

基于改进 MobileNetV2 的地基云图分割网络

步宏坤¹, 常帅^{1,3*}, 谷野¹, 郭春宇², 宋承邦¹, 徐伟³, 吕天宇³, 赵薇¹, 佟首峰¹¹长春理工大学空地激光通信国防重点学科实验室, 吉林 长春 130022;²珩辉光电测量技术(吉林)有限公司, 吉林 长春 130000;³中国科学院长春光学精密机械与物理研究所, 吉林 长春 130033

摘要 在大气测量领域,云是大气模型中最不确定的因素,对云图进行准确分割识别必不可少。然而由于云和大气条件的随机性,云图分割精度和准确率等方面存在着挑战。针对这一问题,设计了一种名为 CloudHS-Net 的新型网络,该网络基于 MobileNetV2,通过引入混合拼接结构、空洞卷积和混合空洞的设计思想,结合高效通道注意力机制,用于实际云图的分割测量。在 SWIMSEG 和 HHCL-Cloud 数据集上进行了与其他先进模型的对比测试,以深入了解网络性能和各部分结构的作用。实验结果表明,高效通道注意力和混合拼接结构均能有效提升模型的分割性能。与当前先进的地基云图分割网络相比,CloudHS-Net 在天空云图分割任务中表现出色,准确率达到 95.51%,平均交并比达到 89.86%。该模型成功降低了来自大气环境的干扰,如太阳光线等,加强了对云的关注,提高了云图分割的精度,更为精准地获取了云的覆盖状态,实验结果表明了该方法的可行性。

关键词 地基云图; 图像分割; MobileNetV2; 混合空洞卷积; 高效通道注意力

中图分类号 P412

文献标志码 A

DOI: 10.3788/LOP240505

Ground-Based Cloud Image Segmentation Network Based on Improved MobileNetV2

Bu Hongkun¹, Chang Shuai^{1,3*}, Gu Ye¹, Guo Chunyu², Song Chengbang¹, Xu Wei³,
Lü Tianyu³, Zhao Wei¹, Tong Shoufeng¹¹National Defense Key Discipline Laboratory on Space-Ground Laser Communication, Changchun University of Science and Technology, Changchun 130022, Jilin, China;²Henghui Optoelectronic Measurement Technology (Jilin) Co., Ltd., Changchun 130000, Jilin, China;³Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, Jilin, China

Abstract In the field of atmospheric measurement, clouds are the most uncertain factor in atmospheric models, so accurate segmentation and recognition of cloud image are indispensable. However, due to the stochastic nature of clouds and atmospheric conditions, challenges exist in the precision and accuracy of cloud image segmentation. To address this issue, we propose a novel network named CloudHS-Net based on MobileNetV2. This network incorporates a hybrid concatenation structure, dilated convolutions, and a mixed dilated design, along with an efficient channel attention mechanism, for practical cloud image segmentation. The performance of the network is thoroughly evaluated on the SWIMSEG and HHCL-Cloud datasets through comparative tests with other advanced models, providing insights into the network's performance and the roles of its various components. Experimental results demonstrate that the efficient channel attention and hybrid concatenation structures effectively enhance the segmentation performance of the model. Compared to current advanced ground-based cloud image segmentation networks, CloudHS-Net excels in the task of sky cloud image segmentation, achieving an accuracy of 95.51% and mean intersection over union (MIoU) of 89.86%. The model reduces disturbances originating from atmospheric environment, such as sunlight, pay stronger attention to cloud. This leads to enhanced precision in cloud image segmentation, allowing for a more accurate capture of cloud coverage status and the experimental results show that the method is feasible.

Key words ground cloud image; image segmentation; MobileNetV2; hybrid dilated convolution; efficient channel attention

收稿日期: 2024-01-12; 修回日期: 2024-02-14; 录用日期: 2024-02-21; 网络首发日期: 2024-03-21

基金项目: 吉林省科技发展计划(YDJZ202301ZYT5407)、长春市科技发展计划(23ZCX02)

