

周聪, 张成宏, 董元昌, 等, 2026. 基于CBAM U-Net模型的成都X波段相控阵雷达降水估计[J]. 高原气象, 45(3): 691–704. ZHOU Cong, ZHANG Chenghong, DONG Yuanchang, et al, 2026. CBAM U-Net Model-Based Precipitation Estimation for Chengdu X-band Phased Array Radar [J]. Plateau Meteorology, 45(3): 691–704. DOI: 10.7522/j.issn.1000-0534.2025.00093. CSTR: 32265.14.gyqx.CN62-1061/P.2025.00093.

基于CBAM U-Net模型的成都X波段 相控阵雷达降水估计

周 聪¹, 张成宏², 董元昌², 张 涛¹

(1. 成都市气象台, 四川 成都 611134;

2. 中国气象局成都高原气象研究所, 四川 成都 610218)

摘要: 强降水事件的频发对城市防灾减灾提出了严峻挑战, 精细化高时空分辨率定量降水估计(Quantitative Precipitation Estimation, QPE)对强降水过程的监测有重要意义, 具备高时空分辨率探测资料的X波段相控阵雷达为开展高精度QPE的研究提供了有力的数据支撑。由于传统雷达QPE方法缺乏非线性映射能力和动态自适应学习机制等局限性, 本研究提出了一种基于CBAM U-Net模型的分钟雨量QPE方法。该模型通过嵌入通道-空间注意力CBAM模块增强对关键降水区域及特征通道的学习能力, 并在模型数据样本中添加时间维以优化雷达与地面雨量计数据的时间匹配。利用2023–2024年7–9月成都平原地区四部X波段相控阵雷达基数据, 构建模型训练集和测试集, 并结合学习率预热与余弦退火策略优化训练过程, 不仅加快收敛速度, 且鲁棒性更强。为评估模型效果, 采用回归评估(CC 、 R_{MSE} 、 R_{MAE} 、 R_{MB})与分类评估(POD、FAR、CSI)指标对CBAM U-Net、Attention U-Net、U-Net与两个 $R(Z_H)$ 关系式的降水估计结果进行对比分析。结果表明, 在整体的误差指标和稳定性方面, 深度学习模型显著优于传统 $Z-R$ 关系。模型中, CBAM U-Net表现最佳($CC=0.665$, $R_{MSE}=0.331\text{ mm}\cdot\text{min}^{-1}$, $R_{MAE}=44.651\%$, $R_{MB}=7.324\%$), Attention U-Net次之, 而U-Net则存在明显的低估现象。在多阈值分类评估中, CBAM U-Net对短时强降水阈值($0.34\text{ mm}\cdot\text{min}^{-1}$, 对应小时雨强 $20\text{ mm}\cdot\text{h}^{-1}$)和橙色暴雨预警信号阈值($0.67\text{ mm}\cdot\text{min}^{-1}$, 对应小时雨强 $40\text{ mm}\cdot\text{h}^{-1}$)的临界成功指数(CSI)分别达0.655和0.485, 较Attention U-Net(0.609和0.408)与U-Net(0.537和0.160)显著提升。个例分析进一步验证了CBAM U-Net具备更强的时序变化特征追踪能力: 在2024年9月10日“脉冲式”降水过程中, CBAM U-Net精准定位降水曲线波峰、波谷的位置, 良好地刻画了降水时序变化的特征, 较U-Net和Attention U-Net表现更优; 在2024年9月29日稳定性降水过程中, CBAM U-Net准确勾勒出降水变化的整体趋势, 但对分钟雨量 $0.1\sim 0.2\text{ mm}\cdot\text{min}^{-1}$ 微小波动的敏感性不足。CBAM模块通过双重注意力机制, 有效提升了模型对强降水时序变化特征的捕捉能力, 但受限于深度学习模型系统性平滑的特性, 对分钟雨量 $\geq 1.17\text{ mm}\cdot\text{min}^{-1}$ 的极端强降水仍存在明显低估。

关键词: 雷达QPE; X波段相控阵雷达; 短时强降水; 深度学习; CBAM U-Net模型

文章编号: 1000-0534(2026)03-0691-14 **中图分类号:** P413 **文献标识码:** A

DOI: 10.7522/j.issn.1000-0534.2025.00093

CSTR: 32265.14.gyqx.CN62-1061/P.2025.00093

收稿日期: 2025-03-23; 定稿日期: 2025-08-20

资助项目: 川西南(雅安)暴雨实验室科技发展基金项目(CXNBYSYSZD202404); 高原与盆地暴雨旱涝灾害四川省重点实验室科技发展基金项目(SCQXKJYJXMS202314); 高原与盆地暴雨旱涝灾害四川省重点实验室科技发展基金项目(SC-QXKJQN202112); 四川省科技计划重点研发项目(2024YFFK0408); 中国气象局创新发展专项(CXFZ2024J013)

作者简介: 周聪(1993—), 男, 江苏扬州人, 硕士研究生, 主要从事雷达数据应用和人工智能气象应用研究. E-mail: 2420997386@qq.com

通信作者: 张涛(1988—), 男, 四川营山人, 高级工程师, 主要从事灾害性天气预报和天气雷达资料应用研究. E-mail: radar_zt@163.com

© Editorial Department of Plateau Meteorology (CC BY-NC-ND)

1 引言

在全球变暖的背景下,极端强降水事件的频发催生了高时空分辨率定量降水估计(Quantitative Precipitation Estimation, QPE)的迫切需求。由于中小尺度对流系统具有生消变化快、水平尺度小的特点,传统的地面雨量计观测难以满足其精细化监测的需求。而天气雷达凭借高时空连续观测能力,成为捕捉此类天气系统的核心手段(黄兴友等, 2024)。但传统S波段雷达受限于6 min更新频次和250 m空间分辨率,难以完整刻画中小尺度对流系统的时空演变过程(熊德方等, 2023)。相较而言,X波段相控阵雷达通过电子扫描实现分钟级数据更新和10 m级的空间分辨率,显著增强了强降水微物理特征的捕捉能力(张哲等, 2022)。庄潇然等(2023)基于北京房山X波段双偏振雷达探测资料,不仅精准监测到2017年6月18日北京门头沟泥石流事件的极端降水过程,还通过高分辨率的QPE产品成功定位山区强降水核心区域,有效弥补了山区雨量站稀疏的观测短板。然而,X波段雷达的短波长特性使其信号易受波束衰减(Beam Attenuation, BA)和路径积分效应(Path-Integrated Attenuation, PIA)的影响,尤其在强对流降水天气中,反射率因子(Horizontal Reflectivity, Z_H)的探测值会随降水强度增大而系统性偏低,因此基于单偏振量的 $R(Z_H)$ 关系往往会导致估计结果偏离实际雨强。针对这一问题,多种基于双偏振参量的QPE方法得到了大量的研究,如基于反射率因子和差分反射率(Differential Reflectivity, Z_{DR})的 $R(Z_H, Z_{DR})$ 方法(Chandrasekar and Bringi, 1988),基于差传播相移率(Specific Differential Phase Shift, K_{DP})的 $R(K_{DP})$ 方法(Chandrasekar et al, 1990),基于差分反射率和差传播相移率的 $R(K_{DP}, Z_{DR})$ 方法等(Ryzhkov and Zrnić, 1995)。以上方法均为静态的雨强-雷达参量关系式,忽略了不同天气过程以及同一天气过程的不同区域雨滴谱(Drop Size Distribution, DSD)的时空差异(吴亚昊等, 2016),缺乏对对流云演变过程的动态适应机制的研究,导致在夏季短时强降水过程中,它们的降水估计结果存在显著误差(谷军霞等, 2018; 李佳慧等, 2025)。

