

文章编号: 1671-251X(2025)03-0022-11

DOI: 10.13272/j.issn.1671-251x.2024120033

极薄煤层破碎顶板条件下液压支架带压移架 残余支撑力决策方法

张传伟^{1,2}, 张刚强¹, 路正雄³, 李林岳¹, 何正伟¹, 龚凌霄¹, 黄骏峰¹

(1. 西安科技大学 机械工程学院, 陕西 西安 710054; 2. 陕西交通职业技术学院, 陕西 西安 710018;
3. 西安科技大学 安全科学与工程学院, 陕西 西安 710054)

摘要: 在破碎顶板条件下, 液压支架带压移架过程中残余支撑力的精准决策对于提高极薄煤层智能化开采效率和保障作业安全至关重要。为实现极薄煤层破碎顶板条件下液压支架带压移架残余支撑力的准确决策, 提出了一种基于改进蜣螂算法(IDBO)优化深度混合核极限学习机(DHKELM)的液压支架带压移架残余支撑力决策方法。在混合核极限学习机(HKELM)基础上引入极限学习机自动编码器(ELM-AE)结构来构建 DHKELM 模型, 以增强对复杂输入的特征提取和非线性映射能力; 引入 ICMIC 混沌映射、Lévy 飞行和贪婪策略对蜣螂算法(DBO)进行改进, 形成具备更高寻优精度和更快收敛速度的 IDBO 算法; 利用 IDBO 算法优化 DHKELM 模型的超参数, 建立 IDBO-DHKELM 模型。结合极薄煤层综采工作面液压支架带压移架实测数据, 通过可视化和相关性分析, 确定支架号、带压移架前支架支撑力、推移油缸进液压力和推移油缸行程变化速度作为影响残余支撑力的关键特征, 并构建残余支撑力决策样本数据集, 最终完成 IDBO-DHKELM 模型的训练与评估。实验结果表明: 基于 IDBO-DHKELM 模型的液压支架带压移架残余支撑力决策结果的均方根误差(RMSE)、平均绝对误差(MAE)及决定系数(R^2)分别为 0.143, 0.119, 0.971, 具有较高的决策精确度。

关键词: 极薄煤层; 液压支架; 带压移架; 残余支撑力; 改进蜣螂算法; 深度混合核极限学习机
中图分类号: TD355.4 文献标志码: A

Decision-making method for residual support force of hydraulic supports during pressurized moving under fragmented roof conditions in ultra-thin coal seams

ZHANG Chuanwei^{1,2}, ZHANG Gangqiang¹, LU Zhengxiong³, LI Linyue¹,
HE Zhengwei¹, GONG Lingxiao¹, HUANG Junfeng¹

(1. School of Mechanical Engineering, Xi'an University of Science and Technology, Xi'an 710054, China;
2. Shaanxi College of Communication Technology, Xi'an 710018, China;
3. School of Safety Science and Engineering, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: Accurate decision-making on the residual support force of hydraulic supports during pressurized moving under fragmented roof conditions is crucial for improving intelligent mining efficiency in ultra-thin coal seams and ensuring operational safety. To address this challenge, this study proposed a novel decision-making method based on a Deep Hybrid Kernel Extreme Learning Machine (DHKELM) optimized by an Improved Dung

收稿日期: 2024-12-10; 修回日期: 2025-03-21; 责任编辑: 盛男。

基金项目: 陕西省重点研发计划项目(2022GD-TSLD-63, 2022GD-TSLD-64); 陕西省教育厅青年创新团队科研计划项目(23JP100)。

作者简介: 张传伟(1974—), 男, 安徽淮南人, 教授, 博士, 研究方向为煤矿智能化及机电系统智能控制, E-mail: zhangcw@xust.edu.cn。通信作者: 路正雄(1986—), 男, 山西晋中人, 博士研究生, 研究方向为煤矿智能综采装备设计与煤矿智能化, E-mail: 13259716754@163.com。

引用格式: 张传伟, 张刚强, 路正雄, 等. 极薄煤层破碎顶板条件下液压支架带压移架残余支撑力决策方法[J]. 工矿自动化, 2025, 51(3): 22-31, 38.

ZHANG Chuanwei, ZHANG Gangqiang, LU Zhengxiong, et al. Decision-making method for residual support force of hydraulic supports during pressurized moving under fragmented roof conditions in ultra-thin coal seams[J]. Journal of Mine Automation, 2025, 51(3): 22-31, 38.



扫码移动阅读

Beetle Optimization (IDBO) algorithm. The DHKELM model was constructed by incorporating an Extreme Learning Machine Autoencoder (ELM-AE) into the Hybrid Kernel Extreme Learning Machine (HKELM) framework, enhancing its feature extraction capability and nonlinear mapping efficiency for complex inputs. Furthermore, the Dung Beetle Optimization (DBO) algorithm was enhanced with ICMIC chaotic mapping, Lévy flight, and a greedy strategy, yielding the IDBO algorithm with improved optimization accuracy and faster convergence. The IDBO algorithm was further employed to optimize the hyperparameters of the DHKELM model, forming the IDBO-DHKELM model. Using field-measured data from hydraulic supports during pressurized moving in a fully mechanized ultra-thin coal seam mining face, key influencing factors of residual support force—including support number, support force before pressurized moving, pushing cylinder inlet pressure, and pushing cylinder stroke variation speed—were identified through visualization and correlation analysis. A residual support force decision-making dataset was subsequently constructed, and the IDBO-DHKELM model was trained and evaluated. Experimental results demonstrate that the proposed IDBO-DHKELM model achieves high decision-making accuracy, with a root mean square error (RMSE) of 0.143, a mean absolute error (MAE) of 0.119, and a coefficient of determination (R^2) of 0.971.

Key words: ultra-thin coal seam; hydraulic support; pressurized moving; residual support force; improved dung beetle optimization (IDBO); deep hybrid kernel extreme learning machine(DHKELM)

0 引言

随着煤炭工业的高速发展,厚及中厚煤层的易开采资源逐渐减少,极薄煤层开采比重逐渐增加^[1-2]。但极薄煤层开采面临开采空间狭小、工人劳动强度大、开采效率低、智能化程度不足等问题^[3]。推动极薄煤层的安全、高效、智能开采对保障我国能源安全具有重要战略意义^[4]。

液压支架作为极薄煤层综采的核心支护设备,其智能化水平对实现极薄煤层智能化开采至关重要^[5-6]。在破碎顶板条件下,液压支架需采用带压移架方式跟机作业。为确保支架顶梁持续对破碎顶板提供稳定支撑,立柱底腔需保持一定的残余支撑力,并且残余支撑力的精确调控直接关系到顶板的支护效果和支架的跟机效率。然而,目前基于固定时间的液压支架自动跟机控制方式难以对破碎顶板条件下的残余支撑力准确调节,常导致支架带压移架失败,仍依赖人工进行跟机移架。对于极薄煤层工作面,这不仅极大增加了工人劳动强度和作业风险,还降低了移架效率,无法满足安全、高效、智能开采需求。因此,在破碎顶板条件下,如何实现液压支架自主跟机带压移架过程中残余支撑力的精准决策与自适应调控,对于极薄煤层的智能化开采、提高开采效率及保障作业安全具有重要意义^[7-8]。

