

庄潇然, 代刊, 曾康, 等. 2025. 利用生成对抗网络提升江淮地区强降水临近预报性能[J]. 气象, X(X): Zhuang X R, Dai K, Zeng K, et al. 2025. Meteor Mon,

利用生成对抗网络提升江淮地区强降水临近预报性能¹

庄潇然^{1,2} 代刊³ 曾康⁴ 徐珺³ 王啸华^{1,2} 刘梅^{1,2}

1. 江苏省强对流灾害风险预警重点实验室, 南京 210041
2. 江苏省气象台, 南京 210041
3. 国家气象中心, 北京 100081
4. 中国气象局乌鲁木齐沙漠气象研究所, 乌鲁木齐 830002

摘要: 本文通过优化生成对抗网络 (Generative Adversarial Networks, GAN) 提出两种作用于江淮地区的深度学习强降水临近预报方法 PhySGAN (PhyDNet 结合 SGAN) 和 PhyMGAN (PhyDNet 结合 MGAN), 提供江淮地区未来 3 h 的降水量预报。通过预报技巧评分、“复杂场景”性能评估和典型应用实例分析了两种方法在 2024 年江苏地区汛期短时强降水 (降水量 $\geq 20 \text{ mm h}^{-1}$) 预报表现, 得到以下结论: PhySGAN 和 PhyMGAN 在不同检验时段的 3 h 内短时强降水 TS 评分较基础试验 PhyDNet 和通用生成对抗网络试验 PhyGAN 均有明显提升, 通过修正预报频率, 使得 TS 增益幅度随预报时效增加, 进而提升了较长时效的短时强降水 TS 表现; 从各方法在“复杂场景”所展示出的预报性能来看, 深度学习较传统外推方法能体现强降水生消演变, PhySGAN 和 PhyMGAN 较 PhyDNet 和 PhyGAN 表现出更好的预报性能, 前者对强降水形态、强度等局部细节刻画能力更好, 后者对强降水雨带的整体轮廓和位置表征更好; 结合汛期典型强降水实例应用发现, PhySGAN 和 PhyMGAN 在系统性强降水和局地强降水案例中均提前预报出降水增强过程, 对临灾预警起到有效指导。此外, PhyMGAN 对 50 mm h^{-1} 以上极端降水强度有一定指示作用, PhySGAN 则能够更好体现雨带形态和位置的转变。

关键词: 生成对抗网络, 江淮地区, 强降水临近预报, 检验评估, 典型案例

中图法分类号 P435 文献标志码: A

Using Generative Adversarial Networks to Improve Heavy Precipitation

¹ 中国气象局能力提升联合研究专项 (22NLTSZ001, 24NLTSQ015)、中国气象局揭榜挂帅项目 (CMAJBGS202512)、江苏省社会发展重大科技示范项目 (BE2023766) 和中国气象局重点创新团队 (CMA2022ZD04) 共同资助

2025 年 2 月 18 日收稿, 2025 年 x 月 xx 日收修定稿。

第一作者: 庄潇然, 主要从事集合预报与可预报性、强对流天气机理与预报技术等研究。E-mail: zxrz3212009@163.com

通讯作者: 代刊, 主要从事智能预报技术研究。E-mail: daikan@cma.gov.cn

Nowcasting in the Jianghuai Area

ZHUANG Xiaoran^{1,2} DAI Kan³ ZENG Kang⁴ XU Jun³ WANG Xiaohua^{1,2} LIU Mei^{1,2}

1 Jiangsu Key Laboratory of Severe Storm Disaster Risk, Nanjing 210041

2 Jiangsu Meteorological Observatory, Nanjing 210041

3 National Meteorological Center, Beijing 100081

4 Urumqi Institute of Desert Meteorology, CMA, Urumqi 830002

Abstract This paper proposes two deep learning-based short-term heavy precipitation nowcasting methods for the Jianghuai region by optimizing Generative Adversarial Networks (GAN), namely PhySGAN (combining PhyDNet and SGAN) and PhyMGAN (combining PhyDNet and MGAN), so as to provide precipitation forecasts in the next 3 hours for the Jianghuai region. Based on the forecast skill score, the performance assessment in "complex scenarios" and the analysis of typical application examples, this paper analyzes the forecast performance of the two methods in the short-time severe precipitation ($\geq 20 \text{ mm h}^{-1}$) forecasts in Jiangsu during the flood season of 2024. The results show that the TS of short-term heavy precipitation within 3 hours in different verification periods of PhySGAN and PhyMGAN are significantly improved compared with those of the basic experiment PhyDNet and the general GAN experiment PhyGAN. The two new methods can correct the low frequency problem of short-term heavy precipitation forecasts by PhyDNet and PhyGAN, so that the TS increases with the increase of the forecast lead time, thereby effectively extending the nowcasting lead time of short-term heavy precipitation. Judged from the forecast performance shown by each method in "complex scenarios", deep learning can reflect the evolution of the generation and dissipation of heavy precipitation relative to the traditional extrapolation methods. PhySGAN and PhyMGAN show better forecast performance than PhyDNet and PhyGAN. The former has a better ability to depict local details such as the shape and intensity of heavy precipitation, while the latter has a better representation of the overall contour and position of the heavy precipitation rain band. Combined with the application of typical heavy precipitation cases during the flood season, both PhySGAN and PhyMGAN can forecast the precipitation enhancement process in advance in both systematic heavy precipitation and local heavy precipitation cases, effectively guiding the early warning of disasters. In addition, PhyMGAN has a certain indicative effect on extreme rainfall intensities above 50 mm h^{-1} , while PhySGAN can better reflect the changes in the shape and position of the rain band.

Key words: Generative Adversarial Networks, Jianghuai region, heavy precipitation nowcasting, evaluation, representative cases

引 言

全球气候变化背景下，我国江淮地区短时强降水事件（小时降水强度 $\geq 20 \text{ mm h}^{-1}$ ）趋于多发、重发，由此引发的城市内涝、山洪等次生灾害给人民生命财产造成较大威胁，也给气象预报预警业务带来更多挑战（郑永光等，2015；汪卫国等，2024；苑希民等，2024）。

基于高时空分辨率天气雷达的临近预报是开展短时强降水精细化预警业务的主要手段，

区别于中短期预报所关注的强降水会发生及其粗略影响区域,精细化临灾预警更加关注局地降水强度演变,因此传统准线性外推预报方法在预报时效超出 1 h 后很难提供帮助(周康辉等, 2021; 王永灿等, 2023; 庄潇然等, 2023, 2025)。深度学习技术已成为临近预报中应对降水强度演变问题的主要手段,国内外学者利用雷达回波数据建模,并结合回波-降水转换关系开展了一系列降水临近预报方法研究, Shi et al (2015, 2017) 先后提出卷积长短期记忆神经网络(Convolutional LSTM Network, ConvLSTM)和轨迹卷积门控循环单元(Trajectory Gated Recurrent Unit, TrajGRU),并结合雷达回波数据建立未来 2 h 以内的回波/降水临近预报,结果表明深度学习方法的预报技巧优于光流法等传统外推方法; Wang et al (2017, 2018, 2023) 先后提出 PredRNN 及其改良版 PredRNN++和 PredRNN-v2,这一类模型较 ConvLSTM 进一步提升了降水时空信息学习的能力; 王永灿(2023)构建了基于生成对抗网络(Generative Adversarial Network, GAN)的 GA-RNN 雷达回波临近预报模型,并结合机器学习降水反演方法实现了 0~2 h 降水临近预报,结果优于固定 Z-R 降水反演关系; Ravuri et al (2021) 提出生成式降水临近预报模型(Deep Generative Model of Rainfall, DGMR),并利用雷达估测降水场作为输入预报未来 90 min 的降水概率,结果表明 DGMR 的降水预报技巧优于光流法以及通过卷积神经网络(U-Net)建立的临近预报模型。考虑雷达回波反演降水的二次误差,庄潇然等(2023, 2025)提出了基于深度学习的双通道融合降水临近预报方法,可以直接输出未来 3 h 的逐 6 min 降水量,规避了降水反演二次误差,有效提升了降水量预报技巧,为深度学习降水临近预报由研究走向应用提供了思路。

