

# 珠海一号高光谱影像云检测算法

陈 丽<sup>1,2</sup>, 贾源源<sup>1,2</sup>

(1 中科院上海技术物理研究所 上海 200083;

2 中国科学院大学 北京 100049)

**摘要:** 珠海一号高光谱卫星具有高空间、高光谱、高时间分辨率等特点, 有效推动了高光谱遥感数据在农林环境、自然资源探测等领域的广泛应用, 其中高精度的云检测是遥感数据预处理的关键步骤。如何对高光谱图像有效特征提取并克服传统云检测方法特征复杂、算法参数多、计算量大、鲁棒性差等缺陷, 是高光谱云检测研究的关键问题。为此, 提出了一种多尺度特征融合的 U 型结构网络, 模型首先利用残差模块进行特征编码, 并将编码进行多尺度融合, 在网络的跳跃连接处引入了坐标注意力机制提取有用信息, 最后通过残差解码得到输出结果。实验前首先利用主成分分析降维, 将高光谱数据重构为 4 维影像数据, 然后通过数据标注与数据增强, 建立珠海一号高光谱影像云检测数据集。采用了 38-Cloud 云数据集训练初始网络参数, 随后利用构建的数据集进行迁移学习。实验结果表明, 对于所建立的珠海一号高光谱云检测数据集, 所提方法的像素准确率达到 92.28%, 可以实现高精度的高光谱遥感影像云检测。

**关键词:** 云检测; 残差网络; 多尺度; 注意力机制; U 型结构网络

**中图分类号:** P407.8; TP75 **文献标志码:** A **文章编号:** 2095-1000(2023)02-0092-08

**DOI:** 10.12347/j.ycyk.20221128001

**引用格式:** 陈丽, 贾源源. 珠海一号高光谱影像云检测算法[J]. 遥测遥控, 2023, 44(2): 92-99.

## Cloud detection algorithm based on Zhuhai-1 hyperspectral image

CHEN Li<sup>1,2</sup>, JIA Yuanyuan<sup>1,2</sup>

(1. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 20083, China;

2. University of Chinese Academy of Sciences, Beijing 10049, China)

**Abstract:** Zhuhai-1 hyperspectral satellite has the characteristics of high spatial, high spectral and high temporal resolution, which effectively promotes the wide application of hyperspectral remote sensing data in the fields of agriculture, forestry and natural resources detection, among which high precision cloud detection is the key step of remote sensing data preprocessing. How to effectively extract features from hyperspectral images and overcome the defects of traditional cloud detection methods, such as complex features, many algorithm parameters, large amount of computation, and poor robustness, is a key issue in the research of hyperspectral cloud detection. In this paper, a U-shaped structure network with multi-scale feature fusion is proposed. The model firstly uses the residual module for feature coding and multi-scale fusion of coding. The coordinate attention mechanism is introduced at the jump junction of the network to extract useful information, and finally the output is obtained by residual decoding. Before the experiment, principal component analysis (PCA) was used to reduce the dimensionality of hyperspectral data to reconstruct the 4D image data. Then, through data annotation and data enhancement, the Zhuhai-1 hyperspectral image cloud detection dataset was established. In this paper, 38-Cloud Cloud data is used to train the initial network parameters, and then the constructed data sets are used for transfer learning. The experimental results show that for the established Zhuhai-1 satellite hyperspectral cloud detection dataset, the pixel accuracy of the proposed method reaches 92.28%, which can realize high precision hyperspectral remote sensing image cloud detection.

**Keywords:** Cloud detection; Residual network; Multiscale; Attention mechanism; U-Net

**Citation:** CHEN Li, JIA Yuanyuan. Cloud detection algorithm based on Zhuhai-1 hyperspectral image[J]. Journal of Telemetry, Tracking and Command, 2023, 44(2): 92-99.

## 引 言

珠海一号高光谱卫星(OHS)隶属于珠海一号卫星星座,空间分辨率为10 m,光谱分辨率为2.5 nm,波长范围400 nm~1 000 nm,星上载荷支持获取256波段,根据上注指令,自主选择其中32波段下传,通过8星组网,可实现2天半左右覆盖全球、特定区域1天重访,数据采集能力强,为遥感应用研究提供全球覆盖高光谱数据支持,地物分析能力突出,在农业、林业、灾害应急保障和自然资源等领域得到了广泛的应用<sup>[1]</sup>。光学卫星对地遥感中,云在可见光到近红外波段对太阳辐射具有强反射特性,会导致影像获取地表信息缺失或错误表达。研究表明,全球云的平均覆盖面积超过66%<sup>[2]</sup>,大面积的云覆盖成为遥感影像利用的重大障碍。因此在将卫星图像用于应用研究前,正确有效地进行云检测是至关重要的预处理步骤。

