基于牛顿-拉夫逊法优化CNN-LSTM的岩石抗压强度预测模型研究*

夏永西[1],刘艳章[1,2],黄诗冰[1,2],曹文耀[1],张贺[1],苏旭[1]

(1.武汉科技大学 资源与环境工程学院, 湖北 武汉 430081;
2.冶金矿产资源高效利用与造块湖北省重点实验室, 湖北 武汉 430081)

摘要:为提升岩石单轴抗压强度的预测效率与精度,提出一种基于卷积神经网络(CNN)与长短期记忆网络(LSTM)相结合的预测模型,并采用牛顿-拉夫逊优化算法(NRBO)对模型关键参数进行优化。通过广泛收集包括点载荷强度、施密特锤回弹数、孔隙率及纵波波速的岩石物理参数试验数据,经预处理后保留381组有效样本,并进行可视化分析与异常值处理。采用CNN进行特征提取,LSTM捕捉时序依赖,NRBO优化学习率、正则化系数及隐藏层节点数等超参数。试验结果表明,NRBO-CNN-LSTM模型在测试集上表现最优,其决定系数达到0.98,均方根误差为6.27,平均绝对误差为4.82,显著优于其他对比模型,显示出更强的拟合能力与泛化性能。该优化模型能够有效融合岩石多源物理特征,实现高精度、高稳定性的单轴抗压强度预测,可为工程实际提供可靠的技术参考。

关键词:单轴抗压强度;牛顿-拉夫逊优化算法;卷积神经网络;长短期记忆网络;预测模型

中图分类号:TD313 **文献标识码**:A **文章编号**:1005-2763(2025)11-0151-07

Study on a CNN-LSTM Model Optimized with Newton-Raphson-Based Optimizer for Predicting Rock Compressive Strength

XIA Yongxi[1], *LIU Yanzhang*[1,2], *HUANG Shibing*[1,2], *CAO Wenyao*[1], *ZHANG He*[1], *SU Xu*[1]

(1.School of Resources and Environmental Engineering, Wuhan University of Science and Technology, Wuhan, Hubei 430081, China;
2.Hubei Provincial Key Laboratory of Efficient Utilization and Blocking of Metallurgical Mineral Resources, Wuhan, Hubei 430081, China)

Abstract: In order to improve the prediction efficiency and accuracy of uniaxial compressive strength of rocks, a combined model based on convolutional neural network (CNN) and long short-term memory (LSTM) network was proposed and optimized using Newton-Raphson-based optimizer (NRBO). Extensive collection of rock physical parameter experimental data, including point load strength, Schmidt hammer rebound number, porosity, and longitudinal wave velocity, was conducted. After preprocessing, 381 valid samples were retained and visualized for analysis and outlier handling. CNN was used for feature extraction, LSTM captured temporal dependencies, and NRBO optimized hyperparameters such as learning rate, regularization coefficient, and number of hidden layer nodes. The experimental results show that the NRBO-CNN-LSTM model performs the best on the test set, with a coefficient of determination of 0.98, a root mean square error of 6.27, and an average absolute error of 4.82, significantly better than other comparison models, demonstrating stronger fitting ability and generalization performance. This optimization model can effectively integrate multiple physical characteristics of rocks, achieve high-precision and high stability prediction of uniaxial compressive strength, and provide reliable technical reference for engineering practice.

Key words: Uniaxial compressive strength, Newton-Raphson-based optimizer, Convolutional neural network, Long short-term memory network, Prediction model

0 引言

岩石单轴抗压强度是评估岩石力学性质和稳定性的重要参数之一。根据国际岩石力学学会[1]和美国测试与材料学会[2]的标准化建议,在单轴抗压强度测试中通常需要一个相对高质量的岩芯。然而,

* **收稿日期**:2024-11-20
基金项目:国家自然科学基金面上项目(42377191)
作者简介:夏永西(1999—),男,安徽合肥人,硕士研究生,从事矿山岩石力学的研究。E-mail:cloverpg7@163.com

