ISSN 1004-9037,CODEN SCYCE4
Journal of Data Acquisition and Processing Vol. 40,No. 3,May 2025,pp. 675－685
DOI:10. 16337/j. 1004-9037. 2025. 03. 009

http://sjcj. nuaa. edu. cn
E-mail:sjcj@nuaa. edu. cn
Tel/Fax:＋86-025-84892742

# 基于深度学习的岩石钻孔全景图像识别

先永利[1,2]，陈学健[2]，彭真明[1]，汪　杰[3]，彭　波[4,5]

(1. 电子科技大学信息与通信工程学院，成都 611731；2. 西华大学电气与电子信息学院，成都 610039；3. 武汉航工智能科技有限公司，武汉 430100；4. 西南科技大学信息与控制工程学院，绵阳 621010；5. 西南科技大学特种环境机器人技术四川省重点实验室，绵阳 621010)

**摘　要**：岩土钻孔监测作为一种最常见的隧道超前探测技术，可真实、原位反映岩土的材质、特征及地下水情况等，对确保施工安全至关重要。根据岩土钻孔监测目标特点，本文研制了一套基于全景摄像的适用于岩土长孔道内壁近距离、动态高分辨成像的智能视觉系统。通过EfficientNetV2网络的改进和滑动窗口预测，实现了8类岩石钻孔图像的智能识别。实验结果表明，视觉系统能满足长孔道的近距离高分辨全景成像，且实现岩石材质的智能状态评估，在测试集上的识别成功率达到91.49%，基本具备了岩土钻孔状态的综合智能化评估能力。

**关键词**：钻孔监测；全景成像；EfficientNetV2网络；智能识别

**中图分类号**：TP391　　**文献标志码**：A

## Panoramic Image Recognition of Rock Borehole Based on Deep Learning

XIAN Yongli[1,2], CHEN Xuejian[2], PENG Zhenming[1], WANG Jie[3], PENG Bo[4,5]

(1. School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China; 2. School of Electrical Engineering and Electronic Information, Xihua University, Chengdu 610039, China; 3. Wuhan Hanggong Intelligent Technology Co., Ltd, Wuhan 430100, China; 4. School of Information and Control Engineering, Southwest University of Science and Technology, Mianyang 621010, China; 5. Robot Technology Used for Special Environment Key Laboratory of Sichuan Province, Southwest University of Science and Technology, Mianyang 621010, China)

**Abstract**: Geotechnical borehole monitoring, as one of the most common tunneling advanced detection techniques, can truly reflect the material properties, characteristics, and groundwater conditions of geomaterials, which is vital to ensure construction safety. Based on the characteristics of the geotechnical borehole monitoring objectives, a smart visual system based on panoramic cameras is developed. The system is suitable for close-range and dynamic high-resolution imaging of the inner walls of long geotechnical boreholes. Based on the improved EfficientNetV2 network and the sliding window prediction, the rapid intelligent recognition of eight types of rock borehole images is realized. Experimental results show that the visual system can meet the requirements for close-range high-resolution panoramic imaging of long boreholes and achieve intelligent state assessment of rock materials. The recognition success rate reaches 91.49% on the test set, and the system preliminarily possesses the comprehensive intelligent evaluation capability of geotechnical borehole status.

**Key words:** borehole monitoring; panoramic imaging; EfficientNetV2 network; intelligent recognition

---

**基金项目**：国家自然科学基金(62205342)；四川省自然科学基金(2025ZNSFSC0522)；特种环境机器人技术四川省重点实验室开放基金(22kftk03)。

**收稿日期**：2024-06-23；**修订日期**：2024-09-25

## 引　言

随着国内铁路、公路、地铁及水工等建设的大力发展，隧道工程的需求日益增多[1]。其中，隧道超前探测作为隧道工程的关键环节之一[2]，用于探测隧道、隧洞和地下厂房等地下工程岩土体开挖面前方的地质情况，可提前获取量化的施工前的岩土体结构和性质、地下水及瓦斯等的赋存情况，以及地应力情况等，以保障工程的安全进行。而钻孔法是隧道超前探测中最常见的一种技术[3]，钻孔法可以真实且原位地反映岩土的大概情况，获得比较直观、准确、可靠的地质体特征及细微现象资料，如可由钻孔出水情况判断前方有无地下水和位置信息，确保施工安全。因此，对钻孔探测技术进行持续研究，提升相关功能参数是必要且有意义的。

当前，传统的钻孔法需占用较长的施工作业时间，费用较高，且成像探头直径一般较大（≥Φ75 mm），不能与专用的凿岩台车很好地进行配合[4]。同时，其在超前探测作业过程中需要取芯，这些会受到不良地质体的影响，如岩体破碎、岩体性状改变及软弱夹层等，进而可能导致取芯失败，超前预报失效。因此，为了提高探测效率、节省探测费用，本文研制了一套小口径（≤Φ64 mm）钻孔内视频全景成像系统，可以有效地利用凿岩台车现有平台。在形成Φ64 mm的冲击孔后，将本系统装在钻头位置，即钻杆前端，再一段一段地送入孔内，可实现长孔道内壁的全景成像，进而进行有效观察并及时发现异常情况。

当前类似的数字钻孔摄像系统的钻孔图像识别均专注于对岩层裂缝、孔隙等图像的研究，并进行结构的解释，如Wang等[5]使用正弦曲线对岩层平面进行迭代匹配，实现了结构面的自动识别和参数提取；Li等[6]基于钻孔图像提出了一种基于颜色的岩土界面识别和裂缝求解方法；Zou等[7]对结构面形态特征进行描述和分析，并将该特征用于描述节理粗糙度系数（Joint roughness coefficient, JRC），分析钻孔岩体的抗滑能力；Wang等[8]通过在珊瑚礁的钻孔图像中引入岩体完整性指数（Rock mass integrity index, RMDI），实现了针对珊瑚礁完整性的工程评价。正确预报钻孔不良地质体的详细数据可为准确选择开挖断面及支护设计参数以及优化施工方案提供依据，因此进行岩石智能识别研究具有较高的应用价值。基于自研的岩土钻孔全景成像系统，本文提出一种基于改进EfficientNetV2的岩石钻孔图像识别方法，并引入滑动窗口进行预测，实现岩石目标的识别。

