

煤矿采空区地表裂缝双任务检测方法研究

陈锡明^{1,2}, 姚鑫¹, 任开瑀¹, 姚闯闯¹, 周振凯^{1,3}, 杨依林^{1,2}

1. 中国地质科学院地质力学研究所, 北京 100081;

2. 中国地质大学(武汉) 地理与信息工程学院, 武汉 430078;

3. 中国地质大学(北京) 工程技术学院, 北京 100083

摘要: 采空区地表裂缝识别对矿区的生产安全和生态环境治理具有重要意义。裂缝检测可以通过语义分割和边缘提取任务实现。已有的深度学习裂缝检测方法通常将其分开处理, 无法为后续的几何参数计算和损害程度量化提供足够数据, 并且没有考虑到两个任务之间的互补性。本文设计了一个双任务卷积神经网络 Goaf-DTNet (Dual-Task Convolutional Neural Network for Goaf Crack Recognition) 来同时获取裂缝面状分割和线性踪迹提取结果, 通过建立两个任务之间的信息互补来提高模型的精度。在 Goaf-DTNet 的面状分割分支中, 使用了多尺度特征融合提取鲁棒性特征。同时, 在裂缝线性踪迹提取分支中, 使用面状分割特征对线性踪迹特征提取过程进行引导, 提高模型对裂缝的定位精度。为了验证方法的有效性, 分别在自建的地表裂缝数据集和公共数据集上进行了实验, 实验结果显示本文方法优于其他对比方法。消融实验结果也表明联合训练两个任务可以提升彼此的准确率。除此之外, 在真实大场景图像上的实验结果表明本文方法在矿区地表裂缝监测中具有一定的实际应用潜力, 可以为矿区监测提供有效数据。

关键词: 遥感, 煤矿, 采空区, 无人机 (UAV), 裂缝检测, 卷积神经网络 (CNN), 多任务学习, 深度学习

中图分类号: P2

引用格式: 陈锡明, 姚鑫, 任开瑀, 姚闯闯, 周振凯, 杨依林. 2024. 煤矿采空区地表裂缝双任务检测方法研究. 遥感学报, 28(12): 3271-3286

Chen X M, Yao X, Ren K Y, Yao C C, Zhou Z K and Yang Y L. 2024. Dual-task model for ground crack detection in the goaf of coal mines. National Remote Sensing Bulletin, 28(12): 3271-3286 [DOI: 10.11834/jrs.20243016]

1 引言

在地下煤矿开采区域, 随着开采的进行, 被采空的区域可能会发生塌陷, 导致地表产生大量裂缝 (程健等, 2020)。煤矿采空区的地表裂缝不仅会对人们的生命和生产安全产生巨大威胁, 还会影响当地的生态环境。因此, 对地裂缝进行周期性地检测, 识别裂缝发生的位置、发育及分布特征, 并采取相应的补救措施防止其恶化, 是一项具有重要意义的工作。

随着无人机 UAV (Unmanned Aerial Vehicle) 遥感技术的普及, 该方法已经成为精细地表观测的主要手段之一。其具有成本低、效率高、作业灵活的特点 (赵毅鑫等, 2021)。除此之外, 无人机 (UAV) 的一个重要优势是可以获取工作区的高时间、高空间、高光谱分辨率数据。这为煤矿采空区地

表裂缝的动态识别与监测提供了可靠的数据源。但是传统的人工解译结合实地调查的方法无法对裂缝进行高效的检测, 亟需一种自动化识别方法。

裂缝的自动识别方法可以划分为3种, 传统图像处理方法、机器学习方法和深度学习方法。基于计算机图像处理的传统裂缝检测方法有图像阈值 (Liu等, 2008)、小波变换 (Subirats等, 2006)、边缘检测 (徐欢等, 2014)、最小路径搜索 (李清泉等, 2010) 等。基于图像上裂缝区域的强度通常比周围环境要低这一假设, 图像阈值方法通过设定一个阈值直接对裂缝和非裂缝进行区分 (Yang等, 2022)。图像阈值方法对图像中的阴影、噪声和强度不均一是很敏感的, 在复杂背景下无法获得鲁棒的裂缝检测性能 (Zou等, 2012)。因此小波变换方法被应用于增强裂缝特征, 以提高分类的准确率 (郎洪等, 2021)。边缘检测方法也被很多研

收稿日期: 2023-01-20; 预印本: 2023-06-13

基金项目: 中国地质调查项目 (编号: DD20230433); 中国三峡公司项目 (编号: YMJ(XLD)/(19)110)

第一作者简介: 陈锡明, 研究方向为深度学习遥感信息提取。E-mail: chenxm@cug.edu.cn

通信作者简介: 姚鑫, 研究方向为地质灾害与 InSAR 研究。E-mail: yaoxinphd@163.com

究应用于裂缝检测 (Zhao 等, 2021)。如徐欢等 (2014) 利用多尺度形态学和 Otsu 算法 (Otsu, 1979) 对传统的 canny 边缘检测算子 (Canny, 1986) 进行了改进, 实现了实时、准确的路面裂缝检测。边缘检测算法的缺点是比较依赖局部灰度和梯度信息, 适用于边缘特征比较明显的裂缝图像 (叶亮, 2020)。在很多情况下无法获得完整的裂缝检测结果。针对这一问题, 李清泉等 (2010) 提出了一种基于最小代价路径搜索的路面检测方法。

上述这些传统的图像处理方法的缺点是只在特定的场景或数据集上有效, 没有足够的泛化性。并且煤矿区域背景复杂, 传统的方法无法实现鲁棒的裂缝提取。

相比传统的图像处理方法, 基于机器学习的裂缝提取方法准确率更高。如 Shi 等 (2016) 基于随机结构森林 (Random Structured Forests) 提出了一个新的道路裂缝提取方法: CrackForest。陈瑶等 (2016) 使用支持向量机 (SVM) 方法对裂缝进行分类。结合 UAV 和机器学习, 可以对矿区的地表裂缝进行自动识别。还可以根据识别结果对裂缝的长度、宽度、方向等进行定量的分析 (Zhang 等, 2020, 2022)。

机器学习方法的一个主要缺点是需要繁琐的特征工程, 这一过程需要大量的时间和专家知识才能实现。近年来, 深度学习在计算机视觉领域得到了前所未有的快速发展。得益于其优秀的特征提取能力和端到端的检测方式, 深度学习已经成为当前裂缝自动检测的主要方法。如 Cha 等 (2017) 使用了一个简单的卷积神经网络对裂缝进行图像级的分类, 也就是判断一副图像上是否有裂缝。在测试图像上, 通过滑动窗口的形式进行预测, 对其中预测为裂缝的图像块进行拼接得到检测结果。地表裂缝也可以通过目标检测任务实现 (程健等, 2020)。但为了得到更准确的裂缝空间信息, 方便后续的定性与定量分析, 通常将裂缝检测看作边缘提取或语义分割任务。Zou 等 (2019) 基于 SegNet (Badrinarayanan 等, 2017) 提出了一个融合了多尺度信息的裂缝检测网络 Deepcrack-1, 该网络对不同级别的编码和解码层的特征进行配对融合, 并采用深监督的策略对网络进行训练。Liu 等 (2019) 基于 HED (Xie 和 Tu, 2015) 提出了 Deepcrack-2 网络, 并结合导向滤波和条件随机场提高裂缝分割精度。考虑到前景像素和背景像素的比例, 裂缝检测与边缘检测任务更相似 (Yang 等, 2020)。为了

