

doi: 10.16104/j.issn.1673-1891.2023.02.008

基于弱监督的 VGG 深度学习网络遥感影像云检测

惠 苗

(三明学院信息工程学院, 福建 三明 365004)

摘要: 大多遥感影像云检测方法中, 训练数据需要对影像的每个像素进行标记, 标记成本非常昂贵, 为了减轻深度学习遥感影像云检测中人工劳动标记数据的成本, 图像块标签代替像素标签进行深度学习训练。首先, 将多种下垫面的遥感影像裁剪成图像块并标记, 带有标签的图像块作为数据集; 其次, 块状的数据集训练改进 VGG 深度学习网络, 训练好的网络对大型遥感影像进行云检测; 最后, 选取多种中分辨率卫星图像分别用改进 VGG 与 VGG 网络进行了云检测对比实验。结果表明: 改进 VGG 遥感影像云检测方法能很好地检测出碎云和厚云, 整个云区的精度都在 90% 以上。使用带标签的图像块, 不仅减少了人工劳动, 而且有效地进行遥感影像云检测, 可为弱监督深度学习的遥感影像相关研究提供参考。

关键词: 弱监督; VGG16 网络; 遥感影像; 云检测

中图分类号: TP751 **文献标志码:** A **文章编号:** 1673-1891(2023)02-0046-07

Remote Sensing Image Cloud Detection Based on VGG Deep Learning Network with Weak Supervision

HUI Miao

(School of Information Engineering, Sanming University, Sanming, Fujian 365004, China)

Abstract: In most remote sensing image cloud detection methods, the training data needs to mark each pixel of the image, which is very expensive. In order to reduce the cost of manual labor marking data in deep learning remote sensing image cloud detection, the image block label replaces the pixel label for in-depth learning training. Firstly, the remote sensing images of various underlying surfaces are cut into image blocks and labeled, and the labeled image blocks are used as data sets. Then, the block data set is trained to improve the VGG deep learning network, and the trained network is used for cloud detection of large remote sensing images. Finally, multiple medium resolution satellite images are selected for cloud detection comparison experiments using improved VGG and VGG networks. The results show that the improved VGG remote sensing image cloud detection method can effectively detect fragmented and thick clouds, with an average accuracy of over 90% for the entire cloud area. The use of tagged image blocks not only reduces manual labor, but also effectively detects clouds in remote sensing images, which can provide a reference for the research of remote sensing images with weak supervision and deep learning.

Keywords: weak supervision; VGG16 network; remote sensing image; cloud detection

0 引言

根据国际卫星云气候计划观测数据, 全球区域被大量的云覆盖, 地球表面的年均云层覆盖率在全球范围内约为 58%~66%^[1], 由于光学遥感数据中大量云的存在, 导致遥感图像观测信息的缺失, 浪费卫星宝贵的存储资源, 降低图像的数据利用率^[2]。

云层的存在对下游的遥感图像处理 and 识别造成很大的影响, 高精度的云检测是陆表定量参数精确提取的前提。因此, 发展遥感图像的云检测技术, 是判别遥感图像观测信息缺失程度以及遥感图像进一步利用的关键。

研究人员致力于研究遥感影像云检测的方法, 随着计算机视觉处理技术的不断发展, 逐步形成了

收稿日期: 2023-02-01

基金项目: 三明学院科学研究发展基金暨福建省中青年骨干教师教育科研项目(JAT210430/B20211); 三明学院纵向科研结余资金项目(113/KD22006P)。

作者简介: 惠苗(1980—), 女, 山西忻州人, 副教授, 硕士, 主要研究方向: 信息处理与重建、人工智能、高等教育。

3 大类检测方法:基于光谱阈值的方法^[3-5]、基于机器学习的方法^[6-8]、基于深度学习的方法^[9-11]。基于光谱阈值的方法简单易行,但检测准确率低;基于机器学习方法需要人工进行特征定义,效率低;基于深度学习方法精度高,泛化能力强,是当前最受欢迎的云检测方法之一。Jeppesen 等^[12]提出 RSNet 是基于 U-Net 模型结构,实现了基于 RGB 图像的高精度云检测;Francis 等^[13]基于 U-Net 框架,结合了 Inception 等模块,提出了 CloudFCN 云检测方法;Chai 等^[14]基于 SegNet 分割网络,针对 Landsat 卫星图像实现了云和云阴影的检测;Yang 等^[15]针对低分辨率遥感缩略图像提出了 CDnet,通过设计特征金字塔、边缘细化等模块提高了低分辨率图像云检测的检测精度。基于深度学习方法的云检测能有高检测精度,主要得益于大量的人工标记数据集,特别是近些年的大部分云检测方法归为语义分割任务,人工标记每个像素是否为云,这将耗费大量的人力物力。

