

DOI: 10.11779/CJGE201810007

# 基于深度学习技术的公路隧道围岩分级方法

柳厚祥<sup>1</sup>, 李汪石<sup>1,3</sup>, 查焕奕<sup>1</sup>, 蒋武军<sup>2</sup>, 许腾<sup>1</sup>

(1. 长沙理工大学土木工程学院, 湖南 长沙 410114; 2. 湖南省永吉高速公路建设开发有限公司, 湖南 吉首 416000;  
3. 湖南省建筑设计院有限公司, 湖南 长沙 410000)

**摘要:** 通过深度学习技术提取公路隧道掌子面图片中的围岩分级相关信息。训练以掌子面图片和特征标签为数据集的深度卷积神经网络模型, 识别围岩的节理、裂隙、破碎程度、粗糙程度、光滑程度、泥夹石和涌水等分布式特征; 结合深度学习技术和岩体裂隙图像智能解译方法统计围岩节理组数和间距来描述结构面完整程度; 再利用色彩模型确定岩石种类描述出岩石坚硬程度; 最后将围岩分级各判别因子转换为 BQ 值进行分级, 获得围岩分级最终结果。结果表明: 深度学习模型适用于识别围岩不同形态特征, 利用图像识别技术获取的围岩分级参数能够实现对公路隧道围岩等级的综合判定。该处理结果与传统 BQ 分级结果相吻合, 验证了深度学习围岩分级的可行性和准确性。

**关键词:** 公路隧道; 围岩分级; 深度学习技术; 图像识别

中图分类号: U451.2

文献标识码: A

文章编号: 1000 - 4548(2018)10 - 1809 - 09

作者简介: 柳厚祥(1965 - ), 男, 湖南省邵阳人, 硕士生导师, 博士。E-mail: liuhoux1@163.com。

## Method for surrounding rock mass classification of highway tunnels based on deep learning technology

LIU Hou-xiang<sup>1</sup>, LI Wang-shi<sup>1,3</sup>, ZHA Zhuan-yi<sup>1</sup>, JIANG Wu-jun<sup>2</sup>, XU Teng<sup>1</sup>

(1. School of Civil Engineering, Changsha University of Science & Technology, Changsha 410114, China; 2. Hunan Yongzhou to Jishou Expressway Construction and Development Co., Ltd., Jishou 416000, China; 3. Hunan Province Architectural Design Institute Co., Ltd., Changsha 410000, China)

**Abstract:** By extracting the relevant information of surrounding rock classification of road tunnel face using the deep learning technology, a multilayer convolution neural network model is established to recognize the distributive features of surrounding rock including joints, cracks, broken situations, rough degrees, smooth degrees, mud stone and water burst, etc. The deep learning AlexNet model is modified to count the number and spacing of rock joints. The deep convolution is used to extract different rock boundaries, and the specific species of rock are determined by the comprehensive color model. The degree of development of structural plane, rock hardness, structural plane roughness, groundwater development, structural types and degree of grade factors of the surrounding rock classification are qualitatively described for the results of the surrounding rock classification so as to obtain the final results of the surrounding rock classification. The results show that the deep learning model is applicable to identify different morphological characteristics of the surrounding rock. Based on the Matlab interface technology, image recognition technology, boundary extraction technology and HIS color model, the comprehensive judgement of surrounding rock classification of highway tunnels is realized. In order to verify its feasibility and accuracy, the classification results of the deep learning technology are compared with those of the traditional BQ classification.

**Key words:** highway tunnel; rock mass classification; deep learning technology; image recognition

## 0 引言

近年来,我国在隧道围岩分级研究领域有了较大的发展,一些学者提出了利用 BP 神经网络和支持向量机进行围岩分级<sup>[1-4]</sup>,给出每个分级指标的现场测试方法,创新地使用了训练、预测形式的快速分级方法。陈安凡等<sup>[5]</sup>、牛文林等<sup>[6]</sup>建立围岩分级专家系统,利用互联网的优势提高了围岩分级的准确度。文献[7~

9]总结和改进了针对不同环境的围岩分级方法,为现场的设计变更提供了具体依据。现有的围岩分级方法都使用复杂的设备来提取围岩分级参数,事实上在施工阶段依靠人的主观判断来进行围岩分级仍然是主要

基金项目:湖南省交通科技项目(201331);长沙理工大学优秀学科项目(17ZDXK01)

收稿日期:2017-08-09

的方式。原因是施工单位在成本和效率上的双重考量,没有丰富的专业知识往往会有误判的情况产生。因此寻找一种综合两者优点的隧道围岩分级方法是研究的必然趋势。本文从人工智能的角度考虑,运用深度学习技术<sup>[10-12]</sup>识别出围岩分级相关特征,提出了一种准确快速的围岩分级方式。

