基于多算法对比的岩石单轴抗压强度预测*

吴亚娟[1,2]，黄德昕[1,2]，温韬[1,2,3]，贾文君[1,2]

（1.长江大学 地球科学学院， 湖北 武汉 430100；
2.多灾害防控与工程安全国际科技合作基地， 湖北 武汉 430100；
3.湖北长大科技开发有限公司加查县分公司， 西藏 山南市 856499）

摘要：合理有效地确定岩石单轴抗压强度对保障矿山岩体工程安全意义重大。基于两组包括纵波波速、施密特锤回弹值、点荷载强度、施密特硬度等间接指标的岩石单轴抗压强度数据集，选取PSO-BP、PSO-LSTM、CNN-LSTM、PSO-BILSTM四种组合算法，通过7种评价指标综合评价最优的岩石单轴抗压强度预测算法。结果表明：PSO-LSTM算法在两组数据集上的预测值与实际值拟合较好，各评价指标均较高；基于指标评分法量化分析各算法的预测性能，PSO-LSTM在数据集一和数据集二上分别获得27分和21分的总高分，具有最高的预测精度。输入参数关联度分析显示，数据集一中点载荷强度对单轴抗压强度预测结果影响最大，关联度为0.735 5；数据集二中抗拉强度对单轴抗压强度预测结果影响最大，关联度为0.829 2。同时，各算法在数据集二上的预测效果更好，表明采用与单轴抗压强度关联度高的输入参数能够有效提高预测效果。研究成果可为岩石单轴抗压强度的确定提供参考。

关键词：单轴抗压强度；算法预测；PSO-LSTM；关联度；间接指标

中图分类号：TD313 **文献标识码**：A **文章编号**：1005-2763(2025)11-0141-10

Prediction of Uniaxial Compressive Strength of Rocks Based on Multi Algorithm Comparison

WU Yajuan[1,2], *HUANG Dexin*[1,2], *WEN Tao*[1,2,3], *JIA Wenjun*[1,2]

(1.School of Geosciences, Yangtze University, Wuhan, Hubei 430100, China;
2.International Cooperation Center for Mountain Multi-Disasters Prevention and Engineering Safety, Wuhan, Hubei 430100, China;
3.Jiacha County Branch of Hubei Yangtze University Technology Development Co., Ltd., Shannan, Xizang 856499, China)

Abstract: Reasonably and effectively determining the uniaxial compressive strength of rocks is of great significance for ensuring the safety of mining rock engineering. Based on two groups of rock uniaxial compressive strength datasets including longitudinal wave velocity, Schmidt hammer rebound value, point load strength, Schmidt hardness, and other indirect indicators, four combination algorithms including PSO-BP, PSO-LSTM, CNN-LSTM, and PSO-BILSTM, were selected. And the optimal rock uniaxial compressive strength prediction algorithm was comprehensively evaluated through 7 evaluation indicators. The results show that the PSO-LSTM algorithm fits well with the predicted values and actual values on two datasets, and all evaluation indicators are high. Based on the metric scoring method to quantitatively analyze the predictive performance of various algorithms, PSO-LSTM can achieve a total high score of 27 and 21 on Dataset 1 and Dataset 2, respectively, demonstrating the highest prediction accuracy. The analysis of input parameter correlation shows that the point load strength has the greatest impact on the prediction of uniaxial compressive strength in Dataset 1, with a correlation degree of 0.735 5. The tensile strength has the greatest impact on the prediction of uniaxial compressive strength in Dataset 2, with a correlation coefficient of 0.829 2.Meanwhile, the predictive performance of each algorithm in Dataset 2 is better, indicating that using input parameters with high correlation with uniaxial compressive strength can effectively improve the predictive performance. The research results can provide a reference for determining the uniaxial compressive strength of rocks.

Key words: Uniaxial compressive strength, Algorithm prediction, PSO-LETM, Correlation, Indirect indicator

---

* **收稿日期**：2024-12-19

基金项目：国家自然科学基金项目(42477174)；西藏自治区科技计划项目(XZ202402ZD0001，XZ202301YD0034C，XZ202502YD0003)；青海省基础研究计划项目(2024-ZJ-904)

作者简介：吴亚娟(1979—)，女，安徽亳州人，博士研究生，主要研究方向为工程地质力学。E-mail：29249701@qq.com

通信作者：温韬(1990—)，男，江西宜春人，博士，教授，主要从事工程地质力学方面的研究工作。E-mail：wentao200840@sina.com

0 引言

岩石强度是工程岩体分类、岩体质量分级及开挖稳定性评估的重要参数[1-2]。然而,在实验室确定岩石单轴抗压强度(UCS)存在诸多限制,例如需要特定几何形状的高质量岩芯,试样制备困难,试验成本高昂且非常耗时,这使得一些低成本项目无法开展相应试验[3-4]。因此,诸多学者提出了通过采用易获取的参数间接预测岩石强度,如纵波波速(V_p)、施密特锤回弹值(R_n)、杨氏模量、点荷载强度($I_{s(50)}$)、密度等[5-7]。

已有研究表明,岩石强度的预测方法主要有回归分析法和人工智能法两大类。回归分析法采用数理统计确定数学公式,描述单轴抗压强度与间接指标之间的关系,包括简单回归和多元回归。通过对数据进行回归分析,目前已有基于 $I_{s(50)}$、V_p、R_n、超声脉冲速度、抗拉强度(BTS)等参数建立的单一变量或多变量与 UCS 的回归公式[8-12]。然而回归分析法的局限性较明显,该方法获得的经验公式模型结构较为简单,不能准确地表现出岩石关系的复杂性。人工智能技术为 UCS 预测提供了一种更加高效的方法,近年来取得了较好的效果。在单一算法预测 UCS 方面,目前已采用随机森林、极限梯度提升树和轻量梯度提升机等集成算法进行 UCS 预测,并与经验模型进行对比分析,结果表明,集成算法具有更好的预测效果[13-14]。在多算法组合预测 UCS 方面,目前已有基于海洋捕食者算法与人工神经网络(ANN)算法相结合、粒子群优化算法(PSO)和 ANN 算法相结合、选择性集成学习算法和遗传算法相结合的方法对 UCS 进行预测,并获得了很好的预测效果[15-19]。与回归分析法相比,单一算法与多算法组合预测方法因不限制输入参数,能够快速处理庞大数据,使其在 UCS 预测中具有更好的应用,且多算法组合预测 UCS 具有更明显的优势。

