

# 基于改进 U-Net 的遥感图像道路提取算法

熊雅行

(江西理工大学,土木与测绘工程学院,江西 赣州 341000)

**摘要:** 针对基于 U-Net 模型对遥感图像道路特征提取能力不足、分割结果不清晰等问题,文章提出了一种改进的 U-Net 算法:首先在编码器中引入级联的空洞空间金字塔模块充分利用图像全局上下文信息从而改善分割结果模糊的问题;再通过在通道中嵌入坐标注意力机制模块加强对道路特征信息的提取,最后在解码器部分引入空间注意力机制旨在提高道路分割边缘的清晰度。实验表明:在马赛诸塞州数据集下改进后的 U-Net 模型比原始 U-Net 网络模型在 Recall、F1-Scores 和 IoU 三个指标下分别提高了 0.085、0.038、0.045,提取的道路结构更完整且相互连通,证明了算法优化的有效性。

**关键词:** 遥感图像;道路提取;U-Net;空洞空间金字塔;坐标注意力机制;空间注意力机制

中图分类号:TP751 TP393

文献标识码:A

文章编号:2096-9759(2023)06-0084-04

## Road Extraction from High Resolution Remote Sensing Images Based on Improved U-Net

XIONG Yaxing

(College of civil and surveying engineering, Jiangxi University of Science and technology, Ganzhou 341000, Jiangxi)

**Abstract:** Aiming at the problems of insufficient road feature extraction ability and unclear segmentation results of remote sensing images based on U-Net model, this paper proposes an improved U-Net algorithm: firstly, a cascading void space pyramid module is introduced into the encoder to make full use of the global context information of the image to improve the problem of blurring of segmentation results; Then, by embedding the coordinate attention mechanism module in the channel, the extraction of road feature information is strengthened, and finally the spatial attention mechanism is introduced in the decoder part, aiming to improve the clarity of the road segmentation edge. Experiments show that the improved U-Net model under the Massachusetts dataset is improved by 0.085, 0.038 and 0.045 respectively compared with the original U-Net network model under the three indicators of Recall, F1-Scores and IoU, respectively, and the extracted road structure is more complete and interconnected, which proves the effectiveness of algorithm optimization.

**Keyword:** remote sensing image; Road extraction; U-Net; Atrous Spatial Pyramid; Pooling Attention mechanism; Spatial attention mechanisms

## 0 引言

道路是现代交通基础设施的主体<sup>[1]</sup>,研究道路信息的提取在交通导航、无人驾驶、路径规划和交通管理、地理信息系统更新等方面有着重要的实用价值和意义<sup>[2]</sup>。传统的道路提取方法如光谱分析法<sup>[3]</sup>、阈值分割法<sup>[4]</sup>、区域法<sup>[5]</sup>、知识模型法<sup>[6]</sup>等,上述方法往往都需要人工干预,工作量巨大费时费力,不能实现道路的自动化提取,相对于传统方法,基于深度学习的方法它的自适应学习能力和特征拟合能力都十分强大,在道路提取的精度和自动化程度上都有较大的优势。全卷积神经网络(FCN)<sup>[7]</sup>是首个实现端到端直接从输入到输出分割结果的语义分割网络,之后许多学者在其的基础上进行改进发展了一些变种的网络模型如 U 型网络模型(U-Net)<sup>[8]</sup>,语义分割网络模型(Segnet)<sup>[9]</sup>,语义分割模型(develapv3)<sup>[10]</sup>等等。林娜等<sup>[11]</sup>提出一种基于 U-Net 模型并结合特征融合和空洞卷积的改进算法,改善了道路细节丢失和提取结果模糊等问题。张新华等<sup>[12]</sup>在 U-Net 模型中引入了空间空洞金字塔<sup>[13]</sup>模块,融合了不同尺寸的图像特征信息获得更多的全局上下文信息,旨在解决分割结果模糊等问题。宋廷强等<sup>[14]</sup>提出了结合通道注意力和空间注意力的 U-Net 改进算法,加强对有用特征信息的提取,提高模型的分割精度。因此本文结合上述研究方法的优势与道路结构对 U-Net 模型进行改进。

## 1 研究方法

本文通过深入研究 U-Net 网络模型结构特点和不足,在

其基础上设计了一种改进的 UNet 网络模型,将空间空洞金字塔模块作编码器与解码器底部连接的桥梁旨在获得多尺度的上下文信息提高模型的分类精度;在通道部分引入坐标注意力机制加强有用信息的提取;在解码器部分引入空间注意力加强模型分割边缘的清晰度。