过去的研究从不同层面体现了深度学习在定量降水临近预报中的适用性(Zhou et al, 2020; 代刊等, 2025; 祁海霞等, 2025; 曾小团等, 2025; 钟琦等, 2025),但各种方法对于强降水、特别是 20 mm h^{-1} 以上短时强降水的预报有效性仍然未知。Zhang et al (2023) 提出了物理机制约束的生成式深度学习模型 NowcastNet,即通过生成对抗网络刻画雷达估测降水场中的对流尺度细节演变信息,并结合物理约束下的演变网络刻画输入降水场中的尺度变化特征,从而实现物理规律和深度学习的有机结合,试验结果表明 NowcastNet 较 DGMR 进一步提升了 1 h 时效后强降水的预报能力; 曾康等(2024)提出了具有一定天气学意义的频域生成对抗网络(Spectrum GAN, SGAN)技术,并与物理约束时空卷积神经网络 PhyDNet(Le Guen and Thome, 2020)结合发展了 0~3 h 雷达回波临近预报方法,有效缓解了回波预报中的“模糊”问题(即预报回波随时效呈现均态发展,并伴随强度衰减)(Das et al, 2024),提升了强对流天气中的强回波预报技巧评分。

目前,深度学习在强降水临近预报研究和应用中的局限性仍旧突出(Ha et al, 2023; Han et al, 2023; Tan et al, 2024), Zhang et al (2023) 采用的模型训练集和测试集均为雷达反演降水场,因此降水反演二次误差仍然存在; 曾康等(2024)仅开展了雷达回波预报研究,还缺乏对降水预报场景的相关尝试; 尽管庄潇然等(2025)尝试将 GAN 与 PhyDNet 结合并

应用于降水临近预报,发现相关举措能够有效提升强对流天气背景下的典型局地强降水过程预报效果,但整体预报表现与业务应用预期仍有差距;此外,GAN被认为能用于改善深度学习临近预报类任务中普遍存在的“模糊”问题,但对降水预报技巧提升并无明确帮助(Ravuri et al, 2021; 曾康等, 2024)。本文进一步对GAN在强降水临近预报中的适用性进行研究,提出改良的强降水临近预报方法并在江苏地区开展应用分析,以推动深度学习临近预报的技术改良和应用深化。

1 数据集介绍

本文涉及的深度学习模型均源自江苏省气象局强对流专用数据集训练,包括雷达组合反射率和降水量,网格数为 480×560 ,水平网格距 0.01° ,时间分辨率 6 min ,覆盖江苏及安徽中东部地区,数据集的具体制作方式见庄潇然等(2023)。针对 $0 \sim 3 \text{ h}$ 降水临近预报任务,筛选2018—2023年4—9月区域内有超过5%降水量站点有雨($>0.1 \text{ mm h}^{-1}$)的时次用于数据集制作,模型训练过程中,划分2018—2022年4—9月共计50 165组数据样本选为训练集,2023年4—6月3721组样本作为验证集,同年7—9月的3778组数据样本作为测试集。由于实际业务应用是本文的研究主要着眼点,因此对新方法在2024年汛期实际应用时段的检验评估结果将另文给出。

2 试验设置

从基本原理来说GAN由生成器和鉴别器组成,其中鉴别器用于在平面空间上对预报场鉴别,而生成器则试图让鉴别器认定其生成的预报结果为真值,在模型构建过程中可以将任意深度学习网络用作生成器,在其与鉴别器“博弈”的过程中使得预报结果趋于真实。针对降水临近预报任务中GAN训练不稳定、超参敏感性等不足的问题,Karnewar and Wang(2020)、曾康等(2024)先后提出多尺度梯度GAN(Multi-scal Gradient GAN, MGAN)和SGAN,本文进一步针对强降水临近预报任务,将二者作为鉴别器与PhyDNet结合,提出两种新的强降水临近预报方法。

2.1 基于SGAN的强降水临近预报方法

为了克服深度学习临近预报中的“模糊”问题,曾康等(2024)提出基于SGAN的雷达回波临近预报方法,通过离散余弦变换滤波器(庄潇然等, 2017)将生成器PhyDNet得到的二维回波场转换到谱空间,保留其中 200 km 以下波段部分进行对抗约束,从而使得鉴别过程更加聚焦于训练数据中的小尺度信息,该方法较传统GAN不仅改善了训练难于收敛的不足,还有效缓解了雷达回波预报的“模糊”问题。本文采用的基于SGAN的强降水临近预报方法技术路线与曾康等(2024)基本一致,将PhyDNet作为生成器得到未来 3 h 的雷达组合反射率和降水预报,并与对应真值共同输入鉴别器SGAN,通过计算综合损失函数,输出经过鉴别的 3 h 降水量预报。区别于曾康等(2024)研究方法的是,本研究为了提升短时强降水以上量级预报效果,在加权损失函数的降水强度权重设置中增加了 $\geq 30 \text{ mm h}^{-1}$ 阈值(表

1)。

2.2 基于 MGAN 的强降水临近预报方法

SGAN 通过滤除 200 km 以上的波段能够使生成对抗网络更聚焦于小尺度天气系统信息，而对于系统性强降水，大尺度背景对天气系统的整体结构和演变同样重要。对此，本文利用 MGAN 初步生成大尺度的粗分辨率预报场，再基于此结果逐步生成小尺度高分辨率的预报场，鉴别器则对大尺度和小尺度预报场进行综合鉴别，以此实现 GAN 在降水预报中的优化。

以 PhyDNet 为生成器，MGAN 为鉴别器，共同构成强降水临近预报模型 PhyMGAN。PhyDNet (图 1a) 的编码器将原数据 480×560 的网格点逐步下采样生成 120×140 和 30×35 的网格点，最低的 30×35 网格点的数据经过 PhyDNet 主体计算后生成 30×35 网格点的大尺度预报结果，再由生成器的解码器逐步上采样生成 120×140 和 480×560 网格点的高分辨率预报结果，鉴别器 MGAN 将生成的 3 种网格分辨率预报结果与真值插值而来对应分辨率真值进行综合鉴别 (图 1b)。MGAN 的鉴别损失函数 (L_{MGAN}) 可表示为：

$$L_{\text{MGAN}} = E_{x \sim \text{Pdata}(x)} [\log D(x_1, x_2, x_3)] + E_{x \sim \text{Pg}(x)} \left[\log \left(1 - D(G(x_1, x_2, x_3)) \right) \right] \quad (1)$$

式中： $E_{x \sim \text{Pdata}(x)}$ 表示从真值样本中采样 x 的期望； $E_{x \sim \text{Pg}(x)}$ 表示从预报样本中采样 x 的期望； D 是鉴别器； G 是生成器； x_1 、 x_2 和 x_3 分辨率对应 480×560 、 120×140 和 30×35 的网格点数据。

