

基于多尺度特征融合的遥感影像水体检测

曾宝秀¹, 董传祥²

(1. 中科卫星(山东)科技集团有限公司, 山东 济南 250000; 2. 山东科技大学 测绘与空间信息学院, 山东 青岛 266590)

摘要: 地表水在全球生态环境中发挥着重要作用, 因此动态捕捉地球上地表水的分布和范围是必要的。然而, 由于地表环境的高度复杂性, 现有的地表水体检测方法在适用性和精确度方面存在局限性, 特别是在高异质性区域, 如城镇、山地和云覆盖区域等。为了提升不同地表环境中不同类型水体的识别精度, 提出一种基于多尺度特征融合的遥感影像水体检测方法(MFWD)。该方法首先基于深度残差网络模型提取水体和地表的各级特征; 其次, 设计空洞空间金字塔池化(ASPP)模块和通道-空间注意力机制(CSAM)模块充分挖掘高级语义信息, 捕获水体的高级特征; 最后, 利用跨尺度连接融合不同尺度的低级空间细节特征和高级语义信息, 获得全面的特征表示, 从而有效识别水体。利用 Sentinel-2 数据进行水体检测实验, 结果表明, MFWD 方法获得了 95.6% 的整体识别精度, 提高了不同类型水体的识别准确性, 改善了对细小水体和高异质性区域水体的检测效果。

关键词: 空洞空间金字塔池化; 注意力机制; 多尺度特征融合; 遥感影像; 水体检测

DOI: 10.11907/rjtk.241148

开放科学(资源服务)标识码(OSID):

中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(2024)005-0168-07



Water Body Detection Based on Multi-Scale Feature Fusion for Remote Sensing Images

ZENG Baoxiu¹, DONG Chuanxiang²

(1. AIRSAT Technology Group, Jinan 250000, China;

2. College of Geodesy and Geomatics, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: Surface water plays an important role in the global ecological environment and human life. Dynamically capturing the distribution and extent of surface water on Earth is necessary. However, due to the high complexity of land surface environments, existing surface water body detection methods have limitations in applicability and accuracy, especially in highly heterogeneous regions such as urban areas, mountains, and cloud-covered areas. To improve the recognition accuracy of different types of water bodies in different land surface environments, this study proposes a water body detection method for remote sensing images based on multi-scale feature fusion (MFWD). The proposed method first extracts multi-level features of water bodies and land surfaces based on a deep residual network model. Then, an Atrous Spatial Pyramid Pooling (ASPP) module and a Channel-Spatial Attention Mechanism (CSAM) module are designed to fully exploit advanced semantic information and capture advanced features of water bodies. Finally, cross-scale connections are utilized to fuse multi-scale low-level spatial details and high-level semantic information, obtaining comprehensive feature representations for effective water body recognition. Experiments on Sentinel-2 data demonstrate that the proposed MFWD method achieves an overall recognition accuracy of 95.6%, exhibiting improved accuracy in identifying different types of water bodies. Moreover, the detection of small-scale water bodies as well as water bodies in highly heterogeneous regions is enhanced.

Key Words: atrous spatial pyramid pooling; attention mechanism; multi-scale feature fusion; remote sensing images; water bodies detection

0 引言

地表水是地球上最重要的资源之一, 在环境和气候调

节等方面发挥着重要作用。准确、持续地了解陆地上的水资源情况是许多不同应用的基础, 如精准农业、灾害管理、干旱检测和地表分析等^[1-2]。然而, 由于出现气候变化、土地利用/土地覆盖变化和其他形式的环境变化, 地表水在

收稿日期: 2024-02-22

作者简介: 曾宝秀(1991-), 男, 中科卫星(山东)科技集团有限公司工程师, 研究方向为遥感图像处理; 董传祥(1995-), 男, 山东科技大学测绘与空间信息学院硕士研究生, 研究方向为计算机视觉。

