

文章编号: 1000-4653(2025)04-0132-09

基于 GRU-Attention-BiLSTM 的船舶轨迹预测模型

袁志涛^{1,2}, 李泽伟¹, 刘克中^{1,2}, 陈默子^{1,2}, 袁航¹

(1. 武汉理工大学 航运学院, 湖北 武汉 430063;

2. 内河航运技术湖北省重点实验室, 湖北 武汉 430063)

摘要: 针对复杂通航水域中船舶轨迹预测准确性不高的问题, 提出了基于 GRU-Attention-BiLSTM 的船舶轨迹预测模型, 该模型编码器部分使用门控循环单元 (GRU) 来捕捉轨迹序列中的时序特征, 解码器采用双向长短期记忆网络 (BiLSTM) 并加入注意力 (Attention) 机制来调整数据特征的权值。以历史时刻的船舶经度、纬度、速度及航向为模型输入基础特征, 同时引入中值滤波平滑处理后的水域船舶密度作为附加特征。选取宁波舟山港核心港区 2024 年 3 月的 AIS 数据进行模型的训练和验证, 并与 GRU、LSTM、Seq2Seq-LSTM、Attention-BiLSTM 和 Transformer 模型进行定量和定性对比, 结果表明本文模型在不同的预测时长和航行场景下都有更优的预测结果。

关键词: 复杂通航水域; 船舶轨迹预测; 注意力机制

中图分类号: U675.79

文献标志码: A

DOI: 10.3969/j.issn.1000-4653.2025.04.015

Research on ship trajectory prediction model based on GRU-Attention-BiLSTM

YUAN Zhitao^{1,2}, LI Zewei¹, LIU Kezhong^{1,2}, CHEN Mozi^{1,2}, YUAN Hang¹

(1. School of Navigation, Wuhan University of Technology, Wuhan 430063, China;

2. Hubei Key Laboratory of Inland Shipping Technology, Wuhan 430063, China)

Abstract: To address the issue of low accuracy in ship trajectory prediction in complex navigable waters, this paper proposes a GRU-Attention-BiLSTM model for ship trajectory prediction. In the encoder part, the Gated Recurrent Unit (GRU) is employed to capture temporal features in trajectory sequences. The decoder adopts a Bidirectional Long Short-Term Memory Network (BiLSTM) integrated with an Attention mechanism to adjust the weights of data features. The model input is based on the longitude, latitude, speed and heading of the ship at the historical moment, and the ship density in the water area after median filtering smoothing is introduced as an additional feature. Using Automatic Identification System (AIS) data from the core port area of Ningbo-Zhoushan Port in March 2024, the model was trained and validated. Quantitative and qualitative comparisons with GRU, LSTM, Seq2Seq-LSTM, Attention-BiLSTM, and Transformer models demonstrate that the proposed model achieves superior prediction performance across different prediction durations and navigation scenarios.

Key words: complex navigable waters; ship trajectory prediction; attention mechanism

在航道受限、交通繁忙、航路交错且存在较多静态障碍物的复杂通航水域, 通过准确预测船舶未来的行动轨迹, 有助于提前预警可能发生的危险局面, 从而保障船舶、人员和货物的安全^[1]。因此, 一种

高效准确的船舶轨迹预测模型对于确保海上运输安全至关重要^[2]。

通过设计特定的物理方程来模拟船舶行为特征的传统数学建模方法被广泛应用于船舶轨迹预测研

收稿日期: 2025-01-02

基金项目: 国家自然科学基金项目 (52031009) 资助

通信作者: 袁志涛 (1986—), 男, 硕士生导师, 研究方向为水路交通安全保障等。E-mail: ztyuan@whut.edu.cn

引用格式: 袁志涛, 李泽伟, 刘克中, 等. 基于 GRU-Attention-BiLSTM 的船舶轨迹预测模型[J]. 中国航海, 2025, 48(4): 132-140.

YUAN Z T, LI Z W, LIU K Z, et al. Research on ship trajectory prediction model based on GRU-Attention-BiLSTM[J]. Navigation of China, 2025, 48(4): 132-140. (in Chinese)

究领域。HOUENOU 等^[3]建立了曲线运动模型,并利用扩展卡尔曼滤波算法预测船舶的位置、速度和加速度。这个过程计算量很大,且适用场景单一。

随着人工智能的发展,机器学习方法能够学习船舶历史运动模式与未来轨迹之间的关系。RONG 等^[4]将船舶运动分解为经度和纬度方向,利用高斯回归模型估计纵向加速度的概率密度函数和纬度方向位置的概率密度函数,预测轨迹的不确定性。ZHANG 等^[5]提出了一种基于小波的隐马尔可夫模型(Hidden Markov Model, HMM) 轨迹预测算法,解决了卡尔曼滤波和线性回归精度不高、时滞大等缺点。但在实际应用中机器学习存在样本量不足、局部优化等问题。

近年来神经网络因在其他领域的优异表现,在轨迹预测领域获得了广泛关注。其中长短期记忆网络(Long Short Term Memory Network, LSTM) 和门控循环单元(Gated Recurrent Unit, GRU) 等模型常被用于解决时序特征难以捕捉的问题。刘成勇等^[6]基于复杂内河的航行环境条件,提出了一种结合注意力机制和 LSTM 的 Atten-LSTM 模型,能高效、准确地预测船舶航迹并保证其可靠性。鞠聪^[7]提出了一种基于 CNN 和 GRU 的混合船舶轨迹预测模型(CNN-GRU),通过改进数据处理和模型构建,显著提高了预测精度和效率。同时,相较于传统的单向 LSTM,双向 LSTM(Bi-directional Long Short Term Memory, BiLSTM) 及其变体在许多轨迹序列建模中都表现得更加出色。郭逸婕等^[8]融合 TCN 网络和 Bi-LSTM 网络学习轨迹序列的前后状况来提取序列中更多的信息,实现对船舶未来轨迹更精准的预测。XUE 等^[9]结合 GRU 与 Transformer 优势互补进行长期预测,提高了预测精度和计算效率。

