

基于迁移学习技术的隧道围岩岩性识别方法

柳厚祥, 王建

(长沙理工大学 土木工程学院, 长沙 410114)

摘要:为实现隧道围岩岩性的自动识别与分类,提出了基于迁移学习技术的围岩岩性识别方法。首先,通过采用 Inception-ResNet-V2 (IRV2) 卷积神经网络模型在 Image-Net 数据集上进行预训练,并利用模型迁移学习技术对岩石图片数据集(包含花岗岩、石灰岩、玄武岩和页岩)进行再训练,获取隧道围岩岩性识别模型;然后,对 IRV2 进行模型测试,并与 ResNet-50、Inception-V3 和 VGG16 三种模型的识别性能进行对比;最后,进行子图像法与整体图像法的识别效果对比试验。实验结果表明:(1) IRV2 的各项分类性能指标均表现为最优,且均可达到 90% 以上,表明该模型可以实现围岩岩性的有效识别与精确分类;(2) 对于具有更加突出的纹理、结构和构造等外部特征的岩石图片,模型的识别性能更好;(3) 子图像法相比于整体图像法可有效提高模型的识别性能。

关键词:隧道工程;岩性识别;迁移学习;子图像法;Inception-Resnet-V2

中图分类号:U452.1

文献标识码:A

文章编号:1673-0836(2023)02-0437-09

Lithology Identification Method of Tunnel Surrounding Rock Based on Transfer Learning Technology

Liu Houxiang, Wang Jian

(School of Civil Engineering, Changsha University of Science and Technology, Changsha 410114, P. R. China)

Abstract: In order to realize the automatic recognition and classification of the surrounding rock lithology of the tunnel, a method of lithology recognition based on migration learning technology is proposed. First, pre-training on the Image-Net dataset by using the Inception-ResNet-V2 (IRV2) convolutional neural network model, and using model transfer learning technology to retrain the rock image dataset (including granite, limestone, basalt and shale) to obtain The lithology recognition model of the surrounding rock of the tunnel; then, the IRV2 model is tested, and the recognition performance of the three models; ResNet-50, Inception-V3 and VGG16 is compared; finally, the sub-image method and the overall image method are performed Comparative test of recognition effect. The experimental results show that: (1) The various classification performance indicators of IRV2 are all the best, and all can reach more than 90%, indicating that the model can realize the effective identification and accurate classification of surrounding rock lithology; (2) For rock pictures with more prominent texture, structure and structure, the recognition performance of the model is better; (3) The sub-image method can effectively improve the model's performance compared to the overall image method. Identify performance.

Keywords: tunnel engineering; lithology identification; transfer learning; sub-image method; inception-resnet-v2

收稿日期:2022-12-19(修改稿)

作者简介:柳厚祥(1965—),男,湖南邵阳人,博士,教授,主要从事隧道与地下结构设计理论与方法等方面的研究。

E-mail:liuhoux1@163.com

基金项目:湖南省水利厅科技项目(XSKJ2019081-39);湖南省教育厅科学研究重点项目(19A025)

0 引言

岩体质量是关系着工程设计、施工与稳定性超前预测的重要指标^[1-3]。而隧道围岩岩性识别在岩体质量评价、围岩稳定性分析等工作中是至关重要的。若不能准确地识别围岩岩性,那么隧道工作面则可能会出现塌方问题与施工障碍,这无疑给隧道的建设、运营和维护带来了严峻挑战。目前,对隧道围岩岩性的识别一般仍采用传统经验法,常依赖于施工技术人员通过观察围岩的结构、构造等多方面特征进行识别^[4],此方法对施工技术人员要求较高,需要有充足的经验作为知识支撑,易受人为因素的影响,且误判率高。

为解决上述问题,诸多学者针对岩性识别进行了大量研究:Singh 等^[5]利用神经网络对玄武岩图片进行分析处理,可实现对玄武岩的精确分类;张炎等^[6]对基于主成分的多重分形法在岩性识别中的应用进行了深入研究,可有效地识别粉砂岩、泥岩与细砂岩;张翠芬等^[7]依据各岩性单元的特征向量统计结果构建比值运算,再结合主成分分析特征向量对图片进行彩色合成,使得岩石岩性的识别准确率显著提高。然而以上岩性识别方法或局限性太大,或实验过程过于复杂,仍不能满足实际工程的需要。

近年来,随着物联网技术的飞速发展、人工智能技术的不断提高,我国越发重视各种高科技手段在隧道工程中的应用^[8]。其中,深度学习技术与土木工程相互交叉,为研究人员提供了一种快速高效的分析方法,并在诸多领域取得了突破性进展。例如,一些学者深入探究了运用卷积神经网络识别混凝土裂缝^[9-13],该方法具有较高的识别精度;柳厚祥等^[14]研究了利用深度学习技术与传统 BQ 分级相结合的方法进行公路隧道围岩分级,其分级准确率可稳定在 80% 以上;Chen 等^[15]提出了一种基于深度学习和隧道掌子面地质图片的岩体结构自动分类框架,对镶嵌、颗粒、层状、块状和破碎 5 种岩体结构的分类准确率达到 95% 左右;Su 等^[16]利用卷积神经网络对岩石薄片图片进行特征的提取与识别,以达到岩石分类的目的,其识别准确率可达到 89% 以上;胡启成等^[17]深入研究了基于地质图像大数据与深度学习技术的岩性识别方法,测试准确率在 90% 左右。综上所述,深度学习方法已

