文章编号:1674-2974(2024)12-0119-10 DOI:10.16339/j.cnki.hdxbzkb.2024289

# 基于DCNN-LSTM模型的船舶违章行为检测

郑元洲[1,2],李鑫[1,2],钱龙[1,2†],秦瑞朋[1,2],李果[1,2],李梦希[1,2]
(1. 武汉理工大学 航运学院,湖北 武汉 430063;
2. 内河航运技术湖北省重点实验室,湖北 武汉 430063)

**摘 要**:桥区水域船舶违章行为的精准检测对于预控船桥碰撞至关重要.为保障船舶航行安全,提出了一种面向桥区水域的船舶违章行为检测模型.通过实时采集长江武汉段连续桥区船舶自动识别系统(AIS)数据及预处理工作,采用卷积神经网络(CNN)提取船舶行为信息,与长短时记忆神经网络(LSTM)相结合,建立深度卷积长短时记忆模型(DCNN-LSTM)学习船舶时空行为特征,并结合船舶超速、掉头、追越三种违章行为进行实验分析.结果表明,DCNN-LSTM模型相较于CNN、LSTM和支持向量机(SVM)模型表现出较强的优势,其准确率、精确率和$F_1$分别为88.96%、96.49%和92.87%,实现了船舶违章行为的精准检测和识别.以典型水域船舶违章行为进行实例分析,进一步论证了DCNN-LSTM的有效性和优越性.为桥区水域船舶安全监管提供了可靠的理论基础,推动了船舶智能化发展.

**关键词**:深度学习;内河航道;CNN;LSTM;DCNN-LSTM
**中图分类号**:U698 **文献标志码**:A

# Ship Violation Behavior Detection Based on DCNN-LSTM Model

ZHENG Yuanzhou[1,2], LI Xin[1,2], QIAN Long[1,2†], QIN Ruipeng[1,2], LI Guo[1,2], LI Mengxi[1,2]
(1. School of Navigation, Wuhan University of Technology, Wuhan 430063, China;
2. Hubei Key Laboratory of Inland Shipping Technology, Wuhan 430063, China)

**Abstract**: Accurate detection of ship violations in bridge area waters is very important for the pre-control of ship-bridge collisions. To ensure the safety of ship navigation, this paper presents a detection model of ship violation facing bridge area waters. AIS data of continuous bridge area in the Wuhan section of the Yangtze River is real-time collected and preprocessed, and the Convolutional Neural Network (CNN) with powerful feature learning ability is used to extract ship behavior information. And combined with the Long Short Term Memory (LSTM), a deep CNN-LSTM is established to learn the spatiotemporal behavior characteristics of ships, and the experimental analysis is carried out based on three kinds of illegal behaviors on ship overspeed, turning around, and overtaking. The results show that the DCNN-LSTM model proposed has a strong advantage over the CNN, LSTM, and Support Vector Machine (SVM) models, and its accuracy rate, precision rate, and $F_1$ are 88.96%, 96.49%, and 92.87%, respectively, realizing the accurate identification of ship violation. The validity and superiority of DCNN-LSTM are further demonstrated by analyzing the violation of ships in typical waters. The research results provide a reliable

* **收稿日期**:2023-10-14
**基金项目**:国家自然科学基金资助项目(52171350), National Natural Science Foundation of China(52171350).
**作者简介**:郑元洲(1976—),男,湖北武汉人,武汉理工大学教授,博士
† 通信联系人,E-mail: lqian@whut.edu.cn

theoretical basis for ship safety supervision in bridge waters and promote the development of ship intelligence.

**Key words**: deep learning; inland waterways; CNN; LSTM; DCNN-LSTM

近年来，我国内河航运迅速发展，跨江桥梁的建设越来越多，在改善水陆交通的同时，对船舶航行安全也造成一定的影响.因此，构建精确的桥区水域船舶违章行为检测模型，对预测桥区水域船舶交通事故、规范过桥船舶行为至关重要[1].

目前，大多数在册船舶都已安装了船舶自动识别系统(automatic identification system，AIS)，为船舶提供了丰富的船舶运动信息，如船舶位置经纬度、对地航速(SOG)、对地航向(COG)等[2].运用AIS数据对船舶安全航行的研究越来越多，在研究船舶行为识别方面，Zouaoui等[3]通过监控港口中船舶的行为来维护港口安全，基于概率隐马尔可夫模型方法与反应式同步语言方法相结合的方式进行建模，从而识别正常和异常的船舶行为.Handayani等[4]基于支持向量机(support vector machine，SVM)对船舶AIS历史数据进行分类研究，进而识别船舶异常行为，可视化分析了轨迹信息.张代勇等[5]提取AIS数据中有效信息，设计提取船舶对遇和追越等会遇行为特征的算法，实现对内河水域的异常行为进行快速识别.马杰等[6]提出联合支持向量机和贝叶斯滤波的辨识会遇态势模型，对交叉、对遇和追越等会遇态势进行有效识别，有效降低了单独使用SVM的误判概率.何帆等[7]通过时空分析法与航行状态判定法建立了相关的船舶异常行为识别数学模型，并将其运用到ECIVMS SDK电子地图平台上，从而对船舶违章信息进行有效识别.王立林等[8]从大量船舶航迹数据中抽取出可鉴别的船舶航迹，使用多尺度卷积技术提取轨迹数据的特征，构建面向船舶航迹的船舶行为识别网络.李爽[9]为解决渔船可疑行为中的“一船多码”现象，根据分段余弦相似性识别渔船共用统一MMSI号的情况，有效解决渔船监管混乱的问题.d'Afflisio等[10]提出基于广义似然比测试和模型阶数选择的异常检测方法，通过多重假设检验解决船只故意报告虚假AIS信息的问题.马文耀等[11]提出了船舶异常行为的一致性检测算法，在船舶轨迹点中引入能够体现操纵模式的特征，以转向行为与变速行为度量操纵行为相似性，能有效检测船舶变速与转向异常行为.Qian等[12]从AIS数据提取出一系列典型的轨迹，结合深度长短时记忆网络框架和遗传算法对每类典型轨迹进行预测，从而提高了预测精度和计算效率.

