

DOI:10.13409/j.cnki.jdpme.20250401001

基于 PSO-LightGBM 模型的边坡稳定性 预测研究*

张仕杰^{1,2}, 张煜^{1,2}, 张宁^{1,2}

(1. 安徽建筑大学土木工程学院, 安徽 合肥 230601;

2. 安徽省岩土工程智能建造与灾变防控重点实验室, 安徽 合肥 230601)

摘要: 边坡稳定性的准确预测对降低边坡失稳风险具有重要意义。为高效且准确地预测边坡稳定性,提出了一种基于粒子群(PSO)优化轻量级梯度提升机(LightGBM)的边坡稳定性预测模型,即 PSO-LightGBM 模型。该模型首先采用粒子群算法优化 LightGBM 模型中的重要参数,在实际工程应用中,降低了 LightGBM 模型参数所产生的影响。然后采用优化后的 LightGBM 模型对边坡稳定性进行分类预测。选取 K 近邻(KNN)、支持向量机(SVM)、LightGBM、网格搜索优化 LightGBM(GS-LightGBM)以及遗传优化 LightGBM(GA-LightGBM)作为对比模型,并采用准确率、精确率、召回率与 F1 分数作为各模型预测性能的评价指标,并通过混淆矩阵可视化各模型分类结果。基于 PSO-LightGBM 模型的特征重要性分析,量化了各因素在边坡稳定性预测中的相对重要性。研究表明,在测试集上 PSO-LightGBM 模型的各项评价指标上均显著优于其他对比模型,表现出较强的分类预测性能与泛化能力。通过特征重要性分析,影响边坡稳定性的因素从大到小依次为:坡角、坡高、内聚力、内摩擦角、土体重度与孔隙水压力。本研究为边坡稳定性的准确预测提供了一种新方法,对边坡工程安全设计与风险评估具有重要参考意义。

关键词: 边坡稳定性; 机器学习; 轻量级梯度提升机(LightGBM); 粒子群算法

中图分类号: TP183 **文献标识码:** A **文章编号:** 1672-2132(2025)05-1233-08

Research on Slope Stability Prediction Based on PSO-LightGBM Model

ZHANG Shijie^{1,2}, ZHANG Yu^{1,2}, ZHANG Ning^{1,2}

(1. College of Civil Engineering, Anhui Jianzhu University, Hefei 230601, China;

2. Anhui Provincial Key Laboratory of Intelligent Construction and Disaster Prevention and Control of Geotechnical Engineering, Anhui Jianzhu University, Hefei 230601, China)

Abstract: The accurate prediction of slope stability is of great significance for reducing the risk of slope instability. To achieve efficient and accurate slope stability prediction, this study proposed a slope stability prediction model based on particle swarm optimization (PSO) for light gradient boosting machine (LightGBM), namely the PSO-LightGBM model. This model first used the PSO algorithm to optimize key parameters of the LightGBM model, reducing the impact of parameters of the LightGBM

* 收稿日期:2025-04-01;修回日期:2025-05-15

基金项目:安徽省高校杰出青年科研项目(2022AH020027)、安徽省自然科学基金水科学联合基金(2408055US003)资助

作者简介:张仕杰(2002—),男,硕士研究生。主要从事边坡工程灾害预警与防治研究。E-mail: zsj020131@163.com

通信作者:张宁(1985—),男,教授,博导,博士。主要从事岩土工程地震研究。E-mail: ningzhanghhu@163.com

model in practical engineering applications. Then, the optimized LightGBM model was adopted to classify and predict the slope stability. K-nearest neighbor (KNN), support vector machine (SVM), LightGBM, grid search-optimized LightGBM (GS-LightGBM), and genetic algorithm-optimized LightGBM (GA-LightGBM) were selected as comparison models. Accuracy, precision, recall, and F1 score were used as evaluation indicators for the predictive performance of each model, and the classification results of each model were visualized through the confusion matrices. Based on the feature importance analysis of the PSO-LightGBM model, the relative importance of each factor in slope stability prediction was quantified. The results showed that the PSO-LightGBM model significantly outperformed all other comparison models across all evaluation indicators on the test set, demonstrating strong classification prediction performance and generalization ability. Through feature importance analysis, the factors affecting slope stability were ranked in descending order as follows: slope angle, slope height, cohesion, internal friction angle, soil unit weight, and pore water pressure. This study provides a new method for the accurate prediction of slope stability and offers an important reference for the safety design and risk assessment of slope engineering.

