

张睿,张莹,栾雅琳,等.基于 ConvNeXt 的围岩裂隙识别提取与完整性评估方法[J].辽宁工程技术大学学报(自然科学版),2026,45(3):314-322.DOI:10.11956/j.issn.1008-0562.20260015
ZHANG Rui, ZHANG Ying, LUAN Yalin, et al. Fracture segmentation and rock mass integrity intelligent prediction based on ConvNeXt[J]. Journal of Liaoning Technical University (Natural Science), 2026, 45(3): 314-322. DOI: 10.11956/j. issn. 1008-0562.20260015

基于 ConvNeXt 的围岩裂隙识别提取与完整性评估方法

张睿¹, 张莹², 栾雅琳^{1*}, 狄圣杰², 陶莹莹¹, 王骐恺¹, 张艳美¹

(1. 中国石油大学(华东) 储运与建筑工程学院, 山东 青岛 266580;

2. 中国电建集团 西北勘测设计研究院有限公司, 陕西 西安 710065)

摘要: 针对传统声波测试方法在隧洞岩体完整性评价中, 对测试设备和现场条件依赖性强、难以快速便捷预测岩体完整性系数 K_v 的问题, 提出一种基于深度学习的岩体完整性一体化评估方法。以围岩裂隙图像为输入, 构建裂隙图像数据集, 引入基于 ConvNeXt 的区域卷积神经网络模型, 实现裂隙的自动识别与语义分割; 采用图像处理技术对裂隙进行定量分析, 提取裂隙长度、密度、交叉点数量、粗糙度等 7 项几何特征; 利用遗传规划算法建立裂隙特征参数与 K_v 之间的非线性映射关系。研究结果表明, 在裂隙识别方面, 该方法构建的裂隙分割模型召回率达到 91.83%; 基于遗传规划模型的交叉验证结果显示, K_v 预测的均方根误差为 0.0263 ± 0.0094 , 平均绝对百分比误差为 $2.57\% \pm 0.46\%$ 。该方法能够有效实现基于裂隙图像特征的 K_v 预测, 为岩体完整性评价提供不依赖声波测试的有效途径。

关键词: 隧洞岩体; 围岩裂隙; 深度学习; 图像分析; 完整性系数

中图分类号: TU457

文献标志码: A

文章编号: 1008-0562(2026)03-0314-09

Fracture segmentation and rock mass integrity intelligent prediction based on ConvNeXt

ZHANG Rui¹, ZHANG Ying², LUAN Yalin^{1*}, DI Shengjie², TAO Yingying¹,
WANG Qikai¹, ZHANG Yanmei¹

(1. College of Storage and Transportation and Architectural Engineering, China University of Petroleum (East China), Qingdao 266580, China; 2. Northwest Engineering Corporation Limited, Power China, Xi'an 710065, China)

Abstract: In order to overcome the strong dependence of traditional acoustic wave testing methods on testing equipment and site conditions in tunnel rock mass integrity evaluation, and to achieve rapid and convenient prediction of the rock mass integrity coefficient (K_v), an integrated rock mass integrity assessment method based on deep learning is proposed. Taking surrounding rock fracture images as input, a fracture image dataset is constructed, and a ConvNeXt-based region convolutional neural network model is introduced to realize automatic fracture identification and semantic segmentation. Subsequently, image processing techniques are employed to quantitatively analyze the identified fractures, from which seven geometric features, including fracture length, density, number of intersections, and roughness are extracted. Furthermore, a genetic programming algorithm is utilized to establish a nonlinear mapping relationship between fracture feature parameters and K_v . The results indicate that the proposed model achieves a recall rate of 91.83% in fracture identification. Cross-validation based on the genetic programming model shows that the root mean square error of K_v prediction is 0.0263 ± 0.0094 , and

收稿日期: 2026-01-12 修回日期: 2026-03-01 接受日期: 2026-03-07 责任编辑: 焦丽

基金项目: 山东省自然科学基金项目 (ZR2025QC486); 陕西省自然科学基金项目 (2024JC-YBQN-0357); 陕西省重点研发计划 (2025CY-YBXM-466)

作者简介: 张睿 (2001-) 女, 辽宁 阜新人, 硕士研究生, 主要从事岩土工程方面的研究。E-mail: rui277940@163.com

通信作者: 栾雅琳 (1990-) 女, 山东 莱州人, 博士, 高级实验师, 主要从事岩土工程方面的研究。E-mail: luanyalin@upc.edu.cn

the mean absolute percentage error is $2.57\% \pm 0.46\%$. The proposed method effectively enables K_v prediction based on fracture image features, providing an alternative approach to rock mass integrity evaluation that does not rely on acoustic wave testing and demonstrates promising engineering application potential.

