

DOI:10.19651/j.cnki.emt.2519429

基于 DeepLabV3+改进的双偏振雷达定量降水估计方法^{*}周文博¹ 张永宏^{1,2} 王俊飞³ 杨天笑¹(1.南京信息工程大学自动化学院 南京 210044; 2.南京信息工程大学江苏省大气环境与装备技术协同创新中心 南京 210044;
3.南京信息工程大学电子与信息学院 南京 210044)

摘 要: 针对双偏振雷达定量降水估计中精度不足与计算效率较低的问题,提出了一种基于 DeepLabV3+改进的轻量化多尺度融合算法 DPCR-Net。该算法采用轻量化主干网络结合倒置残差与膨胀卷积,在减少参数的同时保持特征提取能力;通过密集级联自适应特征金字塔(D-ASPP)增强特征复用与对小目标的敏感性;并利用混合注意力解码器融合多尺度特征,抑制噪声并保留细节。在 NJU-CPOL 数据集上的实验结果显示,所提方法的平均绝对误差(MAE)、均方根误差(RMSE)和相关系数(CC)分别为 0.519 7、4.174 4 和 0.661 0,命中率为 0.897 4,参数量仅 4.11 M,计算量为 8.29 G。相比主流模型,所提算法在估计精度与计算效率上均有提升,可支持高精度实时降水估计及边缘设备部署。

关键词: 降水量估计;双偏振雷达;轻量化网络;注意力机制;语义分割

中图分类号: TP391.4;TN957.52 **文献标识码:** A **国家标准学科分类代码:** 510.40

Quantitative precipitation estimation method for dual-polarization
radar based on improvements of DeepLabV3+Zhou Wenbo¹ Zhang Yonghong^{1,2} Wang Junfei³ Yang Tianxiao¹(1.School of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, China;
2.Jiangsu Provincial Collaborative Innovation Center for Atmospheric Environment and Equipment Technology,
Nanjing University of Information Science and Technology, Nanjing 210044, China; 3.School of Electronic and
Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Addressing the issues of insufficient accuracy and low computational efficiency in quantitative precipitation estimation for dual-polarization radar, this paper proposes a lightweight multi-scale fusion algorithm, DPCR-Net, based on an improved DeepLabV3+. This algorithm employs a lightweight backbone network combined with inverted residual and dilated convolution to reduce parameters while maintaining feature extraction capabilities; enhances feature reuse and sensitivity to small targets through a densely cascaded adaptive feature pyramid; and utilizes a hybrid attention decoder to fuse multi-scale features, suppress noise and preserve details. Experimental results on the NJU-CPOL dataset show that the method achieves a mean absolute error (MAE), root mean squared error (RMSE) and correlation coefficient (CC) of 0.519 7, 4.174 4 and 0.661 0, respectively, with a hit rate of 0.897 4, a parameter count of only 4.11 M and a computational cost of 8.29 G. Compared to mainstream models, the algorithm proposed in this paper improves both estimation accuracy and computational efficiency, enabling high-precision real-time precipitation estimation and deployment on edge devices.

Keywords: precipitation estimation; dual-polarization radar; lightweight network; attention mechanism; semantic segmentation

0 引 言

降雨引发的暴雨、洪涝等自然灾害,对农业生产、水资源调配、社会经济运行以及人民生命财产安全构成严重威

胁,准确刻画降水的分布特征是有效开展灾害预警、精准实施水资源管理、科学保障粮食稳产的关键前提^[1-2]。因此,准确、及时的定量降水估计对于恶劣天气和水资源管理决策至关重要^[3-5]。降雨估计主要依赖雨量计、气象雷达和卫

收稿日期:2025-07-22

* 基金项目:国家自然科学基金(42175157,42475151)、江苏省研究生科研创新计划项目(KYCX25_1647)、国家重点研发计划项目(2021YFE0116900)、风云卫星应用先行计划项目(FY-APP-2022.0604)资助

星遥感 3 种手段。雨量计可直接测量降水,但需密集布点才能反映空间分布,实际中常因站点稀疏或分布不均而难以准确表征区域降水^[6]。卫星具备全球覆盖能力,适用于地面观测稀少地区,但其精度、分辨率和反演不确定性仍是挑战^[7]。相较之下,气象雷达则具有高时空分辨率,可提供近乎实时的连续降水监测图像,对理解降水机制、精准预报及洪水预警具有重要意义^[8-10]。

传统雷达降水估计主要基于 Z - R 关系,利用水平反射率因子(Z_H)反演降水强度。然而,由于降水粒子复杂,仅依赖反射率难以满足精细化需求。为此,双偏振雷达技术得以发展,通过增加垂直直化通道,可获取水平反射率(Z_H)、差分反射率(Z_{DR})、差分传播相移率(K_{DP})等参数,从而更细致地识别降水粒子信息^[11]。研究表明,双偏振雷达通过引入 Z_{DR} 等偏振参数,能有效改善传统方法对小雨高估、大雨低估的问题,提高估测精度^[12]。但实际应用中,雷达仍受地面杂波等误差影响, Z - R 关系存在局限,且降水系统中的部分物理机制尚未被充分认知,制约了传统方法的进一步突破。

深度学习凭借强大的数据拟合能力,为降水估计开辟了新途径。它利用卷积神经网络直接从雷达数据与雨量计的映射关系中学习降水模式,克服了传统方法对物理方程的依赖。Li^[13]等基于稠密块构建 RQPenetD1 模型,利用双偏振雷达多维参量实现地表降水端到端估计,精度显著超越传统方法。Bouget 等^[14]基于 UNet 提出融合的雷达双因子深度学习模型,引入数值天气预报风速场强化降水临近预报,效果显著优于单雷达反演降雨输入的模式。Trebing 等^[15]提出的 SmaAt-UNet 通过在 UNet 中集成注意力模块并使用深度可分离卷积来减少参数数量和运算量,能以更少的参数量实现有效的降水预报。Bai 等^[16]提出 Rainformer,通过全局特征提取单元和门控融合单元构建特征提取平衡网络,结合窗口自注意力与局部特征融合机制以提升对高强度降雨的预测性能。Shen 等^[17]提出的 ADC_Net 融合空洞卷积、注意力卷积及循环卷积构建了一个类似 UNet 镜像金字塔结构的雷达降水模型。尹传豪等^[18]提出 GLnet,融合 Unet 和 Swin-Transformer 构建了一个非对称双路特征提取网络,通过卷积和自注意力机制分别提取雷达回波的局部与全局特征以实现降水预测。此外,Li 等^[19]提出了 SwinNowcast 模型,通过在传统 UNet 框架内引入窗口化自注意力,模型能够同时学习局部细节和全局相关性。这些方法虽在一定程度上提升了降水估计性能,但仍普遍面临模型参数冗余、计算效率低下的挑战,且在复杂降水场景下,对强降雨核心区域的精细刻画和弱降水区域的连续性保持能力仍有不足。

本研究将定量降水估计构建为像素级回归问题,其任务本质与语义分割高度一致,即对图像中的每个像素点进行密集预测。这一范式借鉴了视觉测量领域的成功思路,例如基于语义分割的水位线提取^[20]和面向实时性优化的

