基于牛顿拉夫逊算法与BP神经网络的岩爆烈度预测模型*

李军民[1],王永智[2],张亭[2],周义升[3],罗宏伟[3],柳小强[3]

(1.陕西旬阳鑫源矿业有限责任公司, 陕西 旬阳市 725700;
2.西北矿冶研究院, 甘肃 白银市 730900;
3.白银有色集团股份有限公司深部矿业公司, 甘肃 白银市 730900)

摘要:岩爆烈度预测是矿山安全管理中的关键任务。为提升预测精度与工程实用性,提出一种结合牛顿拉夫逊优化算法(NRBO)与BP神经网络(BPNN)的岩爆烈度预测模型(NRBO-BPNN)。该模型通过引入基于梯度的NRBO搜索机制,有效克服了传统BPNN模型在训练过程中易陷入局部最优解的问题,显著提高了全局搜索能力与收敛效率。对比试验结果表明,NRBO-BPNN在训练集和测试集上的准确率分别达到100%和86.67%,总准确率达96%,仅出现4次误判,优于传统BPNN、支持向量机(SVM)、随机森林(RF)和极限学习机(ELM)等常见模型。基于所提模型开发了岩爆烈度预测综合系统,并成功应用于马路坪矿与冬瓜山铜矿的现场数据分析中,验证了其工程适用性与实用价值。研究结果表明,NRBO-BPNN可为矿山工程安全设计提供更加高效、准确的决策支持,具有显著的工程推广潜力。

关键词:岩爆烈度;NRBO优化算法;BP神经网络;岩爆预测

中图分类号:TD32;TU45 **文献标识码**:A **文章编号**:1005-2763(2025)08-0127-07

Rockburst Intensity Prediction Model Based on Newton-Raphson-Based Optimizer and BP Neural Network

LI Junmin[1], *WANG Yongzhi*[2], *ZHANG Ting*[2], *ZHOU Yisheng*[3], *LUO Hongwei*[3], *LIU Xiaoqiang*[3]

(1.Shaanxi Xunyang Xinyuan Mining Co., Ltd., Xunyang, Shaanxi 725700, China;
2.Northwest Research Institute of Mining and Metallurgy, Baiyin, Gansu 730900, China;
3.Deep Mining Company, Baiyin Nonferrous Group Co., Ltd., Baiyin, Gansu 730900, China)

Abstract: Rockburst intensity prediction is a critical task in mine safety management. To improve prediction accuracy and practical applicability, a rockburst intensity prediction model named NRBO-BPNN that combined the Newton-Raphson Based Optimizer (NRBO) with a BP Neural Network (BPNN) was proposed. By integrating a gradient-guided search mechanism based on the Newton-Raphson method, the model effectively overcomes the problem that the traditional BPNN is easy to fall into the local optimal solution during the training process, and significantly improves the global search ability and convergence efficiency. Experimental comparisons demonstrated that the NRBO-BPNN model achieved an accuracy of 100% on the training set and 86.67% on the testing set. The total accuracy rate is 96%, and only four misjudgments occur. It is superior to common models such as traditional BPNN, Support Vector Machine (SVM), Random Forest (RF) and Extreme Learning Machine (ELM). Finally, a comprehensive system for predicting rockburst intensity was developed based on the proposed model and successfully applied to on-site data analysis of Maluping Mine and Dongguashan Copper Mine, verifying its engineering applicability and practical value. The research results indicate that NRBO-BPNN can provide more efficient and accurate decision support for mining engineering safety design, and has significant potential for engineering promotion.

Key words: Rockburst intensity, NRBO optimization, BP Neural Network, Rockburst prediction

0 引言

岩爆是矿山、隧道等工程中破坏剧烈的灾害,发生时可能造成严重的经济损失和人员伤亡[1]。例如,南非某深埋矿山在2 000 m以下的巷道发生岩爆,造成里氏3.2和2.9级的地震[2];锦屏二级水电

* **收稿日期**:2025-05-21
基金项目:甘肃省科技计划(重点研发计划)项目(23YFGD0002);白银市科技基金项目(2022-2-3G)
作者简介:李军民(1976—),男,甘肃白银人,高级工程师,主要从事矿山管理与开采设计的工作。E-mail:270422854@qq.com

