, 107241. <https://doi.org/10.1016/j.envint.2022.107241>
- Sorte, S., Rodrigues, V., Borrego, C., & Monteiro, A. (2020). Impact of harbour activities on local air quality: A review. *Environmental Pollution*, 257, 113542. <https://doi.org/10.1016/j.envpol.2019.113542>
- Stockie, J. M. (2011). The Mathematics of Atmospheric Dispersion Modeling. *SIAM Review*, 53(2), 349–372. <https://doi.org/10.1137/10080991X>
- Sun, C., Wang, H., Liu, C., & Zhao, Y. (2019). Dynamic prediction and optimization of Energy Efficiency Operational Index (EEOI) for an operating ship in varying environments. *Journal of Marine Science and Engineering*, 7(11). <https://doi.org/10.3390/jmse7110402>
- Theodoropoulos, P., Spandonidis, C. C., Themelis, N., & Giordamlis, C. (2021). *Evaluation of Different Deep-Learning Models for the Prediction of a Ship's Propulsion Power*. 1–26.
- Tichavska, M., Tovar, B., Gritsenko, D., Johansson, L., & Jalkanen, J. P. (2019). Air emissions from ships in port: Does regulation make a difference? *Transport Policy*, 75(September 2015), 128–140. <https://doi.org/10.1016/j.tranpol.2017.03.003>

- Toscano, D., & Murena, F. (2019). Atmospheric ship emissions in ports: A review. Correlation with data of ship traffic. *Atmospheric Environment: X*, 4(June), 100050. <https://doi.org/10.1016/j.aeaoa.2019.100050>
- Toscano, D., Murena, F., Quaranta, F., & Mocerino, L. (2021). Assessment of the impact of ship emissions on air quality based on a complete annual emission inventory using AIS data for the port of Naples. *Ocean Engineering*, 232(February), 109166. <https://doi.org/10.1016/j.oceaneng.2021.109166>
- Truong, T. T., Lee, J., & Nguyen-Thoi, T. (2022). An effective framework for real-time structural damage detection using one-dimensional convolutional gated recurrent unit neural network and high performance computing. *Ocean Engineering*, 253, 111202. <https://doi.org/10.1016/j.oceaneng.2022.111202>
- UNCTAD. (2022). *Review of maritime transport. Navigating stormy waters*. United Nations. https://unctad.org/system/files/official-document/rmt2022_en.pdf
- United Nations Conference on Trade and Development. (2021). *REVIEW OF MARITIME TRANSPORT 2021*. United Nations.
- U.S. Environmental Protection Agency. (2023). *AERMOD Implementation Guide* (EPA-454/B-23-009; p. 38). U.S. Environmental Protection Agency. https://gaftp.epa.gov/Air/aqmg/SCRAM/models/preferred/aermod/aermod_implementation_guide.pdf
- US ICF International. (2009). *Current Methodologies in Preparing Mobile Source Port-Related Emission Inventories. Final report*.
- Vira, J., Carboni, E., Grainger, R. G., & Sofiev, M. (2017). Variational assimilation of IASI SO₂ plume height and total column retrievals in the 2010 eruption of Eyjafjallajökull using the SILAM v5.3 chemistry transport model. *Geoscientific Model Development*, 10(5), 1985–2008. <https://doi.org/10.5194/gmd-10-1985-2017>
- Wang, R., Cui, K., Sheu, H.-L., Wang, L.-C., & Liu, X. (2023). Effects of Precipitation on the Air Quality Index, PM_{2.5} Levels and on the Dry Deposition of PCDD/Fs in the Ambient Air. *Aerosol and Air Quality Research*, 23(4), 220417. <https://doi.org/10.4209/aaqr.220417>
- Wang, X., Shen, Y., Lin, Y., Pan, J., Zhang, Y., Louie, K. K. P., Li, M., & Fu, Q. (2019). Atmospheric pollution from ships and its impact on local air quality at a port site in Shanghai. *Atmospheric Chemistry and Physics*, 19(9), 6315–6330. <https://doi.org/10.5194/acp-19-6315-2019>
- WHO. (2018). *World Health Organisation. Ambient air pollution: Health impacts. WHO Global Air Quality Guidelines: Particulate Matter (PM_{2.5} and PM₁₀), Ozone, Nitrogen Dioxide, Sulfur Dioxide and Carbon Monoxide* (1st ed). (2021). World Health Organization.
- Xiao, G., Wang, T., Chen, X., & Zhou, L. (2022). Evaluation of Ship Pollutant Emissions in the Ports of Los Angeles and Long Beach. *Journal of Marine Science and Engineering*, 10(9), 1206. <https://doi.org/10.3390/jmse10091206>

- Yang, L., Zhang, Q., Zhang, Y., Lv, Z., Wang, Y., Wu, L., Feng, X., & Mao, H. (2021). An AIS-based emission inventory and the impact on air quality in Tianjin port based on localized emission factors. *Science of the Total Environment*, 783, 146869. <https://doi.org/10.1016/j.scitotenv.2021.146869>
- Yuan, H., Xiao, C., Wang, Y., Peng, X., Wen, Y., & Li, Q. (2020). Maritime vessel emission monitoring by an UAV gas sensor system. *Ocean Engineering*, 218(October), 108206. <https://doi.org/10.1016/j.oceaneng.2020.108206>
- Zhang, Y., Yang, X., Brown, R., Yang, L., Morawska, L., Ristovski, Z., Fu, Q., & Huang, C. (2017). Shipping emissions and their impacts on air quality in China. *Science of the Total Environment*, 581–582, 186–198. <https://doi.org/10.1016/j.scitotenv.2016.12.098>
- Zhang, Z., Song, C., Zhang, J., Chen, Z., Liu, M., Aziz, F., Kurniawan, T. A., & Yap, P.-S. (2023). Digitalization and innovation in green ports: A review of current issues, contributions and the way forward in promoting sustainable ports and maritime logistics. *Science of The Total Environment*, 912, 169075. <https://doi.org/10.1016/j.scitotenv.2023.169075>
- Zhao, J., Zhang, Y., Patton, A. P., Ma, W., Kan, H., Wu, L., Fung, F., Wang, S., Ding, D., & Walker, K. (2020). Projection of ship emissions and their impact on air quality in 2030 in Yangtze River delta, China. *Environmental Pollution*, 263, 114643. <https://doi.org/10.1016/j.envpol.2020.114643>
- Zhu, J., He, Y., Yang, X., & Yang, S. (2024). Ultra-short-term wind power probabilistic forecasting based on an evolutionary non-crossing multi-output quantile regression deep neural network. *Energy Conversion and Management*, 301, 118062. <https://doi.org/10.1016/j.enconman.2024.118062>
- Zou, Z., Zhao, J., Zhang, C., Zhang, Y., Yang, X., Chen, J., Xu, J., Xue, R., & Zhou, B. (2020). Effects of cleaner ship fuels on air quality and implications for future policy: A case study of Chongming Ecological Island in China. *Journal of Cleaner Production*, 267, 122088. <https://doi.org/10.1016/j.jclepro.2020.122088>

GYVENIMO APRAŠYMAS (CV)

Vardas, pavardė: Giedrius Šilas

Telefono nr.: +37061220132

El-paštas: giedrius.silas@gmail.com



Darbo patirtis	
2016 – Iki dabar	<i>Klaipėdos valstybinė kolegija</i> Įmonės veiklos sritys: švietimas, mokslinė veikla Lektorius • paskaitų, praktikumų dėstymas; vadovavimas praktikai, baigia- miesiems darbams; • dalyvavimas rengiant ir tobulinant studijų programas; • dalyvavimas atliekant taikomąją mokslo veiklą; • straipsnių skelbimas referuojamuose tarptautiniuose mokslo lei- diniuose; • vadovavimas studentų taikomajai mokslo, projektinei veiklai, rengti studentus konkursams; • bendradarbiavimas su socialiniais partneriais; • naujos laboratorinės įrangos įdarbinimas. Pasiekimai • kvalifikacijos rengiant ir publikuojant mokslinės veiklos rezulta- tus padidėjimas; • naujos laboratorinės įrangos paruošimas mokslinei veiklai.
2014 – 2017	<i>Klaipėdos universitetas jūrų tyrimų atviros prieigos centras</i> Įmonės veiklos sritys: švietimas, mokslinė veikla Laborantas • tyrimų atlikimas laboratorijoje; • tyrimų rezultatų analizė; • tyrimų rezultatų ataskaitų rengimas; • dalyvavimas mokslinėje veikloje. Pasiekimai • kvalifikacijos dirbant su laboratorine įranga padidėjimas.

Išsilavinimas	
2020 – 2025	<i>Klaipėdos Universitetas</i> Daktaro mokslo laipsnio diplomas Jūrų transporto inžinerija
2014 – 2016	<i>Klaipėdos Universitetas</i> Magistro diplomas Chemijos inžinerija
2010 – 2014	<i>Klaipėdos Universitetas</i> Bakalauro diplomas Aplinkos inžinerija
2006 – 2010	<i>Klaipėdos Žemynos gimnazija</i>
Mokymai:	✓ Laboratorinės įrangos darbo; ✓ Virtualaus mokymosi metodai ir priemonės ✓ ArcGIS for Advanced ✓ Python programavimo pagrandai.

PAPILDOMA INFORMACIJA	
Darbas kompiuteriu	• <i>MS Windows 7/8.1/10;</i> • <i>MS Office 365, Word, Excel, PowerPoint, Outlook;</i> • <i>CAD programos: Autodesk AutoCad, nanoCAD;</i> • <i>vaizdo apdorojimo programos: InfranView;</i> • <i>NeuralDesigner;</i> • <i>Anaconda, python programavimo kalbos programa.</i>
Kalbos	• Lietuvių – gimtoji; • anglų – C1.
Asmeninės savybės	• Geri organizaciniai, analitiniai gebėjimai; • atsakingumas; • sąžiningumas; • pastabumas.
Kita	B kategorijos vairuotojo pažymėjimas

Summary

1. SCIENTIFIC ANALYSIS OF SHIP POLLUTION ASSESSMENT AND THE IMPACT OF SHIP POLLUTION ON PORT AIR QUALITY

Maritime transport is an integral part of global trade, responsible for transporting about 90% of all international goods (Sheikh et al., 2023). Over the past decades, as shipping volumes have increased, the level of air pollution has significantly risen, particularly due to nitrogen oxides (NO_x), sulfur oxides (SO_x), and carbon dioxide (CO₂) emissions, which contribute to climate change and negatively affect health (Fuentes García et al., 2021; Nunes et al., 2017). During the COVID-19 pandemic, the shipping sector experienced a temporary decline, but since 2022, shipping volumes have begun to grow again, reaching pre-pandemic levels (European Maritime Safety Agency, 2022).

To address the environmental impact of shipping, international organizations such as the International Maritime Organization (IMO) have implemented stringent measures. The MARPOL Convention (International Maritime Organization, 1973) is one of the key documents regulating the amount of pollutants emitted by ships, setting strict fuel sulfur content requirements, especially in control areas such as the Baltic Sea (Nunes et al., 2017).

Atmospheric dispersion models, such as CALPUFF and AERMOD, are used to predict the spread of pollutants, but their accuracy is limited due to complex initial

data requirements and varying environmental conditions (Ashworth et al., 2013; Martina & Trini Castelli, 2023). Direct measurements of ship emissions are challenging and expensive, which is why statistical methods and artificial intelligence tools, such as artificial neural networks, are increasingly being used (Schaub et al., 2020). These networks have great potential to accurately predict pollutant emissions and fuel consumption by using real-time data from ship management systems (Kim & Jung, 2021).

The application of artificial neural networks not only allows for more accurate pollution assessments but also optimizes ship routes and fuel consumption (Jurdana et al., 2020; Moreira et al., 2021). Despite some challenges, such as the need for large data sets, these models could become one of the main tools for reducing pollution in ports and throughout the maritime transport sector. Furthermore, they can help assess the effectiveness of pollution reduction measures and contribute to a more sustainable future in the shipping industry.