本文基于 V_p、R_n、$I_{s(50)}$ 等现场易获取的岩石参数,利用两组不同间接参数组成的岩石数据集进行 UCS 预测。通过 4 种多算法组合进行 UCS 预测,并采用 7 种评价指标对算法预测结果进行分析,确定 UCS 预测效果最好的算法,以及与预测结果关联程度最大的输入参数。

1 预测算法基本原理

1.1 粒子群优化神经网络算法(PSO-BP)

PSO-BP 是一种融合了粒子群优化(PSO)算法和反向神经网络(BP)的训练算法。在 PSO-BP 算法中,PSO 算法用于探索神经网络权重的搜索空间,通过模拟粒子在解空间中的搜索和迭代更新来寻找最优解。而 BP 算法则用于在每次迭代过程中对神经网络进行权重的局部调整,以逐步优化网络性能。PSO-BP 算法通过综合全局搜索和局部优化两种方法,可以更好地找到神经网络的最优权重配置,从而提高网络的性能和泛化能力[20]。

1.2 粒子群优化长短期记忆网络算法(PSO-LSTM)

PSO-LSTM 将 PSO 算法和长短期记忆网络(LSTM)算法结合起来,采用 PSO 优化 LSTM 算法的参数,从而提高其预测性能[21]。PSO 算法用于搜索 LSTM 算法中的权重和偏置参数的最优组合,通过不断调整参数,使得 LSTM 算法能够更好地拟合训练数据,并具备较好的泛化能力。

1.3 粒子群优化双向长短期记忆网络算法(PSO-BILSTM)

PSO-BILSTM 的基本思想是通过 PSO 算法来搜索双向长短期记忆网络(BILSTM)算法的参数空间,以找到最佳的参数组合,从而提高预测性能。PSO 算法通过不断更新粒子的位置和速度,以寻找最佳解,而在 PSO-BILSTM 中,每个粒子代表一个 BILSTM 算法,并根据其在参数空间中的位置和速度来调整算法的参数[22]。

1.4 卷积神经网络优化长短期记忆网络算法(CNN-LSTM)

CNN-LSTM 算法结合了卷积神经网络(CNN)与 LSTM,CNN 能够有效地提取数据的特征值,通过 LSTM 中的门控机制对 CNN 提取到的特征值进行长短期记忆以达到特征融合的目的。同时,该算法能够通过对数据特征的“选择性记忆”过程降低特征之间冗余带来的影响,最终将融合后的特征融入分类器进行分类。数据经过 CNN 多次重复卷积和池化后可以有效提取强化后的特征信息,将提取的特征展平并提供给 LSTM 算法输入层进行读取,然后经过多个隐藏层处理,将信息传入全连接层后得到预测输出[23]。上述 4 种多算法组合预测算法流程如图 1 所示。

