

DOI: 10.14042/j.cnki.32.1309.2023.05.003

# 基于深度学习的雷达降雨临近预报及洪水预报

李建柱, 李磊菁, 冯平, 唐若宜

(天津大学水利工程仿真与安全国家重点实验室, 天津 300350)

**摘要:** 为探究深度学习的雷达降雨临近预报在流域洪水预报中的适用性, 采用 U-Net、嵌入注意力门的 Attention-Unet 和添加转换器的多级注意力 TransAtt-Unet 开展雷达降雨临近预报, 将预报降雨作为 HEC-HMS 水文模型的输入, 对柳林实验流域进行洪水预报。结果表明: 1 h 预见期时, Attention-Unet 对短时强降雨预报结果较好, TransAtt-Unet 预报降雨模拟的洪峰流量和径流量相对误差小于 20%, 各深度学习模型对量级较大的降雨和洪水预报精度较高; 2 h 预见期的预报降雨强度、降雨总量、洪峰流量和径流量存在显著低估, U-Net 能取得相对较好的降雨预报结果。基于深度学习的 1 h 预见期雷达降雨临近预报及洪水预报可为流域防洪减灾提供科学依据。

**关键词:** 雷达降雨临近预报; 降雨定量估计; 深度学习; 洪水预报; 柳林实验流域

**中图分类号:** P333 **文献标志码:** A **文章编号:** 1001-6791(2023)05-0673-12

近年来, 极端降雨事件导致洪涝灾害频发, 对洪水预报精度和时效性的要求越来越高<sup>[1]</sup>。准确的降雨预报是洪水预报的关键, 可为防洪减灾工作提供重要的科学依据<sup>[2]</sup>。传统的洪水预报主要以地面雨量站实测降雨输入水文模型, 导致洪水预报的有效预见期短, 且雨量站实测降雨无法反映其空间分布特性<sup>[3]</sup>。天气雷达具有高时空分辨率、高精度和可靠性等特点<sup>[4]</sup>。将雷达降雨临近预报结果作为水文模型的输入进行洪水预报, 能在一定程度上延长洪水预见期<sup>[5]</sup>, 是水文预报领域的主要发展趋势, 但降雨临近预报是尚未解决的重要科学难题<sup>[6]</sup>。

以光流法、质心跟踪法、交叉相关法为主的传统雷达回波外推方法<sup>[7]</sup>, 能在较短预见期内对缓慢变化的回波过程取得较好的外推效果, 但无法准确描述迅速变化的回波过程<sup>[8]</sup>。近年来大量研究将深度学习的方法引入到水文气象领域, 并取得显著成效<sup>[9-10]</sup>。Zhang 等<sup>[6]</sup>提出一种具有预测误差优化的神经网络模型 NowcastNet, 基于中国和美国的雷达资料开展降雨预报, 显著提高了极端强降雨的预报精度。Ritvanen 等<sup>[11]</sup>提出一种基于卷积神经网络 U-Net 的拉格朗日模型, 改善了强降雨的临近预报效果。作为一种应用广泛的基础模型, U-Net 在临近预报领域得到推广<sup>[12]</sup>。Han 等<sup>[13]</sup>将 U-Net 模型用于雷达回波外推, 并与循环神经网络的 TrajGRU 和交叉相关法的预报结果进行对比, 表明 U-Net 模型在时空序列预测问题的适用性。

预报降雨的重要用途之一是作为水文模型的输入进行洪水预报<sup>[14-15]</sup>。Heuvelink 等<sup>[16]</sup>使用确定性和概率性方法进行降雨预报, 并将结果作为 WALRUS 水文模型的输入进行流量预报, 在小流域取得较好的预报效果; Nguyen 等<sup>[17]</sup>将雷达回波外推和数值模式天气预报结合, 提高了降雨预报精度, 并指出降雨预报与分布式水文模型结合使用的优势; 包红军等<sup>[18]</sup>构建了临近降雨集合预报的中小河流洪水预报模型, 延长了洪水预报的预见期。但目前使用深度学习的方式开展雷达降雨临近预报, 从而进行洪水预报的精度还有待提高, 尤其是在半干旱半湿润地区的小流域。

U-Net 结构简单, 可根据目标灵活调整和添加模块, 为实现更加精确的雷达降雨临近预报和洪水预报提供了更多可能。因此, 本研究采用深度学习的 U-Net, 并尝试使用嵌入注意力门的 Attention-Unet(简称为 Att-

收稿日期: 2023-05-19; 网络出版日期: 2023-09-19

网络出版地址: <https://link.cnki.net/urlid/32.1309.P.20230918.1718.002>

基金项目: 国家自然科学基金资助项目(52279022)

作者简介: 李建柱(1981—), 男, 河北沧州人, 教授, 博士, 主要从事水文水资源方面研究。E-mail: lijianzhu@tju.edu.cn

Unet) 和添加转换器的多级注意力 TransAtt-Unet 进行柳林实验流域典型降雨过程的 1 h 和 2 h 预见期雷达回波外推, 利用动态雷达反射率因子和降雨强度关系计算外推回波对应的逐小时降雨, 作为半分布式水文模型 HEC-HMS 的输入进行洪水预报, 对比分析预报降雨与雨量站实测降雨模拟的洪水精度差异, 探讨基于深度学习的雷达降雨临近预报在小流域洪水预报中的适用性。

## 1 研究区域与数据

### 1.1 流域概况

选择河北省邢台市内丘县柳林实验流域为研究区。如图 1 所示, 流域出口位于  $114^{\circ}21'E$ 、 $37^{\circ}17'N$ , 布设有柳林水文站进行水位和流量观测。流域面积为  $57.4 \text{ km}^2$ , 主河道长  $13.2 \text{ km}$ , 流域坡度为  $30.9\%$ 。地处半干旱半湿润气候区, 季节变化分明, 径流的年内和年际分配不均, 降雨多发生在 6—9 月, 多年平均降水量为  $594.5 \text{ mm}$ , 多年平均径流深为  $80.7 \text{ mm}$ 。雷达资料来源于中国新一代多普勒天气雷达监测网河北省石家庄市的 Z9311 站。雷达位于  $114^{\circ}42'50"E$ 、 $38^{\circ}21'00"N$ , 采用 VP21 体扫模式, 扫描半径为  $230 \text{ km}$ , 时间分辨率为  $6 \text{ min}$ , 能够完成 9 个不同仰角的扫描。柳林实验流域在距离雷达  $120 \text{ km}$  范围内, 可保证雷达回波数据的质量。

