

改进全卷积网络方法的高分二号影像农村道路提取

李朝奎^{1,2}, 曾强国³, 方军^{1,2}, 吴馁^{1,2}, 武凯华^{1,2}

1. 湖南科技大学 地理空间信息技术国家地方联合工程实验室, 湘潭 411201;
2. 湖南科技大学 测绘遥感信息工程湖南省重点实验室, 湘潭 411201;
3. 湖南省第二测绘院遥感应用推广部, 长沙 410000

摘要: 针对目前利用高分遥感数据提取农村道路的研究与应用少, 提取结果精准度不够的问题, 提出了结合空洞卷积和 ASPP (Atrous Spatial Pyramid Pooling) 结构的改进全卷积农村道路提取网络模型 DC-Net (Dilated Convolution Network)。该模型基于全卷积的编解码结构来提取道路深度特征信息, 同时针对农村道路细长的特点, 在解编码层之间加入了以空洞卷积为基础的 ASPP (Atrous Spatial Pyramid Pooling) 结构来提取道路的多尺度特征信息, 在不牺牲特征空间分辨率的同时扩大了特征感受野 FOV (Field-of-View), 从而提高细窄农村道路的识别率。以长株潭城市群郊区部分区域为试验对象, 以高分二号国产卫星遥感影像为实验数据, 将本文提出的方法与经典的几种全卷积网络方法进行实验结果对比分析。实验结果表明: (1) 本文所提出的道路提取模型 DC-Net 在农村道路的提取上具有可行性, 整体提取平均精度达到 98.72%, 具有较高的提取精度; (2) 对比几种经典的全卷积网络模型在农村道路提取上的效果, DC-Net 在农村道路提取的精度和连通性、以及树木和阴影的遮挡方面, 均表现出了较好的提取结果; (3) 本文提出的改进全卷积网络道路提取模型能够有效地提取高分率遥感影像中农村道路的特征信息, 总体提取效果较好, 为提高基于国产高分影像的农村道路提取精度提供了一种新的思路和方法。

关键词: 全卷积网络, DC-Net, 空洞卷积, ASPP, 农村道路提取

引用格式: 李朝奎, 曾强国, 方军, 吴馁, 武凯华. 2021. 改进全卷积网络方法的高分二号影像农村道路提取. 遥感学报, 25(9): 1978-1988

LI C K, Zeng Q G, Fang J, Wu N and Wu K H. 2021. Road extraction in rural areas from high resolution remote sensing image using a improved Full Convolution Network. National Remote Sensing Bulletin, 25(9): 1978-1988 [DOI: 10.11834/jrs.20219209]

1 引言

公路网是全国道路交通运输的重要组成部分, 更是农村地区经济发展的最重要的设施近年来, 中国农村公路的建设取得了巨大的进展。为了解农村公路的建设情况, 需要对建成的道路进行数据采集。目前交通运输行业主要采用 GPS 技术进行农村公路的采集, 并通过由下向上逐级上报的方式实现全国农村公路的统计汇总 (李程, 2018)。这种传统调查手段受人为干扰因素影响较大, 数据的真实性、准确性、全面性得不到保障。

随着遥感技术的快速发展, 遥感技术的进步将遥感影像的分辨率带入亚米级, 正是由于高分影像的大规模生产, 使得利用遥感影像准确地提取农村地区的细小道路成为可能。

农村道路包含了农村公路。在高分辨率遥感影像中, 农村道路的特征更加复杂且不规则。农村道路在影像中常表现为几个像素到十几个像素宽度。不同于城市道路, 农村道路较少受到建筑阴影以及路上车辆的影响。但是农村道路经常受到树木及其阴影的遮挡, 道路细长且与一些建筑的屋顶较相似, 要完整地从小分辨率遥感影像中

收稿日期: 2019-05-06; 预印本: 2021-04-30

基金项目: 国家重点研发计划(编号:2017YFB0503802, 2018YFB0505401); 湖南省科技计划项目(编号:2018GK2015); 湖南省自然科学基金(编号:2020JJ1003); 武汉大学测绘遥感信息工程国家重点实验室开放研究基金资助(编号:19104); 湖南省教育厅资助科研项目(19C0730); 长沙理工大学公路工程教育部重点实验室开放基金(编号:kfj170203)

第一作者简介: 李朝奎, 1967年生, 男, 教授, 研究方向为三维地理建模及其应用。E-mail: chkl_hn@163.com

通信作者简介: 方军, 1985年生, 男, 讲师, 研究方向为城市空间分析与建模。E-mail: fangjun008@hnust.edu.cn

提取非常困难。

在以往学者的研究中,积攒了大量从高分辨率影像中提取城市道路的研究思路方法,但是由于农村道路的特殊情况,针对农村道路提取的精确方法尚未提出。传统的道路提取方法(林祥国等,2009;戴激光等,2018)大都先提取道路在影像中的固有特征,如光谱特征、纹理特征等,然后根据这些特征来挖掘道路在影像中的位置信息。虽然这些特征简单且易理解,但是仅依靠这些简单特征来提取道路,效果难以提升。

