

基于 ABiM-Ship 的智能船舶轨迹预测

刘云翔, 牛洪阔*, 朱建林

(上海应用技术大学 智能技术学部, 上海 201418)

摘要: [目的]为提升船舶轨迹预测的精度与稳健性, [方法]提出 ABiM-Ship 网络, 以双向选择性状态空间模型对历史航迹编码, 利用注意力机制显式对齐航迹与航向、航速, 设计 2 阶段端到端联合预测, 先回归未来航迹与航向、航速, 再以残差校正, 引入 Huber 损失以约束物理误差并稳定收敛。[结果]试验表明: 该网络在短、中、长程上的平均预测误差等指标表现均显著优于传统主流基线, 预测精确度较高, 且表征方法, 2 阶段结构与 Huber 损失均贡献显著增益。[结论]研究成果在保持线性时序复杂度的同时实现对轨迹、航向与航速的显式耦合与粗到细预测, 具备良好的可复现与可推广性, 可为复杂海域高密度交通的智能导航与协同调度提供可推广的技术路径与工程参考。

关键词: 船舶自动识别系统; 注意力机制; 选择性结构状态空间模型; 细化预测; 轨迹预测

中图分类号: U675.7 **文献标志码:** A **【DOI】** 10.13788/j.cnki.cbgc.2026.03.03

Intelligent Ship Trajectory Prediction Based on ABiM-Ship

LIU Yunxiang, NIU Hongkuo*, ZHU Jianlin

(Faculty of Intelligence Technology, Shanghai Institute of Technology, Shanghai 201418, China)

Abstract: [Purpose] To improve the accuracy and robustness of ship trajectory prediction, [Method] an ABiM-Ship network that encodes historical trajectories using a bidirectional selective state space model is proposed. An attention mechanism to explicitly align trajectories with heading and speed is utilized. A two-stage end-to-end joint prediction is designed, first regressing future trajectories, heading, and speed, then refining them using residual correction. Huber loss is introduced to constrain physical errors and stabilize convergence. [Result] The experimental results show that this network outperforms traditional mainstream baselines in terms of average prediction error over short, medium, and long distances, achieving high prediction accuracy. The representation method, two-stage structure, and Huber loss all contribute significantly to performance gains. [Conclusion] The research findings achieve explicit coupling and coarse-to-fine prediction for trajectories, heading, and speed while maintaining linear temporal complexity. They have good reproducibility and scalability, providing a generalizable technical path and engineering reference for intelligent navigation and collaborative scheduling in complex maritime areas with high traffic density.

Key words: automatic identification system; attention mechanism; selective state space model; prediction refine; trajectory prediction

0 引言

海上运输是全球最重要的运输方式之一。随着

智能航运与自动化技术的发展, 航运网络与航线组织正在迈向高密度与智能化。对高度智能化的船舶

收稿日期: 2025-08-21; 修回日期: 2025-10-18

基金项目: 国家自然科学基金委员会资助项目 (61976140)

作者简介: 刘云翔 (1964—), 男, 博士、教授、硕士研究生导师。研究方向: 智能检测及控制技术、智能决策支持系统、智能信息处理、人工智能等。

通信作者: 牛洪阔 (2000—), 男, 硕士研究生。研究方向: 智能船舶航行轨迹预测、智能车辆行进轨迹预测、人工智能、机器学习等。E-mail: 236142132@mail.sit.edu.cn

而言，如何在复杂多变的海洋环境中保障航行安全至关重要，而轨迹规划与轨迹预测因此成为关键能力^[1]。近年来，基于自动识别系统（Automatic Identification System, AIS）的海事交通监测与统计逐渐成为行业趋势^[2-3]。AIS数据能够提供船舶的历史轨迹、航向与航速等关键信息，为智能船舶等轨迹预测提供了丰富的数据基础。然而，受复杂航道与环境干扰、AIS噪声及不规则采样等因素影响，船舶轨迹预测不仅需要捕获长时依赖与多尺度动态，还需要显式建模航向、航速与位置信号之间的运动学耦合，这对模型的特征与泛化提出了更高的要求。

传统的统计与概率方法广泛应用于船舶轨迹的时间序列预测，包括卡尔曼滤波^[4]、高斯过程回归^[5]、马尔可夫链^[6]与灰色预测模型^[7]等。这类方法具备一定的可解释性与计算效率，但在处理非线性、长时依赖以及噪声敏感的场景时往往受限。随着深度学习的发展，基于反向传播（Back Propagation, BP）训练的前馈神经网络多层感知机（Multilayer Perceptron, MLP）、循环神经网络（Recurrent Neural Network, RNN）、门控循环单元（Gated Recurrent Unit, GRU）与长短期记忆网络（Long Short-Term Memory, LSTM）等方法逐步成为主流。LSTM在预测稳定性与精度方面相较其他神经网络表现突出^[8]，而GRU由于结构更为简洁，具备更高的计算效率^[9]。

为进一步提升模型精度，一些工作探索了多模块融合与层次化表征。刘珊珊等^[10]采用卷积神经网络（Convolutional Neural Network, CNN）提取时序潜在特征，并结合双向长短期记忆模型（Bi-Long Short Term Memory, Bi-LSTM）对历史信息进行记忆建模；赵程栋等^[11]在此基础上以RNN替代CNN，并引入特征注意力机制与Bi-LSTM融合，在预测精度上取得改进。这些方法在一定程度上增强了时序特征抽取与关键特征选择能力，但由于循环架构的并行性与记忆机制限制，仍可能出现远距依赖建模不足、关键信息衰减与训练稳定性受限等问题。

