

基于时序融合网络的短波测向误差预测模型

姚佳辰, 胡贇鹏, 张 静, 葛成龙

(信息工程大学, 河南 郑州 450001)

摘要: 针对短波测向误差存在多重周期性、非平稳性及长程依赖相互交织的复杂特征, 进而导致预测精度受限的问题, 提出一种基于时序融合网络(TSF-Net)的短波测向误差预测模型。首先, 针对原始数据中随机缺失与连续缺失并存的特点, 采用分层预处理策略, 通过线性插补与周期相似性填补相结合的方式, 构建规整的高质量输入序列; 其次, 采用并行双流特征提取架构, TimesNet 分支针对性提取测向误差和多周期演化模式, Transformer 分支针对性捕获全局长程依赖与非平稳时变; 最后, 通过自适应加权融合模块, 采用静态与动态双路径权重机制实现双分支特征的互补融合。仿真结果表明, 该模型比表现次优的 TimesNet 模型预测精度提高 6.2%~8.7%。

关键词: 短波测向; 误差预测; 时间序列分析; Transformer 模型; TimesNet 模型

中图分类号: TP391.4

文献标识码: A

文章编号: 1671-0673(2026)03-0253-06

A Shortwave Direction-Finding Error Prediction Model Based on Time-Series Fusion Network

YAO Jiachen, HU Yunpeng, ZHANG Jing, GE Chenglong

(Information Engineering University, Zhengzhou 450001, China)

Abstract: Aiming at the problem that shortwave direction-finding errors exhibit intertwined characteristics of multi-periodicity, non-stationarity and long-range dependencies, which in turn limits the prediction accuracy, a shortwave direction-finding error prediction model based on time-series fusion network (TSF-Net) is proposed. Firstly, in view of the coexistence of random and consecutive missing values in the raw data, a hierarchical preprocessing strategy is designed, combining linear interpolation and periodic-similarity-based imputation to construct well-aligned and regular high-quality input sequences. Secondly, a parallel dual-stream feature extraction architecture is adopted, where the TimesNet branch targetedly extracts the multi-periodic evolution patterns of direction-finding errors, and the Transformer branch targetedly captures the global long-range dependencies and non-stationary time-varying characteristics. Finally, an adaptive weighted fusion module is constructed to realize complementary fusion of dual-branch features through a static and dynamic dual-path weighting mechanism. Simulation results show that the proposed model achieves a 6.2% to 8.7% relative improvement in prediction accuracy compared with the second-best TimesNet baseline model.

Key words: short-wave direction finding; error prediction; time series analysis; Transformer; TimesNet

随着现代战场电磁环境日趋复杂以及对态势感知能力要求的不断提升, 短波测向在军事通信

领域的地位日益提高^[1]。短波测向定位作为获取辐射源信息的关键手段, 其精度直接决定了态势

感知和频谱管理的效能。然而电离层时变特性导致信号传播路径不断变化,使得测向误差呈现非平稳、多周期交织的复杂时序特征。如果能够提前预知测向误差的变化趋势和数值,就可以对实时测向结果进行有效的预补偿,显著提升单站定位的可靠性和连续性。

目前针对短波测向误差预测的专门研究还处于起步阶段,但时间序列预测领域的相关成果可为本文提供重要借鉴。针对时间序列预测的早期研究主要采用单一统计模型,如自回归积分滑动平均模型(Autoregressive Integrated Moving Average, ARIMA)被用于误差的短期平稳成分建模,但其线性与平稳性假设无法描述由电离层扰动引发的非高斯、突变型分量,在复杂时变环境下预测能力有限^[2]。随着深度学习的发展,单一神经网络模型被广泛探索。以长短期记忆网络(Long Short-Term Memory, LSTM)、门控循环单元(Gated Recurrent Unit, GRU)为代表的循环神经网络(Recurrent Neural Network, RNN)通过门控机制捕获序列依赖,在预测中取得了一定效果。然而,RNN及其变体在处理由电离层长时记忆效应导致的极长程依赖时,仍面临梯度衰减与爆炸风险;同时其串行计算特性导致训练效率低下,限制了其对历史远时刻状态的建模能力^[3]。卷积神经网络(Convolutional Neural Network, CNN)因其并行计算能力和局部特征提取优势被引入时序建模,在超小样本场景下显著提升长序列识别精度^[4],但受限于感受野大小,单一CNN架构难以同时捕获不同尺度的全局依赖。Transformer模型凭借全局自注意力机制在长程依赖建模上展现出显著优势^[5],但其对局部上下文和序列内在周期性的不敏感,使其难以有效提取误差序列中的多尺度周期模式,限制了其在复杂误差序列中的应用。TimesNet模型的提出为时序周期性建模提供了新思路。该模型通过快速傅里叶变换(Fast Fourier Transform, FFT)分析序列的固有周期,将一维时序特征重塑为二维张量,从而利用CNN卷积核同时捕获周期内与周期间的演化模式^[6]。

