

DOI:10.3969/j.issn.1003-5060.2024.04.009

# 基于改进的 U-Net 卷积神经网络的 遥感影像水体信息提取方法

宋子俊<sup>1,2</sup>, 董张玉<sup>1,2,3</sup>, 张鹏飞<sup>1,2</sup>, 张远南<sup>1,2</sup>

(1. 合肥工业大学 计算机与信息学院, 安徽 合肥 230601; 2. 工业安全与应急技术安徽省重点实验室, 安徽 合肥 230601; 3. 合肥工业大学 智能互联系统安徽省实验室, 安徽 合肥 230601)

**摘要:**针对当前遥感影像水体信息提取存在细节水体提取能力较弱、重要特征损失较大的问题,文章提出一种基于改进的 U-Net 网络实现遥感影像水体信息提取的方法。该方法首先通过引入 Resnet 残差卷积模块深化传统 U-Net 网络架构提升特征挖掘能力,并引入 Respath 残差连接模块减少跳跃连接过程中的语义差距,同时引入 PSCov 多尺度卷积模块、Eca 有效通道注意力机制模块,提高网络特征学习能力,构建 PS-Eca-Multiresunet 网络模型,弥补传统 U-Net 网络存在的细节特征提取能力较弱问题。选择“2020 年第四届中科星图杯高分遥感图像解译软件大赛”数据集进行实验,结果表明,与传统 U-Net 网络模型相比,该方法水体提取的平均交并比提高了 9.08,像素精度提升了 7.4%。改进的网络提取结果能够有效避免阴影影响,提高对细节水体的提取精度,实现遥感影像水体信息的高精度提取。

**关键词:**水体提取;深度学习;多尺度卷积;有效通道注意力机制;Multiresunet 网络

**中图分类号:**TP751.1;TP753 **文献标志码:**A **文章编号:**1003-5060(2024)04-0488-09

## Water body information extraction method for remote sensing images based on improved U-Net convolutional neural network

SONG Zijun<sup>1,2</sup>, DONG Zhangyu<sup>1,2,3</sup>, ZHANG Pengfei<sup>1,2</sup>, ZHANG Yuannan<sup>1,2</sup>

(1. School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China; 2. Anhui Province Key Laboratory of Industry Safety and Emergency Technology, Hefei 230601, China; 3. Intelligent Interconnected Systems Laboratory of Anhui Province, Hefei University of Technology, Hefei 230601, China)

**Abstract:** Aiming at the problems of weak ability to extract detailed water bodies and large loss of important features in current water body information extraction from remote sensing images, this paper proposes a method to extract water body information from remote sensing images using an improved U-Net network. The method firstly deepens the traditional U-Net network architecture by introducing the Resnet residual convolution module to improve the feature mining ability, and introduces the Respath residual connection module to reduce the semantic gap in the skip connection process, while introducing the PSCov multi-scale convolution module and Eca effective channel attention mechanism module to improve the network feature learning ability, and constructs the PS-Eca-Multiresunet network model to compensate for the shallow feature loss problem that exists in general networks. The dataset of 2020 GEOVIS Cup Gaofen Challenge on Automated High-Resolution Earth Observation Image Interpretation is selected for the experiment. The results show that the average intersection ratio of water extraction by this method is 9.08 higher than that of the traditional U-Net network model,

**收稿日期:**2021-12-23; **修回日期:**2022-02-06

**基金项目:**安徽省重点研究与开发计划资助项目(202004a07020030);安徽省自然科学基金资助项目(2108085MF233)和中央高校基本科研业务费专项资金资助项目(JZ2021HGTD0111)

**作者简介:**宋子俊(1997—),男,安徽淮南人,合肥工业大学硕士生;

董张玉(1986—),男,安徽安庆人,博士,合肥工业大学副教授,硕士生导师,通信作者, E-mail: dzyhfut@hfut.edu.cn.

and the precision of image elements is 7.4% higher than that of the traditional U-Net network model. The improved network extraction results can effectively avoid the influence of shadows, improve the extraction accuracy of detailed water bodies, and achieve high-precision extraction of water body information from remote sensing images.

**Key words:** water body extraction; deep learning; multi-scale convolution; effective channel attention mechanism; Multiresunet network

## 0 引言

近年来,数据及时存储和成像传感器技术的进步使得遥感技术得到飞速发展<sup>[1]</sup>。通过提升遥感平台监测能力,增加遥感平台数量,人们得以获得更多不同光谱、空间和时间分辨率的遥感图像<sup>[2]</sup>。水体作为生态系统中的重要组成部分,其变化会对其他自然资源和人力资产造成影响,因此遥感影像中水体信息的精准提取在自然灾害检测、城市规划、水资源管理等方面具有重要意义<sup>[3]</sup>。