Keywords: slope stability; machine learning; light gradient boosting machine (LightGBM); particle swarm optimization

0 引言

边坡稳定性分析和预测是岩土工程领域的一个关键问题。近年来,我国边坡工程量不断增加,边坡失稳现象频发,造成了严重的自然灾害与经济损失^[1]。传统的边坡稳定性分析法主要包括极限平衡法^[2-3]与数值模拟法^[4-5],这些方法在全面分析边坡稳定性、深入揭示边坡变形与破坏机理以及广泛的适用范围等方面具有一定的优势。然而,边坡稳定性与各影响因素之间往往呈现复杂的非线性关系,传统分析法在处理这些复杂因素时存在一定的局限性。

近年来,随着人工智能等新兴技术的发展,机器学习算法已广泛应用于边坡稳定性预测研究中^[6]。众多学者将BP神经网络、K近邻和支持向量机等机器学习算法应用在边坡稳定性预测上,通过其强大的非线性映射能力捕捉数据中的复杂关系,从而准确且高效地预测边坡稳定性^[7-10]。尽管上述机器学习算法在边坡稳定性研究中得到了广泛应用,但存在对数据不敏感、易陷入局部最优与稳定性较低等问题,并在解释预测结果方面具有一定的局限性^[11-12]。而轻量级梯度提升机是一种高效的梯度提升决策树算法(LightGBM),能够反映影响因素与边坡稳定性之间复杂非线性关系,并且具有更强的泛化能力与计算效率^[13-14]。张凯等^[15]在边坡稳定性

预测中使用了LightGBM算法模型,提高了预测效果与模型泛化性能。白龙发等^[16]使用平衡优化器算法(EO)对LightGBM算法中的超参数进行优化,进一步提高了预测模型的可靠性。然而,模型的预测性能易受到参数设置的影响,因此如何优化模型参数对于提高模型预测精度与泛化能力具有重要意义。J. Kennedy等^[17]首次提出基本粒子群算法(Particle Swarm Optimization, PSO)的概念,并提出了包括非线性函数优化和神经网络训练在内的应用。随后许多学者将其应用于LightGBM模型的参数优化上,J. J. Zhu等^[18]使用PSO对LightGBM模型进行参数优化并应用在识别贫困学生上。H. Luo等^[19]在全球导航卫星领域(GNSS)的信号标注和分类领域上使用了PSO算法对LightGBM模型进行了优化。二者结果上都体现了PSO算法对LightGBM模型有较强的优化效果。但在岩土工程领域还鲜有PSO-LightGBM算法模型的应用。

因此,为了实现高效的和高精度的边坡稳定性预测,提出了基于PSO优化LightGBM的边坡稳定性预测模型PSO-LightGBM,具体过程如下:利用粒子群算法优化LightGBM模型中的重要参数,使用优化后的LightGBM对边坡稳定性进行分类预测,最后根据实验目的,将K近邻(KNN),支持向量机(SVM)以及未经过任何优化处理的LightGBM分别设置为对照组来比较其各自分类效果及泛化能力。针对不同模型所得出的结果分别以准确率、

精确率、召回率、F1分数四个评价指标进行综合衡量并结合混淆矩阵来进行展示以便直观观察到各个模型所得到的结果情况。PSO-LightGBM在所有评价指标上都表现出了更优的效果,同时能够看出其具备较好的分类预测能力和较强的泛化能力。可为今后的边坡稳定性精准预测问题提供新的思路,对于后续边坡工程的安全性设计和风险评估都有着重要的参考意义。

1 模型原理

1.1 粒子群算法

粒子群算法(Particle Swarm Optimization,简称PSO)是一种对鸟群觅食行为予以模拟的随机优化算法^[20]。粒子群算法基于对动物集群活动行为的观测,通过群体里的个体对信息的共享,促使整个群体的运动于问题求解空间中历经从无序至有序的演化历程,进而获取最优解。

