

多尺度特征融合的膨胀卷积残差网络 高分一号影像道路提取

马天浩^{1,2}, 谭海^{2*}, 李天琪^{1,2}, 吴雅男^{1,2}, 刘祺²

¹ 辽宁工程技术大学测绘与地理科学学院, 辽宁 阜新 123000;

² 自然资源部国土卫星遥感应用中心, 北京 100048

摘要 针对全卷积神经网络多次下采样操作导致的道路边缘细节信息损失和道路提取不准确的问题, 本文提出了多尺度特征融合的膨胀卷积残差网络高分一号影像道路提取方法。首先, 通过目视解译的方法制作大量的道路提取标签数据; 其次, 在残差网络 ResNet-101 的各个残差块中引入膨胀卷积和多尺度特征感知模块, 扩大特征点的感受野, 避免特征图分辨率减小和道路边缘细节特征的损失; 然后, 通过叠加融合和上采样操作将各个尺寸的道路特征图进行融合, 得到原始分辨率大小的特征图; 最后, 将特征图输入 Sigmoid 分类器中进行分类。实验结果表明: 本文方法的提取精度优于经典全卷积神经网络模型, 准确率达到 98% 以上, 有效保留了道路的完整性及其边缘的细节信息。

关键词 遥感; 道路提取; 高分一号影像; 残差网络; 膨胀卷积; 多尺度特征

中图分类号 P237

文献标志码 A

doi: 10.3788/LOP202158.0228001

Road Extraction from GF-1 Remote Sensing Images Based on Dilated Convolution Residual Network with Multi-Scale Feature Fusion

Ma Tianhao^{1,2}, Tan Hai^{2*}, Li Tianqi^{1,2}, Wu Yanan^{1,2}, Liu Qi²

¹ School of Geomatics, Liaoning Technical University, Fuxin, Liaoning 123000, China;

² Land and Resources Remote Sensing Application Center of the Ministry of Natural Resources, Beijing 100048, China

Abstract This paper aimed to solve the problems of road edge detail information loss and inaccurate road extraction due to multiple downsampling operations of the fully convolutional neural network. Thus, a road extraction method of GF-1 remote sensing images based on dilated convolution residual network with multiscale feature fusion is proposed. First, numerous labels for road extraction are generated through visual interpretation. Second, dilated convolution and multiscale feature perception modules are introduced in each residual block of the residual network, namely, ResNet-101, to enlarge the receptive field of the feature points without reducing the feature map resolution and losing the detailed edge information. Third, through superposition fusion and upsampling operations, the road feature maps of various sizes are fused to obtain the feature maps of the original resolution size. Finally, for classification, the feature maps are input into the Sigmoid classifier. The experimental results indicate that the proposed method is more accurate than the conventional fully convolutional neural network models, with the accuracy rate being more than 98%. The proposed method effectively preserves the integrity and detailed edge information of the road area.

Key words remote sensing; road extraction; GF-1 image; residual network; dilated convolution; multiscale features

OCIS codes 280.4788; 100.4996; 100.3008

收稿日期: 2020-06-08; 修回日期: 2020-07-08; 录用日期: 2020-07-24

* E-mail: 896963286@qq.com

1 引言

道路是遥感影像中重要的基础地理信息之一,从各类遥感影像中提取道路具有重要意义。随着卫星影像分辨率和精度的不断提高,从大量高分辨率遥感影像数据源中自动提取道路的研究也日益活跃^[1-2]。国内外学者针对高分辨率遥感影像中道路的提取算法进行了大量研究。这些算法根据所提取的信息层次的不同可分为基于像元、基于区域和基于深度学习的方法。

基于像元的道路提取方法主要根据道路像元和背景像元所表现出来的差异性来识别道路。文献[3]首先利用 Otsu 方法获得道路像元和非道路像元的二值图,然后采用 Zernike 矩进行了道路的提取;该方法的计算时间较长且精度有待提高。文献[4]利用 Canny 边缘检测算子来识别和提取矿区道路,然后通过边缘信息进行边缘匹配来获得道路边缘;该方法的精度依赖于边缘检测算法,且对其他环境中道路的识别精度不高。

