

基于拉格朗日特征融合的临近降水预报网络^①



蒋志凯¹, 葛玲玲²

¹(南京信息工程大学 计算机学院, 南京 210044)

²(国家气象信息中心, 北京 100081)

通信作者: 蒋志凯, E-mail: 202312490519@nuist.edu.cn

摘要: 随着极端气候频发, 提升降水预报能力已成为气象业务中的迫切需求. 现有的大多数基于数据驱动的方法将降水的运动与强度耦合建模, 尽管能有效捕捉大尺度降水系统, 却难以准确预测中小尺度强降水的剧烈演变, 限制了其在强降水预报上的评分. 本文基于拉格朗日变换实现运动与强度的解耦, 构建了一种双分支融合网络 LAFUNet, 一个分支直接分析原始雷达图像序列, 以捕捉大尺度降水的空间结构与运动特征; 另一个分支将降水场转换至拉格朗日坐标系, 专注于建模降水强度的演变, 从而更有效地表征与中小尺度强降水相关的非线性强度变化. 此外, 双分支交互模块用于自适应地融合两个分支的特征. 实验基于 CIKM 和 SEVIR 公开雷达数据集开展, 结果表明, 该模型在强降水预报上的性能突出. 尤其是在 SEVIR 数据集上, 针对强度阈值超过 219 的极端降水事件, 其未来 1 h 的 CSI 指标高达 0.1368, 显著超越了 VMRNN 等模型.

关键词: 深度学习; 临近降水预报; 拉格朗日变换; 交叉注意力机制

引用格式: 蒋志凯, 葛玲玲. 基于拉格朗日特征融合的临近降水预报网络. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10113.html>

Precipitation Nowcasting Network Based on Lagrangian Feature Fusion

JIANG Zhi-Kai¹, GE Ling-Ling²

¹(School of Computer Science, Nanjing University of Information Science & Technology, Nanjing 210044, China)

²(National Meteorological Information Center, Beijing 100081, China)

Abstract: With the increasing frequency of extreme climate events, enhancing precipitation forecasting capability has become an urgent need in meteorological operations. Most existing data-driven methods model precipitation motion and intensity in a coupled manner. Although effective at capturing large-scale precipitation systems, these methods struggle to accurately predict the rapid evolution of small- to medium-scale heavy precipitation, thereby limiting their forecast skill for intense rainfall events. In this study, a dual-branch fusion network named LAFUNet is proposed, which decouples motion and intensity via Lagrangian transformation. One branch directly analyzes original radar image sequences to capture the spatial structure and motion characteristics of large-scale precipitation systems. The other branch transforms the precipitation field into the Lagrangian coordinates, focusing on modeling intensity evolution to better represent the nonlinear intensity changes associated with small- to medium-scale heavy precipitation. Additionally, a dual-branch interaction module is designed to adaptively fuse features from both branches. Experiments are conducted on the public CIKM and SEVIR radar datasets. The results demonstrate that the proposed model achieves outstanding performance in heavy precipitation nowcasting. Particularly on the SEVIR dataset, for extreme precipitation events with an intensity threshold exceeding 219, the model attains a CSI score of 0.1368 for 1 hour forecasts, significantly outperforming comparative models such as VMRNN.

Key words: deep learning; precipitation nowcasting; Lagrangian transformation; cross attention mechanism

^① 基金项目: 国家自然科学基金 (U21B2049, 42205153); 2024 年度广东省基础与应用基础研究基金气象联合基金 (2024A1515510019)

收稿时间: 2025-09-22; 修改时间: 2025-10-14; 采用时间: 2025-10-29; csa 在线出版时间: 2026-01-15

临近降水预报涉及预测目标区域短期 0–2 h 内降水的时空分布^[1–3]。生成准确和及时的临近预报对于减轻自然灾害、保护农业生产力和公共安全等方面至关重要^[4]。然而,降水系统固有的快速演变和非线性动力学特性对实现高精度预报提出了重大挑战,这集中体现于中小尺度对流系统的生消、发展及演变过程,尤其是其中强降水系统剧烈且非线性特征的精准刻画。此外,降水系统本身具有快速生消、物理过程复杂及强非线性等特点,加之其演变受热力、动力与水汽条件多因子耦合影响,进一步增大了高精度预报的难度^[5–7]。

为了应对挑战,近些年越来越多有效的深度学习技术被开发出来,极大地推动了临近降水预报领域的发展,其中大多数现有方法将该问题作为雷达序列预测任务。ConvLSTM^[8]是一个开创性的框架,将卷积操作与长短期记忆网络结合起来,以捕获时空相关性。随后, TrajGRU^[9]结合了来自光流场的物理约束来动态模拟像素级回波运动。PredRNN^[10]引入了一种基于 ConvLSTM 的新型记忆传递机制,通过层与层之间的双向信息流路径,促进了空间形态和时间动态的协同建模。SwinLSTM^[11]将 Swin Transformer 块与 LSTM 结合,用自注意力机制替代了 ConvLSTM 中传统的卷积结构,证明了学习全局空间依赖关系的重要性。VMRNN^[12]将 Mamba 的高效长程建模能力与 LSTM 的时序控制相结合,为预报任务提供了新的高效基线。

同时, CNN 架构在提取降水系统的结构特征方面具有显著优势,因为它具有强大的捕捉空间结构的能力。例如, SmaAt-UNet^[13]将注意力机制与深度可分离卷积集成在一起,以提高参数效率,同时保留 U-Net 架构的特征提取能力。SAR-UNet^[14]基于 SmaAt-UNet 框架,创新性地编码器和解码器路径上添加了 CBAM 模块与深度可分离卷积并行的残差连接。RainHCNet^[15]提出混合通道-空间注意力机制,有效捕获降水图像中的高频局部信息和低频全局关系。SimVP^[16]和 SimVP-v2^[17]证明了一个简化的 CNN 架构可以获得很好的预测性能。

进一步地,为解决标准卷积有限的感受野, MIMO^[18]结合了 Transformer 自注意力,使模型能够提取全局降水特征。Rainformer^[19]通过门控机制生成遗忘矩阵,平衡融合局部和全局特征。SLTSL^[20]通过自注意力机制增强了对流系统中整体空间结构的捕获,同时保留了