综上所述，目前基于AIS数据挖掘的船舶行为研究主要集中在船舶会遇态势、船舶航迹聚类和船舶行为预测等，并未有效利用AIS时间序列的时间特征且存在参数难以调整的问题，为解决上述问题，本文根据AIS数据序列的特征，将卷积神经网络(convolutional neural network，CNN)强大的时序特征提取能力和长短期记忆网络(long short term memory，LSTM)相结合，搭建深度卷积长短时记忆模型(deep convolutional neural network-long short term memory，DCNN-LSTM)来识别桥区水域的三种违章行为，在保留序列全局特征的同时，对局部特征进行更加准确的提取，提高了序列数据处理的准确性.并与传统的CNN、LSTM和SVM模型进行对比实验，实验结果表明，本文所提出的模型在准确率、精确率、召回率和$F_1$四个指标上均表现出较好的优势，可以准确识别出桥区船舶三种违章行为.

## 1 概述

### 1.1 CNN模型

CNN通常被应用于图像和视频等二维数据处理领域，本文采用一维CNN架构来对AIS数据进行处理，能够更好地学习数据的语义特征，减少参数数量，有效保留了时序数据的位置信息[13].

CNN的组成主要包括：输入层(input layer)、卷积层(convolutional layer)、池化层(pooling layer)以及输出层(output layer).卷积层主要用于提取特征，池化层用来进行特征压缩，网络模型结构如图1所示.

池化层根据预设的池化函数，对特征图相邻区域的特征向量统计运算，得到池化后的特征向量.本文采用最大池化函数进行运算，能够更好地捕捉数据中的显著特征，其计算过程如式(1)所示.

$$p_i^l = \max_{r \in R} \left( \boldsymbol{c}_{i \times T + r}^l \right) \tag{1}$$

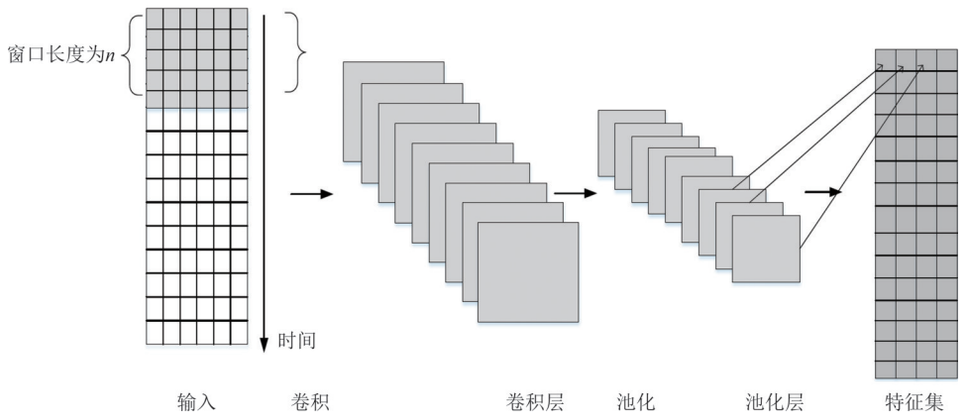



图 1　CNN 模型

Fig.1　CNN model

式中:$p$为最大池化操作的输出值;$l$表示模型中第$l$层;$i$为当前池化层的特征图索引;$r$为池化窗口大小;$R$为池化操作的区域;$T$是池化步长;$\boldsymbol{c}$是特征向量;max表示最大池化运算.

### 1.2　LSTM模型

LSTM模型作为一种特殊的循环神经网络模型,其自带的遗忘门在处理长序列时表现优秀,有效解决了模型在处理长序列数据时存在的梯度消失和梯度爆炸的问题.

在LSTM结构中增加了记忆单元(memory cell)以记忆过去的信息,并增加了输入门(input gate)、输出门(output gate)和遗忘门(forget gate)三种门结构来控制历史信息的传递[14],如图2所示.

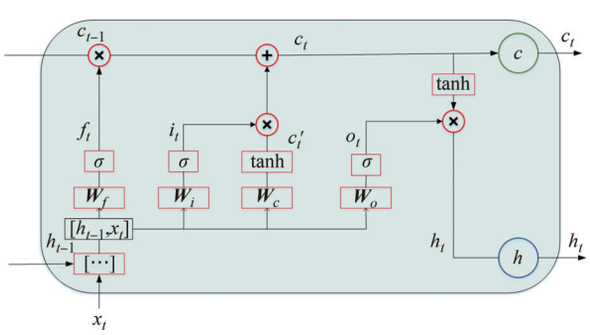



图 2　LSTM 结构

Fig.2　LSTM structure

$i_t$、$f_t$、$o_t$分别为$t$时刻输入门、遗忘门和输出门的计算结果;其中,输入门主要用来决定保留多少当前时刻的输入信息到当前时刻的单元状态;遗忘门主要用来决定保留上一时刻的单元状态$c_{t-1}$的多少信息到当前时刻单元状态$c_t$中;输出门主要用来决定当前时刻的单元状态有多少输出[15]. LSTM单元的计算公式如式(2)~式(7)所示.

$$f_t = \sigma\left(\boldsymbol{W}_f \cdot [h_{t-1}, x_t] + \boldsymbol{b}_f\right) \tag{2}$$

$$i_t = \sigma\left(\boldsymbol{W}_i \cdot [h_{t-1}, x_t] + \boldsymbol{b}_i\right) \tag{3}$$

$$c'_t = \tanh\left(\boldsymbol{W}_c \cdot [h_{t-1}, x_t] + \boldsymbol{b}_c\right) \tag{4}$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot c'_t \tag{5}$$

$$o_t = \sigma\left(\boldsymbol{W}_o \cdot [h_{t-1}, x_t] + \boldsymbol{b}_o\right) \tag{6}$$

$$h_t = o_t \tanh\left(c_t\right) \tag{7}$$

式中:$x_t$表示$t$时刻的输入,$h_t$为当前时刻网络最终输出,$h_{t-1}$为上一时刻网络的输出,$c'_t$为当前输入的单元状态;$c_t$为当前时刻的单元状态;$\boldsymbol{W}_i$、$\boldsymbol{W}_f$、$\boldsymbol{W}_o$、$\boldsymbol{W}_c$分别为三个门控和单元状态的权重矩阵;$\boldsymbol{b}_i$、$\boldsymbol{b}_f$、$\boldsymbol{b}_o$、$\boldsymbol{b}_c$分别为各个门控和单元状态的偏置;$\sigma$代表激活函数;tanh函数为双曲正切函数.

### 1.3　DCNN-LSTM构建

由于一维卷积神经网络(One-dimensional Convolutional Neural Network, 1D-CNN)擅长从数据中捕获局部特征,但是难以捕获序列数据中的长期依赖关系[16];LSTM虽然拥有强大的时序记忆能力,能够对时序信息进行学习,但是对于长序列的处理计算复杂度较高,且并不擅长处理输入中的局部特征[17].考虑到实验所用船舶轨迹为带有时间序列且包含多个特征的AIS数据,本文通过结合CNN自动提取特征的能力和LSTM对时序数据进行学习处理的能力,构建针对AIS时序数据的DCNN-LSTM,其网络结构如图3所示.

