

文章编号:1005-0930(2023)06-1382-028 中图分类号:U45 文献标识码:A
doi:10.16058/j.issn.1005-0930.2023.06.003

基于机器视觉的隧道围岩智能识别分级与 开挖安全风险研究

黄宏伟¹, 陈佳耀²

(1.同济大学地下建筑与工程系,岩土及地下工程教育部重点实验室,上海 200092;2.北京交通大学土木建筑工程学院,城市地下工程教育部重点实验室,北京 100044)

摘要:岩石隧道建设正逐步进入到长、大、深、难工程阶段.采用新奥法开挖过程中,由于高度不确定性的围岩地质和富有经验的专家数量有限,施工过程面临巨大的围岩质量判别和开挖安全评价挑战.针对岩体结构特征表征模型、精细化分级及评价方法的科学问题,采用现场实测、数据统计、智能算法、数值模拟等手段,提出岩体工作面特征量化提取算法,建立了基于多源异构数据融合的围岩精细化分级模型,开展了复杂地质环境中隧道开挖的安全评价研究.取得了如下主要成果:针对软弱夹层、节理裂隙和地下水的图像语义分割,表观结构图像的分类及围岩的关键特征,基于建立的岩石隧道开挖面摄影图像数据库,应用深度学习算法、超参数与模块优化等方式,实现了特征信息的准确分类和精细化表征;建立了包含岩体几何、环境和物理力学参数的13维多源异构数据库,构建了TPE-GBRT混合预测模型,获取了混合机器学习模型最优化的参数组合,实现了围岩分级RMR指标的精准预测;构建了基于离散裂隙网络DFN的岩体地质环境,由此建立基于开挖面信息的3DEC三维隧道模型,应用强度折减法模拟了隧道连续开挖过程,评价了应力应变、剪切滑移等稳定性特征和安全状态.

关键词:岩石隧道;机器视觉;图像特征;深度学习;围岩分级;数值模拟;多源异构数据;安全评价

近年来,作为我国基础设施建设中重要组成部分的隧道工程飞速发展.预计至2030年,公路、铁路隧道总里程均将突破30000km,其中大部分为岩石隧道.未来岩石隧道将步入长、大、深建设工程阶段,且具有重要战略和军事地位^[1].然而,岩石地层中复杂的工程与水文地质条件给钻爆法开挖建设带来巨大、不可避免的施工难度.针对钻爆法开挖的岩石隧道,由于开挖面围岩分级不清、安全状态判定不当等引起的事故仍频频发生,而工程人员对隧道周边地质特征的识别不精准、对变更滞后的地质勘察报告的高依赖性以及以经验主导判断围岩等级为隧道施工安全判定提供直接指导的现状并未改变.因此,尽管隧

收稿日期:2023-06-01;修订日期:2023-08-12

基金项目:中央高校基本科研业务费(2023JBRC005);国家自然科学基金项目(52279107,52308388)

作者简介:黄宏伟(1966—),男,博士,教授,博士生导师.E-mail:huanghw@tongji.edu.cn

通信作者:陈佳耀(1992—),男,博士,副教授,硕士生导师.E-mail:jychen1@bjtu.edu.cn

道开挖面信息量巨大,充分提取、分析和利用开挖面特征来进行隧道开挖安全风险评估仍面临巨大挑战^[2].加之前期地质勘察难以反映隧道全域工程及水文地质特征,且工程师的经验丰富程度与人力规模难以匹配快速发展的隧道建设规模,往往会导致围岩等级误判、安全评估不准,引起塌方、突水突泥等各种不良后果^[3].国务院《“十四五”国家应急体系规划》将“重大灾害事故定量风险评估技术”列为国家应急体系规划中亟需解决的关键技术.因此,亟需对钻爆法岩体开挖面围岩等级和安全风险进行准确、快速、客观地识别与评估,提高隧道安全状态判断水平,保障隧道施工安全,成为国家基础设施安全建设的重大需求.

在岩石隧道现场识别岩体开挖面特征方面,近年来国际上已逐步从接触式测量向基于机器视觉的岩体信息采集和识别的技术发展,其中数字摄影技术是机器视觉的典型代表^[4].尽管如此,建设期岩体开挖面中样本采集和特征规律辨识仍挑战重重,如开挖面施工过程长期受限于粉尘颗粒、照明强度、均匀度、温湿度及施工工序交替循环导致的可利用摄影时间短等挑战^[5].另外,受到赋水差异、复杂裂隙形态等对岩体表观亮度、像素分布、纹理、灰度值规律等的影响,岩体开挖面图像相较于普通样本图像在特征规律辨识上更加复杂.研究表明:数字图像技术虽具有处理速度快、自动化程度高等优势,但其对岩体自身特征的识别精度、效率及鲁棒性受拍摄外部环境的干扰显著^[6-7].图像分割算法是数字图像处理技术的典型,代表性算法包括边缘检测、线检测及其他检测算法^[8-10].因此迫切需要新的技术方法,能揭示并克服样本获取的复杂环境,快速识别隧道开挖面的主要特征,并对各个特征进行量化提取.

近十年,人工智能技术在隧道及地下工程领域取得了前所未有的飞速发展,由于人工智能技术自身的不断变革和隧道工程领域的巨大需求,其在隧道领域的开发与应用不断被赋予新的生机^[11].在人工智能赋能的工程特征挖掘领域,2019年斯坦福大学 Bergen 等在 Science 杂志指出,深度学习使图像识别更精准、智能及快速,将在地球科学领域迎来持续蓬勃的发展^[12].由此,深度学习框架在岩体特征研究方面得到了井喷式的应用,尤其集中在岩性^[13-18]、岩体裂隙^[19-21]、岩体块体和粒度^[22-25]、结构面^[26-28]及其他^[29-30]被广泛关注的特征方面.目前深度学习在二维岩体工程特征的提取方面存在的主要挑战包括:(1)岩体样本多集中于边坡或裸岩,与施工期隧道开挖所遇的岩体纹理和特征存在较大的差异,后者在图像识别方面难度更大;(2)岩体特征提取主要服务于岩体结构稳定性判定,更多岩体细节需要被深入挖掘,如岩体间的软弱夹层、地下水的赋存分布等,这类特征在当前研究中涉及较少;(3)因像素及纹理复杂分布、辨识难度大等,一些关键特征在视觉信息中尚未被深入表征,如风化程度和破碎程度等.

岩石隧道围岩分级和开挖安全评估不能完全依靠开挖面的地质特征识别,还必须掌握岩体的物理力学参数、隧址环境及稳定性.作为评估隧道安全的重要要素之一的物理力学参数及隧址环境难以完全通过表观图像得到,需结合已有地勘报告和现场开挖的测量得以获取.同时,现有的岩体分类方法通常是将工程观测、测量与专家定性判断采用公式化的形式融合,为工业界建立数据统一平台提供通用框架^[31-37].然而,要建立与现场工况围岩特征匹配的分级系统难度巨大,加之采用钻爆法开挖遭遇的岩体复杂性和不确定性,使建立与项目紧密相关的岩体分类系统变得非常困难,尤其是显式的分级体系.而构建与

项目相关性较大的分级系统需准确收集现场多源数据集,并在下一阶段施工前对隧道围岩进行快速质量评估.因此亟需采用新的技术完善基于工作面信息、力学特性等的快速、准确、客观的综合围岩等级判定模式,进而利用多源异构数据预知或准确判定围岩等级,以指导建设者及时做出调整和应急措施^[38-43].智能化围岩分级方法为实现岩体分类提供了一种有价值的方法^[44-46],但也存在一些挑战^[47-50]:(1)很多智能化学习方法无法全面考虑标准中的指标,甚至随着数据维度的增大会引发指数级计算量的增长;(2)由于现场数据获取难,很多研究的判定数据集存在维数多、基数小等缺陷,给数据模型的建立带来了困难;(3)在数据驱动模型中,确定参数权重对于综合评价分级体系意义重大,很多智能化方法无法揭示和讨论指标权重.可喜的是,机器学习技术可为此复杂关系的建立提供技术保障.2021年中国工程院编制的《全球工程前沿》指出,通过机器学习技术挖掘、利用和分析实现复杂环境下的自适应施工和运维是未来研究中的机遇和挑战.在稳定性分析方面,岩石隧道中复杂的裂隙网络常引发开挖面坍塌、涌水突泥等事故,甚至引起长距离的泥石流而导致大范围区域灾害^[51-55].当前方法在诸如离散裂隙环境中建模难度大、耗时长,且难以在模型中融合机器视觉和岩体参数实现动态量化安全评估.因此亟需有效的计算方法模拟复杂的离散裂隙环境,并能结合获取的参数动态更新分析模型,以实现隧道开挖的动态量化安全评估.3DEC是一款基于离散单元法基本理论以描述离散介质力学行为的计算分析程序.由于其理想的编译性和计算力,近年来在工程领域被不断开发应用^[56-58].而强度折减法则能将专家经验或规范要求与数值模拟融合,计算开挖安全系数,从而实现隧道开挖的安全评价^[59-61].因此,借助机器学习技术融合多源数据实现岩体围岩状态的智能预测,借助数值方法融合机器视觉及环境参数建立离散裂隙网络环境下的三维模型,实现岩石隧道的开挖模拟,可为复杂环境隧道的安全评价提供可靠的科学依据,将成为隧道工程学科发展的前沿.

鉴于此,针对岩石隧道开挖安全,基于机器视觉深度学习识别和开挖面外部数据融合,开展岩石隧道开挖面的安全稳定性评估研究.首先利用机器视觉和接触式测量技术,建立岩石隧道开挖面特征和环境数据的数据库;采用深度学习技术,提出隧道开挖面图像关键特征识别方法;结合环境数据,提出基于集成机器学习技术的岩体围岩质量预测;建立基于开挖面特征和环境数据的三维模型,采用数值模拟方法进行裂隙环境下的隧道动态开挖模拟,分析岩石隧道开挖稳定性,开展裂隙隧道开挖安全评价.限于篇幅,将针对上述关键特征识别、围岩预测和安全评价等方面研究成果进展进行综述.

1 基于机器视觉的围岩智能分级、安全评价流程与原理

1.1 围岩智能化分级与开挖安全风险评估流程

数字摄影测量法是一种结合数字影像与摄影测量基本原理,采用视觉成像、图像匹配、影像插值、模式识别等涵盖多学科的测量方法^[62].在不接触被测物体的情况下,能精准快速地获取物体的相对关系和空间信息,记录被测物在空间中的状态和位置,可测量人员无法直接到达的危险区域.其凭借高效率、高精度、信息全面等优势在工程地质领域得到了国内外学者的广泛关注和应用.经过长时间的理论研究及工程实践,采用数字摄影技术获取岩体结构面信息已逐步在实际工程中展现优势.图1所示为该研究的主要流程,主

要针对开挖面样本难以高效准确获取、核心特征识别提取困难、开挖围岩难以客观预测、开挖安全风险难以定量评估等关键难题,采用深度学习、集成机器学习方法及离散元模拟方法,用于有效识别和量化开挖面图像特征,智能预测隧道围岩质量,实现隧道开挖安全评价,形成集图像获取、图像识别、多源异构特征融合、围岩分级和安全评价的综合技术方案,服务于复杂岩石隧道的安全施工,确保隧道建设的安全稳定。

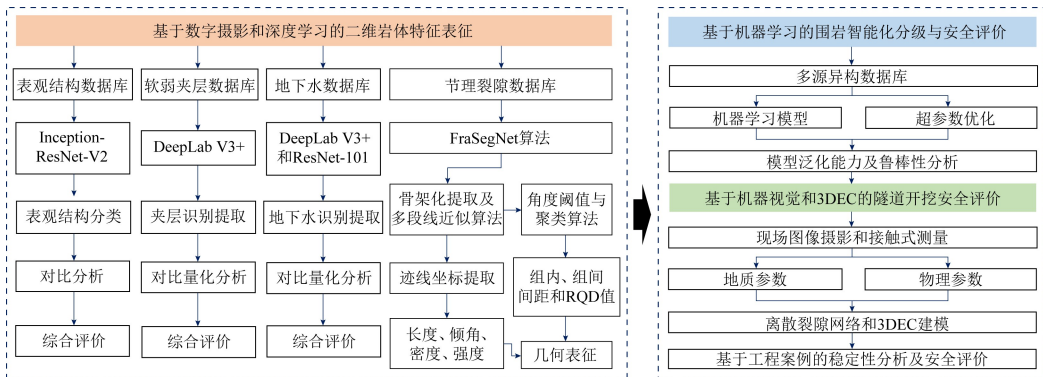


图1 围岩智能化分级与开挖安全风险评估流程

Fig.1 Process of intelligent surrounding rock classification and excavation safety risk assessment