研究表明,TimesNet在多尺度周期建模方面表现突出,为处理具有多周期交织特性的复杂序列提供了有效工具^[7-9]。鉴于单一模型在捕获测向误差复合特征时各有侧重且存在固有局限,研究者开始探索融合多模型的混合架构。这类方法通过将不同模型的优势互补,旨在同时捕获序列的多

种特性。CoRe-GAN将卷积长短期记忆网络(Convolutional LSTM, ConvLSTM)与生成对抗网络(Generative Adversarial Network, GAN)结合,展示了通过对抗训练增强时空特征表达能力的可行性^[10];TCN-BiLSTM混合模型结合时间卷积网络(Temporal Convolutional Network, TCN)与双向长短期记忆网络(Bidirectional Long Short-Term Memory, BiLSTM),验证了局部模式提取与双向时序依赖建模相结合的有效性^[11];ICEEMDAN-VMD-GRU通过改进的自适应噪声完备集合经验模态分解(Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, ICEEMDAN),变分模态分解(Variational Mode Decomposition, VMD)与GRU的结合,有效处理非平稳时序数据中的线性和非线性模式^[12]。

初步研究表明,融合模型能够在一定程度上克服单一模型的短板,实现对时间序列更全面的表征。然而,上述模型在周期性建模与全局依赖捕获上各有侧重,但均未能全面刻画测向误差的复合特征,针对复杂时变环境下的高精度预测方案仍需进一步研究。

针对以上问题,本文提出一种基于时序融合网络(Time-Series Fusion Network, TSF-Net)的短波测向误差预测模型。首先,构建分层数据清洗与规整流程,针对原始数据中随机缺失与连续缺失并存的特点,分别采用线性插补与周期相似性填补方法,得到连续完整的误差序列;其次,设计并行双流特征提取器,分别由TimesNet与Transformer构成,针对性建模多周期演化模式与全局长程依赖;最后,通过自适应加权融合模块,采用静态与动态双路径权重机制实现双分支特征的互补融合,并输出未来多步预测值。

1 问题描述

图1展示了某测向站一段时间的实测误差序列。可以看出,短波测向误差是一个兼具多重周期性、非平稳性、长程依赖及非高斯突变等复杂特性的时序信号。首先,电离层状态的缓慢漂移以及设备老化等因素,会导致误差的统计特性随时间推移发生缓慢变化,呈现出非平稳趋势。其次,电离层还具有一定“记忆”效应,当前状态与历史远时刻状态存在耦合,使得测向误差不仅受近期观测影响,也可能与较远的历史状态相关,图中可观察到相似波动模式的重复出现。最后,当发生

太阳耀斑、地磁暴等突发空间天气事件时,电离层结构在短时间内发生剧烈扰动,导致误差序列中出现尖峰、跳变等非高斯特征。此外,实际采集数据中还存在随机缺失与连续缺失并存的复合型缺陷,如图1中标注的缺失片段。




图1 短波测向误差实测数据时序图

上述复杂特性对预测模型的构建提出了更高要求。在实际应用中,构建高精度预测模型面临以下3方面的问题。1)原始数据质量缺陷。实测误差数据存在随机缺失与连续缺失并存的复合缺陷,而序列的多重周期、长程依赖等特性对数据完整性高度敏感。单一插补方法难以兼顾两类缺失,易引入额外误差,削弱模型特征提取能力。需设计分层预处理策略,构建规整的高质量输入序列。2)复杂特征的耦合建模。序列中多周期局部演化与全局长程依赖相互交织。单一模型无法同时高效捕捉两类耦合特征。3)特征融合的动态适配。现有混合模型多采用静态加权融合,无法适应误差序列统计特性的动态变化,难以实现分支特征的互补增强。综上所述,亟需构建端到端的误差预测解决方案,突破数据规整、特征提取、特征融合环节的技术瓶颈,实现短波测向误差的高精度、高鲁棒性多步预测,为短波侦测智能调度决策优化提供可靠的误差先验信息。

