

基于 Vision Transformer 模型的隧道围岩实时识别系统研究

熊涛, 于洋, 朱碧堂, 刘强, 曾建军, 吴荆凯

(华东交通大学土木建筑学院, 江西 南昌 330013)

摘要: 针对传统隧道围岩分级依赖人工经验、主观性强且效率低下的问题, 本研究创新引入 Vision Transformer 模型, 构建“采集-处理-评价”全流程围岩实时识别系统, 突破传统卷积神经网络局部感受野局限, 实现全局地质特征的高效捕捉。系统包含数字图像采集终端、智能分级处理模块与智慧化评价模块, 依托 2 621 张多地质条件掌子面图像构建数据集, 经 100 个 epochs 训练后识别准确率达 92.49%, 优于 EfficientNet 和 ResNet34 模型。通过轻量化移动端 App, 可快速完成图像采集、智能分级及施工方法推送。经晓沅隧道工程验证, 系统与传统 BQ 分级法结果吻合度超 90%, 所推送的施工方法及爆破参数能降低超欠挖偏差、减少围岩扰动, 为隧道智能化施工提供了创新且可靠的技术方案。

关键词: 围岩实时识别; 围岩分级; Vision Transformer; 移动端应用; 深度学习; 智能化施工

中图分类号: U451.2

文献标志码: A

Research on real-time identification system of surrounding rock of tunnel based on Vision Transformer model

Tao XIONG, Yang YU, Bitang ZHU, Qiang LIU, Jianjun ZENG, Jingkai WU

(School of Civil Engineering and Architecture, East China Jiaotong University, Nanchang 330013, Jiangxi, China)

Abstract: To address the issues of traditional tunnel surrounding rock classification, such as over-reliance on manual experience, strong subjectivity, and low efficiency, this study innovatively introduces the Vision Transformer model and constructs a full-process real-time surrounding rock identification system with the workflow of "acquisition-processing-evaluation". Breaking through the limitation of the local receptive field of traditional convolutional neural networks, the system achieves efficient capture of global geological features. It comprises three components: a digital image acquisition terminal, an intelligent classification processing module, and an intelligent evaluation module. Based on a dataset of 2,621 tunnel face images covering multiple geological conditions, the model reaches a recognition accuracy of 92.49% after 100 training epochs, outperforming the EfficientNet and ResNet34 models. Through a lightweight mobile App, rapid image acquisition, intelligent classification, and real-time recommendation of construction methods can be realized. Verified in the Xiaoyuan Tunnel project, the system shows a consistency of over 90% with the results of the traditional BQ classification method. The recommended construction methods and blasting parameters effectively reduce over-excavation and under-excavation deviations as well as surrounding rock disturbance, providing an innovative and reliable technical solution for intelligent tunnel construction.

Keywords: real-time surrounding rock identification; surrounding rock classification; vision transformer; mobile application; deep learning; intelligent construction

在隧道工程建设中, 围岩状况的准确识别, 直接关系到施工安全、成本控制与整体工程质量的保障, 具有决定性意义^[1], 尤其随着我国基础设施建设的快速推进, 隧道工程规模与数量持续增长, 围岩稳定性的实时、科学判识已成为关键课题。在实际施工过程中, 工程人员常面临高地应力、软岩大变形、高压富水、岩体结构突变等复杂地质条件, 这些实时变化的不确定性因素对围岩状态的及时识别提出了严峻挑战。然而, 传统围岩质量分级方法主要依赖工程师的现场经验与人工判断^{[2]-[4]}, 存在主观性强、不确定性大等局限, 在面临复杂多变地质工况时, 往往存在识别滞后、定量依据不足等问题, 导致施工与支护设计方案难以精准匹配实际围岩条件, 易引发支护时机不当、参数选择失准等决策偏差, 进而诱发塌方、突水突泥等灾害^{[5]-[6]}。因此, 如何突破传统方法的局限, 已成为当前隧道工程安全推进中亟待解决的关键问题。

目前, 围岩识别领域的研究取得了一定进展。地质雷达、地震波等地球物理技术因其能够探测岩体内

部结构而被广泛应用于围岩分级中,周东等^[8]采用探地雷达属性分析技术对隧道内溶洞进行三维可视化研究,实现了溶洞规模、形状和位置的精准识别;徐昆杰等^[9]该研究提出了一种基于钻进参数与 TSP 地震波数据融合的围岩智能判识方法,有效提高了围岩分级的准确率;郑继东等^[10]运用 TSP 地震探测系统对大瑞铁路高黎贡山隧道围岩进行分类,准确预测了富水段和节理裂隙发育段。这些物理探测方法往往被结合使用,以相互验证与补充。三维地震波超前探测和地震层析成像技术的发展,进一步实现了围岩结构的三维可视化,为评估隧道整体稳定性及岩体质量提供了更丰富的信息^{[11]-[14]}。

随着计算机视觉和人工智能技术的发展,基于机器视觉和深度学习的围岩识别方法成为研究热点。黄宏伟等^[15]采用 DeepLab V3+等算法对岩体结构特征进行语义分割,将图像信息转化为几何参数,提升了岩体特征提取的自动化水平;柳厚祥等^[16]利用 AlexNet 模型对隧道掌子面照片进行分析,并结合 Matlab 图像识别技术分析岩体节理,判定围岩质量。此外,ResNet18、DenseNet 等其他卷积神经网络(CNN)模型在围岩节理裂隙、风化程度等特征识别上也取得了显著效果^{[17]-[21]}。实践表明,基于人工智能深度学习对图片处理并提取围岩判定指标的方法是可行且高效的。近年来 Vision Transformer 模型在计算机视觉领域实现突破性进展,已逐步应用于岩土工程领域^{[22][24]}。其凭借自注意力机制对全局上下文信息的高效捕获能力,有效弥补了传统 CNN 模型处理大范围地质特征时的固有局限,但其在隧道掌子面围岩实时识别方面的研究较少,且现有系统在完成目标识别后,难以基于现场动态条件实时生成并推荐优化的施工方法,制约施工效率。

