



## 一种并行LSTM-FCN模型在船舶航迹预测中的应用

胡丹, 孟新, 路帅, 邢力宁

引用本文:

胡丹, 孟新, 路帅, 邢力宁. 一种并行LSTM-FCN模型在船舶航迹预测中的应用[J]. 控制与决策, 2022, 37(8): 1955–1961.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1795>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于卷积长短时记忆神经网络的城市轨道交通短时客流预测

Metro short-term traffic flow prediction with ConvLSTM

控制与决策. 2021, 36(11): 2760–2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

#### 一种基于深度学习的时间序列预测方法

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

#### 基于改进卷积神经网络的动力下肢假肢运动意图识别

Intent recognition of power lower-limb prosthesis based on improved convolutional neural network

控制与决策. 2021, 36(12): 3031–3038 <https://doi.org/10.13195/j.kzyjc.2020.0326>

#### 一种基于池计算的宽度学习系统

A broad learning system based on reservoir computing

控制与决策. 2021, 36(9): 2203–2210 <https://doi.org/10.13195/j.kzyjc.2019.1729>

#### 迁移学习引导的变源域长短时记忆网络建筑负荷预测

Load forecasting of buildings using LSTM based on transfer learning with variable source domain

控制与决策. 2021, 36(10): 2328–2338 <https://doi.org/10.13195/j.kzyjc.2020.0215>

# 一种并行LSTM-FCN模型在船舶航迹预测中的应用

胡 丹<sup>1,2</sup>, 孟 新<sup>1†</sup>, 路 帅<sup>3</sup>, 邢力宁<sup>4</sup>

(1. 中国科学院国家空间科学中心 复杂航天系统电子信息技术重点实验室, 北京 100190; 2. 中国科学院大学, 北京 100049; 3. 中科天智运控科技有限公司, 深圳 518052; 4. 国防科技大学 系统工程学院, 长沙 410073)

**摘 要:** 航迹预测是保障船舶航行安全、提高海洋交通管制效能、高效搜索海面目标的关键技术. 为提高船舶航迹预测精确度, 针对航迹特征多维度的特点, 提出一种并行LSTM-FCN(parallel LSTM-FCN, PLSTM-FCN)模型. 该模型有效结合LSTM模型对时间序列数据长期趋势预测的优势和全卷积网络(FCN)模型擅于提取时间序列数据细节变化规律的特点, 通过并行结构设计保证相同训练效率下提取特征参数翻倍, 实现较高精确度的高维航迹数据特征提取和趋势预测. 基于动态时间规整算法和拉依达准则的船舶历史航迹数据预处理方法, 可提高PLSTM-FCN模型从不同类型船舶历史航迹中深度学习航行趋势和转弯细节的效率. 基于船舶自动识别系统(AIS)数据的仿真实验结果表明, PLSTM-FCN模型对多维特征船舶航迹预测的精确度明显优于传统循环神经网络.

**关键词:** 船舶航迹预测; 深度学习; 长短时记忆网络; 全卷积神经网络; 船舶自动识别系统

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1795

**引用格式:** 胡丹, 孟新, 路帅, 等. 一种并行LSTM-FCN模型在船舶航迹预测中的应用[J]. 控制与决策, 2022, 37(8): 1955-1961.

## Parallel LSTM-FCN model applied to vessel trajectory prediction

HU Dan<sup>1,2</sup>, MENG Xin<sup>1†</sup>, LU Shuai<sup>3</sup>, XING Li-ning<sup>4</sup>

(1. Key Laboratory of Electronics and Information Technology for Space Systems, National Space Science Center, Chinese Academy of Sciences, Beijing 100190, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China; 3. Zhong Ke Tian Zhi Operation Control Technology Company, Shenzhen 518052 China; 4. College of Systems Engineering, National University of Defense Technology, Changsha 410073, China)

