

DOI: 10.19650/j.cnki.cjsi.J1905142

遥感图像云检测的多尺度融合分割网络方法^{*}

郭 玥, 于希明, 王少军, 彭 宇

(哈尔滨工业大学测控工程系 哈尔滨 150080)

摘 要:在进行可见光遥感图像高精度云检测时,云自身特征的多变性,以及地物与云之间的特征相似性,会降低检测精度。因此,提出一种带权重的多尺度融合分割网络云检测方法。首先,通过有云区域和无云区域的特征学习,降低对云状的敏感性,同时利用全卷积网络进行端到端训练,实现对每个像素点分类。该方法能够自动提取深层特征,并可将云的深层语义特征与浅层细节特征结合,不但有利于区分下垫面中与云特征相似的地物,还可提高云边缘检测效果,从而提升云量值的检测精度。与其他深度学习分割网络的实验比较分析表明,所提方法可以实现 95.39% 的像素分类准确度,云量值检测误差优于 1%,为解决遥感图像云污染问题提供了新的思路。

关键词:云检测;图像分割;卷积网络;多尺度融合

中图分类号: TN911 TP751 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Cloud detection in remote sensing images with multilevel scale fused network

Guo Yue, Yu Ximing, Wang Shaojun, Peng Yu

(Department of Test and Control Engineering, Harbin Institute of Technology, Harbin 150080, China)

Abstract: When high-precision cloud detection is implemented on visible spectral remote sensing images, the variability of the cloud form and the similarity between the cloud area and the earth object will reduce detection accuracy. To address this problem, this paper proposes a weighted multilevel scale fused network (WMSFNet), which can be trained end-to-end without manual intervention. Firstly, the sensitivity to the cloud form is reduced by learning cloud area and earth object in turn. Meanwhile, WMSFNet can automatically extract high-level spatial features through the fully convolutional network. In this way, cloud and earth object can be distinguished at the pixel level. A multilevel feature fused structure is designed to combine semantic information with spatial information from different levels. The detection of segmentation boundaries can be enhanced. Experiments performed on several real remote sensing images demonstrate that the proposed method can reach pixel accuracy of 95.39%, which is better than other state-of-the-art semantic segmentation methods. The error rate of cloud fraction is less than 1%, which provides a new solution for cloud-contaminated remote sensing images.

Keywords: cloud detection; image segmentation; convolutional network; multilevel scale fusion

0 引 言

遥感是获取地球资源和环境信息的重要手段,可见光遥感由于具备分辨率高、图像细节清晰、内容丰富等特点^[1],是当前重点发展的遥感技术。而云是影响可见光遥感图像质量的主要因素之一。一般情况下,地球表面 50% 的区域被云覆盖^[2],云的存在给遥感图像处理带来

极大不便。被云覆盖的遥感图像可用信息少,却占用系统大量的存储空间和传输带宽,进而降低卫星数据的利用率。因此,可见光遥感图像的高精度云检测成为提升遥感数据利用率的关键。高精度云检测的目的是能够判断图片中云的位置并精确提取云量值,云量值即统计全图中云的面积占整个图片面积的比值。当检测的云量值大于设定的阈值,则说明该幅图片可利用价值低,可以将其剔除。

收稿日期:2019-05-14 Received Date:2019-05-14

^{*} 基金项目:国家自然科学基金(61571160)项目资助

云检测方法经历了从人工判断到计算机处理的阶段,早期的云检测和分类主要依靠观测人员的人工目测进行判断^[3],十分依赖观测人员的主观经验,而且随着遥感资料的迅速增多,全部依靠人工判断效率低下、无法满足需求。寻求自动高效的云检测方法已经成为卫星资料处理中心的重要研究方向。

依靠计算机处理进行云检测的方法是在提取云图特征的基础上完成的,云图特征的提取不断挖掘更深层特征,提取方式也正在从人工提取向自动提取转变。云与地物最直观的区别在于灰度特征,云在图片中表现为偏白,可以通过设定灰度阈值的方法进行云检测^[4-8]。阈值法计算简单,是应用最多的云检测方法,但是需要先验知识且受影响因素较多,检测精度较低。鉴于云的灰度特征不能代表云的所有特性,后续的云检测方法深入挖掘云的其他特征^[9-14],包括频率特征及纹理特征等。

