

基于高效卷积神经网络的降水临近预报

李磊菁^{1,2}, 孙飞飞³, 李建柱¹, 张 婷¹, 冯 平¹, 付体江², 王永涛²

(1. 天津大学水利工程智能建设与运维全国重点实验室; 2. 贵州省水利科学研究院; 3. 中水北方勘测设计研究有限责任公司)

摘要:融合卷积神经网络的 U-Net 模型和 Efficient-Net 框架构建了轻量化 Efficient-UNet 模型,以柳林实验流域为例,对典型降雨过程进行 1 h 预见期雷达回波外推,基于全局动态校正、动态分级校正和动态分区校正方法,利用实测降水数据开展定量降水预报,并与 U-Net、SmaAt-UNet 和 3 层编码器-解码器结构的 Simple-UNet 模型的预报结果对比。结果表明:在 1h 预见期内,Efficient-UNet 与 U-Net 模型回波外推效果相似,但 Efficient-UNet 模型对回波轮廓和变化趋势有更好的外推性能, SmaAt-UNet 模型则对强回波有更高的外推精度, Simple-UNet 模型的外推效果最差;动态分级和动态分区校正方法的降水预报精度差别不大,与全局动态校正方法相比,降水预报精度均有所提升, Efficient-UNet 模型的降水预报精度与 U-Net 模型较为一致,且优于其他模型,但 Efficient-UNet 模型参数更少,占用的计算资源也更少。

关键词:降水预报;卷积神经网络;天气雷达;回波外推;U-Net 模型;Efficient-Net 模型;柳林实验流域

中图分类号:P456.1 文献标志码:A 文章编号:1004-6933(2026)05-0205-10

Precipitation nowcasting based on efficient convolutional neural network//Li Leijiang^{1,2}, Sun Feifei³, Li Jianzhu¹, Zhang Ting¹, Feng Ping¹, Fu Tijiang², Wang Yongtao² (1. State Key Laboratory of Hydraulic Engineering Intelligent Construction and Operation, Tianjin University; 2. Guizhou Water Conservation Science and Research Institute; 3. China Water Resources Beifang Investigation, Design and Research Co., Ltd.)

Abstract: A lightweight Efficient-UNet model was developed by integrating the U-Net model of convolutional neural network with the Efficient-Net framework. Taking the Liulin Experimental Watershed as a case study, radar echo extrapolation with 1h lead time was performed for representative rainfall events. Based on measured precipitation data, quantitative precipitation forecasts were further conducted using the global dynamic correction, dynamic intensity-class correction, and dynamic regional correction methods. The forecast results of the Efficient-UNet model were systematically compared with those of the U-Net model, the SmaAt-UNet model, and the Simple-UNet model with a three-layer encoder-decoder structure. The results showed that, within 1h lead time, the Efficient-UNet model achieved radar echo extrapolation performance comparable to the U-Net model, and exhibited superior capability in predicting the spatial extent and temporal evolution of radar echoes. The SmaAt-UNet model provided higher accuracy for strong echo, whereas the Simple-UNet model yielded the poorest overall extrapolation performance. The precipitation forecasting accuracies obtained using the dynamic intensity-class and dynamic regional correction methods were comparable, and both outperformed the global dynamic correction method. The precipitation forecasting accuracy of the Efficient-UNet model was generally consistent with the U-Net model and superior to those of the other models, whereas, the Efficient-UNet model required substantially fewer model parameters and lower computational resources.

Key words: precipitation forecasting; convolutional neural network; weather radar; echo extrapolation; U-Net model; Efficient-Net model; the Liulin Experimental Watershed

受气候变化、自然变迁和人类活动的影响,极端降水导致洪涝灾害频发,此类灾害往往具有突发性强、预见期短、灾害损失严重等特点^[1-2]。准确、及时

的降水预报对防洪减灾至关重要^[3]。传统的降水监测主要采用雨量计,其有限的时空代表性难以反映降水的空间变异性,从而影响降水和洪水的预报

基金项目:天津市科技计划项目(24ZYCGYS00730);国家自然科学基金项目(52279022);贵州省科技厅项目(黔科合服企[2024]016号)

作者简介:李磊菁(1998—),男,工程师,博士研究生,主要从事水文水资源研究。E-mail:llileijiang@tju.edu.cn

通信作者:李建柱(1981—),男,教授,博士,主要从事水文水资源研究。E-mail:lijianzhu@tju.edu.cn

精度^[4]。基于雷达回波外推的降水临近预报通过追踪反射率的图像变化趋势,可对局部地区未来0~2h降水发展趋势和演变过程进行精确、及时的预报^[5],是目前降水临近预报的主要途径。

近年来,机器学习和深度学习在诸多领域得到广泛应用,并在气象领域取得显著成效^[6-8]。利用深度学习进行雷达回波外推,其本质可归结为时间序列预测任务,即基于历史时刻的雷达回波序列,通过神经网络模型来预测未来时刻的雷达回波图像^[9]。Shi等^[10]将ConvLSTM模型应用于回波序列预测,为深度学习方法的降水临近预报研究奠定了重要基础;Agrawal等^[11]将雷达回波外推转换为图像预测问题,采用引入卷积神经网络(CNN)的U-Net模型进行回波预测,其结果优于传统外推方法;Han等^[12]应用U-Net和TrajGRU模型开展雷达回波外推,取得了相似的预报效果,且U-Net模型消耗的计算资源更少。由于U-Net模型结构简单,可根据需求灵活对网络结构进行调整,因此,大多数研究均以在该基础上添加复杂的功能结构为主要思路^[13-15]。例如:Geng等^[16]提出结合多分支特征提取的U-Net模型,Tan等^[17]提出双层拼接结构的U-Net模型,均提升了回波外推精度,但数量庞大的模型参数消耗了更多的计算资源,降低了模型应用的普适性。提升模型预报精度和应用便捷度是当前研究的重点^[18]。Efficient-Net模型^[19]的出现为U-Net模型轻量化提供了思路,其通过复合缩放使网络在保持较高精度的同时,显著减少了模型的参数和计算成本。Efficient-UNet(下文简称“Eff-UNet”)模型作为一种结合U-Net和Efficient-Net模型优势的轻量化架构,已在多个视觉任务中展现出潜力,如在降水误差校正^[20]、遥感图像变化检测^[21]、图像特征分类^[22]等方面的应用,验证了其在特征提取与分类任务中的高效性。然而,现有研究多集中于静态图像处理或分类,对于雷达回波外推的时空序列预测问题,Eff-UNet模型的特征提取能力、对运动模式的刻画效果以及轻量化优势,还有待深入探究。

