

引用格式: Wang Zhuo, Yan Haowen, Lu Xiaomin, *et al.* High-resolution Remote Sensing Image Road Extraction Method for Improving U-Net[J]. Remote Sensing Technology and Application, 2020, 35(4): 741-748. [王卓, 闫浩文, 禄小敏, 等. 一种改进U-Net的高分辨率遥感影像道路提取方法[J]. 遥感技术与应用, 2020, 35(4): 741-748.]
doi:10.11873/j.issn.1004-0323.2020.4.0741

一种改进U-Net的高分辨率遥感影像道路提取方法

王卓^{1,2,3}, 闫浩文^{1,2,3}, 禄小敏^{1,2,3}, 冯天文^{4,5}, 李亚珍^{4,5}

(1. 兰州交通大学测绘与地理信息学院, 甘肃 兰州 730070;

2. 地理国情监测技术应用国家地方联合工程研究中心, 甘肃 兰州 730070;

3. 甘肃省地理国情监测工程实验室, 甘肃 兰州 730070;

4. 中国科学院西北生态环境资源研究院, 甘肃 兰州 730000;

5. 中国科学院大学, 北京 100049)

摘要:从遥感影像中准确高效地提取道路信息,对基础地理数据库的建立与维护具有重大意义。高分辨率遥感影像背景信息复杂,导致现有算法无法较好地从中提取道路信息。U-Net网络在图像分割方面有较好的实验效果,但道路分割结果准确性不佳,因此,提出了一种改进U-Net网络的高分辨率影像道路提取方法。首先,设计基于U-Net的网络结构,将VGG16作为网络编码结构,可更好地提取特征语义信息;其次,利用Batch Normalization与Dropout解决网络训练过程中出现的过拟合;最后,对训练数据利用旋转与镜像变换进行扩充,采用ELU激活函数,提升了网络训练速度。实验结果表明:该方法可以较为准确高效地提取道路信息。

关键词:高分辨率遥感影像;道路提取;U-Net网络

中图分类号: TP75 **文献标志码:** A **文章编号:** 1004-0323(2020)04-0741-08

1 引言

遥感影像中蕴含大量的地物空间信息,为地理空间信息的获取提供了方便快捷的途径,但如何精准高效地提取地物信息仍然是遥感领域的难点和热点。道路作为基础的地物要素之一,其提取依旧是地理科学和遥感等领域研究的重点。精准地提取道路信息能够提升路网构建、更新和维护的效率,同时,其在无人驾驶^[1]、军事打击^[2]、灾害救援^[3]等领域都具有重大意义。

对于道路提取,相关学者已经做了大量的研究工作。张永宏等^[4]对现有的道路提取模型做了全面的分析与总结,将其按照道路提取的层次进展分为以下3类:基于像元、对象和深度学习等方法。基于

像元的道路提取方法能够充分利用影像的光谱特征和空间特征,如Richard等^[5]利用光谱特征进行提取,罗庆洲等^[6]利用光谱特征和几何特征进行提取。该类方法能够在场景简单的影像中可以较好地提取道路,但在复杂场景下,则较难区分道路和建筑物及其阴影。基于对象的方法利用空间、纹理和光谱特征,将临近像元作为对象来识别影像,如蔡红玥等^[7]提出的改进的分水岭算法,余长慧等^[8]提出的利用MRF的方法,Li等^[9]提出的利用模糊集理论进行区域合并的方法,曹云刚等^[10]提出的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方法,Das等^[11]提出的利用多光谱影像的局部线性特征结合支持向量机对道路进行提取的方法。该

收稿日期:2019-10-17;修订日期:2020-06-23

基金项目:国家重点研发计划项目(2017YFB0504203),国家自然科学基金项目(41671447、41861055),国家青年基金项目(41801395),中国博士后科学基金(2019M653795),兰州交通大学优秀平台(201806)。