## 1　系统介绍

由于钻孔探测应用场景具有小型、全景、大行程和防水等特点，全景摄像系统采用多段圆柱体螺纹连接的静密封设计，双摄像模组在轴向上串联布局且光轴正交；此外，外形采用导向设计，保证摄像系统在孔内的中心轴上，防止其在移动过程中卡顿。考虑到待检孔洞的材质和深度等特性会严重限制无线信号的传输，系统采用一体化设计，且自备应急电源和前端视频储存模块。最后，系统自带LED照明，配合腔体内的自平衡结构和轮式编码计数单元，在孔内全景视频和局部高清图像获取的同时，完成对应的孔深信息和方位信息的记录。

岩石钻孔全景摄像系统组成如图1所示。系统由全景摄像模组、高分辨率摄像模组、筒型密封机构、照明单元、计米单元、导向扶正单元以及钻杆连接单元等组成。其中，2台摄像模组和照明单元在密封机构内部；计米单元与密封机构间刚性连接，且工作过程中计米单元的滚轮与孔道内壁有效接触，配合轮式编码可实现孔深的有效测量；导向扶正单元采用柔性耐磨材料，外形导向设计，包络尺寸与孔径一致；钻杆连接单元可实现系统在现有平台上的有效安装。全景摄像主要用于目标全局的快速成像，而位于系统中段的高清摄像模块，是用于解决部分感兴趣区域的高清解析

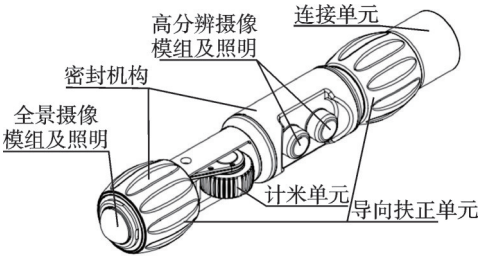


图1　岩石钻孔全景摄像系统组成

Fig.1　Composition of rock borehole panoramic camera system

和采集留档。系统实物图如图2(a)所示,利用该系统采集到的一幅钻孔图像如图2(b)所示。

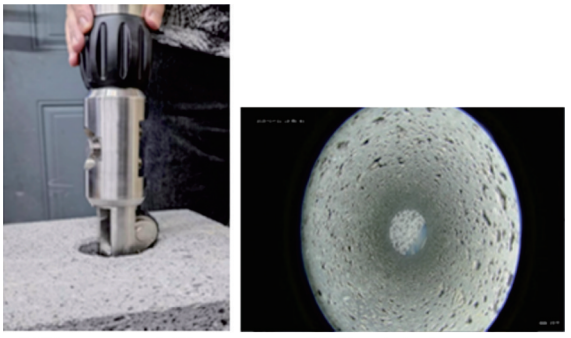


图2 图像采集系统

Fig.2 Image acquisition system

## 2 算法描述

### 2.1 全景图像展开算法

为了实现岩石钻孔图像的识别,需先对系统采集到的全景图像进行展开处理。全景摄像系统将目标内壁情况表征在极坐标系中,而全景图像展开算法可以生成其对应的正交坐标图像。图像展开主要涉及图像的坐标配准和坐标映射,坐标配准主要实现摄像系统相对检测目标的坐标统一问题[9];坐标映射则实现展开图像的坐标计算,相对应的模型如图3所示[10],对于全景图像上的任意一个像素点,均可以得到其在对应单位球面上相应的经度$\theta$和纬度$\varphi$。图中,$OP$为全景摄像机视场内的任一观察线,$P_1$为$OP$观察线上有效物距处的目标点。

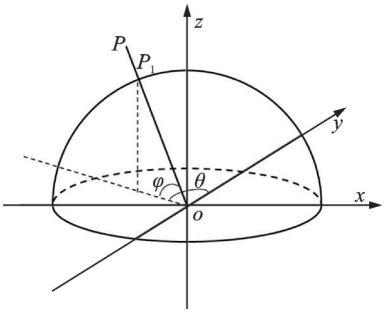


图3 全景透视模型

Fig.3 Panoramic perspective model

考虑到球面不同距离存在近大远小,即成像的圆环有内外径差别,故展开算法还涉及图像插值。本文根据目标最远处的端面特点,通过其圆心的自动定位,为坐标配准提供了基准坐标。然后,以基准坐标为原点,引入有效角度,可实现内外圆环的生成,即得到了待展开区域。最后结合坐标映射,通过坐标转换、线性插值可得全景图像的展开结果。经上述全景展开算法处理后,图2(b)的展开结果如图4所示。

