



移动阅读

顾清华,薛步青,卢才武,等. 基于 D-LinkNet 网络的露天矿道路智能识别与路网建模[J]. 煤炭学报, 2020, 45(S2): 1100-1108.

GU Qinghua, XUE Buqing, LU Caiwu, et al. Road intelligent recognition and road network modeling of open pit based on D-LinkNet network[J]. Journal of China Coal Society, 2020, 45(S2): 1100-1108.

# 基于 D-LinkNet 网络的露天矿道路智能识别与路网建模

顾清华<sup>1,2</sup>, 薛步青<sup>1,2</sup>, 卢才武<sup>1,2</sup>, 宋江珊<sup>1,2</sup>

(1. 西安建筑科技大学 资源工程学院, 陕西 西安 710055; 2. 西安建筑科技大学 西安市智慧工业感知计算与决策重点实验室, 陕西 西安 710055)

**摘要:**随着露天矿无人驾驶技术和智能调度的快速发展, 矿车在生产调度中迫切需要更为精确、更符合实际的矿区路网模型。为了满足无人矿车的高精度路网导航需求, 首先通过无人机倾斜摄影技术分别采集不同天气、不同角度和不同采矿场条件的露天矿区图像瓦片数据, 结合矿区道路成像特点提出了基于矿区道路特征的图像正负分类方法, 实现对矿区道路的整体划分; 然后根据图像数据特征提出了一种强弱光图像互补方法, 可用于消除强光数据集中图像光照失衡问题, 生成最优训练集; 其次露天矿区非结构化道路图像较结构化道路图像经解析处理后平面形态及连通性维度更高, 横纵剖面上的几何形态等道路信息更复杂。基于 ResNet101 构建更符合露天矿道路提取的 D-LinkNet101 网络模型, 运用最优训练集训练 D-LinkNet101 网络, 并从采集到的瓦片数据中提取出道路图像; 最后将提取的道路图像与原始图像(包含焦距, GPS 等)结合生成露天矿路网模型, 根据生成露天矿路网模型的特有噪声进行相应模型修复处理, 从而生成高精度的露天矿路网模型。实验结果表明: 该方法提取的路网数据真实可靠, 可满足露天矿区主干路网的智能识别和路网建模的精度要求。

**关键词:**露天矿; 路网模型; 智能提取; D-LinkNet101; 瓦片数据

中图分类号: TD854

文献标志码: A

文章编号: 0253-9993(2020)S2-1100-09

## Road intelligent recognition and road network modeling of open pit based on D-LinkNet network

GU Qinghua<sup>1,2</sup>, XUE Buqing<sup>1,2</sup>, LU Caiwu<sup>1,2</sup>, SONG Jiangshan<sup>1,2</sup>

(1. School of Resources Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; 2. Xi'an Key Laboratory of Smart Industry Perception Computing and Decision Making, Xi'an University of Architecture and Technology, Xi'an 710055, China)

**Abstract:** With the rapid development of driverless technology and intelligent dispatching in open-pit mine, more accurate and practical road network model is urgently needed in mine production and dispatching. In order to meet the high accurate road network navigation requirements of tramcar, firstly, the image tile data of the open-pit mining area are collected by the UAV tilt photography technology in different weather, different angles and slope conditions, and the positive and negative classification method based on the road characteristics of the mining area is proposed in combination with the road imaging characteristics of the mining area, so as to realize the overall division of the road in the mining area. Secondly, the plane shape and connectivity dimension of the unstructured road aerial photograph image of the

收稿日期: 2020-03-15 修回日期: 2020-04-20 责任编辑: 钱小静 DOI: 10.13225/j.cnki.jccs.2020.0414

基金项目: 国家自然科学基金资助项目(51774228, 52074205); 陕西省杰出青年基金资助项目(2020JC-44)

作者简介: 顾清华(1981—), 男, 山东诸城人, 教授, 博士。E-mail: qinghuagu@126.com

通讯作者: 薛步青(1995—), 男, 陕西西安人, 硕士研究生。E-mail: xuebuqing@126.com

open-pit mining area is higher than that of the structured road data after image analysis and processing, which has more complete geometric shape and other road information on the horizontal and vertical sections. The D-LinkNet101 network model based on ResNet101, which is more suitable for road extraction in the open pit mine, is selected to train the D-LinkNet101 network with the optimal training set, and the road image is extracted from the collected tile data. Finally, the extracted road image is combined with the original image (including focal length, GPS, etc.) to generate the road network model of the open pit mine, and the corresponding model is repaired according to the specific noise of the road network model of the open pit mine, so as to generate a high-precision road network model of the open pit mine. The experimental results show that the road network data extracted by this method is real and reliable, which can meet the requirements of intelligent identification and road network modeling accuracy of the main road network in open-pit mining area.