除 L_{MGAN} 外，损失函数的设计包含了加权平均绝对误差 (L_w)，相较于曾康等 (2024)，权重表 (表 1) 中增加了 30 mm h^{-1} 的权重，以提升模型对于强降水预报任务的偏重， L_w 和 L_{MGAN} 共同构成了综合损失函数 (L)：

$$L_w = \frac{1}{N} \sum_{i=1}^N (w(y_i^{\text{Prec}}) |y_i^{\text{Prec}} - y_i^{\text{Prec}}| + w(y_i^{\text{Radar}}) |y_i^{\text{Radar}} - y_i^{\text{Radar}}|) \quad (2)$$

$$L = L_w + L_{\text{MGAN}} \quad (3)$$

式中： y_i^{Prec} 和 y_i^{Prec} 分别代表模型的降水预报场和观测场； y_i^{Radar} 和 y_i^{Radar} 分别代表模型的雷达反射率因子预报场和观测场； $w(y_i^{\text{Prec}})$ 和 $w(y_i^{\text{Radar}})$ 分别代表降水和雷达反射率因子的损失函数权重； N 代表所有预报时次所有格点的样本总和。训练过程模型保存的指标为 20 mm h^{-1} 阈值的降水 TS 评分。生成器训练时，GAN 的损失函数通常具有平衡其他损失函数的超参数 (Reulen et al, 2024)， L_{MGAN} 与 L_w 之间的平衡超参数与曾康等 (2024) 保持一致，比例设置为 1:10。

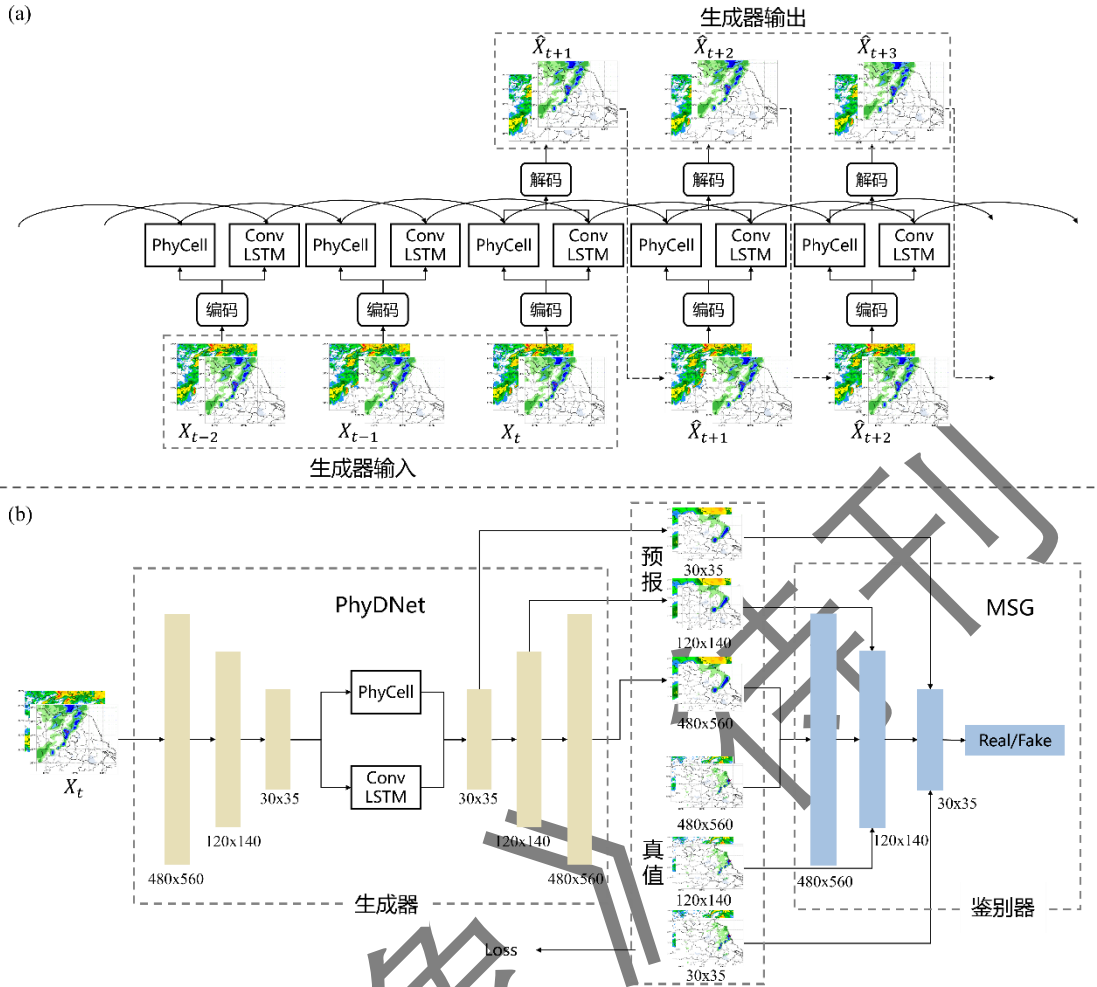


图1 PhyMGAN 模型结构图

(a) PhyDNet 模型结构图, (b) MGAN 模型结构图

Fig.1 Diagrams of the PhyMGAN model with (a) for the PhyDNet model and (b) for the MGAN model

表1 模型加权平均损失函数中不同降水强度 (y) 和雷达组合反射率因子的权重设置

Table 1 Design of weighted loss function for precipitation rate (y) and radar reflectivity

降水强度 / (mm h^{-1})	权重	反射率因子 / dBz	权重
$y \leq 2$	1	$y < 15$	0.5
$2 \leq y < 5$	2.5	$15 \leq y < 25$	1
$5 \leq y < 10$	5	$25 \leq y < 35$	2.5
$10 \leq y < 20$	10	$35 \leq y < 45$	5
$20 \leq y < 30$	20	$45 \leq y < 50$	10
$y \geq 30$	30	$y \geq 50$	15

2.3 对照试验设置

设置了基础试验 PhyDNet 和将其用作生成器的三组对照试验 (表 2), PhyGAN 为通用


空间鉴别器 GAN 与 PhyDNet 的结合, PhySGAN 和 PhyMGAN 则分别将 SGAN 和 MGAN 作为鉴别器。四组试验均采用逐 6 min 雷达组合反射率和降水量作为输入和输出, 且均用到加权平均损失函数 (表 1)。本文将过去 2 h (即起报时刻前 2 h) 逐 6 min 的雷达组合反射率 ($X_{t-19}^{\text{Radar}}, X_{t-18}^{\text{Radar}}, \dots, X_t^{\text{Radar}}$) 和降水场 ($X_{t-19}^{\text{Prec}}, X_{t-18}^{\text{Prec}}, \dots, X_t^{\text{Prec}}$) 作为模型输入, 通过不同试验实现未来 3 h 的雷达组合反射率 ($X_{t+1}^{\text{Radar}}, X_{t+2}^{\text{Radar}}, \dots, X_{t+30}^{\text{Radar}}$) 和降水 ($X_{t+1}^{\text{Prec}}, X_{t+2}^{\text{Prec}}, \dots, X_{t+30}^{\text{Prec}}$) 预报。训练开始前雷达组合反射率和降水均归一化至 [0, 1] 区间。

表 2 对照试验设置表

Table 2 Setup table for control experiment

试验名称	试验说明
PhyDNet	基础试验
PhyGAN	控制试验, PhyDNet 为生成器, 通用 GAN 为鉴别器
PhySGAN	优化试验 1, PhyDNet 为生成器, SGAN 为鉴别器
PhyMGAN	优化试验 2, PhyDNet 为生成器, MGAN 为鉴别器

采用预报业务通用的 TS 和 Bias 对上述四组深度学习试验输出的逐小时短时强降水 (降水强度 $\geq 20 \text{ mm h}^{-1}$) 预报结果进行评估, 真值为 2024 年 6 月 19 日至 8 月 15 日的地面分钟级降水量站, 站点分布见图 2。TS 和 Bias 的计算方法可参见 Shi et al (2017)。



