

基于级联U-Net的遥感影像道路分割和轮廓提取方法

李余, 杨祥立, 张乐, 梁雅麟, 高显, 杨建喜

引用本文

李余, 杨祥立, 张乐, 梁雅麟, 高显, 杨建喜. 基于级联U-Net的遥感影像道路分割和轮廓提取方法[J]. 计算机科学, 2024, 51(3): 174-182.

LI Yu, YANG Xiangli, ZHANG Le, LIANG Yalin, GAO Xian, YANG Jianxi. Combined Road Segmentation and Contour Extraction for Remote Sensing Images Based on Cascaded U-Net [J]. Computer Science, 2024, 51(3): 174-182.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[TMGAT:类型匹配约束的图注意力网络](#)

TMGAT:Graph Attention Network with Type Matching Constraint

计算机科学, 2024, 51(3): 235-243. <https://doi.org/10.11896/jsjcx.221200097>

[基于标签信息融合与多任务学习的中文命名实体识别](#)

Chinese Named Entity Recognition Based on Label Information Fusion and Multi-task Learning

计算机科学, 2024, 51(3): 198-204. <https://doi.org/10.11896/jsjcx.230200114>

[基于双分支串行混合注意力的输电线路缺陷检测深度神经网络模型](#)

Deep Neural Network Model for Transmission Line Defect Detection Based on Dual-branch

Sequential Mixed Attention

计算机科学, 2024, 51(3): 135-140. <https://doi.org/10.11896/jsjcx.230600109>

[基于多空间属性信息融合的序列推荐](#)

Sequential Recommendation Based on Multi-space Attribute Information Fusion

计算机科学, 2024, 51(3): 102-108. <https://doi.org/10.11896/jsjcx.230600078>

[基于注意力-生成对抗网络的任务分析方法研究](#)

Study on Task Analysis Methods Based on Attention-GAN

计算机科学, 2024, 51(3): 63-71. <https://doi.org/10.11896/jsjcx.221100012>

基于级联 U-Net 的遥感影像道路分割和轮廓提取方法

李余¹ 杨祥立¹ 张乐² 梁雅麟¹ 高显¹ 杨建喜¹

1 重庆交通大学信息科学与工程学院 重庆 400074

2 电子科技大学信息与通信工程学院 成都 611731

(leeeeyu@163.com)

摘要 针对基于深度学习的遥感图像道路信息提取模型往往只能输出单任务结果且多任务之间相关性利用不充分的问题,提出了一种基于级联 U-Net 的道路语义分割和轮廓联合检测方法,将道路语义分割后的特征图与原始图像融合后进行道路轮廓的提取,实现道路语义分割和边界轮廓的联合训练。首先使用 U-Net 网络结构提取光学遥感图像丰富的层次化特征,通过级联结构将特征串联融合,分别用于提取道路的语义类别和边界轮廓。其次在每级 U-Net 结构中引入注意力机制模块,进行空间上下文信息和深层次特征提取,改善网络提取过程中出现的细节模糊现象。最后,使用骰子系数和交叉熵误差组成的联合损失函数进行多任务整体训练,实现深度学习模型对遥感图像中道路语义类别和边界轮廓的同时提取。通过在加拿大渥太华城市地区的光学遥感数据集上进行实验,基于级联 U-Net 的道路信息联合提取方法在分割指标上分别获得了 42% 的精确度、58% 的召回率、48.2% 的 F1 分数以及 71.6% 的平均交并比,在道路检测指标上取得了 0.896 的全局最佳阈值(ODS)。结果表明,该模型在满足联合提取道路多任务信息的同时具有更优的检测精度。

关键词: 遥感影像;道路分割;轮廓提取;级联 U-Net;注意力机制

中图分类号 TP753

Combined Road Segmentation and Contour Extraction for Remote Sensing Images Based on Cascaded U-Net

LI Yu¹, YANG Xiangli¹, ZHANG Le², LIANG Yalin¹, GAO Xian¹ and YANG Jianxi¹

1 School of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China

2 School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China

Abstract Aiming at the problem that the deep-learning-based model for road information extraction can only output single-task results and the inadequate use of correlation between multiple tasks, a combined road segmentation and contour extraction method based on cascaded U-Net is proposed, which extracts the road contour after fusing the feature map of road semantic segmentation with the original image. Firstly, the U-Net network structure is used to extract the hierarchical features of optical remote sensing images, and the cascaded U-Net structure is introduced to concatenate the features to extract the pixel-level label and contours of roads respectively. Secondly, the attention mechanism module is added to each stage of U-Net to extract spatial context information and deep level features to improve the detection sensitivity of details. Finally, the joint loss function composed of dice coefficient and cross-entropy error is used for the overall training to extract simultaneously the road semantic segmentation and contour results. On the optical remote sensing dataset of the urban area of Ottawa, Canada, the joint extraction method of road information based on cascaded U-Net achieves 42% precision, 58% recall, 48.2% F1 score and 71.6% mIoU in the segmentation index, and achieves a global optimal threshold(ODS) of 0.896 in the road detection index. The results show that, the model can meet the requirements of joint extraction of road multi-task information and has better detection accuracy.

Keywords Remote sensing image, Road segmentation, Contour extraction, Cascaded U-Net, Attention mechanism

1 引言

研究日益增多。高分辨率卫星影像包含了丰富的地物目标特征,如何从图像中提取有价值的信息成为了研究的热门话题^[1]。道路是重要的交通基础设施和基础地理信息,利用

随着遥感成像系统的快速发展,人们对遥感图像的探索

到稿日期:2022-12-05 返修日期:2023-04-03

基金项目:国家自然科学基金(62101081);重庆市教委科学技术研究项目(KJZD-M202000702, KJQN202100747)

This work was supported by the National Natural Science Foundation of China(62101081) and Science and Technology Research Program of Chongqing Municipal Education Commission(KJZD-M202000702, KJQN202100747).

