



基于参数优化VMD和改进BiLSTM的低轨卫星网络业务预测方法

佟谣, 刘波, 齐小刚

引用本文:

佟谣, 刘波, 齐小刚. 基于参数优化VMD和改进BiLSTM的低轨卫星网络业务预测方法[J]. *智能系统学报*, 2026, 21(3): 627-638.

TONG Yao, LIU Bo, QI Xiaogang. A traffic prediction method for a low earth orbit satellite network based on parameter-optimized VMD and improved BiLSTM[J]. *CAAI Transactions on Intelligent Systems*, 2026, 21(3): 627-638.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202508026>

您可能感兴趣的其他文章

面向机器学习的分布式并行计算关键技术及应用

Key technologies and applications of distributed parallel computing for machine learning
智能系统学报. 2021, 16(5): 919-930 <https://dx.doi.org/10.11992/tis.202108010>

基于F1值的非极大值抑制阈值自动选取方法

Automatic selection method of non-maximum suppression threshold based on F1 score
智能系统学报. 2020, 15(5): 1006-1012 <https://dx.doi.org/10.11992/tis.202006056>

基于生成对抗网络的机载遥感图像超分辨率重建

Super-resolution reconstruction of airborne remote sensing images based on the generative adversarial networks
智能系统学报. 2020, 15(1): 74-83 <https://dx.doi.org/10.11992/tis.202002002>

大数据背景下高校招生策略预测

The strategy of college enrollment predicted with big data
智能系统学报. 2019, 14(2): 323-329 <https://dx.doi.org/10.11992/tis.201709011>

快速双非凸回归算法及其电力数据预测应用

Fast double nonconvex regression algorithm for forecast of electric power data
智能系统学报. 2018, 13(4): 665-672 <https://dx.doi.org/10.11992/tis.201708033>

高斯核函数卷积神经网络跟踪算法

Convolutional neural network tracking algorithm accelerated by Gaussian kernel function
智能系统学报. 2018, 13(3): 388-394 <https://dx.doi.org/10.11992/tis.201612040>

DOI: 10.11992/tis.202508026

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20260305.1546.002>

基于参数优化 VMD 和改进 BiLSTM 的低轨 卫星网络业务预测方法

佟谣^{1,2}, 刘波³, 齐小刚^{1,2}

(1. 西安电子科技大学 数学与统计学院, 陕西 西安 710071; 2. 西安市信息网络优化与数学方法重点实验室, 陕西 西安 710071; 3. 空军工程大学 信息与导航学院, 陕西 西安 710003)

摘要: 低地球轨道卫星业务预测对于缓解拥塞问题和改善资源调度至关重要。为进一步提高业务预测精度, 提出了基于参数优化 VMD (variational mode decomposition) 和改进 BiLSTM 的预测方法 VPI-TPIB。该方法包含两个核心模型: 基于改进麻雀搜索算法参数优化的变分模态分解 (variational mode decomposition based on parameter optimization of improved sparrow search algorithm, VPI) 模型和基于改进双向长短期记忆网络的业务预测 (traffic prediction based on improved bidirectional long short-term memory network, TPIB) 模型。在 VPI 模型中, 采用引入 Tent 混沌映射和高斯变异改进后的麻雀搜索算法对 VMD 关键参数的选择进行优化, 从而有效提升数据分解效果; 在 TPIB 模型中, 通过引入自注意力机制改进 BiLSTM, 实现对分解数据的动态特征权重分配和双向时序建模, 提高模型预测精度。实验结果表明, 与基准 LSTM 模型相比, 所提方法在两个真实数据集上的 MAE 分别降低了 42.64% 和 81.59%。

关键词: 低地球轨道卫星网络; 业务流量; 业务预测; 机器学习; 变分模态分解; 改进麻雀搜索算法; 自注意力机制; 双向长短期记忆网络

中图分类号: TP181 文献标志码: A 文章编号: 1673-4785(2026)03-0627-12

中文引用格式: 佟谣, 刘波, 齐小刚. 基于参数优化 VMD 和改进 BiLSTM 的低轨卫星网络业务预测方法 [J]. 智能系统学报, 2026, 21(3): 627-638.

英文引用格式: TONG Yao, LIU Bo, QI Xiaogang. A traffic prediction method for a low earth orbit satellite network based on parameter-optimized VMD and improved BiLSTM [J]. CAAI transactions on intelligent systems, 2026, 21(3): 627-638.

A traffic prediction method for a low earth orbit satellite network based on parameter-optimized VMD and improved BiLSTM

TONG Yao^{1,2}, LIU Bo³, QI Xiaogang^{1,2}

(1. School of Mathematics and Statistics, Xidian University, Xi'an 710071, China; 2. Xi'an Key Laboratory of Information Network Optimization and Mathematical Methods, Xi'an 710071, China; 3. College of Information and Navigation, Air Force Engineering University, Xi'an 710003)

Abstract: Traffic prediction in low earth orbit satellite networks is critical for mitigating congestion and optimizing resource allocation. To further enhance prediction accuracy, a prediction method based on parameter-optimized variational mode decomposition (VMD) and an improved bidirectional long short-term memory (BiLSTM) network is proposed. The method comprises two core models: a parameter-optimized VDM model based on an improved sparrow search algorithm (VPI) and a traffic prediction model based on an improved BiLSTM network (TPIB). In the VPI model, an improved sparrow search algorithm incorporating Tent chaotic mapping and Gaussian mutation is adopted to optimize key parameters for VMD, thereby improving decomposition performance. In the TPIB model, a self-attention mechanism is introduced to enhance BiLSTM, enabling dynamic feature weight allocation for decomposed data and bidirectional temporal modeling, thereby improving prediction accuracy. Experimental results show that, compared with the baseline LSTM model, the proposed method reduces the mean absolute error (MAE) by 42.64% and 81.59% on the two real-world datasets, respectively.

Keywords: low earth orbit satellite network; service traffic; traffic prediction; machine learning; variational mode decomposition; improved sparrow search algorithm; self-attention mechanism; bidirectional long short-term memory network

收稿日期: 2025-08-22. 网络出版日期: 2026-03-06.

基金项目: 国家自然科学基金项目 (62372354, 62373291); 航空科学基金项目 (2024Z071081003, 2024M066081001).

通信作者: 齐小刚. E-mail: xgqi@xidian.edu.cn.

