

融合图卷积神经网络与循环注意力机制的船舶航迹预测

陈信强¹, 陈伟平¹, 韩冰³, 李朝锋¹, 吴华锋², 朱宗良¹

(1. 上海海事大学 物流科学与工程研究院, 上海 201306; 2. 上海海事大学 商船学院, 上海 201306;
3. 上海船舶运输科学研究所有限公司, 上海 200135)

摘要: 船舶航迹预测在海洋交通管理、航运安全等领域的重要性日益凸显。当前的船舶时序预测方法在处理水上交通多特征数据输入时存在一些限制, 未能充分捕捉特征之间的相关性以及关注时序数据中的重要信息。针对这些不足, 并进一步提高船舶航迹预测的精度, 提出融合改进的图卷积网络(GCN)与循环注意力单元(RAU)的船舶航迹预测方法(GCAU)。利用图卷积网络来捕捉特征之间的相关性, 从而提升模型对特征之间相关性的提取能力。该方法还引入RAU中的注意力门, 能有选择性地获取时间层面的特征。对4种不同的船舶时序预测方法进行评估, 并且在3个不同的场景下进行测试。结果表明: GCAU在所有测试场景中均表现最佳, 其具有更低的均方误差(MSE)和均方根误差(RMSE)、平均绝对百分比误差(MAPE)和平均绝对误差(MAE)指标, 能有效地提高船舶航迹预测的准确性和稳定性, 为海事交通管理等领域提供更可靠的决策支持。

关键词: 船舶航迹; 图卷积网络; 循环注意力机制; 船舶安全; 航迹预测

中图分类号: U697.1

文献标志码: A

DOI: 10.3969/j.issn.1000-4653.2025.03.005

Ship trajectory prediction via an ensemble graph convolution neural network and recurrent attention mechanism

CHEN Xinqiang¹, CHEN Weiping¹, HAN Bing³, LI Chaofeng¹,
WU Huafeng², ZHU Zongliang¹

(1. Institute of Logistics Science and Engineering, Shanghai Maritime University, Shanghai 201306, China;
2. Merchant Marine College, Shanghai Maritime University, Shanghai 201306, China; 3. Shanghai Ship and Shipping Research Institute Co., Ltd., Shanghai 200135, China)

Abstract: Ship trajectory prediction has become increasingly important in marine traffic management, shipping safety, and related fields. Current methods for ship time-series prediction exhibit certain limitations when handling multi-feature data inputs in water traffic scenarios, as they fail to adequately capture the correlations among features or focus on the critical information within time-series data. To address these shortcomings and further improve the accuracy of ship trajectory prediction, this study proposes a method named GCAU, which integrates an improved Graph Convolutional Network (GCN) with a Recurrent Attention Unit (RAU). First, Graph Convolutional Networks are employed to capture interdependencies between features, thereby enhancing the model's capability to extract feature correlations. Second, an attention gate is

收稿日期: 2024-03-17

基金项目: 国家重点研发计划项目(2021YFC2801002); 国家自然科学基金项目(52331012; 52472347; 52071200); 中国博士后科学基金项目(2021M700790); 福建省自然科学基金项目(2022J01131710)

作者简介: 陈信强(1987—), 男, 副教授, 研究方向为海事大数据挖掘、交通图像处理。E-mail: xqchen@shmtu.edu.cn

通信作者: 韩冰(1981—), 男, 研究员, 博士, 研究方向为智能船舶及人工智能应用、船舶动力定位系统。E-mail: han.bing@coscoshipping.com

引用格式: 陈信强, 陈伟平, 韩冰, 等. 融合图卷积神经网络与循环注意力机制的船舶航迹预测[J]. 中国航海, 2025, 48(3): 41-48.

CHEN X Q, CHEN W P, HAN B, et al. Ship trajectory prediction via an ensemble graph convolution neural network and recurrent attention mechanism[J]. Navigation of China, 2025, 48(3): 41-48. (in Chinese)

incorporated into the Recurrent Attention Unit (RAU), enabling selective emphasis on time-level features. Finally, the study evaluates four different ship time-series prediction methods across three distinct scenarios. The results demonstrate that GCAU outperforms the other methods in all tested scenarios, achieving lower values in Mean Squared Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), and Mean Absolute Error (MAE). The proposed method can effectively enhance the accuracy and stability of ship trajectory prediction, thereby providing more reliable decision support for maritime traffic management and other related applications.

