

融合光流法和深度学习的降水临近预报模型及其预报试验¹

韩丰 薛峰 吕终亮 何锡汶 刘涛

国家气象中心, 北京 100081

摘要: 为提升降水临近预报性能, 本文基于注意力机制与编码-解码结构设计了 OF-RainNet 模型。该模型同时输入定量降水估计 (SWAN-QPE) 和 0~2h 基于光流法的定量降水预报 (SWAN-QPF) 产品, 实现降水平流外推信息与深度学习模型的有效融合; 引入超级词元注意力模块 (STA) 提取对降水预报有意义的语义单元并计算多头注意力, 实现 1km 分辨率、逐 6min 起报的 1h 和 2h 降水预报。以北京为研究区域, 开展 OF-RainNet 模型的临近预报试验。对 2024 年、2025 年的 7-8 月降水批量检验结果表明, OF-RainNet 对不同强度 (≥ 5 、 ≥ 10 、 ≥ 20 、 $\geq 50\text{mm}\cdot\text{h}^{-1}$) 降水的 1h、2h 预报 TS 评分均高于 SWAN-QPF 和 PredRNNv2, 相对提升大多在 10% 以上 (除 $\geq 5\text{mm}\cdot\text{h}^{-1}$ 外); 相较于不引入光流外推产品和 STA 模块, OF-RainNet 的 TS 评分显著提升, 强降水 Bias 略高于 1。个例检验表明, OF-RainNet 的预报性能优于 PredRNNv2, 对强降水持续阶段的预报能力优于局地触发阶段, 1h 预报优于 2h 预报。总体上看, OF-RainNet 有效提升了模型的降水临近预报能力, 融合方法能获得正技巧, 可为强降水短临预报提供技术参考。

关键词: 降水临近预报; 注意力机制; 深度学习; 光流法

中图分类号: P409, P456

DOI: 10.7519/j.issn.1000-0526.2026.010801

引言

临近降水预报在山洪地质灾害、中小河流洪水等灾害性天气防灾减灾工作中扮演着不可或缺的角色 (Gao et al, 2021; 罗健文等, 2024)。然而, 实现高精度、高准确率的实时降水临近预报依然是个突出挑战 (曹勇等, 2016)。

多项研究表明, 基于雷达回波的外推预报是临近预报 (0~2h) 中预报性能相对较好的技术方法之一。现阶段, 外推预报可分为传统外推技术 (如光流法, 交叉相关法) 和深度学习外推模型。传统外推技术以雷达回波的发展变化符合拉格朗日守恒定律为理论基础, 通过分析相邻时刻雷达回波的空间演变规律, 提取回波的运动矢量, 再根据矢量对当前时刻的回波进行外推运算, 最终实现降水临近预报 (Pulkkinen et al, 2021; 曹勇等, 2021; 韩丰等, 2023), 相关技术已在业务中进行了大量的实时应用。

近年来, 以深度学习为代表的人工智能技术在图像识别和推理领域取得了突破性进展 (周康辉等, 2021), 由于其挖掘海量数据和非线性建模的优秀能力, 众多学者将其应用到气

¹国家自然科学基金项目 (U244220013), 国家重点研发计划 (2022YFC3002904), 中国气象局重点创新团队 (CMA2022ZD07) 共同资助

收稿日期: 修回日期:

第一作者简介: 韩丰, 主要从事气象短临预报算法研究; E-mail: hanfeng@cma.gov.cn

通讯作者: 薛峰, 主要从事气象信息技术相关研究; E-mail: xuef@cma.gov.cn

象领域。姚文等（2025）提出一种基于轻量化卷积神经网络（YOLOv5）与多目标跟踪算法（DeepSort）相结合的天气雷达鸟杂波识别与追踪算法，提升鸟类杂波的识别准确率。皇甫江等（2022）基于双偏振雷达数据利用深度学习构建定量估测降水模型。钟琦等（2025）使用 LightGBM 模型和降水相关的物理量参数，提升了强降水的预报能力。渠鸿宇等（2024）基于 XGBoost 模型研发台风快速增强预报模型和预报订正模型。

在基于雷达回波的外推预报任务中，深度学习模型不仅能给出降水系统的位置，还能一定程度上给出降水强度的变化趋势。Shi et al(2015)提出的卷积长短期记忆网络(ConvLSTM)，该模型融合了卷积神经网络(CNN)和循环神经网络(RNN)的特点，通过卷积提取回波的空间特征，再将空间特征通过长短期记忆网络(LSTM)单元进行时序建模，大幅提升了基于深度神经网络的临近预报准确性。随后，Shi et al(2017)进一步研发了TrajGRU模型，通过提升模型对回波运动规律的模拟能力，进一步提升了临近预报的准确性。Wang et al(2017; 2018; 2023)先后提出了PredRNN、PredRNN++、PredRNNv2等模型，通过设计实现时空长短期记忆网络(ST-LSTM)和具有级联双记忆结构的LSTM(CausalLSTM)，解决了模型训练中梯度消失的问题，进一步提高了模型对复杂天气系统动态预测的准确性。庄潇然等(2023)基于PhyDNet(Le Guen and Thome, 2020)提出PhyDNet-RP模型进行降水临近预报试验，发现在降水预报模型中，增加雷达回波输入可以提升模型对强降水发展演变的模拟能力。Zhang et al(2023)提出NowcastNet将物理演变方案与深度学习相结合，获得了更长的预报时间和精细的预报细节。国家气象中心基于NowcastNet发展“风雷”临近预报模型，该模型基于雷达组合反射率开展0-3h的临近预报，经检验发现，其客观检验评分优于传统光流外推算法，能够为强对流临近预报提供较好的指导产品(盛杰等, 2025)。

另一类采用编码-解码架构(Encoder-Decoder)的模型也在临近预报中取得了不错的应用效果(徐成鹏等, 2022)。Han et al(2023)将视频预测模型SimVP(Gao et al, 2021)迁移到降水临近预报中，提升了降水预报准确率。Trebing et al(2021)将注意力机制引入U-Net架构，设计SmaAt-UNet，在保持相同的预报性能基础上，大幅减少了资源消耗。

对比两种降水临近外推预报技术路线可知，以光流法为代表的传统外推方法在实时业务中已得到广泛应用，通过长时间的实践和调优，该类方法具备一定的降水临近预报能力，尤其是在降水系统的移动速度和方向方面有较好的预报效果，但由于其原理上忽略了运动方程中的局地生消项，无法模拟天气系统发展演变，对生命周期较短，变化剧烈的对流性强降水的预报能力明显不足(韩丰等, 2023)。基于深度学习的外推模型在降水系统的发展演变预测中表现出一定程度的优势，但预报结果往往会随着预测时间的延长而出现“平滑”现象(袁凯等, 2022)，而且模型对于回波运动方向和速度的预测没有传统方法稳定。