近年来,人工智能技术的快速发展为雷达QPE问题提供了创新性解决方案。人工神经网络(Artificial Neural Network, ANN)以其自适应学习能力率先应用于该领域,例如傅德胜等(2015)基于径向基函数(Radial Basis Function, RBF)建立的降水估

计模型,其准确性显著优于传统Z-R关系。此外,梯度提升决策树(Gradient Boost Decision Tree, GBDT)通过集成学习策略优化了模型鲁棒性,陈训来等(2019)研究表明,GBDT在强降水事件(小时雨强超过 $30 \text{ mm} \cdot \text{h}^{-1}$)中的估计误差较动态Z-R法降低21.3%,有效缓解了对极端降水低估的现象。

上述方法均依赖人工特征选择(如反射率均值、标准差等),难以充分挖掘雷达参量与降水量间的深层关联(Shen, 2018)。深度学习技术通过自动提取高维特征克服了这一缺陷。Chen et al (2019)结合地面雷达与星载TRMM(Tropical Rainfall Measuring Mission)雷达数据构建多层感知器(Multilayer Perceptron, MLP),其估计结果与雨量计数据的相关系数(Cross-Correlation Coefficient, CC)提升至0.89。卓健等(2023)提出融合快速动态分级法(Fast Dynamic Categorical method, FDC)的MLP架构,将单部雷达输入扩展为多分支网络,在广西地区实现分钟级、1 km网格的业务化QPE产品,强降水事件的均方根误差(Root Mean Square Error, R_{MSE})降低至 $2.1 \text{ mm} \cdot \text{h}^{-1}$ 。相比之下,传统神经网络因缺乏特征通道注意力机制,难以区分融化层干扰与有效降水回波,导致复杂降水场景的泛化能力受限(Shen, 2018)。

基于深度学习的降水估计方法,其本质是通过深度学习网络对数据中降水信息进行精准定位并赋予更高的权重,最终拟合得到降水估计结果,这与医学图像检测分割任务的本质较为相似。而作为处理医学图像检测分割任务的里程碑模型U-Net(Ronneberger et al, 2015),不仅具有数据高效性的特点即在小样本条件下仍能取得较好的收敛效果,而且具备更为灵活的特征融合机制及轻量高效的架构(Ronneberger et al, 2015)。基于此,Oktay et al(2018)提出Attention U-Net模型,Attention U-Net在U-Net框架中解码部分引入注意力门(Attention Gates),这些门动态聚焦于目标区域,抑制非关键特征,从而显著提升对于小目标的识别精度。关吉平等(2024)以Attention U-Net为核心搭建具备处理卫星多通道数据能力的卫星降水估计网络框架,评估结果表明,Attention U-Net的降水估计效果优于使用传统物理反演方法的卫星降水产品FY4A-QPE(FengYun-4A Quantitative Precipitation Estimation)和CMORPH(Climate Prediction Center MORPHing),也优于U-Net模型。

成都平坝地区凭借得天独厚的地理区位与创新发展战略,近年来社会经济发展迅猛,并成功承

办第31届世界大学生夏季运动会、中国西部国际博览会等重大国际活动,城市综合承载力与国际影响力持续提升。但与此同时,该区域内极端降水事件日益频发,不仅对公众日常出行造成严重干扰,也给社会生产、城市安全带来严峻挑战。因此,如何获取高质量、高时空分辨率的雷达QPE产品,对解决因短时强降水引发的城市内涝问题具有重大意义。

针对以上问题,本研究聚焦于成都平坝地区夏季的短时强降水天气,利用X波段双偏振相控阵雷达探测数据,搭建以CBAM(Convolutional Block Attention Module) U-Net为核心的雷达强降水估计模型,该模型以U-Net网络框架为基础,引入CBAM模块,通过顺序组合空间注意力子模块(Spatial Attention Module)与通道注意力子模块(Channel Attention Module),增强了模型对更为关键的空间区域以及数据通道的学习能力。同时,在制作模型数据样本时,本研究将雷达探测到的液态粒子降落至地面所需时间纳入考量,并且在数据样本中添加时间维,以增加样本与地面雨量计数据的相关度,进而提升模型在雷达降水估计中的性能,以期在成都平坝地区短时强降水的精准预报和灾

害防御提供有力的产品技术支持。

2 研究区域和时段

2.1 研究区域

受地形遮挡作用,位于成都西部山区的雷达,其低仰角探测数据质量较差,且地面气象观测站分布稀疏;而布设于平坝地区的雷达受地物回波影响较小,同时地面气象观测站的密度更高、覆盖范围更广。因此,本研究将位于成都平坝地区的新都站(104.235°E, 30.777°N, 海拔526 m, 站号ZS402)、天府新区站(104.111°E, 30.484°N, 海拔539 m, 站号ZS403)、双流站(103.998°E, 30.312°N, 海拔486 m, 站号ZS405)和简阳站(104.641°E, 30.487°N, 海拔479 m, 站号ZS406)的X波段双偏振相控阵雷达(以下简称X-PAR)有效探测区域作为研究区域,雷达具体参数见表1。如图1所示,4部X-PAR雷达的60 km探测范围内均受到龙泉山脉的遮挡,其中天府新区雷达的遮挡影响最为显著,其最大遮蔽角为2.2°。因此,本研究采用4部雷达仰角超过2.2°的探测基数据作为研究数据来源。文中所用时间均采用北京时。




图1 4部X波段相控阵雷达分布及研究区域高程(填色,单位:m)
4个红色圆圈分别表示4部雷达的最大扫描范围

Fig. 1 Locations of four X-band phased array radars and elevation of the study area (shading, unit: m).
The four red circles in the figure denote the maximum scanning coverage of the four radars, respectively

DEM(Digital Elevation Model)高程数据来自地理空间数据云平台(<https://www.gscloud.cn>),采用SRTMDEMUTM数字高程数据产品,分辨率为

90 m,数据投影坐标系为WGS84。文中涉及的地图是基于中华人民共和国自然资源部标准地图服务网站下载的审图号为川S[2021]00059号的标准

表1 X波段双偏振相控阵雷达主要参数
Table 1 Key parameters of X-band dual-polarization
phased array radar

主要参数	量值
时间分辨率/s	60
空间分辨率/m	30
角度分辨率/(°)	1
最低扫描仰角/(°)	0.9
最大探测距离/km	60
扫描仰角数/个	40

地图制作，底图无修改。

2.2 研究时段

本研究聚焦成都地区夏季短时强降水天气展开研究，因此在筛选地面雨量计时，其观测数据需满足小时雨强超过 20 mm·h⁻¹ 的标准(中国气象局公共气象服务中心, 2019)。同时，考虑到雷达静锥区以及波束展宽随径向距离迅速增大对数据质量的影响，选取的地面雨量计需位于雷达径向距离 10~40 km 范围。

基于上述条件，对 2023—2024 年 7—9 月的数据进行筛选，共识别出 14 次强降水天气过程。这些过程中，短时强降水发生的具体时段、最大小时雨强以及观测到小时雨强≥20 mm·h⁻¹ 的台站数量，详见表 2。

