

基于改进UNet++的洪水区域图像分割算法

姬正杰, 魏霖静

(甘肃农业大学 信息科学技术学院, 甘肃 兰州 730070)

摘要: 精准识别与划定可能受到洪水影响的地区对于规划与实施防洪措施十分重要。针对洪水区域识别过程中易受到地形、气候、光照以及数据不平衡等因素影响的问题, 提出一种基于改进UNet++的洪水区域图像分割算法。该算法以UNet++分割网络为基础框架, 在每层解码器的第一个卷积单元后嵌入空洞空间金字塔池化以得到新的解码特征; 同时通过密集连接和跳跃连接将不同解码路径的特征融合, 采用Lovasz Hinge Loss损失函数来获取全局最优并采用数据增强的方式对原有数据进行扩充。实验结果表明, 该算法在Flood Area Segmentation数据集上的IOU值达到80.53%, 与目前流行的图像分割算法DeepLabv3、UNet、FCN(Res18)、PspNet、FCN(Res50)、UNet++相比, 依次高出7.41、6.21、3.81、3.70、1.92、1.82个百分点。该算法具有较高的分割精度和良好的稳定性, 整体性能优异, 为实际防洪监测提供了技术支持。

关键词: 洪水; 图像分割; 卷积神经网络; UNet++; 空洞空间金字塔池化

DOI: 10.11907/rjdk.241448

开放科学(资源服务)标识码(OSID):

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2025)006-0168-07



Flood Region Image Segmentation Algorithm Based on Improved UNet++

Ji Zhengjie, Wei Linjing

(College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China)

Abstract: Accurately identifying and delineating areas that may be affected by floods is crucial for planning and implementing flood control measures. A flood area image segmentation algorithm based on improved UNet++ is proposed to address the problem of being easily affected by factors such as terrain, climate, lighting, and data imbalance in the process of identifying flood areas. This algorithm is based on the UNet++ segmentation network framework, and embeds a hollow space pyramid pooling after the first convolution unit of each decoder layer to obtain new decoding features; At the same time, the features of different decoding paths are fused through dense connections and skip connections, and the Lovasz Hint Loss function is used to obtain the global optimum. The original data is then expanded through data augmentation. The experimental results show that the IOU value of this algorithm on the Flood Area Segmentation dataset reaches 80.53%, which is 7.41, 6.21, 3.81, 3.70, 1.92, and 1.82 percentage points higher than the currently popular image segmentation algorithms DeepLabv3, UNet, FCN (Res18), PspNet, FCN (Res50), and UNet++, respectively. The proposed algorithm has high segmentation accuracy and good stability, with excellent overall performance, providing technical support for practical flood control monitoring.

Key Words: flood; image segmentation; convolutional neural networks; UNet++; atrous spatial pyramid pooling

0 引言

洪水灾害是当今发生最为频繁的自然灾害之一, 因其影响范围广、造成的损失大等特点, 常对国民经济和人民生命财产安全带来严重威胁^[1]。洪水区域监测主要依赖遥

感图像, 然而遥感图像的分割任务存在很多挑战, 如易受到光照、云层遮挡等因素的影响, 导致图像中存在大量噪声和不规则性, 增加了分割难度。遥感图像本身也具有复杂的地物类型、纹理和光谱特征等, 亦会影响分割效果。精准识别与划定可能受到洪水影响的地区有助于规划和实施防洪措施, 更好地制定应急计划和资源调配策略, 减

收稿日期: 2024-05-11

扫描二维码阅读全文:



基金项目: 甘肃省重点研发计划项目(23YFWA003); 移动通信国家重点实验室开放课题(2023D15)

作者简介: 姬正杰(1996-), 男, 甘肃农业大学信息科学技术学院硕士研究生, 研究方向为深度学习、计算机视觉; 魏霖静(1977-), 女, 博士, 甘肃农业大学信息科学技术学院教授, 研究方向为农业大数据、智能计算。