### 1.1 U-Net 网络模型

首先介绍一下 U-Net 网络模型,它的整体网络结构形如‘U’字型,故而得名。U-Net 模型主要有编码器、解码器两部分组成,具体结构如图 1 所示:




图 1 U-Net 模型结构

编码器又被称为压缩路径,主要作用是提取图像特征,压缩路径由 4 个 block 组成,每个模块使用了 3 个有效卷积和 1 个最大池化降采样,传统的采样会降低图像的分辨率。

收稿日期:2023-03-13

作者简介:熊雅行(1997-),女,江西宜春人,硕士生,主要研究方向为深度学习在遥感图像处理中的应用。

解码器也被称为扩展路径, 同样由 4 个 block 组成, 每个模块它通过反卷积还原特征图的大小然后与编码器的对应的特征图拼接融合成一张新的特征图。

U-Net 网络作为 FCN 的变种网络, 本身具有全卷积神经网络特征表达的优势, 同时它又通过跳跃连接复用低层次的语义信息很好的解决了 FCN 提取的特征图存在粗糙等问题, 它是目前主流的语义分割网络之一。

## 1.2 改进的 U-Net 网络模型

但是由于遥感图像中道路结构复杂甚至可能存在道路被遮挡的情况, 基于 UNet 模型提取道路结构很有可能存在道路结构断开的情况, 为提高模型抗遮挡能力, 本文在 UNet 模型的基础上引入了 ASPP 模块和融合注意力模块旨在增强模型的分割效果。

改进的 Unet 模型主要由编码网络、解码网络 2 部分组成, 具体结构如图 2 所示:




图 2 改进的 U-Net 网络结构图

第一部分为编码器部分, 在每个通道中引入了一个通道注意力模块可以使模型建模通道关系调整通道维度的权重。将改进的 ASPP 模块作为编码器与解码器底部连接的桥梁, 目的是利用不同扩张率的空洞卷积获得多尺度的图像上下文信息, 提高解码器分类精度, 增加模型细节表达能力。

第二部分为解码器部分, 将空间注意力机制引入到每层上采样模块中, 加强模型对道路区域的特征提取, 帮助解码器恢复原来特征图的分辨率, 从而提取更多的更完整的道路信息提高模型的分割效果。

### 1.2.1 融合注意力机制

#### (1) 通道注意力机制

坐标注意力机制 (Coordinate Attention, CA)<sup>[15]</sup> 是一种最新的通道注意力, 它的优势有: 可以通过沿垂直和水平方向上的平均池化引入了位置信息, 这样既可以沿通道维度上调整权重, 又有利于生成空间选择性注意图加强模型对道路区域的识别和特征提取; 参数较少, 几乎不增加计算机的开销; 非常灵活。因此本文讲坐标注意力机制插入到 U-Net 模型每个通道中, 旨在加强有用信息的提取, 抑制无用信息的干扰, 提高模型分类精度和分割效果。坐标注意力机制网络结构如下图 3 所示。

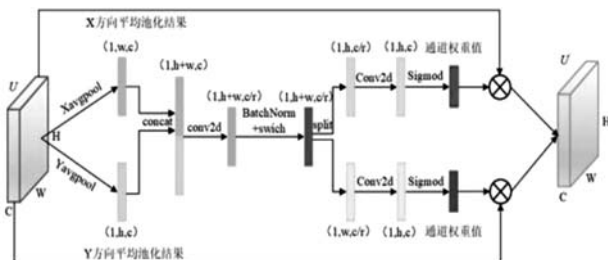


图 3 坐标注意力机制网络结构图

首先将一张大小为  $H \times W \times C$  的特征图  $U$  输入到坐标注意力模型中, 分别进行  $X$  方向平均池化和  $Y$  方向平均池化后在通道维度上进行拼接生成 1 个大小  $1 \times (H+W) \times C$  的新的特征图; 经过卷积压缩通道数为  $C/r$ ,  $r$  代表衰减率; 接着通过使用卷积变换函数 BN 和 swish 激活函数对其进行非线性变换操作; 之后将特征图分离为原来的两个大小为  $1 \times H \times C$  和  $1 \times W \times C$  的特征图并使用 Sigmoid 函数激活为原始输入的每个特征通道生成一对沿和水平方向上的权重值。最后, 将学习到的权重与原始输入特征图相乘得到新的输出特征图  $U'$ , 则  $U'$  中具有更丰富的语义信息。此网络的计算过程如下:

$$U' = U \times \sigma_1 \times \sigma_2 \quad (1)$$

其中,  $U$  为输入特征图,  $\sigma_1, \sigma_2$  分别为通道沿垂直和水平方向上的权重,  $U'$  为输出的特征图。

#### (2) 空间注意力机制

解码器恢复的高层次特征图通过通道与解码器提取的低层次的融合, 而原始 U-Net 模型的编码器部分采用的是传统的卷积的方式提取特征, 在提取到的特征图中很有可能存在噪声等无用信息的干扰, 这样很容易导致在道路的分割中出现边缘模糊、道路断开等问题, 为提高 U-Net 模型分割效果, 本文网络在解码器部分加入空间注意力融合模块使模型重点关注道路特征的区域, 加强对道路特征的提取, 恢复提取道路结构的连续性, 增强对道路分割边缘的清晰度。空间注意力机制网络结构如图 4 所示:




图 4 空间注意力机制网络结构图

首先对一张大小为  $H \times W \times C$  的特征图  $F$  分别进行全局最大池化和全局平均池化操作, 接着进行空间融合, 然后通过一个  $7 \times 7$  大小的卷积核加强特征提取, 再通过 Sigmoid 激活函数得到空间权重值并与原始图像逐像素相乘得到新的特征图  $F'$ , 具体公式如下:

$$F' = M_s(F) \otimes F \quad (2)$$

其中,  $M_s(F)$  为空间权重值, 定义如下:

$$M_s(F) = \sigma(f^{7 \times 7}([F_{\max}, F_{\text{avg}}])) \quad (3)$$

式中,  $\sigma$  表示 Sigmoid 激活函数,  $f^{7 \times 7}$  表示  $7 \times 7$  的卷积操作。

### 1.2.2 空洞空间金字塔模块

编码器输出的最后一张特征图具有最丰富的语义特征, 为提高其特征信息利用率故在该特征图后面插入空洞空间金字塔模块 (ASPP) 通过不同的扩张率对特征图进行多次空洞卷积提取特征从而获得多尺度的上下文信息; 并且在不额外引入参数的情况下扩大了卷积核的感受野获得更大范围的特征信息同时保证分辨率不降低。

通过不同的扩张率可以增大过滤器的感受野, 具体计算公式为:

$$S = (r-1) \times (k-1) + k \quad (4)$$

其中  $r$  为扩张率,  $k$  为过滤器的长度。但是 ASPP 也有不足的地方, 它通过空洞卷积得到的某一层的结果中相互之间

缺少依赖,会造成局部信息丢失,影响分类结果。为了解决这个问题,本文对 ASPP 模块结构进行改进,将其由原来的独立分支法改为串行结构,实现更密集的像素采样,同时扩大了感受野,提高算法的特征提取能力,解决了局部信息不一致的问题。改进后的 ASPP 模块如图 5 所示:




图 5 改进后的 ASPP 模块

通过叠加两个空洞卷积可以获得更大的感受野,叠加后的感受野大小可以通过以下公式获得:

$$S = S_1 + S_2 - 1 \quad (5)$$

其中  $S_1$  和  $S_2$  分别是两个空洞卷积各自的感受野大小。由公式(4)和公式(5)可知原 ASPP 模块的最大感受野为 37,改进的 ASPP 模块的最大感受野为 73。改进后的模块通过跳层连接实现信息共享,不同膨胀率的空洞卷积相互补充,增加了感受野的范围。

## 2 实验结果与分析

### 2.1 数据集及预处理

实验使用马萨诸塞州(Massachusetts)数据集,图像分辨率为 1m,一共包含 1171 张的遥感图像和对应的标签,已经划分好了 1108 张训练集,14 张验证集,49 张测试集以及各自对应的标签。为保证实验效果,将数据集通过旋转、水平、垂直、色彩变换等方式进行数据增强以扩充训练样本。

### 2.2 实验环境

实验采用 pytorch1.10.0 为深度学习框架搭建模型,库达(cuda)为 11.3,图像处理器(GPU)为 A40,中央处理器(CPU)为 15 核,内存为 90GB,显存为 48GB。学习率为 0.0001,一次输入数(batchsize)为 4,使用优化器(Adma)更新网络权重,迭代次数为 100 次。为防止正负样本不均,采用损失函数为混合损失函数(Dice loss)。

