



Artikel

VEPO-S2S: Eine Schiffsporträt-orientierte Flugbahnvorhersage Modell basierend auf dem S2S-Framework

Xinyi Yang ^{1,2,3,†}, Zhonghe Han ^{1,3,4,5,†}, Yuanben Zhang ^{1,3,4,5}, Hu Liu ^{2,*}, Siye Liu ^{1,3,4,5}, Wanzheng² Ai und Junyi Liu ^{1,3,4,5}

¹ Institut für Luft- und Raumfahrtinformationsforschung, Chinesische Akademie der Wissenschaften, Peking 100190, China; yxy915200@163.com (XY); hanzh@aircas.ac.cn (ZH); zhangyb@aircas.ac.cn (YZ); 18010076513@163.com (SL); liujy004735@aircas.ac.cn (JL)

² Fakultät für Schiffbau und Seefahrt, Zhejiang Ocean University, Zhoushou 361022, China; aiwanzheng@126.com Schlüssellabor für

³ Netzwerkinformationssystemtechnologie, Institut für Elektronik, Chinesische Akademie der Wissenschaften, Peking 100190, China Schlüssellabor für Zielerkennungs- und Anwendungstechnologie

⁴ (TCAT), Peking 100190, China 5 Fakultät für Elektronik-, Elektro- und Nachrichtentechnik, Universität der Chinesischen Akademie der Wissenschaften,

Peking 100190, China *

Korrespondenz: liuhu@zjou.edu.cn Diese

[†] Autoren haben zu gleichen Teilen zu dieser Arbeit beigetragen.

Zusammenfassung: Die Vorhersage von Schiffsfahrbahnen spielt eine entscheidende Rolle bei der Gewährleistung der Sicherheit auf See und der Reduzierung von Schiffsunfällen. Bei der Vorhersage von Fahrbahnen wurden durch die Anwendung von Sequenzmodellierungsmethoden, die rekurrende neuronale Netzwerke (RNNs) und Sequenz-zu-Sequenz-Netzwerke (Seq2Seq) enthalten, erhebliche Fortschritte erzielt. Allerdings (1) konzentrieren sich die meisten dieser Studien auf die Anwendung von Fahrbahninformationen wie Längengrad, Breitengrad, Kurs und Geschwindigkeit und vernachlässigen dabei die Auswirkungen unterschiedlicher Schiffsmerkmale und Verhaltenspräferenzen auf die Fahrbahnen. (2) Es bestehen weiterhin Herausforderungen bei der Erfassung dieser Merkmale und Präferenzen sowie bei der Ermöglichung ihrer sinnvollen Integration und effizienten Darstellung durch das Modell. Um dieses Problem zu lösen, führen wir ein neuartiges Deep Framework VEPO- S2S ein, das aus einem mehrstufigen Schiffsfahrbahndarstellungsmodul (Multi-Rep) und einem Merkmalsfusions- und -decodierungsmodul (FFDM) besteht. Abgesehen von den Flugbahninformationen haben wir zunächst die mehrstufigen Schiffseigenschaften in Multi-Rep definiert, die Attribute auf flacher Ebene (Schiffslänge, -breite, -tiefe usw.) und Merkmale auf tiefer Ebene (Segelortpräferenz, Reisezeitpräferenz usw.) umfassen. Anschließend wurde Multi-Rep so konzipiert, dass es Flugbahninformationen und mehrstufige Schiffseigenschaften erhält, wobei unterschiedliche Encoder zur Kodierung verwendet wurden. Als Nächstes wählte und integrierte das FFDM die oben genannten Merkmale aus Multi-Rep zur Vorhersage, indem sowohl a priori- als auch a posteriori-Mechanismen, eine Feature-Fusion-Komponente und ein verbesserter Decoder eingesetzt wurden. Dadurch kann das Modell sie effizient nutzen und die Gesamtleistung verbessern. Schließlich führten wir Vergleichsexperimente mit mehreren Basismodellen durch. Die Versuchsergebnisse zeigen, dass VEPO-S2S den Modellen sowohl quantitativ als auch qualitativ überlegen ist.

Schlüsselwörter: Deep Learning; Vorhersage der Schiffsrouten; Sequenz-zu-Sequenz-Netzwerk; Schiffsunfälle; Risikobewertung; Schiffsporträt



Zitat: Yang, X.; Han, Z.; Zhang, Y.;

Liu, H.; Liu, S.; Ai, W.; Liu, J.

VEPO-S2S: Ein Schiffsporträt

Orientiertes Trajektorienvorhersagemodell basierend auf dem S2S-Framework. Appl.

Sci. **2024**, *14*, 6344. [https://](https://doi.org/10.3390/app14146344)

doi.org/10.3390/app14146344

Wissenschaftlicher Herausgeber: Phivos Mylonas, Katia Lida Kermanidis und Manolis

Maragoudakis

Erhalten: 3. Juni 2024

Überarbeitet: 13. Juli 2024

Akzeptiert: 16. Juli 2024

Veröffentlicht: 20. Juli 2024



Copyright: © 2024 bei den Autoren.

Lizenznehmer MDPI, Basel, Schweiz.

Dieser Artikel ist ein Open Access-Artikel vertrieben unter den Bedingungen und Bedingungen der Creative Commons

Namensnennungslizenz (CC BY)

(<https://creativecommons.org/licenses/by/4.0/>).

1. Einleitung

Die Schifffahrtsindustrie hat in der Weltwirtschaft an Bedeutung gewonnen und war in den letzten Jahrzehnten für über 90 % des weltweiten Frachtaufkommens verantwortlich [1]. Daher ist es noch dringlicher geworden, die Sicherheit auf See zu gewährleisten und die Effizienz der Schifffahrt zu verbessern. Der Einsatz eines automatischen Identifikationssystems (AIS) zur Vorhersage von Schiffsrouten kann Kollisionen verhindern und Aufsichtsbehörden eine Risikobewertung ermöglichen. Konkret geht es bei dieser Aufgabe darum, zukünftige Routen auf der Grundlage historischer Trajektorienpunkte vorherzusagen. Einige Algorithmen [2,3], wie der Kalman- Filter und Support Vector Machines, ermöglichen relativ genaue Vorhersagen

Modelle sind häufig durch Vereinfachungen eingeschränkt und weisen bei komplexeren Situationen eine mittelmäßige Leistung auf [4].

Inzwischen hat Deep Learning bedeutende Fortschritte gemacht und findet breite Anwendung in unterschiedlichsten Bereichen. Rekurrerende neuronale Netzwerke (RNNs) werden als Vorhersagemodelle für Zeitreihen häufig zur Flugbahnvorhersage eingesetzt, leiden jedoch unter Problemen wie dem Verschwinden oder Explodieren von Gradienten. In den letzten Jahren haben Forscher die auf RNNs basierenden Ansätze zur Flugbahnvorhersage kontinuierlich verbessert und bemerkenswerte Ergebnisse erzielt. Die Autoren von [5,6] schlugen ein GRU-basiertes Modell zur Erfassung der zeitlichen Dynamik von Flugbahnsequenzen vor. Dieses Modell kann die nichtlinearen und komplexen Beziehungen zwischen Eingaben und Ausgaben erlernen und so die historischen Bewegungsmuster von Schiffen kodieren. Die Autoren von [7] schlugen ein auf Langzeit-Kurzzeitgedächtnis (LSTM) basierendes Flugbahnmodell vor, das Schiffsbewegungsmuster aus der aktuellen Umgebung und Zeit lernt. Die Autoren von [8] schlugen eine Methode zur Flugbahnvorhersage vor, die bidirektionales Langzeit-Kurzzeitgedächtnis (BiLSTM) und dichte-basiertes räumliches Clustering von Anwendungen mit Rauschen (DBSCAN) kombiniert. Diese Methode integriert mit DBSCAN erkannte Schiffsbewegungen. Die Autoren von [9,10] versuchten, Aufmerksamkeitsmechanismen einzubauen, um wichtige Informationen zu erfassen. Diese Methoden können jedoch nur einen Punkt nacheinander vorhersagen, was zu einer schnellen Fehlerakkumulation bei mehrstufigen Vorhersagen führt. Das Aufkommen von Seq2Seq-Modellen hat dieses Problem erheblich gemildert. Seq2Seq ist eine Art neuronales Encoder-Decoder-Netzwerk, das ursprünglich im Bereich der maschinellen Übersetzung verwendet wurde und weithin zur Flugbahnvorhersage eingesetzt wurde. Es unterstützt die Ausgabe mehrerer Punkte in einer einzigen Iteration und reduziert so effektiv die Fehlerakkumulation. Die Autoren von [11] entwickelten ein auf ConvLSTM und Seq2Seq basierendes Modell, das die Fähigkeit verbessert, globale zeitliche Abhängigkeiten zu erfassen. Die Autoren von [12] teilten das Seegebiet mithilfe eines räumlichen Rasters auf, das auf dem Seq2Seq-Modell basiert, und erzielten gute Ergebnisse bei der Langzeitvorhersage. Die Autoren von [13] schlugen das METO-S2S-Modell vor, das einen multisemantischen Decoder verwendet und die Auswirkungen verschiedener semantischer Schiffsdaten auf die Flugbahnvorhersage berücksichtigt. Neben Methoden, die auf RNNs basieren, die zeitliche Informationen nutzen, besteht ein weiterer untersuchter Ansatz darin, räumliche Informationen für die Modellierung zu verwenden, wobei Graph Convolutional Networks (GCNs) am repräsentativsten sind. Um das Problem der räumlich-zeitlichen Abhängigkeiten zu lösen, kombinierte [14] ein k-GCN mit einem LSTM, wobei das GCN zur Erfassung räumlicher Korrelationen zwischen Knoten und das LSTM zur Verarbeitung räumlich-zeitlicher Korrelationen von Knoten verwendet wurden, wodurch die Vorhersage von Schiffsgeschwindigkeiten ermöglicht wurde. Die Autoren von [15] führten ein DAA-SGCN-Modell ein, das ein ST-GCN zur Extraktion räumlicher sozialer Interaktionsmerkmale und ein RT-CNN zur Extraktion zeitlicher Merkmale verwendete und dabei die sozialen Interaktionen zwischen Schiffen voll berücksichtigte. Die Autoren von [16] berücksichtigten nicht nur die Absichten des Schiffs selbst, sondern berücksichtigten auch den Einfluss der statischen Umgebung und der umgebenden dynamisch interagierenden Agenten. Diese Forschung konzentrierte sich weitgehend auf die Anwendung von Flugbahninformationen zur Vorhersage und erzielte bemerkenswerte Erfolge. Aufgrund der komplexen Abhängigkeiten von historischen Informationen und des starken Einflusses räumlicher Korrelationen sind präzise Vorhersagen jedoch nur schwer zu erreichen, wenn man sich ausschließlich auf Trajektorieninformationen verlässt. Darüber hinaus spielen mehrstufige Schiffsmerkmale wie Schiffsattribute und Fahrortpräferenzen eine entscheidende Rolle bei der Trajektorienvorhersage. Gemäß den Manövrierfähigkeitsstandards von Schiffen [17] sind Kursstabilität und Wendefähigkeit entscheidende Messwerte für die Manövrierfähigkeit, die vom Blockkoeffizienten abhängen, der wiederum durch die Attribute eines Schiffes bestimmt wird. Variationen in den Attributen eines Schiffes wirken sich erheblich auf die Manövrierfähigkeit aus und beeinflussen damit Entscheidungen bezüglich Häfen, Fahrrinnen und Routen. Außerdem enthüllen Fahrortpräferenzen deren Tendenzen zu bestimmten Seegebieten, die bei Vorhersagen stärker berücksichtigt werden sollten. Wie in Abbildung 1 dargestellt, weisen zwei Schiffstypen unterschiedliche Bewegungstrajektorien auf. Im Vergleich zu Trawlern haben Frachtschiffe typischerweise größere Volumina und höhere Blockkoeffizienten, was zu einem größeren Wenderadius und einer schlechteren Kursstabilität führt. Um die potenziellen Risiken zu mindern, wählen Frachtschiffe tendenziell breitere Schifffahrtswege und Fahrrinnen und halten sich strikt an festgelegte Fahrpläne, um eine pünktliche Lieferung der Fracht zu gewährleisten und die allgemeine logistische Effizienz zu verbessern, was zu ruhigeren und regelmäßigeren Fahrtrouten führt. Im Gegensatz dazu operieren

und relevante Regulierungsrichtlinien, was häufig zu unregelmäßigen und konzentrierten Navigationspfaden führt. Daher ist es wichtig, die Verhaltensmuster verschiedener Schiffe zu untersuchen und maßgeschneiderte prädiktive Analysen basierend auf Schiffsattributen und Einsatzgebieten durchzuführen.




Abbildung 1. Trajektorienbeispiele für verschiedene Schiffstypen veranschaulichen erhebliche Unterschiede in Navigationstrajektorien unter dem Einfluss verschiedener Schiffsattribute und -typen.

Aus diesem Grund bestehen weiterhin Herausforderungen bei der Erlangung umfassenderer Eigenschaften sowie deren ratsamer Auswahl und Implementierung. Inspiriert von Benutzerpersönlichkeiten [18] haben wir oberflächliche Attribute und tiefe Merkmale integriert und mehrstufige Schiffsmerkmale definiert, um ein umfassendes Schiffsporträt zu erstellen. In Anbetracht der genannten Herausforderungen schlagen wir ein Schiffsbahnvorhersagemodell VEPO-S2S auf Grundlage der Seq2Seq-Architektur vor, das aus einem mehrstufigen Schiffsbahndarstellungsmodul (Multi-Rep) und einem Merkmalsfusions- und -dekodierungsmodul (FFDM) besteht. Multi-Rep dient der Erfassung und Darstellung von Merkmalen und besteht aus zwei Komponenten: der Merkmalerfassungskomponente und der Merkmalsausdruckskomponente. In der Merkmalerfassungskomponente geben wir zunächst die Bahninformationen an, die Längen- und Breitengrad, Geschwindigkeit, Kurs und Fahrdistanz umfassen. Anschließend werden mehrstufige Schiffseigenschaften definiert, die Attribute auf niedriger Ebene (wie Länge, Breite, Tiefgang usw.) sowie Merkmale auf tiefer Ebene (bevorzugte Segelorte, bevorzugte Reisezeit usw.) umfassen. Alle diese werden über die Komponente zur Merkmalerfassung erfasst und dann separat mithilfe von drei unabhängigen Encodern innerhalb der Komponente zur Merkmalsausprägung codiert.

Abgesehen davon stoßen grundlegende Seq2Seq-Modelle trotz der Einbindung von Flugbahninformationen und Schiffseigenschaften in das Modell auf Herausforderungen bei deren Erkennung und effizienten Nutzung. Daher ist es zwingend erforderlich, die Flugbahninformationen und Schiffseigenschaften auszuwählen und zu integrieren, bevor sie angewendet werden. Zu diesem Zweck schlagen wir das FFDM-Modul vor, das aus einer Portrait Selection-Komponente, einer Feature Fusion-Komponente und einer Multi-Head Decoding-Komponente besteht. Zunächst erkennt die Portrait Selection-Komponente die relevantesten Schiffseigenschaften für die aktuelle Vorhersageumgebung durch Analyse der codierten Eigenschaften. Anschließend ist die Feature Fusion-Komponente so konzipiert, dass sie Flugbahninformationen aus dem Multi-Rep-Modul mit relevanten Schiffseigenschaften zusammenführt. Schließlich dient die Ausgabe als Eingabe für die Multi-Head Decoding-Komponente, die auf Grundlage des herkömmlichen Seq2Seq-Decoders entwickelt wurde. Die Multi-Head Decoding-Komponente besteht aus zwei unterschiedlichen GRU-Blöcken, von denen jeder den Anteil der Flugbahninformationen und Schiffseigenschaften während der Vorhersage steuert und so präzisere Ausgabeergebnisse liefert.

