

Article

VEPO-S2S : une prédiction de trajectoire orientée portrait de navire Modèle basé sur le framework S2S

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, Wanzheng Ai et Junyi Liu 1,3,4,5

¹ Institut de recherche sur l'information aérospatiale, Académie chinoise des sciences, Pékin 100190, Chine ; yxy915200@163.com (XY); hanzh@aircas.ac.cn (ZH); zhangyb@aircas.ac.cn (YZ); 18010076513@163.com (SL); liujy004735@aircas.ac.cn (JL)

² École d'architecture navale et maritime, Zhejiang Ocean University, Zhoushou 361022, Chine ; aiwanzheng@126.com Laboratoire clé de technologie des systèmes d'information sur les réseaux, Institut

³ d'électronique, Académie chinoise des sciences, Pékin 100190, Chine Laboratoire clé de technologie de cognition et d'application cible (TCAT), Pékin 100190, Chine 5 École d'électronique, d'électricité et de communication

⁴ Ingénierie, Université de l'Académie chinoise des sciences, Pékin 100190, Chine *

Correspondance : liuhu@zjou.edu.cn Ces

† auteurs ont contribué à parts égales à ce travail.

Résumé : La prédiction des trajectoires des navires joue un rôle crucial pour assurer la sécurité maritime et réduire les accidents maritimes. Des progrès substantiels ont été réalisés dans les tâches de prédiction de trajectoire grâce à l'adoption de méthodes de modélisation de séquence, contenant des réseaux de neurones récurrents (RNN) et des réseaux séquence à séquence (Seq2Seq). Cependant, (1) la plupart de ces études se concentrent sur l'application d'informations sur les trajectoires, telles que la longitude, la latitude, le cap et la vitesse, tout en négligeant l'impact des différentes caractéristiques des navires et préférences comportementales sur les trajectoires. (2) Des défis subsistent pour acquérir ces caractéristiques et préférences, ainsi que pour permettre au modèle de les intégrer judicieusement et de les exprimer efficacement. Pour résoudre ce problème, nous introduisons un nouveau cadre profond VEPO-S2S, composé d'un module de représentation de trajectoire de navire à plusieurs niveaux (Multi-Rep) et d'un module de fusion et de décodage de fonctionnalités (FFDM). Outre les informations sur la trajectoire, nous avons d'abord défini les caractéristiques du navire à plusieurs niveaux dans Multi-Rep, englobant les attributs de niveau peu profond (longueur du navire, largeur, tirant d'eau, etc.) et les caractéristiques de niveau profond (préférence d'emplacement de navigation, préférence de temps de voyage, etc.). Par la suite, Multi-Rep a été conçu pour obtenir des informations sur la trajectoire et les caractéristiques des navires à plusieurs niveaux, en appliquant des encodeurs distincts pour le codage. Ensuite, le FFDM a sélectionné et intégré les fonctionnalités ci-dessus de Multi-Rep pour la prédiction en utilisant à la fois des mécanismes a priori et a posteriori, un composant de fusion de fonctionnalités et un décodeur amélioré. Cela permet au modèle de les exploiter efficacement et d'améliorer les performances globales. Enfin, nous avons mené des expériences comparatives avec plusieurs modèles de base. Les résultats expérimentaux démontrent que VEPO-S2S est à la fois quantitativement et qualitativement supérieur aux modèles.

Mots-clés : apprentissage profond ; prédiction de trajectoire de navire ; réseau séquence à séquence ; accidents maritimes ; l'évaluation des risques; portrait de navire



Citation : Yang, X. ; Han, Z. ; Zhang, Y. ; Liu, H. ; Liu, S. ; Ai, W. ; Liu, J. VEPO-S2S : un portrait de navire

Modèle de prédiction de trajectoire orientée basé sur le cadre S2S. Appl. Sci. 2024, 14, 6344. <https://doi.org/10.3390/app14146344>

Rédacteur académique : Phivos Mylonas, Katia Lida Kermanidis et Manolis Maragoudakis

Reçu : 3 juin 2024

Révisé : 13 juillet 2024

Accepté : 16 juillet 2024

Publié : 20 juillet 2024



Copyright : © 2024 par les auteurs.

Licencié MDPI, Bâle, Suisse.

Cet article est un article en libre accès distribué selon les termes et conditions des Creative Commons

Licence d'attribution (CC BY) (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

L'industrie maritime est devenue plus importante dans l'économie mondiale, représentant plus de 90 % du fret mondial au cours des dernières décennies [1]. Par conséquent, assurer la sécurité maritime et améliorer l'efficacité de la navigation est devenu encore plus urgent. L'utilisation d'un système d'identification automatique (AIS) pour prédire les trajectoires des navires peut prévenir les collisions et fournir une évaluation des risques aux régulateurs. Plus précisément, cette tâche consiste à prévoir les trajectoires futures sur la base de points de trajectoire historiques. Certains algorithmes [2,3], tels que le filtre de Kalman et les machines vectorielles de support, permettent des prédictions relativement précises. Cependant,

les modèles sont souvent contraints par des simplifications et présentent des performances médiocres lorsqu'ils sont confrontés à des situations plus complexes [4].

Aujourd'hui, l'apprentissage profond a fait des progrès significatifs et a trouvé de larges applications dans divers domaines. Les réseaux de neurones récurrents (RNN), en tant que modèles de prédiction de séries chronologiques, ont été largement appliqués à la prédiction de trajectoires, mais ils souffrent de problèmes tels que la disparition et l'explosion du gradient. Ces dernières années, les chercheurs ont constamment amélioré les approches de prédiction de trajectoire basées sur les RNN et ont obtenu des résultats remarquables. Les auteurs de [5,6] ont proposé un modèle basé sur GRU pour capturer la dynamique temporelle des séquences de trajectoires. Ce modèle peut apprendre les relations non linéaires et complexes entre les entrées et les sorties, codant ainsi les schémas de mouvement historiques des navires. Les auteurs de [7] ont proposé un modèle de trajectoire basé sur la mémoire à long terme (LSTM) qui apprend les schémas de mouvement des navires à partir de l'environnement et du temps actuels. Les auteurs de [8] ont proposé une méthode de prédiction de trajectoire combinant la mémoire bidirectionnelle à long terme (BiLSTM) et le clustering spatial basé sur la densité d'applications avec bruit (DBSCAN). Cette méthode intègre les modèles de trajectoire des navires détectés à l'aide de DBSCAN pour améliorer encore les performances. Les auteurs de [9,10] ont tenté d'incorporer des mécanismes d'attention pour capturer des informations cruciales. Cependant, ces méthodes ne peuvent prédire qu'un seul point de manière séquentielle, ce qui entraîne une accumulation rapide d'erreurs dans les prédictions en plusieurs étapes. L'émergence des modèles Seq2Seq a considérablement atténué ce problème. Seq2Seq est un type de réseau neuronal codeur-décodeur initialement utilisé dans le domaine de la traduction automatique, et il a été largement appliqué à la prédiction de trajectoire. Il prend en charge la sortie multipoint en une seule itération, réduisant ainsi efficacement l'accumulation d'erreurs. Les auteurs de [11] ont développé un modèle basé sur ConvLSTM et Seq2Seq, améliorant la capacité à capturer les dépendances temporelles globales. Les auteurs de [12] ont divisé la zone maritime à l'aide d'une grille spatiale basée sur le modèle Seq2Seq et ont obtenu de bons résultats en matière de prévision à long terme. Les auteurs de [13] ont proposé le modèle METO-S2S, qui utilise un décodeur multi-sémantique, prenant en compte les effets de diverses données sémantiques des navires sur la prévision de trajectoire. Outre les méthodes basées sur les RNN qui utilisent des informations temporelles, une autre approche explorée consiste à utiliser des informations spatiales pour la modélisation, les réseaux convolutifs graphiques (GCN) étant les plus représentatifs. Pour résoudre le problème des dépendances spatio-temporelles, [14] a combiné un k-GCN avec le LSTM, en utilisant le GCN pour capturer les corrélations spatiales entre les nœuds et le LSTM pour gérer les corrélations spatio-temporelles des nœuds, permettant ainsi la prédiction des vitesses des navires. Les auteurs de [15] ont introduit un modèle DAA-SGCN, utilisant un ST-GCN pour extraire les caractéristiques d'interaction sociale spatiale et un RT-CNN pour extraire les caractéristiques temporelles, en tenant pleinement compte des interactions sociales entre les vaisseaux. Les auteurs de [16] ont non seulement pris en compte les propres intentions du navire, mais ont également pris en compte l'impact de l'environnement statique et des agents environnants en interaction dynamique. Cette recherche s'est largement concentrée sur l'application des informations de trajectoire à des fins de prédiction et a abouti à des résultats remarquables. Cependant, en raison des dépendances complexes entre les informations historiques et de la forte influence des corrélations spatiales, le fait de se fier uniquement aux informations sur la trajectoire rend difficile l'obtention de résultats prédictifs précis. De plus, les caractéristiques du navire à plusieurs niveaux, telles que les attributs du navire et les préférences de localisation de navigation, jouent également un rôle crucial dans la prédiction de trajectoire. Selon les normes de manœuvrabilité des navires [17], la stabilité du cap et la capacité de virage sont des paramètres cruciaux pour la manœuvrabilité, dépendant du coefficient de bloc, qui est déterminé par les attributs d'un navire. Les variations dans les attributs d'un navire ont un impact significatif sur la manœuvrabilité, affectant ainsi les décisions concernant les ports, les chenaux et les routes. De plus, les préférences de localisation des navigations révèlent leurs tendances vers des zones maritimes spécifiques, qui devraient recevoir plus d'attention dans les prévisions. Comme le montre la figure 1, deux types de vaisseaux présentent des trajectoires de mouvement distinctes. Comparés aux chalutiers, les cargos ont généralement des volumes plus importants et des coefficients de blocage plus élevés, ce qui se traduit par un rayon de braquage plus grand et une stabilité de cap moins bonne. Pour atténuer les risques potentiels, les cargos ont tendance à choisir des voies de navigation et des chenaux plus larges, en respectant strictement les horaires établis pour garantir une livraison ponctuelle des marchandises et améliorer l'efficacité logistique globale, ce qui se traduit par des trajectoires de navigation plus fluides et plus régulières. À l'inverse, les chalutiers opèrent dans des

et des politiques réglementaires pertinentes, ce qui entraîne souvent des routes de navigation irrégulières et concentrées. Il est donc crucial d'étudier les modèles de comportement des différents navires et de mener des analyses prédictives sur mesure basées sur les attributs des navires et les zones opérationnelles.




Figure 1. Des exemples de trajectoires pour différents types de navires illustrent des différences significatives dans les trajectoires de navigation sous l'influence de divers attributs et types de navires.

Pour cette raison, des défis persistent pour obtenir des caractéristiques plus complètes, ainsi que pour leur sélection et leur mise en œuvre judicieuses. Inspirés par les personnalités des utilisateurs [18], nous avons incorporé des attributs de niveau peu profond et des caractéristiques de niveau profond, définissant les caractéristiques du navire à plusieurs niveaux pour construire un portrait complet du navire. Compte tenu des défis mentionnés ci-dessus, nous proposons un modèle de prédiction de trajectoire de navire VEPO-S2S basé sur l'architecture Seq2Seq, comprenant un module de représentation de trajectoire de navire à plusieurs niveaux (Multi-Rep) et un module de fusion et de décodage de fonctionnalités (FFDM). Multi-Rep a pour fonction d'acquiescer et d'exprimer des fonctionnalités, composées de deux composants : le composant d'acquisition de fonctionnalités et le composant d'expression de fonctionnalités. Dans le composant d'acquisition de fonctionnalités, nous spécifions d'abord les informations de trajectoire qui incluent la longitude, la latitude, la vitesse, le cap et la distance de navigation. Ensuite, les caractéristiques du navire à plusieurs niveaux sont définies, couvrant les attributs de niveau peu profond (tels que la longueur, la largeur, le tirant d'eau, etc.) ainsi que les caractéristiques de niveau profond (préférence d'emplacement de navigation, préférence de temps de voyage, etc.). Tous ces éléments sont acquis via le composant d'acquisition de fonctionnalités, puis codés séparément à l'aide de trois encodeurs indépendants au sein du composant d'expression de

En dehors de cela, malgré l'incorporation d'informations sur la trajectoire et les caractéristiques des navires dans le modèle, les modèles Seq2Seq de base rencontrent des difficultés pour les discerner et les exploiter efficacement. Il est donc impératif de sélectionner et d'intégrer les informations sur la trajectoire et les caractéristiques du navire avant de les appliquer. Pour atteindre cet objectif, nous proposons le module FFDM qui comprend un composant de sélection de portrait, un composant de fusion de fonctionnalités et un composant de décodage multi-têtes. Dans un premier temps, le composant de sélection de portrait discerne les caractéristiques des navires les plus pertinentes pour l'environnement de prévision actuel en analysant les caractéristiques codées. Ensuite, le composant Feature Fusion est conçu pour fusionner les informations de trajectoire du module Multi-Rep avec les caractéristiques pertinentes du navire. Enfin, la sortie sert d'entrée pour le composant de décodage multi-têtes, conçu sur la base du décodeur Seq2Seq traditionnel. Le composant de décodage multi-têtes se compose de deux blocs GRU distincts, chacun contrôlant la proportion d'informations sur la trajectoire et les caractéristiques du navire pendant la prédiction, fournissant ainsi des résultats de sortie plus précis.

En résumé, les principales contributions de cet article peuvent être résumées comme suit :

- Nous proposons un cadre de prédiction de trajectoire de navire VEPO-S2S, qui englobe le module de représentation de trajectoire de navire à plusieurs niveaux (Multi-Rep) et le module de fusion et de décodage de fonctionnalités (FFDM). Ce cadre prend pleinement en compte la trajectoire

informations et caractéristiques des navires, garantissant leur intégration judicieuse et leur expression efficace pour obtenir des résultats plus précis.