在图3中,DCNN-LSTM模型主要由Conv 1d层、Pooling层、Dropout层、LSTM层、全连接层和Softmax函数构成. DCNN-LSTM、LSTM和CNN模型的网络参数如表1~表3所示.

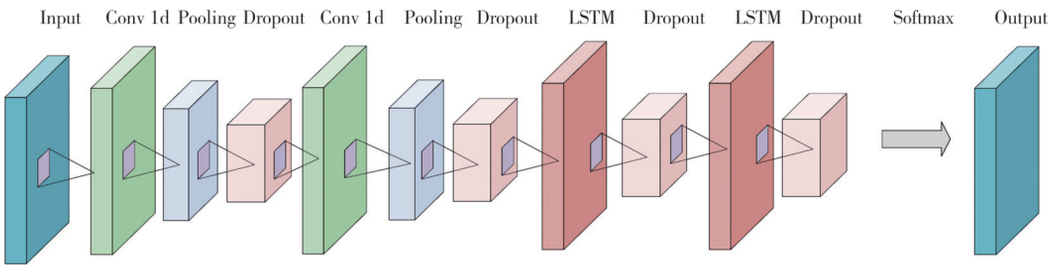



图 3 DCNN-LSTM 模型

Fig.3 DCNN-LSTM model

**表 1 DCNN-LSTM 网络参数**

**Tab.1 DCNN-LSTM network parameters**

| 隐层(类型) | 输出形状 | 参数量 |
|---|---|---|
| conv1d (Conv1D) | (None,118,32) | 512 |
| max_pooling1d (MaxPooling1D) | (None, 59, 32) | 0 |
| dropout (Dropout) | (None, 59, 32) | 0 |
| conv1d_1 (Conv1D) | (None, 57, 32) | 3 104 |
| max_pooling1d_1 (MaxPooling1D) | (None, 28, 32) | 0 |
| dropout_1 (Dropout) | (None, 28, 32) | 0 |
| lstm (LSTM) | (None, 28, 64) | 24 832 |
| dropout _2 (Dropout) | (None, 28, 64) | 0 |
| lstm_1 (LSTM) | (None, 16) | 5 184 |
| dropout_3 (Dropout) | (None, 16) | 0 |
| flatten (Flatten) | (None, 16) | 0 |
| dense (Dense) | (None, 4) | 68 |

注:DCNN-LSTM 模型参数量:33 734

**表 2 LSTM 网络参数**

**Tab.2 LSTM network parameters**

| 隐层(类型) | 输出形状 | 参数量 |
|---|---|---|
| lstm_1 (LSTM) | (None, 120, 64) | 17 920 |
| lstm_2 (LSTM) | (None, 120, 64) | 33 024 |
| lstm_3 (LSTM) | (None, 120, 32) | 12 416 |
| lstm_4 (LSTM) | (None, 16) | 3 126 |
| dense (Dense) | (None, 4) | 5 124 |

注:LSTM 模型参数量:66 564

如表 1~表 3 所示,本文所建立的 DCNN-LSTM 模型由 12 个隐层组成,具体包括 2 个 Conv1D 层、2 个 MaxPooling1D 层、4 个 Dropout 层、2 个 LSTM 层、1 个 Flatten 层和 1 个 Dense 层. LSTM 模型由 5 个隐层构成,具体包括 4 个 LSTM 层和 1 个 Dense 层.CNN 模型由 10 个隐层构成,具体包括 4 个 Conv1D 层、4 个 MaxPooling1D 层、1 个 Flatten 层和 1 个 Dense 层. 可知,DCNN-LSTM 模型通过结合 2 个 LSTM 层和 2 个 Conv1D 层,模型参数量更少,仅有 33 734 个参数,同时兼具强大的时序特征表达能力. 实验中,DCNN-LSTM 网络使用 Softmax 函数、损失函数和优化函数进行网络训练,其数学表达式分别如式(8)~式(10)所示.

**表 3 CNN 参数**

**Tab.3 CNN parameters**

| 隐层(类型) | 输出形状 | 参数量 |
|---|---|---|
| Conv1d_1(Conv1D) | (None, 118, 32) | 512 |
| max_pooling1d(MaxPooling1D) | (None, 59, 32) | 0 |
| conv1d_2 (Conv1D) | (None, 57, 64) | 6 208 |
| max_pooling1d_2(MaxPooling1D) | (None, 28, 64) | 0 |
| conv1d_3 (Conv1D) | (None, 26, 128) | 24 704 |
| max_pooling1d_3(MaxPooling1D) | (None, 13, 128) | 0 |
| conv1d_4 (Conv1D) | (None, 11, 256) | 98 560 |
| max_pooling1d_4(MaxPooling1D) | (None, 5, 256) | 0 |
| flatten (Flatten) | (None, 1 280) | 0 |
| dense (Dense) | (None, 4) | 5 124 |

注:CNN 参数量:135 108

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^{K} e^{z_j}} \tag{8}$$

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \tag{9}$$

$$\theta_{t+1} \leftarrow \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \gamma}\hat{m}_t \tag{10}$$

式中:$z_j$ 表示输入向量 $z$ 中的元素;$\sum_{j=1}^{K} e^{z_j}$ 代表归一化项;$K$ 为多类分类器中的类数;$n$ 为样本总量;$y_i$ 和 $\hat{y}_i$ 分别为预测值和真实值;$\theta$ 为更新参数;$\eta$ 表示学习率;$\hat{v}_t$ 和 $\hat{m}_t$ 分别为代价函数对梯度的一阶和二阶矩;$\gamma$ 表示平滑项.

## 2 船舶违章行为定义

### 2.1 数据采集与预处理

本文使用的 AIS 数据主要来自武汉长江大桥、武汉长江二桥、武汉二七长江大桥,根据武汉海事局港区海事处的规定,桥区水域范围划定如表 4 所

示,采集到的部分AIS数据如表5所示.