作者简介:王卓(1994—),男,甘肃庆阳人,硕士研究生,主要从事遥感影像解译。E-mail:1078095001@qq.com

通讯作者:闫浩文(1969—),男,甘肃民勤人,教授,主要从事地图自动综合和空间方向关系方面的研究。E-mail:haowen2010@gmail.com

类算法可以较好地提取道路,但对于空间位置相邻、几何形状相似的地物较难区分。基于深度学习的方法使计算机可从浅层的特征自动学习更加复杂抽象的特征,从而能够准确和高效地进行分类判别,如刘笑等^[12]提出的基于全卷积神经网络的方法,贺浩等^[13]提出的基于 Encoder-Decoder 网络的方法,Kampffmeyer 等^[14-17]提出的应用 FCN 及其改进的道路提取方法,Kestur^[18]等提出的 UFCN 网络模型,Zhang 等^[19]提出的基于 ResNet 与 U-Net 的网络模型,Panboonyuen 等^[20]提出的基于 SegNet 与 ELU 的网络模型。该类方法可以较好地将道路区域进行分割,但其分割结果存在孤立点与断裂道路。综上所述,以上 3 种算法都不能很好地提取道路信息,提取的准确率有待进一步提升。

U-Net^[21]在保留了高级的语义信息的同时采用跳跃连接顾及了低级的细节信息^[19],对生物医学影像分割效果较好,但训练易出现过拟合,分割效果不能满足道路提取的需求。王宇等^[22]提出结合残差网络的建筑物提取方法,以 Encoder-Decoder 为基础,引入残差网络结构和 Batch Normalization,提高了分类精度。崔刚等^[23]为研究不同分辨率图像的冬小麦识别效果,采用了基于 PSPNet^[24]的网络结构,该结构采用了跳跃连接,冬小麦识别研究中取得了很好的效果。为此,提出了一种改进 U-Net 的高分辨率遥感影像道路提取方法,利用 Batch Normalization、ELU 与 Dropout 较好地解决了过拟合所导致的准确率较低的问题,并利用 TGRS2017 数据集^[25]进行了有关实验,实现道路信息的高维、复杂、抽象特征的自动提取,解决目前算法提取结果存在较多孤立点与少量断裂道路的问题。

2 遥感影像道路提取方法

基于 U-Net 网络模型提取道路信息的实验过程具体如下:首先,将高分辨率遥感数据进行人工解译,并对其训练数据根据网络结构和硬件需求裁剪成相应大小,制作训练数据集。实验采用的数据集为 TGRS2017 数据集^[14],并对该数据集进行旋转与镜像的操作进行扩充。其次,将训练数据输入实验网络模型进行学习训练,不断更新网络模型中的参数,使损失值减少到最低,保存当前网络模型。最后,利用其训练好的网络模型进行道路提取。

2.1 U-Net 与 VGG16

U-Net^[21]于 2015 年由 Ronneberger 等提出,其

网络结构如图 1 所示,图中 Conv2D 代表卷积计算,MaxPooling 为最大池化操作,UpSampling2D 为上采样计算。U-Net 网络是由用于获取上下文信息的编码路径与用于实现精确定位的对称扩展路径组成。其中收缩编码路径与卷积神经网络的典型结构相同,由卷积计算与池化计算交替组合而成,逐渐缩小特征图像大小,同时增加每一层的特征图像数量。扩展路径每一组计算都包含该特征图像的上采样操作,然后进行卷积计算。因扩展路径会扩大输出特征图像的分辨率,为精确化上采样特征图像,在扩展路径中采用跳跃连接将其收缩路径中的高分辨率特征图像相结合。模型的输出为图像蒙版,用于表示不同的要素。

