基于轨迹时序建模的船舶走私行为识别方法

何四海，徐一智，敬彦民，白学智，雷　晨

（成都天奥信息科技有限公司，成都 610000）

摘　要： 针对海上走私活动隐蔽性强、行为模式复杂、自动识别难度大的问题，提出一种基于雷达与AIS融合轨迹的船舶走私行为实时识别方法。通过分析走私船舶“出发—越界—接驳—返航—上岸”的典型行为模式，构建融合地理语义信息的轨迹时序特征体系，并针对走私行为样本稀缺及类别不平衡问题，设计加权损失函数与轨迹数据增广策略。在此基础上，采用多层长短期记忆网络（Long Short-Term Memory，LSTM）对船舶轨迹时序特征进行建模，并引入融合目标类型、边界跨越状态和离岸距离等特征，增强模型对特定走私行为空间-时间模式的识别能力。实验结果表明，与DNN及Bi-LSTM等对比模型相比，该方法在精确率、召回率、F1分数和准确率等指标上均取得更优表现，同时具有较低的推理延迟，能够满足船舶走私行为实时识别需求，可为智慧海防系统的主动预警与精准管控提供技术支撑。

关键词： 船舶轨迹分析；走私行为识别；LSTM；雷达与AIS融合；数据增广；智慧海防

中图分类号： TP391　　**文献标识码：** A

Identification method of ship smuggling behavior based on trajectory time series modeling

HE Sihai，XU Yizhi，JING Yanmin，BAI Xuezhi，LEI Chen

（Chengdu Spaceon Technology Co.，Ltd.，Chengdu 610000，China）

Abstract: A real-time recognition method for ship smuggling activities based on radar and AIS fused trajectory data is proposed to address the challenges posed by the high concealment, complex behavioral patterns, and difficulties in automatic identification of maritime smuggling activities. By analyzing the typical behavioral sequence of smuggling vessels—namely, departure, boundary crossing, rendezvous, return voyage, and landing—a trajectory time-series feature system integrated with geographic semantic information is constructed. To mitigate the issues of scarce smuggling behavior samples and class imbalance, a weighted loss function and a trajectory data augmentation strategy are designed. On this basis, a multi-layer Long Short-Term Memory (LSTM) network is employed to model the temporal features of vessel trajectories, and additional features such as vessel type, boundary-crossing status, and offshore distance are incorporated to enhance the model's capability in recognizing the spatiotemporal patterns specific to smuggling behaviors. Experimental results demonstrate that, in comparison with baseline models including DNN and Bi-LSTM, the proposed method achieves superior performance in terms of precision, recall, F1-score, and accuracy, while maintaining low inference latency, thereby satisfying the real-time requirements for ship smuggling behavior recognition. This work is expected to provide technical support for proactive warning and precise control in intelligent maritime surveillance systems.

Key words: ship trajectory analysis, smuggling behavior identification, LSTM, radar and AIS fusion, data augmentation, smart maritime defense

1　引言

近年来，海上走私活动呈现出较强的隐蔽性和机动性，部分不法人员通过夜间航行、恶劣天气条件下作业以及关闭船舶自动识别系统（Automatic Identification System，AIS）等方式规避监管，对海上安全和正常经济秩序造成潜在威胁。为提升海防监管能力，智慧海防系统广泛采用雷达、AIS等多源感知设备对海上目标进行持续监测。其中，雷达具有全天候目标探测能力，可有效发现未开启AIS的船舶；AIS能够提供船舶身份、位置、航向和航速等信息。通过对雷达与AIS数据进行关联融合，可以充分发挥两类感知手段的互补优势，实现对海上目标更加连续、完整的跟踪。然而，面对海量、多源、连续的船舶轨迹数据，如何从中实时、准确地识别具有

特定时空模式的走私行为，仍是提升海防主动预警和精准执法能力所面临的重要技术问题。

近年来，基于深度学习的船舶行为分析逐渐成为相关领域的研究热点。现有研究多以AIS轨迹数据为主要数据源，利用LSTM等时序模型对船舶航向、航速、位置等动态特征进行建模，并应用于异常行为检测、轨迹预测和行为分类等任务，取得了一定成果[1-5]。然而，现有方法仍存在局限：一方面，多数研究主要依赖AIS数据，对雷达与AIS融合轨迹中所包含的目标连续性及非AIS目标信息利用不足；另一方面，针对特定走私行为的研究相对较少，尤其是对于“出发—越界—接驳—返航—上岸”这一具有明显地理语义和阶段性特征的行为模式，尚缺乏面向实际海防业务场景的专门时序建模方法。

