

# 遥感影像水体提取模型的新型研究

冯 澳<sup>1</sup>, 李鸿翔<sup>1</sup>, 刘子曦<sup>1</sup>, 王艺霏<sup>2</sup>, 伍 煊<sup>1</sup>, 肖子滢<sup>1</sup>, 刘 涛<sup>1</sup>

(1. 四川农业大学 信息工程学院, 四川 雅安 625014;

2. 西南财经大学 经济与管理研究院, 四川 成都 611130)

**摘 要:** 如何从遥感影像中准确且高效地提取出水体特征是学者研究的重点。无论是传统方法还是水体指数计算法, 大部分都无法相对统一应用于各种遥感影像中的水体提取, 也无法解决城市中细小水体难以被提取的问题, 具有一定的局限性。针对以上问题, 文中提出一种基于改进 Deeplabv3+ 网络的新型提取模型。首先对遥感影像进行大气校正和假彩色处理, 降低数据色差的影响, 有效地对水体与背景色进行颜色区分。再根据 NDWI 计算和阈值分割, 得到二值 NDWI 特征图, 将波段信息与假彩色图像进行特征融合。神经网络模型选择 Deeplabv3+ 作为框架结构, 并采用 ResNet-101 作为优化的骨干网络。通过对 ASPP 模块改进后, 提高了整体提取效果。与选取的 U-Net, SegNet, FCN, PSPNet 四种模型进行对比, 改进 Deeplabv3+ 模型在 PA 上分别提高了 3.893%, 5.242%, 4.318% 和 3.471%, 在 IOU 上分别提高了 6.534%, 3.732%, 3.749% 和 6.331%, 在 Recall 上分别提高了 6.111%, 6.698%, 5.776% 和 4.901%。同时在提取结果上也降低了噪点, 增强了提取水体的完整度和边缘细化能力, 具有很好的实用性。

**关键词:** 遥感影像; 水体提取; NDWI; Deeplabv3+; 阈值分割; ResNet-101

中图分类号: TP399

文献标识码: A

文章编号: 1673-629X(2021)0056-06

## Research on Water Extraction Model from Remote Sensing Image Based on Improved Deeplabv3+ Network

FENG Ao<sup>1</sup>, LI Hong-xiang<sup>1</sup>, LIU Zi-xi<sup>1</sup>, WANG Yi-fei<sup>2</sup>,

WU Xuan<sup>1</sup>, XIAO Zi-han<sup>1</sup>, LIU Tao<sup>1</sup>

(1. School of Information Engineering, Sichuan Agricultural University, Yaan 625014, China;

2. Research Institute of Economics and Management, Southwestern University of Finance and Economics,  
Chengdu 611130, China)

**Abstract:** How to accurately and efficiently extract water features from remote sensing images is the focus of scholars' research. Whether it is traditional methods or water index calculation methods, most of them cannot be relatively uniformly applied to water extraction in various remote sensing images, nor can they solve the problem that small water bodies in cities are difficult to extract, and they have certain limitations. In response to the above problems, we propose a new extraction model based on improved Deeplabv3+ network. Firstly, atmospheric correction and false color processing are performed on remote sensing images to reduce the influence of data color difference and effectively distinguish the water body from the background color. Then according to NDWI calculation and threshold segmentation, a binary NDWI feature map is obtained, and the band information is feature-fused with the false color image. The neural network model chooses Deeplabv3+ as the frame structure, and uses ResNet-101 as the optimized backbone network. After improving the ASPP module, the overall extraction effect is improved. Compared with the selected U-Net, SegNet, FCN and PSPNet, the improved Deeplabv3+ model has increased 3.893%, 5.242%, 4.318%, 3.471% on PA, and 6.534%, 3.732%, 3.749%, 6.331% on IOU, and 6.111%, 6.698%, 5.776%, 4.901% on Recall. At the same time, the extraction result also reduces noise, enhances the integrity of the extracted water body and the edge refinement ability, and has good practicability.