近年来, 低地球轨道 (low earth orbit, LEO) 卫星因其广泛的覆盖范围和低时延特性, 已成为重要的太空通信节点^[1-2]。然而, 随着用户流量的快

速增长, 带宽有限、流量分布不均和变化频繁等问题不断加剧, 导致网络拥塞, 严重影响通信服务质量 (quality of service, QoS)^[3-5]。尽管高效的资源分配能在一定程度上缓解这些问题, 但其执行时间较长, 且在需求突增时无法迅速响应。相比之下, 运用卫星流量数据提前预测地面业务带宽需求能为资源调度争取更多准备时间, 从而降低拥塞发生的概率并有效提升 QoS^[6]。因此, 设计一种精准有效的 LEO 卫星网络业务预测方法具有重要的理论意义和应用价值。

随着复杂网络的快速发展, 卫星流量数据呈现出显著的非线性、自相似性、长期依赖性以及波动性等复杂特征^[7-10]。这些特征给业务预测带来了前所未有的挑战。为了解决这一问题, 文献 [11] 通过自回归滑动平均 (auto-regression and moving average, ARMA) 模型识别数据相关性来预测卫星业务带宽需求。尽管该方法所需的数据量较小, 但由于其依赖统计和平稳性假设, 导致模型预测精度较低且难以有效捕捉数据中的强非线性特征^[12]。相比之下, 深度学习模型能够捕获网络流量随时间变化的非线性动态模式, 从而提高预测准确性。其中, 能够有效缓解梯度消失或爆炸问题的长短期记忆网络 (long short-term memory, LSTM) 模型已被广泛应用于业务预测^[13-14], 但其局限性在于仅能从前向学习序列信息。为了解决这一问题, 文献 [15] 提出采用双向长短期记忆网络 (bidirectional long short-term memory, BiLSTM), 通过同时利用前向和后向特征信息来提取长期依赖关系, 提高业务预测精度。然而, 卫星流量数据受自然环境突变与人类生活规律等因素的影响, 往往表现出较强的波动性和自相似性。单一的 BiLSTM 模型对数据波动性特征处理能力不足且难以识别序列中的重要信息, 如果用于预测业务数据, 会导致精度提升有限。

为解决数据波动性特征处理问题, 文献 [16] 运用经验模态分解 (empirical mode decomposition, EMD) 处理数据, 以降低其波动性, 但 EMD 存在模态混叠和端点效应问题, 且分解后的本征模态函数 (intrinsic mode functions, IMFs) 收敛效果不佳, 因此还需引入其他数据分解算法对业务数据波动性进行处理。变分模态分解 (variational mode decomposition, VMD)^[17] 通过约束变分问题有效避免了 EMD 的分解缺陷, 同时具备优异的序列数据处理性能。基于此, 文献 [18] 提出 VMD-BiLSTM 的多尺度组合预测方法, 结果表明预测精度相较于单一模型有所提高, 但因 VMD 分解效果受参数影响严重, 传统人工经验所确定的参数缺乏理

论依据, 难以保证 VMD 分解数据的有效性。对于序列数据中重要信息识别的问题, 文献 [19] 提出在 BiLSTM 模型之后引入注意力机制来增强自相似特征的捕捉能力。然而, 由于 BiLSTM 模型本身对自相似关系的识别能力有限, 且注意力机制被置于模型末端, 导致该方法整体优化效果不够理想。

为解决上述研究问题并进一步提升业务预测精度, 本文在 VMD 和 BiLSTM 的基础上, 提出了一种基于 VPI-TPIB 的业务预测方法。首先将卫星流量数据输入至基于改进麻雀搜索算法参数优化的变分模态分解 (variational mode decomposition based on parameter optimization of improved sparrow search algorithm, VPI) 模型中, 通过设计的改进麻雀搜索算法 (improved sparrow search algorithm, ISSA) 来动态优化 VMD 的关键参数, 实现对业务流量数据自适应的波动特征处理, 降低分解误差; 随后, 为充分挖掘数据特性, 将分解得到的 IMFs 分量输入至基于改进双向长短期记忆网络的业务预测 (traffic prediction based on improved bidirectional long short-term memory network, TPIB) 模型中, 通过将自注意力机制 (self-attention, SA) 前置, 以增强序列信息的识别能力, 提高预测精度; 最终通过全连接层进行特征融合并输出预测结果。

综上所述, 本文的主要贡献包括: 1) VPI 模型的提出。模型在麻雀搜索算法 (sparrow search algorithm, SSA) 的基础上增加了 Tent 混沌映射和高斯变异机制, 以优化算法全局搜索与局部搜索能力。随后运用改进算法自适应优化 VMD 参数, 解决了参数依赖人工经验而无法有效分解数据的问题, 从而精准提取业务流量数据波动特征并抑制分解误差。2) TPIB 模型的设计。本文提出了 SA 机制先动态计算分解序列特征权重, BiLSTM 后建模长期依赖关系的网络结构, 显著提升了模型对数据特征的学习能力。3) “分解-预测”协同框架的构建。通过将 VPI 模型与 TPIB 模型相结合, 实现了特征处理与预测建模的协同优化。实验结果表明, VPI-TPIB 模型在两个真实数据集上均表现出良好的预测性能, 验证了该模型的泛化能力, 为后续相关方法研究提供了有价值的参考。

1 VPI-TPIB 方法

1.1 总体框架

LEO 卫星业务流量复杂的数据特征构成了极具挑战的预测场景, 为进一步提高业务预测精度, 本文提出了预测方法 VPI-TPIB。该方法流程如图 1 所示。

VPI-TPIB 具体步骤如下:

步骤 1 数据预处理。归一化处理流量数据 $X = \{x_1, x_2, \dots, x_n\}$, 使其保持较小量级, 具体处理过程为

$$X' = \frac{X - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: X' 为处理后的流量数据, x_{\max} 和 x_{\min} 分别为原始数据中的最小值与最大值, 再将经归一化处理后的数据按指定比例分成两部分, 训练集用于

模型学习, 测试集用于评估模型性能。

步骤 2 VPI 阶段。基于 VMD 核心思想构建业务流量变分问题并通过 ISSA 算法自适应优化 VMD 参数, 最后输出分解后的 IMFs 集合。

步骤 3 TPIB 阶段。将 IMFs 输入至 SA 机制中提取数据关键信息并利用 BiLSTM 模型捕获长期依赖关系, 训练完成后再通过全连接层进行综合预测。最终叠加各 IMFs 预测数据并反归一化处理, 得到预测结果。

