基于 WOA-CNN-LSTM 模型的露天矿边坡稳定性预测*

郑发萍[1],周宗红[2],慕慧文[2],刘剑[2]

(1.昆明理工大学 公共安全与应急管理学院, 云南 昆明 654093;
2.昆明理工大学 国土资源工程学院, 云南 昆明 654093)

摘要:随着露天矿开采规模扩张,边坡稳定性问题日益突出。精准预测边坡稳定性并提前防范,对实现露天矿安全高效开采具有重大意义。基于因子分析构建了鲸鱼优化算法-卷积神经网络-长短期记忆网络(WOA-CNN-LSTM)边坡稳定性预测模型。选取黏聚力、内摩擦角、边坡角、边坡高度、孔隙压力比和容重6个因素作为模型的判别指标,利用因子分析法消除6个指标间的相关性,降低数据维数,提取公因子。将提取的公因子作为WOA-CNN-LSTM模型的输入,并将该模型应用于边坡工程实例中,验证模型的可靠性。结果表明,利用WOA算法迭代更新寻找最优网络参数原理,对CNN-LSTM网络进行优化,可有效克服CNN-LSTM模型易陷入局部最优解、梯度下降影响边坡稳定性预测精度的问题,提高了模型的预测精度和泛化能力,同时为边坡稳定性预测提供了一种新思路。

关键词:露天矿边坡稳定性;因子分析;WOA-CNN-LSTM模型;预测精度;矿山安全

中图分类号:TD804 **文献标识码**:A **文章编号**:1005-2763(2026)07-0108-08

Prediction of Open-Pit Slope Stability Based on the WOA-CNN-LSTM Model

Zheng Faping[1], *Zhou Zonghong*[2], *Mu Huiwen*[2], *Liu Jian*[2]

(1.Faculty of Public Safety and Emergency Management, Kunming University of Science and Technology, Kunming, Yunnan 654093, China;
2.Faculty of Land Resource Engineering, Kunming University of Science and Technology, Kunming, Yunnan 654093, China)

Abstract: With the expansion of open-pit mining scale, slope stability problems have become increasingly prominent. Great significance is attached to realizing safe and efficient open-pit mining by accurately predicting slope stability and taking preventive measures in advance. A whale optimization algorithm-convolutional neural network-long short-term memory (WOA-CNN-LSTM) prediction model for slope stability was constructed based on factor analysis. Six factors, including cohesion, internal friction angle, slope angle, slope height, pore pressure ratio and unit weight, were selected as the discrimination indicators of the model. Factor analysis was adopted to eliminate the correlation among the six indicators, reduce data dimensions and extract common factors. The extracted common factors were taken as the inputs of the WOA-CNN-LSTM model, and the model was applied to slope engineering cases to verify its reliability. The research results show that the CNN-LSTM network can be optimized by iteratively updating and searching for optimal network parameters using the WOA algorithm. The problems of the CNN-LSTM model, including falling into local optimal solutions and thegradient descent affectingthe prediction accuracy of slope stability, can be effectively overcome. The prediction accuracy and generalization ability of the model are thus improved, and a new idea for slope stability prediction is provided.

Key words: Open-pit slope stability, Factor analysis, WOA-CNN-LSTM model, Prediction accuracy, Mine safety

0 引言

随着露天矿山开采深度的增加,边坡高度和面积不断增大,坡体通常具有形态高陡、风化裂隙密集发育、坡面岩体软弱破碎的特点,在自然环境与开采扰动等影响下易发生失稳、滑坡等灾害,严重影响矿山安全和经济效益。高效的智能预测算法对于减少边坡灾害的发生具有重要的工程应用价值。目前,学者们通过大量确定性方法和不确定性方法对边坡稳定性进行预测。确定性方法主要包括极限平衡

* **收稿日期**:2025-07-10
基金项目:国家自然科学基金项目(52264019)
作者简介:郑发萍(2000—),女,四川会理人,硕士研究生,研究方向为矿山安全。E-mail:zfp121800@163.com
通信作者:周宗红(1967—),男,安徽宿州人,教授,博士生导师,主要从事采矿与岩石力学教学与研究。E-mail:zhou20051001@163.com

法[1]、强度折减法[2]和数值模拟[3]等方法,这些方法在评估边坡稳定性状态方面具有较好的表现,但这类方法前期需做大量的地质勘查,工作量大且成本高,处理边坡非线性关系存在限制性。近年来许多学者尝试将不确定性方法用于边坡稳定性分析,并取得了较好的效果,如模糊综合评价法[4]、云模型[5]、粗糙集[6]等方法,然而不确定模型需要根据以往经验预先对边坡稳定性影响因素指标进行人为量化,具有较强的人为主观性,导致边坡稳定性预测精度低。