通信作者:杨建喜(yjx@cqjtu.edu.cn)

对地观测手段从高分辨率遥感影像中提取道路信息,是广大学者正深入研究的课题^[2]。由于遥感影像数据本身的复杂性,以及人工标注耗时繁琐的限制,从海量遥感影像中高效地提取符合应用需求的道路信息,仍然是一个亟待解决的问题。

近年来,借助人工智能、机器学习和图像处理技术,从遥感图像中自动提取出道路信息是一种常用的方法。目前所提出的诸多方法,可以分为传统方法和基于深度学习的方法。传统的道路信息提取方法主要采用模板匹配^[3]、知识驱动^[4]和面向对象方法^[5],对遥感图像中的道路目标进行特征表达,从而进行信息提取。在道路信息提取过程中,传统方法通常会因为建筑物、树木等产生的阴影而出现提取效果不理想的情况。在信息大数据可用性增强以及计算能力日益强大的推动下,深度学习算法在语义分割、计算机视觉等领域取得了突破性的进展,基于深度学习的方法在道路信息提取过程中也被广泛使用^[6-14]。深度学习的多层网络结构能够提取抽象且有表达能力的特征,得到从原始遥感图像到“低-中-高”层抽象的表达,从而具有更好的道路信息提取能力^[15-16]。

基于深度学习的遥感图像道路信息提取主要包括道路路面分割、轮廓提取和中心线提取等。道路分割任务主要是将遥感图像中的道路像素提取出来^[17]。Wang 等^[18]在 U-Net 模型的基础上,添加一个小解码器来形成双解码器结构,能够学习到小型道路信息提取的特征;通过引入扩张卷积注意模块,增加了感受野,提高了小型道路信息提取的可靠性和准确性。Zhang 等^[19]提出用残差结构代替普通卷积单元来构建网络,通过将 U-Net 与 Res-Net 结合使网络更容易训练,道路信息提取结果更准确。Xin 等^[20]把 Dense-U-Net 引入道路分割中,利用密集连接模块连接传统的 U-Net 网络的编码器和解码器,加强了不同特征的融合,可以用于复杂场景中的道路信息提取。为了解决特征的空间分辨率随着网络的加深而降低的问题,Tan 等^[21]引入尺度融合模块融合不同尺度的池化层中的特征,增强模型精确感知道路边缘和形状的能力,提升道路分割的准确性。轮廓检测和中心线提取则是提取单像素宽度的道路边界和中心线^[22-23],通过从道路边缘获得路面分割的结果,从中学习一些有意义的低级特征来获得精细的预测。Xu 等^[24]将道路边缘检测转化为从遥感图像中离线检测顶点和连接线,通过模仿学习训练提出的 iCurb 网络,实现对纽约市遥感影像数据集的道路信息提取。针对线性结构不规则,难以区分中心线位置和相邻位置的问题,Sironi 等^[25]根据回归方法重新定义中心线检测任务。首先训练回归器,以返回在尺度空间中最近中心线的距离,再将其应用于输入图像,最后中心线和相应的尺度对应于回归量的局部最大值。Guo 等^[26]提出了一种基于自监督学习框架的遥感图像道路中心线自动提取方法,从而避免了人工手动选择训练样本和其他优化步骤带来的干扰。目前,基于深度学习的道路信息提取研究,大多数都是针对单个特定任务的。因此,如何利用深度学习模型同时提取遥感图像中的道路语义类别和边界轮廓值得进一步研究。

多任务学习^[27]通过网络模型并行学习,可以联合输出不同应用领域的实验结果。在多任务学习中不同任务之间具有相似性或相关性时,模型任务之间的信息共享可能是有利的。遥感图像道路信息提取中,道路路面分割和轮廓检测任务在

一定程度上存在着相互依赖的关系。Heidler 等^[28]通过将语义分割框架和边缘检测框架自然组合到一个新的深度学习模型中,同时完成对南极海岸线的分割以及边缘联合检测,在边缘检测任务和分割任务同时输出的情况下,可以改善分割结果,但对于连续且大面积的遮挡难以检测。对于道路信息多任务提取而言,道路路面提取和道路轮廓提取任务在一定程度上是相互依赖的。道路表面和轮廓均具有明显的线性几何特征,在拓扑结构中也相互连接,道路轮廓位于道路边缘部分。因此,在遥感图像道路分割和轮廓提取两个子任务中,道路表面提取结果对轮廓提取起着决定性的作用,道路轮廓又增强了道路的典型线性特征。

针对上述特性,Cheng 等^[29]最先提出了一种基于 SegNet 的端到端卷积神经网络,实现了同时进行道路检测和中心线提取。为了解决道路中心线提取不连续的问题,Shao 等^[30]将从道路中提取出的特征作为中心线提取的条件,使用两个任务之间的信息传递和参数共享来提出一种基于双任务的端到端的卷积神经网络。Liu 等^[31]将道路表面分割、边缘检测和中心线提取三者结合起来,提出了一个多任务端到端的卷积神经网络 RoadNet。为了提高道路信息的连通性,Lu 等^[32]提出了一种级联多任务道路信息提取框架,用于同时提取道路表面、中心线和边缘,并使用硬样本挖掘损失函数来更多地关注硬样本,进一步增强了道路完整性。针对道路分割和轮廓提取任务,Ghandorb 等^[33]使用分割掩码生成道路边缘信息,在编码器中引入注意力机制加强分割结果对边缘检测的影响,并使用加权交叉熵和 Tversky 项作为损失函数处理高度不平衡的数据集,从而更高效地结合两个任务。