Key words: ship trajectory; graph convolutional network; recurrent attention unit; ship safety; trajectory prediction

海上运输是国内外商品交换中最重要的运输方式之一,货物运输量占全部货运量的90%^[1]以上。随着全球船舶交通的增长,准确预测船舶轨迹已成为航海安全、交通管理和环境保护等领域中至关重要的问题。预测结果可帮助船员、港口管理人员和决策者规划航线,降低事故风险^[2]。研究者们一直在探索提高船舶轨迹预测准确性和可靠性的有效方法^[3]。轨迹预测常采用基于统计模型的方法,该方法通过对历史轨迹数据进行分析 and 建模,获取船舶行为的统计规律和趋势,并利用这些规律来预测未来的轨迹。例如:赵帅兵等^[4]使用改进的卡尔曼滤波算法进行河段船舶轨迹预测;姜佰辰等^[5]构建多项式卡尔曼滤波器,解决实际过程中船舶轨迹的预测问题。尽管统计模型可提供一定的预测精度,但在处理复杂环境和非线性关系时可能存在局限性。此外,传统轨迹预测算法不能充分利用海量的船舶自动识别系统(Automatic Identification System, AIS)数据来学习船舶历史航行特性。

目前,国内外学者已在利用深度学习预测船舶轨迹方面取得良好效果。例如:张显炆等^[6]利用自编码器完成海面舰船轨迹预测;马兴民等^[7]结合支持向量机和二阶光滑核函数建立船舶航迹预测模型;周世波等^[8]利用聚类算法分析船舶AIS数据,以得到船舶交通流特征和群体行为模式;张扬等^[9]提出一种基于序列到序列模型的轨迹预测算法,以解决船舶历史轨迹相似度低、预测精度较低等问题。周慧君^[10]提出一种顾及胁迫反应机制的船舶轨迹预测方法;CHEN等^[11]基于深度学习方法开展船舶轨迹预测与分析的研究。然而,这些方法忽略了时间序列中的重要信息,导致多步船舶轨迹预测精度较低^[12]。

许多研究者在循环神经网络及其变体的基础上引入注意力机制,让模型能捕捉时间序列中的重要信息,从而提高预测性能。例如:NIU等^[13]提出一种新的循环注意力单元(Recurrent Attention Unit, RAU);刘成勇等^[14]利用注意力机制和长短期记忆网络(Long Short Term Memory, LSTM),提高船舶轨迹预测的精度。传统方法关注时序中重要时间步长

的特征,但不能深度挖掘船舶多特征输入中的潜在相关性。结合图卷积网络(Graph Convolutional Networks, GCN)挖掘船舶多维数据特征间的深层潜在相关性研究较少。在陆地车辆、行人和机器人领域,图卷积网络已广泛应用^[15-18]。尽管这些方法利用图卷积提取各个特征节点的潜在相关性以提高预测精度,但未利用注意力机制深度挖掘时间序列中的重要信息。

综上所述,在以往的轨迹预测方法中存在2个主要缺陷。

1) 未充分利用多维特征之间的相关依赖性,导致预测结果不准确。

2) 未充分挖掘时间序列中的重要信息,限制了模型性能。

在船舶轨迹预测领域,图卷积网络提取特征关系的研究有限。为解决这些问题,本研究结合图卷积网络和RAU,以发挥他们提取特征相关性和关注重要信息的优势。通过该方法,旨在提高船舶轨迹预测的准确性和稳定性,并为航运行业提供可靠的预测结果。本研究提出GCAU方法,利用图卷积提取特征相关性,然后利用循环注意力机制根据注意力权重自动提取时间维度重要的特征信息。该方法在船舶进、出海口和内河航道等3个场景预测船舶轨迹,通过验证均方误差(Mean Squared Error, E_{MS})、平均绝对误差(Mean Absolute Error, E_{MA})、平均绝对百分比误差(Mean Absolute Percentage, E_{MAP})和均方根误差(Root Mean Square Error, E_{RMS})指标,证明了GCAU方法的有效性。

1 方法

1.1 基本思路

本文提出GCAU模型来实现基于AIS动态信息的船舶轨迹预测任务。GCAU模型由GCN和RAU两部分组成。本研究提出的GCAU船舶轨迹预测算法框架见图1。本研究使用历史的 n 个时间序列数据作为输入, n 取10,其中,每个序列包含经度、纬度、艏向和对地航速。

1) 首先使用图卷积来对节点特征进行有效的

表征学习,从而捕捉到节点之间的依赖关系。然后将图卷积的输出作为 RAU 的输入,利用 RAU 的注意力模块,针对性地关注时序中的重要特征关系,使 GCAU 能处理并建模时序数据中的长期依赖性。

