

DOI:10.3876/j.issn.1000-1980.2023.01.019

基于改进 XGBoost 不平衡围岩超前分类方法的 隧洞工程施工仿真研究

韩峰¹, 余佳¹, 徐国鑫², 张君¹, 肖尧¹, 王晓玲¹

(1. 天津大学水利工程仿真与安全国家重点实验室, 天津 300072; 2. 陕西省引汉济渭工程建设有限公司, 陕西 西安 710302)

摘要: 为了在围岩类别不平衡的条件下实现围岩类别有效判断, 进而提高隧洞工程施工仿真准确性, 基于改进极限梯度提升(XGBoost)不平衡围岩超前分类方法进行隧洞工程施工仿真研究。采用自动邻域确定合成过采样(AND-SMOTE)方法优化围岩类别不平衡性, 并采用改进的XGBoost不平衡围岩超前分类模型进行围岩超前分类, 进而优选仿真参数, 提高仿真结果的准确性, 其中, 以模型交叉验证平均准确率为目标, 采用哈里斯鹰优化(HHO)算法自动优化XGBoost超参数, 以提高围岩分类精度。工程应用表明, 相比未改进的XGBoost不平衡、KNN、SVC等6个模型, 改进的XGBoost不平衡围岩超前分类模型分类精度更高; 考虑围岩类别不平衡性后, 改进的XGBoost不平衡围岩超前分类模型分类精度提高了8.6%; 此外, 基于围岩超前分类的隧洞工程施工仿真结果与实际进度的相对偏差相比传统仿真降低了11.3%, 更符合工程实际。

关键词: 隧洞工程施工仿真; 围岩超前分类; 类别不平衡; XGBoost模型; 哈里斯鹰优化算法; AND-SMOTE

中图分类号: TV554

文献标志码: A

文章编号: 1000-1980(2023)01-0150-08

Study on tunnel construction simulation based on advanced classification of imbalanced surrounding rock using improved XGBoost

HAN Feng¹, YU Jia¹, XU Guoxin², ZHANG Jun¹, XIAO Yao¹, WANG Xiaoling¹

(1. State Key Laboratory of Hydraulic Engineering Simulation and Safety, Tianjin University, Tianjin 300072, China;

2. Hanjiang-to-Weihe River Valley Water Diversion Project Construction Co., Ltd., Shaanxi Province, Xi'an 710302, China)

Abstract: In order to realize the effective judgment of surrounding rock classification under the condition of imbalanced surrounding rock classification and improve the simulation accuracy of tunnel construction, a study on the tunnel construction simulation is carried out based on the advanced classification of imbalanced surrounding rock with improved eXtreme Gradient Boosting (XGBoost). The Automatic Neighborhood size Determination-SMOTE (AND-SMOTE) method is used to optimize the class imbalance of surrounding rock, and the improved XGBoost model is used for advanced classification of surrounding rock, and then the simulation parameters are optimized, which improved the accuracy of tunnel construction simulation. In order to improve the accuracy of surrounding rock classification, the Harris Hawks Optimization (HHO) algorithm is used to automatically optimize the hyperparameters of XGBoost ensemble classifier. The engineering application shows that the improved XGBoost model has higher classification accuracy than the unimproved XGBoost, KNN, SVC and other 6 models. The classification accuracy of the improved XGBoost model is improved by 8.6% after considering the class imbalance of surrounding rock. In addition, the relative deviation between the results of tunnel construction simulation based on the advanced classification of surrounding rock and the actual progress is reduced by 11.3% compared with the traditional simulation, which is more in line with the engineering reality.

Key words: tunnel construction simulation; advanced classification of surrounding rock; class imbalance; XGBoost; Harris Hawks Optimization algorithm; AND-SMOTE

围岩类别是影响隧洞工程施工的关键因素。根据 SL 378—2007《水工建筑物地下开挖工程施工规范》,

基金项目: 国家自然科学基金青年科学基金(52009090); 天津市自然科学基金(19JCYBJC22600)

作者简介: 韩峰(1997—), 男, 硕士研究生, 主要从事地下工程施工仿真研究。E-mail: hanfeng0113@tju.edu.cn

通信作者: 余佳(1992—), 女, 助理研究员, 博士, 主要从事水电地下工程施工智能仿真与风险分析研究。E-mail: yujia@tju.edu.cn

引用本文: 韩峰, 余佳, 徐国鑫, 等. 基于改进 XGBoost 不平衡围岩超前分类方法的隧洞工程施工仿真研究[J]. 河海大学学报(自然科学版), 2023, 51(1): 150-157.

HAN Feng, YU Jia, XU Guoxin, et al. Study on tunnel construction simulation based on advanced classification of imbalanced surrounding rock using improved XGBoost[J]. Journal of Hohai University(Natural Sciences), 2023, 51(1): 150-157.

