



DOI:10.12404/j.issn.1671-1815.2405624

引用格式:林志,吴逸飞,杨滢,等.考虑随钻参数的隧道围岩智能分级预测模型[J].科学技术与工程,2025,25(15):6510-6519.

Lin Zhi, Wu Yifei, Yang Ying, et al. Intelligent classification prediction model of tunnel surrounding rock considering drilling parameters [J]. Science Technology and Engineering, 2025, 25(15): 6510-6519.

考虑随钻参数的隧道围岩智能分级预测模型

林志¹, 吴逸飞², 杨滢³, 瞿培栋³, 苟小英^{1*}, 罗伟³

(1. 重庆交通大学土木工程学院, 重庆 400074; 2. 重庆奉建高速公路有限公司, 重庆 404100;

3. 云南航天工程物探检测股份有限公司, 昆明 650217)

摘要 围岩分级是隧道工程建设中的核心要素。随着中国机械化和智能化建造技术的迅速发展,基于随钻参数的围岩智能分级方法已成为推动隧道智能化机械施工的关键保障。尤其在西部山区,由于地形复杂、施工难度大,再加上山区隧道机械化施工经验不足,且现有智能围岩分级方法实用性有限,机械化建造对提升工程质量和有效控制施工风险至关重要。提出一种基于随钻测量参数的智能隧道围岩分级预测方法。以多条特长隧道为研究对象,采集现场随钻参数并进行围岩力学性能测试,构建随钻参数样本库,并通过支持向量回归(support vector regression, SVR)和粒子群优化-反向传播(particle swarm optimization-back propagation, PSO-BP)智能算法构建围岩智能分级预测模型。研究表明,随钻参数与围岩分级指标的相关系数绝对值 $|r_s| > 0.6$,显示出显著相关性,其中扭矩和旋转速度与围岩分级指标的相关性最强。使用数据清洗工具建立了包含574份理想样本的标准化参数指标数据库。对比分析智能算法的预测精度,结果表明 PSO-BP 预测模型的表现最佳。经瞬变电磁(transient electromagnetic, TEM)和隧道地震(tunnel seismic prediction, TSP)超前地质预报验证,基于 PSO-BP 神经网络的围岩智能分级预测模型能够准确预测围岩分级,为隧道机械化开挖提供可靠的分级支持。

关键词 围岩分级; 随钻参数; 相关性; 机器学习; PSO-BP 预测模型

中图分类号 U452;

文献标志码 A

Intelligent Classification Prediction Model of Tunnel Surrounding Rock Considering Drilling Parameters

LIN Zhi¹, WU Yi-fei², YANG Ying³, QU Pei-dong³, GOU Xiao-ying^{1*}, LUO Wei³

(1. Civil Engineering College, Chongqing Jiaotong University, Chongqing 400074, China;

2. Chongqing Fengjian Expway Co., Ltd., Chongqing 404100, China;

3. Yunnan Aerospace Engineering Geophysical Detecting Co., Ltd., Kunming 650217, China)

[Abstract] Rock mass classification is a fundamental component in tunnel engineering construction. With the rapid advancement of mechanized and intelligent construction technologies in China, drilling-parameter-based intelligent rock mass classification methods have become crucial in facilitating smart mechanized tunneling. This need is especially pronounced in the mountainous regions of Western China, where complex terrain and challenging construction, combined with limited experience in mechanized tunneling and the restricted applicability of current intelligent rock mass classification methods, make mechanized construction crucial for improving project quality and effectively controlling construction risks. A predictive method was proposed for intelligent rock mass classification using drilling measurement parameters. Focusing on multiple long tunnels as research subjects, on-site drilling parameters were collected and rock mass mechanical tests was conducted to construct a drilling parameter database, then intelligent algorithms was applied, such as support vector regression (SVR) and particle swarm optimization-back propagation (PSO-BP), to develop a predictive model for rock mass classification. The result indicates that the absolute value of correlation coefficient $|r_s|$ between drilling parameters and rock mass classification indices is greater than 0.6, demonstrating a significant correlation, where torque and rotational speed show the strongest correlation with rock mass classification indices. A standardized parameter index database with 574 ideal samples was established through data-cleaning tools. Comparative analysis of predictive accuracy across intelligent algorithms indicated that the PSO-BP model demonstrated the best performance. The PSO-BP neural network-based prediction model was validated by transient electromagnetic (TEM) and tunnel seismic prediction (TSP) advanced geological forecasting, confirming its accuracy in predicting rock mass classifi-

收稿日期: 2024-07-26 修订日期: 2024-11-17

基金项目: 国家自然科学基金(52078089, 52274176); 云南省重点研发计划(202203AA080006); 三峡库区奉建高速公路安全智能建造科技示范工程[(2021)581]; 重庆英才创新创业领军人才项目(CQYC20220302517); 重庆市自然科学基金创新发展联合基金(CSTB2022NSCQ-LZX0079)

第一作者: 林志(1975—), 男, 汉族, 四川南江人, 博士, 教授。研究方向: 公路隧道与地下工程的科研、技术开发、工程设计咨询和标准规范。E-mail: zhilin@cqjtu.com。

* 通信作者: 苟小英(1998—), 女, 汉族, 四川巴中人, 博士研究生。研究方向: 装配式隧道及隧道减灾工程。E-mail: xygou2017@163.com。

cation and providing reliable support for mechanized tunnel excavation.