基于区域的方法是将遥感影像分割成块状区域,然后利用道路的纹理、颜色等特征信息对这些块状区域进行道路识别^[5]。文献[6]采用标记点的分水岭算法将影像分割为区域对象,然后在分割区域中引入 Markov 模型来提取道路。文献[7]利用数学形态学算法和最大期望聚类的图像分割算法实现了遥感影像中道路的提取,但该方法对道路边缘提取得不够完善。文献[8]首先利用滤波和聚类算法获取候选道路段,然后使用区域增长法得到了道路网;该方法的步骤繁琐,缺乏灵活性,而且路面的干扰信息和灰度不一致会影响算法的分割效果。

基于像元和基于区域的道路提取方法的局限如下:对于地物信息复杂和存在多种类型道路的遥感影像,道路提取精度较低;需要人为设计大量的先验知识,无法自动有效地提取道路区域;提取的道路特征较为单一,不适合迁移和扩展。

基于深度学习的道路自动提取算法利用机器学习的能力从大数据中学习深层次的抽象道路特征。文献[9]使用深度卷积神经网络(DCNN)从原始遥感影像中提取建筑物和道路的特征,但由于 DCNN 不能获取细节特征,因此分割结果比较粗糙。为了解决这一问题,文献[10]提出了全卷积神经网络(FCN),全卷积神经网络将卷积神经网络的全部全连接层替换为卷积层,可以接受任意尺寸的图像,实现像素级别的分类。文献[11]利用全卷积

神经网络和隐藏层的多层次特征信息,在资源三号影像上实现了较好的道路中心线的提取结果。为了解决全卷积神经网络不能充分利用上下文信息进行像素分类从而导致分割结果出现噪声的问题,研究人员提出了 FCN-8s。FCN-8s 采用跳跃连接的结构,将上采样输出的特征图与网络中间层中具有相同分辨率的特征图进行融合,以弥补下采样丢失的细节信息^[12]。为了提高分割精度,文献[13]提出了 U-Net 模型,该模型采用将低级特征信息与高级语义信息进行级联的对称式网络结构。上述语义分割网络在一定程度上提高了目标的分割精度,改善了提取效果,但是在高分辨率遥感影像的道路提取中,不能保证不同尺度道路的自适应识别,而且对全局上下文信息结合得不充分。

本文提出了一种多尺度特征融合的膨胀卷积残差神经网络高分一号影像道路自动识别方法,该方法可以有效减少人为干预,实现遥感影像中道路的自动提取,弥补传统方法的不足。在残差网络中引入膨胀卷积和多尺度特征感知模块,结合深度残差网络、膨胀卷积和金字塔池化单元的优势,可以获得深层抽象语义特征,减少特征图分辨率的损失;将高层次和低层次的特征信息进行融合,可以有效保留边缘轮廓信息,弥补上述语义分割网络在多尺度特征表达上的不足,提高道路自动提取的精度。

2 基本原理

通常情况下,卷积神经网络包含输入层、卷积层、池化层、全连接层和激活函数^[14]。本文采用的膨胀卷积残差网络是不包含全连接层的端到端的图像分割网络,输入是一个二维平面,输出也是一个二维平面。

卷积层的作用是提取输入数据的特征。用多个卷积层可以提取更深层次的语义特征。卷积操作就是对有一定区域大小的数据和具有权重参数的卷积核进行内积得到特征图^[15]。卷积运算公式可以表示为

$$X_j^l = f\left(\sum_{i \in M_j} X_i^{l-1} \cdot \omega_{ij}^l + b_j^l\right), \quad (1)$$

式中: i 代表卷积行数; j 代表卷积列数; l 代表层数; M_j 代表输入的特征图; ω 为卷积核权重; b 为偏置项; f 为激活函数,其作用是对上层卷积层提取的简单低维特征进行非线性映射。训练神经网络的目的就是不断地更新参数,找到最优参数。

激活函数的本质是为神经网络引入非线性特

征,使神经网络能够学习、处理更加复杂的非线性问题。常用的非线性激活函数有 Sigmoid 函数、Tanh 函数、ReLU 函数和 ELU 函数^[16]。本文采用 ELU 函数,它在输入负数时被激活,输出一定范围的值而非直接变为 0,并且该区的输出值在一定程度上具有抗干扰能力,弥补了 ReLU 函数的缺点。

池化层的输入一般是上一层的卷积层输出,对卷积层得到的特征图进行下采样操作可以对输出特征实现压缩降维。池化层可以防止过拟合现象和扩大感受野,同时具有旋转不变性,它也可以对特征图中的重要特征进行突出。常用的池化方式有两种:最大池化和平均池化。本文采用最大池化。最大池化就是将输入的图像划分为若干个矩形区域,对每个子域输出最大值,以提取响应最强烈的特征并加