本研究引入 Vision Transformer 模型,用于隧道掌子面围岩等级的智能识别,构建“采集-处理-评价”全流程架构,通过自主研发的轻量化移动端 App,实现了围岩图像的快速识别与施工方法的即时推送,形成了从智能感知到决策支持的完整闭环,为隧道智能化施工提供了创新性的实用解决方案。

1 智能分级系统结构与原理

1.1 系统整体框架

相较于传统孤立处理图像的系统,围岩智能分级系统整体上分为数字图像采集终端、围岩智能分级处理模块和围岩智慧化评价模块三个部分,这三个部分相互配合,形成一个完整的工作流程,实现从图像采集到最终围岩评价结果输出的全过程,系统技术框架如图 1 所示。数字图像采集终端是系统获取原始数据的前端部分,主要借手机、平板电脑和监控摄像头等常见的视频图像采集设备来完成。其核心功能就是采集隧道掌子面的图像,这些图像是后续进行围岩分级的基础。采集图像之后,终端将图像信息上传至服务器,为后续处理环节提供数据支持。

围岩智能分级处理模块是系统核心处理部分,部署在服务器端。其接收从数字图像采集终端上传的掌子面图像,并利用训练好的深度学习模型对图像进行处理。该模型能够对图像中的围岩特征进行识别和分析,进而完成对围岩的智能分级,确定围岩等级。该模块是实现智能化分级的关键,其处理结果直接关系到后续评价的准确性。

围岩智慧化评价模块则是在围岩智能分级处理模块得出的分级结果基础上进行工作。围岩智慧化评价模块结合现场的地质雷达数据、声波探测数据等其他相关数据,对掌子面前方的围岩等级进行快速、全面的智慧化评价。通过综合多方面的数据,该模块能够更准确、更全面地反映围岩的实际情况,为隧道施工方案提供更可靠的参考依据。

在数据交互流程方面,由数字图像采集终端采集掌子面图像,之后将图像信息上传到服务器,服务器中的围岩智能分级处理模块接收图像并利用深度学习模型进行处理,得到围岩分级结果;围岩智慧化评价模块获取该分级结果,并结合现场其他探测数据进行综合评价,最终形成对掌子面前方围岩等级的全面判断。这三个模块紧密协作,确保整个系统能够高效、准确地完成围岩分级与评价工作。



图 1 围岩智能分级系统技术框架

Fig 1 Technical framework of the intelligent classification system for surrounding rock

1.2 Vision Transformer 模型结构

Vision Transformer 模型在本研究中作为核心算法创新，其优势源于对传统卷积神经网络（CNN）固有局限的突破。传统 CNN 模型依赖于局部感受野的层级堆叠来提取特征，虽善于捕捉局部纹理、颜色等表象信息，但在处理隧道掌子面图像时，难以有效建模大范围节理组空间关系、优势结构面走向等依赖全局上下文信息的地质特征。Vision Transformer 模型通过将图像分割为块序列并引入自注意力机制，其克服了传统 CNN 依赖局部滑动窗口提取特征的约束，通过将图像转化为序列数据并引入自注意力机制^[25]，实现了对隧道掌子面全局特征的高效捕捉。该模型的整体架构遵循 Transformer 编码器的经典设计，主要由输入嵌入层、Transformer 编码器堆叠模块及分类头三部分构成如图 2 所示，各组件协同完成从图像输入到围岩等级输出的全过程。

1.2.1 输入处理与嵌入层

输入嵌入层的核心功能是将二维的掌子面图像转化为适合 Transformer 处理的一维序列向量。该模型首先对输入的 RGB 格式图像进行分块处理，按照 16×16 的固定尺寸将图像分割为 196 个互不重叠的图像块。每个图像块包含 768 个像素值，通过线性投影操作转化为 768 维的特征向量。为保留图像的空间位置信息，模型引入可学习的位置编码。位置编码与图像块向量维度一致，通过与图像块向量逐元素相加，使模型能够感知各图像块在原始图像中的相对位置。此外，模型额外引入一个可学习的分类标记，其维度同样为 768 维，与 196 个图像块向量拼接后形成长度为 197 的序列，作为 Transformer 编码器的输入。此设计借鉴了 BERT 模型的分​​类思路，最终的围岩等级分类结果将基于该分类标记的输出特征确定。

1.2.2 Transformer 编码器模块及分类头

Transformer 编码器模块是 Vision Transformer 模型的核心部分，由 12 个相同的编码器块堆叠而成。每个编码器块包含层归一化、多头注意力机制、残差连接以及前馈神经网络等组件。层归一化用于对输入向量进行标准化处理，使数据分布更加稳定，便于模型的训练和计算。多头注意力机制是该模块的关键，它能够让模型从多个不同角度关注输入数据的不同部分，以确保捕捉到更丰富的特征信息。在处理围岩图像时，可同时关注围岩的纹理细节、节理走向、颜色特征等多方面信息，提升对复杂图像特征的提取能力。多头注意力被分为 12 个头，每个头独立计算注意力，并将结果拼接，从多个角度捕捉特征。注意力计算之后通过残差连接与输入向量相加，再进行一次层归一化，随后进入前馈神经网络。前馈神经网络包含两个线性层，中间采用 GELU 激活函数。第一个线性层将向量维度扩展至 3 072，第二个线性层再将其缩回到 768 维。此设计增强了模型的非线性表达能力，有助于区分围岩的细微差异。同时，模型中引入了 Dropout 和 DropPath 技术，在训练过程中随机丢弃部分神经元，防止模型过度拟合训练数据，提高模型对不同隧道图像的泛化能力。