少洪灾造成的不良影响。因此,研究快速准确的洪水区域图像分割算法十分必要。

1 相关工作

1.1 传统图像分割方法

传统的图像分割方法包括基于阈值、边缘、区域以及聚类的方法。其中,基于阈值的图像分割方法是对图像灰度直方图进行分类,灰度值在同一范围内的像素归为同一类^[2-4]。基于边缘的图像分割方法可分为串行边缘检测和并行边缘检测两种^[5]。并行边缘检测直接借助微分算子进行卷积实现分割,分割效果较好,是常用的边缘检测方法,包括LoG、Canny等^[6-7]。基于区域的图像分割方法根据图像的空间信息进行分割,通过像素的相似性特征对像素点进行聚类并构成区域,常见的方法包括区域生长法和分裂合并法^[8-9]。基于聚类的图像分割方法根据特征相似性对像素或区域进行分组来实现分割,包括K-means、模糊C均值等。传统图像分割方法需要大量标注数据,在增加成本的同时降低了模型的泛化能力,而且对复杂图像的分割效果不佳。

1.2 基于深度学习的图像分割方法

随着深度学习技术的快速发展,全卷积神经网络(Fully Convolutional Networks, FCN)作为语义分割的开创之作,奠定了图像分割的基准框架^[10]。随后, Ronneberger等^[11]提出编码器—解码器结构的UNet网络,并通过跳跃连接的方式联系浅层与深层特征信息,提高了整体分割性能。Zhao等^[12]提出的PSPNet结合上下文信息,通过金字塔池化模块将局部与全局信息融合,增强了特征表达能力,并提高了分割精度。Chen等^[13]提出一种atrous卷积,扩大了卷积核的感受野,且在不增加参数数量和计算量的同时融合了多尺度特征。Zhou等^[14]提出的UNet++继承了UNet的编码器—解码器结构,在此基础上引入跳跃连接和密集连接,使得网络能够获得更多细粒度特征信息。

目前,基于深度学习的图像分割方法在洪水区域分割与检测中得到了一定应用。例如,姜佩奇等^[15]提出一种融合大场景点云分割与深度学习的洪水风险快速模拟方法,通过数据采集与预处理、点云分割方法提高了洪水风险测绘的建模与分析精度。李建柱等^[16]设计了嵌入注意力机制的UNet网络,在量级较大的降雨和洪水预报方面取得较高精度。崔震等^[17]将长短时记忆神经网络嵌入至编码器—解码器结构中,同时采用贝叶斯概率预报处理器量化洪水预报不确定性,提出一种三峡入库洪水概率预报方法。孙书腾等^[18]同时构建了UNet网络和HRNet网络在Sen1Flood11标准数据上进行训练,然后评估其在测试集上的性能,研究结果表明HRNet在独立测试数据集上的提取精度为91%,在真实洪水事件检测中展现出较强的泛化能力,可提供接近实时的洪水测绘服务。汪松松等^[19]构建

了基于循环神经网络与长短时记忆神经网络的洪灾水位预测模型,通过调整学习速率与步长逐步降低模型误差,在小流域山洪水位预测的实时性与准确性方面取得较好效果。

虽然上述研究取得了一定成果,但是洪水区域遥感图像依然存在噪声干扰显著、灰度分布不均等问题,分割精度仍有提升空间^[20]。为此,本文提出一种基于改进UNet++的洪水区域遥感图像分割算法AUNet++。首先,通过密集连接和跳跃连接使网络中的信息传递更加直接和密集,有助于加快信息传播速度,使模型更容易学习到复杂的特征;其次,将空洞空间金字塔池化(Atrous Spatial Pyramid Pooling, ASPP)模块嵌入到UNet++网络结构中每层解码器的第一个卷积单元后,利用多尺度融合和跳跃连接结构更好地捕捉目标对象的上下文信息,提高模型对目标的理解和表达能力;再次,采用Lovasz Hinge Loss损失函数辅助模型更快找到全局最优,通过数据增强的方式解决数据量少的问题;最后,通过特征融合整合不同路径提取到的特征,得到最终分割结果。

