

基于双分支复合小波注意力网络的雷达定量降水估计*

马星洪¹ 钟琦² 杨昊¹ 陈敏¹ 周航¹

1 成都信息工程大学计算机学院, 成都 610225

2 中国气象局气象干部培训学院, 北京 100081

摘要: 当前基于深度学习的雷达反射率因子定量降水估计方法大多采用全局映射策略, 这在一定程度上限制了模型对局部降水特征的解析能力, 为此, 本研究提出了一种双分支复合小波注意力网络模型 (dual-branch composite wavelet attention UNet, DCWA-UNet)。该模型主要从两个方面进行改进: 设计了由主分支和简化卷积下采样分支构成的双分支编码器与特征聚合子网络的混合架构, 实现了从雷达体扫数据到站点降水强度的端到端映射, 从而构建出以站点为中心的样本体系。引入了复合小波注意力模块 (composite wavelet attention module, CWAM), 通过多尺度特征分解和动态权重分配, 增强模型对雷达回波的表征能力; 同时采用加权均方误差损失函数, 突出强量级降水的梯度贡献。采用 2019—2021 年夏季四川盆地的降水地面观测与雷达观测资料, 构建了一个包含 4020 个样本的数据集, 用于模型训练和测试, 并与 SimVP 等深度学习方法进行了对比。结果表明: DCWA-UNet 在不同降水强度下均表现出明显的综合性能优势, 在 $[0.1, 30) \text{ mm h}^{-1}$ 降水强度范围内, 其临界成功指数与平均绝对误差提升显著。在 $[5, 10) \text{ mm h}^{-1}$ 降水强度下, DCWA-UNet 的临界成功指数显著高于 SimVP 及其他对比模型, 平均绝对误差相比 SimVP 降低了 4.9%; 在 $[10, 30) \text{ mm h}^{-1}$ 降水强度下, 临界成功指数较 SimVP 提升了 4.0%, 平均绝对误差降低了 4.0%, 并且误报率为所有对比模型中的最低值。

关键词: 雷达定量降水估计, 双分支编码器, 复合小波注意力模块, 加权均方误差, U-Net

中图分类号: P412

Radar Quantitative Precipitation Estimation Based on a Dual-Branch Composite Wavelet Attention Network

MA Xinghong¹ ZHONG Qi² YANG Hao¹ CHEN Min¹ ZHOU Hang¹

1 School of Computer Science, Chengdu University of Information Technology, Chengdu 610225

2 CMA Training Centre, Beijing 100081

Abstract: Current deep learning-based QPE methods using radar reflectivity factors mostly adopt global mapping strategies, which to some extent limits the models' ability to analyze local precipitation features. To this end, this study proposes a Dual-Branch Composite Wavelet Attention UNet (DCWA-UNet) model. The model is mainly improved from the following two aspects. Firstly, a hybrid architecture consisting of a dual-branch encoder (main branch + simplified convolutional downsampling branch), and a feature

*国家自然科学基金项目(42030611)、国家重点研发计划(2023YFC3007502)、四川省科技成果转化示范项目(2024ZHC0026)和中国气象局气象干部培训学院科研项目-培育项目(2025CMATCPY06)共同资助
第一作者: 马星洪, 主要从事人工智能气象应用与遥感应用技术研究。E-mail: mxh010825@163.com
通信作者: 钟琦, 主要从事数值预报及人工智能应用研究。E-mail: zhongqi@cma.gov.cn

aggregation subnetwork is designed, which enables the end-to-end mapping from radar volume scan data to station precipitation intensity, thereby constructing a station-centered sample system. Secondly, a Composite Wavelet Attention Module (CWAM) is introduced to enhance the model's representation capability for radar echoes through multi-scale feature decomposition and dynamic weight allocation. Meanwhile, a weighted mean square error loss function is adopted to emphasize the gradient contribution of heavy precipitation. Using ground-based precipitation observation and radar observation data in the Sichuan Basin during the summers of 2019–2021, a dataset containing 4020 samples is constructed for model training and testing, and comparative experiments are conducted with deep learning models such as SimVP. The results show that DCWA-UNet achieves obvious comprehensive performance advantages under different precipitation intensities, with particularly significant improvements in critical success index (CSI) and mean absolute error (MAE) within the precipitation range of $[0.1, 30) \text{ mm}\cdot\text{h}^{-1}$. For precipitation intensities of $[5, 10) \text{ mm}\cdot\text{h}^{-1}$, the CSI of DCWA-UNet is significantly higher than that of SimVP and other comparative models, and the MAE is reduced by 4.9% compared to SimVP; for precipitation intensities of $[10, 30) \text{ mm}\cdot\text{h}^{-1}$, the CSI is improved by 4.0% and the MAE is reduced by 4.0% compared to SimVP. Moreover, the false alarm rate is the lowest among all comparative models.

Key words: radar-based quantitative precipitation estimation, dual-branch encoder, composite wavelet attention module, weighted mean squared error, U-Net

引言

降水的时空分布很不均匀,再加上强量级降水事件的频繁发生,给社会经济带来了不小的损失(肖红茹等, 2025; 龙柯吉等, 2020; 刘啸宇, 2020)。四川盆地被山脉和高原环绕,这种复杂地形也在一定程度上影响了降水的时空分布(龙柯吉等, 2025; 陈贺等, 2007)。如果能更准确地估计降水分布,特别是强量级降水,对减轻灾害损失会很有帮助(钟琦等, 2025; Fang et al, 2025; Zhong et al, 2025)。定量降水估计(quantitative precipitation estimation, QPE)是气象灾害预警和水资源管理中的关键环节(Zhang et al, 2020),目前业务上用的定量降水估计方法主要依靠多普勒天气雷达数据(Sokol et al, 2021),其理论基础是雷达反射率因子(Z)与地面降水速率(R)之间的经验关系模型 $Z = aR^b$ (张鹏等, 2021; Crosson et al, 1996; Zhang et al, 2011),通过对参数 a 和 b 做区域性调整,该经验模型虽然可以实现快速预测,但由于它是基于单点映射的,很难反映出降水场的空间异质性和多尺度关联,所以对局部强降水区域的特征解析能力比较有限。随着地面观测网络越来越完善,基于深度学习的QPE方法逐渐发展起来,这类方法通过融合雷达反射率因子和雨量计标签数据,试图突破传统模型的线性或指数形式约束。不过,雷达数据在质量控制上仍面临诸多挑战,比如地物杂波、超折射杂波和噪声杂波等非降水回波,会明显影响雷达对降水的测量效果(徐黄飞等, 2025; 井高飞等, 2020; 吴昊, 2022)。这也使得现有模型在处理降水时空变化的复杂性以及强量级降水时仍然存在不足(李婵珠等, 2024),特别是在降水估计的准确性和强量级降水的敏感性方面(赵军平等, 2025)。

近几年,基于深度学习的QPE方法取得了不少进展,Chen et al (2023)提出RRED-Net模型,集成了小波变换去噪和交叉注意力机制,并用回归焦点损失来优化长尾分布,在 $[20, \infty) \text{ mm}\cdot\text{h}^{-1}$ 降水强度下,TS提升到了39.6%,RMSE降到了 $2.5775 \text{ mm}\cdot\text{h}^{-1}$;Li et al (2023)设计了密集块架构RQPENet,通过多极化参数融合,使小时降雨的RMSE相比传统方法最高降低了49.8%;Wen et al (2024)构建了三维ConvLSTM-UNet模型,利用雷达体扫的时空特征来提升降水预测能力;Huangfu et al (2024)则基于KDP阈值开发了多参数网络POLnet,配合自定义损失函数,使RMSE、MAE和MRE指标都有大幅提升。不过现有研究在处理强量级降水时,大多还是存在对降水强度的变化特

征提取不够和对降水核心区域的空间定位精度偏低的问题。编码器-解码器网络在很多任务中应用广泛，其成功主要归功于跳跃连接机制(Ronneberger et al, 2015)。通过这种机制，编码器中的浅层细节特征可以和解码器中的深层粗粒度特征结合起来，从而保留更多细节，增强特征的融合能力，但是在降水估计任务中，深层网络的多层级下采样可能会导致降水核心区的高频细节在特征传递过程中被稀释。因此，本研究尝试引入加权均方误差损失函数和双分支编码结构来缓解上述问题。我们设计了双分支编码结构并加入了复合小波注意力模块(composite wavelet attention module, CWAM)，通过多尺度特征分解和动态权重分配增强模型对雷达回波特征的捕捉能力，同时利用简化卷积下采样分支来保留原始局部细节，再结合加权损失函数(Weighted Mean Squared Error, WMSE)强化中强降水的梯度贡献，让模型对强量级降水变得更加敏感。

1 方法

1.1 模型架构

本研究提出的 DCWA-UNet(Dual-branch Composite Wavelet Attention UNet)模型(图 1)是在 UNet 基础框架上做的改进和创新。模型由四个核心组件组成：双分支特征编码器、复合小波注意力模块(CWAM)、特征解码器以及特征聚合子网络，各组件通过协同工作实现高效的特征学习与信息传递。

