

DOI:10.19651/j.cnki.emt.2208947

基于改进型 U-Net 的遥感云图分割方法<sup>\*</sup>崔志强<sup>1</sup> 单慧琳<sup>1,2</sup> 张银胜<sup>1,2</sup> 吉茹<sup>2</sup>

(1. 无锡学院电子信息工程学院 无锡 214105; 2. 南京信息工程大学电子与信息工程学院 南京 210044)

**摘要:** 云检测是遥感图像预处理的重要步骤,云检测精度直接影响后续遥感图像应用的准确性,针对现有云与云阴影分割任务中,泛化能力差,误检漏检现象严重的问题,本文提出了一种改进型 U-Net 网络模型,该模型以 U-Net 为主干网络,加入高效通道注意力机制,修改激活函数。将遥感图像作为输入,放入基于高效通道注意力的 U 型云图分割模型中进行训练,在获得最优权重后,输出包含云区域、云阴影区域和背景区域的遥感图像分割结果。实验结果表明,相比于现有分割模型,本模型在云和云阴影的分割任务中参数量最低,准确率最高,泛化效果最好。

**关键词:** 卷积神经网络;语义分割;U-Net;注意力机制

**中图分类号:** TP391 **文献标识码:** A **国家标准学科分类代码:** 520.20

Method of remote sensing cloud image segmentation algorithm  
based on improved U-NetCui Zhiqiang<sup>1</sup> Shan Huilin<sup>1,2</sup> Zhang Yinsheng<sup>1,2</sup> Ji Ru<sup>2</sup>

(1. College of Electronic and Information Engineering, Wuxi University, Wuxi 214105, China;

2. College of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

**Abstract:** Cloud detection is an important step in the preprocessing of remote sensing images. The accuracy of cloud detection directly affects the accuracy of subsequent remote sensing image applications. Aiming at the problems of poor generalization ability and serious misdetection and missed detection in the existing cloud and cloud shadow segmentation tasks, this paper designs an improved convolutional neural network model, which uses U-Net as the backbone network and adds efficient channel attention mechanism and modifies activation function. The remote sensing image is used as input and put into the U-shaped cloud image segmentation model based on efficient channel attention for training. After obtaining the optimal weight, the remote sensing image segmentation result including cloud area, cloud shadow area and background area is output. The experimental results show that, compared with the existing segmentation models, this model has lowest parameters, highest accuracy, and best generalization effects in the segmentation task of clouds and cloud shadows.

**Keywords:** convolution neural network; semantic segmentation; U-Net; attention mechanism

## 0 引言

在高分辨率的遥感卫星图像中,云团及其投射阴影不可避免,其遥感影像中的部分区域会被云团污染,甚至会被完全遮盖,进而影响遥感图像的分类、分割、变化检测以及图像匹配等,因此获取未被云团或者云阴影污染的卫星图像是研究前提<sup>[1]</sup>,准确的识别云团及其云阴影区域是遥感卫星图像的处理是关键步骤。云层的光谱信息由粒子大小、水汽、高度、光学厚度等因素决定,影像上云的光谱特征存在多种表现形式,云本身的亮度、透明度以及纹理形状等

特征的表现形式存在差异性,容易与陆地类似于云的明亮物体混淆<sup>[2]</sup>。云阴影检测方面,云阴影容易与土地、地表阴影、水体等偏暗的地物特征相混淆,从而形成误检<sup>[3]</sup>。目前自动的云和云阴影的分割具有一定的难度,早期云检测的方法分为阈值方法和统计学习方法两类。Fu 等<sup>[4]</sup>提出了一种基于集成阈值和随机森林的云检测方法,Zhu 等<sup>[5]</sup>使用经典的 Fmask(function of mask)算法用于 Landsat 系列的卫星图像的云检测。阈值方法简单且计算速度快,已经广泛的用于遥感图像的云检测中。统计学习方法是从小样本数据中计算光谱和纹理信息,采用模式识别的方法,例