[**Keywords**] rock mass classification; drilling parameters; correlation; machine learning; PSO-BP prediction model

在隧道施工现场,不利地质条件、施工技术和主观判断等因素均会影响围岩分级的准确度。为适应隧道机械化智能施工快速发展的需求,准确评估围岩等级对快速推进隧道施工的数字化、智能化发展尤为重要,据此,众多国内外学者依托新兴隧道钻进施工技术提出一些新型围岩分级预测方法,以实现快速、精准评估围岩等级^[1]。

随钻测量技术作为钻进过程中最常用的施工方法,其可有效完善现存的岩体质量指标评价体系^[2]。该技术最初被应用于石油工程,后被引进矿山开采。随钻测量技术通过在钻杆中布置传感器等仪器实现实时采集地层数据,然后将钻杆建立的信息传递路径发送至地面数据接受设备,最后通过对实时钻进数据分析处理即可实现实时优化和调整钻探施工。随钻测量技术采集的参数主要包括钻进速率、钻压、扭矩、震动、钻孔温度和压力等,统称为随钻参数。通过随钻参数可评估岩石的硬度、坚固程度和裂隙发育情况。为实现精确评估围岩等级,尚需进一步建立岩体质量评价指标体系。多次隧道钻孔作业可有效补充岩体结构信息,其对表征岩体质量指标具有不可比拟的优势和潜力,因此,获取有效的钻探参数并探明钻探参数与围岩质量指标的关系对评估岩体等级意义显著。基于此,Schunnesson^[3-4]首次提出基于冲击钻探,监测随钻参数来表征岩体质量指标(rock quality designation, RQD)。He等^[5]利用旋切触探技术建立一种预测钻孔岩石质量的方法,并提出了岩体RQD与机械比能的经验模型。Van Eldert等^[6-8]提出将收集到的MWD(measurement while drilling)数据进行过滤和归一化,使用多元线性回归和Levenberg-Marquardt方法与岩体特征相关联,以提供一种岩体质量定量方法。最终通过归一化的MWD数值映射得到品质因子,并协助岩石支护决策过程。研究表明由于岩石性质的差异性,致使随钻测量参数呈现差异化。因此,利用随钻参数表征岩石力学性质并建立准确的随钻参数与围岩质量相关性模型是必举之措。基于此,宋玲等^[9]利用旋转触探仪器进行室内实验,建立轴向压力、扭矩与试件抗压强度、弹性模量、黏聚力和内摩擦角的数学模型。王玉杰等^[10]、余磊^[11]利用数字钻进测试系统,进行多种钻进实验、物理力学参数实验与单轴压缩试验,基于力学极限平衡和能量守恒原理,建立钻进参数——岩石强度参数模型以及单轴抗压强度模型,并验证了模型的合理性。于恒昌^[12]通过室内实验揭示了钻进过程中随钻参数之间以及随钻参数与岩石力学参数之间的相关性,并利用支持

向量机建立了随钻参数与无侧限抗压强度以及黏聚力-内摩擦角参数的关系模型。上述研究证明了随钻测量技术在钻探过程中能够获取实时、深入的岩体内部信息,在岩体分级中具有独特的优势。

然而,围岩分级方法众多,早期围岩分级工作因勘察手段和研究方法的桎梏,大多以岩石强度为主要指标,采用单一因素定性或半定量指标分类方法,如普世坚固系数分级法^[13],RQD法、太沙基分类法^[14]等。随着钻探技术的进步和运算方法的完善,众多学者提出综合定性定量分级方法,陈志敏等^[15]根据岩堆体特点,选取岩石单轴饱和抗压强度、节理裂隙密度、岩体完整性系数、含水率和填充土含量作为分级指标。王明年等^[16]提出一种基于钻进参数的隧道掌子面围岩单轴抗压强度和弹性模量解析方法。Deng等^[17-18]选择钻进参数稳定段均值作为岩性识别、岩石强度识别和钻进参数优化等的特征。由于中国围岩分级研究起步较晚,在初期阶段利用岩石极限抗压强度和岩石天然重度为指标分级,但随着岩土工程领域的理论与实际应用的深入发展,以及计算机技术和智能算法的快速发展,学者们提出了众多基于智能算法的围岩分级方法,如具有极强学习和分类能力的支持向量机、随机森林和神经网络等智能算法。江杰等^[19]运用MATLAB和C++编程技术,开发了一个BP(back propagation)神经网络训练模型,实现了围岩快速分级的目的。张峰瑞等^[20]结合差异进化算法进一步提出基于DE-BP(differential evolution-back propagation)模型隧道围岩分级方法。何云松等^[21]采用交叉验证与网格搜索技术精细调优支持向量机模型实现准确预测围岩分级。马俊杰等^[22]结合汶马高速公路隧道开挖现场的数据采集样本成功建立了一个SVM(support vector machine)隧道围岩分级模型,实现了有效识别围岩类别。岳中文等^[23]利用机器学习算法分析随钻数据,并综述了机器学习算法岩性识别的发展历程。既往研究表明,基于SVM、BP(back propagation)神经网络和RBF(radial basis function)神经网络等智能算法建立的围岩分级模型及预测模型较多。