鲁棒的时间动态建模的优势。

上述的大多数数据驱动方法虽然在预测大尺度降水系统的空间分布和运动趋势方面表现出了熟练程度,但在预测高强度降水事件方面表现出明显的局限性,具体表现为现有模型在强降水事件的预测中普遍存在强度低估问题,即预测值显著低于实际观测值。这一局限性可归因于强降水样本的相对稀少以及模型对非线性物理过程表征能力的不足。随着预报时效的延长,误差不断累积,导致预测的强降水区域强度偏弱,难以准确反映实际情况^[21]。

为了解决这一不足, L-CNN^[22]提出了使用拉格朗日变换将降水场序列转换至拉格朗日坐标系中,将平流运动与降水的增长和衰减过程解耦,使深度学习模型能够专门关注降水强度的动态演变。这种方法在预测中小尺度强降水系统的强度方面展现出显著优势。然而,在这个坐标系中很难捕捉到降水的完整空间分布和运动趋势。

基于上述分析,本文提出了一种双分支融合网络 LAFUNet, 该网络利用了原始雷达序列分支和拉格朗日分支各自的优势。在拉格朗日坐标系中,网络侧重于通过解耦平流运动来模拟降水的增长和衰减。由于强降水云团的强度变化剧烈,这种方法特别适合用于表征与其相关的非线性强度演变。同时,在原始雷达序列分支中,模型则会着重于捕获降水场的空间分布和宏观运动。该网络的核心是双分支交互模块,它通过自适应融合两个分支的特征来增强对降水系统的预报。实验结果表明,本文提出的融合网络性能优于仅用原始雷达序列分支进行预测的模型,从而提高了临近降水预报的性能。

总体而言,本文提出的方法为临近降水预报方向提供了一种新的研究思路,具体贡献总结如下。

(1) 本文基于拉格朗日变换实现运动与强度解耦,设计了双分支融合网络架构,一个分支直接在原始雷达序列数据上进行学习,专注于捕捉降水系统的大尺度空间形态与整体移动趋势;另一个分支引入拉格朗日变换,专注于模拟降水的强度演变,以表征与强降水强相关的非线性强度变化。

(2) 使用双分支交互模块作为网络核心模块,通过粗粒度关联和细粒度融合两阶段交互机制,使得网络能够自适应地分配注意力权重,更好地融合两个分支的特征。

1 双分支融合网络

1.1 网络架构

为解决现有模型在强降水预报中存在的强度低估问题, 本文提出了一种名为 LAFUNet 的双分支融合网络. 该网络的核心思想是通过拉格朗日变换解耦降水场的运动与强度演变, 并利用双分支架构分别捕捉雷达序列分支和拉格朗日序列分支各自的优势. 如图 1 所示, 网络以历史雷达序列 $X_R = \{\Psi_{t-k}, \Psi_{t-k+1}, \dots, \Psi_t\}$ 作为输入. 首先, 计算该输入序列的光流场 $O^{[23]}$, 将其应用于半拉格朗日外推算法^[24], 得到拉格朗日坐标系下的完整降水场, 并从中提取拉格朗日输入场序列 $X_L = \{\tilde{\Psi}_{t-k}, \tilde{\Psi}_{t-k+1}, \dots, \tilde{\Psi}_t\}$. 随后, 计算原始雷达序列和拉格朗日序列的帧间差异场序列, 分别得到 $\Delta X_R = \{\Delta\Psi_{t-k+1}, \dots, \Delta\Psi_t\}$ 和 $\Delta X_L = \{\Delta\tilde{\Psi}_{t-k+1}, \dots, \Delta\tilde{\Psi}_t\}$. 这些差异场序列随后被输入至由 3 个模块构成的网络中, 包括特征提取阶段 (FE)、Inception 模块^[16]以及双分支交互模块 (IM). 在初始特征提取阶段, 首先通过两个 3×3 卷积层对输入 ΔX_R 和 ΔX_L 进行处理, 以提取原始雷达序列分支的浅层特征 F_R 和拉格朗日分支的浅层特征 F_L . 随后, 将 F_R 和 F_L 输入 Inception 模块中以提取多尺度特征. Inception 模块由一个 1×1 卷积和多个采用不同尺寸卷

积核 ($3 \times 3, 5 \times 5, 7 \times 7$ 和 11×11) 的组卷积分支构成, 以进行多尺度信息提取. 通过多个 Inception 模块的叠加使模型能够捕捉降水序列的时间演化特征. 在每个 Inception 模块后, 通过双分支交互模块整合拉格朗日分支的强度演化特征与原始雷达序列分支的空间分布和运动特性, 实现互补信息的自适应融合. 此外, 利用跳跃连接操作充分结合浅层特征, 以提高降水场的重建质量. 最后的特征重构阶段和初始特征提取阶段一样, 由两个 3×3 卷积层构成, 从而预测出两个分支下一个时刻的差异输出 $\Delta\widehat{\Psi}_{t+1}$ 和 $\Delta\tilde{\widehat{\Psi}}_{t+1}$. 最终, 通过 $\widehat{\Psi}_{t+1} = \Psi_t + \Delta\widehat{\Psi}_{t+1}$ 和 $\tilde{\widehat{\Psi}}_{t+1} = \tilde{\Psi}_t + \Delta\tilde{\widehat{\Psi}}_{t+1}$ 构成下一个时间步的预测. 该网络在迭代预测过程中采用滑动窗口的方式来更新输入差异场序列, 即每次添加最新预测的差异场, 并移除最早的差异场, 从而保持输入序列的时序连续性. 这个迭代过程最终会产生两个分支的未来预测的完整序列场 \hat{Y}_R 和 \hat{Y}_L .

本文利用原始雷达序列分支和拉格朗日分支的损失来训练模型, 损失函数描述如公式 (1) 所示:

$$Loss = MSE(Y_R, \hat{Y}_R) + MSE(Y_L, \hat{Y}_L) \quad (1)$$

其中, Y_R 和 Y_L 分别代表原始雷达序列分支和拉格朗日分支的真实值, MSE 是均方差损失函数.

