

Artículo

VEPO-S2S: una predicción de trayectoria orientada a retratos de Vessel Modelo basado en el marco 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 y Junyi Liu ²
^{1,3,4,5}

¹ Instituto de Investigación de Información Aeroespacial, Academia China de Ciencias, Beijing 100190, China; xxy915200@163.com (XY); hanzh@aircas.ac.cn (ZH); zhangyb@aircas.ac.cn (YZ); 18010076513@163.com (SL); liujy004735@aircas.ac.cn (JL)

² Escuela de Arquitectura Naval y Marítima, Zhejiang Ocean University, Zhoushou 361022, China; aiwanzheng@126.com

³ Laboratorio clave de tecnología de sistemas de información de redes, Instituto de Electrónica, Academia de Ciencias de China, Beijing

⁴ 100190, China Laboratorio clave de tecnología de aplicación y cognición objetivo (TCAT), Beijing 100190, Escuela de Electrónica, Electricidad y Comunicaciones de China 5 Ingeniería, Universidad de la Academia de Ciencias de Beijing 100190, China

* Correspondencia: liuhu@zjou.edu.cn Estos

† autores contribuyeron igualmente a este trabajo.

Resumen: La predicción de las trayectorias de los buques juega un papel crucial para garantizar la seguridad marítima y reducir los accidentes marítimos. Se han logrado avances sustanciales en las tareas de predicción de trayectorias mediante la adopción de métodos de modelado de secuencias, que contienen redes neuronales recurrentes (RNN) y redes de secuencia a secuencia (Seq2Seq). Sin embargo, (1) la mayoría de estos estudios se centran en la aplicación de información de trayectoria, como longitud, latitud, rumbo y velocidad, y descuidan el impacto de las diferentes características de los buques y preferencias de comportamiento en las trayectorias. (2) Quedan desafíos para adquirir estas características y preferencias, así como para permitir que el modelo las integre de manera sensata y las exprese de manera eficiente. Para abordar el problema, presentamos un novedoso marco profundo VEPO- S2S, que consta de un módulo de representación de trayectoria de embarcaciones de varios niveles (Multi-Rep) y un módulo de decodificación y fusión de funciones (FFDM). Además de la información de la trayectoria, primero definimos las características de la embarcación de niveles múltiples en Multi-Rep, que abarcan los atributos de niveles poco profundos (longitud, ancho, calado, etc.) de la embarcación y características de niveles profundos (preferencia de ubicación de navegación, preferencia de tiempo de viaje, etc.). Posteriormente, se diseñó Multi-Rep para obtener información de trayectoria y características de embarcaciones multinivel, aplicando distintos codificadores para la codificación. A continuación, FFDM seleccionó e integró las funciones anteriores de Multi-Rep para la predicción empleando mecanismos a priori y a posteriori, un componente de fusión de funciones y un decodificador mejorado. Esto permite que el modelo los aproveche de manera eficiente y mejore el rendimiento general. Finalmente, realizamos experimentos comparativos con varios modelos de referencia. Los resultados experimentales demuestran que VEPO-S2S es cuantitativa y cualitativamente superior a los modelos.

Palabras clave: aprendizaje profundo; predicción de la trayectoria del buque; red secuencia a secuencia; accidentes marítimos; Evaluación de riesgos; retrato de barco



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

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

VEPO-S2S: un retrato de barco

Modelo de predicción de trayectoria orientada
basado en el framework S2S. *Aplica. Ciencia.*

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

10.3390/app14146344

Editor académico: Phivos Mylonas,

Katia Lida Kermanidis y Manolis

Maragoudakis

Recibido: 3 de junio de 2024

Revisado: 13 de julio de 2024

Aceptado: 16 de julio de 2024

Publicado: 20 de julio de 2024



Copyright: © 2024 por los autores.

Licenciatario MDPI, Basilea, Suiza.

Este artículo es un artículo de acceso abierto,
distribuido bajo los términos y

condiciones de los Creative Commons

Licencia de atribución (CC BY) ([https://creativecommons.org/licenses/by/](https://creativecommons.org/licenses/by/4.0/)

4.0/).

1. Introducción

La industria del transporte marítimo se ha vuelto más importante en la economía global y representa más del 90% del transporte mundial de mercancías en las últimas décadas [1]. En consecuencia, garantizar la seguridad marítima y mejorar la eficiencia de la navegación se ha vuelto aún más urgente. El uso de un sistema de identificación automática (AIS) para predecir las trayectorias de los barcos puede prevenir colisiones y proporcionar una evaluación de riesgos a los reguladores. Específicamente, esta tarea implica pronosticar trayectorias futuras basadas en puntos de trayectoria histórica. Algunos algoritmos [2,3], como el filtro de Kalman y las máquinas de vectores de soporte, permiten predicciones relativamente precisas. Sin embargo, es

Los modelos a menudo están limitados por simplificaciones y exhiben un rendimiento mediocre cuando se enfrentan a situaciones más complejas [4].

Hoy en día, el aprendizaje profundo ha logrado avances significativos y ha encontrado una amplia aplicación en diversos dominios. Las redes neuronales recurrentes (RNN), como modelos de predicción de series temporales, se han aplicado ampliamente en la predicción de trayectorias, pero adolecen de problemas como la desaparición y explosión del gradiente. En los últimos años, los investigadores han mejorado constantemente los enfoques de predicción de trayectorias basados en RNN y han logrado resultados notables. Los autores de [5,6] propusieron un modelo basado en GRU para capturar la dinámica temporal de las secuencias de trayectoria. Este modelo puede aprender las relaciones complejas y no lineales entre entradas y salidas, codificando los patrones de movimiento históricos de los buques. Los autores de [7] propusieron un modelo de trayectoria basado en la memoria a corto plazo (LSTM) que aprende los patrones de movimiento de los vasos del entorno y el tiempo actuales. Los autores de [8] propusieron un método de predicción de trayectoria que combina memoria bidireccional a largo plazo (BiLSTM) y agrupación espacial de aplicaciones con ruido basada en densidad (DBSCAN). Este método integra los patrones de trayectoria de los vasos detectados mediante DBSCAN para mejorar aún más. Los autores de [9,10] intentaron incorporar mecanismos de atención para capturar información crucial. Sin embargo, estos métodos solo pueden predecir un punto secuencialmente, lo que resulta en una rápida acumulación de errores en predicciones de varios pasos. La aparición de modelos Seq2Seq ha aliviado significativamente este problema. Seq2Seq es un tipo de red neuronal codificador-decodificador que se utiliza inicialmente en el campo de la traducción automática y se ha aplicado ampliamente a la predicción de trayectorias. Admite salida multipunto en una sola iteración, lo que reduce efectivamente la acumulación de errores. Los autores de [11] desarrollaron un modelo basado en ConvLSTM y Seq2Seq, mejorando la capacidad de capturar dependencias temporales globales. Los autores de [12] dividieron el área del mar utilizando una cuadrícula espacial basada en el modelo Seq2Seq y lograron buenos resultados en la predicción a largo plazo. Los autores de [13] propusieron el modelo METO-S2S, que emplea un decodificador multiséntico, teniendo en cuenta los efectos de diversos datos semánticos del barco en el pronóstico de trayectoria. Además de los métodos basados en RNN que utilizan información temporal, otro enfoque explorado implica el uso de información espacial para el modelado, siendo las redes convolucionales de gráficos (GCN) las más representativas. Para abordar el problema de las dependencias espaciotemporales, [14] combinó un k-GCN con LSTM, utilizando el GCN para capturar correlaciones espaciales entre nodos y el LSTM para manejar correlaciones espaciotemporales de nodos, permitiendo la predicción de las velocidades de los barcos. Los autores de [15] introdujeron un modelo DAA-SGCN, utilizando un ST-GCN para extraer características de interacción social espacial y un RT-CNN para extraer características temporales, considerando completamente las interacciones sociales entre vasos. Los autores de [16] no sólo consideraron las propias intenciones de la embarcación, sino que también tuvieron en cuenta el impacto del entorno estático y los agentes circundantes que interactúan dinámicamente. Esta investigación se centró en gran medida en aplicar información de trayectoria para la predicción y logró logros notables. Sin embargo, debido a las intrincadas dependencias de la información histórica y la fuerte influencia de las correlaciones espaciales, depender únicamente de la información de la trayectoria dificulta obtener resultados predictivos precisos. Además, las características de la embarcación de varios niveles, como los atributos de la embarcación y las preferencias de ubicación de navegación, también desempeñan un papel crucial en la predicción de la trayectoria. Según los estándares de maniobrabilidad de los barcos [17], la estabilidad del rumbo y la capacidad de giro son métricas cruciales para la maniobrabilidad, que dependen del coeficiente de bloqueo, que está determinado por los atributos del barco. Las variaciones en los atributos de un buque afectan significativamente la maniobrabilidad, afectando así las decisiones relativas a puertos, calles y rutas. Además, las preferencias de ubicación de navegación revelan sus tendencias hacia áreas marítimas específicas, que deberían recibir más atención en las predicciones. Como se muestra en la Figura 1, dos tipos de vasos exhiben trayectorias de movimiento distintas. En comparación con los arrastreros, los buques de carga suelen tener mayores volúmenes y coeficientes de bloqueo más altos, lo que da como resultado un radio de giro mayor y una peor estabilidad del rumbo. Para mitigar los riesgos potenciales, los buques de carga tienden a seleccionar rutas y calles de navegación más amplias, cumpliendo estrictamente con los cronogramas establecidos para garantizar la entrega puntual de la carga y mejorar la eficiencia logística general, lo que resulta en trayectorias de navegación más fluidas y regulares. Por el contrario, los arrastreros operan dentro de zonas de pesca

y políticas regulatorias pertinentes, lo que a menudo resulta en rutas de navegación irregulares y concentradas. Por lo tanto, es crucial investigar los patrones de comportamiento de diferentes embarcaciones y realizar análisis predictivos personalizados basados en los atributos de las embarcaciones y las áreas operativas.




Figura 1. Los ejemplos de trayectoria para varios tipos de embarcaciones ilustran diferencias significativas en las trayectorias de navegación bajo la influencia de diversos atributos y tipos de embarcaciones.

Por esta razón, aún persisten desafíos para obtener características más integrales, así como su aconsejable selección e implementación. Inspirándonos en las personas de los usuarios [18], incorporamos atributos de nivel superficial y características de nivel profundo, definiendo características de embarcación de niveles múltiples para construir un retrato completo de la embarcación. Teniendo en cuenta los desafíos mencionados anteriormente, proponemos un modelo de predicción de trayectoria de embarcaciones VEPO-S2S basado en la arquitectura Seq2Seq, que comprende un módulo de representación de trayectoria de embarcaciones multinivel (Multi-Rep) y un módulo de decodificación y fusión de características (FFDM). Multi-Rep cumple la función de adquirir y expresar características y consta de dos componentes: el componente de adquisición de características y el componente de expresión de características. En el componente de adquisición de características, primero especificamos la información de la trayectoria que incluye la longitud, latitud, velocidad, rumbo y distancia de navegación. Luego, se definen las características de la embarcación de niveles múltiples, que cubren los atributos de niveles poco profundos (como la longitud, el ancho, el calado, etc.), así como las características de niveles profundos (preferencia de ubicación de navegación, preferencia de tiempo de viaje, etc.). Todos estos se adquieren a través del componente de adquisición de funciones y luego se codifican por separado utilizando tres codificadores independientes dentro del componente de expresión.

Aparte de eso, a pesar de la incorporación de información de trayectoria y características de la embarcación en el modelo, los modelos básicos de Seq2Seq enfrentan desafíos para discernirlos y aprovecharlos de manera eficiente. Por lo tanto, es imperativo seleccionar e integrar la información de la trayectoria y las características del barco antes de aplicarlas. Para lograr este propósito, proponemos el módulo FFDM que consta de un componente de selección de retrato, un componente de fusión de funciones y un componente de decodificación de cabezales múltiples. Al principio, el componente de selección de retratos discierne las características más relevantes de la embarcación para el entorno de predicción actual mediante el análisis de las características codificadas. Luego, el componente Feature Fusion está diseñado para fusionar información de trayectoria del módulo Multi-Rep con características relevantes de la embarcación. Finalmente, la salida sirve como entrada para el componente de decodificación de cabezales múltiples, que está diseñado en base al decodificador tradicional Seq2Seq. El componente de decodificación de cabezales múltiples consta de dos bloques GRU distintos, cada uno de los cuales controla la proporción de información de trayectoria y características de la embarcación durante la predicción, lo que proporciona resultados de salida más precisos.

En resumen, las principales contribuciones de este artículo se pueden resumir de la siguiente manera:

- Proponemos un marco de predicción de la trayectoria de la embarcación VEPO-S2S, que abarca el módulo de representación de la trayectoria de la embarcación de múltiples niveles (Multi-Rep) y el módulo de fusión y decodificación de funciones (FFDM).