3 资料与方法

3.1 模型标签设置

成都的夏季对流云降水具有局地性强、持续时间短且发展变化迅速的特点。传统雷达因时空分辨率的限制，难以对其进行有效监测与分析。而具有高时空分辨率(时间分辨率达 1 min，径向分辨率为 30 m)的 X-PAR 雷达，能够实时、细致地捕捉不同发展阶段对流云的雷达回波特征，为深入研究提供了可靠的数据支持。基于此，本研究将地面雨量计观测到的分钟雨量数据作为模型标签：一方面，分钟级数据能够精确刻画对流云在不同发展阶段降水效率的变化特征；另一方面，丰富的分钟雨量数据为模型训练提供了充足的数据样本，提升了模型训练的准确性与稳定性。

3.2 模型数据样本制作

在雷达数据采集方面，垂直维度，截取地面雨量计(成都平坝地区的地面雨量计海拔多在 0.5 km)上方 1.3~2.3 km 高度层(海拔 1.8~2.8 km)的 Z_H、

表2 2023—2024年夏季发生于成都平坝地区的短时强降水天气过程

Table 2 Short-term heavy precipitation weather in the plain areas of Chengdu in summer from 2023 to 2024

降水过程 编号	日期	发生的具体 时段	最大小时 雨强 /(mm·h ⁻¹)	小时雨强 ≥20 mm·h ⁻¹ 的台站 数量/个
1	2023 年 7 月 13 日	02:00—16:00	107.0	61
2	2023 年 7 月 17 日	16:00—19:00	41.3	2
3	2023 年 7 月 24 日	13:00—15:00	30.0	2
	2023 年 7 月 25 日	13:00—14:00	74.6	46
		17:00—21:00		
	2023 年 7 月 26 日	08:00—12:00	55.5	17
		19:00—21:00		
	2023 年 7 月 27 日	00:00—04:00	66.2	45
		06:00—07:00		
4	2023 年 7 月 31 日	18:00—19:00	36.4	1
	2023 年 8 月 1 日	07:00—10:00	43.8	13
		20:00—21:00		
	2023 年 8 月 2 日	10:00—14:00	66.7	22
	2023 年 8 月 3 日	08:00—12:00	68.7	49
		16:00—17:00		
	2023 年 8 月 4 日	16:00—18:00	58.8	3
	2023 年 8 月 5 日	12:00—16:00	51.2	6
	2023 年 8 月 6 日	13:00—17:00	67.1	36
	2023 年 8 月 7 日	05:00—06:00	29.7	1
	2023 年 8 月 8 日	8 日 19:00 至 9 日 00:00	85.8	16
5	2023 年 8 月 10 日	17:00—21:00	52.3	17
	2023 年 8 月 11—12 日	11 日 17:00 至 12 日 07:00	89.2	102
6	2023 年 8 月 23 日	12:00—14:00 22:00—23:00	44.2	17
7	2023 年 8 月 29 日	10:00—13:00	49.4	14
8	2023 年 9 月 9—10 日	9 日 20:00 至 10 日 03:00	59.8	17
9	2023 年 9 月 11 日	00:00—05:00 08:00—09:00 10:00—11:00	39.5	54
10	2023 年 9 月 22 日	06:00—07:00	23.8	1
11	2024 年 7 月 20 日	04:00—07:00	61.3	34
12	2024 年 8 月 2 日	22:00—23:00	53.6	4
13	2024 年 9 月 10 日	03:00—05:00	60.7	59
14	2024 年 9 月 29 日	14:00—16:00 17:00—18:00	49.3	27

K_{DP} 和 Z_{DR} 数据,该高度层设置避免了地表杂波干扰并且与850~700 hPa高度层对应,有研究表明850~700 hPa高度层的水汽条件对四川盆地夏季暴雨的形成具有重要作用(熊德方等,2023);水平维度,考虑到X-PAR雷达的径向距离分辨率以及神经网络感受野的适配性计算,选取以地面雨量计为中心,包含32个径向距离库(960 m)×32个方位角的采样窗口。经上述筛选,得到水平32径距×32方位,垂直1 km的雷达数据块。因本研究聚焦夏季短时强降水,为排除固态粒子或混合相态粒子的干扰,对数据块中 $CC<0.9$ 的距离库进行剔除。同时,全球降水测量计划(Global Precipitation Measurement, GPM)的双频测雨雷达(Dual-frequency Precipitation Radar, DPR)观测结果显示,形成地面降水的雷达反射率因子阈值普遍介于15~20 dBZ,其中18 dBZ在中纬度地区与地面降水具有高概率对应。因此,进一步对数据块中 $Z_H<18$ dBZ的距离库进行剔除。

由于雨量计与雷达之间的距离各不相同,因此不同雨量计所对应的雷达数据块内包含的雷达基数据仰角数量也存在差异。以矩阵 $A=[e, c, h, w]$ 来表征截取的雷达数据块,其中 e 代表仰角数; $c=3$ 表示数据通道即选取的雷达参数量数; h 和 w 均取值为32,分别对应径向距离库和方位角的数量。若雨量计距雷达较近,其对应数据块可能包含多层雷达基数据即 $e\geq 2$,此时选取不同仰角下同一水平位置数据的最大值作为该水平位置的代表值,最终提取得到大小为 $[c, h, w]$ 的雷达数据矩阵。需要注意的是对处于两部雷达探测重合区域的雨量计,本研究选取距雨量计更近的雷达站作为数据来源。

此外, Zhang et al (2023)的研究表明,在成都

夏季对流云降水过程中,雨滴的平均等效直径为1.958 mm,对应的下落末速度接近 $6\text{ m}\cdot\text{s}^{-1}$ (柳臣中等,2016)。由此可计算得到雨滴从雷达数据块中心位置(地面雨量计上方1.8 km、海拔2.3 km)降落至雨量计附近约需5 min。理论上,若以地面雨量计数据的时次 T_0 为基准,与之对应的雷达数据样本时次 $T=(T_0-5)\text{ min}$ 。然而,实际降水过程中存在诸多误差因素,导致雷达与雨量计数据存在匹配偏差(如:雨滴直径大小不一,其对应的下落末速度有所差异;数据块内雨滴距地面雨量计的高度不尽相同等)。为降低这些因素对模型估计结果的不利影响,本研究将时次 T 及其前后各2 min的雷达数据矩阵纳入考量,共计5个时次的数据作为模型的训练样本,即 $C=[c, t, h, w]$,其中 $t=5$,代表时间维,以此提升模型数据样本与地面雨量计的相关度。

3.3 CBAM U-Net模型

如图2所示, CBAM U-Net模型以U-Net框架为基础,采用编码-解码结构,编码部分由卷积(Convolution)和最大池化(Max-pooling)操作组成,主要作用是进行特征提取和降低维度;解码部分则通过上采样(Up-sampling)和跳跃连接(Skip-connection)操作,实现数据维度的恢复以及高、低维特征信息的融合。如此将编码器的低层高分辨率特征(定位信息)与解码器的高层语义特征(上下文信息)融合,实现对强降水关键区域的识别。本研究中,模型数据样本包含3个数据通道,因此不仅要加强对于关键区域的关注,还需提取不同雷达参量与地面降水间的相关性信息。于是采用Woo et al (2018)提出的CBAM注意力模块嵌入U-Net框架中编码部分。CBAM模块由通道注意力子模块(Channel Attention Module)和空间注意力子模块




