

基于 LP-Transformer 的船舶轨迹预测方法*

答欣^{1,2} 曹朋亮^{3,4} 费岳军¹ 刘建国¹

(1. 自然资源部东海发展研究中心, 上海, 200136;

2. 安泰经济与管理学院 上海交通大学, 上海, 200136;

3. 上海国际港务(集团)股份有限公司, 上海, 200136;

4. 同济大学 交通学院, 上海, 201804)

摘 要 船舶航行轨迹预测是未来海上情报获取的重要一环。本文的创新点包括: ①本文首先基于真实场景的船舶轨迹自动识别系统(automatic identification system, AIS)数据库的历史轨迹信息, 对船舶轨迹数据进行深入的特征拆解与优化; ②引入宏聚类与微聚类方法, 提升模型对复杂轨迹模式的识别能力; ③基于角度聚类构建长期预测 Transformer(long-term prediction Transformer, LP-Transformer)模型, 优化长序列预测; ④通过真实数据验证模型, 证明本文提出的方法在精确性和鲁棒性方面的性能均更优。

关键词 LP-Transformer, 自动识别系统, 轨迹预测, 船舶轨迹网络

中图分类号 U495

1 引言

海上运输是全球最重要的国内与国际贸易运输方式之一。近年来, 随着对更大运载能力和更高航速船舶需求的增加, 海上安全和相关的安保问题变得愈加突出。为了保障海上交通的安全, 开发支持交通控制与管理的工具变得至关重要^[1]。图 1 展示了船舶轨迹预测及其安全评估过程。左侧部分描述了船舶在时间轴上的运动轨迹, 分为前向轨迹点、反向轨迹点、实际轨迹点和预测轨迹点, 体现了船舶从时刻 t_1 到 t_n 的实际和预测运动情况。右侧部分展示了基于预测轨迹的安全评估, 其中两个示例分别为安全场景和风险场景。在安全场景中, 预测的船舶轨迹显示两艘船的交互位于安全范围内, 无碰撞风险; 而在风险场景中, 预测轨迹发生重叠, 表明存在潜在的碰撞风险^[2]。整体图示通过分析不同时间步长的船舶轨迹预测, 反映了轨迹推演在未来航行安全性评估中的重要作用, 为碰撞预警和避碰操作提供了依据。

AIS 的引入, 为海上交通监测、分析和建模提供了大量数据。AIS 能够频繁传输船舶位置、对地速度(speed over ground, SOG)、航向等信息, 作为一种关键的通信和导航辅助设备, 广泛用于船舶之间及其与岸基系统的交互。国际海事组织(International Maritime Organization)已对 AIS 的安装作出规范性要求。AIS 设备可传输船舶的静态和动态信息, 包括船舶类型、长度、海事移动服务标识(maritime mobile service identity)、导航位置(经纬度)、对地速度和对地航向(course over ground,

* 基金信息: 自然资源部海洋生态监测与修复技术重点实验室项目“海洋资源调查与生态监测技术”(MEMRT2025); 徐圩新区海洋产业绿色化与海洋经济高质量发展研究(015631-GKQT208-ZX001)。

通信作者: 曹朋亮, 上海国际港务(集团)股份有限公司博士后工作站, 同济大学交通学院博士后流动站, 博士后。Email: dreamcpl2@126.com。




图1 船舶运行轨迹预测

COG) 等。AIS 数据已广泛应用于海上交通研究领域, 如数据挖掘、渔船识别、无人船、海洋环境影响分析以及航行风险评估^[1]。

然而, 随着海上自主水面船舶 (maritime autonomous surface ships, MASS) 和混合交通模式的出现, 海上运输行业面临新的安全挑战。尽管 MASS 技术带来了创新, 但也引发了新的安全风险, 可能导致严重的人员伤亡和财产损失。因此, 确保混合交通模式的安全并防止灾难性事故成为当务之急。在这一背景下, 近年来学界广泛探索了提升海上安全水平的新方法, 特别是基于 AIS 数据的船舶轨迹预测技术得到了深入研究。基于 AIS 数据, Mou 等对鹿特丹港附近的分道航行计划中的碰撞事件进行了统计分析^[3]。Qu 等通过分析 AIS 数据, 提出了评估新加坡海峡船舶碰撞风险的三项指标: 速度离散度、加减速程度以及模糊船舶域重叠^[4]。Sadeghi 等基于 AIS 数据和佩德森轨迹模型 (Pedersen trajectory model), 确定了潜在碰撞船舶的数量^[5]。Abebe 等研究了湾区船舶搁浅的频率^[6]。

在河口的交通特征分析中, Xiang 等使用了里斯本港的 AIS 数据, 并将其用于交通模拟输入^[7]。随后, 他们还将“船舶域”概念融入交通模拟模型, 评估了河口的近船碰撞情景。Gao 等进一步利用 AIS 数据, 对葡萄牙海岸附近的船舶碰撞风险进行了统计识别和表征^[8]。

此外, 随着先进的数字通信和模拟技术的发展, 无人设备, 包括 MASS 的制造与应用已成为现实。MASS 的核心功能之一是自主导航系统, 该系统依赖于海上态势感知和船舶轨迹预测技术。然而, 船舶轨迹预测研究仍然面临着实时数据缺乏、多样化影响因素以及人工智能技术发展限制等挑战。虽然现有的预测方法考虑了过程噪声, 但它们依赖于确定性模型, 而这些模型通常无法反映真实场景中多种不确定因素影响导致的轨迹偏差。

本文的创新点主要体现在以下几个方面。

(1) 数据预处理创新: 在数据预处理阶段, 针对船舶轨迹数据的特征进行深入拆解和优化, 确保轨迹信息的精确表达, 为后续分析奠定坚实的基础。

(2) 宏聚类与微聚类方法的引入: 本文结合实际应用场景, 创新性地引入了宏聚类与微聚类方法。通过从不同尺度对数据进行聚类处理, 进一步提高了模型对复杂船舶轨迹模式的识别与分析能力。

(3) LP-Transformer 模型构建: 本文构造了基于角度聚类的 LP-Transformer 模型, 充分结合角度信

息与 Transformer 的长序列处理优势，提升了模型在长时间序列轨迹预测中的表现。

（4）模型先进性的实证验证：本文在真实的船舶轨迹数据上对所提出的模型进行了验证，实验结果表明，模型在实际应用中的表现优越，进一步证明了其在复杂航行环境中的预测精度与可靠性。

