

谭小雨. 基于多源数据意图动态时空图注意力的船舶航迹预测[J]. 智能计算机与应用, 2026, 16(2): 189-196. DOI: 10.20169/j. issn. 2095-2163. 25072801

基于多源数据意图动态时空图注意力的船舶航迹预测

谭小雨

(湖北工业大学 理学院, 武汉 430068)

摘要: 随着海上贸易日益频繁, 准确的船舶航迹预测对于提高航运效率和安全管理具有重要意义, 但目前航迹预测方法普遍忽略相邻船舶的运动信息, 以及忽略环境因素如风浪、风速、风向等对船舶的未来航行的航迹产生影响。针对上述问题, 本研究利用 AIS 数据和环境数据融合的多源数据, 提出一种改进的意图动态时空图注意力网络框架 (MS-IDSTGAT), 融入航行意图识别模块对船舶进行意图识别, 以及加入船舶时空动态图构建模块捕捉船舶间的动态交互关系。实验结果表明, 在融合的多源数据集上对比基线模型以及进行消融实验证明了研究所提出算法的有效性, 且在单一 AIS 数据上也进行对比证明了多源数据的有效性, 可以为复杂海上交通场景下的高精度航迹预测提供有效的解决方案。

关键词: 航迹预测; 时空图注意力; 船舶交互; 多源数据; 意图识别

中图分类号: TP393.08

文献标志码: A

文章编号: 2095-2163(2026)02-0189-08

Ship trajectory prediction based on intention dynamic spatio-temporal graph attention with multi-source data

TAN Xiaoyu

(School of Science, Hubei University of Technology, Wuhan 430068, China)

Abstract: With the increasing frequency of maritime trade, accurate ship trajectory prediction has become crucial for enhancing shipping efficiency and ensuring safe maritime management. However, existing trajectory prediction methods often overlook the movement information of neighboring vessels and the influence of environmental factors such as wind speed, wave height, and wind direction on future ship trajectories. To address these limitations, this study adopts a multi-source data fusion approach that integrates AIS data with environmental data, and proposes an improved Multi-Source data Intention Dynamic Spatio-Temporal Graph Attention Network framework (MS-IDSTGAT). The framework incorporates a navigation intention recognition module to infer ship maneuvering intentions and introduces a ship spatio-temporal dynamic graph construction module to model the dynamic interactions among vessels. Experimental results demonstrate that the proposed method outperforms baseline models on both the fused multi-source dataset and the single AIS dataset. Ablation studies further confirm the effectiveness of the proposed algorithm, highlighting the value of multi-source data integration in achieving high-precision trajectory prediction in complex maritime environments.

Key words: trajectory prediction; spatio-temporal graph attention; ship interaction; multi-source data; intention recognition

0 引言

随着国际交流的日益密切, 船只海上贸易变得越来越频繁。海上航行是一个复杂的动态系统, 受到诸多因素影响, 如海洋气象、船舶自身特性、航道条件等。海上交通事故一旦发生, 则将给环境、经济和人员安全造成巨大影响, 其中大部分事故是由人为因素引起的^[1]。这使得海上贸易为各国实现经济发展繁荣的同时, 也给海上交通带来了压力。对船舶进行准确的航迹预测可以为航运公司、港口管

理部门等提供重要的决策支持, 帮助改善船舶安全管理, 进一步优化船舶调度、提高运输效率。

目前, 国内外有很多专家对航迹预测方法进行了研究, 主要分为 2 类。一类是基于传统统计的航迹预测方法, 主要是通过数学物理学知识建立动力学模型, 根据现有状态进行预测, 但这些模型受假设限制较多, 还容易受到环境和天气等多方面的影响, 导致预测结果不精确。另一类是基于机器学习、深度学习的航迹预测方法。但大多数方法仅利用船舶自动识别系统 (Automatic Identification System, AIS)

作者简介: 谭小雨(2001—), 女, 硕士研究生, 主要研究方向: 深度学习, 轨迹预测。Email: 18207479367@163.com。

收稿日期: 2025-07-28

哈尔滨工业大学主办 ◆ 科技创新与应用

数据,忽略了气象、海况等环境因素对船舶航行的重要影响,且在船舶密集海域仍存在只考虑单船只自身信息等的局限性。因此,本研究提出一种基于多源数据的意图动态时空图注意力网络框架(Multi-Source data Intention Dynamic Spatio-Temporal Graph Attention Network, MS-IDSTGAT)用于船舶航迹预测。考虑到传统方法大多忽略气象因素对船舶航迹的影响以及船舶间的交互关系,本研究同时考虑 AIS 数据、气象数据以及船舶间的动态交互关系,通过捕获船舶位置速度变化和图结构信息来建模空间依赖关系,实现高精度航迹预测。

