

文章编号: 1671-251X(2025)05-0129-11

DOI: 10.13272/j.issn.1671-251x.2025010025

# 改进黏菌算法优化 TCN-LSTM-MHSA 的巷道锚杆(索)应力预测模型

齐俊艳<sup>1</sup>, 车玉浩<sup>2</sup>, 王磊<sup>2</sup>, 袁瑞甫<sup>3</sup>

(1. 河南理工大学 软件学院, 河南 焦作 454000;

2. 河南理工大学 计算机科学与技术学院, 河南 焦作 454000;

3. 河南理工大学 能源科学与工程学院, 河南 焦作 454000)

**摘要:** 锚杆(索)应力的变化过程呈现明显的短期突变与长期时序依赖特征,而传统单一预测模型对长期趋势建模能力有限且对局部突变敏感性不足,往往难以全面捕捉上述复杂特征。针对该问题,提出一种基于改进黏菌算法(ISMA)优化时间卷积网络(TCN)-长短期记忆网络(LSTM)-多头自注意力机制(MHSA)的锚杆(索)应力预测模型。在煤矿巷道锚杆(索)应力预测问题中,模型训练过程通常涉及超参数调整、学习率选择等复杂优化任务,为提升模型的训练效率与预测精度,提出 ISMA,引入邻域搜索与动态步长因子增强局部搜索能力,融合人工蜂群搜索机制提升全局搜索效率,有效增强模型跳出局部最优解的能力。TCN-LSTM-MHSA 模型采用 TCN 提取局部时序特征,利用 LSTM 学习数据的长期依赖关系,通过 MHSA 强化对全局时序依赖的建模,从而提高模型对锚杆(索)应力的预测能力。在 TCN-LSTM-MHSA 模型的训练中利用 ISMA 对学习率进行迭代寻优,以提高模型的预测精度和速度。实验结果表明:① 与黏菌算法(SMA)、遗传算法(GA)、粒子群算法(PSO)、麻雀搜索算法(SSA)相比,ISMA 优化策略在多个基准函数测试中表现出更优的收敛速度与寻优能力。② 在应力预测实验中,通过消融实验验证了 TCN, LSTM, MHSA 模块的必要性。③ ISMA 优化 TCN-LSTM-MHSA 模型在 MAE, RMSE 及  $R^2$  等指标上均优于 BP, GRU 等主流预测模型,具有更高的预测精度和稳定性。

**关键词:** 锚杆(索)支护; 锚杆(索)应力预测; 黏菌算法; 时间卷积网络; 长短期记忆网络; 多头自注意力机制

中图分类号: TD353.6

文献标志码: A

TCN-LSTM-MHSA model optimized by improved slime mould algorithm for stress prediction of roadway anchor bolts (cables)

QI Junyan<sup>1</sup>, CHE Yuhao<sup>2</sup>, WANG Lei<sup>2</sup>, YUAN Ruifu<sup>3</sup>

(1. School of Software, Henan Polytechnic University, Jiaozuo 454000, China;

2. School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454000, China;

3. School of Energy Science and Engineering, Henan Polytechnic University, Jiaozuo 454000, China)

**Abstract:** The variation process of anchor bolt (cable) stress exhibits distinct short-term fluctuations and long-term temporal dependencies. However, traditional single prediction models have limited capability in modeling long-term trends and insufficient sensitivity to local fluctuations, often making it difficult to fully

收稿日期: 2025-01-10; 修回日期: 2025-05-19; 责任编辑: 王晖, 郑海霞。

基金项目: 河南省高校科技创新团队支持计划(22IRTSTHN005)。

作者简介: 齐俊艳(1978—), 女, 河南新乡人, 副教授, 研究方向为计算机网络控制、数据挖掘、工作流等, E-mail: qjywl@hpu.edu.cn。通信作者: 车玉浩(1997—), 男, 河南新乡人, 硕士研究生, 研究方向为机器学习、预测算法、智能信息处理等, E-mail: yuhao\_che@163.com。

引用格式: 齐俊艳, 车玉浩, 王磊, 等. 改进黏菌算法优化 TCN-LSTM-MHSA 的巷道锚杆(索)应力预测模型[J]. 工矿自动化, 2025, 51(5): 129-139.

QI Junyan, CHE Yuhao, WANG Lei, et al. TCN-LSTM-MHSA model optimized by improved slime mould algorithm for stress prediction of roadway anchor bolts (cables)[J]. Journal of Mine Automation, 2025, 51(5): 129-139.



扫码移动阅读

capture these complex features. To address this problem, an anchor bolt (cable) stress prediction model based on an Improved Slime Mould Algorithm (ISMA) optimized Temporal Convolutional Network (TCN)-Long Short-Term Memory (LSTM)-Multi-Head Self-Attention (MHSA) architecture is proposed. In the problem of anchor bolt (cable) stress prediction in coal mine roadways, model training often involves complex optimization tasks such as hyperparameter tuning and learning rate selection. To improve the training efficiency and prediction accuracy of the model, ISMA was proposed, which enhanced local search capability by introducing neighborhood search and a dynamic step-size factor. Global search efficiency was improved through integrating an Artificial Bee Colony (ABC) search mechanism, thereby effectively improving the model's ability to escape from local optima. The TCN-LSTM-MHSA model was constructed by using TCN to extract local temporal features, employing LSTM to learn long-term dependencies in the data, and strengthening global temporal modeling through MHSA, thereby enhancing the prediction capability for anchor bolt (cable) stress. During training, ISMA was used to iteratively optimize the learning rate of the TCN-LSTM-MHSA model to improve prediction accuracy and speed. Experimental results showed that: ① Compared with the Slime Mould Algorithm (SMA), Genetic Algorithm (GA), Particle Swarm Optimization (PSO), and Sparrow Search Algorithm (SSA), the ISMA optimization strategy demonstrated better convergence speed and optimization ability in multiple benchmark function tests. ② In the stress prediction experiment, ablation experiments verified the necessity of TCN, LSTM, and MHSA modules. ③ The ISMA-optimized TCN-LSTM-MHSA model outperformed mainstream prediction models such as BP and GRU in MAE, RMSE, and  $R^2$  metrics, showing higher prediction accuracy and stability.