**Abstract:** Trajectory prediction is very important to navigation safety, marine traffic control and surface vessels search. In order to improve the accuracy of vessel trajectory prediction and according to the multi-dimensional characteristics of vessel trajectory features, a new model named parallel LSTM-FCN (PLSTM-FCN) is proposed. The model can exact features and trend from multi-dimensional vessel trajectory, because of combining with the LSTM which has advanced to predict time series trend and the fully convolutional networks (FCN) which is adept in exacting detail features of time series. Simultaneously, the training efficiency of the PLSTM-FCN which has more parameters is the same as the LSTM-FCN, because of the concurrent design. In order to improve the learning efficiency, a preprocessing method based on the dynamic time warping algorithm and the Laida criterion is proposed. The simulation experiment is carried out based on the data of automatic identification systems (AIS). Experimental results show that the PLSTM-FCN is more accurate than the typical RNN in vessel trajectory prediction.

**Keywords:** vessel trajectory prediction; deep learning; long short-term memory networks; fully convolutional networks; automatic identification system

## 0 引 言

船舶航迹预测是指根据船舶历史航迹信息预测下一时刻船舶的位置, 在海面目标搜索、近海交通管制、海上碰撞事故预警等领域发挥着重要作用. 近年来, 随着海洋事业的高速发展, 我国的船舶保有量增幅巨大, 海洋运输和交通发展迅猛. 因此, 如何保障船

舶航行安全、提高海洋交通管制效能、高效搜索海面目标, 成为当前海洋事业研究的热门问题, 而提高船舶航迹预测精确度是解决上述问题的关键.

许多学者针对船舶航迹预测问题已开展了很多卓有成效的工作. 文献[1]首先根据对称分段路径距离对航迹数据进行预处理, 然后构建循环神经网络

模型进行航迹预测,但只以船舶的经度和纬度作为预测的先验信息,其本质仍属于曲线拟合问题,针对有大幅度转弯的航迹,其预测细节不足.文献[2-4]结合AIS数据和深度学习,采用LSTM模型,将速度、航向、经度、纬度和时间间隔作为输入来预测未来航迹,具有较好的预测精度.文献[5]首先将指定海域划分为网格,然后以船舶的位置、速度和方向为关键要素计算网格状态,利用 $k$ 阶马尔科夫链建立状态转移矩阵进行预测,但在计算每个时刻的网格状态时对历史航迹信息利用率不高.文献[6]采用BP神经网络进行航迹预测,以AIS数据中的船舶经纬度、航速和航向信息进行训练和预测,但BP神经网络处理非线性问题的能力相对较弱,仅适用于航迹较短的情况.文献[7]设计了PSO-LSTM模型进行船舶航迹预测,通过PSO算法优化LSTM网络,提高了LSTM网络的预测精度,但引入PSO算法后降低了模型的实时计算效率.文献[8-10]提出用Kalman滤波算法对船舶的速度和加速度进行估计,实现了船舶位置预测,但由于对历史航迹信息利用率不高,其预测精度有限.文献[11-12]使用高斯过程来表述复杂运动模式,基于正态分布的前提对目标轨迹进行回归预测,但普适性不高.

当前航迹预测研究大多仅考虑船舶位置、航速和航向对预测的影响,忽略了船舶固有属性(例如船长度、宽度、吃水深度等)与环境因素造成的船舶航速和转向的偏差.因此,本文提出一种并行LSTM-FCN模型(parallel LSTM-FCN, PLSTM-FCN),以包含船舶动态信息和固有信息的历史航迹数据为学习样本,通过LSTM学习航迹数据的长期序列趋势,通过FCN学习航迹数据的细节变化特征,通过并行的LSTM-FCN结构在保证相同的学习效率情况下提高特征参数提取能力,实现对船舶航迹的高精确度预测.