列向分割设计^[21],均为利用像素级预测实现物理量反演提供了方法参照。因此,能够进行端到端像素级预测的语义分割模型,是完成该任务的合适框架。在众多语义分割模型中,DeepLabV3+^[22]因其能有效融合多尺度上下文信息与空间细节的架构,被选为本研究降水估计的基线模型。但将其用于双偏振雷达降水估计时,其庞大的计算量、空洞金字塔模块(atrous spatial pyramid pooling, ASPP)的固定结构以及解码器的简单设计,制约了模型效率与对复杂降水场特征的精确捕捉。针对 DeepLabV3+ 的上述不足,近年来已有一些改进研究。例如,王银等^[23]将挤压激励模块嵌入 ASPP 以增强通道特征选择增强提高了语义分割任务中对边界和细节判断的准确性。李明等^[24]在 DeepLabV3+ 基础上引入了多尺度注意力机制与混合损失函数,提升模型的特征表达能力和泛化能力。惠飞等^[25]在 DeepLabV3+ 中采用深度可分离卷积进行轻量化设计,并引入注意力机制与并行分支以增强特征融合与边缘精度。然而,这些改进多侧重于单一注意力机制的引入或模块的局部优化,未能系统性地解决特征提取效率、多尺度特征自适应融合与细节恢复之间的平衡问题。这样会出现强降雨核心区域漏估和弱降水区域连续性不足导致降水估计精度不高等问题,针对这些问题,本研究提出一种基于 DeepLabV3+ 网络改进的轻量级多尺度融合算法 DPCR-Net,用于双偏振雷达数据的降水估计任务。具体而言,本研究的工作包括:

1) 引入 Mobilenetv2^[26] 轻量化特征提取网络,替换原 DeepLabV3+ 模型中的 Xception 网络,作为本研究算法的主干网络。在保留特征提取能力的情况下,大幅减少计算量。

2) 提出密集级联自适应特征金字塔模块(dense adaptive scattering pyramid with precipitation-sensitivity, D-ASPP),改变原有空洞金字塔中卷积块连接方式和膨胀率组合,提出注意力密集卷积模块(dual attention dense convolution, DAD-Conv)代替原有卷积块,使用自适应区域池化模块(adaptive region pooling, ARP),增加特征复用效率,提高特征提取精度。

3) 提出混合注意力编码器模块(hybrid attention decoder, HAD),从空间和通道维度关注重点降水区域信息,解决浅层高分辨率特征携带大量噪声与深层特征因连续卷积丢失细节的问题,追踪到更丰富的特征信息。

1 改进的 DeepLabV3+ 算法

本研究提出的模型通过引入双偏振雷达数据来解决传统单参量方法的局限性,充分捕捉降雨信息。模型通过叠加形状同为(1,256,256)的水平反射率因子 Z_H 和差分反射率 Z_{DR} 形成形状为(2,256,256)的双通道雷达数据输入,以地面站的真实降水为标签,开展降水估计任务研究。本节首先介绍网络模型的整体结构,其次分别介绍网络模型

中每个重要模块的设计原理和细节,最后介绍实验选取的损失函数。

1.1 总体结构

本研究的网络结构在语义分割模型 DeepLabV3+网

均进行了相应的改进,DPCR-Net 网络总体框架如图 1 所示。

1)编码区

首先输入雷达数据通过主干网络 Mobilenetv2 网络进




图 1 总体框架

Fig.1 Overall framework

行特征提取,替代原 DeepLabV3+中使用的 Xception 骨干网络,大幅减少了模型训练时间和参数数量。处理后的特征送入 D-ASPP 模块以获得深层语义特征,并且从骨干网络引出 1 条浅层特征送入解码区。进入 D-ASPP 模块的特征,经过膨胀率分别为 4、8、12 的 DAD-Conv 卷积模块,这 3 个不同的空洞卷积模块通过级联式连接,膨胀率从小到大排列,经上一层膨胀率卷积模块处理后的特征被送入下一级卷积模块中,有效实现特征复用。同时针对任务中强降水一般集中于小区域的特点,选用了当前的膨胀率的组合,增加对强降水区域的关注度。经过 3 层 DAD-Conv 卷积模块的特征与经过 ARP 模块处理的另一条分支进行拼接,经卷积调整得到深层语义特征输出到解码区进一步处理。

2)解码区

为了更好地保留雷达数据的空间细节,首先从主干网络 Mobilenetv2 的第 4 层提取浅层特征,通过 1×1 卷积调整通道,经过通道注意力模块(channel attention,CA)计算通道权重,增强重要通道,使模型能获得雷达回波中的更为详细的局部细节纹理与高分辨率空间结构,提高分割边界的准确度。接着将获得的浅层高分辨特征与 D-ASPP 生成的深层语义特征,1×1 卷积与上采样操作调整特征图形状一致后,进行特征拼接。拼接输出的特征经过卷积块注意力模块(convolutional block attention module,CBAM)以聚焦降水核心区边界,降低误判降水区域风险。最终通过 1×1 卷积与上采样操作还原特征图到降水标签尺寸,获得降水估计结果图。

1.2 主干网络

Mobilenetv2^[26]是谷歌提出的一种轻量化的特征提取网络,与原 DeepLabV3+模型中使用 Xception 网络作为主干网络相比更为精简,有参数量少与预测精度高的特点。如表 1 所示,首先通过 3×3 常规卷积将双通道的雷达特征图升维到 32 通道特种空间(输入分辨率 256×256),随后经过 18 个倒置瓶颈残差层进行多尺度降雨特征提取,相较于原网络 17 层的设计新增了降水特异性特征提取层,通过膨胀卷积策略,在保持特征图分辨率同时扩大感受野,适应降水估计任务对空间细节的需求。其中使用 ReLU6 作为非线性激活函数使模型有更好的鲁棒性,最终 1×1 卷积层将 320 通道扩展至 1 280 维高维空间输出深层特征以进行下一步的特征提取。在输出深层特征之前,由 Mobilenetv2 网络的第 4 层处理之后便引出浅层特征输入到解码区,其中浅层特征图分辨率是原图 1/4,避免过度下采样导致弱降水信息丢失。

Mobilenetv2 基本结构有 3 个部分:深度可分离卷积、倒残差结构(inverted residuals)与线性瓶颈结构。相较于前一代模型 MobilenetV1,主要的设计亮点就是倒残差结构。在残差结构中最后一层中以线性激活函数替代了 ReLU6 激活函数,并且只有在 stride=1 且输入特征矩阵和输出特征矩阵 shape 相同时才会有 shortcut 连接,当 stride=2 时没有 shortcut 连接。倒残差结构如图 2 所示。

使用 Mobilenetv2 网络可以在保留特征提取能力的同时有效的减少计算量,减少模型训练时间与资源算力,适用于类似降水估计这种需要进行快速响应的任务。

表 1 Mobilenetv2 的网络结构和参数说明

Table 1 Network structure and parameter description of Mobilenetv2

输入	操作层	扩张 倍数	输出 通道	重复 次数	步长
$256^2 \times 2$	3×3 卷积层	—	32	1	2
$128^2 \times 32$	倒置瓶颈残差层	1	16	1	1
$128^2 \times 16$	倒置瓶颈残差层	6	24	2	2
$64^2 \times 24$	倒置瓶颈残差层	6	32	3	2
$32^2 \times 32$	倒置瓶颈残差层	6	64	4	2
$16^2 \times 64$	倒置瓶颈残差层	6	96	3	1
$16^2 \times 96$	膨胀瓶颈残差层	6	160	3	2
$8^2 \times 160$	倒置瓶颈残差层	6	320	1	1
$8^2 \times 320$	1×1 降维卷积	—	1 280	1	1




图 2 倒残差结构

Fig. 2 Inverted residuals structure

1.3 D-ASPP 模块

针对雷达降水估计任务中降水场空间分布异质性强、局部强降水特征易丢失等问题,研究通过在 ASPP 模块基础上引入 ARP 模块和 DAD-Conv 模块,并且将空洞卷积架构改进为级联式,构建出 D-ASPP 模块。

图 3 是原 DeepLabV3+ 模型中空洞金字塔模块 (ASPP),采用并行多分支结构,输入分别经过一个 1×1 卷积、膨胀率组合为 6、12、18 的 3 $\times$ 3 空洞卷积和全局平均池化(global average pool, GAP)等 5 条支路,拼接后得到深层语义特征。