站 2 号辅助洞在 AK9+670 号桩发生掌子面强烈岩爆,导致掌子面前方 4～5 m 范围的围岩崩落[3];引汉济渭秦岭隧洞 4# 支洞中等以上等级的岩爆频发,给施工安全带来隐患[4]。现阶段工程中,开展岩爆烈度预测研究是岩爆防治的主要手段。

岩爆烈度预测研究旨在揭示岩爆机理,并采取有效防控措施。科学、准确的岩爆烈度预测方法能够有效预防岩爆并减少危害。长期以来,岩爆烈度预测的研究主要集中在单一指标准则上,如 Russenes 准则、Hoek 准则、Turchaninov 准则、弹性应变能准则、Barton 标准。然而,随着工程中岩爆事件发生频率的增加,单一指标准则在高精度预测方面逐渐显现出局限性,因此,研究趋势正逐步向综合多指标标准转变。近年来,机器学习方法在多指标岩爆预测中得到了广泛应用,研究人员已开展了大量相关研究。例如,王超等[5]基于无约束优化算法建立了 10 个岩爆烈度 BP 神经网络预测模型,预测了在样本数量分别为 40, 70 和 100 时的岩爆烈度等级,并提出了考虑不同样本规模影响的岩爆烈度等级预测指数。张亭等[6]采用动量梯度下降法优化误差反传神经网络,选取应力系数、脆性系数和弹性能量指数作为模型的预测指标,收集 46 组实例样本的数据,建立岩爆烈度预测的动量梯度下降 BPM 神经网络模型。李军民等[7]建立了一种支持向量机(SVM)岩爆烈度分级方法,选取 60 组岩爆案例,通过压缩因子和异步学习因子改进粒子群优化算法(APSO)的寻优能力,优化 SVM 模型,建立岩爆烈度预测的 APSO-SVM 模型。

上述岩爆烈度预测方法有效促进了岩爆预测技术的发展,并为深部岩爆灾害机理的理解和防控提供了指导。然而,这些方法仍存在一些局限性:一是传统的岩爆烈度预测方法通常基于单一指标进行预测,无法全面考虑岩爆发生的多维因素,导致预测结果不够精确;二是传统优化方法容易陷入局部最优解,尤其在复杂的非线性问题中,优化效率较低,且对初始参数依赖较强;三是利用编程软件建立的岩爆烈度预测模型多为复杂系统,操作简便、效率高且具有良好可视化效果的综合预测系统较少。为克服这些局限性,本文提出了一种牛顿拉夫逊算法(Newton-Raphson Based Optimizer, NRBO)优化 BP 神经网络(Back Propagation Neural Network, BPNN)的岩爆防治技术,并结合编程软件开发了一个集成的岩爆烈度预测程序。与传统方法相比,所提出的 NRBO-BPNN 方法在岩爆烈度预测中展现出显著优势。

1 方法原理

NRBO-BPNN 模型的研究过程主要包括数据准备、模型构建和预测输出 3 个阶段。在数据准备阶段,通过现场监测数据和相关文献资料,构建包含多因素特征的样本数据集,并进行归一化处理。模型构建阶段利用 NRBO 算法对 BPNN 网络的初始权重和阈值进行优化,以提升神经网络的预测精度和收敛速度。NRBO 算法结合牛顿拉夫逊搜索机制,通过对种群中最优和最差个体的动态学习,引导网络参数搜索向更优解演化。在预测输出阶段,通过输出等级得到误差指标,评估模型预测性能,并以图表形式展示实际值与预测值的拟合效果。整体流程如图 1 所示。