目前大多数基于深度学习的遥感图像道路信息提取方法都是单任务模型,并且现有的道路分割和轮廓联合提取方法未能充分利用两个任务之间的共性关系。针对以上问题,本文提出了一种基于级联 U-Net 模型,级联结构通过将路面和轮廓在图像中的几何、光谱和拓扑特征进行融合串联,将语义分割得到的特征图与原图进行融合并传送到道路轮廓检测网络中来提升道路轮廓的检测精度。同时,由于优化过程中级联 U-Net 同时更新道路分割和轮廓提取两部分网络参数,在很大程度上改善了分割的结果。两个任务之间的信息传输和特征共享,也能够降低训练过程中参数过拟合的风险。

本文的主要工作如下:

- 1) 将用于语义分割和轮廓提取的 U-Net 结构使用级联结构串联起来,通过语义分割的特征来提升轮廓提取的效果。
- 2) 在每个 U-Net 结构中引入卷积注意力模块,结合空间和通道注意力机制加强道路信息提取的连通性,改善网络提取过程中出现的细节模糊问题。
- 3) 采用骰子系数和交叉熵误差组成的联合损失函数进行端到端的模型参数学习,处理数据不平衡问题。

2 模型方法

本文框架以级联方式执行道路分割和道路轮廓检测任务,级联 U-Net 整体结构如图 1 所示。该框架以 U-Net 作为道路信息提取任务的基本网络,并在 U-Net 单元中添加了卷积注意力模块,用来处理提取过程中出现的细节模糊问题;

采用端到端的学习方式训练模型参数,进行道路表面分割和

道路轮廓检测的联合提取。

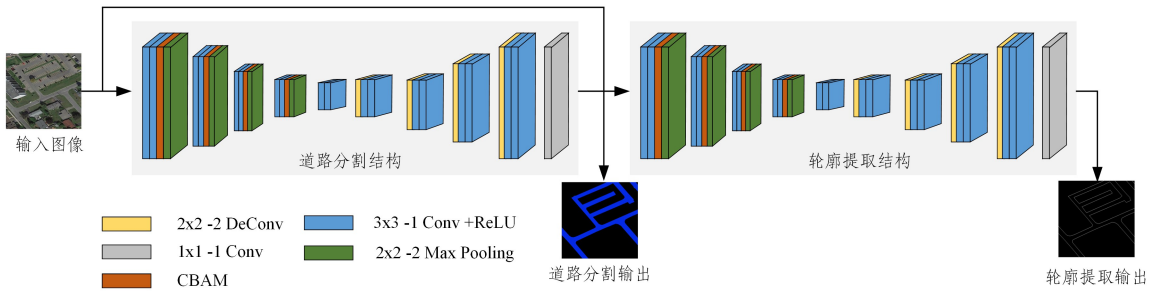


图1 整体网络框架图

Fig. 1 Overall network framework

2.1 U-Net 网络结构

U-Net 由 Ronneberger 等^[34]于 2015 年提出,其网络结构简洁,且具有良好的分割效果,被广泛应用于医学图像处理和其他图像解析任务中。在 U-Net 网络架构设计中,其网络呈高度对称,主要由编码器和解码器两部分组成。编码器部分是基本的卷积网络,包含了卷积层、池化层和激活函数,其网络结构主要是以去除了全连接层的 VGG16 网络结构为基础,通过卷积操作和下采样操作对输入的图像进行特征提取,从而提取出合适的低层信息特征图。解码器部分有上采样、跳跃连接和卷积层,通过上采样操作,使用跳跃连接,通过将低级别信息传递到更高级别上来获取更加精细的细节。将解码器和编码器中具有相同分辨率的特征图进行特征融合,使图像的分辨率在进行还原过程中能够更好地恢复目标的细节,最后经过一个 1×1 的卷积层和激活函数之后得到道路与背景的二分类结果。

级联框架包含两个 U-Net 网络结构,分别用于道路分割和轮廓提取。两个用于不同任务的 U-Net 网络具有相同的参数结构,每个基本的 U-Net 网络结构如图 2 所示,网络结构中使用到的基本模块如下。

卷积层(Convolutional Layer, Conv):计算连接到前一层局部区域的神经元的输出,每个输出通过其权重与前一层中连接到的区域之间进行逐像素相乘,然后将结果相加计算。

本文中用的是 3×3 Conv 层。

批处理层(Batch Normalization, BN):为了避免梯度消失并减少内部变量偏移,BN 层把每个小批次输入数据的平均分布归一化为零均值和单位方差的高斯分布,以提升深度神经网络的学习效率。

修正线性单元层(Rectified Linear Unit, ReLU):激活函数将除正值外的数据均设置为零,正值保持原有数据不变。使用 ReLU 函数训练卷积网络比使用 tanh 或 sigmoid 函数的效率高数倍。

池化层(Pooling):池化层在编码器部分进行下采样的过程中,在空间维度上操作,生成缩小的特征图。本文实验使用 2×2 大小的最大池化层。

反卷积层(Deconvolutional Layer, DConv):主要通过多个学习滤波器的卷积式操作来加密这些稀疏激活。与 Conv 层相反,DConv 层将单个输入激活并与多个输出连接起来。

2.2 卷积注意力模块

为了更进一步关注道路的细节信息,本文网络在编码器中添加了卷积注意力模块 Convolutional Block Attention Module, CBAM)。如图 2 所示,在网络进行下采样的过程中,每经过两个卷积之后,嵌入 CBAM 模块,分别从通道和空间维度筛选出道路特征,抑制非道路特征,增加道路特征的有效表达能力。

