



Vaasan yliopisto
UNIVERSITY OF VAASA

Terhi Mäki-Turja

Matkustaja-autolautan työntötehon mallintaminen

Aurora Botnia -aluksen dataan ja sääolosuhteisiin perustuva
koneoppimismallinnus

Tekniikan ja innovaatiojohtamisen yksikkö
Energiatekniikan diplomityö
Energia- ja informaatiotekniikan ohjelma

Vaasa 2025

VAASAN YLIOPISTO**Tekniikan ja innovaatiojohtamisen yksikkö**

Tekijä:	Terhi Mäki-Turja
Tutkielman nimi:	Matkustaja-autolautan työntötehon mallintaminen : Aurora Botnia -aluksen dataan ja sääolosuhteisiin perustuva koneoppimis-mallinnus
Tutkinto:	Diplomi-insinööri
Oppiaine:	Energiatekniikka
Työn valvoja:	Anne Mäkiranta
Työn ohjaajat:	Teemu Ovaska ja Jani Boutellier
Valmistumisvuosi:	2025
Sivumäärä:	75

TIIVISTELMÄ:

Merenkulku aiheuttaa noin kolme prosenttia globaaleista ihmisen toiminnasta aiheutuvista päästöistä. Kansainvälinen merenkulkujärjestö IMO (International Maritime Organization) on päivittänyt kasvihuonekaasustrategiansa ja sen tavoitteena on vähentää merenkulusta aiheutuvia päästöjä. Alusten polttoaineenkulutuksella on merkittävä vaikutus merenkulun päästöihin, ja polttoaineenkulutukseen vaikuttavat monet asiat.

Tämän diplomityön tarkoituksena on mallintaa Merenkurkussa liikennöivän Aurora Botnia -aluksen propulsiotehoon vaikuttavia muuttujia. Tarkoitus on pyrkiä tunnistamaan erilaisten sääelementtien ja laivan ajamisen muuttujien vaikutusta propulsiotehon tarpeeseen ja sitä kautta polttoaineenkulutukseen. Erityisenä kiinnostuksen kohteena on biolikaantumisen vaikutuksen mahdollinen näkyminen käytettävissä olevasta datasta ja sen mahdollinen ennustaminen.

Aurora Botnia -alukselta saatu data sekä Ilmatieteen laitoksen meripöijudata ja jäädata on yhdistetty Wasalinelta saatuihin tietoihin aluksen pesuajankohdista. Yhdistettyä dataa on mallinnettu käyttämällä MATLAB-ohjelmaa. Koneoppimismallinnuksessa on käytetty lineaarista regressiota ja keinokekoista neuroverkkoa (ANN). Työssä on tutkittu eteenpäin työntävää propulsiotehoa suhteessa muihin muuttujiin.

Datan valinnassa ja käsittelyssä on jouduttu tekemään joitakin oletuksia. Numeerista tai visuaalisiin havaintoihin perustuvaa tietoa aluksen pohjan likaantumisen ei ollut olemassa. Jään vaikutuksesta likaantumiseen tai jään ilmenemisestä reitillä ei ollut saatavissa täsmällistä tietoa.

Tuloksista voidaan päätellä, että aluksen nopeudella on suurin vaikutus propulsiotehon tarpeeseen. Seuraavaksi merkittävin tekijä on suhteellinen tuulennopeus. Keinokekoisella neuroverkolla mallinnettaessa seuraavaksi merkittävimmät muuttujat ovat viippaus, merkitsevä aallonkorkeus, Frouden syvyysluku ja syväys. Pohjan puhtaudella pesupäivän mukaan arvioitaessa ei ollut suurta merkitystä tehontarpeeseen kuten ei veden lämpötilallakaan.

Lineaariregression avulla luotu malli ennustaa tarvittavan työntötehon tarpeen. Arvovälille nolasta yhteen normalisoidulla datalla mallin keskiarvoinen keskineliövirhe (MSE) on 0,0027 ja jäännösvirrehajonta (RMSE) 0,0520.

AVAINSANAT: aikasarjat, koneoppiminen, laivat, mallintaminen, meriliikenne, monimuuttujamenetelmät, potkurit, teho

UNIVERSITY OF VAASA**School of Technology and Innovations**

Author:	Terhi Mäki-Turja		
Title of the thesis:	Ferry propulsion modelling: Machine learning modelling based on Aurora Botnia vessel data and environmental data		
Degree:	Master of Science in Technology		
Discipline:	Energy Engineering		
Supervisor:	Anne Mäkiranta		
Instructors:	Teemu Ovaska and Jani Boutellier		
Year:	2025	Pages:	75

ABSTRACT:

Shipping is responsible for about three percent of the global anthropogenic emissions. The International Maritime Organization (IMO) has set a target of reaching net-zero GHGs emissions by 2050. Vessel fuel consumption significantly affects total emissions and is a resultant of many factors. This thesis aims to model these factors' effects on propulsion needed on Aurora Botnia, a ferry trafficking in the Kvarken region. The goal is to identify various weather and ship operating variables' effect on needed thrust and consequently fuel consumption. A particular interest is taken on biofouling and detecting and predicting it from available data.

The vessel data from Aurora Botnia has been combined with the buoy and ice data from the Finnish Meteorological Institute (FMI) as well as the log of when the hull was cleaned. This combined data was modelled by using MATLAB and its machine learning tools for linear regression and Artificial Neural Network (ANN). Modelling was focused on forward thrust in relation to other variables.

In data handling and selection some presumptions were made. Vessel fouling data was based on hull cleaning dates rather than numerical or visual observations. There was no precise data on ice seasons on the route or its effect on biofouling.

Results from the ANN approach show that the propulsion needed is most significantly affected by the speed of the vessel. The second most significant factor is the relative wind speed. After this, the most significant factors are trim, significant wave height, Froude depth number and draught, in order. When assessed according to the days since the hull was cleaned, neither biofouling nor water temperature were found to be significant factors.

Using linear regression, the model reliably prognosed the needed thrust. When data was normalized between 0 and 1, the average mean squared error was 0,0027 and the average root mean squared error was 0,0520.

KEYWORDS: machine learning, marine traffic, modelling, multivariable methods, power, propellers, ships, time series

Sisällys

1	Johdanto	8
2	Teoria	11
2.1	Meriliikenne ja päästövaatimukset	11
2.2	Aluksen geometria	12
2.3	Muut alueella tehdyt tutkimukset	12
2.4	Syväys ja trimmi eli viippaus	12
2.5	Matala vesi ja Frouden syvyyssluku	13
2.6	Biolikaantuminen	13
2.7	Reitinvalinta ja sääolosuhteet	14
3	Tapauksen esittely	16
3.1	Aurora Botnia	16
3.1.1	Voimanlähteet	16
3.1.2	Azipod	17
3.1.3	Nacos Platinum	17
3.2	Merenkurkku	17
3.3	Kasvusto	18
4	Työn data	19
4.1	Käytettävissä oleva data	19
4.2	Käytettävissä olevat muuttujat	19
4.2.1	Paikkaan ja nopeuteen liittyvät muuttujat	19
4.2.2	Syvyyteen ja asentoon liittyvät muuttujat	20
4.2.3	Tuuleen liittyvät muuttujat	20
4.2.4	Azipodeihin liittyvät muuttujat	20
4.2.5	Veteen liittyvät muuttujat	21
4.2.6	Pohjan pesuun liittyvä muuttuja	21
5	Datan käsittely	22
5.1	Käytetty ohjelmisto	22
5.2	Laskennalliset muuttujat	22

5.2.1	Frouden syvyyssluku	22
5.2.2	PowerSum	23
5.2.3	PowerEteen	23
5.2.4	PowerEro ja nopeusero	24
5.2.5	Lämpimätpäivät	24
5.3	Yhdistäminen ja käsittely	25
5.4	Käytettävän datan valikoiminen	26
6	Tulokset	30
6.1	Datan mallintaminen neuroverkolla	30
6.2	Datan mallintaminen lineaariregressiolla	34
7	Tulosten tarkastelu	38
8	Johtopäätökset	44
9	Yhteenveto	47
	Lähteet	49
	Liitteet	54
	Liite 1. Täydentäviä tuloksia	54
	Liite 2. Muuttujien yksiköt	58
	Liite 3. MATLAB-koodit: aineiston yhdistäminen	59
	Liite 4. MATLAB-koodit: laskennalliset muuttujat	65
	Liite 5. MATLAB-koodit: aineiston rajaamiseen käytettävät koodit	68
	Liite 6. MATLAB-koodit: tulosten laskeminen	72

Kuvat

Kuva 1. Aluksen liikennöintireitti, kun telakkakäynti on poistettu	27
Kuva 2. Reitti, kun telakkakäynti, suuret nopeuserot ja negatiiviset teho- ja nopeusarvot on poistettu	28
Kuva 3. Neuroverkon rakenne	31
Kuva 4. Yksittäisten muuttujien vaikutus työntötehoon neuroverkkomallissa	32
Kuva 5. Lineaariregression ennuste ja todelliset arvot	36
Kuva 6. Yksityiskohta ennustettujen ja todellisten arvojen kuvaajasta	37
Kuva 7. Muuttujien vaikutukset neuroverkossa, jossa on seitsemän kerrosta	42

Taulukot

Taulukko 1. Muuttujien kulmakertoimet neuroverkkomallissa	33
Taulukko 2. Lineaariregression muuttujien kulmakertoimet	35
Taulukko 3. Neuroverkkojen kerrosten lukumäärän vaikutus	41

Symbolit ja lyhenteet

Symbolit

α_p	paapuurin puolen Azipodin ohjauskulma
α_s	styyrpuurin puolen Azipodin ohjauskulma
F_r	Frouden syvyyssluku
h	veden syvyys
P_E	teho eteenpäin
P_p	paapuurin puolen teho
P_s	styyrpuurin puolen teho
P_{sum}	yhteenlaskettu teho
V	aluksen nopeus veden läpi

Lyhenteet

DWT	dead weight tonnage, kuollut paino, aluksen kantavuus eli aluksen lastin, polttoaineen, vesivarastojen, tarvikkeiden ja henkilöiden yhteispaino
GT	gross tonnage, bruttovetoisuus, yksikötön aluksen vetoisuuden suure
MAPE	mean absolute percentage error, prosentuaalinen keski-itseisvirhe
mpk	meripeninkulma, merimaili, 1852 m
MSE	mean squared error, keskineliövirhe
ps	port side, paapuuri
RMSE	root mean squared error, jäännösvirrehajonta
ro-ro	roll-on/roll-off eli aluksessa voidaan ajaa sen läpi pitkittäissuuntaisesti
RoPax-alus	roll-on/roll-off matkustaja-alus eli alus, jolla on mahdollista kuljettaa rah- tia ja matkustajia
sb	starboard, styyrpuuri

1 Johdanto

Meriteitä pitkin käydään noin 80–90 prosenttia maailmankaupasta. Merenkulku aiheuttaa noin kolme prosenttia globaaleista ihmisen toiminnasta aiheutuvista päästöistä (Ampah ja muut, 2021). Tulevaisuuden merenkulun tavoitteena on vähentää sen aiheuttamia ilmastopäästöjä merkittävästi aiempaan verrattuna. Vaihtoehtoisten polttoaineiden käyttämisen lisäksi on tärkeää vähentää käytettyä polttoainemäärää.

Kansainvälinen merenkulkujärjestö IMO (International Maritime Organization) päivitti heinäkuussa 2023 kasvihuonekaasustrategiansa. Sen tavoite on, että alusten kasvihuonekaasupäästöt ovat nettomääräisesti nolla vuoteen 2050 mennessä (International Maritime Organization, 2023a).

Alusten polttoaineenkulutuksella on merkittävä vaikutus merenkulun päästöihin. Kulku-
vastukseen ja sitä kautta polttoaineen kulutukseen vaikuttaa suuri joukko erilaisia asioita. Näitä asioita ovat aluksen pysyvät ominaisuudet, kuten rungon muoto ja paino, sekä muuttuvat ominaisuudet, kuten syväys ja trimmi (laivan eteen- tai taaksepäin kallistuneisuus). Lisäksi muuttuvia ominaisuuksia on laaja joukko erilaisia veteen ja säähän liittyviä mitattavia suureita, kuten tuulen nopeus ja suunta, veden suolaisuus ja lämpötila sekä vallitsevat virtaukset (Altarriba, 2020).

Myös aluksen biolikaantuminen vaikuttaa sen kulkuvastukseen. Biolikaantuminen tarkoittaa aluksen vedenalaisiin osiin kertyvää kasvustoa, kuten merirokkoja ja leviä. Tämä kasvusto vaihtelee paikallisesti sekä mahdollisesti vuodenaikojen mukaan. Kasvustoa voidaan poistaa joko telakalla tai vedessä tapahtuvan puhdistuksen avulla (Adland ja muut, 2018; Altarriba, 2021; Luoma ja muut, 2022).

Säännöllinen ja riittävän usein tapahtuva pohjan puhdistus paitsi vähentää polttoaineenkulutusta myös estää sen, että orgaaniset kasvustot eivät pääse kiinnittymään tiukasti. Tällöin pohja voidaan pestä hellävaraisemmin kuin tiukasti kiinnittyneiden organismien

poistaminen vaatisi, ja aluksen maalipinta ei kärsi. Tämä säästää kustannuksia ja helpottaa jatkossa tapahtuvaa pesua (Luoma ja muut, 2022).

Propulsio- eli työntötehon tarpeesta on tehty monia eri tutkimuksia. Myös tämän tutkimuksen kohteena olevaa, Merenkurkussa liikennöivää matkustaja-autolautta Aurora Botniaa on tutkittu (Häggman, 2022; Öztürk & Başar, 2022). Veden syvyyden vaikutusta ovat tutkineet muun muassa Nguyen ja muut (2019). Myös biolikaantumista ja sen vaikutusta polttoaineenkulutukseen on tutkittu paljon, mutta nämä tutkimukset keskittyvät lähinnä lämpimissä ja syvissä vesissä kulkeviin aluksiin. Biolikaantumisen vaikutus voi lisätä polttoaineenkulutusta lähteestä riippuen 4–59 % (Laurie ja muut, 2021; Uzun ja muut, 2019). Aluksista, jotka kulkevat matalissa vesissä tai osittain jäisissä olosuhteissa on vähän tutkimuksia (Hughes & Ashton, 2016).

Tämän diplomityön tavoitteena oli mallintaa Merenkurkussa, Vaasa-Uumaja -väliä, liikennöivän Aurora Botnia -aluksen propulsiotehon tarvetta lastaus- ja sääolosuhteet huomioon ottaen. Mallinnuksessa huomioitiin olosuhteiden lisäksi se, että osan reitistä alus kulkee matalassa vedessä. Tässä työssä keskityttiin työntötehon tarpeeseen eikä siihen, millaisella energialla tuo teho on saatu aikaiseksi, minkä mahdollisti Azipod-potkurilaitteelta saatu data.

Tarkoituksena oli selvittää, voidaanko tehontarvetta ennustaa pelkästään nykyaikaisten alusjärjestelmien datan ja vapaasti saatavilla olevan säädatan perusteella, koneoppimista hyödyntäen. Samalla selvitettiin, onko mallinnus mahdollista ilman syvällistä ymmärrystä työntötehoon vaikuttavista asioista ja laivageometrian huomiointia.

Aurora Botnian propulsiotehon mallintamiseen käytettiin MATLAB-ohjelmaa. Data mallinukseen saatiin Wasalinelta ja Wärtsilältä osana KvarkenData-projektia. Muu data oli Ilmatieteen laitoksen avoimista lähteistä noudettua säädataa. Mallinnuksessa käytettiin lineaarista regressiota ja keinotekoisia neuroverkkoja.

Ilmastonmuutoksen aiheuttama lämpeneminen vaikuttanee Itämeren alueen jääolosuhteisiin, jotka sitten voivat lisätä biolikaantumista ja hankaloittaa veneen pohjan pesua (Altarriba, 2021). Tämän vuoksi on hyvä pystyä ennakoimaan puhdistuksen tarvetta tarkemmin, ja siinä tämän tutkimuksen tulos voi auttaa.

Tämän työn luvussa kaksi perehdytään työhön liittyvään teoriaan ja aiempiin tutkimuksiin. Luvussa kolme on esitelty tutkittava tapaus ja luvussa neljä perehdytään tutkimuksen dataan. Luvussa viisi käydään läpi datan käsittelyyn liittyvät asiat. Luku kuusi kertoo tutkimuksen tulokset ja luvussa seitsemän analysoidaan saatuja tuloksia. Luvussa kahdeksan tarkastellaan tutkimuksesta tehtyjä johtopäätöksiä ja luvussa yhdeksän on työn yhteenveto.

2 Teoria

Erilaisten merenkulkualusten propulsiotehon tarvetta on tutkittu paljon ja erilaisista näkökulmista. Useat näistä tutkimuksista keskittyvät johonkin tiettyyn muuttujaan kuten polttoainevalintaan, trimmiin (viippaukseen), reittivalintoihin tai painolastiin (Ampah ja muut, 2021; Martić ja muut, 2024; Öztürk & Başar, 2022). On olemassa myös useita tutkimuksia, joissa mallinnetaan työntötehon tarvetta tai polttoaineen kulutusta erilaisia matemaattisia malleja käyttäen. Nämä mallit saattavat perustua joko aluksilta saatuun todelliseen dataan tai simuloituun dataan (Ampah ja muut, 2021; Martić ja muut, 2024; Öztürk & Başar, 2022).

2.1 Meriliikenne ja päästövaatimukset

Kansainvälinen merenkulkujärjestö IMO (International Maritime Organization) on Yhdistyneiden kansakuntien alainen erikoisjärjestö, joka käsittelee merenkulkuun liittyviä asioita. Muun muassa kansainväliseen merenkulkuun liittyvät turvallisuuskysymykset, meren saastumisen ehkäiseminen ja oikeudelliset kysymykset kuuluvat IMO:ssa käsiteltäviin asioihin (International Maritime Organization, ei pvm.-a).

IMO:n vuonna 2023 päivittämä kasvihuonekaasustrategia tavoittelee alusten nettonolapäästöjä vuoteen 2050 mennessä. Myös aluksen energiatehokkuuden parantamisen suunnittelun ohjeissa (SEEMP, Ship Energy Efficiency Management Plan) tarjotaan näkökulmia erilaisiin keinoihin vaikuttaa aluksen energiatehokkuuteen. Aluksen pohjan likaantumisen vaikutukset nostetaan esiin sekä energiatehokkuuden että vieraslajien leviämisen näkökulmasta (International Maritime Organization, 2022, 2023a, 2024).

2.2 Aluksen geometria

Aluksen geometria vaikuttaa merkittävästi sen kulkuvastukseen. Kokonaisuudessaan aluksen geometria on pysyvä eikä se varsinaisesti muutu. Toisaalta aluksen asento (trimmi ja kallistuneisuus) vaikuttaa vedessä olevan osan geometriaan kuin myös biolikaantumisen. Nämä ominaisuudet vaikuttavat kulkuvastukseen, mutta tässä tutkimuksessa niitä ei huomioida muuttuneen geometrian näkökulmasta eikä mitään aluksen fyysisiä ominaisuuksia kuten märkäpinta-alaa lasketa (Bertram, 2012; Molland ja muut, 2011).

