

DOI: 10.11779/CJGE202112010

岩坡坡面裂隙网络智能识别与参数提取

张紫杉, 王述红*, 王鹏宇, 王存根

(东北大学资源与土木工程学院, 辽宁 沈阳 110819)

摘要: 作为高陡岩质边坡建模的重要先决条件, 快速精准地进行岩坡表面裂隙网络的参数化建模近年来成为了研究的热点。研究引入深度学习技术与智能算法聚类思想, 提出了一种结合无人机摄影技术的高陡边坡坡面裂隙网络智能识别与几何参数提取的方法。采用空洞卷积算法对传统 U-net 分割识别网络进行改进, 并运用 GMM-EM 算法对识别出的二值图中的裂隙进行聚类, 最后引入 RANSAC 算法实现裂隙面的几何参数自动提取并运用 DICE 相似系数对识别结果进行对比分析。结果表明, 该方法裂隙提取的准确率高于 97%, 相较于传统算法有所提高。同时, 将该方法应用于云南鲁奎山铁矿边坡工程, 实现了高陡岩坡表面裂隙信息的快速采集, 为后续高陡岩质节理边坡建模提供了必要的技术支撑。

关键词: 高陡岩质边坡; 岩体裂隙识别; 深度学习; U-net 网络; 高斯混合聚类

中图分类号: TU45 文献标识码: A 文章编号: 1000-4548(2021)12-2240-09

作者简介: 张紫杉(1990—), 男, 博士研究生, 主要从事岩体裂隙面智能识别方面的研究工作。E-mail: zhangzishan_neu@163.com。

Intelligent identification and extraction of geometric parameters for surface fracture networks of rocky slopes

ZHANG Zi-shan, WANG Shu-hong, WANG Peng-yu, WANG Cun-gen

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

Abstract: As an important prerequisite for modeling the high steep rocky slope, a fast and accurate parametric modeling for fracture networks of rocky slopes has become a popular research topic in recent years. Focusing on the deep learning and intelligent algorithmic clustering method, a UAV photography-based joint detection technique is proposed to identify and extract the geometric parameters of the fracture network on high steep slope surface. A dilated convolution is adopted to improve the traditional U-net segmentation network, and a GMM-EM algorithm is employed to cluster the segmented fractures on the binary images. Finally, a RANSAC algorithm is used to perform the extraction process of geometric parameter of the fracture network. Seen from the comparative results of DICE similar index, the accuracy of segmentation recognition is more than 97%, which shows that the proposed fracture extraction technique is more efficient and accurate than other traditional algorithms. The improved technique is applied to the slope of Lukushan open pit, implementing the in-site rapid data extraction of fracture networks on the slope surface. This technique may provide an effective technical support for the refined modeling of high and steep rocky slopes.

Key words: high and steep rocky slope; rock mass fracture identification; deep learning; U-net network; Gaussian mixture model

0 引言

作为高陡岩质边坡建模的重要先决条件, 快速精准地进行岩体表面裂隙网络的参数化构建越来越受到学者们的关注。近些年来, 围绕高陡边坡裂隙面的采集问题, 学者们提出了各种解决方案。目前比较主流的方法是先通过 Lidar 技术^[1]或摄影测量技术^[2]生成点云, 再通过解析点云进行裂隙平面的提取。Guo 等^[3]提出了运用多尺度边缘链检测方法提取点云中各结构面的交线; Zhang 等^[1, 4]提出了运用 ISODATA 算

法与区域增长法对岩体激光点云进行解析生成裂隙平面; Voge 等^[5]和 Chen 等^[6]通过对点云进行 K-means 聚类来提取岩体中的非连续面; Wang 等^[7]和 Chen 等^[8]通过 RANSAC 平面拟合技术实现岩体点云的三维平面提取; 贾曙光等^[9]运用轻小型无人机进行岩体三维空间解析建模并通过最小二乘法进行局部平面拟

基金项目: 国家自然科学基金项目(U1602232); 辽宁省重点研发项目(2019JH2/10100035)

收稿日期: 2021-03-08

*通信作者 (E-mail: shwang@mail.neu.edu.cn)

合; Pan 等^[10]运用地基激光扫描仪进行裂隙网络的重建。上述研究成果表明, 目前基于裂隙面的识别主要集中在对点云的处理和识别上。该类研究虽然可以较为准确地识别岩体三维空间裂隙面, 但对解算设备的计算能力要求较高。同时, 该类识别方法无法对平面内的裂隙进行识别。

随着计算机技术的发展, 各种基于深度学习技术的算法^[11], 尤其是用于边缘检测技术的算法正逐渐被应用到各类裂隙的解析与识别中。李尧等^[12]结合地质雷达结合 BP 网络进行岩块裂隙的识别; Zhang 等^[13]运用传统 U-net 网络对沥青路面裂隙进行扫描; 薛亚东等^[14]和黄宏伟等^[15]运用卷积神经网络对隧道衬砌的裂隙进行识别; 朱大庆等^[16]运用全卷积网络对砾石边缘进行检测; 薛东杰等^[17]运用 FCN 网络对岩体表面迹线进行识别; 王鹏宇等^[18]用 CNN 网络对不同裂隙分布岩体进行划分。上述学者将深度学习技术运用于各种岩体边缘与裂隙的识别中, 都达到了较为理想的效果。但同时, 在识别出图片中的裂隙网络之后, 对单一裂隙的提取与参数化表征却鲜有研究。在实际的岩体建模的过程中, 如何运用深度学习网络识别出的结果进行裂隙网络的参数化表征, 正是本研究希望解决的问题。

本研究致力于通过对深度学习网络 U-net 的改进, 提高复杂岩体表面裂隙的识别精度。同时结合 GMM-EM 分割算法, 对岩体平面裂隙网络进行快速识别与参数化表征。结合无人机摄影测量技术, 使该识别方法可以高效地应用于现场岩坡坡面裂隙的提取, 为现场实时裂隙面参数采集提供新的思路。

1 改进 U-net 网络的裂隙识别

1.1 U-net 简介

目前, 混凝土裂隙智能识别已经广泛的应用在包括隧道工程在内的一系列工程中^[13-15]。本文涉及的针对岩体裂隙的识别相较于传统对混凝土裂隙的识别, 具有种类更多样, 被测物体非均质性更强等特点。这使得在实际进行识别的过程中, 难度将大幅增加, 传统边缘检测算法已经不能很好地提取复杂岩体中的裂隙。因此本研究通过改进 U-net 网络, 寻找到了一种更加精确的岩体裂隙识别方法。