在PSO算法中,假设有 M 个粒子群体在 D 维空间中进行搜索,则第 i 个粒子的当前位置与速度分别为 $x_{ij}=(x_{i1},x_{i2},\dots,x_{iD})$ 和 $v_{ij}=(v_{i1},v_{i2},\dots,v_{iD})$ 。每一代粒子在第 $t+1$ 次迭代的速度和位置的更新公式为:

$$v_{id}^{(t+1)} = \omega v_{id}^{(t)} + c_1 r_1 (P_{best,d} - x_{id}^{(t)}) + c_2 r_2 (G_{best,d} - v_{id}^{(t)}) \quad (1)$$

$$x_{id}^{(t+1)} = x_{id}^{(t)} + v_{id}^{(t+1)} \quad (2)$$

式中, ω 为惯性权重; c_1 和 c_2 分别为学习因子; r_1 和 r_2 ,为两个在 $[0,1]$ 内变化的随机数; $P_{best,d}$ 和 $G_{best,d}$ 分别表示粒子和群体经历的最优位置。

1.2 LightGBM 模型

轻量级梯度提升机(Light Gradient Boosting Machine, LGBM)是一种基于改进梯度提升(GBDT)的集成学习算法,通过构建多棵决策树以提升模型的预测性能^[21]。在传统的GBDT算法中,分裂的计算通常是遍历每个特征的所有可能值,而LightGBM引入了直方图算法来加速特征分裂过程。它将连续的特征值离散化为一个个区间(bin),然后基于这些区间构建直方图。在训练时,LightGBM只需要根据这些区间计算分裂点的增益值,而不需要遍历每个特征的具体值,从而提高了计算效率。

传统的GBDT采用层级生长策略(图1,绿色代

表下一次分裂的节点),即每次在当前层的所有节点都进行分裂,在处理大规模数据时效率低下。相比之下,LightGBM采用叶子生长策略(图2,绿色代表下一次分裂的节点),即每次选择增益最大的叶子节点进行分裂,这种策略能够更直接地优化模型的损失函数,从而显著提升训练效率。




图1 层级生长

Fig.1 Level-wise growth




图2 叶子生长

Fig.2 Leaf-wise growth

2 PSO-LightGBM 模型构建

LightGBM算法对回归预测有很好的效果,但是太多的参数使其在实际应用中无法充分发挥最大效能。这些参数影响LightGBM的准确率以及训练速度,首先,通过调整学习率来持续增强模型性能,学习率越小,通常需要树的数量更多,准确率越高,但是会降低模型训练速度,并且出现过拟合现象。树的最大深度和叶子节点数显著影响模型的性能与效能,叶子节点最小样本数与划分节点时的最小增益也需仔细调整,而PSO算法可以在迭代训练中有效平衡LightGBM参数取值,并找到最优值,PSO优化LightGBM的参数见表1。

表1 优化的参数及其含义

Table 1 Optimized parameters and their descriptions

| 序号 | 参数 | 含义 |
|----|-------------------|------------|
| 1 | learning_rate | 学习率 |
| 2 | n_estimators | 树的数量 |
| 3 | max_depth | 树的最大深度 |
| 4 | num_leaves | 树的叶子节点数 |
| 5 | min_child_samples | 叶子节点最小样本数 |
| 6 | min_split_gain | 划分节点时的最小增益 |

对此构建了基于 PSO-LightGBM 的边坡稳定性预测模型,流程如图 3 所示,构建步骤如下:

(1) 进行数据标准化,以均衡各项指标量纲差异。

(2) 明确 LightGBM 算法参数优化需求及其寻优区间,初始化粒子群体,评估各粒子的适应度指标。

(3) 评估粒子适应度,识别群体中的最优解,并对粒子的位置与速度进行更新,以寻求最佳参数组合。

(4) 循环执行(2)至(3)步骤,直至达到预定的迭代上限。

(5) 输出最优参数组合,并输入 LightGBM 模型的超参数中,训练得到 PSO-LightGBM 模型。

(6) 采用分类性能评价指标对的预测性能进行评估并通过混淆矩阵可视化分类结果与其他模型进行对比,并进行特征重要性分析,以深入探究各特征变量对边坡稳定性的影响程度。