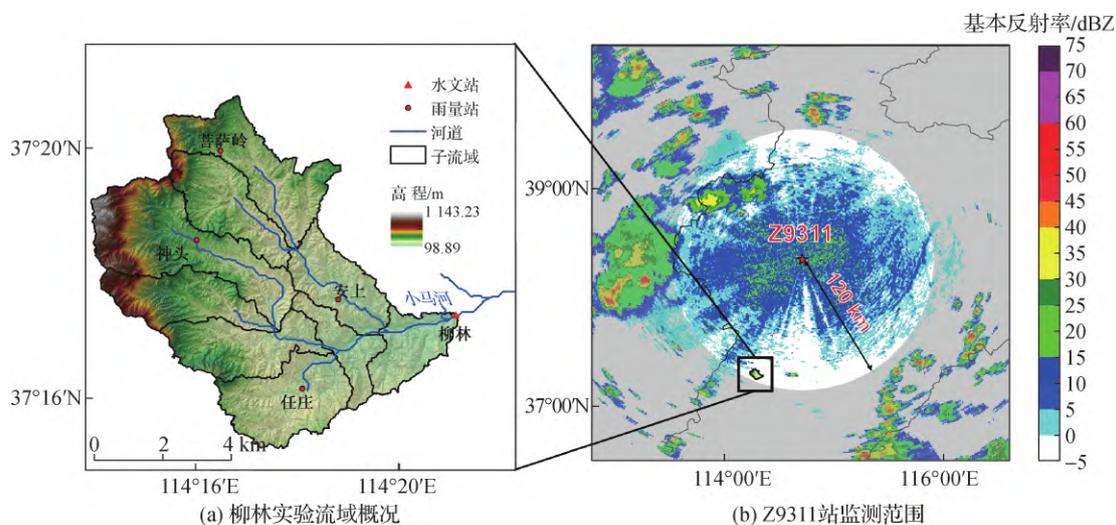


图 1 柳林实验流域位置和雷达监测范围

Fig. 1 Location of Liulin experimental watershed and radar monitoring range

### 1.2 雷达数据预处理

将 2018—2020 年降雨时段的雷达基数据, 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, 用于深度学习模型的训练。由于柳林实验流域面积较小, 将回波图裁剪至流域周围 128 行 128 列的范围 ( $113^{\circ}36'36"E$ 、 $37^{\circ}30'36"N$  到  $114^{\circ}53'24"E$ 、 $36^{\circ}47'24"N$ )。以训练集中 20180521 场次降雨为例, 图 2 为经过预处理与未处理回波对比图, 经过质量控制后的回波剔除了杂波干扰并显著减少波束遮挡, 具有较高的可靠性。训练集和验证集共包含 20 000 帧回波图, 按照 8:2 的比例划分进行模型训练和验证。测试集选取 2012 年、2016 年和 2021 年的 4 场典型降雨过程对应的雷达数据。

### 1.3 典型降雨洪水过程

降雨洪水资料来源于河北省邢台水文勘测研究中心。洪水资料为柳林水文站汛期实测逐小时流量数据,

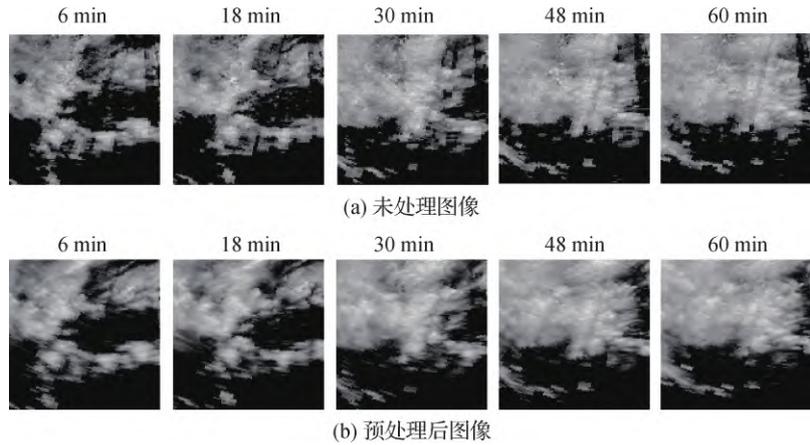


图 2 20180521 场次降雨未处理与预处理后回波对比

Fig. 2 Comparison of unprocessed and preprocessed echoes of 20180521 case

暴雨资料为流域内菩萨岭、神头、任庄、安上和柳林 5 个雨量站汛期逐小时雨量, 筛选出与雷达回波时段对应的典型降雨洪水过程对降雨和洪水预报精度进行评价。降雨洪水信息如表 1 所示。由于 20211006 场次降雨过程在汛期后发生, 柳林水文站未对其洪水过程进行观测。

表 1 典型降雨洪水过程信息

Table 1 Information of typical rainfall and flood processes

| 降水场次     | 降水量/mm | 最大小时雨量/mm | 降雨时长/h | 洪水径流深/mm | 洪峰流量/( $m^3 \cdot s^{-1}$ ) |
|----------|--------|-----------|--------|----------|-----------------------------|
| 20120726 | 75.9   | 58.4      | 5      | 5.1      | 47.0                        |
| 20160719 | 251.9  | 42.7      | 18     | 129.2    | 368.0                       |
| 20210721 | 149.4  | 26.9      | 29     | 29.9     | 93.3                        |
| 20211006 | 25.5   | 8.2       | 5      | /        | /                           |

## 2 研究方法

### 2.1 雷达回波外推的深度学习模型

#### 2.1.1 U-Net

U-Net 网络由 4 层编码器-解码器组成, 是一种卷积神经网络。如图 3(a) 所示, 网络的左边是编码器, 应用最大池化和双重卷积来减小图像大小和加倍特征映射的数量。编码器之后的右侧为解码器, 通过双线性插值进行上采样操作, 使特征图大小增加 1 倍。每层编码器和解码器之间通过 1 个跳跃连接保存来自较浅层的细尺度信息。完成上述采样操作之后, 模型通过一个  $1 \times 1$  的卷积, 输出代表网络预测值的单个特征图。

#### 2.1.2 Att-Unet

Att-Unet(图 3(a)) 在 U-Net 的解码器前添加注意力门, 以此过滤跳跃连接传播的特征, 再将编码器的特征与解码器中相应的特征进行拼接, 有效抑制无关区域的激活, 减少编码器中无关信息的跳跃连接, 达到改善预测效果的目的<sup>[19]</sup>。本研究将 Att-Unet 模型调整为时间序列预测模型进行回波外推。

