

redistribution controller is based on the idea of combining frequency control according to demand and rapid load reduction. The basic idea is that the use of dynamic feedback between the power system and electric thrusters can improve frequency regulation on a ship. Due to the relatively large inertia of the ship, a rapid power modification at the thrusters by the power redistribution controller will have little effect on the response of the ship. In addition, other energy-using consumers can also be brought under control. Thus, the development of a power redistribution controller is an important task that reduces load fluctuations on the ship's network and increases the efficiency of its electrical system. The most significant result is the definition of a new approach to power redistribution control based on the correction of the difference between the actual speed of the propeller on the shaft and the set speed. This approach involves the use of two different control strategies. The first strategy is to use the feedback from the grid frequency deviation to correct the screw shaft speed deviations. The second control strategy is to use feedback from the generating system to correct torque deviations. It was found that the second strategy has improved robustness, but an observer is required to use it. For further research, it is possible to consider the directions of modelling the functioning of the power redistribution controller according to the second strategy in order to determine the reliability of the observer to the parameters of data inaccuracies and the possibility of using it for control.

Keywords: power redistribution controller, ship, power system, load, dynamic feedback, electric thruster, strategy.

УДК 004.032.26:629.5.017.2

doi.org/10.33298/2226-8553.2024.1.39.16

Пліта Л.Л., Трофименко І.В., Федунів В.М., Іваненко В.М.

МЕТОДИКА РОЗРОБКИ КАСКАДНОЇ МОДЕЛІ РОЗРАХУНКУ КООРДИНАТ СУДНА НА ОСНОВІ ГЛИБОКОГО НАВЧАННЯ

Метою статті є дослідження методики розробки каскадної моделі розрахунку координат судна на основі глибокого навчання, здатної прогнозувати відносну швидкість судна в нерухомій системі координат під впливом вітру і хвиль. Поставлена мета досягається шляхом побудови топології каскадної моделі розрахунку координат судна, визначення порядку формування навчального набору даних та тестування результатів навчання. Для визначення координат місця розташування судна, зокрема, з використанням автономних навігаційних систем, необхідно забезпечити стабільність судна по заданій траєкторії. Однак, супутникові навігаційні системи мають свої недоліки, такі як обмеженість використання в певних умовах, наприклад, в середовищах, де радіохвилі не проходять, а також проблеми з шумами і цілісністю системи. У випадках, коли стикаються з форс-мажорними природними явищами, які можуть пошкодити супутникові системи, стеження судна може залежати від алгоритмів обробки навігаційної інформації в автономних системах для підвищення точності і цілісності інтегрованих навігаційних систем, що використовують дані супутникової навігації. Часто визначення деяких зовнішніх факторів, таких як параметри збурення, супроводжується значними похибками, що призводить до значної невизначеності при прогнозуванні обчислюваних координат. У порівнянні з наявними алгоритмами, використання нейронних мереж може бути більш ефективним у умовах невизначеності, оскільки вони мають нелінійні властивості перетворення вхідних сигналів у вихідні. Таким чином, прогноз обчислюваних координат при впливі зовнішніх факторів повністю відповідає цим умовам. Найбільш

суттєвим результатом є каскадна модель розрахунку координат судна на основі довготривалої короткочасної пам'яті (*Long short-time memory; LSTM*). В рамках подальшого напрямку роботи можна зазначити, що навіть якщо ця прогностична модель є більш точною, ніж традиційні методи, її ефективність повинна бути підвищена, щоб досягти оптимальних результатів. Також, важливо зазначити, що гіперпараметр оптимізації є ключовим елементом для моделей глибокого навчання. Гіперпараметри визначають як навчальну продуктивність моделі, так і якість її тестування.

Ключові слова: судно, координати, обчисленням шляху, модель, нейронна мережа, глибоке навчання, довготривала короткочасна пам'ять.

Постановка проблеми. На підставі великої кількості експериментальних даних, які вказують на неточності в розрахунках для різних районів океану і різних типів суден, а також на основі теоретичних досліджень можна зробити висновок, що координати, які отримуються, залежать від режиму руху судна і значень деяких зовнішніх факторів. При цьому процес зміни похибок розрахунку в часі не є стабільним, а залежить від зміни зовнішніх факторів, які впливають на судно. Визначення координат місця розташування судна, особливо з використанням автономних навігаційних систем, дуже пов'язане з проблемою стабілізації судна по заданій траєкторії. Як відомо, супутникові навігаційні системи мають ряд недоліків, таких як неможливість використання в певних умовах, наприклад, в середовищах, непрозорих для радіохвиль між супутником і споживачем, а також проблеми з шумами і цілісністю системи.

