

DOI:10.3969/j.issn.1003-5060.2026.08.013

基于集成学习的矿山巷道锚杆安全系数预测

袁海平¹, 潘璐阳¹, 李恒喆¹, 朱传奇², 倪斌¹

(1. 合肥工业大学 土木与水利工程学院, 安徽 合肥 230009; 2. 深部煤矿采动响应与灾害防控国家重点实验室, 安徽 淮南 232001)

摘要:稳定的巷道锚网支护是矿山安全、高效开采的重要保障,传统设计方法常存在过度支护的问题。为合理地确定锚网支护参数,经济有效地实现锚网支护设计,定量地预测岩巷安全性,文章采用 Hoek-Brown 强度准则中地质强度指标(geological strength index,GSI)法将矿山巷道围岩等级进行精细化划分,对各围岩等级下的不同锚网支护方案开展数值分析,获取多组锚杆应力数据以建立矿山巷道锚杆安全系数数据库。基于数据库利用随机森林(random forest,RF)、极限梯度提升回归树(eXtreme gradient boosting,XGBoost)和轻量级梯度提升机(light gradient boosting machine,LightGBM)这3种集成算法建立预测模型,使用贝叶斯优化算法(Bayesian optimization algorithm,BOA)对各模型进行参数寻优优化,同时采用几种单一学习器进行预测精度对比,最后进行数据特征值重要度分析。结果表明:集成学习比单一学习器预测精度更高,其中 BOA-LightGBM 模型训练时间最短,预测精度最高,可作为岩巷支护体系智能决策的优选算法;各参数对岩巷锚杆安全系数的影响不同,其中围岩等级是影响最大的因素。该研究为矿山巷道锚网支护设计优化和岩巷安全性预测提供新的思路,以期提高矿山的经济效益。

关键词:矿山巷道;Hoek-Brown 强度准则;锚网支护;集成学习;贝叶斯优化算法(BOA);安全系数

中图分类号:TD353

文献标志码:A

文章编号:1003-5060(2026)08-1089-10

Safety factor prediction of mine roadway bolts based on ensemble learning

YUAN Haiping¹, PAN Luyang¹, LI Hengzhe¹, ZHU Chuanqi², NI Bin¹

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China; 2. State Key Laboratory of Mining Response and Disaster Prevention in Deep Coal Mines, Huainan 232001, China)

Abstract: The stable anchor network support of roadways signifies an important guarantee for safe and efficient exploitation of mine, while the traditional design methods often have the problem of excessive support. In order to reasonably determine the anchor network support parameters, economically and effectively realize the anchor network support design, and quantitatively predict the safety of rock roadway, this paper adopts the geological strength index(GSI) method based on the Hoek-Brown strength criterion to divide the surrounding rock grades of mine roadways, and carries out the numerical analysis of different anchor network support schemes under the condition of each surrounding rock grade. Multiple groups of rock bolt stress data have been obtained to establish the safety factor database of mine roadway rock bolts. In addition, a prediction model based on three ensemble algorithms has been proposed: random forest(RF), eXtreme gradient boosting(XGBoost) and light gradient boosting machine(LightGBM). The hyperparameters of each model have been searched and optimized by the Bayesian optimization algorithm(BOA). Several single learners were employed to compare the prediction accuracy. Furthermore, an importance analysis of rock roadway eigenvalues was carried out to study the relative importance of each eigenvalue. The results indicate that the ensemble learning

收稿日期:2024-04-07;修回日期:2024-06-09

基金项目:国家自然科学基金资助项目(51874112);深部煤矿采动响应与灾害防控国家重点实验室开放基金重点资助项目(SKLMRDPC22KF02)

作者简介:袁海平(1976—),男,江西九江人,博士,合肥工业大学教授,博士生导师,通信作者,E-mail:seapie@hfut.edu.cn.

has higher prediction accuracy than single learners, and the BOA-LightGBM model has the shortest training time and the highest prediction accuracy, which can be adopted as the optimal algorithm for intelligent decision-making of rock roadway support system. The importance analysis demonstrates that various parameters have different effects on the safety factor of rock bolts in the mine roadways, and the surrounding rock grade represents the most influential factor. This study offers novel insights into the design optimization of anchor network support and the safety prediction of rock roadways to improve the economic benefits of mine.

Key words: mine roadway; Hoek-Brown strength criterion; anchor network support; ensemble learning; Bayesian optimization algorithm(BOA); safety factor

随着矿井开采深度和超深井数量的不断增加,矿产资源的有效提取和利用对于社会经济的长远发展和科技创新的持续进步至关重要。矿山巷道稳定、合理支护是矿山安全、高效开采不可或缺的保障。近年来,由于矿山开采水平和速度正逐步向深部延伸^[1],矿山巷道将面临“三高”巨大挑战,即高地压、高地温和高水压,这些影响均将导致矿产资源开采难度的提高和成本的增加^[2]。为合理有效地应对上述难题,保障矿山安全生产施工的同时实现矿山巷道支护设计的经济可行成为当前岩巷支护领域的研究热点。