Conclusions of the First Chapter

1. From a technical perspective, ships are unique because they differ in fuel quality, engine characteristics, technical condition, age, emission reduction measures, and other factors. Much of this information is not readily accessible.
2. Modern dispersion models can offer various assessment possibilities, but their use is limited due to the need for a large amount of initial data for accurate model operation. As a result, the model's calculation process becomes too lengthy for port operations, as the port environment is dynamic, with constantly changing conditions that require evaluation based on the current state. The assessment in ports is also complicated by the fact that the engines are often underutilized, and the layout and environmental conditions of port basins vary.
3. Artificial neural network models can be used for the effective assessment of ship pollution in ports because they require significantly fewer material and human resource investments. These models also allow real-time evaluation of the current situation in the port. The main disadvantage of using such methods is the need for large datasets of ship parameters, but this is well supported by the parameter monitoring and warning systems on ships, whose data is ideal for training neural networks.

2. METHODOLOGY FOR ASSESSING SHIP POLLUTION IN KLAIPĖDA PORT

Based on the conducted research, two methodologies were developed: integration of AIS (Automatic Identification System) data into the Cooperative Programme for Monitoring and Evaluation of the Long-Range Transmission of Air Pollutants in Europe (EMEP) methodology, and the creation and application of an artificial neural network model for assessing emissions from ships operating in the port.

Integrating AIS data into the EMEP methodology allows the port to be evaluated not as a single entity, but by analyzing emissions at each port quay and at any given moment. Technical ship data, including position and speed information (AIS), were used in the study and integrated into the existing EMEP methodology, enabling the assessment of total port emissions. For the development of artificial neural networks, detailed AIS and ship technical data, along with data from air pollution measurement stations, were used. During the study, changes in particulate matter concentration in the surrounding air were linked to the movement of ships, their technical characteristics, and meteorological conditions at the time. Artificial neural networks were used to establish connections between a large number of different parameters. The developed model can predict how the concentration of different fractions of particulate matter will change due to ship emissions, depending on the ship's position, its technical parameters, speed, and meteorological conditions. The research was limited to ship pollution, with pollution from the city or terminals not being assessed.

2.1. Methodology for the Development and Application of Artificial Neural Networks

Detailed AIS and ship technical data, along with data from air pollution measurement stations, were used in the study. During the research, changes in particulate matter concentrations in the surrounding air were correlated with ship movements, their technical characteristics, and meteorological conditions at the time. Artificial neural networks were used to identify relationships between a large number of different parameters. As a result, a model was developed that can predict how the concentrations of different particulate matter fractions in the environment will change, depending on the ship's position, its technical parameters, speed, and meteorological conditions. The model can also be trained to determine concentrations of gaseous pollutants (NO_x, SO_x). The data for model development were sourced from a direct measurement station located in the Klaipėda port area.

Emissions measurements were conducted at the AQM 65 measurement station. The parameters of the AQM 65 measurement station are provided in Table 1. During the study, the AQM 65 measurement station was located in the Klaipėda port area (55.705542; 21.121891).

Table 1. Parameters of the AQM 65 Measurement Station (Aeroqual, 2024)

Parameter	Accuracy	Range	Display Resolution
Profiler (Optical Particle Counter)	$<\pm 5 \mu\text{g}/\text{m}^3 + 15\%$ from measurements	PM₁ 200 $\mu\text{g}/\text{m}^3$	0,1 $\mu\text{g}/\text{m}^3$
		PM_{2.5} 2000 $\mu\text{g}/\text{m}^3$	
		PM₁₀ 5000 $\mu\text{g}/\text{m}^3$	

Particles with sizes of 1 micron (PM1), 2.5 microns (PM2.5), 10 microns (PM10), as well as the total suspended particulate matter concentration ($\mu\text{g}/\text{m}^3$) were obtained from the AQM 65 station. The particulate matter concentrations were recorded at one-minute intervals. Data from a one-year period (from 2020 to 2021) were used for the study.

For the analysis of the pollutant (PM1, PM2.5, and PM10) plume peaks emitted by ships operating in the port, a Microsoft Excel VBA code was written. The code defines the conditions under which the data were filtered, and the ship plume peak concentrations and their durations were selected. The data for peak analysis were initially filtered based on the distance from the ship to the measurement station. The data were limited to a 1 km radius from the measurement station. The filtered data were then processed using the written Microsoft Excel VBA code. The code specified that the ship plume concentration peaks should consist of at least three points. Additionally, the duration of the peak should not exceed 15 minutes. The code also included a condition to capture individual peaks, not multiple peaks at the same time (double or triple peaks were recorded as one).

The number of neurons in the artificial neural network model was selected experimentally. By increasing the total number of neurons across all perceptron layers of the neural network model, the standard deviation at each stage of the model's operation – training, validation, and testing — was checked (Figure 1).

The results showed that the optimal number of neurons in the perceptron layers was 424. Further increasing the number of neurons in the model reduced the standard deviation; however, when the model's performance was tested using a new dataset, it was found that the model encountered an overfitting problem, where it provided very good results in terms of error evaluation but performed poorly with new data.

Each ship's position (coordinates and position relative to the end of the port), speed over ground, and meteorological parameters were recorded at 1.5-minute intervals (tx). Ship technical data were sourced from the IHS Fairplay database based on the IMO number.

Summary




Fig. 1 Standard Deviation of Neural Network Model Phases as a Function of the Number of Neurons

Pollutant measurements (PM1, PM2.5, PM10) were conducted 24/7, with measurement intervals of 1 minute. Data from the period of 2020-2021 were used for model development. The time intervals for each ship's position, speed over ground, as well as meteorological parameters and pollutant measurements, were synchronized according to AIS data using linear interpolation to obtain the final dataset.

Ship technical data were taken from the IHS Fairplay World Shipping Encyclopedia. The matching of technical data with ships was based on the IMO number in both the AIS system and the IHS Fairplay database.

Meteorological data were obtained from two sources – directly measured by the station sensors and from available online archives. The data were recorded at 30-minute intervals (Freemeteo, 2020). Linear interpolation was used to determine the meteorological conditions for each minute of the AIS data.

The AIS data was provided by the Lithuanian Transport Safety Administration. The AIS data was filtered by coordinates, limiting the data to ships operating in the waters of Klaipėda Port. Ship identification parameters were used, as well as the definition of the position, speed, and direction of movement at a given time t .

For training the neural network, data and machine learning software Neural Designer (version 5.9.8) was used (Explainable AI Platform | Neural Designer, n.d.).

Summary

Table 2. Input parameters of the neuronal network model

Parameter	Measurement unit	Source
DWT	-	IHS Fairplay database (ACML, 2024) Other ship technical databases: BalticShipping, 2024 Marine MAN Ltd, 2021
GT	t	
Ship length	m	
Beam	m	
Depth	m	
Total engine power	kW	
Draft	m	
Wind speed	km/h	(Freemeteo, 2020) online meteorological data archive
Wind direction	Degrees (°)	
Pressure	mb	
Moisture	%	
Ship speed	km/h	AIS data (Lietuvos transporto saugos administracija)
Ship course over ground	Degrees (°)	
Direction	Degrees (°)	
Longitude	Degrees (°)	
Latitude	Degrees (°)	
Distance from the end of port	m	




Fig. 2 Data array used to create a model of neuronal networks algorithm

An approximation network was used, consisting of 17 input variables (Table 2) and 3 target variables, which were the concentrations of PM1, PM2.5, and PM10 ($\mu\text{g}/$

m³) measured at the AQM 65 station. The input parameters were selected to characterize the ship's size and type, allowing the neural network model to distinguish the ship's dimensions. The dataset was constructed based on the algorithm presented in Figure 2. The wind direction was chosen to ensure that the wind would carry the ship's pollutant plume toward the AQM 65 station. A data filter was applied, limiting the wind direction to between 180 and 360 degrees.

Table 3. Artificial neural network model parameters

Layer name	Number of neurons	Activation functions
Perseptron layer 1	20	Hyperbolic tangent (tahn)
Perseptron layer 2	100	Hyperbolic tangent (tahn)
Perseptron layer 3	150	Hyperbolic tangent (tahn)
Perseptron layer 4	150	Hyperbolic tangent (tahn)
Perseptron layer 5	4	Linear
Bounding layer	-	Data range

For training the artificial neural network model, a standard data distribution was used: 60% of the data for model training, 20 % for model validation, and 20 % for testing. A 5-layer neural network with 4 hyperbolic tangent (tanh) activation functions was selected (Table 3).

2.2. AIS Data Integration into EMEP Methodology

The modified EEA/EMEP methodology was used to assess ship pollution in the Klaipėda Port area. In using statistical air quality assessment models, many simplifications are often applied in ports, and longer-term assessments are commonly used, where pollutant emissions are estimated as a sum over a certain period (Nguyen et al., 2022; Progiou et al., 2020b). Such assessments are also frequently presented when developing operational strategies and evaluating the air quality of port cities (Klaipėda City Municipality Air Quality Management Program 2020-2023, 2020; Klaipėda State Seaport Green Port Concept, 2021). However, as shown by Mujal-Colilles et al. (2022), Toscano et al. (2021) and Yang et al. (2021), detailed assessments provide important insights into the localization of emissions, their changes over time, and energy consumption in the port (Colarossi et al., 2022).

The EMEP/EEA third-level air pollution assessment methodology was used (European Environment Agency, 2019). Emissions were evaluated based on the ship's technical parameters and movement (the operation performed) according to a developed algorithm (Figure 3). The engine type and other technical parameters were determined using the IHS Fairplay registry. The ship's operation was evaluated based on its speed, which was

obtained from AIS data. Calculations were made for both auxiliary and main engines during the same operations. The load factor (LF) parameter for the main and auxiliary engines was selected according to the EMEP methodology for each operation separately.




Fig. 3 Methodology for calculating emissions by integrating AIS data into EMEP/EEA Tier 3 methodology

As shown in Figure 3, the algorithm uses three datasets – IHS Fairplay data, AIS data, and EMEP data. The AIS data was sorted to include only ships in the port's water area and included the ship's position coordinates, speed, and IMO number for identification. The IHS Fairplay data block is a ship technical information database, that included the ship type, gross tonnage (GT), main engine type, number of engines, and engine power. The AIS data block provides information on the ship's activity. The EMEP data block, which includes information on the load factor, the ratio of main and auxiliary engines, pollutant emission factors, and SFOC values, was used to determine the emission factors and the main-to-auxiliary engine ratio. The ship's speed from the AIS data block was used to determine the ship's operation (maneuvering, docked) and select appropriate engine load factors. The main-to-auxiliary engine ratio, obtained from the EMEP data block, was used to determine the power of the main and auxiliary engines. Emission calculations were based on the pollutant emission factors from the EMEP data block, the time and load factor from the AIS data block, and the power of the main and auxiliary engines from the IHS Fairplay data block.

When selecting emission factors, the engine type (gas turbine, high-speed diesel, medium-speed diesel, slow-speed diesel, steam turbine) and the fuel used were considered. The IMO number was used to identify the ship's technical parameters from the IHS Fairplay database. The ship's position in the port and its speed were determined using

Summary

AIS system data. The ship's operation (maneuvering, docked) was evaluated based on its speed – if the speed was >0 m/s, it was considered a maneuvering operation, and if the speed was 0, the ship was docked. Calculations were performed for both auxiliary and main engines during the same operations. To improve accuracy, only ships with consistent data were evaluated. A data filter was applied that removed data if the time difference between data entries in the AIS dataset was greater than 4 minutes and 15 seconds.