У деяких умовах, наприклад, при наявності форс-мажорних природних явищ, які можуть серйозно пошкодити орбітальне угруповання супутників, системи стеження судна можуть стати єдиним засобом навігації для визначення координат. У зв'язку з цим виникає необхідність розробки алгоритмів обробки навігаційної інформації в таких системах для підвищення точності автономних систем і цілісності інтегрованих навігаційних систем, що використовують дані супутникової навігації і автономних систем. Важливо відзначити, що процес зміни помилки в системах числення носить нелінійний характер.

Деякі зовнішні фактори, наприклад параметри збурення, часто визначаються з великими похибками, що призводить до значної невизначеності в прогнозуванні обчислюваних координат. На відміну від існуючих алгоритмів, нейронні мережі мають нелінійні властивості перетворення вхідних сигналів у вихідні, і можуть бути більш ефективними в умовах невизначеності. Отже, прогноз обчислюваних координат під впливом зовнішніх факторів повністю відповідає цим умовам.

Аналіз останніх досліджень і публікацій. Методи машинного навчання і глибокого навчання останнім часом використовуються для вирішення практичних завдань в судноплавстві [1, 2]. Застосування полягає у підвищенні ефективності та безпеки експлуатації судна шляхом визначення траєкторії, швидкості та енергоефективності судна, а також виявлення ризиків аномалій та зіткнень. Такі нові підходи можуть підтримувати типові проблеми оптимізації доставки. Наприклад, при плануванні траєкторії судна оцінюється оцінка ризиків зіткнення або визначення корисності часу прибуття [3] можуть бути поліпшені, відповідно, за рахунок використання методів машинного навчання для виявлення перешкод [4, 5] і прогнозування швидкості. Спеціальне застосування, в якому методи машинного навчання мають важливе значення, стосується пошуково-рятувальних операцій під час морської міграції [6], які можуть бути додатково вдосконалені методами глибокого навчання для візуального виявлення та розпізнавання мови [7]. Зростаюче використання машинного навчання та методів глибокого навчання в дослідженнях морського транспорту було обумовлено різними джерелами морських даних. Однак деякі джерела, що надаються датчиками, можуть страждати від проблем з якістю і можуть бути ненадійними через збої, пов'язані з людською помилкою, апаратними несправностями, помилками програмування або неправильною установкою та налаштуванням [8]. У міру вдосконалення технологій можна розглянути деякі рішення для подолання проблем з даними [9, 10]. Тому особливу увагу слід приділити очищенню і попередній обробці даних перед проведенням будь-якого аналізу. Крім використання навігаційних даних про історичні

рейси суден і записи суднових рейсів, методи глибокого навчання на основі згорткових нейронних мереж можуть бути застосовані до супутникових і дистанційних зондувань зображень для завдань виявлення суден для поліпшення навігації і безпеки морського руху [11, 12].

Методи машинного навчання також були застосовані для вирішення проблеми прогнозування швидкості судна. Автори в роботі [13] досліджували статистичну залежність між швидкістю, обертами суднового гвинта за хвилину. Вони порівнювали лінійну регресію, аналіз авторегресії першого порядку та моделі змішаного ефекту за допомогою вимірювань контейнерних суден протягом року. Авторами роботи [14] була запропонована модель для прогнозування руху судна у вигляді часових рядів, включаючи швидкість. Вони використовували нелінійну авторегресію екзогенної мережі і модель, засновану на нейронній мережі зі зворотним зв'язком. Вони запропонували моделі, засновані на історичних вхідних змінних з даних датчиків судна для кожної змінної, для отримання багатоступеневих виходів. Автори у роботі [15] передбачили швидкість суден на внутрішніх водних шляхах за допомогою моделі на основі багатошарового перцептрона і внесли дані про розташування і швидкість суден з системи автоматичної ідентифікації (AIS). Вони порівнювали запропоновану модель з моделлю кінцевої імпульсної характеристики і авторегресійної моделлю. Автори в [16] використовували дані AIS і метеорологічний звіт з 14 танкерів і 62 вантажних суден. Вони передбачали швидкість, використовуючи набір вхідних даних, включаючи збір інформації про погоду, курс судна, осад і т. д. Вони порівнювали методи лінійної регресії, поліноміальної регресії, дерева рішень і ансамблевого дерева.