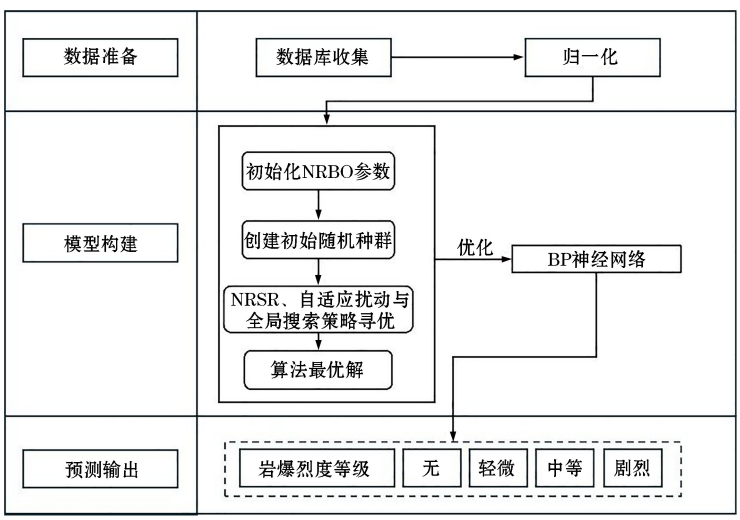


图 1 NRBO-BPNN 方法流程

Fig.1 Flow of NRBO-BPNN method

1.1 NRBO 原理

本文提出的 NRBO 优化方法包括初始种群生成、搜索机制设计与自适应更新策略 3 个阶段。首先,利用随机策略生成初始种群。然后,通过引入基于牛顿拉夫逊搜索法的更新机制(Newton-Raphson Search Rule, NRSR),指导种群沿梯度方向加速进化。在此基础上,结合动态调节因子与全局扰动因子,实现搜索能力与收敛精度的动态平衡。

1.1.1 初始种群生成

初始种群由多维向量组成,采用随机初始化策略生成候选解,确保解空间的广度与多样性。这一过程为后续迭代提供了充分的搜索基础。设种群规模[8]为N_p,每个个体$\boldsymbol{X}_n$由维度为m的模糊决策向量构成。初始种群的表示形式如式(1)所示:

$$\boldsymbol{X}_n=\begin{bmatrix} x_1^1 & x_2^1 & \cdots & x_m^1 \\ x_1^2 & x_2^2 & \cdots & x_m^2 \\ \vdots & \vdots & & \vdots \\ x_1^{N_p} & x_2^{N_p} & \cdots & x_m^{N_p} \end{bmatrix}_{N_p\times m} \tag{1}$$

式中,x_n表示第n个个体的取值。

1.1.2 牛顿拉夫逊搜索机制(NRSR)

牛顿拉夫逊搜索机制(NRSR)是 NRBO 算法的核心组成部分,旨在通过数学形式的拉夫逊搜索法,在可行区域中寻找更优位置。该机制不依赖于目标函数的具体表达形式,而是通过样本点之间的位置关系与泰勒展开构建搜索方向,其基本公式如下:

$$NRSR=\mathrm{rand}n\times\frac{(X_w-X_b)\times\boldsymbol{\Delta x}}{2\times(X_w+X_b-2\times x_n)} \tag{2}$$

式中:rand$n$是随机数;X_w与X_b分别表示当前种群中的最差与最优个体;$\boldsymbol{\Delta x}$为步长向量,由当前个体与最优解之间的差异确定,详见式(4)。该方法采用当前个体的位置进行搜索,从而节省计算资源。

为提升算法的适应性,引入动态调节因子δ,其表达式如下:

$$\delta=\left(1-\left(\frac{2\times I}{I_{\max}}\right)\right)^5 \tag{3}$$

式中:I为当前迭代次数;$I_{\max}$为最大迭代次数。该参数在搜索初期保持较高值以维持多样性,在后期逐渐减小以增强收敛能力。

步长向量$\boldsymbol{\Delta x}$的计算方式如下:

$$\boldsymbol{\Delta x}=\mathrm{rand}(1,m)\times|X_b-X_n^I| \tag{4}$$

式中:rand$(1,m)$是具有m维度决策变量的随机数;X_n^I表示第I次迭代中的第n个个体。

1.1.3 自适应扰动与全局搜索策略

为增强算法的跳出局部最优能力,NRBO 算法引入全局扰动向量,综合考虑最优解与随机个体间的差异信息,构建扰动项,计算公式如下。

$$\boldsymbol{\rho}=a\times(X_b-X_n^I)+b\times(X_{r_1}^I-X_{r_2}^I) \tag{5}$$

式中:$\boldsymbol{\rho}$为扰动向量;a和b是(0,1)之间的随机数;r_1和r_2是从总体中随机选择的不同整数,r_1和r_2的值不相等。

通过控制扰动项的比例,模型能够在后期实现局部精细搜索,同时在早期阶段保持全局探索能力。在后期阶段,进一步引入向量扰动机制,利用当前个体与其邻域的均值位置构建微调方向,从而提升局部搜索的精度。

1.2 BP 神经网络

在本文构建的 BP 神经网络[9]中包含输入层、输出层和隐含层共 3 层神经网络,其中隐含层结构的设置参考了文献[10]和[11]中关于神经元数量与网络性能关系的研究成果。为确保模型在面对岩爆烈度预测这一非线性复杂问题时具备足够的学习能力,同时兼顾计算效率与泛化性能,本文最终采用单隐含层结构,该结构在试验验证中表现出较优的拟合效果和较低的误差水平。