Este marco tiene plenamente en cuenta la trayectoria.

información y características de los buques, asegurando su integración sensata y expresión eficiente para lograr resultados más precisos.

- Proponemos el módulo Multi-Rep, que integra información de trayectoria con características de embarcaciones de niveles múltiples y emplea múltiples codificadores para la codificación. Este módulo tiene la capacidad de capturar representaciones temporales de las trayectorias, así como el retrato detallado de los buques.
- Para abordar el desafío de fusionar y representar eficazmente múltiples características dentro de nuestro modelo, proponemos el FFDM. Este módulo selecciona e integra características empleando mecanismos a priori y a posteriori, un componente de fusión de características y un decodificador mejorado. El FFDM puede representar mejor la correlación espaciotemporal entre trayectorias históricas.
- Realizamos experimentos comparativos en varios modelos de referencia. Los resultados experimentales demostraron que VEPO-S2S superó a otros modelos de referencia tanto en aspectos cuantitativos como cualitativos, produciendo resultados de predicción más sólidos y precisos <https://github.com/AIR-SkyForecast/AIR-SkyForecast-VEPO-S2S/new/principal> (consultado el 15 de julio de 2024).

2. Trabajos relacionados

2.1. Predicción de la trayectoria del barco

Los métodos tradicionales de predicción de trayectorias han logrado resultados favorables en la predicción de trayectorias de vehículos, barcos y peatones. Los autores de [19] propusieron un método de navegación inercial asistido dinámicamente para estimar los valores observados. Los autores de [20] introdujeron un método de filtrado de Kalman basado en modelos matemáticos para el seguimiento de superficies de largo alcance, lo que permite la predicción directa de la posición del objetivo y el rumbo sin necesidad de conversión del sistema de coordenadas. Para mejorar la precisión de la predicción del movimiento del barco en condiciones de perturbaciones ambientales, ref. [21] propusieron un algoritmo de reconocimiento del movimiento de un barco basado en el método de mínimos cuadrados. Sin embargo, esos métodos mostraron una precisión predictiva limitada cuando se enfrentaron a situaciones complejas.

En los últimos años, el desarrollo de métodos de aprendizaje profundo para la predicción de la trayectoria de los buques ha progresado rápidamente y se han logrado avances significativos en esta tarea. La mayoría de las investigaciones adoptan la estructura RNN. Algunas investigaciones se basan en un LSTM [22] o un GRU [6]. Además, para investigar la predicción de barcos bajo diferentes densidades de trayectoria, ref. [23] propusieron un modelo basado en un LSTM y el K-vecino más cercano (KNN). Los autores de [24] introdujeron el modelo MP-LSTM, que integra las fortalezas de TPNet y LSTM, abordando las deficiencias de los métodos existentes en términos de precisión y complejidad del modelo.

Mientras tanto, algunos académicos intentaron utilizar la arquitectura Seq2Seq para abordar problemas de predicción. Los autores de [25] introdujeron un modelo de red neuronal basado en LSTM y Seq2Seq, utilizado para capturar dependencias a largo plazo en datos históricos dentro de trayectorias.

Los autores de [26] propusieron el modelo ST-Seq2Seq basado en la arquitectura GRU. Los autores de [27] propusieron un modelo de predicción de trayectoria basado en BiGRU y Seq2Seq, que considera completamente las interacciones entre barcos. Además, se han propuesto varios otros modelos de predicción de trayectorias. Los autores de [13] introdujeron el modelo METO-S2S basado en un decodificador multiséntico, considerando la influencia de diversa información semántica del barco en la predicción de la trayectoria. También utilizaron vectores semánticos (SLV) para guiar las predicciones de modelos en PESO [28], logrando resultados sobresalientes en el conjunto de datos AIS de código abierto en los Estados Unidos. Además del modelo Seq2Seq, [29] aplicó el marco Transformer combinado con LSTM para capturar trayectorias históricas en series de tiempo y superar problemas relacionados con la decadencia de la información distante. Para expresar la interdependencia entre barcos, [30] propuso el modelo de red neuronal convolucional multigráfico espaciotemporal (STMGCN), que modela tanto los datos espaciotemporales como los tipos de barcos por separado. Los autores de [31] combinaron la convolución de atención del gráfico (GAT) con una estructura de convolución causal extendida y diseñaron el modelo GAGW. La red de convolución de atención de gráficos se encarga de extraer información de interacción entre diferentes naves en el espacio.

La mayoría de los estudios antes mencionados se centran principalmente en la utilización de información de trayectorias de nivel superficial. Estos estudios suelen utilizar la velocidad, el rumbo y la posición como datos de entrada del modelo. Sin embargo, esto es insuficiente para guiar la evasión de buques en una situación complicada. Adquirir características más ricas y profundas, así como su aplicación sensata, es crucial para guiar la evitación de barcos y la planificación general de rutas. Por lo tanto, la investigación actual sobre la predicción de la trayectoria de los buques prestará más atención a excavar las características abundantes y comprender la dinámica de los entornos del mundo real.

2.2. Modelo Seq2Seq EI

El modelo Seq2Seq se ha aplicado ampliamente en el campo de la traducción automática [32], que consta de un codificador y un decodificador, donde el codificador incorpora la información de entrada y genera un vector semántico de alta dimensión, mientras que el decodificador decodifica y genera el resultado. Presentamos principalmente la investigación relacionada en tareas de regresión basadas en Seq2Seq, incluida la predicción de energía, la predicción de escurrimiento y la predicción de existencias.

En previsión de energía, ref. [33] propusieron un modelo Seq2Seq basado en un LSTM que tiene en cuenta la correlación inherente dentro de los datos, capturando efectivamente las relaciones secuenciales en series de tiempo. Para abordar el problema de la baja precisión en las predicciones de temperatura a corto plazo, [34] propuso un modelo basado en Seq2Seq. En el ámbito de la predicción de la escurrimiento, ref. [35] realizaron mejoras en Seq2Seq reemplazando la estructura RNN con una capa lineal para manejar datos históricos. Además, la introducción de un mecanismo de atención condujo a una mayor precisión de predicción. En [36], se introdujo TEN-Seq2Seq para manejar datos tabulares y profundidades de pozos, que mostraron una mayor robustez en comparación con LSTM y FCNN. Los autores de [37] propusieron un método novedoso para predecir el nivel de un yacimiento utilizando LSTM y el modelado Seq2Seq basado en mecanismos de atención. Los autores de [38] propusieron una estructura para las predicciones del precio de las acciones basada en redes Seq2Seq.

El modelo Seq2Seq también ha logrado avances significativos en el campo de la temperatura de la superficie del mar (SST). Los autores de [39] aplicaron el modelo Seq2Seq con atención de dos módulos (TMA-Seq2Seq) para la predicción de SST de series temporales a largo plazo, obteniendo un rendimiento superior en comparación con los métodos basados en datos. En [40], se propuso una nueva red Seq2Seq para lograr la predicción de k-paso adelante basada en las características del ruido marino. Los autores de [41] utilizaron el modelo Seq2Seq para proporcionar un pronóstico espaciotemporal de la probabilidad de formación de hielo marino, lo que condujo a una mayor precisión.

2.3. Personas de usuario

Las personas de usuario son un producto del desarrollo de Internet, que permite descubrir diferencias entre individuos dentro de grupos. Los autores de [42] propusieron un modelo de persona de usuario de empleado basado en redes neuronales, que establece personas de acuerdo con los niveles de habilidad y estados mentales de los empleados, lo que permite recomendaciones laborales personalizadas para los empleados de la empresa. Los autores de [43] propusieron un método para recomendaciones híbridas de servicios web basadas en personas de usuario para abordar el problema del inicio en frío para nuevos usuarios, mejorando tanto la precisión como la calidad de las recomendaciones.

Recientemente, predecir el comportamiento futuro basándose en perfiles de usuario se ha convertido en una práctica popular. Los autores de [44] transformaron las características de preferencia emocional de los usuarios en información de atención y las combinaron con modelos LSTM para predecir los rasgos de personalidad de los usuarios en línea. Los autores de [45] propusieron el modelo T-LSTM para la predicción de la ocupación del usuario, superando los desafíos en el rendimiento predictivo y ofreciendo un enfoque novedoso y eficaz para una predicción precisa de la ocupación del usuario. Los autores de [46] introdujeron un método para predecir recompensas impulsivas en menores utilizando perfiles de usuario, facilitando pronósticos precisos de conductas de recompensa impulsivas en usuarios menores de edad. Los autores de [47] aplicaron la predicción de personalidad en el campo de las advertencias académicas para estudiantes universitarios. La construcción de personajes estudiantiles para explorar la relación entre los factores estudiantiles y el desempeño académico proporciona una guía sólida para que los maestros y administradores ajusten los planes de enseñanza.

En este trabajo, creamos un perfil para cada barco e introducimos un novedoso modelo basado en Seq2Seq, que demuestra ser más adecuado en la práctica para la detección de colisiones y la advertencia de riesgos.

3. Método propuesto

Presentamos el método en tres partes. Primero, proporcionamos definiciones y el planteamiento del problema. A continuación, le ofrecemos una descripción completa del procesamiento de datos. Luego, describimos el proceso detallado de construcción del retrato de la embarcación. Finalmente, proporcionamos una descripción completa de nuestro modelo propuesto VEPO-S2S, incluido el módulo de representación de trayectoria de embarcaciones multinivel y el módulo de decodificación y fusión de funciones.

4. Definiciones y planteamiento del problema

El objetivo de VEPO-S2S es predecir la trayectoria futura de un buque basándose en AIS datos. Para articular nuestro enfoque más claramente, proporcionamos las siguientes definiciones:

[Trayectoria del barco] Un punto de trayectoria se define como una tupla $x_t = (lon_t, lat_t, sog_t, cog_t, dist_t, l, w, d, t, \alpha, \beta, \gamma)$ en el tiempo t , en el que x_t se compone de longitud lon_t , latitud lat_t , velocidad de rumbo cog_t , distancia de navegación $dist_t$, longitud l , ancho w , calado d , tipo t , ubicación de navegación sog_t , preferencia α , preferencia de tiempo de viaje β y preferencia de tiempo de fondeo γ , respectivamente. La trayectoria de una embarcación $X = (x_{t0}, x_{t1}, \dots, x_{tn})$ se define como una secuencia cronológica, donde $\{t_i, i = 0, 1, 2, \dots, n\}$ es un conjunto de marcas de tiempo.

[Secuencia de posición] La posición del barco en el momento t se define como una tupla $y_t = (lon_t, lat_t)$, y la secuencia de posiciones del barco en el momento $(1, 2, \dots, t)$ se define como $Y = (y_1, y_2, \dots, y_t)$.

[Predicción de la trayectoria del barco] Dada una trayectoria observada $X = (x_1, x_2, \dots, x_t)$ en el instante - marca $(1, 2, 3, \dots, t)$, el objetivo es predecir la trayectoria $Y = (y_{t+1}, y_{t+2}, \dots, y_{t+k})$ en las siguientes marcas de tiempo $(t + 1, t + 2, \dots, t + k)$.

4.1. Preprocesamiento de

datos El preprocesamiento de datos AIS es esencial para entrenar modelos de aprendizaje profundo, especialmente para modelos que requieren información de trayectoria y características de la embarcación. En VEPO-S2S, seleccionamos datos AIS de aguas costeras del suroeste y sureste de EE. UU. para capacitación, validación y prueba. El conjunto de datos incluye atributos estáticos como la identidad del servicio móvil marítimo (MMSI), la longitud y el ancho del buque. Además, abarca información dinámica de la navegación del barco, como longitud, latitud, velocidad y rumbo. Los datos AIS originales pueden experimentar condiciones climáticas adversas durante el proceso de recepción, lo que provoca retrasos en la transmisión de la señal y errores de recepción [48]. Además, el rendimiento de los modelos de aprendizaje profundo podría verse afectado negativamente por la pérdida de datos resultante de problemas técnicos y mantenimiento de equipos. Por lo tanto, realizamos un preprocesamiento integral de los datos AIS antes del entrenamiento (ver Figura 2).




Figura 2. El proceso de preprocesamiento de datos.

El proceso se muestra en los siguientes pasos: (1)

Ordenar y Clasificar: Filtramos embarcaciones con información completa sobre longitud, ancho, calado y tipo, luego separamos los datos de trayectoria de cada embarcación según la Identidad del Servicio Móvil Marítimo (MMSI).) número y los clasificó en orden ascendente de marcas de tiempo.

(2) Denoise: Eliminamos puntos con marcas de tiempo duplicadas y longitud y latitud irrazonables.