- Nous proposons le module Multi-Rep, qui intègre les informations de trajectoire avec les caractéristiques des navires à plusieurs niveaux et utilise plusieurs encodeurs pour le codage. Ce module a la capacité de capturer des représentations temporelles des trajectoires ainsi que le portrait détaillé des navires.
- Pour relever le défi de fusionner et de représenter efficacement plusieurs caractéristiques au sein de notre modèle, nous proposons le FFDM. Ce module sélectionne et intègre des caractéristiques en utilisant des mécanismes a priori et a posteriori, un composant Feature Fusion et un décodeur amélioré. Le FFDM peut mieux représenter la corrélation spatio-temporelle entre les trajectoires historiques.
- Nous avons mené des expériences comparatives sur plusieurs modèles de base. Les résultats expérimentaux ont démontré que le VEPO-S2S a surpassé les autres modèles de base sur les plans quantitatif et qualitatif, produisant des résultats de prédiction plus robustes et plus précis <https://github.com/AIR-SkyForecast/AIR-SkyForecast-VEPO-S2S/new/principal> (consulté le 15 juillet 2024).

2. Travaux connexes

2.1. Prédiction de la trajectoire des navires

Les méthodes traditionnelles de prédiction de trajectoire ont obtenu des résultats favorables dans la prévision des trajectoires des véhicules, des navires et des piétons. Les auteurs de [19] ont proposé une méthode de navigation inertielle assistée dynamiquement pour estimer les valeurs observées. Les auteurs de [20] ont introduit une méthode de filtrage de Kalman basée sur une modélisation mathématique pour le suivi de surface à longue portée, permettant la prédiction directe de la position et du cap de la cible sans nécessiter de conversion du système de coordonnées. Pour améliorer la précision de la prédiction du mouvement des navires en cas de perturbations environnementales, réf. [21] ont proposé un algorithme de reconnaissance de mouvement de navire basé sur la méthode des moindres carrés. Cependant, ces méthodes présentaient une précision prédictive limitée face à des situations complexes.

Ces dernières années, le développement de méthodes d'apprentissage profond pour la prévision de la trajectoire des navires a progressé rapidement et des progrès significatifs ont été réalisés dans ce domaine. La plupart des recherches adoptent la structure RNN. Certaines recherches s'appuient sur un LSTM [22] ou un GRU [6]. De plus, pour étudier la prédiction des navires sous différentes densités de trajectoire, réf. [23] ont proposé un modèle basé sur un LSTM et le K-plus proche voisin (KNN). Les auteurs de [24] ont introduit le modèle MP-LSTM, qui intègre les atouts de TPNNet et LSTM, comblant les lacunes des méthodes existantes en termes de précision et de complexité du modèle.

Pendant ce temps, certains chercheurs ont tenté d'utiliser l'architecture Seq2Seq pour résoudre les problèmes de prédiction. Les auteurs de [25] ont introduit un modèle de réseau neuronal basé sur un LSTM et Seq2Seq, utilisé pour capturer les dépendances à long terme dans les données historiques au sein des trajectoires.

Les auteurs de [26] ont proposé le modèle ST-Seq2S2q basé sur l'architecture GRU. Les auteurs de [27] ont proposé un modèle de prédiction de trajectoire basé sur BiGRU et Seq2Seq, qui prend pleinement en compte les interactions entre les navires. De plus, plusieurs autres modèles de prédiction de trajectoire ont été proposés. Les auteurs de [13] ont introduit le modèle METO-S2S basé sur un décodeur multi-sémantique, considérant l'influence de diverses informations sémantiques du navire sur la prédiction de trajectoire. Ils ont également utilisé des vecteurs sémantiques (SLV) pour guider les prédictions du modèle dans PESO [28], obtenant ainsi des résultats exceptionnels sur l'ensemble de données open source AIS aux États-Unis. En plus du modèle Seq2Seq, [29] a appliqué le cadre Transformer combiné au LSTM pour capturer les trajectoires historiques dans des séries chronologiques et surmonter les problèmes liés à la dégradation des informations à distance. Pour exprimer l'interdépendance entre les navires, [30] ont proposé le modèle de réseau neuronal convolutionnel multi-graphique spatio-temporel (STMGCN), qui modélise séparément les données spatio-temporelles et les types de navires. Les auteurs de [31] ont combiné la convolution d'attention graphique (GAT) avec une structure de convolution causale étendue et ont conçu le modèle GAGW. Le réseau de convolution d'attention graphique est chargé d'extraire les informations d'interaction entre différents vaisseaux dans l'espace.

La majorité des études susmentionnées se concentrent principalement sur l'utilisation d'informations sur les trajectoires à faible profondeur. Ces études utilisent généralement la vitesse, la trajectoire et la position comme entrées de modèle. Cependant, cela ne suffit pas pour guider l'évitement d'un navire dans une situation complexe. L'acquisition de caractéristiques plus riches et plus profondes, ainsi que leur application judicieuse, sont cruciales pour guider l'évitement des navires et la planification globale des itinéraires. Par conséquent, les recherches actuelles sur la prévision de la trajectoire des navires accorderont davantage d'attention à l'exploration des caractéristiques abondantes et à la compréhension de la dynamique des environnements du monde réel.

2.2. Modèle Seq2Seq

Le modèle Seq2Seq a été largement appliqué dans le domaine de la traduction automatique [32], qui consiste en un encodeur et un décodeur, où l'encodeur intègre les informations d'entrée et génère un vecteur sémantique de haute dimension, tandis que le décodeur décode et affiche le résultat. Nous présentons principalement les recherches connexes sur les tâches de régression basées sur Seq2Seq, notamment la prédiction de puissance, la prédiction de ruissellement et la prévision de stocks.

En prévision de puissance, réf. [33] ont proposé un modèle Seq2Seq basé sur un LSTM qui prend en compte la corrélation inhérente aux données, capturant efficacement les relations séquentielles dans les séries temporelles. Pour résoudre le problème de la faible précision des prévisions de température à court terme, un modèle basé sur Seq2Seq a été proposé par [34]. Dans le domaine de la prévision du ruissellement, réf. [35] ont apporté des améliorations au Seq2Seq en remplaçant la structure RNN par une couche linéaire pour gérer les données historiques. De plus, l'introduction d'un mécanisme d'attention a conduit à une précision de prédiction plus élevée. Dans [36], TEN-Seq2Seq a été introduit pour gérer les données tabulaires et les profondeurs de puits, qui présentaient une meilleure robustesse que LSTM et FCNN. Les auteurs de [37] ont proposé une nouvelle méthode pour prédire un niveau de réservoir en utilisant le LSTM et la modélisation Seq2Seq basée sur le mécanisme d'attention. Les auteurs de [38] ont proposé une structure de prédiction du cours des actions basée sur les réseaux Seq2Seq.

Le modèle Seq2Seq a également fait des progrès significatifs dans le domaine de la température de surface de la mer (SST). Les auteurs de [39] ont appliqué le modèle Seq2Seq avec une attention à deux modules (TMA-Seq2Seq) pour la prédiction SST de séries chronologiques à long terme, obtenant des performances supérieures par rapport aux méthodes basées sur les données. Dans [40], un nouveau réseau Seq2Seq a été proposé pour réaliser la prédiction k-step-ahead basée sur les caractéristiques du fouillis marin. Les auteurs de [41] ont utilisé le modèle Seq2Seq pour fournir une prévision spatio-temporelle de la probabilité de présence de glace de mer, conduisant à une plus grande précision.

2.3. Personnalités des utilisateurs

Les personnalités des utilisateurs sont un produit du développement d'Internet, qui permet de découvrir les différences entre les individus au sein des groupes. Les auteurs de [42] ont proposé un modèle de personnalité d'utilisateur employé basé sur des réseaux de neurones, qui établit des personnalités en fonction des niveaux de compétence et de l'état mental des employés, permettant ainsi des recommandations d'emploi personnalisées pour les employés de l'entreprise. Les auteurs de [43] ont proposé une méthode de recommandations hybrides de services Web basées sur les personnalités des utilisateurs pour résoudre le problème du démarrage à froid pour les nouveaux utilisateurs, améliorant à la fois la précision et la qualité des recommandations.

Récemment, prédire le comportement futur sur la base des profils d'utilisateurs est devenu une direction populaire. Les auteurs de [44] ont transformé les caractéristiques de préférences émotionnelles des utilisateurs en informations d'attention et les ont combinées avec des modèles LSTM pour prédire les traits de personnalité des utilisateurs en ligne. Les auteurs de [45] ont proposé le modèle T-LSTM pour la prédiction de l'occupation des utilisateurs, surmontant les défis de performance prédictive et offrant une approche nouvelle et efficace pour une prédiction précise de l'occupation des utilisateurs. Les auteurs de [46] ont introduit une méthode pour prédire les récompenses impulsives chez les mineurs en utilisant des profils d'utilisateurs, facilitant des prévisions précises des comportements de récompense impulsifs chez les utilisateurs mineurs. Les auteurs de [47] ont appliqué la prédiction de personnalité dans le domaine des avertissements académiques destinés aux étudiants universitaires. Construire des personnalités d'étudiants pour explorer la relation entre les facteurs des étudiants et les performances académiques fournit des conseils solides aux enseignants et aux administrateurs pour ajuster les plans d'enseignement.

Dans ce travail, nous avons créé un profil pour chaque navire et introduit un nouveau modèle basé sur Seq2Seq, qui s'avère plus adapté en pratique à la détection de collision et à l'avertissement de risque.

3. Méthode proposée

Nous présentons la méthode en trois parties. Tout d'abord, nous fournissons des définitions et l'énoncé du problème. Nous fournissons ensuite un aperçu complet du traitement des données. Ensuite, nous décrivons le processus détaillé de construction du portrait du navire. Enfin, nous fournissons une description complète de notre modèle proposé VEPO-S2S, y compris le module de représentation de trajectoire de navire à plusieurs niveaux et le module de fusion et de décodage de fonctionnalités.

4. Définitions et énoncé du problème

L'objectif de VEPO-S2S est de prédire la trajectoire future d'un navire grâce à l'AIS données. Pour articuler plus clairement notre approche, nous proposons les définitions suivantes :

[Trajectoire du navire] Un point de trajectoire est défini comme un tuple $x_t = (\text{lont}, \text{latt}, \text{sogt}, \text{cogt}, \text{distt}, l, w, d, t, \alpha, \beta, \gamma)$ au temps t , dans lequel x_t est composé de la longitude lont , latitude latt , vitesse cogt , distance de navigation distt , longueur l , largeur w , tirant d'eau d , type t , emplacement de navigation sogt , préférence α , préférence de temps de voyage β et préférence de temps d'ancrage γ , respectivement. Une trajectoire de navire $X = (x_{t0}, x_{t1}, \dots, x_{tn})$ est définie comme une séquence chronologique, où $\{t_i, i = 0, 1, 2, \dots, n\}$ est un ensemble d'horodatages.

[Séquence de positions] La position du navire au temps t est définie comme un tuple $y_t = (\text{lont}, \text{latt})$, et la séquence de positions du navire au temps $(1, 2, \dots, t)$ est définie comme $Y = (y_1, y_2, \dots, y_t)$.

[Prédiction de trajectoire du navire] Étant donné une trajectoire observée $X = (x_1, x_2, \dots, x_t)$ à l'horodatage $(1, 2, 3, \dots, t)$, l'objectif est de prédire la trajectoire $Y = (y_{t+1}, y_{t+2}, \dots, y_{t+k})$ aux horodatages suivants $(t + 1, t + 2, \dots, t + k)$.

4.1. Prétraitement des

données Le prétraitement des données AIS est essentiel pour la formation de modèles d'apprentissage profond, en particulier pour les modèles qui nécessitent des informations sur la trajectoire et les caractéristiques des navires. Dans VEPO-S2S, nous avons sélectionné les données AIS des eaux côtières du sud-ouest et du sud-est des États-Unis à des fins de formation, de validation et de test. L'ensemble de données comprend des attributs statiques tels que l'identité du service mobile maritime (MMSI), la longueur et la largeur du navire. De plus, il englobe des informations dynamiques sur la navigation des navires telles que la longitude, la latitude, la vitesse et le cap. Les données AIS originales peuvent subir des conditions météorologiques défavorables pendant le processus de réception, entraînant des retards de transmission du signal et des erreurs de réception [48]. De plus, les performances des modèles d'apprentissage profond pourraient être affectées par la perte de données résultant de problèmes techniques et de maintenance des équipements. Par conséquent, nous avons effectué un prétraitement complet des données AIS avant la formation (voir Figure 2).




Figure 2. Le processus de prétraitement des données.

Le processus est illustré par les étapes suivantes : (1)

Trier et classer : Nous avons filtré les navires avec des informations complètes sur la longueur, la largeur, le tirant d'eau et le type, puis avons séparé les données de trajectoire de chaque navire en fonction de l'identité du service mobile maritime (MMSI).) numéro et les ont triés par ordre croissant d'horodatages.

(2) Débruitage : nous avons supprimé les points présentant des horodatages en double et une longitude et une latitude déraisonnables.

(3) Segment : Nous avons séparé la trajectoire en différents segments lorsque l'intervalle de temps entre deux points de trajectoire adjacents dépassait 60 min ou lorsque la distance entre trois points de trajectoire consécutifs était inférieure à 100 m.

(4) Interpoler : nous avons utilisé une interpolation par spline cubique pour garantir un intervalle de 10 minutes entre des points de trajectoire consécutifs.

(5) Calcul : Nous avons calculé le cap et la vitesse pour chaque point de trajectoire.