注: 蓝圈代表雷达 150 km 半径覆盖范围。

图 2 评估区域、自动站 (黑点) 及 S 波段雷达 (红点) 分布

Fig.2 Distribution of assessed areas, automatic weather stations (black dot) and S-band radars (red dot)

3 定量评估结果

首先对各深度学习预报方法在 2024 年 6 月 19 日至 8 月 15 日的预报技巧表现进行定量评估。图 3 分别给出整体时段、梅雨期系统性强降水时段（6 月 19 日至 7 月 16 日）和出局局地强降水时段（7 月 17 日至 8 月 15 日）中四组试验的 20 mm h^{-1} 短时强降水 TS 评分，可以看出各种深度学习强降水临近预报方法在整体时段和系统性强降水时段表现相对一致(图 3a, 3b)，PhySGAN 和 PhyMGAN 在前 1 h 较基础试验 PhyDNet 的提升幅度分别可达 17.2% 和 13%，在 2~3 h 增量更加明显。与此同时，注意到该提升幅度随预报时效增加，这可能是由于 PhySGAN 和 PhyMGAN 均改善了 PhyDNet 中的降水强度随时间衰减的问题，进而重点提升了后期强降水中心的预报效果。值得注意的是，在局地强降水时段中（图 3c），PhySGAN 和 PhyMGAN 在 2~3 h 较基础试验的 TS 增幅与系统性强降水时段相比有不同程度的下降，这说明新方法对于持续时间短、空间尺度小的局地强降水过程预报效果提升空间仍相对有限，但该结果和系统性强降水时段也存在共性，即 PhySGAN 在前 1 h 的 TS 表现最优，PhyMGAN 在 2~3 h 最优。此外，注意到 PhyGAN 在各评估时段内 TS 均最低，特别是体现在系统性强降水时段，说明通用 GAN 鉴别器在训练过程中缺乏对复杂天气过程的鉴别能力，不能直接用于强降水这一类多尺度特征明显的预报任务。




图 3 四组深度学习预报方法在 2024 年江苏汛期不同检验时段的 TS
(a) 整体时段, (b) 系统性强降水时段, (c) 局地强降水时段

Fig.3 The TS scores of the deep learning-based forecast methods in different verification periods in Jiangsu during the flood season of 2024

(a) overall period, (b) period of systematic heavy rainfall, (c) period of local heavy rainfall

图 4 进一步给出各组试验的 Bias 表现，与图 3 相结合能够直观看出 PhySGAN 和 PhyMGAN 之所以能够获得更优的 TS 评分得益于修正了 PhyDNet 和 PhyGAN 对于 20 mm h^{-1} 以上短时强降水预报频率偏低的问题。值得注意的是，PhyMGAN 在系统性强降水时段 2~3 h 的 Bias 超过了 1.5 (图 4b)，即通过“过度预报”换取较高的 TS，相较之下 PhySGAN 的 Bias 在各时段内均更接近于最优数值 1。




图 4 四组深度学习预报方法在 2024 年江苏汛期不同检验时段的 Bias

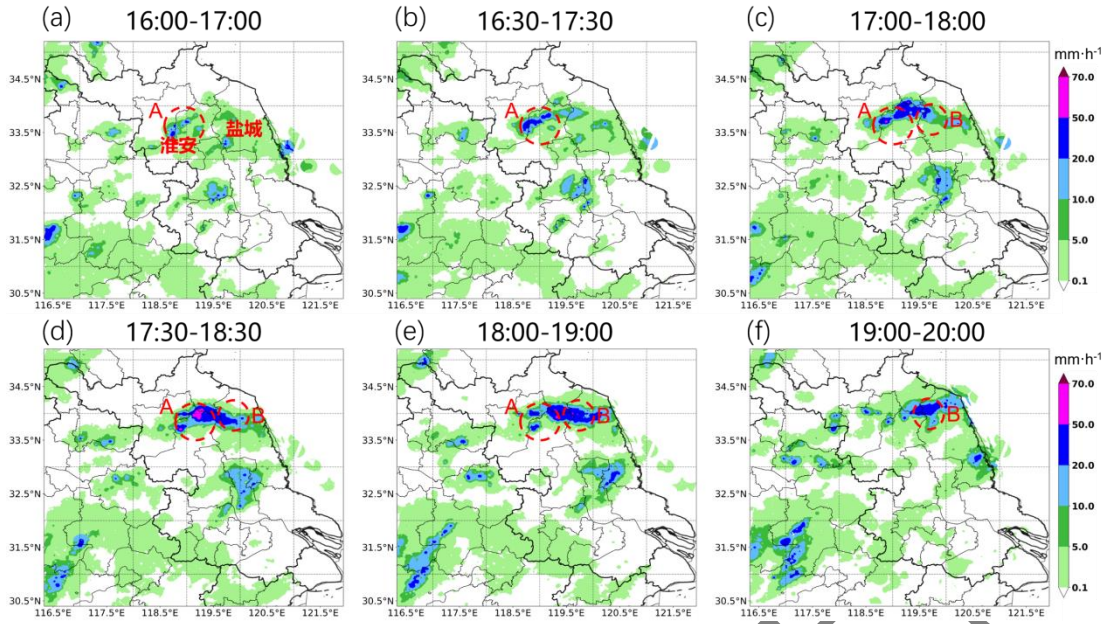
(a) 整体时段, (b) 系统性强降雨时段, (c) 局地强降雨时段

Fig.4 The BIAS scores of the four deep learning-based forecast methods in different verification periods in Jiangsu during the flood season of 2024

(a) overall period, (b) period of systematic heavy rainfall, (c) period of local heavy rainfall

4 “复杂场景” 预报方法性能分析

为更直观地理解各预报方法的性能, 选取 2024 年 7 月 1 日 17:00—20:00 发生在江苏沿淮地区的一次局地短历时强降雨过程进行分析, 此次过程兼具局地性、突发性等多重特征, 阶段 1 (17:00—18:00): 淮安北部局地零散降水区 (雨区 A) 发生明显增强 (图 5a, 5b), 并出现小范围短时强降雨 (图 5c), 结合风暴追踪可知雨区 A 向偏北方向移动 (图略); 阶段 2 (18:00—19:00): 雨区 A 东侧位于江苏盐城西北部的降水系统发展组织化 (雨区 B), 18:30 雨区 B 的滑动小时降水量达到 20 mm (图 5d), A 和 B 发生合并形成相对完整的东西走向中尺度线状雨带; 阶段 3 (19:00—20:00): 伴随雨区 B 向北偏东方向发展, 雨区 A 逐渐减弱 (图 5e, 5f)。也就是说, 尽管该过程从强度或致灾性角度均不能被称为重大/典型案例, 但考虑到 17:00—20:00 无论是降水系统的强度演变还是移动方向均发生了复杂变化, 从实际业务角度来说是一次“复杂场景”, 可用于多维度揭示预报产品性能。需注意的是, 此处仅用于分析各方法性能及对预报预警业务的潜在增益, 不强调优劣。



注：红圈为本次个例重点关注雨区。

图 5 2024 年 7 月 1 日 16:00—20:00 不同时刻的滑动小时降水量

Fig.5 The sliding hourly accumulated precipitation at different moments from 16:00 to 20:00 BT 1 July 2024

为了不失一般性，首先给出业务常用的交叉相关方法在 17:00 起报的未来 3 h 降水量预报表现（图 6），由于该方法为准线性的外推方法，因此仅能呈现出雨区 A 增强前向北线性外推趋势，整个 3 h 时效内无论是降水强度还是移向均无明显变化，对业务无指示作用。

