

基于SCA-GBDT的边坡稳定性预测混合模型

杨星雨¹,王 宁²

(1. 紫金(长沙)工程技术有限公司; 2. 中南大学资源与安全工程学院)

摘要:边坡稳定性智能预测是边坡治理和边坡结构设计的重要基础。边坡稳定性评估具有复杂性和非线性,各种智能预测模型通常具有更好的性能,为研究边坡稳定性问题提供了新的方向。构建了基于正弦余弦算法(SCA)优化梯度提升树(GBDT)的边坡稳定性预测混合模型。收集436个边坡案例来建立数据库,包含6个参数(边坡高度 H 、边坡角 β 、容重 γ 、内聚力 C 、内摩擦角 φ 、孔隙水压力系数 r_u)和边坡状态数据。80%数据划分为训练集,20%数据为测试集进行测试。通过结合五重交叉验证和正弦余弦算法来调整模型的超参数。根据准确率、精确率、召回率、F1分数、AUC来评估所提出方法的性能。同时,研究对比了5个经典分类机器学习模型,以评估模型预测边坡稳定性的性能和适用性。结果表明:SCA能显著提高GBDT模型的性能,SCA-GBDT模型的准确率、精确率、召回率、F1分数、AUC分别为0.886 0,0.877,0.915,0.896和0.955。通过SHAP算法对模型特征重要性分析,发现内摩擦角对预测结果的影响最显著。SCA-GBDT模型为预测边坡稳定性提供了一种可靠的方法,可以应用于边坡工程实践。

关键词:边坡稳定性;预测模型;机器学习;正弦余弦算法;梯度提升树;内摩擦角

中图分类号:TD167

文章编号:1001-1277(2025)03-0059-07

文献标志码:A

doi:10.11792/hj20250311

引言

边坡失稳是一个全球性的工程地质问题,是除地震和火山外自然界三大地质问题之一^[1]。许多岩土工程,如露天采矿、道路交通、水利水电等活动改变了地表结构,形成了大量边坡^[2]。这些边坡在开挖扰动、爆破振动、孔隙水压和地震活动的动载荷作用下,极易发生滑坡失稳等地质灾害,对生命财产安全造成巨大威胁。因此,为了降低边坡失稳风险,科学准确地评估边坡稳定性对工程设计和灾害防治具有重要意义^[3]。由于边坡系统的复杂性,其受多种参数的影响,表现出显著的非线性和不确定性,边坡稳定性分析方法一直是岩土工程中的研究热点和难点。

现有边坡稳定性分析方法通常分两类,传统模型和机器学习(ML)模型。传统边坡稳定性预测方法包括现场监测技术、理论分析方法、数值模拟方法^[4]等。目前,许多边坡变形监测技术,包括位移传感器^[5]、振动测量^[6]、激光扫描^[7]等已被应用于边坡变形的现场监测,以提供预警信号。这些技术具有相对较高的预测精度,可以实时获取边坡变形数据,从而为边坡稳定性评估和预警决策提供重要依据,但安装过程复杂,成本极高。理论分析方法是从力学角度提出的。

许多理论分析方法已被用于边坡稳定性分析^[8],如极限平衡法(LEM)、强度折减法(SRM)等。虽然理论分析方法简单,但由于公式和假设的简化,不适用于条件复杂的边坡。传统方法还包括数值模拟方法,有限元法、边界元法、离散元等方法在边坡稳定性分析中得到了广泛应用^[9]。虽然数值模拟方法操作方便,但精度在很大程度上取决于本构模型和力学参数。边坡作为一个复杂系统,具有高维性、非线性、不确定性、动态演变性和协同性等特点,导致稳定性分析具有一定的复杂性和难度。因此,传统方法的应用显现出很大的局限性,分析结果的可靠度不高。随着边坡案例的积累,研究人员使用机器学习算法开发边坡稳定性预测模型^[10-13],主要有2种类型的预测输出:安全系数(FOS)和稳定性状态。机器学习算法在边坡稳定性预测方面表现良好,然而,需要大量的边坡稳定性案例来提高其可信度^[14]。