**Key words:** open pit; road network model; intelligent extraction; D-LinkNet101; tile data

露天矿区路网数据是露天矿采场运输管理的重要组成部分,是露天矿智慧矿山建设的重要基础,尤其随着露天矿区无人驾驶的逐步推广应用,矿区路网模型的快速实时构建成为露天矿无人驾驶应用及智能调度迫切需要解决的问题之一。传统的矿区路网构建主要是通过专业测量人员实地测量、GPS 轨迹聚类提取 2 种方式,前者存在人力财力投入成本大、对从业人员专业技术要求高,而且数据处理周期长、工作量大等问题;后者虽可通过 GPS 轨迹点快速生成轨迹线,但往往难以真实描述道路的宽度、坡度等重要特征,且属于事后分析,难以满足露天矿无人驾驶对路网数据高精度、高时效性的要求,因此亟需一种精度高、更新速度快的智能路网数据提取方法。

目前国内外研究多数是针对城市道路或小区等结构化道路进行识别和提取进行,在轨迹聚类方面:多数学者利用轨迹点、线聚类,图论与图像处理,轨迹增量合并等方法进行了研究<sup>[1-3]</sup>。随着深度学习的兴起,运用深度神经网络进行城市道路提取已成为研究热点。文献[4]提出了基于改进损失函数与网络结构的 Unet 网络,在没有物体遮挡的情况下能够提取到比较完整的城市道路。为解决传统机器学习道路提取算法复杂、计算量大的问题,文献[5]提出一种基于 Dense Unet 模型的遥感影像道路网提取方法,该方法具有参数少、鲁棒性强等特点,可用于复杂场景下的道路提取。文献[6]给出了全新的 ResNet 网络学习框架,该网络简化了神经网络训练,重新定义了层的输入方法使得通过残差函数可以搭建更深层的神经网络,这种残差网络层可随着网络层数深度的增加显著提高道路识别精度。在 ResNet 网络基础上,文献[7]提出了一种在 D-LinkNet 网络模型,该模型在不添加池化层的基础上有效地增大图像中心特征的感受野,增强了提取道路的精准率和连续性。而后文献[8]针对 D-LinkNet 网络中 2 次连续下采样

造成的特征信息损失,提出用包含一个步长为 2 的 3 个连续  $3 * 3$  的卷积代替原来网络的  $7 * 7$  卷积的 Stem-D-LinkNet 网络,该网络能在解码过程中更好地恢复道路的细节信息。

矿区道路随露天采场的开采不断变化,与城市道路属性存在诸多不同,矿区道路具有以土石路为主、无道路标识线、光谱特征不显著及道路宽度不固定等特点,故针对矿区道路的研究仍较为匮乏。学者主要从 2 个方面进行了研究:一是从车辆 GPS 轨迹数据中获取道路信息,通过轨迹聚类或栅格化构建路网骨架,文献[9]针对传统栅格法提取路网精度较低的问题,建立了 GPS 轨迹点的道路概率模型,从而改进了栅格图像初始化的方法。并采用改进的细化算法对其进行细化处理,得到道路网骨架信息,完成了露天矿路网的自动提取;文献[10]结合露天矿区路网不断变化的情况,通过改进的 DBSCAN 密度聚类算法对数据进行聚类分析,实现了矿区路网的自动更新;二是通过道路遥感影像、无人机测绘影像等,利用图像识别技术实现对道路网的准确提取。主要研究有:文献[11]提出一种基于 Canny 边缘检测算子的矿区道路自动提取方法,利用 Canny 算子对遥感图像进行边缘检测,得到边缘信息,然后进行边缘匹配,判定道路边缘,完成对研究区内的道路进行定位和矢量化。文献[12]通过对矿区遥感影像进行边缘检测将道路与其他物进行了分离,通过分割提取了露天矿道路。另外文献[13]结合道路的路面质量、坡度和承载能力等因素,提出了对露天矿道路的描述方法,对露天矿运输道路网络的建立进行了研究。

针对传统的露天矿路网提取方法存在工作量大,轨迹线难以真实描述道路特征以及如何利用深度学习实现露天矿路网智能提取等问题,笔者首先通过无人机倾斜摄影技术采集矿山图像瓦片数据<sup>[14]</sup>,结合矿区道路图像的纹理,色差,对比度等特征,提出基于

道路特征的图像正负分类方法;然后针对采集过程中由于地理遮挡或者天气原因导致无人机采集到部分道路图像存在光照强度失衡问题,提出一种强弱光图像互补方法;其次为满足矿山非结构化道路复杂信息的提取,选择了编码结构具有 101 层的 D-Link-Net101 网络结构,并且将输入的图片尺寸规范化为  $512 * 512$  大小,用以训练网络模型。对采集到的露天矿图像用已训练的 D-LinkNet101 进行道路提取,将提取的道路图像与原始图像及其地理信息结合生成带有道路信息的露天矿图像作为 Context Capture 软件构建模型的数据,最终通过 Context Capture 软件输出露天矿路网模型。此外需对生成路网模型中的噪声点和节点进行自动修复与矫正,进而生成高精度露天矿路网模型。

## 1 露天矿路网提取流程

本文提出了一种基于 D-LinkNet 网络对露天矿路网智能识别与路网建模的方法。具体步骤为:① 分别在晴天和阴天对露天矿的两个采矿场进行不同角度拍摄;② 对采集到的图像进行正负分类分组,对比每组图像训练出网络性能综合选出最优训练集生成条件;③ 结合露天矿面积大小在拍摄图像重叠度为 70%以上情况的下采集 3 000 张以上该条件下的图像作为建模数据,利用最优训练集训练 D-LinkNet 网络,并对露天矿建模图像数据进行道路提取;④ 通过对弱光图像光照补偿后形成强光图像互补集,组合生成完整的强光训练集,将提取到的路径与原始图像及其 GPS 信息及进行结合,利用绘图软件生成露天矿路网。综合上述步骤本方法流程图如图 1 所示。

