

文章编号:1000-4653(2025)01-0077-07

# 基于非集计和 LSTM 模型的港口水域船舶短时交通流预测研究

蔡嘉诚, 连峰, 杨忠振  
(宁波大学 海运学院, 浙江 宁波 315832)

**摘要:**随着海运量的持续高涨,港区航道船舶交通流密度不断增加,港口水域通航环境日趋复杂,港口水域船舶短时交通流预测在航道交通组织与航行安全保障中的作用愈发重要。为解决集计预测模型精度低的问题,基于进港船舶自动识别系统(AIS)数据,采用非集计的方法构建长短时记忆网络(LSTM)与历史轨迹匹配的混合预测模型,用以计算港口水域船舶短时航行轨迹,把船舶航行轨迹与进港航道断面的交叉次数作为短时航道断面的船舶流量。基于2020年6—12月宁波舟山港水域的AIS数据的验证计算显示,非集计方法的预测精度高达80%,明显高于传统的集计方法,该方法的提出为港口实施航道交通流管控策略、提高航道利用率奠定了技术基础。

**关键词:**非集计模型;船舶自动识别系统;长短时记忆网络;港口航道;短时段轨迹预测

中图分类号:U69 文献标志码:A DOI:10.3969/j.issn.1000-4653.2025.01.010

## Research on short-term ship traffic flow prediction in port waters based on disaggregated model and long short-term memory (LSTM) model

CAI Jiacheng, LIAN Feng, YANG Zhongzhen  
(Marine College, Ningbo University, Ningbo 315832, China)

**Abstract:** With the continuous increase in seaborne trade volume, ship traffic density in port areas is rising, and navigation conditions in port waters are becoming more complex. Short-term ship traffic prediction in port waters is playing an increasingly critical role in ship traffic control and navigation safety management. To address the limitation of low accuracy in aggregate models, this paper, based on ship Automatic Identification System (AIS) data, employs a disaggregate method to construct a hybrid prediction model. This model combines the Long Short-Term Memory (LSTM) network with ships' historical trajectories to calculate short-term ship trajectories in port waters. The counts of ships' trajectories intersecting with an approach channel section are used to predict the short-term ship flow across the section. A numerical example from Ningbo-Zhoushan Port during June to December 2020 demonstrates that the forecasting accuracy of the proposed model reaches up to 80%, significantly higher than that of traditional aggregate models. The model developed here provides a technical foundation for ports to implement ship traffic control methods and improve channel utilization rates.

**Key words:** disaggregate model; ship traffic; AIS; LSTM; port channel; short term trajectory

随着港航物流量的增加,港口水域的船舶交通流愈发密集,航道内船舶航行安全风险增加,港口航道交通管理问题日趋复杂,港口设施效率保证和资源配置的难度不断增加。港口水域短期船舶交

通流预测是港口航道交通管控的基础,有助于提高航道的通航效率与航行安全。目前,主要有两种短时船舶交通流的预测方法,分别是以数理统计与微积分等传统数学模型与物理方法为基础的预测方法

收稿日期:2023-04-22

基金项目:国家自然科学基金项目(72271132;72072097)

作者简介:蔡嘉诚(1999—),男,硕士生,研究方向为港航运输管理。E-mail:2013415619@qq.com

通信作者:杨忠振(1964—),男,教授,博士,研究方向为交通运输规划与管理。E-mail:yangzhongzhen@nbu.edu.cn

引用格式:蔡嘉诚,连峰,杨忠振.基于非集计和 LSTM 模型的港口水域船舶短时交通流预测研究[J].中国航海,2025,48(1):77-83.

CAI J C, LIAN F, YANG Z Z. Research on short-term ship traffic flow prediction in port waters based on disaggregated model and long short-term memory (LSTM) model[J]. Navigation of China, 2025, 48(1): 77-83. (in Chinese)

和以现代科学技术与方法为手段的预测方法。

1) 传统数学模型的预测方法主要包括卡尔曼滤波模型、时间序列模型和灰色模型等。张矢宇等<sup>[1]</sup>通过分析选定断面处的船舶交通流时空特性,结合回归模型和卡尔曼滤波模型对南京下游航道整治区域的船舶交通流量进行预测,证明其预测的船舶交通流有较高的时空精度;HE等<sup>[2]</sup>和余珍等<sup>[3]</sup>基于内河历史船舶自动识别系统(Automatic Identification System, AIS)数据,结合时间序列法和自回归积分滑动平均模型(Auto-Regressive Integrated Moving Average Model, ARIMA)预测武汉长江大桥的船舶流量,结果显示组合预测与现场观测数据较为吻合;刘成勇等<sup>[4]</sup>结合灰色预测理论与马尔科夫预测方法预测分析长江口河段的船舶交通流量,发现与单一灰色预测模型相比,灰色马尔科夫预测模型的精度更高。