**Key words:** anchor bolt (cable) support; anchor bolt (cable) stress prediction; slime mould algorithm; temporal convolutional network; long short-term memory network; multi-head self-attention mechanism

## 0 引言

锚杆(索)支护是煤矿井下巷道中应用最为广泛的支护形式。在我国井工煤矿中, 80% 以上的巷道为煤巷或半煤岩巷, 主要采用锚杆或锚索进行支护。其基本原理是将围岩应力有效传递至稳定地层, 从而提升巷道的整体稳定性与安全性。目前, 多数煤矿巷道的锚杆支护率已超过 90%, 部分矿区甚至达到 100%<sup>[1-2]</sup>。锚杆(索)的应力是衡量巷道稳定性的关键指标, 对于防止巷道事故、确保人员安全及指导工程施工等方面具有重大意义<sup>[3]</sup>。随着煤矿开采等环境变化, 锚杆(索)会受到不同方向和强度的应力作用。过大的应力负荷可能使锚杆(索)发生塑性变形或断裂, 失去原有的支撑功能, 进而导致巷道坍塌、矿井渗水或其他安全事故的发生。此外, 锚杆(索)应力的持续变化还可能加速锚杆(索)材料的老化或疲劳, 降低其长期稳定性。因此, 准确预测锚杆(索)应力变化趋势对于及时发现潜在的支护问题、制定科学的安全管理策略、避免突发事故至关重要。

目前, 许多学者针对锚杆(索)支护状态监测预警提出了很多方法, 张哲诚等<sup>[4]</sup>在锚杆托盘与围岩之间安装 MCS-400 型无损锚杆(索)测力计, 实测锚杆实际受力及随时间的变化规律。董建军等<sup>[5]</sup>基于

光纤布拉格光栅(Fiber Bragg Grating, FBG)传感器技术自主研发应力传感器, 揭示了回采巷道锚杆(索)安全状态及演化规律。原钢等<sup>[6]</sup>基于多参数输入与输出高斯过程回归对锚杆支护状态进行了预测。徐毅青等<sup>[7]</sup>建立 2 种耦合模型并推导模型的本构方程和有效预应力的变化公式, 验证了分段预测模型的合理性和准确性。彭泓等<sup>[8]</sup>提出一种针对锚杆杆体受力进行监测的矿用光纤光栅锚杆传感器技术, 实现了杆体破裂预报预警功能。张涵等<sup>[9]</sup>通过设置永久监测和临时监测设施, 分析支护采用的锚杆和锚索应力的监测结果, 评估整体稳定性及安全性, 并结合相关规范和数据分析, 建立了监测预警机制。

上述研究为锚杆(索)支护状态的监测与预警提供了宝贵经验, 但仍存在以下不足: ① 大多数方法聚焦于应力的实时监测与静态分析, 缺乏对未来变化趋势的预测能力。② 部分预测方法未能有效挖掘锚杆(索)应力数据的时间序列特性, 难以同时捕捉其短期波动与长期演化特征, 导致预测准确度受限。而在实际应用中, 锚杆(索)应力的变化过程呈现明显的短期突变与长期时序依赖特征: 一方面存在由爆破震动、机械作业引起的瞬时突变, 表现为数秒内的剧烈波动; 另一方面, 围岩缓慢变形导致的应力长期累积变化趋势亦普遍存在。而传统单一预测模型

对长期趋势建模能力有限且对局部突变敏感性不足,往往难以全面捕捉上述复杂特征。

针对上述问题,本文构建了一种改进黏菌算法(Improved Slime Mould Algorithm, ISMA)优化时间卷积网络(Temporal Convolutional Network, TCN)-长短期记忆网络(Long Short-term Memory, LSTM)-多头自注意力机制(Multi-Head Self-Attention, MHSA)的巷道锚杆(索)应力预测模型。首先,通过 TCN 的小尺度卷积核快速识别由采动影响等造成的瞬时应力波动;LSTM 通过细胞状态的连续更新捕捉锚杆(索)应力长期非线性累计趋势;MHSA 可增强全局特征建模能力,有效提升对锚杆(索)应力预测的泛化能力。然后,针对传统固定学习率或梯度下降方式优化不足的问题,采用邻域搜索自适应更新策略与人工蜂群搜索机制(Artificial Bee Colony Algorithm, ABC)对黏菌算法(Slime Mould Algorithm, SMA)进行改进,对模型学习率进行优化,从而提升训练效率和预测精度。最后,在实际工程采集的锚杆(索)应力数据集上进行了验证。

## 1 SMA

在煤矿巷道锚杆(索)应力预测问题中,模型训练过程通常涉及超参数调整、学习率选择等复杂优化任务。然而,传统优化算法在实际应用中存在以下不足:遗传算法(Genetic Algorithm, GA)易陷入局部最优,且收敛速度易受影响<sup>[10]</sup>;粒子群算法(Particle Swarm Optimization, PSO)对高维学习率调节不敏感<sup>[11]</sup>;麻雀搜索算法(Sparrow Search Algorithm, SSA)采用固定比例机制,局部开发效率低<sup>[12]</sup>;鲸鱼优化算法(Whale Optimization Algorithm, WOA)易震荡且不适用于离散参数优化<sup>[13]</sup>。这些不足在煤矿井下复杂环境下尤其突出,难以有效捕捉锚杆(索)应力的短期波动与长期演化特征,导致预测模型性能受限。

为了解决复杂任务参数优化问题,受黏菌模型<sup>[14]</sup>启发, Li Shimin 等<sup>[15]</sup>提出了新型优化算法 SMA,已广泛应用于模型参数优化<sup>[16-18]</sup>等领域。SMA 模拟了黏菌在觅食过程中的行为特征,通过生长形成静脉网络,依据食物质量调整结构形态以寻求最优觅食路径,其觅食行为可分为搜索食物、接近食物和捕获食物 3 个阶段<sup>[19]</sup>,如图 1 所示,其中  $X_m$  为当前随机选择黏菌个体的位置,  $X_1, X_2, X_3$  为黏菌种群中各个个体的位置,  $X_{\text{cats}}$  为目标食物的位置,表示问题的解目标区域,黏菌趋近该区域觅食,  $S_{x,y}$  为在  $x$  位置和  $y$  维度内的随机性扰动,用于增加

解的多样性,避免早熟收敛。SMA 在觅食过程中对个体位置的动态调整、对周围环境的适应反应及多阶段的搜索策略,兼顾全局探索与局部开发能力,适应煤矿锚杆(索)应力预测中对短期突变和长期变化的需求。




图 1 SMA 觅食过程

Fig. 1 SMA foraging process

$$X_{t+1} = \begin{cases} R(U_B - L_B) + L_B & R < z \\ X_t^b + b(WX_t^A - X_t^B) & r < p \\ cX_t & r \geq p \end{cases} \quad (1)$$