海上走私具有较强的组织性和隐蔽性，其中一种典型作案方式是不法人员驾驶机动性较强的船艇从本方海岸线出发，驶往境外或目标水域进行接驳装货，随后返回本方海域，并通过高速冲滩、靠岸等方式完成货物转运。该行为在轨迹层面通常表现出较为明显的阶段性和空间关联性。因此，本文针对上述特定船舶走私行为，以雷达与AIS融合形成的目标轨迹为数据基础，结合海域边界、离岸距离等地理语义信息，构建船舶轨迹时序特征体系，并采用LSTM网络对轨迹序列进行建模，实现对特定走私行为的自动识别。

2　走私行为识别模型

2.1　问题概述

基于雷达与AIS融合目标开展船舶行为分析，是提升海防监测覆盖范围和智能分析能力的重要技术手段。然而，将融合轨迹应用于特定走私行为识别时，仍面临数据质量、样本分布和实时处理等方面的问题。

（1）融合轨迹存在数据质量和格式不统一问题。由于雷达和AIS数据来源、更新频率及数据质量存在差异，融合后的目标轨迹可能存在缺失点、异常点以及采样间隔不一致等问题[6-8]。同时，不同船舶轨迹的持续时间、轨迹点数量和采样间隔存在明显差异，无法直接作为LSTM等时序模型的统一输入，需要通过轨迹筛选、异常值处理、插值和序列标准化等方式进行预处理。

（2）走私行为样本存在严重类别不平衡问题。在实际海域监控场景中，绝大多数船舶处于正常航行状态，而真正发生走私行为的目标数量较少，因此正常轨迹与走私轨迹之间存在显著的数量差异。若直接采用原始样本进行模型训练，模型容易倾向于多数类，导致对少数类走私行为的识别能力下降，尤其容易出现走私行为漏检问题。

（3）特定走私行为具有明显的阶段性和地理语义特征。仅依赖经纬度、航速等基础运动特征，难以充分表达船舶是否跨越海域边界、是否进入目标水域以及是否存在冲滩靠岸意图。因此，需要对船舶运动状态与海域地理语义进行联合建模，使模型能够从连续轨迹中学习“出发—越界—接驳—返航—上岸”的完整行为模式。

针对上述问题，本文构建了一套面向船舶走私行为识别的完整处理方法。首先，通过数据预处理统一融合轨迹的数据格式和时序结构；其次，针对走私行为样本不足问题，采用轨迹增广和正样本拆分策略扩充训练数据；最后，构建引入类别权重的多层LSTM识别模型[9]，使模型更加关注少数类走私行为，并在保证识别精度的同时满足实时推理需求。

2.2　融合目标轨迹

2.2.1　融合目标定义

融合目标是指将雷达跟踪目标与AIS目标进行关联，在信息融合后形成的统一海上目标。AIS能够提供较为丰富的船舶身份和属性信息，包括MMSI、位置、航向、航速等动态信息，以及船长、船型等静态信息[10]；雷达跟踪目标主要提供位置、航向、航速等动态信息，具有更新频率高、连续跟踪能力强等特点。

雷达与AIS数据融合后，可以充分发挥两类传感数据的互补优势：AIS能够提供船舶身份及属性信息，雷达则能够弥补AIS关闭或信号缺失情况下的目标探测能力，从而提高海上目标的持续跟踪能力。特别是在多部雷达协同覆盖的场景下，通过雷达之间的交叉覆盖和接力跟踪，即使目标未发送AIS信号，也能够利用雷达跟踪信息维持目标轨迹的连续性。

2.2.2　轨迹点特征选取

针对特定走私行为，综合考虑轨迹数据可获得性、船舶运动状态及地理语义信息，从融合轨迹中选取6项核心特征，构成单个轨迹点的特征向量，包括经度、纬度、航速、融合目标类型、是否跨越海上分界线以及离岸距离。

（1）经度、纬度和航速：经度和纬度用于描述船舶的空间位置，航速用于反映船舶的运动状态，是刻画船舶轨迹时空变化规律的基础特征。三者能够共同反映船舶在不同时间节点上的位置变化和运动状态，为模型学习船舶的连续运动模式提供基础。

（2）融合目标类型：本文未将船长、船型等静态船舶属性作为模型输入特征。一方面，部分融合目标不存在AIS子源，无法提供完整的静态属性信息；另一方面，实际走私船舶可能主动关闭AIS，其目标信息主要来源于雷达。因此，融合目标是否包含AIS子源能够在一定程度上反映目标的信息来源及其可识别状态，可作为辅助判别特征输入模型。