传统的遥感影像水体提取方法有阈值法<sup>[4]</sup>、水体指数法<sup>[5]</sup>、决策树法<sup>[6]</sup>以及监督分类法<sup>[7]</sup>。整体而言,这些方法都存在提取结果受人为主观因素影响和提取精度较差的问题。随着深度学习的不断发展,在目标识别、语义分割和图像分类等领域以卷积神经网络(convolutional neural network, CNN)<sup>[8]</sup>和全卷积网络(fully convolutional network, FCN)<sup>[9]</sup>为代表的深度学习技术逐渐被广泛应用,文献<sup>[10]</sup>通过在FCN中引入密集连接结构,实现了遥感影像中的水体自动提取,但是其结果易受建筑阴影影响。随后 SegNet<sup>[11]</sup>、U-Net<sup>[12]</sup>等多种能够实现像素级语义分割的编码-解码(encoder-decoder)结构卷积神经网络模型被广泛用于遥感图像分类与语义分割领域,其中U-Net网络结构由于具有跳跃连接操作,能够弥补浅层特征丢失问题,被应用于遥感图像分割领域。文献<sup>[13]</sup>利用U-Net网络对遥感影像中的水体实现了较好的提取效果,但由于细节水体在图像中的表现范围较小,结果显示对较小的河道区域存在一定的漏分情况且易受建筑阴影影响。文献<sup>[14]</sup>指出U-Net网络在水体提取过程中易受山体阴影与建筑物影响,导致识别精度较低,这是由于U-Net存在构架较浅不能明确表征复杂的地物的问题。近年来,研究人员提出了注意力机制与多尺度特征融合两种方法,用以提升图像识别精度。文献<sup>[15]</sup>通过引入Resnet<sup>[16]</sup>网络加深U-Net网络构架,并通过引入注意力机制提升网络对建筑区域敏感度,提升了遥感影像建筑物提取

精度。文献<sup>[17]</sup>提出了混合深度卷积(Mix-conv),将不同尺寸的卷积核进行有效结合,提升了图像识别的准确率,但是其存在高计算量的问题。针对当前基于深度学习的水体信息提取存在的特征损失较大、网络对细节特征提取能力较弱、水体与阴影区分度较差、提取精度较低等问题,本文提出了一种基于Respath残差卷积、PSConv多尺度卷积特征融合和Eca有效通道注意力的改进U-Net网络,用于遥感影像水体信息提取。

本文提出的PS-Eca-Multiresunet(polyscale efficient channel attention-multiresunet)网络结构,用Resnet50网络替代传统U-Net网络的编码器以增加架构深度,并引入Respath模块减少不同层级的特征在跳跃连接过程中的语义差距,同时引入具有轻量化、高效性的有效通道注意力Eca机制模块<sup>[18]</sup>和PSConv多尺度卷积模块<sup>[19]</sup>,以达到增强网络对重要特征的提取能力和水体细节部分的区分能力、减小特征损失、提高水体提取精度的目的。

## 1 网络结构

在各种卷积神经网络模型中,目前编码-解码结构网络模型最常用于图像分类与语义分割领域。在常见的编码-解码结构网络模型中,编码器部分通过卷积和最大池化对图像的低级特征进行提取,得到具有更大视野域的特征图;在解码器部分由于采样而下降的分辨率特征经过卷积与反卷积得以恢复,特征图的维度逐渐恢复为与原始数据相同;同时存在跳跃连接融合上、下采样中相同维度图像的特征信息,实现对采样过程中特征信息损失的弥补。

目前提出的残差网络、多尺度卷积、注意力机制都在图像分类的精度和效率上有优秀的表现。因此本文引入Resnet残差卷积模块、PSConv多尺度卷积模块、Eca有效通道注意力机制模块、Respath残差连接模块,改进传统的U-Net网络模型,通过提升网络特征挖掘能力和学习能力来实现遥感影像水体提取精度的提高。

1.1 PS-Eca-Multiresunet 网络模型结构

本文提出的 PS-Eca-Multiresunet 网络模型结构如图 1 所示。

图 1 网络左半部分为编码结构,即图像下采样结构,它用 Resnet50 网络代替了传统 U-Net

编码结构,在输入一张分辨率为  $256 \times 256$  像素的图片后,会经过 5 层 Reslayer 残差卷积模块将遥感影像抽取成大小为  $8 \times 8 \times 2048$  的高度抽象特征图,其中各层 Reslayer 输出尺寸及组成方式见表 1 所列。