基于以上分析，本文设计了一种融合光流外推和深度学习技术的预报模型OF-RainNet，深度耦合光流外推的运动特征与深度学习的非线性拟合能力，最终提升降水的临近预报能力。OF-RainNet采用编码-解码结构，在编码阶段，一方面将强对流天气短时临近预报系统(SWAN)的光流外推预报产品(SWAN-QPF)和降水估计(SWAN-QPE)作为模型输入，实现回波的位置预报信息和深度学习外推模型的融合，充分发挥两类技术的优势；另一方面，考虑到降水的空间非线性分布特征，本文采用超级词元注意力(Super Token Attention, STA)模块提取对降水预报有意义的语义单元并计算多头注意力，以提升模型对于降水的时空特征提取能力。最终实现1km分辨率、逐6min起报的1h和2h降水临近预报。最后，本文以北京为目标

区域设计对比试验，通过 2024-2025 年的汛期检验，讨论 OF-RainNet 模型的预报性能。

1. OF-RainNet 模型

本文基于编码-解码架构设计 OF-RainNet 模型，其结构如图 1 所示。该模型由编码器和解码器两部分组成：在编码阶段，使用 3×3 卷积串联坐标注意力模块作为特征提取器，提取数据的空间特征，最后串联多个注意力模块，通过超级词元注意力（STA）模块操作捕捉全局和局部信息。在解码阶段，先将特征信息进行上采样，再与高分辨率特征图融合，最终实现降水预报。为了提升模型的降水预报能力，OF-RainNet 在以下两个方面进行改进：

- 1) 在编码阶段，分别对实况序列和外推序列进行特征提取。同时在编码器和解码器之间通过跳跃链接机制，将外推序列的特征直接传递至解码部分，补充细节信息。
- 2) 应用 STA 模块，实现降水词元（Token）的聚合，强化全局特征提取能力，进而实现全局和局部的空间特征融合。同时降低计算成本，兼顾效率与性能。



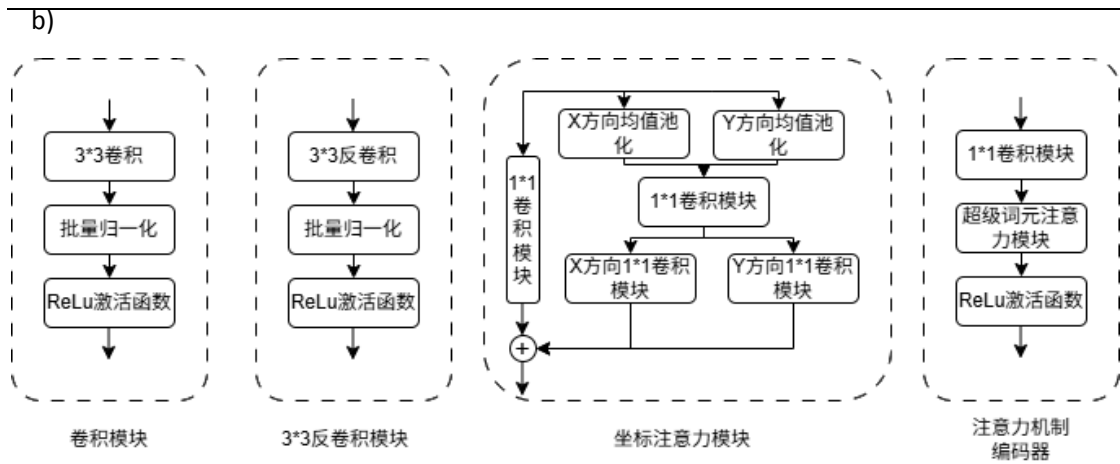


图 1 OF-RainNet 模型(a)整体架构和 (b) 各主要模块结构

Fig.1 Overall architecture of OF-RainNet: (a) general structure and (b) structures of main modules

1.1 编码器

编码器采用堆叠策略，将 3×3 卷积模块与坐标注意力模块相结合。编码器由两个 3 层编码器组成，分别对应实况序列与外推序列的特征提取。在特征提取过程中，每层的第一个卷积模块采用步长为 1 的 3×3 卷积，确保特征提取的精细化；每层最后一个卷积模块则采用步长为 2 的 3×3 卷积，实现下采样操作。在传统模型中，过度依赖卷积模块堆叠易导致空间细节信息大量损失。本文设计 OF-RainNet 模型时，通过在卷积模块堆叠中穿插坐标注意力模块，利用 1×1 卷积模块聚合特征通道，既能强化特征层的空间信息与通道信息，又能减少冗余信息，最终优化模型对空间特征的提取效果。

1.2 STA 模块

Transformer 是以注意力机制为核心的模型单元，目前广泛应用于图像识别、翻译、自然语言对话和语音生成等领域。Transformer 的输入是文字式的“小单元”，即字、词或词组。而降水网格数据为大规模数据矩阵，所以在图像类任务应用 Transformer 时，需要把图像拆成小的图像单元，即词元，也可以理解为图像的语义单元 (Vaswani et al, 2017; Dosovitskiy et al, 2021)。

一般图像类任务都采用固定的窗口生成词元，但是考虑到降水数据在小空间内具有明显的突变且纹理信息丰富，其他区域则仅有部分纹理或者无纹理，如果按照固定的窗口进行 Token 划分，难以精准捕捉降水系统的空间特征；此外，现有 Transformer 在浅层网络中更倾向于捕获局部特征，全局特征提取能力相对有限。

为了提升模型全局特征提取能力，同时增强降水所在词元的特征表达能力，本文使用 Huang et al (2023) 提出的 STA 模块。STA 模块的核心流程包括三个阶段，即超级词元采样、多头自注意力计算和超级词元上采样。

1) 超级词元采样：首先通过步长为 2 的 3×3 卷积将降水网格数据转换为词元。然后通过平均池化操作，将词元分割成固定大小的网格区域，每个区域生成一个初始超级词元。遍历每个词元，计算其与周围 9 个超级词元之间的关联程度（通过计算词元和超级词元之间的内积得到）。最后使用关联程度作为权重，将词元线性组合成新的超级词元。