## 2 矿区道路图像数据处理

### 2.1 露天矿图像正负分类方法

为提升数据集样本质量,对采场道路结合纹理,色差,对比度等特征进行图像正负分类。采集的露天矿图像道路分为正负 2 类样本。正样本类为:① 矿石固化永久道路,是通过在矿石中加入一定的稳定剂从而实现将矿石固化稳定,再通过铺装、碾压形成的路面,其主要通过对矿石进行固化形成。因长期经矿车碾压,其成像纹理基本为一整体,纹理细长,通常与周边非道路区域存在较强对比性;② 渣石永久道路,露天矿道路主要由该类道路组成,其纹理类似于矿石固化永久道路,通常与周边非道路区域能形成较强的色差对比;③ 渣石临时道路,该类道路通常在采矿点附近或者存在于渣石永久道路之间,其纹理为小块状,与周边非道路区域色差对比比较弱,如图 2 所示为

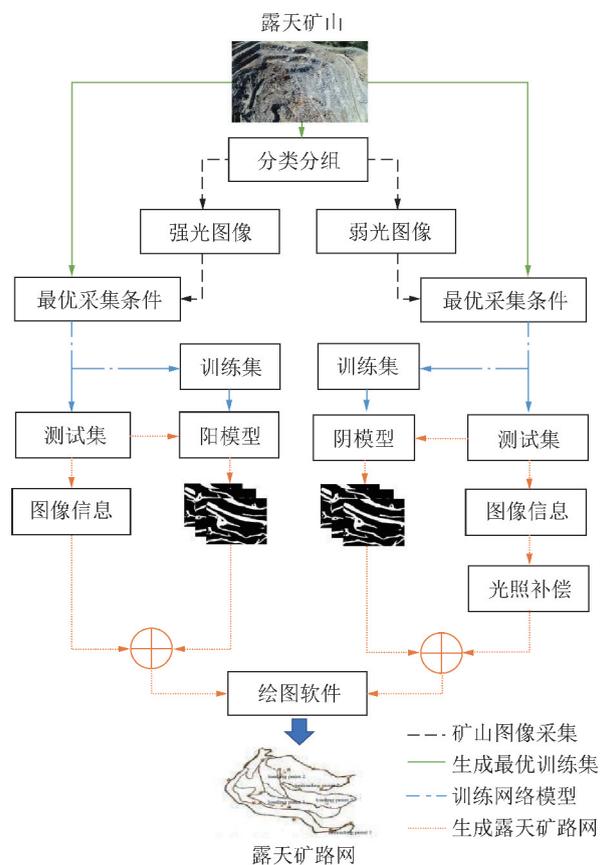


图 1 露天矿路网提取流程

Fig. 1 Road network extraction flow chart of open pit mine 3 类道路的示意图。负样本类为:① 非道路矿石区域,该类区域纹理通常呈圆块状,是渣石临时道路周边干扰;② 非道路岩石区域,该类区域是渣石永久道路的干扰因素。



图 2 3 类露天矿道路示意

Fig. 2 Road diagram of class III open pit

正样本中矿石固化永久道路和渣石永久道路普遍被认为是矿场的主干道路,也是露天矿路网的主要

识别对象。实际上无人机航拍的露天矿道路图像中道路类别总是伴随着临时道路的出现,但若分级提取露天矿道路需将航拍图像进行切分,这将导致道路信息提取工作非常复杂,且会破坏原始图像的地理信息。直接通过从原始图像中提取出道路信息,训练集就应该以原始的航拍图像为主,但实验表明直接使用原始图像作为训练集构建神经网络会导致神经网络只能识别出主干道,基本不能识别出临时道路。为了使得神经网络可学习更多临时道路的细节特征,在原始的训练集中添加一些如图 2 所示人工切分出的临时道路和负样本,从而弥补了原始训练集所训练出神经网络在临时道路信息参数不足的缺陷。

## 2.2 强弱光图像互补方法

通过对比晴天和阴天两类露天矿图像建模效果后发现晴天时采集的图像(强光图像)建模效果较阴天采集的图像(弱光图像)效果更优,但在晴天对采场实地采集图像过程中因为存在地理遮挡等其他因素导致无人机采集到部分道路图像存在光照强度失衡问题,因而晴天采集到的图像不能直接应用于路网建模。阴天时因光线较均匀故几乎不存在图像失衡问题,但存在图像色彩丢失问题,故整体建模效果不好。为能够提取更多道路信息和消除构建出模型的阴影,本文提出运用弱光图像对强光图像中存在阴影遮挡部分图像进行修补的强弱光图像互补方法。具体步骤为:①运用强光和弱光数据集分别构建神经网络,并从建模图像中提取出强弱光两个道路图像集;②从强光道路集中剔除光照失衡部分区域的图像;③在弱光道路集中找出强光光照失衡的区域图像集,并通过对该类图像进行光照补偿(调整该部分图像的对比度和色度等<sup>[15]</sup>)组成强光补集如图 3 所示为弱光图像光照补偿前后对比图;④把强光道路图像集和其补集结合组成最终建模的图像数据集。

## 2.3 露天矿最优训练集采集条件

在露天矿的不同开采阶段中矿场路网存在较大差异,需保持对露天矿路网模型定期更新,故需对露天矿数据进行定期采集。首次采集数据时采集丰富的瓦片数据对比得出数据集的最优采集条件可以大大缩短之后定期采集的工作量,运用无人机分别在晴天和阴天对露天矿的两个采场进行图像采集,每次采集的拍摄角度为 90°的正射和拍摄角度为 45°的斜射,以保证采集到足够丰富的露天矿区图像瓦片信息。