图2 CBAM U-Net模型结构示意图

Fig. 2 Schematic diagram of CBAM U-Net network structure

(Spatial Attention Module)构成,这两个子模块基于平均池化和最大池化操作,将它们顺序组合并嵌入编码部分,不仅能够学习到空间区域中值得关注的特征信息,还能提取出更为关键的数据通道,从而提升模型在雷达降水估计中的性能。此外,需要注意的是,由于模型训练样本涵盖时间维,因此编码阶段,本研究采用三维卷积和三维池化操作来提取数据样本中包含的时间维与空间维特征信息。

3.4 Z-R关系与评估指标

本研究选用以下Z-R关系作为评估CBAM U-Net模型降水估计性能优劣的对比对象,

$$R(Z_H) = 452 \cdot Z_H^{1.331} \tag{1}$$

$$R(Z_H) = 346.3 \cdot Z_H^{1.324} \tag{2}$$

式(1)和式(2)分别由Zhang et al[2023, 下文简称为 $R(Z_H)-Z$]和刘艳霞等[2024, 下文简称为 $R(Z_H)-L$]通过对成都地区雨滴谱数据拟合得到,且它们均适用于夏季对流云的降水估计。在运用式(1)和式(2)进行降水估计时,为避免X波段相控阵雷达在某些方位因地形阻挡等因素而存在数据缺失,本研究的处理方法为:读取雷达第一、二层仰角下在地面雨量计位置处的探测数据,以及CR(Composite Reflectivity)产品在雨量计位置处的值,然后取三者均值作为 Z_H 值进行计算。

为客观反映雷达降水估计值与雨量计观测值之间的误差,本研究选取回归评估参量 CC 、 R_{MSE} 、 R_{MAE} (Relative Mean Absolute Error)、 R_{MB} (Relative Mean Bias)作为误差评估指标,

$$CC = \frac{\sum_{i=1}^n (R_i - R_{ave})(G_i - G_{ave})}{\sqrt{\sum_{i=1}^n (R_i - R_{ave})^2 \sum_{i=1}^n (G_i - G_{ave})^2}} \tag{3}$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_i - G_i)^2} \tag{4}$$

$$R_{MAE} = \frac{\sum_{i=1}^n |R_i - G_i|}{\sum_{i=1}^n G_i} \times 100\% \tag{5}$$

$$R_{MB} = \frac{\sum_{i=1}^n (R_i - G_i)}{\sum_{i=1}^n G_i} \times 100\% \tag{6}$$

式中: R_i 为第*i*个估计值; G_i 为第*i*个观测值; R_{ave} 和 G_{ave} 分别代表所有雷达降水估计样本以及所有气象站观测样本的均值。

为实现对模型性能更加全面、深入的评估,本研究进一步引入分类评估参量,旨在细致分析模型针对不同降水效率对流云的降水估计性能,包括命中率(Probability of Detection, POD)、空报率(False Alarm Rate, FAR)以及临界成功指数(Critical Success Index, CSI)。其计算公式如下:

$$POD = \frac{TP}{TP + FN} \tag{7}$$

$$FAR = \frac{FP}{TP + FP} \tag{8}$$

$$CSI = \frac{TP}{TP + FP + FN} \tag{9}$$

式中: TP 为雨量计观测值与估计值均大于阈值; FP 为雨量计观测值小于阈值,而估计值大于阈值; FN 为雨量计观测值大于阈值,而估计值小于阈值。在分类评估指标中,分钟雨量阈值的设置如表3所示,阈值是依据四川省气象灾害预警信号发布与传播规定的成都地区发布暴雨预警信号标准(四川省人民政府令, 2024)计算得出。

表3 分类评估指标中分钟雨量阈值的设置及说明

Table 3 Setting and explanation of minute rainfall thresholds in classification evaluation metrics				
要素	是否降水	小时雨强达 20 mm·h ⁻¹	小时雨强达 40 mm·h ⁻¹	小时雨强达 70 mm·h ⁻¹
分钟雨量阈值 /(mm·min ⁻¹)	0.1	0.34	0.67	1.17
说明	表征模型估计晴雨的准确性	表征模型估计短时强降水的准确性	表征模型估计降水是否满足橙色暴雨预警信号标准的准确性	表征模型估计降水是否满足红色暴雨预警信号标准的准确性

3.5 试验设置

试验设置主要包括:(1)本研究将2023年数据集作为模型训练集,共有85078个数据样本(训练样本65000个,验证样本20078个);2024年数据集作为模型测试集,共包含9893个数据样本。(2)本

研究基于PyTorch框架搭建了CBAM U-Net模型,采用均方误差损失函数(Mean Squared Error Loss, MSELoss)作为优化目标,并结合Adam(Adaptive Moment Estimation)优化算法进行模型训练。主要参数设置如下:Batch_size=8, Epochs=200, Learn-

ing_rate=0.0005。为优化训练过程,本研究采用学习率预热策略,即在前10个Epoch中,学习率逐步从初始值递增至0.0005。第11个Epoch开始使用余弦退火方案(Loshchilov et al, 2017)进行学习率衰减,以防止模型在训练过程中出现过拟合与梯度爆炸。此外,考虑到模型数据样本中 Z_{DR} 可能存在负值,模型采用LeakyReLU作为激活函数。(3)本研究将CBAM U-Net模型与Attention U-Net、U-Net以及两个 $R(Z_H)$ 关系式的降水估计结果进行对比,评估不同方法在利用X波段相控阵雷达数据进行降水估计时的性能表现。

4 结果与分析

4.1 整体评估结果

表4给出了不同雷达降水估计方法的误差评估结果。 $R(Z_H)$ 关系式在各指标的表现显著低于深度学习模型: $R(Z_H)-Z$ 与 $R(Z_H)-L$ 的CC值均小于0.2(0.151

和0.150), R_{MSE} 超过 $0.8\text{ mm}\cdot\text{min}^{-1}$ ($0.837\text{ mm}\cdot\text{min}^{-1}$ 和 $1.026\text{ mm}\cdot\text{min}^{-1}$), R_{MAE} 高于84%(84.766%和95.108%),且 R_{MB} 分别为1.577%和26.874%,均呈现高估现象。

对比发现,深度学习模型的CC均超过0.47, R_{MSE} 降至 $0.43\text{ mm}\cdot\text{min}^{-1}$ 以下,表明模型估计降水与实况降水的一致性以及绝对误差控制均优于传统Z-R关系。三种模型中,CBAM U-Net在整体降水估计效果上表现最优,其CC达到0.665, R_{MSE} 为 $0.331\text{ mm}\cdot\text{min}^{-1}$, R_{MAE} 为44.651%,均优于其他两种模型。Attention U-Net的降水估计效果次之,而U-Net表现相对较差,且其 R_{MB} 低至-30.742%,出现了显著的低估。可见,在模型中引入注意力机制,有助于提升模型对于关键区域和重要通道的学习能力,提取与降水相关度更高的特征信息。尤其在针对局地强对流时,注意力机制的引入缓解了因忽略局部强回波特征而导致的降水低估问题。

表4 5种降水估计方法针对X波段雷达的降水估计效果评估
Table 4 Performance evaluation of five QPE methods for X-band Radar