Keywords: tunnel rock mass; surrounding rock fractures; deep learning; image analysis; integrity coefficient

0 引言

隧洞岩体的完整性是决定地下洞室稳定性的关键因素,对围岩力学行为、支护结构设计及施工安全具有重要影响。传统完整性评价主要依赖现场波速测试,通过岩体与完整岩石纵波波速平方比定义的岩体完整性系数 K_v 进行评价^[1],但该方法操作复杂且易受施工干扰。随着图像采集与智能分析技术的发展,基于裂隙信息的岩体完整性评价为突破传统方法局限提供了新的研究思路。

在岩体完整性系数的间接评价方面,现有研究主要通过引入多种现场测试数据来修正或替代传统波速法,提升完整性系数的估计精度。蔡建华等^[2]提出声波对穿距离控制标准及测点布置方法,实现岩体完整性快捷测试。殷明伦等^[3]基于实测数据提出考虑结构面类别的 J_v 修正方法,间接表征 K_v 。MUHAMMAD等^[4]结合电阻率层析成像(ERT)和诱导极化(IP)技术实现对 K_v 的二维和三维分布预测。WANG^[5]通过整合钻孔图像与雷达数据,构建多尺度、多参数的井周岩体完整性评估方法。这类方法的核心优势在于融合多源信息,但其工程适用性仍受现场测试条件的制约。

在岩体裂隙的直接识别与提取方面,研究方法从传统图像处理逐步向深度学习演进,识别精度不断提升,但多数研究止步于裂隙表征层面。早期研究依赖于三维激光扫描、边缘检测^[6]等技术,傅金阳等^[7]提出基于三维SLIC超像素分割,对隧道开挖面节理裂隙进行识别。ZHAO等^[8]提出物理信息图像法,从不同方向、尺度和类型的页

岩中精准提取层理面几何特征。王军祥等^[9]结合小波分析与区域生长实现裂隙定量识别。WU等^[10]提出断裂点检测网络,实现三维点云中裂隙的自动提取。传统方法步骤繁琐且依赖人工参数。王春艳等^[11]融合U²-Net与动态索引旋转卷积(DIRC)技术提升识别裂隙的精度。CHAIYASARN等^[12]采用CNN-FCN集成实现自动检测。尽管识别技术不断进步,现有方法仍集中于裂隙的识别与表征,对于如何将提取的裂隙特征进一步应用于岩体完整性评价,特别是建立裂隙特征与完整性系数之间的定量关联,尚缺乏深入研究。

综上,岩体完整性评价与裂隙识别技术均取得显著进展,但裂隙几何特征与 K_v 之间的定量关联仍有待深入研究,制约了图像识别成果在工程评价中的直接应用。为此,提出一种融合改进ConvNeXt模型与裂隙几何特征自动提取的方法,利用改进的ConvNeXt网络对岩体图像进行裂隙分割与特征提取,通过图像分析量化裂隙的几何参数,构建裂隙特征与 K_v 的映射关系,实现岩体完整性系数的预测,为隧洞岩体完整性智能评价提供可行的新方法。

1 基于深度学习的围岩裂隙识别

1.1 Mask R-CNN模型与改进模型

Mask R-CNN^[13]模型是一种基于深度卷积神经网络的实例分割算法,通过在Faster R-CNN^[14]模型的目标检测框架上增加一个并行的掩码分支,实现对目标对象的精准像素级分割,其网络架构见图1。




图1 Mask R-CNN网络架构

Fig.1 Mask R-CNN network architecture

算法流程如下：①利用残差神经网络(ResNet)和特征金字塔网络(FPN)，从输入图像中提取丰富多尺度特征；②通过区域建议网络(RPN)快速生成可能包含裂隙的候选区域；③使用感兴趣区域对齐(RoIAlign)，将候选区域标准化为固定大小的特征图；④将对齐后的特征同时送入两个分支，一个分支负责边界框回归与类别识别，另一分支负责生成像素级分割掩码。

Mask R-CNN模型通过区域建议网络和多任务预测分支，实现像素级目标检测与分类，但在处理结构复杂、对比度模糊的图像时，ResNet^[15]主干网络的特征提取能力不足。为此，引入ConvNeXt^[16]替代Mask R-CNN模型中的主干网络。

ConvNeXt融合Transformer^[17]设计理念，保持卷积计算效率的同时，实现性能的提升，其核心改进如下：①深度可分离卷积采用7×7大核作为核

心空间特征提取器，替代传统的小卷积堆叠，增强对长距离依赖和图像细节的建模能力；②在深度卷积后，接入层归一化(layer normalization)，在小批量训练中，该策略的稳定性优于批归一化(batch normalization)；③将特征送入逆瓶颈结构的通道混合器，通过1×1卷积将通道维度扩展至4倍并应用GELU激活函数，再通过1×1卷积将通道恢复至原始维度，以实现更高效的特征变换。