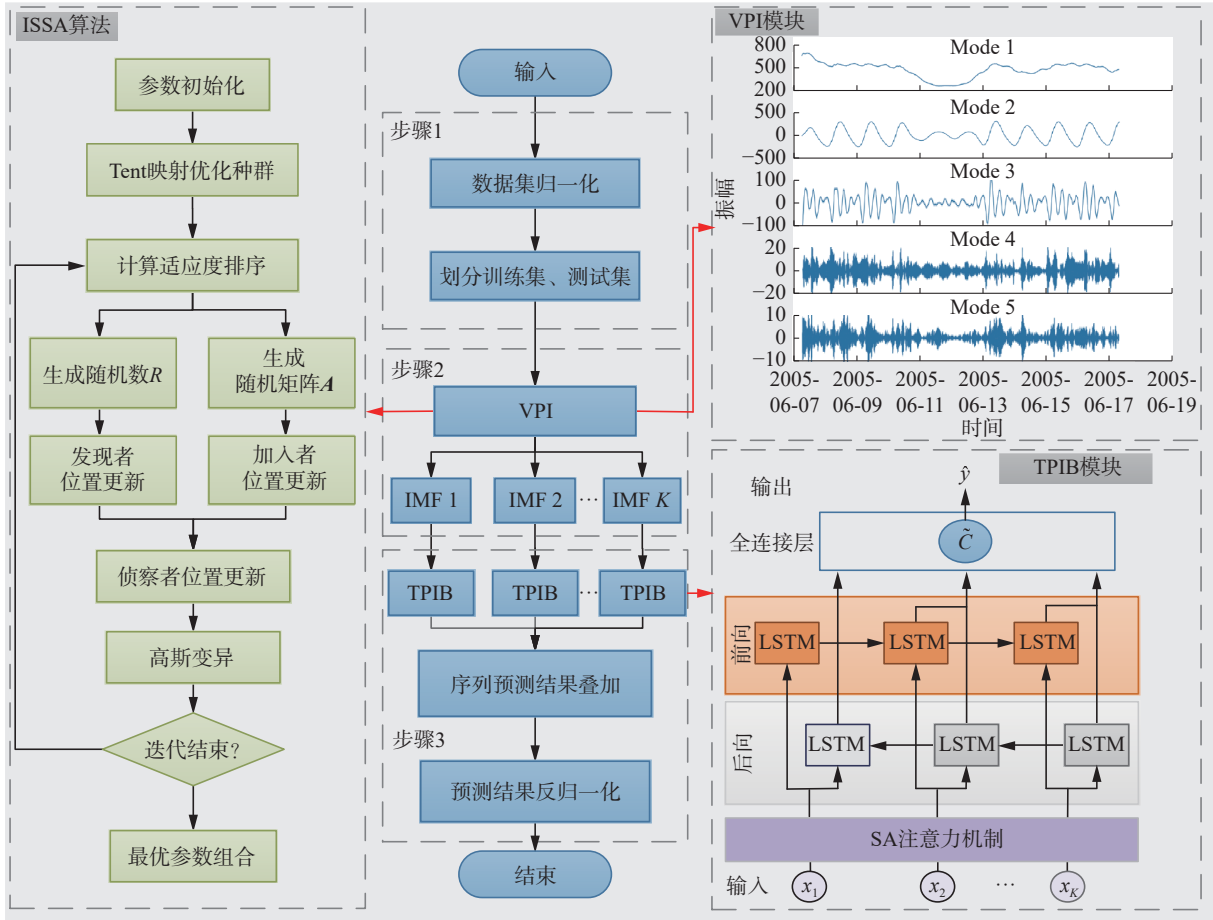


图 1 VPI-TPIB 方法流程

Fig. 1 VPI-TPIB method process

1.2 VPI 模型

在 LEO 卫星通信系统中, 业务流量数据受空间链路切换的路由震荡以及多径效应等因素影响, 呈现出显著的波动性特征。为此, 本文采用 VMD 方法对业务流量进行数据分解。然而, VMD 的分解效果极易受算法中分解数量 K 和惩罚因子 α 的影响^[20]。一旦设置不当容易造成分解过程的随机性, 让分解后的序列存在过分解或欠分解的情况, 进而增大预测误差。当 K 值过大时, 在分解过程中可能将卫星信道噪声或瞬时干扰误判为有效模式; 而 K 值过小则可能遗漏重要的业务特征。类似地, 不恰当的 α 值会引发分解结果过度

平滑或模式混叠问题。同时, 在 LEO 卫星通信场景下, 手动设置参数会导致模型无法有效应对流量短期增长等不同数据环境, 降低模型的泛化性。针对上述问题, 本文提出改进麻雀搜索算法动态优化 VMD 参数组合的模型, 实现根据业务流量数据特征自动调整 K 和 α 参数, 在保证分解质量的同时, 还能有效应对业务流量的数据波动情况。

1.2.1 业务流量数据的变分模态分解

VMD 能够将业务流量数据分解为多个中心频率不同但相对平稳的分量, 从而有效降低数据波动性。为避免分解后的 IMFs 分量出现混叠现

象,在分解前需构建约束变分问题,条件要求分解后的 IMF_s 集合 {u_k} 整体求和等于业务流量数据。具体公式为

$$\begin{cases} \min_{\{u_k, \omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left(\left(\varphi(t) + \frac{j}{\pi t} \right) * u_k(t) \right) e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^K u_k = X' \end{cases} \quad (2)$$

式中: $\varphi(t)$ 为狄拉克分布函数, K 为目标寻优的参数分解数量, $\{\omega_k\}$ 为求解后最小中心频率集合, $u_k(t)$ 和 $\omega_k(t)$ 为业务流量数据分解产生的第 k 个分量和其所对应的频率。

由于约束变分问题求解困难,故引入拉格朗日变换和惩罚因子 α 将式 (2) 转变为无约束变分问题,方便运用迭代算法进行求解,转换结果为

$$L(\{u_k, \omega_k, \lambda\}) = \alpha \sum_{k=1}^K \left\| \partial_t \left(\left(\varphi(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right) e^{-j\omega_k t} \right\|_2^2 + \left\| X' - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda, X' - \sum_{k=1}^K u_k(t) \right\rangle$$

最后,通过交替方向乘子法计算 {u_k}、{ω_k} ,寻求变分问题最优解,从而将业务流量数据分解为 IMF_s 集合 {u_k} ,更新过程为

$$\begin{cases} u_k^{n+1}(\omega) = \frac{\hat{X}'(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \\ \omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \end{cases}$$

式中: n 为当前求解迭代次数, i 为当前迭代次数下遍历所有 IMF_s 的序号, ω 表示连续的频率值, $\hat{X}'(\omega)$ 、 $\hat{u}_k(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别为 $X'(t)$ 、 $u_k(t)$ 、 $\lambda(t)$ 的傅里叶变换形式。

1.2.2 改进麻雀搜索算法

对于参数组合 $[K, \alpha]$ 的选取,群体智能优化算法因其全局搜索能力而优于人工调参方法。相较于其他智能优化算法,SSA 算法具有优越的寻优性能并且能够通过分层搜索机制动态适应流量突变,实现 VMD 参数的自适应优化。然而,SSA 算法存在两个缺陷:1) 种群初始位置通过 $[0, 1]$ 均匀随机分布生成,可能导致个体搜索空间分布不均,影响全局探索效果;2) 局部搜索能力较弱,易陷入局部最优,降低求解精度。这些缺陷会直接影响 VMD 的参数优化效果,进而降低业务数据的分解质量。为此,本文对 SSA 算法进行改进,引入 Tent 混沌映射优化初始种群分布并采用高斯变异机制提升局部搜索精度,从而全面提高算法的收敛速度与寻优能力。

1) Tent 混沌映射优化初始种群

Tent 映射^[21] 具有高度的初始条件敏感性和长期行为不可预测性,展现出显著的混沌特性。与 Logistic^[22]、Chebyshev^[23] 和 Circle^[24] 映射相比,其在收敛速度和遍历性方面表现更优。因此,本文利用 Tent 映射规则生成混沌数并映射到解空间中以改进种群初始值,使其在区间内取值均匀且不可预测。混沌数迭代过程为

$$p_{i+1} = f(p_i) = \begin{cases} \beta p_i, & p_i \in [0, \beta) \\ \frac{1-p_i}{1-\beta}, & p_i \in [\beta, 1] \end{cases} \quad (3)$$

式中: p_i 为第 i ($i \in [1, t_{\max}]$) 次迭代的混沌数, $\beta \in (0, 1)$ 为混沌映射的控制参数, t_{\max} 为 Tent 映射最大迭代次数。