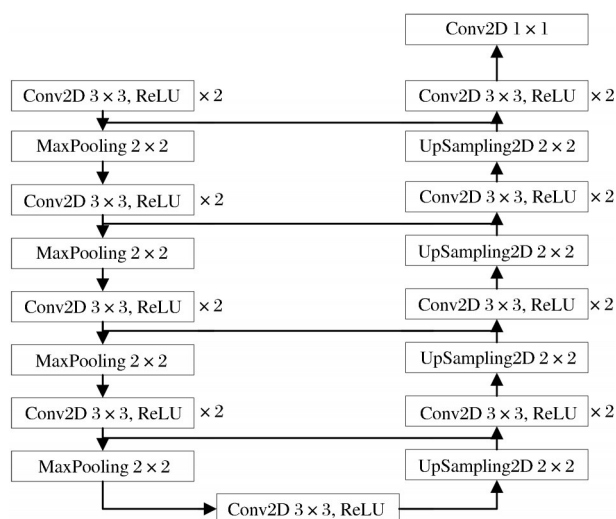


图 1 U-Net 网络结构

Fig.1 U-Net network architecture

VGGNet^[26]于 2014 年被牛津大学计算机视觉组和 Google DeepMind 提出,并在 2014 年 ILSVRC 比赛中取得定位任务冠军和分类任务亚军。VGG-Net 验证了网络深度的增加可提高网络的性能,其核心思想是采用较小的卷积核来增加网络深度,3×3 的卷积核是最小的能够捕捉八邻域信息的卷积核,且多个 3×3 的卷积核比单个大尺寸的卷积核具有更多的非线性函数和更少的参数。因此,VGGNet 被广泛的用来提取图像特征。VGG16 由 16 层组成,如图 2 所示,图中 Conv2D 代表卷积计算,MaxPooling 为最大池化操作,Flatten 将计算结果转化为一维向量,Dense 为全连接层。VGG16 包含 13 个卷积层和 4 个最大池化层与 3 个全连接层,其中每个卷积层采用 RELU 激活函数,其中每个卷积层采用的都是 3×3 的卷积核,经历第一个卷积计算后

产生64个通道的特征图,随着网络层数的加深,在经历每一次的池化计算后,卷积计算得到的通道数翻倍,直到其通道数达到512后,其余的卷积操作不会再增加特征图的通道数。




图2 VGG16网络结构

Fig.2 VGG16 Network Architecture

2.2 Batch Normalization、ELU与Dropout

因深层神经网络在做非线性变换前的激活函数输入值会随着网络深度加深,或在训练过程中其分布逐渐发生偏移或变动,导致其整体分布向非线性函数取值区间的上下限靠近,从而致使反向传播时低层神经网络的梯度消失。针对该梯度消失问题,批规范化^[27](Batch Normalization,简称BN)通过一定的规范化手段,固定每层网络输入特征的均值与方差,可解决梯度弥散,提升训练速度与收敛速度,增加分类效果,较好防止过拟合。

随机失活(Dropout)^[28]使某个神经元的激活值以一定的概率 p 停止工作,降低了网络神经元之间相互复杂的共适应关系,使模型泛化性更强,不太依赖某些局部的特征,从而防止过拟合现象。

指数线性单元^[29](ELU),融合了sigmoid与ReLU,其函数如图3所示,左侧具有软饱和性,右侧具有无饱和性,右侧线性部分可以使ELU缓解梯度消失,左侧非线性部分使ELU对于输入的变化或噪声更具鲁棒性,使神经网络具有更快的收敛速度。




图3 ELU函数

Fig.3 ELU function

2.3 本文实验网络结构

实验网络结构如图4所示,实验将去除全连接层的VGG16网络结构作为U-Net网络的编码器,并在解码路径的每层卷积计算后增加BN,从而达到了增大梯度,提升训练速度与收敛速度,增加分类的效果,防止过拟合。网络的解码路径与其编码路径相对应,使用上采样将特征图像大小扩大至原来两倍,并在上采样计算后,将上采样的计算输出与解码器相对应的输出部分进行串联(Concatenate),最后增加Dropout层,使其不太过于依赖某些局部特征,从而达到防止过拟合的效果,同时采用与其编码路径对应的卷积计算。采用ELU作为所有 3×3 卷积计算的激活函数,加快实验网络的收敛速度。