提取更加鲁棒的表征, 应对裂缝提取中正负类别极不平衡的问题, 作者使用了特征金字塔来融合上下文信息, 采取与 HED 网络相似的策略, 在不同特征层级对网络进行监督训练, 大大提高了模型对细裂缝的检测能力。Yu 等 (2022) 首次将深度学习和无人机航空遥感结合, 对地震引起的地表裂缝识别进行深入研究。作者设计了一个融合了空间和通道注意力机制的卷积神经网络, 并引入了可变形卷积提高裂缝检测精度。对于裂缝的尺度, 几何形态差异大这一特点, 可以通过融合不同层级的特征来提高模型对不同尺度裂缝的检测能力, 并使用深监督策略帮助模型收敛, 提高泛化能力 (Liu 等, 2022; Qu 等, 2022; Yang 等, 2020)。

上述的深度学习方法在裂缝检测中都取得了非常好的效果。但是这些方法都是只针对单一任务进行的, 即分割或边缘提取任务 (Jiang 等, 2022; König 等, 2022; Xu 等, 2021)。图 1 展示了不同任务的地表裂缝标注方式, 图 1 (a)、图 1 (b) 分别是本文数据集中线性提取任务和面状分割任务的标注方式。




图 1 不同任务的裂缝标注

Fig. 1 The crack annotation of different tasks

Yu 等 (2022) 对地震引起的地表裂缝使用 ArcGIS 软件进行了线性标注。但是作者发现使用 1 个像素宽的标签, 模型无法学到足够的特征, 使得模型难以收敛。边缘提取相比于分割任务要更困难, 因为边缘提取的类别不平衡更加严重。因此, 作者对标签进行了不同程度的扩张 (图 1 (c)), 实验发现当标签为 7 个像素宽时模型有最高的 F1 得分, 3 个像素和 9 个像素宽时分别得到了最高的查准率和查全率。这种标签相比于完整标注整个裂缝来说成本更低。但是, 由此训练的模型得到的结果无法用于后续裂缝宽度的计算。而在本文的研究区, 也就是煤矿采空区中, 裂缝的宽度是评估裂缝危害程度的一个重要指标。

因此, 本文提出了一个同时执行裂缝分割和边缘提取的双任务网络 Goaf-DTNet (Dual-task

Convolutional Neural Network for Goaf Crack Recognition)。多任务网络的归纳偏置是,若不同任务之间可以互相提供有效信息,那么就有可能提高模型性能和泛化性。多任务网络还显示地避免了重复计算共享层的特征,节省大量空间,提升了每一个任务的推理速度(Vandenhende等,2022)。本文提出的多任务模型,采用ResNet34(He等,2016)作为骨干提取共享特征,并加入了一个空洞空间金字塔池化ASPP(Atrous Spatial Pyramid Pooling)模块(Chen等,2017)用于捕获多尺度上下文信息。然后在裂缝面状分割分支中,引入了一个多尺度特征融合模块MFFM(Multi-scale Feature Fusion Module)来提取多尺度信息,以提高模型对不同尺度裂缝的检测能力。由于裂缝线性踪迹提取任务类别不平衡问题更为严重,检测难度更大,本文提出了一个分割引导的裂缝线性特征提取模块SGFM(Segmentation-Guided linear crack Feature extraction Module)来提高线性裂缝提取分支对裂缝特征的定位精度。

2 方 法

2.1 网络结构

本文提出了一个用于同时提取煤矿采空区地

裂缝面状分割和线性踪迹的双任务模型。模型的整体结构如图2所示。原始图像首先输入到骨干网络提取共享特征,然后经过一个裂缝面状分割分支和线性踪迹提取分支,最终输出裂缝面状分割和线性踪迹提取预测图。模型的骨干中采用了ResNet34和一个ASPP模块用于提取共享特征。采空区裂缝的一个主要特征是尺度差异比较大。ASPP模块通过使用不同空洞率的卷积操作,可以提取多尺度感受野的特征,提高模型对裂缝检测的准确率。此外,模型包含两个特定任务特征提取分支,裂缝面状分割分支以及裂缝线性踪迹提取分支。面状分割分支由4个连续的多尺度融合模块和上采样模块,以及两个卷积模块组成。值得注意的是,Goaf-DTNet中的所有上采样操作都是通过双线性插值实现的。因为在裂缝的线性踪迹提取任务中,相较于裂缝面状分割,裂缝像素占整幅图像的百分比要更低,类别不平衡的现象更加严重。因此,本文在线性踪迹提取分支中,引入了SGFM。该模块中,面状分割特征被用于引导裂缝线性分支提取更精确的裂缝定位信息。




图2 本文方法(Goaf-DTNet)的模型结构

Fig. 2 The schematic diagram of the proposed method (Goaf-DTNet)


除此之外,在两个分支中都使用了深度监督策略(Deep Supervision Strategy)。深度监督通过在网络中间层添加分类器,计算中间层的分类结果与标签之间的差异,为模型训练提供更多的直接指导(Lee等,2015)。如图2所示,每个分支的不同阶段都独立地计算一次预测损失。对不同阶段的预测输出进行上采样后,与最终输出进行连接,然后通过一个卷积层对不同尺度的特征图进行融合得到最终的预测结果。

2.2 多尺度特征融合和ASPP模块

煤矿采空区的背景相比道路、房屋建筑和桥梁等结构表面要复杂得多。裂缝的亮度、几何形态变化非常大。除此之外,煤矿采空区裂缝的尺度差异显著。因此采空区裂缝检测的其中一个主要困难就是如何有效提取多尺度裂缝特征。而卷积操作获得的信息是局部的,简单堆叠卷积层无法获得足够的感受野和全局空间信息。解决这一问题的主要方法是融合多尺度信息。已有不少研究指出,网络的深层特征通常分辨率比较低,具有更丰富的语义特征和上下文信息。而浅层的特征则保留了更多的细节,但是背景噪声也比较多