经过 Transformer 编码器处理后，分类标记向量被送入分类头。分类头由一个线性层构成，将 768 维

的向量映射到多个输出维度，输出结果经 Softmax 函数转换为概率分布，概率最高的类别即为围岩等级的识别结果。

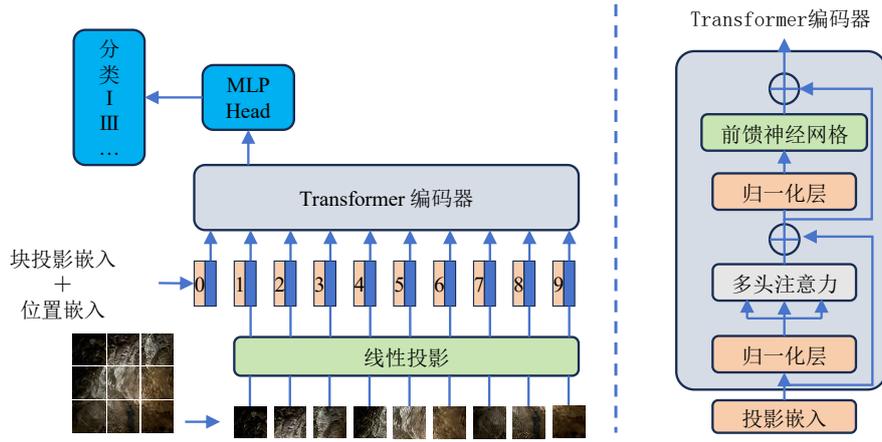


图 2 Vision Transformer 模型结构

Fig 2 Model structure of Vision Transformer

2 Vision Transformer 模型训练与评估

2.1 数据集构建

模型训练数据集源于国内 5 个不同地区、4 类典型地质条件下的隧道工程现场采集，涵盖华南花岗岩区、西南喀斯特区、华北砂岩区及西北黄土区，确保数据能够覆盖隧道工程中常见的围岩赋存环境，提升模型对复杂工况的适应性。数据集共包含 2 621 张掌子面图像，具体构成如表 1 所示。

其中，I-V 级围岩图像均来源于实际施工掌子面，每个等级样本数量控制在 413-460 张，样本占比介于 15.8%-17.6% 之间，避免单一等级样本过度集中导致的模型偏倚。I 级围岩取自完整坚硬岩体隧道，岩性以新鲜花岗岩、玄武岩为主，无明显节理裂隙；II 级围岩涵盖微风化砂岩、灰岩隧道，岩体较完整，局部存在少量闭合节理；III 级围岩来自中风化花岗岩、片麻岩隧道，岩体呈破碎镶嵌结构，节理中等发育；IV 级围岩包含强风化砂岩、页岩及破碎灰岩隧道，岩体碎裂结构，结构面贯通性强；V 级围岩取自残坡积层、全风化花岗岩及软岩隧道，岩体呈砂土状或散体结构，富水条件下样本占比约 30%。此外，为模拟现场非围岩图像干扰场景，额外纳入 450 张干扰样本，包括施工机械、人员、支护结构等场景图像，提升模型抗干扰能力。

为确保训练集与验证集中各围岩等级、各地质条件的样本占比一致，数据划分采用分层抽样策略，训练集约占总样本量的 90%，验证集约占 10%，具体分配如表 1 所示。通过上述设计，数据集实现了围岩等级的数量均衡，且覆盖了不同地质类型和围岩状态，为验证模型在各类工况下的适用性提供了可靠的数据支撑。

表 1 数据集组成

Tab 1 Composition of the dataset

图片分类	地质条件覆盖	训练集数量/张	验证集数量/张	占比/%
I 级围岩	华南花岗岩区、西南玄武岩区	428	43	16.3
II 级围岩	华北砂岩区、华南灰岩区	413	41	15.8
III 级围岩	华南花岗岩区、西北片麻岩区	460	46	17.6
IV 级围岩	西南喀斯特区、华北页岩区	442	44	16.8
V 级围岩	西北黄土区、西南残坡积层	428	43	16.3
其他	各地区隧道施工场景	450	45	17.2

2.2 训练结果分析

模型训练采用 Adam 优化器,初始学习率设为 0.0001,并应用余弦退火调度策略使其逐步衰减至 0.00001 以下,以确保参数稳定更新。批量大小设置为 32,以在训练效率与计算稳定性之间取得平衡。为抑制过拟合,模型引入了比率为 0.1 的 Dropout 层及系数为 0.00001 的权重衰减。训练目标为最小化交叉熵损失,该损失函数用于衡量模型预测结果与真实围岩等级之间的差异。交叉熵损失广泛应用于多类别分类任务,其内部机制融合了 Softmax 函数与交叉熵计算。在损失计算过程中,先对模型输出的原始 logits 进行 Softmax 归一化,将其转换为类别概率分布,基于该分布与真实标签计算交叉熵损失,以反映模型预测与真实情况之间的差异^[26]。假设有 M 个类别,对于每个样本,交叉熵损失的计算公式如下:

$$L = \frac{1}{N} \sum_i L_i = -\frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_{ic}) \quad (1)$$

表 2 模型对比

Tab 2 Comparison of models

深度学习模型	Vision Transformer	EfficientNet	ResNet34
提出时间	2021	2019	2015
迭代次数	100	100	100
准确率/%	92.49	91.25	90.30
损失/%	23.22	26.1	47.4

其中, M 是类别, i 是第 i 个样本, y_{ic} 是第 i 个样本类别 c 的标签, p_{ic} 是第 i 个样本对应类别 c 的概率。该损失函数的目标是使模型的输出概率分布尽可能接近真实标签的概率分布,最小化模型对真实类别的预测概率与实际标签的差距,以便模型能够更好地进行分类任务。