2 模型构建

AUNet++模型结构如图1所示。该模型主要包括编码器、解码器、ASPP以及深度监督模块。以下逐一介绍各模块的运行机制。




Fig. 1 AUNet++ model structure

图1 AUNet++模型结构

2.1 编码器与解码器

UNet网络是在FCN的基础上开发而来的,因结构为U形状而得名,拥有一个对称的编码器和解码器结构,中间为跳跃连接。其中,编码器进行图像的下采样,负责捕获图像的全局特征和上下文信息,帮助网络学习图像的抽象表示;解码器进行图像的上采样,负责将抽象表示转换回原始输入图像的分辨率,并精细化分割结果。然而,传统

的UNet网络存在参数量大、深度浅、全局空间信息易损失等问题,不仅会导致网络模型占用内存较大,而且会降低图像边界的分割精度,影响普适性与扩展性。因此,本文以同样采用编码器—解码器架构的UNet++为基准模型,通过引入密集连接,允许每一层的特征图与之前所有层的特征图直接连接在一起,使得每一层都能够直接访问前面所有层的信息,从而增强了特征的复用性和信息传递能力,有助于缓解梯度消失问题,提高网络的非线性建模能力。AUNet++模型将原UNet++网络中解码器部分的 $X^{0,1}$ 、 $X^{1,1}$ 、 $X^{2,1}$ 、 $X^{3,1}$ 特征分别进行ASPP操作,得到不同尺度的特征信息,生成新的解码特征,然后进行后续的密集连接和跳跃连接操作。假设 $x^{i,j}$ 代表 $x^{i,j}$ 节点的输出特征图, $x^{i,j}$ 的计算公式为:

$$x^{i,j} = \begin{cases} H(x^{i-1,j}), j = 0 \\ H([\mathbf{x}^{i,k}]_{k=0}^{j-1}), u(x^{i+1,j-1}), j > 0 \end{cases} \quad (1)$$

式中: i 表示下采样过程中的第 i 层; j 表示相同深度的连接层中第 j 个卷积单元; $H()$ 表示带有激活函数的卷积运算; $u()$ 表示上采样过程; $[]$ 表示叠加操作。

2.2 ASPP

在传统的卷积神经网络中,特征图感受野大小一般通过卷积核大小和池化操作来控制。然而,通过增加卷积核大小来增大感受野会使网络参数量和计算量大幅度增加,从而增加了模型的复杂度与计算成本。此外,池化操作也会影响特征图尺寸大小,可能会导致特征信息丢失。为解决上述问题,本文引入空洞卷积来解决图像密集分割问题。与传统卷积不同的是,空洞卷积引入扩张率(Dilation Rate)的概念,定义了卷积核在处理数据时各值的间距。具体如图2所示。




Fig. 2 Atrous convolution

图2 空洞卷积

图2中,大网格框表示特征图,黑色圆点表示大小为 3×3 的卷积核,灰色网格框表示进行卷积操作后的感受野。图2(左)表示扩张率为1的空洞卷积,卷积后的感受野为3,这也是传统卷积的感受野。图2(中)表示扩张率为2的空洞卷积,卷积后的感受野为7。图2(右)表示扩张率为4的空洞卷积,卷积后的感受野为15。感受野的计算公式为:

$$k' = k + k(k-1) \times (d-1) \quad (2)$$

$$RF_{i+1} = RF_i + (k' - 1) \times S_i \quad (3)$$

$$S_i = \prod_{i=1}^i \text{Stride}_i \quad (4)$$

式中: k 表示卷积核大小; d 表示扩张率; k' 表示等效卷

积核大小; RF_{i+1} 表示当前网络层感受野; RF_i 表示上一层感受野; S_i 表示不包括当前层的之前所有层步长的乘积。

为了在密集连接中得到多尺度的上下文特征信息,提高特征表达能力,本文引入ASPP模块,将输入特征与3个不同空洞率的空洞卷积以及1个 1×1 的普通卷积拼接融合,得到不同尺度的输出特征。ASPP模块结构如图3所示。