1.2 基于机器视觉的岩体信息识别提取原理

卷积神经网络(Convolutional Neural Network, CNN)是一类含卷积运算并具深度结构的前馈神经网络,是深度学习的代表算法之一。传统的神经网络普遍采用的全连接方式会导致参数量巨大,网络训练时间长、耗能高,甚至难以训练等问题。而CNN则通过卷积运算实现了神经元的局部连接和权值共享,即它是一种不完全连接的网络,这极大地降低了网络的训练难度,也提升了模型的综合表现。故主要采用CNN算法实现目标图像的识别和特征提取。在CNN输入层与输出层之间常具有多个隐含层,这些隐含层主要包括卷积层、池化层、全连接层、归一化层等,此外还可能有反卷积层。另外,除初始化选择模型内部函数及求解方式外,还需进行参数的初始化设置。为区别模型训练完成后的权重、偏置等参数,初始化设置参数被称为超参数,其中主要包括学习率、批次、迭代次数、权重衰减、动量等。由于不同的岩体特征(软弱夹层、节理裂隙、地下水、岩体表面观结构等)识别涉及方法有差别,故不对每一类岩体特征所采用的CNN模型结构进行详细分析。

1.3 基于机器视觉的岩体几何信息提取原理

1.3.1 尺寸转化原理

在语义分割中,识别区域常通过像素特征呈现,而并非区域的实际面积。故需计算工程尺度和图像像素的相关关系,以估算语义分割图像中不同区域的实际面积,如软弱夹层及地下水流态区域。显然每个分割区域的面积需根据像素数量(n_i)和每个像素大小(S_i)估算。如图2,单个像素尺寸是通过在隧道工作面放置卷尺为基准计算得到的。由于隧道施工现场的特殊地质和构造环境,很难将卷尺放置在任意需要摆放的位置,故在换算比例层面做了简化,并有以下几个假设:(1)隧道工作面为2D平面;(2)整个隧道工作面像素分布均匀,忽略图像扭曲带来的误差。

由图2可知,每个像素的长度 l_p 计算如式(1)




图2 像素与实际尺寸转换

Fig.2 Schematic diagram of image pixel to actual size conversion

$$l_p = \frac{L}{N} \quad (1)$$

其中: L 为卷尺的实际长度; N 为采集图像中与卷尺相对应的像素个数.故每个像素代表的实际面积 S_p 计算如式(2)

$$s_p = (l_p)^2 = \left(\frac{L}{N}\right)^2 \quad (2)$$

由此可计算出识别得到的岩石工作面不同特征区域的总面积 S 如式(3)

$$S = \sum_{i=1}^t n_i s_p \quad (3)$$

其中: t 为从岩石隧道工作面图像中提取的特征区域个数.每次采集图像均会在工作面放置基准卷尺以便于尺寸的标定与转换,拍摄图像后分别计算并记录每个工作面图像的比例系数 l_p 值.

1.3.2 岩体几何信息量化原理 对于如软弱夹层、地下水流态等特征的面积信息,可结合像素和实际尺寸的比例 l_p 转化求得,而区域面积则可结合式(3)计算的比例得到.故在进行面积等参数的统计求解时,只需统计各类别区域像素个数和尺寸转化比例即可.

对于节理裂隙等在曲率形态等方面需侧重统计的特征,涉及参数常包括迹线长度、倾角、密度、强度、间距、表观S-RQD(surface rock quality designation).这类参数的实际尺寸的测量远比面积计算复杂,此时 l_p 系数仅可用于尺寸的转换,无法满足岩体裂隙从识别后的像素特征转化为特征参数的数字化.另外,对裂隙迹线图进行定量评估需要提取每个裂隙的主干结构并识别岩体裂隙迹线的像素节点.裂隙骨架图则为迹线几何特性的表征提供了重要的前期基础.由于裂隙骨架图仍包含大量的像素点,且每个裂隙的曲率各不相同,统计起来难度极大.故笔者提出一套将裂隙特征信息化的方法,包括基于链码的迹线节点定位方法和多段线近似算法,用于生成裂隙多段线图并获取裂隙迹线的关键节点坐

标,以及基于角度阈值的迹线断开算法和基于 K-means++的迹线分组算法,用于实现迹线的有效分组.具体方法如下.

首先,提出基于链码的节点定位方法,用以自动搜索裂隙骨架图中的关键特征点.引入链码思想,即定义裂隙骨架中每个像素点之间有相关关系,且都可由链码简洁地表示.如图 3 所示,链码算法从左到右、从上到下遍历迹线所有像素点,并为迹线骨架中的每个像素点分配一个链码,从而实现用链码表示每一条骨架迹线.




图 3 基于链码的像素转坐标算法示意

Fig.3 Schematic diagram of pixel coordinate transformation algorithm based on chain code

随后,采用多段线提取算法进行多段线近似分析,主要过程如图 4 所示.其中,定义参数 D 为连接两个连续关键节点的直线与这两个关键节点连接曲线内的迹线像素点之间的欧氏距离.而控制节点选择的密度参数为 D_{max} ,该参数是手动设置的距离阈值.如图 4(a)和图 4(b).由于每条迹线的链码信息均包括了起点坐标和链码序列,故所有像素点的坐标可以在迹线骨架的链码上推导出来,式(4)为表征的坐标示意,可见包含 n 个像素点的裂隙骨架可表示为 n 个数组

$$[X_0 Y_0][X_1 Y_1] \cdots [X_n Y_n] \tag{4}$$

其中,每个数组表示像素点的相应 2D 坐标.从坐标为 $[X_0 Y_0]$ 的起始像素点开始,选取像素点 $[X_k Y_k]$ 作为迹线关键节点.由 $[X_0 Y_0]$ 和 $[X_k Y_k]$ 形成的线段可表示为线函数,如式(5)所示

$$AX + BY + C = 0 \tag{5}$$

式中: A 、 B 和 C 均为常量,可以从两个像素点的坐标 ($[X_0 Y_0]$ 和 $[X_k Y_k]$) 计算导出.而对于任意像素点 $[X_i Y_i]$ 在上述两个像素点之间的欧氏距离的计算式为

$$d_i = \frac{|AX_i + BY_i + C|}{\sqrt{A^2 + B^2}} (i = 1, 2, \dots, k - 1) \tag{6}$$

由 1 条迹线得到的 1 组欧氏距离 (d_1, d_2, \dots, d_{k-1}) 可计算出 $[X_1 Y_1]$ 和 $[X_{k-1} Y_{k-1}]$ 间所有像素点的欧氏距离.若在该数据中有且仅存在 1 个点使欧氏距离大于 D_{max} ,则认定像素点 $[X_k Y_k]$ 为迹线多段线的关键节点.若所有欧氏距离小于 D_{max} 值,则遍历到下一个像素点 $[X_{k+1} Y_{k+1}]$ 并将其作为遍历的关键节点,以计算一组新的欧氏距离 (d_1, d_2, \dots, d_k),直到找到一个使欧氏距离大于 D_{max} 值的点.然而,当遍历到迹线端点后仍找不到大于 D_{max} 的点

时,则将最后一个端点作结束,不再计算欧氏距离.因此,起始像素点之后的迹线关键节点均由所选的欧氏距离参数 D_{max} 值确定.

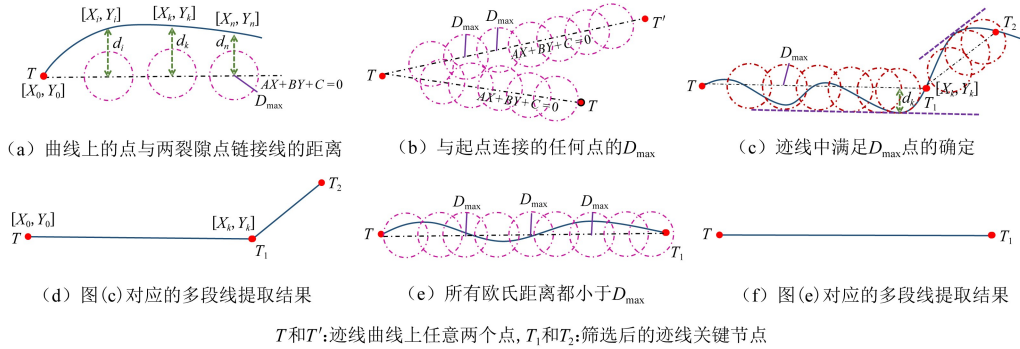



图4 多段线近似算法核心过程

Fig.4 Process of the polyline approximation algorithm

为统计迹线分组及间距特性,笔者提出基于角度阈值的算法用于检测和断开迹线多段线中曲率较大的点,主要原理是在连续迹线中找到合理的断点,以最小化该点生成的两条线与两个端点之间的角度^[63],即查找由连续迹线的起点和端点连接的直线的最远点.在算法中, ∂_i 参数用于计算这两条直线之间的最小角度. ∂_{max} 为用于控制断点位置的手动可调的角度阈值.如图5所示,以裂隙迹线为例,旨在找到使两端迹线形成具有最小角度 ∂_1 的节点,并对比 ∂_1 和 ∂_{max} 的大小关系:若 $\partial_1 \leq \partial_{max}$ (图5(a)),则被搜索的节点即为第1个断点 B_1 ; 否则,整条迹线将被认定为平整的隶属于1个组的迹线,不需被断开.随后将第1个断点 B_1 作为新起点,以检索剩余两边迹线的下一个潜在的断点.若 $\partial_2 \leq \partial_{max}$ (图5(b)),则搜索的节点被认定为第2个断点 B_2 ; 否则,剩余的迹线将被认定为平整的隶属于1个组的迹线,也不需要再被断开.以此类推,不断检测后续迹线的最小角度点,并做角度阈值判定,直到不再满足断开连接要求(图5(c)).断开迹线的结果示例如图5(d),可见整个



$P_1 \sim P_n$:多段线近似算法中被提取的迹线关键节点, $B_1 \sim B_3$:迹线多段线中的断点

图5 基于角度阈值的裂隙迹线断开过程

Fig.5 Fracture trace breaking process based on angle threshold

迹线被断点分为4部分,并以不同的颜色显示.值得注意的是,标识为断点的节点不会因此被删除,因为删除会影响迹线长度的统计.通过这种角度阈值算法,呈现曲线形态的岩体裂隙迹线可被有效地断开.

精准的迹线分组是隧道工作面岩体同组迹线间距测量的前提.迹线断开后,应用 K-means++模型开展裂隙自动聚类分析.该模型在初始质心选择上做了改进,原理是尽可能控制不同类质心间的距离^[64].假设已选择了 m_i 初始簇的质心(其中 $0 < m_i < K$),则距离当前聚类质心较远的点被选为 m_{i+1} 簇质心的可能性更高.将迹线倾角(T)作为聚类的关键输入参数,选为迹线分组的主要依据.同时引入轮廓有效性指数(SVI)^[65],用于选择最佳聚类数(K)并对裂隙迹线进行分组.SVI 是用于评估实际类别未知的任务,其表达式为

$$SVI(t_i) = \frac{b(t_i) - a(t_i)}{\max[a(t_i), b(t_i)]} \quad (7)$$

式中: t_i 为 K_i 聚类中的迹线倾角; $a(t_i)$ 为在同一类别迹线中 t_i 与其他同组迹线倾角间的平均距离,并且是其他不同类别中随机选择的迹线倾角之间的平均距离.SVI 值为 $[-1, 1]$,其中 SVI 值越接近 0 表示越重叠的聚类,负值表示不正确的聚类分配.SVI 值越大表示聚类性能越好,即同一类别样本之间的距离相对较小,不同类别样本之间的距离较大.

1.4 智能化围岩分级及安全评价原理

为结合机器视觉、环境及力学等参数开展岩石质量指标(RMR)预测研究,提出基于多源异构数据的集成机器学习预测围岩分级(图6),采用的算法是梯度提升回归树(GBRT),并在研究过程中采用一些对比算法,包括随机森林(RF)、决策树(DT)和多层感知机(MLP).其中,GBRT的核心概念是通过提升(Boosting)弱模型以形成单个强模型,而非构建新的优化模型.在单个决策树中,特征空间先被分类为多个子节点,以实现每个区域因变量的模型分析^[66-67].然后将每个单独区域划分为新的子节点实现进一步的分析.重复该过程,直到满足所有判定完成条件.GBRT模型构建的基本思路是在梯度方向上通过训练1个新学习器来降低前1个学习器的误差率,且新学习器是前学习器基础上的迭代生成.为优化超参数,提出一种贝叶斯优化方法,即树结构Parzen估计器(TPE)^[68].TPE算法通过将超参数优化任务限制为“树”结构,并假定超参数彼此独立.随后采用k-折交叉验证方式提升模型的综合表现.