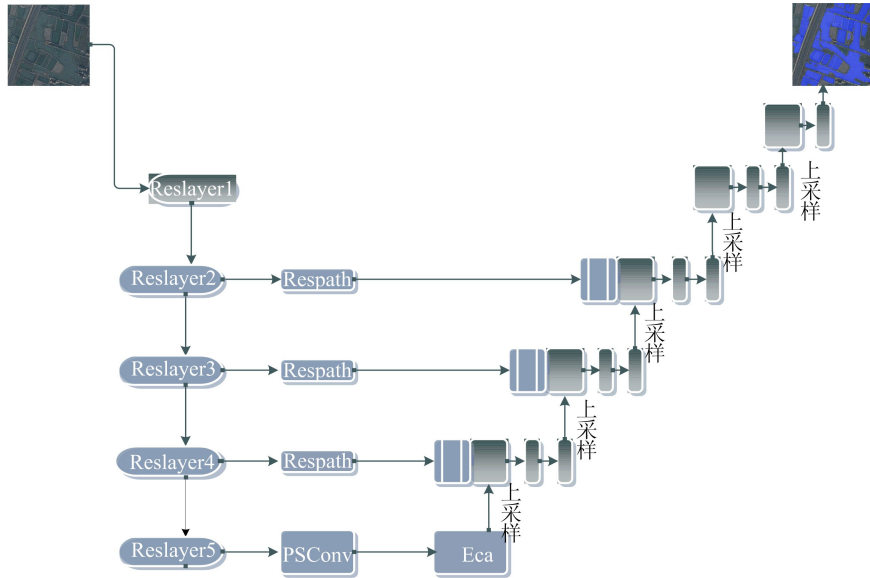


图 1 PS-Eca-Multiresunet 网络结构示意图

表 1 各层 Reslayer 输出尺寸及组成方式

模块名	输出尺寸	组成方式
Reslayer1	$128 \times 128$	1 个 $7 \times 7 \times 64$ 卷积核 1 个 $3 \times 3$ 最大池化层和
Reslayer2	$64 \times 64$	3 个 $\begin{bmatrix} 1 \times 1 \times 64 \\ 3 \times 3 \times 64 \\ 1 \times 1 \times 256 \end{bmatrix}$ 卷积块
Reslayer3	$32 \times 32$	4 个 $\begin{bmatrix} 1 \times 1 \times 128 \\ 3 \times 3 \times 128 \\ 1 \times 1 \times 512 \end{bmatrix}$ 卷积块
Reslayer4	$16 \times 16$	6 个 $\begin{bmatrix} 1 \times 1 \times 256 \\ 3 \times 3 \times 256 \\ 1 \times 1 \times 1024 \end{bmatrix}$ 卷积块
Reslayer5	$8 \times 8$	3 个 $\begin{bmatrix} 1 \times 1 \times 512 \\ 3 \times 3 \times 512 \\ 1 \times 1 \times 2048 \end{bmatrix}$ 卷积块

表 1 中:  $\begin{bmatrix} 1 \times 1 \times 64 \\ 3 \times 3 \times 64 \\ 1 \times 1 \times 256 \end{bmatrix}$  表示由 1 个大小为  $1 \times 1 \times 64$  的卷积核、1 个大小为  $3 \times 3 \times 64$  的卷积核和 1 个大小为  $1 \times 1 \times 256$  的卷积核按残差卷积块

方式连接,具体如图 2 所示;其他同理。

随后通过 PSConv 模块和 Eca 机制模块对得到的高度抽象特征图进行多尺度卷积,以提高特

征利用度,弥补特征损失并提升网络对重要特征的提取能力。




图 2 残差卷积方式示意图

图 1 网络右半部分为解码结构,它由一系列的上采样层构成。其核心为与下采样相对应的 5 组上采样与卷积。每一组上采样层对上一层进行  $2 \times 2$  反卷积上采样得到的深层特征与左侧 Reslayer 下采样过程中相同长宽特征图,通过 Concatenate 方式进行融合,即维度的融合,再进行 2 次大小为  $3 \times 3$  的卷积,从而恢复了特征图细节并保证其相应的空间信息维度不变。其中下采样过程中得到的特征图通过 Respath 模块与相对

应的上采样层进行残差连接。最后将经过 5 层上采样与卷积的融合特征图进行一次大小为  $3 \times 3$  的卷积得到输出图像,实现遥感影像水体提取。

### 1.2 Respath 模块

在传统 U-Net 网络中,卷积层的输出在编码器进行池化操作之前通过跳过连接被传输到解码器。然后将这些特征图与上采样操作的输出连接起来,并将连接起来的特征图传播到后续的层,以弥补池化操作期间丢失的空间信息。然而由于合并的两组特征之间可能存在语义差距,从而导致这两组不相容的特征融合可能会在整个学习过程中造成一些差异,继而对预测过程产生不利影响。本文使用 Respath 连接减小跳跃连接过程中的语义差距,其结构如图 3 所示,输入  $x$  分别经过 1 个  $3 \times 3$  卷积和 1 个  $1 \times 1$  卷积并将卷积结果相加且赋予其一个权重后与原输入相加得到结果  $x_2$ ,  $x_2$  经过相同操作后得到结果  $x_3$ ,对  $x_3$  赋予权重并与原输入  $x$  相加即可得到最终输出。它不是简单地将特征映射从编码器阶段连接到解码器阶段,而是首先将它们通过带有残差连接的卷积层链,然后再与解码器特征连接。这使得编码器的特征要经过更多的处理,从而减小合并的两组特征之间的语义差距,增强网络的学习能力,提高遥感影像中水体的提取精度。




图 3 Respath 模块结构示意图

### 1.3 PSConv 模块

虽然 CNN 具有极强的建模能力,但其存在尺度敏感特性。为增强 CNN 的尺度鲁棒性,多尺度特征融合受到了极大关注。目前以 Mixconv 为代表的多尺度特征融合往往采用多个不同尺寸的卷积核进行融合,而忽视了核空间的更细粒度的利用。从具体的卷积方式来看,常规卷积采用特征金字塔样式进行特征融合;目前流行的 Mixconv 卷积方式通过对输入输出通道分组,不同组使用不同的卷积核提取特征后再进行特征融合。本文所用的 PSConv 通过在输入输出通道中具有周期变化性的卷积核进行卷积,在同一个卷积核内实现多尺度的特征提取。以  $F \in \mathbf{R}^{C_{in} \times H \times W}$

表示形状为  $C_{in} \times H \times W$  输入特征图,其中:  $C_{in}$  为通道数;  $H$  和  $W$  分别为高度和宽度。将  $C_{out}$  个滤波器与输入特征图分别卷积,用以获得通道数为  $C_{out}$  的期望输出特征图,为了匹配输入特征图中的通道数,每个滤波器都有  $C_{in}$  个核大小为  $K \times K$  的卷积核,用  $G \in \mathbf{R}^{C_{out} \times C_{in} \times K \times K}$  表示上述滤波器。 $H \in \mathbf{R}^{C_{out} \times H \times W}$  表示通道数为  $C_{out}$ 、高度和宽度分别为  $H$  和  $W$  的输出特征图。则常规卷积和 PSConv 卷积分别定义为:

$$H_{c,x,y} = \sum_{k=1}^{C_{in}} \sum_{i=-K'}^{K'} \sum_{j=-K'}^{K'} G_{c,k,i,j} F_{k,x+i,y+j} \quad (1)$$

$$H_{c,x,y} = \sum_{k=1}^{C_{in}} \sum_{i=-K'}^{K'} \sum_{j=-K'}^{K'} G_{c,k,i,j} F_{k,x+d_{c,k},y+d_{c,k}} \quad (2)$$

