

基于 MS-UNet 的 Landsat 影像云检测

王海涛¹, 王一琛¹, 王永强², 钱育蓉^{1*}

¹新疆大学软件学院, 新疆 乌鲁木齐, 830046;

²新疆大学信息工程与科学学院, 新疆 乌鲁木齐, 830046

摘要 针对在进行 RGB 彩色遥感图像云检测研究时,云的形态多变导致对薄云、碎云的检测十分困难的问题,提出一种基于多尺度特征提取的 U 型网络 (MS-UNet)。为了在获得更大感受野的同时保留图像更多的语义信息,提出了一种多尺度模块;在第一组卷积中引入 FReLU(Funnel Rectified Linear Unit)激活函数,以获得更多的空间信息。经过下采样进一步进行特征提取,在上采样像素恢复中通过跳跃层将丢失的信息补充,将云的深层语义特征与浅层细节特征结合,以更好地实现对云的分割。实验结果表明,所提方法能有效地分割出薄云与碎云,与 UNet、MF-CNN、SegNet、DeepLabV3_ResNet50 和 DeepLabV3_ResNet101 网络相比,所提方法的总体精度分别提升了 0.075,0.065,0.070,0.013,0.005。

关键词 大气光学; 云检测; 遥感图像; 深度学习; 多尺度; 空间条件

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/LOP202158.1401002

Cloud Detection of Landsat Image Based on MS-UNet

Wang Haitao¹, Wang Yichen¹, Wang Yongqiang², Qian Yurong^{1*}

¹College of Software, Xinjiang University, Urumqi, Xinjiang 830046, China;

²College of Information Engineering and Science, Xinjiang University, Urumqi, Xinjiang 830046, China

Abstract In order to solve the problem that the detection of thin clouds and broken clouds is very difficult due to the changeable cloud shapes in the research of cloud detection in RGB color remote sensing images, a U-shaped network based on multi-scale feature extraction (MS-UNet) is proposed. Firstly, a multi-scale module is proposed in order to obtain a larger receptive field while retaining more semantic information of the image. Secondly, the FReLU (Funnel Rectified Linear Unit) activation function is introduced in the first group of convolutions to obtain more spatial information. Finally, further feature extraction is performed after down-sampling, and in the up-sampling pixel recovery, the missing information is completed by jump layers, and the deep semantic features of the cloud are combined with the shallow detail features to achieve better cloud segmentation. Experimental results show that this method can effectively segment thin clouds and broken clouds. Compared with UNet, MF-CNN, SegNet, DeepLabV3_ResNet50, and DeepLabV3_ResNet101 networks, the overall accuracy is increased by 0.075, 0.065, 0.070, 0.013, and 0.005, respectively.

Key words atmospheric optics; cloud detection; remote sensing image; deep learning; multi-scale; spatial conditions

OCIS codes 010.1615; 100.2000; 100.3008; 100.4996

收稿日期: 2020-10-12; 修回日期: 2020-11-13; 录用日期: 2020-11-19

基金项目: 国家自然科学基金(61966035)、国家自然科学基金联合基金(U1803261)、智能多模态信息处理团队(XJEDU2017T002)、自治区科技厅国际合作项目(2020E01023)

通信作者: *qyr@xju.edu.cn

1 引言

遥感影像为各行各业提供了重要的数据支持,但是在获取遥感影像时通常会受到“云污染”,根据国际卫星云气候计划 (ISCCP) 的监测数据,地球表面接近七成的区域被云层覆盖^[1]。因此,如何更加准确地对遥感图像进行云检测,成为了遥感领域中的热门问题。

遥感图像中的云检测问题实际上就是对图像中像素进行二分类,将有云的部分从图像中分割出来。在过去的几十年中,研究者针对不同的方法对云检测进行了大量的研究。总的来说,这些方法可大致概括为以下三种:阈值法^[2-3]、统计学习法^[4-5]和深度学习法^[6-8]。

