

基于改进 DeepLabv3+ 网络的露天矿路网提取方法

郭梦利^{1,2}, 阮顺领^{2,3*}, 卢才武^{2,3}, 顾清华^{2,3}

¹ 西安建筑科技大学管理学院, 陕西 西安 710055;

² 西安市智慧工业感知计算与决策重点实验室, 陕西 西安 710055;

³ 西安建筑科技大学资源工程学院, 陕西 西安 710055

摘要 针对无人机获取的露天矿影像道路提取过程中道路边界信息丢失和路网提取不准确问题, 提出一种基于改进 DeepLabv3+ 网络的露天矿路网提取方法。利用 Retinex 算法对原始图像进行降噪预处理, 得到色彩和光照均衡的数据集; 并针对道路区域与背景所占像素比例相差较大的特点, 使用占比加权的方法解决了网络训练中正负样本严重不平衡的问题; 最后在原始 DeepLabv3+ 模型的基础上构建具有不同空洞速率的密集连接 ASPP 模块来优化所提取的露天矿道路网络, 扩大道路特征点的感受野, 提高多尺度特征的覆盖范围。实验结果表明, 该语义分割方法的效果优于原 DeepLabv3+ 算法, 平均交并比达到 79.27%, 能够在较大范围内准确地提取道路目标, 可应用于露天矿区主干路网的提取。

关键词 遥感; 露天矿; 路网提取; DeepLabv3+; 空洞空间金字塔池化

中图分类号 TD672

文献标志码 A

doi: 10.3788/LOP202158.2228005

Road Extraction Method of Open-Pit Mine Based on Improved DeepLabv3+ Network

Guo Mengli^{1,2}, Ruan Shunling^{2,3*}, Lu Caiwu^{2,3}, Gu Qinghua^{2,3}

¹ School of Management, Xi'an University of Architecture and Technology, Xi'an, Shaanxi 710055, China;

² Xi'an Key Laboratory of Intelligent Industry Perception Computing and Decision Making, Xi'an, Shaanxi 710055, China;

³ School of Resource Engineering, Xi'an University of Architecture and Technology, Xi'an, Shaanxi 710055, China

Abstract An improved road network extraction method of open-pit mine based on DeepLabv3+ is proposed to address road boundary information loss and inaccurate road network extraction during road extraction of open-pit mine images captured using unmanned aerial vehicle. First, the Retinex algorithm is used to preprocess the original images to get a dataset with balanced color and light. Second, because the proportion of pixels between the road region and background are largely different, the proportion weighting method is used to correct the serious imbalance between positive and negative samples in network training. Finally, a densely connected ASPP module with different rates is built using the DeepLabv3+ model to optimize the feature extraction of the open-pit mine road, thereby expanding the receptive field of the road feature points and improving the coverage of multiscale features. Experimental results show that the semantic segmentation method is better than the original DeepLabv3+ algorithm. The mean intersection over union reaches 79.27%, accurately extracting road areas in a large range. The proposed method can be applied to extract the main road network of open-pit mines.

Key words remote sensing; open-pit mine; road extraction; DeepLabv3+; atrous spatial pyramid pooling

OCIS codes 100.4996; 100.3008; 280.4788

收稿日期: 2020-12-14; 修回日期: 2021-01-11; 录用日期: 2021-01-21

基金项目: 国家自然科学基金(51974223, 51774228)、陕西省自然科学基金基础研究计划项目(2019JM-492)

通信作者: *ruanshunling@163.com

1 引言

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,是发展露天矿智慧矿山的基础数据支撑。随着露天矿区无人驾驶的逐步推广应用,露天矿路网数据的快速生成和更新显得尤为重要。准确的三维露天矿路网信息在露天矿无人驾驶智能交通导航、智能调度、数字地图更新、道路发展规划、应急保障等方面具有重大的应用意义。在此情况下,如何利用无人机低空遥感技术拍摄的海量数据,快速且完备地自动提取具有导航意义的露天矿区路网图是目前亟待解决的问题之一。

目前许多研究都是对高分辨率遥感图像下的城市结构化道路进行提取,主要分为两类:道路中心线提取和道路区域提取。道路中心线是线性元素,空间几何是由一系列路点序列依次连接组成的直线,是道路的本质特征线,道路中心线一般通过形态学或中轴变换(median axis transformation, MAT)从道路二值图的分割图像中获得^[1]。道路区域是表面元素,是通过图像分割生成的,不同空间形状结构的道路边界线组成了各种表面元素的形状结构^[2]。本文主要研究从高分辨率的无人机倾斜图像中提取露天矿道路区域。