(Lu等,2022; Ronneberger等,2015)。

因此,为了克服煤矿采空区复杂背景带来的大量噪声,获得更好的裂缝提取结果,在骨干网络的最后添加了一个ASPP模块。ASPP模块采用了多个不同空洞率的卷积层以及一个池化层(Pooling Layer),然后对每个层所获得的特征进行连接。因为融合了不同感受野的特征,ASPP可以有效地捕多尺度上下文信息。图3(a)展示了ASPP模块的结构。除此之外,为了得到更加连续完整的裂缝提取结果,在裂缝面状分割分支中采用了MFFM用于进一步融合全局和局部特征,结构如图3(b)所示。首先,对来自骨干网络中较高级的特征进行上采样,经过一个卷积层与较低级的特征进行连接。然后通过SE(Squeeze-and-Excitation)通道注意力模块(Hu等,2018)学习通道之间的相关性,筛选出对裂缝提取更有利的特征。接着,来自ASPP模块或上采样模块的特征通过两个 3×3 卷积层后与之前得到的融合特征进行相加得到最终的输出特征。本文中所有的 3×3 卷积层都接着一个批归一化层和激活层。因为融合了足够多的全局和局部上下文信息,MFFM得到的特征有了更丰富的语义信息与细节,可以有效提高模型的裂缝检测能力。



(a) 空洞空间金字塔池化模块

(a) ASPP



(b) 多尺度融合模块

(b) MFFM

图3 空洞空间金字塔池化模块和多尺度特征融合模块结构

Fig. 3 The structure of ASPP module and MFFM

2.3 分割引导的裂缝线性特征提取模块

裂缝面状分割任务和线性踪迹提取是两个互补的任务,可以互相提供有用的空间信息。对于线性踪迹提取,由于背景信息主导了模型的优化,

使得模型倾向于将目标预测为背景。因此提高模型的定位能力,最小化输出结果中的假反例对于正确预测裂缝非常重要。如图4所示,通过来自面状裂缝分割分支的特征 x_s 生成一个空间注意力掩

膜, 与来自主干网络的特征 x_b 进行点乘后得到语义增强后的裂缝特征 x_{fo} 。




图4 SGFM结构

Fig. 4 The structure of SGFM

因为裂缝的面状分割特征可以限制线性裂缝特征的位置, 为线性踪迹提取分支提供引导, 从而获得更加精准的定位信息。来自 ASPP 模块或线性踪迹提取分支中的一个上采样模块的特征 x_e 通过 3 个卷积层进一步提取特征, 得到具有多尺度语义信息的裂缝特征 $x_{e'}$, 并与 x_{fo} 在特征通道维度上进行连接得 x_o 。 x_o 不仅具有丰富的上下文信息, 还融合了来自面状分割分支的引导信息, 使模型区分裂缝和背景的能力更强。

2.4 对比方法

为了验证本文方法的有效性。选取了 HRNet (Wang 等, 2021)、Deepcrack-1 (Zou 等, 2019)、

Deepcrack-2 (Liu 等, 2019)、Crack-CADNet (Yu 等, 2022)、RoadVecNet (Abdollahi 等, 2021), U-Net (Ronneberger 等, 2015) 和 PSPNet (Zhao 等, 2017) 7 种深度学习模型与本文提出的方法进行对比。其中, RoadVecNet 是一个可以同时提取裂缝面状分割和线性踪迹结果的网络, 该模型采用了级联的方式, 在得到的分割结果上进一步提取线性踪迹。HRNet 是一个在语义分割方面表现非常好的网络, 该网络采用了多个不同分辨率的并行分支, 在整个信息提取过程中保持表征的高分辨率, 不同分辨率特征之间的信息不断交互, 使得提取的表征具有更丰富的语义和更准确的空间信息。Deepcrack-1 使用通道连接操作融合不同层级的特征。Deepcrack-2 是 Liu 等 (2019) 提出的一个裂缝检测网络, 该网络是边缘提取中的经典网络 HED 的改进。Crack-CADNet 是最近提出的地震裂缝自动检测网络。U-Net 通过跳跃连接融合编码器和解码器的特征, 可以很好地保持空间细节。PSPNet 通过金字塔池化提高模型感受野, 具有良好的全局和局部上下文提取能力。

3 数据与实验

3.1 研究区与裂缝数据集

研究区位于陕西省北部的神木市。使用无人机对 A、B、C 这 3 个矿区采集了遥感影像, 分辨率为 5—7 cm/像素, 并建立了数字正射影像 DOMs (Digital Orthophoto Maps)。研究区位置以及 DOMs 如图 5 所示。




图5 研究区所在位置

Fig. 5 The location of the study area

3个矿区的DOMs大小分别为 90551×37400 、 130245×102797 、和 97042×107414 个像素。A矿区的数据获取时间是2021年5月，B、C矿区的获取时间是2021年8月。通过人工标注，制作了采空区地表裂缝识别数据，将该数据集叫做Goaf-Cracks。使用A、C两个矿区制作训练数据，矿区B制作测试数据。以192的步长，将数据切分成 256×256 大小的图像块，剔除无效数据后，得到总共2224幅影像，A、B、C这3个矿区的样本数量分别是586、410、1228张。图6展示了数据集中的一些具有代表性的样本。




图6 地表采空区裂缝数据集 Goaf-Cracks

Fig. 6 Data from the Goaf-Cracks dataset

3.2 实验设置

本文方法在当前主流的深度学习框架Pytorch下实现，在一块显存为11 G的NVIDIA Geforce RTX 2080 Ti上进行训练。在训练阶段，总训练epoch数设为150。初始学习速率设置为0.0001，分别在50、90、120个epoch时学习速率除以10。采用Adam优化器更新网络参数，batch size的大小设置为8。Binary focal loss (Lin等, 2020)可以缓解因样本类别极不平衡使得模型向样本多的类别倾斜的问题，因此在两个任务分支都采用了该损失函数。除此之外，对训练数据集进行了增强以提高数据量。在 0° — 90° ，以 15° 为间隔对图片进

行6个不同角度的旋转。对原图像和旋转后的图像进行水平和垂直翻转。数据增强后，得到训练样本的总数为36280张。

3.3 评价指标

为了对裂缝的检测结果做定量化的精度评价。采用了查准率 (precision)、召回率 (recall)、F1得分 (F1-score) 与交并比 (IoU) 作为裂缝面状分割任务的评价指标。裂缝线性踪迹的提取可以看作是一个边缘检测任务，因此采用边缘检测任务的常用指标，即 ODS (Optimal Dataset Scale)、OIS (Optimal Image Scale)、AP (Average Precision) 对模型进行评价。在本文的研究中，裂缝识别可以看作一个二分类问题。因此，通过裂缝预测结果与真实标签的比较，可以得到样本的真正例 TP (True Positive)、假正例 FP (False Positive)、真反例 TN (True Negative)、假反例 FN (False Negative)。查准率从预测结果出发，是被正确预测为裂缝的像素个数与所有被预测为裂缝的像素个数的比值。召回率则是从真实标签出发，是被正确预测为裂缝的像素个数与真实标签中裂缝像素个数的比值。交并比是每个类别真实值与预测值的交集与并集的比值。ODS表示整个数据集在某一个阈值下取得的最好的F1得分。OIS表示数据集每一张图片在某一阈值下取得最好的F得分的平均值。AP为P-R (precision-recall) 曲线下的面积。各项评价指标的表达式如下：