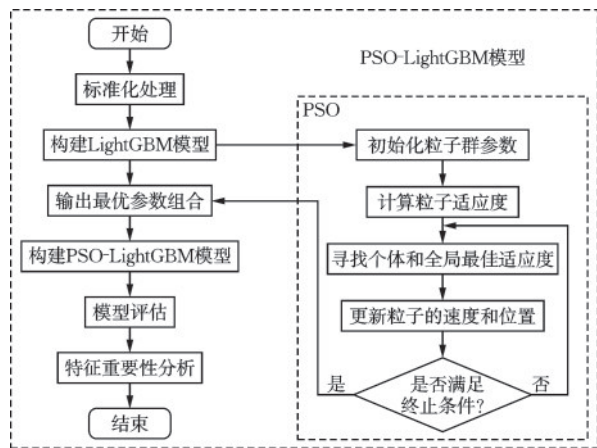


图 3 PSO-LightGBM 模型流程
Fig.3 Flowchart of PSO-LightGBM model

3 数据分析

3.1 数据集

边坡稳定性受多种因素影响,包括地质构造、岩性、水文条件和边坡几何形态等多个方面。本文参考相关学者的研究成果^[22-24],选取土体重度 γ 、内聚力 c 、内摩擦角 φ 、坡角 β 、边坡高度 h 以及孔隙水压力 r_u 作为边坡稳定性评价指标。坡度和边坡高度是决定边坡稳定性的关键几何要素;土体的重量、

黏聚力和摩擦角体现了其物理属性与强度特征,这些直接决定了土体的抗剪切能力;而孔隙水压通过调整土体的有效应力状态,对边坡稳定性产生间接影响。本研究从文献[25-28]中选取 140 组边坡稳定性案例,建立边坡安全系数数据集,见表 2,其中“1”表示边坡稳定,“0”表示边坡失稳。为了更好地描述评价指标的分布规律,各评价指标的小提琴分布如图 4 所示,其中,小提琴图的纵向延伸范围反映了

表 2 边坡稳定性数据集
Table 2 Slope stability dataset

| 编号 | $\gamma /$ ($\text{kN}\cdot\text{m}^{-3}$) | $c /$ kPa | $\varphi /$ ($^\circ$) | $\beta /$ ($^\circ$) | $h /$ m | $r_u /$ kPa | 状态 |
|-------|---|--------------|--------------------------|------------------------|---------|----------------|----|
| 1 | 18.80 | 14.4 | 25.02 | 19.98 | 30.6 | 0.0 | 1 |
| 2 | 18.77 | 30.01 | 9.99 | 25.02 | 50.0 | 0.1 | 1 |
| 3 | 19.97 | 19.96 | 36.00 | 45.50 | 50.0 | 0.5 | 0 |
| 4 | 22.38 | 10.05 | 35.01 | 45.00 | 10.0 | 0.4 | 0 |
| | | | | | | | |
| 139 | 23 | 0 | 20 | 20 | 100 | 0.30 | 0 |
| 140 | 22.4 | 100 | 45 | 45 | 15 | 0.25 | 1 |

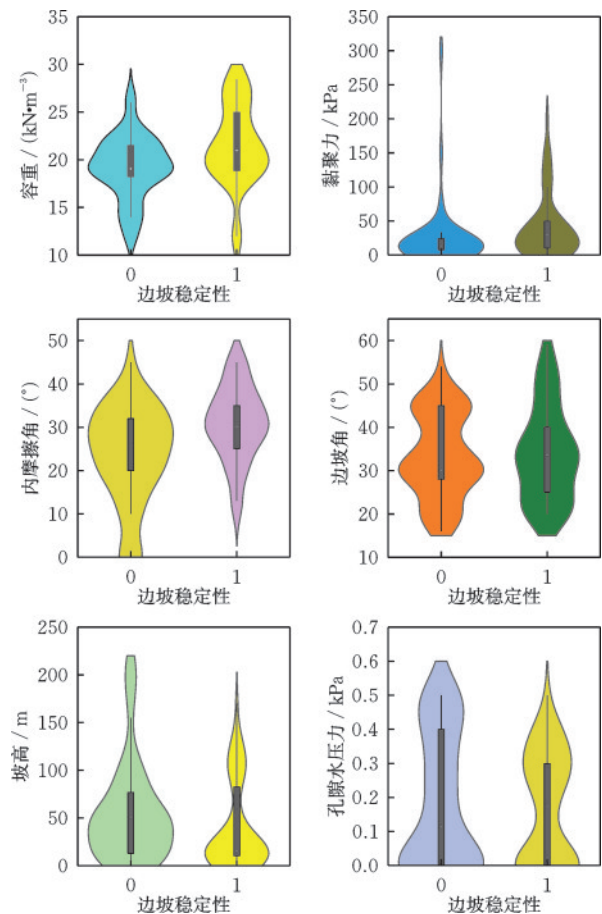


图 4 各指标小提琴分布
Fig.4 Violin plots of different indicators

数据的离散特性,横向宽度变化表征了数据分布的密度特征。

3.2 评价指标选取

本文选取准确率(Accuracy)、精确率(Precision)、召回率(Recall)与F1分数(F1-score)作为模型性能评价指标,并通过混淆矩阵对分类结果进行可视化。其中,准确度指正确判别样本的比率,精确性表示判定为正例中真正正例的比例,而召回率描述的是正例样本中被正确判定的比例。F1分数则是精确性与召回率的和谐均值。这些评估指标的计算方法分别如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (6)$$