针对液压支架带压移架跟机技术,已有众多学者展开了相关研究,主要包括带压移架控制策略和残余支撑力理论分析等方面。在带压移架控制策略方面,牛剑峰^[9]提出了一种与破碎顶板条件耦合的液压支架跟机控制策略,即通过压力传感器监测顶

板卸压状况及行程传感器判断支架拉动可能性的耦合控制策略。付翔等^[10]针对综采工作面复杂场景下液压支架人机交互协作任务需求,设计了液压支架中部跟机多模态人机协同控制系统,实现了不同顶板条件下的多模态控制。朱金雨等^[11]设计了一种通过压力与时间双向判断的液压支架自动化跟机系统,实现了带压移架的有序控制。韩宝珠等^[12]提出了一种基于 PLC 的液压支架带压移动控制方案,利用 PLC 和传感器技术,提升了液压支架带压移架的可靠性。在残余支撑力理论分析方面,杨科等^[13]推导出了在大倾角条件下带压移架的临界值,为支架失稳分析提供了理论依据。张武等^[14]基于液压支架液压系统的工作原理,利用 AMESim 软件进行仿真分析,探讨了泵站供液流量和主进回液管径对支架带压移架速度的影响。曹连民等^[15]建立了液压支架带压移架的力学模型,分析了带压移架过程中的残余支撑力范围,并设计了相应的带压移架控制回路。李志旭^[16]通过对液压支架带压移架过程进行力学特性分析,确定了立柱底腔的残余支撑力范围,并开展了液压支架力学分析计算。上述研究在液压支架带压移架跟机技术方面取得了一定进展,但现有的控制策略相对固化单一,未充分考虑复杂开采环境中残余支撑力与顶板压力、推移油缸进液压力等因素间的强耦合性及非线性关系。因此,实现带压移架残余支撑力的精准决策是一个复杂的难题。近年来,基于机器学习的数据驱动智能决策方法在煤矿开采领域逐渐兴起,凭借其强大的特征提取和非线性拟合能力,机器学习算法已广泛应用于矿压预测^[17]和瓦斯预测^[18]等任务中,这为带压移架残余支

撑力的精准决策提供了新的研究思路。

为实现极薄煤层破碎顶板条件下液压支架带压移架残余支撑力的精准决策,本文提出了一种基于改进蛭螂算法(Improved Dung Beetle Optimizer, IDBO)优化深度混合核极限学习机(Deep Hybrid Kernel Extreme Learning Machine, DHKELM)的液压支架带压移架残余支撑力决策方法。在混合核极限学习机(Hybrid Kernel Extreme Learning Machine, HKELM)基础上引入极限学习机自动编码器(Extreme Learning Machine Autoencoder, ELM-AE)结构来构建 DHKELM 模型;引入无限折叠迭代(Iterative Chaotic Map with Infinite Collapses, ICMIC)混沌映射、Lévy 飞行和贪婪策略对蛭螂算法(Dung Beetle Optimizer, DBO)进行改进,形成 IDBO 算法;采用 IDBO 算法对 DHKELM 的超参数进行优化,构建基于 IDBO-DHKELM 模型的液压支架带压移架残余支撑力决策方法,可实现极薄煤层破碎顶板条件下液压支架带压移架残余支撑力的精准决策,为液压支架自适应调控提供技术支持。

1 IDBO-DHKELM 模型

1.1 DHKELM 模型

HKELM 通过结合径向基函数(Radial Basis Function, RBF)核函数的强学习能力和 Poly 核函数的优异泛化能力,以权重系数组合构成混合核函数,有效克服了极限学习机(Extreme Learning Machine, ELM)因随机生成隐藏层权值向量和偏置引起的共线性问题^[19-20],显著提升了模型在处理复杂非线性

数据时的决策性能。

RBF 核函数表达式为

$$K_{\text{RBF}}(\mathbf{x}_n, \mathbf{x}'_n) = \exp\left(-\frac{\|\mathbf{x}_n, \mathbf{x}'_n\|^2}{2\alpha^2}\right) \quad (1)$$

式中: \mathbf{x}_n 为第 $n(n=1, 2, \dots, g, g$ 为输入样本向量数量)个输入样本向量; \mathbf{x}'_n 为与 \mathbf{x}_n 进行 RBF 核函数计算的样本向量, $\mathbf{x}_n, \mathbf{x}'_n \in \mathbf{X}$, \mathbf{X} 为输入样本矩阵; α 为 RBF 核函数参数。

Poly 核函数表达式为

$$K_{\text{Poly}}(\mathbf{x}_n, \mathbf{x}'_n) = [(\mathbf{x}_n \mathbf{x}'_n) + m]^s \quad (2)$$

式中 m, s 为 Poly 核函数参数。

混合核函数表达式为

$$K(\mathbf{x}_n, \mathbf{x}'_n) = rK_{\text{RBF}}(\mathbf{x}_n, \mathbf{x}'_n) + (1-r)K_{\text{Poly}}(\mathbf{x}_n, \mathbf{x}'_n) \quad (3)$$

式中 r 为核权重系数, $r \in [0, 1]$ 。

液压支架带压移架残余支撑力受到顶板条件和供液能力等影响,呈现出复杂非线性及动态变化特性。虽然 HKELM 具备较强的非线性数据拟合能力,但在处理复杂动态特征时,受限于特征提取能力,难以充分挖掘深层次数据特征,从而限制了其在残余支撑力决策中的应用效果。为提升模型对复杂非线性动态特征的提取能力,在 HKELM 基础上引入 ELM-AE 结构^[21],形成 DHKELM 模型,其结构如图 1 所示。ELM-AE 采用无监督学习方式从数据中自动提取深层次特征,提升了 DHKELM 模型的特征表达能力,从而增强了对残余支撑力复杂变化规律的适应性。

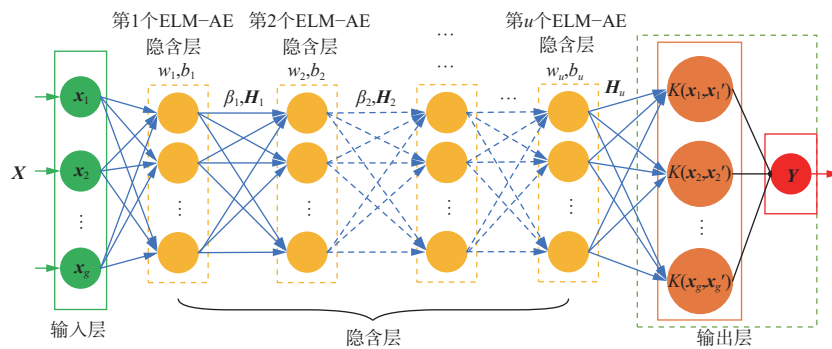


图 1 DHKELM 结构

Fig. 1 Structure of DHKELM

DHKELM 具体实现步骤如下:

- 1) 随机初始化第 $i(i=1, 2, \dots, u, u$ 为 ELM-AE 数量)个 ELM-AE 隐含层中的输入权重 w_i 和偏置 b_i 。
- 2) 通过将上一个 ELM-AE 隐含层的输出特征矩阵作为下一个 ELM-AE 隐含层的输入,依次计算第 i 个 ELM-AE 隐含层的输出特征矩阵 \mathbf{H}_i 和输出权

重 β_i 。

$$\mathbf{H}_i = f(w_i \mathbf{X} + b_i) \quad (4)$$

$$\beta_i = \left(\frac{\mathbf{I}}{\delta} + \mathbf{H}_i^T \mathbf{H}_{i-1} \right)^{-1} \mathbf{H}_i^T \mathbf{H}_{i-1} \quad (5)$$

式中: $f(\cdot)$ 为激活函数; \mathbf{I} 为单位矩阵; δ 为正归化系数。

- 3) 将最后一个 ELM-AE 隐含层的输出特征矩

阵 H_u 作为 HKELM 的决策输入, 并计算 HKELM 的输出权重 β :

$$\beta = \left(\frac{I}{\delta} + G \right)^{-1} H_u \quad (6)$$

式中 G 为混合核函数矩阵。

DHKELM 的决策值为

$$Y = \begin{bmatrix} K(x_1, x'_1) \\ K(x_2, x'_2) \\ \vdots \\ K(x_g, x'_g) \end{bmatrix} \left(\frac{I}{\delta} + G \right)^{-1} T \quad (7)$$

式中 T 为目标输出矩阵。

1.2 IDBO

DBO 是一种模拟蛭螂滚球、觅食、繁殖和偷窃行为的群智能优化算法^[22]。相比其他群智能算法, DBO 算法在处理复杂、多维的优化问题时可表现出较好的收敛性和寻优能力。然而, DBO 算法随机初始化种群位置会导致种群分布不均, 遍历性较差, 从而影响整体求解性能。在算法后期, DBO 的收敛速度较慢, 特别是在处理具有多个局部最优解的问题时, 容易陷入局部最优, 影响其全局搜索能力。通过引入 ICMIC 混沌映射、Lévy 飞行与贪婪策略对 DBO 进行改进, 以提高其在 DHKELM 模型超参数优化时的收敛速度和寻优性能。

1) ICMIC 混沌映射。为改善种群的初始分布, 引入了 ICMIC 混沌映射。ICMIC 混沌映射具有较好的随机性、均匀性、遍历性, 能够有效覆盖搜索空间, 减少初始种群分布不均带来的问题, 使得初始种群能够更均匀地覆盖搜索空间。ICMIC 混沌映射的表达式为

$$q_{j+1} = \sin(\rho/q_j) \quad (8)$$

式中: q_j 为 ICMIC 映射的第 j ($j = 1, 2, \dots, z, z$ 为蛭螂数量) 个蛭螂位置, $-1 \leq q_j \leq +1$ 且 $q_j \neq 0$; ρ 为映射参数, $\rho \in (0, +\infty)$ 。

2) Lévy 飞行和贪婪策略。在个体位置更新过程中, Lévy 飞行策略通过引入长跳跃机制, 使得算法在搜索过程中能够更有效地跳出局部最优解, 增强全局搜索能力。Lévy 飞行策略的粒子位置更新表达式为

$$q_a = q_b + (q_b - q_c) CL_{Lévy}(\lambda) \quad (9)$$

式中: q_a 为 Lévy 飞行策略更新后的粒子位置; q_b 为全局最佳粒子位置; q_c 为当前粒子位置; C 为常数, 用于调整步长; $L_{Lévy}(\cdot)$ 为 Lévy 飞行路径, 遵循 Lévy 分布; λ 为 Lévy 飞行步长。

在 Lévy 飞行的基础上, 贪婪策略则进一步保证局部搜索效率。若当前最佳粒子位置 q_d 的适应度值 $F(q_d)$ 大于 Lévy 飞行策略更新后的粒子位置 q_a 的适应度值 $F(q_a)$, 则 $q_d = q_a$ 。通过在每次更新时选择最优解的方式, 确保每次更新都朝着更优的方向进行。Lévy 飞行和贪婪策略的结合不仅加快了收敛速度, 还提升了算法的寻优精度。

1.3 IDBO-DHKELM 模型

DHKELM 模型结合 ELM-AE 的深层特征提取能力与 HKELM 的非线性映射能力, 在液压支架带压移架残余支撑力决策时, 模型的决策性能高度依赖于超参数(隐含层节点数、正则化系数、惩罚系数、核权重系数、RBF 核函数参数和 Poly 核函数参数)的选择。而传统超参数调整方法难以有效获得最优解, 且易陷入局部最优。为优化 DHKELM 的超参数, 引入 IDBO 算法。IDBO 通过 ICMIC 混沌映射生成多样化的初始种群位置, 利用 Lévy 飞行策略增强全局搜索能力, 并通过贪婪策略快速收敛到最优解。在复杂参数空间中, IDBO 能够自适应搜索超参数组合, 显著提升 DHKELM 的泛化能力与决策精度。IDBO-DHKELM 模型建立流程如图 2 所示。

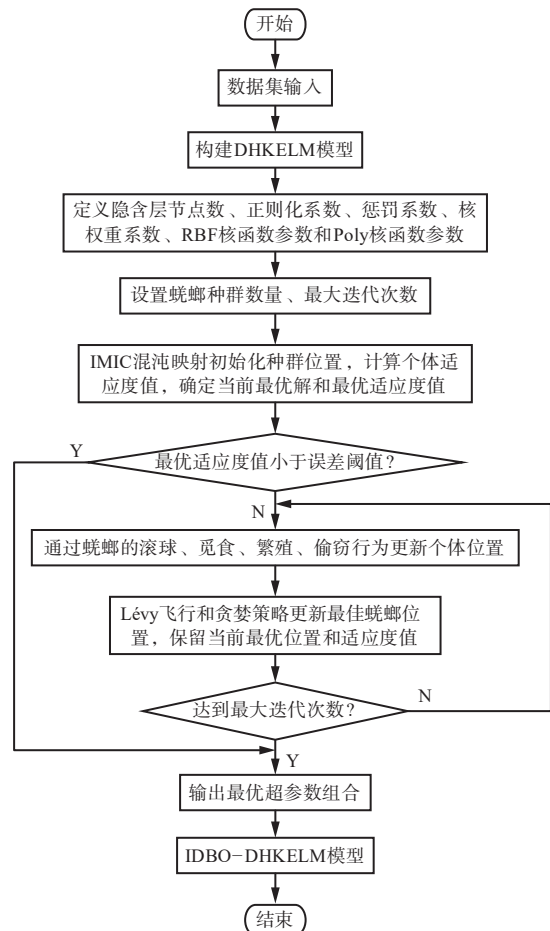


图 2 IDBO-DHKELM 模型建立流程

Fig. 2 Model development process of IDBO-DHKELM

IDBO-DHKELM 模型建立具体步骤如下:

1) 参数初始化。定义隐含层节点数、正则化系数、惩罚系数、核权重系数、RBF 核函数参数和 Poly 核函数参数的寻优范围,并设置蜣螂种群数量和最大迭代次数。

2) 个体位置更新。利用 ICMIC 混沌映射生成多样化的初始种群位置,并计算个体适应度值,确定当前最优解。检查当前最优适应度值是否小于预设误差阈值:若是,提前终止优化,输出最优参数组合;否则,通过蜣螂的滚球、觅食、繁殖和偷窃行为更新个体位置。同时采用 Lévy 飞行策略增强全局搜索能力,避免陷入局部最优。每次更新后,通过贪婪策略选择最优解并保留当前最优位置和适应度值。

3) 输出最优解。在满足误差阈值或达到最大迭代次数后,输出最优参数组合。使用优化后的超参数初始化 DHKELM 模型,建立 IDBO-DHKELM 模型。

2 基于 IDBO-DHKELM 模型的液压支架带压移架残余支撑力决策方法

为实现极薄煤层破碎顶板条件下液压支架带压移架时残余支撑力精准决策,利用 IDBO 优化 DHKELM 模型的超参数,实现基于 IDBO-DHKELM 模型的液压支架带压移架残余支撑力决策,流程如图 3 所示。

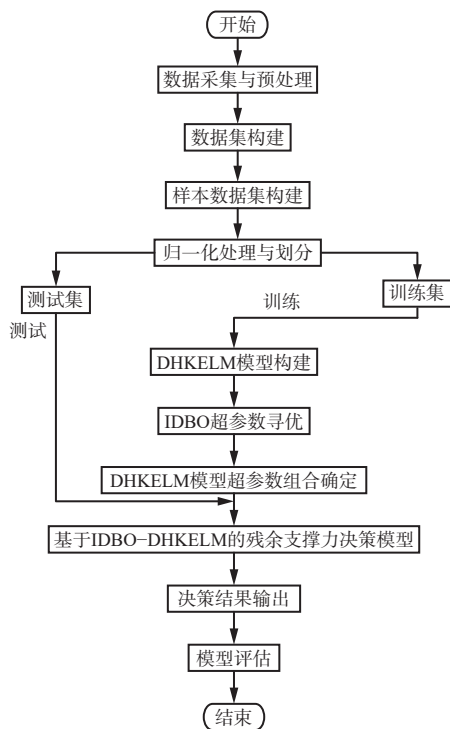


图 3 基于 IDBO-DHKELM 模型的液压支架带压移架残余支撑力决策流程

Fig. 3 Decision-making process of residual support force of hydraulic supports during pressurized moving based on IDBO-DHKELM model

基于 IDBO-DHKELM 模型的液压支架带压移架残余支撑力决策具体步骤如下:

1) 数据采集与预处理。通过液压支架电液控制系统的传感器网络,采集液压支架带压移架过程中的立柱压力、推移油缸压力和行程等数据。为应对井下复杂环境导致的数据缺失和异常,采用线性插值法填充缺失数据,并使用时域相邻值替换法修正异常波动数据,确保数据的完整性和准确性。

2) 数据集构建与划分。通过对不同支架支撑力变化特点和带压移架过程中传感器数据进行可视化分析和相关性分析,确定影响带压移架残余支撑力的关键特征,并构建决策样本数据集。为消除不同量纲和数量级差异对模型训练效果的影响,采用 min-max 归一化方法对样本数据统一缩放至 [0, 1] 范围内。最后将归一化数据按 8:2 的比例随机划分为训练集和测试集。

3) 模型训练与决策。将归一化后的训练集数据输入 DHKELM 模型进行训练,采用均方误差(Mean-Square Error, MSE)作为适应度函数。利用 IDBO 的自适应性寻优能力优化 DHKELM 模型超参数。模型训练完成后,将测试集输入 IDBO-DHKELM 模型进行决策,决策结果反归一化后输出残余支撑力决策值。

3 实验验证

3.1 实验数据

实验数据来源于延安市禾草沟二号煤矿 1123 极薄煤层综采工作面。该矿煤层平均厚度为 0.79 m,工作面长度为 120 m,且工作面倾角近水平。工作面配备 80 台 ZZ4000/6.5/13D 中间液压支架和 4 台 ZZG4000/08/16D 过渡液压支架。顶板的基本顶主要为泥质粉砂岩和粉砂岩,属中等易破碎顶板;直接顶主要为泥岩和砂质泥岩,其特点为不稳定且易破碎。因此,液压支架在进行跟机移架时,需采用带压移架方式,以确保支架对破碎顶板的有效支护。

在该极薄煤层综采工作面,液压支架电液控制系统通过安装在支架关键部位的传感器,实时监测支架支护状态、运行状态及其他生产数据。通过安装在立柱底腔处的压力传感器监测支架在升降柱过程中的支撑力。液压支架带压移架时,推移油缸有杆腔进液,无杆腔回液。安装于推移油缸处的行程传感器用于监测推移油缸行程变化,安装于推移油缸有杆腔供液管路上的压力传感器用于监测拉架过程中的推移油缸进液口压力。各传感器每 1 s 记录 1 次数据,共采集工作面 46 d 数据,并通过工业环网


传输并储存至地面数据库。

由于井下环境复杂多变,各传感器在数据采集过程中易受到多种因素干扰,导致部分数据出现缺失或异常现象。为保证数据的准确性和完整性,对于数据异常问题,分情况进行处理:单个异常值采用时域相邻值替换,如某一时刻的数据发生异常,则用前一时刻或后一时刻的数值进行替换;若异常数据较多,则去除本台液压支架当天数据。对于缺失数据,采用线性插值法进行填充,通过连接相邻已知的数据点的直线来估算缺失值。