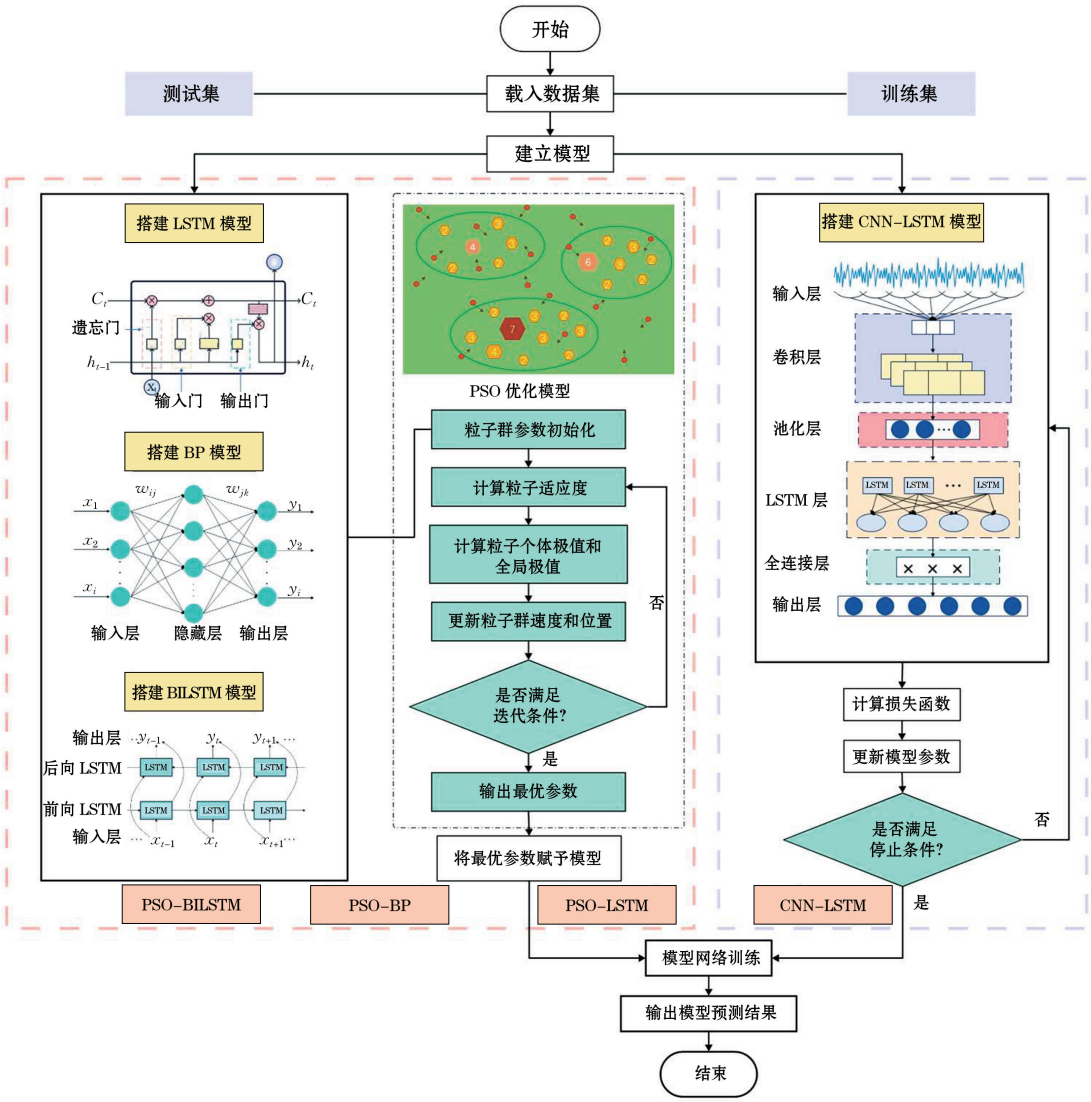


图 1　算法流程

Fig.1　The algorithm flowchart

本文采用两种方式对比验证多算法组合预测岩石单轴抗压强度模型的性能,其一为采用同种优化算法对不同预测算法进行优化;其二为采用不同优化算法对同种预测算法进行优化。因此,本文先进行 PSO-BP、PSO-LSTM 与 PSO-BILSTM 的对比验证,再进行 PSO-LSTM 和 CNN-LSTM 的对比验证,最后综合评价组合算法的优劣性。

2　岩石数据库

2.1　数据库

本文选取两组数据进行多算法组合预测 UCS 验证。数据集一包括 124 组岩石数据,包括 V_p、R_n、$I_{s(50)}$ 和 UCS 四种参数[24];数据集二包括 87 组岩石类型数据,包括 $I_{s(50)}$、V_p、BTS、施密特硬度(SHH)、邵氏硬度(SSH)和 UCS 六种参数[25]。这些参数可以通过无损检测的方法快速获取,在许多文献中已被证实其可用来预测 UCS 的可靠性[5-7],并在许多预测算法中被频繁使用[8-12]。

2.2　参数选择

为了分析各参数与 UCS 之间的相关性程度,绘制数据集参数的矩阵散点图,如图 2 所示。图 2 中显示了所有参数及其与 UCS 之间的统计特征和相关矩阵,并提供了每个变量的相应分布。根据矩阵散点图可以看出,UCS 与各参数之间均呈线性正相关关系,相关系数 $r \geqslant 0.60$,即可说明参数与 UCS 具有很强的相关性[26]。数据集一中,R_n 与 UCS 的相

关性最高,相关系数达 0.75;V_p 与 UCS 的相关性最低,相关系数为 0.68。数据集二中,BTS 与 UCS 的相关性最高,相关系数达 0.93;V_p 与 UCS 的相关性最低,相关系数为 0.74。通过参数的矩阵散点图可知,V_p 与 UCS 的关联程度最低,BTS、$I_{s(50)}$、SHH、SSH、R_n 等与 UCS 的关联程度较高。

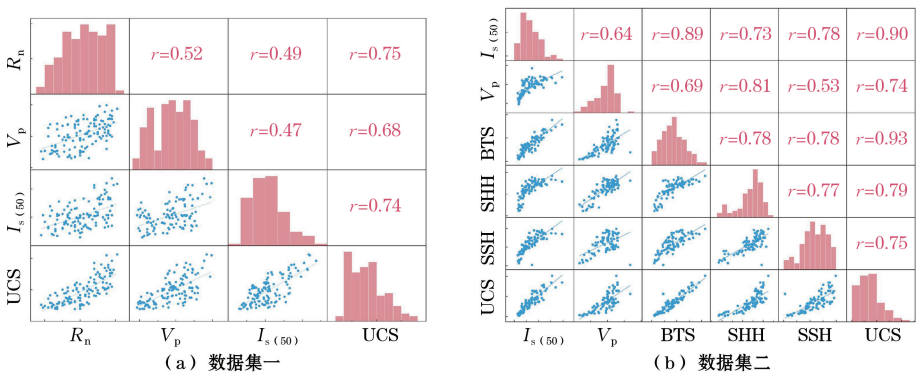


图 2　参数的矩阵散点图

Fig.2　Matrix scatter plots of parameters

为了检测数据集中是否有异常值,对两组数据集的参数分别绘制小提琴图,如图 3 和图 4 所示。小提琴图中的方形盒上下边界表示上四分位点和下四分位点,方形盒中心白点表示数据中位数,黑点数量表示数据在相应位置的密度。数据集一中,R_n 数据分布较为均匀,小提琴图两头窄中间宽,中位数在图形中段;V_p 小提琴图存在两个波峰,数据在中部和下部存在集中区域;$I_{s(50)}$ 和 UCS 小提琴图为上窄下宽型分布,说明数据主要集中在下部,上部数据较为分散。数据集二中,$I_{s(50)}$、BTS 和 UCS 小提琴图呈上窄下宽型分布,数据集中在下部,上部数据分布较为分散;V_p 和 SHH 小提琴图呈上宽下窄型分布,数据集中在上部波峰位置,V_p 小提琴图上端细长,说明存在分布较为离散的数据;SSH 小提琴图不存在明显的波峰,数据分布较为均匀,中位数在中部位置。综合来看,两个数据集中参数对应的小提琴图整体呈两头窄中间宽,数据分布均匀且不存在异常值。