**Key words:** remote sensing image; water extraction; NDWI; Deeplabv3+; threshold segmentation; ResNet-101

## 0 引 言

水是人类赖以生存的重要资源, 小到城市地表的

水渠, 大到贯穿内陆的江河, 都是人们生活用水的主要来源<sup>[1]</sup>。实时且高效地获取某个区域内的水资源信息

收稿日期: 2020-12-24

基金项目: 国家创新训练计划 (202010626034)

作者简介: 冯 澳 (2000-), 男, 研究方向为深度学习; 通讯作者: 刘 涛 (1980-), 男, 硕士, 副教授, 研究方向为农业信息化和计算机应用。

将为市政决策、环境保护带来极大的便利和帮助<sup>[2]</sup>。随着人造地球卫星的数量与日俱增,地物检测技术得到了飞速发展,借助于卫星遥感影像,可以有效进行地表的水体信息提取<sup>[3-4]</sup>。

在利用遥感图像进行水体提取的研究中,传统的方法有光谱分类法、单波段阈值法、谱间关系法<sup>[5]</sup>。光谱分类法是依据影像上的地物光谱特征差异,将水体和背景地物进行分类<sup>[6]</sup>。单波段阈值法是选择使水体与非水体的反射率方差最大化的值作为阈值,将遥感影像的直方图分割为水体信息和背景信息<sup>[7]</sup>。谱间关系法是通过分析水体与其他地物在 TM 影像不同波段上的灰度曲线图,从而提取出水体的特征<sup>[8]</sup>。但是这些方法在阴影较多的遥感影像上的分类结果不够理想,提取出的水体面积将会显著多于实际面积。针对水体在多光谱遥感数据上的波谱特性,一些学者利用影像特定的波段进行归一化差值或类似处理,以此突出影像中的水体信息。Mc Feeters<sup>[9]</sup>于 1996 年提出归一化水体指数(NDWI),徐涵秋<sup>[10]</sup>在此基础上修改了波长组合并提出改进的归一化差异水体指数(MNDWI)。闫需等<sup>[11]</sup>结合水系与背景噪音反射的特征,提出了增强型水体指数(EWI)。通过这些水体指数,不仅能描述出影像上的水体信息,还能有效地把水体与背景地物进行区分。然而以上的研究实例中,大部分是针对不同水域的单独影像,无法相对统一且高效地应用于各种遥感影像中的水体提取,也无法解决城市中细小水体难以被提取的问题,具有一定的局限性<sup>[12]</sup>。

近年来,随着计算机视觉的快速发展,语义分割逐渐被应用到更多领域中解决问题<sup>[13]</sup>。作为计算机视觉领域的基本任务之一,语义分割的根本目的是要达到像素级的分类,这和遥感图像的解译有很多共同点<sup>[14]</sup>。基于此,文中提出一种新型模型。首先将遥感影像进行大气校正和假彩色处理,再通过 NDWI 计算和阈值分割得到二值 NDWI 特征图。以此作为多波段信息的代表,在改进后的 Deeplabv3+模型中与原始输入进行特征融合,有效地提取出水体信息。与选取的 U-Net, SegNet, FCN, PSPNet 四种模型相对比,在 PA, IOU, Recall 三种评价指标和提取结果上均有显著的提高。

## 1 数据集制作

### 1.1 数据集来源

Sentinel-2A 卫星是“全球环境与安全监测”计划的第二颗卫星,它提供了独特的全球覆盖范围,具有广阔的视野,用于采集地球陆地表面的高分辨率图像<sup>[15]</sup>。文中分别采用 Sentinel-2A 于 2019 年 12 月 28

日和 2019 年 12 月 11 日所获得的中国长江流域和珠三角地区的两景经过几何精校正的 Level-1C 级遥感产品作为研究对象,像素大小为 10 980×10 980。


### 1.2 数据集处理

在所有本身不带有辐射源的遥感系统中,所记录能量的强度和光谱组成会明显受到大气影响,消除这些影响的过程被称为大气校正<sup>[16]</sup>。考虑到所使用的数据来自不同地区,而遥感图像领域并没有和 Imagenet 数据集类似的预处理归一化参数,为了降低由于数据色差对后续实验的影响,使用 Sen2Cor 工具<sup>[17]</sup>对得到的 Level-1C 级数据进行大气校正得到 Level-2A 级数据,使所有遥感影像数据能够被统一到相近的色度范围内。

使用卷积神经网络对遥感图像中的水体进行提取对图像数据有一定的要求。由于卷积神经网络的工作本质是对图像像素进行特征的提取,在此过程中会存在对纹理和颜色的敏感性<sup>[18]</sup>。经过大气校正的影像中植被和水体颜色相近,不利于直接输入神经网络中,因此需要将遥感影像进行假彩色处理,得到标准假彩色的图像数据,如图 1 所示。