$$\text{precision} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (2)$$

$$F1 = \frac{2TP}{2TP + FN + FP} \quad (3)$$

$$\text{IoU} = \frac{TP}{TP + FN + FP} \quad (4)$$

$$\text{ODS} = \frac{1}{N_{\text{img}}} \sum_i^{N_{\text{img}}} \max(F1_t; \forall t \in (0.01, \dots, 0.99)) \quad (5)$$

$$\text{OIS} = \max \left(\left(\frac{1}{N_{\text{img}}} \sum_i^{N_{\text{img}}} F1_t^i \right); \forall t \in (0.01, \dots, 0.99) \right) \quad (6)$$

$$\text{AP} = \int_0^1 P - R(r) dr \quad (7)$$

式中，式(5)、(6)中的 N_{img} 为测试数据集图像， t 为划分预测概率图中裂缝和非裂缝像素的阈值， i 为测试集中的一张图片。

4 实验结果与分析

4.1 Goaf-Cracks数据集

4.1.1 面状分割任务实验结果

在 Goaf-Cracks 数据集上对不同模型进行训练和测试。图 7 为不同方法的裂缝面状分割任务结果。从整体来看, 不同的深度学习方法都具有裂缝自动识别能力。然而, 当目标裂缝特别细小时, 如图 7 中的前两列所示, 如果不仔细观察, 通过肉眼也是很难分辨的。相比于其他方法, Goaf-DTNet 可以得到更为精确的识别结果, 受到与裂缝的相似特征的影响较小。除了本文方法, 其他方法都

产生了比较多的假正例。第 3 列的图像的背景比较复杂, 具有与裂缝相似的阴影特征。HRNet、Crack-CADNet、U-Net、Deepcrack-1、PSPNet 和 RoadVecNet 都将部分阴影错误地识别成了裂缝, 而本文方法和 Deepcrack-2 则很好地将裂缝完整地识别了出来。最后两列图片中裂缝比较大, 特征也比较明显, 所有的方法都得到了不错的识别结果。但是观察细节, 可以发现 Deepcrack-2 和 RoadVecNet 得到的结果最不完整, 而 Goaf-DTNet 的结果相比于其他方法更精细, 与标签更为接近。

为了进一步量化评价模型, 在表 1 列出了不同方法的评价指标结果。通过不同指标结果可以看出, 本文方法的整体精度要高于其他方法。




图 7 不同模型在测试数据上的面状分割任务结果

Fig. 7 Visualization of surface segmentation results derived from the test dataset

表1 面状分割任务的测试结果

Table 1 The test results of the surface segmentation task

方法	Precision	Recall	F1	IoU
PSPNet	0.5143	0.6187	0.5616	0.3905
Deepcrack-2	0.5624	0.6218	0.5906	0.4191
RoadVecNet	0.7729	0.5126	0.6164	0.4455
U-Net	0.5819	0.8192	0.6805	0.5157
Deepcrack-1	0.7027	0.6945	0.6986	0.5368
Crack-CADNet	0.5856	0.8632	0.6978	0.5358
HRNet	0.5914	0.8750	0.7058	0.5453
Goaf-DTNet	0.5985	0.8816	0.7130	0.5540

除了查准率低于 RoadVecNet 和 Deepcrack-1, 召回率、F1 得分以及 IoU 分别为 0.8816、0.7130 和

0.5540, 相比于其他方法都有所提升。F1 值和 IoU 相比于 HRNet、Crack-CADNet 提高了约 1%。IoU 比最低的 PSPNet 提升了 16.35%。图 8 (a) 为 8 个模型在测试集上的裂缝面状分割任务的 P-R (Precision-Recall) 曲线, 从图 8 (a) 可以看出本文方法的曲线下面积最大。HRNet 和 Crack-CADNet 的性能比较接近, 而 Deepcrack-2 则是在所有模型中表现最差的, 这可能是由于 Deepcrack-2 的模型结构较为简单, 上下文语义信息不足导致的。这也表明融合不同尺度的特征是提高裂缝识别性能的一个有效方法。




图8 不同模型在两个任务上的P-R曲线

Fig. 8 The P-R curves of two tasks from different models

如图9所示, 使用箱型图来展示模型的稳定性。箱型图是用来显示一组数据的中心位置和散布情况的统计图。图9为不同方法在测试数据集上的 F1 和 IoU 分布, 其中 HRNet、Crack-CADNet 的表现与 Goaf-DTNet 较为接近。从图9可以看出 Goaf-DTNet 的箱体扁平程度仅次于 Crack-CADNet, 箱体的高度是所有方法中最高的。这表明了本文方法在裂缝识别中有较好的稳定性。

4.1.2 裂缝线性踪迹提取任务实验结果

同样地, 对于裂缝线性踪迹提取任务, 我们也比较了不同模型的表现。如图10所示, 除了

Deepcrack-2 和 PSPNet, 其他方法都得到了仅一个像素宽的裂缝图。一个可能的原因是 Goaf-DTNet、RoadVecNet、Crack-CADNet、U-Net 和 Deepcrack-1 采用了几乎对称的编码—解码结构, 解码器逐级地将特征图进行上采样得到与输入图片大小一致的预测图, 这有利于恢复裂缝的结构。而 HRNet 则通过并行连接高分辨率和低分辨率的特征图, 使得在整个特征提取过程中都可以保持特征图的高分辨率, 因此特征图上裂缝的空间信息更加精确。Deepcrack-2 只是简单地将网络的不同阶段卷积模块的预测图上采样后进行融合, 缺乏足够的

空间细节信息,使得模型缺少产生线性识别结果的能力。PSPNet虽然通过金字塔池化融合了不同感受野的特征,但是在恢复输出图像分辨率的过程中缺乏来自底层的细节特征,空间信息恢复能力相对不足。针对肉眼难以识别的细小裂缝,本文方法相对于其他方法的检测能力更好。RoadVecNet是一个级联结构的多任务网络,该模型的线性提取子网络是在面状分割子网络输出的基础上进行的,这使得线性裂缝提取结果完全依赖于分割结

果。从图10的可视化结果可以看出,RoadVecNet的线性踪迹提取结果是比较差的。而本文的多任务网络Goaf-DTNet,嵌入了SGFM,帮助裂缝线性踪迹识别子网络有效提取特征。这样,裂缝线性踪迹提取的结果并不是完全依赖于裂缝面状分割任务的结果,而是通过分割分支上的特征提供的额外空间信息来提高准确率。由表2可知,本文方法的OIS、ODS、AP分别为0.4828、0.5625和0.5384,ODS和AP均超过了所有对比方法。