The load factor (LF) parameter for the main (ME) and auxiliary engines (AE) was selected according to the EMEP methodology for each operation separately. The load factor for maneuvering operations was set to 50% for auxiliary engines and 20% for main engines. The LF value for ordering operations depends on the ship type. For all ships except tankers, the load factor for auxiliary engines is 40%, while for tankers, the value is 60%.

Based on the modified EMEP equations, the energy consumption, fuel, and CO₂ emissions of ships docked at the quay were evaluated. Fuel calculation was also performed based on the EMEP III-level specific fuel consumption values and applied to each ship in the port. CO₂ was calculated by considering the consumed fuel, using the EMEP specific fuel oil consumption values, then applying a typical 87% carbon content of fuel and estimating the emitted CO₂, assuming all the carbon is burned into CO₂. This was done using the modified EMEP equations.

Energy while hotelling:

$$e_H = \sum_p T_p \sum (P_e \times LF_e) \quad (1)$$

For released CO₂ amount:

$$E_{CO_2} = \sum_p T_p \sum \left(P_e \times LF_e \times SFOC_{e,j,p} \times \frac{12}{44} \times 0.87 \right) \quad (2)$$

e_H – ships at the quay of ships consumed by ships.

E_{CO_2} = the amount of CO₂ thrown throughout the trip (kg).

SFOC = specific consumption of fuel oil, kg/kWh.

LF = engine load factor (%).

P = engine power (kW).

T = time (hour).

e = category of engine (main, auxiliary).

j = engine type (slow, medium and fast diesel, gas and steam turbines).

p = different phase of travel (cruise, standing at the quay, maneuvering).

Based on the ships' AIS data, the amount of emitted pollutants was evaluated for each ship's position throughout the entire port. The pollutant emissions were then summed up for each hour of port activity and for each port quay by adding the emissions from ships docked at the quay and those passing the quay.

3. RESEARCH RESULTS

3.1. Analysis of the particulate matter of ships operating in the port of Klaipėda

For the analysis of ship pollution in Klaipėda Port, data from the AQM 65 air pollution monitoring station over a 6-month period were used. The data was filtered to ensure that only ships within a 1 km range around the monitoring station were included in the final dataset.




Fig. 4 Average peak concentrations by ship type

Upon analyzing the concentrations of pollutants – 1, 2.5, and 10 µm fraction particulate matter (PM1, PM2.5, and PM10), it was determined that the average concentrations of all three particulate fractions are lowest for container ships and highest for bulk cargo ships (Figure 4). For all ship types, except tankers, the highest concentration values are for the 10 µm particulate fraction. In the case of tankers, the highest concentration was recorded for the 2.5 µm particulate fraction.

When evaluating the emission plumes for each particulate fraction, it was found that the peaks of the PM1 and PM2.5 plumes can be easily identified. The only exception to identifying PM2.5 peaks occurred when evaluating RoRo ships. In this case, in some instances, it was not possible to accurately assess the peak concentrations, as shown in Figure 5, where double peaks or larger concentration jumps in the peaks were occasionally recorded.

This phenomenon may be influenced by the height of RoRo ships, as the pollutant plume can pass above the monitoring station, leading to incorrect assessment of the peak pollutant plume values. Additionally, RoRo ships may have exhaust gas cleaning equipment (scrubbers), which could also affect the plume assessment.

The identification of peaks in the 10 μm particulate fraction plume is more challenging, as the larger particulate sizes approach the size of particles that contribute to background concentrations, making the identification of plume peaks more difficult.




Fig. 5 RoRo type ships peaks of PM2,5

The analysis of particulate matter plume peaks from ships allows for an assessment of which ship type has the highest peak concentrations. According to the available data, the highest peak concentration for the PM1 fraction was recorded for bulk cargo ships – 66.16 $\mu\text{g}/\text{m}^3$. This type of ship also recorded the lowest peak concentration (5.14 $\mu\text{g}/\text{m}^3$) when compared to other ship types. Figure 6 presents the minimum and maximum peak concentrations of the 1 μm particulate matter plume. The greater distribution of PM1 plume peak concentrations in bulk cargo ships may be influenced by leaks on the ships, where some dry cargo could escape into the atmosphere.

Summary




Fig. 6 PM1 peak concentration distribution by ship type

In addition to peak concentration values, the minimum, maximum, and average durations of the peaks for all three particulate matter fractions (PM1, PM2.5, and PM10) were also assessed. It was found that the shortest average plume peak duration was recorded for bulk cargo ships (Figure 7): for the PM1 fraction – 6.48 min, PM2.5 – 6.4 min, and PM10 – 6.14 min. The longest particulate matter plume peak durations in the atmosphere were recorded for tankers (PM1 fraction, average duration of 11.26 min) and container ships (PM2.5 and PM10 fractions, average durations of 9.6 and 11.2 min, respectively).




Fig. 7 Average particulate matter plume peaks duration by ship type

Summary

When evaluating the maximum particulate matter concentration persistence in the plumes, it was determined that the average duration of maximum concentrations in the atmosphere across all ship types was approximately 8 minutes, regardless of the evaluated particulate fraction (PM1 – 7.73 min; PM2.5 – 7.82 min; PM10 – 8.12 min).




Fig. 8 Average and maximum ship speeds (km/h) in analyzed area (1 km radius around measurement station) by ship type

When examining the peak concentrations of ship plumes operating in the port, the ship speeds in the analyzed area (1 km around the monitoring station, Figure 8) and the entire port (Figure 9) were also evaluated. It was found that the highest maximum speed among ships operating in the port was recorded for tugboats – 24.26 km/h. The lowest maximum speed was recorded for RoRo ships – 17.22 km/h. However, when considering the average ship speeds, the highest speed (9.68 km/h) was recorded for tankers, while the lowest (0.29 km/h) was for fishing vessels.




Fig. 9 Average and maximum speeds (km/h) of ships operating in port by ship type

Summary

When analyzing the data of ships operating throughout the entire port, similar trends were observed as in the ships operating within a 1 km radius around the monitoring station. The lowest maximum and average speeds were recorded for fishing vessels – 17.78 km/h and 0.56 km/h, respectively. However, the highest values for maximum and average speeds were distinct. The highest maximum speed (24.26 km/h) was recorded for tugboats, while the highest average speed (5.07 km/h) was recorded for RoRo ships. The lower the ship's speed, the longer it takes for the ship to pass through the port to the quay, and the longer the peak concentration of its plume remains in the atmosphere. The data presented in Figures 8 and 9 indicate that the analysis of ship emission plume peaks within a 1 km radius around the monitoring station can also be applied to the entire port, as the movement patterns of ships throughout the port remain similar. The analysis of ship plume peak concentrations and durations in the port allows for an assessment of how long the peak concentrations of ship plumes remain in the atmosphere each day. It was found that the plume peak concentrations of bulk cargo ships persist the longest, while fishing vessels have the shortest durations (Figure 10). The longest average plume peak concentration duration in the atmosphere per day was recorded for PM1 at 71.3 minutes, PM2.5 at 70.41 minutes, and PM10 at 67.49 minutes. The shortest recorded average plume peak concentration duration was: PM1 – 14 minutes, PM2.5 – 14.86 minutes, and PM10 – 14.23 minutes.




Fig. 10 Average ships plume concentration peaks duration by ship type

A similar trend was observed when evaluating the peak concentrations of ship plumes. The highest maximum concentrations were recorded for bulk cargo ships (PM1 – 66.16 $\mu\text{g}/\text{m}^3$; PM2.5 – 67.58 $\mu\text{g}/\text{m}^3$) and fishing vessels (PM10 – 155.98 $\mu\text{g}/\text{m}^3$).

Summary

Meanwhile, the highest minimum concentration for all particulate fractions was recorded in the tanker plume peaks: PM1 – 19.87 $\mu\text{g}/\text{m}^3$; PM2.5 – 20.41 $\mu\text{g}/\text{m}^3$; PM10 – 21.34 $\mu\text{g}/\text{m}^3$. The maximum and minimum concentration values for the plume peaks of all ships are presented in Table 4.

Table 4. Ships plume peak concentration values per day by ship type

	Maximum ships plume peak concentration, $\mu\text{g}/\text{m}^3$			Minimum ships plume peak concentration, $\mu\text{g}/\text{m}^3$		
	PM1	PM2,5	PM10	PM1	PM2,5	PM10
RoRo	22,03	22,25	88,62	8,53	7,58	17,56
Tankers	22,19	25,50	25,79	19,87	20,41	21,34
Container ships	15,80	12,76	32,26	5,88	5,63	8,45
Bulk carriers	66,16	67,58	89,16	5,14	16,91	4,37
Tugs	42,65	39,56	88,80	14,53	14,79	4,37
Fishing vessels	59,07	60,12	155,98	14,55	16,25	4,36

In both the case of plume peak duration and peak concentration, the highest values were recorded for bulk cargo ships. This is because, during the analyzed period, most ships passing through the area on average per day were bulk cargo ships (Table 5).

Table 5. Number of ships in the port per day by ship type

	The average number of ships	Maximum number of ships	Minimum number of ships
RoRo	3	6	1
Tankers	5	10	1
Container ships	4	8	1
Bulk carriers	11	20	1
Tugs	6	8	4
Fishing vessels	2	6	1

When analyzing the relationship between the average peak concentrations and duration of ship plumes, a direct correlation was observed between peak duration and average peak concentration – as the peak duration increases, so does the average peak concentration (Figure 11). The graph shows that as the peak duration increases or decreases, the average peak concentration changes accordingly. An exceptional case is observed for fishing vessels, as their plume concentrations are typically high, but the peak duration is usually short, which causes a discrepancy from the previously mentioned correlation, as seen in the graph.

Summary




Fig. 11 Dependence between ships plume peak duration and average peak concentration

3.2. Neural network model results analysis

For the development of the artificial neural network model, the software NeuralDesigner was used, which allows for evaluating the model's performance and generating error and data correlation reports. When assessing the model's learning outcomes and the correlation of the test data, it was determined that the coefficient of determination for PM1 is 0.8952, for PM2.5 is 0.8889, and for PM10 is 0.7586 (Figures 12 to 14). Correlation was evaluated between real data from measurement station and data predicted by artificial neural networks model.




Fig. 12 Correlation between real data and neural network model forecasts of 1 μm diameter particulate matter

Summary




Fig. 13 Correlation between real data and neural network model forecasts of 2.5 μm diameter particulate matter




Fig. 14 Correlation between real data and neural network model forecasts of 10 μm diameter particulate matter

Summary

Although the results from the artificial neural network (ANN) model show that the predicted particulate matter (PM) pollution values are close to the actual data, a more detailed analysis with other datasets is needed to properly assess the model.

Figure 15 shows a segment where the model's predicted values significantly differ from the actual data. A similar pattern can be observed when analyzing the error values for each particulate matter fraction.




Fig. 15 PM1 real data and forecasting data correlation graph fragment

From Table 6, the previously mentioned phenomenon is clearly visible, where at times the model's predictions deviate significantly from the real data. The maximum percentage error for the particulate matter of all three fractions ranges from 63% to 71%, but the average percentage error does not exceed 3%. When evaluating the model's training and testing functions, it was found that the root mean square error during training is relatively small, reaching 0.175 for training and 0.233 for testing.

When analyzing the model architecture, the number of neurons that would be most effective for model development was tested. Based on the standard deviation values, it was determined that the model would perform most effectively using a 524-neuron architecture. However, during the results analysis, it was noticed that using 524 neurons leads to the occurrence of overfitting. This phenomenon occurs when the data used for training and testing shows excellent results, but when the model is presented with a new data set and the predicted results are compared to the real data, it becomes evident that the model performs very poorly in making predictions.