现场取样、标准样品制备和实验室测试周期长、成本高、破坏性大,难以满足岩土工程的实际需求。因此,采用一种准确、快速的方法来确定岩石的单轴抗压强度是至关重要的。

大量研究表明,岩石的单轴抗压强度与其物理力学参数密切相关,如点载荷强度($I_{s(50)}$)、施密特锤回弹数(SHN)、密度(ρ)、孔隙率(n)、纵波波速(V_p)等。陈建勋等[3]对砂质板岩进行了单轴抗压强度试验和点荷载试验,得出饱和砂质板岩点荷载强度与单轴抗压强度之间具有显著的线性正相关性;YILMAZ I 等[4]利用施密特锤进行测试,建立了施密特锤回弹硬度、正切杨氏模量和无侧限抗压强度之间的回归方程,然而这些经验关系式仅适用于石膏;MISHRA D 等[5]采用块冲试验和点载荷强度作为预测岩石抗压强度的经验方法,得出块冲压指数在巴西劈裂抗拉强度(BTS)预测中的表现优于 $I_{s(50)}$。除了传统的统计方法外,采用基于机器学习的方法对岩石的单轴抗压强度进行预测也得到了众多学者们的关注。KUMAR B R[6]将人工神经网络和模糊推理相互结合,利用含水率、密度和点荷载强度等岩石基本特性参数,建立了岩石的弹性模量预测模型;吴顺川等[7]提出基于 Stacking 集成学习算法构建了岩石的单轴抗压强度预测模型,并与其他学习模型进行比较,认为 Stacking 集成学习具有一定的可行性和可靠性;吴禄源等[8]收集了不同类型岩石的三轴试验数据,然后采用 3 种主流的集成学习算法建立了岩石抗压强度预测模型,并使用贝叶斯优化算法进行超参数优化,进行结果评估后得出 LightGBM 模型泛化性能优于另外两种模型,且运行耗时相对最少;李文等[9]采用径向基函数作为 LS-SVM 的核函数,以岩石密度、点荷载强度、纵波波速为输入特征,建立了页岩单轴抗压强度预测模型;SUN Huan 等[10]使用了 X 射线计算机断层扫描和卷积神经网络,这是一种估算岩石单轴抗压强度的创新方法。但上述预测方法在评价岩石强度方面仍存在局限性:运用数学手段开展预测所得的预测结果精度较差,可信度存疑;而采用较为简单的机器学习方法所得模型泛化性能和适用性能差,无法在复杂多变的外部环境条件下始终保持模型的预测结果真实可信,具有明显的局限性。

近年来,机器学习方法的提出和在各领域的迅速发展与应用,为解决岩石力学参数预测精度低、泛化能力差等一系列问题提供了技术支撑。李康楠等[11]提出一种基于链式方程多重插补法(Multivariate Imputation by Chained Equations, MICE)与卷积神经网络(Convolutional Neural Network, CNN)的岩爆烈度等级预测模型,与其他三个模型进行对比得出 MICE-CNN 岩爆等级预测模型准确率更高。熊峰等[12]基于卷积神经网络-深度迁移学习算法建立岩石图像智能识别模型,训练和测试后具有快速和准确识别岩石种类的能力。满轲等[13]提出 CNN-LSTM(Convolutional Neural Network Long Short-Term Memory)模型预测 TBM 隧道稳定段掘进参数和岩爆等级,得出该模型具有较高的鲁棒性和准确率。冯永存等[14]提出一种将遗传算法(Genetic Algorithm, GA)和长短期记忆神经网络(LSTM)网络相结合,利用实时钻井参数计算岩石力学参数的方法,使其更好地捕捉特征参数与岩石力学参数的非线性关系。以上研究均展现出机器学习构建岩石力学参数预测模型的优势,但模型构建相对简单,并主要为间接预测岩石单轴抗压强度,无法对非线性、非平稳时间序列进行准确预测。

通过对以往研究进行总结分析,未来岩石单轴抗压强度预测研究的重点将是大量传统岩石物理参数与能够进行非线性、非平稳、多因素的长时间序列预测的组合神经网络模型的有机融合。本文针对已有的岩石单轴抗压强度预测方法与模型存在的缺点和对前沿时序神经网络模型的研究,提出了将卷积神经网络(CNN)与长短期记忆网络(LSTM)组合的方法,并使用牛顿-拉夫逊算法(Newton-Raphson-Based Optimizer, NRBO)对 CNN-LSTM 神经网络模型的学习率、正则化系数和隐藏层节点数 3 个相关参数进行优化。通过该模型将岩石的点载荷强度、施密特锤回弹数、孔隙率、纵波波速作为特征预测岩石的单轴抗压强度,并对模型进行评估和结果分析,验证牛顿-拉夫逊法优化的 CNN-LSTM 模型的可行性和有效性,以期为实际工程应用提供参考。

