

文章编号:1005-0930(2024)03-0702-019 中图分类号:TP751.2 文献标识码:A  
doi:10.16058/j.issn.1005-0930.2024.03.006

## 基于深度学习的钻孔图像岩体结构面识别

李炜<sup>1</sup>, 刘耕<sup>2,3</sup>, 葛云峰<sup>2</sup>, 张占荣<sup>1</sup>, 黄国良<sup>1</sup>

(1. 中铁第四勘察设计院集团有限公司, 湖北 武汉 430063; 2. 中国地质大学(武汉)工程学院, 湖北 武汉 430074;  
3. 湖南省地震局, 湖南 长沙 410004)

**摘要:** 岩体结构面对岩体稳定性和渗透性有着重要影响, 是决定深部地下工程稳定性的重要因素。针对井下电视技术获取的钻孔影像, 提出了一种基于深度学习算法(You Only Look Once version 4, YOLO v4)的岩体结构面识别方法, 并计算识别岩体结构面的几何参数。首先, 采集图像数据并进行预处理。以某隧道工程为案例, 使用智能钻孔光学成像仪采集4号和6号钻孔图像, 筛选含有结构面的钻孔图像进行标注以建立Ground truth数据集。从中随机选择数据集的70%作为训练数据、10%作为验证数据、20%作为测试数据, 并对训练数据集使用数据增强处理。接下来使用CSPDarkNet53网络作为特征提取网络, 构建YOLO v4模型, 并采用试错法获取最优参数进行模型训练。利用测试集生成P-R(Precision-Recall)曲线来测试最终的模型训练效果, 结果显示P-R曲线的平均精度达0.87, 这表明YOLO v4训练结果较好。最后, 将定位的结构面采用Canny算法通过拟合上、中、下正弦曲线函数获取岩体结构面边缘, 并依据正弦函数的系数计算结构面的4个几何参数(倾向、倾角、深度和张开度)。

**关键词:** 岩石力学; 岩体结构面; 智能识别; 井下电视; 深度学习; YOLO v4

岩体内部常常发育不同规模的结构面, 如节理裂隙、断层、破碎带、软弱夹层等<sup>[1]</sup>, 对岩体的稳定性、渗流特性有重大影响<sup>[2-3]</sup>, 是决定深埋地下工程稳定性的重要因素。因此, 如何快速高效地识别岩体结构面, 并准确地计算岩体结构形态的原位信息, 对于工程地质勘探与项目设计施工等具有重要的实际工程意义<sup>[4-5]</sup>。

目前, 岩体结构面测量方法主要有传统的测线法<sup>[6]</sup>、测窗法<sup>[7]</sup>, 以及依靠新技术的摄影测量方法<sup>[8-9]</sup>和三维激光扫描方法<sup>[10-11]</sup>。传统的方法直接通过罗盘、测绳等工具测量, 但是其效率较低, 而且需要地质工作者到达待测量的地点进行人工测量。在面对难以到达的危险地段时, 传统方法常常束手无策。摄影测量方法和三维激光扫描技术都属于非接触测量方法, 不需要地质工作者到达测量地点, 因此效率更高, 对于危险地段的岩体测量具有较大优势<sup>[12-13]</sup>。摄影测量方法和三维激光扫描技术只能测量地上岩体, 在测量地下岩体

收稿日期:2023-05-12; 修订日期:2023-11-16

基金项目: 中国铁建股份有限公司科技研发计划项目(2022-B20); 湖北省重点研发计划项目(2021BAA050); 国家重点研发计划项目(2023YFC3081200); 国家自然科学基金项目(042077264)

作者简介: 李炜(1995—), 男, 硕士, 工程师. E-mail: 2060176661@qq.com

通信作者: 葛云峰(1985—), 男, 博士, 教授. E-mail: geyunfeng@cug.edu.cn

时,由于空间狭小、缺乏光线等原因,往往难以开展工作.而具备独立光源、可以 360°无死角拍摄钻孔孔壁图像的井下电视技术可以弥补此缺点<sup>[14-15]</sup>,目前已经成为研究地下岩体的重要技术<sup>[16]</sup>.

采用井下电视技术,首先获取岩心钻孔的孔壁图像,再对图像进行数据处理,计算岩体结构面参数.对钻孔的孔壁图像进行数据处理时,可以采取人工判读和自动识别两种方法.人工判读一般由地质工作者主观地给出结构面正弦曲线控制点或者输入必要的特征参数,再进行正弦函数曲线拟合,计算出拟合参数<sup>[17]</sup>.但是人工判读方法受地质工作者的主观认知水平影响较大,效率也较低<sup>[18-19]</sup>.此外,钻孔深度往往长达数百米甚至上千米,在处理大量的钻孔图像时,即使是经验丰富的地质工作者也容易因为疲乏而产生误判.自动识别方法包括图像空间变换、图像分割、Hough 变换法、灰度值极差法<sup>[16,20]</sup>、定位信号特征值 D 法<sup>[21]</sup>等等.其中:图像空间变换和 Hough 变换法适应性较差,而且 Hough 变换的计算性能消耗太大<sup>[22]</sup>;图像分割方法主要利用图像灰度特征和梯度特征的特征信号,计算较为复杂,而且未考虑到数字钻孔图像的横向连续性;定位信号特征值 D 法虽然可以完成结构面识别,但只能实现半自动化定位,而且存在一定误差,有时受噪声点的干扰不能识别出完整的结构面区域.所以基于深度学习的结构面自动识别方法成为解决该难题的新方向.

随着深度学习方法的引入和数值计算设备的改进,已经有众多学者将深度学习模型应用到实际中,例如人脸识别<sup>[23]</sup>、汽车识别<sup>[24]</sup>、人体动作识别<sup>[25]</sup>等.但是将深度学习模型应用到钻孔图像的较少,目前仅部分学者使用,如 Dias 等<sup>[26]</sup>使用 Fast R-CNN 自动检测钻孔图像中的裂隙.这部分学者只实现了结构面的定位,并未计算出结构面的几何参数,尚未真正将深度学习模型应用到工程地质领域.结构面的识别不仅仅包含识别定位,还需要对产状、张开度、深度等几何参数的计算<sup>[27]</sup>.而地下岩体的结构面几何参数对于地下工程的开挖、施工等至关重要,仅利用算法识别定位出钻孔图像中结构面是远远不够的,还需要根据定位结果计算出结构面的几何参数.但是在狭窄的钻孔空间中,人工测量结构面几何参数非常困难,几乎不可能实现.深度学习算法却可以自动识别钻孔图像中结构面,并计算出结构面的几何参数,解决钻孔中空间小、测量困难等难题,真正实现结构面识别.

因此,笔者选择算法成熟、应用广泛、有相关论文参考的 YOLO v4 算法,以某隧道工程为例,收集钻孔图像并创建数据集,构建深度学习结构面识别模型,识别定位钻孔图像中的结构面位置,并根据定位结果计算结构面的几何参数.

## 1 研究方法

钻探是地质勘探的常用技术手段,一般完成的钻孔深入地下数百米,甚至上千米.由于地质构造等原因,常常在钻孔中伴随着结构面、裂隙等.结构面或裂隙受地质沉积、胶结等作用,会被钙质、铁质、泥质胶结物充填.这些填充物在颜色上与母岩有着明显区别,一般呈白色或深褐色.YOLO v4 模型主要依靠钻孔图像中结构面与母岩的颜色差异来实现结构面的识别和定位.

操作流程主要分为两部分,分别是结构面的识别定位和结构面几何参数的计算(图 1).以某隧道工程为案例,使用智能钻孔光学成像仪采集工程的 4 号钻孔和 6 号钻孔的孔壁

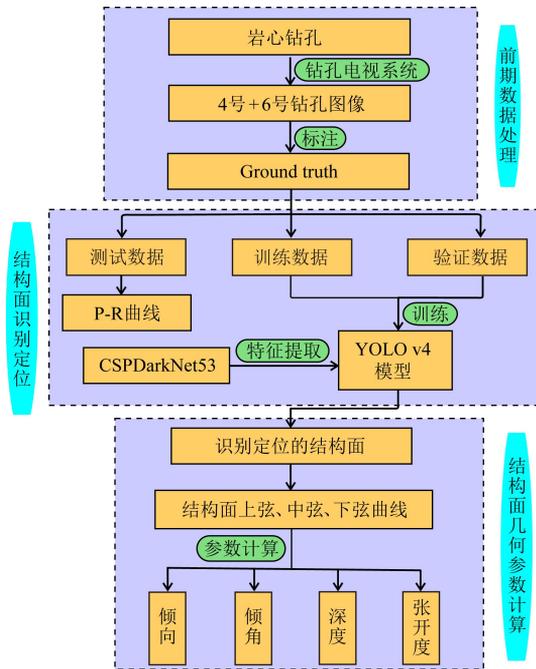


图1 所提方法技术路线

Fig.1 The workflow of the proposed method

图像,筛选孔壁图像中包含结构面的图像,制作为数据集.将194张钻孔图像结构面进行标注,建立数据集.将数据集随机分成训练集(70%)、验证集(10%)、测试集(20%),对训练集使用数据增强处理,获得544张训练集图像.使用CSPDarkNet53作为特征提取网络构建YOLO v4模型,将训练集输入到YOLO v4模型中.采用试错法获取最优参数并以此参数训练模型,利用训练好的YOLO v4模型识别定位结构面.最后,将识别定位的结果使用canny算法拟合出结构面的上、中、下3个正弦曲线函数,依据3个正弦曲线的函数系数计算结构面几何参数(倾向、倾角、张开度和深度).

