

文章编号: 1005-0930(2025)03-0701-013 中图分类号: U455 文献标识码: A
doi: 10.16058/j.issn.1005-0930.2025.03.008

基于机器学习的山岭公路隧道初期支护智能决策

全跃¹, 方育智², 段志宏¹, 周鸣亮², 文元勇¹,
黄宏伟², 张东明²

(1. 云南宣会高速公路有限公司, 云南 曲靖 654200; 2. 同济大学土木工程学院地下建筑与工程系, 上海 200092)

摘要: 针对钻爆法隧道初期支护决策中施工信息实时获取困难、历史数据利用率低导致时效性与安全性不足问题, 提出一种融合机器视觉与多源数据驱动的智能支护决策方法. 基于云南宣会高速公路隧道工程数据, 构建了包含 13 维特征参数的多源数据库, 特征参数通过卷积神经网络视觉提取、现场记录与试验测量多途径获取. 采用集成学习框架开发了支护方案分类与参数回归双预测模型: (1) 基于 AdaBoost 分类模型实现支护方案智能选择, 精确率、召回率和 F1 值分别达 0.960、0.978、0.966; (2) 基于随机森林回归模型完成支护参数定量预测, MAE = 0.0416、 $R^2 = 0.8275$. 网格搜索优化与错误代价评估表明, 双模型性能显著优于传统机器学习方法. 研究成果基于机器视觉与数据挖掘深度融合, 为山岭隧道支护设计提供了智能化决策支持.

关键词: 钻爆法隧道; 初期支护; 机器视觉; 多源数据; 集成学习; 智能决策

随着我国交通网络不断扩展, 越来越多的偏远地区、山区及特殊地质区域纳入建设范畴. 同时, 隧道工程的施工技术与材料科学也在不断发展, 以应对“里程更长、埋深更深、跨度更大”等复杂挑战. 由于岩土材料的初始应力场复杂、变异性大、地域差异明显, 加之岩土的本构关系难以精确确定, 隧道建设过程中, 初期支护方案及支护参数的选择常需参考以往工程经验. 在此背景下, 如何有效利用前期开挖过程中获取的数据信息, 为后续隧道的初期支护方案提供科学依据, 已成为大数据时代隧道工程领域面临的新课题.

目前山岭隧道施工前, 设计单位主要依据地质勘察报告, 并通过荷载结构法、地层结构法以及数值模拟等方法, 初步制定适应不同岩层条件的支护方案^[1]. 在施工过程中, 若遇到较薄弱的岩体或不稳定的开挖面, 施工团队会根据实际情况对支护参数进行调整, 这通常依据开挖面的情况和工程师的现场判断. 这类依赖现场观察、测量或采样试验的手段, 通常被称为接触式测量方法^[2]. 然而, 在当前的钻爆法隧道施工中, 采用接触式方法获取工作面核心信息仍存在诸多挑战, 主要包括测量耗时长、操作危险性高, 且受主观判断与经验影响较大等问题^[3-4]. 在当前工程实践中, 过度依赖接触式方法获取参数, 导致大量宝贵的工程经验未能通过数据化手段展示和利用, 这在一定程度上诱发了各类工程事故. 例如, 2013 年 7 月 3 日晚, 十天高速某黄土隧道左线洞口浅埋段 (ZK719+385 至 ZK719+377.2) 发生塌方, 塌方导致地表形成面积为 54.7m² 的圆形坑洞, 隧道左上导坑的初期支护整体破坏, 造成重大损失. 事故主要原因在于原设计围岩分级与实际情况差异较大, 初期支护设计强度不足, 无法保证围岩在开挖至二次衬砌期间的稳定性^[5]. 类似事故近年也时有发生, 如 2019 年广西那峨隧道及山西忻城山隧道塌方等, 均是由于未能做到初期支护的动态准确决策而引发.

近年来, 国际上逐渐转向基于机器视觉的岩体信息采集与识别技术^[6-7]. 其中, 数字摄影技术作为机器视觉的典型应用, 能够高效捕捉岩体表面的几何信息, 且操作简便、数据采集快捷^[8-9], 为现场提供了客观且高效的数据支撑. 因此, 本研究将采用更多的非接触式方法, 并结合接触式测量, 完善隧道工作面的数据采集与分析系统^[10-12].

收稿日期: 2024-11-13; 修订日期: 2025-03-13

基金项目: 云南省交通运输厅科技项目 (云交科教便 [2023] 146 号); 云南省黄宏伟专家工作站 (202205AF150015); 云南交投科技创新计划项目 (YCIC-YF-2022-15)

作者简介: 全跃 (1992—), 男, 博士, 高级工程师. E-mail: tongyue2014@yeah.net

通信作者: 方育智 (1999—), 硕士研究生. E-mail: 2330992@tongji.edu.cn

在山岭隧道的钻爆法施工中,初支通常采用锚喷支护,这种技术在矿山行业已有 60 余年的应用历史.锚喷支护主要作用是限制围岩变形、调节围岩应力分布,防止岩石松散坠落.在实际施工中,当发现围岩开挖面情况与设计存在差异时,及时、合理地调整支护方案和参数尤为重要.然而,现有的支护方案调整仍主要依赖经验法,因此,结合围岩参数信息的支护方案辅助决策模型研究成为一个重要的研究方向.

通过机器学习方法,对大数据进行挖掘与模式学习,可以充分利用过往工程经验的优势,并结合数值模拟、响应面分析及不确定性分析对所得支护参数进行评价,从而获得更加合理的初期支护设计方案.在工程经验数据的应用领域,部分学者已利用数据库技术建立了隧道工程经验数据库,为基于经验法的支护设计提供了数据支持.Leu 等^[13]提出一种基于人工神经网络(ANN)的数据挖掘方法,用于预测隧道支护的稳定性.刘佳宝^[14]开发了铁路隧道结构设计系统,通过对大量隧道数据的研究,建立了铁路隧道数据库,利用围岩特征曲线法计算初期支护的安全系数,为设计及施工提供了参考.Jiang 等^[15]提出一种将支持向量机(SVM)、粒子群算法(PSO)与数值分析方法相结合的综合优化方法,用于隧道位移反馈控制.孙中秋等^[16]基于数据库及 CAD 平台,构建了隧道设计数据存储和利用体系,实现了设计过程中支护参数的自动反馈,显著提高了设计参数的合理性.此外,Eldert 等^[17]通过随钻测量(MWD)技术提升了对开挖面前方岩体的预测精度,从而辅助支护决策.

在数据驱动的施工支护决策方面,陈佳耀等^[18]利用深度学习图像识别技术,综合了围岩结构分类、开挖面地下水情况量化^[19]、开挖面裂隙情况量化^[20]和软弱夹层量化^[21]等多项指标,提出一种基于数据融合驱动的 NATM 隧道开挖面围岩分级方法^[22].Erharter 等^[23]基于强化学习算法,提出一个旨在优化隧道开挖策略的框架,该框架以经济和安全为目标,选择最佳的开挖策略和土体挖掘顺序.Liu 等^[24]基于随钻测量数据,选取了穿透率、锤击压力、旋转压力、进料压力、锤击频率和比能 6 个特征参数,构建了一个基于随钻测量的人工神经网络(ANN)支护方案预测模型.满建宏等^[25]通过收集文献数据建立隧道工作面稳定性数据库,通过 MARS 算法评估开挖工作面稳定性,并得出隧道几何参数比岩土体力学参数更能影响工作面稳定性的结论.