(1) 输入层设置为 3 个神经元,对应岩爆烈度预测所选取的 3 个主要指标,分别为σ_θ/σ_c,σ_c/σ_t和W_{et},其中,σ_θ是岩石的最大主应力,σ_c是岩石的单轴抗压强度,σ_t是岩体的抗拉强度,W_{et}是岩体单位体积所储存的弹性能。

(2) 输出层为 4 个神经元,用于输出预测结果。

(3) 隐含层的神经元数量应考虑两个因素:一方面,保证模型具有充分的非线性映射能力,以捕捉输入变量间复杂的交互关系;另一方面,防止神经元数量过多导致模型过拟合或训练不稳定。因此,在多次试验对比基础上,选定 10 个神经元作为隐含层结构,在训练精度与模型泛化之间取得良好平衡。

2 岩爆烈度预测的 NRBO-BPNN 模型

2.1 数据集

全面、准确地反映岩爆的形成条件是岩爆烈度指标选取的关键,岩爆的发生与岩体在不同物理环境下的应力、脆性和能量储存密切相关,σ_θ/σ_c能够反映岩体在应力作用下的稳定性,揭示岩爆发生的潜在风险,σ_θ/σ_c越大,岩体破裂的概率越高。σ_c/σ_t用于描述岩石在应力作用下的脆性程度,表示岩石在受压破裂时的应力响应。σ_c/σ_t较高的岩石更容易在应力作用下发生破裂,进而诱发岩爆。因此,σ_c/σ_t作为影响岩爆发生的关键因素,能有效地提供

有关岩体破坏模式的重要信息,有助于判断岩爆发生的敏感性。W_{et}是评估岩石在外力作用下储存和释放能量的能力,它反映了岩石的弹性特征和储能能力。在岩爆发生前,岩石通常会积累一定的弹性能量,当外力超过岩体的承载能力时,这些能量会迅速释放,引发岩爆。因此,W_{et}作为岩石弹性和储能能力的度量,能够有效地评估岩爆的潜在发生概率和烈度。

本研究所使用的岩爆烈度数据集基于多个国内外岩石力学试验研究与地下工程实例的综合整理,主要参考文献[12]至文献[16]中公开发表的数据,研究所用数据共计 100 组,这些数据涵盖了影响岩爆烈度的主要指标,具有较强的工程代表性。在模型运算过程中,传统 BPNN 需要人工设定的权重参数在本研究中由 NRBO 算法自适应优化完成。NRBO 通过引入 NRSR 与全局扰动因子,动态调整输入特征的权重及网络连接参数,从而提升模型的预测精度并避免陷入局部最优。此外,输入变量在训练前均经过归一化处理,以确保各维度数据在同一数量级范围内,提高模型的稳定性与训练效率。按照常规比例,选取 100 组数据集,用于模型的训练与性能评估,数据特征见表 1。

表 1 岩爆烈度数据集数据特征

Table 1 Data characteristics of rockburst intensity data set

岩爆烈度等级	岩爆烈度指标	均值	中位数	最小值	最大值	标准差
1	σ_θ/σ_c	0.20	0.20	0.10	0.43	0.20
	σ_c/σ_t	24.50	23.00	6.70	47.90	36.00
	W_{et}	3.00	2.00	1.40	7.40	2.30
2	σ_θ/σ_c	0.43	0.42	0.22	0.67	0.37
	σ_c/σ_t	20.77	20.40	6.80	34.30	24.00
	W_{et}	2.94	2.90	0.90	5.10	5.10
3	σ_θ/σ_c	0.57	0.56	0.28	0.84	0.40
	σ_c/σ_t	24.20	21.85	9.50	55.00	14.70
	W_{et}	4.41	4.30	2.00	7.10	7.10
4	σ_θ/σ_c	0.72	0.68	0.42	1.41	0.58
	σ_c/σ_t	19.08	17.25	11.20	32.20	13.20
	W_{et}	6.18	6.25	2.00	13.20	6.30

(1) 文献汇总与筛选。选取具有权威性和代表性的岩爆相关研究文献,包括实验室测试(如三轴压缩、单轴抗拉、声发射测试)和现场监测数据(如巷道围岩应力变化与岩爆等级记录)。