通信作者: *changshuai@cust.edu.cn

1 引言

云作为影响全球气候的重要因素,却是大气模型中最不确定的因素^[1]。在大气光学中,高空云中冰晶粒子、液态水云对光的散射和吸收不仅会影响气溶胶高精度测量^[2]、天空偏振模式^[3],还会限制卫星遥感影像的广泛应用。相较于卫星遥感^[4]、激光雷达对云的研究,地基云图利用成像技术,在地面采集对应天空区域的图像,可以直观地描述该区域云图分布覆盖程度,详细记录云类的外部形态特征,从而反映此时的天气状况。通过分析云的分布覆盖规律,可以对光伏发电的功率进行预测^[5],对天文台进行选址观测^[6],对天气、气候进行分析^[7]。因此,利用地面设备采集地基云图,并计算云的覆盖区域及非云区域,是后续研究常态化的必备内容,具有极高的应用价值。

传统计算云覆盖区域采用的是基于图像像素的分割方法,主要以颜色阈值和超像素为主。由于拍摄的地基云图受到所用相机的规格以及太阳光线天空环境和天气条件的影响,Long 等^[8]、Kreuter 等^[9]、Yang 等^[10]、Klebe 等^[11]等在色彩阈值、自适应阈值、全天空阈值上进行研究,但这些分割算法的适用性在对晴天、阴天的复杂变化中不能令人满意。Liu 等^[12]、Shi 等^[13]、Dev 等^[14]等采用超像素方法对云图分割进行研究,在实际应用中分割效果同样不能令人满意。

近年来,深度学习的算力需求更加容易满足,卷积神经网络凭借着其强大的特征提取能力已成为地基云图像分割研究中使用的主流技术。Shi 等^[15]提出了一种基于增强全卷积网络(EFCN)的自动云图分割架构,该架构可用于从天空相机图像中分割云和非云。后

来,Shi 等^[16]优化了 U 形网络(U-Net),改进模型性能,提出了 CloudU-Net 分割白天和夜间的云图。Xie 等^[17]提出了具有对称编码器-解码器结构的 SegCloud 模型,实现了天空、云和太阳区域的分割。张雪等^[18]研究了轻量化的云图分割模型,以小参数运算达到了较好效果。Zhang 等^[19]采用多尺度注意力关注边界的分割。吉茹等^[20]以多尺度结合改进的 Transformer 架构提高边缘检测效果。Zhang 等^[21]设计了一种基于多分支非对称卷积模块和注意力机制的地基云图分割模型(MACNN),该模型能够获取多尺度的云特征,从而提升分割效果。

虽然云图分割网络精度和参数在不断提升,但在地基云图的研究上以剪裁出来的云图为主,人为舍弃了整幅图片复杂信息干扰,在全天空大视场图片上的研究较少。本文在确保分割精度的前提下,对整幅地基云图进行了云图分割算法的研究。同时,选取了 MobileNetV2^[22]这一具有高精度且参数数量较少的网络结构作为基础主干网络。通过运用空洞卷积、混合拼接、通道注意力机制等技术手段,减少了复杂环境对分割效果的干扰,推动了云图分割技术在仪器部署上的应用。该方法输出的精准分割结果,可用于实现高效的全天空云图分割。。

2 基本原理

所提基于 MobileNetV2 的深度卷积神经网络 CloudHS-Net 的整体结构如图 1 所示。模型主要以 MobileNetV2 为基础,输出低层次特征,结合通道拼接后的混合拼接(HS)结构输出高层次特征,将丰富的图层特征与高效通道注意力(ECA)机制^[23]结合,以输出




图 1 CloudHS-Net 模型网络结构

Fig. 1 CloudHS-Net model network structure

处理后的极度聚合特征,并将其与低层次特征相融合。这一过程进一步提升了云图边界的准确性。

2.1 基础网络

深度学习模型层数越多,可调节参数越多,逼近函数的效果越好^[24],因此更深层次的模型可以获得更高层次的特征,为了提取更加丰富的云特征,以 MobileNetV2 作为模型基础,来获取浅层次的通用特征和深层次的细节特征。MobileNetV2 模型^[25]的主要亮点是采用了倒残差结构。倒残差结构包括深度可分离卷积层、残差模块和 ReLU 等。MobileNetV2 的倒残差结构如图 2 所示,对 32 个特征通道先进行升维操作变成 192 个通道,在高维度上来获取更丰富的信息同时通过 3×3 的深度可分离卷积提高运算效率,之后降维恢复 32 通道,再加入残差模块,形成倒残差结构。