近来利用深度学习方法来提取高分辨率遥感影像中的道路的研究越来越多(Zhou等,2018;Doshi,2018;Li等,2019;Yi等,2010;张睿等,2008),主要原因在于深度学习中的卷积神经网络CNN(Convolutional Neural Network)具有特征自提取的能力,不再依靠单一的特征来识别道路。CNN可以利用训练样本来学习道路在影像中的各种特征,以及各种特征组合来识别道路。应用比较多的基于CNN的模型方法包括VGG(Visual Geometry Group)(Papadomanolaki等,2017),FCN(Fully Convolutional Networks)(Zhang等,2018;Cheng等,2017),cascaded CN(Chen等,2017)和U-Net(Zhong等,2016)。VGG通过扫描影像中的每一个像素来识别是否为道路,因此不会漏掉农村这种较细的道路,能获得较为精细的结果。但是,VGG只利用每个像素周围很小的区域来判断像素是否为道路,一个是很难确定每个像素周围的区域大小,太小导致识别率下降,太大导致计算冗余;二是识别出的道路有很多噪声,使得道路不连贯。相对而言,FCN往往得到的是较为粗糙的结果。FCN使用下采样获得较小尺寸的特征图,然后利用这个特征图上采样还原到原影像大小得到最终提取结果。这种上采样一下采样结构可以有效地避免复杂背景的干扰,但是却忽略了细窄道路的细节。U-Net使用FCN的基本结构,不同的地方在于U-Net在每个下采样阶段使用跳跃连接,与对应的上采样阶段连接。这样,在上采样阶段,就可以利用下采样每个阶段的特征图来优化最终得到的结果。相比较于VGG和FCN,U-Net可以得到一个较为不错的结果。但是,下采样的特征图并没有被充分的学习利用,提取对象的多尺度信息也没有被充分利用,使得U-Net还有可以优化的空间。为了充分学习多尺度信息,一种

ASPP(Atrous Spatial Pyramid Pooling)结构(Chen等,2017,2018)被提出,该结构主要包含了不同等级的扩张卷积来获取多尺度信息。通过扩张卷积,能够有效地捕获不同尺度下的特征点,可以有效地提升卷积过程的效率。这种结构可以有效地提取细窄道路在影像中的不同尺度特征,提高农村道路识别的准确度。

本文提出了一种以ASPP与U-Net为基础的模型框架DC-Net来提取长株潭城市群郊区部分地区的农村道路。该模型与U-Net模型的不同之处在于在每个下采样阶段通过ASPP结构将特征不同尺度信息整合。此外,还将下采样层替换为ResNet34(He等,2016)来加深网络,提取更深层次特征。

2 全卷积网络农村道路提取方法

本研究在高分辨率遥感影像的基础上提出了一种新的卷积神经网络模型来提取农村地区的道路。首先,对原始高分二号遥感影像进行切片处理,大小为1024×1024像素。为了能够训练该模型,还需要为每张切片制作对应的道路样本。然后,将制作好的道路样本及其对应影像作为输入数据输入模型中训练,将训练好的模型用来提取道路。最后,将需要提取的影像输入训练好的模型,输出结果为相同大小尺寸的道路与非道路的二值影像。

2.1 DC-Net基本原理与结构

图1是DC-Net模型的结构原理,与传统卷积神经网络不同的是,它用卷积层代替了全连接层进行模型构建,能够输出与原始影像等大的识别结果,在提取特征时更能考虑目标的整体特征,对于目标的空间定位也更加准确。

2.1.1 编码层结构

DC-Net结构主要分为3个部分,分别为编码层、解码层和中间层ASPP,ASPP会在2.2节中详细介绍。首先是编码层,为了能够加深网络提取更深层次特征,使用在ImageNet(Deng等,2009)数据集上预训练好的ResNet34作为模型的编码层,34表示其有34个隐藏层,其结构如图2所示,图2中融合操作为求和。

从图2中可以看出,ResNet34利用很多个构建块将卷积网络中的常用隐藏层有规律地组合起来,

仅使用池化层来降低特征图的尺寸大小，并且采用统一卷积步长提取图像特征。其核心构建块内部结构如下：

(1) 卷积构建块。卷积构件块为底层特征提取器，由卷积层 (Convolution Layer) 一批规范化层 (Batch Normalization) (Ioffe 和 Szegedy, 2015) 一修正线性激活函数层 ReLU (Rectified Linear Units) (Glorot 等, 2011) 组成。

卷积层利用卷积核对原始图像像素做线性乘法运算，滑动提取图像局部区域特征，公式为

$$y_l^{i',j',d'} = b_l^{d'} + \sum_{i=1}^{H'} \sum_{j=1}^{W'} \sum_{d=1}^{D'} f_l^{i,j,d} \times x_l^{i,j,d'} \quad (1)$$

式中， l 为网络层数， H 为高度方向上像素个数， W 为宽度方向上像素个数， D 为深度方向上像素个数，图像输入数据为 $x_l \in \mathbf{R}^{H \times W \times D}$ ；卷积核为 $f_l \in \mathbf{R}^{H' \times W' \times D'}$ ，可以看成是一个滑动窗口， $b_l^{d'}$ 数值大小为权值；输出特征图为 $y_l \in \mathbf{R}^{H' \times W' \times D'}$ 。