改进模型的计算流程与原始Mask R-CNN模型一致，仍采用区域建议网络生成候选区域，并通过感兴趣区域对齐特征后送入双分支预测头。引入ConvNeXt作为特征提取骨干，可强化模型对复杂场景中细节信息与长距离依赖的建模能力。改进模型的网络结构见图2，其中展示了ConvNeXt模块的内部设计，后续流程与图1一致。




图2 改进后模型网络架构
Fig.2 improved model network architecture

1.2 制作数据集与模型训练

图像数据采集自青岛市黄岛区某典型流纹岩地质露头区域，该区域有多种构造类型，如走滑断裂和接触界面等，能为模型提供具有代表性的裂隙学习样本。原始图像共317张，覆盖不同时段，包含岩面干燥、潮湿，以及局部覆尘等自然状态，数据信息见表1。

表1 裂隙图像数据集信息统计			
Tab.1 information statistics of the fracture image dataset			
采样点编号	采集样本数	图像分辨率	地质构造场景类型
1	58	3 072×4 096	两期岩浆活动接触界面
2	63	3 072×4 096	正断层及派生节理区域
3	67	3 072×4 096	断裂破碎带及构造反转
4	57	3 072×4 096	走滑断裂与花状构造
5	72	3 072×4 096	常规无特殊构造区域

数据集样本照片见图3。为实现图像的物理尺寸标定，拍摄时放置标准刻度参照物，见图3(a)。将每张原始图像划分为500×700像素的子图像，剔除无裂隙图像，共获得有效样本1 035张。采用Labelme工具^[18]，按规范对图像中的节理面与裂隙进行像素级语义标注，获得模型训练所需的真值标签，准确区分地质裂隙与表面纹理、污迹等干扰信息。标注完成后，将所有结果转换为二值掩码图，裂隙为白色，背景为黑色。复核全部掩码后，对图像及掩码进行尺度归一化处理。

为提升模型的泛化能力并规避过拟合，采用随机亮度调整、旋转等方式对样本图片实施数据增强，样例见图3(b)。处理后数据集的有效样本量扩充至4 140张，按8:2的数量比划分为训练集和测试集。




图3 数据集样本示例

Fig.3 sample images from the dataset

测试环境基于深度学习框架PyTorch和Python 3.12构建,计算平台配置Intel Core i5-10210U处理器和16 GB内存。所有代码均在x64架构下运行,利用PyTorch的自动微分和CPU优化加速计算。

将ConvNeXt与ResNet-50和Swin Transformer进行对比,所有模型使用相同的训练参数:优化器为AdamW,初始学习率为0.000 1,权重衰减为0.000 5,采用每3个周期衰减0.1的分步衰减策略。考虑到GPU内存限制,批量大小为1,并使用梯度累积技术每2次前向传播更新1次参数。训练过程自动检测CUDA设备并监控损失变化,共训练10个周期,每周期结束后在验证集上评估性能,确保模型收敛。

1.3 训练结果与分析

通过训练损失曲线和4项测试集量化指标对ConvNeXt、ResNet-50,以及Swin Transformer的性能进行对比评估。

(1) 训练损失函数

采用Mask R-CNN的多任务损失函数(total loss)作为模型训练的优化目标^[19],该损失函数由分类损失、边框回归损失和掩码损失构成,共同监督模型完成目标识别、定位与分割。分类损失 L_{cls} 通过多类交叉熵函数计算预测类别概率与真实类别标签之间的差异;边框回归损失 L_{bbox} 采用smooth L_1 损失函数,对预测边界框参数与真实边界框参数之间的偏差进行度量;掩码损失 L_{mask} 在目标区域内逐像素计算预测掩码与真实掩码的误差,采用二值交叉熵损失函数进行定义。

$$L_{cls} = - \sum_{i=0}^K y_i \log_a p_i, \quad (1)$$

$$L_{bbox} = \sum_{i \in \{x, y, w, h\}} \text{smooth} L_1(t_i - t_i^*), \quad (2)$$

$$\text{smooth} L_1(\Delta x) = \begin{cases} 0.5 \Delta x^2 & |\Delta x| < 1 \\ |\Delta x| - 0.5 & \text{其他} \end{cases}, \quad (3)$$

$$L_{mask} = - \frac{1}{N} \sum_{k=1}^N [y_k \log_a \hat{y}_k + (1 - y_k) \log_a (1 - \hat{y}_k)], \quad (4)$$

式(1)~式(4)中: K 为类别总数; y_i 为该区域属于第*i*类的真实标签; a 为底数; p_i 为模型预测该区域属于第*i*类的概率; t_i 和 t_i^* 分别为预测边界框与真实边界框在位置与尺度参数上的回归结果; Δx 为真实边界框与候选框之间的偏移量; N 为掩码中像素点数; y_k 为第*k*个像素的真实标签; $\hat{y}_k$ 为对应像素属于目标区域的预测概率; $\{x, y, w, h\}$ 为框的位置。