1 相关工作

早期研究主要依赖动力学模型,如卡尔曼滤波器^[2](Kalman Filter, KF)是通过当前目标的状态行为进行估计,同时利用新观测出来的数据对下一时刻的航迹进行预测。Mathew 等学者^[3]提出了基于马尔可夫的航迹预测模型,仅通过依赖当前状态预测未来。在高斯混合模型上,Dalsnes 等学者^[4]基于高斯混合模型,用多个高斯分布的组合来刻画数据分布,对船舶进行短期预测。但这些模型受假设限制较多,预测结果不精确。

随着神经网络快速发展,深度学习模型及其相关变体已经广泛应用于航迹预测中。在早期,BP 神经网络被运用到航迹预测领域^[5],预测效果、精度和时间明显优于传统的动力学模型。卷积神经网络(CNN)多是对目标进行识别分类、目标检测^[6]。循环神经网络(RNN)一般用于处理序列数据的神经网络,但在长序列预测过程中存在梯度消失和梯度爆炸问题。Hu 等学者^[7]进一步提出了双向 LSTM 捕捉更复杂的时序依赖关系。Zhang 等学者^[8]提出的时空图注意力网络(ST-GAT)将图注意力机制扩展到时空领域,在多个交通预测数据集上取得了最先进结果。Liu 等学者^[9]对 ST-GAT 做出改进,提出基于 Graph SAGE 的动态时空图卷积网络(DST-Graph SAGE),利用时空模块从节点空间邻居的过去观测中提取局部时空相关性,同时引入注意机制,根据图特征动态学习交通节点间的权值。

针对海上运输中海洋气象环境多变、恶劣天气会增加海上运输的难度的问题,Ye 等学者^[10-11]提出并改进了基于卫星 AIS 和环境数据的自适应多源船舶航迹数据预测模型 AMD,采用多层感知机和门控循环单元网络设计多源特征提取网络,通过融合中间结果来增强模型的适应性。Yang 等学者也

提出基于 RAGAN 多船舶的方法,通过整合交互门函数,有效捕捉碰撞风险和影响,以及实现船舶相互作用航迹预测^[12]。Wang 等学者^[13]提出在复杂海洋环境下多船舶的航迹以及进行规划。有学者综合考虑海洋气象环境中的海浪、风速和风向对船舶的实际航行影响,引入元启发式鲸鱼优化算法(WOA),帮助船舶在大规模复杂海洋环境中找到低能耗和安全的航线^[14]。还有通过计算风、波浪和水流的干扰力导致的船舶失速,采用基于 Maklink 法和 Dijkstra 算法求解初始路径,并用主从并行机制实现自适应遗传算法对初始路径优化^[15]。

现有船舶航迹预测方法在多源数据融合、航行意图利用和船舶交互关系建模等方面仍存在不足。本文提出的方法旨在通过 TCN 处理多源时序数据、航行意图识别融合及 ST-GAT 捕捉动态交互关系,最后,由 BiGRU 输出航迹,系统解决问题,提高船舶航迹预测的精度和适应性。

2 方法

本研究提出的基于多源数据的意图动态时空图注意力网络 MS-IDSTGAT 基于以下 2 个关键假设:

(1) 船舶航迹受到历史运动状态和环境条件的共同影响。

(2) 船舶不是独立航行的实体,而是相互影响的动态系统。基于这些假设,文中设计了 4 个关键组件构成 MS-IDSTGAT 模型,如图 1 所示。接下来将会在下文中详细介绍每一个模块。




图 1 MS-IDSTGAT 网络模型架构图

Fig. 1 MS-IDSTGAT network model architecture diagram

2.1 面向多源数据的时空图注意力网络

在密集航行区域,船舶航行的未来航迹与其他船舶息息相关,不应被视为孤立个体,而是形成复杂的相互作用系统。本研究引入基于时空图注意力网络的构建方法,研发的时空图注意力交互网络结构如图 2 所示。区别于传统的注意力机制,主要分别通过时间和空间注意力提取特征,将时间和空间的依赖关系联合,结合时空位置编码以保留时空信息建模^[8]。

模块利用船舶的位置信息(经纬度)、航速

(Speed Over Ground , SOG) 和航向 (Speed Over Ground , COG) 计算船舶间的空间关系,同时考虑航速差异和航向差异,构建反映船舶运动状态的邻接矩阵^[11]。更重要的是,模块融合从航行识别网络提取的意图特征,通过意图调整网络对基础图的边权重进行动态调整。给定船舶集合 $V = \{v_1, v_2, \dots, v_N\}$, 每艘船舶的位置坐标 (lat_i, lon_i) , 船舶之间的哈弗辛距离为:

$$d_{ij} = 2R \cdot \arcsin \left(\sqrt{\sin^2\left(\frac{\Delta lat_{ij}}{2}\right) + \cos(lat_i) \cdot \cos(lat_j) \cdot \sin^2\left(\frac{\Delta lon_{ij}}{2}\right)} \right) \quad (1)$$