图 2 MobileNetV2 的倒残差网络结构

Fig. 2 Inverse residual network structure of MobileNetV2

在细节上,使用 ReLU 变形的 ReLU6,方便后续云图分割实际应用中,在移动开发设备能有很好的数值分辨率。运用批归一化(BN)操作,将输入数据规范化分布,有效降低神经网络的复杂度,并减少了网络退化和过拟合的风险。同时,通过引入 Dropout,进一步增强网络的泛化能力。

在利用 MobileNetV2 获取丰富特征的同时,模型提前输出出低层次特征。这些低层次特征随后与丰富的特征相结合,并进行卷积处理。卷积核的设计中同样加入了 BN 层和 ReLU 激活函数,这有助于提高网络的泛化能力并防止过拟合。在网络的上采样阶段,选择了双线性插值操作来将特征图还原至原始尺寸,这有助于减少空间信息的丢失,并进一步提升分割精度。

2.2 混合拼接结构

在 MobileNet 输出低层次之后,运用空洞卷积^[26]、混合空洞原则和通道拼接等 3 种思想,设计了混合空洞拼接结构,提取高聚合的特征图。

首先,在图像分割领域,普通卷积一般需要池化(pooling)下采样操作,下采样后需要进行上采样恢复,数据尺寸会发生变化,而空洞卷积只有卷积,没有池化操作,可以保持数据结构不变。空洞卷积在普通卷积核中间插入 0 进行填补,形成空洞,可以在不改变输入特征图高度及宽度信息的前提下,增大卷积核的局部感受野。例如, 3×3 的卷积核感受野为 9,当引入 2 的扩张率时,虽然运算参数量保持相同,输出的特征图大小也相同,但是感受野扩大到了 5×5 。这样的设计增加了提取特征的范围,提高了图像分割架构的准

确性。

空洞卷积中很重要的一点是扩张率,其代表将原本的一个卷积核扩展到多少倍,扩展后的卷积核尺寸计算方法如下:

$$k_{\text{expanded}} = r \times (k - 1) + 1, \quad (1)$$

式中: k_{expanded} 为扩张后的卷积核大小; r 为扩张率; k 为卷积核大小。

使用卷积核进行云图信息获取时,要考虑到云是具有强烈随机性的对象,云的大小、云的形状、云的位置会导致预测的云图具有强烈的多样性。目前通常使用 3×3 的卷积核获取云图信息,但是在云的采集图像中,云占据不同大小的区域,针对大型云需要使用较大的扩张率的卷积核,针对小型云要使用较小的扩张率,大型复杂的云图边界需要用小型卷积核进行细节分割。所以本文采取的方案是堆叠多个不同扩张率的卷积核。

单个元素的输出结果取决于输入的区域,该元素对应输入层的区域大小,代表卷积核在图像上看到的区域大小,即感受野。感受野越大,包含的上下文关系越多,扩张率为 $[1, 1, 1]$ 的 3×3 卷积核堆叠形成 7×7 感受野,而 $[1, 2, 3]$ 的 3×3 卷积核堆叠形成 13×13 感受野。可以看出,空洞卷积堆叠可大大增强对中心点周围信息利用率。

但是,随着近年来对空洞卷积的深入研究,发现多个相同扩张率空洞卷积堆叠会导致部分像素不参与计算,造成大量的特征信息丢失,影响最终模型效果,该现象名为栅格效应,具体如图 3 所示。

因此加入混合空洞卷积(HDC)^[27],目的是经过一系列卷积操作使得方形感受野被完全覆盖,没有任何空洞或缺失的边缘。HDC 的一项原则为扩张率要满足相应公式和约束。定义“两个非零值像素之间的最大距离”为

$$M_i = \max [M_{i+1} - 2r_i, M_{i+1} - 2(M_{i+1} - r_i), r_i], \quad (2)$$

式中: M_i 这个距离表示第 i 层最大可使用的扩张率; r_i 表示第 i 层的扩张率。约束为 $M_i \leq k$, k 为卷积核大小,此时在模型中选择的卷积核 $k=3$ 。

HDC 还要求扩张卷积的扩张率不能有大于 1 的公约数。因此采取的扩张率为 $[1, 2, 6]$ 的均匀结果。在 126 的组合中,卷积核的感受野为 19×19 ,利用 361 个像素里的特征信息对中心点周围信息的提取更为均匀,均匀感受野如图 3 所示。

最后为避免卷积过程中的信息丢失,将两个不同层数的卷积特征进行通道拼接,形成一个多维度的丰富卷积特征层,充分利用不同通道进行特征提取,有助于增强模型网络的信息获取能力,如图 4 所示。拼接得到的 256 通道特征图传递给下一级的注意力机制进行权重分配。

