

文章编号:1000-4653(2025)03-0157-09

基于多任务 Informer 模型的船舶轨迹 预测及行为识别研究

李世刚^{1,2}, 刘克中^{1,3,4}, 陈立家^{1,3,4}, 周乃祺^{1,3,4}, 周阳^{1,3,4}, 黄嘉韬^{1,3,4}

(1. 武汉理工大学 航运学院, 湖北 武汉 430063;

2. 交通运输部东海航海保障中心, 上海 200086;

3. 武汉理工大学 内河航运技术湖北省重点实验室, 湖北 武汉 430063;

4. 武汉理工大学 水路交通控制全国重点实验室, 湖北 武汉 430063)

摘要:为有效预判航行风险,并为船舶避碰、交通管理等决策提供重要依据,研究了一种基于多任务 Informer 模型的船舶轨迹预测及行为识别模型。该模型以 Informer 框架为基础,并引入多任务学习模式,通过设计多任务损失函数将船舶行为识别与轨迹预测并联训练,解决了 AIS 数据中船舶行为不准确无法作为模型输入的问题;在模型训练时,并设计基于同方差不确定性的损失函数自适应更新策略,自适应分配两个任务的损失权重。利用太仓航段水域中的真实 AIS 数据进行试验中多任务的 Informer 船舶轨迹预测模型在轨迹预测中的损失比 LSTM 和 Informer 模型分别降低了 40.2% 和 14.7%;在行为识别任务中多任务模型的识别准确率比 LSTM 和 Informer 模型分别提升了 11.7% 和 5.95%。表明了多任务模型能在有效提升船舶轨迹预测的性能的同时实现船舶对行为的准确识别。

关键词:轨迹预测;行为识别;AIS 数据;Informer 模型;多任务学习

中图分类号:U675.79

文献标志码:A

DOI:10.3969/j.issn.1000-4653.2025.03.019

Research on ship trajectory prediction and behavior recognition based on multi-task Informer model

LI Shigang^{1,2}, LIU Kezhong^{1,3,4}, CHEN Lijia^{1,3,4}, ZHOU Naiqi^{1,3,4}, ZHOU Yang^{1,3,4}, HUANG Jiatao^{1,3,4}

(1. School of Navigation, Wuhan University of Technology, Wuhan 430063, China;

2. Eastern Navigation Service Center, Maritime Safety Administration, People's Republic of China,

Shanghai 200086, China; 3. Hubei Key Laboratory of Inland Shipping Technology, Wuhan University

of Technology, Wuhan 430063, China; 4. National Key Laboratory of Waterway Traffic Control,

Wuhan University of Technology, Wuhan 430063, China)

Abstract: Ship trajectory prediction and behavior recognition can help effectively assess navigational risks and provide an important basis for decision-making in collision avoidance and traffic management. To improve the accuracy of ship trajectory prediction and behavior recognition, this paper studies a multi-task Informer model for simultaneous trajectory prediction and behavior recognition. Based on the Informer framework, the model incorporates a multi-task learning approach. It addresses the issue that inaccurate ship behavior records in AIS data cannot be directly used as model inputs by designing a multi-task loss function that jointly trains behavior recognition and trajectory prediction in parallel. During training, an adaptive updating strategy for the loss function-based on homoscedastic uncertainty-is designed to automatically allocate weights to the losses of the two tasks. Evaluated using real AIS data from the Taicang sector waters, the multi-task

收稿日期:2024-11-19

基金项目:国家自然科学基金重点项目(52031009)

通信作者:李世刚(1981—),男,博士研究生,研究方向为通航安全及保障技术。E-mail:13951933812@163.com

引用格式:李世刚,刘克中,陈立家,等.基于多任务 Informer 模型的船舶轨迹预测及行为识别研究[J].中国航海,2025,48(3):157-165.

LI S G, LIU K Z, CHEN L J, et al. Research on ship trajectory prediction and behavior recognition based on multi-task Informer model

[J]. Navigation of China, 2025, 48(3): 157-165. (in Chinese)

Informer model reduces trajectory prediction loss by 40.2% and 14.7% compared to LSTM and Informer models, respectively. In behavior recognition, the multi-task model improves accuracy by 11.7% and 5.95% compared to LSTM and Informer models, respectively. The results demonstrate that the multi-task model effectively enhances the performance of ship trajectory prediction while achieving accurate recognition of ship behavior.