由于制作图像块标签明显比图像像素标签节省非常多劳动,为减少人工标记成本,采用带标签的图像块作为遥感影像云检测的数据集。一种弱监督学习的遥感影像云检测方法是带标签的图像块进行网络训练得到的遥感影像像素级别的云掩膜,实现端到端的自动化云检测。遥感影像云检测中使用的深度学习网络为满足小样本数据需求,将 VGG16 网络的卷积层由 5 组改为 4 组,全连接层由 3 层改为 2 层,修改了卷积核的步长和通道数。获取

遥感影像的云掩膜是先对大型遥感影像进行边缘扩充,然后利用重叠滑动窗口分割影像预测到滑动窗口中心点是否是云,用这个结果表示对应像素点的像素值,重组后得到遥感影像的云掩膜。

本文试验使用 Landsat8 遥感影像制作数据集,改进的 VGG16 深度学习网络进行训练,训练好的网络对遥感影像云检测。为了评估这种遥感影像云检测方法的可行性和有效性,对结果的定性和定量方面进行了分析和讨论。结果表明改进 VGG16 网络云检测的效果比原 VGG16 云检测效果更适合小样本数据,并且弱监督学习的遥感影像云检测方法在减少人工标记成本的基础上,准确率还能达到 90% 以上。

1 研究方法

1.1 研究对象

本文选用 Landsat8 遥感影像作为研究对象。Landsat8 卫星自 2013 年发射,是连续的陆地探测卫星的后续卫星。装备有陆地成像仪和热红外传感器,一共 11 个波段,覆盖了从红外到可见光的不同波长范围。Landsat 卫星数据连续性好,易于获取,是目前应用最广泛的数据集之一。从地理空间数据云(<http://www.gscloud.cn/>)下载遥感影像数据,选取不同下垫面贫瘠、森林、草/作物、灌木林、雪/冰、城市、水等遥感影像 19 景,用于制作块状数据集和云检测试验。此遥感影像中云覆盖率不等(表 1),有厚云、薄云和云阴影。

表 1 样本示例

		不同云覆盖率的图片		
		<35%	35%~65%	>65%
原图				
对应 手动掩码				

1.2 数据采集及处理

由于遥感数据占用存储空间大,按像素标记数据集制作成本高,耗费大量的人工劳动。本文制作按图像块标记的数据集用于云检测 VGG 模型的训练,少量的像素级云掩码用于像素级云检测结果的评估。

1) 数据采集。数据来自地理空间数据云的 Landsat8 卫星数据,每个景的遥感影像压缩文件中包含 11 个不同波段的 TIF 格式 Landsat 8 Level-1 数据,元数据文件(MTL.txt),空间分辨率分别为 30 和 100 m。

2) 预处理和训练集制作。选取包含云的影像进行数据集制作,将各景影像的 11 个波段先进行波段合成,去除无信息边缘,然后切割为不重叠的子景图像大小为 64 mm × 64 mm,并存储为 tiff 格式。然后用数字对这些子景做标记(有云或无云),“0”表示图像块 40% 以上无云,“1”表示 30% 以上是云,“2”表示 35% 以上是云阴影,图像块及其对应标签用于训练、验证数据。使用了云覆盖率中等的影像 14 景,制作成 84 735 张各类图像块,按 9:1 分为训练

集和验证集。

3) 测试集制作。为测试云检测的效果,本文使用与训练集不同的其他 5 景遥感影像用于测试。云检测的结果得到的是每个像素是否是云,因此用于测试需要给每景遥感影像中的云进行手工掩码。

1.3 云检测工作流程

在云检测工作中,工作流程如图 1 所示,图像块有带云和非云标签的数据集输入 VGG16 网络进行训练,训练好的网络用于云检测工作。由于本文使用弱监督的深度学习,一张图像块是得到一个分类结果,而云检测工作中一张图像块需要得到和图像块一样大小的像素级云掩膜,因此对每个像素的云分类采用像素邻域的分类结果作为像素分类。在云检测时,由于 Landsat8 影像图幅较大,直接作为深度学习网络输入图像占用内存高,图像处理器很难负担,因此为验证云检测方法性能,本文遥感影像分割成内存可以支持的尺寸进行预测,每块图像通过重叠的滑动窗口取 11 × 64 × 64 大小的图像块 VGG16 网络预测云检测结果,再将每块影像进行拼接得到大型影像的云掩膜。