收稿日期:2022-01-27

<sup>\*</sup> 基金项目:国家自然科学基金(62071240)、校自然科学研究项目(2020yng001)资助

如聚类分析、支持向量机和人工神经网络等方法来实施云检测。Richard 等<sup>[6]</sup>将遥感图像裁剪为 1 616 像素矩阵作为输入样本,并将计算出的光谱、纹理和其他物理特性输入到概率模型中。Liou 等<sup>[7]</sup>采用奇异值分解(singular value decomposition, SVD)的方法提取云的纹理特征,之后利用 Kohonen 网络进行云检测。和阈值方法相比,统计学习的云检测方法准确率和稳定性更高,依然存在薄云、碎云的漏检问题。

国内外基于卷积神经网络(convolutional neural networks, CNN)的云检测技术做了大量研究工作。Hughes 等<sup>[8]</sup>2014 年开发了一种自动的去除云和云阴影的空间过程,Shi 等<sup>[9]</sup>通过简单线性迭代聚类(simple linear iterative cluster, SLIC)方法将图像聚类为超像素作为子区域,训练了 CNN 学习超像素的特征,识别图像的超像素特征来生成云的概率图。毋立芳等<sup>[10]</sup>提出基于 FCN 的云图分割方法,将云图分割实现到了像素级的分割,但是上采样受到池化层的影响,所以无法做到信息的完全化复原。SegNet<sup>[11]</sup>巧妙地使用编码—译码这样的结构优化了上述问题的不足,SegNet 充分考虑内存占用问题,在空间复杂度上具有优势,然而除非存储量十分有限,SegNet 就其网络本身,优势并不明显。Zhao 等<sup>[12]</sup>提出了 PSPNet,级联多个具有不同步长的全局池化操作来聚合更多的上下文信息实现高质量的像素级场景解析,但它在遥感图像数据集上训练速度较慢、时间较长。Ronneberger 等<sup>[13]</sup>提出用于图像分割的 U-Net,它是一个对称编解码网络结构,其独特之处是使用镜像折叠外推缺失的上下文信息,补充输入图片的语义信息,通过跳跃连接将编解码器中的特征图直接拼接,有效的融合了深层细节信息和浅层语义信息。

现有的 U-Net 模型大都会等权重地分配特征张量上所有空间位置和通道上的信息,而产生大量的计算冗余,导致模型训练速度变慢,分割精度变低。本文提出一种改进型 U-Net 的遥感云图分割方法,注意力机制的引入在一定程度上提升了模型的效率和性能。另外,激活函数的修改提高了网络的抗噪声性能和非线性建模能力。

### 1 云图分割模型

#### 1.1 U-Net 网络结构

在遥感图像中云检测的语义分割任务中,浅层的语义特征主要表征纹理、光谱、位置等信息,深层的语义特征主要是对像素点分类问题的表征。图 1 为原始 U-net 的网络结构图,输入 512×512 图片,进入网络左侧编码部分,进行卷积运算,卷积运算中经过卷积核、归一化和 ReLU 函数等一系列运算后,学习到对应的语义特征。完成卷积运算后,进行下采样操作。下采样过程主要采用的是卷积和最大池化的方式来进行的,模型每进行一次特征提取后,采用最大池化来降低特征图的大小,减少了模型的参数数量的同时也缓解了模型运算压力。设计中每使用一次最大池化,特征

图分辨率都会缩小 1/2,使用 4 次最大池化,输出的特征图分辨率大小为输入原图的 1/16。




图 1 U-Net 网络结构图

右侧解码网络部分主要将输出的压缩特征图还原成原特征图大小,采用的是特征融合和反卷积的方式来进行的,能够缓解遥感图像中样本边缘像素丢失问题,反卷积操作能有效提高图像分辨率。与下采样的过程相反,经过 4 次的反卷积操作后,特征图的分辨率和大小恢复到原图。U-Net 的最后一层是卷积核大小为 1×1 的卷积层,该层将包含 64 个通道的特征图转化为分类结果。