1 算法介绍

1.1 牛顿-拉夫逊优化算法

NRBO 迭代速度快并能有效处理机器学习中的诸多挑战性问题。RAVICHANDRAN S 等[15]使用 64 个基准函数对牛顿-拉夫逊法的性能进行评

估，对 12 个现实约束工程问题进行优化，得出牛顿-拉夫逊法具有较高的勘探开发平衡性、较高的收敛速度和有效避免局部最优的能力。NRBO 利用目标函数的二阶导数信息来进行迭代，相比于只利用一阶导数的最速下降法，它具有更快的收敛速度，特别是在接近极值点时表现尤为明显。该算法通过二次曲线来逼近目标函数，并利用该曲线的极小值作为下一次迭代的点，这使得它能够在合适的条件下迅速接近目标函数的极小值。其核心公式如下：

$$x_{n+1}=x_n-\frac{f'(x_n)}{f''(x_n)},n=1,2,3,\cdots \tag{1}$$

式中：x_n 为当前迭代的近似解；$f'(x_n)$ 为目标函数在 x_n 处的一阶导数的有限差分近似，其定义为 $f'(x_n)=\dfrac{f(x_n+\Delta x)-f(x_n-\Delta x)}{2\Delta x}$；$f''(x_n)$ 为目标函数在 x_n 处的二阶导数的有限差分近似，其定义为：$f''(x_n)=\dfrac{f(x_n+\Delta x)+f(x_n-\Delta x)-2f(x_n)}{\Delta x^2}$；$\Delta x$ 为 x_n 和 x_{n+1} 的差值。

将 $f'(x_n)$ 和 $f''(x_n)$ 代入式(1)可得：

$$x_{n+1}=x_n-\frac{[f(x_n+\Delta x)-f(x_n-\Delta x)]\Delta x}{2f(x_n+\Delta x)+2f(x_n-\Delta x)-4f(x_n)} \tag{2}$$

1.2 卷积神经网络

卷积神经网络(CNN)是一类擅长处理具有网格结构数据的深度学习模型，广泛应用于图像处理、视频分析和自然语言处理等领域。CNN 通过层级结构对输入数据进行特征提取和转换，能够自动学习数据中的重要特征，减少人为干预。CNN 的基本单元包含：

(1) 卷积层，卷积层是 CNN 的核心组件，通过卷积操作提取输入数据的局部特征，每个卷积核在输入数据上滑动，计算卷积核与输入数据局部区域的点积，从而生成特征图；

(2) 激活函数，非线性激活函数(如 ReLU)在每个卷积层后面应用，以增加模型的非线性表达能力，提升模型对复杂特征的捕捉能力；

(3) 池化层，池化层通过降采样操作减少特征图的尺寸，保留重要特征，同时减少计算复杂度，防止过拟合；

(4) 全连接层，全连接层将提取到的高层次特征输入到一个或多个全连接神经元中，进行最终的分类或回归任务。

图 1 为 CNN 神经网络流程。CNN 相比其他神经网络算法的优势有两个方面，一是局部连接与参数共享，卷积操作只在局部区域进行，参数共享机制减少了模型参数的数量，提升了计算效率；二是平移不变性，通过池化操作和卷积核的滑动，CNN 对输入数据的平移具有鲁棒性，能够有效识别特征的位置变化。

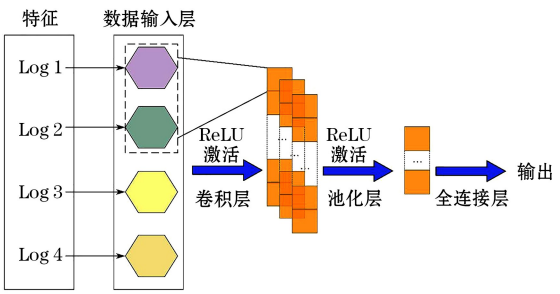


图 1 CNN 神经网络流程

Fig.1 CNN neural network flowchart

1.3 长短期记忆网络

长短期记忆网络(LSTM)是一种改进的循环神经网络(Recurrent Neural Network，RNN)，LSTM 通过引入记忆单元和门控机制，在处理时间序列数据时表现出色，解决了传统 RNN 容易出现的梯度爆炸和梯度消失的问题，使其能够在长时间序列数据中保持稳定的学习能力。LSTM 神经网络如图 2 所示。图中 C_{t-1} 和 C_t 分别是 $t-1$ 和 t 时刻的神经网络流状态。