总损失值越低,模型的综合预测性能越好,总损失值的表达式为

$$L = L_{cls} + L_{bbox} + L_{mask} \quad (5)$$

各模型训练过程中损失值变化情况见图4。在前100次迭代训练中,ConvNeXt模型损失值先快速减小,后趋于平稳,ResNet-50的损失值减小缓慢且有波动,Swin Transformer的损失值收敛迟缓,可见使用ConvNeXt主干的模型,在损失收敛速度和稳定性方面优于其他模型。




图4 3种模型的训练损失值对比

Fig.4 comparison of training loss values of three models

(2) 模型测试结果

为定量评估模型的分割性能, 采用准确率 (Accuracy)、交并比 (IoU)、召回率 (Recall) 与 Dice 相似系数, 分别从总体精度、空间重叠度、漏检控制与形状相似性等维度衡量模型性能。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}, \quad (6)$$

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}}, \quad (7)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (8)$$

$$\text{Dice} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}}, \quad (9)$$


式 (6) ~ 式 (9) 中, TP、TN、FP、FN 分别为真正例、真负例、假正例与假负例的样本数量。

各模型在测试集上的性能对比见表 2。使用 ConvNeXt 作为主干网络的模型, 4 项测试指标均优于 ResNet-50 和 Swin Transformer。

表 2 3 种模型的测试指标
Tab.2 testing metrics of the three models

模型	准确率/%	召回率/%	IoU/%	Dice/%
ConvNeXt	89.51	91.83	71.73	82.95
ResNet-50	84.64	86.62	68.42	73.63
Swin Transformer	78.16	79.58	55.49	75.91

各模型对同一张图像的预测结果见图 5。对比可见, ConvNeXt 模型生成的分割边界更精确, 稳定性更高。基于上述训练与测试, ConvNeXt 主干网络实现了岩体裂隙的像素级分割, 将原始图像转化为裂隙和背景的二值掩码图, 为后续几何特征提取提供数据基础。



(a) 原图 (b) ResNet-50 (c) ConvNeXt

图 5 不同模型的预测结果对比

Fig.5 comparison of prediction results of different models

2 裂隙参数提取方法

在完成裂隙图像分割识别后, 进行裂隙的矢量化处理, 计算长度、宽度和倾角等几何特征参数。构建从岩体图像中提取裂隙参数的技术体系, 通过数字图像处理与识别算法, 将深度学习模型输出的二值掩码图转化为具有明确物理意义的量化指标^[20-23]。

2.1 基于连通域分析的基础几何参数计算

选择裂隙最大长度 x_1 、最大宽度 x_2 、裂隙数量 x_3 , 以及裂隙面积占比 x_4 构建基础几何参数, 量化裂隙的发育规模。通过现场拍摄时置于岩体表面的标准参照物, 确定像素与物理尺寸的转换系数 k 。

采用连通域分析的计算流程, 对裂隙二值掩码图进行连通域标记与统计分析, 识别所有独立的裂隙区域并获取其外接矩形与像素面积等基本属性。为消除噪声干扰, 设置面积阈值 T_{area} 为 20 像素, 对微小连通域进行过滤。

裂隙数由过滤后的连通域总数直接确定, 裂隙面积占比为裂隙像素总面积与图像总像素面积的比, 表示为

$$x_3 = \frac{\sum_{i=1}^N A_{i, \text{crack}}}{A_{\text{total}}} \times 100\%, \quad (10)$$

式中: $A_{i, \text{crack}}$ 为裂隙区域 i 的像素数; A_{total} 为图像总像素数。

对于单条裂隙的尺寸度量, 通过各连通域的最小外接矩形计算, 裂隙的物理长度和宽度分别为外接矩形的长边和短边, 并通过像素尺寸与标定系数换算, 最终取所有裂隙中的最大值。

2.2 交叉点检测与平行裂隙组识别

(1) 平行裂隙组数 x_5 的选择

x_5 用来识别岩体中的优势结构面方向, 需对裂隙进行分组, 通过计算裂隙方向角并进行聚类实现平行裂隙组的自动划分。

首先计算单条裂隙方向角, 对于 2.1 节中识别出的第 i 个独立裂隙区域, 计算其最小外接矩形。将该矩形的长边方向定义为该裂隙的主方向。对于任意两条裂隙 i 和 j , 考虑到方向角的周期性, 其方向差异度为

$$d_{ij} = \min(|\theta_i - \theta_j|, 180^\circ - |\theta_i - \theta_j|), \quad (11)$$

式中, θ_i 、 θ_j 分别为裂隙 i 和 j 的方向角度。

遍历所有裂隙组, 计算其方向差异度 d_{ij} , 形成

$N \times N$ 的差异度矩阵 D 。设定角度容差阈值 $\Delta\theta$ 为 15° ，若 $d_{ij} \leq \Delta\theta$ ，则认为裂隙 i 和 j 方向近似平行，将所有满足该平行关系的裂隙合并，形成若干个独立的裂隙组，统计最终输出的独立集合数，即为平行裂隙组数。