其中:  $K' = \frac{K-1}{2}$ ;  $H_{c,x,y}$ 、 $G_{c,k,i,j}$ 、 $F_{k,x+i,y+j}$  分别为  $H \in \mathbf{R}^{C_{out} \times H \times W}$ 、 $G \in \mathbf{R}^{C_{out} \times C_{in} \times K \times K}$ 、 $F \in \mathbf{R}^{C_{in} \times H \times W}$  中的一个元素;  $D_{c,k}$  为膨胀率  $D \in \mathbf{R}^{C_{out} \times C_{in}}$  中的一个元素;  $c$  为输出通道数;  $k$  为输入通道数;  $x, y$  分别为输入特征元素高度和宽度;  $i, j$  分别为滤波器元素高度和宽度。

由以上分析可以看出, PSConv 混合了不同的扩张因子并将其置于卷积核的不同位置,通过扩张因子集合沿输入和输出通道的轴周期性循环,达到集成不同尺度特征的目的。基于 PSConv 的以上优势,本文引入 PSConv 模块。编码器部分得到的高度抽象特征图通过 PSConv 模块进行多尺度特征后传送到解码器部分进行上采样,从而提高了特征提取精度,并且有效避免了传统多尺度特征融合的高计算量问题,实现了遥感影像中水体的快速精确提取。

### 1.4 Eca 机制模块

本文通过嵌入 Eca 机制模块使得网络拥有注意力,即对类别区分度较为明显的特征提高关注的同时,对具有明显类间相似度的特征进行抑制,从而实现网络特征学习能力的加强。Eca 机制模块结构如图 4 所示。




图 4 Eca 机制模块结构示意图

图 4 中,  $X \in \mathbf{R}^{H \times W \times C}$  是高度、宽度和通道数分

别为  $H$ 、 $W$ 、 $C$  的输入特征图,通过挤压操作,利用全局平均池化(global average pool, GAP)对全局信息进行收缩,使其被包含于一个通道描述符中。通过对空间维数  $H \times W$  进行压缩操作,产生一个  $1 \times 1 \times C$  的特征对整张图像进行表达。与 SE 注意力机制不同, Eca 注意力机制只考虑每个通道与  $k$  个相邻通道之间的交互作用,同时为了使模型复杂度降低,所有通道可以共享相同的参数,那么第  $i$  个通道  $y_i$  的权重  $\rho_i$  可表示为:

$$\rho_i = \sigma\left(\sum_{j=1}^k w^j y_i^j\right), y_i^j \in \Omega_i^k \quad (3)$$

其中:  $\Omega_i^k$  为与  $y_i$  相邻的  $k$  个通道的集合;  $\sigma(\cdot)$  为 Sigmoid 函数;  $\rho_i$  为通道包含的遥感影像特征的重要程度,模型对第  $i$  个通道关注度越高,与该通道对应的  $\rho_i$  就越大,建模特征之间就越相关。因此, Eca 机制模块可以由一个卷积核大小为  $k$  的一维卷积快速实现,其公式为:

$$\rho = \sigma(\text{C1D}_k(y)) \quad (4)$$

其中:  $\rho$  表示权重;  $y$  表示通道; C1D 表示一维卷积;  $k$  表示对应卷积核大小,并由关于通道数  $C$  的函数进行自适应确定。  $k$  表示局部跨通道间交互作用所覆盖的范围,其公式为:

$$k = \left\lfloor \frac{\text{lb } C}{2} + \frac{1}{2} \right\rfloor_{\text{odd}} \quad (5)$$

其中,  $|x|_{\text{odd}}$  表示最接近  $x$  的奇数。

从式(5)可以看出,该模块通过快速一维卷积产生通道注意,其卷积核大小可由通道维数的函数自适应确定。通过编码器部分得到的高度抽象特征图,经过 Eca 注意力机制模块对每个通道赋予不同的权重。通道权重越大,提取到的特征类别越容易进行区分;通道权重越小,所提取的特征类间相似度越明显,从而提升了网络对重要特征的提取能力。

## 2 数据与实验

### 2.1 数据

本文实验所用的数据集源于“2020 年第四届中科星图杯高分遥感图像解译软件大赛”。该数据集中包含 1 000 张大小为  $256 \times 256$  像素的高分二号水体光学数据,将数据集中 800 张水体影像用于训练,200 张水体影像用于模型训练精度验证。

对训练数据进行标签预处理,二值化标注影像中的水体与非水体,即水体部分用 1 进行标注,非水体部分用 0 进行标注,部分水体影像及标签

如图 5 所示。



图 5 水体影像数据集示例

### 2.2 实验流程

实验首先对遥感影像数据进行标签预处理,随后在 PS-Eca-Multiresunet 网络中注入预处理过的训练数据,不断调节得到合适的参数,获得先验模型。为了验证模型的水体提取精度,将未参与训练的 200 张测试集影像注入训练后的网络模型进行水体提取实验。同时为了验证本文所提方法在含有建筑物阴影、树木阴影等场景复杂区域中区分阴影与细节水体的能力,从测试结果中选取 3 种复杂区域影像的提取结果与 U-Net 等网络模型对相同影像数据的提取结果进行对比。3 种复杂区域分别为:河流、水塘、建筑混合区域;河流、湖泊、建筑混合区域;细小河流。