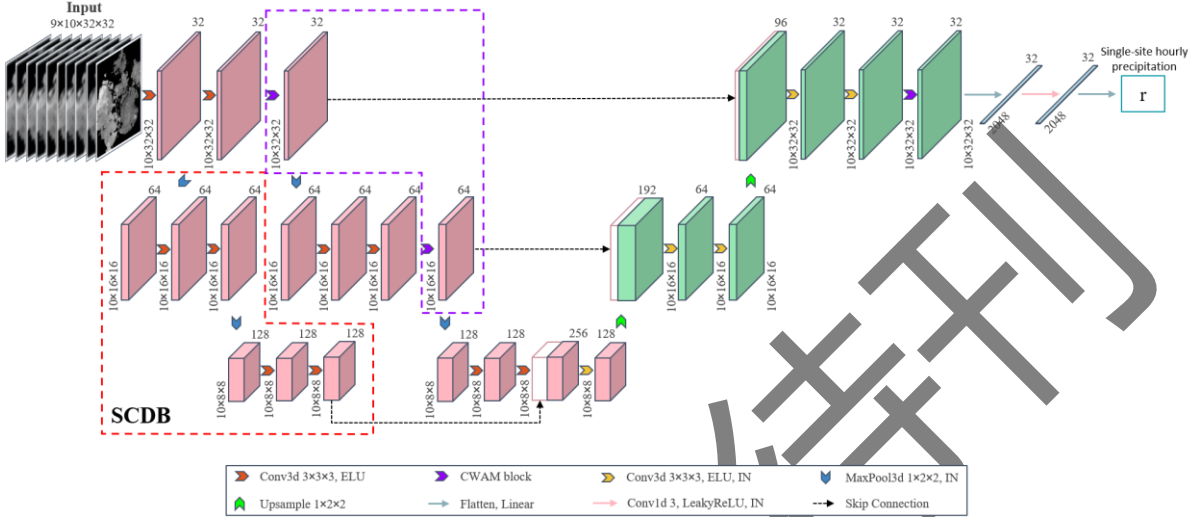
编码器部分由两级级联的下采样模块构成，包含并行处理的简化卷积下采样分支(simplified convolutional downsampling branch, SCDB)和主分支，这两条分支采用“同步下采样-层级融合”的方式协同工作：在两级下采样中，均通过 $1 \times 2 \times 2$ 的三维最大池化降低分辨率，两条分支保持相同节奏，以保证各分支输出的特征图在空间分辨率、时间深度及通道数上都一致，为后面的融合奠定基础；每级下采样结束后，主分支经 CWAM 优化后输出的特征和 SCDB 输出的原始特征会逐元素相加融合。主分支更侧重强化降水核心区的多尺度关联特征，而 SCDB 则保留弱降水微尺度波动这类原始细节，两者融合后得到“局部细节+全局特征”的复合特征张量，然后再传入下一级下采样或解码器。其中，SCDB 分支在每个层级里，先做两次 $3 \times 3 \times 3$ 三维卷积(ELU 激活函数)提取基础的时空特征，然后通过 $1 \times 2 \times 2$ 三维最大池化和实例归一化完成特征下采样。主分支基本结构类似，但在 SCDB 基础上嵌入了 CWAM，通过小波分解-重构机制增强对雷达回波特征的表达能力。双分支编码结构通过主分支提取经 CWAM 优化的多尺度特征，同步结合简化卷积下采样分支保留原始局部细节，既能从整体上捕捉全局特征，又能在关键降水区域精细提取局部信息。

图 2a 给出 CWAM 的具体结构，其核心组件由离散小波变换(discrete wavelet transform, DWT)、逆离散小波变换(inverse DWT, IDWT; Yao et al, 2022)和双通道注意力机制构成。该模块采用双支路并行处理：主支路采用卷积注意力模块(convolutional block attention module, CBAM)，从空间和通道两个维度动态调整雷达回波特征的权重(Woo et al, 2018)；辅支路首先使用 DWT 进行频率分解，然后通过通道注意力挑选重要的频率分量，再结合空间注意力聚焦降水得核心区域，这样就形成了一个层次化得特征选择机制，最后再通过 IDWT 实现特征重构。两条支路得到的特征张量经过加权融合后输出，此设计目的是增强模型对雷达回波多尺度特征的表达能力。

解码器部分同样由两级上采样构成，每级上采样通过 $1 \times 2 \times 2$ 的三维插值操作逐级恢复特征图的

分辨率，并与编码器对应层级的特征图进行跳跃连接实现信息互补。随后经过两次 $3 \times 3 \times 3$ 三维卷积的处理，完成特征融合和细节恢复，形成完整的“扩张-收缩”特征处理路径。

特征聚合子网络采用层级降维策略，通过线性投影层将三维特征转换为时序向量后，依次经过核尺寸为 3 的一维卷积层、LeakyReLU 激活函数(Xu et al., 2020)和实例归一化处理。这样通过逐步提炼时空特征中的有效信息，最终输出单个站点的小时降水量回归预测值。



注：红色矩形区块表征编码器各级别的特征输出，绿色区块对应解码器上采样过程中的输出，白色区块为各层级编码器的特征映射，蓝色长条代表降维后的特征张量；特征区块上方的数字代表“通道数”，左侧或右侧的数字代表“时间×高度×宽度”。

图 1 DCWA-UNet 模型框架

Fig.1 Architecture of DCWA-UNet model

1.2 复合小波注意力模块 (CBAM)

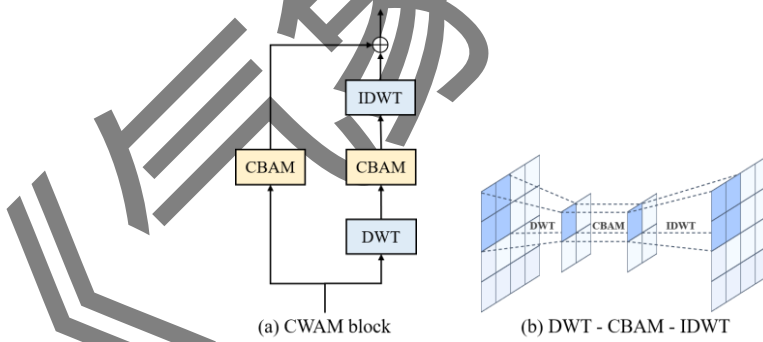


图 2(a) CWAM 模块双路径结构图，(b) DWT-CBAM-IDWT 特征尺度变化流程

Fig.2 (a) The dual-path structure of CWAM and (b) the multi-scale feature flow of DWT-CBAM-IDWT

本研究在 UNet 网络的各层级跳跃连接处植入 CWAM(图 2)。该模块通过 DWT、CBAM 和 IDWT 的协同作用，实现了多尺度特征融合机制，目的是解决气象雷达数据处理中的两个关键问题——跨尺度特征保留和局部特征增强。

CBAM 作为核心注意力单元，采用通道-空间双路注意力架构(图 3)。其工作流程包含两个阶段：通道注意力模块通过全局平均池化与最大池化捕获特征通道的全局统计特性，经共享权重的多层感知器生成通道权重向量；空间注意力模块则通过通道维度池化生成二维空间特征图，利用 7×7 卷积

核提取空间关联模式。两种注意力权重通过逐元素相乘方式级联作用于输入特征，实现特征选择与增强的协同优化。

如图 2a 所示，CWAM 采用双路径并行架构处理输入特征张量。主处理路径直接通过 CBAM 实现特征通道-空间双重注意力加权，强化显著气象特征。并行处理支路则实施特征分解—增强—重构操作：首先通过 DWT 实现可逆下采样，将输入特征分解为低频近似分量和三个方向的高频细节分量；随后对包含低频近似与高频细节的所有子带分量分别实施 CBAM 注意力增强，在降低计算复杂度的同时增强局部特征的时空相关性；最终通过 IDWT 将优化后的多尺度特征重构为与输入同维度的增强特征。其中 DWT 选用 Haar 小波基函数(代伟, 2025)，该正交基具有计算复杂度低、局部作用特性等特点，适用于降水数据强度阈值梯度变化大这一特征的精确捕获。

这种“分解—增强—重构”的设计具有双重优势：其一，通过小波域特征增强机制，在维持高频细节完整性的同时实现跨尺度特征表达；其二，注意力机制在分解子带上的应用，使模型能够以分层方式聚焦关键气象区域。下文消融试验表明，“分解—增强—重构”的处理范式可使模型在各降水强度阈值综合性能提升。

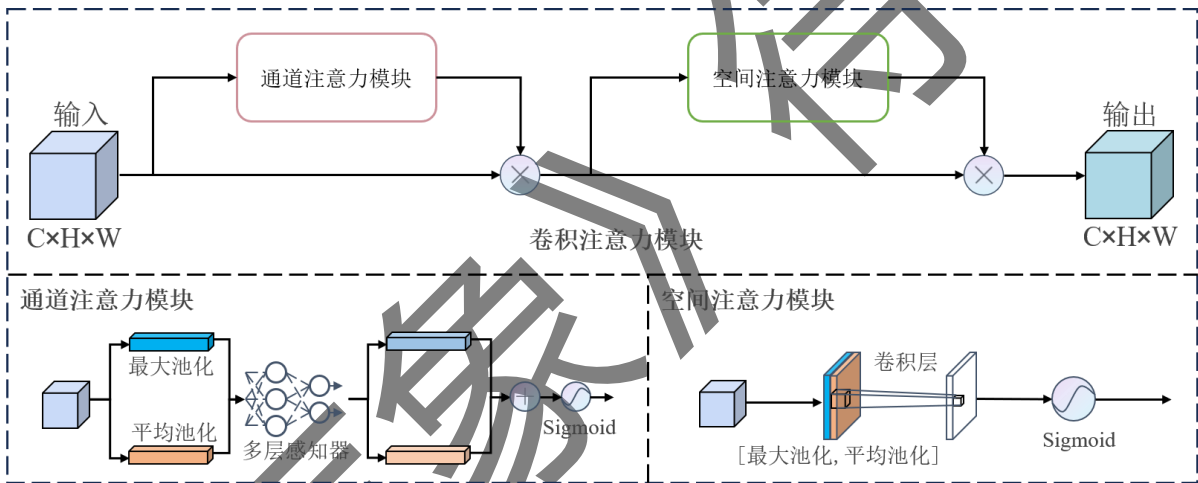


图 3 卷积注意力模块示意图

Fig. 3 Schematic diagram of the Convolutional Block Attention Module

1.3 特征聚合子网络

为有效实现雷达三维特征到站点降水量的非线性映射，设计特征聚合子网络。该网络通过层次化特征压缩与融合机制，将经编码器-解码器处理后输出的四维雷达特征张量($32 \times 10 \times 32 \times 32$ ，第一个“32”为模型中间特征提取过程中生成的特征通道数，“10”代表时间维度上的 10 个时序帧，后两个“32”分别为特征图的空间高度与空间宽度)逐步转换为单值降水预测，其核心设计包含三个关键处理阶段。首先采用线性投影层对三维空间特征进行全局信息压缩，将雷达反射率因子特征映射为时序特征向量。随后通过一维卷积层组捕获小时尺度的时序演变模式，配合 LeakyReLU 激活函数增强非线性表征能力，实例归一化层则用于稳定不同强度降水的特征分布。最后通过全连接层实现特征维度匹配，输出站点小时降水量预测值。

