

DOI: 10.11779/CJGE201908015

四类常见边坡岩石类别识别和边界范围确定的方法

王鹏宇, 王述红*

(东北大学资源与土木工程学院, 辽宁 沈阳 110819)

摘要: 岩质边坡岩石的分类与边界范围的确定对于边坡稳定性的分析至关重要, 目前人工方法效率低且受主观因素影响, 所以基于 Tensorflow 建立了岩质边坡图像集分析的卷积神经网络模型, 通过卷积操作和池化操作分别对 80000 张岩质边坡图像进行特征信息的提取和压缩, 然后对网络模型进行训练从而实现了岩质边坡岩石的自动识别与分类; 采用训练集和测试集中的岩质边坡图像对模型进行检验分析, 训练集准确率达到 98%, 测试集准确率达到 90%, 显示了训练之后的网络模型具有良好的鲁棒性, 达到了理想的训练效果。接下来以边坡不同岩石的颜色为主要区分依据, 利用深度学习回归操作对岩质边坡不同种类岩石的范围进行确定, 为验证算法效果, 选取标准彩色岩质边坡图像进行仿真试验, 边界检测效果准确。最终采用深度学习建立的网络模型, 实现了岩质边坡岩石识别与边界范围划分的快速化、自动化, 为后续将图像识别获取的岩质边坡信息导入团队自主研发的 GeoSMA-3D 软件中, 作为对岩质边坡等级判定的重要参数。

关键词: 岩质边坡; 卷积神经网络; 深度学习; 图像识别; 边界范围

中图分类号: TU45 **文献标识码:** A **文章编号:** 1000-4548(2019)08-1505-08

作者简介: 王鹏宇(1994—), 男, 博士研究生, 主要从事岩石力学方面的研究工作。E-mail: wangpengyu6666@126.com。

Method for identifying four common rock types of slopes and determining boundary range

WANG Peng-yu, WANG Shu-hong

(School of Resources & Civil Engineering, Northeastern University, Shenyang 110819, China)

Abstract: Rock classification and boundary determination of rock slopes are very important for the analysis of slope stability. At present, the artificial methods are inefficient and affected by subjective factors. So a convolution neural network model for the image set analysis of a rock slope is established based on Tensorflow. Through convolution operation and pooling operation, the feature information of 8000 original rock slope images is extracted and compressed respectively. Then the network model is trained to realize the automatic recognition and classification of the rock slope. The model is tested and analyzed by using the images of rock slopes in training set and testing set. The accuracy rate of the training set and the testing set is 98% and 90%, respectively. It is shown that the network model after training has good robustness and achieves ideal training effect. Next, the color of different rocks on the slope is taken as the main basis. The boundary of different types of rock on the rock slope is calibrated by the deep learning boundary extraction technology. To verify the effectiveness of the algorithm, the standard color image of the rock slope is selected for simulation experiment, and the results of boundary detection are accurate. The network model established by deep learning realizes the requirements of rapid and automatic rock identification and boundary range division of rock slopes, and introduces the rock slope information acquired by image recognition into the GeoSMA-3D software independently developed by the team, as an important parameter for determining the grade of rock slopes.

Key words: rock slope; convolutional neural network; deep learning; image recognition; boundary range

0 引言

边坡不同岩石的类别和范围的划定是边坡科学研究中的基础性工作。过去往往通过复杂的仪器设备进行现场取样, 人为地根据岩石的颜色、结构构造等辨识边坡岩石的种类以及不同岩石边界范围的标定, 这样的过程费时费力。但是随着大数据时代的来临, 通过人

工智能对边坡岩石图像快速识别类别成为可能^[1-3]。自

基金项目: 国家自然科学基金项目 (U1602232, 51474050); 中央高校基本科研业务专项资金项目 (N170108029); 辽宁省自然科学基金项目 (20170540304; 20170520341); 东北大学双一流建设项目 (2018)

收稿日期: 2019-01-22

*通讯作者 (E-mail: shwang@mail.neu.edu.cn)

20世纪80年代以来,神经网络在理论和应用等方面都获得了巨大成功,2016年围棋选手李世石4:1惨败于AlphaGo,将“深度学习”推向高潮,人工智能时代已经来临。所谓深度学习(deep learning)就是通过多隐层的感知器将低层次的特征有效组合起来,对特征逐步进行提取从而形成能够表示某类属性的抽象高层次特征,即通过多层抽象来学习数据表征^[4-6]。

本文试图基于Tensorflow框架将卷积神经网络(convolutional neural networks, CNNs)引入到岩质边坡岩石图像处理中。通过深度学习不仅需要对比坡岩石的类别进行识别还需要对不同岩石的范围进行标定,为分析岩质边坡的稳定性提供重要的参考依据。