其中, R 表示地球半径(6 371 km)。

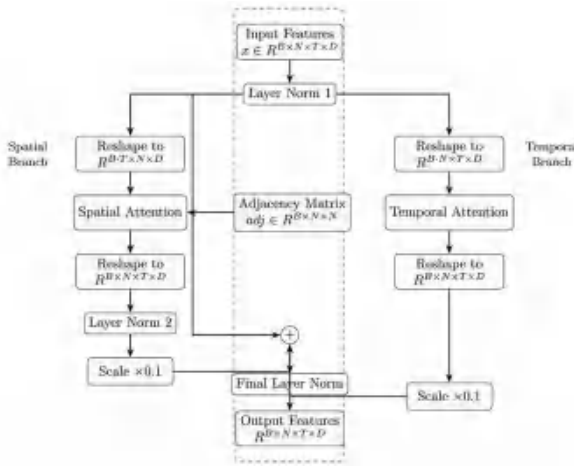


图2 时空图注意力交互网络结构

Fig. 2 Spatio-temporal graph attention interaction network structure

根据式(1),进一步推得:

$$\Delta lat_{ij} = lat_j - lat_i \quad (2)$$

$$\Delta lon_{ij} = lon_j - lon_i \quad (3)$$

速度差异和航向差异函数的定义公式具体如下:

$$\Delta sog_{ij} = |sog_i - sog_j| \quad (4)$$

$$\Delta cog_{ij} = 1 - \cos(\theta_i - \theta_j) \quad (5)$$

其中, θ_i 和 θ_j 表示将航向 cog_i 和 cog_j 转换为弧度后的值。

时空图注意力中的空间图注意力(Spatial Graph Attention, SGA)专注于建模船舶间的空间交互关系,捕捉同一时间步内不同船舶间的相互影响。对于每个时间步 t , 研究需计算 N 艘船舶之间的注意力权重。数学公式为:

$$\alpha_{ij}^{(t)} = \frac{\exp(e_{ij}^{(t)})}{\sum_{k=1}^N \exp(e_{ik}^{(t)})} \quad (6)$$

其中, $e_{ij}^{(t)}$ 表示从船舶 i 到船舶 j 在时间步 t 的注

意力得分,计算公式如下:

$$e_{ij}^{(t)} = \frac{(\mathbf{W}_Q X_i^{(t)}) (\mathbf{W}_K X_j^{(t)})^T}{\sqrt{d_k}} \quad (7)$$

其中, \mathbf{W}_Q 和 \mathbf{W}_K 分别表示查询和键的参数矩阵, d_k 表示缩放因子。注意力得分反映了船舶 i 的行为对船舶 j 的影响程度,这对于理解船舶之间的互动,如避让行为至关重要。

时间注意力(Temporal Sequence Attention, TSA)专注于船舶间的时间交互关系,捕获同一船舶在不同时间步之间的长期依赖关系和复杂模式。对于每艘船舶,计算时间步之间的注意力权重:

$$\beta_{ts}^{(i)} = \frac{\exp(e_{ts}^{(i)})}{\sum_{r=1}^T \exp(e_{tr}^{(i)})} \quad (8)$$

其中, $e_{ts}^{(i)}$ 表示船舶 i 从时间步 t 到时间步 s 的注意力得分,计算公式如下:

$$e_{ts}^{(i)} = \frac{(\mathbf{W}'_Q X_i^{(t)}) (\mathbf{W}'_K X_i^{(s)})^T}{\sqrt{d_k}} \quad (9)$$

其中, \mathbf{W}'_Q 和 \mathbf{W}'_K 分别表示时间查询和键的参数矩阵。这一机制使模型能够识别船舶的航行模式,如直线航行、转向、加减速等行为。同时采用多头注意力机制 SGA 和 TSA 分别高效捕获空间交互和时间演化特征,在实际航行场景中是紧密耦合、相互影响的,通过残差连接和层归一化整合空间和时间注意力输出。