2.3 注意力机制

注意力机制源于人类视觉,在大量的信息处理任




图3 扩张率为[2, 4, 8]的卷积核栅格化示意和扩张率为[1, 2, 6]的卷积核均匀感受野示意

Fig. 3 Receptive field of [2, 4, 8] dilation rate convolution kernel stack and receptive field of [1, 2, 6] dilation rate convolution kernel stack




图4 混合空洞拼接过程

Fig. 4 The process of hybrid dilated convolution splicing

务中,人们会重点关注部分重要信息,忽略其他信息。在高维的卷积通道中有部分无效信息,通道注意力会在特征聚合后,选择输入的部分特征给予不同的权重从而筛选出重要的信息。典型通道注意力-挤压激励网络(SENNet)^[28]的流程如下:特征图经过全局平均池化后,被压缩成特征向量以 $[1, 1, C]$ 形式保存,通过全连接层对特征向量的通道进行降维操作,通过激活函数后经过全连接层恢复,通过 Sigmoid 激活函数获得归一化的权重。由于全连接层会增加参数和计算量,且降维操作会损失一部分信息,后续模型需要尽量降低运算量。所提方法使用ECA结构,去除全连接层,能够有效捕获跨通道交互信息,且仅需少数参数就能达到较好的效果。其结构如图5所示, $W \times H \times C$ 的特征通过全局平均池化(GAP)获得聚合特征,之后ECA通过执行 $k=5$ 的快速一维卷积来生成通道权重,与原特征相乘得出经过有效筛选的特征。

对于全局平均池化后的聚合卷积特征 y ,需要通过 $C \times C$ 参数矩阵获取对应的权重信息 ω 。

$$\omega_i = \sigma \left(\sum_{j=1}^k w^j y_i^j \right), y_i^j \in \Omega_i^k, \quad (3)$$

式中: Ω_i^k 表示 y_i 的 k 个相邻通道的集合。对于全连接层,通过卷积核大小为 k 的快速一维卷积(CID_k)来替




图5 高效通道注意结构示意图

Fig. 5 Schematic diagram of the efficient channel attention network structure

代实现:

$$\omega = \sigma [\text{CID}_k(y)]. \quad (4)$$

而自适应的一维卷积核大小计算公式为

$$k = \phi(C) = \left\lfloor \frac{\log_2 C}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}}, \quad (5)$$

式中: $\lfloor t \rfloor_{\text{odd}}$ 表示 t 的最接近奇数; γ 设为 2; b 设为 1。通道数为 256, 一维卷积核 $k=5$ 。之后通过 $k=5$ 的一维卷积核快速获取权重信息 ω 。

因此, ECA 结构去除了全连接层的降维操作, 采用一维卷积来局部跨通道交互提取信息, 使用更少的参数量和计算量, 为信息丰富的 256 通道特征图赋予

权重,加快模型训练预测速度,有效避免了降维对于通道注意力学习效果的影响,实现了与经典 SENet 通道注意力相似的学习效果。

2.4 评价指标

采用精准率、召回率、准确率、错误率、F1 值 (F1_score) 和平均交并比 (MIoU) 作为评价指标来衡量分割结果性能。

2.5 实验环境

本次实验使用 Windows 10 系统,利用 PyCharm 软件进行 PyTorch 深度学习网络框架的搭建,使用 Python 3.10,PyTorch 2.01 通过 NVIDIA 公司的显卡进行 GPU 运行。CloudHS-Net 网络模型及其他对比模型的搭建基于 PyTorch 深度学习框架,同时应用 Google 官方网站提供的 MobileNetV2 预训练模型。选取的各模型训练时采用的参数统一设置,批大小

(batch size) 为 8,优化器为自适应优化的 Adam,损失函数采用二元交叉熵,学习率统一设置为 0.0005,分割类别数为 2。

地基云图数据来自新加坡南洋理工大学发布的公开数据集——新加坡全天空图像分割数据集 (SWIMSEG)^[29]。SWIMSEG 的云图样本将地基云图分为多个图像块,每个图像块覆盖约 $60^{\circ}\sim 70^{\circ}$ 的天空,分辨率为 600×600 ,共计 1013 张。另外为推进全天空云图分割应用,采集并标注了一组 180° 的大视场数据集 HHCL-Cloud,处理后分辨率为 1900×1900 ,共计 483 张,通过缩小随机旋转对称,增强到 1449 张。在本次设计的实验中,数据集中 90% 的图片用于云图分割模型的训练,剩下 10% 的图片作为预测集,用来检验训练模型的性能。图 6 为 SWIMSEG 数据集以及 HHCL-Cloud 数据集示例。