I、II类围岩质量好,自稳能力强,相比于IV、V类围岩,开挖循环进尺取值大,支护工艺较简单;另外爆破参数、清底安装活动等也在一定程度上受到围岩类别的影响。实际工程中围岩类别的分布呈现不平衡的特点^[14],为了实现隧洞工程施工进度的准确预测和施工组织的合理安排,有必要考虑围岩类别不平衡的特点,对开挖前方围岩进行超前分类,进而开展隧洞工程施工仿真研究。

近年来,国内外学者考虑施工过程各类因素的影响,致力于提出更符合工程实际的地下工程施工仿真方法。钟登华等^[5]通过细化出渣过程并考虑运输机械故障,提出了基于故障预测的地下洞室群施工仿真方法;Yu等^[6-7]从地质条件、施工活动等方面量化施工过程风险,提出了考虑风险影响的隧洞工程施工仿真方法;张玉贤等^[8]通过分析围岩稳定性等结构安全问题对隧洞工程施工进度的制约机制,构建了相应的施工仿真模型;Kim等^[9]综合考虑成本、工期及硬岩掘进风险,提出了能够适应动态规划与反馈控制的隧洞工程施工进度仿真方法;Kim等^[10]对不同地质条件下的支护参数进行细化,提出了改进的钻爆仿真方法。上述研究虽然在隧洞工程施工仿真过程中考虑了机械故障、地质风险、结构安全等因素的影响,但是围岩类别均依据初期地质勘探结果确定,未能准确反映真实的地质条件;Bi等^[11-12]采用马尔可夫预测模型,基于已揭露围岩性质建立围岩转移概率矩阵,预测未开挖洞段各类围岩出现的概率,进而选择相应的仿真参数,然而该方法围岩类别预测的准确性很大程度依赖于对已揭露围岩的掌握程度。

超前地质预报具有能够直接获取掌子面前方围岩特性指标的优势,已有学者基于超前地质预报数据,采用人工神经网络^[13]、支持向量机^[14-15]、贝叶斯网络^[16]等方法进行围岩超前分类研究。然而上述研究方法多为单一弱分类器,同时忽略了隧洞围岩类别存在的不平衡特性,易导致分类器学习倾向于多数类,分类精度较低。

集成学习算法通过基学习器组合能够进一步提高模型的预测精度^[17]。其中极限梯度提升(eXtreme gradient boosting, XGBoost)是基于梯度树增强(gradient boosting decision tree, GBDT)算法改进的高效集成学习算法^[18],具有正则化、并行处理运算、内置交叉验证和高灵活性等优势,目前在分类问题中应用广泛^[19]。然而, XGBoost 算法中基学习器数目、学习率、树最大深度等超参数能否合理设置是影响模型性能的关键。人工调参的方式需要大量先验知识,存在耗时费力、难以确定最优超参数组合的不足^[20-21]。

针对上述问题,本文基于 TSP 超前地质预报数据,考虑围岩类别的不平衡性,采用改进的 XGBoost 不平衡围岩超前分类模型进行围岩超前分类,进而优选仿真参数并最终进行隧洞工程施工仿真分析。其中关键在于解决两个问题:①优化围岩类别的不平衡性,采用自动邻域确定合成过采样(automatic neighborhood size determination-SMOTE, AND-SMOTE)方法,通过对少数类围岩样本进行合成过采样,优化围岩类别的不平衡性。②提升围岩超前分类的精度,以分类器交叉验证平均准确率为目标,采用全局搜索能力较强的哈里斯鹰优化(Harris hawks optimization, HHO)算法对 XGBoost 不平衡围岩超前分类模型学习率、弱分类器数、树最大深度等超参数进行寻优,自动确定最优超参数组合,最大程度发挥模型分类性能,提高分类精度。

1 仿真方法

1.1 基于 AND-SMOTE 合成过采样的围岩类别不平衡性优化方法

目前国内外典型的隧洞围岩分级方法 BQ 法、RMR 法、Q 值法等主要从岩石坚硬程度、岩体完整性及赋存环境三方面进行围岩类别评估。本文采用横波速度、纵波速度、波速比、动态杨氏模量、泊松比和地下水情况 6 个指标作为围岩分类指标,其中动态杨氏模量、泊松比可表征岩石坚硬程度,纵波速度可表征岩体完整性,横波速度、波速比、地下水情况可表征赋存环境^[22]。横波速度、纵波速度、波速比、动态杨氏模量、泊松比可由 TSP 超前地质预报直接解译得到,而地下水情况基于红外探测超前地质预报结果进行量化。

AND-SMOTE 方法是 Yun 等^[23]提出的对 SMOTE 合成过采样方法的改进。采用自动邻域大小确定(AND)的方法自动确定近邻数,并通过定义和检查近邻数变化过程中少数类邻域多数类样本数量的变化速率,选择速率突变处对应的近邻数进行少数类围岩样本合成,确保合成样本的安全性,保持少数类围岩样本的原始分布,从而帮助 SMOTE 获得最佳性能。

1.2 基于 HHO 算法的 XGBoost 不平衡围岩超前分类模型

1.2.1 XGBoost 算法

假定 n 个 m 维特征围岩指标的样本训练集 $D = \{(x_i, y_i) | i = 1, 2, \dots, n\}$, $x_i \in R_m$, 其中 R_m 表示 m 维向量空间, x_i 表示围岩特征(横波速度、纵波速度、波速比、动态杨氏模量、泊松比及地下水情况), y_i 表示围岩类