本文提出一种正弦余弦算法(Sine Cosine Algorithm, SCA)优化梯度提升树(Gradient Boosting Decision Tree, GBDT)预测模型进行边坡稳定性预测。构建了一个包含436个边坡案例的数据库并进行特征分析,选择6个特征参数(边坡高度 H 、边坡角 β 、容重 γ 、内聚力 C 、内摩擦角 φ 、孔隙水压力系数 r_u)作为模型

输入,边坡稳定性作为模型输出。基于五重交叉验证,使用SCA优化GBDT模型对边坡稳定性数据进行训练和测试。将SCA-GBDT模型与5种常规模型进行性能对比;通过特征重要性分析来评估特征重要性权重。本研究建立的方法为边坡稳定性预测提供了新思路。

1 算法原理

1.1 梯度提升树

GBDT是一种广泛应用于机器学习领域的集成学习算法^[15],由FRIEDMAN在2001年提出,已成为机器学习领域最具影响力的算法之一,尤其在结构化数据上具有显著优势。它通过构建和组合多个决策树模型来提高预测性能。GBDT通过逐步迭代的方式,构建一组弱学习器(通常为决策树),每次迭代时拟合当前模型残差的负梯度,从而逐步减少预测误差。其在分类、回归任务,尤其是结构化数据上的表现尤为突出,已成为许多机器学习任务中的基准模型。

GBDT的基本步骤为:①给予模型一定的训练集作为训练数据样本。②构建基于训练集的初始化模型,该初始化模型的输出通常选择为使损失函数最小化的常数。对于回归任务,初始化值通常是目标变量的均值;对于分类任务,初始化值则是目标类别的先验概率。③在第 m 轮迭代中,GBDT通过计算当前模型的负梯度来捕捉模型的误差信息。④在第 m 轮迭代中,GBDT通过训练一个新的决策树来拟合上一步计算得到的残差。⑤在拟合新的学习器后,GBDT将当前轮次的弱学习器与之前的模型进行加权组合,形成新的模型。⑥计算残差、拟合弱学习器、更新模型反复进行,直到模型达到预设的停止条件,如指定的迭代次数 M 或误差下降到某一阈值。⑦生成一个强大的集成模型,并对数据进行预测。

1.2 正弦余弦算法

SCA由MIRJALILI^[16]于2016年提出,是一种基于三角函数(正弦和余弦)寻优机制的元启发式全局优化算法。SCA算法受到自然界中正弦波和余弦波的启发,通过模拟这些波动的特性,来平衡全局探索与局部开发的能力。

SCA算法的核心思想是利用正弦波和余弦波在搜索空间中引导解的更新。具体步骤如下:

1)初始化。在 n 维空间中,初始化 N 个候选解的位置:

$$X_i^{(0)} = [x_1, x_2, \dots, x_n] \quad (i = 1, 2, \dots, N) \quad (1)$$

式中: $X_i^{(0)}$ 为第 i 个解的初始位置; x_n 为候选解在 n 维

度空间上的值; N 为解的数量。

2)更新规则。在每次迭代中,更新每个解的位置。SCA算法通过以下公式实现解的更新:

$$X_i^{(t+1)} = X_i^{(t)} + C \sin(Bt + \phi) \quad (p < 0.5) \quad (2)$$

$$X_i^{(t+1)} = X_{\text{best}}^{(t)} + C \cos(Bt + \phi) \quad (p > 0.5) \quad (3)$$

式中: $X_i^{(t+1)}$ 为第 i 个候选解在第 $t+1$ 次迭代中的位置; $X_{\text{best}}^{(t)}$ 为当前最优解的位置; C 和 B 是幅度与频率的参数; ϕ 为随机相位,通常在 $[0, 2]$ 随机生成; p 为 $[0, 1]$ 的随机数。