(a)南京遥感影像



(b)广州遥感影像

图 1 经过大气校正和标准假彩色处理后的南京、广州两地遥感影像

### 1.3 训练集和验证集

借鉴于语义分割的经验,训练数据的代表性往往比数据数量更加重要<sup>[19]</sup>。为了均衡训练数据的特征,首先对选取的两幅图片进行数据标注。从图 1 中选取具有代表性的四个像素大小均为 2 048×2 048 的区域

生产训练集。T1 和 T2 分别选用的是以农田、少量城市建筑、具有贯穿性水域的区域。T3 和 T4 分别选用了较多城市建筑、细小河流为主的区域。再选取 V1-V4 四个像素大小均为  $2\,048 \times 2\,048$  的区域用作生产验证集。T1, T2, T3, T4 四个区域的具体影像如图 2 所示。




图 2 标准假彩色图像的训练集

再对选取的四个区域进行数据的增广处理。通过将四张图片进行随机切割、旋转角度、添加噪声点的处理后,扩充成像素大小分别为  $128 \times 128$ ,  $256 \times 256$ ,  $512 \times 512$ ,  $1\,024 \times 1\,024$  的图片集。针对像素大小为  $128 \times 128$  的图片,设定类别占比阈值为 90%,删去其中占比超过阈值的图像,形成以下训练集,如表 1 所示。



表 1 不同尺寸的训练样本数量

像素大小	图片数目
128×128	4 096
256×256	1 024
512×512	256
1 024×1 024	64

## 2 NDWI 计算和阈值分割

NDWI 被广泛应用于遥感图像中的水体提取任务中,它很好地利用了多波段遥感图像特征,将近红外波段和绿波段结合在一起,计算过程如公式(1)所示。为提高神经网络对水体特征提取的效果,文中对训练样本进行 NDWI 计算,并得到灰度图,如图 3 所示。

$$\text{NDWI} = \frac{\text{Green} - \text{NIR}}{\text{Green} + \text{NIR}} \quad (1)$$



(c)NDWI 后 T3 区域 (d)NDWI 后 T4 区域

图 3 经 NDWI 计算后的灰度图

其中植被和水体的差异较大。为了使图像在适应网络输入的同时更突出水体与非水体的差异性,文中使用自适应阈值法对灰度图进行分割。最大类间方差法是由日本学者大津提出的一种自适应阈值分割算法<sup>[20]</sup>,该算法假设图像的像素能够根据阈值而被分成背景与目标两部分,然后通过计算最佳阈值来区分这两类像素,使得区分程度最大化。首先计算背景像素的占比  $\omega_1$  与前景像素的占比  $\omega_2$ ,如公式(2)和公式(3)所示。

$$\omega_1 = \frac{N_1}{\text{Sum}} \quad (2)$$

$$\omega_2 = 1 - \omega_1 \quad (3)$$

再计算背景的灰度平均值  $\mu_1$  以及前景的灰度平均值  $\mu_2$ ,进而得到  $0 \sim M$  灰度区间内的灰度累积值  $\mu$ ,如公式(4)~公式(6)所示。

$$\mu_1 = \sum_{i=0}^t i * \Pr(i | C_0) = \sum_{i=0}^t i * \Pr / \sum_{i=0}^t P_i = \frac{\mu(t)}{\omega_1} \quad (4)$$


$$\mu_2 = \sum_{i=t+1}^{M-1} i * \Pr(i | C_1) = \sum_{i=t+1}^{M-1} i * \Pr / \sum_{i=t+1}^{M-1} P_i = \frac{\mu - \mu(t)}{\omega_2} \quad (5)$$

$$\mu = \mu_1 * \omega_1 + \mu_2 * \omega_2 \quad (6)$$

通过以上步骤,可得类间方差  $g$ ,如公式(7)所示:


$$g = \omega_1 * (\mu - \mu_1)^2 + \omega_2 * (\mu - \mu_2)^2 \quad (7)$$

最后通过遍历的方式,得到使得类间方差  $g$  最大的阈值  $T$ ,利用阈值  $T$  进行图像的二值化。即以阈值  $T$  作为分界线,把经过灰度图进行转换,其中水体的颜色转化为白色,非水体部分的颜色转化为黑色,得到图 4。可以看出此时水体与非水体部分的区分效果较好。