模型	CC	$R_{MSE}/(\text{mm}\cdot\text{min}^{-1})$	$R_{MAE}/\%$	$R_{MB}/\%$
CBMA U-Net	0.665	0.331	44.651	7.324
Attention U-Net	0.488	0.399	59.233	7.360
U-Net	0.471	0.427	59.406	-30.742
$R(Z_H)-Z:R(Z_H)=452\cdot Z_H^{1.331}$	0.151	0.837	84.866	1.577
$R(Z_H)-L:R(Z_H)=346.3\cdot Z_H^{1.324}$	0.150	1.026	95.108	26.874

为深入剖析5种方法的降水估计稳定性,图3展示了4部雷达在9个降水时段的CC、 R_{MSE} 、 R_{MAE} 以及 R_{MB} 箱线图。从CC、 R_{MSE} 和 R_{MAE} 的数据表现来看[图3(a)~(c)],CBAM U-Net模型的CC最大值超过0.8,中位数约为0.65; R_{MSE} 均小于 $0.53\text{ mm}\cdot\text{min}^{-1}$; R_{MAE} 中位数在46%左右,并且模型估计数据的离散程度较小,表明针对不同雷达站、不同降水时段,CBAM U-Net模型均表现出较好的降水估计性能。其他两种模型在CC、 R_{MSE} 和 R_{MAE} 的数据表现较为接近且均优于Z-R关系。

CBAM U-Net与Attention U-Net模型 R_{MB} 的中位线均位于0线以上[图3(d)],虽然Attention U-Net的中位线与0线更接近,但CBAM U-Net的箱体较0线偏离更小,因此两者整体的 R_{MB} 基本一致(CBAM U-Net: 7.324%; Attention U-Net: 7.360%)。相反,U-Net模型除最大值外,其余数据样本的 R_{MB} 均小于0%,且上四分位数接近-25%,

说明U-Net的估计降水较实况降水存在系统性偏低,这与整体误差评估的结果一致(-30.742%)。与模型相比,两个 $R(Z_H)$ 关系式的箱体长度显著偏长,即针对不同站点、不同过程的降水估计效果差异显著,方法的稳定性较差,这主要与 $R(Z_H)$ 关系依赖经验公式,难以适应不同降水场景有关。

综上所述,CBAM U-Net模型在准确性方面表现最优且具有较高的稳定性,Attention U-Net次之,而U-Net虽然稳定性较好,但却存在显著的低估问题。与深度学习模型相比, $R(Z_H)$ 方法无论在准确性还是稳定性均表现不佳。

4.2 不同降水强度下的评估结果

为进一步探究5种方法针对不同降水强度时的降水估计效果,本研究选取表3中的分钟雨量作为分类评估的阈值,以更全面地了解各方法在不同降水强度下的适应性和准确性,为实际应用提供更具针对性的参考依据,具体的评估结果如表5所示。




图3 CBMA U-Net、Attention U-Net、U-Net、 $R(Z_H)-Z$ 和 $R(Z_H)-L$ 估计分钟雨量的 CC (a)、 R_{MSE} (b)、 R_{MAE} (c)、 R_{MB} (d)箱线图
箱体上下边为上下四分位数,箱内横线为中位数,虚线两端横线为极值点,离散点为异常值

Fig. 3 Box plots of CC (a), R_{MSE} (b), R_{MAE} (c) and R_{MB} (d) for minute rainfall estimated by CBAM U-Net, Attention U-Net, U-Net, $R(Z_H)-Z$ and $R(Z_H)-L$. The upper and lower edges of the box represent the upper and lower quartiles, the horizontal line inside indicates the median, the horizontal lines at the end of the dashed line indicate the extreme points, and the discrete points represent the outliers

表5 不同分钟雨量阈值下分类评估指标统计

Table 5 Statistics of classification evaluation metrics for different minute rainfall thresholds

分钟雨量阈值 /(mm·min ⁻¹)	评估 指标	模型				
		CBAM U-Net	Attention U-Net	U-Net	$R(Z_H)-Z$	$R(Z_H)-L$
0.10	CSI	0.894	0.846	0.860	0.820	0.842
	POD	0.992	0.946	0.952	0.890	0.922
	FAR	0.100	0.112	0.101	0.088	0.094
0.34	CSI	0.655	0.609	0.537	0.492	0.555
	POD	0.915	0.849	0.650	0.608	0.713
	FAR	0.302	0.316	0.243	0.280	0.285
0.67	CSI	0.485	0.408	0.160	0.244	0.298
	POD	0.643	0.608	0.176	0.331	0.437
	FAR	0.336	0.447	0.373	0.518	0.517
1.17	CSI	0.181	0.084	0.008	0.074	0.092
	POD	0.204	0.100	0.008	0.130	0.198
	FAR	0.385	0.650	0.538	0.852	0.854

首先,针对晴雨分类的估计,CBAM U-Net 模型在 POD 方面表现突出,达到了 0.992,表明该模型能够准确识别出绝大部分的降雨天气;Attention U-Net 与 U-Net 对于晴雨天气的估计效果基本一致,略差于 CBAM U-Net。值得注意的是两个 $R(Z_H)$ 关系式的 FAR 均低于深度学习模型,这可能与深度学习模型本身存在的系统性偏差有关。综合 CSI 指数来看,CBAM U-Net 模型的晴雨分类结果要优于其他方法。

当分钟雨量阈值增大至 $0.34 \text{ mm} \cdot \text{min}^{-1}$ 和 $0.67 \text{ mm} \cdot \text{min}^{-1}$ 时,5 种方法的评估指标出现不同程度的下滑。其中,CBAM U-Net 模型依然展现出更好的适用性,POD 分别能达到 0.915($0.34 \text{ mm} \cdot \text{min}^{-1}$)和 0.643($0.67 \text{ mm} \cdot \text{min}^{-1}$),其 CSI 评分分别为 0.655($0.34 \text{ mm} \cdot \text{min}^{-1}$)和 0.485($0.67 \text{ mm} \cdot \text{min}^{-1}$),与其他方法相比,降水估计效果优势显著。然而 U-Net 模型的指标却出现急速下滑,尤其当阈值为 $0.67 \text{ mm} \cdot \text{min}^{-1}$ 时,其 CSI 指数低至 0.160,且显著低于 Z-R 关系。

随着阈值增大到 $1.17 \text{ mm} \cdot \text{min}^{-1}$,CBAM U-Net 模型的 CSI 指数也迅速降至 0.181,其他方法均低于 0.1,可见五种方法在评估分钟雨量超过 $1.17 \text{ mm} \cdot \text{min}^{-1}$ 的超高降水效率对流云时,都难以准确刻画其降水量的变化特征。经统计发现模型训练集中分钟雨量超过 $1.17 \text{ mm} \cdot \text{min}^{-1}$ 的极端值样本占比约为 5.4%,呈现较为明显的偏态分布。这种分布特征导致极端值样本对总损失的贡献被常态样本的累积损失大幅稀释:模型迭代优化过程中,占比超 94% 的常态样本因数量优势,其损失贡献主导了参数更新方向,模型更倾向于拟合常态区间的降水规律;而极端值样本因数量稀少,其损失信号难以推动参数向捕捉极端降水特征的方向调整,最终使得模型对极端值的特征学习能力显著不足。

综上所述,在多阈值条件下的评估中,CBAM U-Net 模型的降水估计效果最优,Attention U-Net 次之。而 U-Net 的表现存在较大反差,随着降水强度的增大,其评估指标迅速转差,凸显了注意力机制对强降水的适应性提升。

