

基于残差神经网络的道路提取算法研究*

熊 炜^{1,2,3}, 管来福¹, 童 磊¹, 王传胜¹, 刘 敏^{1,2}, 曾春艳^{1,2}

(1. 湖北工业大学 电气与电子工程学院, 武汉 430068; 2. 湖北工业大学 太阳能高效利用湖北省协同创新中心, 武汉 430068; 3. 美国南卡罗来纳大学 计算机科学与工程系, 南卡 哥伦比亚 29201)

摘 要: 针对遥感图像道路提取信息丢失问题, 提出了一种基于残差神经网络的道路提取算法。首先构建编码器-解码器网络, 结合预编码器以及空洞卷积模块进行训练, 提取更多的语义信息; 其次并联设计的空洞卷积模块加在编码器-解码器结构的中间部分, 它可以对不同感受野的特征图进行特征提取; 最后编码器-解码器之间采用跳连的方式进行多尺度的特征融合, 学习更多低维和高维的特征。实验结果表明, 在 Massachusetts 道路数据集上, 该方法相比其他算法在 Precision、Recall 和 F1-score 性能指标上分别有 11%、0.3% 和 7.4% 的提升; 同时在 Accuracy 指标上也达到了 97.9%, 相比于其他算法, 该算法有一定的应用价值。

关键词: 道路提取; 遥感图像; 空洞卷积; 多尺度特征融合

中图分类号: TP311 **文献标志码:** A **文章编号:** 1005-488X(2020)01-0006-07

Research on Road Extraction Algorithm Based on Residual Neural Networks

XIONG Wei^{1,2,3}, GUAN Laifu¹, TONG Lei¹, WANG Chuansheng¹, LIU Min^{1,2}, ZENG Chunyan^{1,2}
(1. School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, CHN; 2. Hubei Collaborative Innovation Center for High-Efficiency Utilization of Solar Energy, Hubei University of Technology, Wuhan, 430068, CHN; 3. Department of Computer Science and Engineering, University of South Carolina, Columbia, SC 29201, USA)

Abstract: In order to solve the problem of road extraction information loss in remote sensing images, a road extraction algorithm based on residual neural networks was proposed. Firstly, an encoder-decoder network was constructed, combined with pre-coder and dilated convolution module to extract more semantic information. Secondly, the parallel designed dilated convolution module was added to the middle part of the encoder-decoder structure, which could extract features of different receptive field features. Finally, the encoder-decoder used jumper to perform multi-scale feature fusion,

收稿日期: 2019-07-29

* **基金项目:** 国家留学基金项目(201808420418); 国家自然科学基金项目(61571182, 61601177); 湖北省自然科学基金项目(2019CFB530)

作者简介: 熊 炜(1976—), 男, 副教授, 研究生导师, 主要从事图像文档分析与理解、计算机视觉与模式识别、深度学习与人工智能等研究; (E-mail: xw@mail.hbut.edu.cn)

管来福(1991—), 男, 硕士研究生, 研究方向为基于深度学习的高分辨率道路提取技术; (E-mail: 201710329@hbut.edu.cn)

童 磊(1993—), 男, 硕士研究生, 研究方向为基于深度学习的语义分割技术。(E-mail: tonglei@hbut.edu.cn)

learning more low-dimensional and high-dimensional features. In the Massachusetts road dataset, this method had 11 %, 0.3 %, and 7.4 % improvement in Precision, Recall, and F1-score performance indicators. At the same time, it also achieved 97.9 % in the Accuracy index. Compared with other algorithms, the algorithm has certain application value.

Key words: road extraction; remote sensing image; dilated convolution; multi-scale feature fusion