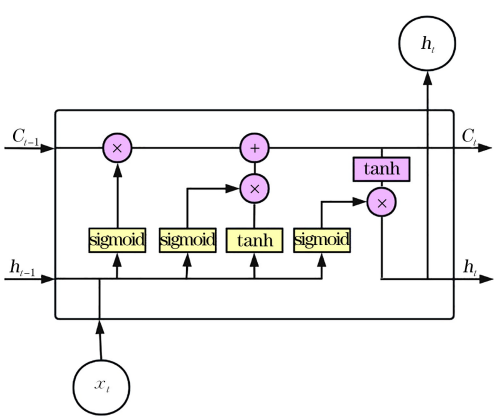


图 2 LSTM 神经网络

Fig.2 LSTM neural network

1.4 基于牛顿-拉夫逊法优化 CNN-LSTM 的预测模型

图 3 所示为经过牛顿-拉夫逊法优化改进的 CNN-LSTM 预测模型网络结构。CNN 特有的卷

积核能提取数据中的特征信息,LSTM 则具有记忆单元,将两种模型融合后,能更有效地获取数据中的特征信息。融合后的模型涉及到影响预测结果的参数主要是学习率、正则化系数和隐藏层节点数,引入牛顿-拉夫逊法对这 3 个参数进行不停的迭代优化,从而找出适合该模型预测的最佳参数。

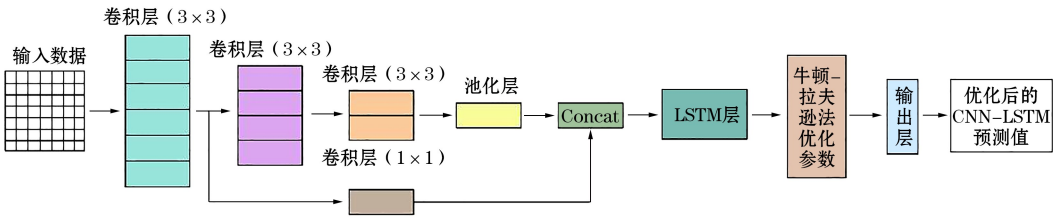


图 3 牛顿-拉夫逊法优化 CNN-LSTM 模型网络结构

Fig.3 Network structure of CNN-LSTM model optimized by Newton-Raphson method

2 试验数据及模型

2.1 数据来源与预处理

本文使用的数据集来源于已发表的各类学术论文,以核心论文与学位论文为主。为了有效验证和分析各变量对单轴抗压强度的影响,本文收集的数据主要包括完整的岩石特性,一共 498 组数据。选取单轴抗压强度为关键输出指标;4 个关键输入参数分别为岩石的点载荷强度、施密特锤回弹数、孔隙率、纵波波速,利用这些试验数据合成数据库。其中,19 组数据来源于文献[16],所用岩石为强度在 109.17～193.33 MPa 的花岗岩;2 组数据来源于文献[17],所用岩石为强度在 10.00～16.95 MPa 的凝灰岩;19 组数据来源于文献[18],所用岩石为强度在 2.03～10.41 MPa 的钙质岩; 30 组数据来源于文献[19],所用岩石为强度在 22.7～71.54 MPa 的石灰华;35 组数据来源于文献[20],所用岩石为强度在 65.21～241.56 MPa 的橄榄岩;7 组数据来源于文献[21],所用岩石为强度在 32～92 MPa 的石灰华和石灰岩;54 组数据来源于文献[22],所用岩石为强度在 17.55～198.15 MPa 的花岗岩、片岩和砂岩;145 组数据来源于文献[23],所用岩石为强度在 20.3～112.9 MPa 的花岗岩;15 组数据来源于文献[24],所用岩石为强度在 14.97～51.51 MPa 的砂岩、石灰岩和石灰华;2 组数据来源于文献[25],所用岩石为强度在 110.61～223.76 MPa 的大理岩;170 组数据来源于文献[26],所用岩石为强度在 12.01～215.21 MPa 的黏土岩、花岗岩、片岩、砂岩、石灰华、石灰岩、板岩、白云岩和泥灰岩。