别,将多个 CART 决策树(围岩基分类器)的预测结果进行综合,得到最终的围岩类别:

$$\bar{y}_i = \sum_{k=1}^K f_k(x_i) \quad (f_k \in F) \quad (1)$$

式中: F 为所有可能的 CART 决策树的集合; f_k 为其中的一棵树; K 为树的个数。XGBoost 不平衡围岩超前分类模型的目标为学习该 K 棵树,使得如式(2)所示的目标函数最小:

$$L^{(t)} = \sum_{i=1}^n q(y_i, \bar{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (2)$$

式中: q 为预估值与真值之间的损失; Ω 为正则化用于设置决策树的惩罚,它可以防止过拟合。

XGBoost 不平衡围岩超前分类模型建立过程需要确定弱分类器数、树最大深度、最小样本权重、正则化参数、惩罚项参数等超参数,能否找到最优超参数组合对于 XGBoost 不平衡围岩超前分类模型能否发挥最佳分类效果至关重要。人工调参需要大量先验知识,不仅耗时费力,而且难以获得最佳的超参数组合。本文采用 HHO 算法对上述超参数进行自动寻优。

1.2.2 HHO 算法

HHO 算法是 Heidari 等^[24]于 2019 年提出的基于群体的算法之一,通过模仿哈里斯鹰的群体狩猎行为,采用突袭围捕策略实现全局优化。相关研究表明,与成熟的元启发式算法相比,该优化算法具有较强的全局搜索能力,且需调节的参数较少,具有一定的竞争性。

HHO 算法以猎物的逃逸能量 E 为判别依据,将哈里斯鹰种群迭代分为两个阶段。

a. 搜索阶段。 $|E| \geq 1$, 认为猎物体力充沛且哈里斯鹰距离猎物较远,哈里斯鹰尝试确定猎物位置,此时哈里斯鹰在数学模型中的位置指离猎物最近的位置。

b. 围捕阶段。 $|E| < 1$, 进一步根据逃逸能量是否大于 0.5 以及猎物是否能逃脱(逃脱概率 $\lambda \geq 0.5$ 即认为能逃脱)将围捕阶段分为 4 种围捕策略:软围攻、硬围攻、快速俯冲式软围攻及快速俯冲式硬围攻,各围捕策略设定了不同的位置更新方式以模拟围捕过程^[25]。

1.2.3 基于 HHO 算法的 XGBoost 不平衡围岩超前分类模型建立流程

采用 HHO 算法对 XGBoost 不平衡围岩超前分类模型弱分类器数、学习率、树最大深度、最小样本权重、采样比例、特征比例、 L_1 正则化参数、 L_2 正则化参数和惩罚项参数共 9 个关键超参数进行寻优,具体建模流程见图 1。

基于 HHO 算法的 XGBoost 不平衡围岩超前分类(HHO-XGBoost)模型建立具体步骤如下。

步骤 1 以 7:3 将 AND-SMOTE 方法合成过采样不平衡性优化后的围岩分类数据集随机划分为训练集及测试集。

步骤 2 初始化 HHO 模型参数,设置超参数取值范围,生成初始哈里斯鹰种群,种群中每一只哈里斯鹰的位置为 9 维向量,代表 XGBoost 不平衡围岩超前分类模型待优化的弱学习器数、学习率等 9 个超参数。

考虑到交叉验证能够实现模型对训练集的充分学习,同时提高模型的泛化性能,因此,采用模型交叉验证的平均准确率作为 HHO 模型优化 XGBoost 不平衡围岩超前分类模型超参数的适应度函数,记为 $C(CV_score)$:

$$C = \frac{1}{L} \sum_{l=1}^L \frac{n_l}{n} \quad (3)$$

式中: L 为交叉验证折数; n 为验证集样本数; n_l 为第 l 次交叉时模型正确分类的样本数。

步骤 3 比较适应度值,调整哈里斯鹰种群的个体位置并更新猎物的位置与 E 。根据突袭围捕策略更新种群位置,遍历每个个体的适应度值,找出最优适应度值(适应度值越

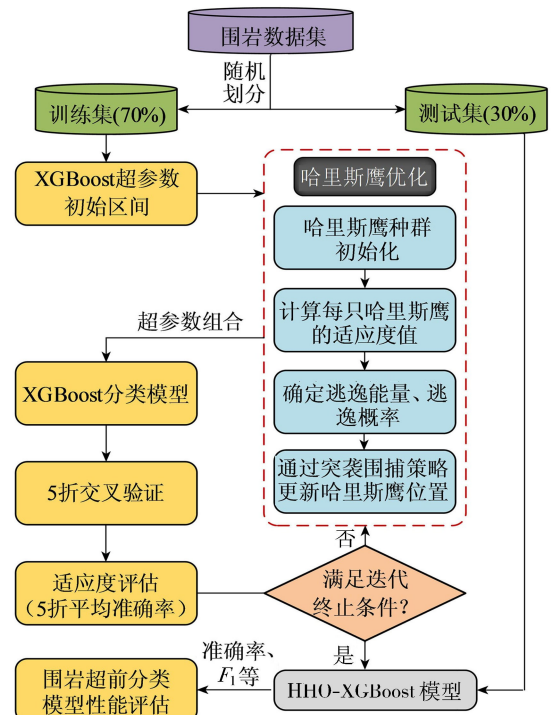


图 1 建模流程

Fig. 1 Modeling process

高代表适应度值越优),与猎物的适应度值进行比较,若优于猎物的适应度值,则取代猎物位置。

步骤 4 终止条件判断。判断当前迭代次数 t 是否大于最大迭代次数 T ,若满足则输出当前最优解,否则继续迭代搜索。

步骤 5 基于寻优所得最优超参数组合,建立 HOO 算法优化的 XGBoost 不平衡围岩超前分类模型,进而采用测试集对模型进行性能评估。

1.3 基于围岩超前分类的隧洞工程施工仿真 CYCLONE 模型

围岩类别是围岩基本稳定状况的客观反映,是影响隧洞工程施工参数选择的关键因素。在确定施工循环进尺时,围岩分类等级越高,代表其稳定性越好,循环进尺越大;在爆破设计中,不同类别围岩对于爆破的反馈程度不同,因此针对不同类别的围岩,爆破设计的掏槽形式、装药量、炮孔布置均有差异,以最大限度提高爆破效率,减少震动破坏;在支护设计中,一般根据围岩类别、断面尺寸、开挖方法确定支护方式,对于自稳能力较强的围岩,如 I、II 类围岩,可适当降低支护要求;此外,围岩质量的好坏将直接影响施工安全,因此不同类别围岩的安全处理、清底等工序要求不同,如对于质量较差的围岩则要求更严格,工序时间更长。综上所述,围岩类别对隧洞工程施工的开挖、支护等多个工序均有影响,直接指导隧洞循环进尺、爆破参数、支护参数等施工参数的选取。

通过及时获取隧洞掌子面前方一定范围内未开挖洞段的超前地质预报成果,提取横波速度、纵波速度、波速比、泊松比、动态杨氏模量和地下水情况 6 个指标,并基于不平衡数据条件建立 HHO-XGBoost 模型以实现围岩类别的预测。根据预测结果优选对应的爆破参数、循环进尺、安全处理时间等施工参数,进而建立基于围岩超前分类的隧洞工程施工仿真 CYCLONE 模型,如图 2 所示。

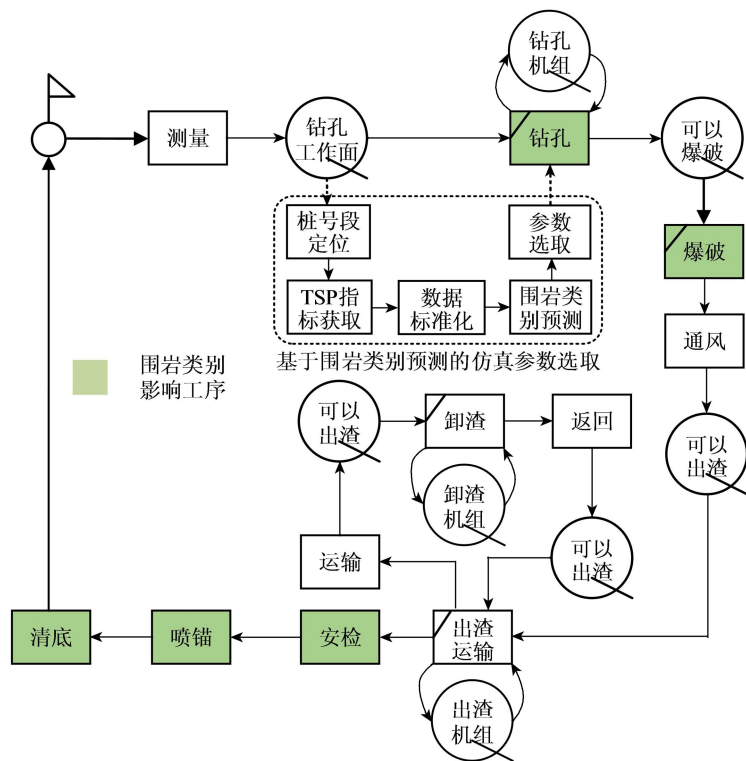


图 2 CYCLONE 模型
Fig. 2 CYCLONE model

2 工程实例

以我国某引水隧洞工程施工支洞为研究对象,开展基于改进 XGBoost 不平衡围岩超前分类方法的隧洞工程施工仿真应用研究。该隧洞工程通过地层主要为印支期花岗岩,围岩类别包括 II、III、IV 类,其中 II 类居多,围岩类别存在不平衡性。