1.4 损失函数

表 1 不同降水强度样本占比和降水等级

Table 1 Proportion of samples with different precipitation intensities and the precipitation grades

降水强度/(mm·h ⁻¹)	占比/%	降水等级
[0.1,2)	74.56	小雨
[2,5)	14.30	中雨
[5,10)	6.40	大雨
[10,30)	4.20	暴雨
[30,∞)	0.54	大暴雨

本文参照(中华人民共和国国家质量监督检验检疫总局和中国国家标准化管理委员会, 2012; 中国气象服务协会, 2019; Shi et al, 2017)将降水强度划分为 5 个等级 (如表 1 所示), 样本分析显示不同降水等级的占比存在高度不平衡。为缓解降水数据中低降水量样本占比过高(约 74.56%)导致的模型训练偏差(严劭天, 2023), 本研究采用固定权重的加权均方误差(weighted mean squared error, WMSE)作为损失函数(Shi et al, 2017), 其定义如式(1)所示

$$WMSE = \frac{\sum_{i=1}^n Weight_i (R'_i - R_i)^2}{\sum_{i=1}^n Weight_i} \quad (1)$$

$$Weight_i = \begin{cases} 0.3, & R_i \in [0.1, 2) \\ 1.4, & R_i \in [2, 5) \\ 4.0, & R_i \in [5, 10) \\ 5.0, & R_i \in [10, 30) \\ 20.0, & R_i \in [30, \infty) \end{cases} \quad (2)$$

式中: R_i 表示第*i*个样本的实际降水强度(单位: mm·h⁻¹), R'_i 为模型预测值, $Weight_i$ 为根据降水量强度预设的分级权重系数[式(2)]。其中, 样本权重系数($Weight_i$)的确定方式为: 以数据集总样本量为分子, 分母为降水类别数与该类别样本量的乘积, 即通过“总样本量/(类别数×类别样本量)”的计算方式, 分配不同降水强度样本的权重。通过预设分级权重策略, 对有效降水样本赋予基础权重系数, 同时对[30, ∞) mm h⁻¹降水强度样本施加额外权重因子, 使其损失梯度贡献显著增强, 有效平衡了高频低值样本与稀疏极端事件的学习权重, 以避免传统均方误差函数因样本分布不平衡导致的强降水特征被抑制的问题。

2 数据及试验

2.1 数据及预处理

本研究采用四川省气象局 2019—2021 年夏季气象观测数据, 包括 2019 年 6—8 月、2020 年 6—8 月以及 2021 年 7—8 月; 区域覆盖 28°~33°N、103°~108°E。数据集包含 54 686 条雷达反射率因子拼图, 空间分辨率达 0.01° × 0.01°, 时间分辨率为 6 min; 降水数据选用覆盖四川盆地的 3443 个自动雨量站, 累计 54 227 条时间分辨率为 6 min 的观测记录。雨量站分布如图 4 所示, 研究区域站点整体较为密集和均匀, 形成了相对完善的观测网络。数据预处理包含四个关键步骤: (1)空间维度对齐: 基于雨量站经纬度坐标与雷达数据 0.01°空间分辨率, 将离散站点降水观测通过坐标映射至规则化网格体系, 建立雷达网格-雨量站的空间对应关系。具体而言, 以研究区域左下角(28°N、103°E)为坐标基准, 将雨量站经纬度与基准坐标的差值除以雷达数据空间分辨率转换为网格像素坐标, 建立每个雨量站与雷达 500×500 网格中唯一像素的对应关系, 为后续截取雷达回波区域提供

空间基准。(2)时间维度整合：将雷达观测数据和雨量站观测数据的时间分辨率均统一到 1 h。将连续 10 个 6 min 间隔的雷达观测序列沿时间轴堆叠，构建小时级三维特征立方体；将连续 10 个 6 min 间隔的雨量站观测数据相加得到 1 h 的累计降水数据。(3)区域特征提取：以各雨量站为中心，截取 32×32 像素(约 32 km×32 km)的雷达回波区域，同步保留该区域内的雷达拼图信息作为模型输入，保留站点周边关键气象特征。(4)数据标准化：基于整个数据集对雷达反射率因子和降水量进行 Min-Max 归一化。




图 4 四川盆地核心研究区域 3443 个自动雨量站分布

Fig. 4 Distribution of 3 443 automatic rain gauge stations in the core study area of the Sichuan Basin

2.2 试验设计

试验数据共包含 4020 个有效观测样本。将数据集划分为三部分：训练集(2019—2020 年 6—8 月, 70%, 共 2296 个样本)、独立测试集(2019—2020 年 6—8 月, 30%, 共 985 个样本)及验证集(2021 年 7—8 月, 共 739 个样本)。试验基于 PyTorch 1.12.1 框架和 Python 3.10.10 实现, 采用 Adam 优化器(初始学习率 0.01)配合 OneCycleLR 动态学习率调度策略(最大学习率为 0.01, 周期数为 60), 批量大小设置为 32。所有对比模型的训练均采用统一超参数配置。

为了检验 DCWA-UNet 的性能, 本研究选取 UNet、SmaAT-UNet(Trebing et al., 2021)与 SimVP(Gao et al., 2022)三种模型进行性能对比试验, 为了确保试验的公平性, 除了模型本身存在差异外, 其余所有超参数均按照上述统一标准进行设置。UNet 作为编码器-解码器结构的原始版本, 与其对比能够直观验证本研究模型的改进是否有效; SmaAT-UNet 虽然在 UNet 中引入了轻量化的自注意力机制, 但它还是单路径的特征处理与本研究的双分支架构和多尺度分解策略有明显的方法差异; SimVP 与本研究模型具有相似的编码器-解码器基础架构, 这种结构共性下模型的性能差异基本可以归因于特征处理机制的不同。DCWA-UNet 通过双分支架构和复合小波注意力机制的协同设计, 继承了 UNet 多尺度特征融合的优点, 同时重点加强了对降水核心区域的表征能力。SmaAT-UNet 通过深度可分离卷积实现模型轻量化, 但其特征压缩过程导致降水的预测精度明显下降。SimVP 凭借时序建模优势, 临界成功指数 (CSI) 在 $[30, \infty) \text{ mm} \cdot \text{h}^{-1}$ 的降水强度中表现较好, 但在其余降水区间的 CSI 较 DCWA-UNet 降低了 3.9%~7.5% (表 3)。

2.3 评估指标

为评估模型降水估计的综合性能，采用分类与回归两类评价指标。分类指标聚焦降水的判别能力，包括 CSI、命中率(POD)及虚警率(FAR)(Gilleland et al, 2009)，CSI、POD 和 FAR 的值域均为[0, 1]，CSI 越高表明模型对降水的判别精度越高，POD 越高则反映命中率越高，而 FAR 越低代表虚警率越小。

在回归指标方面，选用均方根误差(RMSE)和平均绝对误差(MAE)，用于评估模型对降水强度的估计偏差(邓国卫等, 2024)。RMSE 对强量级降水误差更敏感，能够反映模型在强量级降水下的稳定性；MAE 则体现整体误差水平，代表模型平均预测的可靠性。这两个指标分别从降水强度的判别精度和数值估计稳定性，量化模型在降水估计任务中的性能表现。

3 测试结果统计分析

表 2 给出了 DCWA-UNet 模型在不同损失函数下的降水估计性能。在 $[30, \infty)$ $\text{mm} \cdot \text{h}^{-1}$ 降水强度下，采用 WMSE 损失函数后，MAE 降低了 3.64%，FAR 从 0.0537 下降到 0.0443，说明该损失函数能有效提升强量级降水的预测精度并降低误报率；在 $[5, 10)$ $\text{mm} \cdot \text{h}^{-1}$ 降水强度下，WMSE 进一步提升了 CSI 并降低了 RMSE；在 $[10, 30)$ $\text{mm} \cdot \text{h}^{-1}$ 降水强度下，各项指标都有稳定改善，说明加权策略对不同强度的降水具有一定的适应性。即使在 $[0.1, 2)$ $\text{mm} \cdot \text{h}^{-1}$ 降水强度下，WMSE 仍然能够保持 CSI 稳定，且 MAE 和 RMSE 也有小幅度优化，没有因为偏重强量级降水而导致整体性能下降。

表 2 2019—2020 年 6—8 月研究区 DCWA-UNet 模型在测试集中不同损失函数不同降水强度阈值下的估计性能
Table 2 Comparison of prediction performance of DCWA-UNet model under different loss functions and precipitation intensity thresholds in the test set in the study area from June to August of 2019 - 2020