近年来在自然语言处理领域表现突出的注意力机制（Attention）与选择性状态空间序列模型（Selective State Space Models）为时序建模带来了新的范式^[12-13]。前者通过全局依赖建模显著增强了长程关系的捕获能力；后者以线性时序复杂度与强序列建模能力兼备而广受关注。基于该方向，XUE等^[14]通过改进的Transformer强化潜在特征编码，显著提升了预测精度；ZHANG等^[15]将Mamba引入轨迹预测以刻画预测代理的时序潜特征，并在长序列建模方面取得领先表现。然而，已有海事场景的研究多在坐标序列上直接建模，较少在网络结构层面显式融合航向、航速等运动学变量与空间位置信号之间的耦合关系，同时也少见将“由粗到细”的2

阶段端到端联合训练及残差精修机制引入航迹预测流程，导致模型在训练和推理过程中均缺乏修正能力。此外，在船舶轨迹预测领域中，对于损失函数的应用大多停留在分类损失或回归损失的独立应用上，这种方法虽然使得模型收敛速度更可观，但忽略了概率差距和物理距离相互之间的约束关系。据此，本文提出ABiM-Ship网络，并将系统阐述：以双向选择性状态空间模型（BiMamba）对历史航迹进行编码，并通过注意力机制对历史航迹特征与航向、航速特征显式对齐的表征方法；端到端“由粗到细”的2阶段残差预测机制；联合分类交叉熵与基于物理距离的Huber损失的训练目标；在公开AIS数据上对比试验与消融验证方法的有效性与可推广性。上述缺口共同构成了本文方法的主要动机与切入点。

1 基于ABiM-Ship的智能船舶轨迹预测模型

1.1 注意力机制

注意力机制是一种面向序列数据的自适应加权建模方法^[16]。与需要逐步传播信息的循环网络不同，注意力通过计算任意2个位置之间的相似性，直接建立长程依赖，从而缓解长距离信息衰减与梯度传播困难，并具备良好的并行计算特性。其计算流程见图1，图1中：输入特征经3组线性映射得到查询（Query, q ）、键（Key, k ）与值（Value, v ）。 q 表示需要的信息， k 表示当前拥有的信息， v 表示被聚合的内容。随后根据 q 与各 k 的匹配程度计算注意力权重，并用这些权重对应的 v 做加权求和得到输出。




图1 注意力机制计算流程示意图

Fig. 1 Schematic Diagram of the Calculation Process of Attention Mechanism

1.2 选择状态空间序列模型

作为选择性状态空间模型的新范式，Mamba通过线形递推的“隐状态”在线形时间 $O(T)$ 内扫描整段序列，天然适合长序列建模与并行加速；与循环网络相比，其缓解了长依赖衰减与梯度不稳问题；与注意力相比，其计算与显存随长度线性增长，适合AIS这类长序列、噪声大、采样不齐的数据。

如图2(a)所示，单向扫描只能从一个方向汇聚特

征。对于航迹序列, 早期速度/航向的慢变趋势与临近时刻的急变事件都可能影响未来运动, 主要包含卷积层(Conv)和状态空间模型(State Space Models,

SSM)。BiMamba采用向前与向后2条对称分支, 分别从2个方向扫描已观测到的历史序列, 在不泄漏未来信息的前提下, 获得更完整的上下文, 见图2(b)。

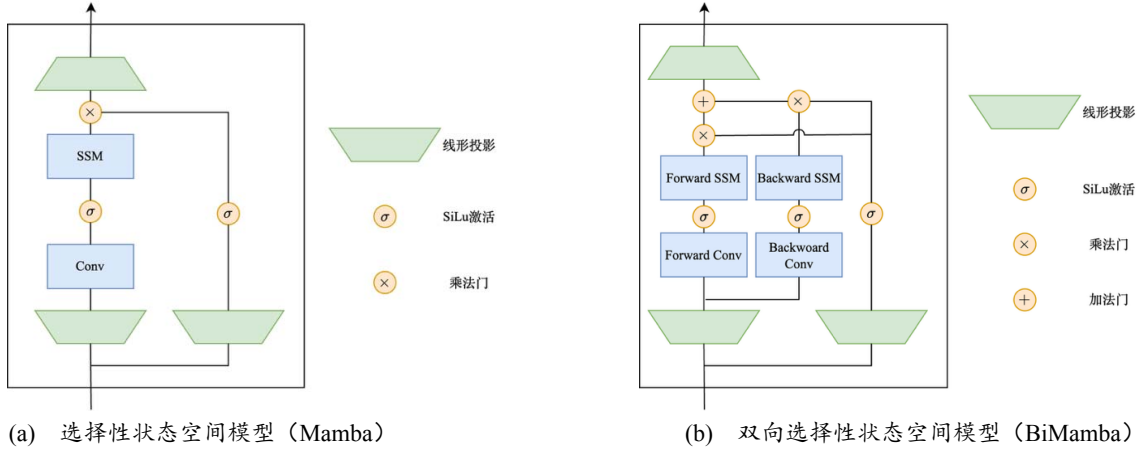


图2 选择性状态空间模型与其衍生模型

Fig. 2 Selective State Space Model and its Derivative Model

2 融合注意力机制的双向选择性状态空间模型

2.1 数据预处理

2.1.1 观测定义与重采样

本文沿用TrAISformer^[17]和GeoTrackNet^[18]的数据表示, 历史数据中的经纬度坐标、航向和航速分别离散为独热向量并经属性嵌入后拼接为高维稀疏向量。即, 给定AIS观测数据 $\{x_t\}_{1:T}=[p_t, m_t, s_t, h_t]_{1:T}$ 。其中, p 、 m 、 s 和 h 分别对应船舶的纬度、经度、对地航速和对地航向。首先对原始轨迹按固定时间步长 Δt 重采样, 采用线性插值获得等间隔序列 $x_{1:T}$ 。同时执行异常值剔除、重复记录去除及环状平滑。其中, 对地航向的环状平滑, 将航行角度统一至 $[-\pi, \pi]$ 区间内。