Zusammenfassend können die wichtigsten Beiträge dieses Papiers wie folgt zusammengefasst werden: • Wir schlagen ein Schiffsbahnvorhersage-Framework VEPO-S2S vor, das das mehrstufige Schiffsbahndarstellungsmodul (Multi-Rep) und das Feature Fusion and Decoding Module (FFDM) umfasst. Dieses Framework berücksichtigt vollständig die B

Informationen und Schiffseigenschaften, um deren sinnvolle Integration und effizienten Ausdruck sicherzustellen und so genauere Ergebnisse zu erzielen.

- Wir schlagen das Multi-Rep-Modul vor, das Flugbahninformationen mit mehrstufigen Schiffseigenschaften integriert und mehrere Encoder zur Kodierung verwendet. Dieses Modul kann zeitliche Darstellungen der Flugbahnen sowie detaillierte Porträts der Schiffe erfassen.
- Um die Herausforderung zu bewältigen, mehrere Merkmale effektiv zu verschmelzen und in unserem Modell darzustellen, schlagen wir das FFDM vor. Dieses Modul wählt und integriert Merkmale, indem es a priori und a posteriori Mechanismen, eine Feature Fusion-Komponente und einen verbesserten Decoder verwendet. Das FFDM kann die räumlich-zeitliche Korrelation zwischen historischen Verläufen besser darstellen.
- Wir haben Vergleichsexperimente mit mehreren Basismodellen durchgeführt. Die experimentellen Ergebnisse zeigten, dass VEPO-S2S sowohl in quantitativer als auch qualitativer Hinsicht besser abschneidet als andere Basismodelle und zu robusteren und genaueren Vorhersageergebnissen führt <https://github.com/AIR-SkyForecast/AIR-SkyForecast-VEPO-S2S/new/main> (abgerufen am 15. Juli 2024).

2. Verwandte Werke

2.1. Vorhersage der Schiffsflugbahn

Herkömmliche Methoden zur Flugbahnvorhersage haben gute Ergebnisse bei der Vorhersage von Flugbahnen für Fahrzeuge, Schiffe und Fußgänger erzielt. Die Autoren von [19] schlugen eine dynamisch unterstützte Trägheitsnavigationsmethode zur Schätzung beobachteter Werte vor. Die Autoren von [20] führten eine auf mathematischer Modellierung basierende Kalman-Filtermethode für die Oberflächenverfolgung über große Entfernungen ein, die die direkte Vorhersage der Zielposition und -richtung ermöglicht, ohne dass eine Konvertierung des Koordinatensystems erforderlich ist. Um die Genauigkeit der Schiffsbewegungsvorhersage bei Umweltstörungen zu verbessern, schlug Ref. [21] einen Schiffsbewegungserkennungsalgorithmus auf Grundlage der Methode der kleinsten Quadrate vor. Diese Methoden zeigten jedoch bei komplexen Situationen eine begrenzte Vorhersagegenauigkeit.

In den letzten Jahren hat die Entwicklung von Deep-Learning-Methoden zur Vorhersage von Schiffsrouten rasche Fortschritte gemacht und es konnten erhebliche Fortschritte bei dieser Aufgabe erzielt werden. Die meisten Forschungsarbeiten verwenden die RNN-Struktur. Einige Forschungsarbeiten basieren auf einem LSTM [22] oder einem GRU [6]. Um die Schiffsvorhersage bei unterschiedlichen Flugbahndichten zu untersuchen, wurde in [23] außerdem ein Modell auf Basis eines LSTM und des K-Nearest Neighbor (KNN) vorgeschlagen. Die Autoren von [24] führten das MP-LSTM-Modell ein, das die Stärken von TPNet und LSTM integriert und die Mängel bestehender Methoden sowohl hinsichtlich der Genauigkeit als auch der Modellkomplexität behebt.

In der Zwischenzeit haben einige Wissenschaftler versucht, die Seq2Seq-Architektur zu verwenden, um Vorhersageprobleme zu lösen. Die Autoren von [25] führten ein neuronales Netzwerkmodell ein, das auf einem LSTM und Seq2Seq basiert und verwendet wird, um langfristige Abhängigkeiten in historischen Daten innerhalb von Trajektorien zu erfassen. Die Autoren von [26] schlugen das auf der GRU-Architektur basierende ST-Seq2Seq-Modell vor. Die Autoren von [27] schlugen ein auf BiGRU und Seq2Seq basierendes Flugbahnvorhersagemodell vor, das die Interaktionen zwischen Schiffen vollumfänglich berücksichtigt. Darüber hinaus wurden mehrere andere Flugbahnvorhersagemodelle vorgeschlagen. Die Autoren von [13] führten das auf einem multisemantischen Decoder basierende METO-S2S-Modell ein, das den Einfluss verschiedener semantischer Schiffsinformationen auf die Flugbahnvorhersage berücksichtigt. Sie verwendeten auch semantische Vektoren (SLV) zur Steuerung der Modellvorhersagen in PESO [28] und erzielten damit hervorragende Ergebnisse mit dem Open-Source-AIS-Datensatz in den USA. Zusätzlich zum Seq2Seq-Modell verwendete [29] das Transformer-Framework in Kombination mit LSTM, um historische Flugbahnen in Zeitreihen zu erfassen und Probleme im Zusammenhang mit dem Informationsverfall über große Entfernungen zu überwinden. Um die gegenseitige Abhängigkeit zwischen Schiffen auszudrücken, schlug [30] das Modell des spatiotemporalen Multi-Graph Convolutional Neural Network (STMGCN) vor, das sowohl räumlich-zeitliche Daten als auch Schiffstypen separat modelliert. Die Autoren von [31] kombinierten die Graph Attention Convolution (GAT) mit einer erweiterten kausalen Faltungsstruktur und entwarfen das GAGW-Modell. Das Graph Attention Convolution Network ist für die Extraktion von Interaktionsinformationen zwischen verschiedenen Schiffen im Weltraum verantwortlich.

Die Mehrheit der oben genannten Studien konzentriert sich hauptsächlich auf die Nutzung von Informationen zur Flugbahn in geringer Tiefe. Diese Studien verwenden typischerweise Geschwindigkeit, Kurs und Position als Modelleingaben. Dies reicht jedoch nicht aus, um Schiffen in einer komplizierten Situation auszuweichen. Die Erfassung umfangreicherer und tieferer Merkmale sowie deren sinnvolle Anwendung sind für die Schiffsausweichung und die allgemeine Routenplanung von entscheidender Bedeutung. Daher wird die aktuelle Forschung zur Vorhersage von Schiffsflugbahnen mehr Wert darauf legen, die zahlreichen Merkmale herauszuarbeiten und die Dynamik realer Umgebungen zu verstehen.

2.2. Seq2Seq-Modell

Das Seq2Seq-Modell wird häufig im Bereich der maschinellen Übersetzung eingesetzt [32]. Es besteht aus einem Encoder und einem Decoder, wobei der Encoder die Eingabeinformationen einbettet und einen hochdimensionalen semantischen Vektor generiert, während der Decoder ihn decodiert und das Ergebnis ausgibt. Wir präsentieren hauptsächlich die damit verbundene Forschung zu Regressionsaufgaben auf der Grundlage von Seq2Seq, einschließlich Leistungsvorhersage, Abflussvorhersage und Bestandsvorhersage.

Im Bereich der Leistungsprognose schlug Ref. [33] ein Seq2Seq-Modell auf Basis eines LSTM vor, das die inhärente Korrelation innerhalb der Daten berücksichtigt und so die sequentiellen Beziehungen in Zeitreihen effektiv erfasst. Um das Problem der geringen Genauigkeit bei kurzfristigen Temperaturvorhersagen zu lösen, wurde in [34] ein Seq2Seq-basiertes Modell vorgeschlagen. Im Bereich der Abflussvorhersage verbesserte Ref. [35] Seq2Seq, indem die RNN-Struktur durch eine lineare Schicht zur Verarbeitung historischer Daten ersetzt wurde. Darüber hinaus führte die Einführung eines Aufmerksamkeitsmechanismus zu einer höheren Vorhersagegenauigkeit. In [36] wurde TEN-Seq2Seq zur Verarbeitung tabellarischer Daten und Brunnentiefen eingeführt, das im Vergleich zu LSTM und FCNN eine bessere Robustheit aufwies. Die Autoren von [37] schlugen eine neuartige Methode zur Vorhersage eines Reservoirpegels unter Verwendung von LSTM und aufmerksamkeitsmechanismusbasierter Seq2Seq-Modellierung vor. Die Autoren von [38] schlugen eine Struktur für Aktienkursvorhersagen auf Basis von Seq2Seq-Netzwerken vor.

Das Seq2Seq-Modell hat auch im Bereich der Meeresoberflächentemperatur (SST) bedeutende Fortschritte gemacht. Die Autoren von [39] verwendeten das Seq2Seq-Modell mit zwei Modulen (TMA-Seq2Seq) für die Vorhersage von SST in langfristigen Zeitreihen und erzielten dabei eine bessere Leistung als datengesteuerte Methoden. In [40] wurde ein neuartiges Seq2Seq-Netzwerk vorgeschlagen, um die k-Schritt-Vorhersage basierend auf den Eigenschaften von Meeresechos zu erreichen. Die Autoren von [41] verwendeten das Seq2Seq-Modell, um eine räumlich-zeitliche Vorhersage der Wahrscheinlichkeit von Meereis zu erstellen, was zu einer höheren Genauigkeit führte.

2.3. Benutzer-Personas

Benutzerpersönlichkeiten sind ein Produkt der Internetentwicklung, das es ermöglicht, Unterschiede zwischen Individuen innerhalb von Gruppen zu entdecken. Die Autoren von [42] schlugen ein auf neuronalen Netzwerken basierendes Mitarbeiter- Benutzerpersönlichkeitsmodell vor, das Persönlichkeiten entsprechend den Fähigkeiten und mentalen Zuständen der Mitarbeiter erstellt und so personalisierte Stellenempfehlungen für Unternehmensmitarbeiter ermöglicht. Die Autoren von [43] schlugen eine Methode für hybride Webdienstempfehlungen auf der Grundlage von Benutzerpersönlichkeiten vor, um das Kaltstartproblem für neue Benutzer zu lösen und sowohl die Genauigkeit als auch die Qualität der Empfehlungen zu verbessern.

In letzter Zeit ist die Vorhersage zukünftigen Verhaltens auf Grundlage von Benutzerprofilen zu einem beliebten Gebiet geworden. Die Autoren von [44] transformierten emotionale Präferenzmerkmale von Benutzern in Aufmerksamkeitsinformationen und kombinierten sie mit LSTM-Modellen, um die Persönlichkeitsmerkmale von Online-Benutzern vorherzusagen. Die Autoren von [45] schlugen das T-LSTM-Modell zur Vorhersage der Benutzerbeschäftigung vor, wodurch Herausforderungen bei der Vorhersageleistung überwunden wurden und das einen neuen und effektiven Ansatz für eine genaue Vorhersage der Benutzerbeschäftigung bietet. Die Autoren von [46] führten eine Methode zur Vorhersage impulsiver Belohnungen bei Minderjährigen anhand von Benutzerprofilen ein, die genaue Prognosen des impulsiven Belohnungsverhaltens bei minderjährigen Benutzern ermöglicht. Die Autoren von [47] wandten die Persona-Vorhersage im Bereich der akademischen Warnungen für Universitätsstudenten an. Die Konstruktion von Studentenpersönlichkeiten zur Erforschung der Beziehung zwischen Studentenfaktoren und akademischer Leistung bietet Lehrern und Administratoren eine gute Orientierungshilfe für die Anpassung von Lehrplänen.

In dieser Arbeit haben wir für jedes Schiff ein Profil erstellt und ein neuartiges Seq2Seq-basiertes Modell eingeführt, das sich in der Praxis als besser geeignet für die Kollisionserkennung und Risikowarnung erweist.

3. Vorgeschlagene

Methode Wir präsentieren die Methode in drei Teilen. Zuerst liefern wir Definitionen und die Problemstellung. Als nächstes geben wir einen umfassenden Überblick über die Datenverarbeitung. Dann beschreiben wir den detaillierten Prozess der Erstellung des Schiffsporträts. Abschließend liefern wir eine umfassende Beschreibung unseres vorgeschlagenen Modells VEPO-S2S, einschließlich des Moduls zur mehrstufigen Schiffstrajektorien-darstellung und des Moduls zur Merkmalsfusion und -decodierung.

4. Definitionen und Problemstellung

Das Ziel von VEPO-S2S ist die Vorhersage der zukünftigen Flugbahn eines Schiffes auf Basis von AIS Daten. Um unseren Ansatz klarer auszudrücken, geben wir die folgenden Definitionen an:

[Schiffstrajektorie] Ein Trajektorienpunkt wird als Tupel $x_t = (\text{lont}, \text{latt}, \text{sgt}, \text{cogt}, \text{ditt}, \text{l}, \text{w}, \text{d}, \text{t}, \ddot{y}, \ddot{y})$ zum Zeitpunkt t definiert, wobei sich x_t jeweils aus Längengrad lont , Breitengrad latt , Geschwindigkeitskurs cogt , Segeldistanz ditt , Länge l , Breite w , Tiefgang d , Typ t , Segelort sgt , Präferenz $\ddot{y}$, bevorzugte Reisezeit $\ddot{y}$ und bevorzugte Ankerzeit $\ddot{y}$ zusammensetzt.

Eine Schiffsbahn $X = (x_{t0}, x_{t1}, \dots, x_{tn})$ wird als chronologische Abfolge definiert, wobei $\{t_i, i = 0, 1, 2, \dots, n\}$ eine Reihe von Zeitstempeln ist.

[Positionsequenz] Die Position des Schiffs zum Zeitpunkt t wird als Tupel $y_t = (\text{lont}, \text{latt})$ definiert, und die Sequenz der Positionen des Schiffs zum Zeitpunkt $(1, 2, \dots, t)$ wird als $Y = (y_1, y_2, \dots, y_t)$ definiert.

[Vorhersage der Schiffsflugbahn] Bei einer beobachteten Flugbahn $X = (x_1, x_2, \dots, x_t)$ zu den Zeitpunkten $(1, 2, 3, \dots, t)$ besteht das Ziel darin, die Flugbahn $Y = (y_{t+1}, y_{t+2}, \dots, y_{t+k})$ zu den folgenden Zeitpunkten $(t+1, t+2, \dots, t+k)$ vorherzusagen.

4.1. Vorverarbeitung von

Daten Die Vorverarbeitung von AIS-Daten ist für das Training von Deep-Learning-Modellen unerlässlich, insbesondere für Modelle, die Flugbahninformationen und Schiffeigenschaften benötigen. In VEPO-S2S haben wir AIS-Daten aus südwestlichen und südöstlichen Küstengewässern der USA zum Training, zur Validierung und zum Testen ausgewählt. Der Datensatz enthält statische Attribute wie die Maritime Mobile Service Identity (MMSI), Schiffslänge und -breite. Darüber hinaus umfasst er dynamische Informationen zur Schiffsnavigation wie Längen- und Breitengrad, Geschwindigkeit und Kurs. Während des Empfangs der ursprünglichen AIS-Daten können widrige Wetterbedingungen auftreten, die zu Signalübertragungsverzögerungen und Empfangsfehlern führen können [48]. Darüber hinaus kann die Leistung von Deep-Learning-Modellen durch Datenverluste aufgrund technischer Probleme und Geräewartung beeinträchtigt werden. Daher haben wir vor dem Training eine umfassende Vorverarbeitung der AIS-Daten durchgeführt (siehe Abbildung 2).




Abbildung 2. Der Prozess der Datenvorverarbeitung.

