

基于密集空洞金字塔的 SAR 多尺度道路检测*

张 慧¹ 牟立强² 覃 熠² 崔宗勇²

(1. 电子科技大学成都学院 成都 611731; 2. 电子科技大学信息与通信工程学院 成都 611731)

摘 要: SAR 图像中道路检测,能够实现不同复杂背景条件下不同尺度道路目标的精确判别,在战场监测、目标定位和跟踪等军事和民用领域中,发挥着重大的作用。相较于利用边缘检测或区域分割等方法提取道路的传统方法,目前基于卷积神经网络的方法具有优秀的特征提取能力和准确的分割效果,在道路检测中发挥着越来越重要的作用。然而 SAR 数据集往往包含多种分辨率图像,道路尺度不一,所需感受野不同,导致目前的方法仍难以解决多尺度道路检测问题。针对上述问题,本文提出了一种基于密集空洞金字塔网络的多尺度道路检测方法。该方法将密集连接与 U-net 结合,通过渐进式空洞率设计替代传统固定空洞率结构,在编码器中构建密集空洞金字塔模块,逐步扩展感受野以适配不同分辨率道路特征;结合多尺度注意力机制,动态融合浅层细节与深层语义信息,抑制复杂背景干扰,能够增强特征图的提取,提升对于小尺度道路的检测性能。针对高分三号 SAR 图像数据的试验结果表明,本文提出的网络在 1 m、3 m、10 m 分辨率下平均交并比达到 74.39%、68.01%、66.32%,较对比方法提升 2.04%~13.7%。针对于同幅图像中不同尺度道路以及不同分辨率 SAR 图像中的不同道路,本文所提方法均能有效降低对细小道路的漏检,同时能降低环境干扰带来的虚警,相较于其他方法能够达到最优的道路检测性能。

关键词: SAR 图像;道路检测;金字塔网络

中图分类号: TN959.17 **文献标识码:** A **国家标准学科分类代码:** 510.4050

SAR multi-scale road detection based on dense dilated pyramid

Zhang Hui¹ Mou Liqiang² Qin Yi² Cui Zongyong²

(1. Chengdu College, University of Electronic Science and Technology of China, Chengdu 611731, China; 2. School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: Road detection in Synthetic Aperture Radar (SAR) images enables precise identification of multi-scale road targets under complex backgrounds, playing a critical role in military and civilian applications such as battlefield surveillance, target localization, and disaster response. Compared to traditional methods relying on edge detection or region segmentation, Convolutional Neural Network (CNN)-based approaches exhibit superior feature extraction and segmentation accuracy. However, existing methods still struggle with multi-scale road detection due to the diverse resolutions and varying receptive fields required for roads of different scales in SAR datasets. To address these challenges, this paper proposes a multi-scale road detection method based on a Dense Dilated Pyramid Network. The method integrates dense connections into a U-Net architecture, replacing traditional fixed-dilation-rate structures with progressive dilation rates to construct a dense dilated pyramid module in the encoder. This design progressively expands the receptive field to adapt to multi-resolution road features. Additionally, a multi-scale attention mechanism dynamically fuses shallow details and deep semantic information while suppressing background interference. Experiments on Gaofen-3 SAR datasets demonstrate that the proposed method achieves mean Intersection over Union values of 74.39%, 68.01% and 66.32% at 1 m, 3 m and 10 m resolutions, respectively, outperforming state-of-the-art methods by 2.04%~13.7%. The method significantly reduces missed detections of small-scale roads and lowers false alarms caused by environmental interference, achieving optimal detection performance across multi-scale scenarios in both single-image and cross-resolution settings.