2) 由于船舶交通流具有非线性和随机性<sup>[5]</sup>的特征,传统数学模型的预测精度并不高,因此,基于神经网络、无参数回归和支持向量机(Support Vector Machines, SVM)等以现代科学技术和方法为主要研究手段的预测方法逐渐成为研究的重点,这类方法采用的模型并不追求严格意义上的数学推导和明确的物理意义,更重视对真实交通流现象的拟合结果。冯宏祥等<sup>[6]</sup>基于SVM理论,用长江苏通大桥的断面观测数据,预测大桥断面船舶的短期流量,证明其方法的精度高于线性回归预测法(Statistical Package for the Social Sciences, SPSS);李晋等<sup>[7]</sup>基于船舶AIS数据,用遗传算法优化得到的神经网络预测进出天津港的船舶流量,发现优化后的神经网络的预测精度要高于单一模型;刘敬贤等<sup>[8]</sup>结合卷积神经网络和长短时记忆网络(Long Short-Term Memory, LSTM)构建交通流量预测模型,并引入动态时间规整算法作为模型的损失函数,预测武汉长江二七大桥附近水域的船舶交通流量,发现比单一的神经网络预测的结果更接近实际。

以上2种预测方法都是基于集计模型,根据对象断面的历史流量数据,估算未来短时的船舶流量。这种船舶短期交通流量预测精度低,因为,集计模型难以应对预测过程中的随机性和复杂性,且需要的历史数据在采集时有丢失和噪声严重的问题。为减少预测结果的不确定性,提高船舶交通流量的预测精度,可基于预测区域内每艘船舶未来的轨迹来预测对象航道断面的短期船舶流量。在船舶轨迹预测方面,徐铁等<sup>[9]</sup>和姜佰辰等<sup>[10]</sup>基于船舶的典型航行特征数据,利用卡尔曼滤波法预测船舶轨迹,发现预

测精度随预测时间间隔的增加降低。随着神经网络技术的发展,研究者将神经网络模型用于解决复杂的多变量输入问题。GAN等<sup>[11]</sup>采用K-Means聚类算法结合人工神经网络对长江段的船舶轨迹长度进行预测,试验结果表明预测精度比传统预测方法的高。任雨翔等<sup>[12]</sup>和GAO等<sup>[13]</sup>基于LSTM网络构建船舶轨迹预测模型,预测未来一段时间内船舶的位置、航向与航速等。另外,为提高船舶轨迹预测的精度,研究者进行混合预测,发挥不同预测方法的优势,最大限度地减少预测误差。如高大为等<sup>[14]</sup>结合当前航迹模型与区域预测模型,实施短时船舶交通流预测,并基于海上AIS和内河AIS数据进行测试,结果显示混合预测具有较高的预测精度;ZHANG等<sup>[15]</sup>基于历史轨迹数据库,通过比较船舶的航行特征与历史轨迹之间的相似度,利用随机森林算法结合船舶挂靠港口的频率的决策模型来预测船舶未来轨迹和到港时间。WEI等<sup>[16]</sup>采用实时分解、Boosting算法和误差修正框架的混合模型预测大型船舶的多步轨迹,发现混合预测模型具有更高的预测精度。

综上所述,目前,有关船舶轨迹预测的研究大多只使用船舶的历史AIS数据,忽略对当前船舶AIS数据的挖掘。实际上,当前船舶AIS数据隐含着未来一个或几个短时间段内船舶可能出现的位置信息,是最可靠地分析下一个或几个时间段船舶所在位置的数据。尤其在港口水域,船舶AIS数据的准确性和完整性都非常好。例如,本文案例中的宁波舟山港水域的日AIS数据多达1 G,0~14 kn且存在航向变化的3 s刷新动态数据平均每次可刷新350艘船舶的记录,AIS数据完整度极高。因此,显示预测短期船舶交通流时,轻视当前AIS数据过度重视历史AIS数据有可能出现基础数据倒挂的现象。本文的创新之处在于把港口水域中所有目标船舶都作为研究对象,基于当前的船舶AIS数据与历史AIS数据,构建LSTM网络与Hausdorff距离匹配历史进港轨迹的混合预测模型,先基于当前的AIS数据预测船舶的航行轨迹,再预测航道断面的短时船舶交通流,这种混合预测方法可极大地提高港口水域短期船舶交通流量的预测精度。