### 2.3 实验评价指标

本实验选用像素精度(pixel accuracy,  $P_A$ )、均交并比(mean intersection over union,  $M_{IoU}$ )进行精度评价。像素精度的含义是总像素数中预测正确的像素数量占的比例,它是一种计算预测值与实际值之间匹配的像素比例的评价指标,该值越大表示正确预测的像素数量占总像素数的比例越大,预测值与实际值的像素匹配度越高,即图像识别精确度越高。 $P_A$  的计算公式为:

$$P_A = \frac{\sum_{i=0}^n P_{ii}}{\sum_{i=0}^n \sum_{j=0}^n P_{ij}} \quad (6)$$

其中:  $i, j$  为行、列号;  $n$  为每行每列的最大值;  $P_{ii}$  为正确提取的像素数量;  $P_{ij}$  为  $i$  被预测为  $j$  的像素数量,即分母表示总像素数量。

均交并比是语义分割常用的评价指标,反映了预测值与真实值之间的交集平均值,比值越接近 1 则重合度越高,即语义分割质量越高,其计算公式为:

$$M_{IoU} = \frac{1}{N+1} \sum_{i=0}^n \frac{P_{ii}}{\sum_{j=0}^n P_{ij} + \sum_{j=0}^n P_{ji} - P_{ii}} \quad (7)$$

其中:  $N$  为提取类别数目;  $P_{ii}$  为匹配像元的数目;  $P_{ij}$  为  $i$  被错误预测为  $j$  的数目;  $P_{ji}$  为  $j$  被错误预测为  $i$  的数目;  $n$  为每行每列的最大值。

## 2.4 实验环境

本文所使用程序开发平台为 Visual Studio Code, 选用 Python 作为开发语言, 版本为 3.7.10。深度学习框架为 Pytorch 1.9.0, Conda 4.9.2。学习率设置为  $10^{-4}$ , 训练批次设置为 40, 优化器为 Adam。

实验硬件平台为 2.3 GHz 八核 16 线程 Inter

Core i7-10875H CPU, 内存为 16 GiB, 显卡为 6 GiB 的 NVIDIA RTX2060 显卡, 实验操作系统为微软 Windows 10 家庭中文版。

## 3 结果与讨论

### 3.1 结果对比

3 种区域在不同网络下的提取结果, 其中明显改善部分用红框标出。

区域 A(河流、水塘、建筑混合区域)的水体提取结果如图 6 所示。

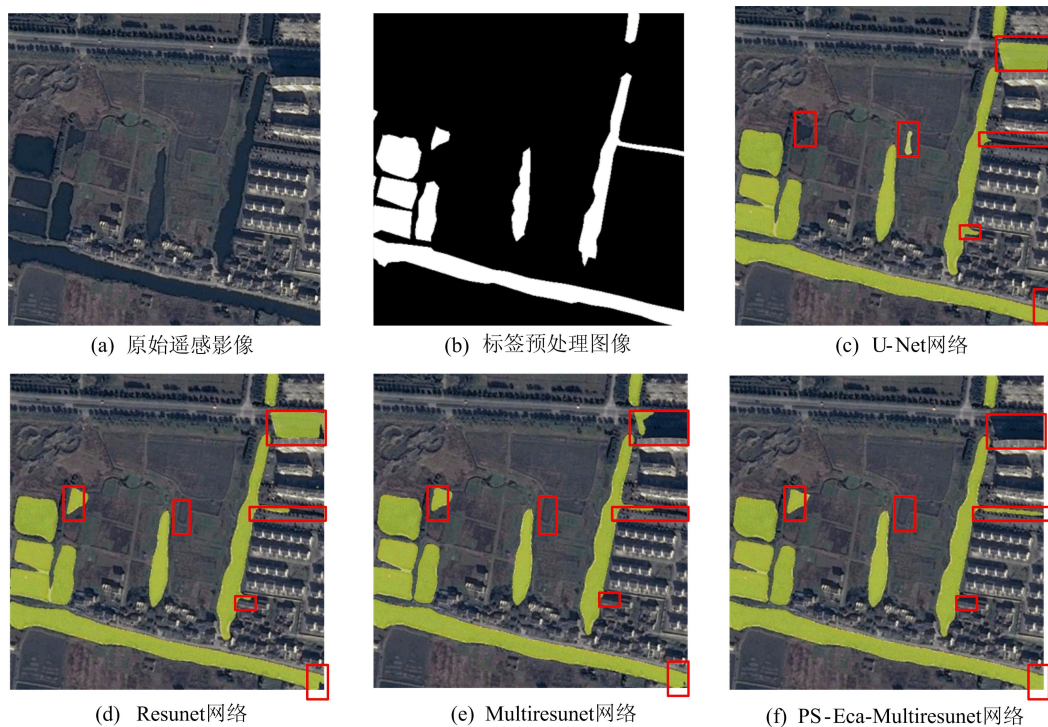


图 6 区域 A 水体提取结果

从图 6 可以看出: 在图片中间部分, 传统 U-Net 网络对水塘区域水体提取有明显缺失和误分, 引入残差卷积后的 Resunet 网络可以较好地提取出河流及水塘等面积较大水体, 但在细节水体方面, 本文提出的 PS-Eca-Multiresunet 网络具有更好地提取精度; 图片中间右侧上方红框部分, 传统 U-Net 网络和引入残差卷积的 Resunet 网络将建筑之间阴影误分为水体, 引入 Respath 连接和残差卷积后的 Multiresunet 网络误分区域明显减少, 但仍有小部分残留, 改进后的 PS-Eca-Multiresunet 网络则很好地区分出水体与房屋阴影; 对于建筑物之间的细小河道, 图片中部右侧红框部分, PS-Eca-Multiresunet 有更完整的提取效果。同时从图中右下角红框可以看出, 随着各个模块的增加, 网络对河流的提取更加完整。