1 边坡岩石识别特征及研究方法

常规的边坡岩石识别与分类主要有两种方法。第一种是物理试验法,即运用物理测试手段对边坡岩石进行检测。例如,采用X射线粉末衍射、扫描电镜、红外光谱、差热分析、电子探针、高光谱图像等方法进行分析^[7-8]。第二种是数学统计分析法,即通过传统的数学统计与计算分析对岩质边坡的分类特征进行识别与提取。例如,运用 S_r 和 Y_0 作为分类特征或者综合运用多重分形局部奇异性与空间加权分析的方法识别和提取岩石异常信息^[9-11]。

上述两类方法存在试验复杂、周期偏长、受主观影响较大等缺陷,同时无法满足现场测量评价的需要,为了可快速准确地提取岩质边坡岩石信息,很多专家通过智能算法对岩石图像进行了研究:张旭等^[12]应用朴素贝叶斯 K 邻近算法进行了岩石图像分类;康丽萍等^[13]分别利用softmax多分类器和多分类支持向量机(SVM)实现图像分类;张嘉凡等^[14]提出了基于聚类分析算法的岩石CT图像分割及量化方法;Li等^[15]采用迁移学习方法对砂岩图像进行了训练,最终获得了精度较高的砂岩图像分类模型。分析上述研究进展发现存在一些不足之处:首先图像采用经过后续加工后的标准岩石薄片,而不是以原始状态的岩质边坡图像作为训练数据集;其次,未对边坡不同岩石的边界进行标定,无法确定边坡各类岩石的边界范围。对此,本文提出一种基于CNN的边坡岩石分类及范围标定的方法,其中数据集采用现场未经处理的边坡岩石图像。

2 岩质边坡图像识别的原理与方法

2.1 四类常见边坡岩石图像样本库的建立

从互联网到物联网,再到最后的万物智能,大数据发挥了至关重要的作用,从图1数据规模与深度学习效果的关系可以看出充足的数据样本可以大大提高

深度学习的效果^[16]。




图1 数据规模与深度学习效果的关系

Fig. 1 Relationship between data size and deep learning effects

对高陡边坡岩石图像的采集存在一定的风险性,复杂多变的地质条件加大了工程人员的测量难度,如何不受地质条件的限制实现边坡全景图像的获取,并保证测量人员的安全,成为边坡图像获取中的棘手问题。对此团队采用无人机设备进行了岩质边坡全景图像的采集(见图2),取得了很好的效果。生成8000张高分辨率原始图像数据集,对数据集进行增强处理,先将8000张原始数据集图片采用Horizontal flips操作,对图像进行水平翻转,再采用Random crops操作,对图像进行裁剪,将图片调整为 224×224 的大小,图像数据集扩大到80000张。

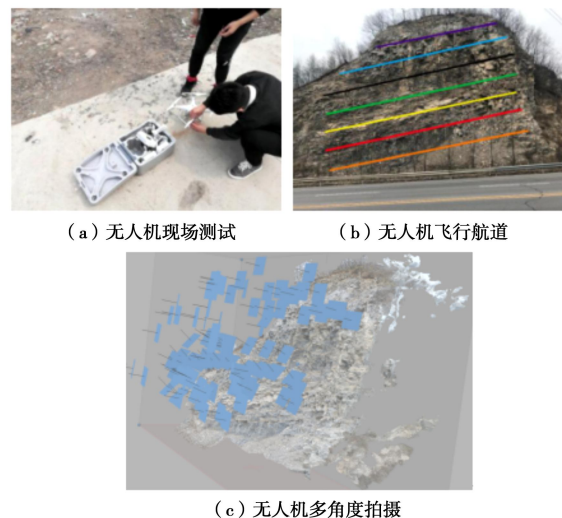


图2 无人机现场采集数据

Fig. 2 Data acquisition by UAV on site

采集了常见的4类边坡岩石图像,训练集与测试集数量见表1,训练集是从各类岩质边坡总样本中随机抽取,剩下的作为测试集。

表1 样本数据

Table 1 Sample data

边坡岩石种类	图像数量	训练集	测试集
玄武岩	20000	16000	4000
花岗岩	20000	16000	4000
砂岩	20000	16000	4000
片岩	20000	16000	4000

2.2 图像预测方法

岩质边坡图像在计算机中表示成三维数组形式

(w, h, d), 其中 w 为图像宽度, h 为图像高度, d 为图像色彩通道, 当图像是灰度图时 d 取 1, 彩色图时 d 取 3。每张图像由若干像素点组成, 每个像素点取值范围从 0 到 255, 本文将边坡岩石图像统一切割成 $224 \times 224 \times 3$ 的大小。通过得分函数计算每张图像属于各类别的得分值, 当某一类别得分值最高, 预测结果则属于该类别, 得分函数为

$$f(x, W) = Wx + b \quad (1)$$

式中, x 为图像中各像素点大小, W 为计算机随机生成的权重参数, b 为图像进行的几分类操作。假定一张边坡岩石图像有 4 个像素点, 分别为 56, 231, 24, 2, 进行 3 分类操作, 得分函数计算出该图像属于 A 类别的得分值为 -96.8, 属于 B 类别的得分值为 437.9, 属于 C 类别的得分值为 61.95, 可以通过得分值判断该图像属于 B 类别 (见图 3)。