引 言

高分辨率图像中提取道路信息对于地理信息更新有着重要意义,同时它也已经广泛地应用到交通管理、车辆导航、无人驾驶以及城市规划等领域。遥感图像中分割出道路,可以表示为一个二分类问题,即将每个像素分为道路和非道路。经过这么多年的发展,涌现了很多传统的道路提取算法。曹云刚等人^[1]对遥感图像的道路算法进行了总结,按照提取层次的不同分为基于特征、基于对象以及基于知识的道路提取算法。Eslami等人^[2]采用卫星图像进行自动化的交通检测,使用阈值操作进行道路检测,车辆的检测使用支持向量机(Support Vector Machine, SVM)。Zheng等人^[3]提出了轮廓提取的方法,先采用支持向量机将遥感图像划分为道路和非道路,再利用张量投票方法提取图像中的道路轮廓。Zhu等人^[4]提出了MAP-MRF框架,使用了马尔科夫随机场,同时引入模拟退火算法对图像进行分割,提取道路信息;同时还采用了SVM和FCM(Fuzzy C-Mean)模型,利用FCM对遥感图像进行聚类,再使用SVM进一步分类,最后获得道路信息。Wegner等人^[5]提出了条件随机场(Conditional Random Field, CRF)算法。除此之外,Wegner等人还提出了 p^N -Potts模型^[6]可以在高阶CRF中获得有效的推理。Das等人^[7]提出了利用道路的两个显著特征,即明显的光谱对比度和局部线性轨迹,设计了一个多级框架,从高分辨率多光谱卫星图像中提取道路,同时也加入了概率化的支持向量机。王钰等人^[8]提出了一种多特征融合的道路提取算法,结合图像分割的方式完成对象表达,再对光谱特征和空间特征进行多特征融合,通过机器学习的方式提取到初始化道路网络,最后利用二阶矩特征实现道路网络的精细化。

越来越多的研究人员采用卷积神经网络(Convolution Neural Network, CNN)和全卷积网络(Fully Convolutional Network, FCN)进行道路提取。不

同于传统的方法仅仅使用低维信息进行道路获取,卷积神经网络能够通过嵌入很多高维和多尺度信息可以减少错误的检测。文献[9—10]采用了CNN对高分辨率遥感或者航拍图像进行目标分类。Mnih等人^[11]第一次尝试使用深度学习技术解决道路提取任务,提出了一种受限的玻尔兹曼机,从高分辨率的遥感图片中检测道路。Wei等人^[12]提出了一种用于遥感图像道路提取的精细卷积神经网络(RSRCNN),提出了一种新的损失函数,在交叉熵损失函数中合并了道路结构的几何信息。受启发于U-Net^[13]以及深度残差学习^[14]的巨大成功,Singh等人^[15]提出了两步深度卷积神经网络,也是采用U-Net网络结构,主要的区别是采用两个U-Net组合的方式,分别是高精度网络和高召回率网络。Hong等人^[16]提出了Road-RCF(Road Richer Convolutional Features)算法,应用重新构造的道路样本集合和RCF网络生成道路概率,提取初始道路信息,通过细化算法提取道路中心线后,最终提取矢量化道路;Road-RCF算法不足之处在于,不能准确地获得道路的宽度。对比卷积神经网络,全卷积网络可以获得更高维的特征,包含更多抽象的语义信息。Zhong等人^[17]使用FCN检测建筑和道路。Fu等人^[18]设计了基于FCN的多尺度网络,采用CRF细化输出分类图。Panboonyuen等人^[19]提出了一种增强的DCNN框架,该框架通过采用Landscape Metrics(LMs)和CRF针对遥感图像的道路提取,同时使用ELU(Exponential Linear Unit)激活函数提高道路获取的准确性。Qin等人^[20]提出了BASNet算法,基于残差神经网络设计了预测网络和残差细化网络相组合的框架,两个网络都采用了编码器-解码器结构,设计的网络采用深监督的方式,还融合了多种损失函数,对显著性目标进行检测。Devalla等人^[21]提出了DRUNET算法,利用残差块构建了U-Net网络,设计了四层网络结构,每一层相对应的编码器-解码器采用了相同的空洞卷积率进行特征编码和特征解码,在OCT(Optical Coherence Tomogra-

phy)医疗图像分割中取得了不错的效果。

文章根据道路结构的复杂性,设计了编码器-解码器的网络架构,结合残差神经网络,不同于DRUNET^[21]算法利用残差块构建四层编码器-解码器结构,本算法设计了五层对称的编码器-解码器结构,前四层解码器和解码器没有使用空洞卷积进行特征提取,在第五层网络加入了空洞卷积模块(Dilated Convolutional Module, DCM),将带有不同空洞卷积比率的空间卷积进行并联,用来提取高维的道路特征信息;同时编码器和解码器之间采用跳连的方式进行不同维度的特征融合,学习更多低

维和高维的道路特征,分割出准确的道路结构。最后文中提出的算法与当前最先进的算法进行对比,在Massachusetts道路数据集^[22]上的实验结果表明,精度、F1值、召回率以及准确率均有很大的提升效果。