3)幅度与频率的控制。频率 B 可以是一个常数,默认值通常为1,表示波动的频率。

幅度 C 通常设置为一个递减的值,以便随着迭代次数的增加,搜索范围逐渐缩小。其可以表示为:

$$C = C_{\text{ini}}(1 - \frac{t}{T}) \quad (4)$$

式中: C_{ini} 为初始幅度; T 为最大迭代次数。

4)终止条件。当达到最大迭代次数或满足其他设定的终止准则时,算法迭代终止。

2 边坡稳定性预测混合模型的开发

2.1 数据库收集与分析

边坡稳定性受地形地貌、地质构造、地层岩性、水文条件及人为活动等多种内外部因素的综合影响。在重力和孔隙水压的作用下,边坡潜在滑动面的最大剪切力大于抗剪强度时,发生局部边坡失稳,失稳边坡结构示意图如图1所示。根据工程案例和理论分析,主要影响因素可归纳为边坡的物理力学参数、几何结构参数和水文条件、边坡状态。本研究选择了6个关键因素作为预测模型的输入,包括边坡高度(H)、边坡角(β)、容重(γ)、内聚力(C)、内摩擦角(φ)、孔隙水压系数(r_u),并以边坡稳定性作为模型输出。数据来源于文献[17-20],总共包括436个边坡案例。这些边坡案例不仅包含来源于中国、美国、加拿大、澳大利亚等的边坡工程案例,还包含部分有限元仿真案例。数据库已广泛应用于边坡稳定性的预测工作,其描述性统计结果如表1所示。




图1 失稳边坡结构示意图

Fig. 1 Schematic diagram of slope instability structure

表 1 数据库描述性统计结果

Table 1 Descriptive statistics of the database

指标	$\gamma/(\text{kN}\cdot\text{m}^{-3})$	C/kPa	$\varphi/(^{\circ})$	$\beta/(^{\circ})$	H/m	r_u
平均值	21.45	37.22	26.85	34.76	80.97	0.23
标准差	3.72	39.49	10.02	11.04	88.08	0.28
最小值	10.06	0	0	4.24	3.45	0
25 %	18.84	11.97	20.00	27.00	30.47	0
50 %	21.20	28.95	27.07	35.00	52.00	0.20
75 %	23.97	45.97	35.00	44.04	100.00	0.35
最大值	31.30	300.00	57.36	65.00	565.00	1.00
累计	436	436	436	436	436	436

绘制了各特征之间相关性和分布情况的矩阵散点分布图(如图 2 所示),定量分析特征之间的相关关

系。图 2 中每个单元表示 2 个变量之间的关系。根据边坡状态分为 2 组数据,用不同颜色(蓝色和红色)表示。同时,图 2 中显示了不同边坡状态下,相关系数的差异。其中,对角线上的是各个变量的分布直方图,2 组边坡数据有相似分布。在每个单元格中显示了 2 个特征之间的线性相关系数,其代表 2 个变量间线性关系的强度,取值为 $-1 \sim 1$,数值接近 1 或 -1 表示强相关性,接近 0 表示无线性相关。每个散点分布图中还包含 1 条趋势线,表示 2 个变量间的线性回归关系,整体斜率较小,表明这些变量间相关性较低。变量间的相关性大多为 $0.1 \sim 0.3$,可认为大部分变量是弱相关或中等相关,即这些特征之间相对独立。因此,有必要结合多种特征对边坡稳定性进行综合预测。




图 2 数据库相关矩阵散点分布图

Fig. 2 Scatter plot of the database correlation matrix

2.2 SCA-GBDT模型

本研究依托 Pycharm 软件与多个 Python 开源库进行,基于包含 436 个边坡案例的数据库,使用 GBDT 模型进行初步建模;基于五重交叉验证通过 SCA 优化 GBDT 模型的超参数,包括决策树数目($N_{estimators}$)、学习率($learning_rate$)、决策树最大深度(max_depth)、最小分离样本数($min_samples_split$);将五重交叉验证后的平均准确率作为适应度函数,在