(3) Segmento: separamos la trayectoria en diferentes segmentos cuando el intervalo de tiempo entre dos puntos de trayectoria adyacentes superó los 60 min o cuando la distancia entre tres puntos de trayectoria consecutivos fue inferior a 100 m.

(4) Interpolar: empleamos interpolación spline cúbica para garantizar un intervalo de 10 minutos entre puntos consecutivos de la trayectoria.

(5) Calcular: Calculamos el rumbo y la velocidad para cada punto de la trayectoria.

(6) Normalizar: normalizamos la longitud, latitud, velocidad, rumbo, largo, ancho, y calado utilizando el método de normalización mínimo-máximo, como se expresa en la Ecuación (1)

$$x_{norma} = \frac{x - x_{mín}}{x_{máx} - x_{mín}} \quad (1)$$

donde x son los datos originales, xmin y xmax representan el valor mínimo y máximo en los datos de la trayectoria, respectivamente. xnorm son los datos normalizados.

4.2. Construcción de retratos de embarcaciones

Este capítulo logra la construcción de retratos de usuarios de embarcaciones basados en datos AIS, incluido el establecimiento de un sistema de etiquetas y la creación de retratos de embarcaciones.

4.2.1. Construcción del sistema de

etiquetas Como se muestra en la Figura 3, establecimos un sistema de etiquetas basado en atributos de nivel superficial y características de nivel profundo. Los Atributos de nivel poco profundo incluían una serie de atributos fundamentales de una embarcación (como la eslora, la anchura, el calado y el tipo). Estos atributos impactan significativamente el desempeño de maniobra de los buques. Según los estándares de maniobrabilidad del barco [17], tanto la estabilidad del rumbo como la capacidad de giro son indicadores fundamentales de la maniobrabilidad y se ven afectados por el coeficiente de bloqueo del barco. El coeficiente de bloque se define como el desplazamiento de un barco dividido por el producto de su eslora, anchura y calado. Además, diferentes tipos de barcos tienen diferentes coeficientes de bloque debido a variaciones en la forma de sus cascos submarinos. Para buques del mismo desplazamiento, los buques con coeficientes de bloque más pequeños (como los portacontenedores) exhiben una mejor estabilidad de rumbo pero una peor capacidad de giro que aquellos con coeficientes de bloque más grandes (como los petroleros). Por lo tanto, requieren calles de navegación más amplias para reducir el riesgo de colisiones con otras embarcaciones. Además, estos atributos (largo, ancho, calado y tipo) también juegan un papel crucial en la selección de calles, puertos y rutas. Según los manuales de ingeniería costera [49], el ancho de la calle suele ser de dos a cinco veces el ancho del barco. Las embarcaciones deben considerar tanto la anchura como la profundidad a la hora de navegar para garantizar la seguridad y la eficiencia. A la hora de seleccionar el puerto, según PIANC [50], los buques grandes deben elegir puertos con suficiente espacio de atraque y maniobra para garantizar un atraque seguro. En la planificación de rutas, los buques deben considerar su radio de giro y calado, eligiendo rutas adecuadas para evitar el riesgo de encallamiento o colisión. En consecuencia, estos atributos son cruciales para la viabilidad y deben considerarse detenidamente para garantizar predicciones más precisas de los diferentes buques.

Para modelar la información de trayectoria y las características de la embarcación multinivel de manera más efectiva, tomamos en cuenta no solo los atributos de nivel superficial sino también las características de nivel profundo. Las Características de Nivel Profundo se definen como la Preferencia de Lugar de Navegación, la Preferencia de Tiempo de Viaje y la Preferencia de Tiempo de Fondeo. La preferencia de ubicación de navegación refleja el patrón de comportamiento del barco. Por ejemplo, los buques portacontenedores que se dedican al transporte marítimo de línea suelen operar en rutas fijas y dentro de zonas portuarias para la manipulación y el transporte de carga. Las rutas fijas y los horarios regulares del transporte marítimo garantizan la puntualidad de la logística, lo que reduce las pérdidas y mejora los ingresos. Mientras tanto, los arrastreros operan principalmente en zonas de pesca específicas [52], donde sus preferencias de ubicación de navegación están influenciadas por la distribución de los recursos pesqueros. A diferencia del transporte marítimo de línea, los arrastreros tienen un patrón de navegación más flexible, y a menudo ajustan sus lugares de pesca según la temporada, para cumplir con las restricciones regulatorias y aumentar los ingresos. Esta preferencia proporciona una visión más completa

comprensión del comportamiento de los buques y mejora la precisión de la predicción de la trayectoria. En cuanto a la preferencia de tiempo de viaje y la preferencia de tiempo de fondeo, los buques portacontenedores tienden a minimizar el tiempo de fondeo [53], cumpliendo estrictamente los horarios para optimizar la eficiencia operativa. Este modo operativo no sólo garantiza el transporte oportuno de mercancías sino que también ayuda a reducir los costos operativos. Por el contrario, las preferencias de tiempo de viaje de los arrastreros están más influenciadas por las regulaciones de gestión pesquera y las demandas del mercado. Esta información temporal contribuye a una comprensión más profunda de los patrones de comportamiento de los buques y permite que los modelos de predicción capturen con precisión las fluctuaciones en los movimientos de los buques a lo largo del tiempo.




Figura 3. Proceso de análisis y modelado a nivel de etiqueta.

4.2.2. Construcción de retratos de embarcaciones

El retrato de una embarcación consta de atributos de nivel superficial y características de nivel profundo. Con respecto al procesamiento de atributos de nivel superficial, empleamos el siguiente enfoque: en primer lugar, seleccione datos AIS con atributos que no estén vacíos (como largo, ancho, calado y tipo). Y luego seleccionamos aleatoriamente 100 puntos de datos según la identidad del servicio móvil marítimo (MMSI). Para cada atributo, considere el valor con la frecuencia más alta como el atributo de la embarcación actual para construir el perfil poco profundo de la embarcación. Este proceso se puede expresar en la fórmula como Ecuación (2)

$$Y = \{y_i | y_i = \{x_{1, 2, \dots, m}, D_k, X, x_j, P(x_j | D_k) \rightarrow \max\} \quad (2)$$

donde Y representa los atributos de nivel superficial de todos los recipientes, y cada elemento y_i denota los del i -ésimo recipiente. D_k representa la recopilación de datos AIS con atributos completos, X denota el conjunto de atributos de todos los datos AIS y cada elemento x_j representa el valor de frecuencia más alto para D_k .

Después de obtener los atributos de nivel superficial, nos centramos en el proceso de adquisición de características de nivel profundo, que incluyen la preferencia de ubicación de navegación, la preferencia de tiempo de viaje y la preferencia de tiempo de fondeo. Para la preferencia de ubicación de navegación, debido a la diferencia en la cantidad y distribución de los puntos de trayectoria del barco, empleamos HDBSCAN (agrupación espacial jerárquica de aplicaciones con ruido basada en densidad) [54] para el análisis de conglomerados. Los resultados de la agrupación se muestran en la Figura 4. Los diferentes colores representan diferentes agrupaciones y las etiquetas negras indican los centros de agrupación. Mientras tanto, para capturar la preferencia de tiempo de viaje y la preferencia de tiempo de fondeo, dividimos un día en 24 segmentos y asignamos los puntos de trayectoria de cada barco a los períodos correspondientes. La distribución de los puntos de la trayectoria en cada período refleja las preferencias temporales de los buques. Después del procesamiento, el perfil de cada embarcación se puede expresar como la Ecuación (3)

$$Smmsi = \{\text{Immsi}, \text{wmmsi}, \text{dmmsi}, \text{tmmsi}, \text{ammsi}, \beta\text{mmsi}, \gamma\text{mmsi}\} \quad (3)$$

donde $lmmsi$, $wmmsi$, $dmmsi$ y $tmmsi$, respectivamente, representan los atributos de nivel superficial de longitud, ancho, calado y tipo, $\alpha mmsi$ representa la preferencia de tiempo de viaje, $\beta mmsi$ significa Preferencia de tiempo de fondeo y $\gamma mmsi$ es la Preferencia de lugar de navegación. Mientras que $\alpha mmsi$ y $\beta mmsi$ se transforman en dos características de 24 dimensiones, $\gamma mmsi$ se convierte en una característica de 114 dimensiones. La utilización del retrato de embarcación se elabora en Sección 4.3.1.




Figura 4. Resultado del grupo de trayectorias. Diferentes colores representan diferentes grupos, y el negro las etiquetas indican los centros de los grupos.

4.3. Modelo VEPO-S2S

Proponemos un nuevo modelo de predicción de trayectoria VEPO-S2S basado en Seq2Seq modelo, y la estructura se muestra en la Figura 5. Como muestra la figura, VEPO-S2S consiste del Módulo de Representación de Trayectoria de Embarcaciones de Múltiples Niveles (Multi-Rep) y la Función Módulo de Fusión y Decodificación (FFDM). El Multi-Rep tiene como objetivo adquirir trayectoria información y Características del Buque Multinivel, codificándolas con varios codificadores. El FFDM está diseñado para seleccionar y fusionar la información y características anteriores de Multi-Rep para predicción.




Figura 5. La estructura de VEPO-S2S comprende el módulo de representación de trayectoria de embarcaciones multinivel (Multi-Rep) y el módulo de fusión y decodificación de características (FFDM). El Multi-Rep está diseñado para obtener información de trayectoria y características de embarcación multinivel, aplicando distintos codificadores para codificar. El FFDM tiene como objetivo seleccionar e integrar las características anteriores de Multi-Rep para la predicción.

4.3.1. Módulo de representación de trayectoria de embarcaciones multinivel

El módulo de representación de trayectoria de embarcaciones multinivel está diseñado para adquirir información de trayectoria y características de embarcaciones multinivel y aplicar codificadores distintos para la codificación. En esta subsección, presentamos el módulo de representación de trayectoria de embarcaciones de varios niveles, que consta del componente de adquisición de características y el componente de representación de características. Para el Componente de Adquisición de Características, obtuvimos información de trayectoria y Características de la Embarcación de Niveles Múltiples a través del preprocesamiento de datos, como se describe en la Sección 4.1, y la construcción del retrato de la embarcación, como se describe en la Sección 4.2. Simultáneamente, basándose en los modelos RNN y Seq2Seq, introdujimos el componente de representación de características, que consta de tres codificadores distintos. Esos codificadores están diseñados para manejar por separado diferentes características de entrada del comp. El codificador de trayectoria es responsable de codificar la información de la trayectoria (incluida la longitud, latitud, velocidad, rumbo y distancia de navegación). Este proceso se puede expresar mediante la siguiente ecuación (4)

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

donde X_{traj} representa la información de la trayectoria, incluida la longitud, latitud, velocidad, rumbo y distancia de navegación normalizadas para diez puntos de la trayectoria. $H = [h_1, h_2, \dots, h_{10}]$ significa el estado oculto en cada paso de tiempo, h denota el estado oculto en el paso de tiempo final y h representa el estado oculto último. De manera similar al codificador de trayectoria, la tarea del codificador de etiquetas Enclabel es codificar la trayectoria dorada y generar el estado codificado H_y , donde Y_{label} representa cinco puntos de trayectoria que contienen la longitud y la latitud.

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

La tarea del codificador de funciones de retrato es incrustar características de embarcaciones de varios niveles. tics en un vector de alta dimensión. Primero, los valores numéricos continuos normalizados (incluidos el largo, el ancho y el calado) se concatenaron e incrustaron en un vector semántico de ocho dimensiones. En segundo lugar, el tipo de recipiente discreto se transformó en un valor continuo para la entrada del modelo y se integró individualmente en otro vector semántico.

En tercer lugar, codificamos dos características de nivel profundo de 24 dimensiones para capturar la preferencia de tiempo de viaje y la preferencia de tiempo de fondeo (como se menciona en la Sección 4.2.2), mientras que la preferencia de ubicación de navegación se codificó por separado. Finalmente, se concatenaron para formar un vector de características de siete dimensiones, que se ingresó en el codificador de características de retrato para su codificación. Este proceso se puede expresar mediante la siguiente ecuación (6)

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

donde por representa la característica de retrato y embedsp , embedtype , embedtim y $\text{embed}\alpha$ son las capas de incrustación. Encpor es el codificador de funciones verticales. l , w y d representan la longitud, el ancho y el calado, respectivamente, t es el tipo, α representa la preferencia de tiempo de viaje,

β representa la preferencia de tiempo de fondeo y γ es la preferencia de ubicación de navegación (como se menciona en la ecuación (3)).

