



基于贝叶斯优化的时间卷积网络船舶航迹预测

李金源 朱发新 滕宪斌 毕齐林

Ship track prediction based on Bayesian optimization in temporal convolutional networks

LI Jinyuan, ZHU Faxin, TENG Xianbin, BI Qilin

在线阅读 View online: <https://doi.org/10.19693/j.issn.1673-3185.03755>

您可能感兴趣的其他文章

Articles you may be interested in

欠驱动船舶自适应神经网络有限时间轨迹跟踪

Finite time trajectory tracking of underactuated ship based on adaptive neural network

中国舰船研究. 2022, 17(4): 24-31 <https://doi.org/10.19693/j.issn.1673-3185.02564>

基于卷积神经网络的蒸汽动力系统故障诊断

Fault diagnosis of steam power system based on convolutional neural network

中国舰船研究. 2022, 17(6): 96-102 <https://doi.org/10.19693/j.issn.1673-3185.02616>

基于图卷积网络的非均衡数据船舶柴油机故障诊断

Fault diagnosis of marine diesel engines based on graph convolutional network under unbalanced datasets

中国舰船研究. 2022, 17(5): 289-300 <https://doi.org/10.19693/j.issn.1673-3185.02859>

基于全卷积神经网络的板条多压头成形回弹预测及模具设计

Springback prediction and mould design for multi-square punch forming of the strip based on FCN

中国舰船研究. 2023, 18(6): 197-207 <https://doi.org/10.19693/j.issn.1673-3185.02964>

基于三维N型卷积神经网络和频域注意力亥姆霍兹正则化的近场声源重建方法

Near-field acoustic reconstruction method based on three-dimensional N-shaped convolution neural network and frequency focal-KH regularization

中国舰船研究. 2023, 18(6): 186-196 <https://doi.org/10.19693/j.issn.1673-3185.03127>

基于NARX神经网络的船舶升沉运动实时预测方法

A real-time prediction method for ship heave motion using NARX neural network

中国舰船研究. 2020, 15(1): 48-55, 67 <https://doi.org/10.19693/j.issn.1673-3185.01717>



扫码关注微信公众号, 获得更多资讯信息

本文网址: <http://www.ship-research.com/cn/article/doi/10.19693/j.issn.1673-3185.03755>

期刊网址: www.ship-research.com

引用格式: 李金源, 朱发新, 滕宪斌, 等. 基于贝叶斯优化的时间卷积网络船舶航迹预测 [J]. 中国舰船研究, 2024, 19(6): 303–311.

LI J Y, ZHU F X, TENG X B, et al. Ship track prediction based on Bayesian optimization in temporal convolutional networks[J]. Chinese Journal of Ship Research, 2024, 19(6): 303–311 (in Chinese).

基于贝叶斯优化的时间卷积网络 船舶航迹预测



扫码阅读全文

李金源¹, 朱发新^{*1}, 滕宪斌², 毕齐林²

¹ 浙江海洋大学 船舶与海运学院, 浙江 舟山 316022

² 广州航海学院 轮机工程学院, 广东 广州 510725

摘要: [目的] 为提高船舶航迹预测精度和计算效率, 解决传统方法容易出现的梯度爆炸、计算时间长等问题, 提出基于改进的贝叶斯优化算法与时间卷积神经网络的航迹预测模型。[方法] 首先, 通过引入时间模式注意力机制, 提取各输入特征的权重, 保证航迹历史数据的时序性, 同时引入可逆残差网络, 减少时间卷积神经网络模型训练过程中占用的内存; 然后, 再采用贝叶斯优化算法对时间卷积网络中的超参数(内核大小 K 、膨胀系数 d) 进行寻优; 最后, 采用五折交叉验证方法对模型进行验证, 获得最优模型后进行航迹预测。[结果] 采用 AIS 采集的航迹数据验证, 结果表明, 在弱耦合、中耦合和强耦合航迹预测中, 均方根误差分别平均提高 5.5×10^{-5} , 3.5×10^{-4} 和 6×10^{-4} 。[结论] 所提出网络对复杂航迹具有良好的适应性, 其预测精度均优于传统模型及 LSTM 模型, 在耦合较强的航迹中仍能保持较高的预测精度。

关键词: 导航; 神经网络; 贝叶斯优化算法; 时间卷积网络; 时间模式注意力机制模块; 可逆残差网络; AIS 数据

中图分类号: U666

文献标志码: A

DOI: 10.19693/j.issn.1673-3185.03755

Ship track prediction based on Bayesian optimization in temporal convolutional networks

LI Jinyuan¹, ZHU Faxin^{*1}, TENG Xianbin², BI Qilin²

¹ School of Ship and Marine, Zhejiang Ocean University, Zhoushan 316022, China

² College of Marine Engineering, Guangzhou Maritime College, Guangzhou 510725, China

Abstract: [Objective] As the traditional ship trajectory prediction method is prone to gradient explosion and long calculation time, this paper seeks to improve its accuracy and calculation efficiency by proposing a ship trajectory prediction model based on an improved Bayesian optimization algorithm (IBOA) and temporal convolution network (TCN). [Method] A temporal pattern attention (TPA) mechanism is introduced to extract the weights of each input feature and ensure the timing of the historical flight track data. At the same time, a reversible residual network (RevNet) is introduced to reduce the memory occupied by TCN model training. The IBOA is then used to find the optimality of the hyperparameters in the TCN (size of kernel K , expansion coefficient d). The model is finally validated using a five-fold cross-validation method, and trajectory prediction is carried out after obtaining the optimal model. [Result] The trajectory data is collected by automatic identification system (AIS) and verified. The root mean square error (RMSE) is found to be increased by 5.5×10^{-5} , 3.5×10^{-4} and 6×10^{-4} in weak coupling, medium coupling and strong coupling track prediction respectively. [Conclusion] The proposed network has good adaptability to complex trajectories and higher accuracy than the traditional model and long short-term memory (LSTM) model, while maintaining high prediction accuracy for trajectories with strong coupling.