通过对 Vision Transformer 模型进行 100 个训练周期的结果分析可知,模型在整个训练过程中表现出稳定的学习能力与持续的优化趋势。如图 3 所示,训练损失逐渐下降至 0.2322,同时训练准确率稳步提升至 92.49%,表明模型对图像数据中的关键特征与潜在模式实现了有效捕捉与理解。该结果反映出模型在训练集上未出现过拟合现象,且进一步增加训练轮次有望带来性能提升。据此, Vision Transformer 模型在分类图像方面表现出色,具备进一步提高识别准确性的潜力。

EfficientNet 和 ResNet34 模型对比如表 2 所示,可见 Vision Transformer 模型比 EfficientNet 和 ResNet34 模型准确率有所提升,这可能受益于 Vision Transformer 通过自注意力机制实现了非局部感受野,能够捕获全局信息,适用于一些需要全局上下文的任务;使用了独立的位置编码来处理空间信息,使得模型对输入图像的位置信息更加敏感。

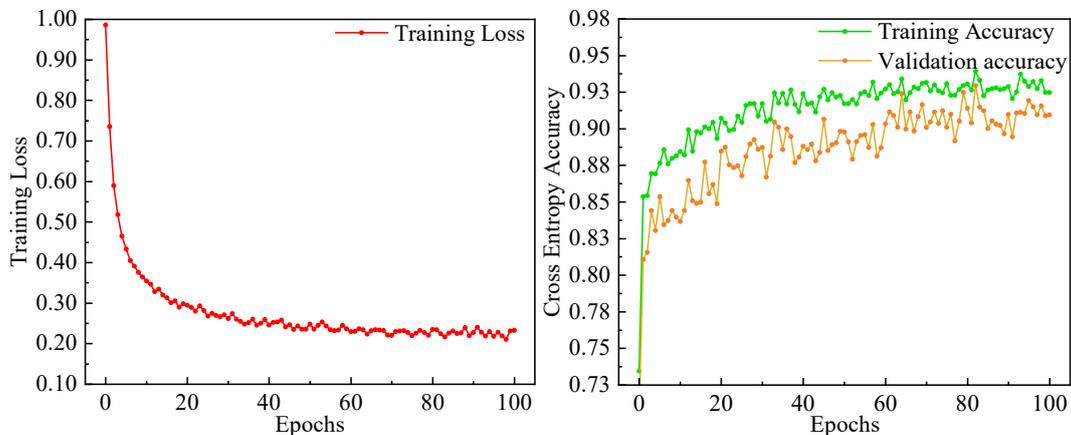


图 3 Vision Transformer 模型训练的损失及准确率

Fig 3 Loss and accuracy of Vision Transformer model training

2.3 未训练数据集应用

模型泛化能力直接决定其工程实用价值，需通过独立未知数据集验证其跨场景适应性。选取通铜高速公路隧道中三个标段的隧道掌子面图像作为测试数据集，包括 T1 南楼岭隧道、T2 坳岭隧道和 T3 杨梅山隧道，每个标段各选取 100 张图像。采用与训练阶段相同的评估指标即准确率，对三种模型在测试集上的表现进行对比分析。结果如表 3 所示，Vision Transformer 模型在 3 个独立测试标段中均表现出最优的泛化性能：T2 标段准确率最高达 92%，T3 标段最低为 89%，平均准确率为 90.7%，相较于训练阶段波动幅度较小。对比其他两种模型，Vision Transformer 模型在三个标段的准确率都高于 EfficientNet、ResNet34 模型；在长度最长、地质条件最复杂的 T3 标段，其准确率仍能达到 89%，显著优于其他两种模型。

表 3 模型在各标段准确率对比

Tab 3 Comparison of Model Accuracy Across Different Segments

深度学习模型	T1 准确率/%	T2 准确率/%	T3 准确率/%	平均准确率/%
Vision Transformer	91	92	89	90.7
EfficientNet	90	88	86	88.0
ResNet34	89	89	84	87.3

3 系统开发与实现

3.1 软件开发流程

为构建完整的围岩智能识别与施工方案推送系统，软件开发涵盖后端开发、前端开发、模型部署与移动应用开发四个主要部分。

后端开发采用 IntelliJ IDEA 与 Maven，通过 Spring Initializr 快速构建项目结构并引入所需依赖。配置 application.properties 设定应用属性后，基于数据库设计编写实体类确立数据模型，再依三层架构实现控制层、业务逻辑层及数据访问层开发。项目经 Maven 打包为 JAR 文件后，部署于配置 Java 环境的服务器，通过远程传输上传 JAR 包，以后台命令启动确保持久运行。

前端开发是以 Visual Studio Code 为工具，通过 vue create 命令先初始化 Vue 项目。根据 UI 设计开发前端组件页面并编写业务逻辑，并配置 Vue Router 管理路由与跳转。项目经 Vue CLI 打包后，将静态文件上传至远程服务器，配置并启动 Nginx 以保障静态资源能够正常访问。

利用 PyTorch 加载训练完成的深度学习模型，并转换为 ONNX 格式以适配部署需求。在服务器端安装 Flask 及相关依赖，构建 Flask 应用并编写模型加载代码，定义 API 端点用于接收输入数据并返回预测结果。启动应用，验证其在服务器上的正常运行状态。

为实现系统能在手机端正常运行，通过 Vue CLI 创建 Vue 项目用于开发移动端应用，集成 Cordova 插件以配置移动应用打包所需功能。借助 HBuilderX 添加 Android 平台并完成打包信息配置，最终通过 HBuilderX 打包生成 APK 文件供手机端安装。

3.2 系统执行流程

将训练好的模型被集成至自主研发的移动端应用程序中，系统执行流程如图 4 所示。用户启动应用后进入主界面，可选择从手机相册导入掌子面图像，或直接调用相机进行实时拍摄。图像上传成功后，系统自动对图像进行预筛选，判断其是否为有效围岩图像。若确认为围岩图像，则进一步提取其视觉特征，并将特征数据上传至服务器进行智能识别。识别完成后，系统界面自动展示围岩等级判定结果，并基于识别结果推荐相应的施工方法。