(a)T1 区域灰度图 (b)T2 区域灰度图





### 3 实验模型

#### 3.1 输入处理

现有的研究说明,具有单一输入尺度的模型往往在分割时效果不好<sup>[21-22]</sup>。在遥感影像的水体提取过程中,输入端的尺寸较大则会丢失一些图像细节信息,输入端的尺寸较小则会因为水体数据提取不全产生训练误差,从而影响模型精度<sup>[23]</sup>。此外,由于相同范围内的特征大小和特征类型大部分相似,因此随着网络训练迭代次数的增加,单一输入尺度的模型会出现训练集过度拟合或网络无法收敛的现象。获取到的 Sentinel-2A 卫星遥感影像数据的空间分辨率为 10 m,属于中等分辨率。遥感影像中城市内的河流道路往往

偏窄,在图像观感上小到只有 1 个像素宽,而贯穿城市的河流宽度却相对大的多,单一输入尺度无法满足对大面积水域提取的同时处理好狭窄河流的特征提取,因此,针对以上问题,文中采用多尺度的特征输入。

模型的输入端先将不同尺寸的训练图片均统一到 512×512 像素大小,此过程与池化层中的平均池化理念相似。Lanczos<sup>[24]</sup>是一种常用的插值缩放算法,使用其对图像进行统一放缩并取得连续的像素分布。通过统一像素,让相邻的像素点之间的差异变得更加平滑,避免在图像进行卷积时出现特征值偏差太大的情况。

#### 3.2 改进 Deeplabv3+ 的网络模型

Deeplabv3+<sup>[25]</sup>是语义分割网络系列的最新模型。作者使用编码器和解码器集成多尺度信息,在保留 ASPP 模块的同时,使用 Xception<sup>[26]</sup>作为骨干网络来提高语义分割的鲁棒性和运行速度。ResNet-101<sup>[27]</sup>模型可以训练极深的神经网络,解决了深层网络在反向传播过程中容易出现梯度消失的问题。考虑准确性,训练的迭代次数以及训练速度,文中选择 Deeplabv3+模型作为框架结构,并采用 ResNet-101 作为优化的骨干网络。整个实验模型如图 5 所示。

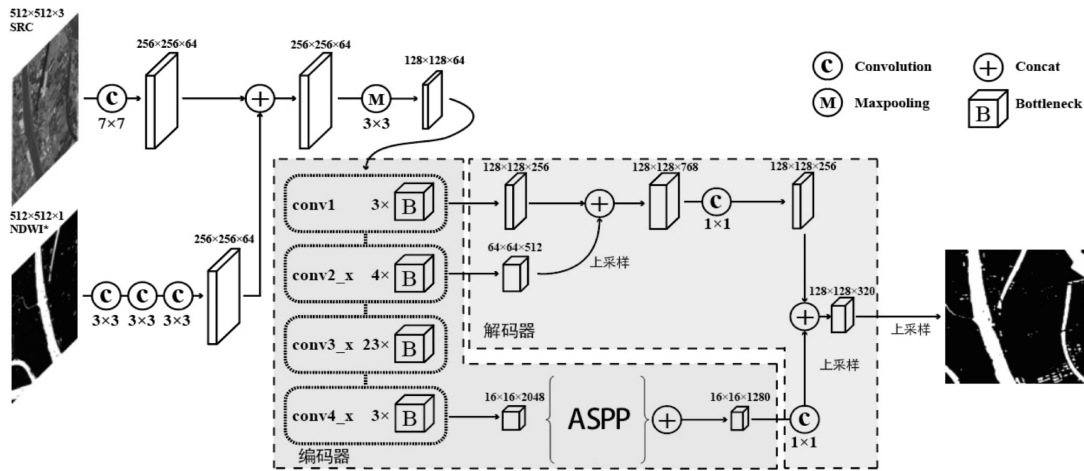


图 5 改进 Deeplabv3+ 的网络模型

在 Deeplabv3+ 中,ASPP 模块输出的特征图与深度卷积网络中特定层的特征图合并,然后进行上采样以获得最终的预测结果,这种将高级和低级特征的融合可以更好地同时保留边界信息和语义信息。基于此,文中针对遥感影像中的水体特征,对 ASPP 模块进行改进。较低级别的特征包含大面积水域的边界信息,而 ASPP 模块获得的特征包含更多的语义信息,因此,在图 5 中的解码器部分,将 ResNet-101 的第二个 CONV 模块输出为低级特征,再通过 1×1 卷积,上采样和连接方法的结合,提取了 ResNet101 的第一个模块后的浅层特征图。再将这两个低级特征图与 ASPP 模块上采样的高级特征结合起来,经过上采样后获得预测结果,使得整体的提取效果更好。