Key words: navigation; neural networks; Bayesian optimization algorithm; temporal convolutional networks; temporal pattern attention mechanism module; reversible residual networks; AIS data

收稿日期: 2024-01-24 修回日期: 2024-03-23 网络首发时间: 2024-07-19 14:22

基金项目: 浙江省大学生科技创新活动计划资助项目(2023R411044)

作者简介: 李金源, 男, 1997年生, 硕士生。研究方向: 船舶智能控制, 数据挖掘。E-mail: 1297437371@qq.com

朱发新, 男, 1982年生, 硕士, 副教授。研究方向: 船舶安全与污染控制。E-mail: zhufax7758@163.com

*通信作者: 朱发新

0 引言

当前,船舶行业正处于向智能化、信息化高速发展的时代,船舶智能化程度是海上交通发展水平的重要体现。船舶航迹实现精准预测是船舶智能化的重要方面,也是船舶进行避障、路径规划的前提。因此,研究如何精准预测船舶航迹,对于船舶行业发展具有重要意义。

近年来,不少学者针对船舶航迹预测进行了研究。Zhou等^[1]结合船舶自动识别系统(AIS)采用BP神经网络(back propagation neural network)对船舶航迹进行较精准的预测。张新和李广儒^[2]采用BP神经网络对航迹进行预测,同时采用遗传算法优化神经元的个数及权值,与传统神经网络相比提高了预测的精度。Chen等^[3]采用维数学习灰狼优化支持向量回归(dimension learning grey wolf optimizer and support vector regression, DLGWO-SVR)实现对航迹的预测。Zhang等^[4]采用长短期记忆网络(long short-term memory, LSTM)循环神经网络对航迹进行了预测。考虑到传统的LSTM网络对航迹预测的步长较短,导致预测效率较低,王余宽等^[5]提出基于滑动窗口LSTM网络对船舶航迹进行预测,提高了模型精度及泛化能力。鄢博冉等^[6]针对AIS系统数据中存在较大的系统噪声和测量噪声问题,提出采用滑动卡尔曼循环网络对航迹进行实时预测。王森杰等^[7]采用生成对抗网络,同时对多艘船舶航迹进行了预测。针对传统时间序列预测方法对船舶航迹特征提取不充分的问题,蒋通等^[8]采用聚类分析和注意力机制、双向长短时记忆网络(Att-Bi-LSTM)的航迹预测方法,提高了预测模型的精度和稳定性。胡丹等^[9]针对航迹特征多维度特点,提出一种并行长短期记忆网络和全卷积网络(LSTM-FCN)模型实现了对多维特征船舶航迹较高精度的预测,提高了航迹预测的精准度和稳定性。于琛等^[10]提出了一种基于自回归综合移动平均模型-双向门控循环单元网络(ARIMA-BIGRU)航迹组合预测模型。

目前,常用船舶航迹预测的神经网络模型主要是循环神经网络(recurrent neural network, RNN)及其变体LSTM和GRU(门控循环单元)等。虽然取得了不错的效果,但是RNN及其变体具有训练时间长、收敛速度慢以及会发生梯度爆炸等缺点,制约了其在实时性高的船舶航迹预测中的应用。近年来, Bai等^[11]提出时间卷积网络(temporal convolutional network, TCN),对比了RNN及其变体等神经网络,结果表明,TCN模型在多种序列

模型中表现出了更好的效果。TCN的出现为进一步获取船舶航迹数据特征提供了新思路。TCN网络不同于普通卷积网络,其结构由因果卷积、空洞卷积和残差模块组成^[12],使其具有了从大样本中提取特征和预测的能力,并避免了随着网络深度的增加预测性能降低等问题。基于TCN模型的上述优势,不少学者将其应用于时间序列预测。赵洋等^[13]采用TCN对短期电力负荷进行预测,结果表明,TCN可以获得更高的预测精度。林涛等^[14]采用一种收缩的TCN模型对空气质量进行预测,相比于LSTM、传统TCN算法,该模型具有更高的精度。王秀娜等^[15]采用随机森林(random forest)和TCN组合算法对航空发动机故障进行预测,取得了良好效果。Zhu等^[16]提出基于TCN残差修正混合模型的风电功率预测方法,验证了所提方法具有更佳的预测性能。Hu等^[17]提出基于完全集成经验模态分解与自适应噪声(CEEM-DAN)-LSTM-TCN的超短期风电功率预测,该方法对超短期风能具有较好的预测能力。Zhang等^[18]采用IWOA(改进的鲸鱼优化算法)-TCN-Attention模型对船舶运动姿态进行预测,结果表明,该方法对船舶运动姿态预测具有较高的精度。

综上,TCN模型应用于多方面的时间序列预测均取得不错的效果,但目前少有人将其应用于处理船舶航迹数据中,缺乏相关的实验报告。考虑到船舶在航行过程中受到外部环境(风、浪、流)扰动下,AIS系统数据中存在异常值,使得航迹预测精度不高,本文将构建基于改进的TCN的船舶航迹预测模型。首先,对AIS原始数据预处理,然后构建基于改进的TCN船舶航迹预测模型,并且针对TCN模型中超参数(内核大小 K ,膨胀因子 d 等)难以确定等问题,采用贝叶斯优化(Bayesian optimization algorithm, BOA)算法对超参数进行寻优,从而进一步提高船舶航迹预测模型的精度。

1 构建TCN船舶航迹预测模型

1.1 传统的基本TCN航迹预测模型

船舶航行过程中所具有的强非线性、不确定性等特点给实时准确的航迹预测带来了挑战。采用RNN及其变体(如LSTM)进行船舶航迹预测时存在训练时间长、易发生梯度爆炸和消失等问题,而TCN中的卷积操作具有并行计算优势,卷积操作能够同时处理多个位置的信息,可减少训练时间。此外,TCN使用了残差连接,可通过跨层直接信息传递缓解梯度消失问题。本文构建了

