

DOI: 10.3969/j.issn.1673-6141.2023.04.009

基于多模态融合的GF-5号遥感图像云检测

张苏贵^{1,2}, 张晶晶^{1,2*}, 寻丽娜^{1,2}, 孙晓兵³, 熊伟³,
阎庆^{1,2}, 李穗⁴

(1 安徽大学计算智能与信号处理教育部重点实验室, 安徽 合肥 230601;

2 安徽大学电气工程与自动化学院, 安徽 合肥 230601;

3 中国科学院通用光学定标与表征技术重点实验室, 安徽 合肥 230031;

4 安徽文达信息工程学院, 安徽 合肥 231201)

摘要: 云检测对于遥感图像的应用具有重要意义。目前已有的云检测方法关于遥感图像的偏振信息研究较少, 性能和泛化能力有限。为有效利用遥感图像偏振信息, 提出了一种基于深度学习的多模态融合遥感图像云检测方法并进行了初步实验评价。该网络是一种三参数输入流架构, 具有编码器-解码器结构, 利用通道空间注意模块对遥感图像中的反射率特征和偏振特征进行多模态融合。在解码器上采样阶段, 利用迭代注意特征融合方法融合高、低级特征映射。评价实验数据集来源于多角度偏振成像仪 (DPC) 云产品和云掩码产品。评价实验结果表明, 所提出的网络模型实现了良好的云检测性能, 识别准确率达到93.91%。

关键词: 云检测; 偏振信息; 多模态融合; 通道空间注意; 迭代注意特征融合

中图分类号: P407

文献标识码: A

文章编号: 1673-6141(2023)04-371-012

Cloud detection of GF-5 remote sensing image based on multimodal fusion

ZHANG Sugui^{1,2}, ZHANG Jingjing^{1,2*}, XUN Lina^{1,2}, SUN Xiaobing³,
XIONG Wei³, YAN Qing^{1,2}, LI Sui⁴

(1 Key Laboratory of Intelligent Computing and Signal Processing of Ministry of Education,
Anhui University, Hefei 230601, China;

2 School of Electrical Engineering and Automation, Anhui University, Hefei 230601, China;

3 Key Laboratory of Optical Calibration and Characterization, Chinese Academy of Sciences, Hefei 230031, China;

4 Anhui Wenda University of Information Engineering, Hefei 231201, China)

Abstract: Cloud detection is of great significance for the application of remote sensing images. However, as for the existing cloud detection methods, there is limited research on the polarization information of remote sensing images, and their performance and generalization ability are also limited. To effectively

基金项目: 中国科学院通用光学定标与表征技术重点实验室开放研究基金

作者简介: 张苏贵 (1997-), 女, 江苏宿迁人, 硕士研究生, 主要从事遥感图像云检测方面的研究。E-mail: zsg5802085@163.com

导师简介: 张晶晶 (1974-), 女, 安徽合肥人, 博士, 副教授, 硕士生导师, 主要从事数字图像处理、遥感信息处理和模式识别方面的研究。

E-mail: 874878644@qq.com

收稿日期: 2022-10-31; 修改日期: 2023-01-19

*通信作者。

utilize the polarization information of remote sensing images, a multimodal fusion remote sensing image cloud detection method based on depth learning is proposed and its preliminary experimental evaluation is conducted. In the method, the network is a three-parameter input stream architecture with an encoder-decoder structure, and the channel-spatial attention module is used to perform multimodal fusion of reflectance and polarization features in remote sensing images. In the upsampling stage of the decoder, the iterative attention feature fusion method is used to fuse the high- and low-level feature maps. The evaluation experimental data set comes from Directional Polarization Camera (DPC) cloud products and cloud mask products. The evaluation results show that the proposed network model achieves good cloud detection performance, with a recognition accuracy of 93.91%.

Key words: cloud detection; polarization information; multimodal fusion; channel-spatial attention; iterative attention feature fusion

0 引言

地球表面约50%~70%的区域被云层覆盖,这对自然界的水文平衡和气候变化有显著影响^[1]。同时,云层的遮挡对遥感图像的地物信息造成不同程度的损失,降低遥感图像质量^[2],不利于遥感图像的后续分析和使用。因此,云检测成为遥感图像应用领域基本的预处理任务^[3]。

目前,遥感影像技术日趋成熟,能够获取的信息越来越多,如空间信息、光谱信息以及偏振信息。2018年5月,中国国家航天局发射了载有多角度偏振成像仪(DPC)的高分五号(GF-5)卫星^[4]。该卫星能够获取8个不同波段通道的数据,每个波段具有9个观测角度的结果^[5]。

针对遥感图像云检测,国内外学者提出了大量的方法,传统的遥感图像云检测方法主要包括基于规则的云检测方法和基于机器学习的云检测方法。基于规则的云检测方法中应用最广泛的是光谱阈值法。Zhu和Woodcock^[6]、Kriebel等^[7]利用云与地物在可见光及红外通道上具有不同的反射率和亮温等特性设置阈值进行云与非云像素的区分,由于雪具有与云相似的反射特性,该方法无法正确检测云雪共存区域。此外,该方法对遥感图像中的所有像素应用相同的阈值,对传感器依赖性强,泛化能力弱。机器学习方法利用图像纹理特征、亮度特征以及局部统计特征建立模型^[8]。Rossi等^[9]利用奇异值分解提取云的特征,并通过支持向量机(SVM)在Quickbird图像中进行云检测。Li等^[10]利用亮度和纹理特征训练SVM分类器来检测云。Chen和Dong^[11]基于灰度共生矩阵统计方法获取遥感图像的纹理信息,利用非线性支持向量机算法进行了云检测。一般来说,机器学习方法比阈值方法能产生更准确的云检测结果。然而,大多数基于机器学习的方法将输入视为单个像素,不考虑不同波段维数和观测角度维数所反映的信息,忽略了遥感图像空间相关性的关键特征。