## 1 背景知识

### 1.1 卷积神经网络

卷积神经网络(convolutional neural network, CNN)在处理类似网格结构的数据时具有优异的表现<sup>[13]</sup>. CNN一般包括卷积层、池化层和全连接层.其中卷积层负责提取数据的复杂局部特征,通过稀疏交互、参数共享和等变表示来提高机器学习效率,卷积后通过不同的激励函数实现非线性变换,例如采用ReLU激励函数实现函数值大于0的非线性变换;池化层在保证输入的代表近似不变的情况下,根据不同的池化函数对输入值进行少量平移调整或特征降维,并在一定程度上防止过拟合;全连接层负责将卷

积层和池化层产生的特征图映射为一个固定长度的特征向量.

与卷积神经网络在卷积层之后使用若干全连接层得到固定长度特征向量不同,全卷积网络(fully convolutional networks, FCN)<sup>[14-15]</sup>使用不同参数的卷积层替换所有的全连接层. FCN能够接受任意尺寸的图像作为输入,所以FCN常用于解决图像语义分割问题,通过反卷积层对特征图进行上采样,实现在保留原始图像的空间信息基础上对原始图像按像素进行分类. FCN在处理时间序列数据时比CNN更灵活,时序数据可以任意序列长度作为输入,经过FCN后能够保留更多的序列数据特征.

船舶航迹属于一种高维度的时间序列数据,在时间轴上按照一定规律采样形成多维网格数据后可使用FCN提取特征参数.

### 1.2 循环神经网络

循环神经网络(recurrent neural network, RNN)是一类用于处理时序数据的神经网络.其网络内部自循环的设计实现了输入信息的持续存在,使得在处理当前时序数据时不会忽略历史数据的影响. RNN的本质可以看作是同一个神经网络的多个复制,每一个网络都会将自己的输出传给后一个网络,这种特性使其可以处理长序列数据,但也可能导致极端非线性情况的出现而发生梯度消失和梯度爆炸.

长短时记忆网络(long short-term memory networks, LSTM Networks)<sup>[16]</sup>,是一种特殊的循环神经网络,常应用于时间序列数据的回归和分类<sup>[17-18]</sup>,能有效解决长序列训练过程中的梯度消失和梯度爆炸问题.

LSTM networks通过遗忘门实现对无用信息的丢弃,通过输入门实现对有用历史信息的存储,通过输出门实现对输出数据的控制.计算公式为

$$\begin{cases} f_t = \sigma(W_f[h_{t-1}, x_t] + b_f), \\ i_t = \sigma(W_i[h_{t-1}, x_t] + b_i), \\ g_t = \tanh(W_g[h_{t-1}, x_t] + b_g), \\ o_t = \sigma(W_o[h_{t-1}, x_t] + b_o), \\ c_t = f_t h_{t-1} + i_t g_t, \\ h_t = o_t \tanh(c_t). \end{cases} \quad (1)$$

## 2 基于PLSTM-FCN的预测方法

以某海域内的大量历史航迹对PLSTM-FCN模型进行训练后,可用于该海域内的船舶航迹预测.以 $t$ 时刻之前的连续 $k$ 个航迹点信息作为输入,预测 $t+1$

时刻船舶的位置,函数表达式为

$$\hat{y}_{t+1} = g(x_t, x_{t-1}, \dots, x_{t-k+1}). \quad (2)$$

其中: $\hat{y}_{t+1}$ 为预测的 $t+1$ 时刻船舶位置( $\text{lat}_{t+1}$ ,  $\text{lon}_{t+1}$ ),  $x_t$ 为船舶在时刻 $t$ 的航迹特征向量. 本文使用的航迹特征包括:与下一个航迹点的间隔时间;当前航迹点纬度、经度、航速、航向;船舶的长度、宽度和吃水深度.