2) 通过全连通层进行预测,输出未来 T 个时间序列的经度和纬度信息, T 取值范围为 $[1, 30]$ 。

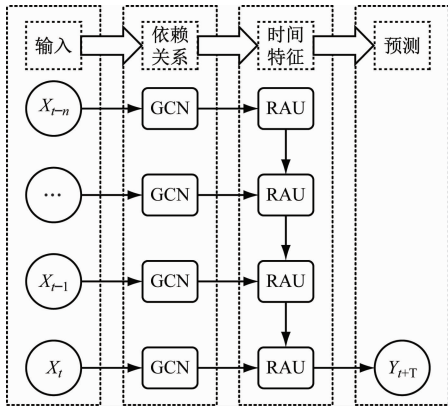


图1 GCAU 船舶轨迹预测框架

Fig. 1 GCAU ship trajectory prediction framework

1.2 图卷积

GCN 能有效建模图结构,考虑节点之间的连接关系,捕捉相邻节点的依赖信息。与单独使用循环神经网络(Recurrent Neural Network, RNN)及其变体相比,GCN 能更好地利用图结构信息进行预测任务。通过结合 GCN 和 RAU,可学习复杂拓扑结构,捕获节点间的依赖性。轨迹预测中,根据预定义的邻接矩阵可学习各个因素间的潜在依赖性。轨迹预测中根据预定义的邻接矩阵能学习各个因素间的潜在依赖性。

GCN 利用节点连接关系学习节点特征。其在傅里叶域构造一个滤波器,将其应用于图结构中的节点,通过一阶邻域捕获节点间的空间特征。通过叠加多个卷积层,建立 GCN 模型,有

$$\mathbf{L} = \mathbf{D}^{-\frac{1}{2}}(\mathbf{A} + \mathbf{I})\mathbf{D}^{-\frac{1}{2}} \quad (1)$$

$$\mathbf{H}_{GCl+1} = \sigma(\mathbf{L}\mathbf{H}_{GCl}\mathbf{W}_l) \quad (2)$$

式(1)和式(2)中: \mathbf{I} 为单位矩阵; \mathbf{L} 为拉普拉斯算子; \mathbf{D} 为邻接矩阵 \mathbf{A} 的度矩阵; \mathbf{H}_{GCl} 为第 l 层的特征,对于输入层而言, H 就是 X ; \mathbf{W}_l 为第 l 层的权重矩阵; σ 为非线性激活 sigmoid 函数。本研究选择单层 GCN 并为更好学习节点间的相关依赖性,在图卷积内部加入一个可学习矩阵 \mathbf{W}_w ,图卷积公式为

$$\mathbf{C}_G(X) = \sigma(\mathbf{L}\mathbf{W}_w\mathbf{H}_{GCl}\mathbf{W}_l) \quad (3)$$

本研究使用图卷积神经网络在 AIS 数据中捕获数据间的特征依赖性。图卷积示意图见图 2。图 2 中:假设节点 3 为 AIS 数据的纬度特征,GCN 模型可得到纬度特征与相关特征之间的拓扑关系,对

AIS 拓扑结构和船舶数据的属性进行编码,以此得到特征之间的依赖性。




图2 图卷积示意

Fig. 2 Schematic of graph convolution

1.3 循环注意力单元

时间依赖性在轨迹预测中是一个关键问题。引入注意力机制的 RAU 可计算注意力权重,衡量不同时间步的重要性,并根据先前状态和当前输入信息来调整关注度。通过将注意力权重与输入序列的向量表示相乘并加权求和,得到当前时间步的隐藏状态向量。循环注意力机制可动态调整对不同时间步的关注度,从而提升轨迹预测的准确性和鲁棒性,使模型能更好地预测船舶未来的位置和轨迹。

GRU 基本结构图见图 3,GRU 由更新门和重置门组成,其中更新门 z_t 为

$$z_t = \sigma(\mathbf{W}_z[x_t, H_{t-1}] + b_z) \quad (4)$$

式(4)中: \mathbf{W}_z 为重置门权重矩阵; H_{t-1} 为 $t-1$ 时刻的隐藏层状态; x_t 为 t 时刻的输入量; b_z 为更新门的偏置信息; $[x_t, H_{t-1}]$ 为用 cat 函数将张量 x_t 和 H_{t-1} 拼接为一个张量。重置门 r_t 为

$$r_t = \sigma(\mathbf{W}_r[x_t, H_{t-1}] + b_r) \quad (5)$$

式(5)中: \mathbf{W}_r 为重置门权重矩阵; b_r 为重置门的偏置信息。基于 r_t 可计算候选隐藏状态 \tilde{h}_t ,定义为

$$\tilde{h}_t = \tan h(\mathbf{W}_h[x_t, r_t \odot H_{t-1}] + b_h) \quad (6)$$

式(6)中: \mathbf{W}_h 为更新候选隐藏状态权重矩阵; b_h 为更新候选隐藏状态偏差; \odot 为 Hadamard 积。




图3 GRU 基本结构

Fig. 3 Structure of GRU model

最终 GRU 基本模块的输出 H_t 隐藏层状态被定义为

$$H_t = z_t \odot H_{t-1} + (1 - z_t) \odot \tilde{h}_t \quad (7)$$

RAU 基本结构图见图 4。图 4 中:虚线连接的




图4 RAU基本结构

Fig. 4 Structure of RAU model

部分表示注意力门,其根据之前的隐藏状态 H_{t-1} 和当前的输入 x_t 生成一个权值向量。因此,注意力的隐藏状态 \hat{h}_t 可计算出来, c_t 、 a_{ti} 、 \hat{h}_t 的定义分别见式(8)~式(10)。

$$c_t = \mathbf{W}_c [x_t, H_{t-1}] + b_c \quad (8)$$

$$a_{ti} = \frac{\exp(c_{ti})}{\sum_j \exp(c_{tj})} \quad (9)$$

$$\hat{h}_t = \mathbf{a}_t \odot \text{ReLU}(\mathbf{W}_{h_t} [x_t, H_{t-1}] + b_{h_t}) \quad (10)$$