(2) 裂隙骨架交叉点的数量 x_6 的选择

x_6 用来量化裂隙网络的复杂程度，通过骨架化与像素级邻域分析实现该目标。

采用骨架化算法对裂隙二值掩码图进行处理，通过迭代腐蚀，在保持裂隙拓扑结构不变的前提下，消除边界像素直至其宽度为1，得到单像素宽的裂隙骨架图。遍历骨架图中的每一个前景像素点 $p(x,y)$ ，考察其8邻域 $\sum N_8(p)$ ，当邻域内前景像素的数量满足 $\sum N_8(p) \geq 3$ 时，判定为交叉点候选，此条件识别“T”型、“X”型、“Y”型交叉构型。

为避免交叉点区域在8邻域内被重复识别为多个候选点，采用非极大值抑制策略，在以原始候选点为中心的 3×3 窗口内仅保留1个邻域内前景像素最多的点，确保每个交叉点只被计数1次。对去重后的所有候选点进行计数，其总数即为 x_6 。

2.3 基于多特征融合的岩体粗糙度评估

在岩体工程中，节理粗糙度系数 (JRC) 通常用于表征结构面的表面起伏特征，但本文研究面向二维图像条件下岩体完整性系数的整体表征，重点关注图像尺度下岩体表面的不规则性与破碎特征。鉴于研究对象与尺度不同，构建一种基于图像特征的粗糙度^[24]指标 x_7 ，采用具有互补性的特征，灰度波动、边缘复杂度和局部纹理，从起伏幅度、轮廓曲折度和微观结构变异度对岩体表面特性进行描述，并用于后续完整性系数预测分析。根据二值掩码图，从原始RGB图像中截取出每个独立的目标区域图像块，对其进行特征提取，包括灰度波动特征 F_1 、边缘复杂度特征 F_2 、局部纹理特征 F_3 。

F_1 将目标区域原始图像转换为灰度图，并计算其像素值的标准差 σ_c ，以表征表面的明暗变化幅度。 F_2 对灰度图应用Canny算子得到边缘图像。通过计算边缘像素数与目标区域总像素数的比值得到边缘密度 ρ_c 。 F_3 计算目标区域的局部二值模式 (LBP) 图像，并求取该LBP图像的方差 V_{LBP} ，用来量化局部纹理的剧烈变化程度。

采用Z-Score方法对上述3个特征进行归一化，

并通过线性加权融合计算粗糙度初始评分 S' ，即

$$S' = 0.4 \times \frac{\sigma_c - \mu_c}{\sigma_c} + 0.4 \times \frac{\rho_c - \mu_c}{\sigma_c} + 0.2 \times \frac{V_{LBP} - \mu_v}{\sigma_v}, \quad (12)$$

式中： σ_c 、 σ_v 、 σ_v 为3个特征对应的标准差； μ_c 、 μ_c 、 μ_v 为3个特征对应的均值。

将初始评分 S' 通过线性变换映射到区间 $[0,50]$ ，得到最终粗糙度评分 S 。根据预先设定的阈值区间，将评分 S 划分为5个粗糙度等级，见表3。

表3 粗糙度评分与等级划分

得分范围	粗糙度等级	粗糙度描述
0~10	1	极光滑
>10~20	2	较光滑
>20~30	3	中等粗糙
>30~40	4	粗糙
>40~50	5	极粗糙

通过对裂隙的几何形态、网络结构及表面粗糙度进行量化分析，构建7维特征参数集，作为裂隙特征与 K_v 映射模型的输入特征集。

3 完整性系数预测与机理分析

3.1 预测模型构建与结果分析

为验证遗传规划模型在完整性系数预测中的有效性^[25]，选取支持向量机回归模型和随机森林回归模型作为对比基线模型。以相同的裂隙特征参数作为输入，完整性系数作为输出，在统一的数据预处理和特征处理流程下进行对比分析。选取均方根误差 E_{RMS} 和平均绝对百分比误差 E_{MAP} 作为主要评价指标。

为减小样本划分随机性对模型评价结果的影响，采用五折交叉验证策略对不同模型的预测性能进行评估，计算测试集的 E_{RMS} 和 E_{MAP} ，结果见表4。支持向量机模型和遗传规划模型的 E_{RMS} 与 E_{MAP} 处于同一数量级，表明这两种模型均能够较好地实现完整性系数的预测，而随机森林模型整体误差相对偏大。

表4 模型预测性能对比

模型	E_{RMS}	$E_{MAP}/\%$
遗传规划	0.026 3±0.009 4	2.57±0.46
支持向量机	0.021 3±0.001 9	1.97±0.59
随机森林	0.046 9±0.014 2	9.09±2.11

在预测精度相似的情况下,相比于支持向量机等黑箱模型,遗传规划模型能输出显式数学表达式,可解释性和工程可读性更好,在预测完整性系数时综合优势明显。因此,通过遗传规划优化,获得 K_v 的预测模型。