图 3 传统空洞金字塔结构

Fig. 3 Inverted residuals structure

相较于传统 ASPP,本研究在空洞金字塔架构设计中,采用级联式连接替代传统 ASPP 的并行多分支结构,该改进提升了特征复用效率,通过逐级递增的膨胀率(4、8、12)形成链式特征传递,每级卷积输出经通道注意力筛选后作为下一级输入,形成特征复用链条,减少了冗余分支,使浅层局部纹理与深层全局语义持续交互,相较于并行结构的

孤立特征提取,缩短了梯度反向传播路径,缓解了高膨胀率导致的局部特征稀释问题,提高了雷达回波图特征的提取效率。同时在雷达降雨估计任务中,强降雨核心区常表现为小尺度、高梯度的空间特征,而传统 ASPP 模块采用的 6、12、18 大膨胀率组合在下采样特征图上的等效感受野覆盖范围过大,难以精细捕获小范围降雨特征。为此,本

研究将膨胀率调整为 4、8、12 的组合,提高对强降雨核心区域的分割能力,精细化特征提取。改进后的 D-ASPP 模块

如图 4 所示。下面对其 ARP 模块和 DAD-Conv 模块分别介绍。




图 4 D-ASPP 模块结构

Fig. 4 D-ASPP module structure

1) ARP 模块

传统 ASPP 中使用全局平均池化操作通过均匀压缩特征图的空间维度获取全局上下文信息,但在处理复杂空间结构时难以捕捉区域化差异特征,出现空间细节丢失的问题。为此本模型在 D-ASPP 中将全局池化模块替换为自适应区域池化模块(adaptive region pooling, ARP),通过分区域特征聚合提升多尺度特征提取效果。

假设输入特征为 $X \in \mathbf{R}^{B \times C \times H \times W}$, 其中 B 为批次大小, C 为通道数, $H \times W$ 为图像空间尺寸, H 与 W 分别是特征图的高和宽。首先将图像划分为 $K_h \times K_w$ 个子区域,对每个子区域执行平均池化以提取局部特征:

$$P_{b,c,i,j} = \frac{1}{N_{i,j}} \sum_{(m,n) \in R_{i,j}} X_{b,c,m,n} \quad (1)$$

式中: $R_{i,j}$ 为第 (i,j) 个子子区域的空间坐标集合; $N_{i,j}$ 为该区域的像素数量; $P \in \mathbf{R}^{B \times C \times K_h \times K_w}$ 为池化之后的特征。

然后通过双线性插值将池化后的低分辨率特征恢复至原始空间尺寸,避免传统池化操作导致的空间信息丢失。将低分辨率特征 P 上采样恢复至图像的原始尺寸 $H \times W$:

$$Y = \text{Interpolate}(P, \text{size} = (H \times W), \text{mode} = \text{bilinear}) \quad (2)$$

式中: $\text{Interpolate}()$ 是插值函数,将低分辨率特征图上采样到指定尺寸; $\text{mode} = \text{bilinear}$ 为使用双线性插值算法恢复空间细节。

得到的输出 $Y \in \mathbf{R}^{B \times C \times H \times W}$ 与输入 X 尺寸相同,但融合了局部区域的上下文信息。

本研究将输出的目标尺寸设置为 $\text{size} = (2, 2)$, 通过 2×2 区域划分提取局部特征,再通过插值恢复空间关系,相对于将整个特征图压缩为单值,可有效表征降水分布的非均匀性。该设计通过分区域对特征的关注,强化了模型对局部语义信息的感知能力。自适应区域池化模块有效提升了细小目标分割精度与边缘连续性,尤其适用于此类具有显著区域差异的降水估计任务。

2) DAD-Conv 模块

提出了一种双注意力密集卷积模块(dual attention dense convolution, DAD-Conv)取代传统 ASPP 中并联的空洞卷积,作为 D-ASPP 中串联的模块,结构如图 5 所示。首先通过 1×1 卷积块调整来自上一层的特征通道数,将通道数降低从而减少后续 3×3 空洞卷积的计算量,同时整合通道信息为后续操作提供更有效的特征表示,再进行群组归一化(GroupNorm)、ReLU 激活完

成特征压缩。随后进入空洞卷积层(Conv2d 3×3 dilation= R),标准空洞卷积能够再保持特征分辨率 and 像素空间不变的前提下增加感受野,来追踪上下文特征,捕捉到不同尺度的降水特征,经二次归一化激活后进入双注意力优化阶段。针对本研究降水估计任务中输入使用的是水平反射率因子 Z_H 和差分反射率 Z_{DR} 双偏振参数叠加后的输入,引入了高效通道注意力模块(efficient channel attention, ECA)学习关键偏振组合通道间的关系,突出对降水预测重要的通道而抑制不重要

的通道,增加偏振参数之间的关联特性,这样可以提高模型对关键降水特征的敏感性。图5中展示了ECA模块的结构,其核心思想是通过一维卷积来捕捉通道之间的依赖关系。模块首先根据通道数自适应地计算一维卷积核大小 k ,核大小的计算公式为:

$$k = \left\lceil \left| \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right|_{\text{odd}} \right\rceil \quad (3)$$

式中: C 是输入特征的通道数; γ 与 b 是超参数。取绝对值向下取整到最近的奇数是为了确保核大小是奇数。




图5 DAD-Conv 模块结构

Fig. 5 DAD-Conv module structure

得到核大小 k 后,ECA模块将一维卷积学到的特征权重应用到输入端,最终得到输出特征。这个过程用如式(4)所示。

$$\text{out} = \text{Conv1D}_k(\text{in}) \quad (4)$$

输出的特征最终输入到空间注意力(spatial attention, SA)模块中,通过融合双路池化特征,用最大池化捕捉强降雨核心区域降水核,平均池化保持弱降水连续区域连续性,进一步提高降水特征捕捉的全面性,最终输出经双重注意力优化的特征图。

1.4 HAD 模块

提出了一种混合注意力解码器模块(hybrid attention decoder, HAD),结构如图6所示。

HAD采用了双分支特征融合的框架,浅层特征由主干网络引出,先经过 1×1 卷积块调整通道维度,再由GroupNorm和ReLU激活后输入SE^[27](squeeze-and-excitation)模块进行通道权重重标定,SE模块由3个核心操作压缩阶段(Squeeze)、激励阶段(Excitation)和重标定(Scale)组成,SE模块结构如图7所示。Squeeze操作采用全局平均池化压缩空间维度,生成通道级统计描述符,捕捉每个特征通道的全局降水响应强度,Squeeze操作定义为:




图6 HAD 模块结构

Fig. 6 HAD module structure

$$z_c = F_{\text{sq}}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (5)$$

式中: z_c 是 z 的第 c 个元素; F_{sq} 为使用的全局平均池化。




图 7 SE 模块结构

Fig. 7 SE module structure

然后 Excitation 操作通过两层全连接层学习通道之间的非线性关系,流程为:

$$s = F_{ex}(z, \mathbf{W}) = \sigma(\mathbf{W}_2 \delta(\mathbf{W}_1 z)) \quad (6)$$

式中: $\mathbf{W}_1$ 为降维权重矩阵; $\mathbf{W}_2$ 为升维权重矩阵; δ 表示 ReLU 激活函数; σ 为 Sigmoid 激活函数生成通道权重 $[0, 1]$; s 是最终的权重。

最后通过 Scale 阶段将权重向量作用于原始特征图 u , 得到最终输出 $\tilde{X}$, 过程为:

$$\tilde{X}_c = F_{scale}(u_c, s_c) = s_c u_c \quad (7)$$

本研究选择在深层特征提取后引入 CBAM^[28] 轻量化注意力模块, 结合了空间和通道的注意力机制模块, 在这两个维度上关注重要降雨信息, CBAM 模块结构如图 8 所示。CBAM 模块输入特征图, 通过通道与空间两个维度对特征图进行推理计算生成注意力权重分布图, 通过逐元素相乘操作对原始特征进行跨维度协同优化, 实现特征表达的自适应精细化重构。