2 相关工作

针对轨迹预测已有学者提出了一些方案，依据时空轨迹特征的建模方式的不同，近年来的文献可以分为以下三类：①传统轨迹预测方法；②基于循环神经网络（recurrent neural network，RNN）/长短期记忆网络（long short-term memory，LSTM）的深度学习模型；③基于自相关 Transformer 的深度学习模型。

2.1 传统轨迹预测模型

在海上监视中，船舶轨迹预测是一个关键工具，支持包括目标跟踪、碰撞避免和异常交通行为检测等决策任务。其核心目的是捕捉船舶运动特性并预测未来位置。为实现这一目标，已开发了多种方法，如高斯过程、扩展卡尔曼滤波器、支持向量机和神经网络等，部分方法的概述如表 1 所示。

表 1 传统轨迹预测方法概览

模型名称	基本核心原理	优势	劣势	应用场景
高斯过程	基于高斯分布的线性回归模型，假设输出变量为目标变量的线性组合	简单易懂，快速训练，适合线性关系	不能很好地处理非线性关系，对异常值敏感	房价预测、股票价格预测等线性回归问题
卡尔曼滤波器	递归估计系统状态，基于线性系统模型和高斯噪声假设	对于动态系统有很好的实时处理能力，适应性强	仅适用于线性系统，假设噪声为高斯分布	导航系统、机器人定位、经济数据估计等
扩展卡尔曼滤波器	卡尔曼滤波器的非线性扩展，使用泰勒展开线性化非线性模型	可以处理非线性系统，广泛应用于实际问题	线性化过程可能导致估计误差，计算复杂度较高	自动驾驶导航、航天器跟踪、无人机飞行控制等
支持向量机	通过构造超平面将数据分类，最大化类间间隔	对高维数据有效，鲁棒性强，适合小样本学习	对参数选择敏感，训练时间较长，难以处理大规模数据	图像分类、文本分类、手写数字识别等
神经网络	由多个神经元组成的多层网络，通过非线性激活函数进行学习	强大的非线性建模能力，适用于大规模数据和复杂问题	需要大量数据进行训练，计算资源消耗大，缺乏可解释性	图像识别、自然语言处理、游戏智能等

在船舶轨迹预测领域，统计方法的应用较为广泛，其中高斯过程回归模型尤为常见^[9]。Suo 等通过将时间作为自变量，视船舶轨迹为一维高斯过程，该方法基于白噪声驱动的非线性时变随机微分方程，利用观测值与预测值的先验分布和协方差矩阵，计算出预测的后验分布^[9]。Abebe 等则将船舶运动分为横向和纵向，通过高斯过程对横向运动的不确定性建模，并基于加速度估计纵向运动。模型的超参数由历史 AIS 数据推导，均值和协方差函数用于描述船舶的横向位置及其不确定性^[6]。

尽管高斯过程的适用性强且易于理解，但它的计算复杂度较高，尤其是随着预测的时间跨度增大，精度可能会下降。此外，对于长时间轨迹预测，高斯过程模型对未来输入变化的考虑较少，导致其在某些应用中的适用性相对有限。然而，其在处理不确定性方面的优势使其成为解决海上复杂场景中船舶轨迹预测问题的有力工具。

相比之下，也有研究使用了多项式卡尔曼滤波器，主要用于短期预测，通过多项式拟合估计船舶轨

迹的分段特征^[10]。卡尔曼滤波器能够在不确定条件下估计系统状态，并结合不同时刻的联合分布来推断未知变量。该方法首先通过多项式拟合确定状态方程与观测方程，接着设定初始状态、误差协方差矩阵等参数，并进行多步预测。Jaskólski 等利用扩展卡尔曼滤波器估计船舶状态并预测航行轨迹，显示出其在处理噪声数据时的良好性能^[11]。尽管卡尔曼滤波器在短期预测中占据较少存储空间，但其初始条件和假设对预测结果有显著影响。

2.2 基于神经网络的模型概览

神经网络作为一种仿生计算系统，通过互连节点模拟人脑神经元的工作方式，识别数据中的隐藏模式和关系，实现数据的分类和聚类，尤其适用于处理复杂的现实问题。神经网络能够学习并模拟非线性和复杂的输入输出关系，具有广泛的应用前景。随着人工智能技术的普及，神经网络逐渐应用于海上导航领域。历史船舶轨迹和特征数据被用作神经网络的输入，而船舶的预测轨迹则作为输出。有学者提出了一种融合多种船舶运动模式的深度学习方法，训练后的神经网络可以预测不同类别船舶的轨迹，精度依赖于船舶类别，仍然存在改进空间。在预测任务中，不同类型的神经网络被广泛应用，包括人工神经网络、反向传播（back propagation，BP）网络、多层神经网络、卷积自编码器神经网络。随着人工智能技术的不断发展，神经网络逐渐被引入海上航行领域，通过输入历史船舶轨迹数据和轨迹特征，输出预测的船舶轨迹，部分方法的概述如表 2 所示。

表 2 基于神经网络的模型概览

模型名称	基本核心原理	优势	劣势	应用场景
人工神经网络	模拟生物神经网络的结构，通过连接权重学习输入与输出之间的映射关系	能够处理复杂的非线性关系，适应性强，易于扩展	训练时间长，易过拟合，缺乏可解释性	图像识别、语音识别、预测分析等
反向传播网络	通过反向传播算法计算梯度，优化网络权重，实现自主学习	实现简单、计算效率高，可以通过梯度下降方法快速收敛	可能陷入局部最优解，依赖于良好的初始化	图像分类、回归问题、时间序列预测等
多层神经网络	由输入层、隐藏层和输出层组成，使用非线性激活函数进行学习	具备更强的表达能力，可以捕捉更复杂的模式	结构设计复杂，计算资源需求高，训练时间长	图像分类、自然语言处理、推荐系统等
卷积自编码器神经网络	结合卷积神经网络和自编码器的特点，通过卷积层提取特征	能够有效地进行特征提取和降维，处理图像数据效果显著	对数据量和计算资源要求较高，训练过程较为复杂	图像压缩、去噪、图像生成等

在一些研究中，首先对船舶轨迹进行聚类，随后利用聚类结果训练人工神经网络进行轨迹预测，预测准确率可达 70%。有学者进一步使用最小二乘支持向量机与粒子群优化算法（particle swarm optimization，PSO），进行了船舶运动的短期预测。在神经网络的应用方面，船舶轨迹预测模型通常基于 AIS 数据进行轨迹相似性分组，形成交通模式的概述以推断船舶未来行为。例如，Sun 等利用人工神经网络学习船舶的正常行为，检测异常并预测运动轨迹，他们还利用计算机视觉技术，根据轨迹相似性分组并推导出交通模式^[12]。Chen 等采用分段线性分割和动态时间扭曲技术对船舶轨迹进行压缩和对齐，实现了轨迹分类和聚类^[13]，优化船舶运动预测。Wang 等则使用 AIS 数据，研究了人工神经网络模型应对不确定性场景的能力^[14]。