阈值法是一种非常基础的检测方法,由于遥感图像有很多不同波段的光谱,因此可以根据波段的不同在单个像素中将“云”检测出来。掩模算法 (FMask)^[2] 和大津法 (OTSU)^[3] 是典型的基于阈值的算法,他们用阈值函数来判定每一个像素对应的光谱是否为云。但是这种方法高度依赖人为对阈值的设定,需要经过大量的迭代实验才能获得较为精准的取值,获取成本高昂。其次,阈值法对图像中的噪声相当敏感,鲁棒性较差。随着遥感技术的发展,遥感图像的成像质量越来越高,随之而来的基于统计学习的方法被提了出来,例如判别分析法^[4] 和支持向量机 (SVM)^[5], 这些方法基于高质量的遥感图像,利用其分辨率高、空间特征明显的特点,对其形状、纹理、边缘等特征进行分类,但是这类方法过度依赖于图片的像素。深度学习的发展将计算机视觉研究带向了一个新的台阶^[9-11], 遥感图像云检测用于计算机视觉领域的图像分割,也成为了研究的热点问题。Mohajerani 等^[6] 在 2018 年将 FCN (Fully Convolutional Networks)^[12] 应用到云检测中,首次将语义分割引入到云检测问题中,成功地将云分割出来,分割精度达到 88%; Wieland 等^[7] 将 UNet^[13] 应用于 Landsat 和 Sentinel 2 数据,完成了云和云阴影的像素分割,分割精度达到 89%。Shao 等^[8] 提出了一种多尺度特征卷积神经网络 (MF-CNN), 将高层语义信息与低层空间信息相结合,成功地将薄云与厚云检测出来,对薄云的检测精度达到 78%, 对厚云的检测精度达到 90%。虽然深度学习的出现让“云检测”进入了一个新的台阶,使得遥感图像的高维特征得到了更加充分的利用,检测精度也实现了一定的提升,但是基于深度学习的检测

算法在边缘信息以及局部信息的获取上依旧存在着改进的空间。

对于当前基于深度学习的遥感图像“云检测”中存在的“薄云”和“碎云”漏检、错检的问题,本文提出了一种基于多尺度特征提取的 U 型网络 (MS-UNet), 对 Landsat 8 的 RGB 彩色图像进行云检测。在特征提取中,将 UNet 每层的两个 3×3 的卷积核替换成一组多尺度卷积,通过多尺度特征提取,加强对空间特征的学习,并对 ReLU (Rectified Linear Unit) 激活函数进行优化,用 FReLU^[14] (Funnel Rectified Linear Unit) 激活函数提升空间敏感性,以获得更好的分割效果。经过改进后,网络性能获得了很好的提升,能够更好地检测出碎云、薄云。

2 原理与方法

2.1 UNet 网络结构

UNet 是在 FCN 架构的基础上开发的,并于 2015 年首次应用于生物医学图像分割。UNet 采用对称的编解码结构,是语义医学图像分割中最常用的方法之一,基本的 UNet 架构的示意图如图 1 所示^[13]。

图 1 的左半部分是编码路径,右半部分是解码路径。具体来说,在编码路径的每个块包含两个 3×3 卷积和一个最大池层,卷积层用来对输入的遥感图像进行特征提取,最大池化的效果使特征图的大小缩小为原来的 $1/2$ 。解码路径中的每个块包含反卷积、跳跃连接以及两个 3×3 卷积,反卷积将像素尺寸扩大两倍,跳越连接将信息从编码路径传输到解码路径,通过对图像丢失信息的补充,提高了 UNet 分割图像的能力。最后通过使用 1×1 卷积进行通道降维,获得最终的分割结果。然而 UNet 在特征提取过程中不可避免地会丢失一些重要的特征信息,从而对碎云和薄云产生错检、漏检。

2.2 本文提出的方法

1) 多尺度特征提取

在计算机视觉中,特征提取是非常重要的第一步,输入的 RGB 图像经过卷积操作后,含有主要信息的特征图片被提取出来。如图 2 所示,在 UNet 中,每一层由两个 3×3 的卷积核进行特征提取。