随着隧道钻进设备的不断进步,计算机技术的迅速迭代更新,中国隧道智能化建设也快速发展。但目前隧道钻进数据采集主要停留在数据收集或初步人工数据分析阶段,针对艰险山区复杂地质环境的大断面公路隧道的深度识别与数据挖掘研究对象和样板较少,致使围岩地质信息未被充分利用。目前主要通过超前地质预报与地质勘察实现不良地质的识别手

段获取隧道地质信息,因此,由岩性的复杂性和不确定性导致通过随钻参数直接评估围岩等级与实际围岩分级偏差较大,据此,采用机器学习模型训练方法建立智能化围岩分级预测模型意义重大。

1 随钻参数与围岩指标相关性分析

目前隧道钻探施工设备主要采用多功能钻机和凿岩台车,并通过冲击钻凿和水压排屑的方式钻进施工。冲击钻凿的基本原理为冲击力引发的岩石断裂,从而达到钻进目的,其工作原理为多功能钻探设备的冲击系统通过高频冲击活塞对钻杆尖端施加冲击力,该力由钻杆传递至钻头,最终施加于岩石表层,引发岩石断裂。然而,钻进过程中遇到不同岩体结构及岩层时,由于岩石物理学性质的突然变化,钻机的推力、扭矩、转速、钻速等随钻参数亦会产生相应改变。因此分析随钻参数与围岩指标的相关关系是必要的。采用随钻测量技术开展围岩分级评估。随钻测量即是一种通过解译钻机推力、扭矩、转速、钻速等随钻参数变化,评价岩体结构特征和力学性质的原位测量技术^[1-2]。研究拟采用西南地区隧道现场收集的钻进参数为主要研究对象,分析其与现场围岩分级指标的相关性。

1.1 随钻参数评估指标

隧道钻进设备采用意大利卡萨地 C6XP-2 多功能钻机与全电脑凿岩台车,如图 1 所示。

通过对钻探图谱中的传感器数据进行处理方可得到钻进参数,现场采集的随钻参数主要包括钻进速度、推进压力、扭矩和旋转速度,如图 2 所示。

因为围岩岩性存在较大的复杂性和不确定性,以及钻进方式的影响,故围岩随钻参数评估指标体系不仅应包括钻机数据,还应采集掌子面的岩石地质信息,如围岩等级、硬度、完整性、内摩擦角和内聚力等。掌子面的岩石力学性能参数主要通过现场岩心钻取采样和制备标准岩石单轴抗压强度试样的方式测取,同时还需注意开展岩石波速测试以评估围岩等级,掌子面现场采样测试如图 3 所示。



图 1 钻进设备

Fig. 1 Drilling equipment




图 2 钻机数据现场采集

Fig. 2 Collecting filed data



(a) 现场测试



(b) 岩石试件

图 3 围岩分级指标测试

Fig. 3 Rock classification index testing

1.2 相关性分析

对现场采集的 1 000 组围岩分级样本开展随钻参数与围岩分级指标相关性分析。其中,围岩分级指标标准采用单轴饱和抗压强度(R_c)和完整性系数(K_v),表 1 和表 2 为围岩分级指标量化表。随钻参数主要包括钻机钻进速度、推进压力、扭矩和旋转速度。


根据建立的围岩分级量化指标,绘制随钻参数样本的散点图,如图 4 和图 5 所示。

表 1 岩石坚硬性指标
Table 1 Rock hardness index


围岩坚硬程度	极软岩	软岩	较软岩	较坚硬岩	坚硬岩
单轴抗压强度 R_c /MPa	<5	5 ~ 15	15 ~ 30	30 ~ 60	>60

表 2 岩体完整性指标
Table 2 Rock integrity index


完整程度	完整	较完整	较破碎	破碎	极破碎
岩体完整性系数 (K_v)	>0.75	0.75 ~ 0.55	0.55 ~ 0.35	0.35 ~ 0.15	<0.15




(a) 单轴抗压强度与钻进速度关系散点图




(a) 完整性系数与钻进速度关系散点图




(b) 单轴抗压强度与推进压力关系散点图




(b) 完整性系数与推进压力关系散点图




(c) 单轴抗压强度与扭矩关系散点图



(c) 完整性系数与扭矩关系散点图



(d) 单轴抗压强度与旋转速度关系散点图



(d) 完整性系数与旋转速度关系散点图

图 4 单轴抗压强度与随钻参数散点图

Fig. 4 Scatter plot of uniaxial compressive strength and drilling parameter

图 5 完整性系数与随钻参数散点图

Fig. 5 Scatter plot of rock integrity coefficient and drilling parameter

根据围岩等级评价指标与随钻参数的分布关系可知,散点图出现数据堆叠现象,可见围岩分级指标与随钻参数呈现高度相关性。鉴于散点分布情况可知,围岩分级指标与随钻参数间表现为典型的非线性相关性,可采用非线性相关函数建立二者的相关性模型。针对 Spearman 可有效度量复杂的非线性相关性特点,采用 Spearman 的相关系数 r_s 计算围岩分级指标与随钻参数的相关值。 r_s 的正负性表明 X (独立变量)和 Y (依赖变量)的相关方向,各参数相关性量化值如表 3 所示。