此外，Zhang 等采用数据驱动方法，提出了一种无监督学习方法，通过分析海上交通的分布特征，

估算船舶的兼容路线及位置概率,结合轨迹压缩和聚类技术推断船舶的空间模式,并利用 PSO-BP 算法预测最佳航线^[15]。

Zhang 等构建了一个包含两个 LSTM 层的神经网络,能够基于前 10 分钟的船舶状态预测 20 分钟后的位置^[16]。Qian 等提出了一种结合多种船舶运动模式的深度学习方法,在适当训练后,可以预测不同类型船舶的轨迹。然而,预测精度仍随船舶类别变化,需要进一步改进模型^[17]。

近年来,“序列到序列”递归神经网络模型被应用于船舶轨迹的网格化和序列化预测,包括对主要航线和到达时间的预测。LSTM 模型也被用于预测船舶位置,评估概率分布并取得了较好的结果。为了进一步提高预测的准确性,研究还引入了多方位自主设备传感器作为额外的数据输入。然而,这种方法依赖于大量 AIS 数据,导致计算成本较高^[18]。尽管大型 AIS 历史数据集可作为海洋轨迹预测的参考,但其数据质量通常无法保障,且数据冗余是一个显著问题。同时,环境条件或技术故障可能导致异常数据的产生,进而影响轨迹预测的准确性。如何在训练预测机制所需的大型数据集与减少数据冗余和噪声数据的负面影响之间找到平衡,依然是当前实践中的关键问题。然而,尽管这些方法通过多源数据输入提高了预测准确性,但它们高度依赖于大量 AIS 数据,计算性能相对较低。AIS 数据质量差异和数据冗余问题依然是轨迹预测中的挑战,尤其在全球范围内由于技术问题产生的异常数据可能严重影响预测精度。

虽然基于统计的方法具有计算存储占用少、适用于短期预测等优势,但它们依赖于理想条件下的假设,难以捕捉浅礁、岛屿等空间因素对船舶轨迹的影响。而深度学习通过更好地学习环境因素对船舶运动的影响,展现出了更强的实用性。因此,未来的研究需着重于在优化输入数据集和减少噪声数据影响的基础上,提升深度学习方法在轨迹预测中的性能。

2.3 基于自相关的深度学习模型

目前船舶轨迹预测工作多使用基于 RNN 或 LSTM 的递归预测方案,但这些方法预测时间范围短,且预测结果会受累积误差的影响^[19]。如何建模真实环境中的复杂长程(long-term)船舶轨迹仍然是很有挑战的课题。现有的长时间序列预测模型,如高斯过程、卡尔曼滤波器和神经网络,虽然在短期预测中表现良好,但在处理长时间序列时存在一定的局限性。这些模型通常难以有效捕捉长期依赖关系,并且随着时间的推移,预测精度逐渐下降。此外,确定性模型在应对复杂、不确定的环境中往往表现不足。为了更精准地预测船舶航行长程轨迹,弥补现有方法在复杂真实环境预测中的不足,基于 Transformer 的方法逐渐被引入时间序列预测领域。Transformer 架构擅长处理长距离依赖关系,具有较强的全局建模能力,因此在长时间序列预测中展示了显著的优势。它通过自注意力机制捕捉数据中的全局特征,提升了预测的精度和稳定性,尤其在应对长时间跨度的预测任务时表现优越。例如, Li 等总结了专门用于时空预测任务的基于 Transformer 的模型,相比传统递归神经网络,该模型具有更强的性能,强调了 Transformer 在处理复杂轨迹数据方面的有效性^[20]。Han 等引入的 Trajectory Transformer 模型侧重于行人轨迹预测,并说明了如何通过其注意力机制有效地建模复杂的社会行为和多样化的互动模式,进一步验证了 Transformer 对此类应用的适用性^[21]。Jaderberg 等通过设计一种专门的注意力机制来解决车辆与环境的相互作用问题,提高了预测的准确性和实用性,探索了 Transformer 在汽车轨迹预测中的应用^[22]。尽管基于深度学习的轨迹预测方法在准确性和效率方面取得了显著进步,但它们通常需要大量的计算资源,并且在处理极长的时间序列数据时可能会遇到性能限制^[23-26]。此外,这些模型通常依赖于大量的训练数据进行优化,这可能会限制它们在数据可用性有限的情况下的适用性和灵活性。

3 方法

3.1 问题定义

本文将 x_k 定义为所选取区域的 AIS 采集数据。船舶轨迹序列使用 $\{x_k^t\}$ 表示。 k 表示某一轨迹在时刻 t 的轨迹采样点的数据维度, 本文中关注的维度分别为经度 (Lat), 纬度 (Lon), 对地速度 (SOG) 和对地航向 (COG)。即采集数据可表示为 $x_k \triangleq [\text{Lat}, \text{Lon}, \text{SOG}, \text{COG}]$ 。因此, 时间 $t+1$ 时段的船只航行的历史轨迹数据可以表示为

$$x_k^{0:t} = \{x_k^0, x_k^1, \dots, x_k^t\} \quad (1)$$

待预测的未来 L 个时间点的轨迹表示为

$$x_k^{t+1:t+L} = \{x_k^{t+1}, x_k^{t+2}, \dots, x_k^{t+L}\} \quad (2)$$

对比之前的研究, 要预测选取区域的未来船舶轨迹, 也就是通过最大似然估计的方式, 设计预测模型使得条件概率 $P(x_k^{t+1:t+L} | x_k^{0:t})$ 在观测数据上取值最大:

$$P(x_k^{t+1:t+L} | x_k^{0:t}) = \prod_{l=1}^L p(x_k^{t+l} | x_k^{0:t+l-1}) \quad (3)$$