区域 B(河流、湖泊、建筑物混合区域)的水体提取结果如图 7 所示。

从图 7 可以看出: 在图片左上方红框河流区域, 传统 U-Net 网络有明显提取缺失, 引入残差卷积后的 Resunet 网络误分情况大大减少, 而改进后的 Multiresunet 网络和 PS-Eca-Multiresunet 都很好地完成了提取; 从图片右方及中部下方红框部分可以看出, 随着各个模块的引入, 网络对河流的提取完整度不断提高且能较好地对河流与土地接触部分进行区分; 从图片中部红框可以看出, 引入 PSConv 及 Eca 机制模块后, 本文所提出网络能够有效区分建筑物阴影与水体, 避免阴影对精确度的影响。

区域 C(细小河流)的水体提取结果如图 8 所示。

从图 8 可以看出:与传统 U-Net 网络、Resunet 网络和 Multiresunet 网络相比,PS-Eca-Multiresunet 网络对细节水体有更好的提取效果,如图片中部的细小河流,本文网络的提取效果更加完整;对于图片左上角与右下角红框内的河流区域,U-Net 网络提取完整度不高,通过引入各模块后网络能够更完整地提取出河流;在图片左侧靠上红框部分,传统 U-Net 网络和 Resunet 网络仍

存在将房屋阴影错误分类为水体的情况,Multi-resunet 网络大大减少了误分阴影区域面积,而 PS-Eca-Multiresunet 网络则很好地避免了这一错误;位于图片左侧靠下红框部分的水塘,人工目视解释的标签预处理图像存在漏分现象,而 4 种网络均对其进行了有效提取,说明了基于卷积神经网络的水体提取方法可以有效避免人为因素造成的误差。