## 1 预测方法介绍

1) 对原始AIS数据进行预处理,并判断有效数据集中的船舶是否有进港历史。

2) 利用LSTM网络和基于Hausdorff距离的相似历史进港轨迹匹配法预测区域船舶的航行轨迹。

3) 整合所有预测的船舶轨迹,并根据与断面相交的船舶数量从而得到未来时点的航道断面船舶流量。

4) 比较分析预测结果与集计模型给出的结果,明确本文提出模型的有效性。预测总体流程见图 1。

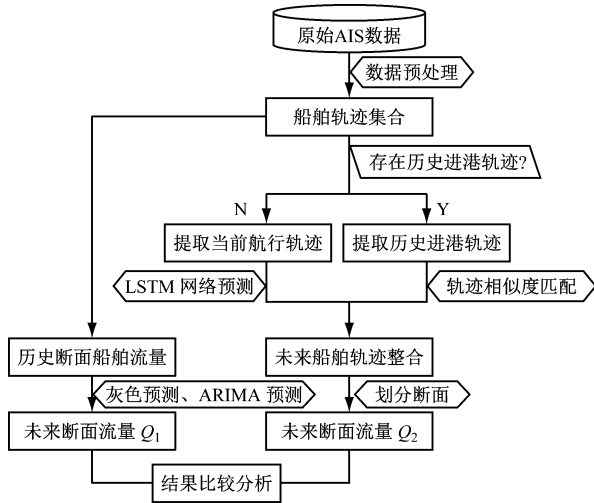


图 1 预测总体流程

Fig. 1 Flow chart of the prediction

## 1.1 数据预处理

在某个时间段内,港口水域会有各种类型的船舶,其尺寸、速度和行为有明显的差异,由于预测船舶交通流量的目的是通过航道管控以实现最有效的泊位作业,因此,主要需要预测的是进港航道断面上的短期船舶交通流,对象是需要泊位服务的船舶。在此背景下,本文选取有明确进港需求的大型货船作为研究对象,即 AIS 静态数据中识别码在 70 ~ 89 区间的移动通信业务标识 (Maritime Mobile Service Identification, MMSI) 的船舶。其中:70 ~ 79 为货船识别编码;80 ~ 89 为油船识别编码。

数据预处理主要是清除异常数据和进行数据插值。清除异常数据主要是剔除水上移动物的 MMSI 为 0 或不同船舶但 MMSI 相同的数据,船舶经度超过 180°、纬度超过 90°、航速与航向明显不合理的数据和没有明确目的港的数据。

为弥补部分缺失 AIS 数据以及避免轨迹间隔不等引起的预测误差,本文用 3 次样条插值<sup>[17]</sup>将目标船舶轨迹通过插值得到间隔均为 10 s 的轨迹路线。假设轨迹中的每个微小区间的函数表达均是不高于 3 次的多项式,则 3 次样条插值函数  $S(x)$  为

$$S_i(x) = a_i x^3 + b_i x^2 + c_i x + d_i \quad (1)$$

式(1)中: $a_i$ 、 $b_i$ 、 $c_i$  和  $d_i$  为待定系数。为使曲线光滑,式(1)要满足  $S(x)$ 、 $S'(x)$  和  $S''(x)$  连续,因此可

构建方程组为

$$S(x_i - 0) = S(x_i + 0) \quad (2)$$

$$S'(x_i - 0) = S'(x_i + 0) \quad (3)$$

$$S''(x_i - 0) = S''(x_i + 0) \quad (4)$$

为计算得到等间隔的船舶轨迹点,首先需根据每个轨迹节点的经纬度值与第 1 类边界条件求 3 次样条方程的 4 个系数,然后构建完整的插值函数。构建完插值函数后,可通过输入船舶轨迹的起始点和终点的位置计算出等时间间隔的插值点,从而弥补轨迹数据缺失带来的预测误差。

数据预处理后,根据船舶 MMSI 可提取并按航次保存船舶 AIS 数据,然后基于 AIS 数据的更新时间间隔  $\Delta t = t_{i+1} - t_i$ ,判断同一组 MMSI 的轨迹是否为同一航次,即若  $\Delta t \geq 24$  h,则储存为新航次。在同一航次内,提取船舶 MMSI 编码为  $i$  的经度、纬度、对地航速和对地航向等 4 种带时间信息的 AIS 动态数据,按照集合保存为

$$T_{i,K} = (x_{i,t}, y_{i,t}, s_{i,t}, c_{i,t}) \quad (5)$$

式(5)中: $K$  为航次; $x$  为经度; $y$  为纬度; $s$  为对地航速; $c$  为对地航向。

## 1.2 轨迹预测模型构建

1) 通过划分港口停泊区域,把杂乱的船舶历史轨迹按到达港区和航次划分为分段进港的历史轨迹。

2) 对于有历史进港轨迹的船舶,基于 Hausdorff 距离衡量当前轨迹与历史进港轨迹之间的相似度,从而找到与之匹配的最优历史进港轨迹;对没有进港历史轨迹的船舶,基于当前船舶的航行特征利用 LSTM 网络预测未来的轨迹。

### 1.2.1 基于 Hausdorff 距离匹配历史进港轨迹的预测模型

1) 进港历史识别。为提取船舶进港的历史轨迹,需确定船舶是否有过进港记录,即:是否驶入港口的停泊区域,为此首先在港区内划定停泊区。为防止将经过码头附近的船舶误识别为进港停泊船舶,需把港区码头泊位附近狭窄的矩形区域设定为停泊区,在此处出现的船舶被认为是驶入港口停泊区的船舶。基于航迹经纬度判断船舶是否通过该区域的方法如下:

$$P_{in} = (x_{i,t_{min}}, y_{i,t_{min}}) \in T_{i,K}, (x_{i,t_{min}}, y_{i,t_{min}}) \in U_j \quad (6)$$

$$P_{out} = (x_{i,t_{max}}, y_{i,t_{max}}) \in T_{i,K}, (x_{i,t_{max}}, y_{i,t_{max}}) \notin U_j \quad (7)$$

$$L = (P_{in}, P_{out}) \quad (8)$$

$$S_{ij} = \begin{cases} 1, & L \cap U_j \\ 0, & \text{Other} \end{cases} \quad (9)$$