卷积运算前后特征图尺寸的计算公式为

$$O = (I - K + 2P) / S + 1, \quad (1)$$

式中: I 为输入的遥感图像尺寸大小; K 为卷积核大小; P 为 padding 大小; S 为步长; O 为最终输出的




图 1 UNet 网络结构

Fig. 1 UNet network structure




图 2 UNet 特征提取模块

Fig. 2 UNet feature extraction module

图片大小。由(1)式可知, padding 的存在使得每次卷积后都会丢失一部分图像信息;此外,由于感受野的不同,输出的特征图在原始图片中像素的映射区域也不同,从而影响对像素特征提取的精度。在原始 UNet 中,两个 3×3 卷积核的感受野实际上等于一个 5×5 卷积核的感受野。因此,本文提出使用一组多尺度的卷积层来替换单一的 3×3 卷积,其结构如图 3 所示。由(1)式可知,在 S 不变时, K 和 P 越小,对图像信息的保留就越完整,因此,使用了大小为 1×1 的卷积来保证每一次卷积后保留更多的特征图信息;用 5×5 的卷积来获得更大的感受野,相比于 3×3 的卷积,前者映射到原始图片上的像素空间更大,在提取特征的时候用到了更多的原图信息,获取了更多的空间特征。最后用 add 将三组卷积获得的特征图片进行相加,对它们进行特征融合,这在获取高层强语义特征的同时,保留了更多的底层细节,使图像包含的特征信息更加丰富。




图 3 多尺度特征提取模块

Fig. 3 Multi-scale feature extraction module

2) 激活函数

ReLU 是神经网络结构中常用的非线性激活函数,如图 4(a)所示,其定义为

$$Y = \max(x, 0), \quad (2)$$

式中: Y 为非线性激活函数; x 为自变量。相比于 sigmoid 函数与 tanh 函数, ReLU 激活函数能够克服梯度消失的现象,加快训练速度。但是在语义分割中, ReLU 激活函数表现出对空间特征的不敏感性,不能够更好地捕捉图片中的空间信息。针对这个问题,本文引入了一种基于空间特性的 FReLU 激活函数,通过增加一个空间层面的条件将 ReLU 函数扩成 2D 激活函数,如图 4(b)所示,它的实现很简单,只增加了一个可以忽略不计的计算开销。该激活函数的形式为

$$Y = \max[x, T(x)], \quad (3)$$

式中: $T(x)$ 为一种高效的空间特征提取方式,其结构简单,不会对网络造成太多负担。为了能够实现




图 4 激活函数示意图。(a) ReLU 函数: $\max(x, 0)$;

(b) FReLU 函数: $\max[x, T(x)]$

Fig. 4 Schematic diagrams of activation function.

(a) ReLU function: $\max(x, 0)$; (b) FReLU function: $\max[x, T(x)]$

这样的空间特征提取,使用一种参数化的池化窗口来加强对空间的关注,该激活函数公式为

$$h(x_{c,i,j}) = \max [x_{c,i,j}, T(x_{c,i,j})], \quad (4)$$

$$T(x_{c,i,j}) = x_{c,i,j}^w p_c^w, \quad (5)$$

式中: $x_{c,i,j}^w$ 为以二维空间上的点 (i, j) 为像素中心,将其第 c 个通道上的非线性激活函数 $h(\cdot)$ 作为输入像素的参数化池化窗口; p_c^w 为在这个参数窗口上的像素在同一通道中共享的系数。FRReLU 函数通过一种非常简单的像素化建模能力,将原始 ReLU 改进成一种在视觉任务中对空间更加敏感的激活函

数。由于在非线性激活的过程中引入了空间条件,网络可以在对应的每个像素上生成相应的 2 维空间条件,同时执行非线性变换,最终生成具有空间相关性的预测结果。

2.3 MS-UNet 网络

本文提出的基于 UNet 的改进的 MS-UNet 网络结构如图 5 所示,在整个网络的特征提取中,使用多尺度特征融合的卷积块替换了原网络中的两个 3×3 卷积。




图 5 改进后的 UNet 网络

Fig. 5 Flowchart of improved UNet

在卷积计算中,假设输入一张大小是 $C \times H \times W$ 的特征图,其中, C 为通道数, H 与 W 分别是特征图的高和宽, W_j, b_j 与 X_j 分别为在第 j 层卷积核处神经元对应的权重、偏置与输入特征图,则第 j 层的输出特征图 Z_j 与其大小 O 可分别表示为

$$Z_j = f(W_j \times X_j + b_j), \quad (6)$$

$$O = \text{floor}[(I + 2P - K)/S] + 1, \quad (7)$$

式中: $f(\cdot)$ 为 ReLU 激活函数。当 (7) 式中 $(I + 2P - k)/S$ 有余数时,使用 $\text{floor}(\cdot)$ 函数进行向下取整,最终计算出输出图片的尺寸 O 。