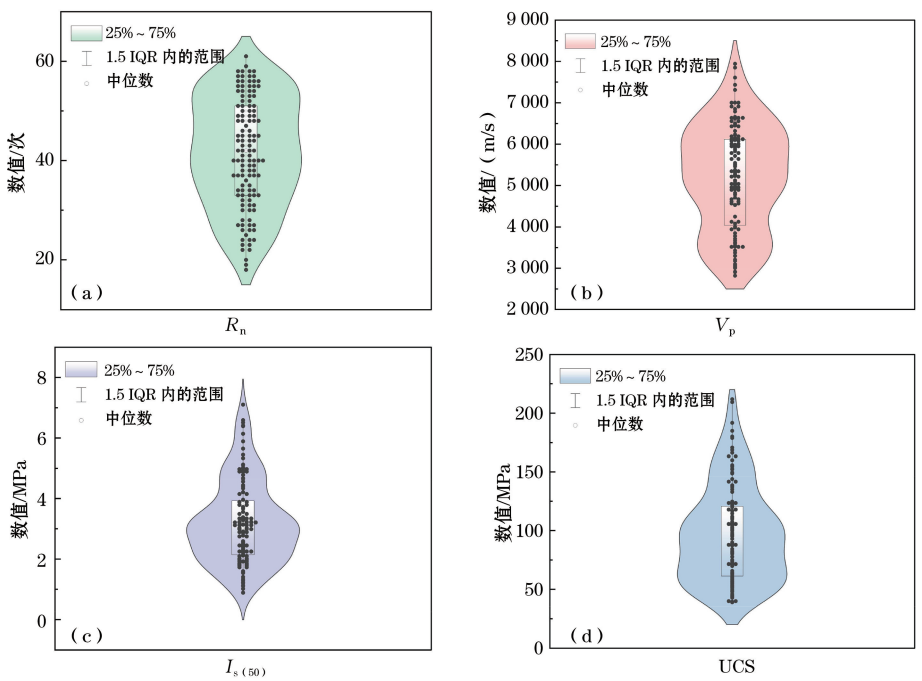


图 3　数据集一的参数小提琴图

Fig.3　Violin diagrams of parameters in dataset 1

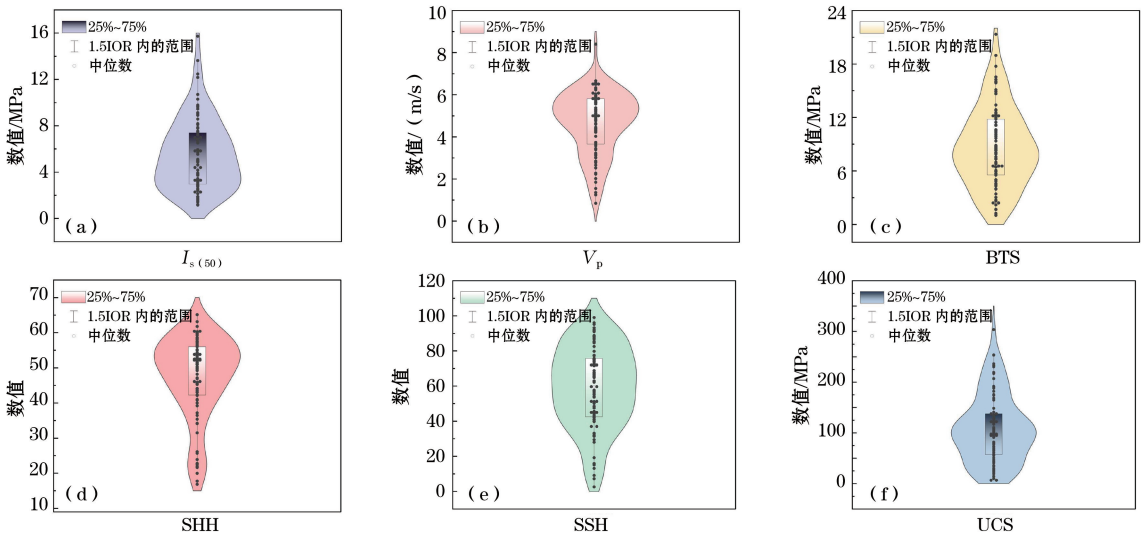


图 4 数据集二的参数小提琴图

Fig.4 Violin diagrams of parameters in dataset 2

3 评价指标

本文采用决定系数(R^2)、均方根误差(E_{RMS})、平均绝对误差(E_{MA})、Willmott 指数(W)、平均绝对百分比误差(E_{MAP})、无差贡献率(V_{AF})、对称平均绝对百分比误差(E_{SMAP}) 7 个评价指标作为检验算法预测性能的评价指标。

R^2 是平方和与偏差平方和的比值,其取值范围为[0,1]。R^2 越接近 1,说明算法拟合越好,R^2 越接近 0,说明算法拟合越差[27]。

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

E_{RMS} 是衡量数据集准确性的指标,用于比较不同算法预测值与实际值之间的预测误差。E_{RMS} 为非负数,值接近 0 表示算法结果与实际值的拟合较好[28]。

$$E_{RMS}=\sqrt{\frac{1}{m}\sum_{i=1}^{m}(y_i-\hat{y}_i)^2} \tag{2}$$

E_{MA} 用于评估预测算法的准确性。E_{MA} 为非负数,值越低表示预测准确性越高[29]。

$$E_{MA}=\frac{1}{m}\sum_{i=1}^{m}|(y_i-\hat{y}_i)| \tag{3}$$

V_{AF} 通过将实际值与算法的预测值进行比较来验证算法的准确性。实际值和预测值之间的差异越大,V_{AF} 越低。

$$V_{AF}=\left|1-\frac{S_r}{S_t}\right|\times 100\% \tag{4}$$

W 为用来预测算法误差程度的标准化度量标准。W 取值范围为[0,1],W 为 1 时表示预测值和实际值之间完全一致,拟合效果很好。

$$W=1-\frac{\sum_{i=1}^{m}(y_i-\hat{y}_i)^2}{\sum_{i=1}^{m}(|\hat{y}_i-\bar{Y}|+|y_i-\bar{Y}|)^2} \tag{5}$$

E_{SMAP} 为实际值和预测值之间的绝对百分比误差的平均值,其中每个误差由实际值和预测值的绝对值之和加权得到,其取值范围为[0,1]。E_{SMAP} 为 0 表示实际值与预测值完全匹配,为 1 表示完全没有匹配,其值越小算法预测效果越好。

$$E_{SMAP}=\frac{1}{m}\sum_{i=1}^{m}\frac{|y_i-\hat{y}_i|}{(|\hat{y}_i|+|y_i|)/2}\times 100\% \tag{6}$$

E_{MAP} 是统计学中评估算法预测准确性的衡量标准。E_{MAP} 值越小,算法预测值越可靠。

$$E_{MAP}=\frac{1}{m}\sum_{i=1}^{m}\left|\frac{y_i-\hat{y}_i}{y_i}\right|\times 100\% \tag{7}$$

式中:y_i 为实际值;$\bar{y}$ 为实际值的平均值;$\hat{y}_i$ 为预测值;$\bar{Y}$ 为预测值的平均值;m 为样本数;S_r 为残差平方和;S_t 为总平方和。