（3）是否跨越海上分界线：特定走私模式包含“越界—返航”过程，船舶是否跨越预设海上分界线是判断该行为模式的重要地理语义特征。将边界跨越状态引

入模型，有助于识别船舶进入目标水域并再次返回本方海域的行为过程。

（4）离岸距离：用于描述船舶与本方海岸线之间的空间关系，可在一定程度上反映船舶接近岸线以及冲滩靠岸的行为趋势。对于特定走私模式，离岸距离与“上岸”阶段具有较强关联，因此将其作为重要的地理语义特征。

2.3 数据预处理方法

为满足LSTM模型对输入数据格式和数据质量的要求，同时适应实际海防场景下的实时识别需求，需要对原始雷达与AIS融合目标轨迹进行标准化预处理[11]。数据预处理流程如图1所示，主要包括轨迹筛选、异常数据处理、轨迹长度标准化和地理语义计算4个步骤。

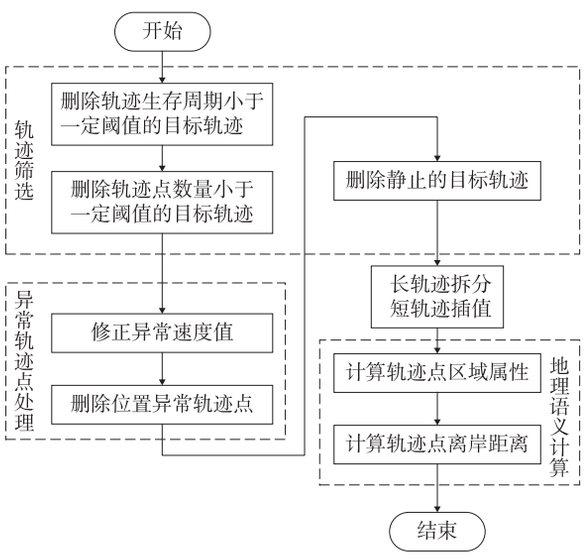

图1 数据预处理流程

首先，通过轨迹筛选剔除生存周期过短、轨迹点数量过少及被判定为静止状态的目标轨迹，从原始数据中去除主要由雷达海杂波等因素形成的虚假目标，同时减少对船舶行为识别贡献有限的短轨迹片段。

其次，对轨迹中的异常数据进行处理。针对航速突变、位置异常等问题，采用中值滤波等方法检测并修正异常点，在尽可能保留真实运动特征的基础上降低随机噪声对轨迹序列的影响，从而保证轨迹数据具有合理的时空连续性和物理可解释性。

再次，对轨迹长度进行标准化。由于不同目标的轨迹点数量存在差异，为保证模型输入序列长度一致，对于长度较长的轨迹采用滑动窗口方法进行切分，将完整轨迹划分为若干固定长度的子序列；对于长度不足的轨迹，则采用线性插值方法进行补充，将其统一扩展至预设的轨迹点数量。插值过程中，根据相邻原始轨迹点的位置和运动状态计算插值点的经纬度、航速等属性，从而降低轨迹长度差异对模型训练造成的影响。

最后，计算轨迹点的地理语义信息。为增强模型对走私行为空间模式的识别能力，结合船舶轨迹与海域地理环境，为每个轨迹点赋予相应的地理上下文信息。参考船舶行为语义建模方法[12]，计算轨迹点的“是否跨越海上分界线”状态和“离岸距离”，具体计算过程如图2所示。上述两项特征分别从边界跨越和岸线接近两个维度描述船舶运动状态，与本文定义的“出发—越界—接驳—返航—上岸”行为模式具有较强关联性。

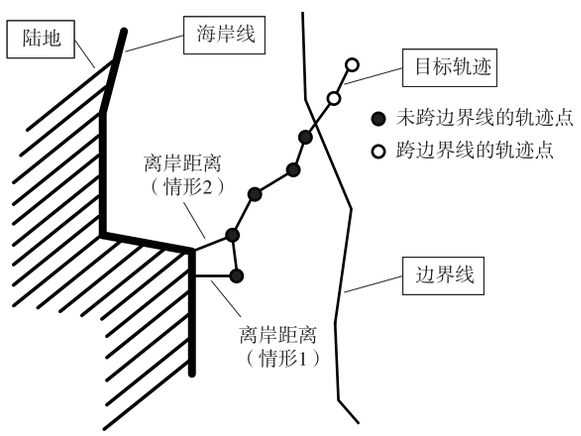

图2 轨迹地理语义信息计算

经过上述处理后，原始雷达与AIS多源异构轨迹被转换为长度统一、质量可靠且包含地理语义信息的标准化时序数据，为后续模型训练和实时推理提供规范的数据输入。

2.4 数据增广方法

2.4.1 走私行为轨迹特征定义

走私行为识别模式来源于某沿海边防派出所的实际执法案例。通过分析涉案船舶的历史走私轨迹，总结出该类行为具有较为明显的阶段性特征，可概括为“出发—越界—接驳—返航—上岸”5个关键阶段，具体表现如下：（1）从本方海岸线出发；（2）以较高航速跨越海域边界线，进入目标水域；（3）在目标水域内停留或低速机动（如盘旋、等待或接驳）；（4）再次以较高航速跨越海域边界线，返回本方海域；（5）以较高航速接近岸线并冲滩靠岸，完成货物装卸或转运。其中，高速和低速航速区间根据真实历史轨迹的航速分布进行确定。例如，可将30~60节作为高速航行区间，将0~2节作为低速或停留状态区间。