U-net 网络作为一种基于编码-解码技术的深度学习模型, 目前已经广泛地应用于生物医学工程、材料工程等学科物体边缘识别中^[19]。U-net 网络通过对样本图片进行降采样和上采样相结合地操作, 可以有效地对图像中的特征进行识别提取。相较于传统基于梯度变化的边缘检测技术, 该网络可以大大提高图像识别的鲁棒性, 减少过拟合风险并增加识别效率。同

时, 通过对不同卷积层级的图像进行特征提取, 可以有效地增加图像识别的感受野, 充分考虑了岩体裂隙识别过程中存在的尺寸效应。

1.2 数据集及标签

本研究的数据集主要来自于使用高清相机与无人机对被测岩体进行拍摄获得的高清图像。在实际数据集制作时, 为了增加图像训练集的样本数量, 采用了整图分割的方法, 如图 1 (a)。将高分辨率的原始图像与标注了裂隙的标签图像按相同的位置分割成 224×224 的标准大小样本。通过该方法共获得了 1323 张有效样本图像。运用这种方法可以增加有效样本的数量, 弥补训练集样本图像不足的问题; 同时, 标准化的样本集可以提高特征提取效率, 降低计算模型的收敛时间。

同时为了增加训练的鲁棒性, 对每一个分割出的数据样本进行旋转与多尺度处理。每张图片会以 22.5° 的增量进行旋转, 同时对于同一张图片进行 3 种不同尺度的图片取样 (见图 1 (b))。新图像的分割范围分别为原分割长度的 2 倍与 3 倍。这样一张被测图片样本通过变换就可以得到 48 个不同的训练样本。完成数据集的采集后, 将总体数据集按照 4:1 的比例随机分割成训练集与验证集, 共得到训练集样本 50800 张, 测试集样本 12700 张。

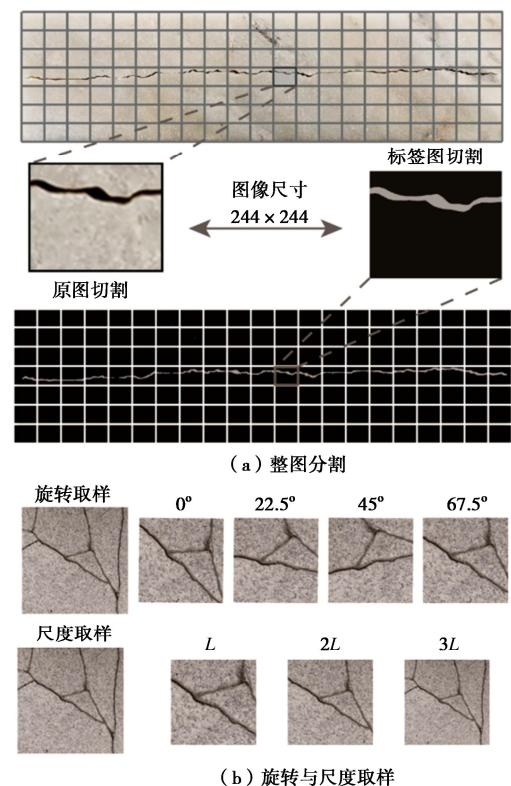


图 1 数据标签图的制作

Fig. 1 Diagram of data and label making

本研究依托 Pytorch 框架进行深度学习模型的搭

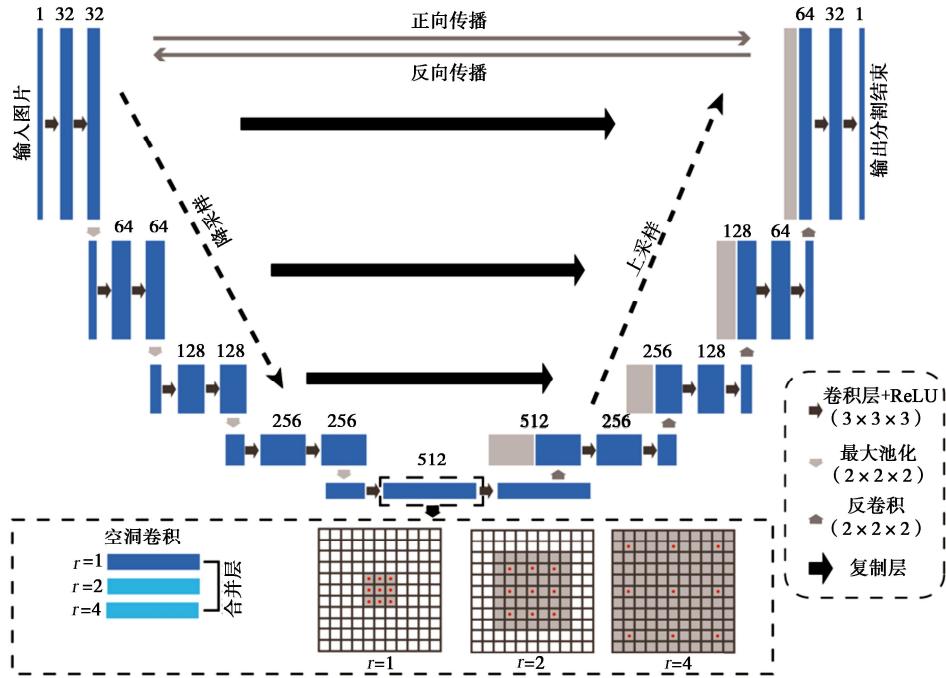


图 2 基于空洞卷积改进的 U-net 网络

Fig. 2 Dilated convolution-improved U-net network

建, 框架的整体结构如图 2 所示。整个 U-net 模型主要分为降采样与上采样 2 个部分。降采样部分主要负责从不同尺度的图片中进行特征提取, 并通过池化算法将图片尺度规模进行逐级减小, 以获得更多地卷积特征; 上采样部分主要用于特征图像还原, 通过反卷积算法将各层特征图片尺度进行扩增, 直至达到原始输入样本的尺寸规模。与传统的 FCN 网络不同, U-net 网络通过将多种维度的特征图拼接在一起, 可以更有效地提取不同尺度下图片的特性, 同时通过拼贴 (crop) 的方法, 尽可能多的保存每个卷积层中的卷积前图像的细节。具体计算设备参数见表 1。为了提高计算速度, 使用英伟达的 Cuda 技术进行 GPU 加速运算。

