

基于改进 ResNet 的 AIS 船舶状态识别模型研究

薛勇军¹ 黄进¹ 黄俊予¹ 丁清源¹

XUE Yongjun HUANG Jin HUANG Junyu DING Qingyuan

摘要

船舶自动识别系统(AIS)为水上交通监管提供了海量运动状态数据,如何从中准确识别船舶航行状态是智能航运领域的关键问题。针对传统方法在AIS多维时序特征提取中精度不足的问题,文章提出一种基于改进残差网络(ResNet)的AIS船舶状态识别模型,采用加权交叉熵损失函数应对类别不平衡问题。实验结果表明,改进模型总体识别准确率达94.8%,较基础ResNet提升3.6个百分点,验证了方法的有效性。

关键词

AIS数据;船舶状态识别;残差网络;注意力机制;时序分类

doi: 10.3969/j.issn.1672-9528.2026.07.030

0 引言

随着全球航运贸易量持续增长,海上交通事故风险不断上升,船舶自动识别系统(AIS)为海事监管提供了丰富的实时数据源。基于AIS数据的船舶行为分析已成为研究热点,如刘钊等^[1]提出通过运动参数统计建模识别船舶异常行为的方法,但其依赖人工设定的阈值规则,面对复杂场景适应性有限。随着深度学习技术在时序分类任务中展现出更强的特征提取能力,残差网络(ResNet)凭借跳跃连接结构有效缓解了深层网络的梯度退化问题,已广泛应用于图像分类、信号识别等领域^[2]。然而,现有方法多将AIS轨迹作为整体分类,对同一航行过程中不同运动状态的实时识别关注较少。与上述方法不同,本文将识别粒度从航段级细化到滑动窗口级(约2~3 min),面向碰撞风险实时评估与交通流态势感知等应用需求,并针对多状态短时变化场景设计多尺度残差融合与双重注意力协同机制,提出一种改进ResNet船舶多种状态识别模型。

1 AIS数据集构建与处理

1.1 AIS数据来源与字段选取

本文所使用的AIS数据来源于我国东南某沿海港口水域的岸基AIS接收站,覆盖2024年1~6月的船舶动态记录,有效报文约2100万条。根据状态识别需求,选取经度、纬度、对地航速(SOG)、对地航向(COG)和船首向(HDG)作为动态特征字段,MMSI与时间戳用于轨迹关联。此外,构造了航速差分 Δv 和航向角差分 $\Delta\theta$ 两个派生特征,增强运动趋势表征能力。特征的选取基于AIS运动学分析,其中SOG与COG直接反映运动速度与方向,HDG与COG的差异可

表征风流压差;航速差分与航向角差分作为一阶导数特征,能捕捉运动状态的瞬时变化趋势。水域日均过境船舶约150艘,涵盖散货船、集装箱船、油轮及客船等多种船型,具有港口水域的典型特征。但由于开阔洋区、狭窄航道及内河水域的船舶操纵特性、交通流密度和AIS报文间隔均可能存在显著差异,模型的跨水域适用性有待后续验证。

1.2 船舶状态划分与样本构建

在确定特征字段后,需将连续AIS时序数据转化为带标签的离散样本。本文将船舶运动状态划分为匀速直航(SC)、加减速航行(AD)、转向航行(TN)和停泊/漂航(MD)四类。参考闫兆进等^[3]对运动特征对行为描述的验证方法,本文进一步将运动特征用于状态分类标签的生成,时刻 t 的航速差分为:

$$\Delta v_t = \text{SOG}_t - \text{SOG}_{t-1} \quad (1)$$

该值为正表示船舶处于加速状态,为负则表示减速。航向角差分需修正 $0^\circ/360^\circ$ 边界跨越问题:

$$\Delta\theta_t = ((\text{COG}_t - \text{COG}_{t-1}) + 180) \bmod 360 - 180 \quad (2)$$

式中:mod为取模运算,修正后 $\Delta\theta_t \in [-180^\circ, 180^\circ]$ 。

基于上述特征,结合航速绝对值,表1为四类状态的判定规则。阈值 $v_{\min}$ 、 Δv_{th} 和 $\Delta\theta_{\text{th}}$ 阈值的选取综合考虑了航海实践经验与数据统计分析,0.5 kn(1 kn = 1.852 km/h)为区分停泊/漂航与航行状态的航速门限,参考了港口水域船舶低速漂泊时的典型SOG分布(均值约0.2~0.4 kn);0.3 kn为相邻时刻航速变化的波动容限,训练集中匀速直航样本的航速差分进行统计95%分位数约为0.28 kn,取0.3 kn可有效过滤正常航速波动;10°为区分直航与转向的航向变化阈值,依据训练集中转向样本的航向角差分分布确定。