## 1 深度学习网络 AlexNet 模型<sup>[13-14]</sup>

掌子面图片收集自湖南湘西永吉高速那丘、六月田、务西作、罗依溪、白尖山、狮子庵隧道及张桑高速麻栗垭、白龙庵、黄香湾隧道。原始数据集由 6000 张掌子面图片构成,经过剪切去除台车和使用数据扩展方法等操作,将图片的大小调整为 256×256 大小,并将数据集增加至 10000 张。数据集可分为 7 大类围岩形态。其中 2000 张作为测试集,8000 张作为训练集,训练集中裂隙特征的图片 1100 张,涌水 100 张,粗糙无规则的图片 2100 张,表面光滑图片 1200 张,岩土混合的图片 1100 张,破碎状图片 1200 张,密集节理 1200 张,测试集中裂隙特征的图片 300 张,涌水 50 张,粗糙无规则的图片 550 张,表面光滑图片 300 张,岩土混合的图片 300 张,破碎状图片 300 张,密集节理 200 张。本文采用卷积神经网络的 AlexNet 模型,图片存储为 JPG 格式,图像要求在光线充足、空气中粉尘颗粒较少的环境下进行拍摄。将原图像经过一系列预处理(裁剪、去除吊车等)后,利用 AlexNet 模型进行分析。

在深度学习分析前,笔者将围岩分级参数与图片中的信息相对应,即图片具有某一特征时它将会自带一些围岩分级参数,见表 1。

表 1 围岩分级因素对应信息

Table 1 Corresponding information of classification factors of surrounding rock

图片类型	围岩分级因素			
	风化程度	完整程度	节理裂隙发育程度	地下水发育程度
裂隙	—	—	发育 <sup>①</sup>	—
涌水	—	—	—	线流状出水或涌流状出水 <sup>②</sup>
光滑	—	完整 <sup>③</sup>	不发育 <sup>④</sup>	—
密集节理	—	破碎 <sup>⑤</sup>	较发育 <sup>⑥</sup>	—
破碎	—	破碎 <sup>⑦</sup>	发育 <sup>⑧</sup>	—
泥石混合	强风化 <sup>⑨</sup>	—	—	—
粗糙	—	较破碎 <sup>⑩</sup>	—	—

注:(1)表中“—”表示需要额外的辅助方法来判断,详见第 2,3 节。

(2)节理裂隙发育程度在一定程度上能够体现完整程度。(3)表中的内容为该类型掌子面图片本身具备的围岩分级参数,即能够从图片来主观判

断出的围岩分级因素。(4)表格内容的逐一注解:①需补充裂隙的组数和间距来表示发育程度,详见第 2 节;②涌水图片主要分两种:线流状出水和涌流状出水,收集两种类型的图片分别训练即可;③光滑的掌子面应是完整的;④光滑的掌子面不具备节理裂隙发育情况;⑤⑥密集节理的结构面组数大于 3 组,且间距较小,因此完整性属于较破碎或破碎;⑦⑧破碎状完整性同样属于破碎,节理裂隙发育明显;⑨泥石混合中有黏土、砂土等存在,属于强风化的结果;⑩粗糙的掌子面完整性为较破碎,但和破碎的掌子面在图片上分析类似。

利用 Caffe 可视化工具箱提取逐层特征并附加各层的特征直方图,特征直方图对于图像的缩放、平移、旋转等变化不敏感,具有一定的视觉不变性和具有较高的鲁棒性,能够准确地描述围岩的形态特征。

AlexNet 网络具有多层特征,本文贴出能够体现形态特征的卷积层第二层可视化结果,加上代表该特征的特征直方图,综合各类围岩所特有的属性,获得分类结果(见图 1~7)。图 1~7 中(a)图是从数据库中选出的能够代表该种类型的典型图片,AlexNet 模型训练结果附带对需要预测图片的百分比,类型百分比越高说明与该类型图片越相似,上附图中以最高值作为预测结果,同时列举出百分比为靠前的几项来观察预测的差异。图 1~7 中(b)图可视化了计算机对结构特征卷积统计的过程,而图 1~7 中(c)图和图 1~7 中(b)图则表达了该类特征的一般特征直方图,对预识别的图片的种类有重要的指导作用。识别率是 AlexNet 模型对该图片种类的预测,识别率越高就说明与该特征越符合,因此我们将识别率最高的一项作为预测的最终结果。从图中识别分布可以看出,裂隙、光滑以及涌水的特征较为明显,识别率较高;密集节理和粗糙两种围岩特征的识别率较低,原因是二者均表现出复杂的纹理和不稳定的图形边界,增加数据集能够提高识别准确率。从整体来看深度学习技术对围岩特征的识别获得了较为满意的结果。图 1~7 中(c)图的横坐标表示全连接层的 2048\*2 神经元,纵坐标表示该代表神经元的特征值;图 1~7 中(d)图表示每种特征值出现的频率。特征直方图在一定程度上代表了图片形态特征,对于预测图片和训练图片,相似度越大则越可能是同一类型图片。