雷达定量降水估计是实现定量降水预报的主要方法,其通过建立反射率因子(Z)与降水强度(R)间的幂指数关系来计算降水量^[23]。但降水在空间和时间尺度上具有高度变异性^[24-25],导致传统定量降水估计方法的准确性较低。为提升 Z - R 关系的估计精度,已有研究提出了多种动态校正方法。早期研究多采用基于雨量站实测数据的全局动态校正方法,通过逐时优化 Z - R 关系参数 A 和 b ,可缓解降水估计误差随小时雨量的明显变化^[26]。然而,该方法忽略了降水类型(如层状云降水与对流性降水)

的差异。为此,Wu等^[27]提出了基于雷达回波顶高分类的动态 Z - R 关系,通过对不同降水类型采用不同的参数集来提升估计精度。此外,考虑到降水空间分布的不均匀性,李佳慧等^[28]采用瓦片分区方法对北京地区降水估计区域进行网格细分,并利用雷达和自动站数据动态拟合 Z - R 关系,结果表明,结合地理分区能有效提升复杂地形的降水估计精度。Kou等^[29-30]也采用类似的空地联合动态校正思路,提升了定量降水估计的精度。已有研究大多基于气象信息丰富的大面积区域,未能充分考虑小流域内降水强度与空间分布的耦合变异特性。针对小流域,从空间和时间两个维度综合提升降水估计的精度是当前研究的难点。

本文面向小流域强对流临近预报中的应用难题,基于U-Net模型在降水临近预报领域的成功应用,在编码器中融入Efficient-Net框架,获得轻量化Eff-UNet模型。对柳林实验流域典型降水过程进行1h预见期雷达回波外推,利用实测降水数据,通过全局动态校正、动态分级校正和动态分区校正方法进行降水预报,并与传统U-Net、SmaAt-UNet和3层编码器-解码器结构的Simple-UNet模型降水预报结果进行对比,评估高效轻量化Eff-UNet模型对降水临近预报的适用性。

1 研究方法

1.1 深度学习回波外推模型

融合U-Net模型和Efficient-Net框架构建轻量化Eff-UNet模型。使用Efficient-Net中的MBConvBlock模块对U-Net的解码器结构进行修改和优化,获得Eff-UNet模型。在3×3网络结构前利用1×1卷积升维,在3×3网络结构后增加了一个关于通道的注意力机制,最后利用1×1卷积降维。与U-Net模型相比,Eff-UNet模型的参数数量减少约66.2%;模型文件大小为100.91MB,缩减约66.8%;平均每轮训练用时为42s,缩短约52.7%,显著减小了内存占用,提高了模型的训练效率。模型中引入的挤压-激励(SE)注意力机制可自适应加权重要特征通道,提升对关键气象系统的识别能力;MBConvBlock模块的深度可分离卷积使模型在保持表达能力的同时,显著减少了参数数量;基于U-Net模型在时间序列预测任务中的成功应用,编码器-解码器结构在编、解码路径中分别实现了时空特征的提取和对空间细节的预测,编码器与解码器间的跳跃连接保留了不同尺度的特征信息,避免了空间细节丢失,使得Eff-UNet模型可以应用于雷达回波外推。

本文将U-Net、SmaAt-UNet^[31]和3层编码器-解

码器结构的 Simple-UNet 模型作为对照模型,以评价 Eff-UNet 模型效果。

1.2 损失函数

雷达回波外推的深度学习模型常用的损失函数为均方误差 (MSE), 但容易造成预测图像模糊化^[32], 使强回波的外推效果较差。平衡均方误差 (BMSE)^[33] 可以在训练过程中赋予强回波更高的权重系数, 提升对强回波的外推效果, 在一定程度上减弱预报时长造成的预测图片模糊效应。因此, 本文参照 Han 等^[33] 的研究方法, 以 BMSE 作为损失函数并计算权重, 基于雷达反射率因子的大小进行分段赋值。

1.3 模型训练

基于 PyTorch 环境, 在 NVIDIA GeForce RTX 3050 上进行 1h 预见期雷达回波外推, 输入过去 1h 的 10 帧回波图, 预测未来 1h 的 10 帧回波图, 以此滚动预测全过程回波序列。采用 Adam 优化器进行训练, 共训练 200 个轮次; 采用学习率调节器, 初始学习率设置为 0.001, 当损失函数值在 4 个周期内没有增加时, 学习率自动减小 10%; 批处理大小设置为 4。基于本文实例验证研究区 (柳林实验流域) 雷达回波资料, 得到不同模型训练与验证的损失函数曲线, 如图 1 所示。所有模型在训练初期均表现出损失函数值快速下降, 表明模型能够迅速学习雷达回波序列的基本时空演变模式。在约 80 个轮次后, 训练期和验证期的损失函数值均缓慢下降, 表明模型在当前架构和数据集下已充分学习, 在约 120 个轮次后, 损失函数波动显著减少并趋于收敛。

1.4 定量降水估计方法

雷达定量降水估计有多种 Z-R 关系校正方法, 主要包括基于雨量站实测数据的动态校正、考虑降水类型的分类校正以及融合地形因子的空间校正等^[27-29]。本文在借鉴动态校正方法的基础上, 采用动态分级和动态分区校正方法, 进一步考虑了降水时空变异性的校正思路, 并保持逐时快速更新的