虽然现有方法在船舶轨迹预测方面取得很大的进展,但依然在适应复杂通航水域方面存在限制。目前轨迹预测方法常采用轨迹点的经度、纬度、对地航向和对地航速作为输入,没有考虑船舶周围环境信息,导致模型无法准确预测船舶在复杂通航水域下不同场景的轨迹变化,预测精度较低。同时复杂轨迹数据对模型特征处理能力提出了更高的要求。

为进一步提高船舶轨迹预测的精度,本文结合 GRU、BiLSTM 和注意力机制,提出了基于 GRU-Attention-BiLSTM 的船舶轨迹预测模型,以捕捉轨迹的时序特征,同时添加基于船舶自动识别系统(Automatic Identification System, AIS) 数据提取的船舶密度信息作为附加特征。

1 BiLSTM 和 GRU 模型

1.1 双向长短期记忆网络(BiLSTM)

LSTM 通过门控机制(gate mechanism) 来控制信息的流动^[10],从而更好地捕捉和记忆时间序列数据之间的依赖关系。然而,在传统的 LSTM 结构中,信息只能沿着时间序列的单个方向进行传递,早期信息在长序列中传递时会逐渐衰减。为了更全面地捕捉序列数据中的上下文信息,GRAVES 等^[11]在 2005 年提出了 BiLSTM,通过引入两个独立的 LSTM 网络,分别沿着时间序列的正向和逆向进行处理。在每个时间步,BiLSTM 同时考虑了当前时刻之前和之后的上下文信息,从而更全面地捕捉了序列数据中的双向关联性。BiLSTM 结构如图 1 所示。




图 1 BiLSTM 结构示意图

Fig. 1 Schematic diagram of BiLSTM structure

BiLSTM 的工作原理如图 2 所示。在每个时间步 n ,前向 LSTM 单元 $A_0, A_1, A_2, \dots, A_n$ 接收当前时间步的输入 X_n 以及前一时间步的隐藏状态 S_{n-1} ,并计算得到当前时间步的前向隐藏状态。同样地,在每个时间步 n ,后向 LSTM 单元 $A'_n, A'_{n-1}, A'_{n-2}, \dots, A'_0$ 接收当前时间步的输入 X_n 以及下一时间步的隐藏状态 S'_{n-1} ,并计算得到当前时间步的后向隐藏状态。将前向和后向的隐藏状态拼接起来,形成当前时刻的输出向量,作为 BiLSTM 的最终输出^[12]。对于每一个独立的 LSTM 网络,其单元结构如图 2 所示。




图 2 LSTM 单元结构示意图

Fig. 2 Schematic diagram of LSTM unit structure

其中: X_t 为当前时刻的输入; C_t 为当前时刻的细胞状态; C_{t-1} 为上一时刻的细胞状态; H_t 为当前时刻的隐藏状态; H_{t-1} 为上一时刻的隐藏状态; \tilde{H}_t 为候选隐藏状态; F_t 为输出门输出; R_t 为输入门输出;

Z_t 为遗忘门输出; σ (sigmoid) 和 \tanh 为两种不同的激活函数; 具体计算过程为

$$F_t = \sigma(\mathbf{W}_F \cdot [H_{t-1}, X_t] + b_F) \quad (1)$$

$$R_t = \sigma(\mathbf{W}_R \cdot [H_{t-1}, X_t] + b_R) \quad (2)$$

$$Z_t = \sigma(\mathbf{W}_Z \cdot [H_{t-1}, X_t] + b_Z) \quad (3)$$

式中: \mathbf{W} 为系数矩阵; b 为偏差项。

更新后的细胞状态可表示为

$$Q_t = \tanh(\mathbf{W}_c \cdot [H_{t-1}, X_t] + b_c) \quad (4)$$

$$C_t = F_t \times C_{t-1} + R_t \times Q_t \quad (5)$$

网络的最终输出可表示为

$$H_t = Z_t \times \tanh(C_t) \quad (6)$$

1.2 门控循环单元 (GRU)

GRU 不仅缓解了 RNN 模型存在的梯度消失问题, 而且在一些任务上的表现优于长短期记忆网络 (LSTM)^[13]。GRU 单元结构如图 3 所示。




图 3 GRU 结构图

Fig. 3 GRU structure diagram

GRU 包含两个门控单元: 更新门和重置门。其中, X_t 为 t 时刻的输入; H_t 为当前时刻的输出; H_{t-1} 为上一时刻的隐藏状态; \tilde{H}_t 为候选隐藏状态; Z_t 为更新门; R_t 为重置门; σ 为激活函数 sigmoid; \tanh 为另外一种激活函数。具体计算过程为

$$R_t = \sigma(\mathbf{W}_R \cdot [H_{t-1}, X_t] + b_R) \quad (7)$$

$$Z_t = \sigma(\mathbf{W}_Z \cdot [H_{t-1}, X_t] + b_Z) \quad (8)$$

$$\tilde{H}_t = \tanh(\mathbf{W}_c \cdot [R_t H_{t-1}, X_t] + b_c) \quad (9)$$

式中: \mathbf{W} 为系数矩阵; b 为偏差项^[14]。

$$H_t = (1 - Z_t) \tilde{H}_t + Z_t H_{t-1} \quad (10)$$

通过图 2 和图 3 可以看出, GRU 与 LSTM 相比, 门控单元数量和中间变量都更少, 结构更加简单, 因此在一些场景下训练速度更快, 也有助于减少模型训练过程中的过拟合现象。