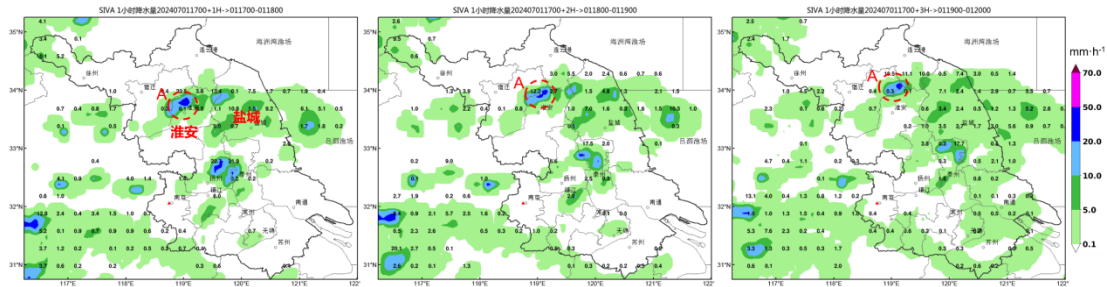


图 6 2024 年 7 月 1 日 17:00 起报的交叉相关外推未来 3 h 的逐小时降水量

Fig.6 Cross-correlation extrapolation for hourly precipitation forecasts with 3 h lead time initiated at 17:00 BT 1

July 2024

相较于外推方法，四组深度学习方法均呈现出降水强度演变刻画性能（图 7）。基础试验 PhyDNet 在 1 h 预报出了雨区 A 发展增强的过程，但 2~3 h 强降水中心出现衰减，未预报出短时强降水落区（图 7a1~c1）。在增加了通用 GAN 之后，PhyGAN 在 2~3 h 几乎完全没能预报出强降水雨区及其中心强度，降水量较基础试验 PhyDNet 更弱，这与 PhyGAN 鉴别器训练过程中缺乏对复杂多尺度天气过程的鉴别能力有关，无法在预报时效延长后生成正确的预报结果（图 7a2~c2）。

与 PhyDNet 和 PhyGAN 相比，PhySGAN 和 PhyMGAN 在本次“复杂场景”中从不同

角度上呈现出更具参考价值的表现。在前 1 h, PhySGAN 和 PhyMGAN 均预报出雨区 A 增强过程(图 7a3, a4), 对短时强降水落区预报均和实况(图 5c)更匹配。从 2 h 开始, PhySGAN 和 PhyMGAN 出现分歧, 前者尽管预报出雨区 B 增强, 但整体雨带发生断裂, 呈现东西两个零散短时强降水中心(图 7b3); PhyMGAN 则比较完整地刻画出了发展增强的东西线状降水雨带(图 7b4), 体现出了一般意义上更优的预报技巧。预报时效达到 3 h 时, PhySGAN 和 PhyMGAN 均预报出雨区 A 降水减弱甚至消散的特征, 但 PhySGAN 中雨区 B 呈东南向移动(图 7c3), PhyMGAN 则呈现东北向移动(图 7c4), 与实况更加接近(图 5f)。另外值得注意的是, PhySGAN 还对主雨带南侧, 发生于江苏泰州一带的局地降水增强过程体现出了一定预报性能(图 7c2, c3)。

总得来说, 从“复杂场景”表现来看, PhySGAN 和 PhyMGAN 体现出了不同预报性能, 前者对强降水形态、强度等局部细节刻画更好, 后者则对强降水雨带的整体轮廓和位置表征更好。结合模型设计分析可知, PhySGAN 着重对输入场中的高频信息进行鉴别, 因此适用于水平方向变化大的局地强降水, 而 PhyMGAN 通过多重尺度设计强化了对空间尺度较大的系统性强降水信息鉴别能力, 进而对整体雨带预报能力较好, 但结合 Bias 表现(图 4)可知, PhyMGAN 在大范围强降水样本较多时易出现过报。

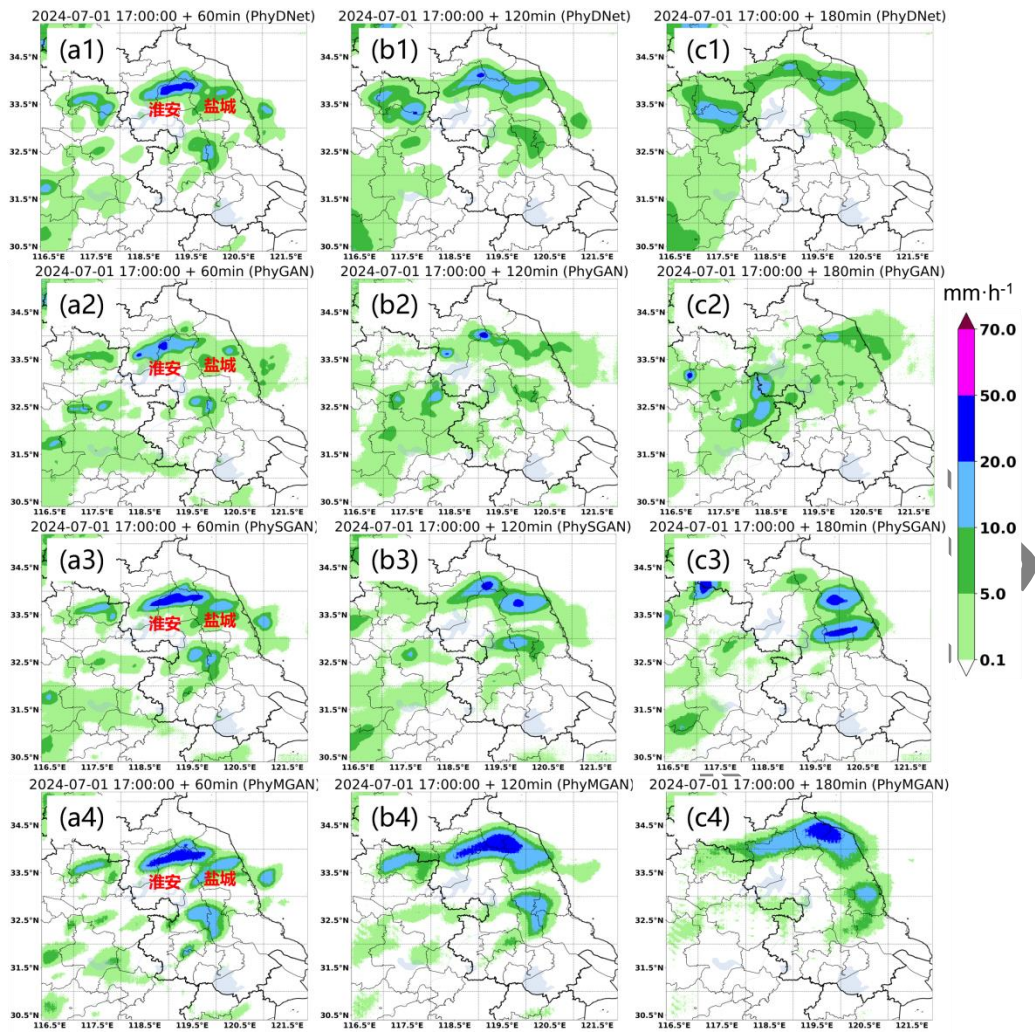


图 7 四组深度学习强降水临近预报方法在 2024 年 7 月 1 日 17:00 起报的未来 3 h 逐小时降水量

Fig.7 Results of hourly precipitation forecasts with 3 h lead time initiated at 17:00 BT 1 July 2024 by four deep learning-based nowcasting methods