## 2.1 PLSTM-FCN模型结构

LSTM-FCN能有效解决时序分类问题,本文对其进行改进后可用于解决8维特征向量的船舶航迹预测问题. 改进后的LSTM-FCN模型如图1所示,结构主体包括1个LSTM模块和1个FCN模块. LSTM模块负责学习时间序列数据的长期趋势;FCN模块负责对切片后的时序数据进行特征提取,由于采用了时域卷积网络,能更好地捕捉到时序数据的局部信息. LSTM模块与FCN模块组合后,既能学习到时序数据的长期变化趋势,又能提取出时序数据的细节变化规律.




图1 LSTM-FCN结构

FCN模块由3个时序卷积(temporal convolutional)模块组成,每个时序卷积模块均包括1个一维卷积层、1个batch normalization层(后接1个ReLU激活函数)和1个dropout层(丢弃率为0.5)组成. 根据船舶航迹数据特征数量,设置第1个卷积层的输入通道数为8,输出通道数为32,卷积核大小为3;第2个卷积层的输入通道数为32,输出通道数为64,卷积核大小为3;第3个卷积层的输入通道数为64,输出通道数为32,卷积核大小为1. 由此,切片后的航迹数据特征从8维映射到了32维,扩展了特征数量.

LSTM模块由1个LSTM层和3个全连接层组

成. 设置LSTM循环层为4,隐藏层为100,负责将按时序输入的船舶航迹序列映射为100维的特征向量. 3个全连接层的输入输出节点数依次为100、128、64、32,负责将100维的特征数据缓慢降维到32维,多个全连接层的使用可以有效提高网络的非线性能力. LSTM模块和FCN模块的输出通过concat层合并为64维向量,最后经1个全连接层映射为2维向量,即为船舶的经度和纬度.

在实验中发现,LSTM-FCN模型对8维特征航迹预测精确度提升有限(详情见第3.3.1节),对于曲线较为平缓的航迹预测精确度有时不如LSTM-RNN模型. 分析原因,可能是因为LSTM-FCN模型认为预测的船舶经度和纬度具有相关性,影响了模型预测精确度. 对此,本文借鉴文献[19-20]的思想(在构建目标运行模型时认为目标在方向上的位置变化具有相对独立性),将改进的LSTM-FCN模型最后全连接层输出设计为1维,用2个LSTM-FCN并行构成PLSTM-FCN模型,分别预测船舶在方向上的位置,用于提高预测精确度. 另外,PLSTM-FCN的每个模块可以独立训练,在提高单个LSTM-FCN对时序数据预测能力的同时保持了训练效率.

## 2.2 航迹数据准备

### 2.2.1 数据来源

船舶自动识别系统(automatic identification system, AIS)是一种用于岸与船、船与岸以及船与船之间通信的新型助航系统<sup>[21]</sup>. 船舶安装AIS设备后,会定时对外广播本船的动态信息(主要包括经度、纬度、航速、航向等)和静态信息(主要包括标识、名称、船舶长度、宽度、吃水情况等). 各海上交通管理系统收集、处理、汇总上述信息后形成AIS数据.

本文以AIS数据为数据来源,根据AIS的数据特点,定义船舶的航迹为

$$VT = [P_1, P_2, \dots, P_n]^T. \quad (3)$$

其中: $n$ 为该航迹的最大航迹点数量; $P_i$ 为第 $t_i$ 时刻的航迹点特征向量,其表达式为

$$P_i = \begin{bmatrix} \text{ival}_i \\ \text{lat}_i \\ \text{lon}_i \\ \text{sog}_i \\ \text{cog}_i \\ \text{length}_i \\ \text{width}_i \\ \text{draft}_i \end{bmatrix}^T. \quad (4)$$

其中:  $ival_i = t_{i+1} - t_i$ , 表示第  $i+1$  个航迹点与第  $i$  个航迹点的间隔时间;  $lat_i$ 、 $lon_i$ 、 $sog_i$ 、 $cog_i$ 、 $length_i$ 、 $width_i$ 、 $draft_i$  依次表示  $t_i$  时刻船舶的纬度、经度、航速、航向以及船长、宽度和吃水深度等信息。