时间和空间上也在不断发生变化^[3-5]。因此,对地表水进行动态、及时监测是监督可用水资源实际状况中的一项重要任务。

传统的水体检测方法会耗费大量人力和时间,并且通常缺乏实时性。随着遥感技术的不断进步,具备覆盖范围广、高精度和实时成像特点的遥感技术正日益成为水资源监测的重要手段。目前,遥感影像水体提取方法主要分为两类:传统基于指数的方法和基于深度学习的方法^[6-7]。基于指数的方法通常利用水体和地物的光谱特征设定阈值区分水体及其它地表覆盖物,该方法简单易用,但依赖于先验的光谱特征分析,缺乏对水体形状、纹理等空间信息的分析,在准确区分水体、山体阴影、建筑阴影和云阴影等方面存在局限性^[8-9]。辅助数据如数字高程模型可在一定程度上改善这些问题,但由于地表环境的复杂性,如何选择最佳阈值提取不同场景中的水体仍是一个重要问题^[10]。

基于深度学习的水体提取方法从庞大的数据集中获取水体特征信息,并通过构建合适的网络结构实现水体提取。Fei等^[11]提出一种基于深度学习的两阶段水体提取方法,改善了针对较窄河流的水体提取效果。Wang等^[12]提出一种将深度学习与谷歌地球引擎平台相结合的水体提取方法,旨在研究城市化进程中大规模、长期的城市湿度变化。为了充分挖掘高级信息,Rezaee等^[13]设计了一个两级网络,利用深层特征提取水体。Chen等^[14]提出一种自适应池化方法,以更好地保留水体的上下文和边界信息。尽管基于深度学习的方法在水体提取中取得了一定进展,但现有方法对全局信息和多尺度信息的捕获能力不足,在小目标水体识别以及水体与阴影的准确区分方面有待进一步提升。

针对以上问题,本文提出一种基于多尺度特征融合的水体提取方法。该方法首先利用空洞空间金字塔池化模块扩大卷积感受野,获得更多上下文信息,丰富特征表达;其次,设计注意力机制模块提升特征挖掘能力,增强有效特征;最后,利用多尺度特征融合模块集成低级空间特征和高级语义信息,提供丰富的特征表示,从而准确地区分水体和地表。

1 相关工作

1.1 空洞卷积

空洞卷积是卷积神经网络中的一种卷积操作,也称为扩张卷积或膨胀卷积^[15]。传统的卷积操作是在输入数据的每个位置应用卷积核,而空洞卷积通过在卷积核中间插入额外的间隔(膨胀率)来扩大卷积核的感受野。与传统的卷积操作相比,空洞卷积扩大了卷积核的感受野,可以更好地捕获输入数据中的长程依赖关系和广泛的上下文信息。Kadry等^[16]利用Deeplabv3+网络实现了不同场景中

的水体识别。尽管空洞卷积能够一定程度上捕获不同的尺度信息,但也会损失信息的连续性,造成局部细节丢失,同时在建立远距离信息相关性方面表现较差。

1.2 注意力机制

视觉注意力机制是近年来计算机视觉领域的重要进展之一,能够选择性关注图像某些区域并抑制其他区域,使模型更有效地处理高维数据,提升目标检测、图像分类和图像分割等任务的表现^[17]。视觉注意力机制通常包括通道注意力机制、空间注意力机制和通道—空间注意力机制。通道注意力机制是对不同通道的特征进行加权,让网络更加关注有用信息,减少冗余信息,如SENet(Squeeze-and-Excitation Networks)等^[18]。空间注意力机制对每个位置的视觉信息进行加权,以提高模型对关键位置的关注度,如LSA(Local Self-Attention)等^[19]。通道—空间注意力机制(Convolutional Block Attention Module, CBAM)结合通道和空间注意力,同时对位置和通道进行加权,使模型同时关注关键位置和通道,并利用通道池化和空间池化获取全局信息^[20]。通道注意力和空间注意力机制各有侧重,而通道—空间注意力机制融合了两者优先点,可以更自适应地选择重要的对象和区域,有效提高了模型性能。