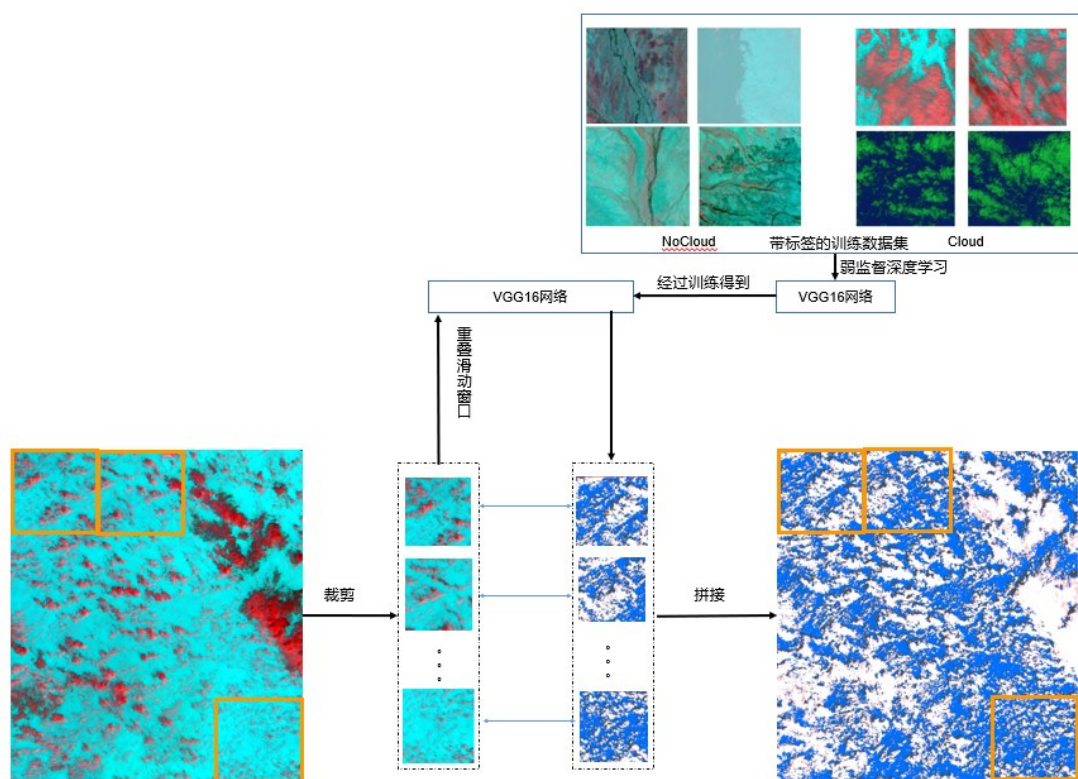


图 1 弱监督深度学习遥感影像云检测工作流程

1.4 VGG16 网络结构

CNN 卷积神经网络作为深度学习的分支,应用于计算机视觉的图像分类、图像分割、目标检测等

领域。一系列的经典 CNN 深度神经网络被提出,在图像分类等任务中表现优异。其中,2014 年 Visual Geometry Group 提出 VGG16 网络^[16],它能很好地适

用于分类和定位任务。VGG网络采用小卷积 3×3 、小池化 2×2 ,减少卷积核计算量,增大感受野。其主要工作证明了增加网络的深度能在一定程度上提升网络性能。

VGG16网络结构为如图2所示,输入图像经过5组VGG block^[16]层不同大小的特征图,图像最终缩放到原输入尺寸的0.125倍。然后是3层全连接层和Softmax输出层得到有云或无云,层与层之间使用

Maxpooling分开,所有卷积后加入ReLU函数。传统VGG16无法对11通道融合特征直接识别,需要修改网络的输入数据通道数和输入数据集的读取方式。另外在传统VGG16网络中输入图像尺寸是 224×224 ,本文使用图像输入尺寸是 64×64 ,因此修改第1组和第2组的Maxpooling,使得第1组和第2组图像尺寸不变。