**表4　武汉段桥梁基本情况**

**Tab.4　Basic situation of bridges in Wuhan section**

| 名称 | 水域范围 | 日均断面流量/($m^3 \cdot s^{-1}$) | 通航代表船型 |
|---|---|---|---|
| 武汉长江大桥 | 上游1 200 m,下游800 m | 200~350 | 10 000 吨级 |
| 武汉长江二桥 | 上游1 200 m,下游800 m | 200~350 | 15 000 吨级 |
| 武汉二七长江大桥 | 上游1 200 m,下游800 m | 200~350 | 5 000 吨级 |

**表5　部分AIS数据**

**Tab.5　Partial AIS data**

| Date | MMSI | Lon/(°) | Lat/(°) | SOG/kn | COG/(°) |
|---|---|---|---|---|---|
| 2021-11-16 15:25:11 | 413 932 554 | 114.288 9 | 30.553 28 | 4.0 | 218.7 |
| 2021-11-16 15:25:19 | 413 789 341 | 114.279 3 | 30.565 45 | 5.9 | 221.0 |
| 2021-11-16 15:25:23 | 413 932 552 | 114.280 3 | 30.567 27 | 3.6 | 221.3 |
| 2021-11-16 15:25:26 | 413 812 946 | 114.289 1 | 30.567 07 | 9.9 | 222.1 |
| 2021-11-16 15:25:31 | 413 932 554 | 114.288 9 | 30.553 28 | 4.0 | 222.2 |
| 2021-11-16 15:25:38 | 413 771 819 | 114.298 2 | 30.571 93 | 10.7 | 221.6 |
| 2021-11-16 15:25:53 | 413 789 341 | 114.280 4 | 30.566 02 | 5.9 | 300.1 |

AIS数据中的动态信息来自GPS,由于设备自身原因或其他外部环境因素影响,轨迹数据中会出现影响整体数据质量的噪声数据[18],导致AIS数据不能直接用于实验,所以对AIS数据执行以下处理:

Step1:删除航行过程中完全重复的数据.由于多个采集点的采集范围重叠,故数据重复出现,需要进行查重和清洗.

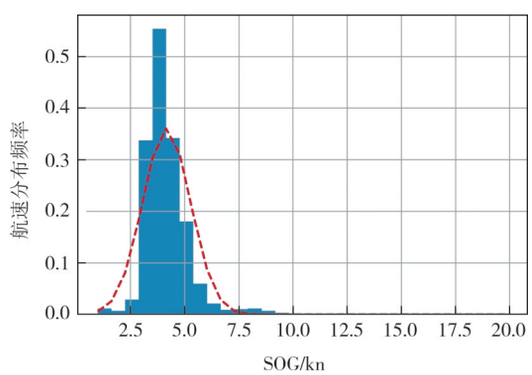
Step2:删除经纬度不符合实际情况的数据以及支流数据.根据研究区域的经纬度范围,删除超出范围的数据;同时删除不在研究范围内的支流数据.

Step3:删除AIS点数量不足50的船舶轨迹.由于AIS数据量大且采集频率高,不足50个轨迹点的船舶轨迹无法充分反映船舶运动特性,因此将其剔除.

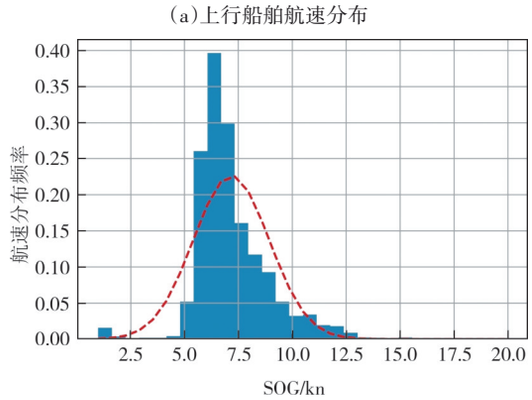
Step4:删除停泊轨迹点及停泊轨迹段.为减少计算时间,若船舶轨迹点速度均低于1 kn,则视为静止状态,并删除该轨迹.

Step5:删除坐标发生突变的轨迹点.删除速度突然增大的轨迹点,通过计算相邻轨迹点的平均速度,删除平均航速大于15 kn的错误数据.

AIS数据经处理后,将船舶轨迹按上下行分离统计航速,如图4所示.武汉桥区水域上行船舶航速基本分布在2 kn~7.5 kn之间,平均航速为4.17 kn;下行船舶航速主要分布在5 kn~12.5 kn,平均航速为7.17 kn,受水流的影响,下行船舶速度明显大于上行船舶速度.




(a)上行船舶航速分布




(b)下行船舶航速分布

图4　上下行船舶航速

Fig.4　Speed of ascending and descending ships

## 2.2　船舶违章行为处理

### 2.2.1　超速行为

超速违章是指驾驶员在行驶过程中,机动船的行驶速度超过法律法规规定的速度.本文采用武汉段桥区水域进行实验,按照武汉市交通运输局在武

汉段水域实施的交通管制,船舶上行航速不低于2 kn,不得高于10 kn;下行航速不高于13 kn,据此设置桥区水域航速界限,超速行为约束函数如式(11)~式(12)所示.

上行:

$$G_{\mathrm{u}}=\begin{cases}0, 2\leqslant V_{\mathrm{s}}\leqslant 10\\ 1, \text{其他}\end{cases} \tag{11}$$

下行:

$$G_{\mathrm{d}}=\begin{cases}0, 0\leqslant V_{\mathrm{s}}\leqslant 13\\ 1, \text{其他}\end{cases} \tag{12}$$

其中,$G_{\mathrm{u}}$、$G_{\mathrm{d}}$分别为根据阈值判定上行和下行船舶是否有超速行为的判定公式;$V_{\mathrm{s}}$表示上、下行船舶航速.当船舶航速大于所给定阈值时,判定此行为为超速行为.

2.2.2 掉头行为

船舶掉头过程中,航速逐渐降低、转向角速度不断加大,直到施舵一定时间后才能稳定[19],所以可以根据转向率的波动判断是否会出现掉头行为.另外,在船舶旋回中,因为船体斜航时,阻力增加;舵阻力增加;推进器效率降低,会出现减速现象.由此可以得出船舶掉头特征提取需同时满足三个条件:

① 在掉头的初始阶段航速降低;

② 在一定时间间隔内,转向率处于逐渐增大的趋势;

③ 航向差从掉头行为开始至结束,航向发生180°左右变化.