Der Vorgang wird in den folgenden Schritten dargestellt: (1) Sortieren und Klassifizieren: Wir filterten Schiffe mit vollständigen Informationen zu Länge, Breite, Tiefgang und Typ, trennten dann die Trajektorien-daten jedes Schiffs basierend auf der Maritime Mobile Service Identity (MMSI)-Nummer und sortierten sie in aufsteigender Reihenfolge der Zeitstempel.

(2) Rauschunterdrückung: Wir haben Punkte mit doppelten Zeitstempeln und unpassenden Längen- und Breitengradangaben entfernt.

(3) Segment: Wir haben die Trajektorie in verschiedene Segmente unterteilt, wenn der Zeitabstand zwischen zwei benachbarten Trajektorienpunkten 60 Minuten überschritt oder wenn der Abstand zwischen drei aufeinanderfolgenden Trajektorienpunkten weniger als 100 Meter betrug.

(4) Interpolieren: Wir verwendeten eine kubische Spline-Interpolation, um ein 10-minütiges Intervall zu gewährleisten zwischen aufeinanderfolgenden Flugbahnpunkten.

(5) Berechnen: Wir berechnen den Kurs und die Geschwindigkeit für jeden Trajektorienpunkt.

(6) Normalisieren: Wir normalisieren Längengrad, Breitengrad, Geschwindigkeit, Kurs, Länge, Breite, und Tiefgang unter Verwendung der Min–Max-Normalisierungsmethode, wie in Gleichung (1) ausgedrückt

$$x_{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (1)$$

wobei x die Originaldaten sind und x_{min} und x_{max} den Minimal- bzw. Maximalwert in den Trajektoriendaten darstellen. x_{norm} sind die normalisierten Daten.

4.2. Aufbau des Schiffsporträts

In diesem Kapitel werden Schiffsbenutzerporträts auf der Grundlage von AIS-Daten erstellt. darunter auch die Einrichtung eines Beschriftungssystems und die Erstellung von Schiffsportraits.

4.2.1. Aufbau des Kennzeichnungssystems

Wie in Abbildung 3 dargestellt, haben wir ein Kennzeichnungssystem basierend auf Attributen auf flacher Ebene und Merkmalen auf tiefer Ebene entwickelt. Die Attribute auf flacher Ebene umfassen eine Reihe grundlegender Attribute eines Schiffes (wie Länge, Breite, Tiefgang und Typ). Diese Attribute wirken sich erheblich auf die Manövrierfähigkeit von Schiffen aus. Gemäß den Manövrierfähigkeitsstandards für Schiffe [17] sind sowohl die Kursstabilität als auch die Wendefähigkeit entscheidende Indikatoren für die Manövrierfähigkeit und werden vom Blockkoeffizienten des Schiffes beeinflusst. Der Blockkoeffizient ist definiert als die Verdrängung eines Schiffes geteilt durch das Produkt aus Länge, Breite und Tiefgang. Darüber hinaus haben verschiedene Schiffstypen aufgrund von Variationen in der Form ihrer Unterwasserrümpfe unterschiedliche Blockkoeffizienten. Bei Schiffen gleicher Verdrängung weisen Schiffe mit kleineren Blockkoeffizienten (wie Containerschiffe) eine bessere Kursstabilität, aber eine schlechtere Wendefähigkeit auf als Schiffe mit größeren Blockkoeffizienten (wie Tanker). Daher benötigen sie breitere Fahrrinnen, um das Risiko von Kollisionen mit anderen Schiffen zu verringern. Darüber hinaus spielen diese Eigenschaften (Länge, Breite, Tiefgang und Typ) auch bei der Auswahl von Fahrrinnen, Häfen und Routen eine entscheidende Rolle. Laut Handbüchern zum Küsteningenieurwesen [49] beträgt die Fahrrinnenbreite typischerweise das Zwei- bis Fünffache der Schiffsbreite. Schiffe müssen bei der Navigation sowohl die Breite als auch die Tiefe beachten, um sicher und effizient zu navigieren. Laut PIANC [50] müssen große Schiffe bei der Hafenauswahl Häfen mit ausreichend Liegeplätzen und Manövierraum wählen, um ein sicheres Anlegen zu gewährleisten. Bei der Routenplanung müssen Schiffe ihren Wenderadius und Tiefgang beachten und geeignete Routen wählen, um das Risiko einer Auflauf- oder Kollisionsgefahr zu vermeiden. Folglich sind diese Eigenschaften für die Durchführbarkeit entscheidend und müssen gründlich berücksichtigt werden, um genauere Vorhersagen für verschiedene Schiffe zu gewährleisten.

Um Trajektorieninformationen und Schiffseigenschaften auf mehreren Ebenen effektiver zu modellieren, berücksichtigen wir nicht nur Attribute auf flacher Ebene, sondern auch Merkmale auf tiefer Ebene. Die Merkmale auf tiefer Ebene sind definiert als bevorzugte Abfahrtsposition, bevorzugte Reisezeit und bevorzugte Ankerzeit. Die bevorzugte Abfahrtsposition spiegelt das Verhaltensmuster des Schiffes wider. Beispielsweise verkehren Containerschiffe, die in der Linienschifffahrt eingesetzt werden, typischerweise auf festen Routen und innerhalb von Hafengebieten für den Umschlag und Transport der Ladung [51]. Die festen Routen und regelmäßigen Fahrpläne der Linienschifffahrt gewährleisten eine pünktliche Logistik, verringern Verluste und steigern den Ertrag. Trawler hingegen operieren hauptsächlich in bestimmten Fischereigebieten [52], wo ihre Präferenzen für die Segelorte von der Verteilung der Fischereiressourcen beeinflusst werden. Im Gegensatz zur Linienschifffahrt haben Trawler ein flexibleres Navigationsmuster und passen ihre Fangorte häufig je nach Saison an, um gesetzlichen Auflagen zu entsprechen und den Ertrag zu steigern. Diese Präferenz bietet eine umfassende

Verständnis des Schiffsverhaltens und verbessert die Genauigkeit der Trajektorienvorhersage. Was die Reisezeitpräferenz und die Ankerzeitpräferenz betrifft, neigen Containerschiffe dazu, die Ankerzeit zu minimieren [53] und halten sich strikt an Fahrpläne, um die Betriebseffizienz zu optimieren. Diese Betriebsart gewährleistet nicht nur den pünktlichen Transport von Gütern, sondern hilft auch, die Betriebskosten zu senken. Im Gegensatz dazu werden die Reisezeitpräferenzen der Trawler stärker von Fischereimanagementvorschriften und Marktanforderungen beeinflusst. Diese zeitlichen Informationen tragen zu einem tieferen Verständnis der Schiffsverhaltensmuster bei und ermöglichen Vorhersagemodellen, Schwankungen in den Schiffsbewegungen im Laufe der Zeit präzise zu erfassen.




Abbildung 3. Modellierungs- und Analyseprozess auf Beschriftungsebene.

4.2.2. Aufbau des Schiffsporträts

Ein Schiffsporträt besteht aus Attributen auf flacher Ebene und Merkmalen auf tiefer Ebene. Bei der Verarbeitung von Attributen auf flacher Ebene verwenden wir den folgenden Ansatz: Wählen Sie zunächst AIS-Daten mit nicht leeren Attributen (wie Länge, Breite, Tiefgang und Typ) aus. Und dann wählen wir zufällig 100 Datenpunkte basierend auf der Maritime Mobile Service Identity (MMSI) aus. Betrachten Sie für jedes Attribut den Wert mit der höchsten Häufigkeit als aktuelles Schiffsattribut, um das flache Profil des Schiffes zu konstruieren. Dieser Prozess kann in der Formel Gleichung (2) ausgedrückt werden

$$Y = \{y_i | y_i = \{x_j | x_j \in \{x_1^1, x_2^1, \dots, x_m^1\}, D_k \in X, x_j \in P(x_j | D_k) \} \} \quad (2)$$

wobei Y die Attribute aller Schiffe im flachen Wasser darstellt und jedes Element y_i die Attribute des i -ten Schiffes bezeichnet. D_k stellt die AIS-Datensammlung mit vollständigen Attributen dar, X bezeichnet den Attributsatz aller AIS-Daten und jedes Element x_j stellt den höchsten Häufigkeitswert für D_k dar.

Nachdem wir die Attribute auf oberflächlicher Ebene ermittelt hatten, konzentrierten wir uns auf die Erfassung der Merkmale auf tieferer Ebene, zu denen die bevorzugte Abfahrtsposition, die bevorzugte Reisezeit und die bevorzugte Ankerzeit gehören. Für die bevorzugte Abfahrtsposition verwendeten wir aufgrund der unterschiedlichen Anzahl und Verteilung der Schiffsbahnpunkte HDBSCAN (hierarchisches dichtebasiertes räumliches Clustering von Anwendungen mit Rauschen) [54] zur Clusteranalyse. Die Clusterergebnisse sind in Abbildung 4 dargestellt. Verschiedene Farben repräsentieren verschiedene Cluster, und die schwarzen Beschriftungen kennzeichnen die Clusterzentren. Um die bevorzugte Reisezeit und die bevorzugte Ankerzeit zu erfassen, teilten wir einen Tag in 24 Abschnitte auf und ordneten die Bahnpunkte jedes Schiffes den entsprechenden Zeiträumen zu. Die Verteilung der Trajektorienpunkte in jedem Zeitraum spiegelt die zeitlichen Präferenzen der Schiffe wider. Nach der Verarbeitung kann das Profil jedes Schiffes als Gleichung (3) ausgedrückt werden

$$Smmsi = \{lmmsi, wmmsi, dmmsi, tmmsi, ymmsi, ymmsi, ymmsi\} \quad (3)$$

wobei lmmssi, wmmssi, dmmssi und trmssi jeweils die Attribute auf flacher Ebene darstellen von Länge, Breite, Tiefgang und Typ, ÿmmsi steht für die Reisezeitpräferenz, ÿmmsi steht für die bevorzugte Ankerzeit und ÿmmsi ist die bevorzugte Segelposition.

Während ÿmmsi und ÿmmsi in zwei 24-dimensionale Merkmale umgewandelt werden, wird ÿmmsi in ein 114-dimensionales Merkmal umgewandelt. Die Verwendung des Schiffsporträts wird in Abschnitt 4.3.1.




Abbildung 4. Das Trajektoriencluster-Ergebnis. Verschiedene Farben repräsentieren verschiedene Cluster, und die schwarzen Beschriftungen zeigen Clusterzentren an.

4.3. VEPO-S2S-Modell

Wir schlagen ein neuartiges Trajektorienvorhersagemodell VEPO-S2S vor, das auf dem Seq2Seq basiert Modell, und die Struktur ist in Abbildung 5 dargestellt. Wie die Abbildung zeigt, besteht VEPO-S2S aus dem Multi-level Vessel Trajectory Representation Module (Multi-Rep) und dem Feature Fusions- und Dekodierungsmodul (FFDM). Das Multi-Rep dient zur Erfassung von Flugbahnen Informationen und mehrstufige Schiffseigenschaften, indem diese mit mehreren Encodern kodiert werden. Das FFDM ist dafür ausgelegt, die oben genannten Informationen und Merkmale auszuwählen und zusammenzuführen aus Mehrfachwiederholung zur Vorhersage.




Abbildung 5. Die Struktur von VEPO-S2S besteht aus dem Multi-level Vessel Trajectory Representation Module (Multi-Rep) und dem Feature Fusion and Decoding Module (FFDM). Das Multi-Rep ist konzipiert zur Erfassung von Flugbahninformationen und Multi-Level-Schiffseigenschaften durch den Einsatz unterschiedlicher Encoder zur Kodierung. Das FFDM zielt darauf ab, die oben genannten Merkmale aus Multi-Rep auszuwählen und zu integrieren zur Vorhersage.

4.3.1. Modul zur mehrstufigen Schiffsbahndarstellung

Das Modul zur mehrstufigen Schiffsbahndarstellung ist dafür ausgelegt, Bahninformationen und mehrstufige Schiffseigenschaften zu erfassen und unterschiedliche Encoder zur Kodierung anzuwenden. In diesem Unterabschnitt stellen wir das Modul zur mehrstufigen Schiffsbahndarstellung vor, das aus der Komponente zur Merkmalerfassung und der Komponente zur Merkmalsdarstellung besteht. Für die Komponente zur Merkmalerfassung haben wir Bahninformationen und mehrstufige Schiffseigenschaften durch Datenvorverarbeitung, wie in Abschnitt 4.1 beschrieben, und Schiffsporträt konstruktion, wie in Abschnitt 4.2 beschrieben, erhalten. Gleichzeitig haben wir, aufbauend auf den Modellen RNN und Seq2Seq, die Komponente zur Merkmalsdarstellung eingeführt, die aus drei unterschiedlichen Encodern besteht. Diese Encoder sind dafür ausgelegt, unterschiedliche Eingabeeigenschaften der Komponente zur Merkmalerfassung zu erfassen. Der Trajektorienencoder ist für die Kodierung der Trajektorieninformationen (einschließlich Längengrad, Breitengrad, Geschwindigkeit, Kurs und Navigationsentfernung) verantwortlich. Dieser Vorgang kann durch die folgende Gleichung (4) ausgedrückt werden:

$$\begin{aligned} X_{traj} &= (x_1, x_2, \dots, x_{10}) \times n \\ &= (lonn, latn, sogn, cogn, disn) \\ H, h, h^y &= \text{Enctraj}(X_{traj}) \end{aligned} \quad (4)$$

wobei X_{traj} die Flugbahninformationen darstellt, einschließlich der normalisierten Länge, Breite, Geschwindigkeit, Kurs und Navigationsdistanz für zehn Flugbahnpunkte. $H = [h_1, h_2, \dots, h_{10}]$ bezeichnet den verborgenen Zustand bei jedem Zeitschritt, h^y bezeichnet den verborgenen Zustand beim letzten Zeitschritt und h stellt den endgültigen verborgenen Zustand dar. Ähnlich wie beim Flugbahncoder besteht die Aufgabe des Label-Encoders Enclabel darin, die Goldflugbahn zu kodieren und den kodierten Zustand H_y auszugeben, wobei Y_{label} fünf Flugbahnpunkte darstellt, die den Längen- und Breitengrad enthalten.

$$\begin{aligned} Y_{label} &= (x_{11}, x_{12}, \dots, \\ &\quad x_{15}) \times n = (lonn, latn) \\ H_y &= \text{Enctraj}(Y_{label}) \end{aligned} \quad (5)$$

Die Aufgabe des Portrait Feature Encoders ist die Einbettung von Multi-level Vessel Characteristics in einen hochdimensionalen Vektor. Zunächst wurden die normalisierten kontinuierlichen numerischen Werte (einschließlich Länge, Breite und Tiefgang) verkettet und in einen achtdimensionalen semantischen Vektor eingebettet. Zweitens wurde der diskrete Schiffstyp in einen kontinuierlichen Wert für die Modelleingabe umgewandelt und einzeln in einen anderen semantischen Vektor eingebettet. Drittens haben wir zwei 24-dimensionale Deep-Level-Features kodiert, um die Reisezeitpräferenz und die Ankerzeitpräferenz zu erfassen (wie in Abschnitt 4.2.2 erwähnt), während die Segelortpräferenz separat kodiert wurde. Schließlich wurden sie zu einem siebendimensionalen Merkmalsvektor verkettet, der zur Kodierung in den Portrait Feature Encoder eingegeben wurde. Dieser Prozess kann durch die folgende Gleichung (6) ausgedrückt werden

$$\begin{aligned} sp &= \text{concat}(l, w, d) \times sp \\ &= \text{embedsp}(sp) \times \text{Typ} \\ &= \text{embedtype}(\text{Typ}) \times \text{tim} = \\ &\quad \text{concat}(\tilde{y}, \tilde{y}) \times \text{tim} = \\ &\quad \text{embedtim}(\text{tim}) \times \tilde{y} = \\ &\quad \text{embed}\tilde{y}(\tilde{y}) \times \text{por} = \\ &\quad \text{concat}(\text{Encpor}(sp, \text{Typ}, \text{Tim}, \tilde{y})) \end{aligned} \quad (6)$$

wobei por das Portrait-Feature darstellt und embedsp , embedtype , embedtim und $\text{embed}\tilde{y}$ die Einbettungsebenen sind. Encpor ist der Portrait Feature Encoder. l , w und d stellen jeweils Länge, Breite und Tiefgang dar, t ist der Typ , $\tilde{y}$ stellt die Reisezeitpräferenz dar,

$\tilde{y}$ stellt die bevorzugte Ankerzeit dar und $\tilde{y}$ ist die bevorzugte Segelposition (wie in Gleichung (3) erwähnt).