式中:  $X_{t+1}$  为黏菌下一次迭代更新的位置,  $t$  为当前迭代次数;  $R$  和  $r$  为  $[0, 1]$  的随机数;  $U_B$  和  $L_B$  分别为搜索范围的上边界和下边界;  $z$  为黏菌分离个体搜索其他食物源的概率;  $X_t^b$  为目前适应度最优的个体位置,  $b$  为振荡参数,模拟黏菌种群中个体信息的交互过程;  $W$  为黏菌个体的权重因子;  $X_t^A$  与  $X_t^B$  为 2 个随机个体位置;  $p$  为条件参数,用于控制黏菌位置更新方式;  $c$  为振荡参数;  $X_t$  为黏菌当前迭代的位置。

当  $R < z$  时,代表黏菌分离部分个体搜索食物,当  $R > z$  时,黏菌通过  $p$  进行接近食物或捕获食物的过程。

$$p = \tanh|F_i - F_{\max}| \quad (2)$$

式中:  $F_i$  为个体  $i$  的适应度值;  $F_{\max}$  为当前最优个体的适应度值。

## 2 ISMA

为了提升 SMA 的全局搜索和局部开发能力,避免陷入局部最优解并提高模型收敛速度,本文提出了基于邻域搜索自适应更新策略与 ABC 的 ISMA,在 SMA 基础架构上,利用改进的邻域搜索自适应更新策略提升其捕获食物阶段局部搜索能力,并通过改进 ABC 增强其接近实物阶段的全局搜索能力,实现对参数空间的高效寻优,其整体优化流程如图 2 所示。首先,通过随机初始化与适应度计算确定个体分布。然后,在迭代过程中,若  $R < z$  则执行分离探索;当  $r < p$  时,采用 ABC 进行全局更新,  $r \geq p$  时,采用邻域搜索自适应更新策略进行局部开发。最后,



在满足最大迭代条件后输出最优解。

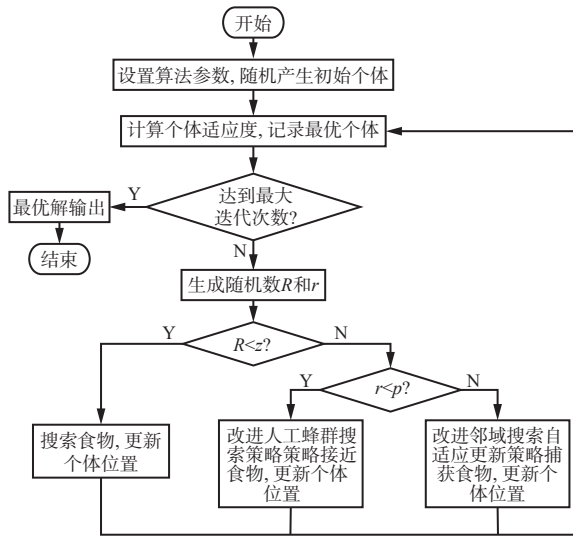


图 2 ISMA 寻优流程

Fig. 2 ISMA optimization process

在 SMA 获取食物过程中, 虽然个体存在  $R < z$  的概率跳出局部最优解, 但受限于  $z$  的大小及参数  $c$  的线性下降, 仍可能导致收敛速度较慢及陷入局部最优的问题。为此, 本文引入邻域搜索思想, 借鉴蜜蜂在特定区域内反复探索并根据环境变化动态调整路径的机制, 以增强算法的局部搜索能力<sup>[20-22]</sup>。对于黏菌当前位置  $X_i$ , 在其邻域内进行位置更新:

$$X_i^{\text{new}} = X_i + \Delta X_i \quad (3)$$

$$\Delta X_i = \alpha(t)(X_{\text{best}} - X_i) + \beta(t)(X_r - X_i) \quad (4)$$

$$\alpha(t) = \alpha_{\max} \left( 1 - \frac{t}{t_{\max}} \right) \quad (5)$$

$$\beta(t) = \beta_{\max} \left( 1 - \frac{t}{t_{\max}} \right) \quad (6)$$

式中:  $\Delta X_i$  为由一个邻域搜索产生的变化量;  $\alpha(t)$  和  $\beta(t)$  为自适应步长因子, 随迭代次数  $t$  动态调整;  $X_{\text{best}}$  为当前种群的最优个体位置;  $X_{\text{best}} - X_i$  为当前位置与最优位置之间的差异量, 用来促进个体向全局最优位置收敛;  $X_r$  为从种群中随机选择的一个个体位置;  $X_r - X_i$  为当前个体位置与随机个体位置之间的差异量, 用来引导探索;  $\alpha_{\max}$  和  $\beta_{\max}$  为最大初始步长;  $t_{\max}$  为最大迭代次数。

在改进后的策略中, 步长的调整不仅依赖于迭代次数, 还需考虑适应度的变化。步长因子  $\alpha(t)$  和  $\beta(t)$  会根据个体的适应度值和搜索阶段进行调节。改进的自适应步长因子动态调整公式为

$$\alpha(t) = \alpha_{\max} \left( 1 - \frac{t}{t_{\max}} \right) \frac{F_i}{F_{\max}} \quad (7)$$

$$\beta(t) = \beta_{\max} \left( 1 - \frac{t}{t_{\max}} \right) \frac{F_i}{F_{\max}} \quad (8)$$

为增强 SMA 的全局搜索能力, 本文引入 ABC, ABC 在复杂多峰值函数优化问题上表现出较好的探索性能, 拥有强大的探索能力<sup>[23]</sup>。

$$Z_{i,j} = x_{i,j} + \phi_{i,j}(x_{i,j} - x_{m,j}) \quad (9)$$

式中:  $Z_{i,j}$  为黏菌个体  $i$  在第  $j$  个维度获取食物过程中的候选解;  $x_{i,j}$  为当前黏菌个体  $i$  在第  $j$  个维度的位置;  $\phi_{i,j}$  为  $[-1, 1]$  的随机数;  $x_{m,j}$  为在第  $j$  个维度上随机选择其他黏菌个体  $m$  的位置 ( $m \neq i$ )。

尽管 ABC 具有出色的搜索性能, 但在开发能力方面存在一定不足。因此, 本文在保留 ABC 原有搜索优势的基础上, 融入了全局最优解的引导机制, 以提升 ABC 在复杂问题上的性能。

$$Z_{i,j} = x_{i,j} + \phi_{i,j}(x_{i,j} - x_{m,j}) + \Omega(x_{g,j} - x_{i,j}) \quad (10)$$