1. 舟山市自来水有限公司 浙江舟山 316000

表 1 船舶状态类别与标签判定规则

状态类别	标签	判定条件
停泊 / 漂航 (MD)	0	$SOG_t < v_{min}$
匀速直航 (SC)	1	$SOG_t \geq v_{min}$ 且 $ \Delta v_t < \Delta v_{th}$ 且 $ \Delta \theta_t < \Delta \theta_{th}$
加减速航行 (AD)	2	$SOG_t \geq v_{min}$ 且 $ \Delta v_t \geq \Delta v_{th}$ 且 $ \Delta \theta_t < \Delta \theta_{th}$
转向航行 (TN)	3	$SOG_t \geq v_{min}$ 且 $ \Delta \theta_t \geq \Delta \theta_{th}$

对三个阈值分别在 $\pm 20\%$ 范围内进行敏感性实验（如表 2 所示），整体波动不超过 0.6 个百分点，表明阈值设定具有较好的鲁棒性，模型对阈值的精确取值并不敏感。确定状态标签后，下一步需将 AIS 轨迹转化为固定长度的特征矩阵以适配深度学习模型输入。

表 2 不同窗口长度下模型识别性能对比

窗口长度	Accuracy	单位：%			
		SC- F_1	AD- F_1	TN- F_1	MD- F_1
10	91.5	92.8	90.1	87.1	93.2
15	93.6	94.5	92.3	89.8	94.5
20	94.8	95.6	93.9	92.4	95.8
25	94.1	95.0	93.2	91.5	95.2
30	93.4	94.3	91.2	90.2	94.8

对每艘船舶的轨迹按 MMSI 聚合排序后，采用固定长度滑动窗口（ $L=32$ ，步长 1）切片，每个样本构造为特征矩阵：

$$\mathbf{X}_i \in \mathbb{R}^{L \times D} \quad (3)$$

式中： $L=32$ 为时间窗口长度， $D=7$ 窗口长度的选取需平衡时间分辨率与状态完整性，本文在 $W=10、15、20、25、30$ 五个候选值上进行了对比实验， $W=20$ 时模型总体准确率最高（94.8%）。以 AIS 报文典型发送间隔 6~10 s 计算， $W=20$ 对应约 2~3 min 的观测窗口，能够覆盖多数船舶标准操纵的典型持续时间，图 1 以航速和航向变化为坐标展示了不同状态在特征空间中的分布。




图 1 船舶速度—航向变化二维状态相图

1.3 AIS 数据清洗归一化

原始 AIS 数据存在噪声和异常记录，需进行清洗。本文删除经纬度为 0 或超出研究水域的记录，剔除航速大 $< 2\text{ s}$ 内的重复报文去重，对相邻报文间隔超过 30 min 的轨迹截断。由于各特征量纲差异较大，采用最小 - 最大归一化：

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4)$$

式中： x 和 x' 分别为归一化前后的特征值， x_{max} 和 x_{min} 为该特征在训练集上的极值。

1.4 训练集、验证集、测试集划分

经窗口化与清洗后，得到有效样本 96 512 个（匀速直航有 28 743 个、加减速有 24 316 个、转向有 19 087 个、停泊 / 漂航有 24 366 个），按 6:2:2 比例分层划分为训练集、验证集和测试集。四类样本的不均衡比为 1.51:1.28:1.00:1.28（以最少的转向类为基准），转向类样本量最少是采用加权交叉熵损失的直接动因。训练集统计显示，SOG 呈双峰分布（低速峰约 0.2 kn 对应停泊、高速峰约 8~12 kn 对应航行），航向角差近似拉普拉斯分布，多模态非高斯分布特点表明传统线性方法难以有效分类，也印证了引入深度学习方法的必要性。各状态统计特征如表 3 所示，可以看出在航速均值和航向变化幅度上具有显著区分度。

表 3 四类状态训练集数据统计特征

训练集	样本数量	SOG 均值 /kn	SOG 标准差 /kn	$ \Delta SOG $ 均值 /kn	$ \Delta COG $ 均值 /($^{\circ}$)
SC	28 743	9.8	3.2	0.12	1.8
AD	24 316	8.5	4.1	0.85	2.5
TN	19 087	7.6	3.8	0.31	18.6
MD	24 366	0.3	0.2	0.08	3.2