FRReLU 激活函数的空间特性使其在图像空间信息提取中具有良好的表现,本文根据 Ma 等^[14] 的思想,将第一层中 1×1 卷积后的 ReLU 函数替换成 FRReLU 函数,如图 6 所示。通过 1×1 的小卷积核

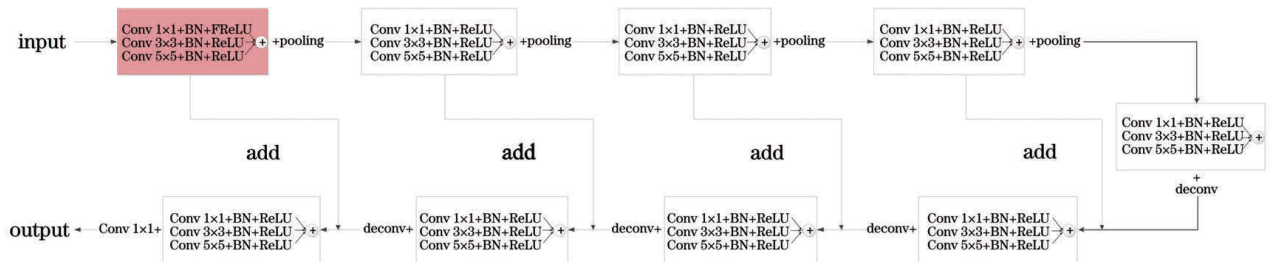


图 6 改进后的 UNet 流程图

Fig. 6 Flowchart of improved UNet

输出一张信息保留最多的特征图,再利用 FReLU 进行非线性激活,同时引入 2 维的空间条件,以更好地提取图像的空间信息。这个过程中只是增加了可忽略不计的开销,却获得了更好的对图像信息的空间敏感度。与之前基于像素^[15]和通道^[16]的方法相比,引入 2 维空间条件的方式用很小的开销实现了像素级的建模能力,并通过常规的卷积方式获取了复杂的遥感图像中的视觉分布信息。在图像初始信息最丰富时,通过加强对空间特征的关注,很好地保留了图像的局部和边缘信息。

在网络的编码器中,每个网络层之间用卷积核大小为 2×2 、步长也为 2 的最大池化进行连接,以更好地保留局部信息,使得模型能够捕获更加丰富的特征信息。在解码器中,使用步长为 2 的 3×3 转置卷积进行层与层之间的连接,以增强网络的学习能力。在跳跃连接层,将原网络中的 concat 改为 add,这可在保留图像信息的同时降低计算开销。在网络的最后,利用一个 sigmoid 激活函数,计算出输入的像素点属于某一类的概率,实现对云的检测。改进后的网络对薄云、碎云的检测精确度有了很大的提升。

3 实验与结果分析

3.1 数据集获取

本文使用的数据集来自陆地卫星 8 号 (Landsat 8)。从中选取了 31 张尺寸约为 $5000 \text{ pixel} \times 5000 \text{ pixel}$ 大小的 R(Band4)、G(Band3)、B(Band2) 三个波段图像生成真彩色图像,并将其裁剪为 4895 张 $384 \text{ pixel} \times 384 \text{ pixel}$ 大小的图像,其中 3543 张用于训练,1352 张用于测试。

3.2 实验环境

本实验在 GeForce GTX 1080 GPU(显存大小为 8 GB)服务器上搭建基于 Pytorch 的语义分割模型 MS-UNet, CPU 是 IntelCorei7-7820HK, 时钟频率为 2.9 GHz, 内存大小为 32 GB, 操作环境为 64 位 Windows 10, 编程语言为 Python3.7, 主要函数库包括 OpenCV、Numpy、PIL 等。

3.3 实验步骤

在数据预处理阶段,将 3534 张图片的像素值归一化至正态分布的 $(0, 1)$ 区间,训练时 batchsize 大小设为 4,共训练 200 个 epoch。在参数优化阶段,使用自适应的 Adam 梯度优化算法,学习率 l_r 为 0.001。测试时,用训练生成的模型对 1352 张图片进行测试,白色表示云,黑色表示背景。

通过对比损失曲线(图 7),可以发现训练次数在达到 30 轮左右时 loss 曲线趋于平缓,随着迭代次数的增加,模型逐渐收敛,达到最优。相比于初始的 UNet 结构,本文提出的 MS-UNet 模型具有更好的收敛性能。