4.3 不同时间演变模态的降水估计对比检验

本研究选取 2024 年 9 月 10 日 04:00—05:00 与 29 日 17:00—18:00 的两次短时强降水天气作为分析样本,检验评估三种深度学习模型对不同时间

演变模态降水的估计能力。其中,10 日的降水过程具有显著“脉冲式”特征,即在 60 min 时段内,分钟雨量呈现剧烈波动,多个站点的分钟雨量超过 $2 \text{ mm} \cdot \text{min}^{-1}$ 。与之相反,29 日 17:00—18:00 为强降水过程趋于结束的时段,以稳定性降水为主,分钟雨量稳定在 $0.2 \sim 1.0 \text{ mm} \cdot \text{min}^{-1}$ 范围。两次过程的具体雨量计分布如图 1 中黄色五角星标记所示。

如图 4 所示,从上至下分别为 CBAM U-Net、Attention U-Net、U-Net 针对 10 日降水过程中 5 个代表性地面雨量计的分钟雨量估计结果,实线为实况降水,虚线为模型估计。CBAM U-Net 模型[图 4(a)~(e)]在降水峰值与相位捕捉上呈现差异化表现。所有站点的估计降水峰值均低于实况,但峰值出现时次与实况高度吻合。以具有“双峰”特征的站点 S1009[图 4(b)]为例,模型虽低估降水峰值,却精准定位降水曲线波峰、波谷的位置,表现出对降水时序变化特征的良好捕捉能力。Attention U-Net 模型[图 4(f)~(j)]同样存在降水峰值低估问题,在站点 S1009[图 4(g)]、S1208[图 4(i)]中表现显著。此外,该模型对站点 S1198[图 4(h)]的估计出现明显相位偏移,未能有效提取该站点降水的时间维特征信息,对降水时序演变的追踪能力不足。U-Net 模型[图 4(k)~(o)]降水峰值低估问题最为突出,且时间维特征提取缺陷明显。以站点 S1198 为例,其估计降水曲线不仅峰值显著低于实况,降水变化的时间节点也存在较大偏差。

图 5 对比了三种模型对 29 日稳定性降水过程的估计效果。针对 CBAM U-Net 模型[图 5(a)~(e)]的分析表明,该模型对降水峰值的估计依然偏低,但较 10 日过程幅度收窄。降水时序变化方面,以站点 S1540[图 5(b)]为例,虽然模型可以勾勒出整体变化趋势,但针对相邻时次分钟雨量 $0.1 \sim 0.2 \text{ mm} \cdot \text{min}^{-1}$ 量级的微小波动呈现敏感性不足的问题。相较之下,Attention U-Net 模型[图 5(f)~(j)]的估计曲线波动幅度更大,在多个站点(如 S1871 的 17:42 时刻和 S1888 的 17:19 时刻)出现降水极小值异常低估的问题,且针对站点 S1879[图 5(i)]降水演变特征的捕捉存在显著提前的现象。U-Net 模型[图 5(k)~(o)]的表现最为局限,以站点 S1540[图 5(o)]为例,估计曲线全时段显著低于实况曲线,且在降水峰值时次(17:37)出现最大偏差。同时,模型的估计值集中在 $0.10 \sim 0.25 \text{ mm} \cdot \text{min}^{-1}$ 的狭窄区




图4 2024年9月10日04:00—05:00站点S1007、S1009、S1198、S1208和S1844的实况以及CBAM U-Net(a~e)、Attention U-Net(f~j)和U-Net(k~o)估计的分钟雨量曲线图

Fig. 4 Time series plots of observed and estimated [CBAM U-Net(a~e), Attention U-Net (f~j) and U-Net (k~o)] minute rainfall at S1007, S1009, S1198, S1208 and S1844 from 04:00 to 05:00 on 10 September, 2024

间,难以反映实况降水超过 $0.4 \text{ mm} \cdot \text{min}^{-1}$ (17:25—17:45时段)的波动特性。

对比两类降水模态下三种模型的降水估计性能可知:CBAM U-Net模型虽存在峰值低估现象,但在时序特征捕捉方面更具优势。相比之下,Attention U-Net模型的低估问题更为突出,且部分站点存在相位偏差;U-Net模型则在两类降水过程中均表现出明显的局限性。由此可见,CBAM模块通过双重注意力机制实现了递进式特征提取。首先,利用通道注意力剔除无效参量干扰,解决了传统U-Net对各通道特征“一视同仁”的问题;随后,通过空间注意力自动聚焦于回波强(Z_{H} 值大)、含水量高(K_{DP} 值大)的区域,并抑制边缘噪声。该级联结构使编码器在提取深层特征时,既能保留与降水物理

机制相关的参量,又能精准定位降水核心区,避免噪声引发的特征混淆,从而有效提升了CBAM U-Net模型的降水估计性能。

5 结论与讨论

本研究构建了基于CBAM U-Net的雷达QPE模型,通过引入CBAM模块,实现了对与降水关联度高的空间区域和特征通道的自适应筛选。在模型训练阶段,采用学习率预热策略结合余弦退火衰减机制,提升了模型收敛效率。与Attention U-Net、U-Net以及两个 $R(Z_{\text{H}})$ 关系式的对比实验表明:在整体误差评估以及稳定性检验方面,CBAM U-Net模型实现了最高准确性($CC=0.665$, $R_{\text{MSE}}=0.331 \text{ mm} \cdot \text{min}^{-1}$, $R_{\text{MAE}}=44.651\%$)以及较好的




图5 2024年9月29日17:00—18:00站点S1166、S1540、S1871、S1879和S1888的实况以及CBAM U-Net (a~e)、Attention U-Net (f~j)和U-Net (k~o)估计的分钟雨量曲线图

Fig. 5 Time Series Plots of Observed and Estimated [CBAM U-Net(a~e), Attention U-Net (f~j) and U-Net (k~o)] minute rainfall at S1007, S1009, S1198, S1208 and S1844 during 17:00—18:00 on September 29, 2024

稳定性; Attention U-Net的准确性次之; 虽U-Net稳定性较好但存在严重低估。而Z-R关系在CC (<0.2)、 R_{MSE} ($>0.8 \text{ mm} \cdot \text{min}^{-1}$)和 R_{MAE} ($>84\%$)指标上显著劣于深度学习模型, 且箱体长度长, 稳定性差。

多阈值分类评估中, CBAM U-Net模型在 $0.10 \text{ mm} \cdot \text{min}^{-1}$ ($CSI=0.894$, $POD=0.992$)、 $0.34 \text{ mm} \cdot \text{min}^{-1}$ ($CSI=0.655$, $POD=0.915$)和 $0.67 \text{ mm} \cdot \text{min}^{-1}$ 阈值 ($CSI=0.485$, $POD=0.643$)中表现最优, CBAM模块有效提升了模型对强降水的适应性; Attention U-Net次之, 而U-Net在 $0.67 \text{ mm} \cdot \text{min}^{-1}$ 阈值时CSI骤降至0.160, 且低于Z-R关系(验证注意力机制的必要性)。当面对极端降水($\geq 1.17 \text{ mm} \cdot \text{min}^{-1}$)时, 所有方法CSI均 <0.2 (CBAM U-Net为0.181), 暴露出模型对极端值的学习能力不足。