$K_v=1.2311-1.78\times10^{-4}\times$

$$\frac{x_1x_6x_7+418.7-x_1x_2(x_6-x_4)(x_1-x_6)}{\sqrt{x_1+2x_5-x_7-x_1}}-0.028\times$$
$$\left(x_1+x_5+x_6+\sqrt{396.89-x_7}-\sqrt{x_4}+\sqrt{x_1}\right)+$$
$$1.92\times10^{-6}\times\left(\frac{182.8+991.7x_1x_2^2}{x_1x_4-x_1-x_3+\sqrt{x_7}}+\frac{e^{2x_6+x_5}}{e^{x_1}+x_2^2}\right)+$$
$$7.69\times10^{-6}\times\left[x_2x_4^{1.25}(x_6x_7^3+x_1x_2^2)\right]-0.008\times$$
$$\left(x_3^2-2x_1+\sqrt{x_5-x_7}+\sqrt{x_7}-\sqrt{x_3}-\sqrt{x_4}\right)。(13)$$

为评估输入特征对完整性系数的影响,采用Morris敏感性分析方法,计算主效应 μ (一阶敏感性指数)和交互效应 σ (总效应敏感性指数)评估各输入变量的影响程度。使用SALib库中的Morris采样模块,采样轨迹数 N 为300,水平数为4,最终计算得出各变量敏感性指标,各输入特征的主效应和交互效应见图6。裂缝最大长度 x_1 、最大宽度 x_2 、总数量 x_3 及像素占比 x_4 为主要影响因素,其 μ 大于 4.0×10^5 ,显著超过其他变量,主效应贡献较大。所有变量的 σ 均偏大,主要变量 x_1 、 x_2 、 x_3 的 σ 均接近或超过 8.0×10^5 ,说明存在交互与非线性耦合的变量,这与工程中裂隙参数相互影响的规律相符。




图6 参数敏感性分析对比

Fig.6 comparative analysis of parameter sensitivities

经过Z-score标准化并统计相对重要性,结果见表5,与遗传规划模型的复杂表达式一致。模型通过测试验证,展现了优异的预测性能和工程应用价值,为岩体完整性评估提供了可靠工具。

表5 Morris敏感性分析结果

Tab.5 Morris sensitivity analysis results			
参数	μ	σ	相对重要性/%
x_1	1.48	1.14	20.57
x_2	0.07	0.61	17.44
x_3	0.53	1.11	18.98
x_4	1.04	0.20	18.39
x_5	-1.36	-1.52	11.79
x_6	-0.93	-1.31	12.81
x_7	-0.85	-0.23	20.57

3.2 参数对岩体完整性系数的影响机制分析

根据遗传规划模型获得的非线性表达式,结合岩体力学与断裂力学原理分析各裂隙特征参数对 K_v 的影响机制。

在裂隙尺度参数中, x_1 被识别为最关键影响因素。其作用机制符合断裂力学原理, x_1 的增加导致应力集中程度加剧,裂隙进一步扩展,降低了岩体波速与完整性系数。遗传规划模型中的高阶非线性项进一步揭示 x_1 在粗糙且交叉的裂隙网络中具有主导破坏作用。 x_2 的影响则呈现显著非线性特征,其效应与裂隙长度、粗糙度等参数密切耦合, x_2 的增大通常导致岩体初始张开度增加,形成结构性弱面;但当裂隙被后期矿物充填时,此种负面效应可能减弱。

遗传规划模型中, x_3 与 x_4 共同构成多个分数项的分母,精确反映了工程实际中的损伤累积效应。随着裂隙密度增大,岩体损伤效应加剧,强度与稳定性显著降低,导致 K_v 值急剧下降。

裂隙网络拓扑参数中,平行裂隙组数 x_5 的增加意味着潜在滑移面增多,加剧岩体各向异性,降低整体稳定性。交叉点数量 x_6 的上升直接导致裂隙网络连通性增强,遗传规划模型通过乘积项显示其与岩体破碎程度呈正相关,交叉点的密集分布引发复杂应力传递与潜在滑移,对完整性产生显著负面影响。

粗糙程度 x_7 的影响机制较为复杂,虽然粗糙裂隙面可提供更大摩擦力,但其不规则性同时增强波的散射与反射,降低波速。遗传规划模型包含的幂函数与指数项,特别是三次方项结构,准确刻画了粗糙度影响的非线性增长特性,最终表现为 K_v 值的减小。

3.3 应用示例与验证

为验证本文方法的实际可操作性并展示其实现流程,选取某典型岩体区域(约20 m×15 m)作为示例。在该选定区域内随机布设20个拍摄点位,

每个拍摄点位拍摄1张岩面图像。

某拍摄点的原始岩体图像见图7(a),将该图像输入ConvNeXt模型,得到裂隙二值掩码图,见图7(b)。利用自动化图像处理算法对该掩码图进行分析,提取7维裂隙特征,得到该样本的最大长度为2842像素、最大宽度为329像素、裂隙数量为19条、面积占比为1.27%、平行裂隙组数为3组、交叉点为8个、粗糙度评分为34.2。将特征向量转化成实际长度后代入遗传规划预测模型,计算得到该样本完整性系数 K_v 预测值为0.61。