图 6 SWIMSEG 数据集以及 HHCL-Cloud 数据集示例

Fig. 6 Examples of SWIMSEG dataset and HHCL-Cloud dataset

3 分析与讨论

3.1 公开数据集 SWIMSEG 实验对比

为了验证 CloudHS-Net 在地基云图上的分割结

果,将 CloudHS-Net 和其他几种云图分割网络在公开数据集 SWIMSEG 上进行比较,包括了 K-means 算法、颜色归一化差值 Otsu、以 Resnet50 为骨干的 U-ResNet、DeepLabv3+、CloudSegNet、MACNN 和所提




图 7 不同方法预测结果。(a) 输入; (b) mask; (c) K-means; (d) Otsu; (e) U-ResNet; (f) DeepLabV3+; (g) CloudSegNet; (h) MACNN; (i) 所提方法

Fig. 7 Prediction results of different methods. (a) Input image; (b) mask; (c) K-means; (d) Otsu; (e) U-ResNet; (f) DeepLabV3+; (g) CloudSegNet; (h) MACNN; (i) proposed method

CloudHS-Net,实验结果如图 7 所示。

在 SWIMSEG 的云图样本上进行实验,可以看到,CloudHS-Net结果与标签云图更为相似。K-means 方法对光线均匀的云图识别较好,但是在有厚积云 and 薄云的复杂情况下,分割效果不理想。Otsu 同样对薄云难以分割。U-ResNet 采用的 Resnet50 和 U-Net 结合对于云边界具有较好的识别效果,但是对于薄云的有些细节边界有较大的误判可能性。CloudSegNet 由于模型层数较低,所取得的效果也不是太好。DeepLabV3+ 采用的空洞空间卷积池化金字塔 (ASPP)可以有效分割出细节的云边界,但是难以界定薄云与天空的边界。MACNN 结合了非对称式的 ASPP 和混合注意力机制,可以识别出薄云与天空的边界,但是在云图细节上和标签有所区别。CloudHS-Net 结果与标签图像更为接近,对云图细节分割效果优于其他 6 种分割算法。

表 1 为不同方法对云图的具体分割结果,Cloud HS-Net 的指标均优于对比的先进分割模型。其中,MIoU 指数比 MACNN 高 1.19 百分点,错误率降低了 1.03 百分点。精准率、准确率、召回率、和 F1 分数都是最优的,这些指标越优秀代表该模型的云分割结果越好。这些评价指标都表明 CloudHS-Net 优于对比云图像分割方法。

表 1 不同方法对云图分割结果

Table 1 Segmentation results of cloud images by different methods unit: %

Method	Precision	Accuracy	Recall	F1-score	Error rate	MIoU
K-means	90.53	83.19	77.25	83.36	16.81	71.48
Otsu	88.15	86.63	87.20	87.67	13.37	78.05
U-ResNet	86.73	86.87	86.91	86.79	13.13	76.68
CloudSegNet	91.42	90.91	90.44	90.75	9.09	83.09
DeepLabV3+	92.28	92.33	92.24	92.26	7.67	85.64
MACNN	92.70	92.60	92.56	92.63	7.40	86.28
CloudHS-Net	93.10	93.63	93.53	93.31	6.37	87.47

3.2 全天空数据集对比实验

为了验证 CloudHS-Net 在全天空云图上的分割能力,将 SWIMSEG 生成的模型直接在 HHCL-Cloud 上进行预测,得出的 MIoU 为 34.70%,准确率为 52.32%。可以看出,数据的差异会产生较大的影响。各模型在 HHCL-Cloud 数据集上训练后,与其他几种云图分割网络的对比结果如图 8 所示。可以看出,对于太阳周围的云图分割,所提方法和标签是更为相似的。在光线影响下对于薄云的边界的分割也是 CloudHS-Net 更好。