被广泛应用于解决工程实际问题,且具有较高的精度和效率。

然而传统的深度学习方法仍然存在如下两点明显缺陷:网络模型结构过于复杂,参数繁多;模型训练需要大量数据^[18]。迁移学习(Transfer learning)^[19-20]的出现为解决上述问题提供了新思路。迁移学习是将预训练模型的结构与参数应用于目标任务模型之中,再利用目标数据集通过再训练得到目标任务模型^[21-22]。迁移学习方法摆脱了传统深度学习方法存在的缺陷,显著提高了模型的学习效果。

本文提出基于 Inception-ResNet-V2^[23-25] 和迁移学习技术的隧道围岩岩性识别方法。运用迁移学习技术,构建并训练迁移学习模型,并结合子图像法对图片进行纹理、颜色、结构及构造等特征的自动提取,从而得到隧道围岩岩性的识别结果。

1 迁移学习技术

1.1 迁移学习模型基本结构

迁移学习模型的体系结构由几个独特的层组成,主要包括卷积层、激活层、池化层、Dropout 层和 Softmax 层^[26-27]。

卷积层被广泛用作特征生成器。卷积神经网络(Convolutional Neural Networks, CNN)的每个卷积核都以确定的步长在输入矩阵上滑动,在输入 RGB 矩阵和每个滑动位置的内核之间进行逐元素乘法,并将所有乘积值加在一起以形成输出加偏置,输出大小由卷积核和步长大小确定。

激活层用于增加卷积输出的非线性。本文采用的非线性 ReLU 激活函数能够避免由于梯度过大而导致的梯度分散(梯度爆炸)和因梯度过小而导致的梯度消失等问题,同时可以保持较高的运算效率。

池化层的作用是特征降维,压缩数据,减少参数量,降低过拟合发生概率,同时增强模型结构的容错性。

Dropout 层是一种随机断开技术,可以以 $1-p$ 的丢失率随机隔离不同节点之间的连接。Dropout 层可减少模型参数量,避免模型发生过拟合,并提高模型结构的鲁棒性。

Softmax 层是多项逻辑损失的组合,在多分类过程中用于对一定权重的分类向量进行归一化,可

以将抽象矩阵转换为具体的分类结果。

1.2 迁移学习的技术优势

运用传统的深度学习技术,即便目标任务与此前的源任务之间具有一定的相关性,但目标任务模型仍是从头开始构建,对于已构建的源模型中的结构和参数也不加任何参考,孤立地构建目标模型会耗费大量的时间和精力。而采用迁移学习技术,倘若不同的任务之间存在相似性,则在源任务中学习到的具有普遍有效的规律知识可以通过微小的改变,甚至不经任何改变即可应用到目标模型之中。采用迁移学习方法有助于目标任务网络模型的构建,减少大量重复性劳动,且削弱了模型对目标任务训练数据量的依赖性。传统深度学习与迁移学习对比示意图如图 1 所示。

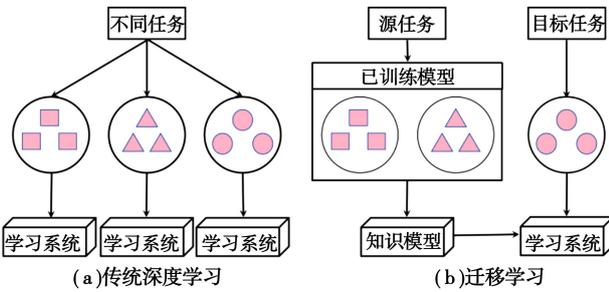


图 1 传统深度学习与迁移学习对比示意图

Fig. 1 Comparison between traditional deep learning and transfer learning

1.3 Inception-ResNet-V2

本文采用的 Inception-ResNet-V2 卷积神经网络模型是在 2018 年由 Google 公司首次提出,它是由 Google-Net(Inception)和残差网络(ResNet)结合构成,在 Inception 中加入残差块,使参数可以通过网络中的捷径跃过一些层直接进行传播,解决了在更深层网络结构中梯度消失的问题。

该算法由以下几个部分组成:前 7 层由 5 层卷积层、2 层最大池化层和 1 层具有 4 个分支 Inception 模块组成;具有 3 个分支的残差 Inception 模块,并重复 5 次该模块;包括 3 个分支的 Inception 模块;具有 2 个分支的残差 Inception 模块,并重复 10 次该模块;包括 4 个分支的 Inception 模块;具有 2 个分支的残差 Inception 模块,并重复 5 次该模块;1 层平均池化层;1 层 Dropout 层;最后为 Softmax 层,输出识别结果。Inception-ResNet-V2 架构示意图如图 2。