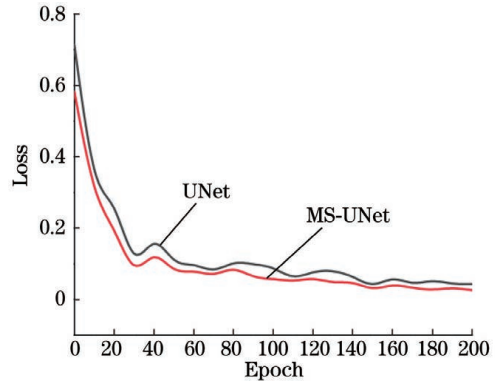


图 7 训练 loss 曲线

Fig. 7 Curves of train loss

3.4 评价指标

为了对测试的结果进行客观的评价,本文使用混淆矩阵^[17-18]对结果进行评估。根据混淆矩阵计算出精确率(precision)、总体精度(accuracy)、召回率(recall)、F1-Score、交并比(IoU)和平均交并比(MIoU),具体表达式为

$$P_{\text{Precision}} = \frac{T_{\text{TP}}}{T_{\text{TP}} + F_{\text{FP}}}, \quad (8)$$

$$A_{\text{Accuracy}} = \frac{T_{\text{TP}} + T_{\text{TN}}}{T_{\text{TP}} + T_{\text{TN}} + F_{\text{FP}} + F_{\text{FN}}}, \quad (9)$$

$$R_{\text{Recall}} = \frac{T_{\text{TP}}}{T_{\text{TP}} + F_{\text{FN}}}, \quad (10)$$

$$F_{\text{F1-Score}} = \frac{2PR}{P + R}, \quad (11)$$

$$I_{\text{IoU}} = \frac{T_{\text{TP}}}{T_{\text{TP}} + F_{\text{FN}} + F_{\text{FP}}}, \quad (12)$$

$$M_{\text{MIoU}} = \frac{1}{N + 1} \sum_{i=0}^N \frac{T_{\text{TP}}}{T_{\text{TP}} + F_{\text{FN}} + F_{\text{FP}}}, \quad (13)$$

式中: T_{TP} 为真实例样本数; F_{FP} 为假实例样本数; T_{TN} 为真反例样本数; F_{FN} 为假反例样本数; $P_{\text{Precision}}$ 为预测为云的样本中真正为云的概率; A_{Accuracy} 为样本中预测正确的像素占有所有像素的比例; R_{Recall} 为被预测为云的样本数; $F_{\text{F1-Score}}$ 为 P 和 R 的加权平均值,用于平衡两者的矛盾, $F_{\text{F1-Score}}$ 最高时,两者同时达到最优值; I_{IoU} 为语义分割常用的评价指标,也是本文中重点考查的指标,它为标签值和预测值的交集和并集之比,比值越接近 1 则语义分割质量越高; M_{MIoU} 为 IoU 的平均值; N 为样本类别数。

3.5 云检测方法对比分析

为了验证本文所提出方法的有效性,首先将其与初始网络 UNet 进行了对比,如图 8 所示。从图 8(a)、(b)中可以看出,在碎云检测中,UNet 容易造成漏检、误检,本文提出的方法对小目标的分割更好;在图 8(c)、(d)中,MS-UNet 相比于 UNet 更能清晰地区分出薄云边界,对像素信息更加敏感。经过改进的 MS-UNet 的整体效果要优于传统的 UNet,在添加了基于空间特征的 FReLU 激活函数后,网络对细节的处理更加优秀,具体指标对比如表 1 所示。从表中可以看出,MS-UNet + FReLU 相对于 UNet,精确率提升了 0.011,总体精度提升了 0.075,召回率提升了 0.158,F1-Score 提升了 0.086,IoU 提升了 0.138,网络的综合性能有了很大的提升。此外,本文还选取了 MF-CNN^[19]、SegNet^[20]和 DeepLabV3^[21]进行了比较,对比结果如图 9 所示。从图中可以看出,MS-UNet 相比于 MF-CNN、SegNet 和 DeepLab 系列网络对细节和边缘的处理更加精细。从表 2 的指标中也能看出,本文方法在性能上更加优秀。基于 UNet 改进的 MS-UNet 算法,在加入了空间敏感性的 FReLU 后,总体精度达到 0.943,但是相对于 DeepLab 系列