为了提高模型的准确性和性能,需对收集的样本数据进行预处理,即对样本数据进行清洗和标准化处理,确保数据的一致性和可比性。初步分析发现所收集的样本数据存在一些缺失值和重复值,为了预测结果尽可能精确,将问题样本删除。最终保留 381 组数据,绘制每种特征的箱线图(如图 4 至图 7 所示)。通过箱线图可甄别出数据集中的异常值。然后,对每项参数中的异常值进行处理,用样本均值替代超出上限的异常值,用样本中位数替换低于下限的异常值。对处理后的数据进行分割,随机选取 70%的数据作为训练集,30%的数据作为测试集。每个特征变量的最小值、最大值和平均值见表 1。

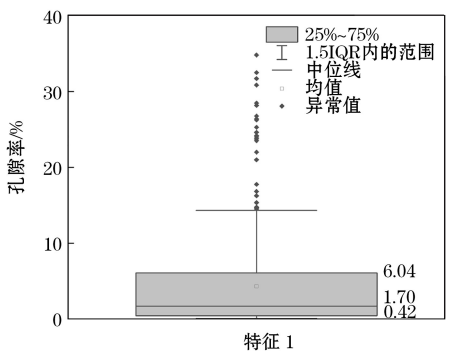


图 4 样本数据孔隙率箱线图

Fig.4 Sample data porosity boxplot

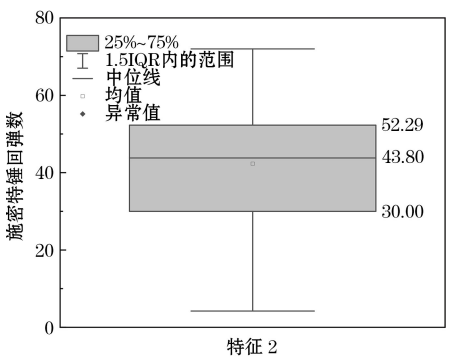


图 5 样本数据施密特锤回弹数箱线图

Fig.5 Sample data Schmidt hammer rebound number boxplot

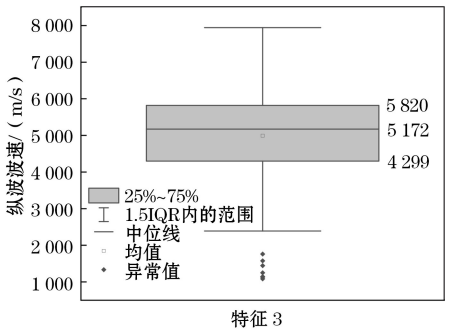


图 6　样本数据纵波波速箱线图

Fig.6　Sample data compressional wave velocity boxplot

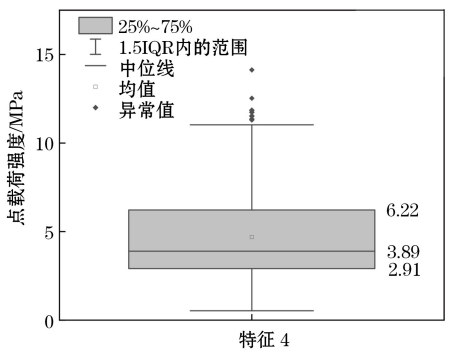


图 7　样本数据点荷载强度箱线图

Fig.7　Sample data point load strength boxplot

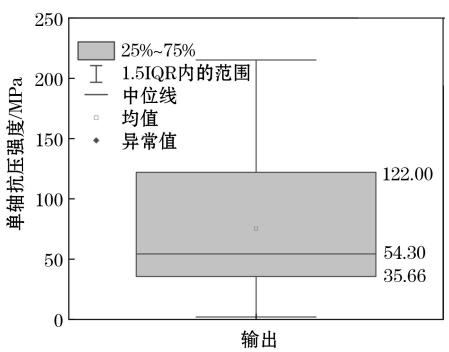


图 8　样本数据单轴抗压强度箱线图

Fig.8　Sample data uniaxial compressive strength boxplot

表 1　样本特征变量

Table 1　Sample characteristic variables

特征名称	孔隙率/%	施密特锤回弹数	纵波波速/(m/s)	点荷载强度/MPa	单轴抗压强度/MPa
最小值	0.06	4.20	1 085	0.53	2.03
最大值	34.79	72.00	7 943	14.13	215.21
平均值	4.30	42.78	5 019	4.50	77.21