2 实验设计

2.1 实验环境

硬件环境: QuadCore Intel Core i7-10800 @ 3.40 GHz;内存 32GB;NVIDIA GTX 3070 GPU8GB。

软件环境: Windows 10 操作系统;TensorFlow 1.13.1 和 Keras 2.2.4。

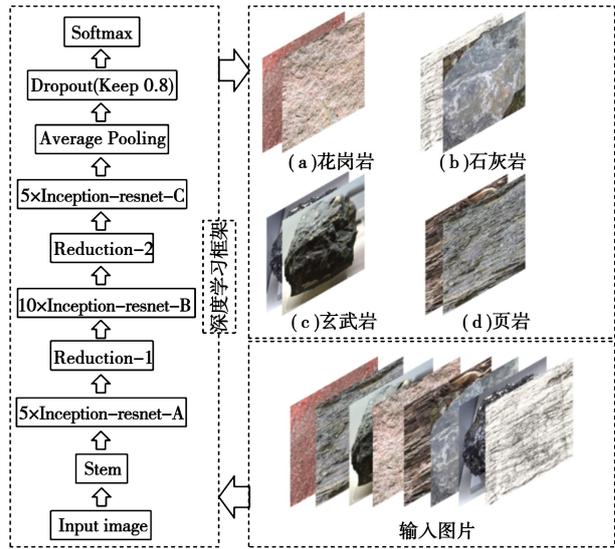


图 2 Inception-ResNet-V2 结构框架

Fig. 2 Inception-ResNet-V2 structure frame

2.2 样本数据

本文采用的岩石图片样本包括私人数据集及网络图片数据集,私人数据集采集于湖南湘西永吉高速的那丘、务西作、狮子庵、六月田、白尖山隧道,选取了其中较常见的花岗岩、石灰岩、玄武岩、页岩四类岩石图片。花岗岩多为花岗结构,块状构造;石灰岩多为晶粒结构或碎屑结构,层状构造;玄武岩多为斑状结构,块状构造;页岩多为泥质结构,水平层理构造。数据集共包括 867 张岩石图片,其中花岗岩 258 张,石灰岩 194 张,玄武岩 225 张,页岩 190 张。训练集、验证集与测试集按照 8:1:1 的比例进行随机分配。详细分配方案如表 1 所示。

表 1 岩石图片数据集分类及数量

Table 1 Classification and quantity of rock image data sets

岩石种类	图片数量	训练集数量	验证集数量	测试集数量
花岗岩	258	208	25	25
石灰岩	194	154	20	20
玄武岩	225	185	20	20
页岩	190	150	20	20

为了增强模型的泛化性能,对数据集图片进行随机亮度变换、随机对比度变换和随机翻转等一系列预处理来增加图片数量,处理之后数据集图片数量为 6 936 幅。并将数据集图片进行归一化处理,以便于模型对输入数据进行处理,图片预处理演示如图 3 所示。

训练集用于模型训练;验证集不参与训练,而是用于确定模型最优超参数,提高模型精度,降低发生过拟合和不收敛的概率;测试集是在确定了所有参数之后,用来评估迁移学习模型的识别性能。