2.4.2 走私行为轨迹增广

实际海上监控场景中，走私行为发生频率远低于正常航行行为，导致走私轨迹正样本数量明显不足。为缓解类别不平衡问题，本文针对走私行为轨迹设计了组合式数据增广方法。

首先，根据前述5项关键行为特征构造符合特定走私行为模式的轨迹样本，使生成轨迹在运动状态和空间关系上满足“出发—越界—接驳—返航—上岸”的基本行为逻辑。在此基础上，为进一步提高样本的多样性和模型泛化能力，采用平移、旋转以及反序等几何变换对轨迹进行二次增广。其中，旋转操作分别以轨迹起点或

终点作为参考中心，从而改变轨迹的空间方向；平移操作用于改变轨迹的空间位置；反序操作用于增加轨迹序列的形态变化。完成几何变换后，进一步对各轨迹点的经纬度和航速施加一定范围内的随机微扰，使增广轨迹与原始轨迹保持基本行为模式一致，同时具有一定差异性。

2.4.3　正常行为轨迹增广

仅增加走私行为正样本仍可能导致模型对局部走私特征产生过度响应。例如，部分正常船舶可能存在单次跨越边界、短时间停留或高速靠岸等行为，但并不构成完整的走私行为。因此，为降低模型对局部行为特征的误判，本文进一步设计基于走私轨迹拆分的正常行为样本构造策略。

该策略将完整走私轨迹拆分为若干仅包含部分走私行为特征的轨迹片段，并将这些片段标记为正常行为样本以加入训练集。通过这种方式，使模型学习到完整行为链与局部行为片段之间的差异，从而避免仅依据单一越界、停留或靠岸行为进行走私判定。具体采用两种轨迹拆分方式，如图 3 所示。

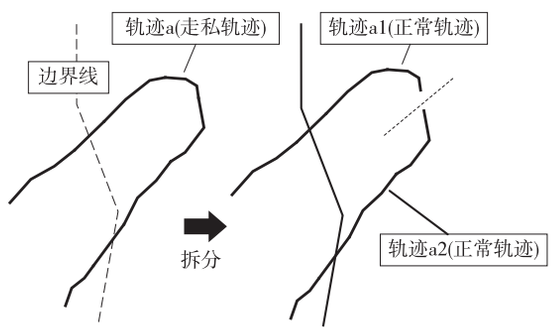

(a)等分拆分

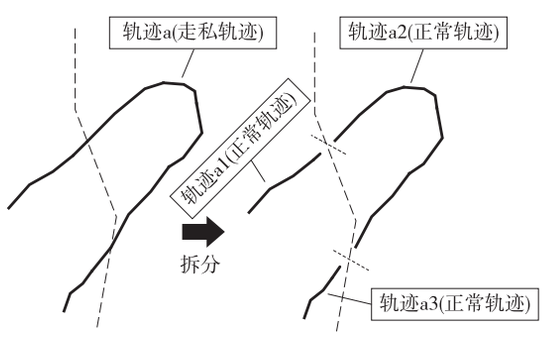

(b)边界拆分

图 3　异常轨迹拆分为正常轨迹

(1)等分拆分：以完整轨迹的中点为分界，将原始走私轨迹拆分为长度基本相等的两段，使每段轨迹仅保留完整行为链中的部分阶段。

(2)边界拆分：根据海域边界线及关键地理语义节点，在跨越边界的位置对完整走私轨迹进行切分，形成若干轨迹片段。

2.5　特定走私行为识别模型

本文以船舶走私行为的时序模式识别为核心任务，构建带类别权重损失函数的多层 LSTM 神经网络作为识别模型主体。模型输入为经过预处理和标准化后的船舶轨迹时序序列，每个时间步输入一个轨迹点的六维特征向量，即经度、纬度、航速、融合目标类型、是否跨越海上分界线以及离岸距离。其特征向量形式为[lon, lat, sog, ftype, boundary, dist]。模型总体结构如图 4 所示。