图9 箱型统计图

Fig. 9 Box plots of different methods for all testing images

从图8(b)中的P-R曲线也可以看出,Goaf-DTNet在该任务上的表现是最好的。

4.2 AerialGoaf数据集

为了进一步测试本文方法的有效性,在开源的AerialGoaf数据集进行了实验。AerialGoaf是通过无人机遥感影像制作的地表裂缝数据集(Cheng等,2020),包含1100张训练图像,200验证图像和435张测试图像。图11展示了不同方法在测试图像上的裂缝面状分割结果。本文方法取得了更加准确的结果,其他方法都存在不同程度的误识现象,如Deepcrack-1和FCD-56(Jégou等,2017)。表3为评价指标结果,Goaf-DTNet的F1、IoU均高于对比方法,相较于第二高的MSL_FCN(Cheng等,2020)分别提高了6.7%和10.22%。在线性踪迹提取方面,本文方法同样在所有方法中取得了最佳性能。

4.3 模型效率分析

综上所述,相比于7种对比方法,本文提出的双任务网络在面状分割和线性提取任务中都取得了最好的性能。为了评估算法效率,计算了不同方法的模型参数量,以及在测试集上执行两个任务需要的总时间和帧率FPS(Frames Per Second)。如表4所示,本文方法的参数量为5138万,但是如果使用HRNet执行两个任务,则需要训练两个模型,这样参数量会是5900万,远大于Goaf-DTNet。两个任务同时进行,不仅可以显示地降低模型的参数量,两个子任务之间互相提供的信息还可以提高模型的精度和泛化性。RoadVecNet虽然同样为多任务网络,但是该网络只是简单的将两个CNN进行级联,这样的缺点是忽略了两个任务之间的信息共享,而且在推理速度上并没有优势。虽然Goaf-DTNet的FPS没有Deepcrack-1、Deepcrack-2、U-Net和PSPNet高,但是如图7和

图 10 所示，Goaf-DTNet 的准确率和可视化结果要更好。除此之外，相比于优秀的裂缝检测网络 HRNet 和 Crack-CADNet，Goaf-DTNet 的推理速度更快。




图 10 不同模型的裂缝线性踪迹提取任务结果

Fig. 10 Visualization results of linear trace extraction derived from the test dataset

表 2 裂缝线性踪迹提取任务测试结果			
Table 2 The quantitative results of the linear trace extraction			
方法	OIS	ODS	AP
Deepcrack-2	0.1448	0.3383	0.1626
PSPNet	0.2588	0.2776	0.1859
Deepcrack-1	0.5106	0.4916	0.3999
RoadVecNet	0.3499	0.5171	0.4609
U-Net	0.4906	0.5267	0.4632
HRNet	0.4257	0.5441	0.5105
Crack-CADNet	0.4805	0.5437	0.5126
Goaf-DTNet	0.4828	0.5625	0.5384

4.4 消融实验

4.4.1 模块消融实验

为了验证提出的 MFFM、SGFM 的作用。如表 5 所示，本文在相同的实验条件下，进行了详细的模块消融实验。基线模型（Baseline）表示没有添加 MFFM 和 SGFM。由于其缺乏多尺度上下文语义信息，基线模型在分割任务上，F1、IoU 相比于 Goaf-DTNet 分别下降了 0.0967 和 0.1086。在裂缝线性踪迹提取任务上，AP 下降了 0.2212。从图 12

的P-R曲线可知，在两个任务上，基线模型的曲线相对于本文方法要低得多。在裂缝面状分割子网络上添加了MFFM后，模型的P-R曲线有了极大的提升（图12（a）），与Goaf-DTNet相近。模型的F1和IoU相对于Baseline分别提高了0.0827和0.0918。这表明MFFM通过融合编码器和解码器的全局和局部空间语义信息，有助于模型提高对裂缝的识别精度。同样地，在裂缝线性提取子网络添加了SGFM后，模型的OIS、ODS和AP相对于基线有了大幅提升，分别提高了0.1246、0.1630和0.2104。但是分割指标均有大幅下降，这是因为在

面状分割任务中缺少了MFMM，只有上采样和普通的卷积模块，无法融合多尺度上下文信息，导致模型对面状裂缝的分割的准确率下降。通过模型的P-R曲线（图12（b））可以知道，SGFM可以显著提升裂缝线性踪迹识别性能。这是因为，SGFM实际上是一个空间注意力模块，分割子网络提取到的特征可以为线性踪迹提取子网络提供空间注意力，使模型更加关注于裂缝区域，从而提高裂缝的提取精度。消融实验表明，添加MFFM和SGFM可以使模型在裂缝识别中获得更高的性能。




图 11 不同模型的面状分割结果

Fig. 11 Surface segmentation results obtained by different models

4.4.2 单双任务消融实验

为了验证联合训练两个任务是否可以提升裂缝检测准确率，使用Goaf-DTNet进行单任务实验。在训练一个任务时，另一个分支不参与网络的

优化。实验结果如表6所示，其中Segmentation、Line_extraction分别指代单独进行面状分割和线性踪迹提取。从实验结果可以得知，Goaf-DTNet在裂缝面状分割和线性提取任务上都有了一定的提

升。F1、IoU的提升分别为1.69%和2.01%。在裂缝线性踪迹提取任务上，虽然ODS有所下降，但OIS和AP分别提升了7.94%和2.53%。通过裂缝面状分割可以知道线性裂缝踪迹的位置，而线性裂缝特征又可以帮助网络提取更加完整的分割结果。在训练的过程中，通过最小化一个联合损失函数(两个任务的损失之和)，以SGFM为桥梁，两个任务中的信息可以进行交互，从而提高各个任务的准确率。

表3 AerialGoaf数据集测试结果

Table 3 The test results on the AerialGoaf dataset

方法	面状分割				线性踪迹提取		
	Precision	Recall	F1	IoU	ODS	OIS	AP
U-Net	0.5986	0.3171	0.4145	0.2615	0.2526	0.2535	0.1556
PSPNet	0.6969	0.2533	0.3716	0.2282	0.1111	0.0673	0.0445
MSL_FCN	0.7339	0.9290	0.8200	0.6949	—	—	—
FCD-56	0.502	0.942	0.656	0.488	—	—	—
Deepcrack-1	0.1891	0.6641	0.2944	0.1726	0.0573	0.0574	0
Goaf-DTNet	0.9042	0.8705	0.8870	0.7971	0.5810	0.5825	0.5496

表4 模型的效率

Table 4 The efficiency analysis of different models

方法	总耗时(双任务)	参数(百万)	帧率
U-Net	4.28	7.78	96.51
Deepcrack-1	7.25	30.91	58.57
Deepcrack-2	5.12	14.70	80.06
PSPNet	9.40	49.07	43.63
RoadVecNet	15.43	30.10	26.60
Crack-CADNet	21.99	20.16	18.65
HRNet	47.12	29.56	8.70
Ours	11.50	51.38	35.7