4.3.2. Módulo de fusión y decodificación de funciones

A pesar de incorporar información de trayectoria y características de la embarcación en el modelo, los modelos básicos Seq2Seq todavía tienen dificultades para discernir y aprovechar de manera eficiente. Por lo tanto, el Módulo de Decodificación y Fusión de Funciones fue diseñado para seleccionar e integrar la información de trayectoria con Características de Embarcación de Niveles Múltiples, aplicando mecanismos a priori y a posteriori en el Componente de Selección de Retratos, un Componente de Fusión de Funciones y un Decodificador de Cabezas Múltiples. El objetivo del componente de selección de retratos es identificar y seleccionar características de embarcaciones multinivel adecuadas para la predicción; por lo tanto, utilizamos una distribución previa y una distribución posterior juntas en la selección de características de la embarcación, y el marco se muestra en la Figura 6. La distribución previa selecciona las características basándose en la similitud entre el vector h del codificador de trayectoria y el vector de retrato, por, que ayuda a filtrar las características más relevantes en las primeras etapas del modelo, reduciendo la sobrecarga computacional. Este proceso se puede expresar como la Ecuación (7)

$$Z_{\text{prior}}(\text{por} = \text{por}_i | h) = \sum_{y_0=1}^7 \frac{\exp(\text{por}_i \cdot h)}{\exp(\text{por}_i \cdot h)} \quad (7)$$

donde por_i ($\text{por}_1, \text{por}_2, \dots, \text{por}_7$), es el producto escalar, h es el vector de codificación de trayectoria y por es el vector de retrato. Específicamente, el modelo asigna pesos más altos a los vectores con mayor similitud al comparar los resultados del producto escalar de diferentes características, reduciendo la interferencia de información redundante y aumentando la eficiencia computacional.




Figura 6. El componente de selección de retratos consta de distribución previa y distribución posterior. La distribución previa expresa el vector de codificación de trayectoria h y la característica de retrato por , y la distribución posterior incorpora la etiqueta y para mejorar la precisión de la selección. Mientras tanto, el KLD está diseñado para cerrar la brecha entre la distribución anterior y la distribución posterior, permitiendo que la distribución anterior se beneficie de la distribución posterior y genere resultados más precisos.

Sin embargo, confiar únicamente en la distribución anterior no puede permitir obtener resultados precisos, ya que normalmente se basa en suposiciones o datos históricos, que no reflejan completamente la situación real; por lo tanto, es imposible seleccionar las características apropiadas para guiar la generación. Por el contrario, las características utilizadas en la etiqueta y se pueden obtener mediante distribución posterior. Por lo tanto, la distribución posterior, derivada de combinar la trayecto

El vector h y la etiqueta y , pueden guiar de manera más efectiva la selección del perfil, que se puede expresar como

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

donde MLP es una capa lineal, $\cdot$ es el producto escalar y $;$ representa el empalme del vector.

Al mismo tiempo, existe una brecha significativa entre la distribución anterior y la distribución posterior. Para abordar este problema, se emplea la pérdida de divergencia Kullback-Leibler (KLD) para obligar a su proximidad. Puede corregir eficazmente errores en la distribución anterior y guiar la selección del perfil en beneficio del modelo. La estabilidad de la divergencia KLD radica en sus propiedades matemáticas, asegurando convergencia y confiabilidad durante el entrenamiento. Al minimizar la pérdida de KLD, el sistema puede lograr un equilibrio adecuado entre las distribuciones anterior y posterior. La fórmula para la divergencia KLD se expresa de la siguiente manera:

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

donde P representa la distribución posterior, que comprende las características requeridas bajo la guía de etiquetas reales.

En general, un enfoque sencillo para aprovechar las características seleccionadas para la generación de resultados es agregar directamente estas características a la entrada del codificador. Sin embargo, este enfoque generalmente no produce resultados satisfactorios debido a la falta de flexibilidad para controlar el grado de participación característica introducida. Por lo tanto, presentamos el componente Feature Fusion para optimizar la utilización de las características. En comparación con conectar directamente esas características, utilizamos una forma más flexible de integrarlas. Aquí, aplicamos un LSTM para fusionar la distribución previa y la trayectoria histórica H , y los resultados del LSTM tomaron en cuenta la continuidad y correlación entre las características a lo largo del tiempo. Además, prior sirvió como estado oculto inicial del LSTM, y la representación de la trayectoria H obtenida por el codificador de trayectoria se utilizó como entrada en cada paso. Finalmente, obtuvimos el vector semántico fusionado c y el proceso se puede expresar mediante la siguiente Ecuación (10)

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

Para regular la participación de las características del recipiente de niveles múltiples en la predicción, introdujimos el componente de decodificación de cabezales múltiples; el diagrama del marco se muestra en la Figura 7. Este componente comprende dos bloques GRU y una unidad de fusión que sintetiza eficientemente los estados ocultos generados por los dos bloques GRU para predecir trayectorias futuras.

El diseño está formulado para ajustar la ponderación entre la información de la trayectoria y las características del buque durante el proceso de predicción. La región naranja es un módulo GRU estándar que recibe la información de trayectoria h . Además, toma el valor de predicción anterior $y - 1$ como entrada, produciendo su estado oculto T_i . Otro GRU se dedica a agregar la distribución anterior a las predicciones; también toma el vector semántico fusionado t , la información de trayectoria h y el valor de predicción anterior $y - 1$ como entradas, generando que p y T se fusionen a través de la puerta de fusión para

la representación de características T_i^w . En última instancia, T_i^w produce la trayectoria final. Este proceso se puede expresar mediante la Ecuación (11):

$$\begin{aligned} y_o^w &= \text{GRU}_n(y - 1, h) \\ \text{inpp} &= \text{concat}(y - 1, c_t^k, \text{anterior}) \\ y_o^w &= \text{GRU}_p(\text{entradapp}, h) \\ O_t &= \sigma(W_z \cdot [\tanh(w_y \cdot T_n); \tanh(W_k \cdot T_p)]) \\ T_i &= O_t \cdot T^w + (1 - O_t) \cdot T_p \end{aligned} \quad (11)$$

donde $i \in \{11, 12, \dots, 15\}$, y W_z , W_y y W_k corresponden a matrices de pesos con diferentes coeficientes. σ y $\tanh$ son la función de activación sigmoidea y la función de activación tanh, respectivamente.




Figura 7. El componente decodificador de cabezales múltiples consta de dos bloques GRU y una unidad de fusión. Puede ajustar de manera flexible la ponderación entre la información de la trayectoria y las características del barco durante el proceso de predicción.

4.3.3. Función de pérdida

El VEPO adopta la raíz del error cuadrático medio (RMSE) y la divergencia de Kullback-Leibler (KLD) (como se menciona en la ecuación (9)) como función de pérdida. El objetivo de este trabajo es utilizar los primeros m puntos indicados por $X_k = (x_{k,1}, x_{k,2}, \dots, x_{k,m})$ para predecir el siguiente n de seguimiento, donde m, n son los hiperparámetros. La secuencia de predicción y el objetivo = $(y_{k,m+1}, y_{k,m+2}, \dots, y_{k,m+n})$. La secuencia y_k está representada por $Y_k = (y_{k,m+1}^k, y_{k,m+2}^k, \dots, y_{k,m+n}^k)$. y $y_k = (y_{k,m+1}, y_{k,m+2}, \dots, y_{k,m+n})$. El objetivo principal es minimizar la función de pérdida durante el entrenamiento, asegurando una mayor precisión en la predicción de los últimos n puntos de la trayectoria. La expresión para la función de pérdida se muestra en la siguiente ecuación (12).

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

5. Experimentos

Para validar la efectividad del modelo VEPO, realizamos una serie de experimentos cuantitativos y cualitativos. Específicamente, primero presentamos la configuración del experimento, incluida la configuración de hiperparámetros, entornos experimentales, conjuntos de datos, modelos de referencia y métricas de evaluación. Posteriormente, presentamos los resultados de la comparación cuantitativa de nuestro método propuesto y otros modelos de referencia. A continuación, describimos los experimentos de ablación realizados para comprobar la eficacia de los diferentes componentes del modelo. Finalmente, representamos los resultados de predicción de VEPO-S2S mediante análisis cualitativo.

5.1. Configuración del experimento

5.1.1. Conjunto de datos

Adoptamos datos AIS (<https://marinecadastre.gov/accessais/>) (consultado el 1 de junio de 2024) desde las aguas costeras del sureste y suroeste de Estados Unidos para entrenamiento, validación y pruebas [13]. Como se muestra en la Tabla 1, hay 68 tipos de embarcaciones y 28,645 embarcaciones en este conjunto de datos. Al mismo tiempo, debido a la particularidad de la construcción del retrato (como se menciona en la Sección 4.2.2), seleccionamos los atributos de la embarcación (incluidos el largo, el ancho, el calado y el tipo). Después del procesamiento, obtuvimos 45 tipos con un total de 6194

vasos. La distribución detallada de los tipos de embarcaciones se muestra en la Figura 8. En nuestro conjunto de datos, el número máximo de tipos de buques era 45, incluidos buques de pasaje, embarcaciones de recreo, veleros, etc. La distribución de los tipos de buques era desigual, clasificándose principalmente en cinco categorías: buques de pasaje, embarcaciones de recreo, veleros, remolcadores y pesqueros. Los buques de pasaje y las embarcaciones de recreo en conjunto representaron más del 23% del total. Los buques restantes, que consisten principalmente en cargueros, portacontenedores y buques cisterna, en conjunto constituyen el 21% del conjunto de datos. Para mejorar la riqueza y exhaustividad de los datos, Empleamos un enfoque de ventana deslizante, dividiendo los datos normalizados en grupos de 15 puntos de trayectoria con un paso deslizante de 1 (ver Figura 9). Posteriormente, cada buque fue asignados a conjuntos de capacitación, validación y pruebas en una proporción de 8:1:1. Este enfoque aumentó la diversidad de los datos y garantizó que cada barco recibiera suficiente validación.

Tabla 1. El detalle de nuestro conjunto de datos.

Conjunto de datos	Región	Recuento de puntos de seguimiento	Tipo Recuento	Recuento de buques
Total	Costa de los Estados Unidos	144.445.580	68	28.645
Nuestra Costa de los Estados Unidos		4.930.061	45	6194




Figura 8. Distribución del tipo de embarcación en nuestro conjunto de datos procesados.




Figura 9. Un ejemplo de división de un conjunto de datos utilizando el método de ventana deslizante y los puntos rojos representan puntos de trayectoria.

5.1.2. Configuración de hiperparámetros y entorno experimental

Utilizamos diez puntos de trayectoria como entradas para predecir los últimos cinco puntos de trayectoria, y esos dos hiperparámetros se pueden ajustar de manera flexible para adaptarse a diferentes tareas. Mientras tanto , las épocas se establecieron en 40 para el entrenamiento de modelos y el mejor desempeño de valoración fue salvado. La tasa de aprendizaje fue 0,001 con una caída de peso de 0,0, se configuró el optimizador a Adam, y el tamaño del lote se estableció en 128. Además, los tamaños ocultos en el GRU fueron

establecido en 64, y el número de capas ocultas era 2. En los hiperparámetros anteriores, seleccionamos dos casos típicos para la visualización, que fueron el número de capas y los tamaños ocultos, cuyos detalles se muestran en las Figuras 10 y 11. Los experimentos Todos se basaron en Python 3.8 utilizando el marco PyTorch. Entrenamos el modelo utilizando el sistema operativo Ubuntu y GTX 3090Ti en el servidor para experimentos.




Figura 10. Influencia de diferentes capas de GRU en la predicción del modelo VEPO-S2S, según el RMSE. El eje X representa el número de capas y el eje Y representa el valor de pérdida de RMSE.




Figura 11. Influencia de diferentes tamaños ocultos en la predicción del modelo VEPO-S2S, según el RMSE. El eje X representa el número de tamaños ocultos y el eje Y representa el valor de pérdida RMSE.

5.1.3. Líneas de base

Para evaluar mejor el rendimiento de VEPO-S2S, lo comparamos con varios modelos de referencia utilizando el mismo conjunto de datos. A diferencia de Seq2Seq, las redes neuronales recurrentes se limitan a predecir múltiples puntos de seguimiento consecutivos. En nuestros experimentos, predijimos continuamente cinco puntos de trayectoria utilizando un RNN, lo que se logró mediante el método de ventana deslizante. Las líneas de base fueron las siguientes:

- (1) Kalman: un modelo de estimación óptima lineal;
- (2) VAR: modelo estadístico para predicción de series temporales multivariadas;
- (3) ARIMA: un modelo de pronóstico estadístico de series de tiempo;
- (4) LSTM: un tipo de red neuronal recurrente, que consta de dos capas;
- (5) BiLSTM: de manera similar a LSTM, BiLSTM se compone de dos LSTM bidireccionales capas;
- (6) GRU: similar a un LSTM;
- (7) BiGRU: similar a un GRU pero con dos capas de GRU bidireccionales;
- (8) LSTM – LSTM: un modelo Seq2Seq con un LSTM de dos capas como codificador y decodificador;

- (9) BiLSTM – LSTM: un modelo Seq2Seq con un BiLSTM de dos capas como codificador y un LSTM de cuatro capas como decodificador;
- (10) GRU – GRU: similar a un LSTM – LSTM; (11)
- BiGRU-GRU: similar a BiLSTM – LSTM; (12)
- Transformador: un modelo Seq2Seq basado en un mecanismo de atención;
- (13) METO-S2S: un método de predicción de la trayectoria del buque basado en S2S con un codificador semántico múltiple y un decodificador orientado a tipos.