表 3 围岩分级指标与钻进参数相关系数

Table 3 Correlation coefficient between surrounding rock classification index and drilling parameters

钻进参数	钻进速度	推进压力	扭矩	旋转速度
单轴抗压强度	-0.687	-0.751	0.872	-0.949
完整性系数	-0.679	-0.759	0.873	-0.943

对比分析围岩分级指标与钻进参数的相关系数可得到如下结论。①钻进速度、旋转速度和推进压力与围岩分级指标 R_c 和 K_v 均为负相关关系,表明随着围岩质量的提高,随钻参数呈下降趋势;②相关性系数的绝对值 $|r_s|$ 均大于 0.6,围岩分级指标与钻进参数相关性较强;③根据 $|r_s|$ 可知,围岩分级指标与随钻参数的相关性强弱关系为旋转速度 > 扭矩 > 推进压力 > 钻进速度,旋转速度和扭矩为评估围岩等级的关键参数。

2 基于随钻参数的围岩智能分级预测模型

针对随钻参数与围岩分级指标的高度相关性,采用机器学习方法建立非线性相关模型^[24]。为了更精确量化随钻参数与围岩分级指标的相关性,首先清除钻进过程中因卡钻、换杆等情况导致的失效数据,建立有效的随钻参数样本库;其次,进一步采用支持向量机回归(support vector regression, SVR)和基于粒子群优化的神经网络算法(particle swarm optimization-back propagation, PSO-BP)两种机器学习模型建立基于随钻参数的掌子面围岩智能分级预测模型;最后,采用多种回归模型检验方法验证围岩分级预测模型的拟合精度。

2.1 标准化随钻参数样本库

一次超前水平钻孔距离为 60 m,因此需每间隔 2 m 换杆,在进行换杆时钻杆存在回抽现象,此时收集的随钻参数与围岩地质条件无关,故换杆时的数据应排除,为保证机器学习训练的准确性同时避免数据出现欠拟合现象,首先需筛除样本库中的无效数据,再辅以异常数据清洗,从而建立标准化随钻参数样本库。

由图 2 可知,钻进速度、扭矩和旋转速度呈现稳定的间隔波动,而推进力基本保持不变,小幅度的间隔波动现象因更换钻杆过程中回拉导致,故应将其从样本库筛除。针对初筛后的样本库,采用标准差与平均值区间法清洗异常数据样本。因随钻参数中旋转速度和扭矩与围岩分级指标的相关性最强,故选择包含上述两个参数的样本继续筛除异常数据,利用标准差与平均值区间法清洗剔除样本库的离散数据,从而建立有效的参数样本库。

假设旋转速度的平均值和标准差分别为 α_1 、 β_1 ,相应的扭矩分别为 α_2 、 β_2 ;首先筛除 $[\alpha_1 - \beta_1, \alpha_1 + \beta_1]$ 区间外的数据,然后继续筛除 $[\alpha_2 - \beta_2, \alpha_2 + \beta_2]$ 区间外的数据。经过对初始样本库中 1 000 个样本的清洗和筛选,最终获取了 574 份理想样本。表 4 为样本库中各级围岩在旋转速度和扭矩参数筛选前后的统计规律。

表 4 样本库筛选前后对比

Table 4 Comparison of the sample library before and after screening

围岩等级	数据类型	统计值	旋转速度	扭矩	样本数量
III 级	清洗前	平均值	101.28	77.01	382
		标准差	1.86	14.3	
	清洗后	平均值	102.94	61.54	
		标准差	0.67	3.73	
IV 级	清洗前	平均值	110.51	84.45	404
		标准差	2.97	2.63	
	清洗后	平均值	110.18	58.48	
		标准差	2.57	2.64	
V 级	清洗前	平均值	118.70	54.51	214
		标准差	5.68	2.34	
	清洗后	平均值	111.48	56.43	
		标准差	3.38	2.13	

初筛后的样本库包括 134 份 III 级围岩样本、387 份 IV 级样本和 53 份 V 级样本。完成离散数据筛除后,不同围岩等级的离散程度明显降低。数据标准化是数据挖掘前期的关键步骤,以保证所有指标具有相同的单位和量纲,便于开展后续的综合评估。采用 min-max 标准化方法对样本库数据进行标准化处理,最终构建机器学习模型。

min-max 标准化,又称离差标准化,通过线性变换将原始数据映射到 $[0, 1]$ 区间内。这种方法有效的保留了数据间的原有关系并消除了量纲影响,但缺点在于易受到异常值干扰。如若集中数据存在最大值,则其他数值在归一化后可能趋于 0;此外,在处理 $[\min, \max]$ 区间外的数据时可能导致错误。但因此时样本库以已经完成异常值和离散值筛查,有效避免了上述情况的出现,故仍可采用 min-max 方法进行标准化处理。min-max 标准化处理方法的转换函数为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式(1)中: x_{\max} 为样本数据中的最大值; x_{\min} 为样本数据中的最小值。