该数据表示方法以结构化方式处理异构数据与多峰分布, 并与分类式损失匹配, 可提升对转向、变速等多模态行为的建模能力。与之相比, 连续值归一化虽避免量化, 但需要网络在潜在特征层面隐式量化与模态划分, 对AIS噪声与不规则采样的鲁棒性较弱^[19]。

2.1.2 观离散化表示与嵌入

为缓解不同量纲的异质性, 将 p 、 m 、 s 和 h 分别离散到 N_p 、 N_m 、 N_s 和 N_h 个单元, 得到4个独热向量 1_{p-t} 、 1_{m-t} 、 1_{s-t} 、 1_{h-t} 。将四者拼接为

$$h_t = [1_{p-t}, 1_{m-t}, 1_{s-t}, 1_{h-t}] \quad (1)$$

随后为每个属性单独学习嵌入矩阵, 将独热向量投影到高维实值向量并拼接得到 e_t :

$$\begin{cases} e_{p-t} = \text{Emb}_p(H_t[0]) \\ e_{m-t} = \text{Emb}_m(H_t[1]) \\ e_{s-t} = \text{Emb}_s(H_t[2]) \\ e_{h-t} = \text{Emb}_h(H_t[3]) \end{cases} \quad (2)$$

式中: Emb为嵌入函数; H_t 映射为高维度向量。

$$e_t = \text{Concat}(e_{p-t}, e_{m-t}, e_{s-t}, e_{h-t}) \quad (3)$$

该方法可在嵌入高维空间中更好地表达多模态运动分布, 同时对异常点的鲁棒性更强, 提升模型的代表能力。

2.2 模型结构

基于LSTM和GRU的传统预测方法虽然解决了循环神经网络的梯度传播不稳定的问题, 但在交互依赖和时序依赖建模上有较强的局限性, 且缺乏并行性和长期记忆能力。相较之下, Transformer的核心注意力机制和Mamba则在全局建模能力、训练稳定性和并行性等方面均优于传统时序数据预测模型。其中, Mamba在保持与Transformer相同的性能的情况下拥有更强大的长时依赖的建模能力和更高的计算效率, 但由于结构类似于LSTM, Mamba在异构数据的编码能力上不如Transformer。故本文结合自注意力机制、交叉注意力机制和Mamba的各自优势构建模型(见图3): 应用Mamba模型当中表现优秀的BiMamba模型对输入序列 e_t 进行建模, 获得输入的历史轨迹的时序特征; 分别对BiMamba的表征和输入数据 e_t 中的历史航速 e_{s-t} 、历史航向 e_{h-t} 使用自注

意力机制编码得到各自潜在特征；再通过交叉注意力机制对以上潜在特征进行编码，为 e_t 与 e_{s-t} 和 e_{h-t} 的深层特征进行建模得到其交互潜在特征；最后，对该交互潜在特征通过多层感知机（MLP）进行解码得到预测坐标分布。

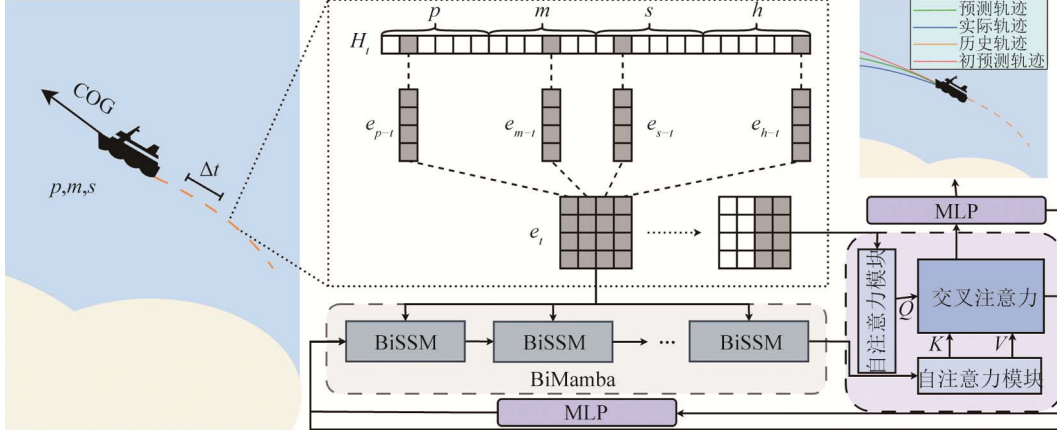


图3 ABiM-Ship 模型结构图

Fig. 3 ABiM-Ship Model Structure Diagram

2.3 模型原理

如图3所示，ABiM-Ship主要包含BiMamba模块、自注意力模块和交叉注意力模块3个核心部分。

2.3.1 双向选择性状态空间模型

常规Mamba模块见图2(a)，主要包含卷积层（Conv）和状态空间模型（State Space Models, SSM）：

$$\begin{cases} \tilde{X} = \text{Norm}(X) \\ X \in \mathbb{R}^{T \times d} \end{cases} \quad (4)$$

$$\begin{cases} G = \sigma(\tilde{X}W_g) \\ W_g \in \mathbb{R}^{d \times d} \end{cases} \quad (5)$$

$$\begin{cases} U = \tilde{X}W_u \\ W_u \in \mathbb{R}^{d \times d} \end{cases} \quad (6)$$

$$\begin{cases} \hat{U} = \phi[U + \text{Conv}(U)] \\ \hat{U} = \{u_t\}_{t=1}^T \end{cases} \quad (7)$$