2 GRU-Attention-BiLSTM 模型构建

2.1 模型总体框架

GRU-Attention-BiLSTM 船舶轨迹预测模型由 GRU 编码器、注意力模块和 BiLSTM 解码器组成, 旨在对船舶轨迹数据进行编码、特征提取和解码预测。

GRU 编码器负责接收每个时间步的轨迹数据

及前一时刻的隐藏状态, 通过非线性变换生成每个时间步的隐藏状态, 并在最后时刻输出一个综合语义向量, 概括整个轨迹序列。

注意力模块解决了固定长度语义向量的信息瓶颈问题, 通过计算 GRU 编码器隐藏状态与 BiLSTM 解码器隐藏状态之间的相关性, 得到权重值, 并利用加权求和生成每个时间步的特性向量, 突出关键特征。BiLSTM 解码器在每个时间步将注意力模块输出的特性向量与当前解码器的隐藏状态拼接, 通过非线性变换恢复形状后, 生成新的隐藏状态和最终输出, 实现对轨迹的逐步预测。

将轨迹点的经度 (Lon)、纬度 (Lat)、对地航向 (COG)、对地航速 (SOG) 和该轨迹点当前时刻所在区域船舶密度 (Density) 五个特征输入编码器进行编码, 最终通过解码器模块输出船舶未来时刻的轨迹。其总体结构如图 4 所示。

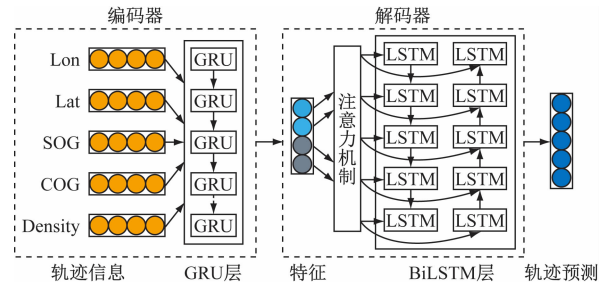


图 4 模型结构示意图

Fig. 4 Schematic diagram of GRU-Attention-BiLSTM model structure

图 5 展示了信息在模型中传递的过程, 在编码阶段, 模型通过特征提取和信息压缩来处理历史航迹序列, 最终通过中间语义编码向量 C 进行统一表示^[15]。解码阶段将船舶的潜在运动模式信息解码为待预测的轨迹信息。




图 5 编码解码结构示意图

Fig. 5 Schematic diagram of Encoder-Decoder structure

2.2 GRU-Attention-BiLSTM 编解码过程

2.2.1 编码过程

首先, 将预处理后的船舶轨迹数据输入 GRU 编码器, 其中的每个 GRU 单元接收来自前一个时间步的隐藏层状态和当前时间步的轨迹数据输入。通过对输入信息进行非线性变换, 生成每个时间步 t 的隐藏层状态。

$$h_t = f(x_t, h_{t-1}) \quad (11)$$

式中: h_{t-1} 为上一时刻隐藏层状态; x_t 为 t 时刻的输入; $f(\cdot)$ 为 GRU 编码器。在序列的最后一个时刻 T ,编码器输出的所有隐藏状态被进一步处理,得到中间语义向量 \mathbf{C} , $t=1,2,\dots,T$ ^[16]。

$$\mathbf{C} = z(h_1, h_2, h_3, \dots, h_T) \quad (12)$$

式中: $z(\cdot)$ 为非线性函数,负责将编码器数据的特征映射到解码器所需的输出空间。

2.2.2 注意力模块

然而,由于固定长度的语义向量 \mathbf{C} 难以全面概括长序列的全部信息,特别是在面对较长的输入时,后续输入可能会覆盖前面的重要信息,导致信息丢失。为解决这一问题,引入了注意力机制。注意力机制通过计算输入序列中每个时间步的特征与解码器当前状态的相关性,为各特征分配不同权重,从而突出关键特征。

注意力机制的运行分为三个步骤:相关性计算、权重归一化、加权求和。

首先,计算 GRU 编码器在 i 时刻的隐藏状态 h_i 与 BiLSTM 解码器在 t 时刻的隐藏状态 h'_t 的相关性得分 s_{ii} ^[17]。

$$s_{ii} = \mathbf{v}_a^T \tanh(\mathbf{W}_a \cdot \text{concat}(h'_t, h_i)) \quad (13)$$

式中: \mathbf{W}_a 为权重矩阵; \mathbf{v}_a 为变换系数。

然后,对相关性得分通过 softmax 函数归一化,计算 GRU 隐藏状态对 BiLSTM 隐藏状态的影响权重,计算公式为

$$a_i = \text{softmax}(s_{ii}) = \frac{\exp(s_{ii})}{\sum_j \exp(s_{ij})} \quad (14)$$