1 算法整体框架

文中采用的模型框架如图1所示,主要分为三个部分:特征编码模块、空洞卷积模块、特征解码模块。

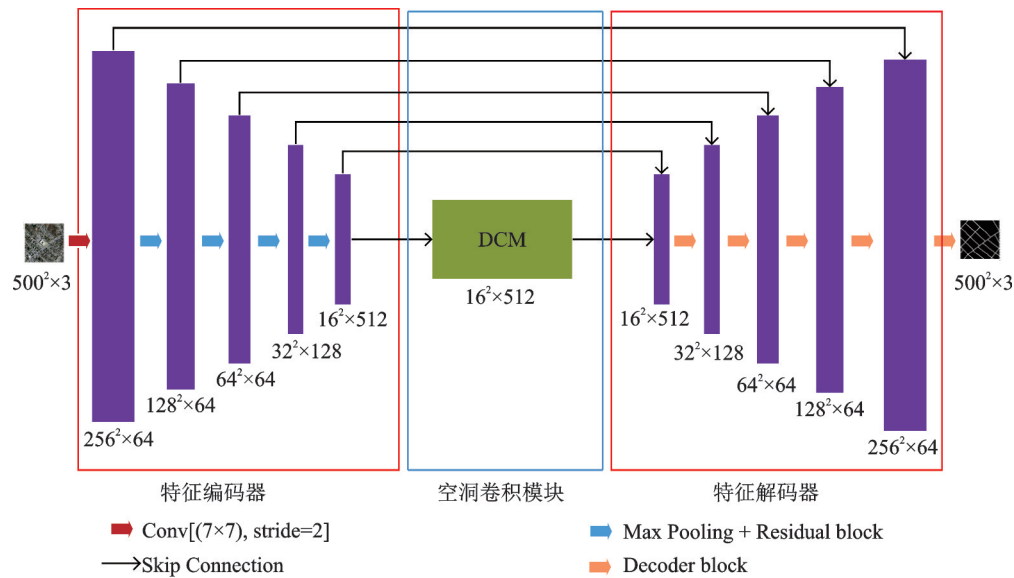


图1 算法整体框架

Fig.1 Algorithm overall framework

1.1 特征编码器

采用ResNet34^[14]做预训练编码器,ResNet34起初被用来做图像分类任务,由于其分类性能的优越,可以对道路和非道路进行分类。模型接收的图像尺寸设置为 500×500 ,不同于文献[21]设计的四层网络,文中的网络深度设置为五层,开始输入的特征维度为 $500 \times 500 \times 3$,第一层使用 7×7 Convolution操作,得到特征维度输出 $256 \times 256 \times 64$,剩下的每一层都要经过Max Pooling和Res-block操作。第二层经过Max Pooling和3个ResNet-block操作得到特征维度输出 $128 \times 128 \times 64$,第三层经过Max Pooling和4个ResNet-block得到特征维度输出 $64 \times 64 \times 128$,第四层经过Max Pooling和6个ResNet-block得到特征维度输出 $32 \times 32 \times 256$,前四层编码器没有使用空洞卷积,第五层经过Max

Pooling操作得到 $16 \times 16 \times 512$ 的特征维度输出。对于后四层的输出结果将经过Skip Connection与同层的解码器部分相连接,进行多尺度的特征融合,得到不同维度的语义信息。文中设计的Res-block如图2所示。

1.2 空洞卷积模块(DCM)

Dilated Convolution中文名称叫做空洞卷积,它




图2 残差模块

Fig.2 Residual block

是在标准的卷积图里注入空洞,以此增加接受域;相比原始的卷积,空洞卷积多了一个超参数(Hyper-Parameter),称之为空洞比率(Dilated Rate),它指的是内核(Kernel)的间隔数量,标准的卷积是空洞卷积比率为1。

在图像分割领域,全卷积网络同传统的卷积神经网络一样,先采用卷积再进行池化操作,降低图像尺寸的同时增大感受野;全卷积网络有两个关键步骤,其中一个是通过池化减小图像尺寸增大感受野,另一个是上采样扩大图像尺寸;先池化再上采样操作过程中,将会造成一些信息损失。使用空洞卷积操作,不通过池化和上采样操作也能获得较大的感受野,因此这里将采用空洞卷积的方式,提取特征信息。图3表示空洞卷积,a、b、c、d分别表示空洞卷积率1、2、4、8所能接收到的感受野。