随着卷积神经网络(CNN)在图像分类中表现出良好的性能,对该算法的研究越来越多地应用在云检测领域。Zhan等^[12]提出利用全卷积神经网络在像素级上从遥感卫星图像中区分云与雪,但是该网络在解码过程中丢失位置信息,导致预测结果存在误差。李佳欣等^[13]利用训练好的SegNet网络,把POLDER卫星遥感影像多角度信息输入到网络当中,证明遥感图像多角度特征的使用有利于云检测精度的提升。Yang等^[14]提出基于CNN的遥感图像云检测方法,该方法利用特征金字塔模块提取多尺度和全局上下文信息,同时利用

边界细化模块获取详细的目标边界,在ZY-3卫星缩略图上取得良好的性能,但是该方法忽视了对薄云区域的检测。

已有研究表明,偏振图像作为不同于多光谱图像的另一种形态,可以为云检测提供额外的信息^[15]。王佳佳等^[6]利用偏振信息设立阈值有效地检测出海洋上空耀光区域的云。但是阈值算法在性能和泛化能力上一般有所限制。目前,综合利用遥感影像反射率信息和偏振信息的云检测算法较少,且偏振信息大多应用在传统云检测方法中。针对以上问题,本文提出一种基于3DU-Net的多模态融合网络,将GF-5 DPC遥感数据中的反射率信息和偏振信息作为网络的输入,利用通道空间注意模块(CSAM)进行多模态融合,增强不同模态融合方式的表达,在上采样特征融合阶段采用迭代注意特征融合(iAFF)模块^[17],充分利用特征图的语义信息进行特征恢复,从而提高网络生成掩码的精度。

1 原理与方法

1.1 DPC数据特点

DPC是GF-5卫星的重要载荷,GF-5卫星在运行过程中,通过DPC可以从不同波段和观测角度观测某一点,从而获取多波段、多角度的偏振信息和辐射信息。DPC数据由8个波段组成,分别为443、490、565、670、763、765、865、910 nm,其中490、670、865 nm三个波段为偏振波段,在每个观测点上可以捕获9个不同角度的多光谱偏振信息。表1列出了每个波段的具体细节。

表1 DPC数据波段特征

Table 1 Characteristics of DPC data bands

波段/nm	波段宽度/nm	偏振与否
443	443~453	否
490	480~500	是
565	555~575	否
670	660~680	是
763	758~768	否
765	745~785	否
865	845~885	是
910	900~920	否

1.2 DPC数据处理

由于目前还没有DPC云检测数据集,为了评估提出的方法,使用的数据集来源于中国科学院合肥物质科学研究院的DPC Level-1云产品和对应的Level-2云掩码产品。王佳佳^[18]的研究已证实DPC对应的Level-2云掩码产品精度较高,可以为业务化产品提供支撑,本研究将其作为实验数据集的标签。云比晴空具有更高的反射率,为了加深云和非云像素的区别,使用DPC反射率数据作为数据集的一部分。实验中使用的反射率数据是每个像素在特定观测角度、特定波段的大气顶部反射率^[19],根据DPC Level-1云产品的归一化辐射亮度 I 和太阳天顶角 β 可计算出反射率 R_c ^[20],计算公式为

$$R_c = \frac{I}{F_0 \cos \beta}, \quad (1)$$

式中 F_0 为太阳入射辐照度。

由于薄云的反射率与地表反射率差异较小, 仅利用反射率数据进行云检测会导致薄云区域误分类。而越来越多的研究表明偏振信息有助于提高薄云的识别能力, 因此本研究中的数据集还包括偏振辐射数据。一般利用斯托克斯参量 I 、 Q 、 U 计算偏振波段的偏振反射率 R_p , 计算公式为

$$R_p = \frac{\sqrt{Q^2 + U^2}}{F_0 \cos \beta}. \quad (2)$$

但是由于反射率数据中已经包含了太阳天顶角信息 β 和太阳辐射辐照度 F_0 , 此时不需要利用公式计算偏振反射率, 而是直接用 Q 、 U 表示偏振信息。 Q 、 U 和 R_c 已经包含了实验所需要的全部信息。

实验中只有 14 个标记数据的轨道, 对应的标签大小为 12168×6084 。将其中 12 个轨道数据作为训练数据集, 另外两个轨道数据作为验证数据集。实验中使用水平翻转、垂直翻转和对角镜像将原始数据数量增加三倍, 一定程度上缓解了过拟合现象。由于硬件设备性能的限制, 将输入图像裁剪为 32×32 大小的像素块。同时, 为了对实验进行定性分析, 选取了 5 张尺寸为 160×160 的代表性样本作为测试图。