降水强度 / $(\text{mm} \cdot \text{h}^{-1})$	模型	CSI ↑	POD ↑	FAR ↓	MAE ↓	RMSE ↓
[0.1, 2)	DCWA-UNet (MSE)	0.7392	0.7790	0.0648	0.8864	2.0206
	DCWA-UNet (WMSE)	0.7447	0.7894	0.0707	0.8402	1.9857
[2, 5)	DCWA-UNet (MSE)	0.4767	0.6848	0.3893	0.8457	1.8619
	DCWA-UNet (WMSE)	0.4982	0.6920	0.3599	0.8007	1.8298
[5, 10)	DCWA-UNet (MSE)	0.4919	0.6790	0.3590	0.8275	1.7518
	DCWA-UNet (WMSE)	0.5190	0.6661	0.2984	0.7806	1.7186
[10, 30)	DCWA-UNet (MSE)	0.5926	0.6911	0.1940	0.9133	1.9568
	DCWA-UNet (WMSE)	0.6118	0.6939	0.1620	0.8677	1.9340
[30, ∞)	DCWA-UNet (MSE)	0.6623	0.6882	0.0537	1.3520	3.2772
	DCWA-UNet (WMSE)	0.6536	0.6740	0.0443	1.3028	3.2569

注：↑表示数值越大越好，↓表示数值越小越好；加粗数据为较优结果；下同。

表 3 展示了各模型在不同降水强度下的评估指标，DCWA-UNet 在大多数降水强度区间上表现占优：在 $[0.1, 2)$ $\text{mm} \cdot \text{h}^{-1}$ 降水强度中，CSI 比 SimVP 提升了 4.8%，MAE 降低了 4.7%；在 $[5, 10)$ $\text{mm} \cdot \text{h}^{-1}$ 和 $[10, 30)$ $\text{mm} \cdot \text{h}^{-1}$ 降水强度中，DCWA-UNet 的 CSI 分别比 SimVP 提升了 7.5%和 4.0%，其中在 $[10, 30)$ $\text{mm} \cdot \text{h}^{-1}$ 降水强度中，FAR 比 SimVP 降低了 23.1%。在 $[30, \infty)$ $\text{mm} \cdot \text{h}^{-1}$ 降水强度中，DCWA-UNet

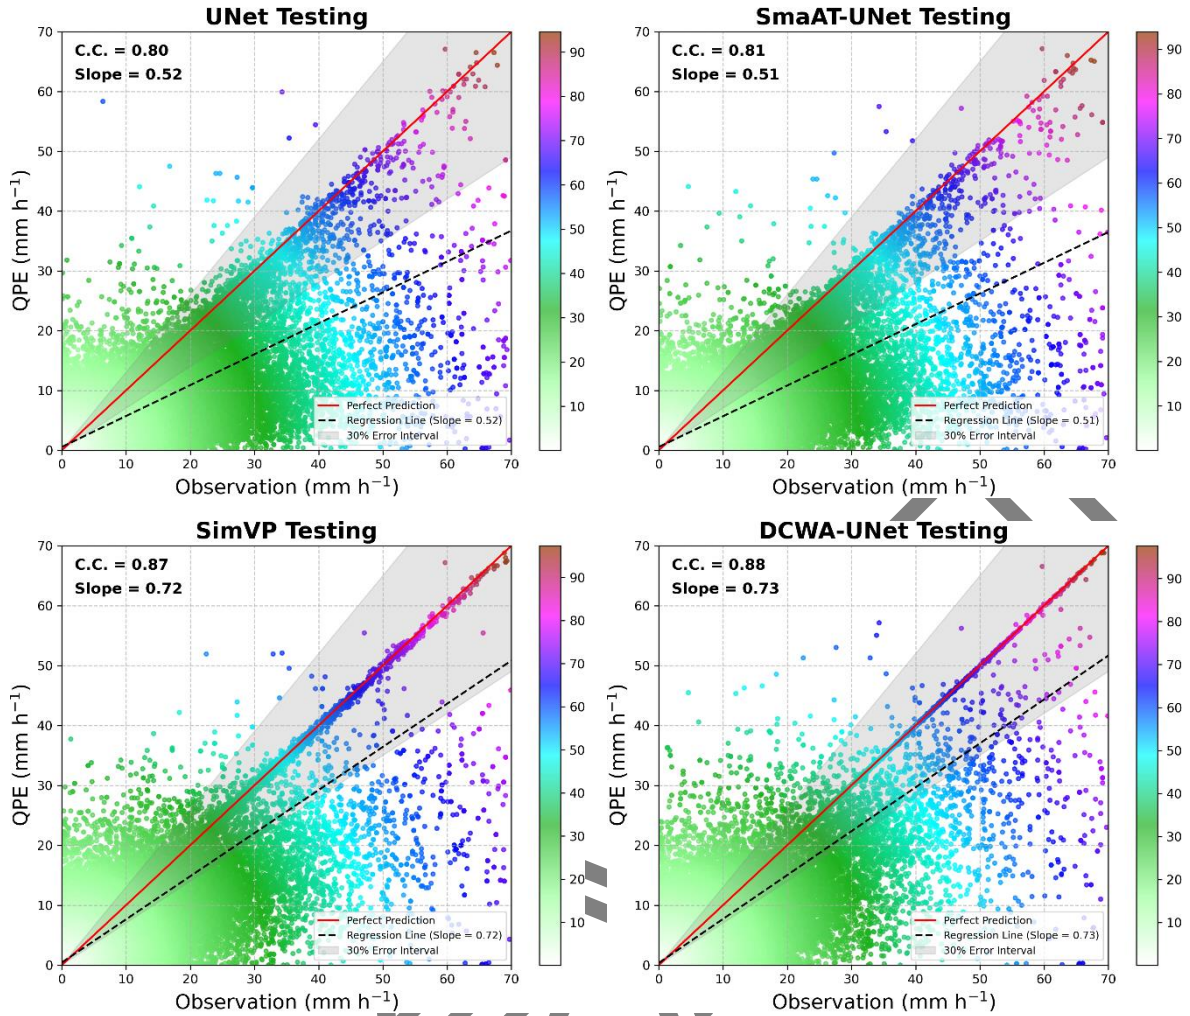
的 CSI 略低于 SimVP, 但 MAE 比 SimVP 降低了 2.0%, 比 UNet 降低了 24.8%, FAR 也比 UNet 降低了 11.9%。整体来看, DCWA-UNet 在 $[0.1, 30)$ mm h^{-1} 降水强度内的 CSI、FAR 和 MAE 持续优于其他对比模型。SimVP 仅在 $[30, \infty)$ mm h^{-1} 降水强度内的 CSI 略高于 DCWA-UNet, 这可能是因为 SimVP 的时序建模更适合强降水的持续性演变, 而 DCWA-UNet 的复合小波注意力机制虽然通过高频分量筛选提升了空间定位精度(MAE 降低了 2.0%), 但多次下采样可能在一定程度上削弱了 $[30, \infty)$ mm h^{-1} 降水强度区域的连续特征, 从而导致 CSI 略低。

表 3 2019—2020 年 6—8 月研究区各模型在测试集中不同降水强度阈值下的估计性能

Table 3 Comparison of prediction performance of different models under different precipitation intensity thresholds in the test set in the study area from June to August of 2019–2020

降水强度 /(mm · h ⁻¹)	模型	CSI ↑	POD ↑	FAR ↓	MAE ↓	RMSE ↓
[0.1, 2)	UNet	0.7427	0.8225	0.1155	1.1554	2.5217
	SmaAT-UNet	0.7182	0.7921	0.1149	1.1409	2.5117
	SimVP	0.7107	0.7525	0.0725	0.8813	1.9783
	DCWA-UNet	0.7447	0.7894	0.0707	0.8402	1.9857
[2, 5)	UNet	0.3027	0.4684	0.5390	1.1133	2.3420
	SmaAT-UNet	0.3106	0.4878	0.5390	1.1068	2.3693
	SimVP	0.4773	0.6543	0.3618	0.8427	1.8289
	DCWA-UNet	0.4982	0.6920	0.3599	0.8007	1.8298
[5, 10)	UNet	0.2729	0.4014	0.5398	1.1046	2.2769
	SmaAT-UNet	0.2737	0.4023	0.5387	1.0890	2.2530
	SimVP	0.4828	0.6554	0.3529	0.8210	1.7141
	DCWA-UNet	0.5190	0.6661	0.2984	0.7806	1.7186
[10, 30)	UNet	0.3761	0.4319	0.2558	1.2315	2.6168
	SmaAT-UNet	0.3769	0.4299	0.2463	1.2004	2.5198
	SimVP	0.5884	0.6981	0.2108	0.9041	1.9090
	DCWA-UNet	0.6118	0.6939	0.1620	0.8677	1.9340
[30, ∞)	UNet	0.5107	0.5249	0.0503	1.7331	4.0527
	SmaAT-UNet	0.5309	0.5367	0.0197	1.7258	4.0674
	SimVP	0.6661	0.6839	0.0377	1.3293	3.1946
	DCWA-UNet	0.6536	0.6740	0.0443	1.3028	3.2569

从图 5 给出的各模型在降水测试集上的散点分布来看。UNet 的相关系数为 0.80, 回归线斜率为 0.52, 散点分布比较分散, 中高量级降水区域的偏离较大。SmaAT-UNet 的相关系数略升至 0.81, 斜率为 0.51, 分布稍有改善。SimVP 的相关系数明显提高, 达到 0.87, 斜率为 0.72, 散点更集中, 中小量级降水吻合度较好。相比之下, DCWA-UNet 的相关系数最高, 为 0.88, 斜率为 0.73, 散点最为集中, 中高量级降水偏离最小, 说明其预测可靠性最好。整体而言, DCWA-UNet 在降水估计任务中的表现较优, 预测值与观测值之间的线性关系最强, 比值更合理, 精度和稳定性均优于其他三个模型。



注：红色实线为理想回归线，灰色阴影为±30%误差范围，黑色虚线为实际回归线；下同。

图5 各模型在研究区2019—2020年6—8月测试集中的降水强度估计值与观测值散点图

Fig.5 Scatter plots of predicted precipitation intensities by different models and observations in the test set in the study area from June to August of 2019 - 2020