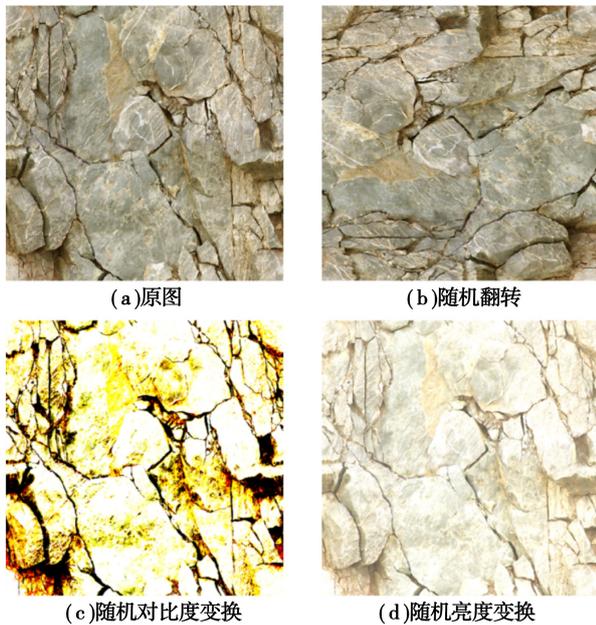


图 3 图片预处理

Fig. 3 Picture preprocessing

2.3 模型训练与测试

迁移学习岩石图像识别方法流程如图 4 所示。

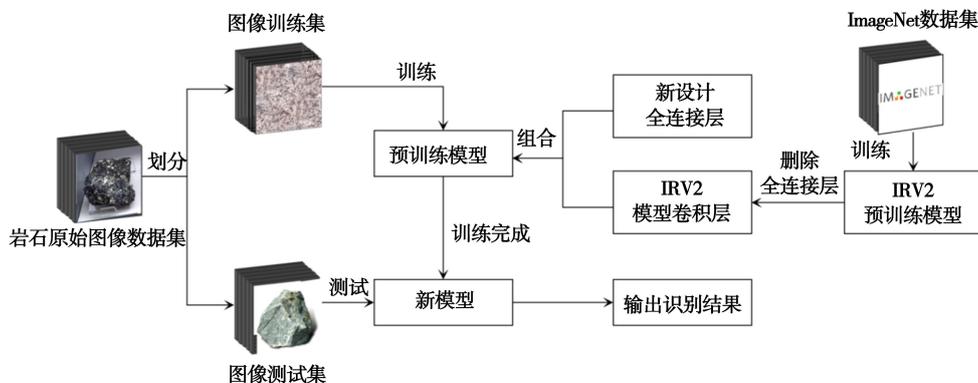


图 4 迁移学习岩石图像识别方法流程

Fig. 4 Flowchart of transfer learning model of rock images

2.3.1 迁移学习模型构建

(1)在 Image-Net 大数据集上对 IRV2 模型进行预训练,然后将原始图片数据集传入预训练模型之中。

(2)构建 Batch Normalization,对模型输出进行归一化处理。

(3)在模型迁移过程中,保持模型的权重参数不变,设置激活函数为 Relu 函数。

2.3.2 迁移学习模型调整

(1)添加全连接层:对已经得到的初始模型进行结构和微参数的调整,使用包含岩石种类标签的 SoftMax 分类器替代原来的分类器,并将 IRV2 网络原来全连接层的输出神经元个数设置为需预测的岩石种类数目。

(2)建立 Dropout 层,以防止模型出现过拟合问题,并增强模型的泛化性能。

(3)设置实验迭代次数,并设定 batch-size 个数,即将一定数目样本例作为一个 batch 进行迭代;初始学习率进行不同的设置,来寻找最优初始学习率。

(4)使用梯度下降算法来优化目标函数,并采用余弦退火函数来降低学习率,使模型尽可能接近 Loss 值的全局最小值。

(5)采用交叉熵函数作为损失函数,来衡量模型预测准确性。

(6)分别以模型初始学习率和优化器种类为自变量进行实验,对验证集的识别效果进行统计,实现确定模型最优参数的目的。

2.3.3 迁移学习模型实验

(1) 模型识别性能对比试验

试验中选用 ResNet-50、Inception-V3 和 VGG16 3种卷积神经网络模型进行迁移学习和目标数据集的训练,将 IRV2 与上述 3 种 CNN 模型的图像识别性能进行对比分析,其详细模型参数如表 2 所示。

表 2 网络模型的详细信息

Table 2 Details of the network model

网络模型	深度	参数量	规模/MB
VGG16	16	138 357 544	528
Inception-V3	159	23 851 784	92
ResNet-50	168	25 636 712	99
IRV2	572	55 873 736	215

(2) 子图像法与整体图像法识别效果对比试验

将测试集的完整围岩图像切割为 4×4 的子图像,并在相应位置进行标记。子图像分割示意图如图 5 所示。

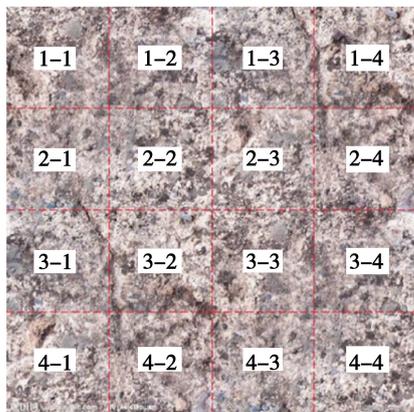


图 5 子图像分割示意图

Fig. 5 Schematic diagram of sub-image segmentation

将整体图像和所有子图像分别放入 IRV2 模型进行特征提取,得到整体图像与每一个子图像的识别结果,依据子图像识别结果通过概率统计方法来确定围岩岩性的识别结果,并将整体图像法和子图像法的识别结果进行对比分析。

3 试验结果分析

3.1 基本评估指标

准确率 (Accuracy)、精度 (Precision)、召回率 (Recall) 和 F1 分数 (F1-Score) 是分类任务中必不可少的指标,常用于评估框架的适用性和优越性。图 6 显示了上述评估指标与判断元素之间的关系,具体公式如式(1)—(4)所示。