网络精确率略有损失,达到 0.901,召回率达到 0.945。综合精确率和召回率可以看出,本文提出的网络获得了最优的 F1-Score,达到 0.921,IoU 达到 0.855,MIoU 可以达到 0.884。总体而言,本文的方法相对于原始的 UNet 网络的性能有了很大的提升,综合性能也优于其他一些典型的语义分割算法。

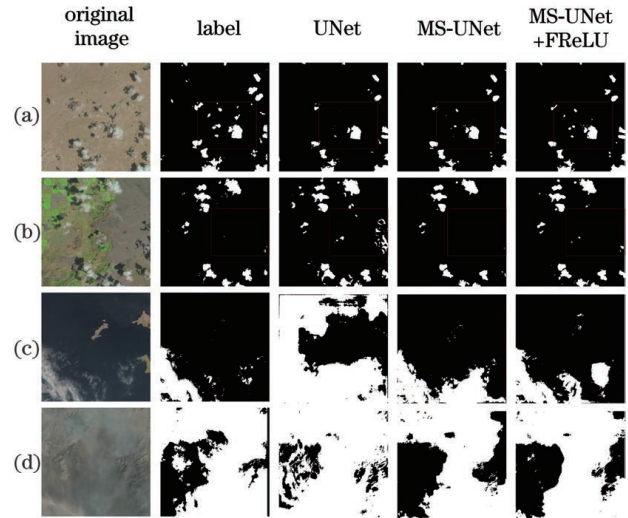


图 8 改进模块的结果对比。(a) (b)碎云;(c) (d)薄云
Fig. 8 Comparison of results of improved modules.
(a) (b) Broken clouds; (c) (d) thin clouds

表 1 改进后的算法与原算法指标对比结果

Table 1 Index comparison results between improved algorithm and original algorithms

Method	Precision	Accuracy	Recall	F1-Score	IoU	MIoU
UNet	0.890	0.868	0.787	0.835	0.717	0.760
MS-UNet	0.881	0.936	0.941	0.912	0.839	0.871
MS-UNet+FReLU	0.901	0.943	0.945	0.921	0.855	0.884




图 9 不同算法的云检测结果对比。(a) (b)碎云;(c) (d)薄云

Fig. 9 Comparison of cloud detection results of different methods. (a) (b) Broken clouds; (c) (d) thin clouds

表 2 不同算法的指标对比

Table 2 Comparison of indicators of different algorithms

Method	Precision	Accuracy	Recall	F1-Score	IoU	MIoU
MF-CNN ^[19]	0.893	0.878	0.886	0.914	0.795	0.833
SegNet ^[20]	0.828	0.873	0.833	0.831	0.711	0.763
DeepLabV3_ResNet50 ^[21]	0.931	0.930	0.877	0.909	0.833	0.863
DeepLabV3_ResNet101 ^[21]	0.912	0.938	0.923	0.918	0.848	0.877
MS-UNet	0.881	0.936	0.941	0.912	0.839	0.871
MS-UNet+FRReLU	0.901	0.943	0.945	0.921	0.855	0.884

4 结 论

基于多尺度特征提取的 MS-UNet 检测算法, 弥补了 UNet 在下采样中造成的边缘以及局部信息丢失的问题, 通过对图片多尺度特征的提取, 使用 FRReLU 激活函数加强对空间信息的关注, 提升了云检测的能力。相比于目前一些较优秀的网络, 所提算法能够更好地对薄云、碎云进行检测, 基本还原了输入图像的细节信息。总体而言, 所提算法能够基于 RGB 彩色图像更加精确地对自然场景中的云进行检测, 解决了目前大多数遥感图像云检测算法中要求多传感器的弊端, 能够很好地实现云检测功能。但是本研究还存在一些没能解决的问题, 如如何精确地分割薄云和厚云, 以及如何在复杂地表环境减少错检、误检。