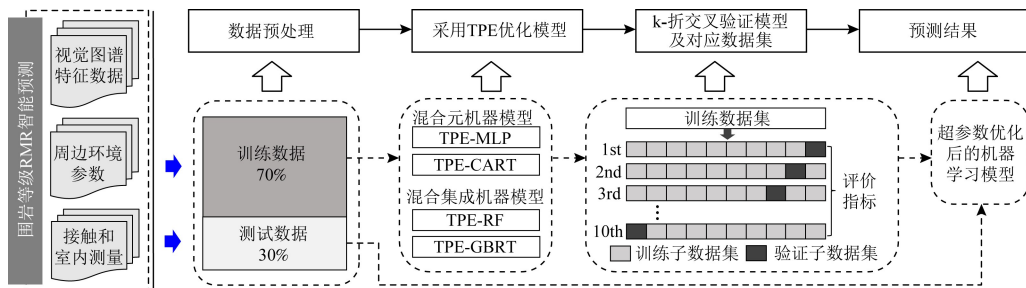


图6 智能化围岩分级主要原理及步骤

Fig.6 Main principles and steps of intelligent surrounding rock classification

采用安全系数计算实现隧道的安全评价,其中强度折减法是安全系数最常见、最重要

的方法之一,于20世纪70年代应用于岩土工程领域^[69].使用强度折减法计算安全系数的过程中,常需要结合行业规范对工程破坏或损伤的破坏临界定义,由此确定最终的强度折减系数.使用结合围岩等级定义收敛位移的标准,其中《锚杆喷射混凝土支护技术规范》(GB50086—2001)是评价地下隧道安全稳定性的主要标准之一^[70].该规范通过归纳和总结国内外大量工程实例得到用于判定不同围岩级别下的隧道允许沉降值.其中,相对位移值是指两测点间实测位移累计值与测点间距之比.结合定义的位移允许值并将其作为强度折减法分析安全系数的判据,即充分考虑基于多源信息下的围岩等级来开展更符合实际工程的安全评价.

2 隧道岩体视觉信息的获取

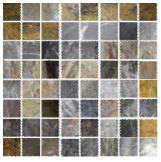
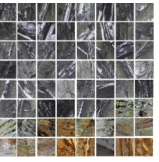
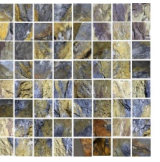
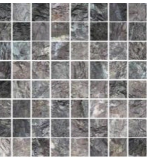
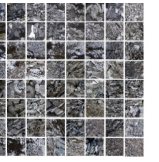
通过分析国内外广泛应用的BQ(Basic quality)分级法、岩体质量Q(Quality)分类法和地质力学RMR(Rock mass rating)分类法,确定各类参数在相关标准中的划分细节.统计分析国内外应用的围岩分级方法,总结出包括岩石强度、岩石完整程度、地下水状况、初始应力状态、结构面状态、岩体声波波速及其他因素在内的8个主要分级因素.从该指标中确立基于机器视觉和接触式测量方法进行分级的主要目标参数,主要包括岩体表观结构、地下水状况、软弱夹层、节理裂隙等视觉指标和隧道埋深、开挖走向、风化程度等测量指标.

2.1 岩体表观结构分类

岩体结构破坏常会伴随工作面坍塌和施工受阻,给隧道常态化施工带来巨大挑战.实现对表观结构的准确识别将有助于工程人员第一时间了解岩体构造,预判围岩变形规律.然而,由于施工期岩石隧道工作面的特殊复杂环境及样本质量、数量等的不足使深度学习的应用较少.为此,通过深入现场收集隧道岩石表观图像数据集,并确定BQ分级标准中定义的散体GS、镶嵌MS、块状BS、层状LS和破碎FS这5种主要的岩石表观结构^[71](表1,确定原则见表2),开展基于机器视觉的岩体结构分类研究.

表1 《岩体工程分类标准》中岩体表观结构定义

Table 1 Rock structure definition in the classification standard for rock mass engineering

| 结构类别 | 块状结构 BS | 层状结构 LS | 镶嵌结构 MS | 破碎结构 FS | 散体结构 GS |
|----------|---|---|---|--|---|
| 结构特征 | 块状岩体 | 层理发育 | 镶嵌紧密 | 岩体破碎 | 岩屑和泥质物 |
| 完整程度 | 完整 | 中等完整 | 一般完整 | 一般破碎 | 破碎 |
| 不连续间距/cm | >30 | >10 | 10~30 | <30 | - |
| 样本示例 |  |  |  |  |  |

鉴于此,使用综合Inception及Resnet网络框架的Inception-Resnet-V2(IRV2)模型对建立的数据集开展表观结构分类.并结合权重衰减项(即正则项)的Softmax交叉熵函数分析模型的综合损失函数,其中,交叉熵只重视正确分类结果的特性,其真实分布 $p(x)$ 采用示性函数 $1\{\cdot\}$ 进行描述.而加入一个权重衰减项(即正则项),使函数变成严格的凸函数,

能保证收敛达到全局最优解.最常见的正则项是 F-范数(Frobenius)平方,由此得到的考虑权重衰减的损失函数为

$$L(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k 1\{y^{(i)} = j\} \cdot \log \frac{e^{\theta_j^T(x^{(i)})}}{\sum_{l=1}^k e^{\theta_l^T(x^{(i)})}} \right] + \frac{\lambda}{2} \|\theta\|_F^2 \quad (8)$$

其中: m 为数据集中用于运行的原图数量; k 为数据集中的标签数量; θ 为 IRV2 模型的参数集, $\|\theta\|_F$ 为 F-范数,主要作用是通过正则化操作提升模型自身泛化能力.模型训练的主要目标是使分类结果尽可能趋近真实类别,即此时相对熵越来越小,故由最小化交叉熵即可获得最小相对熵.

为全面分析 IRV2 模型的可靠性,选取 Inception-v4、ResNet-101 和 ResNet-5 开展对比实验,并选择精度(Accuracy)、准确率(Precision)、召回率(Recall)和 F-score 这 4 个评估指标综合分析识别模型性能.测试结果如图 7 所示,其中每一类的指标均为所有数据集的平均值.可见,块体结构在所有表观结构中的分类指标相对最高,其主要原因是块体图像的纹理特征和外观鲜明,使得其更易被识别.4 种方法的分类表现总体满足 Inception-ResNet-V2、Inception-v4、ResNet-101 和 ResNet-50 的优劣顺序.从反映综合性能的 F-score 看,对于各类方法,破碎和散体的分类难度较高,其主要原因是与结构类别的其他 3 类相比,破碎和散体没有易于识别的明显特征,从而导致分类表明性能相对较差.总体而言,IRV2 在表观岩体结构类型的分类样本中仍具有最理想的表现.

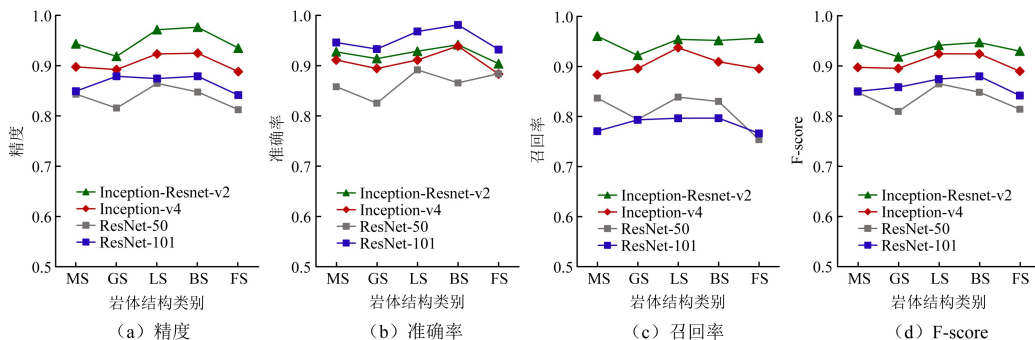


图 7 不同评估指标下各类岩石结构的分类性能

Fig.7 Classification performance of various rock structures evaluated by different indicators

2.2 隧道工作面软弱夹层信息的提取及量化表征

岩体类别多样,软弱夹层赋存条件复杂、检测难度大,随着隧道频繁开挖,软弱夹层的识别滞后及不准确问题将更加尖锐.若不加以准确预判,将极有可能导致工作面陷入坍塌、施工受阻等困境,无疑会给隧道施工带来巨大挑战.结合从隧道现场工作面获取的原始图像的 4 种主要岩体类别(红黏土,黄黏土,白云岩和灰岩),作为夹层的语义分割目标.采用基于 DeepLab V3+ 的像素级深度学习语义分割方法,实现目标图像中每个像素的类别判定的端到端的深度学习网络.采用 DeepLab V3+ 深度提取网络为 Xception 网络,其建立在 Xception_65 结构基础上,主要优化方案是在 Xception_65 之后用深度可分离卷积层替换了原有的普通卷积层^[72-73].使用的损失函数仍为 Softmax 交叉熵损失函数.

将传统图形学算法(大津法 Otsu)和其他语义分割算法(FCN)纳入对比并分析提出方法的综合表现.图 8 展示了单图含有多类夹层的分割结果.总体而言,3 种算法在单图夹层类别增加下的语义分割效果下降,其原因在于这类图像有更复杂的像素边界及像素分布.而对于各类方法的对比,DeepLab V3+相较于其他两种方法具有更准确的分类.另外,FCN 对边界的误判随着单图类别数目的增加而急剧增大,潜在的原因可能是该方法在多次采样过程中导致关键边界信息丢失严重.而 Otsu 法对多夹层的检测性能最差,尽管其精细地分割了原始图像中的很多细节,但因缺乏对图像语义的深度理解,其在分割图像中仅仅识别出了颜色带来的差异边界,在超过两个夹层信息后无法得到除前景和背景外的第 3 类信息.




图 8 采用 3 种方法分割单图含有多类夹层的结果

Fig.8 Segmenting results of a single image containing multiple types of weak interlayers

为进行 DeepLab V3+模型的量化统计,将数据库中未用于训练和验证过程的测试图像进行软弱夹层的分割测试.统计各图中每一类的夹层像素个数,并利用尺寸转化得到每张图中夹层的实际面积.将预测图和标记图进行对比,绘制出各类夹层的面积的散点图.图 9 呈现了不同类型岩石测试图像的预测和标记的面积.可见,除了一些误判外,大多数夹层预测面积接近标记值.通过散点曲线拟合,得出曲线均符合直线拟合,且相关系数大于 0.8945.另外,各类夹层的面积均在对角线明显波动,可见该数据库在不同程度上仍受岩石表面纹理及光照等因素影响.

2.3 隧道工作面地下水分布的量化表征

隧道表面水量的定量评估对于隧道工作面的稳定性评价意义重大,其有效评估有助于在突涌水灾害发生前对隧道工作面进行快速准确地判断.RMR 系统将地下水流态分为 5 类(完全干燥、浸润、潮湿、滴水 and 流水),但实际工程中很难通过肉眼区分浸润和潮湿的状态.故将浸润和潮湿统一为潮湿状态以明确图像标记过程的边界选取,同时将涌水状态

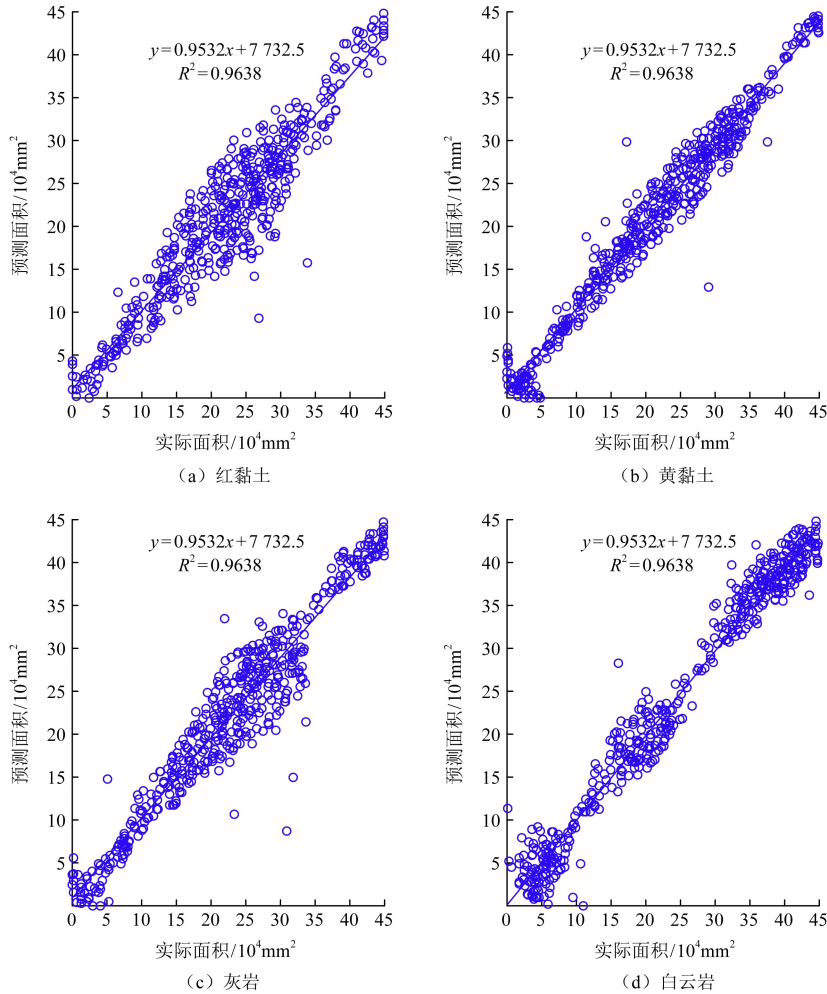


图9 基于 DeepLab V3+分割图中预测和标记结果面积统计

Fig.9 Area statistics of prediction and labeling results in DeepLab V3+ segmentation maps

加入其中,以描述岩石隧道工作面的突水情况.因此,数据库的5类地下水流态分别为干燥、潮湿、滴水、流水和涌水.