2) 高斯变异

本文在 SSA 算法基础上,在每次个体位置更新后,对当前最优个体施加服从正态分布的微小扰动,从而提升算法局部搜索能力。具体公式为

$$M(q) = q(1 + N(0, 1)) \quad (4)$$

式中: q 为原来的种群个体值; $N(0, 1)$ 为期望为 0, 标准差为 1 的正态分布随机数; $M(q)$ 为高斯变异后的个体值。

1.2.3 VPI 模型构建

为自适应优化 VMD 的关键参数 $[K, \alpha]$, 本文提出了 VPI 模型,该模型不仅为参数的选择提供了理论依据,同时显著提升了模型对不同流量数据环境的适应能力,有效抑制了解析结果的随机性。优化后的 VMD 将原始业务流量序列分解为若干个保留数据变化趋势特征的 IMF_s, 显著降低了数据波动性,为后续业务流量预测提供了更具表征能力的输入特征。VPI 模型流程如图 2 所示。

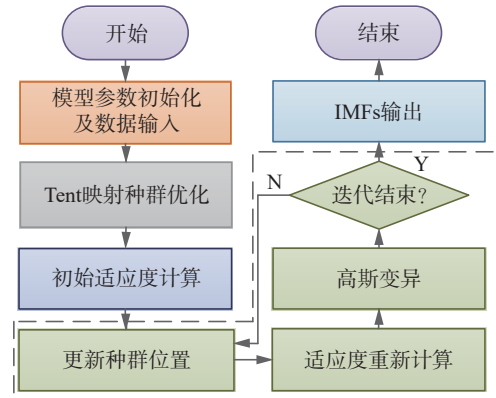


图 2 VPI 模型流程

Fig. 2 VPI model flow

VPI 模型流程具体步骤如下:

步骤 1 模型参数初始化及数据输入。设置麻雀种群个数 N 、 $[K, \alpha]$ 搜索集合和 ISSA 算法最

大迭代次数 T_{max} 等参数并初始化种群个体。同时, 输入预处理后的业务流量数据 $X' = \{x_1', x_2', \dots, x_n'\}$ 。

步骤 2 Tent 映射种群优化。运用式 (3) 计算种群个体混沌数并映射至 $[K, \alpha]$ 解空间作为麻雀位置。

步骤 3 初始适应度计算。遍历种群中所有个体, 根据其位置参数, 利用式 (2) 的变分问题分解业务流量数据, 并计算分解后的 IMF_s 样本熵平均值作为该个体的适应度值。

步骤 4 更新种群位置。根据适应度大小, 更新 ISSA 算法中所有个体位置。

步骤 5 适应度重新计算。根据步骤 4 更新后的麻雀位置重新计算适应度值并更新全局最优解。

步骤 6 高斯变异。运用式 (4) 对当前最优个体施加高斯扰动, 随后重新计算其适应度并更新全局最优解。

步骤 7 IMF_s 输出。若迭代次数大于 T_{max} , 则输出最优个体参数 $[K, \alpha]$ 以及分解后的 IMF_s 集合 $\{u_k\}$ 。否则, 以当前参数重复步骤 4~6。

1.3 TPIB 模型

受 LEO 卫星网络动态拓扑结构、链路状态变化以及地面用户日周期等循环生活行为影响, 业务流量数据呈现出明显的非线性、自相似与长期依赖特征。VPI 模型虽能提取相对平稳的 IMF_s 序列, 但因其他特征干扰, 直接预测效果仍有限。为此, 本文选用 BiLSTM 网络作为基础模型, 通过其双向传播路径同时捕获历史与未来信息, 有效建模序列依赖关系。然而, 随着各 IMF_s 输入长度的增加, 单一 BiLSTM 模型难以准确识别关键节点的重要信息, 进而影响模型预测精度。

注意力机制可以通过计算序列内部所有位置关联权重, 捕获数据间的自相似关系^[25-26]。从常用的注意力机制来看, SE(squeeze-and-excitation) 注意力机制依赖通道压缩操作, 容易造成业务数据信息损失^[27]; 而 CBAM(convolutional block attention module) 注意力机制主要针对空间特征设计, 对时序信号的敏感性不足^[28]。相比之下, SA 机制通过动态捕捉数据内部的自相似关系, 不仅消除了异常数据影响, 还加强了对重要时间步的关注, 这一特性适用于 LEO 卫星业务流量的统计特征^[29]。因此, 本文在 BiLSTM 的基础上引入 SA 机制来增强关键信息提取能力。与 SA 机制置于 BiLSTM 之后相比, 置于模型之前能减缓 BiLSTM 识别 IMF_s 序列重要信息的压力, 有助于分析 IMF_s 中的关键特征, 提升预测精度。根据以上分析, 本文提出了 TPIB 模型, 对 VMD 分解后的 IMF_s 进行预测。

1.3.1 IMF_s 的关键信息提取

SA 机制通过将更多的权重分配在重要的数据上从而达到对 IMF_s 关键信息的获取。在此阶段, 首先将 K 个 IMF_s 序列按行排列形成矩阵 U , 输入至 SA 机制中。 T 为时间步长, 矩阵 U 表达式为

$$U = \begin{bmatrix} u_1(1) & u_1(2) & \cdots & u_1(T) \\ u_2(1) & u_2(2) & \cdots & u_2(T) \\ \vdots & \vdots & \ddots & \vdots \\ u_K(1) & u_K(2) & \cdots & u_K(T) \end{bmatrix} \in \mathbf{R}^{K \times T} \quad (5)$$

随后, 通过线性变换生成查询 Q 、键 K 和值 V 空间, 这些空间分别表示每个 IMF_s 模态与其他模态的相似性关系、模态间相似程度的量化关系和 IMF_s 的实际信息, 处理过程为

$$\begin{cases} Q = UW_q + b_q \in \mathbf{R}^{K \times d} \\ K = UW_k + b_k \in \mathbf{R}^{K \times d} \\ V = UW_v + b_v \in \mathbf{R}^{K \times d} \end{cases} \quad (6)$$

式中: W_q 、 W_k 和 W_v 为可学习的权重矩阵, b_q 、 b_k 和 b_v 为偏置项, d 为隐藏维度。

接着, 运用缩放点积注意力计算 IMF_s 间相关性, 具体公式为

$$A = \text{Softmax} \left(\frac{QK^T}{\sqrt{d}} \right) \in \mathbf{R}^{K \times K} \quad (7)$$

式中 A_{ij} 表示第 i 个 IMF_s 对第 j 个 IMF_s 依赖权重。

最后, 加权聚合值向量, 得到全局交互后的模态表示 Z 并输入至 BiLSTM 中, 加权过程为

$$Z = AV \in \mathbf{R}^{K \times d} \quad (8)$$

1.3.2 TPIB 模型构建

TPIB 模型通过在 BiLSTM 模型之前引入 SA 机制增强对时间步间相关性的建模能力, 从而降低 BiLSTM 对关键序列特征的提取难度, 提升整体预测精度。该模型结构如图 3 所示。

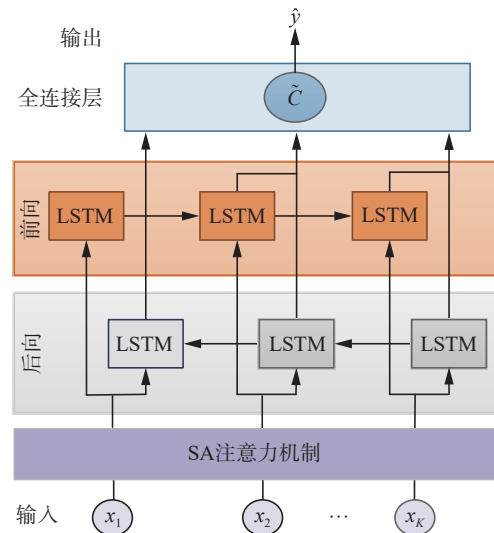


图 3 TPIB 模型结构

Fig. 3 TPIB model structure

TPIB 模型具体步骤如下:

步骤 1 模型输入。将 K 个 IMF 序列按式 (5) 排列, 输入至 SA 机制中。

步骤 2 SA 机制关键信息提取。运用式 (6)~(8) 计算加权聚合向量, 提取 IMF 间关键信息。

步骤 3 BiLSTM 长期依赖关系提取。模型的正向和反向 LSTM 单元以加权信息为依据, 通过选择性保留或遗忘序列前后内容, 并行计算序列隐藏状态, 从而有效提取数据中的长期依赖关系。在整体训练阶段, 通过损失函数持续调整并更新隐藏状态的计算参数。

步骤 4 全连接层输出预测结果。将训练完成后的正向和反向隐藏状态进行拼接, 输入至全连接层中进行全连接映射以实现业务预测。最终对数据进行叠加和反归一化处理, 输出预测结果。

2 VPI-TPIB 性能分析

2.1 实验环境及数据描述

本文实验环境为 Windows 7 操作系统, TensorFlow 2.13.0。为确保实验的合理性, 根据相关文章和多次实验最终确定 BiLSTM 模型由两层构成, 每层分别具有 64 和 32 个隐藏单元, 训练周期数为 50, 批次大小为 32, 学习率为 0.01, 时间步长为 12, 训练集与测试集比例为 8:2; ISSA 算法中发现者、加入者、侦察者占比分别为 70%、10%、20%, 安全阈值取 0.6, 控制参数 β 取 0.7, 其他参数设置见 2.3 节。结合数据维数与参考文献 [30], SA 机制注意力头设置为单头。

如图 4 所示, 实验数据选用了来自 11 个欧洲城市核心区域的私人互联网流量数据 (ec_data) 以及来自英国学术网络骨干的互联网流量数据 (uk_data)。其中, ec_data 和 uk_data 采集时间间隔均为 5 min, 采集时间分别为 2005 年 6 月 7 日—7 月 31 日和 2004 年 11 月 19 日—2005 年 1 月 27 日。由于卫星网络流量数据具有明显的周期性特征, 为避免模型在训练过程中出现过拟合及数据冗余问题, 本文从两个数据集中分别选取连续十天的数据作为实验样本。此外, 基于两个数据集分别进行实验验证, 有助于全面评估所提模型的泛化性。





图 4 原始部分数据

Fig. 4 Original partial data

2.2 评价指标

实验选用均方根误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 作为评价指标, 仿真 10 次评价指标的平均值作为最后的评判结果, 用于评价预测结果的准确性。3 种指标计算公式为

$$\begin{cases} \text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \\ \text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \\ \text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \end{cases}$$

式中: \hat{y}_i 和 y_i 分别表示业务预测和真实值, n 为测试集数量。

2.3 VPI 模型性能分析

为了体现 ISSA 算法寻优 VMD 参数的有效性, 本文将 ISSA 与 SSA 算法、粒子群优化算法 (particle swarm optimization, PSO)、灰狼优化算法 (grey wolf optimizer, GWO)、海洋捕食者算法 (marine predators algorithm, MPA) 进行收敛性能对比。同时, 为保证实验的公平性与一致性, 依据文献 [31], 算法初始种群规模设为 30, 迭代次数设为 50, 参数 $[K, \alpha]$ 搜索范围分别设定为 $[3, 9]$ 和 $[100, 1500]$ 。

图 5 给出了 5 种算法在两个数据集上的适应度迭代曲线。可以看出, 传统算法 PSO 和 GWO 在搜索过程中容易陷入局部最优解, 导致最优值较大且难以获得精确解。虽然 MPA 算法在 uk_data 数据集上展示了一定的搜索能力, 但在 ec_data 数据集上的表现较差, 显示出较低稳定性。相较之下, ISSA 和 SSA 算法在不同数据集上均呈现出随着迭代次数增加而快速收敛的趋势。其中 ISSA 算法局部搜索能力与收敛速度较 SSA 算法得到了进一步增强, 能够在较少的迭代次数内找到精度更高的解集, 并在两个数据集上都表现优异。因此在利用 VMD 分解业务数据时, 采用 ISSA 算法优化 VMD 参数是更为理想的选择。


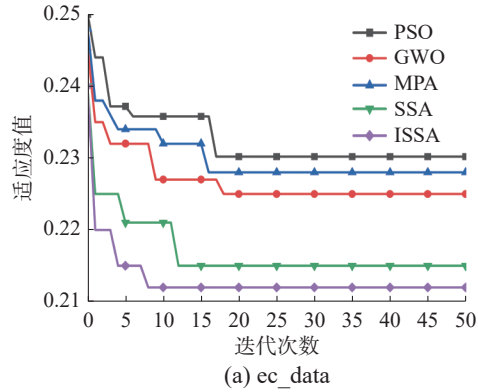


图 5 不同算法迭代曲线对比

Fig. 5 Comparison of iteration curves of different algorithms

两个数据集经 ISSA 对 VMD 参数寻优处理后, $[K, \alpha]$ 取值分别为 $[4, 1326]$ 和 $[5, 828]$ 。图 6 给出了经 VPI 模型分解后得到的子分量。从图中可以看出, 两个数据集的 IMF1 经过 VMD 处理作为主导分量, 能够捕捉原始业务流量数据的长期变化趋势, 曲线幅值变化相对平稳, 反映数据的整体规律。IMF2 则反映了数据的中期波动, 比原始数据更加平滑, 且分量的局部变化较平稳和清晰。而其余各分量则有效提取了业务流量序列中的局部特征和短周期波动, 变化幅度较小。综上, VMD 通过将原始业务流量数据分解为多个平稳分量, 显著降低数据波动性, 为 TPIB 模型提供更清晰的特征输入, 进而提高模型预测精度。





图 6 VPI 模型分解结果

Fig. 6 Decomposition result of the VPI model

2.4 TPIB 模型性能分析

本文将常用的 SA、SE 注意力机制和 CBAM 注意力机制, 分别与 BiLSTM 结合进行对比实验。通过比较 7 种网络模型的预测性能, 验证本文 TPIB 模型的有效性, 为后续复杂模型设计提供有力支撑。预测结果与评价指标对比如图 7 和 8 所示。

通过图 7 和图 8 不同数据集的预测结果以及评价指标对比图可以看出, 相较于其他组合形式, TPIB 模型具有较强的泛化能力和良好的预测性能。其中以 ec_data 数据集为例, TPIB 模型相较于 BiLSTM-CBAM、SE-BiLSTM、CBAM-BiLSTM、BiLSTM-SE、BiLSTM-SA、BiLSTM 模型 RMSE 分别降低了 30.83%、24.32%、17.48%、3.14%、3.12%、3.12%, MAE 分别降低了 37.36%、27.63%、22.50%、4.43%、7.37%、4.19%, MAPE 分别降低了 53.53%、41.86%、36.22%、17.76%、24.45%、17.41%。