式(4)~式(7)中， X 为输入序列， T 为序列长度， U 为映射特征， d 为嵌入维度； $\text{Norm}(\cdot)$ 为归一化函数； σ 为门控激活； ϕ 为激活函数，本文均选择SiLu进行计算； W_g 和 W_u 均为可学习权重参数。

SSM中需要对每个时间步进行计算：

$$z_t = \bar{A}z_{t-1} + \bar{B}u_t \quad (8)$$

$$y_t = Cz_t \quad (9)$$

式(8)和式(9)中： z_t 为隐藏状态表征； \bar{A} 、 \bar{B} 和 C 均为时变参数矩阵； u_t 为 \hat{U} 按长度拆分后的输入；

此外，为了增强模型的纠错能力，第一次预测的解码结果作为初预测结果重新通过MLP编码输入至BiMamba模块并循环一次上述计算过程并重新解码获得精修阶段的预测残差结果，最终将2轮计算的结果相加作为模型最终预测结果。

y_t 为SSM的输出。

经过SSM后再通过门控 G 进行逐元素相乘并线性投影至原维度，最后加上残差：

$$\begin{cases} Y = (Y \odot G)W_o \\ Y = \{y_t\}_{t=1}^T \\ W_o \in \mathbb{R}^{T \times d} \end{cases} \quad (10)$$

$$\text{Mamba}(X) = X + \text{Dropout}(Y) \quad (11)$$

式(10)和式(11)中： \odot 为逐元素乘法； W_o 为可学习权重参数； $\text{Mamba}(\cdot)$ 函数表示上述Mamba模块计算流程。

对于BiMamba，其原理与Mamba相似，但增加一个SSM支路并将2个SSM支路分为前反馈和后反馈支路，最终获得2个输出 Y_{forward} 和 Y_{backward} ，最终将二者相加得到最后输出，见图2(b)。

$$\text{BiMamba}(X) = X + \text{Dropout}(Y_{\text{forward}} + Y_{\text{backward}}) \quad (12)$$

2.3.2 交叉注意力机制与自注意力机制

注意力机制计算流程见图1，对于输入长度为 n 嵌入维度为 d_1 和 d_2 的数据 $X_1 \in \mathbb{R}^{n \times d_1}$ ， $X_2 \in \mathbb{R}^{n \times d_2}$ ，分别映射到查询 q 、键 k 、值 v 序列。

$$\begin{cases} q = X_1W_q & W_q \in \mathbb{R}^{d_1 \times d_k} \\ k = v = X_2W_k & W_k \in \mathbb{R}^{d_2 \times d_k} \end{cases} \quad (13)$$

式中： W_q 和 W_k 为可学习的权重参数矩阵； d_k 为键值矩阵的维度。

将映射后的 q 、 k 和 v 按式(14)计算。

$$\text{Attention}(X_1, X_2) = \text{Softmax}\left(\frac{qk^T}{\sqrt{d_2}}\right)v \quad (14)$$

当 X_1 和 X_2 为2个不同的序列数据时, 则称为交叉注意力机制, 能够对 X_1 和 X_2 的交互进行建模; 当输入只有一个序列数据, 即 $X_1=X_2$ 时, 则称为自注意力机制, 能够对序列数据进行全局交互建模。

2.3.3 ABiM-Ship 模型

经过预处理的 e_t 输入BiMamba, 同时将 e_t 中的后2个序列 e_{s-t} 、 e_{h-t} 合并为 $[e_{s-t}, e_{h-t}]$ 输入自注意力模块:

$$E_t = e_t + \text{BiMamba}(e_t) \quad (15)$$

$$E'_t = [e_{s-t}, e_{h-t}] + \text{Attention}([e_{s-t}, e_{h-t}], [e_{s-t}, e_{h-t}]) \quad (16)$$

式(15)和式(16)中: E_t 为历史时序潜在特征; E'_t 为历史航向和航速的潜在特征。

为捕捉更深层的潜在特征, 将 E_t 和 E'_t 输入交叉注意力模块, 对其建立交互建模:

$$\tilde{E}_t = \text{Attention}(E'_t, E_t) \quad (17)$$

BiMamba分支提供长时依赖建模能力, 注意力机制提供多头、全局注意力, 二者互补。

对于给定的最终潜在特征 \tilde{E}_t , 通过2层MLP进行解码得到未来轨迹的概率分布:

$$\begin{cases} \pi_{\text{pro}-t} = \text{TwoLayerMLP}(\tilde{E}_t) \\ \pi_{\text{pro}-t} \in R^{N_p + N_m + N_s + N_h} \end{cases} \quad (18)$$