式中: a_i 为通过 softmax 函数计算得到的权重值。

最后,利用注意力权重对 GRU 编码器隐藏状态加权求和,得到 t 时刻的特性向量 \mathbf{c}_t ,计算公式为

$$\mathbf{c}_t = \sum a_i h_i \quad (15)$$

2.2.3 解码过程

解码阶段将注意力模块输出的特性向量 \mathbf{c}_t 与 BiLSTM 解码器部分在 t 时刻的隐藏状态 h'_t 拼接,计算 BiLSTM 解码器部分在 t 时刻新的隐藏层状态 N'_t ,计算公式为

$$N'_t = \tanh(\mathbf{W}_c \cdot \text{concat}(\mathbf{c}_t, h'_t)) \quad (16)$$

式中: \mathbf{W}_c 为转换矩阵。因为拼接后的特征纬度会发生变化,所以将 concat 拼接结果与转换矩阵 \mathbf{W}_c 相乘进行形状恢复^[18]。在此基础上,计算 BiLSTM 解码器部分在 t 时刻的最终输出 y_t ,计算公式为

$$y_t = \mathbf{W}_h N'_t + b_h \quad (17)$$

式中: \mathbf{W}_h 为隐藏层输出系数矩阵; b_h 为偏置项。

3 试验设置

3.1 船舶轨迹数据预处理和数据集划分

宁波舟山港是全球货物吞吐量最大的港口之一,航路交错复杂,岛屿、暗礁众多,是典型的复杂通航水域。选取宁波舟山港核心港区 2024 年 3 月的 AIS 数据进行模型的训练和验证。该水域 2024 年 3 月的船舶轨迹点可视化结果如图 6 所示。




图 6 宁波舟山港核心港区 2024 年 3 月船舶轨迹数据可视化

Fig. 6 Visualization of ship trajectory data in the core port area of Ningbo Zhoushan Port in March 2024

3.1.1 AIS 数据预处理

AIS 数据包含了船舶移动通信业务标识码 (Maritime Mobile Service Identify, MMSI)、船长、船宽、船舶类型等静态信息,以及经纬度、航向、航速、转向速度等动态信息,为轨迹预测提供了数据支撑。

由于原始 AIS 数据中存在缺失甚至错误的轨迹信息,因此需对 AIS 数据进行预处理,具体步骤如下:

1) 删除异常数据:删除 MMSI 不是 9 位的、轨迹点经纬度在研究水域范围之外的、COG 或 SOG 数值超出设定范围的异常数据。

2) 轨迹分组:将轨迹按 MMSI 分组,然后将每组数据按照时间排序。

3) 插值处理:利用三次样条插值方法,对分组后的轨迹数据进行插值处理,保证轨迹序列的平滑和连续。

4) 轨迹采样:对插值处理后的每组轨迹以 1 min 为间隔提取轨迹点,在减少数据量的同时保留关键信息。

原始 AIS 数据经过上述步骤预处理后得到 16 472 艘船舶的轨迹,包含 76 725 条轨迹序列,共计 10 776 461 个轨迹点,用于模型的训练和验证。

3.1.2 船舶交通密度特征提取

船舶密度是衡量通航水域中船舶分布密集程度的重要指标。它直观地反映了特定区域的交通繁忙状况。在船舶轨迹预测中,不同的船舶密度区域代表着不同的交通环境特征。通过将船舶密度特征纳入模型,能够使模型更好地理解船舶所处的交通环

境,从而使预测结果更符合实际的交通状况。

本文采用轨迹数据栅格化的方法提取船舶交通密度特征,旨在将连续的地理空间轨迹数据转换为离散化、结构化的网格形式。选用 $100\text{ m} \times 100\text{ m}$ 的网格尺度,将目标水域划分成 364×496 个网格,然后根据 2024 年 3 月的船舶轨迹数据统计每个网格上的轨迹点数量,船舶轨迹点的统计分布可以反映船舶的密度分布。船舶轨迹数据栅格化结果如图 7 所示。




图7 试验水域船舶轨迹数据栅格化结果

Fig. 7 Rasterization results of ship trajectory data in experimental waters

由于船舶轨迹数据栅格化后得到的原始船舶交通密度数据存在噪声和不连续的像素值,此时直接输入模型会影响密度特征构建的准确性,因此,需要进一步对栅格图像进行去噪和平滑处理。采用中值滤波对船舶密度栅格图像进行处理^[19]。二维情况下的中值滤波可定义为

$$Y_{ij} = \text{median}[X_{i+m,j=n}; (m,n) \in W] \{X_{ij}; (i,j) \in Z^2\} \quad (18)$$

式中: W 为平面窗口大小; m 为窗口水平尺寸; n 为窗口垂直尺寸; X_{ij} 为被处理的图像平面上的一个栅格,坐标为 (i,j) ; Y_{ij} 为以 X_{ij} 为中心、窗口 W 范围内所有栅格对应船舶密度的中值,即中值滤波处理的输出值; Z^2 为二维数据串的序号,即栅格图像的坐标集。

中值滤波窗口水平和垂直尺寸均为 3。从图 8 可以看出,原始图像中会出现一些孤立像素点和孔洞,同时缺乏平滑性。中值滤波去噪处理后船舶密度的异常值被去除,从而使数据的分布更加合理,更加清晰地展现出船舶密度变化的趋势和规律。

经过中值滤波处理后,可以根据船舶密度栅格图像提取交通密度特征。首先根据船舶在当前时刻的经纬度和栅格坐标集合搜寻船舶所处的栅格,并计算此栅格在当前时刻的船舶密度,然后将该密度值与该时刻船舶轨迹点的经度、纬度、对地航速、对地航向四个特征拼接,共同组成船舶在当前时刻的




图8 原始图像和中值滤波处理后的图像对比
Fig. 8 Comparison between the original image and the image processed by median filtering