云的灰度、频率、纹理特征均属于人工提取的浅层特征,虽然能够大致区分云与地物,但是利用其进行云检测时存在以下问题。

- 1) 往往直接对整幅图片进行特征提取,由于云状的复杂性,易造成图片中仅有少量云情况的漏检。
- 2) 仅提取浅层特征不利于区分与云特征相似的地物,检测精度差。
- 3) 只能大致判断云的位置,云量值提取精度低。

相较于人工提取的浅层特征,深度卷积神经网络(deep convolutional neural networks, DCNNs)具有更好的特征表达能力,能够自动提取图片的深层特征,提升云检测效果,DCNNs 常被用于图像分类、目标识别和语义分割^[15-17]。云检测需要判断云的位置并精确提取云量值,是一个像素级的分割任务,因此可以基于 DCNNs 进行云检测。

与传统的图像分割方法相比,基于深度学习进行图像分割能够根据图像本身的纹理、场景及其他高层次语义特征得到图像本身需要表达的信息,并最终将图片中的每个像素根据其所属的感兴趣对象进行类别分配,突出显示感兴趣区域的掩模。这类方法预先将输入图片的有云区域与无云区域区分,分别进行学习,从而对云状的复杂性不敏感;能够利用卷积层提取深层语义特征,提高区分下垫面中与云特征相似地物的能力;最终实现对每一像素点分类,得到与输入图片大小相同的二值图片,分别表示有云区域和无云区域,从而实现云位置的判断和云量值的提取。因此,利用 DCNNs 进行云检测可以解决通过人工特征提取的云检测方法中存在的问题。

全卷积网络(fully convolutional networks, FCN)是深度学习算法用作图像分割的开山之作^[18],它将常用的分类模型转换为全卷积模型,将其全连接层替换为卷积层,输出空间映射,从而产生密集像素级别的标签。但是由

于高级深层特征的大输入步幅,分割边界是粗糙的。而本文主要根据云量值判断一幅图片可利用价值的高低,期望云量值的检测精度越高越好。若直接使用 FCN 进行云检测,云量值会因为分割边界粗糙的问题导致提取精度不高。

因此,本文提出一种新型带权重的多尺度融合分割网络(weighted multilevel scale fusion network, WMSFNet)云检测方法。采用多尺度融合的方法利用浅层特征包含的丰富细节信息以及深层特征包含的丰富语义信息,融合二者的优势,在保证检测精度的同时使得分割边界更加精细,并通过优化深层特征和浅层特征的比例达到最好的云区域检出效果。

1 WMSFNet 云检测方法原理

1.1 云检测方法框架

WMSFNet 云检测方法框架如图 1 所示,针对 1 幅输入图片,利用 WMSFNet 进行云检测的步骤如下。




图 1 本文所提云检测方法框架

Fig.1 Framework of the proposed cloud detection

1) 图像标准化。移除图像的平均亮度值,在图像识别任务中,图像的明亮程度不会影响对感兴趣物体的识别。图像标准化有利于感兴趣目标的突出显示,并且减少资源占用。

2) 云图特征提取。利用多层卷积自动提取图片的深

层特征,卷积层是 WMSFNet 的核心,每个卷积层包含固定尺寸的卷积核,在初始化阶段对卷积核权重和偏置参数进行初始化,利用反向传播算法不断更新这些参数,直到达到设定的最大迭代次数,最终实现云与地物的区分。

3) 特征图降维。利用池化层对输入特征的邻近区域进行聚合统计,降低特征图空间尺寸,减少网络中参数数量,减少计算资源损耗,同时,有效抑制过拟合现象。

4) 特征图空间映射。池化层导致特征图尺寸减小,云检测是一个像素级的预测任务,需要得到 1 幅与输入图片大小相同的二值图片,利用反卷积层进行空间映射,产生密集像素级别的标签。反卷积核参数不参与训练过程,在整个训练过程中是固定的。

5) 特征图尺寸复原。反卷积层输出特征图大小与输入图片大小存在偏移,裁剪层的作用是将反卷积层的输出特征图裁剪到与输入图片相同大小,产生最终预测图片。

6) 云量值计算。通过裁剪层后得到 1 幅与输入图片大小相同的二值图片,分别表示有云区域和无云区域。根据二值图片计算云量值,当云量值超出设定的阈值时,表示该幅图片有用信息较少,剔除该图片。