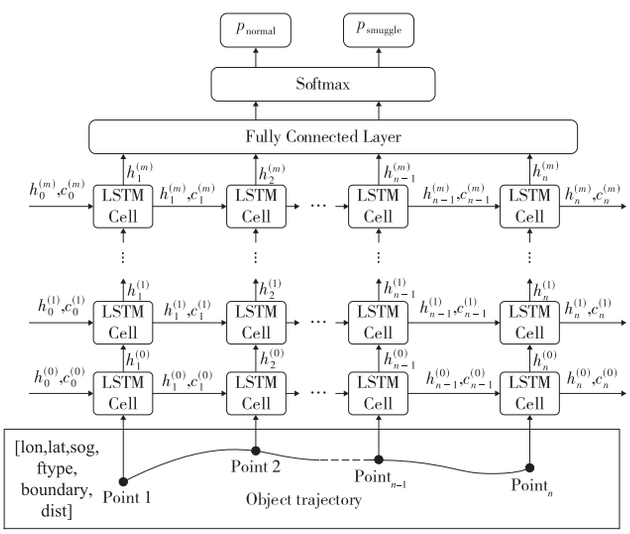

图 4　网络模型结构

在时间步 t，LSTM 网络接收当前轨迹点的特征向量，并结合上一时间步的隐藏状态和细胞状态更新当前状态。经过多层 LSTM 逐层提取后，模型能够从连续轨迹序列中学习船舶运动状态的长期时序依赖关系。将完整轨迹序列($\text{Point}_1, \text{Point}_2, \cdots, \text{Point}_n$)输入模型后，获得各时间步对应的隐藏状态序列($h_1^{(m)}, h_2^{(m)}, \cdots, h_n^{(m)}$)。

随后，通过全连接层对 LSTM 输出的时序隐藏状态进行特征映射，并在全连接层之前引入 Dropout 正则化[13]，以降低模型对训练样本的过度拟合风险。最终，通过 Softmax 层输出两个类别的预测概率，即轨迹属于正常行为的概率 p_{normal} 和属于特定走私行为的概率 p_{smuggle}。

针对走私行为样本数量远少于正常行为样本的问题，模型采用带类别权重的二元交叉熵损失函数，对不同类别设置不同的损失权重，并提高走私行为类别误分类所产生的惩罚，从而缓解类别不平衡对模型训练造成的影响。

带权重的二元交叉熵损失函数为：

$$L=-[\alpha y_0 \ln p_0+\beta y_1 \ln p_1] \tag{1}$$

式中，[y_0, y_1]表示船舶行为类别标签，其中[1,0]表示正常行为，[0,1]表示特定走私行为；p_0 与 p_1 分别表示模型预测为正常行为和走私行为的概率；α 和 β 分别表示正常行为和走私行为对应的类别权重。