2 短波测向误差预测模型

设计一种基于TSF-Net的短波测向误差预测模型,如图2所示。首先,对原始数据进行插值、异常值处理等预处理,得到时间点分布均匀、适合模型训练的数据;其次,通过并行双分支结构并行提

取双流特征,协同建模序列中的周期性模式与全局依赖关系;最后,基于层次化权重融合机制实现自适应特征融合,将两类互补特征进行整合。




图2 短波测向误差预测模型

2.1 时序输入预处理

原始数据中存在两种类型的缺失情况:1)随机缺失,个别测向站因瞬时干扰导致的误差值缺失,约占总数据点的2.3%;2)连续缺失,特定时间段内多个测向站同时无数据,主要因网络传输中断所致,最长连续缺失时长为4 h。

此外,规定测向误差的合理范围为 $[-20^\circ, 20^\circ]$,超出此范围的数值视为异常。采用以下步骤进行异常值处理:1)范围检测,将误差绝对值大于 20° 的数据标记为异常,此类数据约占总数的1.8%;2)统计分析,计算每个测向站误差的均值 μ_i 和标准差 σ_i ,将超过 $3\sigma_i$ 的数据标记为统计异常;3)相关性验证,检查异常点在其他测向站的表现,若多数测向站均正常,则判定为单站设备异常。

缺失值处理。针对连续缺失和随机缺失等两种不同类型的缺失,采用分层处理策略。随机缺失采用线性插补法填补^[13],公式为

$$x_t = \frac{(t - t_{i-1})x_i + (t_i - t)x_{i-1}}{t_i - t_{i-1}} \quad (1)$$

式中: x_t 为待填补值; x_{i-1} 和 x_i 为前后相邻有效值。连续缺失采用基于周期相似性的填补方法,利用历史同期数据(同一时刻、相似频率)的平均值进行填补。

异常值处理。采用邻近有效值的加权平均进行替换,权重与时间距离成反比^[14]。此外,为消除量纲影响并加速模型训练,对每个测向站的误差序列进行Z-score标准化^[15],即:

$$x' = \frac{x - \mu}{\sigma} \quad (2)$$

式中, μ 和 σ 分别为训练集序列的均值和标准差。标准化后的数据均值为0、方差为1,有助于提升模型训练的稳定性与收敛速度。最终预测结果通过反变换还原至原始误差尺度(单位为 $^\circ$)进行评估。

2.2 并行双流特征提取器

经处理后的输入序列同时送入TimesNet分支

与 Transformer 分支,完成多尺度周期性特征提取及全局上下文依赖捕获。

2.2.1 TimesNet 分支

为有效刻画测向误差中由电离层日变化、季节更替等物理过程驱动的多重周期成分,TimesNet 分支在通用架构基础上进行了以下针对性调整。

1)周期发现。通过快速傅里叶变换分析输入序列的频谱,优先识别与电离层变化强相关的主导周期集合,如日周期($p \approx 1440$ min)、半日周期等,并保留能量最强的 k 个周期用于后续变换。

2)一维到二维变换。对每个周期 p_i ,将一维序列 $\mathbf{X}_{1D} \in \mathbf{R}^{L \times C}$ 重塑为二维张量 $\mathbf{X}_{2D}^{(i)} \in \mathbf{R}^{p_i \times f_i \times C}$ (其中: $f_i = \left\lceil \frac{L}{p_i} \right\rceil$; L 为输入序列的时间步长; C 为每个时间步的特征维度),使得行方向对应周期间演化、列方向对应周期内变化,从而显式建模误差序列中的周期内波动与周期间趋势。

3)TimesBlock 微调。在二维张量上应用多尺度卷积模块,通过调整卷积核尺寸与步长,使其更适配测向误差的时变特性,增强对局部周期模式的敏感度。该分支由 N_{times} 个堆叠的 TimesBlock 构成,输出富含多尺度周期性信息的特征表示 $\mathbf{F}_{\text{times}} \in \mathbf{R}^{L \times D_{\text{model}}}$,其中 D_{model} 为隐藏维度。

2.2.2 Transformer 分支

该分支由 N_{trans} 层改进后的 Transformer 编码器构成。输入序列经嵌入层与可学习位置编码后,依次通过多头自注意力、前馈网络及残差连接,最终输出富含全局依赖与非周期上下文信息的特征表示 $\mathbf{F}_{\text{trans}} \in \mathbf{R}^{L \times D_{\text{model}}}$ 。