#### 1.2 高效通道注意力机制

在云和云阴影分割任务中,对于编解码结构的 U-Net,该网络中浅层次的特征图偏向于对云、云阴影和背景的纹理、光谱信息的表征,而深层次的特征图更为抽象,偏向于对云图中区域类别的表征。对于特征图,U-Net 网络无法学习到其重要程度,因此,其分割结果并不突出。本模型加入高效通道注意力机制,结构如图 2 所示,将其融入到 U-Net 网络中,形成改进型 U-Net 云图分割模型,使模型自动学习特征图的重要性,如细节、边缘等信息。




图 2 高效通道注意力机制结构图

高效通道注意力机制用几乎可以忽略不计的参数量建立的特征图与其对于的特征权重之间直接的对应关系,生成输入特征图的软权重。深层次的特征图经过高效通道注意力机制后会生成一维注意力向量,用该向量和特征图进行对应元素相乘,得到加权的特征图,完成原始特征图的注意力操作。

高效通道注意力机制优化模型的方法为:

对于大小为  $W \times W \times C$  的特征图  $U, U = [x_1, x_2, \dots, x_c]$ , 对特征图  $U$  进行一维化操作, 得到一维化后的特征图  $Z$ 。一维化操作是指将每个特征通道独立进行求取平均值操作, 将每个特征通道压缩成一个实数, 可以表征特征通道上的全局分布, 其公式如式(1)所示。

$$z_c = FGAP(x_c) = \frac{1}{w \times w} \sum_{i=1}^w \sum_{j=1}^w x_c(i, j) \quad (1)$$

其中,  $z_c \in Z = \{z_1, z_2, \dots, z_c\}$ ,  $FGAP(\cdot)$  表示将特征通道  $c$  中的特征图通过线性运算变成一个实数,  $x_c$  表示特征通道  $c$  中第  $i$  个特征图数据,  $w$  表示特征通道  $c$  中的特征图尺寸大小。

完成上述操作后, 输入特征  $W \times W \times C$  的特征图变成  $1 \times 1 \times C$ 。之后, 利用每个通道及其  $k$  个近邻构造权重矩阵, 即对于第 1 个通道, 它的第 1 至第  $k$  项为非零项, 其他项均为零。第 2 个通道中, 第 2 至第  $k+1$  项为非零项, 其他项均为零, 以此类推。权重矩阵用来捕获特征图之间的跨通道交互, 其中  $k$  代表本地跨通道交互的覆盖范围, 即有多少个相邻参与一个通道的注意力预测。权重矩阵的表现形式如下:

$$\begin{bmatrix} w^{1,1} & \dots & w^{1,k} & 0 & 0 & \dots & \dots & 0 \\ 0 & w^{2,2} & \dots & w^{2,k+1} & 0 & \dots & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & \dots & 0 & 0 & \dots & w^{c,c-k+1} & \dots & w^{c,c} \end{bmatrix} \quad (2)$$

其中,  $w^{c,c-k+1}$  表示特征通道  $c$  中第一个跨通道交互的数值,  $w^{c,c}$  表示特征通道  $c$  中第  $k$  个跨通道交互的数值。因此, 对于特征图  $U$  中第  $c$  个通道特征图所对应的注意力权重, 可以用式(3)表述。

$$w_c = F_h(w, z) = \sum_{j=1}^k w_c^j z_c^j, z_c^j \in \Omega_c^k \quad (3)$$

其中,  $w_c$  表示第  $c$  个特征图对应的注意力权重, 并且  $W_c = [w_1, w_2, \dots, w_c]$ ,  $w_c^j$  表示对应于该特征图的权重矩阵,  $\Omega_c^k$  表示  $z_c$  对应的  $k$  个相邻的特征通道的集合。进一步的, 为了降低参数使之轻量化, 同时保证对每个通道及其  $k$  个近邻通道的权重能够同时优化, 让所有的特征通道共享权重信息, 式(3)更新为:

$$w_c = F_h(w, z) = \sum_{j=1}^k w^j z_c^j, z_c^j \in \Omega_c^k \quad (4)$$

此时, 轻量级自适应注意力机制的参数量变成了  $k$ 。对于式(4), 可以通过一维卷积来实现。因此, 在轻量级自适应注意力机制中, 最终通过卷积核大小为  $k$  的一维卷积完成了特征通道间的信息交互, 公式可写成:

$$w_c = C1D_k(z) \quad (5)$$

其中,  $C1D$  代表一维卷积。得到特征图对应的注意力权重后, 首先利用 Sigmoid 门, 获得  $0 \sim 1$  之间归一化的权重。然后利用最终的权重加权到特征图  $U$  上得到优化后的特征图。其公式如下:

$$U' = \sigma(w_c) \cdot U \quad (6)$$

其中,  $U'$  为第  $c$  个特征通道优化后的特征图。通过上述操作, 完成对权重的抑制或增强, 即显著的特征图得到增强, 非显著的特征图就会相应得被抑制。完成特征重标定的特征图接着进入下面网络, 进行学习。

### 1.3 改进型 U-Net 网络模型

#### 1) 基于高效通道注意力的 U 型云图分割模型

在 U-Net 模型中, 在解码网络的拼接操作加入高效通道注意力机制, 能够极大的保证输入图像的特征信息最大化保留, 相对于以前的网络结构, 云、云阴影和背景等样本特征信息大大的增加。U-Net 与高效通道注意力机制进行融合改进, 提高实验结果的准确性与泛化性。该操作能识别遥感图像的局部信息和全局信息, 通过语义信息的整合能够提高像素点类别预测的准确性。高效注意力机制通过特征重新标定策略完成对现有特征图重要程度的自动学习, 从而让模型“了解到”哪些特征图比较重要, 需要重点关注, 哪些特征图可以少一些关注度。完成加权操作的特征图和上采样操作得到的特征图进行拼接, 用于最终的像素点分类。

图 3 为基于高效通道注意力的 U 型云图分割模型, 基于高效通道注意力的 U 型云图分割模型和 U-Net 最主要的区别在于: 从编码部分得到的结果是否直接用于解码, 经过改进的 U-Net 网络能够提取更加丰富且准确的特征信息, 使得分割结果和泛化效果更加准确。




图 3 基于高效通道注意力的 U 型云图分割模型

#### 2) 修改激活函数

将批处理规范化加在 U-Net 网络的卷积层和激活层中间, 用 GeLU 激活函数代替原有的 ReLU 激活函数, 采用训练二分类的方式分别训练每一个语义分割类别, 将每个二分类训练的模型进行合并, 以得到改进 U-Net 神经网络。

ReLU 函数定义为:

$$f(x) = \max(0, x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (7)$$

其中,  $x$  表示输入量。

GeLU 函数定义为:

$$GeLU(x) = 0.5x(1 + \tanh[\sqrt{2/\pi}(x + 0.044715x^3)]) \quad (8)$$

激活函数提高了网络的非线性建模能力,定义了输入输出之间的映射关系,在很大程度上决定了神经网络的能力。可以从函数中直观的看到,ReLU 函数在  $x \leq 0$  时,输出的结果均为 0,会导致神经元的死亡;GeLU 函数有效得解决了神经元死亡的问题,提升了激活函数的抗噪声性能。

GeLU 函数与原本使用的 ReLU 函数一样有单侧抑制性,并且当方差为无穷大,均值为 0 的时候,GeLU 就等于 ReLU。但 ReLU 只能输入 0 和正数,GeLU 在激活中引入了随机正则的思想,是一种对神经元输入的概率描述,直观上更符合自然的认识,同时实验效果要比 ReLU 和 ELU 更好。

## 2 实验结果与分析

实验基于 Windows 操作系统,pytorch 框架,将改进型 U-Net 模型和现有成熟的分割网络模型,如 FCN<sup>[10]</sup>、SegNet<sup>[11]</sup>、PSPNet<sup>[12]</sup> 等模型进行了对比,在实验之前完成消融实验。