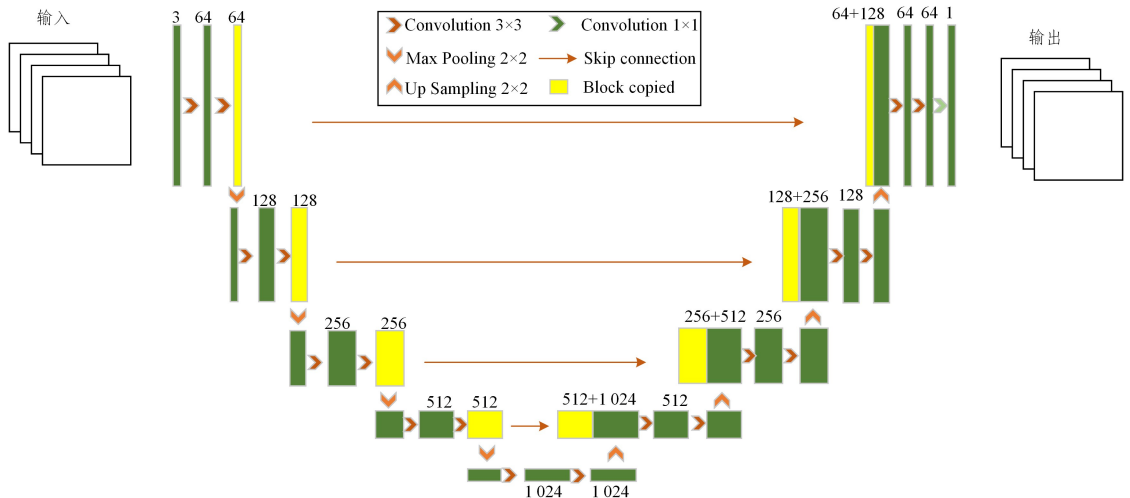


图2 U-Net 网络结构图

Fig. 2 U-Net structure

CBAM 是一种轻量化的注意力模块,能够有效地强调或压缩提取中间特征^[35]。CBAM 模块主要包括通道注意力模块和空间注意力模块^[36]这两部分,其网络结构如图 3 所示。




图 3 卷积注意力模块示意图

Fig. 3 Convolutional attention module

通道注意力模块关注的是输入图像中“什么”是有意义的,通过压缩输入特征的空间维度,聚合空间信息,可以有效地计算通道注意力,其示意图如图 4 所示。通道注意力首先对输入特征图 F 进行最大值池化和平均值池化,之后得到两个描述符 $AvgPool(F)$ 和 $MaxPool(F)$,将这两个描述符分别传输到一个由多层感知机 (Multi-layer Perceptron, MLP) 组成的共享网络中,压缩输入特征图的空间维数,然后经过两个通道,将 MLP 输出的特征逐元素相乘以加权每个通道的特征,最后经过激活函数操作,生成最终的通道注意力权重 M_c ,并将其作为空间注意力子模块的输入特征。




图 4 通道注意力模块示意图

Fig. 4 Channel attention module

通道注意力机制的计算式如下所示:

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) \\ = \sigma(W_1(W_0(F_{avg}^s)) + W_1(W_0(F_{max}^s))) \quad (1)$$

其中, F_{avg}^s 和 F_{max}^s 分别代表通道注意力模块中的平均值池化特征和最大值池化特征; $M_c(F)$ 表示获得的通道注意力图; MLP 表示共享网络中的多层感知机, W_0 和 W_1 分别表示共享 MLP 的权重,在 ReLU 激活函数后面的是 W_0 。

空间注意力模块利用特征之间的关系生成空间特征图,主要以在“哪里”作为信息部分,用于补充通道注意力的不足,其示意图如图 5 所示。空间注意力模块以通道注意力模块输出的特征图 F' 作为该模块的输入,首先在通道维度上分别进行最大池化和平均池化,对通道进行压缩,将它们串联起来生成有效的特征描述符;再通过一个 7×7 大小的卷积核进行卷积操作,将特征图降维至一个通道;然后经过 Sigmoid 激活函数生成空间注意力特征;最后将该特征图和该模块的输入特征相乘,生成最终的特征图。

空间注意力机制的计算式如下所示:

$$M_s(F) = \sigma(f^{7 \times 7}(AvgPool(F); MaxPool(F))) \\ = \sigma(f^{7 \times 7}(F_{avg}^s; F_{max}^s)) \quad (2)$$

其中, F_{avg}^s 大小为 $1 \times H \times W$, F_{max}^s 大小为 $1 \times H \times W$, σ 表示 Sigmoid 函数, $f^{7 \times 7}$ 表示滤波器大小为 7×7 的卷积运算。




图 5 空间注意力模块示意图

Fig. 5 Spatial attention module

2.3 级联 U-Net 结构

在进行多任务训练的过程中,当学习的任务具有相似或相关特性时,模型内的信息共享对于多任务的结果来说是十分有利的。道路表面分割和道路轮廓检测的任务在一定程度上是相关联的,道路分割的结果在边界检测中起着决定性的作用,而道路轮廓检测又增强了道路本身所具有的线性特征。因此,将道路分割和轮廓检测联合起来进行多任务学习是有益的,并且通过两个任务之间的信息传输和相互的联系,在使用较小的训练样本上,可以降低过拟合的风险。

为了更好地从对地观测数据中提取复杂场景中的道路表面和道路轮廓,本文基于多任务学习的概念,以 U-Net 为基础,将路面提取和道路轮廓检测看作一个二分类任务,提出了一种新的双任务端到端深度学习网络——级联 U-Net 网络,其结构如图 1 所示。该网络主要由两部分组成,即用于道路表面提取的语义分割网络和道路轮廓提取的边缘检测网络。