深度学习技术识别的特征为:裂隙 62%,密集节理 31%,光滑 5%,识别率较高;涌水 73%,裂隙 11%,识别率较高;光滑 54%,节理 20%,识别率较高;节理 40%,粗糙 38%,识别率一般;破碎 71%,节理 20%,识别率较高;泥石混合 50%,节理 30%,光滑 10%,识别率较高;粗糙 20%,节理 15%,识别率一般。围岩特征本身具备一些分级参数信息,但是围岩种类和节理间距与数量在该方法下无法确认,因此需要增加额外的步骤来解决这两个参数的获取问题。




图 1 裂隙图处理

Fig. 1 Processing of crack images




图 2 涌水图处理

Fig. 2 Processing of water burst images




图 3 光滑图处理

Fig. 3 Processing of smooth images




图 4 密集节理图处理

Fig. 4 Processing of dense joint images




图 5 破碎图处理

Fig. 5 Processing of broken images




图 6 泥夹石图处理

Fig. 6 Processing of mud stone images




图7 粗糙图处理

Fig. 7 Processing of rough images

## 2 节理特征提取的深度模型建立

岩石节理裂隙是常见的一类结构面,具有分布广、粗细各异等特点,岩石表面残留部分挖机破坏痕迹,增加了裂隙图像处理的难度。基本的围岩分级需获取节理组数、间距两个指标来确定结构面完整程度,深度学习仅分类出特征整体,需利用 matlab 图像识别技术对节理进行进一步分析处理。

### 2.1 节理模型

提取数据库中节理模型的一般特征,首先找出掌子面图片中满足要求的节理并标注,再计算节理组数和相对长度,获得节理发育具体情况。

本实验中训练及测试总共 1400 张图片,其中 1100 张用于训练,300 张用于测试,总共迭代次数为 6000,初始学习率 0.01,当误差率在学习率下不再提高时,就将学习率乘以 0.1,在终止前降低三次,当迭代到 1000 次时算法已经基本收敛,错误率从 0.25 开始逐渐下降最终保持在 0.15 左右,训练结果能够满足使用要求。

训练结束后修改 AlexNet 网络最后的 softmax 函数为欧式距离函数,最后一层输出为节理的定位坐标。将损失函数改为解决回归问题的欧式距离函数,定位标注节理位置和数量(见图 8)。在本方法中,首先,

获取输入图片,提取候选框,然后送到卷积神经网络提取卷积特征,最后进行位置预测,如图 8 所示。首先对输入图片提取候选框,每张图片大约 2000 个候选框,每个候选框对应着左上和右下两个点的坐标,候选框送入卷积神经网络,计算卷积神经网络特征,如图 8 中 C1 即第一层卷积(convolution)运算,P1 为池化(pooling)操作,C2、P2 以此类推,卷积池化交叉使用,并在网络倒数二层连接全连接层(图中 FC1,FC2)预测得到节理裂隙在图像中的位置(即输出位置预测值  $x_1, y_1, x_2, y_2$ )。

标注节理后,再用监督学习的方法得到该类特征的分类器。样本进行归一化,可以对标注的样本进行训练。通常训练步骤为先进行特征选择,设置训练的参数,加入标注的训练样本,穷尽搜索样本的矩形特征,统计出具有统计特性的矩形特征,将其组成强分类器用于识别和标记(见图 9)。




图9 节理裂隙定位和统计图

Fig. 9 Joint positioning and statistical images

由图可知深度学习模型组成的分类器良好地屏蔽了非节理部分,图 9 (a)、(c) 识别出两组明显节理裂隙,图 9 (b) 是一组树状裂隙,标记出大范围的图像面积,图 9 (c) 左上角隧道开挖产生的纹理不被识别,原因是纹理长度和深度均不符合一般的节理特征。标注和统计节理组数是围岩分级的一部分,获取节理相对长度和面积需进一步分割提取。

### 2.2 节理裂隙统计

对节理裂隙特征进行分割提取,细致处理节理部分,得出节理数量及间距等围岩分级相关参数。基本步骤如下:

(1) 首先利用边缘检测对图像增强运算,再运用区域生长法进行阈值分割,设定阈值  $\zeta$  将图像分成

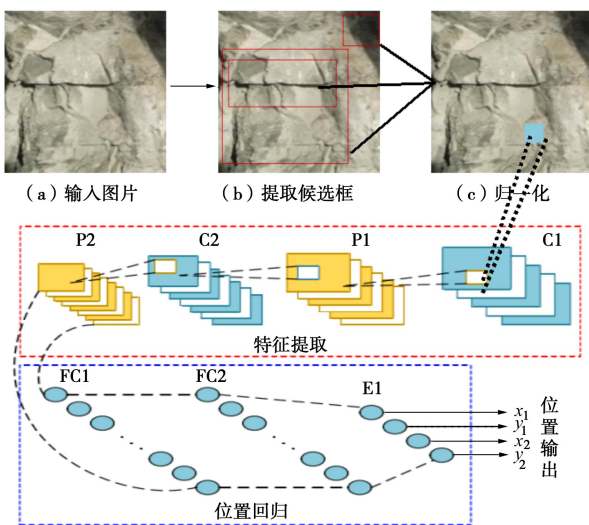


图8 特征提取过程

Fig. 8 Extraction process of features



$\zeta_{max} > \zeta, \zeta > \zeta_{min}$  两部分像素集, 分别对应两种颜色, 这种处理方法称为图像的二值化。

(2) 利用中值滤波对图像降噪处理, 把一组  $x_1, \dots, x_n$  从小到大排序:  $x_{i1} \leq x_{i2} \dots \leq x_{in}$ , 中值为处于变量数列中间位置的  $Med\{x_{i1} \leq \dots \leq x_{in}\}$ , 把数字图像中一点的值用领域的中值代替。