4.3.2. Feature-Fusion- und Dekodierungsmodul

Obwohl die grundlegenden Seq2Seq-Modelle Flugbahninformationen und Schiffseigenschaften in das Modell integrieren, haben sie immer noch Schwierigkeiten, diese effizient zu erkennen und zu nutzen. Daher wurde das Feature Fusion and Decoding Module entwickelt, um die Flugbahninformationen mit mehrstufigen Schiffseigenschaften auszuwählen und zu integrieren, wobei a priori- und a posteriori-Mechanismen in der Portrait Selection Component, einer Feature Fusion Component und einer Multi-Head Decoder Component angewendet werden. Das Ziel der Portrait Selection Component besteht darin, geeignete mehrstufige Schiffseigenschaften für die Vorhersage zu identifizieren und auszuwählen. Daher verwenden wir bei der Auswahl der Schiffseigenschaften eine vorherige und eine nachträgliche Verteilung zusammen. Der Rahmen ist in Abbildung 6 dargestellt. Die vorherige Verteilung wählt die Eigenschaften basierend auf der Ähnlichkeit zwischen dem Vektor h vom Flugbahnencoder und dem Portraitvektor por aus, was dazu beiträgt, die relevanteren Eigenschaften in den frühen Phasen des Modells herauszufiltern und den Rechenaufwand zu reduzieren. Dieser Prozess kann als Gleichung (7) ausgedrückt werden

$$Z_{prior}(por = por_i | h, \tilde{y}) = \tilde{y} \frac{\exp(por_i \tilde{y} h \tilde{y})}{\sum_{i=1}^7 \exp(por_i \tilde{y} h \tilde{y})}, \quad (7)$$

wobei por_i ($por_1, por_2, \dots, por_7$), $\tilde{y}$ das Skalarprodukt, h der Trajektoriencodierungsvektor und por der Portraitvektor ist. Insbesondere weist das Modell Vektoren mit größerer Ähnlichkeit höhere Gewichte zu, indem es die Skalarproduktergebnisse unterschiedlicher Merkmale vergleicht, wodurch die Interferenz redundanter Informationen verringert und die Rechenleistung erhöht wird.




Abbildung 6. Die Portraitauswahlkomponente besteht aus einer vorherigen und einer nachfolgenden Verteilung. Die vorherige Verteilung drückt den Trajektoriencodierungsvektor h und das Porträtmerkmal por aus, und die nachfolgende Verteilung enthält das Label y , um die Auswahlgenauigkeit zu verbessern. Gleichzeitig ist die KLD so konzipiert, dass sie die Lücke zwischen der vorherigen und der nachfolgenden Verteilung schließt, sodass die vorherige Verteilung von der nachfolgenden Verteilung profitieren und genauere Ergebnisse erzielen kann.

Wenn man sich jedoch nur auf die vorherige Verteilung verlässt, kann man keine genauen Ergebnisse erzielen, da sie normalerweise auf Annahmen oder historischen Daten basiert, die die tatsächliche Situation nicht vollständig widerspiegeln. Daher ist es unmöglich, die geeigneten Merkmale auszuwählen, um die Generierung zu steuern. Im Gegensatz dazu können die in der Bezeichnung y verwendeten Merkmale durch die Posterior-Verteilung erhalten werden. Daher ergibt sich die Posterior-Verteilung, die durch Kombination der Trajektorie abgeleitet wird.

Vektor $h_{\tilde{y}}$ und Label y können die Auswahl des Profils effektiver steuern, was ausgedrückt werden kann als

$$Z_{\text{post}}(\text{por} = \text{por} | h_{\tilde{y}}, y) = \frac{\exp(\text{por} \cdot \text{MLP}([h_{\tilde{y}}; y]))}{\sum_{i=1}^7 \exp(\text{por}_i \cdot \text{MLP}([h_{\tilde{y}}; y]))} \quad (8)$$

wobei MLP eine lineare Schicht ist, $\cdot$ das Skalarprodukt ist und $;$ das Vektorspleißen darstellt.

Gleichzeitig besteht eine erhebliche Lücke zwischen der Vorverteilung und der Nachverteilung. Um dieses Problem zu lösen, wird der Kullback-Leibler-Divergenzverlust (KLD) eingesetzt, um ihre Nähe zu erzwingen. Dadurch können Fehler in der Vorverteilung effektiv korrigiert und die Profilauswahl zum Vorteil des Modells gesteuert werden. Die Stabilität der KLD-Divergenz liegt in ihren mathematischen Eigenschaften, die Konvergenz und Zuverlässigkeit während des Trainings gewährleisten. Durch Minimieren des KLD-Verlusts kann das System ein geeignetes Gleichgewicht zwischen der vorherigen und der nachfolgenden Verteilung herstellen. Die Formel für die KLD-Divergenz wird wie folgt ausgedrückt:

$$DKL(PQ) = - \sum_i P(i) \log \frac{P(i)}{Q(i)} \quad (9)$$

wobei P die Posterior-Verteilung darstellt, die die unter Anleitung realer Beschriftungen erforderlichen Merkmale umfasst.

Im Allgemeinen besteht ein unkomplizierter Ansatz zur Nutzung der ausgewählten Merkmale für die Ergebniserzeugung darin, diese Merkmale direkt an den Eingang des Encoders anzuhängen. Dieser Ansatz führt jedoch normalerweise nicht zu zufriedenstellenden Ergebnissen, da es an Flexibilität bei der Steuerung des Grads der eingeführten Merkmalsbeteiligung mangelt. Daher führen wir die Feature Fusion-Komponente ein, um die Nutzung der Merkmale zu optimieren. Im Vergleich zur direkten Verbindung dieser Merkmale haben wir eine flexiblere Methode zur Integration verwendet. Hier haben wir ein LSTM angewendet, um die vorherige Verteilung und die historische Trajektorie H zu verschmelzen, und die Ergebnisse des LSTM berücksichtigen die Kontinuität und Korrelation zwischen den Merkmalen im Laufe der Zeit. Darüber hinaus diente das Vorherige als anfänglicher verborgener Zustand des LSTM, und die vom Trajektorien-Encoder erhaltene Trajektoriendarstellung H wurde bei jedem Schritt als Eingabe verwendet. Schließlich haben wir den fusionierten semantischen Vektor c erhalten, und der Prozess kann durch die folgende Gleichung ausgedrückt werden (10)

$$c_t^k = \text{LSTM}(\text{vorherig}, H) \quad (10)$$

Um die Einbeziehung mehrstufiger Schiffseigenschaften in die Vorhersage zu regulieren, haben wir die Multi-Head-Decodierungskomponente eingeführt; das Rahmendigramm ist in Abbildung 7 dargestellt. Diese Komponente besteht aus zwei GRU-Blöcken und einer Fusionseinheit, die die von den beiden GRU-Blöcken generierten verborgenen Zustände effizient synthetisiert, um zukünftige Flugbahnen vorherzusagen.

Das Design ist so formuliert, dass die Gewichtung zwischen den Trajektorieninformationen und den Schiffseigenschaften während des Vorhersageprozesses angepasst wird. Der orangefarbene Bereich ist ein Standard-GRU-Modul, das die Trajektorieninformationen h empfängt. Zusätzlich verwendet es den vorhergehenden Vorhersagewert y_{t-1} als Eingabe und erzeugt seinen verborgenen Zustand T_i . Ein weiteres GRU ist dafür vorgesehen, die vorherige Verteilung por in die Vorhersagen einzufügen; es verwendet auch den fusionierten semantischen Vektor t , die Trajektorieninformationen h und den vorhergehenden Vorhersagewert y_{t-1} als Eingaben und erzeugt p und T werden durch das Fusionsgate zu c^k fusioniert.

die Merkmalsdarstellung T_i . Schließlich erzeugt T die endgültige Trajektorie. Dieser Prozess kann durch Gleichung (11) ausgedrückt werden:

$$\begin{aligned} T_{\text{ich}}^N &= \text{GRU}_N(y_{t-1}, h) \\ \text{inpp} &= \text{concat}(y_{t-1}, c^k, \text{vorher}) \\ T_{\text{ich}}^P &= \text{GRU}_P(\text{inpp}, h) \\ Ot &= y(W_z \cdot [\tanh(W_y \cdot T_{\text{ich}}^N); \tanh(W_k \cdot T_p)]) \\ Ti &= Ot \cdot T^N + (1 - Ot) \cdot T_p \end{aligned} \quad (11)$$

wobei $\hat{y}$ (11, 12, ..., 15) und W_z , W_y und W_k Gewichtsmatrizen mit unterschiedlichen Koeffizienten entsprechen. $\hat{y}$ und $\tanh$ sind jeweils die Sigmoid-Aktivierungsfunktion und die tanh-Aktivierungsfunktion.




Abbildung 7. Die Multi-Head-Decoder-Komponente besteht aus zwei GRU-Blöcken und einer Fusions-einheit. Sie kann die Gewichtung zwischen den Flugbahninformationen und den Schiffseigenschaften während des Vorhersageprozesses flexibel anpassen.

4.3.3. Verlustfunktion

VEPO verwendet den mittleren quadratischen Fehler (RMSE) und die Kullback-Leibler-Divergenz (KLD) (wie in Gleichung (9) erwähnt) als Verlustfunktion. Ziel dieser Arbeit ist es, die ersten m Punkte zu verwenden, die mit $X_k = (x_{k1}, x_{k2}, \dots, x_{kN})$ bezeichnet werden, um die nachfolgenden n vorherzusagen, wobei m und n die Hyperparameter sind. Die Vorhersage-sequenz und das Ziel $Y_k = (y_{k1}, y_{k2}, \dots, y_{kn})$ werden jeweils durch $Y_k = (y_{k1}, y_{k2}, \dots, y_{kn})$ dargestellt. Das primäre Ziel ist es, die Verlustfunktion während des Trainings zu minimieren und dadurch eine höhere Genauigkeit bei der Vorhersage der letzten n Trajektorienpunkte sicherzustellen. Der Ausdruck für die Verlustfunktion ist in der folgenden Gleichung (12) dargestellt.

$$L = \frac{1}{n} \sum_{k=1}^N (Y_k - \hat{Y}_k)^2 + \text{DKL} \quad (12)$$

5. Experimente Um

die Wirksamkeit des VEPO-Modells zu bestätigen, haben wir eine Reihe quantitativer und qualitativer Experimente durchgeführt. Insbesondere stellen wir zunächst die Versuchseinstellungen vor, einschließlich der Hyperparametereinstellungen, Versuchsumgebungen, Datensätze, Basismodelle und Bewertungsmetriken. Anschließend präsentieren wir die quantitativen Vergleichsergebnisse unserer vorgeschlagenen Methode und anderer Basismodelle. Danach beschreiben wir die Ablationsexperimente, die durchgeführt wurden, um die Wirksamkeit verschiedener Komponenten des Modells zu belegen. Abschließend stellen wir die Vorhersageergebnisse von VEPO-S2S durch qualitative Analyse dar.

5.1. Experimenteinstellungen

5.1.1. Datensatz

Wir haben AIS-Daten übernommen (<https://marinecadastre.gov/accessais/>) (abgerufen am 1. Juni 2024) aus den Küstengewässern des Südostens und Südwestens der Vereinigten Staaten für Training, Validierung und Tests [13]. Wie in Tabelle 1 gezeigt, gibt es in diesem Datensatz 68 Schiffstypen und 28.645 Schiffe. Gleichzeitig haben wir aufgrund der Besonderheit der Porträt-konstruktion (wie in Abschnitt 4.2.2 erwähnt) die Schiffsattribute (einschließlich Länge, Breite, Tiefgang und Typ) ausgewählt. Nach der Verarbeitung erhielten wir 45 Typen mit insgesamt 6194

Schiffe. Die detaillierte Verteilung der Schiffstypen ist in Abbildung 8 dargestellt. In unserem Datensatz Die maximale Anzahl der Schiffstypen betrug 45, bestehend aus Passagierschiffen, Sportbooten, Segelschiffe usw. Die Verteilung der Schiffstypen war ungleichmäßig und sie wurden hauptsächlich in fünf Kategorien eingeteilt: Passagierschiffe, Sportboote, Segelschiffe, Schleppschiffe und Fischereifahrzeuge. Passagierschiffe und Sportboote machten zusammen über 23 % der Gesamtzahl aus. Die übrigen Schiffe, hauptsächlich Frachtschiffe, Containerschiffe und Tanker, machen 21 % des Datensatzes aus. Um den Reichtum und die Vollständigkeit der Daten zu erhöhen, Wir verwendeten einen gleitenden Fensteransatz und teilten die normalisierten Daten in Gruppen von 15 Trajektorienpunkte mit einem Gleitschritt von 1 (siehe Abbildung 9). Anschließend wurde jedes Schiff im Verhältnis 8:1:1 auf Trainings-, Validierungs- und Testsätze verteilt. Dieser Ansatz erhöhte die Vielfalt der Daten und stellte sicher, dass jedes Schiff eine ausreichende Validierung erhielt.

Tabelle 1. Die Details unseres Datensatzes.

Datensatz	Region	Trackpunkte	Anzahl Typ	Anzahl	Schiffsanzahl
Gesamt	Küste der Vereinigten Staaten	144.445.580	68		28.645
Unsere Küste	der Vereinigten Staaten	4.930.061	45		6194




Abbildung 8. Die Verteilung der Schiffstypen in unserem verarbeiteten Datensatz.




Abbildung 9. Ein Beispiel für die Aufteilung eines Datensatzes mit der Methode des gleitenden Fensters und die roten Punkte stellen Flugbahnpunkte dar.

5.1.2. Hyperparameter-Einstellungen und experimentelle Umgebung

Wir haben zehn Trajektorienpunkte als Eingaben verwendet, um die letzten fünf Trajektorienpunkte vorherzusagen. und diese beiden Hyperparameter können flexibel an unterschiedliche Aufgaben angepasst werden. In der Zwischenzeit wurden die Epochen für das Modelltraining auf 40 festgelegt, und die beste Bewertungsleistung gespeichert. Die Lernrate betrug 0,001 bei einem Gewichtsabfall von 0,0, der Optimierer wurde an Adam, und die Batchgröße wurde auf 128 gesetzt. Darüber hinaus wurden die versteckten Größen in der GRU

auf 64 eingestellt und die Anzahl der verborgenen Schichten war 2. In den obigen Hyperparametern haben wir zwei typische Fälle zur Visualisierung ausgewählt, nämlich die Anzahl der Schichten und die verborgenen Größen, deren Details in den Abbildungen 10 und 11 dargestellt sind. Die Experimente basierten alle auf Python 3.8 unter Verwendung des PyTorch-Frameworks. Wir haben das Modell für Experimente mit dem Ubuntu-Betriebssystem und GTX 3090Ti auf dem Server trainiert.




Abbildung 10. Der Einfluss verschiedener GRU-Schichten auf die Vorhersage des VEPO-S2S-Modells laut RMSE. Die X-Achse stellt die Anzahl der Schichten dar und die Y-Achse den RMSE-Verlustwert.




Abbildung 11. Der Einfluss verschiedener versteckter Größen auf die Vorhersage des VEPO-S2S-Modells laut RMSE. Die X-Achse stellt die Anzahl der versteckten Größen dar und die Y-Achse den RMSE-Verlustwert.