(6) Normaliser : nous avons normalisé la longitude, la latitude, la vitesse, le cap, la longueur, la largeur, et ébauche en utilisant la méthode de normalisation min-max, telle qu'exprimée dans l'équation (1)

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

où x est les données d'origine, x_{min} et x_{max} représentent respectivement la valeur minimale et maximale dans les données de trajectoire. x_{norm} est les données normalisées.

4.2. Construction de portraits de navires

Ce chapitre réalise la construction de portraits d'utilisateurs de navires basés sur les données AIS, incluant la mise en place d'un système de labellisation et la création de portraits de navires.

4.2.1. Construction du système d'étiquettes

Comme le montre la figure 3, nous avons établi un système d'étiquettes basé sur des attributs de niveau peu profond et des fonctionnalités de niveau profond. Les attributs des eaux peu profondes comprenaient une série d'attributs fondamentaux d'un navire (tels que la longueur, la largeur, le tirant d'eau et le type). Ces attributs ont un impact significatif sur les performances de manœuvre des navires. Selon les normes de manœuvrabilité des navires [17], la stabilité du cap et la capacité de virage sont des indicateurs essentiels de la manœuvrabilité et sont affectées par le coefficient de blocage du navire. Le coefficient de bloc est défini comme le déplacement d'un navire divisé par le produit de sa longueur, de sa largeur et de son tirant d'eau. De plus, différents types de navires ont des coefficients de bloc différents en raison des variations dans la forme de leurs coques sous-marines. Pour les navires de même déplacement, les navires avec des coefficients de bloc plus petits (comme les porte-conteneurs) présentent une meilleure stabilité de cap mais une capacité de virage plus faible que ceux avec des coefficients de bloc plus grands (comme les pétroliers). Ils nécessitent donc des chenaux de navigation plus larges pour réduire le risque de collision avec d'autres navires. De plus, ces attributs (longueur, largeur, tirant d'eau et type) jouent également un rôle crucial dans la sélection des fairways, des ports et des routes. Selon les manuels d'ingénierie côtière [49], la largeur du chenal est généralement de deux à cinq fois la largeur du navire. Les navires doivent tenir compte à la fois de la largeur et de la profondeur lors de la navigation pour garantir la sécurité et l'efficacité. Lors de la sélection des ports, selon le PIANC [50], les grands navires doivent choisir des ports dotés d'un poste d'amarrage et d'un espace de manœuvre suffisants pour garantir un accostage sûr. Lors de la planification de l'itinéraire, les navires doivent tenir compte de leur rayon de braquage et de leur tirant d'eau, en choisissant des itinéraires appropriés pour éviter le risque d'échouement ou de collision. Par conséquent, ces attributs sont cruciaux pour la faisabilité et doivent être soigneusement pris en compte pour garantir des prévisions plus précises des différents navires.

Pour modéliser plus efficacement les informations de trajectoire et les caractéristiques des navires à plusieurs niveaux, nous prenons en compte non seulement les attributs de niveau peu profond, mais également les caractéristiques de niveau profond. Les fonctionnalités de niveau profond sont définies comme la préférence d'emplacement de navigation, la préférence de temps de voyage et la préférence de temps d'ancrage. La préférence d'emplacement de navigation reflète le modèle de comportement du navire. Par exemple, les porte-conteneurs engagés dans le transport de ligne opèrent généralement sur des itinéraires fixes et dans les zones portuaires pour la manutention et le transport des marchandises [51]. Les itinéraires fixes et les horaires réguliers des transports maritimes garantissent la ponctualité logistique, réduisant ainsi les pertes et augmentant les revenus. Pendant ce temps, les chalutiers opèrent principalement dans des zones de pêche spécifiques [52], où leurs préférences de localisation de navigation sont influencées par la répartition des ressources halieutiques. Contrairement aux navires de ligne, les chalutiers ont un modèle de navigation plus flexible, ajustant souvent leurs lieux de pêche en fonction de la saison, pour se conformer aux contraintes réglementaires et augmenter leurs revenus. Cette préférence offre une vision plus complète

compréhension du comportement des navires et améliore la précision de la prévision de trajectoire. En ce qui concerne la préférence de temps de voyage et la préférence de temps d'ancrage, les porte-conteneurs ont tendance à minimiser le temps d'ancrage [53], en respectant strictement les horaires pour optimiser l'efficacité opérationnelle. Ce mode opérationnel garantit non seulement le transport des marchandises dans les délais, mais contribue également à réduire les coûts d'exploitation. En revanche, les préférences des chalutiers en matière de durée de voyage sont davantage influencées par les réglementations en matière de gestion des pêcheries et les demandes du marché. Ces informations temporelles contribuent à une compréhension plus approfondie des modèles de comportement des navires et permettent aux modèles de prévision de capturer avec précision les fluctuations des mouvements des navires au fil du temps.




Figure 3. Processus de modélisation et d'analyse au niveau de l'étiquette.

4.2.2. Construction de portraits de navires

Un portrait de navire se compose d'attributs de niveau peu profond et de caractéristiques de niveau profond. Concernant le traitement des attributs de niveau peu profond, nous utilisons l'approche suivante : tout d'abord, sélectionnez les données AIS avec des attributs non vides (tels que la longueur, la largeur, le tirant d'eau et le type). Ensuite, nous sélectionnons au hasard 100 points de données en fonction de l'identité du service mobile maritime (MMSI). Pour chaque attribut, considérez la valeur avec la fréquence la plus élevée comme attribut du navire actuel pour construire le profil peu profond du navire. Ce processus peut être exprimé dans la formule comme l'équation (2)

$$Y = \{y_i | y_i = \{x_{xx^*, 2, \dots, m}, D_k, X, x_j^*, P(x_j | \text{NSP}) \rightarrow \max\} \quad (2)$$

où Y représente les attributs de niveau peu profond de tous les navires, et chaque élément y_i désigne ceux du i -ème navire. D_k représente la collection de données AIS avec des attributs complets, X désigne l'ensemble d'attributs de toutes les données AIS et chaque élément x_j représente la valeur de fréquence la plus élevée pour D_k .

Après avoir obtenu les attributs de niveau peu profond, nous nous sommes concentrés sur le processus d'acquisition de fonctionnalités de niveau profond, qui incluent la préférence de lieu de navigation, la préférence de temps de voyage et la préférence de temps d'ancrage. Pour la préférence de localisation de navigation, en raison de la différence dans la quantité et la répartition des points de trajectoire des navires, nous avons utilisé HDBSCAN (clustering spatial hiérarchique basé sur la densité des applications avec bruit) [54] pour l'analyse de cluster. Les résultats du clustering sont présentés dans la figure 4. Différentes couleurs représentent différents clusters et les étiquettes noires désignent les centres de clustering. Pendant ce temps, pour capturer la préférence de temps de voyage et la préférence de temps d'ancrage, nous avons divisé une journée en 24 segments et attribué les points de trajectoire de chaque navire aux périodes correspondantes. La répartition des points de trajectoire dans chaque période reflète les préférences temporelles des navires. Après traitement, le profil de chaque navire peut être exprimé par l'équation (3)

$$S_{mmsi} = \{l_{mmsi}, w_{mmsi}, d_{mmsi}, t_{mmsi}, a_{mmsi}, \beta_{mmsi}, \gamma_{mmsi}\} \quad (3)$$

où l_{mmsi} , w_{mmsi} , d_{mmsi} et t_{mmsi} représentent respectivement les attributs de niveau peu profond de la longueur, de la largeur, du tirant d'eau et du type, a_{mmsi} représente la préférence de temps de voyage, β_{mmsi} signifie la préférence de temps d'ancrage et γ_{mmsi} est la préférence de lieu de navigation. Alors que a_{mmsi} et β_{mmsi} sont transformés en deux entités à 24 dimensions, γ_{mmsi} est converti en une entité à 114 dimensions. L'utilisation du portrait de navire est élaborée dans Article 4.3.1.




Figure 4. Le résultat du cluster de trajectoire. Différentes couleurs représentent différents clusters, et le noir les étiquettes indiquent les centres de cluster.

4.3. Modèle VEPO-S2S

Nous proposons un nouveau modèle de prédiction de trajectoire VEPO-S2S basé sur Seq2Seq modèle, et la structure est illustrée à la figure 5. Comme le montre la figure, VEPO-S2S se compose du module de représentation de trajectoire de navire à plusieurs niveaux (Multi-Rep) et de la fonctionnalité Module de fusion et de décodage (FFDM). Le Multi-Rep est ciblé pour acquérir une trajectoire informations et caractéristiques des navires à plusieurs niveaux, en les codant avec plusieurs encodeurs. Le FFDM est conçu pour sélectionner et fusionner les informations et caractéristiques ci-dessus à partir de Multi-Rep pour la prédiction.




Figure 5. La structure de VEPO-S2S comprend le module de représentation de trajectoire de navire à plusieurs niveaux (Multi-Rep) et le module de fusion et de décodage de fonctionnalités (FFDM). Le Multi-Rep est conçu pour obtenir des informations sur la trajectoire et les caractéristiques des navires à plusieurs niveaux, en appliquant des encodeurs distincts pour l'encodage. Le FFDM vise à sélectionner et intégrer les caractéristiques ci-dessus de Multi-Rep pour la prédiction.

4.3.1. Module de représentation de trajectoire de navire à plusieurs niveaux

Le module de représentation de trajectoire de navire à plusieurs niveaux est conçu pour acquérir des informations sur la trajectoire et les caractéristiques des navires à plusieurs niveaux et appliquer des encodeurs distincts pour le codage. Dans cette sous-section, nous introduisons le module de représentation de trajectoire de navire à plusieurs niveaux, qui comprend le composant d'acquisition de fonctionnalités et le composant de représentation de fonctionnalités. Pour le composant d'acquisition de caractéristiques, nous avons obtenu des informations sur la trajectoire et les caractéristiques du navire à plusieurs niveaux grâce au prétraitement des données, comme décrit dans la section 4.1, et à la construction du portrait du navire, comme décrit dans la section 4.2. Simultanément, en nous appuyant sur les modèles RNN et Seq2Seq, nous avons introduit le composant de représentation des fonctionnalités, composé de trois encodeurs distincts. Ces encodeurs sont conçus pour gérer séparément différentes caractéristiques d'entrée du composant d'acquisition de fonctionnalités. L'encodeur de trajectoire est chargé d'encoder les informations de trajectoire (y compris la longitude, la latitude, la vitesse, le cap et la distance de navigation). Ce processus peut être exprimé par l'équation suivante (4)

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

où X_{traj} représente les informations de trajectoire, y compris la longitude, la latitude, la vitesse, le cap et la distance de navigation normalisées pour dix points de trajectoire. $H = [h_1, h_2, \dots, h_{10}]$ signifie l'état caché à chaque pas de temps, h désigne l'état caché au pas de temps final et h^* représente l'état caché ultime. Semblable à l'encodeur de trajectoire, la tâche de l'encodeur d'étiquettes Enclabel est d'encoder la trajectoire d'or et de générer l'état codé H_y , où Y_{label} représente cinq points de trajectoire contenant la longitude et la latitude.

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

La tâche du Portrait Feature Encoder est d'intégrer les caractéristiques des navires à plusieurs niveaux. tics dans un vecteur de grande dimension. Premièrement, les valeurs numériques continues normalisées (y compris la longueur, la largeur et le dépouille) ont été concaténées et intégrées dans un vecteur sémantique à huit dimensions. Deuxièmement, le type de navire discret a été transformé en valeur continue pour l'entrée du modèle et intégré individuellement dans un autre vecteur sémantique. Troisièmement, nous avons codé deux fonctionnalités de niveau profond en 24 dimensions pour capturer la préférence de temps de voyage et la préférence de temps d'ancrage (comme mentionné dans la section 4.2.2), tandis que la préférence de lieu de navigation a été codée séparément. Enfin, ils ont été concaténés pour former un vecteur de caractéristiques à sept dimensions, qui a été entré dans le Portrait Feature Encoder pour le codage. Ce processus peut être exprimé par l'équation suivante (6)

$$\begin{aligned} sp &= \text{concat}(l, w, d) \quad sp = \\ \text{embedsp}(sp) \quad \text{type} &= \\ \text{embedtype}(\text{type}) \quad \text{tim} &= \\ \text{concat}(\alpha, \beta) \quad \text{tim} &= \\ \text{embedtim}(\text{tim}) \quad \gamma &= \\ \text{embedy}(\gamma) \quad \text{por} &= \\ \text{concat}(\text{Encpor}(sp, \text{taper}, \text{Tim}, \gamma)) & \end{aligned} \quad (6)$$

où por représente la fonction portrait, et embedsp , embedtype , embedtim et $\text{embed}\alpha$ sont les couches d'intégration. Encpor est l'encodeur de fonctionnalités de portrait. l , w et d représentent respectivement la longueur, la largeur et le tirant d'eau, t est le type, α représente la préférence de temps de voyage,

β représente la préférence de temps d'ancrage et γ est la préférence d'emplacement de navigation (comme mentionné dans l'équation (3)).