Key words: trajectory prediction; behavioral discrimination; AIS data; Informer; Multi task learning

当前船舶轨迹预测与行为识别研究主要集中在模型设计与训练数据两大关键领域。模型设计方面,旨在开发和优化能够有效捕捉和预测复杂时序数据的算法;训练数据方面,重点在于处理和利用高质量的数据集以提高模型的预测能力和可靠性^[1]。

在轨迹预测模型的研究中,循环神经网络^[2] (Recurrent Neural Network, RNN)和长短期记忆网络^[3] (Long Short-term Memory Networks, LSTM)被广泛应用于船舶轨迹预测。一些学者还在这些模型中加入注意力机制模块,如赵程栋等^[4]提出的结合特征注意力机制的循环神经网络和 Bi-LSTM 模型,通过分配特征权重提高预测精度。然而,这种基于循环结构的模型存在长期依赖捕捉不足、信息不平衡及难以并行训练的问题^[5]。随着自注意力机制^[6]的出现,循环结构的限制被解除,自注意力模型在船舶轨迹预测中得到广泛研究^[7-8]。例如,徐瑞龙等^[9]利用 Transformer 搭建船舶轨迹预测模型,提升了轨迹预测的精度和效率,然而 Transformer 的自注意力机制仍然存在时间复杂度高的问题。

在训练数据方面,传统的轨迹预测方法往往忽略了船舶的航行意图,导致准确性和可信度不高。此外,AIS 数据的航行状态标签常因人为错误、设备故障或数据传输问题而不准确^[10],直接使用这些数据会降低预测结果的可信度和应用价值。近年来,Informer 模型因其高效的长序列预测能力在船舶轨迹预测中备受关注。例如,陈立家^[11]等提出的 C-Informer 模型通过因果卷积增强局部特征敏感性,使预测误差降低 28.6%;郭洋^[12]等提出融合滑动窗口与 Informer 的渔船预测方法 (Sliding window-based Informer Fishing vessel Prediction, SIFP),通过数据预处理提升渔船轨迹的噪声鲁棒性,MAE 较传统 LSTM 提高 0.18%。然而,现有方法多聚焦单一任务,未能结合行为识别与环境感知。因此需要采用多任务学习 (Multi-task Learning, MTL) 方式,让一个模型同时完成船舶轨迹预测与行为识别任务,通过让模型学习轨迹和行为之间的关系可以提高两种任务的性能和结果的可信度。杨红等^[13]利用多任务学习的思想,提出基于多任务学习的模型,并联 CNN 与 Bi-LSTM 网络联合优化轨迹预测与行为识别任务,但其未结合 Informer 的稀疏注意力机制,限制了长期依赖建模能力。

针对复杂水域中船舶行为的多样性及不同航行意图对轨迹的影响,本文提出了一种基于多任务学习的模型,将船舶轨迹预测与行为识别两个任务同时作为输出,使其能根据船舶历史轨迹变化自主学习轨迹与行为之间的关系,从而提升了预测准确性和可信度。同时,模型结合 Informer 模型的多头概率稀疏自注意力机制,降低了时间复杂度,提升了预测速度。此外,在损失计算时,通过设计等效距离的轨迹预测损失和损失函数权重自适应更新策略,进一步优化了模型性能。

1 基于 AIS 数据的船舶轨迹及行为分析

1.1 AIS 数据预处理

深度学习模型对船舶轨迹建模效果与 AIS 数据的质量密切相关。为了确保模型输入船舶轨迹数据准确,必须在轨迹预测前需要对原始 AIS 数据进行预处理。

1.1.1 AIS 数据清洗

AIS 数据在传输过程中可能会存在失真现象,以长江太仓区域的 AIS 数据为例,我们将船舶的纬度限定在 $31.45^{\circ}\text{N} \sim 31.63^{\circ}\text{N}$ 之间,研究其航速和经度的分布情况。不同特征分布箱型图如图 1 所示,其中图 1a 反映了在限定范围内船舶航速的异常值,图 1b 反映了在限定范围内船舶经度的异常值。





图 1 不同特征箱型图

Fig. 1 Box plots of different features

从图 1 中可以看出,在确定了纬度范围后,船舶的航速特征及经度特征都出现了明显的异常值。如图 1a 所示,在船舶的航速分布中,大部分航速低于 20 kn,但仍有个别航速超过 100 kn,构成明显的异常值。从图 1b 显示出经度中同样出现了远超出当前水域的异常值,这些异常数据严重影响了船舶轨迹分析的准确性。为了删除这些异常数据,需要通

过设置水域范围和航速阈值对异常点进行清洗。

船舶轨迹清洗前后效果对比如图 2 所示,其中图 2a 是清洗前的轨迹,其中图 2b 是清洗后的轨迹^[14]。



(a) 清洗前 (b) 清洗后

图 2 船舶轨迹清洗前后效果对比

Fig. 2 Box plots of different features

从图 2 中可以看出,清洗前的船舶轨迹中存在大量漂移点,很多轨迹点出现在太仓航段范围之外,甚至位于陆地上,使船舶轨迹并不连续。而清洗后的轨迹有效减少了轨迹中的异常点,可以清晰地显示该水域中船舶抛锚靠泊以及航行的轨迹特征。