特点。

1.4.1 全局动态校正方法

动态校正 Z-R 关系是指利用雷达组合反射率因子和雨量站逐时实测降水资料, 建立实测降水-雷达回波数据对, 通过实测降水数据动态校正降水计算结果, 确定计算参数, 以此估算流域面雨量。具体方法为: 通过调节动态变化参数 A、b, 使降水计算结果与实测降水数据间误差判别函数值 (CTF)^[7] 最小, 得到适用于该时段的最佳参数。参数 A 的变化范围一般为 16~1200, 以 20 为间隔, 取 60 个 A 值; 参数 b 的变化范围一般为 1~2.87, 以 0.05 为间隔, 取 38 个 b 值, 每张回波图共计算 60×38 次。动态校正 Z-R 关系建立在逐时快速更新资料的基础上, 采用上一时段最优的 Z-R 关系计算下一时段的降水。

1.4.2 动态分级校正方法

反射率因子 (Z) 与雨滴的体积大小直接相关, 不同降水类型的雨滴分布存在显著差异, 对 Z-R 关系的计算精度产生影响, 因此对不同等级的反射率因子需采用不同的计算参数。动态分级校正 Z-R 关系建立在全局动态校正的基础上, 将回波反射率因子划分为 6 个等级: >0~10 dBZ、>10~20 dBZ、>20~30 dBZ、>30~40 dBZ、>40~50 dBZ、>50 dBZ, 利用动态校正方法获得各等级反射率因子对应的计算参数, 并用于下一时段的计算。该方法基于整体反射率因子分布区间, 从以稳定层状云降水为主的弱回波向以强对流降水为主的强回波逐步分级过渡, 量化不同强度反射率因子的降水微物理过程, 并考虑了降水强度和降水性质在短时间内的延续性, 可有效应对数据中强反射率因子样本稀疏的问题, 进而精准捕捉短时强降水的回波反射率因子。率定的研究区各级别反射率因子计算参数如表 1 所示, 以 30 dBZ 为分界点, 计算参数呈现出不同的分布特征。30 dBZ 以下反射率因子的参数 A 普遍小于 300, 参数 b 约为 1.2; 30 dBZ 以上反射率因子参数 A 和 b 显著增大, 呈现出层状与对流性降水混合的参数特征。




图 1 不同模型训练与验证的损失函数曲线

Fig. 1 Loss function curves for different model training and validation

表 1 不同等级反射率因子对应的计算参数
Table 1 Calculation parameters corresponding to different levels of reflectivity factors

反射率因子/dBZ	参数 A 范围	参数 A 均值	参数 b 范围	参数 b 均值
>0~10	76~356	240	1.07~1.63	1.26
>10~20	136~336	270	1.10~1.75	1.15
>20~30	176~496	262	1.05~1.84	1.21
>30~40	196~376	370	1.35~2.65	1.55
>40~50	256~476	350	1.37~1.93	1.66
>50	236~576	516	1.75~2.10	1.81

1.4.3 动态分区校正方法

动态分区校正 $Z-R$ 关系综合考虑了降水的时间和空间变化特点,按照流域泰森多边形分区结果对雷达回波图进行地理分区,每个区域对应一个地面雨量监测站点,建立各站点与回波分区的数据对关系,再应用全局动态校正的 $Z-R$ 关系计算各分区的最佳参数,用于下一时段的降水计算。该方法可同时捕捉降水的空间异质性和时间演变特性,提升了对复杂下垫面的适应性。

1.5 评价指标

采用命中率 (POD)、虚警率 (FAR)、临界成功指数 (CSI) 和 F1 分数等二元评价指标评价雷达回波外推精度^[23]。POD、FAR、CSI 和 F1 分数的范围均为 0~1,POD、CSI 和 F1 分数的最优值为 1,FAR 的最优值为 0。采用预报降水与实测降水数据间的平均绝对误差 (MAE)、相关系数 (r)、平均偏差 (BIAS) 评价降水预报精度^[34]。

2 实例验证

2.1 研究区概况与数据来源

2.1.1 研究区概况

选择河北省邢台市内丘县柳林实验流域为研究区进行验证 (图 2)。流域出口位于 $37^{\circ}17'N$ 、 $114^{\circ}21'E$,流域内共有 5 个雨量站。该流域控制河段属海河流域子牙河水系小马河,流域西高东低,面积为 57.4 km^2 ,主河道长 13.2 km ,坡度为 30.9 ‰ 。流域地处半干旱半湿润气候区,多年平均降水量为 594.5 mm ,多年平均径流深为 80.7 mm ,降水与洪水多集中于 6—9 月。受太行山地形影响,局地短历时强降水时有发生。

2.1.2 雷达资料及数据预处理

雷达回波资料来源于我国新一代多普勒天气雷达监测网河北省石家庄市的 S 波段 Z9311 雷达站。该雷达站位于 $38^{\circ}21'N$ 、 $114^{\circ}42'50''E$,采用 VCP21 体扫模式,有效探测半径为 230 km ,可在 6 min 内完成 9 个不同仰角的扫描。柳林实验流域位于该雷达 120 km 探测半径范围内,雷达扫描数据具有较高的

质量。雷达基数据经过编码转换、杂波抑制、衰减订正、地物遮挡订正、坐标转换后,形成反射率混合扫描数据图,将处理完成的回波图裁剪至流域所在区域,范围为 128×128 格点,覆盖经纬度范围为 $36^{\circ}47'24''N\sim37^{\circ}30'36''N$ 、 $113^{\circ}36'36''E\sim114^{\circ}53'24''E$ 。将 2018—2021 年 2 万帧降水时段回波图,按照 8 : 2 的比例划分为训练集和验证集,用于模型训练和验证;以 2022 年 3 场典型降水场次的回波图作为测试集,用于检验模型预测效果。




图 2 柳林实验流域概况

Fig. 2 Overview of the Liulin Experimental Watershed

2.1.3 典型降水场次

降水数据来源于河北省邢台水文勘测研究中心。共收集了 2022 年汛期 3 场降水数据,基本信息如表 2 所示。3 场典型降水历时均约为 10h,最大小时降水量和降水总量存在一定的差异,具有一定代表性。将 3 场降水回波过程作为测试集用于雷达回波外推,验证深度学习模型的适用性。

表 2 降水基本信息

Table 2 Information of rainfall events

降水场次编号	开始时间	结束时间	降水总量/mm	最大小时降水量/mm
20220727	12:00	22:00	42.19	12.49
20220808	06:00	15:00	130.16	38.85
20221001	09:00	19:00	40.09	8.57