当前与矿山巷道支护设计相关的研究规范相对较少,而实际工程中常根据工程类比与经验判断的方法来进行支护设计,往往导致设计结果趋向保守,对于围岩等级较高的区域,势必会存在过度支护和支护造价过高的问题。针对这种情况,文献[3]将协同理论引入隧道支护设计,基于隧道设计多目标优化创建了隧道围岩协同支护系统,实现了隧道支护体系的优化;文献[4]对巷道多个断面进行锚杆应力监测,并结合数值模拟研究了长壁工作面回采过程中锚杆应力的演化规律,对支护设计提出了优化建议。

然而,上述工作并未考虑不同围岩等级条件下矿山巷道内多种支护参数间复杂的相互作用,理论指导意义具有一定的局限性。目前机器学习方法被广泛应用于此类多参数间相互作用问题的求解,其本质为多自变量与因变量之间的非线性映射,而监督式机器学习中的回归算法在此类问题中适用性明显。随着土木工程领域的数字化与智能化发展趋势日益突出^[5-6],机器学习深受多数研究者的青睐。文献[7]基于全断面隧道掘进机(tunnel boring machine, TBM)掘进数据,利用机器学习算法构建了综合地质条件预测模型,准确预测了掘进面的岩体类型,为隧道安全、高效施工提供参考;文献[8]基于现场数据,基于机器学习

算法建立隧道沉降预测模型,准确识别了隧道沉降的演化过程。然而现有的不同类型的算法丰富多样,为依循智能化发展趋势,文献[9]强调应对不同算法进行统一的综合测试和比选以找寻适用于矿山巷道支护的最佳智能算法。

相较于单一学习器,多个学习器组合而成的集成学习算法表现出更高的准确性和泛化能力,是目前备受关注的主流机器学习方法类型。文献[10]提出一种 TBM 掘进模式识别方法,基于集成学习算法对第二模式的掘进推力和刀盘扭矩进行实时预测,为 TBM 参数优化和风险预警提供重要参考;文献[11]基于集成学习算法建立了岩石抗压强度预测模型。

综上,上述优化方法大多对单一围岩等级进行评价,或采用的支护参数相对有限,无法为不同等级围岩条件下差异化支护参数的选取提供有效参考,不足以满足对矿山巷道支护的经济性、合理性需求;集成学习算法在矿山巷道锚网支护研究方面的应用相对有限。因此,本文以华中地区某铁矿为背景依托,在矿山巷道围岩精细化划分的基础上,对不同锚网支护方案进行数值分析并建立锚杆安全系数数据库,基于贝叶斯优化算法(Bayesian optimization algorithm, BOA)优化 3 种集成学习算法,构建了矿山巷道锚杆安全系数预测模型,实现了对岩巷锚杆安全系数的准确预测,验证了集成学习算法比单一学习器更优越,对比选出最适合岩巷支护使用的优选算法,分析各支护参数对安全系数的影响程度,为矿山巷道锚网支护优化以及巷道安全性预测提供重要参考。

1 Hoek-Brown 强度准则

1.1 广义 Hoek-Brown 强度准则

本文采用文献[12]提出的广义 Hoek-Brown 强度准则经验公式:

$$\sigma_1 = \sigma_3 + \sigma_c \left(m_b \frac{\sigma_3}{\sigma_c} + s \right)^a \quad (1)$$

$$m_b = \exp \left(\frac{I_{GSI} - 100}{28 - 14D} \right) m_i \quad (2)$$

$$s = \exp \left(\frac{I_{GSI} - 100}{9 - 3D} \right) \quad (3)$$

$$a = 0.5 + \frac{1}{6} \left[\exp \left(\frac{-I_{GSI}}{15} \right) - \exp \left(\frac{-20}{3} \right) \right] \quad (4)$$

其中: σ_1 、 σ_3 为第一、第三主应力; σ_c 为岩石单轴抗压强度; m_b 为考虑扰动效应折减 m_i 的值; m_i 为材料常数, 表示岩体软硬程度; s 为岩石材料常数, 表示岩体破碎程度; D 为岩体扰动程度; a 为经验参数, 量纲为 1^[13]。

1.2 岩体参数的获取

多数数值模拟软件是基于 Mohr-Coulomb 强度准则来编写, 因此本文采用文献[13-14]提出的将 H-B 应力曲线与 M-C 应力曲线进行拟合的方式来获取岩体质量参数, 其基本原理是在相同界限范围内两条应力曲线所覆盖的面积相等, 如图 1 所示。




图1 H-B与M-C准则最大和最小主应力关系曲线

由此得到黏聚力和内摩擦角的公式为:

$$c = \frac{\sigma_c [(1+2a)s + (1-a)m_b \sigma_{3n}]}{(1+a)(2+a)} \times \frac{(s + m_b \sigma_{3n})^{a-1}}{\sqrt{\frac{1+6am_b(s + m_b \sigma_{3n})^{a-1}}{2(1+a)(2+a)}}} \quad (5)$$

$$\varphi = \sin^{-1} \left[\frac{6am_b(s + m_b \sigma_{3n})^{a-1}}{2(1+a)(2+a) + 6am_b(s + m_b \sigma_{3n})^{a-1}} \right] \quad (6)$$