2.2 基于随钻参数的机器学习模型训练

2.2.1 SVR 支持向量机围岩分级预测模型

支持向量回归(SVR)具有最小化预测模型输出值与实际值的偏差的优点,可在有效降低误差平方和的同时保持预测模型的良好泛化性能,即通过最大化间隔来增强模型对未见数据的预测能力。SVR 算法作为一种非概率性的回归分析工具,采用钻进速度、旋转速度、扭矩及推进压力等作为预测模型的输入参数,而将围岩的内摩擦角、黏聚力、单轴抗压强度、完整性系数及围岩基本质量指标设置为输出目标。通过对比预测值与实际值的均方误差(mean squared error, MSE)和决定系数(R^2),可判断该算法在围岩地质指标预测工程中的可靠性与准确性,其计算方法为

$$MSE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)|^2 \quad (2)$$

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (3)$$

式中: n 为样本总数; i 为当前样本序列数; \hat{y}_i 为实测数据; y_i 为预测值; \bar{y} 为实测数据的平均值。MSE 值趋近于零,则表示预测结果与实际情况高度一致;针对 R^2 检验方法,其值愈趋于 1,表明模型的拟合精度越好。


围岩分级指标的 SVR 支持向量机模型预测结果如图 6 所示。

由图 6 可知,围岩单轴抗压强度和围岩完整系数的均方误差 (MSE) 和决定系数 (R^2) 分别为 3.310 2、0.905 78 和 0.000 256 97、0.958 73,表明基于预测值与实际值误差较小,基于 SVR 支持向量机的围岩分级预测模型精度满足工程要求。


2.2.2 基于 PSO-BP 神经网络围岩分级预测模型

BP 神经网络具有自学习、存储广泛和输入-输出相互映射的特点,且无须预先定义映射关系的具体数学表达式,因此不仅能有效地量化分析非线性相关性,还能学习并表征复杂数据模型。尽管 BP 网络在模式识别和预测等领域优点显著,但其工作性能仍受神经元数量和学习率等参数的主观因素影响,致使其预测模型的稳定性和训练效率受限。为克服上述桎梏并增强预测模型的全局搜索能力和收敛速度,引入粒子群优化(PSO)算法对 BP 神经网络进行优化,即提出一种基于 PSO-BP 神经网络模型。

围岩分级指标的 PSO-BP 神经网络模型预测结果如图 7 所示。



(a) 围岩单轴抗压强度预测效果



(b) 围岩完整性系数预测效果

图 6 SVR 支持向量机模型

Fig. 6 Support vector regression (SVR) model


由图 7 可知,围岩单轴抗压强度和完整系数的均方误差 (MSE) 为 0.005 098 5 和 0.011 511,决定系数(R^2)为 0.986 56 和 0.977 98,表明通过训练样本获得的围岩单轴抗压强度和完整性系数的预测值与真实值保持较好的一致性,模型拟合效果良好,基于 PSO-BP 神经网络的围岩分级预测模型具有高准确度与可靠性。

2.3 围岩智能分级预测模型精度检验

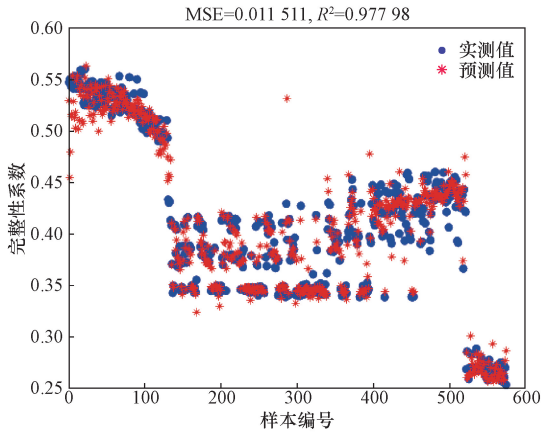
基于建立的两两种预测模型,进一步检验其预测精度,以判断最优围岩智能分级预测模型。采用决定系数、均方误差和平均相对误差率综合检验两种机器学习模型对岩石单轴抗压强度和围岩完整系数的预测精度,其中,平均相对误差率为预测值偏离真实值的平均相对误差的比率。

2.3.1 岩石单轴抗压强度

两种预测模型对岩石单轴抗压强度评价指标如表 5 所示,模型预测值与真实值拟合对比情况如图 8 所示。



(a) 围岩单轴抗压强度预测效果



(b) 围岩完整性系数预测效果

图7 PSO-BP神经网络模型

Fig.7 PSO-BP neural network model

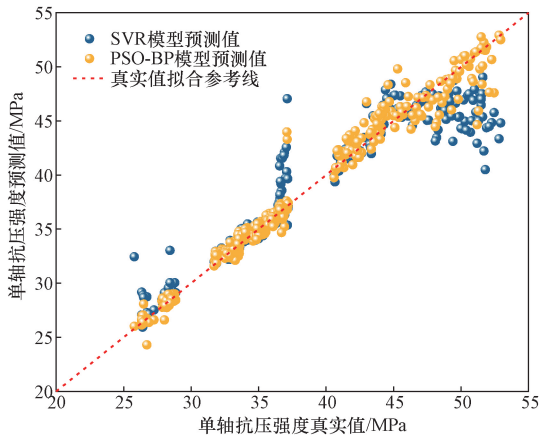


图8 预测模型的单轴抗压强度预测值与真实值拟合对比

Fig.8 Fitting comparison of predicted and actual values of uniaxial compressive strength for the trained model