使用空洞卷积的优点是在不造成信息损失的情况下加大了感受野,每个卷积输出也能包含较大

范围的特征信息。文中设计的空洞卷积模块如图4所示。

空洞卷积可以采用并联的方式,调整空洞卷积的比率可以改变每层感受野的大小。文中设计的网络在编码器-解码器中间部分加入了语义分割使用到的ASPP(Atrous Spatial Pyramid Pooling)^[23-24]策略,采用多个空洞卷积相并联的方式提取道路特征信息。相比文献[21]设计的网络,第四层只使用了单个空洞卷积比率为8的空洞卷积,相比较而言文中设计的网络可以对不同感受野的特征图进行道路特征提取,减少道路信息的丢失,改善预测的道路结构丢失问题。文中设计的DCM包含五个并联分支,伴随着空洞卷积率逐次增加,空洞卷积率分别为1、2、4、8,感受野的计算公式如式(1)所示:

$$S = k + (k - 1)(n - 1) \tag{1}$$

其中, k 表示卷积核大小,默认设置为3, n 表示空洞卷积率,所以每一分支的感受野大小分别为3、5、9、17,最后一个分支为全局池化操作。




图3 空洞卷积

Fig.3 Dilated convolution

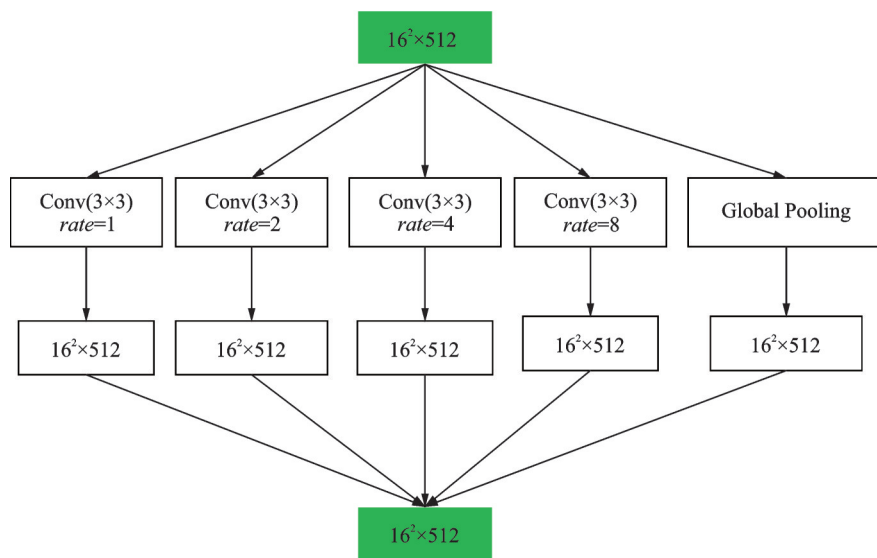


图4 空洞卷积模块

Fig.4 Dilated convolution module

1.3 特征解码器

采用特征解码器恢复从空洞卷积模块获得的高维语义特征, Skip Connection 将从编码器中获得一些详细的信息, 弥补连续的池化以及跨卷积操作带来的信息损失, 文中采用有效的卷积块组合的方式, 增强解码的性能。对比不同的网络结构, 简单的上采样和反卷积是 U 形网络中常见的操作, 比如常见的 U-Net^[13] 网络, 上采样操作通过双线性插值可以增加图片的尺寸, 反卷积也可以采用卷积运算放大图像的尺寸。文中选择双线性插值的方法恢复解码器中更高维度的特征。文中设计的特征解码器模块如图 5 所示, 提出的解码器模块包括 1×1 Convolution、Bilinear-Interpolation、 1×1 Convolution, 三部分进行串联作用于整个解码部分。




图 5 解码器模块

Fig.5 Decoder module

1.4 损失函数

文中采用的损失函数分为两部分, 分别为 *BCEL* (Binary Cross Entropy Loss) 和 *DCL* (Dice Coefficient Loss), 两者的和作为模型训练的总损失。

BCEL 损失函数定义如公式(2)所示:

$$BCEL(Pre_i, GT_i) = - \sum_{i=1}^W \sum_{j=1}^H [(gt_{i,j} \times \log pre_{i,j}) + (1 - gt_{i,j}) \times \log(1 - pre_{i,j})] \quad (2)$$