1.3 网络框架

DPC 数据是三维数据, 包括空间、角度以及光谱维度信息。若使用二维卷积网络, 则需要将角度维度和光谱维度整合到一个通道, 这会造成信息丢失。针对这一问题, 选取 3DU-Net 作为骨干网络, 利用连续的三维卷积操作和最大池化操作提取多尺度的偏振特征和空间光谱角度特征。为了融合 DPC 数据偏振特征和空间光谱角度特征, 在 3DU-Net 网络基础上加以改进, 利用 CSAM 将偏振特征与空间光谱角度特征进行融合。由于传统的 3DU-Net 网络在解码器上采样阶段往往采用简单的拼接或相加操作将高级语义特征与浅层特征进行融合, 容易产生信息冗余, 导致卷积核无法接收到有效的特征信息。针对这个问题, 本研究对解码器上采样特征融合部分加以改进, 引用 iAFF 模块将浅层网络生成的低级高分辨率特征映射与经过卷积池化操作后获得的高级语义特征映射进行融合。

对 3DU-Net 加以改进的网络整体框架如图 1 所示。该网络框架由编码器、多模态融合、解码器和检测四部分组成。网络采用三输入模式, 将反射率图像 $F_r(32 \times 32 \times 9 \times 8)$ 、偏振图像 $F_Q(32 \times 32 \times 9 \times 3)$ 、偏振图像 $F_U(32 \times 32 \times 9 \times 3)$ 作为网络输入, 角度维度放在输入数据形式的第三维, 将光谱维度放在通道维, 在编码器部分利用连续三维卷积操作提取偏振特征和反射率图像的空间角度光谱特征, 卷积核大小为 $3 \times 3 \times 3$, 利用最大池化操作进行下采样, 从而得到不同尺度的特征图。

1.3.1 通道空间注意模块

深度学习中利用注意力机制能够有效地捕获重要信息。受此启发, 利用 CSAM 将解码器生成的偏振特征和角度光谱特征进行融合, 达到突出两种模态的共同信息、减少无效冗余信息的目的。CSAM 由通道注意模块和空间注意模块组合而成, 其结构如图 2 所示。编码器生成的角度光谱特征 X 和偏振特征 Y 在通道维进行拼接, 得到的特征图 M 作为通道注意模块的输入。通道注意模块分别利用全局平均池化和全局最大池化操作压缩空间维度, 保持通道维度不变, 对得到的特征图进行两次全连接操作, 将得到的两个特征图进行元素相加, 利用 Sigmoid 函数得到的注意力权重作用于特征图 M , 得到加权特征图 N 。通道注意模块可

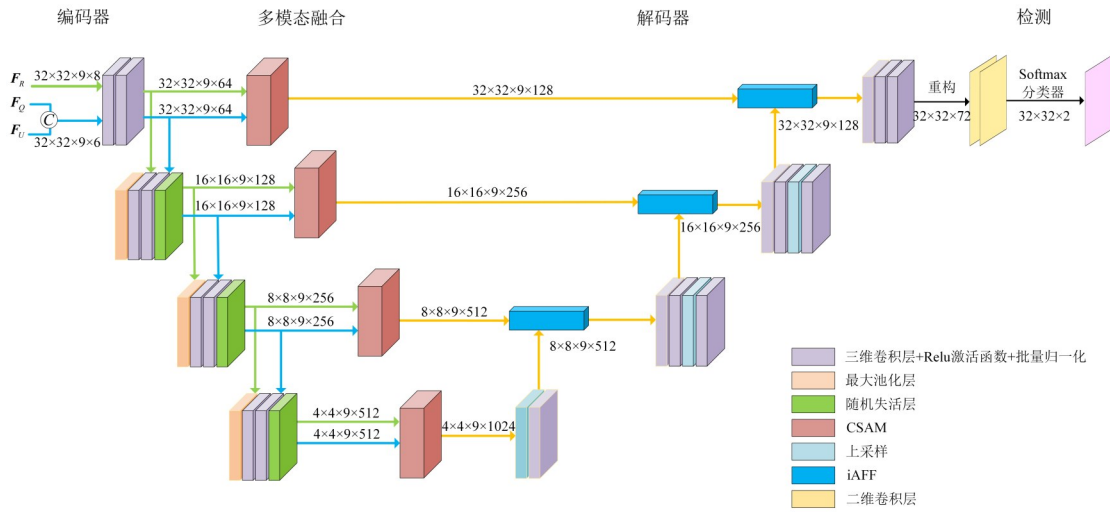


图 1 整体网络模型架构

Fig. 1 The overall network model architecture

以增强有效通道信息的表达, 抑制无效信息。因此, 在将波段信息作为输入数据的通道维度后, 可以有效突出重要波段的光谱信息和偏振信息。空间注意模块保持空间维度不变, 沿着通道轴对加权特征图 N 分别进行全局平均池化和全局最大池化操作, 将得到的特征图进行拼接, 经过卷积和 Sigmoid 函数得到空间注意力权重, 与加权特征图 N 相乘, 突出重要的空间角度信息。将由空间注意模块产生的结果与特征图 M 对应元素相加得到最终的结果, 既突出重要波段与空间角度信息, 又减少处理过程中细节信息的丢失。图 2 中, f_{gmp} 表示全局最大池化操作, f_{gap} 表示全局平均池化操作, f_{c1} 、 f_{c2} 表示全卷积操作, f_{smp} 表示沿通道维最大池化操作, f_{sap} 表示沿通道维的平均池化操作, \oplus 表示拼接, \otimes 表示 Sigmoid 激活函数, \oplus 表示元素级求和, \otimes 表示元素级相乘。