(2) 指标计算方法。σ_θ/σ_c依据现场测试或文献提供的围岩最大主应力与岩石单轴抗压强度计算得出;σ_c/σ_t来自岩石基本力学性质测试获得的单轴抗压强度与抗拉强度;W_{et}为基于应力-应变曲线计算的岩石单位体积弹性能量,采用 Hoek 定义的弹性能量表达式。

(3) 岩爆烈度等级划分。岩爆烈度等级划分为 4 级:无、轻微、中等、剧烈,分别对应模型输出的 1～4 级标签。

2.2 模型建立

NRBO-BPNN 模型的构建主要包括数据预处理、网络结构设计、NRBO 优化集成与模型训练 4 个环节。

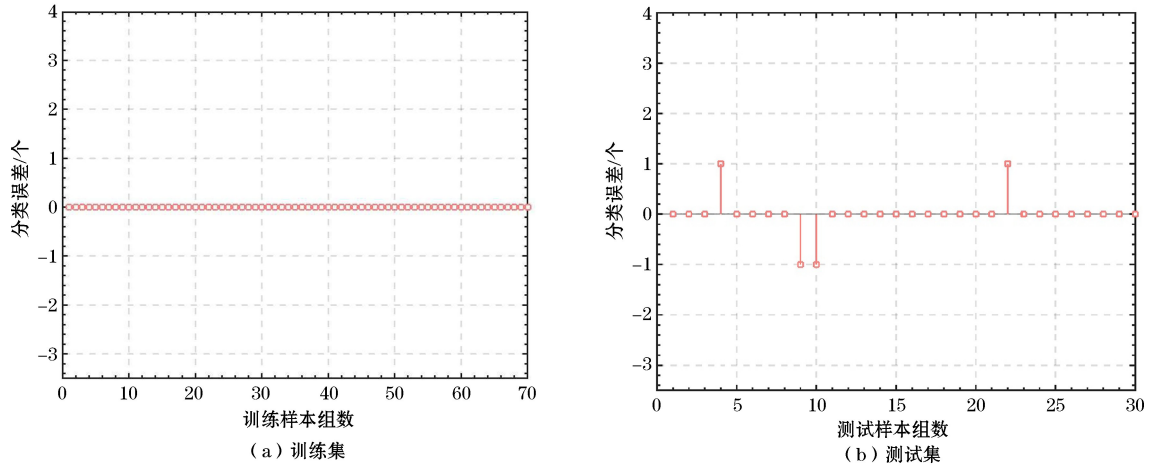
首先,将本文收集到的 100 组岩爆数据按 7∶3 比例划分为训练集与测试集,并采用 Min-Max 归一化方法对输入特征进行标准化处理,以确保特征量纲一致、提升训练稳定性。随后,设计 BPNN 结构,具体配置如下:输入层节点数为 3,隐含层设定为 10 个节点,输出层为 4 个节点。激活函数方面,隐含层采用 ReLU 函数以增强非线性表达能力,输出层则采用线性激活函数,适用于多分类任务中的概率输出转换。为进一步提升模型性能,引入 NRBO 优化算法对网络权重和偏置进行动态调节。在训练阶段,模型通过标准的正向传播与反向传播过程进行误差迭代更新,并同步执行 NRBO 优化策略,对网络参数持续优化,直至满足误差收敛条件或达到预设迭代次数。

2.3 结果

在完成 NRBO-BPNN 模型的训练与优化后,为评估其性能与泛化能力,本文对训练集与测试集的预测结果进行了系统分析。如图 2(a)所示,NRBO-BPNN 模型在训练集上的预测准确率达到了 100%,所有样本的分类误差为 0,说明模型已充分学习训练数据中的特征关系,拟合能力较强。

图 2(b)展示了模型在测试集上的预测结果,准确率为 86.67%,可以看出,大部分样本的分类误差依然为 0,仅有少数样本存在±1 个或±2 个的分类偏差。这表明模型在未见数据上的表现仍具备良好的泛化能力,预测稳定性较高。