图7 应用示例

Fig.7 application example

对全部20个样本重复上述流程, K_v 预测值分布在0.4579~0.6849区间内,均值为0.57,变异系数为0.09。该区域整体完整性等级为较完整至较破碎,与现场地质调查结果一致。上述验证表明,本文方法在多点测试中结果稳定,具备快速、轻便的特点,适用于无法开展波速测试的场景。

4 结论

围绕岩体完整性系数的快速评估需求,提出一种从裂隙图像智能识别、几何参数自动提取到完整性系数非线性预测的方法,主要结论如下。

(1) 通过对Mask R-CNN模型进行改进,引入ConvNeXt作为主干网络,在岩体裂隙识别任务中实现了91.83%的召回率,分割精度和收敛稳定性均优于ResNet-50和Swin Transformer模型,为裂隙参数的精准提取奠定了可靠基础。

(2) 构建了裂隙多维度参数自动化提取体系,可从二值掩码图中有效量化裂隙的尺度、密度、网络拓扑与表面形态等7个特征参数,实现了裂隙几何信息向具有力学意义的量化指标的转化。

(3) 在支持向量机和随机森林等模型对比基础上,构建了具有综合优势的遗传规划 K_v 非线性预测模型,揭示了裂隙参数与完整性系数之间的复杂关系。该模型具备良好的工程适用性和较强

的可解释性。深入分析表明,岩体破坏由多重裂隙特征的协同作用引起。

本文结合深度学习、图像分析与遗传规划算法,构建了从裂隙识别到岩体完整性系数预测的完整方法体系,在无法开展传统波速测试的工程条件下具有良好的应用潜力。未来研究将从以下方向开展:①扩充覆盖不同岩性与工程尺度的多场景数据集,提升模型在复杂工程条件下的泛化能力;②结合三维重建技术,将二维裂隙图像分析拓展至三维裂隙网络表征;③推进模型轻量化与移动端部署,实现工程现场的快速实时评估。

参考文献(References):

- [1] 中华人民共和国住房和城乡建设部. 工程岩体分级标准: GB/T 50218—2014[S]. 北京: 中国计划出版社, 2015: 6-10.
- [2] 蔡建华, 张海超, 汪旭. 隧道掌子面岩体完整性系数快捷测试布置方法研究[J]. 现代隧道技术, 2019, 56(2): 164-169.
CAI Jianhua, ZHANG Haichao, WANG Xu. Research of the arrangement method for quick testing rock-mass integrity index on tunnel face[J]. Modern Tunnelling Technology, 2019, 56(2): 164-169.
- [3] 殷明伦, 张晋勋, 江玉生, 等. 岩体体积节理数表征岩体完整系数的结构面类别修正研究[J]. 岩土力学, 2021, 42(4): 1133-1140.
YIN Minglun, ZHANG Jinxun, JIANG Yusheng, et al. Study of correction of the structural plane category based on the rock mass integrity coefficient characterized by the volumetric joint count [J]. Rock and Soil Mechanics, 2021, 42(4): 1133-1140.
- [4] HASAN M, SHANG Y J, YI X T, et al. Determination of rock mass integrity coefficient using a non-invasive geophysical approach [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2023, 15 (6): 1426-1440.
- [5] WANG J C, HAN Z Q, WANG C, et al. Rock mass integrity evaluation method of roadway surrounding rock mass based on borehole image acoustic radar data [J]. Scientific Reports, 2025, 15: 22050.
- [6] KASHYAP S, BHANDARI A K, GIRI P. Low resource FPGA implementation based efficient image edge detector architecture [J]. Multimedia Tools and Applications, 2024, 83(9): 25595-25615.
- [7] 傅金阳, 梁向荣, 王宇, 等. 基于三维超像素分割的隧道围岩结构面智能识别方法[J]. 中国公路学报, 2023, 36(11): 289-301.
FU Jinyang, LIANG Xiangrong, WANG Yu, et al. Intelligent identification of discontinuity in surrounding rock of tunnels based on three-dimensional superpixel segmentation [J]. China Journal of Highway and Transport, 2023, 36(11): 289-301.
- [8] ZHAO G B, RUAN M D, TUNCAY D, et al. Investigation on capturing bedding planes in laminated shale through advanced physics-informed image processing for multiscale geomechanical simulation [J]. Engineering Geology, 2025, 347: 107929.
- [9] 王军祥, 曾相森, 徐晨晖, 等. 基于图像处理技术的岩体裂隙定量识别方法研究[J]. 地下空间与工程学报, 2022, 18(2): 446-457.