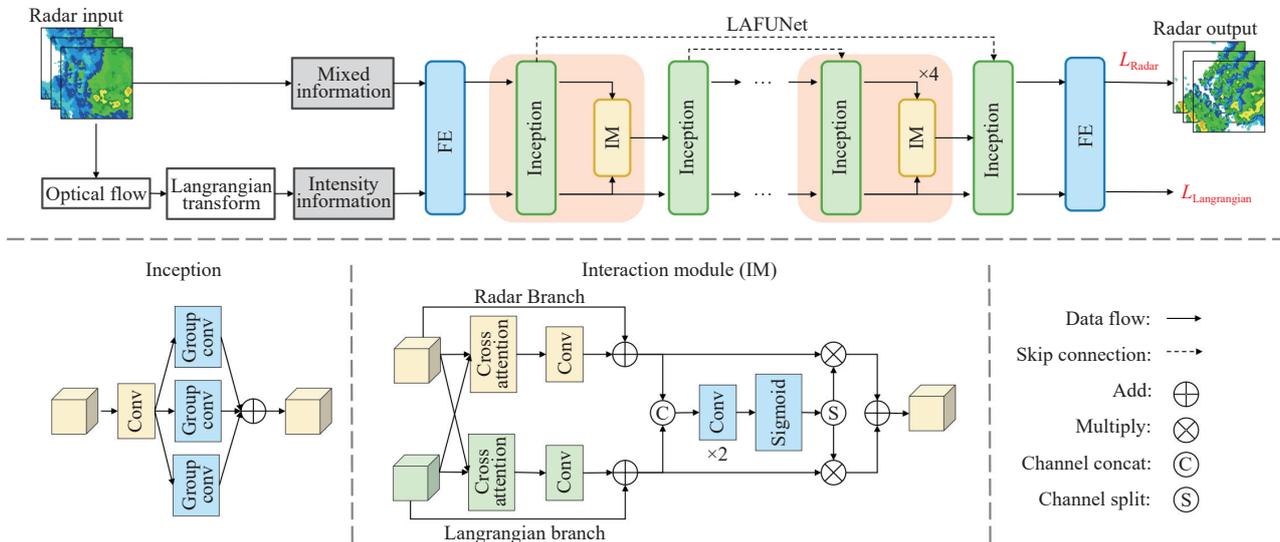


图 1 双分支融合网络架构图

1.2 拉格朗日变换

降水场的演变一般可以用以下平流方程来模拟, 如式 (2) 所示:

$$\frac{\partial \Psi}{\partial t} + v \cdot \nabla \Psi = S \quad (2)$$

其中, Ψ 为降水场, t 为时间, $v \cdot \nabla \Psi$ 表示降水的水平运动, S 表示降水的强度演变.

现有的大多数深度学习模型都直接基于原始的雷达图像序列来模拟这一过程, 并且在预测大尺度降水系统的演变方面取得了令人满意的结果. 然而, 其主要

局限性在于平流与降水强度演变的复杂耦合. 这种复杂性极大地阻碍了模型准确捕捉中小尺度强降水系统的能力.

因此, 本文将降水场映射到拉格朗日坐标系中, 式(2)可改写为式(3):

$$\frac{\partial \tilde{\Psi}}{\partial t} = S \quad (3)$$

其中, $\tilde{\Psi}$ 表示拉格朗日坐标系中的降水场. 此坐标系中忽略了平流项, 降水场的演变主要受其强度变化的影响. 这种方法有助于对强降水区域进行更集中的分析.

具体来说, 为了将降水场转换为拉格朗日坐标系下 $\tilde{\Psi}$. 本文首先利用密集 Lucas-Kanade 算法^[24]从原始雷达输入场序列中得到光流场 O ^[23]. 该场中的每个像素定义其对应的时空轨迹. 随后, 以最后一个历史观测时间 T_{in} 为参考, 采用半拉格朗日外推算法 E^T ^[24]沿所有时间对降水场进行外推. 当目标时间满足 $T - T_{in} > 0$ 时, 沿时间轴进行前向外推, 模拟降水场的未来状态. 当 $T - T_{in} < 0$ 时, 实现了降水场的反向外推. 这个外推过程如式(4)所示:

$$\tilde{\Psi} = E^T(\Psi, O), T = 1, 2, \dots, n \quad (4)$$

其中, n 表示总时间步数.

1.3 双分支交互模块

双分支交互模块的设计是基于双分支架构的互补特性. 拉格朗日分支擅长于模拟降水增长和衰减的动态过程, 从而有助于增强对强降水局部区域的分析. 原始雷达序列分支则侧重于捕捉降水场的空间分布和运动过程. 该模块通过粗粒度关联-细粒度融合两阶段交互机制, 实现双分支特征的协同优化. 在粗粒度特征交互的初始阶段, 一方面, 通过对从 Inception 模块获得的原始雷达序列特征 F_R 进行卷积运算, 生成查询向量 Q_R . 同时, 拉格朗日键向量 K_L 和拉格朗日值向量 V_L 以同样的方式由拉格朗日特征 F_L 导出. 然后计算原始雷达序列查询和拉格朗日键值对之间的交叉注意. 在此过程中, 拉格朗日特征通过其键值表示提供关键信息, 使原始雷达序列能够更有效地学习中小尺度高强度降水区域的动态特征. 另一方面, 允许拉格朗日分支融合原始雷达序列中有关大尺度空间分布和运动模式的降水信息. 这种互动动态地建立了特征之间的加权关联, 实现了两个分支的初始整合, 如式(5)和式(6)所示:

$$\hat{F}_L = \text{Softmax}\left(\frac{Q_L K_R^T}{\sqrt{d}}\right) V_R + F_L \quad (5)$$

$$\hat{F}_R = \text{Softmax}\left(\frac{Q_R K_L^T}{\sqrt{d}}\right) V_L + F_R \quad (6)$$

其中, \hat{F}_L 和 \hat{F}_R 分别表示拉格朗日分支和原始雷达序列分支粗粒度融合的输出.

为进一步细化两个分支特征的融合, \hat{F}_L 和 \hat{F}_R 沿着通道维度串联起来. 这个组合张量由两个 3×3 卷积层和 Sigmoid 激活函数处理, 以模拟两个分支之间的深度依赖关系. 然后沿着通道维度分离输出以产生各自的注意力图 A_L 和 A_R . 这些映射被用来重新加权粗粒度特征 \hat{F}_L 和 \hat{F}_R , 产生最终的细粒度融合特征表示 F_{final} , 如式(7)和式(8)所示:

$$A_L, A_R = \text{Split}(\text{CS}(\text{Concat}(\hat{F}_L, \hat{F}_R))) \quad (7)$$

$$F_{final} = A_L \odot \hat{F}_L + A_R \odot \hat{F}_R \quad (8)$$

其中, Concat 表示 channel concat, Split 表示 channel split, CS 表示两个 3×3 卷积层和一个 Sigmoid 激活函数, \odot 是 Hadamard 积. 然后将得到的 F_{final} 作为输入提供给原始雷达序列分支的下一个 Inception 模块.