快网络收敛速度。其计算公式为

$$X_{i,j}^l = \max_{m>0,s>n} \{X_{i+s,m,j+s+n}^{l-1}\}, \quad (2)$$

式中: s 表示池化的模板尺寸; m 和 n 表示相应方向的步长。

虽然多次对特征图使用池化操作可以提取深层次和感知全局的语义特征,但会损失道路边缘的细节特征,不能精确挖掘高分辨率影像的道路特征。为了在降低特征图分辨率的同时防止丢失道路边缘的细节特征,在网络结构中用膨胀卷积代替相应的普通卷积。膨胀卷积通过设置不同的膨胀率在卷积核中填充 0 元素使卷积核膨胀到相应的尺寸,从而达到扩大卷积核感受野的目的^[17]。图 1 表示当原始卷积核大小为 3×3 时,膨胀率为 1、2 和 4 的膨胀卷积核感受野的大小。




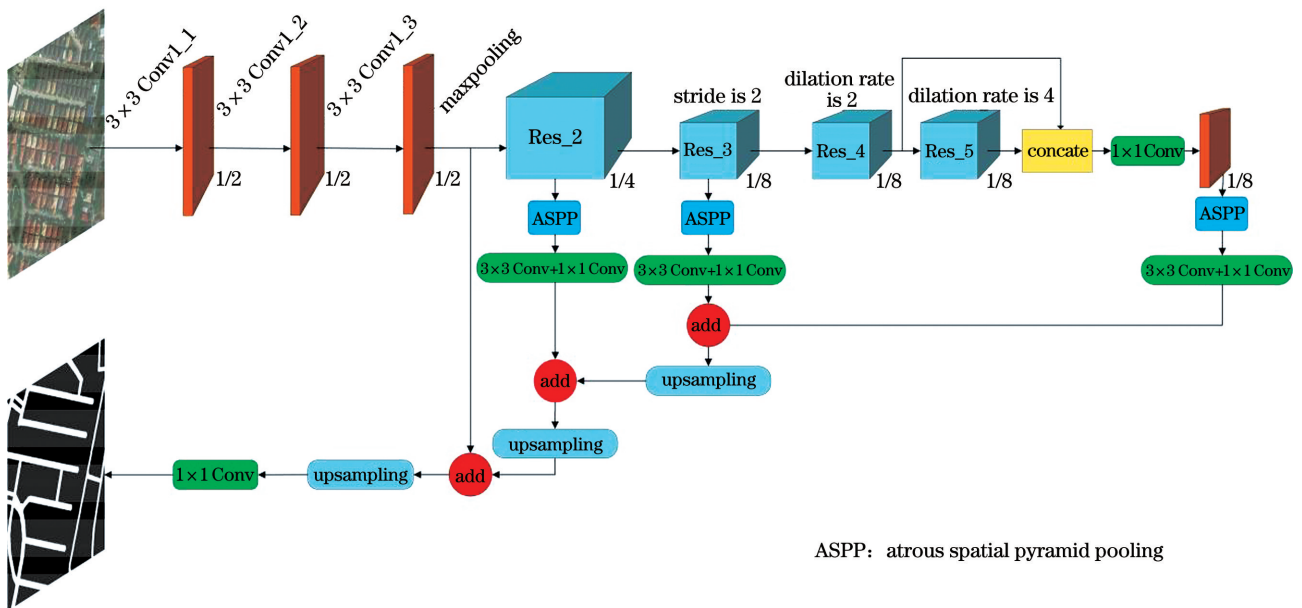
图 1 膨胀卷积核感受野的大小。(a)膨胀率为 1;(b)膨胀率为 2;(c)膨胀率为 4

Fig. 1 Receptive field size of dilated convolution kernel. (a) Dilation rate is 1; (b) dilation rate is 2; (c) dilation rate is 4