图 2 通道空间注意模块

Fig. 2 Channel-spatial attention module

1.3.2 迭代注意特征融合模块

为了解决上采样特征融合信息冗余的问题, 引入 iAFF 模块以更好地融合语义和尺度不一致的特征, 其结构如图 3 所示, 其中 H 、 W 、 D 、 C 分别代表特征图的高、宽、深度、通道数, iAFF 模块的输入 X 代表浅层网络生成的低级高分辨率特征映射, Y 代表经过卷积池化操作后获得的高级语义特征映射, 基于多尺度通道注意模块 (MS-CAM) 对不同尺度的两个分支提取通道注意力, 达到充分提取上下文信息的效果。iAFF 可表示为

$$Z = M(X^1 \oplus Y^1) \otimes X + [1 - M(X^1 \oplus Y^1)] \otimes Y, \quad (3)$$

$$\mathbf{X}^1 = \mathbf{M}(\mathbf{X} \oplus \mathbf{Y}) \otimes \mathbf{X}, \quad (4)$$

$$\mathbf{Y}^1 = [1 - \mathbf{M}(\mathbf{X} \oplus \mathbf{Y})] \otimes \mathbf{Y}, \quad (5)$$

式中 $\mathbf{Z} \in \mathbf{R}^{H \times W \times D \times C}$ 代表融合后特征图, \mathbf{M} 表示由 MS-CAM 模块生成注意力权重操作, \mathbf{X}^1 表示特征 \mathbf{X} 经注意力加权后的特征, \mathbf{Y}^1 表示特征 \mathbf{Y} 经注意力加权后的特征, \oplus 表示元素级求和, \otimes 表示元素级相乘。

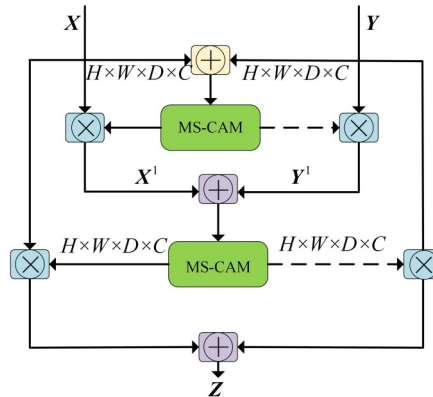


图3 iAFF模块

Fig. 3 The module of iAFF

图4为MS-CAM利用具有不同尺度的两个分支提取通道注意力,其中一个分支用全局平均池化提取全局特征的注意力,另一个分支使用逐点卷积提取局部特征的通道注意力。选择逐点卷积作为通道上下文聚合器,它只利用每个空间位置的像素点通道交互,从而能够在保持网络轻量级的基础上实现多尺度通道注意。MS-CAM对输入特征 $\mathbf{X} \in \mathbf{R}^{H \times W \times D \times C}$ 分别进行全局上下文聚合和局部上下文聚合,其中局部特征通道注意力 \mathbf{L} 、全局特征通道注意力 \mathbf{G} 、特征 \mathbf{X} 经 MS-CAM 生成的注意力权重 \mathbf{Y} 的计算公式分别为

$$\mathbf{L} = \mathbf{B}\{\text{PConv2}\{\mathbf{R}\{\mathbf{B}\{\text{PConv1}(\mathbf{X})\}\}\}\}, \quad (6)$$

$$\mathbf{G} = \mathbf{B}\{\text{PConv2}\{\mathbf{R}\{\mathbf{B}\{\text{PConv1}[\text{Gap}(\mathbf{X})]\}\}\}\}, \quad (7)$$

$$\mathbf{Y} = \mathbf{M}(\mathbf{X}) = \sigma(\mathbf{L} \oplus \mathbf{G}), \quad (8)$$

式中 \mathbf{B} 表示批量归一化, PConv2 代表通道数恢复成原通道数的逐点卷积操作, \mathbf{R} 代表 Relu 激活函数, PConv1 代表将输入 \mathbf{X} 的通道数设置为原来通道数的 $1/r$ 倍的逐点卷积, Gap 代表全局平均池化操作, σ 表示 Sigmoid 激活函数。

2 实验与讨论

2.1 实验设置

所有的网络在 Keras 框架下进行训练,选择自适应动量 (Adam) 优化算法进行优化,学习速率从 10^{-4} 开始,使用自适应调整学习率对学习率进行动态调整。本次实验对数据集共训练 80 轮,当连续训练 10 轮的验证损失不减少时,结束训练。实验中使用的损失函数是交叉熵损失函数。为定量和定性评价提出的网络,设置了以下两组实验:

- 1) 为了验证所提网络的先进性和有效性,与其他经典语义分割网络进行对比实验。

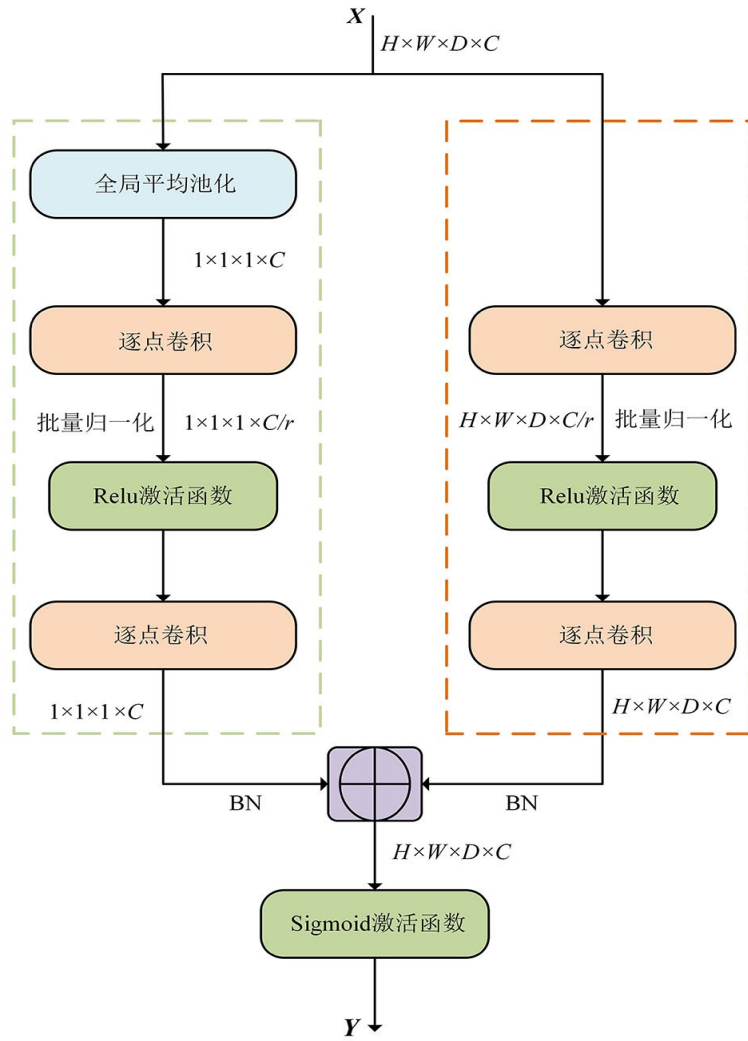


图 4 多尺度通道注意模块

Fig. 4 MS-CAM

2) 为验证在高分辨率遥感影像中多模态融合和注意特征融合对云检测性能的影响, 进行了消融实验。

2.2 实验评价指标

通过像素准确率 P_A 、类别像素精度 P_{CA} 、召回率 R_{call} 和平均交并比 M_{IoU} 4 个指标对模型进行评价, 具体计算公式分别为

$$P_A = \frac{T_p + T_n}{T_p + T_n + F_p + F_n}, \tag{9}$$

$$P_{CA} = \frac{T_p}{T_p + F_p}, \tag{10}$$

$$R_{call} = \frac{T_p}{T_p + F_n}, \tag{11}$$

$$M_{IoU} = \frac{1}{2} \left(\frac{T_p}{T_p + F_p + F_n} + \frac{T_n}{T_n + F_n + F_p} \right), \tag{12}$$

式中 T_p 表示已识别的正样本像素数, T_n 表示将正样本识别为负样本的像素数, F_p 表示从负样本中识别为正样本的像素数, F_n 表示已识别的负样本像素数。

2.3 结果与分析


2.3.1 与传统方法的对比

为了验证模型的性能和检测效果,将提出的模型和其他经典深度学习模型进行对比实验,实验结果如表2所示。为了让实验效果更加直观,选取5张代表性样本作为测试图,其可视化结果如图5所示,其中非云像素点标记为黑色,正确分类的云像素点标记为灰色,分类错误的像素点标记为红色。从图5可以看出,与其他实验方法相比,本研究方法的结果与影像真实地表标签 (Ground truth) 最接近,在云边界以及薄云区域误检漏检情况更少,在视觉上优于其他方法。从表2评价指标看,本研究方法的 P_A 比 U-Net 模型提升了 1.78%, P_{CA} 提升了 1.44%, R_{cal} 提升了 1.32%, M_{IoU} 提升了 3.31%。结果表明,本工作所提出的模型在云检测方面具有较好的性能,云检测精度有所提高,对云区域和非云区域都有很好的预测能力。

表2 不同方法云检测准确率

Table 2 Cloud detection accuracy of different methods

实验方法	$P_A/\%$	$P_{CA}/\%$	$R_{cal}/\%$	$M_{IoU}/\%$
FCN	88.64	84.53	88.51	79.16
SegNet	86.23	80.58	90.91	75.74
DeepLab v1	91.89	88.70	91.78	84.62
U-Net	92.13	94.10	93.67	84.31
DANet	90.12	86.22	90.10	81.58
BiSeNet	91.29	88.04	90.93	83.55
This work	93.91	95.54	94.99	87.62