其中, Pre_i 表示第 i 张预测图像, GT_i 表示第 i 张标签图像, $gt_{i,j}$ 表示 GT 图像第 i, j 位置的像素值, $pre_{i,j}$ 表示预测图像 Pre 第 i, j 位置的像素值, N 表示 Batch Size, W 表示图像的宽度, H 表示图像的高度。

DCL 损失函数定义如公式(3)所示:

$$DCL = 1 - \frac{\sum_{i=1}^N |Pre_i \cap GT_i|}{\sum_{i=1}^N (|Pre_i| + |GT_i|)} \quad (3)$$

其中, Pre_i 表示第 i 张预测图像, GT_i 表示第 i 张标签图像, N 表示 Batch Size。

总的损失函数 *Loss* 如公式(4)所示:

$$Loss = BCEL + DCL \quad (4)$$

2 数据处理及实验结果

2.1 数据处理

文章采用 Massachusetts 道路数据集^[22], 该数据集包含 1171 张图像, 尺寸大小为 1500×1500 , 每张图像都有对应的标签(Ground Truth)。该数据集覆盖有城市、郊区、农村总共涉及的面积超过 2600 平方公里, 数据集涉及到道路、河流、海洋、建筑和港口等。由于训练集中存在大量的白背景图像, 训练时需要对有白背景图像进行剔除。挑选 789 张合格的图像, 随机分 709 张为训练集, 80 张为测试集, 然后将图像裁剪为 500×500 尺寸大小。

2.2 实验细节

在 Ubuntu16.04 以及 Pytorch 深度学习平台进行训练和测试, 处理器使用的是英特尔 i5-9400F, 使用的显卡型号为 NVIDIA RTX 2070, 电脑内存大小为 16G。训练阶段, 为了避免训练中出现过拟合的风险, 对数据集进行数据扩充, 具体的操作包括水平翻转、垂直翻转、对角线翻转; 每张图像还进行了随机缩放、随机拉伸和随机偏移操作。除此之外, 对图像色彩进行随机变换, 提高数据的增强能力。为了优化模型, 文中采用 Binary Cross Entropy Loss 和 Dice Coefficient Loss 损失函数; 由于 Adam 优化器比 SGD 优化器具有更快的收敛速度, 选择 Adam 优化器。初始的学习率设置为 2×10^{-3} , 当训练损失减少的很慢时, 学习率会变为原来的 $1/3 \sim 1/5$ 。测试阶段, 对 80 张测试集图像进行裁剪, 挑选 480 张图像进行测试。

2.3 实验结果

2.3.1 评价指标

道路提取可以被看作是一个二分类问题, 道路像素是正值(Positive), 非道路像素是负值(Negative)。对于道路提取的指标评价可以采用语义分割^[23, 26]的评价方法, 结合真实的分类和预测的分类, 将预测的图像按照像素值分为不同的类别, 包括 True Positive(TP)、False Positive(FP)、True Negative(TN)以及 False Positive(FN)。精确率、召回率、F1 分数以及准确率在道路提取任务中普遍采用的评价指标, 其中, 精确率(Precision)是由分类器直接

分类的道路像素在所有预测像素中所占的百分比,召回率(Recall)是用来评估正确预测的道路像素百分比作为实际道路像素,F1值(F1-score)是精确率和召回率的调和平均值,准确率(Accuracy)是对分类器进行总体评估。定义如下四个评价指标评估算法的性能。

Precision如公式(5)所示:

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

Recall如公式(6)所示:

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

F1-score如公式(7)所示:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

Accuracy如公式(8)所示:

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (8)$$

2.3.2 算法比较

为了更好的比较算法的性能,与不同的算法在Massachusetts道路数据集下进行定性的比较,表1显示了不同算法的比较结果。

表1 不同算法的性能比较

Tab.1 Performance comparison of different algorithms

	精确率/ (%)	召回率/ (%)	F1值/ (%)	准确率/ (%)
CRF ^[5]	40.5	32.2	35.9	82.5
Minimum cost path ^[6]	47.1	67.9	55.6	89.9
FCN ^[17]	43.5	68.6	53.2	90.4
RSRCNN ^[12]	60.6	72.9	66.2	92.4
Seg Net ^[19]	77.3	76.5	76.8	95.7
Two-Step-DCNN ^[15]	87.9	89.3	88.6	98.1
Road-RCF ^[16]	85.8	98.5	91.5	96.3
U-Net(5 layer)	98.8	98.8	98.8	97.8
U-Net(7 layer)	98.8	98.7	98.8	97.7
Ours	98.9	98.8	98.9	97.9