4 消融试验

为了检验 DCWA-UNet 中复合小波注意力模块(CWAM)和简化卷积下采样分支(SCDB)的设计有效性，本章设计了渐进式消融试验，对比基线模型(UNet3D)、单模块增强模型(UNet3D+CWAM)和完整模型(UNet3D+CWAM+SCDB)的性能差异。试验结果表明(表4)，CWAM 主要提升强量级降水的预测能力，而 SCDB 则有助于保留小量级降水的特征完整性。

由表4可见，在 $[30, \infty)$ mm h^{-1} 降水强度中，只加 CWAM 的模型相比基线，MAE 降低了 2.5%，FAR 优化了 18.8%，在 $[5, 10)$ mm h^{-1} 降水强度中，其 CSI 提高了 4.8%，这说明 CWAM 通过小波分解能够有效增强降水核心区的特征表征。完整模型在 $[30, \infty)$ mm h^{-1} 降水强度中，比只加 CWAM 模型的 MAE 进一步降低了 1.9%，FAR 大幅下降了 25.3%；在 $[0.1, 2)$ mm h^{-1} 降水强度中，SCDB 使 CSI 提高了 16.9%，FAR 降低了 14.3%，这说明 SCDB 保留了原始细节，避免了 CWAM 可能带来的过度特征筛选。两个模块协同工作，使得完整模型在所有降水强度中的 CSI 和 MAE 都优于基线模型，并且在大多数降水强度区间中，POD、FAR 和 RMSE 也优于基线模型，这表明 CWAM 与

SCDB 分别从多尺度特征增强和局部细节保留两个角度，共同优化了降水预测精度。

图 6 给出了各消融模型在测试集上的散点分布，UNet3D 的相关系数为 0.86，回归线斜率为 0.72，散点整体分布比较集中，但在中高强度降水中仍然存在一定的偏离。加上 CWAM 之后，UNet3D-CWAM 的相关系数提升到 0.87，斜率仍为 0.72，散点分布略有改善，这说明 CWAM 在一定程度上提高了降水估计的准确性。而完整的 DCWA-UNet 相关系数达到 0.88，斜率为 0.73，散点最为集中，预测值与观测值的吻合度最高，尤其是在中高强度降水部分，偏离程度进一步减少，这表明 DCWA-UNet 能够更好地捕捉降水的细节特征，整体预测性能优于前两个模型。

表 4 2019—2020 年 6—8 月研究区 DCWA-UNet 在测试集中不同消融试验性能对比

Table 4 Performance comparison of DCWA-UNet ablation experiments in the test set in the study area from June to August of 2019 - 2020

降水强度 /(mm · h ⁻¹)	CWAM	SCDB	CSI ↑	POD ↑	FAR ↓	MAE ↓	RMSE ↓
[0.1, 2)	×	×	0.6939	0.7306	0.0674	0.9017	2.0126
	✓	×	0.6371	0.6758	0.0825	0.8729	2.0114
	✓	✓	0.7447	0.7894	0.0707	0.8402	1.9857
[2, 5)	×	×	0.4611	0.6643	0.3988	0.8646	1.8631
	✓	×	0.4762	0.6655	0.3740	0.8390	1.8785
	✓	✓	0.4982	0.6920	0.3599	0.8007	1.8298
[5, 10)	×	×	0.4756	0.6826	0.3893	0.8651	1.8276
	✓	×	0.4982	0.6624	0.3322	0.8148	1.7432
	✓	✓	0.5190	0.6661	0.2984	0.7806	1.7186
[10, 30)	×	×	0.5893	0.6996	0.2110	0.9290	1.9474
	✓	×	0.5952	0.6844	0.1798	0.8977	1.9489
	✓	✓	0.6118	0.6939	0.1620	0.8677	1.9340
[30, ∞)	×	×	0.6526	0.6880	0.0730	1.3621	3.2329
	✓	×	0.6685	0.6979	0.0593	1.3274	3.2559
	✓	✓	0.6536	0.6740	0.0443	1.3028	3.2569

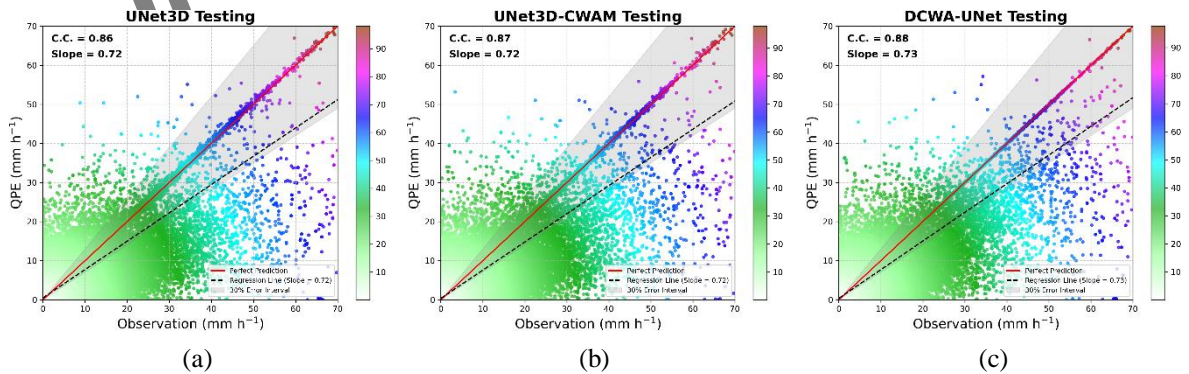
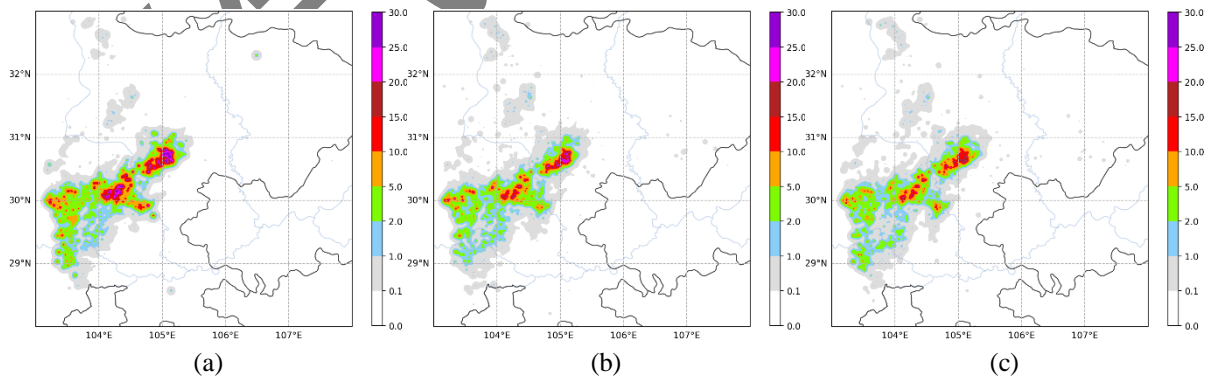


图 6 各消融模型在研究区 2019—2020 年 6—8 月测试集中的降水强度估计值与观测值散点图

Fig.6 Scatter plots of predicted precipitation intensities by (a) baseline model (UNet3D), (b) single-module enhanced model (UNet3D-CWAM) and (c) full model (DCWA-UNet) and observations

in the test set in the study area from June to August of 2019 - 2020

图 7 展示了 2020 年 6 月 15 日 23 时（北京时，下同）降水事件的观测与模型预测结果(图 7)。地面观测插值显示(图 7a)，降水区呈现出较为集中的团状结构，整体位于四川盆地西南方位，且存在多处较强的降水区域。DCWA-UNet(图 7b)和 SimVP(图 7c)均准确再现了降水主体的空间形态，但对于 $[25, \infty)$ mm h^{-1} 降水强度区域的预测二者存在差异：DCWA-UNet 的低估程度显著小于 SimVP，预测结果更接近观测值，且能捕捉到部分 $[25, \infty)$ mm h^{-1} 降水强度峰值区域；而 SimVP 不仅低估更明显，且几乎未捕捉到 $[25, \infty)$ mm h^{-1} 的降水强度峰值区。SmaAT-UNet(图 7d)和 UNet(图 7e)对降水梯度的刻画存在明显偏差，且对整体降水表现出大面积的低估现象。图 8 呈现了 2020 年 7 月 14 日 19 时降水事件的观测与模型预测结果，各模型与站点观测插值相比，同样存在不同程度的降水低估现象。但 DCWA-UNet(图 8b)在低估程度上最小，整体降水强度更接近观测值，尤其在 $30.5 \sim 31^\circ \text{N}$ 、 $106 \sim 107^\circ \text{E}$ 区域内的降水峰值区域，DCWA-UNet 较其他模型低估现象明显减轻，表明 DCWA-UNet 对强降水的响应更敏感。图 9 和图 10 分别展示了 2019 年 8 月 5 日 20 时和 2020 年 7 月 30 日 22 时两个个例各预测模型的 MAE 空间分布。在两个个例中，DCWA-UNet 的 MAE 整体均处于较低水平，仅局部有零星相对高值；SimVP 的 MAE 整体误差也较小，但相比 DCWA-UNet，部分区域高值点稍多；而 SmaAT-UNet 和 UNet 在较大范围区域内呈现成片高 MAE 分布，预测误差显著更大。整体而言，DCWA-UNet 与 SimVP 在降水空间格局的刻画上表现接近，但 SimVP 较 DCWA-UNet 对局部强降水存在更严重的低估问题；相较之下，两者的预测效果均显著优于 UNet 和 SmaAT-UNet 模型。表 5 给出了两个个例的峰值预测结果：2019 年 8 月 5 日 20 时于 31.66°N 、 104.4°E 处观测到 55.30 mm h^{-1} 降水强度峰值，DCWA-UNet 预测值(55.35 mm h^{-1})与实况误差仅 0.09%，显著优于 SimVP 及严重低估的 SmaAT-UNet 和 UNet。2020 年 7 月 30 日 22 时于 30.4°N 、 107.09°E 处观测到 44.10 mm h^{-1} 降水强度峰值，DCWA-UNet(43.96 mm h^{-1})与实况误差仅 0.32%，而 SimVP、SmaAT-UNet 和 UNet 分别存在 2.2%、6.8% 和 5.5% 的系统性低估误差。