本研究依托于宣会高速沿线 29 座隧道的工程实践,这些隧道面临软弱岩体、岩溶、偏压、瓦斯等有害气体、采空区、下穿河道及膨胀土等复杂的不良地质条件.在隧道穿越这些区域时,工作面极易发生塌方、大变形、突涌水以及有害气体泄漏等事故,可能导致严重的人员伤亡和经济损失.这些不良地质条件也广泛存在于我国西南其他地区.随着交通基础设施的快速发展和隧道建设需求的增加,本研究提出的钻爆法隧道支护智能决策方法具有广泛的推广应用潜力.

本文基于围岩与支护数据,结合现有的公路和铁路隧道设计规范中的初期支护参数建议值,运用多种机器学习算法,构建了一种融合观测信息与结构安全的支护方案预测模型.该模型可以在一定程度上辅助钻爆法隧道施工现场的支护方案及钢架布置间距的快速决策.这一新方法有助于现场决策更加高效,既能避免因决策延误导致的塌方等安全风险,也能防止支护参数选择不当引发的资源浪费.

1 研究方法 with 数据来源

1.1 现场数据采集

本研究选取宣会高速沿线多条在建的分离式两车道隧道施工数据作为数据库的主要来源.数据采集主要通过摄影测量法这一非接触式手段,获取了 10 余条在建隧道的工作面原始高清图像.隧道岩体特征图像数据库在初步筛选、裁剪、数据扩充和标记处理后得以建立^[5].在基于机器视觉的特征提取方面,本研究采用团队前期已建立的卷积神经网络(Convolutional Neural Networks, CNN)对工作面图像进行特征识别与量化分割.通过训练、验证和测试,智能提取并统计了各类岩体特征,包括围岩结构类别(RCS)^[5]、软弱夹层(WIA)^[6]及地下水面积(GWA)和类别(GWC)^[8]、节理迹线参数(主倾角 PTA、最大长度 TL_{max} 、平均长度 TL_a 、密度(TD)、强度(TI)^[7]等,本研究将这项技术拓展应用至新的地质场景下,并进一步应用其提取结果至本支护决策工作,作为模型的输入参数.另一方面,接触式测量方法则用于获取岩体的单轴抗压强度(UCS)和风化程度(WD).每个隧道工作面的岩体样本通过现场单轴压缩测试测得岩石单轴抗压强度,而风化程度则借助地质锤和回弹仪等设备进行评估.隧道的当前埋深(H)以及隧道走向(TS)由现场工程师手动记录.因此,本研究在数据收集过程中结合了接触式和非接触式方法,从而客观地评价岩体质量.

对于一个隧道工作面,可以形成一组 13 维的多源异构的特征数据库.指标的选取主要来自对当前最广泛应用的岩石分类系统的参照,包括 RMR^[26]、Q^[27]、ISRM^[28] 及 BQ^[29] 等.本研究从这些系统中确定了 3 大类指标:(1)岩体不连续面关键特征,包括岩体软弱夹层、节理裂隙迹线等;(2)围岩的基本特性,包括岩体表观结构、岩石强度、风化程度和地下水等;(3)隧道赋存的场地条件,包括隧道埋深和开挖走向等.图 1 展示了采用接触式和非接触式测量方法后,多源异构山岭隧道数据库中的 10 个定量和 3 个定性指标及其来源.本研究将采用上述参数作为数据驱动模型的输入参数.

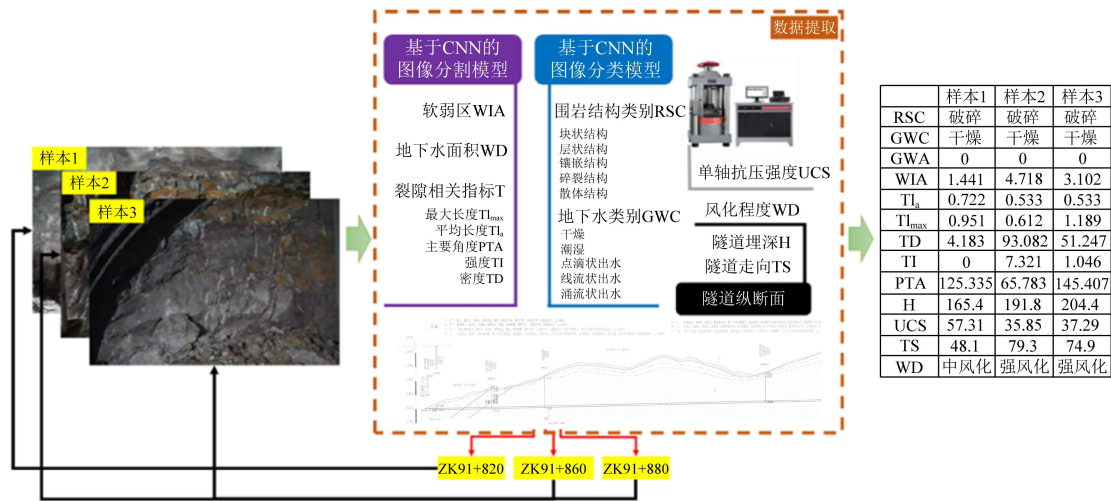


图 1 主要岩体特征的采集提取过程

Fig.1 Acquisition and extraction process of major rock features

为实现隧道初期支护预测,多源异构山岭隧道数据库中的每一组数据需要建立到每一组初期支护方案及参数的映射.因此,对基于云南宣会隧道工作面围岩特征信息建立的多源异构山岭隧道数据与其最终敲定的支护方案(代号分别为 SF4a、SF4b、SF5a、SF5b、SF5c)进行了对应.值得注意的是,数据集中采用每个开挖面的支护方案,是在专业工程师根据详尽的地勘信息,结合数值模拟和工程经验给出的初期设计方案的基础上,现场观察记录出露围岩实际情况并结合钻探地下水和取样试验指标,再修正试算给出的更准确的动态实际施作方案,这确保后续模型将学习更为准确的动态决策思路.每类支护方案详细覆盖了喷砼支护施作的厚度,锚杆支护采用的型号、长度和间距,钢筋网支护的规格和搭接间距,钢拱架支护的钢架型号和间距,以确保现场施工人员能严格按设计方案施工.这 5 类支护方案的详细数据见表 1.