式(6)~式(9)中: $U_j$ 为港区 $j$ 的矩形停泊区域; $P_{in}$ 为船舶 $i$ 在第 $K$ 航次中出现在 $U_j$ 内时间最早的点; $P_{out}$ 为船舶 $i$ 在第 $K$ 航次中出现在 $U_j$ 外时间最晚的点; $L$ 为 $P_{in}$ 和 $P_{out}$ 的连线; $S_{ij}$ 为船舶 $i$ 在港区 $j$ 的停泊状态,当直线 $L$ 与矩形停泊区域相交时,状态 $S_{ij}$ 为1,否则为0。

在确定船舶的进港行为后,需提取船舶进港航行轨迹。为增加历史进港轨迹的可靠性,本文选择船舶到达停泊区域前48 h的轨迹作为历史进港轨迹,即:在停泊状态 $S_{ij} = 1$ 的船舶集合中,提取点 $P_{in}$ 的 $t$ 时刻之前48 h的船舶轨迹数据,储存为

$$T_{ij,K} = (x_{i,t}, y_{i,t}, s_{i,t}, c_{i,t}) \quad (10)$$

2) 历史进港轨迹匹配。在提取历史进港轨迹后,需对当前轨迹与历史轨迹进行相似度分析,并选择相似度最高的历史轨迹进行匹配。由于两段轨迹间不可避免地存在差异,因此把当前轨迹的终点与距离历史进港轨迹最近的点通过线性插值法连接起来,以此弥补轨迹之间的空隙。历史轨迹匹配流程图见图2。




图2 历史轨迹匹配流程

Fig. 2 Trajectory matching process

①根据相同目的港,比较船舶当前轨迹与进过港的所有船舶的历史进港轨迹。由于 Hausdorff 距离能直接比较不同数据长度间的相似度,也能消除轨迹子段之间的公共偏差,因此,用 Hausdorff 距离度量2个轨迹之间的相似度<sup>[18]</sup>,设2个轨迹集合 $T_1 = \{a_1, a_2, \dots, a_p\}$ 和 $T_2 = \{b_1, b_2, \dots, b_q\}$ ,距离衡量为

$$h(T_1, T_2) = \max_{a_i \in T_1} (\min_{b_j \in T_2} \|a_i - b_j\|) \quad (11)$$

式(11)中: $h(T_1, T_2)$ 为轨迹集合 $T_1$ 中每个点 $a_i$ 到距离此点最近的 $T_2$ 集中点 $b_j$ 之间的距离 $\|a_i - b_j\|$ 序列中的最大值, $h(T_1, T_2)$ 越大,表示两个轨迹之间的相似度越小。

②通过比较当前轨迹与各历史进港轨迹之间的 Hausdorff 距离值,把距离最小的轨迹集合确定为相似度最高的历史进港轨迹。

③在得到相似度最高的历史进港轨迹后,可用

线性插值法将当前轨迹的终点与距离该点最近的历史轨迹点相连作为当前船舶的预测轨迹。

### 1.2.2 LSTM 网络轨迹预测模型

对没有历史进港轨迹或轨迹异常的船舶,根据 AIS 数据中的时间、位置(经度、纬度)、航向和航速等4个要素,构建船舶航行动态时间序列数据,然后利用 LSTM 网络来训练和预测船舶的未来轨迹。

LSTM 是神经网络的一种,常用于时间序列预测,与其他网络相比 LSTM 在面对多输入变量的问题时具有更好的处理能力<sup>[19]</sup>,LSTM 预测网络结构见图3。

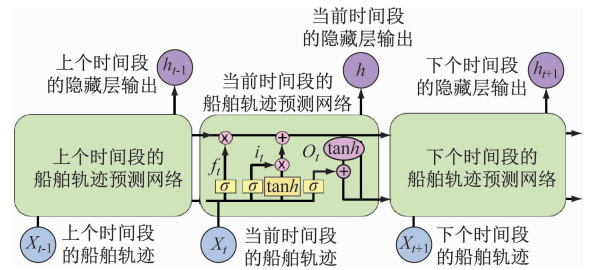


图3 LSTM 预测网络结构

Fig. 3 The structure of LSTM prediction network

1) 训练的第一步是通过遗忘门 $f_i$ 确定需从单元状态丢弃的信息。遗忘门 $f_i$ 是对上一层中输入到本层中的信息的遗忘概率。选择 Sigmoid 函数作为激活函数,函数输出 $f_i$ 的值为 $[0, 1]$ ,数值越大表示信息的重要性越高。

$$f_i = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (12)$$

2) 输入门所做的工作是对当前时刻输入的信息进行处理,其由用 Sigmoid 激活函数输出后的 $i_i$ 和用 tanh 激活函数输出的 $\tilde{C}_i$ 2个部分组成,有