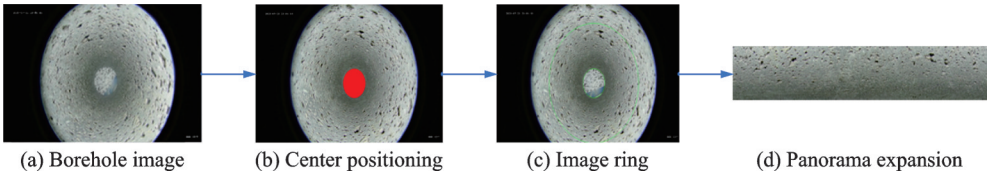


图4 全景展开过程

Fig.4 Panoramic expansion process

### 2.2 改进的EfficientNetV2识别算法

本系统主要用于岩土的原位数据获取和材质智能分类,鉴于工作场景的特殊性,对识别模型的准确率及轻量化等提出了较高要求,通过兼顾上述2项指标的SOTA(State-of-the-art)水平网络分析,本文采用了一种高效的卷积神经网络架构EfficientNet[11],该网络的设计目标是在保持模型准确性的同时,尽可能减少模型的计算量和参数量,非常适用于系统的后续移动式和嵌入式开发。而EfficientNetV2[12]作为EfficientNet的改进版本,通过引入融合移动倒置瓶颈卷积结构(Fused moblile inverterd bottleneck convolution,Fused-MBConv)模块和渐进式学习策略进一步改进模型性能,在收敛速度与精度上都有较大的提升[13-14]。EfficientNetV2通过配置参数可分为EfficientNetV2-S、EfficientNetV2-M和EfficientNetV2-L三个版本。考虑到模型性能与复杂度的均衡,以及未来部署嵌入式系统的规划,本文选取EfficientNetV2-S(EV2-S)作为识别模型开展相关应用研究。EV2-S通过堆叠Fused-MBConv模块和移动倒置瓶颈卷积(Moblile inverterd bottleneck convolution, MBConv)模块来构建,两者的结构图如图5所示,EV2-S结构如表1所示。图中,Project Conv 3×3通常指一个用于降维或调整通道数的3×

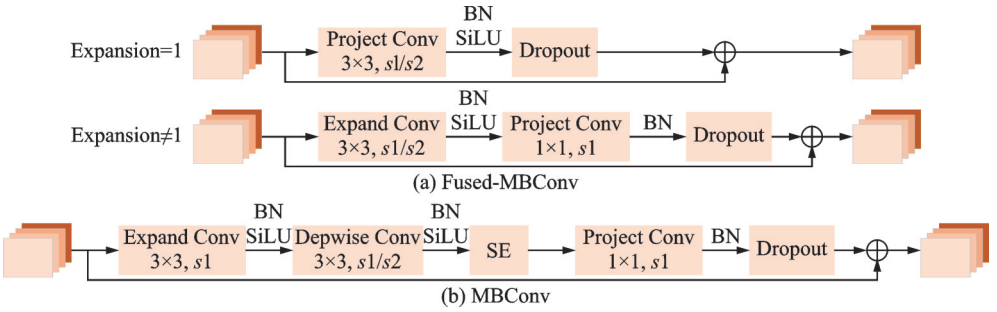


图5 Fused-MBConv和MBConv网络结构

Fig.5 Structures of Fused-MBConv and MBConv networks

**表1 EV2-S网络结构表**

**Table 1 Structure of EV2-S network**

| Stage | Operator | Stride | Channel | Layer |
|---|---|---|---|---|
| 0 | Conv 3×3 | 2 | 24 | 1 |
| 1 | Fuse-MBConv 1, $k$3×3 | 1 | 24 | 2 |
| 2 | Fuse-MBConv 4, $k$3×3 | 2 | 48 | 4 |
| 3 | Fuse-MBConv 4, $k$3×3 | 2 | 64 | 4 |
| 4 | MBConv 4, $k$3×3, SE0.25 | 2 | 128 | 6 |
| 5 | MBConv 6, $k$3×3, SE0.25 | 1 | 160 | 9 |
| 6 | MBConv 6, $k$3×3, SE0.25 | 2 | 256 | 15 |
| 7 | Conv 1×1&Pooling&FC | — | 1 280 | 1 |

3卷积层，$s1$/$s2$表示该卷积的步长(stride)。其中，$s1$表示stride=1，保持输入的空间尺寸不变；$s2$表示stride=2，对输入进行下采样，长宽减半。

尽管EV2-S网络中的Squeeze-and-Excitation注意力机制通过学习通道权重来增强模型对有用通道信息的关注，但它仅仅考虑了通道维度的注意力，无法捕捉空间维度的注意力，对于复杂的岩层钻孔图像存在一定局限性。为解决上述问题，本文提出了动态多尺度EfficientNetV2模型(Dynamic multi-scale EfficientNetV2, DM-E2Net)。该模型在EV2-S基础上，结合Efficient multi-scale attention (EMA)[15]与Omni-dimensional dynamic convolution (ODC)[16]进行构建，可以增强网络特征提取能力与特征适应性。

EMA和ODC的网络结构图分别如图6和图7所示。图6中，$C$、$H$、$W$分别表示通道数、高度和宽度，输入特征按通道分成$G$组，每组通道数为$C//G$，其中// 表示整除，向下取整。图7中，$x$和$y$分别表示输入和输出特征向量；GAP表示全局平均池