式(8)~式(10)中: \mathbf{W}_c 、 \mathbf{W}_{h_t} 和 b_c 为 b_{h_t} 可学习的参数,基于 c_t 得到注意力权重向量 \mathbf{a}_t , c_{ti} 为 c_t 的第 i 个值。

除注意门外,RAU 从 GRU 继承更新门、重置门和候选隐藏状态计算公式。最终,RAU 基本单元格




图5 GCRU模型结构

Fig. 5 Structure of the GCRU model

2 试验设计与结果分析

2.1 试验数据选取

原始 AIS 数据包含着许多静态信息(船舶标识码(Maritime Mobile Service Identity, MMSI)、船舶类型和船体信息等)和动态信息,其中,动态信息与船舶轨迹更相关。本文选取3种不同航行场景(出海口、内河航道和入海口)的船舶数据,并从中提取经度、纬度、艏向和对地航速4个维度的历史数据进行轨迹预测研究。在出海口和入海口场景中,船舶拥挤,船速可能发生变化。在内河航道中,存在较多弯道,船舶的艏向变化较快。试验中对数据进行30 s均匀采样,并引入真实的3种航行场景数据。试验数据信息统计见表1,原始数据分布图见图6。

在利用图卷积网络进行船舶轨迹预测时,需设定一个邻接矩阵。针对船舶动态消息对船舶经纬度

状态的更新可按式(11)完成。

$$H_t = z_t \odot H_{t-1} + (1 - z_t) \odot \bar{h}_t + \hat{h}_t \quad (11)$$

1.4 GCAU 船舶轨迹预测方法

为捕捉 AIS 数据各特征之间的依赖性并且注意时间序列中更重要的关键特征,本文提出一种基于图卷积网络和 RAU 的船舶轨迹预测模型(GCAU)。GCRU 模型结构图见图5,图5中:左侧为船舶轨迹预测过程;右侧为 GCAU 单元的具体结构;GC 为图卷积过程,如式(3)所示,每个单元内的 z_t 被定义为式(4)、 r_t 被定义为式(5)、 \bar{h} 被定义为式(6)、 a_t 被定义为式(9)、 H_t 被定义为式(11)。

为帮助模型更好地适应数据,并减少异常值对模型参数的影响,本研究选择了 $S_{M,LI}$ 作为误差函数见式(12)。与 MSE 损失函数相比, $S_{M,LI}$ 损失函数在 $|x| < 1$ 的区域内是平方损失,而在其他区域则是线性损失。使 $S_{M,LI}$ 对大误差有更小的敏感性,即对于异常值具有更好的鲁棒性。

$$S_{M,LI}(x) = \begin{cases} 0.5(y-x)^2, & |y-x| < 1 \\ |y-x| - 0.5, & |y-x| \geq 1 \end{cases} \quad (12)$$

式(12)中: x 为真实值; y 为模型输出值。

表1 试验数据信息统计

Tab. 1 Experimental data information statistics

船舶 ID	MMSI	船舶类型	航行区域	数据长度	场景
船舶#1	214 182 516	货船	沿海航行	8 251	出海口
船舶#2	368 188 920	货船	内河航行	1 629	内河航道
船舶#3	235 076 731	油船	沿海航行	11 465	入海口

的影响,本研究考虑到船舶运动的惯性较大,艏向和对地航速对船舶未来运动轨迹有一定的影响。因此,设定一个邻接矩阵 \mathbf{A} 见式(13),其中不同行和列分别代表经度、纬度、艏向和对地航速。通过设置邻接矩阵 \mathbf{A} ,可表示不同特征之间的连接关系。具体而言,本研究用0和1来表示是否存在连接关系。例如, \mathbf{A} 中的第一行第三列($A[1][3]$)为1,表示艏向对船舶未来的经度有影响,即存在连接关系。而




图6 原始数据分布

Fig. 6 Raw data distribution map


第三行第四列($A[3][4]$)为0,表示船舶对地航速对艏向没有影响,即不存在连接关系。通过设定这样的邻接矩阵,可在图卷积网络中充分考虑不同特征之间的关联性,从而提高轨迹预测模型的准确性和稳定性。

$$A = \begin{bmatrix} 1 & 0 & 1 & 1 \\ 0 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 \\ 1 & 1 & 0 & 1 \end{bmatrix} \quad (13)$$