$$i_i = (\sigma W_i \cdot [h_{t-1}, x_t] + b_i) \quad (13)$$

$$\tilde{C}_i = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (14)$$

3) 输出门输出的状态 $C_i$ 是由前面的遗忘门和输入门共同作用后得到的,最终状态 $C_i$ 可理解为由上一时刻中的状态信息 $C_{t-1}$ 与遗忘门的输出 $f_i$ 的乘积和输入门得到的 $i_i$ 与 $\tilde{C}_i$ 乘积组成,计算为

$$C_i = C_{t-1} \times f_i + i_i \times \tilde{C}_i \quad (15)$$

确定输出门的结果后,需要通过 tanh 函数激活并与上一过程中由 Sigmoid 函数激活的隐藏状态 $h_{t-1}$ 和本时刻的输入数据 $x_t$ 共同作用得到的 $o_i$ 相乘,从而得到模型的最终输出结果,有

$$o_i = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (16)$$

$$h_i = o_i \times \tanh(C_i) \quad (17)$$

式(12)~式(17)中: $i_i$ 为记忆门; $[h_{t-1}, x_t]$ 为由 $t$ 时刻的状态向量和输入向量构成的矩阵向量; $W_f$ 、 $W_i$ 、

$W_c$  和  $W_o$  为  $x_i$  的权重矩阵;  $b_o$  为输出门的误差;  $b_c$  为备选细胞状态偏差;  $b_f$  为输入门和遗忘门的偏差;  $C_t$  为长期细胞状态,  $\tilde{C}_t$  为即时细胞状态;  $\sigma$  为 Sigmoid 函数。

### 1.3 断面船舶流量统计方法

在港口水域设置进港航道断面,利用 Python 语言的地理科学计算库,按照各船舶的 MMSI 将离散的船舶轨迹点集合连接成连续的航迹线,通过交点算法判断船舶轨迹是否与断面相交和航向是否为进港方向,若均满足则存储该轨迹经过断面的时间,并以 1 h 为间隔统计断面流量。对曾经经过选定港口区域的船舶进行处理,可得到任意 1 d 各 24 个时间间隔的进港船舶流量。断面船舶流量统计步骤见图 4。

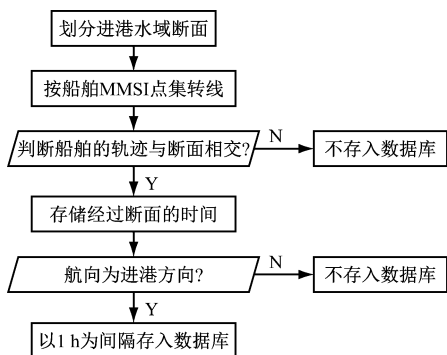


图 4 断面船舶流量统计步骤

Fig. 4 Statistics steps for section ship flow

## 2 案例分析

宁波舟山港的货物吞吐量已连续 13 a 位居全球第 1,其各港区的进港航道船舶交通流密集,核心港区的年船舶流量超过 120 万艘次。本文选取宁波舟山港核心港区作为研究区域,将其附近水域 2020 年 6—12 月的船舶 AIS 数据作为历史数据,所用数据来自东海航海保障中心宁波航标处,每日的历史数据均有近 10 000 000 条船舶动态信息。分别用集计模型和本文的模型方法预测 2020 年 12 月 28 日 24 个时段的进港航道断面船舶流量,并比较分析两者的差异。

### 2.1 进港断面和船舶确定

为实施计算,在宁波舟山港核心港区船舶定线制水域 2<sup>#</sup>警戒区穿山半岛—岙山岛连线水域设置进港断面见图 5,此处船舶交通流密集,是测试模型的理想断面。

从 12 月 28 日的船舶 AIS 静态数据中,选取距断面近且进出 4 个主要港区(北仑港区、穿山港区、

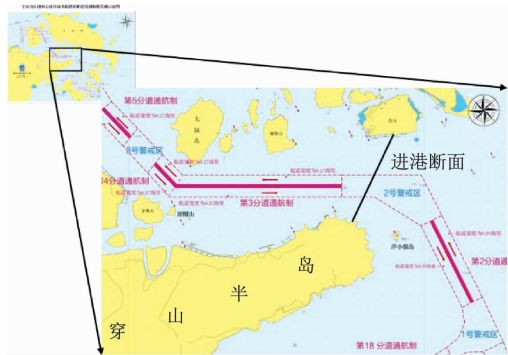


图 5 选取进港断面

Fig. 5 Selected port entry section

大榭港区和梅山港区)的货船和油船,共 413 艘。按 MMSI 编码保存他们在 2020 年 6—12 月期间在该区域的历史轨迹。

### 2.2 进港船舶轨迹预测

#### 2.2.1 历史轨迹匹配

分别在上述 4 个港区划定船舶停泊区域,根据历史进港识别模型从这 413 艘船舶的历史轨迹中识别到 313 艘船舶 6—12 月期间的历史进港记录见表 1,按船舶航次和目的港区保存数据。

表 1 313 艘船舶 6—12 月期间的历史进港记录

Tab. 1 Port entry records of 313 ships during

目的港区	June—December		单位:次
	总进港航次数	单艘船最多进港航次数	
北仑港区	619	22	
穿山港区	512	12	
大榭港区	507	9	
梅山港区	461	13	