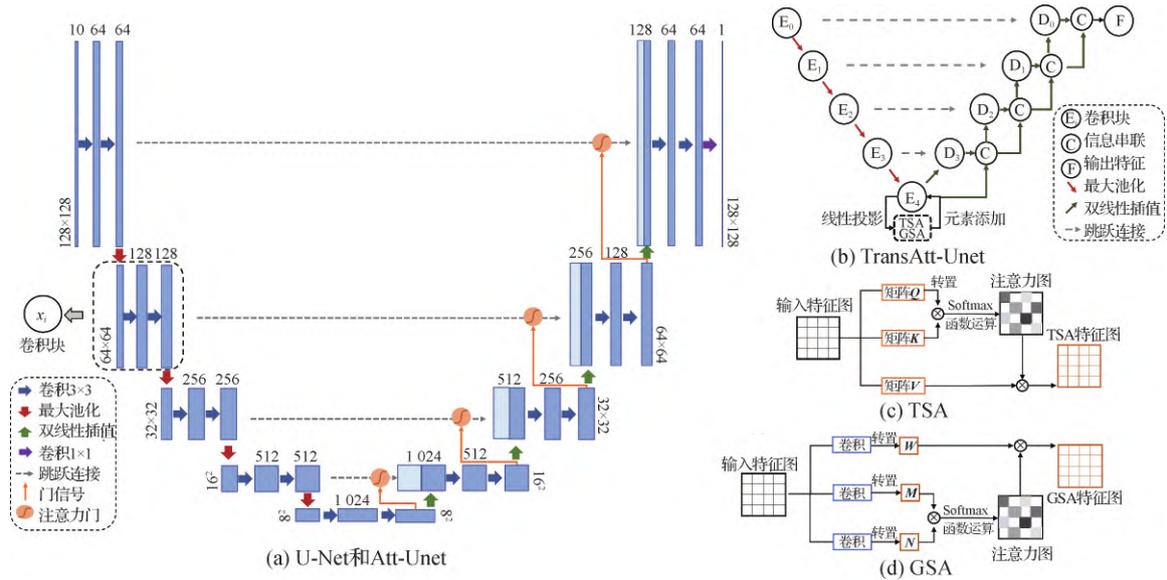


图 3 U-Net、Att-Unet、TransAtt-Unet 和 TSA、GSA 模块结构

Fig. 3 Structure of U-Net , Attention-Unet , TransAtt-Unet , TSA and GSA modules

2. 1. 3 TransAtt-Unet

TransAtt-Unet 将多层次引导注意和多尺度跳跃连接联合嵌入 U-Net，如图 3 ( b)。将变换器自注意力 ( TSA) 和全局空间注意力 ( GSA) 嵌入到网络中，同时在解码器中使用多尺度跳跃连接来聚合不同语义尺度的特征，从而有效减少卷积层叠加和连续采样操作造成的细节损失。如图 3 ( c) 和图 3 ( d) 所示，TSA 将特征嵌入到  $Q$ 、 $K$ 、 $V$  3 个矩阵中，在  $Q$  和  $K$  的转置之间采用 Softmax 函数进行归一化运算，形成注意力图，再与  $V$  矩阵相乘得到注意力权重。GSA 对特征进行卷积转置映射为  $W$ 、 $M$ 、 $N$ ，对  $M$ 、 $N$  采用 Softmax 函数进行归一化运算得到位置注意力信息，再与  $W$  相乘得到位置特征。在解码器部分采用残差多尺度跳跃连接的方式<sup>[20]</sup>，输入特征图通过双线性插值向上采样到输出的分辨率，然后与输出特征图进行级联，作为后续块的输入。

2. 2 深度学习模型训练

1 h 外推数据集取前 1 h 间隔 6 min 共 10 帧回波图 ( 反射率因子)，预测后 1 h 共 10 帧回波图 ( 2 h 外推为前 20 帧预测后 20 帧)。深度学习模型基于 Pytorch 环境，初始学习率设置为 0. 001，批处理大小设置为 8，损失函数采用均方根误差 (  $E_{MS}$ )<sup>[13]</sup>，在 NVIDIA Geforce RTX 3050 上采用 Adam 优化器训练 200 个轮次。当损失函数在 4 个周期内没有增加时，学习率调节器将学习率自动减小 10%。采用二元评价指标命中率 ( Probability of detection ,  $D_{PO}$ )、虚警率 ( False alarm ratio ,  $R_{FA}$ )、临界成功指数 ( Critical success index ,  $I_{CS}$ ) 和准确率 ( Accuracy ,  $A$ ) 进行雷达回波外推精度的评价<sup>[21]</sup>。

2. 3 雷达降雨临近预报

多普勒天气雷达采用  $Z-R$  关系描述雷达反射率因子 (  $Z$ ) 和降雨强度 (  $R$ ) 的幂指数关系<sup>[22]</sup>。中国的多普勒雷达普遍采用  $Z = aR^b$  (  $a = 300$  ,  $b = 1. 4$ ) 进行降雨定量估计，但仅适用于平均情况。基于实测资料动态调整的  $Z-R$  关系，可以实现更加精确的降雨估计<sup>[23]</sup>。殷志远等<sup>[24]</sup>采用 4 种不同的  $Z-R$  关系开展雷达降雨定量估计，并将结果用于水文模拟，表明动态  $Z-R$  关系的降雨定量估计精度最高，洪水模拟效果最好。动态  $Z-R$  关系建立在逐小时快速更新资料的基础上，通过动态调节参数  $a$  和  $b$ ，使逐小时雷达估测降雨与对应

雨量站观测降雨的最优判别函数  $\delta$  达到最小<sup>[23]</sup>, 从而确定适用于逐小时雷达定量降雨估计的多组  $Z-R$  关系参数。为保证参数  $a$  和  $b$  的取值合理, 限定  $a$  和  $b$  数值调节范围分别为  $[150.00, 400.00]$ 、 $[0.80, 2.40]$ , 调整间隔分别为 10 和 0.05。经过上述步骤最终确定出每场降雨过程的动态  $Z-R$  关系参数如图 4 所示。采用相关系数( Correlation coefficient,  $C_C$ )、平均偏差( Mean bias,  $B_M$ ) 和平均绝对误差( Mean absolute error,  $E_{MA}$ ) 进行降雨预报精度评价<sup>[14]</sup>。

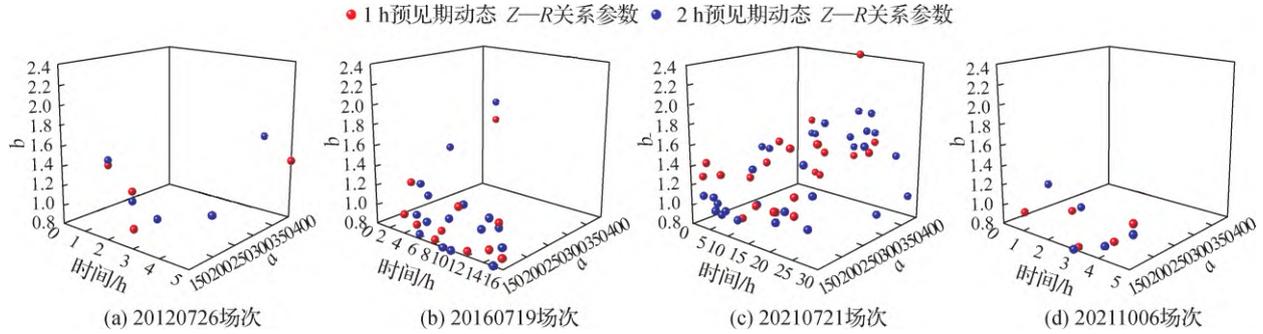


图 4 动态  $Z-R$  关系参数

Fig. 4 Parameters of dynamic  $Z-R$  relationship

### 2.4 水文模型

李建柱等<sup>[25]</sup>研究了地形数据源和分辨率对柳林实验流域洪水模拟精度的影响, 结果表明, 基于无人机三维倾斜摄影构建的 1 m 分辨率 DEM 能反映流域真实地形的变化, 在此基础上构建的 HEC-HMS 模型能较好地模拟流域洪水过程。本研究采用作者基于无人机三维倾斜摄影构建的 1 m 分辨率 HEC-HMS 模型, 将雷达降雨临近预报结果作为 HEC-HMS 水文模型的输入, 进行柳林实验流域洪水预报。采用洪峰流量相对误差 ( $E_{RP}$ )、径流量相对误差 ( $E_{RV}$ )、峰现时差 ( $\Delta T$ ) 和纳什效率系数 ( $E_{NS}$ ) 进行洪水预报精度评价<sup>[25]</sup>。