与双向长短期记忆网络(Bi-LSTM)相比，本文采用的单向 LSTM 结构仅利用当前及历史轨迹信息进行状态更新，不依赖未来轨迹点，更符合海上目标实时识别场

景的因果约束。同时，单向结构具有参数量相对较少、计算开销较低等特点，有利于在保证识别精度的同时降低推理延迟，实现识别准确性与实时性的平衡。

3 走私行为实时识别实现方法

3.1 总体流程

船舶走私行为实时识别是一个涵盖数据处理、模型训练、模型部署和在线推理的完整工程化流程，可分为离线模型训练和在线实时识别两个阶段，如图5所示。

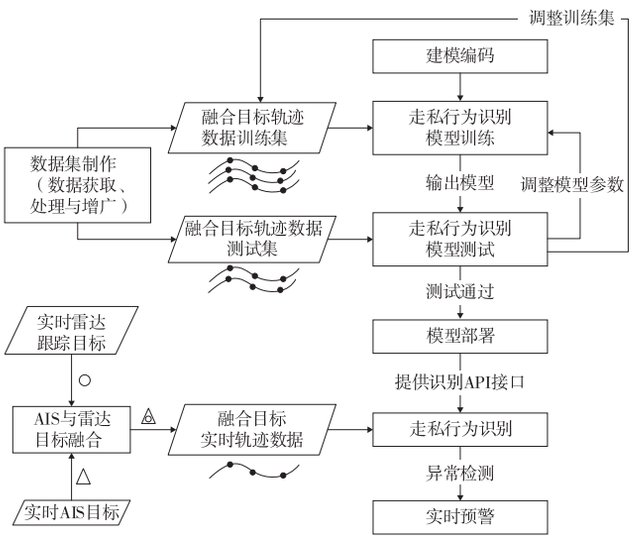

图5 走私行为实时识别方法总体流程

（1）离线模型训练阶段：主要完成训练数据构建、模型训练、性能评估和模型发布，为在线识别提供稳定的模型服务。其中，数据获取与处理是指从雷达与AIS系统获取原始融合目标轨迹，并按照第2.3节所述的数据预处理方法进行轨迹筛选、异常数据处理、长度标准化和地理语义计算，生成符合模型输入要求的标准化轨迹时序数据。数据集构建与增广是指将预处理后的轨迹划分为正常行为和走私行为两类。针对实际场景中走私行为样本数量少、类别分布严重不均衡的问题，采用第2.4节所述的轨迹增广方法扩充走私行为样本，并通过完整走私轨迹拆分构造具有部分走私特征的困难负样本，从而改善训练数据的类别分布和样本多样性。模型训练与发布是指基于构建的数据集训练带类别权重损失函数的多层LSTM模型。训练过程中重点关注走私行为的召回率，并结合验证集性能选择最优模型参数。模型达到预设性能要求后，对模型进行序列化并部署至业务服务器，为在线实时识别提供模型服务。

（2）在线实时识别阶段：利用离线训练完成的模型对实时监控数据流进行持续分析，并根据识别结果触发相应的风险预警。其中，模型部署与数据接入是指将训练完成的LSTM模型部署于业务服务器，实时接入雷达与AIS融合处理后的船舶目标轨迹数据。实时数据处理与识别是指对每个持续跟踪的船舶目标，随着新轨迹点不断产生，按照与离线训练阶段一致的预处理方法进行实时数据处理。当目标轨迹累计长度达到模型规定的输入长度后，将当前轨迹序列输入已部署的LSTM模型进行前向推理，获得该轨迹片段属于走私行为的预测概率。实时预警与反馈是指当模型输出的走私行为概率超过预设风险阈值时，系统判定该目标存在较高的走私行为风险，并立即触发预警，同时将目标位置、轨迹、识别结果及风险信息反馈至业务平台，为值守人员开展进一步研判和处置提供依据。

3.2 数据集制作与模型训练

3.2.1 数据集构建

本文使用的轨迹数据集由真实轨迹数据和人工合成轨迹数据两部分组成。真实轨迹数据采集自深圳某湾区连续4天的雷达与AIS融合目标数据，其中包含大量正常航行轨迹以及少量经人工核验的走私行为轨迹。由于真实走私行为在实际监控数据中的发生频率较低，正、负样本数量存在明显差异。为解决走私行为样本严重不足的问题，依据第2.4.1节定义的“出发—越界—接驳—返航—上岸”行为模式，人工构造符合该行为特征的走私轨迹样本。

所有真实轨迹和人工合成轨迹均按照第2.3节所述的数据预处理流程进行标准化处理，统一轨迹长度、数据格式及特征表示。随后，针对走私行为样本开展平移、旋转等几何变换增广，并通过完整走私轨迹拆分构造具有局部走私特征的正常行为样本，以改善类别分布并增加困难样本数量。

在数据集划分方面，按照7∶2∶1的比例将经过增广处理后的样本随机划分为训练集、验证集和独立测试集。其中，训练集用于模型参数学习，验证集用于模型选择和超参数调整，测试集仅用于最终性能评价，以降低模型评估过程中的数据泄露风险。

轨迹数据存储采用TDengine时序数据库。利用其面向时序数据的存储和查询能力，可按照目标标识及时间范围快速检索船舶轨迹数据，便于轨迹数据的批量读取、预处理和模型训练，为后续实时识别系统的数据管理提供支撑[14]。

3.2.2 模型训练配置与评估指标

模型采用第2.5节设计的带类别权重损失函数的多层LSTM网络，在PyTorch 2.0框架下完成训练。模型参数采用Adam优化器进行更新[15]，并结合学习率调度策略动态调整训练过程中的学习率[16]。损失函数采用式(1)所定义的加权二元交叉熵损失，通过提高走私行为类别的损失权重，使模型更加关注少数类样本，降低走私行为漏检的可能性。

训练过程中，以验证集上的损失和分类性能为模型选择依据，并保存验证阶段综合表现最优的模型参数。完成训练后，利用独立测试集对模型进行评价。

考虑到船舶走私行为识别更加关注少数类的检测能力，本文选取精确率（Precision）、召回率（Recall）、F1分数（F1-Score）和准确率（Accuracy）作为主要分类评价指标，同时统计单条轨迹的平均推理时间和模型参数量，用于评价模型的计算效率和工程部署能力。

3.3　模型部署与识别预警

为实现训练模型向实际业务系统的应用转化，本文构建了面向实时船舶轨迹分析的识别与预警系统。首先，将第 2.5 节所述的 LSTM 识别模型通过 TorchServe 进行封装，并以 RESTful API 服务形式提供模型推理接口。在此基础上，结合实时轨迹数据处理和风险判定模块，形成完整的在线识别流程。