基于 TCN 船舶航迹预测模型。设 TCN 模型输入序列为 $x_i = [x_i(1), x_i(2), \dots, x_i(n)]$, 其中, x_i 为船舶航迹某特征的序列数, n 为每个特征对应的序列个数, i 表示经/纬度、航速、航向、时间间隔等航迹相关特征; 输出的序列为 $y_j = [y_j(1), y_j(2), \dots, y_j(n)]$, 其中 j 表示经度或纬度。图 1 所示为 TCN 船舶航迹预测模型建立的基本流程。

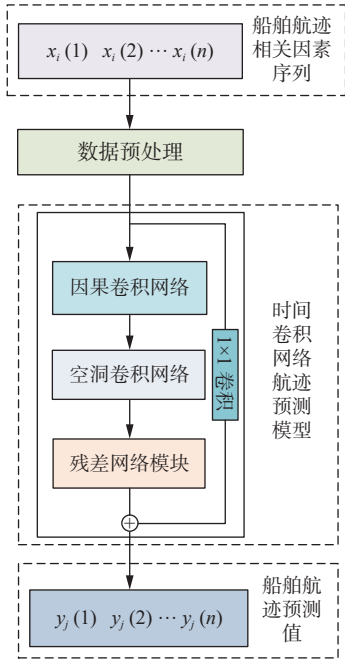


图 1 TCN 船舶航迹预测模型基本流程

Fig. 1 Basic process of TCN ship trajectory prediction model

因果卷积网络 (causal convolutional neural network, CCNN) 是一个单向结构, 即对于 t 时刻的航迹预测值其只依赖于 t 时刻及其之前相关因素的值。设 CCNN 的滤波器为 $F = (f_1, f_2, \dots, f_k)$, 在 $x_i(m)$ 处的船舶航迹预测值为

$$y_i(m) = (F * x_i)_{x_i(m)} = \sum_{k=1}^K f_k x_i(m) - K + k \quad (1)$$

式中: f 为卷积映射函数; k 为卷积网络的当前层数; m 为每个特征对应的第几个序列数。

CCNN 需要依赖前期数据进行预测, 导致数据较长时需要的网络深度大, 导致网络结构复杂, 实时性差, 难以保证船舶航行过程中的实时性。因此, 采用 CCNN 来增大卷积的视野, 如图 2 所示。CCNN 的计算为

$$y_i(m) = (df * x_i)_{x_i(m)} = \sum_{l=1}^L f_l x_i(m - d * l) \quad (2)$$

式中: l 为滤波器的大小; $m - d * l$ 代表历史的方向。

卷积的感受视野与膨胀因子 d 和内核大小 K 等超参数的关系式为




图 2 因果卷积结构图

Fig. 2 Causal convolution structure diagram

$$\omega = 1 + \sum_{c=0}^{C-1} (K-1) * b^c = 1 + (K-1) * \frac{b^C - 1}{b-1} \quad (3)$$

式中: b 为膨胀基; c 表示新层下面的层数; C 表示卷积层的层数; ω 表示卷积的感受视野大小。

CCNN 与膨胀卷积网络 (dilated convolutional network, DCN) 在解决较浅的神经网络中可实现较好的预测效果, 但在船舶航迹预测中产生大量与航迹相关的数据, 较浅的神经网络不足以充分学习大量的数据规律, 需采用深度学习网络 (deep learning network, DLN) 对航迹历史数据进行充分学习, 但随着网络的加深, 这会导致网络退化的问题。因此, 引入一个残差网络 (ResNet) 模块对网络模型进行优化, ResNet 采用一个跳过一层或多层的“跳连接”操作^[19], 以避免深层网络造成学习性能的退化。残差模块的计算公式为

$$O(x) = \text{Activation}(F(x) + x) \quad (4)$$

其中, $\text{Activation}()$ 为激活函数; $F(x)$ 为残差函数; x 为输入序列。

1.2 改进的 TCN 船舶航迹预测模型

目前, 由于 TCN 具有可避免梯度爆炸或消失、可并行训练等优点, 被广泛应用于时间序列预测中。但是, 传统的 TCN 模型有两个较为明显的缺点: 1) 需获取有效历史长度的原始序列, 导致训练期间消耗内存大; 2) 迁移性差、超参数难以确定等。因此, 本文结合船舶航迹数据的特点, 针对需要完整序列才能预测、训练中网络层连接复杂导致内存开销大的问题, 采用可逆残差网络 (reversible residual network, RevNet) 代替 TCN 模型中的标准残差模块, 在传播过程中按照数据需求计算每一层网络的激活值, 同时 RevNet 允许在每一层网络之间保持梯度的完整性, 不需要额外存储每一层网络的输出, 减少了内存消耗。同时, 采用时间模式注意力机制模块 (temporal pat-

tern attention mechanism module, TPAMM) 对 TCN 模型中通过卷积操作后的特征分别赋予不同权重, 最后通过全连接层进行输出, 获得预测航迹值。针对迁移性差、超参数难以确定的问题, 本文以最小建模误差为目标函数, 采用改进的贝叶斯优化算法 (IBOA) 对 TCN 的超参数寻优, 再通过五折交叉验证 (5-fold cross-validation) 算法对模型进行验证, 获得最优模型, 输出预测结果。

1.2.1 可逆残差网络 (RevNet)

残差模块被广泛应用于网络较深的神经网络, 解决网络深度带来的训练困难问题。在航迹预测中, 为了更好地挖掘历史航迹信息, 采用含残差模块的 TCN 网络模型对数据进行训练, 获得了不错效果。但训练过程中需占用大量内存, 计算机资源消耗大。因此, 本文引入 RevNet 对 TCN 深层网络进行了优化。可逆残差块由两个相似的残差函数分割成两个部分, 模块的主要结构如图 3 所示。