## 3 结果及分析

### 3.1 回波外推结果分析

以反射率 20 dBZ 和 30 dBZ 为阈值计算二元评价指标。1 h 回波外推评价结果见表 2, Att-Unet 对 20120726 场次降雨的回波外推效果相对较好, 注意力门加强了 Att-Unet 对强回波的识别和外推效果, 同时抑制弱回波或杂波产生的干扰, 但对弱回波或中等回波的外推效果较差; TransAtt-Unet 采用的多尺度跳跃连接和注意力机制使模型能综合不同尺度的图像特征, 提高模型精度和稳定性, 因此, 该模型对于持续时间较长、降雨过程变化丰富的 20160719 场次回波过程取得了较好的外推效果; 20210721 和 20211006 场次降雨的过程回波总体偏弱, 各模型的 1 h 预见期回波外推精度差异并不显著。2 h 回波外推评价结果见表 3, U-Net 模型对 30 dBZ 阈值的回波外推效果优于其他模型, 其原因是雷达回波外推需要预测每个像素的精确值; Att-Unet 和 TransAtt-Unet 所采用的注意力门或者多尺度跳跃连接结构仅增强局部特征的学习, 而忽略随时间动态变化的信息, 因此导致预测时效性的不足。U-Net 模型尽管结构简单, 但以往研究表明其在时间序列预测中具有一定适用性<sup>[26]</sup>, 对不同等级回波信息具有一定的泛化能力<sup>[27]</sup>, 因此, 尽管 U-Net 的 1 h 预见期回波外推效果略差于添加注意力机制的模型, 但能在更长预见期的回波外推中保持相对较好的效果。总体来看, 3 种模型对中等强度回波外推效果均好于强回波, 1 h 预见期回波外推效果好于 2 h 预见期。

国内外研究主要依靠天气雷达外推实现 1 h 预见期降雨预报<sup>[5]</sup>。与传统的雷达外推方法相比, 深度学习

对回波和降水的演变趋势具有更好的预报效果，更适用于剧烈变化的降雨过程<sup>[28]</sup>。曹伟华等<sup>[29]</sup>使用基于 U-Net 网络搭建的 RainNet 模型开展雷达降雨临近预报，并与交叉相关的外推结果进行对比，指出了深度学习模型对降雨消亡过程的时空演变趋势和强度变化范围具有更好的预报效果，而交叉相关法更适合于稳定降雨的预报。本研究预报的 4 场典型降雨过程，除 20211006 场次持续时间短、降雨强度较小外，其余场次降雨过程变化较为剧烈，回波过程变化较为迅速，因此，采用深度学习的方法进行雷达降雨临近预报更为合适。

表 2 1 h 回波外推结果评价指标值

Table 2 Evaluation index value of 1 h echo extrapolation results

| 降雨场次     | 模型             | $D_{PO}$ |        | $R_{FA}$ |        | $I_{CS}$ |        | $A$    |        |
|----------|----------------|----------|--------|----------|--------|----------|--------|--------|--------|
|          |                | 20 dBZ   | 30 dBZ | 20 dBZ   | 30 dBZ | 20 dBZ   | 30 dBZ | 20 dBZ | 30 dBZ |
| 20120726 | U-Net          | 0.83     | 0.37   | 0.07     | 0.19   | 0.78     | 0.33   | 0.82   | 0.56   |
|          | Att-U-net      | 0.82     | 0.52   | 0.12     | 0.17   | 0.76     | 0.44   | 0.80   | 0.65   |
|          | TransAtt-U-net | 0.75     | 0.35   | 0.06     | 0.17   | 0.72     | 0.34   | 0.77   | 0.58   |
| 20160719 | U-Net          | 0.71     | 0.37   | 0.14     | 0.44   | 0.61     | 0.21   | 0.61   | 0.31   |
|          | Att-U-net      | 0.79     | 0.46   | 0.15     | 0.45   | 0.68     | 0.24   | 0.69   | 0.33   |
|          | TransAtt-U-net | 0.87     | 0.47   | 0.14     | 0.49   | 0.75     | 0.24   | 0.75   | 0.31   |
| 20210721 | U-Net          | 0.74     | 0.42   | 0.14     | 0.21   | 0.67     | 0.36   | 0.81   | 0.71   |
|          | Att-U-net      | 0.70     | 0.49   | 0.26     | 0.44   | 0.54     | 0.28   | 0.64   | 0.51   |
|          | TransAtt-U-net | 0.72     | 0.52   | 0.26     | 0.46   | 0.55     | 0.29   | 0.65   | 0.53   |
| 20211006 | U-Net          | 0.45     | 0.24   | 0.56     | 0.76   | 0.19     | 0.09   | 0.74   | 0.64   |
|          | Att-U-net      | 0.44     | 0.21   | 0.55     | 0.79   | 0.24     | 0.08   | 0.75   | 0.61   |
|          | TransAtt-U-net | 0.43     | 0.28   | 0.56     | 0.72   | 0.21     | 0.09   | 0.69   | 0.63   |

表 3 2 h 回波外推结果评价指标值

Table 3 Evaluation index value of 2 h echo extrapolation results

| 降雨场次     | 模型             | $D_{PO}$ |        | $R_{FA}$ |        | $I_{CS}$ |        | $A$    |        |
|----------|----------------|----------|--------|----------|--------|----------|--------|--------|--------|
|          |                | 20 dBZ   | 30 dBZ | 20 dBZ   | 30 dBZ | 20 dBZ   | 30 dBZ | 20 dBZ | 30 dBZ |
| 20120726 | U-Net          | 0.66     | 0.37   | 0.14     | 0.16   | 0.60     | 0.35   | 0.64   | 0.63   |
|          | Att-U-net      | 0.62     | 0.18   | 0.14     | 0.17   | 0.59     | 0.18   | 0.65   | 0.48   |
|          | TransAtt-U-net | 0.66     | 0.20   | 0.11     | 0.13   | 0.59     | 0.20   | 0.63   | 0.51   |
| 20160719 | U-Net          | 0.59     | 0.20   | 0.42     | 0.63   | 0.38     | 0.12   | 0.43   | 0.47   |
|          | Att-U-net      | 0.48     | 0.12   | 0.44     | 0.64   | 0.31     | 0.07   | 0.37   | 0.47   |
|          | TransAtt-U-net | 0.57     | 0.15   | 0.36     | 0.60   | 0.41     | 0.10   | 0.42   | 0.48   |
| 20210721 | U-Net          | 0.69     | 0.48   | 0.14     | 0.33   | 0.62     | 0.33   | 0.77   | 0.62   |
|          | Att-U-net      | 0.60     | 0.36   | 0.25     | 0.39   | 0.46     | 0.22   | 0.59   | 0.51   |
|          | TransAtt-U-net | 0.65     | 0.38   | 0.29     | 0.46   | 0.48     | 0.22   | 0.57   | 0.48   |
| 20211006 | U-Net          | 0.50     | 0.17   | 0.48     | 0.77   | 0.32     | 0.08   | 0.67   | 0.58   |
|          | Att-U-net      | 0.42     | 0.18   | 0.67     | 0.81   | 0.21     | 0.02   | 0.60   | 0.54   |
|          | TransAtt-U-net | 0.41     | 0.17   | 0.61     | 0.80   | 0.20     | 0.04   | 0.64   | 0.52   |