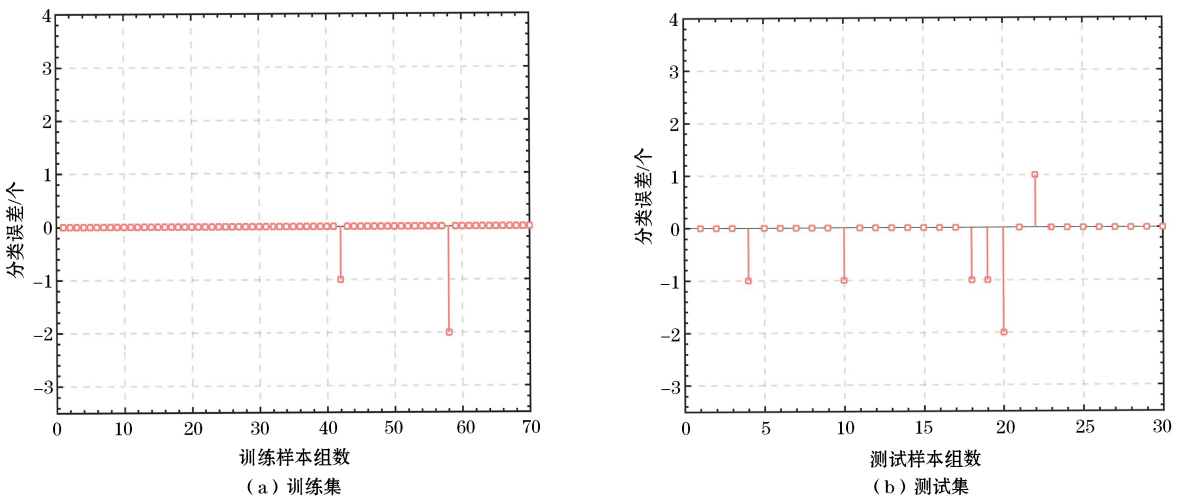
同时,为对比 NRBO-BPNN 与传统 BPNN 模型在岩爆烈度预测中的性能差异,本文进一步统计了传统 BPNN 在训练集与测试集上的准确率,结果见图 3。传统 BPNN 模型在训练集和测试集上的准确率分别为 97.14%和 80%,相比于 NRBO-BPNN 模型,降低了 2.86 和 6.67 个百分点。结果表明,NRBO 算法在避免局部最优、提升收敛速率和提高预测精度方面发挥了关键作用,显著增强了神经网络模型的整体性能。



(a) 训练集 (b) 测试集

图 2 NRBO-BPNN 模型岩爆烈度预测结果

Fig.2 Prediction results of rockburst intensity by NRBO-BPNN model



(a) 训练集 (b) 测试集

图 3 传统 BPNN 模型岩爆烈度预测结果

Fig.3 Prediction results of rockburst intensity by traditional BPNN model

2.4 分析与讨论

2.4.1 结果分析

对比图 2 与图 3 可知,NRBO-BPNN 模型的性能显著优于传统 BPNN 模型。这一提升的根本原因在于引入了 NRBO 算法,其在提升模型全局寻优能力、加速收敛速度以及增强泛化能力方面发挥了关键作用。

传统 BPNN 模型在处理岩爆烈度等复杂、高维、非线性工程问题时,常因初始权重敏感性强、易陷入局部最优等问题,预测精度和稳定性不足。而 NRBO 优化算法通过全局搜索策略和动态陷阱规避机制,有效克服了上述局限,其在参数空间中对网络权重与偏置进行全局更新,避免陷入局部极值区域,同时加快了优化过程的收敛速率。

在工程实际中,岩爆烈度预测涉及众多相互关联的地质与应力变量,数据特征呈现出高度非线性和复杂耦合关系,对预测模型的建模能力和鲁棒性提出了更高要求。NRBO-BPNN 通过提升模型对非线性特征的建模能力,提高了在多变量高维数据场景下的适应性。此外,其陷阱避免算子能够在模型训练过程中动态调整搜索路径,有效减少在不确定性和噪声较强的工程数据中的性能波动,从而增强了模型在实际岩土工程环境下的稳定性和实用性。

因此,NRBO-BPNN 模型在应对数据非线性、维度高、结构复杂等工程难点方面表现出显著优势,为实现更加智能化和精细化的地质灾害预测提供了有效的技术支撑。

2.4.2 与其他机器学习模型对比

为了进一步验证本文所提出的 NRBO-BPNN

模型的性能,本文还采用了支持向量机(SVM)、随机森林(RF)和极限学习机(ELM)模型,利用相同的数据集进行岩爆烈度预测。这些传统机器学习方法具有不同的优化机制和特点,能够为 NRBO-BPNN 提供有效的对比,从而全面评估其在岩爆烈度预测中的优势和实际应用效果。所有模型的运行结果见表 2。