5 典型预报应用案例

上文首先评估了各深度学习强降水临近预报方法的技巧评分,并结合一次演变特征复杂、预报难度大的“复杂场景”揭示了各深度学习及传统外推方法在强降水预报业务中的潜在增益,结果表明本文提出的 PhySGAN 和 PhyMGAN 均具备业务紧缺的强降水生消演变预报性能,并兼具较优的评分表现。

PhySGAN 和 PhyMGAN 均已于 2024 年汛期前部署应用于江苏省气象台,逐 6 min 滚动更新提供未来 3 h 的定量降水预报。本节将在上文结论基础上,通过 2024 年江苏地区汛期两次典型强降水案例直观阐述两种新方法的应用表现及其业务增益,考虑传统外推方法在降水增强过程中作用较小,因此本节不加入对比。

5.1 案例 1: 7 月 8 日系统性强降水过程

7 月 8 日 20:00 至 9 日 08:00,受高空槽、冷式切变线、低空急流等天气尺度系统的共

同影响，江苏自西北向东南出现一次系统性强降水过程，受影响的江苏、安徽、山东有超过 300 个国家及区域自动站 12 h 累计降水量超过 100 mm。此次过程大尺度强迫明显，全球数值模式提前 3 d 以上就预见此次过程，江苏相关省市级气象部门也于 8 日 20:00 前发布了暴雨蓝色或黄色预警。回顾整个过程，8 日 21:00 江苏西北部陆续出现局地零散的 20 mm h^{-1} 以上短时强降水（图 8a1, b1, c1），随后发生快速增强（图 8d1, a2, b2），8 日 23:00 和 9 日 00:00 多个站点出现 70 mm h^{-1} 以上降水强度（图 8c2, d2, e2），是整个 12 h 强降水时段内的降水强度之最。因此，尽管此次过程气象服务难度总体较低，但能否预报出 22:00 后降水的快速增强将对区县级暴雨预警升级以及精细化专业气象服务形成考验。

从 21:00 起报的 PhySGAN 和 PhyMGAN 表现来看（图 8a3~e3、a4~e4），二者均预报出江苏的西北部和东北部两处降水增强过程，这对预报员能够起到较好的提示作用，其中 PhySGAN 对降水形态的刻画更加精细，而 PhyMGAN 则倾向于预报成片短时强降水雨带。从强度上来看，二者均未预报出 23:00 后江苏西北部出现的局部 50 mm h^{-1} 以上降水强度区域（图 8c2~e2），其中 PhyMGAN 在 9 日 00:00 的降水强度最大预报值为 43.2 mm h^{-1} ，与实况更加接近。从两组试验 22:00 起报结果来看（图 8a5~e5、a6~e6），此时 PhyMGAN 预报出 2 h（即 9 日 00:00）后江苏西北部局部会出现 50 mm h^{-1} 以上的降水强度，尽管 8 日 23:00 相关地区局部降水强度就达到 50 mm h^{-1} ，但这仍然对预报预警工作具有明确指示意义；此外，随着横槽转竖，9 日 00:00 之后实况降水逐渐呈现东北—西南走向（图 8e2~g2），PhyMGAN 未能体现出这一雨带形态和位置的转变（图 8c6~e6），相较之下 PhySGAN 预报表现更好，特别是较好地体现出了雨带西段的位置（图 8c5~e5），能够更好地帮助预报员开展下游地区的精细化专业预报服务。

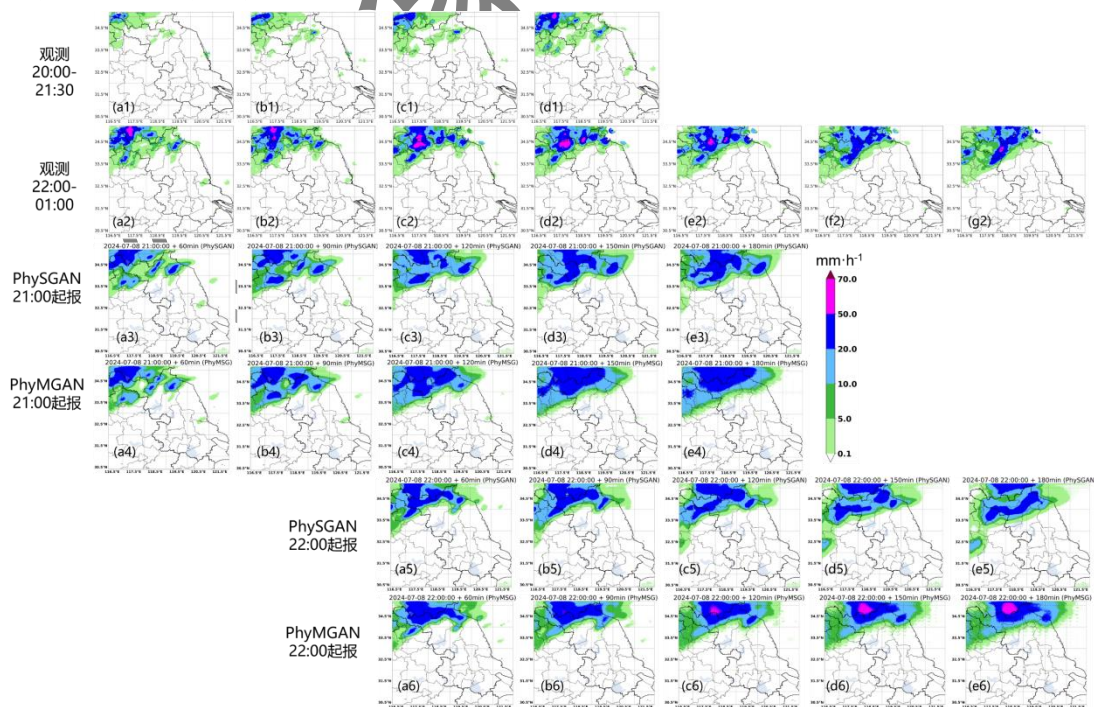


图 8 2024 年 7 月 8 日系统性强降水过程 (a1~d1) 8 日 20:00—21:30 和 (a2~g2) 8 日 22:00 至 9 日 01:00 逐 30 min 间隔的观测小时降水量, 8 日 (a3~e3, a4~e4) 21:00 和 (a5~e5, a6~e6) 22:00 (a3~e3, a5~e5) PhySGAN、(a4~e4, a6~e6) PhyMGAN 起报的未来 3 h 小时逐降水量

Fig.8 The hourly precipitation observed every 30 min from (a1-d1) 20:00 to 21:30 BT 8 and (a2-g2) 22:00 BT 8 to 01:00 BT 9, and the hourly precipitation forecasts with 3 h lead time initiated at (a3-e3, a4-e4) 21:00 BT 8 and (a5-e5, a6-e6) 22:00 BT 8 by (a3-e3, a5-e5) PhySGAN and (a4-e4, a6-e6) PhyMGAN during the systematic heavy precipitation process on 8 July 2024