2) 自注意力计算：应用多头注意力机制计算超级词元间的注意力矩阵。

3) 超级词元上采样：使用 1) 中映射关系，将超级词元映射回词元空间。将映射回来的

超级词元表示与原始词元相加，融合全局和局部信息最后输出。

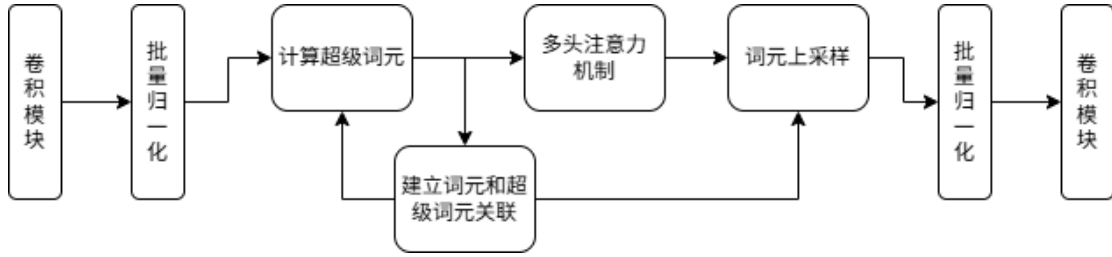


图 2 STA 模块

Fig.2 Design of Super Token Attention

图 2 为本文使用的 STA 模块的结构。Of-RainNet 通过堆叠了 4 层的超级词元注意力模块进行特征提取，最后使用 1×1 卷积、全局平均池化和全连接层连接模型的解码器部分。

1.3 解码器

解码器采用 3 层反卷积模块串联坐标注意力模块的堆叠策略来逐渐还原降水预报结果。在此过程中，第一个反卷积操作承担了上采样功能，将特征空间恢复至与原始输入匹配的分辨率，该操作的采样步长设为 2。随后的坐标注意力模块和反卷积模块则通过步长为 1 的卷积，对特征信息进行精细化处理，以确保输出结果的细节质量。此外，通过解码器模块的跳跃连接，可以利用外推序列输入的浅层特征，进一步补充并恢复降水预报结果的细节信息。

1.4 模型超参数设置

Of-RainNet 模型采用 3 层编码器、3 层解码器、4 层 STA 模块，每个 STA 模块采用 4 头注意力机制。使用 Adam 优化器，初始学习率设置为 0.001，学习率衰减系数设置为 0.5，batch_size 设置为 4。

1.5 损失函数优化

损失函数用于计算模型参数的梯度，是深度学习模型优化的核心组件。目前最常用的损失函数包括均方根误差 (MSE) 和绝对误差 (MAE)，其中 MSE 损失函数容易导致预报结果过于平滑。本文采用了 Shi et al (2017) 提出的加权 MAE 损失函数 (B-MAE)，以提升模型在较强降水场景下的预报效果。该损失函数公式如下：

$$loss = \frac{1}{N} \sum_{i=1}^N \left(w_p \left| \widehat{y}_i^p - y_i^p \right| \right) \quad (1)$$

其中 w_p 为对应分段的权重， y_i^p 为降水真值场， \widehat{y}_i^p 为降水预报场，其中 p 为降水强度等级， N 为网格格点数。

表 1 Of-RainNet 模型中损失函数的分段权重

Tab.1 Design of Piecewise Weights for Loss Functions

级别 (p)	降水强度 ($\text{mm} \cdot \text{h}^{-1}$)	权重
1	< 2	1
2	$[2, 5)$	2
3	$[5, 10)$	5

4	[10, 30)	10
5	≥ 30	30

1.6 实时运行流程

在实时运行时，OF-RainNet 逐 6min 起报，实时收集 SWAN 系统输出的 QPE 降水序列（SWAN-QPE）和 0-2h 降水外推数据（SWAN-QPF），输出 1h、2h 时效的降水临近预报产品。

2. 数据集

选取北京（115°~118°E, 39°~42°N）作为 OF-RainNet 模型试验区域。本文使用 2021—2025 年 SWAN 系统的 SWAN-QPE 和逐 6min 预报间隔 0-2h SWAN-QPF 产品构建数据集，SWAN-QPF 采用梯度拟搜索光流法（韩丰等，2023）。其中 2021 年 4 月至 2023 年 10 月的数据作为学习集，2024 年 7—8 月和 2025 年 7—8 月的数据作为检验集。本文中所有的数据时间均为北京时。

在制作数据集时，为了扩大数据集，选取京津冀范围（113°-120°E, 36°-43°N）作为数据集提取范围。采用步长为 30 的滑动 300×300 窗口，选择窗口内降水格点超过 10% 且最大降水强度超过 $3\text{mm}\cdot\text{h}^{-1}$ 的数据所对应的数据作为一个降水事件。对每个降水事件提取过去 1h 降水序列和未来 2h 降水序列，得到一组样本，共得到 7962 个样本数据。以该降水事件未来 1h 的 SWAN-QPE 产品和未来 2h 的 SWAN-QPE 产品作为真值，分别训练 1h、2h 的 OF-RainNet 降水临近预报模型。

3. 检验分析

3.1 试验设计

为评估模型的性能和外推数据对预报结果的影响，本文设计试验方案如表 2 所示，其中 Test2~Test5 为对照试验组。

表 2 试验方案设计

Fig.2 test scheme

试验名称	试验方案
Test1	OF-RainNet
Test2	SWAN 光流法
Test3	PredRNNv2
Test4	不使用 SWAN-QPF 数据的 OF-RainNet
Test5	不使用 STA 模块的 OF-RainNet

通过对比 Test1 和 Test2，验证 OF-RainNet 对输入的 SWAN-QPF 光流法外推预报是否有正的订正效果；通过对比 Test1 和 Test3，验证 OF-RainNet 和其他深度学习模型如 PredRNNv2 相比，是否有正技巧；通过对比 Test1 和 Test4，验证在 OF-RainNet 中加入 SWAN-QPF 产品输入是否具有正向效果；通过对比 Test1 和 Test5，验证 STA 模块对预报效果的影响。其中 PredRNNv2 采用开源版本。Test5 中，将 STA 模块换成常规的 Transformer 模块。

3.2 检验方法

使用 TS、POD 和 Bias 三种检验指标，如式 (2)，开展长时间序列测试。使用试验范围内的 236 个自动气象站作为评分站，对不同强度降水的预报进行检验。在计算命中数 ($n_{成功}$)、空报数 ($n_{空报}$) 和漏报数 ($n_{漏报}$) 时，采用点对面 (半径 3km) 的检验方法。

$$\begin{aligned} POD &= \frac{n_{成功}}{n_{成功} + n_{漏报}} \\ TS &= \frac{n_{成功}}{n_{成功} + n_{漏报} + n_{空报}} \\ BIAS &= \frac{n_{成功} + n_{空报}}{n_{漏报} + n_{空报}} \end{aligned} \quad (2)$$