Автори в роботі [17] використовували змодельовані дані з програмного забезпечення маршрутизації для трансатлантичного маршруту конкретного контейнеровоза частотою 30 нм з байєсівськими мережами для прогнозування швидкості судна. Вони використовували в якості вхідних даних значну висоту хвиль, піковий період хвиль, вихід головного двигуна, частоту обертання вала і відносний кут зіткнення хвиль. Автори в роботі [18] запропонований MLP на основі змодельованих даних програмного забезпечення маршрутизації для прогнозування швидкості судна в різних умовах експлуатації. Входами служили вихідний крутний момент маршового двигуна, обороти вала руху, значна висота хвилі, піковий період хвиль і відносний кут зіткнення хвиль. Вони також показали, що прогнозування швидкості може бути виконано з хорошими характеристиками, використовуючи тільки фактори навколишнього середовища і не враховуючи обороти і крутний момент від двигуна. Експерименти розглядали чотири змодельовані набори даних, кожен з яких відповідав подорожі на схід або захід у Північній Атлантиці протягом чотиримісячного періоду.

Метою статті є дослідження методики розробки каскадної моделі розрахунку координат судна на основі глибокого навчання, здатної прогнозувати відносну швидкість судна в нерухомій системі координат під впливом вітру і хвиль.

Основні результати дослідження. Визначення положення судна шляхом обчислення його поточних (злічених) координат з відомого початкового курсу, швидкості з урахуванням дрейфу, дрейфу за течією і часом називається обчисленням координат судна (обчисленням шляху судна).

В якості моделі розрахунку координат судна у статті пропонується використовувати каскадну модель двох глибоких нейронних мереж, що прогнозують відносну швидкість руху судна у фіксованій системі координат.

В якості базової глибокої нейронної мережі в роботі використовується довготривала короткочасна пам'ять (Long short-time memory; LSTM) [19]. LSTM – це особливий вид архітектури рекурентних нейронних мереж, здатний вивчати довгострокові залежності. Ключовим компонентом LSTM є стан комірки, горизонтальна лінія, що проходить уздовж верхньої частини діаграми.

Графік комірок LSTM представлений на рисунку 1. У мережах LSTM використовується затвор забудки (1), вхідний затвор (2) і вихідний затвор (3). прями́й прохі́д комірки LSTM визначається такими рівняннями:

$$f_t = \sigma_g(W_f x_t + U_f h_t - 1 + b_f), \quad (1)$$

$$i_t = \sigma_g(W_i x_t + U_i h_t - 1 + b_i), \quad (2)$$

$$o_t = \sigma_g(W_o x_t + U_o h_t - 1 + b_o), \quad (3)$$

$$\tilde{c}_t = \tanh(W_{\tilde{c}} x_t + U_{\tilde{c}} h_t - 1 + b_{\tilde{c}}), \quad (4)$$

$$c_t = f_t c_{t-1} - 1 + i_t \tilde{c}_t, \quad (5)$$

$$h_t = o_t \tanh(c_t), \quad (6)$$

де σ_g – функція активації сигмовидної лінії;

$\tilde{c}_t$ і c_t – вектори станів комірки;

W и U – вагові матриці;

b – вектор переміщення;

h_t – вихідний вектор шару LSTM.




Рисунок 1 – Приклад перегляду комірки LSTM

Перша нейронна мережа LSTM 1 прогнозує швидкість дрейфу судна V_{oy1} , а навчальний набір даних формується відповідно до рівняння Ріккати

$$\frac{dV_{oy1}}{dt} = f(V_{oy1}, t) = -\frac{C_{\gamma\beta}^{\beta} \rho A_{L\sigma}}{2m(1+k_{22})} |V_{ox1}| V_{oy1} - \frac{c_2 \rho A_{L\sigma}}{2m(1+k_{22})} |V_{oy1}| V_{oy1} - \frac{C_{\gamma\beta}^{\beta} \rho A_{L\sigma}}{2m(1+k_{22})} |V_{ox1}| V_{oy1} - \frac{1.05 \rho_A A_{VL}}{2m(1+k_{22})} V_r^2 \sin \alpha_r - \frac{1+k_{11}}{1+k_{22}} V_{ox1} \frac{dK}{dt} + \frac{1}{m(1+k_{22})} \frac{F_W}{\cos \theta}, \quad (7)$$

де $C_{\gamma\beta}^{\beta}$ і c_2 – коефіцієнти, що визначають в'язкість тертя;

k_{11} і k_{22} – відповідно поздовжній і поперечний коефіцієнти з'єднаних мас;

$A_{L\sigma}$ – задана площа зануреної частини діаметральної площини;

A_{VL} – площа бічного вітрила;

ρ і ρ_A – щільність атмосферного повітря і води;

m – маса судна;

V_{ox1} – поздовжня з центром ваги, що жорстко з'єднана з судном;

V_r і α_r – швидкість і напрямок нахилу видимого вітру відповідно;

K – курс судна;

F_W – сила на стороні схвильованої поверхні моря.