Summary

Table 6. Testing data errors for each particulate matter fraction

	Minimal error	Maximum error	Average error	Standard deviation
	PM1			
Absolute error	0	53,3825	1,56361	2,61044
Relative error	0	0,64489	0,0188893	0,0315356
Percentage error	0	64,489	1,88893	3,15356
	PM2,5			
Absolute error	0	53,2732	1,75063	2,6874
Relative error	0	0,633621	0,0208216	0,0319634
Percentage error	0	63,3621	2,08216	3,19634
	PM10			
Absolute error	0,000001144	154,566	3,23794	4,8947
Relative error	0,000000053	0,714507	0,0149679	0,0226265
Percentage error	0,000000529	71,4507	1,49679	2,26265

The developed artificial neural network (ANN) model allows for real-time prediction of ship wake concentrations at any location in the port for any ship. Unlike other models, this approach does not require initial data on emissions, exhaust gas temperature, chemical composition, emission rates, etc., which cannot be obtained from ships without direct measurements.

In addition to error assessment and the model's suitability for predicting pollution, the results analysis also allows for the evaluation of the interdependencies between parameters and results. During the results analysis, the dependence of output parameters on input parameters was examined (Figure 16). The importance of each parameter's influence was assessed on a scale from 0 to 1. The closer the result is to 0, the greater the likelihood that the parameter has little or no influence on the results. The closer the values are to 1, the greater the impact of the parameter on the results.

From the figure, it can be seen that the prediction results for all particulate matter fractions primarily depend on meteorological parameters – wind direction, wind speed, relative humidity, and pressure. For results based on the ship's technical parameters, the main influence comes from parameters describing the ship's size, such as the ship's length, width, Gross Tonnage (GT), deadweight (DWT), and others. Figure 17 highlights the ship's technical parameters and their impact on the results. From the figure, it is evident that the most important technical parameters are not the ship's power or speed, but rather the geometric parameters that describe its size. The greatest influence on the results comes from the ship's Gross Tonnage, while the least influence comes from the ship's draft.

Summary




Fig. 16 The significance of the importance of the input parameters of the model




Fig. 17 The significance of the importance of ship technical input parameters of the model

3.3. Dynamic Evaluation of Port Pollution Using AIS data and EMEP methodology

The Port of Klaipėda consists of 22 different terminals, and various companies operate within the port area. For this reason, the variety of ships arriving at the Port of Klaipėda is quite large. When dividing the ships into 11 groups, the highest emissions of pollutants, in terms of nitrogen oxides (NO_x), are generated by three types of ships: Ro-Ro ships (26%), container ships (24%), and bulk carriers (21%).

Following these three largest emitter groups is the “other ships” category (8%), which consists of various auxiliary, repair, and other types of vessels. The emissions from tankers and general cargo ships are similar, at 7.28% and 7.17%, respectively. The percentage of NO_x emissions from tugboats is 4%. The remaining emissions are distributed among LNG tankers, refrigerated cargo ships, and fishing vessels.

When evaluating the average daily emissions in the Port of Klaipėda from November 25, 2020, to January 9, 2021, based on the available data, the result obtained is 5.28 tons of NO_x. When comparing this result with previous studies, it is very similar to the studies conducted by the Klaipėda City Municipality in 2020 (Klaipėdos Miesto Savivaldybės Aplinkos Oro Kokybės Valdymo Programa 2020 –2023 m., 2020) and much higher than the results from the 2014 study by Abrutytė et al. (Table 8).

The difference between the study by Abrutytė et al. and others can be attributed to much older data with a lower ship traffic volume. The average and maximum emission values for all pollutants are presented in Table 8. The difference between the average and maximum calculated emissions and the emissions from studies conducted by other authors ranged from 255% to 278%, depending on the pollutant.

Table 8. Average and maximum emissions in Klaipėda port

Pollutant	Average emission	Maximum emission	Minimum emission	Average emission*	Average emission**
Nitrogen oxides (NO _x), t/d	5,28	7,64	2,74	2,59	5,06
Total suspended particles (TSP), t/d	0,52	0,74	0,29	-	0,3
Non methane volatile compounds (NMVOC), t/d	0,22	0,32	0,12	-	0,311
Black carbon, t/d	0,064	0,0095	0,0033	-	-
Carbon dioxide (CO ₂), t/d	235	341	125	-	-
Energy, kWh	371603	545076	197517	-	-

* – Abrutytė et al. research

** – In a study of Klaipėda City Municipality

Summary

The energy generated by ships' generators and its distribution in the port during the period from November 25, 2020, to January 9, 2021, is evenly distributed. With a minimum energy amount of 197,518 kWh, the maximum consumption value was 545,076 kWh of energy per day, corresponding to 340 tons of CO₂ per day (Figure 18).



Fig. 18 Ship generators produced energy and CO₂ emissions and their distribution in time

The spread of emissions also depends on the distribution of emission intensity across the port terminals. When emissions were allocated to the Klaipėda port quays, it was found that emissions were higher at Quays 1, 54–57, and 127–128, where tankers (Quay 1), general cargo ships (Quays 54–57), and Ro-Ro ships (Quays 127–128) were being loaded/unloaded. The distribution of emissions over time at these quays, where emissions tended to be the highest, reached up to 1.24 and 1.07 tons per day, respectively. When comparing these values with the average NO_x emissions at the port (5.28 tons of NO_x per day), up to 20 % of pollutant emissions on certain days can be emitted in one location (Figures 19 and 20).




Fig. 19 Distribution of emissions in 1 - 90 port quays

Summary




Fig. 20 Distribution of emissions in 91 - 142 port quays

The maximum emissions at Quays 127–128 (55.658357; 21.155559) were 1.24 tons per day, while at Quay No. 1 (55.726619; 21.093111), they were 1.18 tons per day of NO_x (Figure 21). It is important to note that although the average ship emissions at the port were approximately 5.28 tons per day, under suitable conditions, 20 % of all emissions from ships can be concentrated at one or another quay in the port. This is very important when assessing the port's impact and emission dispersion, as well as when planning air pollution monitoring stations.




Fig. 21 Distribution of daily NO_x emissions in the first and 127-128 port quays

Using the Port of Klaipėda as an example, three locations in the port were identified where emissions were significantly higher due to more intensive ship traffic and the technical characteristics of the ships. It was found that although the average ship

emissions at the port were approximately 5.28 tons per day, under suitable conditions, 20% of all ship emissions could be concentrated at one quay. Such peak emissions, although temporary, can be a significant source of pollution in nearby residential areas. The average daily energy consumption and CO₂ emissions at the quay during the analyzed period ranged from 500 to 5000 kWh and from 120 to 350 tons of CO₂, respectively, per quay. While this assessment has limitations due to the lack of precise data on auxiliary engine power and load, it provides a good understanding of the potential energy consumption and the evaluation of possible CO₂ reduction opportunities for the entire port or on a per-quay basis.

3.4. Third chapter conclusions

1. A detailed analysis of vessel traffic and exhaust gas plumes in the port was carried out. The average intensity of vessel traffic was determined according to ship type, considering the number of ships and their average speed, as well as the impact of vessel exhaust gas plumes on the environment at the analyzed location and during the vessel's passage through the port. The results of the study showed that the average vessel speed ranged from 0.2 to 25 km/h. Peak concentrations of vessel exhaust gas plumes ranged from 5.2 to 43.84 µg/m³, and the impact at the analyzed location lasted from 6.14 to 11.26 minutes. Peak analysis indicated that to accurately assess the air pollution in the port environment, it is essential not only to analyze pollutant emissions but also to identify areas where air quality is most affected. An environmental air pollution indicator is needed to help identify the port zones with the greatest impact. A neural network (NN) model enables the creation of such a ranking, which can be used in conjunction with the EMEP methodology. The application of the NN model with the EMEP methodology would allow not only for assessing direct emissions from ships but also for identifying the zones with the greatest impact. This would provide the opportunity to apply targeted measures for pollution reduction in port operations planning.
2. When evaluating the model's learning results and the test data errors, it was found that the determination coefficient for PM1 (KD1) is 0.8952, PM2.5 (KD2.5) is 0.8889, and PM10 (KD10) is 0.77. The test errors are well represented by the Gaussian distribution model. The maximum percentage error for all three particulate matter fractions ranges from 63% to 71%, but the average percentage error does not exceed 3%.
3. The results of the studies revealed the dynamic impact of port activities on environmental air pollution, showing that the amount of emitted air pollutants is unstable both in terms of time and geo-location. The shipping impact zones change dynamically and can create temporary locations with elevated emissions.

- 3.1. By integrating AIS data into the EMEP methodology, a detailed emissions assessment system was created, allowing for a better understanding of their distribution within port areas and their impact on neighboring residential areas. The average emissions at the Klaipėda port were assessed as follows: NO_x – 5.28 t/day, PM – 0.52 t/day, NMVOC – 0.22 t/day, BC – 0.064 t/day, CO₂ – 235 t/day. The difference between maximum and average emissions was 37.8%.
- 3.2. The obtained average ship emissions in the port are close to the results of other researchers when the port is evaluated as a single source, but a detailed analysis showed that the emission discharge points are not uniform. By applying the same methodology for assessing energy consumption from diesel generators at the piers, insights were provided regarding the piers with the highest energy consumption, as well as the average and maximum energy consumption for ships in the port, identifying potential targets for CO₂ and other pollutant reductions.
- 3.3. The proposed methodology allows for a detailed assessment of air pollutants and CO₂ emissions, as well as energy consumption at the piers, providing valuable insights into emission hotspots and reduction potentials.

GENERAL CONCLUSIONS

The dissertation analyzes a broad range of scientific topics, assessing air pollution due to shipping activities. It provides an overview of applied research methodologies, technologies, analytical and modeling methods, and evaluation of results. The main aspects and shortcomings, which form the basis for the formulation of the research objectives and tasks, are identified. Methodological solutions applied to the research object, the Klaipėda State Seaport, are created and thoroughly described, revealing the main characteristics of port shipping as a dynamic pollution object and developing forecasting tools for them.

1. A detailed methodology has been developed for assessing the impact of vessels operating in a dynamic port on environmental air quality, covering: a) A comprehensive evaluation of the impact of vessel traffic and emissions on air quality in the port. b) A detailed comparative assessment of energy consumption and emission discharge by vessels operating in the port. c) A forecasting model based on neural networks for assessing the impact of shipping on environmental air quality.
2. A detailed analysis of vessel traffic and exhaust gas plumes in the port was conducted. The impact of ship exhaust gas plumes on environmental air quality in the analyzed area and during the vessel's passage through the port was

assessed. The average ship speed in the port ranged from 0.2 to 25 km/h. The duration of the impact of ship exhaust gases at one of the study points lasted up to 11.26 minutes, and the concentration of particulate matter in the exhaust plume ranged from 5.2 to 43.84 $\mu\text{g}/\text{m}^3$, depending on the type of ship.

3. The results of the neural network-based forecasting model for air pollution from ships leaving the port are comparable to the accuracy of dispersion models used in studies of stationary pollution sources and are suitable for practical use. The forecasting results for all particulate matter fractions mainly depend on meteorological parameters – wind direction, wind speed, relative humidity, and pressure. The results from the ship's technical parameters are mainly influenced by the parameters defining the ship's size (GT, DWT, length, width, etc.).
4. The highest concentrations of particulate matter within the study area were found for bulk carriers. This could be linked to the possible influence of the size of these vessels. It was found that the greatest impact on particulate matter concentrations in shipping is from PM1 – PM2.5 particle size ranges (PM1 $R^2 = 0.8952$; PM2.5 $R^2 = 0.8889$). When analyzing larger particle size concentration correlations, the relationship with shipping exhaust gas plumes tends to decrease (PM10 $R^2 = 0.7586$; TSP $R^2 = 0.5626$).
5. After integrating AIS data into the EMEP methodology, a detailed emissions assessment system was created, allowing for a better understanding of their distribution within port areas and their impact on neighboring residential areas. The variation of port environmental pollution over time can be assessed, and different segments of the port area can be analyzed in detail. The assessment of pollution changes over time helps determine whether the pollution is related to cargo operations or the intensity of vessel traffic. Emission differences in shipping within the port can vary up to 20 times between individual piers, and the total daily pollutant emissions from vessels can vary by up to 20%.
6. To more effectively manage ship pollution impacts, it is recommended to combine the EMEP methodology with neural network models, which can more accurately assess pollution distribution and identify the most affected zones. This approach can lead to more targeted environmental decisions, reduce air pollution in ports, and improve public health protection. The application of neural network models would not only allow for creating a pollution impact rating for each vessel but also optimize port operations to reduce high-pollution zones and their negative effects on the environment and people.