### 3.2 降雨预报精度分析

利用动态  $Z-R$  关系计算各降雨场次真实回波和外推回波的逐小时降雨, 精度和相关性评价指标见表 4。20160719、20210721 和 20211006 场次真实回波的反演降雨与实际降雨有较高的相关性, 但 20120726 场次真实回波反演降雨与实际降雨的相关性较弱, 但该场次回波外推取得较高的技能评分, 其原因可能是 2012 年 Z9311 雷达为单偏振雷达, 所采集的原始回波数据存在一定的数值和发生时间的系统误差, 且该场降雨过程变化迅速, 导致预报降雨与实际产生误差。TransAtt-U-net 对 20160719 和 20210721 场次降雨在 1 h 预见期内具有较小的误差, Att-U-net 在 20160719 场次降雨的预报中具有最高的相关性。3 种模型对 20211006 场次降雨预报效果差别并不显著, 其原因是该场降雨强度较小, 深度学习模型对此类降雨预报性能较接近。在 2 h 预见期降雨预报中, U-Net 模型的降雨预报效果优于其他模型, 这与雷达回波外推结果相对应, 表明了 U-Net 在较长预见期降雨预报中的适用性。

表 4 降雨相关性评价指标值

Table 4 Rainfall correlation evaluation index value

| 降雨场次     | 模型             | $E_{MA}/mm$ |       | $C_C$ |       | $B_M/mm$ |       |
|----------|----------------|-------------|-------|-------|-------|----------|-------|
|          |                | 1 h         | 2 h   | 1 h   | 2 h   | 1 h      | 2 h   |
| 20120726 | U-Net          | 22.57       | 22.49 | -0.28 | -0.41 | -1.96    | -2.32 |
|          | Att-U-net      | 23.99       | 21.28 | -0.22 | -0.32 | -0.66    | -3.08 |
|          | TransAtt-U-net | 24.20       | 22.66 | -0.28 | -0.32 | -1.76    | -2.66 |
|          | 真实回波           | 14.78       |       | 0.31  |       | 2.93     |       |
| 20160719 | U-Net          | 8.86        | 8.84  | 0.48  | 0.42  | 0.22     | -6.21 |
|          | Att-U-net      | 8.70        | 10.71 | 0.59  | 0.17  | 0.25     | -7.05 |
|          | TransAtt-U-net | 7.88        | 10.52 | 0.58  | 0.13  | -0.74    | -6.77 |
|          | 真实回波           | 6.02        |       | 0.77  |       | -0.06    |       |
| 20210721 | U-Net          | 4.57        | 4.78  | 0.52  | 0.38  | 0.31     | -1.90 |
|          | Att-U-net      | 4.85        | 5.58  | 0.32  | 0.19  | -0.93    | -1.31 |
|          | TransAtt-U-net | 4.40        | 5.65  | 0.47  | 0.21  | -0.22    | -1.29 |
|          | 真实回波           | 3.09        |       | 0.67  |       | -0.41    |       |
| 20211006 | U-Net          | 2.81        | 2.65  | 0.84  | 0.61  | -2.81    | -2.39 |
|          | Att-U-net      | 2.61        | 2.79  | 0.79  | 0.63  | -2.61    | -2.79 |
|          | TransAtt-U-net | 2.48        | 2.62  | 0.82  | 0.65  | -2.48    | -2.62 |
|          | 真实回波           | 1.67        |       | 0.88  |       | -1.67    |       |

预报降雨过程如图 5 所示。3 种模型在 1 h 预见期时, 预报的 20120726 场次降雨峰值与实际较为一致, 但出现 1 h 时差; 对 20160719 和 20210721 场次降雨过程预报结果出现部分异常值, 这与回波外推过程较大的虚警率有关, 但总体上能反映降雨过程变化和雨强峰值; 20211006 场次降雨则存在少量低估, 但能预报出该场降雨峰值出现的时间, 这与动态  $Z-R$  算法对较弱降雨的系统性低估有关。2 h 预见期降雨可以一定程度预报降雨过程的变化, 但对各场降雨的峰值存在显著低估。

目前, 小流域降雨临近预报效果普遍较差。Heuvelink 等<sup>[16]</sup>采用拉格朗日持续性方法在一个 40 km<sup>2</sup>的

流域上对一场强降雨进行预报，产生了 50% 相对误差，发现面积越小的流域对过程变化迅速的降雨越容易产生误报；石毅<sup>[30]</sup>采用 Farneback 光流法和 ConvLSTM 在柳林实验流域进行降雨预报，结果表明光流法对回波演变的敏感性相对较低，ConvLSTM 对强回波存在显著的均化趋势，导致 1 h 预见期强降雨存在严重的低估。本研究采用的深度学习方法，在 1 h 预见期内对不同类型的降雨均取得相对较好的回波外推效果，且能较准确的预报出强降雨峰值和变化过程，尽管 2 h 预见期的预报精度相对较差，但能预报出降雨变化过程。预报结果存在的误差与定量降雨估计方法的系统误差和小流域上有限的雷达回波信息相关。动态  $Z-R$  关系在定量降雨估计中具有相对较高的精度，但在降雨预报的业务化应用中仍然具有优化的空间，如 Mihulet 等<sup>[31]</sup>使用机器学习的方法改善了定量降雨估计的效果。另外，由于流域面积较小，随着预见期的延长降雨发生的实际位置也许出现在雷达图之外，使得深度学习的方法对剧烈变化的降雨产生较大的误差，Heuvelink 等<sup>[16]</sup>也指出面积越小的流域对降雨发生的位置敏感性越高。