2 改进 ResNet 船舶状态识别模型设计

2.1 ResNet 基础网络

残差网络通过跳跃连接，将学习目标从拟合目标映射 $H(x)$ 转变为拟合残差映射 $F(x)$ ：

$$H(x) = F(x) + x \quad (5)$$

式中： x 为残差块输入； $F(x)$ 为卷积层变换后的输出，当 $F(x)$ 趋近于 0 时，网络等效为恒等映射。

本文将 ResNet 的二维卷积替换为一维卷积以适应时序数据，并针对 AIS 状态识别任务设计了多尺度残差融合模块与双重注意力机制。

2.2 AIS 时序特征残差块设计

2.2.1 一维卷积特征提取

AIS 数据本质为多维时间序列，相邻时刻存在运动连续性。一维卷积通过在时间轴滑动固定大小的卷积核捕获局部

运动模式，具有参数共享与平移不变性优势，基础残差块采用两层一维卷积堆叠（卷积核大小为3），每层后接批归一化和 ReLU 激活，采用 same 填充保持时序长度，跳跃连接将输入直接加到输出上，通道数不一致时通过 1×1 卷积对齐。

2.2.2 多尺度残差融合模块

上述基础残差块的卷积核大小固定为3，单一尺度难以同时兼顾短程局部特征与长程趋势特征，为此本文进一步设计多尺度残差融合模块，模块包含3个并行的一维卷积分支，并行使用卷积核大小为3、5、7的一维卷积分支，对应于短程、中程和长程的时间感受野。给定输入 $Z \in \mathbb{R}^{L \times C}$ ，三分支输出为：

$$Z_k = \text{ReLU}(\text{BN}(\text{Conv1D}_k(Z))), k \in \{3, 5, 7\} \quad (6)$$

将三分支输出在通道维度拼接：

$$Z_{\text{cat}} = \text{Concat}(Z_3, Z_5, Z_7) \quad (7)$$

拼接后通过 1×1 卷积压缩通道数回 C ，再与输入残差连接：

$$Z_{\text{out}} = \text{ReLU}(\text{Conv1D}_1(Z_{\text{cat}}) + Z) \quad (8)$$

该模块结构如图2所示。多尺度并行与残差融合的设计在不显著增加深度的前提下扩展了感受野范围。




图2 多尺度残差融合模块结构

2.3 注意力机制与特征重标定

2.3.1 通道注意力模块

经过多尺度残差融合模块提取的特征包含了多个通道，每个通道对应于不同类型的运动模式表示。本文引入通道注意力模块对各通道特征进行自适应加权，对特征图在时间维度上进行全局平均池化，得到各通道的全局描述符，再通过两层全连接网络生成通道权重向量，将其与原始特征图逐通道相乘，实现对重要特征通道的强化与次要通道的抑制。完成通道维度的特征筛选后，还需在时间维度上区分不同时刻的重要性。

2.3.2 时序注意力模块

不同时刻的观测值对状态判别的贡献同样存在差异，

有必要在船舶航迹预测中引入循环神经网络捕获时序依赖的方法^[4]。以转向为例，关键时段集中在航向变化最显著的若干时刻，因此时序注意力模块对通道注意力输出 $F \in \mathbb{R}^{L \times C}$ 在通道维度分别进行平均池化和最大池化，拼接后通过卷积核大小为7的一维卷积融合，经 Sigmoid 生成时序权重：

$$\alpha = \sigma(\text{Conv1D}_7(\text{Concat}(\text{AvgPool}_C(F), \text{MaxPool}_C(F)))) \quad (9)$$

式中： $\alpha \in \mathbb{R}^{L \times 1}$ 为时序注意力权重向量，广播后与 F 逐元素相乘实现关键时刻特征增强。图3为该模块的计算结构示意图。通道与时序注意力的串联使用实现了双维度特征重标定，经过上述模块加权后的特征即可送入分类器完成状态判别。




图3 AIS 轨迹时序注意力模块结构

2.4 分类输出与损失函数设计

特征提取后接全局平均池化与两个全连接层（含 Dropout=0.5），经 Softmax 输出四类概率分布。由于实际 AIS 数据中不同运动状态的样本数量并不均衡，使用标准交叉熵损失容易导致模型偏向多数类、对少数类识别能力不足，因此采用加权交叉熵损失函数：

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C w_c \cdot y_{ic} \cdot \log(\hat{y}_{ic}) \quad (10)$$

式中： N 为样本总数， $C=4$ 为类别数， y_{ic} 和 $\hat{y}_{ic}$ 分别为真实标签与预测概率。 $w_c = N/(C \cdot N_c)$ 使少数类获得更高的损失权重，让模型更加均衡地学习各类状态的判别特征。