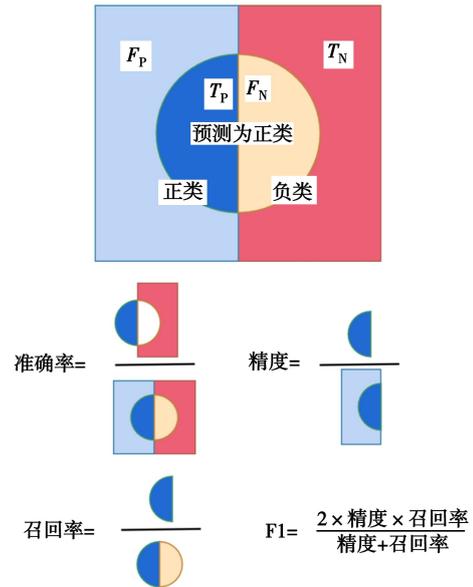


图 6 评估指标的简单定义

Fig. 6 The simple definition of assessment indicators

准确率表示算法对总体样本的分类性能,计算公式为:

$$A = \frac{T_p + T_n}{T_p + F_n + F_p + T_n} \times 100\% \quad (1)$$

式中: A 为准确率; T_p 为把正类判别为正类的样本数; F_n 为把正类判别为负类的样本数; T_n 为把负类判别为负类的样本数; F_p 为把负类判别为正类的样本数。

精度表示算法对正类样本预测的准确性,计算公式为:

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (2)$$

式中: P 为精度

召回率表示算法对正类样本预测的全面性,计算公式为:

$$R = \frac{T_p}{T_p + F_n} \times 100\% \quad (3)$$

式中: R 为召回率。

使用 $F1$ 分数来综合衡量精度与召回率,可以更为全面的评估算法的分类性能,计算公式为:

$$F1 = \frac{2PR}{P + R} \quad (4)$$

式中: $F1$ 为精度和召回率的调和平均值。

3.2 训练、验证结果分析

试验中训练集与验证集的识别准确率随迭代次数的变化关系如图 7 所示。

由图 7 可以看出,随着迭代次数的不断增加,训练集和验证集的识别准确率都逐渐增大。迭代 60 步,训练集准确率已基本稳定在 96% 左右;迭代 40 步,验证集准确率已基本稳定在 93% 左右,验证集准确率在收敛之后明显低于训练集准确率。

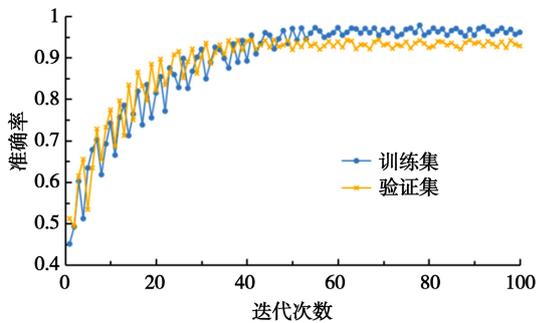


图 7 识别准确率与迭代次数的关系

Fig. 7 Relationship between recognition accuracy and the number of iterations

试验中训练集与验证集的损失交叉熵与迭代次数的关系如图 8 所示。

由图 8 可以看出,训练集和验证集上的损失值随着迭代次数的增加而降低,训练集总损失收敛值在 0.04 左右,验证集总损失收敛值在 0.07 左右,可见训练集的总损失收敛值明显低于验证集的总损失收敛值,表明训练集预测类别与真实类别之间的差距更小,即预测准确率更高。

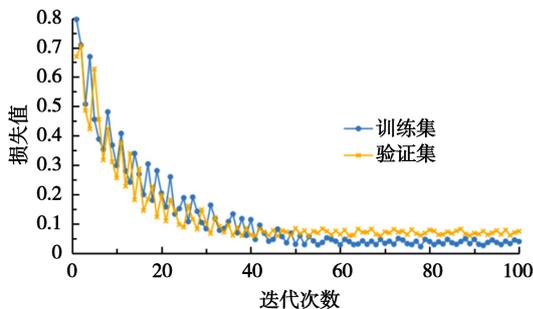


图 8 损失率与迭代次数的关系

Fig. 8 Relationship between loss rate and number of iterations

3.3 不同模型的识别效果分析

在图 9 中绘制了 IRV2、Inception-V3、ResNet-50 和 VGG16 四种 CNN 模型在测试集上的识别准确率、精度、召回率和 $F1$ 分数 4 个方面的比较。首先,IRV2 模型识别性能测试的各项评估指标均达到 90% 以上,说明模型具有较强泛化能力和鲁棒性,可有效地识别围岩的岩性特征。其次,显而易见,IRV2 识别性能最优,VGG16 识别性能最差。最后,还可以得出,4 种 CNN 模型的所有评估指标都呈现出相似的趋势,指标值从高到低排,大致遵循如下顺序:花岗岩、玄武岩、页岩和石灰岩。由于花岗岩具有较为独特的构造、结构、纹理及颜色等外部特征,因此使得 CNN 模型对花岗岩的识别性能尤为突出;由于石灰岩的外部特征不太明显,使得石灰岩图片的分类性能相对较差。