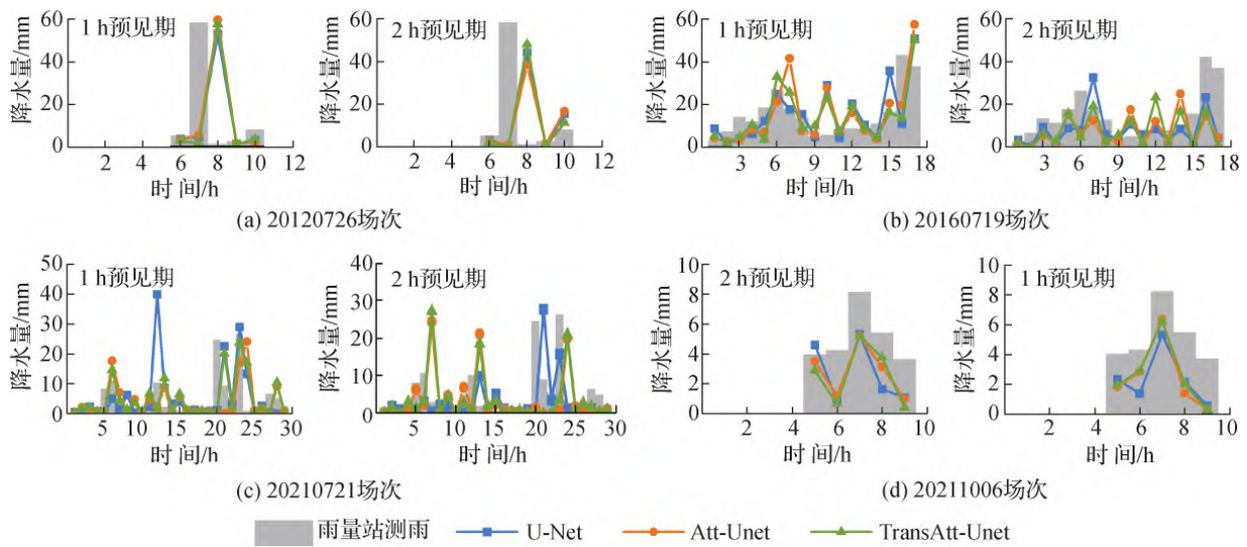


图 5 预报逐小时降雨过程

Fig. 5 Forecasted hourly rainfall process

### 3.3 洪水预报精度分析

表 5 为洪水预报精度评价结果。3 场实测降雨模拟的洪峰流量均小于实测洪峰流量，但  $E_{NS}$  均达到了 0.7 以上。预报降雨模拟的 20120726 和 20210721 场次峰量较小的洪水， $E_{NS}$  均小于 0.3，但 20120726 场次洪水 1 h 预见期径流量相对误差小于 20%，20210721 场次洪水的洪峰流量预报效果也好于实测降雨模拟结果。对于 20160719 场次峰量较大的洪水，1 h 预见期预报的洪水  $E_{NS}$  均能达到 0.7 以上且预报洪峰流量相对误差均小于 20%，满足预报的精度要求。2 h 预见期洪水预报效果显著变差，洪峰流量和径流量的预报也存在较大误差。1 h 预见期时，TransAtt-Unet 对于 3 场洪水的预报洪峰流量和径流量相对误差均小于 20%，且 20160719 场次洪水  $E_{NS}$  达 0.78；Att-Unet 则较准确地预报出 20210721 场次洪水的洪峰流量，相对误差仅为 -0.9%。由于 2 h 预见期预报的降水量存在显著低估，使得预报洪峰流量显著小于实测值，但 U-Net 模型对 3 场洪水预报的  $E_{NS}$  为 3 个深度学习模型的最优值，且预报的 20160719 场次洪水  $E_{NS}$  达 0.52。

表 5 洪水预报精度评价结果

Table 5 Accuracy evaluation of forecasted floods

| 洪水场次          | 模型            | 预见期   | $Q_S / (m^3 \cdot s^{-1})$ | $E_{RP} / \%$ | $V_S / mm$ | $E_{RV} / \%$ | $\Delta T / h$ | $E_{NS}$ |      |
|---------------|---------------|-------|----------------------------|---------------|------------|---------------|----------------|----------|------|
| 20120726      | U-Net         | 1 h   | 31.3                       | -33.4         | 4.4        | -13.6         | 1              | 0.23     |      |
|               |               | 2 h   | 19.2                       | -59.2         | 4.7        | -8.0          | 1              | 0.16     |      |
|               | Att-UNet      | 1 h   | 40.3                       | -24.5         | 5.6        | 8.8           | 1              | 0.06     |      |
|               |               | 2 h   | 17.8                       | -62.1         | 3.9        | -43.6         | 3              | 0.08     |      |
|               | TransAtt-UNet | 1 h   | 38.0                       | -19.2         | 5.3        | 2.2           | 1              | 0.23     |      |
|               |               | 2 h   | 19.0                       | -59.6         | 4.3        | -17.1         | 1              | 0.15     |      |
|               | 实测降雨模拟        |       |                            | 36.7          | -21.9      | 7.05          | 37.2           | 0        | 0.72 |
|               | 20160719      | U-Net | 1 h                        | 372.4         | 1.2        | 162.5         | 25.8           | 1        | 0.76 |
| 2 h           |               |       | 198.4                      | -46.1         | 89.3       | -30.9         | 3              | 0.52     |      |
| Att-UNet      |               | 1 h   | 407.3                      | 10.7          | 165.9      | 28.4          | 1              | 0.77     |      |
|               |               | 2 h   | 185.3                      | -49.7         | 79.3       | -38.6         | 4              | 0.34     |      |
| TransAtt-UNet |               | 1 h   | 354.9                      | -3.6          | 154.8      | 19.9          | 1              | 0.78     |      |
|               |               | 2 h   | 191.3                      | -48.1         | 83.9       | -35.0         | 3              | 0.37     |      |
| 实测降雨模拟        |               |       | 343.3                      | -6.7          | 167.7      | 29.8          | 1              | 0.83     |      |
| 20210721      |               | U-Net | 1 h                        | 123.2         | 32.0       | 33.0          | 10.4           | 0        | 0.25 |
|               | 2 h           |       | 32.3                       | -65.4         | 7.7        | -74.3         | 0              | 0.14     |      |
|               | Att-UNet      | 1 h   | 92.5                       | -0.9          | 17.9       | -40.1         | 1              | 0.04     |      |
|               |               | 2 h   | 41.6                       | -55.4         | 11.6       | -61.3         | 1              | -0.09    |      |
|               | TransAtt-UNet | 1 h   | 101.0                      | 8.3           | 25.7       | -14.0         | 0              | 0.19     |      |
|               |               | 2 h   | 57.0                       | -38.9         | 12.8       | -57.2         | 1              | 0.02     |      |
|               | 实测降雨模拟        |       |                            | 76.2          | -18.3      | 27.7          | -7.3           | 0        | 0.79 |

预报洪水过程线如图 6 所示。3 种模型 1 h 预见期洪水变化过程与实际较为一致, 预报的 20120726 场次洪水峰现时间和洪水涨落时间较实际滞后 1 h; 20160719 场次预报洪水与实测降雨模拟的峰现时间均较实际滞后 1 h, 预报洪峰与实际较为接近, 但径流量存在一定的高估; 对于 20210721 场次洪水预报, U-Net 预报的洪峰流量较实际偏大, Att-UNet 预报的峰现时间较实际滞后 1 h, TransAtt-UNet 的预报结果与实际更为接近, 3 种模型均能预报出该场洪水的涨落过程。深度学习的方法对于剧烈变化的降雨引发的洪水, 1 h 预见期的预报洪水  $E_{NS}$  较低, 但能较好地预报出洪水的变化过程和洪峰流量, 对量级较大的洪水能取得较高的  $E_{NS}$ , 且能在准确预报洪水变化过程的基础上, 较准确地预报出洪峰流量、径流量和峰现时间。2 h 预见期降雨虽然可以预报出洪峰形成过程, 但对洪峰流量和径流量存在显著低估。糜佳伟等<sup>[32]</sup>在梅溪流域(面积约 956 km<sup>2</sup>)进行降雨预报和洪水预报, 指出 1 h 预见期降雨预报结果能满足中小流域洪水预报需求。本研究在降雨径流响应时间更快的柳林实验流域进行洪水预报, 尽管预报洪水  $E_{NS}$  较小, 但能在 1 h 预见期对不同类型降雨引发的洪水取得较为准确的洪峰流量和径流量预报效果, 预报的 20160719 场次大洪水的洪峰流量和径流量相对误差小于实测降雨模拟洪水结果, 因此, 1 h 预见期洪水预报效果具有一定的准确性, 为流域的防洪减灾工作争取了更长的时间。未来可在更多流域开展雷达降雨临近预报和洪水预报研究, 以验证本文采用的深度学习方法在其他流域的适用性。