### 2.1 云图分割流程

本文数据集来自哨兵二号卫星,可提供植被、土壤、云层覆盖以及从可见光到短波红外波段的 13 个光谱范围的图像。实验数据使用的是哨兵二号卫星波段 2(红色),波段 3(绿色),波段 4(蓝色)3 个可见波段的图像。其中大图切成小块,对小块用标注工具 Labelme 手动人工标注,用以生成训练数据和测试数据。实验所用数据集的尺寸大小为  $224 \times 224 \times 3$ ,共包含 5 000 张遥感图像。在这 5 000 张数据集中,将其分为 3 部分,训练集占 80%,验证集占 10%,测试集占 10%。

在受监督深度学习中,对于语义分割任务,设计一种从高分辨率光学遥感图像进行处理像素级语义分割的卷积神经网络模型,云与云阴影像素级语义分割系统如图 4 所示。该分割系统对于数据集,采用了一些数据增强方法,将数据集扩充为原来的两倍,扩充现有数据的多样性,例如随机修剪,平移变换,噪声扰动等等。随后将训练的数据输入到模型中进行训练,通过带标签的数据监督学习,利用梯度下降算法微调整个网络参数。最后,将训练最佳的模型权重用测试数据进行测试,直接输出最终预测效果图。

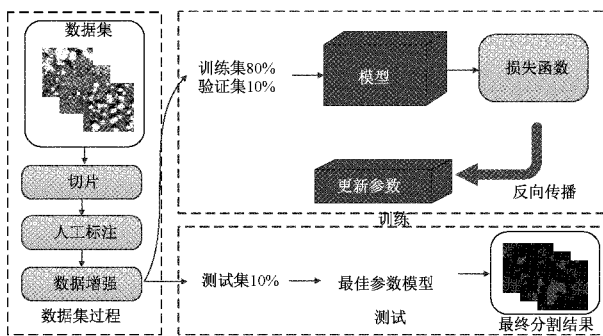


图 4 云与云阴影像素级语义分割系统

### 2.2 不同模型指标对比

改进型 U-Net 模型与其他分割网络在云和云阴影检测任务中的四组泛化实验结果,对不同模型的参数量进行了对比。表 1 为不同分割模型的准确率、平均交并比,精确率、召回率和 F1-指数的结果。

评价指标	FCN	PSPNet	U-Net	SegNet	改进型 U-Net
准确率	94.83	93.02	98.07	99.28	99.59
精确率	94.77	90.05	96.11	98.57	98.80
召回率	96.16	90.73	97.33	98.61	98.87
F1-指数	95.43	90.35	96.74	98.60	98.83
平均交并比	94.51	93.28	97.65	98.84	99.16

从表 1 中可以看出,对于准确率这一项指标,PSPNet 的准确率最低,为 93.20%;其次是 FCN,为 94.83%;的准确率最高,达到 99.59%。

在精确率的指标对比中,改进型 U-Net 的精确率最高,为 98.80%;其次是 SegNet,它的精确率为 98.57%;PSPNet 的精确率最低,为 90.05%;FCN 的精确率也不突出,为 94.77%。

对于召回率这一项指标,PSPNet 的召回率最低,仅为 90.73%。其他 4 个模型的召回率均高于 96%。就召回率这项指标而言,改进型 U-Net 的召回率最高,达到 98.87%。

F1-指数作为一个综合指标,结果比起精确率和召回率更有说服力。在这项指标中,改进型 U-Net 的 F1-指数最高,为 98.83%,比 PSPNet 的 F1-指数高出 8.48%;比 FCN 的 F1-指数高出 3.40%;比 U-Net 的 F1-指数高出 2.09%;比 SegNet 的 F1-指数高出 0.23%。

对于平均交并比这一项分割任务中最为重要的评价指标,PSPNet 的平均交并比最低,为 93.28%;其次是 FCN,为 94.51%;排名第三的模型为 U-Net,它的平均交并比为 97.65;SegNet 的平均交并比仅次于改进型 U-Net,为 98.84%。改进型 U-Net 的平均交并比最高,为 99.16%。