采集的数据集最终被用于训练和测试神经网络并从中提取道路信息,所以最优训练也就是能够构建

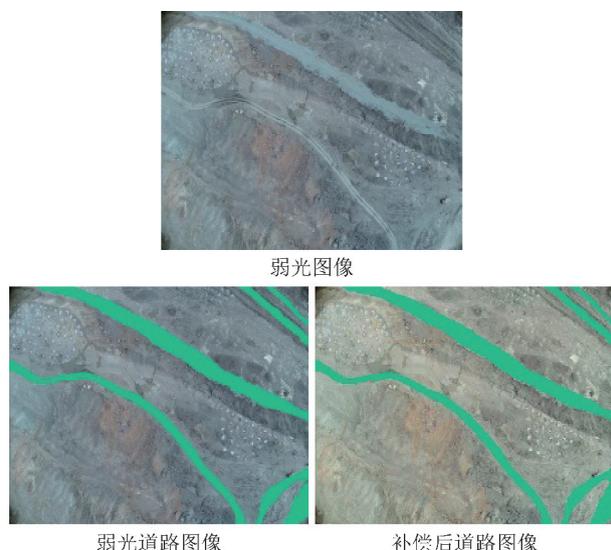


图 3 弱光图像光照补偿前后对比

Fig. 3 Comparison of low light image before and after light compensation

出性能(IOU (Intersection-Over-Union)、连续性、噪点数量等)最好神经网络的数据集。数据集中除了天气因素外还存在道路类别、拍摄角度、采场 3 个变量因子。道路区域类别为:固化道路、渣石道路、临时道路,拍摄角度分为正射和斜射 2 个采场。每类道路数据集都包含:采场 1 拍摄角度 90°、采场 1 拍摄角度 45°、采场 2 拍摄角度 90°、采场 2 拍摄角度 45°四组数据。运用调整 1 个因子且保持其余因子不变的控制变量原理对比训练集训练出的模型性能,综合得出 3 类道路区域的最优采集条件。

## 3 基于 D-LinkNet 的矿区道路网络

### 3.1 露天矿 D-LinkNet101 网络

D-LinkNet101 网络在提取图像特征领域被广泛的应用,其网络结构由 ResNet101 编码结构和 LinkNet 解码结构及其中间的空洞卷积层组成,因为空洞卷积的加入在没有增加神经网络池化层的基础上提升了特征图中心的感受野,使得识别出的道路图像具有连续性强和准确率高的特点,该网络也是目前基于图像提取道路最受欢迎的网络结构之一。露天矿道路主要由半结构化或非结构化道路组成,其比普通结构化道路拥有更不规则的边缘,从而使得采集到的道路图像信息更加复杂,增加了矿山道路提取难度。通过对比 ResNet34, ResNet50, ResNet101 及 ResNet152 作为 D-LinkNet 网络的编码结构,ResNet101 较 ResNet34, ResNet50 在网络模型性能上有明显提升,而 Resnet50 则在 ResNet101 基础上提升效果不显著且效率低下。故采用具有 101 层卷积的 ResNet101 作为 D-LinkNet 网络的编码结构组成 D-LinkNet101。

用 D-LinkNet101 作为露天矿路网提取的网络模型,另外为保证提取露天矿道路图像的精度规范输入的图像尺寸为  $512 \times 512$ 。

### 3.2 D-LinkNet101 结构

#### 3.2.1 编码与解码

D-LinkNet101 网络的编码结构由 ResNet101 结构组成,编码过程图像输入数据为  $512 \times 512 \times 3$ , 经过第 1 次下采样后特征图变为  $256 \times 256 \times 64$ 。之后再经

过 4 次下采样,特征图变为  $16 \times 16 \times 2\,048$ , 具体特征图变化见表 1。如图 4 所示为 D-LinkNet 网络整体网络结构,网络的解码结构采用了 LinkNet 网络的解码结构,经过空洞卷积层后特征图大小和层数依然为尺寸  $16 \times 16$  大小的 2 048 层特征图,特征经过 4 次上采样后又重新变为  $256 \times 256 \times 64$  的特征图。最终通过 2 次反卷积变为  $512 \times 512$  的特征图,利用 sigmoid 函数的对特征图中的像素点做二分类输出<sup>[16]</sup>。