在深度学习模型骨干架构和算法流程上开展一定地创新.骨干架构上,在DarkNet53的基础上,引入批量归一化层(Batch Normalization Layer)和Mish激活

函数层(Mish Activation Layer),构建CSPDarkNet53特征提取网络.算法流程上,YOLO v4算法目前主要用于汽车和人体识别等领域,本研究将其扩展到了岩体力学领域.此外,YOLO v4算法只能实现结构面的定位,无法计算出结构面的产状、深度、张开度等几何参数.而针对YOLO v4识别出的岩体结构面,笔者进一步开展了结构面几何参数计算研究.

## 1.1 深度学习理论

### 1.1.1 YOLO v4 算法原理

深度学习算法目前主要应用在图像识别领域,如汽车识别等,鲜有学者应用到地质领域.经过广大学者不断地改进,深度学习算法的识别准确率越来越高,应用范围越来越广泛,深度学习算法有望应用到地质领域,成为解决众多地质难题的一种新方法.因此基于深度学习算法,选取较为成熟的、识别准确率高、适用性强的YOLO v4算法作为识别定位结构面的核心算法.YOLO v4模型预测目标位置的算法原理与YOLO v3类似,均使用先验框(Anchor box)来预测图像中检测目标的位置.其预测结构面的计算过程中包含3个重要部分,分别是预定义先验框位置、计算分类的置信度 $C$ (Confidence core)、计算预测偏差.YOLO v4模型预先设置若干个先验框,并赋予预定义先验框位置坐标和大小.预定义先验框位置包括先验框的 $x$ 、 $y$ 、 $w$ 、 $h$ 和置信度 $C$ 共5个值,其中: $x$ 、 $y$ 为先验框中心点的置; $w$ 、 $h$ 为先验框的长度和宽度.模型经过训练,对先验框与Ground truth标注的含有结构面的矩形框位置、大小进行校正,不断修正先验框位置.

先验框的置信度采用交并比(Intersection Over Union, IOU)的方法计算,其计算元素示意如图2所示.IOU为先验框与Ground truth交集的面积同二者的并集面积之比.其计算式如下

$$IOU = \frac{Area(\text{先验框}) \cap Box(\text{Groundtruth})}{Area(\text{先验框}) \cup Box(\text{Groundtruth})} \quad (1)$$

与  $IOU$  对应的另一个参数是  $Pr$ (结构面), 该参数代表这个框中结构面存在的可能性. 若框中没有结构面, 则  $Pr(\text{结构面}) = 0$ ; 若含有结构面, 则  $Pr(\text{结构面}) = 1$ . 这两个参数值的乘积为置信度, 即置信度 =  $IOU \times Pr(\text{结构面})$ . 置信度用来评判模型预测结构面的边界框的准确性. 置信度越大, 准确性越高, 代表 YOLO v4 模型训练越好, 识别定位结构面越准确.

如图 3 所示, 结构面图像以及先验框输入模型之后 (预定义先验框 4 个, 即每次训练之前, 分配 4 个先验框), 模型将结构面图像切割为多个小方格, 按照预定义先验框的数量和位置坐标 (图 3 中虚线) 在小方格中预测. 预定义先验框的大小通过 K-means 聚类算法获取, 通过对训练集中样本的 Ground truth 的长和宽进行聚类分析, 得到更加适合的结构面大小的先验框长和宽. 根据预定义先验框的位置与真实结构面的位置计算预测偏差, 并不断修正先验框的位置, 利用模型不断缩小预测偏差, 最终框定出正确的结构面位置, 以矩形框的形式输出.

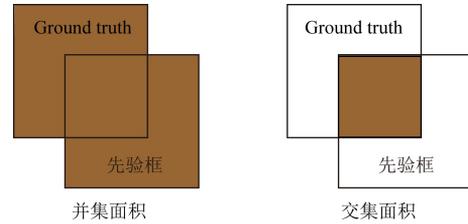


图 2  $IOU$  计算元素示意  
Fig.2 Schematic diagram of  $IOU$  calculation elements

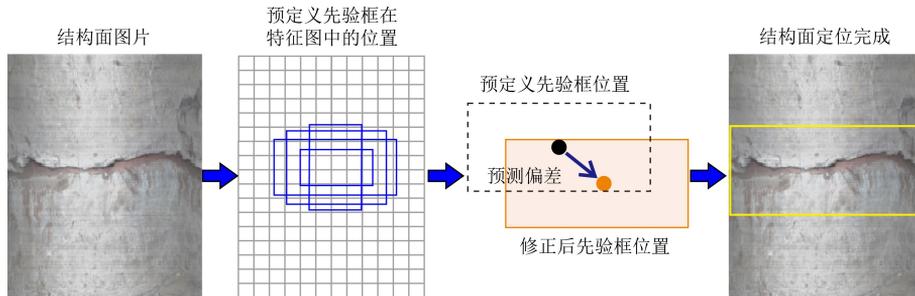


图 3 YOLO v4 识别定位结构面的原理

Fig.3 Schematic diagram of YOLO v4 for identification and positioning of rock joints

**1.1.2 CSPDarkNet53 特征提取网络** YOLO v4 目标检测网络是一种单阶段目标检测网络, 是预训练的卷积神经网络, 使用的特征提取网络是标配网络——CSPDarkNet53. 该网络是针对 YOLO v3 的特征提取网络 (DarkNet53) 的一种改进, 其创造性地采用了跨阶段局部连接 (Cross-stage Partial, CSP). CSPDarkNet53 网络整体由残差模块组成, 每个残差模块包含不同数量的 CSP 结构. CSP 结构依次堆叠 1 次、2 次、8 次、8 次、4 次, 每次的堆叠分别组成 1 个残差模块, 共组成 5 个残差模块, 如图 4 所示. CSPDarkNet53 特征提取网络引入了残差模块 (Residual Block), 后面的残差模块可以直接学习隔位残差模块的输出, 从而提高模型的学习速度, 加快模型收敛速度. 增加模块之间的传递通道, 可以避免在传递过程中有用信息的丢失, 而且可以有效减少计算参数量, 提高模型的准确率.

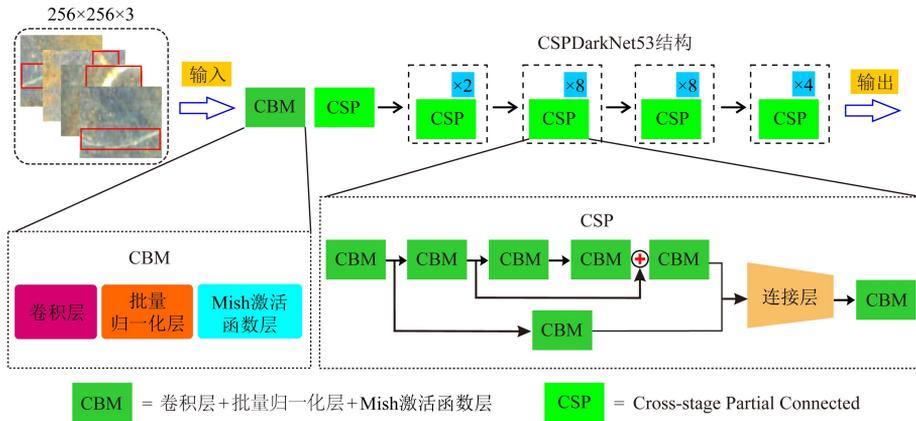


图4 CSPDarkNet53 特征提取网络结构

Fig.4 CSPDarkNet53 feature extraction network structure

此外, CSPDarkNet53 还引入了批量归一化层 (Batch Normalization Layer) 和 Mish 激活函数层 (Mish Activation Layer). 每个卷积层 (Convolution Layer) 之后以此添加批量归一化层和 Mish 激活函数层, 三者共同构成一个 CBM, CBM 是构成 CSPDarkNet53 特征提取网络的基础单元. CSPDarkNet53 网络与 DarkNet53 网络的不同之处在于其引入 Mish 激活函数层代替原来的 Leaky ReLu 激活函数层. Mish 激活函数允许一部分的负梯度信息流入, 更加有利于模型的特征提取, 可提高模型的训练效率<sup>[28]</sup>. 而且加入了批量归一化层, 允许 YOLO v4 模型在训练时使用较大的初始学习率, 学习率衰减速度也很快, 可以加快网络收敛速度, 使得 YOLO v4 这种深层次复杂架构的模型也能够进行训练<sup>[29]</sup>. 此外, 加入批量归一化层还可有效避免网络在训练过程中出现的梯度爆炸、梯度消失等问题.