目前,已开发了多种方法来实现遥感图像的云检测任务,包括基于光谱阈值的方法<sup>[3-8]</sup>、基于经典机器学习的方法<sup>[9,10]</sup>和基于深度学习的方法<sup>[11-13]</sup>。基于光谱阈值的方法通常识别云像素光谱特征,并通过适当的阈值将云区域与非云区域分开。例如,Irish等<sup>[3]</sup>提出一种自动云覆盖评估算法(Automatic Cloud Cover Assessment, ACCA),用于Landsat-7 ETM+(Enhanced Thematic Mapper Plus)卫星图像自动云检测。Zhu等人<sup>[4]</sup>开发了掩膜函数Fmask(Function of Mask),它可以通过精心设计的多通道阈值方法来识别Landsat图像中的云和云影,在此基础上,后续依此提出Tmask(Multi-temporal Mask)<sup>[5]</sup>、改进的Fmask<sup>[6]</sup>方法,进一步提高云检测精度。Li等人<sup>[7]</sup>提出的MFC(Multi-feature Combined)方法通过联合图像纹理和光谱信息,实现了对GF-1影像的高精度云检测。Qiu等人<sup>[8]</sup>开发了Fmask4.0,通过整合辅助数据、开发基于HOT(Haze Optimized Transformation)的云概率方法及结合光谱纹理信息,实现极地雪、冰、云区分,在Landsats 4-8、Sentinel-2影像数据都取得了高精度云检测效果。由于高精度云检测需要大量光谱信息以确定阈值,基于光谱阈值的云检测方法常常泛化能力弱,场景适应性及鲁棒性差。随着机器学习理论的发展,机器学习模型在图像分类的优异表现,吸引了云检测领域研究者的注意力。例如,Kang等人<sup>[9]</sup>通过训练支持向量机在

HIS颜色空间分割云层,引导滤波技术细化云边界,提出一种无监督云检测方法。An等人<sup>[10]</sup>通过堆叠颜色特征、统计信息、纹理特征和结构化信息建立复杂的图像特征空间,训练基于最小化数据特征及标签之间残差的场景学习器实现云检测。传统的机器学习方法通过对遥感图像空间信息的挖掘利用,降低了云检测方法对光谱信息的高度依赖,但由于经典机器学习模型通常依据大量的先验知识,进行复杂的模型构建和特征提取,在面对复杂下垫面时往往需要人工干预才能有效地捕捉影像特征,以达到云检测的目的。由于卷积神经网络CNNs(Convolutional Neural Networks)具有自动提取图像特征的特性,基于深度学习的云检测方法迅速发展。Ronneberge等人<sup>[11]</sup>通过在传统全卷积神经网络FCN(Fully Convolutional Networks)编解码器之间加入特征融合及反卷积操作,提出U-Net模型。张家强等人<sup>[12]</sup>将残差模块引入U-Net模型编码层用于云检测,提高了模型的精度和泛化能力。Jeppesen等人<sup>[13]</sup>基于U-Net框架提出RS-Net,使用Landsat 8图像RGB通道实现高精度的快速云检测。

基于U-Net模型的云检测方法已初见成效,但传统U型编解码结构编码端所采用的简单卷积与下采样操作,使该结构无法准确获取上下文语义信息,造成特征融合尺度单一、网络参数多、计算冗余等问题。针对上述情况,本文提出了一种新型U-Net网络,具体改进如下:①采用残差网络ResNet来提取主干特征信息;②为了更好地融合浅层和深层特征,减少信息丢失,将编码层进行了多尺度特征融合;③在跳跃连接后引入了Coordinate Attention注意力机制对权值进行调整,有利于提取有用信息;④利用跳跃连接进行残差解码。本文采用了38-Cloud云数据训练初始网络参数,随后利用构建的数据集进行迁移学习。通过在珠海一号高光谱云检测数据集进行对比实验,改进后的U-Net模型较原版U-Net模型在训练时长及检测精度上均有较大提高。