Keywords: SAR image; road detection; pyramid network

0 引 言

合成孔径雷达(synthetic aperture radar, SAR)是一种

高分辨率成像雷达,其受任何气候、云层和光照等因素的影响,能够在任意时刻,甚至不利气候环境下保持工作状态,因此 SAR 技术在灾情救援、地形测绘和制图、海洋监测、军

事探测等各个领域都有十分广泛的研究与应用。而道路作为地表关键基础设施,其精准检测对战场态势感知、应急路径规划等任务至关重要^[1-3]。然而,SAR 图像中道路目标呈现显著的多尺度特性:

1)跨分辨率尺度差异:1 m 分辨率图像中道路宽度可达 3~5 像素,而 10 m 分辨率下退化为 1~2 像素的线状目标,传统检测方法难以兼顾长度与宽度特征;2)同场景多尺度共存:高分辨率(如 1 m)SAR 图像中常包含不同宽度的道路,尺度差异导致漏检率升高。

早期研究主要依赖边缘检测、区域生长等人工设计特征方法,但其对噪声敏感且泛化能力不足。近年来,基于深度学习的方法显著提升了道路检测精度^[4-6]。2015 年提出的全卷积网络(fully convolutional networks,FCN),可以输入任意尺寸图像,首次将深度学习方法引入图像分割领域研究中^[7-8]。文献[9]提出 DeepLab 深度卷积网络模型,首次通过利用空洞卷积代替反卷积操作来增加感受野,获得更多上下文信息。文献[10]提出 ParseNet 模型,引入全局池化层来弥补感受野不足问题。文献[11]提出了多路径神经网络 RefineNet,通过递归方式获取低层特征来优化高层特征,有效地利用多级特征来生成高分辨率特征图。文献[12]提出了混合空间金字塔池化网络(mixed spatial pyramid pooling, MSPP),利用全局融合注意力(global attention fusion, GAF)模块生成的注意力机制图与浅层特

征图相融合得到加权特征图,最后将高层特征图与加权特征图连接起来进行上采样得到最终预测结果。然而,现有方法在 SAR 道路检测中仍存在以下局限:

1)多尺度建模不足:深度网络中普通的卷积核难以适应 SAR 图像分辨率跨度大的特性,导致低分辨率下小目标漏检;2)特征复用效率低:例如 ResU-Net++ 等残差网络侧重深层语义传递,忽略浅层多尺度特征的密集交互。

针对上述多尺度带来的道路漏检等问题,本文提出了一种基于密集空洞金字塔网络(dense dilated pyramid Unet, DDP-Unet)的多尺度道路检测方法。该方法针对 SAR 图像中道路检测面临的多尺度问题,创新性地 将空洞卷积和密集连接机制相结合,并用结合后产生的新模块替代 U-net 网络本身的卷积层,能够迅速扩大模型感受野,并通过不同的感受野分别保留图像中不同尺度的道路特征,然后将这些多尺度特征进行密集的级联融合,防止对小尺度道路特征的忽视,从而提高检测模型的精确度。

1 基于密集空洞金字塔网络的道路检测

SAR 图像中道路的多尺度问题主要包括两种情况:一种是不同分辨率图像中道路的长度和宽度信息不同,如图 1 所示;另一种是同一幅 SAR 图像中包含尺度不同的多条道路,且分辨率越高该问题越明显,如图 2 所示。

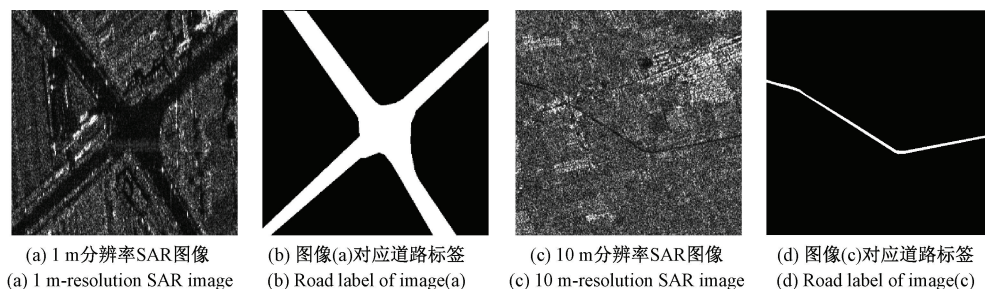


图 1 不同分辨率道路图像及其标签

Fig. 1 Comparison of roads and their labels images under different resolutions




图 2 同一幅图像中不同尺度道路及其标签

Fig. 2 Multi-scale roads and their labels in the same SAR image

针对以上问题,传统检测方法极易造成道路目标的漏检。本文在分析 SAR 图像中道路目标特性的基础上,引入空洞卷积和密集连接机制,提出密集空洞金字塔网络

DDP-Unet,其整体框架如图 3 所示。该网络具有整体上较为对称的编码-解码结构,由 5 种卷积块和相应层之间的跳连组成。密集连接被用于构建网络的主要部分,取代了传