**1.1.3 YOLO v4 结构** YOLO v4 主体由输入端、脊柱 (Back bone)、多尺度特征融合颈部 (Neck) 和预测头部 (Head) 4 部分组成, 如图 5 所示. 输入端即经过数据增强处理的训练集, 共 544 个结构面训练样本. 脊柱为 CSPDarkNet53 特征提取网络, 主要用于提取并传递从训练样本中学习到的特征. 多尺度特征融合颈部连接着脊柱和预测头部, 连接着来自 CSPDarkNet53 网络提取的特征图, 并将其作为输出传送到预测头部. 多尺度特征融合颈部由空间金字塔池模块 (Spatial Pyramid Pooling, SPP) 和路径聚合网络 (Path Aggregation Network, PAN) 组成. SPP 模块连接低分辨率特征映射的最大池化层输出, 提取最具代表性的特征. SPP 模块分别使用  $1 \times 1$ 、 $5 \times 5$ 、 $9 \times 9$  和  $13 \times 13$  的内核进行最大池化操作, 步幅值设置为 1, 特征映射的连接增加了主干特征的接受域, 提高了网络检测小目标的准确性<sup>[30]</sup>. SPP 模块拼接的特征图通过 PAN 与高分辨率特征图融合, PAN 通过上采样和下采样操作, 设置自底向上和自顶向下的路径, 实现低级和高级特征的组合, 输出一组聚合的特征映射用于预测.

YOLO v4 网络使用一级对象检测器作为检测头部, 共有 3 个检测头部作为输出, 处理聚合的特征图. 每个预测头部的输出端都可以预测结构面位置, 3 个输出端的输出大小依次为  $32 \times 32 \times 3$ 、 $16 \times 16 \times 3$  和  $8 \times 8 \times 3$  的特征映射. 预测头部用于预测结构面的位置, 并生成一个边界框, 同时输出每个结构面类别的置信度百分数.

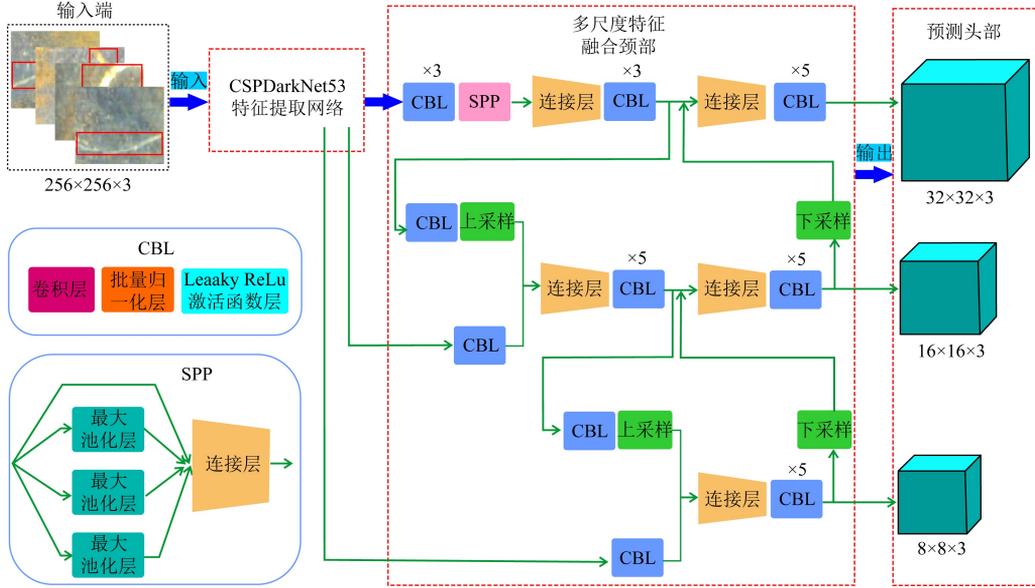


图 5 YOLO v4 结构

Fig.5 Structure diagram of YOLO v4

**1.1.4 损失函数** YOLO v4 定义的损失函数包含 3 部分,分别是 Corrd 损失误差 (Corrd Loss)、IOU 损失误差 (IOU Loss) 和分类损失误差 (Classification Loss), 损失函数计算式为<sup>[31]</sup>

$$YOLOv4 \text{ Loss} = \text{Corrd Loss} + \text{IOU Loss} + \text{Classification Loss} \quad (2)$$

Corrd 损失误差计算式为

$$\text{Corrd Loss} = \lambda_{\text{corrd}} \sum_{i=1}^{s^2} \sum_{j=1}^B 1_{ij}^{\text{obj}} [ (x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 ] + \lambda_{\text{corrd}} \sum_{i=1}^{s^2} \sum_{j=1}^B 1_{ij}^{\text{obj}} (r_i - \hat{r}_i)^2 \quad (3)$$

其中:  $\lambda_{\text{corrd}}$  为误差的权值;  $s^2$  为输入图像的网格数;  $B$  为每个网格生成的边界框数;  $1_{ij}^{\text{obj}}$  为参数, 其值为 1 或者 0, 当第  $i$  行第  $j$  列中的网格中存在结构面时, 参数值为 1, 否则为 0;  $(\hat{x}_i, \hat{y}_i, \hat{r}_i)$  为预测边界圆的中心坐标和半径;  $(x_i, y_i, r_i)$  为真实边界圆的中心坐标和半径. 设置  $\lambda_{\text{corrd}}$  参数值为 5,  $s^2$  为 7,  $B$  为 9. IOU 误差值计算式如下

$$\text{IOU Loss} = \sum_{i=0}^{s^2} \sum_{j=0}^B 1_{ij}^{\text{obj}} (-c_i \log \hat{c}_i) + \lambda_{\text{noobj}} \sum_{i=0}^{s^2} \sum_{j=0}^B 1_{ij}^{\text{noobj}} [ - (1 - c_i) \log (1 - \hat{c}_i) ] \quad (4)$$

其中:  $c_i$  为真实值的置信度;  $\hat{c}_i$  为预测值的置信度; 设置  $\lambda_{\text{noobj}}$  参数值为 0.5. 分类误差值计算式如下

$$\text{Classification Loss} = \sum_{i=0}^{s^2} \sum_{j=1}^B 1_{ij}^{\text{obj}} \sum_{c \in \text{classes}} [ -p_i(c) \log \hat{p}_i(c) - (1 - p_i(c)) \log (1 - \hat{p}_i(c)) ] \quad (5)$$

其中:  $c$  为检测目标的分类;  $p_i(c)$  为目标的真实概率;  $\hat{p}_i(c)$  为目标的预测分类概率.

**1.1.5 精度测试** 为了更加准确地衡量 YOLO v4 的性能, 采用的评价指标为平均精度 (Average Precision, AP). 平均精度是数据样本中含有结构面的准确率 (Precision) 和召回率 (Recall) 的评价指标, 准确率和召回率的计算式如下

$$Precision = \frac{TP}{TP + FP} = \frac{TP}{n} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

其中:  $TP$  表示真阳性 (True Positive); 当值小于设置的阈值时, 为  $FP$ , 即假阳性 (False Positive);  $FN$  为假阴性 (False Negative), 即预测图像中不存在结构面, 但实际图像中确实存在结构面. 根据检测结果绘制一条纵轴为精确率、横轴为召回率的 P-R 曲线, 平均精度值即为 P-R 曲线的面积, 其计算式为

$$AP = \frac{\sum Precision}{Recall} \quad (8)$$

## 1.2 结构面几何参数计算

### 1.2.1 正弦函数拟合

钻孔一般为圆柱体, 结构面在钻井中与钻孔相交为一个平面, 一个标准的结构面与钻井孔壁的交线呈三维椭圆形状. 若将钻孔沿着竖直方向展开, 钻孔的二维展开图为矩形, 而结构面的展开图为一沿着水平方向展布的正弦曲线, 如图 6 所示. 从几何角度分析, 结构面所在的平面与水平面的夹角为倾角 ( $\beta$ ), 拟合的正弦曲线的中间值所在位置为深度 ( $d$ ), 拟合的正弦曲线上边缘与下边缘的距离为结构面的视张开度 ( $A_a$ ), 拟合的正弦曲线的最小值点所对位置沿着顺时针方向与正北方向的夹角为倾向 ( $\alpha$ ). 若结构面的深度越大, 则正弦曲线的中间值越大; 若结构面的倾向越大, 正弦曲线的极小值点越靠近右边缘; 若结构面的倾角越大, 正弦曲线的振幅越大. 因此可以拟合结构面在钻孔图像中的正弦曲线, 通过正弦曲线的系数计算出结构面的几何参数.