3 实验与结果分析

3.1 实验数据

实验数据集采用TGRS2017数据集^[25],包含224幅Google Earth影像,影像大小大于 600×600 ,空间分辨率为1.2 m/像素,数据集涵盖城市、郊区和农村地区,且图像背景较为复杂。随机挑选20幅影像作为测试数据集,其余数据被随机分为两部分,其中80%用于训练网络模型,20%用于验证训练的模型,为方便模型训练,将影像规范化为 512×512 大小。为增强训练样本,对训练数据集进行旋转 90° 、 180° 、 270° 和镜像的处理。本文实验模型参数如表1所示。

3.2 实验结果分析

为验证本文的道路提取效果,以及数据扩充对实验的影响,采用总体分类精度和Kappa系数来进行精度验证,评价效果。总体分类精度是正确分类的像元个数除以总像元个数,Kappa系数的计算基




图 4 实验网络结构

Fig.4 Experimental network structure

表 1 实验参数

Table 1 Experimental parameters

参数名称	参数值
学习率	0.000 1
优化器	Adam
损失函数	binary_crossentropy
Batchsize	2
Epochs	35
Dropout(keep_prob)	0.5

于混淆矩阵,其数值一般处于 $[0,1]$,当 Kappa 系数位于 $[0.61,0.80]$,表示该实验结果与真实值具有高度的一致性,当 Kappa 系数位于 $[0.81,1]$,表示该实验结果与真实值几乎完全一致。

3.2.1 数据扩充前后对比实验

U-Net 可以从较小的训练数据集中进行学习,但对于深度学习而言,训练数据集的完整性、准确性与丰富性对实验效果有着较高的影响,丰富且高质量的训练数据可以训练出更好的模型。获取大量的训练数据需要耗费相当大的人力与物力,且某些训练数据获取与制作存在困难,因此需要采用一些方法,对已有的训练数据进行扩充,解决训练数据缺乏的问题,提升模型的泛化性和准确性。其中,对图像采用旋转与镜像的操作,是一种常用的数据扩充方式,扩充后的数据集是同一目标图像在不同角度的视觉表示。

为探究数据集对本实验的影响,本文建立了数

据扩充前后的训练数据集,分别在实验网络中训练模型。实验结果如图 5 所示,总体分类精度与 Kappa 系数如表 2 所示。

表 2 数据扩充前后实验

Table 2 Experiment before and after data expansion

区域	扩充后		未扩充	
	总体分类精度/%	Kappa 系数	总体分类精度/%	Kappa 系数
A	99.13	0.94	98.40	0.89
B	95.32	0.83	93.59	0.76

实验结果表明,数据集扩充后,提取效果有较好的提升。在区域 A 中,将建筑物误分为道路的区域,在数据扩充后,该区域分类正确;区域 B 中,数据扩充前对细小道路的提取效果不佳,数据扩充后,断裂部分减少。综上,数据扩充后,实验精度明显提升,该方法的总体分类精度提升 1.23%,Kappa 系数提升 0.06。由此可见,实验数据的合理扩充对实验效果有着较好的提升,可以提升其网络模型的泛化学习能力。

3.2.2 与其他算法对比实验

为验证实验效果,本文将数据集扩充后,在同等实验条件和数据集下,将其与基于 Encoder-Decoder 网络的遥感影像道路提取方法^[13]和 U-Net 网络^[21]进行对比实验,其对比实验效果如图 6 所示,总体分类精度与 Kappa 系数如表 3 所示。




图5 数据扩充前后实验结果

Fig.5 Experimental results before and after data expansion

表3 不同算法对比实验

Table 3 Comparison of different algorithms

区域	本文		文献[13]		U-Net ^[21]	
	总体分类精度/%	Kappa系数	总体分类精度/%	Kappa系数	总体分类精度/%	Kappa系数
a	98.01	0.91	97.39	0.89	97.16	0.88
b	98.42	0.93	97.84	0.90	96.91	0.87
c	97.97	0.90	97.89	0.90	97.39	0.88
d	97.68	0.91	97.20	0.90	97.53	0.91