轨迹点特征。

3.1.3 数据归一化

将预处理并添加船舶交通密度信息后的船舶轨迹数据按照 7:2:1 的比例划分为训练集、验证集和测试集。其中训练集用于优化模型参数,学习输入与输出之间的关系;验证集用于评估模型在新数据上的性能,防止过拟合并选择最佳配置。测试集用于评估模型的泛化能力和预测准确性。

为加快模型收敛以及增加数据的稳定性,将船舶轨迹数据的五个特征维度分别归一化至 $[0,1]$ 区间。归一化公式为

$$Y = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (19)$$

式中: Y 为归一化后的数据, X 为某一特征维度的数据, X_{\min} 和 X_{\max} 分别为该特征维度数据的最小值和最大值。

3.2 模型参数设置

本研究基于 Python 库中的 TensorFlow 深度学习框架搭建所提出的改进的 GRU-BiLSTM 模型,并进行相关试验。GRU 与 BiLSTM 模块中神经元的数量设置为 128,在保证模型具有足够复杂度的同时,避免了过拟合问题。模型中每个层的模块神经元数量和维度变化的设置如图 9 所示,其中 n 即为设定的历史轨迹步长和预测时间步长。

在模型训练阶段,将均方误差函数 (mean-square error, MSE) 作为模型的损失函数来度量生成的预测轨迹与真实轨迹之间的偏差。对于每艘船舶的均方误差的计算方法是求同一时刻的预测轨迹点与真实轨迹点之间欧式距离的平方和。预测值和真实值越接近,两者的均方误差就越小。训练的最终目的是让损失函数的值达到最小。本模型训练过程中,需要同时计算船舶 n 个预测时间步的经度和纬度的误差之和,损失函数计算公式为

$$M_{SE} = \frac{1}{n} \sum_{i=1}^n [(x_i - x'_i)^2 + (y_i - y'_i)^2] \quad (20)$$

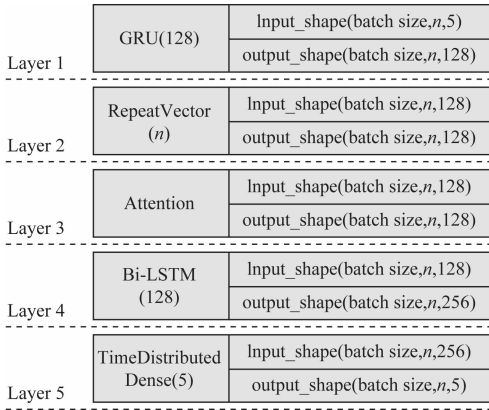


图9 模型的网络结构

Fig. 9 Network structure diagram of the model

式中: x_t, y_t 表示船舶在时间步 t 时真实的经度和纬度; x'_t, y'_t 表示船舶在时间步 t 时预测的经度和纬度; n 即为设定的预测时间步长。

模型在训练时选择了 Adam 优化器, 引入了学习率自适应缩放机制和动量项, 有助于在训练的早期和后期更好地平衡收敛速度和稳定性, 有助于平滑梯度的变化。同时该优化器对稀疏梯度的处理较好。

模型的初始学习率被设置为 0.01, Dropout 被设置为 0.5, batch size 被设置为 128。分别对不同学习率 0.005、0.01、0.02 等进行了测试, 发现学习率为 0.01 时能够在保证模型稳定收敛的前提下, 相对较快地使损失函数值下降, 因此确定其为最终学习率。0.5 的 Dropout 率在防止过拟合的同时, 也保留了模型足够的学习能力。batch Size 设置为 128 可以在保证模型能够有效收敛的同时, 合理利用计算资源, 减少训练过程中的波动, 使得模型能够更稳定地学习船舶轨迹数据中的特征。Epoch 设置为 100 时, 模型训练最终可以使损失函数达到最小并保持相对稳定, 每个 epoch 自适应降低学习率。

3.3 模型评价指标

采用平均位置误差 (ADE) 和终点位置误差 (FDE) 对模型预测结果的精确度进行评价。其中 ADE 表示预测轨迹和真实轨迹之间所有对应轨迹点的平均欧氏距离。FDE 表示最后一个预测轨迹点与对应真实轨迹点之间的欧氏距离^[20]。计算公式为

$$A_{DE} = \frac{\sum \|p_{true} - p_{pred}\|}{N} \quad (21)$$

$$F_{DE} = \frac{\sum \|p_{true(end)} - p_{pred(end)}\|}{N} \quad (22)$$

式中: p_{true} 表示真实位置; $p_{true(end)}$ 表示真实终点位置;

p_{pred} 表示预测位置; $p_{pred(end)}$ 表示预测终点位置; N 表示轨迹点数量; $\|\cdot\|$ 表示二范数, 用以计算欧氏距离。

4 试验与结果分析

试验使用测试集对模型进行测试, 以评估模型的泛化能力和预测准确性。

原始轨迹数据经过数据清洗、轨迹插值预处理后得到 1 min 等间隔的轨迹点。对每条轨迹序列, 采用滑动窗口切片处理, 窗口长度为历史轨迹时长与预测轨迹时长之和 (在本文中, 两者被设置为相等)。每个切片包含历史轨迹和未来真实轨迹 (Ground Truth)。

在模型训练阶段, 遍历训练集轨迹, 通过滑动窗口生成切片, 输入模型。模型将切片拆分为历史轨迹和 Ground Truth, 历史轨迹输入解码器, 通过最小化预测轨迹与 Ground Truth 的均方误差完成训练。