Fig. 3 ASPP module structure

图3 ASPP模块结构

由图3可以看出,本文首先采用扩张率分别为6、12、18的空洞卷积滤波器进行并行卷积,并将不同扩张率提取的特征与全局特征进行融合得到最终的特征图。以特征 $X^{0,1}$ 为例,在经过 $X^{0,0}$ 与 $X^{1,0}$ 的特征融合后得到 $X^{0,1}$ 为 $[8, 32, 244, 244]$,其中8为batchsize,32为当前特征通道数,224为特征图尺寸大小。其次,对 $X^{0,1}$ 进行卷积核大小为 1×1 的卷积操作,将通道数调整为out_channels,即为32。再次,分别进行卷积核大小为 3×3 ,扩张率为6、12、18的空洞卷积操作,得到3个不同感受野的特征图,并通过卷积核大小为 1×1 的全局平均池化得到全局感受野的特征图,再进行上采样来保证特征融合时的通道数一致。最后将这些特征进行融合,并通过 1×1 卷积调整通道数得到新的特征 $X^{0,1}$,作为执行后续密集连接和跳跃连接的输入特征。

2.3 深度监督

深度监督机制是指在网络的多个层级中添加监督信号,使其在训练过程中可以从不同层级的特征中学习,从而提高性能和稳定性^[21]。如图4所示,分别在最顶层的不同输出层特征 $X^{0,1}$ 、 $X^{0,2}$ 、 $X^{0,3}$ 、 $X^{0,4}$ 后进行卷积核大小 1×1 的卷积操作,保证输出特征的尺寸保持不变;同时使用sigmoid激活函数,将卷积后的特征与最后的输出层连接在一起。在不同层级中加入深度监督机制可使梯度更容易地反向传播到浅层网络,减轻了梯度消失问题,加快了网络收敛速度,还可使网络具备更好的泛化能力,从而防止过拟合现象。

本文采用Lovasz Hinge Loss作为损失函数,其是一种




Fig. 4 Deep supervision mechanism

图4 深度监督机制

主要用于结构化预测任务的损失函数,是非凸 IOU 损失的凸替代方法^[22]。与非凸的损失函数相比,该函数更容易找到全局最优解。其计算公式为:

$$\text{Lovasz Hinge Loss}(\hat{y}, y) = \text{Lovasz}(\text{HingeLoss}(\hat{y}, y)) \quad (5)$$

$$\text{Hinge Loss}(\hat{y}, y) = \max(0, 1 - \hat{y} \cdot y) \quad (6)$$

$$\text{Lovasz}(f) = \sum_{i=1}^n v(i) \quad (7)$$

式中: $\hat{y}$ 表示预测值; y 表示实际标签值; Hinge Loss 在二分类问题中用于衡量预测值与实际标签值之间的距离,其会对错误分类进行线性惩罚; Lovasz 表示 Lovasz 扩展,其将 Hinge Loss 推广到结构化预测任务中,定义在标签或像素集合上,而不是单个预测上,而且考虑了预测值与实际标签值的顺序关系。式(7)为集合函数 f 的 Lovasz 扩展, $v(i)$ 表示在将元素 i 添加到集合时,保持相对于实际标签值的顺序时集合函数值的变化。 Lovasz Hinge Loss 通过在所有可能的预测排序上对 Hinge Loss 进行积分,并加权 Lovasz 扩展来定义。

3 数据集构建


本研究使用的数据源自 Kaggle 平台上的 Flood Area Segmentation 数据集,包含不同地区的洪水区域图像以及对应的真实分割标签 mask,共计 290 张。部分数据如图 5 所示。将该数据集按照 7:3 的比例划分为训练集和测试集。



Fig. 5 Partial flood area images


图 5 部分洪水区域图片

成功的神经网络需要大量数据训练。由于本文使用的数据集数量较少,需要采用数据增强方法对原数据进行扩充,从而获得更多样本。采用 Albumentations 图像数据增强开源库,对原始图像进行翻转、平移、随机裁剪、添加噪声等操作,同时对与原始图像对应的真实分割标签 mask 进行相同的变换。数据增强示意如图 6 所示。