人工智能等学科的快速发展,推动了边坡稳定性预测的研究,机器学习以高效率、快速自主学习和准确的预测能力,为边坡稳定性评价提供了可靠的预测方法。傅杨攀等[7]选取 CSMR 岩体质量分级指标作为边坡稳定性预测的影响因子,引入卷积神经网络原理(Convolutional Neural Networks,CNN),建立了边坡稳定性评价模型,同时与有限元分析法计算结果进行对比,结果表明,卷积神经网络模型具有较强的泛化能力。He 等[8]提出了一种基于多尺度、多通道、一维卷积神经网络的边坡稳定性预测模型,在一维卷积神经网络(1DCNN)的基础上,引入多尺度机制(MSM)和多通道机制(MCM)对 1DCNN 结构进行优化,提高了模型的性能,进而提高了边坡稳定性的预测准确性[8]。

Sun 等[9]开发了一种 BOP-Stacking 集成学习模型,该模型采用了贝叶斯优化算法来优化决策树(Decision Tree,DT)、支持向量机(Support Vector Machines,SVM)和最近邻算法等回归算法的超参数,集成模型有效提高了边坡稳定性的预测精度,从而为边坡稳定性的智能决策提供了强有力的支持。荣光旭等[10]融合卷积神经网络(CNN)与长短记忆网络(long short-term memory,LSTM)建立边坡稳定性预测模型 CNN-LSTM,并证明了该模型的可行性及预测性能优势,超参数的调优过程则是为了提高模型预测准确性而反复调整的过程,但在模型应用中超参数的选择都是依据经验而定,容易对预测精度产生不利影响。

为了克服传统依据经验选取参数而导致的预测精度低的问题,本文引入鲸鱼优化算法(Whale Optimization Algorithm,WOA)用于优化 CNN-LSTM 模型的超参数[11],建立一种基于 WOA 优化 CNN-LSTM 的边坡稳定性预测模型(WOA-CNN-LSTM),利用鲸鱼优化算法(WOA)对 CNN-LSTM 模型中"学习率""隐藏节点""正则化系数"3 个超参数进行智能寻优,有效解决了传统 CNN-LSTM 模型因参数繁多、超参数难以确定而导致的预测精度不足的问题。为进一步提升模型输入效率,借助因子分析简化变量维数的优势,将其提取的公共因子作为 WOA-CNN-LSTM 模型的输入变量。通过与其他模型的对比试验,验证了该模型的稳定性与优越性。将模型应用于露天矿边坡工程实例中,预测结果与实际情况高度吻合,进一步证明了经 WOA 优化后的 CNN-LSTM 模型用于边坡稳定性预测的可行性。

1 算法原理

1.1 因子分析法

因子分析是一种基于降维思想的方法,在尽可能保留原始数据信息的前提下,将复杂的多变量系统整合为几个独立的少数公共因子,通过较少的因子揭示原始数据的大部分信息。该方法通过公共因子线性组合来表达变量,实现对变量相关性的合理解释和降低数据维度,从而减少冗余信息,其具体步骤如下。

(1) 对数据进行标准化处理。将影响边坡稳定性的因素指标 X 转化为均值为 0,方差为 1 的形式:

$$X_{\text{norm}}=\frac{(X-\mu)}{\sigma} \tag{1}$$

式中:X_{norm} 是标准化处理后的结果;μ 是数据的均值;σ 是数据的标准差。

(2) 建立相关系数矩阵及因子相关性检验。在因子分析之前需对标准化处理后的数据开展适用性检验,判断其是否适合采用因子分析方法。观测变量之间的相关性,采用检验统计量(Kaiser-Meyer-Olkin,KMO)和 Bartlett 球形检验,若 $KMO>0.6$,且 $Bartlett<0.1$,则表明适合因子分析,否则将认为变量可能提供独立信息,不适合进行因子分析[12]。

(3) 求解相关系数矩阵 $\boldsymbol{R}$ 的特征值 $\lambda_i(i=1,2,\cdots,m)$ 及与其相对应的标准正交化特征向量 $\boldsymbol{U}_i(i=1,2,\cdots,m)$,根据特征值 λ_i 和特征向量 $\boldsymbol{U}_i$ 计算因子载荷矩阵 $\boldsymbol{A}$ 及累计贡献率。本文依据特征值大于 1(Kaiser 准则)或累积方差贡献率大于 80% 的原则确定因子个数[13]。

$$\boldsymbol{A}=(\sqrt{\lambda_1}\boldsymbol{U}_1,\sqrt{\lambda_2}\boldsymbol{U}_2,\cdots,\sqrt{\lambda_m}\boldsymbol{U}_m) \tag{2}$$

$$\frac{\sum_{i=1}^{n}\lambda_i}{\sum_{i=1}^{m}\lambda_i}\geqslant 80\% \tag{3}$$

(4) 采用回归法计算因子得分系数,代入载荷矩阵 $\boldsymbol{A}$,计算公共因子得分系数矩阵 $\boldsymbol{b}_j$。将主因子表示为变量的线性组合,计算公因子得分。

$$F_p = b_{j1}X_{1n} + b_{j2}X_{2n} + \cdots + b_{jp}X_{pn} \quad (4)$$

式中:F_p 代表提取的公因子;X_{1n} 代表边坡影响因素评价指标。

1.2 鲸鱼优化算法(WOA)