由于卷积层计算输出的特征图的分布不断变化，随着网络的加深，训练会越来越困难，收敛

越来越慢。所以，使用批规范化是对特征图做归一化处理，让卷积层计算输出的特征图稳定下来，让模型更易训练。

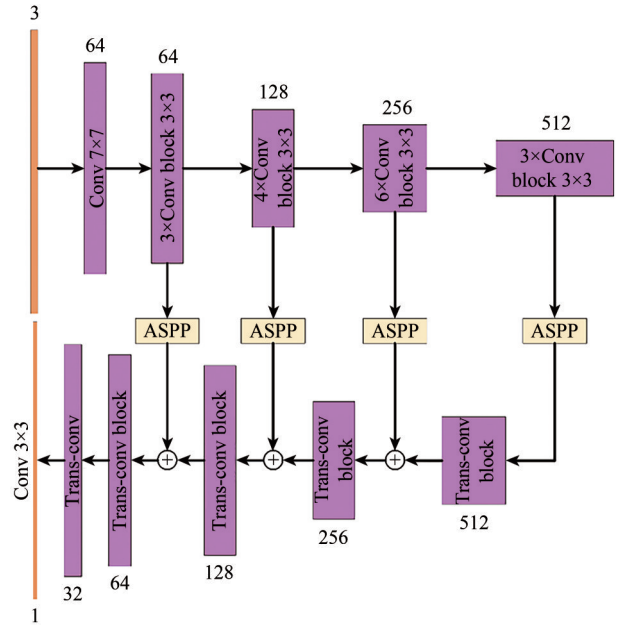


图1 DC-Net结构图
Fig. 1 The structure of DC-Net




图2 编码层结构
Fig. 2 The structure of encoding layer

ReLU 激活函数的作用是上层卷积层提取的简单低维特征进行非线性映射以组合出更复杂的

高维特征 (刘笑 等, 2018)，计算方法为

$$f = \max(0, x) \quad (2)$$

(2) 残差构建块。CNN在不断加深的同时会出现 Degradation 的问题 (Hu 等, 2015)。残差构建块通过直接将输入信息传到输出, 保护信息的完整性, 整个网络只需要学习输入、输出差别的那一部分, 简化学习目标和难度。ResNet34 使用的残差构件块结构如图 3 所示, 构件块的中间为两个卷积构建快, 将输入值和输出值求和并作为一个残差构建块的输入。

DC-Net 模型在编码层中使用的 ResNet34 整体结构的详细信息如表 1 所示。

2.1.2 解码层结构

DC-Net 结构的解码层的主要作用是将编码层生成的特征图通过卷积与反卷积 (Transposed-convolution) (Zeiler 等, 2015) 的一系列操作还原成与输入尺寸相同的分类结果图, 其尺寸还原的上

采样操作主要通过反卷积实现。解码层结构采用了 Linknet 的解码层结构, 主要由反卷积构建块组成, 而反卷积构建块主要是由卷积构建块和反卷积层构成。反卷积构建块的结构如图 4 所示, 图 4 中 m, n 分别代表输入和输出的特征图通道数目。




图 3 残差构建块
Fig. 3 Residual block

表 1 编码层结构详细信息

Table 1 The detail information of encoding layer structure

编码层	输入	输出	类型	核	步长	padding
Encoder0	1024×1024×3	512×512×64	conv	7×7	2	3
	512×512×64	256×256×64	maxpooling	3×3	2	1
Encoder1	256×256×64	256×256×64	3×res_block	3×3	1	1
Encoder2	256×256×64	128×128×64	maxpooling	2×2	2	0
	128×128×64	128×128×128	4×res_block	3×3	1	1
Encoder3	128×128×128	64×64×128	maxpooling	2×2	2	0
	64×64×128	64×64×256	6×res_block	3×3	1	1
Encoder4	64×64×256	32×32×256	maxpooling	2×2	2	0
	32×32×256	32×32×512	3×res_block	3×3	1	1

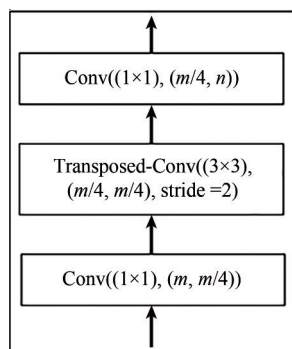


图 4 反卷积构建块结构

Fig. 4 The structure of transposed convolution block

在采样过程中, 是通过反卷积算法来进行特征图原始尺寸的还原, 在每次反卷积迭代后, 图的尺寸都会增加一倍。同时通过反卷积构建块中

的卷积构建块实现特征图维数的降低。每次的反卷积构建块的输入为上一层反卷积构建块的输出与对应中间层 ASPP 输出值的和。解码层的整体结构详细信息见表 2。

2.2 基于 ASPP 的多尺度特征提取

在一张图片中, 如果一个对象只看到局部而无法判断该对象的属性, 那就增大局部范围, 增多可以判断的条件, 这样就可以增大确定该对象属性的几率。同理, 高分辨率遥感影像中的农村道路本身就比较细窄, 很小的视野范围可能就难以辨认。但是增大视野就会很容易判断是否为农村道路。将该思想应用在全卷积网络中叫做增大感受野 (receptive field), 增大感受野的方式有使

用池化层, 增大卷积核尺寸等。但是, 这些往往需要更大的计算量。如何在不增加计算量的同时

又增大感受野, 空洞卷积就是一个有效的解决方法。

表2 解码层结构详细信息

Table 2 The detail information of decoding layer structure

编码层	输入	输出	类型	核	步长	padding
Decoder4	32×32×512	32×32×128	conv	1×1	1	0
	32×32×128	64×64×128	Trans-conv	3×3	2	1
	64×64×128	64×64×256	conv	1×1	1	0
	64×64×256	64×64×64	conv	1×1	1	0
Decoder3	64×64×64	128×128×64	Trans-conv	3×3	2	1
	128×128×64	128×128×128	conv	1×1	1	0
	128×128×128	128×128×32	conv	1×1	1	0
Decoder2	128×128×32	256×256×32	Trans-conv	3×3	2	1
	256×256×32	256×256×64	conv	1×1	1	0
	256×256×64	256×256×16	conv	1×1	1	0
Decoder1	256×256×16	512×512×16	Trans-conv	3×3	2	1
	512×512×16	512×512×64	conv	1×1	1	0
Decoder0	512×512×64	1024×1024×32	Trans-conv	4×4	2	1
	1024×1024×32	1024×1024×1	conv	3×3	1	1