(a) Vertical flip

(a) 垂直翻转



(b) Random size clipping

(b) 随机大小裁剪



(c) Horizontal flip

(c) 水平翻转

Fig. 6 Example diagram of data augmentation

图 6 数据增强示例

4 实验方法与结果分析

4.1 实验环境

实验环境为 Windows10 64 位操作系统,处理器为 Intel (R) Core(TM) i9-10885H, GPU 为 GeForce RTX 3090, 显存大小为 24 G。模型使用深度学习开源框架 PyTorch1.7.1 进行训练, CUDA 驱动版本为 11.1, 编程语言使用 Python3.8.3。

4.2 评价标准

为客观真实地评价所提算法的性能,采用 Dice 系数、交并比 (Intersection over Union, IOU)、准确率 (Precision)、召回率 (Recall) 和 F1 分数作为评价指标。以上 5 个指标数值越大,表明分割结果与标签值越拟合,相似度越高,分割效果越好,精度也越高。

各指标的计算公式分别为:

$$D_{ice} = \frac{2TP}{2TP + FP + FN} \quad (8)$$

$$R_{recall} = \frac{TP}{TP + FN} \quad (9)$$

$$P_{recision} = \frac{TP}{TP + FP} \quad (10)$$

$$F1 = \frac{2 * P_{recision} * R_{recall}}{P_{recision} + R_{recall}} \quad (11)$$

式中: TP 、 TN 、 FP 、 FN 分别表示真阳性、真阴性、假阳性、假阴性。本文实验数据中洪水区域被视为阳性,其余区域为阴性。

4.3 实验结果分析

4.3.1 比较实验

为验证 AUNet++ 算法模型在洪水区域分割任务中的优越性,将其与 DeepLabv3^[23]、UNet、FCN(Res18)、PspNet、FCN(Res50)、UNet++ 等 6 种图像分割算法进行比较。为保证比较的公平性,各模型的实验环境、参数及数据集设置均一致。实验结果如表 1 所示。

Table 1 Segmentation result comparison of different network models

表 1 不同网络模型分割结果比较 (%)					
模型	IOU	Dice score	Precision	Recall	F1 score
DeepLabv3	73.12	84.47	90.23	79.40	84.47
UNet	74.32	82.35	84.10	86.19	85.03
FCN(Res18)	76.72	86.83	89.05	84.71	86.83
PspNet	76.83	86.90	89.76	84.21	86.90
FCN(Res50)	78.61	88.02	87.33	88.72	88.02
UNet++	78.71	84.67	88.11	88.46	88.01
本文模型	80.53	86.37	89.00	89.50	89.12

可以看出, DeepLabv3 和 FCN(Res50) 分别在准确率 Precision 和 Dice score 两个分割指标上略高于本文模型,原因在于 FCN(Res50) 网络结构中采用 ResNet50 作为骨干网络,相较 ResNet18 具有更深的网络层数,能够学习更加复

杂和抽象的特征,提高了模型的表征能力。而 DeepLabv3 算法采用交叉熵损失函数 (Cross Entropy Loss), 能够更有效地提高像素级别的分类准确率,从而提高整体语义分割的准确率。UNet++ 的各项指标均优于 UNet, 这是由于 UNet++ 在 UNet 的基础上引入了更多复杂的层级连接,使得网络能够更好地利用不同层级的特征信息,提高了分割质量。本文模型在 IOU、Recall、F1 score 3 项指标上均优于所有 6 种对照模型,说明其在洪水区域分割任务中的预测值与真实值 mask 之间的重叠程度高,能够将像素精准地分配至洪水区域。