图 8 全天空数据集对比。(a)输入;(b) mask;(c) U-ResNet;(d) DeepLabV3+;(e) CloudSegNet;(f) MACNN;(g) 所提方法
Fig. 8 Comparison of all sky datasets. (a) Input; (b) mask; (c) U-ResNet; (d) DeepLabV3+; (e) CloudSegNet; (f) MACNN; (g) proposed method

表 2 显示了 CloudHS-Net 及其他对比模型在 HHCL-Cloud 数据集上的评价指标,最好的指标都以黑色加粗表示出来。CloudHS-Net 相较于表现较为优秀的 MACNN 而言,精确率增加了 0.93 百分点,准确率增加了 0.8 百分点,错误率降低了 0.8 百分点,召回率增加了 1.03 百分点,F1 分数增加了 1 百分点,平均交并比增加了 0.85 百分点。即所提方法在不同的数据集上取得的效果具有一致性。同时将 HHCL-Cloud 产生的模型在 SWIMSEG 进行测试,MIoU 为 86.56%。准确率为 92.84%,证明模型的泛化性较好。

接着将云图分割模型的参数量、运算量、训练时间和预测时间进行对比实验,来衡量分割算法的复杂度,结果如表 3 所示。由表 3 可知,U-ResNet 的运算量是最大的,训练时间也是最长的。CloudSegNet 的复杂度最低,但是其分割效果不如 MACNN 和 CloudHS-

表 2 不同方法对云图分割评估指标

Table 2 Evaluation indexes of cloud image segmentation by different methods unit: %

Method	Precision	Accuracy	Recall	F1-score	Error rate	MIoU
U-ResNet	91.97	93.27	93.93	92.94	6.73	86.81
CloudSegNet	93.31	94.21	93.89	93.59	5.79	88.01
DeepLabV3+	92.57	93.46	92.90	92.74	6.54	86.54
MACNN	93.81	94.71	94.54	94.15	5.29	89.01
CloudHS-Net	94.74	95.51	95.57	95.15	4.49	89.86

Net。DeepLabV3+ 的表现中规中矩。CloudHS-Net 的分割指标是最优的且参数量和训练时间都比 MACNN 要少,CloudHS-Net 参数量并没有增加多少,但分割性能提升较多,具备较高性价比。

表 3 5 种网络的参数量、运算量、训练时间、测试时间对比

Table 3 Total params, total GFLOPs, training time, and testing time of five kinds of networks

Method	Total params /10 ⁶	Total GFLOPs /10 ⁹	Training time /h	Testing time /s
U-ResNet	43.933	184.100	4.0	15
CloudSegNet	1.832	23.728	1.7	69
DeepLabV3+	5.813	52.867	2.3	83
MACNN	56.8	94.5	3.7	114
CloudHS-Net	6.224	79.935	2.6	92

在实际模型部署和仪器设计中,所提模型参数量相对于 CloudSegNet 有所增加,但分割精度有较大提升,对 140 张云图的预测时间没有太大区别,在天文台、气象工作等实际任务中,高精度、较少运算参数的

表 4 Hybrid Splicing 和 ECANet 结构消融性实验

Table 4 ablation experiments of Hybrid Splitting and ECANet structures

unit: %

Method	Precision	Accuracy	Recall	F1-score	Error rate	MIoU
MobileNetV2	91.70	91.66	91.46	91.56	8.34	84.45
+ ECA	92.70	93.55	92.99	92.84	6.45	86.72
+ HS	93.76	94.66	94.45	94.09	5.34	88.89
CloudHS-Net	94.74	95.51	95.57	95.15	4.49	89.86

3.4 讨论

地基云图的分割是地面观测气象云图的基础,通过模型的移植可以完成仪器的实现。在实际仪器运用中, CloudHS-Net 网络采用的 ReLU6 激活函数可以在嵌入式设备中保持系统的鲁棒性, MobileNetV2 主干会降低实际运用中的开销,同时网络中有 Dropout 结构,可以随机丢弃部分神经元,而 BN 层使得输入落在激活函数非饱和区,提高系统鲁棒性。由表 1 和表 2 可以看出, CloudSegNet 的网络结构层数较少,且采用的池化操作导致网络分割精度低。U-ResNet 多次运用上下采样容易导致信息丢失,对不同数据的泛化性不足。CloudHS-Net 使用 MobileNetV2 加深模型层数,同时保证系统鲁棒性,使用混合拼接和 ECA 结构获得高维的云图信息,摒弃无效干扰特征,对与低层次直观特征高聚合的丰富特征进行分割。与其他网络相比, CloudHS-Net 在地基云图的分割任务中更具备实际意义。