4 结果分析

在数据集中选择合适的训练集和测试集比例对

预测结果非常重要,本文对两个数据集采用不同的数据集比例。根据多次测试,将数据集一中70%的数据(87组)作为训练集,30%的数据(37组)作为测试集;将数据集二中80%的数据(70组)作为训练集,20%的数据(17组)作为测试集。

4.1 评价指标分析

基于7种评价指标对各算法预测结果进行评估。表1为各算法在数据集一上的预测结果评价指标,由表1可知,PSO-LSTM算法表现最好,6项评价指标取得最优值,仅E_{MAP}指标较差;而PSO-BILSTM算法表现最差,6项评价指标中取得最差值,仅E_{MAP}指标较好。该结果表明,各算法在数据集一上的预测效果评价中,E_{MAP}的代表性相对弱于其他评价指标。

对比同种优化算法对不同预测算法的优化效果,结果表明,PSO-LSTM算法表现最好,PSO-BP算法在所有评价指标上均优于PSO-BILSTM,PSO-BILSTM表现最差。对比不同优化算法对同种预测算法的优化效果,结果表明,PSO-LSTM算法在所有评价指标上均优于CNN-LSTM算法,能够取得更好的预测性能。

综上所述,基于数据集一对4种组合算法预测UCS的效果评估中,PSO-LSTM算法的预测效果最佳,PSO-BILSTM算法的预测效果最差。

表1 各算法在数据集一上的预测结果评价指标

Table 1 Evaluation indicators for the predicted results of each algorithm on dataset 1

算法	R^2	E_{RMS}	E_{MA}	V_{AF}/%	W	E_{SMAP}	E_{MAP}/%
CNN-LSTM	0.783	21.853	17.801	63.94	0.928 6	0.168	17.79
PSO-LSTM	0.828	19.453	15.512	75.29	0.947 1	0.144	15.14
PSO-BP	0.809	20.557	16.106	71.66	0.939 0	0.146	14.80
PSO-BILSTM	0.775	22.297	18.298	54.83	0.919 3	0.169	17.77

表2为各算法在数据集二上的预测结果评价指标,由表2可知,PSO-LSTM算法在R^2、E_{RMS}、V_{AF}、W等指标上取得最优值,CNN-LSTM算法在E_{MA}、E_{SMAP}、E_{MAP}等指标上取得最优值。对比同种优化算法对不同预测算法的优化效果,结果表明,PSO-LSTM算法表现最好,PSO-BP算法在6种评价指标上的表现优于PSO-BILSTM算法,仅E_{MA}值较高,即PSO-BP算法的预测效果优于PSO-BILSTM。综上所述,基于数据集二对4种组合算法预测UCS的效果评估中,PSO-LSTM算法的预测效果最佳,PSO-BILSTM算法的预测效果最差。

表2 各算法在数据集二上的预测结果评价指标

Table 2 Evaluation indicators for the predicted results of each algorithm on dataset 2

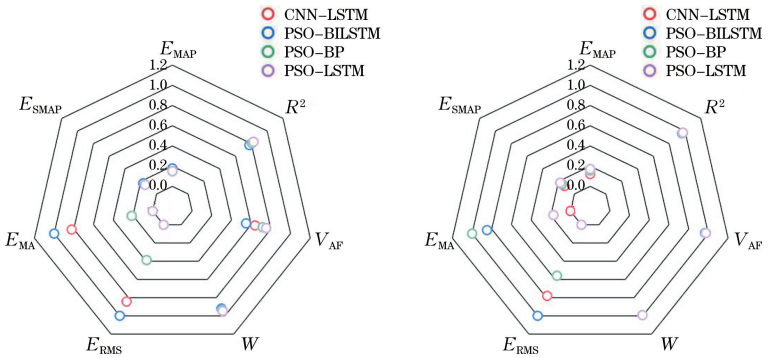
算法	R^2	E_{RMS}	E_{MA}	V_{AF}/%	W	E_{SMAP}	E_{MAP}/%
CNN-LSTM	0.966	8.595	5.806	96.87	0.991 6	0.125	12.18
PSO-LSTM	0.974	7.452	6.038	97.46	0.993 5	0.179	17.21
PSO-BP	0.968	8.269	7.143	97.19	0.992 4	0.157	15.68
PSO-BILSTM	0.963	8.914	6.940	96.60	0.990 9	0.159	16.11

为了更直观地比较各算法预测性能在不同评价指标上的表现,将7种评价指标映射在雷达图中,如图5所示。图中位于右侧的R^2、V_{AF}和W指标数值越大代表预测效果越好,位于左侧的E_{RMS}、E_{MA}、E_{SMAP}和E_{MAP}指标数值越小代表预测越准确,其中由于E_{RMS}和E_{MA}的原始数据量级较大,已对其进行了归一化处理。基于各指标在雷达图中的分布位置,采用指标评分法对算法预测性能进行量化评估,对每一项评价指标,排名第一的算法记4分,第二记3分,第三记2分,第四记1分,最终根据各算法在所有评价指标上的总分进行综合评价。

各算法在数据集一上的预测结果评价得分:PSO-LSTM为27分,PSO-BP为22分,CNN-LSTM为13分,PSO-BILSTM为8分。结果表明,PSO-LSTM在UCS预测方面具有明显优势,4种算法的预测性能从优至差依次为:PSO-LSTM、PSO-BP、CNN-LSTM、PSO-BILSTM。

各算法在数据集二上的预测结果评价得分:PSO-LSTM为21分,CNN-LSTM为20分,PSO-BP为19分,PSO-BILSTM为10分。结果表明,PSO-LSTM在UCS预测中表现最佳,4种算法的预测性能从优至差依次为:PSO-LSTM、CNN-