3.2 船舶数据的预处理

3.2.1 数据预处理

数据预处理对于深度学习任务来说十分重要。采集到的 AIS 原始数据常常因为接收/传递的传感器信号问题以及特殊天气的影响等, 出现数据遗失或数据噪声等情况。这些包含噪声的原始数据会影响模型对船只运动模式信息的提取, 降低预测精度。一些研究人员发现对数据去噪可以有效降低高频噪声带来的负面影响。Friedman 等以时间为自变量, 在数据预处理过程中将离散时间点得到的船舶运行轨迹看成一维高斯过程。该方法使用白噪声驱动非线性时变随机微分方程定义先验连续时间^[23]。也有学者借鉴风速预测方法, 将船舶数据的预处理与基于权变理论的线性和非线性预测系统结合, 有效解决了原始数据的位置缺失问题^[24]。还有学者提出了组合预测模型, 使用的数据预处理和优化算法策略能够有效提升模型的预测准确性^[12]。Park 等应用三次样条函数, 以 1 秒的间隔插值由目标船只的纬度、经度、航向和速度组成的观测轨迹数据^[18]。这种差值方法能够将时间戳变为 2 分钟, 解决所收集 AIS 数据动态信息缺失问题。因此, 在进行轨迹预测之前需要先提升输入轨迹数据的质量。传统的船舶轨迹数据预处理模块主要有两方面功能: 剔除异常数据 (即过滤掉明显违背运动规律的离群轨迹点) 和根据相邻信息对缺失轨迹点进行插值补全。除此之外本文发现, 数据分布的调整对提升预测精度也十分重要。因此, 本文在数据预处理中加入了冗余数据去除模块, 通过区域密度和聚类重采样的方式构造分布合理的训练数据。

3.2.2 数据重采样

经过数据采集与初步预处理, 获得了 23 779 条轨迹数据。图 2 展示了这些轨迹数据在研究区域内的分布情况, 图中呈现出大量船舶轨迹, 以放射状模式向海洋方向延伸, 表明在此区域内船舶的活动频繁,

主要航线可能集中于靠近海岸的部分。轨迹的密度在某些区域明显较高，尤其是在靠近港口及航道的位置，表明船舶的集聚现象与航道规则或交通流量密切相关。从船舶轨迹的聚类特征可以看到，原始轨迹数量庞大且存在显著的数据冗余，特别是在主要航道中，存在大量重叠的轨迹段。这种不均衡的数据分布不仅可能影响模型的表现，使其过于关注占比较大的重叠区域的时空特征，同时也忽视了重叠区域外的长尾数据分布，从而降低了模型在真实场景中对轨迹的泛化能力。





图 2 靠岸边区域轨迹分布及重叠现象展示

为此，本文采用数据重采样技术来调整样本数据的分布。首先，通过统计区域内船只轨迹的密度分布，进行初步的数据分布调整。随后，基于轨迹的长度和相似性等信息，对轨迹进行聚类，并根据聚类结果重新进行采样，以降低相似轨迹的采样权重，从而确保数据分布的多样性。

由于船舶轨迹聚类的方向不一致，本文选择了四条船舶的航线数据进行分析，以揭示不同船舶在特定观测时间范围内的航行角度、航线及方向等方面的差异。如图 3 所示，这些船舶在航行过程中表现出显著的多样性。例如，某些船舶在特定航段上呈现出较大的航行角度变化，而其他船舶则保持相对稳定的航线。此外，不同船舶在同一时间段内的行驶方向和速度也存在显著差异，这可能与各自的目的地、航行任务及外部环境因素有关。






图 3 船舶轨迹示例图

本文对轨迹长度进行了可视化展示,结果显示不同轨迹的长度分布不均衡(图 2),重叠区域内短程轨迹占比大(集中在港口附近)。如果直接使用模型拟合这样的数据分布,将导致模型过于关注短途的较简单轨迹,而降低对中长距离轨迹的预测精度。因此,亟须借助重采样技术对原始数据分布进行调整,以提高模型的预测能力,确保其能够更准确地反映船舶在不同距离航行中的行为特征。

在对轨迹进行聚类时,本文基于船首向数据将每一个船舶视为一个个体,使用核心点(core point)、边界点(border point)及其相关参数(如最小点数 MinPts),进一步提升多条船舶的轨迹聚类精度。核心点以多个黑色大圆点表示,这些点在其邻域内具备足够数量的点(至少为 MinPts=4),是聚类的中心并形成聚类的基础;而边界点位于核心点的邻域内,虽不满足成为核心点的条件,但依附于聚类的边界。图中黑色小点则表示噪声点,这些点不属于任何聚类,通常是离散且未与核心点相连的点。 ε 是确定每个数据点与其他数据点之间的最小距离,MinPts 是 ε 识别为聚类所需的最小数据量。如图 4 所示,如果 ε 中的 MinPts 超过了阈值 MinPts,则自动创建一个新的集群,并通过对相邻数据执行相同的寻找操作扩充该集群。在聚类过程中,多个圆圈代表各核心点的邻域范围,聚类的形成从核心点出发,逐步扩展至边界点,最终构建出密集区域。如果将选取的数据设为 D ,其中一个点设为 Point, ε neighborhood(N) (密度聚类中特指以某点为中心、半径为 ε 的区域,邻域记为 N) 可以表示为

$$N(p) = \{q \in D \mid \text{distance}(p, q) \leq \varepsilon\} \quad (4)$$

当 p 满足: $|N(p)| \geq \text{MinPts}$ 时,它就是核心点,图示化表达如图 4 所示。




图 4 核心点聚类图

轨迹分布重采样前后可视化如图 5 所示。




图5 经过数据重采样后的轨迹数据在区域内的可视化及其重点区域放大

从图5可以看到轨迹重叠大大减轻,轨迹密度的处理降低了冗余数据对预测精度的负面影响,但可以看到部分区域的轨迹仍然有较大重叠,说明相同运动模式的船只轨迹仍然存在冗余。

3.2.3 轨迹特征编码

图6展示了船舶轨迹数据处理与基于Transformer的轨迹预测整体框架。该框架主要包括两个部分:一是轨迹数据的多层级分块与聚类标签构建,二是基于编码器—解码器结构的轨迹预测模型。首先,输入的船舶轨迹数据经过统一处理后,被划分为若干一级轨迹分块,记为 $H_1, H_2, \dots, H_m$ 。这些一级分块用于表示原始轨迹在不同航行阶段中的局部片段。随后,每个一级轨迹分块会被进一步划分为更细粒度的二级子分块,记为 H_i ,以刻画轨迹内部更局部的运动变化特征。经过多层级聚类后,模型从这些子分块中提取三级聚类代表点,形成代表性轨迹模式集合 R ,其中, $CT_1, CT_2, \dots, CT_r$ 表示不同的聚类代表轨迹或代表性轨迹片段。