2 实验分析

2.1 数据集

本文在两个具有代表性的雷达公开数据集(包括 CIKM 和 SEVIR)上进行评估.

对于 CIKM 数据集^[25], 本文采用 DiffCast^[26]的数据预处理过程. 最初, 所有样本都填充到统一的 128×128 分辨率. 然后将结果数据集划分为 8000 个训练样本、2000 个验证样本和 4000 个测试样本. 每个样本是 15 个雷达回波帧序列, 时间分辨率为 6 min. 将雷达回波图像的像素值调整到 0-76 范围内, 并在阈值[20, 30, 35, 40]处进行二值化处理, 以计算各项指标.

对于 SEVIR 数据集^[27], 本研究侧重于垂直集成液体(VIL)雷达数据. 最初, 选择风暴事件相对应的序列. 然后将所选序列在空间上下采样到 128×128 像素的统一分辨率. 本文按时间顺序划分数据集, 使用 2017 年 1 月 1 日-2018 年 12 月 31 日、2019 年 1 月 1 日-2019 年 6 月 1 日以及 2019 年 6 月 2 日-2019 年 12 月 31 日作为选取的时间段. 其中, 7490 个样本用于训练, 1221 个用于验证, 2262 个用于测试. 按照 SEVIR 概述的过程, 本文将像素值归一化到 0-255 的范围内. 为了便于评估, 在多个强度阈值{16, 74, 133, 160, 181, 219}下进行二值化处理.

2.2 评估标准

在评估指标方面, 本文采用阈值法将预测回波图与观察值进行转换. 如果该值大于给定阈值, 则将相应值设置为 1; 否则设置为 0. 本文计算了真阳性预测 TP (预测=1, 真值=1)、假阳性预测 FP (预测=1, 真值=0)、真阴性预测 TN (预测=0, 真值=0) 和假阴性预测 FN (预测=0, 真值=1) 的数量.

此外, 本文使用 3 个广泛认可的指标进行评估, 包括临界成功指数 (CSI)、海德克技能分数 (HSS) 和命中率 (POD). CSI 表示正确预测降水区域占实际或预测有降水的区域总数的比例; HSS 表示去除随机事件的影响后的预报准确率; POD 则表示预测的真正有降水区域占实际降水区域的比重. CSI 和 POD 的取值范围均为 $[0, 1]$, HSS 的取值范围为 $[-1, 1]$, 值越接近 1, 代表预测性能越佳. 如式 (9)–式 (11) 所示:

$$CSI = \frac{TP}{TP + FN + FP} \quad (9)$$

$$HSS = \frac{2(TP \times TN - FN \times FP)}{(TP + FN)(FN + TN) + (TP + FP)(FP + TN)} \quad (10)$$

$$POD = \frac{TP}{TP + FN} \quad (11)$$

2.3 实验参数设置

所有实验都在 PyTorch 中进行, 并在单个 NVIDIA RTX 3090 GPU 上进行训练. 本文对所有模型采用统一的训练配置. 本文使用学习率为 $1E-4$ 的 Adam 优化器, 批次大小设置为 4. 同时, 为了防止模型过拟合, 本文采用了训练早停机制.

2.4 实验结果

为验证所提出模型的性能, 本文与 7 种最先进的方法进行了定量比较, 包括 VMRNN^[12]、SmaAt-UNet^[13]、SAR-UNet^[14]、RainHCNet^[15]、MIMO^[18]、NowcastNet^[28]和 EarthFarseeer^[29]. 同时, 为了进行严格和公平的评估, 所有基线模型都在统一的实验框架内重新实施和评估.

CIKM 和 SEVIR 数据集的指标比较结果见表 1 和表 2. 数据表明, 本文的模型 LAFUNet 在关键评价指标 CSI 、 HSS 和 POD 上优于其他先进方法. 这种性能优势在高强度降水事件中尤为显著. 本文将这种优越的能力归因于其有效地融合了两个分支的特征.

表 1 不同模型在 CIKM 数据集上的 CSI 、 HSS 、 POD 指标结果

模型	$CSI \uparrow$				$HSS \uparrow$				$POD \uparrow$			
	20	30	35	40	20	30	35	40	20	30	35	40
SmaAt-UNet	0.5740	0.2289	0.1570	0.0803	0.6487	0.3355	0.2391	0.1273	0.7198	0.2787	0.1891	0.1025
MIMO	0.5594	0.1949	0.1426	0.0717	0.6324	0.2935	0.2266	0.1214	0.7266	0.2871	0.1986	0.1098
NowcastNet	0.5691	0.2126	0.1539	0.0854	0.6455	0.3159	0.2383	0.1388	0.7044	0.2641	0.1891	0.1136
EarthFarseeer	0.5619	0.2282	0.1658	0.0931	0.6388	0.3361	0.2537	0.1511	0.6906	0.2808	0.2013	0.1207
VMRNN	0.5762	0.2454	0.1736	0.0800	0.6534	0.3595	0.2652	0.1329	0.7014	0.3026	0.2155	0.1008
SAR-UNet	0.5666	0.2259	0.1580	0.0891	0.6426	0.3305	0.2376	0.1407	0.7006	0.2758	0.1937	0.1251
RainHCNet	0.5668	0.2302	0.1499	0.0648	0.6419	0.3368	0.2297	0.1084	0.7107	0.2837	0.1766	0.0765
LAFUNet (Ours)	0.5666	0.2627	0.1850	0.0952	0.6437	0.3804	0.2818	0.1548	0.6907	0.3448	0.2378	0.1311

注: \uparrow 表示指标越接近1, 性能越好

表 2 不同模型在 SEVIR 数据集上的 CSI 、 HSS 、 POD 指标结果

模型	$CSI \uparrow$				$HSS \uparrow$				$POD \uparrow$			
	74	133	181	219	74	133	181	219	74	133	181	219
SmaAt-UNet	0.6904	0.4140	0.2286	0.0920	0.7892	0.5589	0.3434	0.1467	0.7873	0.4773	0.2538	0.1009
MIMO	0.6723	0.3929	0.1891	0.0489	0.7753	0.5412	0.2970	0.0866	0.7840	0.4750	0.2139	0.0520
NowcastNet	0.6855	0.4122	0.2157	0.0805	0.7859	0.5606	0.3324	0.1362	0.7799	0.4779	0.2354	0.0858
EarthFarseeer	0.6807	0.3937	0.2198	0.0834	0.7823	0.5403	0.3404	0.1417	0.7671	0.4460	0.2392	0.0886
VMRNN	0.6940	0.4260	0.2390	0.0782	0.7926	0.5723	0.3574	0.1296	0.7861	0.4960	0.2703	0.0840
SAR-UNet	0.6879	0.4278	0.2359	0.1061	0.7871	0.5737	0.3539	0.1726	0.7874	0.5113	0.2689	0.1209
RainHCNet	0.6779	0.3798	0.1594	0.0425	0.7800	0.5289	0.2598	0.0772	0.7713	0.4295	0.1670	0.0432
LAFUNet (Ours)	0.6861	0.4344	0.2647	0.1368	0.7857	0.5811	0.3946	0.2214	0.7821	0.5259	0.3119	0.1661