表 1 5 类支护方案

Table 1 Details of the five types of support options

支护方案	喷砼	锚杆	钢筋网	钢架
	厚度/cm	长度及间距/m	间距/cm	间距/m
SF4b	C ₃₀	φ22 砂浆锚杆	φ8 单层	116
	23	L=2.5/0.6×1	25×25	0.8
SF4a	C ₃₀	φ22 砂浆锚杆	φ8 单层	116
	23	L=2.5/1.0×1	25×25	1
SF5b	C ₃₀	φ25 中空注浆锚杆	φ8 单层	118
	25	L=3.0/0.6×1	20×20	0.6
SF5a	C ₃₀	φ25 中空注浆锚杆	φ8 单层	118
	25	L=3.0m/0.8×1	20×20	0.8
SF5c	C ₃₀	φ25 中空注浆锚杆	φ8 单层	120
	27	L=3.0m/0.6×1	20×20	0.6

在隧道施工过程中,针对不同跨度和围岩等级,公路及铁路隧道设计规范均对各支护参数提供了建议值.在实际工程设计中,围岩等级、隧道埋深及跨度确定,钢筋网的间距也随之确定.而喷射混凝土的厚度、锚杆的长度与间距、钢架型号在工程现场的可协调空间较小.在施工中,钢架的安装由工人手动调整,其间距控制与锚杆间距相似,精度通常可控制在 3cm 范围内.相较于锚杆间距,钢架间距具有更高的现场快速决策灵活性,能够更好地适应施工过程中难以预见的变化.综合上述考虑,本文拟在支护方案预测的基础上,在 V 级围岩情况下,将最有决策价值的钢架间距作为支护参数预测目标.

1.2 多源异构数据库格式与组成

基于云南宣会高速沿线隧道建设过程中收集的数据,建立了围岩参数与支护参数对应关系的数据库,分

别为围岩-支护方案数据库和围岩-支护参数数据库.通过机器学习方法,构建了围岩-支护方案分类预测模型和围岩-支护参数回归预测模型.围岩特征参数的获取方法主要借鉴文献[30],通过CNN方法提取了云南宣会高速沿线隧道中的围岩结构类别、地下水类别、地下水面积、软弱区面积、裂隙平均长度、裂隙最大长度、裂隙密度、裂隙强度和主裂隙角度共9个参数,提取算法本身的精确度已在原文中得以验证.隧道埋深和走向由设计文件获取,并由现场工程师记录实际值;单轴抗压强度和风化程度则分别通过取样试验和现场测量评估得到.围岩-支护方案数据库包含133组样本数据,每组包括14个数据项,其中13个为开挖面特征参数,1个为支护方案参数.围岩-支护参数数据库包含76组样本,每组同样包括14个数据项,其中13个为开挖面特征参数,1个为钢架间距参数.上述所有数据已经过团队与施工台账逐一校对并交由专业工程师验证其合理性和准确性.围岩-支护方案数据库的特征见表2.在输出参数方面,为施工现场提供了单独输出衬砌方案和输出具体的初期支护参数两种参考维度.

表2 围岩-支护方案数据库的参数种类与数据特征

Table 2 Parameter types and data characteristics of the enclosure-support scheme database

变量	符号	单位	平均值	标准差	最小值	中值	最大值
围岩结构类别	RSC	-	2.489	1.229	1	2	5
地下水类别	GWC	-	2.406	1.200	1	2	5
地下水面积(开挖面处)	GWA	m ²	8.493	7.826	0	7.824	26.593
软弱区面积	WIA	m ²	3.521	2.752	0	3.051	10.330
裂隙平均长度	TL _a	m	0.503	0.230	0.022	0.522	1.122
裂隙最大长度	TL _{max}	m	0.922	0.258	0.283	0.928	1.637
裂隙密度	TD	-	40.309	23.346	1.046	36.605	103.540
裂隙强度	TI	-	7.801	6.383	0	6.275	25.101
主裂隙角度	PTA	°	97.705	50.636	3.378	113.309	186.849
隧道埋深	H	m	221.624	87.352	68	217	370
单轴抗压强度	UCS	MPa	20.084	12.247	3.55	17.50	54.89
隧道走向	TS	°	61.481	18.827	14.1	63.6	89.9
风化程度	WD	-	3.150	0.996	1	3	5
输出参数	衬砌方案	SP	2.992	1.490	1	3	5

针对V级围岩条件下的支护参数——即钢架间距的预测模型进行研究.剔除强度高于V级围岩的样本后,剩余样本数量为76个.在实际施工过程中,设计文件中的支护参数经常因现场围岩条件、地下水等因素发生变化,并记录在施工日志和台账中.通过对这些文档的整理和分析,将76个V级围岩的数据样本与相应的钢架间距对应.钢架间距从0.5m到1.0m不等,本文用于构建钢架间距回归预测模型的数据见表3.

表3 围岩-支护参数数据库

Table 3 Database of perimeter rock-support parameters

样本编号	1	2	3	4	5	...	75	76	
RSC	块状	镶嵌	块状	层状	镶嵌		块状	块状	
GWC	湿润	湿润	线状流水	滴水	湿润		线状流水	干燥	
GWA	13.827	4.842	17.589	13.357	13.737		13.227	0	
WIA	3.778	3.834	6.001	4.269	2.807		6.727	2.722	
TL _a	0.422	0.289	0.589	0.811	0.411		1.122	0.422	
TL _{max}	0.518	1.323	1.102	0.613	0.581		1.637	1.043	
TD	35.559	20.917	6.275	25.101	28.238	...	1.046	14.642	
TI	2.092	10.459	4.183	7.321	10.459		1.046	0	
PTA	40.031	3.378	154.328	169.71	139.405		174.588	137.081	
H	360	292	330	248	353		299	282	
UCS/MPa	8.53	15.69	17.46	15.97	12.61		24.02	6.45	
TS	84.1	16.9	48.9	60.6	70.8		86	61.7	
WD	未风化	强风化	强风化	微风化	中等风化		未风化	强风化	
输出参数	Spacing	0.6	0.65	0.6	0.8	0.6	...	0.65	0.6

模型搭建使用 python 语言.在模型训练前,对支护方案分类预测和钢架间距回归预测的输入参数进行了数据预处理.为消除不同量纲的影响,采用了标准缩放方法:通过减去均值并将数据缩放到单位方差,使得特征值标准化,标准化后的特征服从标准正态分布.针对文本型数据的处理,使用了 sklearn 库中的 OrdinalEncoder 类,将输入参数中的 3 个文本类数据分别编码为数值标签.经过数据预处理后的围岩-支护方案数据库形式见表 4.

表 4 预处理后的围岩-支护方案数据库

Table 4 Database of pre-treated perimeter rock-support schemes

样本编号	分类型数据			数值型数据					支护方案
	RSC	GWC	WD	GWA	WIA	...	UCS/Mpa	TS	
0	1.0	2.0	1.0	0.68	0.09	...	-0.95	1.21	3.0
1	3.0	2.0	4.0	-0.47	0.11	...	-0.36	-2.38	3.0
2	1.0	4.0	4.0	1.17	0.90	...	-0.22	-0.67	5.0
⋮		⋮				⋮			⋮
130	4.0	2.0	3.0	-0.09	1.07	...	0.04	0.65	1.0
131	2.0	2.0	2.0	-0.81	-0.74	...	0.90	0.14	1.0
132	4.0	3.0	2.0	-0.57	-1.28	...	1.29	0.95	1.0

2 支护方案与支护参数智能预测模型

2.1 特征指标组合选取

对于支护方案预测数据集的建立,先将 13 个特征指标按照两个维度进行分组,拟重组尝试出最佳特征组合.其中第 1 个维度是机器学习维度,不涉及实际物理意义,第 2 个维度则考虑实际物理意义.