图6 船舶轨迹特征初聚类与特征编码

进一步地,聚类代表点与四级原始轨迹数据 $O_1, O_2, \dots$ 建立对应关系,并生成轨迹样本与聚类标签之间的映射关系。在图中 $T_1, T_2, \dots, T_6$,表示不同的原始轨迹样本, $CL_{R1}, CL_{R2}, \dots$ 等表示相应轨迹所属的聚类标签。其中,CL表示cluster label,即聚类标签;其下标用于区分不同的轨迹簇或代表性轨迹模式。

因此,这一阶段的作用是将复杂的原始轨迹转化为具有类别标识的轨迹模式,为后续模型学习船舶运动规律提供结构化输入。

在完成轨迹预处理、重采样和分块之后,长轨迹按照最大序列长度被拆分为若干短轨迹序列,并构造训练样本。本文训练阶段设置历史观测窗口为 3h,预测时间范围为 3~17h,用于学习船舶在不同时间跨度下的轨迹演化规律。

在 Transformer 预测部分,模型输入包括船舶轨迹的多维动态特征,如经度、纬度、对地速度和对地航向等。为增强模型对轨迹局部变化的感知能力,输入特征不仅包含原始位置与运动状态,还可以引入经纬度变化量、速度变化和航向变化等轨迹增量特征。经过特征嵌入和时间标记处理后,轨迹序列被转换为适合 Transformer 处理的输入嵌入表示。

随后,输入嵌入进入编码器部分。编码器通过多头自注意力机制计算查询 Q、键 K 和值 V,从而捕捉轨迹序列中不同时间位置之间的依赖关系。经过注意力计算后,模型通过残差连接、层归一化和前馈网络进一步增强特征表达能力。该编码过程重复 N 层,用于提取历史轨迹中的时序相关性、空间变化规律和船舶运动模式。

解码器部分接收预测阶段的输入序列,并结合编码器输出的历史轨迹特征进行未来轨迹生成。与编码器类似,解码器中也包含多头注意力、残差连接、层归一化和前馈网络等结构,并重复 M 层。在解码过程中,模型不断融合历史轨迹信息与当前预测序列特征,从而捕捉船舶未来运动方向、速度变化和空间位置演化趋势。

最终,解码器输出经过线性层和 Softmax 函数,得到不同候选轨迹模式或聚类标签的概率分布。该概率结果可用于判断船舶未来更可能属于哪一类运动模式,并进一步生成对应的预测轨迹。图中轨迹表示模型输出的不同预测轨迹模式,反映了船舶未来运动方向和路径演化的多种可能性。

3.3 船舶轨迹预测模型

为去除同质化的冗余数据,提升模型在真实场景中的泛化效果,本文首先通过 Angle-Clus 模型进行重采样。Angle-Clus 模型的轨迹聚类过程,分为微聚类和宏聚类两个步骤。首先,微聚类用于处理源源不断的数据输入,由于数据源是无限的,无法存储所有预处理过的数据并实时计算聚类,因此引入了轨迹微聚类的概念。微聚类是指聚类颗粒度非常细,微聚类的数量远多于最终的轨迹聚类数量。这一过程能够有效减少数据存储压力,并通过细粒度聚类保留局部轨迹信息。

其次,宏聚类是在接收到用户的轨迹聚类请求后执行的,利用微聚类作为输入,进行更高层次的轨迹聚类。相比不断更新的微聚类,宏聚类只在特定时刻被调用,因此新数据仅对局部聚类结果产生影响。微聚类使得最终聚类的计算更加高效,避免直接对原始轨迹线段进行计算的高复杂度操作。图 7 形象地展示了船舶轨迹聚类的宏观和微观处理过程。上半部分的宏聚类展示了输入的航迹数据,通过聚集不同方向的轨迹形成多个虚线圈定的聚类,这一过程强调了在大范围内识别相似轨迹的重要性。最终输出为简化后的轨迹表示,为后续分析提供了基础。下半部分的微聚类则更加关注局部细节,展示了在细化过程中通过粗灰色线标注的特征,从而实现对轨迹的局部调整与精细化处理。最终输出呈现了更加细致的轨迹数据,强调了细粒度聚类在捕捉复杂航行行为中的重要性。

在数据预处理完成后,模型通过编码器部分进一步提取关键特征。图 8 详细展示了基于 Transformer 架构的船舶轨迹预测模型的结构与处理流程,分为输入数据、编码器、解码器及输出结果等多个部分。首先,输入数据部分由一系列编码后的轨迹数据 $x_0, x_1, \dots, x_{t-1}$ 组成,这些数据记录了船舶在不同时间步的动态行为,涵盖经度、纬度、对地速度和对地航向等信息。图中的部分轨迹线条清晰地展现了船舶的




图7 基于船首向数据的宏聚类和微聚类图示

实际移动轨迹，这些线条不仅反映了船舶在特定时间段内的运动特征，还为模型的训练和预测提供了基础数据。




图8 LP-Transformer 轨迹预测方法示意总图

在编码器部分，输入的历史轨迹序列首先经过角度聚类模块，以提取船舶航向变化和运动方向相关的特征信息。随后，轨迹特征进入由多个编码器层堆叠构成的时序建模模块。每个编码器层包含序列分解、前馈网络和残差连接结构：序列分解用于分离轨迹中的趋势项与波动项，前馈网络用于增强特征的非线性表达能力，残差连接则有助于保持原始轨迹信息并稳定深层特征传递。经过 N 次编码器层处理后，模型获得能够表征船舶历史运动规律的编码器输出，为解码器生成未来预测轨迹提供基础。

在解码器部分，预测序列 $s_0, s_1, \dots, s_{r-1}$ 首先经过角度聚类模块进行处理，以提取与未来轨迹生成相关的局部航向变化特征。与编码器中的角度聚类侧重于历史轨迹的整体运动方向不同，解码器端的角度聚

类更强调预测起始序列中的细粒度方向变化,为后续预测提供更精细的角度约束。随后,特征进入解码器层,并依次经过序列分解、前向角度聚类注意力模块、序列分解、前馈网络和再次序列分解等结构。其中,序列分解模块用于不断分离预测序列中的趋势项与波动项,减弱轨迹非平稳性对预测结果的影响;前馈网络则进一步增强特征的非线性表达能力。

在解码过程中,编码器输出的历史轨迹特征会被引入前向角度聚类注意力模块,使解码器能够在生成未来轨迹时同时参考历史运动规律和当前预测序列的方向变化。该模块通过角度聚类机制强化对船舶航向变化、转向趋势和运动连续性的建模,从而提高模型对未来轨迹动态演化过程的捕捉能力。经过 M 层解码器结构迭代后,模型最终输出多条未来预测轨迹。