3.2 模型输入变量与数据集划分

在工作面推进过程中,由于顶板上覆岩层应力和垮落步距的变化,导致工作面不同区域的顶板破碎程度和压力产生显著差异,这些差异直接反映在液压支架的支撑力变化上,使得不同区域支架的支撑力变化模式也呈现出不同的特点。本文对2号过渡液压支架和40号中部液压支架的部分支撑力数据变化进行分析,如图4所示。可看出2号过渡液压支架带压移架前支架支撑力变化范围为17.5~34 MPa,带压移架前支架平均支撑力为26.54 MPa;带压移架时残余支撑力变化范围为1~2.5 MPa,平均残余支撑力为1.36 MPa。而40号中部液压支架带压移架前支架支撑力变化范围为25.8~40 MPa,带压移架前支架平均支撑力为33.15 MPa;带压移架时残余支撑力变化范围为1~4 MPa,平均残余支撑力为2.31 MPa。对比分析表明,中部液压支架区域的顶板压力较高且破碎程度较大,支架需要更高的支撑力以维持顶板的稳定性,因此残余支撑力相对更高。而过渡液压支架区域顶板压力相对较低、破碎程度较小,带压移架前支架支撑力和带压移架时残余支撑力均较低且变化幅度较小。这表明,不同区域支架的带压移架前支撑力在一定程度上决定了带压移架时残余支撑力,反映了顶板破碎程度对液压支架支护性能的显著影响。

对第50号液压支架在带压移架工况下的支架支撑力、推移油缸进液压力及推移油缸行程的变化进行可视化,如图5所示。当支架进行带压移架时,操作人员同时打开降柱和移架手柄。移架手柄被打开后,供液系统向推移油缸有杆腔供液,从而使支架产生一定的拉架力,但由于带压移架前支架支撑力较高,导致拉架阻力过大,推移油缸行程并未发生变化。为顺利完成带压移架,必须降低支架支撑力以减小拉架阻力。当推移油缸进液压力为21.8 MPa时,支架支撑力从初始的38.8 MPa开始逐渐下降,当支架支撑力下降至3.5 MPa时,推移油缸行程开始减



(a) 2号过渡液压支架支撑力



(b) 40号中部液压支架支撑力

图4 不同位置液压支架支撑力

Fig. 4 Supporting force at different hydraulic support positions
小,此时操作人员停止降柱操作。推移油缸行程继续减小,直至减少至65 mm,达到所需移架位移后,停止移架操作。最后,支架支撑力由3.5 MPa上升至23.9 MPa,完成升柱动作。这一过程表明,推移油缸的有杆腔进液压力和推移油缸行程变化速度(液压支架带压移架过程中,推移油缸行程随时间变化的速率)直接影响残余支撑力的调控。




图5 50号液压支架带压移架时数据变化曲线

Fig. 5 Data variation curves of No.50 hydraulic support during pressurized moving

通过对不同位置支架支撑力变化和带压移架过程的可视化分析,结合现场调研和工人操作经验,得

出不同支架的带压移架前支架支撑力、推移油缸进液压力、推移油缸行程变化速度和工作面倾角是影响带压移架残余支撑力的关键因素。为进一步量化这些因素的影响,采用皮尔逊相关系数对各影响因素与残余支撑力进行相关性分析,见表 1(为便于比较,所有相关系数取绝对值,值越大,表明相关性越强)。结果表明,推移油缸进液压力、带压移架前支架支撑力、推移油缸行程变化速度、支架号和工作面倾角与残余支撑力的相关性依次减弱。由于该极薄煤层工作面倾角接近水平,所以工作面倾角与残余支撑力相关性较低,可忽略其影响。确定带压移架前支架支撑力、推移油缸进液压力、推移油缸行程变化速度和支架号是影响残余支撑力的关键特征并作为 IDBO-DHKELM 模型的输入变量,残余支撑力为模型的输出变量。经过数据筛选,共构建 5 142 组样本数据,其中包含 4 836 组中部液压支架样本和 306 组过渡液压支架样本。最后,将样本数据进行归一化处理,并按照 8:2 的比例随机划分为训练集和测试集,分别用于模型的训练和测试。

表 1 残余支撑力与各影响因素相关性分析结果

Table 1 Correlation analysis between residual support force and influencing factors

参数	皮尔逊相关系数				
	推移油缸进液压力	带压移架前支架支撑力	推移油缸行程变化速度	支架号	工作面倾角
带压移架残余支撑力	0.41	0.33	0.18	0.15	0.07

3.3 模型决策评估指标

为全面评估模型的决策性能,选取平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Squared Error, RMSE)及决定系数 R^2 作为模型决策评估指标。MAE 用于衡量模型决策值与实际值之间的平均绝对差异,MAE 越小,表明模型整体决策精度越高;RMSE 用于反映模型决策值与实际值之间差异的平方均值,RMSE 越小,表明模型的决策误差越小,决策效果越好; R^2 反映模型对数据的拟合程度,取值范围为 [0, 1], R^2 越接近于 1,表明模型对实际数据的拟合程度越强。

3.4 模型决策结果及评价

对比分析 ELM, HKELM, DHKELM, IDBO-DHKELM 模型在残余支撑力决策中的表现;通过使用 Schwefel 函数和 Rastrigin 函数对 PSO, DBO, IDBO 算法进行对比测试,验证 IDBO 算法在参数优化方面的优势,并分析不同优化算法对 DHKELM 模型超参数优化效果的影响。

3.4.1 模型决策结果对比分析

ELM, HKELM, DHKELM 和 IDBO-DHKELM 模型的决策结果对比如图 6 所示。ELM 模型的残余支撑力决策值与实际值之间存在较大的偏差,表现出较差的决策效果,这是由于 ELM 模型单一隐含层结构和随机的权值和偏置在处理复杂的非线性数据时,难以有效学习和表达数据中的复杂模式。HKELM 模型通过引入混合核技术,改善了模型处理复杂非线性数据的能力, HKELM 模型的残余支撑力决策值与实际值的偏差较 ELM 模型有所减小。DHKELM 模型通过结合 ELM-AE 结构和混合核技术优势,有效提升了数据的特征表达和非线性映射能力,其决策值相比于 ELM 和 HKELM 模型更接近实际值,但仍存在一定的误差。IDBO-DHKELM 模型通过引入 IDBO 算法,自适应调整超参数,优化 DHKELM 模型的训练过程,增强了模型对复杂非线性数据动态变化特征的学习能力,显著降低了决策误差,使得模型决策值更加接近实际值。由此可见, IDBO-DHKELM 模型在残余支撑力决策方面表现出了最佳效果。




图 6 不同模型的决策结果对比

Fig. 6 Comparison of decision-making results from different models

不同模型的决策结果评价见表 2。IDBO-DHKELM 模型在各项评价指标上均优于 ELM, HKELM 和 DHKELM 模型。其 RMSE 为 0.143, 较 ELM, HKELM 和 DHKELM 模型分别降低了 61.89%, 53.87% 和 43.07%; MAE 为 0.119, 较 ELM, HKELM 和 DHKELM 模型分别降低了 61.84%, 53.03% 和 42.53%, 表明 IDBO-DHKELM 模型在残余支撑力决策精度上具有显著的优势; R^2 为 0.971, 较 ELM, HKELM 和 DHKELM 模型分别提升了 23.24%, 12.38% 和 6.35%, 表明 IDBO-DHKELM 模型对残余支撑力的拟合效果较好。