1.2 WMSFNet 网络结构

WMSFNet 使用 VGGNet^[19] 作为主干提取特征,由于云检测是一个像素级的预测任务,需要将 VGGNet 中的全连接层替换为卷积层,并增加反卷积层将分类结果映射到原图像大小。表 1 所示为 VGGNet 和 WMSFNet 的结构。在 VGGNet 中,把具有相同输出特征图尺寸的卷积层设置为一级,根据 VGGNet 的特点,除了池化层会将输入特征图尺寸变为原来的 1/2,其他层均不会改变输入特征图尺寸。因此,每经过一级网络,输出特征图尺寸会缩减为输入特征图的 1/2。




图2 WMSFNet 网络结构

Fig.2 Architecture of WMSFNet for cloud detection

表 1 VGGNet 与 WMSFNet 结构

Table 1 Architecture of VGGNet and WMSFNet

级数	VGGNet		WMSFNet	
	卷积层	尺寸	卷积层	尺寸
第 1 级	2 层, 3x3, 64	1/2	不变	1/2
第 2 级	2 层, 3x3, 128	1/4	不变	1/4
第 3 级	3 层, 3x3, 256	1/8	不变	1/8
第 4 级	3 层, 3x3, 512	1/16	不变	1/16
第 5 级	3 层, 3x3, 512	1/32	增加反卷积层	1/8
/	全连接层	/	替换为卷积层	1/8
/	/	/	融合第 3 级特征图	1/8
/	/	/	增加反卷积层	1

针对深度学习分割方法在云与地物边缘检测粗糙的问题,本文利用多尺度融合思想,将浅层细节特征与深层语义特征融合,利用深层语义特征提高云检测精度,利用浅层细节特征加强在云边缘的检测效果。多尺度融合采用逐像素加权相加的方式实现,如式(1)所示,设 A 、 B 为输入的二维矩阵, C 为输出矩阵, α 和 β 为权重系数, A_{ij} 、 B_{ij} 、 C_{ij} 分别对应矩阵第 i 行 j 列的元素。经过实验验证, α 和 β 分别为 1 和 3 时可以得到最好的云区域检测效果。

$$C_{ij} = \frac{\alpha \times B_{ij} + \beta \times A_{ij}}{(\alpha + \beta)} \quad (1)$$

WMSFNet 网络结构如图 2 所示,其卷积层与其他深度学习网络的卷积层一致,不进行详细说明,设输入特征图的长宽分别为 H 和 W ,输出特征图的长、宽为 H_o 和 W_o ,卷积核窗口的大小为 k ,步幅为 s ,补 0 的个数为 p 。则 H_o 和 W_o 可由式(2)和式(3)获得。

$$H_o = (H + 2 \times p - k) / s + 1 \quad (2)$$

$$W_o = (W + 2 \times p - k) / s + 1 \quad (3)$$

可以认为前 3 级卷积层提取的是浅层特征,后 2 级卷

积层提取的是深层特征,浅层特征包含丰富细节信息,深层特征包含丰富语义信息,融合二者的优势,以达到最好的云检测效果。由于第 3 级输出特征图与第 5 级输出特征

图大小不同,不能直接逐像素相加进行融合。因此,需要先将第5级输出特征图利用反卷积层上采样到原来的4倍后与第3级输出特征图进行逐像素加权平均,最后将融合后的特征图利用反卷积层上采样到原来的8倍,并通过裁剪层得到1幅与输入图片大小相同的二值图片。

1.3 WMSFNet 反卷积层

反卷积^[20]操作实际上是一个转置卷积的过程,例如一个反卷积核的大小为 k ,步长为 s ,补0的个数为 p ,则在计算反卷积时相当于和大小为 k 的卷积核进行卷积,且步长为1,补0的个数为 $k-p-1$,并需要在各个输入单元之间补 $s-1$ 个0。设输入特征图的通道数为 N_c ,长、宽分别为 H 和 W ,输出特征图的通道数为 N_f ,长宽分别为 H' 和 W' 。 H_o 和 W_o 的大小可由式(4)和(5)导出。

$$H'_o = s \times (H - 1) + k - 2 \times p \quad (4)$$

$$W'_o = s \times (W - 1) + k - 2 \times p \quad (5)$$

反卷积操作的具体计算过程如图3所示。图3(a)表示输入特征,图3(b)表示经过反卷积层的输出特征,其中反卷积层的卷积核大小 $k=4$, $s=2$, $p=0$,输入尺寸为 4×4 ,补0后的输入尺寸为 13×13 ,输出尺寸为 10×10 。