1.1.2 AIS 数据重采样

AIS 数据获取的原始船舶轨迹序列存在周期间隔不一致的问题,无法直接用于机器学习模型。因此,本文采用线性插值的方法对原始 AIS 数据进行均匀采样。线性插值法是一种通过两个已知点来预测或估算中间点值的方法。其核心思想是假设两个已知数据点之间的变化是均匀的,从而可以通过直线连接这两点来预测中间任意位置的值。具体来说,若已知两个数据点 (x_0, y_0) 和 (x_2, y_2) ,那么在这两点之间任一点 x_1 上的值 y_1 可以通过以下线性插值得出,插值原理如图 3 所示。




图 3 线性插值原理

Fig. 3 Linear interpolation schematic

插值计算如式(1)所示。

$$y = y_0 + \frac{(y_1 - y_0)}{(x_1 - x_0)}(x - x_0) \quad (1)$$

1.2 船舶轨迹预测与船舶行为识别相关性分析

AIS 系统通过报文形式进行数据传输,目前定义了 27 种报文类型,以便不同类型的站点报告自身位置和进行短信交流及信道管理。AIS 报文有明码和暗码两种。暗码主要以 VHF 数据链报文(VHF Data-link Message, VDM)和 VHF 数据链本船报告

(VHF Data-link Own vessel's report, VDO) 形式存在,前者代表收到的其他船舶数据,后者为本船自身广播信息。报文以 16 进制校验码结束,确保数据的准确性。暗码报文格式支持系统所需信息的存储和传输。将报文数据信息每一位转换为 6 bit 二进制码,按照对应的 bit 为进行解析就可以根据解析出来相对应的数字判断出具体的航行状态。

船舶的航行状态直接影响其轨迹,我们选择了 AIS 数据中的四种航行状态为例:动力在航(Under way using engine)、靠泊(Moored)、锚泊(At anchor)、操纵能力受到限制(Restricted maneuverability)。动力在航状态表示船舶正常航行,轨迹连续且动态变化,是轨迹预测的核心挑战;靠泊/锚泊表示船舶静止状态,轨迹固定但需识别停泊意图,验证模型对静态行为的分类能力;操纵能力受限为特殊状态,轨迹可能异常或受限,涉及安全预警,是行为识别的关键场景。这四类状态组合可全面测试模型在典型状态任务上的综合性能。

在动力在航状态下,船舶使用引擎航行,反映了船舶在目的地之间的直接移动,此时船舶的速度相对稳定且较高。在靠泊状态下,船舶通常通过缆绳或链条固定在码头、泊位或其他固定设施上,船舶位置非常稳定,几乎不发生变化。在锚泊状态下,船舶的经纬度变化较小,但随着风流的变化,船舶会在一定范围内移动,通常表现为在较小区域内的多个环形或椭圆形轨迹。在操纵能力受到限制状态下,船舶通常由于某些特定的操作条件(如船舶大小、正在进行的作业、设备故障或其他操作限制)而无法自由改变航向或速度。例如,在进行管道铺设时,施工船会在特定施工区域内移动,速度较慢,经常需要调整航向以适应施工需求,或在施工点几乎保持不动。图 4 展示了这四种不同的船舶轨迹。



(a) 操作受限

(b) 靠泊

(c) 动力在航

(d) 锚泊

图 4 四种航行状态船舶轨迹

Fig. 4 Trajectories of ships in four navigation states

因此,分析船舶轨迹的规律时,需要考虑船舶的航行状态,因为这些状态显著影响船舶的行为和轨迹。

2 船舶轨迹预测及行为识别模型构建

在深度学习模型训练过程中,由于 AIS 数据中航行状态标签易受人为错误、设备故障或数据传输问题的影响,直接使用这些标签作为输入可能会降低预测结果的可信度。因此,考虑到船舶行为与轨迹变化之间的内在关联,采用多任务学习方法进行模型训练能够有效提升预测性能。

2.1 模型整体框架设计

多任务学习通过共享模型底层参数,同时为每个任务设计独立的顶层参数,有效挖掘了任务之间的关联性。在船舶轨迹预测和行为识别任务中,两个任务使用相同的输入——历史轨迹序列。轨迹预测任务基于历史轨迹信息预测未来位置,而行为识别任务则根据运动特征进行分类。尽管输出结果不同,但由于任务间的相关性,可以通过共享隐层特征表示来提升模型性能,同时在输出端为每个任务单独设计输出层。因此,基于多任务学习的船舶轨迹预测及行为识别模型框架如图 5 所示。