2.2 结果与分析

2.2.1 回波外推精度评价

对 3 场典型降水开展 1 h 预见期回波外推。选用回波反射率因子的阈值为 10、20、30 dBZ,计算二元评价指标,对回波外推效果进行评价,结果如表 3 所示。各深度学习模型对于 10 dBZ 阈值的外推效果显著优于 30 dBZ 阈值,对于降水强度和降水总量较小的 20220727 和 20221001 场次降水,各阈值下的评价指标均优于降水强度和降水总量较大的 20220808 场次降水,表明采用的深度学习模型对偏弱回波的外推效果更好。此外,2018—2021 年柳林

表 3 不同回波反射率因子阈值下 1 h 预见期回波外推精度评价指标值

Table 3 Evaluation index values of 1 h lead time echo extrapolation accuracy under different echo reflectivity factor thresholds

降雨场次	模型	POD			FAR			CSI			F1 分数		
		10 dBZ	20 dBZ	30 dBZ	10 dBZ	20 dBZ	30 dBZ	10 dBZ	20 dBZ	30 dBZ	10 dBZ	20 dBZ	30 dBZ
20220727	U-Net	0.84	0.74	0.32	0.16	0.38	0.64	0.72	0.47	0.16	0.73	0.52	0.18
	SmaAt-UNet	0.82	0.75	0.33	0.21	0.36	0.65	0.68	0.48	0.18	0.72	0.56	0.16
	Simple-UNet	0.62	0.43	0.11	0.38	0.56	0.81	0.51	0.32	0.08	0.43	0.22	0.08
	Eff-UNet	0.84	0.82	0.27	0.20	0.34	0.62	0.69	0.53	0.15	0.70	0.58	0.18
20220808	U-Net	0.66	0.65	0.19	0.46	0.64	0.76	0.38	0.27	0.09	0.43	0.31	0.12
	SmaAt-UNet	0.68	0.52	0.10	0.42	0.60	0.80	0.36	0.26	0.07	0.44	0.26	0.10
	Simple-UNet	0.56	0.33	0.02	0.63	0.75	0.95	0.21	0.16	0.01	0.34	0.18	0.03
	Eff-UNet	0.73	0.50	0.05	0.47	0.63	0.96	0.43	0.21	0.01	0.49	0.28	0.02
20221001	U-Net	0.85	0.66	0.17	0.21	0.39	0.78	0.69	0.42	0.07	0.71	0.47	0.09
	SmaAt-UNet	0.84	0.68	0.18	0.22	0.40	0.80	0.65	0.43	0.06	0.69	0.46	0.08
	Simple-UNet	0.66	0.51	0.10	0.35	0.56	0.91	0.52	0.28	0.02	0.51	0.31	0.03
	Eff-UNet	0.88	0.79	0.23	0.20	0.38	0.87	0.70	0.51	0.04	0.72	0.55	0.06

实验流域中小降水偏多,构建的训练集中较弱回波总量偏大,导致深度学习模型对弱回波有更好的外推效果。总体来看, Eff-UNet 模型在各场次降水中均能取得与 U-Net 模型接近的回波外推精度,对反射率因子阈值为 10 dBZ 回波外推精度的评价指标值比 SmaAt-UNet 模型更优; Simple-UNet 模型由于精简了模型层数,其特征提取能力减弱,回波外推效果与其他模型相比差别显著。对于 20221001 场次降水, 10 dBZ 和 20 dBZ 阈值下 Eff-UNet 模型的各项评价指标均优于 U-Net 模型,这是由于 MBConvBlock 模块的通道注意力机制能够自适应增强对弱回波特征的表征能力,同时该场次的降水回波过程变化平缓且以弱回波为主,与训练数据分布高度吻合,使得 Eff-UNet 模型的多尺度特征提取能力得到充分发挥。然而, Eff-UNet 模型对 20220808 场次降水的回波外推精度评价指标值比 U-Net 模型稍差,且对 30 dBZ 阈值的评价指标值显著变差。其原因可能是该场降水的回波变化过程剧烈,且极端值较多,而 Eff-UNet 模型采用的深度可分离卷积结

构在极端值特征提取上存在固有局限,对高强度回波的局部响应能力不及标准卷积。

2.2.2 回波外推可视化分析

对 3 场降水 1 h 预见期回波外推个例进行可视化分析,以直观评价各模型对回波变化趋势和细节的外推性能,结果如图 3 所示(图中输入回波为过去 1 h 回波图, 真实回波为未来 1 h 回波图)。20220727 场次降水的整体回波反射率因子集中在 30 dBZ 以下,局部存在反射率因子约为 40 dBZ 的回波。在 30 min 内,各模型对于反射率因子约为 15 dBZ 的回波轮廓均能取得稳定的外推效果,且对于反射率因子约为 40 dBZ 的局部强回波预测较为准确;30 min 之后, Eff-UNet 模型仅能外推出反射率因子为 35 dBZ 以下的回波,而 U-Net 和 SmaAt-UNet 模型仍能外推出反射率因子约为 40 dBZ 的回波,对强回波有更高的外推精度,但 Eff-UNet 模型外推的回波轮廓更接近真实值。20220808 场次降水出现反射率因子约为 50 dBZ 的强回波,且变化过程细节丰富。在 30 min 内, Eff-UNet 模型可外推出强回波




图 3 回波外推个例分析结果

Fig. 3 Results of case analysis of echo extrapolation

轮廓和变化过程,但各模型预测的最大回波反射率因子均未超过 45 dBZ;30 min 之后,这种低估趋势更加明显,所有模型在 60 min 时外推的回波反射率因子大多为 30 dBZ 以下。20221001 场次降水的整体回波反射率因子以 30~40 dBZ 为主,且变化过程较为缓慢,SmaAt-UNet 模型在 60 min 时外推的回波反射率因子更接近真实值,但 Eff-UNet 模型所预测的回波变化过程与实际情况更为接近。