注: \uparrow 表示指标越接近1, 性能越好

为了更直观地展示本文网络的提升效果, 本文绘制了 CSI 、 HSS 和 POD 指标的折线图, 展示了高阈值下各模型随预测时间增加的表现. 如图 2 和图 3 所示,

本文所提出的模型 LAFUNet 在高阈值下明显领先于先前的模型, 这意味着其具有更高的强降水准确性, 进一步凸显了其卓越性能.

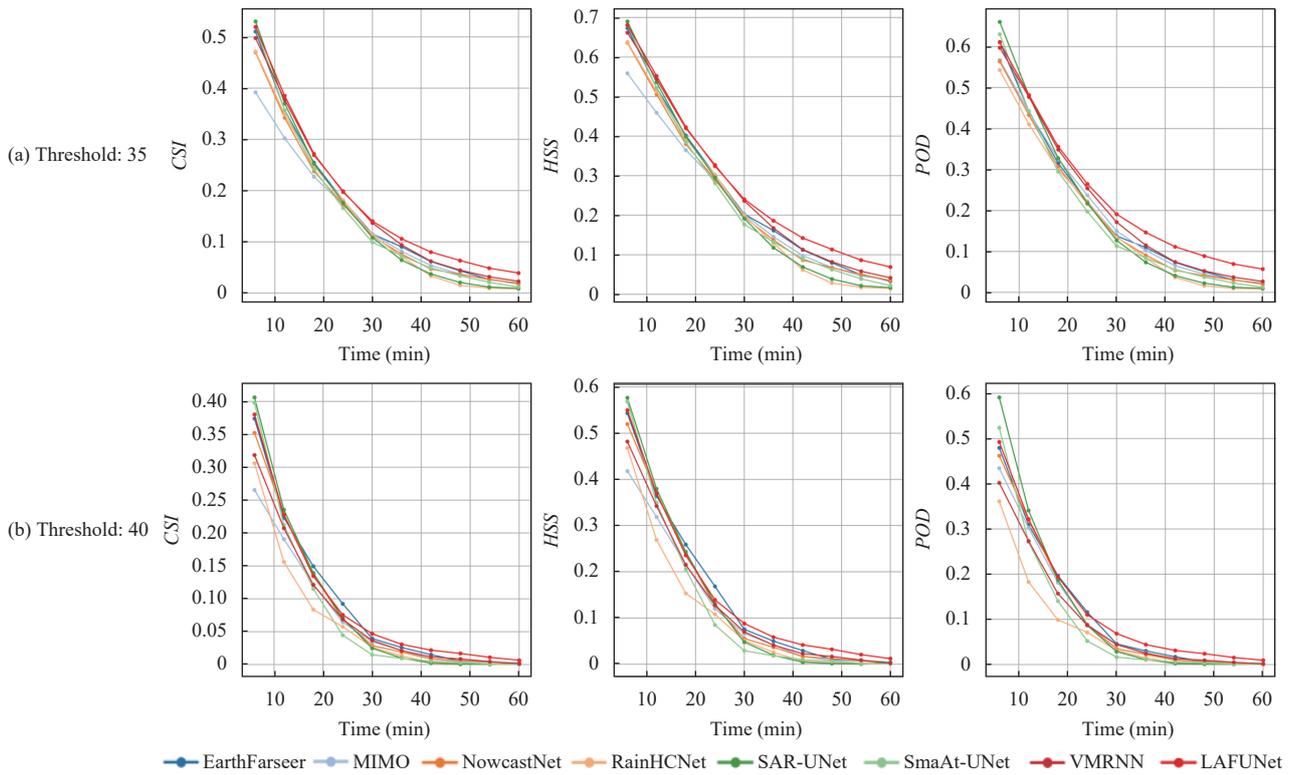


图2 不同模型在CIKM数据集35和40阈值下的CSI、HSS和POD指标折线图

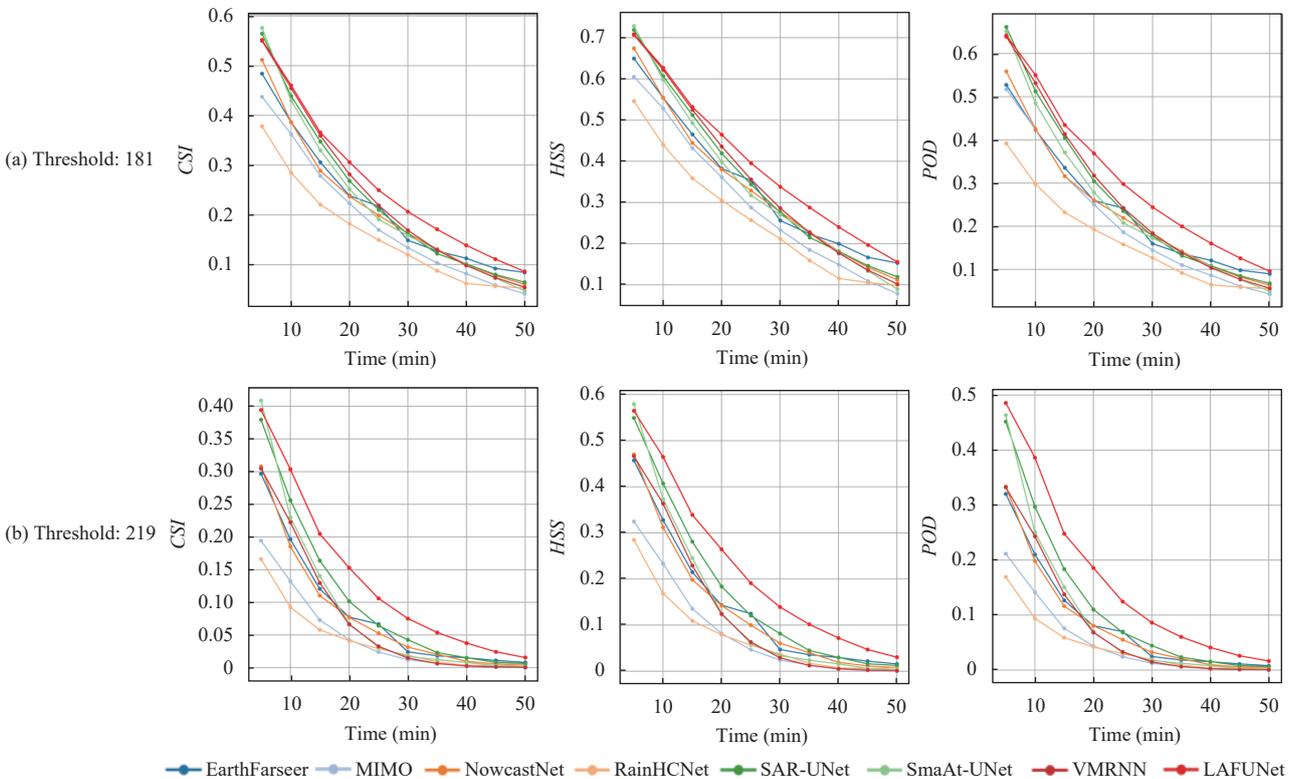


图3 不同模型在SEVIR数据集181和219阈值下的CSI、HSS和POD指标折线图

为了进一步展示所提出模型的实际预测效果, 本文在 CIKM 和 SEVIR 数据集上分别选择了一个雷达序列, 并绘制了所提出模型及其他主流模型的预测效果图.

本文首先在 CIKM 数据集上进行模型能力的验证. 如图 4 所示, 在早期预测阶段, 所有模型均能较为准确地预测出核心强降水区域. 然而, 随着预测时间延长, 各模型的性能差异逐渐显现, MIMO、EarthFarseeer 和 SAR-UNet 在中后期预测后出现显著性能衰减, 表现为强降水区域的快速消失; SmaAt-Unet、VMRNN、RainHCNet 和 NowcastNet 虽在中后期保持一定预测能力, 但对强降水区域的预测准确性也随时间推移而逐步下降. 相比之下, 只有 LAFUNet 能够在全时段预