1.3 多尺度特征融合

丰富的特征信息,包括低层和高层特征,是准确识别物体的关键。深层次的网络结构能够挖掘高层次特征,但同时会丢失低层空间细节特征。多尺度特征融合是指将来自不同尺度或不同层次的特征信息结合起来,以获取更加全面、丰富的信息,从而增强模型的鲁棒性和泛化能力。常用的多尺度特征融合方法包括特征金字塔、注意力机制和跨尺度连接等。尺度特征融合使模型可以充分利用不同尺度下的信息,提高了模型对复杂场景的理解能力,从而在视觉和语言任务中获得更好的表现。例如Hu等^[21]设计了多尺度注意力网络,提高了遥感影像水体分割精度,但该方法更关注于挖掘不同尺度的高级特征,对低级空间细节特征的捕获能力不足。

2 基于多尺度特征融合的遥感影像水体检测方法

为提高对不同场景中不同类型水体识别的准确性,本文提出一种基于多尺度特征融合的遥感影像水体检测方法(Water Body Detection Method Based on Multi-Scale Feature Fusion for Remote Sensing Images, MFWD)。该方法基于编码器—解码器结构设计了多尺度特征融合水体检测网络,具体结构如图1所示。编码器部分首先采用ResNet101模型提取水体特征,结合空洞空间金字塔池化模块(Atrous Spatial Pyramid Pooling, ASPP)和通道—空间注意力模块(Channel-Spatial Attention Mechanism, CSAM)充分挖掘高级语义信息,捕获水体高级特征;解码器部分通过多尺度特征融合集成低级空间细节特征与高级语义

特征,获得全面的特征表示,以逐渐恢复水体细节信息,获得水体检测结果。

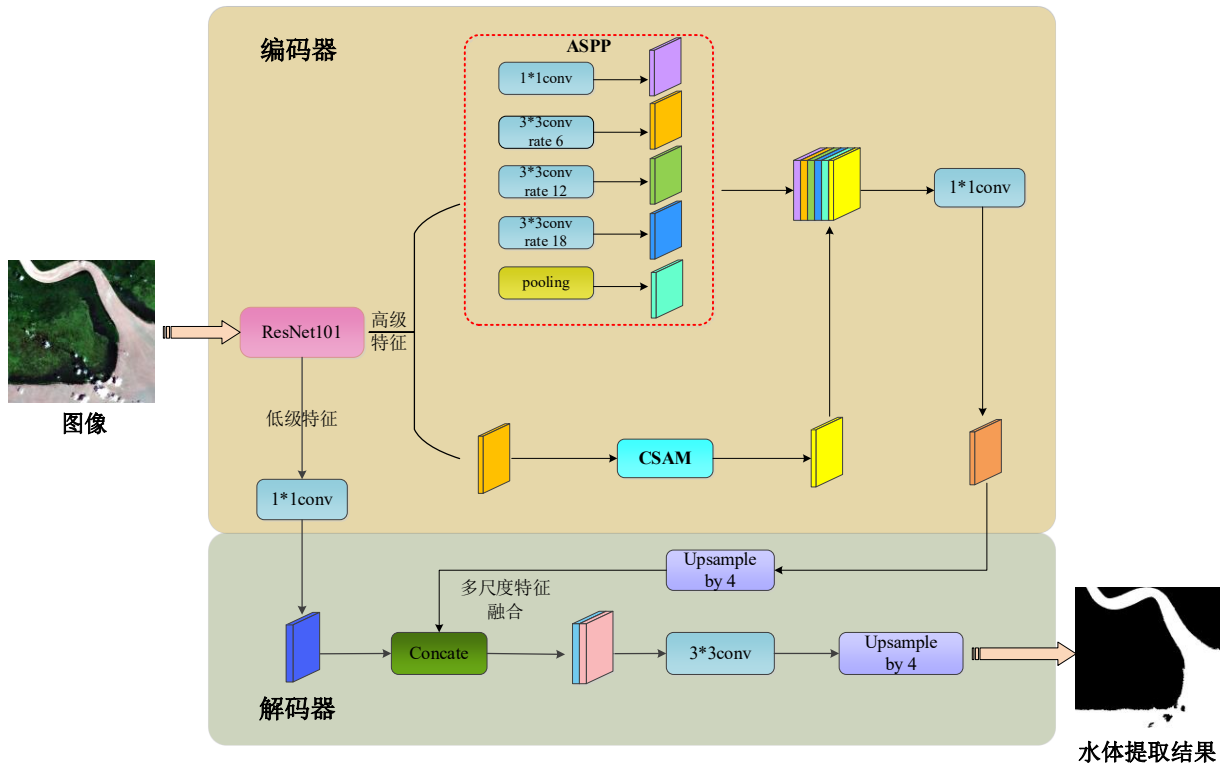


Fig. 1 Network architecture for water body detection based on multi-scale feature fusion