2.2.1 空洞卷积

空洞卷积一个直观的描述就是在一般的卷积核中添加空洞, 空洞处为0, 如图5为不同等级的空洞卷积核, 这样就实现了增大感受野而不增大计算量的效果。空洞卷积的计算方式为

$$y[i, j] = \sum_{k=1}^K x[i + r \cdot k, j + r \cdot k] \omega[k] \quad (3)$$

式中, $y[i, j]$ 为空洞卷积的输出, $x[i, j]$ 为输入, $\omega[k]$ 是大小为 k 的卷积核, r 为卷积核的不同采样等级。当 $r=1$ 时, 卷积核为没有任何孔洞的标准卷积核。图5中展示了 $r=1, 2, 4, 8$ 等4个等级的空洞卷积核, 中心红色像素为目标像素, 黄色像素为进行卷积运算的像素。可以看到, 等级越高感受野越大。




图5 不同等级空洞卷积

Fig. 5 Atrous convolutions with rate=1, 2, 4 and 8

2.2.2 ASPP多尺度特征提取结构

空洞卷积核的采样等级也不是越大越好, 感受野太大, 很多多余的信息会干扰到目标地物的识别, 所以需要选择合适的采样等级。ASPP多尺度特征提取结构就可以很好的解决采样等级选择的问题。图6为本文采用的ASPP结构, 该结构采用编码层中不同额采样层作为输入, 计算后生成的特征图与对应上采样层的输出进行求和作为下一个上采样层的输入。从图6中可以看出, ASPP结构分别使用了采样等级为1, 2, 4, 8的空洞卷积对输入特征图进行卷积运算, 那么每一层的感受野的大小就是3, 7, 15, 31。使用不同采样等级的特征图带入模型计算, 获取不同的尺度特征, 最后再进行特征之间的融合, 最后就可以不加人工干预地确定采样等级, 更为准确。特征图在编码层进行下采样的过程中, 随着网络的加深, 特征图会逐渐失去其原本的空间特性。为了充分利用编码层和解码层之间不同层级的空间特性, DC-Net在编码层和解码层之间的不同层级使用多个ASPP结构, 充分提取和利用特征图的多尺度空间信息来适应农村道路这种较细地物的提取。

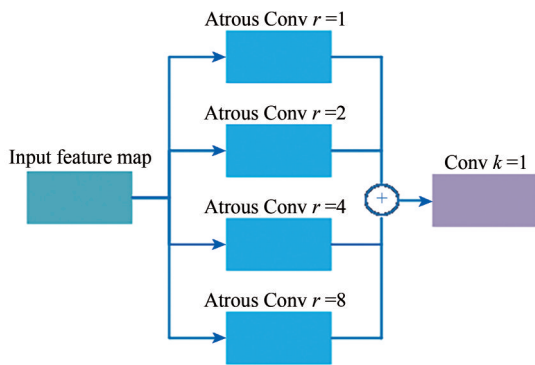


图6 本文ASPP结构示意图
Fig. 6 The structure of ASPP

二号遥感影像，其多光谱与全色波段融合后的空间分辨率为1 m。为了满足实验模型的输入要求，将选定区域的融合影像进行切片，切片大小为1024×1024像素，共计1000张，覆盖区域面积为1048.58 km²。影像中主要包含了农村道路，居民住宅，植被，河流湖泊等地物。农村道路在影像中很细小，其宽度在影像中大概占据3—10个像素大小，这使得提取很具有挑战性。为了使模型可以学习，需要对切片数据进行道路的标注，标注的道路样本为1024×1024大小的二值黑白影像，白色为道路，黑色为背景，共计1000张。为了进一步对模型结果进行精度评定，将总体样本中随机选出1/6的样本作为验证，选择出的部分样本如图7所示。

3 实验与分析

3.1 实验数据

实验样本数据源为长株潭城市群郊区的高分




图7 部分训练样本

Fig. 7 The remote sensing imagery and the corresponding ground truth

3.2 模型训练与提取结果

3.2.1 训练细节

本文的程序设计基于Facebook公司开源的Pytorch深度学习框架，程序语言为Python，系统平台为Ubuntu，利用一张GTX 1080ti显卡及CUDA并行计算平台实现GPU编程加速。因为是道路提取问题是二分类问题，所以使用的目标损失函数为交叉熵损失函数(Binary Cross Entropy Loss)，其计算方式如式(4)所示：

$$\text{loss} = -\sum_{i=1}^n \hat{y}_i \log y_i + (1 - \hat{y}_i) \log(1 - y_i) \quad (4)$$

式中， \hat{y}_i 为每个样本的预测值， y_i 为每个样本的真值。同时使用Adam(Adaptive Moment Estimation)优化算法进行参数优化以及收敛加速。

在训练时由于显卡显存(11 G)的限制，每次将4对样本作为一个数据块(mini batch)来训练模型，设置迭代epoch值为300，但是在训练过程中，当loss值不再降低时便自动停止训练。模型的初始参数为Resnet34预训练好的参数，初始学习率设置为0.0002，每当loss值不再下降时，学习率便下降五分之一，这样便于找到目标函数的最优值。

3.2.2 评价指标

通过训练好的模型从高分影像中提取的结果为二值影像，其中，像素为1的道路可以理解为正样本 (positive)，像素为0背景的可以理解为负样本 (negative)。同时为了能够准确的评价模型的识别结果,引入 Precision (Chaurasia 和 Culurciello, 2017), Recall (Heipke 等, 1997), OA (Overall Accuracy) (Xu 等, 2018), F1-score (Martin 等, 2004) 4个指标，其中 Precision 表示预测为正的样本中有多少样本被正确预测，Recall 代表真实标签为正的样本中有多少是被预测正确的，OA 表示有样本预测正确比例，F1-score 是综合了 Precision 和 Recall 的一个评价指标。这些指标需要通过4个量来计算，分别为 TP (True Positive), FP (False Positive), TN (True Negative) 和 FN (False Negative)，意思是真正预测也为正、真实为负预测为正、真实负预测也为负、真实为正预测为负的样本数目。那么这4种指标的计算公式如式 (5)、(6)、(7)、(8) 所示：