图 3 得分函数的计算结果

Fig. 3 Calculated results of score function

2.3 预测结果的修正

在图像识别过程中仅仅依靠得分函数进行分类判断是不够准确的。比如有三类边坡岩石类别 A, B, C, 计算得分值如表 2 所示。

表 2 得分函数预测结果

Table 2 Predicted results of score function

网络分类	真实分类		
	A	B	C
A	3.2	1.3	2.2
B	5.1	4.9	2.5
C	-1.7	2.0	-3.1

对比发现图像最大得分值所对应的岩质边坡类别与实际类别不一致, 出现分类错误, 需要引入修正方法, 本文在网络中加入 SVM 损失函数:

$$L_i = \sum_{j \neq y_i} \max(0, s_j - s_{y_i} + 1) \quad (2)$$

式中, s_j 为预测结果属于错误类别的得分, s_{y_i} 为预测结果属于正确类别时的得分。利用 SVM 损失函数计算出 A 类边坡岩石图像的损失值为 $\max(0, 5.1-3.2+1) + \max(0, -1.7-3.2+1)=2.9$; B 类边坡岩石图像的损失值为 $\max(0, 1.3-4.9+1) + \max(0, 2-4.9+1)=0$; C 类边坡岩石图像的损失值为 $\max(0, 2.2-(-3.1)+1) + \max(0, 2.5-(-3.1)+1)=10.9$ 。

由损失函数计算结果发现图像预测结果与实际越

接近损失值越小, 图像预测结果与实际越偏离损失值越大。当有多组图像时, SVM 损失函数表达式为

$$L = \frac{1}{N} \sum_{i=1}^N \sum_{j \neq y_i} \max(0, f(x_i; W)_j - f(x_i; W)_{y_i} + 1), \quad (3)$$

式中, N 为图像的数量。在边坡岩石图像识别的神经网络模型计算得分函数时发现有时会出现 $W_1^T x = W_2^T x$ 的现象, 比如当像素点 $x = [1, 1, 1, 1]$ 时, 计算机自动生成的权重参数 $W_1 = [1, 0, 0, 0]$ $W_2 = [0.25, 0.25, 0.25, 0.25]$ 时, $W_1^T x = W_2^T x = 1$ 。虽然得分值相同, 但是权重参数 $W_1 = [1, 0, 0, 0]$ 时只关注图像数据中的第一个像素点, 其他像素点等于任何值对得分结果没有任何影响。权重参数 $W_2 = [0.25, 0.25, 0.25, 0.25]$ 的分布则比较均匀, 会对图像数据中所有像素点进行计算。 W_1 只能关注图像数据中的一部分, W_2 关注于图像数据的整体, 为了在边坡岩石图像识别卷积神经网络中得到 W_2 类型的权重参数, 在网络模型中引入正则化惩罚项, 即

$$R(W) = \sum_k \sum_l W_{k,l}^2 \quad (4)$$

权重参数 W_1 的正则化惩罚结果为 1, W_2 的正则化惩罚结果为 0.25, SVM 损失函数的最终形式为

$$L = \frac{1}{N} \sum_{i=1}^N \sum_{j \neq y_i} \max(0, f(x_i; W)_j - f(x_i; W)_{y_i} + 1) + \lambda R(W) \quad (5)$$

当得分值越大, 对应的损失函数结果越小, 得分值越小, 对应的损失函数结果越大, 所以损失函数值越小, 预测结果越准确。

2.4 得分值的转化

通过上述 SVM 损失函数计算输出的是得分值, 而不同类别的得分值之间相互比较很麻烦, 因为本文进行的是边坡岩石图像分类操作, 引入 softmax 分类器可以成功地得分值转换成为概率值, 概率值在分类处理时更加方便、直观。一张边坡岩石图像预测属于玄武岩边坡的概率为 60%, 属于砂岩边坡的概率为 30%, 属于花岗岩边坡的概率为 20%, 此时便可以直观地将该岩石图像归类为玄武岩边坡。

softmax 函数如式 (6) 所示, 其中输入值是一组向量, 向量中各元素为所有类别的评分值, 结果输出一组向量, 向量中每个元素值范围为 0~1, 且所有元素之和为 1。

$$f_j(z) = \frac{e^{z_j}}{\sum_k e^{z_k}} \quad (6)$$

式中, Z_j 为边坡岩石图像属于正确类别时的得分, Z_k 为图像属于错误类别时的得分。得分值转化为概率值时采用如下式所示的损失函数:

$$L_i = -\log\left(\frac{e^{f_{yi}}}{\sum_j e^{f_{yj}}}\right), \quad (7)$$

式中, f_{yi} 为边坡岩石图像属于正确类别时的概率值, f_{yj} 为图像属于错误类别时的概率值。

输出概率时采用对数函数计算损失值, 因为当对正确类别的概率值计算损失值时, 概率值越趋近于 1 符合正确类别的概率越大, 所以要求其损失计算结果越趋近于 0, 概率值越趋近 0 符合正确类别的概率越小, 所以要求其损失计算结果越大, 这样的变化趋势符合对数函数。对数函数中当 x 取值越接近于 1 时, 对应的结果 y 值越小, 也就是损失值越小; 当 x 取值越接近于 0 时, 对应的结果 y 越大, 得到的损失值越大。

3 岩质边坡图像深度学习模型构建

卷积神经网络为代表的深度学习模型是目前图像识别中应用最广泛的方法, 完整的卷积神经网络包含输入层、卷积层、池化层、全连接层、输出层。相比其他神经网络多了卷积层和池化层。卷积层可以更有效的提取图像的特征, 池化层压缩图像特征, 减少计算量^[17-18]。本文卷积神经网络总体模型结构的设计和模型的运算过程如图 4 所示, 整体模型共包含 16 层: 其中 13 个卷积层, 3 个全连接层。


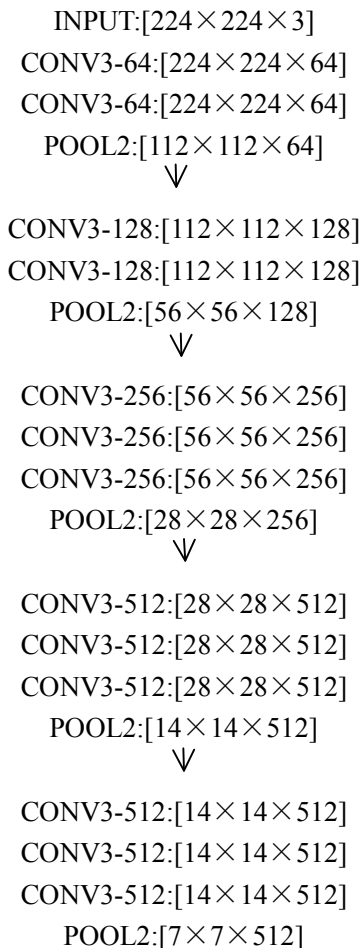



图 4 模型结构

Fig.4 Model structure

所谓隐藏层就是对输入的边坡岩石图像进行一系列的特征提取、压缩等操作。本文采用不同的隐藏层对拟合效果进行分析, 当只有一个隐藏层时计算函数为 $f = Wx$, 得分函数为线性方程, 分类效果如图 5(a) 所示, 当隐藏层增加到 3 层时计算函数为 $f = W_3 \max(0, W_2 \max(0, W_1 x))$, 分类效果如图 5(b) 所示, 当隐藏层为 6 时分类效果如图 5(c) 所示。可以发现越多的隐藏层, 越能够表达复杂的模型, 拟合效果越好。本文经过多次试算最终确定隐藏层包含 13 个卷积层和 5 个池化层时网络学习效果最好。



(a) 隐藏层为 1 (b) 隐藏层为 3 (c) 隐藏层为 6

图 5 神经网络具有不同隐藏层的拟合效果

Fig. 5 Fitting effects of neural network with different hidden layers

3.1 岩质边坡图像特征的提取

卷积操作提取边坡岩石图像特征的过程如图 6 所示, 借助卷积核与图像上相应大小的区域进行卷积运算, 其中每一个卷积核对应着一个权值矩阵, 然后对权重矩阵所覆盖的图像像素进行加权, 结果作为该卷积核在图像该区域的响应, 该区域计算结束之后卷积核以一定步长滑动, 类似于图像处理中使用的“窗口”从而使卷积核作用于整张图像, 最终得到一张特征图, 可以使用多个卷积核同时对一张图像进行卷积操作。卷积计算表达式为

$$f(x, y) \times w(x, y) = \sum_{s=-1}^a \sum_{t=-b}^b w(s, t) f(x-s, y-t), \quad (8)$$

式中, $f(x, y)$ 为边坡岩石图像上点 (x, y) 的灰度值, $w(x, y)$ 为卷积核。

在卷积之前图像输入的大小为 $W_1 \times H_1 \times D_1$, 卷积过程中需要指定的超参数为卷积核 filter 的个数 K 、filter 的大小 F 、stride 步长 S 、pad 边界填充 P , 经过一次卷积操作后图像输出的大小为

$$\left. \begin{aligned} W_2 &= (W_1 - F + 2P) / S + 1, \\ H_2 &= (H_1 - F + 2P) / S + 1, \\ D_2 &= K. \end{aligned} \right\} \quad (9)$$