根据 12 月 28 日的 AIS 静态数据中船舶的目的港区信息,利用历史轨迹匹配模型匹配相同目的港区的同一艘船舶的历史进港轨迹。以 MMSI = 351841000 且目的地港区为穿山港区的集装箱船为例的历史轨迹匹配示意图 6。

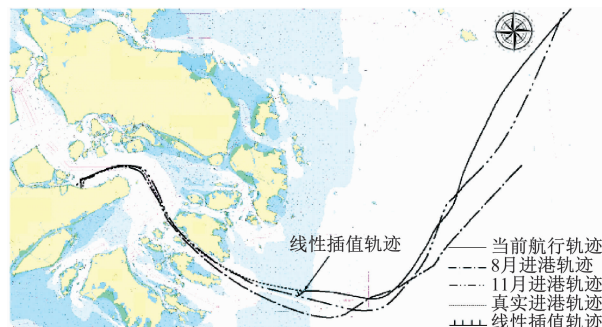


图 6 历史轨迹匹配示意图

Fig. 6 Historical track matching schematic

图6中:实线轨迹为这艘船12月27日12—24时的航行轨迹,两条点划线分别为其8月和11月的进港轨迹。根据 Hausdorff 距离确定的轨迹间的相似度,可把8月的轨迹作为与之匹配的历史进港轨迹。然后,把当前轨迹的终点与距离8月历史轨迹最近的点用线性插值法连接起来得到图6中类似刻度线的轨迹线,预测的轨迹即为刻度线连接锁线。与图6中虚线的实际进港轨迹比较可以发现,由于进港航道固定,历史轨迹匹配的方法与实际的进港轨迹有着较高的相似度。

### 2.2.2 LSTM 网络预测船舶轨迹

针对无合适历史进港轨迹的船舶,提取其当前航行轨迹,并按照80%和20%的比例把这些轨迹数据划分为训练集和测试集。然后,通过多次测试,把模型训练的 epoch 设定为30, Batch size 设定为256, 选取均方误差 (Mean Square Error, MSE) 作为 LSTM 模型的损失函数。确定完参数后,对模型进行训练,经过设定的30次训练后,可得到 LSTM 模型训练和测试损失曲线见图7。




图7 LSTM 模型训练和测试损失曲线

Fig. 7 LSTM model training and testing loss curves

由图7可知:随着训练集的损失值降低,测试集的损失值随之降低,且损失曲线趋于稳定,证明模型的参数设定正常,并未出现过拟合化的问题,可用于船舶轨迹预测。因此,将船舶当前的经纬度、航向和航速输入预测模型,得到 LSTM 网络预测的船舶轨迹见图8。




图8 LSTM 网络预测的船舶轨迹

Fig. 8 Ship trajectory prediction by LSTM network

### 2.3 预测结果比较

通过上述预测得到413艘船舶的未来轨迹后,对之前所选定的进港断面做流量统计可得到12月

28日当天24个时间间隔的进港船舶流量。为比较分析本文提出的模型精度,基于12月21—27日7d的历史断面进港船舶流量,利用集计模型中的灰色理论模型以及ARIMA模型预测得到同时段的断面进港船舶流量。3种方法的预测的12月28日港口水域断面船舶流量预测对比见图9。




图9 12月28日港口水域断面船舶流量预测对比

Fig. 9 Comparison of ship flow forecasts in December 28

可用相对误差 (Relative Error, RE) 和平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 评价2种模型预测的精度,具体计算方法为

$$X_{RE} = (y_i - \hat{y}_i) / y_i \times 100\% \quad (18)$$

$$X_{MAPE} = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i) / y_i| \times 100\% \quad (19)$$

式(18)和式(19)中: $y_i$ 和 $\hat{y}_i$ 分别为第*i*个样本的真实值和预测值; $n$ 为预测验证数据集的样本个数。

利用灰色理论模型和ARIMA模型预测的断面进港船舶流量的MAPE分别为72.00%和45.54%,非集计模型的MAPE为19.96%,表明非集计模型在短时船舶流量预测上有更高的精度,3种方法预测的相对误差比较见图10。

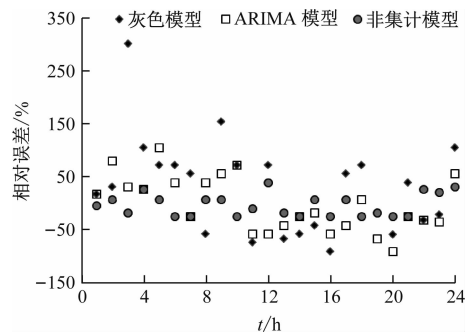


图10 三种方法预测相对误差比较

Fig. 10 Comparison of relative errors of three methods

由图9和图10可知:非集计模型的预测精度比传统的集计模型的高,非集计模型的预测值只有在少数预测点的相对误差较大,大部分预测点的相对预测误差均比较理想。尤其值得指出的是,非集计模型预测的当日3个流量高峰时间段内(0000—0100,1000—1100,2200—2300)的船舶流量更精确。