2.3 Muut alueella tehdyt tutkimukset

Itämeren alueella on tehty alusten biolikaantumisen tutkimusta muun muassa osana Euroopan Unionin rahoittamaa, Interreg Baltic Sea Region -ohjelman COMPLETE-hanketta. Hankkeessa kiinnitettiin huomiota vieraslajien vaikutuksiin ja pintakäsittelymateriaalien myrkyllisyyteen, mutta myös eri tekijöiden vaikutusta alusten kulkuvastuksiin. Näissä tutkimuksissa kuitenkin jätettiin matalan veden alueet huomiotta ja tutkimukset on tehty jäätömään aikaan (Altarriba, 2020, 2021; Luoma ja muut, 2022). Tässä tutkimuksessa nämä näkökulmat kuitenkin otetaan huomioon.

2.4 Syväys ja trimmi eli viippaus

Syväys tarkoittaa aluksen keskilaivankaaren kohdasta mitattavaa pystysuoraa etäisyyttä aluksen alimmasta kohdasta vesilinjaan. Kullakin aluksella on oma nimellinen syväys, ja todellinen syväys riippuu aluksessa olevan lastin ja varustuksen painosta. Syväyksellä on merkittävä vaikutus kulkuvastukseen muuttuvan märkäpinta-alan vuoksi. Kasvavan märkäpinta-alan hydrodynaaminen vastus on selkeästi suurempi kuin vastaavasti pienenevän pinta-alan ilmanvastuksen väheneminen (Altarriba, 2021; International Maritime Organization, 2023b).

Trimmi tarkoittaa keulan ja perän syväyksien eroa ja se vaikuttaa aluksen kulkuvastukseen. Trimmiin vaikuttaa aluksen lastaus ja se on tapauskohtainen. Aurora Botnia ei pyyhdy välillä purkamaan lastia, joten aluksella on yksi lastauksesta riippuva trimmi kullekin matkalle. Perätrimmissä aluksen perän syväys on suurempi kuin keulan syväys ja trimmiarvo on negatiivinen. Keulatriimissä keulan syväys on suurempi kuin perän syväys ja trimmiarvo positiivinen (Le ja muut, 2021; Musulin ja muut, 2024; Rawson & Tupper, 2001).

2.5 Matala vesi ja Frouden syvyysluku

Matala vesi lisää kitkasta aiheutuvaa vastusta ja yleensä myös aaltojen vastusta. Kun Frouden syvyysluku on lähellä yhtä, vastus lisääntyy merkittävästi (Bertram, 2012). Matalan veden määritelmä riippuu kuitenkin sekä veden syvyydestä että aallonpituudesta. Täten ei voida yksiselitteisesti määrittää, mikä alue on matalan veden aluetta ja mikä syvän, vaan se riippuu sääolosuhteista (Nguyen ja muut, 2019).

Muut tutkimukset eivät tutki matalan veden alueita vaan rajaavat nämä pois. Aurora Botnia kulkee kuitenkin suuren osan reitistään matalassa vedessä, joten tässä tutkimuksessa tätä rajausta ei tehdä.

2.6 Biolikaantuminen

Biolikaantumisella (engl. biofouling) tarkoitetaan vedenalaisten rakenteiden likaantumista biologisesta aineksesta, kuten merirokosta ja levistä (Altarriba, 2021). Biolikaantuminen alkaa välittömästi, kun kohde on kosketuksissa veteen. Ensimmäisten minuuttien ja tuntien aikana pinnalle kehittyy orgaaninen kalvo ja tämän jälkeen muunlainen kasvusto ja eliöstö kehittyvät olosuhteista riippuen (Vinagre ja muut, 2020).

Veden suolaisuudella ja auringonvalolla on merkitys kasvuston lisääntymiseen. Murto-vettä suolaisemmissa vesissä kasvu on voimakkaampaa. Kasvu on voimakkainta lämpimissä pintavesissä. Auringonvalon aiheuttaman kasvun lisääntymisen vuoksi joskus alusten pohjia pestään vain muutaman metrin levyiseltä alueelta vesirajasta kohti pohjaa (Altarriba, 2021).

Biolikaantumisen vaikutusta on tutkittu paljon ja myös Itämerellä. Näistä tutkimuksista käy ilmi, että biolikaantuminen ei vaikuta ainoastaan aktiivisesti kulkuvastuksen lisääntymisenä vaan maalipinnan mahdollisen vaurioitumisen kautta myös välillisesti (Luoma ja muut, 2022). IMO:n ohjeessa suositellaan seuraamaan biolikaantumista ja tarvittaessa puhdistamaan pohjaa ja potkureita osittain tai kokonaan. Myös pohjan pinnan laadulla ja karkeudella todetaan olevan suora vaikutus tehontarpeeseen (International Maritime Organization, 2022). Altarriban (2021) tutkimuksessa käytettyjen alusten pesuväli perustui kokemusperäiseen havainnointiin ja se tehtiin kesäkaudella eli toukokuun alusta lokakuuhun 6–8 kertaa, joillain aluksilla jopa kahden viikon välein.

Biolikaantumisen ehkäisyyn käytetään usein erilaisia pinnoitteita, joiden laatu ja vaikutavuus vaihtelee paljonkin. Tässä tutkimuksessa ei kuitenkaan keskitytty pohjankäsittelyaineeseen, sillä aluksella oli koko ajan käytössä sama pinnoite eikä maalipintaa uusittu koejakson aikana.

Eräs biolikaantumisen näkökulmista on vieraslajien leviäminen. Tässä tutkimuksessa sitä ei oteta huomioon, sillä tutkittava alus liikkuu säännöllisesti edestakaisin reitillä, jonka pituus on vain noin 100 km, pysytellen hyvin samalla leveyspiirillä, joten lajisto on samankaltaista koko reitin matkalla.

2.7 ReitINVALINTA ja sääolosuhteet

Sääolosuhteet merellä vaikuttavat sekä suoraan polttoainenkulutukseen että mahdollisiin reittivalintoihin. Tutkimuksia esimerkiksi reittivalintojen tekemisestä sääennusteiden

perusteella on olemassa. Merivirrat ja virtaukset voivat vaihdella suurestikin erityisesti matalikkojen ja rantojen läheisyydessä ja niillä voi olla merkittäviä vaikutuksia vaadittavaan työntötehoon (Altarriba, 2020; Öztürk & Başar, 2022).

Tämän diplomityön kohteena olleen aluksen reittiin voidaan vaikuttaa ainoastaan avomerellä, sillä osassa reitistä väylät ovat kapeita ja vesistö ympärillä on matalaa. Reitin kokonaispituus on noin 53 merimailia, josta merikartan perusteella arvioiden korkeintaan kolmasosalla matkasta on edes teoriassa mahdollista tehdä reitinvalintaa.

3 Tapauksen esittely

Tutkimuksen kohteena oli Merenkurkussa liikennöivä alus Aurora Botnia. Alus liikennöi Vaasan ja Uumajan välillä kahdesta neljään kertaan vuorokaudessa, päivästä ja vuodenajasta riippuen. Aluksen reitti kulkee osittain Merenkurkun saariston Unescon maailmanperintökohteen alueella. Alue on tavallisesti talviaikaan jääpeitteinen.

3.1 Aurora Botnia

Aurora Botnia on Kvarken Link Ab Oy:n omistama alus. Kvarken Link Ab Oy:n omistavat tasaosuuksin Vaasan kaupunki ja Uumajan kunta. Toiminta tapahtuu Wasaline-nimen alla ja toiminnan taustalla on varustamoyritys NLC Ferry Ab Oy. Aurora Botnia on vuonna 2021 valmistunut monipolttoainelaiva ja maailman ympäristöystävällisemmäksi mainittu lastin ja matkustajien kuljettamiseen tarkoitettu alus eli RoPax-alus. Säännöllinen reittiliikenne alkoi lauantaina 28.8.2021 (DNV AS, 2022; Leiwo, 2021; Mäkinen, 2022).

Aurora Botnia on 150 m pitkä ja 26 m leveä alus, jonka syväys on 6 m. Sen kuollut paino (DWT) on 3500 tonnia ja bruttovetoisuus (GT) 24036. Alus kuuluu jääluokkaan 1A Super. Siinä on 1500 kaistametriä tilaa kuorma- ja henkilöautoille ja kapasiteetti 800 matkustajalle (DNV AS, 2022; Mäkinen, 2022). Alukselta kerätään paljon erilaista dataa sisäänrakennettujen anturien avulla.

3.1.1 Voimanlähteet

Aluksen pääasiallisina voimanlähteinä ovat neljä Wärtsilän 8V31DF monipolttoainemoottoria. Moottorit voivat käyttää dieselien lisäksi polttoaineena nesteytettyä maakaasua (LNG) ja biokaasua (LBG). Alusta voidaan ajaa yhden tai useamman moottorin voimalla (Wärtsilä, 2023, 2024a, 2024b).

Aluksella on myös kaksi Leclanchén 1,1 megawattitunnin litium-ioniakustoa, jota voidaan käyttää voimanlähteenä yhdessä monipolttoainemoottorien kanssa tai itsenäisesti. Eri-tyisesti satama-alueilla voimanlähteenä käytetään ainoastaan akkuja. Akkuja käytetään myös tehohuippujen tasaamiseen (Moore, 2021; Peter, 2021).

3.1.2 Azipod

Azipod on ABB:n valmistama potkurilaitte. Aurora Botnialla on käytössä kaksi 5,8 MW:n Azipod yksikköä. Kiinteälapaisia yksikköjä voidaan kääntää pysty akselinsa ympäri 360 astetta ja ne ovat jäävahvistettuja, Polar Code 6 -jääluokan vaatimusten mukaisia potkurilaitteita (ABB, 2020; International Association of Classification Societies, 2016; Wärtsilä, ei pvm.).

3.1.3 Nacos Platinum

Nacos Platinum on Wärtsilän navigointi- ja viestintäjärjestelmä, joka yhdistää navigoinnin, automaation, voimantuotannon ja propulsio-ohjausjärjestelmät. Järjestelmä on yhdistetty Wärtsilän Data Bridge -alustaan, mikä mahdollistaa alukselta saadun datan analysoinnin (Wärtsilä, 2019).

3.2 Merenkurkku

Merenkurkku on alue Pohjanlahdessa, Selkämeren ja Perämeren välissä. Merenkurkun saaristossa on Unescon maailmanperintökohdealue. Merenkurkku on matala ja kapea merialue ja maankohoaman vuoksi se madaltuu vuosittain. Alueen mataluus lisää alueen luonnon haavoittuvuutta ja vaikuttaa käytettävissä oleviin alusten pohjan puhdistustapoihin ja keinoihin suojella aluksen pohjaa biolikaantumiselta (Luoma ja muut, 2022; Suomen ympäristökeskus, 2023).

Alueen mataluus vaikuttaa merkittävästi myös aluksen kulkuvastukseen (Nguyen ja muut, 2019). Aluksen reitillä on datan mukaan vettä kölin alla pienimmillään 2,8 metriä ja suurimmillaan 140 metriä.

3.3 Kasvusto

Merenkurkussa elää murtovesialueen eliöitä, joista joillekin Merenkurkku on niiden pohjoisin levinneisyysalue. Biolikaantumista aiheuttavia eliöitä on vähemmän kuin Merenkurkun vettä lämpimämmissä ja suolaisemmissa vesissä, mutta erilaiset levät ja esimerkiksi merirokko kuitenkin aiheuttavat näkyvääkin biolikaantumista vedenalaisissa rakenteissa (Luoma ja muut, 2022; Metsähallitus & Suomen ympäristökeskus, 2024).

Aurora Botniasta kasvusto poistetaan 1–2 kertaa vuodessa, yleensä heinäkuussa ja toisinaan myös marraskuussa. Tällöin koko aluksen pohja pestään harjaamalla. Alus puhdistetaan vedessä (B. Holmblad, sähköpostikeskusteluja, 30.8.2024–29.10.2024).

4 Työn data

Aurora Botnia -alukselta kerätään monenlaista dataa. Tähän työhön käytettiin osaa tuosta datasta. Ilmatieteen laitoksen avointa dataa on myös paljon saatavilla ja sitä hyödynnettiin myös. Toisissa tutkimuksissa (Saukko, 2020) ilmi tulleet ongelmat, kuten datan hajanaisuus, sisältö, määrä ja muoto, eivät tässä tapauksessa olleet ongelmia, sillä kaikki tieto alukselta tuli saman järjestelmän kautta. Kun kaikki omistajuuteen ja salassapitovelvollisuuteen liittyvät asiat saatiin sovittua yritysten ja yliopiston kesken, eivät neekään tuottaneet hankaluuksia.

4.1 Käytettävissä oleva data

Tutkimuksessa käytettiin Wärtsilän Nacos-järjestelmän kautta saatua dataa. Tarkemmat kuvaukset käytössä olleista muuttujista on selitetty seuraavassa alaluvussa. Säädata saatiin Ilmatieteen laitoksen kahdelta eri meripoijuilta. Toinen poijuista on Maalahden Storskäretin pintalämpötilapoiju ja toinen on Selkämerellä, noin 60 km:n päässä Suomen rannikosta sijaitseva aaltopoiju (Ilmatieteen laitos, ei pvm.-a, ei pvm.-b).

4.2 Käytettävissä olevat muuttujat

Käytettävissä olevien muuttujien nimet tulivat Wärtsilän Nacos-järjestelmästä ja ne on esitelty tässä sellaisinaan. Muuttujien yksiköt löytyvät liitteestä 2. Myös säädataan liittyvät muuttujanimet tulivat nimettyinä datan lataamisen myötä.

4.2.1 Paikkaan ja nopeuteen liittyvät muuttujat

Aluksen sijaintia merellä ilmaisevat muuttujat latitude ja longitude. Latitude ilmaisee leveysasteet (latitudi) ja longitude pituusasteet (longitudi). Arvot saadaan Nacos-järjestel-

mästä desimaalimuodossa. Sog tulee sanoista speed over ground, ja se kuvaa aluksen nopeutta maan suhteen. Stw tulee sanoista speed through water, ja se on aluksen nopeus veden suhteen. Aluksen kulkusuunnasta kertoo kaksi muuttujaa. Cog (course over ground) on aluksen kurssi maan suhteen ja heading aluksen kompassisuunta.

4.2.2 Syvyyteen ja asentoon liittyvät muuttujat

Muuttuja depth eli syvyys tarkoittaa veden syvyyttä kölin alta meren pohjaan mitattuna. Draught tarkoittaa laivan syväästä. Se kertoo kuinka syvällä vedessä alus ui. Se mitataan vesilinjasta pystysuoraan laivan alimpaan kohtaan. Trim eli trimmi eli viippaus tarkoittaa aluksen keula- ja peräsyväyksen välistä eroa. Mikäli luku on positiivinen, on keulan syväys suurempi kuin perän. Luvun ollessa negatiivinen on tilanne päinvastainen (International Maritime Organization, ei pvm.-b; Le ja muut, 2021).

4.2.3 Tuuleen liittyvät muuttujat

Tuulen suuntaan ja nopeuteen liittyviä ominaisuuksia on kuusi: angle wind relative, angle wind true, direction wind relative, direction wind true, speed wind relative ja speed wind true. Kukin ominaisuudesta ilmaistaan kahdella eri muuttujalla, suhteellinen (relative) ja tosi (true). Angle ottaa huomioon aluksen suunnan ja direction on se ilmasuunta, josta tuuli käy. Speed ilmoittaa tuulen nopeuden.

4.2.4 Azipodeihin liittyvät muuttujat

Azipodeihin liittyviä muuttujia on kuusi erilaista: powerpropulsion ps, powerpropulsion sb, rpmpropulsion ps, rpmpropulsion sb, AZP_P_steeringangle ja AZP_S_steeringangle. Paapuurin puolelle (ps tai _P_) on omansa ja styyrpuurin puolelle (sb tai _S_) omansa. Powerpropulsion ilmoittaa tehon, rpmpropulsion potkurin kierrosluvun ja steeringangle ohjauskulman.

4.2.5 Veteen liittyvät muuttujat

Veden lämpötila celsiusasteina saatiin kahdesta eri mittauspisteestä. VedenLmptilaC_ML on Maalahdesta mitattu tulos ja se saatiin Ilmatieteenlaitoksen Storskäretin pintalämpötilapoijusta. Poiju on ankkurointia varten muokattu MetOceanin iSVP-poiju, jonka U.S.Sensorin valmistaman anturin tarkkuus on valmistajan mukaan 0,05 °C ja käytännössä n. 0,2 °C (Ilmatieteen laitos, ei pvm.-b).

Muuttuja VedenLmptilaC_SM saatiin Selkämerellä sijaitsevasta aaltopoijusta. Tästä poijusta saatiin myös aaltoihin liittyvät muuttujat merkitsevä aallonkorkeus, aallokon tulo-suunta ja aallokon modaalinen periodi. Selkämeren poiju on Directional Waverider -aaltopoiju, ja se mittaa aallokkoa kompassin ja kiihtyvyyssantureiden avulla. Veden lämpötila mitataan noin 0,4 m pinnan alapuolelta. Aaltopoiju on ankkuroitu Selkämerelle alueelle, jossa merenpohjan syvyys on noin 120 m (Ilmatieteen laitos, ei pvm.-a, ei pvm.-b).

4.2.6 Pohjan pesuun liittyvä muuttuja

Päiviä pesusta -muuttuja kertoo edellisestä pesupäivästä kuluneiden päivien lukumäärän. Wasaline antoi tiedot aluksen pesupäivistä (B. Holmblad, sähköpostikeskusteluja, 30.8.2024–29.10.2024).

Lisäksi käytössä olisi ollut akustoon liittyvää dataa, mutta tätä dataa ei käytetty, sillä työssä ei keskitytty siihen, mistä lähteestä energia saadaan. Samasta syystä, ja aineiston salaisuuden vuoksi, myöskään polttoaineen massoihin ja tilavuuksiin liittyvää dataa ei käytetty. Kuten ei myöskään tarkkailtu kunkin moottorin tuottamaa tehoa.

5 Datan käsittely

Tässä työssä datan käsittelyyn valittiin MATLAB, sillä se soveltui suuren datamäärän hallintaan ja yhdistämiseen. Nacos-järjestelmästä saatu data oli aikaleimattua, joten muun datan yhdistäminen siihen onnistui MATLABilla. Datan esikäsittely ennen mallintamista parantaa merkittävästi mallinnuksesta saatavia tuloksia (Laurie ja muut, 2021).

5.1 Käytetty ohjelmisto

Datan käsittelyssä käytettiin MATLAB-ohjelmaa ja sen versiota 9.14.0.2254940 (R2023a) Update 2. Data saatiin erilaisissa tiedostomuodoissa, kuten Excel-muotoisena, ja tämä data siirrettiin MATLABiin.