图 8 CBAM 模块结构

Fig. 8 CBAM module structure

通道注意力(CA)首先将卷积得到的特征图分别通过全局最大池化和全局平均池化, 提取出降雨特征信息, 然后将特征输入到两层全连接层中进行通道权重的计算, 经过 sigmoid 函数激活之后, 以对原特征图进行逐元素相乘加权, 加权后的特征图通道可以抑制无效降雨信息以保留特征图重要降雨特征。通道注意力的计算过程为:

$$M_c(F) = \sigma(\text{Conv}(\text{AvgPool}(F)) + \text{Conv}(\text{MaxPool}(F))) \quad (8)$$

空间注意力(SA)将经过通道注意力处理后的特征图作为输入, 经过类似处理先经由全局最大池化和全局平均池化分别得到特征图上的最大值与平均值, 经过特征拼接之后的卷积层处理得到基于降雨的空间分布关键信息, 经过 sigmoid 函数激活后加权处理, 得到优化后的特征图。空间注意力的计算过程为:

$$M_s(F) = \sigma(f(\text{AvgPool}(F); \text{MaxPool}(F))) \quad (9)$$

1.5 损失函数

在降水估计任务中, 深度学习模型常因单一损失函数的局限面临准确度不足与强降雨低估问题。传统均方误差(mean squared error, MSE)对极端降雨值过度敏感, 易受异常回波干扰, 导致强降雨估计偏差; 平均绝对误差(mean absolute error, MAE)虽降低异常值敏感性, 更适合对平均值的估计, 但其单峰优化特性会迫使模型向均值回归, 弱化对暴雨中心等时空特征的捕捉能力。本研究采用 Huber 损失函数, 通过动态切换 MSE 与 MAE 的优化机制, 在预测误差较小时(如普通降水区域)保留 MSE 的平滑梯度以加速收敛; 在误差较大时(如极端降雨像素)切换为 MAE 模式以抑制异常值干扰。这种双模态特性缓解了传统方法对强降雨区域的系统性低估, 从而在保证估计精度的同时, 提升对极端天气事件可靠性。Huber 损失函数的表达式为:

$$L_\delta(y, f(x)) = \begin{cases} \frac{1}{2}(y - f(x))^2, & |y - f(x)| \leq \delta \\ \delta |y - f(x)| - \frac{1}{2}\delta, & |y - f(x)| > \delta \end{cases} \quad (10)$$

式中: δ 为超参数, δ 的数值大小决定了 Huber 损失对 MAE 和 MSE 的侧重性。当 $\delta \sim 0$ 时, Huber 损失更侧重于 MAE; 当 $\delta \sim 1$ 时, 更侧重于 MSE。通常 δ 取 1.0。

2 实验与结果

2.1 NJU-CPOL 数据集介绍

本研究使用南京大学 c 波段双极化气象雷达的数据。数据集包含了 2014—2019 年期间 258 个降雨事件。每个降雨事件有 20~200 帧不等, 其时间分辨率为 6~7 min, 在水平方向上空间分辨率为 1 km。本研究使用雷达中心周围 256 km × 256 km 区域的 3 km 高度等高平面位置显示(constant altitude

plan projection indicator, CAPPI)数据。包含3个参量:1)水平反射率因子 Z_H , 单位为 dBZ; 2)差分反射率 Z_{DR} , 单位为 dB; 3)比差分相移 K_{DP} , 单位为 $^{\circ}/\text{km}$ 。该数据集是由上述雷达数据集集中的参量 K_{DP} 计算得到的近似地面降水, 也包含 34 987 帧, 与雷达数据集时空一一对应。每帧是一张尺寸为 256×256 地面降水数据图, 数据单位为 $\text{mm}/6 \text{ min}$ 。

2.2 实验参数设置

在开始训练之前对网络模型进行主要的参数设置, 本研究使用自适应矩估计 (adaptive moment estimation, Adam) 优化器作为优化器, 初始学习率设置为 0.000 1, 训练周期数为 100, 批量数 Batchsize 设置为 8, 随着训练的深入逐渐降低学习率, 旨在防止网络入局部最优解。为了防止模型的过拟合设置了早停策略, 早停轮次为 20 个训练周期。所有实验均在 CUDA12.7 下使用 python=3.8 的 pytorch 实现, 使用显存为 24 G 的 NVIDIA GeForce RTX 3090 GPU 显卡进行训练。

2.3 评价指标

1) 模型评价指标

(1) 参数量

参数数量 (Params) 用于评估模型的复杂性, 参数越多意味着模型越复杂, 可能会带来更高的准确性, 但也需要更多的计算资源。

(2) 浮点计算量

每秒浮点运算次数 (FLOPs) 是一种测量模型计算能力的指标, 以每秒执行的浮点运算数量为表达方式。它通常用于比较不同模型和算法的计算效率。

2) 实验评价指标

为了定量评估模型在降水强度估计的准确性, 本文使用平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean squared error, RMSE) 以及相关系数 (correlation coefficient, CC) 作为衡量估计结果与真实降雨的误差。同时为了充分说明本文算法的性能, 增加了 3 种分类指标, 分别为命中率 (probability of detection, POD)、虚警率 (false alarm ration, FAR)、临界成功指数 (critical success index, CSI), 用于评估模型检测降雨单元的能力。这些指标的数学公式为:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y'_i - y_i| \quad (11)$$

式中: y'_i 表示模型输出的降水强度; y_i 表示真实降水强度; n 表示样本总数。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (12)$$

式中: y'_i 表示模型输出的降水强度; y_i 表示真实降水强度; n 表示样本总数。

$$\text{CC} = \frac{\sum_{i=1}^n (y'_i - \bar{y}') (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (y'_i - \bar{y}')^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (13)$$

式中: y'_i 表示模型输出的降水强度; y_i 表示真实降水强度; n 表示样本总数。 $\bar{y}$ 和 $\bar{y}'$ 分别表示标签和输出的平均值。

$$\text{POD} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (14)$$

$$\text{FAR} = \frac{\text{FP}}{\text{FP} + \text{TP}} \quad (15)$$

$$\text{CSI} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (16)$$

式中: TP 为真阳性事件的数量 (正确分类为降雨的像素数); FN 为假阴性事件的数量 (被错误分类为无降雨的像素数); FP 为假阳性事件的数量 (被错误分类为降雨的像素数); TN 为真阴性 (正确分类为无降雨的像素数)。

MAE 评估估计降水与真实降水的整体差异, 值越接近 0 表示差异越小; RMSE 衡量预测值与真实值的离散程度, 其值越小表明数据分布越集中; CC 反映 QPE 雨量与真实降水的线性相关性, 越接近 1 表示相关性越强; POD 评估降水事件被正确识别的比例, 值越大表示命中率越高; FAR 衡量非降水事件被误判为降水的概率, 值越小表示虚警越少; CSI 综合评估降水检测的整体性能, 值越大表明预测效果越优。

2.4 网络模型改进实验

本文算法是在原模型 DeepLabV3+ 的架构思路, 优化了其主干网络与 ASPP 模块, 在解码端引入了注意力机制经过卷积处理进一步融合了浅层特征与深层特征, 使网络对图像中的浅层特征和深层语义信息进行重点的关注。本节中, 为了验证不同模块改动的有效性, 在 NJU-CPOL 数据集上对不同主干网络、ASPP 模块和解码端中不同的注意力机制等进行对比实验, 来证明本研究提出网络的识别准确性。