鉴于此,笔者提出一种模拟工程师巡检的基于 CNN 的两步骤地下水流态识别法.首先执行分类步骤以识别完全干燥样本,随后执行分割步骤以完成定量分割含水样本.其中分类步骤采用残差网络 ResNet-101 模型来确定干燥和含水图像的概率.若分类结果为干燥,则图像被识别为表观安全状态,识别标记为 NS; 否则将其作为输入到分割模型,其中分割步骤采用 DeepLab V3+结构来量化流态.对分类步骤使用精度、准确率、召回率和 F-score 等指标评价,对分割步骤则使用像素精度、平均像素精度和平均交并比等指标评价.

在分类模型训练后,开展图像验证和测试研究.表2所示为820张验证和615张测试数据集样本的评价指标.可见,在验证、测试阶段的 F-score 分别超过 94.03%和 92.55%,且无论在验证或测试阶段,含水样本分类效果均稍弱于干燥样本,均显示出模型在地下水分

类任务的良好表现.

将分类结果为含水的样本继续用于语义分割,并使用预训练后的特定权重和偏置的 DeepLab V3+模型用于地下水流态图像测试.图 10 展示了干燥、潮湿、滴水、流水和涌水的预测和实际流态区域面积的散点统计数据.测试过程中的噪声点和误判可能会使预测结果偏离基准线,且离散点越远、测试结果误差越大.对于 5 种不同类别的地下水流态的分割表现,流水预测区域通常较大地偏离真实区域,导致这种现象的潜在原因是流水区域与干燥及滴水区域相似,容易形成与相近区域之间的混淆,从而造成误判.潮湿区域的预测则在基准线上波动,表明其分割结果中存在一定的模糊性,可适当地提升该类的鲁棒性.

表 2 ResNet-101 模型分类结果的参数统计

Table 2 Parametric statistics of ResNet-101-based classification results

| 阶段 | 类别 | 阳性 | 阴性 | TP | TN | FP | FN | 精度 | 准确性 | 召回率 | F-score |
|----|----|-----|-----|-----|-----|----|----|--------|--------|--------|---------|
| 验证 | 干燥 | 440 | 380 | 412 | 362 | 18 | 28 | 0.9439 | 0.9581 | 0.9364 | 0.9471 |
| | 含水 | 380 | 440 | 362 | 412 | 28 | 18 | 0.9439 | 0.9282 | 0.9526 | 0.9403 |
| 测试 | 干燥 | 330 | 285 | 305 | 267 | 18 | 25 | 0.9301 | 0.9443 | 0.9242 | 0.9342 |
| | 含水 | 285 | 330 | 267 | 305 | 25 | 18 | 0.9301 | 0.9144 | 0.9368 | 0.9255 |

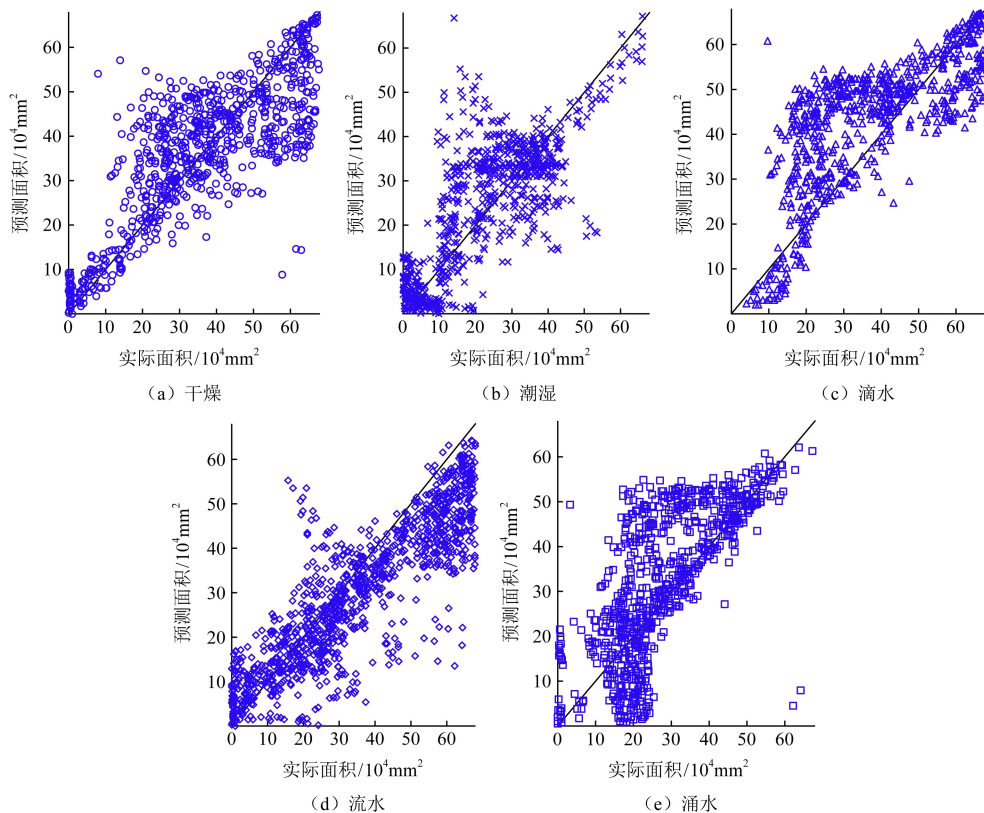


图 10 地下水流态语义分割预测和实际面积统计

Fig.10 Prediction and actual area statistics of water inflow segmentation results

2.4 岩体节理裂隙信息量化提取与统计

二维裂隙迹线图提取和评估涉及图像、图像转坐标、坐标运算等复杂的数据处理过程,涵盖的流程复杂且应用的算法众多.首先将用于裂隙迹线图提取的 FraSegNet 模型和迹线骨架图提取算法,并结合迹线几何特征量化算法,实现像素的坐标化,由此计算迹线长度、迹线倾角、迹线密度、迹线强度、迹线间距等数字化统计信息^[20].

2.4.1 节理裂隙量化提取的主要方法 FraSegNet 模型如图 11 所示,模型由输入层、基于 CNN 的编码特征提取模块、解码模块和输出层 4 部分组成.其中,编码模块是从卷积神经网络 VGG19^[74] 修改而来,原始的 VGG19 包括 5 个卷积单元 16 层、4 个池化层和 3 个全连接层,整体网络结构相对简单.而改进的模块用空间金字塔池化(ASPP)模块代替 VGG 最后一层池化层.整个模型中,通过误差反向传播算法使用每个卷积层的权重和偏差参数来进一步学习特征.在每个卷积层之后进行批量归一化以减少协变量的偏移,以及 ReLU 激活函数以加速收敛.解码器主要应用于多尺度的上采样操作,以确保每个卷积层输出的特征图与初始输入图像大小一致.将引导滤波器用作边缘平滑算子,使图像结构转移到滤波输出,从而实现新的滤波目标.如此融合操作可以使边缘保持平滑性能,极大地避免了因浅卷积层输出带来的噪声影响,也避免了因纯考虑深层影响引起的边缘不清问题^[75].

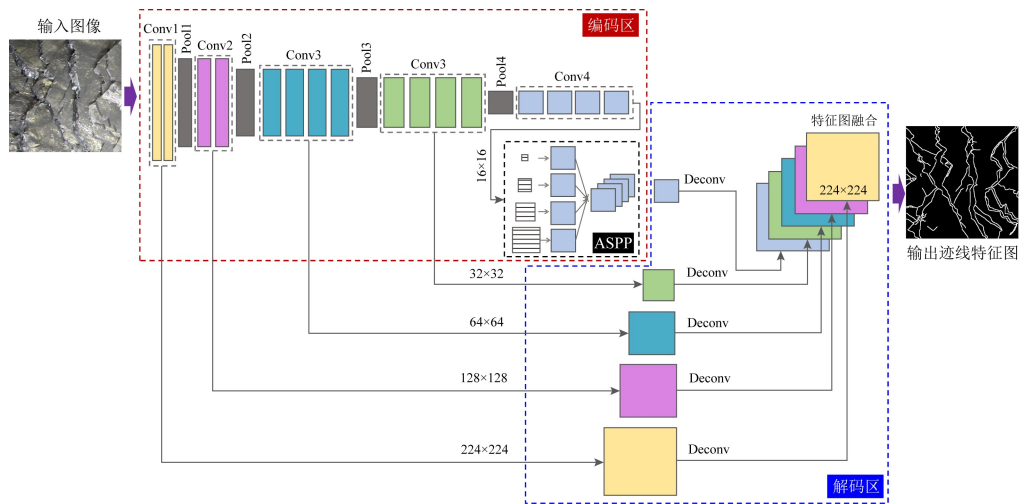


图 11 FraSegNet 模型结构

Fig.11 Structure diagram of FraSegNet model

FraSegNet 模型使用随机梯度下降算法作为优化器,该算法在运算过程中每次仅随机选择 1 个样本来更新 1 个训练周期内的模型参数.同时,模型定义了 1 个交叉熵的损失函数,用于计算手动标记的裂隙迹线图与由 FraSegNet 模型预测的相应特征图之间的差异,计算式为

$$L = - \sum_{i \in G_+} w_0 \log Pr(P_i = 1) - \sum_{i \in G_-} w_1 \log Pr(P_i = 0) \quad (9)$$

其中: w_0 和 w_1 分别为非迹线和迹线类别的损失权重; $Pr(P_i)$ 为预测特征图的概率分布; G_+ 和 G_- 分别为输入图像的非迹线像素和迹线像素.每个卷积层均生成 1 个预测特征图,

其相应的侧面输出损失定义为 $L_{\text{side-output}}^i$, 其中 i 为模型中卷积的层号. 每一层的侧面输出图被连接到最终融合预测, 产生的融合损失为 L_{fused} . 将整体的交叉熵损失函数定义为 5 个卷积层和融合预测损失值的总和, 计算式为

$$L_{\text{overall}} = \sum L_{\text{side-output}}^{i=1 \text{ to } 5} + L_{\text{fused}} \quad (10)$$

2.4.2 节理裂隙提取结果 为分析 FraSegNet 模型的提取效果, 图 12 展示了采用不同方法得到的裂隙特征提取和骨架可视化图, 分别包括标记图、FraSegNet、DeepLab V3+、Canny、FCN 和 Laplacian 方法. 通过定性比较可知, FraSegNet 模型在像素级的边界识别和噪声规避方面比 FCN 和传统边缘检测算法更有效. 虽然传统方法可以根据图像纹理特征通过调整阈值来精确地分割裂隙, 但 FraSegNet 模型可以更深入地了解迹线领域知识所传达的真实裂隙的语义. 而作为深度学习框架的 FCN 模型无法有效避免裂隙表面破碎带来的噪点和误判. DeepLab V3+ 模型表现出与 FraSegNet 模型相似的特征提取表现, 但二者在裂隙迹线的宽度上有一些差异, 尚不能通过肉眼定性判断哪种方法更优. 通过骨架图可见, 基于深度学习的算法的性能明显优于传统的图像边缘检测算法. 通过与标记真实图进行比较, DeepLab V3+ 和 FCN 模型转化的骨架图含有大量的噪声和缺失. 而 FraSegNet 模型具有最优表现, 因为其在裂隙骨架的交叉处几乎没有很多显著的噪声.