4.3.2. Module de fusion et de décodage de fonctionnalités

Malgré l'intégration des informations sur la trajectoire et des caractéristiques des navires dans le modèle, les modèles Seq2Seq de base ont encore du mal à les discerner et à les exploiter efficacement. Par conséquent, le module de fusion et de décodage de caractéristiques a été conçu pour sélectionner et intégrer les informations de trajectoire avec les caractéristiques des navires à plusieurs niveaux, en appliquant des mécanismes a priori et a posteriori dans le composant de sélection de portrait, un composant de fusion de caractéristiques et un décodeur multi-têtes. Composant. L'objectif de la composante de sélection de portraits est d'identifier et de sélectionner les caractéristiques des navires à plusieurs niveaux appropriées pour la prédiction ; par conséquent, nous utilisons ensemble une distribution a priori et une distribution postérieure dans la sélection des caractéristiques du vaisseau, et le cadre est illustré à la figure 6. La distribution a priori sélectionne les caractéristiques en fonction de la similarité entre le vecteur h de l'encodeur de trajectoire et le vecteur portrait. por , qui permet de filtrer les caractéristiques les plus pertinentes dès les premiers stades du modèle, réduisant ainsi la charge de calcul. Ce processus peut être exprimé par l'équation (7)

$$Z_{prior}(por = por_i | h) = \sum_{j=1}^7 \frac{\exp(por_i \cdot h_j)}{\exp(por_i \cdot h_j)} \quad (7)$$

où por_i ($por_1, por_2, \dots, por_7$), est le produit scalaire, h est le vecteur de codage de trajectoire et por est le vecteur portrait. Plus précisément, le modèle attribue des poids plus élevés aux vecteurs présentant une plus grande similarité en comparant les résultats du produit scalaire de différentes caractéristiques, réduisant ainsi l'interférence des informations redondantes et augmentant l'efficacité du calcul.




Figure 6. Le composant de sélection de portrait comprend une distribution préalable et une distribution postérieure. La distribution antérieure exprime le vecteur de codage de trajectoire h et la caractéristique du portrait por , et la distribution postérieure intègre l'étiquette y pour améliorer la précision de la sélection. Pendant ce temps, le KLD est conçu pour combler l'écart entre la distribution antérieure et la distribution postérieure, permettant à la distribution antérieure de bénéficier de la distribution postérieure et de générer des résultats plus précis.

Cependant, se fier uniquement à la distribution a priori ne peut pas permettre d'obtenir des résultats précis, car elle repose généralement sur des hypothèses ou des données historiques qui ne reflètent pas pleinement la situation réelle ; il est donc impossible de sélectionner les caractéristiques appropriées pour guider la génération. En revanche, les caractéristiques utilisées dans l'étiquette y peuvent être obtenues par distribution a posteriori. Par conséquent, la distribution a posteriori, obtenue en combinant la trajectoire

le vecteur h et l'étiquette y , peuvent guider plus efficacement la sélection du profil, qui peut être exprimé comme

$$Z_{\text{post}}(\text{por} = \text{pori} | h, y) = \sum_{i=1}^7 \frac{\exp(\text{pori} \cdot \text{MLP}([h; y]))}{\exp(\text{pori} \cdot \text{MLP}([h; y]))} \tag{8}$$

où MLP est une couche linéaire, $\cdot$ est le produit scalaire et $;$ représente l'épissage vectoriel. Simultanément, il existe un écart significatif entre la distribution a priori et la distribution a posteriori. Pour résoudre ce problème, la perte de divergence Kullback-Leibler (KLD) est utilisée pour contraindre leur proximité. Il peut corriger efficacement les erreurs dans la distribution antérieure et guider la sélection du profil au profit du modèle. La stabilité de la divergence KLD réside dans ses propriétés mathématiques, assurant convergence et fiabilité lors de l'entraînement. En minimisant la perte KLD, le système peut trouver un équilibre approprié entre les distributions antérieure et postérieure. La formule de la divergence KLD s'exprime comme suit :

$$DKL(PQ) = \sum_{i=1}^n P(i) \log \frac{P(i)}{Q(i)} \tag{9}$$

où P représente la distribution a posteriori, qui comprend les caractéristiques requises sous la direction d'étiquettes réelles.

En général, une approche simple pour exploiter les caractéristiques sélectionnées pour la génération de résultats consiste à ajouter directement ces caractéristiques à l'entrée de l'encodeur. Cependant, cette approche ne donne généralement pas de résultats satisfaisants en raison du manque de flexibilité dans le contrôle du degré d'implication des caractéristiques introduit. Par conséquent, nous introduisons le composant Feature Fusion pour optimiser l'utilisation des caractéristiques. Au lieu de connecter directement ces caractéristiques, nous avons utilisé une manière plus flexible de les intégrer. Ici, nous avons appliqué un LSTM pour fusionner la distribution a priori et la trajectoire historique H , et les résultats du LSTM ont pris en compte la continuité et la corrélation entre les caractéristiques au fil du temps. De plus, Prior servait d'état caché initial du LSTM et la représentation de trajectoire H obtenue par l'encodeur de trajectoire était utilisée comme entrée à chaque étape. Enfin, nous avons obtenu le vecteur sémantique fusionné c et le processus peut être exprimé par l'équation suivante (10)

$$c_t^k = \text{LSTM}(\text{avant}, H) \tag{dix}$$

Pour réguler l'implication des caractéristiques des navires à plusieurs niveaux dans la prédiction, nous avons introduit le composant de décodage multi-têtes ; le diagramme-cadre est représenté à la figure 7. Ce composant comprend deux blocs GRU et une unité de fusion qui synthétise efficacement les états cachés générés par les deux blocs GRU pour prédire les trajectoires futures.

La conception est formulée pour ajuster la pondération entre les informations sur la trajectoire et les caractéristiques du navire au cours du processus de prévision. La région orange est un module GRU standard qui reçoit les informations de trajectoire h . De plus, il prend la valeur de prédiction précédente $y - 1$ comme entrée, produisant son état caché T_i . Un autre GRU est dédié à l'ajout de la distribution a priori por dans les prédictions ; il prend également le vecteur sémantique fusionné t , les informations de trajectoire h^n et la valeur de prédiction précédente $y - 1$ comme entrées, générant p et T sont fusionnés via la porte de fusion pour

la représentation des caractéristiques T_i . En fin de compte, T produit la trajectoire finale. Ce processus peut être exprimé par l'équation (11) :

$$\begin{aligned} \tau_{je}^n &= \text{GRU}_n(y - 1, h) \\ \text{inpp} &= \text{concat}(y - 1, c_t^k, \text{avant}) \\ \tau_{je}^p &= \text{GRU}_p(\text{inpp}, h) \\ O_t &= \sigma(W_z [\tanh(wy \cdot T_n); \tanh(Wk \cdot T_p)]) \\ T_i &= O_t \cdot T^n + (1 - O_t) \cdot T_p \end{aligned} \tag{11}$$

où $i \in \{11, 12, \dots, 15\}$ et W_z , W_y et W_k correspondent à des matrices de poids avec des coefficients différents. σ et $\tanh$ sont respectivement la fonction d'activation sigmoïde et la fonction d'activation $\tanh$.




Figure 7. Le composant décodeur multi-têtes se compose de deux blocs GRU et d'une unité de fusion. Il peut ajuster de manière flexible la pondération entre les informations de trajectoire et les caractéristiques du navire pendant le processus de prévision.

4.3.3. Fonction de perte

Le VEPO adopte l'erreur quadratique moyenne (RMSE) et la divergence Kullback – Leibler (KLD) (comme mentionné dans l'équation (9)) comme fonction de perte. L'objectif de ce travail est d'utiliser les m premiers points notés $X_k = (x_1^k, \dots, x_m^k)$ pour prédire le n suivant trace, où m et n sont les hyperparamètres. La séquence de prédiction et la cible $= (y_{m+1}^k, y_{m+2}^k, \dots, y_{m+n}^k)$ sont représentées par $Y_k = (y_{m+1}^k, y_{m+2}^k, \dots, y_{m+n}^k)$ et $Y_k = (y_{m+1}^k, y_{m+2}^k, \dots, y_{m+n}^k)$ respectivement. L'objectif principal est de minimiser la fonction de perte pendant l'entraînement, garantissant une plus grande précision dans la prédiction des n derniers points de trajectoire. L'expression pour la fonction de perte est illustré dans l'équation suivante (12).

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

5. Expériences

Pour valider l'efficacité du modèle VEPO, nous avons mené une série d'expériences quantitatives et qualitatives. Plus précisément, nous introduisons d'abord les paramètres d'expérimentation, y compris les paramètres d'hyperparamètres, les environnements expérimentaux, les ensembles de données, les modèles de base et les métriques d'évaluation. Par la suite, nous présentons les résultats de comparaison quantitative de notre méthode proposée et d'autres modèles de base. Suite à cela, nous décrivons les expériences d'ablation menées pour justifier l'efficacité des différents composants du modèle. Enfin, nous décrivons les résultats de prédiction de VEPO-S2S grâce à une analyse qualitative.

5.1. Paramètres d'expérience

5.1.1. Base de données

Nous avons adopté les données AIS (<https://marinecadastre.gov/accessais/>) (consulté le 1er juin 2024) depuis les eaux côtières du sud-est et du sud-ouest des États-Unis pour la formation, la validation et les tests [13]. Comme le montre le tableau 1, il existe 68 types de navires et 28 645 navires dans cet ensemble de données. Dans le même temps, en raison de la particularité de la construction du portrait (comme mentionné dans la section 4.2.2), nous avons sélectionné les attributs du navire (y compris la longueur, la largeur, le tirant d'eau et le type). Après traitement, nous avons obtenu 45 types avec un total de 6194

navires. La répartition détaillée des types de navires est présentée à la figure 8. Dans notre ensemble de données, le nombre maximum de types de navires était de 45, comprenant des navires à passagers, des bateaux de plaisance, voiliers, etc. La répartition des types de navires était inégale et ils étaient principalement classés en cinq catégories : les navires à passagers, les bateaux de plaisance, les voiliers, les remorqueurs et les bateaux de pêche. Les navires à passagers et les bateaux de plaisance représentaient ensemble plus de 23 % du total. Les navires restants, constitués principalement de cargos, de porte-conteneurs et de pétroliers, collectivement constituent 21% de l'ensemble des données. Pour améliorer la richesse et l'exhaustivité des données, nous avons utilisé une approche de fenêtre glissante, divisant les données normalisées en groupes de 15 points de trajectoire avec un pas glissant de 1 (voir Figure 9). Par la suite, chaque navire a été alloués aux ensembles de formation, de validation et de test dans un rapport de 8:1:1. Cette approche a augmenté la diversité des données et veillé à ce que chaque navire reçoive une validation suffisante.

Tableau 1. Le détail de notre ensemble de données.

Base de données	Région	Nombre de points de suivi	Nombre de types	Nombre de navires
Total	Côte des États-Unis	144 445 580 4	68	28 645
	Notre côte des États-Unis	930 061	45	6194




Figure 8. Répartition des types de navires dans notre ensemble de données traitées.




Figure 9. Un exemple de division d'un ensemble de données à l'aide de la méthode de la fenêtre glissante et des points rouges représentent des points de trajectoire.

5.1.2. Paramètres des hyperparamètres et environnement expérimental

Nous avons utilisé dix points de trajectoire comme entrées pour prédire les cinq derniers points de trajectoire, et ces deux hyperparamètres peuvent être ajustés de manière flexible pour s'adapter à différentes tâches. Pendant ce temps, les époques ont été fixées à 40 pour la formation du modèle, et les meilleures performances de valorisation a été sauvé. Le taux d'apprentissage était de 0,001 avec une diminution de poids de 0,0, l'optimiseur a été défini à Adam, et la taille du lot a été fixée à 128. De plus, les tailles cachées dans le GRU étaient

défini sur 64 et le numéro de couche cachée était 2. Dans les hyperparamètres ci-dessus, nous avons sélectionné deux cas typiques pour la visualisation, à savoir le nombre de couches et les tailles cachées, dont les détails sont présentés dans les figures 10 et 11. Les expériences étaient tous basés sur Python 3.8 utilisant le framework PyTorch. Nous avons formé le modèle à l'aide du système d'exploitation Ubuntu et de GTX 3090Ti sur le serveur à des fins d'expérimentation.




Figure 10. L'influence des différentes couches GRU sur la prédiction du modèle VEPO-S2S, selon le RMSE. L'axe X représente le nombre de couches et l'axe Y représente la valeur de perte RMSE.




Figure 11. L'influence des différentes tailles cachées sur la prédiction du modèle VEPO-S2S, selon le RMSE. L'axe X représente le nombre de tailles cachées et l'axe Y représente la valeur de perte RMSE.

5.1.3. Lignes de base

Pour mieux évaluer les performances de VEPO-S2S, nous l'avons comparé à plusieurs modèles de base utilisant le même ensemble de données. Contrairement à Seq2Seq, les réseaux neuronaux récurrents se limitent à prédire plusieurs points de suivi consécutifs. Dans nos expériences, nous avons prédit en continu cinq points de trajectoire à l'aide d'un RNN, obtenu grâce à la méthode de la fenêtre glissante. Les lignes de base étaient les suivantes :

- (1) Kalman : un modèle d'estimation optimal linéaire ;
- (2) VAR : un modèle statistique pour la prédiction de séries chronologiques multivariées ;
- (3) ARIMA : un modèle de prévision statistique de séries chronologiques ;
- (4) LSTM : un type de réseau neuronal récurrent, composé de deux couches ;
- (5) BiLSTM : De la même manière que le LSTM, le BiLSTM est composé de deux LSTM bidirectionnels couches ;
- (6) GRU : similaire à un LSTM ;
- (7) BiGRU : similaire à un GRU mais avec deux couches GRU bidirectionnelles ;
- (8) LSTM – LSTM : un modèle Seq2Seq avec un LSTM à deux couches comme encodeur et décodeur ;

(9) BiLSTM – LSTM : un modèle Seq2Seq avec un BiLSTM à deux couches comme codeur et un LSTM à quatre couches comme décodeur ; (10) GRU–GRU : similaire à un LSTM–LSTM ; (11) BiGRU–GRU : similaire à un BiLSTM–LSTM ; (12) Transformer : un modèle Seq2Seq basé sur un mécanisme d'attention ; (13) METO-S2S : une méthode de prédiction de trajectoire de navire basée sur S2S avec un encodeur multi-sémantique et un décodeur orienté type.