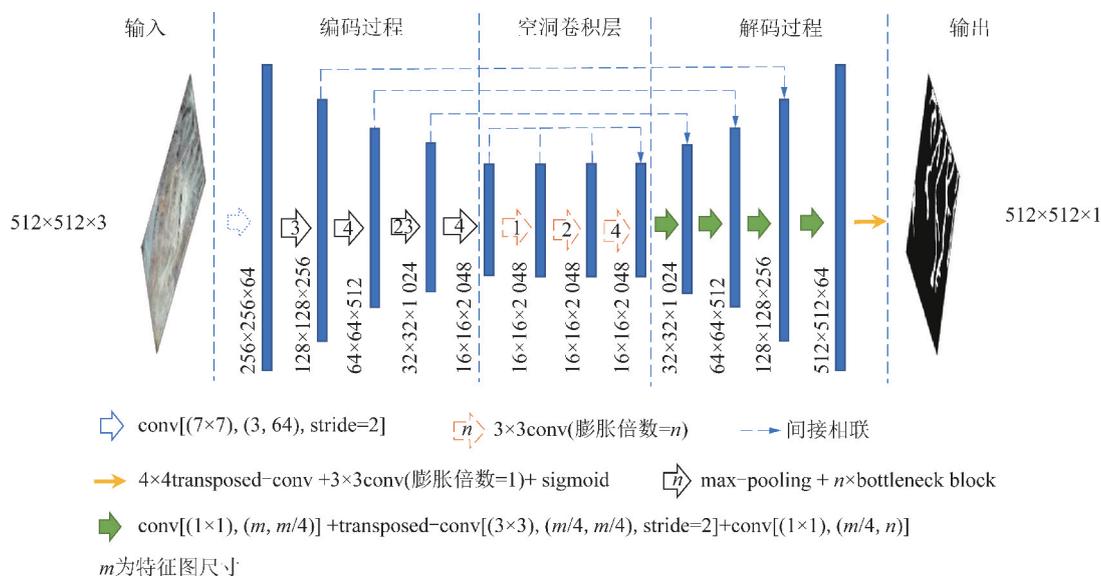


图 4 D-LinkNet 网络结构  
Fig. 4 D-LinkNet network structure

表 1 D-LinkNet101 的编码结构

Table 1 Coding structure of D-LinkNet101

下采样	输入	层数×结构	输出
1	$512 \times 512 \times 3$	{ $7 \times 7$ conv, stride=2}	$256 \times 256 \times 64$
	$256 \times 256 \times 64$	{ $3 \times 3$ conv, stride=2}	$128 \times 128 \times 64$
2	$128 \times 128 \times 64$	$3 \times \begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$128 \times 128 \times 256$
	$128 \times 128 \times 256$	{ $3 \times 3$ conv, stride=2}	$64 \times 64 \times 256$
3	$64 \times 64 \times 256$	$4 \times \begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 3$	$64 \times 64 \times 512$
	$64 \times 64 \times 512$	{ $3 \times 3$ conv, stride=2}	$32 \times 32 \times 512$
4	$32 \times 32 \times 512$	$23 \times \begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1\,024 \end{bmatrix} \times 3$	$32 \times 32 \times 1\,024$
	$32 \times 32 \times 1\,024$	{ $3 \times 3$ conv, stride=2}	$16 \times 16 \times 1\,024$
5	$16 \times 16 \times 1\,024$	$4 \times \begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2\,048 \end{bmatrix} \times 3$	$16 \times 16 \times 2\,048$

#### 3.2.2 空洞卷积层

空洞卷积层串联的膨胀率依次为 1, 2, 4, 8 等, 当加入空洞卷积后特征图中心的特征感受野会变为 3, 7, 5, 3。当输入的图像经过 5 次下采样编码后特征图变为  $16 \times 16 \times 2\,048$ 。每个特征图尺寸为  $16 \times 16$ , 特征图中心的特征经过 3 次膨胀, 中心特征的感受野依次变为 3, 7, 5。15×15 的特征图刚好覆盖了最初的特征图。空洞卷积由于在没有增加池化层的情况下增大了特征图中心的感受野, 因此使得图像保留了更多的道路特征<sup>[17]</sup>。D-LinkNet 在编码与解码之间的空洞卷积如图 5 所示。

## 4 矿区路网提取实例

### 4.1 数据集

#### 4.1.1 露天矿图像采集

本次实验数据集的采集地点在洛阳钼矿露天矿场。无人机共在阴天晴天进行两次采集, 采集条件为: 飞行高度 200 m, 重叠度为 75%。共有图像 7 122 张。如图 6 所示为无人机拍摄图像构建的露天矿实景三维模型。

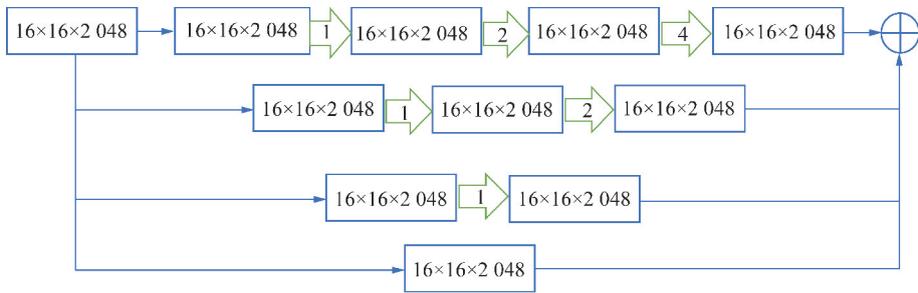


图 5 空洞卷积平行层

Fig. 5 Center parallel dilated convolution layers



图 6 露天矿实景三维模型

Fig. 6 Three dimensional model of open pit real scene

#### 4.1.2 最优采集图像条件

首先对采集到的图像基于道路正负分类方法进行分类,然后通过对比相同类别道路不同采集方式的训练集训练的神经网络模型性能(IOU、噪点、连续性等),最后综合筛选出露天矿各类道路图像的采集条件。

#### 4.1.3 训练集与测试集

按照得出的最优训练采集条件,运用无人机对洛阳钼矿进行二次图像采集,采集到 3 235 张图像,图像分辨率为 5 472×3 648。为了更好地利用图像的信息,将数据分为训练集与测试集,并将图像规范化为 512×512。训练集有 2 520 张,测试集包含 715 张,因此存在数据过度使用的风险,所以需要采集到的图像数据进行扩充。本实验对图像进行了多种翻转,移动与缩放,从而极大地扩充了数据集。如图 7 所示为矿山道路与其真实道路。