Priedai

A priedas.

Microsoft Excel VBA pikų identifikavimo kodas

```

Sub FindAndCopyPeaksPM10new()
    Dim SignalRange As Range
    Dim TimeRange As Range
    Dim PeakRange As Range
    Dim SignalData As Variant
    Dim TimeData As Variant
    Dim SmoothedSignal As Variant
    Dim peakStart As Long
    Dim peakMax As Long
    Dim peakEnd As Long
    Dim peakTime As Date
    Dim peakDuration As Double ' Now in minutes
    Dim peakConcentrations As Variant
    Dim i As Long, j As Long
    Dim averageValue As Double
    Dim peakList As New Collection
    Dim peak As Variant

    ' Define the range where your signal and timestamp data are located
    Set SignalRange = Range("AM1:AM400000")
    Set TimeRange = Range("A1:A400000")

    ' Read data into arrays
    SignalData = SignalRange.Value
    TimeData = TimeRange.Value

    ' Calculate the average value of the signal
    averageValue = Application.WorksheetFunction.Average(SignalRange)

    ' Apply smoothing to the signal data
    SmoothedSignal = SmoothData(SignalData, 2) ' Applying a simple average smoothing

    ' Set up a range to store the peaks
    Set PeakRange = Range("BG1:BJ400000")
    PeakRange.ClearContents ' Clear any previous contents

    ' Check that there is enough data to process
    If UBound(SmoothedSignal) < 3 Then Exit Sub ' Not enough data to process

    ' Loop through the smoothed signal data to find peaks
    For i = 2 To UBound(SmoothedSignal) - 1
        If IsNumeric(SmoothedSignal(i)) And SmoothedSignal(i) > averageValue * 2 Then
            If SmoothedSignal(i) > SmoothedSignal(i - 1) And SmoothedSignal(i) >=
SmoothedSignal(i + 1) Then
                ' We have identified the peak maximum
                peakMax = i
                peakStart = i
            
```

Priedai

```

peakEnd = i

' Scan backwards to find the start of the peak
While peakStart > 2 And SmoothedSignal(peakStart - 1) < SmoothedSignal(peakStart)
    peakStart = peakStart - 1
Wend

' Scan forward to find the end of the peak
While peakEnd < UBound(SmoothedSignal) And SmoothedSignal(peakEnd + 1) <
SmoothedSignal(peakEnd)
    peakEnd = peakEnd + 1
Wend

' Check if the peak has 3 or more data points and the duration is 15 minutes or less
If (peakEnd - peakStart + 1 >= 3) And ((CDate(TimeData(peakEnd, 1)) -
CDate(TimeData(peakStart, 1))) * 1440 <= 15) Then
    peakTime = TimeData(peakMax, 1) ' Peak time at maximum concentration
    peakDuration = (CDate(TimeData(peakEnd, 1)) - CDate(TimeData(peakStart, 1))) *
1440 ' Convert days to minutes

    ' Store peak concentrations
    ReDim peakConcentrations(1 To peakEnd - peakStart + 1, 1 To 1)
    For j = peakStart To peakEnd
        peakConcentrations(j - peakStart + 1, 1) = SignalData(j, 1)
    Next j

    ' Add to peak list
    peakList.Add Array(peakTime, peakDuration, peakConcentrations)
End If
End If
End If
Next i

' Sort and display the peaks
Call SortByTime(peakList)
Dim outputRow As Long: outputRow = 1
For Each peak In peakList
    PeakRange.Cells(outputRow, 1).Value = "Peak at " & peak(0)
    PeakRange.Cells(outputRow, 2).Value = "Duration: " & Format(peak(1), "0.00") & " min-
utes"
    PeakRange.Cells(outputRow + 1, 1).Resize(UBound(peak(2), 1), 1).Value = peak(2)
    outputRow = outputRow + UBound(peak(2), 1) + 2
Next peak
End Sub

Function SmoothData(data As Variant, span As Integer) As Variant
    Dim smoothed() As Double
    ReDim smoothed(1 To UBound(data, 1))
    Dim i As Long, j As Integer, count As Integer
    Dim sum As Double

    ' Iterate through each point in the data array
    For i = 1 To UBound(data, 1)
        sum = 0

```

```

count = 0
' Average over a window from -span to +span
For j = -span To span
    If (i + j >= 1) And (i + j <= UBound(data, 1)) Then ' Ensure index is within the bounds
        If IsNumeric(data(i + j, 1)) Then ' Check if the data point is numeric
            sum = sum + data(i + j, 1)
            count = count + 1
        End If
    End If
Next j
If count > 0 Then
    smoothed(i) = sum / count ' Calculate average if the count is not zero
Else
    smoothed(i) = data(i, 1) ' Handle cases where no valid data points are in the span
End If
Next i

SmoothData = smoothed
End Function

Sub SortByTime(ByRef peakList As Collection)
    If peakList.count = 0 Then Exit Sub ' Exit if no peaks to sort

    Dim i As Long, j As Long
    Dim temp As Variant
    Dim sorted As Boolean
    Dim peakArray() As Variant
    ReDim peakArray(1 To peakList.count) ' Redimension only if there are items


    ' Copy collection to an array for sorting
    For i = 1 To peakList.count
        peakArray(i) = peakList(i)
    Next i

    ' Bubble sort by peak time (simple and not efficient for large datasets)
    Do
        sorted = True
        For i = 1 To UBound(peakArray) - 1
            If peakArray(i)(0) > peakArray(i + 1)(0) Then
                temp = peakArray(i)
                peakArray(i) = peakArray(i + 1)
                peakArray(i + 1) = temp
                sorted = False
            End If
        Next i
    Loop Until sorted
End Sub

```


B priedas.

RoRo tipo laivų greičio pasiskirstymo žemėlapis (HeatMap)




C priedas.

Tanklaivių greičio pasiskirstymo žemėlapis (HeatMap)




D priedas.

Konteinerinių laivų greičio pasiskirstymo žemėlapis (HeatMap)



E priedas.

Sausakrūvių laivų greičio pasiskirstymo žemėlapis (HeatMap)




F priedas.

Vilkikų greičio pasiskirstymo žemėlapis (HeatMap)




G priedas.
Žvejybinių laivų greičio pasiskirstymo žemėlapis (HeatMap)




H priedas.

KD2,5 realių duomenų ir neuroninių tinklų modelio prognozuojamų duomenų koreliacija



I priedas.

KD10 realių duomenų ir neuroninių tinklų modelio
prognozuojamų duomenų koreliacija



J priedas.

Dirbtinių neuroninių tinklų modelio Python kodas

```

'''
Artificial Intelligence Techniques SL
artelnics@artelnics.com

Your model has been exported to this python file.
You can manage it with the main method where
you
can change the values of your inputs. For example:

if we want to add these 3 values (0.3, 2.5 and 1.8)
to our 3 inputs (Input_1, Input_2 and Input_1), the
main program has to look like this:

def main ():
    #default_val = 3.1416
    inputs = [None]*3

    Id_1 = 0.3
    Id_1 = 2.5
    Id_1 = 1.8

    inputs[0] = Input_1
    inputs[1] = Input_2
    inputs[2] = Input_3
    ...

Inputs Names:
    0) laivo_greitis_km_div__h
    1) cog_decoded
    2) true_heading_decoded
    3) lon
    4) lan
    5) atstumas_iki_uosto_galo
    6) DWT
    7) Gt
    8) Length_Overall
    9) Beam
    10) Draft
    11) Depth
    12) Engine_KW_Total
    13) WS_int
    14) WD_int
    15) Santykinis_dregnumas
    16) Slegis__mb

'''

import math
import numpy as np

class NeuralNetwork:
    def __init__(self):
        self.inputs_number = 17

        def calculate_outputs(self,
            inputs):
            laivo_greitis_km_div__h =
            inputs[0]

            cog_decoded = inputs[1]

            true_heading_decoded =
            inputs[2]

            lon =
            inputs[3]

            lan =
            inputs[4]

            atstumas_iki_uosto_galo =
            inputs[5]

            DWT =
            inputs[6]

            Gt =
            inputs[7]

            Length_Overall = inputs[8]

            Beam =
            inputs[9]

            Draft =
            inputs[10]

            Depth =
            inputs[11]

            Engine_KW_Total =
            inputs[12]

            WS_int =
            inputs[13]

            WD_int =
            inputs[14]

            Santykinis_dregnumas =
            inputs[15]

            Slegis__mb = inputs[16]

            scaled_laivo_greitis_km_div
            __h = (laivo_greitis_km_div__h-
            0.6113830209)/3.367530107;

            scaled_cog_decoded =
            (cog_decoded-205.9029999)/117.6419983;

            scaled_true_heading_decode
            d = (true_heading_decoded-
            270.7109985)/150.4360046;