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

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

$$\text{OA} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

$$\text{F1} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

3.2.3 实验结果

使用训练数据集对 DC-Net 模型进行训练，并将训练好的模型保存用于验证数据集的道路提取，对提取后的道路进行 Precision、Recall、F1 以及 OA 的指标计算，结果如表 3 所示。训练过程中的 Loss 的变化情况如图 8 所示。农村道路提取效果如图 9 所示。

表 3 DC-Net 道路提取结果

Table 3 The result of road extraction with DC-Net				
数据	Precision	Recall	F1-score	OA
GF-2	0.9075	0.9049	0.9062	0.9872

从表 3 和图 8 可以得知，本文所提出的 DC-Net 模型对验证数据集的农村道路提取精度达到了 98.72%，证明了其在高分辨率遥感影像中农村道路提取的可行性和有效性。从图 9 可以看出：DC-

Net 提取的道路基本上不存在像传统提取方法出现的“椒盐”噪声的情况，基本上都可以提取出完整的道路。道路提取结果用不同颜色来区别道路与非道路的变化情况：绿色表示 TP，即实际为道路且预测为道路；红色表示 FP，即实际为非道路且预测为道路；蓝色为 FN，即实际为道路且预测为非道路；黑色为 TN，即实际为非道路且预测为非道路。红色框内是特殊道路部分，这些为道路标签图中没有标出的道路，但在预测的时候提取出来了，这也说明了 DC-Net 在训练时强大的学习能力和举一反三的能力。

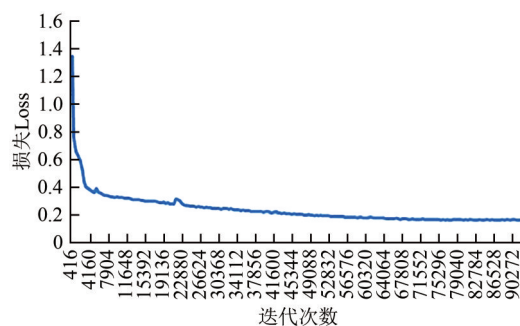


图 8 训练过程中的损失变化

Fig. 8 The loss value change when training

3.3 实验分析

为了验证提出的 DC-Net 深度学习模型在高分辨率遥感影像道路提取中的有效性和优越性。将 DC-Net 同几种经典的应用在语义分割领域的深度学习网络模型 FCN、U-Net、Segnet、Linknet、RefineNet、DeepLabv2 进行道路提取效果对比。为了保证对比客观公平，所有的模型都是在同一套数据集的测试数据集上进行对比。比较结果如表 4 所示，表 4 中的最优值都以加粗的方式显示。

从表 4 中可知，模型结果相对简单的 FCN 以及 U-Net 在特征提取方面的能力不如其他结构相对复杂的模型。本文提出的 DC-Net 模型在测试数据集上，各项指标基本上都能表现出优异的结果。为了直观比较各个模型道路提取效果，在测试数据集中选出局部场景进行农村道路提取效果的直观对比，如图 10 所示，其中图 10 (a) 为农村道路较为复杂的局部场景原始影像，图 10 (b) — (i) 分别为道路标签图、FCN 提取结果、U-Net 提取结果、Segnet 提取结果、Linknet 提取结果、Refinenet 提取结果、DeepLabv2 提取结果以及 DC-Net 提取结果。