3 算法的整体框架

鉴于高分一号卫星影像的分辨率较高,在道路

提取过程中要充分考虑道路边缘的细节信息,因此本文提出了一种多尺度特征融合的膨胀卷积残差网络高分一号影像道路提取方法。图 2 是本文方法的



ASPP: atrous spatial pyramid pooling

图 2 本文设计的道路识别网络结构

Fig. 2 Road identification network structure designed in this paper

道路识别网络结构示意图。该网络模型是以经典的 ResNet-101 网络模型为基础进行改进后得到的,包含膨胀卷积残差神经网络结构和多尺度特征感知模块。首先利用膨胀卷积残差网络对输入图像进行特征提取,膨胀卷积残差网络的残差区块 3 和残差区块 5 输出两个大小是原图 1/8 的 64 维特征图,残差区块 2 输出一个大小是原图 1/4 的 64 维特征图, Conv1_3 输出一个大小为原图的 1/2 的 64 维特征图,将上述 4 个 64 维特征图进行上采样、叠加和卷积操作后输入到 Sigmoid 分类器中,即可实现遥感图像中道路的精细提取。

3.1 膨胀卷积残差神经网络

通过加深卷积神经网络的层数可以获得深层次的、丰富的和抽象的语义特征,但是随着网络层数的加深,会出现梯度爆炸或梯度消失的问题,导致模型过拟合和准确率下降。为了解决网络退化的问题,He 等^[18]提出了深度残差网络结构,该结构不再学习输入与输出之间的函数关系,而是学习差值函数关系。在残差块中,将输入特征图 x 和残差函数 $F(x)$ 相加得到预测特征映射 $H(x)$,表达式为

$$H(x) = F(x) + x. \quad (3)$$

ResNet-101 是容易优化的深层残差网络,它一共有 101 层网络结构,包括 101 个卷积层,大致可划分为 5 个阶段,后面 4 个阶段都包含多个深度残差学习单元。改进后的多尺度膨胀卷积残差神经网络结构如图 3 所示。在第一阶段,用 3 个 3×3 的卷积核代替原始的 1 个 7×7 的卷积核,以减少计算量和

参数。原始 ResNet-101 的每个阶段都会进行下采样处理,使每个阶段的输出缩小为原来的一半。这样做虽然能够扩大卷积核的感受野,获得深层次的语义特征,但是会丢失高分辨率遥感影像中道路边缘的细节信息特征。为了解决以上问题,本文设计了膨胀卷积残差网络,在残差网络的第三和第四阶段不再使用下采样操作,而是在第三、第四、第五阶段分别用膨胀率为 1、2、4 的膨胀卷积代替普通卷积。这样操作不仅可以在保证特征图分辨率不变的情况下,扩大三个阶段卷积核的感受野,还可以在不断增加参数数量和计算量的情况下,学习到全局的深层次语义特征。

3.2 多尺度特征感知模块

在全卷积神经网络中,通常将原始影像经过 ResNet 生成的特征图直接上采样至原始大小,然后通过 Sigmoid 函数分类器获得最终的提取结果。如果直接将这种方式用于遥感影像的道路提取,将会导致不同尺度特征的缺失,无法保证对道路局部特征的自适应识别。

为了有效捕获遥感影像中道路的多尺度信息,本文在残差网络的各个阶段之后加入多尺度特征提取模块,该模块包含空洞空间金字塔池化单元以及卷积核为 3×3 和 1×1 的普通卷积。空洞空间金字塔池化模块(ASPP)由 4 个膨胀率不同的空洞卷积层并行组成,能够解决多尺度问题和捕获上下文信息^[19]。为了避免膨胀率过大导致卷积层退化的问题,本文采用的 ASPP 膨胀卷积的卷积核尺寸为 1×1 ,膨胀率为 1,卷积核尺寸为 3×3 ,膨胀率分别为 3、6、12,卷积核的个数为 520。为了保留上一层特征图的原有信息,本文选取了相当于普通卷积的膨胀率为 1、卷积核为 1×1 的膨胀卷积。最后将所有并行处理的特征结合起来,再经过一个 3×3 和一个 1×1 的卷积就可以输出低分辨率的特征图。

4 实验结果与分析

4.1 数据集与参数设置

本文选取 7 景高分一号卫星影像制作实验数据集。高分一号影像数据是由分辨率分别为 2 m 全色影像和 8 m 多光谱影像融合而成,它的分辨率为 2 m。使用 Photoshop 通过目视解译的方法对遥感影像的道路区域进行勾画提取,得到对应的标签图像。因为计算机硬件的限制,每张训练样本尺寸大小为 $320 \text{ pixel} \times 320 \text{ pixel}$ 。经过裁剪之后共有 24000 张含