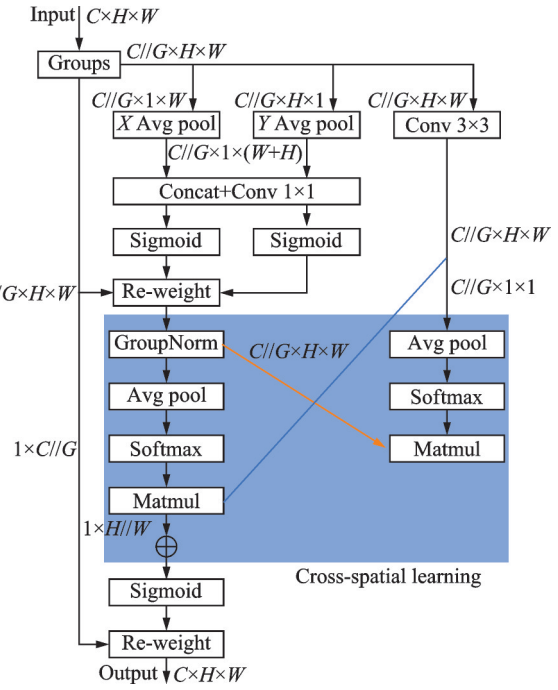


图6 EMA网络结构

Fig.6 Structure of EMA network

化;FC表示全连接层;$w_i$表示第$i$个卷积核,$a_{si}$、$a_{ci}$、$a_{fi}$和$a_{wi}$分别表示位置注意力、输入通道注意力、输出通道注意力和整体卷积核注意力,$i=1,2,\cdots,n$;ReLU为激活函数。EMA的特点在于将部分通道重新塑造为批处理维度,并将通道维度分解为多个子特征,以实现空间语义特征在每个特征组内的均匀分布。EMA不仅编码全局信息以重新校准每个并行分支中的通道权重,还通过跨维度交互进一步聚合两个并行分支的输出特征,从而捕获特征点的像素级成对关系。ODC模块采用了并行结构的部署方式,旨在不损失特征信息的情况下,更好地捕捉多尺度信息,加强对输入数据的感知。

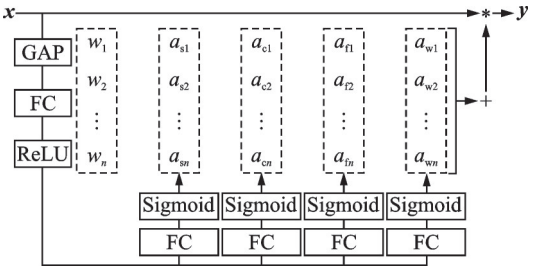


图7 ODC网络结构

Fig.7 Structure of ODC network

图8展示了改进的Fused-MBConv结构,即动态多尺度Fused-MBConv(Dynamic multi-scale fused-MBConv, DM-Fused-MBConv)。在初始网络的Fused-MBConv模块内,当Expansion=1时,以并行的方式引入ODC结构;在Explansion≠1时,引入了EMA注意力。在此基础上,使用DM-Fused-MBConv模块取代EV2-S中的Fused-MBConv模块,构建了基于ODC和EMA的EV2-S,即DM-E2Net,其整体结构如表2所示。

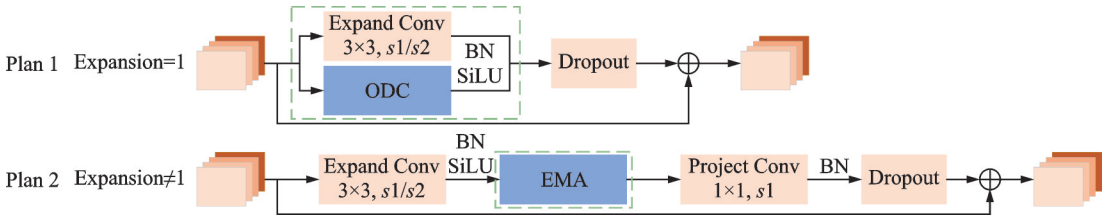


图8 DM-Fused-MBConv网络结构

Fig.8 Structure of DM-Fused-MBConv network

**表2 DM-E2Net网络结构表**

**Table 2 Structure of DM-E2Net network**

| Stage | Operator | Stride | Channel | Layer |
|---|---|---|---|---|
| 0 | Conv 3×3 | 2 | 24 | 1 |
| 1 | DM-Fused-MBConv 1,$k$3×3 | 1 | 24 | 2 |
| 2 | DM-Fused-MBConv 4,$k$3×3 | 2 | 48 | 4 |
| 3 | DM-Fused-MBConv 4,$k$3×3 | 2 | 64 | 4 |
| 4 | MBConv 4,$k$3×3,SE0.25 | 2 | 128 | 6 |
| 5 | MBConv 6,$k$3×3,SE0.25 | 1 | 160 | 9 |
| 6 | MBConv 6,$k$3×3,SE0.25 | 2 | 256 | 15 |
| 7 | Conv 1×1,Pooling&FC | — | 1 280 | 1 |

## 3 实验和结果分析

### 3.1 实 验

#### 3.1.1 数据集

由于智能识别需要大量数据集和确定的目标,本文通过采集8种实物岩石剖面图的方式制作了训练集与验证集,进行网络性能优化。8类岩石分别为砾岩、榴辉岩、砂岩、闪长玢岩、气孔状玄武岩、大理