表 1 改进 U-net 网络计算参数

Table 1 Configuration of improved U-net network equipment

| 项目 | 参数 | 项目 | 参数 |
|-----|-------------------------|------|--------------|
| CPU | Intel i7-8500 | Cuda | 10.0 |
| GPU | NVIDIA Geforce GTX 1080 | 语言 | Python 3.6 |
| RAM | DDR 416G | 系统 | Vmware+linux |
| 框架 | Pytorch 1.7 | | |

1.3 改进 U-net 模型

针对岩体裂隙的识别过程中, 具有岩体复杂多变, 被测裂隙在图中像素占比较少等一系列特点, 同时也为了进一步提升数据集的特征提取效率, 本研究在特征提取时引入了空洞卷积的算法 (图 2)。空洞卷积 (dilated convolution) 是指在设计卷积核时, 在卷积核各元素中间用空洞进行占位, 核元素的间隔数

量称为该算法的空洞率。在常规的降采样过程中, 图像样本的分辨率会依次降低, 对识别精度带来影响。通过对空洞率 r 的控制, 可以有效地增加卷积核感受野范围, 在固定分辨率的基础上, 捕获更多不同尺度的特征信息。本文在对一个层级的图像样本进行卷积运算时, 分别引入了空洞率为 1, 2, 4 的 3 种卷积核, 将 3 次卷积运算的结果进行合并, 使得降采样后的结果可以包含更多维度的特征信息。尤其是在检测岩体裂隙时, 由于裂隙本身的粗细差别极大, 更多维度的特征采集可以显著地提高分割结果的准确率。

1.4 模型训练与识别结果

为了验证模型的收敛性与准确性, 主要通过交叉熵损失函数 (cross entropy loss) 与 DICE 相似系数对模型进行评价。交叉熵主要用来分析在训练过程中实际的输出值与期望的输出值之间的接近程度, 构建损失函数则为了衡量网络权重参数期望与实际输出期望之间的差异, 这种差异可用于反向传播中参数的修正更新, 通过迭代方法使模型识别结果更趋近于实际的标签值,

$$H(p, q) = - \sum_x (p(x) \lg q(x) + (1 - p(x)) \lg (1 - q(x))) \quad (1)$$

DICE 相似系数是一种判定图形分割结果优劣的技术指标, 它通过对比生成图片和标准图片之间的覆盖交并比例来判断识别结果的准确性,

$$DICE = \frac{2N_{TP}}{2N_{TP} + N_{FP} + N_{FN}} \times 100\% \quad (2)$$

式中 $p(x)$ 为期望输出的概率分布函数; $q(x)$ 为实际输出的概率分布函数; N_{TP} 为判定为正样本的事实正样本像素; N_{FP} 为指判定为正样本的事实负样本像素; N_{FN} 为判定为负样本的事实负样本像素。

模型训练过程与实时评价结果如图 3 所示。测试内容选取了图 4 中花岗岩图片作为预测匹配结果的样本。从损失函数曲线中可以看出, 整个计算模型的损失函数值随迭代步数呈一个明显下降的趋势, 并于 55 步时基本趋近于 0, 这说明整个训练模型的收敛性是非常好的。对比来看, 加入了空洞卷积技术的 U-net 模型在收敛的速度上与原始模型基本相同, 并具有更强的收敛性。从测试样本 DICE 相似系数的变化可以看出, 改进 U-net 模型从第 10 步迭代时开始图像的匹配, 第 13 步时, 系统识别的图像结果与金标准 (ground truth) 基本达到一致。与此相比, 原始 U-net 网络需要更长迭代步数, 迭代到第 25 步才得到一个相对稳定的结果。同时, 改进后网络相较于原始网络在数据准确性上有小幅度提升, DICE 相似系数由 96.2% 上升到 98.3%, 反应了该改进模型在计算速度与计算精确度上相对于原始 U-net 网络识别都有了进一步的提升。

为了进一步测试改进 U-net 模型在各种材料上对裂隙识别的可靠性, 研究选取了混凝土、沥青、花岗岩 3 种不同材质进行裂隙识别。同时, 本研究的测试结果分别与传统 FCN 网络、Sobel 检测、Log 检测等传统裂隙识别方法进行对比, 对比结果见图 4, DICE 相似系数值见表 2。

表 2 各种边缘检测方法的 DICE 相似值对比

Table 2 Comparison of DICE similarity index in each edge detection algorithm (%)

| 岩体种类 | 标签图 | 本文算法 | 传统 FCN | Sobel 检测 | Log 检测 |
|------|-----|-------|--------|----------|--------|
| 混凝土 | 100 | 98.32 | 95.21 | 76.63 | 83.18 |
| 沥青 | 100 | 97.32 | 96.32 | 69.64 | 77.21 |
| 花岗岩 | 100 | 98.82 | 91.23 | 58.01 | 68.47 |