图 3 可逆残差模块

Fig. 3 Reversible residual module

正向传播的计算式为:

$$Y_1 = X_1 + \psi(Y_2) \tag{5}$$

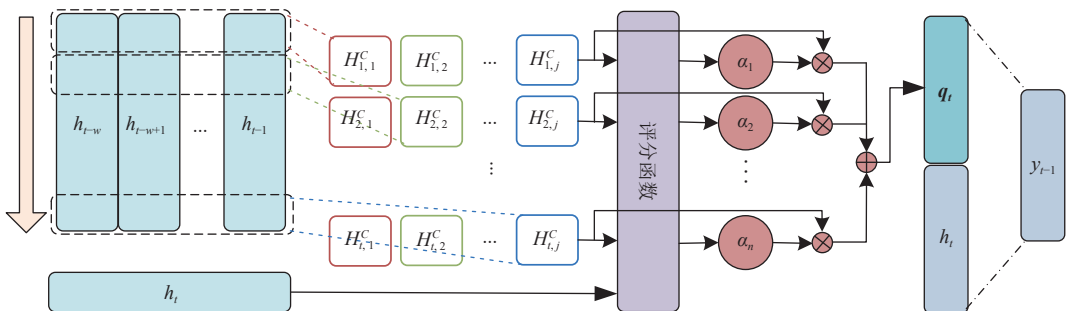


图 4 时间模式注意力机制结构示意图

Fig. 4 Structure of the temporal pattern attention mechanism

$$Y_2 = X_2 + \zeta(X_1) \tag{6}$$

逆向传播的计算式为:

$$X_1 = Y_1 - \psi(Y_2) \tag{7}$$

$$X_2 = Y_2 - \zeta(X_1) \tag{8}$$

式中: X_1, X_2 为残差块输入数据; Y_1, Y_2 为残差块输出数据; ψ 和 ζ 为残差函数。

1.2.2 时间模式注意力机制 (TPAMM)

注意力机制的主要核心是使得网络关注到最为重要的信息^[20]。在船舶航行过程中, 对航迹的影响因素较多, 输入模型的特征数较多, TCN 模型在训练预测过程中训练耗时较多, 且传统的注意力机制需计算每两个数据点之间的注意力分数, 导致计算量较大。因此, 本文在 TCN 预测模型中引入 TPAMM 将航迹特征数据深度挖掘时间序列信息, 在预测任务中, 根据输入特征对预测结果的权重不同, 在训练时采用 TPAMM 对各特征进行权重计算, 进而提高航迹预测的精度。

在船舶航行过程中, 输入的相关特征序列主要有经纬度、航向角和姿态角等, 但相关特征对航迹影响权重各不相同, 且各特征之间存在相关性。在时间卷积预测模型中, 膨胀因果卷积 (dilated causal convolution) 虽然在一定程度上能对各输入特征赋予不同的权重和捕捉到不同特征之间的相关性, 但其特征表示能力有限, 无法充分捕捉到复杂序列中不同特征之间的相关性, 同时缺乏自适应性, 无法有效地聚焦于关键信息, 导致历史航迹关键信息挖掘不充分。典型的注意力机制一般适用于单因素或者用于多因素输入特征权重进行平均的情形, 未能实现多元时序特征内部信息的挖掘。因此, 本文引入一种 TPAMM 改进 TCN 模型, 深度挖掘航迹相关特征的时间序列, 使 TCN 模型充分深度挖掘历史信息的重要信息, 进一步提高航迹预测的精度。TPAMM 的结构示意图如图 4 所示, 其中 h_{t-w} 为隐状态, w 是时间窗口长度, H 为隐状态矩阵, H^c 为时间模式矩阵, $H_{t,j}$

表示第 t 个行向量和第 j 个卷积核作用的结果值, α 表示注意力权重, q_t 为上下文向量。

1.3 改进的贝叶斯优化算法 (IBOA)

贝叶斯优化算法 (BOA) 是一种超参数自动优化算法, 在 TCN 中, 由于航迹数据具有非线性、复杂性, 导致在预测过程中 TCN 网络超参数难以确定。因此, 本文采用改进的 BOA 对 TCN 网络中的内核大小 K 和膨胀因子 d 超参数进行优化, 以最小建模误差为目标函数, 获得最优的超参数组合, 由最优模型对航迹数据进行预测。模型参数优化流程如图 5 所示。BOA 算法的目标函数如式 (9) 所示。

$$\min U(K, d) = \frac{1}{n} \sum_{i=m-1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (9)$$

式中: n 为训练或者测试样本的数目; \hat{y}_i 为某时刻的航迹预测值; y_i 为同一时刻航迹的实际测量值。

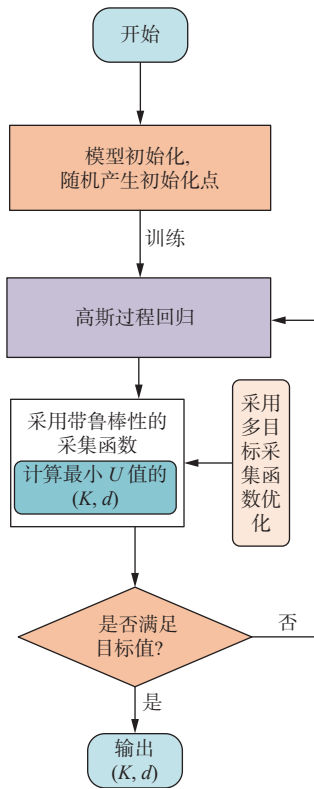


图 5 贝叶斯优化算法参数流程

Fig. 5 Parameter flow of Bayesian optimization algorithm

贝叶斯算法优化参数流程的基本步骤如下:

步骤 1: 模型初始化, 随机初始化超参数候选值的个数 n_0 , 最大迭代次数 N_1 , 再训练模型。

步骤 2: 对高斯过程回归模型进行训练, 用高斯回归模型 $G(K, d)$ 构建带鲁棒性的采集函数 $\alpha((K, d)|D_0)$, 即

$$\max_{K, d} \alpha(K, d) = \max_{K, d} IE_{\varepsilon \sim N(0, \sigma_\varepsilon^2)} [a^{K/d + \varepsilon}((K, d)|D_0)] \quad (10)$$