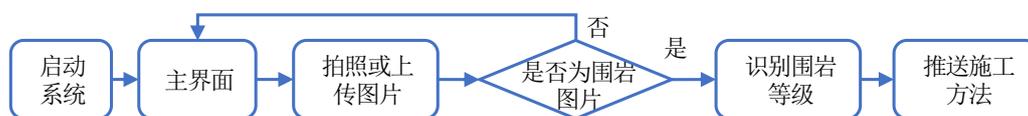


图 4 系统执行流程

Fig 4 Execution process of the system

3.3 系统移动端操作界面

系统移动端操作界面如图 5 所示。打开 App 进入识别系统主界面，主界面(a)包括有拍照识别或上传相册图片进行识别的选项，并且还提供了前人成功的爆破案例用以参考。点击拍照识别或上传图片进入图片的框选界面(b)，图片框选完成点击识别按钮进行围岩等级识别，识别完成后自动跳转至识别结果界面(c)，点击识别出的围岩等级系统进入施工方法选择界面(d)为隧道施工推荐适用的施工方法，选择施工方法进入输入隧道断面开挖参数输入界面(e)，输入参数后系统转到具体施工设计界面(f)根据参数给出推荐的爆破开挖相关参数和隧道支护设计。

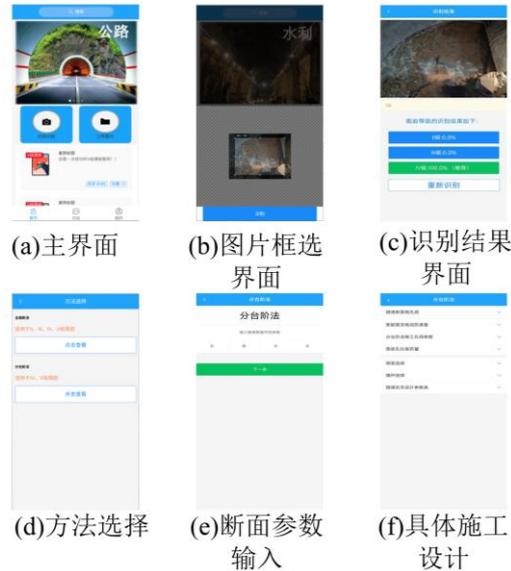


图 5 系统移动端界面示意图

Fig 5 Schematic diagram of the system's mobile terminal interface

4 工程实例

4.1 工程概况

晓沅隧道起点位于赣州市南康市大坪乡晓沅村附近,终点位于赣州市南康市大坪乡东村村附近,为单洞四车道隧道,其起止桩号为 ZK2985+180~ZK2985+570,隧道长度为 390 米,隧道最大埋深 76 米。

隧道出口段地层主要为残坡积层及全强风化花岗岩,为类土质围岩等,为极破碎至破碎岩层。地下水主要为风化带网状孔隙裂隙水、基岩风化裂隙水及构造裂隙水。受断裂带的影响,隧址区内裂隙带内岩体十分破碎,其成润性差,隧道施工到这些构造裂隙带时,容易引起掉块,甚至是洞壁岩体发生剥离等现象,这些均不利于隧道的稳定性。同时这些破碎带一般是地下水的富集地带,为区内的富水层,当隧道施工到破碎带时,常发生涌水现象。受区域构造的影响,构造裂隙深切岩体,也降低了隧道的稳定性。

4.2 围岩分级结果对比分析

根据围岩分级的原理和步骤,将隧道正在开挖的掌子面上传至软件识别,将识别结果与传统的 BQ 分级法结果进行对比验证其准确性,软件对部分断面智能识别结果如图 6 所示,BQ 分级法结果如表 4 所示。

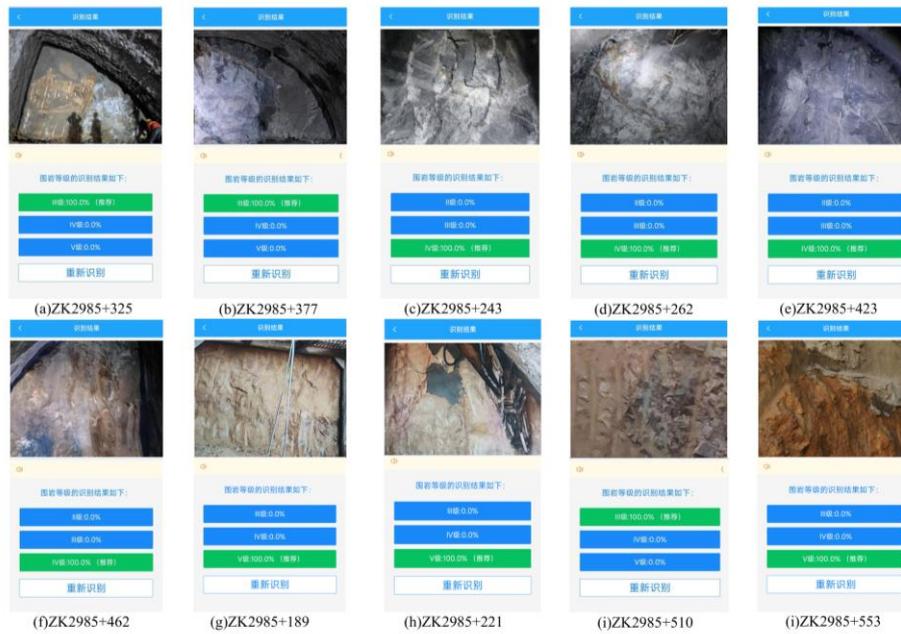


图 6 部分断面智能识别结果

Fig 6 Intelligent recognition results of partial cross-sections

从图 6 中可以看出, ZK2985+325 断面、ZK2985+377 断面和 ZK2985+510 为 III 级围岩, 围岩为中风化花岗岩为较坚硬岩, 岩体较破碎, 围岩呈破碎镶嵌结构。ZK2985+243 断面、ZK2985+262 断面、ZK2985+423 断面和 ZK2985+462 断面为 IV 级围岩, 围岩为中风化花岗岩, 为坚硬岩, 岩体破碎, 结构面发育, 围岩呈碎裂结构。III 级围岩和 IV 级围岩部分大多为灰白色斑点状, 岩体为中粗粒结构, 块状构造。ZK2985+189 断面、ZK2985+221 断面和 ZK2985+553 断面为 V 级围岩, 围岩主要为残坡积层级全强风化花岗岩, 呈黄色夹杂色, 原岩结构已基本破坏, 岩石风化呈砂土状。