随后, 将 $\pi_{\text{pro}-t}$ 经由2层MLP使其非线性映射回嵌入空间, 作为精修阶段的锚点与 e_t 融合后重新经历上述特征提取过程得到概率分布修正值 $\pi_{\text{ref}-t} \in R^{N_p + N_m + N_s + N_h}$:

$$E_{r-t} = \text{TwoLayerMLP}(\pi_{\text{pro}-t}) + \tilde{E}_t \quad (19)$$

$$\tilde{E}_{r-t} = \text{Attention}[E'_t, E_{r-t} + \text{BiMamba}(E_{r-t})] \quad (20)$$

$$\pi_{\text{ref}-t} = \text{TwoLayerMLP}(\tilde{E}_{r-t}) \quad (21)$$

为了避免发生梯度冲突, 作为输入的 $\pi_{\text{pro}-t}$ 为停止梯度的副本, 不会反向影响初预测阶段参数。最终的概率分布 $\pi_t \in R^{N_p + N_m + N_s + N_h}$ 由初阶段预测结果 $\pi_{\text{pro}-t}$ 与残差精修阶段的预测修正结果 $\pi_{\text{ref}-t}$ 相加得到:

$$\pi_t = \pi_{\text{pro}-t} + \pi_{\text{ref}-t} \quad (22)$$

最后将得到的概率分布 $\pi_{\text{pro}-t}$ 经由Softmax函数转换为概率值, 再经过Multinomial函数一次采样结果得到轨迹真值:

$$\begin{cases} y_t = \text{Multinomial}[\text{Softmax}(\pi_t)] \\ y_t \in R^4 \end{cases} \quad (23)$$

式中: y_t 为输出的合并值, 按通道切分可得到4个输出, 即 $y_t = \{y_p, y_m, y_s, y_h\}$ 。

2.4 模型训练流程

模型训练流程见图4, 具体处理步骤如下:

1) 数据预处理与掩码。将获取的连续AIS数据归一化并离散化, 对填充时间步给出 $\{0, 1\}$ 掩码。

2) 去噪及划分。去除步骤1)中出现的异常值并划分数据集, 划分方法参考3.2试验数据集介绍。

3) 向前传播。将输入的数据映射到高维嵌入空间并输入模型, 通过BiMamba模块提取长时依赖特征, 再通过自注意力机制和交叉注意力机制提取历史数据与历史航向和历史航速等运动学变量和空间位置信号的深层交互特征。同时采用端到端联合的二次预测的推理和训练框架增强模型的修正能力以及在2阶段衔接时停止梯度解耦以消除跨阶段的梯度竞争。

4) 损失计算。分类损失采用交叉熵损失, 计算预测轨迹分布与实际轨迹分布的对数似然; 回归损失采用Huber损失, 计算预测轨迹与实际轨迹之间的物理距离。二者相加得到模型整体的损失函数:

$$L_{\text{ce}} = \sum_{t=1}^L CE(h_{T+t}, \tilde{E}_{T+t}) \quad (24)$$

$$L_{\text{reg1}} = \sum_{t=1}^L \text{Huber}(\hat{y}_{T+t}, y'_{T+t}) \quad (25)$$

$$L_{\text{reg2}} = \sum_{t=1}^L \text{Huber}(\hat{y}_{T+t}, y_{T+t}) \quad (26)$$

$$L = L_{\text{ce}} + \lambda_1 L_{\text{reg1}} + \lambda_2 L_{\text{reg2}} \quad (27)$$

式(24)~式(27)中: L 为预测长度; L_{ce} 为最终预测结果的分类损失; L_{reg1} 和 L_{reg2} 为2个预测阶段输出结果回归损失; $y'_t = \text{Multinomial}[\text{Softmax}(\pi_{\text{pro}-t})]$ 初预测阶段结果对应的轨迹真值; \hat{y}_t 为 t 时刻的实际轨迹经纬度和航向、航速数据; λ_1 和 λ_2 为用于平衡不同损失的占比的超参数。

由于Huber计算每步距离并取批量均值, CE 为对数似然, 二者在实现上进行了尺度对齐, 梯度幅度处于同量级, 故本文默认取等权(1, 1), 如表1所示, 以获得稳定训练与良好可复现性。

5) 模型验证与选模。以多步输出的平均位移误差(Average Displacement Error, ADE)作为选模指标, 每轮训练结束的模型参数评估并选出最优模型:

$$D_{\text{ADE}} = \frac{1}{L} \sum_{t=1}^L \sqrt{(y_{p-T+t} - \hat{y}_{p-T+t})^2 + (y_{m-T+t} - \hat{y}_{m-T+t})^2} \quad (28)$$

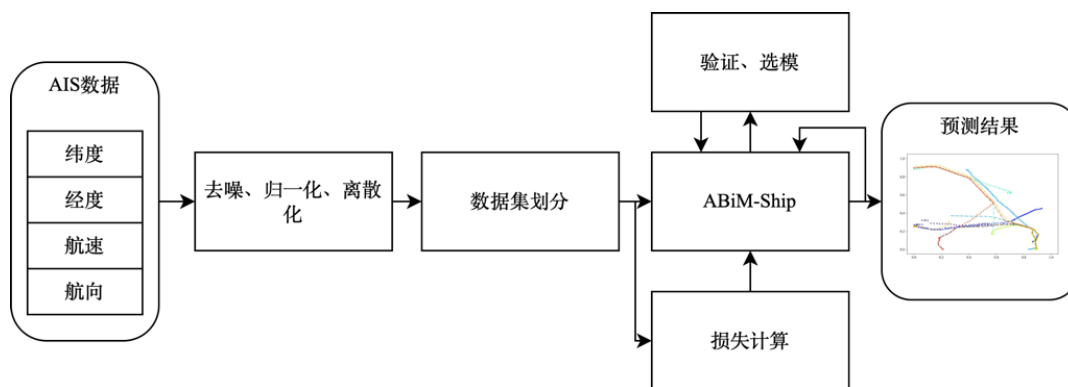


图 4 ABiM-Ship 模型训练流程图

Fig. 4 ABiM-Ship Model Training Flow Chart

表 1 模型参数设置表

Tab. 1 Model Parameter Setting

模型组成	参数设置
预测步长	6,12,18(1 h, 2 h, 3 h)
嵌入维度	128
BiMamba	$d_state=64; d_conv=4; expand=4;$ $activation="SiLu"; dropout=0.1$
注意力模块	$head=8; d_1=d_2=128; dropout=0.1$
优化器	AdamW
权重衰减	0.1
学习率	6×10^{-4}
损失函数	$\lambda_1=\lambda_2=1$
批大小	128