式中:  $\Omega$  为  $[0, 1.5]$  的随机数, 用于控制全局最优引导项的强度;  $x_{g,j}$  为全局最优位置。

### 3 基于 ISMA 优化的应力预测模型

#### 3.1 TCN

TCN 利用因果卷积的方式来捕获序列数据中的长期依赖关系, 其更好的并行计算能力和更灵活的感受野设置提升了模型的训练和推理效率<sup>[24-25]</sup>。TCN 采用分层的卷积核结构, 每个卷积核仅与输入序列的局部区域进行卷积运算, 如图 3 所示, 其中  $\hat{y}_T$  为输出序列在时间步  $T$  的输出值, 卷积核大小分别为 1, 2 和 4, 对应时间维度上不同范围的感受野。扩张卷积可在不增加参数量的前提下扩大感受野, 通过引入扩张系数  $d$ , 使卷积核覆盖更广的时间范围<sup>[26]</sup>。TCN 在位置  $y_T$  处、扩张系数为  $d$  时的卷积计算方法为

$$G_d Y \cdot y_T = \sum_{k=1}^K f_k y_{T-(K-k)d} \quad (11)$$

式中:  $G_d$  为筛选器,  $G_d = (f_1, f_2, \dots, f_K)$ ,  $f_k$  为卷积核权重系数,  $k$  为当前卷积核的索引变量;  $Y$  为时间序列数据,  $Y = (y_1, y_2, \dots, y_T)$ ,  $y_T$  为输入序列在当前时刻  $T$  的值;  $K$  为卷积核大小。

#### 3.2 LSTM

LSTM<sup>[27]</sup> 引入了一种门控机制, 包括遗忘门、输入门和输出门<sup>[28]</sup>, 通过门单元控制信息的保留和遗忘, 能够有效解决信息的长期依赖问题, 避免梯度消失或爆炸。LSTM 网络由多个 LSTM 细胞构成, 如图 4 所示, 其中  $I_t, I_{t-1}, I_{t+1}$  为当前时刻  $t$ , 上一时刻




图3 TCN 扩张因果卷积

Fig. 3 Dilated causal convolution in TCN

$t-1$ , 下一个时刻  $t+1$  的输入数据,  $h_t, h_{t-1}, h_{t+1}$  为当前时刻  $t$ , 上一时刻  $t-1$ , 下一个时刻  $t+1$  的隐藏状态,  $C_t, C_{t-1}, C_{t+1}$  为当前时刻  $t$ , 上一时刻  $t-1$ , 下一个时刻  $t+1$  的细胞状态,  $\sigma$  为激活函数, 输出范围为  $(0,1)$ ,  $\tanh$  用于生成候选的细胞状态。




图4 LSTM 结构

Fig. 4 LSTM structure

### 3.3 MHSA

MHSA 是在自注意力机制基础上引入多头机制, 赋予模型在不同的子空间中并行学习差异化的注意力表示的能力, 从而更全面地捕获数据中的关键信息。

$$\mathbf{O} \in \mathbb{R}^{n \times H_{\text{model}}} \quad (12)$$

式中:  $\mathbf{O}$  为输入矩阵;  $n$  为序列长度;  $H_{\text{model}}$  为输入特征的维度。

为了计算注意力, 输入矩阵  $\mathbf{O}$  会被线性变换为查询矩阵  $\mathbf{Q}$ 、键矩阵  $\mathbf{E}$  和值矩阵  $\mathbf{V}$ , 如图 5 所示。其中,  $\mathbf{Q}_0, \mathbf{Q}_1, \mathbf{E}_0, \mathbf{E}_1, \mathbf{V}_0, \mathbf{V}_1$  分别为 MHSA 中查询矩阵  $\mathbf{Q}$ 、键矩阵  $\mathbf{E}$ 、值矩阵  $\mathbf{V}$  各自映射的不同子空间。




图5 MHSA 输入矩阵的线性变换

Fig. 5 Linear transformation of MHSA input matrix

注意力权重  $\mathbf{W}$  的计算是决定序列中每个元素关注程度的关键步骤。首先计算查询矩阵  $\mathbf{Q}$  和键矩阵  $\mathbf{E}$  的点积, 并按键的维度平方根进行缩放, 以保证数值稳定性和训练效果。然后, 将缩放后的结果输入 Softmax 函数, 得到各位置的注意力分布, 从而引导模型关注输入序列中更为关键的信息。最后, 采用权重  $\mathbf{W}$  对值矩阵  $\mathbf{V}$  进行加权求和, 生成注意力机制的输出  $\mathbf{J}$ , 如图 6 所示。其中,  $\sqrt{\theta_k}$  为缩放因子。




图6 MHSA 不同矩阵加权求和

Fig. 6 Weighted summation of MHSA matrices

### 3.4 预测模型架构

TCN-LSTM-MHSA 模型由输入层、TCN 层、LSTM 层、MHSA 层、全连接层和输出层构成, 结构如图 7 所示。TCN 层提取的局部特征依次输入 LSTM 层, 建立长期依赖关系, 随后由 MHSA 层融合全局上下文信息, 最终通过全连接层输出预测结果。

1) 输入层。模型的输入数据由时间维度为  $N$ 、特征维度为  $M$  的多维时间序列构成, 其中每个时间步对应  $M$  个特征数据。

2) TCN 层。TCN 层通过一维卷积操作处理输入数据, 提取时间序列中的短期依赖。为了有效捕捉不同时间尺度的特征, 使用多层残差块结构, 每个残差块中包含多个卷积核, 卷积核大小和膨胀率通过超参数调整, 以应对不同的序列特征。

3) LSTM 层。LSTM 层进一步处理由 TCN 层提取的特征, 有效过滤无关信息并保留关键的时间序列特征。LSTM 的隐藏状态能够帮助模型记住长期依赖关系。该层采用单层结构, 包含 128 个隐藏神经元, 用以捕获更深层次的时序依赖信息。

4) MHSA 层。该层在模型中起到增强全局信息捕捉能力的作用。MHSA 通过多头并行计算捕捉全局信息, 增强模型对不同时序位置间关系的建模能力。该层采用 4 个注意力头, 每头的嵌入维度为 32, 确保全局信息捕获的高效性。

5) 全连接层与输出层。通过全连接层将经过 MHSA 层处理后的特征进行线性变换, 映射至输出空间。全连接层的输出作为模型的最终预测结果。

### 3.5 基于 ISMA 优化的参数调优

在预测模型训练过程中, 学习率作为模型训练




图 7 TCN-LSTM-MHSA 模型结构

Fig. 7 Architectural framework of TCN-LSTM-MHSA

的关键参数,直接影响模型参数的更新速度和最终收敛效果。在优化问题中,合适的学习率有助于更稳定地搜索全局最优解。若固定学习率或采用基于经验的衰减策略,无法根据模型训练过程中的动态变化进行调整,尤其是在复杂超参数空间中,容易导致模型陷入次优解,无法充分挖掘数据特征。本文在预测模型的训练中利用 ISMA 对学习率进行迭代寻优,以提高模型的预测精度和速度。ISMA 优化 TCN-LSTM-MHSA 模型的过程如图 8 所示。ABC 提高了 SMA 在空间中的探索能力,确保学习率的选择不仅适用于当前阶段,还具有对长期全局优化的适应性。邻域搜索自适应更新策略通过动态调整步长因子,能够在解空间中快速定位学习率的最佳值,确保模型以适当的速度收敛。通过对学习率的优化,可以更快地找到最优解,减少迭代次数,提升模