图2 VGG16网络结构图

1.5 使用重叠滑动窗口扩展场景生成云掩膜

本文采用重叠滑动窗口扩展场景的方法生成遥感影像的云掩膜如图3所示,首先对一张 $11 \times H \times W$ 大小的遥感影像进行边缘填充,填充的方式也可以是填0,或线性插值等方法,本文采用其周边实际遥感影像值的方式进行填充。边缘扩充遥感

影像场景后,使用重叠滑动窗口将扩展的影像分割成 $H \times W$ 个 $11 \times 64 \times 64$ 大小的影像,将这些影像分别输入训练好的VGG16网络进行预测得到影像块的分类值,这些分类结果的二维矩阵图即为遥感影像的云掩膜。




图3 使用重叠滑动窗口生成云掩膜

2 实验结果与分析

2.1 改进VGG16网络

原VGG16网络输入图像尺寸是 224×224 ,本实验将输入图像尺寸改为 64×64 ,并进行了归一化处理,这样不会因为图像尺寸太大导致特征提取不全面,也不会因太小特征提取不足。为满足小样本数据的要求,VGG16网络结构由原来的5块改为4块,各块卷积核的通道数也做了一些修改,全连接层由原来的3层改为2层,对云和不含云做分类,输出节点由1000改为2。改进VGG16是为了使用本文的影像尺寸,并提升云检测效果。改进VGG16网络结构如图4所示,具体参数如表2所示。

在实验过程中,输入图像分辨率为 $11 \times 64 \times$

64 ,第1块卷积层是2个一样的卷积层,用 3×3 、通道数为32、步长为1的卷积核,得到输出为 $32 \times 64 \times 64$ 。这个输出作为最大池化层的输入,最大池化层是 2×2 ,步距是1,图像尺寸不变。

第2块卷积层是2个一样的卷积层,用 3×3 、通道数为64、步长为1的卷积核,得到输出为 $64 \times 64 \times 64$ 。这个输出作为最大池化层的输入,最大池化层是 2×2 ,步距是2,图像尺寸缩小一半。

第3块卷积层是3个一样的卷积层,用 3×3 、通道数为128、步长为1的卷积核,得到输出为 $128 \times 32 \times 32$ 。这个输出作为最大池化层的输入,最大池化层是 2×2 ,步距是2,图像尺寸继续缩小一半。

第4块卷积层是2个一样的卷积层,用 3×3 、通道数为256、步长为1的卷积核,1个卷积层通道数




图4 改进VGG16网络结构图

表2 网络各层操作参数

操作	卷积核	通道	步长	输出
Input		11		[11,64,64]
Conv_1	3×3	32 32	1	[32,64,64]
Maxpooling1	2×2	32	1	[32,64,64]
Conv_2	3×3	64 64	1	[64,64,64]
Maxpooling2	2×2	64	2	[64,32,32]
Conv_3	3×3	128 128 128	1	[128,32,32]
Maxpooling3	2×2	128	2	[128,16,16]
Conv_4	3×3	256 256 512	1	[256,16,16]
Maxpooling4	2×2	512	2	[512,8,8]
FC				32 768

是 512, 得到输出为 $512 \times 16 \times 16$ 。这个输出作为最大池化层的输入, 最大池化层是 2×2 , 步距是 2, 图像尺寸继续缩小一半。提取特征后, 最后全连接层将特征融合, 最后用 softmax 分类。

2.2 实验设置

训练集用于训练改进 VGG16 网络, 验证集用于优化网络参数。改进 VGG16 网络训练时设置学习率初始值为 0.000 1, 损失函数为交叉熵损失 (cross entropy loss), 优化器使用 Adam 优化器, batchsize 设置为 64, 训练 Epoch 为 100, 损失会接近 0, 验证精度在 90% 以上。用于训练的改进 VGG16 网络, 第 1 个 Maxpooling 设置为不改变图像尺寸。

2.3 损失函数

VGG16 网络原始模型中常使用的损失函数为交叉熵损失函数 (cross entropy loss)。交叉熵损失函数的计算如式 (1) 所示。

$$S_c = -(y \log \hat{y} + (1 - y) \log (1 - \hat{y})) \quad (1)$$

式中: y 表示真实的标签值 (正类值为 1, 负类值为 0); \hat{y} 表示预测的概率值 ($\hat{y} \in (0, 1)$)。交叉熵 S_c 表征真实样本标签和预测概率之间的差值。