为了进一步探讨 IRV2 模型的识别性能,图 10 展示了从测试集中选取的 8 张图片的岩性识别结果,使 IRV2 模型的识别结果可视化。由图 10 可以看出,IRV2 模型对 4 类岩石的识别性能出色,其中 7 张图片预测为正类的概率均在 90% 以上,2 张花岗岩图片预测为正类的概率甚至达到 95% 以上。但是其中 1 张石灰岩图片的识别结果出现了极其严重的误判,将其误判为页岩的概率达 54.18%。引起误判的原因可能为:(1) 图片稍显模糊,使模型难以提取到岩石有效的外部特征;(2) 该石灰岩图片的层状结构与页岩相近;(3) 数据集中缺乏具有典型层状结构特征的石灰岩图片。为了避免发生误判,需要采用更加清晰的图片构建数据集,在训练过程中增加具有典型特征的各类岩石图片数量,以增强数据的鲁棒性。

3.4 子图像法识别效果分析

通过子图像分割测试实验,得到每一块子图像的岩性识别结果,并将其进行统计分析。其详细识别结果如图 11 所示。

为了进一步对比分析子图像法和整体图像法识别效果之间的差异,表 3 总结了图 11 中统计数据平均值,以及整体图像分类的测试概率。

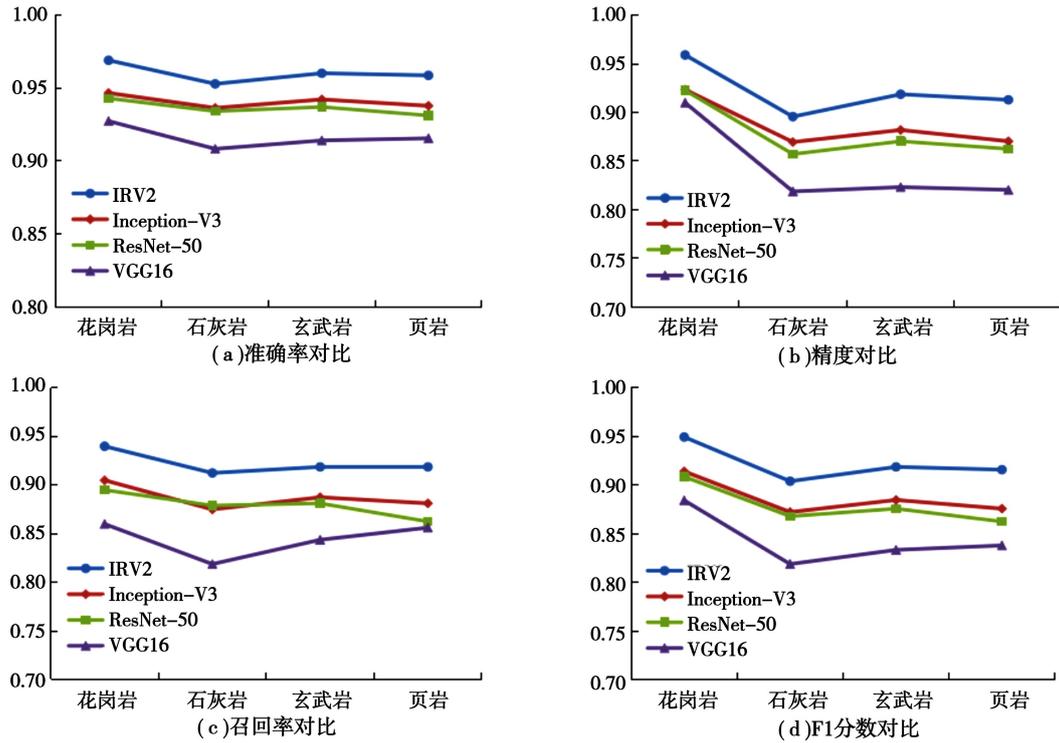


图 9 各类岩石在不同模型测试中的评估指标值

Fig. 9 Evaluation index values of various types of rocks in different model tests