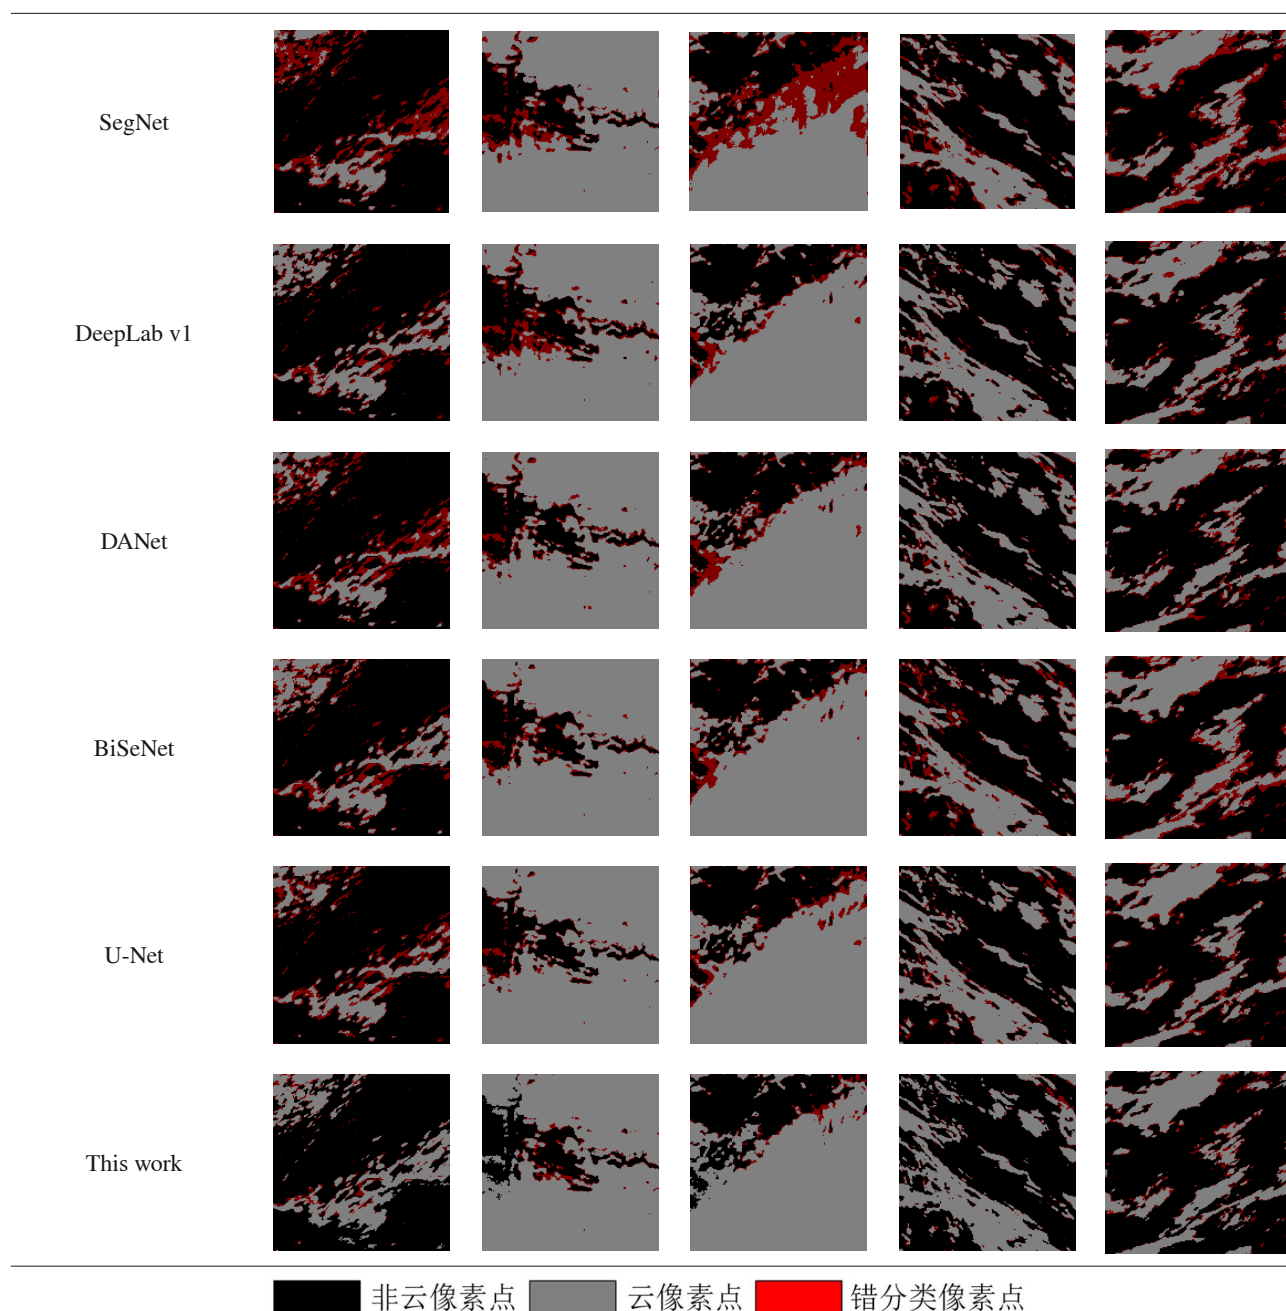


图 5 不同方法的可视化实验结果比较

Fig. 5 Comparison of visualization experimental results of different methods

2.3.2 消融实验结果与分析

为了验证多模态融合和迭代注意特征融合对云检测的影响, 在 DPC 数据集上对 CSAM 和 iAFF 模块在消融实验中的检测精度进行了测试。为了验证偏振信息对实验的影响, 也对仅输入反射率数据和同时输入反射率数据和偏振数据进行了实验。实验对比结果如表 3 所示。