在模型测试阶段, 对测试集轨迹同样进行滑动窗口切片, 并输入训练好的模型。模型解码历史轨迹, 生成预测轨迹, 与 Ground Truth 进行定量和定性对比, 以评估预测效果。

本文采取多步预测方式 (模型同时输出所有的预测轨迹点) 输出预测轨迹。将 GRU-Attention-BiLSTM 模型的预测结果与 GRU、LSTM、Seq2Seq-LSTM、Attention-BiLSTM 和 Transformer 模型进行了定量和定性评估对比, 以分析不同模型的性能差异。

4.1 定量评估

根据宁波舟山港水域船舶交通特点和航海实践需求, 定量评估试验分别设置模型输入的历史轨迹时长为 10 min、15 min 和 20 min。预测轨迹时长与输入的历史轨迹时长相同。试验对比在不同的输入 (输出) 轨迹时长下未添加 (见表 1) 与添加船舶密度特征 (见表 2) 两种情况下的轨迹预测效果, 并使用 ADE 和 FDE 评估预测精度。

从表 1 和表 2 可以看出, 对于不同模型, 当预测时长和输入特征相同时, Seq2Seq-LSTM 和 GRU-Attention-BiLSTM 模型在 ADE/FDE 明显优于 LSTM 和 GRU 模型, 说明引入编码器-解码器能够有效地提高模型的预测性能。而 Attention-BiLSTM 模型对比 LSTM 和 GRU, 因为引入双向 LSTM 和注意力机制, 预测误差相对较小。Transformer 模型在 ADE 上优于 Attention-BiLSTM 模型, 但是在 FDE 上略显劣势。在所有对比模型中 GRU-Attention-BiLSTM 模型的 ADE/FDE 数值均最小, 预测精度最高。

表1 不同模型在不同预测时长下的 ADE/FDE
(未加入区域船舶密度特征)

Tab.1 ADE/FDE of different models at different prediction times (without incorporating ship density features)

模型	10 min		15 min		20 min	
	ADE	FDE	ADE	FDE	ADE	FDE
LSTM	362.1	581.2	634.9	809.8	846.1	1 034.3
GRU	372.9	522.7	610.5	798.5	855.1	949.1
Seq2Seq-LSTM	312.4	535.5	398.1	772.7	773.2	890.1
Attention-BiLSTM	295.3	489.2	431.4	699.1	685.1	884.3
Transformer	281.2	512.5	393.6	732.4	690.1	755.2
GRU-Attention-BiLSTM	231.1	423.4	302.5	506.8	415.9	569.7

表2 不同模型在不同预测时长下的 ADE/FDE
(加入区域船舶密度特征)

Tab.2 ADE/FDE of different models at different prediction times (with incorporating ship density features)

模型	10 min		15 min		20 min	
	ADE	FDE	ADE	FDE	ADE	FDE
LSTM	349.2	537.9	565.3	753.9	796.2	901.2
GRU	356.3	544.2	542.23	735	801.9	877.6
Seq2Seq-LSTM	282.2	486.1	386.1	755.2	612.8	792.7
Attention-BiLSTM	274.1	458.4	413.2	657.8	655.8	851.2
Transformer	254.8	477.5	366.5	613.0	678.9	734.1
GRU-Attention-BiLSTM	210.8	382.4	271.3	453.4	336.5	527.2

当输入特征相同时,所有模型的 ADE 和 FDE 均随着预测时长的增加而增加,即所有模型的预测性能均随着预测时长增加而下降。当预测时长从 10 min 增长到 15 min 和从 15 min 增长到 20 min 时,GRU-Attention-BiLSTM 的 ADE/FDE 的增长率在轨迹点未加入船舶密度特征时分别为 30.9%/19.7% 和 37.5%/12.4%,在加入船舶密度特征后分别为 28.7%/18.6% 和 24%/16.3%,在所有对比模型中增长率均最小,即 GRU-Attention-BiLSTM 模型随着预测时间增加,预测误差的变化幅度最小,预测性能

最稳定。

对于相同的模型和相同的预测时长,当加入区域船舶密度特征后,所有模型的 ADE/FDE 均出现了下降,这说明加入区域船舶密度特征能够进一步提高模型的预测效果。

4.2 定性评估

在定性评估试验中,历史轨迹时长和预测轨迹时长均为 10 min,输入的轨迹点特征包含了区域船舶密度特征。分别根据船舶直线航行、较小幅度转向航行、较大幅度转向航行三种航行场景下的预测结果与真实轨迹(Ground Truth)的可视化对比来判断不同模型的预测效果,如图 10~图 12 所示。




图 10 直线航行场景模型对比

Fig. 10 Comparison of straight-line navigation scene models




图 11 较小幅度转弯航行场景模型对比

Fig. 11 Comparison of small turn navigation scene models

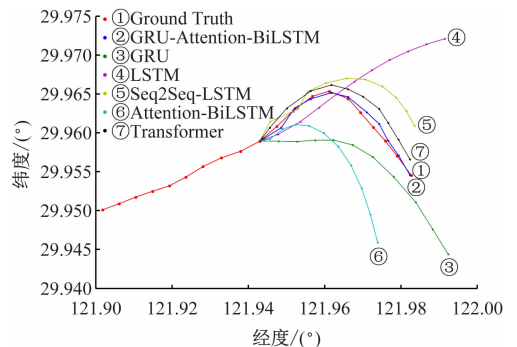


图 12 较大幅度转弯航行场景模型对比

Fig. 12 Comparison of models for large turning navigation scenarios

在船舶直线航行的场景中,GRU-Attention-BiLSTM 的预测轨迹几乎与真实轨迹重合,ADE/FDE 为 72.1 m/86.8 m。Transformer 预测轨迹较为接近