图1 基于多尺度特征融合的水体检测网络结构

2.1 ASPP 模块

多尺度特征融合水体检测网络首先采用 ResNet101 模型进行特征提取,输出的特征包含低级特征和高级特征。本文采用包含 4 通道的地表反射率数据作为 ResNet101 模型的输入,输出为不同分辨率的低级和高级特征。将高级特征输入到 ASPP 模块,采用不同扩张率的空洞卷积扩大卷积核的感受野,捕获多尺度上下文信息,丰富信息表示。在多尺度特征水体检测网络中,ASPP 模块包含 1 个 1×1 的卷积、3 个不同扩张率(6, 12, 18)的空洞卷积和 1 个全局平均池化。卷积层从局部提取特征,全局平均池化从全局提取特征,从而获得多尺度特征。将 ResNet101 提取的高级特征 2 048×32×32 输入 ASPP 结构,ASPP 结构中每一层的输出特征为 256×32×32。将这些特征进行拼接,ASPP 模块输出特征为 1 280×32×32,包含了不同粒度的信息。

2.2 CSAM 模块

注意力机制可以捕捉输入序列中的上下文关联,模型可以根据上下文的重要性,将更多注意力集中在有效特征上,从而提升模型性能。基于单纯卷积结构的编码器对每个像素执行相同操作,这对于区分特殊场景(云覆盖、高山和建筑物等)中的水体和阴影是困难的。因此,本文引入 CSAM 注意力模块以学习不同像素的注意力系数,自适应地强调更重要的特征,并抑制图像中不太重要的特征。

CSAM 模块包含通道注意力模块和空间注意力模块,以自适应地强调水体特征,具体结构如图 2 所示。首先,

将来自 ResNet101 网络的高级特征 1 024×32×32 作为通道注意力模块的输入。通道注意力模块通过全局平均池化和全局最大池化获得统计特征,并生成每个通道的注意力权重,以强调对水体识别更重要的通道。其次,将通道注意力模块的输出作为空间注意力模块的输入特征层。空间注意力模块在每个位置生成注意力权重,以关注目标区域内的相关位置。两级注意力机制提升了特征在通道和空间维度上的表达能力,使模型能够更好地提取水体的判别性特征。该结构充分利用了注意力机制的自适应加权作用,有效加强了特征之间在通道和空间上的联系,提升了模型对水体特征的表达能力。

2.3 多尺度特征融合模块

多尺度特征融合模块包含两次特征拼接:首先,在编码器中将 ASPP 模块与 CSAM 模块的输出特征进行融合,获得不同级别的高级语义特征;其次,在解码器中对来自 ResNet101 的低级特征执行 1×1 卷积操作,并将具有空间细节的低级特征与高级语义特征进行融合,从而获得不同粒度的特征表示。

解码器首先对编码器输出的多尺度语义特征执行 4 倍双线性上采样操作,然后融合不同尺度的特征。最后,通过 3×3 卷积和 4 倍双线性上采样恢复特征细节,生成像素级水体检测结果。多尺度特征水体检测网络结合了 ASPP 模块与 CSAM 模块的优势,可有效捕获多尺度特征,减少信息损失,获得准确的水体识别结果。