## 1 数据处理与研究方法

本文旨在使用改进的U-Net模型对珠海一号高光谱影像进行云检测,主要步骤包括数据预处理、数据集构建、模型改进和实验。方法流程如图1所示。

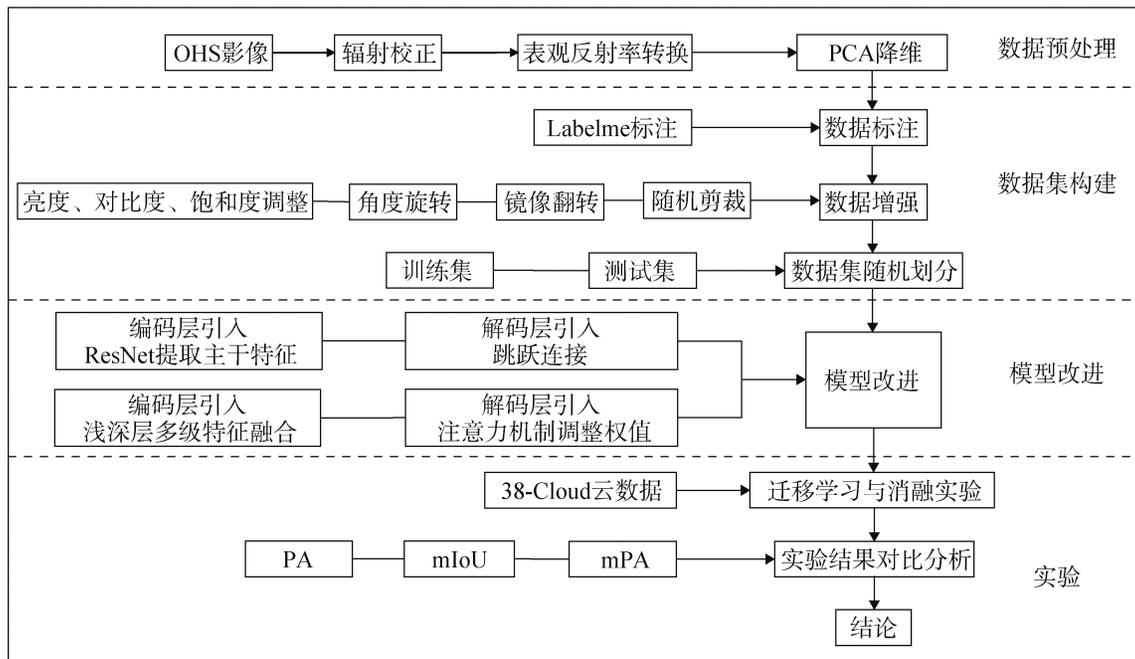


图 1 方法流程图

Fig.1 Flow chart of method

1.1 数据预处理

本文使用珠海一号高光谱卫星数据 L1B 级产品, 波段范围在 400 nm~1 000 nm 之间, 光谱分辨率为 2.5 nm, 空间分辨率为 10 m, 单景图像尺寸为 5 036 像素×5 036 像素, 单景覆盖面积约为 2 536 km<sup>2</sup>, 共采用 6 幅影像作为训练样本, 所有影像数据由珠海欧比特宇航科技股份有限公司提供, 根据每幅影像主要覆盖的下垫面类型可归档为 7 种类型: 裸地、森林、山体、草地/农用地、冰雪覆盖、城市及水体。所选取影像分布在我国各地, 下垫面类型复杂, 据此建立数据集进行云检测研究具有一定代表性。

为了减小不同影像之间的辐射差异, 本文使用的珠海一号 OHS 数据均通过辐射定标后, 转换为大气层顶反射率。

首先, 将 L1B 级像素 DN 值数据通过辐射定标转换为辐亮度值, 辐射定标公式如下:

$$L_{\lambda} = \text{gain} \times \text{DN} + \text{offset} \quad (1)$$

式中,  $L$  为波长为  $\lambda$  的波段的辐亮度值;  $\text{gain}$  和  $\text{offset}$  为该波段的绝对辐射定标系数。之后, 通过公式 (2) 将像素辐亮度值转换为大气层顶反射率值:

$$\rho_{\lambda} = \frac{\pi \times L_{\lambda} \times d^2}{\text{ESUN}_{\lambda} \times \cos \theta_s} \quad (2)$$

式中,  $\rho_{\lambda}$  为波长为  $\lambda$  的波段的大气层顶反射率值;  $d$  为影像获取时刻日地平均距离;  $\text{ESUN}_{\lambda}$  为卷积到传感器波段的标准大气层顶太阳辐照度值;  $\theta_s$  为影像获取时对应太阳天顶角。