该网络中的道路语义分割网络由编码器和解码器两部分组成。编码器部分,在前文提出的 U-Net 网络结构的基础上加入了 CBAM 注意力模块,使用通道注意力和空间注意力来进行有效特征(即道路信息)的筛选,抑制无关特征,增强模型的表达能力,提高网络的提取精度。CBAM 模块是一个可以在网络中即时即用的轻量级模块,因此本文在构建好的 U-Net 网络模型中,在前 4 个下采样中每次经过第二个卷积层操作后嵌入 CBAM 模块。特征图经过最后一次下采样之后进入解码器部分。在解码器部分主要进行上采样操作,来恢复特征维度,并且将在编码器中的道路浅层信息和深层信息通过拼接的方式融合,在保留了更多的道路位置信息的同时,能够更高效地恢复特征。最后特征图经过一个 1×1 的卷积层后输出当前的结果。

道路边界轮廓检测使用和道路语义分割相同的网络,通过级联的方式将这两个模型连接起来,而边界轮廓检测将网络输入原图和进行道路分割之后得到的分割特征图进行组合一起传入轮廓检测的网络中进行训练。在进行道路边界检测时,如果提供了分割信息,那么道路边框检测就会变得相对容易,同时也减少了使用大型神经网络进行轮廓检测的需求。

2.4 损失函数

在网络训练过程中,正确处理不平衡数据极为重要,尤其是在道路信息提取的情况下,图像中道路相比背景只占有较少的区域。由于道路分割和轮廓检测均属于二分类问题,且属于语义分割问题的范畴,因此在本文中道路语义分割和轮廓检测使用联合的损失函数。

二进制交叉熵损失函数(Binary Cross Entropy)广泛应用于像素级分割任务中,例如基于 U-Net 的医学图像分割^[35]。但当目标的像素数远远小于背景当中的像素数时,它具有

误导模型严重偏向背景的优点,而遥感影像中的道路相对于背景来说只占小部分,而骰子系数又是一种集合相似度的度量函数。因此,本文将骰子系数(Dice coefficient, Dice)和二分类交叉熵(Binary Cross Entropy, BCE)相结合组成一个联合损失函数,在训练过程中将其用于评估模型预测值和真值之间的区别。损失函数的值越小,模型的效果越好。其中,二分类交叉熵损失函数的计算式如下:

$$L_{BCE} = -\frac{1}{m} \sum_{i=1}^m [y_i \log_2 \hat{y}_i + (1-y_i) \log_2 (1-\hat{y}_i)] \quad (3)$$

其中, y_i 为像素真实值, \hat{y}_i 为像素预测值, m 为类别数。

骰子系数可以用于计算分割图和真实图之间的相似度。骰子系数主要由基于预测和基本真值的真阳性(TP)、假阳性(FP)和假阴性(FN)确定,计算式如下:

$$L_{Dice} = \frac{2TP}{2TP+FP+FN} \quad (4)$$

最后在给定输入图像 Y_i 和相关的地面真值映射 G_i 后,将联合损失函数用于网络学习。因此,联合损失函数的计算式为:

$$L = \frac{1}{N} \sum_{i=1}^N (L_{BCE}(F(Y_i), G_i) + 1 - L_{Dice}(F(Y_i), G_i)) \quad (5)$$

3 实验

3.1 数据集介绍

本文所使用的数据集以加拿大渥太华地区的几个典型城市道路作为研究区域,采用人工标记数据的方法,评估遥感影像道路信息提取算法的性能^[32]。该数据集图像的空间分辨率为 0.21m,覆盖了 20 个大小约为 8 km² 的区域,数据集图像包括道路原始图像以及已标注道路表面与道路边缘。图 6(a)为任意选取的一张光学遥感图像,道路附近有树木和建筑物引起的阴影和遮挡,导致道路中宽度范围较小的道路信息提取更加困难;图 6(b)为道路分割标签,其中道路表面用蓝色像素标记;图 6(c)为道路边缘标签,道路边缘用白色像素标记。在进行数据预处理时,将 20 个区域按照 7:2:1 的比例分为训练集、测试集和验证集,并将每个区域的图片按照相同规则裁剪成 512×512 大小的样本,裁剪后去掉不符合要求的图片后,数据集包含 6 125 张遥感图像和对应的分割标签、边缘标签。




图 6 训练数据集标记示意图(电子版为彩图)

Fig. 6 Schematic diagram of training data set marking

3.2 网络参数设置

本文使用 Windows11 操作系统、Pytorch1.10 深度学习框架,CPU 配置为 Intel Core i5-12400F, GPU 为 GeForce RTX 3060。在网络训练过程中,使用 Adam 作为模型训练时的优化器;初始学习率为 5×10^{-4} ,每 20 个 epoch 衰减 0.1

倍,共 100 个 epoch。

3.3 评价指标

图像语义分割一般选用精确率、召回率、F1 分数和平均交并比(mean Intersection over Union, mIoU)作为评价算法性能指标^[37]。在道路信息提取过程中,精确率(Precision)表示正确预测道路像素在所有被预测为道路的样本中的比例;召回率(Recall)表示正确预测的道路像素在所有真实目标像素中的比例;F1 分数(F1-score)是一个综合值,可以一定程度上综合反映 Recall 和 Precision 的性能;平均交并比主要计算真实值集合和预测值集合的交并比。指标具体计算方法如下:

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

$$F1\text{-score} = \frac{2 * Precision * recall}{Precision + recall} \quad (8)$$

$$mIoU = \frac{1}{C} \sum_{x=1}^C \frac{TP(x)}{TP(x)+FP(x)+FN(x)} \quad (9)$$

其中, C 为类别数, TP 表示预测正确的道路像素, FP 表示将背景像素预测为道路的像素, FN 表示将道路像素预测为背景的像素。

道路轮廓提取的准确性在一定程度上依赖于图像分割的好坏。一般来说,图像分割越准确,道路轮廓的提取效果越好。如果图像分割效果情况不佳,则相应的轮廓检测可能就达不到理想的效果。道路轮廓检测的评价指标通常使用全局最佳(Optimal Dataset Scale, ODS)和单图最佳(Optimal Image Scale, OIS)^[38]。ODS 表示所有图片使用一个固定阈值使得整个图像处于最佳的结果;OIS 表示每一张图片单独使用一个阈值使得当前图为最佳阈值的结果。