式中, TP 为真正类的样本数量; TN 为真负类的样本数量; FP 为假正类的样本数量; FN 为假负类的

样本数量。

3.3 PSO 优化结果

本研究运用 PSO 算法对 LightGBM 模型的参数进行自动调优,旨在增强模型的预测准确性。如图 5 所示的优化过程曲线表明,PSO 算法经过 34 次迭代后达到收敛状态,适应度值趋于收敛,并获取最优参数组合,LightGBM 模型的参数优化结果见表 3。




图 5 适应度变化曲线

Fig.5 Fitness change curve

表 3 LightGBM 模型参数优化范围与最优值

Table 3 Optimization ranges and optimal values of LightGBM model parameters

| 参数 | 含义 | 搜索范围 | 最优值 |
|-------------------|------------|------------|------|
| learning_rate | 学习率 | [0.01,0.1] | 0.08 |
| n_estimators | 树的数量 | [50,300] | 271 |
| max_depth | 树的最大深度 | [3,15] | 5 |
| num_leaves | 树的叶子节点数 | [5,50] | 28 |
| min_child_samples | 叶子节点最小样本数 | [1,20] | 11 |
| min_split_gain | 划分节点时的最小增益 | [0,0.1] | 0.09 |

3.4 模型性能评价

本研究将边坡稳定性样本数据以 3:1 的比例随机分配为训练集与测试集,训练集用于构建模型,测试集则用于评价模型的效能。为检验 PSO-LightGBM 模型的预测性能与泛化能力,本文选取 K 近邻(KNN)、支持向量机(SVM)、LightGBM、网格搜索优化 LightGBM(GS-LightGBM)以及遗传优化 LightGBM(GA-LightGBM)作为对比模型,采用准确率、精确率、召回率与 F1 分数评价指标对各模型的分类结果进行评估(表 4),并通过混淆矩阵对各模型的进行可视化(图 6)。

根据表 4 中各模型的评价指标值与图 6 混淆矩

阵,PSO-LightGBM 模型表现出最佳的分类预测性能与泛化能力。具体来说,PSO-LightGBM 模型的准确率、精确率、召回率和 F1 分数分别为 0.943、0.875、1.000 和 0.933,均为各模型的最高值,这表明 PSO-LightGBM 模型在各评价性能指标上都超过了其他模型,表现出最佳的分类预测性能与泛化能力。与未优化的 LightGBM 模型相比,PSO-LightGBM 模型的各项评价指标均得到显著提高,准确率、精确率、召回率与 F1 分数分别从 0.885、0.813、0.839 和 0.867 提升到 0.943、0.875、1.000、0.933,这表明通过 PSO 算法对 LightGBM 模型进行参数优化,显著提升了模型的分类预测性能与泛化能力。此外,相较于网格搜索(GS)和遗传算法(GA)优化的 Light-

表 4 各模型评价指标值

Table 4 Evaluation indicator values of each model

| 模型 | 准确率 | 精确率 | 召回率 | F1分数 |
|--------------|-------|-------|-------|-------|
| KNN | 0.714 | 0.625 | 0.714 | 0.667 |
| SVM | 0.771 | 0.688 | 0.786 | 0.733 |
| LightGBM | 0.885 | 0.813 | 0.839 | 0.867 |
| GS-LightGBM | 0.914 | 0.867 | 0.929 | 0.897 |
| GA-LightGBM | 0.914 | 0.823 | 1.000 | 0.903 |
| PSO-LightGBM | 0.943 | 0.875 | 1.000 | 0.933 |