5.1.3. Basislinien

Um die Leistung von VEPO-S2S besser bewerten zu können, haben wir es mit mehreren Basismodellen verglichen, die denselben Datensatz verwenden. Im Gegensatz zu Seq2Seq sind rekurrende neuronale Netzwerke auf die Vorhersage mehrerer aufeinanderfolgender Trackpunkte beschränkt. In unseren Experimenten haben wir mithilfe eines RNN kontinuierlich fünf Trajektorienpunkte vorhergesagt, was durch die gleitende Fenstermethode erreicht wurde. Die Basismodelle waren wie folgt:

- (1) Kalman: Ein lineares optimales Schätzmodell;
- (2) VAR: Ein statistisches Modell zur multivariaten Zeitreihenvorhersage;
- (3) ARIMA: Ein statistisches Zeitreihen-Prognosemodell;
- (4) LSTM: Eine Art rekurrendes neuronales Netzwerk, das aus zwei Schichten besteht;
- (5) BiLSTM: Ähnlich wie LSTM besteht das BiLSTM aus zwei bidirektionalen LSTM Lagen;
- (6) GRU: Ähnlich einem LSTM;
- (7) BiGRU: Ähnlich wie ein GRU, jedoch mit zwei bidirektionalen GRU-Schichten;
- (8) LSTM-LSTM: Ein Seq2Seq-Modell mit einem zweischichtigen LSTM als Encoder und Decoder;

- (9) BiLSTM–LSTM: Ein Seq2Seq-Modell mit einem zweischichtigen BiLSTM als Encoder und einem vierschichtigen LSTM als Decoder;
 (10) GRU–GRU: Ähnlich einem LSTM–LSTM; (11)
 BiGRU–GRU: Ähnlich einem BiLSTM–LSTM; (12)
 Transformer: Ein Seq2Seq-Modell basierend auf einem
 Aufmerksamkeitsmechanismus; (13) METO-S2S: Eine S2S-basierte Methode zur Vorhersage von
 Schiffstrajektorien mit einem mehrfachsemantischen Encoder und einem typorientierten Decoder.

5.1.4. Bewertungsmaßstäbe

Um die Vorhersageleistung des vorgeschlagenen Modells zu bewerten, haben wir vier Bewertungsmaßstäbe verwendet, darunter den mittleren quadratischen Fehler (RMSE), den mittleren absoluten Fehler (MAE), den durchschnittlichen Verschiebungsfehler (ADE) und den endgültigen Verschiebungsfehler (FDE). Der RMSE konzentriert sich auf die Messung der Stabilität des Ergebnisses, während der MAE die Vorhersagefähigkeit eines Modells bewertet. Die ADE steht für den durchschnittlichen euklidischen Distanzfehler zwischen der vorhergesagten Position und der tatsächlichen Position. Darüber hinaus konzentriert sich der FDE auf die endgültige Genauigkeit der Vorhersagen.

$$\begin{aligned}
 \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{k=1}^N (y_k - \hat{y}_k)^2} \\
 \text{MAE} &= \frac{1}{n} \sum_{k=1}^N |y_k - \hat{y}_k| \\
 \text{ADE} &= \frac{1}{n} \sum_{k=1}^N \|y_k - \hat{y}_k\|_2 \\
 \text{FDE} &= \|y_{\text{final}} - \hat{y}_{\text{final}}\|_2
 \end{aligned} \tag{13}$$

wobei y_k und $\hat{y}_k$ die tatsächliche Position und die vorhergesagte Position darstellen, n die Gesamtzahl der vorhergesagten Trackpunkte ist und $\cdot$ und $\|\cdot\|_2$ eine Norm bzw. die euklidische Distanz bezeichnen. y_{final} und $\hat{y}_{\text{final}}$ stellen die Endposition der tatsächlichen Flugbahn bzw. der vorhergesagten Flugbahn dar. Es ist zu beachten, dass die Generalisierungsfähigkeit des Modells umso besser ist, je niedriger der Bewertungsindex ist.

5.2. Vergleich der Modellleistung

5.2.1. Vergleichsergebnisse

Durch Vergleiche mit den Basislinien unter Verwendung der Bewertungsmetriken von RMSE, MAE und ADE zeigte unser Modell eine hohe Robustheit, wie in den Tabellen 2–4 gezeigt. LSTM, BiLSTM, GRU und BiGRU verwenden einen gleitenden Fensteransatz für die Vorhersage mehrerer Punkte, während die anderen sechs Seq2Seq-Modelle dies nicht tun. Unser Modell übertraf die Basislinien am dritten bis fünften Trajektorienpunkt. Allerdings erzielte die GRU bessere Ergebnisse bei der MAE in Tabelle 3 und der ADE in Tabelle 4 in Bezug auf den ersten und zweiten Punkt. Dies liegt hauptsächlich daran, dass die GRU aufgrund ihrer Einfachheit einen strukturellen Vorteil bei der Vorhersage kurzfristiger Sequenzen hat. Allerdings erfährt VEPO-S2S bei der Verarbeitung kurzfristiger Vorhersagen einen leichten Rückgang, da das Porträt des Schiffes möglicherweise nicht leicht erkennbar ist. Wenn die Vorhersagelänge zunimmt, schneidet unser Modell laut RMSE, MAE und ADE besser ab als die Basismodelle.

Da die Flugbahnvorhersage auch ein Problem der Zeitreihenprognose ist, verglichen wir VEPO-S2S mit mehreren Zeitreihenprognosemodellen, darunter ARIMA, Kalman-Filter und VAR. Wie die Tabellen 2–4 zeigen, war unser Modell anderen überlegen; die drei Zeitreihenvorhersagemodelle zeigten gute Ergebnisse bei der kurzfristigen Prognose, aber die Genauigkeit nahm mit zunehmendem Prognosehorizont rapide ab. Insbesondere das VAR-Modell wurde nach dem dritten Zeitschritt unwirksam, da es nicht in der Lage war, langfristige komplexe nichtlineare Beziehungen zu erfassen. Anders als Zeitreihenmodelle, die nur Positionssequenzen verwenden, profitiert VEPO-S2S von zusätzlichen Vorabinformationen, wie z. B. d

und Breite, sowie seine leistungsstarke Fähigkeit, räumlich-zeitliche Korrelationen zu konstruieren aus historische Flugbahnpunkte, was es bei Prognoseaufgaben vorteilhafter macht.

Tabelle 2. Vergleichsergebnisse von VEPO-S2S mit verschiedenen Baselines unter RMSE-Bewertungsmetrik. Hier stellt 10->5 den RMSE-Wert der letzten 5 Flugbahnen dar, die von 10 historischen Flugbahnen vorhergesagt wurden.

Modellname	10-> 1	10->2	10->3	10->4	10->5
Kalman	2,42 × 10 ⁴	3,00 × 10 ⁴	4,22 × 10 ⁴	2,80 × 10 ⁴	5,51 × 10 ⁴
VAR	0,98 × 10 ⁴	10 ⁴	50,43 × 10 ⁴	-	-
ARIMA	3,42 × 10 ⁴	5,30 × 10 ⁴	7,21 × 10 ⁴	9,15 × 10 ⁴	1,16 × 10 ⁴
LSTM	0,88 × 10 ⁴	3,46 × 10 ⁴	2,65 × 10 ⁴	3,51 × 10 ⁴	4,41 × 10 ⁴
BiLSTM	2,64 × 10 ⁴	1,58 × 10 ⁴	2,41 × 10 ⁴	3,32 × 10 ⁴	3,24 × 10 ⁴
GRU	0,86 × 10 ⁴	3,96 × 10 ⁴	4,71 × 10 ⁴	1,94 × 10 ⁴	2,76 × 10 ⁴
BiGRU	3,16 × 10 ⁴	2,21 × 10 ⁴	3,07 × 10 ⁴	3,99 × 10 ⁴	1,69 × 10 ⁴
LSTM-LSTM	1,22 × 10 ⁴	2,49 × 10 ⁴	3,36 × 10 ⁴	2,21 × 10 ⁴	3,14 × 10 ⁴
BiLSTM-LSTM	1,44 × 10 ⁴	1,74 × 10 ⁴	2,35 × 10 ⁴	3,07 × 10 ⁴	2,03 × 10 ⁴
GRU-GRU	0,98 × 10 ⁴	2,28 × 10 ⁴	2,73 × 10 ⁴	1,11 × 10 ⁴	1,71 × 10 ⁴
BiGRU-GRU	1,34 × 10 ⁴	2,40 × 10 ⁴			
1,31 × 10 ⁴	2,02 × 10 ⁴	0,74 × 10 ⁴			
Transformator					5,12 × 10 ⁴
METO-S2S					3,86 × 10 ⁴
Unsere					3,35 × 10 ⁴
					3,17 × 10 ⁴

Tabelle 3. Vergleichsergebnisse von VEPO-S2S mit verschiedenen Baselines unter MAE-Bewertungsmetrik. Hier 10->5 bedeutet, vorhergesagt anhand von 10 historischen Verläufen.

Modellname	10-> 1	10->2	10->3	10->4	10->5
Kalman	1,73 × 10 ⁴	2,34 × 10 ⁴	3,27 × 10 ⁴	4,24 × 10 ⁴	5,16 × 10 ⁴
VAR	0,87 × 10 ⁴	2,12 × 10 ⁴	28,6 × 10 ⁴	-	-
ARIMA	2,69 × 10 ⁴	3,99 × 10 ⁴	5,33 × 10 ⁴	6,69 × 10 ⁴	1,18 × 10 ⁴
LSTM	0,43 × 10 ⁴	0,77 × 10 ⁴	1,66 × 10 ⁴	1,87 × 10 ⁴	2,21 × 10 ⁴
BiLSTM	1,50 × 10 ⁴	1,52 × 10 ⁴	2,35 × 10 ⁴	1,01 × 10 ⁴	1,42 × 10 ⁴
GRU	0,36 × 10 ⁴	0,66 × 10 ⁴	1,84 × 10 ⁴	2,15 × 10 ⁴	1,87 × 10 ⁴
BiGRU	1,53 × 10 ⁴	1,65 × 10 ⁴	1,34 × 10 ⁴	1,72 × 10 ⁴	1,56 × 10 ⁴
LSTM-LSTM	0,70 × 10 ⁴	1,00 × 10 ⁴	1,94 × 10 ⁴	1,10 × 10 ⁴	1,10 × 10 ⁴
BiLSTM-LSTM	0,88 × 10 ⁴	1,20 × 10 ⁴	1,46 × 10 ⁴	1,50 × 10 ⁴	1,92 × 10 ⁴
GRU-GRU	0,51 × 10 ⁴	0,78 × 10 ⁴	1,16 × 10 ⁴	1,42 × 10 ⁴	1,85 × 10 ⁴
BiGRU-GRU	0,74 × 10 ⁴	1,10 × 10 ⁴	1,53 × 10 ⁴	1,70 × 10 ⁴	0,99 × 10 ⁴
10 ⁴ Transformator	1,43 × 10 ⁴	0,95 × 10 ⁴	1,28 × 10 ⁴		
0,53 × 10 ⁴					
METO-S2S		1,46 × 10 ⁴			1,94 × 10 ⁴
Unsere		0,74 × 10 ⁴			1,60 × 10 ⁴

Tabelle 4. Vergleichsergebnisse von VEPO-S2S mit verschiedenen Baselines unter ADE-Bewertungsmetrik. Hier 10->5 bedeutet, vorhergesagt anhand von 10 historischen Verläufen.

Modellname	10-> 1	10->2	10->3	10->4	10->5
Kalman	3,42 × 10 ⁴	4,62 × 10 ⁴	8,22 × 10 ⁴ 11,52 × 10 ⁴	14,29 × 10 ⁴	
VAR	1,38 × 10 ⁴	5,60 × 10 ⁴	123,53 × 10 ⁴	-	-
ARIMA	4,83 × 10 ⁴	7,11 × 10 ⁴	9,42 × 10 ⁴ 11,76 × 10 ⁴	14,14 × 10 ⁴	
LSTM	0,68 × 10 ⁴	1,22 × 10 ⁴	1,87 × 10 ⁴ 2,64 × 10 ⁴	3,51 × 10 ⁴	
BiLSTM	2,37 × 10 ⁴	2,38 × 10 ⁴	2,99 × 10 ⁴ 3,74 × 10 ⁴	4,56 × 10 ⁴	
GRU	0,59 × 10 ⁴	1,05 × 10 ⁴	1,62 × 10 ⁴ 2,27 × 10 ⁴	2,99 × 10 ⁴	
BiGRU	2,42 × 10 ⁴	2,73 × 10 ⁴	4,00 × 10 ⁴ 4,91 × 10 ⁴	5,20 × 10 ⁴	
LSTM-LSTM	1,11 × 10 ⁴ BiLSTM-	1,59 × 10 ⁴	2,13 × 10 ⁴ 2,73 × 10 ⁴	3,38 × 10 ⁴	
LSTM 1,39 × 10 ⁴ GRU-GRU 0,80 ×		1,90 × 10 ⁴	2,47 × 10 ⁴ 3,07 × 10 ⁴	3,72 × 10 ⁴	
10 ⁴ BiGRU-GRU 1,16 × 10 ⁴		1,23 × 10 ⁴	1,74 × 10 ⁴ 2,31 × 10 ⁴	2,93 × 10 ⁴	
1,28 × 10 ⁴ 2,26 × 10 ⁴ 0,83 × 10 ⁴		1,75 × 10 ⁴	2,38 × 10 ⁴ 3,05 × 10 ⁴	3,76 × 10 ⁴	
Transformator		1,50 × 10 ⁴	1,83 × 10 ⁴ 2,25 × 10 ⁴	2,73 × 10 ⁴	
METO-S2S		2,30 × 10 ⁴	2,41 × 10 ⁴ 2,68 × 10 ⁴	3,07 × 10 ⁴	
Unsere		1,17 × 10 ⁴	1,52 × 10 ⁴ 2,01 × 10 ⁴	2,52 × 10 ⁴	

5.2.2. Untersuchung der Seq2Seq-Struktur von VEPO-S2S

Wir führten mehrere Experimente zur Struktur des Encoders und Decoders durch in VEPO-S2S, um optimale Leistung zu erzielen, einschließlich eines VEPO–BiGRU–GRU, eines VEPO–LSTM- LSTM, eines VEPO–BiLSTM–LSTM und eines VEPO–GRU–GRU. Wie in Tabelle 5 gezeigt, ist die beste Ergebnis wurde mit dem VEPO-GRU-GRU erzielt. Daher wurden in den nachfolgenden Experimenten Wir haben VEPO-S2S mit einer GRU-GRU-Struktur für weitere Experimente verwendet.

Tabelle 5. Untersuchungsergebnisse zu unterschiedlichen Seq2Seq-Strukturen.