维度 I 分为:①文本属性组,包括 RSC、GWC、WD 这 3 项特征;②重要数值特征组,包括 PTA 和 H 这 2 项;③第 3 个组为其他 8 项数值型特征.维度 II 分为:①裂隙相关组,包括 Tl_a 、 Tl_{max} 、TD、TI 和 PTA 这 5 项;②强度组,包括 RSC、WD、WIA 和 UCS 这 4 项;③地下水组,包括 GWC 和 GWA 这 2 项;④走向组,包括 TS 这 1 项;⑤埋深组,包括 H 这 1 项.

在上述分组基础上,构建了 12 种特征组合,详见表 5.其中各组合的定义如下:

F-1 组合包含了所有 13 个特征;F-2 组合包含文本属性组和重要数值型特征组;F-3 组合去除裂隙相关组中与强度相关的特征 TD 和 TI;F-4 组合保留了所有文本属性组,并使强度组和地下水组各保留 1 个特征;F-5 组合使地下水组仅保留 1 个特征;F-6 组合去除裂隙组中的长度相关特征 Tl_a 和 Tl_{max} ;F-7 组合去除走向组特征;F-8 组合在保证文本属性组和重要数值型特征组完全保留的前提下,强度组和裂隙组各保留 1 个非重要数值型特征;F-9 组合去除文本属性组;F-10 组合尝试去除重要数值型特征组中的特征 PTA;F-11 组合同样去除重要数值型特征组中的特征 H;F-12 组合去除重要数值型特征组中的所有特征.

表 5 特征组合

Table 5 Combination of features

特征组合	RSC	GWC	WD	GWA	WIA	Tl_a	Tl_{max}	TD	TI	PTA	H	UCS	TS
F-1	√	√	√	√	√	√	√	√	√	√	√	√	√
F-2	√	√	√							√	√		
F-3	√	√	√	√	√	√	√			√	√	√	√
F-4	√	√	√	√		√	√	√	√	√	√		√
F-5	√	√	√		√	√	√	√	√	√	√	√	√
F-6	√	√	√	√	√			√	√	√	√	√	√
F-7	√	√	√	√	√	√	√	√	√	√	√	√	
F-8	√	√	√	√	√	√	√	√	√	√	√	√	√
F-9				√	√	√	√	√	√	√	√	√	√
F-10	√	√	√	√	√	√	√	√	√		√	√	√
F-11	√	√	√	√	√	√	√	√	√	√		√	√
F-12	√	√	√	√	√	√	√	√	√			√	√

为根据历史决策实现未来支护方案的预测,需要采用监督学习分类算法,初选了8种表现较好的经典算法进行性能比选,其分别为逻辑回归(LR)、支持向量机(SVM)、K最近邻(KNN)、决策树(DT)、随机森林(RF)、自适应提升(AdaBoost)、梯度提升(GB)和极限梯度提升(XGB).此处仅简要介绍AdaBoost算法和RF算法:Adaboost算法通过迭代调整样本权重与弱分类器组合,可有效提升支护方案分类任务中对多源异质数据的处理鲁棒性.其聚焦分类错误样本的机制,特别适用于支护决策中关键特征(如软弱区分布、裂隙密度)与非关键特征的差异化权重分配需求,能够降低地质判识误差的累积传播风险;随机森林算法采用Bagging集成与随机子空间策略,通过构建多棵决策树来降低回归预测方差.该特性可抑制支护参数预测中因岩体参数非线性耦合引起的过拟合问题,同时提供特征重要性排序,为工程决策提供可解释性依据.二者在分类-回归任务中的互补优势,符合支护智能决策中“方案选择-参数量化”的双阶段建模需求.

对不同特征组合下支护方案预测模型的算法准确率进行评估.具体方法:将验证集中开挖面的特征数据按12种特征组合进行分组,并将每组数据分别输入8个训练好的算法模型,计算输出预测为正例的样本数与总输入样本数的比值,得到如图2(a)所示的模型准确率.

根据折线趋势(图2(a)),特征组合10、11、12的准确率相较于前9个组合有显著下降,且在所有算法中,KNN算法的表现最为不佳,其准确率均值为0.524,明显低于其他7种算法的均值(0.735~0.819).因此,特征组合F-10、F-11、F-12以及KNN算法被舍弃.

舍弃这些组合和算法后,重绘精简后的折线图(图2(b)),并导出模型准确率表格(表6).

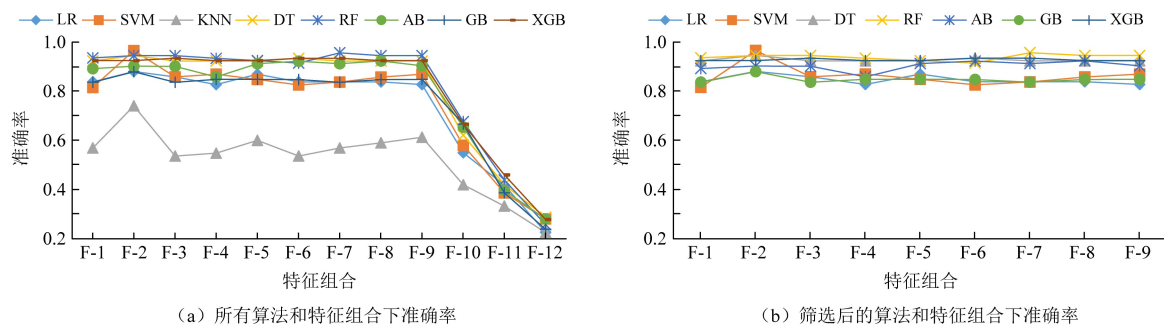


图2 各算法在不同特征组合下的准确率

Fig.2 Accuracy of each algorithm with different combinations of features

表6 优化后各算法在不同特征组合下的准确率

Table 6 Accuracy of the optimized algorithms with different combinations of features

特征组合	监督学习算法							特征均值
	LR	SVM	DT	RF	AB	GB	XGB	
F-1	0.839	0.816	0.924	0.936	0.893	0.837	0.925	0.881
F-2	0.881	0.966	0.946	0.946	0.903	0.880	0.925	0.921
F-3	0.859	0.859	0.924	0.946	0.902	0.837	0.935	0.895
F-4	0.828	0.870	0.924	0.935	0.859	0.849	0.925	0.884
F-5	0.870	0.849	0.924	0.925	0.913	0.849	0.925	0.894
F-6	0.839	0.826	0.935	0.915	0.923	0.848	0.935	0.889
F-7	0.839	0.838	0.924	0.957	0.913	0.837	0.935	0.892
F-8	0.839	0.858	0.924	0.946	0.924	0.848	0.925	0.895
F-9	0.828	0.870	0.924	0.946	0.904	0.849	0.925	0.892
算法均值	0.847	0.861	0.928	0.939	0.904	0.848	0.928	

上述结果表明,均值准确率表现最好的3个算法依次为RF算法、XGB算法和DT算法.其中,RF算法的表现最佳,在特征组合F-7下,其准确率达到最高值0.957.