综合 5 个评价指标,PSPNet 在云和云阴影分割任务中性能最差,改进型 U-Net 的五项评价指标均高于其他模型,改进型 U-Net 对于云和云阴影分割任务是最优的选择。

### 2.3 实验泛化结果对比

为了进一步验证该模型在云和云阴影分割任务中的优越性,将 FCN 模型、PSPNet 模型、SegNet 模型以及改进型 U-Net 模型进行了泛化实验,结果如图 5 所示。

为了保证实验的真实性,避免偶然现象,共进行了四组泛化实验,黑色代表背景区域;红色代表云区域;绿色代表云阴影区域。

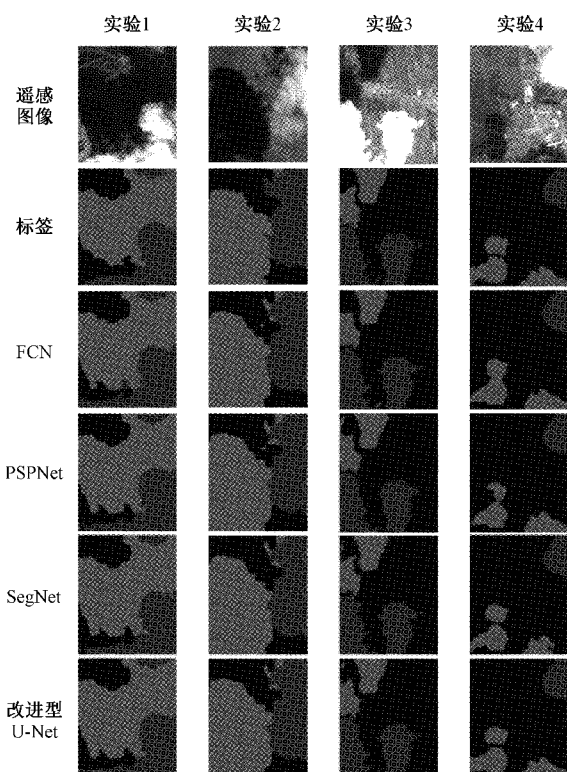


图 5 实验结果对比图

在实验 1 中,改进型 U-Net 的泛化效果最好,在遥感图像的中部偏下区域,FCN 模型出现较大区域误检,该模型将背景区域检测成云,此外还将部分背景区域误检成云阴影区域。PSPNet 的泛化效果比 FCN 模型要好一些,但各区域的边缘信息丢失严重,细节不够清晰。SegNet 模型中,明显出现将云阴影误检成背景的情况。而改进型 U-Net 模型,云图中的细节部分和边缘部分相比于其他模型的泛化结果更加的清晰,能够较好地完成云和云阴影分割任务。在实验 2 中,重点关注遥感图像中间靠上部分的一处偏暗的地物特征,该地物特征与云阴影的光谱信息极其相似,对于 FCN 模型和 PSPNet 模型,该区域被误检成云阴影的区域较大,此外在遥感图像的右侧团云区域,这两个模型都出现了将云样本检测成背景的现象。SegNet 模型的分割效果要优于 FCN 模型和 PSPNet 模型,但相比于改进型 U-Net 模型,还是有一定差距,改进型 U-Net 模型在这张遥感图像中,对于中间靠上部分的偏暗地物特征,改进型 U-Net 误检范围最小,云与云阴影的边缘也是最清晰。实验 3 和实验 4 中,都可以对比看出,改进型 U-Net 的泛化性能要优于其他模型。

综上所述,改进型 U-Net 模型的泛化性能最好,其细节特征以及边缘信息相比于其他模型更加清晰,改进型 U-Net 通过增加高效通道注意力机制,使得模型能够学习到更多且较为细节的特征信息,从而提高了云和云阴影分割任务的准确性。