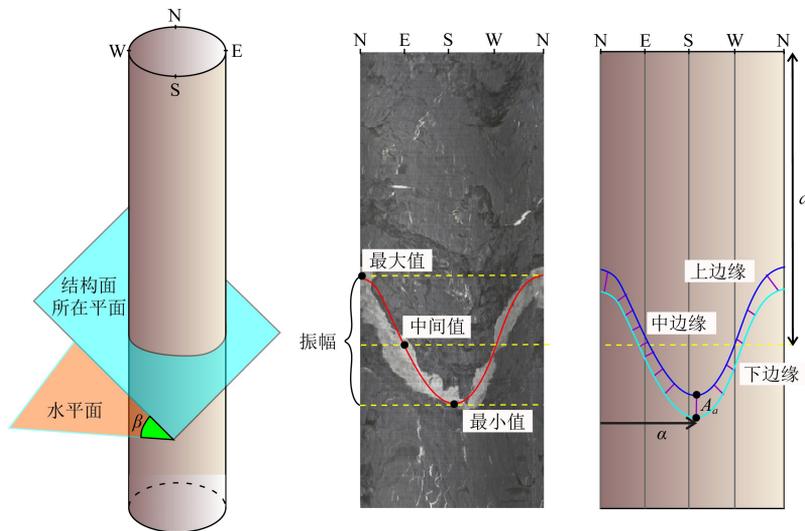


图 6 正弦曲线拟合计算几何参数原理

Fig.6 Schematic diagram of geometric parameters for sinusoidal curve fitting

### 1.2.2 参数计算

首先将定位的结构面采用 Canny 算法获取岩体结构面边缘, 依据结构面的边缘识别结果拟合上、中、下正弦曲线的轮廓, 得到 3 个拟合正弦函数. 再计算上、

中、下结构面的拟合正弦函数表达式,求取其参数,正弦函数式如式(9)所示.依据正弦曲线的系数计算结构面的几何参数(倾向、倾角、深度、张开度),倾向、倾角、深度由中边缘正弦曲线函数式的参数计算,张开度由上、下边缘正弦曲线函数式的参数计算,详细计算式如下<sup>[32]</sup>

结构面正弦拟合曲线函数

$$j = P_1 - P_2 \sin\left(i \frac{2\pi}{N} + P_3\right) \quad (9)$$

倾向

$$\alpha = \begin{cases} P_3 + 270^\circ (0^\circ \leq P_3 \leq 90^\circ) \\ P_3 - 90^\circ (90^\circ \leq P_3 \leq 360^\circ) \end{cases} \quad (10)$$

倾角

$$\beta = \arctan \frac{2KP_2}{D} \quad (11)$$

深度

$$d = \frac{1}{N} \sum_{i=1}^N j_{mi} \quad (12)$$

张开度

$$\begin{cases} A_a = \frac{1}{N} \sum_{i=1}^N (j_{ui} - j_{li}) \\ A = A_a \cos(\beta) \end{cases} \quad (13)$$

其中:( $i, j$ )分别为输入图像的像素坐标,即第 $i$ 行第 $j$ 列像素; $N$ 为输入图像中像素的总数; $P_1, P_2, P_3$ 均为拟合的正弦曲线的期望参数; $K$ 为在竖直方向上两个相邻像素之间的真实距离,反映图像分辨率( $K = 5.5\text{mm}$ ,分辨率为 $16.93$ 像素/ppi); $D$ 为钻孔直径( $D = 91\text{mm}$ ); $j_{mi}$ 为拟合正弦曲线中边缘中的第 $i$ 个像素的深度坐标; $j_{ui}$ 和 $j_{li}$ 分别为拟合正弦曲线上、下边缘中正弦波中对应像素点的深度坐标; $A$ 为张开度, $A_a$ 为视张开度.

## 2 典型案例

### 2.1 工程概况

选取的工程案例为某隧道工程,工程位于永州市东安县芦洪市镇内.工程采用单洞双线形式,全长为 $5\,512.38\text{m}$ .工程区位于剥蚀丘陵区,地势起伏较大,海拔高度为 $310 \sim 480\text{m}$ .丘坡呈长条状“人”字形分布,山体走向与线路走向基本一致,横向两侧自然坡度陡峭,相对高差为 $20 \sim 80\text{m}$ ,丘坡坡度为 $10^\circ \sim 50^\circ$ .隧道区出露的地层有第四系全新统(Q)、泥盆系上统余田桥组( $D_3s$ )、泥盆系中统棋子桥组( $D_2q$ )、泥盆系中统跳马涧组( $D_2t$ )和奥陶系下统中段( $O_1^2$ )等.隧道在洞身范围内节理密集,节理较发育,岩体较破碎.工程区地处祁阳弧形构造部位,地质构造复杂,主要由一系列呈弧形分布的背向斜、压性断裂、旋卷构造以及派生的“多”字形构造共同组成,断层破碎带内节理较发育,岩体较破碎.

### 2.2 数据处理

使用智能钻孔光学成像仪采集钻孔孔壁图像.该仪器是一套全新的先进智能型勘探

设备,采用2 000万像素的近180°全景视角的数字电视成像仪.钻孔图像的现场采集照片如图7所示.JL-IDOI(D)智能钻孔光学成像仪自身携带光源,可在黑暗的环境下正常工作;且使用了目前最先进的DSP图像采集技术,可以360°无死角地对钻孔孔壁进行拍摄,获取的孔壁图像非常清晰.并可对于采集的孔壁图像自动生成深度和方位,方便后期钻孔图像的处理拼接工作.使用某隧道工程的4号和6号钻孔作为数据源,4号孔深为213m,6号孔深为80.4m.两个钻孔编号分别为ZK4和ZK6.利用智能钻孔光学成像仪获取的两个钻孔孔壁图像需要进行前期的数据处理,将钻孔图像进行分割,得到约1 500张像素为277×244的钻孔图像.从大量的图像中筛选出包含结构面的图像,剔除掉没有结构面的图像,最终共获得194张岩体结构面图像,将其作为数据集的原始照片.



图7 研究区现场照片

Fig.7 The site photo in study area

**2.2.1 数据集的构建** 首先,利用MATLAB软件中的APP Image Label对图像进行标记,构建Ground truth数据集.Ground truth即对具有结构面的图片进行标注,使用矩形框标定结构面的位置.图8为典型的含结构面的图像标注过程截图.值得注意的是,在使用矩形框标注的时候,需要仔细地辨别结构面的位置,尽量保证标注的矩形框能够准确无误地标定结构面的位置;同时又使矩形框尽量小,以使后续训练的模型能更加精准地定位结构面.因此Ground truth的建立对整个模型至关重要,需要花费大量的时间、精力,而且需要由熟练掌握地质常识,对各种断层、裂隙、结构面认识全面的地质工作者完成,避免由于人工标注不准确而影响模型定位精度<sup>[33]</sup>.为保证模型的准确性,将标注完成的194张结构面组建成数据集并将其分为3部分,分别为训练集、验证集和测试集.训练集和验证集参与模型的训练,测试集不参与训练,仅用来测试模型的训练效果.随机选择数据集的70%作为训练集,用来训练YOLO v4模型;随机选择数据集的10%(19张图像)作为验证集,参与训练过程,用来初步验证模型的训练准确率;剩余的20%(39张图像)作为测试集,用于生成P-R(Person-Recall)曲线,测试模型的识别精度.若P-R曲线的平均精度低于0.8,则需调整参数,重新训练模型.



图 8 Ground truth 构建过程截图

Fig.8 Screenshot of Ground truth construction process

**2.2.2 数据增强** 目前有许多方法可以进行数据增强,例如将图片水平翻转、垂直翻转、随机裁剪、颜色抖动等等.采用色调、饱和度、亮度(HSV)色彩空间颜色抖动、水平翻转两种不同处理方式进行组合.首先,使用 HSV 色彩空间颜色抖动方法,HSV 即色调(Hue,  $H$ )、饱和度(Saturation,  $S$ )、亮度(Value,  $V$ ),是一种将 RGB 色彩空间中的点在倒圆锥体中的表示方法,如图 9 所示.色调用角度度量,  $0^\circ$  为起点,沿着逆时针旋转,终点为  $360^\circ$ .颜色从  $0^\circ \sim 360^\circ$  依次为红色、黄色、绿色、青色、蓝色、品红色.饱和度表示颜色接近光谱色的程度,取值  $0 \sim 100\%$ .饱和度为 0 时,颜色为白色;饱和度越大,颜色越接近光谱色.亮度表示颜色明亮的程度,对于光源色,明度值与发光体的光亮度有关;对于物体色,此值和物体的透射比或反射比有关.通常取值为  $0$  (黑)  $\sim 100\%$  (白).

具体的操作步骤:首先,将原始图像的所有像素的饱和度和值(HSV 色彩空间的  $S$  和  $V$  分量)提高到两者之间的功率 0.25 倍,将这些值乘以 0.7 和 1.4 之间的因子,并将其加上 0.1,得到新的数据图像<sup>[34]</sup>;其次,采用水平对称的处理方法,将图片水平对称生成新的图片.

YOLO v4 模型可以从海量数据中提取大量特征,适合针对大量数据集的训练.为了增加训练集的数量,使用数据增强操作来扩大训练集.如图 10 所示,1 张图像经过数据增强之后,数量可以扩大为 3 张图像,加上原始图像本身,数量共扩大 4 倍.即 136 张训练集图像经过数据增强操作,训练集可以达到 544 张图片(石新丽等<sup>[35]</sup> 研究证明,训练集样本数量大于 300 即可满足深度学习训练要求),满足 YOLO v4 模型需要大量训练数据集的要求.值得注意的是,数据增强仅仅应用到训练集中,测试集和验证集不进行数据增强处理.