### 2.3 评价指标

本文采用语义分割中 3 种常用的评价指标为模型的评估指标,即召回率(recall),F1 得分(F1-Score),交并比(IoU)。召回率表示的是样本中的道路被正确预测概率。F1 得分是准确率与召回率的调和函数,取值在[0, 1],值越接近 1 表示网络模型道路提取效果越好。交并比是一个综合评价指标,它考虑了道路被错分背景的情况更为全面。具体计算公式如下:

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

$$F_1 = 2 \times \frac{precision \times recall}{precision + recall} \quad (7)$$

$$IoU = \frac{TP}{TP + FN + FP} \quad (8)$$

其中 TP 表示真正例;FP 表示假正例;TN 表示真反例;FN 表示假反例。

### 2.4 实验结果与分析

为了验证改进措施的有效性,本文采用消融实验的方法,

讨论 U-Net 网络模型、仅加入 ASPP 模块的 Unet-ASPP 网络模型、仅加入坐标注意力机制模块的 Unet-ca 网络模型仅加入空间注意力机制的 Unet-SA、同时加入一组通道和空间注意力模块的 CS-Unet 网络以及本文改进的 Unet 网络模型在 Massachusetts 道路数据集上的预测效果并进行分析。

#### 2.4.1 实验结果

表 1 各网络模型道路提取结果的比较

Method	Recall	F1	IoU
Baseline U-Net	0.628	0.717	0.561
Unet-CA	0.702	0.749	0.598
Unet-SA	0.673	0.739	0.587
CS-Unet	0.720	0.754	0.604
Unet-Aspp	0.671	0.728	0.573
改进的 Unet	0.713	0.755	0.606




图 6 不同网络道路预测效果对比

#### 2.4.2 结果分析

由表 1 得出:(1)在 U-Net 的基础上引入 ASPP 模块以后,召回率、F1、IoU 分别提高了 0.043、0.011、0.012,说明引入 ASPP 可以提高模型的分类精度;(2)与基准 UNet 模型相比较,分别引入通道注意力模块和空间注意力模块后模型在 3 个指标上都具有明显的提升,说明了改进措施的有效性;(3)与单独加入注意力模块相比较,加入一组融合的注意力模块在个各指标上精度最高,说明加入了融合注意力机制的模型优越性;(4)本文提出的改进的 Unet 网络模型在召回率、F1 得分、交并比指标上比 U-Net 提高了 0.085、0.038、0.045,说明改进后的 U-Net 模型分割效果更好。

由图 5 可以看出:U-Net 模型预测的道路提取结果存在细节丢失、分割结果模糊,在被树木等遮挡的复杂路况下道路结构存在断开的情况,而在本文提出改进的 U-Net 网络模型下在复杂路况下可以有效减少道路错分、漏分的现象,提取的道路结构相对完整且连通,提取的道路边缘更清晰,分割效果均优于对照网络。

## 3 结论与讨论

本文针对基于 U-Net 模型从遥感图像中提取复杂路况信息不佳的情况,设计了一种改进的 U-Net 算法,在 Massachusetts 数据集上实验结果表明,引入改进后的空洞空间金字塔模块以后可以提高模型的细节提取能力,提高分类精度;在通道中嵌入坐标注意力机制模块加强对有用信息的提取可以有效减少道路错分、漏分的现象;再解码器部分引入了空间注意力机制模块可以提高道路分割边缘的清晰度;改进后的 U-Net 型与

# 基于深度学习的无线传感网络高维数据异常检测方法

胡挺峰

(无锡城市职业技术学院,江苏 无锡 214153)

**摘要:**数据异常检测是计算机算法领域的一个重要课题,为提高检测精度,基于深度学习算法设计一种无线传感网络高维数据异常检测方法。获取浅层的自编码器,得到低维向量和高维向量的差别,在编码器中传递隐藏函数,均方误差的权重,避免训练过拟合,信息传播过程中的代价函数,建立多个数据异常节点的差异化矩阵,基于深度学习算法实现无线传感网络的数据分类。设计高维数据异常检测算法,得到异常检测结果。实验数据表明,在训练数据比例不同的情况下,数据比例越大,检测精度越高。该方法在五个数据集中的准确率、召回率、F1 值均在 0.98 以上,可见其具备较高的检测精度,且适用性较强。