预报结果空间分辨率为 $0.01^\circ \times 0.01^\circ$ ，预报时效为 1h 和 2h。

3.3 长时序检验


图 3 为的是 2024 年 7-8 月和 2025 年 7-8 月，北京地区预报试验的批量检验结果。从 TS 评分来看 (图 3a、3b)，在 1h 和 2h 的预报时效下，除了 1h 预报的 $\geq 1\text{mm}\cdot\text{h}^{-1}$ 阈值以外，Test1 全部高于 Test2 和 Test3。对比 Test1 和 Test2 可以看出，OF-RainNet 融合 SWAN-QPF 后，模型输出评分优于 SWAN，说明模型对 SWAN-QPF 有正向订正作用。其中对于 $\geq 10\text{mm}\cdot\text{h}^{-1}$ 及以上强度降水的预报，OF-RainNet 相对 SWAN 提升超过 10%，强降水预报性能提升明显。对比 Test1 和 Test3 可以看出，OF-RainNet 的技巧随着预报时效的延长和检验阈值的提升而提高。其中，OF-RainNet 在 1h 的预报中和 PredRNNV2 性能基本相当，在 2h 的预报中有超过 10% 的相对提升。对比 Test1 和 Test4 可以看出，融合 SWAN-QPF 后，模型的输出得到较大提升，说明模型可以从 SWAN-QPF 中提取有助于提升预报性能的特征。对比 Test1 和 Test5 可以看出，STA 模块的增加可以明显提升 2h 的预报技巧。从 Bias 评分上看 (图 3c、3d)，OF-RainNet 在大部分的检验项目都略高于对照试验，尤其对 $\geq 20\text{mm}\cdot\text{h}^{-1}$ 和 $\geq 50\text{mm}\cdot\text{h}^{-1}$ 的降水预报 Bias 较其他方法偏大，略高于 1。Test5 对 $\geq 10\text{mm}\cdot\text{h}^{-1}$ 的降水预报 Bias 偏高，但是 $\geq 20\text{mm}\cdot\text{h}^{-1}$ 和 $\geq 50\text{mm}\cdot\text{h}^{-1}$ 的则明显偏低，说明未融合 SWAN-QPF 时，模型会减少对于强降水的预报，一定程度上出现“平滑”结果。

a

b



c



d

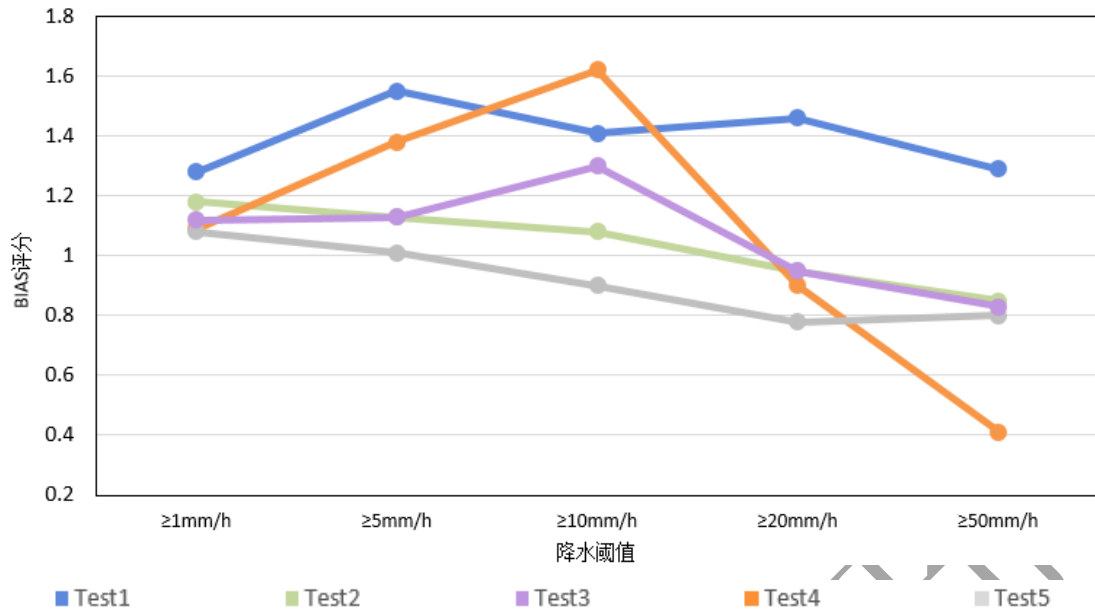


图 3 OF-RainNet 及对照试验组对 2024 年和 2025 年 7—8 月不同降水阈值的预报检验结果

(a, b) TS 评分, (c, d) Bias 评分, (a, c) 1h 预报, (b, d) 2h 预报

Fig.3 Verification Results of OF-RainNet and Control Experiments for Precipitation with Different Rainfall Intensities in July–August 2024 and 2025

(a,b) TS, (c,d) Bias, (a,c) 1h lead time, (b,d) 2h lead time

3.4 个例检验

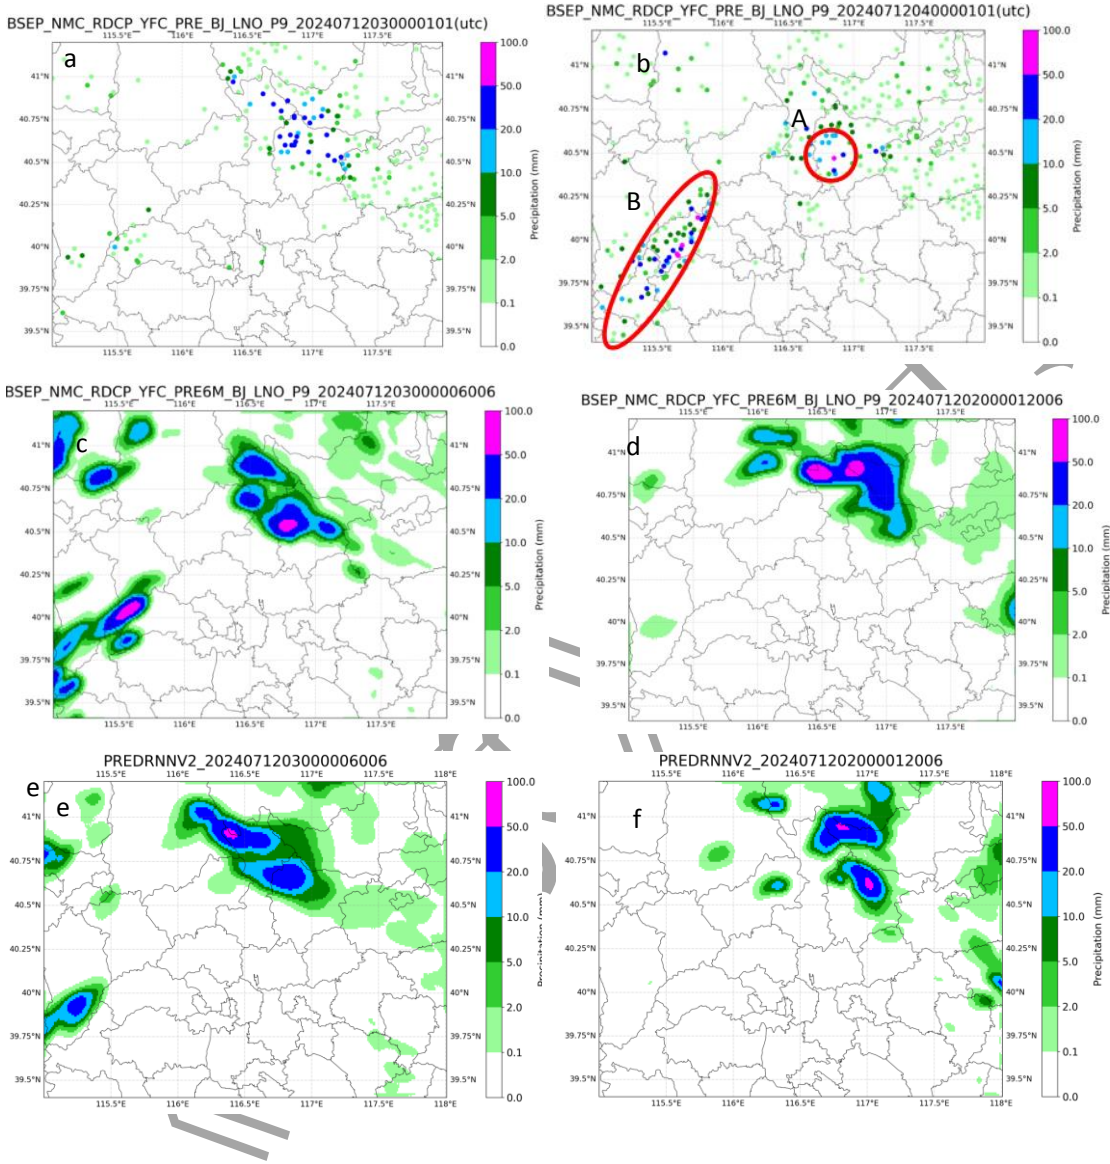
选取北京地区 2 次强降水过程进行个例分析。其中 2024 年 7 月 12 日北京房山暴雨过程主要分析强降水起始阶段, 检验模型对于局地触发强降水的预报能力; 2025 年 7 月 26-27 日北京密云大暴雨过程主要分析强降水维持阶段, 检验模型对于持续的强降水预报能力。