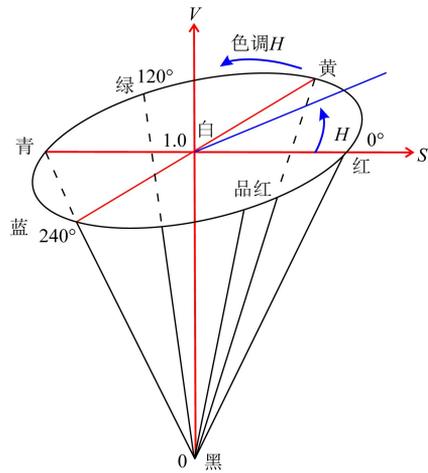


图 9 HSV 颜色空间模型

Fig.9 HSV color space model

因此,最终应用到研究的数据库为:训练集 544 张结构面图像、验证集 19 张结构面图像、测试集 39 张结构面图像,共计 602 张图像.由于是在已经预训练好的模型上进行迁移学习训练,因此只需将数据加入到训练集中重新训练即可,而不需要大量的训练样本,这也是迁移学习的优势<sup>[36-37]</sup>.

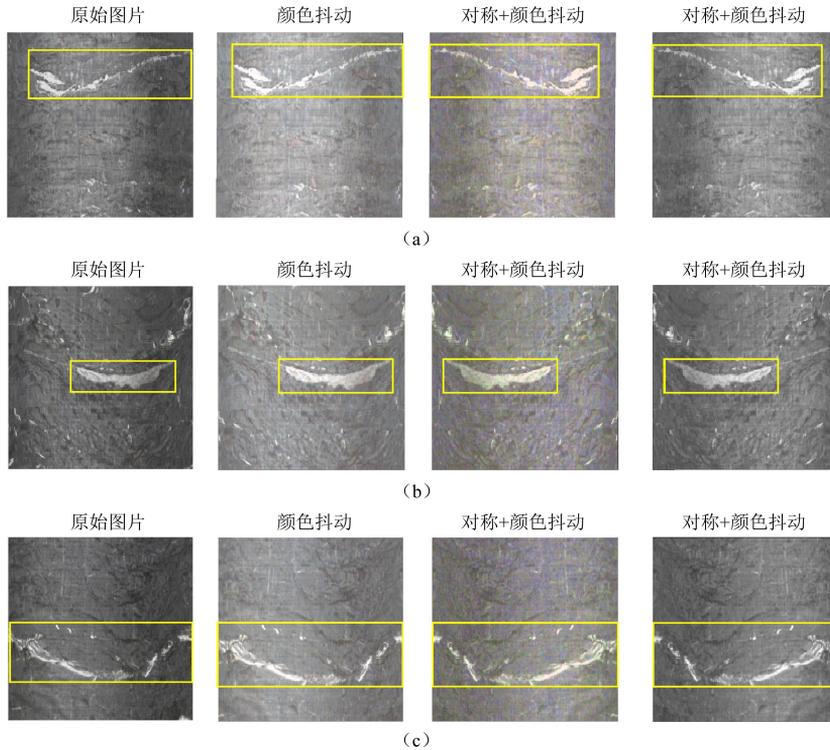


图 10 3 个图像的数据增强处理

Fig.10 Data enhancement processing of three images

### 2.3 模型训练

训练过程中电脑的性能对模型训练的准确率无任何影响,但是电脑性能过低时,只能使用较小的 Batch size 进行训练,此时模型拟合所需要的实际时间会加长,这会降低模型的实际使用效率.因此选择性能较好的专业工作站完成,使用的计算机详细参数如表 1 所示.

表 1 计算机详细参数

Table 1 Detailed computer parameters

硬件	参数
Windows 版本	Windows 10 家庭版
处理器	Intel® Core™ i7-9750H 2.60GHz 2.59GHz
GPU	NVIDIA GeForce GTX 1050Ti GPU
安装内存	32G of RAM
系统类型	64 位操作系统
购买日期	2021 年 1 月

YOLO v4 模型在训练时,输入图像的像素必须为 32 的倍数,因此将训练集的结构面图像缩放为  $256 \times 256$  进行输入.训练和测试框架均在 MATLAB 软件进行.在模型训练过程中,需要使用试错法不断地调试训练参数,直到模型训练和验证的损失率达到最低(小于 1)<sup>[38-39]</sup>,

同时保证测试集的 P-R 曲线的平均精度值尽可能高(大于 0.8),此时的训练参数为模型的最优参数.不同的训练参数会严重影响模型的识别效果,因此需要花费大量的时间不断调试.模型最优参数如表 2 所示.

表 2 模型最优训练参数

Table 2 Optimal training parameters of the model

参数类型	参数值	参数类型	参数值
激活函数	adam	复位输入归一化	false
输入图像像素	256×256×3	Shuffle	every-epoch
梯度衰减系数	0.9	L2Regularization	0.0005
平方梯度衰减因子	0.999	Verbose 频率	20
初始学习率	0.0001	验证频率	1000
学习率表	none	道路检查站	tempdir
小批量	4	批量规范化统计	moving
轮数	150		

### 3 实验结果

#### 3.1 YOLO v4 识别结果

使用最优参数在经过一段时间的训练之后, YOLO v4 模型训练完成, 其训练过程的损失函数如图 11 所示. 模型在训练轮数达到约 1 000 次时收敛, 在约 4 200 次时训练停止. 训练集在前期(训练轮数约 400 次时)迭代中损失值快速缩减, 模型快速拟合, 在训练轮数达到约 400 次之后基本收敛, 损失率逐渐趋近于 0.

钻孔图像的长度一般较长, 为了统一图像规格, 也便于模型识别, 统一将 4 号钻孔的图像以 0.5m 的长度平均分成若干段图片, 作为输入图像, 输入到训练完成的 YOLO v4 模型中. 模型自动识别定位结

构面, 定位结果如图 12 所示(矩形框内为识别定位的结构面, 模型同时输出检测到的结构面数量). 从视觉对比效果来看, 大部分的结构面识别定位均很好. 结构面下边缘存在部分条纹干扰(图 12(b)~图 12(d)), 会对定位结果产生影响, 造成矩形定位框的下边缘略大于真实结构面的位置. 但是整体而言, 模型定位结构面较为准确, 可很好地框定结构面位置. 此外, 还设置手动微调步骤, 对于识别定位相对不准确的结构面(图 12(f))定位矩形框的左、右宽度和上、下高度略小于实际情况, 可以在拟合上、下正弦曲线时进行微调定位框, 确保整个结构面能够识别, 不影响几何参数的计算.

训练完成后, 将测试集的 39 张钻孔图像输入到训练好的网络模型中进行测试, 得到 YOLO v4 对测试集的检测结果, 生成 P-R 曲线及平均准确率, 如图 13 所示. P-R 曲线非常