型的收敛效率,同时能够适应不同阶段的优化需求,避免过早陷入局部最优,增强模型的鲁棒性。

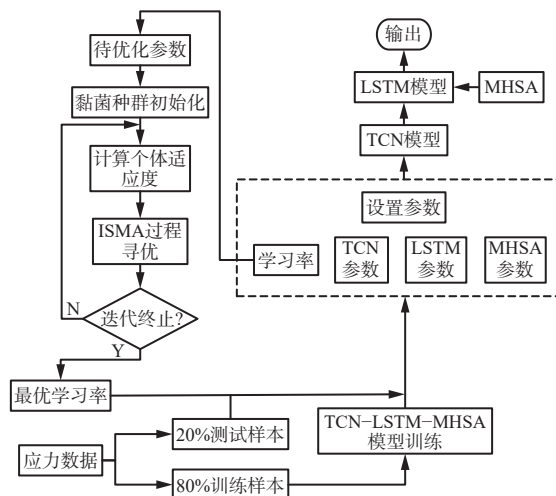


图 8 ISMA 优化预测模型过程

Fig. 8 Process of ISMA-based prediction model optimization

## 4 实验分析

### 4.1 ISMA 性能分析

为了验证 ISMA 的优化效果,将 ISMA 与 SMA, GA, SSA, PSO 进行对比实验。选取 3 个常见的基准测试函数(表 1),测试不同算法在寻优能力、收敛速度和稳定性方面的表现。其中  $D$  为解空间的维度;  $a_n$  为当前解向量  $a$  中的第  $n$  个分量,  $n=1,2,\dots,D$ ;  $l$  为循环索引,  $l=1,2,\dots,n$ 。为了确保不同算法在实验中的公平性,所有算法的种群规模均设定为 50,最大迭代次数统一为 500,同时保持相同的搜索空间上下边界及问题维度。

表 1 基准测试函数

Table 1 Benchmark functions

表达式	搜索空间	理论最优解
$A_1(a) = \sum_{n=1}^D a_n^2$	$[-100, 100]$	0
$A_2(a) = \sum_{n=1}^D  a_n  + \prod_{n=1}^D  a_n $	$[-10, 10]$	0
$A_3(a) = \sum_{n=1}^D \left( \sum_{l=1}^n a_l \right)^2$	$[-100, 100]$	0

5 个优化算法在 3 个基准函数上迭代 500 次的收敛曲线如图 9 所示,具体测试结果见表 2。从表 2 和图 9 可看出,ISMA 寻优精度优于 SMA 与其他优化算法,且 ISMA 比 SMA 及其他优化算法具有更优的收敛速度和寻优能力,这表明引入的邻域搜索自适应更新策略和 ABC 对 SMA 的改进具有较好的效果,有效提升了算法的收敛性能和全局优化能力。




图9 不同基准函数收敛曲线

Fig. 9 Convergence curves of different benchmark functions

表2 测试函数结果统计

Table 2 Statistical results of test functions

基准测试函数	算法	最优值
$A_1$	PSO	$2.31 \times 10^{-10}$
	SSA	$6.36 \times 10^{-9}$
	GA	$3.05 \times 10^{-9}$
	SMA	$2.03 \times 10^{-10}$
	ISMA	$1.35 \times 10^{-10}$
$A_2$	PSO	$1.59 \times 10^{-9}$
	SSA	$4.13 \times 10^{-11}$
	GA	$9.48 \times 10^{-11}$
	SMA	$9.01 \times 10^{-12}$
	ISMA	$8.31 \times 10^{-12}$
$A_3$	PSO	$1.34 \times 10^{-9}$
	SSA	$1.43 \times 10^{-8}$
	GA	$4.86 \times 10^{-8}$
	SMA	$1.20 \times 10^{-9}$
	ISMA	$1.05 \times 10^{-9}$

4.2 数据来源及预处理

实验数据来源于鄂尔多斯某煤矿智能化监测系统,采集对象为运输巷(编号 1800-B1)和回风巷(编号 3302-D1)的锚杆(索)应力传感器网络。采集方式如图 10 所示,采用锚杆(索)测力计与传感器混合组网,传感器安装于锚杆托盘与围岩接触面。样本数据具有较高的时空分辨率,传感器每 25 min 采集 1 次应力数据,确保了应力监测的连续性。数据的空间维度涵盖了典型的矿井巷道类型,包含受采动压力主导的运输巷与受通风应力影响的回风巷,以充分体现煤矿不同工况下的支护应力特征。同时,数据的时间维度涵盖完整生产周期,覆盖煤矿掘进、回采等典型工况,为模型的训练和验证提供了代表性的数据基础。

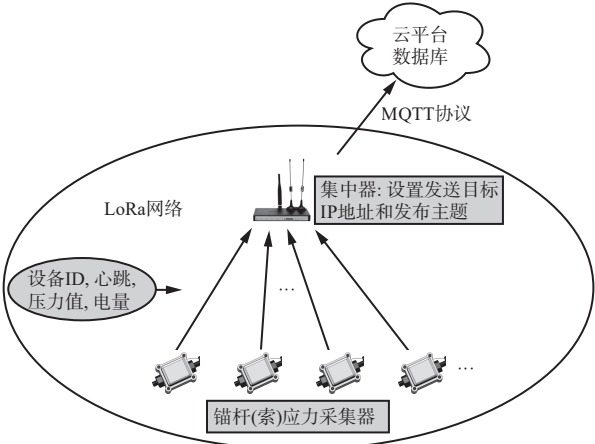


图10 锚杆(索)应力数据采集方式

Fig. 10 Anchor bolts (cables) stress data collection method

煤矿井下监测数据受复杂环境因素影响,可能存在缺失值、异常值等,因此,在数据输入至预测模型前,需进行数据清洗与处理,以提高数据质量。先对缺失值采用线性插值或三次样条法填充,并结合滑动均值滤波平滑处理;再对异常值进行规则识别,使用 K 近邻法修正,确保数据连续性与合理性。