系统整体架构可划分为数据接入与处理层、核心识别层、预警与决策层以及可视化展示层 4 个层次。其中，数据接入与处理层负责接收雷达和 AIS 原始数据，并完成目标关联、轨迹融合、异常处理、轨迹标准化以及地理语义特征计算，为模型提供统一格式的轨迹数据；核心识别层负责调用模型推理服务，将达到输入长度要求的轨迹序列发送至 LSTM 模型，并实时获取模型输出的正常行为和走私行为概率；预警与决策层根据模型输出结果进行风险判定；可视化展示层负责在指挥中心界面实时展示目标位置、运动轨迹、目标属性、识别类别及风险预警信息，使工作人员能够直观掌握目标的空间位置和行为状态。

4　实验

为验证本文提出的船舶走私行为实时识别方法的有效性，在深圳某湾区开展实验。该区域具有较为典型的海上船舶活动环境，并部署了雷达与 AIS 等监控设备，可为多源轨迹数据采集及模型验证提供实际数据基础。

4.1　数据集准备

实验数据主要来源于深圳某湾区连续 4 天的雷达与 AIS 融合目标轨迹。由于真实走私行为发生频率较低，原始数据中正常轨迹与走私轨迹数量存在严重不平衡。根据第 2.4.1 节定义的走私行为轨迹特征，人工构造 1 098 条走私行为轨迹，并结合真实数据中的两条走私行为轨迹，最终获得 1 100 条走私行为轨迹，具体如表 1 所列。

表 1　原始轨迹数据数量

轨迹获取方式	正常轨迹/条	走私轨迹/条
真实轨迹	135 237	2
人工合成	0	1 098
总计	135 237	1 100

所有原始轨迹经过轨迹筛选、异常数据处理、长度标准化及地理语义计算后，形成标准化轨迹序列。由于部分原始长轨迹经过滑动窗口切分，同时短轨迹经过标准化处理后形成新的固定长度序列，预处理后的轨迹数量与原始目标轨迹数量存在差异。最终得到正常轨迹 22 609 条、走私轨迹 1 100 条。在此基础上，采用第 2.4 节所述的综合增广策略进一步改善类别分布。一方面，对走私行为轨迹实施平移、旋转等几何变换，增加走私行为样本的空间形态多样性；另一方面，将完整走私轨迹拆分为仅包含部分行为特征的轨迹片段，并将其作为正常行为困难样本加入数据集，以提高模型对局部相似行为的区分能力。

增广后，最终获得正常轨迹 30 005 条、走私轨迹 12 074 条，如表 2 所列。

表 2　预处理与增广后轨迹数量

预处理后		增广后	
正常轨迹/条	走私轨迹/条	正常轨迹/条	走私轨迹/条
22 609	1 100	30 005	12 074

4.2　实验环境

实验在配置 Intel Xeon Gold 6326 处理器、64 GB 内存和 NVIDIA RTX A6000 显卡的服务器上进行。软件环境采用 Ubuntu Server 24.04 LTS 操作系统、Python 3.9 及 PyTorch 2.0 深度学习框架，并启用 CUDA 11.8 进行 GPU 加速。

4.3　实验结果与分析

本文对提出的带类别权重损失函数的多层 LSTM 模型（Proposed-LSTM）进行性能评价，并与 DNN 及 Bi-LSTM 等基线模型进行对比。同时，通过比较 Proposed-LSTM 在增广数据集和非增广数据集上的实验结果，分析轨迹数据增广策略对模型识别性能的影响。实验结果如表 3 所列。

表 3　模型性能对比结果

模型	精确率/%	召回率/%	F1 分数/%	准确率/%	推理时间/（ms/轨迹）	模型参数量
DNN（增广数据集）	99.78	99.95	99.86	99.92	0.001 3	197 762
Bi-LSTM（增广数据集）	99.78	99.95	99.86	99.92	0.012 1	166 402
Proposed-LSTM（增广数据集）	100	100	100	100	0.006 5	79 106
Proposed-LSTM（非增广数据集）	95.68	98.93	97.21	98.27	0.006 5	79 106

4.3.1 模型性能分析

由表3可知，在增广数据集上，Proposed-LSTM的精确率、召回率、F1分数和准确率均达到100%，整体分类性能优于DNN和Bi-LSTM。同时，Proposed-LSTM的模型参数量为79 106，明显低于DNN的197 762和Bi-LSTM的166 402，说明本文模型在保持较高识别性能的同时具有较小的模型规模。