(3) 在特征群中找出不影响其位置的特征, 将裂隙抽象为一直线段, 其实就是对裂隙几何形状的一种一级近似。直线用极坐标参数表示, 对图像进行霍夫变换。

(4) 对于裂隙识别而言, 其目的就是在平面上找出图像中平面上代表裂隙的点线。参考文献[15], 岩土体裂隙形态参数分析法的识别基本步骤为: 排序、识别首裂隙、判别、计算节理裂隙组数和间距 (见图 10, 节理裂隙长度和间距均是相对值, 原因是图片拍摄的时候不是在固定位置, 原始图片大小也不一致, 导致无法获取实际长度。解决方法是固定距离拍摄掌子面完整图片, 在已知洞洞径的前提下换算可得出实际长度)。

图 10 (d) 通过分类器标记二值化结果, 模拟出相似矩形, 将矩形长宽与整体画面比较计算相对长度、宽度; 同时统计二值化图像白色区域像素点, 与图画像素比较得出相对面积, 通过 matlab 编辑的简易程序计算出结果 (见表 2)。

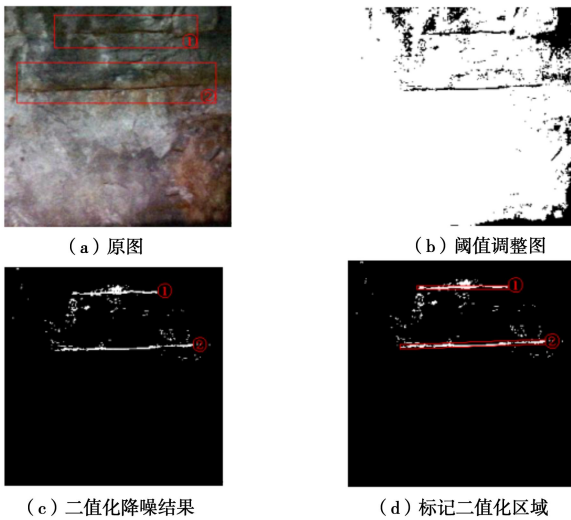


图 10 节理识别过程显示

Fig. 10 Process of joint recognition

表 2 节理识别结果

Table 2 Results of joint recognition

位置	相对长度	相对宽度	相对面积
1	3.53	0.14	0.4942
2	5.68	0.25	1.4200
总计	9.21	0.39	1.9142
裂隙组数	2	裂隙相对间距	2.2600

### 3 岩土边界及种类的深度学习提取

岩石种类繁多, 仅依靠图像识别的难度很大。本文提出以地区典型岩石为主要类别, 如本文所依托的隧道项目位于湖南省湘西永顺县芙蓉镇那丘村一带, 该地区围岩基本以石灰岩 (沉积岩) 为主, 因石灰含量存在差异会出现不同的石灰岩种类: 白云质石灰岩、黑灰岩、泥质灰岩等。岩土识别最重要的两个特征是颜色和纹理, 因纹理的各异性很强, 以颜色为主要突破点, 利用深度学习边界提取技术对围岩种类进行识别。

#### 3.1 深度学习边缘检测

在图像处理中, 用一个卷积核对图像进行卷积运算, 实际上是一个滤波过程:

$$f(x, y) * w(x, y) = \sum_{s=-1}^a \sum_{t=-b}^b w(s, t) f(x-s, y-t), \quad (1)$$

式中,  $f(x, y)$  是图像上点  $(x, y)$  的灰度值,  $w(x, y)$  则是卷积核, 也叫滤波器。

卷积操作提供了一个权重模板, 这个模板在图像上滑动, 并将中心依次与图像中每一个像素对齐, 然后对这个模板覆盖的所有像素进行加权, 并将结果作为这个卷积核在图像上该点的响应。卷积操作可以用来对图像做边缘检测、锐化、模糊等 (见图 11)。