图 5 多任务模型框架

Fig. 5 Multi-task modeling framework

在联合训练船舶轨迹预测和行为识别这两种同时包含分类和回归任务的模型时,输出被分为两部分。一部分通过 Softmax 层实现船舶行为的分类,另一部分通过全连接层预测下一时刻的轨迹。由于每个任务都配置了特定的损失函数,在多任务学习环境中需要整合这些损失。直接将这此损失相加可能会导致某一任务的优化过度,特别是在不同任务的损失尺度差异显著时。这种尺度差异可能使总损失受到某单一任务损失的过度影响,从而削弱其他任务的优化效果。为了平衡不同任务的贡献,需要对损失进行加权求和,最终组合损失的公式为

$$L_{\text{full}} = \lambda_1 L_1 + \lambda_2 L_2 \quad (2)$$

式(2)中, L_{full} 为模型的整体损失; L_1 和 L_2 分别为轨

迹预测和行为识别任务的损失; λ_1 和 λ_2 为损失权重。

2.2 多任务学习模型方案设计

2.2.1 共享层模型设计

Informer 是基于注意力机制的监督学习模型,由编码器和解码器构成。编码器捕获输入序列的长期依赖性,解码器实现序列预测。模型结构如图 6 所示。编码器输入长序列历史数据,解码器输入短序列和预测步长相等的零值组合。

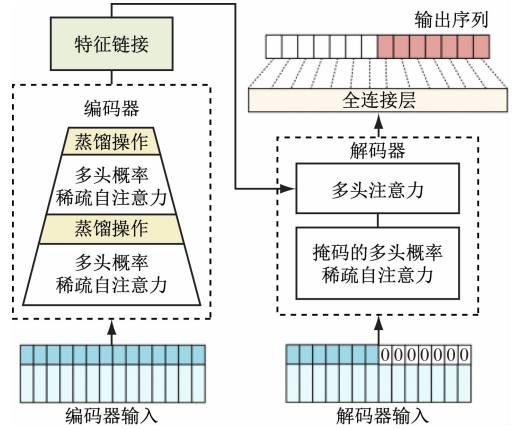


Fig. 6 Informer model

该模型将经过位置编码的数据 $(\mathbf{X}) = [x_1 x_2 \dots x_t]$ 作为输入,其中 t 为时间序列长度。在编码器中,模型将输入转化为向量列表,通过依赖路径进入注意力层,利用点积操作与训练得到的三个矩阵生成查询向量 (\mathbf{Q})、键向量 (\mathbf{K})、值向量 (\mathbf{V})。

步骤 1: 获取三个诠释向量,计算如式(3)所示:

$$\begin{cases} \mathbf{Q} = \mathbf{X} \cdot \mathbf{W}_Q \\ \mathbf{K} = \mathbf{X} \cdot \mathbf{W}_K \\ \mathbf{V} = \mathbf{X} \cdot \mathbf{W}_V \end{cases} \quad (3)$$

式(3)中, \mathbf{X} 为输入的轨迹序列, $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V$ 为三个对应的训练矩阵。

步骤 2: 为每个样本打分,传统的自注意力机制使用二次时间复杂度的点积进行注意力计算,并且需要考虑到 \mathbf{Q}, \mathbf{K} 的空间复杂度,这成为提高预测能力的主要障碍。根据 Informer 自注意力机制的概率分布具有潜在的稀疏性的特点,在模型中使用概率稀疏自注意力 (ProbSparse self-attention) 代替了传统的自注意力机制:

$$\text{Attention} = \text{Softmax}\left(\frac{\bar{\mathbf{Q}} \cdot \mathbf{K}}{\sqrt{D(\mathbf{K})}} \cdot \mathbf{V}\right) \quad (4)$$

式(4)中: $\bar{\mathbf{Q}}$ 由 \mathbf{Q} 依概率稀疏化后得到;Softmax 为激活函数; $D(\mathbf{K})$ 为 \mathbf{K} 向量的维度。

Informer 模型通过编码器—解码器架构实现高效长序列预测。编码器采用概率稀疏自注意力机制,基于 KL 散度筛选高贡献度查询点,将注意力计算复杂度从降低,并通过逐层蒸馏模块(卷积+池化+残差连接)将序列长度减半,渐进式提取关键特征。解码器以因果掩码稀疏自注意力处理目标序列,随后通过编码器—解码器交叉注意力融合蒸馏后的特征,最终经全连接层输出预测结果。该设计通过稀疏化计算与特征压缩的协同优化,兼顾了长序列建模的效率与精度^[15]。

2.2.2 损失函数设计

对于轨迹预测和行为识别组合的多任务模型,模型的输出分为两个部分。一部分是进行船舶轨迹预测;另一部分是船舶行为分类。这两部分通过各自的损失函数进行控制,最终加权合并形成整体损失,然后通过反向传播优化模型性能。