TPIB 模型虽然整体预测精度较高, 但在部分时段会出现预测趋势与实际变化相反, 对数据演

化规律刻画不够精确的情况。这些不足的主要产生原因于 TPIB 模型直接对具有强波动性特征的原始业务流量数据进行预测, 导致模型难以有效捕捉数据的动态变化规律。由此证实了引入 VPI 模型的必要性, 同时验证了“分解-预测”双模型协同框架 VPI-TPIB 的设计优势。





图 7 不同网络模型预测结果对比

Fig. 7 Comparison of prediction results from different network models

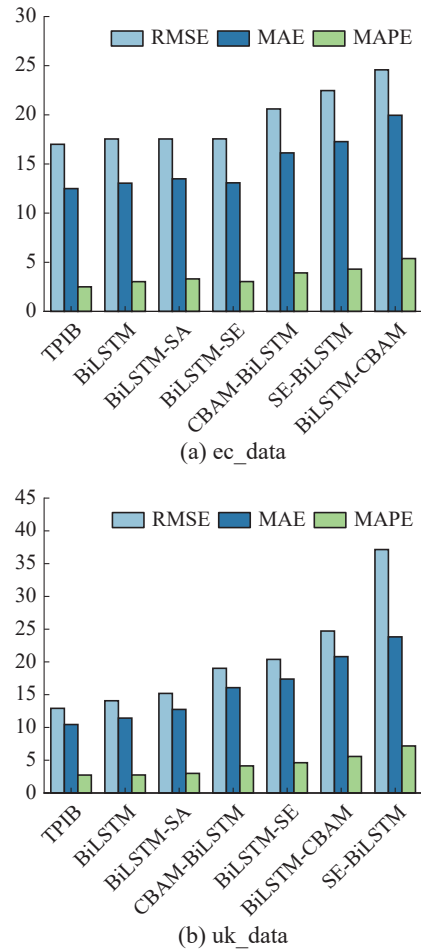


图 8 不同网络模型评价指标对比

Fig. 8 Comparison of evaluation indicators for different network models

2.5 VPI-TPIB 性能分析

2.5.1 消融实验及分析

为验证 VPI-TPIB 方法的有效性和预测效果, 本文将其与基准 LSTM 模型 (算法 1)、BiLSTM (算法 2)、SA-BiLSTM (算法 3)、VMD-BiLSTM (算法 4)、VMD-TPIB (算法 5) 和 VPI-BiLSTM (算法 6) 等消融实验组进行系统对比实验。ec_data 中各模型具体评价指标如表 1 所示, 其中 LSTM 和 BiLSTM 的层数保持一致, 确保实验的合理性。

表 1 ec_data 中不同模型评价指标对比

Table 1 Comparison of evaluation indicators of different models in ec_data

预测模型	RMSE	MAE	MAPE/%
算法1	20.598	15.925	3.610
算法2	17.548	13.047	3.027
算法3	16.954	12.521	2.671
算法4	14.426	11.836	2.085
算法5	13.117	11.412	1.856
算法6	12.138	10.565	1.769
VPI-TPIB	10.560	9.135	1.694

注: 加粗表示最优结果。

由表 1 可知, 本文模型相比于算法 1~6, RMSE 分别降低了 48.73%、39.82%、37.71%、26.79%、19.49% 和 13.00%, MAE 分别降低了 42.64%、29.98%、27.04%、22.82%、19.95% 和 13.54%, MAPE 分别降低了 53.07%、44.04%、36.58%、18.75%、8.73% 和 4.24%。经上述分析可得, 本文所提模型预测精度更高, 稳定性更强。各模型预测结果如图 9 所示。




图 9 ec_data 中不同模型预测结果对比

Fig. 9 Comparison of prediction results of different models in ec_data

从图 9 可知, 算法 2 在算法 1 的基础上引入反向传播机制, 增强了对时间序列特征的建模能力, 能够较好地捕捉真实值的长期变化趋势。进一步地, 算法 3 引入 SA 机制, 对输入信息赋予差异化权重, 从而提升了模型对关键特征的感知能力, 使预测精度有所提高。算法 4 结合 VMD 提取数据中的波动特征, 使预测结果更贴近实际变化曲线。在此基础上, 算法 5 综合了 VMD 的特征分解能力与 TPIB 模型的特征选择优势, 实现了更为准确的业务流量预测。然而因 VMD 参数选择非最优解, 仍存在一定的预测误差。算法 6 通过 VPI 模型优化 VMD 参数, 显著改善了数据分解质量, 但因未使用 TPIB 模型提取序列关键信息, 导致预测能力提升有限。因此, 本文模型通过集成 VPI 与 TPIB 优势, 使预测结果与真实值高度吻合, 具备良好的预测性能。

为进一步验证模型的泛化性, 本文在 uk_data 中重复开展对比实验。误差评价指标与预测结果如表 2 和图 10 所示。

表 2 uk_data 中不同模型评价指标对比
Table 2 Comparison of evaluation indicators of different models in uk_data

预测模型	RMSE	MAE	MAPE/%
算法1	37.999	35.957	9.150
算法2	14.071	11.428	2.747
算法3	12.922	10.442	2.730
算法4	10.391	8.110	1.960
算法5	10.156	7.548	1.750
算法6	9.631	7.139	1.648
VPI-TPIB	8.933	6.618	1.540

注: 加粗表示最优结果。




图 10 uk_data 中不同模型预测结果对比

Fig. 10 Comparison of prediction results of different models in uk_data

由表 2 可知本文模型在处理不同数据集时仍能保持较高的预测精度。相比于算法 1~6, 模型评价指标 RMSE 分别降低了 76.49%、36.52%、30.87%、14.03%、12.04% 和 7.25%, MAE 分别降低了 81.60%、42.09%、36.62%、18.39%、12.32% 和 7.30%, MAPE 分别降低了 83.17%、43.94%、43.59%、21.43%、12.00% 和 6.55%。

从图 10 可以看出, 单一的 LSTM 模型在不同数据集上的预测能力有较大波动, 预测结果差异明显。尽管其他模型在整体趋势上与真实数据较为接近, 但相较之下, VPI-TPIB 模型在预测精度方面具有一定优势, 能够更有效地识别数据的整体变化趋势与关键特征, 预测结果与真实值高度

一致。

2.5.2 对比实验及分析

为了评估 VPI-TPIB 模型的预测性能,本文选取了门控循环单元 (gate recurrent unit, GRU)^[32] 和时间卷积网络模型 (temporal convolutional network,

TCN)^[33] 两种常用单一预测模型、面向数据特征的 Transformer 模型 CycleLLH^[34] 以及改进的 LSTM-GRU 混合预测模型^[35] 进行对比实验分析。上述模型参数选择基于文献 [32-35] 中的既定设置,实验结果如表 3 所示。

表 3 两个数据集中不同模型评价指标对比

Table 3 Comparison of evaluation indicators for different models in two datasets

预测模型	ec_data				uk_data			
	RMSE	MAE	MAPE/%	训练时间/s	RMSE	MAE	MAPE/%	训练时间/s
GRU	20.621	15.965	3.824	71.726	38.056	36.063	9.265	60.296
TCN	19.393	14.769	3.354	65.718	35.921	34.418	8.942	55.371
CycleLLH	13.418	11.620	1.988	85.966	15.428	12.583	3.135	72.965
LSTM-GRU	12.758	10.928	1.937	92.647	10.758	8.698	2.190	81.467
VPI-TPIB	10.560	9.135	1.694	88.969	8.933	6.618	1.540	78.536