为有效捕获测向误差序列中由电离层“记忆效应”引发的长程依赖,以及太阳活动等突发因素导致的非平稳扰动,对标准 Transformer 编码器进行了针对性微调。1)长程依赖增强。通过将注意力头数设置为 8 (高于常规配置),并调整注意力 dropout 比例,增强模型对远距离时间点之间复杂依赖关系的建模能力。2)非平稳适应性。引入可学习的位置编码替代固定位置编码,结合层归一化策略,使模型能自适应误差序列统计特性的时变漂移。3)突发扰动建模。在前馈网络 FFN 中采用 GeLU 激活函数,并强化残差连接,提升对尖峰、跳变等非高斯突变点的响应灵敏度。

2.3 自适应特征融合

本文设计了一种自适应加权特征融合模块,接收两个分支提取的特征 $\mathbf{F}_{\text{times}}$ 和 $\mathbf{F}_{\text{trans}}$,通过双路径

权重计算机制实现特征的智能整合。输出融合特征 $\mathbf{F}_{\text{fused}} \in \mathbf{R}^{L \times D_{\text{model}}}$ 。

融合模块通过静态和动态双路径计算特征权重。静态权重在训练过程中不随输入样本变化,为模型提供基础特征偏好,该偏好反映了模型从整个训练集上学到的各分支特征的平均重要性。通过 Softmax 函数归一化生成静态权重:

$$\mathbf{w}_s = \sigma(\boldsymbol{\theta}) = \frac{\exp(\theta_i)}{\exp(\theta_1) + \exp(\theta_2)} \quad (3)$$

式中: $\boldsymbol{\theta} = [\theta_1, \theta_2] \in \mathbf{R}^2$ 为定义的学习参数向量; θ_1 、 θ_2 分别代表 TimesNet 分支和 Transformer 分支的偏好参数; $i = 1, 2$; 在模型初始化时,将参数 $\boldsymbol{\theta}$ 赋予初始值 $[0, 0]$,并在训练过程中通过梯度下降进行优化。

动态权重基于输入特征内容通过门控网络实时计算: $\mathbf{w}_d = \text{Softmax}(G(\mathbf{h}_c; \Phi))$ 。其中: $\mathbf{h}_c = [\mathbf{F}_{\text{times}} | \mathbf{F}_{\text{trans}}] \in \mathbf{R}^{2D_{\text{model}}}$ 表示特征拼接, $|$ 表示拼接操作; 门控网络 G 采用两层全连接结构,激活函数使用 ReLU。

最终特征权重通过静态与动态权重的组合获得:

$$\mathbf{w}_f = (1 - \alpha)\mathbf{w}_s + \alpha\mathbf{w}_d \quad (4)$$

式中,参数 $\alpha \in [0, 1]$ 为控制动态权重比例。该策略既保留了模型的基础特征偏好,又赋予其对输入特征的适应性。

3 仿真验证与结果分析

为全面验证本文所提模型在短波测向误差预测任务上的有效性、优越性与鲁棒性,设计并实施了系统的数值仿真。基于真实的监测数据,通过离线训练与测试的方式,将本文模型与一系列先进的基准模型进行对比,并从多角度分析其性能。

3.1 仿真条件

仿真所用硬件条件: ASUS M6400RC 工作站, 16 核 3.2 GHz CPU, RTX3050 4 GB 显卡; 软件框架: Windows 11 (x64) 操作系统, Python 3.11.10 编程语言, PyTorch 1.5.1 学习框架。

3.2 仿真设置

本仿真采用的数据集来源于某无线电监测网 2018—2019 年 7 个测向站的实际采集数据,经处理后,得到 55 955 条规整的时间序列记录,时间跨度为 2018-10-07—2019-10-31。仿真性质为回溯性预测数值仿真,即在已知完整历史序列的前提下,模拟实时滚动预测场景,以评估模型的泛化性能。

数据集按时间顺序以7:2:1的比例划分为训练集、验证集和测试集,确保测试集代表未来的、模型未见过的数据,以模拟实际应用中的预测情景。

基准模型选取以下模型进行对比:传统模型ARIMA、经典深度学习模型LSTM、先进Transformer变体Informer、Autoformer以及本模型的独立组件TimesNet、Transformer。