Друга нейронна мережа LSTM 2 має вхідні значення, що характеризують кінематику судна, а на виході – складові вектора відносної швидкості судна в нерухомій системі координат.

У зв'язку з тим, що розмірність вектора вхідних даних в загальному випадку може змінюватися, використання повністю зв'язаних вхідних шарів каскадної моделі досить дороге у використанні, тому для вхідного аналізу будемо використовувати шари згортки (CNN) через їх особливість роботи з великими векторами і матрицями вхідних даних з поступовим зменшенням розмірності.

Загальна схема каскадної моделі розрахунку координат судна наведена на рис. 2.




Рисунок 2 – Загальна схема каскадної моделі розрахунку координат судна

З теорії нейронних мереж відомо, що рішення диференціального рівняння (7) можна представити за допомогою динамічної нейронної мережі, що має зворотний зв'язок, а точніше нейронної мережі, що являє собою модель нелінійної авторегресії із зовнішніми входами. Таким чином, використання мережі LSTM в цьому виправдано. Давайте спочатку визначимося з набором зовнішніх вхідних сигналів X , необхідних для навчання роботи мережі LSTM 1:

$$X = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} \rho |V_{ox1}| \\ \rho_A V_r^2 \sin \alpha_r \\ F_W \\ V_{ox1} \frac{dK}{dt} \end{pmatrix}, \quad (8)$$

який враховує вітер, хвилі, поздовжню і кутову швидкість судна. Як вихідний сигнал, виступає швидкість дрейфу $Y = V_{oy1}$.

Оскільки мережа LSTM 1 динамічна, визначимо кількість в рядках одиничних затримок. У нашому випадку ми маємо справу з двома лініями одиничних затримок – зовнішніми вхідними значеннями і по вихідному сигналу, що подається лінією зворотного зв'язку на мережевий вхід. Дискретність моделі становить 1 с. Кількість затримок для обох ліній буде обрано рівним 15. Це означає, що мережа накопичує інформацію про динаміку роботи системи за попередні 14 с, і дає прогноз на 15 с. Тобто нейронна мережа прогнозує швидкість дрейфу корабля на крок вперед.

Мережа перетворює кінематичні характеристики в компоненти відносної швидкості. тому доцільно використовувати мережу прямого поширення як вхід до мережі LSTM 2. Вхідний вектор $\begin{pmatrix} V_{ox} \\ V_{oy} \end{pmatrix}$ має вигляд

$$X = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} \cos K \\ \sin K \\ V_{ox1} \\ V_{oy1} \end{pmatrix}, \quad (9)$$

і вихідний вектор $Y = \begin{pmatrix} V_{ox} \\ V_{oy} \end{pmatrix}$.

Тепер необхідно сформувати навчальний набір (X, Y) для подальшого навчання каскадної моделі. Визначення навчального набору зразків має на увазі якість і кількість вхідних матеріалів. Виходи визначаються однозначно за допомогою імітаційної моделі. Якість вибірок має на увазі простір можливих значень вхідного вектора, що визначається межами можливих значень його складових, а при розподілі вектору по простору, яке залежить від дискретності складових і закону розподілу, по якому відбувається вибірка складових вектору.

Спочатку визначимо межі вхідного вектора X мережі LSTM 1. Для цього необхідно вказати межі інтервалів можливих значень величин, які утворюють вхідний вектор. Крім того, виникає необхідність виділення дискретності цих можливих значень, так як занадто близькі значення, як показує практика, можуть ускладнити процес навчання нейронної мережі. Друга, третя і четверта складові вхідного сигналу є функціями декількох початкових значень, так як для їх отримання використовується стохастичний алгоритм, існує ймовірність, що після навчання в робочому режимі вхідні значення x_2, x_3, x_4 не будуть належати інтервалам, на яких навчалася мережа. А це призводить до значної втрати точності. Для того щоб уникнути такої ситуації, інтервали можливих значень деяких величин відповідають за формування сигналів x_2, x_3, x_4 потребує розширення.