在早期计算机视觉领域中,许多学者研究了基于遥感图像的道路自动提取技术,但是这些研究绝大部分采用了“特征匹配+道路连接”的思路。如文献[3]提出一种基于无人机倾斜摄影的三维路网提取方法,在道路特征的基础上采用支持向量机(support vector machine, SVM)多特征分类方法识别道路面片,最后进行道路面片三维连接和道路边缘三维修正,实现三维路网的提取,但是提取精度不高,没有解决树木遮盖、阴影等问题。文献[4]融合多种特征实现道路的提取,效果较好,但模型较为复杂。文献[5]结合数学形态算法和 EM 聚类实现对遥感影像道路的提取,但该方法对道路边缘的提取还不够完善。这些方法虽然在一定的应用场合下取得了较好的效果,但是其特征设计和各算法中诸多阈值参数需要人工调整和设计,适用于小规模的道路数据应用,而且这些参数取值在不同的图像中可能会有所不同,在适用性上具有很大的局限性。

随着深度学习技术的发展,深度学习方法在图像分类方面表现出优越的性能^[6],文献[7]结合 DenseNet 模块,运用进化算法优化卷积神经网络,

解决了网络中大量参数与网络结构设计中人工调试的问题。2017 年,Shelhamer 等^[8]提出全卷积网络(fully convolution networks, FCN),解决了语义级别的图像分割问题,也形成了许多应用在不同场景的语义分割模型^[9-12]。空洞卷积(dilated convolutions)^[13]允许网络在增加感受野的同时保持特征图的尺寸(分辨率, resolution)不变,保留空间信息。之后,有人提出了基于编码器-解码器(encoder-decoder)结构的网络(如 U-Net^[14], SegNet^[15]等)。文献[16]提出了基于全卷积神经网络的道路提取方法,该方法能够实现道路高维复杂特征自动提取,获得准确的道路空间位置信息。文献[17]提出了一种提取遥感图像道路的 DenseU-Net 模型,将密集连接方式与 U-Net 相结合,该方法参数少、鲁棒性强,在一定程度上解决了树影遮挡问题。文献[18]提出了多尺度上下文聚合的对抗性网络,将遗传算法与多尺度上下文聚合方法相结合,提高了无人机遥感图像道路提取的准确性,但计算效率还有待提高。文献[19]针对遥感影像道路的特点,设计了 encoder-decoder 网络结构,更多地保留了道路局部信息特征,增强了网络分割道路的细节表示能力,结果表明在 Massachusetts Roads 数据集上,该方法有很强的泛化能力和细节表现力。文献[20]在 SegNet 网络架构上结合 ELU 激活单元,提升了道路的分割提取精度,不足之处是该方法没有充分考虑道路的自身特点。文献[21]提出一种将 VGG 卷积神经网络与张量投票相结合的道路提取方法,该方法有效地消除了噪声干扰,填补了道路面孔洞与断裂,具有较强的实用性,但在道路遮挡严重时还需进一步优化。文献[22]基于深度学习方法实现了道路标线的自动提取与分类,并利用 KD 树聚类分割算法结合矢量化方案实现了道路标线的矢量化,提升了道路标线获取与分类的智能化程度。

受到密集卷积网络和编码-解码网络结构的启发,本文提出一种将密集并行空洞卷积和 DeepLabv3+ 网络^[23]相结合的露天矿路网提取方法——Road-DeepLab,其基本网络结构是 DeepLabv3+。所提出的 Road-DeepLab 和 DeepLabv3+ 的不同之处在于:首先,使用密集连接的 ASPP(atrous spatial pyramid pooling)模块代替普通空间金字塔模块作为多尺度特征提取构建块;其次,针对利用无人机倾斜技术拍摄的图像中道路和非道路比例失衡的问题,修改了网络中的交叉熵

损失函数。基于上述两点,本文构建了一种 Road-DeepLab 路网提取方法,通过与不同网络结果进行对比,验证 Road-DeepLab 网络对露天矿路网提取的性能。

2 道路特征提取网络模型

露天矿山道路运输经常会出现临时道路,其纹理和结构与露天矿山主干非结构化道路具有一定的相似性。为了识别多种道路区域,有效聚合道路的多尺度特征信息,采用主流的 DeepLabv3+ 编解码分割模型进行道路特征提取。编码模块中参考了不同尺度的道路特征信息,并且在学习更深层次特征时伴随池化和有步长的卷积操作,必然会导致在分

割倾斜影像时出现目标道路的边界结构信息严重丢失的情况。而 Road-DeepLab 网络中的 decoder 模块正好可以有效解决道路边界信息丢失的问题。DeepLabv3+ 网络将空洞空间金字塔池化模块和编解码结构相融合,包括基网络对输入图像的特征提取、级联和并联模式下的具有不同空洞速率的空洞卷积层、特征图像空间分辨率恢复。在级联模式下,将下层空洞卷积的输出作为上层空洞卷积的输入,扩大了感受野;并联模式即 Road-DeepLab 网络的 ASPP 模块,在不影响输入图像分辨率的情况下,实现在允许输入多尺度目标的同时重构空间信息来捕捉道路的边界。基于 DeepLabv3+ 的路网提取网络结构如图 1 所示,其中 r 为采样率。