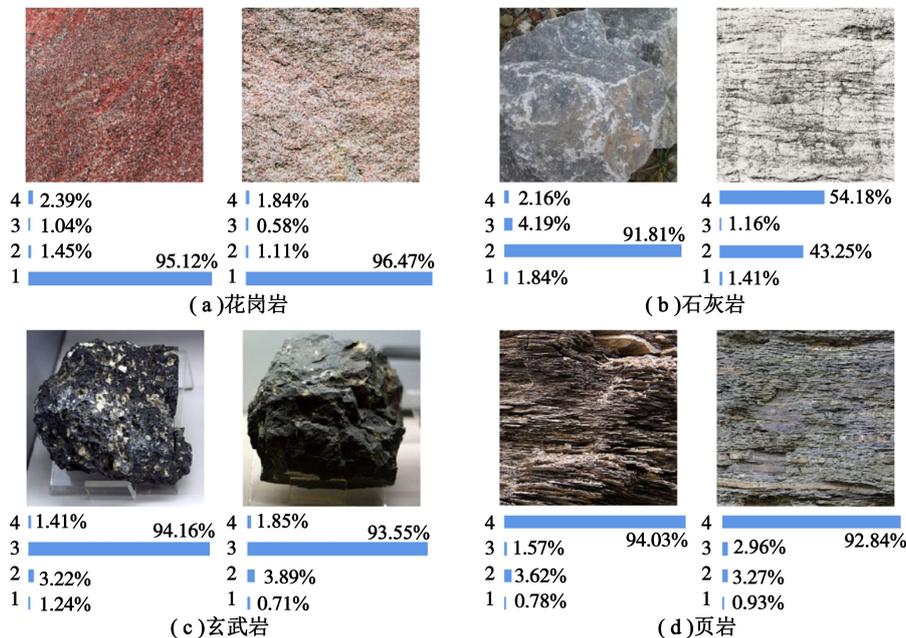


图 10 测试集部分图像岩性识别结果

Fig. 10 Lithology recognition results of some images in the test set

运用整体图像法预测该围岩图像为真实值花岗岩的概率为 91.87%,运用子图像法统计得到预测该围岩图像为真实值花岗岩的概率为 93.48%,表明两种方法都可以准确识别分类结

果,而子图像法的识别准确率比整体图像法提高了 1.61%。由此可见,运用子图像法可有效提高图片识别的准确率。

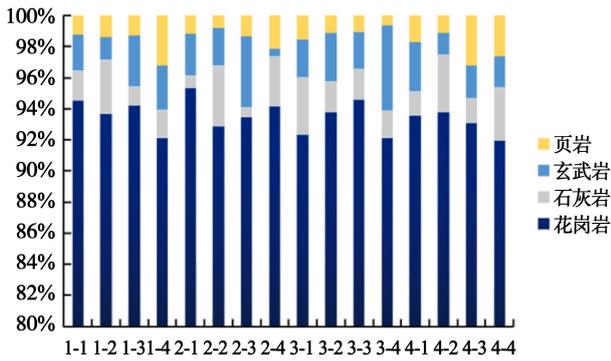


图 11 子图像岩性识别结果统计图

Fig. 11 Statistics of sub-image lithology recognition results

表 3 子图像与整体图像岩性识别结果对比

(单位: %)

Table 3 Comparison of lithology recognition results between sub-image and overall image

(unit: %)

识别方法	岩石种类			
	花岗岩	石灰岩	玄武岩	页岩
子图像	93.48	2.64	2.28	1.60
整体图像	91.87	3.28	2.79	2.06

4 结论

(1) Inception-ResNet-V2 的 4 项分类性能指标均表现为最优,且均可达到 90% 以上,其中花岗岩的各项分类指标可达到 95% 以上。表明该模型具有较强泛化能力和鲁棒性,可以实现围岩岩性的有效识别与精确分类。

(2) 由于花岗岩具有较为独特的构造、结构、纹理及颜色等外部特征,因此使得 CNN 模型对花岗岩的识别性能尤为突出;而石灰岩的外部特征不太明显,因此石灰岩图片的分类性能相对较差。

(3) 子图像法的识别准确率比整体图像法提高了 1.61%。因此,运用子图像法可有效提高模型的识别准确率。

作为使用迁移学习方法对施工中的隧道围岩岩性进行识别和分类的首次尝试,此方法为隧道施工人员提供了更高精度和效率的围岩岩性识别方法。然而由于笔者能力有限,只收集到了永吉高速部分隧道典型的 4 类岩石图片,未来将致力于构建更多种类岩石的识别模型,各类岩石之间的外部特征必然存在更多的相似性,会导致模型识别准确率的降低。因此,将来要加强对每种岩石定名的理性

认识的学习,在实验室对每种岩石进行深入研究,获取各类岩石名称与其外部特征之间的详细对应关系,在图片预处理过程中对每种岩石独特的外部特征进行标记,使模型对其进行针对性的提取和学习,以达到提高模型识别准确率的目的。

参考文献 (References)