XGB算法在使用特征组合F-3、F-6和F-7时表现尤为突出,准确率达0.935.基于这3个特征组合的特点,构建了1个新的特征组合F-13,经验证XGB算法在该组合下表现非常理想.

依据上述分析,为各算法分别赋予其最佳输入特征组合(表7).

表7 各算法对应的最佳特征组合

Table 7 The best combination of features corresponding to each algorithm

算法	LR	SVM	DT	RF	AB	GB	XGB
特征组合	F-2	F-2	F-2	F-7	F-6	F-2	F-13
RSC	✓	✓	✓	✓	✓	✓	✓
GWC	✓	✓	✓	✓	✓	✓	✓
WD	✓	✓	✓	✓	✓	✓	✓
GWA				✓	✓		✓
WIA				✓	✓		✓
Tl _a				✓			
Tl _{max}				✓			
TD				✓	✓		
TI				✓	✓		
PTA	✓	✓	✓	✓	✓	✓	✓
H	✓	✓	✓	✓	✓	✓	✓
UCS				✓	✓		✓
TS					✓		

对于钢架间距的回归预测,经与上述类似的评价过程后,确定了 RF 算法、SVM 算法和 AdaBoost 算法 3 个优选算法,接着进行了变量重要性评估,得出每个算法特征重要性排序表.首先从重要性最高的特征开始,根据特征的重要性排序,依次从现有特征集中增加一个特征变量,逐步扩展特征组合,直到涵盖所有特征,从而构建多个不同的特征组合.接下来,通过比较不同特征组合下训练模型的均方误差(MSE),选择 MSE 最小的特征组合作为后续模型优化的输入变量.随机森林和 AdaBoost 算法均属于集成算法,其变量重要性评估原理相似,主要基于袋外数据(OOB)计算袋外误差.首先,计算算法的初始袋外误差 err_{OOB1} ,然后对袋外样本中的某一特征引入噪声干扰,再次计算袋外误差 err_{OOB2} .若算法有 N_{tree} 个基评估器,则某一特征的重要度计算式为

$$Importance = \sum (err_{OOB2} - err_{OOB1}) / N_{tree} \quad (1)$$

该数值越大,表明该特征对模型的预测贡献越大.通过这种方法,可以精确地评估每个特征对回归预测的影响.对于支持向量机,则在利用线性核函数情况下,算法为各个特征赋予的权重来计算.某个特征的重要度为

$$Importance = weight_i / \sum_1^n weight \quad (2)$$

以随机森林算法处理过程为例,特征重要度最高的两个特征分别为埋深和主裂隙角度,其重要度分别为 0.65 和 0.14.其余的特征重要度相比于前两个则下降很多.首先只输入埋深这一个特征进行预测,此时均方误差是最高的,为 0.012,特征不断增加的情况 MSE 持续下降,直到第 9 个特征的输入,MSE 降到最低为 0.0056.因此将重要度前 9 项作为输入参数构建模型时,模型初步表现最佳.经上述处理,得到 3 种算法对应的最佳特征组合(表 8).

2.2 模型优化

支护方案预测模型训练过程中采用网格搜索计算进行参数调优.使用 sklearn 库中模型选择模块 `sklearn.model_selection` 中的 `GridSearchCV` 进行模型的超参数调整.以准确率为优化目标函数,获得其最高时的最优参数组合.先通过经验和本身数据的特征和规模,确定各个算法需要调整的超参数的种类和范围,再通过网格搜索方法循环

遍历尝试所有参数组合,从而获得使算法有最佳表现的组合,作为参数取值组合^[31].超参数寻优范围见表 9,

表8 回归算法特征组合

Table 8 Combination of regression algorithm features

特征	随机森林	支持向量机	AdaBoost
RSC		✓	
GWC	✓	✓	✓
WD			✓
GWA	✓	✓	✓
WIA	✓		✓
Tl _a	✓		✓
Tl _{max}			✓
TD	✓		
TI	✓		✓
PTA	✓	✓	✓
H	✓	✓	✓
UCS	✓		✓
TS			✓

寻优结果见表 10.

表 9 超参数寻优范围

Table 9 Hyperparameter optimization range

算法	超参数	可选值
LR	Penalty	['l1', 'l2']
	solver	'newton-cg', 'lbfgs', 'liblinear', 'sag', 'saga'
	multi_class	'ovr', 'multinomial'
	C	[0.01, 0.05, 0.1, 0.25, 0.5, 0.75, 1, 10]
SVM	Kernel	'linear', 'poly', 'rbf', 'sigmoid'
	C	[0.05, 0.1, 0.25, 0.5, 0.75, 1.0]
DT	criterion	'entropy', 'gini'
	max_depth	[3, 10]
	min_samples_leaf	[1, 10]
RF	n_estimators	[0, 200]
	max_depth	[0, 20]
	criterion	'gini' or 'entropy'
AB	n_estimators	range(1, 100, 5)
	algorithm	'SAMME', 'SAMME.R'
	learning_rate	np.arange(0.01, 1, 0.1)
GB	learning_rate	np.arange(0.01, 1, 0.1)
	n_estimators	np.arange(10, 200, 10)
	subsample	np.arange(0.01, 1.0, 0.1)
	max_depth	np.arange(2, 10, 1)
	min_samples_split	np.arange(2, 10, 1)
	min_samples_leaf	np.arange(1, 10, 1)
XGB	n_estimators	np.arange(5, 100, 5)
	learning_rate	np.arange(0.01, 1, 0.1)
	max_depth	np.arange(1, 10, 1)
	min_child_weight	np.arange(1, 10, 1)
	gamma	np.arange(0, 1, 0.1)
	colsample_bytree	np.arange(0, 1, 0.1)

针对支护参数预测模型,用学习曲线的方法确定算法各个超参数的搜索范围,作 5 折交叉验证实现参数寻优.以 MSE 为目标函数寻得的最佳参数见表 11.

表 11 不同算法对应的超参数优化结果

Table 11 Hyperparameter optimization results corresponding to different algorithms

算法	超参数	最佳值	MSE
RandomForest	n_estimators	200	0.0048
	max_depth	76	
SVR	kernel	rbf	0.0114
	gamma	0.01	
	C	1.0	
	epsilon	0.01	
AdaBoost	n_estimators	13	0.0049
	learning_rate	0.26	

的计算方法,宏平均将每个类别视为同等重要,微平均将每个样本视为同等重要.在选择宏平均和微平均时,需要根据具体样本情况来决定.宏平均更适用于类别之间数量相近的情况,而对于类别不平衡的情况,微平均更为适用,因为其对每个样本的评估指标计算的权重相同.由于样本中各个类别的数量十分接近,所以选择宏平均重点介绍.