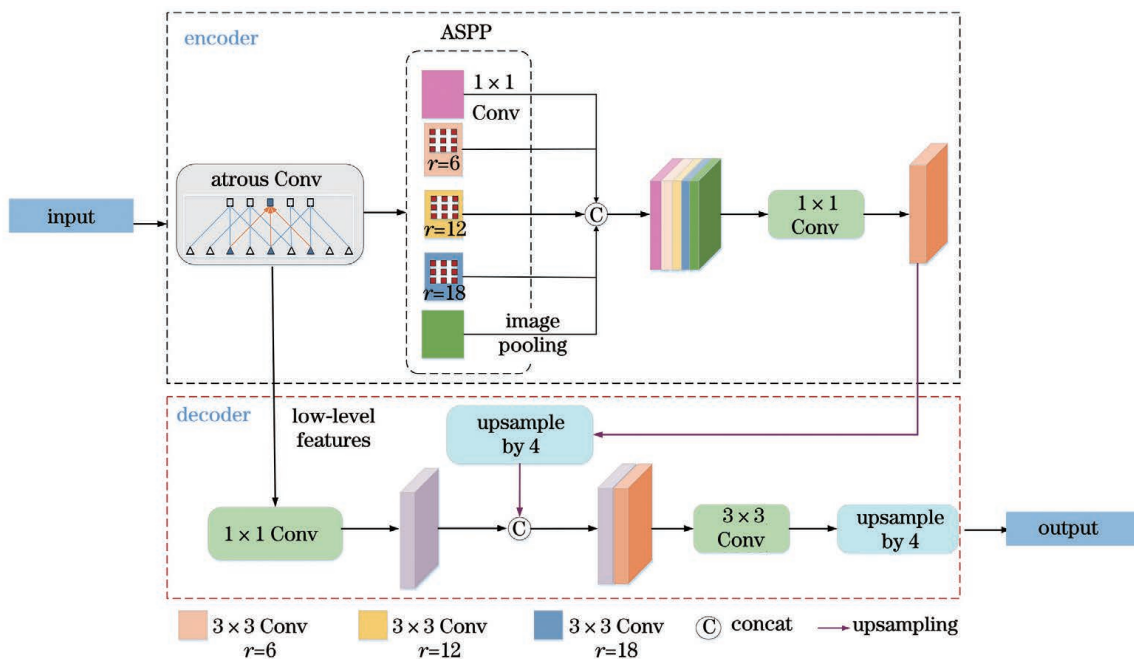


图 1 基于 DeepLabv3+ 的路网提取网络结构

Fig. 1 Road extraction network structure based on DeepLabv3+

3 道路图像分割优化模型

3.1 编解码模块

露天矿道路一般呈网状,没有规则的结构,为了能够提取道路的高级特征图,需要更深的网络层次。随着网络层次的加深,前一层网络参数的变化会导致每一层网络的输入分布发生变化,同时会导致梯度消失,因此在每个 3×3 的深度卷积之后加入批标准化(batch normalization, BN)处理和纠正线性单元(rectified linear unit, ReLU),使每个卷积核的通道数均为 256 条,从而减少训练过程中每层输入数据分布的变化。

在网络编码过程中,首先将预处理后的道路图像经过基础网络 Xception 和采样率为 6、12、18 的 3×3 并行密集空洞卷积 ASPP 模块进行道路特征提取,合并之后进行 1×1 卷积压缩特征提取,最后经过 4 倍上采样增加特征分辨率,得到特征图 F1;如上所述,在编码过程中,与 F1 具有相同空间分辨率的低级特征拥有 256 条通道,占据较大的权重,为了防止在网络训练时偏向低级特征,对 encoder 提取的与 F1 具有相同空间分辨率的特征图利用 48 通道 1×1 卷积进行卷积降维,得到特征图 F2,该操作有利于平衡 F2 的权重,降低网络训练难度。其次,将 F1 与 F2 串联得到特征图 F3。最后,通过对 F3 进行 3×3 的卷积和因子为 4 的双线性插值上