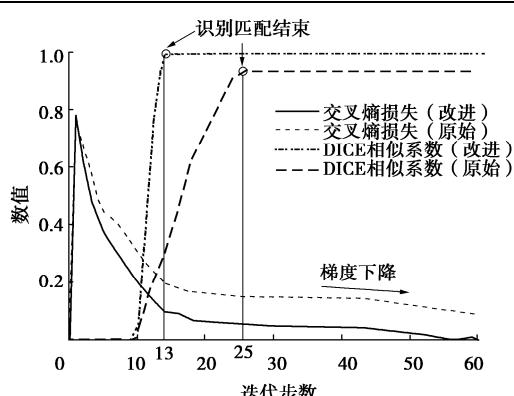


图 3 训练准确度参数曲线

Fig. 3 Parametric curves of training accuracy

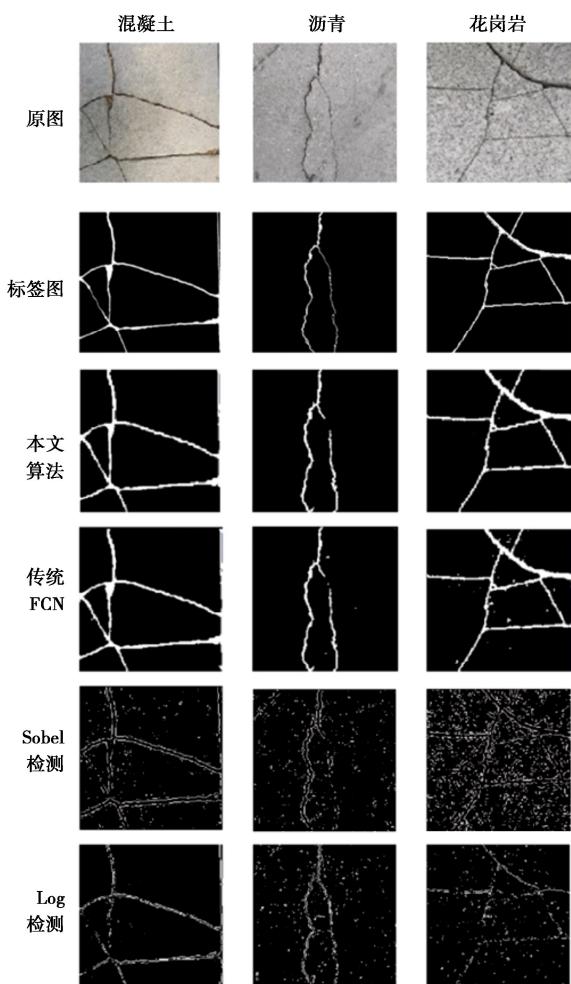


图 4 改进 U-net 法与其他裂隙检测方法的结果对比

Fig. 4 Comparison of results between improved U-net method with other fracture detection methods

由表 2 中的数据可以看出, 本文提出的改进 U-net 算法与传统边缘检测算法相比, 识别的准确度有显著地提升。尤其是在处理花岗岩这种非均质性极强的岩体时, 本文算法没有受到石英等矿物产生的噪声点的干扰, 较为准确地检测标识出了裂隙的形态与位置。与传统 FCN 方法与边缘检测算法的结果相比, 本文算法也在裂隙完整性、噪声屏蔽等方面有一定优势。

2 基于 GMM-EM 的裂隙网络参数提取

本文上半部分详述了基于改进 U-net 网络对岩体裂隙进行分割识别的方法, 分析了其在计算精度与收敛速度上的优势。同时, 也应该注意到无论是本文提出的方法还是传统图像分割方法, 都只关注于将裂隙从图片样本中分割出来。对分割后的图片, 如何进行裂隙高效地划分与参数化表征却鲜有研究。因此, 本文引入 GMM-EM (高斯混合模型-最大期望) 算法, 对裂隙的迹长、倾角等参数进行标定。

2.1 GMM 模型

高斯混合模型 (gaussian mixed model) 是指多个高斯分布函数的线性组合模型。该模型主要用于解决数据点呈现多元线性分布时的数据集聚类问题。目前已经在解决 SLAM 中边缘检测、物体重构等^[20]问题上发挥了重要的作用。本研究引入 GMM 模型来对裂隙网络进行聚类分解。传统的高斯分布的求解首先是对数据集进行高斯分布拟合,

$$g(x) = \frac{1}{(2\pi)^{\frac{D}{2}} \sqrt{\Sigma}} \exp \left[-\frac{1}{2} (x - \mu)^T \Sigma^{-1} (x - \mu) \right]. \quad (3)$$

估算单一高斯分布的参数 $\hat{\mu}$, $\hat{\Sigma}$,

$$\hat{\mu}, \hat{\Sigma} = \arg \max_{\mu, \Sigma} g(\{x_i\} | \mu, \Sigma) \quad . \quad (4)$$

假设每一个观测独立, 构建最大似然估计函数:

$$\begin{aligned} \arg \max_{\mu, \Sigma} \prod g(x_i | \mu, \Sigma) \\ = \arg \min_{\mu, \Sigma} \sum_{i=1}^N \left(\frac{1}{2} (x_i - \mu)^T \Sigma^{-1} (x_i + \mu) + \frac{1}{2} \ln |\Sigma| \right). \end{aligned} \quad (5)$$

为了得到拟合的最优解, 通常将观测结果作为损失函数 $J(\mu, \Sigma)$, 同时对损失函数 $J(\mu, \Sigma)$ 求偏导, 当偏导数为 0 时, 可得期望与方差的最优解,

$$J(\mu, \Sigma) = \sum_{i=1}^N \left(\frac{1}{2} (x_i - \mu)^T \Sigma^{-1} (x_i + \mu) + \frac{1}{2} \ln |\Sigma| \right), \quad (6)$$

$$\left. \begin{aligned} \frac{\partial J}{\partial \mu} = 0, \\ \frac{\partial J}{\partial \Sigma} = 0, \end{aligned} \right\} \quad (7)$$

$$\left. \begin{aligned} \hat{\mu} = \frac{1}{N} \sum_{i=1}^N x_i \\ \hat{\Sigma} = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{\mu})(x_i - \hat{\mu})^T \end{aligned} \right\} \quad (8)$$

高斯混合模型借助了传统高斯模型的思路, 对多个高斯模型进行加权求和,

$$\left. \begin{aligned} p(x) = \sum_{k=1}^K \omega_k g_k(x | \mu_k, \Sigma_k), \\ \sum_{k=1}^K \omega_k = 1. \end{aligned} \right\} \quad (9)$$

此时, GMM 的目标函数 $p(x)$ 的 $\hat{\mu}$, $\hat{\Sigma}$ 无法仅通过传统单一似然估计方法进行求解, 因此需要用 EM (最大期望) 方法进行求解。

2.2 EM 参数反演

EM (expectation maximization) 参数反演方法的主要思路是通过引入隐含变量 z , 即数据观测值 x 在各个分布中占全体的比重, 分别对期望矩阵与协方差矩阵用 z 进行估计。经过多次的迭代更新, 最终使得 GMM 中所有的高斯模型的期望与方差协调收敛。此时, 观测并记录每个观测点对于更新后的 GMM 模型中每一个高斯分布的概率, 最终根据概率值确定被测

点的隶属情况。算法主要包含以下步骤:

(1) 计算初始 $\hat{\mu}$, $\hat{\Sigma}$: 通过式 (4) ~ (8) 初步估计 GMM 模型中各个高斯分布的初始参数。

(2) 引入隐含变量 z ,

$$z_k^i = \frac{g_k(x_i | \mu_k, \Sigma_k)}{\sum_{k=1}^K g_k(x_i | \mu_k, \Sigma_k)}, \quad (10)$$

式中, z_k^i 为在第 i 个数据点在被观测时, 第 k 个高斯分布函数占全体的比重。

(3) 用 z_k 表示期望与方差,

$$\left. \begin{aligned} \hat{\mu} &= \frac{N}{z_k} \sum_{i=1}^N z_k^i x_i, \\ \hat{\Sigma} &= \frac{N}{z_k} \sum_{i=1}^N N z_k^i (x_i - \hat{\mu})(x_i - \hat{\mu})^T, \\ z_k &= \sum_{i=1}^N z_k^i. \end{aligned} \right\} \quad (11)$$

(4) 将 z_k 表示的期望与方差 $\hat{\mu}$, $\hat{\Sigma}$ 带入 GMM 模型求出新的 z 。

(5) 重复 (3), (4) 步直到模型稳定收敛。

(6) 对数据点集中每一个样本点按收敛后的 GMM-EM 模型, 分别计算其隶属各高斯分布的概率, 判定其隶属于概率最高的高斯分布, 完成模型聚类分割。

2.3 RANSAC 裂隙参数识别

RANSAC (随机抽样一致) 算法是一种常见的图元提取方法, 目前已经广泛的应用在二维点云的图元提取、图像配准等领域^[21]。在通过高清图像识别裂隙的过程中, 虽然 GMM-EM 聚类方法可以将复杂的裂隙网络进行合理划分, 但每一个分割得出二维点云集中通常会含有大量的噪点。如果仅仅使用最小二乘法等线型拟合方法对分割子集中的裂隙进行参数拟合, 这些噪点会对拟合过程产生严重干扰, 影响识别结果的准确性。

RANSAC 算法的目的是辨识出符合目标数学模型的有效数据。对于包含大量噪点的数据集的处理有很好的鲁棒性。具体影响程度 Wang 等^[7]曾做过相应地研究。用 RANSAC 算法拟合裂隙形态的主要步骤为:

(1) 初始化。进行 GMM-EM 算法分组后, 取其中一个数据集合 T , 从中提取出一个聚类子集 E_i , 其中包含元素点个数为 N 。

(2) 点集优化。从 E_i 中运用随机抽样准则抽取两个点 e_1, e_2 。连接 e_1, e_2 , 通过求解线性方程得到初始直线 L_{ini} 。设置最大距离 d , 计算集合 E 中所有点到直线 L_{ini} 的距离, 选取距离直线 L_{ini} 距离在 d 以内的点, 组成新的点集合 E_i 。

(3) 迭代比对。反复进行步骤(2), 进行 k 次迭代后, 生成点集 $\mathbf{E}_1, \mathbf{E}_2, \mathbf{E}_3, \dots, \mathbf{E}_k$; 此时点集中局内点的个数分别为 $N_1, N_2, N_3, \dots, N_k$; 取点集中 N 最大的集合为数据集 \mathbf{T} 的目标集合 \mathbf{E}_T

(4) 参数解算。对目标集合 \mathbf{E}_T 中的点进行最小二乘多项式拟合, 确定 \mathbf{E}_T 的多元拟合函数,

$$\left. \begin{aligned} Ax + By + C = 0, \\ \alpha = \arctan \left| \frac{B}{A} \right|, \\ l = \sqrt{[\max(x_i) - \min(x_i)]^2 + [\max(y_i) - \min(y_i)]^2}. \end{aligned} \right\} \quad (12)$$

用式(12)^[9]解算得到数据子集 \mathbf{T} 中被测裂隙的倾角 α_0 和迹长 l_0 。

2.4 局部坐标到全局坐标的转换

完成高清图片中裂隙的解析后, 还需要通过全局-局部空间坐标转换, 来获取在大地坐标系下的裂隙参数, 即该裂隙在实际空间中的坐标参数。如图 5 所示, 坐标系 XYZ 所示为整个岩坡全局坐标系, xyz 所示为摄影图像的局部坐标系。通过无人机云台搭载的定向陀螺仪与 GPS 定位仪, 可以测得图片拍摄时相机的空间位置角 ω, φ, κ 以及相机在大地坐标系下的位置坐标 (X_0, Y_0, Z_0) 。通过下式计算得到在岩坡全局坐标系下的裂隙面产状空间参数:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} X_0 \\ Y_0 \\ Z_0 \end{bmatrix} + \frac{n}{m} R_\varphi R_\kappa R_\omega \begin{bmatrix} x \\ y \\ z \end{bmatrix}, \quad (13)$$

$$\begin{bmatrix} \alpha_1 \\ \beta_1 \end{bmatrix} = R_\varphi R_\kappa R_\omega \begin{bmatrix} \alpha \\ \beta \end{bmatrix}, \quad (14)$$

$$l_1 = \frac{n}{m} l, \quad (15)$$

$$R_\varphi R_\kappa R_\omega = \begin{bmatrix} \cos \varphi \cos \kappa & -\cos \varphi \sin \kappa & \sin \varphi \\ \cos \omega \sin \kappa + \sin \omega \sin \varphi \cos \kappa & \cos \omega \cos \kappa - \sin \omega \sin \varphi \sin \kappa & -\sin \omega \cos \varphi \\ \sin \omega \sin \kappa - \cos \omega \sin \varphi \cos \kappa & \sin \omega \cos \kappa + \cos \omega \sin \varphi \sin \kappa & \cos \omega \cos \varphi \end{bmatrix}. \quad (16)$$

式中 α, β, l 为高清图像中解析出的倾向、倾角与迹长; (x, y, z) 为高清图片中解析出的裂隙面的坐标; α_1, β_1, l_1 为对应全局坐标系下的裂隙面倾向、倾角与迹长; (X, Y, Z) 为对应全局坐标系下裂隙面的空间三维坐标; m 为高清摄影图片的单位标尺长度; n 为相应标尺在实际岩体上的长度。

2.5 GMM-EM 方法的优势

目前多种聚类算法相继被引入二维裂隙网络的识别研究中, 但常见算法通常具有一定的局限性。基于中心点间距的聚类方法, 如 k-means 方法等, 在处理点云集的聚类问题时, 通常会形成以初始点为聚心, 一定长度为半径的团状聚类集。在对图形分割算法生