5.1.4. Métricas de evaluación

Para evaluar el rendimiento de predicción del modelo propuesto, utilizamos cuatro métricas de evaluación, incluido el error cuadrático medio (RMSE), el error absoluto medio (MAE), el error de desplazamiento promedio (ADE) y el error de desplazamiento final (FDE). El RMSE se centra en medir la estabilidad del resultado, mientras que el MAE evalúa la capacidad de predicción de un modelo. El ADE representa el error de distancia euclidiana promedio entre la posición prevista y la posición real. Además, el FDE se centra en la precisión final de las predicciones.

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

donde y_k y $\hat{y}_k$ representan la posición verdadera y la posición prevista, n es el número total de puntos de seguimiento previstos y $\|\cdot\|_2$ denota una norma y la distancia euclidiana, respectivamente. y_{final} y $\hat{y}_{\text{final}}$ representan la posición final de la trayectoria real y la trayectoria predicha, respectivamente. Vale la pena señalar que cuanto menor sea el índice de evaluación, mejor será la capacidad de generalización del modelo.

5.2. Comparación del desempeño del modelo

5.2.1. Resultados de

la comparación A través de comparaciones con las líneas de base utilizando las métricas de evaluación de RMSE, MAE y ADE, nuestro modelo demostró una gran solidez, como se muestra en las Tablas 2 a 4. LSTM, BiLSTM, GRU y BiGRU emplean un enfoque de ventana deslizante para la predicción de múltiples puntos, mientras que los otros seis modelos Seq2Seq no lo hacen. Nuestro modelo superó las líneas de base en el tercer al quinto punto de la trayectoria. Sin embargo, el GRU obtuvo mejores resultados en el MAE del Cuadro 3 y en el ADE del Cuadro 4, respecto al primer y segundo punto. Esto se debe principalmente a que GRU tiene una ventaja estructural en la predicción de secuencias a corto plazo debido a su simplicidad. Sin embargo, VEPO-S2S experimenta una ligera disminución cuando maneja predicciones a corto plazo, ya que el retrato del barco puede no ser fácilmente discernible. Cuando la longitud de la predicción aumenta, nuestro modelo funciona mejor que los modelos de referencia, según RMSE, MAE y ADE.

Al mismo tiempo, considerando que la predicción de trayectorias también es un problema de pronóstico de series de tiempo, comparamos VEPO-S2S con varios modelos de pronóstico de series de tiempo, incluidos ARIMA, Kalman Filter y VAR. Como muestran las tablas 2 a 4, nuestro modelo fue superior a otros; Los modelos de predicción de tres series temporales tuvieron un buen desempeño en el pronóstico a corto plazo, pero la precisión disminuyó rápidamente a medida que aumentaba el horizonte de pronóstico. Específicamente, el modelo VAR se volvió ineficaz después del tercer paso porque no logró capturar relaciones no lineales complejas a largo plazo. A diferencia de los modelos de series temporales que solo utilizan secuencias de posición, VEPO-S2S se beneficia de información previa adicional, como la eslora de

y ancho, así como su poderosa capacidad para construir correlaciones espaciotemporales a partir de puntos de trayectoria histórica, lo que lo hace más ventajoso en tareas de pronóstico.

Tabla 2. Resultados de comparación de VEPO-S2S con varias líneas de base según la métrica de evaluación RMSE. Aquí, 10->5 representa el valor RMSE de las últimas 5 trayectorias predichas por 10 trayectorias históricas.

Nombre del modelo	10->1	10->2	10->3	10->4	10->5
Kalmán	$2,42 \times 10^{-4}$	$3,00 \times 10^{-4}$	$4,22 \times 10^{-4}$	$2,80 \times 10^{-4}$	$5,51 \times 10^{-4}$
var	$0,98 \times 10^{-4}$	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	$3,16 \times 10^{-4}$	$2,21 \times 10^{-4}$	$3,07 \times 10^{-4}$	$3,99 \times 10^{-4}$	$1,69 \times 10^{-4}$
LSTM-LSTM	$1,22 \times 10^{-4}$	$2,49 \times 10^{-4}$	$3,36 \times 10^{-4}$	$2,21 \times 10^{-4}$	$3,14 \times 10^{-4}$
BiLSTM-LSTM	$1,44 \times 10^{-4}$	$1,74 \times 10^{-4}$	$2,35 \times 10^{-4}$	$3,07 \times 10^{-4}$	$2,03 \times 10^{-4}$
GRU-GRU	$0,98 \times 10^{-4}$	$2,28 \times 10^{-4}$	$2,73 \times 10^{-4}$	$1,11 \times 10^{-4}$	$1,71 \times 10^{-4}$
BiGRU-GRU	$1,34 \times 10^{-4}$	$2,40 \times 10^{-4}$			
Transformador					$5,12 \times 10^{-4}$
METO-S2S					$3,86 \times 10^{-4}$
Nuestro					$3,35 \times 10^{-4}$
					$3,17 \times 10^{-4}$

Tabla 3. Resultados de comparación de VEPO-S2S con varias líneas de base según la métrica de evaluación MAE. Aquí, 10->5 medias predichas a través de 10 trayectorias históricas.

Nombre del modelo	10->1	10->2	10->3	10->4	10->5
Kalmán	$1,73 \times 10^{-4}$	$2,34 \times 10^{-4}$	$3,27 \times 10^{-4}$	$4,24 \times 10^{-4}$	$5,16 \times 10^{-4}$
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	$0,43 \times 10^{-4}$	$0,77 \times 10^{-4}$	$1,66 \times 10^{-4}$	$1,87 \times 10^{-4}$	$2,35 \times 10^{-4}$
BiLSTM	$1,50 \times 10^{-4}$	$1,52 \times 10^{-4}$	$1,01 \times 10^{-4}$	$1,42 \times 10^{-4}$	$2,87 \times 10^{-4}$
gru	$0,36 \times 10^{-4}$	$0,66 \times 10^{-4}$	$1,84 \times 10^{-4}$	$2,15 \times 10^{-4}$	$1,34 \times 10^{-4}$
BiGRU	$1,53 \times 10^{-4}$	$1,65 \times 10^{-4}$	$1,72 \times 10^{-4}$	$1,56 \times 10^{-4}$	$1,94 \times 10^{-4}$
LSTM-LSTM	$0,70 \times 10^{-4}$	$1,00 \times 10^{-4}$	$1,10 \times 10^{-4}$	$1,46 \times 10^{-4}$	$2,13 \times 10^{-4}$
BiLSTM-LSTM	$0,88 \times 10^{-4}$	$1,20 \times 10^{-4}$	$1,50 \times 10^{-4}$	$1,92 \times 10^{-4}$	$1,16 \times 10^{-4}$
GRU-GRU	$0,51 \times 10^{-4}$	$0,78 \times 10^{-4}$	$1,42 \times 10^{-4}$	$1,53 \times 10^{-4}$	$1,85 \times 10^{-4}$
BiGRU-GRU	$0,74 \times 10^{-4}$	$1,10 \times 10^{-4}$	$1,70 \times 10^{-4}$	$0,99 \times 10^{-4}$	$1,28 \times 10^{-4}$
Transformador	$1,43 \times 10^{-4}$	$0,95 \times 10^{-4}$	10^{-4}		
METO-S2S		$1,46 \times 10^{-4}$			$1,72 \times 10^{-4}$
Nuestro		$0,74 \times 10^{-4}$			$1,94 \times 10^{-4}$
					$1,60 \times 10^{-4}$

Tabla 4. Resultados de comparación de VEPO-S2S con varias líneas de base según la métrica de evaluación ADE. Aquí, 10->5 medias predichas a través de 10 trayectorias históricas.

Nombre del modelo	10->1	10->2	10->3	10->4	10->5
Kalmán	$3,42 \times 10^{-4}$	$4,62 \times 10^{-4}$	$8,22 \times 10^{-4}$	$11,52 \times 10^{-4}$	$14,29 \times 10^{-4}$
var	$1,38 \times 10^{-4}$	$5,60 \times 10^{-4}$	$123,53 \times 10^{-4}$	-	-
ARIMA	$4,83 \times 10^{-4}$	$7,11 \times 10^{-4}$	$9,42 \times 10^{-4}$	$11,76 \times 10^{-4}$	$14,14 \times 10^{-4}$
LSTM	$0,68 \times 10^{-4}$	$1,22 \times 10^{-4}$	$1,87 \times 10^{-4}$	$2,64 \times 10^{-4}$	$3,51 \times 10^{-4}$
BiLSTM	$2,37 \times 10^{-4}$	$2,38 \times 10^{-4}$	$2,99 \times 10^{-4}$	$3,74 \times 10^{-4}$	$4,56 \times 10^{-4}$
gru	$0,59 \times 10^{-4}$	$1,05 \times 10^{-4}$	$1,62 \times 10^{-4}$	$2,27 \times 10^{-4}$	$2,99 \times 10^{-4}$
BiGRU	$2,42 \times 10^{-4}$	$2,73 \times 10^{-4}$	$4,00 \times 10^{-4}$	$4,91 \times 10^{-4}$	$5,20 \times 10^{-4}$
LSTM-LSTM	$1,11 \times 10^{-4}$	$1,59 \times 10^{-4}$	$2,13 \times 10^{-4}$	$2,73 \times 10^{-4}$	$3,38 \times 10^{-4}$
LSTM 1,39 $\times 10^{-4}$ GRU-GRU 0,80		$1,90 \times 10^{-4}$	$2,47 \times 10^{-4}$	$3,07 \times 10^{-4}$	$3,72 \times 10^{-4}$
$\times 10^{-4}$ BiGRU-GRU 1,16 $\times 10^{-4}$		$1,23 \times 10^{-4}$	$1,74 \times 10^{-4}$	$2,31 \times 10^{-4}$	$2,93 \times 10^{-4}$
$1,28 \times 10^{-4}$ 2,26 $\times 10^{-4}$ 0,83 $\times 10^{-4}$		$1,75 \times 10^{-4}$	$2,38 \times 10^{-4}$	$3,05 \times 10^{-4}$	$3,76 \times 10^{-4}$
Transformador		$1,50 \times 10^{-4}$	$1,83 \times 10^{-4}$	$2,25 \times 10^{-4}$	$2,73 \times 10^{-4}$
METO-S2S		$2,30 \times 10^{-4}$	$2,41 \times 10^{-4}$	$2,68 \times 10^{-4}$	$3,07 \times 10^{-4}$
Nuestro		$1,17 \times 10^{-4}$	$1,52 \times 10^{-4}$	$2,01 \times 10^{-4}$	$2,52 \times 10^{-4}$

5.2.2. Exploración de la estructura Seq2Seq de VEPO-S2S

Realizamos varios experimentos sobre la estructura del codificador y decodificador en VEPO-S2S para lograr un rendimiento óptimo, incluido un VEPO-BiGRU-GRU, un VEPO-LSTM- LSTM, un VEPO-BiLSTM-LSTM y un VEPO-GRU-GRU. Como se muestra en la Tabla 5, la mejor El resultado se obtuvo con el VEPO-GRU-GRU. Por lo tanto, en los experimentos posteriores, Utilizamos el VEPO-S2S con una estructura GRU-GRU para realizar más experimentos.

Tabla 5. Resultados de la exploración en diferentes estructuras Seq2Seq.