采样来改善特征图,将输出的道路特征图空间分辨率恢复成与输入图像相同,经过 Softmax 分类层输出

路网分割图,优化后的路网提取 Road-DeepLab 模型如图 2 所示。

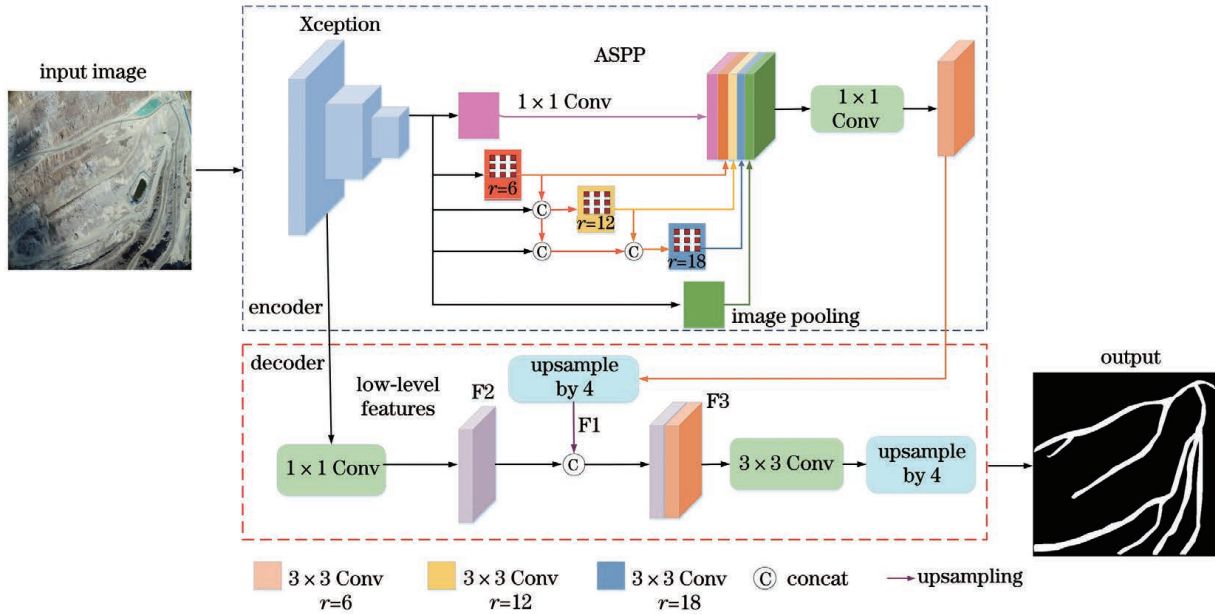


图 2 所设计的 Road-DeepLab 路网提取模型
Fig. 2 Proposed road extraction model of Road-DeepLab

在整个露天矿道路提取网络中,为了避免训练过程中道路的有效特征信息在损失函数中被平均后不显著,影响训练效果,采用逐像素的加权交叉熵损失函数,如(1)式所示。

$$L = -\frac{1}{n} \sum_{i=1}^n \left[\lambda_1 y_i \ln \alpha_i + \lambda_2 e^{-f(d_i)} (1 - y_i) \cdot \ln(1 - \alpha_i) \right], \quad (1)$$

式中: y_i 为第 i 个像素的真实值; α_i 为经过 Softmax 后第 i 个像素的预测值;比例系数 λ_1 和 λ_2 均为正数,且 $\lambda_1 \geq \lambda_2$ 。对于每个像素 x ,Softmax 分类器的输出为

$$P_k(x) = \frac{\exp[\alpha_k(x)]}{\sum_{k=1}^K \exp[\alpha_k(x)]}, \quad (2)$$

式中: x 为二维平面上的像素位置; K 为类别总数; $\alpha_k(x)$ 表示 Softmax 输出的像素 x 对应的第 k 条通道的值; $P_k(x)$ 表示像素 x 属于第 k 类的概率。因此,整个网络的损失可表示为

$$E = \sum_x w_l \ln [P_l(x)], \quad (3)$$

式中: w_l 为类别 l 的损失权重; $P_l(x)$ 为像素 x 属于真实类别 l 的概率。

3.2 特征提取优化

露天矿道路特征提取编码过程中包含了多步卷积和池化操作,同时 DeepLabv3+ 中的 ASPP 模块

以不同采样率的空洞卷积对输入的道路图进行采样,一连串的卷积采样过程使得特征信息中所包含的道路像素较为稀疏,因此参与采样像素运算的数量也相对减少,此现象在二维的情况下更加明显。为了获得更加密集的像素采样,本网络的 ASPP 模块采用“跳层密集连接”来共享信息,不同扩张率的卷积相互依赖,实现每一层的输出与下一层的输入特征图相连接,并将连接结果作为该卷积层的输入,其中包含了 3 层采样率分别为 6、12、18 的 3×3 卷积,每一层都包含扩张卷积的输出,除采样率为 6 的顶层卷积层外,其余 2 层都整合了多尺度对特征图进行处理,经过 3 层级联堆叠,获得了更大的感受野,得到更为密集的特征图输出。