实验结果表明,基于Encoder-Decoder网络的遥感影像道路提取方法^[13]的提取结果,区域a~d均存在较多孤立点,区域b存在少量的邻近道路粘连现象,区域c存在断裂道路。U-Net^[21]提取结果的孤立点数量较少,区域b存在邻近道路的粘连与部分细小道路提取效果不佳的现象,区域c道路边缘的提取效果不佳,区域d道路结构信息提取不完整。相比以上两种方法,本文方法提取结果中的孤立点与邻近道路的粘连现象极少,能够较好地提取细小道路,准确地分割道路边缘,更加完整地保存道路的细节信息。

本文所改进方法的总体分类精度在98%左右,Kappa系数在0.9以上,说明该方法提取的道路结果与真实值几乎完全一致。与基于Encoder-Decoder网络的遥感影像道路提取方法^[13]和U-Net^[21]方法相比,总体分类精度分别提升0.44%和0.77%,Kappa系数分别提升0.02和0.03。对比3种算法的提取结果,本文的总体精度和Kappa系数均高于其余两种算法,证明本文方法的提取结果更加可靠,可将其

应用在实际生产工作中。

4 结 语

针对现有算法对高分辨率遥感影像的道路信息提取不完整,且存在漏提、错提、断裂等问题,利用U-Net网络较强的图像分割能力,提出了一种改进U-Net的高分辨率影像道路提取方法。该方法将VGG16作为网络编码结构,并在编码路径中添加BN,解码路径添加Dropout层,选用ELU激活函数,较好地解决了神经网络训练中出现的过拟合问题。实验结果表明,数据集的扩充有助于提高道路提取结果的准确度,具体表现在孤立点与断裂部分的减少;此外,该方法可以通过计算机自主学习道路的复杂抽象特征,避免了传统算法人工确定参数造成的主观影响,进一步提高了道路提取的准确度,较好地解决了错提、漏提与道路断裂等问题。该方法的道路提取平均Kappa系数大于0.9,与其他方法相比,道路的提取结构更加完整。