其中, σ_{3n} 为最大围压强度 σ_{3max} 与单轴抗压强度 σ_c 的比值。

$$\sigma_{3n} = \sigma_{3max} / \sigma_c \quad (7)$$

$$\frac{\sigma_{3max}}{\sigma_{cm}} = 0.47 \left(\frac{\sigma_{cm}}{\gamma H} \right)^{-0.94} \quad (8)$$

$$\sigma_{cm} = \sigma_c \frac{[m_b + 4s - a(m_b - 8s)](m_b/4)^{a-1}}{2(1+a)(2+a)} \quad (9)$$

其中, σ_{cm} 为岩体质量强度。

岩体弹性模量可由 H-B 强度准则^[13]得到:

$$E_m = E_i \left(0.02 + \frac{1 - D/2}{1 + e^{(60+15D-I_{GSI})/11}} \right) \quad (10)$$

$$E_i = R_M \sigma_c \quad (11)$$

其中: E_m 为岩体弹性模量; E_i 为完整岩体模量; R_M 为模量比^[12]。

2 数值计算

2.1 计算参数及数值模拟方案

以华中某铁矿为背景依托, 建立典型三心拱断面模型, 巷宽 4.0 m、高 2.9 m、拱高 1.3 m, 模型长 50 m、宽 15 m、高 50 m。采用放射性网格划分方式, 中部拱形网格单元宽度设置为 0.1 m。建立 FLAC3D 结构模型, 如图 2 所示。




图2 典型三心拱断面数值计算模型

本计算模型中埋深取该铁矿平均埋深 (500 m), 假定上覆岩层平均容重 γ 取 26 kN/m³, 根据现场岩石组成, 材料参数 m_i 取 10。1.0、2.0 级围岩只需素喷支护, 本文主要研究 3.0、4.0 级围岩支护稳定性, 巷道开挖方式为一次开挖再支护, 支护采用锚网支护。根据现场情况, 锚杆采用管缝式锚杆, FLAC3D 中采用 Cable 单元模拟, 针对 3.0 级围岩, 锚杆直径依次选用 25、28、32 mm; 针对 4.0 级围岩, 锚杆直径依次采用 40、46、52 mm, 锚杆具体参数见表 1 所列。锚杆垫片采用 Q235 钢, 厚度 6 mm, 尺寸 150 mm × 150 mm, 采用 Liner 单元模拟; 钢筋网采用直径 6 mm 的冷拔冷萃钢丝, 材料为 Q235 钢, 间距为 0.1 m × 0.1 m, 采用 Geogrid 单元模拟。

为实现对围岩的精细化划分, 将 1.0~5.0 级围岩分成 20 份。地质强度指标 (geological strength

index, GSI) 取值 100 对应 1.0 级围岩, 并按照每隔数量 4 进行递减。为提高计算精度, 对围岩扰动系数 D 的取值也进行精细化划分, 1.0 级围岩对应的值为 0, 每隔 0.04 递增到 5.0 级围岩。

从精细化划分完成的围岩等级中选取 3.0、4.0 级围岩的 GSI 和 D 值, 通过式(2)~(4)进行计算, 得到 m_b 、 s 和 a 的值, 再利用式(5)、式(6)计算围岩的内摩擦角和黏聚力, 最后通过式(10)、式(11)计算精细围岩等级的弹性模量。计算所得 3.0、4.0 级围岩的岩体力学参数见表 2 所列。

表 1 锚杆参数

材质	密度/ (kg/m ³)	弹性 模量/GPa	屈服 强度/MPa	直径/ mm
Q420	7 800	200	410	25、28、32
Q460	7 800	200	430	40、46、52

表 2 岩体力学参数

围岩等级	I_{GSI}	D	c/MPa	$\varphi/(\text{°})$	E_m/GPa
3.0	60	0.40	2.264	33.530	15.677
3.2	56	0.44	1.983	32.097	11.770
3.4	52	0.48	1.748	30.536	8.627
3.6	48	0.52	1.545	28.841	6.248
3.8	44	0.56	1.364	27.018	4.533
4.0	40	0.60	1.197	25.061	3.339
4.2	36	0.64	1.040	22.974	2.531
4.4	32	0.68	0.890	20.766	1.993
4.6	28	0.72	0.745	18.428	1.641
4.8	24	0.76	0.606	15.980	1.411

依托现场情况, 本次数值模拟只考虑 2 种锚杆长度(1.8、2.2 m), 2 种间距(0.8、1.0 m), 4 种排距(0.9、1.2、1.0、1.5 m); 帮部与顶板采用统一平行排列支护模式, 支护断面形式如图 3 所示。




图 3 支护断面形式

将所有支护方案进行排列组合, 共 240 种方案, 见表 3 所列, 依次对每个方案进行模拟分析。

表 3 数值模拟方案

方案数	围岩等级	锚杆长度/m	锚杆直径/mm
120	3.0~3.8	1.8、2.2	25、28、32
120	4.0~4.8	1.8、2.2	40、46、52