测中维持对核心强降水区域的定位, 预测强度与实际观测值更加吻合, 显著优于其他模型.

本文进一步在 SEVIR 数据集上进行验证. 如图 5 所示, 在早期预测阶段, 所有模型均展现出稳定的降水强度预测能力, 基本能够准确捕捉强降水区域的分布与强度. 随着预测时间延长至中后期, 模型的预测能力开始出现明显分化, MIMO 在后期性能衰减明显, 预测强度显著低于实际观测值; EarthFarseeer、VMRNN、SAR-UNet、RainHCNet 和 NowcastNet 则表现出不同程度的强度低估现象. 值得注意的是, LAFUNet 在整个预测周期内均能保持对强降水区域的完整预测, 不仅准确识别了核心降水区域, 更完整保留了降水强度信息, 实现了对高强度降水事件的稳定预测.

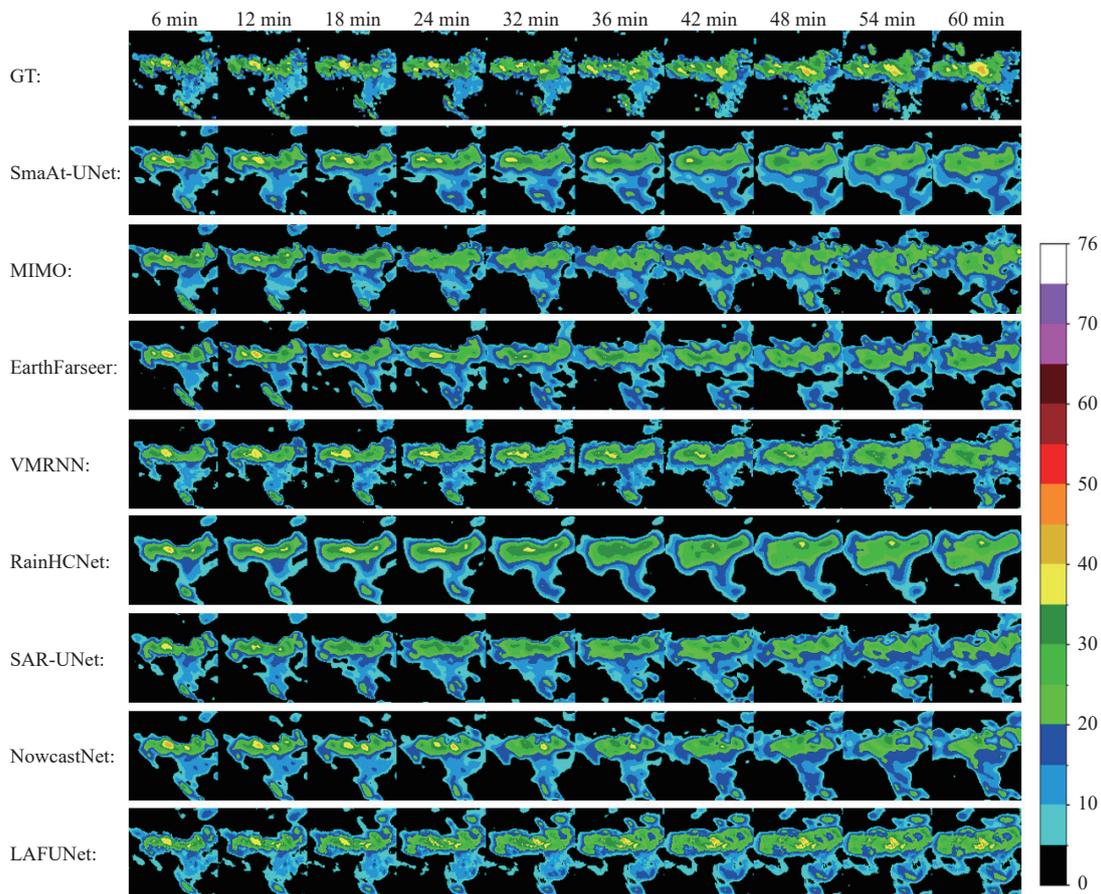


图 4 CIKM 数据集可视化

2.5 消融实验

本文在 CIKM 和 SEVIR 数据集上构建了多个模型变体, 以系统评估所提出的双分支结构及交互模块的贡献. 具体包括: Baseline (仅使用原始雷达序列的单分支

模型)、w/o Interaction (包含并行原始雷达分支和拉格朗日分支, 但未使用交互模块) 及完整的 LAFUNet (在双分支基础上引入交互模块实现跨分支融合). 消融实验结果如表 3 和表 4 所示, 加粗表示最优结果.