1) 船舶轨迹预测任务损失函数

当进行船舶轨迹预测时,经度和纬度的变化并非等效,因为地球的曲率导致经度和纬度所代表的距离不同。因此,简单地将经纬度转换为线性距离可能会引入预测误差,尤其是在远离赤道的地区。为了克服这一问题,改进损失函数时需要考虑地球表面的曲率。本文使用基于误差距离的损失函数,替代传统的均方误差损失,通过误差距离更准确地反映预测船舶位置的误差,进而衡量模型在船舶位置预测中的表现,并指导模型的训练和优化过程。由于地球是一个不规则球体,无法用简单的欧氏距离计算地球上两点间的距离,因此使用 Haversine 公式作为损失函数,计算地球上两个轨迹点之间的距离,计算如式(5)所示^[16]。

$$\begin{cases} h = \text{havsine}(\varphi_j - \varphi_i) + \\ \quad \cos \varphi_j \cos \varphi_i \text{havsine}(\lambda_j - \lambda_i) \\ \text{havsine}(\theta) = \sin^2\left(\frac{\theta}{2}\right) \\ L_{\text{haversine}} = 2R \arcsin \sqrt{h} \end{cases} \quad (5)$$

式(5)中: R 为地球半径,取值为 6 371 km; φ_i 和 φ_j 分别为 i 和 j 点的纬度,单位($^{\circ}\text{N}$); λ_i 和 λ_j 分别为 i 和 j 点的经度,单位($^{\circ}\text{E}$), $L_{\text{haversine}}$ 即为 i 和 j 两点之间的距离损失。

2) 船舶行为分类任务损失函数

船舶行为分类任务则采用交叉熵损失函数(Cross Entropy loss)进行优化,交叉熵损失函数可以衡量模型预测的类别概率分布与实际的类别分布之间的不一致性,计算如式(6)所示。

$$L_{\text{cross}} = - \sum_{c=1}^C y_c \ln(p_c) \quad (6)$$

式(6)中: L_{cross} 为交叉熵损失值, C 代表类别的总数。 y_c 代表样本的标签表示,如果观察值属于类别 c ,则为 1,否则为 0。 p_c 表示模型预测观察值属于类别的概率。

2.2.3 基于同方差不确定性的损失函数自适应更新策略

由于多任务学习模型的效果依赖于损失函数权重的配置,这些权重决定了模型在处理轨迹预测与行为识别任务时的关注重点。因此,需要结合贝叶斯模型中的不确定性建模理论,设计多任务学习模型的损失权重更新策略。

贝叶斯理论将深度学习中的不确定性分为两类:一类是由于模型对数据缺乏足够认知所导致的认知不确定性,另一类是由数据中的固有噪声引起的偶然不确定性。在偶然不确定性中,多任务模型中的每个任务分配一个适应性权重,依据任务的难度和不确定性来调整损失函数,从而使模型在处理各个任务时更加平衡。基于同方差不确定性的多任务损失函数:

$$L_{\text{full}} = \frac{1}{2\sigma_1^2} L_{\text{haversine}} + \frac{1}{2\sigma_2^2} L_{\text{cross}} + \ln \sigma_1 \sigma_2 \quad (7)$$

式(7)中, σ_1 和 σ_2 两任务的噪声,损失函数自适应更新即为最小化该损失函数的过程,根据数据自适应地学习损失 $L_{\text{haversine}}$ 和 L_{cross} 的相对权重,将噪声 σ 作为可优化参数,在训练过程中不断更新,从而使多任务网络自适应地学习损失的相对权重,使任务不确定性大的权重减小,不确定性小的权重增大,如随着 σ_1 的增大,任务一的权重就会降低,但噪声增加太多会忽略数据,因而目标函数最后一项 $\ln \sigma_1 \sigma_2$ 是噪声正则化器。

3 试验分析

3.1 试验数据来源

太仓水域环境如图 7 所示。

从图 7 中可以看出,太仓航段位于长江与海岸线交汇处,是重要的航运枢纽,承担着国内外贸易与长江内河的交通任务。由于该区域船只数量众多、交通流密度大,因此被视为典型的繁忙水域。此外,该水域水文气象复杂,东南风和潮汐作用下常出现高浪和急流。加之太仓区港口“南港北锚”的独特布局,船舶需要频繁横越航道,进一步增加了交通环境的复杂性,并提升了船舶碰撞的风险。太仓水域复杂的交通状况对水上应急救援、交通秩序维持及




图7 太仓水域环境

Fig.7 Taicang Watershed Environment

港口监管等方面提出了极大挑战。在这样的环境中开展轨迹预测与行为识别相关算法的研究,能够有效验证算法的实用性与有效性。

因此,试验选取了太仓航段部分水域的真实AIS数据进行模型的训练与验证。数据中包含8000组各类船舶的轨迹,其中在航、靠泊、锚泊和操纵能力受到限制的船舶轨迹数量各占四分之一。每组轨迹由40个轨迹点组成,其中前25个轨迹点作为输入的历史轨迹,后15个轨迹点为船舶预测轨迹的真实值。其中,70%的数据作为训练集,用于模型的学习,提供了数据特征和标签的映射关系,帮助模型优化参数;20%的数据作为验证集,用于模型的超参数调优和性能评估,确保模型在未见数据上的泛化能力,防止过拟合,10%的数据作为测试集,用于最终评估模型的真实性能,模拟实际应用中的表现,确保模型在未知数据上的可靠性。