训练集上进行多次迭代优化,获得最优超参数组合;将最优 SCA-GBDT 模型对测试集进行验证并评估。模型构建和分析的各个步骤都确保了建立的模型既科学又系统,从而能够为实际的边坡稳定性预测提供有力支持。SCA-GBDT 模型构建流程如图 3 所示。具体步骤为:

1)收集包含 436 个边坡案例的数据库,对数据库进行描述性统计和归一化处理。




图3 SCA-GBDT模型构建流程

Fig. 3 Construction process of the SCA-GBDT model

2)将数据库随机划分为训练集(80%)和测试集(20%)。

3)通过GBDT模型对训练集进行初始建模。

4)构建SCA模型,设置粒子群数量,并确定GBDT模型待优化参数及参数范围。

5)SCA模型进行迭代搜索,一重交叉验证后的平均准确率作为目标函数,记录每次迭代搜索的目标函数值。

6)满足终止迭代条件时,获得最优SCA-GBDT模型的超参数组合。

7)通过混淆矩阵以多种指标评估SCA-GBDT模型的性能,并将SCA-GBDT模型与多种模型的性能进行对比。

8)通过SHAP(SHapley Additive exPlanation,SHAP)算法分析模型特征的重要性排序。

2.3 模型评估

本研究使用了4个评估指标:准确率(A)、精确率(P)、召回率(R)和F1分数($F_{1-Score}$),来综合评估SCA-GBDT模型的性能。这些指标都是正向的,数值越高,表示模型性能越好。

准确率为正确分类的实例与实例总数之比,表示为:

$$A = \frac{TN + TP}{TP + TN + FN + FP} \quad (5)$$

式中: TN 和 TP 分别为分类正确的阴性和阳性样本的数量; FN 和 FP 分别为分类错误的阴性和阳性样本的数量。

精确率为所有预测阳性中真阳性的比例:

$$P = \frac{TP}{TP + FP} \quad (6)$$

召回率为真阳性在所有实际阳性中所占的比例:

$$R = \frac{TP}{TP + FN} \quad (7)$$

F1分数在精确率和召回率之间提供了平衡:

$$F_{1-Score} = \frac{2PR}{P + R} \quad (8)$$

4种评估指标示意图如图4所示。




图4 评估指标示意图

Fig. 4 Diagram of evaluation indicators

除上述4个指标外,ROC曲线下面积(AUC)是评估分类模型的另一个广泛使用的指标。ROC曲线从真阳性率(TPR)和假阳性率(FPR)都为零的点开始,在点(1,1)结束。模型的ROC曲线越接近图的左上角,表明 AUC 越高,模型性能越好。因此, AUC 是反映分类器整体有效性的重要指标。

$$TPR = \frac{TP}{TP + FN} \quad (9)$$

$$FPR = \frac{FP}{TP + TN} \quad (10)$$

3 结果与讨论

3.1 模型训练结果

为获得最优模型,不仅需要调整GBDT的超参数,还需要考虑SCA的参数,即种群规模。因此,SCA的种群规模分别设置为10,20,35,50,65,80和100,对GBDT进行8次训练。每次训练设置100次迭代。模型迭代训练过程适应度值变化如图5所示。




图5 SCA优化GBDT模型迭代过程

Fig. 5 Iteration process of the SCA-optimized GBDT model

从图 5 可以看出:不同种群规模的 SCA 优化的 GBDT 模型经过 100 次迭代后都是稳定的,收敛速度快,并且是一致的,这证明了智能算法的优越性。同时,不同模型收敛曲线的相似性反映了本研究提出模型的可靠性。通过对模型收敛曲线进行比较,证明了该混合模型在评估边坡稳定性方面具有有效性和优越性。此外,使用智能算法可以有效选择超参数,从而提高模型的泛化能力。这些发现强调了在边坡稳定性评估中使用混合模型和智能算法的重要性。

表 2 SCA-GBDT 模型最优参数设置

Table 2 Optimal parameter settings of the SCA-GBDT model

指标	Population size	N_estimators	learning_rate	max_depth	min_samples_split
范围	[10,100]	[1,100]	[0.001,0.5]	[0,100]	[2,50]
最优值	80	49	0.094	16	20