## 2.4 不同模型的参数量对比

不同模型的参数量对比,其结果如表 2 所示。由表 2 可以看出,FCN 模型的参数量最大,为 128.11 M。其次是 PSPNet,参数量大小为 44.64 M。改进型 U-Net,即基于高效通道注意力的 U 型云图分割参数量和 U-Net 的参数量相似,均为 24.73 M,在这几种模型中最小。改进型 U-Net 模型用几乎可以忽略不计的参数量,提升了云和云阴影分割模型的性能。

表 2 各模型参数量对比表

模型	参数量
FCN	128.11 M
Segnet	30.78 M
PSPnet	44.64 M
U-Net	24.73 M
改进型 U-Net	24.73 M

## 3 结 论

基于改进型 U-Net 的云图分割模型的主干网络为 U-Net 网络,该结构的优点是在获取上下文语义信息的同时还能获取位置信息。该网络中每个卷积层得到的特征图都会级联到对应的上采样层,该操作实现了不同尺度下特征信息的融合,提高了模型的结果精确度。改进型 U-Net 使得通道与其对应的特征权重间有直接的对对应关系,从而重新标定的特征通道的重要程度,该模块使用了几乎可以忽略不计的参数,获得了明显的性能增益。通过各种模型实验结果对比,证明了本文设计的云检测模型的优越性,相比于其他模型,对于云和云阴影的检测任务,改进型 U-Net 准确率最高,泛化效果最好,参数量最低。

## 参考文献

- [1] 何全军,曹静,黄江,等. 基于多光谱综合的 MODIS 数据云检测研究[J]. 国土资源遥感, 2006(3):19-22.
- [2] 董志鹏,王密,李德仁,等. 利用对象光谱与纹理实现高分辨率遥感影像云检测方法[J]. 测绘学报, 2018, 47(7):996-1006.
- [3] 刘心燕,孙林,杨以坤,等. 高分四号卫星数据云和云阴影检测算法[J]. 光学学报, 2019, 39(1):446-457.
- [4] 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, 2018, 11(1), DOI:10.3390/rs11010044.
- [5] 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.

- [6] BANKERT, RICHARD L. Cloud classification of AVHRR imagery in maritime regions using a probabilistic neural network [J]. J. appl. meteorol, 1994, 33(8):909-918.
- [7] LIU R J, AZIMI-SADJADI M R, REINKE D L. Detection and classification of cloud data from geostationary satellite using artificial neural networks[C]. IEEE World Congress on IEEE International Conference on Neural Networks, IEEE, 1994.
- [8] HUGHES M J, HAYES D J. Automated detection of cloud and cloud shadow in single-date Landsat imagery using neural networks and spatial post-processing[J]. Remote Sensing, 2014, 6(6): 4907-4926.
- [9] SHI M, XIE F, ZI Y. Cloud detection of remote sensing images by deep learning [C]. 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), IEEE, 2016:701-704.
- [10] 毋立芳, 贺娇瑜, 简萌. 局部聚类分析的 FCN-CNN 云图分割方法[J]. 软件学报, 2018, 29(4):157-167.
- [11] BADRINARAYANAN V, KENDAL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39:2481-2495.
- [12] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]. Proceedings of International Conference on Computer Vision and Pattern Recognition, 2017: 6230-6239.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical imagesegmentation [C]. Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015:234-241.
- [14] LI J, WU Z, HU Z, et al. A lightweight deep learning based cloud detection method for Sentinel-2A imagery fusing multi-scale spectral and spatial features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, DOI:10.1109/TGRS.2021.3069641.
- [15] WANG Q, WU B, ZHU P. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020.
- [16] 薄振华, 管雪元, 马训穷, 等. 遥感云图纹理特征提取算法实时加速设计[J]. 电子测量技术, 2021, 44(1):125-129.

#### 作者简介

崔志强, 本科, 主要研究方向为深度学习、图像处理等。

单慧琳(通信作者), 博士研究生, 副教授, 主要研究方向为深度学习、信号与信息处理等。

E-mail: shanhuilin@nuist.edu.cn