图3 反卷积计算过程

Fig.3 Calculation process of deconvolutional layers

反卷积层的卷积核是一个双线性核,可以通过双线性插值获得,设卷积核当前点的坐标为 (i,j) ,中心点的坐标为 (a,b) ,则卷积核当前点的权重值 D 由式(6)计算得到。

$$D = [1 - |(i - a) / 2|] \times [1 - |(j - b) / 2|] \quad (6)$$

以一个大小为 4×4 的双线性核为例说明其计算过程,如图4所示。以第2个格为例,其坐标值为 $(0,1)$,该点对应的权重值为:

$$D(0,1) = [1 - |(1 - 1.5) / 2|] \times [1 - |(0 - 1.5) / 2|] = 0.1875 \quad (7)$$

1.4 WMSFNet 裁剪层

在WMSFNet前5级网络中,只有池化层会影响输出特征图的大小,设输入特征图的大小为 H ,经过第5级的池化后,输出特征图的大小为 $H/2^5$,接下来通过卷积核窗口大小为 7×7 的卷积层,设该层输出为 H_6 ,由式(8)可以得到输出特征图的大小为:




图4 双线性核计算过程

Fig.4 Calculation process of bilinear kernel

$$H_6 = (H/2^5 - 7) / 1 + 1 = (H - 192) / 2^5 \quad (8)$$

接下来是2层卷积层,它们都是 1×1 的卷积核,对输出的尺寸并不会产生影响。因此,最终输入反卷积层的尺寸就是 H_6 。另外,由式(8)注意到如果对于长或宽小于192 pixel的图片,云检测方法是没办法进行处理的,为解决这一问题,对输入图片进行第一次卷积时,将图片补0 100 pixel,此时 H_6 为:

$$H_6 = (H - 192 + 2 \times (100 - 1)) / 2^5 = (H + 6) / 2^5 \quad (9)$$

下一步是将 H_6 的输出上采样到原来的4倍,由式(4)可知,设反卷积的输出特征图长为 H_7 ,则 H_7 为:

$$H_7 = (H_6 - 1) \times 4 + 8 = (H + 38) / 8 \quad (10)$$

而第3级反卷积层的输出特征图的长 H_3 为:

$$H_3 = (H + 198) / 8 \quad (11)$$

第5级卷积层输出特征图经过反卷积层的输出特征图大小 H_7 与第3级卷积层输出特征图 H_3 不相等,显然不能直接进行融合, H_7 与 H_3 的差值为20,需要利用裁剪层将 H_3 裁剪为与 H_7 相同大小,需要指定裁剪的位置,以告知算法在哪里进行裁剪,此时应该设置裁剪的偏移量为10。同理,将融合后的特征图再次经过反卷积层上采样到原来的8倍,与输入图片的尺寸仍有差异,此时应设置裁剪的偏移量为23。由于裁剪相当于将第1层卷积层补0的数目剪去了,剪去的部分不包含图片的信息,因此不会损失精度。

2 WMSFNet 云检测方法实现

为得到云检测模型,首先需要完成云检测网络的训练过程,由于云检测网络训练过程需要依赖计算机进行大量的迭代实验,所需时间较长,对硬件依赖程度较大,最终使用AMX PSC-HB1X服务器实现云检测的训练过程。服务器内存资源为255.90 GB,采用新一代Intel Xeon E5-2640 v4系列处理器,处理器主频为2.40 GHz,具有超高的计算密度,能够满足本文提出的云检测方法在训练过程中需要的带宽需求。

在网络的训练阶段最主要的任务就是得到云检测模型,即获得更新后的卷积核权重和偏置参数。训练

过程首先需要初始化 WMSFNet 中卷积核参数,在正向传播阶段,每一次迭代得到的训练结果与训练标签之间存在一定的误差,误差会导致识别错误,需要通过学习过程不断调整参数,才能得到合适的卷积核参数。WMSFNet 的损失函数为 Softmax Loss,首先 Softmax 的计算公式如下:

$$S_j = \frac{e^{a_j}}{\sum_{k=1}^T e^{a_k}} \quad (12)$$

式中: a_j 表示输入到 Softmax 层的输入向量 a 的第 j 个值, j 的范围是 $1 \sim T$; S_j 表示经过 Softmax 层的输出向量 S 的第 j 个值,即该样本属于第 j 个类别的概率。Softmax Loss 的公式如下:

$$L = - \sum_{j=1}^T y_j \log S_j \quad (13)$$

式中: y 是一个 $1 \times T$ 的向量, y_j 表示 y 的第 j 个元素,且只有一个值是 1,其他 $T-1$ 个值为 0。WMSFNet 的训练损失为最后一层中每个像素的 Softmax Loss 之和。训练过程的目的是使损失函数越来越小。与其他深度学习方法类似,卷积核参数的调整也是通过 BP 算法进行学习。在每次迭代过程中,一些造成识别效果不好的参数都得到更新,使得新的参数对云的检测效果更好,直到达到训练次数,得到最终云检测模型。

在利用检测模型进行云检测时,输入图片经过云检测模型后得到的输出特征图通道数为 2,通过提取该输出特征图数据,可以发现这 2 个输出通道对应位置的数据是相反数关系,即在输出特征图通道数为 1 的某一像素点值为 A ,则输出特征图通道数为 2 的对应像素点为 $-A$ 。若 A 为正数,则代表该像素点属于云,反之属于地物,即实现对输入图片的二值化处理。

3 实用验证

3.1 实验设定

为了评估 WMSFNet 在云检测方面的性能,本文选取高分一号卫星拍摄的 2 m 分辨率全色可见光遥感图像进行测试验证,图片分辨率为 256×256 pixel。为了验证本文提出的方法在全色可见光遥感图像中的效果,本文分别与基于人工特征提取的云检测方法以及用于自然图像分割的成熟语义分割模型进行对比,充分说明 WMSFNet 在云检测方面的有效性。其中基于人工特征提取的云检测方法包括基于单一特征提取的阈值法和基于多特征提取加 SVM 的模式识别方法;用于自然图像分割的成熟语义分割模型包括 FCN、U-net^[21] 和 Deeplab V3+^[22] 模型。

基于 WMSFNet 的云检测方法选用 100 张图片进行训练,20 张图片进行测试验证。通过后续实验可以看出

本文在小样本数据集上已经可以获得较优的检测效果,说明多尺度融合结构可以更加充分的利用特征信息,减少对训练数据的需求量。训练和测试数据中主要包括下列 3 种不同场景,第 1 种是最简单的场景,图片中除了背景之外仅包含云;第 2 种场景不仅含有云,而且包括陆地,存在灰度变化明显的海陆边界;第 3 种场景相对复杂,在背景中含有与云特征相似的建筑物。3 种场景下的测试实例如图 5 所示。




图 5 测试图片与标注图片

Fig.5 Original test pictures and labeled pictures

3.2 评估准则

图像分割中通常使用许多标准来衡量方法的精度,本文采用文献[18]提到的逐像素标记的精度标准。假设共有 $k+1$ 个类, P_{ij} 表示本属于类 i 但被预测为类 j 的像素数量。即 P_{ii} 表示标记正确的像素数量,而 P_{ij} 和 P_{ji} 表示标记错误的像素数量。

1) 像素精度 (pixel accuracy, PA): 标记正确的像素数量占总像素数量的比例。

$$PA = \frac{\sum_{i=0}^k P_{ii}}{\sum_{i=0}^k \sum_{j=0}^k P_{ij}} \quad (14)$$

2) 均像素精度 (mean pixel accuracy, MPA): 计算每个类内被正确分类像素数的比例,然后求平均。

$$MPA = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij}} \quad (15)$$

3) 均交并比 (mean intersection over union, MIoU): 计算真实值和预测值集合的交集和并集之比,然后求平均。

$$MIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij} + \sum_{j=0}^k P_{ji} - P_{ii}} \quad (16)$$

4) 频权交并比 (frequency weighted intersection over union, FWIoU): 在式 (16) 的基础上根据每个类出现的频率为其设置权重。

$$FWIoU = \frac{1}{\sum_{i=0}^k \sum_{j=0}^k P_{ij}} \sum_{i=0}^k \frac{P_{ii} \sum_{j=0}^k P_{ij}}{\sum_{j=0}^k P_{ij} + \sum_{j=0}^k P_{ji} - P_{ii}} \quad (17)$$