岩、花岗岩和板岩,对应的剖面图如图9所示。设备采集到的钻孔图像经过全景展开后作为测试集,用于钻孔图像识别测试。部分实物岩石全景展开图像如图10所示。

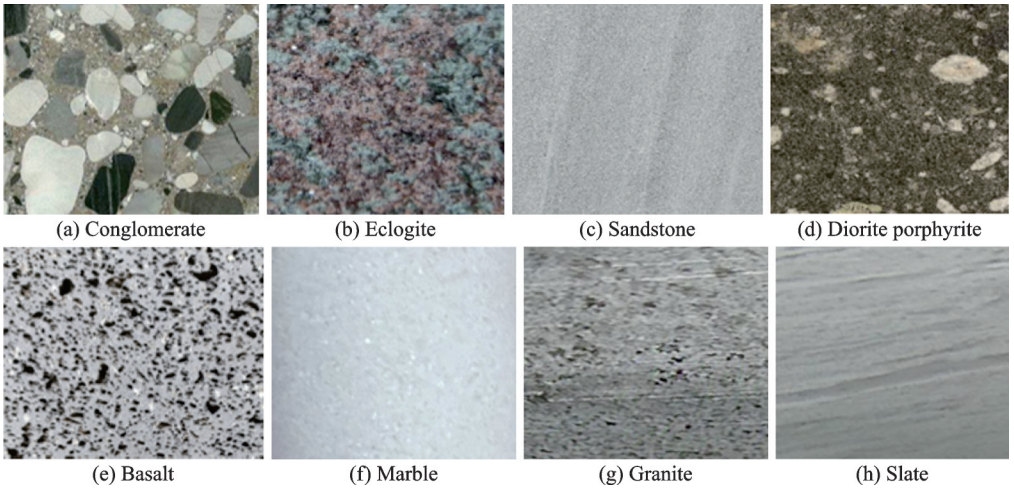


图9 训练集与验证集部分样本

Fig.9 Partial samples for training and validation sets

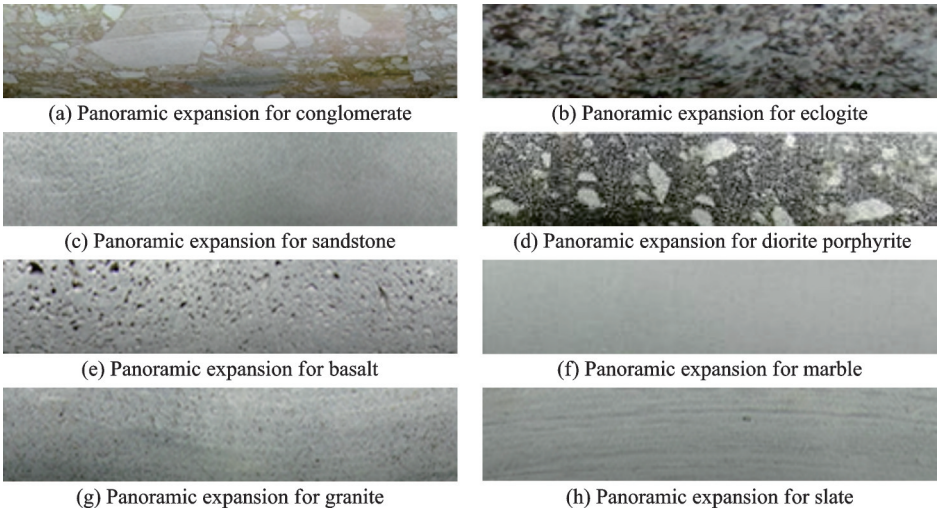


图10 部分全景展开图像

Fig.10 Part of panoramic expansion images

为了提高模型的鲁棒性,缓解训练过拟合的问题,本文对采集的图像进行数据集增强。考虑到岩层特征的特殊性,训练集使用旋转、翻转、色度色调变化和中心裁剪等进行数据增强,验证集仅使用旋转与翻转进行数据增强,8种岩石的实物图片的训练集、验证集和测试集的数量如表3所示。

**表3 数据集分布**

**Table 3 Distribution of datasets**

| 种类 | 砾岩 | 榴辉岩 | 砂岩 | 闪长玢岩 | 玄武岩 | 大理岩 | 花岗岩 | 板岩 | 总计 | 数据增强后 |
|---|---|---|---|---|---|---|---|---|---|---|
| 训练集 | 232 | 92 | 232 | 114 | 170 | 213 | 219 | 193 | 1 465(70%) | 9 925 |
| 验证集 | 102 | 39 | 74 | 50 | 74 | 92 | 95 | 84 | 610 (30%) | 3 660 |
| 测试集 | 21 | 11 | 22 | 13 | 20 | 16 | 24 | 14 | 141 | 141 |

### 3.1.2 迁移学习与数据增强实验

迁移学习[17]是深度学习中一种常见的策略,即提取训练好的模型权重(预训练模型)迁移到其他神经网络中做微调,从而达到加快模型训练速度或取得更好训练效果的目的。本文通过一系列实验,验证了验证集上迁移学习与数据增强的作用。在120轮训练中,不同训练方法的验证集最高准确率如表4所示。为了便于分析,加载官方提供的预训练权重(https://github.com/google/automl/tree/master/efficientnetv2),并应用到本文数据集进行迁移学习,实验方法命名为EV2-S+pre;数据增强后的方法命名为EV2-S+data;预训练权重与增强同时使用命名为EV2-S+data+pre;冻结除全连接层以外的层的方法命名为EV2-S+data+pre+frz。实验结果表明:数据增强和使用预训练权重都有益于本文模型精度的提升;只训练全连接层,其训练速度有大幅度提升,但准确率提升相对较小。

**表4 不同训练方法的准确率对比**

**Table 4 Comparison of accuracy among different training methods**

| 训练方法 | 批次大小 | 学习率 | 输入尺寸/(像素×像素) | 最高准确率/% |
|---|---|---|---|---|
| EV2-S | 8 | 0.001 | 384×384 | 61.80 |
| EV2-S+data | 8 | 0.001 | 384×384 | 82.05 |
| EV2-S+pre | 8 | 0.001 | 384×384 | 84.10 |
| EV2-S+data+pre | **8** | **0.001** | **384×384** | **91.09** |
| EV2-S+data+pre+frz | 8 | 0.001 | 384×384 | 78.61 |

### 3.1.3 消融实验

改进模块的消融实验在最优训练方法(EV2-S+data+pre)基础上进行,为了便于记录,本文提出的DM-E2Net改进点划分为2个方案,分别命名为Plan 1和Plan 2。Plan 1是在Fused-MBconv模块中以并行方式加入ODC动态卷积模块;Plan 2是在Fused-MBconv中加入EMA模块结构。不同模型实验结果如表5所示。DM-E2Net与EV2-S的准确率与损失值对比曲线如图11所示。

**表5 实验性能对比**

**Table 5 Comparison of experimental performance**

| 模型 | 批次大小 | 学习率 | 浮点运算量/$10^9$ | 模型参数量/$10^6$ | 最高准确率/% |
|---|---|---|---|---|---|
| EV2-S | 8 | 0.001 | 68.07 | 21.46 | 91.09 |
| EV2-S+Plan 1 | 8 | 0.001 | 61.08 | 21.46 | 92.43 |
| EV2-S +Plan 2 | 8 | 0.001 | 83.17 | 21.51 | 91.86 |
| EV2-S+Plan 1+Plan 2(DM-E2Net) | **8** | **0.001** | **83.18** | **21.51** | **92.65** |