2.2　试验模型

图 9 展示了岩石单轴抗压强度预测模型构建流程。试验过程主要分为 4 个阶段：数据预处理、模型建立、训练和测试以及结果分析评价过程。数据预处理工作包括收集因变量(单轴抗压强度)及主要影响因素的数据收集，并构建输入和输出参数数据库；分别建立随机森林、BP 神经网络、CNN-LSTM 神经网络和 NRBO-CNN-LSTM 神经网络预测模型；训练和测试阶段将上述划分后的训练集和测试集编号并作为输入，最后输出每个模型的结果进行比较，进一步评价各模型的适用范围。

其中，本文提出的 NRBO-CNN-LSTM 神经网络模型中，牛顿-拉夫逊法作为优化算法，对 CNN-LSTM 神经网络模型中的学习率、正则化系数和隐藏层节点数等关键参数进行自动寻优，有效提升了模型性能。而 CNN-LSTM 模型集成了 CNN 在空间特征提取和 LSTM 在时间序列建模的优势，尤其适用于视频分析、时空预测等兼具时空特征的数据处理。NRBO-CNN-LSTM 模型能够有效捕捉和处理复杂的岩石特性数据之间的联系，具有较高的预测精度和鲁棒性。

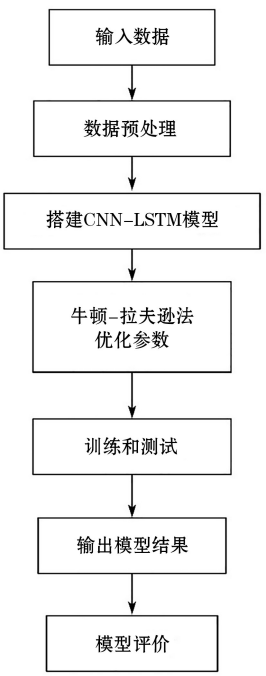


图 9　模型流程

Fig.9　Model flowchart

3　试验结果

3.1　评价指标

本文选用均方根误差(*RMSE*)、平均绝对误差(*MAE*)和决定系数(R^2)3 个常用指标来评估机器学习模型的性能 。

在工程测量中 $RMSE$ 被广泛用于衡量观测值和真实值之间的偏差,$RMSE$ 越小,说明模型的预测误差越小,性能越好,其计算公式如下:

$$RMSE=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2} \tag{3}$$

式中:n 为观测值的总数;y_i 为实际观测值;$\hat{y}_i$ 为预测值;$\bar{y}_i$ 为观测值的平均值。

MAE 是所有预测值与真实值偏差的绝对值的平均。MAE 可以避免误差相互抵消的问题,因而可以准确反映实际预测误差的大小。MAE 越小,说明模型的预测误差越小,性能越好,其计算公式如下:

$$MAE=\frac{1}{n}\sum_{i=1}^{n}|y_i-\hat{y}_i| \tag{4}$$

R^2 用于表征试验数据与拟合函数的契合程度。若 R^2 值越接近 1,则表示拟合程度越高;反之,R^2 值越接近 0,拟合程度越低,其计算公式如下:

$$R^2=1-\frac{\sum_{i=1}^{n}(y_i-\hat{y}_i)^2}{\sum_{i=1}^{n}(y_i-\bar{y}_i)^2} \tag{5}$$

3.2 结果分析

不同算法的预测结果见表 2。

表 2 四种机器学习模型的预测结果评价

Table 2 Evaluation of prediction results of four machine learning models

模型	*RMSE*	*MAE*	R^2
随机森林	19.83	14.61	0.85
BP 神经网络	17.49	11.22	0.89
CNN-LSTM 神经网络	8.32	6.08	0.96
NRBO-CNN-LSTM 神经网络	6.27	4.82	0.98

对比表 1 中四种模型的评价结果,CNN-LSTM 神经网络的预测结果远优于随机森林和 BP 神经网络。而经过 NRBO 优化的 CNN-LSTM 神经网络预测结果进一步提升,其相关系数从 0.96 提升到 0.98,均方根误差从 8.32 降至 6.27,平均相对误差从6.08 减少至 4.82。