对于一个 K 分类问题,其混淆矩阵为一个 $K \times K$ 的矩阵,用来记录模型预测结果与真实结果之间的差异.

表 10 支护方案预测不同算法对应的超参数优化结果与准确率指标

Table 10 Hyper-parameter optimization results and accuracy indexes corresponding to different algorithms for support scheme prediction

算法	超参数	最佳参数	准确率
LR	Penalty	'l1'	0.967
	solver	'saga'	
	multi_class	'multinomial'	
	C	0.75	
SVM	Kernel	linear	0.968
	C	1.0	
DT	criterion	'entropy'	0.979
	max_depth	3	
	min_samples_leaf	3	
RF	n_estimators	50	0.978
	max_depth	13	
	criterion	'gini'	
AB	n_estimators	6	0.957
	algorithm	'SAMME.R'	
	learning_rate	0.41	
GB	learning_rate	0.91	0.957
	n_estimators	15	
	subsample	0.91	
	max_depth	5	
	min_samples_split	2	
	min_samples_leaf	1	
XGB	n_estimators	15	0.967
	learning_rate	0.31	
	max_depth	4	
	min_child_weight	1	
	gamma	0	
	colsample_bytree	0.9	

将 3 种算法的最优参数输入到模型中,对训练集各样本的钢架间距进行拟合预测,预测结果如图 3 所示.

由上可见,随机森林模型和 AdaBoost 模型对钢架间距的拟合效果明显优于 SVM 算法, MSE 分别为 0.0048 和 0.0049.

3 支护智能决策预测模型的评估与验证

3.1 评估方法概述

对于多分类问题,常用的评价指标包括准确率、宏平均精确率、宏平均召回率、微平均精确率、微平均召回率和微平均 $F1$ 值.其中,宏平均和微平均分别为两种不同的




图3 3种算法训练集拟合结果对比

Fig.3 Comparison of the fitting results of the training set of the three algorithms

混淆矩阵的每一行表示真实类别,每一列表示预测类别,矩阵对角线上的元素表示预测正确的样本数,其他元素表示预测错误的样本数.以多分类混淆矩阵为基础的3类宏平均指标介绍如下.

宏平均精确率(Macro-average Precision, P_{macro})指将每个类别的精确率求平均,即所有类别的精确率的算术平均值.其计算公式为

$$P_{macro} = \frac{1}{K} \sum_{i=1}^K \frac{TP_i}{TP_i + FP_i} \quad (3)$$

式中: K 为类别数; TP_i 、 FP_i 分别为第*i*个类别中模型正确预测为该类别和错误预测为该类别的样本数.宏平均召回率(Macro-average Recall, R_{macro})指将每个类别的召回率求平均,即所有类别的召回率的算术平均值.其计算式为

$$R_{macro} = \frac{1}{K} \sum_{i=1}^K \frac{TP_i}{TP_i + FN_i} \quad (4)$$

式中: K 为类别数; TP_i 、 FN_i 分别为第*i*个类别中模型正确预测为该类别和错误预测为其他类别的样本数.宏平均F1值(Macro-average F1-score, $F1_{macro}$)指将每个类别的F1值求平均,即所有类别的F1值的算术平均值.其计算式为

$$F1_{macro} = \frac{1}{K} \sum_{i=1}^K \frac{2 \times P_i \times R_i}{P_i + R_i} \quad (5)$$

式中: R_i 为类别数; P_i 和 R_i 分别为第*i*个类别的精确率和召回率.

3.2 支护方案预测模型性能评估

针对每个算法匹配了最合适的特征组合和超参数,训练出7个机器学习分类预测模型.对7个模型的精确率(Precision)、召回率(Recall)、F1值、宏/微平均进行计算和评价,讨论7个模型针对实际情况不同支护方案的分类性能,结果如图4所示.

从宏平均指标来看,本文所构建的模型对不同类别的支护方案分类能力均较强.其中,AdaBoost模型表现最好,所有指标均在其他模型之上,其精确率、召回率和F1值分别为0.960,0.978和0.966.




图4 不同算法的宏平均

Fig.4 Macro averaging for different algorithms

从机器学习分类模型的通用评价指标来看,表现最好的3个模型为AdaBoost、DT和GB.但结合工程实际,需要考虑分类错误导致的经济和安全代价,错误地将“需要更强支护方案分类为低支护强度方案”和“需要较弱支护方案分类为强支护强度方案”,后者的风险是过度支护,造成部分经济损失,而前者的后果则可能会引发隧道坍塌等重大工程事故,危及施工人员的生命安全,同时造成更严重的经济损失.

		预测类别				
		S4b	S4a	S5b	S5a	S5c
真实类别	S4b	0	1	1	1	1
	S4a	2	0	1	1	1
	S5b	3	2	0	1	1
	S5a	4	3	2	0	1
	S5c	5	4	3	2	0

图5 风险表格示意
Fig.5 Schematic risk table

为将上述现实因素纳入评估体系,先将上述所有支护方案代号按照强度从低到高排列为 SF4b、SF4a、SF5b、SF5a、SF5c.如分类错误风险图(图5)所示,当分类正确时,对应对角线处的风险为0;当出现“高估所需支护强度”情况,对应对角线右上角部分,均为经济损失.当出现“低估所需支护强度”情况,对应对角线左下角部分,且预测强度和实际需要的强度所差的级别越多,风险越大.

将利用分类错误风险表(图5)和各模型混淆矩阵热力图(图6)来对模型的代价进行评估,从加入了错误代价的角度,对模型进行评价.按照支护方案强度由弱到强的顺序(SF4b SF4a SF5b SF5a SF5c)绘制出3个机器学习评价指标层面最优的算法混淆矩阵(图6).

各热力图中方格的数字代表被分类到各类别的占比.计算模型的代价时,利用各模型热力图各方格中的比率,乘以分类错误风险表中对应方格的风险级别,再分类汇总为这个模型的代价值.公式为




图6 3个模型的混淆矩阵热力图
Fig.6 Heat map of confusion matrix for three models

$$C = \sum_{i=1}^N \sum_{j=1}^N p_{ij} \times r_{ij} \tag{6}$$

式中: C 为模型的代价值; N 为分类的类别数; p_{ij} 为混淆矩阵中第*i*行第*j*列的值; r_{ij} 为风险表中第*i*行第*j*列的风险等级.计算得各个模型的代价值见表12.

表12 各模型代价值
Table 12 Model proxy values

模型	LR	SVM	DT	RF	AB	GB	XGB
代价值	1.08	1.21	0.42	1.42	0.33	0.42	0.69

综合考虑机器学习评价指标与现实应用,最佳模型为 AdaBoost 模型,其分类精确率、召回率和 $F1$ 值分别为 0.960,0.978 和 0.966,代价值为 0.33,在所有测试集 40 个样本中,仅一次错误地将 SF5c 样本分类为 SF5a.