3 试验

3.1 试验环境

本文试验的硬件环境：中央处理器为英特尔至

强Silver 4314，内存128 GB，显卡为英伟达RTX A6000，显存48 GB。试验软件环境：Ubuntu 22.04.5 LTS, pytorch 2.1.0。

3.2 试验数据及模型参数

本文选取丹麦海事管理局（Danish Maritime Authority, DMA）的公开AIS数据集。原始数据覆盖2019年1月1日—2019年3月31日的货轮和油轮航迹，选取区域为北纬55.5°东经10.3°至北纬58.0°东经13.0°的矩形区间。未经处理的原始数据共 7.12×10^8 条AIS报文。

对于该数据集，本文按固定时间步 $\Delta t=10$ min对轨迹进行重采样以获得等间隔序列，并将2019年1月1日—2019年3月10日时间段内的数据划归为训练集，2019年3月11日—2019年3月20日时间段内的数据划为验证集，2019年3月21日—2019年3月31日的数据化为测试集。部分处理后的数据见表2。模型参数设置见表1。

表 2 部分数据试验数据（处理后）

Tab. 2 Partial Data Experimental Data (After Processing)

mmsi	时间戳	纬度 p	经度 m	航速 s	航向 h
209155000	0	0.086 490 800 00	0.863 617 407 000	0.353 333 333	0.155 555 556
	1	0.095 470 600 00	0.877 809 167 000	0.348 333 333	0.631 944 444
	...				
209332000	51	0.007 745 942 88	0.207 137 355 000	0.466 666 667	0.436 111 111
	0	0.453 851 200 00	0.931 112 963 000	0.270 000 000	0.613 055 556
	1	0.447 278 000 00	0.920 831 481 000	0.263 333 333	0.670 000 000
310132000	...				
	51	0.001 080 800 02	0.832 122 889 000	0.173 333 333	0.713 916 667
	0	0.933 670 800 00	0.000 192 592 593	0.593 333 333	0.263 611 111
...	1	0.932 664 514 00	0.034 192 857 100	0.586 666 667	0.224 365 079
	...				
	59	0.013 282 800 00	0.202 887 778 000	0.600 000 000	0.440 555 556

3.3 评价标准

本文采用haversine距离分别计算预测长度为1 h、2 h及3 h的预测轨迹坐标与实际坐标间的误差:

$$\begin{cases} d = 2R\arcsin\left[\sqrt{\sin^2\bar{\psi} + \cos\psi_1\cos\psi_2\sin^2\bar{\omega}}\right] \\ \bar{\psi} = (\psi_2 - \psi_1)/2 \\ \bar{\omega} = (\omega_2 - \omega_1)/2 \end{cases} \quad (29)$$

式中: ψ_1 和 ψ_2 分别为预测和实际坐标的纬度; ω_1 和 ω_2 分别为预测和实际坐标的经度。

3.4 试验对比

为验证提出的ABiM-Ship模型的有效性, 本文对比现有的船舶轨迹预测领域内主流的基础模型和组合模型: Conv、LSTM、LSTM-attn、TrAISformer^[17]和GeoTrackNet^[18]等见表3^[19], 并对ABiM-Ship的每个关键模块进行消融试验, 见表4。其中, 每个模型训练5次取误差平均值, 每次训练迭代50轮。

表3可知: ABiM-Ship在1 h误差达到0.45 n mile, 2 h误差达到0.87 n mile, 3 h误差达到1.42 n mile, 均超越以上6种基线模型, 代表着该模型在短、中、长期预测中均拥有领先性能。其中, 各模型某场景下

的示例见图5, 不同颜色对应不同的船只, 每个颜色对应的不同样式的线条。

如表4所示, 本文以只包含一个自注意力模块直接对输入 e_t 建模和只包含分类损失的TrAISformer^[17]为基准对比模型进行消融试验: 分别训练增加BiMamba不使用自注意力机制、增加BiMamba并使用自注意力机制、增加对SOG和COG二次建模的自注意力模块同时包含交叉注意力模块、增加回归损失及引入2阶段训练框架共6种模型, 每个模型训练3次并取平均值获得试验数据, 最优数据由黑体展示。

表 3 评价标准对比 (单位: n mile)

Tab. 3 Comparison of Evaluation Criteria (Unit: n mile)

模型	1 h 误差	2 h 误差	3 h 误差
LSTM	5.83	8.39	11.64
Conv	4.23	6.77	9.66
LSTM_attn	3.35	6.41	9.65
Clustering_LSTM_attn	0.78	1.93	3.66
GeoTrackNet	0.72	1.59	2.67
TrAISformer	0.48	0.94	1.64
ABiM-Ship	0.42	0.85	1.42

表 4 ABiM-Ship 消融对比

Tab. 4 ABiM-Ship Ablation Comparison

自注意力 (不含 SOG、COG)	自注意力 (含 SOG、COG)	交叉 注意力	BiMamba	Refine	分类 损失	回归 损失	1 h 误差/ n mile	2 h 误差/ n mile	3 h 误差/ n mile
√					√		0.48	0.94	1.64
			√		√		0.49	0.92	1.60
√			√		√		0.48	0.90	1.59
√	√		√		√		0.47	0.88	1.51
√	√	√	√		√		0.45	0.87	1.50
√	√	√	√		√	√	0.45	0.87	1.48
√	√	√	√	√	√	√	0.42	0.85	1.42