- [1] 陈庆发,刘恩江,高飞红,等. 裂隙岩体质量三维精细分级 S-RMR_{mbi} 方法及可视化[J]. 地下空间与工程学报, 2020, 16(4): 1130-1141. (Chen Qingfa, Liu Enjiang, Gao Feihong, et al. Three-dimensional sub-classification for jointed rock mass quality (S-RMR_{mbi}) based on comprehensive fuzzy identifying theory [J]. Chinese Journal of Underground Space and Engineering, 2020, 16(4): 1130-1141. (in Chinese))
- [2] 史秀志,黄敏,周健,等. 工程岩体质量等级判别的未确知均值聚类法[J]. 地下空间与工程学报, 2010, 6(6): 1168-1173, 1214. (Shi Xiuzhi, Huang Min, Zhou Jian, et al. Assessment of classification of engineering rock mass quality based on uncertainty average clustering measurement method [J]. Chinese Journal of Underground Space and Engineering, 2010, 6(6): 1168-1173, 1214. (in Chinese))
- [3] 闫天俊,吴雪婷,吴立. 地下洞室围岩分类相关性研究与工程应用[J]. 地下空间与工程学报, 2009, 5(6): 1103-1109. (Yan Tianjun, Wu Xueting, Wu Li. Correlation study on surrounding rockmass classification for underground cavern and its application [J]. Chinese Journal of Underground Space and Engineering, 2009, 5(6): 1103-1109. (in Chinese))
- [4] Chatterjee S, Bhattacharjee A, Samanta B, et al. Image-based quality monitoring system of limestone ore grades [J]. Computers in Industry, 2010, 61(5): 391-408.
- [5] Singh N, Singh T N, Tiwary A, et al. Textural identification of basaltic rock mass using image processing and neural network [J]. Computational Geosciences, 2010, 14: 301-310.
- [6] 张焱,周永章,朱继田. 基于主成份的多重分形法在岩性识别中的应用[J]. 中山大学学报(自然科学版), 2015, 54(3): 145-150, 157. (Zhang Yan, Zhou Yongzhang, Zhu Jitian. Application of multifractal method based on principal components in lithology identification [J]. Journal of Sun Yat-Sen University (Natural Science Edition), 2015, 54(3): 145-150, 157. (in Chinese))

- [7] 张翠芬,郝利娜,王元俭,等. Landsat8 OLI 图片增强与岩性识别方法[J]. 地质与勘探, 2017, 53(2): 325-333. (Zhang Cuifen, Hao Lina, Wang Yuanjian, et al. An image enhancement and lithology identification method based on Landsat8 OLI data [J]. *Geology and Prospecting*, 2017, 53(2): 325-333. (in Chinese))
- [8] 张俊儒,燕波,龚彦峰,等. 隧道工程智能监测及信息管理系统的研究现状与展望[J]. 地下空间与工程学报, 2021, 17(2): 567-579. (Zhang Junru, Yan Bo, Gong Yanfeng, et al. Research status and prospects of intelligent monitoring technology and information management systems for tunnel engineering [J]. *Chinese Journal of Underground Space and Engineering*, 2021, 17(2): 567-579. (in Chinese))
- [9] Cha Y J, Choi W, Suh G, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2018, 33(9): 731-747.
- [10] Chaiyasarn K, Sharma M, Ali L, et al. Crack detection in historical structures based on convolutional neural network [J]. *International Journal of Geomate*, 2018, 15(51): 240-251.
- [11] Dda B, Heb A, Es A, et al. Automatic crack classification and segmentation on masonry surfaces using convolutional neural networks and transfer learning [J]. *Automation in Construction*, 2021, 125: 1-18.
- [12] Dorafshan S, Thomas R J, Maguire M. Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete [J]. *Construct Build Mater*, 2018, 186(20): 1031-1045.
- [13] Bang S, Park S, Kim H, et al. Encoder-decoder network for pixel-level road crack detection in black-box images [J]. *Computer Aided Civil & Infrastructure Engineering*, 2019, 34(8): 713-727.
- [14] 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. (in Chinese))
- [15] 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.
- [16] Su C, Xu S, Zhu K, et al. Rock classification in petrographic thin section images based on concatenated convolutional neural networks [J]. *Earth Science Informatics*, 2020, 13(4): 1477-1484.
- [17] 胡启成,叶为民,王琼,等. 基于地质图像大数据的岩性识别研究[J]. 工程地质学报, 2020, 28(6): 1433-1440. (Hu Qicheng, Ye Weimin, Wang Qiong, et al. Study on lithology recognition based on big data of geological image [J]. *Journal of Engineering Geology*, 2020, 28(6): 1433-1440. (in Chinese))
- [18] Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks [J]. *Pattern Recognition*, 2018, 77: 354-377.
- [19] Tan C, Sun F, Kong T, et al. A survey on deep transfer learning [A] // *International Conference on Artificial Neural Networks* [C]. 2018: 270-279.
- [20] Pan S J, Yang Q. A survey on transfer learning [J]. *IEEE Transactions on Knowledge & Data Engineering*, 2010, 22(10): 1345-1359.
- [21] Qureshi A S, Khan A, Zameer A, et al. Wind power prediction using deep neural network based meta regression and transfer learning [J]. *Applied Soft Computing*, 2017, 58: 742-755.
- [22] Xu G, Zhu X, Fu D J, et al. Automatic landcover classification of geo-tagged field photos by deep learning [J]. *Environmental Modelling & Software*, 2017, 91: 127-134.
- [23] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [A] // *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [C]. 2015: 1-9.
- [24] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning [A] // *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence* [C]. 2017: 4278-4284.
- [25] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [A] // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [C]. 2016: 770-778.
- [26] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [A] // *Proceedings of the 25th International Conference on Neural Information Processing Systems* [C]. 2012: 1097-1105.
- [27] Huang G, Liu Z, Van D M, et al. Densely connected convolutional networks [A] // *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [C]. 2017: 4700-4708.