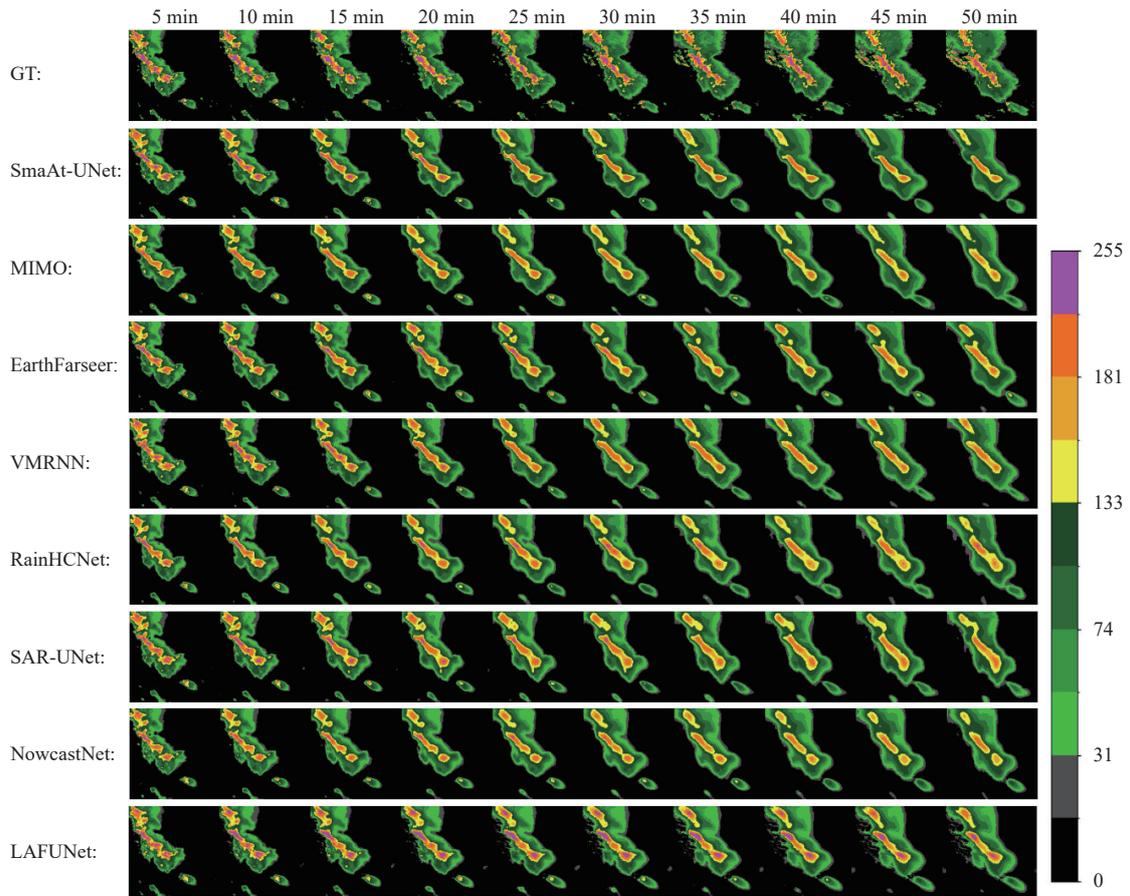


图5 SEVIR数据集可视化

表3 CIKM数据集上的消融实验结果

模型	CSI↑				HSS↑				POD↑			
	20	30	35	40	20	30	35	40	20	30	35	40
Baseline	0.5728	0.2302	0.1658	0.0876	0.6470	0.3363	0.2546	0.1428	0.7210	0.2954	0.1891	0.1025
w/o Interaction	0.5683	0.2597	0.1789	0.0931	0.6472	0.3778	0.2723	0.1511	0.6816	0.3306	0.2199	0.1191
LAFUNet (Ours)	0.5666	0.2627	0.1850	0.0952	0.6437	0.3804	0.2818	0.1548	0.6907	0.3448	0.2378	0.1311

注: ↑表示指标越接近1, 性能越好

表4 SEVIR数据集上的消融实验结果

模型	CSI↑				HSS↑				POD↑			
	74	133	181	219	74	133	181	219	74	133	181	219
Baseline	0.6971	0.4200	0.2006	0.0732	0.7946	0.5665	0.3029	0.1181	0.7951	0.4803	0.2158	0.0783
w/o Interaction	0.6850	0.4247	0.2455	0.1218	0.7852	0.5717	0.3699	0.1987	0.7752	0.5072	0.2809	0.1218
LAFUNet (Ours)	0.6861	0.4344	0.2647	0.1368	0.7857	0.5811	0.3946	0.2214	0.7821	0.5259	0.3119	0.1368

注: ↑表示指标越接近1, 性能越好

实验结果表明, 引入拉格朗日分支特征在所有评估指标上均带来一致性能提升, 证明了拉格朗日表示的有效性. 进一步地, 基于交互模块的自适应特征融合机制带来了额外的性能增强, 凸显了跨分支交互融合的重要性.

3 结论与展望

本研究引入了双分支融合网络, 旨在通过协同整

合原始雷达序列分支和拉格朗日分支的特征来解决临近降水预报的基本挑战. 网络的核心是双分支交互模块, 通过双分支之间的动态交互促进自适应特征融合. 在 CIKM 和 SEVIR 雷达数据集上的实验结果表明, 虽然纯数据驱动方法可以捕获强降水的初始阶段, 但其预测精度在较长的预测范围内显著降低. 相比之下, 本文提出的网络 LAFUNet 在预测高强度降水区域方面