2.2 面向多源数据的意图航行识别

本研究首先采用时间卷积网络(Temporal Convolutional Network, TCN)处理数据,用于捕获输入时间序列的长期依赖关系和局部特征模式。TCN 主要部分为因果和膨胀卷积。其中,因果卷积使得输出信息只依赖于输入信息,避免受到未来信息的干扰。膨胀卷积在卷积时对输入进行间隔采样,即膨胀因子 d 。膨胀卷积每层卷积的感受野随着层数的增加呈指数级增长,模型可以获得足够长的历史信息,同时保证因果卷积确保模型不使用未来信息^[16]。对于第 i 层膨胀卷积,其膨胀率定义为:

$$d_i = 2^{i-1}, i = 1, 2, \dots, L \quad (10)$$

其中, L 表示总层数。相应的填充大小 p_i 为:

$$p_i = (k - 1) \times d_i \quad (11)$$

其中, k 表示卷积核大小。

TCN 进行时序特征提取后,对船舶进行意图航行识别,将意图作为航迹预测的重要先验信息。首先,特征提取器通过非线性映射将航迹原时序特征

转换为意图特征空间,然后通过意图分类器根据提取的意图特征进行多类别意图判别来推断船舶的航行意图,如直线航行、转向、加减速、避障和靠港等,输出这些意图的概率分布^[17]。对比可以表示为:

$$\mathbf{F} = \mathbf{W}_2 \cdot \text{Dropout}(\text{ReLU}(\mathbf{W}_1 \cdot \mathbf{X}_{\text{encoded}} + \mathbf{b}_1)) + \mathbf{b}_2 \quad (12)$$

其中, $\mathbf{X}_{\text{encoded}}$ 表示航迹编码特征,包含了船舶的速度、航向和位置变化信息; $\mathbf{W}_1, \mathbf{b}_1$ 表示第一层线性变换的权重和偏置; $\mathbf{W}_2, \mathbf{b}_2$ 表示第二层线性变换的权重和偏置; \mathbf{F} 表示提取的意图特征。在此基础上则可得到:

$$\mathbf{I} = \text{IntentClassifier}(\mathbf{F}) \quad (13)$$

其中, \mathbf{I} 表示意图类别分数,可映射为不同的航行意图,如直线航行、转向、加减速、避障和靠港等。

2.3 面向多源数据的双向门控航迹输出

传统方法要么偏重时序建模如 LSTM、Transformer,要么侧重空间关系建模如 GNN,难以同时有效处理 2 种依赖关系^[18]。GRU 通过引入重置门和更新门,能有效地捕捉序列中的依赖关系。重置门主要是保留多少过去的信息,当 r_t 越接近 0 时,过去信息越不考虑,当 r_t 越接近 1,过去信息越保留。更新门通过新旧信息的融合比例 z_t ,候选隐藏状态 \tilde{h}_t 则基于当前输入和经过重置门筛选的历史信息计算得出的新信息,然后得到最终隐藏状态 h_t ^[6]。

本研究使用双向 GRU 网络(结构见图 3),输入为从时空注意力模块处理后的时序特征表示,同时考虑了序列的前向和后向信息,捕捉船舶的动态变化特征。将输入的隐藏状态特征解码转化为具体的航迹坐标输出经纬度预测值。可以通过如下公式表示:

$$r_t = \sigma(\mathbf{W}_r \cdot [h_{t-1}, x_t] + b_r) \quad (14)$$

$$z_t = \sigma(\mathbf{W}_z \cdot [h_{t-1}, x_t] + b_z) \quad (15)$$

$$\tilde{h}_t = \tanh(\mathbf{W}_h \cdot [r_t \odot h_{t-1}, x_t] + b_h) \quad (16)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (17)$$




图 3 BiGRU 网络结构

Fig. 3 Network structure of BiGRU

3 实验

3.1 数据集与实验设置

本文研究使用 NVIDIA GeForce RTX 4090 进行试验,采用来自台湾海峡海域 22.9°N-25.4°N, 118.0°E-121.3°E, 时间为 2023 年 12 月 17 日的 AIS 的实际船舶航行数据以及相应的气象条件数据。船舶的航迹热力图如图 4 所示。经过预处理步骤后,超参数设置为 batchsize 128, AdamW 优化器,学习率为 2e-4,权重衰减为 1e-5,采用余弦退火学习率调度,训练 200 轮,Dropout 为 0.3,损失函数采用最常见的均方误差 MSE,启用混合精度训练,按照 7.0 : 1.5 : 1.5 的比例划分为训练集、验证集和测试集。为全面评估模型性能,采用以下评估指标。



图 4 船舶航迹点热力图

Fig. 4 Ship track point heat map

(1) 平均绝对误差 (MAE): 预测位置与真实位置的平均绝对差异。可由下式求得:

$$\text{MAE} = \frac{1}{N \times T} \sum_{i=1}^N \sum_{t=1}^T |Y_{i,t} - \hat{Y}_{i,t}| \quad (18)$$

(2) 均方根误差 (RMSE): 预测航迹与真实航迹的欧氏距离。可由下式求得:

$$\text{RMSE} = \sqrt{\frac{1}{N \times T} \sum_{i=1}^N \sum_{t=1}^T \|Y_{i,t} - \hat{Y}_{i,t}\|^2} \quad (19)$$