总体来看,各模型在 30 min 内均能取得较为准确的回波反射率因子和较好的回波细节外推效果,但 30 min 之后则存在显著的回波反射率均化趋势,其原因是深度学习网络提取回波图像特征时,会随着时间的延续产生更多特征信息的丢失和误差累积^[35]。Eff-UNet 模型对中等及以下强度的回波轮廓和变化相对平缓的回波过程具有外推优势,但对极端强回波的外推存在局限,其原因与 MBConvBlock 模块对持续变化的强回波特征提取能力较弱有关,深度可分离卷积虽提升了计算效率,但在长序列预测中对强回波特征的提取能力不及标准卷积,跳跃连接中的特征融合过程也可能导致强度信息的均化。此外,Eff-UNet 模型具有参数少、效率高的特点,对于部分场次回波能取得更优的外推评价指标值和更好的回波轮廓外推效果,为实现降水临近预报的便捷化高效应用提供了可能。

2.2.3 降水预报精度评价

基于 3 种校正方法的降水预报精度分析结果如表 4 所示。动态分级和动态分区校正方法预报结果的 MAE 相对全局动态校正较小,且预报降水强度与实际降水强度的相关系数也更大,表明采用分级和分区的方式动态校正 Z-R 关系有助于提升降水预报精度。动态分级和动态分区校正方法没有明显的精度差异,在 20220808 场次降水中动态分区校正方

法的误差相对较小,且预报降水强度与实际降水强度的相关系数更大,该场降水可能伴随强对流活动,降水的空间分布异质性更强,因此,动态分区校正方法更有优势。动态分级校正方法对 20221001 场次降水具有更高的预报精度,其原因是:20221001 场次降水类型相对单一,但其强度分布有一定层次,分级校正能有效区分不同强度回波对应的降水,因而表现稍好。由 BIAS 结果可以看出,3 种校正方法对强降水均存在明显低估。在 4 种回波外推模型中,U-Net 模型性能相对稳定,在各场次降水预报中误差均较小,而 Eff-UNet 与 U-Net 模型预报精度最为接近,部分场次 Eff-UNet 模型的相关系数甚至比 U-Net 模型更高。SmaAt-UNet 模型的 BIAS 在所有模型中均较小,表明该模型对整体降水过程预报具有较强的稳定性。Simple-UNet 模型的预报精度和稳定性最差,在 20220808 场次降水预报中出现了明显的平均偏差,且在 20221001 场次降水预报中出现了较大误差。

2.2.4 预报降水过程评价

预报降水过程如图 4 所示。由预报结果可知,各模型均出现了不同程度的强降水低估和弱降水高估,且预报降水峰值较实际滞后约 1 h。对于 20220727 场次降水,各模型均无法预报出准确的降水强度,采用动态分区校正方法预报的降水强度误差相对较小。对于 20220808 场次降水,采用动态分级和动态分区校正方法的 U-Net 模型和 Eff-UNet 模型均能得到降水的强度变化过程。对于 20221001 场次降水,采用动态分级校正方法的 Eff-UNet 模型预报的降水强度略小于真实值,但预报的降水过程与实际最为接近;而采用动态分区校正方法的 U-Net 模型预报的降水强度最接近真实值。各校正方法的预报结果均出现不同程度的误差;全局动态校正方法预报的各场降水均出现较大误差,且难以反

表 4 基于不同校正方法的降水预报精度分析结果

降水场次		MAE /(mm/h)			r			BIAS /(mm/h)		
		全局动态校正	动态分级校正	动态分区校正	全局动态校正	动态分级校正	动态分区校正	全局动态校正	动态分级校正	动态分区校正
20220727	U-Net	3.09	3.27	2.77	0.54	0.54	0.57	-1.12	0.09	-1.03
	SmaAt-UNet	4.17	4.15	3.72	0.39	0.46	0.41	-0.23	0.31	-0.74
	Simple-UNet	3.47	3.66	3.29	0.42	0.40	0.46	-1.41	-1.28	-1.52
	Eff-UNet	3.98	3.35	3.25	0.45	0.55	0.53	0.38	-0.49	-0.42
20220808	U-Net	11.06	11.28	9.90	0.29	0.33	0.41	-7.99	-4.67	-4.16
	SmaAt-UNet	11.48	10.80	11.00	0.24	0.38	0.37	-9.63	-6.43	-5.99
	Simple-UNet	11.84	12.10	11.05	0.29	0.15	0.30	-11.29	-9.86	-7.81
	Eff-UNet	11.66	11.07	10.89	0.28	0.36	0.39	-7.46	-5.95	-4.60
20221001	U-Net	2.67	3.00	2.63	0.35	0.36	0.39	-0.90	1.05	-0.51
	SmaAt-UNet	3.86	2.00	3.27	0.16	0.49	0.23	0.31	-1.93	-0.25
	Simple-UNet	6.11	2.31	5.30	0.26	0.50	0.30	3.08	0.76	2.22
	Eff-UNet	3.02	2.07	2.78	0.27	0.55	0.37	-0.57	-1.79	-0.33




图4 基于不同校正方法的预报降水过程

Fig. 4 Forecasted precipitation process based on different correction methods

映降水的真实变化过程;动态分级和动态分区校正方法预报结果的误差相对较小,预报的降水过程也更接近于实际。动态分级和动态分区校正方法在整体精度上没有显著差异,其原因与柳林实验流域的特定条件密切相关。研究流域空间尺度相对较小,降水的空间变异性在一定程度上被平滑,其雨滴谱分布和 $Z-R$ 关系趋于相对均一,导致基于地理空间的动态分区校正方法对于精度提升的效果并不显著,削弱了动态分区校正的潜在优势;降水过程在流域范围内的强度分布相对一致,降低了回波反射率因子的分级需求。这与Li等^[36]的发现相似,即流域大小和降水类型会对预报结果的准确性产生影响。此外,动态分区校正将有限的雷达-雨量数据对分散到更小的子区域中,导致每个分区可用于动态优化参数的样本量减少,降低了该方法的稳定性和可靠性。动态分级校正基于反射率因子等级和降水强度的变化,具有更充分的数据支撑,因而取得了与动态分区校正相近的整体预报精度。

总体来看,U-Net和Eff-UNet模型预报降水的性能几乎一致,略优于SmaAt-UNet和Simple-UNet模型,但对3场测试降水,尤其是20220808场次强降水的预报效果一般,其原因主要为:①CNN的局限性。U-Net及其变体主要依赖卷积核的局部感受野和跳跃连接传递信息。对于持续时间长、运动路径复杂的强对流系统,模型难以捕捉其生成、发展和