2.2 锚杆安全系数

管缝式锚杆是一种全长摩擦型锚杆, 依托管壁与钻孔之间的摩擦力起锚固作用, 工作前的截面形状如图 4 所示。




图 4 管缝式锚杆截面示意图

为合理评估矿山巷道锚杆支护的安全性, 根据《岩石锚杆(索)技术规程》(CECS 22: 2005) 第 7.3.1 节, 采用锚杆的抗拔安全系数作为判断依据, 即锚杆的极限抗拔力与工作荷载的比值。具体计算公式为:

$$K_t = F_{\max}/F_{\text{eq}} \quad (12)$$

其中: $F_{\max}$ 为锚杆极限抗拔力; F_{eq} 为锚杆工作荷载。 $F_{\max}$ 具体公式^[15]为:

$$F_{\max} = \left[\frac{(2\pi - \theta_0)r_1}{r_2} \right] r_2 \int_0^L \tau(x) dx \quad (13)$$

其中: r_1 、 r_2 分别为锚杆安装前的外半径和内半径; L 为锚杆长度; θ_0 为锚杆的开口角度; $\tau(x)$ 为围岩与锚杆界面的剪应力。

$$\tau(x) = p\mu + c_w \quad (14)$$

其中: μ 为锚杆与围岩间的摩擦系数; c_w 为围岩黏聚力; p 为管缝式锚杆对围岩产生的围压。

$$p = \frac{8E_b I (r_1 - r_2) (\pi - \theta_0)}{r_1^4 [12(\pi - \theta_0) + 8\sin(2\theta_0) - \sin(4\theta_0)]} \quad (15)$$

其中: E_b 为锚杆弹性模量; $I = (r_1 - r_2)^3/12$, 为锚杆截面惯性矩。

假设管缝式锚杆在插入钻孔后, 处于闭合状态, 即 θ_0 取 0, 则式(15)可简化为:

$$p = \frac{E_b (r_1 - r_2)^4}{18r_1^4} \quad (16)$$

通过式(13)~(16)计算出模拟方案中的锚杆抗拔应力, 结果见表 4 所列。

表 4 锚杆抗拔应力

围岩等级	直径/mm	抗拔应力/MPa		直径/mm	抗拔应力/MPa		直径/mm	抗拔应力/MPa	
		1.8 m	2.2 m		1.8 m	2.2 m		1.8 m	2.2 m
3.0	25	819.295	1 001.361	28	677.109	827.578	32	558.122	682.150
3.2	25	719.595	879.505	28	594.125	726.153	32	489.321	598.059
3.4	25	635.545	776.777	28	524.445	640.989	32	431.738	527.680
3.6	25	562.511	687.513	28	464.006	567.118	32	381.865	466.724
3.8	25	497.294	607.804	28	410.017	501.132	32	337.302	412.259
4.0	40	306.621	374.759	46	232.693	284.403	52	190.309	232.600
4.2	40	268.218	327.822	46	203.063	248.188	52	165.821	202.670
4.4	40	232.179	283.774	46	175.070	213.975	52	142.590	174.276
4.6	40	198.143	242.175	46	148.450	181.438	52	120.403	147.159
4.8	40	166.020	202.914	46	123.162	150.531	52	99.243	121.297

2.3 构建矿山巷道锚杆安全系数数据库

完成数值模拟工作后,将各方案的锚杆应力结果进行汇总,对表 4 中锚杆极限抗拔应力大于材料屈服强度的情形取屈服强度进行计算,通过

Python 语言对应力结果进行整理分析,得到对应的锚杆安全系数。处理后获得 26 000 条数据,用以构建矿山巷道锚杆安全系数数据库,构建流程如图 5 所示。




图 5 应力数据库的构建

3 算法介绍及模型训练

3.1 算法介绍

集成学习中有两类最具代表性的算法:一类采用袋装法(Bagging),即对样本进行有放回的随机采样(Bootstrap),代表算法有随机森林(random forest, RF);另一类采用提升法(Boosting),即对样本进行权重的优化迭代,代表算法为极限梯度提升回归树(eXtreme gradient boosting, XGBoost)和轻量级梯度提升机(light gradient boosting machine, LightGBM)。本文通过对比这 3 种具有代表性的集成学习算法来找寻最适用于本案例的智能算法。RF 是文献[16]提出的一种集成算法,通过结合 Bagging 和决策树(Cart)算法,随机对样本子集、部分特征值进行 Bootstrap,以此并行生成多个 Cart;通过取平均组合各决策树的预测结果得到最终预测结果,可降低模型对训练样本中全部特征值的依赖性以提高模

型的泛化性能。

XGBoost 是文献[17]提出的一种集成算法。该算法较传统梯度提升法对目标函数进行二阶梯度提升并引入一个正则化项,描述模型的复杂程度,防止模型在训练过程中出现过拟合,同时基于串行生成 Cart 进行迭代和拟合残差,不断提升模型的性能。相比传统梯度提升算法,引入的正则项避免了产生过拟合的现象,且二次项的梯度提升使得预测结果更加准确。

LightGBM 是微软公司在 GitHub 上开源的一种机器学习算法。其 Cart 生成是基于直方图算法,即将数据中的连续浮点特征值划分为 N 个整数区间,以此构建包含 N 个直方图的数据结构。遍历数据时,LightGBM 算法能够根据离散化后的数值,在直方图中进行统计量的累积和计算,并快速找到最佳分割点,避免额外的预排序存储,从而显著降低了内存消耗,极大提高了时间效率。