鲸鱼优化算法是由 Mirjalili 提出的一种新型启发式搜索算法[14]。通过鲸鱼群体收缩、包围、追捕和攻击猎物等过程实现优化收缩的目的。该算法具体寻优过程如下。

(1) 收缩包围。座头鲸发现猎物位置后,根据目标位置不断更新自己的位置逐渐包围猎物,种群中其他鲸鱼向最优鲸鱼包围位置靠拢更新自身位置,其更新位置方程式为:

$$\boldsymbol{X}_{(t+1)} = \boldsymbol{X}^*_{(t)} - \boldsymbol{BD} \quad (5)$$

$$\boldsymbol{D} = |\boldsymbol{CX}^*_{(t)} - \boldsymbol{X}_{(t)}| \quad (6)$$

式中:t 是迭代次数;$\boldsymbol{X}_{(t+1)}$ 是鲸鱼更新后的位置向量;$\boldsymbol{X}^*_{(t)}$ 是迭代次数为 t 时的最优鲸鱼位置向量,即当前找到的最佳解;$\boldsymbol{X}_{(t)}$ 是当前鲸鱼的位置向量;$\boldsymbol{D}$ 代表当前鲸鱼个体与最优解之间的距离向量;$\boldsymbol{B}$ 和 $\boldsymbol{C}$ 是系数向量,$\boldsymbol{B}=2a\boldsymbol{r}_1-a$,$\boldsymbol{C}=2\boldsymbol{r}_2$,收敛因子 a 随迭代过程从 2 线性递减至 0,$\boldsymbol{r}_1$、$\boldsymbol{r}_2$ 是[0,1]区间内的随机向量[15]。

(2) 气泡网捕食。鲸鱼在进行螺旋泡泡式捕猎过程中,这一同步选择的数学模型表达式为:

$$\boldsymbol{X}_{(t+1)} = D'\mathrm{e}^{bl}\cos(2\pi\pi\boldsymbol{l}) + \boldsymbol{X}^*_{(t)} \quad (7)$$

$$D' = |\boldsymbol{X}^*_{(t)} - \boldsymbol{X}_{(t)}| \quad (8)$$

式中:D'为螺旋路径计算的欧氏距离;$\boldsymbol{l}$ 为螺旋随机向量,$\boldsymbol{l}\subseteq(-1,1)$;$b$ 为常数,用来描述螺旋形状。

(3) 搜索猎物。鲸鱼根据彼此的位置进行随机搜索,基于系数向量 $\boldsymbol{B}$ 的绝对值,决定鲸鱼个体寻找猎物搜索的方法。当 $\boldsymbol{B}$ 的绝对值大于 1 时,迫使鲸鱼远离当前最优位置,当 $\boldsymbol{B}$ 的绝对值小于 1 时,进入猎物包围阶段。$\boldsymbol{B}$ 的绝对值大于 1 时,鲸鱼优化算法执行全局搜索,其位置更新数学公式如下:

$$\boldsymbol{X}_{(t+1)} = \boldsymbol{X}_{\mathrm{rand}}(t) - \boldsymbol{BD}_{\mathrm{rand}} \quad (9)$$

$$\boldsymbol{D}_{\mathrm{rand}} = |\boldsymbol{CX}_{\mathrm{rand}}(t) - \boldsymbol{X}_{(t)}| \quad (10)$$

式中:$\boldsymbol{X}_{\mathrm{rand}}(t)$为随机选中的鲸鱼个体的位置向量;$\boldsymbol{D}_{\mathrm{rand}}$为当前个体与随机选中个体之间的距离向量[16]。

1.3 CNN-LSTM 网络模型

本文采用 CNN-LSTM 模型对边坡稳定性状态进行预测。将边坡影响因素数据作为 CNN 的输入层,为更好地提取特征,CNN 模型选择 2 个卷积层及大小为 2×1 的卷积核,第一层卷积核个数设置为 16,第二层设置为 32;通过池化层的最大池化操作,可降低数据维度,并保留更多数据波动的特征信息。将边坡稳定性影响因素特征信息进行分类后输出,最后将这些提取的特征值作为 LSTM 层的输入,通过全连接层预测边坡稳定性状态;CNN-LSTM 模型回归功能的目标函数为 MSE 损失函数;CNN-LSTM 模型最大训练次数设置为 1 000,利用 Adam 算法将训练误差反向传播,逐层逐步更新模型参数,初始学习率为 0.001,CNN-LSTM 模型结构如图 1 所示。