LSTM、PSO-BP、PSO-BILSTM,但前 3 种算法的预测性能差异不大。



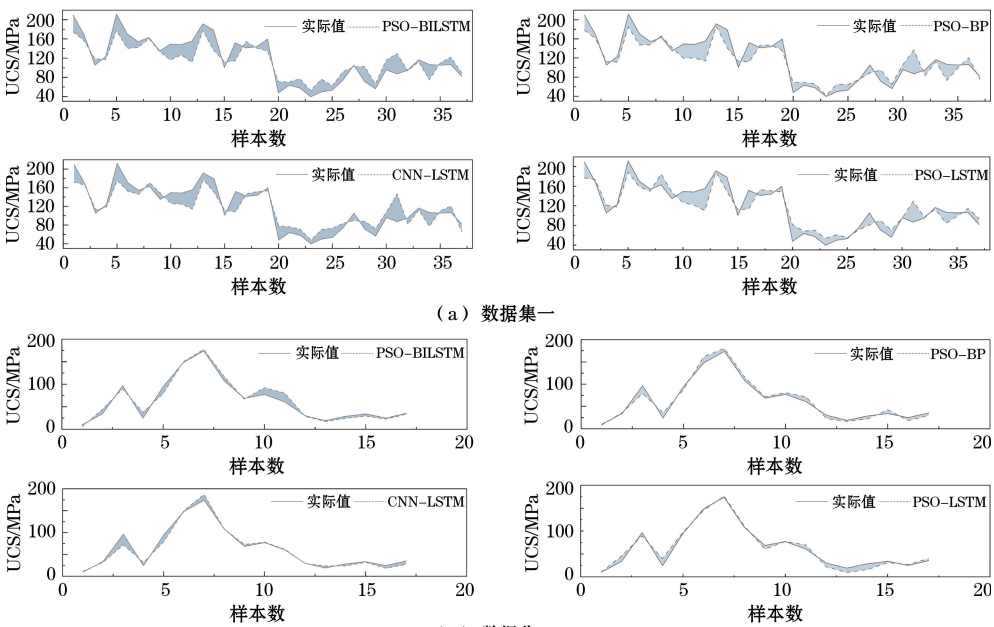
(a) 数据集一　　(b) 数据集二

图 5　评价指标雷达图

Fig.5　Radar charts of evaluation indicators

4.2　预测结果分析

基于 PSO-BP、PSO-LSTM、PSO-BILSTM、CNN-LSTM 4 种算法在两组数据集上得到的 UCS 预测值,绘制实际值和预测值的对比,如图 6 所示。图中显示,PSO-LSTM 算法在两组数据集上的预测曲线与实际值曲线最接近,表明该算法在两组数据集上的预测效果均优于其他模型。此外,数据集二的算法预测曲线与实际值曲线几乎重合,而数据集一的拟合效果相对较差,这表明模型的输入因子对 UCS 预测结果具有较大影响。



(a) 数据集一

(b) 数据集二

图 6　预测值与实际值对比

Fig.6　Comparison of the predicted values and the actual values

为了量化 PSO-BP、PSO-LSTM、PSO-BILSTM、CNN-LSTM 4 种算法的预测效果,分析各算法在数据集上的预测值和实际值之间的拟合关系,如图 7 和图 8 所示。图中所有预测值点均分布在拟合曲线的两侧,斜率越接近 1,表明预测结果越接近实测值。

数据集一中(见图 7),各算法 90% 预测带和 90% 置信带范围较大,说明数据分布较为离散,拟合曲线与 $y=x$ 最接近的为 PSO-LSTM 算法,拟合系数为 0.91。数据集二中(见图 8),4 种算法的拟合曲线与 $y=x$ 均比较接近,拟合系数不小于 0.98,说明各算法的预测值与实际值的拟合效果较好。PSO-LSTM 算法对应的拟合曲线最接近对角线函数,斜率为 0.99,拟合系数为 0.99。