3.2 模型训练

成功构建矿山锚杆^[18]应力数据库后,对锚杆安全系数进行预测,流程如图 6 所示。




图 6 锚杆安全系数预测流程图

3.2.1 数据预处理

从矿山巷道锚杆安全系数数据库中均匀抽取 1/5 的数据(共 5 200 条)作为验证集,其余 4/5 的数据(共 20 800 条)作为训练集。将围岩等级、锚杆直径、长度、排距与间距、所处的不同位置作为特征值,锚杆的安全系数值作为标签值。由于所采取支护方案的锚杆排布不一致,统一选取 8 个锚杆的位置作为特征值,如图 7 所示。

最后将所有特征值进行标准化。本文所应用的预测模型主要通过 Python 语言中的 Scikit-learn 库进行实现。

3.2.2 交叉验证

交叉验证是一种用于评估机器学习性能的统计方法,其原理是将数据集划分为多个互斥的子集进行多轮训练和评估,以确保模型在不同的数据子集中都能具有良好的表现,主要用于避免偶然误差。




图 7 锚杆位置

3.2.3 贝叶斯优化算法

BOA 原理是明确待需要寻优的超参数及其取值范围,定义要优化的目标函数后使用高斯过程来建立目标函数的后验概率模型,用于得到近似目标函数的概率分布。并根据一些参数组合的评估结果构建代理模型,用于近似目标函数高效地确定下一个要尝试的参数组合,以此不断更新代理模型,逐步逼近最优解。

相较于传统的网格搜索超参数寻优方法,BOA 不用对超参数进行穷举排列搜索,耗时更短,资源利用更有效。本文使用 BOA 优化各模型并结合十折交叉验证法对超参数进行寻优,搜索范围、结果见表 5 所列。

表 5 各算法的超参数搜索范围及取值

BOA-RF			BOA-XGBoost			BOA-LightGBM		
超参数	搜索范围	取值	超参数	搜索范围	取值	超参数	搜索范围	取值
决策树数量	(1,300,10)	150	决策树数量	(1,300,10)	70	叶子节点数	(1,300,10)	50
最大深度	(1,100,5)	66	最大深度	(1,10,1)	5	学习率	(0.05,0.4,0.05)	0.1
最大特征数	(1,12,1)	8	学习率	(0.05,0.4,0.05)	0.3	子样本比例	(20,100,10)	20
最小叶子节点样本数	(1,4,1)	1	子样本采样比例	(0.1,1,0.1)	1	最小叶子节点样本数	(0.1,1,0.1)	0.7
最小分割样本数	(1,4,1)	2	特征采样比例	(0.1,1,0.1)	1	特征采样比例	(0.1,1,0.1)	0.8

从训练耗时上来看,BOA-RF、BOA-XGBoost、BOA-LightGBM 耗时依次减少,分别为 295.455、90.991、26.194 s,BOA-XGBoost 训练的耗时比 BOA-RF 算法提升 224.708%,而 BOA-LightGBM 比 BOA-XGBoost 训练的耗时提升了 247.373%,可见 Boosting 算法在本数据集的表现比 Bagging 算法更好,BOA-LightGBM 是其中运行速度最快的集成算法。

4 模型评价

回归模型常用的评价指标有决定系数 R^2 、平均绝对误差 E_{MAE} 、均方误差 E_{MSE} 和均方根误差 E_{RMSE} 。其中, R^2 越接近 1,表示模型预测精度越高; E_{MAE} 、 E_{MSE} 和 E_{RMSE} 越接近 0,表示模型误差越小。3 种集成学习算法的预测结果及差值如图 8~图 10 所示。




图 8 基于 RF 模型锚杆安全系数的预测值及其差值




图 9 基于 XGBoost 模型锚杆安全系数的预测值及其差值




图 10 基于 LightGBM 模型锚杆安全系数的预测值及其差值

为避免图像过于紧密,抽取样本的步长设定为 10。由图 8~图 10 可知,3 种模型的预测值与真实值均比较接近,误差均不大,在 0 上下波动,说明 3 种模型的预测结果较好,同时三者的误差曲线轮廓较为相似。可见 3 种模型的泛化能力突出,从侧面反映出本次数值计算得到的数据质量较高,没有明显的噪声。

为检验基于集成学习所建立预测模型的准确性和优越性,还采用常规的单一机器学习算法构建预测模型作预测对比,包括决策树回归、岭回归、线性回归、支持向量机回归这 4 种预测模型。各预测模型使用相同的数据集进行训练预测,各模型精度评估结果对比见表 6 所列。

由表 6 可知,BOA-RF、BOA-XGBoost、BOA-LightGBM 这 3 种集成模型在训练集和验证集上的表现均比单一学习器好,决定系数 R^2 都达到 0.99 以上,训练集上分别为 0.994 59、0.994 86、0.995 00,验证集上分别为 0.994 79、0.994 68、0.994 87,三者的预测结果准确度依次增加,且 E_{MAE} 、 E_{MSE} 、 E_{RMSE} 依次降低,可见 BOA-LightGBM 是其中预测效果最好的模型。

对于相同的数据集时,单一学习器中决策树回归模型表现最好,其训练集的决定系数达到 0.902 31;而岭回归和线性回归的预测精度明显低于决策树,训练集的决定系数约为 0.844 00;支持向量机的预测效果最差,训练集的决定系数仅为 0.832 70,与集成学习模型相比存在明显差距。