3.2 不同模型对比分析

本研究的主要目的是提出 SCA-GBDT 模型,并确定评估边坡稳定性的最佳模型。引入一个未优化的 GBDT 模型和 4 种经典分类模型(XGboost、Adaboost、RF、SVM)进行对比,以证明 SCA 算法在超参数选择方面的潜力及本研究提出模型的优越性。在 SCA-GBDT 模型中,使用预定义的最佳参数组合进行训练,而其他经典模型则通过网格搜索算法确定最佳参数。为了比较不同模型的性能,本研究使用了五重交叉验证,并在测试集上测试了模型的性能。5 个经典模型和 SCA-GBDT 模型的结果如表 3 所示。从表 3 可以看出:SCA-GBDT 模型在测试阶段的表现均优于其他模型,为边坡稳定性评估提供了强有力的工具。

表 3 不同模型的性能对比

Table 3 Performance comparison of different models

模型	准确率	精确率	召回率	F_1 -Score
SCA-GBDT	0.886 0	0.877	0.915	0.896
GBDT	0.829 5	0.848	0.829	0.838
Adaboost	0.829 5	0.820	0.873	0.845
XGboost	0.840 9	0.846	0.805	0.825
RF	0.829 5	0.790	0.850	0.819
SVM	0.772 7	0.829	0.723	0.773

除了使用 4 个基本的模型评估指标外,本研究还引入了 ROC 曲线、AUC 直观反映模型的性能,如图 6 所示。从图 6 可以看出:SCA-GBDT 模型的 ROC 曲线最接近左上角,AUC 最大,为 0.955,表明分类性能最佳。GBDT 模型的 AUC 为 0.942,SCA-GBDT 模型 AUC 提高了 0.013,这进一步验证了智能算法在模型优化中的作用及混合模型在评估边坡稳定性中的重要性。总体而言,引入 ROC 曲线和混淆矩阵,可以直观、全面地了解模型性能,从而有助于选择最合适的模型来评估边坡稳定性。

SCA-GBDT 模型在种群规模为 35 时,模型适应度函数值最先稳定且最小。因此,本研究中 SCA-GBDT 模型的种群规模设置为 35。利用确定的种群规模进行模型训练,并进一步调整 GBDT 模型的超参数,包括 N_estimators、learning_rate、max_depth、min_samples_split。在模型训练过程中,使用五重交叉验证来提高其泛化性能。SCA-GBDT 模型的最佳种群规模及输出的 GBDT 模型最佳参数组合如表 2 所示。




图 6 不同模型的 ROC 曲线比较

Fig. 6 ROC curve comparison of different models

3.3 混淆矩阵

混淆矩阵通过显示预测结果和实际情况之间的差异来衡量模型的准确性。本研究使用混淆矩阵分析了各种模型的性能,对角矩阵值表示预测准确数量。不同模型的混淆矩阵如图 7 所示。从图 7 可以看出:SCA-GBDT 模型的混淆矩阵显示出相对较多的对角矩阵值,表明预测值与真实值存在较高的一致性。混淆矩阵的分析进一步验证了 SCA-GBDT 模型在评估边坡稳定性方面的高性能和可靠性。综合 6 个模型的评价指标,SCA-GBDT 模型是边坡稳定性预测的最佳模型。

3.4 特征重要性分析

SHAP 是一种基于博弈论的特征重要性解释方法^[21]。其结合了 Shapley 值和加性特征模型,为机器学习模型提供一致且解释性强的特征重要性评估。这对优化模型、减少特征和深入了解数据集的突出特征具有重要意义。使用 SHAP 算法分析了 SCA-GBDT 模型中特征的重要性,结果如图 8 所示。从图 8 可以看出:参数 φ 的重要性得分最高(4.310 3),参数 C 、 β 、 γ 、 H 和 r_u 的重要性得分分别为 2.883 1、2.368 3、1.155 0、1.120 7 和 0.498 3,结果强调了参数 φ 在边坡