其中,航向转向率和航向差计算公式如式(13)~式(14)所示.

$$\mathrm{rate}_{\mathrm{COG}}=\frac{\left|\mathrm{cog}_i-\mathrm{cog}_{i-1}\right|}{t_i-t_{i-1}} \tag{13}$$

$$\Delta c=\begin{cases}360^{\circ}-c(t)-c(t-1), c(t)-c(t-1)\geqslant 180^{\circ}\\ 360^{\circ}+\left(c(t)-c(t-1), c(t)-c(t-1)\leqslant -180^{\circ}\right.\\ c(t)-c(t-1), -180^{\circ}<c(t)-c(t-1)<180^{\circ}\end{cases} \tag{14}$$

其中,$\mathrm{rate}_{\mathrm{COG}}$表示航向转向率;$\mathrm{cog}_i$表示船舶$t_i$时刻轨迹点的航向;$\Delta c$表示船舶航向差;$c(t)$表示$t$时刻船舶的航向.

2.2.3 追越行为

在《中华人民共和国内河避碰规则》[20]中,对两船追越作了规定."一机动船正从另一机动船正横后大于22.5度的某一方向赶上、超过该船,可能构成碰撞危险时,应当认定为追越."从这一条文规定里,可以看出追越行为涉及追越船与被追越船的判断,具体操作流程如下:

①分离上下行轨迹:根据武汉段桥区水域的航道走向,上行船舶航向大致分布在200°~240°之间,下行船舶航向大致分布在20°~60°之间,按此航向范围分离上下行船舶轨迹.

②数据时间对齐:将AIS时间戳精确到分钟,以寻找时间相同的轨迹点.

③筛选潜在追越目标船舶:在1 min内,筛选相对距离小于300 m的船舶轨迹对(MMSI1, MMSI2)作为潜在追越目标船舶.

④确定追越船:通过比较(MMSI1, MMSI2)之间的经度确定前后船,提取MMSI1与MMSI2相同时段(时长30 min)内的数据,对齐数据并计算轨迹点之间的距离.判断距离是否呈现先减小后增大的趋势,若是,则判定后船为追越船.

## 3 实验结果与分析

### 3.1 评价指标

本文搭建的模型用于是否为违章行为的识别,属于二分类任务,为了评价甄别效果,选择准确率(Accuracy)、精确率(Precision)、召回率(Recall)和$F_1$作为模型的评价指标[21],具体为:

$$\mathrm{Accuracy}=\frac{\mathrm{TP}+\mathrm{TN}}{N} \tag{15}$$

$$\mathrm{Precision}=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FP}} \tag{16}$$

$$\mathrm{Recall}=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}} \tag{17}$$

$$F_1=2\times\frac{\mathrm{Precision}\times\mathrm{Recall}}{\mathrm{Precision}+\mathrm{Recall}} \tag{18}$$

其中,$N$表示样本总量;TP表示测试集实际为正例,模型也预测为正例的样本数;TN表示测试集实际为反例,模型也预测为反例的样本数;FP表示测试集实际为反例,但模型预测为正例的样本数;FN表示测试集实际为正例,但模型预测为反例的样本数.

### 3.2 数据集构建

由2.2节可知,所构建的桥区水域违章行为数据集由MMSI、航速、航向、经度、纬度、标签组成,样本数及对应片段长度如表6所示.在将识别出的数据输入神经网络之前,使用滑动窗口法、One-hot编码、数据归一化、数据集分割的方法对数据集进行处理,使原始数据更适于用神经网络处理,从而确保神经网络能够正确地训练.

实验中,首先构建预处理获取的片段序列及其

**表6　提取的各类行为样本数及对应标签**

**Tab.6　The number of samples and corresponding labels of various behaviors extracted**

| 行为 | 样本长度 | 数量 | 标签 |
|---|---|---|---|
| 正常航行 | 24 | 204 | ZC |
| 超速行为 | 24 | 61 | CS |
| 掉头行为 | 24 | 90 | DT |
| 追越行为 | 24 | 25 | ZY |

所对应的实际类别Y作为模型输入，设置学习率为$10^{-3}$，迭代次数为300，优化器为Adam，并按照6∶2的比例随机划分为训练集和测试集，DCNN-LSTM模型具体流程如图5所示.

### 3.3　违章行为识别结果

为验证所构建DCNN-LSTM船舶违章行为检测模型，以长江武汉段桥区水域的船舶为例展开实验，并与CNN、LSTM和SVM[4]模型进行对比分析.其中，SVM网络模型中选择径向基核函数$K(x,y)=\exp(-\|x-y\|^2/\sigma^2)$为核函数，核函数参数和惩罚系数$C$的取值分别为$\sigma^2=3$，$C=50$.

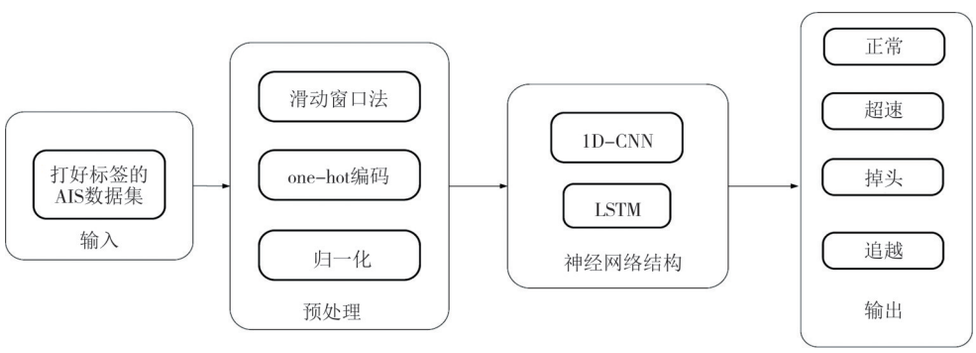



图5　DCNN-LSTM算法流程

Fig.5　DCNN-LSTM algorithm flow

由图6和图7可知，在经过300次迭代后，CNN网络在增加了LSTM通道模块后，测试集网络识别准确率达到了0.889 6，损失率为0.108 4，可以较为准确地检测出三种违章行为.