- WANG Junxiang, ZENG Xiangsen, XU Chenhui, et al. Study on quantitative identification method of rock fracture based on image processing technology[J]. Chinese Journal of Underground Space and Engineering, 2022, 18(2): 446-457.
- [10] WU X, WANG F Y, CHEN J P, et al. Automatic extraction of tunnel surrounding rock fractures based on FPD-net and integrated post-processing technology[J]. Tunnelling and Underground Space Technology, 2025, 166: 106993.
- [11] 王春艳, 王康乐, 姜勇, 等. 基于U²-Net与动态索引旋转卷积的混凝土路面裂缝提取[J]. 辽宁工程技术大学学报(自然科学版), 2025, 44(6): 746-752.
- WANG Chunyan, WANG Kangle, JIANG Yong, et al. Crack extraction of concrete pavement based on U²-Net and dynamic index-based rotational convolution[J]. Journal of Liaoning Technical University (Natural Science), 2025, 44(6): 746-752.
- [12] CHAIYASARN K, BUATIK A, MOHAMAD H, et al. Integrated pixel-level CNN-FCN crack detection via photogrammetric 3D texture mapping of concrete structures[J]. Automation in Construction, 2022, 140: 104388.
- [13] De CARVALHO O L F, De CARVALHO JÚNIOR O A, De ALBUQUERQUE A O, et al. Instance segmentation for large, multi-channel remote sensing imagery using mask-RCNN and a mosaicking approach[J]. Remote Sensing, 2021, 13(1): 39.
- [14] LI Q L, XU X Y, GUAN J J, et al. The improvement of faster-RCNN crack recognition model and parameters based on attention mechanism [J]. Symmetry, 2024, 16: 1027.
- [15] LYU H T, QIU F, AN L, et al. Deer survey from drone thermal imagery using enhanced Faster R-CNN based on ResNets and FPN [J]. Ecological Informatics, 2024, 79: 102383.
- [16] 杨宇轩, 钟宝荣. 基于改进ConvNeXt模型的轻量化岩屑岩性识别方法[J]. 现代电子技术, 2024, 47(24): 131-136.
- YANG Yuxuan, ZHONG Baorong. Method of lightweight rock debris lithology identification based on improved ConvNeXt model [J]. Modern Electronics Technique, 2024, 47(24): 131-136.
- [17] WANG D F, HU H F, CHEN D H. Transformer with sparse self-attention mechanism for image captioning [J]. Electronics Letters, 2020, 56(15): 764-766.
- [18] RUSSELL B C, TORRALBA A, MURPHY P K P, et al. LabelMe: a database and web-based tool for image annotation [J]. International Journal of Computer Vision, 2008, 77(1/2/3): 157-173.
- [19] 周欣, 徐培哲, 李堃, 等. 基于损失函数与注意力机制改进的YOLOv8火焰目标检测算法优化研究[J]. 船海工程, 2025, 54(2): 19-25.
- ZHOU Xin, XU Peizhe, LI Kun, et al. Optimization of YOLOv8 flame target detection algorithm based on improved loss function and attention mechanism[J]. Ship & Ocean Engineering, 2025, 54(2): 19-25.
- [20] ZHAO Y, HE X, JIANG L S, et al. Influence analysis of complex crack geometric parameters on mechanical properties of soft rock [J]. International Journal of Coal Science & Technology, 2023, 10: 78.
- [21] WANG S W, XU J B, WU X, et al. Concrete crack recognition and geometric parameter evaluation based on deep learning [J]. Advances in Engineering Software, 2025, 199: 103800.
- [22] QIN Y, XU N X, HAN J, et al. Experimental study on the effects of geometric parameters of filled fractures on the mechanical properties and crack propagation mechanisms of rock masses [J]. Rock Mechanics and Rock Engineering, 2023, 56(4): 2697-2716.
- [23] 吴顺川, 孙贝贝, 余一松, 等. 考虑几何特征的岩体裂隙迹线多尺度图像识别方法[J]. 华中科技大学学报(自然科学版), 2024, 52(9): 101-109, 117.
- WU Shunchuan, SUN Beibei, YU Yisong, et al. Multi-scale image recognition method of rock mass fracture traces considering geometric features [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2024, 52(9): 101-109, 117.
- [24] 韩圳. 煤岩表面粗糙度智能图像识别技术及应用[D]. 徐州: 中国矿业大学, 2021: 31-45.
- [25] 谢渊, 高玮, 汪义伟, 等. 基于哈里斯鹰优化遗传规划的钢筋混凝土地下结构硫酸盐腐蚀寿命预测[J]. 土木工程学报, 2022, 55(4): 33-41.
- XIE Yuan, GAO Wei, WANG Yiwei, et al. Life prediction of RC underground structure by sulfate attack based on harris hawks optimizing genetic programming [J]. China Civil Engineering Journal, 2022, 55(4): 33-41.