3.4.2 DHKELM 模型参数优化方法决策分析

为验证 IDBO 在收敛速度和寻优精度上的优势,选择 CEC2005 基准函数集中的 Schwefel 函数测试

表 2 不同模型的决策结果评价

Table 2 Evaluation of different models in decision-making

模型	RMSE	MAE	R^2
ELM	0.376	0.312	0.788
HKELM	0.310	0.253	0.864
DHKELM	0.251	0.207	0.913
IDBO-DHKELM	0.143	0.119	0.971

IDBO 全局寻优能力, 以及 Rastrigin 函数测试其在处理多个局部最优解时的局部搜索性能。测试函数的维度、取值范围和最优解信息见表 3。

表 3 测试函数

Table 3 Test functions


函数	维度	取值范围	最优解
Schwefel	30	[-100, 100]	0
Rastrigin	30	[-5.12, 5.12]	0

在 Schwefel 和 Rastrigin 函数测试过程中, 将 IDBO 与 PSO, DBO 算法进行对比分析, 为减少随机因素的影响, 并保证实验的公平性, 种群规模和最大迭代次数统一设置为 30 和 300, 每个测试函数独立运行 10 次, 绘制平均适应度值变化曲线, 如图 7 所示。可看出在 Schwefel 函数测试过程中, 3 种算法的适应度值均随着迭代次数的增加逐渐收敛, 其中 IDBO 算法的收敛速度最快, DBO 算法次之, 且均达到最优适应度值 0, PSO 算法的收敛速度较慢, 未达到最优适应度值。在 Rastrigin 函数测试中, PSO 算法未达到收敛状态, IDBO 算法收敛速度仍最佳。由此可见, IDBO 算法在收敛速度和寻优精度上均优于 DBO 和 PSO 算法, 证明了其高效性、稳定性。


在此基础上, 分析不同优化算法 (PSO, DBO 和 IDBO) 对 DHKELM 模型超参数优化的决策效果。实验参数设置: 种群数量为 30, 最大迭代次数为 50。DHKELM 模型的隐含层节点数、核权重系数、惩罚系数、正则化系数、RBF 核函数参数 α 、Poly 核函数参数 m 和 s 寻优范围分别设定为 [1, 100], [0, 1], $[10^{-3}, 10^3]$, $[10^{-3}, 10^3]$, $[10^{-2}, 10^2]$, $[10^{-2}, 10^2]$ 和 [1, 10]。

为探讨不同隐含层数对 DHKELM 模型决策效果的影响, 分析不同隐含层数下模型的 R^2 和 RMSE, 如图 8 所示。当隐含层数为 2 时, R^2 最大 (0.971)、RMSE 最小 (0.143), 决策准确率最佳。随着隐含层数增加, 决策准确率降低, 当隐含层数为 4 时, R^2 最小 (0.938)、RMSE 最大 (0.227), 决策准确率最差。因此, 设置 DHKELM 模型的隐含层数为 2。

不同算法优化 DHKELM 模型的适应度值随迭



(a) Schwefel 函数测试结果



(b) Rastrigin 函数测试结果

图 7 平均适应度值变化曲线

Fig. 7 Variation curves of average fitness values

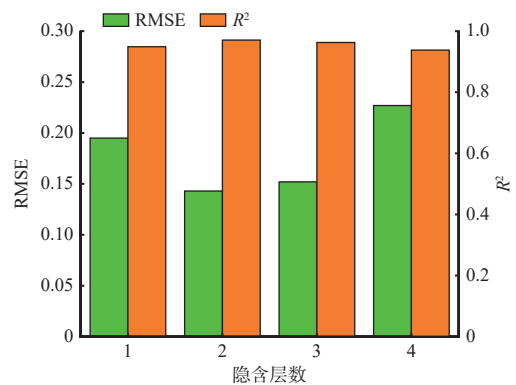


图 8 不同隐含层数下的决策结果

Fig. 8 Decision-making results under different hidden layers configurations

代次数变化曲线如图 9 所示。可看出不同算法优化 DHKELM 模型的适应度值随着迭代次数增加逐渐减小, 其中 IDBO-DHKELM 模型表现出较快的收敛速度和较小的误差, 在迭代到第 13 次时, 适应度值达到最小 (0.023) 且趋于稳定状态, 表明 IDBO 优化 DHKELM 模型超参数时具有较好的收敛性和寻优精度。IDBO 优化的最优超参数组合: 第 1 层隐含层节点数为 30, 第 2 层隐含层节点数为 58, 核权重系数为 0.36, 惩罚系数为 142.64, 正则化系数为 353.57, RBF 核函数参数 α 为 69.53, Ploy 核函数参数 m, s 分别为 41.16, 6。

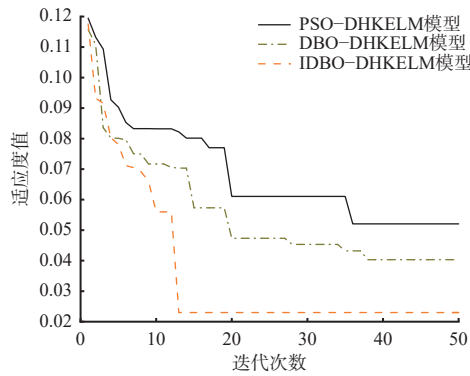


图 9 不同算法优化 DHKELM 模型迭代曲线

Fig. 9 Iteration curves of different algorithms for optimizing DHKELM model

不同算法优化 DHKELM 模型的决策结果如图 10 所示。可看出相较于基于 DBO-DHKELM 和 PSO-DHKELM 模型, 基于 IDBO-DHKELM 模型的残余支撑力决策值更接近实际值。

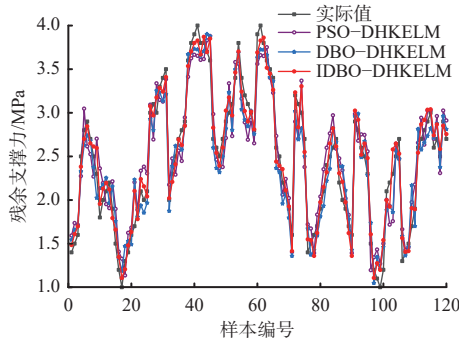


图 10 不同算法优化 DHKELM 模型决策结果对比

Fig. 10 Comparison of decision-making performance among different algorithms optimizing DHKELM model