表5 预测模型单轴抗压强度评价指标

Table 5 Evaluation index for uniaxial compressive strength using training models

预测模型	决定系数	均方误差	平均相对误差率/%
SVR	0.905 78	3.310 2	2.86
PSO-BP	0.986 56	0.005 095 8	1.65

相较于 SVR 模型, PSO-BP 模型在预测围岩单轴抗压强度参数方面具有更高的决定系数, 较低的均方误差和平均相对误差率, 预测模型精度检验结果表明 PSO-BP 模型更符合评价指标的预测精度要求。

对比分析预测数据与真实值拟合参考曲线, 当预测数据紧邻实拟合参考线时, 表明此时预测值与真实值一致性良好。对比分析图 8 的两种预测模型, 发现 PSO-BP 模型的预测数据与实际拟合参考线更为接近, 离散值较少, 偏离程度更小。可见, PSO-BP 模型可精确预测围岩的单轴抗压强度。

2.3.2 围岩完整性

检验两种预测模型评估围岩完整性的精度, 如表 6 所示, 并绘制了预测值与真实值拟合对比图, 如图 9 所示。

对比两种预测围岩完整性系数模型的决定系数(R^2)、均方误差(MSE)和平均相对误差率可知, PSO-BP 模型展现出较 SVR 模型更高的决定系数, 虽然在均方误差方面略逊于 SVR 模型, 但两者在平均相对误差率方面相差不大。

鉴于两种预测模型在评价指标上的精度差异不明显, 可进一步对比预测值与真实值的一致性来判断最优预测模型。由图 9 可知, PSO-BP 模型的预测值与真实值拟合参考线的偏离程度小于 SVR 模型, 尤其针对误差最值, PSO-BP 模型离散度更小, 拟

表6 预测模型完整性系数评价指标

Table 6 Evaluation index for rock integrity parameter using training models

预测模型	决定系数	均方误差	平均相对误差率/%
SVR	0.958 73	0.000 256 97	2.41
PSO-BP	0.977 98	0.011 511	2.42




图9 预测模型的完整性系数预测值与真实值拟合对比

Fig.9 Fitting comparison of predicted and actual values of rock integrity parameter for the trained model

合精度更高。可见,PSO-BP 预测模型的整体预测精度更好,可有效预测围岩的完整性。

综合上述模型预测精度检验结果可知,PSO-BP 模型相较 SVR 模型在预测围岩岩体的单轴抗压强度和完整性方面呈现出高精度、高可靠性的优点,且该模型具有更高的决定系数和更低的均方误差,预测结果更贴近真实值,因此预测性能更优,基于 PSO-BP 神经网络的预测模型可精确预测围岩质量参数并有效评估现场围岩等级。

3 基于 PSO-BP 围岩智能分级预测模型的现场验证

针对已经探明的隧道围岩智能分级预测模型,基于西南地区隧道现场某工区隧道,采集共计 100 个围岩分级样本,开展基于 PSO-BP 预测模型的工程适用性和可靠性验证,样本情况如表 7 所示。

针对验证预测模型的随钻参数样本,输入围岩分级指标预测模型,从而预测围岩等级。评估围岩智能分级方法准确性的依据为预测值评估的围岩等级与实际测定围岩等级是否保持一致性。为检验预测模型的可靠性,研究采用瞬变电磁超前地质预报和隧道地震(tunnel seismic prediction, TSP)超前地质预报手段测定围岩等级,并将其与实测围岩等级和基于 PSO-BP 神经网络的围岩智能分级预测结果开展对比分析。针对西南地区 A 隧道,验证样本的预测结果与实际情况对比如表 8 所示。

岩石属性与相应的隧道里程围岩分级结果如图 10 所示。

据验证样本的一致性检验数据可知,基于 PSO-BP 神经网络的围岩智能分级预测模型的平均预测准确率与实测数据完全保持一致。其中,III 级围岩、IV 级围岩和 V 级围岩的预测准确率均高于瞬变

表 7 现场围岩级别样本数

Table 7 Field surrounding rock samples

样本围岩级别	样本隧道名称	样本数量
V 级	A 隧道	17
IV 级	B 隧道	46
III 级	B 隧道	37

表 8 围岩分级预测结果

Table 8 Prediction results of surrounding rock classification

隧道里程	实测	PSO-BP 预测	瞬变电磁	TSP
K42+492~K42+581	III 级	III 级	III 级	III 级
K42+581~K42+646	IV 级	IV 级	III 级	IV 级
K42+646~K42+692	IV 级	IV 级	IV 级	III 级