5.1.4. Paramètres d'évaluation

Pour évaluer les performances de prédiction du modèle proposé, nous avons utilisé quatre mesures d'évaluation, dont l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE), l'erreur de déplacement moyenne (ADE) et l'erreur de déplacement finale (FDE). Le RMSE se concentre sur la mesure de la stabilité du résultat, tandis que le MAE évalue la capacité de prédiction d'un modèle. L'ADE représente l'erreur de distance euclidienne moyenne entre la position prévue et la position réelle. De plus, le FDE se concentre sur l'exactitude finale des prédictions.

$$\begin{aligned}
 \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{nk=1}^n (\text{oui} - \text{oui})^2} \\
 \text{MAE} &= \frac{1}{n} \sum_{nk=1}^n y_k - y_{k1} \\
 \text{AED} &= \frac{1}{n} \sum_{nk=1}^n y_k - y_{k2} \\
 \text{FDE} &= y_f^{\text{inal}} - y_f^{\text{inal}2}
 \end{aligned} \tag{13}$$

où y_k et y_k représentent la position réelle et la position prédite, n est le nombre total de points de trace prédits, et $\cdot$ et $\cdot^2$ désignent respectivement une norme et la distance euclidienne. y_f^{inal} et y_f^{inal} représentent respectivement la position finale de la trajectoire réelle et de la trajectoire prédite. Il convient de noter que plus l'indice d'évaluation est faible, meilleure est la capacité de généralisation du modèle.

5.2. Comparaison des performances du

modèle 5.2.1. Résultats de la

comparaison Grâce à des comparaisons avec les lignes de base utilisant les mesures d'évaluation du RMSE, du MAE et de l'ADE, notre modèle a démontré une forte robustesse, comme le montrent les tableaux 2 à 4. Les modèles LSTM, BiLSTM, GRU et BiGRU utilisent une approche à fenêtre glissante pour la prédiction de plusieurs points, contrairement aux six autres modèles Seq2Seq. Notre modèle a surpassé les lignes de base entre le troisième et le cinquième point de trajectoire. Cependant, le GRU a obtenu de meilleurs résultats au MAE dans le tableau 3 et à l'ADE dans le tableau 4, en ce qui concerne le premier et le deuxième points. Cela est principalement dû au fait que le GRU présente un avantage structurel dans la prédiction des séquences à court terme en raison de sa simplicité. Cependant, le VEPO-S2S connaît une légère diminution lors du traitement des prévisions à court terme, car le portrait du navire peut ne pas être facilement discernable. Lorsque la longueur de prédiction augmente, notre modèle fonctionne mieux que les modèles de base, selon le RMSE, le MAE et l'ADE.

Simultanément, considérant que la prédiction de trajectoire est également un problème de prévision de séries chronologiques, nous avons comparé VEPO-S2S avec plusieurs modèles de prévision de séries chronologiques, notamment ARIMA, Kalman Filter et VAR. Comme le montrent les tableaux 2 à 4, notre modèle était supérieur aux autres ; les modèles de prévision à trois séries chronologiques ont donné de bons résultats en matière de prévision à court terme, mais leur précision a rapidement diminué à mesure que l'horizon de prévision s'élargissait. Plus précisément, le modèle VAR est devenu inefficace après le troisième pas de temps car il ne parvenait pas à capturer les relations non linéaires complexes à long terme. Différent des modèles de séries chronologiques qui utilisent uniquement des séquences de positions, le VEPO-S2S bénéficie d'informations préalables supplémentaires, telles que la longueur

et la largeur, ainsi que sa puissante capacité à construire des corrélations spatio-temporelles à partir de points de trajectoire historiques, ce qui le rend plus avantageux dans les tâches de prévision.

Tableau 2. Résultats de comparaison de VEPO-S2S avec différentes références sous la métrique d'évaluation RMSE. Ici, 10->5 représente la valeur RMSE des 5 dernières trajectoires prédites par 10 trajectoires historiques.

Nom du modèle	10 -> 1	10->2	10->3	10->4	10->5
Kalman	$2,42 \times 10^{-4}$	$3,00 \times 10^{-4}$	$4,22 \times 10^{-4}$	$2,80 \times 10^{-4}$	$5,51 \times 10^{-4}$
VAR	$0,98 \times 10^{-4}$	$50,43 \times 10^{-4}$	-	-	-
ARIMA	$3,42 \times 10^{-4}$	$5,30 \times 10^{-4}$	$7,21 \times 10^{-4}$	$9,15 \times 10^{-4}$	$1,16 \times 10^{-4}$
LSTM	$0,88 \times 10^{-4}$	$3,46 \times 10^{-4}$	$2,65 \times 10^{-4}$	$3,51 \times 10^{-4}$	$4,41 \times 10^{-4}$
BiLSTM	$2,64 \times 10^{-4}$	$1,58 \times 10^{-4}$	$2,41 \times 10^{-4}$	$3,32 \times 10^{-4}$	$3,24 \times 10^{-4}$
GRU	$0,86 \times 10^{-4}$	$3,96 \times 10^{-4}$	$4,71 \times 10^{-4}$	$1,94 \times 10^{-4}$	$2,76 \times 10^{-4}$
BiGRU	$3,16 \times 10^{-4}$	$3,64 \times 10^{-4}$	$2,21 \times 10^{-4}$	$3,07 \times 10^{-4}$	$3,99 \times 10^{-4}$
LSTM-LSTM	$1,22 \times 10^{-4}$	$1,69 \times 10^{-4}$	$2,49 \times 10^{-4}$	$3,36 \times 10^{-4}$	$2,21 \times 10^{-4}$
BiLSTM-LSTM	$1,44 \times 10^{-4}$	$3,14 \times 10^{-4}$	$4,11 \times 10^{-4}$	$1,74 \times 10^{-4}$	$2,35 \times 10^{-4}$
GRU-GRU	$0,98 \times 10^{-4}$	$3,07 \times 10^{-4}$	$2,03 \times 10^{-4}$	$2,28 \times 10^{-4}$	$2,73 \times 10^{-4}$
BiGRU-GRU	$1,34 \times 10^{-4}$	$1,11 \times 10^{-4}$	$1,71 \times 10^{-4}$	$2,40 \times 10^{-4}$	$5,12 \times 10^{-4}$
Transformateur	$1,31 \times 10^{-4}$	$2,02 \times 10^{-4}$	$0,74 \times 10^{-4}$	-	$3,86 \times 10^{-4}$
MÉTO-S2S	-	-	-	-	$3,35 \times 10^{-4}$
Les notes	-	-	-	-	$3,17 \times 10^{-4}$

Tableau 3. Résultats de comparaison de VEPO-S2S avec différentes références sous la métrique d'évaluation MAE. Ici, 10->5 signifie prédit à travers 10 trajectoires historiques.

Nom du modèle	10 -> 1	10->2	10->3	10->4	10->5
Kalman	$1,73 \times 10^{-4}$	$2,34 \times 10^{-4}$	$3,27 \times 10^{-4}$	$4,24 \times 10^{-4}$	$5,16 \times 10^{-4}$
VAR	$0,87 \times 10^{-4}$	$2,12 \times 10^{-4}$	$28,6 \times 10^{-4}$	-	-
ARIMA	$2,69 \times 10^{-4}$	$3,99 \times 10^{-4}$	$5,33 \times 10^{-4}$	$6,69 \times 10^{-4}$	$1,18 \times 10^{-4}$
LSTM	$0,43 \times 10^{-4}$	$0,77 \times 10^{-4}$	$1,66 \times 10^{-4}$	$1,87 \times 10^{-4}$	$2,21 \times 10^{-4}$
BiLSTM	$1,50 \times 10^{-4}$	$1,52 \times 10^{-4}$	$2,35 \times 10^{-4}$	$1,01 \times 10^{-4}$	$1,42 \times 10^{-4}$
GRU	$0,36 \times 10^{-4}$	$0,66 \times 10^{-4}$	$1,84 \times 10^{-4}$	$2,15 \times 10^{-4}$	$1,87 \times 10^{-4}$
BiGRU	$1,53 \times 10^{-4}$	$1,65 \times 10^{-4}$	$1,34 \times 10^{-4}$	$1,72 \times 10^{-4}$	$1,56 \times 10^{-4}$
LSTM-LSTM	$0,70 \times 10^{-4}$	$1,00 \times 10^{-4}$	$1,94 \times 10^{-4}$	$1,10 \times 10^{-4}$	$2,13 \times 10^{-4}$
BiLSTM-LSTM	$0,88 \times 10^{-4}$	$1,20 \times 10^{-4}$	$1,46 \times 10^{-4}$	$1,50 \times 10^{-4}$	$1,92 \times 10^{-4}$
GRU-GRU	$0,51 \times 10^{-4}$	$0,78 \times 10^{-4}$	$1,16 \times 10^{-4}$	$1,42 \times 10^{-4}$	$1,85 \times 10^{-4}$
BiGRU-GRU	$0,74 \times 10^{-4}$	$1,10 \times 10^{-4}$	$1,53 \times 10^{-4}$	$1,70 \times 10^{-4}$	$0,99 \times 10^{-4}$
Transformateur	$1,43 \times 10^{-4}$	$0,95 \times 10^{-4}$	$1,28 \times 10^{-4}$	-	$1,72 \times 10^{-4}$
MÉTO-S2S	10^{-4}	$0,53 \times 10^{-4}$	-	-	$1,94 \times 10^{-4}$
Les notes	-	$0,74 \times 10^{-4}$	-	-	$1,60 \times 10^{-4}$

Tableau 4. Résultats de comparaison de VEPO-S2S avec différentes références sous la métrique d'évaluation ADE. Ici, 10->5 signifie prédit à travers 10 trajectoires historiques.

Nom du modèle	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	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 × 10−4	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	
Transformateur		1,50 × 10−4	1,83 × 10−4	2,25 × 10−4	2,73 × 10−4
MÉTO-S2S		2,30 × 10−4	2,41 × 10−4	2,68 × 10−4	3,07 × 10−4
Les notes		1,17 × 10−4	1,52 × 10−4	2,01 × 10−4	2,52 × 10−4

5.2.2. Exploration de la structure Seq2Seq de VEPO-S2S

Nous avons mené plusieurs expériences sur la structure du codeur et du décodeur dans VEPO-S2S pour obtenir des performances optimales, y compris un VEPO-BiGRU-GRU, un VEPO-LSTM- LSTM, un VEPO-BiLSTM-LSTM et un VEPO-GRU-GRU. Comme le montre le tableau 5, les meilleurs **Le résultat a été obtenu avec le VEPO-GRU-GRU. Ainsi, dans les expériences ultérieures,** nous avons utilisé le VEPO-S2S avec une structure GRU-GRU pour des expérimentations plus approfondies.

Tableau 5. Résultats d'exploration sur différentes structures Seq2Seq.

Encodeur de nom de modèle		Décodeur 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. Analyse plus approfondie

Contrairement à l'évaluation des tâches de prédiction de trajectoire continue, nous avons effectué une évaluation de points individuels à l'aide du RMSE, du MAE et du FDE. Comme nous pouvons le voir dans les tableaux 6 à 8, les erreurs de prédiction de tous les modèles ont montré une augmentation notable du premier au cinquième point de prédiction. Ceci est attribué à une réduction significative des informations disponibles pour chaque prédiction, passant de la première à la dernière prédiction. Ligne de base RNN Les modèles utilisent une approche de fenêtre glissante pour la prédiction et accumulent progressivement des inexactitudes à chaque prédiction. À l'inverse, les modèles de base Seq2Seq ont la capacité pour prédire simultanément plusieurs points, ce qui peut réduire la tendance à l'escalade des erreurs par rapport aux modèles de base RNN. De plus, les modèles de séries chronologiques s'appuient sur sur les relations linéaires entre plusieurs séries temporelles ; cependant, dans les prévisions à long terme tâches, les caractéristiques non linéaires deviennent plus importantes, entraînant une augmentation rapide des imprécisions au fil du temps. De plus, notre modèle surpasse presque toutes les lignes de base. Nous observons également un performances similaires entre METO-S2S et VEPO-S2S aux quatrième et cinquième points de Figure 6, indiquant que VEPO et METO sont d'excellents modèles pour les séquences longues tâches de prédiction.

Tableau 6. Les résultats de l'analyse quantitative de chaque point de trajectoire sous l'indice d'évaluation RMSE.

Nom du modèle	D'abord	Deuxième	Troisième	Quatrième	Cinquième
Kalman	$2,42 \times 10^{-4}$	$3,27 \times 10^{-4}$	$5,81 \times 10^{-4}$	$3,74 \times 10^{-4}$	$8,15 \times 10^{-4}$
VAR	$0,98 \times 10^{-4}$	$86,61 \times 10^{-4}$		-	-
ARIMA	$3,42 \times 10^{-4}$	$6,63 \times 10^{-4}$	$9,93 \times 10^{-4}$	$13,28 \times 10^{-4}$	$16,72 \times 10^{-4}$
LSTM	$0,88 \times 10^{-4}$	$2,10 \times 10^{-4}$	$3,63 \times 10^{-4}$	$5,43 \times 10^{-4}$	$7,60 \times 10^{-4}$
BiLSTM	$2,64 \times 10^{-4}$	$2,65 \times 10^{-4}$	$4,77 \times 10^{-4}$	$6,39 \times 10^{-4}$	$8,38 \times 10^{-4}$
GRU	$0,86 \times 10^{-4}$	$2,06 \times 10^{-4}$	$3,52 \times 10^{-4}$	$5,16 \times 10^{-4}$	$6,96 \times 10^{-4}$
BiGRU	$3,16 \times 10^{-4}$	$2,42 \times 10^{-4}$	$5,24 \times 10^{-4}$	$6,44 \times 10^{-4}$	$6,83 \times 10^{-4}$
LSTM-LSTM	$1,22 \times 10^{-4}$	$2,46 \times 10^{-4}$	$3,90 \times 10^{-4}$	$5,50 \times 10^{-4}$	$7,20 \times 10^{-4}$
BiLSTM-LSTM	$1,44 \times 10^{-4}$	$2,77 \times 10^{-4}$	$4,30 \times 10^{-4}$	$5,95 \times 10^{-4}$	$7,68 \times 10^{-4}$
GRU-GRU	$0,98 \times 10^{-4}$	$2,18 \times 10^{-4}$	$3,59 \times 10^{-4}$	$5,14 \times 10^{-4}$	$6,84 \times 10^{-4}$
BiGRU-GRU	$1,34 \times 10^{-4}$	$2,82 \times 10^{-4}$	$4,45 \times 10^{-4}$	$6,17 \times 10^{-4}$	$7,96 \times 10^{-4}$
Transformateur	$0,74 \times 10^{-4}$	$2,08 \times 10^{-4}$	$3,24 \times 10^{-4}$	$4,59 \times 10^{-4}$	$6,07 \times 10^{-4}$
MÉTO-S2S		$2,03 \times 10^{-4}$	$2,71 \times 10^{-4}$	$3,76 \times 10^{-4}$	$5,23 \times 10^{-4}$
Les notes		$1,44 \times 10^{-4}$	$2,47 \times 10^{-4}$	$3,76 \times 10^{-4}$	$5,22 \times 10^{-4}$

Tableau 7. Les résultats de l'analyse quantitative de chaque point de trajectoire sous l'indice d'évaluation MAE.