针对2024年9月两次短时强降水天气(10日“脉冲式”; 29日稳定性)的评估显示: CBAM U-Net模型在两类降水模态中均表现最优, 在“脉冲式”过程中虽低估峰值, 但能精准捕捉降水相位; 在稳定性降水中的整体趋势拟合最佳, 却存在对 $0.1 \sim 0.2 \text{ mm} \cdot \text{min}^{-1}$ 微波动敏感性不足的问题。在两类降水模态下, 除存在峰值低估外, Attention U-Net对部分站点(如10日S1198和29日S1879)的估计降水存在显著的相位偏差。3种模型中, U-Net的表现最差, 其低估幅度最大且时序变化特征的偏差明显, 尤其在29日过程中, 站点S1540的估计曲线全时段显著低于实况曲线, 并且完全丢失实况降水的时间演变信息。

尽管CBAM U-Net模型的降水估计效果优于Attention U-Net和U-Net, 但仍存在一些亟待解决的

问题。一方面,模型对极端强降水的估计能力不足,对此可采用加权损失函数,对实况雨量超过 $1.0 \text{ mm} \cdot \text{min}^{-1}$ 的样本赋予更大的损失权重,以增强模型对极端降水特征的学习能力;另一方面,该模型仅适用于成都平坝地区,且仅针对夏季强对流天气,缺乏普适性。后续将针对上述问题开展更为深入的研究。

参考文献(References):

- Chandrasekar V, Bringi V N, 1988. Error structure of multiparameter radar and surface measurements of rainfall part I: differential reflectivity[J]. *Journal of Atmospheric and Oceanic Technology*, 5(6): 783–795. DOI: 10.1175/1520-0426(1988)005<0783:esomra>2.0.co;2.
- Chandrasekar V, Bringi V N, Balakrishnan N, et al, 1990. Error structure of multiparameter radar and surface measurements of rainfall. part III: specific differential phase[J]. *Journal of Atmospheric and Oceanic Technology*, 7(5): 621–629. DOI: 10.1175/1520-0426(1990)007<0621:esomra>2.0.co;2.
- Chen H N, Chandrasekar V, Tan H M, et al, 2019. Rainfall estimation from ground radar and TRMM precipitation radar using hybrid deep neural networks[J]. *Geophysical Research Letters*, 46(17–18): 10669–10678. DOI: 10.1029/2019GL084771.
- Loshchilov I, Hutter F, 2016. SGDR: stochastic gradient descent with warm restarts [A]. *International Conference on Learning Representations (ICLR)*. DOI: 10.1109/ICML.2017.468.
- Oktay O, Schlemper J, Le L, et al, 2018. Attention U-Net: learning where to look for the pancreas [EB/OL]. arXiv: 1804.03999. <https://arxiv.org/abs/1804.03999>
- Ronneberger O, Fischer P, Brox T, 2015. U-Net: convolutional networks for biomedical image segmentation [M]//*Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015*. Cham: Springer International Publishing: 234–241. DOI: 10.1007/978-3-319-24574-4_28.
- Ryzhkov A V, Zrnić D S, 1995. Comparison of dual-polarization radar estimators of rain [J]. *Journal of Atmospheric and Oceanic Technology*, 12(2): 249–256. DOI: 10.1175/1520-0426(1995)012<0249:codpre>2.0.co;2.
- Shen C P, 2018. A transdisciplinary review of deep learning research and its relevance for water resources scientists[J]. *Water Resources Research*, 54(11): 8558–8593. DOI: 10.1029/2018WR022643.
- Woo S, Park J, Lee J Y, et al, 2018. CBAM: convolutional block attention module [M]//*Computer Vision-ECCV 2018*. Cham: Springer International Publishing: 3–19. DOI: 10.1007/978-3-030-01234-2_1.
- Zhang T, Wei W, Zheng L Y, et al, 2023. Characteristics and variations of raindrop size distribution in Chengdu of the western Sichuan Basin, China[J]. *Atmosphere*, 14(1): 76. DOI: 10.3390/atmos14010076.
- 陈训来, 陈元昭, 赵春阳, 等, 2019. 梯度提升决策树在雷达定量降水估测中的应用研究[J]. *气象科技进展*, 9(3): 132–137. DOI: 10.3969/j.issn.2095-1973.2019.03.018.
- Chen X L, Chen Y Z, Zhao C Y, et al, 2019. Application of gradient boost decision tree in radar quantitative precipitation estimation[J]. *Advances in Meteorological Science and Technology*, 9(3): 132–137. DOI: 10.3969/j.issn.2095-1973.2019.03.018.
- 傅德胜, 肖晨, 谭畅, 等, 2015. RBF神经网络在雷达定量估测降水中的应用研究[J]. *气象科学*, 35(2): 199–203. DOI: 10.3969/2013jms.0097.
- Fu D S, Xiao C, Tan C, et al, 2015. Application of RBF neural network in radar quantitative precipitation estimation [J]. *Journal of the Meteorological Sciences*, 35(2): 199–203. DOI: 10.3969/2013jms.0097.
- 谷军霞, 师春香, 潘畅, 2018. 天气雷达定量估测降水研究进展[J]. *气象科技进展*, 8(1): 71–78. DOI: 10.3969/j.issn.2095-1973.2018.01.008.
- Gu J X, Shi C X, Pan Y, 2018. Advances in research of the weather radar quantitative precipitation estimation [J]. *Advances in Meteorological Science and Technology*, 8(1): 71–78. DOI: 10.3969/j.issn.2095-1973.2018.01.008.
- 关吉平, 高延波, 黄从雷, 等, 2024. 基于 Attention-Unet 网络的 FY-4A 卫星降水估计[J]. *气象学报*, 82(3): 398–410. DOI: 10.11676/qxxb2024.20230037.
- Guan J P, Gao Y B, Huang C L, et al, 2024. Estimating FY-4A satellite precipitation based on a deep learning model Attention-Unet[J]. *Acta Meteorologica Sinica*, 82(3): 398–410. DOI: 10.11676/qxxb2024.20230037.
- 黄兴友, 张永轩, 李芳, 等, 2024. 利用雷达数据开展对流降水临近预报的循环神经网络方法试验[J]. *大气科学*, 48(6): 2329–2341. DOI: 10.3878/j.issn.1006-9895.2405.24009.
- Huang X Y, Zhang Y X, Li F, et al, 2024. Experiments of convective precipitation nowcasting based on a recurrent neural network method and weather radar data [J]. *Chinese Journal of Atmospheric Sciences*, 48(6): 2329–2341. DOI: 10.3878/j.issn.1006-9895.2405.24009.
- 柳臣中, 周筠珺, 谷娟, 等, 2016. 成都地区雨滴谱特征[J]. *应用气象学报*, 26(1): 112–121. DOI: 10.11898/1001-7313.20150112.
- Liu C Z, Zhou Y J, Gu J, et al, 2016. Characteristics of raindrop size distribution in Chengdu [J]. *Journal of Applied Meteorological Science*, 26(1): 112–121. DOI: 10.11898/1001-7313.20150112.
- 李佳慧, 马建立, 陈明轩, 等, 2025. 基于瓦片分区的雷达动态定量降水估测方法研究[J]. *高原气象*, 44(1): 122–133. DOI: 10.7522/j.issn.1000-0534.2024.00052.
- Li J H, Ma J L, Chen M X, et al, 2025. Research on dynamic quantitative precipitation estimation method based on Tile partitioning for radar [J]. *Plateau Meteorology*, 44(1): 122–133. DOI: 10.7522/j.issn.1000-0534.2024.00052.
- 刘艳霞, 文军, 谢晓林, 2024. 青藏高原中东部和四川盆地的夏季雨滴谱对比分析研究[J]. *高原气象*, 43(1): 28–41. DOI: 10.7522/j.issn.1000-0534.2023.00033.
- Liu Y X, Wen J, Xie X