注: 加粗表示最优结果。

通过表 3 不同数据集的评价指标可以看出,相较于其他模型, VPI-TPIB 模型具有较强的泛化能力和良好的预测性能。其中以 ec_data 数据集为例,模型相较于 GRU、TCN、CycleLLH、改进的 LSTM-GRU 模型 RMSE 分别降低了 48.79%、45.54%、21.30% 和 17.23%, MAE 分别降低了 42.78%、38.15%、21.38% 和 16.41%, MAPE 分别降低了 55.70%、49.48%、14.79% 和 12.55%。

结合模型原理分析数据结果可知,单一的 GRU 与 TCN 模型虽然能够通过更新门与因果卷积捕捉数据的时序关系,但对于数据的波动变化处理不够充分,导致误差较大,影响预测精度;而 CycleLLH 采用多层感知机与周期整合处理数据时序特征,但同样忽略数据波动特征导致预测精度不佳;最后,利用贝叶斯优化超参数的改进 LSTM-GRU 模型在一定程度上有利于提取数据波动性,但随着序列长度的增加其固有缺陷导致数据重要信息识别能力较差,限制了精度的进一步提升。相比之下,本文模型通过 ISSA 算法自适应优化 VMD 和改进 BiLSTM,有效提取了数据特征,以保证模型预测精度。

为了更全面地对比 VPI-TPIB 模型性能,表 3 中列出了各模型的训练时间。在 ec_data 数据集中, VPI-TPIB 模型训练时间较最快的 TCN 模型增加 35.38%,但 RMSE、MAE 和 MAPE 分别降低 45.54%、38.15% 和 49.48%。在 uk_data 数据集中,训练时间增加 41.84%,而三项误差指标分别下降 75.13%、80.77% 和 82.78%。综合各模型的预测误差和训练时间, VPI-TPIB 模型具有较高的性价比且预测优势明显。

2.5.3 鲁棒性实验及分析

为了验证 VPI-TPIB 模型的鲁棒性,本文参考

文献 [34], 通过向原始输入序列中比例为 ε 的数据注入 $[-0.2x_i, 0.2x_i]$ 范围内的白噪声扰动,并采用 RMSE、MAE 及指标相对无噪声时的平均增长百分比作为依据,以评估模型性能。

如表 4 所示,当噪声比例分别为 1%、5%、10% 时,评价指标呈现细微的上升趋势,平均上升比例分别为 0.9%、4.0%、9.3%。结果表明,在引入噪声后, VPI-TPIB 模型的预测性能并未出现明显下降。这不仅验证了模型在处理噪声数据的鲁棒性,也为其在复杂、多变的卫星通信数据环境中的应用提供了有力的支撑。

表 4 两个数据集中不同噪声注入比例模型评价指标对比
Table 4 Comparison of model evaluation indicators with different noise injection ratios in two datasets

噪声比例/%	ec_data		uk_data		平均上升比例/%
	RMSE	MAE	RMSE	MAE	
0	10.560	9.135	8.933	6.618	—
1	10.658	9.218	9.015	6.673	0.9
5	10.922	9.495	9.352	6.889	4.0
10	11.717	9.836	9.919	7.123	9.3

3 结束语

本文提出了基于参数优化 VMD 和改进 BiLSTM 的低轨卫星网络业务预测方法 VPI-TPIB。该方法采用两级处理架构:首先通过 VPI 模型实现基于 ISSA 算法的自适应数据分解,将波动性强的原始数据分解为多个局部平稳的分量,有利于后续模型学习数据的本质规律;随后在 TPIB 模型中利用 SA 注意力机制选择数据中关键信息,结合 BiLSTM 网络捕获多尺度时序依赖关系,最

终实现高精度预测。实验结果表明, 该模型在两个数据集上均展现出良好的预测性能, 有效验证了其在 LEO 卫星网络业务预测中的适用性和泛化性, 为网络资源的分配和调度提供更加可靠的依据。

未来的研究将从两个方面进一步优化模型: 一是考虑业务流量数据中的时空特性, 增强模型的鲁棒性; 二是提高模型计算效率, 增强其实时预测性能。通过持续改进, VPI-TPIB 方法有望在 LEO 网络中实现更高效的业务预测, 有效缓解传输拥塞, 提升通信保障能力。

参考文献:


- [1] MAO Bomin, ZHOU Xueming, LIU Jiajia, et al. On an intelligent hierarchical routing strategy for ultra-dense free space optical low earth orbit satellite networks[J]. *IEEE journal on selected areas in communications*, 2024, 42(5): 1219–1230.
- [2] HUI Mingming, ZHAI Shenghua, WANG Daqing, et al. A review of LEO-satellite communication payloads for integrated communication, navigation, and remote sensing: opportunities, challenges, future directions[J]. *IEEE internet of things journal*, 2025, 12(12): 18954–18992.
- [3] PRIYA J C, NANTHAKUMAR G, CHOUDHURY T, et al. 6G-DeFLI: enhanced quality-of-services using distributed hash table and blockchain-enabled federated learning approach in 6G IoT networks[J]. *Wireless networks*, 2025, 31(1): 361–375.
- [4] CHEN Chen, SUN Chengxin, LI Huimin, et al. ST-GAGCN-LEO: a spatiotemporal graph attention and gated convolutional network for LEO satellite traffic prediction[J]. *IEEE transactions on aerospace and electronic systems*, 2025, 61(4): 9669–9685.
- [5] 朱圳, 刘立芳, 齐小刚. 基于数据挖掘的通信网络故障分类研究[J]. *智能系统学报*, 2022, 17(6): 1228–1234.
- [6] ZHU Zhen, LIU Lifang, QI Xiaogang. Research on communication network fault classification based on data mining[J]. *CAAI transactions on intelligent systems*, 2022, 17(6): 1228–1234.
- [7] JIANG Bin, YAN Yingchun, YOU Li, et al. Robust secure transmission for satellite communications[J]. *IEEE transactions on aerospace and electronic systems*, 2023, 59(2): 1598–1612.
- [8] ZHANG Yan, WANG Yong, CAO Haotong, et al. Self-similar traffic prediction for LEO satellite networks based on LSTM[J]. *IET communications*, 2025, 19(1): e12863.
- [9] 张定华, 胡祎波, 曹国彦, 等. 面向工业网络通信安全的数据流特征分析[J]. *西北工业大学学报*, 2020(1): 199–208.
- [10] ZHANG Dinghua, HU Yibo, CAO Guoyan, et al. Data-flow feature analysis for industrial networks communication security[J]. *Journal of Northwestern Polytechnical University*, 2020(1): 199–208.
- [9] XIAO Zhenyu, YANG Junyi, MAO Tianqi, et al. LEO satellite access network (LEO-SAN) toward 6G: challenges and approaches[J]. *IEEE wireless communications*, 2024, 31(2): 89–96.
- [10] PENG Liang, YAN Jie, WEI Peng, et al. Spatio-temporal correlation-based incomplete time-series traffic prediction for LEO satellite networks[J]. *Frontiers of information technology & electronic engineering*, 2025, 26(5): 788–804.
- [11] TIAN Miao, SUN Chen, WU Shaozhi. An EMD and ARMA-based network traffic prediction approach in SDN-based Internet of vehicles[J]. *Wireless networks*, 2021: 1–13.
- [12] 冯强, 赵建光, 杨茸, 等. 时间序列中非平稳性和波动性的建模及预测[J]. *计算机科学与探索*, 2025, 19(5): 1313–1321.
- [13] FENG Qiang, ZHAO Jianguang, YANG Rong, et al. Modeling and predicting time series with non-stationarity and volatility[J]. *Journal of frontiers of computer science and technology*, 2025, 19(5): 1313–1321.
- [13] BI Jing, ZHANG Xiang, YUAN Haitao, et al. A hybrid prediction method for realistic network traffic with temporal convolutional network and LSTM[J]. *IEEE transactions on automation science and engineering*, 2022, 19(3): 1869–1879.
- [14] KAVEHMADAVANI F, NGUYEN V D, VU T X, et al. Intelligent traffic steering in beyond 5G open RAN based on LSTM traffic prediction[J]. *IEEE transactions on wireless communications*, 2023, 22(11): 7727–7742.
- [15] LI Guohao, TIAN Zhongda. A new method of network traffic prediction based on combination model[J]. *Peer-to-peer networking and applications*, 2024, 17(3): 1075–1090.
- [16] HAN Chi, XIONG Wei, YU Ronghuan, et al. LEO satellite network traffic forecasting based on ARIMA-BPNN model[C]//2023 3rd International Conference on Electronic Information Engineering and Computer Communication. Piscataway: IEEE, 2024: 402–406.
- [17] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. *IEEE transactions on signal processing*, 2014, 62(3): 531–544.
- [18] MA Changxi, HU Yanming, XU Xuecai. Hybrid deep learning model with VMD-BiLSTM-GRU networks for short-term traffic flow prediction[J]. *Data science and management*, 2025, 8(3): 257–269.
- [19] ZHANG Hong, YANG Gang, YU Hailiang, et al. Kalman filter-based CNN-BiLSTM-ATT model for traffic