```

```

scaled_lon = (lon-
21.13220024)/0.01588520035;

scaled_lan = (lan-
55.68859863)/0.02323950082;

scaled_atstumas_iki_uosto_g
alo = (atstumas_iki_uosto_galo-
5.756040096)/2.750770092;

scaled_DWT = (DWT-
7290.709961)/13526.59961;

scaled_Gt = (Gt-
6391.22998)/9868.290039;

scaled_Length_Overall =
(Length_Overall-89.62950134)/58.01979828;

scaled_Beam = (Beam-
15.60210037)/7.093110085;

scaled_Draft = (Draft-
5.316390038)/2.753319979;

scaled_Depth = (Depth-
7.493969917)/4.573830128;

scaled_Engine_KW_Total =
(Engine_KW_Total-4502.379883)/5861.25;

scaled_WS_int = (WS_int-
4.373760223)/4.753039837;

scaled_WD_int = (WD_int-
262.9490051)/47.06069946;

scaled_Santykinis_dregnuma
s = (Santykinis_dregnumas-
0.8214399815)/0.1280580014;

scaled_Slegis_mb =
(Slegis_mb-1013.969971)/9.005459785;

perceptron_layer_1_output_0
= np.tanh( 0.391922 +
(scaled_laivo_greitis_km_div_h*-0.00138481) +
(scaled_cog_decoded*-0.00122606) +
(scaled_true_heading_decoded*-0.00209937) +
(scaled_lon*-0.00231752) + (scaled_lan*-
0.00516193) +
(scaled_atstumas_iki_uosto_galo*0.003138) +
(scaled_DWT*-0.00124859) +
(scaled_Gt*0.00357855) +
(scaled_Length_Overall*-0.00657042) +
(scaled_Beam*0.000610746) +
(scaled_Draft*0.00463256) +
(scaled_Depth*0.00858583) +
(scaled_Engine_KW_Total*-0.00155983) +
(scaled_WS_int*-0.378758) +
(scaled_WD_int*0.108343) +
(scaled_Santykinis_dregnumas*0.48814) +
(scaled_Slegis_mb*-2.49424) );

perceptron_layer_1_output_1
= np.tanh( -0.906304 +
(scaled_laivo_greitis_km_div_h*-0.00360465) +
(scaled_cog_decoded*-0.00355239) +
(scaled_true_heading_decoded*-0.00140288) +
(scaled_lon*0.00712972) +
(scaled_lan*0.00948927) +
(scaled_atstumas_iki_uosto_galo*-0.00458251) +
(scaled_DWT*0.0123258) + (scaled_Gt*-
0.0171216) +
(scaled_Length_Overall*0.0158273) +
(scaled_Beam*-0.0141371) + (scaled_Draft*-
0.00311112) + (scaled_Depth*0.00455735) +
(scaled_Engine_KW_Total*0.00716738) +
(scaled_WS_int*-1.58974) + (scaled_WD_int*-
0.180995) + (scaled_Santykinis_dregnumas*-
0.318093) + (scaled_Slegis_mb*0.752598) );

perceptron_layer_1_output_2
= np.tanh( -0.662032 +
(scaled_laivo_greitis_km_div_h*-0.00125008) +
(scaled_cog_decoded*0.000839953) +
(scaled_true_heading_decoded*-0.00350232) +
(scaled_lon*-0.0139618) + (scaled_lan*-
0.00364485) +
(scaled_atstumas_iki_uosto_galo*-0.00673877) +
(scaled_DWT*0.00357797) + (scaled_Gt*-
0.000547034) + (scaled_Length_Overall*-
0.00555379) + (scaled_Beam*0.000655928) +
(scaled_Draft*-0.00524128) +
(scaled_Depth*0.0127691) +
(scaled_Engine_KW_Total*-0.0011189) +
(scaled_WS_int*-1.81568) + (scaled_WD_int*-
0.469553) + (scaled_Santykinis_dregnumas*-
0.195762) + (scaled_Slegis_mb*-0.707639) );

perceptron_layer_1_output_3
= np.tanh( -0.136856 +
(scaled_laivo_greitis_km_div_h*-0.000415782) +
(scaled_cog_decoded*0.001721) +
(scaled_true_heading_decoded*0.00535212) +
(scaled_lon*-0.02678) + (scaled_lan*-
0.00243141) +
(scaled_atstumas_iki_uosto_galo*-0.0175911) +
(scaled_DWT*0.00175654) + (scaled_Gt*-
0.0159328) +
(scaled_Length_Overall*0.00193597) +
(scaled_Beam*-0.00458089) +
(scaled_Draft*0.0035755) +
(scaled_Depth*0.00416662) +
(scaled_Engine_KW_Total*0.00685806) +
(scaled_WS_int*-0.0569454) +
(scaled_WD_int*-1.08987) +
(scaled_Santykinis_dregnumas*-0.923491) +
(scaled_Slegis_mb*-0.190059) );

perceptron_layer_1_output_4
= np.tanh( -1.18619 +
(scaled_laivo_greitis_km_div_h*-0.00388044) +
(scaled_cog_decoded*0.000769151) +
(scaled_true_heading_decoded*0.00142966) +

```



```

(scaled_lon*0.00598418) + (scaled_lan*-
8.85796e-05) +
(scaled_atstumas_iki_uosto_galo*0.0054529) +
(scaled_DWT*0.0111381) + (scaled_Gt*-
0.0197432) +
(scaled_Length_Overall*0.00310366) +
(scaled_Beam*0.000339942) +
(scaled_Draft*0.000425307) + (scaled_Depth*-
0.00251284) +
(scaled_Engine_KW_Total*0.00822873) +
(scaled_WS_int*0.00139139) +
(scaled_WD_int*0.214357) +
(scaled_Santykinis_dregnumas*-0.0212399) +
(scaled_Slegis_mb*-1.23335) );

= np.tanh(
-0.0329016 +
(scaled_laivo_greitis_km_div_h*-0.00202381) +
(scaled_cog_decoded*0.00999074) +
(scaled_true_heading_decoded*0.00115758) +
(scaled_lon*-0.0140403) + (scaled_lan*-
0.016241) +
(scaled_atstumas_iki_uosto_galo*0.00297892) +
(scaled_DWT*0.0336455) + (scaled_Gt*-
0.0308579) +
(scaled_Length_Overall*0.00619456) +
(scaled_Beam*0.00459473) + (scaled_Draft*-
0.0144899) + (scaled_Depth*-0.00830763) +
(scaled_Engine_KW_Total*0.0118653) +
(scaled_WS_int*-0.0410013) +
(scaled_WD_int*-0.925868) +
(scaled_Santykinis_dregnumas*0.414418) +
(scaled_Slegis_mb*-1.12913) );

= np.tanh(
-0.0801488 +
(scaled_laivo_greitis_km_div_h*0.0055081) +
(scaled_cog_decoded*0.00601159) +
(scaled_true_heading_decoded*0.0112257) +
(scaled_lon*-0.0170865) + (scaled_lan*-
0.0104685) + (scaled_atstumas_iki_uosto_galo*-
0.0047034) + (scaled_DWT*0.0145305) +
(scaled_Gt*-0.0161625) +
(scaled_Length_Overall*0.018717) +
(scaled_Beam*-0.0136318) +
(scaled_Draft*0.0127034) + (scaled_Depth*-
0.0109364) +
(scaled_Engine_KW_Total*0.0011398) +
(scaled_WS_int*-1.30195) + (scaled_WD_int*-
0.052202) +
(scaled_Santykinis_dregnumas*0.508022) +
(scaled_Slegis_mb*-0.131769) );

= np.tanh(
-0.429785 +
(scaled_laivo_greitis_km_div_h*0.00977388) +
(scaled_cog_decoded*-0.00398953) +
(scaled_true_heading_decoded*-0.00221308) +
(scaled_lon*-0.0252961) + (scaled_lan*-
0.00867184) +
(scaled_atstumas_iki_uosto_galo*-0.00812273) +
(scaled_DWT*-0.00762594) + (scaled_Gt*-
0.00406975) + (scaled_Length_Overall*-
0.011087) + (scaled_Beam*0.0174235) +
(scaled_Draft*-0.00609118) +
(scaled_Depth*0.0195315) +
(scaled_Engine_KW_Total*-0.0102405) +
(scaled_WS_int*0.276921) +
(scaled_WD_int*0.0430382) +
(scaled_Santykinis_dregnumas*-0.398226) +
(scaled_Slegis_mb*-0.717784) );

= np.tanh(
1.22303 +
(scaled_laivo_greitis_km_div_h*-0.0016539) +
(scaled_cog_decoded*-0.00261323) +
(scaled_true_heading_decoded*0.00091352) +
(scaled_lon*-0.00336174) +
(scaled_lan*0.00998768) +
(scaled_atstumas_iki_uosto_galo*-0.0137531) +
(scaled_DWT*0.0144148) + (scaled_Gt*-
0.0148112) +
(scaled_Length_Overall*0.0196291) +
(scaled_Beam*-0.00947169) + (scaled_Draft*-
0.00875369) + (scaled_Depth*-0.0047143) +
(scaled_Engine_KW_Total*0.00791415) +
(scaled_WS_int*-0.424296) + (scaled_WD_int*-
0.2654) + (scaled_Santykinis_dregnumas*-
1.60198) + (scaled_Slegis_mb*0.0862321) );

= np.tanh(
0.807389 +
(scaled_laivo_greitis_km_div_h*0.00223964) +
(scaled_cog_decoded*-0.00521504) +
(scaled_true_heading_decoded*-0.00195444) +
(scaled_lon*0.0111983) + (scaled_lan*2.77473e-
05) +
(scaled_atstumas_iki_uosto_galo*0.00472792) +
(scaled_DWT*0.00484023) + (scaled_Gt*-
0.0028556) + (scaled_Length_Overall*-
0.00684281) + (scaled_Beam*0.00351737) +
(scaled_Draft*-0.00637638) +
(scaled_Depth*0.013929) +
(scaled_Engine_KW_Total*0.00151449) +
(scaled_WS_int*-0.759867) + (scaled_WD_int*-
0.990747) +
(scaled_Santykinis_dregnumas*0.0666865) +
(scaled_Slegis_mb*-1.1099) );

= np.tanh(
-0.619982 +
(scaled_laivo_greitis_km_div_h*-0.00778073) +
(scaled_cog_decoded*0.00375351) +
(scaled_true_heading_decoded*-0.000975288) +
(scaled_lon*-0.0110536) + (scaled_lan*-
0.00716817) +
(scaled_atstumas_iki_uosto_galo*-0.0045523) +
(scaled_DWT*0.00992508) + (scaled_Gt*-
0.0190224) +
(scaled_Length_Overall*0.00142845) +
(scaled_Beam*0.0102386) + (scaled_Draft*-
0.00246682) + (scaled_Depth*-0.0164052) +
(scaled_Engine_KW_Total*0.00870054) +
(scaled_WS_int*0.0337112) +
(scaled_WD_int*0.912243) +
(scaled_Santykinis_dregnumas*-0.0692496) +
(scaled_Slegis_mb*-0.603712) );

```

```

perceptron_layer_1_output_1
1 = np.tanh( 0.00907516 +
(scaled_laivo_greitis_km_div_h*0.00323775) +
(scaled_cog_decoded*-0.00774903) +
(scaled_true_heading_decoded*0.00167736) +
(scaled_lon*-0.00786243) + (scaled_lan*-
0.00241063) +
(scaled_atstumas_iki_uosto_galo*0.000322804)
+ (scaled_DWT*0.00817303) + (scaled_Gt*-
0.0119394) + (scaled_Length_Overall*-
0.00136658) + (scaled_Beam*-0.00906655) +
(scaled_Draft*0.00518147) +
(scaled_Depth*0.00331311) +
(scaled_Engine_KW_Total*0.00581561) +
(scaled_WS_int*0.351995) + (scaled_WD_int*-
0.595195) +
(scaled_Santykinis_dregnumas*0.718041) +
(scaled_Slegis_mb*1.21205) );

```

```

perceptron_layer_1_output_1
2 = np.tanh( 1.03587 +
(scaled_laivo_greitis_km_div_h*-0.000434045)
+ (scaled_cog_decoded*0.00337921) +
(scaled_true_heading_decoded*-0.00353261) +
(scaled_lon*-0.0129214) + (scaled_lan*-
0.00307727) +
(scaled_atstumas_iki_uosto_galo*-0.00893669) +
(scaled_DWT*-0.00308469) + (scaled_Gt*-
0.0049347) + (scaled_Length_Overall*-
0.00799707) + (scaled_Beam*0.0185495) +
(scaled_Draft*0.00368496) + (scaled_Depth*-
0.0114471) +
(scaled_Engine_KW_Total*0.00294621) +
(scaled_WS_int*0.226672) + (scaled_WD_int*-
1.45218) + (scaled_Santykinis_dregnumas*-
0.0868142) + (scaled_Slegis_mb*0.114619) );

```

```

perceptron_layer_1_output_1
3 = np.tanh( 0.162464 +
(scaled_laivo_greitis_km_div_h*0.00726936) +
(scaled_cog_decoded*0.00984172) +
(scaled_true_heading_decoded*0.00324753) +
(scaled_lon*-0.047218) + (scaled_lan*-
0.0267626) + (scaled_atstumas_iki_uosto_galo*-
0.0220309) + (scaled_DWT*0.0423295) +
(scaled_Gt*-0.0421739) +
(scaled_Length_Overall*0.00501857) +
(scaled_Beam*0.00107792) + (scaled_Draft*-
0.0196266) + (scaled_Depth*0.00364943) +
(scaled_Engine_KW_Total*0.0191426) +
(scaled_WS_int*-0.416796) +
(scaled_WD_int*1.02659) +
(scaled_Santykinis_dregnumas*0.559527) +
(scaled_Slegis_mb*0.713257) );

```

```

perceptron_layer_1_output_1
4 = np.tanh( -1.71263 +
(scaled_laivo_greitis_km_div_h*-0.00141882)
+ (scaled_cog_decoded*-0.000491828) +
(scaled_true_heading_decoded*-0.00191007) +
(scaled_lon*-0.00131543) +
(scaled_lan*0.00964223) +
(scaled_atstumas_iki_uosto_galo*-0.0151711) +