Layer name	Layer	Dilation rate
Conv1_x	$3 \times 3, 64, \text{stride is } 2$	1
	$3 \times 3, 64$	1
	$3 \times 3, 64$	1
Maxpooling	$3 \times 3, 64, \text{stride is } 2$	
Res2_x	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	1
Res3_x	$1 \times 1, 128, \text{stride is } 2$	1
	$3 \times 3, 128$	1
	$3 \times 3, 512$	1
	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	1
Res4_x	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	2
Res5_x	$\begin{bmatrix} 1 \times 1, 521 \\ 3 \times 3, 512 \\ 1 \times 1, 2046 \end{bmatrix} \times 3$	4

图 3 膨胀卷积残差神经网络的结构图

Fig. 3 Dilated convolution residual neural network structure

标签数据的遥感影像,如图 4 所示,然后将其以 8:2

的比例分成训练集(19200 张)和验证集(4800 张)。

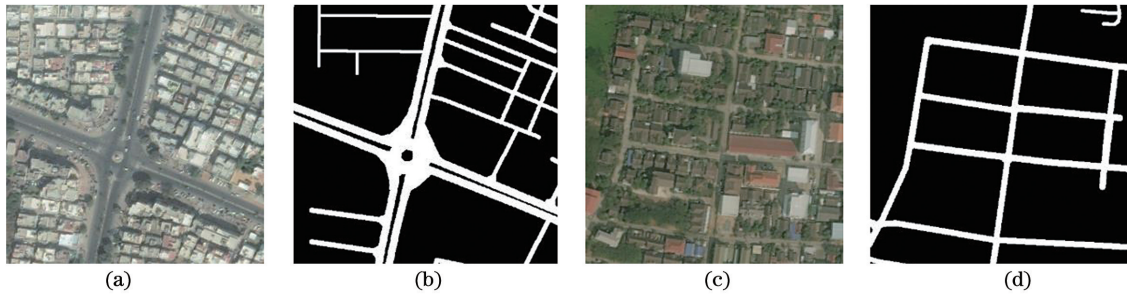


图 4 训练样本与标签。(a)输入图像 a;(b)a 的标签;(c)输入图像 b;(d)b 的标签

Fig. 4 Training samples and labels. (a) Original image a; (b) label of image a; (c) original image b; (d) label of image b

本文实验环境为 Linux 操作系统,系统版本为 ubuntu18.04,显卡型号为 NVIDIA QuadroP6000,显存容量为 24 GB,采用 Tensorflow 深度学习框架。实验参数设置如下:基本学习率 base_lr 设置为 0.0001,迭代轮数 epoch 设置为 60,训练集和验证集的批大小(batch size)均设置为 8。

4.2 结果对比与分析

为了验证本文设计的道路提取方法的有效性,将

经典语义分割网络 FCN-8s、SegNet^[20] 和 ResNet-101 与本文方法进行对比实验(选用相同的训练集)。测试数据区域位于城市和农村,包含土路、沥青公路、高速公路等道路以及植被、建筑等地物。

图 5 是实验结果对比图。为了对比不同方法的提取结果在细节和完整性上的差异,本文对原始影像和实验结果的部分区域进行放大显示,如图 6 所示。从图 5 和图 6 中可以看出,FCN-8s 的提取结果




图 5 实验结果的对比。(a)输入图像;(b)目视真值;(c)FCN-8s 的提取结果;(d)SegNet 的提取结果;(e)ResNet-101 的提取结果;(f)本文方法的提取结果

Fig. 5 Comparison of experimental results. (a) Input images; (b) ground truth; (c) extraction results of FCN-8s; (d) extraction results of SegNet; (e) extraction results of ResNet-101; (f) extraction results of our method

有三个不足之处:1)有大范围的漏提取和误提取区域;2)道路边缘处的锯齿现象较明显;3)在复杂的住宅区出现了斑点噪声。造成上述三个问题的原因是 FCN-8s 进行了 4 次下采样操作,使得特征图的分辨率下降,丢失了全局和细节语义特征信息。从图 5 和图 6 中还可以看出,SegNet 和 ResNet-101 的提取结果有三个共同的缺点:1)道路中间区域有漏提取的空洞;2)提取的道路不完整,有断裂现象;3)双向车道的边界不清晰。SegNet 的解码器只包含一种尺度信息,限制了像素点的准确分类。ResNet-