5.2 案例 2: 9 月 11 日局地强降水过程

9 月 11 日 16:00—20:00, 受东风急流 (东风波) 和弱冷空气影响, 江苏东部沿海地区出现一次突发性局地极端强降水过程, 造成江苏东部的盐城市区出现严重城市内涝。由 17:00—20:00 的 3 h 累计降水量可见 (图 9), 此次过程具有空间尺度小、强降水范围集中、强度大等特征, 结合雷达回波演变特征可见 (图 10), 16:30—17:30 江苏东部沿海地区的零散降水回波逐渐组织化形成 γ 中尺度强降水单体 (图 10a~10c), 该单体随后缓慢西移 (图 10d), 受影响地区短时间内出现极端强降水, 17:00—20:00 最大降水量超过 150 mm。区别于案例 1, 本次强降水过程业务预报难度极高, 不仅体现在能否预报出 16:30 后的局地降水量激增, 还体现在能否成功预报出强降水单体局地维持。需要特别说明的是, 无论是欧洲中期天气预报中心 (ECMWF) 全球数值预报系统 (图 9b), 还是临近两个起报时次的江苏本地快速更新数值预报系统 (图 9c, 9d), 对此次江苏东部沿海地区局地强降水几乎未给出任何指示 (全球模式存在 6 h 左右滞后, 江苏本地模式约 3 h), 因此本节将聚焦本文提出的预报方法能否为预报业务带来帮助。

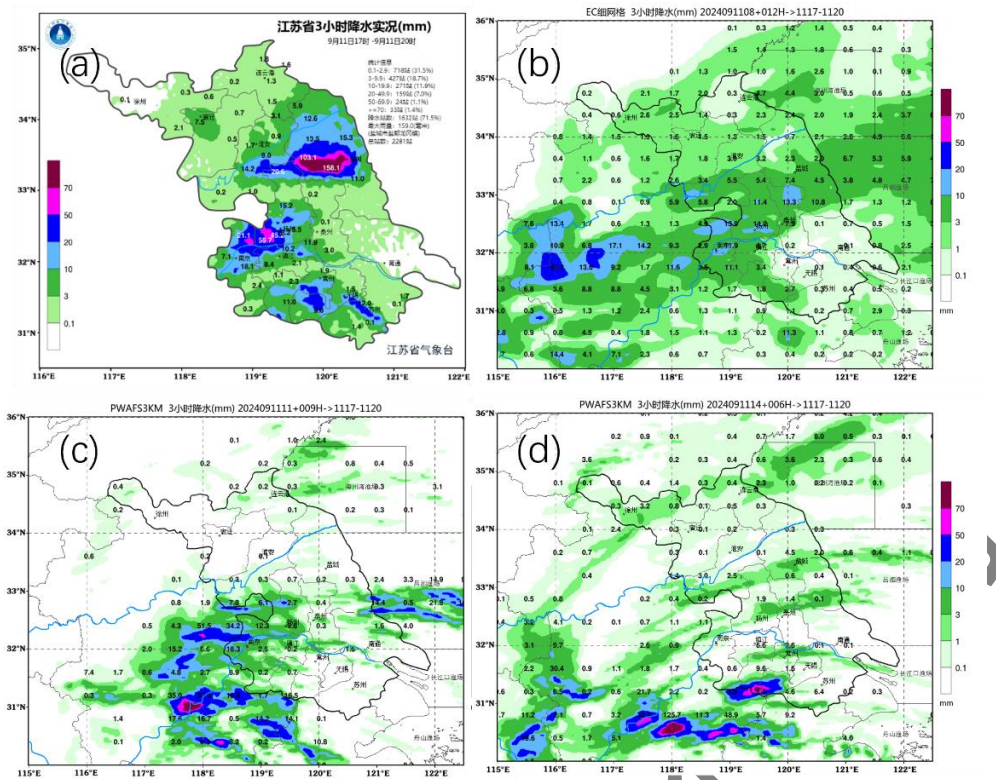
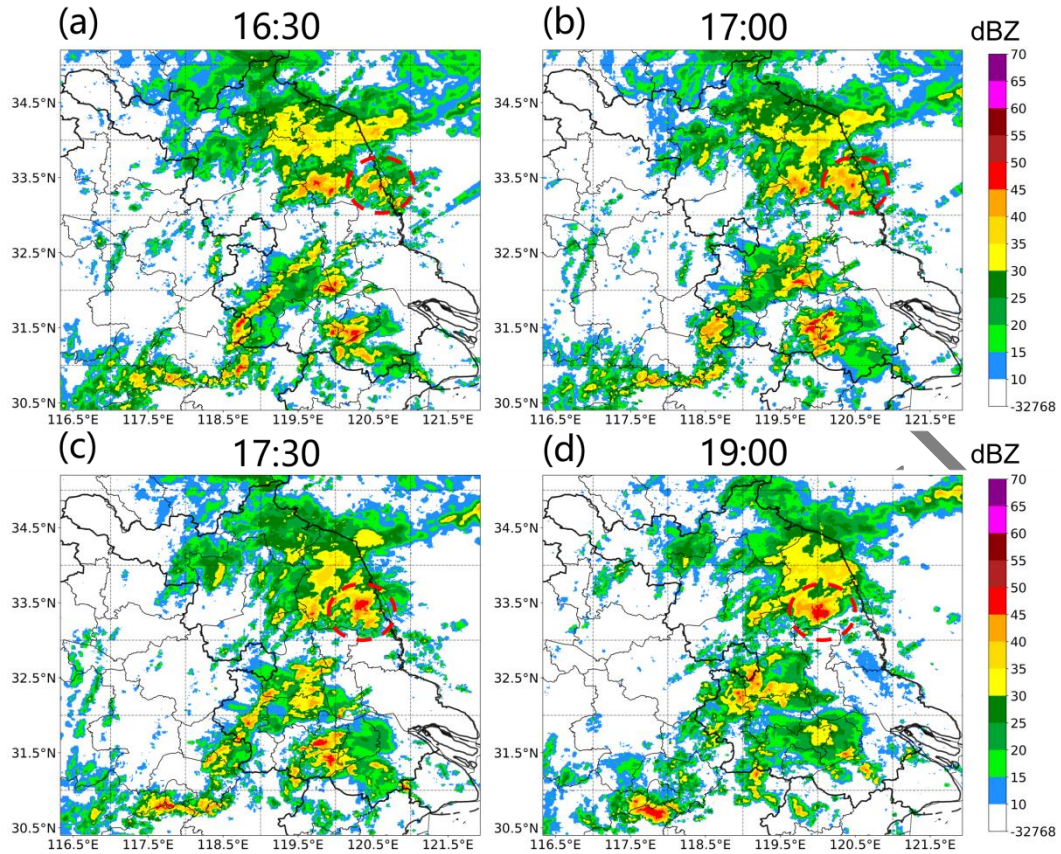


图9 2024年9月11日 (a) 17:00—20:00的累计降水量实况, (b) ECMWF在08:00和 (c, d) 江苏本地数值预报模式分别在 (c) 11:00和 (d) 14:00起报的17:00—20:00的累计降水量

Fig.9 (a) The accumulated precipitation observed from 17:00 to 20:00 BT and (b-d) the 17:00-20:00 accumulated precipitation forecasts by (b) ECMWF model initiated at 08:00 BT, and (c, d) Jiangsu local numerical forecasting system initiated at (c) 11:00 BT and (d) 14:00 BT 11 September 2024



注：红圈所示为强降水中心位置。

图 10 2024 年 9 月 11 日 16:30—20:00 逐 30 min 雷达组合反射率因子

Fig.10 The 30 min radar composite reflectivity from 16:30 to 20:00 BT 11 September 2024

图 11 给出了 16:30 开始 PhySGAN 和 PhyMGAN 多个时次起报的 3 h 累计降水量，可以看出从 16:30 开始，在实况尚未发生强降水的时候，两种预报方法即预报出江苏东部沿海存在局地强降水中心，体现出局地降水增强的预报能力，尽管该中心较实况略偏西，但能够有效提示预报员相关地区出现局地极端强降水中心的可能性。随着起报时间持续更新，PhySGAN 和 PhyMGAN 均持续预报江苏东部沿海的局地强降水，且中心逐渐西移，与实况趋于接近，为预报员提供了更加明确的信号。此外，PhyMGAN 对整个强降水雨带范围预报过大，这样尽管 TS 评分会更高，但可能由于重点不够突出从而给应用带来一定负面作用，相较之下 PhySGAN 则对强降水雨带的刻画则更为精细，指示意义更加明确。