У теперішній час існує чотири скінченних набори можливих значень вхідних компонентів, що зберігаються в оперативній пам'яті у вигляді векторів деякої довжини. У системі MATLAB є функція, що дозволяє генерувати псевдовипадкові натуральні числа від 1 до деякого максимуму заданого значення за законом рівномірного розподілу. Якщо вибрати в якості цієї величини кількість елементів вектора можливих значень відповідного початкового значення, кожен раз користуючись цією функцією, отримаємо псевдовипадкове значення цієї величини. Це створює псевдовипадкову часову послідовність для кожної початкової величини. Потім приступають до відповідної часової послідовності векторів вхідного сигналу $X\{X\}_{i=1-n}$. Використовуючи алгоритм вирішення рівняння Ріккаті (7), знайдемо відповідну послідовність вихідного сигналу $\{Y\}_{i=1-n}$. Таким чином, успішно формується навчальний набір даних $\{X, Y\}_{i=1-n}$.

Визначивши якість зразків для навчання, тепер необхідно вибрати їх оптимальну кількість. Незважаючи на те, що деякі дослідження нейронних мереж пропонують певні формули для оцінки необхідної кількості вибірок, на практиці ці методики не завжди працюють. Тому в цьому випадку доводиться звертатися до методу проб і помилок. Експериментально встановлено, що нейронна мережа LSTM 1 навчається на зразках, якщо їх кількість дорівнює 20 000.

Для нейронної мережі LSTM 2 аналогічним чином визначаються набори значень курсів і швидкості дрейфу. Кількість зразків для навчання було обрано методом проб і помилок і становить 10 000. Потрібну меншу кількість зразків в порівнянні з їх кількістю для мережі LSTM 1 можна пояснити тим, що друга мережа не має в своїй структурі єдиних ліній затримки і, як наслідок, вона має малу кількість вільних параметрів (ваги і пороги).

Сформувавши множину навчальних прикладів для обох мереж, проводиться їх навчання. Процедури навчання і тестування мережі складаються з трьох основних етапів: пряме поширення сигналів по мережі через кожен шар, навчання мережі за допомогою алгоритму зворотного поширення помилок, зберігання значень сигналу пам'яті в кожному прихованому шарі у вигляді ортогональної множини в багатовимірному просторі.

Після навчання каскадної моделі нейронних мереж постає завдання перевірити їх працездатність за допомогою таких послідовностей вхідних і вихідних сигналів, які не

використовувалися для навчання. Для перевірки роботи мережевої системи необхідно сформувати послідовності вхідних значень, отримати вихідні послідовності системи і порівняти їх з результатами, отриманими за допомогою імітаційної моделі.

Тестування каскадної моделі складається з двох етапів. На першому етапі не враховується часове співвідношення значень, необхідних для формування вхідного сигналу. Другий етап враховує взаємозв'язок величин як між собою, так і в часі. На кожному етапі розглядається як стаціонарний характер сигналів, так і зміни з часом. Обидва етапи доповнюють один одного. В якості критерію відповідності нейронної мережі імітаційної моделі традиційно вибирається найбільше значення обсягу в певний проміжок часу.

Таким чином, за результатами тестування каскадної моделі нейронної мережі можна зробити висновок, що побудована система з двох нейронних мереж в 2 000 модельних ситуаціях прогнозує відносну швидкість судна таким чином, щоб розбіжність між прогнозованими нею координатами і координатами, отриманими за допомогою імітаційної моделі, не перевищувала в плані те, що було визначено на практиці. Це означає, що нейронна мережа замінює алгоритм злічення, заснований на чисельному інтегруванні рівняння (2).

Таким чином, синтезована каскадна модель працює в просторі швидкостей. Перша мережа перетворює силові впливи від зовнішніх факторів у швидкість бічного дрейфу судна. Друга мережа на виході має складові вектора відносної швидкості судна у фіксованій системі координат. Абсолютна швидкість судна виходить шляхом додавання відносної і поточної швидкості. Вибір архітектури мережі багато в чому визначається роллю номера, які вони відтворюють у моделі. Для навчання мереж необхідно сформувати навчальний набір зразків за допомогою імітаційної моделі. Кількість і якість цих зразків визначається методом проб і помилок. Після закінчення навчання виникає необхідність тестування мережевої системи, яке проходить в два етапи. На першому етапі не враховується взаємозв'язок між величинами, на другому пропонується певна модель взаємозв'язку між величинами. Результати випробувань дозволяють припустити, що навчена каскадна модель практично ідентична імітаційної моделі. Тестування мережі з використанням вхідних сигналів від натурних спостережень також дозволяє зробити висновок на користь адекватності каскадної моделі нейронної мережі.