为验证所提网络的性能, 共做了 6 组实验。从表 3 实验 (a) 组和 (b) 组、(c) 组和 (d) 组、(e) 组和 (f) 组对照结果来看, 和仅输入反射率数据相比, 同时输入反射率数据和偏振数据对于云检测准确率有所提升, 表

表3 消融实验的云检测结果

Table 3 Cloud detection results of ablation experiments

实验组别	实验方法	$P_A/\%$	$P_{CA}/\%$	$R_{cal}/\%$	$M_{IoU}/\%$
(a)	3DU-Net + R	90.84	90.61	94.89	82.26
(b)	3DU-Net + R+ P	92.13	94.10	93.67	84.31
(c)	3DU-Net + CSAM + R	92.56	91.57	91.70	86.01
(d)	3DU-Net + CSAM + R + P	93.09	92.05	92.03	86.33
(e)	3DU-Net + CSAM + iAFF + R	93.33	92.52	92.48	87.36
(f)	3DU-Net + CSAM + iAFF + R + P	93.91	95.54	94.99	87.62

明偏振信息对反射率信息起到补充作用,因此同时利用反射率信息和偏振信息有利于云检测精度的提升。从实验 (b)、(d) 组结果可以看出,在 3DU-Net 基础上加入 CSAM 模块,识别准确率 P_A 从 92.13% 提升至 93.09%,表明利用 CSAM 融合偏振和反射率信息实现了模态信息互补,拓宽了输入数据信息的范围,从而提升检测效果。利用 iAFF 代替原 3DU-Net 中的连接操作进行上采样融合,使模型快速捕获有效信息,有效集成多尺度特征图, P_A 从 93.09% [实验 (d)] 进一步提升至 93.91% [实验 (f)]。图 6 为分别选取薄云区域遥感影像、只利用反射率作为输入、同时利用反射率数据和偏振数据作为输入的云检测结果可视化对比图。从图中可以看出,同时利用偏振信息和反射率信息在薄云区域和碎云区域误分类更少,能够有效识别薄云和碎云。

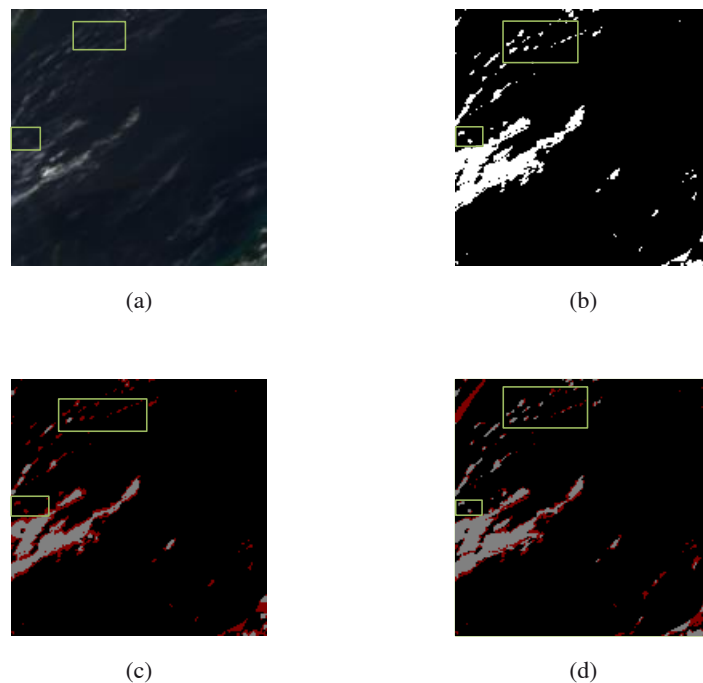


图 6 云检测结果可视化。(a) 薄云区域遥感影像; (b) 影像真实地表标签; (c) 利用反射率信息做为输入的可视化结果图; (d) 利用反射率和偏振信息的可视化结果图

Fig. 6 Visualization of cloud detection results. (a) Remote sensing imagery of thin cloud areas; (b) ground truth; (c) the results using reflectance information as input; (d) the results using reflectance and polarization information

3 结 论

现有研究表明,利用遥感图像的空间光谱角度信息能够实现较好的云检测效果,但是对于薄云、碎云区域漏检情况严重,针对此问题,提出了在3DU-Net的基础上引入CSAM和iAFF的深度学习云检测方法。该方法考虑到GF-5 DPC数据结构的特点,充分利用了遥感图像的偏振信息和空间光谱角度信息。在编码器部分利用卷积池化操作提取遥感图像多尺度的偏振信息和空间光谱角度信息。通过CSAM将偏振信息与空间光谱角度信息进行融合,使得偏振信息对空间光谱角度信息加以补充,减少了只使用光谱信息时在薄云区域造成的信息丢失。iAFF模块利用尺度不同的两个分支来提取通道注意力权重,聚合多尺度上下文信息,在强调全局信息的同时突出局部细节信息,从而能够有效保持云边界信息,提高模型最终预测精度。实验证明,相对于只使用光谱信息进行云分类,利用偏振信息能够减少薄云、碎云区域误分类的情况。本研究方法在DPC数据集上的云检测像素准确率达到93.91%,类别像素准确率达到95.54%,与另外6种传统的深度学习云检测方法相比,云检测精度有所提升,证明了该方法的有效性。