假设 H_k^v 表示卷积核大小为 k 、空洞速率为 v 的卷积操作,则 ASPP 模块可表示为

$$y = H_3^6(x) + H_3^{12}(x) + H_3^{18}(x). \quad (4)$$

空洞卷积可以在不改变特征图分辨率的情况下增大感受野,使得每个卷积输出都包含较大范围的信息。在一维情况下,对于输出信号 y 和输入信号 x ,空洞卷积计算公式为

$$y(i) = \sum_{z=1}^Z x(i + v \cdot z)w(z), \quad (5)$$

式中: $w(z)$ 表示滤波器在第 z 个位置的参数; Z 表示滤波器的尺寸。加入空洞卷积相当于在卷积核的

两个值之间插入 $r-1$ 个 0, 因此感受野会增大, 并且两者之间为正相关关系。对于一个卷积核大小为 k 、空洞速率为 v 的空洞卷积, 它能提供的感受野大小为

$$R = (v - 1) \times (k - 1) + k, \quad (6)$$

对于多层级联的空洞卷积层 R_1, R_2, \dots, R_n , 它能够提供的感受野大小为

$$R = R_1 + R_2 + \dots + R_n - (n - 1). \quad (7)$$

因此, 所设计的用于获取稠密特征的 ASPP 模块, 能提供的感受野大小如图 3 所示。




图 3 所设计网络的 ASPP 感受野

Fig. 3 Receptive field of ASPP in the proposed network

3.3 道路结构的数据不平衡修正

露天矿道路提取本质上是一个二分类任务, 将道路作为前景信息, 其余部分视为背景信息。在本实验的数据集中, 经计算道路占 15%, 其他部分占 85%。由此可知, 实验数据中道路和背景之间的像素比例相差较大, 如果使用相同的权重直接训练网络, 则会使网络倾向于将道路划分为背景类, 最终的提取结果是生成的道路提取图中几乎没有道路像素区域, 导致分类模型的性能变差。因此, 本实验根据道路和背景所占的像素比分别为其设置合适的权重来消除此类不平衡带来的影响。具体方法为: 为背景类设置较小的损失权重系数, 为道路区域类设置较大的损失权重系数, 计算公式为

$$\omega_0 = \frac{\sum_i N_i / 2}{\sum_i N_{i0}}, \quad (8)$$

$$\omega_1 = \frac{\sum_i N_i / 2}{\sum_i N_{i1}}, \quad (9)$$

式中: ω_0 为背景像素的权重; ω_1 为道路区域像素的权重; N_{i0} 为第 i 幅图像中背景像素数量; N_{i1} 为第 i 幅图像中道路区域像素数量; N_i 为第 i 幅图像中像素的总数。经过多次实验来调整参数, 最后验证当背景和道路的权重之比为 1:4 (均取整) 时训练效果最好。

4 实验与分析

4.1 数据扩充和配置

实验的数据是由无人机在航拍高度为 200 m, 地面重叠度为 75% 的条件下对洛阳某露天矿按照不同光照、时间和拍摄角度拍摄得到的。由于采集的数据量有限, 为了防止在训练过程中因目标样本数量不足而产生过拟合现象, 增强模型的稳健性, 将原始图像按照 9:1 随机分为训练集和测试集两部分, 并将道路图像分辨率规范到 1024 pixel \times 1024 pixel, 然后对训练集进行旋转、缩放、裁剪等预处理操作, 将可用的数据量大约扩充了 3 倍, 增强后的数据图像共 1200 张, 其中训练集 1100 张, 测试集 100 张。考虑到计算机性能和计算速度, 对规范后的图像进行切分, 切块后的图像分辨率均为 512 pixel \times 512 pixel。

计算机硬件配置为处理器 AMD R7-4800H, 内存为 16 GB, 显卡为 NVIDIA GeForce RTX 2060GPU, 操作系统为 Windows 10。所涉及的网络均在 TensorFlow 框架下搭建, 实验程序语言为 Python。

4.2 样本预处理

露天矿区自然环境较差、矿区作业复杂, 如卡车运载、挖掘等机械操作, 导致矿区现场常常伴有尘土、扬沙等现象; 同时, 无人机在飞行时经常采用倾斜的方式获取图像, 此时会受到天气的影响, 这些客观条件都会影响图像质量。经对原始数据集的分析, 发现部分图片模糊不清、色彩暗淡, 这会影响网络对图像中道路特征的学习和提取, 不能直接作为网络的输入图像。因此, 使用多尺度 Retinex (multi scale Retinex, MSR) 算法对原始图像进行预处理, 计算公式为

$$r(x, y) = \sum_{n=1}^N \omega_n \{ \ln S_n(x, y) - \ln [F_n(x, y) * S_n(x, y)] \}, \quad (10)$$

式中: N 为尺度个数; $F_n(x, y)$ 为第 n 个尺度上的高斯环绕函数; ω_n 为每个尺度所占权重; $*$ 为卷积符号。根据道路的景深信息对不同区域进行去雾, 在增强图像中远处道路细节的同时又保持近距离道路的色彩, 抑制光晕现象, 保持道路图像的高保真度, 达到色彩和光照均衡的效果。图 4 为降噪增强前后的对比图。