3.2 试验环境及评价指标

该试验在Python3.8下训练,采用Adam优化器,学习率设置为 $1e-3$,批大小为64,Dropout层参数设为0.1,模型的输入为25个历史轨迹序列,输出为预测的15个船舶轨迹序列和船舶行为的分类;编码层层数为2,解码层层数为2,注意力头数为4,嵌入层维度为256。

船舶轨迹预测的评价指标为预测船舶轨迹点与船舶真实轨迹点之间的距离误差,可通过式(4)计算得出。

船舶行为识别的评价指标包括准确率(A)、精确率(P)、召回率(R)和 F_1 分数(F_1 Score)。

准确率表示分类正确的样本占总样本个数的比例:

$$A = \frac{P_T + N_T}{P_T + P_F + N_T + N_F} \quad (8)$$

精确率为正确预测的正例数占预测为正例总数的比例,是评估模型准确识别正例的能力的指标:

$$P = \frac{P_T}{P_T + P_F} \quad (9)$$

召回率为正确预测的正例数占实际正例总数的比例,是评估模型捕获正例能力的指标:

$$R = \frac{P_T}{P_T + N_F} \quad (10)$$

F_1 分数为精确率和召回率的调和平均数,提供了一个综合考虑二者的性能指标:

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (11)$$

式(8)~(11)中, P_T 为正确预测的正例数量,表示模型正确识别出的目标行为模式的实例数。 P_F 为错误预测的正例数量, N_F 表示模型错误地将非目标行为模式的实例识别为目标行为模式。

3.3 试验效果分析

为了验证多任务学习Informer模型的有效性,本试验将其与传统的单任务学习模型进行对比试验。单任务模型分别独立训练轨迹预测和行为识别任务,二者之间没有共享的知识和特征表示。通过对比多任务模型与单任务模型完成轨迹预测与行为识别的准确度,检验多任务学习模型在联合训练下能否有效提高两个任务的性能。

3.3.1 轨迹预测效果分析

将多任务的Informer模型再测试集中输出的轨迹预测结果与单独完成轨迹预测的LSTM、Informer模型在测试集中的表现分别对比。

1) 不同模型的轨迹预测效果对比。三个模型的输入、输出步长均相同,其中Informer模型的参数设置与本文模型一致,模型仅输出预测的船舶轨迹,并采用距离损失作为损失函数。LSTM模型同样采用距离损失,并以递归方式预测未来时间点的船舶轨迹,其隐藏层节点数为256,层数为2,学习率和Batch Size设置与本文模型一致。三个模型的最终轨迹预测损失值如表1所示,距离损失的迭代过程如图8所示。

表1 不同模型预测效果

Tab.1 Predictive effects of different models

模型	轨迹预测损失值/km
多任务的Informer模型	0.052
单任务的Informer模型	0.061
LSTM模型	0.087




图8 不同模型预测迭代情况

Fig. 8 Iterative plot of different model predictions

通过辅助任务(行为识别),模型能够在处理轨迹数据时获得额外的上下文信息,有助于其在预测时更精确地调整输出,以更好地符合实际航道情况。从表1中可以看出模型的具体提升效果。在模型方面,LSTM模型的最小损失值为0.087 km,而基于Informer的两种模型的最终损失值分别为0.052 km和0.061 km,损失分别降低了40.2%和14.7%。这反映了Informer模型相比传统LSTM能更有效地捕捉长期依赖关系,并通过自注意力机制在时间序列预测中实现更好的性能。在两种基于Informer的轨迹预测模型中,多任务模型的损失相比单任务模型降低了14.8%,表明多任务模型通过同时处理轨迹预测和船舶行为识别任务,显著提高了预测精度。

2) 预测效率对比。通过改变模型在轨迹预测时输出的预测轨迹步长(3~15步),分析Informer框架与依靠循环结构搭建的LSTM网络在预测效率上的差距,定义预测效率计算如式(12)所示。

$$s_f = \frac{t_{\text{LSTM}}}{t_i} \quad (12)$$

式(12)中, t_{LSTM} 和 t_i 分别为LSTM和本文模型预测一次船舶轨迹序列所需要的时间。不同预测步长下,预测效率变化曲线如图9所示。




图9 预测效率曲线

Fig. 9 Predicted efficiency comparison curves

从图9中可以看出,LSTM模型的预测时间是多任务Informer模型的2.77至3.84倍,且随着预测步长的增加,本文模型与LSTM模型的性能差距

逐渐扩大。这表明,LSTM网络通过循环方式实现未来轨迹的预测,随着预测步长的增加,预测时间也不断增加;而本文模型依赖于Informer的生成式解码器,一次性输出多步轨迹,因而在预测效率上优于LSTM模型。