采用评价指标定量分析 PSO-DHKELM, DBO-DHKELM 和 IDBO-DHKELM 模型的决策结果, 见表 4。可看出相较于 PSO-DHKELM, DBO-DHKELM 模型, IDBO-DHKELM 模型 RMSE 分别降低了 40.90%, 35%, MAE 分别降低了 41.38%, 32.39%, R^2 分别提升了 4.97%, 2.97%。表明利用 IDBO 优化 DHKELM 模型超参数, 可有效提高残余支撑力决策精度。

表 4 不同算法优化 DHKELM 模型决策结果评价

Table 4 Evaluation of different optimization algorithms for DHKELM model

模型	RMSE	MAE	R^2
PSO-DHKELM	0.242	0.203	0.925
DBO-DHKELM	0.220	0.176	0.943
IDBO-DHKELM	0.143	0.119	0.971

此外, 利用 Matlab 中内置的图像生成函数, 绘制 IDBO-DHKELM 模型的决策结果和误差, 分别如

图 11、图 12 所示。可看出数据点紧密地集中在拟合线附近, 表明 IDBO-DHKELM 模型在对残余支撑力决策时具有较好的拟合效果; IDBO-DHKELM 模型的决策值与实际值的误差不超过 0.5 MPa, 且相对误差集中在 10% 以内, 表明 IDBO-DHKELM 模型具有较高的决策精度和稳定性。




图 11 IDBO-DHKELM 模型决策结果

Fig. 11 Decision-making results of IDBO-DHKELM model




图 12 IDBO-DHKELM 模型决策误差

Fig. 12 Decision-making error analysis of IDBO-DHKELM model

4 结论

1) 在 HKELM 基础上引入 ELM-AE 结构, 构建了 DHKELM 模型, 以增强对复杂输入的特征提取和非线性映射能力。引入 ICMIC 混沌映射、Lévy 飞行和贪婪策略对 DBO 算法进行改进, 形成 IDBO 算法, 该算法具备更高的寻优精度和更快的收敛速度。利用 IDBO 算法优化 DHKELM 模型的超参数, 构建了基于 IDBO-DHKELM 模型的液压支架带压移架残余支撑力决策方法。

2) 结合极薄煤层综采工作面液压支架带压移架实测数据, 采用线性插值和时域相邻值替换法对数据进行预处理。通过可视化和相关性分析, 确定支架号、带压移架前支架支撑力、推移油缸进液压力和推移油缸行程变化速度为影响液压支架带压移架残余支撑力的关键特征。

3) 采用 Schwefel 和 Rastrigin 函数对 IDBO 算法进行性能测试, 结果表明, IDBO 算法在寻优精度和收敛速度上均优于 PSO 和 DBO 算法。不同模型决策性能对比结果表明, IDBO-DHKELM 模型的残余支撑力决策结果的 RMSE, MAE 和 R^2 分别为 0.143, 0.119 和 0.971, 其决策精度显著优于 ELM, HKELM 和 DHKELM 模型。

参考文献(References):

- [1] 袁永, 屠世浩, 陈忠顺, 等. 薄煤层智能开采技术研究现状与进展[J]. 煤炭科学技术, 2020, 48(5): 1-17.
YUAN Yong, TU Shihao, CHEN Zhongshun, et al. Current situation and development of intelligent mining technology for thin coal seams[J]. Coal Science and Technology, 2020, 48(5): 1-17.
- [2] ZHAO Tongbin, ZHANG Zhenyu, TAN Yunliang, et al. An innovative approach to thin coal seam mining of complex geological conditions by pressure regulation[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2014, 71: 249-257.
- [3] 童应山, 王森, 张连东, 等. 基于覆岩破断特征的极薄煤层工作面支架工作阻力确定[J]. 西安科技大学学报, 2024, 44(1): 64-73.
TONG Yingshan, WANG Sen, ZHANG Liandong, et al. Determination of support working resistance in the working face of extremely-thin coal seam based on overburden fracture characteristics[J]. Journal of Xi'an University of Science and Technology, 2024, 44(1): 64-73.
- [4] 王国法, 刘峰, 庞义辉, 等. 煤矿智能化——煤炭工业高质量发展的核心技术支撑[J]. 煤炭学报, 2019, 44(2): 349-357.
WANG Guofa, LIU Feng, PANG Yihui, et al. Coal mine intellectualization: the core technology of high quality development[J]. Journal of China Coal Society, 2019, 44(2): 349-357.
- [5] 周开平. 薄煤层智能化无人工作面成套装备与技术[J]. 煤炭科学技术, 2020, 48(3): 59-67.
ZHOU Kaiping. Complete equipment and technology for intelligent unmanned working face in thin coal seam[J]. Coal Science and Technology, 2020, 48(3): 59-67.
- [6] 杨生华, 周永昌, 芮丰, 等. 薄煤层开采与成套装备技术的发展趋势[J]. 煤炭科学技术, 2020, 48(3): 49-58.
YANG Shenghua, ZHOU Yongchang, RUI Feng, et al. Development trend of thin coal seam mining and complete equipment technology[J]. Coal Science and Technology, 2020, 48(3): 49-58.
- [7] 王国法, 刘峰, 孟祥军, 等. 煤矿智能化(初级阶段)研究与实践[J]. 煤炭科学技术, 2019, 47(8): 1-36.
WANG Guofa, LIU Feng, MENG Xiangjun, et al. Research and practice on intelligent coal mine construction (primary stage) [J]. Coal Science and Technology, 2019, 47(8): 1-36.
- [8] 葛世荣. 智能化采煤装备的关键技术[J]. 煤炭科学技术, 2014, 42(9): 7-11.
GE Shirong. Key technology of intelligent coal mining equipment[J]. Coal Science and Technology, 2014, 42(9): 7-11.
- [9] 牛剑峰. 综采液压支架跟机自动化智能化控制系统研究[J]. 煤炭科学技术, 2015, 43(12): 85-91.
NIU Jianfeng. Study on automatic and intelligent following control system of hydraulic powered support in fully-mechanized coal mining face[J]. Coal Science and Technology, 2015, 43(12): 85-91.
- [10] 付翔, 李浩杰, 张锦涛, 等. 综采液压支架中部跟机多模式人机协同控制系统[J]. 煤炭学报, 2024, 49(3): 1717-1730.
FU Xiang, LI Haojie, ZHANG Jintao, et al. Multimodal human-machine collaborative control system for hydraulic supports following the shearer in the middle range of fully mechanized mining face[J]. Journal of China Coal Society, 2024, 49(3): 1717-1730.
- [11] 朱金雨, 李国莲. 液压支架跟机自动化系统设计[J]. 工矿自动化, 2013, 39(12): 1-4.
ZHU Jinyu, LI Guolian. Design of machinery-tracked automatic system of hydraulic support[J]. *Industry and Mine Automation*, 2013, 39(12): 1-4.
- [12] 韩宝珠, 安叶青. 基于 PLC 的液压支架带压移架控制技术[J]. 煤炭技术, 2022, 41(7): 185-187.
HAN Baozhu, AN Yeqing. Control technology of hydraulic support moving under pressure based on PLC[J]. Coal Technology, 2022, 41(7): 185-187.
- [13] 杨科, 池小楼, 刘帅. 大倾角煤层综采工作面液压支架失稳机理与控制[J]. 煤炭学报, 2018, 43(7): 1821-1828.
YANG Ke, CHI Xiaolou, LIU Shuai. Instability mechanism and control of hydraulic support in fully mechanized longwall mining with large dip[J]. Journal of China Coal Society, 2018, 43(7): 1821-1828.
- [14] 张武, 贾艳平, 路正雄, 等. 大采高液压支架带压移架性能研究[J]. 煤矿机械, 2020, 41(7): 53-55.
ZHANG Wu, JIA Yanping, LU Zhengxiong, et al. Performance study on moving support with pressure for hydraulic support in large mining height[J]. Coal Mine Machinery, 2020, 41(7): 53-55.
- [15] 曹连民, 张亚珠, 郭徽, 等. 大采高液压支架带压移架技术[J]. 煤矿安全, 2018, 49(3): 83-86.
CAO Lianmin, ZHANG Yazhu, GUO Hui, et al. Advancing support with pressure technology for hydraulic support with large mining height[J]. Safety in Coal Mines, 2018, 49(3): 83-86.