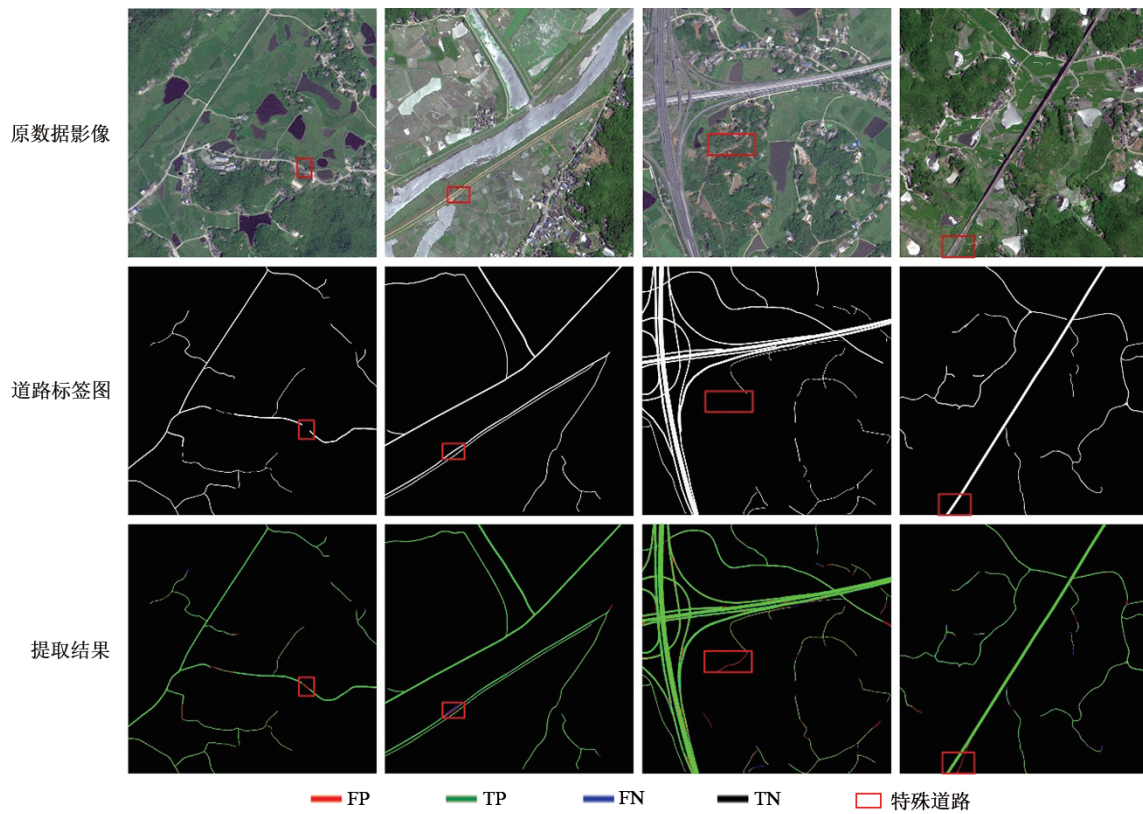


图9 DC-Net道路提取结果

Fig. 9 The result of road extraction with DC-Net

表4 不同模型农村道路提取结果对比

Table 4 The comparison of road extraction with different models in rural areas

模型	图像1			图像2			总体		
	Precision	Recall	F1-score	Precision	Recall	F1-score	Precision	Recall	F1-score
FCN	0.6453	0.8001	0.7144	0.6898	0.7468	0.7172	0.5210	0.8484	0.6456
U-Net	0.8801	0.7239	0.7944	0.7769	0.7649	0.7709	0.6273	0.5962	0.6114
Segnet	0.7631	0.8943	0.8235	0.8426	0.7635	0.8011	0.8087	0.8173	0.8130
Linknet	0.8322	0.8677	0.8496	0.9046	0.9103	0.9074	0.8632	0.6024	0.7096
RefineNet	0.9100	0.8802	0.8949	0.8997	0.9098	0.9047	0.8620	0.8994	0.8803
DeepLabv2	0.8322	0.8927	0.8614	0.8918	0.9012	0.8965	0.8757	0.8901	0.8828
DC-Net	0.8632	0.9123	0.8871	0.9264	0.9077	0.9170	0.9075	0.9049	0.9062

由图 10 的提取结果对比可以看出，在农村道路细窄且有树木或阴影遮挡场景下，除 Refinenet、DeepLabv2 以及 DC-Net 以外，道路提取效果不佳，说明 Refinenet、DeepLabv2 和 DC-Net 模型对于道路的阴影因素具有一定的屏蔽作用。在图 10 中选取 A 和 B 两处道路细节（用红色方框标注范围）进一步对比可以发现：A 区域有茂密植被完全遮挡的道路，只有 Segnet 和 DC-Net 屏蔽了树木遮挡的影响，识别出了完整道路；B 区域为多条道路的连接处，这部分在原标签样本中并没有完全标记出来，

而只有 DC-Net 准确地识别并连通了路口，显示出本文 DC-Net 模型的优越性。

通过对比其他几种模型结构，本文所提模型 DC-Net 在模型结构上，使用 ASPP 中不同等级空洞卷积来增大道路特征图的感受野，获取不同等级尺度的道路特征。针对不同类型和背景的道路，ASPP 结构的多尺度空洞卷积会充分提取它们的复杂特征，不再只固定使用某一种尺度的空洞卷积。如在具有树木遮挡的道路区域，小尺度空洞卷积学习不到的特征便使用较大尺度空洞卷积来学习

更大范围特征,同时结合小尺度区域遮挡部分特征确定被遮挡部分道路。这样便可以识别出被遮挡区域的道路,保证了道路的连接性。Segnet模型中的池化索引记录过程也具有类似的作用,所以对于道路上的树木遮挡也具有一定的屏蔽作用。DeepLabv2模型虽然也使用了ASPP结构并附加了全连接条件随机场的后期优化,使得边缘较为平

滑,对细节部分的还原有所欠缺。本文所提模型DC-Net针对较细的农村道路,在编码层与解码层之间使用多个ASPP结构。随着编码层深度的增加,输出的道路特征图的空间信息越来越少,在不同深度处使用ASPP结构可以学习到不同空间尺度下的道路信息,这使得较细的农村道路也可以很好地定位并完整地还原。