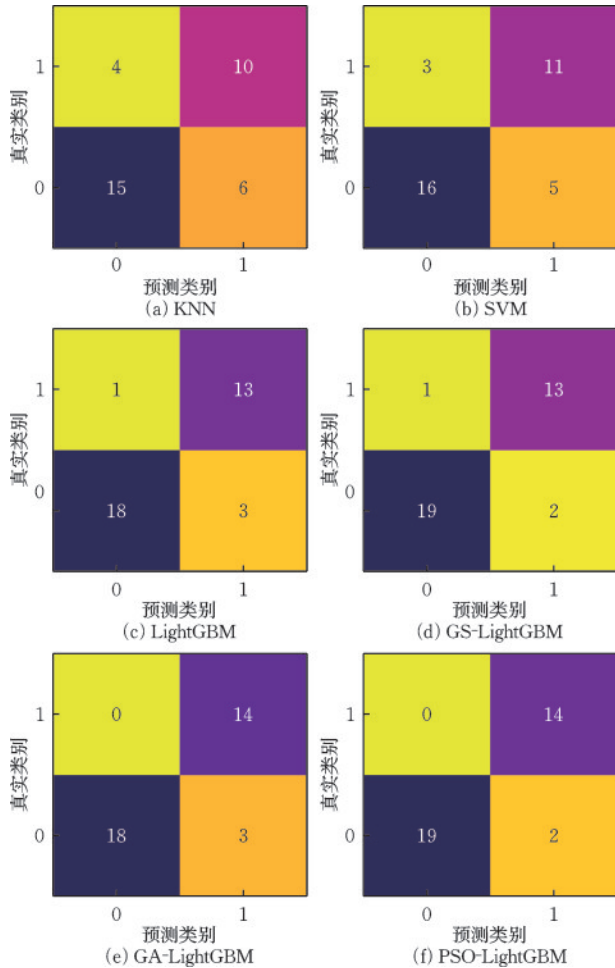


图 6 各模型混淆矩阵

Fig.6 Confusion matrix of each model

GBM 模型, PSO-LightGBM 模型不仅保持了高召回率, 同时在准确率、精确率和 F1 分数上均取得最优值, 这充分验证了 PSO 算法在模型参数优化方面的有效性, 其卓越的全局搜索能力不仅显著提升了模型的预测精度, 更有效增强了模型在边坡稳定性预测任务中的泛化能力和可靠性。因此, PSO-LightGBM 模型是本文所提出的边坡稳定性分类预测的最佳模型, 为边坡稳定性预测提供了新方法。

3.5 特征重要性分析

为进一步解释各评价指标对边坡稳定性的影响, 本文通过 PSO-LightGBM 模型的特征重要性分析, 通过计算各输入特征在模型决策树中的分裂增益 (Gain), 以确定各评价指标对边坡稳定性的相对重要性。对于每个特征 i , 重要性计算公式为:

$$\begin{cases}
 Importance_i = \sum Gain_i \\
 Gain = \frac{1}{2} \left[\frac{\left(\sum_{x \in L} g_x \right)^2}{\sum_{x \in L} h_x + \lambda} + \frac{\left(\sum_{x \in R} g_x \right)^2}{\sum_{x \in R} h_x + \lambda} - \frac{\left(\sum_{x \in P} g_x \right)^2}{\sum_{x \in P} h_x + \lambda} \right]
 \end{cases}
 \quad (7)$$

式中, g_x 为样本的一阶梯度; h_x 为样本的二阶梯度; λ 为正则化系数; L, R, P 分别为分裂后的左子节点、右子节点和父节点。

根据图 7 所示的特征重要性排序结果, 坡角是影响边坡稳定性最重要的因素, 特征重要性值为 0.215, 其次是坡高 (0.204)、内聚力 (0.195)、内摩擦角 (0.153)、土体重度 (0.142) 与孔隙水压力 (0.091)。值得注意的是, 坡角、坡高与内聚力的特征重要性相近, 这表明在边坡稳定性的评估研究中, 应重点关注边坡角、坡高与内聚力的准确性, 进一步提升边坡稳定性评估的可靠性。




图 7 特征重要性排序

Fig.7 Feature importance ranking

4 结论

(1) 在对边坡稳定性预测模型的对比研究中, PSO-LightGBM 模型的准确率、精确率、召回率和 F1 分数分别为 0.943、0.875、1.000 和 0.933, 与对比