统 U-Net 中的卷积层,以便更好地提取特征,强化模型特征学习能力,得到更加完整的 SAR 图像道路提取结果。同时,还使用注意力模块来引导网络关注感兴趣的区域(在本任务中为道路区域),减少背景干扰对低分辨率 SAR 图像道路特征的影响。虚线箭头表示网络的跳连操作,将来自编码器中浅层网络提取的特征图与解码器中对应的深层网络提取特征图在通道维度上级联在一起。

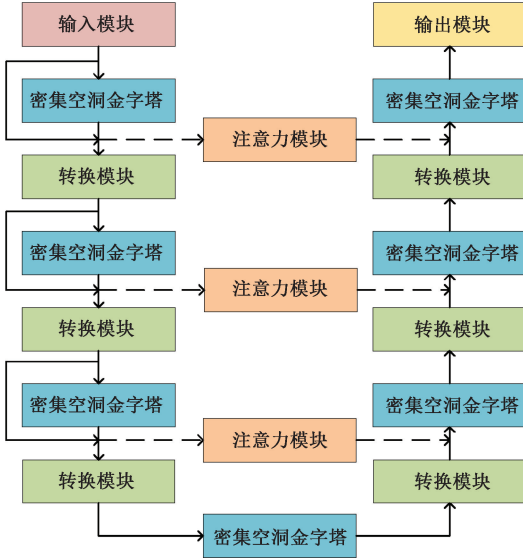


图 3 DDP-Unet 整体结构

Fig. 3 Overall architecture of DDP-Unet

1.1 空洞卷积

空洞卷积(dilated convolution)有时也被称为膨胀卷积和扩张卷积^[13-15],其能够在不增加模型参数量的情况下,获取图像更大范围的特征信息。其最重要的一个参数名为扩张率或者称为空洞率(dilation rate),代表了用固定的元素“0”将原本卷积核中的参数隔开的距离。

在一维的情况下,如果假设 x_i 是输入,而 y_i 是输出,那么空洞卷积的计算可以表示为:

$$y_i = \sum_{k=1}^K x_{i+d \cdot k} \cdot w_k \quad (1)$$

其中, d 是空洞率, w_k 是滤波器的第 k 个参数, K 是滤波器大小。

空洞卷积的感受野计算公式为:


$$k_d = k + (k - 1)(r - 1) \quad (2)$$

其中, k 是卷积核的大小,也就是普通卷积的感受野大小, n 表示空洞率,当 $n=1$ 时, $k_d = k$,即为普通卷积。

空洞卷积与普通卷积的对比如图 4 所示,可以看出空洞卷积的感受野明显大于普通卷积,却不消耗额外的计算和参数资源。因此,使用空洞卷积代替下采样/上采样可以很好的保留图像的空间特征,也不会损失图像的全局关联性信息,被广泛用于图像分割网络中。


1.2 密集空洞金字塔网络

空洞卷积应用于深度网络的一个重要方式,是将多个



(a) 普通卷积感受野

(a) Receptive field of standard convolution



(b) 空洞卷积感受野

(b) Receptive field of dilated convolution

图 4 感受野增长对比

Fig. 4 Comparison of receptive field expansion

不同空洞率的空洞卷积层进行串联或并联,然后作为网络的额外模块插入卷积网络中。在 DeepLab v2 中,空洞卷积被引入空间金字塔结构,构成了空洞空间金字塔池化(atrous spatial pyramid pooling, ASPP)^[14],如图 5 所示,并在 DeepLab v3 中被进一步优化。ASPP 将不同空洞率的空洞卷积层以并联的形式,对不同感受野下的特征图在通道维度上进行拼接,以提取图像的多尺度特征。