Codificador de nombre de modelo		Decodificador RMSE	MAE	ADE	FDE	
VEPO-S2S	BiGRU	GRU	$3,60 \times 10^{-4}$	$1,99 \times 10^{-4}$	$3,15 \times 10^{-4}$	$5,28 \times 10^{-4}$
VEPO-S2S	LSTM	LSTM	$3,46 \times 10^{-4}$	$1,72 \times 10^{-4}$	$2,72 \times 10^{-4}$	$4,94 \times 10^{-4}$
VEPO-S2S	BiLSTM	LSTM	$4,19 \times 10^{-4}$	$2,48 \times 10^{-4}$	$3,39 \times 10^{-4}$	$5,97 \times 10^{-4}$
VEPO-S2S	gru	GRU	$3,17 \times 10^{-4}$	$1,60 \times 10^{-4}$	$2,52 \times 10^{-4}$	$4,57 \times 10^{-4}$

5.2.3. Análisis mas extenso

A diferencia de la evaluación de tareas de predicción de trayectoria continua, realizamos una evaluación de puntos individuales utilizando RMSE, MAE y FDE. Como podemos ver en las tablas 6 a 8, los errores de predicción de todos los modelos mostraron un aumento notable desde el primero al Quinto punto de predicción. Esto se atribuye a una reducción significativa de la información disponible para cada predicción, al pasar de la primera a la última predicción. Línea de base RNN Los modelos emplean un enfoque de ventana deslizante para la predicción y acumulan gradualmente imprecisiones con cada predicción. Por el contrario, los modelos de referencia Seq2Seq tienen la capacidad para predecir simultáneamente múltiples puntos, lo que puede reducir la tendencia a la escalada de errores en comparación con los modelos de referencia RNN. Además, los modelos de series temporales se basan sobre relaciones lineales entre múltiples series temporales; sin embargo, en la predicción a largo plazo tareas, las características no lineales se vuelven más prominentes, lo que provoca que las imprecisiones aumenten rápidamente con el tiempo. Además, nuestro modelo casi supera todas las líneas de base. También observamos un rendimiento similar entre METO-S2S y VEPO-S2S en los puntos cuarto y quinto en Figura 6, que indica que tanto VEPO como METO son modelos excelentes para secuencias largas Tareas de predicción.

Tabla 6. Resultados del análisis cuantitativo de cada punto de la trayectoria bajo el índice de evaluación RMSE.

Nombre del modelo	Primero	Segundo	Tercero	Cuatro	Quinto
Kalmán	$2,42 \times 10^{-4}$	$3,27 \times 10^{-4}$	$5,81 \times 10^{-4}$	$3,74 \times 10^{-4}$	$8,15 \times 10^{-4}$
var	$0,98 \times 10^{-4}$	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	$1,34 \times 10^{-4}$	$2,82 \times 10^{-4}$	$4,45 \times 10^{-4}$	$6,17 \times 10^{-4}$	$7,96 \times 10^{-4}$
Transformador	$1,31 \times 10^{-4}$	$2,08 \times 10^{-4}$	$3,24 \times 10^{-4}$	$4,59 \times 10^{-4}$	$6,07 \times 10^{-4}$
METO-S2S	$2,02 \times 10^{-4}$	$2,03 \times 10^{-4}$	$2,71 \times 10^{-4}$	$3,76 \times 10^{-4}$	$5,23 \times 10^{-4}$
Nuestro	$0,74 \times 10^{-4}$	$1,44 \times 10^{-4}$	$2,47 \times 10^{-4}$	$3,76 \times 10^{-4}$	$5,22 \times 10^{-4}$

Tabla 7. Resultados del análisis cuantitativo de cada punto de la trayectoria bajo el índice de evaluación MAE.

Nombre del modelo	Primero	Segundo	Tercero	Cuatro	Quinto
Kalmán	$1,73 \times 10^{-4}$	$2,94 \times 10^{-4}$	$5,13 \times 10^{-4}$	$3,38 \times 10^{-4}$	$7,13 \times 10^{-4}$
var	$0,87 \times 10^{-4}$	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	$0,88 \times 10^{-4}$	$1,53 \times 10^{-4}$	$2,28 \times 10^{-4}$	$3,08 \times 10^{-4}$	$3,98 \times 10^{-4}$
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	$1,34 \times 10^{-4}$	$2,82 \times 10^{-4}$	$4,45 \times 10^{-4}$	$6,17 \times 10^{-4}$	$7,96 \times 10^{-4}$
Transformador	$0,81 \times 10^{-4}$	$1,09 \times 10^{-4}$	$1,58 \times 10^{-4}$	$2,20 \times 10^{-4}$	$2,93 \times 10^{-4}$
S2S	$0,53 \times 10^{-4}$	$2,03 \times 10^{-4}$	$2,21 \times 10^{-4}$	$2,71 \times 10^{-4}$	$2,92 \times 10^{-4}$
METO-S2S	10^{-4}	$0,96 \times 10^{-4}$	$1,48 \times 10^{-4}$	$2,13 \times 10^{-4}$	$2,88 \times 10^{-4}$
Nuestro					

Tabla 8. Resultados del análisis cuantitativo de cada punto de la trayectoria bajo el índice de evaluación FDE.

Nombre del modelo	Primero	Segundo	Tercero	Cuatro	Quinto
Kalmán	$3,42 \times 10^{-4}$	$4,62 \times 10^{-4}$	$8,22 \times 10^{-4}$	$11,52 \times 10^{-4}$	$14,29 \times 10^{-4}$
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	$1,39 \times 10^{-4}$	$2,41 \times 10^{-4}$	$3,61 \times 10^{-4}$	$4,89 \times 10^{-4}$	$6,32 \times 10^{-4}$
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	$1,16 \times 10^{-4}$	$2,23 \times 10^{-4}$	$3,65 \times 10^{-4}$	$5,06 \times 10^{-4}$	$6,60 \times 10^{-4}$
Transformador	$2,22 \times 10^{-4}$	$1,72 \times 10^{-4}$	$2,50 \times 10^{-4}$	$3,50 \times 10^{-4}$	$4,67 \times 10^{-4}$
METO-S2S	$0,83 \times 10^{-4}$	$2,30 \times 10^{-4}$	$2,71 \times 10^{-4}$	$3,49 \times 10^{-4}$	$4,62 \times 10^{-4}$
Nuestro		$1,51 \times 10^{-4}$	$2,34 \times 10^{-4}$	$3,37 \times 10^{-4}$	$4,57 \times 10^{-4}$

El modelo VEPO-S2S propuesto consta del módulo de representación de trayectoria de embarcaciones multinivel (Multi-Rep) y el módulo de fusión y decodificación de características (FFDM). El Multi-Rep está diseñado específicamente no sólo para integrar información de trayectoria sino también para considerar plenamente las características del barco y las preferencias de comportamiento, codificándolas con distintos

codificadores para enriquecer la representación de características. Además, el FFDM selecciona y integra la información y las características anteriores en función del entorno de predicción actual, lo que permite que el modelo los aproveche de manera eficiente. Estas dos ventajas hacen que VEPO-S2S más precisa que las otras líneas de base.

5.3. Estudio de ablación

Investigar la función de las características del recipiente multinivel en VEPO-S2S y En el módulo de fusión y decodificación de funciones, diseñamos varios experimentos de ablación, que se introducen en la siguiente parte:

- 1. sin sa. Eliminar la entrada de los atributos de nivel poco profundo en el recipiente multinivel
Módulo de representación de trayectoria, incluida la longitud, el ancho, el calado y el tipo de la embarcación. (ver Sección 4.3.1);
- 2. sin k1. Eliminar la preferencia de ubicación de navegación en la trayectoria del barco de varios niveles
Módulo de Representación (ver Sección 4.3.1);
- 3. sin k2. Eliminar la preferencia de tiempo de viaje de la trayectoria del barco de varios niveles
Módulo de Representación (ver Sección 4.3.1);
- 4. sin k3. Eliminar la preferencia de tiempo de fondeo de la trayectoria de embarcación de varios niveles
Módulo de Representación (ver Sección 4.3.1);
- 5. sin p_s. Elimine el componente de selección de retrato de Feature Fusion y
Módulo de decodificación (ver Sección 4.3.2);
- 6. con / de _f. Eliminar el componente Feature Fusion de Feature Fusion and Decoding
Módulo (ver Sección 4.3.2);
- 7. sin muti_d. Elimine el componente decodificador de cabezales múltiples de Feature Fusion y
Módulo de decodificación, que utiliza en su lugar un único GRU para decodificar, que no recibe información de trayectoria por separado (ver Sección 4.3.2).

Los resultados se muestran en la Tabla 9. Evaluamos el desempeño utilizando el RMSE, MAE, ADE y FDE. Los resultados indican que la eliminación del componente de selección de retrato tuvo el impacto más significativo en la métrica RMSE, reduciéndola de $3,17 \times 10^{-4}$ a $4,48 \times 10^{-4}$. Esto indica que el componente de selección de retrato juega un papel crucial en el modelo. Esto se debe a que el componente de selección de retrato es responsable de seleccionar las características del buque que son más adecuadas para el entorno actual. Cuando el Si se elimina el componente de selección de retrato, el rendimiento del modelo disminuye significativamente. Además, se observa que la eliminación del Componente Decodificador Multicabezal tuvo el efecto menor impacto, con una disminución de $3,17 \times 10^{-4}$ a $3,32 \times 10^{-4}$. Esto se debe a que mejorar el decodificador no afecta la estructura general. El modelo todavía tiene la capacidad de seleccionar y aprenda a utilizar las características correspondientes para generar predicciones precisas. Sin embargo, reforzar el decodificador conduce a una ligera mejora en el rendimiento del modelo. De acuerdo con el análisis anterior, las métricas de evaluación MAE, ADE y FDE exhibieron tendencias similares.

Tabla 9. Resultados cuantitativos de diferentes estudios de ablación.

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

Después de eliminar varias innovaciones, el rendimiento del modelo disminuyó. Por eso, el modelo está equipado con todas las características y componentes para lograr una óptima resultados, demostrando la eficacia de nuestros puntos innovadores.

5.4. Analisis cualitativo

Para analizar mejor el rendimiento de VEPO-S2S, seleccionamos varias comparaciones modelos disponibles para varios análisis cualitativos, como se describe en esta subsección.

5.4.1. Comparación de líneas de base

Como se muestra en la Figura 12, nuestro modelo logró predicciones precisas en ambos escenarios. en comparación con otras líneas de base. La dificultad de la predicción aumentó de (a) a (b). En un), el carguero tenía una ruta recta. La mayoría de los modelos produjeron predicciones satisfactorias, especialmente VEPO y METO. Sin embargo, el GRU se desvió de su verdadera trayectoria. (b) muestra un portacontenedores girando, donde nuestro modelo se desempeña mejor. Además, el METO-S2S El modelo predijo con precisión los primeros cuatro puntos, pero se desvió de la trayectoria real en el último punto. El modelo GRU-GRU funciona mejor que el modelo GRU; sin embargo, todavía lucha por lograr resultados de predicción satisfactorios. En la práctica, las predicciones incorrectas pueden fácilmente provocar accidentes. Se puede observar que los resultados predichos por VEPO-S2S fueron superior a otros, lo que puede evitar problemas de seguridad.




Figura 12. Las predicciones de buques de carga y portacontenedores bajo varios modelos, con el la dificultad de las predicciones aumenta de (a) a (b). Nuestro modelo funciona mejor en ambos escenarios. En (a), que implica la navegación en línea recta de buques de carga, todos los modelos excepto GRU logran una navegación decente resultados de predicción. En (b), que implica el giro de un buque portacontenedores. Además, el modelo METO-S2S También es capaz de realizar las tareas de predicción hasta cierto punto. Sin embargo, otros modelos luchan por lograr un rendimiento de predicción satisfactorio.

5.4.2. Resultado visual de la estructura Seq2Seq

Como podemos ver en la Figura 13, VEPO-GRU-GRU es más robusto en comparación con VEPO- BiGRU-GRU, VEPO-BiLSTM-LSTM y VEPO-LSTM-LSTM. (a) representa una trayectoria suave, que indica la navegación normal de un buque de carga. (b) muestra una trayectoria curva, posiblemente sugiriendo maniobras de evasión por parte de un petrolero. En varios tipos de embarcaciones y estados de movimiento, todas las estructuras del modelo VEPO-S2S exhiben consistentemente satisfactorio actuación. En particular, el modelo VEPO-S2S con estructura GRU-GRU muestra mejor robustez.




Figura 13. Las predicciones de trayectoria del carguero y petrolero utilizando diferentes estructuras del Modelo VEPO-S2S, con la dificultad predictiva aumentando gradualmente de (a) a (b). Como se muestra en En el gráfico, VEPO-GRU-GRU logra el mejor rendimiento predictivo.

5.4.3. Resultados de ablación cualitativa

Realizamos varios estudios detallados para ilustrar mejor los cambios en los resultados experimentales antes y después de la ablación. Siete figuras muestran los resultados de los experimentos en los atributos de nivel poco profundo, la preferencia de ubicación de navegación, la preferencia de tiempo de viaje, la preferencia de tiempo de anclaje, el componente de selección de retrato, la fusión de características Componente y el Componente Decodificador Multicabezal para un remolcador. Más precisamente, nosotros presentar cuatro trayectorias en cada imagen, incluidos los puntos de seguimiento de entrada, las etiquetas y el Resultados predictivos antes y después de la ablación.

Para cada figura, es evidente que la curva verde se alinea estrechamente con la trayectoria real. Observamos que si un barco carece de alguno de los atributos de nivel poco profundo, el lugar de navegación Preferencia de tiempo de viaje o Preferencia de tiempo de fondeo, existen sesgos significativos tanto en la dirección como en la distancia en los resultados previstos.