2.2 数据预处理

为处理 AIS 数据中的异常噪点,采取以下步骤进行数据预处理。

1) 将 AIS 数据按照时间间隔大于 30 min 的部




(a) 原始数据

分进行分割,得到不同的轨迹段。

2) 检测每个轨迹段中是否存在速度异常的轨迹点,即船速大于 30.0 n mile/h 或小于 0.5 n mile/h 的点,将其从轨迹点中去除。

3) 对无异常值的轨迹段进行均匀采样,每 30 s 采集一个点。

4) 对于缺失的采样点,采用线性插值方法进行补充,以获得完整的轨迹点。数据预处理前后对比见图 7。图 7 中:数据预处理过程中,对原始数据进行增删补查等操作,删除不规则的数据噪点,将数据间隔均匀化,以适用于时序预测模型。文中经纬度以东经和北纬为正值。



(b) 预处理后的数据

图7 数据预处理前后对比

Fig. 7 Comparison of data before and after preprocessing

2.3 数据集划分

为避免数据数量级相差太大导致模型训练效果差,先对数据用离差标准化方法归一化处理,将原始数据映射到 $[0,1]$ 区间,有

$$X_{\text{norm}} = \frac{X_l - X_{\text{min}l}}{X_{\text{max}l} - X_{\text{min}l}} \quad (14)$$

式(14)中: X_{norm} 为归一化后的特征向量; X_l 为第 l 维数据原始特征向量; $X_{\text{min}l}$ 为 X_l 特征向量中的最小值; $X_{\text{max}l}$ 为 X_l 特征向量中的最大值。

将归一化后的试验数据采取滑动窗口将经度、纬度、艏向和对地航速四维时序数据划分为输入特

征(X)和目标值(Y),创建(X,Y)样本对将用于训练模型进行预测,滑动窗口生成数据集示意图 8。 N 固定为 10 个步长(5 min),输入特征维度包括经度、纬度、艏向和对地航速。目标值长度 n 为未来 1 到 30 个步长(0.5 ~ 15 min)的轨迹预测,预测特征维度为 2(经度、纬度)。为确保模型的泛化能力,对得到的(X,Y)数据集进行随机打乱,并将其划分为训练集、验证集和测试集。这样做有助于避免模型对数据顺序的依赖性,并减少对特定样本顺序的记忆。

2.4 试验结果与分析

在对比试验中,选择经典的时序预测模型

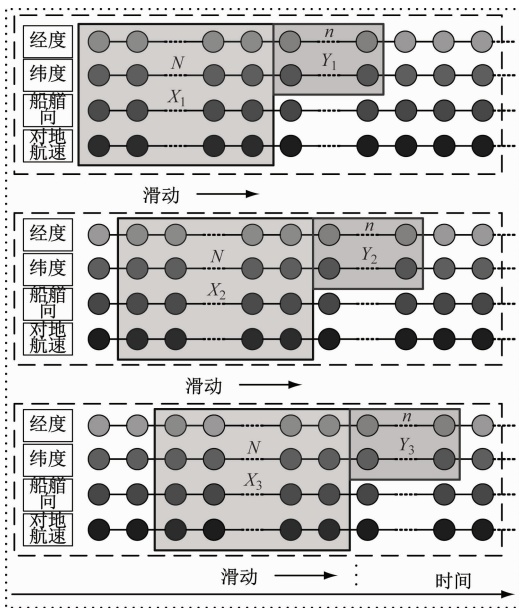


图8 滑动窗口生成数据集示意

Fig.8 Schematic of the sliding window to generate the dataset

LSTM、GRU, 以及利用图卷积与 GRU 结合的 TGCN^[21] 时序预测网络, 通过对 3 艘船舶的测试数据集进行分析, 使用经度和纬度 2 个维度上的指标来评估预测精度, 包括均方误差、均方根误差、平均绝对百分比误差和平均绝对误差分别见式(15)~式(18)。

$$E_{MS} = \frac{1}{n} \sum_{i=1}^n (\tilde{y}_i - y_i)^2 \quad (15)$$

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{y}_i - y_i)^2} \quad (16)$$

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |\tilde{y}_i - y_i| \quad (17)$$

$$E_{MAP} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\tilde{y}_i - y_i}{y_i} \right| \quad (18)$$

式(15)~式(18)中: n 为总预测步长之和; \tilde{y} 和 y_i 分别为经纬度的预测值和真实值。

3 种航行场景下的模型预测精度对比见表 2, 展示各个模型 1 到 30 步预测的指标平均值。

1) 通过船舶#1 统计数据可知本研究提出的 GCAU 模型 E_{MS} 为 2.0×10^{-6} 效果最优, 其他 3 个指标也优于对比模型, 说明 GCAU 在准确性和误差度量方面表现出色。