在整个实验模型中,先将遥感影像中的多波段信息添加到网络,以提高水体提取的准确性。再使用自适应阈值分割后的二进制 NDWI 图像与标准的假彩色图像结合,并通过三个 3×3 卷积核进行连接。然后和 ResNet-101 中第一卷积层的特征图拼接,连续输入到后续的残差块中,经过改进的 ASPP 模块结合高级和低级功能信息。最后,使用解码器模块将预测图像恢复为输入大小。

### 4 实验过程和结果分析

#### 4.1 测试集

为验证模型是否可以用于普遍的遥感影像水体提取,选取了 Sentinel-2A 卫星于重庆和潮州获得的遥感

影像。其中图 6(a) 以较大的流域为主, 图 6(b) 含有多分支的水域。与训练集相同, 将两张图片进行大气校正与假彩色处理, 如图 6 所示。再通过数据增广处理后, 作为测试集。



(a) 重庆遥感影像



(b) 潮州遥感影像

图 6 经过大气校正和标准假彩色处理后的重庆、潮州两地遥感影像

#### 4.2 评价指标

采用 PA, IOU 和 Recall 作为实验的评价指标。其中 PA 是像素准确率, 反映了预测类别正确的像素数

量占总像素的比例。IOU 是一种标准度量, 反映了模型对水体的预测结果与真实的标注结果之间的交集与并集的比值。Recall 是召回率, 用于计算正确分类的水体像素与图像中被标记为水的像素总数的比例。三种评价指标的计算公式如下:

$$PA = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (8)$$

$$IOU = \frac{T_p}{T_p + F_p + F_N} \quad (9)$$

$$Recall = \frac{T_p}{T_p + F_N} \quad (10)$$

其中,  $T_p$  表示被分类正确的水像素数量,  $T_N$  表示被分类正确的非水体像素数量,  $F_p$  表示被错误分类为水体的像素数量,  $F_N$  表示被错误分类为非水体的像素数量。

#### 4.3 对比模型

文中选择两种类型的多尺度网络结构作为对比模型。一种是串行多尺度结构的网络, 选择 U-Net<sup>[28]</sup>, SegNet<sup>[29]</sup> 和 FCN<sup>[30]</sup> 为代表, 这些网络在逐层连接中组合了高级和低级特征信息, 以获得多比例视图。另一种是由 PSPNet<sup>[31]</sup> 为代表的并行多尺度网络结构, 它可以视为框架结构, 输入通过深度神经网络获得的高级特征图。将以上四种模型作为对比模型, 与实验模型训练 30 000 轮后, 模型完全收敛, 得到的各项评价指标如表 2 所示。再将测试集输入各模型中, 得到的结果对比如图 7 所示。




图 7 各模型的结果对比

#### 4.4 结果分析

由表 2 可见,对比模型中,PSPNet 在 PA 和 Recall 两个指标上最高,分别为 90.887% 和 89.881%,而 SegNet 在 IOU 指标上最高,为 90.824%。相较于 U-Net, SegNet, FCN, PSPNet 四种模型,改进后的 Deeplabv3+ 模型在三种评价指标上为 94.358%, 94.556% 和 94.782%,均有显著的提高。

表 2 各模型的得分结果 %

模型	PA	IOU	Recall
U-Net	90.465	88.022	88.671
SegNet	89.116	90.824	88.084
FCN	90.040	90.807	89.006
PSPNet	90.887	88.225	89.881
实验模型	94.358	94.556	94.782

图 7 中,第一列的测试集从上往下分别称为图 a, b, c, d, e, f。对于图 a 和图 b,文中实验模型相对于对比模型,在细小河流上对水体提取效果更加均衡,并在保证水体边缘处理的同时抑制了噪点。对于图 c,改进后的 Deeplabv3+ 不仅减少了噪点,也获得了更加完整和平滑的水体边缘细节。对于图 d, e, f,文中模型在保证大面积水域提取效果的同时,也提高了水体提取完整度和边缘细化能力。因此在遥感影像的水体提取上,文中实验模型相比于其他多尺度网络模型,具有更好的效果。