4.3 模型性能分析

使用上述 UAV 数据集对 Road-DeepLab 进行网络训练, 训练参数如表 1 所示。其中: base_




图 4 降噪前后对比图。(a)原始道路图像;(b)降噪后的道路图像

Fig. 4 Comparison before and after noise reduction.
(a) Original road image; (b) road image after noise reduction

learning_rate 表示基础学习率, training_number_of_steps 表示迭代次数, train_batch_size 表示每次学习图像的数量, weight_decay 表示权重衰减。

表 1 Road-DeepLab 网络的训练参数

Table 1 Training parameters of Road-DeepLab network

Parameter	Value
Weight_decay	0.0001
Training_number_of_steps	100
Base_learning_rate	0.0001
Train_batch_size	2

图 5 所示为训练过程中的损失曲线,可以看出模型在训练到第 9 代时损失值出现了一个比较明显的上升变化,这是因为原始图像经过 Xception 网络后包含了大量的道路低级特征图,而密集连接的

表 2 不同 ASPP 模块的道路分割结果对比

Table 2 Comparison of road segmentation results of different ASPP modules

Structure	Max receptive field	MIOU / %	Time / ms
ASPP(6,12,18)	37	75.34	123
Dense ASPP(6,12)	37	75.23	88
Dense ASPP(6,18)	49	76.98	91
Dense ASPP(6,12,18)	73	79.24	127
Dense ASPP(6,12,18,24)	121	79.83	169

4.4 对比实验结果及分析

为了衡量网络的性能,采用 MIOU 和像素精度(pixel accuracy, PA)对实验结果进行评估比较,计算公式为

$$f_{\text{MIOU}} = \frac{1}{m} \sum_{i=1}^m \frac{P_{ii}}{\sum_{j=1}^m P_{ij} + \sum_{j=1}^m P_{ji} - P_{ii}}, \quad (11)$$

ASPP 模块输出的是道路的高级特征图,两种特征图融合时低级特征图的存在会降低高级特征图的占比。在训练到第 24 代之后,损失值趋于一个平缓稳定的状态,说明模型基本收敛。在网络训练收敛之后,选取损失值最低的权重模型作为本次实验的测试模型,进行所设计网络有效性的验证。

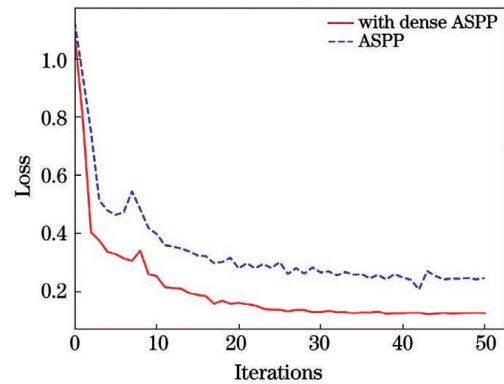


图 5 Road-DeepLab 模型的损失曲线

Fig. 5 Loss curve of Road-DeepLab model

构建不同的 ASPP 模块进行道路分割,其结果对比如表 2 所示。当使用密集连接 ASPP(6, 12, 18, 24) 时分割精度最高,但其分割一幅图像的时间比原始结构的 ASPP 多 46 ms,消耗时间大约超出原分割网络的 1/3,而密集连接 ASPP(6,12,18) 的平均交并比(mean intersection over union, MIOU)相比于原始网络提高了 3.90%,分割时间只延长了 4 ms,具有很高的时效性,由此也说明使用密集连接的 ASPP(6,12,18) 代替原始网络的 ASPP 模块可以实现很好的性能。

$$f_{\text{PA}} = \frac{\sum_{i=1}^m P_{ii}}{\sum_{i=1}^m \sum_{j=1}^m P_{ij}}, \quad (12)$$

式中: P_{ij} 表示真实值为 i 但被预测为 j 的像素数; m 表示类别个数。

将相同的数据集分别对 U-Net、SegNet、DeepLabv3+ 网络进行训练和实验,并将实验结果

与本文算法的结果进行比较。图 6 所示为 Road-DeepLab 模型和其他模型在验证集上的损失曲线对比,表 3 所示为不同网络模型的性能比较。由表 3

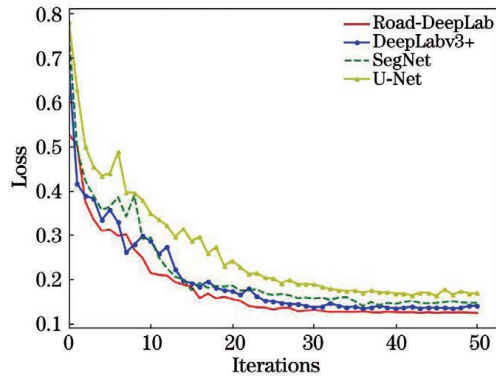


图 6 不同模型的损失对比

Fig. 6 Comparison of losses of different models

可知,U-Net 的性能最差,相比于其他 3 个模型,Road-DeepLab 网络的结果最优,其 MIOU 值为 79.27%。从图 6 及表 3 可以看出,Road-DeepLab 模型的损失更少,精度却更高。