图7 不同模型的混淆矩阵

Fig. 7 Confusion matrix of different models

稳定性的关键作用。此外,参数 C 和 β 也具有相对高的重要性,对模型的准确性有相当大的影响。参数 r_u 虽然重要性较低,但可以提高模型的泛化性能。需要注意的是,重要性排序与QI等^[22]的研究结果有所不同,这是由于使用了不同的数据库和模型。




图8 模型特征重要性排名

Fig. 8 Importance ranking of model characteristics

未来,需进一步研究各种参数组合对模型的影响,这可以减少工作量,节省时间,并在扩展数据库时最大限度地降低经济成本。这些信息将有助于准确预测边坡稳定性,提高模型鲁棒性,从而防止过拟合并确保可靠的预测。

4 结论

1)边坡失稳的智能预测和预警对于减少滑坡和防灾减灾至关重要。本文基于正弦余弦算法优化梯度提升树的边坡稳定性预测混合模型的研究中,通过构建一个包含436个边坡案例的数据库,成功应用机器学习技术来提高边坡稳定性评估的准确性和可靠性。

2)研究结果表明,SCA-GBDT模型在多个评估指

标上均优于经典模型(GBDT、XGboost、Adaboost、RF、SVM),显示出其在边坡工程实践中的广泛应用潜力。SCA-GBDT模型测试集的准确率、精确率、召回率和 $F_{1-score}$ 值分别为0.886 0,0.877,0.915和0.896, AUC 为0.955。

3)研究强调了不同特征参数在模型构建中的关键作用, φ 的特征重要性最高;其他参数 C 、 β 、 γ 、 H 、 r_u 也对SCA-GBDT模型的构建具有显著影响。这为后续研究提供了方向,即在数据收集和模型优化过程中,需重点关注这些关键特征。

4)未来的研究可以进一步探索不同参数组合对模型性能的影响,以优化模型的鲁棒性和泛化能力。此外,扩展数据库的多样性和规模也将有助于提高模型的适用性和准确性。

5)SCA-GBDT模型为边坡稳定性预测提供了一种创新且有效的方法,具有重要的理论价值和良好的实际应用前景,符合国家对工程安全和科技创新的重视。

[参考文献]

- [1] 罗战友,杨晓军,龚晓南.基于支持向量机的边坡稳定性预测模型[J].岩石力学与工程学报,2005,24(1):144-148.
- [2] 刘春,杜俊生,王敬堃.基于灰色关联分析理论的边坡稳定性预测[J].地下空间与工程学报,2017,13(5):1 424-1 430.
- [3] LAWAL A I, HOSSEINI S, KIM M, et al. Prediction of factor of safety of slopes using stochastically modified ANN and classical methods: A rigorous statistical model selection approach[J]. Natural Hazards, 2023, 120(2): 2 035-2 056.
- [4] SHEN Y X, WU S C, CHENG H Y, et al. Uncertainty analysis method of slope safety factor based on quantile-based ensemble learning [J]. Bulletin of Engineering Geology and the Environment, 2023, 82(3): 1435.