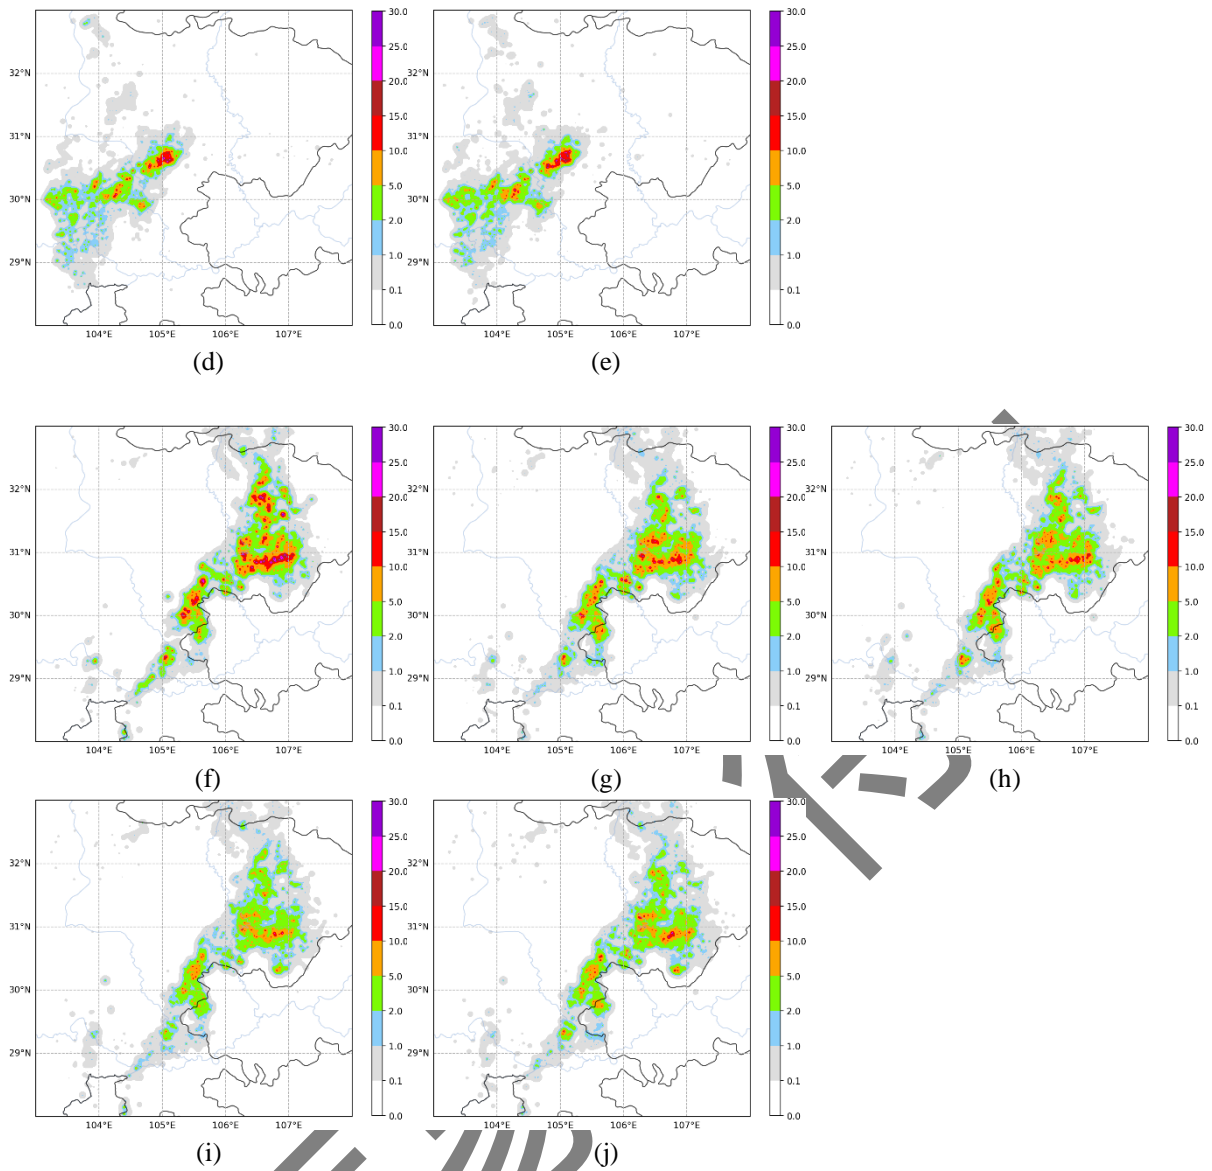


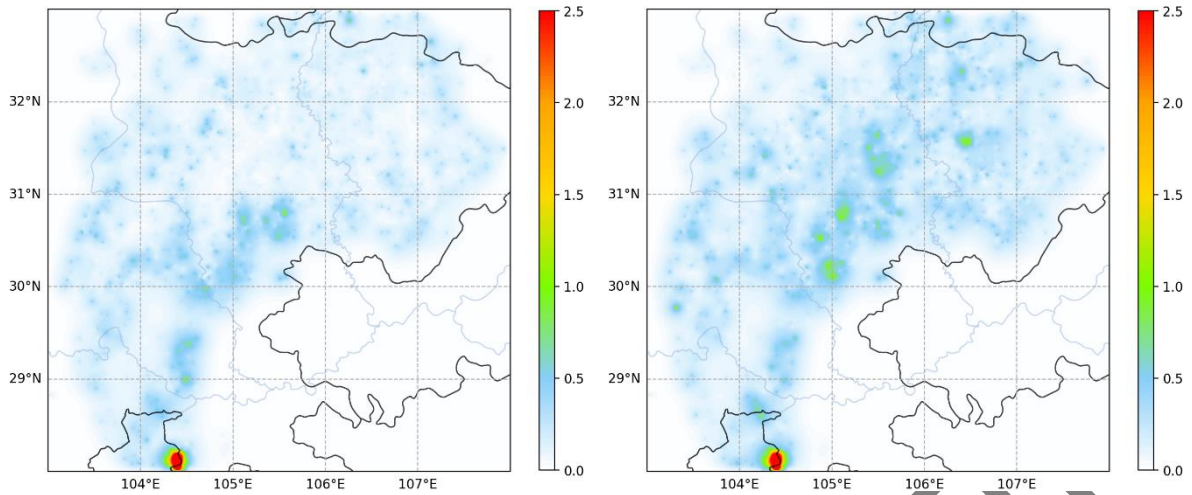
图7 2020年(a~e)6月15日23时和(f~g)7月14日19时研究区观测与模型的降水强度估计

(a, f) 观测, (b, g) DCWA-UNet, (c, h) SimVP, (d, i) SmaAT-UNet, (e, j) UNet

Fig.7 Observations and model-predicted precipitation intensities in the study area at (a-e) 23:00 BT

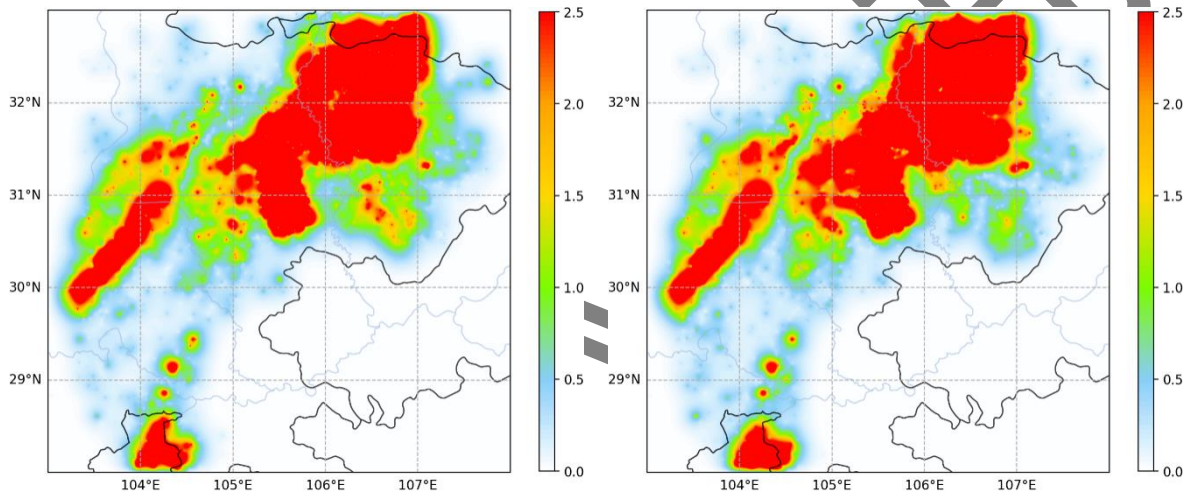
June 15 and (f-j) 19:00 BT 14 July 2020

(a, f) observation, (b, g) DCWA-UNet, (c, h) SimVP, (d, i) SmaAT-UNet, (e, j) UNet