3.4.1 2024 年 7 月 12 日北京房山暴雨过程

2024 年 7 月 12 日中午至午后, 北京地区受到东北冷涡后部偏西北气流、中低层偏南风影响, 西风槽在东移过程中在 500hPa、700hPa 形成中小尺度低涡, 同时 850hPa、700hPa 偏南风加强到 12m/s, 为强对流天气形成提供了动力与水汽条件, 08 时 $T\text{-ln}P$ 图上北京上空出现明显的不稳定层结, 且整层湿度较大, K 指数达到 42.9, 最终导致局地短时强降水过程。12:00 降水在房山突然加强, 迅速向东移动影响城区, 16:00 降水基本结束, 最大小时降水量达到 69mm, 最大过程累计降水量逾 129mm。图 4a、4b 为 11:00、12:00 的小时降水量实况, 图中可见, 北京地区有两个强降水中心, 分别位于密云西南部和门头沟西部(图中 A、B)。图 4c、4e 分别为 OF-RainNet 模型和 PredRNNv2 模型 11:00 起报的 1h 降水, 由图可见 OF-RainNet 模型对于两个强降水中心都有较好体现, 其中 B 区域降水中心量级与实况接近, 位置稍偏西, A 区域强降水中心范围偏小, 整体形态与实况一致; 而 PredRNNv2 模型对 B 区域的降水强度明显估计不足。图 4d、4f 分别为两种模型 10:00 起报的 2h 降水预报, 结果可以看出两种模型对 B 区域的强降水都出现漏报, A 区域的强降水中心虽然都有体现, 但位置都出现有一定程度的偏移。实况可见, B 区的降水在 1h 内得到明显增强, OF-RainNet 模型提前 1h 对该区域降水中心的局地增强有较好的预报效果(图 4c), 但是提前 2h 的预报则出现漏报(图 4d)。这主要是由于 10:00 左右, B 区域虽已聚集较大的不稳定能量, 但是在雷达回波上还没有任何强降水发生的信号, 说明基于雷达回波的外推模型要加强对于突发强

带格式的：字
文 (Calibri)
(宋体)，五号

降水的预报能力，需要引入更多的数据，比如高低空的环境场。从其对此次过程 OF-RainNet 模型预报的 TS 和 POD 评分 (表 3) 可以看出，其 1h 预报效果较好， $\geq 10\text{mm}\cdot\text{h}^{-1}$ 和 $\geq 20\text{mm}\cdot\text{h}^{-1}$ 的命中率分别达到 0.68 和 0.54，但是 2h 预报 TS 评分较低，强降水命中数很少。该个例检验评分整体上较长时序检验评分低，说明 OF-RainNet 模型对于短历时且移动速度较快的突发强降水，预报能力偏弱。



注：图中 AB 对应的椭圆形区域示意分析的强降水区

图 4 2024 年 7 月 12 日小时降水量 (a, b) 实况与 (c,d) OF-RainNet、(e,f) PredRNNv2 模型预报结果对比

(a) 11: 00, (b) 12: 00, (c,e) 11:00 起报的 1h 预报, (d,f) 10:00 起报的 2h 预报

Fig. 4 Comparison of hourly precipitation at (a)11:00, (b)12:00 on July 12, 2024 between observations and forecasts from (c,d) OF-RainNet and (e,f) PredRNNv2 models
(c,e) 1h lead time; (d,f) 2h lead time

表 3 OF-RainNet 模型对北京 2024 年 7 月 12 日降水过程的预报评分

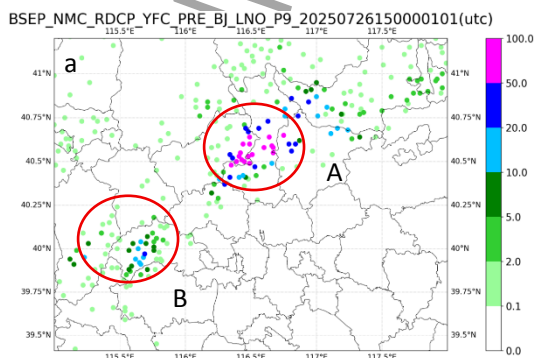
Tab.3 Skills of the Precipitation Process in the Beijing Experimental Area on July 12, 2024

阈值	1h (TS/POD)	2h (TS/POD)
----	-------------	-------------

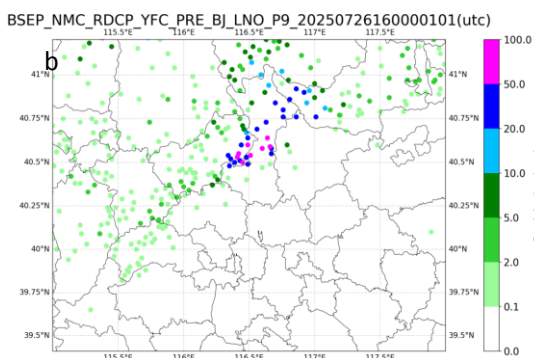
5mm•h-1	0.36/0.75	0.15/0.38
10mm•h-1	0.24/0.68	0.05/0.17
20mm•h-1	0.18/0.54	0.01/0.03