5.2 Laskennalliset muuttujat

Saadun datan lisäksi taulukkoon lisättiin joitain laskennallisia muuttujia. Tämä siksi, että vaikka neuroverkot osaavatkin luoda erilaisia riippuvuuksia muuttujien välillä, näin ei välttämättä ole lineaariregressiota tehtäessä. Toinen syy on se, että joitakin valmiiksi laskettuja muuttujia on helpompi vertailla ja ymmärtää kuin erillisiä sarakkeita. Laskennallisia muuttujia voidaan myös helposti käyttää hyväksi datan rajausta tehtäessä. Laskennallisten muuttujien MATLAB-koodit on esitetty liitteessä 4.

5.2.1 Frouden syvyyssluku

Frouden syvyyssluku on yksikötön luku, joka kertoo aluksen nopeuden suhteesta veden syvyyteen. Frouden syvyyssluku lasketaan kaavalla

$$F_r = \frac{V}{\sqrt{hg}}, \quad (1)$$

missä F_r tarkoittaa Frouden syvyytlukua, V aluksen nopeutta veden läpi (m/s), h aluksen kölin alla olevan veden syvyyttä (m) ja g gravitaatiokiihtyvyyttä (m/s²). Frouden luku lasketaan suoraan MATLABiin siirrettyssä datataulukossa, joten lukujen pyöristetyt arvot ovat Wärtsilän järjestelmän antamia arvoja. Gravitaatiokiihtyvyytenä käytettiin lukua 9,81 m/s². Wärtsilän järjestelmä antaa nopeuden veden läpi solmuina eli meripeninkulmina tunnissa, ja tämä muutetaan yksikköön metriä sekunnissa kaavalla

$$V_{m/s} = V_s \frac{\frac{1852m}{3600s}}{h}, \quad (2)$$

missä $V_{m/s}$ tarkoittaa nopeutta yksikössä metriä sekunnissa ja V_s tarkoittaa nopeutta solmuina. Mpk on meripeninkulma.

5.2.2 PowerSum

Työntötehoihin liittyvä laskennallinen muuttuja on PowerSum. Tämä muuttuja on laskettu yksinkertaisesti yhdistämällä styyrpuurin ja paapuurin puoleisten Azipodien antama teho. Kaavalla ilmaistuna

$$P_{sum} = P_s + P_p, \quad (3)$$

missä P_{sum} on yhteenlaskettu teho, P_s on styyrpuurin puoleisen Azipodin teho ja P_p on paapuurin puoleisen Azipodin teho.

5.2.3 PowerEteen

Toinen tehoihin liittyvä laskennallinen muuttuja on PowerEteen-muuttuja. Tämä muuttuja on laskettu siten, että on otettu kummankin Azipodin (styyrpuurin ja paapuurin) tuottama teho ja niiden kulma rungon suhteen. Kulmat 0° ja 360° tarkoittavat samaa.

Tällöin Azipod-potkurien tuottama teho suuntautuu suoraan taaksepäin eli alusta eteenpäin työntäen. Kulman asteluku suurenee myötäpäivään käännettäessä.

PowerEteen on laskettu kaavalla

$$P_E = P_s \cdot \cos \alpha_s + P_p \cdot \cos \alpha_p, \quad (4)$$

missä P_E on teho eteenpäin, α_s on styyrpuurin puoleisen Azipodin kulma ja α_p on paa-puurin puoleisen Azipodin kulma. Vaikka matemaattinen asteluku lisääntyy vastapäivään pyörittäessä ja tässä myötäpäivään pyörittäessä, kosinifunktio antaa silti oikean arvon suhteessa tehon suuntaan.

5.2.4 PowerEro ja nopeusero

Muuttuja PowerEro laskee eteenpäin työntävän ja yhteenlasketun työntötehon välisen erotuksen itseisarvon. Vastaavasti nopeusero laskee erotuksen itseisarvon muuttujien sog ja stw välillä.

5.2.5 Lämpimätpäivät

Lämpimätpäivät (lampimatpaivat) laskee perättäisten lämpimien päivien määrää Maa-lahden sääpoijun lämpötilatiedoista. Kyseinen lämpimäksi ajateltu lämpötila määrätään ohjelmaa kutsuttaessa. Tämä muuttuja luotiin sen takia, että veden lämpötila vaikuttaa muun muassa merirokon lisääntymiseen (Nasrolahi ja muut, 2012) ja haluttiin tutkia, näkyykö tämä jollakin tavalla tuloksissa.

5.3 Yhdistäminen ja käsittely

Wärtsilän järjestelmästä saatu data, Wasalinelta saatu data ja Ilmatieteen laitoksen avoimesta lähteestä saatavilla oleva data yhdistettiin yhdeksi taulukoksi. Taulukkoa on täydennetty, sillä Wärtsilältä saatu data sisältää tietoa 30 sekunnin välein, säädata tunnin välein ja pesupäivätaulukko päivän välein. Kaikki kerätty data yhdistettiin taulukoksi AB.

Sääpoijujen antamia tietoja on käsitelty siten, että niinä päivinä, kun dataa on olemassa, on väli edelliseen arvoon interpoloitu lineaarisesti. Niiltä päiviltä, kun dataa ei ole olemassa, on arvoksi merkitty NaN (Not a Number). Sääpoijujen antamia tietoja ei ole tallennettu.

Wasalinelta pesupäivistä saatujen tietojen pohjalta muodostettiin oma rivi taulukkoon. Jäiden aluksen pohjaa biolikaantumisesta puhdistava vaikutus huomioitiin siten, että jäisten aikojen ”päiviä pesusta” -arvoksi merkittiin nolla. Jäiset ajat määrättiin ilmatieteen laitoksen avoimen datan jäätalvitilaston perusteella Vaasan sataman jäätietojen mukaan (Ilmatieteen laitos, ei pvm.-c).

On myös huomioitava, että ensimmäisen vuoden ”päiviä pesusta” -muuttuja ei pidä täsmällisesti paikkansa. Alus on ollut vedessä jo ennen liikennöintiä ja ensimmäiseksi ”pesupäiväksi” on merkitty saadun datan ensimmäinen päivä. Ensimmäinen päivä, jolloin alukselta on paikkadataa, on 18.6.2021, jolloin dataa oli jo 18 päivän ajalta ja päiviä pesusta siis arvolla 18. Ei tiedetä täsmälleen, kuinka kauan alus on ollut vedessä Rauman telakalla. Biolikaantumisen näkökulmasta on otettava huomioon myös se, että telakka-alueella biolikaantuminen voi tapahtua eri tavalla kuin liikennöivään alukseen.

Taulukkoon lisättiin myös laskennalliset muuttujat. Kun kaikki käytettävissä oleva data yhdistettiin, oli käytössä 53 eri muuttujaa ja yli kolme miljoonaa (3146173) näytettä. Näistä 53 muuttujasta kahdeksan oli laskennallisia ja muut olivat joko avoimesta lähteestä tai yhteistyötahojen tarjoamia. Tästä datasetistä oleellisen tiedon valikoiminen oli yksi hankaluuksista, joka muiden tutkimusten (Laurie ja muut, 2021; Saukko, 2020) pe-

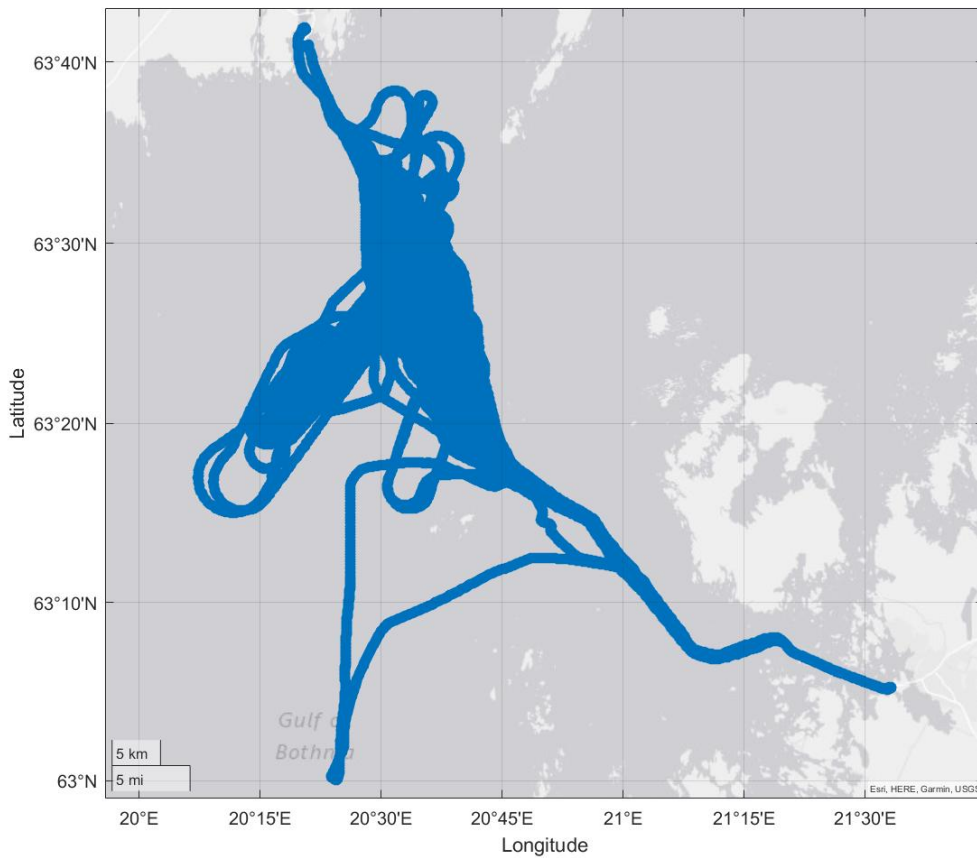
rusteella oli odotettavissa. Kaikki datan yhdistämiseen liittyvät koodit on eritelty tarkemmin liitteessä 3. Laskennallisten muuttujien koodit ovat liitteessä 4.

5.4 Käytettävän datan valikoiminen

Datan suuren määrän vuoksi esimerkiksi MATLABin valmiita funktioita, kuten satunnainen metsä -menetelmän TreeBagger-toteutusta, ei ollut tässä tapauksessa mahdollista käyttää. Aluksi dataa rajattiinkin muilla perusteilla.

Ensin rajattiin pois se data, joka oli ajalta ennen kuin alus aloitti säännöllisen reittiliikenteen. Datan perusteella liikennöinti Vaasan ja Uumajan välillä alkoi 27.8.2021 klo 10.14. Toinen ajan perusteella pois rajattu data liittyi aluksen telakkakäyntiin. Lisäksi poistettiin selkeät mittapoikkeamat, kuten ohjauskulmat, jotka olivat yli 360° ja syväykset, jotka olivat yli 30 m, sekä rivit, joilla näiden muuttujien arvo oli NaN.

Pois rajattiin myös ne sarakkeet, joiden tietoja ei joko tarvittu tai haluttu käyttää. Näitä sarakkeita olivat polttoaineeseen ja akustoon liittyvät sarakkeet sekä laskennalliset apusarakkeet styyrpuurin ja paapuurin eteenpäin työntävälle teholle. Näiden poistojen jälkeen taulukon AB koko oli 2874610x41. Tästä datasta on piirretty kuva 1, jossa näkyy aluksen reitti kartalla.




Kuva 1. Aluksen liikennöintireitti, kun telakkakäynti on poistettu

Datasta poistettiin myös kaikki sellainen data, jossa aluksen nopeus veden läpi oli negatiivinen, sekä sellainen data, joissa työntöteho oli negatiivinen. Rivit, joilla aluksen nopeus maan suhteen ja aluksen nopeus veden suhteen erosivat enemmän kuin yhden solmun, poistettiin myös. Tämä rajausta tehtiin siksi, että aluksen potkurit voivat tuottaa työntötehoa mihin suuntaan tahansa ja täten aluksen nopeus veden suhteen, joka yleensä ilmaisee veden virtauksien voimakkuutta, ei välttämättä pidä paikkansa. Tämä ilmeni muun muassa tilanteissa, joissa alus oli paikoillaan laiturissa eli nopeus maan suhteen oli nolla solmua, mutta nopeus veden suhteen esimerkiksi -1 solmu.

Rajanopeudeksi valikoitui yksi solmu, sillä Ilmatieteen laitoksen mukaan tyypilliset virtaukset Itämeressä ovat 5–10 senttimetriä sekunnissa ja myrskyissä voidaan saavuttaa

50 senttimetrin sekuntinopeus. Tämä nopeus vastaa noin yhtä solmua (Ilmatieteen laitos, 2022). Näiden rajausten jälkeen taulukon AB koko oli 15566046x41. Tämän datajoukon perusteella on piirretty kuva 2.



Kuva 2. Reitti, kun telakkakäynti, suuret nopeuserot ja negatiiviset teho- ja nopeusarvot on poistettu

Koska Merenkurkun alue on monella tapaa erityinen, on tämän tutkimuksen tuloksia mielenkiintoisia verrata valtamerellä tehtyihin tutkimuksiin. Laurie ja muut (2021) käyttivät tutkimuksessaan kahdeksaa parametriä. Nämä muuttujat olivat nopeus veden suhteen, suhteellinen tuulennopeus, meren lämpötila, trimmi, syväys, Frouden syvyysluku, merkitsevä aallonkorkeus ja päiviä pesusta.

Suurimmat korrelaatiokertoimet PowerEteen-muuttujan suhteen olivat PowerSum, stw, sog, Frouden syvyytluku, syvyys, suhteellinen tuulennopeus, kompassisuunta, syväys, todellinen tuulennopeus, aluksen kurssi maan suhteen ja päiviä pesusta. Näissä korrelaatiokerroin oli enemmän kuin 0,05. Pienemmät kuin -0,05 korrelaatiokertoimella olevat muuttujat olivat todellinen tuulensuunta, longitudi ja trim. Merkittävin ero Laurien ja muiden (2021) käyttämiin muuttujiin oli merkitsevä aallonkorkeus, jonka korrelaatiokerroin oli lähellä nollaa sekä veden lämpötilat.

Kompassisuunnan, aluksen kurssin maan suhteen, longitudin ja syvyyden vaikutusta korrelaatioon saattaa osittain selittää se, että alus kulkee hyvin täsmällisesti samalla reitillä ja syvimmän veden alueella alus kulkee nopeimmin. Veden lämpötilan vaikutus ja merkitsevä aallonkorkeus otettiin mukaan, vaikka niiden korrelaatiokertoimet eivät olleetkaan suuria. Tässä tutkimuksessa päädyttiinkin valitsemaan käytettäviksi muuttujiksi samat muuttujat, joita Laurie ja muut (2021) ovat tutkimuksessaan käyttäneet.

Kun seurattavat muuttujat oli valittu, poistettiin vielä ne rivit, joista puuttui jokin muuttujan arvo. Jos käytetään Maalahden poijun lämpötiloja, samalla kun poistetaan ne rivit, joilla lämpötilamuuttujalla ei ole arvoa, poistuvat jäätalvet. Kun lämpötilana käytettiin Maalahden poijun lämpötilaa, rivejä oli jäljellä 790659. Mallinnusta varten aineisto normalisoitiin kaavalla, joka löytyy liitteestä 5.

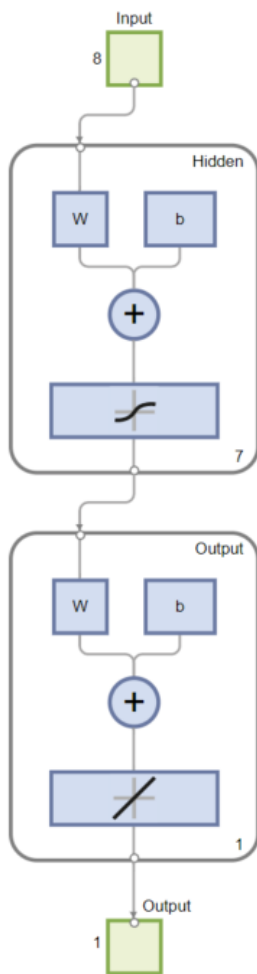
6 Tulokset

Valittua dataa mallinnettiin kahdella eri tavalla: keinotekoisella neuroverkolla ja lineaari-regressiolla. Kummallakin mallinnustavalla osa aineistosta käytettiin mallin kouluttamiseen ja osa arviointiin, vaikka keskenään hieman eri tavalla.

6.1 Datan mallintaminen neuroverkolla

Datan mallintamiseen MATLABilla käytettiin Levenberg-Marquardt-algoritmia neuroverkon kouluttamiseen. Levenberg-Marquardt-algoritmi on muunnelma Newtonin menetelmästä, ja soveltuu hyvin käytettäväksi neuroverkoissa, joissa suorituskkyä arvioidaan keskineliövirheen avulla. MATLABissa algoritmi on erityisen tehokas, sillä se perustuu sisäänrakennettuihin funktioihin ja täten laskenta on nopeampaa ja tarkempaa kuin manuaalisilla toteutuksilla (Hagan ja muut, 2014; MATLAB, ei pvm.).

Neuroverkossa käytettiin yhtä piilokerrosta. Ohjelma jakaa datan satunnaisesti kolmeen eri aineistoon: koulutus-, testaus- ja arviointiaineistoon. Koulutusaineisto sisältää 70 % koko aineistosta, ja testaus- ja arviointiaineisto sisältävät kumpikin 15 % aineistosta. Kun koko aineisto koulutetaan viisi kertaa, saadaan keskiarvoiseksi keskineliövirheeksi (MSE = mean squared error) 0,00268 ja korrelaatiokertoimeksi (R) 0,97774. Taulukko tuloksista löytyy liitteestä 1. Kuvassa 3 on esitetty neuroverkon rakenne MATLABin kuvaamana.