步骤 3: 采用多目标采集函数进行优化, 即

$$\max(\alpha_{\varepsilon_1}^{K, d}((K, d)|D_0), \alpha_{\varepsilon_2}^{K, d}((K, d)|D_0), \alpha_{\varepsilon_3}^{K, d}((K, d)|D_0)) \quad (11)$$

式中: α 为采集函数; ε 为高斯噪声。

步骤 4: 获取评估点 (K, d) 的函数值 $U(K, d)$, 加入至当前评估点集合中, 最后输出最优候选评估点 $\{(K, d), U\}$, 获得最优超参数值。

1.4 交叉验证方法

为了避免本文构建的模型过拟合或者欠拟合, 采用 K_1 折交叉验证方法将数据集划分成 K_1 份, 选用其中一份为测试集, 其他数据集为训练集, 重复进行 K_1 次实验, 得到 K_1 个模型, 通过取 K_1 次实验结果评价指标的平均值对模型进行综合评价, 如图 6 所示。




图 6 K_1 折交叉验证法

Fig. 6 K_1 -fold cross-validation method

1.5 贝叶斯算法优化 TCN 的航迹预测模型

在船舶航行过程中, 其航迹受多因素的共同影响, 导致航迹预测困难。因此, 采用贝叶斯优化 TCN 模型预测航迹 (图 7)。具体流程如下:

1) 数据预处理。在船舶航行过程中, 与航迹相关的数据由于受到外来干扰, 容易产生异常值, 对航迹的预测具有重要影响, 因此首先对原始数据进行异常值检测及处理, 再对处理后的数据进行归一化处理。

2) 初始化 TCN 模型的结构。传统的 TCN 在处理序列较长的数据时, 训练内存消耗大, 因此采用 RevNet 网络改进 TCN 原始结构, 以提高模型的训练效率, 同时采用 TPAMM 对输入特征进行信息深度挖掘, 进一步提高预测模型的精度。

3) 初始化 IBOA 算法参数。传统的 TCN 模型具有迁移能力差、超参数难以确定等缺点。因此, 以模型误差最小为目标函数, 采用 BOA 算法对 TCN 中的内核大小 K 和膨胀因子 d 进行优化, 同时为得到较好的预测结果, 采用五折交叉验证方法对模型进行验证, 获得最优模型。

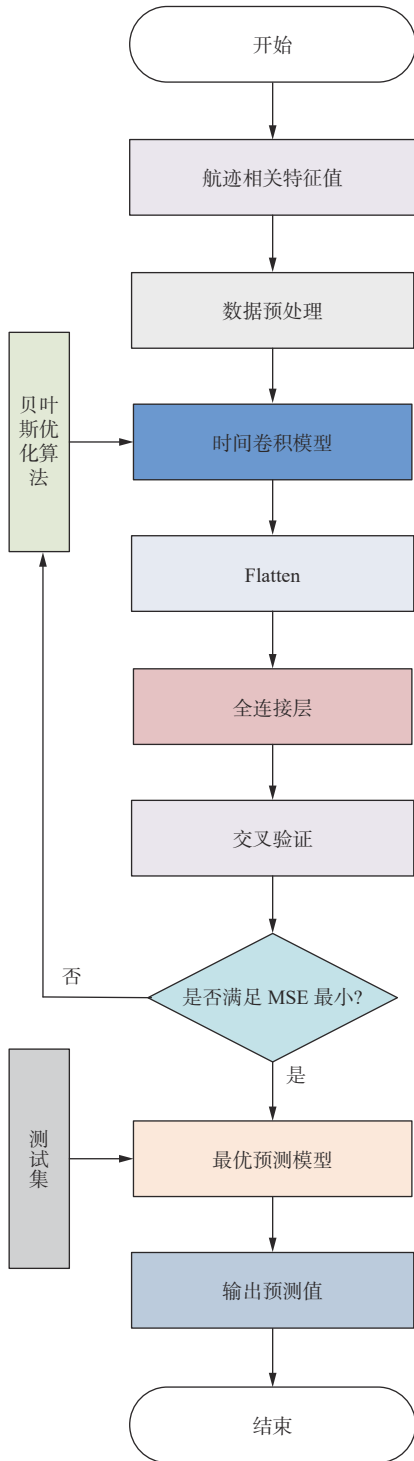


图 7 基于 IBOA-TCN 的航迹预测流程

Fig. 7 IBOA-TCN-based trajectory prediction process

4) 航迹预测。利用历史航迹信息对预测模型进行训练, 得到最优模型后再将测试集输入模型中进行计算, 最后得到航迹经度或纬度预测数据, 并与实际测试集比较, 获得模型的预测结果。

2 AIS 数据的来源及预处理

2.1 AIS 数据的来源

本文 AIS 数据来源于某船在美国沿海水域 2022

年 12 月 30 日的 AIS 的真实数据^[21]。AIS 数据中包含了大量的船舶动态信息和静态信息, 本文主要使用的数据包括数据记录时间、经/纬度、航速、艏向。同时, 考虑到航迹点记录时间间隔对船舶航迹的影响, 本文采用相邻航迹点的数据记录时间间隔作为特征变量进行输入。设船舶航迹预测模型的输入相关变量为

$$X(t) = \{\eta, \lambda, v, h, \Delta t\} \quad (12)$$

式中: X 为输入变量集合; η 为船舶位置经度; λ 为船舶位置纬度; v 为船舶航速; h 为船舶艏向; Δt 为相邻航迹点的数据记录时间间隔, s 。

2.2 AIS 数据预处理

由于船舶航行过程中会受到外部环境的干扰, AIS 数据在接收时易出现异常缺失值, 导致后续航迹建模预测结果误差较大。因此, 需对 AIS 数据进行异常值处理, 同时为避免艏向在 0° 到 360° 存在跳跃问题, 艏向采用正弦和余弦函数^[22]共同表示。设 t 时刻艏向为 C_t , 其对应的三角函数转换后的值为 $\sin C_t$ 和 $\cos C_t$, 并设为 α_1 和 β_1 。因此, 最终航迹预测的输入特征为