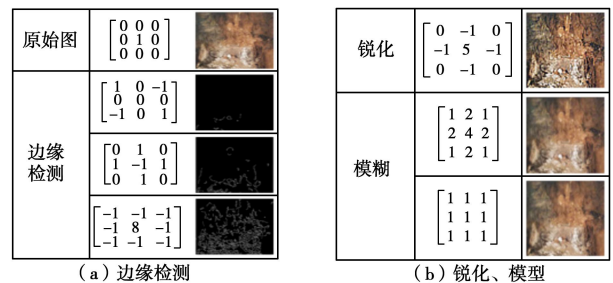


图 11 卷积可视化

Fig. 11 Convolution visualization

单个卷积核检测往往表现出噪声大、边界不明朗的特点, 而深度学习的过程就是多个卷积层叠加的过程, 多层的卷积会逐渐去除噪声, 凸显不同物体的边界。

为验证算法效果, 采用普通使用的 3 幅具有明显差异的标准彩色图进行仿真实验, 对图像分别利用传统边缘提取算子, 包括 sobel 算子、prewitt 算子以及本文的算法进行边缘提取, 结果如图 12 所示。深度学习处理结果可以看出, 在卷积层所显示的图片边缘明显优于一般的边缘检测, 能够很清晰地分辨出两种岩土之间的边界 (见图 12)。




图 12 岩土边缘提取对比

Fig. 12 Extraction of geotechnical edge

3.2 主色与 HIS 色彩空间

RGB 和 HIS 值均是描述颜色特征的基本向量，HIS 颜色空间与 RGB 颜色空间相比，具有颜色参量相关性低的优势。尤其是参量 I 与 H、S 之间，更有对外界环境产生惰性的特征，因此我们只需对 H 和 S 进行分析，就可以削减光照及其他外界因素对采样图像的影响。获得图像的 RGB 值，经过转换得到 H、S 值公式 (2~3)，就能够对 4 种岩土进行分类。

$$H = \begin{cases} \theta & G \geq B \\ \theta + \pi & G \leq B \end{cases}, \quad (2)$$

$$\theta = \frac{\pi}{2} - \tan^{-1} \left( \frac{2R - G - B}{\sqrt{3}(G - B)} \right),$$

$$S = \frac{2}{\sqrt{6}} \times \sqrt{(R - G)^2 + (R - B)(G - B)}. \quad (3)$$

灰岩的具体分类及特征如下：泥质灰岩的黏土矿物浓度达 25%到 50%；白云质灰岩中云石浓度达 25%

到 50%；石灰岩密度非常大，是晶体状等等。石灰岩积密度 2.7 g/cm<sup>3</sup> 左右，摩氏硬度 3.5~5，压缩强度 65~100 MPa。利用室内点荷载实验求得各类岩石的抗压强度范围，对应 RGB 值对岩石参数进行统计 (见表 3)。

深度卷积操作检测出不同种类围岩的边界，防止主色识别出现跨界的现象，例如图 13 (b) 出现部分噪点，原因是两边存在若干 RGB 值相同的像素点，连续封闭的边界能够解决颜色向量的误判问题。边界识别和岩土分离的基本步骤为：①利用深度卷积技术进行岩土边界提取；②使用 matlab 图像拼接命令组合边界和原图；③二值化岩石对应的主色区域；④计算彩色部分的相对面积，得出该图片各岩石种类对应的百分比 (见图 13)。




图 13 边缘检测与岩土识别

Fig. 13 Edge detection and rock identification

由图 13 (c)、(d) 计算得出该样本中的石灰岩比例为 60%，黏土为 40%，其他岩石种类未出现在图片中。样本中黏土的含水率很高，表现为潮湿或滴水状态。泥夹石围岩中黏土的存在极大地降低了围岩的

表 3 RGB 特征及围岩分级参数

Table 3 RGB characteristics and classification parameters of surrounding rock mass

岩石种类	石灰岩	黑灰岩	泥质灰岩	黄黏土
RGB 范围	150 < R(i, j) < 203 155 < G(i, j) < 210 130 < B(i, j) < 198	74 < R(i, j) < 88 73 < G(i, j) < 86 72 < B(i, j) < 90	90 < R(i, j) < 135 85 < G(i, j) < 100 78 < B(i, j) < 98	127 < R(i, j) < 200 80 < G(i, j) < 14 60 < B(i, j) < 90
抗压强度	70~120 MPa	100~120 MPa	40~60 MPa	强风化
硬度系数	f=3 较硬岩	f=4 硬岩	f=3 较硬岩	f=1 软土



稳定性,因此,出现大面积黏土的围岩等级定位在IV~V级之间。

本节利用 Matlab 工具计算出了围岩种类(见图 14)。对比围岩预测结果可以看出该方法对黏土的识别率较高,而对石灰岩和泥质灰岩的识别率一般,黑灰岩相对其他围岩颜色特征明显,因此能够准确识别。