101 虽然加入了残差学习,但是经过编码器的四次下采样后直接在解码器进行四次上采样,缺乏多尺度语义信息,限制了模型精度的提升。本文所提道路识别算法的总体提取效果较好,道路较为完整连续,道路边缘位置准确,可以清晰地分割双向车道,但出现了将露天停车场误提取为道路以及道路两旁树木遮盖区域漏提取的情况。主要原因如下:1)露天停车场内的地表特征与道路特征比较相似,样本集中,而且露天停车场内的样本数量较少;2)高大植被的阴影对道路的遮挡会干扰道路信息的提取。



图 6 实验结果的放大。(a)输入图像;(b)目视真值;(c)ResNet-101 的提取结果;(d)本文方法的提取结果

Fig. 6 Enlarged display of experimental results. (a) Input images; (b) ground truth; (c) extraction results of ResNet-101; (d) extraction results of our method

为了定量评价本文道路识别方法的有效性,选择准确率、精确率、召回率、 F_1 值和交并比 IoU 五项指标定量评价道路识别结果的精度。其中:准确率 A 表示正确分类的区域占总区域的比例;精确率 P 代表提取的道路中真实道路所占的比例;召回率 R_{recall} 代表预测的道路中真实道路所占的比例; F_1 值代表精确率与召回率的加权平均值;交并比代表实际真实值和预测值之间的相关度,该值越高表示

提取效果越好。

$$A = \frac{\alpha_{TP} + \alpha_{TN}}{\alpha_{TP} + \alpha_{FP} + \alpha_{TN} + \alpha_{FN}}, \quad (4)$$

$$P = \frac{\alpha_{TP}}{\alpha_{TP} + \alpha_{FP}}, \quad (5)$$

$$F_1 = 2 \times \frac{P \times R_{recall}}{P + R_{recall}}, \quad (6)$$

$$IoU = \frac{\alpha_{TP}}{\alpha_{TP} + \alpha_{FN} + \alpha_{FP}}, \quad (7)$$

式中： α_{TP} 表示预测为道路并且预测正确（正确提取的道路）的范围； α_{FP} 表示将背景预测为道路的范围； α_{FN} 表示将道路预测为背景的范围； α_{TN} 表示将背景区域预测正确的范围。

由表 1 可以看出，本文所提道路识别方法相比于其他方法在准确率、精确率、召回率、 F_1 值和交并比上的效果更好，准确率为 98.11%，精确率为 96.58%，召回率为 96.53%， F_1 值为 96.55%，交并比为 76.15%。可见，与其他方法相比，本文的道路提取方法在本文的数据集上可以取得最好的提取结果。本文方法引入了膨胀卷积，可以有效弥补下采样操作导致的特征图分辨率的损失（只需要进行三次下采样操作），从而有效保留了细节特征。此外，多尺度特征感知模块将特征图池化成不同的尺度，并与原始特征图进行融合，形成了多尺度表达。

表 1 各方法提取精度的定量评价

Method	Accuracy	Precision	Recall	F_1	IoU
FCN-8s	80.16	79.84	80.98	78.23	50.53
SegNet	90.56	89.58	91.29	90.63	60.31
ResNet-101	93.21	92.32	91.24	90.46	63.45
Ours	98.11	96.58	96.53	96.55	76.15

5 结 论

本文基于深度学习框架，通过图像预处理、标签制作、卷积神经网络结构设计、网络训练、结果输出和精度评价构建了高分一号影像道路自动提取深度学习模型。考虑到传统方法依赖于人为设计，以及经典全卷积神经网络多次下采样丢失边缘细节信息且不能有效利用多尺度信息的问题，本文基于 ResNet-101 提出了多尺度特征融合的膨胀卷积残差网络高分一号影像道路提取方法，膨胀卷积残差网络结构结合了深度残差网络、膨胀卷积和金字塔池化单元的优势。深度残差网络可以学习更抽象的深层语义特征，防止过拟合；膨胀卷积可以成倍增加特征点的感受野而不降低特征图的分辨率，且不会丢失空间信息；金字塔池化单元可以将特征图池化为不同的尺度并与原始输入特征图进行融合，有效利用了多尺度信息，使网络模型可以对不同形状、不同大小和不同复杂场景的道路进行有效拟合。