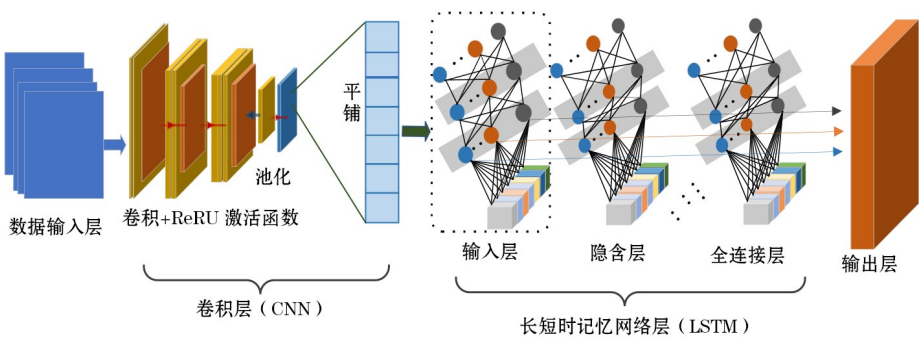


图 1 CNN-LSTM 预测模型总体结构

Fig.1 Overall structure of the CNN-LSTM prediction mode

2 预测指标选取及样本分析

2.1 预测指标选取

为了使模型预测结果更有说服力,从文献[17]至文献[23]中收集了 182 组不同边坡工程实例数据作为数据集(稳定和失稳边坡案例数量分别为 87 组和 95 组),由于篇幅有限,部分数据见表 1。参数的选择基于可获得性、相互独立性及稳定性原则,本文选取了容重(γ)、黏聚力(c)、内摩擦角(φ)、边坡角(β)、边坡高度(H)和孔隙压力比 r_u 6 个影响因素作为预测边坡稳定性的指标,其中,容重、黏聚力和内摩擦角这 3 个指标可用来表征边坡的基本物理力学参数,黏聚力和内摩擦角在摩尔-库伦失效准则中起着重要作用,容重在一定条件下会增加岩土体下滑力,进而对边坡稳定性造成威胁。边坡角和边坡高度这 2 个指标可用来表征边坡的几何结构,边

坡高度对剩余下滑力的影响是显著的,尤其是在高边坡或超高边坡工程中,当高度增加时,边坡稳定性急剧下降。孔隙比表征边坡失稳的外界触发因素降雨和注液量变化。

表 1 原始样本数据

Table 1 Original sample data

序号	c/kPa	φ/(°)	β/(°)	H/m	r_u/kPa	γ/(kN·m^{-3})	边坡实际状态
1	20	36	45	50	0.323	20	失稳
2	40	35	47.1	292	0.323	27	失稳
3	46	35	50	284	0.279	25	稳定
				……			
181	50	40	42	407	0.25	27	稳定
182	159	44.93	31.5	172.98	0.1	26.18	失稳

2.2 数据可视化分析

在建立模型之前,利用 Pearson 相关性分析方法探究各预测指标之间的关联程度,预测指标的相关性矩阵如图 2 所示。相关性指标 0～0.1 表示无相关;0.1～0.3 表示弱相关;0.3～0.5 表示中等相关;0.5～1.0 表示强相关[24]。从图 2 可以看出,某些因素之间存在较强的相关性,如边坡高度(H)与黏聚力(c)、边坡高度(H)与天然容重(γ)之间的相关系数分别为 0.6,0.68,均大于 0.5,表明预测指标之间存在较为明显的相关性,会影响模型预测准确度。因子分析法可以消除指标之间的冗余信息,提高判别指标间的独立性。

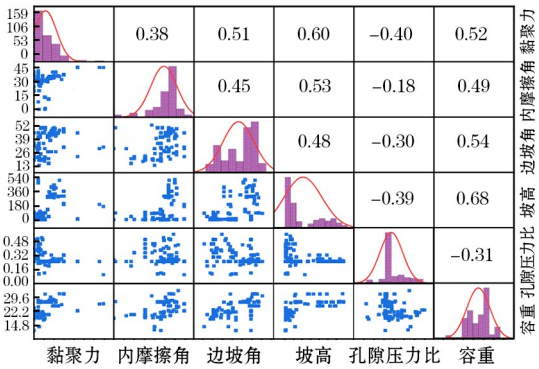


图 2 各预测指标 Pearson 相关系数矩阵

Fig.2 Pearson correlation coefficient matrix of various predictive indicators

2.3 WOA-CNN-LSTM 模型的建立

本文以 6 个预测指标作为模型的变量输入,先对数据进行标准化处理,然后进行因子分析,降低数据之间的维度。将数据集按照 70%训练集、30%测试集进行划分。采用 WOA 算法对 CNN-LSTM 模型中的"学习率""隐藏节点""正则化系数"进行优化,设置鲸鱼优化算法的初始规模为 5,最大迭代次数为 10,优化参数范围分别设置为[10^{-3},10^{-2}]、[10,30]、[10^{-4},10^{-1}]。WOA-CNN-LSM 边坡稳定性预测模型如图 3 所示。