3 实验与分析

3.1 实验环境与参数设置

实验在配备高性能 GPU 的服务器上进行，采用 PyTorch 框架，Adam 优化器与余弦退火学习率调度。训练 200 个 epoch 并启用早停（patience=20）。配置如表4所示。

表 4 实验环境与模型训练参数

参数	配置
操作系统	Ubuntu 20.04 LTS
GPU	NVIDIA RTX 4090 (24 GB)
深度学习框架	PyTorch 2.1.0
CUDA	12.1
优化算法	Adam
初始学习率	0.001
Batch size	64
Epochs	200 (早停 patience=20)
Dropout 率	0.5

3.2 对比模型与实验方案

在上述实验环境下，为评估模型性能，选取标准 LSTM、基础一维 ResNet18、ResNet18+SE、CNN-LSTM 及 ResNet1D-AttLSTM 模型（Ke 等^[5]提出），作为近期提出的先进方法。所有模型均在相同配置下实验。评价指标选取总体准确率和各类别 F_1 值。

3.3 船舶状态识别结果分析

测试集性能对比如表 5 所示。标准 LSTM 准确率 88.7%，对局部运动模式捕获有限。基础 ResNet18 达 91.2%，但转向类 F_1 偏低（85.3%）。加入 SE 后提升至 92.6%。CNN-LSTM 为 92.1%。ResNet1D-AttLSTM 达 93.5%。本文模型在所有指标上取得最优，总体准确率 94.8%，较基础 ResNet18 提升 3.6 个百分点，各类别 F_1 值均在 92% 以上，其中转向类 F_1 提升最为显著。

表 5 不同模型船舶状态识别性能对比

模型	单位：%				
	Accuracy	SC- F_1	AD- F_1	TN- F_1	MD- F_1
LSTM	88.7	90.1	87.6	83.2	91.5
ResNet18-1D	91.2	93.0	90.4	85.3	93.7
ResNet18-1D+SE	92.6	94.1	91.8	88.7	94.2
CNN-LSTM	92.1	93.5	91.2	87.5	94.0
ResNet1D-AttLSTM	93.5	94.8	92.7	90.1	95.0
本文方法	94.8	95.6	93.9	92.4	95.8

3.4 消融实验与可视化分析

上述对比实验表明本文模型整体性能最优，为进一步揭示各改进模块的独立贡献，多尺度融合（MS）、通道注意力（CA）和时序注意力（TA）。基础网络准确率 91.2%，加入 MS 后提升至 92.8%，表明多尺度卷积核在捕获不同时间跨度运动模式上具有互补优势；再加入 CA 达 93.7%，说明通道注意力有效增强了航速和航向通道在对应状态识别中的判别权重；最终加入 TA 达 94.8%，转向类 F_1 从 85.3% 提升至 92.4%，表明时序注意力能聚焦航向突变的关键时刻，显著

改善短时突变状态的识别。图 4 展示了训练损失及验证准确率曲线，可见改进模型收敛更快且未出现明显过拟合。




图 4 模型训练损失（左）与识别准确率（右）曲线

4 结语

本文提出了一种基于改进 ResNet 的 AIS 船舶状态识别模型，通过多尺度残差融合与双重注意力机制实现特征重标定，采用加权交叉熵损失缓解类别不均衡，总体准确率达 94.8%，四类状态 F_1 值均超 92%。但需要指出的是，目前研究中状态类别的划分依赖于预设的阈值规则，对于复杂的混合运动模式的处理还不够精细，模型仅在单一港口水域验证，不同海域的船舶类型、交通流密度和气象条件差异可能影响泛化能力。后续工作将引入无监督方法自动发现运动状态类别，探索跨水域迁移学习策略，并结合气象水文信息构建多源融合模型，推动 AIS 智能分析在船舶交通流管理、碰撞预警和港口调度中的深入应用。

参考文献：

[1] 刘钊, 齐磊, 梁茂晗, 等. 数据驱动的船舶异常行为识别方法[J]. 中国航海, 2022, 45(4): 1-7.

[2] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 770-778.

[3] 闫兆进, 杨慧, 慈慧, 等. 船舶轨迹提取模型构建与交通流分析[J]. 地球信息科学学报, 2023, 25(11): 2134-2149.

[4] 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.

[5] Ke Jiankang, Lu Faxing, Liu Yifei, et al. A ResNet1D-AttLSTM-based approach for ship trajectory classification[J]. Applied Sciences, 2025, 15(7): 3489.

【作者简介】

薛勇军（1988—），男，江苏南通人，本科，环境工程中级，研究方向：海洋感知、多模态数据融合。

（收稿日期：2026-06-11 修回日期：2026-07-14）