边坡岩石图像的固定分辨率为 $224 \times 224 \times 3$, 本文设计的深度学习模型卷积层使用 3×3 大小的卷积核, stride 取 1, pad 取 1; 卷积运算过程如图 4 所示。使用 ReLU 函数作为激活函数: $f(x) = \max(0, x)$, 当 $x \leq 0$, $\nabla f(x) = 0$; 当 $x > 0$, $\nabla f(x) = 1$ 。通过卷积操作对岩质边坡图像进行特征的提取, 卷积可视化如图 7 所示。





图 6 卷积核对图像特征的提取

Fig. 6 Extraction of image features by convolution kernel



(a) 低层次特征 (b) 中层次特征 (c) 高层次特征

图 7 岩质边坡图像卷积可视化

Fig. 7 Convolution visualization of rock slope image

3.2 岩质边坡图像特征的压缩

为减少计算机对图像数据的运算工作量, 池化层将卷积之后的特征图进行压缩, 去除特征图中重复冗余的信息, 保留重点特征信息。池化运算分为平均池化和最大池化, 本文选用最大池化计算方法, 池化核大小设定为 2×2 , stride 取 2。计算方式如图 8 所示。




图 8 最大池化的计算

Fig. 8 Calculation of maximum pooling

3.3 全连接层与输出层

经过反复卷积和池化操作之后, 提取出边坡岩石图像的深层次特征并缩减特征图的维度和大小; 之后将最后一层岩质边坡图像特征转化为一维向量的形式并连接成一个全连接网络, 全连接层使用 softmax 分

类器, 如图 9 所示, 最终输出属于 4 种边坡岩石类型的概率值。




图 9 岩质边坡图像深度学习全过程

Fig. 9 Whole process of deep learning of rock slope image

3.4 岩质边坡图像识别训练方法

对采集的边坡岩石图像数据进行训练, 总迭代次数 3000 次, 初始学习率设置为 0.0001, 训练过程中为了减少计算量以及防止过拟合现象的出现, 所以采用如图 10 所示的 Drop-Out 操作, Drop-Out 的概率取值 60%。训练时每次随机选择 2000 张图像进行训练, 每张图像都会多次使用, 并选择 200 张图像进行交叉验证, 每迭代 100 次对训练进行评价。




图 10 Drop-Out 计算方法

Fig. 10 Drop-Out calculation method

整个训练过程如图 11 所示, 可以分为前向传播和反向传播。前向传播首先从训练数据集中随机选取样本 (X, Y_p) , 其中 X 表示待输入的边坡岩石图像, Y_p 表示该图像的实际类别, 经过反复交替执行卷积与池化操作后输出该图像类别 O_p 。反向传播: 边坡岩石图像经前向传播输出的预测类别 O_p 与相应的实际类别 Y_p 的差, 然后使用极小化误差的方法反向传播优化各权值参数 W 。




图 11 反向传播过程中 ReLU 函数的计算

Fig. 11 Calculation of ReLU function in back propagation

3.5 网络训练结果

本文深度学习模型在训练过程中训练准确率、测试准确率及损失值随迭代次数的变化如图 12 所示。其中训练准确率表示训练集中的边坡岩石图像分类正确

的概率，测试准确率表示未经训练的测试集中边坡岩石图像分类正确的概率，损失值表示边坡岩石图像网络识别模型学习的效果，损失值越小学习训练效果越好，通过反向传播修正权重参数 W ，从而降低损失值。




图 12 训练过程中 3 项指标的变化

Fig.12 Variation of three indices during training

从图 12 可以看出，当迭代到 1500 步时网络基本收敛，损失值在之前迭代过程中迅速下降并在 0.1 左右趋于平稳；训练准确率和测试准确率分别达到 95% 和 85%；根据 3 个指标的变化趋势可以看出岩质边坡岩石图像网络识别模型训练效果理想。

使用训练的岩石图像网络模型对测试集中 16000 张图像分类，结果如表 3 所示，其中正确分类 14790 张图像 (92.4%)，错误分类 1210 张图像 (7.6%)，对比结果可以看出：网络模型对玄武岩边坡和砂岩边坡的识别率较高，这两类岩质边坡特征明显容易准确识别，但是容易将花岗岩边坡和片岩边坡分类混淆。

表 3 测试结果

Table 3 Test results

网络分类	真实分类			
	玄武岩边坡	花岗岩边坡	砂岩边坡	片岩边坡
玄武岩边坡	3910	60	20	90
花岗岩边坡	50	3520	30	420
砂岩边坡	10	40	3890	20
片岩边坡	30	380	60	3470