评价指标为均方根误差(Root Mean Square Error, RMSE)和平均绝对误差(Mean Absolute Error, MAE),计算公式如下:

$$E_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (5)$$

$$E_{\text{MA}} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (6)$$

式中: y_i 为真实值; $\hat{y}_i$ 为模型预测值; N 为测试样本数。RMSE强调较大预测误差的惩罚,对异常值较为敏感;MAE则反映预测误差的平均绝对水平,更具鲁棒性。二者结合可全面评估模型的预测精度与稳定性。

参数设置如下,输入长度 $L = 144$,对应24 h数据,预测长度 $H \in \{1, 3, 6, 12\}$,隐藏维度 $D_{\text{model}} = 512$,TimesNet与Transformer分支层数均为3,注意力头数为8,批大小为32,初始学习率 1×10^{-4} ,使用Adam优化器进行训练。

3.3 融合策略消融仿真

为验证本文提出的自适应加权融合策略的有效性,并探讨不同融合方式对模型性能的影响,设计两组对比仿真。

3.3.1 动态权重比例 α 的影响

为探究动态权重在融合中的重要性,调整控制动态权重占比参数 α ,观察模型在 $H = 1$ 下的表现变化。仿真结果如图3所示。




图3 动态权重比例 α 对预测性能的影响($H=1$)

由图3可知,当 $\alpha = 0.5$ 时模型表现最优,说明融合过程中调整较为均衡。纯静态或纯动态均不如二者结合,验证了融合策略中“基础偏好+输入

适应”的双重机制的有效性。动态权重占比过高($\alpha \geq 0.9$)会导致性能下降,可能因过度依赖输入而产生过拟合。

3.3.2 不同融合方式对比

比较4种融合策略:1)简单拼接,将TimesNet与Transformer特征沿通道维度拼接,后接全连接层;2)简单平均,对两路特征逐元素取平均值;3)静态加权,仅使用可学习静态权重 w_s 进行加权融合;4)自适应加权,即本文提出的静态与动态权重结合的融合方式。所有仿真使用相同的输入长度 $L = 72$,预测长度 $H = 1$,其余超参数保持一致。

表1为4种融合策略的仿真结果。

表1 不同融合方式性能对比

单位:(°)

融合方式	RMSE	MAE
简单拼接	0.71	0.56
简单平均	0.70	0.59
静态加权	0.66	0.54
自适应加权	0.52	0.36

仿真结果表明:简单拼接与平均方式性能相当,说明二者均未充分利用特征互补性。静态加权较前两者有明显提升,表明可学习权重能更好地平衡两路特征贡献。自适应加权进一步优化了RMSE,说明动态权重机制能根据输入特征灵活调整融合比例,提升模型适应性。

3.4 总体性能对比分析

表2为各模型在不同预测长度下的性能。

表2 各模型在不同预测长度下的对比仿真结果

单位:(°)

模型	RMSE/MAE			
	$H=1$	$H=3$	$H=6$	$H=12$
ARIMA	0.78 / 0.65	1.23 / 0.93	1.85 / 1.51	1.99 / 1.60
LSTM	0.63 / 0.46	0.88 / 0.66	1.33 / 1.01	1.42 / 1.10
Transformer	0.59 / 0.42	0.76 / 0.56	1.01 / 0.85	1.20 / 0.92
Informer	0.55 / 0.38	0.79 / 0.51	1.13 / 0.86	1.25 / 0.96
Autoformer	0.57 / 0.41	0.77 / 0.57	0.94 / 0.89	1.22 / 0.94
TimesNet	0.56 / 0.38	0.72 / 0.52	0.81 / 0.77	1.15 / 0.88
TSF-Net	0.52 / 0.36	0.67 / 0.48	0.76 / 0.71	1.05 / 0.81

在实际监测数据集上的仿真结果表明,基于TSF-Net的预测模型在RMSE与MAE指标上均显著优于基准模型。相比次优的TimesNet模型,在1步、3步、6步和12步预测中,RMSE分别降低约7.1%、6.9%、6.2%和8.7%,MAE分别降低约5.3%、7.7%、7.8%和8.0%;与经典LSTM模型相比,RMSE