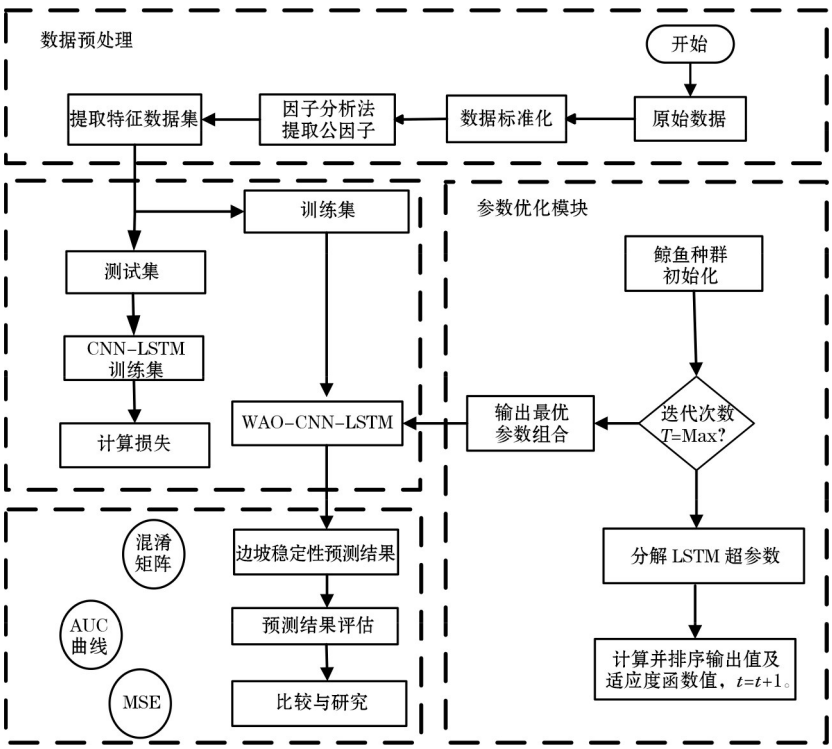


图 3 WOA-CNN-LSTM 模型流程

Fig.3 WOA-CNN-LSTM model flow

2.4 因子分析

为确保因素选取的可靠性,采用 SPSS 软件对 6 个显著相关的指标进行 KMO 检验和 Bartlett 球度检验,样本的 KMO 值为 0.719,Bartlett 球度指标检验 Sig 为 0.000,表明这 6 个指标之间存在较强的相关性,适合进行因子分析,可以实现数据维度降低的目的。

对标准化后的数据进行因子分析,得到公共因子方差解释率(见表 2),根据特征值大于 1 且累积方差贡献率超过 80%原则确定最终公因子个数。

表 2 公共因子总方差解释表

Table 2 Total variance explaining table of common factors

指标	旋转前方差解释率			旋转后方差解释率		
	特征根	方差解释率/%	累积/%	特征根	方差解释率/%	累积/%
c/kPa	2.806	46.759	46.759	1.605	26.747	26.747
φ/(°)	1.104	18.407	65.166	1.593	26.543	53.290
β/(°)	0.734	12.233	77.400	1.039	17.316	70.605
H/m	0.629	10.486	87.886	1.037	17.281	87.886
r_u/kPa	0.411	6.848	94.734	—	—	—
γ/(kN·m^{-3})	0.316	5.266	100.000	—	—	—

注:"—"表示该指标在此因子上的贡献极低,可视为"不相关"。

由表 2 可知,前 4 个公共因子累加能解释样本总体方差的 87.886%,可反映出初始变量的绝大部分信息。对因子载荷矩阵进行方差最大化旋转后,得到因子旋转后的方差解释率,前 4 个因子变量的特征值均大于 1,确定提取前 4 个对原变量方差解释显著的成分作为公共因子,分别定义为 F_1、F_2、F_3、F_4。

2.5 对比分析及 WOA-CNN-LSTM 模型检验

为验证 WOA-CNN-LSTM 模型的分类性能,将 WOA-CNN-LSTM 模型与 CNN-LSTM 模型、CNN 模型和 CNN-SVM 模型进行对比分析,并绘制混淆矩阵,如图 4 所示。采用准确率、精确率、召回率、F_1 分数(F_1-score)和均方误差(Mean Square Error,MSE)5 个评判指标验证模型在边坡稳定性预测方面的适用性,各模型预测性能评估结果见表 3。

表 3 模型性能评估结果

Table 3 Evaluation results of model performance

预测模型	准确率/%	召回率	精确率	F_1 分数	MSE
WOA-CNN-LSTM	94.54	1.00	0.91	0.95	0.055
CNN-LSTM	90.09	0.93	0.88	0.92	0.091
CNN	75.93	0.88	0.76	0.82	0.152
CNN-SVM	83.33	0.81	0.84	0.82	0.389