3.4.2 2025 年 7 月 26-27 日北京北部大暴雨过程

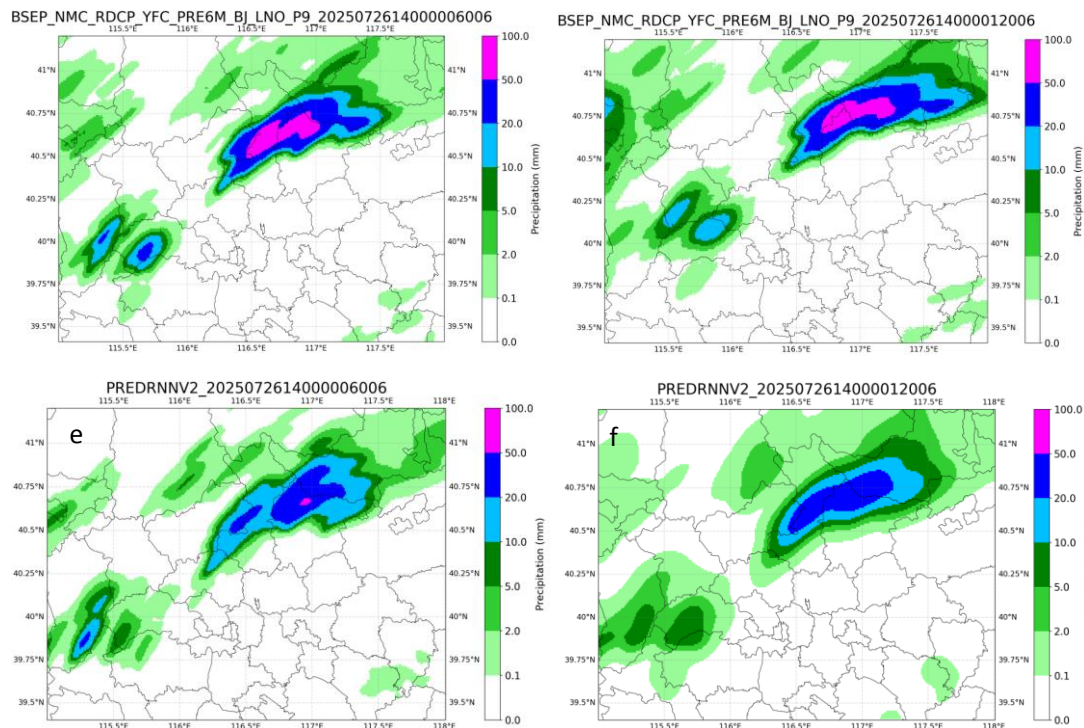
7 月 26 日夜间，北京北部地区经历了一场极端暴雨天气。延庆、怀柔、密云等地出现大暴雨，局地达到特大暴雨级别。最强降水时段集中在 26 日 19 时至 27 日 01 时，其中密云黄土梁站累计降水量超过 300 mm。图 5 给出 26 日 23 时和 27 日 00 时的实况与预报对比。其中，图 5a、5b 为 26 日 23:00、27 日 00:00 的降水实况，可以看出位于怀柔中部（图中 A）的强降水超过 50mm•h-1，强降水维持且少动，门头沟西部（图中 B）的强降水超过 20mm•h-1，之后减弱（图 5b）。图 5c 为 OF-RainNet26 日 22:00 起报的 1h 降水预报，与实况对比可以看出，模型对两个强降水中心都有较好的预报效果，降水强度和位置都与实况较为接近，其中 $\geq 50\text{mm}\cdot\text{h}^{-1}$ 降水全部预报命中， $\geq 20\text{mm}\cdot\text{h}^{-1}$ 和 $\geq 10\text{mm}\cdot\text{h}^{-1}$ 的降水区形态也和实况较为一致，北京及周边的弱降水预报也较为准确，整体预报效果较好。图 5d 为 OF-RainNet26 日 22:00 起报的 2h 降水预报，对比图 5b 和图 5d 可以看出，2h 预报降水整体向西北方移动了 10km，这可能是由于 SWAN-QPF 外推数据给出了降水有一定的移动趋势。A 区域的降水强度预报较为准确，位置偏西北 10km 左右，范围较实况偏大。B 区域的降水有减弱的预报趋势（由 $\geq 20\text{mm}\cdot\text{h}^{-1}$ 减弱到 $\geq 10\text{mm}\cdot\text{h}^{-1}$ ），但和实况相比还存在一定空报。整体上看，2h 的预报对降水整体强度和形态把握较好，位置偏西北。图 5e 和图 5f 为同时次 PredRNNV2 模型的预报结果，对比 OF-RainNet 模型预报结果，发现 PredRNNV2 预报整体降水强度偏弱，尤其是在 2h 的预报中，A 区域的强降水强度明显偏低，而 OF-RainNet 模型则在该区域的预报强度维持，这可能是由于光流外推 QPF 产品为模型提供了降水运动的先验信息，对降水强度的预报起到约束作用。表 4 为此次过程 OF-RainNet 的 TS 和 POD 评分，1h 的 $\geq 20\text{mm}\cdot\text{h}^{-1}$ 和 $\geq 50\text{mm}\cdot\text{h}^{-1}$ 阈值的 TS 和 POD 分达到 0.39/0.58 和 0.11/0.19，说明模型对于本次过程的强降水，在 1 小时内有较高的预报能力，且空报不多。在 2h 预报时段内，各项评分都明显下降， $\geq 20\text{mm}\cdot\text{h}^{-1}$ 的 TS 评分下降到 0.12， $\geq 50\text{mm}\cdot\text{h}^{-1}$ 没有命中，说明在提前 2h 的强降水预报能力还需要加强。该个例评分整体和长时序较为一致，说明 OF-RainNet 模型对于持续性降水预报效果较好。



c



d



注：图中 AB 对应的椭圆形区域示意文中的分析区。

图 5 2025 年 7 月 (a, c, e) 26 日 23: 00, (b, d, f) 27 日 00:00 的小时降水量 (a, b) 实况与 (c, d) OF-RainNet、(e, f) PredRNNv2 模型 26 日 22:00 起报的预报结果对比 (c,e) 1h 预报, (d,f) 2h 预报

Fig.5 Comparison of hourly precipitation at 23:00 on July 26 and 00:00 on July 27, 2025 between (a,b) observations and forecasts by OF-RainNet (c,d) and PredRNNv2 (e,f) models (c,e) 1h lead time, (d,f) 2h lead time