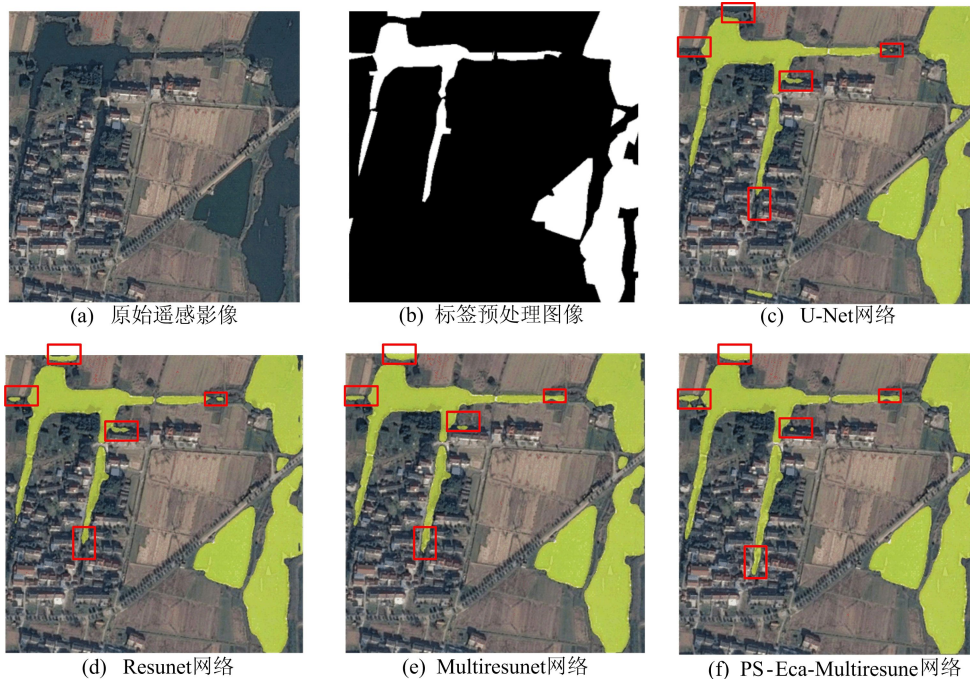


图 7 区域 B 水体提取结果

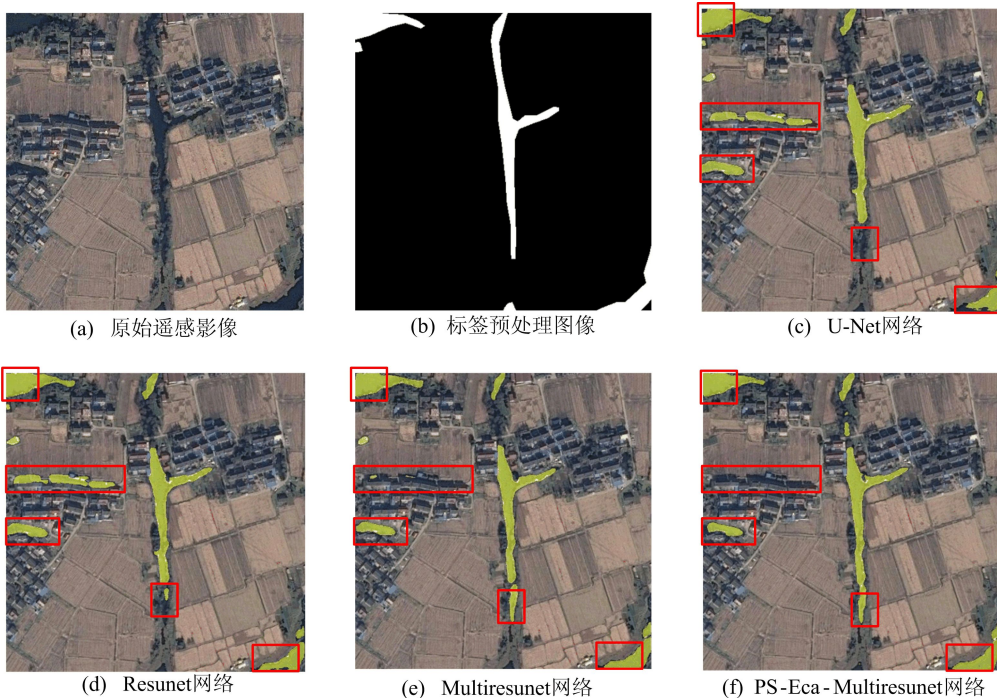


图 8 区域 C 水体提取结果

### 3.2 讨论

本文使用均交并比和像素精度评价 4 种网络结构对水体的提取结果,见表 2 所列。

表 2 4 种网络结构对水体信息提取精度对比

网络结构	$M_{IoU}$	$P_A/\%$	测试时间/s
U-Net	78.86	91.02	18
Resunet	83.64	95.24	24
Multiresunet	86.27	96.58	25
PS-Eca-Multiresunet	87.94	97.79	28

由表 2 可知,本文提出的 PS-Eca-Multiresunet 网络结构在均交并比和像素精度 2 个指标上与传统 U-Net 网络结构、引入残差卷积和残差连接的 Resunet 网络和 Multiresunet 网络结构相比都有明显提升。以传统 U-Net 网络结构为基准,只引入残差卷积的 Resunet 网络交并比提升了 4.78,像素精度提升了 4.6%;引入残差连接和残差卷积的 Multiresunet 网络结构交并比提升了 7.41,像素精度提升了 6.1%;本文提出的 PS-Eca-Multiresunet 网络结构均交并比提升了 9.08,像素精度提升了 7.4%。结合上文的结果可以看出,与传统的 U-Net 网络结构相比,本文提出的 PS-Eca-Multiresunet 网络结构对遥感影像中水体和房屋阴影区分效果较好,细小河流水体边缘分割更准确,水体的提取精度更高。本文方法通过 Reslayer 残差卷积模块深化网络结构对大量遥感影像水体深层特征进行挖掘,同时通过 Respath 连接模块减小跳跃连接过程中的语义差距,并通过 PSConv 机制模块和 Eca 机制模块提升网络特征学习能力,使得本文提出的 PS-Eca-Multiresunet 网络结构在面对细节的水体信息时拥有更强的敏感程度,从而实现水体提取精度的提升。

4 种网络结构的水体提取测试所用时间见表 2 所列。由表 2 可知:U-Net 耗时最短,仅用 18 s 即完成测试;Resunet 和 Multiresunet 分别增加了残差卷积和 Respath 连接模块,故而耗时有增加;PS-Eca-Multiresunet 由于在 Multiresunet 基础上又增加了 PSConv 模块和 Eca 机制模块,卷积运算数量最多,网络复杂度最高,因此在 4 种网络结构中耗时最长,但只比耗时最少的 U-Net 多了 10 s,仍具有较高的工业应用价值。

## 4 结 论

针对当前遥感影像水体信息提取存在的细节水体提取能力较弱、重要特征损失较大的问题,本

文提出了一种新的 PS-Eca-Multiresunet 网络结构。通过利用残差卷积和残差连接提高了传统 U-Net 网络特征挖掘能力,通过引入 PSConv 模块和 Eca 机制模块提高了传统 U-Net 网络特征学习能力。实验结果表明,与利用传统 U-Net 网络进行遥感影像水体信息提取相比,本文提出的利用 PS-Eca-Multiresunet 网络提取方法均交并比提高了 9.08,像素精度提升了 7.4%,因此本文方法可以有效提取细节特征,提升提取精确度,实现了遥感影像水体信息提取的准确性。

### [参 考 文 献]

- [1] SINGH A. Review article digital change detection techniques using remotely-sensed data[J]. International Journal of Remote Sensing, 1989, 10(6): 989-1003.
- [2] JOHN R, CHEN D. Remote sensing technology for mapping and monitoring land-cover and land-use change[J]. Progress in Planning, 2004, 61(4): 301-325.
- [3] 何海清, 杜敬, 陈婷, 等. 结合水体指数与卷积神经网络的遥感水体提取[J]. 遥感信息, 2017, 32(5): 82-86.
- [4] 李霄, 李霖, 翁敏, 等. 基于资源三号卫星的洪灾发生后水体提取研究[J]. 测绘地理信息, 2018, 43(3): 115-118.
- [5] 杨骥, 韩留生, 陈水森, 等. 一种基于城市水体指数与分形几何算法的 OLI 遥感影像水体提取方法[J]. 测绘通报, 2018(4): 44-49.
- [6] 张红梅, 王大卫, 高杨, 等. 基于 OLI 数据与决策树法的去山体阴影水体信息提取研究[J]. 测绘工程, 2017, 26(11): 45-48.
- [7] 王碧晴, 王珂, 廖伟逸. 遥感影像分割下的青藏高原湖泊提取[J]. 遥感信息, 2018, 33(1): 117-122.
- [8] HU F. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery[J]. Remote Sensing, 2015, 7(11): 14680-14707.
- [9] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [10] 梁泽毓, 吴艳兰, 杨辉, 等. 基于密集连接全卷积神经网络的遥感影像水体全自动提取方法[J]. 遥感信息, 2020, 35(4): 68-77.
- [11] 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.
- [12] 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 Lecture Notes in Computer Science. [S. l. : s. n. ], 2015: 234-241.