Висновки. Основним результатом є створення моделі каскадної нейронної мережі, яка здатна прогнозувати відносну швидкість судна в нерухомій системі координат під впливом вітру і хвиль. Для ефективного навчання цієї мережі необхідно мати досить великий обсяг даних, що покривають діапазон значень, які можуть зустрічатися на практиці. Це вимагає створення імітаційної моделі, здатної дати уявлення про швидкість дрейфу судна в умовах вітру і хвиль. Для цього використовуються відомі співвідношення для зовнішніх сил, що діють на судно, які дозволяють скласти диференціальне рівняння Ріккаті. Навчання нейронних мереж вимагає наборів даних. Після навчання каскадної моделі необхідно провести тестування за допомогою спеціальної методики. Результати випробувань свідчать про те, що водоспадна модель може замінити імітаційну модель з точністю, що не перевищує допустимого значення. Каскадна модель нейронної мережі, яка замінює рівняння Ріккаті, має не тільки перевагу перед диференціальною моделлю, але і здатна нелінійно перетворювати зовнішні фактори в швидкість дрейфу корабля. На відміну від відомих методів чисельного вирішення диференціальних рівнянь, які або лінеаризовані через певні проміжки часу, або обмежені сумою перших кількох доданків ряду, каскадна модель здатна обробляти складні нелінійні залежності між вхідними і вихідними даними. Хоча ця прогностична модель є більш точною, ніж традиційна практика, її ефективність повинна бути підвищена для досягнення оптимальних результатів. Також слід зазначити, що гіперпараметр оптимізації є ключовим аспектом в моделях глибокого навчання. Гіперпараметри контролюють як навчальну продуктивність моделі, так і якість її тестування.

ЛІТЕРАТУРА

1. Emerging approaches applied to maritime transport research: Past and future / R. Yan et al. *Communications in Transportation Research*. 2021. Vol.1. P.100011. URL: <https://doi.org/10.1016/j.commtr.2021.100011> (date of access: 02.02.2024).
2. Exploiting AIS Data for Intelligent Maritime Navigation: A Comprehensive Survey From Data to Methodology / E. Tu et al. *IEEE Transactions on Intelligent Transportation Systems*. 2018. Vol. 19, no. 5. P. 1559–1582. URL: <https://doi.org/10.1109/tits.2017.2724551> (date of access: 02.02.2024).
3. Alessandrini A., Mazzarella F., Vespe M. Estimated Time of Arrival Using Historical Vessel Tracking Data. *IEEE Transactions on Intelligent Transportation Systems*. 2019. Vol. 20, no. 1. P. 7–15. URL: <https://doi.org/10.1109/tits.2017.2789279> (date of access: 02.02.2024).
4. Öztürk Ü., Akdağ M., Ayabakan T. A review of path planning algorithms in maritime autonomous surface ships: Navigation safety perspective. *Ocean Engineering*. 2022. Vol. 251. P. 111010. URL: <https://doi.org/10.1016/j.oceaneng.2022.111010> (date of access: 05.03.2024).
5. Early Detection of Obstacle to Optimize the Robot Path Planning / K. Sharma et al. *Drones*. 2022. Vol. 6, no. 10. P. 265. URL: <https://doi.org/10.3390/drones6100265> (date of access: 02.02.2024).
6. Hoffmann Pham, K.; Boy, J.; Luengo-Oroz, M. Data Fusion to Describe and Quantify Search and Rescue Operations in the Mediterranean Sea. In *Proceedings of the 2018 IEEE 5th International Conference on Data Science and Advanced Analytics (DSAA)*, Turin, Italy, 1–3 October 2018. P. 514–523.
7. Real-Time Survivor Detection System in SaR Missions Using Robots / K. Sharma et al. *Drones*. 2022. Vol. 6, no. 8. P. 219. URL: <https://doi.org/10.3390/drones6080219> (date of access: 02.02.2024).
8. Automatic Identification System (AIS): Data Reliability and Human Error Implications / A. Harati-Mokhtari et al. *Journal of Navigation*. 2007. Vol. 60, no. 3. P. 373–389. URL: <https://doi.org/10.1017/s0373463307004298> (date of access: 02.02.2024).
9. Masnicki R., Mindykowski J. Case study—based zigbee network implementation for maritime on-board safety improvement. In *Proceedings of the 2019 IMEKO TC-19 International Workshop on Metrology for the Sea*, Genova, Italy, 3–5 October 2019. P. 3–5.
10. Zigbee-Based Low Power Consumption Wearables Device for Voice Data Transmission / A. S. AlShuhail et al. *Sustainability*. 2022. Vol. 14, no. 17. P. 10847. URL: <https://doi.org/10.3390/su141710847> (date of access: 02.02.2024).
11. R-CNN-Based Ship Detection from High Resolution Remote Sensing Imagery / S. Zhang et al. *Remote Sensing*. 2019. Vol. 11, no. 6. P. 631. URL: <https://doi.org/10.3390/rs11060631> (date of access: 02.02.2024).
12. Domain Adaptive Ship Detection in Optical Remote Sensing Images / L. Li et al. *Remote Sensing*. 2021. Vol. 13, no. 16. P. 3168. URL: <https://doi.org/10.3390/rs13163168> (date of access: 02.02.2024).
13. Statistical models for the speed prediction of a container ship / W. Mao et al. *Ocean Engineering*. 2016. Vol. 126. P. 152–162. URL: <https://doi.org/10.1016/j.oceaneng.2016.08.033> (date of access: 02.02.2024).
14. Neural-network-based modelling and analysis for time series prediction of ship motion / G. Li et al. *Ship Technology Research*. 2017. Vol. 64, no. 1. P. 30–39. URL: <https://doi.org/10.1080/09377255.2017.1309786> (date of access: 02.02.2024).
15. Long-Term Ship Speed Prediction for Intelligent Traffic Signaling / S. Gan et al. *IEEE Transactions on Intelligent Transportation Systems*. 2017. Vol. 18, no. 1. P. 82–91. URL: <https://doi.org/10.1109/tits.2016.2560131> (date of access: 02.02.2024).
16. Machine Learning Approaches for Ship Speed Prediction towards Energy Efficient Shipping / M. Abebe et al. *Applied Sciences*. 2020. Vol. 10, no. 7. P. 2325. URL: <https://doi.org/10.3390/app10072325> (date of access: 02.02.2024).
17. Krata P., Vettor R., Soares C.G. Bayesian Approach to Ship Speed Prediction based on Operational Data. In *Developments in the Collision and Grounding of Ships and Offshore Structures*. London: CRC Press, 2019. P. 384–390.