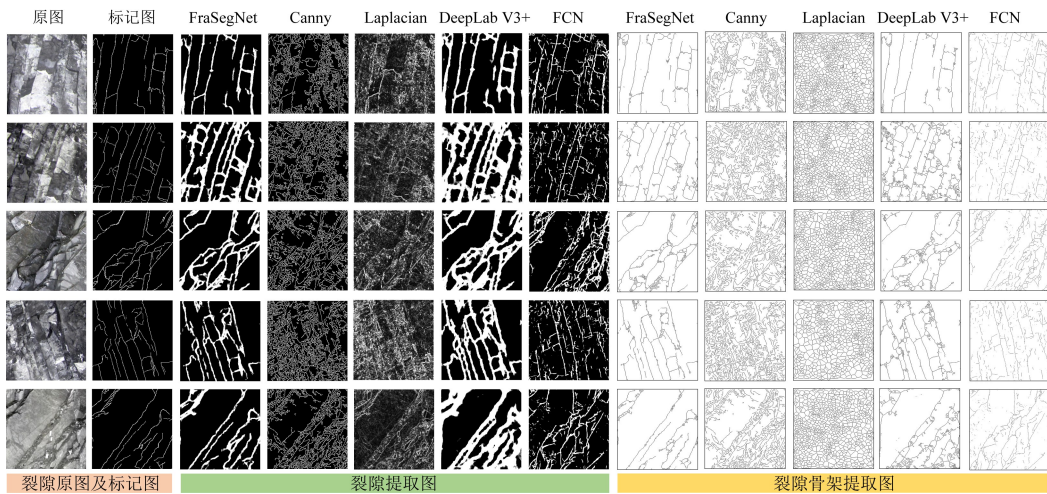
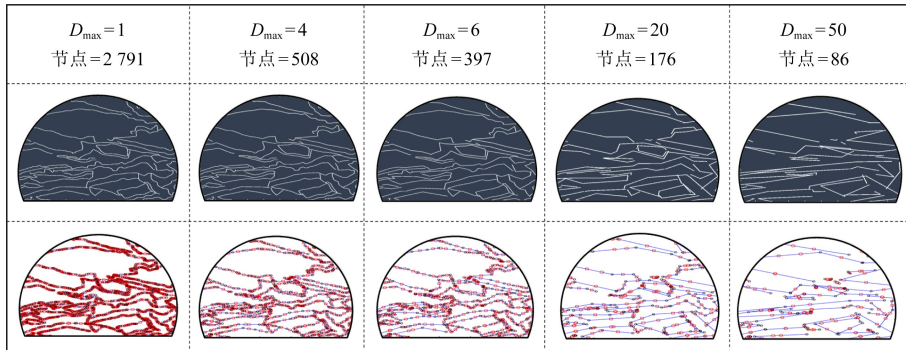


图 12 采用不同方法的裂隙及骨架提取对比

Fig.12 Comparison of fracture and corresponding skeleton extraction using different methods

通过基于链码的多段线近似方法对裂隙骨架图进行处理, 定义参数 D_{max} 值衡量提取的关键节点数量及近似裂隙多段线图与标记原图之间的相似性. 为表征参数与相似性之间的关系, 图 13 展示了裂隙多段线和关键节点数量, 选取 D_{max} 值为 0.5~50 像素. 结果表明, 较小的 D_{max} 值 (≤ 4 像素) 可能会因过度强调裂隙迹线弯曲, 导致迹线关键节点大量增加, 影响计算效率; 而较大的 D_{max} 值 (≥ 20 像素) 则可能会导致迹线弯曲细节不能被理想地表达, 此时大多数迹线被近似为一条直线, 无法捕获迹线的正确曲率. 因此 D_{max} 值被定性设置为 6 像素, 以生成具有合理节点数量的可靠裂隙多段线图.

随后, 合理断开迹线的连接节点以进行迹线分组, 即采用角度阈值法以控制断点的断

图 13 不同 D_{\max} 影响下关键节点数量和裂隙多段线近似结果Fig.13 Approximate results of key node quantity and fracture polyline under various D_{\max} values

开程度.对各种 θ_{\max} 值对应的迹线断开结果进行定性比较,以选择最优的 θ_{\max} 参数.对比原则是评估裂隙图中大多数迹线中明显转弯的节点是否被准确断开.图 14 展示了两个裂隙迹线图断开中分别将 θ_{\max} 值设置为 $120^{\circ} \sim 175^{\circ}$ 时的断开结果,不同颜色的裂隙多段线表示颜色间的交界处被节点断开.可见,较小的 θ_{\max} 值($\leq 120^{\circ}$)可能会忽略迹线中大量的关键拐点,从而导致迹线的不合理分组,而较大的 θ_{\max} 值($\geq 160^{\circ}$)可能会过分强调裂隙迹线的局部曲率而导致裂隙多段线中出现大量无意义的断点.因此,建议 θ_{\max} 在 $120^{\circ} \sim 160^{\circ}$ 选择角度阈值使所提算法能够以合理的精度断开裂隙迹线.故将 θ_{\max} 设置为 150° 以形成最终断开的迹线图.

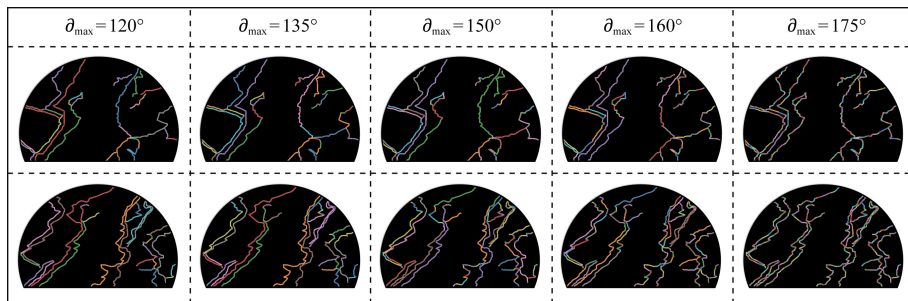


图 14 基于角度阈值法的迹线断开优化结果

Fig.14 Optimization results of trace break based on angle threshold method

基于上述优化参数,应用轮廓有效性指数(SVI)优化 K-means++算法以自动选择最佳的裂隙组数(GN).图 15 展示了工作面分组裂隙和相应 SVI 的可视化结果,其中每个分组的迹线都以一种颜色显示,可清楚辨析分组编号.当 $GN=3$ 时,SVI 参数达到最大值 0.614,其次是 GN 为 2、4 和 5,SVI 值分别为 0.603、0.571 和 0.56.虽然各组聚类结果对 SVI 值没有特别显著波动,但 SVI 值关系到迹线分组的合理性.因此,选取示例工作面的最佳裂隙迹线分组数为 3.

2.4.3 节理裂隙量化结果 结合裂隙长度、倾角、强度和密度等几何评价指标,对 600 个试验样本的统计结果进行对比,并对方法性能进行量化.统计了预测和标记的裂隙多段




图 15 基于 K-means++ 和 SVI 优化系数的迹线分组结果

Fig.15 Results of trace grouping based on K-means++ and SVI optimized coefficients

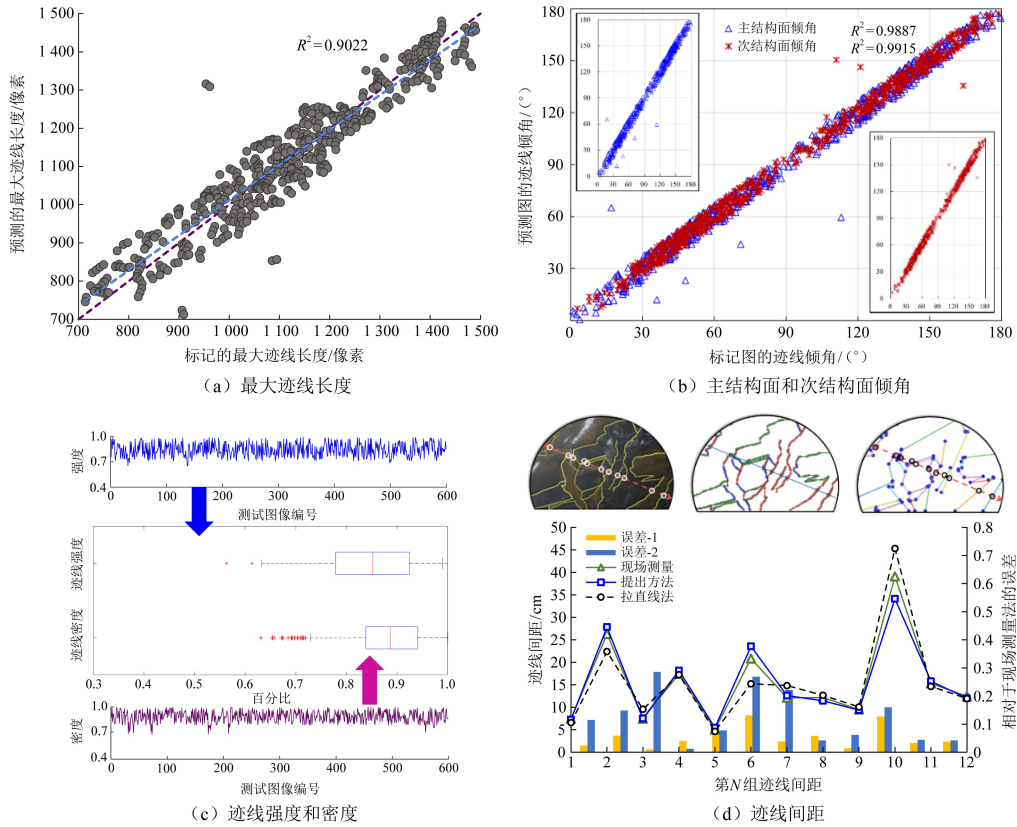


图 16 裂隙参数统计结果

Fig.16 Statistical results of fracture parametric statistics

线图的最大迹线长度 T_{le} 值(图 16(a)),其中, T_{le} 值在一定程度上取决于关键节点连接的连续性,即迹线间间断的存在将会中止最大长度的统计.因此,对于最大迹线长度,一定程度的统计误差是可行的.最大迹线长度的预测一般可以有效地反映实际工作面的状况.

图 16(b)展示了主要和次要倾角的统计结果,可见主次倾角的相关系数 R^2 分别达到了 0.9887 和 0.9915.其中,主次倾角的统计结果优于裂隙长度,其潜在原因是角度反映对裂隙形态或者轮廓的描述,而长度则反映了裂隙连续性的特征.总体而言,裂隙连续性比裂隙形态更难量化.而角度的量化准确度也可进一步反映基于深度学习提取迹线的可行性.图 16(c)展示了迹线强度 S_{ie} 和密度 S_{de} 的评价指标和统计结果,通过比较圆形测窗中的相对强度/密度来计算.可见,两个指标在众多样本中表现出较大波动.从两个指标的总体统计结果箱形图看, S_{ie} 和 S_{de} 的平均值分别为 85.7% 和 88.65%.尽管存在一些数据波动性,但所提出的方法仍可以准确描述大部分裂隙标记的实际密度和强度.总间距是计算测线与所有迹线的交点坐标,并计算记录所有相邻距离,由此也可计算表面 S-RQD 值.为进行全面分析,将现场测量和拉直线法用于总间距的对比中.图 16(d)展示了 3 种不同方法在某一工作面图像的可视化及测线位置.为简化展示,在此仅比较了相对复杂的测线生成的统计信息.可见,本文方法与拉直线法在迹线图的表现形态上存在许多差异,但其明显更接近于现场测量的交点分布,因此更符合实际.

3 隧道围岩分级及风险评估案例

3.1 围岩智能化分级

基于上述研究,采用各类 CNN 方法对工作面图像的主要特征进行量化语义分割,主要包括如软弱夹层的类别数和面积^[29]、地下水的类别数和面积^[30]、裂隙迹线长度(最大值和平均值)、迹线强度和密度、主迹线倾角等^[20].同时,岩体表观结构类别^[26]、软弱夹层类别和地下水类别也可用基于 CNN 的模型进行自动识别.此外,每个隧道工作面相应的单轴抗压强度(UCS)、风化程度、隧道深度和走向等信息无法从数字图像中获取,需要从现场工程师提供的手动记录数据表中得到.对于一个隧道工作面,可形成多源异构数据库用于 RMR 预测.为实现智能化预测,需进行 RMR 计算以进行监督式模型训练.依靠经验丰富的工程师提供的每个隧道工作面的 6 个参数,从 RMR 系统的经验公式中计算相应的 RMR 值.图 17 展示了 6 个参数值和 133 个隧道工作面的计算 RMR 值情况.由此作为采用数据驱动方式进行数据筛选和评估的输出版.