真实轨迹, ADE/FDE 依然达到了 96.4 m/169.5 m。其他对比模型的预测轨迹偏离真实轨迹的程度相对较大, 预测效果均不及 GRU-Attention-BiLSTM 模型。

在船舶较小幅度转向航行的场景中, 此时, GRU-Attention-BiLSTM 模型和 Seq2Seq-LSTM 模型预测船舶的转向幅度都更为接近真实轨迹, 但是在平均位置误差上, GRU-Attention-BiLSTM 模型明显优于 Seq2Seq-LSTM 模型, 前者的 ADE 仅为后者的 42%, ADE/FDE 为 89.1 m/82.5 m。Transformer 模型的预测轨迹整体趋势虽然接近真实轨迹, 但在后半程逐渐偏离, 误差增大, ADE/FDE 为 128.2 m/272.3 m。其他模型全程的预测误差均相对较大。

在船舶较大幅度转向航行的场景中, Transformer 模型在对比模型中表现最好, 其 ADE/FDE 为 202.3 m/363.9 m。GRU-Attention-BiLSTM 模型的预测结果依然最接近真实轨迹, ADE/FDE 仅为 106.2 m/143.5 m。而其他对比模型预测的轨迹的转向时机或转向幅度的偏差均较大。

通过定量和定性评估试验的结果可以看出, BiLSTM 和注意力机制提高了模型捕捉 AIS 数据的长期依赖关系的能力, 使得预测效果明显优于对比模型。

4.3 消融试验

为进一步研究 GRU-Attention-BiLSTM 模型中各个组件的作用, 构造三个变体模型。第一个变体模型将 GRU 模块替换为 LSTM, 并命名为 LSTM-Attention-BiLSTM; 第二个变体模型将 BiLSTM 模块替换为 LSTM, 并命名为 GRU-Attention-LSTM; 第三个变体模型删除了 Attention 模块, 并命名为 GRU-BiLSTM。三个变体模型分别探究 GRU、BiLSTM 和 Attention 三个模块在 GRU-Attention-BiLSTM 模型中的重要作用。消融试验的历史轨迹时长和预测轨迹时长均为 10 min, 输入的轨迹点特征包含了区域船舶密度特征。通过计算此时三种变体模型的 ADE/FDE 数值以表征预测准确度。

表 3 是 GRU-Attention-BiLSTM 及其三种变体模型的 ADE/FDE 数值。从表中数据可以看出, GRU-Attention-BiLSTM 模型相比于 LSTM-Attention-BiLSTM 模型, ADE 减少了 19.1%, FDE 减少了 12.5%。这得益于 GRU 相比 LSTM 具有更为简洁的结构, 使其在提取复杂特征时具有更好的效果。相比于 GRU-Attention-LSTM 模型, GRU-Attention-BiLSTM 模型在 ADE 和 FDE 指标上分别减少了 24.2% 和 21.8%。这一改进归功于 BiLSTM 的双向结构, 它能够更有效地捕捉轨迹序列中的依赖关系和上下文信息。此外, GRU-Attention-BiLSTM 模型相较于

GRU-BiLSTM 模型, ADE 减少了 23.9%, FDE 减少了 15.6%。这表明注意力机制可以使模型更加聚焦于关键特征, 从而进一步提升预测精度。

表 3 GRU-Attention-BiLSTM 及其三种变体模型的 ADE/FDE 数值

Tab.3 ADE/FDE values of GRU-Attention-BiLSTM and its three variant models 单位: m

模型	ADE	FDE
LSTM-Attention-BiLSTM	260.5	436.8
GRU-Attention-LSTM	278.2	489.1
GRU-BiLSTM	277.1	453.3
GRU-Attention-BiLSTM	210.8	382.4

消融试验结果说明了 GRU-Attention-BiLSTM 模型的各个模块对提高船舶轨迹预测准确度都具有一定的作用。

5 结束语

为进一步提高复杂通航水域船舶轨迹预测的准确性, 提出了基于 GRU-Attention-BiLSTM 的船舶轨迹预测模型。选取宁波舟山核心港区这一典型复杂通航水域作为试验水域, 并以 ADE 和 FDE 作为评价指标。定量和定性评估试验结果表明, GRU-Attention-BiLSTM 相较于对比模型在不同预测时长和航行场景下都具有更准确的预测结果。同时, 引入平滑、去噪处理后的区域船舶密度作为轨迹点的附加特征输入进一步提高了预测准确度。最后, 消融试验结果表明 GRU、BiLSTM 和 Attention 三个模块对提高 GRU-Attention-BiLSTM 模型的预测性能都具有一定的作用。

展望未来研究, 我们将着重弥补当前不足。针对复杂通航环境因素欠缺问题, 计划深入探究水流、风向、航道规则等多元因素与船舶轨迹的内在关联, 构建多因素融合的预测模型。此外, 后续研究会构建大规模多船交互数据集, 创新模型架构以精准捕捉船舶间动态关系, 进而提高模型在复杂航运场景下的预测性能与可靠性。在实际应用中, AIS 数据可能存在误差、缺失或延迟等问题, 后续研究中将构建更为完善的数据预处理与质量监控体系, 通过多源数据融合与校验技术, 提高输入数据的准确性与可靠性, 推动本研究向实用化、全面化方向迈进。

参 考 文 献

- [1] FANG Z X, YU H C, KE R X, et al. Automatic identification system-based approach for assessing the near-miss collision risk dynamics of ships in ports[J].