实验结果表明，本文的道路提取方法与 FCN-8s、SegNet 和 ResNet-101 相比，能够在复杂

环境的城市和野外区域实现道路提取，而且提取精度较高，提取结果更加完整连续。但本文方法仍有不足之处，例如在建筑物交叉密集区域会将露天停车场误提取，本研究团队后续拟借助其他卷积神经网络模型以及采用扩充数据集的方法提高道路提取的准确率。

参 考 文 献

- [1] Wu Liang, Hu Y A. A survey of automatic road extraction from remote sensing images [J]. Acta Automatica Sinica, 2010, 36(7): 912-922.
吴亮, 胡云安. 遥感图像自动道路提取方法综述[J]. 自动化学报, 2010, 36(7): 912-922.
- [2] Xue F, Wang R S. Road extraction by combined using statistical and structural information [J]. Acta Optica Sinica, 2001, 21(4): 504-508.
薛峰, 王润生. 组合利用统计和结构信息的道路提取算法[J]. 光学学报, 2001, 21(4): 504-508.
- [3] Mu H L, Zhang Y, Li H B, et al. Road extraction base on Zernike algorithm on SAR image [C] // 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), July 10-15, 2016, Beijing, China. New York: IEEE Press, 2016: 1274-1277.
- [4] Zeng F M, Yang B, Wu D W, et al. Extraction of roads in mining area based on Canny edge detection operator [J]. Remote Sensing for Land & Resources, 2013, 25(4): 72-78.
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.
- [5] Qu L, Wang K R, Chen L L, et al. Fast road detection based on RGBD images and convolutional neural network [J]. Acta Optica Sinica, 2017, 37(10): 1010003.
曲磊, 王康如, 陈利利, 等. 基于 RGBD 图像和卷积神经网络的快速道路检测 [J]. 光学学报, 2017, 37(10): 1010003.
- [6] Yu C H, Yi Y H. Object-based road extraction in remote sensing image using Markov random field [J]. Geomatics and Information Science of Wuhan University, 2011, 36(5): 544-547.
余长慧, 易尧华. 利用 MRF 方法的高分辨率影像道路提取 [J]. 武汉大学学报 (信息科学版), 2011, 36(5): 544-547.
- [7] 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.

- [8] Jin J, Dang J W, Wang Y P, et al. Research on object oriented algorithm for road extraction in high-resolution remote sensing image[J]. Journal of Lanzhou Jiaotong University, 2017, 36(1): 57-61.
金静, 党建武, 王阳萍, 等. 面向对象的高分辨率遥感影像道路提取算法[J]. 兰州交通大学学报, 2017, 36(1): 57-61.
- [9] Saito S, Yamashita T, Aoki Y. Multiple object extraction from aerial imagery with convolutional neural networks[J]. Electronic Imaging, 2016, 2016(10): 1-9.
- [10] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 3431-3440.
- [11] 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.
- [12] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. [2020-06-08]. <https://arxiv.org/abs/1409.1556v6>.
- [13] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015: 234-241.
- [14] Guo Z S, Li C H, Wang Z M. Road extraction from ZY-3 remote sensing image based on U-Net like convolution architecture[J]. Science of Surveying and Mapping, 2020, 45(4): 51-57.
郭正胜, 李参海, 王智敏. U型卷积神经网络的 ZY-3 影像道路提取方法[J]. 测绘科学, 2020, 45(4): 51-57.
- [15] Pei L, Liu Y, Tan H, et al. Cloud detection of ZY-3 satellite remote sensing images based on improved fully convolutional neural networks [J]. Laser & Optoelectronics Progress, 2019, 56(5): 052801.
裴亮, 刘阳, 谭海, 等. 基于改进的全卷积神经网络的资源三号遥感影像云检测[J]. 激光与光电子学进展, 2019, 56(5): 052801.
- [16] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]//International Conference on Neural Information Processing Systems. [S.l.]: Curran Associates Inc., 2012: 1097-1105.
- [17] Cheng X Y, Zhao L Z, Hu Q, et al. Real-time semantic segmentation based on dilated convolution smoothing and lightweight up-sampling[J]. Laser & Optoelectronics Progress, 2020, 57(2): 021017.
程晓悦, 赵龙章, 胡穹, 等. 基于膨胀卷积平滑及轻型上采样的实时语义分割[J]. 激光与光电子学进展, 2020, 57(2): 021017.
- [18] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [19] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation [EB/OL]. [2020-06-08]. <https://arxiv.org/abs/1706.05587>.
- [20] 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.