2.1 基于 AND-SMOTE 方法的隧洞围岩类别不平衡性优化

通过工程现场 TSP203PLUS 系统超前地质预报实测成果“前方围岩物性图”获取已开挖洞段的横波速度、纵波速度、波速比、泊松比、动态杨氏模量 5 项围岩指标定量值。同时对红外探测结果给定的五类地下水级别,即干燥、渗滴水、线状出水、股状出水、集中涌水,在不同区间内取值以实现量化^[26],干燥取[0,0.2),渗滴水取(0.2,0.4],以此类推。上述 6 项指标与各桩号处对应的实际围岩类别共同构成围岩分类初始数据集。

在初始数据集中,少数类 III、IV 类围岩与多数类 II 类围岩不平衡率 IR 值达 6.4,数据集呈现明显的不平衡特性。采用 AND-SMOTE 方法对数据集进行少数类合成,在保证数据集原始分布的前提下扩充少数类 III、IV 类围岩样本,直至少数类围岩样本量与多数类样本量一致,以实现数据集平衡性优化,从而建立最终围岩超前分类数据集。AND-SMOTE 方法采样前后各类样本赋值及分布情况(以横波速度与泊松比指标为例绘制)如图 3 所示。

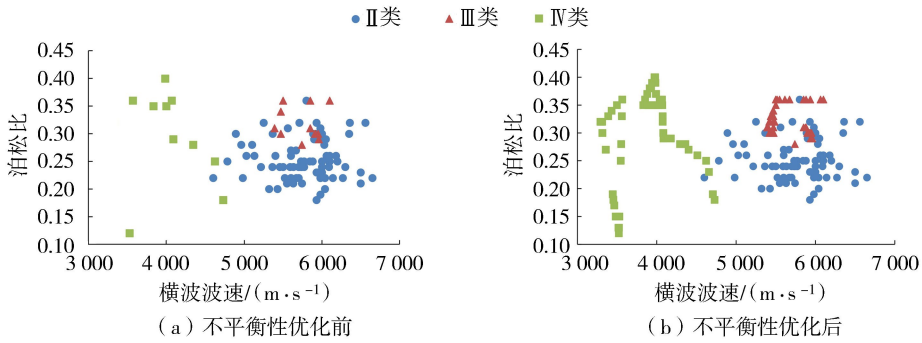


图 3 不平衡性优化前后各类围岩样本分布

Fig.3 Sample distribution before and after class imbalance optimization

2.2 HHO-XGBoost 模型的隧洞围岩超前分类

将经过不平衡优化的数据集以 7 : 3 随机划分为训练集与测试集。以训练集 5 折交叉验证的平均准确率 CV_score 为目标,采用 HHO 模型对 XGBoost 不平衡围岩超前分类模型学习率、树最大深度、弱学习器数等 9 个超参数进行寻优,HHO 寻优参数最大迭代次数、种群数量及 levy 飞行参数分别设置为 300、10 和 0.01,寻优所得最优超参数为:弱学习器数 240、树最大深度 4、学习率 1、最小样本权重 1.60、采样比例 0.56、特征比例 0.50、 L_1 正则化参数 0.22、 L_2 正则化参数 2.46、惩罚项参数 0.07。该超参数组合下模型对于训练集的交叉验证平均准确率为 97.5%,进一步通过测试集对所得模型进行性能评估,得到混淆矩阵如图 4 所示。




图 4 围岩分类模型混淆矩阵

Fig.4 Confusion matrix of surrounding rock classification model

由图 4 可知,70 项测试样本中仅有 3 项被错分,总体分类准确率达到 95.7%,具体测试集分类性能评价结果如表 1 所示,其中, F_1 为精确度和召回率的调和平均数。进一步采用已建立的 XGBoost 不平衡围岩超前分类模型对该工程斜 16+10 ~ 斜 22+75 桩号段的围岩类别进行预测,各类围岩平均准确率达 95.5%;而该桩号段的设计围岩类别划分尺度粗,平均准确率仅为 32.5%,具体结果如表 2 所示。

表 1 模型分类性能评估结果

Table 1 Evaluation results of model classification performance

类别	精确度	召回率	F_1	数据量/个
II类	0.950	0.905	0.927	21
III类	0.920	0.958	0.939	24
IV类	1.000	1.000	1.000	25
加权平均值	0.958	0.957	0.957	70

表 2 围岩类别预测结果对比

Table 2 Comparison of prediction results of surrounding rock classifications

围岩类别	实际围岩长度/m	预测围岩		设计围岩	
		准确长度/m	准确率/%	准确长度/m	准确率/%
II类	339	316	93.2	189	55.8
III类	251	244	97.2	27	10.8
IV类	75	75	100.0	0	0
合计	665	635		216	

设计围岩类别、预测围岩类别、实际围岩类别分布如图 5 所示。




图 5 围岩类别分布

Fig.5 Distribution of surrounding rock classification

2.3 基于围岩超前分类的隧洞工程施工仿真分析

基于预测所得围岩类别,根据该工程施工组织设计选取对应的循环进尺、爆破参数等隧洞工程施工仿真参数,围岩类别与仿真参数对应关系如表 3 所示。

表 3 围岩类别-仿真参数对应关系

Table 3 Corresponding relationship between surrounding rock classification and simulation parameters