表5 模块消融实验结果

Table 5 The ablation study with different modules

基线	MFFM	SGFM	F1	IoU	OIS	ODS	AP
√			0.6163	0.4454	0.2675	0.3974	0.3172
√	√		0.6990	0.5372	0.2768	0.3875	0.3046
√		√	0.5601	0.3890	0.3921	0.5604	0.5276
√	√	√	0.7130	0.5540	0.4828	0.5625	0.5384




图12 模块消融实验的P-R曲线
Fig. 12 The P-R curve of the ablation study of the modules

表6 单双任务消融实验结果

Table 6 The ablation study with single and dual tasks

方法	面状分割				线性踪迹提取		
	Precision	Recall	F1	IoU	ODS	OIS	AP
Segmentation	0.5745	0.8832	0.6961	0.5339	—	—	—
Line_extraction	—	—	—	—	0.5484	0.4831	0.5131
Goaf-DTNet	0.5985	0.8816	0.7130	0.5540	0.4828	0.5625	0.5384

4.5 真实场景应用实验

为了测试 Goaf-DTNet 的实际应用能力，验证方法的性能。如图 13 所示，从一个新的矿区选取了 5 个大小为 1500×1000 像素的典型区域，使用 Goaf-Cracks 数据集训练得到的 Goaf-DTNet 进行测试。区域 I 处在一个凹地上，光线比较弱，有密集的植树坑。区域 II 位于一个坡上，光线充足，裂缝的尺寸比较大。区域 III 的裂缝尺度变化比较大，分布地很密集，几乎全部为纵向裂缝。区域 IV 的裂缝主要以横向为主，受到植被遮挡和阴影的影响。区域 V 处在一处平地上，裂缝具有一定的角度，呈弧形密集分布，受到阴影的影响，且多数裂缝比较细小。

5 个区域的裂缝识别结果如图 14 所示。从裂缝提取结果可以看出，本文方法在 5 个区域上都得到了较为满意的效果。这反映出 Goaf-DTNet 能够适应各种不同类型的裂缝，准确提取出煤矿采空区中不同区域的地表裂缝。从区域 III 和 V 的检测结

果可以知道，对于肉眼难以辨认的细小裂缝，本文方法也能够很好的识别。在遮挡和阴影影响比较大的区域，如区域 I、IV 上，还是会存在一些裂缝被漏检。但是从整体的识别结果来看，Goaf-DTNet 具有较强的抗噪声干扰能力，可以提取准确的裂缝信息。通过提取到的裂缝面状分割结果，可以定性或定量的评估裂缝的大小，而裂缝线性踪迹提取结果则可以快速提供裂缝的位置，长度，方位等信息，为煤矿灾害治理提供有效数据。




图 13 用于真实场景实验的 5 个区域(图中粉红色框所示)
Fig. 13 The five selected areas marked by the pink rectangle for crack detection test in reality (Marked by the pink boxes)




图 14 模型在 5 个区域的应用结果(第二列图像中粉红色为正确预测的裂缝,黄褐色表示假反例,绿色为假正例)
Fig. 14 Crack extraction results of Goaf-Crack on five selected sites (True positives, false negatives, and false positives in the images of the second column are highlighted in pink, brownish-yellow, and green, respectively)

5 结 论

本文针对煤矿采空区的地表裂缝,提出了一个双任务模型:Goaf-DTNet。模型包含两个子网络分支,可以实现端到端的训练,能够从背景复杂的UAV影像上同时提取裂缝的面状分割和线性踪迹结果。并使用UAV遥感影像,构建了一个采空区地表裂缝数据集Goaf-Crack进行测试。本文的主要结论如下:

(1) 通过对比实验表明,本文方法在两个任务上的评价指标相比其他深度学习方法要高。模型在测试数据集上的F1、IoU指标分别达到了0.7130和0.5549,裂缝线性提取指标AP达到了0.5384。

(2) 本文提出的MFFM通过融合多尺度上下文语义信息,有利于模型得到更加完整和连续的裂缝识别结果。SGFM使用空间注意力机制,利用分割特征来为线性裂缝特征提供更多的空间信息以提高模型精度。消融实验表明,这个两个模块显著提高了模型在裂缝面状分割和线性踪迹任务上的准确率。

(3) 利用两个任务之间的协同作用可以提高各个缝检测任务的准确率。

虽然本文模型在地表裂缝提取上取得了不错的效果。但是仍然存在很多需要改进的地方,如对于比较长的裂缝无法获得完整连续的结果,以及对与裂缝相似的地物存在错识。矿区的地表背景相对道路等要复杂得多,植被、风沙对裂缝的掩埋都会对裂缝的识别带来困难。不同于人眼,CNN无法通过线索推理出裂缝的走向和位置,这一局限性导致模型无法提取出完整的裂缝结果。除此之外,当测试数据的分布与训练数据分布差异较大时,往往无法得到满意的结果,这也是阻碍深度学习在地表采空区裂缝提取实际应用上的一个关键问题。因此,后续的工作重点是研究地表裂缝的迁移学习方法,提高模型的泛化能力。

参考文献(References)

Abdollahi A, Pradhan B and Alamri A. 2021. RoadVecNet: a new approach for simultaneous road network segmentation and vectorization from aerial and google earth imagery in a complex urban setup. *GIScience and Remote Sensing*, 58(7): 1151-1174 [DOI: 10.1080/15481603.2021.1972713]

Bradinarayanan V, Kendall A and Cipolla R. 2017. Segnet: A deep con-

volutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12): 2481-2495 [DOI: 10.1109/TPAMI.2016.2644615]

Canny J. 1986. A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PA-MI-8(6): 679-698 [DOI: 10.1109/TPAMI.1986.4767851]

Cha Y J, Choi W and Büyüköztürk O. 2017. Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5): 361-378 [DOI: 10.1111/mice.12263]

Chen L C, Papandreou G, Schroff F and Adam H. 2017. Rethinking atrous convolution for semantic image segmentation. *arXiv preprint arXiv: 1706.05587* [DOI: 10.48550/arXiv.1706.05587]

Chen Y, Mei T, Wang X J, Li F and Liu Y W. 2016. A bridge crack image detection and classification method based on a climbing robot. *Journal of University of Science and Technology of China*, 46(9): 788-796 (陈瑶, 梅涛, 王晓杰, 李峰, 刘彦伟. 2016. 基于爬壁机器人的桥梁裂缝图像检测与分类方法. *中国科学技术大学学报*, 46(9): 788-796) [DOI: 10.3969/j.issn.0253-2778.2016.09.011]

Cheng J, Ye L, Guo Y N and Wang R B. 2020. An aerial image detection method of ground crack in goaf based on deformable convolutional network with hybrid domain attention. *Journal of China Coal Society*, 45(S2): 993-1002 (程健, 叶亮, 郭一楠, 王瑞彬. 2020. 采空区地裂缝混合域注意力变形卷积网络检测方法. *煤炭学报*, 45(S2): 993-1002) [DOI: 10.13225/j.cnki.jccs.2020.0164]