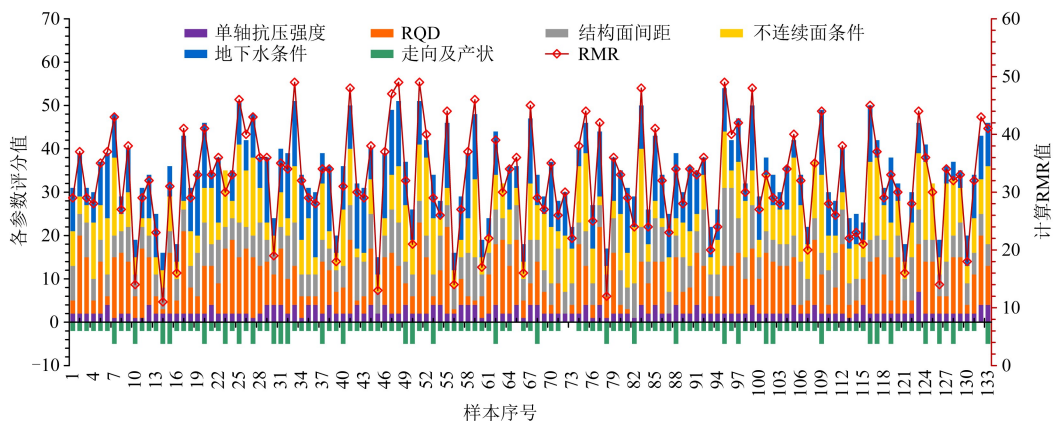


图 17 RMR 系统中 6 个输入参数和对应的计算值

Fig.17 Six input parameters and corresponding calculated values in the RMR system

将隧道工作面的多源异构数据用作输入数据库来预测 RMR 值.对此,建立 133 组 13 维的数据库和 133 个 RMR 值作为目标输出.分别将数据库随机分为测试数据集(40/133)和训练数据集(93/133),用于数据驱动机器学习模型的运作.采用 4 种算法(TPE-RF、TPE-CART、TPE-MLP、TPE-GBRT)对数据库中的训练集和测试集进行最终预测,并分别记录训练集和测试集的 RMR 预测结果(图 18).通过应用已训练的模型,所有预测结果可在 1s 内获得.越靠近对角线 $y=x$ 的数据点说明最终效果越好,可见混合集成模型的效果明显优于混合元模型.混合集成模型的训练集有非常理想的结果,但在未预先训练的测试集中表现明显减弱.

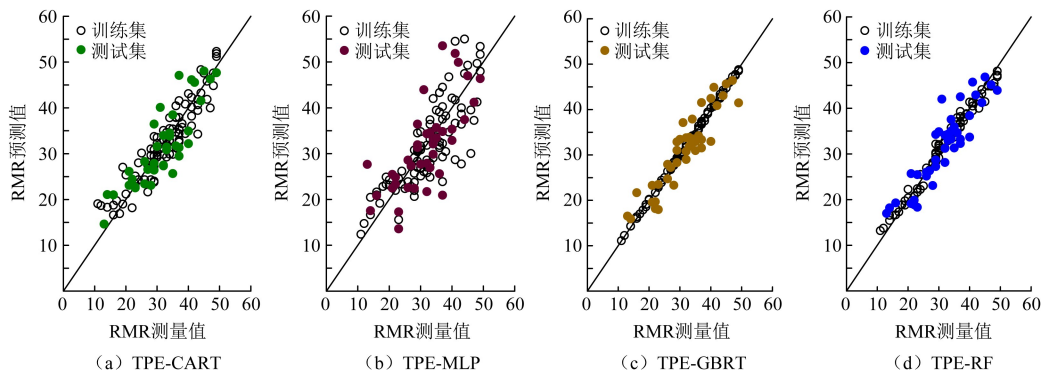


图 18 对训练集和测试集的 RMR 机器学习预测

Fig.18 Machine learning-based RMR predictions for training and testing sets

为量化模型表现,分别计算训练集和测试集的 R 、MAE、RMSE 和 MAPE 等性能指标值,并记录在表 3 中.可见,对于训练集,TPE-GBRT 算法的预测输出与实际值最接近, R 接近为 1,其次是 TPE-RF、TPE-CART 和 TPE-MLP. TPE-GBRT 算法在测试过程的 MAE、RMSE 和 MAPE 指标中均在 4 种算法中最小,表现了出色的综合预测性能.同时,在测试预测结果中,混合集成算法往往具有较低的 MAE、RMSE、MAPE 值及较高的 R 值.因此,混合集成模型的性能一般优于混合元模型.因此,从定量和定性角度分析,TPE-GBRT 均表现出最优性能.

表 3 4 种算法的 RMR 预测对比

Table 3 Comparison of RMR predictions for four algorithms

| 混合模型 | 训练集 | | | | 测试集 | | | |
|----------|--------|--------|--------|--------|--------|--------|--------|--------|
| | R | MAE | RMSE | MAPE/% | R | MAE | RMSE | MAPE/% |
| TPE-CART | 0.9217 | 2.6632 | 3.5103 | 9.72 | 0.8516 | 3.5656 | 4.4926 | 12.25 |
| TPE-MLP | 0.7550 | 4.2715 | 5.9649 | 13.73 | 0.6325 | 5.3589 | 6.6474 | 18.89 |
| TPE-GBRT | 0.9995 | 0.2557 | 0.3947 | 0.85 | 0.9220 | 2.7520 | 3.3676 | 9.67 |
| TPE-RF | 0.9899 | 0.9855 | 1.4287 | 3.51 | 0.9055 | 2.9638 | 3.6669 | 10.54 |

3.2 隧道开挖风险与案例分析

在《锚杆喷射混凝土支护技术规范》的允许沉降值定义和强度折减理论的前提下,结合 3DEC 数值模拟,通过记录不同围岩等级下隧道拱顶沉降模拟值,计算模型的强度折减

系数,计算基于岩体分级和不连续结构面参数的隧道安全系数.选取云南蒙自-屏边高速公路冷泉隧道的8个断面作为工程案例进行图像特征的提取、建模和安全评价等研究.冷泉隧道是该区节理裂隙发育最显著的岩石隧道之一,最大埋深约为312m,全线无高地应力状况,隧址区未见地表水体分布,地表水系不发育.主要赋存岩体包括中风化的白云岩、灰岩和泥岩等,岩体中不含煤层,故不存在有毒有害气体.通过各类深度学习方法分割或分类对应特征后,运用提出的后处理方法分别量化岩体的几何参数.可见8个工作面案例存在较多相似之处,如表观岩体结构均为层状结构,地下水状况良好,均为干燥.另外,统计中也结合了单轴抗压强度、隧道走向、风化程度等无法通过图像获取的特征.

在DFN建模过程中,除结构面的倾角、倾向的分布外,还包括多个参数,如迹线分布规律、迹线间距、迹线长度分布等.由于节理空间分布的复杂性,假设迹线均匀分布于岩体环境中.而其余参数则结合DFN进行建模.根据冷泉隧道工作面案例的实际不连续面统计情况及圣维南原理,建立1:1的隧道开挖模型,建立的隧道模型共划分148 359个块体,其模型网格划分情况及相应的隧道侧切如图19所示.隧道模型XYZ方向分别施加位移边界约束条件.为模拟地应力,依据8个隧道工作面的平均埋深262m在数值模型内部增加竖直z方向的初始应力.在每个开挖进尺中隧道的拱顶和拱底中点布设两个监测点(图19),共需8个循环,每个循环中点分别布设拱顶和拱底的测点,共16个测点,分别为拱顶M-1至M-8和拱底M-1'至M-8'测点.分别记录开挖过程中测点周边的竖向位移、位移云图及变形向量图.

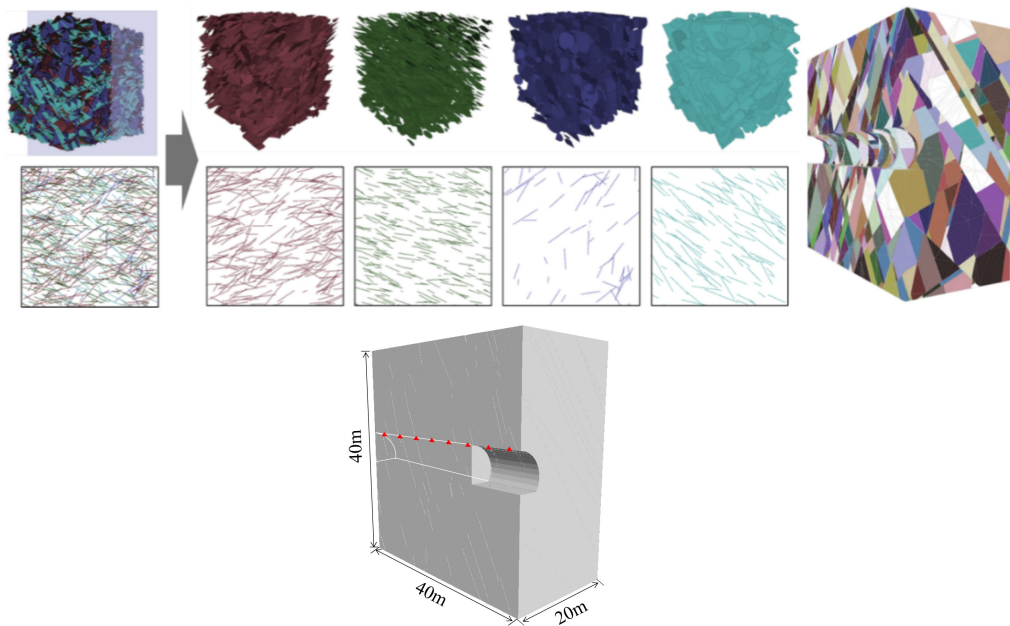


图19 基于DFN的隧道开挖模型建立及开挖监测点布设

Fig.19 DFN-based tunnel excavation model establishment and excavation monitoring point layout

在岩体力学参数方面,研究建模过程中选择的岩体为灰岩,将裂隙接触的力学参数选为软弱夹层的泥岩特性,勘察中分别采取5组岩样进行天然及饱和单轴抗压试验,采集

3组岩样进行重度及抗拉、抗剪试验,采集2组岩样进行变形试验,得到相应的岩体物理力学参数.对块体单元、节理面和优势结构面均选用摩尔-库伦弹塑性本构模型.开挖过程中有2点简化:(1)不模拟开挖嗣后支护工作;(2)均假设为全断面开挖,用于监测隧道周边关键点应力应变规律.隧道开挖的位移量是评价安全稳定性的重要指标,图20展示了冷泉隧道在连续开挖过程中围岩的位移云和变形向量.可见,随着连续开挖,隧道顶底部均出现不同程度的位移,即朝着已开挖的空区挤压,工作面岩体也朝着已开挖空间挤压.随着开挖的深入,各区域位移仍一直在扩展,其潜在原因是已开挖的区域没有嗣后施加支护作用.开挖面前方的围岩也存在坍塌的风险,如开挖步4~8过程中工作面岩体均没有按开挖的范围移除,从而引起了周边一些块体的掉落.另外,拱顶的一些滑移块体也有掉落的隐患,如开挖步3后,顶板位置一直存在不稳定的三角块.而拱底位置也出现大面积块体松动及分离的部位,主要原因是底部块体的应力集中和开挖引起的卸荷回弹等作用.后续隧道仰拱的开挖和施作也将减少底部位移带来的安全风险.