1) 不同骨干网络的对比实验

本研究是采用语义分割的思路进行研究降水任务, 在语义分割模型中, 特征提取模块的效果优劣对最终的结果有着关键影响, 因此本研究使用不同的特征提取主干网络进行对照实验。为了评价不同的骨干网络对降水任务的适配性, 实验基于改进后的网络模型通过更换不同的主干网络, 在 NJU-CPOL 数据集上进行了 5 组对比实验, 使用降水任务的指标和模型的参数量作为衡量标准, 对比实验的结果如表 2 所示。

由表 2 可知, 使用 Mobilenetv2 作为主干网络时, CC 达到了 0.661 0, 并且参数数量和计算量仅为 4.11 M 和 8.29 G。虽然实验 1 中 ResNet101 网络 MAE 和 RMSE 指标占优, 但是参数量也是对照组中最大的, 同时 Mobilenetv2 网络的 MAE 是非常接近表现最优的 ResNet101 网络, 表明其预测值与真实降水量同样有着较小的偏差, 但是参数量远远大于 Mobilenetv2。Mobilenetv2 的 CC 高于其他所有网络, 证明其对捕捉降水与雷达回波之间复杂非线性关系有较强的能力。综合考

表 2 基于不同主干网络的性能对比

Table 2 Performance comparison based on different backbone networks

方法	MAE	RMSE	CC	POD	FAR	CSI	Params/M	FLOPs/G
ResNet101	0.518 8	4.128 7	0.655 9	0.886 1	0.617 3	0.365 4	46.35	190.27
Xception	0.570 6	4.417 9	0.618 3	0.878 2	0.649 7	0.332 4	25.81	13.49
EfficientNetv2	0.533 8	4.171 2	0.650 3	0.881 7	0.610 6	0.368 9	21.91	25.13
ConvNeXt	0.646 5	4.979 6	0.532 5	0.899 3	0.665 9	0.320 9	29.70	13.30
Mobilenetv2	0.519 7	4.174 4	0.661 0	0.897 4	0.602 6	0.378 9	4.11	8.29

虑本研究模型选择 Mobilenetv2 作为主干网络,在保持最小参数数量的情况下有着不俗的精度,展示了在雷达降雨估计任务上极佳的精度与效率平衡能力。这对于雷达降雨估计系统的实时性要求和在雷达边缘计算设备上的部署具有极其重要的意义。

2) ASPP 改进实验

本文引入 DADConv 和 ARP 重构了 ASPP 模块并且

提出 D-ASPP 模块,表中 GAP 是原 ASPP 中的全局平均池化模块,单独使用相当于原 DeepLabV3+网络中的原始 ASPP,本实验将其作为对照组。为了选出 ASPP 模块中的最佳组合,在 Mobilenetv2 主干网络的基础上进行了 4 组对比实验,以降水任务的指标来验证组合有效性。实验对比结果数据如表 3 所示,图 9 可视化了不同方案对降水估计结果的影响。

表 3 ASPP 改进实验对比结果

Table 3 Comparison results of ASPP improvement experiment

组别	GAP	ARP	DADConv	MAE	RMSE	CC	POD	FAR	CSI
1	✓			0.546 8	4.225 6	0.632 8	0.873 5	0.621 2	0.358 7
2		✓		0.526 8	4.119 2	0.649 6	0.881 8	0.626 1	0.355 9
3	✓		✓	0.534 0	4.122 2	0.647 2	0.878 5	0.618 0	0.362 5
4		✓	✓	0.520 4	4.155 4	0.654 3	0.885 5	0.608 5	0.373 7




图 9 ASPP 改进实验可视化结果

Fig. 9 Visualization result of ASPP improvement experiment

通过表 3 结果可知,当模型不加入 ARP 和 DADConv 模块时,也就是网络中使用原始的 ASPP 模块时,虽然对降水区域的识别有一定程度的准确性,但是图 9 中区域显示对部分区域的降水量存在漏判的情况,总体精度较低,

这在降水估计的实际任务中可能会产生一定影响。将 GAP 模块替换为 ARP 模块后,关键指标全面优于基准组,其中 MAE 显著降低 3.66%,CC 提升 2.66%,证明 ARP 通过自适应感受野优化,有效增强降水空间分布的建模能

力。在保留 GAP 基础上添加 DADConv 后降水事件识别指标 CSI 提升 1.06%,FAR 降低 0.52%,表明其动态卷积机制强化了局部降水特征的提取精度。由此证明 ARP 与 DADConv 均为有效改进单元,单独使用可提升模型性能。当融合 ARP+DADConv 形成 D-ASPP 时,所有指标提升更为明显,说明两个模块联合使用对整体模型性能提升更为显著。除此之外图 9 的可视化结果可以看出,在加入 ARP 与 DADConv 模块之后减少了降水区域的漏识别现象,对不同强度的降水量的识别更加精细。故本文选择组别 4 的组合方式构建出 D-ASPP 模块应用到网络中。

3) HAD 中不同注意力机制的对比实验

注意力机制是通过动态计算特征图中不同位置或通道

的权重值,引导网络聚焦于对当前任务更重要的信息,同时抑制或忽略那些不相关的、无用的特征信息。这种机制能够有效地过滤掉冗余或干扰信息,避免这些无用特征对模型的拟合结果产生负面影响,从而提升模型的判别能力和预测精度。本文在提出的 HAD 解码器中对多种注意力机制(包括 SE、CBAM、ECA)及其组合方式进行了对比分析,其中表格中单个勾选的是浅层特征输入端和深层特征输入端都使用了这个注意力机制。为评估不同注意力机制组合对降水估计任务的有效性,基于改进后的 DeepLabV3+网络设置了多组实验,引入了 6 种不同的注意力机制的组合方式进行对比,并以关键评价指标 MAE、RMSE、CC、POD、FAR 和 CSI 作为验证依据。对比结果如表 4 所示。

表 4 不同注意力机制组合的对比结果

Table 4 Comparison results of different combinations of attention mechanisms

组别	SE	CBAM	ECA	MAE	RMSE	CC	POD	FAR	CSI
1	✓			0.546 2	4.177 8	0.638 2	0.889 5	0.636 0	0.348 8
2		✓		0.528 6	4.175 9	0.647 0	0.886 8	0.614 9	0.367 8
3			✓	0.542 3	4.206 1	0.634 4	0.872 5	0.619 9	0.359 9
4		✓	✓	0.538 6	4.225 0	0.644 9	0.892 4	0.629 4	0.355 1
5	✓		✓	0.526 3	4.208 0	0.646 6	0.894 7	0.613 7	0.370 1
6	✓	✓		0.519 7	4.174 4	0.661 0	0.897 4	0.595 2	0.378 9

由表 4 可知,仅应用组别 1 中 SE 注意力组合时,性能表现相对基础。仅应用组别 2 中 CBAM 注意力组合时,各项指标显著优于 SE,取得了当前最优的单注意力组合的结果,尤其 MAE 降低了约 3.22%,CSI 提升了约 5.45%。仅应用组别 3 中 ECA 注意力组合时,表现介于 SE 和 CBAM 之间。当在组别 4 中采用 CBAM+ECA 组合效果未超越单一组别 2 中的 CBAM 注意力,多个指标现反而不如单独使用 CBAM,表明在该任务中,ECA 与 CBAM 组合未产生协同增益。组别 5 中 SE+ECA 虽部分指标优于单注意力,但显著弱于 SE+CBAM 组合。组别 6 中 SE+CBAM 注意力机制的组合 SE 与 CBAM 的组合产生强协同效应,相比单 CBAM 以及其他组合(如组别 4:CBAM+ECA)表现出更强性能的提升。它显著降低了关键预测误差 MAE 和 RMSE,提高了预测与观测的空间相关性 CC,并最显著地提升了降水事件的识别能力(高 POD、低 FAR、高 CSI)。这种组合有效地融合了 SE 在通道维度上的特征重加权能力与 CBAM 在空间和通道维度上的联合注意力能力,更好地捕获了降水特征在不同层次上的关键信息。综合分析,本研究选择了性能更强大的组别 6,帮助模型更好的完成降水任务。