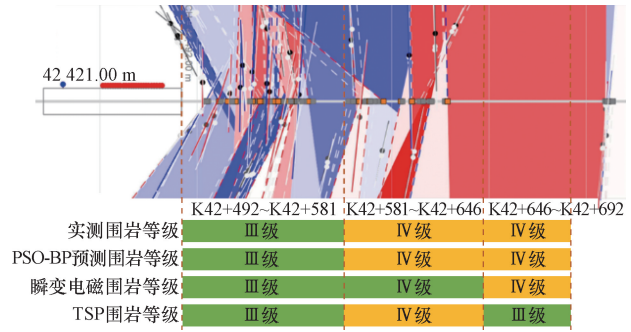


图 10 围岩分级预测结果

Fig. 10 Prediction results of surrounding rock classification

电磁超前地质预报和 TSP 超前地质预报的围岩分级结果,满足工程应用要求,一致性检验结果验证了基于 PSO-BP 神经网络的围岩智能分级预测模型在实际工程应用中的准确性和可靠性,可推广应用于隧道钻进工程的围岩分级预测研究。

4 结论

研究探讨了隧道机械钻进施工过程中的随钻参数与围岩分级指标间的相关性,并建立了基于 PSO-BP 神经网络的围岩智能分级预测模型,可有效预测实际隧道钻进工程中的围岩分级情况,从而实时指导实际隧道钻进工程。主要结论如下:

(1) 通过剖析随钻参数与围岩分级指标的相关性,发现二者之间具有较强的相关性(相关系数绝对值 $|r_s|$ 均大于 0.6);钻进速度、推进力、旋转速度与围岩单轴抗压强度(R_c)和完整性系数(K_v)间表现为负相关关系,而扭矩与之为正相关。对比分析各 $|r_s|$ 可知,旋转速度和扭矩与围岩分级指标相关性最显著,揭示了其在预测围岩分级中的重要性。

(2) 通过对 1 000 个样本进行数据筛选、清除和 min-max 标准化处理后,构建了一个包含 574 个理想样本的标准化随钻参数样本库;基于该样本库,分别建立了支持向量回归(SVR)和 PSO-BP 神经网络两种围岩智能分级预测模型,并对两者进行了对比分析。实验结果表明,二者的预测精度均能够满足工程实际要求,为隧道钻进施工过程中的围岩智能分级提供了有效的工具。

(3) 通过对比分析 SVR 和 PSO-BP 两种预测模型的均方误差(MSE)、决定系数(R^2)和平均相对误差率,结果表明 PSO-BP 模型在围岩分级预测方面的性能明显优于 SVR 模型,表现为 PSO-BP 模型的决定系数为 0.977 98,相比 SVR 的 0.011 511 具有显著提高;此外,在围岩单轴抗压强度的预测中,PSO-BP 模型的均方误差(MSE)为 0.005 098 5,平

均相对误差率为 1.65%，均优于 SVR 模型，证明了 PSO-BP 模型在围岩分级预测中的优越性。

(4) 研究提出的基于 PSO-BP 神经网络的围岩智能分级预测模型具有较高的预测精度，但研究数据基于特定的隧道钻进工程，且 PSO-BP 模型的训练过程可能受到局部最优解的限制，尽管采用了粒子群优化算法进行参数优化，但模型在面对复杂地质条件时的稳定性和可靠性仍需进一步验证，可采用多源数据融合与优化模型相结合的方法对复杂地质情况进一步展开研究。