消散的全生命周期规律,导致在预见期延长后,预测误差迅速累积,回波结构变得模糊。Su等^[37]提出Evolution-UNet-ConvNeXt模型,通过融合潜在物理信息的特征,提升了对高强度回波的外推性能,可为后续模型结构和性能的优化提供参考。②训练集分布不均对训练效果产生影响。训练集样本以中弱回波为主,强回波样本在数据集中占比较低,模型在预测过程中更好地拟合了占多数的弱回波,降低了对强回波的拟合精度。未来研究中可采用改善数据集分布的思路,如薛丰昌等^[38]利用改进的归一化方法改变样本数据分布,并在一定程度上提升了模型的外推性能。③预报过程的误差累积影响降水计算精度。最终的降水预报误差不仅来源于回波外推,还与 $Z-R$ 关系密切相关,特别是在强降水时, $Z-R$ 关系的非线性更强,参数 A 和 b 的微小偏差会导致降水量的较大估算误差,这也是所有模型均出现对强降水显著低估的原因。Cheng等^[39]采用机器学习方法开展降水预报,提升了降水预报精度,为进一步提升降水计算精度提供参考。未来研究中可尝试融合其他降水临近预报方法的优势,同时完善训练集数据,采用各种量级的回波进行模型训练,以提升模型对各种强度降水和回波过程的外推性能。

3 结论

a. 各模型均存在强回波外推均化趋势, Eff-

UNet 和 U-Net 模型的外推精度评价指标值相近,且对变化趋势较缓、总体强度较低的回波具有更高的外推精度,对回波的轮廓和变化趋势有外推优势。

b. 基于动态分级和动态分区校正方法的降水预报精度差别不大,但均优于全局动态校正方法,Eff-UNet 模型的降水预报性能与 U-Net 模型较为一致,且优于其他模型,但均出现不同程度的强降水低估。

c. Eff-UNet 模型显著减少了模型参数,模型文件大小比 U-Net 模型缩减了约 66.8%,且保持了良好的预报性能,可为大范围降水临近预报的高效化、轻量化应用提供技术支持。

参考文献:

[1] 张伟,王璇,孙慧超,等. 基于多重精度降雨数据的北京市极端降雨事件研究[J]. 水资源保护,2025,41(2): 123-132. (Zhang Wei, Wang Xuan, Sun Huichao, et al. Research on extreme precipitation events in Beijing based on multi-resolution rainfall data [J]. Water Resources Protection,2025,41(2):123-132. (in Chinese))

[2] 刘丁蓉,杨凯,孙仕. 珠三角城市群内涝灾害韧性综合评估及障碍因子识别[J]. 水利经济,2024,42(4): 23-29. (Liu Dingrong, Yang Kai, Sun Shi. Comprehensive assessment and obstacle factor recognition of waterlogging disaster resilience in Pearl River Delta urban agglomeration [J]. Journal of Economics of Water Resources,2024,42(4):23-29, 38. (in Chinese))

[3] 徐宗学,陈浩,任梅芳. 变化环境下我国典型特大城市洪涝灾害成因分析[J]. 水资源保护,2025,41(5): 33-40. (Xu Zongxue, Chen Hao, Ren Meifang. Analysis on causes of flooding/waterlogging disasters in typical megacities of China under changing environment [J]. Water Resources Protection, 2025, 41 (5): 33-40. (in Chinese))

[4] 任立良,万仪欣,袁山水,等. 基于网格聚合理论和 Copula 函数的流域极端降水三维识别及时空动态演变研究[J]. 水资源保护,2025,41(5): 151-159. (Ren Liliang, Wan Yixin, Yuan Shanshui, et al. Three-dimensional identification and spatiotemporal dynamic evolution study of extreme precipitation in river basins based on grid aggregation theory and Copula function[J]. Water Resources Protection, 2025, 41 (5): 151-159. (in Chinese))

[5] 周艳平,黄一,杨建. 基于 pySTEPS 的登陆热带气旋降雨短临预报分析[J/OL]. 河海大学学报(自然科学版), 2025-09-02. <https://link.cnki.net/urlid/32.1117.TV.20250901.1548.014>. (Zhou Yanping, Huang Yi, Yang Jian. Assessment of landfall tropical cyclones rainfall nowcasting using pySTEPS [J/OL]. Journal of Hohai

University (Natural Sciences),2025-09-02. <https://link.cnki.net/urlid/32.1117.TV.20250901.1548.014>. (in Chinese))

[6] 左其亭,李英睿. 基于雷达和智能技术的暴雨风险-效益评估与调控[J]. 水资源保护,2025,41(5): 22-32. (Zuo Qiting, Li Yingrui. Rainstorm risk-benefit assessment and regulation based on radar and intelligent technologies [J]. Water Resources Protection,2025,41(5):22-32. (in Chinese))

[7] 李建柱,李磊菁,冯平,等. 基于深度学习的雷达降雨临近预报及洪水预报[J]. 水科学进展,2023,34(5): 673-684. (Li Jianzhu, Li Leijing, Feng Ping, et al. Radar rainfall nowcasting and flood forecasting based on deep learning[J]. Advances in Water Science, 2023, 34 (5): 673-684. (in Chinese))

[8] Li Binqun, Xia Yijie, Tao Siji, et al. Integrating process-based and deep learning models for flood simulation in karst basins[J]. Water Science and Engineering, 2026, 19 (1): 23-34.

[9] 刘万,谢帅,钟德钰,等. 基于深度学习与 HEC-HMS 模型的小流域暴雨洪水耦合预报[J]. 水利学报,2025,56(3): 364-374. (Liu Wan, Xie Shuai, Zhong Deyu, et al. Coupled forecasting of rainstorms and floods in small watershed based on Deep Learning and HEC-HMS Model [J]. Journal of Hydraulic Engineering, 2025, 56 (3): 364-374. (in Chinese))

[10] Shi Xingjian, Chen Zhouong, Wang Hao, et al. Convolutional LSTM network; a machine learning approach for precipitation nowcasting[C]//Proceedings of the 29th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2015: 802-810.