4 边坡不同类别岩石范围的确定

上述提出了岩质边坡岩石类型识别分类的网络模型，但岩质边坡的岩石类型不是单一的，种类往往繁多，仅依靠图像识别分类操作无法对边坡不同种类岩石范围进行确定，纹理和颜色是不同类别岩石之间最大的区别。因为岩石纹理属于微观层面光靠宏观图像

无法准确获取，所以以颜色为主要区别特征利用深度学习回归操作确定边坡不同岩石范围。

4.1 边坡岩石图像特征加强处理

以岩石的颜色为主要特征确定边坡不同岩石的范围，为了得到更好的划分效果对岩石图像的颜色特征进行加强处理。图像的颜色特征通常采用 RGB 和 HIS 的基本向量进行描述，HIS 中 H 表示图像色调，S 表示图像色深，I 表示图像光强。HIS 的颜色参量相关性具有比 RGB 的颜色参量相关性低的优势，其中光强 I 对外界环境具有很强的惰性^[19]，所以重点对图像的色调 H 和色深 S 进行分析^[20-21]。通过下式将边坡岩石图像的 RGB 值转换得到色调 H 和色深 S 的值，实现对岩石图像颜色特征的加强。

$$H = \begin{cases} \theta & (G \geq B) \\ \theta + \pi & (G < B) \end{cases}, \quad (10)$$

$$\theta = \frac{\pi}{2} - \arctan\left(\frac{2R - G - B}{\sqrt{3}(G - B)}\right), \quad (11)$$

$$S = \frac{2}{\sqrt{6}} \times \sqrt{(R - G)^2 + (R - B)(G - B)}. \quad (12)$$

4.2 边坡不同岩石回归操作

对岩质边坡岩石类别的识别在深度学习中属于 classification 操作，而确定不同岩石的范围属于 location 操作，location 操作的过程仍然是输入一个边坡岩石图像，经过多次卷积和池化操作，最终得到一个特征图，将特征输入到全连接层。但是区别在于岩石识别中全连接层采用的是 class scores，在确定不同岩石范围中全连接层采用的是 box coordinates。采用 box coordinates 对输入全连接层的特征图计算预测位置和真实位置之间的差异，两者之间的差异通过损失值来衡量，通过不断地拟合操作使得预测位置和真实位置之间的差异越来越小。

上文已经构建了岩质边坡岩石类别分类的深度学习模型，所以直接采用上述模型结构。同时将全连接层中的 class scores 改为 box coordinates，将损失函数采用的 softmax 函数改为欧式距离 L2distance 函数，网络中其他参数均保持不变^[22]。虽然分类和回归操作的全连接层都连接相同的特征图，但是对特征图采用不同的损失函数所进行的操作是不同的，将原来 softmax 损失函数改为解决回归问题的欧式距离 L2distance 函数，最后结果会输出岩质边坡图像中不同类型岩石的范围坐标 (x, y, w, h) 。

为验证模型训练效果，选择无人机测量生成的现场岩质边坡图像。通过网络模型中分类和回归的操作对岩质边坡的岩石种类进行识别并确定不同类别岩石的范围，结果如图 13 所示。

可以看出训练好的网络模型能够确定边坡岩石所

属类别及该类岩石的范围。图像中没有进行标定的部分说明不属于本文研究四类岩石, 因为网络模型没有学习过, 所以无法进行识别。下一步将采集更多类别的边坡岩石数据样本, 增加网络模型岩石识别的种类, 使网络不仅仅局限于本文的四类边坡岩石。

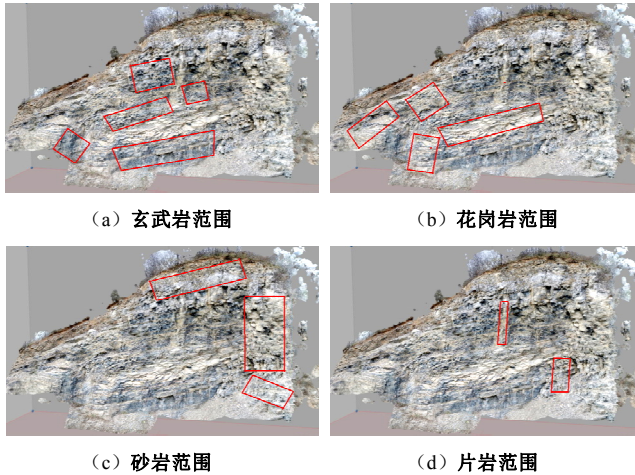


图 13 岩质边坡图像分类和回归结果

Fig. 13 Classification and regression results of rock slope images

5 结 论

采用无人机对云南岩质边坡进行图像采集, 提出基于卷积神经网络的深度学习方法对图像进行特征学习, 实现边坡岩石类别的自动分类和边界范围的确定, 得到以下 3 点结论。