1.2 PCA 数据降维

高光谱影像数据量大, 且难以保证所有光谱波段对于云检测有积极作用。为了减少光谱冗余问题, 采用了 PCA 算法进行数据降维, 同时为满足后续基于 38-Cloud 云数据集的场景迁移学习需求, 本文针对高光谱影像大气层顶反射率数据依据 Landsat 8 云检测常用波段的光谱范围, 通过主成分分析在蓝、绿、红、近红外波段分别提取 1 个主要光谱波段, 重构影像数据。处理示例如图 2 所示。

1.3 数据集构建

使用 Labelme 软件对重构影像数据进行逐像素点标注, 如图 3 所示, 其中云像素显示为红色, 非云像素显示为黑色。

考虑到原始高光谱影像尺寸和实际训练时间等因素, 将标注后的影像无重叠分割成 486 幅 512 像素×512 像素大小的图像, 随后对其分别进行了旋转、镜像翻转、随机裁剪、中心裁剪、亮度、对比度调整等操作, 实现数据增强目的, 扩充数据量到 3 402 幅图像, 数据集有效类别数为 2。

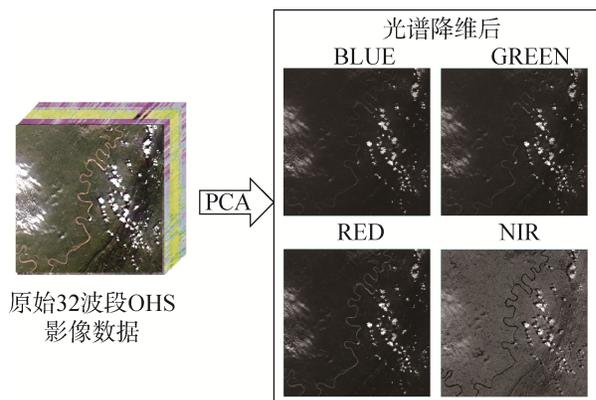


图2 PCA降维处理示例

Fig.2 Example of PCA dimensionality reduction processing

## 2 模型结构

本文算法整体框架如图4所示。网络主要分为左边编码模块和右边解码模块两部分。在编码模块依靠卷积和下采样来提取不同尺度的特征图，

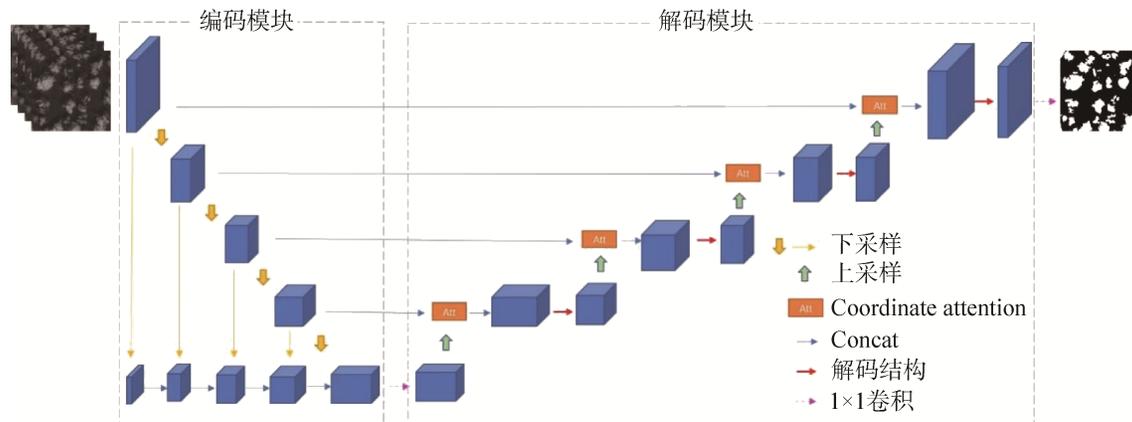


图4 网络整体框架

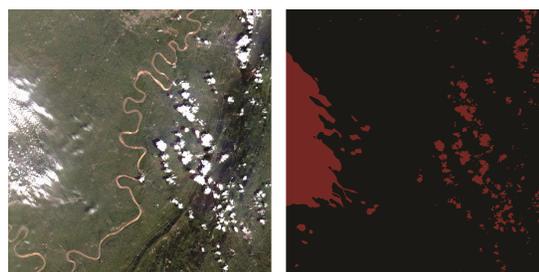
Fig.4 Overall network framework

### 2.1 残差网络模块

随着网络深度的不断增加，模型会出现梯度消失的问题，导致网络精度下降。而He等人<sup>[15]</sup>提出的ResNet可以有效解决该问题。为了提高算法的检测精度，增强算法的鲁棒性和泛化能力，本文利用了ResNet网络作为主干特征提取网络来代替原本的编码过程。构建ResNet网络的核心是残差模块，其公式为