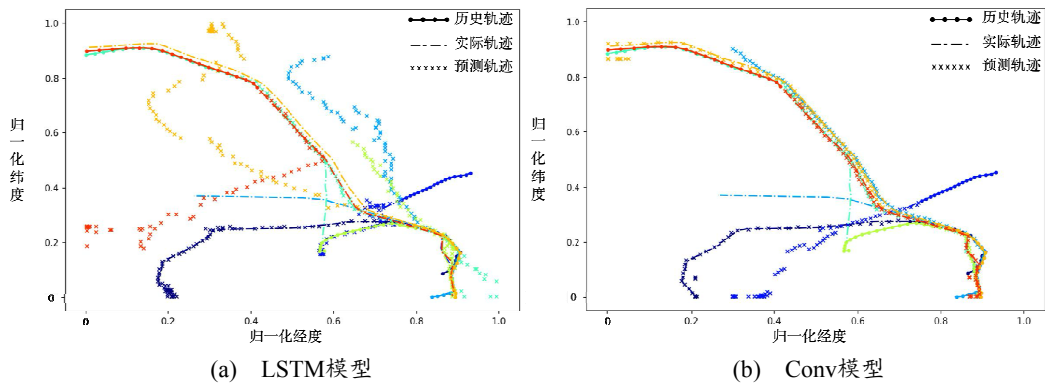


图 5 各模型在某场景下预测结果对比图

Fig. 5 Comparison of the Prediction Results of Each Model in a Scenario

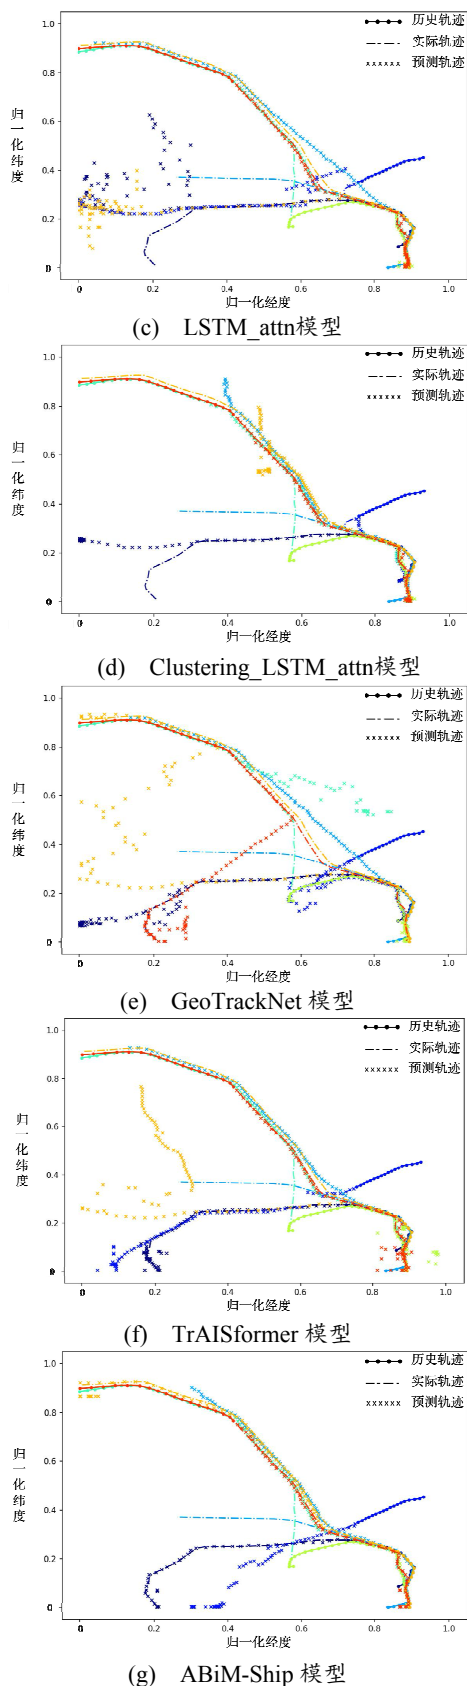


图5 各模型在某场景下预测结果对比图(续)

Fig. 5 Comparison of the Prediction Results of Each Model in a Scenario (Continued)

分析表4中数据可知：1) 仅将基准模型中的自注意力机制替换为BiMamba在中短程预测中获得的收益有限，但长程预测从1.64提升到了1.60，这也验证了Mamba类模型对长时依赖具有更强的建模能力；2) 当再增加一层自注意力模块对历史空间数据与SOG、COG等运动量进行建模时，短、中、长程的预测结果均有显著提升，分别从0.48、0.90和1.59降至0.45、0.87和1.50；3) 增加回归损失后，对长程预测能力有所提升，从1.50降至1.48，说明在预测长度较长时，回归损失对模型收敛的影响更大；4) 2阶段预测框架的引入对模型全预测长度的精确度提升显著，短、中和长程误差分别从0.45、0.87和1.48降至0.42、0.85和1.42。

4 结论

本文围绕AIS航迹的不规则采样与噪声背景，提出了面向智能船舶航行轨迹预测的ABiM-Ship框架：以BiMamba高效编码历史长程与局部动态，以交叉注意力显式对齐航迹表征以学习运动耦合，并通过2阶段预测框架在不增加推理开销级别的前提下显著降低多步误差。同时，本文还在损失层面对经纬度采用地理Huber约束，协同分类交叉熵以缩小整体预测误差。基于DMA公共数据集的系统试验与消融表明：ABiM-Ship在短、中、长程预测中均显著优于主流基线，相对提升约10%~13%。