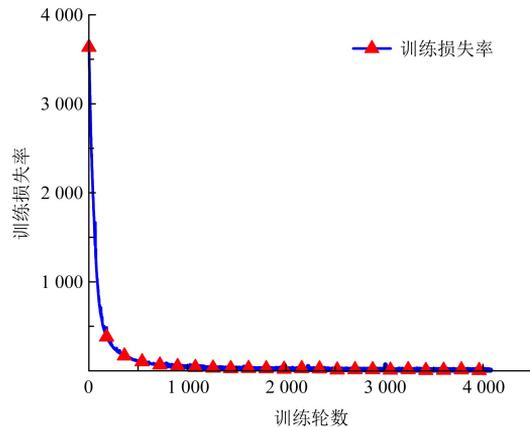


图 11 YOLO v4 训练损失率

Fig.11 The training loss rate for YOLO v4

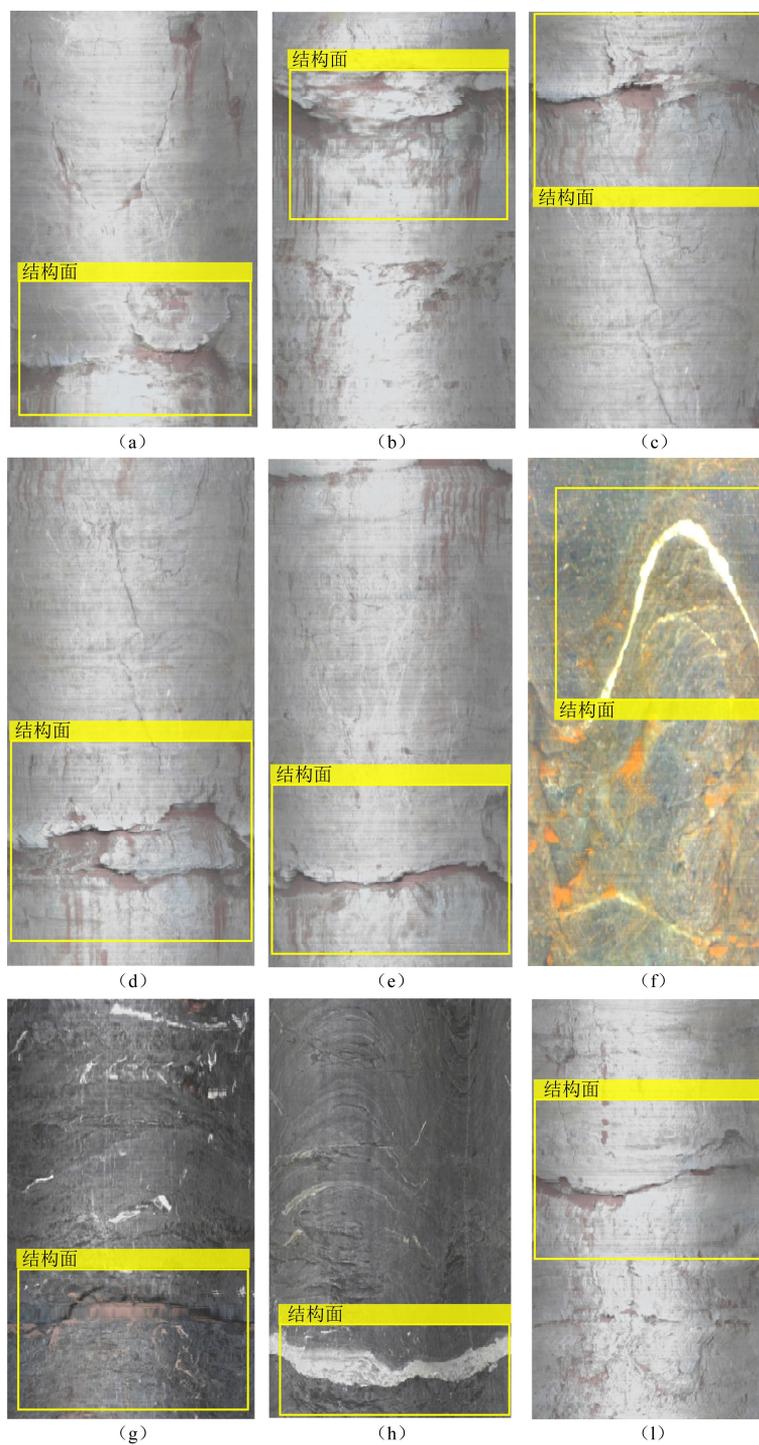


图 12 YOLO v4 模型自动识别定位结构面

Fig.12 Automatic identification and positioning of rock joints in YOLO v4

接近顶端值 1,平均准确率达到 0.87.这表明训练好的模型识别效果很好.

### 3.2 几何参数计算

以图 12(g)和图 12(i)所示的两个结构面为例,展示通过拟合正弦曲线计算结构面几何参数的计算结果.采用 Canny 算法获取岩体结构面边缘并依据边缘识别结果拟合上、中、下结构面,拟合的曲线如图 14 所示,结构面的上、下边缘如图 14(c)、图 14(e)所示,结构面张开度为上下边缘曲线区间内竖向线段填充区.图 12(g)所示结构面左侧张开度较大,而右侧结构面闭合,因此拟合的

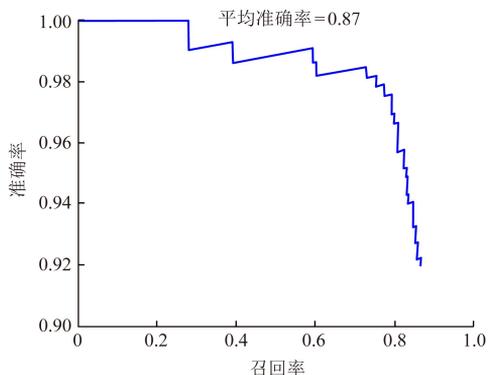


图 13 测试集 P-R 曲线

Fig.13 P-R curve of test set

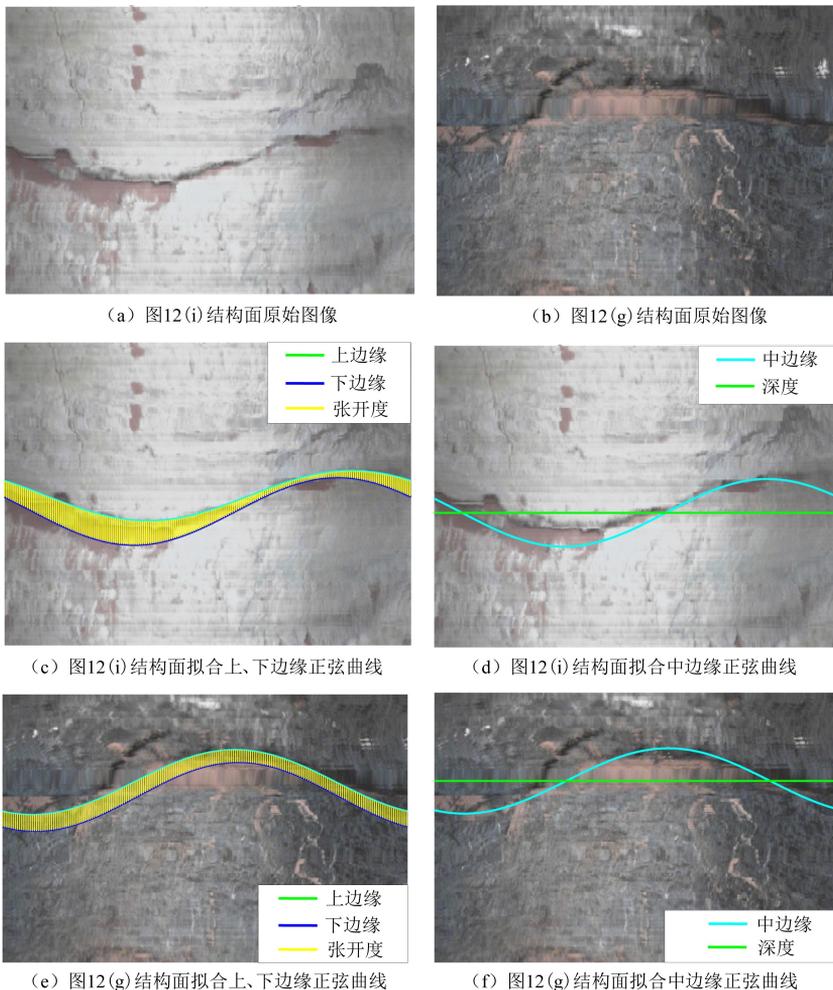


图 14 结构面拟合图

Fig.14 Fitting diagram of rock joint

上、下正弦曲线并不平行.从图中可见,上、下结构面边界拟合均较为吻合,3个结构面的上、下边界均位于正弦曲线内.图14(d)、图14(f)中曲线为拟合中边缘正弦曲线,直线代表结构面深度位置.从图14中可见,图12(g)和图12(i)所示两个结构面的中边缘正弦曲线和结构面拟合效果很好,正弦曲线可很好地覆盖结构面.

将图12所示的9处结构面一一进行拟合,并将拟合的正弦曲线参数代入公式(9)~公式(13),计算得出结构面的4个几何参数.为了更加直观地展示各参数结果,选择以柱状图的形式展示几何参数,如图15所示(4个几何参数结果均保留3位小数).

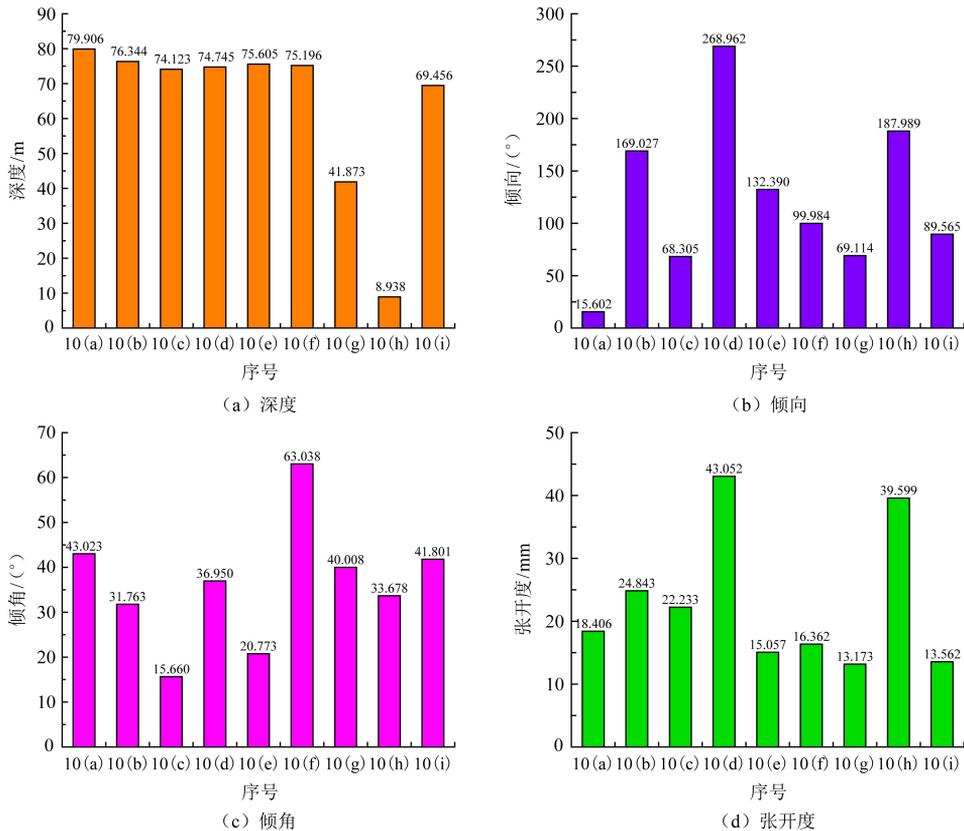


图15 结构面的4个几何参数

Fig.15 Four geometric parameters of the rock joints

## 4 讨论

虽然深度学习模型可以较好地识别定位结构面并计算结构面几何参数,但是仅适用于本研究区的钻孔图像结构面识别.例如针对4号钻孔的结构面识别效果很好,但是若换成其他研究区的钻孔图像,最终的识别效果也不理想.这是由于不同区域的地层岩性及结构面的充填类型等不同,形成的钻孔图像颜色不同,模型不能进行识别.但是本文所提的方法是适用的,可以在训练样本中加入新区域的图片进行重新训练,此时所获得的模型就可以对新的区域进行预测和识别.此外,当图像中含有多个结构面时,不同的结构面之间