- L, 2024. A comparative study on the summer raindrop size distribution among areas over the central and eastern Qinghai-Xizang (Tibetan) plateau and the western Sichuan Basin[J]. Plateau Meteorology, 43 (1): 28–41. DOI: 10.7522/j.issn.1000-0534.2023.00033.
- 四川省人民政府令, 2024. 四川省气象灾害预警信号发布与传播规定[Z]. 2024-02-01. Decree of the People's Government of Sichuan Province, 2024. Regulations on the Issuance and Dissemination of Meteorological Disaster Warning Signals in Sichuan Province[Z]. 2024-02-01.
- 吴亚昊, 刘黎平, 周筠珩, 等, 2016. 雨滴谱的变化对降水估测的影响研究[J]. 高原气象, 35(1): 220–230. DOI: 10.7522/j.issn.1000-0534.2014.00093. Wu Y H, Liu L P, Zhou Y J, et al, 2016. Study of raindrop influence of spectrum change on precipitation estimation[J]. Plateau Meteorology, 35(1): 220–230. DOI: 10.7522/j.issn.1000-0534.2014.00093.
- 熊德方, 孙淑清, 彭京备, 等, 2023. 2020年夏季川渝地区洪涝灾害及暴雨过程研究[J]. 大气科学, 47(4): 1007–1023. Xiong D F, Sun S Q, Peng J B, et al, 2023. Analysis of flood disasters and heavy precipitation events in the Sichuan-Chongqing Region in the summer of 2020[J]. Chinese Journal of Atmospheric Sciences, 47(4): 1007–1023.
- 张哲, 戚友存, 李东欢, 等, 2022. 2021年郑州“7·20”极端暴雨雨滴谱特征及其对雷达定量降水估测的影响[J]. 大气科学, 46(4): 1002–1016. Zhang Z, Qi Y C, Li D H, et al, 2022. Raindrop size distribution characteristics of the extreme rainstorm event in Zhengzhou 20 July, 2021 and its impacts on radar quantitative precipitation estimation[J]. Chinese Journal of Atmospheric Sciences, 46(4): 1002–1016.
- 中国气象局 公共气象服务中心, 2019. 短时气象服务降雨量等级: T/CMSA 0013–2019. Public Meteorological Service Center of China Meteorological Administration, 2019. Rainfall grade for short-term meteorological service: T/CMSA 0013–2019.
- 庄潇然, 王辉, 孟庆春, 等, 2023. X波段双偏振雷达对造成北京门头沟泥石流的强降水观测分析[J]. 气象科学, 43(5): 578–588. DOI: 10.12306/2022jms.0014. Zhuang X R, Wang H, Meng Q C, et al, 2023. Observation and analysis of a mudslide event in Beijing by X-band dual-polarization radar[J]. Journal of the Meteorological Sciences, 43(5): 578–588. DOI: 10.12306/2022jms.0014.
- 卓健, 廖胜石, 苏传程, 等, 2023. MLP在雷达定量降水估测中的应用[J]. 热带气象学报, 39(3): 289–299. DOI: 10.16032/j.issn.1004-4965.2023.027. Zhuo J, Liao S S, Su C C, et al, 2023. Application of MLP in radar quantitative precipitation estimation[J]. Journal of Tropical Meteorology, 39(3): 289–299. DOI: 10.16032/j.issn.1004-4965.2023.027.

CBAM U-Net Model-Based Precipitation Estimation for Chengdu X-band Phased Array Radar

ZHOU Cong¹, ZHANG Chenghong², DONG Yuanchang², ZHANG Tao¹

(1. Chengdu Meteorological Observatory, Chengdu 611134, Sichuan, China;

2. Institute of Plateau Meteorology, China Meteorological Administration, Chengdu 610218, Sichuan, China)

Abstract: The frequent occurrence of heavy precipitation events poses severe challenges to urban disaster prevention and mitigation. High-resolution quantitative precipitation estimation (QPE) products are of great importance for monitoring intense rainfall processes, while X-band phased array radars (X-PAR), delivering detection data with high spatiotemporal resolution, provide a robust foundation for advanced QPE research. Due to the limitations of traditional radar-based QPE methods, such as insufficient nonlinear mapping capabilities and the lack of dynamic adaptive learning mechanisms, a minute-scale rainfall QPE method based on the CBAM U-Net model is proposed. This model enhances the learning capability for key precipitation regions and feature channels by incorporating the Channel and Spatial Attention Module (CBAM) and optimizes the temporal alignment between radar and ground rain gauge observations by introducing a temporal dimension to the model input. X-PAR data from four radars in Chengdu's plain area during July-September 2023–2024 were used to construct training and testing datasets. Additionally, the training process was optimized through the integration of learning rate warm-up and cosine annealing strategies, which accelerated the convergence speed and improved the model's robustness. Evaluation metrics, including regression indices (CC , R_{MSE} , R_{MAE} , R_{MB}) and classification metrics (POD, FAR, CSI), were applied to compare the performance of the CBAM U-Net against Attention U-Net, U-Net, and two Z-R methods. Results show that deep learning models significantly outperform traditional Z-R methods in both error metrics and stability. Among the three models, CBAM U-Net achieves the best performance ($CC=0.665$, $R_{MSE}=0.331 \text{ mm} \cdot \text{min}^{-1}$, $R_{MAE}=44.651\%$, $R_{MB}=7.324\%$), followed by Attention U-Net, while U-Net shows significant underestimation. In multi-threshold classification evaluations, CBAM U-Net achieves CSI of 0.655 and 0.485 at thresholds of $0.34 \text{ mm} \cdot \text{min}^{-1}$ (corresponding to $20 \text{ mm} \cdot \text{h}^{-1}$) and $0.67 \text{ mm} \cdot \text{min}^{-1}$ (corresponding to $40 \text{ mm} \cdot \text{h}^{-1}$) respectively, which are notably higher than those of the Attention U-Net (0.609, 0.408) and U-Net (0.537, 0.160). Case studies further verify that CBAM U-Net has a stronger capability to capture temporal features. During the "pulse-type" precipitation event on 10 September 2024, CBAM U-Net accurately identifies the peaks and troughs of precipitation curves and effectively characterizes the temporal variation features of precipitation, performing better than U-Net and Attention U-Net. During the stable precipitation process on 29 September 2024, CBAM U-Net successfully captures the overall trend of precipitation changes but shows insufficient sensitivity to minor fluctuations within the range of $0.1 \sim 0.2 \text{ mm} \cdot \text{min}^{-1}$. The CBAM module effectively improves the model's capability to capture temporal characteristics of heavy precipitation via its dual attention mechanism. However, due to the inherent systematic smoothing effect of deep learning models, notable underestimation still occurs for extreme heavy precipitation events with minute rainfall rates $\geq 1.17 \text{ mm} \cdot \text{min}^{-1}$.

Key words: quantitative precipitation estimation; X-band phased array radar; short-time heavy rainfall; CBAM U-Net