$$X(t) = \{\eta, \lambda, v, \alpha_1, \beta_1, \Delta t\} \quad (13)$$

因实际数据输入特征集合中各特征的量纲不相同, 若直接输入会导致预测误差大, 所以对各输入特征进行归一化处理, 以避免量纲不相同带来的误差。本文采用的归一化公式如下^[23]:

$$A = \frac{a - \min a}{\max a - \min a} \quad (14)$$

式中: a 为各输入特征的原始数据; $\min a$ 为原始特征数据的最小值; $\max a$ 为原始数据中的最大值。

为验证数据预处理对模型预测精度影响的有效性, 采用 IBOA-TCN 算法模型对预处理前后的 3 种航迹数据进行预测, 然后采用平均绝对误差 (MAE) 进行结果评价分析。表 1 为预处理数据 MAE 评价指标。

表 1 预处理数据 MAE 评价指标

Table 1 MAE evaluation indicators for pre-processed data

航迹类型	预处理前		预处理后	
	经度/(°)	纬度/(°)	经度/(°)	纬度/(°)
直线型航迹	0.0012	0.0011	0.0008	0.0007
S型航迹	0.0058	0.0063	0.0051	0.0056
M型航迹	0.0066	0.0069	0.0057	0.0062

从表 1 中可知, 数据预处理前后相比, 预处理后数据建模预测具有较高的精度, 因此在数据建

模前, 对数据进行预处理是必要的。

2.3 预测模型评价指标

为比较不同模型对航迹预测的效果, 本文采用均方根误差 (RMSE) 和 MAE 作为船舶航迹预测精度的评价指标^[24], 两个指标的值越小, 预测模型的性能越好。评估表达式为:

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (15)$$

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \times 100\% \quad (16)$$

式中: n 为训练或者测试样本的数目; \hat{y}_i 为某时刻的航迹预测值; y_i 为同一时刻航迹的实际测量值。

3 实验设计及分析

为了测试本文预测模型的有效性, 所有模型仿真实验均基于工作站 (2—GPU Tesla V100—32G, 2-CPU Xeon(R) E5-2678W) 运行, 采用软件 Python3.7 进行仿真。同时, 分别使用 LSTM 预测模型、传统 TCN 预测模型和本文 IBOA-TCN 模型进行对比分析。以美国沿海水域 2022 年 12 月 30 日 30 艘不同航迹的船舶数据作为实验数据, 按照训练集为 80%、测试集为 20% 划分实验数据, 选择 AIS 数据中船舶航行耦合较小的“直线型”航迹、中耦合的“转弯型”航迹及耦合较大的“类 M 型”航迹进行预测。

3.1 不同预测模型参数及实验分析

1) 模型参数设置。

为验证本文模型的有效性, 前期通过多组实验验证, 最终选用表 2 参数时的预测效果最好。

表 2 实验模型参数表

Table 2 Parameters for experimental model

算法参数	TCN	LSTM
卷积核大小	5	
卷积核数量	64	
扩张因子	8	
优化器	Adam	Adam
隐藏层	8	64
学习率	0.001	0.001
迭代次数	1 000	1 000
批次大小	64	64

2) 交叉验证实验结果及分析。

为了验证本文选取数据的有效性, 采用 $K_1=5$ 对

数据集进行实验, 评价指标取指标的平均值, 表 3 所示为本文所提 IBOA-TCN 算法模型的实验结果。结果表明, 本文选用的训练集及数据集具有合理性, 模型具有较高的泛化能力。

表 3 交叉实验结果对比

Table 3 Results comparison of crossover experiments

算法模型	e_{RMSE}		e_{MAE}	
	经度/(°)	纬度/(°)	经度/(°)	纬度/(°)
直线型航迹	0.0008	0.0003	0.0002	0.0006
S型航迹	0.0024	0.0021	0.0023	0.0025
M型航迹	0.0024	0.0035	0.0018	0.0033

3) 实验验证及分析。

为了验证本文所提 IBOA-TCN 预测模型的精度, 将 IBOA-TCN 模型与 LSTM 模型、传统的 TCN 模型行对比实验, 结果如图 8~图 10 所示。由图可以看出, IBOA-TCN 模型对“直线型”、“S 型”和“类 M 型”航迹的预测精度比其他两种模型都更精确, 证明了本文算法预测的有效性。其中, 耦合度较小的“直线型”航迹预测效果最好, 耦合度最大的“类 M 型”航迹预测效果最差, 这说明船舶航行航迹的耦合度影响了预测效果。