#### 5 结束语

在寻找高精度水体提取模型的基础之上,统一且批量地进行大规模提取是一项具有挑战性的任务。文中先通过对经过大气校正和假彩色处理的遥感影像进行 NDWI 计算、自适应阈值分割得到为二值 NDWI 图像,再利用并行卷积的方式添加进 ResNet-101 中,巧妙地将波段信息与假彩色图像的特征信息融合在一起,有利于神经网络提取水体特征。在 Deeplabv3+ 的基础上,采用 ResNet-101 作为优化的骨干网络,并对 ASPP 模块进行改进,保证大面积水域提取效果的同时,也提高了水体提取完整度和边缘细化能力。通过与选取的 U-Net, SegNet, FCN, PSPNet 四种模型的对比,文中模型不仅在 PA, IOU, Recall 三种评价指标上有了显著提高,在测试结果中也抑制了噪点,增强了水体提取完整度和边缘细化能力,为计算机视觉和遥感领域的结合提供了新思路。

#### 参考文献:

[1] 陈家琦. 全球变化和水资源的可持续发展[J]. 水科学进展, 1996(3): 4-9.

[2] 朱长明, 骆剑承, 沈占锋, 等. DEM 辅助下的河道细小线性水体自适应迭代提取[J]. 测绘学报, 2013, 42(2): 277-283.

[3] 龚林松, 李士进. 基于改进的 SLIC 和 OTSU 的遥感影像水体提取[J]. 计算机技术与发展, 2019, 29(1): 145-149.

[4] 杨柳, 田生伟. 基于分布式计算的遥感图像水体识别研究[J]. 计算机应用与软件, 2016, 33(6): 138-140.

[5] 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.

[6] 于欢, 张树清, 李晓峰, 等. 基于 TM 影像的典型内陆淡水湿地水体提取研究[J]. 遥感技术与应用, 2008(3): 310-315.

[7] 陈文倩, 丁建丽, 李艳华, 等. 基于国产 GF-1 遥感影像的水体提取方法[J]. 资源科学, 2015, 37(6): 1166-1172.

[8] 王国华, 裴亮, 杜全叶, 等. 针对资源三号卫星影像水体提取的谱间关系法[J]. 遥感信息, 2020, 35(3): 117-121.

[9] MCFEETERS S K. The use of the normalized difference water index (NDWI) in the delineation of open water features [J]. International Journal of Remote Sensing, 1996, 17, 1425-1432.

[10] 徐涵秋. 利用改进的归一化差异水体指数(MNDWI)提取水体信息的研究[J]. 遥感学报, 2005(5): 589-595.

[11] 闫需, 张友静, 张元. 利用增强型水体指数(EWI)和 GIS 去噪音技术提取半干旱地区水系信息的研究[J]. 遥感信息, 2007(6): 62-67.

[12] 沈占锋, 夏列钢, 李均力, 等. 采用高斯归一化水体指数实现遥感影像河流的精确提取[J]. 中国图象图形学报, 2013, 18(4): 421-428.

[13] 景庄伟, 管海燕, 彭代峰, 等. 基于深度神经网络的图像语义分割研究综述[J]. 计算机工程, 2020, 46(10): 1-17.

[14] ZHAO Bo, FENG Jiashi, WU Xiao, et al. A survey on deep learning-based fine-grained object classification and semantic segmentation[J]. International Journal of Automation and Computing, 2017, 14(2): 119-135.

[15] 何云, 黄翀, 李贺, 等. 基于 Sentinel-2A 影像特征优选的随机森林土地覆盖分类[J]. 资源科学, 2019, 41(5): 992-1001.

[16] HAGOLLE O, HUC M, PASCUAL D V, et al. A multi-temporal and multi-spectral method to estimate aerosol optical thickness over land, for the atmospheric correction of FormoSat-2, LandSat, VENμS and sentinel-2 images[J]. Remote Sensing, 2015, 7(3): 2668.

[17] 苏伟, 张明政, 蒋坤萍, 等. Sentinel-2 卫星影像的大气校正方法[J]. 光学学报, 2018, 38(1): 322-331.

[18] 郑远攀, 李广阳, 李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用, 2019, 55(12): 20-36.

[19] 张顺, 龚怡宏, 王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用[J]. 计算机学报, 2019, 42(3): 453-482.