```

```

(scaled_DWT*-0.0087063) +
(scaled_Gt*0.011754) +
(scaled_Length_Overall*-0.00417929) +
(scaled_Beam*0.00489042) + (scaled_Draft*-
0.00397957) + (scaled_Depth*0.00481289) +
(scaled_Engine_KW_Total*-0.00557664) +
(scaled_WS_int*-0.16182) + (scaled_WD_int*-
0.644043) + (scaled_Santykinis_dregnumas*-
0.27821) + (scaled_Slegis_mb*1.46921) );

```

```

perceptron_layer_1_output_1
5 = np.tanh( 0.835449 +
(scaled_laivo_greitis_km_div_h*-0.0155488) +
(scaled_cog_decoded*-0.00252379) +
(scaled_true_heading_decoded*-0.00123939) +
(scaled_lon*0.00640465) +
(scaled_lan*0.00249983) +
(scaled_atstumas_iki_uosto_galo*0.00417831) +
(scaled_DWT*-0.026316) +
(scaled_Gt*0.0171842) +
(scaled_Length_Overall*-0.0194698) +
(scaled_Beam*0.024611) +
(scaled_Draft*0.0171524) + (scaled_Depth*-
0.0112006) + (scaled_Engine_KW_Total*-
0.00793045) + (scaled_WS_int*-0.981068) +
(scaled_WD_int*0.0462127) +
(scaled_Santykinis_dregnumas*0.307344) +
(scaled_Slegis_mb*-0.636095) );

```

```

perceptron_layer_1_output_1
6 = np.tanh( -0.377743 +
(scaled_laivo_greitis_km_div_h*-9.73573e-05)
+ (scaled_cog_decoded*-0.0073389) +
(scaled_true_heading_decoded*0.00532722) +
(scaled_lon*0.00430508) + (scaled_lan*-
0.0044355) +
(scaled_atstumas_iki_uosto_galo*0.00264982) +
(scaled_DWT*0.017351) + (scaled_Gt*-
0.0252724) +
(scaled_Length_Overall*0.0245637) +
(scaled_Beam*-0.00703843) + (scaled_Draft*-
0.00981763) + (scaled_Depth*0.0118186) +
(scaled_Engine_KW_Total*0.00320993) +
(scaled_WS_int*0.734923) + (scaled_WD_int*-
0.0924064) + (scaled_Santykinis_dregnumas*-
0.192318) + (scaled_Slegis_mb*-0.727304) );

```

```

perceptron_layer_1_output_1
7 = np.tanh( -0.754516 +
(scaled_laivo_greitis_km_div_h*0.00423098) +
(scaled_cog_decoded*0.0045065) +
(scaled_true_heading_decoded*0.00482074) +
(scaled_lon*-0.0104756) + (scaled_lan*-
0.00278772) +
(scaled_atstumas_iki_uosto_galo*-0.00469086) +
(scaled_DWT*-0.0027351) +
(scaled_Gt*0.00395435) +
(scaled_Length_Overall*-0.0132485) +
(scaled_Beam*0.00933504) +
(scaled_Draft*0.00468381) + (scaled_Depth*-
0.00330791) +

```

Priedai

```

unscaling_layer_output_0=perceptron_layer_5_o
utput_0*9.08852005+4.985030174;

                                cog_decoded = default_val
                                #Change this value
                                inputs[1]

                                unscaling_layer_output_1=pe
                                rceptron_layer_5_output_1*9.298899651+5.8006
                                60133;

                                = cog_decoded

                                unscaling_layer_output_2=pe
                                rceptron_layer_5_output_2*12.27299976+10.873
                                2996;

                                default_val      true_heading_decoded =
                                #Change this value
                                inputs[2]

                                = true_heading_decoded

                                unscaling_layer_output_3=pe
                                rceptron_layer_5_output_3*34.69290161+19.484
                                60007;

                                default_val      lon =
                                #Change this value
                                inputs[3]

                                = lon

                                PM1_int
                                = max(0, unscaling_layer_output_0);
                                PM1_int
                                = min(82.77760315, unscaling_layer_output_0);

                                default_val      lan =
                                #Change this value
                                inputs[4]

                                = lan

                                PM2_5_int = max(0,
                                unscaling_layer_output_1);

                                default_val      atstumas_iki_uosto_galo =
                                #Change this value
                                inputs[5]

                                = atstumas_iki_uosto_galo

                                PM2_5_int =
                                min(84.07730103, unscaling_layer_output_1);

                                default_val      DWT =
                                #Change this value
                                inputs[6]

                                = DWT

                                PM10_int =
                                min(217.2160034, unscaling_layer_output_2);
                                TSP_int
                                = max(0.8899999857, unscaling_layer_output_3);
                                TSP_int
                                = min(1336.459961, unscaling_layer_output_3);

                                default_val      Gt =
                                #Change this value
                                inputs[7]

                                = Gt

                                out =
                                [None]*4

                                out[0] =
                                PM1_int

                                Length_Overall = default_val
                                #Change this value
                                inputs[8]

                                = Length_Overall

                                out[1] =
                                PM2_5_int

                                Beam =
                                default_val      #Change this value
                                inputs[9]

                                = Beam

                                out[2] =
                                PM10_int

                                Draft =
                                default_val      #Change this value
                                inputs[10] = Draft

                                out[3] =
                                TSP_int

                                Depth =
                                default_val      #Change this value
                                inputs[11] = Depth

                                return

                                = Beam

                                out;

                                def main (self):

                                default_val = 3.1416

                                inputs =
                                [None]*17

                                laivo_greitis_km_div__h =
                                default_val      #Change this value
                                inputs[0]

                                = laivo_greitis_km_div__h

                                Engine_KW_Total =
                                default_val      #Change this value

```

Priedai

```

        inputs[12] = Engine_KW_Total

        WS_int = default_val
        #Change this value
        inputs[13] = WS_int

        WD_int = default_val
        #Change this value
        inputs[14] = WD_int

        Santykinis_dregnumas = default_val
        #Change this value
        inputs[15] = Santykinis_dregnumas

        Slegis__mb = default_val
        #Change this value

        inputs[16] = Slegis__mb

        outputs = NeuralNetwork.calculate_outputs(self, inputs)

        print("\nThese are your
        outputs:\n")
        PM1_int:" + str(outputs[0]) + "\n" )
        PM2_5_int:" + str(outputs[1]) + "\n" )
        PM10_int:" + str(outputs[2]) + "\n" )
        TSP_int:" + str(outputs[3]) + "\n" )

        nn = NeuralNetwork()
        nn.main()

```

Priedai

K priedas. Pradinių AIS duomenų failo fragmentas

Date	MMSI	IMO	sog. decoded	cog decoded	true heading decoded	LON	LAN
2021-01-01 00:00	209707000	8801060	0.2	274	189	20.865168	55.7145
2021-01-01 00:00	256892000	9691046	1.2	349.7	256	20.644987	55.888901
2021-01-01 00:00	235011600	9301603	0	0.1	250	21.164406	55.646194
2021-01-01 00:00	244790715	9677399	0.4	107	183	20.8561	55.71685
2021-01-01 00:00	538007454	9575216	0.2	278	184	20.862005	55.728794
2021-01-01 00:00	255805693	9005376	0.2	280.1	204	20.846573	55.725845
2021-01-01 00:00	273456380	8813702	0	202.8	341	21.143465	55.662418
2021-01-01 00:00	311018300	9383448	0.5	271	220	20.39695	55.797611
2021-01-01 00:00	538007349	9302918	0.2	261	208	20.838417	55.71365
2021-01-01 00:00	277459000	0	0	67.3	511	21.149048	55.663738
2021-01-01 00:00	277066000	0	0	255.5	170	21.149176	55.664629
2021-01-01 00:00	277466000	9458535	0	324	324	21.136873	55.685753
2021-01-01 00:00	277493000	0	0	192.9	73	21.14905	55.664371
2021-01-01 00:00	230941700	9622502	0	209.8	243	21.127518	55.702187
2021-01-01 00:00	257970000	9246152	0	134.5	135	21.108549	55.719952
2021-01-01 00:00	261094060	0	0	346.8	346	21.124142	55.703926
2021-01-01 00:00	244168000	9378280	0	245.8	1	21.138052	55.664215
2021-01-01 00:00	277526000	7427659	0.1	262.4	279	21.156581	55.653942
2021-01-01 00:00	636017370	9774484	12.5	263.5	263	20.282261	55.709576
2021-01-01 00:00	2770110	0	102.3	360	511	21.095688	55.727703
2021-01-01 00:00	215122000	9798363	8.6	90.9	92	21.051371	55.729015
2021-01-01 00:00	2770090	0	102.3	360	511	20.995438	55.306141
2021-01-01 00:00	277280000	0	0	344.2	511	21.149073	55.664988
2021-01-01 00:00	277560000	9188245	0	3.8	342	21.144489	55.65736
2021-01-01 00:00	305067000	9422275	0	288.1	101	21.153891	55.658696
2021-01-01 00:00	304642000	9246554	11.3	246	246	20.738832	55.713165
2021-01-01 00:00	377065000	6808090	9.6	271.1	272	21.013256	55.733944
2021-01-01 00:00	277533000	0	0.1	60.7	354	21.101624	55.719109
2021-01-01 00:00	219027995	9198721	0	39.9	340	21.143728	55.659233
2021-01-01 00:00	277542000	972915400	0	195.6	328	21.119524	55.711582
2021-01-01 00:00	277464000	0	0.1	211.5	155	21.152813	55.66246
2021-01-01 00:00	253447000	9591416	0	0.2	279	21.140007	55.682907
2021-01-01 00:00	277148000	7920405	0.1	231.6	511	21.126669	55.700489
2021-01-01 00:00	277293000	8419910	0	15.4	15	21.152718	55.660549
2021-01-01 00:00	218759000	8518558	0	298.3	101	21.157429	55.65538
2021-01-01 00:00	636092390	9444912	0	320	169	21.1457	55.670399
2021-01-01 00:00	636018805	9231377	0	7	169	21.1462	55.668583
2021-01-01 00:00	246530000	9355812	0	258.7	349	21.142817	55.6763
2021-01-01 00:00	277541000	9752008	7.3	289.4	282	21.068958	55.729805
2021-01-01 00:00	277149000	7237262	0	174	511	21.1266	55.7005
2021-01-01 00:00	538003308	9387334	0	279.4	310	21.104191	55.722019
2021-01-01 00:00	277545000	8829425	0.1	150.5	511	21.12307	55.70784
2021-01-01 00:00	257670000	9430961	0	19	338	21.135468	55.691132
2021-01-01 00:00	563025500	9725029	0	19.1	145	21.162544	55.645313
2021-01-01 00:00	277504000	9350680	0	347	347	21.13905	55.6861
2021-01-01 00:00	219827000	9129598	0	247.8	343	21.144453	55.662285
2021-01-01 00:00	356843000	9084229	0.2	108.2	209	20.860889	55.701752
2021-01-01 00:00	210065000	9333369	0	203	102	21.158167	55.652832
2021-01-01 00:00	2770030	0	102.3	360	511	21.137283	55.69009
2021-01-01 00:00	277273000	0	0	246.7	511	21.149137	55.66391
2021-01-01 00:00	277421000	9550917	0	299	96	21.1259	55.70055
2021-01-01 00:00	277385000	9534731	0	328	140	21.119705	55.710903
2021-01-01 00:00	563614000	9629536	0	317.1	0	21.137638	55.663712
2021-01-01 00:00	277522000	0	0	230.6	172	21.149162	55.664551
2021-01-01 00:00	277078000	8727721	0	273.9	511	21.124132	55.703117
2021-01-01 00:00	277425000	9568847	0	332	511	21.119967	55.711201
2021-01-01 00:00	613003546	8834823	0	354.3	511	21.125134	55.706599
2021-01-01 00:00	630123200	7223223	0	1.9	511	21.123962	55.709019
2021-01-01 00:00	209239000	9006277	0	357	134	21.107264	55.720646
2021-01-01 00:00	277408000	9350721	0	324	324	21.136551	55.685349
2021-01-01 00:00	253398000	9559183	0	360	349	21.138794	55.68681
2021-01-01 00:00	314396000	9491745	0	13.4	157	21.134094	55.69289
2021-01-01 00:00	373694000	9624627	0	359.5	352	21.147184	55.665302
2021-01-01 00:00	277314000	0	11	91.5	511	21.048647	55.728851
2021-01-01 00:00	2770100	0	102.3	360	511	21.082176	56.025162
2021-01-01 00:00	277540000	9751999	6.7	291.3	282	21.064528	55.730453
2021-01-01 00:00	304010297	9041320	0	277.5	282	21.157339	55.666971
2021-01-01 00:00	210008000	8328027	0	292.9	146	21.15749	55.648376
2021-01-01 00:00	209707000	8801060	0.2	271	176	20.865	55.7145
2021-01-01 00:00	261094060	0	0	297.7	297	21.124134	55.703926
2021-01-01 00:00	277459000	0	0	73.2	511	21.149055	55.663761
2021-01-01 00:00	277066000	0	0	254.7	170	21.149172	55.664841
2021-01-01 00:00	277493000	0	0	160.7	73	21.149044	55.664388
2021-01-01 00:00	257970000	9246152	0	134.5	135	21.108566	55.719967
2021-01-01 00:00	244790715	9677399	0.1	254	209	20.856417	55.716782
2021-01-01 00:00	538007454	9575216	0.2	51.7	179	20.861969	55.728844
2021-01-01 00:00	255805693	9005376	0.1	208.5	196	20.846306	55.725815
2021-01-01 00:00	244168000	9378280	0	245.8	1	21.138044	55.664089