Cheng J, Ye L, Guo Y N, Zhang J and An H B. 2020. Ground crack recognition based on fully convolutional network with multi-scale input. *IEEE Access*, 8: 53034-53048 [DOI: 10.1109/ACCESS.2020.2981370]

He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]

Hu J, Shen L and Sun G. 2018. Squeeze-and-excitation networks//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE: 7132-7141 [DOI: 10.1109/CVPR.2018.00745]

Jégou S, Drozdal M, Vazquez D, Romero A and Bengio Y. 2017. The one hundred layers tiramisu: fully convolutional densenets for semantic segmentation//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. Honolulu: IEEE: 1175-1183 [DOI: 10.1109/CVPRW.2017.156]

Jiang X, Mao S J, Li M, Liu H, Zhang H Y, Fang S W, Yuan M Z and Zhang C. 2022. MFPA-Net: an efficient deep learning network for automatic ground fissures extraction in UAV images of the coal mining area. *International Journal of Applied Earth Observation and Geoinformation*, 114: 103039 [DOI: 10.1016/j.jag.2022.103039]

König J, Jenkins M, Mannion M, Barrie P and Morison G. 2022. What's cracking? A review and analysis of deep learning methods for structural crack segmentation, detection and quantification. *arxiv preprint arXiv: 2202.03714* [DOI: 10.48550/arXiv.2202.03714]

Lang H, Wen T, Lu J, Ding S and Chen S D. 2021. 3D pavement crack

- detection method based on deep learning. *Journal of Southeast University (Natural Science Edition)*, 51(1): 53-60 (郎洪, 温添, 陆键, 丁朔, 陈圣迪. 2021. 基于深度学习的三维路面裂缝类病害检测方法. *东南大学学报(自然科学版)*, 51(1): 53-60) [DOI: 10.3969/j.issn.1001-0505.2021.01.008]
- Lee C Y, Xie S N, Gallagher P, Zhang Z Y and Tu Z W. 2015. Deeply-supervised nets//*Proceedings of 2015 Artificial Intelligence and Statistics (AISTATS)*. San Diego: PMLR: 562-570
- Li Q Q, Zou Q and Mao Q Z. 2010. Pavement crack detection based on minimum cost path searching. *China Journal of Highway and Transport*, 23(6): 28-33 (李清泉, 邹勤, 毛庆洲. 2010. 基于最小代价路径搜索的路面裂缝检测. *中国公路学报*, 23(6): 28-33) [DOI: 10.19721/j.cnki.1001-7372.2010.06.005]
- Lin T Y, Goyal P, Girshick R, He K M and Dollár P. 2020. Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2): 318-327 [DOI: 10.1109/TPAMI.2018.2858826]
- Liu C Q, Zhu C G, Xia X, Zhao J K and Long H H. 2022. FFEDN: feature fusion encoder decoder network for crack detection. *IEEE Transactions on Intelligent Transportation Systems*, 23(9): 15546-15557 [DOI: 10.1109/TITS.2022.3141827]
- Liu F F, Xu G A, Yang Y X, Niu X X and Pan Y L. 2008. Novel approach to pavement cracking automatic detection based on segment extending//*Proceedings of 2008 International Symposium on Knowledge Acquisition and Modeling*. Wuhan: IEEE: 610-614 [DOI: 10.1109/KAM.2008.29]
- Liu Y H, Yao J, Lu X H, Xie R P and Li L. 2019. DeepCrack: a deep hierarchical feature learning architecture for crack segmentation. *Neurocomputing*, 338: 139-153 [DOI: 10.1016/j.neucom.2019.01.036]
- Lu X Y, Zhong Y F, Zheng Z, Chen D Y, Su Y, Ma A L and Zhang L P. 2022. Cascaded multi-task road extraction network for road surface, centerline, and edge extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-14 [DOI: 10.1109/TGRS.2022.3165817]
- Otsu N. 1979. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1): 62-66 [DOI: 10.1109/TSMC.1979.4310076]
- Qu Z, Cao C, Liu L and Zhou D Y. 2022. A deeply supervised convolutional neural network for pavement crack detection with multi-scale feature fusion. *IEEE Transactions on Neural Networks and Learning Systems*, 33(9): 4890-4899 [DOI: 10.1109/TNNLS.2021.3062070]
- Ronneberger O, Fischer P and Brox T. 2015. U-Net: Convolutional networks for biomedical image segmentation//*Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015*. Munich: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Shi Y, Cui L M, Qi Z Q, Meng F and Chen Z S. 2016. Automatic road crack detection using random structured forests. *IEEE Transactions on Intelligent Transportation Systems*, 17(12): 3434-3445 [DOI: 10.1109/TITS.2016.2552248]
- Subirats P, Dumoulin J, Legeay V and Barba D. 2006. Automation of pavement surface crack detection using the continuous wavelet transform//*Proceedings of 2006 International Conference on Image Processing*. Atlanta: IEEE: 30373040 [DOI: 10.1109/ICIP.2006.313007]
- Vandenhende S, Georgoulis S, Van Gansbeke W, Proesmans M, Dai D X and Van Gool L. 2022. Multi-task learning for dense prediction tasks: a survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(7): 3614-3633 [DOI: 10.1109/TPAMI.2021.3054719]
- Wang J D, Sun K, Cheng T H, Jiang B R, Deng C R, Zhao Y, Liu D, Mu Y D, Tan M K, Wang X G, Liu W Y and Xiao B. 2021. Deep high-resolution representation learning for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(10): 3349-3364 [DOI: 10.1109/TPAMI.2020.2983686]
- Xie S N and Tu Z W. 2015. Holistically-nested edge detection//*Proceedings of 2015 IEEE International Conference on Computer Vision (ICCV)*. Santiago: IEEE: 1395-1403 [DOI: 10.1109/ICCV.2015.164]
- Xu H, Li Z B, Jiang Y Y and Huang J B. 2014. Pavement crack detection based on OpenCV and improved Canny operator. *Computer Engineering and Design*, 35(12): 4254-4258 (徐欢, 李振璧, 姜媛媛, 黄剑波. 2014. 基于OpenCV和改进Canny算子的路面裂缝检测. *计算机工程与设计*, 35(12): 4254-4258) [DOI: 10.16208/j.issn1000-7024.2014.12.037]
- Xu L, Hatsutani T, Liu X, Techapanurak E, Zou H and Okatani T. 2021. Pushing the envelope of thin crack detection. *arXiv preprint arXiv: 2101.03326* [DOI: 10.48550/arXiv.2101.03326]
- Yang D P, Peng B, Al-Huda Z, Malik A and Zhai D H. 2022. An overview of edge and object contour detection. *Neurocomputing*, 488: 470-493 [DOI: 10.1016/j.neucom.2022.02.079]
- Yang F, Zhang L, Yu S J, Prokhorov D, Mei X and Ling H B. 2020. Feature pyramid and hierarchical boosting network for pavement crack detection. *IEEE Transactions on Intelligent Transportation Systems*, 21(4): 1525-1535 [DOI: 10.1109/TITS.2019.2910595]
- Ye L. 2020. *Aerial Image Visual Detection and Recognition Method of Ground Crack in Goaf of Coal Mine*. Beijing: China University of Mining and Technology. (叶亮. 2020. 煤矿采空区地裂缝的航拍视觉检测与识别方法. 北京: 中国矿业大学) [DOI: 10.27623/d.cnki.gzkyu.2020.001217]
- Yu D W, Ji S P, Li X, Yuan Z D and Shen C Y. 2022. Earthquake crack detection from aerial images using a deformable convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 4412012 [DOI: 10.1109/TGRS.2022.3183157]
- Zhang F, Hu Z Q, Fu Y K, Yang K, Wu Q Y and Feng Z W. 2020. A new identification method for surface cracks from UAV images based on machine learning in coal mining areas. *Remote Sensing*, 12(10): 1571 [DOI: 10.3390/rs12101571]
- Zhang F, Hu Z Q, Liang Y S, Fu Y K and Yang K. 2022. An optimal approach for crack extraction from UAV sub-images after cutting. *International Journal of Remote Sensing*, 43(7): 2638-2659 [DOI: 10.1080/01431161.2022.2066485]
- Zhao H S, Shi J P, Qi X J, Wang X G and Jia J Y. 2017. Pyramid scene parsing network//*Proceedings of 2017 IEEE Conference on Com-*