图 7 洛阳钼矿图像与真实道路

Fig. 7 Image and Ground Truth of Luoyang molybdenum mine

## 4.2 模型训练

### 4.2.1 实验环境

本实验使用的计算机有 4 张 RTX2080 显卡。实

验程序语言为 Python 和 Matlab,基于 Pytorch 构建神经网络。

### 4.2.2 预编码

迁移学习常被用于计算机视觉,尤其是在训练集的图片数量有限的情况下,本文应用语义分割中应用预训练模型<sup>[18]</sup>对编码网络进行的预训练。

### 4.2.3 训练神经网络并输出识别道路图像

实验的优化器选择 Adam,选择 BEC+dice 作为损失函数<sup>[19]</sup>,初始的学习率设置为 0.000 2。当训练的损失下降较低时,自动地训练 3~5 次变化 1 次。运用训练集对 D-LinkNet 网络进行训练,训练出神经网络。将采集到的矿山图像输入进训练好的 D-LinkNet 网络中,输出提取路径所需图像数据。如图 8 所示为网络的输入的矿山图像和识别的矿山道路。



图 8 神经网络的输入和输出图像

Fig. 8 Input and output image of neural network

## 4.3 生成路网模型

### 4.3.1 数据整理

生成路网首先需将提取的道路图像(通过将神经网络提取的图像分辨率还原为 5 472×3 648 得到)与原始图像进行结合形成露天矿路径图像如图 9 所示。无人机采集到的露天矿图像中包含了 GPS 等地理信息,经过路径提取后的图像在图像的处理过程中失去了原有图像的地理信息,所以需将原始图像中的地理信息添加到露天矿路径图像上生成带有地理信息的露天矿路径图像用于路网模型的构建。

### 4.3.2 路网模型构建与噪声修复

将带有路径信息露天矿图像作为地图软件(以例 Context Capture)的输入数据,经软件建模后可输

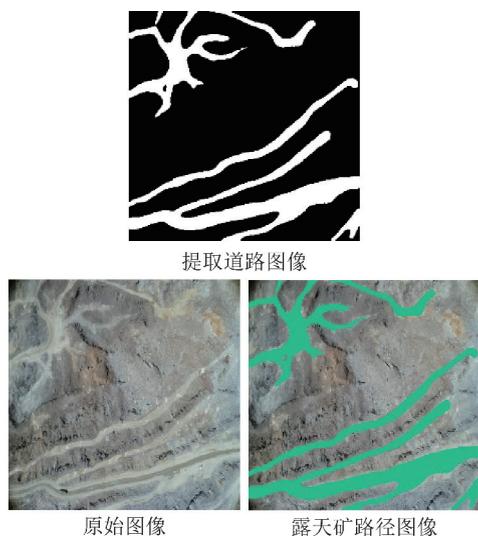


图9 提取的图像与真实图像

Fig. 9 Extracted image and real image

出 3MX 格式的 3D 露天矿路网模型。输入软件的图像在相较于原图像添加了道路信息,但识别过程中可能存在部分图像识别不准确,以至于构建的初始模型存在道路连接点中断、空洞、噪点等现象,如图 10 所示。为解决原模型的噪声等问题需要对生成的原模型进行修复,具体为:通过 Context Capture 软件重新生成可修复的三维模型,并将重建结果导入 Mesh-mixer 修复软件中,该软件会自动检测需要修复区域并进行修复<sup>[20]</sup>,然后人工使用该软件对模型中路网剩余的轻微噪点进行修复和对露天矿路网中识别不当区域进行精度校准,最终生成露天矿高精度路网模型。图 11 为修复后洛阳钼矿破碎站路网模型。



图 10 洛阳钼矿破碎站路网修复前

Fig. 10 Before road network restoration of Luoyang molybdenum mine crushing station

#### 4.3.3 露天矿云路网模型

Context Capture 软件生成的路网为本地路网,须通过 arcGIS(10.0 以上版本)软件将本地路网上传到云架构的 GIS 平台,通过云平台实现多用户的路网实时共享,进而实现多辆矿车实时调度。

## 5 实验结果分析与评价

### 5.1 训练集性能对比

在训练神经网络过程中,找出最适合训练神经网络



图 11 洛阳钼矿破碎站路网修复后

Fig. 11 After road network restoration of Luoyang molybdenum mine crushing station

的训练集是非常有必要的。本实验中经过对图像数据的预分类处理,生成了最优训练集。为验证本实验中生成最优训练集的重要性,应用当下热门的 Unet, LinkNet, D-LinkNet 及 Stem-D-LinkNet 对矿山图像进行道路提取并进行了性能测试,如图 12 所示为生成最优训练集前后模型的性能对比图。图中蓝色虚线表示未生成最优训练集直接训练生成网络模型的 IOU 性能折线。橙色线表示运用本文方法生成最优训练集后训练的网络模型 IOU 性能折线。结果清晰的表明,生成最优训练集后的训练的神经网络识别的性能比未经处理的性能更优。可看出在对比的网络中 Unet 网络的 IOU 指数最低,经过预处理后生成的模型 IOU 提升显著。提升最多的为 Stem-D-LinkNet, IOU 性能提升了约 8%。Unet, LinkNet, D-LinkNet 等网络性能都有不同幅度地提升。

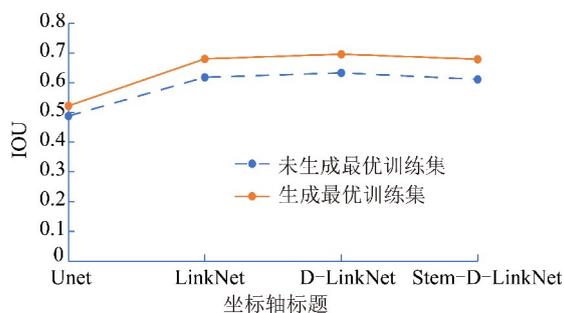


图 12 生成最优训练集前后神经网络性能对比

Fig. 12 Comparison of model performance before and after generating the optimal training set