2.4 实验评价指标

采用定量评价来总结云检测方法的优劣。定量评价指标采用主流的像素级评估指标进行评估^[17]。定量评价指标通过测试图像的准确率 (Accuracy)、分类精度 (Precision) 和召回率 (Recall), 平衡 F 分数 (F1 -score) 来获得, 如式 (2)~(5) 所示。

$$A = \frac{T_p + T_N}{T_p + F_N + F_p + T_N} \times 100\% \quad (2)$$

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (3)$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% \quad (4)$$

$$F_1 = \frac{2 \times (P \times R)}{P + R} \times 100\% \quad (5)$$

式 (2)~(5) 中: A 表示准确率, %; P 表示分类精度, %; R 表示召回率, %; F_1 表示 F1 分数, %; T_p 表示被模型预测为正类的正样本; T_N 表示被模型预测为负类的负样本; F_N 表示被模型预测为负类的正样本; F_p 表示被模型预测为正类的负样本。





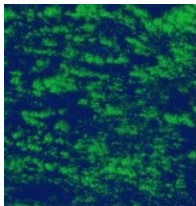



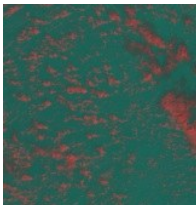
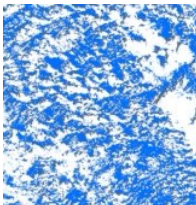
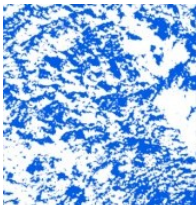
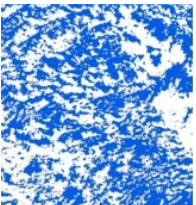
2.5 云检测结果与评估

为验证弱监督深度学习云检测方法的性能, 评估方法的有效性和可行性, 本文采集 Landsat8 遥感影像, 制作块状训练和验证数据集, 像素级测试数据集。训练 VGG16 网络后, 使用重叠滑动窗口扩展场景生成云掩膜, 并对云检测结果与手工掩膜进行可视化和评价指标对比, 分析了 VGG16 网络的云检测的性能。

从实验结果中选取了 3 个典型场景进行视觉评价, 如表 3 所示。波段合成的影像为影像原图, 真值为 Landsat8 Biome 验证数据中经过人工方式标注的云掩膜, VGG16 云检测为原 VGG16 深度学习算法检测的结果, 改进 VGG16 云检测为文中改进的 VGG16 深度学习算法检测的结果, 检测结果及真值中的云白色标识、阴影灰色标识, 其他蓝色标识。使用弱监督改进 VGG16 的云检测比 VGG16 的云检测的视觉效果更接近于真值, 其中 VGG16 的云检测中更多的物像素被检测为云, 改进 VGG16 的云检测边缘更

准确,厚云、薄云都有不错的检测效果。对于云阴影检测效果在文件 LC80160502014041 LGN00 影像中检测效果较好,在文件 LC81010142014189LGN00 影像中检测效果一般。

表 3 弱监督改进 VGG16 网络的陆地卫星遥感影像云检测效果

场景 ID	影像信息	波段合成的影像	真值	VGG16 云检测	改进 VGG16 云检测
LC81010142014189 LGN00	中心纬度:66.683 07 中心经度:161.04034 下垫面:湿地				
LC80150312014226 LGN00	中心纬度:42.808 81 中心经度:-77.409 42 下垫面:城市				
LC80160502014041 LGN00	中心纬度:15.506 67 中心经度:-85.684 48 下垫面:森林				

本文也从深度学习的常用评估指标对弱监督改进 VGG16 网络云检测结果进行定量评价,如表 4 所示。分别使用 VGG16 和改进 VGG16 在 Landsat8 数据集上进行了实验,预测结果和手工标注的掩码进

行了评估,改进 VGG16 的云检测结果在准确率、分类精度、召回率和 F1 分数都高于 VGG16 的云检测结果。对比 3 个先进方法的评估结果,改进 VGG16 在召回率上低于 GAN-CDM-6,其他参数更高。

表 4 弱监督改进 VGG16 网络云检测在测试集上的准确率

模型	准确率	精确度	召回率	F1 分数
VGG16	85.57	90.27	84.09	87.07
改进 VGG16	90.45	90.35	92.93	90.56
WDCD-6 ^[18]	72.09	63.90	98.12	77.39
GCM-6 ^[18]	60.30	57.68	69.34	62.98
GAN-CDM-6 ^[18]	90.20	85.43	96.30	90.54