表 3 不同模型性能比较

Table 3 Performance comparison of different models

Model	PA / %	MIOU / %
U-Net	69.80	59.87
SegNet	72.74	61.06
DeepLabv3+	88.59	75.43
Road-DeepLab	92.41	79.27

图 7 为不同网络的提取结果对比图。为了验证所设计网络结构的优越性,将相同的测试图输入预




图 7 不同网络路网提取结果对比。(a)原始图像;(b)U-Net 提取结果;(c)SegNet 提取结果;(d)DeepLabv3+ 提取结果;(e)Road-DeepLab 提取结果

Fig. 7 Comparison of extraction results using different road networks. (a) Original images; (b) U-Net extraction results; (c) SegNet extraction results; (d) DeepLabv3+ extraction results; (e) Road-DeepLab extraction results

训练好的不同模型,结果如图 7 所示。由图 7 可知,使用 Road-DeepLab 网络的提取效果优于其他 3 个网络,该网络提取的露天矿路网轮廓更加清晰,提取的道路较完整且连续,道路边缘位置准确,很少出现漏检和过拟合现象;而其他 3 个网络均存在过拟合现象,提取结果存在大量道路断连和毛边问题。使用 U-Net 的提取效果最差,几乎不能体现露天矿道路的几何形状和分布;SegNet 次之,虽然可以看出道路的大概轮廓,但存在较多孤立点和识别误区,大量道路出现断裂,存在漏检现象,仍然不能体现出道路的基本信息;原始 DeepLabv3+ 网络的提取结果虽然能够显示道路的结构,但是存在部分道路断裂和噪点的情况。比较而言,Road-DeepLab 网络更具有优越性和有效性,有利于获取真实、连续的道路网。

为了在大面积范围内识别露天矿道路,将一




图 8 Road-DeepLab 模型的路网提取效果图。(a)原始图像;(b)标签图像;(c)提取图像

Fig. 8 Road extraction effect of Road-DeepLab model. (a) Original image; (b) label image; (c) extracted image

5 结 论

基于无人机拍摄的露天矿道路图像数据,提出一种改进 DeepLabv3+ 网络的露天矿路网提取方法。首先,通过对目标样本二分类问题作类别不平衡修正,有效地避免了对道路和背景使用相同的权重进行网络训练,改善了网络的分类性能。其次,构建不同采样率的密集连接 ASPP 模块,通过实验对比不同 ASPP 模块结果,说明所设计网络使用的密集连接 ASPP(6,12,18)模块在分割时间和性能上达到更优的效果,可以获取更密集和更丰富的多尺度道路信息。经过对比网络 U-Net、SegNet、DeepLabv3+ 和 Road-DeepLab,结果表明 Road-DeepLab 网络提取的路网最干净,很少出现断裂和毛边情况,而且基本上可以提取完整的露天矿主干道网,能够为露天矿无人驾驶和智慧调度提供精确的路径。但是,由于倾斜影像覆盖范围较广,因此图像会包含采场中的一些临时道路,其纹理和结构与主道路有所区别,导致网络不能提取非常完备的

幅道路图像平均切分成 4 幅,并将切分后的 4 幅子图作为网络输入进行测试,然后将输出的切片按照切割的顺序进行拼接,恢复出一张覆盖范围较大的路网图,如图 8 所示。其中,图 8(a)中虚线框与实线框显示的部分分别与图 8(c)的内容相对应。为了验证本网络提取道路细节的效果,在制作图像标签时故意没有标注整体道路区域。结果显示,图 8(b)与图 8(c)的不同之处在于框选出来的部分,结合图 8(a)~(c)可知,Road-DeepLab 网络可识别出标签以外比较细小的道路,并且延长了图像视野中有效的道路,如图 8 中虚线框部分所示。实线框部分为渣石堆,由于其顶部被铲平和经过长期沉淀,其纹理、颜色和结构与露天矿非结构化道路非常相似,因此分类器误将渣石堆部分识别为道路,但是总体上分割出来的露天矿路网与真实路径基本一致。

道路信息,这也是提取露天矿路网下一步需要改进的地方。

参 考 文 献

- [1] Miao Z L, Shi W Z, Zhang H, et al. Road centerline extraction from high-resolution imagery based on shape features and multivariate adaptive regression splines[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(3): 583-587.
- [2] Li Z L, Huang P Z. Quantitative measures for spatial information of maps[J]. International Journal of Geographical Information Science, 2002, 16(7): 699-709.
- [3] Li L. 3D road network extraction method based on UAV oblique photography [J]. China Journal of Highway and Transport, 2019, 32(11): 219-226, 254.
李磊. 一种基于无人机倾斜摄影的三维路网提取方法[J]. 中国公路学报, 2019, 32(11): 219-226, 254.
- [4] Cao Y G, Wang Z P, Shen L, et al. Fusion of pixel-based and object-based features for road centerline