- IEEE Transactions on Intelligent Transportation Systems, 2019, 20(2): 534-543.
- [2] ZHAO J S, YAN Z W, ZHOU Z Z, et al. A ship trajectory prediction method based on GAT and LSTM [J]. Ocean Engineering, 2023, 289: 116159.
- [3] HOUENOU A, BONNIFAIT P, CHERFAOUI V, et al. Vehicle trajectory prediction based on motion model and maneuver recognition [C]//2013 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2013: 4363-4369.
- [4] RONG H, TEIXEIRA A P, GUEDES SOARES C. Ship trajectory uncertainty prediction based on a Gaussian Process model [J]. Ocean Engineering, 2019, 182: 499-511.
- [5] ZHANG X Y, LIU G, HU C, et al. Wavelet analysis based hidden Markov model for large ship trajectory prediction [C]//2019 Chinese Control Conference (CCC). IEEE, 2019: 2913-2918.
- [6] 刘成勇, 乔文杰, 陈蜀喆, 等. 基于 LSTM 与注意力机制的船舶航迹预测模型研究[J]. 中国航海, 2021, 44(4): 94-100.
- LIU C Y, QIAO W J, CHEN S Z, et al. On ship track prediction with LSTM and attention mechanism [J]. Navigation of China, 2021, 44(4): 94-100. (in Chinese)
- [7] 鞠聪. 基于 CNN-GRU 的船舶航迹预测研究[D]. 大连: 大连海事大学, 2023.
- JU C. Research on vessel track prediction based on CNN-GRU [D]. Dalian: Dalian Maritime University, 2023. (in Chinese)
- [8] 郭逸婕, 张君毅, 王鹏. 基于注意力机制的 TCN-BiLSTM 船舶航迹预测[J]. 计算机测量与控制, 2024, 32(1): 30-36.
- GUO Y J, ZHANG J Y, WANG P. Prediction for TCN-BiLSTM ship trajectory based on attention mechanism [J]. Computer Measurement and Control, 2024, 32(1): 30-36. (in Chinese)
- [9] XUE H Q, WANG S, XIA M L, et al. G-Trans: a hierarchical approach to vessel trajectory prediction with GRU-based transformer [J]. Ocean Engineering, 2024, 300: 117431.
- [10] GREFF K, SRIVASTAVA R K, KOUTNIK J, et al. LSTM: a search space odyssey [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2222-2232.
- [11] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures [J]. Neural Networks, 2005, 18(5-6): 602-610.
- [12] 孙隽丰, 李成海, 曹波. 基于 TCN-BiLSTM 的网络安全态势预测[J]. 系统工程与电子技术, 2023, 45(11): 3671-3679.
- SUN J F, LI C H, CAO B. Network security situation prediction based on TCN-BiLSTM [J]. Systems Engineering and Electronics, 2023, 45(11): 3671-3679. (in Chinese)
- [13] CHUNG J Y, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [J]. arXiv preprint arXiv:1412.3555, 2014.
- [14] 赵琦, 许志远, 葛佳薇. 基于 GRU-DconvLSTM 的船舶航迹预测[J]. 船舶工程, 2023, 45(6): 124-129.
- ZHAO Q, XU Z Y, GE J W. Ship trajectory prediction based on GRU-DConvLSTM [J]. Ship Engineering, 2023, 45(6): 124-129. (in Chinese)
- [15] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks [C]//Neural Information Processing Systems: Proceedings of the 28th International Conference on Neural Information Processing Systems. NIPS, 2014(2): 3104-3112.
- [16] 陈小建. 基于 Encoder-Decoder-ILSTM 模型的瓦斯浓度预测研究[J]. 能源与节能, 2023(12): 102-105.
- CHEN X J. Gas concentration prediction based on encoder-decoder-ILSTM modeling [J]. Energy and Energy Conservation, 2023(12): 102-105. (in Chinese)
- [17] 唐坤, 戴语琴, 徐永能, 等. 基于 Encoder-Decoder 注意力网络的异常驾驶行为在线识别方法[J]. 兵器装备工程学报, 2023, 44(8): 63-71.
- TANG K, DAI Y Q, XU Y N, et al. Online recognition methods of abnormal driving based on encoder-decoder attention network [J]. Journal of Ordnance Equipment Engineering, 2023, 44(8): 63-71. (in Chinese)
- [18] 宋良才, 索贵龙, 胡军涛, 等. 基于注意力机制的 Encoder-Decoder 光伏发电预测模型[J]. 计算机与现代化, 2020(9): 112-117.
- SONG L C, SUO G L, HU J T, et al. Encoder-decoder photovoltaic power generation prediction model based on attention mechanism [J]. Computer and Modernization, 2020(9): 112-117. (in Chinese)
- [19] 赵夫群. 基于改进中值滤波的图像去噪算法[J]. 计算机与数字工程, 2023, 51(2): 292-295.
- ZHAO F Q. Image denoising algorithm based on improved median filter [J]. Computer and Digital Engineering, 2023, 51(2): 292-295. (in Chinese)
- [20] 王森杰, 何正伟. 基于生成对抗网络的船舶航迹预测模型[J]. 中国航海, 2021, 44(2): 72-77.
- WANG S J, HE Z W. Ship trajectory prediction model based on generative adversarial networks attention and interaction [J]. Navigation of China, 2021, 44(2): 72-77. (in Chinese)