表 2 不同机器学习模型的岩爆烈度预测

Table 2 Rockburst intensity prediction of different machine learning model

模型	训练集准确率/%	测试集准确率/%	总准确率/%	误判个数
NRBO-BPNN	100.00	86.67	96.00	4
BPNN	97.14	80.00	92.00	8
SVM	92.86	76.67	88.00	12
RF	95.71	80.00	91.00	9
ELM	88.57	63.33	81.00	19

从表 2 中可以看出,引入 NRBO 优化算法的 NRBO-BPNN 模型在训练集和测试集上均表现出色,尤其是在测试集上,NRBO-BPNN 展示了较高的准确率和较少的误判个数,表明其在岩爆烈度预测中具备强大的泛化能力和精确的预测性能。

BPNN 尽管在训练集上表现不错,但其测试集准确率仍然低于 NRBO-BPNN,且误判个数较多。SVM 和 RF 模型在准确率上与 NRBO-BPNN 模型略有差距,且误判个数较高,进一步表明其在岩爆烈度预测中的泛化能力不足。最为明显的是 ELM 模型,其在所有测试中表现最差,尤其在测试集上的低准确率和高误判个数,反映出其在处理复杂数据时的局限性。

3 工程应用

为验证最优模型的工程应用[12]效果,以马路坪矿和冬瓜山铜矿工程实例为背景,基于本文提出的 NRBO-BPNN 模型,开发了一套岩爆烈度预测综合系统,并与 BPNN 模型、SVM 模型、RF 模型和 ELM 模型预测结果进行对比。

马路坪矿位于阳水背斜东侧北段,地层倾角为 110°～165°,典型倾角为 20°～35°。该结构以断层为主,所有断层均为走向断层。现场记录显示,矿区中段 750 m、红色页岩岩性的矿区道路产生了侧壁和微弱的岩爆。冬瓜山铜矿矿体最大主应力为 30～38 MPa,属于高应力区,在开采过程中多次发生岩爆。该矿的矽卡岩在－790 m 处出现一次岩爆,锚网支撑后,锚杆被切断,在地层边界出现 1.8 m 长的地板隆起。应用 NRBO-BPNN 模型对马路坪矿和冬瓜山铜矿岩爆实例进行预测,预测结果见表 3。由表 3 可知,本文所建 NRBO-BPNN 模型的预测结果与现场情况一致,且优于 BPNN 模型、SVM 模型、RF 模型和 ELM 模型,是一种具有应用前景的模型。

表 3 工程实例预测结果

Table 3 Prediction results of project examples

工程名称	σ_θ/σ_c	σ_c/σ_t	W_{et}	实际岩爆烈度	预测岩爆烈度				
					NRBO-BPNN	BPNN	SVM	RF	ELM
马路坪矿	0.45	11.20	2.03	2	2	1	3	2	1
冬瓜山铜矿	0.46	11.10	3.97	3	3	2	4	2	4

4 结论

本文提出了一种基于 NRBO-BPNN 的岩爆烈度预测方法,通过结合 NRBO 算法和 BPNN 模型,有效提升了岩爆预测的准确性和工程应用性。与传统的复杂编程软件和单一模型相比,NRBO-BPNN 模型在岩爆烈度预测中表现出更高的精度和可靠性,具有广阔的应用前景。

(1) 通过引入 NRBO,解决了原始数据多维度相关性高的问题,提升了数据处理的效率和预测模型的稳定性。

(2) 与传统的 BPNN 模型、SVM 模型、RF 模型和 ELM 模型相比,NRBO-BPNN 模型具有更高的预测准确性,训练集准确率为 100%,测试集准确率为 86.67%。

(3) 开发了岩爆烈度预测综合系统,将该模型应用于马路坪矿和冬瓜山铜矿工程,成功实现了岩爆烈度的精准预测,验证了该模型在实际矿区中的有效性,为矿山安全设计提供了新的技术支持。

参考文献(References):

[1] 钱七虎.岩爆、冲击地压的定义、机制、分类及其定量预测模型[J].岩土力学,2014,35(1):1-6.
QIAN Qihu. Definition, mechanism, classification and quantitative forecast model for rockburst and pressure bump [J]. Rock and Soil Mechanics,2014,35(1):1-6.

[2] 曹树刚.现代采矿理论及技术研究进展[M].重庆:重庆大学出版社,2020.
CAO Shugang. Research progress of modern mining theory and technology [M]. Chongqing: Chongqing University Press,2020.