- extraction from high-resolution satellite imagery[J]. *Acta Geodaetica et Cartographica Sinica*, 2016, 45(10): 1231-1240, 1249.
- 曹云刚, 王志盼, 慎利, 等. 像元与对象特征融合的高分辨率遥感影像道路中心线提取[J]. *测绘学报*, 2016, 45(10): 1231-1240, 1249.
- [5] Zhang Z J, Yang F B. Road extraction algorithm for remote sensing images based on improved expectation-maximization clustering [J]. *Laser & Optoelectronics Progress*, 2020, 57(6): 061005.
- 张宗军, 杨风暴. 基于改进最大期望聚类的遥感影像道路提取算法[J]. *激光与光电子学进展*, 2020, 57(6): 061005.
- [6] Huang S, Li F F, Chen Q. Computed tomography image classification algorithm based on improved deep residual network[J]. *Acta Optica Sinica*, 2020, 40(3): 0310002.
- 黄盛, 李菲菲, 陈虬. 基于改进深度残差网络的计算断层扫描图像分类算法[J]. *光学学报*, 2020, 40(3): 0310002.
- [7] Ma Y J, Liu P P. Convolutional neural network based on DenseNet evolution for image classification algorithm [J]. *Laser & Optoelectronics Progress*, 2020, 57(24): 241001.
- 马永杰, 刘培培. 基于 DenseNet 进化的卷积神经网络图像分类算法[J]. *激光与光电子学进展*, 2020, 57(24): 241001.
- [8] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [9] Wei Y N, Wang Z L, Xu M. Road structure refined CNN for road extraction in aerial image [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(5): 709-713.
- [10] Duan L H, Hu X Y. Multiscale refinement network for water-body segmentation in high-resolution satellite imagery [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(4): 686-690.
- [11] Zhang K H, Liu X H, Chen Y F. Research on semantic segmentation of portraits based on improved Deeplabv3 + [J]. *IOP Conference Series: Materials Science and Engineering*, 2020, 806: 012057.
- [12] Li L F, Sun R Y. Bridge crack detection algorithm based on image processing under complex background [J]. *Laser & Optoelectronics Progress*, 2019, 56(6): 061002.
- 李良福, 孙瑞赞. 复杂背景下基于图像处理的桥梁裂缝检测算法[J]. *激光与光电子学进展*, 2019, 56(6): 061002.
- [13] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions [EB/OL]. (2015-11-23) [2020-12-10]. <https://arxiv.org/abs/1511.07122>.
- [14] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [M] // Navab N, Hornegger J, Wells W, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science*. Cham: Springer, 2015, 9351: 234-241.
- [15] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.
- [16] Liu X, Wang G H, Yang H C, et al. Road extraction from remote sensing image based on fully convolutional networks [J]. *Remote Sensing Information*, 2018, 33(1): 69-75.
- 刘笑, 王光辉, 杨化超, 等. 全卷积神经网络遥感影像道路提取方法[J]. *遥感信息*, 2018, 33(1): 69-75.
- [17] Xin J, Zhang X C, Zhang Z Q, et al. Road extraction of high-resolution remote sensing images derived from DenseUNet [J]. *Remote Sensing*, 2019, 11(21): 2499.
- [18] Li Y X, Peng B, He L, et al. Road segmentation of unmanned aerial vehicle remote sensing images using adversarial network with multiscale context aggregation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(7): 2279-2287.
- [19] He H, Wang S C, Yang D F, et al. An road extraction method for remote sensing image based on Encoder-Decoder network [J]. *Acta Geodaetica et Cartographica Sinica*, 2019, 48(3): 330-338.
- 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.
- [20] Panboonyuen T, Vateekul P, Jitkajornwanich K, et al. An enhanced deep convolutional encoder-decoder network for road segmentation on aerial imagery [M] // Meesad P, Sodsee S, Unger H. *Recent advances in information and communication technology 2017. Advances in intelligent systems and computing*. Cham: Springer, 2018, 566: 191-201.
- [21] Li T Q, Tan H, Dai J G, et al. Road extraction method combining convolutional neural network and tensor voting [J]. *Laser & Optoelectronics Progress*, 2020, 57(20): 201019.
- 李天琪, 谭海, 戴激光, 等. 结合卷积神经网络和张量投票的道路提取方法[J]. *激光与光电子学进展*, 2020, 57(20): 201019.

- [22] Huang G, Liu X L. Automatic extraction and classification of road markings based on deep learning [J]. Chinese Journal of Lasers, 2019, 46 (8): 0804002.
黄刚, 刘先林. 基于深度学习的道路标线自动提取与分类方法[J]. 中国激光, 2019, 46(8): 0804002.
- [23] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 833-851.