会对模型的识别结果产生干扰.当结构面距离较近时,模型识别定位会不准确,输出错误的识别数量;结构面距离较远时,影响较小.如图 16 所示,虽然模型能够框定出结构面的位置,但是下部的两个结构面位置非常接近,两个结构面之间互相影响,模型会产生误判,仅识别出 1 个结构面,而实际图像中有 2 个结构面.模型在识别定位上部结构面时,受到下部结构面的影响,导致定位矩形框下边界过大.

由于研究数据有限,仅采集了 4 号和 6 号两个钻孔的孔壁图像,数量较少.最终只对 4 号钻孔结构面密集区进行了结构面识别,并未对整个岩心钻孔全部识别.此外,所建立的结构面识别定位模型的输入图像必须是经过前期数据处理的图像.图像长度必须统一(统一长度为 0.5m),若长度不统一,部分图像识别的准确率会降低;且输入图像不包含左侧深度标识,但是井下电视设备获取的钻孔孔壁图像均包含深度标识.因此模型目前不能实现实时检测,即不能实现在钻孔电视录像的同时,直接识别出结果面.这两点均限制了该模型的进一步实际应用.因此,笔者仍然会进一步对其改进,以增加 YOLO v4 模型的实际应用性.

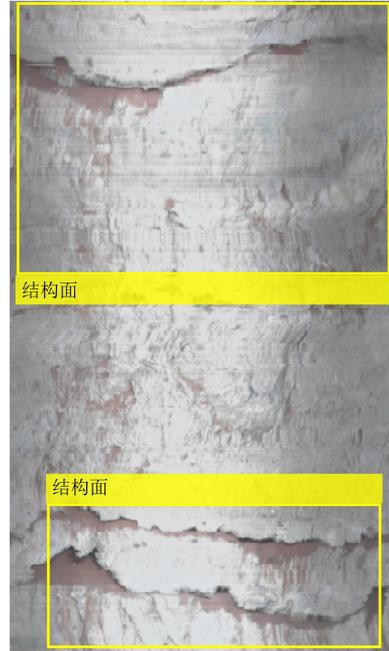


图 16 多个结构面识别定位结果  
Fig.16 Results of identification and location on multiple rock joints

## 5 结论

笔者提出了一种基于深度学习的钻孔图像识别方法,使用最新的 YOLO v4 算法,重新构建了数据集,进行了钻孔图像的结构面识别定位,并依据定位结果获取了这些结构面的 4 个几何参数.将基于深度学习的钻孔图像识别的方法应用到某隧道工程案例中,成功计算出钻孔的结构面几何参数.得出结论如下:

(1) 选取某隧道工程的 4 号和 6 号钻孔作为数据源,使用智能钻孔光学成像仪采集钻孔孔壁图像,并对采集的图像进行分割筛选,选取其中包含结构面的图像(194 张).使用 MATLAB 软件中的 APP Image Label 构建结构面的 Ground truth,并将数据集分成训练集(70%)、验证集(10%)、测试集(20%)3 部分,训练集 136 张图像使用数据增强处理得到 544 张图像;

(2) 使用 CSPDarkNet53 网络作为 YOLO v4 的特征提取网络,构建 YOLO v4 模型.使用数据增强处理后的训练集来训练模型,使用验证集在模型训练过程中实时验证模型的训练准确度.使用测试集生成 P-R 曲线,测试模型的最终训练效果,寻找最优参数.测试集的 P-R 曲线平均准确度达 0.87.训练完成的 YOLO v4 模型实现了 4 号钻孔的 9 个结构面的定位,结果显示,模型的定位矩形框非常贴合结构面位置,识别定位的准确率较高;

(3) 使用正弦函数拟合结构面上、中、下 3 个边界,计算结构面的 4 个几何参数:倾

向、倾角、深度与张开度.计算4号钻孔的9个结构面图像几何参数,并将几何参数结果汇总成图.研究表明,YOLO v4模型可以识别定位钻孔图像中的结构面,并能进行几何参数的计算;

(4)值得注意的是,该深度学习模型仅对案例中的两个钻孔适用,应用到其他工程区域需要进行适当改善,这是因为不同工程区域地质条件(如地层、岩性及结构面的充填类型等)不同,模型的训练样本可能不包含其他工程区域的特征.但是所提的方法是适用的,可以在训练样本中加入新的工程区域的照片进行重新训练,所获得的模型就可以对新的工程区域进行识别和计算.

### 参考文献

- [ 1 ] Schepers R, Rafat G, Gelbke C, et al. Application of borehole logging, core imaging and tomography to geotechnical exploration[J]. International Journal of Rock Mechanics and Mining Sciences, 2001, 38(6): 867-876
- [ 2 ] 孙广忠.论“岩体结构控制论”[J].工程地质学报, 1993, 1(1): 14-18  
Sun Guangzhong. On “Cybernetics of rock structure”[J]. Journal of Engineering Geology, 1993, 1(1): 14-18
- [ 3 ] Coli N, Pranzini G, Alfi A, et al. Evaluation of rock-mass permeability tensor and prediction of tunnel inflows by means of geostructural surveys and finite element seepage analysis[J]. Engineering Geology, 2008, 101(3-4): 174-184
- [ 4 ] Deng Zhaopeng, Cao Maoyong, Laxmisha Rai. Horizontal fracture recognition of borehole image based on improved region growing and hough transform[J]. Science Technology and Engineering, 2019, 19(31): 239-245
- [ 5 ] 许振浩, 马文, 李术才, 等. 岩性识别: 方法、现状及智能化发展趋势[J]. 地质论评, 2022, 68(6): 2290-2304  
Xu Zhenhao, Ma Wen, Li Shucui, et al. Lithology identification: Method, research status and intelligent development trend[J]. Geological Review, 2022, 68(6): 2290-2304
- [ 6 ] 黄磊, 唐辉明, 葛云峰, 等. 适用于半迹长测线法的岩体结构面直径新试算法[J]. 岩石力学与工程学报, 2012, (1): 140-153  
Huang Lei, Tang Huiming, Ge Yunfeng, et al. A new test algorithm for rock mass disjoint diameter based on semi-trace long line method[J]. Chinese Journal of Rock Mechanics and Engineering, 2012, (1): 140-153
- [ 7 ] 陈剑平, 王清, 赵红亮. 窗口测线法获取岩体RQD[J]. 岩石力学与工程学报, 2004, (9): 1491-1495  
Chen Jianping, Wang Qing, Zhao Hongliang. Rock mass RQD obtained by window line method[J]. Chinese Journal of Rock Mechanics and Engineering, 2004, (9): 1491-1495
- [ 8 ] 周晓敏, 孟晓林, 张雪萍, 等. 倾斜摄影测量的城市真三维模型构建方法[J]. 测绘科学, 2016, (9): 159-163  
Zhou Xiaomin, Meng Xiaolin, Zhang Xueping, et al. Oblique photogrammetry for urban three-dimensional model construction[J]. Science of Surveying and Mapping, 2016, (9): 159-163
- [ 9 ] 徐思奇, 黄先锋, 张帆, 等. 倾斜摄影测量技术在大比例尺地形图测绘中的应用[J]. 测绘通报, 2018, (2): 111-115  
Xu Siqi, Huang Xianfeng, Zhang Fan, et al. Application of tilt photogrammetry in large scale topographic map mapping[J]. Bulletin of Surveying and Mapping, 2018, (2): 111-115
- [ 10 ] 徐进军, 王海城, 罗喻真, 等. 基于三维激光扫描的滑坡变形监测与数据处理[J]. 岩土力学, 2010, (7): 2188-2191+2196  
Xu Jinjun, Wang Haicheng, Luo Yuzhen, et al. Landslide deformation monitoring and data processing based on 3D laser scanning[J]. Rock and Soil Mechanics, 2010, (7): 2188-2191+2196
- [ 11 ] 吴静, 靳奉祥, 王健. 基于三维激光扫描数据的建筑物三维建模[J]. 测绘工程, 2007, (5): 57-60  
Wu Jing, Jin Fengxiang, Wang Jian. Building 3D modeling based on 3D laser scanning data[J]. Engineering of Surveying and Mapping, 2007, (5): 57-60
- [ 12 ] Vöge M, Lato M J, Diederichs M S. Automated rockmass discontinuity mapping from 3-dimensional surface data[J]. Engineering Geology, 2013, 164: 155-162
- [ 13 ] Dewez T J B, Girardeau-Montaut D, Allanic C, et al. Facets: A cloudcompare plugin to extract geological planes from unstructured 3D point clouds[J]. ISPRS-International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, 2016, 41: 799-804