**关键词:**深度学习;无线传感网络;高维数据;数据异常检测

**中图分类号:**G647

**文献标识码:**A

**文章编号:**2096-9759(2023)06-0087-03

## 0 引言

在大数据时代到来以后,无论是在数据的精密处理领域还是数据应用领域,均需要对海量高维数据进行检测。但是,数据的浪潮汹涌而至,每时每刻都有大量的信息产生,数据的维度也每时每刻都在增加,从最初的几维成长到几十维、上百维。很多算法都受困于传统的数据处理难题,集中于针对静态数据的解算,而忽略了对高位数据中关键信息的提取与应用。在现有的相关研究中,文献[1]结合时间序列异常数据的修正与检测技术,对数据进行高精度的提取与分析,通过建立回归模型的方式,解决了梯度消失等问题,并对误差序列的估计进行修正与管理,结合更深层次的网络结构,获取了更高精度的检测结果。文献[2]将变压器的运行和维护作为实验对象,结合已有的监测数据,剔除了其中大量的伪数据,并获取了一种基于凝聚层次聚类算法的时间序列检测模型。在该模

型的基础上,确定数据类型,并通过实时监测的数据获取异常结果。文献[3]为解决高维传感器中的数据受到环境扰动影响较大的问题,获取了一阶差分信号序列的关键节点,并将空间中具备相关性的传感器实时划分到同一簇类,使用分割算法预设特征属性,获取了异常检测的判定结果。结合上述文献,本文设计了一种基于深度学习的无线传感网络高维数据异常检测方法。

## 1 基于深度学习算法建立无线传感网络数据分类模型

为获取无线传感网络数据中的分类信息,需要建立一个分类模型。首先需要使用训练及建立隔离森林,随即划分部分节点特征,在重构误差函数之后,将特定的神经网络作为解决表征向量的功能指标,同时利用三层结构建立编码网络,通过深度学习方法获取的浅层自编码器<sup>[4-5]</sup>。

在该自编码器中,编码结构与解码结构均由连接层获取,

**收稿日期:**2023-02-03

**作者简介:**胡挺峰(1973.07-),男(汉族),江苏无锡人,硕士,副教授,主要研究方向:信息安全,数据分析,神经网络等。

原始 U-Net 模型相较,在网络性能、模型识别率等方面都取得显著的提高,提取的道路结构更具有完整性、连通性。下一步研究方向可以放在模型精度优化与道路形态相结合方面。

## 参考文献:

- [1] 戴激光,王杨,等.光学遥感影像道路提取的方法综述[J].遥感学报,2020,24(07):804-823.
- [2] 贾建鑫,孙海彬,等.多源遥感数据的道路提取技术研究现状及展望[J].光学精密工程,2021,29(02):430-442.
- [3] 左娟,李勇军.结合纹理与形状特征的高分辨率遥感影像道路提取[J].测绘,2013,36(03):111-113.
- [4] 阙昊懿,黄辉先,等.基于双阈值 SSDA 模板匹配的遥感图像道路边缘检测研究[J].国土资源遥感,2014,26(04):29-33.
- [5] 谢志伟,平继伟,等.基于邻域特征的电子地图道路交叉点自动提取[J].中国科技论文,2020,15(5):599-604.
- [6] 朱芳芳,李仲勤,等.特征分量的城市建筑物面向对象提取方法[J].测绘科学,2020,45(01):84-91.
- [7] Long J, Shelhamer E, et al. Fully convolutional networks for semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition,2015: 3431-344.
- [8] Olaf Ronneberger;Philipp Fischer; et al.U-Net:Convolutional

- Networks for Biomedical Image Segmentation [J]. Medical Image Computing and Computer-Assisted Intervention-MI-CCAI 2015,2015,Vol.9351: 234-241
- [9] Badrinarayanan V, Kendall A, et al. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12):2481-249
- [10] Chen L C, Papanantidreou G, et al. Rethinking atrous convolution for semantic image segmentation[J]. arXiv preprint arXiv:1706.05587, 2017.
- [11] 林娜,张小青,等.空洞卷积 U-Net 的遥感影像道路提取方法[J].测绘科学,2021,46(09):109-114+156.
- [12] 张新华,黄梦醒,等.基于深度学习的卫星图像道路分割算法[J].计算机工程,2021,47(10):306-313.
- [13] 陈洪云,孙作雷,孔薇.融合深度神经网络和空洞卷积的语义图像分割研究[J].小型微型计算机系统,2020,41(01):166-170.
- [14] 宋廷强,刘童心,等.改进 U-Net 网络的遥感影像道路提取方法研究[J].计算机工程与应用,2021,57(14):209-216.
- [15] Q. Hou, D. Zhou and J. Feng, "Coordinate Attention for Efficient Mobile Network Design," 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition.11