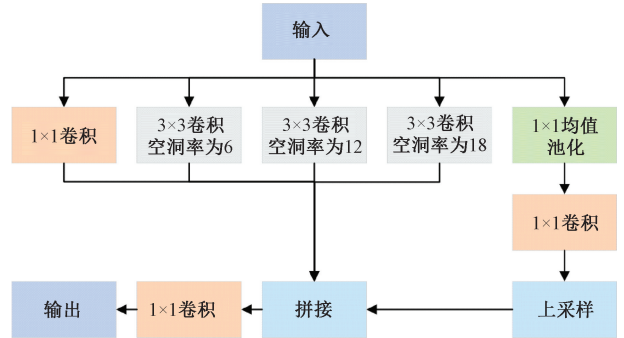


图 5 空洞空间金字塔池化结构图

Fig. 5 Structure of atrous spatial pyramid pooling

密集空洞金字塔中的密集空洞层组合方式,沿用密集连接机制,如图 6 所示,每一层的输入都包括了之前所有层的输出,其中 C 表示特征并联连接。




图 6 密集空洞金字塔结构

Fig. 6 Architecture of the dense dilated pyramid

密集空洞金字塔第 l 层输出可定义为式(3):

$$x_l = H_{l,k_l}([x_{l-1}, x_{l-2}, \dots, x_0]) \quad (3)$$

其中, H_{l,k_l} 为代表第 l 层, 空洞率为 k_l 的密集空洞层运算, $[]$ 被定义为通道级串联操作。

为了方便设置, 且满足空洞率的设计需要, 第 l 层密集空洞层的空洞卷积运算, 空洞率被设置为 $k_l = 2l - 1$, 即第 1 层空洞率为 1, 第 2 层为 3, 依次类推。

1.3 多尺度注意力模块

SAR 图像中道路的区域相对较小, 尤其在中低分辨率 SAR 图像中, 这一现象更为明显。本文采用具有空间注意力和通道注意力相结合的多尺度注意力机制来引导网络更多关注多个道路目标。多尺度注意力模块的结构如图 7 所示。




图 7 多尺度注意力模块

Fig. 7 Structure of the multi-scale attention module

多尺度注意力模块由两个子模块组成: 通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM), 公式如下:

$$F_s(x) = \sigma(f^{3 \times 3}([A(x); M(x)])) F_c(y) = \sigma(MLP(A(y)) + MLP(M(y))) \quad (4)$$

其中, $F_c(y)$ 和 $F_s(x)$ 分别表示通道和空间注意力模块的输出, σ 表示 Sigmoid 激活函数, $f^{3 \times 3}$ 表示卷积核为 3×3 的卷积层, $A(x)$ 表示 x 上的最大值池化运算, $M(x)$ 代表 x 的平均值池化运算, MLP 表示两层感知器的变换函数。

2 实验结果与分析

2.1 数据介绍

作为基础的两个数据集中图片均来自于高分三号卫星数据, 分辨率主要有 1 m、3 m 和 10 m。分辨率为 1 m 的图片共 3 557 张, 分辨率为 3 m 的图片共 1 983 张, 分辨率为 10 m 的图片共 1 740 张, 所有的图片尺寸大小均为 512×512 。本文将每种数据的 60% 划分为训练集, 剩下的平均分为测试集和验证集, 所有图像随机分配。

本文采用 Mixup 对训练样本进行增强, 公式如下:

$$\begin{aligned} \tilde{x} &= \lambda x_i + (1 - \lambda) x_j \\ \tilde{y} &= \lambda y_i + (1 - \lambda) y_j \end{aligned} \quad (5)$$

式中: (x_i, y_i) 与 (x_j, y_j) 是从训练集中随机选取出来的两组训练样本及其对应的标签, $\lambda \in (0, 1)$ 。

在训练过程中, 其取值服从 $bera(\partial, \partial)$ 的随机分布, ∂ 的取值越大, 越容易导致欠拟合, 在不同数据集上, 针对不同任务, ∂ 的最佳取值不同。图 8 所示当 λ 取值为 0.5 时得到的训练数据图和和标签图示例。




图 8 Mixup 数据增强示例

Fig. 8 Examples of mixup data augmentation

2.2 试验设置

本试验中所采用的对比模型为 DHA-Unet 模型^[15]及引入 ASPP 的 DHA-Unet+ASPP 模型、以及近年来应用较为广泛的 ResU-Net++ 模型^[16]。所有试验都在 Linux 系统下完成, 计算机语言是 python, 深度学习框架是 pytorch, GPU 为 NVIDIA RTX 3080 显卡, 显存大小为 10 G。