2) 船舶#2 代表的内河航道场景中 E_{MS} 为 1.63×10^{-5} 效果最优, 其他 3 项指标均优于对比模型, 进一步验证 GCAU 在内河航道场景中的预测能力较强。

3) 船舶#3 代表有出入海口的航线中 E_{MS} 为 3.3×10^{-5} , 其他 3 项指标均优于对比模型, 说明

表 2 3 种航行场景下的模型预测精度对比

Tab.2 Comparison of model prediction accuracies for three navigation scenarios

场景	Model	E_{MS}	E_{MA}	E_{MAP}	E_{RMS}
场景 1	LSTM	2.3×10^{-6}	0.001 1	0.003 0	0.001 5
	GRU	7.6×10^{-4}	0.011 4	0.035 1	0.026 2
	TGCN	2.2×10^{-5}	0.002 1	0.006 1	0.004 7
	GCAU	2.0×10^{-6}	0.000 7	0.002 2	0.001 4
场景 2	LSTM	2.1×10^{-5}	0.003 2	0.005 0	0.004 5
	GRU	4.0×10^{-4}	0.013 4	0.020 1	0.018 8
	TGCN	8.0×10^{-4}	0.017 2	0.027 3	0.027 6
	GCAU	1.6×10^{-5}	0.002 6	0.004 3	0.003 7
场景 3	LSTM	4.5×10^{-5}	0.004 5	0.007 3	0.006 6
	GRU	8.9×10^{-4}	0.020 3	0.031 3	0.028 1
	TGCN	2.1×10^{-4}	0.010 3	0.021 2	0.014 2
	GCAU	3.3×10^{-5}	0.003 6	0.006 8	0.005 5

GCAU 在处理出入海口船舶轨迹的预测问题时, 仍然具备一定的准确性和可靠性。

模型在不同场景下的预测误差随预测步长变化情况见图 9, 由图 9 可知: 随着预测步长的增加, LSTM 和 TGCN 模型开始累积误差, 特别是在场景 2 中, 误差增长更快。预测步长为 10 以内时, LSTM 和 GCAU 模型在 3 个场景中的预测效果接近, 但在内河航道(场景 2)和入海口(场景 3)处, GCAU 模型表现更好。预测步长为 [10, 20), LSTM 开始出现误差积累, GRU 和 TGCN 模型的误差也有所增加, 只有 GCAU 模型的误差没有明显增大。在预测步长为 [20, 30], LSTM、GRU 和 TGCN 模型的预测结果都不如 GCAU 模型精确。

船舶#1 在出海口处的预测序列所得到的权重矩阵和隐藏层输出的加入注意力前后对比见图 10。由图 10a 可知: 地航速对经度的影响为负相关, 对纬度的影响为正相关, 并且相关系数较大。艏向对经纬度的影响均为正相关, 但对纬度的影响更大; 加入注意力模块前后对比如图 10b 所示, 隐藏层输出的亮度反映特征点的重要程度, 颜色更亮的地方代表着更重要的信息, 而颜色暗淡的地方表示对输出影响较小。这样, 在 RAU 中加入注意力机制, 模型能够更关注时序中的重要信息, 从而取得更好的预测性能。

不同模型效果对比图和 GCAU 轨迹预测图见图 11。由图 11a 左侧所知: 在场景 1 中, GCAU 模型




图9 不同场景下的预测误差随预测步长变化情况

Fig.9 Plot of prediction error with prediction step size for different scenarios

的预测效果最接近真实值,而 GRU 和 LSTM 模型的预测结果偏离较大;图 11b 左侧可看到场景 2 中, GCAU 模型能准确地预测船舶的走势,其他对比模型存在预测误差较大;图 11c 左侧可看到场景 3 中,

对比模型的预测效果较差,而 GCAU 模型表现显著优于其他模型;GCAU 模型提取的轨迹如图 11 右侧所示,GCAU 预测轨迹与真实轨迹贴近,能够稳定、精确地预测船舶轨迹。



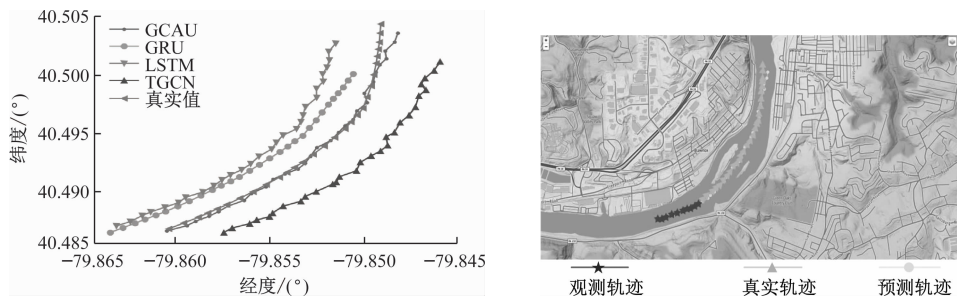


图 10 图卷积权重图与注意力前后对比


Fig.10 Graph convolutional weight map and before and after attention graph convolutional weight map vs. before and after attention