通过对比表 6 结果可知:BOA-LightGBM 模型具有强大的运行能力,不仅预测精度最高,而且训练耗时最短,对于大规模数据的处理,BOA-LightGBM 模型具有显著的优势,因此可以将其作为矿山锚网支护体系设计和智能决策的优选模型。

表 6 各模型预测性能对比

模型	训练集				验证集			
	R^2	E_{MAE}	E_{MSE}	E_{RMSE}	R^2	E_{MAE}	E_{MSE}	E_{RMSE}
BOA-RF	0.994 59	0.100 43	0.026 87	0.163 93	0.994 79	0.103 98	0.027 05	0.164 46
BOA-XGBoost	0.994 86	0.101 29	0.025 49	0.159 65	0.994 68	0.108 55	0.027 65	0.166 27
BOA-LightGBM	0.995 00	0.099 72	0.024 57	0.156 76	0.994 87	0.106 02	0.026 66	0.163 28
决策树回归	0.902 31	0.521 78	0.484 48	0.696 05	0.887 14	0.543 84	0.586 22	0.765 65
岭回归	0.844 23	0.633 58	0.772 50	0.878 92	0.843 38	0.636 36	0.813 51	0.901 95
线性回归	0.844 30	0.633 39	0.772 19	0.878 74	0.843 40	0.636 23	0.813 41	0.901 89
支持向量机回归	0.832 70	0.611 51	0.829 69	0.910 87	0.828 47	0.620 58	0.890 98	0.943 92

5 数据分析及应用

5.1 数据分析

由于 RF、XGBoost 和 LightGBM 在构建 Cart 时的方式和侧重点不同^[19-24],对特征值重要性的评价指标不同,本文使用排列重要性指标来对三者特征值重要性进行分析。排列重要性是一种模型无关的特征重要性评估方法,其原理为随机打乱某个特征的值,随后观察模型在打乱后的数据上的性能变化,如果该特征的重要性较高,那么打乱就会导致模型性能的明显下降。将图 7 中的测点位置整合为直墙、拱肩、拱顶这 3 种特征值,最终 3 个集成模型的特征值重要度分析结果如图 11 所示。




图 11 锚网支护参数特征重要度

由图 11 可知:3 种模型在特征值判断上具有较高的一致性,锚杆的安全系数受多种因素的影响,在所使用的 7 个特征值中,围岩等级被确定为最重要的因素,3 种模型平均重要度达到 0.547;位置特征值中,影响程度最大的是直墙位置,平均重要度分别为 0.239,其次为拱肩位置,平均重要度分别为 0.084,拱顶位置对安全系数的影响最小,平均重要度为 0.023;锚杆属性特征值中,间距×排距的重要度最大,平均值为 0.054,其次为锚杆直径,平均重要度为 0.046,锚杆长度的重要度最低,平均值仅为 0.006。结果表明:围岩等级、直墙位置是控制巷道稳定的关键因素,在巷道设计和施工过程中,应优先对围岩等级进行评估;其次应考虑处于不同位置的锚杆采取差异化支护;此外锚杆的长度对巷道稳定性的影响不太高,采用较长的锚杆反而会使造价增加。

采用重要度影响最大的围岩等级与直墙位置的平均安全系数关系曲线如图 12 所示。由图 12 可知,岩巷锚杆安全系数随着围岩等级的增加不

断降低,围岩等级在安全系数为 3.8~4.0 分界处由于锚杆材质的不一致出现一个过渡趋势,根据《岩石锚杆(索)技术规程》(CECS 22:2005)中的第 7.3.1 节,锚杆最小安全系数为 1.4,因此,可知当围岩等级处于约 4.2 级以上时,锚网支护已不再满足要求,应采取更强效的支护形式。




图 12 安全系数与围岩等级关系曲线

5.2 数据应用

在数据库的支持下,在进行锚网支护设计时只需将现场围岩等级、锚杆各项参数输入构建的 BOA-LightGBM 预测模型,即可得到该工况下锚杆的安全系数,为实际工程根据不同锚杆位置选择合理的支护参数,实现经济合理的矿山巷道支护设计及优化提供指导,具体实际应用案例如下。

现场某处检测 I_{GSI} 约为 36,对应的围岩等级为 4.2 级,现拟对该工况下的巷道断面进行支护设计,采用对安全系数影响较大的 1.8 m 锚杆,将其余各参数进行排列组合并输入到建立好的 BOA-LightGBM 预测模型中,预测结果见表 7 所列。

表 7 案例预测结果

锚杆直径/mm	间距/m	排距/m	安全系数		
			直墙	拱肩	拱顶
25	0.8	0.9	1.349	2.246	4.074
	0.8	1.2	1.271	2.131	3.973
	1.0	1.0	1.163	2.126	3.317
	1.0	1.5	1.143	2.123	3.219
28	0.8	0.9	1.532	2.641	4.539
	0.8	1.2	1.457	2.522	4.382
	1.0	1.0	1.354	2.485	3.733
	1.0	1.5	1.292	2.428	3.624
32	0.8	0.9	1.813	2.961	4.889
	0.8	1.2	1.722	2.815	4.753
	1.0	1.0	1.528	2.792	4.052
	1.0	1.5	1.454	2.667	3.945