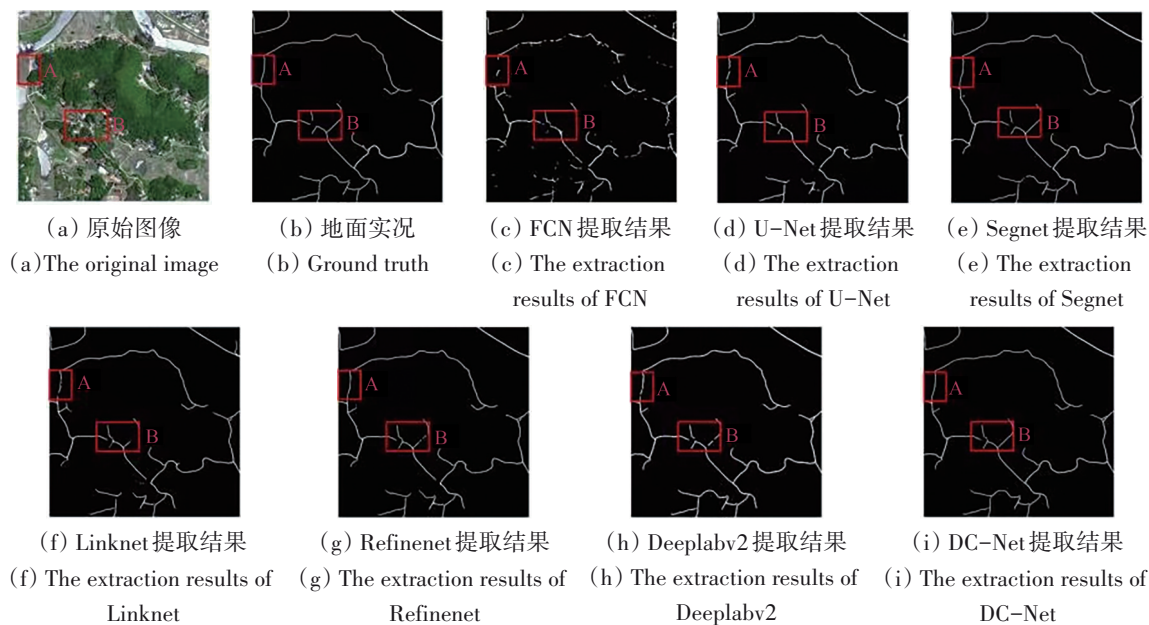


图10 农村道路提取结果对比

Fig. 10 The comparison of road extraction in rural areas

综上所述,无论是道路提取的精度还是道路提取的效果(包括阴影和树木的遮挡、较细的农村道路的提取还是道路的连接性等),本文所提具有多个ASPP结构的道路提取模型DC-Net都表现出了优秀的提取结果。

4 结论

本文以深度学习中的全卷积网络模型为基础,提出了结合空洞卷积和ASPP结构的改进全卷积农村道路提取模型DC-Net。该方法针对农村道路细长和连接性的特点,结合空洞卷积扩大模型训练过程中特征图的感受野,使得农村道路的提取更具完整性。研究表明:

本文所提道路提取模型DC-Net在农村道路的提取上具有可行性,整体提取平均精度达到98.72%,具有较高的提取精度。

与几种经典的全卷积网络模型进行农村道路提取效果的对比,在农村道路提取的精度和连接

性,以及树木和阴影的遮挡方面,DC-Net都表现出了较好的提取结果。

本文提出的改进全卷积网络道路提取模型能够有效地提取高分辨率遥感影像中农村道路的特征信息,总体提取效果较好,为提高基于国产高分影像的农村道路提取精度提供了一种新的改进思路和方法。进一步的研究需要探讨ASPP层数与对象特征、精度要求之间的关系。

参考文献(References)

- Chaurasia A and Culurciello E. 2017. LinkNet: exploiting encoder representations for efficient semantic segmentation//2017 IEEE Visual Communications and Image Processing (VCIP). St. Petersburg, FL, USA: IEEE: 1-4 [DOI: 10.1109/VCIP.2017.8305148]
- Chen L C, Papandreou G, Schroff F and Adam H. 2017. Rethinking atrous convolution for semantic image segmentation. arXiv preprint arXiv: 1706.05587
- Chen L C, Zhu Y K, Papandreou G, Schroff F and Adam H. 2018. Encoder-decoder with atrous separable convolution for semantic im-