### 2.2.2 数据处理

本文使用的航迹来源于 AIS 数据, 由于 AIS 信号发送、传输和接收的过程中会发生信号中断或信息缺失的情况, 同时 AIS 数据中可能会出现较大偏差的时间序列数据, 需要对其进行数据处理。航迹数据处理共分 3 步: 1) 剔除无效数据; 2) 航迹相似度筛选; 3) 进行航迹分段。

剔除无效数据的依据包括两个方面: 剔除有部分特征数值为空的航迹点数据和剔除部分特征值域超出实际值范围的航迹点数据。本文设定航迹点的纬度不应超过  $[-90^\circ, 90^\circ]$  的范围, 经度不应超过  $[-180^\circ, 180^\circ]$  范围, 民船的最大航速不超过 40 节/小时, 航向不能超过  $[0, 360^\circ]$  范围。如果有某项特征值超出了数值范围, 则删除整个航迹点数据。

动态时间规整 (dynamic time wrapping, DTW) 算法已被证明能很好地解决两个长度不等的时序数据相似度计算问题<sup>[22]</sup>, 因此, 本文航迹相似度筛选以此为依据。首先以航迹点数量最多的航迹作为基准航迹; 然后采用 DTW 算法计算其他航迹与之相似

度, 生成相似度序列数据; 最后采用拉依达准则<sup>[23]</sup> 删掉相似度值异常的航迹数据。

航迹分段的依据是航迹点之间的时间间隔: 首先, 依次计算当前航迹点与下一航迹点的时间间隔; 然后, 采用拉依达准则找到第 1 个间隔时间异常点, 将原航迹从该航迹点分段, 以该航迹点作为新航迹的起点; 最后, 在新航迹继续使用拉依达准则找到第 1 个间隔时间异常点, 再分段, 直到没有间隔时间异常点为止。

经过数据处理后的船舶航迹去掉了异常数据, 且每条航迹内的航迹点之间的时间间隔曲线较为平缓, 航迹之间具有一定的相似度, 可作为模型训练的航迹数据集。

### 2.2.3 构造输入输出

本文以处理后的船舶航迹数据集构建预测模型的输入输出。令航迹数据集为

$$VTS = \{VT_1, VT_2, \dots, VT_M\}. \quad (5)$$

如图 2 所示, 设  $seq\_len$  为单次输入模型的序列长度, 则按  $seq\_len+1$  长度的窗口从 VT 的首位开始逐步向右平移, 由此获得  $total\_size$  组输入数据  $X$  和输出数据  $Y$ 。其中: 输入数据  $X$  的维度为  $(total\_size, seq\_len, 8)$ , 输出数据的维度为  $(total\_size, 1, 2)$ 。




图2 航迹预测输入输出数据集

## 3 实验验证

### 3.1 实验环境和数据

本文实验基于 Python 语言下的 PyTorch 框架进行, 实验的硬件环境和软件环境具体信息如表 1 所示。

实验数据来自 <https://marinecadastre.gov> 下载的 2019 年 1 月的 AIS 数据, 选择了纬度在  $15^\circ \sim 31^\circ$  之间、经度在  $-98^\circ \sim -70^\circ$  范围内 (墨西哥湾海域) 的航迹。经过航迹数据处理后, 一共包含了 552 条船舶、

16 730 条航迹、927 730 个航迹点数据。

表1 实验环境列表

|      |      |                                      |
|------|------|--------------------------------------|
| 硬件环境 | 处理器  | Intel(R)Core(TM) i7-9750 H, 2.60 GHz |
|      | 内存   | 16 GB                                |
|      | 显卡   | NVIDIA GeForce GTX 1 650, 4 GB       |
| 软件环境 | 操作系统 | Windows 10(64 位)                     |
|      | 编程语言 | Python 3.7                           |
|      | 基础框架 | PyTorch 1.3                          |
|      | 编程软件 | Spyder 3.3.6                         |