2.5 消融实验

本节中,针对提出的 D-ASPP 模块和 HAD 解码器与改进后的骨干网络,在统一实验条件下系统开展网络消融研究,以验证各模块对降水估计任务的有效性。在 NJU-

CPOL 数据集上开展对网络模型模块的消融实验,设置 5 组递进式对比方案:改进前的 DeepLabV3+模型作为 Baseline、替换主干网络为 Mobilenetv2 的方案 Baseline+Mobilenetv2、增加 D-ASPP 模块的改进方案 Baseline+D-ASPP、增加 HAD 解码器的改进方案 Baseline+HAD,以及同时融合改进后的主干网络和 D-ASPP 与 HAD 模块的完整方案 DPCR-Net。所有方案均基于相同的训练策略,采用 MAE、RMSE、CC、POD、FAR 和 CSI 等 6 项关键指标作为量化评估依据。消融实验结果详见表 5,而图 10 展示了消融实验的可视化结果。由表 5 可知,当模型仅仅使用 Baseline 时虽然对降水区域保持着一定精度的识别效果,但是由图 10 可知也存在着识别区域模糊,部分降水区域漏识别的问题,这在实际生产生活的应用中会产生重大影响。将原 DeepLabV3+模型的主干网络替换为轻量化的 Mobilenetv2 网络时,旨在降低模型复杂度的同时保持特征提取能力。如表 5 所示,与 Baseline 相比,该方案的 MAE 降低约 1.57%,RMSE 降低约 3.83%,CC 提升约 4.87%,表明误差指标有所改善,且预测与真实降水之间的线性相关性增强。当加入 D-ASPP 模块后关键性能得到了全面提升,MAE 降低了约 6.32%,RMSE 降低了约 5.43%,CC 从 0.603 4 提升至 0.654 3,增幅约 8.44%,证明 D-ASPP 通过多尺度特征融合有效提升空间建模能力。在引入 HAD 模块后同样带来性能增益,POD 达到 0.888 8,较 Baseline 增幅约 2.45%,表明 HAD 的解码结构优化可

强化降水事件识别能力。当同时融合改进后的主干网络、D-ASPP 与 HAD 模块后在 5 项核心指标上达到了最优水平,MAE 降至全表最低值 0.519 7,较 Baseline 降低了约 6.45%,RMSE 较 Baseline 降低了约 5.00%,CSI 较基线提升 0.29%为全表最高值,CC 与 POD 均为表内最高值。对比数据表明,D-ASPP 更擅长降低全局误差,对 MAE 与 RMSE 优化贡献度最高,而 HAD 则侧重于优化事件识别

指标,而且两者结合之后产生了正向的协同效应,D-ASPP 模块与 HAD 解码器均为有效的独立改进单元,但二者在特征提取与解码重建阶段的功能互补性,使其融合后能最大化网络性能。因此,本文选定 DPCR-Net 作为最终网络架构。图 10 可视化结果进一步表明该方案对降水区域的识别更加完整,进一步优化了降雨区域被漏识别与识别精度差的问题,使得弱降水区域边界更清晰。

表 5 消融实验结果
Table 5 Ablation experiment results

方法	MAE	RMSE	CC	POD	FAR	CSI
Baseline	0.555 5	4.393 8	0.603 4	0.867 5	0.595 2	0.377 8
Baseline+Mobilenetv2	0.546 8	4.225 6	0.632 8	0.873 5	0.621 2	0.358 7
Baseline+D-ASPP	0.520 4	4.155 4	0.654 3	0.885 5	0.608 9	0.373 7
Baseline+HAD	0.531 7	4.158 5	0.645 4	0.888 8	0.612 9	0.368 9
DPCR-Net	0.519 7	4.174 4	0.661 0	0.897 4	0.602 6	0.378 9




图 10 消融实验结果可视化
Fig. 10 Visualization of ablation experiment results

2.6 与不同模型的对比实验

本研究将提出的网络与 SmaAt-UNet^[15]、Rainformer^[16]、GLnet^[18]、SwinNowcast^[20] 及 PERSIANN-CNN^[29] 5 个流行的降水模型在 NJU-CPOL 数据集上进行对比实验。并且选取了当前先进的 DeepLabV3+ 网络改进模型 DeepLabV3+SE-ASPP^[23]、DeepLabV3+ECANet^[24] 和 DeepLabV3+CBAM^[25] 与基线模型和本文算法进行性能对比。不同 DeepLabV3+ 网络改进方案之间的性能对比结果数据如表 6 所示;不同降水模型的对比实验结果数据如表 7 所示;不同降水模型的对比实验结果可视化图如图 11 所示。

本文算法是在 DeepLabV3+ 模型架构基础上进行改

进的,表 6 详细对比了不同 DeepLabV3+ 改进方案和基线模型与本文算法的性能差异,已验证本文工作的优势和先进性。这些模型分别从注意力机制、模块结构轻量化等角度对原 DeepLabV3+ 进行优化,其设计思想与本文工作具有可比性,但侧重方向各异。DeepLabV3+ECANet 通过引入 ECA 模块,自适应学习通道间依赖关系,避免 SE 模块中降维操作带来的特征损失,同时结合多尺度特征融合策略增强模型对降水空间异质性的捕捉能力。其 MAE 和 RMSE 较原 DeepLabV3+ 均有所降低,CC 提升至 0.625 7,表明多尺度注意力机制对降水估计精度有正向增益。然而 CSI 指标 0.376 7 略低于基线,说明其在极端降水事件识别上存在局限。DeepLabV3+SE-ASPP 通过将 SE 模块

表 6 不同 DeepLabV3+网络改进方案之间的性能对比

Table 6 Performance comparison among different DeepLabV3+ network improvement schemes

模型	MAE	RMSE	CC	POD	FAR	CSI	Params/M	FLOPs/G
DeepLabV3+	0.555 5	4.393 8	0.603 4	0.867 5	0.595 2	0.377 8	37.04	28.12
DeepLabV3+ECANet	0.542 9	4.361 3	0.625 7	0.875 4	0.596 2	0.376 7	5.41	13.67
DeepLabV3+SEASPP	0.531 0	4.232 3	0.647 2	0.873 4	0.602 9	0.378 3	4.15	8.35
DeepLabV3+CBAM	0.523 6	4.297 1	0.653 9	0.882 5	0.603 1	0.374 8	6.87	9.57
本文算法	0.519 7	4.174 4	0.661 0	0.897 4	0.602 6	0.378 9	4.11	8.29

表 7 不同降水模型的对比实验结果

Table 7 Comparative experimental results of different precipitation models

模型	MAE	RMSE	CC	POD	FAR	CSI	Params/M	FLOPs/G
PERSIANN-CNN	0.575 7	4.292 9	0.622 0	0.823 1	0.602 6	0.297 7	0.81	39.49
SmaAt-UNet	0.560 5	4.303 1	0.594 7	0.809 0	0.615 7	0.367 5	5.16	9.77
Rainformer	0.548 9	4.256 0	0.601 2	0.852 6	0.612 3	0.370 4	171.72	59.31
GLnet	0.543 5	4.234 1	0.624 7	0.873 3	0.610 8	0.368 7	42.15	58.71
SwinNowcast	0.521 2	4.150 2	0.656 0	0.884 1	0.591 7	0.369 0	98.25	50.26
本文算法	0.519 7	4.174 4	0.661 0	0.897 4	0.602 6	0.378 9	4.11	8.29