$$y = F(x) + x \quad (3)$$

其中  $x$  和  $y$  为模块的输入和输出， $F(x)$  为残差函



(a) 原图 (a) Original  
(b) 标签图 (b) Labeled image

图3 原始影像和标签图像示例

Fig.3 Example of original and labeled image

同时将各尺度下提取到的每层特征图通过下采样到相同的尺度大小进行特征融合。在网络的右侧部分开始解码时，首先将编码过程获取的特征图与解码中上采样获取的同一尺度特征进行融合，通过注意力机制模块 Coordinate Attention<sup>[14]</sup>获取权重特征图，然后再对其进行解码。网络算法通过编码器模块提取到特征，解码器模块则对图像信息进行还原从而实现云分割。

数。为减小模型结构，本文构建的残差网络在ResNet50的基础上进行了调整，减少了残差模块数量，其所包含的残差模块具体数量见表1。

### 2.2 多尺度信息融合

在遥感图像中，有的云因体积比较小，在图中只占较少的像素，如果直接下采样有可能会丢失部分有用信息。因此本文算法在U-Net网络的基础上增加了一种融合多个尺度信息的方式。这种融合方法是将编码层上的特征图下采样至最小特征图的大小，实现对不同尺度的上下文信息提取，并将其融合在一起，如图5所示。通过不同感受

表 1 残差网络模块结构参数

Table 1 Structural parameters of residual network module

Layer name	Conv1	Conv2_x	Conv3_x	Conv4_x	Conv5_x
Output size	112×112	56×56	28×28	14×14	7×7
Blocks	Conv 7×7,64	Max_pool 3×3 $\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 2$

野的特征融合在一起, 可以更好的获取浅层细节信息和深层语义信息, 得到更多的上下文联系, 减少了特征信息的丢失, 为后续解码过程做铺垫。

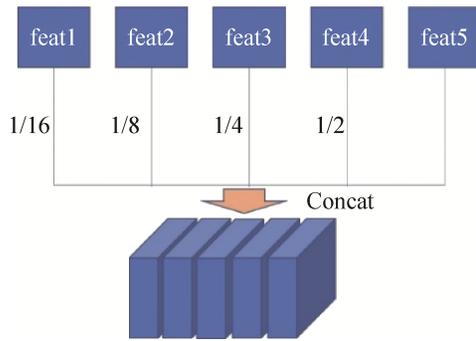


图 5 多层特征融合

Fig.5 Multi-layer feature fusion

### 2.3 Coordinate Attention (CA)

注意力机制 CA 可以从有限的资源中筛选出高价值信息, 降低其他信息的关注度, 有效提高任务处理的准确率。在网络训练中, 通过添加注意力机制可以增强网络的特征提取能力。SENet<sup>[16]</sup>即典型的通道注意力机制, 能够显著地提升模型性能, 但其只关注通道信息而忽略了位置信息。而本文引入的 CA 结构能够将位置信息嵌入到通道注意力中, 可以同时捕获位置信息和通道信息, 且比其他同时关注通道信息和位置信息的注意力机制模块更轻量高效。

CA 模型与 SENet 模型在整体架构上非常相似, 都采用了分支网络来计算注意权重。CA 与 SENet 的不同之处在于: SENet 是直接二维全局平均池化后线性激活得到单维的通道注意力权重, 如图 6 (a) 所示, 这种方式相当于把二维空间信息压缩成了一维, 即丢失了位置信息; 而 CA 也进行了全局池化, 但将其分解为垂直 (Y) 和水平 (X) 两个方向并行, 保留了这两个方向的长距离依赖关系,

如图 6 (b) 所示。通过这种方式可以分别沿两个空间方向聚合成独立注意力图, 每个图都捕获了一个空间方向保留精确的位置信息, 即在生成的注意力图中保留了位置信息。最后生成对方向和位置敏感的特征图, 可以将其互补地输入特征图, 以增强关注对象的表示。

CA 模块对于一个输入特征图  $X \in R^{C \times H \times W}$ ,  $C$ 、 $H$ 、 $W$  代表其通道数、高和宽, 首先沿着水平和垂直两个方向进行一维平均池化, 因此, 高度为  $h$  的第  $c$  个通道的输出可以表示为

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (4)$$

式中  $x_c(h, i)$  为  $c$  通道下  $(h, i)$  位置的值。同理, 宽度为  $w$  的第  $c$  个通道的输出可以写为

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq i < H} x_c(i, w) \quad (5)$$