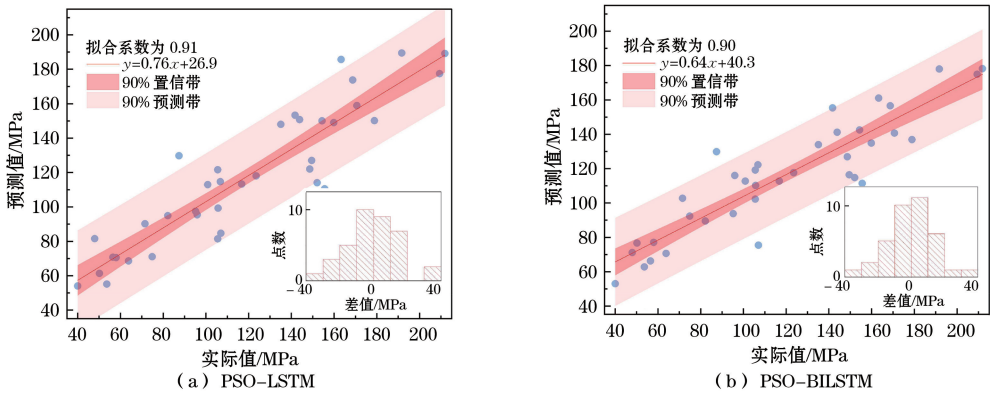


图 7 数据集一的预测值与实际值拟合结果

Fig.7 Fitting results between predicted values and actual values of dataset 1

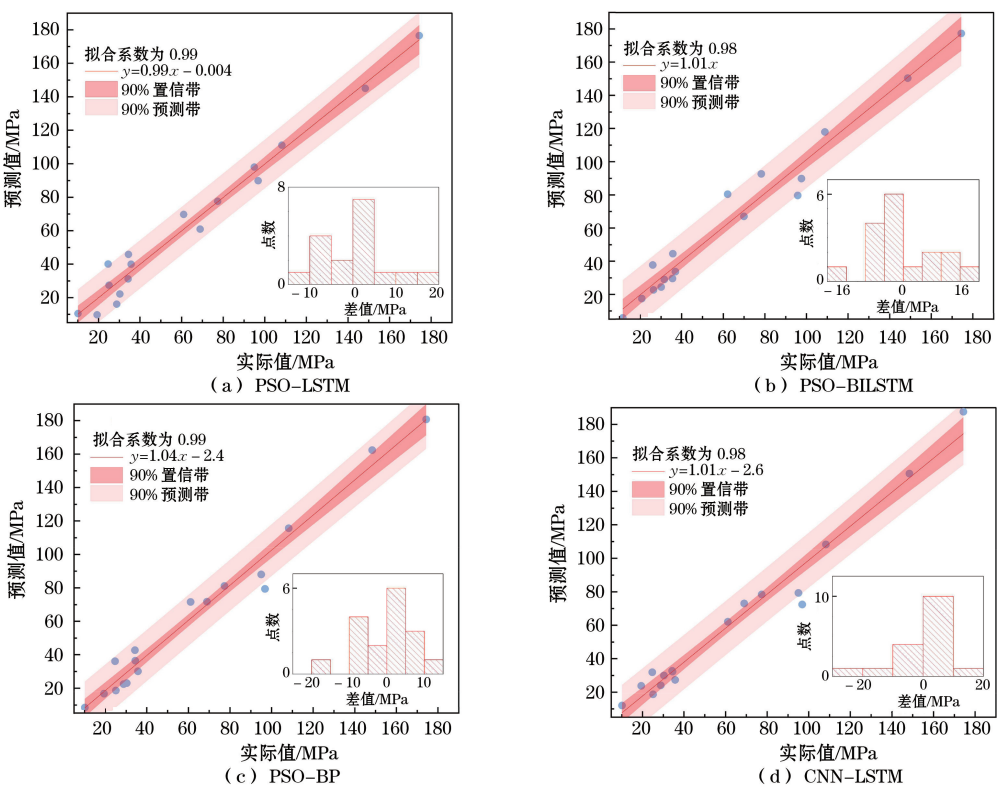


图 8 数据集二的预测值与实际值拟合结果

Fig.8 Fitting results between predicted values and actual values of dataset 2

4.3 敏感性分析

关联度是衡量不同因素关联性大小的指标。灰色关联度方法通过分析输入参数与 UCS 之间发展趋势的相似程度,衡量参数对 UCS 预测结果的影响程度[30],关联度越大,表明该输入参数对 UCS 预测的影响越大。

图 9 为输入参数与 UCS 之间的关联度。由图 9 可知,数据集一中 3 个参数与 UCS 的关联度介于 0.60～0.75 之间,其中 R_n 关联度为 0.624 8,V_p 关联度为 0.691 7,$I_{s(50)}$ 关联度为 0.735 5。$I_{s(50)}$ 与 UCS 关联度最高,但 3 种参数的关联度差距不大。数据集二中 $I_{s(50)}$ 和 BTS 与 UCS 的关联度均大于 0.8,SHH 和 SSH 与 UCS 的关联度较低,约为 0.5。综上所述,数据集一中,$I_{s(50)}$ 为影响 UCS 预测的主要因素;数据集二中,$I_{s(50)}$ 与 BTS 为影响 UCS 预测的主要因素。

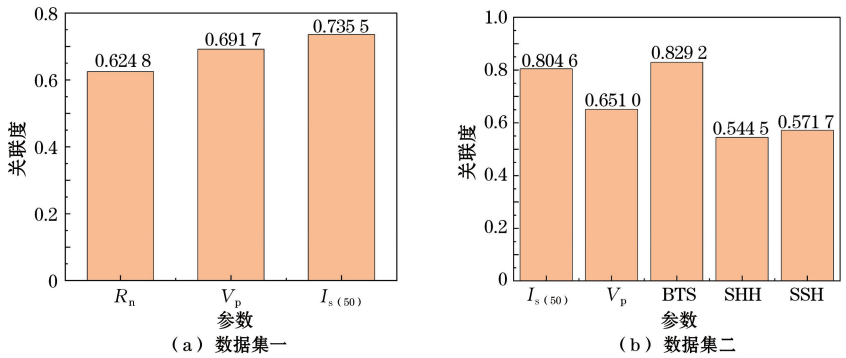


图 9 输入参数与 UCS 预测结果之间的关联度

Fig.9 The correlation between input parameters and UCS prediction results

5 结论

(1) 通过 PSO-BP、PSO-LSTM、PSO-BILSTM、CNN-LSTM 4 种组合算法对两组岩石单轴抗压强度数据集进行预测,并采用 7 种评价指标对算法预测结果进行综合分析。结果表明,PSO-LSTM 算法在两组数据集上均具有最高的预测精度,各评价指标均较高,且预测值与实际值拟合较好。

(2) 通过指标评分法确定了 4 种算法的预测性能优劣顺序,各算法在数据集一上的预测性能从优至差依次为:PSO-LSTM、PSO-BP、CNN-LSTM、PSO-BILSTM;各算法在数据集二上的预测性能从优至差依次为:PSO-LSTM、CNN-LSTM、PSO-BP、PSO-BILSTM,但前 3 种算法的预测性能差异不大。

(3) 针对多种输入参数进行关联度分析,结果表明,数据集一中 $I_{s(50)}$ 对 UCS 预测结果影响最大,关联度为 0.735 5;数据集二中 BTS 对 UCS 预测结果影响最大,关联度为 0.829 2。此外,数据集二中的输入参数与 UCS 的关联度整体高于数据集一的输入参数,考虑到各算法在数据集二上的预测效果更好,因此,在 UCS 预测过程中,选择与 UCS 关联度高的输入参数可以获得更准确的预测结果。

参考文献(References):

[1] LIU Zida, LI Diyuan, LIU Yongping, et al. Prediction of uniaxial compressive strength of rock based on lithology using stacking models[J]. Rock Mechanics Bulletin,2023,2(4):100081.

[2] SONG Chao, ZHAO Tengyuan, XU Ling, et al. Probabilistic prediction of uniaxial compressive strength for rocks from sparse data using Bayesian Gaussian process regression with Synthetic Minority Oversampling Technique (SMOTE)[J]. Computers and Geotechnics,2024,165:105850.

[3] SALDAÑA M, GONZÁLEZ J, PÉREZ-REY I, et al. Applying statistical analysis and machine learning for modeling the UCS from P-wave velocity, density and porosity on dry travertine[J]. Applied Sciences, 2020, 10(13):4565.

[4] ABBASZADEH SHAHRI A, MAGHSOUDI MOUD F, MIRFALLAH LIALESTANI S P. A hybrid computing model to predict rock strength index properties using support vector regression[J]. Engineering with Computers, 2022,38(1):579-594.