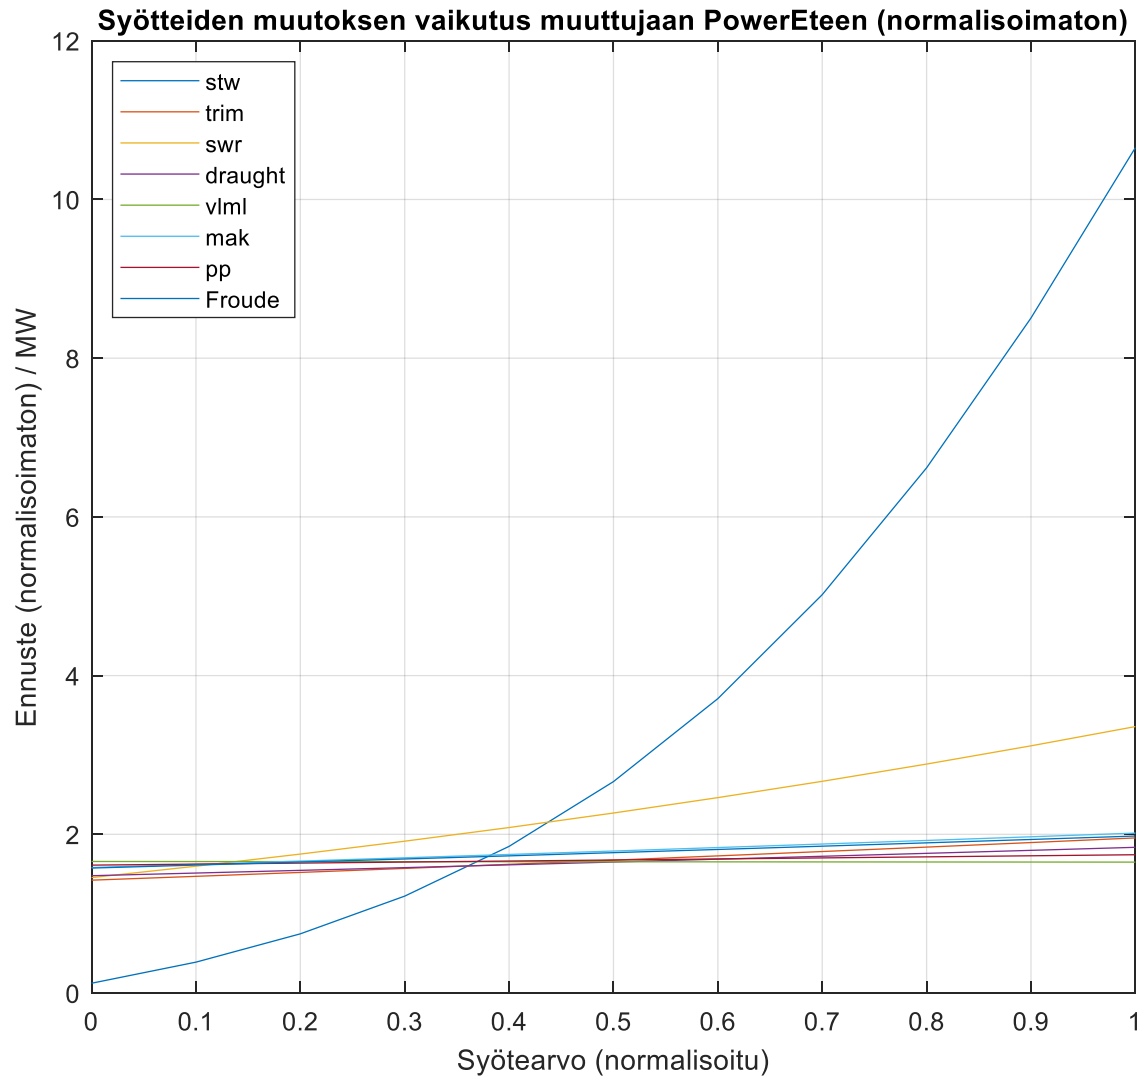


Kuva 3. Neuroverkon rakenne

Neuroverkossa on kahdeksan syötettä ja yksi tulos (vihreät laatikot). Piilokerros sisältää painot (W), sisäiset korjaustekijät (b), summauksen ja aktivointifunktion. Kerroksessa on seitsemän painoelementtiä (Weight Elements). Tuloskerros sisältää painot, sisäiset korjaustekijät ja summauksen, mutta ei funktiota. Tuloskerros tuottaa yhden tuloksen.

Kunkin muuttujan vaikutusta propulsiotehon tarpeeseen tutkittiin siten, että kaikista muuttujista laskettiin keskiarvo ja yhtä muuttujaa kerrallaan muuttamalla kokeiltiin neuroverkkomallia siten, että ajettiin kyseisen muuttujan arvot minimistä maksimiin. Normalisoidun datan tapauksessa minimi oli nolla ja maksimi oli yksi. Kukin muuttuja ajettiin

erikseen ja kaikki kuvaajat piirrettiin kuvaan 4 siten, että vaaka-akseli on normalisoitu ja pystyakselilla on normalisoimattomat arvot.



Kuva 4. Yksittäisten muuttujien vaikutus työntötehoon neuroverkkomallissa

Kuvasta 4 voidaan todeta, että kaikki muut käyrät ovat suoria tai lähes suoria, paitsi nopeus veden läpi. Toinen kuvasta selkeästi muista erottuva suora on suhteellista tuulennopeutta ilmaiseva muuttuja. Muiden muuttujien sijoittuminen hyvin lähelle toisiaan käy ilmi myös niiden kulmakertoimista. Taulukossa 1 on esitetty kunkin muuttujan laskennallinen kulmakerroin ja lisäksi MATLABin polyfit-funktiolla laskema kulmakerroin sekä normalisoidulle että normalisoimattomalle kohdemuuttujalle.

Taulukko 1. Muuttujien kulmakertoimet neuroverkkomallissa

Nimeke, muuttuja	Laskettu keskiarvo	Polyfit-keskiarvo	Normalisoimaton polyfit-keskiarvo
stw, nopeus veden läpi	0,93397	0,90493	10,19040
trim, viippaus	0,04728	0,04726	0,53213
swr, suhteellinen tuulennopeus	0,17087	0,17036	1,91850
draught, syväys	0,03320	0,03319	0,37380
vlml, veden lämpötila Maalahti	-0,00093	-0,00093	-0,01045
mak, merkitsevä aallonkorkeus	0,03833	0,03833	0,43159
pp, päiviä pesusta	0,01130	0,01130	0,12721
Froude, Frouden syvyysluku	0,03509	0,03508	0,39504

Laskettu keskiarvo on laskettu mallin antaman pienimmän ja suurimman ennusteen välisistä arvoista. Kuvaajasta voidaan todeta, että nämä arvot ovat kunkin suoran ensimmäinen ja viimeinen arvo. Kaikki laskentaan käytetyt luvut on esitetty liitteessä 1. Polyfit-keskiarvo on vähintään kolmen desimaalin tarkkuudella sama kuin laskennallinen keskiarvo kaikilla muilla muuttujilla paitsi nopeudella, ja myös tämä voidaan kuvasta nähdä. Normalisoimattoman polyfit-keskiarvon voidaan katsoa kertovan suoraan suurimman muutoksen tehontarpeeseen (megawatteina), minkä kukin muuttuja voi aiheuttaa.

Merkittävin vaikutus tehontarpeeseen on siis nopeudella veden läpi ja seuraavaksi ensiten vaikuttaa suhteellinen tuulennopeus. Viippaus ja merkitsevä aallonkorkeus sekä Frouden syvyysluku ja syväys ovat seuraavaksi merkittävimmät. Pohjan puhtauden merkitys on tämän tutkimuksen mukaan enintään 0,13 megawattia lisääntynyt tehontarve muiden muuttujien ollessa keskimääräisiä. Veden lämpötilalla ei ole suurta merkitystä.

6.2 Datan mallintaminen lineaariregressiolla

MATLABin komento `fitlm` sovittaa lineaariregressiomallin annettuun dataan. Dataa voi mallintaa monella tapaa, mutta tässä päädyttiin erilaisten kokeilujen jälkeen malliin, jossa kaikki muut muuttujat ovat ensimmäisen asteen muuttujia, mutta nopeudesta veden suhteen ja suhteellisesta tuulennopeudesta käytetään myös toisen asteen muuttujaa.

Jokaista valittua kahdeksaa muuttujaa ajettiin kolmella eri vaihtoehdolla (esimerkiksi stw , stw^2 ja stw^3), josta sitten valittiin sopivin ja edettiin seuraavaan muuttujaan. Merkittävin ero oli ensimmäisen ja toisen ajon välillä, joissa vertailtiin nopeuksia stw ja stw^2 . Muissa ajoissa kaikkien muuttujien osalta vaihtelu oli melko pientä. Koska koulutuksessa valitaan satunnaisesti koulutus- ja testiaineisto, niin kullakin kerralla tulos oli hieman eri. Tämä tuloksen vaihtelu näkyy arvojen kolmannessa ja neljännessä desimaalissa eli samoissa kohdissa kuin keskinäisen koulutuksen eroissa. Mahdollisimman yksinkertainen ja riittävän tarkasti toimiva malli saatiin siis valitsemalla muuttujista nopeus veden suhteen ja suhteellinen tuulennopeus ensimmäisen ja toisen potenssin muuttujat ja muista ainoastaan ensimmäisen potenssin muuttujat. Muuttujien valintamenettely on esitelty tarkemmin liitteessä 1.

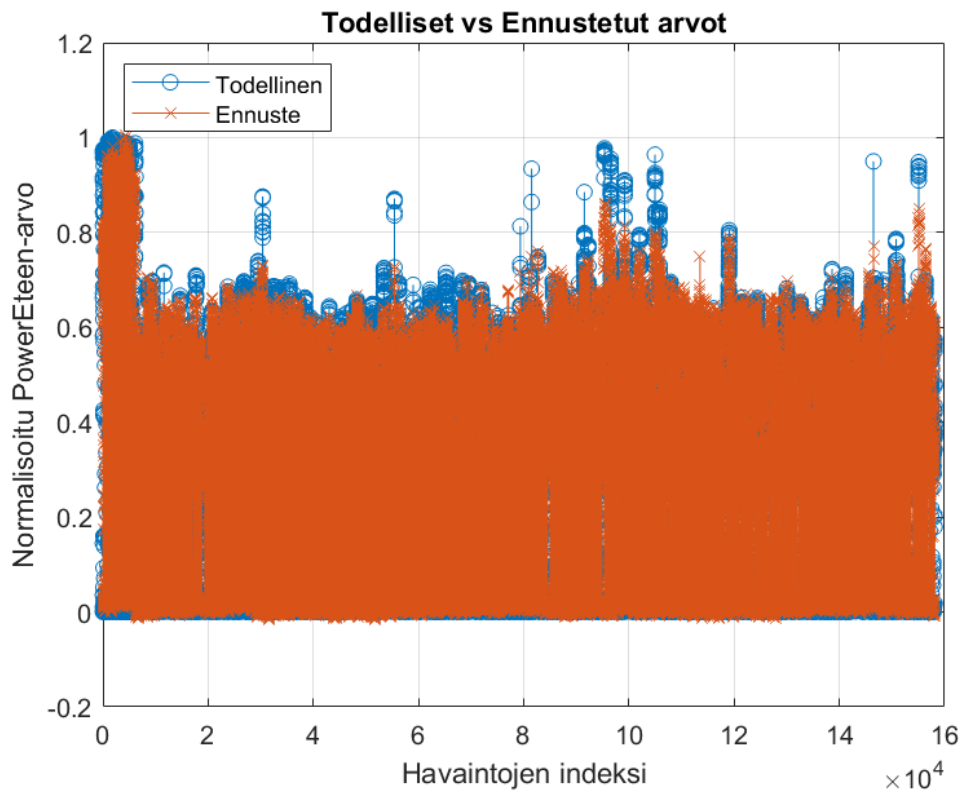
Koulutus tehtiin siten, että koko datasta valittiin satunnaisesti 80 % koulutusaineistoksi ja 20 % testiaineistoksi. Tuloksena saatiin kullekin muuttujalle kulmakerroin. Satunnaisotannon vuoksi nämä kulmakertoimet vaihtelevat hieman, joten kaikille kertoimille laskettiin keskiarvo. Myös mallin hyvydestä kertovat arvot keskineliövirhe, jäännösvirnehajonta, selitysaste ja korjattu selitysaste vaihtelevat hieman ja näistäkin laskettiin keskiarvo. Tarkemmat laskelmat ovat liitteessä 1. Mallin keskiarvoinen keskineliövirhe on 0,0027 ja jäännösvirnehajonta 0,0520. Selitysaste R^2 -arvon keskiarvo on 0,9554, kuten myös korjatun R^2 selitysasteen. Taulukossa 2 näkyy keskiarvo kustakin tutkitun muuttujan kulmakertoimesta eli vaikutuksesta kohdemuuttujaan.

Taulukko 2. Lineaariregression muuttujien kulmakertoimet

Nimeke, muuttuja	Laskettu keskiarvo
intercept, akselin leikkauspiste (vakiotermi)	-0,0420
stw ja stw ² , nopeus veden läpi	-0,1642 stw + 1,0888 stw ²
trim, viippaus	0,0728
swr ja swr ² , suhteellinen tuulennopeus	-0,2382 swr + 1,3340 swr ²
draught, syväys	0,0379
vlml, veden lämpötila Maalahti	-0,0028
mak, merkitsevä aallonkorkeus	0,0199
pp, päiviä pesusta	0,0158
Froude, Frouden syvyysluku	0,0792

Muuttujista, joista on käytössä myös toisen asteen muuttuja, on huomattavaa, että ensimmäisten asteiden kulmakertoimet ovat negatiiviset ja täten nopeuksien vaikutusta arvioitaessa on otettava kumpikin muuttujatekijä huomioon.

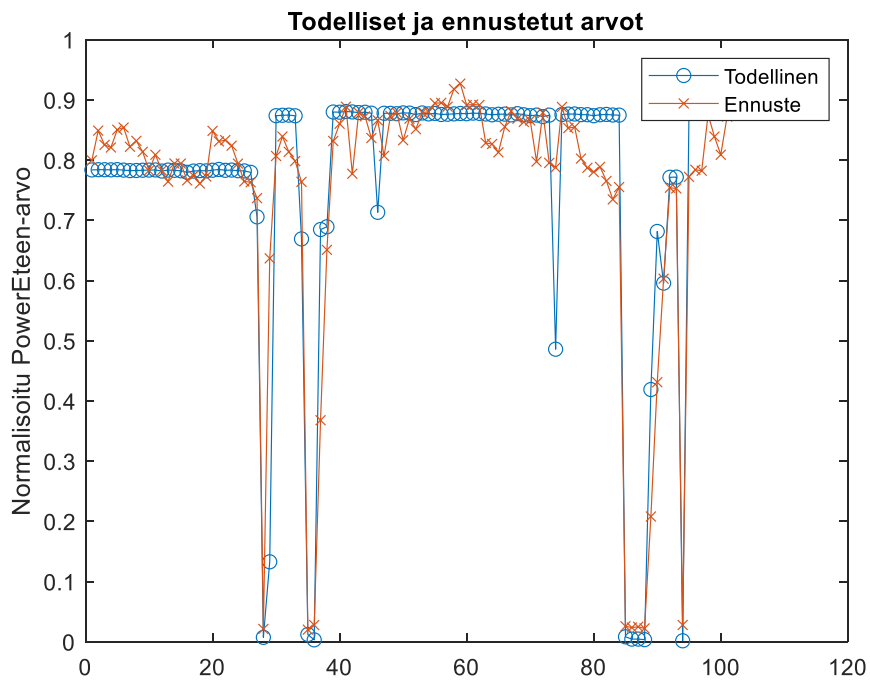
Yhden koulutuksen tulokset ovat kokonaisuutena liitteessä 1 ja siitä on nähtävissä, että muidenkin arvojen (standardivirhe, t-arvo ja todennäköisyysarvo) mukaan malli ennustaa hyvin mitattuja arvoja eikä kyse ole sattumasta, ja merkittävimmät muuttujat ovat samat, joilla on suurimmat kertoimet. Kuvassa 5 on erään koulutuksen tulos kuvaajana. Se havainnollistaa, kuinka paljon kunkin testidataksi erotetun rivin ennuste ja todellinen arvo eroavat toisistaan.



Kuva 5. Lineaariregression ennuste ja todelliset arvot

Kuvasta 5 näkyy myös poikkeamatilanteita, jolloin todellinen kulutus on ollut hetkittäisesti suurempaa kuin ennustettu. Vastaavasti tilanteita, jolloin ennusteet ovat olleet suurempia kuin todellinen kulutus näkyy myös muutamia. Kuvasta näkyy selkeästi myös liikennöinnin ensimmäisenä vuonna ollut keskimääräisesti nopeamman liikuttamisen aika.

Kuvassa 6 näkyy yksityiskohta kuvan 5 kuvaajasta. Kuvaajassa näkyy myös kohtia, jolloin data-aineisto on datan valinnan vuoksi katkennut, eikä kuvaaja sisällä ajallisesti kaikkia peräkkäisiä havaintoja.



Kuva 6. Yksityiskohta ennustettujen ja todellisten arvojen kuvaajasta

Kuvasta 6 voidaan nähdä, miten todellinen PowerEteen-arvo on ollut hyvin tasainen peräkkäisissä havainnoissa. Ennuste sen sijaan heittelee todellisen arvon ylä- ja alapuolella.

7 Tulosten tarkastelu

Työntötehon tarpeeseen vaikuttavien muuttujien mallinnus alus- ja säädataan perustuen on monimutkaista. Kuten muun muassa Laurie ja muut (2021) kirjoittavat, on datan valikoinnilla suuri merkitys ja se huomattiin tässäkin työssä. Käytettävissä olevaa dataa oli paljon, mutta käyttökelpoisen ja tarpeellisen materiaalin valinta oli vaikea prosessi.

Datan käsittelyssä käytiin monenlaisia vaiheita läpi. Dataa rajattiin siten, että otettiin huomioon vain tietyn syvyiset vesialueet tai rajattiin alue tietylle maantieteelliselle alueelle. Lopullisessa rajauksessa näistä luovuttiin ja käytettiin suurinta mahdollista datamäärää, joka edellä mainittujen valintaperusteiden jälkeen oli jäljellä.

Edes datan erilaisen valikoinnin ja useiden koeajojen jälkeen toistettavia ja loogisia tuloksia oli vaikea saada aikaan. Erityisesti muuttujat sog (speed over ground) ja stw (speed through water) olivat hankalia. Oletettavaa on, että nopeuden lisääntyessä tarvittaisiin lisää työntötehoa. Näin ei kuitenkaan aina ollut stw:n kohdalla ja tätä ongelmaa ratkaistiin pitkään. Erilaisilla datavalikoimilla saatiin toisinaan oikean suuntaisia tuloksia ja toisinaan täysin epäloogisia.

Alussa oletettiin stw:n eron suhteessa sog:hen muodostuvan veden virtauksesta. Tässä oli jäänyt huomiotta se, että alus eroaa monesta muusta tutkitusta aluksesta siinä, että sillä on käytössä Azipod-potkurilaitteet. Nämä potkurit voivat kääntyä akselinsa ympäri 360 ° ja tämä aiheuttaa tavanomaisesta, kiinteäsuuntaisilla potkureilla ja peräsimellä varustetuista aluksista eroavaa pyörteilyä. Oletettavasti tämä virtaus näkyy myös stw-muuttujassa. Azipod-potkureita käytetään myös esimerkiksi satamissa aluksen käsitteilyyn niin, että niillä ajetaan "toisiaan vasten" eli toisen ollessa 90 °:n ja toisen 270 °:n kulmassa. Tämä aiheuttaa veden pyörteilyä, joka ilmenee datasta esimerkiksi siten, että sog on nolla solmua ja stw -2.7 solmua. Näiden "valheellisten virtaamien" poistaminen datasta johti toistettaviin ja loogisiin tuloksiin.

Erilaisten muuttujien, kuten biolikaantumisen, vaikutusta aluksiin on tutkittu paljon. Useimmat näistä tutkimuksista on tehty lämpimien vesien alueella ja siten, että matalan veden alueet on jätetty pois tutkittavasta datasta. Merenkurkku on alueena erityispiirteinen. Se on erittäin matala alue ja vaikka tutkimuksessa käytetyssä datassa Aurora Botnian reitillä syvin vesialue oli 103 metriä, mittaustuloksista 99,5 %:ssa syvyys oli alle 40 metriä, keskiarvon ollessa 12 metriä.