18. Moreira L., Vettor R., Guedes Soares C. Neural Network Approach for Predicting Ship Speed and Fuel Consumption. *Journal of Marine Science and Engineering*. 2021. Vol. 9, no. 2. P. 119. URL: <https://doi.org/10.3390/jmse9020119> (date of access: 02.02.2024).
19. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997. Vol. 9, no. 8. P. 1735–1780. URL: <https://doi.org/10.1162/neco.1997.9.8.1735> (date of access: 02.02.2024).

REFERENCES

1. Yan, R., Wang, Y., Qu, X., Nguyen, H.-D., & Prasad, N. R. (2021). Emerging approaches applied to maritime transport research: Past and future. *Communications in Transportation Research*, 1, 100011. <https://doi.org/10.1016/j.commtr.2021.100011>
2. Tu, E., Jones, D., Jeffries, M., Jones, N., Li, S., Reinhardt, J., Stevens, A., van der Heide, A. J., Nguyen, V.-T., & Mellema, J. (2018). Exploiting AIS Data for Intelligent Maritime Navigation: A Comprehensive Survey From Data to Methodology. *IEEE Transactions on Intelligent Transportation Systems*, 19(5), 1559–1582. <https://doi.org/10.1109/tits.2017.2724551>
3. Alessandrini, A., Mazzarella, F., & Vespe, M. (2019). Estimated Time of Arrival Using Historical Vessel Tracking Data. *IEEE Transactions on Intelligent Transportation Systems*, 20(1), 7–15. <https://doi.org/10.1109/tits.2017.2789279>
4. Öztürk, Ü., Akdağ, M., & Ayabakan, T. (2022). A review of path planning algorithms in maritime autonomous surface ships: Navigation safety perspective. *Ocean Engineering*, 251, 111010. <https://doi.org/10.1016/j.oceaneng.2022.111010>
5. Sharma, K., Singh, S., Kaiwartya, O., Cengiz, K., & Vikash, C. (2022). Early Detection of Obstacle to Optimize the Robot Path Planning. *Drones*, 6(10), 265. <https://doi.org/10.3390/drones6100265>
6. Hoffmann Pham, K., Boy, J., & Luengo-Oroz, M. (2018). Data Fusion to Describe and Quantify Search and Rescue Operations in the Mediterranean Sea. In *Proceedings of the 2018 IEEE 5th International Conference on Data Science and Advanced Analytics (DSAA)*. 514–523.
7. Sharma, K., Kumar, J., Singh, S., Kaiwartya, O., Cengiz, K., & Vikash, C. (2022). Real-Time Survivor Detection System in SaR Missions Using Robots. *Drones*, 6(8), 219. <https://doi.org/10.3390/drones6080219>
8. Harati-Mokhtari, A., Wall, A., Brooks, P., & Wang, J. (2007). Automatic Identification System (AIS): Data Reliability and Human Error Implications. *Journal of Navigation*, 60(3), 373–389. <https://doi.org/10.1017/s0373463307004298>
9. Masnicki, R., & Mindykowski, J. (2019). Case study—based zigbee network implementation for maritime on-board safety improvement. In *Proceedings of the 2019 IMEKO TC-19 International Workshop on Metrology for the Sea*. 3–5.
10. AlShuhail, A. S., Ismail, W., & Idrus, S. M. (2022). Zigbee-Based Low Power Consumption Wearables Device for Voice Data Transmission. *Sustainability*, 14(17), 10847. <https://doi.org/10.3390/su141710847>
11. Zhang, S., Yang, X., Ma, X., Xiao, R., Cui, D., & Chen, J. (2019). R-CNN-Based Ship Detection from High Resolution Remote Sensing Imagery. *Remote Sensing*, 11(6), 631. <https://doi.org/10.3390/rs11060631>
12. Li, L., Tang, J., Wang, C., Ying, S., Luo, B., Du, X., & Wei, Y. (2021). Domain Adaptive Ship Detection in Optical Remote Sensing Images. *Remote Sensing*, 13(16), 3168. <https://doi.org/10.3390/rs13163168>
13. Mao, W., Eriksen, T., & Faster, M. (2016). Statistical models for the speed prediction of a container ship. *Ocean Engineering*, 126, 152–162. <https://doi.org/10.1016/j.oceaneng.2016.08.033>
14. Li, G., Qian, Z., Zhu, Z., & Sheng, D. (2017). Neural-network-based modelling and analysis for time series prediction of ship motion. *Ship Technology Research*, 64(1), 30–39. <https://doi.org/10.1080/09377255.2017.1309786>