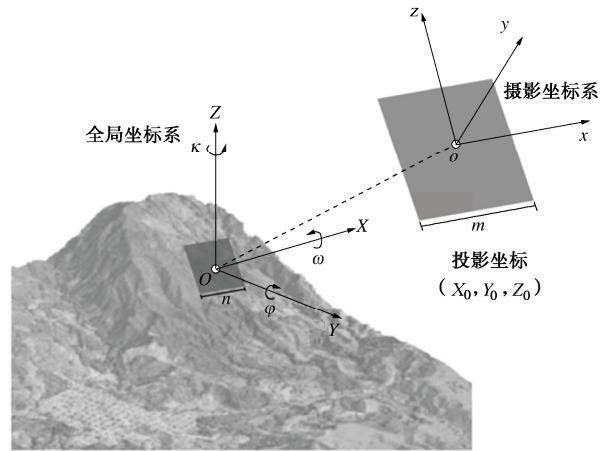


图 5 全局-局部空间坐标转换

Fig. 5 Conversion of global-local spatial coordinates

成的二值图进行聚类识别时, 尤其是裂隙这种线性分布的点云集聚类时, 会因多个相近裂隙间互相干扰, 使分割的结果与预计结果间有较大偏差(图 6)。于此同时, 也有学者运用均值偏移或生长^[4]的方法处理该类问题。该类方法虽然可以有效地解决多条临近裂隙形成裂隙团状集合的问题, 但为了优化裂隙识别的速度与精度, 通常会从多个初始点同时开始生长和偏移, 这使得聚类出的裂隙形态比较破碎, 甚至会将一段完整的裂隙分割成多段。其根本原因是该类算法会误将所有分交叉点定义为分割边界, 使分割结果出现严重的失真。相比之下, 本文提出的 GMM-EM 算法可以在保证分割结果呈线性而非团状的同时, 保持裂隙点云集的完整性, 客观上更好地对裂隙网络进行聚类分割。

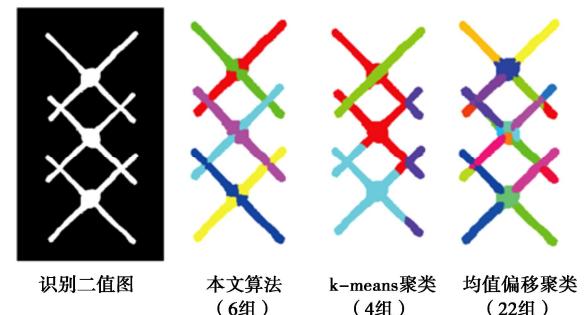


图 6 GMM-EM 聚类算法与其他算法的结果对比

Fig. 6 Comparison of clustering results of GMM-EM algorithm with other algorithms

3 工程实例

3.1 复杂裂隙网络识别基本步骤

为了展示裂隙网络参数标定的过程, 研究选取了一块 $1 \text{ m} \times 1 \text{ m}$ 的含有复杂裂隙的大理石板作为研究对象, 对裂隙参数识别步骤进行展示:

(1) 图像裂隙识别

根据本文第一部分提到识别算法, 运用改进 U-net 深度学习网络对高清图像进行裂隙识别。将图片由原始的位图转化为具有清晰裂隙标注的二值图, 如图 7 (b) 所示。

(2) 裂隙分割

将有清晰裂隙标注的二值图转化为矩阵型式, 由于实际二值化后的图像具有大面积数据空洞, 通常通过稀疏矩阵存储的方法来减小内存用量, 有效地提高了计算效率。使用 GMM-EM 聚类算法, 对二值图中的裂隙点云集进行点云聚类分割。图 7 (c) 为迭代收敛后的高斯混合模型。通过该方法, 可以将交叉网状的裂隙进行高效地拆分, 最终得到图 7 (d) 中的裂隙分割聚类结果。

(3) 参数化识别

使用 RANSAC 算法对分割后的各个聚类子集进行参数识别, 如图 7 (e) 所示。将生成的平面内裂隙解算结果与空中摄影云台得到的空间位置角等参数进行联合坐标变换与解析, 最后可以得到以迹长为直径的空间裂隙网络结构 (图 7 (f))。

(4) 空间离散裂隙网络生成

在完成对表面确定性裂隙网络的参数标定后, 通过王述红等^[22]的相关研究, 对岩体内部裂隙面进行 Monte Carlo 模拟。根据岩坡坡面结构面的空间分布规律, 通过随机模拟就可以得到同时包含实测确定性裂隙面和模拟生成的非确定性裂隙面的全空间离散裂隙网络。该全空间裂隙网络模型可以通过数据接口导入 3DEC、Flac3D、ANSYS 等数值计算软件中进行后续节理岩体的计算。该流程的使用可以极大地提高复杂裂隙网络的采集效率。

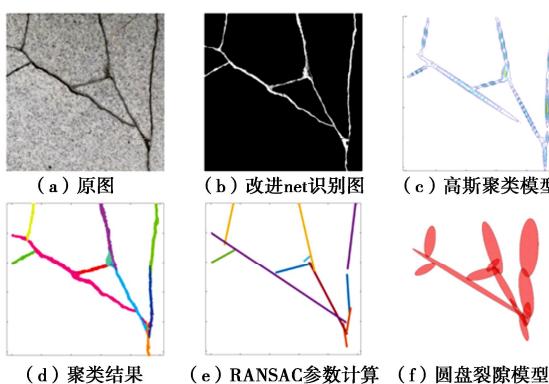


图 7 平面复杂裂隙网络识别流程

Fig. 7 Identification of planar complex fracture network

3.2 边坡现场结构面采集

为了验证该方法在实际工程下的适用性, 本研究选取了云南省新平县鲁奎山铁矿北帮岩石边坡作为测量识别的目标区域 (图 8)。该段边坡位于#18 采场 1530 中段上盘, 区域尺寸为 12 m×10 m, 区域距地