3.2 实验方案和评价标准

将上述 16 730 条航迹按 7 : 3 的比例随机分为 2 组,其中 11 711 条作为训练数据,5 019 条作为测试数据. 设置输入序列长度为 5,将航迹按 2.2.3 节的方法拆分为适用于 PLSTM-FCN 模型的输入输出数据. 设置批次长度 (batch size) 为 32,每轮训练从剩余的输入输出数据中随机抽取 32 组进行训练,其中输入数据维度为 (32, 5, 8),输出数据维度为 (32, 1, 2),一共训练 10 轮 (epoch). 模型训练使用均方误差 (MSE) 作为损失函数,有

$$\text{MSELoss} = \frac{1}{M} \sum_{i=1}^M (\hat{y} - y)^2. \quad (6)$$

其中:  $M$  为单次训练的样本总数,  $\hat{y}$  为预测的船舶位置,  $y$  为真实的船舶位置.

3.3 对比实验

将基于 PLSTM-FCN 模型的船舶航迹预测与典型的循环神经网络进行对比实验,以验证本文模型的有效性.

3.3.1 不同模型对比实验

采用前文所述方法生成的训练集和测试集数据,分别对 PLSTM-FCN、LSTM-FCN、LSTM-RNN 模型进行训练和测试. 随机从测试集中筛选出 5 条航迹,使用 3 个训练好的模型进行预测,对比每条典型航迹的预测情况和均方误差.

3 个模型训练后在测试集的 MSE 结果如表 2 所示. LSTM-FCN 比 LSTM-RNN 模型的位置预测精确度有一定提升,但提升幅度不大,而本文提出的 PLSTM-FCN 模型在整个测试集的预测 MSE 值要明显优于 LSTM-FCN 和 LSTM-RNN 模型.

表 2 测试集的预测实验结果

| 预测模型      | MSE       |
|-----------|-----------|
| PLSTM-FCN | 0.003 317 |
| LSTM-FCN  | 0.012 107 |
| LSTM-RNN  | 0.016 731 |

预测航迹与实际航迹对比如图 3 所示. 航迹 1 和航迹 3 有 2 次角度较小的转弯,航迹 2 和航迹 5 有 1 次角度较大的转换,航迹 4 整体近似圆弧形,航迹 5 有连续转弯. 对比航迹预测曲线和所对应航迹的 MSE 直方图,在有大角度转换的航迹情况下,LSTM-FCN 模型预测精确度比 LSTM-RNN 模型有一定的提升,但在较为平缓的航迹预测时,出现了精确度不如 LSTM-RNN 的情况,而 PLSTM-FCN 模型的航迹预测精确度整体明显优于模型 LSTM-FCN 和 LSTM-RNN. 其原因可能是针对高维度特征的航迹预测时,LSTM-FCN 模型认为预测的船舶经度和纬度具有相关性,影响了模型预测能力;而 PLSTM-FCN 模型认为预测的船舶经度和纬度不相关,采用并行的结构设计,提高了预测精确度.




图 3 航迹预测对比

3 个模型针对典型航迹的预测实验结果如表 3 所示. 预测精确度方面,本文提出的 PLSTM-FCN 模型预测的 MSE 值比 LSTM-RNN 模型小了 1 或 2 个数量级;预测耗时方面,对航迹点数量约 1 100 的航迹预测


总耗时,PLSTM-FCN 模型为 5 s ~ 6 s,略高于 LSTM-RNN 模型的 1 s ~ 2 s,原因是 PLSTM-FCN 模型包含更多的特征参数.