随后, 将两个方向的输出拼接在一起, 并适用卷积变换函数对其进行变换:

$$f = \delta(F_1[z^h, z^w]) \quad (6)$$

式中,  $\delta$  为非线性激活,  $[\ ]$  表示空间上的 Concat 过程,  $F_1$  表示  $1 \times 1$  卷积,  $f$  表示为在水平和垂直两个方向上的中间特征图, 其大小为  $C/r \times (H+W)$ ,  $r$  是缩小比, 其与在 SENet 中的定义相同。然后沿着空间维度方向将  $f$  分割为两个独立的张量  $f^h \in R^{C/r \times H}$ ,  $f^w \in R^{C/r \times W}$  并分别使用  $F_h$ 、 $F_w$  两个  $1 \times 1$  卷积并激活得到与输入  $X$  具有相同通道数的张量。

### 2.4 残差解码

U-Net 网络在解码过程中对上采样后的融合特征图进行了两个卷积, 受残差网络中跳跃链接的启发, 本文在原来的解码过程中也增加了跳跃连接, 如图 7 所示。通过残差模块可以缓解网络梯度消失的问题, 有利于信息的后向传播, 提高检测精度。

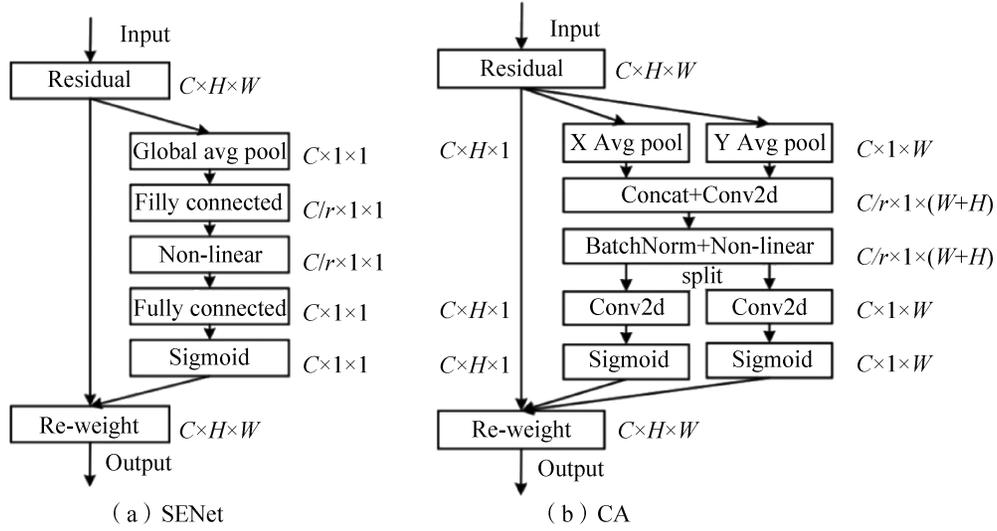


图6 注意力机制原理图比较

Fig.6 Schematic comparison of attention mechanisms

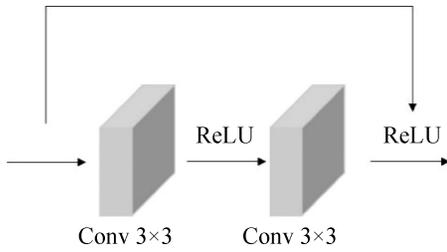


图7 残差解码

Fig.7 Residual decoding

### 3 实验及结果分析

#### 3.1 评价指标

本文选择像素准确率  $PA$  (Pixel Accuracy)、平均像素准确率  $mPA$  (Mean Pixel Accuracy) 及平均交并比  $mIoU$  (Mean Intersection over Union) 作为评价指标<sup>[17]</sup>。  $PA$  是正确分类的像素与所有像素的比率。  $mPA$  是所有类别的  $PA$  的平均值。  $mIoU$  是平均交并比，即所有类别的预测值和真值的交集和并集的比率。这些指标的值越高，说明模型正确分类个数越多，分类能力越强。这些指标可以通过表2中所示的混淆矩阵来解决，其中  $TP$  (True Positive)、  $FP$  (False Positive)、  $FN$  (False Negative) 和  $TN$  (True Negative) 代表真正例、假正例、假反例和真反例。

评价指标的计算公式如下：

$$PA = \frac{TP + TN}{TP + FN + FP + TN} \quad (7)$$

$$mPA = \frac{1}{2} \left( \frac{TP}{TP + FN} + \frac{TN}{FP + TN} \right) \quad (8)$$