最终,解码器的输出 $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_r$ 表示模型对未来轨迹的预测。右侧的可视化结果部分通过 1 到 3 行曲线和 4 到 6 行曲线展示了不同类别的预测轨迹,表征目标未来运动的多种可能演化路径。

4 实验设计和结果

4.1 实验设计

4.1.1 AIS 数据相关介绍

AIS 是一种用于船舶和其他海上移动物体的跟踪和识别技术^[1-4]。AIS 通过甚高频 (very high frequency, VHF) 无线电波实现船舶之间及与岸基设施之间的信息交换,旨在提高航行安全性、增强海上交通管理并促进环境保护。AIS 系统定期发送船舶的位置、速度、航向、目的港、货物类型等关键信息,这些数据对于监测船舶动态、预防碰撞以及优化航线具有重要意义。

AIS 数据的实时性和高频率更新 (通常每 2 秒到 10 秒发送一次位置报告) 使得海上交通的管理变得更加高效。该数据不仅为海洋环境监测和海洋资源管理提供了基础支撑,还为科研和商业应用奠定了数据基础。例如,在航运公司中, AIS 数据可用于航线优化、燃料消耗监控及运送效率分析。此外, AIS 数据也在学术研究中被广泛应用,助力船舶行为建模、海洋安全分析和生态环境研究。

然而, AIS 数据也存在一定的局限性。例如,数据的准确性依赖于船舶设备的功能和操作,某些小型船舶可能没有配备 AIS 系统。此外, AIS 信号在某些情况下可能受到地形、气候等因素的干扰,导致数据丢失或失真。因此,在使用 AIS 数据进行分析时,需结合其他数据源进行交叉验证,以提高结果的可靠性和准确性。

4.1.2 数据描述

本文基于公开 AIS 数据,选取 2019 年全年美国南加州洛杉矶—长滩港附近海域的船舶轨迹作为研究对象。该区域覆盖洛杉矶港、长滩港及邻近外海主要航道,包括货轮和油轮的原始数据。经过筛选,共计收集到 594 374 条未经过预处理的轨迹数据。为了构建高质量的数据集,本文采用了前文提到的数据预处理和重采样技术,经过这些操作,最终得到 3023 条经过重采样的轨迹数据。此外,根据随机时间点截断固定序列长度的数据总共生成了 18 354 条有效记录。

在数据集的拆分过程中,按照惯例将数据划分为训练集、验证集和测试集,其中训练集占总数据的 70%,验证集占 10%,测试集占 20%。训练集用于模型的学习与参数优化,而验证集则用于调整模型的超参数,以确保最佳性能。测试集则用于与其他方法进行横向对比,以评估模型的泛化能力和准确性。

本文采用指标 MAE、MAPE (mean absolute percentage error, 平均绝对百分比误差)、RMSE。假设 $Y = (Y_1, Y_2, \dots, Y_N)^T$, Y 代表真实值, $\hat{Y}$ 代表预测值。其中, N 为需要测试的样本数量, 指标定义如下:

$$\text{MAE}(Y, \hat{Y}) = \frac{1}{N} \sum_{i=1}^N |Y_i - \hat{Y}_i| \quad (5)$$

$$\text{MAPE}(Y, \hat{Y}) = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100\% \quad (6)$$

$$\text{RMSE}(Y, \hat{Y}) = \left[\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \right]^{\frac{1}{2}} \quad (7)$$

4.2 结果分析

图 9 是测试集中随机采样的轨迹中, 分别使用不同方法产生的预测偏移, 为进一步展示模型的效果, 本文还展示了经过 15 分钟、30 分钟、60 分钟之后的平均预测误差。




图 9 不同时间步长下的预测误差对比

表 3 对比了多种模型在船舶轨迹预测任务中的表现, 分别评估了它们在 15 分钟、30 分钟和 60 分钟预测时间下的 MAE、RMSE 和 MAPE。从结果来看, LP-Transformer 在所有时间跨度上的预测效果优于其他模型, 其误差最小且表现最为稳定, 展示了其在短期和长期预测任务中的广泛适应性。

表 3 不同时间步长下的预测误差对比

数据	模型	15 分钟			30 分钟			60 分钟		
		MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE
AIS data	LSTM seq2seq	5.16	7.60	13.20%	5.16	7.60	13.20%	5.16	7.60	13.20%
	Conv seq2seq	4.79	8.21	10.30%	5.23	10.45	11.23%	5.24	13.23	11.23%
	LSTM seq2seq att	4.54	7.84	8.94%	4.54	9.82	11.64%	4.54	12.07	15.92%
	TrAISformer	3.44	6.30	9.60%	3.77	7.23	10.90%	4.37	8.69	13.20%
	LP-Transformer	2.99	5.89	8.04%	3.59	7.28	10.25%	4.45	8.93	13.62%

注: LSTM seq2seq: 长短期记忆网络的编码器—解码器模型; Conv seq2seq: 卷积结构的序列到序列模型; LSTM seq2seq att: 在 LSTM seq2seq 基础上引入注意力机制的改进模型, 其中“att”表示 attention; TrAISformer: 面向 AIS 船舶轨迹预测任务提出的 Transformer 类模型

在短时间预测（15 分钟）中，LP-Transformer 的 MAE、RMSE 和 MAPE 均为最低，分别为 2.99、5.89 和 8.04%，显著优于其他模型，尤其是在与 TrAISformer 相比时，该模型展现了更低的预测偏差。这表明 LP-Transformer 在处理短期船舶轨迹时具备很强的准确性和稳定性。

在中时间预测（30 分钟）中，LP-Transformer 同样表现优异，其 MAE 为 3.59，RMSE 为 7.28，MAPE 为 10.25%。这表明 LP-Transformer 不仅在短期预测中占优，在中期预测中依然能够保持高效的预测能力。

在长时间预测（60 分钟）中，多个模型的误差都有所上升，LP-Transformer 以 4.45 的 MAE、8.93 的 RMSE 和 13.62% 的 MAPE 领先于大部分其他模型，表明 LP-Transformer 在处理较长时间跨度的复杂轨迹预测时具备更强的鲁棒性和适应能力。