3.2 不同预测模型的精度对比

由于航迹预测效果图的坐标不统一, 对直接




图 8 “直线型”航迹预测图

Fig. 8 Chart for linear type trajectory prediction

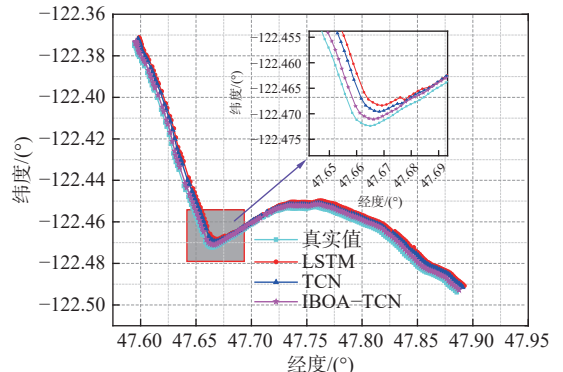


图 9 “S 型”航迹预测图

Fig. 9 Chart for S-type trajectory prediction

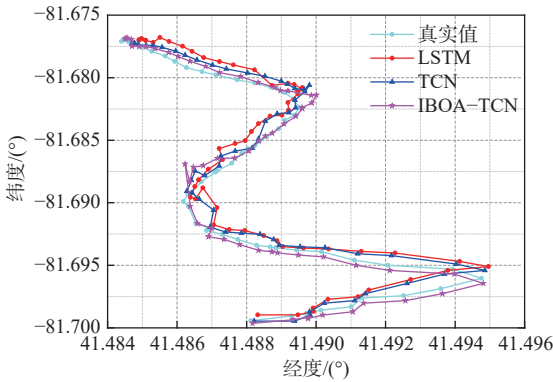


图 10 “类 M 型”航迹预测图

Fig. 10 Chart for Class M type trajectory prediction

判断航迹预测效果产生了一定的影响。因此,本文采用 MAE 和 RMSE 对航迹精度进行评价,如图 11~图 13 所示。由图可知,IBOA-TCN 模型航迹预测评价指标 MAE 和 RMSE 均最小。通过图中经纬度的 RMSE 值计算得出 IBOA-TCN 算法在 3 种不同航迹下相比于 TCN 算法分别平均提高的精度为: 5.5×10^{-5} , 3.5×10^{-4} 和 6×10^{-4} 。

4 结 语

本文提出了一种基于 IBOA-TCN 算法模型的航迹预测方法。首先,采用 RevNet 网络代替单向

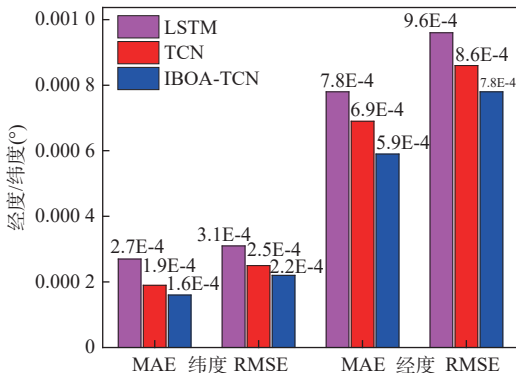


图 11 “直线型”航迹经纬度评价指标

Fig. 11 Longitude and latitude evaluation indexes for linear type trajectory

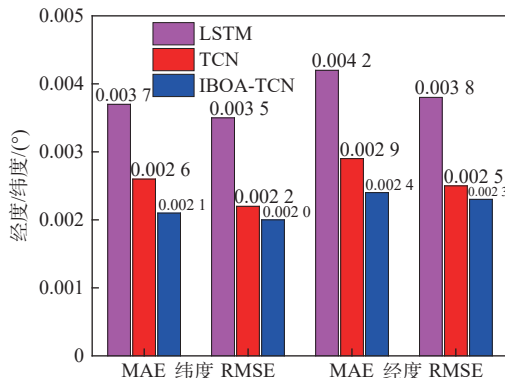


图 12 “S 型”航迹经纬度评价指标

Fig. 12 Longitude and latitude evaluation indexes for S-type trajectory

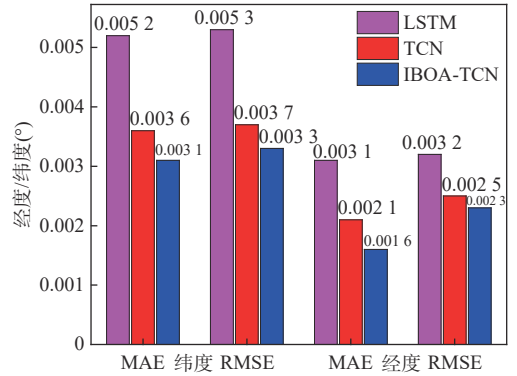


图 13 “类 M 型”航迹经纬度评价指标

Fig. 13 Longitude and latitude evaluation indexes for M-like type trajectory

残差网络,减少 TCN 模型训练时的内存消耗;然后,采用 TPAMM 对影响船舶航迹预测的不同特征赋予不同的权重,以保证航迹历史数据的时序性;最后,采用贝叶斯网络对 TCN 超参数进行优化,提高船舶航迹预测模型的精度。基于船舶航迹实际数据的仿真表明,相较于 LSTM,TCN 等预测模型,所提方法具有更高的精度,可为船舶航迹预测提供更全面的参考。针对目前贝叶斯优化结合 TCN 船舶航迹预测的研究,未来可以从以下方向开展研究:

- 1) 进一步探索贝叶斯优化在模型参数调整中的应用,通过引入更复杂的先验知识和优化策略,提高模型对航迹数据的拟合能力和泛化性。
- 2) 考虑将 TCN 模型与其他深度学习模型(如 RNN 和 LSTM 等)进行集成,以进一步提升船舶航迹预测的准确性和稳定性。
- 3) 针对复杂实时环境下的船舶航迹预测需求,探索模型的实时性和效率,使其能够在实际船舶交通管理等领域得到广泛应用。

参考文献:

[1] ZHOU H, CHEN Y J, ZHANG S M. Ship trajectory prediction based on BP neural network[J]. *Journal on Artificial Intelligence*, 2019, 1(1): 29–36.

[2] 张新,李广儒.基于 GA-BP 神经网络的船舶航迹预测[J].*广州航海学院学报*,2020,28(4):15–18.
ZHANG X, LI G R. Prediction model of ship trajectory based on GA-BP[J]. *Journal of Guangzhou Maritime University*, 2020,28(4):15–18 (in Chinese)

[3] CHEN Y Y, YANG S H, SUO Y F, et al. Ship track prediction based on DLGWO-SVR[J/OL]. *Scientific Programming*. (2021-01-01) [2024-03-23]. doi: 10.1155/2021/9085617.