5) 云量值检测误差: 云量值即统计全图中云的面积占图片全部面积的比值。云量值 Q 可以通过标记为云的像素点数量 N_{cloud} 除以整幅图片的像素点数量 N 获得, 如式(18)所示。

$$Q = N_{\text{cloud}} / N \quad (18)$$

3.3 实验结果

为了验证本文提出的方法在全色可见光遥感图像中较其他方法具有更好的效果, 本文分别与基于单一特征提取的阈值法、基于多特征提取和 SVM 的模式识别方法以及能够自动提取深层特征的用于自然图像分割的 FCN、U-net、Deeplab V3+模型进行对比, 各方法在不同场景测试实例的检测结果如图 6 所示。图 6 中白色区域代表检测为云的区域, 黑色区域代表检测为地物的区域。




图 6 不同云检测方法的可可视化结果

Fig.6 Visual comparison of different cloud detection methods on test data

阈值法的检测效果如图 6(b) 所示, 阈值法针对云与地物区分较大的场景中具有较好的效果, 但是如果地物与云具有较为相似的特征, 阈值法的检测效果很差, 说明单一的灰度特征不能概括云的所有特性。进而, 继续挖掘云的其他特征, 通过提取云的灰度、频率、纹理特征, 并通过 SVM 分类器验证 1 幅图片中是否有云, 检测效果如图 6(c) 所示。这种方法需要先将 1 幅图片均分成许多小块, 并通过 SVM 预测每 1 个小块中是否有云。由于采取图像均分的方式, 每 1 个小块中可能既包括有云区域又包括无云区域, 因此这种方法只能大致提取云量值, 检测精度较低。

除了灰度、频率和纹理特征外, 云还有许多抽象的深层语义特征。可以利用深度学习的方法自动提取云的深层特征。本文与自然图像分割基础模型 FCN、常用模型 U-net, 以及先进的模型 Deeplab V3+对比, 不同深度学习分割方法进行云检测的结果如图 6(d) ~ (g) 所示。U-net 在所有分割算法中效果最差, 与 WMSFNet 的逐像素加权的融合方式不同, U-net 采用通道数叠加的方式融合浅层特征, 且 U-net 没有用 VGGNet 作预训练模型, 从而导致云检测效果较差, 在背景中灰度变化明显的区域容易造

成误判。除 U-net 外, FCN 和 Deeplab V3+都能大致检测出云的轮廓, 但是 FCN 的大输入步幅导致了边缘检测粗糙的问题, Deeplab V3+由于引入了空洞卷积和条件随机场, 在云边缘的检测效果较为精细, 但是一些处在图像边界的云像素点容易造成误判。由于 WMSFNet 方法融合了浅层细节特征和深层语义特征, 从而能够在云边缘检测上取得较好效果, 云量值提取更加精确。

不同深度学习分割方法的量化指标结果如表 2 所示。WMSFNet 的像素精度 PA 和均交并比 $MIoU$ 分别达到 95.39% 和 89.06%, 相较于本文对比的其他分割网络中检测效果最好的 Deeplab V3+模型分别高出 2.25% 和 1.79%。

表 2 深度分割方法量化指标比较				
Table 2 Metrics of different methods on cloud detection				
(%)				
量化指标	FCN	U-net	Deeplab V3+	WMSFNet
PA	92.23	79.59	93.14	95.39
MPA	91.72	83.00	92.16	94.87
MIoU	82.59	67.07	86.21	89.06
FWIoU	86.01	67.86	87.27	91.35

不同云检测方法的云量值检测结果如表 3 所示。原始图片云量值可以通过手动标记有云区域,用有云区域像素点数量除以图片所有像素点数量获得。SVM 方法的云量值计算采用图 6(c)中空方块数量除以所有方块数量得到。其他方法的云量值计算通过预测的二值图片中判别为云的像素点数目除以图片的所有像素点数目获得。

表 3 云量值检测结果比较

Table 3 Metrics of different methods on cloud fraction (%)				
方法	图片 1	图片 2	图片 3	云量值误差
真值	39.18	25.42	40.49	-
阈值法	28.86	23.42	27.57	8.49
SVM	56.25	62.50	75.00	29.55
FCN	42.13	25.58	41.58	1.40
U-net	46.20	33.97	80.20	18.42
Deeplab	31.81	24.87	44.16	3.86
WMSFNet	39.65	24.64	41.31	0.69