(下转第 515 页)

- [20] 中华人民共和国国土资源部. 土壤和沉积物13个微量元素形态顺序提取程序:GB/T 25282—2010[S]. [出版地不详:出版者不详],2010:1-4.
- [21] 中华人民共和国国家卫生和计划生育委员会. 食品安全国家标准 食品中多元素的测定:GB 5009.268—2016[S]. [出版地不详:出版者不详],2016:1-5.
- [22] 全国土壤普查办公室. 中国土壤[M]. 北京:中国农业出版社,1998:356.
- [23] WILDING L P. Spatial variability: its documentation, accommodation and implication to soil surveys[C]//Soil spatial variability. Las Vegas NV:[s. n.],1985:166-194.
- [24] 张传琦. 土壤中重金属砷、镉、铅、铬、汞有效态浸提剂的研究[D]. 合肥:安徽农业大学,2011.
- [25] 熊礼明,鲁如坤. 土壤有效Cd浸提剂对Cd的浸提机制[J]. 环境化学,1992,11(3):41-47.
- [26] 鲁成秀. 富营养化湖泊沉积物:水界面重金属释放的生物化学过程研究[D]. 济南:山东师范大学,2016.
- [27] 杨金燕,杨肖娥,何振立. 采用浸提法探讨土壤中外源铅的生物有效性[J]. 环境生态学,2020,2(9):31-37.
- [28] 张羽. 土壤中重金属钒生物有效性的分析方法研究[D]. 济南:山东师范大学,2014.
- [29] 周国华. 土壤重金属生物有效性研究进展[J]. 物探与化探,2014,38(6):1097-1106.
- [30] 刘情,陈红燕,唐豆豆,等. 苏南典型区土壤水稻系统中重金属迁移特征及定量模型研究[J]. 环境科技,2016,29(4):20-25.
- [31] LI H, LUO N, LI Y W, et al. Cadmium in rice: transport mechanisms, influencing factors, and minimizing measures [J]. Environmental Pollution, 2017, 224: 622-630.
- [32] 武文飞,南忠仁,王胜利,等. 绿洲土Cd、Pb、Zn、Ni复合污染下重金属的形态特征和生物有效性[J]. 生态学报,2013,33(2):619-630.
- [33] 杨宏伟,王明仕,徐爱菊,等. 黄河(清水河段)沉积物中锰、钴、镍的化学形态研究[J]. 环境科学研究,2001,14(5):20-22.
- [34] 沈志勇. 南京市郊土壤重金属形态特征及生物累积研究[D]. 南京:河海大学,2007.
- [35] ZHANG Q, ZHANG L, LIU T, et al. The influence of liming on cadmium accumulation in rice grains via iron-reducing bacteria [J]. Science of the Total Environment, 2018, 645: 109-118.
- [36] 范晶晶,许超,王辉,等. 3种有机物料对土壤镉有效性及水稻镉吸收转运的影响[J]. 农业环境科学学报,2020,39(10):2143-2150.
- [37] AKOUMIANAKI-IOANNIDOU A, PAPANIMITRIOU K, BAROUCHAS P, et al. The effects of Cd and Zn interactions on the concentration of Cd and Zn in sweet bush basil (*Ocimum Basilicum* L.) and peppermint (*Mentha piperita* L.) [J]. Fresenius Environmental Bulletin, 2015, 24(1):77-83.
- [38] 赵转军. 共存元素影响下干旱区绿洲土壤:蔬菜系统中Cd污染化学行为的盆栽实验研究[D]. 兰州:兰州大学,2010.
- [39] 颜世红,吴春发,胡友彪,等. 典型土壤中有效态镉CaCl<sub>2</sub>提取条件优化研究[J]. 中国农学通报,2013,29(9):99-104.

(责任编辑 吴亮)

## (上接第495页)

- [13] 郑泰皓,王庆涛,李家国,等. 基于深度学习的高分六号影像水体自动提取[J]. 科学技术与工程,2021,21(4):1459-1470.
- [14] 何红术,黄晓霞,李红春,等. 基于改进U-Net网络的高分遥感影像水体提取[J]. 地球信息科学学报,2020,22(10):2010-2022.
- [15] 李传林,黄风华,胡威,等. 基于Res-AttentionUnet的高分辨率遥感影像建筑物提取方法[J]. 地球信息科学学报,2021,23(12):2232-2243.
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2016: 770-778.
- [17] TAN M, LE Q V. MixConv: mixed depthwise convolutional kernels[EB/OL]. [2020-08-02]. <http://arxiv.org/pdf/1907.09595.pdf>.
- [18] WANG Q, WU B, ZHU P, et al. Ecanet: efficient channel attention for deep convolutional neural networks[C]//Proceedings of 2020 IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2020: 11531-11539.
- [19] LI D, YAO A, CHEN Q. PSConv: squeezing feature pyramid into one compact Poly-Scale convolutional layer[C]//Proceedings of 2020 European Conference on Computer Vision. [S. l.]: s. n., 2020: 615-632.

(责任编辑 李凯)