图20 冷泉隧道连续开挖云位移和变形向量(剖面)

Fig.20 Displacement and deformation vector map of continuous excavation of lengquan tunnel(section view)

图21所示为隧道拱顶和拱底中点的位移变化.可见,拱顶和拱底位移均呈现出阶梯变化,但不同开挖步引起的位移影响不尽相同,如开挖步对当前开挖区域的位移影响最大,邻近的空间影响次之,距离开挖工序越远的区域影响越小.而对于位移收敛值,拱顶的位移值普遍在7~8cm,而拱底的位移则跳跃性较大,较多的测点收敛在3~5cm,但开挖步7对应的测点M-7'则在第7和第8步开挖的过程中有较大的波动,潜在原因是开挖引起了较大范围的块体分离.在拱顶位移数据中,各测点均在开挖后产生较大的沉降,而随着邻近开挖的推进,沉降并未收敛,而是以较小的速率下沉,由此引起隧道的持续性变形,若此时不加以支护,隧道将可能存在坍塌风险.在拱底的位移中,通过监测点数据可见开挖会引起邻近拱底的微弱沉降,而开挖后则会有较大幅度的隆起,最终收敛于稳定值.不

同的是,拱顶由于自重应力的影响导致沉降持续时间长,且一直以缓慢的速度沉降,而拱底则在收敛后基本不变。




图 21 基于 3DEC 的隧道开挖模拟位移监测数据

Fig.21 Simulated vertical displacement of tunnel excavation

利用 3DEC 编译强度折减法的安全系数计算,实现开挖安全评价.通过对粘聚力 c 和内摩擦角 φ 折减,采用拱顶位移作为折减循环预警值,评价连续开挖下隧道围岩的安全状态.利用自带 Fish 语言编译安全系数.结合《锚杆喷射混凝土支护技术规范》和围岩等级选取相对位移的最大、最小及均值,计算最大、最小和平均安全系数,统计结果如图 22(a) 所示.可见,不同的开挖安全系数波动显著,平均安全系数在 1.61~1.89,保守安全系数在 1.34~1.67,而最大安全系数在 1.85~2.12.尽管开挖隧道没有发生坍塌破坏,但最低安全系数 1.34 也需施工期间预警.为说明不同围岩等级和隧道工作面形态下连续开挖的安全系数,分别建立以每个工作面为基础信息的 3DEC 模型,并对每一个连续开挖模型进行分析,统计出每个开挖模型对应的 8 个开挖步骤的平均安全系数(图 22(b)).由图可知,不同围岩等级下的安全系数差异较为显著,如 III 级围岩的安全系数均值约为 1.87,而 IV 级围岩开挖的安全系数则约为 1.56.可见,开挖安全系数与围岩等级存在一定负相关,即等级

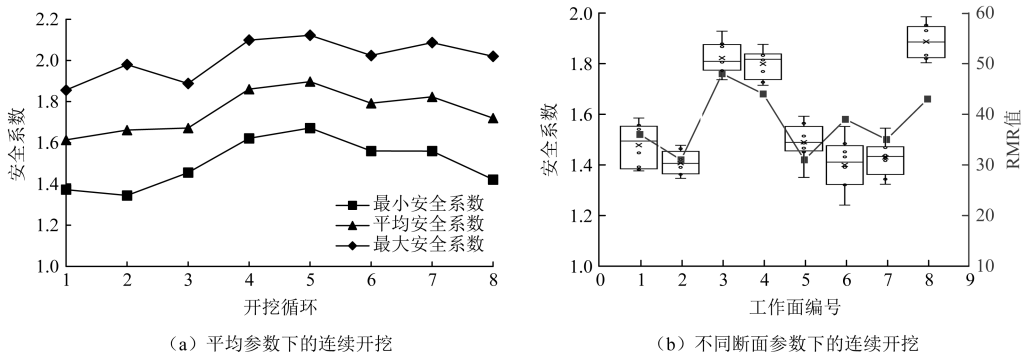


图 22 基于强度折减法的安全系数统计

Fig.22 Statistics of safety factors based on strength reduction method

越高、安全系数越小。值得注意的是,当前围岩等级和安全系数间的相关关系的样本仍较少,要深入揭示工作面参数对安全系数的影响规律可采用模拟实验统计学设计方法进一步分析,如正交分析、响应面设计方法等。由于篇幅限制,这里不再赘述。

4 结论

在岩体中修建隧道工程,常因岩体赋存介质的非均质性、不连续性和不确定性以及地层的隐蔽性、不可预见性而难以驾驭和控制,难以准确预测围岩性态和工程状态。围绕岩石隧道围岩分级和安全评价这一主线,分别从工作面信息获取方法、特征多维识别研究、围岩分级与安全评价等方面系统地对外国研究现状进行综述分析,得出主要结论如下:

(1)采用 Inception-ResNet-V2 模型用于岩体表观结构分类,该模型在提高结构分类准确性,且在精度、准确率、召回率及 F-score 等指标上表现优越。采用语义分割深度学习算法,实现了软弱夹层的语义分割,提升了边界识别的精度。提出了基于 CNN 的模拟人工巡检过程的两步骤方法量化提取工作面地下水流动信息,提高了地下水分类效率及定量分割精度。开发了用于自动提取岩体裂隙迹线的 FraSegNet 模型,通过骨架提取、多段线近似、迹线断开和自动化分组等算法,实现了岩体迹线像素-坐标-信息的转化。通过设定距离阈值 D_{\max} 可有效控制节点密度以实现裂隙骨架的精细化提取,通过角度阈值 α_{\max} 可自动搜索断点来断开迹线。迹线分组中,轮廓有效性指数 SVI 可优化迹线组数。实现了迹线长度、倾角、强度、密度、间距等多个评价指标的准确计算;

(2)提出围岩智能化分级的机器学习模型,引入贝叶斯超参数优化算法 TPE,提出 TPE-GBRT 混合机器学习算法预测岩体的 RMR 值。以基于机器视觉和现场测量数据建立的 13 维多源异构数据为输入数据,结合 MAE、RMSE、 R 和 MAPE 等指标,证明了混合集成算法明显优于混合元模型。提出基于机器视觉及现场实测的工作面数据的岩体裂隙离散网络 DFN 建模方法,分析了其建模的合理性。尽管基于点云提取的结构面产状由于不同工作面区域的分布存在较大差异而更离散,但是 DFN 建模生成的结构面产状与实际工程保持较高的一致性。采用拱顶沉降作为强度折减法的评价指标,分析了围岩的应力应变、节理滑移等模型状态,详细评价了连续工作面开挖的安全系数,给出了不同围岩等级和不同工作面形态下开挖的安全评价;

(3)主要采用深度学习、图形学及无监督算法和模型,针对性提取和量化工作面的关键特征及分布,取得了初步进展。然而,开挖过程中地质条件的不确定性极大地提升了模型表征和预测难度,针对同区域或同隧道的地质连续表征研究涉及较少,未来研究可深入揭示关键特征的纵向演化规律,实现前方岩体的智能化预测。另一方面,图像特征规律的揭示往往无法深度剖析地质发展,也无法获取物理力学参数值。未来可结合接触式测量法,同步获取表观信息和物理力学参数,得到围岩评价的系统化参数。随钻技术是记录掘进关键参数的重要手段,未来可借助该方法充分获取多源异构信息,实现对围岩的精细化评价。

参考文献

- [1] 钱七虎.隧道工程建设地质预报及信息化技术的主要进展及发展方向[J].隧道建设,2017,37(3):251-263
Qian Qihu. Main developments and directions of geological prediction and informatized technology of tunnel construction [J]. Tunnel Construction, 2017, 37(3): 251-263

- [2] 关宝树.软弱围岩隧道变形及其控制技术[J].隧道建设,2011,31(1):1-17
Guan Baoshu.Deformation of tunnels with soft surrounding rocks and its control[J].Tunnel Construction,2011,31(1):1-17
- [3] 田四明,王伟,巩江峰.中国铁路隧道发展与展望(含截至2020年底中国铁路隧道统计数据)[J].隧道建设(中英文),2021,41(2):308-325
Tian Siming,Wang Wei,Gong Jiangfeng.Development and prospect of railway tunnels in China(Including statistics of railway tunnels in China by the end of 2020)[J].Tunnel Construction(Chinese and English),2021,41(2):308-325
- [4] 朱合华,武威,李晓军,等.基于iS3平台的岩体隧道信息精细化采集、分析与服务[J].岩石力学与工程学报,2017,36(10):2350-2364
Zhu Hehua,Wu Wei,Li Xiaojun,et al.High-precision acquisition,analysis and service of rock tunnel information based on iS3 platform[J].Chinese Journal of Rock Mechanics and Engineering,2017,36(10):2350-2364
- [5] 李术才,刘洪亮,李利平,等.基于数码图像的掌子面岩体结构量化表征方法及工程应用[J].岩石力学与工程学报,2017,36(1):1-9
Li Shucai,Liu Hongliang,Li Liping,et al.A quantitative method for rock structure at working faces of tunnels based on digital images and its application[J].Chinese Journal of Rock Mechanics and Engineering,2017,36(1):1-9
- [6] Reid T R,Harrison J P.A semi-automated methodology for discontinuity trace detection in digital images of rock mass exposures[J].International Journal of Rock Mechanics and Mining Sciences,2000,37(7):1073-1089
- [7] Lemy F,Hadjigeorgiou J.Discontinuity trace map construction using photographs of rock exposures[J].International Journal of Rock Mechanics and Mining Sciences,2003,40(6):903-917
- [8] Pham D L,Xu C,Prince J L.Current methods in medical image segmentation[J].Annual Review of Biomedical Engineering,2000,2(1):315-337
- [9] Haralick R M,Shapiro L G.Image segmentation techniques[J].Computer Vision,Graphics, and Image Processing,1985,29(1):100-132
- [10] Cheng H D,Jiang X H,Sun Y,et al.Color image segmentation:Advances and prospects[J].Pattern Recognition,2001,34(12):2259-2281
- [11] 陈湘生,徐志豪,包小华,等.中国隧道建设面临的若干挑战与技术突破[J].中国公路学报,2020,33(12):1
Chen Xiangsheng,Xu Zhihao,Bao Xiaohua,et al.Challenges and technological breakthroughs in tunnel construction in China[J].China Journal of Highway and Transport,2020,33(12):1
- [12] Bergen K J,Johnson P A,De Hoop M V,et al.Machine learning for data-driven discovery in solid earth geoscience[J].Science,2019,363(6433):eaau0323
- [13] Xu Z, Ma W, Lin P, et al. Deep learning of rock images for intelligent lithology identification [J]. Computers & Geosciences, 2021, 154: 104799
- [14] Li J,Zhang L,Wu Z,et al.Autonomous Martian rock image classification based on transfer deep learning methods[J].Earth Science Informatics,2020,13(3):951-963
- [15] 张野,李明超,韩帅.基于岩石图像深度学习的岩性自动识别与分类方法[J].岩石学报,2018,34(2):333-342
Zhang Ye,Li Mingchao,Han Shuai.Automatic identification and classification in lithology based on deep learning in rock images.[J].Acta Petrologica Sinica,2018,34(2):333-342
- [16] 李明超,符家科,张野,等.耦合岩石图像与锤击音频的岩性分类智能识别分析方法[J].岩石力学与工程学报,2020,39(5):996-1004
Li Mingchao,Fu Jiako,Zhang Ye,et al.Intelligent recognition and analysis method of rock lithology classification based on coupled rock images and hammering audios[J].Chinese Journal of Rock Mechanics and Engineering,2020,39(5):996-1004
- [17] 许振浩,马文,林鹏,等.基于岩石图像迁移学习的岩性智能识别[J].应用基础与工程科学学报,2021,29(5):1075-1092
Xu Zhenhao, Ma Wen, Lin Peng, et al. Intelligent lithology identification based on transfer learning of rock images [J]. Journal of Basic Science and Engineering, 2021, 29(5): 1075-1092
- [18] 刘力辉,陆蓉,杨文魁.基于深度学习的地震岩相反演方法[J].石油物探,2019,58(1):123-129
Liu Lihui,Lu Rong,Yang Wenkui.Seismic lithofacies inversion based on deep learning[J].Geophysical Prospecting for Petroleum,2019,58(1):123-129

- [19] Lee Y K, Kim J, Choi C S, et al. Semi-automatic calculation of joint trace length from digital images based on deep learning and data structuring techniques [J]. *International Journal of Rock Mechanics and Mining Sciences*, 2022, 149: 104981
- [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] 柳厚祥, 李汪石, 查焕奕, 等. 基于深度学习技术的公路隧道围岩分级方法 [J]. *岩土工程学报*, 2018, 40(10): 1809-1817
Liu Houxiang, Li Wangshi, Zha Huanyi, et al. Method for surrounding rock mass classification of highway tunnels based on deep learning technology [J]. *Chinese Journal of Geotechnical Engineering*, 2018, 40(10): 1809-1817
- [22] Bamford T, Esmaili K, Schoellig A P. A deep learning approach for rock fragmentation analysis [J]. *International Journal of Rock Mechanics and Mining Sciences*, 2021, 145: 104839
- [23] Alqahtani N J, Chung T, Wang Y D, et al. Flow-based characterization of digital rock images using deep learning [J]. *SPE Journal*, 2021, 26(4): 1800-1811
- [24] Zhou X, Gong Q, Liu Y, et al. Automatic segmentation of TBM muck images via a deep-learning approach to estimate the size and shape of rock chips [J]. *Automation in Construction*, 2021, 126: 103685
- [25] Karimpouli S, Tahmasebi P. Segmentation of digital rock images using deep convolutional autoencoder networks [J]. *Computers & Geosciences*, 2019, 126: 142-150
- [26] 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
- [27] 刘飞跃, 刘一汉, 杨天鸿, 等. 基于岩芯图像深度学习的矿山岩体质量精细化评价 [J]. *岩土工程学报*, 2021, 43(5): 968-974
Liu Feiyue, Liu Yihan, Yang Tianhong, et al. Meticulous evaluation of rock mass quality in mine engineering based on machine learning of core photos [J]. *Chinese Journal of Geotechnical Engineering*, 2021, 43(5): 968-974
- [28] 王运森, 陆健, 贾庸凡. 3D 岩石结构面粗糙度智能提取方法及应用 [J]. *矿业研究与开发*, 2021, 41(10): 168-173
Wang Yunsen, Lu Jian, Jia Yongfan. Intelligent extraction method of 3D rock structure surface roughness and its application [J]. *Mining Research and Development*, 2021, 41(10): 168-173
- [29] 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
- [30] 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
- [31] 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
- [32] Senent S, Mollon G, Jimenez R. Tunnel face stability in heavily fractured rock masses that follow the Hoek-Brown failure criterion [J]. *International Journal of Rock Mechanics and Mining Sciences*, 2013, 60: 440-451
- [33] Hoek E, Carranza C, Corkum B. Hoek-Brown failure criterion, Narms-Tac [M]. Toronto: University of Toronto Press, 2002
- [34] 蒋树屏, 林志, 王少飞. 2018 年中国公路隧道发展 [J]. *隧道建设(中英文)*, 2019, 39(7): 1217-1220
Jiang Shuping, Lin Zhi, Wang Shaofei. Development of highway tunnels in China in 2018 [J]. *Tunnel Construction (Chinese and English)*, 2019, 39(7): 1217-1220
- [35] 洪开荣. 我国隧道及地下工程发展现状与展望 [J]. *隧道建设*, 2015, 35(2): 95-107
Hong Kairong. State-of-art and prospect of tunnels and underground works in China [J]. *Tunnel Construction*, 2015, 35(2): 95-107
- [36] 倪光斌, 赵万强, 王效良. 体现新的铁路建设理念 提高隧道技术标准水平——《铁路隧道设计规范》(TB10003—2005) 主要修订内容简介 [J]. *铁道标准设计*, 2006, (3): 68-70
Ni Guangbin, Zhao Wanqiang, Wang Xiaoliang. Embodying the new concept of railway construction and improving the level of tunnel technical standards-introduction to the main revised content of code for design of railway tunnel (TB10003—2005) [J]. *Railway Standard Design*, 2006, (3): 68-70
- [37] 匡亮, 赵万强, 赵勇, 等. 《铁路隧道设计规范》修订内容评析 [J]. *铁道工程学报*, 2019, 36(8): 90-94
Kuang Liang, Zhao Wanqiang, Zhao Yong, et al. Evaluation and analysis of the revised contents of code for design of railway tunnel [J]. *Journal of Railway Engineering Society*, 2019, 36(8): 90-94