本文方法存在以下几点不足,首先,对建筑密

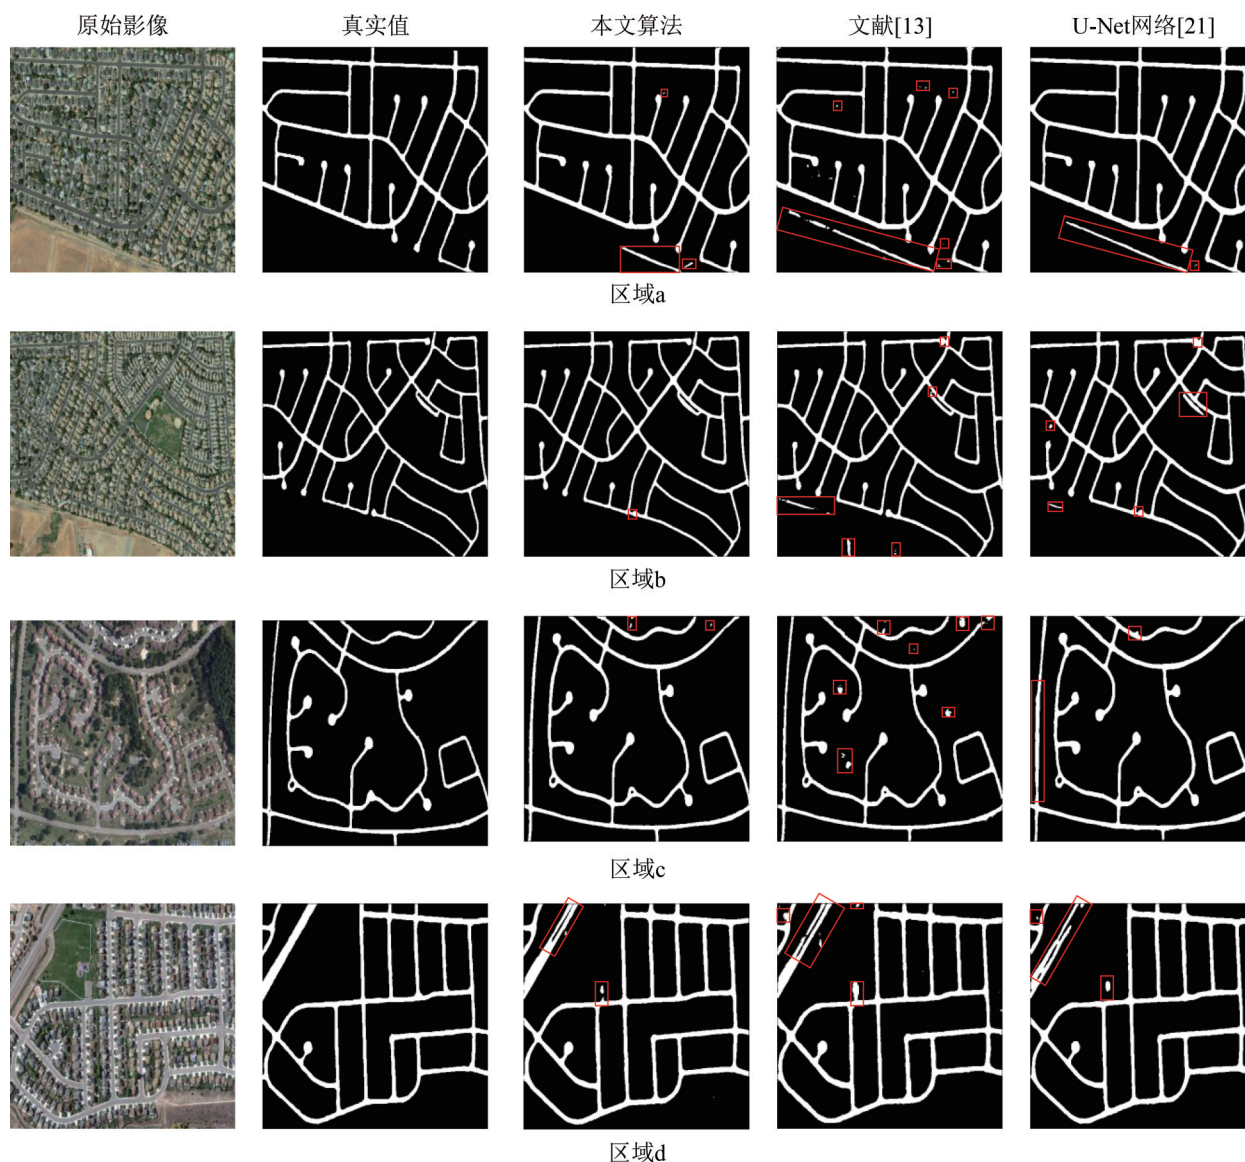


图6 道路对比实验提取结果

Fig.6 Road comparison experiment extraction results

集、阴影及树木遮挡区域的提取效果欠佳;其次,该方法受训练数据集的影响较大,且单一模型提升的精度有限。综上所述,训练数据的有效扩充,探究多模型集成的遥感影像道路提取,将是进一步的研究方向。

参考文献 (References):

- [1] Cheng G, Wang Y, Xu S, *et al.* Automatic Road Detection and Centerline Extraction via Cascaded End-to-End Convolutional Neural Network[J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55(6): 3322-3337. doi: 10.1109/TGRS.2017.2669341.
- [2] Cheng Jianghua, Gao Gui, Ku Xishu, *et al.* Summary of Road Network Extraction Methods for SAR Images [J]. Chinese Journal of Image Graphics, 2013, 18(1): 11-23. [程江华, 高贵, 库锡树, 等. SAR图像道路网提取方法综述[J]. 中国图象图形学报, 2013, 18(1): 11-23.]
- [3] Feng Peng, Gao Feng. Summary of Road Information Extraction Methods in High-Score Remote Sensing Images [J]. Modern Electronic Technology, 2015, 38(17): 53-57. [冯鹏, 高峰. 高分遥感影像中道路信息提取方法综述[J]. 现代电子技术, 2015, 38(17): 53-57.]
- [4] Zhang Yonghong, He Jing, Bingxi, *et al.* A Review of Road Extraction Methods from Remote Sensing Images [J]. Computer Engineering and Applications, 2018, 54(13): 1-10, 51. [张永宏, 何静, 阚希, 等. 遥感图像道路提取方法综述[J]. 计算机工程与应用, 2018, 54(13): 1-10, 51.]
- [5] Gomez R B. Hyperspectral Imaging: A Useful Technology for Transportation Analysis [J]. Optical Engineering, 2002, 41(41): 2137-2143. doi: 10.1109/TGRS.2017.2669341.