试验的参数设置如表 1 所示。

不同空洞密集块中密集空洞层的数量如表 2 所示, 编码器中依次为 5、7、10, 而解码器中依次为 10、7、5。

2.3 1 m 分辨率 SAR 图像道路检测结果与分析

针对分辨率为 1 m 的 SAR 图像的道路检测结果如图 9 所示。从第 1 行检测结果可以发现, DHA-Unet 和

表 1 DDP-Unet 网络参数设置

Table 1 Parameter settings of the DDP-Unet network

参数	数值
输入图像尺寸	$512 \times 512 \times 3$
编码器密集连接层个数	(5,7,10)
解码器密集连接层个数	(10,7,5)
最大训练批次(epoch)	100
一次训练所选取的样本数(batch_size)	4
学习率(Learning_rate)	0.001

ResUnet++方法都无法将两条相邻的平行道路分割开,虽然 DHA-Unet+ASPP 方法将平行道路分开,但产生了较多虚警。本文提出的 DDP-Unet 方法,能够较为精确地将两条相邻的道路分开,且两条道路之间无粘连。主要原因是密集连接机制能够重点关注尺度较小的宽度特征,空

表 2 DDP-Unet 不同卷积层的空洞率设置

Table 2 Dilation rate settings for different convolutional layers in DDP-Unet

卷积层位置	空洞率
编码器第 1 个密集空洞金字塔	(1,3,5,7,9)
编码器第 2 个密集空洞金字塔	(1,3,5,7,9,11,13)
编码器第 3 个密集空洞金字塔	(1,3,5,7,9,11,13,15,17,19)
解码器第 1 个密集空洞金字塔	(1,3,5,7,9)
解码器第 2 个密集空洞金字塔	(1,3,5,7,9,11,13)
解码器第 3 个密集空洞金字塔	(1,3,5,7,9,11,13,15,17,19)

洞卷积能够关注尺度较大的长度特征,通过二者的有机结合,能够实现相邻道路的精确划分,同时能够有效抑制相似形状的虚警。




图 9 不同方法在 1 m 分辨率 SAR 图像中的道路检测结果

Fig. 9 Road detection results of different methods on 1 m-resolution SAR images

图 9 中第 2 行和第 3 行的结果表明,针对同一幅图中不同尺度的道路目标,DHA-Unet、ResUnet++以及 DHA-Unet+ASPP 方法均有较多漏检,导致道路被“中断”;本文提出的 DDP-Unet 能够提取更多细节信息和多尺度信息,进而得到了更加准确和平滑的多尺度道路分割结果。

不同道路检测方法在 1 m 分辨率数据集上的量化结果如表 3 所示。在精确率上,DDP-Unet 相比 DHA-Unet+ASPP 和 ResU-Net++方法分别提升了 0.63% 和 7.47%,但相比于 DHA-Unet 下降了 0.35%;在召回率上,DDP-Unet 相比 DHA-Unet+ASPP、ResU-Net++和 DHA-Unet 方法分别提升了 6.45%、9.40% 和 7.89%,在 F_1 分数上分别提升了 3.35%、8.37% 和 13.12%,在交并比上分别提升了 2.04%、5.86% 和 2.45%。可以看出,在分辨率为 1 m 的数据集上,相比于其他方法,DDP-Unet 在各项评判指标中均表现出了优越的性能。

2.4 3 m 分辨率 SAR 图像道路检测结果与分析

针对分辨率为 3 m 的 SAR 图像的道路检测结果如

表 3 分辨率为 1 m 的数据集试验结果

Table 3 Experimental results on the 1 m-resolution dataset

方法	精确率	召回率	F_1 分数	交并比
DHA-Unet[15]	81.33	79.89	80.60	71.94
ResU-Net++[16]	73.51	78.38	75.87	68.53
DHA-Unet+ASPP	80.35	81.45	80.89	72.35
DDP-Unet	80.98	87.78	84.24	74.39

图 10 所示。从第 1 行检测结果可以发现,3 种方法 DHA-Unet、ResUnet++和 DHA-Unet+ASPP 的检测结果均存在断点或虚警,而本文提出的 DDP-Unet 方法不仅没有虚警,同时检测得到的路面也最为完整,道路连接处更为平滑。