[5] ARMAGHANI D J, TONNIZAM MOHAMAD E, MOMENI E, et al. Prediction of the strength and elasticity modulus of granite through an expert artificial neural network[J]. Arabian Journal of Geosciences,2016,9:48.

[6] KAHRAMAN S. The determination of uniaxial compressive strength from point load strength for pyroclastic rocks[J]. Engineering Geology,2014,170:33-42.

[7] JAMSHIDI A, ZAMANIAN H, ZAREI SAHAMIEH R. The effect of density and porosity on the correlation between uniaxial compressive strength and P-wave velocity[J]. Rock Mechanics and Rock Engineering,2018,51(4):1279-1286.

[8] ALADEJARE A E. Evaluation of empirical estimation of uniaxial compressive strength of rock using measurements from index and physical tests[J]. Journal of Rock Mechanics and Geotechnical Engineering,2020,12(2):256-268.

[9] VASCONCELOS G, LOURENCO P B, ALVES C A S, et al. Ultrasonic evaluation of the physical and mechanical properties of granites[J]. Ultrasonics,2008,48(5):453-466.

[10] RAMLI Nazir, EHSAN Momenl, DANIAL Jajed Armaghani, et al. Correlation between unconfined compressive strength and indirect tensile strength of limestone rock samples [J]. Electronic Journal of Geotechnical Engineering,2013(18):1737-1746.

[11] TANDON R S, GUPTA V. Estimation of strength characteristics of different Himalayan rocks from Schmidt hammer rebound, point load index, and compressional wave velocity[J]. Bulletin of Engineering Geology and the Environment,2015,74(2):521-533.

[12] SHARMA P K, SINGH T N. A correlation between P-wave velocity, impact strength index, slake durability index and uniaxial compressive strength[J]. Bulletin of Engineering Geology and the Environment,2008,67(1):17-22.

[13] 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, et al. Study on prediction method of uniaxial compressive strength of rocks based on stacking ensemble algorithm[J]. Mining Research and Development,2022,42(6):105-111.

[14] 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 for rock compressive strength based on ensemble learning and Bayesian optimization[J]. Earth Science, 2023, 48(5):1686-1695.

[15] YU Zhi, ZHOU Jian, HU Liuqing. Prediction of compressive strength of granite: use of machine learning techniques and intelligent system [J]. Earth Science Informatics,2023,16(4):4113-4129.

[16] LEI Yu, ZHOU Shengtao, LUO Xuedong, et al. A comparative study of six hybrid prediction models for uniaxial compressive strength of rock based on swarm intelligence optimization algorithms[J]. Frontiers in Earth Science,2022,10:930130.

[17] ZHANG Huajin, WU Shunchuan, ZHANG Zhongxin. Prediction of uniaxial compressive strength of rock via genetic algorithm: selective ensemble learning[J]. Natural Resources Research,2022,31(3):1721-1737.

[18] HASSAN M Y, ARMAN H. Several machine learning techniques comparison for the prediction of the uniaxial compressive strength of carbonate rocks[J]. Scientific Reports,2022,12:20969.

[19] PAN Xupeng, NIU Yanwei, ZHAO Yu, et al. Parameter calibration method of clustered-particle logic concrete DEM model using BP neural network-particle swarm optimisation algorithm (BP-PSO) inversion method[J]. Engineering Fracture Mechanics,2023,292:109659.

[20] 毛建锋,李铮,伍军,等.基于 PSO-LSTM 的重载铁路车轨桥系统随机振动响应预测方法[J].铁道科学与工程学报,2024,21(9):3661-3671.
MAO Jianfeng, LI Zheng, WU Jun, et al. Redicting random vibration response of heavy-haul train-track-bridge system based on PSO-LSTM[J]. Journal of Railway Science and Engineering,2024,21(9):3661-3671.

[21] 杨超,张开富.基于 PSO-BiLSTM 神经网络的机身筒段应力预测[J].航空学报,2023,44(7):266-275.
YANG Chao, ZHANG Kaifu. Stress prediction of fuselage tube section based on PSO-BiLSTM neural network[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(7):266-275.

[22] ZHANG Pinzhi, SWAMINATHAN Alagappan, UDDIN Ahmed Abrar. Pulmonary disease detection and classification in patient respiratory audio files using long short-term memory neural networks [J]. Frontiers in Medicine,2023, 10:1269784.

[23] ARMAGHANI D J, MOHAMAD E T, HAJIHASSANI M, et al. Application of several non-linear prediction tools for estimating uniaxial compressive strength of granitic rocks and comparison of their performances[J]. Engineering with Computers,2016,32(2):189-206.

[24] TEYMEN A, MENGÜÇ E C. Comparative evaluation of different statistical tools for the prediction of uniaxial compressive strength of rocks[J]. International Journal of Mining Science and Technology,2020,30(6):785-797.

[25] 董立朋,聂清浩,孙晓坤,等.基于皮尔逊相关系数法的盾构掘进参数对地表沉降影响分析[J].施工技术(中英文),2024,53(1):116-123.
DONG Lipeng, NIE Qinghao, SUN Xiaokun, et al. Analysis of impact of shield tunneling parameters on ground settlement based on Pearson correlation coefficient method [J]. Construction Technology,2024,53(1):116-123.

[26] KHAJEVAND R. Prediction of the uniaxial compressive strength of rocks by soft computing approaches [J]. Geotechnical and Geological Engineering, 2023, 41(6):3549-3574.

[27] ZHAO Tengyuan, SONG Chao, LU Shifeng, et al. Prediction of uniaxial compressive strength using fully Bayesian Gaussian process regression (fB-GPR) with model class selection[J]. Rock Mechanics and Rock Engineering, 2022,55(10):6301-6319.

[28] DADHICH S, SHARMA J K, Madhira M. Prediction of uniaxial compressive strength of rock using machine learning [J]. Journal of The Institution of Engineers (India): Series A,2022,103(4):1209-1224.

[29] 刘思峰,蔡华,杨英杰,等.灰色关联分析模型研究进展[J].系统工程理论与实践,2013,33(8):2041-2046.
LIU Sifeng, CAI Hua, YANG Yingjie, et al. Advance in grey incidence analysis modelling[J]. Systems Engineering-Theory & Practice,2013,33(8):2041-2046.