由于U-Net算法在生物细胞分割任务取得了良好的效果,对U-Net算法进行复现,与原始的U-Net不同,复现的U-Net网络使用了数据扩充操作,对每张图片进行了随机缩放、随机拉伸以及随机翻转操作。除此之外,复现的7层U-Net与5层U-Net的区别,增加了网络深度,多了两层下采样。文中采用了Precision、Recall、F1-score以及Accuracy进行对比评估。从表1中可以看出,复现的U-Net算法也取得了很好的效果。对比文献[15]的Two-Step-DCNN算法,文中提出的算法获得了98.9%的Pre-

cision,相比Two-Step-DCNN算法提高了13%,且均超过表中其他算法;与文献[16]的Road-RCF算法相比,文中提出的算法在Recall和F1-score指标分别达到98.8%、98.9%,性能比Road-RCF分别提高了0.3%和7.3%,且性能均超过表中的其他算法。除此之外,文中提出的算法在Accuracy指标上也达到了97.9%,非常接近文献[15]的Two-Step-DCNN算法达到的98.1%,且均超过表中的其他算法。对于准确率上低于Two-Step-DCNN算法,分析其原因可能是受到该数据集中标签漏标注和训练损失过高的影响,学习到了错误的特征以及丢失了关键的特征,但相比其他算法性能明显提升了。

2.3.3 道路分割结果

提出的算法能够准确地提取到了道路的网络结构,图6所示为道路提取可视化的结果。随机选择了四张预测结果进行比较,如图6所示,5层U-Net比7层U-Net的分割结果好,5层U-Net分割出了更多的道路信息,7层U-Net丢失了许多细小的道路信息,对于显著的道路信息两者都能将大致的道路网络提取出来。提出的算法与5层U-Net以及7层U-Net算法相比较,在可视化效果上优于后者,对于一些不明显的道路特征也能学习到,这也体现了文中提出的算法具有一定的效果。算法的不足之处是出现了道路结构丢失,对于特别复杂的道路,还是需要学习更多的道路特征,减少信息的丢失,才能得到更加完整的道路分割结果。

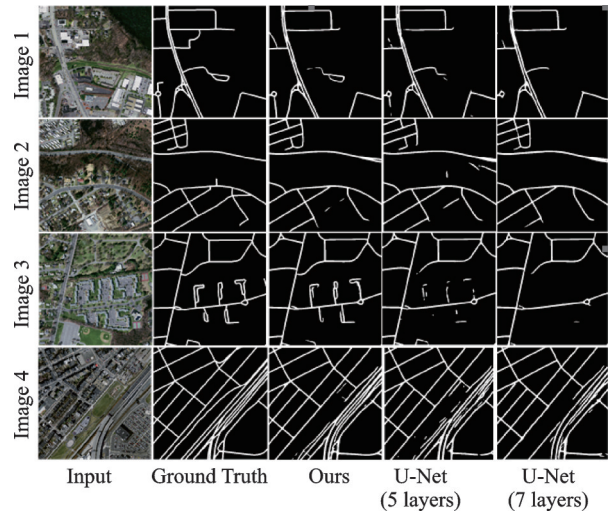


图6 可视化结果

Fig.6 The visualized results

3 结 论

文章提出了基于残差神经网络的道路提取算法,通过设计一个编码器-解码器的网络结构,加入了空洞卷积模块,同时结合多尺度特征信息融合,

提取出了不同维度的特征信息,在训练过程中也对数据集进行扩充,防止训练中出现过拟合现象。最后在 Massachusetts 道路数据集上的实验对比评估结果表明,文章提出的算法在精确率、召回率和 F1 值指标上相比许多算法较优。未来的工作是寻求更优的结构模型以及设计一种新的损失函数降低信息损失,进一步提高道路提取的准确性。