3 结论

本文在遥感影像云检测任务中使用分类神经网络 VGG16 作为特征提取和图像块分类网络,并对 VGG16 网络进行了改进,比改进前的云检测效果更好,它更适合于影像尺寸较小的研究。在训练集和验证集使用图像块标签,减少数据集制作过程中产生的大量人工劳动,测试集采用重叠滑动窗口方式

对大型影像进行像素级云检测。通过可视化和定量评估结果分析讨论了弱监督改进 VGG16 云检测方法的有效性和可行性。从实验的结果来看,弱监督的改进 VGG16 云检测结果较好,但也存在影像中的物像素被检测为云的现象,后续的研究工作中在数据集制作和云检测方法的优化方面做进一步的研究,提高云检测精度。

参考文献:

- [1] FOGA S, SCARAMUZZA P L, GUO S, et al. Cloud detection algorithm comparison and validation for operational Landsat data products [J]. *Remote Sensing of Environment*, 2017, 194: 379–390.
- [2] ZHU Z, WOODCOCK C E. Automated cloud, cloud shadow, and snow detection in multitemporal Landsat data: an algorithm designed specifically for monitoring land cover change [J]. *Remote Sensing of Environment*, 2014, 152: 217–234.
- [3] KEGLELMeyer W P JR. Extraction of cloud statistics from whole sky imaging cameras [R]. SAND-94-8222, Livermore, CA, United States: Sandia National Labs, 1994.
- [4] IRISH R R. Landsat 7 automatic cloud cover assessment [J]. *Algorithms for multispectral, hyperspectral, and ultraspectral imagery VI* [J]. *International Society for Optics and Photonics*, 2000, 4090: 348–355.
- [5] 马芳等. 多通道卫星云图云检测方法的研究 [J]. *大气科学*, 2007(1): 119–128.
- [6] KANG X, GAO G, HAO Q, et al. A coarse-to-fine method for cloud detection in remote sensing images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 16(1): 110–114.
- [7] FU H, SHEN Y, LIU J, et al. Cloud detection for FY meteorology satellite based on ensemble thresholds and random forests approach [J]. *Remote Sensing*, 2019, 11(1): 44.
- [8] WEI J, HUANG W, LI Z, et al. Cloud detection for Landsat imagery by combining the random forest and superpixels extracted via energy driven sampling segmentation approaches [J]. *Remote Sensing of Environment*, 2020, 248: 112005.
- [9] MATEO G G, GOMEZ C L, CAMPS V G. Convolutional neural networks for multispectral image cloud masking [C] // *IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2017: 2255–2258.
- [10] XIE F, SHI M, SHI Z, et al. Multilevel cloud detection in remote sensing images based on deep learning [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(8): 3631–3640.
- [11] WU X, SHI Z W. Utilizing multilevel features for cloud detection on satellite imagery [J]. *Remote Sensing*, 2018, 10(11): 1853.
- [12] JEPPESEN J H, JACOBSEN R H, INCEOGLU F, et al. A cloud detection algorithm for satellite imagery based on deep learning [J]. *Remote Sensing of Environment*, 2019, 229: 247–259.
- [13] FRANCIS A, SIDIROPOULOS P, MULLER J P. CloudFCN: accurate and robust cloud detection for satellite imagery with deep learning [J]. *Remote Sensing*, 2019, 11(19): 2312.
- [14] CHAI D, NEWSAM S, ZHANG H K, et al. Cloud and cloud shadow detection in Landsat imagery based on deep convolutional neural networks [J]. *Remote Sensing of Environment*, 2019, 225: 307–316.
- [15] YANG J, GUO J, YUE H, et al. CDnet: CNN-based cloud detection for remote sensing imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019: 6195–6211.
- [16] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-04-10) [2022-04-26]. <https://doi.org/10.48550/arXiv.1409.1556>
- [17] 刘子力等. 遥感图像云检测方法综述 [J]. *中国空间科学技术*, 2023, 43(1): 1–17.
- [18] Li J, WU Z, SHENG Q, et al. A hybrid generative adversarial network for weakly-supervised cloud detection in multispectral images [J]. *Remote Sensing of Environment*, 2022, 280: 113197.