- [6] Luo Qingzhou, Yin Qiu, Kuang Dingbo. Research on Road Extraction Method Combining Spectrum and Shape Characteristics [J]. Remote Sensing Technology and Applications, 2007, 22 (3): 339-344.[罗庆洲, 尹球, 匡定波. 光谱与形状特征相结合的道路提取方法研究[J]. 遥感技术与应用, 2007, 22(3):339-344.]
- [7] Cai Hongyue, Yao Guoqing. Optimized Method for Road Extraction from High Resolution Remote Sensing Image based on Watershed Algorithm [J]. Land and Resources Remote Sensing, 2013, 25 (3): 25-29.[蔡红玥, 姚国清. 基于分水岭算法的高分辨率遥感图像道路提取优化方法[J]. 国土资源遥感, 2013, 25(3):25-29.]
- [8] Yu Changhui, Yi Yaohua. Object-based Road Extraction in Remote Sensing Image Using Markov Random Field [J]. Journal of Wuhan University (Information Science Edition), 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.]
- [9] Li M, Stein A, Bijker W, *et al.* Region-based Urban Road Extraction from VHR Satellite Images Using Binary Partition Tree [J]. International Journal of Applied Earth Observation & Geoinformation, 2016, 44: 217-225. doi: j. jag. 2015. 09.005.
- [10] Cao Yungang, Wang Zhipan, Shen Li, *et al.* Fusion of Pixel-based and Object-based Features for Road Centerline Extraction from High-resolution Satellite Imagery[J]. Journal of Surveying and Mapping, 2016, 45 (10): 1231-1240.[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.]
- [11] Das S, Mirmaline 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 & Remote Sensing, 2011, 49(10):3906-3931. doi: 10.1109/TGRS.2011.2136381.
- [12] Liu Xiao, Wang Guanghui, Yang Huachao, *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.]
- [13] He Hao, Wang Shicheng, Yang Dongfang, *et al.* A Road Extraction Method for Remote Sensing Image based on Encoder-decoder Network [J]. Journal of Surveying and Mapping, 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.]
- [14] Kampffmeyer M, Salberg A B, Jenssen R. Semantic Segmentation of Small Objects and Modeling of Uncertainty in Urban Remote Sensing Images Using Deep Convolutional Neural Networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2016: 1-9. doi: 10.1109/CVPRW.2016.90.
- [15] Zhong Z, Li J, Cui W, *et al.* Fully Convolutional Networks for Building and Road Extraction: Preliminary Results [C]// 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). IEEE, 2016: 1591-1594. doi: 10.1109/IGARSS.2016.7729406.
- [16] 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. doi: 10.3390/rs9050498.
- [17] 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, 2016, 55(2): 645-657. doi: 10.1109/TGRS. 2016. 2612821.
- [18] Kestur R, Farooq S, Abdal R, *et al.* UFCN: A Fully Convolutional Neural Network for Road Extraction in RGB Imagery Acquired by Remote Sensing from An Unmanned Aerial Vehicle [J]. Journal of Applied Remote Sensing, 2018, 12(1): 016020. doi: 10.1117/1.JRS.12.016020.
- [19] Zhang Z, Liu Q, Wang Y. Road Extraction by Deep Residual U-net [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(5): 749-753. doi: 10.1109/LGRS.2018.2802944.
- [20] Panboonyuen T, Vateekul P, Jitkajornwanich K, *et al.* An Enhanced Deep Convolutional Encoder-decoder Network for Road Segmentation on Aerial Imagery [C] // International Conference on Computing and Information Technology. Springer, Cham, 2017: 191-201. doi: 10.1007/978-3-319-60663-7_18.
- [21] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation [C]// International Conference on Medical Image Computing & Computer-assisted Intervention, 2015, 9351: 234-241. doi: 10.1007/978-3-319-24574-4_28.
- [22] Wang Yu, Yang Yi, Wang Baoshan, *et al.* Building Segmentation in High Resolution Remote Sensing Image by Deep ResNet [J]. Remote Sensing Technology and Application, 2019, 34(4): 736-747.[王宇, 杨艺, 王宝山, 等. 深度残差神经网络高分辨率遥感图像建筑物分割[J]. 遥感技术与应用, 2019, 34(4):736-747.]
- [23] Cui Gang, Wu Jinsheng, Yu Zhen, *et al.* Comparison Analysis on Wheat Mapping Using Deep Learning Algorithm from Different Satellite Data Source [J]. Remote Sensing Technology and Application, 2019, 34(4): 748-755.[崔刚, 吴金胜, 于镇, 等. 深度学习对不同分辨率影像冬小麦识别的适用性研究[J]. 遥感技术与应用, 2019, 34(4):748-755.]
- [24] Zhao H S, Shi J P, Qi X J, *et al.* Pyramid Scene Parsing Network [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 2881-2890. doi: 10.1109/CVPR.2017.660.
- [25] Cheng G, Zhu F, Xiang S, *et al.* Road Centerline Extraction via Semisupervised Segmentation and Multidirection Nonmaximum Suppression [J]. IEEE Geoscience & Remote Sensing