两种方法识别结果对比如表 5 所示。可以看出, 通过对比本系统所得结果和晓沅隧道 BQ 围岩分级资料结果, 发现利用围岩智能分级系统的准确率能够到达 Vision Transformer 深度学习模型的准确率。ZK2985+510 掌子面的识别结果不准确原因是拍摄隧道环境恶劣导致图片不清晰使系统出现了误判。

表 4 BQ 分级法围岩分级结果

Tab 3 Classification results of surrounding rock by BQ classification method

里程桩号	岩体完整性指标 Kv	地下水影响修正系数 K1	结构面产状修正系数 K2	初始地应力状态修正系数 K3	BQ 值	围岩级别
ZK2985+180~ZK2985+230	<0.15				<250	V
ZK2985+230~ZK2985+280	0.34	0.3	0.3	0	306.8	IV
ZK2985+280~ZK2985+400	0.51	0.2	0.2	0	383.7	III
ZK2985+400~ZK2985+490	0.34	0.3	0.3	0	306.8	IV
ZK2985+490~ZK2985+570	<0.15				<250	V

表 5 BQ 围岩分级法与智能围岩分级系统结果对比

Tab 4 Comparison of results between the BQ surrounding rock classification method and the intelligent surrounding rock classification system

掌子面桩号	围岩分级方法	围岩分级结果	掌子面桩号	围岩分级方法	围岩分级结果
ZK2985+189	BQ 分级法	V	ZK2985+377	BQ 分级法	III
	智能分级系统	V		智能分级系统	III
ZK2985+221	BQ 分级法	V	ZK2985+423	BQ 分级法	IV
	智能分级系统	V		智能分级系统	IV
ZK2985+243	BQ 分级法	IV	ZK2985+462	BQ 分级法	IV
	智能分级系统	IV		智能分级系统	IV

ZK2985+262	BQ 分级法	IV	ZK2985+510	BQ 分级法	V
	智能分级系统	IV		智能分级系统	III
ZK2985+325	BQ 分级法	III	ZK2985+553	BQ 分级法	V
	智能分级系统	III		智能分级系统	V

4.3 隧道超欠挖情况对比分析

为验证其对隧道开挖质量的提升作用，选取晓沉隧道 ZK2985+325~ZK2985+377 段作为试验段，开展对比试验研究。试验采用 RIEGL VZ-400 三维激光扫描设备，分别对“采用系统推送爆破参数”与“采用传统经验爆破参数”的两组开挖断面进行全断面点云数据采集；采集后通过 RiSCANPRO 软件完成点云去噪、坐标配准及三维模型重构，进一步提取两组工况下隧道开挖轮廓的超欠挖体积和轮廓贴合度，图 8 为系统推送的炮孔布置位置。

对比分析结果如图 9 所示，图中红色标识区域对应开挖过程中的超挖部分，采用系统推送爆破参数的开挖断面，其轮廓线与设计轮廓的贴合度达 81.2%，超挖体积为 113.49m³，欠挖体积为 70.34m³，且开挖表面无明显爆破扰动裂隙，岩体完整性保留良好；而未采用系统参数的断面，轮廓贴合度仅为 72.6%，超挖体积为 160.47m³，欠挖体积为 107.45m³，部分区域存在因爆破能量控制不当导致的岩体崩落痕迹，扰动范围延伸至开挖轮廓外 5~10cm。两组数据差异表明，围岩实时识别系统推送的爆破参数可通过精准匹配当前围岩等级实现爆破能量的合理分配，显著降低开挖偏差，减少爆破对围岩的扰动破坏，从源头上提升了施工安全性，避免了因过度爆破引发的松弛圈扩大甚至局部塌方风险，并直接减少了混凝土回填量和支护成本，降低了工程材料浪费。



图 8 炮孔布置位置

Fig 8 Blasthole layout positions

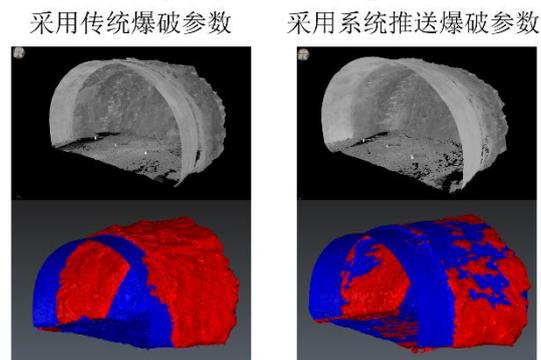


图 9 三维激光扫描对比分析

Fig 9 Comparative analysis of 3D laser scanning

4.4 系统局限性及改进措施

尽管本系统在晓沉隧道的应用中表现出较高的识别准确率与实用价值，但其性能在特定工程环境下仍存在一定局限性。在本研究中，桩号 ZK2985+510 断面的识别结果出现偏差。该断面依据 BQ 法判定为 V 级围岩，而系统错误地识别为 III 级围岩。误判的主要原因为图像采集时处于爆破作业后不久，掌子面附近空气中粉尘浓度较高，且存在照明不足区域，导致所获取的图像细节信息严重缺失，进而影响系统判断的准确性。