(3) 平均位移误差 (ADE): 测量整个航迹的平均预测误差。可由下式求得:

$$\text{ADE} = \frac{1}{N \times T} \sum_{i=1}^N \sum_{t=1}^T \|Y_{i,t} - \hat{Y}_{i,t}\|_2 \quad (20)$$

(4) 最终位移误差 (FDE): 评估航迹终点预测的精确度。可由下式求得:

$$\text{FDE} = \frac{1}{N} \sum_{i=1}^N \|Y_{i,T} - \hat{Y}_{i,T}\|_2 \quad (21)$$

多源数据融合的实验结果如图 5 所示。




图 5 RMSE、MAE 和 R² 折线图

Fig. 5 Line graph of RMSE、MAE and R²

3.2 数据预处理

AIS 数据处理以及与气象融合是船舶航迹预测的基础环节,直接影响预测精度,需要对数据进行处理。流程包括数据清洗、航迹提取、时间一致性处理及多源数据融合等环节^[9]。

(1)数据清洗。首先,对 AIS 数据施加物理约束条件进行初筛,根据船舶参数合理范围剔除异常值。然后,针对关键列中的缺失值,采用互补填充策略,即航向数据缺失时使用航向角填充,反之亦然。航速缺失,则默认填充为 0。

(2)航迹提取。按照船舶 MMSI 进行分组,剔除过于稀疏或静止过长的船舶记录。

(3)时间一致性处理。由于 AIS 数据获取的时间间隔分布不均匀,本研究采用三阶样条插值方法进行数据处理。当有效数据点不足,退化为线性插值以保证计算稳定。

(4)多源数据融合。本研究采用 2 种空间匹配策略:最邻近匹配和反距离权重插值 (Inverse Distance Weighting, IDW)^[19]。先采用 IDW 插值估值 K 个气象点,通过距离加权平均计算插值结果,如果 IDW 匹配点不足,则采用最邻近匹配。进行基于气象的交叉验证,令 $K = 2, 3, 4, 5, 6, 8$ 。结果表明在 $K = 4$ 时、误差最小, R^2 最大效果最好,故取 $K = 4$ 。研究给出的距离计算公式为:

$$d = \sqrt{[(\text{lon}_2 - \text{lon}_1)^2 + (\text{lat}_2 - \text{lat}_1)^2]} \quad (22)$$

(5)归一化处理。由于不同维度数据的量纲不一致,需要消除量纲不一致的影响,采用最大最小值归一化。数学定义公式为:

$$X_{\text{norm}} = \frac{X_{\text{max}} - X_{\text{min}}}{X - X_{\text{min}}} \quad (23)$$

3.3 实验结果与分析

3.3.1 对比试验分析

为全面评估方法有效性,本文对比其他的一些船

舶航迹预测方法如 LSTM^[16]、BiGRU^[6]、GCN^[21] 等,实验采用不同时间跨度 (30 min 和 60 min) 通过 MAE、RMSE、ADE 和 FDE 多种评估指标进行全面比较,所有的指标均以 10^{-3} 为单位。各预测模型 30 min、60 min 误差结果见表 1、表 2。表 1、表 2 的实验结果表明,MS-IDSTGAT 模型在多源数据集的航迹预测任务中表现优异,综合评估指标显示 MS-IDSTGAT > GCN^[21] > BiGRU^[6] > STGAT^[8] > LSTM^[16], 其中 MS-IDSTGAT 模型的表现结果最优,这验证了其在复杂海域密集航道的航迹预测任务中的高效性。此外,通过对比 30 min 和 60 min 结果可以看出,短时预测精度比长时预测效果好,当预测时间延长时性能普遍下降。为了更好地展示模型性能,分别在不同预测时间长短下各选取 2 艘船舶进行展示,真实航迹可视化 30 min、60 min 结果如图 6 和图 7 所示,MS-IDSTGAT 的预测航迹最接近真实航迹。同时图 8 和图 9 展示了不同模型在经度和纬度上的预测误差差异结果,发现预测结果在经度上误差普遍大于在纬度上的误差,MS-IDSTGAT 明显优于其他模型,证明了该方法在船舶预测的有效性。

表 1 各预测模型 30 min 误差结果

Table 1 The 30-minute error results of each prediction model

模型	MAE	RMSE	ADE	FDE
LSTM ^[16]	0.894 44	2.600 75	1.448 04	1.390 28
BiGRU ^[6]	0.430 54	1.441 94	0.695 14	0.872 66
GCN ^[21]	0.402 20	1.478 97	0.644 12	0.744 92
STGAT ^[8]	0.557 00	1.883 09	0.884 52	0.949 18
MS-IDSTGAT	0.236 66	0.480 77	0.406 45	0.379 00