参 考 文 献

- [1] 徐博, 谢慈航, 吴莹. 隧道围岩分级方法研究综述[J]. 隧道建设, 2023, 43(S1): 25-36.
Xu Bo, Xie Cihang, Wu Ying. A review of methods for tunnel surrounding rock classification [J]. Tunnel Construction, 2023, 43(S1): 25-36.
- [2] 赵思光, 王明年, 童建军, 等. 基于钻进参数多变量特征挖掘的隧道围岩智能分级模型研究[J]. 隧道建设, 2024, 44(12): 2469-2479.
Zhao Siguang, Wang Mingnian, Tong Jianjun, et al. Intelligent classification model of tunnel surrounding rock based on drilling parameter multi variable feature mining [J]. Tunnel Construction, 2024, 44(12): 2469-2479.
- [3] Schunnesson H. RQD predictions based on drill performance parameters [J]. Tunnelling and Underground Space Technology, 1996, 11(3): 345-351.
- [4] Schunnesson H. Rock characterisation using percussive drilling [J]. International Journal of Rock Mechanics and Mining Sciences, 1998, 35(6): 711-725.
- [5] He M M, Li N, Yao X C, et al. A new method for prediction of rock quality designation in borehole using energy of rotary drilling [J]. Rock Mechanics and Rock Engineering, 2020, 53: 3383-3394.
- [6] Van Eldert J, Schunnesson H, Saiang D, et al. Improved filtering and normalizing of measurement-while-drilling (MWD) data in tunnel excavation[J]. Tunnelling and Underground Space Technology, 2020, 103: 103467.
- [7] Van Eldert J, Funebag J, Saiang D, et al. Rock support prediction based on measurement while drilling technology[J]. Bulletin of Engineering Geology and the Environment, 2021, 80: 1449-1465.
- [8] Van Eldert J, Schunnesson H, Johansson D, et al. Application of measurement while drilling technology to predict rock mass quality and rock support for tunnelling[J]. Rock Mechanics and Rock Engineering, 2020, 53(3): 1349-1358.
- [9] 宋玲, 李宁, 李骞. 软岩的旋转触探参数与力学参数的内在关系研究[J]. 岩石力学与工程学报, 2011, 30(6): 1274-1282.
Song Ling, Li Ning, Li Qian. Study of intrinsic relationship between mechanical parameters and parameters of rotary penetration test of soft rock [J]. Chinese Journal of Rock Mechanics and Engineering, 2011, 30(6): 1274-1282.
- [10] 王玉杰, 余磊, 赵宇飞, 等. 基于数字钻进技术的岩石强度参数测定试验研究 [J]. 岩土工程学报, 2020, 42(9): 1669-1678.
Wang Yujie, She Lei, Zhao Yufei, et al. Experimental study on measurement of rock strength parameters based on digital drilling technology [J]. Chinese Journal of Geotechnical Engineering, 2020, 42(9): 1669-1678.
- [11] 余磊. 岩石强度与耐磨性参数的数字钻进测定技术研究[D]. 西安: 西安理工大学, 2019.
She Lei. Research on digital drilling technique for determination of rock strength and wear resistance parameters [D]. Xi'an: Xi'an University of Technology, 2019.
- [12] 于恒昌. 基于数字钻探测试技术的岩石力学参数测定方法研究[D]. 济南: 山东大学, 2018.
Yu Hengchang. Study on testing methods of rock mechanics parameters based on digital drilling testing technology [D]. Jinan: Shandong University, 2018.
- [13] 关宝树. 普氏岩石坚固性系数 [J]. 铁路标准设计, 1964(4): 24.
Guan Baoshu. Protodyakonov rock hardness coefficient [J]. Railway Standard Design, 1964(4): 24.
- [14] 沈中其, 关宝树. 铁路隧道围岩分级方法 [M]. 四川: 西南交通大学出版社, 2000.
Shen Zhongqi, Guan Baoshu. Classification methods for railway tunnel surrounding rock [M]. Sichuan: Southwest Jiaotong University Press, 2000.
- [15] 陈志敏, 张赓旺, 李宁. 隧道穿越岩堆体围岩剪切特性及分级 [J]. 科学技术与工程, 2024, 24(20): 8640-8647.
Chen Zhimin, Zhang Gengwang, Li Ning. Shear characteristics and classification of surrounding rock of tunnel through rock pile [J]. Science Technology and Engineering, 2024, 24(20): 8640-8647.
- [16] 王明年, 易文豪, 赵思光, 等. 基于钻进参数的隧道掌子面围岩单轴抗压强度和弹性模量解析 [J]. 中国公路学报, 2024, 37(7): 22-34.
Wang Mingnian, Yi Wenhao, Zhao Siguang, et al. Analysis of uniaxial compressive strength and elasticity modulus of tunnel face surrounding rock based on drilling parameters [J]. China Journal of Highway and Transport, 2024, 37(7): 22-34.
- [17] Deng L C, Li X Z, Xu W. et al. Integrated monitoring of lithology parameters while drilling in small-scale coring platform [J]. Rock Mechanics and Rock Engineering, 2022, 55: 7269-7288.
- [18] Deng L X, Li X Z, Xu W T, et al. Measurement while core drilling based on a small-scale drilling platform: mechanical and energy analysis [J]. Measurement, 2022, 204: 112082.
- [19] 江杰, 蒲鸥, 欧孝夺, 等. 岩溶区公路隧道围岩分级专家系统设计与应用 [J]. 长江科学院院报, 2018, 35(7): 94-99.
Jiang Jie, Pu Ou, Ou Xiaoduo, et al. Design and application of expert system for classification of surrounding rock in highway tunnels in karst areas [J]. Journal of Changjiang River Scientific Research Institute, 2018, 35(7): 94-99.
- [20] 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.
- [21] 何云松, 薛秋池, 赵其华. 基于改进向量机的岩体质量分级

- 研究[J]. 水利水电技术, 2017, 48(1): 133-138.
- He Yunsong, Xue Qiuchi, Zhao Qihua. Improved support vector machine-based study on rock mass quality classification [J]. Water Resources and Hydropower Engineering, 2017, 48 (1): 133-138.
- [22] 马俊杰, 李天斌, 孟陆波, 等. MSVM 在汶马高速公路隧道围岩分级中的应用[J]. 成都理工大学学报(自然科学版), 2019, 46(3): 373-380.
- Ma Junjie, Li Tianbin, Meng Lubo, et al. Application of MSVM to the classification of surrounding rock in Wenchuan-Barkam Highway tunnels, Sichuan, China [J]. Journal of Chengdu University of Technology (Science & Technology Edition), 2019, 46 (3): 373-380.
- [23] 岳中文, 闫逸飞, 王煦, 等. 基于随钻数据的岩性识别机器学习算法研究进展[J]. 科学技术与工程, 2023, 23(10): 4044-4057.
- Yue Zhongwen, Yan Yifei, Wang Xu, et al. Research progress of machine learning algorithm for lithology identification based on data while drilling[J]. Science Technology and Engineering, 2023, 23(10): 4044-4057.
- [24] 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.
- He Chuan, Chen Ziquan, Zhou Zihan, et al. Intelligent design and evaluation method of tunnel support system based on machine learning [J]. China Journal of Highway and Transport, 2023, 36 (11): 205-217.