- Letters, 2017, 13(4): 545-549. doi: 10.1109/LGRS. 2016. 2524025.
- [26] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-scale Image Recognition[J]. arXiv Preprint arXiv:1409.1556, 2014.
- [27] Ioffe S, Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift [J]. arXiv Preprint arXiv:1502.03167, 2015.
- [28] Srivastava N, Hinton G, Krizhevsky A, *et al.* Dropout: A Simple Way to Prevent Neural Networks from Overfitting[J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [29] Clevert Djork-Arné, Unterthiner T, Hochreiter S. Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)[J]. arXiv Preprint arXiv:1511.07289, Computer Science, 2015.

High-resolution Remote Sensing Image Road Extraction Method for Improving U-Net

Wang Zhuo^{1,2,3}, Yan Haowen^{1,2,3}, Lu Xiaomin^{1,2,3}, Feng Tianwen^{4,5}, Li Yazhen^{4,5}

(1.Faculty of Geomatics, Lanzhou Jiaotong University, Lanzhou 730070, China;

2.National-Local Joint Engineering Research Center of Technologies and Application for National Geographic State Monitoring, Lanzhou 730070, China;

3.Gansu Provincial Engineering Laboratory for National Geographic State Monitoring, Lanzhou 730070, China;

4.Northwest Institute of Eco-Environment and Resources, Chinese Academy of Sciences, Lanzhou 730000, China;

5.University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Accurate and efficient extraction of road information based on remote sensing image is a great significance for the establishment and maintenance of basic geographic databases. Due to the complex background information of high-resolution remote sensing images, existing algorithms cannot extract road information very well. U-Net network has good experimental results in image segmentation, but the accuracy of road segmentation results is not good. For this reason, this paper proposes a high-resolution image road extraction method based on improved U-Net network. Firstly, the U-Net-based network structure is designed and implemented. The network uses VGG16 as the network coding structure, which can extract feature semantic information better. Secondly, the use of Batch Normalization and Dropout solves the phenomenon of over-fitting that occurs during the network training process. Finally, the training data is expanded by rotation and mirror transformation, and the ELU activation function is used to improve the network training speed. The experimental results show that the method can extract road information more accurately and efficiently.

Key words: High resolution remote sensing image; Road extraction; U-Net