运输巷 1800-B1 的应力采集器所采集的部分数据见表 3,2 个巷道不同设备的整体应力趋势如图 11 所示。可看出应力数据整体变化幅度较大,且局部突变明显,这为验证预测模型性能提供了充分依据。

4.3 模型参数设置

各模型相应参数设置见表 4。


ISMA 训练参数见表 5,其中  $n\_agents$  为黏菌种群的个体数量,为保证种群在搜索过程中的多样性,同时避免陷入局部最优,选择了较为平衡的值 20,  $n\_variables$  为优化问题中变量的维度,变量个数设置为 1,即优化目标为预测模型的学习率参数,  $lower\_bound$  为搜索空间中变量的最小值,  $upper\_bound$




表 3 锚杆(索)部分应力数据

Table 3 Partial stress data of anchor bolts (cables)

应力值/kN	采集时间(年-月-日T时:分:秒)
63.8	2024-09-03T 15:15:27
63.4	2024-09-03T 15:38:58
62.9	2024-09-03T 16:02:28
62.7	2024-09-03T 16:25:58
62.3	2024-09-03T 16:49:28
62.7	2024-09-03T 17:12:59
62.9	2024-09-03T 17:36:30
62.9	2024-09-03T 18:00:02
63.1	2024-09-03T 18:23:33
63.4	2024-09-03T 18:47:03



(a) 运输巷1800-B1应力



(b) 回风巷3302-D1应力

图 11 不同巷道锚杆(索)应力数据

Fig. 11 Stress data of anchor bolts (cables) in different tunnels

表 4 各模型相应参数

Table 4 Parameters of different models

模型层次	名称	参数值
TCN层	卷积核大小	3
	残差块	3
	空间丢失因子	2
LSTM层	隐含层神经元	128
MHSA层	注意力头	4
	维度	32

表 5 黏菌算法相应参数

Table 5 Parameters of SMA

名称	参数值
n_agents	20
n_variables	1
lower_bound	0.000 01
upper_bound	0.1
max_iter	10

为搜索空间中变量的最大值,学习率较小的下限(0.000 01)可确保学习率控制在较低值范围内,适用于 ISMA 的精细搜索;较大的上限(0.1)为探索初始较大学习率的可能性提供空间。 $\text{max\_iter}$  为算法运行的最大迭代次数,学习率优化为单变量问题,搜索空间规模较小,为提高计算效率,迭代次数设置为 10。

#### 4.4 预测实验分析

为检验模型改进效果,对测试集进行了预测验证。采用平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE)及决定系数  $R^2$  衡量预测误差的平均水平、整体波动性和模型对数据拟合的程度。RMSE 用于衡量模型预测值与真实值之间的平均偏差, RMSE 越小表示误差越小、预测效果越好;  $R^2$  反映了模型对数据拟合程度的好坏,  $R^2$  越接近 1, 表示模型对数据的解释能力越强、拟合效果越好。

在学习率优化过程中, SMA 与 ISMA 的收敛对比如图 12 所示。可看出 ISMA 收敛速度更快,跳出局部最优的能力更强,且优化所得适应度值优于 SMA。




图 12 SMA 与 ISMA 收敛率对比

Fig. 12 Comparison of convergence rates between SMA and ISMA

不同优化器优化学习率损失对比如图 13 所示,可看出 ISMA 在学习率动态优化和损失函数收敛表现上优于 Adam(Adaptive Moment Estimation)和 SGD(Stochastic Gradient Descent),模型在初期能够快速收敛至较低损失值,展现出更快的收敛速度。同时, ISMA 的损失函数曲线整体平滑且收敛稳定,避免了 Adam 和 SGD 在中后期训练过程中可能出现的震荡和跳跃现象。这证明了 ISMA 在提升优化效率和全局稳定性方面的优势。实验结果表明, ISMA 更适合复杂非线性模型的优化任务,有助于提高模型的预测精度和鲁棒性。

为了分析 TCN-LSTM-MHSA 预测模型中各模块对预测性能的贡献,本文设计消融实验以评估不同模块对模型性能的影响,进而验证模型有效性和






图 13 不同优化器优化学习率损失对比

Fig. 13 Comparison of learning rate loss optimized by different optimizers

必要性,实验结果见表 6。可看出在 1800-B1 上,TCN-LSTM-MHSA 预测模型的 MAE, RMSE,  $R^2$  分别为 0.414,0.569,0.996,在 3302-D1 上,TCN-LSTM-MHSA 预测模型的 MAE, RMSE,  $R^2$  分别为 1.521, 2.608,0.967,均优于其他模型在 1800-B1 和 3302-D1 上的表现,体现出各模块在建模过程中的良好协同效果。

表 6 消融实验结果

Table 6 Ablation experiment results

地点	模型结构	MAE	RMSE	$R^2$
1800-B1	LSTM+MHSA	0.779	0.929	0.989
	TCN+MHSA	2.058	2.119	0.946
	TCN+LSTM	0.629	0.805	0.992
	TCN-LSTM-MHSA	0.414	0.569	0.996
3302-D1	LSTM+MHSA	2.054	3.264	0.948
	TCN+MHSA	1.611	2.654	0.954
	TCN+LSTM	2.368	3.657	0.935
	TCN-LSTM-MHSA	1.521	2.608	0.967

为充分测试 ISMA-TCN-LSTM-MHSA 的预测性能,与 BP 模型及 GRU 模型进行对比,预测结果如图 14 所示。不同模型在数据集上的性能表现见表 7。

由图 14 和表 7 可看出,本文提出的 ISMA-TCN-LSTM-MHSA 模型在不同巷道、不同设备上的预测结果优于 BP 和 GRU。运输巷 1800-B1 与回风巷 3302-D1 预测结果决定系数  $R^2$  分别为 0.996 和 0.967,对 2 个巷道多个设备进行预测,其平均决定系数  $R^2$  分别为 0.994 和 0.961,均高于 BP 和 GRU 预测模型,体现出模型对锚杆(索)应力数据具有较好的预测能力。同时,本文模型在降低整体误差方面具有良好表现,运输巷 1800-B1 与回风巷 3302-D1 预测结果的 RMSE 分别为 0.569 和 2.608,2 个巷道多个设备平均 RMSE 分别为 0.571 和 2.616,误差均低于