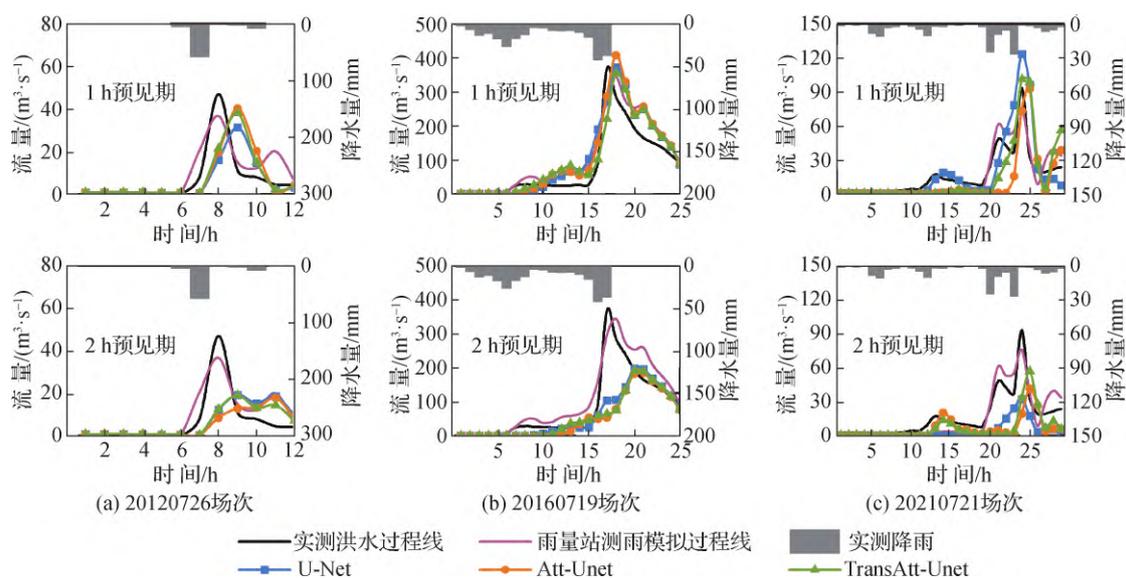


图6 模拟和预报洪水过程线

Fig. 6 Simulated and forecasted flood hydrographs

## 4 结 论

采用深度学习的 U-Net、Att-Unet 和 TransAtt-Unet 进行雷达回波外推, 通过动态雷达反射率因子和降雨强度关系实现雷达降雨临近预报, 将降雨预报的结果输入 HEC-HMS 水文模型对柳林实验流域典型洪水过程进行预报, 得到以下主要结论:

(1) 1 h 预见期时 Att-Unet 对强回波过程外推效果较好, TransAtt-Unet 对变化更丰富的回波过程外推效果较好; 2 h 预见期时 U-Net 外推效果更稳定。

(2) 深度学习模型在 1 h 预见期对短时强降雨存在时间上的误差, 对持续时间较长的降雨存在少量预报异常值, 但均能较准确地预报降雨强度和过程; 2 h 预见期降雨存在显著低估和较大误差。

(3) 3 种模型的 1 h 预见期预报的洪水能反映实际变化过程, TransAtt-Unet 预报的洪峰流量和径流量误差更小, Att-Unet 能对部分场次洪水取得较准确的洪峰预报效果。U-Net 在 2 h 预见期洪水预报效果精度最高。

### 参考文献:

- [1] 雍斌, 张建云, 王国庆. 黄河源区水文预报的关键科学问题[J]. 水科学进展, 2023, 34(2): 159-171. (YONG B, ZHANG J Y, WANG G Q. Key scientific issues of hydrological forecast in the headwater area of Yellow River[J]. Advances in Water Science, 2023, 34(2): 159-171. (in Chinese))
- [2] 金君良, 舒章康, 陈敏, 等. 基于数值天气预报产品的气象水文耦合径流预报[J]. 水科学进展, 2019, 30(3): 316-325. (JIN J L, SHU Z K, CHEN M, et al. Meteorological-hydrological coupled runoff forecasting based on numerical weather prediction products[J]. Advances in Water Science, 2019, 30(3): 316-325. (in Chinese))
- [3] IMHOFF R O, BRAUER C C, van HEERINGEN K J, et al. Large-sample evaluation of radar rainfall nowcasting for flood early warning[J]. Water Resources Research, 2022, 58(3): e2021WR031591.
- [4] IMHOFF R O, de CRUZ L, DEWETTINCK W, et al. Scale-dependent blending of ensemble rainfall nowcasts and numerical weather prediction in the open-source pysteps library[J]. Quarterly Journal of the Royal Meteorological Society, 2023, 149(753):

1335-1364.