从断面船舶流量变化曲线上来看,非集计模型预测结果比集计模型预测结果更加接近实际,验证该方法在短期船舶流量预测中的可行性。

### 3 结束语

本文利用非集计模型的思路预测港口水域的短时船舶交通流量,首先详细描述基于 AIS 数据的两种船舶轨迹预测方法,其次将该方法应用于宁波舟山港附近水域的货船和油船中,预测进港断面 12 月 28 日 24 个时段的船舶流量。为判断方法的预测性能,应用传统灰色理论预测模型以及 ARIMA 模型对同一时刻的船舶流量进行预测,使用 RE 和 MAPE 对 2 种预测方法进行评价,结果表明非集计模型的预测精度要明显优于传统集计模型,验证本文构建的预测模型能有效预测断面未来的船舶流量。

在实际应用方面,当前港区交通管理问题严峻,本文所构建的预测模型可在缓解港区交通压力,提高港口的工作效率上有较好的实用价值。通过精确的断面船舶流量预测,能够缓解港口调度的困难。同时,为进一步提高断面流量预测的精度,下一步需针对航行轨迹异常的船舶来优化本文的预测模型。

### 参 考 文 献

- [1] 张矢宇,杨宇昊,陈尘,等.基于回归-卡尔曼滤波组合模型的航道整治区域船舶交通流时空预测[J].大连海事大学学报,2021,47(1):37-44.  
ZHANG S Y, YANG Y H, CHEN C, et al. Spatio-temporal prediction of ship traffic flow in waterway regulation area based on regression-Kalman filter combination model [J]. Journal of Dalian Maritime University, 2021, 47(1):37-44. (in Chinese)
- [2] HE W, ZHONG C, SOTELO M A, et al. Short-term vessel traffic flow forecasting by using an improved Kalman model [J]. Cluster Computing, 2019, 22(4): 7907-7916.
- [3] 余珍,蒋仲廉,雷国平,等.内河断面船舶交通流量预测方法研究[C].第十三届中国智能交通年会大会论文集,北京:中国智能交通协会,2018:425-431.  
YU Z, JIANG Z L, LEI G P, et al. Time series forecasting of inland vessel traffic flow [C]. Proceedings of the 13th China Intelligent Transportation Annual Conference, Beijing: China Intelligent Transportation Systems Association, 2018:425-431. (in Chinese)
- [4] 刘成勇,万伟强,陈蜀喆,等.基于灰色马尔科夫模型的船舶交通流预测[J].中国航海,2018,41(3):95-100.  
LIU C Y, WAN W Q, CHEN S Z, et al. Prediction of

- vessel traffic flow based on grey markov model [J]. Navigation of China, 2018, 41 (3): 95-100. (in Chinese)
- [5] ZHANG Z, YIN J, WANG N, et al. Vessel traffic flow analysis and prediction by an improved PSO-BP mechanism based on AIS data [J]. Evolving Systems, 2019, 10: 397-407.
- [6] 冯宏祥,肖英杰,孔凡邗.基于支持向量机的船舶交通流量预测模型[J].中国航海,2011,34(4):62-66.  
FENG H X, XIAO Y J, KONG F C. Study of vessel traffic forecasting model based on support vector machine [J]. Navigation of China, 2011, 34 (4): 62-66. (in Chinese)
- [7] 李晋,钟鸣,李扬威.基于 AIS 船舶数据的港口交通流量预测模型研究[J].交通信息与安全,2018,36(3):72-78.  
LI J, ZHONG M, LI Y W. A forecasting model of marine traffic flows at ports based on AIS data [J]. Journal of Transport Information and Safety, 2018, 36 (3):72-78. (in Chinese)
- [8] 刘敬贤,高广旭,刘奕,等.基于卷积神经网络及长短时记忆网络的短时船舶交通流量预测[J].中国航海,2022,45(2):56-61.  
LIU J X, GAO G X, LIU Y, et al. Short-term water traffic flow prediction with convolutional neural network and long short-term memory network [J]. Navigation of China, 2022, 45(2):56-61. (in Chinese)
- [9] 徐铁,蔡奉君,胡勤友,等.基于卡尔曼滤波算法船舶 AIS 轨迹估计研究[J].现代电子技术,2014,37(5):97-100.  
XU T, CAI F J, HU Q Y, et al. Research on estimation of AIS vessel trajectory data based on Kalman filter algorithm [J]. Modern Electronics Technique, 2014, 37(5):97-100. (in Chinese)
- [10] 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)
- [11] GAN S, LIANG S, LI K, et al. Trajectory length prediction for intelligent traffic signaling: a data-driven approach [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(2): 426-435.
- [12] 任宇翔,赵建森,刘卫,等.基于 AIS 数据和 LSTM 网络的船舶航行动态预测[J].上海海事大学学报,2019,40(3):32-37.