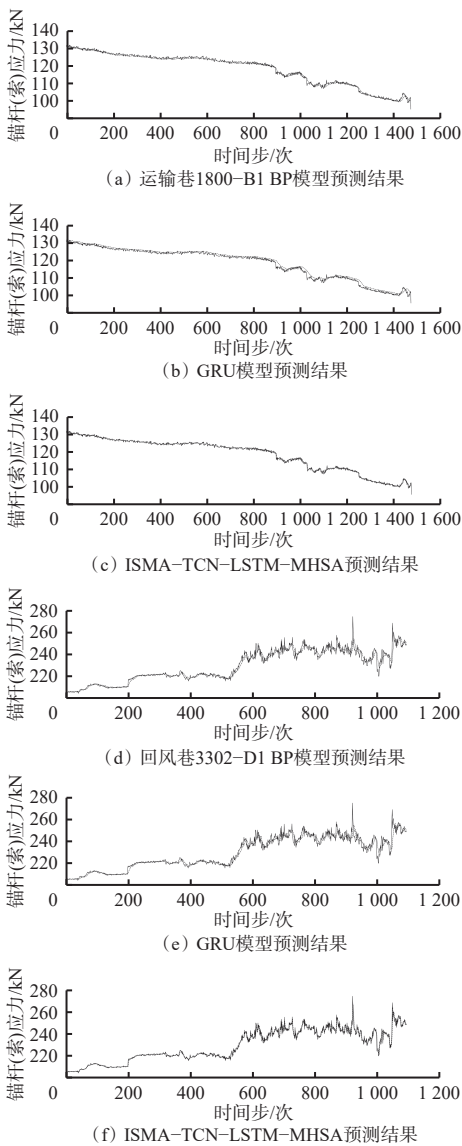


图 14 不同模型预测结果

Fig. 14 Predictions of different models

表 7 各模型性能表现评价

Table 7 Performance evaluation of each model

设备	模型	MAE	RMSE	$R^2$
运输巷1800-B1	BP	0.565	0.744	0.993
	GRU	0.867	1.108	0.985
	ISMA-TCN-LSTM-MHSA	0.414	0.569	0.996
运输巷中5个设备平均	BP	0.581	0.756	0.991
	GRU	0.869	1.112	0.981
	ISMA-TCN-LSTM-MHSA	0.417	0.571	0.994
回风巷3302-D1	BP	2.026	3.305	0.947
	GRU	2.132	3.549	0.939
	ISMA-TCN-LSTM-MHSA	1.521	2.608	0.967
回风巷中5个设备平均	BP	2.035	3.311	0.932
	GRU	2.143	3.557	0.928
	ISMA-TCN-LSTM-MHSA	1.530	2.616	0.961

BP 和 GRU 预测模型。这表明本文所提模型能够更准确地捕捉锚杆(索)应力的变化趋势,验证了其在复杂多变巷道环境下的预测稳定性。

## 5 结论

1) 改进的 SMA 能够增强避免陷入局部最优解的能力,同时提升全局搜索能力,从而加速模型收敛,能够更加有效地优化模型训练过程中的参数更新,进一步增强模型对复杂数据特征的优化能力。

2) 构造的 TCN-LSTM-MHSA 模型能够更好地捕捉锚杆(索)应力的短时突变、长期演化及空间关联性,提升预测精度和泛化能力。

3) 在不同巷道锚杆(索)应力数据集上进行了验证对比。结果表明,ISMA-TCN-LSTM-MHSA 模型的预测性能优于其他预测模型,能够更准确地捕捉锚杆(索)应力变化趋势,提高了预测精度。

## 参考文献(References):

- [1] 康红普,姜鹏飞,刘畅,等.煤巷锚杆支护施工装备现状及发展趋势[J].工矿自动化,2023,49(1):1-18.  
KANG Hongpu, JIANG Pengfei, LIU Chang, et al. Current situation and development trend of rock bolting construction equipment in coal roadway[J]. Journal of Mine Automation, 2023, 49(1): 1-18.
- [2] 张农,魏群,吴建生.煤矿巷道喷涂柔膜技术及适用性[J].煤炭科学技术,2022,50(1):78-85.  
ZHANG Nong, WEI Qun, WU Jiansheng. Spray-on membrane technology and its applicability in coal mine roadways[J]. Coal Science and Technology, 2022, 50(1): 78-85.
- [3] 李永亮,杨仁树,温明睿,等.煤矿巷道顶板锚索受力特征与分区锚固机理[J].煤炭科学技术,2022,50(5):73-83.  
LI Yongliang, YANG Renshu, WEN Mingrui, et al. Stressed characteristics and regional anchoring mechanism of cable bolts in coal mine roadway roof[J]. Coal Science and Technology, 2022, 50(5): 73-83.
- [4] 张哲诚,张向东,刘源浩,等.横向简谐荷载作用下端锚黏结式锚杆黏结性试验研究[J].煤炭学报,2016,41(6):1407-1415.  
ZHANG Zhecheng, ZHANG Xiangdong, LIU Yuanhao, et al. Experimental research of anchors bonding mechanical properties under transverse harmonic loads[J]. Journal of China Coal Society, 2016, 41(6): 1407-1415.
- [5] 董建军,谢郑权,杨嫡,等.基于FBG传感器的回采巷道锚杆支护监测分析[J].安全与环境学报,2021,21(5):2013-2021.  
DONG Jianjun, XIE Zhengquan, YANG Di, et al. Monitoring and analysis of the bolt supporting for the mining roadways based on the FBG sensor[J]. Journal of Safety and Environment, 2021, 21(5): 2013-2021.
- [6] 原钢,刘杰.基于多参数输入与输出高斯过程回归的锚杆支护状态预测[J].液压气动与密封,2023,43(11):47-50.  
YUAN Gang, LIU Jie. Prediction of anchor bolt support status with multi-parameter input and output gaussian process regression[J]. Hydraulics Pneumatics & Seals, 2023, 43(11): 47-50.
- [7] 徐毅青,邓绍玉,葛琦.锚索预应力初期与长期损失的预测模型研究[J].岩土力学,2020,41(5):1663-1669.  
XU Yiqing, DENG Shaoyu, GE Qi. Prediction models for short-term and long-term pre-stress loss of anchor cable[J]. Rock and Soil Mechanics, 2020, 41(5): 1663-1669.
- [8] 彭泓,刘亚飞.基于光纤光栅技术的巷道支护锚杆受力监测[J].煤炭科学技术,2022,50(6):61-67.  
PENG Hong, LIU Yafei. Stress monitoring of roadway supporting bolt based on fiber bragg grating technology[J]. Coal Science and Technology, 2022, 50(6): 61-67.
- [9] 张涵,赵建利.巴基斯坦某水电站工程高边坡支护锚杆应力监测分析[J].水利科学与寒区工程,2024,7(7):101-107.  
ZHANG Han, ZHAO Jianli. Analysis on stress monitoring and high slope support of a hydropower project in Pakistan[J]. Hydro Science and Cold Zone Engineering, 2024, 7(7): 101-107.
- [10] 林东风,黄汉明,沈俏.基于改进遗传算法的广度架构搜索算法[J].计算机工程与设计,2024,45(12):3667-3673.  
LIN Dongfeng, HUANG Hanming, SHEN Qiao. Wide architecture search algorithm based on improved genetic algorithm[J]. Computer Engineering and Design, 2024, 45(12): 3667-3673.
- [11] 易云飞,王志勇,施运应.基于蜣螂优化的改进粒子群算法[J].重庆邮电大学学报(自然科学版),2024,36(3):533-542.  
YI Yunfei, WANG Zhiyong, SHI Yunying. The improved particle swarm optimization algorithm based on dung beetle optimization[J]. Journal of Chongqing University of Posts and Telecommunications(Natural Science Edition), 2024, 36(3): 533-542.
- [12] 卢磊,贺智明,黄志成.基于多策略改进的麻雀搜索算法[J].计算机与现代化,2023(10):23-31.  
LU Lei, HE Zhiming, HUANG Zhicheng. An improved sparrow search algorithm based on multi-strategy[J]. Computer and Modernization, 2023(10): 23-31.
- [13] 黄元春,张凌波.改进的鲸鱼优化算法及其应用[J].计算机工程与应用,2019,55(21):220-226,270.  
HUANG Yuanchun, ZHANG Lingbo. Improved whale