La Figura 14 ilustra los resultados con y sin atributos de nivel superficial. En el ausencia de atributos de nivel superficial, las predicciones de VEPO-S2S se desvían de la trayectoria real en los puntos cuarto y quinto. Esto se debe a que los atributos de nivel superficial determinan la inercia del buque y su capacidad de giro. Normalmente, los buques más grandes tienen más dificultades en alterar sus estados de movimiento actuales. Cuando faltan atributos de nivel superficial, el modelo lucha por evaluar con precisión estas capacidades de la embarcación. Por lo tanto, a largo plazo predicciones, el modelo no proporciona una guía efectiva y conduce a desviaciones de las trayectoria correcta en etapas posteriores.




Figura 14. Las trayectorias previstas de un remolcador, donde las líneas verde y roja son la predicción. resultados utilizando VEPO-S2S con y sin atributos de nivel superficial, respectivamente. El nivel superficial Los atributos están asociados con la inercia y la capacidad de giro de la embarcación. El modelo sin Los atributos de nivel superficial no pueden captar bien esta habilidad, lo que puede causar errores.

La Figura 15 muestra los resultados con y sin la preferencia de ubicación de navegación. La preferencia de ubicación de navegación ayuda al modelo a reconocer la adaptabilidad de una embarcación al terreno.

Los buques con distintos grados de adaptabilidad a los terrenos eligen diferentes métodos para evitar colisiones. Sin la preferencia de ubicación de navegación, el modelo tiene dificultades para capturar detalles de rutas, lo que dificulta la generación de elecciones correspondientes y conduce a oscilaciones en las trayectorias previstas.




Figura 15. Las trayectorias previstas de un remolcador, donde las líneas verde y roja representan los resultados de predicción de VEPO-S2S con y sin considerar la preferencia de ubicación de navegación, respectivamente. La preferencia de ubicación de navegación ayuda al modelo a identificar la adaptabilidad de la embarcación al entorno geográfico. Cuando no se considera la preferencia de ubicación de navegación, el modelo VEPO-S2S no es correcto.

La Figura 16 muestra los resultados de la comparación con y sin la preferencia de tiempo de viaje. La preferencia de tiempo de viaje refleja los hábitos de las tripulaciones y de los barcos que navegan en varios momentos. Por ejemplo, las maniobras para evitar colisiones son diferentes durante períodos de alto y bajo tráfico de buques. Sin la orientación de la preferencia de tiempo de viaje, los resultados previstos presentan fluctuaciones considerables.




Figura 16. Las trayectorias previstas de un remolcador, donde las líneas verde y roja representan la resultados de predicción del modelo VEPO-S2S con y sin considerar la preferencia de tiempo de viaje, respectivamente. La preferencia de tiempo de viaje está relacionada con los hábitos de las tripulaciones. Cuando llega la hora del viaje No se considera preferencia, el modelo VEPO-S2S puede producir predicciones inexactas.

La Figura 17 muestra los resultados con y sin la Preferencia de Tiempo de Anclaje, que está relacionado con los hábitos de trabajo y descanso. La trayectoria del remolcador cambia más significativamente cuando está en condiciones de funcionamiento. Por lo tanto, es difícil para el modelo determinar con precisión el movimiento actual del remolcador sin el tiempo de fondeo Preferencia, que conduce a desviaciones de los verdaderos puntos de la trayectoria.




Figura 17. Las trayectorias predichas de un remolcador, donde las líneas verde y roja representan los resultados de predicción del modelo VEPO-S2S con y sin considerar la preferencia de tiempo de fondeo, respectivamente. La preferencia de tiempo de anclaje ayuda al modelo a identificar los hábitos de trabajo y descanso del buque. En ausencia de la preferencia de tiempo de anclaje, el modelo produce un error estimación para cada marca de tiempo.

La Figura 18 muestra los resultados de la comparación visual del componente de selección de retratos. Sin el componente de selección de retrato, el resultado se desvía de la pista real. Esto se debe a que el componente de selección de retratos puede seleccionar las características más relevantes para predicción y sin ella, se pueden introducir características irrelevantes en la predicción. proceso, lo que resulta en desviaciones significativas en los resultados previstos.




Figura 18. Las trayectorias previstas de un remolcador, donde las líneas verde y roja son la predicción. resultados utilizando VEPO-S2S con y sin el componente de selección de retrato, respectivamente. El retrato El componente de selección es responsable de seleccionar las características más relevantes para la predicción. Sin este componente, el modelo no puede seleccionar características apropiadas para ayudar en la predicción. lo que lleva a una disminución en la robustez del modelo.

La Figura 19 muestra los resultados de la comparación visual del componente Feature Fusion, que integra eficazmente la información de la trayectoria con las características de la embarcación y mejora la correlación entre ellos. Sin el componente Feature Fusion, las características de la embarcación lucha por expresarse plenamente, lo que conduce a predicciones incorrectas.




Figura 19. Las trayectorias previstas de un remolcador, donde las líneas verde y roja son la predicción. resultados de VEPO-S2S con y sin componente fusionado, respectivamente. La característica fusionada El componente integra eficazmente la información de la trayectoria y las características del barco y aumenta la correlación entre ambos. Sin el componente fusionado característico, las características de la embarcación son difíciles expresarse adecuadamente en el modelo VEPO-S2S, lo que lleva a una disminución en la precisión del modelo.

La Figura 20 indica los resultados de la comparación del componente decodificador de cabezales múltiples. que puede ajustar el nivel de participación en la información de la trayectoria y las características de la embarcación. La adaptabilidad del modelo disminuye al retirar el componente decodificador de cabezales múltiples. Según estos estudios de ablación, el modelo VEPO-S2S demuestra una precisión satisfactoria y robustez.




Figura 20. Las trayectorias previstas de un remolcador, donde las líneas verde y roja son los resultados de la predicción utilizando VEPO-S2S con y sin el componente decodificador multicabezal, respectivamente. El componente decodificador de cabezales múltiples regula la participación de la información de trayectoria y características del buque en el proceso de predicción. Sin él, la adaptabilidad del modelo VEPO-S2S disminuye. Arrugas.

6. Conclusiones

A través de un estudio de la literatura relevante, encontramos que las características de los vasos y el comportamiento Las preferencias tienen un impacto significativo en las trayectorias. Por lo tanto, este estudio propone una nueva modelo de predicción de trayectoria, VEPO-S2S, que considera completamente la información de la trayectoria, características de los vasos y preferencias de comportamiento. VEPO-S2S consta de dos partes: el multinivel Módulo de representación de trayectoria de embarcaciones y módulo de fusión y decodificación de características. El módulo de representación de trayectoria de embarcaciones multinivel obtiene información de trayectoria (como longitud, latitud, rumbo, velocidad y distancia de navegación) junto con las características de la embarcación de varios niveles, que abarcan atributos de nivel poco profundo (eslora, tipo, y calado) y características de nivel profundo (preferencia de ubicación de navegación, preferencia de tiempo de viaje, y preferencia temporal de fondeo). Estos se codifican mediante múltiples codificadores. La característica El Módulo de Fusión y Decodificación tiene como objetivo seleccionar las características del buque más relevantes para el entorno de predicción actual e integrarlos con la información de trayectoria antes

decodificación con un decodificador mejorado. Los resultados experimentales demuestran que este modelo supera cualitativamente a otros modelos de referencia y muestra un rendimiento excelente en mapas basados en cuadrículas.

7. Trabajos futuros

En este trabajo, tomamos en cuenta el impacto de las características y preferencias más allá de la información de la trayectoria en la predicción de la trayectoria. En el futuro, nuestro objetivo es optimizar nuestro modelo para mejorar la eficiencia y la precisión de la predicción, validado en más conjuntos de datos de navegación globales. Además, exploraremos otros modelos destacados, como el modelo grande de series temporales. Además, existen otros factores que influyen en los movimientos de las embarcaciones, como el clima, las condiciones del mar, las corrientes oceánicas y los arrecifes. Por lo tanto, nuestro objetivo es incorporar más factores influyentes en el proceso de modelado y realizar más investigaciones en escenarios más complejos.

Contribuciones de los autores: Conceptualización, ZH; metodología, ZH y XY; software, SL; validación, HL y JL; análisis formal, YZ; investigación, YZ y HL; recursos, NS; curación de datos, WA; redacción: preparación del borrador original, XY; redacción: revisión y edición, ZH; visualización, WA y XY; supervisión, SL y JL. Todos los autores han leído y aceptado la versión publicada del manuscrito.

Financiamiento: Esta investigación fue financiada por la Fundación de Ciencias Naturales de la provincia de Zhejiang, China, bajo la subvención LY21E090005, y el Proyecto de la Oficina de Ciencia y Tecnología de Zhoushan (2021C21010).

Declaración de la Junta de Revisión Institucional: No aplicable.

Declaración de Consentimiento Informado: No aplicable.

Declaración de disponibilidad de datos: todos los datos utilizados en este documento se pueden descargar del sitio web público: marinecadastre.gov/accessais (consultado el 31 de diciembre de 2021).

Conflictos de intereses: Los autores declaran no tener ningún conflicto de intereses.

Abreviaturas

En este manuscrito se utilizan las siguientes abreviaturas:

AIS	Sistema de identificación automática
Sec2Seq	Red secuencia a secuencia, el modelo
VEPO	orientado verticalmente de Vessel
Módulo de representación de trayectoria de embarcaciones de múltiples niveles y múltiples reps.	
FDM	el módulo de fusión y decodificación de funciones

Referencias

1. Yang, CH-H.; Wu, CH-H.; Shao, J.-C.; Wang, Y.-C.; Hsieh, C.-M. Predicción inteligente de la trayectoria de los buques basada en AIS utilizando bi-lstm. Acceso IEEE 2022, 10, 24302–24315.
2. Fossen, S.; Fossen, TI Diseño de filtro Kalman extendido y predicción de movimiento de barcos utilizando datos en vivo del sistema de identificación automática (ais). En Actas de la Segunda Conferencia Europea sobre Ingeniería Eléctrica e Informática (EECS) de 2018, Berna, Suiza, 20 a 22 de diciembre de 2018; págs. 464–470.
3. Kawan, B.; Wang, H.; Li, G.; Chhantyal, K. Modelado basado en datos de la predicción del movimiento del barco basado en la regresión del vector de soporte. En Actas del 58.º SIMS, Reykjavik, Islandia, 25 a 27 de septiembre de 2017.
4. Li, H.; Jiao, H.; Yang, Z. Predicción de la trayectoria del barco basada en el aprendizaje automático y el aprendizaje profundo: una revisión sistemática y un análisis de métodos. Ing. Aplica. Artif. Intel. 2023, 126, 107062.
5. Suo, Y.; Chen, W.; Claramunt, C.; Yang, S. Un marco de predicción de la trayectoria de un barco basado en una red neuronal recurrente. Sensores 2020, 20, 5133.
6. Wang, C.; Ren, H.; Li, H. Predicción de la trayectoria del buque basada en datos ais y gru bidireccional. En Actas de la Conferencia Internacional sobre Visión por Computadora, Imagen y Aprendizaje Profundo (CVIDL) de 2020, IEEE, Nanchang, China, 15 a 17 de mayo de 2020; págs. 260–264.
7. Tang, H.; Yin, Y.; Shen, H. Un modelo para la predicción de la trayectoria de los vasos basado en una red neuronal de memoria a corto plazo. J. Mar. Ing. Tecnología. 2022, 21, 136-145.