由表 7 可知,在 4.2 级围岩下,直墙处的安全

系数整体低于其他位置处,且拱顶处的安全系数最大,且随着锚杆直径的增加、排布越紧凑,安全系数的值也越大,可见直墙处为主要控制位置,且锚杆直径与排布对安全系数有一定的影响,这与图 11 分析的结论一致。同时由安全系数预测结果可知:对于该工况,采用直径 25 mm 的锚杆时,直墙处的安全系数均小于上述锚杆的最小安全系数 1.4,不满足设计要求;采用 28 mm 的锚杆,排布为 1.0 m×1.0 m、1.0 m×1.5 m 时不满足要求,排布为 0.8 m×0.9 m、0.8 m×1.2 m 时,直墙处安全系数满足要求;而对于拱肩、拱顶而言,采用 25 mm 的锚杆即可满足要求。因此对于该工况,直墙处应采用 28 mm 锚杆;拱肩、拱顶处采用 25 mm 锚杆即可;为了方便施工,统一采用 0.8 m×1.2 m 排布以进行支护。

6 结 论

1) 采用 Hoek-Brown 强度准则中的 GSI 法精细划分围岩等级,通过 FLAC3D 计算矿山巷道在不同围岩等级下不同锚网支护参数的锚杆应力。使用 Python 对数据进行整理用以建立安全系数数据库。所得数据具有明显的规律性,适合机器学习算法进行深入分析和学习。

2) 基于 BOA 优化 RF、XGBoost 和 LightGBM 这 3 种集成算法,构建锚杆安全系数预测模型,结合十折交叉验证的方式对超参数进行寻优训练,3 种模型的训练耗时依次为 295.455、90.991、26.194 s,结果表明 LightGBM 算法是训练耗时最短的集成学习算法。

3) 将数据集中围岩等级、锚杆直径、锚杆长度、锚杆间距、锚杆排距以及锚杆所处位置作为特征值,用于预测锚杆的安全系数。选取 4 种单一学习器进行预测对比。结果表明,集成学习具有更高的预测准确度,其中 BOA-LightGBM 算法的预测精度最高。对比耗时和精确度可将 BOA-LightGBM 作为矿山安全性预测的优选算法。

4) 基于排列重要性对 3 种集成模型进行特征值重要度分析,结果表明,对锚杆安全系数影响最大的因素是围岩等级,位置特征中直墙处的影响最大,属性特征中间距与排距的影响最大。对围岩等级及拱顶位置安全系数相关性分析得出,当围岩处于 4.2 级以上时,锚网支护不再满足安全要求。

5) 本研究提出一种对岩体质量等级进行精细化划分的方法,利用集成学习算法准确预测了

岩巷的安全系数,并比选出最适用于岩巷安全系数预测的集成学习算法,为矿山巷道的不同等级围岩的合理化锚网定量安全性预测以及优化支护设计提供了一个新思路,对提高矿山的经济效益有重要意义。然而,对于采用不同支护方式的不同断面矿山巷道安全性预测评估尚存在不足,需要进一步研究和探索。

[参 考 文 献]

- [1] 蔡美峰,谭文辉,吴星辉,等. 金属矿山深部智能开采现状及其发展策略[J]. 中国有色金属学报, 2021, 31(11): 3409-3421.
- [2] Zhu H H, Yan J X, Liang W H. Challenges and development prospects of Ultra-long and Ultra-deep mountain tunnels[J]. Engineering, 2019, 5(3): 384-392.
- [3] 孙振宇,张顶立,房倩,等. 隧道支护结构体系协同优化设计方法及其应用[J]. 岩土工程学报, 2021, 43(3): 530-539.
- [4] Zhang K, Zhang G M, Hou R B, et al. Stress evolution in tunnel rock bolts during mining in a fully mechanized long-wall face, and an evaluation of rock bolt support design[J]. Rock Mechanics and Rock Engineering, 2015, 48(1): 333-344.
- [5] Topuz B, Alp N C. Machine learning in architecture[J]. Automation in Construction, 2023, 154: 105012.
- [6] Barnewold L, Lottermoser B G. Identification of digital technologies and digitalisation trends in the mining industry[J]. International Journal of Mining Science and Technology, 2020, 30(6): 747-757.
- [7] Zhang Q L, Liu Z Y, Tan J R. Prediction of geological conditions for a tunnel boring machine using big operational data[J]. Automation in Construction, 2019, 100: 73-83.
- [8] Chne R P, Zhang P, Wu H N, et al. Prediction of shield tunneling-induced ground settlement using machine learning techniques[J]. Frontiers of Structural and Civil Engineering, 2019, 13(6): 1363-1378.
- [9] 田四明,李术才,刘大刚,等. 隧道主动支护体系全过程信息化动态设计与智能决策方法研究[J]. 铁道学报, 2023, 45(11): 1-10.
- [10] 朱梦琦,朱合华,王昕,等. 基于集成 CART 算法的 TBM 掘进参数与围岩等级预测[J]. 岩石力学与工程学报, 2020, 39(9): 1860-1871.
- [11] 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.
- [12] Hoek E, Diederichs M S. Empirical estimation of rock mass modulus[J]. International Journal of Rock Mechanics and Mining Sciences, 2006, 43(2): 203-215.
- [13] Hoek E, Brown E. The Hoek-Brown failure criterion and GSI-2018 edition[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2019, 11(3): 445-463.