[11] Agrawal S, Barrington L, Bromberg C, et al. Machine learning for precipitation nowcasting from radar images [EB/OL]. (2019-12-11) [2025-10-14]. <https://arxiv.org/abs/1912.12132>.

[12] Han Lei, Zhao Yangyang, Chen Haonan, et al. Advancing radar nowcasting through deep transfer learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 4100609.

[13] 赵金龙,李剑萍,李万春. 基于 WEU-Net 模型的贺兰山东麓滞洪区水体信息提取[J]. 河海大学学报(自然科学版), 2023, 51 (4): 18-26. (Zhao Jinlong, Li Jianping, Li Wanchun. Water body information extraction for flood detention area in the eastern foot of Helan Mountain based on WEU-Net model [J]. Journal of Hohai University (Natural Sciences), 2023, 51 (4): 18-26. (in Chinese))

[14] Li Jianzhu, Li Leijing, Zhang Ting, et al. Flood forecasting based on radar precipitation nowcasting using U-net and its improved models[J]. Journal of Hydrology, 2024, 632: 130871.

[15] Cheng Qiming, Zhu Jiayue, Su Yihong, et al. Enhanced

- rainfall nowcasting using deep learning models incorporating polarimetric radar data[J]. *Natural Hazards*, 2025, 121(17):19761-19780.
- [16] Geng Huantong, Zhao Han, Shi Zhanpeng, et al. MBFE-UNet: a multi-branch feature extraction UNet with temporal cross attention for radar echo extrapolation[J]. *Remote Sensing*, 2024, 16(21):3956.
- [17] Tan Youwei, Zhang Ting, Li Leijing, et al. Radar-based precipitation nowcasting based on improved U-Net model [J]. *Remote Sensing*, 2024, 16(10):1681.
- [18] Li Wenhui, Zhou Ying, Li Yue, et al. Hierarchical transformer with lightweight attention for radar-based precipitation nowcasting [J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21:1000705.
- [19] Tan Mingxing, Le Q V. EfficientNet: rethinking model scaling for convolutional neural networks [C]// *Proceedings of the 36th International Conference on Machine Learning*. Long Beach: PMLR, 2019:6105-6114.
- [20] Dao V, Arellano C J, Nguyen P, et al. Bias correction of satellite precipitation estimation using deep neural networks and topographic information over the western U. S. [J]. *Journal of Geophysical Research: Atmospheres*, 2025, 130(4):e2024JD042181.
- [21] Wang Yukun, Wang Mengmeng, Hao Zhonghu, et al. MSGFNet: multi-scale gated fusion network for remote sensing image change detection [J]. *Remote Sensing*, 2024, 16(3):572.
- [22] Ahmed T, Sabab N H N. Classification and understanding of cloud structures via satellite images with EfficientUNet [J]. *SN Computer Science*, 2022, 3(1):99.
- [23] 皇甫江, 胡志群, 郑佳锋, 等. 利用深度学习开展偏振雷达定量降水估测研究[J]. *气象学报*, 2022, 80(4):565-577. (Huangfu Jiang, Hu Zhiqun, Zheng Jiafeng, et al. A study on polarization radar quantitative precipitation estimation using deep learning [J]. *Acta Meteorologica Sinica*, 2022, 80(4):565-577. (in Chinese))
- [24] 李新, 陈馨蕾, 周义斌, 等. 黄淮海和江淮平原小时极端降水时空演变及归因分析[J]. *水资源保护*, 2025, 41(5):285-295. (Li Xin, Chen Xinlei, Zhou Yibin, et al. Spatiotemporal evolution and attribution analysis of hourly extreme precipitation in the Huang-Huai-Hai Plain and Jiang-Huai Plain [J]. *Water Resources Protection*, 2025, 41(5):285-295. (in Chinese))
- [25] 徐珂, 陈炼钢, 吴树诚, 等. 1983—2023 年漓江上游降雨时空演变特征精细解析[J]. *水利水电科技进展*, 2025, 45(4):85-93. (Xu Ke, Chen Liangang, Wu Shucheng, et al. Detailed analysis of spatiotemporal evolution characteristics of rainfall in the upper Lijiang River Basin from 1983 to 2023 [J]. *Advances in Science and Technology of Water Resources*, 2025, 45(4):85-93. (in Chinese))
- [26] Wang Gaili, Liu Liping, Ding Yuanyuan. Improvement of radar quantitative precipitation estimation based on real-time adjustments to Z-R relationships and inverse distance weighting correction schemes [J]. *Advances in Atmospheric Sciences*, 2012, 29(3):575-584.
- [27] Wu Wenxin, Zou Haiibo, Shan Jiusheng, et al. A dynamical Z-R relationship for precipitation estimation based on radar echo-top height classification [J]. *Advances in Meteorology*, 2018, 2018(1):8202031.
- [28] 李佳慧, 马建立, 陈明轩, 等. 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*, 2025, 44(1):122-133. (Li Jiahui, Ma Jianli, Chen Mingxuan, et al. Research on dynamic quantitative precipitation estimation method based on tile partitioning for radar [J]. *Plateau Meteorology*, 2025, 44(1):122-133. (in Chinese))
- [29] Kou Leilei, Tang Jiaqi, Wang Zhixuan, et al. An adaptive rainfall estimation algorithm for dual-polarization radar [J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19:1004805.
- [30] 韩丰, 唐文苑, 周楚炫, 等. 基于 SWAN 系统的降水临近预报算法改进和应用评估[J]. *气象学报*, 2023, 81(2):304-315. (Han Feng, Tang Wen yuan, Zhou Chuxuan, et al. Improving a precipitation nowcasting algorithm based on the SWAN system and related application assessment [J]. *Acta Meteorologica Sinica*, 2023, 81(2):304-315. (in Chinese))
- [31] Trebing K, Stańczyk T, Mehrkanoon S. SmaAt-UNet: precipitation nowcasting using a small attention-UNet architecture[J]. *Pattern Recognition Letters*, 2021, 145:178-186.
- [32] Choi H, Kim Y, Kim S, et al. Unveiling the role of weighted loss functions in deep learning-based nowcasting of extreme rainfall events [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63:5106722.
- [33] Han Lei, Liang He, Chen Haonan, et al. Convective precipitation nowcasting using U-Net model [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60:4103508.
- [34] 沈哲辉, 韩静妍, 桂敬聪, 等. 长江流域再分析与卫星反演降水数据的适用性分析[J]. *河海大学学报(自然科学版)*, 2025, 53(1):50-61. (Shen Zhehui, Han Jingyan, Gui Jingcong, et al. Analysis of the applicability of reanalysis and satellite-derived precipitation data in the Yangtze River Basin [J]. *Journal of Hohai University (Natural Sciences)*, 2025, 53(1):50-61. (in Chinese))
- [35] 袁凯, 庞晶, 李武阶, 等. 深度学习模型在 2021 年汛期武汉市雷达回波临近预报中的应用评估[J]. *干旱气象*, 2023, 41(1):173-185. (Yuan Kai, Pang Jing, Li Wujie, et al. Application evaluation of deep learning models in radar echo nowcasting in Wuhan in flood season of 2021 [J]. *Journal of Arid Meteorology*, 2023, 41(1):