参 考 文 献

- [1] Li Y Y, Yu R C, Xu Y P, et al. Spatial distribution and seasonal variation of cloud over China based on ISCCP data and surface observations [J]. Journal of the Meteorological Society of Japan Ser II, 2004, 82 (2): 761-773.
- [2] Zhu Z, Wang S X, Woodcock C E. Improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4-7, 8, and Sentinel 2 images [J]. Remote Sensing of Environment, 2015, 159: 269-277.
- [3] Gao X J, Wan Y C, Zheng S Y, et al. Real-time automatic cloud detection during the process of taking aerial photographs [J]. Spectroscopy and Spectral Analysis, 2014, 34(7): 1909-1913.
高贤君, 万幼川, 郑顺义, 等. 航空摄影过程中云的实时自动检测 [J]. 光谱学与光谱分析, 2014, 34 (7): 1909-1913.
- [4] Amato U, Antoniadis A, Cuomo V, et al. Statistical cloud detection from SEVIRI multispectral images [J]. Remote Sensing of Environment, 2008, 112 (3): 750-766.
- [5] Latry C, Panem C, Dejean P. Cloud detection with SVM technique [C]//2007 IEEE International Geoscience and Remote Sensing Symposium, July 23-28, 2007, Barcelona, Spain. New York: IEEE Press, 2007: 448-451.
- [6] Mohajerani S, Krammer T A, Saeedi P. A cloud detection algorithm for remote sensing images using fully convolutional neural networks [C]//2018 IEEE 20th International Workshop on Multimedia Signal Processing (MMSp), August 29-31, 2018, Vancouver, BC, Canada. New York: IEEE Press, 2018: 1-5.
- [7] Wieland M, Li Y, Martinis S. Multi-sensor cloud and cloud shadow segmentation with a convolutional neural network [J]. Remote Sensing of Environment, 2019, 230: 111203.
- [8] Shao Z F, Pan Y, Diao C Y, et al. Cloud detection in remote sensing images based on multiscale features-convolutional neural network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(6): 4062-4076.
- [9] Pei L, Liu Y, Tan H, et al. Cloud detection of ZY-3 satellite remote sensing images based on improved fully convolutional neural networks [J]. Laser & Optoelectronics Progress, 2019, 56(5): 052801.
裴亮, 刘阳, 谭海, 等. 基于改进的全卷积神经网络的资源三号遥感影像云检测 [J]. 激光与光电子学进展, 2019, 56(5): 052801.
- [10] Hu J F, Zhang X Z, Yang C J. Cloud detection of RGB color remote sensing images based on improved M-net [J]. Laser & Optoelectronics Progress, 2019, 56(16): 162804.
胡敬锋, 张秀再, 杨昌军. 基于改进 M 型卷积网络的 RGB 彩色遥感图像云检测 [J]. 激光与光电子学进展, 2019, 56(16): 162804.
- [11] Fu Q, Luo W L, Lü J X. Land utilization change detection of satellite remote sensing image based on

- AlexNet and support vector machine [J]. *Laser & Optoelectronics Progress*, 2020, 57(17): 172802.
- 付青, 罗文浪, 吕敬祥. 基于 AlexNet 和支持向量机相结合的卫星遥感影像土地利用变化检测 [J]. *激光与光电子学进展*, 2020, 57(17): 172802.
- [12] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [13] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [M]//Navab N, Hornegger J, Wells W M, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science*. Cham: Springer, 2015, 9351: 234-241.
- [14] Ma N N, Zhang X Y, Sun J. Funnel activation for visual recognition [M]//Vedaldi A, Bischof H, Brox T, et al. *Computer vision-ECCV 2020. Lecture notes in computer science*. Cham: Springer, 2020, 12356: 351-368.
- [15] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1026-1034.
- [16] Goodfellow I J, Warde-Farley D, Mirza M, et al. Maxout networks [J]. *Computer*, 2013, 28(3): 1319-1327.
- [17] Huang B, Zhao B, Song Y M. Urban land-use mapping using a deep convolutional neural network with high spatial resolution multispectral remote sensing imagery [J]. *Remote Sensing of Environment*, 2018, 214: 73-86.
- [18] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks [J]. *Journal of Machine Learning Research*, 2010, 9: 249-256.
- [19] Shao Z F, Pan Y, Diao C Y, et al. Cloud detection in remote sensing images based on multiscale features-convolutional neural network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(6): 4062-4076.
- [20] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.
- [21] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation [EB/OL]. (2017-06-17) [2020-10-12]. <https://arxiv.org/abs/1706.05587>.