- optical flow[J]. *Journal of Intelligent & Robotic Systems*, 2020, 100(3): 1179-1194.
- [14] MOURIKIS A I, ROUMELIOTIS S I. A multi-state constraint Kalman filter for vision-aided inertial navigation[C]. *IEEE International Conference on Robotics and Automation*, Rome, 2007: 3565-3572.
- [15] CARLSSON H, SKOG I, JALDÉN J. Self-calibration of inertial sensor arrays[J]. *IEEE Sensors Journal*, 2021, 21(6): 8451-8463.
- [16] 于永军, 徐锦法, 张梁, 等. 惯导/双目视觉位姿估计算法研究[J]. *仪器仪表学报*, 2014, 35(10): 2170-2176.
YU Yongjun, XU Jinfa, ZHANG Liang, et al. Research on SINS/binocular vision integrated position and attitude estimation algorithm[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(10): 2170-2176.
- [17] 万继成, 张旭辉, 杨文娟, 等. 基于视觉与惯导的掘进机组合定位方法[J/OL]. *煤炭科学技术*: 1-12[2025-01-27]. <http://kns.cnki.net/kcms/detail/11.2402.td.20240524.1014.003.html>.
WAN Jicheng, ZHANG Xuhui, YANG Wenjuan, et al. Combined positioning method of roadheader based on vision and inertial navigation[J/OL]. *Coal Science and Technology*: 1-12[2025-01-27]. <http://kns.cnki.net/kcms/detail/11.2402.td.20240524.1014.003.html>.
- [18] 毛清华, 周庆, 安炎基, 等. 惯导与视觉信息融合的掘进机精确定位方法[J]. *煤炭科学技术*, 2024, 52(5): 236-248.
MAO Qinghua, ZHOU Qing, AN Yanji, et al. Precise positioning method of tunneling machine for inertial navigation and visual information fusion[J]. *Coal Science and Technology*, 2024, 52(5): 236-248.
- [19] 王平, 周雪峰, 安爱民, 等. 一种鲁棒且线性的 PnP 问题求解方法[J]. *仪器仪表学报*, 2020, 41(9): 271-280.
WANG Ping, ZHOU Xuefeng, AN Aimin, et al. Robust and linear solving method for Perspective-n-Point problem[J]. *Chinese Journal of Scientific Instrument*, 2020, 41(9): 271-280.
- [20] VALENTI R G, DRYANOVSKI I, XIAO Jizhong. Keeping a good attitude: a quaternion-based orientation filter for IMUs and MARGs[J]. *Sensors*, 2015, 15(8): 19302-19330.
- [21] 庞义辉, 刘新华, 王泓博, 等. 基于千斤顶行程驱动的液压支架支护姿态与高度解析方法[J]. *采矿与安全工程学报*, 2023, 40(6): 1231-1242.
PANG Yihui, LIU Xinhua, WANG Hongbo, et al. Support attitude and height analysis method of hydraulic support based on jack stroke drive[J]. *Journal of Mining and Safety Engineering*, 2023, 40(6): 1231-1242.
- [16] 李志旭. 液压支架带压移架控制技术研究与应用[D]. 青岛: 山东科技大学, 2020.
LI Zhixu. Research and application on control technology of advancing support with pressure for hydraulic support[D]. Qingdao: Shandong University of Science and Technology, 2020.
- [17] 曾庆田, 吕珍珍, 石永奎, 等. 基于 Prophet+LSTM 模型的煤矿井下工作面矿压预测研究[J]. *煤炭科学技术*, 2021, 49(7): 16-23.
ZENG Qingtian, LYU Zhenzhen, SHI Yongkui, et al. Research on prediction of underground coal mining face pressure based on Prophet+LSTM model[J]. *Coal Science and Technology*, 2021, 49(7): 16-23.
- [18] 王鹏, 伍永平, 王桂林, 等. 矿井瓦斯浓度 Lagrange-ARIMA 实时预测模型研究[J]. *煤炭科学技术*, 2019, 47(4): 141-146.
WANG Peng, WU Yongping, WANG Shuanlin, et al. Study on Lagrange-ARIMA real-time prediction model of mine gas concentration[J]. *Coal Science and Technology*, 2019, 47(4): 141-146.
- [19] TIAN Zhongda, LI Shujiang, WANG Yanhong, et al. Wind power prediction method based on hybrid kernel function support vector machine[J]. *Wind Engineering*, 2018, 42(3): 252-264.
- [20] 王超, 蔺红, 庞晓虹. 基于 HPO-VMD 和 MISMA-DHKELM 的短期光伏功率组合预测[J]. *太阳能学报*, 2023, 44(12): 65-73.
WANG Chao, LIN Hong, PANG Xiaohong. Short-term photovoltaic power combination prediction based on HPO-VMD and MISMA-DHKELM[J]. *Acta Energetica Solaris Sinica*, 2023, 44(12): 65-73.
- [21] CHU Yunfei, FENG Chunyan, GUO Caili, et al. Network embedding based on deep extreme learning machine[J]. *International Journal of Machine Learning and Cybernetics*, 2019, 10(10): 2709-2724.
- [22] XUE Jiankai, SHEN Bo. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. *The Journal of Supercomputing*, 2023, 79(7): 7305-7336.

~~~~~  
(上接第 31 页)