Modellname	Encoder	Decoder	RMSE	MAE	ADE	FDE
VEPO-S2S	BiGRU	GRU	3,60 × 10 ⁴ 1,99 × 10 ⁴	3,15 × 10 ⁴ 5,28 × 10 ⁴		
VEPO-S2S	LSTM	LSTM	3,46 × 10 ⁴ 1,72 × 10 ⁴	2,72 × 10 ⁴ 4,94 × 10 ⁴		
VEPO-S2S	BiLSTM	LSTM	4,19 × 10 ⁴ 2,48 × 10 ⁴	3,39 × 10 ⁴ 5,97 × 10 ⁴		
VEPO-S2S	GRU	GRU	3,17 × 10 ⁴ 1,60 × 10 ⁴	2,52 × 10 ⁴ 4,57 × 10 ⁴		

5.2.3. Weitere Analyse

Im Gegensatz zur Auswertung kontinuierlicher Trajektorienvorhersageaufgaben haben wir eine Einzelpunktauswertung mit RMSE, MAE und FDE durchgeführt. Wie wir aus den Tabellen [6–8](#) [ersehen können](#), Die Vorhersagefehler aller Modelle zeigten einen deutlichen Anstieg vom ersten zum fünfter Vorhersagepunkt. Dies ist auf eine erhebliche Reduzierung der verfügbaren Informationen für jede Vorhersage zurückzuführen, wenn man von der ersten zur letzten Vorhersage übergeht. RNN-Basislinie Modelle verwenden einen gleitenden Fensteransatz für die Vorhersage und akkumulieren mit jeder Vorhersage allmählich Ungenauigkeiten. Im Gegensatz dazu haben die Seq2Seq-Basismodelle die Fähigkeit mehrere Punkte gleichzeitig vorherzusagen, was die Tendenz zur Fehlereskalation im Vergleich zu den RNN-Basismodellen verringern kann. Darüber hinaus basieren Zeitreihenmodelle auf linearen Beziehungen zwischen mehreren Zeitreihen; bei langfristigen Vorhersagen Aufgaben, nichtlineare Merkmale treten stärker in den Vordergrund, was zu einer raschen Zunahme der Ungenauigkeiten führt im Laufe der Zeit. Darüber hinaus übertrifft unser Modell fast alle Basislinien. Wir beobachten auch eine ähnliche Leistung zwischen METO-S2S und VEPO-S2S am vierten und fünften Punkt in Abbildung 6 zeigt, dass sowohl VEPO als auch METO hervorragende Modelle für lange Sequenzen sind. Vorhersageaufgaben.

Tabelle 6. Die Ergebnisse der quantitativen Analyse jedes Trajektorienpunkts unter dem RMSE-Bewertungsindex.

Modellname	Erste	Zweite	Dritte	Vierte	Fünfte
Kalman	2,42 × 10 ⁴	3,27 × 10 ⁴	5,81 × 10 ⁴	3,74 × 10 ⁴	8,15 × 10 ⁴
VAR	0,98 × 10 ⁴	10 ⁴	86,61 × 10 ⁴	-	-
ARIMA	3,42 × 10 ⁴	6,63 × 10 ⁴	9,93 × 10 ⁴	13,28 × 10 ⁴	16,72 × 10 ⁴
LSTM	0,88 × 10 ⁴	2,10 × 10 ⁴	3,63 × 10 ⁴	5,43 × 10 ⁴	7,60 × 10 ⁴
BiLSTM	2,64 × 10 ⁴	2,65 × 10 ⁴	4,77 × 10 ⁴	6,39 × 10 ⁴	8,38 × 10 ⁴
GRU	0,86 × 10 ⁴	2,06 × 10 ⁴	3,52 × 10 ⁴	5,16 × 10 ⁴	6,96 × 10 ⁴
BiGRU	3,16 × 10 ⁴	2,42 × 10 ⁴	5,24 × 10 ⁴	6,44 × 10 ⁴	6,83 × 10 ⁴
LSTM-LSTM	1,22 × 10 ⁴	2,46 × 10 ⁴	3,90 × 10 ⁴	5,50 × 10 ⁴	7,20 × 10 ⁴
BiLSTM-LSTM	1,44 × 10 ⁴	2,77 × 10 ⁴	4,30 × 10 ⁴	5,95 × 10 ⁴	7,68 × 10 ⁴
GRU-GRU	0,98 × 10 ⁴	2,18 × 10 ⁴	3,59 × 10 ⁴	5,14 × 10 ⁴	6,84 × 10 ⁴
BiGRU-GRU	1,34 × 10 ⁴	2,82 × 10 ⁴	4,45 × 10 ⁴	6,17 × 10 ⁴	7,96 × 10 ⁴
Transformator	1,31 × 10 ⁴	2,08 × 10 ⁴	3,24 × 10 ⁴	4,59 × 10 ⁴	6,07 × 10 ⁴
METO-S2S	2,02 × 10 ⁴	2,03 × 10 ⁴	2,71 × 10 ⁴	3,76 × 10 ⁴	5,23 × 10 ⁴
Unsere	0,74 × 10 ⁴	1,44 × 10 ⁴	2,47 × 10 ⁴	3,76 × 10 ⁴	5,22 × 10 ⁴

Tabelle 7. Die Ergebnisse der quantitativen Analyse jedes Flugbahnpunkts unter dem MAE-Bewertungsindex.

Modellname	Erste	Zweite	Dritte	Vierte	Fünfte
Kalman	1,73 × 10 ⁴	2,94 × 10 ⁴	5,13 × 10 ⁴	3,38 × 10 ⁴	7,13 × 10 ⁴
VAR	0,87 × 10 ⁴	10 ⁴	81,62 × 10 ⁴	-	-
ARIMA	2,69 × 10 ⁴	5,26 × 10 ⁴	7,99 × 10 ⁴	10,77 × 10 ⁴	13,62 × 10 ⁴
LSTM	0,43 × 10 ⁴	1,11 × 10 ⁴	2,01 × 10 ⁴	3,11 × 10 ⁴	4,40 × 10 ⁴
BiLSTM	1,50 × 10 ⁴	1,52 × 10 ⁴	2,60 × 10 ⁴	3,79 × 10 ⁴	4,94 × 10 ⁴
GRU	0,36 × 10 ⁴	0,95 × 10 ⁴	1,72 × 10 ⁴	2,63 × 10 ⁴	3,67 × 10 ⁴
BiGRU	1,53 × 10 ⁴	1,77 × 10 ⁴	2,53 × 10 ⁴	3,09 × 10 ⁴	3,26 × 10 ⁴
LSTM-LSTM	0,70 × 10 ⁴	1,30 × 10 ⁴	2,02 × 10 ⁴	2,85 × 10 ⁴	3,77 × 10 ⁴
BiLSTM-LSTM	0,88 × 10 ⁴	1,53 × 10 ⁴	2,28 × 10 ⁴	3,08 × 10 ⁴	3,98 × 10 ⁴
GRU-GRU	0,51 × 10 ⁴	1,04 × 10 ⁴	3,59 × 10 ⁴	5,14 × 10 ⁴	6,84 × 10 ⁴
BiGRU-GRU	1,34 × 10 ⁴	2,82 × 10 ⁴	4,45 × 10 ⁴	6,17 × 10 ⁴	7,96 × 10 ⁴
Transformator	2,02 × 10 ⁴	1,09 × 10 ⁴	1,58 × 10 ⁴	2,20 × 10 ⁴	2,93 × 10 ⁴
METO-S2S	0,53 × 10 ⁴	2,03 × 10 ⁴	2,21 × 10 ⁴	2,71 × 10 ⁴	2,92 × 10 ⁴
Unsere		0,96 × 10 ⁴	1,48 × 10 ⁴	2,13 × 10 ⁴	2,88 × 10 ⁴

Tabelle 8. Die Ergebnisse der quantitativen Analyse jedes Flugbahnpunkts unter dem FDE-Bewertungsindex.

Modellname	Erste	Zweite	Dritte	Vierte	Fünfte
Kalman	3,42 × 10 ⁴	4,62 × 10 ⁴	8,22 × 10 ⁴	11,52 × 10 ⁴	14,29 × 10 ⁴
VAR	1,38 × 10 ⁴	5,30 × 10 ⁴	122,49 × 10 ⁴	-	-
ARIMA	4,83 × 10 ⁴	9,38 × 10 ⁴	14,05 × 10 ⁴	18,79 × 10 ⁴	23,65 × 10 ⁴
LSTM	0,68 × 10 ⁴	1,76 × 10 ⁴	3,19 × 10 ⁴	4,93 × 10 ⁴	6,99 × 10 ⁴
BiLSTM	2,37 × 10 ⁴	2,38 × 10 ⁴	4,22 × 10 ⁴	6,00 × 10 ⁴	7,84 × 10 ⁴
GRU	0,59 × 10 ⁴	1,48 × 10 ⁴	2,75 × 10 ⁴	4,20 × 10 ⁴	5,86 × 10 ⁴
BiGRU	2,42 × 10 ⁴	2,84 × 10 ⁴	4,00 × 10 ⁴	4,91 × 10 ⁴	5,20 × 10 ⁴
LSTM-LSTM	1,11 × 10 ⁴	2,06 × 10 ⁴	3,21 × 10 ⁴	4,52 × 10 ⁴	5,98 × 10 ⁴
BiLSTM-LSTM	1,39 × 10 ⁴	2,41 × 10 ⁴	3,61 × 10 ⁴	4,89 × 10 ⁴	6,32 × 10 ⁴
GRU-GRU	0,80 × 10 ⁴	1,66 × 10 ⁴	2,76 × 10 ⁴	4,02 × 10 ⁴	5,42 × 10 ⁴
BiGRU-GRU	1,16 × 10 ⁴	2,23 × 10 ⁴	3,65 × 10 ⁴	5,06 × 10 ⁴	6,60 × 10 ⁴
Transformator	2,22 × 10 ⁴	1,72 × 10 ⁴	2,50 × 10 ⁴	3,50 × 10 ⁴	4,67 × 10 ⁴
METO-S2S	0,83 × 10 ⁴	2,30 × 10 ⁴	2,71 × 10 ⁴	3,49 × 10 ⁴	4,62 × 10 ⁴
Unsere		1,51 × 10 ⁴	2,34 × 10 ⁴	3,37 × 10 ⁴	4,57 × 10 ⁴

Das vorgeschlagene VEPO-S2S-Modell besteht aus dem Multi-level Vessel Trajectory Representation Module (Multi-Rep) und dem Feature Fusion and Decoding Module (FFDM). Das Multi-Rep ist nicht nur darauf ausgelegt, Flugbahninformationen zu integrieren, sondern auch berücksichtigen Sie die Eigenschaften und Verhaltenspräferenzen des Schiffes vollständig und kodieren Sie sie mit unterschiedlichen

Encoder, um die Darstellung von Merkmalen zu bereichern. Darüber hinaus wählt und integriert die oben genannten Informationen und Funktionen auf der Grundlage der aktuellen Prognoseumgebung, wodurch das Modell sie effizient nutzen kann. Diese beiden Vorteile machen VEPO-S2S genauer als die anderen Basislinien.

5.3. Ablationsstudie

Untersuchung der Funktion der Multi-Level Vessel Characteristics in VEPO-S2S und Mit dem Feature Fusion and Decoding Module haben wir mehrere Ablationsexperimente entwickelt, die werden im folgenden Teil vorgestellt:

1. ohne sa. Löschen Sie die Eingabe der Attribute für flaches Wasser im Multi-Level Vessel Modul zur Trajektoriendarstellung, einschließlich Schiffslänge, -breite, -tiefgang und -typ (siehe Abschnitt 4.3.1);
2. ohne k1. Löschen Sie die Segelortpräferenz in der mehrstufigen Schiffsbahn Repräsentationsmodul (siehe Abschnitt 4.3.1);
3. ohne k2. Löschen Sie die Reisezeitpräferenz aus der mehrstufigen Schiffsrouten Repräsentationsmodul (siehe Abschnitt 4.3.1);
4. ohne k3. Löschen Sie die Ankerzeitpräferenz aus der mehrstufigen Schiffsbahn Repräsentationsmodul (siehe Abschnitt 4.3.1);
5. ohne p_s. Löschen Sie die Portrait Selection-Komponente aus der Feature Fusion und Dekodierungsmodul (siehe Abschnitt 4.3.2);
6. w/of _f. Löschen Sie die Feature Fusion-Komponente aus der Feature Fusion- und Dekodierungsfunktion. Modul (siehe Abschnitt 4.3.2);
7. ohne muti_d. Löschen Sie die Multi-head Decoder-Komponente aus dem Feature Fusion und Decoding Module, das stattdessen eine einzelne GRU zur Dekodierung verwendet, die keine Flugbahninformationen müssen separat angegeben werden (siehe Abschnitt 4.3.2).

Die Ergebnisse sind in Tabelle 9 aufgeführt. Wir haben die Leistung mit RMSE, MAE, ADE und FDE. Die Ergebnisse zeigen, dass die Löschung der Portrait Selection Component hatte den größten Einfluss auf die RMSE-Metrik und reduzierte sie von $3,17 \times 10^4$ auf $4,48 \times 10^4$. Dies deutet darauf hin, dass die Portraitauswahlkomponente eine entscheidende Rolle spielt bei das Modell. Dies liegt daran, dass die Portraitauswahlkomponente für die Auswahl verantwortlich ist die Schiffseigenschaften, die für die aktuelle Umgebung am besten geeignet sind. Wenn die Wenn die Komponente „Portraitauswahl“ entfernt wird, nimmt die Leistung des Modells erheblich ab. Darüber hinaus wird festgestellt, dass die Löschung der Multi-Head-Decoder-Komponente die am wenigsten Einfluss, mit einem Rückgang von $3,17 \times 10^4$ auf $3,32 \times 10^4$. Dies liegt daran, dass die Verbesserung Der Decoder hat keinen Einfluss auf die Gesamtstruktur. Das Modell hat immer noch die Möglichkeit, und erfahren Sie, wie Sie die entsprechenden Merkmale nutzen können, um genaue Vorhersagen zu treffen. Die Verstärkung des Decoders führt jedoch zu einer leichten Verbesserung der Modellleistung. Im Einklang mit der obigen Analyse zeigten die Bewertungsmetriken MAE, ADE und FDE ähnliche Trends.

Tabelle 9. Quantitative Ergebnisse verschiedener Ablationsstudien.

Abtragung	RMSE	MAE	ADE	FDE
VEPO-S2S	$3,17 \times 10^4$	$1,60 \times 10^4$	$2,52 \times 10^4$	$4,57 \times 10^4$
ohne sa	$3,53 \times 10^4$	$1,88 \times 10^4$	$2,96 \times 10^4$	$5,27 \times 10^4$
ohne k1	$3,50 \times 10^4$	$1,82 \times 10^4$	$2,88 \times 10^4$	$5,07 \times 10^4$
ohne k2	$3,50 \times 10^4$	$1,88 \times 10^4$	$2,96 \times 10^4$	$5,19 \times 10^4$
ohne k3	$3,55 \times 10^4$	$1,95 \times 10^4$	$3,07 \times 10^4$	$5,38 \times 10^4$
ohne p_s	$4,48 \times 10^4$	$1,99 \times 10^4$	$3,15 \times 10^4$	$5,84 \times 10^4$
mit _fw/o	$3,42 \times 10^4$	$1,81 \times 10^4$	$2,88 \times 10^4$	$5,13 \times 10^4$
muti_d	$3,32 \times 10^4$	$1,76 \times 10^4$	$2,77 \times 10^4$	$4,87 \times 10^4$

Nach dem Entfernen verschiedener Innovationen nahm die Leistung des Modells ab. Daher Das Modell ist mit allen Eigenschaften und Komponenten ausgestattet, um optimale Ergebnisse, die die Wirksamkeit unserer innovativen Punkte belegen.

5.4. Qualitative Analyse

Um die Leistung von VEPO-S2S besser analysieren zu können, haben wir mehrere Vergleichs-kompatible Modelle für mehrere qualitative Analysen, wie in diesem Unterabschnitt beschrieben.

5.4.1. Vergleich von Baselines

Wie in Abbildung 12 dargestellt, erzielte unser Modell in beiden Szenarien genaue Vorhersagen im Vergleich zu anderen Basislinien. Die Schwierigkeit der Vorhersage nahm von (a) auf (b) zu. In (a) das Frachtschiff hatte eine gerade Route. Die meisten Modelle lieferten zufriedenstellende Vorhersagen, insbesondere VEPO und METO. Allerdings wich die GRU von der wahren Flugbahn ab. (b) zeigt ein Containerschiff, das wendet, wo unser Modell am besten abschneidet. Darüber hinaus ist das METO-S2S Das Modell sagte die ersten vier Punkte genau voraus, wich jedoch von der tatsächlichen Flugbahn ab in der letzte Punkt. Das GRU-GRU-Modell ist leistungsfähiger als das GRU-Modell, aber es Schwierigkeiten, zufriedenstellende Vorhersageergebnisse zu erzielen. In der Praxis können falsche Vorhersagen leicht zu Unfällen führen. Es kann beobachtet werden, dass die von VEPO-S2S vorhergesagten Ergebnisse anderen überlegen, wodurch Sicherheitsprobleme vermieden werden können.