- optimization algorithm and its application[J]. *Computer Engineering and Applications*, 2019, 55(21): 220-226, 270.
- [14] MONISMITH D R, MAYFIELD B E. Slime Mold as a model for numerical optimization[C]. *Swarm Intelligence Symposium*, St. Louis, 2008. DOI: [10.1109/SIS.2008.4668295](https://doi.org/10.1109/SIS.2008.4668295).
- [15] LI Shimin, CHEN Huiling, WANG Mingjing, et al. Slime mould algorithm: a new method for stochastic optimization[J]. *Future Generation Computer Systems*, 2020, 111: 300-323.
- [16] HOUSSEIN E H, MAHDY M A, BLONDIN M J, et al. Hybrid slime mould algorithm with adaptive guided differential evolution algorithm for combinatorial and global optimization problems[J]. *Expert Systems with Applications*, 2021, 174. DOI: [10.1016/j.eswa.2021.114689](https://doi.org/10.1016/j.eswa.2021.114689).
- [17] HUSAIN S, AKHMETOV M, KANYMKULOV D, et al. Optimization of behavioral model of VO<sub>2</sub> switches using slime mould algorithm[C]. *International Symposium on Networks, Computers and Communications*, Doha, 2023. DOI: [10.1109/ISNCC58260.2023.10323871](https://doi.org/10.1109/ISNCC58260.2023.10323871).
- [18] DUAN Zaixin, QIAN Xuezhong, SONG Wei. Multi-strategy enhanced slime mould algorithm for optimization problems[J]. *IEEE Access*, 2025, 13: 7850-7871.
- [19] 薛贵军, 赵广昊, 史彩娟. 基于改进黏菌算法优化 BiLSTM 的短期供热负荷控制预测[J]. *沈阳工业大学学报*, 2024, 46(4): 434-441.
- XUE Guijun, ZHAO Guanghao, SHI Caijuan. Short-term heating load prediction based on improved slime mould algorithm optimized BiLSTM[J]. *Journal of Shenyang University of Technology*, 2024, 46(4): 434-441.
- [20] 王岩, 王聪英, 申艳梅. 改进的蜂群优化聚类集成联合相似度推荐算法[J]. *计算机工程*, 2020, 46(10): 88-94, 102.
- WANG Yan, WANG Congying, SHEN Yanmei. Clustering ensemble joint similarity recommendation algorithm optimized by improved bee colony[J]. *Computer Engineering*, 2020, 46(10): 88-94, 102.
- [21] 陶子君, 陆芷, 蒙炳金. 大规模符号网络划分的学习驱动型扩展变邻域搜索算法[J]. *计算机应用研究*, 2025, 42(3): 770-776.
- TAO Zijun, LU Zhi, MENG Bingjin. Learning-driven extended variable neighborhood search for signed graph partitioning[J]. *Application Research of Computers*, 2025, 42(3): 770-776.
- [22] 杜晓昕, 牛丽明, 王波, 等. 基于邻域搜索策略的蜣螂优化算法及应用[J]. *广西师范大学学报(自然科学版)*, 2025, 43(2): 149-167.
- DU Xiaoxin, NIU Liming, WANG Bo, et al. Dung beetle optimization algorithm based on neighborhood search strategy and application[J]. *Journal of Guangxi Normal University(Natural Science Edition)*, 2025, 43(2): 149-167.
- [23] 冯腾飞, 刘小生, 钟钰, 等. 矿区边坡变形预测的 IGM-LSSVM 模型[J]. *金属矿山*, 2019(3): 168-172.
- FENG Tengfei, LIU Xiaosheng, ZHONG Yu, et al. Slope deformation prediction in mining area based on IGM-LSSVM model[J]. *Metal Mine*, 2019(3): 168-172.
- [24] IBRAHIM E A, VAN DEN DOOL B, DE S, et al. Dilate-invariant temporal convolutional network for real-time edge applications[J]. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2022, 69(3): 1210-1220.
- [25] 刘辉, 凌宁青, 罗志强, 等. 基于 TCN-LSTM 和气象相似日集的电网短期负荷预测方法[J]. *智慧电力*, 2022, 50(8): 30-37.
- LIU Hui, LING Ningqing, LUO Zhiqiang, et al. Power grid short-term load forecasting method based on TCN-LSTM and meteorological similar day sets[J]. *Smart Power*, 2022, 50(8): 30-37.
- [26] 王珺, 王然风, 魏凯, 等. 基于时间序列对齐和 TCNformer 的重介精煤灰分多步预测[J]. *工矿自动化*, 2024, 50(5): 60-66.
- WANG Jun, WANG Ranfeng, WEI Kai, et al. Multi step prediction of dense medium clean coal ash content based on time series alignment and TCNformer[J]. *Journal of Mine Automation*, 2024, 50(5): 60-66.
- [27] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [28] DE JESUS D A R, MANDAL P, CHAKRABORTY S, et al. Solar PV power prediction using a new approach based on hybrid deep neural network[C]. *IEEE Power & Energy Society General Meeting, Atlanta*, 2019. DOI: [10.1109/PESGM40551.2019.8974091](https://doi.org/10.1109/PESGM40551.2019.8974091).