- puter Vision and Pattern Recognition (CVPR). Honolulu: IEEE: 6230-6239 [DOI: 10.1109/CVPR.2017.660]
- Zhao Y X, Sun B, Liu S M, Zhang C, He X, Xu D and Tang W. 2021. Identification of mining induced ground fissures using UAV and infrared thermal imager: temperature variation and fissure evolution. *ISPRS Journal of Photogrammetry and Remote Sensing*, 180: 45-64 [DOI: 10.1016/j.isprsjprs.2021.08.005]
- Zhao Y X, Xu D, Sun B, Jiang Y D, Zhang C and He X. 2021. Investigation on ground fissure identification using UAV infrared remote sensing and edge detection technology. *Journal of China Coal Society*, 46(2): 624-637 (赵毅鑫, 许多, 孙波, 姜耀东, 张村, 何祥. 2021. 基于无人机红外遥感和边缘检测技术的采动地裂缝辨识. *煤炭学报*, 46(2): 624-637) [DOI: 10.13225/j.cnki.jccs.xr20.1948]
- Zou Q, Cao Y, Li Q Q, Mao Q Z and Wang S. 2012. CrackTree: automatic crack detection from pavement images. *Pattern Recognition Letters*, 33(3): 227-238 [DOI: 10.1016/j.patrec.2011.11.004]
- Zou Q, Zhang Z, Li Q Q, Qi X B, Wang Q and Wang S. 2019. Deep-crack: learning hierarchical convolutional features for crack detection. *IEEE Transactions on Image Processing*, 28(3): 1498-1512 [DOI: 10.1109/TIP.2018.2878966]

Dual-task model for ground crack detection in the goaf of coal mines

CHEN Ximing^{1,2}, YAO Xin¹, REN Kaiyu¹, YAO Chuangchuang¹, ZHOU Zhenkai^{1,3}, YANG Yilin^{1,2}

1. Institute of Geomechanics, Chinese Academy of Geological Sciences, Beijing 100081, China;

2. School of Geography and Information Engineering, China University of Geosciences, Wuhan 430078, China;

3. School of Engineering and Technology, China University of Geosciences (Beijing), Beijing 100083, China

Abstract: Automatic detection of ground cracks in the goaf of coal mines plays an important role in production security and ecological environment management. Given the complex background, variable geometry, and scale of cracks in coal mines, automatically detecting ground cracks in the goaf remains challenging. Crack extraction can be treated as a segmentation task from a global view or as a skeleton extraction task (boundary detection) from a local view. Many methods view crack extraction as a single task independently. However, these methods cannot produce enough data for the subsequent measurement and quantitative evaluation of the extent of the detriment of ground cracks. Moreover, they disregard the information interaction of different tasks, which could potentially improve accuracy and efficiency. To solve these problems, this study designed a dual-task Convolutional Neural Network (CNN) called dual-task CNN for goaf crack recognition (Goaf-DTNet) to automatically detect ground cracks by using unmanned aerial vehicle imagery with a high spatial resolution.

In Goaf-DTNet, an atrous spatial pyramid pooling module is introduced to extract multiscale semantic information. In consideration of the characteristics of ground cracks in the goaf, a Multiscale Feature Fusion Module (MFFM) was designed for the crack segmentation branch to further integrate local and global contextual information. A Segmentation-Guided crack skeleton Feature extraction Module (SGFM) was used in the crack skeleton extraction branch to provide spatial information through the spatial attention mechanism. The proposed dual-task model can explicitly avoid parameter calculation in the shared layers, thus reducing the memory footprint and accelerating each task. Meanwhile, the complementary information from the communication between two tasks can improve the detection accuracy of each task.

For the task of skeleton extraction, the F1-score and Intersection over Union (IoU) value are 0.71 and 0.55, respectively; the former is about 1% higher than the F1-score of the second best method, and the latter is 16.35% higher than the IoU of PSPNet. In the task of surface segmentation, the proposed model performs better than the compared methods. Its Optimal Dataset Scale (ODS) and Average Precision (AP) value are 0.56 and 0.54, respectively. In addition, the test results for an open-source dataset show that the proposed method is better than the others, and its F1-score and IoU value are 0.89 and 0.80, respectively. In skeleton extraction, the Optimal Image Scale (OIS), ODS, and AP of the proposed method are 0.58, 0.58, and 0.55, respectively. Ablation experiments are conducted to prove the effectiveness of the proposed MMFM and SGFM. Results indicate that after adding MMFM to the crack segmentation branch, the F1-score and IoU increase by 0.0827 and 0.0918, respectively, showing that the method facilitates crack detection by fusing local and global information. In the crack skeleton extraction task, OIS, ODS, and AP increase by 0.1246, 0.1630, and 0.2140, respectively, after SGFM is embedded into the branch.

Experimental results show that Goaf-DTNet is effective in ground crack detection from the goaf of coal mines. The proposed MFFM helps the model obtain complete and continuous crack identification results by integrating multiscale context semantic information. SGFM uses information from the surface segmentation branch to provide abundant spatial information for linear crack features, thus effectively improving the detection accuracy. Furthermore, the accuracy of each task is enhanced by taking advantage of the synergy between two tasks.

Key words: remote sensing, coal mines, goaf, Unmanned Aerial Vehicle (UAV), crack detection, Convolutional Neural Networks (CNN), multi-task learning, deep learning

Supported by China Geology Survey Project (No. DD20230433); China Three Gorges Corporation (No. YMJ(XLD)/(19)110)