- flow prediction[J]. *Computers, materials & continua*, 2023, 76(1): 1047–1063.
- [20] LI Guohui, DENG Haonan, YANG Hong. Traffic flow prediction model based on improved variational mode decomposition and error correction[J]. *Alexandria engineering journal*, 2023, 76: 361–389.
- [21] FU Youfa, LIU Dan, FU Shengwei, et al. Enhanced Aquila optimizer based on tent chaotic mapping and new rules[J]. *Scientific reports*, 2024, 14: 3013.
- [22] ALAWIDA M. Enhancing logistic chaotic map for improved cryptographic security in random number generation[J]. *Journal of information security and applications*, 2024, 80: 103685.
- [23] 孟学尧, 郭倩倩, 郭海儒. 一种改进萤火虫算法的模糊聚类方法[J]. *小型微型计算机系统*, 2021, 42(6): 1165–1170.
- MENG Xueyao, GUO Qianqian, GUO Hairu. Fuzzy clustering method based on improved firefly algorithm[J]. *Journal of Chinese computer systems*, 2021, 42(6): 1165–1170.
- [24] 回立川, 陈雪莲, 孟嗣博. 多策略混合的改进麻雀搜索算法[J]. *计算机工程与应用*, 2022, 58(16): 71–83.
- HUI Lichuan, CHEN Xuelian, MENG Sibao. Improved sparrow search algorithm based on multi-strategy mixing[J]. *Computer engineering and applications*, 2022, 58(16): 71–83.
- [25] SUN Shuguang, WANG Zewei, WANG Jingqin, et al. Remaining useful life prediction for circuit breaker based on SM-CFE and SA-BiLSTM[J]. *IEEE transactions on instrumentation and measurement*, 2023, 72: 3517314.
- [26] GUO Jielong, LIU Meijun, LUO Peng, et al. Attention-based BiLSTM for the degradation trend prediction of lithium battery[J]. *Energy reports*, 2023, 9: 655–664.
- [27] ZHU Rong, TANG Jie, HE Xuansen, et al. SE-MAConvLSTM: a deep learning framework for short-term traffic flow prediction combining squeeze-and-excitation network and multi-attention convolutional LSTM network[J]. *PLoS one*, 2024, 19(12): e0312601.
- [28] ZHANG Zhiwei, GONG Shuhui, LIU Zhaoyu, et al. A novel hybrid framework based on temporal convolution network and transformer for network traffic prediction[J]. *PLoS one*, 2023, 18(9): e0288935.
- [29] MA Xuesen, ZHENG Biao, JIANG Gonghui, et al. Cellular network traffic prediction based on correlation ConvLSTM and self-attention network[J]. *IEEE communications letters*, 2023, 27(7): 1909–1912.
- [30] 殷礼胜, 孙双晨, 魏帅康, 等. 基于自适应 VMD-Attention-BiLSTM 的交通流组合预测模型[J]. *电子测量与仪器学报*, 2021, 35(7): 130–139.
- YIN Lisheng, SUN Shuangchen, WEI Shuaikang, et al. Traffic flow combination prediction model based on adaptive VMD-attention-BiLSTM[J]. *Journal of electronic measurement and instrumentation*, 2021, 35(7): 130–139.
- [31] 王瑞, 李哲, 逯静. 基于融合聚类和 BKA-VMD-TCN-BiLSTM 的短期光伏功率预测[J]. *电子科技大学学报*, 2025, 54(4): 592–603.
- WANG Rui, LI Zhe, LU Jing. Short-term photovoltaic power forecasting based on fusion clustering and BKA-VMD-TCN-BiLSTM[J]. *Journal of University of Electronic Science and Technology of China*, 2025, 54(4): 592–603.
- [32] LIU Zhiguo, LI Weijie, FENG Jianxin, et al. Research on satellite network traffic prediction based on improved GRU neural network[J]. *Sensors*, 2022, 22(22): 8678.
- [33] CAO Mengxiang, LIU Jin, ZHI Jiamao, et al. TLS-net: a hybrid time series prediction model combining TCN and LSTM for ship-satellite network traffic[C]//2023 7th International Conference on Transportation Information and Safety. Piscataway: IEEE, 2023: 1168–1173.
- [34] 唐文杰, 肖一磊, 孔祥宇, 等. CycleLLH: 一种基于周期性整合的新型网络流量预测模型[J]. *计算机学报*, 2024, 47(12): 2867–2888.
- TANG Wenjie, XIAO Yilei, KONG Xiangyu, et al. CycleLLH: a new network traffic prediction model based on cycle integration[J]. *Chinese journal of computers*, 2024, 47(12): 2867–2888.
- [35] QI Liangang, WANG Enqiang, XU Tianfang, et al. Improving satellite network efficiency with terminal traffic prediction and SQP-SRA algorithm[J]. *Computer communications*, 2025, 242: 108293.

作者简介:



佟谣, 硕士研究生, 主要研究方向为卫星网络资源管理。E-mail: 23071213248@stu.xidian.edu.cn。



刘波, 副教授, 主要研究方向为软件定义网络、网络流量优化、卫星网络路由与资源分配。E-mail: lbo.xidian@163.com。



齐小刚, 教授, 博士生导师, 主要研究方向为复杂系统建模与仿真、网络算法设计与应用。主持完成国家自然科学基金项目等 30 余项, 登记软件著作权 13 项, 发表学术论文 150 余篇。E-mail: xgqi@xidian.edu.cn。