图 10 中第 2 行结果表明,针对同一幅 SAR 图像中不同尺度的道路目标,DHA-Unet、ResUnet++以及 DHA-Unet+ASPP 方法均有较多漏检,同时有较多“毛刺”,本文

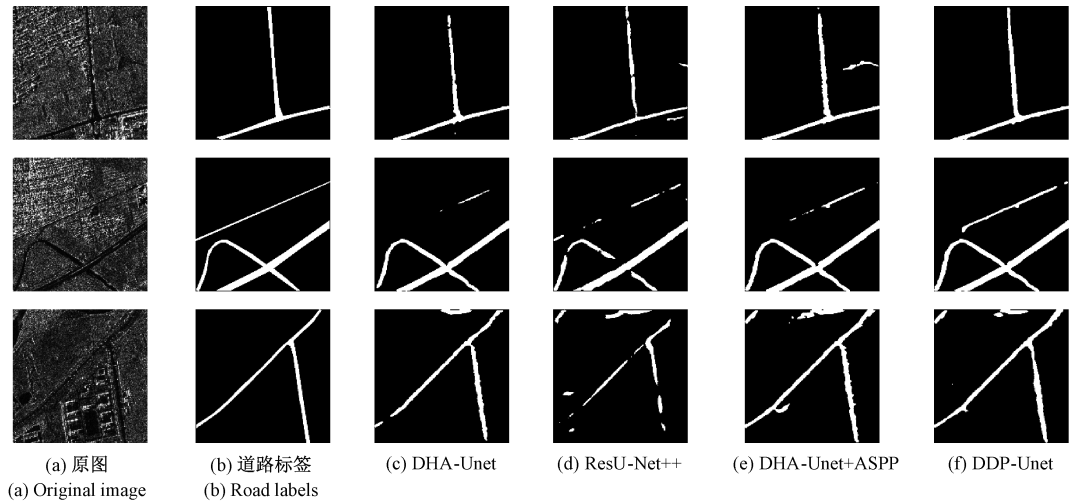


图 10 不同方法在 3 m 分辨率 SAR 图像中的道路检测结果

Fig. 10 Road detection results of different methods on 3 m-resolution SAR images

提出的 DDP-Unet 方法,能够较好保持不同尺度道路的完整性,断点最少。第 3 行的结果表明,针对建筑干扰等复杂情况,虽然本文提出的方法也会产生虚警,但是相较于其他 3 种方法,虚警数量最少,没有“断点”且“毛刺”最少,平滑度较高。不同道路检测方法在 3 m 分辨率数据集上的量化结果如表 4 所示。

表 4 分辨率为 3 m 的数据集试验结果

Table 4 Experimental results on the 3 m-resolution dataset

方法	精确率	召回率	F_1 分数	交并比
DHA-Unet[15]	75.10	77.35	76.21	64.33
ResU-Net++[16]	68.42	71.29	69.83	56.73
DHA-Unet+ASPP	69.18	77.82	73.25	66.31
DDP-Unet	73.13	84.62	78.67	68.01