降低幅度最高达 21.4%。由表 2 可以看出:1)深度学习模型显著优于传统模型。所有深度学习模型(LSTM、Transformer 系列)的 RMSE/MAE 均远低于 ARIMA,证实了深度学习方法处理非线性复杂序列的有效性。2)Transformer 家族优于 LSTM。得益于自注意力机制对长程依赖的捕获能力,Transformer 及其变体普遍优于 LSTM。3)TimesNet 在周期性任务中的优势。单独的 TimesNet 模型在多数情况下优于 Transformer、Informer 和 Autoformer,验证了其专门为多重周期性设计的二维建模架构在处理短波测向误差这类强周期序列时的优势。这与“TimesNet 在多变量股票预测中性能最优”的结论内在一致,体现了其强大的多尺度模式捕捉能力。4)融合模型的优越性。本文提出的 TSF-Net 在所有预测长度上均取得了最佳性能,强有力地证明了 TimesNet 的周期性分析能力与 Transformer 的全局上下文依赖捕获能力形成了有效互补。当序列中同时存在清晰的周期模式和突发的非周期事件时,融合模型能更全面、更稳健地进行建模和预测。

4 结束语

针对短波测向误差序列预测问题,设计了一种基于时序融合网络 TSF-Net 的短波测向误差预测模型。通过双分支结构分别提取序列的周期性特征与全局依赖特征并进行有效融合,从而全面刻画了误差序列的复杂动态。在实际监测数据集上的仿真表明,基于 TSF-Net 的预测模型在精度上显著优于各基准模型,模型架构设计合理。未来的研究工作可以从以下几个方面展开:1)探索更先进的融合机制,如引入注意力门控来自适应加权两个分支的特征;2)融入多源外部信息,如太阳活动指数、地磁指数等,构建多变量预测模型;3)网络轻量化与边缘部署,研究知识蒸馏、剪枝等技术,以适配对实时性要求高的边缘计算场景。

参考文献:

[1] 袁帅克.短波无线电测向定位技术研究[D].沈阳:沈阳理工大学,2023:1-72.
[2] ATHANASOPOULOS G, HYNDMAN R J, KOURENTZES N, et al. Forecast reconciliation: a review[J]. Monash Econometrics and Business Statistics Working Papers,

2023;40(2). DOI:10.1016/j.ijforecast.2023.10.010.
[3] IKEDA S, ITO T, HASEBE K, et al. A comparative study on long-term cryptocurrency price prediction using LSTM, GRU, and Bi-LSTM[J]. Journal of Robotics, Networking and Artificial Life, 2025,11(1):49-53.
[4] LI C, ZHENG X W, CHEN C Q, et al. Tiny data is sufficient: a generalizable CNN architecture for temporal domain long sequence identification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025,36(7):12977-12990.
[5] LIU S M. LTR-Net: a deep learning-based approach for financial data prediction and risk evaluation in enterprises[J]. PLoS One, 2025,20(8):No.e0328013.
[6] ZHOU J Q, YANG X H, REN Z. SCConv-denoising diffusion probabilistic model anomaly detection based on TimesNet[J]. Electronics, 2025,14(4):No.746.
[7] ONUR CAKIROGLU M, KURBAN H, BUXTON E, et al. A novel discrete time series representation with de bruijn graphs for enhanced forecasting using TimesNet[J]. IEEE Access, 2025,13:123182-123198.
[8] LIN R H, CHEN S, WU B D, et al. WaveTimes: short-term load forecast based on wavelet decomposition and improved TimesNet[J]. Chinese Journal of Electronics, 2025,34(6):1911-1923.
[9] TING C C, WU K T, LIN H C, et al. MixModel: a hybrid TimesNet-informer architecture with 11-dimensional time features for enhanced traffic flow forecasting[J]. Mathematics, 2025,13(19):No.3191.
[10] BYUN G, YANG H, RAZA S M, et al. Generative spatio-temporal image exploitation for datacenter traffic prediction[J]. Computer Networks, 2024,254:No.110755.
[11] MAHMOUD A, MOHAMMED A. Leveraging hybrid deep learning models for enhanced multivariate time series forecasting[J]. Neural Processing Letters, 2024,56(5):No.223.
[12] SATHE A M, SUPRAJA R, THOMAS A A. Enhancing agricultural sustainability: time series forecasting with ICEEMDAN-VMD-GRU for economic-resilience[J]. Results in Engineering, 2025,27:No.106423.
[13] 熊巍,王娟,潘晗,等.多重稳健的高维缺失数据插补研究[J].统计与信息论坛,2023,38(2):3-15.
[14] CHANDOLA V, BANERJEE A, KUMAR V. Anomaly detection: a survey[J]. ACM Computing Surveys, 2009,41(3):1-58.
[15] HASTIE T, TIBSHIRANI R, FRIEDMAN J. The elements of statistical learning: data mining, inference, and prediction[M]. 2nd ed. New York, USA: Springer, 2009:1-745.

(编辑:冯春)