表2 混淆矩阵

Table 2 Confusion matrix

真实情况	预测结果	
	云	非云
云	$TP$	$FN$
非云	$FP$	$TN$

$$mIoU = \frac{1}{2} \left( \frac{TP}{TP + FN + FP} + \frac{TN}{FP + FN + TN} \right) \quad (9)$$

#### 3.2 模型参数设置

本文网络训练采用 Adam 进行梯度下降法，momentum=0.9，weight\_decay=0，初始学习率  $Lr$  设置为  $10^{-4}$ ，学习率按“cos”方式进行衰减，设置 batchsize=8。由于图像分割的与训练网络模型不适用于遥感多光谱图像，因此本文实验在第一部分未使用预训练模型参数进行训练，训练时 epoch=100。第二部分使用本文数据集进行迁移学习时，使用第一部分训练的结果作为预训练模型参数进行模型微调，训练时 epoch=24，初始学习率降低为  $10^{-6}$ 。整体数据集划分见表3。

#### 3.3 实验结果分析

本文首先在 38-Cloud 遥感云数据集上进行了

表3 数据集划分

Table 3 Dataset division

数据集	训练集(张)	测试集(张)
Landsat-8	8 124	903
本文数据集	2 381	1 021

实验, 图 8 所示为其改进前和改进后的验证集损失下降图。可以看出原始的 U-Net 网络存在梯度爆炸(或消失)的情况, 使得模型损失在下降到一定程度后开始反弹。而本文改进的 U-Net 可以有效地解决该问题, 损失稳定下降。

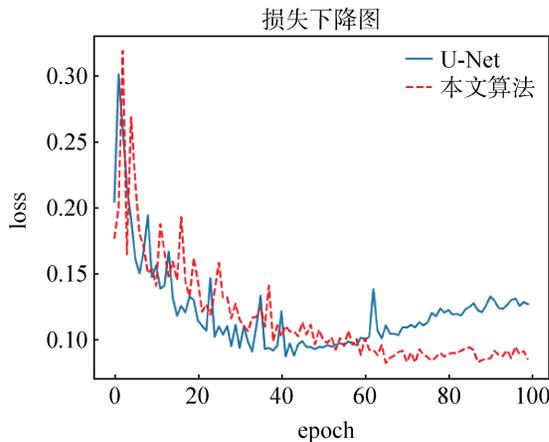


图 8 损失下降图

Fig.8 Loss descent diagram

为验证本文设计的优化模块的有效性, 在 Cloud-38 数据集上进行了消融实验, 对比结果如表 4 所示。可以看出所改进的每个模块的引入都对云检测精度有正面的影响, 其中 CA 模块比其他模块精度提升更高, 在 *mIoU* 指标上提升了近 9%。消融实验验证了本文改进的模块可以使得算法的检测效果更好。

表 4 消融实验

Table 4 Ablation experiment

残差网络模块	多尺度融合	CA	残差解码	<i>PA</i>	<i>mPA</i>	<i>mIoU</i>
√	√	×	×	74.25	66.33	52.75
√	√	√	×	81.74	71.41	60.83
√	√	√	√	82.04	73.19	61.64

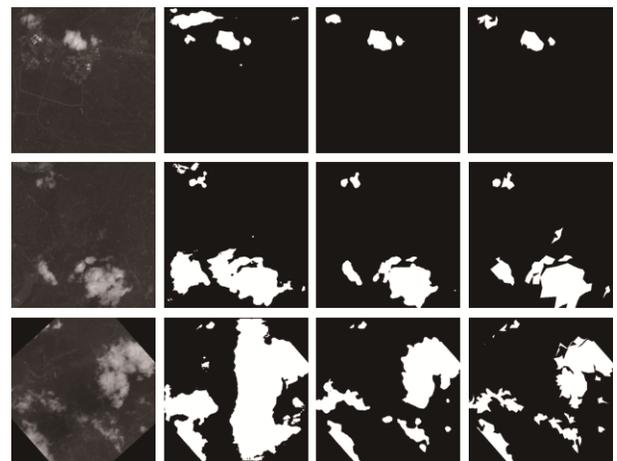
在第二部分实验时, 将 Cloud-38 训练好的参数作为预训练参数在构建的数据集上进行迁移学习。将本文模型与 U-Net 云分割网络进行比较, 实验结果如表 5 所示。本文算法与 U-Net 算法参数量相近, 但 GFLOPS 却远低于 U-Net, 使用训练本模型所花时间更少。同时其分割能力显著提高, 在各指标均有提升, 其中在 *mIoU* 指标上提升了 5.99%。图 9 所示为可视化对比图, 从图中可以看出 U-Net 网络将非云部分识别为了云, 而本文的算