表 4 OF-RainNet 模型对北京 2025 年 7 月 26—27 日降水过程的预报评分

Tab.4 Skills of the Precipitation Process in the Beijing Experimental Area on July 26, 27, 2025

降水强度 阈值	1h 预报 (TS/POD)	2h 预报 (TS/POD)
$\geq 5\text{mm}\cdot\text{h}^{-1}$	0.52/0.76	0.25/0.41
$\geq 10\text{mm}\cdot\text{h}^{-1}$	0.45/0.64	0.18/0.28
$\geq 20\text{mm}\cdot\text{h}^{-1}$	0.39/0.58	0.12/0.18
$\geq 50\text{mm}\cdot\text{h}^{-1}$	0.11/0.19	0.0/0.0

3. 4. 3 个例检验小结

OF-RainNet 的整体预报性能均优于 PredRNNv2。在较强降水预报方面, OF-RainNet 的降水强度和范围预报都与实况更为接近, 而 PredRNNv2 则存在明显的预报平滑问题, 降水

强度预报偏低；在整体预报方面，OF-RainNet 对降水的整体形态和空间位置的预报也更为精准。从降水过程不同阶段和不同预报时效的预报能力上看，OF-RainNet 对强降水持续阶段的预报能力优于强降水突发阶段，1 h 预报明显优于 2 h 预报。

4. 结论

本文基于注意力机制和编码-解码结构设计了 OF-RainNet 降水预报模型，实现了降水平流外推运动信息和深度学习模型的有效融合。以北京地区为试验区域，构建 1km 分辨率、逐 6min 的 1h 和 2h 的降水临近预报试验，结论如下：

- 1) 模型以 SWAN 的 1hQPE 和 0~2hQPF 作为输入数据，通过编码阶段显式输入 SWAN 外推产品，实现传统外推和深度学习模型的融合。模型引入超级词元注意力模块 (STA)，提取面向降水临近预报有意义的语义单元并计算多头注意力，设计分段权重的损失函数，最终实现降水的 1h 和 2h 临近预报。
- 2) 通过 2024 年 7-8 月和 2025 年 7-8 月的长时间序列对比试验发现，OF-RainNet 对 $\geq 5\text{mm}\cdot\text{h}^{-1}$ 、 $\geq 10\text{mm}\cdot\text{h}^{-1}$ 、 $\geq 20\text{mm}\cdot\text{h}^{-1}$ 、 $\geq 50\text{mm}\cdot\text{h}^{-1}$ 降水的 1h、2h 时效预报 TS 评分全部高于 SWAN-QPF 和 PredRNNv2 模型，其中对 $\geq 10\text{mm}\cdot\text{h}^{-1}$ 及以上强度的降水 TS 评分相对提升超过 10%，说明 OF-RainNet 融合外推预报和深度学习模型后能获得正预报技巧，强降水预报性能提升明显。相较于未引入光流外推产品和 STA 模块的基础模型，OF-RainNet 的 TS 评分显著提升，强降水 Bias 略高于 1。说明 STA 模块和外推产品的引入，能够有效提升 OF-RainNet 模型的强降水预报能力。
- 3) 通过个例检验发现，OF-RainNet 的预报性能优于 PredRNNv2，对强降水持续阶段的预报能力优于局地触发阶段，1h 预报优于 2h 预报。

预报试验结果表明，仅依赖雷达观测的外推预报，难以捕捉强降水的局地精细化发展演变特征，尤其是对局地触发的强降水预报技巧较低。本文通过深度学习模型构建多源预报数据融合框架，实现了不同预报方法数据的有效融合，为未来的工作提供了新的思路和技术方向。后续研究可在模型输入层扩展不同方法的预报产品，如“风雷”预报产品、数值模式环境场、物理量场和回波预报场等。通过深度学习模型挖掘各类预报产品的核心优势，实现多预报方法的集成融合，进一步提升临近客观预报对降水生消演变的预报能力。

参考文献

- 曹勇, 包红军, 张恒德, 等, 2021. 基于快速滚动更新的无缝隙定量降水预报模型[J]. 河海大学学报(自然科学版), 49(4): 303-308. Cao Y, Bao H J, Zhang H D, et al, 2021. Seamless quantitative precipitation forecasting model based on rapid rolling update technique[J]. J Hohai Univ (Nat Sci), 49(4): 303-308 (in Chinese).
- 曹勇, 刘凑华, 宗志平, 等, 2016. 国家级格点化定量降水预报系统[J]. 气象, 42(12): 1476-1482. Cao Y, Liu C H, Zong Z P, et al, 2016. State-level gridded quantitative precipitation forecasting system[J]. Meteor Mon, 42(12): 1476-1482. (in Chinese)
- 韩丰, 唐文苑, 周楚炫, 等, 2023. 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, 81(2): 304-315. Han F, Tang W Y, Zhou C X, et al, 2023. Improving a precipitation nowcasting algorithm based on the SWAN system and related application assessment[J]. Acta Meteor Sin, 81(2): 304-315 (in Chinese).
- 皇甫江, 胡志群, 郑佳锋, 等, 2022. 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, 80(4): 565-577. Huang F J, Hu Z Q, Zheng J F, et al, 2022. A study on polarization radar quantitative precipitation estimation using deep learning[J]. *Acta Meteor Sin*, 80(4): 565-577 (in Chinese).
- 罗健文, 邹茂扬, 杨昊, 等, 2024. 面向降雨预报的雷达回波预测序列外推方法[J]. *计算机应用研究*, 41(4): 1138-1142. Luo J W, Zou M Y, Yang H, et al, 2024. Research on extrapolation of radar echo prediction sequence for rainfall prediction[J]. *Appl Res Comput*, 41(4): 1138-1142 (in Chinese).
- 渠鸿宇, 董林, 马新野, 等, 2024. 基于 XGBoost 的西北太平洋台风快速增强预报模型[J]. *气象*, 50(12): 1531-1541. Qu H Y, Dong L, Ma X Y, et al, 2024. Forecast model of northwest pacific typhoon rapid intensification based on XGBoost[J]. *Meteor Mon*, 50(12): 1531-1541 (in Chinese).
- 盛杰, 金荣花, 张小雯, 等, 2025. 临近气象预报大模型“风雷”V1 版本检验及个例评估[J]. *气象*, 51(4): 389-399. Sheng J, Jin R H, Zhang X W, et al, 2025. Verification and Case Evaluation of the “Fenglei” V1 meteorological nowcasting model[J]. *Meteor Mon*, 51(4): 389-399 (in Chinese).
- 徐成鹏, 曹勇, 张恒德, 等, 2022. U-Net 模型在京津冀临近降水预报中的应用和检验评估[J]. *气象科学*, 42(6): 781-792. Xu C P, Cao Y, Zhang H D, et al, 2022. Application and test evaluation of U-Net model in Beijing-Tianjin-Hebei precipitation nowcasting[J]. *J Meteor Sci*, 42(6): 781-792 (in Chinese).
- 姚文, 李松书, 王海江, 等, 2025. 基于 YOLOv5 与 DeepSort 对天气雷达数据鸟杂波的识别与追踪[J]. *气象*, 51(4): 417-430. Yao W, Li S S, Wang H J, et al, 2025. Identification and tracking of bird clutter in weather radar data based on YOLOv5 and DeepSort[J]. *Meteor Mon*, 51(4): 417-430 (in Chinese).
- 袁凯, 李武阶, 李明, 等, 2022. 四种机器深度学习算法对武汉地区雷达回波临近预报的检验和评估[J]. *气象*, 48(4): 428-441. Yuan K, Li W J, Li M, et al, 2022. Examination and evaluation of four machine deep learning algorithms for radar echo Nowcasting in Wuhan Region[J]. *Meteor Mon*, 48(4): 428-441 (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).
- 周康辉, 郑永光, 韩雷, 等, 2021. 机器学习在强对流监测预报中的应用进展[J]. *气象*, 47(3): 274-289. Zhou K H, Zheng Y G, Han L, et al, 2021. Advances in application of machine learning to severe convective weather monitoring and forecasting[J]. *Meteor Mon*, 47(3): 274-289 (in Chinese).
- 庄潇然, 郑玉, 王亚强, 等, 2023. 基于深度学习的融合降水临近预报方法及其在中国东部地区的应用研究[J]. *气象学报*, 81(2): 286-303. Zhuang X R, Zheng Y, Wang Y Q, et al, 2023. A deep learning-based precipitation nowcast model and its application over East China[J]. *Acta Meteor Sin*, 81(2): 286-303 (in Chinese).
- Dosovitskiy A, Beyer L, Kolesnikov A, et al, 2021. An image is worth 16x16 words: transformers for image recognition at scale[PP/OL].V2. (2021-06-03) [2025-12-10] .<https://doi.org/10.48550/arXiv.2010.11929>
- Gao Z H, Shi X J, Wang H, et al, 2021. Deep learning and the weather forecasting problem: precipitation nowcasting[M/OL]//Deep Learning for the Earth Sciences: A Comprehensive Approach to Remote Sensing, Climate Science and Geosciences.Wiley. (2021-08-20)