3) 实时轨迹预测效果分析。模型在测试集中不同时间步长下的轨迹预测距离误差如图10所示。




图10 预测距离误差

Fig. 10 Predicted distance error

从图10中可以看出,在各个时间点的误差距离整体变化较小,预测船舶轨迹点的误差始终保持在0.05 km左右,表明轨迹预测的精度并未随着船舶运动时间和移动距离的增加而显著提高。这表明,模型的多步预测方法能够有效把握船舶在一定时间内的运动规律。

3.3.2 行为识别效果分析

将多任务的Informer模型在测试集中输出的行为识别结果与单独完成行为识别任务的LSTM、Informer模型在测试集中的表现对比。

为对比两种模型对不同船舶行为识别效果,本文使用混淆矩阵对试验结果进行分析。此时Informer模型和LSTM模型的输出均为船舶行为的分类,并以交叉熵损失作为损失函数。三种船舶行为识别模型的混淆矩阵对比如图11所示,其中图11a为本文多任务的Informer模型的行为识别混淆矩阵,图11b为只执行行为识别任务的Informer模型的混淆矩阵,图11c为LSTM模型在行为识别任务中的混淆矩阵。

本文所提出的模型针对四种行为的识别准确率均超越了其他两种对比模型。具体而言,三种模型的行为识别整体准确率依次为96.5%、90.55%及84.8%。相较于单任务的Informer模型,多任务模型在预测准确率上提升了5.95%;与LSTM模型相比,则提升了11.7%。这一结果表明,多任务模型在船舶行为复杂的水域中展现出更高的适用性,从而证实了该方法能显著提升船舶行为识别的准确性。




图 11 不同模型混淆矩阵对比

Fig. 11 Comparison of Confusion Matrices for Different Models

分析两种基于 Informer 模型的混淆矩阵可见,在识别直行船舶行为时,由于操纵能力受到限制的船舶(以下简称“受限船”)同样伴随着位置变化,二者之间易发生混淆。然而,多任务模型在船舶直行识别上的准确率相较于单任务模型提高了 6%。对于受限船的行为识别,由于其航速较低,容易与锚泊和靠泊船舶混淆。但多任务模型有效地减少了操纵能力受到限制与靠泊、直行之间的混淆现象,且对该行为的识别准确率提升了 6.9%。这进一步验证了多任务模型通过获取预测轨迹信息的补充,在行为识别任务中能有效降低单任务模型对特征不明显的

船舶行为的误检率,从而显著提高了对船舶操作受限状态检测的准确性。

三种模型的预测的精确率、召回率以及 F_1 分数如图 12 所示。从图 12 中可以看出在行为识别任务中,本文构建的模型在行为识别的 3 个评价指标上都优于其他两种模型,从衡量模型综合性能的 F_1 分数上可以看出,本文构建的多任务的 Informer 模型对抛锚和受限船行为识别能力提升最为明显,同样说明了对于这两类易混淆的行为,多任务学习的策略,能够使模型能够更精确地提升实际应用效果。




图 12 不同模型船舶行为识别效果对比

Fig. 12 Comparison of Ship Behavior Recognition Effect of Different Models

4 结束语

为提高繁忙水域中海事智能监管领域中轨迹预测与行为识别模型的效果,本文基于太仓水域的真实 AIS 数据,分析了船舶运动轨迹的特点,提出了一种多任务的 Informer 船舶轨迹预测模型。该模型以 Informer 为基础框架,利用其降低网络模型的时间复杂度,同时引入多任务学习模式。通过设计轨迹预测与行为识别任务的损失函数,将两者联合训练。此外,本文还提出了基于同方差不确定性的损失权重自适应更新方法,使得模型在一个深度学习框架下能够同时完成轨迹预测与行为识别任务。相关试验表明,针对复杂水域环境,多任务 Informer 模型能

够通过学习轨迹预测与行为识别任务之间的相关信息,提升两个任务的效果。与单任务模型相比,轨迹预测损失降低了 14.7%,行为识别准确率提升了 5.95%,验证了本文模型在提升两个任务性能方面的有效性。

本文模型通过高精度轨迹预测与行为意图识别的同步输出,系统可更准确地提前预判潜在会遇冲突,为船舶自动驾驶系统或船员提供融合时空特征的避让策略建议。同时基于船舶行为的深度挖掘,为动态航路规划、拥堵疏导等管理决策提供前瞻性预判依据。