173-185. (in Chinese))

[36] Li Jianzhu, Shi Yi, Zhang Ting, et al. Radar precipitation nowcasting based on ConvLSTM model in a small watershed in North China[J]. Natural Hazards, 2024, 120(1):63-85.

[37] Su Yihong, Cheng Qiming, He Yang, et al. An Evolution-Unet-ConvNeXt approach based on feature fusion for enhancing the accuracy of short-term precipitation forecasting [J]. Atmospheric Research, 2025, 317: 107984.

[38] 薛丰昌,章超钦,王文硕,等. 基于自注意力和门控循环神经网络的雷达回波外推算法研究[J]. 气象学报, 2024, 82(1):127-135. (Xue Fengchang, Zhang Chaoqin, Wang Wenshuo, et al. Improving radar echo extrapolation algorithms based on self-attention and gated recurrent neural networks [J]. Acta Meteorologica Sinica, 2024, 82(1):127-135. (in Chinese))

[39] Cheng Yongyun, Chang C T, Chen B F, et al. Extracting 3D radar features to improve quantitative precipitation estimation in complex terrain based on deep learning neural networks [J]. Weather and Forecasting, 2023, 38(2):273-289.

(收稿日期:2025-10-14 编辑:施业)

+++++

(上接第 163 页)

[29] 邓晓军, 许有鹏, 韩龙飞, 等. 城市化背景下嘉兴市河流水系的时空变化[J]. 地理学报, 2016, 71(1):75-85. (Deng Xiaojun, Xu Youpeng, Han Longfei, et al. Spatial-temporal changes of river systems in Jiaxing under the background of urbanization[J]. Acta Geographica Sinica, 2016, 71(1):75-85. (in Chinese))

[30] 田凯, 赵彦伟, 白洁, 等. 多源补水格局下白洋淀换水周期与示踪剂传输时间的时空特征[J]. 湖泊科学, 2025, 37(4):1302-1313. (Tian Kai, Zhao Yanwei, Bai Jie, et al. Spatio-temporal characteristics of water renewal cycle and tracer transport time in Lake Baiyangdian Wetland under multi-source water supply pattern [J]. Journal of Lake Sciences, 2025, 37(4):1302-1313. (in Chinese))

[31] 丁越崙, 张洪, 单保庆. 海河流域河流空间分布特征及演变趋势[J]. 环境科学学报, 2016, 36(1):47-54. (Ding Yuekui, Zhang Hong, Shan Baoqing. The spatial distribution and evolution trend of rivers in Hai River Basin[J]. Acta Scientiae Circumstantiae, 2016, 36(1):47-54. (in Chinese))

[32] Zhang Yinghu, Huang Chenyang, Zhang Wenqi, et al. The concept, approach, and future research of hydrological connectivity and its assessment at multiscales [J]. Environmental Science and Pollution Research, 2021, 28(38):52724-52743.

[33] 贺蔚, 黄金雅莹, 蒋爱丽, 等. 人工湿地对平原河网水动力与水质的影响效应[J]. 水科学进展, 2025, 36(5):869-881. (He Wei, Huang Jinyaxuan, Jiang Aili, et al. Effects of constructed wetlands on hydrodynamic conditions and water quality in urban plain river networks [J]. Advances in Water Science, 2025, 36(5):869-881. (in Chinese))

[34] 窦明, 余佳琦, 关键, 等. 基于水资源分区的中国水系发育度与连通度相关性[J]. 水科学进展, 2023, 34(6):877-886. (Dou Ming, Yu Jiaqi, Guan Jian, et al. Study on relationship between water system development and connectivity in China based on water resource zoning [J]. Advances in Water Science, 2023, 34(6):877-886. (in Chinese))

[35] 危小建, 江平, 陈竹安, 等. 基于拓扑结构和空间网络结构的水系连通性评价[J]. 人民长江, 2019, 50(5):76-81. (Wei Xiaojian, Jiang Ping, Chen Zhu'an, et al. Connectivity evaluation on water system based on topological structure and spatial network structure [J]. Yangtze River, 2019, 50(5):76-81. (in Chinese))

[36] Li Fawen, Yang Yang. Impacts of the middle route of China's South-to-North Water Diversion Project on the water network structure in the receiving basin [J]. Environmental Science and Pollution Research, 2024, 31(10):15611-15626.

[37] Jacome R S, Anchieta T, Brentan B M, et al. Core-periphery structure for district metered area partitioning in urban water distribution systems[J]. Water Science and Engineering, 2025, 18(3):262-273.

[38] 王宗志, 张安齐, 王坤, 等. 等高截水工程实施后东海县河网区水系格局及连通性变化定量分析[J]. 水资源保护, 2025, 41(3):31-38. (Wang Zongzhi, Zhang Anqi, Wang Kun, et al. Quantitative analysis of water system pattern and connectivity changes in river network area after implementation of contour interception project in Donghai County[J]. Water Resources Protection, 2025, 41(3):31-38. (in Chinese))

(收稿日期:2025-11-15 编辑:王芳)