(1) 深度学习技术对图像的数量和质量要求很高, 利用无人机对高陡边坡的全景图像进行采集, 提高了图像获取的效率和数量, 并且能够保证工作人员的安全, 同时不受地质条件限制。本文利用无人机设备对云南边坡进行全景高清图像采集, 极大地满足了卷积神经网络的训练要求。

(2) 将卷积神经网络分类操作应用到边坡岩石图像分类中, 输入原始岩质边坡图像数据, 由卷积网络自动提取图像特征, 训练之后网络达到 90% 的准确率, 说明网络模型可以有效地提取边坡岩石图像的特征, 实现岩质边坡岩石的自动识别分类。

(3) 以岩石的颜色作为主要区分特征, 利用深度学习回归操作对边坡不同类别岩石的范围进行划分。输入任意边坡图像进行检测, 验证了网络模型边界范围确定方法的准确性, 实现了岩质边坡不同岩石划分快速化、自动化的要求。

6 展 望

(1) 深度学习无需多余的专业仪器, 依靠图像实现对边坡岩石的识别和范围的确定, 后续将图像识别

获取的岩质边坡信息导入团队自主研发的 GeoSMA-3D 边坡稳定分析软件中, 将通过岩石种类描述边坡岩石的坚硬程度以及不同岩石范围描述边坡的完整性, 作为对岩质边坡等级判定的重要参数, 提出一种准确快速的边坡分级方法^[23-25]。

(2) 数据库样本的大小决定了深度学习训练的准确率及训练过程中是否容易出现过拟合, 本文尝试建立岩质边坡图像特征样本库, 但目前图像数量远远不够, 且样本的主要来源为云南岩质边坡, 所以下一步将开展岩质边坡样本收集整理研究工作。增加网络模型岩石识别的种类, 使网络不仅仅局限于本文的四类边坡岩石。

参考文献:

- [1] SINGH C, KAUR K P. A fast and efficient image retrieval system based on color and texture features[J]. *Journal of Visual Communication & Image Representation*, 2016, **41**(10): 41 - 52.
- [2] SMITH S M, BRADY J M. SUSAN: a new approach to low level image processing[J]. *International Journal of Computer Vision*, 2015, **23**(1): 45 - 78.
- [3] 王 洋, 王述红, 郭牡丹, 等. 隧道掌子面节理信息快速数字识别及稳定性分析[J]. *岩土工程学报*, 2011, **33**(11): 1734 - 1739. (WANG Yang, WANG Shu-hong, GUO Mu-dan, et al. Fast digital identification of joint information of tunnel work face and its stability analysis[J]. *Chinese Journal of Geotechnical Engineering*, 2011, **33**(11): 1734 - 1739. (in Chinese))
- [4] BOONSIVANON K, MEESOMBOON A. IKDSIFT: an improved keypoint detection algorithm based-on sift approach for non-uniform illumination[J]. *Procedia Computer Science*, 2016, **86**(2): 269 - 272.
- [5] ZISSERMAN A, VEDALDI A. Sparse kernel approximations for efficient classification and detection[C]// *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society, Hawaii, 2012: 2320 - 2327.
- [6] KOBAYASHI T. BFO Meets HOG: feature extraction based on histograms of oriented pdf gradients for image classification[C]// *IEEE Conference on Computer Vision and Pattern Recognition*. Portland OR, 2013, **91**(9): 747 - 754.
- [7] ZAINI N, van der MEER F, van der WERFF H. Determination of carbonate rock chemistry using laboratory-based hyperspectral imagery[J]. *Remote Sensing*, 2014, **6**(5): 4149 - 4172.
- [8] 郭清宏, 周永章, 曹姝旻. 广绿玉玉石的矿物学研究[J]. *中山大学学报(自然科学版)*, 2010, **49**(3): 146 - 151. (GUO