4.3.2 消融实验

为探究所提算法模型使用不同损失函数时的性能表现以及 ASPP 模块的影响,设置一组消融实验,结果如表 2 所示。其中, BCEL 表示 BCEWithLogits 损失函数, BCED 表示 BCEDice 损失函数, LH 表示 Lovasz Hinge Loss 损失函数。为保证实验结果的可信度,每个模型均在相同的实验环境、参数和数据集下进行训练与测试。由表 2 可以看出,在使用相同损失函数的情况下,引入 ASPP 模块后模型 IOU 提升了 0.76%, Dice 值提升了 4.02%, 这是由于 ASPP 模块能将多尺度的上下文信息融合到特征图中,更好地捕获图像的语义信息,增强模型对上下文信息的感知能力,从而提高分割精度。在使用不同损失函数的比较实验中可以看出,本文模型除在准确率上低于使用 BCEWithLogits 损失函数和 ASPP 模块的 UNet++ 模型外,其余各项指标均为最高,与原始 UNet++ 模型相比 IOU 提高了 1.99%, Dice 值提高了 5.30%, 说明 Lovasz Hinge Loss 损失函数能更好地处理分割结果的平滑性和连通性。

Table 2 Segmentation results with and without ASPP modules for different loss functions

表 2 不同损失函数及有无 ASPP 模块的分割结果 (%)									
基准模型	消融因素				IOU	Dice score	Precision	Recall	F1 score
	ASPP	BCEL	BCED	LH					
—	—	√	—	—	78.54	81.07	88.41	86.38	87.87
UNet++	√	√	—	—	79.30	85.09	89.79	88.87	88.41
	√	—	√	—	78.71	84.67	88.11	88.46	88.01
本文模型	√	—	—	√	80.53	86.37	89.00	89.50	89.12

4.3.3 可视化展示

为了更直观地感受本文算法的分割效果,随机选取 3 张洪水区域图像进行分割。结果如图 7 所示。可以看出,本文模型的分割结果在轮廓和细节上与真实分割标签十分相似,具有较高的分割准确性。

5 结语

洪水区域遥感图像分割技术是防洪防灾的重要一环,




Fig. 7 Visual display of segmentation results
图7 分割结果可视化展示

也是清楚了解受灾区域严重程度的有效手段,因此研究高性能图像分割方法十分必要。本文提出的AUNet++分割方法在UNet++解码器中嵌入ASPP模块,使模型能够有效捕获图像中的多尺度信息,更好地理解 and 感知图像中不同尺度的特征,进而将不同解码路径特征融合以分割出洪水区域。此外,本文还采用Lovasz Hinge Loss损失函数帮助模型更快找到全局最优解,通过数据增强的方式对原有数据进行扩充,解决了数据量少的问题。AUNet++算法在不增加网络参数和计算量的情况下减少了特征图中的信息丢失,保留了更多图像细节和语义信息。实验结果表明,该算法具有较高的准确率和稳定性,有效提升了洪水区域分割精度,为实际防洪防灾工作提供了技术支撑。

本文研究的不足之处在于样本数据少,且采用监督学习方式,需要大量标签。后续将收集更多数据,结合半监督学习方式,利用无标签数据提升模型分割性能。

参考文献:

[1] GAO H X, CHEN B, SUN H Q, et al. Research progress and prospect of SAR satellite image flood detection [J]. Journal of Geoinformation Science, 2023, 25(10): 1933-1953.

高寒新,陈波,孙洪泉,等. SAR卫星影像洪水检测研究进展及展望[J]. 地球信息科学学报, 2023, 25(10): 1933-1953.

[2] OTSU N. A threshold selection method from gray-level histograms [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62-66.

[3] PUN T. A new method for grey-level picture thresholding using the entropy of the histogram[J]. Signal Processing, 1980, 2(3): 223-237.

[4] YEN J C, CHANG F J, CHANG S. A new criterion for automatic multilevel thresholding[J]. IEEE Transactions on Image Processing, 1995, 4(3): 370-378.

[5] KHAN J F, BHUIYAN S M A, ADHAMI R R. Image segmentation and shape analysis for road-sign detection[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(1): 83-96.