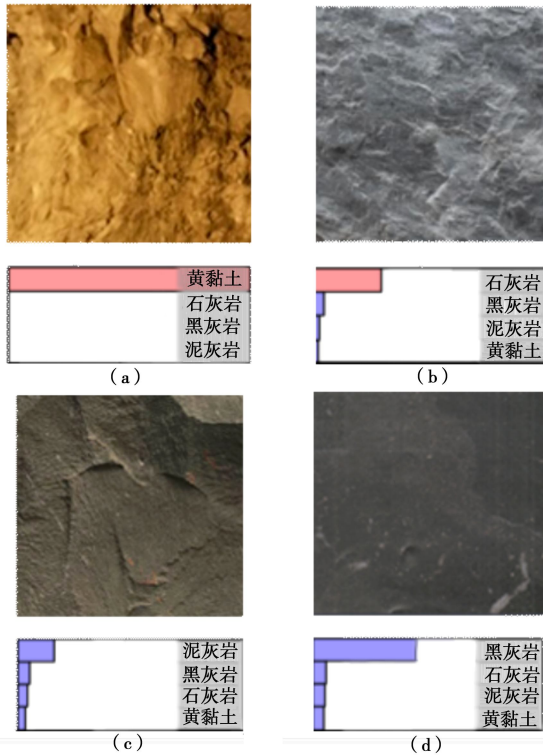


图 14 随机样本计算结果

Fig. 14 Results of a random sample

### 4 隧道围岩分级

本文所采用的方法需经过围岩特征识别、节理计算和岩土识别 4 大步骤,分别得出单轴抗压强度  $R_c$ 、岩体完整系数  $K_v$ 、地下水状况修正系数  $K_1$ 、结构面产状影响修正系数  $K_2$ 。

(1) 利用深度学习技术将预处理的图片进行归类,获得每一种围岩特征所具有的围岩分级基本参数,包括描绘结构面主要类型,是否有涌水现象发生,是否有节理裂隙存在,成份是否单一等。

(2) 使用深度学习技术提取岩土间的边界,利用围岩的 HIS 值进行种类识别,对照普世硬度系数表得出该种岩土的坚硬程度。将坚硬程度用 BQ 分级中的单轴抗压强度  $R_c$  值表示,取  $R_c$  值范围的平均值表示每一种坚硬程度,例如较坚硬的岩石  $R_c$  值是 60~30 MPa 之间,我们取中间值 45 MPa 为该岩石的单轴抗压强度  $R_c$ ,对于坚硬岩和极软岩我们分别取 60 MPa

和 5 MPa 作为围岩分级的  $R_c$  值,详见表 4。

表 4  $R_c, K_v$  随机数组生成对应表

Table 4 Generated random number groups  $R_c$  and  $K_v$

坚硬程度	坚硬岩	较坚硬岩石	较软岩	软岩	极软岩
$R_c$ 随机范围 /MPa	200~60	60~30	30~15	15~5	5~0
中值	60	45	22	10	5
完整程度	完整	较完整	较破碎	破碎	极破碎
$K_v$ 随机范围	1~0.75	0.75~0.55	0.75~0.35	0.35~0.15	0~0.15
中值	0.75	0.65	0.5	0.25	0.15

(3) 利用裂隙特征提取技术和形态参数分析法计算节理的组数和间距,获取结构面发育程度,同样我们采用取平均值的方法获取围岩分级岩体完整系数 ( $K_v$ ) 值,例如节理条数 ( $J_v$ ) 为 3~10 条的围岩  $K_v$  值介于 0.75~0.55 之间,这里取 0.65 作为围岩分级的  $K_v$  值,对于  $J_v < 3$  和  $J_v > 35$  条的围岩,分别取  $K_v$  值为 0.75 和 0.15,详见表 4。使用地质罗盘测到的倾角  $\beta$  和结构面走向和洞轴线夹角  $\alpha$ ,查表可知主要软弱结构面产状影响修正系数  $K_2$ 。

(4) 步骤(1)中已判断出是否有涌水状态出现,因本文选取的围岩分级地段位于湘西猛洞河一带,该地区地下水丰富,鲜有干燥的环境,因此可将地下水状态分为潮湿、涌水两种,除了明显的涌水特征,其他围岩的地下水发育默认为潮湿状态,利用步骤(2)~

(3) 的得到  $R_c$  和  $J_v$  值代入 BQ 分级公式<sup>[16]</sup>获得 BQ 值,查表<sup>[16]</sup>得到地下水状况修正系数  $K_1$ ,确定具体  $K_1$  值的方法类似步骤(2);由于隧道埋深较浅,暂不考虑初始应力的影响。

(5) 取中值方法是为了将定性的围岩分级参数量化来处理,处理后的弊端是在数值上会有误差,但在最终的围岩等级判定上并没有太大改变。笔者随机生成 10000 组[BQ]值,与中值方法相比较后,得出准确率在 87%以上。参照工程岩体分级标准<sup>[16]</sup>制定随机数组的生成方法(见表 4)。

例如:较坚硬的岩石取 55 MPa 作为  $R_c$  值,取 0.45 做为  $K_v$  值,计算出的 BQ 值为 377.5,而取中值法对应的 BQ 值为 360,得出的未修正的围岩分级结果均为 II 类。参照工程岩体分级标准<sup>[16]</sup>获取围岩分级最终结果(见图 15)。

根据该围岩分级的原理及步骤,笔者建立了一套以 matlab GUI 为平台的自动围岩分级系统,载入那丘(N)、六月田(L)和务西作(W)隧道共 250 张正在开挖的的掌子面图片进行测试,将识别结果与传统方法获取参数的 BQ 分级进行对比验证其准确率,表 5 列出了部分实例的分级结果。