为提高系统识别准确率，在数据采集与预处理阶段，可采用统一分辨率进行图像拍摄，并针对每个围岩等级采集多种工况下的样本，以覆盖不同施工环境条件，增强数据的代表性和泛化能力。同时，通过引入随机翻转、亮度调整和高斯模糊等数据增强方法构建扩充样本集，以抑制光照变化、拍摄角度等外部因素对模型训练的干扰。此外，可建立在线学习机制对模型进行持续优化，使系统在获得现场工程师确认后，能够将修正后的样本动态纳入训练集，从而逐步提升模型对特定工程地质特征的适应能力。

5 结论及展望

本文围绕隧道围岩智能分级需求，构建了基于 Vision Transformer 模型的围岩智能识别系统，并通过工程实践验证了其可行性与优越性。研究表明，所提出的系统能够有效解决传统围岩分级方法效率低、主观性强的问题，为隧道施工智能化提供了可靠的技术支撑。

5.1 研究主要结论

1) 基于 2 621 张多地质条件掌子面图像构建的数据集，Vision Transformer 模型经 100 轮训练后准确率达 92.49%，较 EfficientNet 与 ResNet34 模型提升显著。其创新性在于通过自注意力机制突破传统 CNN 的局部感受野限制，实现了对节理组空间关系、结构面走向等全局地质特征的高效捕捉，为复杂围岩环境下的精准识别提供了新方法。

2) 系统通过数字图像采集终端、智能分级处理模块与智慧化评价模块的协同，首次实现了围岩分级的端到端自动化。移动端 App 的轻量化设计支持图像实时采集、识别及施工方法智能推送，创新性地将深度学习模型与施工现场动态决策衔接。

3) 经晓沅隧道工程实例验证，系统展现出优异的工程适用性与落地价值。选取 10 个典型掌子面断面进行验证，系统识别结果与传统 BQ 分级法的对比显示，除因拍摄环境恶劣导致的 1 例误判外，其余 9 例结果完全一致，整体准确率达 90%，跨标段测试平均准确率达 90.7%，模型具备良好的泛化能力。

4) 选取晓沅隧道 ZK2985+325~ZK2985+377 段为试验段，对比“系统推送爆破参数”与“传统经验爆破参数”的应用效果。经三维激光扫描与软件分析，系统推送参数的开挖断面轮廓贴合度达 81.2%，超欠挖体积更小且围岩扰动轻；传统经验参数贴合度仅 72.6%，超欠挖及扰动更显著。

5.2 未来展望

现有系统在复杂施工环境适应性及多源信息融合深度上仍有局限。针对粉尘干扰、照明不足等条件下掌子面图像会出现的识别偏差，需丰富多工况样本数据并结合动态数据增强，提升模型在恶劣环境下的识别稳定性与泛化能力。

此外，当前系统的智慧化评价模块虽具备多源数据融合的架构理念，但与地质雷达、TSP 等数据的深度、实时融合能力仍有较大提升空间。未来可探索基于 Transformer 的多模态融合模型，实现图像与物探数据在特征层面的深度融合，从而提升对掌子面前方地质状况的综合研判能力，为施工决策提供更全面的支持。

参考文献：

- [1] 洪开荣, 冯欢欢. 近 2 年我国隧道及地下工程发展与思考 (2019—2020 年) [J]. 隧道建设 (中英文), 2021, 41 (8): 1259-1280.
HONG K R, FENG H H. Development and thinking of tunnels and underground engineering in China in recent two years (from 2019 to 2020)[J]. Tunnel Construction, 2021, 41(8): 1259-1280.
- [2] KIM Y J, YUN T S. Enhanced rock mass rating prediction from tunnel face imagery: A decision - supportive ensemble deep learning approach[J]. Tunnelling and Underground Space Technology, 2023, 135: 105110.
- [3] 张勇, 石胜伟, 何江达. 基于云模型的隧道围岩工程地质分类方法及应用[J]. 工程地质学报, 2016, 24(03): 339-344.
ZHANG Y, SHI S W, HE J D. Tunnel surrounding rockmass classification based on cloud model and its application[J]. Journal of Engineering Geology, 2016, 24(03): 339-344.
- [4] Jin-Quan L, Ka-Veng Y, Wei-Zhong C, et al. Grouting for water and mud inrush control in weathered granite tunnel: A case study[J]. Engineering Geology, 2020, 279: 105896-.
- [5] 江权, 刘强. 地下洞室变形破坏物理模拟的力学相似畸变映射原理与实例分析[J]. 岩土力学, 2024, 45(01): 20-37.