### 5.2 神经网络模型性能对比

运用矿山图像分别训练 Unet, LinkNet, D-LinkNet, Stem-D-LinkNet 后,不同网络模型的 IOU 性能结果见表 2。表中显示 IOU 指数最优的是 LinkNet, 其次为 D-LinkNet, Stem-D-LinkNet, Unet。其中 IOU 指数最低的是 Unet, 其 IOU 指数为 0.522, 由此可分析出识别出的道路会产生很大的误差。

由图 13 可看出, Unet 网络识别的图像具有噪点多且道路多中断等特征, 这表明 Unet 网络不太适用于矿山这类半结构化道路的提取。对比 LinkNet 和

D-LinkNet 网络提取的结果, D-LinkNet 因为在编码与解码之间加入了空洞卷积, 增加了图像的感受野, 使得识别出的矿山图像具有了很好的连续性, 且出现的噪点量较 LinkNet 低。Stem-D-LinkNet 网络中虽然以 Stem 模块代替了 LinkNet 网络初始步长为 2 的  $7 \times 7$  卷积, 理论上消除了因为初始卷积两次下采样带来的特征信息损失, 但在实际表现中 Stem-D-LinkNet 相较于 D-LinkNet 性能上还是存在一定差距。

表 2 神经模型测试集 IOU 指标  
Table 2 Model test set IOU index

模型	测试集 IOU
Unet	0.522
LinkNet	0.694
D-LinkNet	0.692
Stem-D-LinkNet	0.689

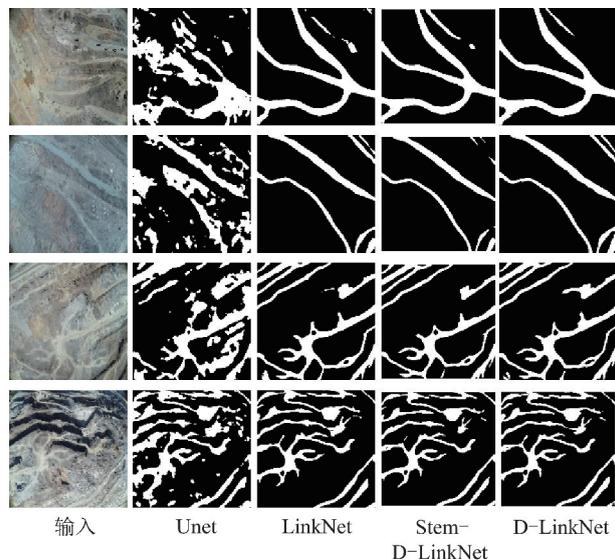


图 13 识别的路径图像

Fig. 13 Recognized road image

### 5.3 实验结果分析

通过上述关于优化训练集与网络模型的分析, 可以得出结论训练集经过优化后比未优化训练出的网络更优。虽 D-LinkNet 在训练模型的 IOU 指标比 LinkNet 低 2%, 但 D-LinkNet 较 LinkNet 有着更好的连续性。运用优化训练集后的 D-LinkNet 可以识别更好的露天矿图像, 在生成露天矿路网模型方面更具优势。通过对 D-LinkNet 网络提取的道路图像分析表明训练的模型在识别的露天矿主干道精确可靠, 在识别临时道路上还存在一定局限性。如图 14 所示为洛阳钼矿中心干道路网。



图 14 洛阳钼矿中心干道路网

Fig. 14 Luoyang molybdenum mine central dry road network

### 5.4 露天矿路网模型精度

目前无人矿车对高精度地图的精度要求普遍低于 1 m。本文运用无人机采集到的露天矿图像的分辨率为  $5\,472 \times 3\,648$ , 最终得到的建模图像的分辨率也是  $5\,472 \times 3\,648$ , 也因此使得运用本方法生成的露天矿路网模型精度高达 0.05 m, 满足无人矿车对高精度路网的导航需求。本方法在构建相同精度的路网模型条件下, 较传统方法可大幅缩短更新周期, 随着智能开采技术的不断发展, 露天矿区路网模型需频繁更新, 相信运用深度学习的方法提取露天矿路网是未来露天矿路网提取的新趋势。

## 6 结 论

(1) 无人机采集数据的过程必须具备多元性, 并要对采集到的图像进行道路分类和数据互补, 以增加数据集的普适性。

(2) 为更好的提取图像中的道路信息, 应按照道路的复杂度选择适当的神经网络结构并通过实验测试确定所需网络层数, 以确保道路信息提取过程高效进行。

(3) 生成高精度路网模型后, 须对路网模型进行相应修复和校准, 以保证模型的地理信息精确。

(4) 较传统路网提取方法缩短了路网建模的工作量, 并提升了路网的精度。但在此基础上, 如何进一步提高精度和实时处理速度, 如何将其与露天矿无人驾驶无缝对接等仍是下一步实现露天矿智能开采的重要研究方向。