Abbildung 12. Die Vorhersagen für Frachtschiffe und Containerschiffe unter verschiedenen Modellen, mit der Die Schwierigkeit der Vorhersagen nimmt von (a) zu (b) zu. Unser Modell ist in beiden Szenarien am besten. (a), bei dem es um die geradlinige Navigation von Frachtschiffen geht, erreichen alle Modelle außer GRU anständige Vorhersageergebnisse. In (b), bei dem es um das Wenden von Containerschiffen geht. Zusätzlich wird das METO-S2S-Modell ist auch in der Lage, die Vorhersageaufgaben bis zu einem gewissen Grad zu erfüllen. Andere Modelle haben jedoch Schwierigkeiten, zufriedenstellende Vorhersageleistung zu erzielen.

5.4.2. Visuelles Ergebnis der Seq2Seq-Struktur

Wie wir in Abbildung 13 sehen können, ist VEPO-GRU-GRU im Vergleich zu VEPO-BiGRU-GRU, VEPO-BiLSTM-LSTM und VEPO-LSTM-LSTM robuster. (a) zeigt eine glatte Flugbahn, die die normale Navigation eines Frachtschiffs darstellt. (b) zeigt eine gekrümmte Flugbahn, möglicherweise ein Hinweis auf Ausweichmanöver eines Öltankers. Über verschiedene Schiffstypen hinweg und Bewegungszuständen zeigen alle Strukturen des VEPO-S2S-Modells durchweg zufriedenstellende Leistung. Insbesondere das VEPO-S2S-Modell mit der GRU-GRU-Struktur zeigt eine bessere Robustheit.




Abbildung 13. Die Trajektorienvorhersagen des Frachtschiffs und des Öltankers unter Verwendung verschiedener Strukturen der VEPO-S2S-Modell, wobei die Vorhersageschwierigkeit von (a) nach (b) allmählich zunimmt. Wie in In der Grafik erzielt VEPO-GRU-GRU die beste Vorhersageleistung.

5.4.3. Qualitative Ablationsergebnisse

Um die Veränderungen der experimentellen Ergebnisse vor und nach der Ablation besser zu veranschaulichen, haben wir mehrere detaillierte Studien durchgeführt. Sieben Abbildungen zeigen die Ergebnisse der Experimente auf die Attribute für flache Gewässer, die bevorzugte Segelposition, die bevorzugte Reisezeit, die Ankerzeit-Präferenz, die Portrait-Auswahl-Komponente, die Feature-Fusion Komponente und die Multi-Head-Decoder-Komponente für einen Schlepper. Genauer gesagt, wir In jedem Bild werden vier Trajektorien dargestellt, einschließlich der Eingabe-Trackpunkte, Beschriftungen und der prädiktive Ergebnisse vor und nach der Ablation.

Bei jeder Abbildung ist zu erkennen, dass die grüne Kurve weitgehend der tatsächlichen Flugbahn entspricht. Wir beobachten, dass, wenn einem Schiff eines der Attribute für flache Gewässer fehlt, der Segelort Präferenz, die Reisezeitpräferenz oder die Ankerzeitpräferenz, gibt es erhebliche Abweichungen sowohl hinsichtlich der Richtung als auch der Entfernung in den vorhergesagten Ergebnissen.

Abbildung 14 zeigt die Ergebnisse mit und ohne Shallow-Level-Attribute. Fehlen von Shallow-Level-Attributen, VEPO-S2S-Vorhersagen weichen von der tatsächlichen Flugbahn ab am vierten und fünften Punkt. Dies liegt daran, dass Shallow-Level-Attribute die Trägheit und Wendefähigkeit des Schiffes. Größere Schiffe haben normalerweise größere Schwierigkeiten bei der Änderung ihrer aktuellen Bewegungszustände. Wenn es an Shallow-Level-Attributen mangelt, Das Modell hat Mühe, diese Fähigkeiten des Schiffes genau einzuschätzen. Daher Prognosen liefert das Modell keine wirksame Orientierung und führt zu Abweichungen von den Korrekte Flugbahn in späteren Phasen.




Abbildung 14. Die vorhergesagten Flugbahnen eines Schleppers, wobei die grünen und roten Linien die Vorhersage darstellen Ergebnisse unter Verwendung von VEPO-S2S mit bzw. ohne Shallow-level Attributes. Die Shallow-level Attribute sind mit der Trägheit und den Wendefähigkeiten des Schiffes verbunden. Das Modell ohne Shallow-level Attributes kann diese Fähigkeit nicht gut erfassen, was zu Fehlern führen kann.

Abbildung 15 zeigt die Ergebnisse mit und ohne Präferenz für Segelstandort. Die bevorzugte Segelposition hilft dem Modell dabei, die Anpassungsfähigkeit eines Schiffes an das Gelände zu erkennen.

Schiffe mit unterschiedlicher Anpassungsfähigkeit an das Gelände wählen unterschiedliche Kollisionsvermeidungsmethoden Routen. Ohne die Segelortpräferenz hat das Modell Schwierigkeiten, Details zu erfassen von Routen, was die Generierung entsprechender Entscheidungen erschwert und zu Schwingungen führt in den vorhergesagten Flugbahnen.




Abbildung 15. Die vorhergesagten Flugbahnen eines Schleppers, wobei die grünen und roten Linien die Vorhersageergebnisse von VEPO-S2S mit bzw. ohne Berücksichtigung der Segelstandortpräferenz darstellen. Die Segelstandortpräferenz hilft dem Modell, die Anpassungsfähigkeit des Schiffes an die geografische Umgebung zu ermitteln. Wenn die Segelstandortpräferenz nicht berücksichtigt wird, ist das VEPO-S2S-Modell das ist nicht richtig.

Abbildung 16 zeigt die Vergleichsergebnisse mit und ohne Reisezeitpräferenz. Die Reisezeitpräferenz spiegelt die Gewohnheiten der Besatzungen und der Schiffe wider. zu verschiedenen Zeiten. So sind die Kollisionsvermeidungsmanöver unterschiedlich während Zeiten mit hohem und niedrigem Schiffsverkehr. Ohne Führung durch die Reisezeitpräferenz, die prognostizierten Ergebnisse weisen erhebliche Schwankungen auf.




Abbildung 16. Die vorhergesagten Flugbahnen eines Schleppers, wobei die grünen und roten Linien die Prognoseergebnisse des VEPO-S2S-Modells mit und ohne Berücksichtigung der Reisezeitpräferenz, Die Reisezeitpräferenz hängt mit den Gewohnheiten der Besatzungen zusammen. Wenn die Reisezeitpräferenz Da Präferenzen nicht berücksichtigt werden, kann das VEPO-S2S-Modell ungenaue Vorhersagen liefern.

Abbildung 17 zeigt die Ergebnisse mit und ohne Ankerzeitpräferenz. hängt mit Arbeits- und Ruhegewohnheiten zusammen. Die Flugbahn des Schleppers ändert sich mehr erheblich, wenn es in betriebsfähigem Zustand ist. Daher ist es für das Modell schwierig, die aktuelle Bewegung des Schleppers ohne die Ankerzeit genau zu bestimmen Präferenz, die zu Abweichungen von den wahren Trajektorienpunkten führt.




Abbildung 17. Die vorhergesagten Flugbahnen eines Schleppers, wobei die grünen und roten Linien die Vorhersageergebnisse des VEPO-S2S-Modells mit und ohne Berücksichtigung der Ankerzeitpräferenz darstellen, Die Ankerzeitpräferenz hilft dem Modell, die Arbeits- und Ruhegewohnheiten zu identifizieren des Schiffes. Ohne die Ankerzeitpräferenz erzeugt das Modell eine falsche Schätzung für jeden Zeitstempel.

Abbildung 18 zeigt die visuellen Vergleichsergebnisse der Portrait Selection-Komponente. Ohne die Portrait Selection-Komponente weicht das Ergebnis vom realen Track ab. Die liegt darin, dass die Portraitauswahlkomponente die relevantesten Merkmale auswählen kann für Vorhersage und ohne sie können irrelevante Merkmale in die Vorhersage eingeführt werden Prozess, der zu erheblichen Abweichungen in den prognostizierten Ergebnissen führt.




Abbildung 18. Die vorhergesagten Flugbahnen eines Schleppers, wobei die grünen und roten Linien die Vorhersage darstellen Ergebnisse mit VEPO-S2S mit und ohne die Portrait Selection-Komponente. Die Portrait Die Auswahlkomponente ist für die Auswahl der relevantesten Merkmale für die Vorhersage verantwortlich. Ohne diese Komponente kann das Modell keine geeigneten Merkmale auswählen, die bei der Vorhersage helfen. was zu einer Verringerung der Modellrobustheit führt.

Abbildung 19 zeigt die visuellen Vergleichsergebnisse der Feature Fusion-Komponente, die integriert effektiv die Flugbahninformationen mit den Schiffsmerkmalen und verbessert die Korrelation zwischen ihnen. Ohne die Feature Fusion-Komponente werden die Schiffseigenschaften können nicht vollständig zum Ausdruck gebracht werden, was zu falschen Vorhersagen führt.




Abbildung 19. Die vorhergesagten Flugbahnen eines Schleppers, wobei die grünen und roten Linien die Vorhersage darstellen. Ergebnisse von VEPO-S2S mit und ohne Feature Fused Component. Die Feature Fused Komponente integriert effektiv Flugbahninformationen und Schiffseigenschaften und erhöht die Korrelation zwischen beiden. Ohne die Feature Fused Component sind Schiffseigenschaften schwer im VEPO-S2S-Modell angemessen auszudrücken, was zu einer Verringerung der Modellgenauigkeit führt.

Abbildung 20 zeigt die Vergleichsergebnisse der Multi-Head-Decoder-Komponente. Dadurch kann der Grad der Einbindung in die Flugbahninformationen und Schiffsmerkmale angepasst werden. Die Anpassungsfähigkeit des Modells nimmt ab, wenn die Multi-Head-Decoder-Komponente entfernt wird. Basierend auf diesen Ablationsstudien weist das VEPO-S2S-Modell eine zufriedenstellende Genauigkeit auf und Robustheit.




Abbildung 20. Die vorhergesagten Flugbahnen eines Schleppers, wobei die grünen und roten Linien die Vorhersageergebnisse unter Verwendung von VEPO-S2S mit bzw. ohne Multi-Head-Decoder-Komponente darstellen.

Die Multi-Head-Decoder-Komponente regelt die Einbindung der Trajektorieninformationen und Schiffseigenschaften in den Vorhersageprozess einbeziehen. Ohne sie ist die Anpassungsfähigkeit des VEPO-S2S-Modells fallen.

6. Schlussfolgerungen

Durch eine Untersuchung der relevanten Literatur fanden wir heraus, dass Schiffsmerkmale und Verhaltensmuster Präferenzen haben einen erheblichen Einfluss auf die Flugbahn. Daher schlägt diese Studie eine neue Flugbahnvorhersagemodell VEPO-S2S, das die Flugbahninformationen vollständig berücksichtigt, Schiffsmerkmale und Verhaltenspräferenzen. VEPO-S2S besteht aus zwei Teilen: dem Multi-Level Modul zur Darstellung der Schiffsbahn und Modul zur Merkmalsfusion und -dekodierung. Das Multi-level Vessel Trajectory Representation Module erhält Trajektorieninformationen (wie Längengrad, Breitengrad, Kurs, Geschwindigkeit und Fahrstrecke) zusammen mit Multi-Level-Schiffseigenschaften, einschließlich Flachwasserattributen (Schiffslänge, Typ, und Tiefgang) und detaillierte Funktionen (Segelortpräferenz, Reisezeitpräferenz, und Ankerzeitpräferenz). Diese werden mit mehreren Encodern codiert. Das Feature Das Fusions- und Dekodierungsmodul zielt darauf ab, die relevantesten Schiffseigenschaften für die aktuelle Prognoseumgebung und integrieren Sie sie mit den Flugbahninformationen vor

Dekodierung mit einem verbesserten Decoder. Die experimentellen Ergebnisse zeigen, dass dieses Modell andere Basismodelle qualitativ übertrifft und bei gitterbasierten Karten eine hervorragende Leistung zeigt.

7. Zukünftige Arbeiten

In dieser Arbeit haben wir den Einfluss von Merkmalen und Präferenzen über die Trajektorieninformationen hinaus auf die Trajektorienvorhersage berücksichtigt. In Zukunft wollen wir unser Modell optimieren, um die Effizienz und Vorhersagegenauigkeit zu verbessern, validiert anhand weiterer globaler Navigationsdatensätze. Darüber hinaus werden wir andere bekannte Modelle untersuchen, wie etwa das große Zeitreihenmodell. Darüber hinaus gibt es andere Faktoren, die die Schiffsbewegungen beeinflussen, darunter Wetter, Seebedingungen, Meeresströmungen und Riffe. Daher wollen wir mehr Einflussfaktoren in den Modellierungsprozess einbeziehen und weitere Untersuchungen in komplexeren Szenarien durchführen.

Beiträge der Autoren: Konzeptualisierung, ZH; Methodik, ZH und XY; Software, SL; Validierung, HL und JL; formale Analyse, YZ; Untersuchung, YZ und HL; Ressourcen, HL; Datenkuratierung, WA; Schreiben – Vorbereitung des Originalentwurfs, XY; Schreiben – Überprüfung und Bearbeitung, ZH; Visualisierung, WA und XY; Überwachung, SL und JL. Alle Autoren haben die veröffentlichte Version des Manuskripts gelesen und stimmen ihr zu.

Finanzierung: Diese Forschung wurde von der Natural Science Foundation der Provinz Zhejiang, China, im Rahmen des Zuschusses LY21E090005 und dem Bureau of Science and Technology Project von Zhoushan (2021C21010) finanziert.

Erklärung des Institutional Review Board: Nicht zutreffend.

Einverständniserklärung: Nicht zutreffend.

Datenverfügbarkeitserklärung: Alle in diesem Dokument verwendeten Daten können von der öffentlichen Website heruntergeladen werden: marinecadastre.gov/accessais (abgerufen am 31. Dezember 2021).

Interessenkonflikte: Die Autoren erklären, dass keine Interessenkonflikte vorliegen.

Abkürzungen

In diesem Manuskript werden die folgenden Abkürzungen verwendet:

AIS	Automatisches Identifikationssystem
Seq2Seq	Sequenz-zu-Sequenz-Netzwerk
VEPO	Vessel Portrait Oriented-Modell
Modul zur mehrstufigen Darstellung der Schiffsbahnen	
FFDM	das Feature Fusion- und Decoding-Modul

Verweise

1. Yang, C.-H.; Wu, C.-H.; Shao, J.-C.; Wang, Y.-C.; Hsieh, C.-M. KI-basierte intelligente Schiffsbahnvorhersage mit BI-LSTM. *IEEE Access* **2022**, *10*, 24302–24315.
2. Fossen, S.; Fossen, T.I. Erweitertes Kalman-Filter-Design und Bewegungsvorhersage von Schiffen unter Verwendung von Live-Daten des automatischen Identifikationssystems (AIS). In *Proceedings der 2. Europäischen Konferenz für Elektrotechnik und Informatik (EECS)* 2018, Bern, Schweiz, 20.–22. Dezember 2018; S. 464–470.
3. Kawan, B.; Wang, H.; Li, G.; Chhantyal, K. Datengesteuerte Modellierung der Schiffsbewegungsvorhersage basierend auf Support Vector Regression. In *Proceedings der 58. SIMS*, Reykjavik, Island, 25.–27. September 2017.
4. Li, H.; Jiao, H.; Yang, Z. Schiffsfahrtbahnvorhersage basierend auf maschinellem Lernen und Deep Learning: Eine systematische Überprüfung und Methodenanalyse. *Eng. Appl. Artif. Intell.* **2023**, *126*, 107062.
5. Suo, Y.; Chen, W.; Claramunt, C.; Yang, S. Ein Rahmenwerk zur Vorhersage der Flugbahn von Schiffen basierend auf einem rekurrenden neuronalen Netzwerk. *Sensoren* **2020**, *20*, 5133.
6. Wang, C.; Ren, H.; Li, H. Vorhersage der Schiffsbahn basierend auf AIS-Daten und bidirektionalem GRU. In *Proceedings der 2020 International Conference on Computer Vision, Image and Deep Learning (CVIDL)*, IEEE, Nanchang, China, 15.–17. Mai 2020; S. 260–264.
7. Tang, H.; Yin, Y.; Shen, H. Ein Modell zur Vorhersage von Schiffsfahrtbahnen basierend auf einem neuronalen Netzwerk mit langem Kurzzeitgedächtnis. *J. Mar. Eng. Technol.* **2022**, *21*, 136–145.