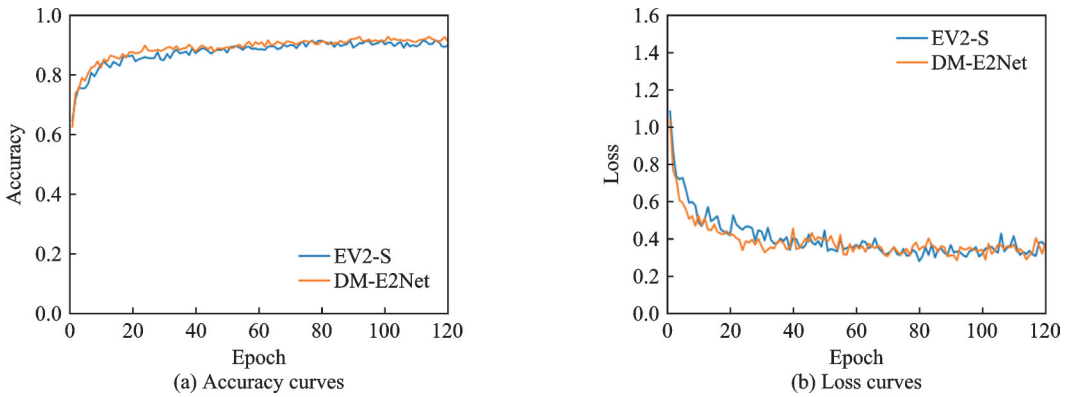


图11 EV2-S与DM-E2Net的性能对比

Fig.11 Performance comparison between EV2-S and DM-E2Net

实验结果表明，在验证集上，当Plan 1、Plan 2分别应用于网络中时，每个方案都实现了准确率的提升；Plan 1和Plan 2相结合的方案，即DM-E2Net，在参数量仅仅增长$0.05\times10^6$的情况下，准确率提升了1.56%，取得了较好的性能表现，这验证了本文改进方案的有效性，即通过加强网络的多尺度特征提取能力与特征适应性能有效提升了网络的识别性能。

图12展示了EV2-S网络与DM-E2Net在验证集上生成的混淆矩阵。分析图12，改进后的网络对岩石钻孔图像的识别更加准确。但无论是改进前还是改进后，网络对板岩与砂岩、砾岩与闪长玢岩的识别都容易产生混淆，这可能是因为部分图像存在一些特征相似的关系，比如砾岩与闪长玢岩具有相似的颗粒状或块状结构；此外，采集数据集的规模不够大、特征不够丰富也是原因之一。

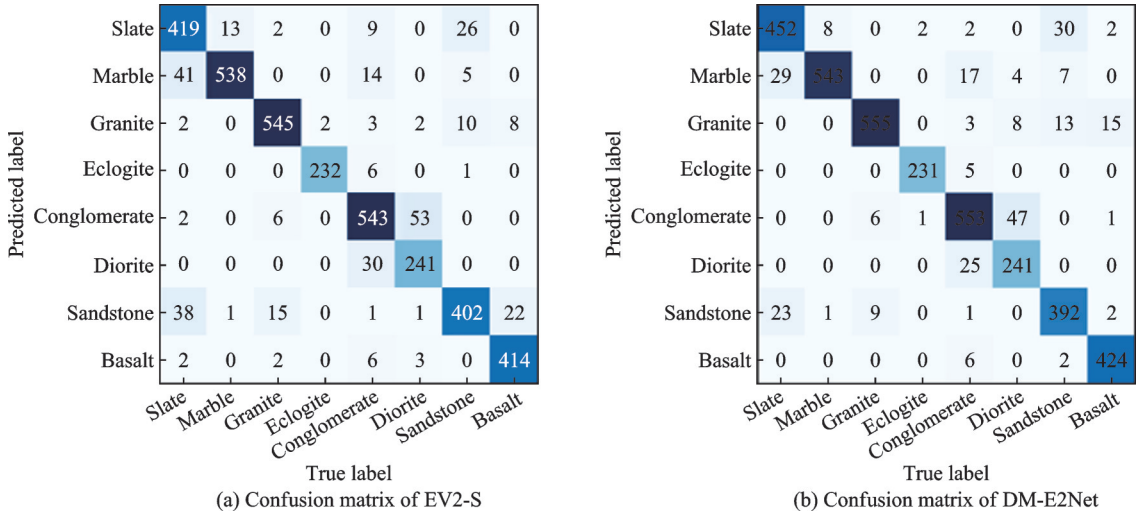


图12 混淆矩阵对比

Fig.12 Comparison of confusion matrix

### 3.1.4 对比实验

基于深度学习的智能分类任务中，评价的指标主要有最高准确率、精确率、召回率和$F_1$值[18]。鉴于本文的系统优先考虑样本是否识别正确，因此重点分析了模型的准确率与精确率。

表6展示了不同网络的训练结果，包括Regnet-3.2gf[19]、Convnext-t[20]、Repvgg-b1[21]，以及其他作者对EfficientNetV2提出的类似方法（在Plan 2方案下，将EMA attention分别替换成Triple attention与ECA attention）[22-23]。对比实验表明：在几种基础网络中，EV2-S表现最佳；DM-E2Net在所有对比网络