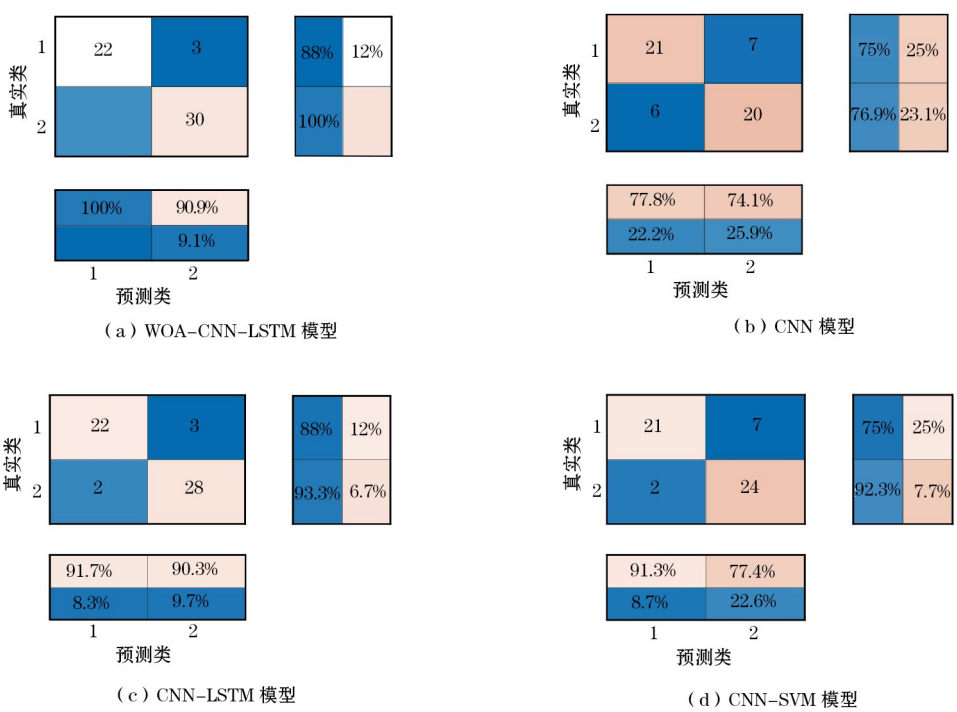


图 4 测试集混淆矩阵

Fig.4 Confusion matrix of test set

由表 3 可知,WOA-CNN-LSTM 模型预测准确率可达到 94.54%,与 CNN-LSTM 模型、CNN 模型和 CNN-SVM 模型相比较,该预测模型准确率分别提高了 4.45,18.61,11.21 个百分点,且 CNN-

LSTM 模型相对 CNN、CNN-SVM 模型在精确度和 F_1 分数值上均有明显的提升,表明 CNN-LSTM 模型在边坡稳定性预测方面的适用性强,同时 WOA-CNN-LSTM 模型的准确率、预测精度、F_1 分数值等评价指标均表现最佳,可见 WOA 优化算法可以有效提高 CNN-LSTM 模型的预测效果和稳定性。

3 工程案例

为进一步验证 WOA-CNN-LSTM 模型在工程实践中应用的可靠性,本文选取某露天铜矿的东部露天采场终了边坡作为研究对象。该矿东部露天采场终了边坡东帮设计高度为 252 m,坡角为 45.57°;西帮设计高度为 216 m,坡角为 41.75°;南帮设计高度为 296 m,坡角为 45.89°;北帮设计高度为 312 m,坡角为 30.05°。矿体产状与周围岩石的产状基本相同,并受到岩性和地层的严格控制,露天采场区域岩性主要为片岩[25]。露天矿边坡工程实例预测结果见表 4。

表 4 工程实例预测结果对比

Table 4 Prediction results comparison of engineering cases

边坡	预测指标						实际状态	不同模型预测结果			
	γ/(kN·m^{-3})	c/kPa	φ/(°)	β/(°)	H/m	r_u/kPa		WOA-CNN-LSTM	CNN-LSTM	CNN	CNN-SVM
东帮边坡	29.16	9.2	55.33	45.57	252	0.2	1	1	1	1	2
西帮边坡	29.16	9.2	55.33	41.75	216	0.2	1	1	1	1	2
南帮边坡	29.16	9.2	55.33	45.89	296	0.2	2	2	2	1	2
北帮边坡	29.16	9.2	55.33	30.05	312	0.2	1	1	1	1	1

由表 4 可知,WOA-CNN-LSTM 和 CNN-LSTM 模型预测结果与实际情况完全吻合,CNN 模型出现一次误判,CNN-SVM 模型在边坡稳定性预测实例中出现了两次误判。WOA-CNN-LSTM 模型在边坡稳定性分析中具有较优的预测精度,同时展现出良好的模型适应性。

4 结论

(1) 边坡稳定性影响因素的相关性分析结果显示,6 个影响因素指标之间存在显著的相关性。因此,采用因子分析方法对数据进行降维处理,提取出 4 个公共因子,消除数据中的冗余信息,很大程度上减少了影响因子间存在相关性所引起的计算误差,同时有效提升了模型的计算效率。