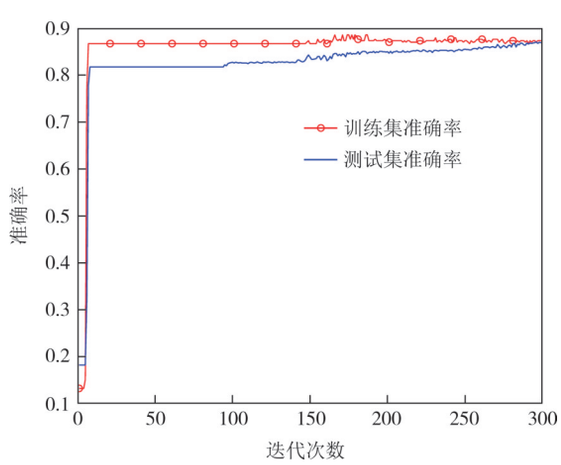



图6　DCNN-LSTM准确率曲线

Fig.6　Accuracy curve of DCNN-LSTM

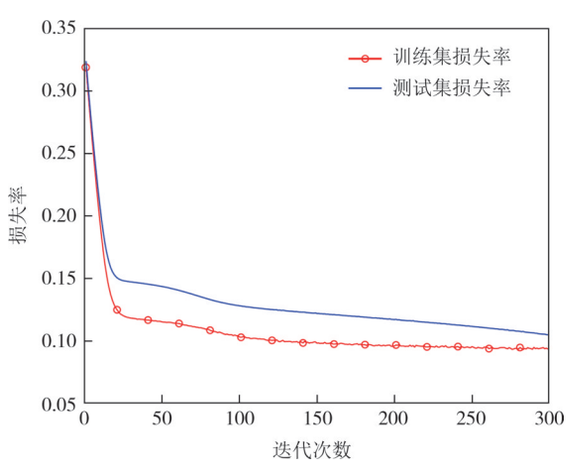



图7　DCNN-LSTM损失率线

Fig.7　DCNN-LSTM loss rate line

为进一步量化DCNN-LSTM模型性能，采用准确率(Accuracy)、精确率(Precision)、召回率(Recall)和$F_1$指标进行量化分析，结果如表7所示.

**表7　四种网络实验结果对比**

**Tab.7　Comparison of experimental results for four networks**

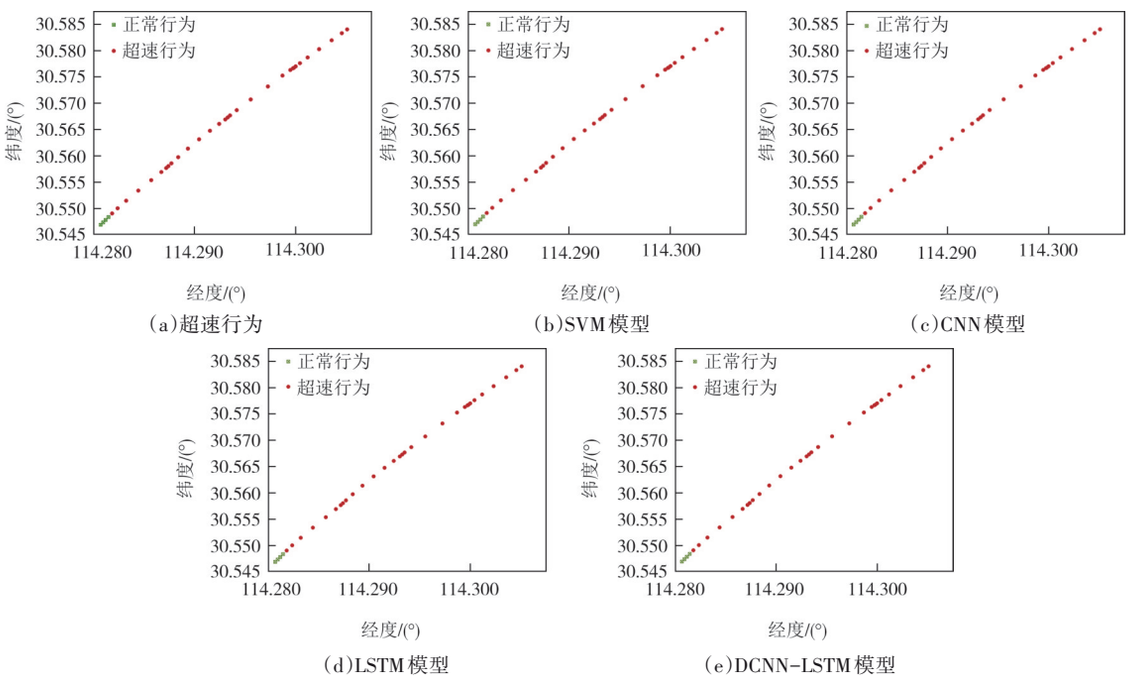
| 网络 | 准确率 | 精确率 | 召回率 | $F_1$ | 训练时间/s |
|---|---|---|---|---|---|
| SVM | 0.840 4 | 0.843 3 | 0.841 3 | 0.841 7 | 156.499 7 |
| CNN | 0.849 5 | 0.864 7 | 0.949 3 | 0.905 0 | 277.631 1 |
| LSTM | 0.864 2 | 0.954 0 | 0.886 1 | 0.918 8 | 708.144 5 |
| DCNN-LSTM | 0.889 6 | 0.964 9 | 0.903 9 | 0.928 7 | 249.420 2 |

由表7可知，DCNN-LSTM方法与SVM模型相比，虽然在训练时长上多93 s，但在准确率、精确率、召回率、$F_1$方面均有提升，分别提升了4.92、12.16、6.26、8.70个百分点；比LSTM网络的准确率、

精确率、召回率和 $F_1$ 分别高出 2.54、1.09、1.78、0.99 个百分点，训练时间缩短了 459 s；与 CNN 方法相比，虽然召回率降低了 4.54 个百分点，但是训练时间缩短了 28 s，准确率、精确率、$F_1$ 分别高出 4.01、10.02、2.37 个百分点.这表明了 DCNN-LSTM 方法在桥区水域违章行为识别问题上比 SVM 模型、单独的 LSTM 和 CNN 方法更具优越性.

### 3.4 实例分析

为直观地评估所建立识别模型的性能和效果，体现模型的优越性，将四种模型的违章行为识别结果进行可视化.在船舶违章行为识别中，超速违章行为与掉头、追越违章行为相比，识别比较简单，四种模型均能有效识别，实验结果如图 8~图 10 所示.