参 考 文 献

- [1] 曹云刚,王志盼,杨磊. 高分辨率遥感影像道路提取方法研究进展 [J]. 遥感技术与应用, 2017, 32(1): 20-26.
- [2] Eslami M, Faez K. Automatic traffic monitoring using satellite images [C]. Proceedings of the 2nd International Conference on Computer Engineering and Technology (IC CET), Chengdu, China, 2010: V6130-V6135.
- [3] Zheng S, Liu J, Shi W, et al. Road central contour extraction from high resolution satellite image using tensor voting framework [C]. Proceedings of the 2006 International Conference on Machine Learning and Cybernetics, Dalian, China, 2006: 3248-3253.
- [4] Zhu D, Wen X, Ling C. Road extraction based on the algorithms of MRF and hybrid model of SVM and FCM [C]. Proceedings of the 2011 International Symposium on Image and Data Fusion (ISIDF), Tengchong, Yunnan, China, 2011: 1-4.
- [5] Wegner J D, Montoya Zegarra J A, Schindler K. A higher-order CRF model for road network extraction [C]. Proceedings of the 26th IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Portland, OR, USA, 2013: 1698-1705.
- [6] Wegner J D, Montoya Zegarra J A, Schindler K. Road networks as collections of minimum cost paths [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 108 (2): 128-137.
- [7] Das S, Mirmalinee T T, Varghese K. Use of salient features for the design of a multistage framework to extract roads from high-resolution multispectral satellite images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49 (10): 3906-3931.
- [8] 王钰,何红艳,谭伟,等. 一种多特征融合的高分辨率遥感图像道路提取算法 [J]. 遥感信息, 2019, 34(1): 111-116.
- [9] Zhang Z, Wang Y, Liu Q, et al. A CNN based functional zone classification method for aerial images [C]. Proceedings of the 36th IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China, 2016: 5449-5452.
- [10] Maggiori E, Tarabalka Y, Charpiat G, et al. Convolutional neural networks for large-scale remote-sensing image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(2): 645-657.
- [11] Mnih V, Hinton G E. Learning to detect roads in high-resolution aerial images [C]. Proceedings of the 11th European Conference on Computer Vision (ECCV), Heraklion, Greek, 2010: 210-223.
- [12] Wei Y, Wang Z, Xu M. Road structure refined CNN for road extraction in aerial image [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 709-713.
- [13] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation [C]. Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI), Munich, Germany, 2015: 234-241.
- [14] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]. Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016: 770-778.
- [15] Singh P, Dash R. A two-step deep convolution neural network for road extraction from aerial images [C]. Proceedings of the 6th International Conference on Signal Processing and Integrated Networks (SPIN), Noida, India, 2019: 660-664.
- [16] Hong Z, Ming D, Zhou K, et al. Road extraction from a high spatial resolution remote sensing image based on richer convolutional features [J]. IEEE Access, 2018, 6(1): 46988-47000.
- [17] Zhong Z, Li J, Cui W, et al. Fully convolutional networks for building and road extraction: preliminary results [C]. Proceedings of the 36th IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China, 2016: 1591-1594.
- [18] Fu G, Liu C, Zhou R, et al. Classification for high resolution Remote sensing imagery using a fully convolutional network [J]. Remote Sensing, 2017, 9 (5): 498; <https://doi.org/10.3390/rs9050498>.
- [19] Panboonyuen T, Jitkajornwanich K, Lawawirojwong S, et al. Road segmentation of remotely-sensed images using deep convolutional neural networks with landscape metrics and conditional random fields [J]. Remote Sensing, 2017, 9 (7): 680; <https://doi.org/10.3390/rs9070680>.
- [20] Qin X B, Zhang Z C, Huang C Y, et al. BASNet: Boundary-aware salient object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, USA, 2019: 7479-7489.
- [21] Devalla S K, Renukanand P K, Sreedhar B K, et al. DRUNET: A dilated-residual u-net deep learning network to digitally stain optic nerve head tissues in optical coherence tomography images [J]. Biomedical Optics Express, 2018, 9 (7): 3244-3265.
- [22] Mnih V. Machine learning for aerial image labeling [D]. Canada: University of Toronto, 2013.
- [23] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation [EB/OL]. (2017-06-17) [2020-03-11], <https://arxiv.org/abs/1706.05587>.
- [24] Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [EB/OL]. (2018-02-07) [2020-03-11], <https://arxiv.org/abs/1802.02611>.
- [25] 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.
- [26] Chaurasia A, Culurciello E. LinkNet: Exploiting encoder representations for efficient semantic segmentation [C]. Proceedings of the IEEE Visual Communications and Image Processing (VCIP), St. Petersburg, FL, United states, 2017: 1-4.