(a) 场景 1



(b) 场景 2



(c) 场景3

图11 不同模型效果对比图和 GCAU 轨迹预测

Fig. 11 Comparison of the effects of different models and prediction of GCAU trajectories

3 结束语

针对船舶轨迹预测任务未能充分挖掘数据特征关联性的问题,本文提出一种融合图卷积网络和循环注意力单元的 GCAU,先利用图卷积网络对特征相关性的捕获能力,提升模型特征相关性提取性能,再利用循环注意力单元中,有选择性地关注时间层面重要的特征。为验证 GCAU 的有效性,结合已有船舶 AIS 数据集,进行了 1 到 30(0.5—15 min) 个有限步长的预测。本研究在出海口、内河航道和入海口 3 种航行场景下验证,试验结果表明本研究相较于对比模型(LSTM、GRU 和 TGCN),均方误差和均方根误差、平均绝对百分比误差和平均绝对误差均有最优表现,表明 GCAU 能更好地预测船舶轨迹。

后续将从以下两个方面深入研究:首先,继续改进和优化 GCAU 模型,进一步提升预测性能和效果,考虑引入其他的深度学习模型和算法进行对比和集成;其次,考虑融合其他类型的数据,如船舶静态特征数据、海洋环境数据等,研究如何有效地融合多模态数据,并提高对不同类型数据之间的关联性建模能力,以进一步提升预测性能。

参 考 文 献

- [1] 周世波, 徐维祥. 船舶轨迹异常检测方法研究进展[J]. 电子测量与仪器学报, 2017, 31(3): 329-337. ZHOU S B, XU W X. Research progress on anomaly detection in vessel tracking[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(3): 329-337. (in Chinese)
- [2] 王冠, 蒲锦华. 实船轨迹测量数据处理软件开发和应用[J]. 国外电子测量技术, 2022, 41(2): 127-131. WANG G, PU J H. Development and application of data processing software for real ship trajectory measurement[J]. Foreign Electronic Measurement Technology, 2022, 41(2): 127-131. (in Chinese)
- [3] 王江, 史元浩, 郭正玉, 等. 融合小波分解和 LSTM 的目标轨迹预测[J]. 电子测量与仪器学报, 2023, 37(1): 204-211. WANG J, SHI Y H, GUO Z Y, et al. Target trajectory prediction by fusing wavelet decomposition and LSTM[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 204-211. (in Chinese)
- [4] 赵帅兵, 唐诚, 梁山, 等. 基于改进卡尔曼滤波的控制河段船舶航迹预测[J]. 计算机应用, 2012, 32(11): 3247-3250. ZHAO S B, TANG C, LIANG S, et al. Track prediction of vessel in controlled waterway based on improved Kalman filter[J]. Journal of Computer Applications, 2012, 32(11): 3247-3250. (in Chinese)
- [5] 姜佰辰, 关键, 周伟, 等. 基于多项式卡尔曼滤波的船舶轨迹预测算法[J]. 信号处理, 2019, 35(5): 741-746. JIANG B C, GUAN J, ZHOU W, et al. Vessel trajectory prediction algorithm based on polynomial fitting Kalman filtering[J]. Journal of Signal Processing, 2019, 35(5): 741-746. (in Chinese)
- [6] 张显炆, 刘刚, 马霄龙, 等. 基于变分自编码的海面舰船轨迹预测算法[J]. 计算机应用研究, 2020, 37(S1): 122-125. ZHANG X C, LIU G, MA X L, et al. A variational self coding based algorithm for predicting the trajectory of sea surface ships[J]. Application Research of Computers, 2020, 37(S1): 122-125. (in Chinese)
- [7] 马兴民, 张勇. 基于光滑核函数多支持向量机的船舶航迹预测[J]. 数学的实践与认识, 2021, 51(20): 143-150. MA X M, ZHANG Y. Ship track prediction based on multiple support vector machines with smooth kernel function[J]. Mathematics in Practice and Theory, 2021, 51(20): 143-150. (in Chinese)
- [8] 周世波, 徐维祥. 密度峰值快速搜索与聚类算法及其在船舶位置数据分析中的应用[J]. 仪器仪表学报, 2018, 39(7): 152-163.