Nom du modèle	D'abord	Deuxième	Troisième	Quatrième	Cinquième
Kalman	$1,73 \times 10^{-4}$	$2,94 \times 10^{-4}$	$5,13 \times 10^{-4}$	$3,38 \times 10^{-4}$	$7,13 \times 10^{-4}$
VAR	$0,87 \times 10^{-4}$	$81,62 \times 10^{-4}$		-	-
ARIMA	$2,69 \times 10^{-4}$	$5,26 \times 10^{-4}$	$7,99 \times 10^{-4}$	$10,77 \times 10^{-4}$	$13,62 \times 10^{-4}$
LSTM	$0,43 \times 10^{-4}$	$1,11 \times 10^{-4}$	$2,01 \times 10^{-4}$	$3,11 \times 10^{-4}$	$4,40 \times 10^{-4}$
BiLSTM	$1,50 \times 10^{-4}$	$1,52 \times 10^{-4}$	$2,60 \times 10^{-4}$	$3,79 \times 10^{-4}$	$4,94 \times 10^{-4}$
GRU	$0,36 \times 10^{-4}$	$0,95 \times 10^{-4}$	$1,72 \times 10^{-4}$	$2,63 \times 10^{-4}$	$3,67 \times 10^{-4}$
BiGRU	$1,53 \times 10^{-4}$	$1,77 \times 10^{-4}$	$2,53 \times 10^{-4}$	$3,09 \times 10^{-4}$	$3,26 \times 10^{-4}$
LSTM-LSTM	$0,70 \times 10^{-4}$	$1,30 \times 10^{-4}$	$2,02 \times 10^{-4}$	$2,85 \times 10^{-4}$	$3,77 \times 10^{-4}$
BiLSTM-LSTM	$0,51 \times 10^{-4}$	$1,53 \times 10^{-4}$	$2,28 \times 10^{-4}$	$3,08 \times 10^{-4}$	$3,98 \times 10^{-4}$
GRU-GRU	$0,51 \times 10^{-4}$	$1,04 \times 10^{-4}$	$3,59 \times 10^{-4}$	$5,14 \times 10^{-4}$	$6,84 \times 10^{-4}$
BiGRU-GRU	$1,34 \times 10^{-4}$	$2,82 \times 10^{-4}$	$4,45 \times 10^{-4}$	$6,17 \times 10^{-4}$	$7,96 \times 10^{-4}$
Transformateur	$2,02 \times 10^{-4}$	$1,09 \times 10^{-4}$	$1,58 \times 10^{-4}$	$2,20 \times 10^{-4}$	$2,93 \times 10^{-4}$
MÉTO-S2S		$2,03 \times 10^{-4}$	$2,21 \times 10^{-4}$	$2,71 \times 10^{-4}$	$2,92 \times 10^{-4}$
Les notes		$0,96 \times 10^{-4}$	$1,48 \times 10^{-4}$	$2,13 \times 10^{-4}$	$2,88 \times 10^{-4}$

Tableau 8. Les résultats de l'analyse quantitative de chaque point de trajectoire sous l'indice d'évaluation FDE.

Nom du modèle	D'abord	Deuxième	Troisième	Quatrième	Cinquième
Kalman	$3,42 \times 10^{-4}$	$4,62 \times 10^{-4}$	$8,22 \times 10^{-4}$	$11,52 \times 10^{-4}$	$14,29 \times 10^{-4}$
VAR	$1,38 \times 10^{-4}$	$5,30 \times 10^{-4}$	$122,49 \times 10^{-4}$	-	-
ARIMA	$4,83 \times 10^{-4}$	$9,38 \times 10^{-4}$	$14,05 \times 10^{-4}$	$18,79 \times 10^{-4}$	$23,65 \times 10^{-4}$
LSTM	$0,68 \times 10^{-4}$	$1,76 \times 10^{-4}$	$3,19 \times 10^{-4}$	$4,93 \times 10^{-4}$	$6,99 \times 10^{-4}$
BiLSTM	$2,37 \times 10^{-4}$	$2,38 \times 10^{-4}$	$4,22 \times 10^{-4}$	$6,00 \times 10^{-4}$	$7,84 \times 10^{-4}$
GRU	$0,59 \times 10^{-4}$	$1,48 \times 10^{-4}$	$2,75 \times 10^{-4}$	$4,20 \times 10^{-4}$	$5,86 \times 10^{-4}$
BiGRU	$2,42 \times 10^{-4}$	$2,84 \times 10^{-4}$	$4,00 \times 10^{-4}$	$4,91 \times 10^{-4}$	$5,20 \times 10^{-4}$
LSTM-LSTM	$1,11 \times 10^{-4}$	$2,06 \times 10^{-4}$	$3,21 \times 10^{-4}$	$4,52 \times 10^{-4}$	$5,98 \times 10^{-4}$
BiLSTM-LSTM	$0,80 \times 10^{-4}$	$2,41 \times 10^{-4}$	$3,61 \times 10^{-4}$	$4,89 \times 10^{-4}$	$6,32 \times 10^{-4}$
GRU-GRU	$0,80 \times 10^{-4}$	$1,66 \times 10^{-4}$	$2,76 \times 10^{-4}$	$4,02 \times 10^{-4}$	$5,42 \times 10^{-4}$
BiGRU-GRU	$1,16 \times 10^{-4}$	$2,23 \times 10^{-4}$	$3,65 \times 10^{-4}$	$5,06 \times 10^{-4}$	$6,60 \times 10^{-4}$
Transformateur	$2,22 \times 10^{-4}$	$1,72 \times 10^{-4}$	$2,50 \times 10^{-4}$	$3,50 \times 10^{-4}$	$4,67 \times 10^{-4}$
MÉTO-S2S		$2,30 \times 10^{-4}$	$2,71 \times 10^{-4}$	$3,49 \times 10^{-4}$	$4,62 \times 10^{-4}$
Les notes		$1,51 \times 10^{-4}$	$2,34 \times 10^{-4}$	$3,37 \times 10^{-4}$	$4,57 \times 10^{-4}$

Le modèle VEPO-S2S proposé comprend le module de représentation de trajectoire de navire à plusieurs niveaux (Multi-Rep) et le module de fusion et de décodage de fonctionnalités (FFDM). Le Multi-Rep est spécialement conçu non seulement pour intégrer les informations de trajectoire, mais également pour prendre pleinement en compte les caractéristiques du navire et les préférences comportementales, en les codant avec des

encodeurs pour enrichir la représentation des caractéristiques. De plus, la FFDM sélectionne et intègre les informations et fonctionnalités ci-dessus en fonction de l'environnement de prédiction actuel, ce qui permet au modèle de les exploiter efficacement. Ces deux avantages font du VEPO-S2S plus précis que les autres lignes de base.

5.3. Étude sur l'ablation

Étudier la fonction des caractéristiques des navires à plusieurs niveaux dans VEPO-S2S et le module de fusion et de décodage de fonctionnalités, nous avons conçu plusieurs expériences d'ablation, qui sont introduits dans la partie suivante :

- 1. sans SA. Supprimez l'entrée des attributs de niveau peu profond dans le navire à plusieurs niveaux
Module de représentation de la trajectoire, comprenant la longueur, la largeur, le tirant d'eau et le type du navire (voir section 4.3.1);
- 2. sans k1. Supprimer la préférence d'emplacement de navigation dans la trajectoire du navire à plusieurs niveaux
Module de représentation (voir section 4.3.1);
- 3. sans k2. Supprimer la préférence de temps de voyage de la trajectoire du navire à plusieurs niveaux
Module de représentation (voir section 4.3.1);
- 4. sans k3. Supprimer la préférence de temps d'ancrage de la trajectoire du navire à plusieurs niveaux
Module de représentation (voir section 4.3.1);
- 5. sans p_s. Supprimez le composant de sélection de portrait de Feature Fusion et
Module de décodage (voir section 4.3.2) ;
- 6. avec de _f. Supprimer le composant Feature Fusion de Feature Fusion and Decoding
Module (voir section 4.3.2);
- 7. sans muti_d. Supprimez le composant décodeur multi-têtes de Feature Fusion et
Module de décodage, utilisant à la place un seul GRU pour le décodage, qui ne reçoit pas informations sur la trajectoire séparément (voir la section 4.3.2).

Les résultats sont présentés dans le tableau 9. Nous avons évalué les performances à l'aide du RMSE, du MAE, ADE et FDE. Les résultats indiquent que la suppression du composant de sélection de portrait a eu l'impact le plus significatif sur la métrique RMSE, la diminuant de $3,17 \times 10^{-4}$ à $4,48 \times 10^{-4}$. Cela indique que le composant de sélection de portrait joue un rôle crucial dans le modèle. En effet, le composant de sélection de portrait est responsable de la sélection les caractéristiques du navire les plus adaptées à l'environnement actuel. Quand le Le composant de sélection de portrait est supprimé, les performances du modèle diminuent considérablement. De plus, on observe que la suppression du composant décodeur multi-têtes a eu pour conséquence moindre impact, avec une diminution de $3,17 \times 10^{-4}$ à $3,32 \times 10^{-4}$. C'est parce que l'amélioration le décodeur n'affecte pas la structure globale. Le modèle a toujours la possibilité de sélectionner et apprenez à utiliser les caractéristiques correspondantes pour générer des prédictions précises. Cependant, le renforcement du décodeur conduit à une légère amélioration des performances du modèle. Conformément à l'analyse ci-dessus, les mesures d'évaluation MAE, ADE et FDE présentées tendances similaires.

Tableau 9. Résultats quantitatifs de différentes études d'ablation.

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

Après avoir supprimé diverses innovations, les performances du modèle ont diminué. Ainsi, le modèle est équipé de toutes les caractéristiques et composants pour obtenir un des résultats démontrant l'efficacité de nos points innovants.

5.4. Analyse qualitative

Afin de mieux analyser les performances du VEPO-S2S, nous avons sélectionné plusieurs comparaisons. modèles fiables pour plusieurs analyses qualitatives, comme décrit dans cette sous-section.

5.4.1. Comparaison des lignes de base

Comme le montre la figure 12, notre modèle a permis d'obtenir des prédictions précises dans les deux scénarios. par rapport à d'autres références. La difficulté de la prédiction a augmenté de (a) à (b). Dans un), le cargo avait une route droite. La plupart des modèles ont produit des prédictions satisfaisantes, notamment VEPO et METO. Cependant, le GRU s'est écarté de la véritable trajectoire. (b) montre un porte-conteneurs tournant, là où notre modèle est le plus performant. De plus, le METO-S2S Le modèle a prédit avec précision les quatre premiers points, mais il s'est écarté de la trajectoire réelle en le dernier point. Le modèle GRU-GRU est plus performant que le modèle GRU ; cependant, c'est quand même a du mal à obtenir des résultats de prédiction satisfaisants. En pratique, des prédictions incorrectes peuvent conduire facilement à des accidents. On peut observer que les résultats prédits par VEPO-S2S étaient Supérieur aux autres, ce qui peut éviter les problèmes de sécurité.




Figure 12. Les prévisions des cargos et des porte-conteneurs selon différents modèles, avec le difficulté des prédictions augmentant de (a) à (b). Notre modèle est le plus performant dans les deux scénarios. Dans (a), qui implique la navigation en ligne droite des cargos, tous les modèles, à l'exception du GRU, obtiennent des résultats décents résultats de prédiction. En (b), qui implique le virage d'un porte-conteneurs. De plus, le modèle METO-S2S est également capable d'accomplir les tâches de prédiction dans une certaine mesure. Cependant, d'autres modèles peinent à obtenir des performances de prédiction satisfaisantes.

5.4.2. Résultat visuel de la structure Seq2Seq

Comme nous pouvons le voir sur la figure 13, VEPO-GRU-GRU est plus robuste que VEPO- BiGRU-GRU, VEPO-BiLSTM-LSTM et VEPO-LSTM-LSTM. (a) représente une trajectoire fluide, indiquant la navigation normale d'un cargo. (b) montre une trajectoire courbe, suggérant éventuellement des manœuvres d'évitement par un pétrolier. Sur différents types de navires et les états de mouvement, toutes les structures du modèle VEPO-S2S présentent systématiquement des résultats satisfaisants. performance. Notamment, le modèle VEPO-S2S avec la structure GRU-GRU montre mieux robustesse.