**表6 不同模型的训练结果**

**Table 6 Training results of different models** %

| 模型 | 最高准确率 | 精确率 | 召回率 | $F_1$ |
|---|---|---|---|---|
| Regnet-3.2gf[19] | 89.26 | 89.57 | 89.82 | 89.69 |
| Convnext-t[20] | 90.77 | 90.92 | 90.77 | 90.84 |
| Repvgg-b1[21] | 90.52 | 90.87 | 90.23 | 90.54 |
| EV2-S[12] | 91.09 | 91.39 | 91.02 | 91.20 |
| EV2-S-Tripleattention[22] | 91.15 | 91.61 | 90.88 | 91.24 |
| EV2-S-ECAattention[23] | 90.22 | 90.59 | 90.25 | 90.41 |
| EV2-S-EMAattention(Plan 2) | 91.86 | 91.80 | 91.99 | 91.89 |
| DM-E2Net | **92.65** | **93.02** | **92.32** | **92.67** |

中处于领先地位。此外,在Plan 2的方案下,相较于Triple attention与ECA attention,本文融合的EMA attention对网络性能的提升更显著。在验证集中,对比改进前的EV2-S网络,DM-E2Net在参数量仅增长$0.05\times10^6$的情况下,网络的整体准确率与平均精确率达到了92.65%和93.02%,分别提升了1.56%和1.63%。

### 3.2 结果分析

上述实验证明了本文提出的DM-E2Net网络的优势。在网络训练阶段为了更好地提取岩层特征,本文训练时输入的图片分辨率调整采用了滑动窗口的预测方法。由设备采集的原始图像如图13(a)所示,其分辨率远大于网络训练的分辨率,直接压缩会使得岩层特征变形,如图13(b)所示。相比直接分辨压缩,图像滑动窗口的预测方法不仅规避了该缺陷,还可得到单张图像不同位置的多个预测结果,如图13(c)所示。最终取预测结果的众值作为实际输入单张图像的最终预测结果,概率为属于最终类别的各个窗口概率的平均值。滑动窗口预测具体流程如图14所示,这种预测方法不仅适配于基于深度学习的大尺寸图像识别,而且能在很大程度上规避实际勘探中由于单张图片中存在不同岩层而影响预测结果的情况。

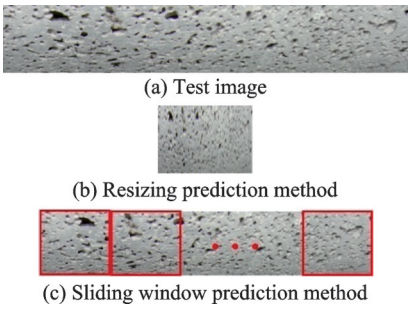


图13 两种预测方式对比

Fig.13 Comparison of two predicting methods

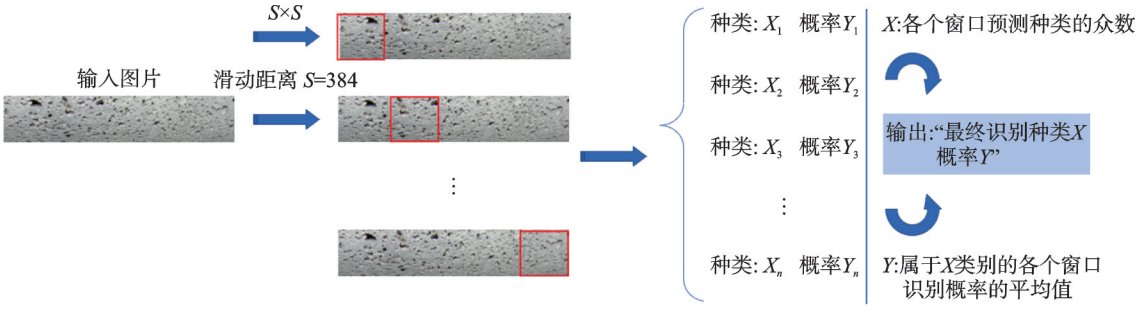


图14 滑动窗口预测示意图

Fig.14 Schematic diagram of sliding window prediction

表7呈现了基于滑动窗口预测的测试结果。在141张测试图片中,成功识别了129张,样本识别成功率达到91.49%。虽然实验结果整体表现较为理想,但仍存在一些误识别情况。具体而言,有2张榴辉岩的图片被错误地识别为砾岩,6张闪长玢岩的图片被误判为砾岩,板岩中的2张图片被识别为砂岩,另外1张被错误地分类为大理岩。这些误差的产生可以归于以下原因:(1)数据集中各类别图片数量不均,模型过于拟合了砾岩的特征;(2)在本文的数据集中,几类图像在客观上存在特征重叠,例如,闪长玢岩、榴辉岩、砾岩这3种岩层的颗粒感非常相似;(3)数据集特征不够丰富,规模不够大也占一部分原因。以上结果与验证集的混淆矩阵分布规律保持一致,也验证了本文使用的迁移学习方法的合理性。

**表7 基于滑动窗口预测的测试结果**

**Table 7 Test results based on sliding window prediction**

| 测试集 | 砾岩 | 榴辉岩 | 砂岩 | 闪长玢岩 | 玄武岩 | 大理岩 | 花岗岩 | 板岩 |
|---|---|---|---|---|---|---|---|---|
| 样本总数 | 21 | 11 | 22 | 13 | 20 | 16 | 24 | 14 |
| 识别成功数量 | 21 | 9 | 20 | 7 | 20 | 16 | 24 | 12 |

## 4 结束语

本文通过对长孔道待检目标特点的分析,设计并实现了一套双摄像的岩土钻孔全景摄像系统。对于系统的智能分析功能,主要通过EV2-S网络的改进和滑动窗口预测,实现了8类岩石钻孔图像的智能识别,在测试集上的识别成功率达到91.49%,基本具备了岩土钻孔状态的综合智能化评估能力。未来研究可通过岩石数据集的扩充解决当前数据规模不平衡、训练不良拟合等问题,进而进一步提高系统的识别率和鲁棒性。

**参考文献:**


[1] MA J, HE S, CUI G, et al. Construction stability and reinforcement technology for the super-large rectangular pipe-jacking tunnel passing beneath the operational high-speed railway in composite stratum[J]. Geomatics, Natural Hazards and Risk, 2023, 14(1): 2208720.