围岩类别	进尺/m	孔距/m	排距/m	测量放线时间/min	装药爆破时间/min	安全处理时间/min	清底安装时间/min
II	3.0	0.5	0.7	20	50	75	20
III	2.5	0.4	0.7	20	50	90	40
IV	1.0	0.35	0.4	20	60	120	60

采用基于预测围岩选取的仿真参数进行该工程斜 16+10 ~ 斜 22+75 桩号段进度仿真计算,得到该桩号段平均仿真工期为 137 d;采用设计围岩类别的传统仿真方法,得到该桩号段的平均仿真工期为 120 d;该桩号段的实际工期为 150 d。传统仿真方法的工期与实际工期相对误差达 20%,而本文提出的基于围岩超前分类的隧洞工程仿真方法所得工期与实际工期的相对误差仅为 8.7%,准确率提高了 11.3%,因此本文提出的仿真方法相比于传统仿真方法更加符合工程实际。

2.4 对比分析

2.4.1 围岩分类模型性能

根据分类结果,HHO-XGBoost 模型表现出了优越的分类性能,从如下两个方面进行性能对比。

a. HHO-XGBoost 模型在不平衡性优化前后两种数据条件下的分类性能对比。由图 6 可知,基于 AND-SMOTE 方法合成过采样的围岩类别不平衡性优化对于分类器性能的改进比较显著。经不平衡数据优化后的数据集训练得到的 HHO-XGBoost 模型的性能明显优于由原始数据集训练得到的 HHO-XGBoost 模型,CV_score、 F_1 、准确率、精确度及召回率分别提升 8.9%、7.6%、8.6%、5.8%及 8.6%。

b. 在围岩类别不平衡性优化后的数据条件下,HHO-XGBoost 模型与常规 XGBoost、KNN、决策树、随机森林等 6 个传统分类器分类性能对比。对比结果如图 7 所示,在 AND-SMOTE 方法不平衡性优化的数据条件下,HHO-XGBoost 模型相比于未优化 XGBoost 以及 KNN、决策树、随机森林等传统分类模型,CV_score、 F_1 、准确率、精确度及召回率 6 个指标的精度均有不同程度的提高,其中,相比于常规分类模型,各分类指标所能达到的最优值分别提高 1.3%、2.9%、2.8%、1.7%及 2.8%,证明了所提出的分类模型具有一定优越性。此外,与未进行超参数寻优的常规 XGBoost 模型相比,HHO-XGBoost 模型的 CV_score、 F_1 、准确率、精确度及召回率分别提高了 2.5%、3.0%、2.8%、2.8%及 2.8%,证明了超参数优化的有效性。

2.4.2 施工仿真结果对比

为了进一步验证基于围岩超前分类仿真方法的有效性与优越性,将基于围岩超前分类的仿真进度、设计围岩的传统仿真进度及实际施工进度进行对比。如图 8 所示,在施工过程的各个阶段,基于围岩超前分类的仿真方法所得的仿真结果均更贴近实际。

取典型桩号斜 18+81、斜 19+97、斜 20+80、斜 21+68 及斜 22+48 处的进度情况进行对比,在各桩号处,基于设计围岩类别的传统仿真工期及基于预测围岩类别的仿真工期均晚于实际工期,前者与实际工期的平均偏差为 29 d,而后者平均偏差仅为 11 d,证明了 HHO-XGBoost 模型仿真方法的可行性与优越性。




图 6 HHO-XGBoost 模型分类性能对比

Fig. 6 Comparison of HHO-XGBoost classification performance

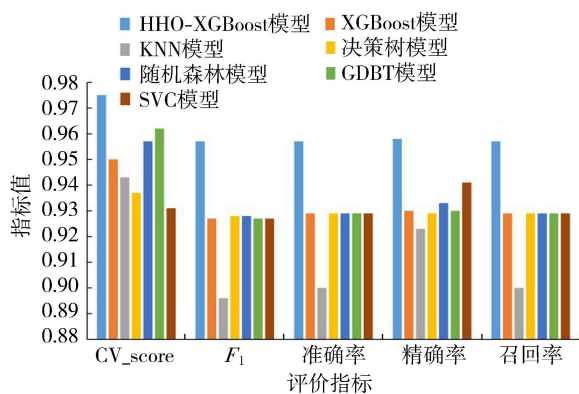


图 7 不平衡性优化后各模型性能对比

Fig. 7 Performance comparison of different models after imbalance optimization

3 结 论

a. 针对隧洞工程围岩类别存在的不平衡特性,采用 AND-SMOTE 方法对少数类围岩样本进行合成过采样,在保留样本原始分布的同时有效优化了围岩类别的不平衡性。

b. 建立了 HHO-XGBoost 模型。以交叉验证平均准确率为目标,采用 HHO 算法对学习率、弱分类器数、树最大深度等超参数进行自动寻优,有效提高了模型的分类精度。

c. 基于围岩超前分类结果,优选循环进尺、爆破参数等施工仿真参数,进而实现基于围岩超前分类的隧洞工程施工仿真。

d. 将所提方法应用于某隧洞工程,在对围岩类别不平衡性进行优化的基础上,采用 XGBoost 不平衡围岩超前分类模型对围岩类别进行预测,进而优选施工仿真参数,开展施工仿真分析。进一步从 XGBoost 不平衡围岩超前分类模型性能以及施工仿真结果两个方面进行对比分析,结果表明,围岩类别不平衡性的优化、HHO-XGBoost 模型均有效提高了围岩超前分类精度;此外基于围岩超前分类的仿真结果与实际进度的相对偏差相比于传统仿真降低了 11.3%,更符合工程实际,证明了所提仿真方法的优越性。