模型相比,均为各模型的最高值,这表明 PSO-LightGBM 模型表现出较强的分类预测性能与泛化能力。

(2) 与未优化的 LightGBM 模型相比, PSO-LightGBM 模型的各项评价指标均得到的显著提高,准确率、精确率、召回率与 F1 分数分别提升了 6.6%、7.6%、19.2% 和 6.5%。此外,相较于网格搜索(GS)和遗传算法(GA)优化的 LightGBM 模型, PSO-LightGBM 不仅保持了高召回率,同时在准确率、精确率和 F1 分数上均取得最优值,这充分验证了 PSO 算法在模型参数优化方面的有效性,其卓越的全局搜索能力不仅显著提升了模型的预测精度,更有效增强了模型在边坡稳定性预测任务中的泛化能力和可靠性。

(3) 在本研究数据集上,通过特征重要性分析,边坡角是影响边坡稳定性最关键的因素,对边坡稳定性影响较大。此外,边坡角、坡高与内聚力的特征重要性相近,这表明在边坡稳定性的评估研究中,应重点关注边坡角、坡高与内聚力的准确性,以进一步提升边坡稳定性评估的可靠性。

综上, PSO-LightGBM 模型为边坡稳定性的准确预测提供了一种新方法,对边坡工程安全设计与风险评估具有重要参考意义。

参考文献:

- [1] Suman S, Khan S Z, Das S K, et al. Slope stability analysis using artificial intelligence techniques [J]. *Natural Hazards*, 2016, 84(2): 727-748.
- [2] 章瑞环, 叶帅华, 陶晖. 基于改进极限平衡法的多级均质黄土边坡稳定性分析[J]. *岩土力学*, 2021, 42(3): 813-825.
Zhang R H, Ye S H, Tao H. Stability analysis of multi-stage homogeneous loess slopes by improved limit equilibrium method [J]. *Rock and Soil Mechanics*, 2021, 42(3): 813-825. (in Chinese)
- [3] Liu S Y, Shao L T, Li H J. Slope stability analysis using the limit equilibrium method and two finite element methods [J]. *Computers and Geotechnics*, 2015, 63: 291-298.
- [4] 曹兰柱, 王珍, 王东, 等. 软弱基底排土场堆载过程中稳定性数值模拟[J]. *防灾减灾工程学报*, 2017, 37(5): 776-781.
Cao L Z, Wang Z, Wang D, et al. Numerical simulation of stability in loading dump with weak basement [J]. *Journal of Disaster Prevention and Mitigation Engineering*, 2017, 37(5): 776-781. (in Chinese)
- [5] Ding Q L, Peng Y Y, Cheng Z, et al. Numerical simulation of slope stability during underground excavation using the lagrange element strength reduction method [J]. *Minerals*, 2022, 12(8): 1054.
- [6] Pei T, Qiu T, Shen C P. Applying knowledge-guided machine learning to slope stability prediction [J]. *Journal of Geotechnical and Geoenvironmental Engineering*, 2023, 149(10): 04023089.
- [7] Zhang Y, Dai M L, Ju Z M. Preliminary discussion regarding SVM kernel function selection in the twofold rock slope prediction model [J]. *Journal of Computing in Civil Engineering*, 2016, 30(3): 04015031.
- [8] 胡军, 董建华, 王凯凯, 等. 边坡稳定性的 CPSO-BP 模型研究[J]. *岩土力学*, 2016, 37(增1): 577-582, 590.
Hu J, Dong J H, Wang K K, et al. Research on CPSO-BP model of slope stability [J]. *Rock and Soil Mechanics*, 2016, 37(Sup1): 577-582, 590. (in Chinese)
- [9] Huang S, Huang M M, Lyu Y J. An improved KNN-based slope stability prediction model [J]. *Advances in Civil Engineering*, 2020, 2020(1): 8894109.
- [10] 马文涛. 基于 PSO 和 LSSVM 的边坡稳定性评价方法 [J]. *岩土力学*, 2009, 30(3): 845-848.
Ma W T. Evaluation of rock slope stability based on PSO and LSSVM [J]. *Rock and Soil Mechanics*, 2009, 30(3): 845-848. (in Chinese)
- [11] Cai Y, Yuan Y, Zhou A H. Predictive slope stability early warning model based on CatBoost [J]. *Scientific Reports*, 2024, 14: 25727.
- [12] Yuan H P, Ji S J, Li H Z, et al. Classification forecasting research of rock burst intensity based on the BO-XGBoost-Cloud model [J]. *Earth Science Informatics*, 2024, 18(1): 95.
- [13] Xu W H, Kang Y F, Chen L C, et al. Dynamic assessment of slope stability based on multi-source monitoring data and ensemble learning approaches: A case study of Jiuxianping landslide [J]. *Geological Journal*, 2023, 58(6): 2353-2371.
- [14] Qiu Y G, Zhou J, He B, et al. Evaluation and interpretation of blasting-induced tunnel overbreak: Using heuristic-based ensemble learning and gene expression programming techniques [J]. *Rock Mechanics and Rock Engineering*, 2024, 57(9): 7535-7563.
- [15] 张凯, 张科. 基于 LightGBM 算法的边坡稳定性预测研究[J]. *中国安全科学学报*, 2022, 32(7): 113-120.
Zhang K, Zhang K. Research on slope stability prediction based on LightGBM algorithm [J]. *China Safety*