4 结论

本文基于机器学习方法建立了 NRBO-CNN-LSTM 模型,用于预测岩石单轴抗压强度,并通过收集的试验数据进行了验证,得出以下结论。

(1) 利用文献调研,通过数据搜集和预处理得到 381 组有效数据,选择岩石的孔隙率、施密特锤回弹数、纵波波速和点荷载强度作为输入特征,验证了其与单轴抗压强度之间存在响应关系,可用于预测单轴抗压强度。

(2) 本文建立的 NRBO-CNN-LSTM 模型在预测岩石单轴抗压强度方面表现优异,其性能远优于随机森林、BP 神经网络模型和 CNN-LSTM 模型。模型决定系数 R^2 为 0.98,均方根误差 $RMSE$ 为 6.27,平均相对误差 MAE 为 4.82,展现了较高的预测精度与鲁棒性。

(3) 未来研究中,一方面可进一步补充岩石单轴抗压强度试验数据,丰富训练样本以弥补当前数据集的不足;另一方面,可探索更多改进的优化算法进行机器学习,进一步提升模型的预测性能和泛化能力。

参考文献(References):

[1] HAWKINS B A. ULUSAY R., HUDSON J A. The complete isrm suggested methods for rock characterisation, testing and monitoring[J]. Bulletin of Engineering Geology and the Environment,2009,68(2):287-288.

[2] American Society of Testing and Materials. Standard test method for unconfined compressive strength of intact rock core specimens: D2938-95[S].West Conshohocken: ASTM International, 2002.

[3] 陈建勋,陈丽俊,罗彦斌,等.砂质板岩单轴抗压强度与点荷载强度换算关系[J].交通运输工程学报,2022,22(4):148-158.
CHEN Jianxun, CHEN Lijun, LUO Yanbin, et al. Conversion relationship between uniaxial compressive strength and point load strength of sandy slate[J]. Journal of Traffic and Transportation Engineering, 2022, 22(4): 148-158.

[4] YILMAZ I, YUKSEK A G . Technical note an example of artificial neural network (ANN) application for indirect estimation of rock parameters[J]. Rock Mechanics and Rock Engineering,2008,41(5):781-795.

[5] MISHRA D, BASU A. Use of the block punch test to predict the compressive and tensile strengths of rocks[J]. International Journal of Rock Mechanics and Mining Sciences, 2012(51):119-127.

[6] KUMAR B R, VARDHAN H, GOVINDARAJ M, et al. Regression analysis and ANN models to predict rock properties from sound levels produced during drilling[J]. International Journal of Rock Mechanics and Mining Sciences,2013(58):61-72.

[7] 吴顺川,王艳超,张化进.基于 Stacking 集成算法的岩石单轴抗压强度预测方法研究[J].矿业研究与开发,2022,42(6):105-111.
WU Shunchuan, WANG Yanchao, ZHANG Huajin. Study on the prediction method of uniaxial compressive strength of rocks based on Stacking ensemble algorithm[J]. Mining Research and Development, 2022, 42(6): 105-111.

[8] 吴禄源,李建会,马丹,等.基于集成学习与贝叶斯优化的岩石抗压强度预测[J].地球科学,2023,48(5):1686-1695.
WU Luyuan, LI Jianhui, MA Dan, et al. Prediction of rock compressive strength based on ensemble learning and Bayesian optimization[J]. Earth Science, 2023, 48(5): 1686-1695.

[9] 李文,谭卓英.基于 MLR 与 LS-SVM 的岩石强度预测模型比较[J].矿业研究与开发,2016,36(11):37-40.
LI Wen, TAN Zhuoying. Comparison on rock strength prediction models based on MLR and LS-SVM[J]. Mining Research and Development, 2016, 36(11): 37-40.

[10] SUN Huan, DU Weisheng, LIU Chi. Uniaxial compressive strength determination of rocks using X-ray computed tomography and convolutional neural networks[J]. Rock Mechanics and Rock Engineering, 2021, 54(8): 1-13.

[11] 李康楠,吴雅琴,杜锋,等.基于卷积神经网络的岩爆烈度等级预测[J].煤田地质与勘探,2023,51(10):94-103.
LI Kangnan, WU Yaqin, DU Feng, et al. Prediction of rockburst intensity grade based on convolutional neural network[J]. Coalfield Geology & Exploration, 2023, 51(10): 94-103.