(2) 将 WOA-CNN-LSTM 模型与 CNN-LSTM 模型、CNN 模型及 CNN-SVM 模型进行对比分析,结果显示,WOA-CNN-LSTM 模型的预测准确率、精确率、F_1 分数分别达到 94.54%、0.91、0.95,准确率较未优化的 CNN-LSTM 模型提升 4.45 个百分点。CNN-LSTM 模型本身已具备较好的边坡稳定性预测能力,而 WOA 智能优化算法,自动搜索最优网络配置,有效避免 CNN-LSTM 模型陷入局部最优,提升了预测精度。WOA-CNN-LSTM 模型在复杂地质条件下的边坡稳定性预测中表现更稳健,能够更精准地捕捉露天矿边坡的稳定性特征。

(3) 本研究将“因子分析 + WOA + CNN-LSTM”三重优化策略应用于露天矿边坡稳定性预测,解决了传统模型依赖人工调参、数据冗余影响精度的问题。试验证明,该模型不仅预测精度高,且具备较强的工程适用性,可为矿山边坡的安全监测与灾害预警提供智能化决策支持。

参考文献(References):

[1] 曾亚武,田伟明.边坡稳定性分析的有限元法与极限平衡法的结合[J].岩石力学与工程学报,2005(增刊 2):5355-5359.
Zeng Yawu, Tian Weiming. Slope stability analysis by combining fem with limit equilibrium method[J]. Chinese Journal of Rock Mechanics and Engineering, 2005(Suppl. 2):5355-5359.

[2] 王东,姜聚宇,韩新平,等.基于强度折减法的露天矿压煤区复合边坡稳定性研究[J].煤炭科学技术,2019,47(3):234-238.
Wang Dong, Jiang Juyu, Han Xinping, et al. Study on stability of composite slope in unexploited coal area of open-pit mine[J]. Coal Science and Technology, 2019, 47(3): 234-238.

[3] 蓝宇.基于数值模拟的露天矿排土场高陡边坡稳定性分析与治理[J].矿业研究与开发,2023,43(3):77-82.
Lan Yu. Stability analysis and treatment of high and steep slope in open-pit dump based on numerical simulation[J]. Mining Research and Development, 2023, 43(3): 77-82.

[4] 赵黎,粟登峰,谭宝会,等.基于 CRITIC-GRA-AHP 法的敏感性排序理论及其在边坡稳定性分析中的应用[J].矿业研究与开发,2024,44(9):82-93.

Zhao Li, Su Dengfeng, Tan Baohui, et al. Sensitivity ranking theory based on CRITIC-GRA-AHP method and its applicationin slope stability analysis[J].Mining Research and Development,2024,44(9):82-93.

[5] 杨文东,杨栋,谢全敏.基于云模型的边坡风险评估方法及其应用[J].华中科技大学学报(自然科学版),2018,46(4):30-34.
Yang Wendong, Yang Dong, Xie Quanmin. Study on slope risk assessment method based on cloud model and its application[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2018, 46(4): 30-34.

[6] 刘舒逸,陈建宏.基于嵌套型优势关系粗糙集与模糊理论的岩质边坡施工安全性评价[J].铁道科学与工程学报,2023,20(12):4571-4581.
Liu Shuyi, Chen Jianhong. Safety evaluation of rock slope construction based on nested dominance relation rough set and fuzzy theory [J]. Journal of Railway Science and Engineering,2023,20(12):4571-4581.

[7] 傅杨攀,刘勇健,陈贡发,等.基于 CSMR 和卷积神经网络的岩质边坡稳定性分析[J].自然灾害学报,2023,32(1):114-121.
Fu Yangpan, Liu Yongjian, Chen Gongfa, et al. Stability analysis of rock slope based on CSMR and convolution neural network[J]. Journal of Natural Disasters, 2023, 32(1):114-121.

[8] He Jia, Zhang Sherong, Wang Chao, et al. MSC-1DCNN-based homogeneous slope stability state prediction method integrated with empirical data[J]. Natural Hazards, 2023, 118(1):729-753.

[9] Sun Junlong, Wu Shunchuan, Zhang Huajin, et al. Based on multi-algorithm hybrid method to predict the slope safety factor: stacking ensemble learning with Bayesian optimization[J]. Journal of Computational Science, 2022, 59:101587

[10] 荣光旭,李宗洋.CNN-LSTM 模型在边坡可靠度分析中的应用[J].黄金科学技术,2023,31(4):613-623.
Rong Guangxu, Li Zongyang. Application of CNN-LSTM model in slope reliability analysis [J]. Gold Science and Technology,2023,31(4):613-623.

[11] 刘立邦,杨颂,王志坚,等.基于改进 WOA-LSTM 的焦炭质量预测[J].化工学报,2022,73(3):1291-1299.
Liu Libang, Yang Song, Wang Zhijian, et al. Prediction of coke quality based on improved WOA-LSTM [J]. CIESC Journal,2022,73(3):1291-1299.