法与标注结果更接近, 验证了该算法可用于珠海一号高光谱图像云检测。

表 5 算法性能对比

Table 5 Comparison of algorithm performance

模型	GFLOPS(G)	Params(M)	<i>PA</i>	<i>mPA</i>	<i>mIoU</i>
U-Net	168.394	35.491	84.59	83.93	72.67
本文算法	119.007	33.343	92.28	89.64	78.66



(a) 原图 (b) U-Net (c) 本文算法 (d) Label  
(a) Original (b) U-Net (c) This article's algorithm (d) Label

图 9 云分割可视化对比

Fig.9 Visual comparison of cloud segmentation

### 4 结束语

珠海一号高光谱卫星通过 8 星组网, 为遥感应用提供了丰富的地表探测信息, 但是由于云的存在, 限制了影像的利用率。本文提出了一种多尺度特征融合的 U-Net 云检测法。基于场景迁移的学习思路, 本研究通过对丰富的 Landsat8 云数据训练初始网络参数, 随后利用构建的 OHS 数据集进行迁移学习, 实现云检测目的。本文方法在 OHS 影像的云检测中像素准确率达到 92.28%, 平均像素准确率达到 89.64%, 平均交并比提升至 78.66%, 对比 U-Net 有较大提升。实验表明, 在面向不同的高光谱数据时可采用本文方法在处理少量数据的情况下实现云检测。然而, 本文方法采用了 38-cloud 数据集进行了预训练, 当数据样本与预训练样本存在较大差异时将出现检测准确率下降的情况。此外, 本文方法也依赖于数据样本的标注量, 标注数量过少、样本不均衡、手工标注的误差等都会使得网络模型性能下降。

## 参考文献

- [1] 李先怡, 范海生, 潘申林, 等. 珠海一号高光谱卫星数据及应用概况[J]. 卫星应用, 2019(8): 12-18.
- [2] ZHANG Y, ROSSOW W B, LACIS A A, et al. Calculation of radiative fluxes from the surface to top of atmosphere based on ISCCP and other global data sets: Refinements of the radiative transfer model and the input data [J]. Journal of Geophysical Research: Atmospheres, 2004, 109(D19).
- [3] IRISH R R, BARKER J L, GOWARD S N, et al. Characterization of the Landsat-7 ETM+ automated cloud-cover assessment (ACCA) algorithm[J]. Photogrammetric engineering & remote sensing, 2006, 72(10): 1179-1188.
- [4] ZHU Z, WOODCOCK C E. Object-based cloud and cloud shadow detection in Landsat imagery[J]. Remote sensing of environment, 2012, 118: 83-94.
- [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] ZHU Z, WANG S, 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.
- [7] LI Z, SHEN H, LI H, et al. Multi-feature combined cloud and cloud shadow detection in GaoFen-1 wide field of view imagery[J]. Remote Sensing of Environment, 2017, 191: 342-358.
- [8] QIU S, ZHU Z, HE B. Fmask 4.0: Improved cloud and cloud shadow detection in Landsats 4-8 and Sentinel-2 imagery[J]. Remote Sensing of Environment, 2019, 231: 111205.
- [9] 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.
- [10] AN Z, SHI Z. Scene learning for cloud detection on remote-sensing images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(8): 4206-4222.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-assisted intervention, Springer, Cham, 2015: 234-241.
- [12] 张家强, 李潇雁, 李丽圆, 等. 基于深度残差全卷积网络的 Landsat 8 遥感影像云检测方法[J]. 激光与光电子学进展, 2020, 57(10): 102801.
- ZHANG Jiaqiang, LI Xiaoyan, LI Liyuan, et al. Landsat 8 remote sensing image based on deep residual fully convolutional network[J]. Laser & Optoelectronics Progress, 2020, 57(10): 102801
- [13] 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.
- [14] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016: 770-778.
- [16] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [17] ZHANG J, LI X, LI L, et al. Lightweight U-Net for cloud detection of visible and thermal infrared remote sensing images[J]. Optical and Quantum Electronics, 2020, 52(9): 1-14.

## [作者简介]

陈丽 1995年生, 博士研究生, 主要研究方向为遥感船舶目标检测。

贾源源 1995年生, 博士研究生, 主要研究方向为高光谱遥感影像大气校正。

(本文编辑: 杨秀丽)