表 2 各预测模型 60 min 误差结果

Table 2 The 60-minute error results of each prediction model

模型	MAE	RMSE	ADE	FDE
LSTM ^[16]	0.674 45	1.894 73	1.088 40	1.127 21
BiGRU ^[6]	0.876 49	2.427 09	1.386 94	1.733 88
GCN ^[21]	0.489 73	2.100 11	0.787 45	0.845 68
STGAT ^[8]	0.617 12	2.030 80	0.992 79	1.158 16
MS-IDSTGAT	0.360 87	0.591 74	0.580 38	0.613 92

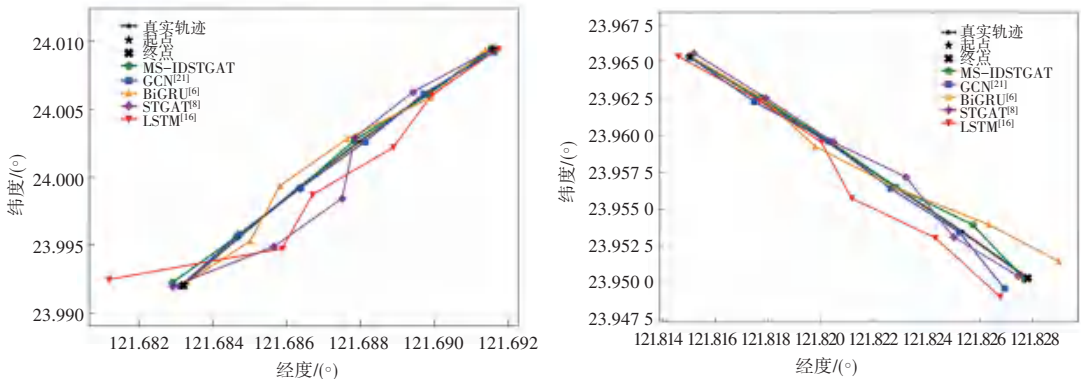


图 6 真实航迹可视化 30 min 结果

Fig. 6 30-minute results of real trajectory visualization

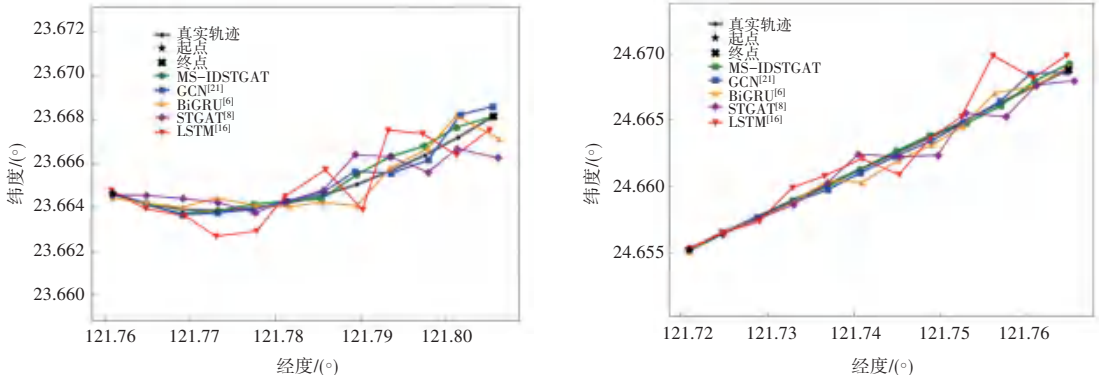


图 7 真实航迹可视化 60 min 结果

Fig. 7 60-minute results of real trajectory visualization




图 8 各预测模型经度误差

Fig. 8 Longitude errors of each prediction model

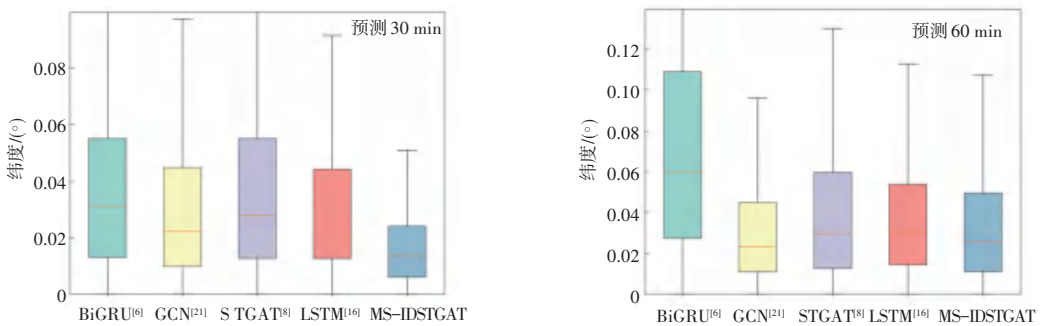


图 9 各预测模型纬度误差

Fig. 9 Latitude errors of each prediction model

3.3.2 消融实验对比分析

船舶在海上航行时会受到海上气象环境的影

响,风速风向的不同会使船舶的速度航向都会发生改变,迎风航行时会导致阻力增加。海浪会使船舶

航行产生剧烈摇动,导致船舶减速或选择绕开附近海域偏离计划航线^[22]。

为了验证使用多源数据的有效性,模型分别在多源数据和仅数据上进行试验,结果见表 3、表 4。结果表明无论是短时预测 30 min、还是长时预测 60 min,多源数据比单一源 AIS 数据进行预测效果要好。

表 3 多源数据和 AIS 数据模型 30 min 预测误差结果

Table 3 30-min prediction error results of multi-source data and AIS data model

模型	MAE	RMSE	ADE	FDE
MS-IDSTGAT	0.236 66	0.480 77	0.406 45	0.379 00
单一-IDSTGAT	0.502 30	0.988 92	0.803 66	0.861 61

表 4 多源数据和 AIS 数据模型 60 min 预测误差结果

Table 4 60-min prediction error results of multi-source data and AIS data model

模型	MAE	RMSE	ADE	FDE
MS-IDSTGAT	0.360 87	0.591 74	0.580 38	0.613 92
单一-IDSTGAT	0.523 49	0.855 18	0.826 74	0.894 86

为了验证模型各组件的有效性,还设计了一系列消融实验。主要考察了 2 个关键组件:意图识别模块和图结构时空注意力机制。文中设计无意图模型移除意图识别模块的模型变体和无图结构模型移除图结构时空注意力的模型变体,这些变体在相同的数据集和训练条件下进行训练和评估,结果见表 5 和表 6。

表 5 消除组件下各模型 30 min 预测误差结果