[2] WEI M, ZHANG N, TONG Y, et al. Research on the advanced prediction model of the tunnel geological radar based on cluster computing[J]. Intelligent Automation & Soft Computing, 2020, 26(3): 597-607.

[3] CHEN W, ZHANG G H, WANG H, et al. Evaluation of possibility of tunnel collapse by drilling and blasting method based on T-S fuzzy fault tree[J]. Rock and Soil Mechanics, 2019, 40: 319-328.

[4] ABBAS A A S, ABOU-EL-HOSSEIN K. Investigation of drill bit temperature during automatic bone drilling[J]. International Journal of Engineering Materials and Manufacture, 2018, 3(4): 245-250.

[5] WANG C, ZOU X, HAN Z, et al. An automatic recognition and parameter extraction method for structural planes in borehole image[J]. Journal of Applied Geophysics, 2016, 135: 135-143.

[6] LI L, YU C, HAN Z, et al. Automatic identification of the rock-soil interface and solution fissures from optical borehole images based on color features[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(10): 3862-3873.

[7] ZOU X, WANG C, WANG Y, et al. Morphological feature description method of structural surface in borehole image during in situ instrumentation[J]. Rock Mechanics and Rock Engineering, 2020, 53(7): 2947-2956.

[8] WANG J C, WANG C Y. Analysis and evaluation of coral reef integrity based on borehole camera technology[J]. Marine Georesources & Geotechnology, 2017, 35(1): 26-33.

[9] DENG Z, CAO M, GENG Y, et al. Generating a cylindrical panorama from a forward-looking borehole video for borehole condition analysis[J]. Applied Sciences, 2019, 9(16): 3437.

[10] 王启超, 张维光, 任永平. 基于全景相机的3D坐标测量方法[J]. 电子测量技术, 2017, 40(12): 203-208.
WANG Qichao, ZHANG Weiguang, REN Yongping. 3D coordinate measurement method based on panoramic camera[J]. Electronic Measurement Technology, 2017, 40(12): 203-208.

[11] TAN M, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[EB/OL]. (2019-05-19). https://arxiv.org/abs/1905.11946v5.

[12] TAN M X, LE Q. EfficientNetV2: Smaller models and faster training[C]//Proceedings of 2021 IEEE International Conference on Machine Learning(ICML). [S.l.]: IEEE, 2021: 10096-10106.

[13] SUNIL C K, JAIDHAR C D, NAGAMMA P. Cardamom plant disease detection approach using EfficientNetV2[J]. IEEE Access, 2021, 10: 789-804.

[14] LIU D, WANG W, WU X, et al. EfficientNetV2 model for breast cancer histopathological image classification[C]//Proceedings of 2022 3rd International Conference on Electronic Communication and Artificial Intelligence (IWECAI). Zhuhai, China: IEEE, 2022: 384-387.

[15] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]//Proceedings of 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, Greece: IEEE, 2023: 1-5.

[16] TAN H, DONG S. Pixel-level concrete crack segmentation using pyramidal residual network with omni-dimensional dynamic

convolution[J]. Processes, 2023, 11(2): 546.

[17] 张燕婷, 马想, 黄跃, 等. 基于迁移学习的Vision Transformer网络对伽马射线暂现源分类[J]. 中国科学: 物理学 力学 天文学, 2024, 54(8): 104-114.
ZHANG Yanting, MA Xiang, HUANG Yue, et al. Classification of gamma-ray transients using vision Transformer network based on transfer learning[J]. Scientia Sinica (Physica, Mechanica & Astronomica), 2024, 54(8): 104-114.

[18] 徐晴, 葛成, 蔡标, 等. 基于深度学习的癫痫脑电信号分类[J]. 数据采集与处理, 2022, 37(4): 787-797.
XU Qing, GE Cheng, CAI Biao, et al. EEG signal classification of epilepsy based on deep learning[J]. Journal of Data Acquisition and Processing, 2022, 37(4): 787-797.

[19] RADOSAVOVIC I, KOSARAJU R P, GIRSHICK R, et al. Designing network design spaces[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 10425-10433.

[20] LIU Z, MAO H, WU C Y, et al. A ConvNet for the 2020s[C]//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, USA: IEEE, 2022: 11966-11976.

[21] DING X, ZHANG X, MA N, et al. RepVGG: Making VGG-style ConvNets great again[C]//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA: IEEE, 2021: 13728-13737.

[22] HUANG Z, SU L, WU J, et al. Rock image classification based on EfficientNet and triplet attention mechanism[J]. Applied Sciences, 2023, 13(5): 3180.

[23] KARTHIK R, VAICHOLE T S, KULKARNI S K, et al. Eff2Net: An efficient channel attention-based convolutional neural network for skin disease classification[J]. Biomedical Signal Processing and Control, 2022, 73: 103406.

**作者简介:**

**先永利**(1986-),女,博士,副教授,硕士生导师,研究方向:数字图像处理、机器视觉、生物医学光学,E-mail:xyl123@mail.ustc.edu.cn。

**陈学健**(1996-),男,硕士研究生,研究方向:数字图像处理、机器视觉。

**彭真明**(1966-),**通信作者**,男,教授,博士生导师,研究方向:图像处理与机器视觉应用、复杂场景视觉检测与识别等,E-mail:zmpeng@uestc.edu.cn。

**汪杰**(1999-),男,工程师,研究方向:机器视觉、智能识别。

**彭波**(1988-),男,博士,讲师,研究方向:智能识别。

(编辑:张黄群)