- age segmentation. arXiv preprint arXiv: 1802.02611
- Cheng G L, Wang Y, Xu S B, Wang H Z, Xiang S M and Pan C H. 2017. Automatic road detection and centerline extraction via cascaded end-to-end convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 55(6): 3322-3337 [DOI: 10.1109/TGRS.2017.2669341]
- Dai J G, Du Y, Fang X X, Wang Y and Miao Z P. 2018. Road extraction method for high resolution optical remote sensing images with multiple feature constraints. *Journal of Remote Sensing*, 22(5): 777-791 (戴激光, 杜阳, 方鑫鑫, 王杨, 苗志鹏. 2018. 多特征约束的高分辨率光学遥感影像道路提取. *遥感学报*, 22(5): 777-791) [DOI: 10.11834/jrs.20188055]
- Deng J, Dong W, Socher R, Li L J, Li K and Fei-Fei L. 2009. ImageNet: a large-scale hierarchical image database//2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami, FL, USA: IEEE: 248-255 [DOI: 10.1109/CVPR.2009.5206848]
- Doshi J. 2018. Residual inception skip network for binary segmentation//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Salt Lake City, UT, USA: IEEE: 216-219 [DOI: 10.1109/CVPRW.2018.00037]
- Glorot X, Bordes A and Bengio Y. 2011. Deep sparse rectifier neural networks//Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics. Fort Lauderdale, FL, USA: PMLR: 315-323
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE: 770-778
- Heipke C, Mayer H, Wiedemann C and Jamet D. 1997. Evaluation of automatic road extraction. *International Archives of Photogrammetry and Remote Sensing*, 32:151-161
- Hu W, Huang Y Y, Wei L, Zhang F and Li H C. 2015. Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015: 258619 [DOI: 10.1155/2015/258619]
- Ioffe S and Szegedy C. 2015. Batch normalization: accelerating deep network training by reducing internal covariate shift. arXiv preprint arXiv: 1502.03167
- Li C. 2018. Application of remote sensing technology in rural road verification. *Geomatics and Spatial Information Technology*, 41(5): 48-49, 52 (李程. 2018. 遥感技术在农村公路核查中的应用研究. *测绘与空间地理信息*, 41(5): 48-49, 52)
- Li Y, Guo L L, Rao J, Xu L L and Jin S. 2019. Road segmentation based on hybrid convolutional network for high-resolution visible remote sensing image. *IEEE Geoscience and Remote Sensing Letters*, 16(4): 613-617 [DOI: 10.1109/LGRS.2018.2878771]
- Lin X G, Zhang J X, Li H T and Yang Y H. 2009. Semi-automatic extraction of ribbon road from high resolution remotely sensed imagery by a T-shaped template matching. *Geomatics and Information Science of Wuhan University*, 34(3): 293-296 (林祥国, 张继贤, 李海涛, 杨景辉. 2009. 基于T型模板匹配半自动提取高分分辨率遥感影像带状道路. *武汉大学学报(信息科学版)*, 34(3): 293-296)
- Liu X, Wang G H, Yang H C, Liu Y and Wang Y. 2018. Road extraction from remote sensing image based on fully convolutional networks. *Remote Sensing Information*, 33(1): 69-75 (刘笑, 王光辉, 杨化超, 刘宇, 王耀. 2018. 全卷积神经网络遥感影像道路提取方法. *遥感信息*, 33(1): 69-75) [DOI: 10.3969/j.issn.1000-3177.2018.01.011]
- Martin D R, Fowlkes C C and Malik J. 2004. Learning to detect natural image boundaries using local brightness, color, and texture cues. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(5): 530-549 [DOI: 10.1109/TPAMI.2004.1273918]
- Papadomanolaki M, Vakalopoulou M and Karantzas K. 2017. Patch-based deep learning architectures for sparse annotated very high resolution datasets//2017 Joint Urban Remote Sensing Event. Dubai, United Arab Emirates: IEEE: 1-4 [DOI: 10.1109/JURSE.2017.7924538]
- Xu Y Y, Xie Z, Feng Y X and Chen Z L. 2018. Road extraction from high-resolution remote sensing imagery using deep learning. *Remote Sensing*, 10(9): 1461 [DOI: 10.3390/rs10091461]
- Yi W B, Chen Y H, Tang H and Deng L. 2010. Experimental research on urban road extraction from high-resolution RS images using Probabilistic Topic Models//2010 IEEE International Geoscience and Remote Sensing Symposium. Honolulu, HI, USA: IEEE: 445-448 [DOI: 10.1109/IGARSS.2010.5650966]
- Zeiler M D, Taylor G W and Fergus R. 2015. Adaptive deconvolutional networks for mid and high level feature learning//2011 International Conference on Computer Vision. Barcelona, Spain: IEEE: 2018-2025 [DOI: 10.1109/ICCV.2011.6126474]
- Zhang R, Zhang J X and Li H T. 2008. Semi-automatic extraction of ribbon roads from high resolution remotely sensed imagery based on angular texture signature and profile match. *Journal of Remote Sensing*, 12(2): 224-232 (张睿, 张继贤, 李海涛. 2008. 基于角度纹理特征及剖面匹配的高分辨率遥感影像带状道路半自动提取. *遥感学报*, 12(2): 224-232) [DOI: 10.11834/jrs.20080229]
- Zhang Z X, Liu Q J and Wang Y H. 2018. Road extraction by deep residual U-net. *IEEE Geoscience and Remote Sensing Letters*, 15(5): 749-753 [DOI: 10.1109/LGRS.2018.2802944]
- Zhong Z L, Li J, Cui W H and Jiang H. 2016. Fully convolutional networks for building and road extraction: preliminary results//2016 IEEE International Geoscience and Remote Sensing Symposium. Beijing, China: IEEE: 1591-1594 [DOI: 10.1109/IGARSS.2016.7729406]
- Zhou L C, Zhang C and Wu M. 2018. D-LinkNet: LinkNet with pre-trained encoder and dilated convolution for high resolution satellite imagery road extraction//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Salt Lake City, UT, USA: IEEE: 182-186 [DOI: 10.1109/CVPRW.2018.00034]

Road extraction in rural areas from high resolution remote sensing image using a improved Full Convolution Network

LI Chaokui^{1,2}, ZENG Qiangguo³, FANG Jun^{1,2}, WU Nei^{1,2}, WU Kaihua^{1,2}

1. National-Local Joint Engineering Laboratory of Geo-Spatial Information Technology, Hunan University of Science and Technology, Xiangtan 411201, China;

2. Hunan Province Key Laboratory of Surveying and mapping Remote Sensing Information Engineering, Hunan University of Science and Technology, Xiangtan 411201, China;

3. Remote Sensing Application Promotion Department of Hunan Second Institute of Surveying and Mapping, Changsha 410000, China

Abstract: Aiming at the problems of limited research, application of extracting rural roads with high-resolution remote sensing data, and insufficient accuracy of extraction results, a new improved full convolution rural road extraction network Distributed Convolution network (DC net) is proposed; it combines void convolution and Air Spatial Pyramid Pooling (ASPP) structure. The model extracts the depth feature information of the road based on the full convolution encoding and decoding structures. At the same time, in accordance with the characteristics of the slender rural roads, the ASPP structure based on the hollow convolution is added between the decoded layers to extract the multiscale characteristic information of the road, and the Field of View (FOV) is expanded without sacrificing the spatial resolution of the feature, thereby improving the recognition rate of narrow and fine rural roads. Some suburban areas of Changzhutan city group are considered the experimental objects and the domestic satellite remote sensing image of Gaogaoer as the experimental data. Experimental results are compared with those of the classical methods of all convolution networks. The results show that: (1) the proposed road extraction model DC net is feasible in rural road extraction, with the overall extraction average accuracy reaching 98.72%, indicating high extraction accuracy; (2) comparative results of the effect of several classic full convolution network models on rural road extraction, DC net extraction accuracy and connectivity, as well as tree and shadow shading in the aspect of block are acceptable; (3) the improved road extraction model of the entire proposed convolution network can effectively extract the feature information of rural roads in high-resolution remote sensing images. The overall extraction effect is improved; it provides a new approach for improving the precision of rural road extraction based on domestic high-resolution images.

Based on the full convolution network model in deep learning, this paper proposes an improved full convolution rural road extraction model DC net which combines hole convolution and ASPP structure. According to the characteristics of long and thin and connectivity of rural roads, this method combined with hole convolution to expand the receptive field of feature map in the process of model training, which makes the extraction of rural roads more complete.

Key words: full convolution network, dilated convolution network, atrous convolution, ASPP, rural road extraction

Supported by National Key Research and Development Program of China (No. 2017YFB0503802, 2018YFB0505401)