4 结 论

本文提出并验证了一种用于地基云图分割的深度卷积神经网络模型 CloudHS-Net,并在公开 SWIMSEG 及大视场全天空的数据集上进行了测试,验证了模型的可行性。所提方法可以有效提取图像信息,增强特征信息的利用率,减少目标信息的丢失,降低了光线等大气环境的干扰,提高预测的准确率。 CloudHS-Net 在公开数据集 SWIMSEG 上的分割精准率、准确率、召回率、F1 分数、错误率和交并比分别是 93.10%、93.63%、93.53%、93.31%、6.47%、87.47%,

CloudHS-Net 具备更多优势。

3.3 消融性实验

为了验证所提混合拼接结构及 ECA 结构的有效性,进行了消融性实验,结果如表 4 所示。可以看到, HS 结构对模型的提升效果是十分明显的,精准率提升了 2.06 百分点,准确率提升了 3 百分点,召回率提升了 2.99 百分点, F1 分数提升了 2.53 百分点,错误率降低了 3 百分点, MIoU 提高了 4.44 百分点。在加入了 ECA 后,精准率、准确率、召回率、F1 分数、 MIoU 分别提高了 1 百分点、1.89 百分点、1.53 百分点、1.28 百分点、2.27 百分点,错误率降低了 1.89 百分点。即混合拼接结构及 ECA 结构均提高了模型网络的性能。经数据集统计,模型最小有效分割云图面积为 12 pixel。

在 HHCL-Cloud 数据集上的结果为 94.74%、95.51%、95.57%、95.15%、4.49%、89.86%。消融实验表明,混合拼接结构和 ECA 结构对提高 CloudHS-Net 的分割性能起着有力的作用。对比实验结果表明, CloudHS-Net 在地基云图和大视场云图分割中具有较好的性能,可为天气气象相关任务提供精确的云覆盖信息。

参 考 文 献

[1] 饶瑞中. 现代大气光学[M]. 北京: 科学出版社, 2012: 68-72.
Rao R Z. Modern atmospheric optics[M]. Beijing: Science Press, 2012: 68-72.

[2] 胡建波, 王雄, 赵少华, 等. 星载高光谱分辨率激光雷达大气气溶胶和云探测研究[J]. 光学学报, 2023, 43(18): 1899901.
Hu J B, Wang X, Zhao S H, et al. Spaceborne high spectral resolution lidar for atmospheric aerosols and clouds profiles measurement[J]. Acta Optica Sinica, 2023, 43(18): 1899901.

[3] 崔岩, 李得先, 周野, 等. 冰云对天空偏振模式的影响[J]. 光子学报, 2023, 52(11): 1101001.
Cui Y, Li D X, Zhou Y, et al. Atmospheric polarization properties under ice cloud conditions[J]. Acta Photonica Sinica, 2023, 52(11): 1101001.

[4] 尚华哲, 胡斯勒图, 李明, 等. 基于被动遥感卫星可见至红外通道观测的云特性遥感[J]. 光学学报, 2022, 42(6): 0600003.
Shang H Z, Husi L T, Li M, et al. Remote sensing of cloud properties based on visible-to-infrared channel observation from passive remote sensing satellites[J]. Acta Optica Sinica, 2022, 42(6): 0600003.