由于目前数据集数量有限,在今后的工作中,将会研究无监督学习或者半监督学习解决数据量小、人工标注数据复杂的问题。此外,该方法在引入CSAM和iAFF提高云检测精度的同时会大大增加网络参数量、计算量,后续可以考虑将网络编码器部分卷积操作加以改进,做进一步的轻量化处理,以减小计算开销。

参考文献:

- [1] Guo Q, Zhao Y H, Li A. Cloud detection for DSCOVER EPIC data [C]. *Proceedings of the 2018 2nd International Conference on Video and Image Processing*. December 29-31, 2018, Hong Kong. New York: ACM, 2018: 55-59.
- [2] Dubovik O, Li Z Q, Mishchenko M I, et al. Polarimetric remote sensing of atmospheric aerosols: Instruments, methodologies, results, and perspectives [J]. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 2019, 224: 474-511.
- [3] Shao M, Zou Y. Multi-spectral cloud detection based on a multi-dimensional and multi-grained dense cascade forest [J]. *Journal of Applied Remote Sensing*, 2021, 15(2): 028507.
- [4] Sun Y Z, Jiang G W, Li Y D, et al. GF-5 satellite: Overview and application prospects [J]. *Spacecraft Recovery & Remote Sensing*, 2018, 39(3): 1-13.
孙允珠, 蒋光伟, 李云端, 等. “高分五号”卫星概况及应用前景展望 [J]. *航天返回与遥感*, 2018, 39(3): 1-13.
- [5] Yan Q, Liu H, Zhang J J, et al. Cloud detection of remote sensing image based on multi-scale data and dual-channel attention mechanism [J]. *Remote Sensing*, 2022, 14(15): 3710.
- [6] Zhu Z, Woodcock C E. Object-based cloud and cloud shadow detection in Landsat imagery [J]. *Remote Sensing of Environment*, 2012, 118: 83-94.
- [7] Kriebel K T, Gesell G, Kästner M, et al. The cloud analysis tool APOLLO: Improvements and validations [J]. *International Journal of Remote Sensing*, 2003, 24(12): 2389-2408.
- [8] Liu Z L, Yang J J, Wang W J, et al. Cloud detection methods for remote sensing images: A survey [J]. *Chinese Space Science and Technology*, 2023, 43(1): 1-17.

- 刘子力, 杨家俊, 王文静, 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.
- [9] Rossi R, Basili R, Frate F D, *et al.* Techniques based on Support Vector Machines for cloud detection on QuickBird satellite imagery [C]. *2011 IEEE International Geoscience and Remote Sensing Symposium*. July 24-29, 2011, Vancouver, BC, Canada. *IEEE*, 2011: 515-518.
- [10] Li P F, Dong L M, Xiao H C, *et al.* A cloud image detection method based on SVM vector machine [J]. *Neurocomputing*, 2015, 169: 34-42.
- [11] Chen G, Dong C E. Support vector machines for cloud detection over ice-snow areas [J]. *Geo-spatial Information Science*, 2007, 10(2): 117-120.
- [12] Zhan Y J, Wang J, Shi J P, *et al.* Distinguishing cloud and snow in satellite images via deep convolutional network [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(10): 1785-1789.
- [13] Li J X, Zhao P, Fang W, *et al.* Cloud detection of multi-angle remote sensing image based on deep learning [J]. *Journal of Atmospheric and Environmental Optics*, 2020, 15(5): 380-392.
李佳欣, 赵鹏, 方薇, 等. 基于深度学习的多角度遥感影像云检测方法 [J]. 大气与环境光学学报, 2020, 15(5): 380-392.
- [14] Yang J Y, Guo J H, Yue H J, *et al.* CDnet: CNN-Based cloud detection for remote sensing imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(8): 6195-6211.
- [15] Zhang J J, Ge K, Xun L N, *et al.* MFCD-net: Cross attention based multimodal fusion network for DPC imagery cloud detection [J]. *Remote Sensing*, 2022, 14(16): 3905.
- [16] Wang J J, Sun X B, Ti R F, *et al.* Multi-angle polarization radiation threshold detection method of cloud cover over ocean [J]. *Journal of Atmospheric and Environmental Optics*, 2021, 16(3): 247-255.
王佳佳, 孙晓兵, 提汝芳, 等. 海洋上空云多角度偏振辐射阈值检测方法研究 [J]. 大气与环境光学学报, 2021, 16(3): 247-255.
- [17] Dai Y M, Gieseke F, Oehmcke S, *et al.* Attentional Feature Fusion [C]. *IEEE Winter Conference on Applications of Computer Vision (WACV)*. January 05-09, 2021, Electr Network, 2021: 3559-3568..
- [18] Wang J J. *Cloud Detection and Cloud Phase Inversion and Examples Analysis of Strong Convective Cloud Clusters Based on DPC Polarized Remote Sensing Data of Gaofen-5 Satellite* [D]. Hefei: University of Science and Technology of China, 2021.
王佳佳. 高五 DPC 偏振遥感云检测相态反演及强对流云团个例研究 [D]. 合肥: 中国科学技术大学, 2021.
- [19] Parol F, Buriez J C, Vanbauce C, *et al.* First results of the POLDER "Earth Radiation Budget and Clouds" operational algorithm [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, 37(3): 1597-1612.
- [20] Sèze G, Vanbauce C, Burie J C, *et al.* Cloud cover observed simultaneously from FOLDER and METEOSAT [J]. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 1999, 24(8): 921-926.