[12] 熊峰,廖一凡,曹伟腾,等.基于卷积神经网络-深度迁移学习的岩性自动识别研究[J].安全与环境工程,2023,30(4):26-34.
XIONG Feng, LIAO Yifan, CAO Weiteng, et al. Study on automatic recognition of rock lithology based on convolutional neural network and deep transfer learning[J]. Safety and Environmental Engineering, 2023, 30(4): 26-34.

[13] 满轲,武立文,刘晓丽,等.基于 CNN-LSTM 模型的 TBM 隧道掘进参数及岩爆等级预测[J].煤炭科学技术,2024,52(增刊 2):21-37.
MAN Ke, WU Liwen, LIU Xiaoli, et al. Prediction of TBM tunneling parameters and rockburst grade based on CNN-LSTM model[J]. Coal Science and Technology, 2024, 52(Suppl.2): 21-37.

[14] 冯永存,丁建琦,蔡文军,等.基于 GA 优化 LSTM 神经网络的岩石力学参数预测方法研究:2023 中国油气人工智能科技大会论文集[C]//北京:《中国学术期刊(光盘版)》电子杂志社有限公司,2023:23-35.
FENG Yongcun, DING Jianqi, CAI Wenjun, et al. Prediction method of rock mechanics parameters based on GA optimization LSTM neural network: Proceedings of the 2023 China Petroleum and Oil Artificial Intelligence Technology Conference[C]// Beijing: Chinese Academic Journals (CD Version) Electronic Journal Co., Ltd., 2023: 23-35.

[15] 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, 128107532.

[16] TUĞRUL A, ZARIF I. Correlation of mineralogical and textural characteristics with engineering properties of selected granitic rocks from Turkey[J]. Engineering Geology, 1999, 51(4): 303-317.

[17] TOPAL T, SÖZMEN B. Deterioration mechanisms of tuffs in Midas monument[J]. Engineering Geology, 2003, 68(3-4): 201-223.

[18] İSMAIL D, ALTAY A, SUPHI U. Estimation of strength and deformation properties of Quaternary caliche deposits[J]. Bulletin of Engineering Geology and the Environment, 2008, 67(3): 353-366.

[19] DEHGHAN S, SATTARI G, CHELGANI C S, et al. Prediction of uniaxial compressive strength and modulus of elasticity for Travertine samples using regression and artificial neural networks[J]. Mining Science and Technology (China), 2010, 20(1): 41-46.

[20] DIAMANTIS K, BELLAS S, MIGIROS G, et al. Correlating wave velocities with physical, mechanical properties and petrographic characteristics of peridotites from the Central Greece[J]. Geotechnical and Geological Engineering, 2011, 29(6): 1049-1062.

[21] YAGIZ S, SEZER A E, GOKCEOGLU C. Artificial neural networks and nonlinear regression techniques to assess the influence of slake durability cycles on the prediction of uniaxial compressive strength and modulus of elasticity for carbonate rocks[J]. International Journal for Numerical and Analytical Methods in Geomechanics, 2012, 36(14): 1636-1650.

[22] MISHRA D, BASU A. Estimation of uniaxial compressive strength of rock materials by index tests using regression analysis and fuzzy inference system[J]. Engineering Geology, 2013, 2013, 16054-16068.

[23] NG I T, YUEN K V, LAU C H. Predictive model for uniaxial compressive strength for Grade III granitic rocks from Macao[J]. Engineering Geology, 2015(199): 28-37.

[24] KHAJEVAND R, FEREIDOONI D. Utilization of the point load and block punch strengths to predict the mechanical properties of several rock samples using regression analysis methods[J]. Innovative Infrastructure Solutions, 2019, 4(1): 15.

[25] LIU Jianbin, ZHANG Zhongjian, LI Biao. Microscopic & macroscopic characterizations of Beijing marble as a building material for UNESCO heritage sites: New insights into physico-mechanical property estimation and weathering resistance[J]. Construction and Building Materials, 2019(225): 510-525.

[26] MAHMOODZADEH A, MOHAMMADI M, IBRAHIM H H, et al. Artificial intelligence forecasting models of uniaxial compressive strength[J]. Transportation Geotechnics, 2021, 27: 100499.