Priedai

L priedas.

AQM 65 taršos vertinimo stoties duomenų fragmentas

Aeroqual Connect - ECM ECO Monitoring, a.s. [AQM65 21012016-493]									
Data export									
7/1/2020 to 12/31/2020									
(UTC+02:00) Helsinki, Kyiv, Riga, Sofia, Tallinn, Vilnius (Summer time adjusted)									
Averaging period: 1 minute									
Time	PM1 (µg/m³)	PM2.5 (µg/m³)	PM10 (µg/m³)	TSP (µg/m³)	WS (m/s)	WD (°)	AIR T (°C)	CO (mg/m³)	NOx (µg/m³)
2020-07-01 00:00	2,08	2,67	2,89	2,89	3,16	94,4	17	0	35,676
2020-07-01 00:01	2,12	2,67	2,81	2,81	3,89	155,1	17	0	49,555
2020-07-01 00:02	2,17	2,83	3,01	3,01	5,04	213,9	17	0	44,893
2020-07-01 00:03	2,24	2,93	3,09	3,09	4,78	238	17	0	36,599
2020-07-01 00:04	2,24	2,88	3,13	3,13	4,07	34,7	16,9	0	64,351
2020-07-01 00:05	2,22	2,8	3,19	3,19	3,68	223,2	16,9	0	52,171
2020-07-01 00:06	2,32	2,91	3,03	3,03	4,11	222,3	16,9	0	34,225
2020-07-01 00:07	2,25	2,99	3,19	3,19	4,66	200	16,9	0	43,371
2020-07-01 00:08	2,26	2,9	2,99	2,99	3,63	227,3	16,9	0	41,006
2020-07-01 00:09	2,32	2,87	2,96	5,84	4,25	190,4	16,9	0	34,613
2020-07-01 00:10	2,25	2,91	3,15	3,15	3,83	193,3	16,9	0	37,212
2020-07-01 00:11	2,25	2,87	3,2	3,2	3,33	241,8	16,9	0	41,183
2020-07-01 00:12	2,32	2,95	3,23	3,23	4,19	198,5	16,9	0	46,36
2020-07-01 00:13	2,29	2,97	3,18	3,18	3,56	170,9	16,9	0	45,562
2020-07-01 00:14	2,39	3,03	3,28	6,15	4,1	228,5	16,9	0	43,684
2020-07-01 00:15	2,27	2,84	3	3	4,48	181,7	16,9	0	38,943
2020-07-01 00:16	2,19	2,77	2,92	2,92	4,89	232,6	16,9	0	31,151
2020-07-01 00:17	2,18	2,79	3,32	3,32	4,54	206,6	16,9	0	27,485
2020-07-01 00:18	2,04	2,64	3,15	11,77	5,42	232,8	16,9	0	23,269
2020-07-01 00:19	2,09	2,65	3,4	3,4	5,78	230,3	16,9	0	8,41
2020-07-01 00:20	2	2,58	3,29	6,16	4,83	221,6	16,9	0	3,955
2020-07-01 00:21	2,07	2,66	3,14	6,01	5,13	207,2	16,9	0	0
2020-07-01 00:22	2,02	2,56	2,67	5,55	5,35	168,3	16,9	0	7,661
2020-07-01 00:23	1,91	2,37	2,62	2,62	4,85	221,1	16,9	0	7,253
2020-07-01 00:24	1,88	2,41	2,52	2,52	5,35	208,1	16,9	0	2,556
2020-07-01 00:25	1,89	2,43	2,68	2,68	4,15	228,1	16,9	0	46,239
2020-07-01 00:26	1,9	2,46	2,78	2,78	4,93	241,8	16,9	0	42,305
2020-07-01 00:27	1,83	2,38	2,75	5,63	4,12	179,4	16,9	0	15,022
2020-07-01 00:28	1,88	2,4	2,7	5,58	4,53	235,5	17	0	10,354
2020-07-01 00:29	1,94	2,5	2,85	2,85	3,97	246,3	17	0	9,138
2020-07-01 00:30	1,9	2,4	2,47	2,47	5,19	218,3	17	0	8,574
2020-07-01 00:31	1,83	2,36	2,97	2,97	3,99	255	17	0	8,78
2020-07-01 00:32	1,85	2,4	2,61	2,61	3,91	194,3	17	0	8,142
2020-07-01 00:33	1,8	2,38	2,5	5,38	4,74	234,6	17	0	6,328
2020-07-01 00:34	1,9	2,42	2,98	2,98	5,08	209,2	17	0	9,795
2020-07-01 00:35	1,96	2,44	2,97	2,97	3,21	212,2	17	0	14,23
2020-07-01 00:36	1,88	2,46	2,57	2,57	3,58	231,2	17	0	24,067
2020-07-01 00:37	1,99	2,58	3,02	3,02	3,4	221,6	17	0	26,294
2020-07-01 00:38	2,03	2,67	2,86	2,86	2,83	83,6	17	0	25,207
2020-07-01 00:39	2,07	2,69	2,75	2,75	3,69	246,1	17	0	19,716
2020-07-01 00:40	1,84	2,34	2,59	2,59	4,93	248	17	0	16,831
2020-07-01 00:41	1,83	2,39	2,82	2,82	3,9	211,1	17	0	13,747
2020-07-01 00:42	1,85	2,46	3,37	3,37	4,22	232,2	17	0	7,379
2020-07-01 00:43	1,89	2,47	2,6	2,6	3,72	237,8	16,9	0	10,781
2020-07-01 00:44	1,85	2,41	2,78	2,78	3,48	301,9	17	0	17,929
2020-07-01 00:45	1,94	2,46	2,73	2,73	5,68	249,2	17	0	35,971
2020-07-01 00:46	1,86	2,43	2,78	2,78	4,41	275,2	17	0	22,765
2020-07-01 00:47	1,95	2,55	2,8	2,8	4,67	252,7	17	0	15,547
2020-07-01 00:48	1,91	2,52	2,82	2,82	3,58	168,5	17	0	8,978
2020-07-01 00:49	2	2,54	2,73	2,73	3,53	285,3	17	0	17,519
2020-07-01 00:50	1,99	2,63	3,13	3,13	4,39	248,1	17	0	19,948
2020-07-01 00:51	2,01	2,61	3,04	3,04	4,98	251,4	17	0	18,833
2020-07-01 00:52	1,95	2,49	2,68	2,68	3,75	218,2	17	0	23,739
2020-07-01 00:53	1,97	2,51	2,99	2,99	3,35	230,9	17	0	25,279
2020-07-01 00:54	1,89	2,45	2,57	2,57	3,51	251,6	17	0	24,578
2020-07-01 00:55	1,91	2,5	2,82	2,82	3,44	195	17	0	22,119
2020-07-01 00:56	2,03	2,69	2,86	2,86	3,88	249,1	17	0	21,012
2020-07-01 00:57	2,08	2,6	2,72	2,72	5,84	237,7	17	0	20,823
2020-07-01 00:58	2,06	2,62	2,77	5,64	3,89	198,6	17	0	14,896
2020-07-01 00:59	2,1	2,66	2,9	2,9	4,37	225,3	17	0	18,852
2020-07-01 01:00	2,18	2,78	3,22	3,22	4,65	238,3	17	0	62,353
2020-07-01 01:01	2,17	2,78	3,16	3,16	3,56	269,7	17	0	35,094
2020-07-01 01:02	2,18	2,94	3,36	3,36	3,68	216	17	0	22,77
2020-07-01 01:03	2,18	2,78	3,19	3,19	3,6	195,1	17	0	12,259
2020-07-01 01:04	2,24	2,89	3,38	3,38	3,88	227,3	17	0	24,282
2020-07-01 01:05	2,28	2,98	3,19	3,19	4,82	251,3	17	0	29,135
2020-07-01 01:06	2,25	2,86	3,12	3,12	4,79	271,8	17	0	23,34
2020-07-01 01:07	2,18	2,83	3,06	3,06	4,63	196,8	17	0	26,654
2020-07-01 01:08	2,34	2,99	3,28	3,28	4,08	216,2	17	0	26,499
2020-07-01 01:09	2,32	2,94	3,22	3,22	4,29	216,1	17	0	17,445
2020-07-01 01:10	2,34	3,03	3,45	3,45	4,04	239,2	17	0	18,081
2020-07-01 01:11	2,36	3,11	3,52	9,27	3,4	195,2	17	0	20,486

M priedas.
Leidimas naudoti 9 paveikslą disertacijoje.

SF

Sam Fickinger<sam.fickinger@aeroqual.com>
Kam: Giedrius Šilas

Hi Giedrius,

Thank you for reaching out to Aeroqual. You are welcome to use any publicly available images for your thesis projects. Let me know if there is anyway we can help!

Cheers,
Sam

Sam Fickinger
Business Development Coordinator

T

E

sam.fickinger@aeroqual.com

Connect with me on [LinkedIn](#)

[aeroqual.com](#)

aeroqual

Real-time
air quality
monitoring solutions



...

 Persiųsti

2024-03-06, Tr 00:06

  Atsakyti

 Atsakyti visiems

 Persiųsti

163

Klaipėdos universiteto leidykla

Giedrius ŠILAS

LAIVŲ POVEIKIO UOSTO ORO TARŠAI VERTINIMO MODELIS IR METODIKA

Daktaro disertacija

Technologijos mokslai,
transporto inžinerija (T 003)

A MODEL AND METHODOLOGY FOR ASSESSING THE IMPACT OF SHIPS ON PORT AIR
POLLUTION

Doctoral dissertation

Technological sciences,
Transport Engineering (T 003)

Klaipėda, 2025

SL 1335. 2025 06 12. Apimtis 13,37 sąl. sp. I. Tiražas 20 egz.
Klaipėdos universiteto leidykla, Herkaus Manto g. 84, 92294 Klaipėda
Tel. (8 46) 398 891, el. paštas: leidykla@ku.lt, interneto adresas: <http://www.ku.lt/leidykla/>
Spausdino UAB „Vitaė Litera“, Savanorių pr. 137, 44146 Kaunas