-
- JIANG Q, LIU Q. Mechanical similarity distortion mapping principle and case analysis for underground cavern physical simulation of deformation and failure[J]. *Rock and Soil Mechanics*, 2024, 45(01): 20-37.
- [6] Wu Z , Wu L , Lin T , et al. An engineering rock mass quality classification system for deep-buried hard rock tunnels[J]. *Frontiers in Earth Science*, 2024.
- [7] 崔向阳, 丁浩, 乌树头隧道施工方案优化选择[J]. *华东交通大学学报*, 2019, 36(2):7.
CUI X Y, DING H. Optimization Selection of Construction Scheme for Wushutou Tunnel [J]. *Journal of East China Jiaotong University*, 2019, 36 (2): 7.
- [8] 周东, 刘毛毛, 刘宗辉, 等. 基于探地雷达属性分析的隧道内溶洞三维可视化研究[J]. *岩土工程学报*, 2023, 45(02): 310-317+442.
ZHOU D, LIU M M, LIU Z H, et al. 3D visualization of karst caves in tunnels based on ground penetrating radar attribute analysis[J]. *Chinese Journal of Geotechnical Engineering*, 2023, 45(02): 310-317+442.
- [9] 徐昆杰, 张治荣, 向露露, 等. 融合钻进参数与地震波反射法的隧道围岩级别分类预测模型研究[J]. *隧道建设(中英文)*, 2025, 45(03): 579-586.
XU K J, ZHANG Z R, XIANG L L, et al. Prediction model for tunnel surrounding rock classification based on integration of drilling parameters and seismic reflection method[J]. *Tunnel Construction*, 2025, 45(03): 579-586.
- [10] 郑继东, 陈水龙, 李东艳, 等. 基于地震探测的围岩分类及其应用[J]. *河南理工大学学报(自然科学版)*, 2019, 38(01): 54-60.
ZHENG J D, CHEN S L, LI D Y, et al. Surrounding rock classification based on seismic detection and its application[J]. *Journal of Henan Polytechnic University (Natural Science)*, 2019, 38(01): 54-60.
- [11] 安哲立, 彭昉, 袁振宇, 等. 隧道地震波三维层析超前地质预报系统及工程应用[J]. *中国铁路*, 2024, (11): 37-44.
AN Z L, PENG Y, YUAN Z Y, et al. 3D tomographic advanced geological prediction system for tunnel seismic waves and its engineering application[J]. *Chinese Railways*, 2024, (11): 37-44.
- [12] 蔡盛. 基于横波的三维超前地质预报方法及应用[J]. *铁道工程学报*, 2022, 39(10): 30-36.
CAI S. 3D advanced geological prediction method based on shear wave and its application[J]. *Journal of Railway Engineering Society*, 2022, 39(10): 30-36.
- [13] Guan P , Shao C , Jiao Y , et al. 3-D Multi-Component Reverse Time Migration Method for Tunnel Seismic Data[J]. *Sensors*, 2021, 21(9): 3244.
- [14] Segura M A M , Nieto G C M , Navarro M , et al. Seismic characterisation of the subsoil under a historic building: Cathedral Church of Saint Mary in Murcia case study[J]. *Engineering Geology*, 2024, 335107529-.
- [15] 黄宏伟, 陈佳耀. 基于机器视觉的隧道围岩智能识别分级与开挖安全风险研究[J]. *应用基础与工程科学学报*, 2023, 31(06): 1382-1409.
HUANG H W, CHEN J Y. Intelligent recognition and classification of tunnel surrounding rock based on machine vision and excavation safety risk research[J]. *Journal of Basic Science and Engineering*, 2023, 31(06): 1382-1409.
- [16] 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 H X, LI W S, ZHA H Y, et al. Highway tunnel surrounding rock classification method based on deep learning technology[J]. *Chinese Journal of Geotechnical Engineering*, 2018, 40(10): 1809-1817.
- [17] 董子开, 李旭, 田国帅, 等. 基于 TBM 岩渣图像的围岩分级预测[J]. *应用基础与工程科学学报*, 2023, 31(06): 1540-1551.
DONG Z K, LI X, TIAN G S, et al. Surrounding rock classification prediction based on TBM muck image[J]. *Journal of Basic Science and Engineering*, 2023, 31(06): 1540-1551.
- [18] 孟馨, 秦拥军, 谢良甫, 等. 基于深度学习的东天山特长隧道围岩等级预测[J]. *科学技术与工程*, 2022, 22(25): 11219-11226.
MENG X, QIN Y J, XIE L F, et al. Surrounding rock grade prediction of East Tianshan extra-long tunnel based on deep learning[J]. *Science Technology and Engineering*, 2022, 22(25): 11219-11226.
- [19] 毛奕喆, 龚国芳, 周星海, 等. 基于马尔可夫过程和深度神经网络的 TBM 围岩识别[J]. *浙江大学学报(工学版)*, 2021, 55(03): 448-454+547.
MAO Y Z, GONG G F, ZHOU X H, et al. TBM surrounding rock recognition based on Markov process and deep neural network[J]. *Journal of Zhejiang University (Engineering Science)*, 2021, 55(03): 448-454+547.
- [20] 吴浩, 陈运涛, 朱赵辉, 等. 改进一维卷积神经网络的隧道围岩收敛变形分级预测[J]. *应用基础与工程科学学报*, 2024, 32(01): 145-159.
WU H, CHEN Y T, ZHU Z H, et al. Grade prediction of tunnel surrounding rock convergence deformation based on improved 1D convolutional neural network[J]. *Journal of Basic Science and Engineering*, 2024, 32(01): 145-159.
- [21] 陈卫东, 李天斌, 黄音昊, 等. 隧道围岩分级特征智能识别及可视化研究[J]. *铁道科学与工程报*, 2024, 21(01): 406-421.
CHEN W D, LI T B, HUANG Y H, et al. Intelligent recognition and visualization of tunnel surrounding rock classification characteristics[J]. *Journal of Railway Science and Engineering*, 2024, 21(01): 406-421.
- [22] Bao S , Liu J , Wang L , et al. Landslide Susceptibility Mapping by Fusing Convolutional Neural Networks and Vision Transformer[J]. 2023.
- [23] LI Y Y, ALKHALIFAH T, HUANG J P, LI Z C. Self-Supervised Pretraining Vision Transformer With Masked Autoencoders for

Building Subsurface Model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-10.

[24] Tong J , Xiang L , Zhang A A ,et al.Fusion of Convolution Neural Network and Visual Transformer for Lithology Identification Using Tunnel Face Images[J].Journal of Computing in Civil Engineering. 2025, 39(2).

[25] Yakoub B ,Laila B ,Al M M R , et al.Vision Transformers for Remote Sensing Image Classification[J].Remote Sensing,2021,13(3):516-516.

[26] Dosovitskiy A , Beyer L , Kolesnikov A ,et al.An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale[C]//International Conference on Learning Representations.2021.



第一作者：熊涛（2002—），男，硕士研究生，研究方向为深部岩体力学与隧道工程。Email:1583173789@qq.com。



通信作者：于洋（1982—），男，教授，博士，博士生导师，研究方向为深部岩体力学与隧道工程。
Email:lukeryuyang@163.com。