图 11 不同降水模型的对比实验结果的可视化

Fig. 11 Visualization of comparative experimental results of different precipitation models

嵌入 ASPP 结构,增强通道特征选择能力。SE-ASPP 利用全局平均池化生成通道权重,强化对降水关键通道的聚焦,从而提升边界细节保持能力。该模型在误差指标上表现优异,MAE 和 RMSE 显著优于原模型,CC 达到 0.647 2,

且参数量 4.15 M 与本文算法接近。但其 POD 和 CSI 提升有限,反映 SE 模块对空间细节的增强仍不足以完全解决弱降水区域的连续性漏估问题。DeepLabV3+CBAM 采用深度可分离卷积替换标准卷积,并引入 CBAM 模块,

协同优化通道与空间维度特征。CBAM 通过双路池化策略同时捕捉降水核心区与边缘信息,在参数量适度增加的前提下,CC 提升至 0.653 9,POD 为对比模型中最高。但其 RMSE 反而高于 SE-ASPP 方案,且 FAR 未见改善,说明空间注意力对噪声的抑制能力在复杂降水场景中仍不稳定。本文算法 DPCR-Net 在关键误差指标上显著优于原 DeepLabV3+模型,其中 MAE 降低 6.45%,RMSE 降低 5.00%,CC 提升 9.55%,证明其通过轻量化设计和多尺度融合机制有效提升了降水估计的准确性,证明引入改进模块之后整体模型产生了正向增益。相较于其他改进方案,DPCR-Net 在 CC 和 CSI 指标上均达到最高值,且参数量 4.11 M 仅为原 DeepLabV3+模型的 11.1%,计算量 8.29 G 降低 70.5%,体现了精度与效率的均衡优化。

不同降水模型在数据集上的对比实验结果如表 7 所示。本文提出的 DPCR-Net 算法在多项关键指标上展现出全面优势。在精度与误差指标方面,DPCR-Net 的 MAE 为所有对比模型中的最优值,较表现次优的 SwinNowcast 降低 0.29%,较传统降水模型 PERSIANN-CNN 显著降低 9.7%。CC 指标达到 0.661 0,明显优于其他对比模型,如 SmaAt-UNet 和 Rainformer,表明其预测结果与真实降水分布具有更强的空间相关性。虽然 RMSE 略高于 SwinNowcast,但相较于 PERSIANN-CNN 和 SmaAt-UNet 仍具有明显优势。在降水事件识别能力方面,DPCR-Net 的 POD 为所有模型最高,较 GLnet 提升 2.8%,表明其对降水事件的检测能力最强。FAR 处于合理区间,与 PERSIANN-CNN 相当,但显著优于 SmaAt-UNet。特别值得注意的是,CSI 指标明显高于其他模型,如 Rainformer 和 GLnet,证明模型在减少漏报与平衡误报上取得更优权衡。本文模型通过更换主干网络,模型的效率得到显著的优化,参数量 4.11 M 远低于 Rainformer 和 SwinNowcast 等大型模型,同时浮点计算量 8.29 G 显著优于 PERSIANN-CNN 和 Rainformer。展现了算法在保持高精度的前提下,大幅压缩了计算资源。

为了进一步验证本文算法在复杂降水场景下的鲁棒性,对测试集典型样本进行了预测可视化。图 11 展示了本文算法和 5 种流行降水模型在强降雨核心区域和弱降水连续区域的预测对比结果。图 11 中可以看出除了本文算法之外,其他网络在对降水区域的识别上均表现出不同程度的对核心强降雨的识别模糊或误识别和对弱降水连续区域的不识别的问题。这表明其他算法对区域降水特征的特征学习程度不高,对局部特征还有全局特征的上下文学习能力不足。在强降水核心区域,DPCR-Net 表现出最佳的形态保持能力。而 PERSIANN-CNN 和 SmaAt-UNet 等模型则出现了雨团融合膨胀和边界模糊问题,例如在图 11 中第 2 行的样本中,PERSIANN-CNN 与 Rainformer 出现了强降雨区域识别的细节丢失,在第 5 行样本中 SmaAt-UNet 等模型对强降雨区域产生了降水强

度高估的问题。本文算法通过 D-ASPP 模块的级联空洞卷积结构,有效捕捉了不同尺度的降水特征,精准保持了强降雨核的独立性和完整性。在弱降水连续区域,DPCR-Net 凭借 HAD 解码器中的混合注意力机制,显著提升了对薄雾状降水结构的识别能力。相比之下,Rainformer 和 GLnet 等模型在弱降水区域连续性与识别准确性不足,例如在第 1 行样本中 PERSIANN-CNN、SmaAt-UNet 和 GLnet 等模型对弱降水区域的预测产生了低估,一部分降水云团没有识别出来。在第 4 行的样本中前 3 个模型对弱降水区域的识别精度较差,出现了降水区域丢失与降水云团糊在一块的情况。而本文算法能够有效保持降水的空间连续性。DPCR-Net 在处理复杂降水系统时展现出更强的鲁棒性。面对降水核的形态变化和强度梯度,算法能够准确识别不同强度的降水区域。这种性能优势主要源于算法的 3 个核心设计:首先,轻量化主干网络在保证特征提取能力的同时大幅降低计算复杂度;其次,D-ASPP 模块通过自适应区域池化和级联空洞卷积增强了多尺度特征提取能力;最后,HAD 解码器通过双注意力机制有效融合深层次特征,提升了对降水细节的保持能力。

综上所述,可视化结果和量化指标共同表明本文算法相比其他流行模型,本文模型通过 D-ASPP 的多尺度特征提取解决了强降水核心区形态失真问题,借助 HAD 解码器的注意力机制修复了弱降水区识别精度差的问题,更好地实现精度和效率上的平衡性。

3 结 论

本研究提出的基于 DeepLabV3+网络改进的轻量级多尺度融合算法 DPCR-Net,通过 Mobilenetv2 轻量化主干生成多尺度降水特征,在参数量降至 4.11 M 的同时保留细节,设计了 D-ASPP 模块通过级联膨胀卷积与自适应区域池化,有效解决远距离弱降水特征稀释问题,最后采用双路注意力解码器分阶段聚合特征,修复降水边界连续性不足的问题。在 NJU-CPOL 数据集上的实验表明:DPCR-Net 以 MAE=0.519 7、CC=0.661 0、CSI=0.378 9 领先其他主流降水对比模型如 PERSIANN-CNN 和 Rainformer,且计算量仅为 8.29 G,参数量为改进前的 DeepLabV3+模型的 11.1%,同时兼顾了降水估计的精度和计算效率。此外进行了一系列消融实验,验证了 D-ASPP 加 HAD 模块应用的有效性,加入后与基线模型相比 MAE 降低 6.45%,CSI 提升 0.29%。通过 ASPP 改进实验可以看出改进后的模块较传统 ASPP 相比 MAE 降低 4.83%,CSI 提升 4.18%。注意力机制组合 SE+CBAM 较单注意力机制提升明显,验证了此注意力组合的合理性。实验结果表明本文算法在强降雨核心区域和弱降水连续区域的降水估计有着更优异的表现并且有效缓解了存在的模型参数大和计算冗余等问题。