在精确率上,DDP-Unet 相比 DHA-Unet+ASPP 和

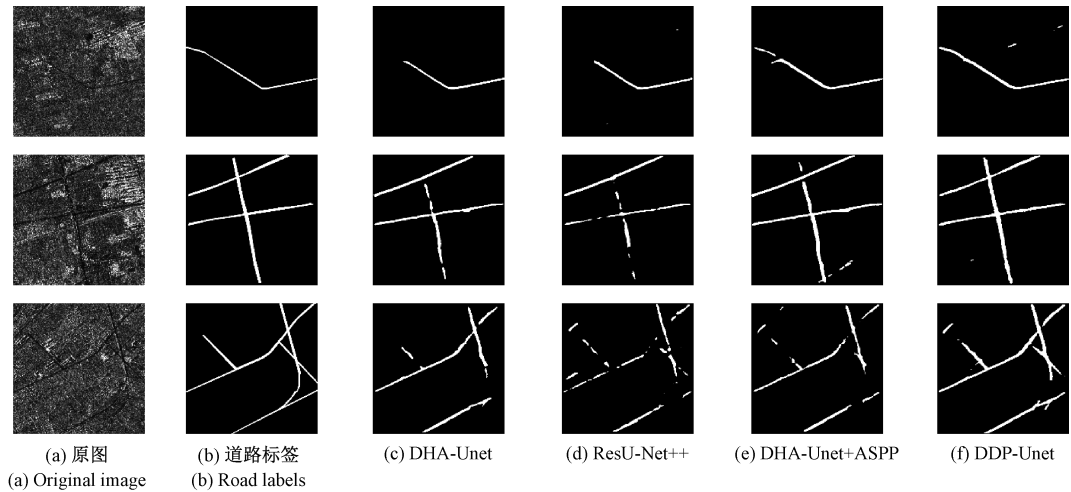


图 11 不同方法在 10 m 分辨率 SAR 图像中的道路检测结果

Fig. 11 Road detection results of different methods on 10 m-resolution SAR images

ResU-Net++方法分别提升了 3.95%和 4.71%,相比于 DHA-Unet 则下降了 1.97%;在召回率上,DDP-Unet 相比 DHA-Unet+ASPP、ResU-Net++和 DHA-Unet 方法分别提升了 6.80%、8.87%和 2.46%,在 F_1 分数上分别提升了 5.42%、8.87%和 2.46%,在交并比上分别提升了 1.70%、11.28%和 3.68%。

可以看出,在分辨率为 3 m 的 SAR 图像数据集上,相比于其他方法,DDP-Unet 在各项评判指标中都表现出了优越的检测性能。

2.5 10 m 分辨率 SAR 图像道路检测结果与分析

针对分辨率为 10 m 的 SAR 图像的道路检测结果如图 11 所示,可以看出,相较于 1 m 和 3 m 分辨率数据,10 m 分辨率 SAR 图像中道路宽度小、受干扰更多。从第一行检测结果可以发现,DHA-Unet、ResU-Net++和 DHA-Unet+ASPP 3 种方法针对左上角道路的检测结果存在严重漏检,而本文提出的 DDP-Unet 方法虽然有一定虚警,但得到了完整度最高的路面。

图 11 中第 2 行结果表明,针对图像中受到干扰的道路目标,DHA-Unet、ResUnet++以及 DHA-Unet+ASPP 方法均有较多漏检,而本文提出的 DDP-Unet 方法能够无缺失地检测出所有的道路;第 3 行的 SAR 图像背景最为复杂,道路干扰也最为严重,虽然本文提出的方法也会产生漏检,但是相较于其他 3 种方法,道路检测的完整度和平滑度均是最优的。不同道路检测方法在 10 m 分辨率数据集上的量化结果如表 5 所示。

表 5 分辨率为 10 m 的数据集试验结果

Table 5 Experimental results on the 10 m-resolution dataset

方法	精确率	召回率	F_1 分数	交并比
DHA-Unet[15]	71.72	74.23	72.95	62.21
ResU-Net++[16]	63.77	60.04	61.85	52.62
DHA-Unet+ASPP	65.48	76.12	70.40	65.28
DDP-Unet	68.36	78.79	73.21	66.32

在精确率上,DDP-Unet 相比 DHA-Unet+ASPP 和 ResU-Net++方法分别提升了 2.88%和 4.59%,相比于 DHA-Unet 则下降了 3.36%;在召回率上,DDP-Unet 相比 DHA-Unet+ASPP、ResU-Net++和 DHA-Unet 方法分别提升了 2.67%、18.75%和 4.56%,在 F_1 分数上分别提升了 2.81%、11.36%和 0.26%,在交并比上分别提升了 1.04%、13.7%和 4.11%。可以看出,在分辨率为 10 m 的数据集上,相比于其他方法,DDP-Unet 在各项评判指标中依旧表现出了最为优越的性能。

3 结 论

针对 SAR 图像中道路精确检测面临的多尺度问题,本文该方法将空洞卷积和密集连接相结合,在扩大模型感受野的同时,将不同感受野获取的图像中不同尺度的道路特征进行密集的级联融合,达到降低虚警和降低漏检的双重目的。

综合 1 m、3 m 和 10 m 分辨率 SAR 图像中道路检测结果,可以看出本文提出的密集空洞金字塔网络 DDP-Unet 方法,在不同分辨率 SAR 图像中均能取得最佳的道路检测性能,说明该方法既能实现同一幅图像中不到尺度道路目标的精确检测,同时能够实现不同尺度图像中道路目标的检测,从而有效验证了本文提出方法的优越性能。

参考文献

[1] BORBA A A D, MARENGONI M, FRERY A C. Road detection in SAR/PolSAR image [C]. IEEE International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing, 2024.