Veden mataluus vaikuttaa aluksen energiankulutukseen. Matalan veden vaikutus kulu-
tukseen ilmenee hyvin Nguyenin ja muiden (2019) tutkimuksesta. Aurora Botnian ta-
pauksessa avuksi otettiin Frouden syvyysluku, joka laskettiin valmiiksi käsiteltävään da-
taan. Neuroverkko olisi oletettavasti osannut tämän riippuvuuden nopeuden ja veden
syvyyden välillä rakentaa, mutta lineaarisessa regressiossa syvyysluvun valmiiksi muo-
dostaminen oli suoraviivaisempi toimintatapa.

Erään merkittävän ongelman aiheutti päiviä pesusta -muuttujan muodostaminen. Wasa-
line kertoi aluksen pohjan pesupäivät, mutta esimerkiksi jääpeite aiheutti oman huomi-
oitavan seikan. Jää hioo kasvustoa pois aluksen pohjasta ja täten puhdistaa sitä. Alussa
tuota aikaa lähdettiin rajaamaan kalenterin mukaan, mutta jossain vaiheessa käyttöön
otettiin jäiden ilmaantumiseen perustuvat määreet. Jäiden ilmaantumisen ajankohta pe-
rustettiin jäänmurtajien käytön ajankohdalla. Jäitä tietenkin ilmenee jo ennen ja jälkeen
jäänmurtajien käyttöajan, mutta se oli ajankohta, joka oli selvästi saatavilla ja oletetta-
vasti perustuu suurin piirtein yhtä paksun jään aikaan. Nämä päivät merkittiin pesupäi-
vänumerolla nolla. Tällä tavoin ratkaistiin talvikausien aiheuttama ongelma pesupäivä-
laskentaan.

On tietysti myös muistettava jo aiemmin mainittu ongelma ensimmäisen vuoden pesu-
päivien paikkansa pitämisestä ja telakalla tapahtuvan biolikaantumisen erilaisuudesta
verrattuna liikennöivään alukseen. Lisäksi on huomioitava, että aluksen pohjan pesun ai-
noa tarkoitus ei ole senhetkisen kasvuston poistaminen. Mikäli kasvusto saa olla kiinnit-
tyneenä aluksen pohjaan pitkiä aikoja, se voi vaikuttaa pohjan maalipintaan. Maalipinta

tulee epätasaisemmaksi ja alttiimmaksi uudelle kasvustolle. Aivan kuten liian karheilla välineillä pesu saattaa hetkellisesti helpottaa tilannetta, mutta kokonaisvaikutus on huonompi, kun maalipinta vaurioituu ja on siten alttiimpi uusien eliöiden kasvualustaksi. Tätä lyhyt- ja pitkäaikaista vaikutusta olisi myös mielenkiintoista tutkia.

Tutkimuksen aikana Frouden syvyyssluvun vaikutus kävi ilmi. Se oli datapaketista riippumatta aina saman kaltainen. Näin oli myös merkitsevän aallonkorkeuden kohdalla. Niiden merkitys onkin suurempi kuin päiviä pesusta -muuttujan.

Veden lämpötilaa yritettiin ottaa tutkimuksessa huomioon. Merirokon ja muiden bioliikaantumista aiheuttavien eliöiden kasvu kiihtyy lämpötilan noustessa. Veden lämpötila nousee kuitenkin verrattain hitaasti ja kasvu ei ehkä olekaan kovin kiihkeää verrattuna vaikkapa Tyynen valtameren alueisiin. Kun tarkasteltiin mallinnuksessa käytettyä dataa, oli pisin aika, jolloin meriveden lämpötila oli yli 20 ° C, kolme vuorokautta peräkkäin.

Kun datan rajaamiseen käytetään Maalahden poijun lämpötiloja ja poistetaan NaN-arvon sisältävät rivit, poistuvat samalla jäätalvet. Jos käytetään Selkämeren lämpötiloja, dataa on hieman enemmän. Käytettäessä Selkämeren lämpötiloja kulmakertoimesta tulee lievästi positiivinen, mutta joka tapauksessa veden lämpötilan merkitys on tutkitun datan kohdalla pieni.

MATLABin ohjelmointi oli eräs diplomityön hankaluuksista. Kokemus MATLABista ennen tätä työtä oli hyvin vähäistä. Suuren datamäärän käsittelyyn se oli kuitenkin looginen valinta. Ohjelmointi onnistui kuitenkin hyvin, ja sillä saatiin aikaan käyttökelpoisia funktioita, joiden avulla datan käsittely oli helppoa. Funktioiden muotoilussa käytettiin toisinaan apuna Microsoftin Copilot-tekoälyohjelmaa.

Erikoista datan käsittelyssä oli, että useissa tapauksissa datasta tehdyt korrelaatiokertoimet vaikuttivat loogisilta, mutta silti neuroverkkomallissa ei saatu kunnollisia ja toistet-

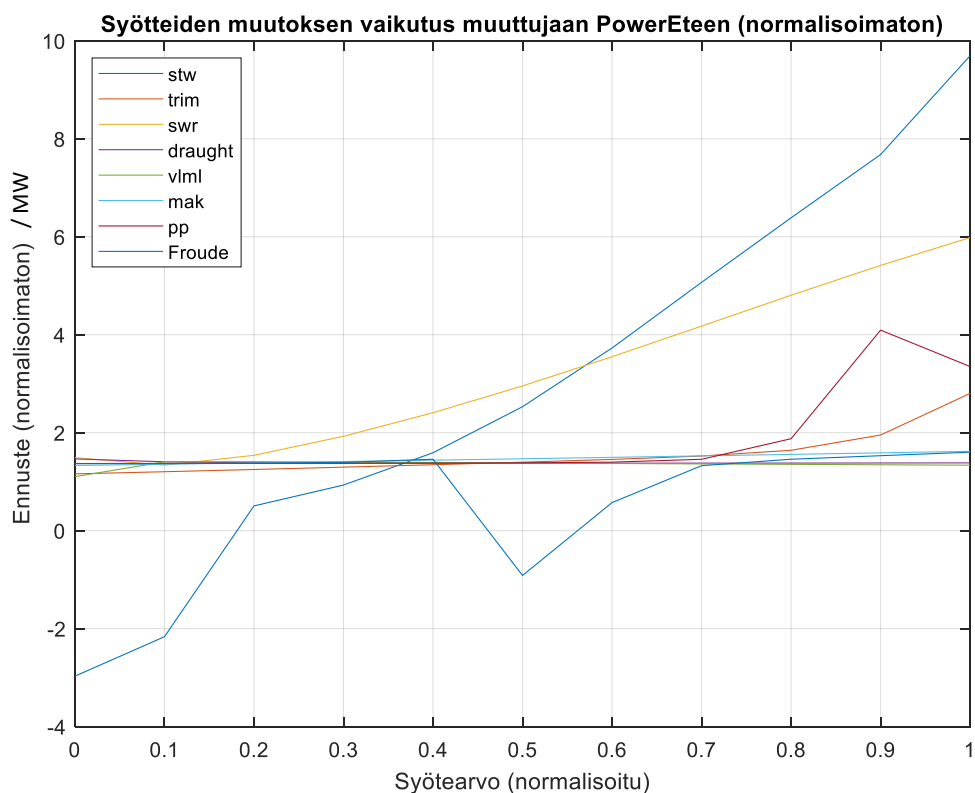
tavia tuloksia aikaan. Riittävän laajaa ymmärrystä neuroverkoista ei ollut, että tämä ongelma olisi osattu ratkaista.

Erilaisten neuroverkkojen ominaisuuksia olisi mielenkiintoista vertailla. Tässä tutkimuksessa koetettiin kouluttaa erilaisia malleja neuroverkon kerroksia lisäämällä. Erilaisten kerrosten lukumäärän tutkimuksen tuloksen näkyvät taulukossa 3.

Taulukko 3. Neuroverkkojen kerrosten lukumäärän vaikutus

Kerrosten lukumäärä	mse
1	0,0027
2	0,0026
5	0,0024
7	0,0023
10	0,0023

Tutkimuksessa kävi ilmi, että keskineliövirhe pienenee, mutta vähän. Vastaavasti mallien kompleksisuus lisääntyi niin, että oli oletettavaa, että neuroverkko loi sellaisiakin yhteyksiä muuttujien välille, mitä niillä ei oikeasti ole. Esimerkkinä kuva 7, jossa neuroverkon kerroksien lukumäärä on seitsemän.



Kuva 7. Muuttujien vaikutukset neuroverkossa, jossa on seitsemän kerrosta

Kuvassa näkyy, miten alhaisin nopeus saavutettaisiin -3 MW:n teholla ja esimerkiksi päiviä pesusta muuttuja tekee koukkauksen alaspäin arvoalueensa maksimia lähestyttäessä. Mielenkiintoinen on Frouden syvyysluvun vaikutuksessa oleva kuoppa, sillä Frouden syvyysluvun vaikutus ei välttämättä ole lineaarista, mutta tuon kuopan tulisi oletettavasti olla huippu. Jonkinlainen yhteys siis löytyy, kun kerroksia lisätään, mutta sen oikeellisuutta tulisi tutkia enemmän.

Lineaariregression tuloksissa arvoalueen maksimi tulisi suurimmalla suhteellisella tuulenopeudella. Tämä saattaa johtua siitä, että suhteellinen tuulenopeus saa poikkeuksellisen suuriakin arvoja, verrattuna nopeuteen veden läpi, joita ei voida pitää mittapoikkeamina. Kahtena erityisen myrskyisenä päivänä suhteellinen tuulenopeus ylittää hetkittäin, mutta peräkkäisissä mittauksissa näkyvinä arvoina, jopa yli 40 m/s. Seuraavaksi merkityksellisimmät muuttujat ovat Frouden syvyysluku, viippaus, syväys ja merkitsevä

aallonkorkeus. Tälläkin mallinnustavalla ”päiviä pesusta” -arvo ja veden lämpötila jäivät merkityksettömimmiksi.

Saatuja tuloksia ei voida suoraan vertailla Laurien ja muiden (2021) saamiin tuloksiin. Siinä tutkimuksessa keskityttiin erilaisten mallien tuottamaan ennusteeseen vaadittavasta työntötehosta ja tässä työssä mallinnettiin eri muuttujien vaikutusta vaadittavaan työntötehoon, ja mallien hyvyyttä arvioitiin eri muuttujilla.

Lineaariregression tulokset olisivat muuten vertailukelpoisia, mutta tutkimuksesta saadut prosentuaaliset keski-itseisvirhe-arvot (Mean Absolute Percentage Error, MAPE) eivät ole suoraan vertailukelpoisia. Tämä johtuu siitä, että Laurien ja muiden (2021) tutkimuksessa käytetään kullekin alukselle suunniteltua nopeusaluetta, joka on 14–22 solmua ja tässä tutkimuksessa on käytössä kaikki nolaa solmua suuremmat nopeudet. Kun jakajana on hyvin pienet luvut, vääristyy suhteellinen virhe ja tulokseksi saadaan todella suuria lukuja prosentuaaliseksi osuudeksi.

Tämän todentamiseksi tutkimuksessa mitattuihin nopeuksiin kokeiltiin lisätä vakioarvo, jolloin saatiin MAPE-arvoksi 2,0–6,2 %, vakiosta riippuen. Laurien ja muiden (2021) saama lineaariregression MAPE-arvo oli 6,45 %. Tästä voidaan arvella, että mikäli tutkimuksessa käytettäisiin vain Aurora Botnialle suunniteltuja nopeuksia, saataisiin vertailukelpoisia ja alhaisen MAPE-arvon omaavia tuloksia. Tässä tutkimuksessa saatuja tuloksia on varmasti mahdollista parantaa, mutta samalla voi sanoa, että on pyritty minimoimaan kaikki ne virheet, jotka huomattiin.

8 Johtopäätökset

Työn tarkoituksena oli mallintaa Aurora Botnia -aluksen työntötehoa ja siihen vaikuttavia muuttujia käytettävissä olevan datan perusteella. Mallintamisessa käytettiin keinoteikoista neuroverkkoa ja lineaariregressiota. Merenkurkun alue toi omat piirteensä tutkimukseen, ja lisäksi eräs kiinnostuksen kohteista oli aluksen pohjan biolikaantumisen vaikutus työntötehon tarpeeseen.

Mallinnuksen selkeänä tuloksena nähdään, että aluksen nopeudella on suurin vaikutus työntötehon tarpeeseen eli mitä nopeammin kuljetaan, sitä enemmän tarvitaan työntötehoa. Seuraavaksi merkittävin tekijä oli suhteellinen tuulennopeus. Aluksen geometriaa ei tutkittu erikseen, mutta trimmin vaikutus oli neuroverkkomallinnuksessa seuraavaksi merkittävin tekijä ennen merkitsevän aallonkorkeuden, Frouden syvyyksluvun ja syväyksen vaikutusta. Lineaariregressiossa näiden muuttujien merkitys oli eri järjestyksessä: Frouden syvyyksluku on merkityksellisin, sitten trimmi, syväys ja merkitsevä aallonkorkeus. Päiviä pesusta -muuttujan merkitys on kummallakin tavalla järjestyksessä toiseksi viimeinen ja meriveden lämpötila viimeinen.

Tutkimuksen perusteella voidaan suositella huomion kiinnittämistä aluksen lastaukseen ja siitä aiheutuvaan trimmin muutokseen. Frouden syvyykslukuun vaikuttaminen on vaikeampaa, sillä pysyäkseen aikataulussa, on aluksen ajettava matalissakin vesissä riittävän nopeasti. Sääolosuhteisiin, kuten suhteelliseen tuulennopeuteen ja aallonkorkeuteen, ei voi vaikuttaa, eikä reittivalinnoillakaan voi juuri vaikuttaa vesiväylien määrätessä reitin.

Jatkossa olisi mielenkiintoista tutkia, miten parametrien lukumäärä vaikuttaa ennusteen hyvyyteen. Kuinka pieneen voi rajata sen parametrien määrän, joita tulisi tarkkailla, että saadaan vielä luotettavia tuloksia? Voidaanko parametrejä lisäämällä saada tarkempia ennusteita? Miten neuroverkon kerrosten lisääminen vaikuttaisi tuloksiin? Toisaalta jatkotutkimuksen kannalta olisi mielenkiintoista saada käyttöön vielä enemmän dataa ja

koettaa ymmärtää, voisiko neuroverkon avulla saada laajemmin juuri tähän alueeseen soveltuvaa mallia aikaiseksi.

Olisi myös mielenkiintoista, että biolikaantumiselle olisi jokin toinen, konkreettisempi mittari kuin tässä tutkimuksessa käytössä ollut päiviä pesusta -muuttuja. Se voisi olla joko visuaaliseen tarkasteluun perustuva tai jonkinlaisella mittalaitteella saatava arvo. Nyt tuo muuttuja oli melko epätarkka ja sisälsi vielä oletuksia talvikaudesta ja sen vaikutuksesta.

Erilaisten mittareiden ja antureiden sijoittelusta ja tarkkuudesta olisi myös hyvä olla tarkempaa tietoa. Esimerkiksi juuri stw-anturin paikka olisi mielenkiintoista tietää ja tutkia lisää virtauksien syntymistä ja vaikutuksia. Toinen mielenkiintoinen täsmennys olisi tieto siitä, miten usein jokin muuttuja voi oikeasti muuttua ja mikä on mittavirhe. Esimerkiksi, jos potkurin kulma on puolen minuutin välein 0, 0, 0, 220 ja 0 astetta, onko poikkeava arvo mahdollinen edes teoriassa, vai onko kyseessä mittavirhe.

Eräs tarkemman tutkimisen kohde olisi keskittyä nopeuksiin, jotka ovat lähellä alukselle suunniteltua nopeutta ja tyypillisimpiä ajonopeuksia. Tällä rajatulla alueella tutkittaisiin tarkemmin vaikkapa viippauksen tai biolikaantumisen merkitystä. Muunkin kuin nopeusdatan erilaisella valinnalla, kuten esimerkiksi käyttämällä jokaisesta tutkittavasta muuttujasta vain tietyn verran tyyppi-arvosta poikkeavia arvoja, tuloksista voisi tulla hyvin erilaisia.

Erilaisia tutkimuksen kohteita olisi siis monia ja laivan jatkuvasti liikennöidessä uutta dataa tulee päivittäin. Ihanteellinen tilanne olisi, jos tulevan tutkimuksen perusteella voitaisiin luoda malli, joka saa datan suoraan Nacos-järjestelmästä ja laskee sen perusteella, koska vene kannattaisi viedä pesulle ja kannattaisiko pestä koko pohja vai riittääkö muutamien metrin kaistale pinnan tuntumasta.

Joka tapauksessa voidaan todeta, että matalassa vedessä ja Azipod-potkureilla varustetun aluksen tapauksessa on monta huomioon otettavaa seikkaa, jotka vaikuttavat tarvittavan työntötehon tarpeeseen verrattuna syvissä vesissä, tavanomaisemmalla propulsiojärjestelmällä varustetuista aluksista tehtyihin tutkimuksiin.

9 Yhteenveto

Meriliikenne aiheuttaa ilmastopäästöjä ja niiden vähentämiselle on tarve Kansainvälisen merenkulkujärjestön IMO:n (International Maritime Organization) asettamien kasvihuonekaasustrategian päästötavoitteiden saavuttamiseksi. Alusten polttoaineenkulutuksella on suuri vaikutus merenkulun ilmastopäästöihin. Aluksen liikuttamiseen vaadittavan propulsiotehon suuruus ja sitä kautta tarvittavan polttoaineen määrä riippuu monista seikoista.

Tämän diplomityön tarkoituksena oli mallintaa Merenkurkussa liikennöivän Aurora Botnia -aluksen propulsiotehon tarpeeseen vaikuttavia muuttujia. Tutkimusmateriaalina käytettiin Vaasan ja Uumajan välillä liikennöivän matkustaja-autolautan Nacos-järjestelmän kautta tarjoamaa dataa, Merenkurkun alueen säädataa sekä aluksen pohjan puhdistamiseen liittyvää dataa.

Työn alussa esiteltiin aiheesta tehtyjä muita tutkimuksia ja aluksen kulkuvastukseen ja siten myös vaadittavaan työntötehoon vaikuttavia seikkoja sekä esiteltiin tutkimuksen kohteena oleva tapaus ja olosuhteet. Useat muut aiheeseen liittyvät tutkimukset on tehty lämpimämmissä kuin Merenkurkun alueen vesissä, sekä tutkimuksista on tavallisesti poistettu matalan veden alueet.

Työssä käytettiin MATLAB-ohjelman koneoppimismallinnuksen lineaarista regressiota ja keinotekoisia neuroverkkoja. Datan käsittelyssä luotiin joitain uusia laskennallisia muuttujia ja poistettiin tarpeettomiksi arvioituja muuttujia. Datan valikoinnissa rajattiin pois muun muassa aluksen normaalilta reitiltä poikkeavat näytteet, negatiivisen työntötehon ja nopeuden näytteet sekä ne näytteet, joilla aluksen nopeus maan ja veden suhteen erosi enemmän kuin yhden solmun. Datan valikoinnin jälkeen näytteitä oli 790 659 ja työntötehoon vaikuttavia vertailtavia muuttujia kahdeksan.