### 参考文献 (References):

- [1] 米春蕾, 彭玲, 姚晓婧, 等. 基于浮动车轨迹数据的路网快速提取[J]. 地理与地理信息科学, 2019, 35(1): 12-19.  
MI Chunlei, PENG Ling, YAO Xiaojing, et al. Rapid extraction of road network based on floating vehicle trajectory data[J]. Geography and Geographic Information Science, 2019, 35(1): 12-19.
- [2] 王冬, 张焱, 姜俊奎. 基于浮动车轨迹数据的城市路网提取[J]. 中国科技论文, 2019, 14(2): 226-231.  
WANG Dong, ZHANG Yan, JIANG Junkui. Urban road network extraction based on floating car track data[J]. Chinese Science and

- Technology Paper, 2019, 14(2): 226-231.
- [3] 邬群勇, 吴祖飞, 张良盼. 出租车 GPS 轨迹集聚和精细化路网提取[J]. 测绘学报, 2019, 48(4): 502-511.  
WU Qunyong, WU Zufei, ZHANG Liangpan. Taxi GPS track aggregation and refined road network extraction[J]. Journal of Surveying and Mapping, 2019, 48(4): 502-511.
- [4] 贺浩, 王仕成, 杨东方, 等. 基于 Encoder-Decoder 网络的遥感影像道路提取方法[J]. 测绘学报, 2019, 48(3): 330-338.  
HE Hao, WANG Shicheng, YANG Dongfang, et al. Road extraction method of remote sensing image based on encoder decoder network[J]. Journal of Surveying and Mapping, 2019, 48(3): 330-338.
- [5] XIN J, ZHANG X, ZHANG Z, et al. Road extraction of high-resolution remote sensing images derived from densenet [J]. Remote Sens, 2019, 11(21): 2499.
- [6] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[A]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Las Vegas: IEEE press, 2016: 770-778.
- [7] ZHOU L, ZHANG C, WU M. D-LinkNet: Linknet with pretrained encoder and dilated convolution for high resolution satellite imagery road extraction[A]. IEEE/CVF Conference on Computer Vision & Pattern Recognition Workshops [C]. Salt Lake City: IEEE, 2018: 182-186.
- [8] PENG B, LI Y, FAN K, et al. New network based on d-linknet and densenet for high resolution satellite imagery road extraction [A]. IGARSS 2019-2019 IEEE International Geoscience and Remote SENSING Symposium [C]. Yokohama, 2019: 3939-3942.
- [9] 孙效玉, 田凤亮, 张航, 等. 基于 GPS 数据的露天矿道路网自动提取[J]. 煤炭学报, 2017, 42(11): 3059-3064.  
SUN Xiaoyu, TIAN Fengliang, ZHANG Hang, et al. Automatic extraction of open pit road network based on GPS data[J]. Journal of Coal Industry, 2017, 42(11): 3059-3064.
- [10] 李强, 陈宜金. 基于卡车的海量 GPS 轨迹数据的矿区路网自动更新技术[J]. 煤炭工程, 2017, 49(4): 94-97.  
LI Qiang, CHEN Yijin. Automatic updating technology of mine road network based on massive GPS track data of truck [J]. Coal Engineering, 2017, 49(4): 94-97.
- [11] 曾发明, 杨波, 吴德文, 等. 基于 Canny 边缘检测算子的矿区道路提取[J]. 国土资源遥感, 2013, 25(4): 72-78.  
ZENG Faming, YANG Bo, WU Dewen, et al. Mining area road extraction based on Canny edge detection operator [J]. Remote Sensing of Land and Resources, 2013, 25(4): 72-78.
- [12] 王植. 一种基于无人机遥感影像的露天矿道路提取方法[P]. 中国专利: CN104966091A, 2015-10-07.
- [13] 孙臣良, 刘静. 露天矿运输道路网络的建立及其路径优化[J]. 科技导报, 2011, 29(30): 47-51.  
SUN Chenliang, LIU Jing. The establishment of transportation road network in open pit mine and its path optimization [J]. Science and Technology Guide, 2011, 29(30): 47-51.
- [14] 卢安毅, 贾玉安. 基于无人机航拍的矿山地质测绘图像分辨率系统研究[J]. 世界有色金属, 2019, 26(11): 13-14.  
LU Anyi, JIA Yu'an. Research on resolution system of mine geological mapping image based on uav aerial photo [J]. World Non-ferrous Metall, 2019, 26(11): 13-14.
- [15] 王欢, 陈向宁, 姜明勇. 偏色图像的色彩还原算法实现[J]. 四川兵工学报, 2012, 33(3): 109-111.  
WANG Huan, CHEN Xiangning, JIANG Mingyong. The color restoration algorithm of the partial color image realizes [J]. Journal of Sichuan Ordnance Engineering, 2012, 33(3): 109-111.
- [16] CHAURASIA A, CULURCIELLO E. LinkNet: Exploiting encoder representations for efficient semantic segmentation[A]. 2017 IEEE Visual Communications and Image Processing (VCIP) [C]. Saint Petersburg: IEEE, 2017: 1-4.
- [17] YU F, KOLTUN V. Multi-Scale Context Aggregation by Dilated Convolutions[A]. International Conference on Learning Representations [C]. San Juan: Elsevier, 2016.
- [18] DENG J, DONG W, SOCHER R, et al. ImageNet: A large-scale hierarchical image database[A]. IEEE Conference on Computer Vision & Pattern Recognition [C], Miami: IEEE, 2009.
- [19] DIEDERIK K, JIMMY B. Adam: A method for stochastic optimization[A]. International Conference on Learning Representations [C]. Salerno: Elsevier, 2014: 1-15.
- [20] 陈启成. 3D 打印建模: Autodesk Meshmixer 实用基础教程[M]. 北京: 机械工业出版社, 2016.