3.4 结果分析

本次实验基于 U-Net 网络模型,为了验证该方法在高分辨率遥感影像道路信息提取上的效果,将其与 CasNet^[30], RoadNet^[32] 和 SegNet^[39] 算法进行对比。另外,通过与未做改进的 U-Net 方法进行比较来进行消融分析。最终的道路分割和轮廓提取的部分预测结果如图 7 和图 8 所示,从左到右依次为输入网络的遥感图像原图、经过相应处理后的标签图、使用本文网络提取的道路结果图、使用 CasNet 模型提取的道路结果图以及 RoadNet 模型提取的道路结果图、U-Net 模型提取的道路结果图、SegNet 模型提取的道路结果图。为了更好地比较提取性能,所有网络在训练和测试中的环境和参数设置相同,且各网络输出的预测结果图的尺寸和输入图的尺寸相同。

为了直观地比较几种对比算法的提取结果,图 7 选取了几张具有代表性的遥感图像和道路分割结果进行分析。在第一行图像中,当道路中间有两棵较大的树遮挡了道路时,人工标注能够推断出遮挡区域应为道路信息。但在使用模型训练的过程中,只能根据上下文信息进行判断,并不能依靠经验来识别出道路。分析可知,除了级联 U-Net 网络能够基本完整地识别出道路的完整性,其他网络的结果均出现了一定程度的断点和模糊现象。CasNet 方法直接忽略掉遮挡情况下的区域,其余几种网络或多或少都存在缺陷。本文在级联

U-Net 网络中引入了卷积注意力模块,只有在双重遮挡的情况下无法连续地分割出道路,其余情况下均能完整地将道路分割出来。综合观察数据集中的分割结果可以看到,所提出的级联 U-Net 网络在有阴影遮挡和道路上有汽车等其他物体占用道路的情况下,相比其他几种算法具有更好的连通性。

在进行道路轮廓检测的过程中,道路分割网络模型对轮廓检测具有较强的主导性,分割效果越好,相应的轮廓检测结果就越准确。为了验证本文方法在道路边界检测上的效果,将其与另外几种对比网络模型进行对比,最终的道路轮廓检测结果如图 8 所示。




图 7 几种道路信息提取方法的分割结果对比

Fig. 7 Comparison of segmentation results of several road extraction methods




图 8 几种道路信息提取方法的轮廓结果对比

Fig. 8 Comparison of contour results of several road extraction methods

可以看出,SegNet 算法提取出的道路轮廓更接近于真实标签,但几种对比网络均不能将道路被遮挡区域和空旷区域的边缘信息检测出来。本文方法在级联 U-Net 的基础上添加了 CBAM 注意力机制,能够有效优化道路边缘细节,在

一定程度上检测出阴影遮挡和道路空情况下的道路边缘,且道路轮廓提取完整。如图 8 第三行图片中,道路两侧为停车位,RoadNet 和 U-Net 直接将车位间隔检测出来,网络提取出的道路轮廓就会呈现出断点的情况,失去了道路原本连续的

特征,而级联 U-Net 提取出的轮廓更加连贯。实验证明了级联 U-Net 联合信息提取方法通过特征的串联,相比其他方法能够更加有效地提取出道路的轮廓。

本文基于上文所提到的语义分割和道路轮廓评价指标,计算了不同方法的道路信息提取结果并进行定量分析,如表 1 所列。分析得知,本文方法在道路分割 mIoU 上达到了 71.6%,相较于 CasNet, SegNet 和 RoadNet 都有大幅提升。在其他各项指标上,本文方法也表现良好,在数值上均高于对比模型。在轮廓检测方面,本文提出的添加了 CBAM 模块的级联 U-Net 网络在 OIS 和 ODS 上均领先于其他方法,表明了本文提出的模型在道路轮廓检测上具有较好的效果。为了更直观地感受边框检测的变化趋势,本文使用了 PR 曲线来表示文中轮廓检测在不同阈值下精确率和召回率的平衡情况,如图 9 所示,随着召回率的增加,精确度逐渐降低,当召回率和精确率均为 0.9 时,精确率和召回率之间取得了最好的一个平衡。总体来看,使用了 CBAM 模块的级联 U-Net 网络对于道路分割的精确性和道路轮廓的完整性具有一定的作用,同时在提取精度上也有明显的提升,证明了本文所提方法在多任务道路信息提取中的可行性和有效性。

表 1 不同方法的性能指标对比

Methods	mIoU/%	Precision/%	Recall/%	F1-score/%	OIS	ODS
CasNet	59.4	26.6	44.8	33.4	0.830	0.844
Roadnet	58.3	24.0	40.6	30.1	0.807	0.821
SegNet	59.3	25.8	45.8	33.0	0.849	0.851
U-Net	62.0	32.8	57.0	41.8	0.838	0.834
Proposed	71.6	42.0	58.6	48.2	0.896	0.896




图 9 本文网络的边框检测 PR 曲线图

Fig. 9 PR curve of border detection

为了更进一步分析卷积注意力模块的作用,设计了一组消融实验,将本文提出的添加了 CBAM 模块的级联 U-Net 网络和基于级联 U-Net 的网络进行对比,道路分割结果如图 7 最后两列所示,道路轮廓检测结果如图 8 最后两列所示,其具体定量分析的结果如表 1 中第四行所列。可以看出,本文方法在道路分割和轮廓检测这两个任务上,对道路的提取结果均比基于级联 U-Net 网络的结果更好;在道路表面分割上,本文网络能够完整地识别道路信息,且相应的轮廓检测也比较完整,能够表述出道路原有的特征。在没有添加 CBAM 模块的级联 U-Net 网络中,其 mIoU 值, OIS 值和 ODS 值分别为 62.0%, 0.838 和 0.834,均低于本文提出的添加了 CBAM 模块的级联 U-Net 网络(mIoU, OIS 和 ODS 分别为 71.6%,