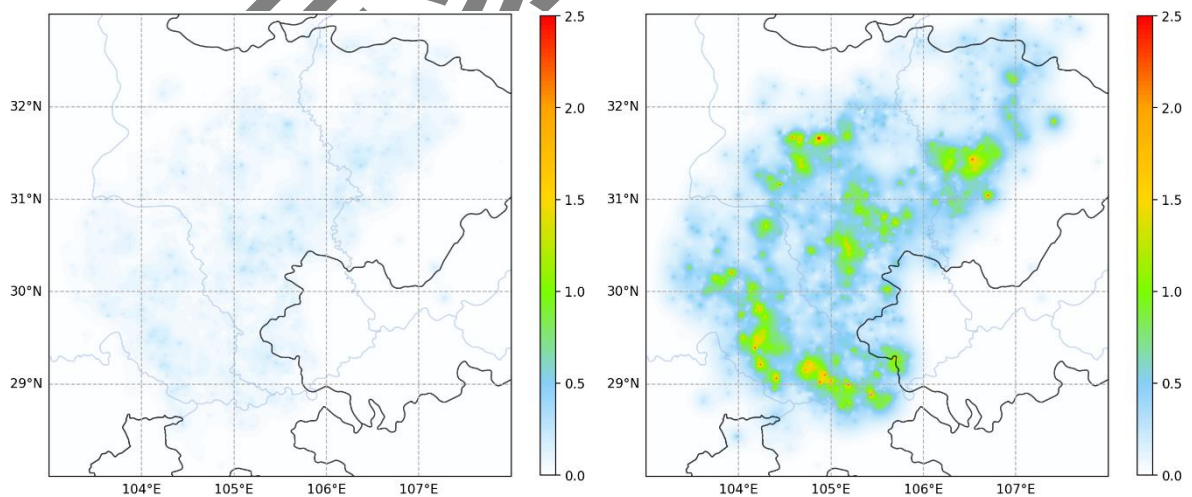
(a)

(b)



(c)

(d)



(e)

(f)

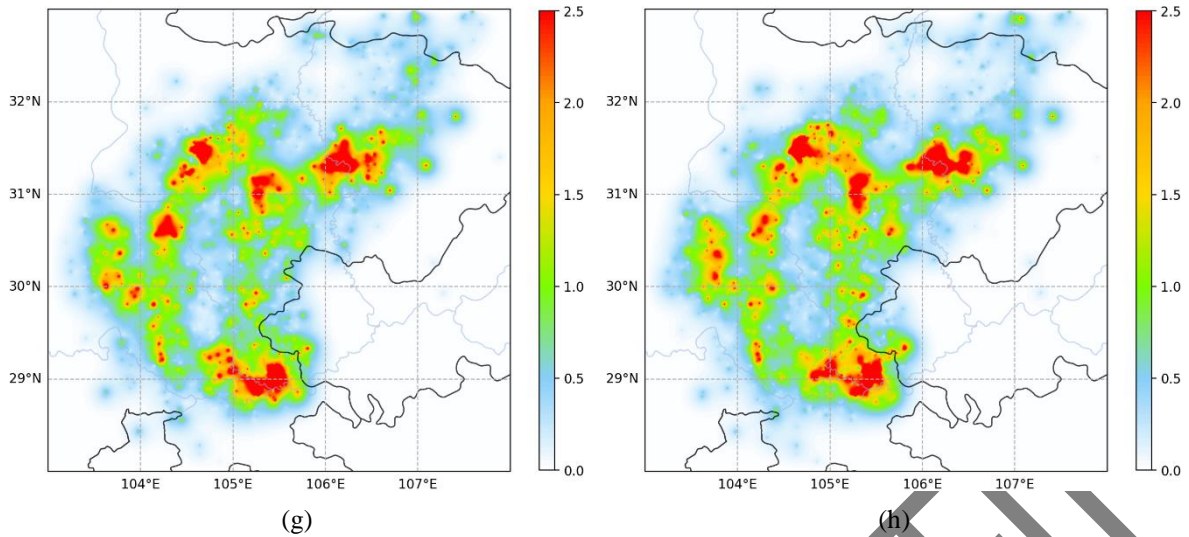


图 8 (a~d) 2019 年 8 月 5 日 20 时和 (e~h) 2020 年 7 月 30 日 22 时研究区降水预测模型降水强度 MAE 空间分布
(a, e) DCWA-UNet, (b, f) SimVP, (c, g) SmaAT-UNet, (d, h) UNet

Fig.8 Spatial distribution of MAEs of precipitation intensities predicted by (a, e) DCWA-UNet, (b, f) SimVP, (c, g) SmaAT-UNet and (d, h) Unet in the study area at (a-d) 20:00 BT 5 August 2019 and (e-h) 22:00 BT 30 July 2020

表 5 研究区个例降水强度峰值预测结果 (单位: $\text{mm} \cdot \text{h}^{-1}$)

Table 5 Predicted peak values of precipitation intensities for the cases in the study area (unit: $\text{mm} \cdot \text{h}^{-1}$)

时间 (BT)	观测降水强度峰值	DCWA-UNet	SimVP	SmaAT-UNet	UNet
2019 年 8 月 5 日 20 时	55.30	55.35	55.01	23.45	23.05
2020 年 7 月 30 日 22 时	44.10	43.96	43.14	41.12	41.67

5 结论和讨论

本研究提出了一种双分支复合小波注意力网络 DCWA-UNet, 通过协同设计双分支编码器、复合小波注意力模块 CWAM 和特征聚合子网络, 实现了从雷达反射率因子立方体到单站点小时降水量的降水预测, 其目的主要是为了缓解传统全局映射方法中因特征稀释导致的局部降水细节丢失的问题(吴雪菲等, 2022)。模型使用双分支编码结构: 主分支通过 CWAM 进行多尺度特征增强; 简化卷积下采样分支 (SCDB) 则通过三维卷积保留原始局部反射率因子细节, 避免低强度降水特征在深层网络中的衰减。特征聚合子网络采用层级降维策略, 先将三维时空特征压缩为时序向量, 再输出降水量预测值。此外, 本研究引入了加权均方误差损失函数(WMSE), 基于降水强度阈值分级赋权, 重点强化中强降水样本的梯度贡献。从消融试验结果来看, 加入 CWAM 后, 模型在 $[2, \infty) \text{mm h}^{-1}$ 降水强度中的 CSI、FAR 和 MAE 均优于基线模型, 这说明了多尺度特征增强的有效性。再加入 SCDB 分支后, 相比只加入 CWAM 的模块, 在 $[0.1, 30) \text{mm h}^{-1}$ 降水强度中的各项指标都有稳定提高, 这说明了 SCDB 分支的有效性。对比试验中, DCWA-UNet 在 $[0.1, 30) \text{mm h}^{-1}$ 降水强度中的 CSI 和 MAE 表现最好, 在 $[30, \infty) \text{mm h}^{-1}$ 降水强度中的 CSI 略低于 SimVP, 这说明模型在强量级降水的空间分布细节捕捉上还有改进空间, 可能与当前小波分解尺度和注意力权重的分配策略有关(唐卫

贞等, 2025), 不过从空间分布个例来看, SimVP 对局部强降水存在较严重的低估, 而 DCWA-UNet 的降水落区更接近观测值。后续工作可以考虑从以下三个方面优化: (1)设计自适应小波基函数, 以动态匹配不同类型的降水模式; (2)通过跨区域迁移学习提升模型对地理环境泛化能力(桑晨禹, 2023); (3)融合卫星数据(李梦迪, 2022), 利用卫星的广覆盖特性与雷达的高分辨率优势, 弥补单一数据源的不足, 进一步提高模型的适应性与估计精度(张璐等, 2022)。另外需要说明的是, 本研究没有专门针对无降水样本进行训练和优化, 而是依靠深度学习模型自身的衍生和泛化能力来识别无降水, 但在强超折射杂波、雷达盲区边缘等情况下, 无降水信号与弱降水信号比较接近, 容易出现误判, 未来可以引入无降水样本和杂波抑制技术, 进一步改善这一问题。

致谢: 感谢四川省气象局在数据资料方面的支持。

参考文献

- 陈贺, 李原园, 杨志峰, 等, 2007. 地形因素对降水分布影响的研究[J]. 水土保持研究, 14(1): 119-122. Chen H, Li Y Y, Yang Z F, et al, 2007. Research on the relationship between terrain factors and precipitation[J]. Res Soil Water Conserv, 14(1): 119-122 (in Chinese).
- 代伟, 2025. 小波变换阈值函数去噪研究[J]. 舰船电子工程, 45(1): 182-185, 190. Dai W, 2025. Research on the wavelet transform threshold function denoising[J]. Ship Electr Eng, 45(1): 182-185, 190 (in Chinese).
- 邓国卫, 孙俊, 郭海燕, 2024. CMPAS 降水融合产品在四川区域性暴雨过程监测中的质量评估[J]. 高原山地气象研究, 44(4): 119-127. Deng G W, Sun J, Guo H Y, 2024. Quality assessment of CMPAS precipitation fusion products in regional rainstorm process monitoring in Sichuan[J]. Plateau Mountain Meteor Res, 44(4): 119-127 (in Chinese).
- 井高飞, 罗丽, 肖辉, 等, 2020. 双偏振雷达在地面自动雨量观测资料质量控制中的应用研究[J]. 气象, 46(9): 1189-1198. Jing G F, Luo L, Xiao H, et al, 2020. Application research of dual-polarization radar in quality control of automatic rain Gauge[J]. Meteor Mon, 46(9): 1189-1198 (in Chinese).
- 李婍珠, 莫伟强, 洗星河, 等, 2024. 一次强对流天气的 X 波段相控阵雷达回波分析[J]. 广东气象, 46(2): 1-5. Li C Z, Mo W Q, Xian X H, et al, 2024. Analysis of the echoes of an X-band phased-array radar for a severe convective weather[J]. Guangdong Meteor, 46(2): 1-5 (in Chinese).
- 李梦迪, 2022. 雷达、卫星和地面雨量计多源降水融合算法研究[D]. 兰州: 兰州大学. Li M D, 2022. Research on the radar-satellite-gauge precipitation merging algorithm[D]. Lanzhou: Lanzhou University (in Chinese).
- 刘啸宇, 2020. 四川省山区降雨诱发型灾害风险评估研究[D]. 雅安: 四川农业大学. Liu X Y, 2020. Research on risk assessment of rainfall induced disaster in mountain area of Sichuan province[D]. Ya'an: Sichuan Agricultural University (in Chinese).
- 龙柯吉, 康岚, 黄晓龙, 等, 2025. 四川复杂地形下雷暴大风客观预报方法研究[J]. 气象, 51(1): 57-67. Long K J, Kang L, Huang X L, et al, 2025. Study on the objective forecasting method of thunderstorm gale under complex terrain in Sichuan Province[J]. Meteor Mon, 51(1): 57-67 (in Chinese).
- 龙柯吉, 康岚, 罗辉, 等, 2020. 四川盆地雷暴大风雷达回波特征统计分析[J]. 气象, 46(2): 212-222. Long K J, Kang L, Luo H, et al, 2020. Statistical analysis of radar echo characteristics of thunderstorm gales in Sichuan Basin[J]. Meteor Mon, 46(2): 212-222 (in Chinese).
- 桑晨禹, 2023. 基于深度迁移学习的双极化气象雷达降水粒子分类研究[D]. 天津: 中国民航大学. Sang C Y, 2023. Classification of precipitation particles by dual polarization weather radar based on deep migration learning[D]. Tianjin: Civil Aviation University of China (in Chinese).
- 唐卫贞, 刘波, 黄洲升, 等, 2025. 基于小波变换增强位置编码 Transformer 的空域流量预测[J]. 现代电子技术, 48(8): 127-132. Tang W Z, Liu B, Huang Z S, et al, 2025. Airspace traffic prediction based on wavelet transform enhanced position coding Transformer[J]. Modern Electron Tech, 48(8): 127-132 (in Chinese).