8. Parque, J.; Jeong, J.; Park, Y. Predicción de la trayectoria del barco basada en bi-LSTM utilizando datos AIS agrupados espectralmente. *J. Mar. Ciencias. Ing.* 2021, 9, 1037.
9. Zhang, S.; Wang, L.; Zhu, M.; Chen, S.; Zhang, H.; Zeng, Z. Un método de predicción de trayectoria de barco lstm bidireccional basado en un mecanismo de atención. En *actas de la Quinta Conferencia de Control de Automatización, Electrónica y Tecnología de la Información Avanzada (IAEAC) de IEEE de 2021, IEEE, Chongqing, China*, 12 a 14 de marzo de 2021; págs. 1987–1993.
10. Bao, K.; Bi, J.; Gao, M.; Sol, Y.; Zhang, X.; Zhang, W. Una predicción mejorada de la trayectoria del barco basada en datos ais utilizando mha-bigrú. *J. Mar. Ciencias. Ing.* 2022, 10, 804.
11. Wu, W.; Chen, P.; Chen, L.; Mou, J. Predicción de la trayectoria del barco: un enfoque integrado que utiliza un modelo de secuencia a secuencia basado en conflictos. *J. Mar. Ciencias. Ing.* 2023, 11, 1484.
12. Nguyen, D.-D.; Van, CL; Ali, MI Predicción de la trayectoria del buque utilizando modelos de secuencia a secuencia sobre una cuadrícula espacial. En *Actas de la 12.ª Conferencia Internacional ACM sobre Sistemas Distribuidos y Basados en Eventos, Lyon, Francia, 25 a 28 de junio de 2018*; págs. 258–261.
13. Zhang, Y.; Han, Z.; Zhou, X.; Li, B.; Zhang, L.; Zhen, E.; Wang, S.; Zhao, Z.; Guo, Z. Meto-s2s: un método de predicción de la trayectoria del buque basado en s2s con codificador semántico múltiple y decodificador orientado a tipos. *Océano. Ing.* 2023, 277, 114248.
14. Zhao, J.; Yan, Z.; Chen, X.; Han, B.; Wu, S.; Ke, R. k-gcn-lstm: una red convolucional de gráficos de k-hop y memoria a corto y largo plazo para la predicción de la velocidad del barco. *Física. Estadística. Mec. Su aplicación.* 2022, 606, 128107.
15. Wang, S.; Li, Y.; Xing, H.; Zhang, Z. Predicción de la trayectoria del buque basada en una red convolucional de gráficos espacio-temporales para zonas marítimas complejas y concurridas. *Océano. Ing.* 2024, 298, 117232.
16. Cao, D.; Li, J.; Mamá, H.; Tomizuka, M. Red neuronal de gráficos temporales espectrales para predicción de trayectorias. En *Actas del 2021 Conferencia internacional IEEE sobre robótica y automatización (ICRA), Xi'an (China), 30 de mayo a 5 de junio de 2021*; págs. 1839–1845.
17. Yasukawa, H.; Yoshimura, Y. Maniobrabilidad del barco; Seizando: Tokio, Japón, 2018.
18. Cooper, A. Por qué los productos de alta tecnología nos vuelven locos y cómo restaurar la cordura; Sams Publishing: Carnel, IN, EE. UU., 2004.
19. Lu, J.; Xie, L. Método de navegación inercial de vehículos oceánicos basado en restricciones dinámicas. *J. Navegación.* 2018, 71, 1553–1566.
20. Cole, B.; Schamberg, G. Filtro Kalman sin perfume para el seguimiento de embarcaciones a larga distancia en coordenadas geodésicas. *Aplica. Océano. Res.* 2022, 124, 103205.
21. Zhang, D.; Chu, X.; Wu, W.; Él, Z.; Wang, Z.; Liu, C. Identificación del modelo de maniobra de giro del barco y situaciones extremas a corto plazo. *Predicción de trayectoria bajo la influencia de las corrientes marinas. Océano. Ing.* 2023, 278, 114367.
22. Sol, Q.; Tang, Z.; Gao, J.; Zhang, G. Predicción de la actitud del movimiento del barco a corto plazo basada en lstm y gpr. *Aplica. Océano. Res.* 2022, 118, 102927.
23. Zhang, L.; Zhu, Y.; Su, J.; Lu, W.; Li, J.; Yao, Y. Un modelo de predicción híbrido basado en knn-lstm para la trayectoria del buque. *Matemáticas* 2022, 10, 4493.
24. Gao, D.-W.; Zhu, Y.-S.; Zhang, J.-F.; Él, Y.-K.; Yan, K.; Yan, B.-R. Un nuevo método mp-lstm para la predicción de la trayectoria de un barco basado en datos ais. *Océano. Ing.* 2021, 228, 108956.
25. Forti, N.; Millefiori, LM; Braca, P.; Willett, P. Predicción de trayectorias de vasos a partir de datos ais mediante redes neuronales recurrentes secuencia a secuencia. En *Actas de la Conferencia Internacional IEEE sobre Acústica, Habla y Procesamiento de Señales (ICASSP) 2020—2020, virtual, 4 a 9 de mayo de 2020*; págs. 8936–8940.
26. Tú, L.; Xiao, S.; Peng, Q.; Claramunt, C.; Han, X.; Guan, Z.; Zhang, J. St-seq2seq: Un seq2seq optimizado para funciones espacio-temporales modelo para la predicción de la trayectoria de los buques a corto plazo. *Acceso IEEE* 2020, 8, 218565–218574.
27. Chen, P.; Yang, F.; Mou, J.; Chen, L.; Li, M. Comportamiento regional de los buques y predicción de trayectorias para la gestión del tráfico marítimo: A Enfoque de red social generativa adversarial. *Océano. Ing.* 2024, 299, 117186.
28. Zhang, Y.; Han, Z.; Zhou, X.; Zhang, L.; Wang, L.; Zhen, E.; Wang, S.; Zhao, Z.; Guo, Z. Peso: Un método de predicción de la trayectoria del barco basado en seq2seq con codificadores paralelos y decodificador orientado al barco. *Aplica. Ciencia.* 2023, 13, 4307.
29. Jiang, D.; Shi, G.; Li, N.; Mamá, L.; Li, W.; Shi, J. Trfm-ls: Método de aprendizaje profundo basado en transformadores para la predicción de la trayectoria de los buques. *J. Mar. Ciencias. Ing.* 2023, 11, 880.
30. Liu, RW; Liang, M.; Nie, J.; Yuan, Y.; Xiong, Z.; Yu, H.; Guizani, N. Stmgcn: Predicción de trayectoria de embarcaciones potenciada por computación de borde móvil utilizando una red convolucional multigráfica espacio-temporal. *Traducción IEEE. Indiana Informar.* 2022, 18, 7977–7987.
31. Li, Y.; Li, Z.; Mei, Q.; Wang, P.; Hu, W.; Wang, Z.; Xie, W.; Yang, Y.; Chen, Y. Investigación sobre el método de predicción del tráfico de barcos en múltiples puertos basado en redes neuronales de gráficos espaciotemporales. *J. Mar. Ciencias. Ing.* 2023, 11, 1379.
32. Cho, K.; Merriënboer, BV; Gulcehre, C.; Bahdanau, D.; Bougares, F.; Schwenk, H.; Bengio, Y. Aprendizaje de representaciones de frases. utilizando el codificador-decodificador rnn para la traducción automática estadística. *arXiv* 2014, arXiv:1406.1078.
33. Gong, G.; An, X.; Mahato, NK; Sol, S.; Chen, S.; Wen, Y. Investigación sobre predicción de carga a corto plazo basada en el modelo seq2seq. *Energías* 2019, 12, 3199.
34. Hwang, S.; Jeon, G.; Jeong, J.; Lee, J. Un novedoso modelo seq2seq basado en series temporales para la predicción de temperatura en el proceso de horno de combustión. *Computación de procedimiento. Ciencia.* 2019, 155, 19–26.
35. Gao, S.; Zhang, S.; Huang, Y.; Han, J.; Luo, H.; Zhang, Y.; Wang, G. Una nueva arquitectura seq2seq para la predicción de escorrentía horaria utilizando precipitaciones y escorrentías históricas como insumos. *J. hidrol.* 2022, 612, 128099.
36. Wang, H.; Wang, S.; Chen, S.; Hui, G. Predicción de la dinámica de producción a largo plazo en yacimientos de gas de esquisto/espacios con un modelo diez-seq2seq basado en atención de dos etapas: un estudio de caso en la formación duvernay. *Ciencia de la geoenergía. Ing.* 2023, 223, 211495.

37. Stefanón, SF; Semán, LO; Aquino, LS; Coelho, LdS Wavelet-seq2seq-lstm con atención a la previsión de series temporales de nivel de presas en centrales hidroeléctricas. *Energía* 2023, 274, 127350.
38. Mootha, S.; Sridhar, S.; Seetharaman, R.; Chitrakala, S. Predicción del precio de las acciones mediante modelado de secuencia a secuencia basado en lstm bidireccional y aprendizaje multitarea. En *actas de la 11.ª Conferencia Anual de Computación Ubicua, Electrónica y Comunicaciones Móviles (UEMCON) del IEEE de 2020*, Nueva York, NY, EE. UU., 28 a 31 de octubre de 2020; págs. 0078–0086.
39. Éi, Q.; Li, W.; Hao, Z.; Liu, G.; Huang, D.; Canción, W.; Xu, H.; Alqahtani, F.; Kim, J.-U. Una red tma-seq2seq para la predicción de la temperatura de la superficie del mar con series temporales multifactoriales. *Computadora. Madre. Continúe.* 2022, 73, 2022.
40. Qu, Q.; Chen, H.; Lei, Z.; Li, B.; Du, Q.; Wang, Y. Predicción de la amplitud del desorden marino a través de una red seq2seq mejorada con atención. *Sensores Remotos.* 2023, 15, 3234.
41. Asadi, N.; Lamontaña, P.; Rey, M.; Ricardo, M.; Scott, KA Pronóstico de la presencia estacional de hielo marino en la Bahía de Hudson utilizando el aprendizaje seq2seq. Disponible en línea: <https://s3.us-east-1.amazonaws.com/climate-change-ai/papers/icml2021/6/paper.pdf> (consultado el 1 de junio de 2024)
42. Zhu, W.; Zhou, R. Construcción de retratos de empleados basada en redes neuronales profundas. En *actas de la novena conferencia internacional sobre sistemas confiables y sus aplicaciones (DSA) de 2022*, IEEE, Wulumuqi, China, 4 y 5 de agosto de 2022; págs. 139–142.
43. Ma, C.; Wang, Z.; Cheng, P.; Liu, X.; Yu, H.; Zhang, H. Método de recomendación híbrida de servicios web basado en retratos de usuarios. *J. Computadora.* 2021, 32, 197–212.
44. Zhao, J.; Zeng, D.; Xiao, Y.; Che, L.; Wang, M. Predicción de la personalidad del usuario basada en la preferencia de tema y el análisis de sentimientos utilizando el modelo lstm. *Reconocimiento de patrones. Letón.* 2020, 138, 397–402.
45. Yan, S.; Zhao, T.; Deng, J. Predicción de la ocupación de los usuarios de las redes sociales con redes neuronales jerárquicas conscientes del contenido. En *actas de la octava conferencia internacional sobre big data y análisis de información (BigDIA) de 2022*, Guiyang, China, 24 y 25 de agosto de 2022; págs. 388–395.
46. Wang, N. Modelo de predicción inteligente por computadora de recompensa impulsiva en Internet basado en un algoritmo de retrato de usuario. En *actas de la cuarta conferencia internacional del IEEE de 2021 sobre automatización, electrónica e ingeniería eléctrica (AUTEEE)*, Shenyang, China, 19 a 21 de noviembre de 2021; págs. 545–548.
47. Mingyu, Z.; Sutong, W.; Yanzhang, W.; Dujuan, W. Un método de predicción interpretable para la crisis académica de los estudiantes universitarios. *advertencia. Inteligencia compleja. Sistema.* 2022, 8, 323–336.
48. Liu, T.; Ma, J. Predicción del comportamiento de navegación del barco basada en datos ais. *Acceso IEEE* 2022, 10, 47997–48008.
49. Silvester, R. *Ingeniería Costera*; Compañía editorial científica Elsevier: Ámsterdam, Países Bajos, 1974.
50. Brolsma, JU Asociación Internacional Permanente de Congresos de Navegación. PIANC, Asociación Mundial para la Infraestructura del Transporte Acuático: una asociación en un mundo cambiante, 1885–2010; PIANC: Bruselas, Bélgica, 2010. Disponible en línea: <https://books.google.co.jp/books?id=ZaSwYgEACAAJ> (consultado el 1 de junio de 2024).
51. Notteboom, TE Transporte de contenedores y puertos: una descripción general. *Rev. Red. Economía.* 2004, 3, 86–106.
52. Gillis, DM Distribuciones libres ideales en la dinámica de flotas: una perspectiva del comportamiento sobre el movimiento de los buques en el análisis pesquero. *Poder. J. Zool.* 2003, 81, 177–187.
53. Mahpour, A.; Nazifi, A.; Amiri, AM Desarrollo de modelo de optimización para reducir el tiempo de descarga y carga en el atraque en puertos de contenedores. *Irán. J. Ciencias. Tecnología. Trans. Civilización. Ing.* 2021, 45, 2831–2840.
54. McInnes, L.; Healy, J.; Astels, S. hdbscan: Agrupación jerárquica basada en densidad. *J. Software de código abierto.* 2017, 2, 205.

Descargo de responsabilidad/Nota del editor: Las declaraciones, opiniones y datos contenidos en todas las publicaciones son únicamente de los autores y contribuyentes individuales y no de MDPI ni de los editores. MDPI y/o los editores renuncian a toda responsabilidad por cualquier daño a personas o propiedad que resulte de cualquier idea, método, instrucción o producto mencionado en el contenido.