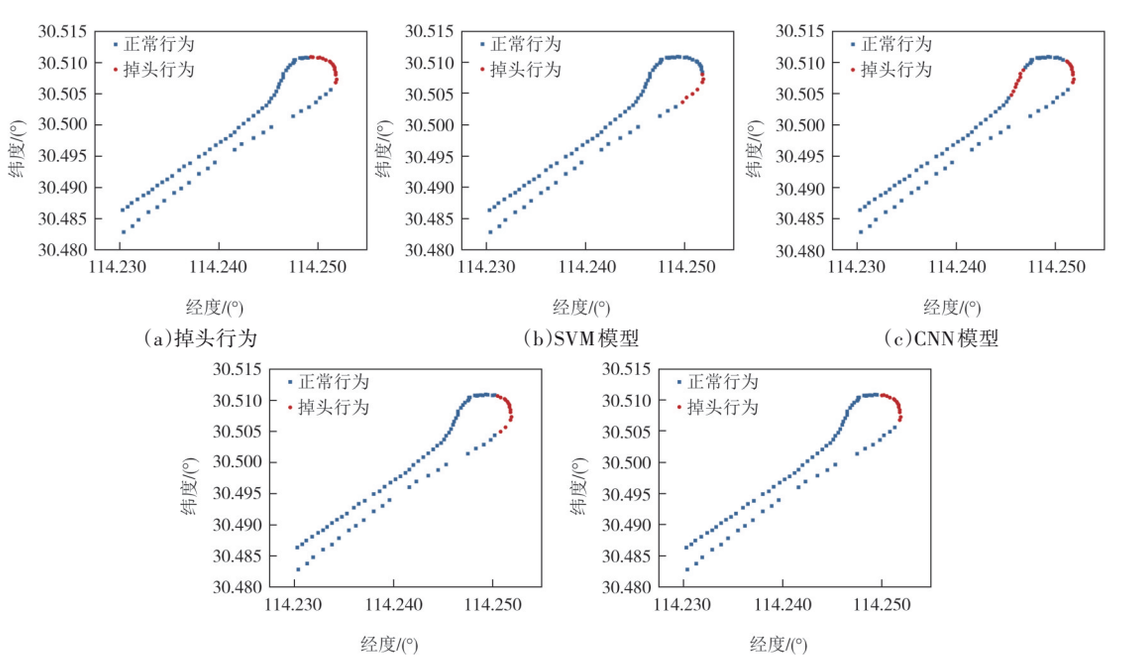



(a)超速行为 (b)SVM 模型 (c)CNN 模型

(d)LSTM 模型 (e)DCNN-LSTM 模型

图 8 超速行为识别结果可视化

Fig.8 Visualization of speeding behavior recognition results




(a)掉头行为 (b)SVM 模型 (c)CNN 模型

(d)LSTM 模型 (e)DCNN-LSTM 模型

图 9 掉头行为识别结果可视化

Fig.9 Visualization of U-turn behavior recognition results

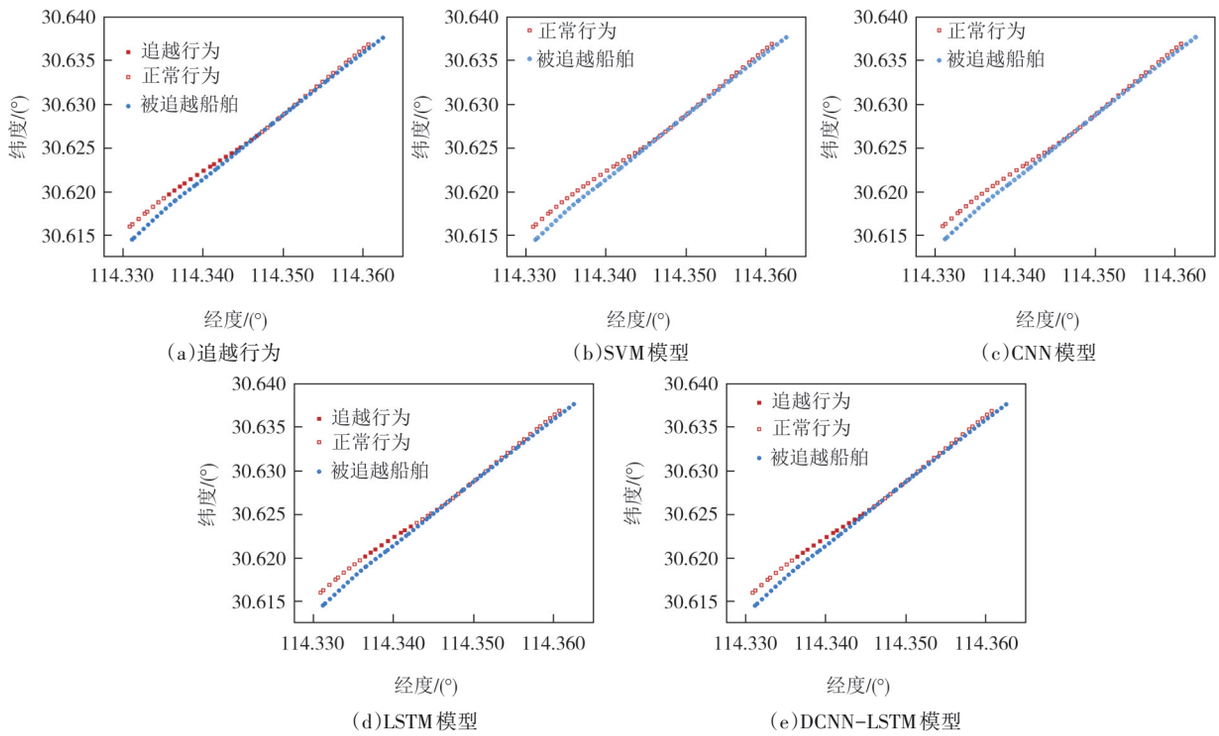



图 10　追越行为识别结果可视化

Fig.10　Visualization of recognition results of overtaking behavior

可视化结果表明，SVM模型因其较低的泛化性能和易陷入局部极值的不足，在识别掉头行为时准确率较低. CNN在识别掉头违章行为时存在将非掉头行为误判为掉头行为的情况，这是因为CNN在处理时序特征方面的准确性较低. LSTM能够识别涉及时序特征的行为，但由于特征提取能力较弱，在识别追越行为方面表现不佳，存在追越中、追越后识别缺失的情况. 然而，DCNN-LSTM模型通过结合CNN自动提取特征的能力和LSTM对时序数据进行学习处理的能力，既保留了序列的全局特征，同时对局部特征进行更准确的提取，提高了处理序列数据的准确性. 该模型能够更好地适应不同类型的序列数据，具有更好的泛化能力，且在不同的工况下展现出更出色的表现.

## 4　结 论

本文针对内河桥区水域船舶交通事故频发，难以有效监管的问题，建立了桥区船舶违章行为识别模型. 首先根据船舶违章行为的时空轨迹设计相应的特征提取算法，实现对超速、掉头和追越三种违章行为特征的精准提取. 其次根据AIS数据序列的特征，结合CNN和LSTM两者的优势，搭建了DCNN-LSTM模型来识别桥区水域的三种违章行为. 实验证明，本文提出的DCNN-LSTM模型在识别任务上，相比于传统CNN、LSTM和SVM模型表现更加优秀，识别准确率和精确率分别为88.96%和96.49%，能够更准确地识别桥区船舶超速、追越和掉头三种违章行为. 本文研究有利于保障桥区水域船舶航行安全，为海事监管提供了一定的理论基础，推动了内河水上交通的智能化发展.