- Automation Equipment, 2021, 41 (1): 17-24. (in Chinese)
- [2] 张红, 袁铁江, 谭捷, 等. 面向统一能源系统的氢能规划框架[J]. 中国电机工程学报, 2022, 42(1): 83-94.  
ZHANG H, YUAN T J, TAN J, et al. Hydrogen energy planning framework for unified energy system [J]. Chinese Journal of Electrical Engineering, 2022, 42(1): 83-94. (in Chinese)
- [3] 姜海洋, 杜尔顺, 朱桂萍, 等. 面向高比例可再生能源电力系统的季节性储能综述与展望[J]. 电力系统自动化, 2020, 44(19): 194-207.  
JIANG H Y, DU E S, ZHU G P, et al. Review and prospect of seasonal energy storage for high proportion of renewable energy power system [J]. Automation of Electric Power Systems, 2020, 44 (19): 194-207. (in Chinese)
- [4] ZIS T, NORTH R J, ANGELOUDIS P, et al. Evaluation of cold ironing and speed reduction policies to reduce ship emissions near and at ports[J]. Maritime Economics & Logistics, 2014, 16:371-398.
- [5] SIFAKIS N, VICHOS E, SMARAGDAKIS A, et al. Introducing the cold-ironing technique and a hydrogen-based hybrid renewable energy system into ports[J]. International Journal of Energy Research, 2022, 46 (14): 20303-20323.
- [6] VICHOS E, SIFAKIS N, TSOUTSOS T. Challenges of integrating hydrogen energy storage systems into nearly zero-energy ports[J]. Energy, 2022, 241:122878.
- [7] 魏震波, 郭毅, 魏平桢 等. 基于 IGDT 的电-气互联综合能源系统多目标扩展规划模型[J]. 高电压技术, 2022, 48(2): 526-537.  
WEI Z B, GUO Y, WEI P A, et al. A multi-objective extended planning model for the integrated energy system of electricity gas interconnection based on IGDT [J]. High Voltage Technology, 2022, 48 (2): 526-537. (in Chinese)
- [8] 孙波, 吴旭东, 谢敬东, 等. 基于信息间隙决策理论的综合负荷聚合商储能优化配置模型[J]. 现代电力, 2021, 38(2): 193-207.  
SUN B, WU X D, XIE J D, et al. Energy storage optimal allocation model of comprehensive load aggregator based on information gap decision theory [J]. Modern Electric Power, 2021, 38(2): 193-207. (in Chinese)
- [9] 于雪菲, 张帅, 刘琳琳, 等. 基于信息间隙决策理论的碳捕集电厂调度[J]. 清华大学学报: 自然科学版, 2022, 62(9): 1467-1473.  
YU X F, ZHANG S, LIU L L, et al. Carbon capture power plant scheduling based on information gap decision-making theory [J]. Journal of Tsinghua University: Natural Science Edition, 2022, 62 (9): 1467-1473. (in Chinese)

(上接第 83 页)

- REN Y X, ZHAO J S, LIU W, et al. Ship navigation behavior prediction based on AIS data and LSTM network [J]. Journal of Shanghai Maritime University, 2019, 40 (3): 32-37. (in Chinese)
- [13] GAO D, ZHU Y, ZHANG J, ET AL. A novel MP-LSTM method for ship trajectory prediction based on AIS data [J]. Ocean Engineering, 2021, 228: 108956.
- [14] 高大为, 朱永生, 张金奋, 等. 基于 AIS 数据的船舶航迹多维预测方法[J]. 中国航海, 2021, 44(3): 56-63.  
GAO D W, ZHU Y S, ZHANG J F, et al. Multi-dimensional prediction of ship track with AIS data augmentation [J]. Navigation of China, 2021, 44(3): 56-63. (in Chinese)
- [15] ZHANG C K, BIN J C, WANG W, et al. AIS data driven general vessel destination prediction: a random forest based approach [J]. Transportation Research Part C, 2020, 118: 102729.
- [16] WEI Y, CHEN Z, ZHAO C, et al. Big multi-step ship motion forecasting using a novel hybrid model based on real-time decomposition, boosting algorithm and error correction framework [J]. Ocean Engineering, 2022, 256: 111471.
- [17] 吴建华, 吴琛, 刘文, 等. 船舶 AIS 轨迹异常的自动检测与修复算法[J]. 中国航海, 2017, 40(1): 8-12.  
WU J H, WU C, LIU W, et al. Automatic detection and restoration algorithm for trajectory anomalies of ship AIS [J]. Navigation of China, 2017, 40(1): 8-12. (in Chinese)
- [18] 杨家轩, 刘元. 基于 DBTCAN 算法的船舶轨迹聚类与航路识别[J]. 上海海事大学学报, 2022, 43(3): 7-12.  
YANG J X, LIU Y. Ship trajectory clustering and route recognition based on DBTCAN algorithm [J]. Journal of Shanghai Maritime University, 2022, 43(3): 7-12. (in Chinese)
- [19] 权波, 杨博辰, 胡可奇, 等. 基于 LSTM 的船舶航迹预测模型[J]. 计算机科学, 2018, 45(S2): 126-131.  
QUAN B, YANG B C, HU K Q, et al. Prediction model of ship trajectory based on LSTM [J]. Computer Science, 2018, 45(S2): 126-131. (in Chinese)