Figure 13. Les prédictions de trajectoire du cargo et du pétrolier en utilisant différentes structures du Modèle VEPO-S2S, avec la difficulté prédictive augmentant progressivement de (a) à (b). Comme le montre Sur le graphique, VEPO-GRU-GRU atteint les meilleures performances prédictives.

5.4.3. Résultats d'ablation qualitatifs

Nous avons mené plusieurs études détaillées pour mieux illustrer les changements dans les résultats expérimentaux avant et après l'ablation. Sept figures présentent les résultats des expériences sur les attributs de niveau peu profond, la préférence de lieu de navigation, la préférence de temps de voyage, la préférence de temps d'ancrage, le composant de sélection de portrait, la fusion de fonctionnalités Composant et le composant décodeur multi-têtes pour un remorqueur. Plus précisément, nous présenter quatre trajectoires dans chaque image, y compris les points de suivi d'entrée, les étiquettes et les résultats prédictifs avant et après ablation.

Pour chaque figure, il est évident que la courbe verte s'aligne étroitement sur la trajectoire réelle. Nous observons que si un navire ne possède pas l'un des attributs de faible profondeur, le lieu de navigation Préférence, Préférence de temps de voyage ou Préférence de temps d'ancrage, il existe des biais importants en termes de direction et de distance dans les résultats prédits.

La figure 14 illustre les résultats avec et sans attributs de niveau peu profond. Dans le absence d'attributs de niveau peu profond, les prédictions VEPO-S2S s'écartent de la trajectoire réelle aux quatrième et cinquième points. En effet, les attributs de niveau peu profond déterminent l'inertie et les capacités de virage du navire. Généralement, les plus gros navires ont plus de difficulté en modifiant leurs états de mouvement actuels. Lorsqu'il y a un manque d'attributs de niveau peu profond, le modèle a du mal à évaluer avec précision ces capacités du navire. Par conséquent, à long terme prédictions, le modèle ne parvient pas à fournir des conseils efficaces et conduit à des écarts par rapport aux trajectoire correcte dans les étapes ultérieures.




Figure 14. Trajectoires prévues d'un remorqueur, où les lignes vertes et rouges représentent la prédiction résultats en utilisant VEPO-S2S avec et sans attributs de niveau peu profond, respectivement. Le niveau peu profond Les attributs sont associés à l'inertie et aux capacités de virage du navire. Le modèle sans Les attributs de niveau peu profond ne sont pas capables de bien saisir cette capacité, ce qui peut provoquer des erreurs.

La figure 15 montre les résultats avec et sans la préférence d'emplacement de navigation. La préférence d'emplacement de navigation aide le modèle à reconnaître l'adaptabilité d'un navire au terrain.

Les navires présentant différents degrés d'adaptabilité aux terrains choisissent différents systèmes d'évitement des collisions itinéraires. Sans la préférence de lieu de navigation, le modèle a du mal à capturer les détails de itinéraires, ce qui rend difficile la génération de choix correspondants et conduit à des oscillations dans les trajectoires prévues.




Figure 15. Trajectoires prévues d'un remorqueur, où les lignes vertes et rouges représentent respectivement les résultats de prédiction de VEPO-S2S avec et sans prise en compte de la préférence de localisation de navigation. La préférence d'emplacement de navigation aide le modèle à identifier l'adaptabilité du navire à l'environnement géographique. Lorsque la préférence de lieu de navigation n'est pas prise en compte, le modèle VEPO-S2S n'est pas correcte.

La figure 16 affiche les résultats de la comparaison avec et sans la préférence de temps de voyage. La préférence de temps de voyage reflète les habitudes des équipages et de la navigation du navire. à divers moments. Par exemple, les manœuvres d'évitement de collision sont différentes pendant périodes de trafic maritime élevé et faible. Sans les conseils de la préférence de temps de voyage, les résultats prévus présentent des fluctuations considérables.




Figure 16. Les trajectoires prévues d'un remorqueur, où les lignes vertes et rouges représentent les résultats de prédiction du modèle VEPO-S2S avec et sans prise en compte de la préférence de temps de voyage, respectivement. La préférence de temps de voyage est liée aux habitudes des équipages. Quand le temps du voyage La préférence n'est pas prise en compte, le modèle VEPO-S2S peut produire des prédictions inexactes.

La figure 17 montre les résultats avec et sans la préférence de temps d'ancrage, qui est lié aux habitudes de travail et de repos. La trajectoire du remorqueur change davantage de manière significative lorsqu'il est en état de marche. Il est donc difficile pour le modèle de déterminer avec précision le mouvement actuel du remorqueur sans le temps d'ancrage Préférence, qui conduit à des écarts par rapport aux véritables points de trajectoire.




Figure 17. Les trajectoires prédites d'un remorqueur, où les lignes vertes et rouges représentent les résultats de prédiction du modèle VEPO-S2S avec et sans prise en compte de la préférence de temps d'ancrage, respectivement. La préférence de temps d'ancrage aide le modèle à identifier les habitudes de travail et de repos du navire. En l'absence de préférence de temps d'ancrage, le modèle produit un résultat incorrect.

La figure 18 montre les résultats de comparaison visuelle du composant de sélection de portrait. Sans le composant de sélection de portrait, le résultat s'écarte de la piste réelle. C'est parce que le composant de sélection de portrait peut sélectionner les caractéristiques les plus pertinentes pour prédiction et sans cela, des caractéristiques non pertinentes peuvent être introduites dans la prédiction processus, ce qui entraîne des écarts importants dans les résultats prévus.




Figure 18. Trajectoires prévues d'un remorqueur, où les lignes vertes et rouges représentent la prédiction résultats en utilisant VEPO-S2S avec et sans le composant de sélection de portrait, respectivement. Le portrait Le composant de sélection est chargé de sélectionner les caractéristiques les plus pertinentes pour la prédiction. Sans ce composant, le modèle ne peut pas sélectionner les caractéristiques appropriées pour faciliter la prédiction, conduisant à une diminution de la robustesse du modèle.

La figure 19 montre les résultats de comparaison visuelle du composant Feature Fusion, qui intègre efficacement les informations de trajectoire avec les caractéristiques du navire et améliore la corrélation entre eux. Sans le composant Feature Fusion, les caractéristiques du navire ont du mal à s'exprimer pleinement, ce qui conduit à des prédictions erronées.




Figure 19. Trajectoires prévues d'un remorqueur, où les lignes vertes et rouges représentent la prédiction résultats par VEPO-S2S avec et sans composant fusionné de fonctionnalités, respectivement. La fonctionnalité fusionnée Le composant intègre efficacement les informations sur la trajectoire et les caractéristiques du navire et augmente la corrélation entre les deux. Sans le composant fusionné de fonctionnalités, les caractéristiques du navire sont difficiles de manière adéquate dans le modèle VEPO-S2S, ce qui entraîne une diminution de la précision du modèle.

La figure 20 représente les résultats de comparaison du composant décodeur multi-têtes, qui peut ajuster le niveau d'engagement dans les informations de trajectoire et les caractéristiques du navire. L'adaptabilité du modèle diminue lors du retrait du composant décodeur multi-têtes. Sur la base de ces études d'ablation, le modèle VEPO-S2S démontre une précision satisfaisante et robustesse.




Figure 20. Trajectoires prévues d'un remorqueur, où les lignes vertes et rouges représentent les résultats de prédiction utilisant VEPO-S2S avec et sans le composant décodeur multi-têtes, respectivement. Le composant décodeur multi-têtes régule l'implication des informations de trajectoire et caractéristiques du navire dans le processus de prévision. Sans cela, l'adaptabilité du modèle VEPO-S2S se réduit à plis.

6. Conclusions

Grâce à une étude de la littérature pertinente, nous avons constaté que les caractéristiques et le comportement des navires les préférences ont un impact significatif sur les trajectoires. Cette étude propose donc une nouvelle modèle de prédiction de trajectoire, VEPO-S2S, qui prend pleinement en compte les informations de trajectoire, caractéristiques du navire et préférences comportementales. VEPO-S2S se compose de deux parties : le multi-niveau Module de représentation de la trajectoire des navires et module de fusion et de décodage de fonctionnalités. Le module de représentation de trajectoire de navire à plusieurs niveaux obtient des informations sur la trajectoire (telles que la longitude, la latitude, le cap, la vitesse et la distance de navigation) ainsi que les caractéristiques du navire à plusieurs niveaux, englobant les attributs de faible profondeur (longueur du navire, type, et tirant d'eau) et des fonctionnalités de niveau approfondi (préférence de lieu de navigation, préférence de temps de voyage, et préférence de temps d'ancrage). Ceux-ci sont codés à l'aide de plusieurs encodeurs. La fonctionnalité Le module de fusion et de décodage vise à sélectionner les caractéristiques des navires les plus pertinentes pour le environnement de prédiction actuel et les intégrer aux informations de trajectoire avant

décodage avec un décodeur amélioré. Les résultats expérimentaux démontrent que ce modèle surpasse qualitativement les autres modèles de base et présente d'excellentes performances sur les cartes basées sur une grille.

7. Travaux futurs

Dans ce travail, nous avons pris en compte l'impact des caractéristiques et des préférences au-delà des informations de trajectoire sur la prédiction de trajectoire. À l'avenir, nous visons à optimiser notre modèle pour améliorer l'efficacité et la précision des prévisions, validées sur des ensembles de données de navigation plus globaux. De plus, nous explorerons d'autres modèles importants, tels que le grand modèle de séries chronologiques. De plus, d'autres facteurs influencent les mouvements des navires, notamment les conditions météorologiques, les conditions maritimes, les courants océaniques et les récifs. Par conséquent, nous visons à intégrer davantage de facteurs d'influence dans le processus de modélisation et à entreprendre des investigations plus approfondies dans des scénarios plus complexes.

Contributions des auteurs : Conceptualisation, ZH ; méthodologie, ZH et XY ; logiciel, SL ; validation , HL et JL ; analyse formelle, YZ ; enquête, YZ et HL ; ressources, HL ; conservation des données, WA ; rédaction – préparation du projet original, XY ; rédaction – révision et édition, ZH ; visualisation, WA et XY ; supervision, SL et JL Tous les auteurs ont lu et accepté la version publiée du manuscrit.

Financement : Cette recherche a été financée par la Fondation des sciences naturelles de la province du Zhejiang, en Chine, dans le cadre de la subvention LY21E090005, et par le Bureau du projet scientifique et technologique de Zhoushan (2021C21010).

Déclaration du comité d'examen institutionnel : sans objet.

Déclaration de consentement éclairé : sans objet.

Déclaration de disponibilité des données : toutes les données utilisées dans ce document peuvent être téléchargées à partir du site Web public : marinecadastre.gov/accessais. (consulté le 31 décembre 2021).

Conflits d'intérêts : Les auteurs ne déclarent aucun conflit d'intérêts.

Abréviations

Les abréviations suivantes sont utilisées dans ce manuscrit :

AIS	Système d'identification automatique
Séq2Séq	Réseau séquence à séquence, le
VÉPO	modèle orienté portrait VEssel
Module de représentation de la trajectoire des navires à plusieurs niveaux et multi-représentations	
FDM	le module de fusion et de décodage de fonctionnalités

Les références

1. Yang, C.-H. ; Wu, CH ; Shao, J.-C. ; Wang, Y.-C. ; Hsieh, C.-M. Prédiction intelligente de la trajectoire des navires basée sur Ais à l'aide de bi-Istm. Accès IEEE 2022, 10, 24302-24315.
2. Fossen, S. ; Fossen, TI Conception étendue du filtre Kalman et prédiction du mouvement des navires à l'aide des données en direct du système d'identification automatique (AIS). Dans Actes de la 2e Conférence européenne sur le génie électrique et l'informatique (EECS) 2018, Berne, Suisse, 20-22 décembre 2018 ; pp. 464-470.
3. Kawan, B. ; Wang, H. ; Li, G. ; Chhantyal, K. Modélisation basée sur les données de la prédiction du mouvement des navires basée sur la régression du vecteur de support. Dans Actes du 58e SIMS, Reykjavik, Islande, 25-27 septembre 2017.
4. Li, H. ; Jiao, H. ; Yang, Z. Prédiction de trajectoire de navire basée sur l'apprentissage automatique et l'apprentissage profond : une revue systématique et une analyse des méthodes. Ing. Appl. Artif. Intell. 2023, 126, 107062.
5. Suo, Y. ; Chen, W. ; Claramunt, C. ; Yang, S. Un cadre de prédiction de trajectoire de navire basé sur un réseau neuronal récurrent. Capteurs 2020, 20, 5133.
6. Wang, C. ; Ren, H. ; Li, H. Prédiction de trajectoire du navire basée sur les données AIS et gru bidirectionnel. Dans Actes de la Conférence internationale 2020 sur la vision par ordinateur, l'image et l'apprentissage profond (CVIDL), IEEE, Nanchang, Chine, 15-17 mai 2020 ; pp. 260-264.
7. Tang, H. ; Yin, Y. ; Shen, H. Un modèle de prédiction de trajectoire de vaisseau basé sur un réseau neuronal à mémoire à long terme et à court terme. J. Mar. Ing. Technologie. 2022, 21, 136-145.