[4] ZHANG Z Y, NI G X, XU Y G. Ship trajectory prediction based on LSTM neural network[C]//*Proceedings of 2020 IEEE 5th Information Technology and Mechatron-*

- ics Engineering Conference. Chongqing: IEEE, 2020: 1356–1364.
- [5] 王余宽, 谢新连, 马昊, 等. 基于滑动窗口 LSTM 网络的船舶航迹预测 [J]. 上海海事大学学报, 2022, 43(1): 14–22. WANG Y K, XIE X L, MA H, et al. Ship trajectory prediction based on sliding window LSTM network[J]. Journal of Shanghai Maritime University, 2022, 43(1): 14–22 (in Chinese).
- [6] 鄢博冉, 高大为, 朱永生, 等. 基于低信噪比 AIS 数据的船舶航迹精准预测 [J]. 船舶工程, 2021, 43(10): 111–117. YAN B R, GAO D W, ZHU Y S, et al. Accurate prediction of ship tracks based on low SNR AIS data[J]. Ship Engineering, 2021, 43(10): 111–117 (in Chinese).
- [7] 王森杰, 何正伟. 基于生成对抗网络的船舶航迹预测模型 [J]. 中国航海, 2021, 44(2): 72–77. WANG S J, HE C W. Ship trajectory prediction model based on generative adversarial network with attention and interaction[J]. Navigation of China, 2021, 44(2): 72–77 (in Chinese).
- [8] 蒋通, 崔良中, 刘立国, 等. 基于聚类分析和 Att-Bi-LSTM 的舰船航迹预测方法 [J]. 计算机仿真, 2022, 39(8): 1–5, 322. JIANG T, CUI L Z, LIU L G, et al. The method of ship track prediction based on cluster analysis and Att-Bi-LSTM[J]. Computer Simulation, 2022, 39(8): 1–5, 322 (in Chinese).
- [9] 胡丹, 孟新, 路帅, 等. 一种并行 LSTM-FCN 模型在船舶航迹预测中的应用 [J]. 控制与决策, 2022, 37(8): 1955–1961. HU D, MENG X, LU S, et al. Parallel LSTM-FCN model applied to vessel trajectory prediction[J]. Control and Decision, 2022, 37(8): 1955–1961 (in Chinese).
- [10] 于琛, 付玉慧, 张逸飞, 等. 基于 ARIMA-BIGRU 的船舶航迹预测 [J]. 航海工程, 2021, 50(6): 147–152. YU C, FU Y H, ZHANG Y F, et al. The track prediction method based on ARIMA-BIGRU neural network[J]. Ship & Ocean Engineering, 2021, 50(6): 147–152 (in Chinese).
- [11] BAI S J, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J/OL]. arXiv preprint arXiv (2018-03-4)[2024-03-23]. <https://arxiv.org/abs/1803.01271>.
- [12] WU P, SUN J W, CHANG X T, et al. Data-driven reduced order model with temporal convolutional neural network[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 360: 112766.
- [13] 赵洋, 王瀚墨, 康丽, 等. 基于时间卷积网络的短期电力负荷预测 [J]. 电工技术学报, 2022, 37(5): 1242–1251. ZHAO Y, WANG H M, KANG L, et al. Temporal convolution network-based short-term electrical load forecasting[J]. Transactions of China Electrotechnical Society, 2022, 37(5): 1242–1251 (in Chinese).
- [14] 林涛, 吉萌萌, 付崇阁, 等. 基于改进时间卷积网络的空气质量预测研究 [J]. 计算机仿真, 2022, 39(10): 451–456, 501. LIN T, JI M M, FU C G, et al. Research on air quality forecasting based on improved temporal convolutional networks[J]. Computer Simulation, 2022, 39(10): 451–456, 501 (in Chinese).
- [15] 王秀娜, 鲁守银, 任飞. 基于随机森林和时间卷积网络的航空发动机故障预测 [J]. 计算机时代, 2022(10): 103–107. WANG X N, LU S Y, REN F. Failure prediction of aero-engine based on random forest and temporal convolutional network[J]. Computer Era, 2022(10): 103–107 (in Chinese).
- [16] ZHU J J, SU L C, LI Y W. Wind power forecasting based on new hybrid model with TCN residual modification[J]. *Energy and AI*, 2022, 10: 100199.
- [17] HU C J, ZHAO Y, JIANG H, et al. Prediction of ultra-short-term wind power based on CEEMDAN-LSTM-TCN [J]. Energy Reports, 2022, 8 Suppl 8: 483–492.
- [18] ZHANG B, WANG S, DENG L W, et al. Ship motion attitude prediction model based on IWOA-TCN-Attention[J]. *Ocean Engineering*, 2023, 272: 113911.
- [19] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770–778.
- [20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017: 6000–6010.
- [21] NOAA. AISDataHandler[DB/OL]. NOAA. (2020-09-08)[2024-01-24]. <https://coast.noaa.gov/htdata/CMSP/AIS-DataHandler/2020/index.html>.
- [22] 高天航, 徐力, 靳廉洁, 葛彪. 考虑航艏向与数据变化差异的船舶轨迹预测 [J]. 交通运输系统工程与信息, 2021, 21(1): 90–94. GAO T H, XU L, JIN L J, et al. Vessel trajectory prediction considering difference between heading and data changes[J]. Journal of Transportation Systems Engineering and Information Technology, 2021, 21(1): 90–94 (in Chinese).
- [23] PANDA S K, JANA P K. Efficient task scheduling algorithms for heterogeneous multi-cloud environment[J]. *The Journal of Supercomputing*, 2015, 71(4): 1505–1533.
- [24] 焦卫东, 杨蓓. MDAT-Net: 一种融合 MSC 和时空注意力的 TCN 航迹预测方法 [J/OL]. 北京航空航天大学学报. (2024-03-08)[2024-03-23]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0717>. JIAO W D, YANG B. MDAT-Net: a TCN trajectory prediction method fusing MSC and spatio-temporal attention[J/OL]. Journal of Beijing University of Aeronautics and Astronautics. (2024-03-08)[2024-03-23] <https://doi.org/10.13700/j.bh.1001-5965.2023.0717> (in Chinese).