## 参考文献

[1]　李梦希,束亚清,郑元洲,等. 桥区水域船舶追越与偏离的非安全行为识别[J]. 武汉理工大学学报(交通科学与工程版),2023,47(3): 561-567.
LI M X, SHU Y Q, ZHENG Y Z, et al. Identification of unsafe behavior of ship overtaking and deviation in bridge area [J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2023, 47(3): 561-567. (in Chinese)

[2]　杨红,韩鹏,刘畅,等. 基于多任务学习的船舶行为识别与轨迹预测[J]. 重庆交通大学学报(自然科学版),2022,41(4):1-7.
YANG H, HAN P, LIU C, et al. Vessel behavior recognition and trajectory prediction based on multi-task learning model [J]. Journal of Chongqing Jiaotong University (Natural Science), 2022, 41(4): 1-7. (in Chinese)

[3]　ZOUAOUI S, ROY V, MAÏZI N. Behavior analysis modulus for harbor security [C]//2012 Oceans. October 14-19, 2012, Hampton Roads, VA, USA: IEEE, 2012: 1-9.

[4] HANDAYANI D O D, SEDIONO W, SHAH A. Anomaly detection in vessel tracking using support vector machines (SVMs) [C]//2013 International Conference on Advanced Computer Science Applications and Technologies. December 23-24, 2013, Kuching, Malaysia: IEEE, 2013: 213-217.

[5] 张代勇,吴青,钟诚,等. 内河船舶行为特征提取方法研究[C]//第十二届中国智能交通年会学术委员会. 第十二届中国智能交通年会大会论文集. 常熟:电子工业出版社,2017: 586-594.
ZHANG D Y, WU Q, ZHONG C, et al. Research on behavior feature extraction method of inland river ships [C]// Academic Committee of the 12th China Intelligent Transportation Annual Conference. Proceedings of the 12th China Intelligent Transportation Annual Conference. Changshu: Publishing House of Electronics Industry, 2017: 586-594. (in Chinese)

[6] 马杰,李文楷,张春玮,等. 基于AIS数据的交汇水域船舶会遇态势辨识[J]. 中国航海,2021,44(1):68-74.
MA J, LI W K, ZHANG C W, et al. Ship encounter situation recognition by processing AIS data from traffic intersection waters [J]. Navigation of China, 2021, 44(1): 68-74. (in Chinese)

[7] 何帆,何正伟,杨帆,等. 基于电子海图的船舶异常行为识别方法研究[J]. 武汉理工大学学报(交通科学与工程版), 2019, 43(4):631-636.
HE F, HE Z W, YANG F, et al. Research on recognition method of abnormal behavior of ships based on electronic chart [J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2019, 43(4): 631-636. (in Chinese)

[8] 王立林,刘俊. 基于多尺度卷积的船舶行为识别方法[J]. 计算机应用,2019,39(12):3691-3696.
WANG L L, LIU J. Ship behavior recognition method based on multi-scale convolution [J]. Journal of Computer Applications, 2019, 39(12): 3691-3696. (in Chinese)

[9] 李爽. 基于AIS的渔船可疑行为检测[D]. 大连:大连海洋大学,2022.
LI S. Behavior detection of fishing vessels based on AIS [D]. Dalian: Dalian Ocean University, 2022. (in Chinese)

[10] D'AFFLISIO E, BRACA P, WILLETT P. Malicious AIS spoofing and abnormal stealth deviations: a comprehensive statistical framework for maritime anomaly detection [J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(4): 2093-2108.

[11] 马文耀, 吴兆麟, 李伟峰. 船舶异常行为的一致性检测算法[J]. 交通运输工程学报, 2017, 17(5): 149-158.
MA W Y, WU Z L, LI W F. Conformal detection algorithm of anomalous behaviors of vessel [J]. Journal of Traffic and Transportation Engineering, 2017, 17(5): 149-158. (in Chinese)

[12] 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.

[13] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: a survey [J]. Mechanical Systems and Signal Processing, 2019, 19(5): 50-54.

[14] DEIHIMI A, ORANG O, SHOWKATI H. Short-term electric load and temperature forecasting using wavelet echo state networks with neural reconstruction [J]. Energy, 2013, 57: 382-401.

[15] 钱龙,王文波,陈贵词, 等. 一种基于遗传算法优化的长短时记忆网络胎儿心电信号提取方法[J]. 生物医学工程学杂志, 2021, 38(2): 257-267.
QIAN L, WANG W B, CHEN G C, et al. A fetal electrocardiogram signal extraction method based on long short term memory network optimized by genetic algorithm [J]. Journal of Biomedical Engineering, 2021, 38(2): 257-267. (in Chinese)

[16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.

[17] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: continual prediction with LSTM [J]. Neural Computation, 2000, 12(10): 2451-2471.

[18] 赵梁滨. 基于AIS数据和循环神经网络的船舶轨迹异常检测[D]. 大连: 大连海事大学, 2019.
ZHAO L B. Ship trajectory anomaly detection based on AIS data and recurrent neural network [D]. Dalian: Dalian Maritime University, 2019. (in Chinese)

[19] 方泉根. 回转角速度指示器在船舶操纵中的应用[J]. 交通部上海船舶运输科学研究所学报, 1994, 17(1): 73-78.
FANG Q G. The application of rot indicator for ship's manoeuvring [J]. Journal of Shanghai Ship and Shipping Research Institute, 1994, 17(1): 73-78. (in Chinese)

[20] 中华人民共和国海事局. 中华人民共和国内河避碰规则[EB/OL].(2016-06-13)[2023-10-14]. https://www.msa.gov.cn/page/article.do? preview=false&articleId=B6DCB96D-303D-4261-9DF0-E501F7F756D1. Maritime Administration of the People's Republic of China. Rules of the People's Republic of China for Preventing Collisions on Inland Rivers [EB/OL]. (2016-06-13) [2023-10-14]. (in Chinese)

[21] 宁耀. 基于深度学习的渔船行为识别方法研究[D]. 兰州: 兰州大学, 2020.
NING Y. Research on fishing boat behavior recognition method based on deep learning [D]. Lanzhou: Lanzhou University, 2020. (in Chinese)