除了分析 MAE、RMSE 和 MAPE 等常规评估指标外，本文还通过可视化对比 LP-Transformer 预测的船舶轨迹与实际轨迹之间的差异，深入研究了该模型在不同时间跨度下的预测精度和稳定性。如图 10 所示，图中呈曲线轮廓的是研究区域的近岸岸线，其作为空间地理基准界定了水域边界；由多组折线、直线构成的密集连续线条为船舶 AIS 历史航行轨迹，直观反映了船舶在近岸海域的实际航迹分布。图 10 上半部分展示了原始 AIS 轨迹的全域分布特征，可见大量船舶轨迹沿近岸水域呈条带状密集聚集，体现了近岸航行的路径趋同性；图 10 下半部分则为 LP-Transformer 算法预测并提取出的典型代表轨迹，通过对冗余轨迹的筛除与对核心路径的提炼，显著提升了轨迹特征的辨识度，图中虚线圆圈标记则精准标定了各轨迹簇的典型代表点，清晰呈现了近岸海域船舶标准化的航行模式。这一模式反映了模型在特定条件下具备良好的预测能力，特别是在航行环境相对简单、数据质量较高时，模型能够准确反映船舶的动态行为。模型能够适应相对规律的航道和清晰的航行特征，提供可靠的预测信息，从而提升船舶航行的安全性和效率。然而船舶在实际运行的过程中，如遇到不稳定的天气、繁忙的航道或数据稀疏的区域，模型的预测准确性可能显著下降，如图 10 中虚线圆圈所示。此外，某些情况下，模型未能充分学习到特定的航行模式，导致其在异常或突发情况中的表现不佳。这种异质性显示了模型在实际应用中的脆弱性，强调了在设计和优化预测算法时需要考虑的各种环境因素和数据特性。




图 10 LP-Transformer 模型的船舶轨迹预测效果

4.3 消融实验

为了验证 LP-Transformer 方法的有效性，我们建立了一个对照组，该组采用角度微聚类和宏聚类，以探讨模型性能的提升是否得益于数据预处理过程中的角度聚类过程。在微聚类的过程中，本文构建了一个几乎相同的微聚类模型（具体而言，我们调整了每个模块中的参数，以确保输出维度与 LP-Transformer 的微聚类结构保持一致），并保持其他参数不变。

对于实验组（即使用 LP-Transformer 架构的组），我们从实验设计中移除了角度聚类模块，并用其

他数据聚类处理过程代替,以避免聚类带来的额外协变量对实验结果的干扰。在宏观角度聚类方面,本文采用了加法操作进行整合。表 4 所示对照实验,能够帮助我们更清晰地验证 LP-Transformer 的性能提升是否主要来源于角度聚类的作用。


表 4 角度聚类平行实验结果

数据	模型	Mean MAE	Mean RMSE	Mean MAPE
AIS data	Angle-Clus ₁ (宏聚类相似参数)	4.12	6.33	14.23%
	Angle-Clus ₂ (微聚类相似参数)	4.13	7.26	11.65%

为进一步验证 LP-Transformer 的预测性能,本文将其与 TrAISformer 以及 Angle-Clus 系列方法进行对比。由于表 3 分别给出了 15min、30min 和 60min 三种预测时长下的误差结果,因此本文对各时间尺度下的 MAE、RMSE 和 MAPE 进行均值计算,以获得统一的 Mean 指标。结果表明,LP-Transformer 的 Mean MAE、Mean RMSE 和 Mean MAPE 分别为 3.68、7.37 和 10.64%,均低于 TrAISformer 的 3.86、7.41 和 11.23%,说明 LP-Transformer 在整体预测精度上优于 TrAISformer。

与 Angle-Clus₁ 和 Angle-Clus₂ 相比,LP-Transformer 在 Mean MAE 和 Mean MAPE 上均表现出明显优势。其中,LP-Transformer 的 Mean MAE 分别较 Angle-Clus₁ 和 Angle-Clus₂ 降低约 10.7%和 10.9%,Mean MAPE 分别降低约 25.2%和 8.7%。这表明 LP-Transformer 在平均绝对误差和相对误差控制方面具有更好的预测能力。虽然 Angle-Clus 方法在 RMSE 指标上具有一定优势,但 LP-Transformer 在 MAE 和 MAPE 两类更能反映整体平均预测偏差的指标上表现更优,因此可以认为 LP-Transformer 具有更稳定、更综合的轨迹预测效果^①。

本文消融实验的可视化结果如图 11 所示,可以观察到主对角线区域的色块在所有图中均表现出较高的显著性,表明模型在这些区域的预测结果与真实值之间存在较小的偏差。然而,第一张图的非对角线区域相对稀疏且颜色较浅,表明在此区域的预测误差较大;而第二张图则显示出非对角线



① 在角度聚类平行实验中,采用 Mean MAE、Mean RMSE、Mean MAPE 而非单次 MAE、RMSE、MAPE,是由于单次实验指标可能受样本随机波动、算法初始化等偶然因素干扰。对多次平行实验结果取均值,可有效消除随机误差,更可靠地反映角度聚类模型的平均预测精度与泛化稳定性,保障实验结论的统计有效性与可重复性。




图 11 消融实验图示

区域存在较多的深色块，暗示在某些情况下模型的预测偏差增大。相比之下，第三张图的非对角线区域色块明显减少且颜色较浅，显示出整体表现的提升，表明模型在处理特定输入时更具鲁棒性。

5 结论

本文研究采用的宏观和微观角度相结合的轨迹聚类方法，在有效降低轨迹特征复杂度的同时，仍能精确提取轨迹中的关键信息。通过分层聚类操作，成功捕捉到轨迹中的不同尺度特征，确保信息提取的全面性与高效性。此外，实验结果表明，LP-Transformer 模型在精度和准确性方面显著优于其他对比模型，尤其是在复杂轨迹数据的预测任务中表现出色。

在提升模型整体计算性能，以增强模型的计算速度方面，本文提出的模型仍有改进空间。未来的研究可以通过引入天气等环境数据，进一步增强模型的应用范围与预测能力，从而为多维度轨迹分析提供更加丰富的参考依据。因此，可以将这项工作扩展到具有长期复杂输入的船舶轨迹数据集的预测中，与现有基准模型进行比较，改进 Transformer 模型，进一步提升 LP-Transformer 模型的预测准确性。