尽管试验表明ABiM-Ship已取得良好效果，但仍存在若干限制，如本文试验主要覆盖特定ROI与船型，跨海域与多船类泛化仍须验证；本文以输出点估计为主，对多模态不确定性的表征仍有提升空间。故未来工作可从融合海图或航道约束与环境先验以提升可解释性与安全性、探索跨区域跨船型的自适应与在线学习方法、结合多目标交互与碰撞规避，试验预测-规划一体化闭环等研究方向展开。

参考文献：

- [1] 赵龙飞, 姜晓轶, 孙苗, 等. 面向海运统计的 AIS 大数据挖掘分析研究[J]. 海洋科学, 2021, 45(12): 55-64.
ZHAO L F, JIANG X Y, SUN M, et al. Research on AIS Big Data Mining and Analysis for Maritime Transport Statistics[J]. Marine Science, 2021, 45(12): 55-64.
- [2] 徐明强. 基于 AIS 数据的港口船舶运营效率评估系统[J]. 中国航海, 2018, 41(3): 119-122.
XU M Q. Port Ship Operation Efficiency Evaluation System Based on AIS Data[J]. China's Navigation, 2018, 41(3): 119-122.
- [3] VOLKOVA T A, BALYKINA Y E, BESPLOV A, et al. Predicting Ship Trajectory Based on Neural Networks

- Using AIS Data[J]. *Journal of Marine Science and Engineering*, 2021, 9(3): 254-265.
- [4] 姜佰辰, 关键, 周伟, 等. 基于多项式卡尔曼滤波的船舶轨迹预测算法[J]. *信号处理*, 2019, 35(5): 741-746.
- JIANG B C, GUAN J, ZHOU W, et al. Ship Trajectory Prediction Algorithm Based on Polynomial Kalman Filtering[J]. *Signal Processing*, 2019, 9(3): 254-265.
- [5] RONG H, TEIXEIRA A P, GUEDES SOARES C. Ship Trajectory Uncertainty Prediction Based on a Gaussian Process Model[J]. *Ocean Engineering*, 2019, 35(5): 741-746.
- [6] GUO S, LIU C, GUO Z, et al. Trajectory Prediction for Ocean Vessels Base on K-Order Multivariate Markov Chain [C]//International Conference on Wireless Algorithms, Systems, and Applications. 2018.
- [7] 周艳萍, 曾宪群, 蔡玲. 改进灰色模型的船舶航行轨迹自动预测研究[J]. *舰船科学技术*, 2021, 43(20): 34-36.
- ZHOU Y P, ZENG X Q, CAI L. Research on Automatic Prediction of Ship Navigation Trajectory with Improved Gray Model[J]. *Naval Science and Technology*, 2021, 43(20): 34-36.
- [8] 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 Dynamic Forecast Based on AIS Data and LSTM Network[J]. *Journal of Shanghai Maritime University*, 2019, 40(3): 32-37.
- [9] 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. Ship Track Prediction Based on Recurrent Neural Network[J]. *System Engineering and Electronic Technology*, 2020, 42(4): 871-877.
- [10] 刘姗姗, 马社祥, 孟鑫, 等. 基于 CNN 和 Bi-LSTM 的船舶航迹预测[J]. *重庆理工大学学报 (自然科学)*, 2020, 34(12): 196-205.
- LIU S S, MA S X, MENG X, et al. Ship Track Prediction Based on CNN and Bi-LSTM[J]. *Journal of Chongqing University of Technology (Natural Science)*, 2020, 34(12): 196-205.
- [11] 赵程栋, 庄继晖, 程晓鸣, 等. 基于特征注意力机制的 RNN-Bi-LSTM 船舶轨迹预测[J]. *广东海洋大学学报*, 2022, 42(5): 1-10.
- ZHAO C D, ZHUANG J H, CHENG X M, et al. RNN-Bi-LSTM Ship Trajectory Prediction Based on Feature Attention Mechanism[J]. *Journal of Guangdong Ocean University*, 2022, 42(5): 1-10.
- [12] ZHOU Z, YE L, WANG J, et al. Hivt: Hierarchical Vector Transformer for Multi-Agent Motion Prediction[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022.
- [13] LIU Y X, NIU H K, ZHU J L. GAMDTP: Dynamic Trajectory Prediction with Graph Attention Mamba Network[J]. *Journal of Intelligent & Fuzzy Systems*, 2025: 18758967251374199.
- [14] XUE H, WANG S, XIA M, et al. G-Trans: a Hierarchical Approach to Vessel Trajectory Prediction with GRU-Based Transformer[J]. *Ocean Engineering*, 2024, 300: 117431.
- [15] ZHANG B, SONG N, ZHANG L. Decoupling Motion Forecasting into Directional Intentions and Dynamic States[C]//Advances in Neural Information Processing Systems. 2024.
- [16] VASWANI A. Attention is All You Need[C]//Advances in Neural Information Processing Systems. 2017.
- [17] NGUYEN D, FABLET R. A Transformer Network with Sparse Augmented Data Representation and Cross Entropy Loss for AIS-Based Vessel Trajectory Prediction[J]. *IEEE Access*, 2024, 12(12): 21596-21609.
- [18] NGUYEN D, VADAINÉ R, HAJDUCH G, et al. GeoTrackNet-a Maritime Anomaly Detector Using Probabilistic Neural Network Representation of AIS Tracks and a Contrario Detection[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 23(6): 5655-5667.
- [19] CAPOBIANCO S, MILLEFIORI LM, FORTI N, et al. Deep Learning Methods for Vessel Trajectory Prediction Based on Recurrent Neural Networks[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2021, 57(6): 4329-4346.