Table 5 30-minute prediction error results of each model eliminating the component

模型	MAE	RMSE	ADE	FDE
MS-IDSTGAT	0.236 66	0.480 77	0.406 45	0.379 00
w/o intent	0.455 54	0.654 83	0.728 40	0.753 07
w/o graph	0.431 24	0.738 30	0.698 10	0.718 09

表 6 消除组件下各模型 60 min 预测误差结果

Table 6 60-minute prediction error results of each model eliminating the component

模型	MAE	RMSE	ADE	FDE
MS-IDSTGAT	0.360 87	0.591 74	0.580 38	0.613 92
w/o intent	0.412 03	0.592 63	0.657 11	0.713 50
w/o graph	0.838 47	1.571 14	1.389 29	1.451 30

与完整模型相比,移除意图识别模块后,所有评估指标均有所下降,在 30 min 预测中,特别是 MAE 和 FDE 误差增加了约 92% 和 99%,这表明引入意图识别后的航迹预测系统能更精确地捕捉船舶的运动

模式和变化趋势,意图感知机制显著提高了预测精度。尤其在多船相互作用的复杂场景中,意图识别为系统提供了理解船舶动机的能力,从而能更准确地预测避让、跟随等行为产生的航迹变化。同时移除图结构时空注意力机制后,也显著降低了模型性能,误差增大幅度远大于移除意图识别模块。这表明图结构能够有效建模船舶航迹的时空依赖关系,船舶之间的位置速度航向航速之间的交互信息作用在重要性上远高于意图识别。完整模型在所有指标上都优于各个变体,证明了各组件之间存在协同效应,共同提升了预测性能。

4 结束语

本文针对船舶航迹预测中存在的多源数据融合不充分、航行意图利用不足及船舶交互关系建模简化等问题,提出了一种多源的时空注意力网络船舶航迹预测框架。有效结合 AIS 数据和气象数据,在时间和空间上对齐,协同航行意图识别和动态图构建,以及 ST-GAT 的船舶动态交互模块,有效捕捉船舶的未来航行意图识别以及船舶间交互关系的时空演化特性。MS-IDSTGAT 在真实数据集上的实验表明,所提方法在预测任务上对 4 种指标进行了评测。评测结果表明,该方法在 AIS 数据和 ERA5 气象数据上对 4 种评估指标即平均绝对误差(MAE)、均方根误差(RMSE)、平均位移误差(ADE)和最终位移误差(FDE)进行评价上均优于现有方法,并进行消融实验证明了方法的有效性。未来工作将增强模型在非正规场景下的预测能力,以及针对海上碰撞风险进行分析。

参考文献

[1] RAJABI A, SARYAZDI A K, BELFKIH A, et al. Towards smart port: An application of AIS data[C]// Proceedings of 2018 IEEE 20th International Conference on High Performance Computing and Communications, IEEE 16th International Conference on Smart City, IEEE 4th International Conference on Data Science and Systems. Piscataway, NJ: IEEE, 2018: 1414-1421.