参考文献:

- [1] ZHU Mengqi, GUTIERREZ M, ZHU Hehua, et al. Performance Evaluation Indicator (PEI): a new paradigm to evaluate the competence of machine learning classifiers in predicting rockmass conditions[J]. *Advanced Engineering Informatics*, 2021, 47: 101232.
- [2] LIU Quansheng, WANG Xinyu, HUANG Xing, et al. Prediction model of rock mass class using classification and regression tree integrated AdaBoost algorithm based on TBM driving data[J]. *Tunnelling and Underground Space Technology*, 2020, 106: 103595.
- [3] HOU Shaokang, LIU Yaoru, YANG Qiang. Real-time prediction of rock mass classification based on TBM operation big data and stacking technique of ensemble learning[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2022, 14(1): 123-143.
- [4] 陈张华, 朱其志, 吕超洋, 等. 蟠龙抽水蓄能电站洞室围岩三轴试验及本构模型[J]. *河海大学学报(自然科学版)*, 2022, 50(5): 105-110. (CHEN Zhanghua, ZHU Qizhi, LYU Chaoyang, et al. Triaxial compression test and constitutive model of surrounding rock of tunnels in Panlong Pumped-Storage Power Station[J]. *Journal of Hohai University (Natural Sciences)*, 2022, 50(5): 105-110. (in Chinese))
- [5] 钟登华, 林瀚文, 吴斌平, 等. 基于 M5P-SVR 故障预测的地下洞室施工仿真[J]. *水力发电学报*, 2019, 38(4): 199-212. (ZHONG Denghua, LIN Hanwen, WU Binping, et al. Simulations of underground cavern construction based on M5P-SVR failure prediction[J]. *Journal of Hydroelectric Engineering*, 2019, 38(4): 199-212. (in Chinese))
- [6] YU Jia, ZHONG Denghua, REN Binyu, et al. Probabilistic risk analysis of diversion tunnel construction simulation[J]. *Computer-aided Civil and Infrastructure Engineering*, 2017, 32(9): 748-771.
- [7] 余佳, 焦铮, 苏哲, 等. 考虑风险因素影响的引水隧洞施工方案优选[J]. *河海大学学报(自然科学版)*, 2021, 49(2): 155-161. (YU Jia, JIAO Zheng, SU Zhe, et al. Construction scheme optimization of diversion tunnel considering influence of risk factors[J]. *Journal of Hohai University (Natural Sciences)*, 2021, 49(2): 155-161. (in Chinese))
- [8] 张玉贤, 张继勋, 任旭华, 等. 基于结构安全的水工隧洞施工仿真系统研究[J]. *水资源与水工程学报*, 2020, 31(5): 149-156. (ZHANG Yuxian, ZHANG Jixun, REN Xuhua, et al. Simulations of hydraulic tunnel construction based on the concept of structural safety[J]. *Journal of Water Resources & Water Engineering*, 2020, 31(5): 149-156. (in Chinese))
- [9] KIM J I, FISCHER M, KAM C. Generation and evaluation of excavation schedules for hard rock tunnels in preconstruction and construction[J]. *Automation in Construction*, 2018, 96: 378-397.
- [10] KIM Y, LEE S S. A study of the effects of geological conditions on Korean tunnel construction time using the updated NTNU drill and blast prediction model[J]. *Applied Sciences*, 2021, 11(21): 10096.
- [11] BI Lei, REN Binyu, ZHONG Denghua, et al. Real-time construction schedule analysis of long-distance diversion tunnels based on lithological predictions using a Markov process[J]. *Journal of Construction Engineering and Management*, 2015, 141(2): 04014076.