[3] 张春生,刘宁,褚卫江,等.锦屏二级深埋隧洞构造型岩爆诱发机制与案例解析[J].岩石力学与工程学报,2015,34(11):2242-2250.
ZHANG Chunsheng, LIU Ning, CHU Weijiang, et al. Inducement mechanism and case analysis of tectonic rockburst in Jinping Ⅱ deep buried tunnel [J]. Chinese Journal of Rock Mechanics and Engineering,2015,34(11):2242-2250.

[4] 魏秀琪,唐春安,张世超,等.秦岭隧洞 4# 支洞微震规律与岩爆预警研究[J].地下空间与工程学报,2020,16(6):1866-1874.
WEI Xiuqi, TANG Chun'an, ZHANG Shichao, et al. Research on rules of microseismicity and early warnings of rockburst in 4# branch tunnel of Qinling tunnel[J]. Chinese Journal of Underground Space and Engineering, 2020, 16(6):1866-1874.

[5] 王超,李岳峰,邵琳,等.基于 9 种无约束优化算法的岩爆预测 BP 模型优选[J].昆明理工大学学报(自然科学版),2021,46(5):32-37.
WANG Chao, LI Yuefeng, SHAO Lin, et al. BP neural network model optimization for rockburst prediction based on nine unconstrained optimization algorithms[J]. Journal of Kunming University of Science and Technology (Natural Science),2021,46(5):32-37.

[6] 张亭,赵晓凤,柴衡山.基于动量梯度下降神经网络的岩爆预测方法[J].江西冶金,2023,43(5):405-409.
ZHANG Ting, ZHAO Xiaofeng, CHAI Hengshan. Rockburst prediction method based on the back propagation momentum neural network[J]. Jiangxi Metallurgy,2023,43(5):405-409.

[7] 李军民,张亭,周义升,等.基于 APSO-SVM 模型的岩爆烈度预测方法[J].现代矿业,2023,39(6):167-170.
LI Junmin, ZHANG Ting, ZHOU Yisheng, et al. Rock burst intensity prediction method based on APSO-SVM model[J]. Modern Mining,2023,39(6):167-170.

[8] RAVICHANDRAN S, MANOHARAN P, PRADEEP J. Newton-Raphson-based optimizer: a new population-based metaheuristic algorithm for continuous optimization problems [J]. Engineering Applications of Artificial Intelligence,2024,128:107532.

[9] RUMELHART D, HINTON G, WILLIAMS R. Learning representations by back-propagating errors [J]. Nature, 1986,323(6088):533-536.

[10] LIPPMANN R P. An introduction to computing with neural nets[J]. IEEE ASSP Magazine,1987,5:12-35.

[11] CYBERKO G. Approximations by superpositions of a sigmoidal function[J]. Math Control Singnal System,1989, 2:303-314.

[12] WANG C, XU J H, LI Y F, et al. Optimization of BP neural network model for rockburst prediction under multiple influence factors [J]. Applied Sciences, 2023, 13(4):2741.

[13] 高梅,张成良,张华超,等.基于 SMOTEENN-CGAN-Stacking 的岩爆烈度等级预测研究[J].工程地质学报,2024,32(6):2264-2276.
GAO Mei, ZHANG Chengliang, ZHANG Huachao, et al. Rockburst intensity level prediction based on SMOTEENN-CGAN-STAKCING[J]. Journal of Engineering Geology, 2024,32(6):2264-2276.

[14] 范成强,夏元友,张宏伟,等.基于 LLE-DBSCAN-SMOTE 数据处理的隧洞岩爆预测[J].中国安全科学学报,2024,34(12):140-148.
FAN Chengqiang, XIA Yuanyou, ZHANG Hongwei, et al. Tunnel rockburst prediction based on LLE-DBSCAN-SMOTE data processing[J]. China Safety Science Journal, 2024,34(12):140-148.

[15] WANG J C, DONG L J. Risk assessment of rockburst using SMOTE oversampling and integration algorithms under GBDT framework[J].Journal of Central South University, 2024,31(8):2891-2915.

[16] 吴菡.基于支持向量机的岩爆预测研究与应用[J].粉煤灰综合利用,2024,38(4):92-96+133.
WU Han. Research on rock burst prediction based on a support vector machine [J]. Fly Ash Comprehensive Utilization,2024,38(4):92-96+133.