-
- [2025-12-10].<https://onlinelibrary.wiley.com/doi/10.1002/9781119646181.ch15>.
- Han D, Choo M, Im J, et al, 2023. Precipitation nowcasting using ground radar data and simpler yet better video prediction deep learning[J]. *GISci Remote Sensing*, 60(1): 2203363.
- Huang H B, Zhou X Q, Cao J, et al, 2024. Vision transformer with super token sampling[PP/OL].V2. (2024-01-25) [2025-10-16].<https://arxiv.org/pdf/2211.11167>.
- Le Guen V, Thome N, 2020. Disentangling physical dynamics from unknown factors for unsupervised video prediction[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE.
- Pulkkinen S, Chandrasekar V, Niemi T, 2021. Lagrangian integro-difference equation model for precipitation nowcasting[J]. *J Atmos Ocean Technol*, 38(12): 2125-2145.
- Shi X J, Chen Z R, Wang H, et al, 2015. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[C]//Proceedings of the 29th International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press.
- Shi X J, Gao Z H, Lausen L, et al, 2017. Deep learning for precipitation nowcasting: a benchmark and a new model[M/OL]//Proceedings of the Conference on Neural Information Processing Systems. Long Beach, CA, USA. (2017-10-05) [2025-09-17].<https://arxiv.org/pdf/1706.03458>.
- Trebing K, Stańczyk T, Mehrkanoon S, 2021. SmaAt-UNet: precipitation nowcasting using a small attention-UNet architecture[J]. *Pattern Recognit Lett*, 145: 178-186.
- Vaswani A, Shazeer N, Parmar N, et al, 2017. Attention is all you need[C]//Proceedings of the 31st Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc.
- Wang Y B, Long M S, Wang J M, et al, 2017. PredRNN: recurrent neural networks for predictive learning using spatiotemporal LSTMs[C]//Proceedings of the 31st Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc.
- Wang Y B, Gao Z F, Long M S, et al, 2018. PredRNN++: towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning[C/OL]//Proceedings of the International Conference on Machine Learning. [2025-09-17].<https://proceedings.mlr.press/v80/wang18b.html>.
- Wang Y B, Wu H X, Zhang J J, et al, 2023. PredRNN: a recurrent neural network for spatiotemporal predictive learning[J]. *IEEE Trans Pattern Anal Mach Intell*, 45(2): 2208-2225.
- Zhang Y C, Long M S, Chen K Y, et al, 2023. Skilful nowcasting of extreme precipitation with NowcastNet[J]. *Nature*, 619(7970): 526-532.

Experimental Study on Precipitation Nowcasting Model by Integrating Optical Flow Extrapolation and Deep Learning

Han Feng¹ Xue Feng¹ Lv Zhongliang¹ He Xiwen¹ Liu Tao¹

(National Meteorological Center, Beijing 100081)

Abstract: To improve the accuracy of precipitation nowcasting, an OF-RainNet model is designed based on self-attention mechanism. By inputting both SWAN-QPE(Quantitative Precipitation Estimation) and 0-2h SWAN-QPF(Quantitative Precipitation Forecast generated by optical flow method) products, the model achieves the integration of precipitation advection extrapolation information and deep learning model. The model introduces the SuperTokenAttention (STA) module to extract meaningful semantic units for precipitation forecasting and calculate multi-head attention, generating 1h and 2h precipitation forecasts at a 1km resolution every 6 minutes. A Beijing precipitation nowcasting experiment was constructed. Through long-term verification and case analysis in July and August of 2024 and 2025, the following conclusions were drawn: At thresholds of 5mm•h-1, 10mm•h-1, 20mm•h-1, and 50mm•h-1, the TS of 1h and 2h forecasts of OF-RainNet are higher than those of SWAN-QPF and PredRNNv2, with an improvement of over 10% in the >10mm•h-1 threshold range. Compared with the basic version without the introduction of optical flow extrapolation products and the STA module, the TS score of OF-RainNet has significantly improved, and the Bias of heavy precipitation is slightly higher than 1. Overall, OF-RainNet effectively improved the precipitation nowcasting skill by introducing the STA module and optical flow extrapolation products, which means the merge method is effective. In addition, case analysis shows that the forecasting skill of OF-RainNet outperforms PredRNNv2. The OF-RainNet performs better in forecasting for the continuous heavy precipitation than that for the locally triggered one, and the forecast with 1h lead time outperform those with 2h lead time. Overall, the OF-RainNet can provide objective support for nowcasting of heavy precipitation.

Key Words: precipitation nowcasting; self-attention; deep learning; optical flow