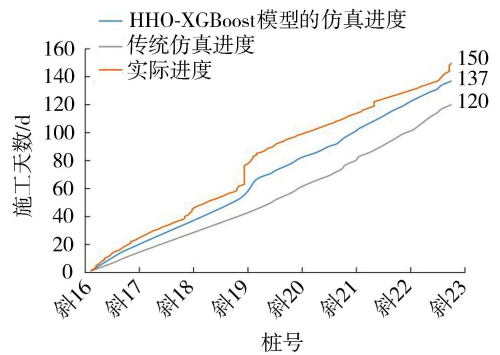


图8 累计进尺对比

Fig. 8 Comparison of cumulative footage

- [12] LIU Donghai, XUAN Peng, LI Shuai, et al. Schedule risk analysis for TBM tunneling based on adaptive cyclone simulation in a geologic uncertainty aware context[J]. *Journal of Computing in Civil Engineering*, 2015, 29(6):04014103.
- [13] 张峰瑞, 姜谔男, 赵亮, 等. 基于 DE-BP 模型隧道围岩的动态分级[J]. *沈阳工业大学学报*, 2021, 43(1):105-112. (ZHANG Fengrui, JIANG Annan, ZHAO Liang, et al. Dynamic classification of tunnel surrounding rock based on DE-BP model[J]. *Journal of Shenyang University of Technology*, 2021, 43(1):105-112. (in Chinese))
- [14] 邱道宏, 李术才, 张乐文, 等. 基于 TSP203 系统和 GA-SVM 的围岩超前分类预测[J]. *岩石力学与工程学报*, 2010, 29(增刊1):3221-3226. (QIU Daohong, LI Shucui, ZHANG Lewen, et al. Predication of surrounding rock classification in advance based on TSP203 system and GA-SVM[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2010, 29(Sup1):3221-3226. (in Chinese))
- [15] 郑帅, 姜谔男, 张峰瑞, 等. 基于机器学习与可靠度算法的围岩动态分级方法及其工程应用[J]. *岩土力学*, 2019, 40(增刊1):308-318. (ZHENG Shuai, JIANG Annan, ZHANG Fengrui, et al. Dynamic classification method of surrounding rock and its engineering application based on machine learning and reliability algorithm[J]. *Rock and Soil Mechanics*, 2019, 40(Sup1):308-318. (in Chinese))
- [16] 吕擎峰, 赵本海, 潘松杰, 等. 基于 TSP 和 PCA-Bayes 法的隧道围岩分级[J]. *地下空间与工程学报*, 2020, 16(1):80-86. (LYU Qingfeng, ZHAO Benhai, PAN Songjie, et al. Classification of tunnel surrounding rock based on TSP system and PCA-bayes discriminant method[J]. *Chinese Journal of Underground Space and Engineering*, 2020, 16(1):80-86. (in Chinese))
- [17] 沈晖华, 时健, 徐佳丽, 等. 基于 Stacking 集成机器学习的波浪预报[J]. *河海大学学报(自然科学版)*, 2020, 48(4):354-358. (SHEN Huihua, SHI Jian, XU Jiali, et al. Wave forecasting algorithm with stacking ensemble machine learning method[J]. *Journal of Hohai University (Natural Sciences)*, 2020, 48(4):354-358. (in Chinese))
- [18] CHEN Tianqi, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//*Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2016:785-794.
- [19] CAN R, KOCAMAN S, GOKCEOGLU C. A comprehensive assessment of XGBoost algorithm for landslide susceptibility mapping in the upper basin of Ataturk Dam, Turkey[J]. *Applied Sciences*, 2021, 11(11):4993.
- [20] 李孝全, 黄超, 徐晨洋, 等. 基于改进 PSO-LSSVM 和蒙特卡洛法的电力系统可靠性评估[J]. *河海大学学报(自然科学版)*, 2016, 44(5):458-464. (LI Xiaoquan, HUANG Chao, XU Chenyang, et al. Reliability evaluation of power system based on improved PSO-LSSVM and Monte Carlo simulation[J]. *Journal of Hohai University (Natural Sciences)*, 2016, 44(5):458-464. (in Chinese))
- [21] 邓韶辉, 王晓玲, 石祖智, 等. 基于 FIG 和 GWO-SVM 的灌浆功率时序预测[J]. *河海大学学报(自然科学版)*, 2020, 48(5):426-432. (DENG Shaohui, WANG Xiaoling, SHI Zuzhi, et al. Prediction of grouting power time series based on FIG and GWO-SVM[J]. *Journal of Hohai University (Natural Sciences)*, 2020, 48(5):426-432. (in Chinese))
- [22] 韩永琦. 用 TSP 预报数据划分铁路隧道围岩级别[J]. *铁道工程学报*, 2017, 34(2):71-75. (HAN Yongqi. Research on the railway tunnel surrounding rock grade using TSP prediction data[J]. *Journal of Railway Engineering Societ*, 2017, 34(2):71-75. (in Chinese))
- [23] YUN J, HA J, LEE J S. Automatic determination of neighborhood size in SMOTE[C]//*Proceedings of the 10th International Conference on Ubiquitous Information Management and Communication*. New York: ACM, 2016:1-8.
- [24] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris hawks optimization: algorithm and applications[J]. *Future generation computer systems*, 2019, 97:849-872.
- [25] ISMAEL O M, QASIM O S, ALGAMAL Z Y. Improving Harris Hawks Optimization Algorithm for hyperparameters estimation and feature selection in v-support vector regression based on opposition-based learning[J]. *Journal of Chemometrics*, 2020, 34(11): e3311.
- [26] BU Lin, LI Shucui, SHI Shaoshuai, et al. A new advance classification method for surrounding rock in tunnels based on the set-pair analysis and tunnel seismic prediction system[J]. *Geotechnical and Geological Engineering*, 2018, 36(4):2403-2413.