8. Park, J.; Jeong, J.; Park, Y. Schiffsflugbahnvorhersage basierend auf bi-LSTM unter Verwendung spektral gruppierter AIS-Daten. *J. Mar. Sci. Eng.* **2021**, *9*, 1037.
9. Zhang, S.; Wang, L.; Zhu, M.; Chen, S.; Zhang, H.; Zeng, Z. Eine bidirektionale LSTM-Schiffsbahnvorhersagemethode basierend auf einem Aufmerksamkeitsmechanismus. In *Proceedings der 2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, IEEE, Chongqing, China, 12.–14. März 2021; S. 1987–1993.
10. Bao, K.; Bi, J.; Gao, M.; Sun, Y.; Zhang, X.; Zhang, W. Eine verbesserte Schiffsflugbahnvorhersage basierend auf AIS-Daten unter Verwendung von mha-bigru. *J. Mar. Sci. Eng.* **2022**, *10*, 804.
11. Wu, W.; Chen, P.; Chen, L.; Mou, J. Vorhersage der Schiffsflugbahn: Ein integrierter Ansatz unter Verwendung eines konvlstm-basierten Sequenz-zu-Sequenz- Modells. *J. Mar. Sci. Eng.* **2023**, *11*, 1484.
12. Nguyen, D.-D.; Van, CL; Ali, MI Vorhersage der Schiffsbahn mithilfe von Sequenz-zu-Sequenz-Modellen über ein räumliches Gitter. In *Proceedings der 12. ACM International Conference on Distributed and Event-Based Systems*, Lyon, Frankreich, 25.–28. Juni 2018; S. 258–261.
13. Zhang, Y.; Han, Z.; Zhou, X.; Li, B.; Zhang, L.; Zhen, E.; Wang, S.; Zhao, Z.; Guo, Z. Meto-s2s: Eine auf s2s basierende Methode zur Vorhersage von Schiffsbahnen mit mehrfach- semantischem Encoder und typorientiertem Decoder. *Ocean. Eng.* **2023**, *277*, 114248.
14. Zhao, J.; Yan, Z.; Chen, X.; Han, B.; Wu, S.; Ke, R. k-gcn-1stm: Ein k-Hop-Graph-Faltungsnetzwerk und Lang-Kurzzeitgedächtnis zur Vorhersage der Schiffsgeschwindigkeit. *Phys. Stat. Mech. Its Appl.* **2022**, *606*, 128107.
15. Wang, S.; Li, Y.; Xing, H.; Zhang, Z. Schiffsbahnvorhersage basierend auf einem räumlich-zeitlichen Graph-Faltungsnetzwerk für komplexe und überfüllte Meeresgebiete. *Ocean. Eng.* **2024**, *298*, 117232.
16. Cao, D.; Li, J.; Ma, H.; Tomizuka, M. Spektrales zeitliches Graph-Neuralnetzwerk zur Flugbahnvorhersage. In *Proceedings of the 2021 IEEE Internationale Konferenz für Robotik und Automatisierung (ICRA)*, Xi'an, China, 30. Mai–5. Juni 2021; S. 1839–1845.
17. Yasukawa, H.; Yoshimura, Y. Schiffsmanövrierfähigkeit; Seizando: Tokio, Japan, 2018.
18. Cooper, A. Warum High-Tech-Produkte uns in den Wahnsinn treiben und wie wir unsere geistige Gesundheit wiederherstellen; Sams Publishing: Carnel, IN, USA, 2004.
19. Lu, J.; Xie, L. Trägheitsnavigationsmethode für Ozeanfahrzeuge basierend auf dynamischen Einschränkungen. *J. Navig.* **2018**, *71*, 1553–1566.
20. Cole, B.; Schamberg, G. Unscented Kalman Filter für die Langstrecken-Schiffsverfolgung in geodätischen Koordinaten. *Appl. Ocean. Res.* **2022**, *124*, 103205.
21. Zhang, D.; Chu, X.; Wu, W.; He, Z.; Wang, Z.; Liu, C. Modellidentifikation von Schiffswendemanövern und extremen Kurzzeit Flugbahnvorhersage unter dem Einfluss von Meeresströmungen. *Ocean. Eng.* **2023**, *278*, 114367.
22. Sun, Q.; Tang, Z.; Gao, J.; Zhang, G. Kurzfristige Vorhersage der Schiffsbewegungslage basierend auf LSTM und GPR. *Appl. Ocean. Res.* **2022**, *118*, 102927.
23. Zhang, L.; Zhu, Y.; Su, J.; Lu, W.; Li, J.; Yao, Y. Ein hybrides Vorhersagemodell basierend auf KNN-LSTM für die Schiffsbahn. *Mathematik* **2022**, *10*, 4493.
24. Gao, D.-W.; Zhu, Y.-S.; Zhang, J.-F.; He, Y.-K.; Yan, K.; Yan, B.-R. Eine neuartige MP-LSTM-Methode zur Vorhersage von Schiffsflugbahnen basierend auf AIS-Daten. *Ocean. Eng.* **2021**, *228*, 108956.
25. Forti, N.; Millefiori, LM; Braca, P.; Willett, P. Vorhersage von Schiffsbahnen aus AIS-Daten über Sequenz-zu-Sequenz-rekurrierende neuronale Netzwerke. In *Proceedings of the ICASSP 2020—2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, virtuell, 4.–9. Mai 2020; S. 8936–8940.
26. You, L.; Xiao, S.; Peng, Q.; Claramunt, C.; Han, X.; Guan, Z.; Zhang, J. St-seq2seq: Ein räumlich-zeitliches, merkmalsoptimiertes seq2seq Modell zur kurzfristigen Vorhersage von Schiffstrajektorien. *IEEE Access* **2020**, *8*, 218565–218574.
27. Chen, P.; Yang, F.; Mou, J.; Chen, L.; Li, M. Regionales Schiffsverhalten und Flugbahnvorhersage für das maritime Verkehrsmanagement: A Ansatz sozialer generativer kontradiktorischer Netzwerke. *Ocean. Eng.* **2024**, *299*, 117186.
28. Zhang, Y.; Han, Z.; Zhou, X.; Zhang, L.; Wang, L.; Zhen, E.; Wang, S.; Zhao, Z.; Guo, Z. Peso: Eine seq2seq-basierte Methode zur Vorhersage von Schiffstrajektorien mit parallelen Encodern und schiffsorientiertem Decoder. *Appl. Sci.* **2023**, *13*, 4307.
29. Jiang, D.; Shi, G.; Li, N.; Ma, L.; Li, W.; Shi, J. Trfm-Is: Transformer-basierte Deep-Learning-Methode zur Vorhersage von Schiffsflugbahnen. *J. Mar. Sci. Eng.* **2023**, *11*, 880.
30. Liu, RW; Liang, M.; Nie, J.; Yuan, Y.; Xiong, Z.; Yu, H.; Guizani, N. Stmgcn: Durch mobiles Edge Computing unterstützte Vorhersage der Schiffsbahnen unter Verwendung eines räumlich-zeitlichen Multigraph-Faltungsnetzwerks. *IEEE Trans. Ind. Inform.* **2022**, *18*, 7977–7987.
31. Li, Y.; Li, Z.; Mei, Q.; Wang, P.; Hu, W.; Wang, Z.; Xie, W.; Yang, Y.; Chen, Y. Forschung zu einer Methode zur Vorhersage von Schiffsverkehr über mehrere Häfen auf der Grundlage räumlich-zeitlicher Graph-Neuralnetze. *J. Mar. Sci. Eng.* **2023**, *11*, 1379.
32. Cho, K.; Merriënboer, BV; Gulcehre, C.; Bahdanau, D.; Bougares, F.; Schwenk, H.; Bengio, Y. Lernen von Phrasendarstellungen Verwendung eines RNN-Encoders/Decoders für die statistische maschinelle Übersetzung. *arXiv* **2014**, arXiv:1406.1078.
33. Gong, G.; An, X.; Mahato, NK; Sun, S.; Chen, S.; Wen, Y. Forschung zur kurzfristigen Lastvorhersage basierend auf dem seq2seq-Modell. *Energien* **2019**, *12*, 3199.
34. Hwang, S.; Jeon, G.; Jeong, J.; Lee, J. Ein neuartiges, auf Zeitreihen basierendes seq2seq-Modell zur Temperaturvorhersage im Brennofenprozess. *Procedia Comput. Wissenschaft.* **2019**, *155*, 19–26.
35. Gao, S.; Zhang, S.; Huang, Y.; Han, J.; Luo, H.; Zhang, Y.; Wang, G. Eine neue seq2seq-Architektur zur stündlichen Abflussvorhersage mit historischer Niederschlag und Abfluss als Input. *J. Hydrol.* **2022**, *612*, 128099.
36. Wang, H.; Wang, S.; Chen, S.; Hui, G. Vorhersage der langfristigen Produktionsdynamik in Tight-/Schiefergaslagerstätten mit einem zweistufigen aufmerksamkeitsbasierten ten-seq2seq-Modell: Eine Fallstudie zur Duvernay-Formation. *Geoenergy Sci. Eng.* **2023**, *223*, 211495.

37. Stefenon, S.F.; Seman, L.O.; Aquino, L.S.; Coelho, L.d.S. Wavelet-seq2seq-lstm mit Fokus auf Zeitreihenprognosen des Pegels von Staudämmen in Wasserkraftwerken. *Energy* **2023**, *274*, 127350.
38. Mootha, S.; Sridhar, S.; Seetharaman, R.; Chitrakala, S. Aktienkursvorhersage mithilfe von bidirektionaler, auf LSTM basierender Sequenz-zu-Sequenz-Modellierung und Multitask-Lernen. In Proceedings der 11. IEEE Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON) 2020, New York, NY, USA, 28.–31. Oktober 2020; S. 0078–0086.
39. He, Q.; Li, W.; Hao, Z.; Liu, G.; Huang, D.; Song, W.; Xu, H.; Alqahtani, F.; Kim, J.-U. Ein tma-seq2seq-Netzwerk zur Vorhersage der Meeresoberflächentemperatur in mehrstufigen Zeitreihen. *Comput. Mater. Contin.* **2022**, *73*, 2022.
40. Qu, Q.; Chen, H.; Lei, Z.; Li, B.; Du, Q.; Wang, Y. Vorhersage der Amplitude von Seestörungen über ein aufmerksamkeitsverstärktes seq2seq-Netzwerk. *Remote Sens.* **2023**, *15*, 3234.
41. Asadi, N.; Lamontagne, P.; King, M.; Richard, M.; Scott, K.A. Saisonale Meereispräsenzvorhersage der Hudson Bay mithilfe von seq2seq- Lernen. Online verfügbar: <https://s3.us-east-1.amazonaws.com/climate-change-ai/papers/icml2021/6/paper.pdf> (abgerufen am 1. Juni 2024)
42. Zhu, W.; Zhou, R. Erstellung von Mitarbeiterporträts auf der Grundlage tiefer neuronaler Netzwerke. In Proceedings der 9. Internationalen Konferenz über zuverlässige Systeme und ihre Anwendungen (DSA) 2022, IEEE, Wulumuqi, China, 4.–5. August 2022; S. 139–142.
43. Ma, C.; Wang, Z.; Cheng, P.; Liu, X.; Yu, H.; Zhang, H. Auf Benutzerporträts basierende hybride Empfehlungsmethode für Webdienste. *J. 2021*, *32*, 197–212.
44. Zhao, J.; Zeng, D.; Xiao, Y.; Che, L.; Wang, M. Vorhersage der Benutzerpersönlichkeit basierend auf Themenpräferenz und Stimmungsanalyse unter Verwendung eines LSTM-Modells. *Mustererkennung. Lett.* **2020**, *138*, 397–402.
45. Yan, S.; Zhao, T.; Deng, J. Vorhersage der Nutzung von Social-Media-Nutzern mit inhaltsbewussten hierarchischen neuronalen Netzwerken. In Proceedings der 8. Internationalen Konferenz für Big Data und Informationsanalyse (BigDIA) 2022, Guiyang, China, 24.–25. August 2022; S. 388–395.
46. Wang, N. Computerintelligentes Vorhersagemodell für impulsive Internetbelohnungen basierend auf einem Benutzerporträtalgorithmus. In Proceedings der 2021 IEEE 4th International Conference on Automation, Electronics and Electrical Engineering (AUTEEE), Shenyang, China, 19.–21. November 2021; S. 545–548.
47. Mingyu, Z.; Sutong, W.; Yanzhang, W.; Dujuan, W. Eine interpretierbare Vorhersagemethode für die akademische Krise von Universitätsstudenten Warnung. *Complex Intell. Syst.* **2022**, *8*, 323–336.
48. Liu, T.; Ma, J. Vorhersage des Schiffs Navigationsverhaltens basierend auf AIS-Daten. *IEEE Access* **2022**, *10*, 47997–48008.
49. Silvester, R. *Coastal Engineering*; Elsevier Scientific Publishing Company: Amsterdam, Niederlande, 1974.
50. Brolsma, J.U. Permanent International Association of Navigation Congresses. PIANC, die Weltvereinigung für Wassertransportinfrastruktur: Eine Vereinigung in einer sich verändernden Welt, 1885–2010; PIANC: Brüssel, Belgien, 2010. Online verfügbar: <https://books.google.co.jp/books?id=ZaSwYgEACAAJ> (abgerufen am 1. Juni 2024).
51. Notteboom, T.E. Containerschiffahrt und Häfen: Ein Überblick. *Rev. Netw. Econ.* **2004**, *3*, 86–106.
52. Gillis, D.M. Ideale freie Verteilungen in der Flottendynamik: Eine verhaltensbezogene Perspektive auf Schiffsbewegungen in der Fischereianalyse. *Can. J. Zool.* **2003**, *81*, 177–187.
53. Mahpour, A.; Nazifi, A.; Amiri, A.M. Entwicklung eines Optimierungsmodells zur Reduzierung der Entlade- und Ladezeit am Liegeplatz in Containerhäfen. *J. Sci. Technol. Trans. Civ. Eng.* **2021**, *45*, 2831–2840.
54. McInnes, L.; Healy, J.; Astels, S. hdbscan: Hierarchisches dichte-basiertes Clustering. *J. Open Source Softw.* **2017**, *2*, 205.

Haftungsausschluss/Anmerkung des Herausgebers: Die in allen Veröffentlichungen enthaltenen Aussagen, Meinungen und Daten sind ausschließlich die der einzelnen Autoren und Mitwirkenden und nicht die von MDPI und/oder den Herausgebern. MDPI und/oder die Herausgeber lehnen jegliche Verantwortung für Personen- oder Sachschäden ab, die aus den im Inhalt erwähnten Ideen, Methoden, Anweisungen oder Produkten resultieren.