Tuloksista huomattiin, että aluksen nopeudella veden läpi oli suurin vaikutus propulsiotehon tarpeeseen. Seuraavaksi merkittävin tekijä oli suhteellinen tuulennopeus. Kei-notekoisella neuroverkolla mallinnettaessa seuraavaksi merkittävimmät muuttujat olivat viippaus, merkitsevä aallonkorkeus, Frouden syvyytluku ja syväys. Biolikaantuminen ja veden lämpötila olivat tutkimukseen valituista muuttujista merkityksettömmät tekijät.

Lineaariregressiomalli ennusti työntötehon tarvetta samojen kahdeksan muuttujan pohjalta. Muuttujista nopeus veden läpi ja suhteellinen tuulennopeus käytettiin myös toisen asteen muuttujia. Mallin keskiarvoinen keskineliövirhe (MSE) oli 0,0027 ja jäännösvirhehajonta (RMSE) 0,0520.

Lähteet

- ABB. (2020, syyskuuta 14). *Wasalinen uuden matkustajalautan vesillelasku vahvistaa ABB:n Azipod®-potkurijärjestelmän asemaa lauttamarkkinoilla | News center.* <https://new.abb.com/news/fi/detail/67582/wasalinen-uuden-matkustajalautan-vesillelasku-vahvistaa-abbn-azipodr-potkurijarjestelman-asemaa-lauttamarkkinoilla>
- Adland, R., Cariou, P., Jia, H. & Wolff, F. C. (2018). The energy efficiency effects of periodic ship hull cleaning. *Journal of Cleaner Production*, 178, 1–13. <https://doi.org/10.1016/J.JCLEPRO.2017.12.247>
- Altarriba, E. (2020). Laivojen pohjien likaantumisen vaikutus kulkuvastukseen Itämerellä: Teoreettinen viitekehys ja empiiriset mittaukset. *Rakenteiden Mekaniikka*, 53(3), 208–239. <https://doi.org/10.23998/rm.79336>
- Altarriba, E. (2021). Laivojen pohjien likaantumisen vaikutus kulkuvastukseen Itämerellä: Chow-Liu-puulla täydennetyt Naiivi Bayes -mallin soveltaminen aluksen kulun analysointiin. *Rakenteiden Mekaniikka*, 53(4), 356–389. <https://doi.org/10.23998/RM.87314>
- Ampah, J. D., Yusuf, A. A., Afrane, S., Jin, C. & Liu, H. (2021). Reviewing two decades of cleaner alternative marine fuels: Towards IMO's decarbonization of the maritime transport sector. *Journal of Cleaner Production*, 320, 128871. <https://doi.org/10.1016/J.JCLEPRO.2021.128871>
- Bertram, V. (2012). Resistance and Propulsion. Teoksessa *Practical Ship Hydrodynamics* (ss. 73–141). Elsevier. <https://doi.org/10.1016/b978-0-08-097150-6.10003-x>
- DNV AS. (2022). *DNV Vessel Register*. <https://vesselregister.dnv.com/vesselregister/details/40916>
- Hagan, M. T., Demuth, H. B., Beale, M. H. & De Jesús, O. (2014). *Neural Network Design 2nd Edition*.
- Hughes, K. A. & Ashton, G. V. (2016). Breaking the ice: the introduction of biofouling organisms to Antarctica on vessel hulls. *Aquatic Conservation: Marine and Freshwater Ecosystems*, 27, 158–164. <https://doi.org/10.1002/aqc.2625>

- Häggman, V. (2022). *M/S Aurora Botnias driftprofil*. Yrkehögskolan Novia.
- Ilmatieteen laitos. (ei pvm.-a). *Ilmatieteen laitos - Havaintoasemat*. Noudettu 25. helmikuuta 2025, osoitteesta <https://www.ilmatieteenlaitos.fi/havaintoasemat>
- Ilmatieteen laitos. (ei pvm.-b). *Ilmatieteen laitos - Poijut*. Noudettu 25. helmikuuta 2025, osoitteesta <https://www.ilmatieteenlaitos.fi/poijut>
- Ilmatieteen laitos. (ei pvm.-c). *Itämeren jäätalvikuvaukset*. Noudettu 19. maaliskuuta 2025, osoitteesta <https://www.ilmatieteenlaitos.fi/jaatalvet>
- Ilmatieteen laitos. (2022, syyskuuta 10). *Itämeren virtaukset*. <https://www.ilmatieteenlaitos.fi/veden-virtaus>
- International Association of Classification Societies. (2016). *Requirements concerning POLAR CLASS*.
- International Maritime Organization. (ei pvm.-a). *Frequently Asked Questions*. Noudettu 13. maaliskuuta 2025, osoitteesta <https://www.imo.org/en/About/Pages/FAQs.aspx>
- International Maritime Organization. (ei pvm.-b). *Regulation 2 - Definitions*. Noudettu 25. helmikuuta 2025, osoitteesta <https://www.imorules.com/GUID-CC2626FC-C5A9-480A-A9D1-B6D43BEB366F.html>
- International Maritime Organization. (2022). *Resolution MEPC 346 78, 2022 Guidelines for the Development of a Ship Energy Efficiency Management Plan (SEEMP)*. [https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions/MEPCDocuments/MEPC.346\(78\).pdf](https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions/MEPCDocuments/MEPC.346(78).pdf)
- International Maritime Organization. (2023a). *2023 IMO strategy on reduction of GHG emission from ships*. <https://wwwcdn.imo.org/localresources/en/OurWork/Environment/Documents/annex/MEPC%2080/Annex%2015.pdf>
- International Maritime Organization. (2023b, tammikuuta). *Section 5 Definitions*. https://www.imorules.com/NSR_V1_PT3_CH1_5.html#GUID-CDA42745-B275-403C-A612-274EBAF41F3C

- International Maritime Organization. (2024). *RESOLUTION MEPC.378(80) (adopted on 7 July 2023) 2023 GUIDELINES FOR THE CONTROL AND MANAGEMENT OF SHIPS' BIOFOULING TO MINIMIZE THE TRANSFER OF INVASIVE AQUATIC SPECIES.*
- Laurie, A., Anderlini, E., Dietz, J. & Thomas, G. (2021). Machine learning for shaft power prediction and analysis of fouling related performance deterioration. *Ocean Engineering*, 234, 108886. <https://doi.org/10.1016/J.OCEANENG.2021.108886>
- Le, T. H., Vu, M. T., Bich, V. N., Phuong, N. K., Ha, N. T. H., Chuan, T. Q. & Tu, T. N. (2021). Numerical investigation on the effect of trim on ship resistance by RANSE method. *Applied Ocean Research*, 111, 102642. <https://doi.org/10.1016/J.APOR.2021.102642>
- Leiwo, H. (2021, elokuuta 25). *Merenkurkun uusi laiva kastettiin – liikituksen kyyneleiltä ei vältytty, kun odotettu alus Aurora Botnia lipui satamaan | Yle.* <https://yle.fi/a/3-12068506>
- Luoma, E., Laurila-Pant, M., Altarriba, E., Nevalainen, L., Helle, I., Granhag, L., Lehtiniemi, M., Srèbalienè, G., Olenin, S. & Lehikoinen, A. (2022). A multi-criteria decision analysis model for ship biofouling management in the Baltic Sea. *Science of the Total Environment*, 852. <https://doi.org/10.1016/j.scitotenv.2022.158316>
- Martić, I., Anušić, B., Degiuli, N. & Grlj, C. G. (2024). Numerically Investigating the Effect of Trim on the Resistance of a Container Ship in Confined and Shallow Water. *Applied Sciences* 2024, Vol. 14, Page 6570, 14(15), 6570. <https://doi.org/10.3390/APP14156570>
- MATLAB. (ei pvm.). <https://uk.mathworks.com/help/deeplearning/ref/trainlm.html>.
- Metsähallitus & Suomen ympäristökeskus. (2024). *The Finnish Inventory Programme for the Underwater Marine Environment (VELMU) Methodology guide.* (12.6.2019 FIN). Zenodo. <https://doi.org/10.5281/ZENODO.11576650>
- Molland, A. F., Turnock, S. R. & Hudson, D. A. (2011). *Ship resistance and propulsion : practical estimation of ship propulsive power.* 537. <https://doi.org/10.1017/9781316494196>
- Moore, R. (2021, kesäkuuta 14). *Aurora Botnia: a 'never-ending story' of development.* Riviera - News Content Hub. <https://www.rivieramm.com/news-content->

hub/news-content-hub/aurora-botnia-a-lsquotonever-ending-storyrsquo-of-development-66007

- Musulini, M., Mihanović, L., Balić, K. & Musulin, H. N. (2024). The Impact of Container Ship Trim on Fuel Consumption and Navigation Safety. *Journal of Marine Science and Engineering* 2024, Vol. 12, Page 1658, 12(9), 1658. <https://doi.org/10.3390/JMSE12091658>
- Mäkinen, E. (2022, maaliskuuta 20). Uusi laiva auttaa Wasalinen kasvuun - Navigator Magazine. *Navigator Magazine*. <https://navigatormagazine.fi/uutiset/uusi-laiva-auttaa-wasalinen-kasvuun/>
- Nasrolahi, A., Pansch, C., Lenz, M. & Wahl, M. (2012). Being young in a changing world: How temperature and salinity changes interactively modify the performance of larval stages of the barnacle *Amphibalanus improvisus*. *Marine Biology*, 159(2), 331–340. <https://doi.org/10.1007/S00227-011-1811-7/FIGURES/7>
- Nguyen, T. N. H., Vu, N. B., Tran, N. T., Nguyen, M. C. & Le, T. H. (2019). Numerical Investigating the Effect of Water Depth on Ship Resistance Using RANS CFD Method. *Polish Maritime Research*, 3(103), 56–64. <https://doi.org/10.2478/pomr-2019-0046>
- Peter, B. (2021). For a greener northern Baltic AURORA BOTNIA. *Shippaxinfo*, 11/2021. www.shippax.com
- Rawson, K. J. & Tupper, E. C. (2001). *Basic ship theory* (5th ed.). Butterworth-Heinemann .
- Saukko, O.-P. J. (2020). *Laivan sähköjakelu ja datan käsittely [diplomityö, Tampereen yliopisto]*. <https://urn.fi/URN:NBN:fi:tuni-202005125197>
- Suomen ympäristökeskus. (2023, huhtikuuta 25). *Meriluonnon monimuotoisuus*. <https://www.ymparisto.fi/fi/luonto-vesistot-ja-meri/luonnon-monimuotoisuus/meriluonnon-monimuotoisuus#merenkurkun-kivikkoinen-kynnys-estaa-suolaisemman-veden-virtaamisen-pohjoiseen>
- Uzun, D., Demirel, Y. K., Coraddu, A. & Turan, O. (2019). Time-dependent biofouling growth model for predicting the effects of biofouling on ship resistance and powering. *Ocean Engineering*, 191, 106432. <https://doi.org/10.1016/J.OCEANENG.2019.106432>

- Vinagre, P. A., Simas, T., Cruz, E., Pinori, E. & Svenson, J. (2020). Marine biofouling: A European database for the marine renewable energy sector. Teoksessa *Journal of Marine Science and Engineering* (Vsk. 8, Numero 8).
<https://doi.org/10.3390/JMSE8070495>
- Wärtsilä. (ei pvm.). *AZIPOD (Azimuthing Podded Drive)*. Noudettu 27. helmikuuta 2025, osoitteesta [https://www.wartsila.com/encyclopedia/term/azipod-\(azimuthing-podded-drive\)](https://www.wartsila.com/encyclopedia/term/azipod-(azimuthing-podded-drive))
- Wärtsilä. (2019, syyskuuta 12). *Wasalinen erittäin tehokkaaseen laivaan tulee Wärtsilän Nacos Platinum -navigointijärjestelmä*. https://www.wartsila.com/fi/media-fi/uutinen/12-09-2019-wasalinen-erittain-tehokkaaseen-laivaan-tulee-wartsilan-nacos-platinum--navigointijarjestelma-3225840?utm_source=organic&utm_medium=MP-press-release&utm_term=marine-power&utm_content=press-release&utm_campaign=Wartsila-providing-systems-solutions-and-maintenance-support-for-worlds-most-environmentally-friendly-ferry
- Wärtsilä. (2023, tammikuuta 24). *What did Wasaline do to save fuel and reduce emissions?* <https://www.wartsila.com/insights/case-study/aurora-botnia-fuel-optimization>
- Wärtsilä. (2024a). *Wärtsilä W31DF Product Guide*.
- Wärtsilä. (2024b, joulukuuta 5). *How Wasaline improved engine room air quality on their ferry*. <https://www.wartsila.com/insights/case-study/wasaline-s-aurora-botnia-improves-engine-room-air-quality>
- Öztürk, O. B. & Başar, E. (2022). Multiple linear regression analysis and artificial neural networks based decision support system for energy efficiency in shipping. *Ocean Engineering*, 243, 110209. <https://doi.org/10.1016/J.OCEANENG.2021.110209>

Liitteet

Liite 1. Täydentäviä tuloksia

Neuroverkon koulutus, normalisoitu data, Laurien muuttajat.

Koulutustapahtuma	MSE	R-arvo
1	0,00269	0,97774
2	0,00267	0,97774
3	0,00268	0,97774
4	0,00267	0,97774
5	0,00268	0,97774
keskiarvo	0,00268	0,97774

Kunkin muuttujan minimi- ja maksimiarvot.

1	2	3	4	5	6	7	8	9
stw	trim	speedwindrelative	draught	VedenLmptilaC_MlTt	MerkitsevAallonkorkeusr	paiviapesusta	Froude	PowerEteen
1.0000e-03	-1.5500	0	4.5080	0.5000	0	0	3.6900e-05	7.7037e-34
22.1000	1.1360	124.6000	6.4200	22.2000	5.2000	180	1.6577	11.2610

Kulmakertoimen laskemisen perusteena olevat ajot, normalisoitu ja normalisoimaton:

```
>> sarakeajo(net, ABKAA, 1,0,1,0.1)
Ensimmäinen ennuste: 0.010984
Viimeisin ennuste: 0.94495
Suoran kulmakerroin: 0.90493
>> sarakeajo(net, ABKAA, 2,0,1,0.1)
Ensimmäinen ennuste: 0.12644
Viimeisin ennuste: 0.17372
Suoran kulmakerroin: 0.047255
>> sarakeajo(net, ABKAA, 3,0,1,0.1)
Ensimmäinen ennuste: 0.12916
Viimeisin ennuste: 0.30003
Suoran kulmakerroin: 0.17036
>> sarakeajo(net, ABKAA, 4,0,1,0.1)
Ensimmäinen ennuste: 0.13076
Viimeisin ennuste: 0.16396
Suoran kulmakerroin: 0.033194
>> sarakeajo(net, ABKAA, 5,0,1,0.1)
Ensimmäinen ennuste: 0.14748
Viimeisin ennuste: 0.14655
Suoran kulmakerroin: -0.00092781
>> sarakeajo(net, ABKAA, 6,0,1,0.1)
Ensimmäinen ennuste: 0.14062
Viimeisin ennuste: 0.17895
Suoran kulmakerroin: 0.038326
>> sarakeajo(net, ABKAA, 7,0,1,0.1)
Ensimmäinen ennuste: 0.14337
Viimeisin ennuste: 0.15467
Suoran kulmakerroin: 0.011296
>> sarakeajo(net, ABKAA, 8,0,1,0.1)
Ensimmäinen ennuste: 0.14012
Viimeisin ennuste: 0.17521
Suoran kulmakerroin: 0.03508
.....
```

```
>> sarakeajoy(net, ABKAA, 1,0,1,0.1,7.7037e-34,11.261)
Ensimmäinen ennuste: 0.010984
Viimeisin ennuste: 0.94495
Suoran kulmakerroin: 10.1904
>> legend('Location','northwest')
>> hold on
>> sarakeajoy(net, ABKAA, 2,0,1,0.1,7.7037e-34,11.261)
Ensimmäinen ennuste: 0.12644
Viimeisin ennuste: 0.17372
Suoran kulmakerroin: 0.53213
>> sarakeajoy(net, ABKAA, 3,0,1,0.1,7.7037e-34,11.261)
Ensimmäinen ennuste: 0.12916
Viimeisin ennuste: 0.30003
Suoran kulmakerroin: 1.9185
>> sarakeajoy(net, ABKAA, 4,0,1,0.1,7.7037e-34,11.261)
Ensimmäinen ennuste: 0.13076
Viimeisin ennuste: 0.16396
Suoran kulmakerroin: 0.3738
sarakeajoy(net, ABKAA, 5,0,1,0.1,7.7037e-34,11.261)
Ensimmäinen ennuste: 0.14748
Viimeisin ennuste: 0.14655
Suoran kulmakerroin: -0.010448
sarakeajoy(net, ABKAA, 6,0,1,0.1,7.7037e-34,11.261)
Ensimmäinen ennuste: 0.14062
Viimeisin ennuste: 0.17895
Suoran kulmakerroin: 0.43159
sarakeajoy(net, ABKAA, 7,0,1,0.1,7.7037e-34,11.261)
Ensimmäinen ennuste: 0.14337
Viimeisin ennuste: 0.15467
Suoran kulmakerroin: 0.12721
sarakeajoy(net, ABKAA, 8,0,1,0.1,7.7037e-34,11.261)
Ensimmäinen ennuste: 0.14012
Viimeisin ennuste: 0.17521
Suoran kulmakerroin: 0.39504
hold off
```

Lineaariregression tulokset, normalisoitu data.

mse	rmse	r ²	adj r ²	stw	^2	^3	trim	^2	^3	swr	^2	^3	drai	^2	^3	ltml	^2	^3	mal	^2	^3	pp	^2	^3	Froi	^2	^3
0,00515	0,071679	0,91528	0,91528	x			x			x			x			x			x			x			x		
0,002806	0,053622	0,9526	0,9526	x	x		x			x			x			x			x			x			x		
0,002855	0,05322	0,95332	0,95331	x	x	x	x			x			x			x			x			x			x		
0,002863	0,053193	0,95337	0,95337	x	x	x	x	x		x			x			x			x			x			x		
0,002854	0,053187	0,95339	0,953339	x	x	x	x	x	x				x			x			x			x			x		
0,002737	0,051568	0,95617	0,95617	x	x	x	x	x	x	x			x			x			x			x			x		
0,002687	0,051647	0,95603	0,95603	x	x	x	x	x	x	x	x		x			x			x			x			x		
0,002645	0,051493	0,9563	0,9563	x	x	x	x	x	x	x	x		x	x		x			x			x			x		
0,002694	0,051179	0,95684	0,95684	x	x	x	x	x	x	x	x		x	x	x	x			x			x			x		
0,002588	0,051352	0,95653	0,95653	x	x	x	x	x	x	x	x		x	x	x	x	x		x			x			x		
0,002618	0,051257	0,95672	0,95672	x	x	x	x	x	x	x	x		x	x	x	x	x	x		x			x			x	
0,002663	0,051234	0,95676	0,95676	x	x	x	x	x	x	x	x		x	x	x	x			x	x			x			x	
0,026359	0,0513	0,95661	0,95661	x	x	x	x	x	x	x	x		x	x	x	x			x	x	x			x			x
0,002712	0,051054	0,95707	0,95707	x	x	x	x	x	x	x	x		x	x	x	x			x			x	x			x	
0,002616	0,051276	0,95668	0,95668	x	x	x	x	x	x	x	x		x	x	x	x			x			x	x	x			x
0,002621	0,051059	0,95705	0,95704	x	x	x	x	x	x	x	x		x	x	x	x			x			x	x	x	x		x
0,002558	0,051208	0,95678	0,95678	x	x	x	x	x	x	x	x		x	x	x	x			x			x	x	x	x		x
				x	x	x	x	x	x	x	x		x	x	x	x			x			x	x	x	x		x

Taulukon x tarkoittaa, että kyseinen muuttuja on ollut mukana kyseisessä koeajossa. Jo-kaista muuttujaa on ajettu kolmella eri vaihtoehdolla, josta sitten valittu sopivin ja edetty seuraavaan.