DNN与Bi-LSTM在本实验中的分类指标相同，说明对于本文定义的特定走私行为模式，关键判别信息主要集中于轨迹的空间位置、航速变化以及边界跨越等特征，其判别模式具有较明显的结构化特征。同时，Bi-LSTM需要利用前向和后向时序信息，而实时识别场景下只能利用当前时刻及历史轨迹数据，无法获取未来轨迹点。因此，单向LSTM更加符合在线实时识别的因果约束。其参数规模较小，有利于降低模型部署和推理过程中的计算开销。

4.3.2 数据增广效果分析

在非增广数据集上，Proposed-LSTM的精确率、召回率、F1分数和准确率分别为95.68%，98.93%，97.21%和98.27%；采用综合增广策略后，上述指标均提升至100%。实验结果表明，数据增广能够有效改善原始轨迹数据中的类别不平衡问题，同时增加走私行为轨迹的空间形态和局部特征变化，使模型获得更加丰富的训练样本。

4.3.3 实时性分析

实验结果显示，Proposed-LSTM对单条标准化轨迹的平均推理时间为0.006 5 ms，在本文实验硬件环境下具有较低的计算开销。以典型岸基监视雷达2.5 s的数据更新周期为参考，单条轨迹推理时间远低于一次雷达数据更新间隔。因此，在合理的并发处理和系统资源配置条件下，模型具有较充足的计算时间裕量，可满足实时船舶轨迹识别的基本要求。

4.3.4 实验小结

综合实验结果可以看出，本文提出的Proposed-LSTM模型能够有效利用船舶轨迹中的时序信息和地理语义特征，对特定走私行为进行识别。在增广数据集上，模型取得了较高的分类性能，同时具有较小的参数规模和较低的推理开销。

5 结束语

针对海上特定船舶走私行为隐蔽性强、人工研判工作量大以及真实走私样本稀缺等问题，本文提出了一种基于雷达与AIS融合轨迹时序建模的船舶走私行为实时识别方法，并构建了从数据获取、轨迹预处理、样本增广、模型训练到在线识别和风险预警的完整处理流程。实验结果表明，该方法在测试数据上取得了较好的识别性能，同时具有较小的模型规模和较低的推理开销，能够满足特定船舶走私行为实时识别的基本需求，为智慧海防系统开展智能辅助研判和风险预警提供了技术参考。

参考文献：

[1] 高曙，刘甜甜，初秀民，等.船舶异常行为研究进展及发展趋势[J].中国航海，2017，40(2)：38-43.

[2] 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.

[3] 杨帆，何正伟，何帆.基于LSTM神经网络的船舶异常行为检测方法[J].武汉理工大学学报(交通科学与工程版)，2019，43(5)：886-892.

[4] 张铂函.基于深度学习的船舶轨迹异常检测[D].大连：大连海事大学，2021.

[5] 周慧君.顾及地理环境的船舶行为识别研究[J].测绘地理信息，2023，48(5)：117-122.

[6] 李贤志.海上走私犯罪案件侦查研究[D].武汉：中南财经政法大学，2021.

[7] 张涛.基于多源时空数据的船舶行为分析及异常检测研究[D].北京：北京邮电大学，2021.

[8] 李林.基于时空数据的海上船舶轨迹异常分析与系统实现[D].青岛：青岛科技大学，2022.

[9] ISMAIL F H，FORESTIER G，WEBER J，et al.Deep learning for time series classification：a review[J].Data Min Knowl Disc，2019(33)：917-963.

[10] 韩鹏.基于AIS数据的船舶轨迹预测方法研究[D].大连：大连海事大学，2022.

[11] 潘家财，姜青山，邵哲平.船舶会遇的时空数据挖掘算法及应用[J].中国航海，2018，41(4)：1-6.

[12] 文元桥，宋荣鑫，黄亮，等.船舶行为的语义建模与表达[J].哈尔滨工业大学学报，2021，53(8)：109-115.

[13] 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.

[14] TDengine官方文档.时序数据库基础[EB/OL].https：//docs.taosdata.com.

[15] KINGMA D P，JIMMY B.Adam：a method for stochastic optimization[J].arXiv：1412.6980V8，2014.

[16] 冯宇旭，李裕梅.深度学习优化器方法及学习率衰减方式综述[J].数据挖掘，2018，8(4)：186-200.

作者简介：

何四海(1988—)，硕士，工程师，研究方向：信息融合、人工智能、场面监视应用，E-mail：466594039@qq.com(通信作者)。

徐一智(1996—)，硕士，工程师，研究方向：人工智能、数据库技术。

敬彦民(1992—)，本科，工程师，研究方向：智慧海防。

白学智(1995—)，本科，工程师，研究方向：大数据技术、计算机视觉。

雷晨(1993—)，硕士，工程师，研究方向：大数据技术、数据挖掘。