8. Parc, J. ; Jeong, J. ; Park, Y. Prédiction de trajectoire de navire basée sur bi-LSTM utilisant des données AIS groupées spectralement. *J. Mar. Sci. Ing.* 2021, 9, 1037.
9. Zhang, S. ; Wang, L. ; Zhu, M. ; Chen, S. ; Zhang, H. ; Zeng, Z. Une méthode bidirectionnelle de prédiction de trajectoire de navire LSTM basée sur un mécanisme d'attention. Dans les actes de la 5e conférence IEEE 2021 sur le contrôle des technologies de l'information avancées, de l'électronique et de l'automatisation (IAEAC), IEEE, Chongqing, Chine, 12-14 mars 2021 ; pages 1987-1993.
10. Bao, K. ; Bi, J. ; Gao, M. ; Soleil, Y. ; Zhang, X. ; Zhang, W. Une prédiction améliorée de la trajectoire des navires basée sur les données AIS utilisant mha-bigru. *J. Mars Sci. Ing.* 2022, 10, 804.
11. Wu, W. ; Chen, P. ; Chen, L. ; Mou, J. Prédiction de trajectoire de navire : une approche intégrée utilisant un modèle séquence à séquence basé sur un convlstm . *J. Mar. Sci. Ing.* 2023, 11, 1484.
12. Nguyen, D.-D. ; Van, CL; Ali, MI Prédiction de la trajectoire des navires à l'aide de modèles séquence à séquence sur une grille spatiale. Dans Actes de la 12e Conférence internationale ACM sur les systèmes distribués et basés sur des événements, Lyon, France, 25-28 juin 2018 ; pp. 258-261.
13. Zhang, Y. ; Han, Z. ; Zhou, X. ; Li, B. ; Zhang, L. ; Zhen, E. ; Wang, S. ; Zhao, Z. ; Guo, Z. Meto-s2s : Une méthode de prédiction de trajectoire de navire basée sur s2s avec un encodeur multi-sémantique et un décodeur orienté type. *Océan. Ing.* 2023, 277, 114248.
14. Zhao, J. ; Yan, Z. ; Chen, X. ; Han, B. ; Wu, S. ; Ke, R. k-gcn- lstm : un réseau convolutionnel de graphes k-hop et une mémoire à long-court terme pour la prévision de la vitesse des navires. *Phys. Stat. Mécanique. Son application.* 2022, 606, 128107.
15. Wang, S. ; Li, Y. ; Xing, H. ; Zhang, Z. Prédiction de la trajectoire des navires basée sur un réseau convolutif de graphiques spatio-temporels pour zones maritimes complexes et peuplées. *Océan. Ing.* 2024, 298, 117232.
16. Cao, D. ; Li, J. ; Maman, H. ; Tomizuka, M. Réseau neuronal à graphes temporels spectraux pour la prédiction de trajectoire. Dans les actes du 2021 Conférence internationale de l'IEEE sur la robotique et l'automatisation (ICRA), Xi'an, Chine, 30 mai-5 juin 2021 ; pages 1839-1845.
17. Yasukawa, H. ; Yoshimura, Y. Manœuvrabilité des navires ; Seizando : Tokyo, Japon, 2018.
18. Cooper, A. Pourquoi les produits de haute technologie nous rendent fous et comment restaurer la raison ; Sams Publishing : Carnel, IN, États-Unis, 2004.
19. Lu, J. ; Xie, L. Méthode de navigation inertielle des véhicules océaniques basée sur des contraintes dynamiques. *J. Navig.* 2018, 71, 1553-1566.
20. Cole, B. ; Schamberg, G. Filtre Kalman non parfumé pour le suivi des navires sur de longues distances en coordonnées géodésiques. *Appl. Océan. Rés.* 2022, 124, 103205.
21. Zhang, D. ; Chu, X. ; Wu, W. ; Lui, Z. ; Wang, Z. ; Liu, C. Identification du modèle de manœuvre de virage du navire et à court terme extrême prédiction de trajectoire sous l'influence des courants marins. *Océan. Ing.* 2023, 278, 114367.
22. Soleil, Q. ; Tang, Z. ; Gao, J. ; Zhang, G. Prédiction de l'attitude du mouvement du navire à court terme basée sur lstm et gpr. *Appl. Océan. Rés.* 2022, 118, 102927.
23. Zhang, L. ; Zhu, Y. ; Su, J. ; Lu, W. ; Li, J. ; Yao, Y. Un modèle de prédiction hybride basé sur knn-lstm pour la trajectoire des navires. *Mathématiques* 2022, 10, 4493.
24. Gao, D.-W. ; Zhu, Y.-S. ; Zhang, J.-F. ; Lui, Y.-K. ; Yan, K. ; Yan, B.-R. Une nouvelle méthode mp-lstm pour la prédiction de trajectoire de navire basée sur les données AIS. *Océan. Ing.* 2021, 228, 108956.
25. Forti, N. ; Millefiori, LM; Braca, P. ; Willett, P. Prédiction des trajectoires des vaisseaux à partir des données AIS via des réseaux neuronaux récurrents séquence à séquence . Dans les actes de la conférence internationale ICASSP 2020-2020 de l'IEEE sur l'acoustique, la parole et le traitement du signal (ICASSP), virtuelle, 4-9 mai 2020 ; pages 8936 à 8940.
26. Vous, L. ; Xiao, S. ; Peng, Q. ; Claramunt, C. ; Han, X. ; Guan, Z. ; Zhang, J. St-seq2seq : Un seq2seq optimisé pour les fonctionnalités spatio-temporelles modèle pour la prévision de la trajectoire des navires à court terme. *Accès IEEE* 2020, 8, 218565-218574.
27. Chen, P. ; Yang, F. ; Mou, J. ; Chen, L. ; Li, M. Comportement régional des navires et prévision de trajectoire pour la gestion du trafic maritime : A approche de réseau social conflictuel génératif. *Océan. Ing.* 2024, 299, 117186.
28. Zhang, Y. ; Han, Z. ; Zhou, X. ; Zhang, L. ; Wang, L. ; Zhen, E. ; Wang, S. ; Zhao, Z. ; Guo, Z. Peso : Une méthode de prédiction de trajectoire de navire basée sur seq2seq avec des encodeurs parallèles et un décodeur orienté navire. *Appl. Sci.* 2023, 13, 4307.
29. Jiang, D. ; Shi, G. ; Li, N. ; Maman, L. ; Li, W. ; Shi, J. Trfm-ls : Méthode d'apprentissage profond basée sur un transformateur pour la prédiction de la trajectoire des navires. *J. Mars Sci. Ing.* 2023, 11, 880.
30. Liu, RW; Liang, M. ; Nie, J. ; Yuan, Y. ; Xiong, Z. ; Yu, H. ; Guizani, N. Stmgcn : Prédiction de la trajectoire des navires basée sur l'informatique mobile à l'aide d'un réseau convolutif multigraphique spatio-temporel. *IEEETrans. Ind. Informer.* 2022, 18, 7977-7987.
31. Li, Y. ; Li, Z. ; Mei, Q. ; Wang, P. ; Hu, W. ; Wang, Z. ; Xie, W. ; Yang, Y. ; Chen, Y. Recherche sur la méthode de prévision du trafic maritime multiport basée sur les réseaux neuronaux à graphes spatio-temporels. *J. Mar. Sci. Ing.* 2023, 11, 1379.
32. Cho, K. ; Merriënboer, BV ; Gulcehre, C. ; Bahdanau, D. ; Bougarès, F. ; Schwenk, H. ; Bengio, Y. Apprentissage des représentations de phrases utilisation du codeur-décodeur rnn pour la traduction automatique statistique. *arXiv* 2014, arXiv : 1406.1078.
33. Gong, G. ; Un, X. ; Mahato, NK ; Soleil, S. ; Chen, S. ; Wen, Y. Recherche sur la prévision de charge à court terme basée sur le modèle seq2seq. *Énergies* 2019, 12, 3199.
34. Hwang, S. ; Jeon, G. ; Jeong, J. ; Lee, J. Un nouveau modèle seq2seq basé sur des séries chronologiques pour la prévision de la température dans le processus de four de cuisson. *Procedia Comput. Sci.* 2019, 155, 19-26.
35. Gao, S. ; Zhang, S. ; Huang, Y. ; Han, J. ; Luo, H. ; Zhang, Y. ; Wang, G. Une nouvelle architecture seq2seq pour la prévision du ruissellement horaire utilisant les précipitations et le ruissellement historiques en entrée. *J. Hydrol.* 2022, 612, 128099.
36. Wang, H. ; Wang, S. ; Chen, S. ; Hui, G. Prédire la dynamique de production à long terme dans les réservoirs de gaz de réservoirs étanches/de schiste avec un modèle dix-seq2seq basé sur l'attention à deux étages : une étude de cas dans la formation de Duvernay. *Géoénergie Sci. Ing.* 2023, 223, 211495.

37. Stefenon, S.F.; Seman, L.O.; Aquino, L.S.; Coelho, L.d.S. Wavelet-seq2seq-lstm avec une attention particulière pour la prévision de séries chronologiques du niveau des barrages dans les centrales hydroélectriques. *Énergie* **2023**, *274*, 127350.
38. Mootha, S.; Sridhar, S.; Seetharaman, R.; Chitrakala, S. Prédiction du cours des actions à l'aide de la modélisation séquence à séquence bidirectionnelle basée sur LSTM et de l'apprentissage multitâche. Dans les actes de la 11e conférence annuelle de l'IEEE sur l'informatique omniprésente, l'électronique et les communications mobiles (UEMCON), New York, NY, États-Unis, 28-31 octobre 2020 ; pages 0078 à 0086.
39. Lui, Q.; Li, W.; Hao, Z.; Liu, G.; Huang, D.; Chanson, W.; Xu, H.; Alqahtani, F.; Kim, J.-U. Un réseau tma-seq2seq pour la prévision de la température de surface de la mer en séries chronologiques multifactorielles. *Calculer. Maître. Continuer.* **2022**, *73*, 2022.
40. Qu, Q.; Chen, H.; Lei, Z.; Li, B.; Du, Q.; Wang, Y. Prédiction de l'amplitude du fouillis marin via un réseau seq2seq amélioré par l'attention. *Télésens.* **2023**, *15*, 3234.
41. Asadi, N.; Lamontagne, P.; Roi, M.; Richard, M.; Scott, K.A. Prédiction saisonnière de la présence de glace de mer dans la baie d'Hudson à l'aide de l'apprentissage seq2seq. Disponible en ligne : <https://s3.us-east-1.amazonaws.com/climate-change-ai/papers/icml2021/6/paper.pdf> (consulté le 1er juin 2024)
42. Zhu, W.; Zhou, R. Construction de portraits d'employés basée sur des réseaux de neurones profonds. Dans les actes de la 9e conférence internationale 2022 sur les systèmes fiables et leurs applications (DSA), IEEE, Wulumuqi, Chine, 4 et 5 août 2022 ; pp. 139-142.
43. Ma, C.; Wang, Z.; Cheng, P.; Liu, X.; Yu, H.; Zhang, H. Méthode de recommandation hybride de services Web basée sur le portrait d'utilisateur. *J. Calculer.* **2021**, *32*, 197-212.
44. Zhao, J.; Zeng, D.; Xiao, Y.; Che, L.; Wang, M. Prédiction de la personnalité de l'utilisateur basée sur les préférences de sujet et l'analyse des sentiments à l'aide du modèle lstm. *Reconnaissance de modèles. Lett.* **2020**, *138*, 397-402.
45. Yan, S.; Zhao, T.; Deng, J. Prédire l'occupation des utilisateurs de médias sociaux avec des réseaux de neurones hiérarchiques sensibles au contenu. Dans les actes de la 8e Conférence internationale 2022 sur le Big Data et l'analyse de l'information (BigDIA), Guiyang, Chine, 24-25 août 2022 ; pp. 388-395.
46. Wang, N. Modèle de prédiction intelligent par ordinateur de la récompense impulsive sur Internet basé sur l'algorithme du portrait de l'utilisateur. Dans les actes de la 4e conférence internationale de l'IEEE 2021 sur l'automatisation, l'électronique et l'ingénierie électrique (AUTEEE), Shenyang, Chine, 19-21 novembre 2021 ; pp. 545-548.
47. Mingyu, Z.; Sutong, W.; Yanzhang, W.; Dujuan, W. Une méthode de prédiction interprétable pour la crise académique des étudiants universitaires avertissement. *Intelligence complexe. Système.* **2022**, *8*, 323-336.
48. Liu, T.; Ma, J. Prédiction du comportement de navigation des navires basée sur les données AIS. *Accès IEEE* **2022**, *10*, 47997-48008.
49. Silvester, R. *Ingénierie côtière*; Elsevier Scientific Publishing Company : Amsterdam, Pays-Bas, 1974.
50. Brolsma, J.U. Association internationale permanente des congrès de navigation. PIANC, l'Association mondiale pour les infrastructures de transport par eau : une association dans un monde en évolution, 1885-2010 ; PIANC : Bruxelles, Belgique, 2010. Disponible en ligne : <https://books.google.co.jp/books?id=ZaSwYgEACAAJ> (consulté le 1er juin 2024).
51. Notteboom, T.E. Transport de conteneurs et ports : un aperçu. *Rév.Netw. Écon.* **2004**, *3*, 86-106.
52. Gillis, D.M. Distributions libres idéales dans la dynamique de la flotte : une perspective comportementale sur les mouvements des navires dans l'analyse des pêcheries. *Peut. J. Zool.* **2003**, *81*, 177-187.
53. Mahpour, A.; Nazifi, A.; Amiri, A.M. Développement d'un modèle d'optimisation pour réduire le temps de déchargement et de chargement au poste à quai ports à conteneurs. *L'Iran. J. Sci. Technologie. Trans. Civ. Ing.* **2021**, *45*, 2831-2840.
54. McInnes, L.; Healy, J.; Astels, S. hdbscan : Clustering basé sur la densité hiérarchique. *J. Logiciel Open Source.* **2017**, *2*, 205.

Avis de non-responsabilité/Note de l'éditeur : Les déclarations, opinions et données contenues dans toutes les publications sont uniquement celles du ou des auteurs et contributeurs individuels et non de MDPI et/ou du ou des éditeurs. MDPI et/ou le(s) éditeur(s) déclinent toute responsabilité pour tout préjudice corporel ou matériel résultant des idées, méthodes, instructions ou produits mentionnés dans le contenu.