- Science Journal, 2022, 32(7): 113-120. (in Chinese)
- [16] 白龙发, 李保珠, 时鹏程. 基于EO-LightGBM融合模型的边坡稳定性预测方法研究[J]. 地质灾害与环境保护, 2024, 35(4): 105-111.
Bai L F, Li B Z, Shi P C. Study on slope stability prediction method based on eo-lightgbm fusion model [J]. Journal of Geological Hazards and Environment Preservation, 2024, 35(4): 105-111. (in Chinese)
- [17] Kennedy J, Eberhart R. Particle swarm optimization [C]//Proceedings of ICNN'95-International Conference on Neural Networks. Perth, WA, Australia. New York: IEEE Press, 2002: 1942-1948.
- [18] Zhu J J, Li B T, Wang Z L. A poverty index prediction model for students based on PSO-LightGBM [J]. Annals of Operations Research, 2025, 348(1): 717-734.
- [19] Luo H, Liu J, He D. GNSS signal labeling, classification, and positioning in urban scenes based on PSO-LightGBM-WLS algorithm [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 2528213.
- [20] 胡少伟, 李原昊, 单常喜, 等. 基于改进的PSO-BP神经网络的边坡稳定性研究[J]. 防灾减灾工程学报, 2023, 43(4): 854-861.
Hu S W, Li Y H, Shan C X, et al. Research on slope stability based on improved PSO-BP neural network [J]. Journal of Disaster Prevention and Mitigation Engineering, 2023, 43(4): 854-861. (in Chinese)
- [21] 董学超, 郭明伟, 王水林. 基于LightGBM的超大沉井下沉状态预测及传感器优化布置[J]. 岩土力学, 2023, 44(6): 1789-1799.
Dong X C, Guo M W, Wang S L. Sinking state prediction and optimal sensor placement of super large open caissons based on LightGBM [J]. Rock and Soil Mechanics, 2023, 44(6): 1789-1799. (in Chinese)
- [22] Zhou J, Li E M, Yang S, et al. Slope stability prediction for circular mode failure using gradient boosting machine approach based on an updated database of case histories [J]. Safety Science, 2019, 118: 505-518.
- [23] 刘顺青, 洪宝宁, 徐奋强, 等. 高液限土边坡稳定性影响因素的敏感性研究[J]. 防灾减灾工程学报, 2014, 34(5): 589-596.
Liu S Q, Hong B N, Xu F Q, et al. Sensitivity studies on factors influencing stability of high liquid limit soil slope [J]. Journal of Disaster Prevention and Mitigation Engineering, 2014, 34(5): 589-596. (in Chinese)
- [24] Choo H, Min D H, Sung J H, et al. Sensitivities of input parameters for predicting stability of soil slope [J]. Bulletin of Engineering Geology and the Environment, 2019, 78(8): 5671-5685.
- [25] Lu P, Rosenbaum M S. Artificial neural networks and grey systems for the prediction of slope stability [J]. Natural Hazards, 2003, 30(3): 383-398.
- [26] Das S K, Biswal R K, Sivakugan N, et al. Classification of slopes and prediction of factor of safety using differential evolution neural networks [J]. Environmental Earth Sciences, 2011, 64(1): 201-210.
- [27] Lin H J, Li L, Qiang Y, et al. Sensitivity analysis of slope stability based on eXtreme gradient boosting and SHapley Additive exPlanations: An exploratory study [J]. Heliyon, 2024, 10(16): e35871.
- [28] Sah N K, Sheorey P R, Upadhyaya L N. Maximum likelihood estimation of slope stability [J]. International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts, 1994, 31(1): 47-53.

(本文编辑:张艺)