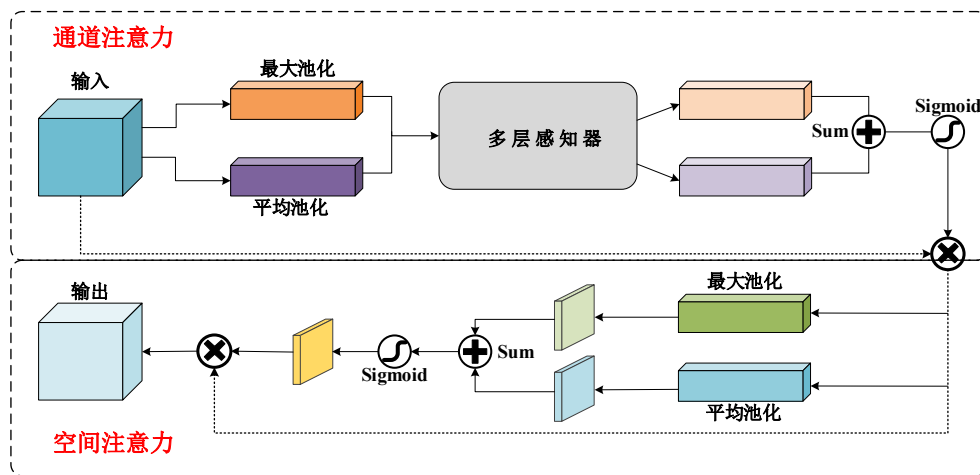


Fig. 2 CSAM module structure

图 2 CSAM 模块结构

3 实验及结果分析

3.1 数据集与实验设置

本文使用 ESWKB 数据集进行实验,该数据集包含 95 个 Sentinel-2 场景,包括各种地表水体,如湖泊、河流、水库和海洋,以及各种土地覆盖类型,如建筑物、道路、森林和冰雪等。此外,该数据集还考虑了平原、丘陵、山地和高原等地形类型,以及无云、多云和大雾等各种天气类型^[1]。考虑到不同方法的适用性,本文使用红、绿、蓝和近红外波段进行水体检测,即第 2、3、4 和 8 波段,空间分辨率为 10 m。

在训练阶段,考虑到网络模型输入和计算效率,将影像和对应水体参考图像裁剪为 512×512 尺寸的图像。最终,训练数据共包括 2 200 多个训练图像。使用 Adam (Adaptive Moment Estimation) 优化器和反向传播动态调整模型参数,设置初始学习率为 0.001,损失函数为二分类交叉熵函数。通过网络的学习和分析不断迭代更新权重最小化输出与真实值之间的误差,从而获得最优水体检测模型来识别遥感影像中的水体。基于训练精度和损失,当模型迭代次数达到 100 时可获得最佳水体检测模型,从而完成训练。

在测试阶段,利用最优水体检测模型进行水体和地表的识别。模型的输出为概率图,根据实际需求设置合适的阈值区分水体和地表。本文设置水体检测的阈值为 0.5,即当像元被预测为水体的概率大于 0.5 时,则判定该像元为水体。

3.2 评价指标

为了直观地评估水体检测方法的有效性,本文使用总体准确率 (Overall Accuracy, OA)、精确率 (Precision)、召回率 (Recall)、F1 得分 (F1-score) 以及平均交并比 (Mean Intersection over Union, MIoU) 对水体检测结果进行精度评估。这些指标分别被定义为:

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - score = \frac{2 \times Precision \times Recall}{precision + Recall} \quad (4)$$

$$MIoU = \frac{1}{2} \times \left(\frac{TP}{TP + FP + FN} + \frac{TN}{TN + FN + FP} \right) \quad (5)$$

式中,TP 表示被正确预测的水体像元总数,TN 表示被正确识别的非水体像元总数,FP、FN 分别表示被错误预测的水体和非水体像元数量。

3.3 实验结果

图 3 显示了 Sentinel-2 场景(包括植被、山地、建筑物、湖泊和海洋等)中不同方法的水体检测结果。细长水体和小水体是水体检测中的难点,由于面积较小,小水体容易与地表混淆,因此在水体检测中经常被遗漏,而细长水体难以被完整检测。由图 3 可以看出,对于细长水体,UNet 模型和 Deeplabv3+ 模型都出现了较大面积的遗漏,无法完整检测出水体;WatNet 方法能够较好地检测水体,但对于细小水体和复杂场景中的水体检测效果还有待进一步提升。本文提出的 MFWD 方法改善了细长水体检测效果,提升了对细长水体和小水体检测的完整性,遗漏较少。