[2] XIA Kerui, GAO Haibo, DING Liang, et al. Trajectory tracking control of wheeled mobile manipulator based on fuzzy neural network and extended Kalman filtering[J]. Neural Computing and Applications, 2018, 30: 447-462.

[3] MATHEW W, RAPOSO R, MARTINS B. Predicting future locations with hidden Markov models[C]//Proceedings of the 2012 ACM Conference on Ubiquitous Computing. New York: ACM, 2012: 911-918.

[4] DALSNES B R, HEXEBERG S, FLÅTEN A L, et al. The neighbor course distribution method with Gaussian mixture models for AIS-based vessel trajectory prediction[C]//Proceedings of

- 2018 21st International Conference on Information Fusion. Piscataway, NJ: IEEE, 2018; 580-587.
- [5] ZHOU Haiting, CHEN Yaojie, ZHANG Sumin. Ship trajectory prediction based on BP neural network[J]. Artificial Intelligence, 2019, 1(1): 29-36.
- [6] ZHANG Ting, SONG Wenjie, FU Mengyin, et al. Vehicle motion prediction at intersections based on the turning intention and prior trajectories model [J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(10): 1657-1666.
- [7] HU Xiong, ZHANG Boyi, TANG Gang. Research on ship motion prediction algorithm based on dual-pass long short-term memory neural network[J]. IEEE Access, 2021, 9: 28429-28438.
- [8] ZHANG Chenhan, YU J Q, LIU Yi. Spatial-temporal graph attention networks: A deep learning approach for traffic forecasting [J]. IEEE Access, 2019, 7: 166246-166256.
- [9] LIU T, JIANG A, ZHOU J, et al. Graph SAGE-based dynamic spatial-temporal graph convolutional network for traffic prediction [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(10): 11210-11224.
- [10] YE Xiao, LI Xingchen, YIN Jiangjin, et al. Adaptive multi-source data fusion vessel trajectory prediction model for intelligent maritime traffic [J]. Knowledge-Based Systems, 2023, 277: 110799.
- [11] YE Xiao, HU Yupeng, LIU Jichao, et al. An adaptive multimodal data vessel trajectory prediction model based on a satellite automatic identification system and environmental data [J]. Marine Science and Engineering, 2024, 12(3): 513.
- [12] JIA Chengfeng, MA Jie, YANG Xin, et al. RAGAN: A generative adversarial network for risk-aware trajectory prediction in multi-ship encounter situations[J]. Ocean Engineering, 2023, 289: 116188.
- [13] WANG Shoumin, NIU Ning, WANG Zhichao, et al. Heterogeneous multi-agent task planning method in complex marine environment[J]. IEEE Access, 2025, 13: 84202-84216.
- [14] HAN Qilong, YANG Xiao, SONG Hongtao, et al. Whale optimization algorithm for ship path optimization in large-scale complex marine environment[J]. IEEE Access, 2020, 8: 57168-57179.
- [15] 周扬刚. 海洋气象条件下的船舶主动变速航线优化研究[D]. 大连: 大连海事大学, 2023.
- [16] GUO Y, ZHANG J, WANG P. Prediction for TCN-BiLSTM ship trajectory based on attention mechanism [J]. Computer Measurement & Control, 2024, 32(1): 30-37.
- [17] CHO Y, HAN J, KIM J. Efficient COLREG-compliant collision avoidance in multi-ship encounter situations [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(3): 1899-1911.
- [18] ZENG Xi, GAO Miao, ZHANG Anmin, et al. Trajectories prediction in multi-ship encounters; Utilizing graph convolutional neural networks with GRU and self-attention mechanism [J]. Computers and Electrical Engineering, 2024, 120: 109679.
- [19] 陈子瑞, 刘明波, 曾贵华, 等. 应用于加速安全约束机组组合问题的 K 最邻近算法[J]. 南方电网技术, 2024, 18(11): 48-57.
- [20] 向峰, 李中志, 熊熙, 等. 粒子群局部优化的反距离权重插值算法[J]. 计算机应用, 2023, 43(2): 385-390.
- [21] 王宇, 侯凌燕, 王超, 等. 基于时间感知图卷积网络的船舶航迹预测[J]. 北京信息科技大学学报(自然科学版), 2024, 39(4): 41-48.
- [22] ADLAND R, JIA H, LODE T, et al. The value of meteorological data in marine risk assessment [J]. Reliability Engineering & System Safety, 2021, 209: 107480.