参考文献

- [1] Yoo S L. Near-miss density map for safe navigation of ships[J]. Ocean Engineering, 2018, 163: 15-21.
- [2] Zhao L B, Shi G Y. A method for simplifying ship trajectory based on improved Douglas-Peucker algorithm[J]. Ocean Engineering, 2018, 166: 37-46.
- [3] Mou J M, van der Tak C, Ligteringen H. Study on collision avoidance in busy waterways by using AIS data[J]. Ocean Engineering, 2010, 37 (5/6): 483-490.
- [4] Qu X B, Meng Q, Li S Y. Ship collision risk assessment for the Singapore Strait[J]. Accident Analysis & Prevention, 2011, 43 (6): 2030-2036.
- [5] Sadeghi Gargari N, Akbari H, Panahi R. Forecasting short-term container vessel traffic volume using hybrid ARIMA-NN model[J]. International Journal of Coastal and Offshore Engineering, 2019, 3 (3): 47-52.
- [6] Abebe M, Noh Y, Kang Y J, et al. Ship trajectory planning for collision avoidance using hybrid ARIMA-LSTM models[J]. Ocean Engineering, 2022, 256: 111527.
- [7] Xiang Z R, Yan J, Demir I. A rainfall-runoff model with LSTM-based sequence-to-sequence learning[J]. Water Resources Research, 2020, 56 (1): e2019WR025326.
- [8] 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.
- [9] Suo Y F, Chen W K, Claramunt C, et al. A ship trajectory prediction framework based on a recurrent neural network[J]. Sensors, 2020, 20 (18): 5133.
- [10] Fossen S, Fossen T I. eXogenous Kalman filter (XKF) for visualization and motion prediction of ships using live automatic identification system (AIS) data[J]. Modeling, Identification and Control: A Norwegian Research Bulletin, 2018, 39 (4): 233-244.
- [11] Jaskólski K, Marchel Ł, Felski A, et al. Automatic identification system (AIS) dynamic data integrity monitoring and trajectory tracking based on the simultaneous localization and mapping (SLAM) process model[J]. Sensors, 2021, 21 (24): 8430.
- [12] Sun Y, Chen X, Jun L, et al. Ship trajectory cleansing and prediction with historical ais data using an ensemble ann framework[J]. International Journal of Innovative Computing, Information and Control, 2021, 17 (2): 443-459.
- [13] Chen X Q, Ling J, Yang Y S, et al. Ship trajectory reconstruction from AIS sensory data via data quality control and prediction[J]. Mathematical Problems in Engineering, 2020, 2 (1): 7191296.
- [14] Wang G Q, Fan E, Zheng G H, et al. Research on vessel speed heading and collision detection method based on AIS data[J]. Mobile Information Systems, 2022, (1): 7257075.
- [15] Zhang Z G, Yin J C, Wang N N, et al. Vessel traffic flow analysis and prediction by an improved PSO-BP mechanism based on AIS data[J]. Evolving Systems, 2019, 10 (3): 397-407.
- [16] Zhang T, Zheng X Q, Liu M X. Multiscale attention-based LSTM for ship motion prediction[J]. Ocean Engineering, 2021, 230: 109066.
- [17] Qian L, Zheng Y Z, Li L, et al. A new method of inland water ship trajectory prediction based on long short-term memory network optimized by genetic algorithm[J]. Applied Sciences, 2022, 12 (8): 4073.
- [18] Park J, Jeong J, Park Y. Ship trajectory prediction based on Bi-LSTM using spectral-clustered AIS data. Journal of Marine Science and Engineering, 2021, (9): 1037.
- [19] Capobianco S, Millefiori L M, Forti N, et al. Deep learning methods for vessel trajectory prediction based on recurrent neural networks[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57 (6): 4329-4346.
- [20] Li X T, Ding H H, Yuan H B, et al. Transformer-based visual segmentation: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46 (12): 10138-10163.
- [21] Han K, Xiao A, Wu E, et al. Transformer in transformer[J]. Advances in Neural Information Processing Systems, 2021,

- 34: 15908-15919.
- [22] Jaderberg M, Simonyan K, Zisserman A, et al. Spatial transformer networks[C]//Proceedings of the 29th International Conference on Neural Information Processing Systems-Volume 2. Cambridge: MIT Press, 2015, 2017-2025.
- [23] Friedman D, Wettig A, Chen D. Learning transformer programs[C]//Proceedings of the 37th International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2023: 49044-49067.
- [24] Lin T Y, Wang Y X, Liu X Y, et al. A survey of transformers[J]. AI Open, 2022, 3: 111-132.
- [25] Yuan Y, Fu R, Huang L, et al. Hrformer: High-resolution vision transformer for dense predict[J]. Advances in Neural Information Processing Systems, 2021, 34: 7281-7293.
- [26] Wang X X, Pi D C, Zhang X Y, et al. Variational transformer-based anomaly detection approach for multivariate time series[J]. Measurement, 2022, 191: 110791.

The Ship Trajectory Prediction Method based on LP-Transformer

ZAN Xin^{1,2}, CAO Pengliang^{3,4}, FEI Yuejun¹, LIU Jianguo¹

(1. Development Research Center of the East China Sea, Shanghai, 200136; 2. Antai College of Economics & Management, Shanghai Jiao Tong University, Shanghai, 200030;
3. Shanghai International Port (Group) Co., Ltd, Shanghai, 200136;
4. College of Transportation, Tongji University, Shanghai, 201804)

Abstract Vessel trajectory prediction is a critical component of future maritime intelligence acquisition. The innovations of this paper are as follows: ① Based on the historical trajectory data from the real-world automatic identification system (AIS) database, this paper first conducts in-depth feature decomposition and optimization on vessel trajectory data; ② Macro-clustering and micro-clustering methods are introduced to improve the model's ability to identify complex trajectory patterns; ③ An LP-Transformer (long-term prediction Transformer) model is constructed based on angle clustering to optimize long-sequence prediction; ④ The model is validated using real-world data, demonstrating that the proposed method achieves superior performance in both accuracy and robustness.

Key words LP-Transformer, Automatic identification system (AIS), Trajectory prediction, Ship track network

作者简介

咎欣 (1991—), 女, 河南新乡人, 自然资源部东海发展研究中心, 上海交通大学安泰经济与管理学院博士后, 研究方向为运输经济理论与政策、海洋战略管理。Email: 18113021@bjtu.edu.cn。

曹朋亮 (1993—), 男, 河南洛阳人, 上海国际港务 (集团) 股份有限公司博士后工作站, 同济大学交通学院博士后流动站, 博士后, 研究方向为数字化交通, 港口集疏运优化。Email: dreamcpl2@126.com。

费岳军 (1971—), 男, 上海人, 自然资源部东海发展研究中心, 正高级工程师, 研究方向为海洋经济与战略管理。Email: fyj12768@163.com。

刘建国 (1983—), 男, 山东人, 自然资源部东海发展研究中心, 高级工程师, 研究方向为海洋资源优化与管理。Email: pululu_0811@163.com。