0.896 和 0.896),说明了 CBAM 模块在处理细节问题上具有较好的作用。

为了验证本文模型中联合损失函数对实验中数据不平衡的影响,使用添加了 CBAM 模块的级联 U-Net 作为基准,选择仅使用二进制交叉熵损失函数(在表 2 中用 BCE 表示)和仅使用骰子系数损失函数(在表 2 中用 Dice 表示)来进行消融实验。实验结果如表 2 所列,使用交叉熵损失函数获得的 mIoU 值为 64.8%,使用骰子系数损失函数得到的 mIoU 值为 63.9%,而使用联合损失函数获得的 mIoU 值比使用交叉熵损失函数和骰子系数损失函数分别提高了 6.8% 和 7.7%,达到了 71.6%。在道路检测的 ODS 上也相应提升了 0.044 和 0.066。从评价指标上可以看出,在遥感图像道路信息联合提取中,本文使用的联合损失函数对于处理数据不平衡问题具有较好的效果。

表 2 消融实验结果对比

Table 2 Comparison of ablation experiment results

Methods	mIoU/%	Precision/%	Recall/%	F1-score/%	OIS	ODS
BCE	64.8	37.5	44.4	40.0	0.846	0.852
Dice	63.9	35.8	44.2	39.6	0.835	0.830
BCE+Dice	71.6	42.0	58.6	48.2	0.896	0.896

结束语 本文提出了一种基于级联 U-Net 的遥感影像道路分割和轮廓联合检测方法来提取道路信息。该模型以 U-Net 为基础,通过级联网络同时完成道路分割和轮廓检测这两项任务,使两者进行整体训练;同时,为了解决道路信息在提取过程中出现的模糊问题,在 U-Net 单元中添加了注意力机制,使得道路分割更加精确,道路轮廓提取的结果更加完整,通过消融实验证明了在遥感影像道路信息提取过程中使用联合损失函数能够更加有效地提取出道路信息。在某种程度上,本文模型在有树木等物体遮挡的情况下能够提取出完整准确的道路信息,但对于连续大规模物体遮挡道路的情况,本文模型还是不能较好地分割道路和进行轮廓检测,无法保证道路完整的连通性。这也是我们接下来需要重点研究的内容,通过融合高级语义信息来精准定位位于大面积遮挡区域下的道路,提取出精确度更高、连通性完整的道路信息。


参考文献

- [1] LI D R, TONG Q X, LI R X, et al. Current issues in high-resolution Earth observation technology [J]. Science China Earth Science, 2012, 55: 1043-1051.
- [2] DAI J G, WANG Y, DU Y, et al. Development and prospect of road extraction method for optical remote sensing image [J]. Journal of Remote Sensing (Chinese), 2020, 24(7): 804-823.
- [3] MENG F, FANG S H. Quasi-automatic extraction of zonal roads from remote sensing images using template matching and BSnake model [J]. Geomatics and Information Science of Wuhan University, 2012, 37(1): 39-42.
- [4] SCHUBER H, VAN DE GRONDE J J, ROERDINK J B T M. Efficient computation of greyscale path openings [J]. Mathe-