[2] 肖芳鸿. 高分辨率 SAR 影像道路及地表空间信息提取研究[D]. 成都:电子科技大学, 2022.

XIAO F H. Research on road and surface spatial information extraction from high-resolution SAR images[D]. Chengdu: University of Electronic Science and Technology of China, 2022.

[3] SHU W, BIE Y, ZHANG R, et al. High-resolution SAR image road extraction based on MRF model[C]. 4th China International SAR Symposium(CISS), 2023.

[4] 黄聪, 杨珺, 刘毅, 等. 基于改进 DeeplabV3+的遥感图像分割算法[J]. 电子测量技术, 2022, 45(21): 148-155.

HUANG C, YANG J, LIU Y, et al. Remote sensing image segmentation algorithm based on improved deeplabV3+ [J]. Electronic Measurement Technology, 2022, 45(21): 148-155.

[5] 张慧敏, 李锋, 黄炜嘉, 等. 基于 CAM-YOLOX 的大场景 SAR 图像近岸场景舰船目标检测[J]. 电子测量技术, 2024, 47(6): 86-93.

ZHANG H M, LI F, HUANG W J, et al. Ship target detection in nearshore scenes of large-scale SAR images based on CAM-YOLOX [J]. Electronic Measurement Technology, 2024, 47(6): 86-93.

[6] 陈坤, 郝明, 庄龙, 等. 基于卷积神经网络的 SAR 图像水体提取[J]. 电子测量技术, 2021, 44(3): 125-131.

CHEN K, HAO M, ZHUANG L, et al. Water body extraction from SAR images based on convolutional neural network [J]. Electronic Measurement Technology, 2021, 44(3): 125-131.

[7] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(4): 640-651.

[8] HENRY C, AZIMI S M, MERKLE N. Road segmentation in SAR satellite images with deep fully convolutional neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(12): 1867-1871.

[9] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs [J]. Computer Science, 2014, 4: 357-361.

[10] LIU W, RABINOVICH A, BERG A C. Parsenet: Looking wider to see better[J]. Computer Science, 2015, DOI: 10.48550/arXiv.1506.04579.

[11] LIN G, MILAN A, SHEN C, et al. Refinenet: Multi-path refinement networks for high-resolution semantic segmentation[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017:

- 5168-5177.
- [12] XIA ZH Y, KIM J. Mixed spatial pyramid pooling for semantic segmentation[J]. Applied Soft Computing, 2020, 91: 106209.
- [13] YU F, KOLTUN V, FUNKHOUSER T. Dilated residual networks [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 636-644.
- [14] ZHE Z, BILIN W, ZHEZHOU Y, et al. Dilated convolutional pixels affinity network for weakly supervised semantic segmentation[J]. Chinese Journal of Electronics, 2021, 30(6): 1120-1130.
- [15] ZHANG H, QIN Y, MOU L, et al. A SAR road extraction method based on dense connection and hybrid attention [C]. 2024 IEEE International Geoscience and Remote Sensing Symposium, 2024: 9587-9590.
- [16] DEBESH J, PIA H S, DAG J, et al. A comprehensive study on colorectal polyp segmentation with ResUNet++, conditional random field and test-time augmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2021, 25(6): 2029-2040.

作者简介

张慧, 硕士, 副教授, 主要研究方向为模式识别、人工智能。

E-mail: zh21y@163.com

牟立强, 硕士研究生, 主要研究方向为 SAR 目标特征提取。

E-mail: 2213273536@qq.com

覃熠, 硕士研究生, 主要研究方向为 SAR 图像处理。

E-mail: 947002974@qq.com

崔宗勇(通信作者), 博士, 副教授, 主要研究方向为 SAR 图像解译。

E-mail: zycui@uestc.edu.cn