参考文献

- [1] 包广斌, 罗瞳, 彭璐, 等. 3DuA-Net: 融合 3D 卷积和注意力的雷达回波外推预报[J]. 电子测量技术, 2024, 47(15): 153-160.
BAO G B, LUO T, PENG L, et al. 3DuA-Net: Fusion of 3D convolution and attention for radar echo extrapolation forecasting[J]. Electronic Measurement Technology, 2024, 47(15): 153-160.
- [2] 方巍, 庞林, 王楠, 等. 人工智能在短临降水预报中应用研究综述[J]. 南京信息工程大学学报(自然科学版), 2020, 12(4): 406-420.
FANG W, PANG L, WANG N, et al. Survey on the application of artificial intelligence in precipitation nowcasting [J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2020, 12(4): 406-420.
- [3] KOU L L, TANG J Q, WANG ZH X, et al. An adaptive rainfall estimation algorithm for dual-polarization radar[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [4] 肖前循, 许海玉, 张宏伟, 等. 星载微波云、降水雷达技术现状与展望[J]. 遥测遥控, 2024, 45(6): 11-20.
XIAO Q X, XU H Y, ZHANG H W, et al. Development status and prospect of spaceborne microwave cloud and precipitation radar technology[J]. Journal of Telemetry, Tracking and Command, 2024, 45(6): 11-20.
- [5] YOU C H, SUH S H, JUNG W, et al. Dual-polarization radar-based quantitative precipitation estimation of mountain terrain using multi-disdrometer data[J]. Remote Sensing, 2022, 14(10): 2290.
- [6] BORGA M, MARRA F, GABELLA M. Rainfall estimation by weather radar[M]. Rainfall. Amsterdam: Elsevier, 2022: 109-134.
- [7] 郭建茂, 吴登国, 韩金龙, 等. 基于雷达和遥感卫星的新疆区域降水反演[J]. 干旱区研究, 2025, 42(6): 957-969.
GUO J M, WU D G, HAN J L, et al. Precipitation retrieval in Xinjiang region based on radar and remote sensing satellite [J]. Arid Zone Research, 2025, 42(6): 957-969.
- [8] 蔡康龙, 胡志群, 谭浩波, 等. 利用卷积神经网络开展偏振雷达定量降水估测研究[J]. 热带气象学报, 2024, 40(1): 64-74.
CAI K L, HU ZH Q, TAN H B, et al. Research on quantitative precipitation estimation by polarized radar using CNN [J]. Journal of Tropical Meteorology, 2024, 40(1): 64-74.
- [9] 郑祥明, 秦华旺, 陈浩然. 基于时空分离的雷达降水图像时空降尺度研究[J]. 电子测量技术, 2023, 46(21): 159-167.
ZHENG X M, QIN H W, CHEN H R. Spatio-temporal downscaling of radar precipitation images based on spatio-temporal separation [J]. Electronic Measurement Technology, 2023, 46(21): 159-167.
- [10] 马志峰, 张浩, 刘劼. 基于深度学习的短临降水预报综述[J]. 计算机工程与科学, 2023, 45(10): 1731.
MA ZH F, ZHANG H, LIU J. A survey of precipitation nowcasting based on deep learning [J]. Computer Engineering & Science, 2023, 45(10): 1731.
- [11] ZHAO K, HUANG H, WANG M J, et al. Recent progress in dual-polarization radar research and applications in China [J]. Advances in Atmospheric Sciences, 2019, 36(9): 961-974.
- [12] 黄兆楚, 印佳楠, 杨洋, 等. 石家庄 S 波段和 X 波段双偏振雷达定量降水估测应用研究[J]. 高原气象, 2025, 44(1): 253-264.
HUANG ZH CH, YIN J N, YANG Y, et al. Application of S-band and X-band dual polarization radar for quantitative precipitation estimation in Shijiazhuang[J]. Plateau Meteorology, 2025, 44(1): 253-264.
- [13] LI W Y, CHEN H N, HAN L. Polarimetric radar quantitative precipitation estimation using deep convolutional neural networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-11.
- [14] BOUGET V, BÉRÉZIAT D, BRAJARD J, et al. Fusion of rain radar images and wind forecasts in a deep learning model applied to rain nowcasting [J]. Remote Sensing, 2021, 13(2): 246.
- [15] TREBING K, STANCZYK T, MEHRKKANOON S. SmaAt-UNet: Precipitation nowcasting using a small attention-UNet architecture [J]. Pattern Recognition Letters, 2021, 145: 178-186.
- [16] BAI C, SUN F, ZHANG J L, et al. Rainformer: Features extraction balanced network for radar-based precipitation nowcasting [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [17] SHEN X J, MENG K Y, ZHANG L, et al. A method of radar echo extrapolation based on dilated convolution and attention convolution [J]. Scientific Reports, 2022, 12(1): 10572.
- [18] 尹传豪, 秦华旺, 戴跃伟, 等. GLnet: 融合全局和局部信息的短临降雨预报网络[J]. 电子测量技术, 2023, 46(17): 102-108.
YIN CH H, QIN H W, DAI Y W, et al. GLnet:

- Precipitation nowcasting network combining global and local information[J]. Electronic Measurement Technology, 2023, 46(17): 102-108.
- [19] LI ZH, LU ZH Y, LI Y ZH, et al. SwinNowcast: A swin transformer-based model for radar-based precipitation nowcasting[J]. Remote Sensing, 2025, 17(9): 1550.
- [20] 刘子奇, 李丹勋, 朱德军, 等. 基于单目视觉的无水尺水位测量方法[J]. 仪器仪表学报, 2024, 45(7): 27-37.
- LIU Z Q, LI D X, ZHU D J, et al. Monocular vision-based gaugeless water level measurement[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 27-37.
- [21] 靖永志, 倪胜, 贾兴科, 等. 基于列向语义分割的悬浮间隙视觉检测方法研究[J]. 仪器仪表学报, 2024, 45(9): 67-76.
- JING Y ZH, NI SH, JIA X K, et al. Research on the visual detection method of levitation gap based on column-oriented semantic segmentation[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 67-76.
- [22] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]. European Conference on Computer Vision(ECCV), 2018: 801-818.
- [23] 王银, 孙海顺, 谢刚, 等. 基于 DeepLabV3+改进的光伏板语义分割模型研究[J]. 电子测量技术, 2024, 47(22): 136-143.
- WANG Y, SUN H SH, XIE G, et al. Research on the improved semantic segmentation model of photovoltaic panels based on DeepLabV3 + [J]. Electronic Measurement Technology, 2024, 47(22): 136-143.
- [24] 李明, 魏利胜. 基于改进 Deeplabv3+的磁瓦表面缺陷分割[J]. 电子测量与仪器学报, 2025, 39(1): 50-56.
- LI M, WEI L SH. Magnetic tile surface defect segmentation based on improved Deeplabv3 + [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(1): 50-56.
- [25] 惠飞, 王悦华, 穆柯楠, 等. 基于改进 DeepLabV3+的轻量化语义分割网络[J]. 计算机工程与设计, 2025, 46(7): 1990-1997.
- HUI F, WANG Y H, MU K N, et al. Lightweight semantic segmentation network based on improved DeepLabV3+[J]. Computer Engineering and Design, 2025, 46(7): 1990-1997.
- [26] SANDLER M, HOWARD A, ZHU M L, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [27] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [28] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision(ECCV), 2018: 3-19.
- [29] SADEGHI M, NGUYEN P, HSU K, et al. PERSIANN-CNN: Application of convolutional neural networks and geographical information for improving the near real-time precipitation estimation products [C]. American Meteorological Society Meeting Abstracts, 2021, 101: 1.

作者简介

周文博, 硕士研究生, 主要研究方向为雷达降水估计及深度学习相关理论等。

E-mail: 202312220014@nuist.edu.cn

张永宏(通信作者), 博士, 教授, 主要研究方向为人工智能、遥感大数据分析与深度学习。

E-mail: zyh@nuist.edu.cn

王俊飞, 博士, 主要研究方向为雷达回波外推、雷达降水估计以及深度学习相关理论等。

E-mail: jf_wang@nuist.edu.cn

杨天笑, 硕士研究生, 主要研究方向为雷达降水估计以及深度学习相关理论等。

E-mail: 202212490009@nuist.edu.cn