Alkuperäinen taulukko kuvakaappauksena.

Päivitetty taulukko:

MSE	RMSE	R_squared	Adjusted_R_squared
0.0051497	0.071679	0.91528	0.91528
0.0028055	0.053622	0.9526	0.9526
0.0028545	0.053228	0.95332	0.95331
0.0028632	0.053193	0.95337	0.95337
0.0028543	0.053187	0.95339	0.95339
0.0027366	0.051568	0.95617	0.95617
0.0026869	0.051647	0.95603	0.95603
0.0026452	0.051493	0.9563	0.9563
0.0026935	0.051179	0.95684	0.95684
0.0025882	0.051352	0.95653	0.95653
0.0026175	0.051257	0.95672	0.95672
0.0026632	0.051234	0.95676	0.95676
0.0026359	0.0513	0.95661	0.95661
0.0027121	0.051054	0.95707	0.95706
0.0026155	0.051276	0.95668	0.95668
0.0026213	0.051059	0.95705	0.95704
0.0025577	0.051208	0.95678	0.95677

Koulutukset valinnalla, joissa kaikki muut ovat ensimmäiseen potenssiin, mutta stw myös toiseen potenssiin.

MSE	RMSE	R_squared	Adjusted_R_squared
0.002874	0.053462	0.95291	0.95291
0.0029239	0.053345	0.95309	0.95309
0.0028072	0.053618	0.95259	0.95259
0.0028341	0.053555	0.95273	0.95273
0.002829	0.053567	0.95268	0.95268
0.0028561	0.053504	0.95283	0.95283
0.0028536	0.05351	0.95284	0.95284
0.00288	0.053448	0.9529	0.9529
0.0028685	0.053475	0.95285	0.95284
0.0029081	0.053382	0.953	0.953

Tunnuslukujen keskiarvot:

0.0029	0.0535	0.9528	0.9528
--------	--------	--------	--------

Koulutukset valinnalla, joissa kaikki muut ovat ensimmäiseen potenssiin, mutta stw ja swr myös toiseen potenssiin.

MSE	RMSE	R_squared	Adjusted_R_squared
0.0026904	0.05203	0.95541	0.95541
0.0026414	0.052148	0.95524	0.95524
0.00269	0.052031	0.9554	0.9554
0.0027061	0.051993	0.95546	0.95546
0.0027066	0.051991	0.95547	0.95547
0.0027494	0.051889	0.9556	0.9556
0.002732	0.05193	0.95559	0.95559
0.002713	0.051976	0.9555	0.95549
0.0027621	0.051858	0.9557	0.9557
0.0027692	0.051841	0.95573	0.95573

Tunnuslukujen keskiarvot:

0.0027	0.0520	0.9555	0.9555
--------	--------	--------	--------

Sarakkeissa valituilla muuttujilla saadut keskineliövirhe, jäännösvirrehajonta, selityssaste ja korjattu selityssaste (mse, rmse, r squared ja adjusted r squared), kun koulutettiin viisi kertaa (riviä).

0.0027	0.0520	0.9553	0.9553
0.0027	0.0521	0.9552	0.9552
0.0027	0.0519	0.9555	0.9555
0.0027	0.0519	0.9556	0.9556
0.0027	0.0519	0.9555	0.9555

Ja näiden keskiarvo:

0.0027	0.0520	0.9554	0.9554
--------	--------	--------	--------

Sekä eri muuttujien kertoimet.

1	2	3	4	5	6	7	8	9	10	11
x_Intercept_	stw	trim	speedwindrelative	draught	VedenLmptilaC_MLtt	MerkitsevAallonkorkeusn	paiviapesusta	Froude	stw_2	speedwindrelative_2
-0.0421	-0.1638	0.0729	-0.2319	0.0378	-0.0030	0.0200	0.0155	0.0791	1.0882	1.3161
-0.0418	-0.1630	0.0725	-0.2388	0.0379	-0.0027	0.0194	0.0161	0.0788	1.0871	1.3368
-0.0418	-0.1637	0.0727	-0.2435	0.0383	-0.0028	0.0198	0.0160	0.0787	1.0887	1.3460
-0.0414	-0.1644	0.0723	-0.2395	0.0376	-0.0028	0.0199	0.0154	0.0791	1.0891	1.3397
-0.0427	-0.1662	0.0734	-0.2370	0.0381	-0.0025	0.0202	0.0161	0.0805	1.0909	1.3283

Ja näiden keskiarvo:

-0.0420	-0.1642	0.0728	-0.2382	0.0379	-0.0028	0.0199	0.0158	0.0792	1.0888	1.3334
---------	---------	--------	---------	--------	---------	--------	--------	--------	--------	--------

Erään koulutuskerran tarkemmat tulokset.

```
>> datajako
mse =
0.0028

Linear regression model:
PowerEteen ~ 1 + stw + trim + speedwindrelative + draught + VedenLmptilaC_MLtt + MerkitsevAallonkorkeusn + paiviapesusta + Froude + stw^2 + speedwindrelative^2

Estimated Coefficients:
              Estimate      SE      tStat      pValue
(Intercept)  -0.041659    0.00057654   -72.257      0
stw          -0.16612     0.0014135   -117.52      0
trim         0.071837     0.00076661    93.706      0
speedwindrelative  -0.2356     0.002674   -88.107      0
draught      0.038175     0.00098337   38.821      0
VedenLmptilaC_MLtt -0.0029037    0.00033444  -8.6822    3.8921e-18
MerkitsevAallonkorkeusn  0.019583    0.00055349   35.382    6.0565e-274
paiviapesusta  0.016088     0.00038922   41.333      0
Froude       0.079676     0.0011264    70.733      0
stw^2        1.0908     0.0015043    725.12      0
speedwindrelative^2  1.3267     0.0069004   192.27      0

Number of observations: 632528, Error degrees of freedom: 632517
Root Mean Squared Error: 0.0519
R-squared: 0.956, Adjusted R-Squared: 0.956
F-statistic vs. constant model: 1.36e+06, p-value = 0
```

Estimate (arvio) kertoo arvioidun kertoimen eli yhden muuttujan vaikutuksen kohde-muuttujaan. SE eli standard error eli standardivirhe mittaa kuinka paljon arvio voi poiketa todellisesta otannan vaikutuksen vuoksi. Pieni arvo tarkoittaa parempaa ja luotettavampaa arviota. tStat-arvo eli t-arvo kuvaa arvion tilastollista merkittävyyttä, suuri arvo on merkitsevempi kuin pieni. p-arvo eli todennäköisyysarvo mittaa todennäköisyyttä, että vaikutus on sattumaa. Pieni arvo tarkoittaa tilastollista merkittävyyttä eikä sattumaa.

Liite 2. Muuttujien yksiköt

sog [kn],

Stw [kn],

Cog [degree_angle],

Heading [degree_angle],

Trim [m],

Depth [m],

Latitude [degree_angle],

Longitude [degree_angle],

Angle.wind.relative [degree_angle],

Angle.wind.true [degree_angle],

Direction.wind.relative [degree_angle],

Direction.wind.true [degree_angle],

Speed.wind.relative [kn],

Speed.wind.true [kn],

massFlowRate.fuel.Ing@engine.main [kg/h],

volFlowRate.fuel@engine [m³/h],

power@generator.diesel [MW],

power@propulsion [MW],

rpm@propulsion [rev/min].

Liite 3. MATLAB-koodit: aineiston yhdistäminen

Liitteessä on kaikki datan käsittelyssä käytetyt koodit. Koodien muotoilussa on saatettu käyttää apuna Microsoft Copilot-tekoälysovellusta ajanjaksolla 11.12.2024–3.2.2025.

Liite sisältää koodit:

Latausjayhdistys3

paiviapesustaajanmukaan

Latausjayhdistys3.m

```
load('AuroraBotniaData3.mat')
AuroraBotniaextractv3(1,:) = []; % Poistaa taulukon ensimmäisen rivin, kun
siinä on höpöjä tietoja.
AuroraBotniaextractv3 = removevars(AuroraBotniaextractv3, "vessel"); %
Aluksen nimeä ei tarvita ja tekstinä sekoittaa taulukon.
AuroraBotniaextractv3 =
renamevars(AuroraBotniaextractv3, "automationdraft", "draught") % Muuttaa nimen
selkeämmäksi.
ABtt = table2timetable(AuroraBotniaextractv3); % Tekee taulukosta timetablen,
että voidaan yhdistää ajan perusteella toisiin taulukoihin.

hajotettuaika = datevec(ABtt.time); % Hajottaa aika-sarakkeen omiksi
elementeikseen.
vuosi = hajotettuaika(:,1); % Määrittää vuoden,
kuukausi = hajotettuaika(:,2); % kuukauden ja
paiva = hajotettuaika(:,3); % päivän kyseisestä sarakkeesta.

aika = table(vuosi,kuukausi,paiva); % Tekee "sarakkeista" ( ) taulukon.
ABtt = [ABtt aika]; % Lisää hajotetut aika-sarakkeet päätäulikon loppuun.
Kuukautta tarvitaan taulukon ajalliseen rajaamiseen. Vuosi ja päivä vain
varuulta tässä vaiheessa mukana, jos myöhemmin tarvii.

load('Maalahtivedenlampotilapvm.mat')
SaaDataMaalahtiDateAdded = removevars(SaaDataMaalahtiDateAdded,
["Havaintoasema", "AikaPaikallinenAika00", "MerkitsevAallonkorkeusm", "AallokonT
ulosuunta", "AallokonTulosuunnanHajonta", "AallokonModaalinenPeriodis"]); %
Poistaa turhat sarakkeet.
MLtt = table2timetable(SaaDataMaalahtiDateAdded); % Tekee taulukosta
timetablen, että voidaan yhdistää ajan perusteella toisiin taulukoihin.

load('Selkameriaaltopoiijupvm.mat')
SaaDataDateAdded = removevars(SaaDataDateAdded,
["Havaintoasema", "AikaPaikallinenAika00"]); % Poistaa turhat sarakkeet.
SMtt = table2timetable(SaaDataDateAdded); % Tekee taulukosta timetablen, että
voidaan yhdistää ajan perusteella toisiin taulukoihin.
```

paiviapesustajaanmukaan % Tekee pesupäivätaulukon erillisellä komennolla.
Tauluko ottaa huomioon jäätalvet.

```
synkattudata = synchronize(ABtt, MLtt, SMtt, pptt, 'union') % Yhdistää kaikki
sarakkeet yhdeksi taulukoksi.
synkattudata.paiviapesusta = fillmissing(synkattudata.paiviapesusta,
"previous"); % Lisää puuttuvat arvot.
% Samalla tavalla voisi täydentää myös sääpoijujen datat, mutta silloin
% talven datasta tulisi väärä.
```

%Alla olevat koodit lisäävät puuttuvat arvot siten, että mikäli seuraavan
%päivän arvo puuttuu, arvoksi merkitään NaN. NaN-rivit voidaan sitten
%helposti poistaa ja täten saadaan sellaiset rivit pois dataasta, joissa ei
ole tietoa sääpoijuista.

```
puuttuvatarvot = isnan(synkattudata{:, "VedenLmptilaC_MLtt"});
```

```
aukot = diff([0; puuttuvatarvot; 0]);
aukonalku = find(aukot == 1);
aukonloppu = find(aukot == -1) - 1;
```

maksimiaukko = days(1); % Määrää kuinka pitkä aika voi olla puutteellista
tietoa. Voi olla myös tunteja, jos tarvii.

```
for i = 1:length(aukonalku)
    if synkattudata.time(aukonloppu(i)) - synkattudata.time(aukonalku(i)) <=
maksimiaukko
        synkattudata.VedenLmptilaC_MLtt(aukonalku(i):aukonloppu(i)) =
interp1(find(~puuttuvatarvot),
synkattudata.VedenLmptilaC_MLtt(~puuttuvatarvot), aukonalku(i):aukonloppu(i),
'linear');
    else
        synkattudata.VedenLmptilaC_MLtt(aukonalku(i):aukonloppu(i)) = NaN;
    end
end
```

```
puuttuvatarvot = isnan(synkattudata{:, "VedenLmptilaC_SMtt"});
```

```
aukot = diff([0; puuttuvatarvot; 0]);
aukonalku = find(aukot == 1);
aukonloppu = find(aukot == -1) - 1;
```

maksimiaukko = days(1);

```
for i = 1:length(aukonalku)
    if synkattudata.time(aukonloppu(i)) - synkattudata.time(aukonalku(i)) <=
maksimiaukko
        synkattudata.VedenLmptilaC_SMtt(aukonalku(i):aukonloppu(i)) =
interp1(find(~puuttuvatarvot),
synkattudata.VedenLmptilaC_SMtt(~puuttuvatarvot), aukonalku(i):aukonloppu(i),
'linear');
    else
        synkattudata.VedenLmptilaC_SMtt(aukonalku(i):aukonloppu(i)) = NaN;
    end
end
```

end

```
puuttuatarvot = isnan(synkattudata{:, "MerkitsevAallonkorkeusm"});
```

```
aukot = diff([0; puuttuatarvot; 0]);
aukonalku = find(aukot == 1);
aukonloppu = find(aukot == -1) - 1;
```

```
maksimiaukko = days(1);
```

```
for i = 1:length(aukonalku)
    if synkattudata.time(aukonloppu(i)) - synkattudata.time(aukonalku(i)) <=
maksimiaukko
        synkattudata.MerkitsevAallonkorkeusm(aukonalku(i):aukonloppu(i)) =
interp1(find(~puuttuatarvot),
synkattudata.MerkitsevAallonkorkeusm(~puuttuatarvot),
aukonalku(i):aukonloppu(i), 'linear');
    else
        synkattudata.MerkitsevAallonkorkeusm(aukonalku(i):aukonloppu(i)) =
NaN;
    end
end
```

```
puuttuatarvot = isnan(synkattudata{:, "AallokonTulosuunta"});
```

```
aukot = diff([0; puuttuatarvot; 0]);
aukonalku = find(aukot == 1);
aukonloppu = find(aukot == -1) - 1;
```

```
maksimiaukko = days(1);
```

```
for i = 1:length(aukonalku)
    if synkattudata.time(aukonloppu(i)) - synkattudata.time(aukonalku(i)) <=
maksimiaukko
        synkattudata.AallokonTulosuunta(aukonalku(i):aukonloppu(i)) =
interp1(find(~puuttuatarvot),
synkattudata.AallokonTulosuunta(~puuttuatarvot), aukonalku(i):aukonloppu(i),
'linear');
    else
        synkattudata.AallokonTulosuunta(aukonalku(i):aukonloppu(i)) = NaN;
    end
end
```

```
puuttuatarvot = isnan(synkattudata{:, "AallokonTulosuunnanHajonta"});
```

```
aukot = diff([0; puuttuatarvot; 0]);
aukonalku = find(aukot == 1);
aukonloppu = find(aukot == -1) - 1;
```

```
maksimiaukko = days(1);
```

```

for i = 1:length(aukonalku)
    if synkattudata.time(aukonloppu(i)) - synkattudata.time(aukonalku(i)) <=
maksimiaukko
        synkattudata.AallokonTulosuunnanHajonta(aukonalku(i):aukonloppu(i)) =
interp1(find(~puuttuvatarvot),
synkattudata.AallokonTulosuunnanHajonta(~puuttuvatarvot),
aukonalku(i):aukonloppu(i), 'linear');
    else
        synkattudata.AallokonTulosuunnanHajonta(aukonalku(i):aukonloppu(i)) =
NaN;
    end
end
end

```

```

puuttuvatarvot = isnan(synkattudata{:, "AallokonModaalinenPeriodis"});

```

```

aukot = diff([0; puuttuvatarvot; 0]);
aukonalku = find(aukot == 1);
aukonloppu = find(aukot == -1) - 1;

```

```

maksimiaukko = days(1);

```

```

for i = 1:length(aukonalku)
    if synkattudata.time(aukonloppu(i)) - synkattudata.time(aukonalku(i)) <=
maksimiaukko
        synkattudata.AallokonModaalinenPeriodis(aukonalku(i):aukonloppu(i)) =
interp1(find(~puuttuvatarvot),
synkattudata.AallokonModaalinenPeriodis(~puuttuvatarvot),
aukonalku(i):aukonloppu(i), 'linear');
    else
        synkattudata.AallokonModaalinenPeriodis(aukonalku(i):aukonloppu(i)) =
NaN;
    end
end
end

```

```

synkattudata = removevars(synkattudata, ["Vuosi_SMtt", "Vuosi_MLtt",
"Kuukausi_SMtt", "Kuukausi_MLtt", "Piv_SMtt", "Piv_MLtt"]); % Poistaa
tarpeettomia muuttujia.