[6] ULUPINAR F, MEDIONI G. Refining edges detected by a LoG operator [J]. Computer Vision Graphics & Image Processing, 1990, 51(3): 275-298.

[7] LI E S, ZHU S L, ZHU B S, et al. An adaptive edge-detection method based on the Canny operator [C]//2009 International Conference on Environmental Science and Information Application Technology, 2009: 465-469.

[8] PHAM D L, XU C Y, PRINCE J L. A survey of current methods in medical image segmentation [J]. Annual Review of Biomedical Engineering, 2000, 2(1): 315-337.

- [9] TREMEAU A, BOREL N. A region growing and merging algorithm to color segmentation[J]. Pattern Recognition, 1997, 30(7): 1191-1203.
- [10] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.
- [12] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2881-2890.
- [13] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs [EB/OL]. <https://ui.adsabs.harvard.edu/abs/2014arXiv1412.7062C/abstract>.
- [14] ZHOU Z, RAHMAN SIDDIQUEE M M, TAJBAKHS N, et al. Unet++: a nested u-net architecture for medical image segmentation[C]//Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, 2018: 3-11.
- [15] JIANG P Q, WU J, ZHANG S R, et al. Point cloud segmentation and flood risk simulation based on deep learning [J]. Advances in Water Science, 2024, 35(1): 62-73.
姜佩奇, 伍杰, 张社荣, 等. 基于深度学习的点云分割与洪水风险模拟方法[J]. 水科学进展, 2024, 35(1): 62-73.
- [16] LI J Z, LI L J, FENG P, et al. Radar rainfall prediction and flood prediction based on deep learning [J]. Advances in Water Science, 2023, 34(5): 673-684.
李建柱, 李磊菁, 冯平, 等. 基于深度学习的雷达降雨临近预报及洪水预报[J]. 水科学进展, 2023, 34(5): 673-684.
- [17] CUI Z, GUO S L, WANG Y, et al. Deep learning model for flood probability prediction of Three Gorges Reservoir [J]. Journal of Hydropower, 2023, 42(4): 1-10.
崔震, 郭生练, 汪芸, 等. 三峡入库洪水概率预报的深度学习模型[J]. 水力发电学报, 2023, 42(4): 1-10.
- [18] SUN S T, LIANG N A, LIU P, et al. Research on Sentinel-1 SAR image flood segmentation based on deep learning [J]. Modern Mapping, 2022, 45(6): 12-15.
孙书腾, 梁乃安, 刘培, 等. 基于深度学习的 Sentinel-1 SAR 影像洪水分割研究[J]. 现代测绘, 2022, 45(6): 12-15.
- [19] WANG S S, XU P B, HU S Y, et al. Research on prediction model of mountain flood level in small watershed based on deep learning[J]. Computer Knowledge and Technology, 2022, 18(20): 89-91.
汪松松, 徐蓬博, 胡书源, 等. 基于深度学习的小流域山洪水位预测模型研究[J]. 电脑知识与技术, 2022, 18(20): 89-91.
- [20] CUI J Q. Extraction and application of agricultural land flood information range based on multi-source remote sensing images and Google Earth Engine[D]. Zhengzhou: Henan Agricultural University, 2023.
崔佳琪. 基于多源遥感影像和 Google Earth Engine 的农用地洪水信息范围提取与应用[D]. 郑州: 河南农业大学, 2023.
- [21] LEE C Y, XIE S, GALLAGHER P, et al. Deeply-supervised nets[C]//Eighteenth International Conference on Artificial Intelligence and Statistics, 2015: 562-570.
- [22] BERMAN M, TRIKI A R, BLASCHKO M B. The lovász-softmax loss: a tractable surrogate for the optimization of the intersection-over-union measure in neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4413-4421.
- [23] YURTKULU S C, ŞAHİN Y H, UNAL G. Semantic segmentation with extended DeepLabv3 architecture [C]//2019 27th Signal Processing and Communications Applications Conference, 2019: 1-4.

(责任编辑:尹晨茹)