- 吴昊, 2022. 天气雷达回波图像数据质量控制与短临外推方法研究[D]. 南京: 南京信息工程大学. Wu H, 2022. Research on weather radar echo image data quality control and near extrapolation[D]. Nanjing: Nanjing University of Information Science and Technology (in Chinese).
- 吴雪菲, 陈爱军, 余安安, 等, 2022. 双偏振雷达评估 IMERG 对不同降水类型的观测精度[J]. 气象科技, 50(4): 476-484, 535. Wu X F, Chen A J, Yu A A, et al, 2022. Using dual-polarization radar to evaluate accuracy of GPM/IMERG in different types of precipitation process[J]. Meteor Sci Technol, 50(4): 476-484, 535 (in Chinese).
- 肖红茹, 周春花, 龙柯吉, 等, 2025. 四川盆地两次持续性极端暴雨对比分析[J]. 气象, 51(3): 269-284. Xiao H R, Zhou C H, Long K J, et al, 2025. Comparative analyses of two persistent extreme rainstorms in Sichuan Basin[J]. Meteor Mon, 51(3): 269-284 (in Chinese).
- 徐黄飞, 余洋, 胡东明, 等, 2025. 影响天气雷达反射率因子准确测量的关键因素分析及其标定效果检验[J]. 气象, 51(6): 735-743. Xu H F, Yu Y, Hu D M, et al, 2025. Analysis of key factors affecting accurate measurement of weather radar reflectivity factor and the verification of their calibration effectiveness[J]. Meteor Mon, 51(6): 735-743 (in Chinese).
- 严劭天, 2023. 面向噪声标签与类别不平衡数据的鲁棒分类算法研究[D]. 杭州: 浙江大学. Yan S T, 2023. Research on robust classification from noisy labels and class imbalance[D]. Hangzhou: Zhejiang University (in Chinese).
- 张璐, 潘畅, 谷军霞, 等, 2022. 国际主流多源融合降水实况产品的研究进展与展望[J]. 气象科技进展, 12(6): 16-27. Zhang L, Pan Y, Gu J X, et al, 2022. Advances and outlook for international mainstream multi-source precipitation merging products[J]. Adv Meteor Sci Technol, 12(6): 16-27 (in Chinese).
- 张鹏, 刘西川, 周则明, 等, 2021. 基于实测雨滴谱数据的微波链路和天气雷达降水估计关系研究[J]. 气象, 47(7): 843-853. Zhang P, Liu X C, Zhou Z M, et al, 2021. Research on precipitation estimators of microwave link and weather radar based on raindrop size distribution data[J]. Meteor Mon, 47(7): 843-853 (in Chinese).
- 赵军平, 张智察, 周方毅, 等, 2025. S 波段和 X 波段雷达定量降水估计在台风“格美”影响浙江期间的评估分析[J]. 海洋气象学报, 45(1): 12-22. Zhao J P, Zhang Z C, Zhou F Y, et al, 2025. Evaluation and analysis of quantitative precipitation estimation using S-band and X-band radars during typhoon Gemi affecting Zhejiang[J]. J Marine Meteor, 45(1): 12-22 (in Chinese).
- 中国气象服务协会, 2019. 短时气象服务降雨量等级: T/CMSA 0013—2019[S]. China Meteorological Service Association, 2019. The grade of rainfall in short time weather service:T/CMSA 0013-2019[S]. <https://www.chinamsa.org/detail.html?channelid=57&id=1106&page=1&search=%E7%9F%AD%E6%97%B6%E6%B0%94%E8%B1%A1%E6%9C%8D%E5%8A%A1%E9%99%8D%E9%9B%A8%E9%87%8F%E7%AD%89%E7%BA%A7&dj=undefined> (in Chinese).
- 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会, 2012. 降水量等级: GB/T 28592—2012[S]. 北京: 中国标准出版社. General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. 2012. Grade of precipitation:GB/T 28592-2012[S]. Beijing: China Standards Press (in Chinese).
- 钟琦, 梁红丽, 代刊, 等, 2025. 降水预报机器学习订正及其在分类型降水测试的效果研究[J]. 气象, 51(8): 914-927. Zhong Q, Liang H L, Dai K, et al, 2025. Study on machine learning correction of precipitation forecast and its validation on two types of precipitation[J]. Meteor Mon, 51(8): 914-927 (in Chinese).
- Chen W S, Hua W J, Ge M S, et al, 2023. Severe precipitation recognition using attention-UNet of multichannel Doppler radar[J]. Remote Sens, 15(4): 1111.
- Crosson W L, Duchon C E, Raghavan R, et al, 1996. Assessment of rainfall estimates using a standard Z-R relationship and the probability matching method applied to composite radar data in central Florida[J]. J Appl Meteor Climatol, 35(8): 1203-1219.
- Fang Z L, Zhong Q, Chen H M, et al, 2025. Improving the fine structure of intense rainfall forecast by a designed generative adversarial network[J]. Geosci Model Dev, 18(23): 9723-9749.

-
- Gao Z Y, Tan C, Wu L R, et al, 2022. SimVP: simpler yet better video prediction[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans: IEEE:3160-3170.
- Gilleland E, Ahijevych D, Brown B G, et al, 2009. Intercomparison of spatial forecast verification methods[J]. *Wea Forecasting*, 24(5): 1416-1430.
- Huangfu J, Hu Z Q, Zheng J F, et al, 2024. Study on quantitative precipitation estimation by polarimetric radar using deep learning[J]. *Adv Atmos Sci*, 41(6): 1147-1160.
- Li W Y, Chen H N, Han L, 2023. Polarimetric radar quantitative precipitation estimation using deep convolutional neural networks[J]. *IEEE Trans Geosci Remote Sens*, 61: 4102911.
- Ronneberger O, Fischer P, Brox T, 2015. U-Net: convolutional networks for biomedical image segmentation[C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015. Munich: Springer.
- Shi X, Gao Z, Lausen L, et al. 2017. Deep learning for precipitation nowcasting: A benchmark and a new model[J]. *Advances in neural information processing systems*, 30.
- Sokol Z, Szturc J, Orellana-Alvear J, et al, 2021. The role of weather radar in rainfall estimation and its application in meteorological and hydrological modelling—a review[J]. *Remote Sens*, 13(3): 351.
- Trebing K, Stańczyk T, Mehrkanoon S, 2021. SmaAt-UNet: precipitation nowcasting using a small attention-UNet architecture[J]. *Pattern Recogn Lett*, 145: 178-186.
- Wen Y Q, Zhang J, Wang D, et al, 2024. A quantitative precipitation estimation method based on 3D radar reflectivity inputs[J]. *Symmetry*, 16(5): 555.
- Woo S, Park J, Lee J Y, et al, 2018. CBAM: convolutional block-attention module[C]//15th European Conference on Computer Vision (ECCV). Munich: Springer:3-19.
- Xu J, Li Z S, Du B W, et al, 2020. Reluplex made more practical: leaky ReLU[C]//IEEE Symposium on Computers and Communications. Rennes: IEEE:1-7.
- Yao T, Pan Y W, Li Y H, et al, 2022. Wave-ViT: unifying wavelet and transformers for visual representation learning[C]//17th European Conference on Computer Vision–ECCV 2022. Tel Aviv: Springer.
- Zhang C J, Wang H Y, Zeng J, et al, 2020. Short-term dynamic radar quantitative precipitation estimation based on wavelet transform and support vector machine[J]. *J Meteor Res*, 34(2): 413-426.
- Zhang J, Howard K, Langston C, et al, 2011. National Mosaic and Multi-Sensor QPE (NMQ) system: description, results, and future plans[J]. *Bull Am Meteor Soc*, 92(10): 1321-1338.
- Zhong Q, Fang Z L, Chen H M, et al, 2025. Fusing multi-scale numerical model forecasts to improve short-term intense rainfall forecast with a deep learning rain network[J]. *J Meteor Res*, 39(6): 1441-1462.