3.3 支护参数预测模型性能评估

将 RF、SVR、AdaBoost 这 3 个模型应用到从未被计算过的 22 个测试集上,用 MAE 和 R^2 评价参数对模型进行最后评估.图 7 所示为 3 个模型对测试集的预测结果.

MAE 值是预测值与真实值之间个体差异的体现,其值 ≥ 0 ,越接近 0,代表模型表现越好. R^2 为 0~1,越接近 1,表示观测数据越精确.图 8 为 3 个模型的 MAE 指标条形图比较.从图 8 可直观看到,在模型是否预测到正确的数值这一评价方面,随机森林和 AdaBoost 的表现都显著好于 SVR,且随机森林的 MAE 最低.观察到随机森林测试集的 MAE 为 0.0416,而训练集则为 0.0243,没有出现过拟合现象.




图7 不同模型对测试集预测结果对比

Fig.7 Comparison of prediction results for different pairs of test sets

在模型是否拟合了足够的信息方面,算法 SVR 的 R^2 指标表现较差,RF 和 AdaBoost 在训练集上的表现均超过 0.9,如图 9 所示.但 RF 在测试集上的表现明显优于 AdaBoost,综合考虑选择随机森林算法模型作为最优的钢架间距预测模型.

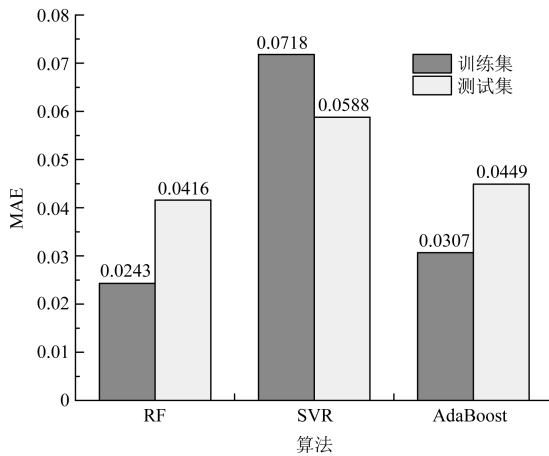


图8 不同算法的 MAE 比较

Fig.8 Comparison of MAE for different algorithms

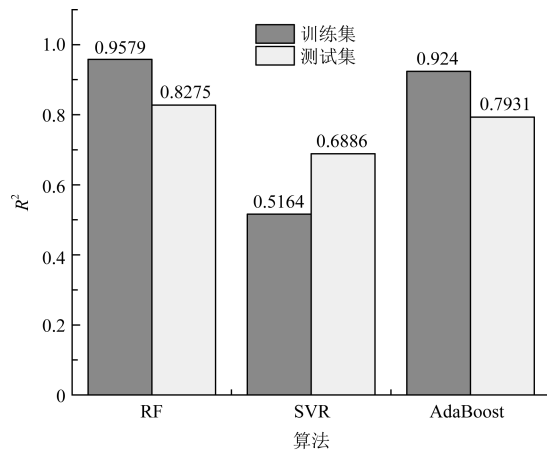


图9 不同算法的 R^2 比较

Fig.9 Comparison of R^2 for different algorithms

4 结论与讨论

本研究以云南省宣会高速隧道工程为依托,基于非接触式机器视觉与多源数据融合技术,构建了钻爆法隧道初期支护智能决策模型体系,得出主要结论如下:

(1)采用卷积神经网络图像处理框架实现了围岩关键特征的自动化提取,包括:围岩结构类别、软弱夹层及地下水面积和分布、节理迹线参数(倾角、长度、密度、强度等);通过现场准确测量获取岩体的单轴抗压强度和风化程度;通过施工台账记录开挖面埋深、隧道轴向、实际施作的支护方案和支护钢架间距等信息,由此建立包含岩体几何、隧道环境、物理力学参数和支护施作信息的 15 维围岩-支护数据库;

(2)通过特征选择、特征组合等特征工程方法,得到了适合不同算法的特征组合.通过网格搜索得到同数据输入条件下各模型的最优超参数组合.从准确率、精确率和召回率等评估角度,最终确定了 AdaBoost 分类模型在支护方案预测中表现出精确率为 0.960、召回率为 0.978、 $F1$ 值为 0.966 的最优性能;

(3)随机森林回归模型在五级围岩钢架间距预测中达到 $MAE = 0.0416$ 、 $R^2 = 0.8275$ 的最佳性能,且预测结果符合施工精度要求.模型的输入参数包括:地下水类别、地下水面积、软弱区面积、平均裂隙长度、裂隙密度、裂隙强度、主裂隙角度、埋深以及单轴抗压强度.以上智能决策方法已在宣会高速黑土隧道和金乐隧道工

程现场应用验证,相较于传统决策流程,效率上显著提高而准确性基本持平,同时该结果也印证了文献[29]中提出的图像识别围岩特征工作的准确性和实用性;

(4)通过应用基于卷积神经网络的机器视觉围岩表观参数智能提取方法,补充少量必要的施工台账记录数据,快速获取了初支智能决策模型输入参数,经算法优化和比选研究,实现了钻爆法隧道现场施工高效准确的智能决策,该方法在工程现场具备应用条件,可成为现场工程师的有效决策辅助.但本研究中构建支护方案预测模型数据集的数据量偏小,围岩集中在山岭隧道四级、五级围岩,隧道断面尺寸单一,对于不同工程背景的隧道较难预测出可信的结果.后续研究可增加围岩-支护数据集的多样性,构建多种断面宽度、多种岩性、多种围岩级别的数据集,或实现与传统力学计算方法的融合,以提高泛化性能.此外,随着大语言模型的迅猛发展,从施工记录文件自动化提取信息也成为可能,这将使决策进一步智能化.