- [5] 张金钟,孙文敬,侯俊,等.测量机器人地表位移监测系统在露天矿边坡监测的应用[J].黄金,2017,38(4):66-70.
- [6] 胡光球,贻世杰,梁新民.高程放大效应对露天采场爆破震动衰减的影响研究[J].黄金,2015,36(7):28-32.
- [7] 肖欢,刘银,何杰华,等.万铜山采区边坡监测方法的选择及应用[J].黄金,2018,39(12):67-70.
- [8] SALMASI F, JAFARI F. A simple direct method for prediction of safety factor of homogeneous finite slopes[J]. Geotechnical and Geological Engineering, 2019, 37(5): 3 949-3 959.
- [9] 吴子牛,王莎,卢欣奇.基于C#语言的ABAQUS二次开发及其在边坡稳定性计算中的应用[J].黄金,2022,43(2):61-64.
- [10] 郑志成,徐卫亚,徐飞,等.基于混合核函数PSO-LSSVM的边坡变形预测[J].岩土力学,2012,33(5):1 421-1 426.
- [11] 段志宏,伍林林.基于灰色理论与BP神经网络的边坡变形预测模型研究[J].湖南交通科技,2024,50(3):57-60.
- [12] DENG C, HU H X, ZHANG T L, et al. Rock slope stability analysis and charts based on hybrid online sequential extreme learning machine model[J]. Earth Science Informatics, 2020, 13(3): 729-746.
- [13] LIN Y, ZHOU K P, LI J L. Prediction of slope stability using four supervised learning methods[J]. IEEE Access, 2018, 6: 31 169-31 179.
- [14] AHMAD F, TANG X W, HU J L, et al. Improved prediction of slope stability under static and dynamic conditions using tree-based models[J]. Computer Modeling in Engineering & Sciences, 2023, 137(1):455-487.
- [15] HANCOCK J T, KHOSHGOFTAAR T M. CatBoost for big data: An interdisciplinary review[J]. Journal of Big Data, 2020, 7(1):94.
- [16] MIRJALILI S. SCA: A Sine Cosine Algorithm for solving optimization problems[J]. Knowledge-Based Systems, 2016, 96: 120-133.
- [17] 祝传兵.边坡稳定性分析与评价[D].昆明:昆明理工大学,2005.
- [18] KARDANI N, ZHOU A N, NAZEM M, et al. Improved prediction of slope stability using a hybrid stacking ensemble method based on finite element analysis and field data[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2021, 13(1): 188-201.
- [19] 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.
- [20] CHAKRABORTY A, GOSWAMI D. Prediction of slope stability using multiple linear regression (MLR) and artificial neural network (ANN) [J]. Arabian Journal of Geosciences, 2017, 10(17):385.
- [21] MANGALATHU S, HWANG S H, JEON J S. Failure mode and effects analysis of RC members based on machine-learning-based shapley additive explanations (SHAP) approach [J]. Engineering Structures, 2020, 219: 110927.
- [22] QI C C, TANG X L. Slope stability prediction using integrated metaheuristic and machine learning approaches: A comparative study [J]. Computers & Industrial Engineering, 2018, 118: 112-122.

Hybrid model for slope stability prediction based on SCA-GBDT

Yang Xingyu¹, Wang Ning²

(1. Zijin (Changsha) Engineering Technology Co., Ltd.;

2. School of Resources and Safety Engineering, Central South University)

Abstract: Intelligent prediction of slope stability is a critical foundation for slope governance and slope structure design. Due to the complexity and nonlinearity of slope stability assessment, various intelligent prediction models often exhibit superior performance, offering new directions for addressing slope stability challenges. This study constructs a slope stability prediction hybrid model based on the Sine Cosine Algorithm (SCA) optimized Gradient Boosting Decision Tree (GBDT). A database was established using 436 slope cases, comprising 6 parameters (slope height H , slope angle β , unit weight γ , cohesion C , internal friction angle φ , and pore water pressure coefficient r_u) along with slope stability status data. The dataset was divided into an 80 % training set and a 20 % testing set. The hyperparameters of the model were tuned by integrating 5-fold cross-validation with the Sine Cosine Algorithm (SCA). The performance of the proposed method was evaluated using accuracy, precision, recall rate, $F_{1\text{-Score}}$, and AUC . Additionally, 5 classical classification machine learning models were compared to assess their applicability and predictive capabilities for slope stability. Results demonstrate that SCA significantly enhances the performance of the GBDT model, with the SCA-GBDT model achieving accuracy, precision, recall rate, $F_{1\text{-Score}}$, and AUC of 0.886 0, 0.877, 0.915, 0.896, and 0.955, respectively. Characteristic importance analysis via the SHAP algorithm revealed that the internal friction angle has the most significant impact on prediction outcomes. The SCA-GBDT model provides a reliable method for slope stability prediction, applicable to practical slope engineering.

Keywords: slope stability; prediction model; machine learning; Sine Cosine Algorithm; Gradient Boosting Decision Tree; internal friction angle