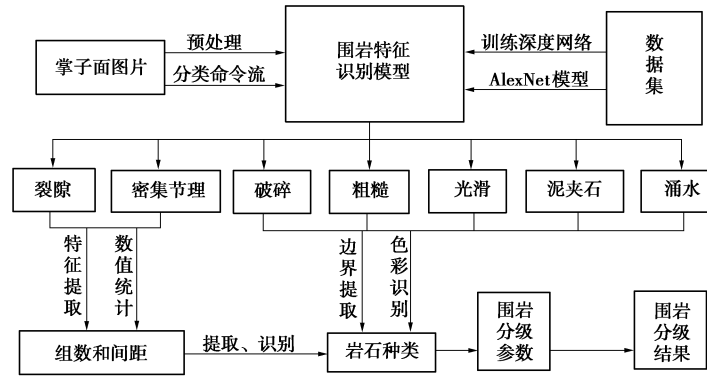


图 15 深度学习围岩分级流程图

Fig. 15 Flow chart of deep learning of surrounding rock mass classification

表 5 深度学习围岩分级与 BQ 分级的结果对比

Table 5 Comparison between results of deep learning of surrounding rock mass classification and those of BQ classification

掌子面桩号及围岩分级方式	单轴抗压强度 $R_c$	岩体完整性指标 $K_v$	地下水影响修正系数 $K_1$	结构面产状修正系数 $K_2$	初始地应力状态修正系数 $K_3$	BQ 值	[BQ]值	修正后的围岩分级结果
深度分级	45	0.65	0.1	0.5	0	387.5	377.5	III
[BQ]Nzk13+835	48	0.70	0.0	0.5	0	409.0	359.0	III
深度分级	45	0.25	0.2	0.8	0	287.5	234.5	V
[BQ]Nzk13+835	23	0.55	0.2	0.3	0	296.5	246.5	V
深度分级	45	0.45	0.2	0.6	0	337.5	297.5	IV
[BQ]Lzk09+971	44	0.70	0.0	0.3	0	407.0	377.0	III
深度分级	45	0.65	0.1	0.5	0	387.5	337.5	III
[BQ]Lzk09+075	46	0.50	0.0	0.4	0	353.0	313.0	III
深度分级	60	0.75	0.2	0.5	0	457.5	417.5	III
[BQ]Wzk07+808	58	0.58	0.0	0.3	0	409.0	379.0	III
深度分级	5	0.15	0.6	1.0	0	142.5	32.5	V
[BQ]Wzk07+900	15	0.14	0.3	0.5	0	170.0	90.0	V

### 5 结 论

本文利用深度学习 AlexNet 模型进行隧道围岩特征识别, 结合 matlab 图像识别技术及岩体裂隙图像智能解译方法, 建立了一种隧道围岩自动分级的系统。对比那丘 (N)、六月田 (L) 和务西作 (W) 隧道 BQ 围岩分级资料结果, 准确率分别达到 87%, 82% 和 84%。Lzk09+971 掌子面的计算结果趋于保守, 原因是拍摄时隧道环境恶劣导致照片的不清晰出现了误判。但总体来看, 该方法能较好地满足湘西这一片区的围岩分级要求。经过进一步分析得出以下结论:

(1) 深度学习围岩分级无需多余的专业仪器获取围岩分级参数, 依靠掌子面图片自动生成分级结果, 在获得掌子面图片上传到电脑端后能够快速自动进行围岩分级。

(2) 深度学习技术对样本图片的质量要求很高, 隧道开挖的昏暗环境导致了一般图片满足不了使用要求, 保证样本拍摄于空气中尘埃较少且有大探照灯照射的环境, 能够极大地提高识别的成功率。

(3) 深度学习技术仅能够对形态类似的围岩进行分类, 围岩形态的无规律特征增加了样本的分类难度,

文中采用的规避方法是优先识别其他特征, 在无有效对应特征的情况下, 才会识别为粗糙无规则的特征, 由于优先级的滞后往往会产生识别率低的结果, 因此对该类样本进行细分将是未来的工作重心。

(4) 对岩石的坚硬程度、岩体完整性指标、地下水发育及结构面发育程度转换为 BQ 值进行描述, 最后结构面产状修正系数用结构面组数和间距来代替, 该方法适用于初始地应力影响较小的围岩区, 对开挖过程中的快速分级, 既规避了人为主观因素对分级的影响又具有较高的分级准确性。

(5) 论文数据集的来源仅是湘西片区, 验证是在永顺一带, 该地区主要以灰岩和黄黏土为主。因岩石种类的不匹配会导致该系统对其它地区的围岩分级出现误差, 获取更多的图片及工程地质数据有利于增加本系统的适用范围。

(6) 传统 BQ 法所取参数都是通过现场及室内试验得出的准确数据, 而本文采用取平均值的方式进行计算, 深度学习法所得的各参数值与常规的 BQ 法所得的各参数值存在差异性, 但这种差异性并对围岩分级最终结果的准确性影响不大。