- [14] Li S J, Feng X T, Wang C Y, et al. ISRM suggested method for rock fractures observations using a borehole digital optical televiewer[J]. *Rock Mechanics and Rock Engineering*, 2013, 46(3): 635-644
- [15] 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
- [16] Wang C, Zou X, Han Z, et al. The automatic interpretation of structural plane parameters in borehole camera images from drilling engineering[J]. *Journal of Petroleum Science and Engineering*, 2017, 154: 417-424
- [17] Assous S, Elkington P, Clark S, et al. Automated detection of planar geologic features in borehole images[J]. *Geophysics*, 2014, 79(1): D11-D19
- [18] Zhou W, Maerz N H. Implementation of multivariate clustering methods for characterizing discontinuities data from scanlines and oriented boreholes[J]. *Computers & Geosciences*, 2002, 28(7): 827-839
- [19] Dias L O, Bom C R, Faria E L, et al. Automatic detection of fractures and breakouts patterns in acoustic borehole image logs using fast-region convolutional neural networks [J]. *Journal of Petroleum Science and Engineering*, 2020, 191: 107099
- [20] Zou Xianjian, Wang Chuanying, Han Zengqiang, et al. Research on automatic recognition method of structural plane in panoramic borehole image[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2017, 36(8): 1910-1920
- [21] Song Kun, Sun Chi, An Dong, et al. Intelligent identification method for rock discontinuities properties by digital borehole panoramic image[J]. *Bulletin of Geological Science and Technology*, 2020, 39(5): 17-22
- [22] Wu Jian, Feng Shaokong, Li Hongjie. Research on automatic interpretation of structural planes in borehole imaging[J]. *Rock and Soil Mechanics*, 2011, 32(3): 951-957
- [23] 金鹏祥, 李丹. 基于YOLOX模型在疫情背景下人脸识别中的应用[J]. *长江信息通信*, 2022, (1): 1-2+6  
Jin Pengxiang, Li Dan. Face recognition based on YOLOX model in the context of COVID-19 [J]. *Changjiang Information and Communication*, 2022, (1): 1-2+6
- [24] 刘德祥, 梁苗, 王钰棋. 改进Faster-RCNN的工程车辆识别方法[J]. *城市勘测*, 2023, (1): 110-113  
Liu Dexiang, Liang Miao, Wang Yuqi. Improving the identification method of engineering vehicle for Faster-RCNN [J]. *Urban Survey*, 2023, (1): 110-113
- [25] Shinde S, Kothari A, Gupta V. YOLO based human action recognition and localization[J]. *Procedia Computer Science*, 2018, 133: 831-838
- [26] Dias L O, Bom C R, Faria E L, et al. Automatic detection of fractures and breakouts patterns in acoustic borehole image logs using fast-region convolutional neural networks [J]. *Journal of Petroleum Science and Engineering*, 2020, 191: 107099
- [27] Su Yutong, Yang Weiyi, Li Junlin. Intelligent recognition method of borehole image fractures for coal and rock based on YOLO v3[J]. *Safety in Coal Mines*, 2021, 52(4): 156-161
- [28] 白钰杰, 裴以建, 朱秀军. 基于改进YOLOv4模型的乳腺钼靶图像肿块检测[J]. *计算机工程与科学*, 2023, (4): 654-664  
Bai Yujie, Pei Yijian, Zhu Xiujun. Detection of breast mass based on modified YOLOv4 model [J]. *Computer Engineering and Science*, 2023, (4): 654-664
- [29] 石颢, 马文琪, 吴宏杰. 改进YOLOv4的混凝土建筑裂缝检测算法[J]. *微电子学与计算机*, 2023, (3): 56-66  
Shi Jie, Ma Wenqi, Wu Hongjie. Improved YOLOv4 crack detection algorithm for concrete buildings [J]. *Microelectronics and Computers*, 2023, (3): 56-66
- [30] 王卫星, 刘泽乾, 高鹏, 等. 基于改进YOLOv4的荔枝病虫害检测模型[J]. *农业机械学报*, 2023, 54(5): 227-235  
Wang Weixing, Liu Zeqian, Gao Peng, et al. Lychee pest detection model based on improved YOLOv4 [J]. *Transactions of the Agricultural Machinery Society*, 2023, 54(5): 227-235
- [31] Gai R, Chen N, Yuan H. A detection algorithm for cherry fruits based on the improved YOLO-v4 model [J]. *Neural Computing and Applications*, 2021: 1-12
- [32] Ge Y, Du B, Tang H, et al. Rock joint detection from borehole imaging logs based on grey-level co-occurrence matrix and Canny edge detector [J]. *Quarterly Journal of Engineering Geology and Hydrogeology*, 2022, 55(1): qjgeh2021-016
- [33] Fan Z, Wu Y, Lu J, et al. Automatic pavement crack detection based on structured prediction with the convolutional neural network [J]. *ArXiv*, 2018: 1-19
- [34] 慕晓冬, 白坤, 尤轩昂, 等. 基于对比学习方法的遥感影像特征提取与分类[J]. *光学精密工程*, 2021, (9): 2222-2234  
Mu Xiaodong, Bai Kun, You Xuanang, et al. Feature extraction and classification of remote sensing image based on contrast learning method [J]. *Optics and Precision Engineering*, 2021, (9): 2222-2234

- [35] 石新丽,赵墨然,李海川,等.基于图像处理的玉米害虫种类识别系统研究[J].农业与技术,2021,41(12):28-31  
Shi Xinli,Zhao Moran,Li Haichuan,et al.Based on image processing of corn pest species identification system research [J].Journal of Agriculture and Technology,2021,41(12):28-31
- [36] 杜义康,罗建利,郭瑜.基于深度迁移学习的铁路隧道衬砌结构病害检测研究[J].昆明理工大学学报(自然科学版),2023,48(4):45-54  
Du Yikang,Luo Jianli,Guo Yu.Detection of railway tunnel lining structure defects based on deep transfer learning[J].Journal of Kunming University of Science and Technology (Natural Science Edition),2023,48(4):45-54
- [37] Li X,Xiong H,Wang H,et al.DELTA:Deep learning transfer using feature map with attention for convolutional networks [J].ArXiv,2019:1-13
- [38] 王培珍,余晨,薛子邯,等.基于迁移学习的煤岩壳质组显微组分识别模型[J].煤炭科学技术,2022,50(1):220-227  
Wang Peizhen,Yu Chen,Xue Zihan,et al.Transfer learning based identification model for macerals of exinite in coal [J].Coal Science and Technology,2022,50(1):220-227
- [39] 郑诚,陈杰,董春阳.结合图卷积的深层神经网络用于文本分类[J].计算机工程与应用,2022,58(7):206-212  
Zheng Cheng,Chen Jie,Dong Chunyang.Deep neural network combined with graph convolution for text classification [J].Computer Engineering and Applications,2022,58(7):206-212

## Detection of Rock Discontinuities in Borehole Images Based on a Deep Learning Method

LI Wei<sup>1</sup>, LIU Geng<sup>2,3</sup>, GE Yunfeng<sup>2</sup>, ZHANG Zhanrong<sup>1</sup>, HUANG Guoliang<sup>1</sup>

(1.China Railway Fourth Survey and Design Institute Group Co.,Ltd.,Wuhan 430063,China;2.Faculty of Engineering, China University of Geosciences (Wuhan),Wuhan 430074,China;3.Hunan Seismological Bureau,Changsha 410004, China)

### Abstract

Rock discontinuity has an important influence on the stability and permeability of the rock mass,thereby significantly determining the stability of deep underground engineering.This paper proposes a method based on a deep learning algorithm (You Only Look Once version 4,YOLO v4) for the identification and positioning of rock discontinuities and the calculation of geometric parameters using borehole images obtained by downhole television technology.First,image data is collected and preprocessed.For the tunnel project,the Intelligent Drilling Optical Imager equipment is used to collect images of borehol No.4 and No.6,and the images were processed to separate those containing rock discontinuities with annotations to create a Ground truth dataset, with 70% of the dataset randomly selected under data enhancement as training data,10% as verification data and 20% as test data.The CSPDarkNet53 was then used as the feature extraction network to build the YOLO v4 model,with optimal parameters determined through trial and error for model training.The test set was designed to generate the P-R (Precision-Recall) curve to test the final model training effect,and the result shows that the average precision of the P-R curve reaches 0.87,indicating that the training result of YOLO v4 is better.Finally,the Canny algorithm was used to obtain the edges of the rock discontinuities by fitting the upper,middle and lower sine functions to the localised structural surface,allowing the four geometric parameters (dip direction,dip angle,depth and aperture) to be calculated.

**Keywords:** rock mechanics; rock discontinuities; intelligent recognition; borehole television; deep learning; YOLO v4