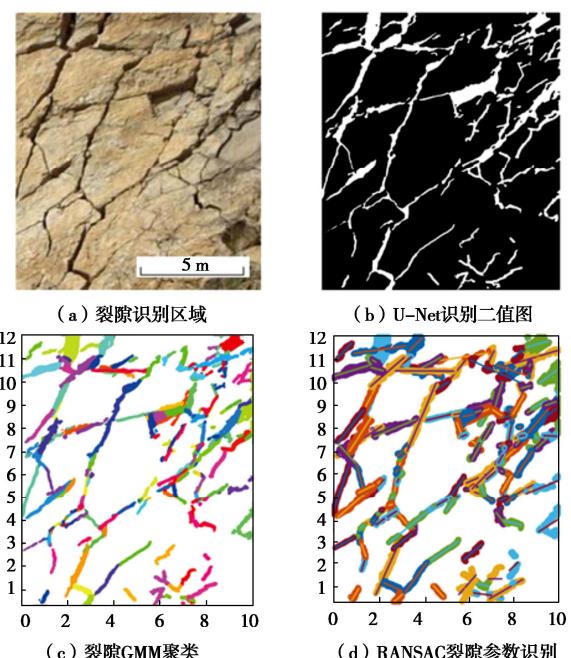
面线高度约 15 m。区域表面节理发育, 岩坡高陡, 坡段下部有岩体滑落造成的碎屑堆积带。被测边坡坡面距地面位置较高, 无法进行近距离人工测量。为了探讨该岩质边坡是否会继续造成滑坡崩塌, 对该目标区域的裂隙面几何参数提取成为了后期进行数值计算工作的先决条件。采用本文提出的基于无人机摄影技术的裂隙面识别方法可以在确保测量人员安全的情况下, 快速准确地识别提取坡面裂隙面参数。



图 8 云南鲁奎山铁矿目标边坡与测量设备

Fig. 8 Measuring region in Lukushan open pit and equipment

为了在确保精度的同时尽量降低成本, 本研究选用了大疆 phantom 4 pro 消费级无人机来获取高清图像, 该设备云台带有一个 8.8 mm/24 mm、光圈为 f/2.8-f/11 的高清镜头, 获取图像分辨率为 5472 px×3648 px。云台自身带有 GNSS 传感器, 可以实时提供 WGS84 的大地坐标系坐标。获取的图片被传回高性能计算机进行图像噪声处理与解析。通过作者团队自主研发的基于改进 U-Net 裂隙面智能识别系统 v1.0 对图片中的裂隙面进行解析, 并结合全局坐标转换生成三维裂隙网络 (图 9)。



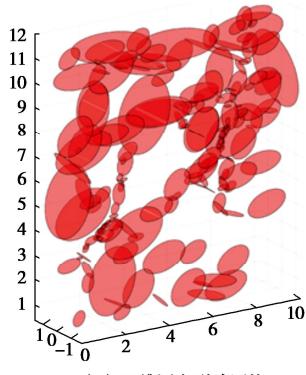
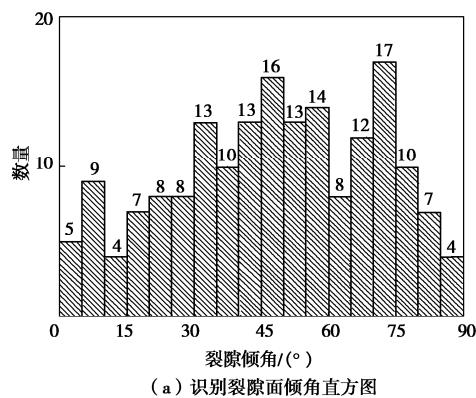


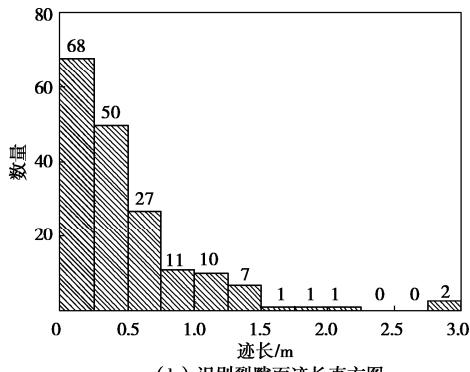
图9 云南鲁奎山边坡裂隙面提取

Fig. 9 Extraction of slope fracture surface in Lukushan open-pit slope

经汇总统计, 该被测区域共识别出裂隙 178 条, 识别结果的 DICE 值为 92.15%, 计算用时 23 s。图 10 为识别出裂隙面的倾角与迹长的直方统计图。从统计数据可以看出该边坡裂隙面倾角分布比较均匀且多处于 $30^\circ \sim 75^\circ$, 迹线长度主要在 0~1.5 m, 走向为 NE27°。将识别出的裂隙面网络与原始图像样本进行对比, 可以看出该算法构建的离散裂隙网络可以很好地反应出整个裂隙网络的空间位置与产状分布情况, 该方法对于开度较大的裂隙面的解算在精度与位置上较为准确。同时也应该注意到部分开度比较小的毛细裂隙在识别过程中容易被算法误判为岩体本身的纹理而被忽视, 因此合理地设置训练网络模型时的标签阈值, 可以提高对裂隙的识别精度。



(a) 识别裂隙面倾角直方图



(b) 识别裂隙面迹长直方图

Fig. 10 Histogram of dip and scanline of Lukushan slope

4 结语

为了解决高陡岩石边坡坡面裂隙采集问题, 尤其是岩体表面交叉裂隙网络的识别问题, 本文提出了一种结合改进 U-net 网络与 GMM-EM 算法的平面裂隙网络识别方法。通过与传统的裂隙识别方法与聚类方法进行对比, 凸显了该方案精度高、适用范围广、运算速度快等特点。将该方法应用于云南鲁奎山铁矿边坡的裂隙面参数化采集中, 取得了较好的识别效果。该方案节约了传统基于 3D 点云模型识别技术中 3D 点云解析时消耗的大量算力, 通过使用预先训练好的 U-net 模型进行裂隙识别, 极大地提高了现场识别效率, 解决了传统基于点云模型的节理面模型不能参数化解析平面迹线的问题, 为基于三维点云的裂隙面识别做了必要补充。同时实现了深度学习网络在现场进行裂隙面采集的应用, 为现场实时进行裂隙面参数化提取提供了新的思路。

参考文献:

- [1] ZHANG P, LI J H, YANG X, et al. Semi-automatic extraction of rock discontinuities from point clouds using the ISODATA clustering algorithm and deviation from mean elevation[J]. International Journal of Rock Mechanics and Mining Sciences, 2018, **110**: 76–87.
- [2] LATO M J, VÖGE M. Automated mapping of rock discontinuities in 3D lidar and photogrammetry models[J]. International Journal of Rock Mechanics and Mining Sciences, 2012, **54**: 150–158.
- [3] GUO J T, LIU Y H, WU L X, et al. A geometry- and texture-based automatic discontinuity trace extraction method for rock mass point cloud[J]. International Journal of Rock Mechanics and Mining Sciences, 2019, **124**: 104132.
- [4] ZHANG P, DU K, TANNANT D D, et al. Automated method for extracting and analysing the rock discontinuities from point clouds based on digital surface model of rock mass[J]. Engineering Geology, 2018, **239**: 109–118.
- [5] VÖGE M, LATO M J, DIEDERICHS M S. Automated rockmass discontinuity mapping from 3-dimensional surface data[J]. Engineering Geology, 2013, **164**: 155–162.
- [6] CHEN J Q, ZHU H H, LI X J. Automatic extraction of discontinuity orientation from rock mass surface 3D point cloud[J]. Computers & Geosciences, 2016, **95**: 18–31.
- [7] WANG S H, ZHANG Z S, WANG C G, et al. Multistep rocky slope stability analysis based on unmanned aerial vehicle

photogrammetry[J]. Environmental Earth Sciences, 2019, **78**: 260.

[8] CHEN N, KEMENY J, JIANG Q H, et al. Automatic extraction of blocks from 3D point clouds of fractured rock[J]. Computers & Geosciences, 2017, **109**: 149 – 161.

[9] 贾曙光, 金爱兵, 赵怡晴. 无人机摄影测量在高陡边坡地质调查中的应用[J]. 岩土力学, 2018, **39**(3): 1130 – 1136. (JIA Shu-guang, JIN Ai-bing, ZHAO Yi-qing. Application of UAV oblique photogrammetry in the field of geology survey at the high and steep slope[J]. Rock and Soil Mechanics, 2018, **39**(3): 1130 – 1136. (in Chinese))

[10] PAN D D, LI S C, XU Z H, et al. A deterministic-stochastic identification and modelling method of discrete fracture networks using laser scanning: development and case study[J]. Engineering Geology, 2019, **262**: 105310.

[11] 张顺, 龚怡宏, 王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用[J]. 计算机学报, 2019, **42**(3): 453 – 482. (ZHANG Shun, GONG Yi-hong, WANG Jin-jun. The development of deep convolution neural network and its applications on computer vision[J]. Chinese Journal of Computers, 2019, **42**(3): 453 – 482. (in Chinese))

[12] 李尧, 李术才, 刘斌, 等. 基于改进后向投影算法的地质雷达探测岩体裂隙的成像方法[J]. 岩土工程学报, 2016, **38**(8): 1425 – 1433. (LI Yao, LI Shu-cai, LIU Bin, et al. Imaging method of ground penetrating radar for rock fracture detection based on improved back projection algorithm[J]. Chinese Journal of Geotechnical Engineering, 2016, **38**(8): 1425 – 1433. (in Chinese))

[13] ZHANG Z X, LIU Q J, WANG Y H. Road extraction by deep residual U-net[J]. IEEE Geoscience and Remote Sensing Letters, 2018, **15**(5): 749 – 753.

[14] 薛亚东, 李宜城. 基于深度学习的盾构隧道衬砌病害识别方法[J]. 湖南大学学报(自然科学版), 2018, **45**(3): 100 – 109. (XUE Ya-dong, LI Yi-cheng. A method of disease recognition for shield tunnel lining based on deep learning[J]. Journal of Hunan University (Natural Sciences), 2018, **45**(3): 100 – 109. (in Chinese))

[15] 黄宏伟, 李庆桐. 基于深度学习的盾构隧道渗漏水病害图像识别[J]. 岩石力学与工程学报, 2017, **36**(12): 2861 – 2871. (HUANG Hong-wei, LI Qing-tong. Image recognition for water leakage in shield tunnel based on deep learning[J]. Chinese Journal of Rock Mechanics and Engineering, 2017, **36**(12): 2861 – 2871. (in Chinese))

[16] 朱大庆, 曹国. 基于全卷积网络的砂石图像粒径检测[J]. 计算机与现代化, 2020(7): 111 – 116. (ZHU Da-qing, CAO Guo. Particle size detection of sandstone images based on full convolutional network[J]. Computer and Modernization, 2020(7): 111 – 116. (in Chinese))

[17] 薛东杰, 唐麒淳, 王傲, 等. 基于 FCN 的岩石混凝土裂隙几何智能识别[J]. 岩石力学与工程学报, 2019, **38**(增刊2): 3393 – 3403. (XUE Dong-jie, TANG Qi-chun, WANG Ao, et al. FCN-based intelligent identification of crack geometry in rock or concrete[J]. Chinese Journal of Rock Mechanics and Engineering, 2019, **38**(S2): 3393 – 3403. (in Chinese))

[18] 王鹏宇, 王述红. 四类常见边坡岩石类别识别和边界范围确定的方法[J]. 岩土工程学报, 2019, **41**(8): 1505 – 1512. (WANG Peng-yu, WANG Shu-hong. Method for identifying four common rock types of slopes and determining boundary range[J]. Chinese Journal of Geotechnical Engineering, 2019, **41**(8): 1505 – 1512. (in Chinese))

[19] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015, 2015. DOI:10.1007/978-3-319-24574-4_28.

[20] FABRESSE F R, CABALLERO F, MAZA I, et al. An efficient approach for undelayed range-only SLAM based on Gaussian mixtures expectation[J]. Robotics and Autonomous Systems, 2018, **104**: 40 – 55.

[21] SCHNABEL R, WAHL R, KLEIN R. Efficient RANSAC for point-cloud shape detection[J]. Computer Graphics Forum, 2007, **26**(2): 214 – 226.

[22] 王述红, 张紫杉, 王存根, 等. 岩体结构面产状随机分布空间表征[J]. 东北大学学报(自然科学版), 2017, **38**(1): 121 – 125. (WANG Shu-hong, ZHANG Zi-shan, WANG Cun-gen, et al. Stochastic spatial characterization of structural plane occurrence in rockmass[J]. Journal of Northeastern University (Natural Science), 2017, **38**(1): 121 – 125. (in Chinese))