## 参考文献:

- [1] 方 昱, 刘保国, 刘开云. 隧道围岩分级的遗传-支持向量分类耦合模型[J]. 铁道学报, 2013, **35**(1): 108 - 114. (FANG Yu, LIU Bao-guo, LIU Kai-yun. Tunnel surrounding rock grading model based on genetic-support vector classification coupling algorithm[J]. Journal of the China Railway Society, 2013, **35**(1): 108 - 114. (in Chinese))
- [2] 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 Lin-di, SONG Cheng-hui. Application of BP neural network in the rapid classification of surrounding rock[J]. China Safety Science Journal, 2010, **20**(2): 41 - 45. (in Chinese))
- [3] 闫 明. 基于系统聚类分析的公路隧道围岩分级方法研究[D]. 吉林: 吉林大学, 2013. (YAN Ming. Study on classification method of road tunnel surrounding rock according to the hierarchical cluster analysis[D]. Jilin: Jilin University, 2013. (in Chinese))
- [4] 白明洲, 许兆义, 王连俊, 等. 隧道围岩分级的模糊信息分析模型及应用研究[J]. 铁道学报, 2001, **23**(6): 85 - 88. (BAI Ming-zhou, XU Zhao-yi, WANG Lian-jun, et al. Study and application on fuzzy information analysis model in tunnel surrounding rock mass classification[J]. Journal of the China Railway Society, 2001, **23**(6): 85 - 88. (in Chinese))
- [5] 陈安凡. 公路隧道围岩分级专家系统研究[D]. 重庆: 重庆大学, 2013. (CHEN An-fan. Research on road tunnel surrounding rock classification expert system[D]. Chongqing: Chongqing University, 2013. (in Chinese))
- [6] 牛文林, 张广洋, 熊国斌, 等. 基于 ASP.NET 技术的围岩分级系统开发[J]. 现代隧道技术, 2011, **48**(1): 12 - 16. (NIU Wen-lin, ZHANG Guang-yang, XIONG Guo-bin, et al. Rock mass classification system based on ASP. NET[J]. Modern Tunnelling Technology, 2011, **48**(1): 12 - 16. (in Chinese))
- [7] 何发亮, 谷明成, 王石春. TBM 施工隧道围岩分级方法研究[J]. 岩石力学与工程学报, 2002, **21**(9): 1350 - 1354. (HE Fa-liang, GU Ming-cheng, WANG Shi-chun. Study on surrounding rock mass classification of tunnel cut by TBM[J]. Chinese Journal of Rock Mechanics and Engineering, 2002, **21**(9): 1350 - 1354. (in Chinese))
- [8] 王乐华, 李建荣, 李建林, 等. RMR 法评价体系的修正及工程应用[J]. 岩石力学与工程学报, 2013, **32**(增刊 2): 3309 - 3316. (WANG Le-hua, LI Jian-rong, LI Jian-lin, et al. Correction of RMR system and its engineering application[J]. Chinese Journal of Rock Mechanics and Engineering, 2013, **32**(S2): 3309 - 3316. (in Chinese))
- [9] 张前进. 基于 TSP 多波关系的围岩稳定性等级判定方法研究[D]. 北京: 中国地质大学, 2013. (ZHANG Qian-jin. Research on the method of grade determination for surrounding rock stability based on TSP multiwave relation[D]. Beijing: China University of Geosciences, 2013. (in Chinese))
- [10] HINTON G, DENG L, YU D, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups[J]. IEEE Signal Process Mag, 2012, **29**(6): 82.
- [11] HINTON G E. Learning multiple layers of representation[J]. Trends in Cognitive Sciences, 2007, **11**(10): 428 - 434.
- [12] HINTON G E. Deep belief networks[J]. Scholarpedia, 2009, **4**(5): 5947.
- [13] JIA Yang-qing, SHEL Hamer E, DONAHUE J, et al. Caffe: Convolutional architecture for fast feature embedding[C]// Proceedings of the ACM International Conference on Multimedia. ACM, 2014: 675 - 678.
- [14] Alex Krizhevsky. ImageNet Classification with Deep Convolutional Neural Networks[C]// Advances in Neural Information Processing Systems, 2012: 1097 - 1105.
- [15] 刘 春, 王宝军, 施 斌, 等. 基于数字图像识别的岩土体裂隙形态参数分析方法[J]. 岩土工程学报, 2008, **9**(9): 1383 - 1388. (LIU Chun, WANG Bao-jun, SHI Bin, et al. Analytic method of morphological parameters of cracks for rock and soil based on image processing and recognition[J]. Chinese Journal of Geotechnical Engineering, 2008, **9**(9): 1383 - 1388. (in Chinese))
- [16] GB T50218—2014《工程岩体分级标准》[S]. 2014. (GB T50218—2014 Standard for engineering classification of rock mass[S]. 2014. (in Chinese))