- [38] Yang B, Mitelman A, Elmo D, et al. Why the future of rock mass classification systems requires revisiting their empirical past[J]. Quarterly Journal of Engineering Geology and Hydrogeology, 2022, 55(1). DOI: 10.1144/qjegh2021-039
- [39] Hou S, Liu Y, Yang Q. 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
- [40] Khatik V M, Nandi A K. A generic method for rock mass classification[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2018, 10(1): 102-116
- [41] Santos A E M, Lana M S, Pereira T M. Evaluation of machine learning methods for rock mass classification[J]. Neural Computing and Applications, 2022, 34(6): 4633-4642
- [42] 段林娣, 宋成辉. 应用 BP 神经网络进行隧道围岩快速分级[J]. 中国安全科学学报, 2010, 20(2): 41-45
Duan Lindi, Song Chenghui. Application of BP neural network in the rapid classification of surrounding rock[J]. China Safety Science Journal, 2010, 20(2): 41-45
- [43] 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
Lü 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
- [44] Wang T T, Huang T H. Anisotropic deformation of a circular tunnel excavated in a rock mass containing sets of ubiquitous joints: Theory analysis and numerical modeling[J]. Rock Mechanics and Rock Engineering, 2014, 47(2): 643-657
- [45] 左昌群, 陈建平. 基于可拓学理论的围岩分级方法在变质软岩隧道中的应用[J]. 地质科技情报, 2007, 26(3): 75-78
Zuo Changqun, Chen Jianping. Rock mass classification based on extenics theory applied in metamorphic soft rock tunnel[J]. Bulletin of Geological Science and Technology, 2007, 26(3): 75-78
- [46] 宫凤强, 李夕兵, 张伟. 隧道围岩分级的距离判别分析模型及应用[J]. 铁道学报, 2008, 30(3): 119-123
Gong Fengqiang, Li Xibing, Zhang Wei. Study and application on distance discriminant analysis model in tunnel surrounding rock classification[J]. Journal of Railways, 2008, 30(3): 119-123
- [47] Galende-Hernández M, Menéndez M, Fuente M, et al. Monitor-While-Drilling-based estimation of rock mass rating with computational intelligence: The case of tunnel excavation front[J]. Automation in Construction, 2018, 93: 325-338
- [48] Şen Z, Sadagah B H. Modified rock mass classification system by continuous rating[J]. Engineering Geology, 2003, 67(3-4): 269-280
- [49] Lary D J, Alavi A H, Gandomi A H, et al. Machine learning in geosciences and remote sensing[J]. Geoscience Frontiers, 2016, 7(1): 3-10
- [50] Rad H N, Jalali Z, Jalalifar H. Prediction of rock mass rating system based on continuous functions using Chaos—ANFIS model[J]. International Journal of Rock Mechanics and Mining Sciences, 2015, 73: 1-9
- [51] 洪开荣, 冯欢欢. 近 2 年我国隧道及地下工程发展与思考(2019—2020 年)[J]. 隧道建设, 2021, 41(8): 11
Hong Kairong, Feng Huanhuan. Development and thinking of tunnels and underground engineering in China in recent 2 years(From 2019 to 2020)[J]. Tunnel Construction, 2021, 41(8): 11
- [52] Guan K, Zhu W, Wei J, et al. A finite strain numerical procedure for a circular tunnel in strain-softening rock mass with large deformation[J]. International Journal of Rock Mechanics and Mining Sciences, 2018, 112: 266-280
- [53] Huang N, Jiang Y, Liu R, et al. Estimation of permeability of 3-D discrete fracture networks: an alternative possibility based on trace map analysis[J]. Engineering Geology, 2017, 226: 12-19
- [54] 郭子红, 钟祖良. 浅埋隧道破裂面的极限平衡分析法[J]. 地下空间与工程学报, 2017, 13(5): 1228-1233
Guo Zihong, Zhong Zuliang. Analysis on shallow tunnel sliding surface with limiting equilibrium method[J]. Chinese Journal of Underground Space and Engineering, 2017, 13(5): 1228-1233
- [55] 王凤云. 深埋隧道软弱围岩稳定性分析及其锚固控制研究[J]. 岩石力学与工程学报, 2020, 39(10): 2160
Wang Fengyun. Stability analysis and its anchorage control of soft rock mass for a deep tunnel[J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 39(10): 2160
- [56] Zhang P, Nordlund E. A 3DEC numerical analysis of the interaction between an uneven rock surface and shotcrete lining[J]. Rock Mechanics and Rock Engineering, 2021, 54: 2267-2289

- [57] Wang X, Cai M. A DFN-DEM multi-scale modeling approach for simulating tunnel excavation response in jointed rock masses[J]. *Rock Mechanics and Rock Engineering*, 2020, 53: 1053-1077
- [58] Wang M, Zhou J, Chen J, et al. Automatic identification of rock discontinuity and stability analysis of tunnel rock blocks using terrestrial laser scanning[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2023, 15(7): 1810-1825
- [59] 吴波, 兰扬斌, 杨仕升, 等. 基于强度折减动力分析法的围岩稳定性研究[J]. *现代隧道技术*, 2020, 57(3): 56-64
Wu Bo, Lan Yangbin, Yang Shisheng, et al. Study on stability of surrounding rock based on strength reduction dynamic analysis method[J]. *Modern Tunnelling Technology*, 2020, 57(3): 56-64
- [60] 赖天文, 雷浩, 刘志强, 等. 不同岩层倾角深埋硬岩隧道围岩开挖变形研究[J]. *铁道工程学报*, 2020, 37(7): 69-76
Lai Tianwen, Lei Hao, Liu Zhiqiang, et al. Research on the deformation of surrounding rocks of deeply buried hard rock tunnels with different incline[J]. *Journal of Railway Engineering Society*, 2020, 37(7): 69-76
- [61] 杜俊, 梅志荣, 傅立磊, 等. 基于强度折减法的浅埋软弱围岩隧道掌子面稳定性研究[J]. *现代隧道技术*, 2020, 57(1): 51-57
Du Jun, Mei Zhirong, Fu Lilei, et al. Study on working face stability of the shallow-buried tunnel in soft surrounding rocks based on strength reduction theory[J]. *Modern Tunnelling Technology*, 2020, 57(1): 51-57
- [62] Linder W. Digital photogrammetry[M]. Berlin: Springer, 2009
- [63] Leng B, Yang H, Hou G, et al. Rock mass trace line identification incorporated with grouping algorithm at tunnel faces[J]. *Tunnelling and Underground Space Technology*, 2021, 110: 103810
- [64] Chen J, Huang H, Zhou M, et al. Towards semi-automatic discontinuity characterization in rock tunnel faces using 3D point clouds[J]. *Engineering Geology*, 2021: 106232
- [65] Rousseeuw P J. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis[J]. *Journal of Computational and Applied Mathematics*, 1987, 20: 53-65
- [66] Breiman L, Friedman J, Stone C J, et al. Classification and regression trees[M]. Boca Raton: CRC Press, 1984
- [67] Lewis R J. An introduction to classification and regression tree (CART) analysis[C]. Proceedings of the Annual Meeting of the Society for Academic Emergency Medicine in San Francisco, California, 2000
- [68] Bergstra J, Bengio Y. Random search for hyper-parameter optimization[J]. *The Journal of Machine Learning Research*, 2012, 13(1): 281-305
- [69] Zienkiewicz O C, Humpheson C, Lewis R. Associated and non-associated visco-plasticity and plasticity in soil mechanics[J]. *Geotechnique*, 1975, 25(4): 671-689
- [70] 尚岳全. 地质工程学[M]. 北京: 清华大学出版社有限公司, 2006
Shang Yuequan. Geological Engineering[M]. Beijing: Tsinghua University Press Co., Ltd., 2006
- [71] 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
- [72] Baheti B, Innani S, Gajre S, et al. Semantic scene segmentation in unstructured environment with modified DeepLabV3+[J]. *Pattern Recognition Letters*, 2020, 138: 223-229
- [73] Zhang X, Zhou X, Lin M, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018
- [74] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv: 1409.1556, 2014
- [75] Liu Y, Yao J, Lu X, et al. DeepCrack: A deep hierarchical feature learning architecture for crack segmentation[J]. *Neurocomputing*, 2019, 338: 139-153

Machine Vision-based Study on Intelligent Rating and Excavation Safety Risk Assessment of Rock Tunnel

HUANG Hongwei¹, CHEN Jiayao²

(1.Key Laboratory of Geotechnical and Underground Engineering of Ministry of Education, Department of Geotechnical Engineering, Tongji University, Shanghai 200092, China; 2. School of Civil Engineering, Key Laboratory for Urban Underground Engineering of Ministry of Education, Beijing Jiaotong University, Beijing 100044, China)

Abstract

The progression into a phase of rock tunnel construction is marked by significant dimensions, notable length, substantial depth, and pronounced complexity. Uncertain geological conditions within surrounding rock formations, combined with limited expert resources, give rise to myriad challenges during the excavation process of the New Austrian Tunnelling Method (NATM) tunnel construction, primarily concerning rock mass quality assessment and excavation safety evaluation. This results in a sequence of scientific inquiries, encompassing aspects related to rock mass structural attribute characterization, hierarchical modeling, and methodologies for safety assessment during excavation. The present study revolves around these scientific inquiries, employing a diverse range of methodologies including on-site measurements, statistical data analysis, intelligent algorithms, and numerical simulations. An algorithm has been devised for quantitatively extracting characteristics of the rock mass face, concomitantly establishing a refined hierarchical model for the classification of rock masses by integrating a variety of heterogeneous data sources. Building upon this foundational work, an investigation into the safety evaluation of tunnel excavation within complex geological environments has been executed. The principal achievements of this study are outlined as follows: Addressing the challenges posed by soft interlayers, joint fissures, and subterranean aquifers has resulted in the development of databases for image semantic segmentation and apparent structure image classification. The application of deep learning algorithms and methodologies such as hyperparameter optimization has facilitated accurate classification and nuanced representation of feature information. Consequently, a comprehensive 13-dimensional heterogeneous database has been established, encapsulating geometric, environmental, and physico-mechanical parameters pertinent to the rock mass. Through the construction of a hybrid TPE-GBRT prediction model, the optimal parameter combination for predictive optimization within the hybrid machine learning model has been identified, facilitating precise prediction of rock mass classification as indicated by the RMR index. Lastly, the geological environment of the rock mass has been modeled on the basis of a discrete fracture network (DFN), leading to the formulation of a three-dimensional tunnel model within 3DEC, grounded in excavation surface data. The continuous tunnel excavation process has been simulated using strength reduction methods, enabling the assessment of stability characteristics, including stress-strain responses, shear displacement, and safety conditions.

Keywords: rock tunnel; machine vision; image features; deep learning; rock mass rating; numerical simulation; multi source heterogeneous data; safety evaluation