未来的研究可以考虑更复杂的船舶交通情况,并选择更多的船舶行为作为轨迹预测的辅助任务,

进一步提升模型的泛化能力。

参 考 文 献

- [1] 甄荣, 邵哲平, 潘家财. 基于 AIS 数据的船舶行为特征挖掘与预测: 研究进展与展望[J]. 地球信息科学学报, 2021, 23(12): 2111-2127.
ZHEN R, SHAO Z P, PAN J C. Advance in character mining and prediction of ship behavior based on AIS data [J]. Journal of Geo-information Science, 2021, 23 (12): 2111-2127. (in Chinese)
- [2] 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. (in Chinese)
- [3] 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(增刊2): 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(Suppl. 2): 126-131. (in Chinese)
- [4] 赵程栋, 庄继晖, 程晓鸣, 等. 基于特征注意力机制的 RNN-Bi-LSTM 船舶航迹预测[J]. 广东海洋大学学报, 2022, 42(5): 102-109.
ZHAO C D, ZHUANG J H, CHENG X M, et al. Ship trajectory prediction of RNN-Bi-LSTM based on characteristic attention mechanism [J]. Journal of Guangdong Ocean University, 2022, 42(5): 102-109. (in Chinese)
- [5] 刘成勇, 乔文杰, 陈蜀喆, 等. 基于 LSTM 与注意力机制的船舶航迹预测模型研究[J]. 中国航海, 2021, 44(4): 94-100.
LIU C Y, QIAO W J, CHEN S Z, et al. On ship track prediction with LSTM and attention mechanism [J]. Navigation of China, 2021, 44 (4): 94-100. (in Chinese)
- [6] NIU Z, ZHONG G, YU H. A review on the attention mechanism of deep learning [J]. Neurocomputing, 2021, 452: 48-62.
- [7] ZHANG X, FU X, XIAO Z, et al. Vessel trajectory prediction in maritime transportation: Current approaches and beyond [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23 (11): 19980-19998.
- [8] LI H, JIAO H, YANG Z. Ship trajectory prediction based on machine learning and deep learning: A systematic review and methods analysis[J]. Engineering Applications of Artificial Intelligence, 2023, 126: 107062.
- [9] 徐瑞龙, 祁云嵩, 石琳. 基于 Transformer 模型和 Kalman 滤波预测船舶航迹[J]. 计算机应用与软件, 2021, 38(5): 106-111.
XU R L, QI Y S, SHI L. Predicting ship tracks based on transformer model and Kalman filtering [J]. Computer Applications and Software, 2021, 38 (5): 106-111. (in Chinese)
- [10] 张黎翔, 朱怡安, 陆伟, 等. 基于 AIS 数据的船舶航迹修复方法研究[J]. 西北工业大学学报, 2021, 39(1): 119-125.
ZHANG L X, ZHU Y A, LU W, et al. Research on ship trajectory repair method based on AIS data [J]. Journal of Northwestern Polytechnical University, 2021, 39(1): 119-125. (in Chinese)
- [11] 陈立家, 周乃祺, 李世刚, 等. 基于 C-Informer 模型的船舶航迹预测方法[J]. 交通信息与安全, 2023, 41(6): 51-60.
CHEN L J, ZHOU N Q, LI S G, et al. Ship trajectory prediction method based on C-Informer [J]. Journal of Transport Information and Safety, 2023, 41(6): 51-60. (in Chinese)
- [12] 郭洋, 李想, 李响凝. 融合滑动窗口和 Informer 网络的渔船航迹预测方法[J]. 计算机技术与发展, 2025, 35(1): 148-153.
GUO Y, LI X, LI X N, et al. Fishing vessel trajectory prediction method integrating sliding window and Informer network [J]. Computer Technology and Development, 2025, 35(1): 148-153. (in Chinese)
- [13] 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)
- [14] 李业, 任鸿翔, 张政. 基于 Encoder-Decoder LSTM 的船舶航迹预测方法[J]. 海洋测绘, 2024, 44(1): 21-25.
LI Y, REN H X, ZHANG Z. Ship trajectory prediction method based on Encoder-Decoder LSTM [J]. Hydrographic Surveying and Charting, 2024, 44 (1): 21-25. (in Chinese)
- [15] ZHOU H, ZHANG S, PENG J, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C]. The 35th AAAI Conference on Artificial Intelligence. Vancouver: AAAI, 2021.
- [16] 钱倍奇, 陈谦, 张政伟, 等. 基于异构数据特征级融合的多任务暂态稳定评估[J]. 电力系统自动化, 2023, 47(9): 118-128.
QIAN B Q, CHEN Q, ZHANG Z W, et al. Multi-task transient stability assessment based on feature-level fusion of heterogeneous data[J]. Automation of Electric Power Systems, 2023, 47(9): 118-128. (in Chinese)