表3 典型航迹预测实验结果对比


| 实验项目  | 预测模型      | 航迹序号    |         |         |         |         |
|-------|-----------|---------|---------|---------|---------|---------|
|       |           | 1       | 2       | 3       | 4       | 5       |
| 航迹点数量 |           | 1 153   | 1 121   | 1 156   | 1 230   | 1 014   |
| 均方误差  | PLSTM-FCN | 3.91e-4 | 5.96e-4 | 7.96e-4 | 6.47e-4 | 2.62e-3 |
|       | LSTM-FCN  | 6.80e-3 | 2.75e-3 | 9.20e-3 | 2.49e-3 | 7.36e-3 |
|       | LSTM-RNN  | 1.01e-2 | 1.06e-2 | 6.05e-3 | 1.93e-2 | 2.06e-2 |
| 耗时/s  | PLSTM-FCN | 5.61    | 5.89    | 5.60    | 5.99    | 4.91    |
|       | LSTM-FCN  | 2.90    | 3.23    | 3.05    | 3.09    | 2.69    |
|       | LSTM-RNN  | 1.45    | 1.52    | 1.44    | 1.68    | 1.31    |

### 3.3.2 不同特征数量对比实验


为验证航迹特征维度增加有利于提高航迹预测的精度,本节进行对比实验. PLSTM-FCN 模型仍使




(a) 航迹1 预测结果对比



(b) 航迹1 预测MSE 曲线



(c) 航迹2 预测结果对比



(d) 航迹2 预测MSE 曲线

图4 基于不同特征数量的航迹预测对比

用航迹点的全部8个特征参数,LSTM-RNN 只使用其中的经纬度2个特征参数. 由于上一节已验证了 PLSTM-FCN 预测能力好于 LSTM-FCN,本节不再对比 LSTM-FCN 模型.

如图4所示,图(a)和(c)是航迹情况,图(b)和(d)是所对应的预测MSE 曲线. 结果表明,使用8个特征参数的 PLSTM-FCN 比使用2个特征参数的 LSTM-RNN 预测精确度更高,特别是预测开始、结束和大转弯时,PLSTM-FCN 预测结果明显较好. 航迹特征参数包括经度、纬度、航速、航向、船舶长度、宽度、吃水深度、间隔时间,使 PLSTM-FCN 能提取到更多的船舶运行细节特征,预测结果更精确.

## 4 结 论

船舶海上航行的状态受多方面因素影响,其固有的属性(如船长度、宽度、吃水深度等信息)会影响其运动特征. 本文综合考虑了船舶的动态信息和静态信息,设计了一种 PLSTM-FCN 模型,以多维特征航迹数据进行深度学习,有效提取船舶的长期运动趋势和短期变化规律. 经实验验证,该模型具有较高的航迹预测精确度. 后续工作将研究自适应航迹分段预测方法,根据航迹当前形态特征自动采用 PLSTM-FCN 模型或 LSTM-RNN 模型,在保持预测精确度的同时提高预测效率.