在高异质性区域,如山地、建筑物和云覆盖区域,由于阴影区域与水体的反射率信息接近,通常会将山地阴影、建筑物阴影以及云阴影误识别为水体。在图 3 中,UNet 模型在复杂场景中准确识别水体的能力较弱,在城镇和云覆盖区域出现了大面积的水体遗漏;Deeplabv3+ 模型能够识别大多数水体,但是仍然存在误识别和遗漏现象,并且对水体的识别不连续;MFWD 方法融合了多尺度特征,增强了有效特征,获得了全面的特征表示,提高了水体识别的准确性和完整性。

为更直观、有效地评估 MFWD 方法,本文使用 ESWKB 数据集中 31 幅 Sentinel-2 影像进行精度验证。表 1 展示了




Fig. 3 Water detection results of different methods

图3 不同方法的水体检测结果

不同方法针对 Sentinel-2 数据水体识别结果的定量分析。从表1中可以看到, MFWD 方法获得了良好的水体检测精度, 其 OA 为 95.60%, 相较于 UNet 与 Deeplabv3+ 模型分别提高了 4.31% 和 2.02%。UNet、Deeplabv3+、WatNet 与 MFWD 方法的 F1-score 分别为 79.32%、83.23%、85.78% 和 86.46%, 意味着 MFWD 方法能更准确地识别水体和地表。

3.4 消融实验

MFWD 方法利用多尺度信息分析水体和地表特征, 利用空洞卷积和注意力机制模块捕获有效特征, 并通过多尺度特征融合丰富了特征表示。受益于空洞空间金字塔池化、注意力机制模块与多尺度特征融合的协同作用, MFWD 方法取得了良好的水体识别结果。为了充分验证所提

Table 1 Quantitative analysis of water body detection results for Sentinel-2 data

表1 Sentinel-2数据水体检测结果定量分析					%
方法	OA	Precision	Recall	F1-score	MIoU
UNet	91.29	80.30	77.41	79.32	71.80
Deeplabv3+	93.58	85.72	90.86	83.23	77.44
WatNet	95.10	95.26	91.63	85.78	79.51
MFWD	95.60	92.83	92.57	86.46	79.82

出方法中不同结构的作用, 本文分别进行了 ASPP 和 CSAM 模块的消融实验。

图4展示了消融实验的水体检测结果, 其中图(c)、(d) 分别表示未使用 ASPP 模块(Without-ASPP)的方法和未使

用 CSAM 模块 (Without-CSAM) 的方法。在图 4 中, Without-ASPP 和 Without-CSAM 方法对不同场景中不同类型的水体识别都出现了不同程度的遗漏,这是由于缺乏全局上

下文信息和丰富的特征,导致了对水体与其它地表的混淆。MFWD 方法可充分挖掘低级和高级特征,获得全面的特征表示,实现了更准确的水体识别结果。




Fig. 4 Results of water body detection in ablation experiments

图 4 消融实验水体检测结果

表 2 为消融实验的水体检测结果精度评估。MFWD 方法的 F1-score 与 MIoU 相比 Without-CSAM 方法提升了 1.74% 和 1.99%,表明 CSAM 模块提升了水体检测性能。通

过与 Without-CSAM 和 Without-ASPP 方法的对比可知,注意力机制和空洞空间金字塔池化模块有助于提高不同地表环境中的水体检测精度,减少了水体遗漏和误识别

现象。

Table 2 Quantitative analysis of water body detection results in ablation experiments

方法	OA	Precision	Recall	F1-score	MIoU	%
Without-CSAM	93.26	92.30	90.42	84.72	77.83	
Without-ASPP	93.88	92.72	91.30	85.25	78.46	
MFWD	95.60	92.83	92.57	86.46	79.82	