[12] 张书豪,艾亚鹏,陈健,等.物元可拓法在引水隧洞围岩稳定性评价中的应用[J].安全与环境学报,2024,24(1):10-18.
Zhang Shuhao, Ai Yapeng, Chen Jian, et al. Application of matter element extension method in stability evaluation of surrounding rock of diversion tunnel[J]. Journal of Safety and Environment,2024,24(1):10-18.

[13] 阎莹,王虹婷,万利,等.基于因子分析与熵值法的不同隧道侧向宽度下驾驶负荷模型[J].中国公路学报,2023,36(2):190-202.
Yan Ying, Wang Hongting, Wan Li, et al. Driver load model under different tunnel lateral widths based on factor analysis and entropy method[J]. China Journal of Highway and Transport,2023,36(2):190-202.

[14] Mirjalili S, Lewis A. The whale optimization algorithm[J]. Advances in Engineering Software,2016,95:51-67

[15] 郁君甫.基于改进鲸鱼优化算法的灰度图像对比度增强算法[J].中阿科技论坛(中英文),2024(4):113-117.
Xi Junfu. Study on contrast enhancement algorithm for grayscale images based on Enhanced Whale Optimization Algorithm (E-WOA) [J]. China-Arab States Science and Technology Forum,2024(4):113-117.

[16] 李家豪,王青于,范玥霖,等.鲸鱼优化算法-双向长短期记忆神经网络用于断路器机械剩余寿命的预测研究[J].高电压技术,2024,50(1):250-262.
Li Jiahao, Wang Qingyu, Fan Yuelin, et al. Research on whale optimization algorithm-bidirectional long-short-term memory neural network for prediction of machinery remaining useful life of circuit breaker[J]. High Voltage Engineering,2024,50(1):250-262.

[17] 顾清华,李梦然,闫宝霞.基于 DE-BA-LSSVM 的露天矿边坡稳定性预测[J].矿业研究与开发,2018,38(8):1-5.
Gu Qinghua, Li Mengran, Yan Baoxia. Prediction of slope stability in open-pit mine based on DE-BA-LSSVM [J]. Mining Research and Development,2018,38(8):1-5.

[18] 付义祥,刘世凯,刘大鹏.RBF 神经网络在边坡岩体稳定性中的预测研究[J].武汉理工大学学报(交通科学与工程版),2003(2):170-173.
Fu Yixiang, Liu Shikai, Liu Dapeng. Prediction of rock slope stability by RBF neural network[J]. Journal of Wuhan University of Technology (Transportation Science & Engineering),2003(2):170-173.

[19] 王佳.基于支持向量机的边坡随机模糊可靠度分析[D].武汉:华中科技大学,2016.
Wang Jia. Slope fuzzy-random reliability analysis based on support vector machine[J]. Wuhan: Huazhong University of Science and Technology,2016.

[20] 邵良杉,马寒,温廷新.基于 RF-ELM 模型的边坡稳定性预测研究[J].中国安全生产科学技术,2015,11(3):93-98.
Shao Liangshan, Ma Han, Wen Tingxin. Study on slope stability prediction based on RF-ELM mode[J]. Journal of Safety Science and Technology,2015,11(3):93-98.

[21] 臧焜岩,李梅红.基于 GA-BP 模型的露天矿边坡稳定性预测[J].中国矿业,2019,28(6):144-148.
Zang Kunyan, Li Meihong. Slope stability prediction of open-pit mine based on GA-BP model[J]. China Mining Magazine,2019,28(6):144-148.

[22] 史笑凡,杨春风,王可意.基于支持向量机和改进 BP 神经网络的路基边坡稳定性研究[J].公路交通科技,2019,36(1):31-37.

Shi Xiaofan, Yang Chunfeng, Wang Keyi. Study on stability of roadbed slope based on SVM and improved BP neural network [J]. Journal of Highway and Transportation Research and Development,2019,36(1):31-37.

[23] 赵国彦,邹景煜,王猛.基于混沌粒子群改进支持向量机对露天矿边坡稳定性的分类预测[J].矿冶工程,2024,44(2):8-12.
Zhao Guoyan, Zou Jingyu, Wang Meng. Classification and prediction of slope stability of open-pit mine with support vector machine based on chaotic particle swarm optimization [J]. Mining and Metallurgical Engineering, 2024, 44(2): 8-12.

[24] 潘晓娟,张文,孙琦,等.高陡岩质斜坡复杂结构面分布规律及统计均质区划分[J].地球科学,2024,49(9):3334-3346.
Pan Xiaojuan, Zhang Wen, Sun Qi, et al. Complex structural plane distribution of high-steep rock slope and division of statistical homogeneous zones[J]. Earth Science, 2024,49(9):3334-3346.

[25] 林逸晖,李广涛,杨天雨,等.基于 PCA-RF 的边坡稳定性预测[J].化工矿物与加工,2023,52(12):59-65.
Lin Yihui, Li Guangtao, Yang Tianyu, et al. Slope stability prediction based on PCA-RF [J]. Industrial Minerals & Processing,2023,52(12):59-65.