```

paiviapesustaaajanmukaan.m

```

% Taulukon alku- ja loppupäivän määrittäminen. Sama kuin moottoridatan
% taulukossa.

alkupvm = '1.6.2021';
loppupvm = '30.5.2024';
alku = datetime(alkupvm, 'InputFormat', 'd.M.yyyy', 'Format', 'yyyy-MM-dd');
loppu = datetime(loppupvm, 'InputFormat', 'd.M.yyyy', 'Format', 'yyyy-MM-
dd');

% Luo timetable, jossa on päivämäärä ja päiviä pesusta-sarake.
paivat = (alku:loppu)';
paiviapesusta = (1:length(paivat))';
pptt = timetable(paivat, paiviapesusta, 'VariableNames', {'paiviapesusta'});

% Määritetään pesupäivät ja muutetaan ne datetime muotoon.
pesupaivat = ["18.7.2022", "27.7.2023", "16.11.2023", "25.7.2024"];
pesupaivat = datetime(pesupaivat, 'InputFormat', 'd.M.yyyy', 'Format', 'yyyy-
MM-dd');

% Asetetaan pesupäivän arvoksi 0.
for i = 1:length(pesupaivat)
    pptt.paiviapesusta(pptt.paivat == pesupaivat(i)) = 0;
end

% https://www.ilmatieteenlaitos.fi/jaatilastot
% täältä valitaan vuosi

% Assistance restrictions for ports
% Etsitään satamarajoitusten alku- ja loppupäivät kullekin kaudelle.

% 2023-2024
%
https://assets.ctfassets.net/hli0qi7fbbos/2q1w38h4bh9dlMzBfTULhd/752e49192498
eff1cd4cee011d3164fd/MaxIceChart2024.pdf

%alku2324pvm = '6.12.2023';
%loppu2324pvm = '28.4.2024';
%alku2324 = datetime(alku2324pvm, 'InputFormat', 'd.M.yyyy', 'Format', 'yyyy-
MM-dd');
%loppu2324 = datetime(loppu2324pvm, 'InputFormat', 'd.M.yyyy',
'Format', 'yyyy-MM-dd');

% 2022-2023
%
https://assets.ctfassets.net/hli0qi7fbbos/3IWM8w7Qkp4Pt3tUsrcwVB/1a656a0e8f84
dd7b2c9f10bb5bdc7938/MaxIceChart2023.pdf

%alku2223pvm = '24.12.2022';
%loppu2223pvm = '7.5.2023';

% 2021-2022

```

```

%
https://assets.ctfassets.net/hli0qi7fbbos/7zDSuemQmposIIyLk1SyJ5/c2cb780f135622262c3f76bf127c1c02/MaxIceChart2022.pdf

%alku2122pvm = '8.12.2021';
%loppu2122pvm = '27.4.2022';

jaakausi = ["8.12.2021", "27.4.2022"; "24.12.2022", "7.5.2023" ; "6.12.2023",
"28.4.2024"];
jaaalut = datetime(jaakausi(:,1), 'InputFormat', 'd.M.yyyy', 'Format','yyyy-
MM-dd');
jaaloput = datetime(jaakausi(:,2), 'InputFormat', 'd.M.yyyy', 'Format','yyyy-
MM-dd');

%Nollataan aikavälit

for i = 1:length(jaaalut)
    pptt.paiviapesusta((pptt.paivat >= jaaalut(i)) & (pptt.paivat <=
jaaloput(i))) = 0;
end

for i = 2:height(pptt)
    if pptt.paiviapesusta(i) ~= 0
        pptt.paiviapesusta(i) = pptt.paiviapesusta(i-1)+1;
    end
end
end

```

Liite 4. MATLAB-koodit: laskennalliset muuttujat

Liitteessä on kaikki laskennallisten muuttujien luomiseen käytetyt koodit. Koodien muotoilussa on saatettu käyttää apuna Microsoft Copilot-tekoälysovellusta ajanjaksolla 11.12.2024–3.2.2025.

Liite sisältää koodit:

froudenluonti

lampimatpaivatluonti

nopeuseroluonti

powereroluonti

powersumluonti

tehoteteenluonti

froudenluonti.m

```
function froude = froudenluonti(data)

data.Froude = data.stw*1.852 ./ (3.6*sqrt(9.81*data.depth)); %Luo Frouden
syvyysluvun nopeudesta ja syvyydestä. Solmut -> m/s

froude = data

end
```

lampimatpaivatluonti.m

```
function lampimatpaivat = lampimatpaivatluonti(data, kynnys) % Kynnys määrää
sen lämpötilas-asteen, jota suuremmat huomioidaan.

if ~ismember({'VedenLmptilaC_MLtt', 'vuosi', 'kuukausi', 'paiva'},
data.Properties.VariableNames)
    error('Sarake puuttuu.') % Tarkistetaan, onko sarakkeet olemassa.
end

data.lampimatpaivat = zeros(height(data),1); % Tekee nollataulukon.

lparvo = 0; % Määrää lämpimänpäivän arvoksi 0.

yksiloitypaiva = unique([data.vuosi, data.kuukausi, data.paiva], 'rows'); %
Etsii erilaiset päivät eli ei montaa tarkistettavaa samalle päivämäärälle.
```

```

for p = 1:size(yksiloitypaiva,1) % Tekee seuraavan toiminnon jokaiselle
yksiloitypaiva-riville.
    kuluvapaiva = yksiloitypaiva(p,:); % Tallentaa päivämäärän.
    rivitpaivalle = data(data.vuosi == kuluvapaiva(1) & ...
        data.kuukausi == kuluvapaiva(2) & ...
        data.paiva == kuluvapaiva(3),:); % Etsii ne rivit,
joille päivämäärä täsmää.

    if any(rivitpaivalle.VedenLmptilaC_MLtt > kynnys) % Tarkistaa täyttykö
millään päivämäärään täsmänneellä rivillä ehto veden lämpötilasta.
        lparvo = lparvo + 1; % Jos täyttyy, niin listää lämpimämpäivän
arvoon yksi.
    else
        lparvo = 0; % Jos ei täyty, niin lämpimämpäivän arvoksi tulee nolla.
    end
    data.lampimatpaivat(data.vuosi == kuluvapaiva(1) & ...
        data.kuukausi == kuluvapaiva(2) & ...
        data.paiva == kuluvapaiva(3)) = lparvo; % Laittaa
lämpimätpäivät sarakkeeseen lämpimätpäivä arvon.
end

lampimatpaivat = data; % Päivitetty data tallennetaan tällä nimellä.

end

```

nopeuseroluonti.m

```

function nopeusero = nopeuseroluonti(data)

data.nopeusero = abs(data.sog - data.stw); %Laskee nopeuksien erotuksen
itseisarvon.

nopeusero = data

end

```

powereroluonti.m

```

function powerero = powereroluonti(data)

data.PowerEro = abs(data.PowerSum - data.PowerEteen); %Laskee itseisarvon
kokonaistyöntötehon ja eteenpäin suuntaavan työntötehon välille.

powerero = data

end

```

powersumluonti.m

```
function powersum = powersumluonti(data)

data.PowerSum = data.powerpropulsionps + data.powerpropulsionsb; %Yhdistää
styyrpuurin ja paapuurin työntötehot.

powersum = data

end
```

tehoteteenluonti.m

```
function tehoteteen = tehoteteenluonti(data)

kulmaS = data.unitautomationAZP_S_STEERING_ANGLE; %Styyrpuurin puolen kulma
datasta.
kulmaP = data.unitautomationAZP_P_STEERING_ANGLE; %Paapuurin puolen kulma
datasta.
kulmaSrad = deg2rad(kulmaS); %Muuttaa kulman radiaaneiksi.
kulmaPrad = deg2rad(kulmaP); %Muuttaa kulman radiaaneiksi.

data.PowerSEteen = data.powerpropulsionsb .* cos(kulmaSrad); %Luo muuttujan,
joka on styyrpuurin puolen Azipodin eteenpäin työntävä teho.
data.PowerPEteen = data.powerpropulsionps .* cos(kulmaPrad); %Luo muuttujan,
joka on paapuurin puolen Azipodin eteenpäin työntävä teho.
data.PowerEteen = data.PowerPEteen + data.PowerSEteen; %Luo muuttujan, joka
on Azipodin eteenpäin työntävä yhteenlaskettu teho.

tehoteteen = data

end
```

Liite 5. MATLAB-koodit: aineiston rajaamiseen käytettävät koodit

Liitteessä on kaikki aineiston rajaamiseen käytetyt koodit. Viimeisenä on yksittäisiä komentoja, joita on myös käytetty aineiston rajaamiseen. Koodien muotoilussa on saatettu käyttää apuna Microsoft Copilot-tekoälysovellusta ajanjaksolla 11.12.2024–3.2.2025.

Liite sisältää koodit:

aallokonpoisto

akunpoisto

polttoaineidenpoisto

ppohjauskulma

ppsyvays

pptehottaa

pvm-poisto

tehojenpoisto

tehopseteenpoisto

telakkapoisto

yksittäiset komennot

aallokonpoisto.m

```
function aallokkopoistettu = aallokonpoisto(data)

data = removevars(data, "AallokonTulosuunta"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "AallokonTulosuunnanHajonta"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "AallokonModaalinenPeriodis"); % Poistaa kyseisen
sarakkeen.

aallokkopoistettu = data

end
```

akunpoisto.m

```
function akkupoistettu = akunpoisto(data)

data = removevars(data, 'unitautomationPFC1_BATTERY_PACK_ACTIVE_POWER'); %
Poistaa kyseisen sarakkeen.
data = removevars(data, 'unitautomationPFC2_BATTERY_PACK_ACTIVE_POWER'); %
Poistaa kyseisen sarakkeen.

akkupoistettu = data

end
```

polttoaineidenpoisto.m

```
function polttoaineipoistettu = polttoaineidenpoisto(data)

data = removevars(data, "massFlowRatefuellngenginemain1"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "massFlowRatefuellngenginemain2"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "massFlowRatefuellngenginemain3"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "massFlowRatefuellngenginemain4"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "volFlowRatefuelenginemain1"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "volFlowRatefuelenginemain2"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "volFlowRatefuelenginemain3"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "volFlowRatefuelenginemain4"); % Poistaa kyseisen
sarakkeen.

polttoaineipoistettu = data

end
```

ppohjauskulma.m

```
function ylikulmapoistettu = ppohjauskulma(data)

ylikulmaS = find(data.unitautomationAZP_S_STEERING_ANGLE <= 360); %Valitse
luvuksi se, jonka yli menevät poistetaan
data = data(ylikulmaS,:);
ylikulmaP = find(data.unitautomationAZP_P_STEERING_ANGLE <= 360); % Poistaa
yli 360 astetta suuremmat kulmat kummaltakin puolelta.
data = data(ylikulmaP,:);

ylikulmapoistettu = data

% Myös kyseisten sarakkeiden NaN-rivit poistuvat tällä koodilla.

end
```

ppsyvays.m

```
function ylisyvays = ppsyvays(data)

ylisyvalla = find(data.draught < 30); %suuremmat kuin annettu luku olevat
syväydet poistetaan
data = data(ylisyvalla,:);

ylisyvays = data

% Myös kyseisten sarakkeiden NaN-rivit poistuvat tällä koodilla.

end
```

pptehottaa.m

```
function tehottaa = pptehtottaa(data)

tehotaa = find(data.PowerEteen > 0); % valitse luvuksi se, jota alemmat tehot
poistetaan, miinustehot tarkoittaa peruuttamista
data = data(tehotaa,:);

tehottaa = data

end
```

pvm-poisto.m

```
function pvm-poistettu = pvm-poisto(data)

data = removevars(data, "vuosi"); % Poistaa kyseisen sarakkeen.
data = removevars(data, "kuukausi"); % Poistaa kyseisen sarakkeen.
data = removevars(data, "paiva"); % Poistaa kyseisen sarakkeen.

pvm-poistettu = data

end
```

tehojenpoisto.m

```
function tehojenpoistettu = tehojenpoisto(data)

data = removevars(data, "powergeneratorodiesel1"); % Poistaa kyseisen
sarakkeen.
data = removevars(data, "powergeneratorodiesel2");
data = removevars(data, "powergeneratorodiesel3");
data = removevars(data, "powergeneratorodiesel4");
data = removevars(data, "powerpropulsionps");
data = removevars(data, "powerpropulsionsb");
data = removevars(data, "rpmpropulsionps");
data = removevars(data, "rpmpropulsionsb");
```

```
data = removevars(data, "unitautomationAZP_P_STEERING_ANGLE");
data = removevars(data, "unitautomationAZP_S_STEERING_ANGLE");
```

```
tehopoistettu = data
```

```
end
```

tehopseteenpoisto.m

```
function tehopseteenpoistettu = tehopseteenpoisto(data)
```

```
data = removevars(data, "PowerPEteen"); % Poistaa kyseisen sarakkeen.
data = removevars(data, "PowerSEteen"); % Poistaa kyseisen sarakkeen.
```

```
tehopseteenpoistettu = data
```

```
end
```

telakkapoisto.m

```
function telakkapoistettu = telakkapoisto(data)
```

```
alkupaiva = datetime('2023-12-30 22:26:30', 'InputFormat', 'yyyy-MM-dd
HH:mm:ss'); % Määrittää alkuajankohdan.
loppupaiva = datetime('2024-01-06 19:16:00', 'InputFormat', 'yyyy-MM-dd
HH:mm:ss'); % Määrittää loppuajankohdan.
```

```
% Luo logiikkavektorin ajanjakson ulkopuolelle jääville riveille
sailytettavatrivit = ~(data.time >= alkupaiva & data.time <= loppupaiva);
```

```
% Käyttää logiikkavektoria timetablen rajaamiseen
data = data(sailytettavatrivit, :);
```

```
telakkapoistettu = data
```

```
end
```

yksittaisetkomennot.m

```
AB = AB(timerange('2021-08-28', '2024-05-30', 'closed'), :)
% Muodostaa taulukon annettujen aikojen (alku, loppu) välille. Päät kuuluvat
mukaan,
% koska closed.
```

```
AB = AB(AB.stw>0, :) % Poistaa rivit, joissa stw on pienempi kuin nolla.
```

```
AB = AB(AB.nopeusero<=1, :) % Poistaa rivit, joissa nopeusero on yksi tai
suurempi.
```

```
AB = rmmissing(AB) % Poistaa rivit, joissa on NaN-arvoja.
```

Liite 6. MATLAB-koodit: tulosten laskeminen

Liitteessä on kaikki tulosten laskemiseen käytetyt koodit. Koodien muotoilussa on saatettu käyttää apuna Microsoft Copilot-tekoälysovellusta ajanjaksolla 11.12.2024–3.2.2025.

Liite sisältää koodit:

datajako

koeajoanttiivis

normalisoitt

sarakeajo

sarakeajoy

datajako.m

```
% Jakaa taulukon AB kahteen osaan satunnaisesti.
```

```
ristiinvalidointi = cvpartition(height(AB), 'Holdout', 0.2);
```

```
koulutusData = AB(training(ristiinvalidointi), :);
```

```
testiData = AB(test(ristiinvalidointi), :);
```

```
% Kouluttaa mallin ja voi lisätä potensseja
```

```
mdl = fitlm(koulutusData, ['PowerEteen ~ stw + stw^2 + trim +  
speedwindrelative + speedwindrelative^2 + draught + VedenLmptilaC_MLtt +  
MerkitsevAallonkorkeusm + paiviapesusta + Froude']);
```

```
% Poimi RMSE
```

```
rmse = mdl.RMSE;
```

```
% Poimi R-squared ja Adjusted R-squared
```

```
r_squared = mdl.Rsquared.Ordinary;
```

```
adj_r_squared = mdl.Rsquared.Adjusted;
```

```
%Katsoo miten ennuste osuu
```

```
ennusteet = predict(mdl, testiData);
```

```
mse = mean((ennusteet - testiData.PowerEteen).^2) % Keskineliövirhe
```

```
% Todelliset arvot testidatasta
```

```
todelliset = testiData.PowerEteen;
```

```
kertoimet1 = mdl.Coefficients;
```

```

% Kuvaajan piirtäminen
figure; % Luo uusi kuvaikkuna
plot(todelliset, 'o-', 'DisplayName', 'Todellinen'); % Todelliset arvot
hold on;
plot(ennusteet, 'x-', 'DisplayName', 'Ennuste'); % Ennustetut arvot
hold off;
legend('Location','northwest'); % Lisää selite kuvaajaan
xlabel('Havaintojen indeksi'); % X-akselin nimi
ylabel('Normalisoitu PowerEteen-arvo'); % Y-akselin nimi
title('Todelliset vs Ennustetut arvot'); % Kuvaajan otsikko
grid on; % Lisää ruudukko
disp mdl

```

koeajoanntiivis.m

```

% 'trainlm' tai 'trainbr'
% eli Levenburg-Marquardt tai Bayesian Regularization

trainFcn = 'trainlm'

hiddenLayerSize = 7;

net = fitnet(hiddenLayerSize,trainFcn);

% Setup Division of Data for Training, Validation, Testing
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Train the Network
[net,tr] = train(net,x,t);

% Test the Network
y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y)

```

normalisoitt.m

```

function normalisoitutt = normalisoitt(data)

normalisoitutt = data;

muuttujat = data.Properties.VariableNames;

for i = 1:numel(muuttujat)
    sarakedata = data.(muuttujat{i});
    normalisoitusarakedata = ( sarakedata - min(sarakedata)) /
(max(sarakedata) - min(sarakedata));
    normalisoitutt.(muuttujat{i}) = normalisoitusarakedata;
end
end

```

sarakeajo.m

```

function sarakeajo(net, data, sarake, alkuarvo, loppuarvo, askel)

arvojoukko = alkuarvo : askel : loppuarvo;
lm = length(arvojoukko);
%disp(arvojoukko)

tulokset = zeros(lm,1);

for i = 1:lm

    data(:, sarake) = arvojoukko(i);
    ennuste = net(data');
    tulokset(i) = ennuste;
    % disp(i)
    % disp(ennuste)
end

disp(['Ensimmäinen ennuste: ', num2str(tulokset(1))]);
disp(['Viimeisin ennuste: ', num2str(ennuste)]);

% Laske suoran kulmakerroin
p = polyfit(arvojoukko, tulokset, 1); % Suora sovitetaan (lineaarinen
regressio)
kulmakerroin = p(1); % Kulmakerroin (m)
disp(['Suoran kulmakerroin: ', num2str(kulmakerroin)]);

%disp(lm)
%disp(arvojoukko(i))

% disp(tulokset)
plot(arvojoukko, tulokset);
title(['Sarakkeen numero ', num2str(sarake), ' muutoksen vaikutus muuttujaan
PowerEteen']);
xlabel('syötearvo');
ylabel('ennuste');
grid on;
end

```

sarakeajoy.m

```

function sarakeajoy(net, data, sarake, alkuarvo, loppuarvo, askel, min_arvo,
max_arvo)

arvojoukko = alkuarvo : askel : loppuarvo;
lm = length(arvojoukko);

tulokset = zeros(lm,1);

for i = 1:lm
    data(:, sarake) = arvojoukko(i);
    ennuste = net(data');
    tulokset(i) = ennuste;
end

```

```
disp(['Ensimmäinen ennuste: ', num2str(tulokset(1))]);
disp(['Viimeisin ennuste: ', num2str(tulokset(end))]);

% Muunna tulokset takaisin normalisoimattomiksi
normalisoimattomat_tulokset = tulokset * (max_arvo - min_arvo) + min_arvo;

% Laske kulmakerroin normalisoimattomille tuloksille
p = polyfit(arvojoukko, normalisoimattomat_tulokset, 1); % Sovita suora
kulmakerroin = p(1); % Kulmakerroin (m)
disp(['Suoran kulmakerroin: ', num2str(kulmakerroin)]); % Tulosta
kulmakerroin

% Piirrä kuvaaja normalisoimattomilla arvoilla
plot(arvojoukko, normalisoimattomat_tulokset);
%title(['Sarakkeen numero ', num2str(sarake), ' muutoksen vaikutus muuttajaan
PowerEteen (normalisoimaton)']);
title(['Syötteiden muutoksen vaikutus muuttajaan PowerEteen
(normalisoimaton)']);
xlabel('Syötearvo (normalisoitu)');
ylabel('Ennuste (normalisoimaton) / MW');
grid on;

end
```