15. Gan, S., Su, Y., Meng, X., & Lam, W. H. K. (2017). Long-Term Ship Speed Prediction for Intelligent Traffic Signaling. *IEEE Transactions on Intelligent Transportation Systems*, 18(1), 82–91. <https://doi.org/10.1109/tits.2016.2560131>
16. Abebe, M., Himmetoglu, B., & Botasav, C. (2020). Machine Learning Approaches for Ship Speed Prediction towards Energy Efficient Shipping. *Applied Sciences*, 10(7), 2325. <https://doi.org/10.3390/app10072325>
17. Krata, P., Vettor, R., & Soares, C. G. (2019). Bayesian Approach to Ship Speed Prediction based on Operational Data. In *Developments in the Collision and Grounding of Ships and Offshore Structures* (pp. 384–390). CRC Press.
18. Moreira, L., Vettor, R., & Guedes Soares, C. (2021). Neural Network Approach for Predicting Ship Speed and Fuel Consumption. *Journal of Marine Science and Engineering*, 9(2), 119. <https://doi.org/10.3390/jmse9020119>
19. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Plita L.L., Trofymenko I.V., Fedunov V.M., Ivanenko V.M.

A METHODOLOGY FOR DEVELOPING A CASCADE MODEL FOR CALCULATING SHIP COORDINATES BASED ON DEEP LEARNING

The aim of the article is to study the methodology for developing a cascade model for calculating ship coordinates based on deep learning, capable of predicting the relative speed of a ship in a fixed coordinate system under the influence of wind and waves. This goal is achieved by building the topology of the cascade model for calculating the ship's coordinates, determining the procedure for forming the training data set, and testing the training results. To determine the ship's location coordinates using autonomous navigation systems, it is necessary to ensure the stability of the ship along a given trajectory. However, satellite navigation systems have their drawbacks, such as limited use in certain environments, such as in environments where radio waves do not pass through, as well as problems with noise and system integrity. In cases where force majeure natural events are encountered that may damage satellite systems, ship tracking may depend on algorithms for processing navigation information in autonomous systems to improve the accuracy and integrity of integrated navigation systems that use satellite navigation data. Often, the determination of some external factors, such as disturbance parameters, is accompanied by significant errors, which leads to significant uncertainty in predicting the calculated coordinates. Compared to existing algorithms, the use of neural networks can be more effective under conditions of uncertainty, as they have nonlinear properties of converting input signals into output signals. Thus, the prediction of the calculated coordinates under the influence of external factors fully meets these conditions. The most significant result is a cascade model for calculating the ship's coordinates based on long short-term memory (LSTM). As a further line of work, it can be noted that even if this predictive model is more accurate than traditional methods, its efficiency should be improved to achieve optimal results. Also, it is important to note that the optimisation hyperparameter is a key element for deep learning models. Hyperparameters determine both the training performance of the model and the quality of its testing.

Keywords: ship, coordinates, path computation, model, neural network, deep learning, long-term short-term memory.