- [5] 刘佳,邱庆泰,李传哲,等. 降水临近预报及其在水文预报中的应用研究进展[J]. 水科学进展, 2020, 31(1): 129-142. (LIU J, QIU Q T, LI C Z, et al. Advances of precipitation nowcasting and its application in hydrological forecasting[J]. Advances in Water Science, 2020, 31(1): 129-142. (in Chinese))
- [6] ZHANG Y C, LONG M S, CHEN K Y, et al. Skilful nowcasting of extreme precipitation with NowcastNet[J]. Nature, 2023, 619(7970): 526-532.
- [7] SOKOL Z, SZTURC J, ORELLANA-ALVEAR J, et al. The role of weather radar in rainfall estimation and its application in meteorological and hydrological modelling: a review[J]. Remote Sensing, 2021, 13(3): 351.
- [8] HAN L, ZHAO Y Y, CHEN H N, et al. Advancing radar nowcasting through deep transfer learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-9.
- [9] BI K F, XIE L X, ZHANG H H, et al. Accurate medium-range global weather forecasting with 3D neural networks[J]. Nature, 2023, 619(7970): 533-538.
- [10] 李步,田富强,李钰坤,等. 融合气象要素时空特征的深度学习水文模型[J]. 水科学进展, 2022, 33(6): 904-913. (LI B, TIAN F Q, LI Y K, et al. Development of a spatiotemporal deep-learning-based hydrological model[J]. Advances in Water Science, 2022, 33(6): 904-913. (in Chinese))
- [11] RITVANEN J, HARNIST B, ALDANA M, et al. Advection-free convolutional neural network for convective rainfall nowcasting[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 1654-1667.
- [12] AYZEL G, SCHEFFER T, HEISTERMANN M. RainNet v1.0: a convolutional neural network for radar-based precipitation nowcasting[J]. Geoscientific Model Development, 2020, 13(6): 2631-2644.
- [13] HAN L, LIANG H, CHEN H N, et al. Convective precipitation nowcasting using U-net model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-8.
- [14] 熊立华,刘成凯,陈石磊,等. 遥感降水资料后处理研究综述[J]. 水科学进展, 2021, 32(4): 627-637. (XIONG L H, LIU C K, CHEN S L, et al. Review of post-processing research for remote-sensing precipitation products[J]. Advances in Water Science, 2021, 32(4): 627-637. (in Chinese))
- [15] 刘家宏,梅超,刘宏伟,等. 特大城市外洪内涝灾害链联防联控关键科学技术问题[J]. 水科学进展, 2023, 34(2): 172-181. (LIU J H, MEI C, LIU H W, et al. Key scientific and technological issues of joint prevention and control of river flood and urban waterlogging disaster chain in megacities[J]. Advances in Water Science, 2023, 34(2): 172-181. (in Chinese))
- [16] HEUVELINK D, BERENQUER M, BRAUER C C, et al. Hydrological application of radar rainfall nowcasting in the Netherlands[J]. Environment International, 2020, 136: 105431.
- [17] NGUYEN H M, BAE D H. An approach for improving the capability of a coupled meteorological and hydrological model for rainfall and flood forecasts[J]. Journal of Hydrology, 2019, 577: 124014.
- [18] 包红军,曹勇,曹爽,等. 基于短时临近降水集合预报的中小河流洪水预报研究[J]. 河海大学学报(自然科学版), 2021, 49(3): 197-203. (BAO H J, CAO Y, CAO S, et al. Flood forecasting of small and medium-sized rivers based on short-term nowcasting and ensemble precipitation forecasts[J]. Journal of Hohai University (Natural Sciences), 2021, 49(3): 197-203. (in Chinese))
- [19] GAO Y B, GUAN J P, ZHANG F H, et al. Attention-unet-based near-real-time precipitation estimation from Fengyun-4A satellite imageries[J]. Remote Sensing, 2022, 14(12): 2925.
- [20] FANG J, YANG C, SHI Y T, et al. External attention based TransUNet and label expansion strategy for crack detection[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 19054-19063.
- [21] TREBING K, STAÑCZYK T, MEHRKANOON S. SmaAt-UNet: precipitation nowcasting using a small attention-UNet architecture[J]. Pattern Recognition Letters, 2021, 145: 178-186.
- [22] ZOU H B, WU S S, TIAN M X. Radar quantitative precipitation estimation based on the gated recurrent unit neural network and echo-top data[J]. Advances in Atmospheric Sciences, 2023, 40(6): 1043-1057.
- [23] GOU Y B, CHEN H N, CHANDRASEKAR V. A dynamic approach to quantitative precipitation estimation using multiradar multigauge network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(9): 6376-6390.

- [24] 殷志远, 杨芳, 王斌, 等. 基于雷达估算降雨的湖北漳河流域径流模拟研究[J]. 自然灾害学报, 2020, 29(1): 143–151. (YIN Z Y, YANG F, WANG B, et al. Research on runoff simulation of Zhanghe basin based on radar estimation precipitation[J]. Journal of Natural Disasters, 2020, 29(1): 143–151. (in Chinese))
- [25] 李建柱, 李磊菁, 张婷, 等. DEM 数据源及分辨率对流域洪水模拟影响研究[J]. 水力发电学报, 2023, 42(3): 26–40. (LI J Z, LI L J, ZHANG T, et al. Effect of DEM data sources and resolutions on watershed flood simulations[J]. Journal of Hydroelectric Engineering, 2023, 42(3): 26–40. (in Chinese))
- [26] KO J, LEE K, HWANG H, et al. Effective training strategies for deep-learning-based precipitation nowcasting and estimation[J]. Computers & Geosciences, 2022, 161: 105072.
- [27] LAGERQUIST R, STEWART J Q, EBERT-UPHOFF I, et al. Using deep learning to nowcast the spatial coverage of convection from himawari-8 satellite data[J]. Monthly Weather Review, 2021, 149(12): 3897–3921.
- [28] SUN F L, LI B, MIN M, et al. Toward a deep-learning-network-based convective weather initiation algorithm from the joint observations of Fengyun-4A geostationary satellite and radar for 0–1 h nowcasting[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 3455–3468.
- [29] 曹伟华, 南刚强, 陈明轩, 等. 基于深度学习的京津冀地区精细尺度降水临近预报研究[J]. 气象学报, 2022, 80(4): 546–564. (CAO W H, NAN G Q, CHEN M X, et al. A study on fine scale precipitation nowcasting in Beijing–Tianjin–Hebei region based on deep learning[J]. Acta Meteorologica Sinica, 2022, 80(4): 546–564. (in Chinese))
- [30] 石毅. 基于雷达短时降雨临近预报小流域洪水预报研究[D]. 天津: 天津大学, 2023. (SHI Y. Flood forecasting based on radar precipitation nowcasting in a small watershed in North China[D]. Tianjin: Tianjin University, 2023. (in Chinese))
- [31] MIHULEȚ E, BURCEA S, MIHAI A, et al. Enhancing the performance of quantitative precipitation estimation using ensemble of machine learning models applied on weather radar data[J]. Atmosphere, 2023, 14(1): 182.
- [32] 糜佳伟, 田济扬, 楚志刚, 等. 耦合天气雷达定量降水估计与定量降水预报的中小流域洪水预报研究[J]. 华北水利水电大学学报(自然科学版), 2022, 43(3): 11–18. (MI J W, TIAN J Y, CHU Z G, et al. Study on flood forecasting of small and media size basins by coupling weather radar quantitative precipitation estimate and quantitative precipitation forecast[J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2022, 43(3): 11–18. (in Chinese))

## Radar rainfall nowcasting and flood forecasting based on deep learning\*

LI Jianzhu, LI Leijing, FENG Ping, TANG Ruoyi

(State Key Laboratory of Hydraulic Engineering Simulation and Safety, Tianjin University, Tianjin 300350, China)

**Abstract:** To explore the applicability of deep learning methods to radar rainfall nowcasting and flood forecasting, U-Net, Attention-Unet and TransAtt-Unet are used to carry out rainfall nowcasting. The nowcasted rainfall results are used as inputs to the HEC-HMS hydrological model for flood forecasting. The results show that with a 1-hour lead time, Attention-Unet has the best performance in nowcasting heavy rainfall with a short duration, and the relative errors in the simulated flood peak and runoff volume by the nowcasted rainfall of TransAtt-Unet are less than 20%. Each deep learning model has a good forecasting accuracy for rainfall and flood events with large magnitudes. The rainfall intensity, rainfall totals, flood peaks and runoff volumes are significantly underestimated with a 2-hour lead time, with U-Net achieving relatively good rainfall nowcasting. The 1-hour lead time radar rainfall nowcasting and flood forecasting based on deep learning can provide a scientific reference for watershed flood prevention and mitigation.

**Key words:** radar rainfall nowcasting; quantitative rainfall estimation; deep learning; flood forecasting; Liulin experimental watershed

\* The study is financially supported by the National Natural Science Foundation of China (No. 52279022).