由表 3 可知,与基于人工特征提取的云检测方法相比,基于深度学习的云检测方法在云量值检测方面具有更好的效果,除 U-net 外,其他深度学习分割模型的云量值检测误差均小于 5%。本文提出的 WMSFNet 模型在高分一号拍摄的 2 m 空间分辨率的全色可见光遥感图像上具有最好的云量值检测效果。云量值检测误差仅仅是 FCN 模型的 49.28%, Deeplab V3+模型的 17.87%, SVM 方法的 2.33%,可以实现小于 1%的云量值检测误差。

4 结 论

本文提出了一种带权重的多尺度融合分割网络方法。该网络可以进行端到端的训练,不需手动调整参数,减少云检测过程中人为因素的影响;分别学习有云与无云区域特征,降低对云状的敏感程度;自动提取云的深层特征,提升区分下垫面中与云特征相似地物的能力;充分融合浅层细节特征和深层语义特征,并优化融合比例,使得分割边界更加精细。实验结果表明针对本文的数据集,WMSFNet 较其他深度学习分割方法具备更好的效果,可以实现 95.39%的像素分类准确度,云量值检测误差小于 1%,为解决遥感图像云污染问题提供了一种新颖的思路。虽然在地面测试阶段,取得了较好的云检测效果,但是,WMSFNet 是一个计算密集型的网络,难以满足实时云检测需求与计算平台体积和功耗受限的矛盾问题,因此,后续工作将通过剪枝和量化等方式在保证精度无断崖式改变的前提下优化网络模型,开展实时云检测方法的研究。

参考文献

[1] 徐芳. 可见光遥感图像海面目标自动检测关键技术研究[D]. 北京: 中国科学院大学, 2018.
XU F. Research on Key Techniques of Maritime Target Detection in Visible Bands of Optical Remote Sensing Images[D]. Beijing: University of Chinese Academy of Sciences, 2018.

[2] 赵晓. 高分辨率卫星遥感图像云检测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2013.
ZHAO X. Study on cloud detection method for high resolution satellite remote sensing image [D]. Harbin: Harbin Institute of Technology, 2013.

[3] 李超伟, 邓新蒲, 赵昊宸. 基于多特征提取的遥感影像云检测方法研究[J]. 数字技术与应用, 2017(9): 124-127.
LI CH W, DENG X P, ZHAO H CH. Cloud detection algorithm for remote sensing images based on multiple feature extraction[J]. Digital Technology & Application, 2017(9): 124-127.

[4] POLI G, ADEMBRI G, GHERARDELLI M, et al. Dynamic threshold cloud detection algorithm improvement for AVHRR and SEVIRI images[J]. IEEE International Geoscience and Remote Sensing Symposium, 2010, 38(1): 4146-4149.

[5] HU X Y, WANG Y, SHAN J. Automatic recognition of cloud images by using saliency features [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(8): 1-5.

[6] LIN CH H, LIN BO Y, LEE K Y, et al. Radiometric normalization and cloud detection of optical satellite images using invariant pixels [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 2016(12): 107-117.

[7] ARAI K. Thresholding based method for rainy cloud detection with NOAA/AVHRR data by means of jacobi iteration method [J]. Remote Sensing, 2016, 5(6): 21-27.

[8] 钟静, 康一飞, 韩昱, 等. 高分一号卫星影像自动云检测[J]. 地理空间信息, 2018, 16(4): 52-55, 10.
ZHONG J, KANG Y F, HAN Y, et al. Automatic cloud detection of GF-1 satellite imagery [J]. Geospatial Information, 2018, 16(4): 52-55, 10.

[9] CHRISTODOULOU C I, MICHAELIDES S C, PATTICHIS C S. Multifeature texture analysis for the classification of clouds in satellite imagery [J]. Geoscience & Remote Sensing IEEE Transactions on, 2003, 41(11): 2662-2668.

[10] 陈鹏, 张荣, 刘政凯. 遥感图像云图识别中的特征提取[J]. 中国科学技术大学学报, 2009, 39(5): 484-488.
CHEN P, ZHANG R, LIU ZH K. Feature detection for