- waterway patterns and motion behaviors [J]. IEEE Transactions on Intelligent Transportation Systems, New York:IEEE,2017: 1-13.
- [4] 孙梦竹. 舰船轨迹数据挖掘与可视化方法研究[D]. 云南:云南师范大学,2019.
SUN M Z. Research on data mining and visualization of ship trajectory [D]. Yunnan: Yunnan Normal University, 2019.
- [5] YAN Z, XIAO Y, CHENG L, et al. Exploring AIS data for intelligent maritime routes extraction [J]. Applied Ocean Research, 2020, 101: 1-10.
- [6] 刘兴龙. 内河 AIS 数据可用性保障方法研究[D]. 武汉:武汉理工大学,2024:42-51.
LIU X L. Study on the approach of ensuring AIS data availability in inland waterway [D]. Wuhan: Wuhan University of Technology, 2024:42-51.
- [7] 李永攀. 基于 AIS 数据的海上交通主要特征研究[D]. 大连:大连海事大学,2019.
LI Y P. Research on the major characteristics of maritime traffic based on AIS data[D]. Dalian: Dalian Maritime University, 2019.
- [8] 郑海林,胡勤友,杨春,等. 上海外高桥港区停留船聚类分析与异常检测[J]. 地球信息科学,2018,20(5): 640-646.
ZHENG H L, HU Q Y, YANG C, et al. Clustering analysis and anomaly detection of berthing ships at WAIGAOQIAO harbour district of Shanghai[J]. Journal of Geo-Information Science, 2018, 20(5): 640-646.
- [9] 王桃苹. 基于 AIS 数据的船舶轨迹时空数据挖掘与可视化[D]. 云南:云南师范大学,2020.
WANG T P. Spatiotemporal data mining and visualization of ship trajectories based on AIS data: a case study of the pearl river estuary [D]. Yunnan: Yunnan Normal University, 2020.
- [10] 丁兆颖,姚迪,吴琳,等. 一种基于改进的 DBSCAN 的面向海量船舶位置数据码头挖掘算法[J]. 计算机工程与科学,2015,37(11): 2061-2067.
DING Z Y, YAO D, WU L, et al. A dock mining algorithm for massive vessel location data based on improved DBSCAN [J]. Computer Engineering and Science, 2015, 37(11): 2061-2067.
- [11] PETER R J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis [J]. Journal of Computational & Applied Mathematics, 1987, 20:53-65.
- [12] ZHAO L, HAIRUO G, MINGYANG Z, et al. A data mining method to extract traffic network for maritime transport management [J]. Ocean and Coastal Management, 2023, 239:1-16.
- (上接第 48 页)
- ZHOU S B, XU W X. Clustering by fast search and find of density peaks and its application in ship Location data analysis[J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 152-163. (in Chinese)
- [9] 张扬,彭鹏飞,卢锐. 基于 Seq2Seq 的船舶轨迹变步长预测方法研究[J]. 电光与控制, 2023, 30(4): 74-77.
ZHANG Y, PENG P F, LU R. A variable-step-size prediction method of vessel trajectory based on Seq2Seq [J]. Electronics Optics & Control, 2023, 30(4): 74-77. (in Chinese)
- [10] 周慧君. 顾及环境胁迫反应机制的船舶轨迹预测方法[J]. 测绘科学, 2022, 47(9): 67-75.
ZHOU H J. Vessel trajectory prediction method considering environmental stress response mechanism [J]. Science of Surveying and Mapping, 2022, 47(9): 67-75. (in Chinese)
- [11] CHEN X, WEI C, ZHOU G, et al. Automatic Identification System (AIS) data supported ship trajectory prediction and analysis via a deep learning model[J]. Journal of Marine Science and Engineering, 2022, 10(9): 1314.
- [12] GAO D W, ZHU Y S, ZHANG J F, et al. A novel MP-LSTM method for ship trajectory prediction based on AIS data[J]. Ocean Engineering, 2021, 228: 108956.
- [13] NIU Z Y, ZHONG G Q, YUE G H, et al. Recurrent attention unit: a new gated recurrent unit for long-term memory of important parts in sequential data [J]. Neurocomputing, 2023, 517: 1-9.
- [14] 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 J, et al. On ship track prediction with LSTM and attention mechanism [J]. Navigation of China, 2021, 44(4): 94-100. (in Chinese)
- [15] LIN Z, YUE W, HUANG J, et al. Ship trajectory prediction based on the TTCN-Attention-GRU model [J]. Electronics, 2023, 12(12): 2556.
- [16] 王天保,刘昱,郭继昌,等. 图卷积神经网络行人轨迹预测算法[J]. 哈尔滨工业大学学报, 2021, 53(2): 53-60.
WANG T B, LIU Y, GUO J C, et al. Pedestrian trajectory prediction algorithm based on graph convolutional network[J]. Journal of Harbin Institute of Technology, 2021, 53(2): 53-60. (in Chinese)
- [17] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: A temporal graph convolutional network for traffic prediction [J]. Ieee Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.
- [18] ZHAO J S, YAN Z W, CHEN X Q, et al. K-GCN-LSTM: a k-hop graph convolutional network and long-short-term memory for ship speed prediction[J]. Physica A: Statistical Mechanics and Its Applications, 2022, 606: 14.