4 结语

针对高异质性区域水体检测精度不高的问题,本文提出一种新的基于多尺度特征融合的遥感影像水体检测方法,通过语义特征挖掘、多尺度上下文建模和细节特征补充,有效提高了复杂异质性区域水体检测精度。利用ASPP模块与CSAM模块进行多尺度上下文建模和语义特征提取,能够获得对水体语义特征的高级表达。多尺度特征融合集成了低级空间细节特征和高级语义特征,增强了水体表示能力。通过对Sentinel-2数据的水体检测实验与定量分析,本文提出的MFWD方法的水体识别精度可达到95.6%,能够有效识别城镇、山地和云覆盖区域中不同类型的水体,并改善了细小水体的识别精度。本文为提高遥感影像水体检测精度提供了一种有效方法,具有一定的理论价值和实际应用前景。后续研究将继续优化模型结构,进一步提高遥感影像水体检测精度和效率。

参考文献:

- [1] LUO X, TONG X H, HU Z W. An applicable and automatic method for earth surface water mapping based on multispectral images[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 103: 102472.
- [2] LIU H Y, SHI Y, CHANG Q N, et al. A new extraction method of surface water based on dense time-sequence images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 3151-3166.
- [3] WANG C X, WANG P, MA N. A new water detection for multispectral images based on data simulation and random forest[C]//IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium, 2022: 3191-3194.
- [4] CHEN L F, CAI X M, XING J, et al. Towards transparent deep learning for surface water detection from SAR imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 118: 103287.
- [5] ZHAO B Y, WU J J, HAN X Y, et al. An improved surface water extraction method by integrating multi-type priori information from remote sensing[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 124: 103529.
- [6] PARAJULI J, FERNANDEZ-BELTRAN R, KANG J, et al. Attentional dense convolutional neural network for water body extraction from sentinel-2 images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 6804-6816.
- [7] LI D, WU B S, CHEN B W, et al. Review of water body information extraction based on satellite remote sensing[J]. *Journal of Tsinghua University (Science and Technology)*, 2020, 60(2): 147-161.
李丹,吴保生,陈博伟,等. 基于卫星遥感的水体信息提取研究进展与展望[J]. *清华大学学报(自然科学版)*, 2020, 60(2): 147-161.
- [8] ZHOU Y, DONG J W, XIAO X M, et al. Open surface water mapping algorithms: a comparison of water-related spectral indices and sensors[J]. *Water*, 2017, 9(4): 256.
- [9] KAPLAN G, AVDAN U. Object-based water body extraction model using Sentinel-2 satellite imagery[J]. *European Journal of Remote Sensing*, 2017, 50(1): 137-143.
- [10] YANG J, DU X R. An enhanced water index in extracting water bodies from Landsat TM imagery[J]. *Annals of GIS*, 2017, 23(3): 141-148.
- [11] FEI J Y, LIU J T, KE L H, et al. A deep learning-based method for mapping alpine intermittent rivers and ephemeral streams of the Tibetan Plateau from Sentinel-1 time series and DEMs[J]. *Remote Sensing of Environment*, 2022, 282: 113271.
- [12] WANG Y D, LI Z W, ZENG C, et al. An urban water extraction method combining deep learning and Google Earth engine[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 769-782.
- [13] REZAEI M, MAHDIANPARI M, ZHANG Y, et al. Deep convolutional neural network for complex wetland classification using optical remote sensing imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(9): 3030-3039.
- [14] CHEN Y, FAN R S, YANG X C, et al. Extraction of urban water bodies from high-resolution remote-sensing imagery using deep learning[J]. *Water*, 2018, 10(5): 585.
- [15] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[DB/OL]. <https://arxiv.org/abs/1511.07122>.
- [16] KADRY S, AL-BETAR M A, YASSINE S, et al. Automatic detection of waterbodies from satellite images using DeepLabV3+[C]//International Conference on Mining Intelligence and Knowledge Exploration, 2023: 78-86.
- [17] GUO M H, XU T X, LIU J J, et al. Attention mechanisms in computer vision: a survey[J]. *Computational Visual Media*, 2022, 8(3): 331-368.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [19] BELLO I, ZOPH B, VASWANI A, et al. Attention augmented convolutional networks[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3286-3295.
- [20] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision, 2018: 3-19.
- [21] HU K, LI M, XIA M, et al. Multi-scale feature aggregation network for water area segmentation[J]. *Remote Sensing*, 2022, 14(1): 206.

(责任编辑:黄健)