- cloud classification in remote sensing images[J]. Journal of University of Science and Technology of China. 2009, 39(5): 484-488.
- [11] GÓMEZ-CHOVA L, CAMPS-VALLS G, BRUZZONE L, et al. Mean map kernel methods for semi-supervised cloud classification [J]. IEEE Transactions on Geoscience & Remote Sensing, 2009, 48(1): 207-220.
- [12] 闫宇松, 龙腾. 遥感图像的实时云检测技术[J]. 北京理工大学学报, 2010, 30(7): 817-821.
YAN Y S, LONG T. Real-time cloud detection in optical sensing image [J]. Transactions of Beijing Institute of Technology, 2010, 30(7): 817-821.
- [13] LI ZH W, SHEN H F, LI H F, et al. Multi-feature combined cloud and cloud shadow detection in GaoFen-1 wide field of view imagery [J]. Remote Sensing of Environment, 2016, 191: 342-358.
- [14] DENG CH W, LI ZH, WANG W ZH, et al. Cloud detection in satellite images based on natural scene statistics and gabor features[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(4): 608-612.
- [15] 王洋, 余祖俊, 朱力强, 等. 基于 CNN 的高速铁路侵限异物特征快速提取方法[J]. 仪器仪表学报, 2017, 38(5): 1267-1275.
WANG Y, YU Z J, ZHU L Q, et al. Fast feature extraction algorithm for high-speed railway clearance intruding objects based on CNN[J]. Chinese Journal of Scientific Instrument, 2017, 38(5): 1267-1275.
- [16] 李绣心, 凌志刚, 邹文. 基于卷积神经网络的半监督高光谱图像分类[J]. 电子测量与仪器学报, 2018, 32(10): 95-102.
LI X X, LING ZH G, ZOU W. Semi-supervised learning via convolutional neural network for hyperspectral image classification[J]. Journal of Electronic Measurement and Instrumentation. 2018, 32(10): 95-102.
- [17] 陈朋, 汤一平, 何霞, 等. 基于多任务 Faster R-CNN 车辆假牌套牌的检测方法[J]. 仪器仪表学报, 2017, 38(12): 3079-3089.
CHEN P, TANG Y P, HE X, et al. Detection method for fake plate vehicles based on multitask faster R-CNN[J]. Chinese Journal of Scientific Instrument, 2017, 38(12): 3079-3089.
- [18] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4): 640-651.
- [19] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J/OL]. Computer Science, 2014. <https://arxiv.org/abs/1409.1556>.
- [20] LIU SH L, FAN H X, NIU X Y, et al. Optimizing CNN-based segmentation with deeply customized convolutional and deconvolutional architectures on FPGA [J]. ACM

Transactions on Reconfigurable Technology and Systems, 2018, 11(3): 19.

- [21] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing & Computer-assisted Intervention. 2015: 234-241.
- [22] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-Decoder with atrous separable convolution for semantic image Segmentation [J]. European Conference on Computer Vision, 2018: 833-851.

作者简介



郭玥, 2013 年哈尔滨工业大学获得学士学位, 现为哈尔滨工业大学电子与信息工程学院测控工程在读硕士研究生, 主要研究方向为硬件加速的图像识别技术与边缘计算。

Guo Yue received his B.Sc. degree from Harbin Institute of Technology (HIT) in 2013. He is a M.Sc. candidate in the Department of Test and Control Engineering at HIT. His research interests include image recognition technology and edge computing.



王少军 (通信作者), 分别在 2005 年、2007 年和 2012 年毕业于哈尔滨工业大学分别获工学学士、硕士和博士学位, 现为哈尔滨工业大学电子与信息工程学院博士后, 深圳鲲鹏人工智能应用创新研究院副院长。主要研究方向为 AI 计算加速, 时间序列分析和自动测试技术。

E-mail: wangsj@hit.edu.cn

Wang Shaojun (Corresponding author) received his B.Sc., M.Sc. and Ph.D. degrees all from Harbin Institute of Technology (HIT) in 2005, 2007 and 2012, respectively. He is currently a post doctor in the School of Electronics and Information Engineering at HIT. He is also the deputy director of Shenzhen Corerain Artificial Intelligence Application Innovation Academy Institute. His research interests include artificial intelligence computation accelerator, time series analysis and automatic test technology.



彭宇, 2004 年于哈尔滨工业大学获得博士学位, 现为哈尔滨工业大学教授、博士生导师, 主要研究方向为虚拟仪器和自动测试、故障预测与健康管理、可重构计算等。

E-mail: pengyu@hit.edu.cn

Peng Yu received his Ph.D. degree from Harbin Institute of Technology (HIT) in 2004. He is currently a professor and Ph.D. supervisor at HIT. His main research interests include virtual instruments and automatic test technology, prognostics and system health management, reconfigurable computing, etc.