- [5] 刘翼飞, 崔承刚. 基于地基云图云量特征的光伏发电功率区间预测[J]. 南方电网技术, 2023, 17(2): 92-100.
Liu Y F, Cui C G. Interval prediction for short-term solar power based on cloud features of ground-based cloud images[J]. Southern Power System Technology, 2023, 17(2): 92-100.
- [6] Varela A M, Bertolin C, Muñoz-Tuñón C, et al. Astronomical site selection: on the use of satellite data for aerosol content monitoring[J]. Monthly Notices of the Royal Astronomical Society, 2008, 391(2): 507-520.
- [7] Glotfelty T, Alapaty K, He J, et al. The weather research and forecasting model with aerosol-cloud interactions (WRF-ACI): development, evaluation, and initial application[J]. Monthly Weather Review, 2019, 147(5): 1491-1511.
- [8] Long C N, Sabburg J M, Calbó J, et al. Retrieving cloud characteristics from ground-based daytime color all-sky images[J]. Journal of Atmospheric and Oceanic Technology, 2006, 23(5): 633-652.
- [9] Kreuter A, Zangerl M, Schwarzmam M, et al. All-sky imaging: a simple, versatile system for atmospheric research[J]. Applied Optics, 2009, 48(6): 1091-1097.
- [10] Yang J, Lü W T, Ma Y, et al. An automatic ground-based cloud detection method based on the local threshold interpolation[J]. Acta Meteorologica Sinica, 2010, 68(6): 1007-1017.
- [11] Klebe D I, Blatherwick R D, Morris V R. Ground-based all-sky mid-infrared and visible imagery for purposes of characterizing cloud properties[J]. Atmospheric Measurement Techniques, 2014, 7(2): 637-645.
- [12] Liu S, Zhang L B, Zhang Z, et al. Automatic cloud detection for all-sky images using superpixel segmentation [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(2): 354-358.
- [13] Shi C Z, Wang Y, Wang C H, et al. Ground-based cloud detection using graph model built upon superpixels [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 719-723.
- [14] Dev S, Savoy F M, Lee Y H, et al. Nighttime sky/cloud image segmentation[C]//2017 IEEE International Conference on Image Processing (ICIP), September 17-20, 2017, Beijing, China. New York: IEEE Press, 2017: 345-349.
- [15] Shi C J, Zhou Y T, Qiu B, et al. Diurnal and nocturnal cloud segmentation of all-sky imager (ASI) images using enhancement fully convolutional networks[J]. Atmospheric Measurement Techniques, 2019, 12(9): 4713-4724.
- [16] Shi C J, Zhou Y T, Qiu B, et al. CloudU-net: a deep convolutional neural network architecture for daytime and nighttime cloud images' segmentation[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 18(10): 1688-1692.
- [17] Xie W Y, Liu D, Yang M, et al. SegCloud: a novel cloud image segmentation model using a deep convolutional neural network for ground-based all-sky-view camera observation[J]. Atmospheric Measurement Techniques, 2020, 13(4): 1953-1961.
- [18] 张雪, 贾克斌, 刘钧, 等. 面向轻量化的地基云图分割技术研究[J]. 测控技术, 2022, 41(9): 37-43.
Zhang X, Jia K B, Liu J, et al. Segmentation technology of ground-based cloud image for lightweight[J]. Measurement & Control Technology, 2022, 41(9): 37-43.
- [19] Zhang Z, Yang S Z, Liu S, et al. Ground-based cloud detection using multiscale attention convolutional neural network[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 8019605.
- [20] 吉茹, 张银胜, 杨宇龙, 等. 基于多尺度特征融合的改进型云图分割方法[J]. 国外电子测量技术, 2022, 41(11): 37-44.
Ji R, Zhang Y S, Yang Y L, et al. Improved cloud image segmentation method based on multi-scale feature fusion[J]. Foreign Electronic Measurement Technology, 2022, 41(11): 37-44.
- [21] Zhang L W, Wei W H, Qiu B, et al. A novel ground-based cloud image segmentation method based on a multibranch asymmetric convolution module and attention mechanism[J]. Remote Sensing, 2022, 14(16): 3970.
- [22] 张男男, 李丽莎, 王宝珠, 等. 基于 MobileNet 的地基云图分割方法研究[J]. 电子技术与软件工程, 2022(18): 129-132.
Zhang N N, Li L S, Wang B Z, et al. Research on segmentation method of foundation cloud image based on MobileNet[J]. Electronic Technology and Software Engineering, 2022(18): 129-132.
- [23] Wang Q L, Wu B G, Zhu P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 11531-11539.
- [24] Lippmann R. An introduction to computing with neural nets[J]. IEEE ASSP Magazine, 1987, 4(2): 4-22.
- [25] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4510-4520.
- [26] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[EB/OL]. (2015-11-23)[2024-11-12]. <http://arxiv.org/abs/1511.07122v3>.
- [27] Wang P Q, Chen P F, Yuan Y, et al. Understanding convolution for semantic segmentation[C]//2018 IEEE Winter Conference on Applications of Computer Vision (WACV), March 12-15, 2018, Lake Tahoe, NV, USA. New York: IEEE Press, 2018: 1451-1460.
- [28] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [29] Dev S, Nautiyal A, Lee Y H, et al. CloudSegNet: a deep network for nychthemeron cloud image segmentation [J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(12): 1814-1818.