(下转第 1106 页)

- [J]. 水科学进展, 2023, 34(2): 299-309.
- [6] 苏磊, 蔺建铭, 张宝森, 等. 封冻河道冰下流速分布规律研究[J]. 人民黄河, 2022, 44(9): 95-99, 105.
- [7] 拾兵, 潘光辉, 于冬, 等. 冰盖下水流纵向紊动特性的试验研究[J]. 中国海洋大学学报(自然科学版), 2015, 45(5): 101-106.
- [8] Wang J, Sui J, Karney B W. Incipient motion of non-cohesive sediment under ice cover: an experimental study[J]. Journal of Hydrodynamics, 2008, 20(1): 117-124.
- [9] Zabilansky L J, Hains D B, Remus J I. Increased bed erosion due to ice[M]//Current practices in cold regions engineering. [S. l. : s. n.], 2006: 1-12.
- [10] Ackermann N L, Shen H T, Olsson P. Local scour around circular piers under ice covers[C]//International Symposium on Ice. Dunedin: [s. n.], 2002: 149-155.
- [11] 王军, 侯智星, 隋觉义, 等. 桥墩-冰塞-局部冲刷相关问题研究进展[J]. 力学学报, 2021, 53(3): 672-681.
- [12] Wang J, Hua J, Sui J, et al. The impact of bridge pier on ice jam evolution-an experimental study[J]. Journal of Hydrology and Hydromechanics, 2016, 64(1): 75.
- [13] 夏天. 河道桥墩处水力特性及其对河冰过程影响研究[D]. 呼和浩特: 内蒙古农业大学, 2015: 3.
- [14] Melville B W. Pier and abutment scour: integrated approach[J]. Journal of Hydraulic Engineering, 1997, 123(2): 125-136.
- [15] 王军, 李志硕, 程铁杰, 等. 冰盖下桥墩局部冲刷随时间变化的试验研究[J]. 水利学报, 2021, 52(10): 1174-1182.
- [16] 张新燕, 吕宏兴, 沈波. 圆柱桥墩局部冲刷机理试验研究[J]. 水利水运工程学报, 2012(2): 34-41.
- [17] Lade A D, Deshpande V, Kumar B, et al. On the morphodynamic alterations around bridge piers under the influence of instream mining[J]. Water, 2019, 11(8): 1676.
- [18] Melville B M. Local scour at bridge sites[D]. New Zealand: University of Auckland, 1975: 8-30.
- [19] 茅泽育, 赵升伟, 相鹏, 等. 冰盖下水流流动的掺混特性[J]. 水利学报, 2005, 36(3): 291-297.
- [20] 李冬. 植被对水流结构影响试验研究[D]. 长沙: 长沙理工大学, 2007: 43-54.
- [21] Lade A D, Mihailovic A, Mihailovic D T, et al. Randomness in flow turbulence around a bridge pier in a sand mined channel[J]. Physica A: Statistical Mechanics and its Applications, 2019, 535: 122426.

(责任编辑 吴 亮)

(上接第 1097 页)

- [14] Hoek E. Strength of rock and rock masses[J]. International Society of Rock Mechanics New Journal, 1994, 2: 4-16.
- [15] Hoek E, Carranza-Torres C, Corkum B. Hoek-Brown failure criterion-2002 edition[J]. Proceedings of NARMS-Tac 2002, 1(1): 267-273.
- [16] Breiman L. Random forests[J]. Machine Learning, 2001, 45(1): 5-32.
- [17] Chen T, Guestrin C. Xgboost: a scalable tree boosting system[C]//Proceedings of the 22nd acm sigkdd International Conference on Knowledge Discovery and Data Mining. San Francisco: [s. n.], 2016: 785-794.
- [18] 杨海清, 周小平, 张永兴. 管缝式锚杆在拉拔荷载作用下受力分析模型[J]. 岩土力学, 2007, 28(增刊 1): 236-240.
- [19] Xu K, Han Z, Xu H, et al. Rapid prediction model for urban floods based on a light gradient boosting machine approach and hydrological-hydraulic model[J]. International Journal of Disaster Risk Science, 2023, 14(1): 79-97.
- [20] 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.
- [21] 陈健, 靳军伟, 李新潮, 等. 基于 XGBoost 算法的大直径穿黄隧道施工期管片上浮研究[J]. 隧道建设(中英文), 2023, 43(增刊 1): 72-80.
- [22] 何川, 陈子全, 周子寒, 等. 基于机器学习的隧道支护体系智能化设计与评价方法[J]. 中国公路学报, 2023, 36(11): 205-217.
- [23] 罗维平, 袁大军, 金大龙, 等. 基于随机森林的复合地层盾构切口泥水压力预测与分析[J]. 土木工程学报, 2020, 53(增刊 1): 43-49.
- [24] 仇文岗, 唐理斌, 陈福勇, 等. 基于 4 种超参数优化算法及随机森林模型预测 TBM 掘进速度[J]. 应用基础与工程科学学报, 2021, 29(5): 1186-1200.

(责任编辑 吴 亮)