- Qing-hong, ZHOU Yong-zhang, CAO Shu-min. Study on mineralogy of Guangning jade[J]. *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 2010, **49**(3): 146 - 151. (in Chinese))
- [9] 肖凡, 陈建国, 侯卫生. 2017. 钦—杭结合带南段庞西垌地区 Ag-Au 致矿地球化学异常信息识别与提取[J]. *岩石学报*, 2017, **33**(3): 779 - 790. (XIAO Fan, CHEN Jian-guo, HOU Wei-sheng. Identification and extraction of Ag-Au mineralization associated geochemical anomaly in Pangxitong district, southern part of the Qinzhou-Hangzhou Metallogenic Belt, China[J]. *Acta Petrologica Sinica*, 2017, **33**(3): 779 - 790. (in Chinese))
- [10] 张旗, 金惟俊, 李承东. 再论花岗岩按照 Sr-Yb 的分类: 标志[J]. *岩石学报*, 2010, **26**(4): 985 - 1015. (ZHANG Qi, JIN Wei-jun, LI Cheng-dong. Revisiting the new classification of granitic rocks based on whole-rock Sr and Yb contents: index[J]. *Acta Petrologica Sinica*, 2010, **26**(4): 985 - 1015. (in Chinese))
- [11] 张旗, 金惟俊, 李承东. 三论花岗岩按照 Sr-Yb 的分类: 应用[J]. *岩石学报*, 2010, **26**(12): 3431 - 3455. (ZHANG Qi, JIN Wei-jun, LI Cheng-dong. On the classification of granitic rocks based on whole-rock Sr and Yb concentrations III: practice[J]. *Acta Petrologica Sinica*, 2010, **26**(12): 3431 - 3455. (in Chinese))
- [12] 张旭, 蒋建国, 洪日昌. 基于朴素贝叶斯 K 近邻的快速图像分类算法[J]. *北京航空航天大学学报*, 2015, **41**(2): 302 - 310. (ZHANG Xu, JIANG Jian-guo, HONG Ri-chang. Accelerated image classification algorithm based on naive Bayes K -nearest neighbor[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2015, **41**(2): 302 - 310. (in Chinese))
- [13] 康丽萍, 孙显, 许光鑫. 加权 KNN 的图文数据融合分类[J]. *中国图象图形学报*, 2016, **21**(7): 854 - 864. (KANG Li-ping, SUN Xian, XU Guang-luan. Fusion method via KNN with weight adjustment for the classification of image-text co-occurrence data[J]. *Journal of Image and Graphics*, 2016, **21**(7): 854 - 864. (in Chinese))
- [14] 张嘉凡, 张雪娇, 杨更社. 基于聚类算法的岩石 CT 图像分割及量化方法[J]. *西安科技大学学报*, 2016, **36**(2): 171 - 175. (ZHANG Jia-fan, ZHANG Xue-jiao, YANG Geng-she. A method of rock CT image segmentation and quantification based on clustering algorithm[J]. *Journal of Xi'an University of Science and Technology*, 2016, **36**(2): 171 - 175. (in Chinese))
- [15] LI N, HAO H Z, GU Q, et al. A transfer learning method for automatic identification of sandstone microscopic image. *Computers & Geosciences*, 2017, **103**(2): 111 - 121.
- [16] 谭永杰. 地质大数据体系建设的总体框架研究[J]. *中国地质调查*, 2016, **3**(3): 1 - 6. (TAN Yong-jie. Study on the overall framework of the construction of large geological data system[J]. *Geological Survey of China*, 2016, **3**(3): 1 - 6. (in Chinese))
- [17] 郑泽宇, 顾思宇. TENSORFLOW 实战 GOOGLE 深度学习框架[M]. 北京: 电子工业出版社, 2017. (ZHENG Ze-yu, GU Si-yu. TENSORFLOW practical GOOGLE deep learning framework[M]. Beijing: Electronic Industry Press, 2017. (in Chinese))
- [18] WU Y C, YIN F, LIU C L. Improving handwritten Chinese text recognition using neural network language models and convolutional neural network shape models[J]. *Pattern Recognition*, 2017, **65**(5): 251 - 264.
- [19] BIANCO S, BUZZELLI M, MAZZINI D, et al. Deep learning for logo recognition[J]. *Neurocomputing*, 2017, **245**(1): 23 - 30.
- [20] ESTEVA A, KUPREL B, NOVOA R A, et al. Dermatologist-level classification of skin cancer with deep neural networks[J]. *Nature*, 2017, **542**(7639): 115 - 118.
- [21] GONG M G, YANG H L, ZHANG P Z. Feature learning and change feature classification based on deep learning for ternary change detection in SAR images[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, **129**(2): 212 - 225.
- [22] 柳厚祥, 李汪石, 查焕奕. 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 - 1816. (LIU Hou-xiang, LI Wang-shi, ZHA Huan-yi. Method for surrounding rock mass classification of highway tunnels based on deep learning technology[J]. *Chinese Journal of Geotechnical Engineering*, 2018, **40**(10): 1809 - 1816. (in Chinese))
- [23] 杨善统, 姜清辉, 尹涛, 等. 边坡临界滑面搜索的改进粒子群优化算法[J]. *岩土工程学报*, 2015, **37**(8): 1411 - 1417. (YANG Shan-tong, JIANG Qing-hui, YIN Tao, et al. Search of critical slip surface of slopes using improved particle swarm optimization method[J]. *Chinese Journal of Geotechnical Engineering*, 2015, **37**(8): 1411 - 1417. (in Chinese))
- [24] 康石磊, 阳军生, 杨峰. 含裂隙类岩试样破坏行为的宏观数值分析[J]. *长江科学院院报*, 2016, **33**(4): 71 - 77. (KANG Shi-lei, YANG Jun-sheng, YANG Feng. Macro- and meso-analysis of failure behavior of rock-like samples with flaws using a numerical method[J]. *Journal of Yangtze River Scientific Research Institute*, 2016, **33**(4): 71 - 77. (in Chinese))