### 参考文献(References)

- [1] 胡玉可, 夏维, 胡笑旋, 等. 基于循环神经网络的船舶航迹预测[J]. 系统工程与电子技术, 2020, 42(4): 871-877.  
(Hu Y K, Xia W, Hu X X, et al. Vessel trajectory prediction based on recurrent neural network[J]. Systems Engineering and Electronics, 2020, 42(4): 871-877.)
- [2] 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.)
- [3] 陈凯达, 朱永生, 闫柯, 等. 基于 LSTM 的船舶航迹预测[J]. 航海工程, 2019, 48(6): 121-125.  
(Chen K D, Zhu Y S, Yan K, et al. The ship track prediction method based on long short-term memory network[J]. Ship & Ocean Engineering, 2019, 48(6): 121-125.)
- [4] 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.  
(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.)
- [5] Guo S, Liu C, Guo Z W, et al. Trajectory prediction for ocean vessels base on  $K$ -order multivariate Markov chain[C]. Wireless Algorithms, Systems, and Applications. Cham, 2018, 140-150.
- [6] 甄荣, 金永兴, 胡勤友, 等. 基于 AIS 信息和 BP 神经网络的船舶航行行为预测[J]. 中国航海, 2017, 40(2): 6-10.  
(Zhen R, Jin Y X, Hu Q Y, et al. Vessel behavior prediction based on AIS data and BP neural network[J]. Navigation of China, 2017, 40(2): 6-10.)
- [7] Yu Liang, Hao Zhang. Ship track prediction based on AIS data and PSO optimized LSTM network[J]. International Core Journal of Engineering, 2020, 6(5): 23-33.
- [8] Perera L P, Oliveira P, Guedes Soares C. Maritime traffic monitoring based on vessel detection, tracking, state estimation, and trajectory prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(3): 1188-1200.
- [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.)
- [10] Lokukaluge Prasad Perera, Carlos Guedes Soares. Ocean vessel trajectory estimation and prediction based on extended Kalman filter[C]. The 2nd International Conference on Adaptive and Self-adaptive Systems and Applications. Lisbon, 2010: 14-20.
- [11] 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.
- [12] 乔少杰, 金琨, 韩楠, 等. 一种基于高斯混合模型的轨迹预测算法[J]. 软件学报, 2015, 26(5): 1048-1063.  
(Qiao S J, Jin K, Han N, et al. Trajectory prediction algorithm based on Gaussian mixture model[J]. Journal of Software, 2015, 26(5): 1048-1063.)
- [13] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [14] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [15] Karim F, Majumdar S, Darabi H, et al. Multivariate LSTM-FCNs for time series classification[J]. Neural Networks, 2019, 116: 237-245.
- [16] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [17] Ordóñez F, Roggen D. Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition[J]. Sensors, 2016, 16(1): 115.
- [18] Donahue J, Hendricks L A, Rohrbach M, et al. Long-term recurrent convolutional networks for visual recognition and description[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 677-691.
- [19] Berry P E, Pontecorvo C, Fogg D A B. Optimal search, location and tracking of surface maritime targets by a constellation of surveillance satellites[R]. Edinburgh: DSTO Information Sciences Laboratory, 2003.
- [20] 慈元卓, 徐一帆, 谭跃进. 卫星对海洋移动目标搜索的几种算法比较研究[J]. 兵工学报, 2009, 30(1): 119-125.  
(Ci Y Z, Xu Y F, Tan Y J. Comparison of several algorithms for maritime moving target search by satellite[J]. Acta Armamentarii, 2009, 30(1): 119-125.)
- [21] 刘畅. 船舶自动识别系统(AIS)关键技术研究[D]. 大连: 大连海事大学, 2013.  
(Liu C. Study of key technology of automatic identification system(AIS)[D]. Dalian: Dalian Maritime University, 2013.)
- [22] Rakthanmanon T, Campana B, Mueen A, et al. Searching and mining trillions of time series subsequences under dynamic time warping[J]. KDD, 2012, 2012: 262-270.
- [23] 王小凯, 朱小文. 计量检定中 3 种判别和剔除异常值的统计方法[J]. 中国测试, 2018, 44(S1): 41-44.  
(Wang X K, Zhu X W. Three statistical methods for distinguishing and eliminating outliers in metrological verification[J]. China Measurement & Test, 2018, 44(S1): 41-44.)

## 作者简介

胡丹(1983—), 男, 高级工程师, 博士生, 从事卫星任务规划的研究, E-mail: rwindwow@163.com;

孟新(1965—), 男, 研究员, 博士生导师, 从事空间信息、计算机软件及应用等研究, E-mail: mengxin@nssc.ac.cn;

路帅(1988—), 男, 高级工程师, 硕士生, 从事智能优化理论与应用的研究, E-mail: chic\_home@126.com;

邢立宁(1980—), 男, 研究员, 博士生导师, 从事智能优化、资源调度及任务规划等研究, E-mail: xinglining@gmail.com.

(责任编辑: 孙艺红)