- mathematical Morphology Theory and Applications, 2016, 1: 189-202.
- [5] LI Q, ZHANG J F, NIU R Q. Damaged road extraction from post-seismic remote sensing images based on GIS and object-oriented method[J]. *Bulletin of Surveying and Mapping*, 2015, 4: 78-81.
- [6] ALSHEHHI R, MARPU P R, WOON W L, et al. Simultaneous extraction of roads and buildings in remote sensing imagery with convolutional neural networks [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 130: 139-149.
- [7] LIU X, WANG G H, YANG H, et al. Road extraction from remote sensing image based on full convolutional network [J]. *Remote Sensing Information*, 2018, 33(1): 69-75.
- [8] ZHANG Y H, XIA G H, KAN X, et al. Road extraction from multi-source high resolution remote sensing image based on fully convolution network [J]. *Journal of Computer Applications*, 2018, 38(7): 2070-2075.
- [9] YUAN M, LIU Z, WANG F. Using the wide-range attention U-Net for road segmentation [J]. *Remote Sensing Letters*, 2019, 10(5): 506-515.
- [10] LAN M, ZHANG Y, ZHANG L, et al. Global context based automatic road segmentation via dilated convolutional neural network [J]. *Information Sciences*, 2020, 535: 156-171.
- [11] CUI L, ZHANG P, CHE J. Overview of Deep Neural Network Based Classification Algorithms for Remote Sensing Image[J]. *Computer Science*, 2018, 45(S1): 50-53.
- [12] LUO L, WANG J X, CHEN S B, et al. BDTNet: Road extraction by Bi-Direction transformer from remote sensing images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [13] LI J, MENG Y, DORJEE D, et al. Automatic road extraction from remote sensing imagery using ensemble learning and post-processing[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 10535-10547.
- [14] YIN W, QIAN M, WANG L, et al. Road extraction from satellite images with iterative cross-task feature enhancement[J]. *Neurocomputing*, 2022, 506: 300-310.
- [15] ZHU X, TUIA D, MOU L, et al. Deep learning in remote sensing [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2017, 4(4): 8-36.
- [16] TONG X Y, XIA G S, ZHONG Y, et al. Exploiting deep features for remote sensing image retrieval: a systematic investigation [J]. *IEEE Transaction on Big Data*, 2019, 6(3): 507-521.
- [17] MNH V, HINTON G E. Learning to detect roads in high-resolution aerial images[C]// *European Conference on Computer Vision*. Berlin, Heidelberg: Springer, 2010: 210-223.
- [18] WANG Y, PENG Y, LI W, et al. DDU-Net: dual-decoder-U-Net for road extraction using high-resolution remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-12.
- [19] ZHANG Z X, LIU Q J, WANG Y H. Road extraction by deep residual U-Net[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(5): 749-753.
- [20] XIN J, ZHANG X C, ZHANG Z Q, et al. Road extraction of high resolution remote sensing images derived from Dense U-Net[J]. *Remote Sensing*, 2019, 21(11): 2499.
- [21] TAN X W, XIAO Z F, WAN Q, et al. Scale sensitive neural network for road segmentation in high-resolution remote sensing images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(3): 533-537.
- [22] LI X, ZHANG S, PAN X, et al. Straight road edge detection from high-resolution remote sensing images based on the ridgelet transform with the revised parallel-beam Radon transform [J]. *International Journal of Remote Sensing*, 2010, 31(19): 5041-5059.
- [23] HUANG X, ZHANG L P. Road centreline extraction from high-resolution imagery based on multiscale structural features and support vector machines [J]. *International Journal of Remote Sensing*, 2009, 30(8): 1977-1987.
- [24] XU Z H, SUN Y X, LIU M. iCurb: imitation learning-based detection of road curbs using aerial images for autonomous driving [J]. *IEEE Robotics and Automation Letters*, 2021, 6(2): 1097-1104.
- [25] SIRONI A, TURETKEN E, LEPETIT V, et al. Multiscale centerline detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(7): 1327-1341.
- [26] GUO Q, WANG Z P. A self-supervised learning framework for road centerline extraction from high-resolution remote sensing images [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 4451-446.
- [27] ZHANG Y, YANG Q. A Survey on Multi-Task Learning [J]. *National Science Review*, 2018, 5(1): 30-43.
- [28] HEIDLER K, MOU L C, BAUMHOER C. HED-UNet: combined segmentation and edge detection for monitoring the antarctic coastline [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 4300514.
- [29] CHENG G L, WANG Y, XU S B, et al. Automatic road detection and centerline extraction via cascaded end-to-end convolutional neural network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(6): 3322-3337.
- [30] SHAO Z F, ZHOU Z F, HUANG X, et al. MRENet: Simultaneous extraction of road surface and road centerline in complex urban scenes from very high-resolution images[J]. *Remote Sensing*, 2021, 13(2): 239.
- [31] LIU Y H, YAO J, LU X H, et al. RoadNet: learning to comprehensively analyze road networks in complex urban scenes from high-resolution remotely sensed images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 57(4): 2043-2056.
- [32] LU X Y, ZHONG Y F, ZHENG Z, et al. Cascaded multi-task road extraction network for road surface, centerline, and edge extraction [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5621414.
- [33] GHANDORH H, BOULILA W, MASOOS S, et al. Semantic segmentation and edge detection—approach to road detection in very high resolution satellite images[J]. *Remote Sensing*, 2022, 14(3): 613.

- [34] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]// International Conference on Medical Image Computing and Computer Assisted Intervention. Munich, Germany, 2015: 234-241.
- [35] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision. Munich, Germany, 2018: 3-19.
- [36] SHAO S, XIAO L, LIN L, et al. Road extraction convolutional neural network with embedded attention mechanism for remote sensing imagery[J]. Remote Sensing, 2022, 14(9): 2061.
- [37] EVERINGHAM M, ALI ESLAMI S M, VAN GOOL L, et al. The PASCAL visual object classes challenge: a retrospective [J]. International Journal of Computer Vision, 2015, 111(1): 98-136.
- [38] LIU Y, CHENG M M, HU X W, et al. Richer convolutional features for edge detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 41(8): 1939-1946.
- [39] BADRINARAYANAN V, KENDALL A, CIPOLLA R. Seg-

Net: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.



LI Yu, born in 1997, postgraduate. His main research interest is remote sensing image analysis and application.



YANG Jianxi, born in 1977, Ph.D, professor, Ph. D supervisor, is a senior member of CCF(No. 68607S). His main research interests include bridge health monitoring and transport infrastructure monitoring.

(责任编辑: 何杨)

CCF 表彰 2023 年度 CSP 优秀单位

为了进一步推进 CSP 认证考试,鼓励更多学生参与 CSP,提高编程能力和计算机素养,CCF 决定从 2020 年开始,由 CSP 认证委员会提名,CCF 秘书长批准,每年对认证点高校进行年度评审。根据各学校的组织参加人数情况(零分人数除外且超过 200 人)和全年排名前十学生成绩总分排名,由高到低,CCF 分别评选出排名前十的年度 CCF CSP“组织优秀单位”和年度“成绩优秀单位”,以表彰他们为 CCF CSP 认证工作做出的重要贡献。

2023 年度共计 31902 人次参加了 CSP 认证考试,目前 CCF 已在全国授权设立了 196 个 CSP 认证点,至今已有 212339 人次参加考试。根据 2023 年各高校认证点全年参与情况,CCF 评选出 2023 年度 CCF CSP“组织优秀单位”和“成绩优秀单位”,获奖名单如下:

组织优秀单位(按人数由高到低排序,不含 0 分人数):

华中科技大学、山东大学、湖南大学、长沙理工大学、南京航空航天大学、西南科技大学、湖北工业大学、中国矿业大学、安徽大学、西安电子科技大学

成绩优秀单位(按分数由高到低排序):

清华大学、中山大学、山东大学、华中科技大学、北京邮电大学、武汉大学、四川大学、西安交通大学、南京航空航天大学、上海交通大学

2024 年 CCF CSP 认证将举办 4 次,考试时间分别为 3 月 31 日、6 月 2 日、9 月 22 日和 12 月 8 日,考前 1 个月左右将开启报名工作。