表现出优异的性能,这一优势直接归因于其对拉格朗日特征的有效整合。

参考文献

- 1 Ravuri S, Lenc K, Willson M, *et al.* Skilful precipitation nowcasting using deep generative models of radar. *Nature*, 2021,597(7878):672–677.[doi:10.1038/s41586-021-03854-z]
- 2 Ma ZF, Zhang H, Liu J. Focal frame loss: A simple but effective loss for precipitation nowcasting. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 6781–6788. [doi: 10.1109/JSTARS.2022.3194522]
- 3 Ma ZF, Zhang H, Liu J. PrecipLSTM: A meteorological spatiotemporal LSTM for precipitation nowcasting. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4109108.
- 4 Yang ZY, Wu H, Liu Q, *et al.* A self-attention integrated spatiotemporal LSTM approach to edge-radar echo extrapolation in the Internet of Radars. *ISA Transactions*, 2023, 132: 155–166. [doi: 10.1016/j.isatra.2022.06.046]
- 5 周云龙, 季繁繁, 潘泽锋. 基于 Halo 注意力机制的双阶段临近降水预报网络. *计算机系统应用*, 2024, 33(5): 67–75. [doi: 10.15888/j.cnki.csa.009502]
- 6 Wang YT, Yao L, Jiang H, *et al.* Precipitation nowcasting based on radar echo images via multiscale spatiotemporal LSTM. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5105614. [doi: 10.1109/TGRS.2025.3584824]
- 7 马志峰, 张浩, 刘劫. 基于深度学习的短临降水预报综述. *计算机工程与科学*, 2023, 45(10): 1731–1753. [doi: 10.3969/j.issn.1007-130X.2023.10.003]
- 8 Shi XJ, Chen ZR, Wang H, *et al.* Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Proceedings of the 29th International Conference on Neural Information Processing Systems*. Montreal: ACM, 2015. 802–810.
- 9 Shi XJ, Gao ZH, Lausen L, *et al.* Deep learning for precipitation nowcasting: A benchmark and a new model. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach: ACM, 2017. 5622–5632.
- 10 Wang YB, Long MS, Wang JM, *et al.* PredRNN: Recurrent neural networks for predictive learning using spatiotemporal LSTMs. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach: ACM, 2017. 879–888.
- 11 Tang S, Li C, Zhang P, *et al.* SwinLSTM: Improving spatiotemporal prediction accuracy using swin Transformer and LSTM. *Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision*. Paris: IEEE, 2023. 13424–13433.
- 12 Tang YJ, Dong PJ, Tang ZH, *et al.* VMRRN: Integrating vision mamba and LSTM for efficient and accurate spatiotemporal forecasting. *Proceedings of the 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle: IEEE, 2024. 5663–5673.
- 13 Trebing K, Stańczyk T, Mehrkanoon S. SmaAt-UNet: Precipitation nowcasting using a small attention-UNet architecture. *Pattern Recognition Letters*, 2021, 145: 178–186. [doi: 10.1016/j.patrec.2021.01.036]
- 14 Renault M, Mehrkanoon S. SAR-UNet: Small attention residual UNet for explainable nowcasting tasks. *Proceedings of the 2023 International Joint Conference on Neural Networks (IJCNN)*. Gold Coast: IEEE, 2023. 1–8.
- 15 Wang L, Wang Z, Hu WJ, *et al.* RainHCNet: Hybrid high-low frequency and cross-scale network for precipitation nowcasting. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 8923–8937. [doi: 10.1109/JSTARS.2025.3549678]
- 16 Gao ZY, Tan C, Wu LR, *et al.* SimVP: Simpler yet better video prediction. *Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans: IEEE, 2022. 3160–3170.
- 17 Tan C, Gao ZY, Li SY, *et al.* SimVPv2: Towards simple yet powerful spatiotemporal predictive learning. *IEEE Transactions on Multimedia*, 2025, 27: 5170–5184. [doi: 10.1109/TMM.2025.3543051]
- 18 Ning SL, Lan MC, Li YR, *et al.* MIMO is all you need: A strong multi-in-multi-out baseline for video prediction. *Proceedings of the 37th AAAI Conference on Artificial Intelligence*. Washington: AAAI Press, 2023. 1975–1983.
- 19 Bai C, Sun F, Zhang JL, *et al.* Rainformer: Features extraction balanced network for radar-based precipitation nowcasting. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4023305.
- 20 Pan ZF, Hang RL, Liu QS, *et al.* A short-long term sequence learning network for precipitation nowcasting. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 4106814.
- 21 An S, Oh TJ, Sohn E, *et al.* Deep learning for precipitation nowcasting: A survey from the perspective of time series forecasting. *Expert Systems with Applications*, 2025, 268:

126301. [doi: [10.1016/j.eswa.2024.126301](https://doi.org/10.1016/j.eswa.2024.126301)]
- 22 Ritvanen J, Harnist B, Aldana M, *et al.* Advection-free convolutional neural network for convective rainfall nowcasting. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 1654–1667. [doi: [10.1109/JSTARS.2023.3238016](https://doi.org/10.1109/JSTARS.2023.3238016)]
- 23 曹春燕, 陈元昭, 刘东华, 等. 光流法及其在临近预报中的应用. *气象学报*, 2015, 73(3): 471–480. [doi: [10.11676/qxxb2015.034](https://doi.org/10.11676/qxxb2015.034)]
- 24 Pulkkinen S, Nerini D, Pérez Hortal AA, *et al.* Pysteps: An open-source Python library for probabilistic precipitation nowcasting (v1. 0). *Geoscientific Model Development*, 2019, 12(10): 4185–4219. [doi: [10.5194/gmd-12-4185-2019](https://doi.org/10.5194/gmd-12-4185-2019)]
- 25 CIKM AnalytiCup 2017 短时定量降水预测数据集. <https://tianchi.aliyun.com/dataset/1085>. (2018-07-03).
- 26 Yu DM, Li XT, Ye YM, *et al.* DiffCast: A unified framework via residual diffusion for precipitation nowcasting. *Proceedings of the 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle: IEEE, 2024. 27758–27767.
- 27 Veillette MS, Samsi S, Mattioli CJ. SEVIR: A storm event imagery dataset for deep learning applications in radar and satellite meteorology. *Proceedings of the 34th International Conference on Neural Information Processing Systems*. Vancouver: ACM, 2020. 1846.
- 28 Zhang YC, Long MS, Chen KY, *et al.* Skilful nowcasting of extreme precipitation with NowcastNet. *Nature*, 2023, 619(7970): 526–532. [doi: [10.1038/s41586-023-06184-4](https://doi.org/10.1038/s41586-023-06184-4)]
- 29 Wu H, Liang YX, Xiong W, *et al.* Earthfarseeer: Versatile spatio-temporal dynamical systems modeling in one model. *Proceedings of the 38th AAAI Conference on Artificial Intelligence*. Vancouver: AAAI Press, 2024. 15906–15914.

(校对责编: 李慧鑫)