参 考 文 献

- [1] Ge Y, Tang H, Xia D, et al. Automated measurements of discontinuity geometric properties from a 3D-point cloud based on a modified region growing algorithm[J]. *Engineering Geology*, 2018, 242: 44-54
- [2] Huang Z K, Pitilakis K, Argyroudis S, et al. Selection of optimal intensity measures for fragility assessment of circular tunnels in soft soil deposits[J]. *Soil Dynamics and Earthquake Engineering*, 2021, 145: 106724
- [3] Vöge M, Lato M J, Diederichs M S. Automated rockmass discontinuity mapping from 3-dimensional surface data[J]. *Engineering Geology*, 2013, 164: 155-162
- [4] Xiao S, Zhang J, Ye J, et al. Establishing region-specific N-Vs relationships through hierarchical Bayesian modeling[J]. *Engineering Geology*, 2021, 287: 106105
- [5] 杨晓华, 肖靖, 辛延甫, 等. 黄土隧道洞口浅埋段塌方冒顶处治及效果分析[J]. *建筑科学与工程学报*, 2021, 38(5): 118-126
Yang Xiaohua, Xiao Jing, Xin Yanfu, et al. Treatment and effect analysis of collapse and roof fall in shallow buried loess tunnel entrance[J]. *Journal of Architecture and Civil Engineering*, 2021, 38(5): 118-126
- [6] Chen J, Yang T, Zhang D, et al. Deep learning based classification of rock structure of tunnel face[J]. *Geoscience Frontiers*, 2021b, 12(1): 395-404
- [7] Chen J, Zhang D, Huang H, et al. Image-based segmentation and quantification of weak interlayers in rock tunnel face via deep learning[J]. *Automation in Construction*, 2020, 120: 103371
- [8] Chen J, Zhou M, Huang H, et al. Automated extraction and evaluation of fracture trace maps from rock tunnel face images via deep learning[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2021c, 142: 104745
- [9] Chen J, Zhou M, Zhang D, et al. Quantification of water inflow in rock tunnel faces via convolutional neural network approach[J]. *Automation in Construction*, 2021d, 123: 103526
- [10] García-Luna R, Senent S, Jurado-Piña R, et al. Structure from Motion photogrammetry to characterize underground rock masses: Experiences from two real tunnels[J]. *Tunnelling and Underground Space Technology*, 2019, 83: 262-273
- [11] Wang F Y, Zhou M L, Zhang D M, et al. Random evolution of multiple cracks and associated mechanical behaviors of segmental tunnel linings using a multiscale modeling method[J]. *Tunnelling and Underground Space Technology*, 2019, 90: 220-230
- [12] Zhang J Z, Huang H W, Zhang D M, et al. Effect of ground surface surcharge on deformational performance of tunnel in spatially variable soil[J]. *Computers and Geotechnics*, 2021a, 136: 104229
- [13] Leu S S, Chen C N, Chang S L. Data mining for tunnel support stability: Neural network approach[J]. *Automation in Construction*, 2001, 10(4): 429-441
- [14] 刘佳宝. 铁路隧道结构设计系统的研究与开发[D]. 北京: 北京交通大学, 2010
Liu Jiabao. Research and development of structural design system for railway tunnels[D]. Beijing: Beijing Jiaotong University, 2010
- [15] Jiang A N, Wang S Y, Tang S L. Feedback analysis of tunnel construction using a hybrid arithmetic based on support vector machine and particle swarm optimisation[J]. *Automation in Construction*, 2011, 20(4): 482-489
- [16] 孙中秋, 袁松, 肖春红. 基于工程经验法的山岭公路隧道信息化设计体系研究及应用[J]. *隧道建设(中英文)*, 2021, 41(5): 849-857
Sun Zhongqiu, Yuan Song, Xiao Chunhong. Research and application of an informatized design system for mountain highway tunnels based on engineering empirical methods[J]. *Tunnel Construction*, 2021, 41(5): 849-857
- [17] 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
- [18] Chen J, Yang T, Zhang D, et al. Deep learning based classification of rock structure of tunnel face[J]. *Geoscience Frontiers*, 2021, 12(1): 395-404
- [19] Chen J, Zhou M, Zhang D, et al. Quantification of water inflow in rock tunnel faces via convolutional neural network approach[J]. *Automation in Construction*, 2021, 123: 103526
- [20] Chen J, Zhou M, Huang H, et al. Automated extraction and evaluation of fracture trace maps from rock tunnel face images via deep learning[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2021, 142: 104745
- [21] Chen J, Zhang D, Huang H, et al. Image-based segmentation and quantification of weak interlayers in rock tunnel face via deep learning[J]. *Automation in Construction*, 2020, 120: 103371

- [22] Zhou M, Chen J, Huang H, et al. Multi-source data driven method for assessing the rock mass quality of a NATM tunnel face via hybrid ensemble learning models[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2021, 147: 104914
- [23] Erharter G H, Hansen T F, Liu Z, et al. Reinforcement learning based process optimization and strategy development in conventional tunneling[J]. *Automation in Construction*, 2021, 127: 103701
- [24] Liu J, Jiang Y, Zhang Y, et al. Influence of different combinations of measurement while drilling parameters by artificial neural network on estimation of tunnel support patterns[J]. *Geomechanics and Engineering*, 2021, 25(6): 439-453
- [25] 满建宏, 黄宏伟, 王飞阳, 等. 基于 MARS 的隧道工作面安全系数预测公式构建研究[J]. *应用基础与工程科学学报*, 2025, 33(2): 526-536
Man Jianhong, Huang Hongwei, Wang Feiyang, et al. Study on construction of tunnel face safety factor prediction formula based on MARS[J]. *Journal of Basic Science and Engineering*, 2025, 33(2): 526-536
- [26] Bieniawski Z. The rock mass rating (RMR) system (geomechanics classification) in engineering practice[M]. *Rock Classification Systems for Engineering Purposes*. ASTM International, 1988
- [27] Barton N, Lien R, Lunde J. Engineering classification of rock masses for the design of tunnel support[J]. *Rock Mechanics*, 1974, 6(4): 189-236
- [28] Barton N. Suggested methods for the quantitative description of discontinuities in rock masses[J]. *ISRM, International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 1978, 15(6): 319-368
- [29] China N S C G o P s R o. TB 10121—2007 technical code for monitoring measurement of railway tunnel[S]. Beijing: China Planning Press, 2014
- [30] Zhou M, Chen J, Huang H, et al. Multi-source data driven method for assessing the rock mass quality of a NATM tunnel face via hybrid ensemble learning models[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2021, 147: 104914

Intelligent Decision-Making for Initial Support of Mountain Highway Tunnel Based on Machine Learning

TONG Yue¹, FANG Yuzhi², DUAN Zhihong¹, ZHOU Mingliang², WEN Yuanyong¹,
HUANG Hongwei², ZHANG Dongming²

(1. Yunnan Xuanhui Expressway Co., Ltd., Qujing 654200, China; 2. Department of Underground Architecture and Engineering, Civil Engineering, Tongji University, Shanghai 200092, China)

Abstract

To address the challenges of real-time construction information acquisition and low historical data utilization in initial support decision-making for drill and blast tunnels, which lead to compromised timeliness and safety, this study proposes an intelligent support decision-making method integrating machine vision and multi-source data-driven approaches. Leveraging construction data from tunnels in the Yunnan Xuanwei-Huize Expressway project, a multi-source database containing 13-dimensional feature parameters was established. These parameters were acquired through convolutional neural network-based visual extraction, on-site recordings, and laboratory tests. An ensemble learning framework was developed to construct dual prediction models for support scheme classification and parameter regression: (1) An AdaBoost-based classification model achieved intelligent support scheme selection with precision, recall, and $F1$ scores of 0.960, 0.978, and 0.966, respectively; (2) A Random Forest-based regression model realized quantitative support parameter prediction with $MAE = 0.0416$ and $R^2 = 0.8275$. Through grid search optimization and error cost evaluation, both models demonstrated superior performance compared to conventional machine learning methods. The research innovatively combines machine vision with multi-source data mining, providing an intelligent decision-making framework for initial support design in mountain tunnels, with significant practical value for engineering applications.

Keywords: drill and blast tunnel; initial support; machine vision; multi-source data; ensemble learning; intelligent decision-making