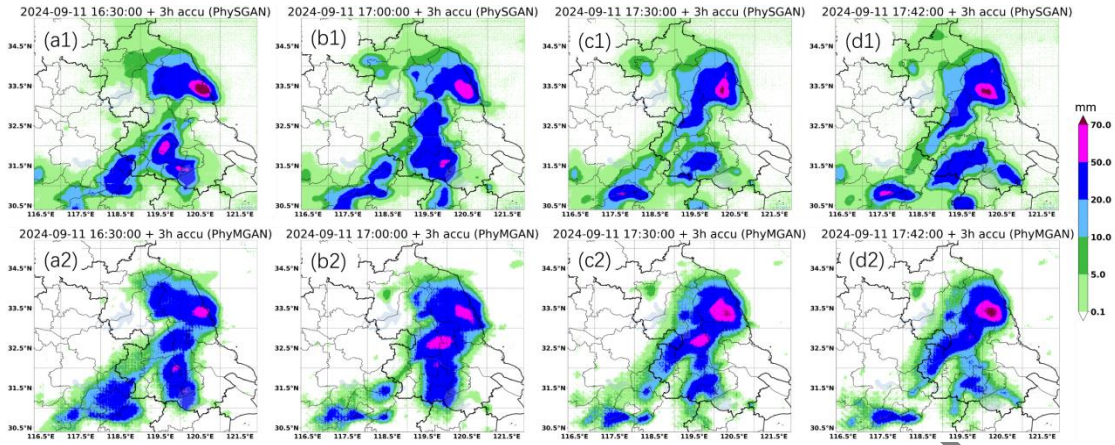


图 11 2024 年 9 月 11 日 (a1~d1) PhySGAN 和 (a2-d2) PhyMGAN 在不同时刻起报的 3 h 累计降水量
 Fig.11 Forecasts of the future 3 h accumulated precipitation by (a1-d1) PhySGAN and (a2-d2) PhyMGAN initiated at different moments on 11 September 2024

6 结论和讨论

本文通过优化通用生成对抗网络提出基于频域生成对抗网络 (SGAN) 和多尺度生成对抗网络的强降水临近预报方法 PhySGAN 和 PhyMGAN, 提供江淮地区未来 3 h 的降水量预报。通过预报技巧评分、“复杂场景”性能评估和典型应用实例分析了两种方法在 2024 年江苏地区汛期短时强降水 (降水量 $\geq 20 \text{ mm h}^{-1}$) 预报中的表现, 得到以下结论:

(1) PhySGAN 和 PhyMGAN 在不同检验时段的 3 h 内短时强降水 TS 评分较基础试验 PhyDNet 和通用生成对抗网络试验 PhyGAN 均有明显提升, 两种新方法通过优化 GAN 使得 TS 增益幅度随预报时效增加, 有效提升了较长时效的 TS 表现。系统性时段检验结果与整体时段一致, 但在局地强降水时段中, 受预报对象可预报性偏低影响, PhySGAN 和 PhyMGAN 较基础试验的 TS 提升幅度有不同程度的下降。

(2) 从 Bias 来看, PhySGAN 和 PhyMGAN 均修正了 PhyDNet 和 PhyGAN 对于短时强降水预报频率偏低的问题, 由此得到较高 TS 评分。其中 PhyMGAN 在系统性强降水时段部分时效的 Bias 超过了 1.5, 即通过“过度预报”换取较高 TS, 相较之下 PhySGAN 的 Bias 更接近于最优数值 1, 说明多尺度鉴别器的设计一定程度上易造成过报。

(3) 从“复杂场景”所展示出的预报性能来看, 四组深度学习方法较传统外推方法均能刻画强降水演变, 本文提出的 PhySGAN 和 PhyMGAN 较 PhyDNet 和 PhyGAN 也有更优的性能表现, 但在“复杂场景”中二者也体现出了明显性能差异, 其中 PhySGAN 对强降水形态、强度等局部细节刻画能力更好, PhyMGAN 则对强降水雨带的整体轮廓和位置表征更好。

(4) PhySGAN 和 PhyMGAN 在 2024 年江淮地区汛期强降水过程中均得到了有效应用。在 7 月 8 日夜间系统性强降水过程中, 二者均提前预报出降水增强过程, 起到较好的临灾预警提醒作用。PhyMGAN 对 23:00 后江苏西北部徐州出现的局部 50 mm h^{-1} 以上极端降水强度有更好的指示作用, PhySGAN 则能够更好体现雨带形态和位置的转变。在 9 月 11 日东风

波造成的局地强降水过程中，PhySGAN 和 PhyMGAN 均在实况出现前预报出江苏东部沿海存在局地强降水中心，体现出局地降水增强的预报能力，随着起报时间持续更新，持续将强降水中心向西订正逐渐与实况趋近，为预报员提供了更加明确的信号和信心。

以上研究结论揭示了 GAN 在短时强降水临近预报中的应用潜力，特别是针对业务关切的降水增强过程，未来将进一步分析相关方法在降水减弱过程中的适用性。值得注意的是，近期国家气象中心基于 NowcastNet (Zhang et al, 2023) 和中国长序列雷达数据建立了人工智能临近预报模型“风雷”V1 (盛杰等, 2025)，有效实现了不同尺度强对流过程的雷达回波预报，并在一定预报时效内正确给出了对流系统的生消演变预报，在未来研究中将考虑借鉴“风雷”模型数据物理双驱动的设计，并将其用于短时强降水临近预报任务。此外，一般认为快速更新同化数值模式对 2 h 后的预报时效更具优势，未来的工作中也将开展深度学习临近预报与数值模式对 2~3 h 强降水预报的性能对比分析。

参考文献

- 代刊, 杨绚, 周康辉, 等, 2025. 深度学习在数字智能天气预报中的应用[J]. 气象, 51(11):1477-1494. Dai K, Yang X, Zhou K H, et al, 2025. Application of deep learning in digital intelligent weather forecasting[J]. Meteor Mon, 51(11):1477-1494 (in Chinese).
- 祁海霞, 彭涛, 智协飞, 等, 2025. 深度学习技术在洪水预报中的应用进展及思考[J]. 气象, 51(4):446-459. Qi H X, Peng T, Zhi X F, et al, 2025. Progress and reflection on application of deep learning techniques in flood forecasting[J]. Meteor Mon, 51(4):446-459 (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).
- 汪卫国, 平凡, 周括, 等, 2024. 雷达资料循环同化对2021年“4·30”南通雷暴大风模拟的影响研究[J]. 大气科学, 48(4): 1593-1607. Wang W G, Ping F, Zhou K, et al, 2024. Influence of Radar Data Cycling Assimilation on Thunderstorm Gale Simulation in Nantong on April 30, 2021[J]. Chin J Atmos Sci, 48(4): 1593-1607(in Chinese).
- 王永灿, 2023. 基于深度学习的雷达图像外推及降水临近预报[D]. 青海: 青海大学. Wang Y C, 2023. Deep learning-based methodology for radar-echo extrapolation and precipitation nowcasting[D]. Qinghai: Qinghai University (in Chinese).
- 王永灿, 魏加华, 李琼, 等, 2023. 基于雷达回波的临近降水预报卷积循环神经网络模型研究[J]. 水利水电技术(中英文), 54(1): 24-41. Wang Y C, Wei J H, Li Q, et al, 2023. Radar echo-based study on convolutional recurrent neural network model for precipitation nowcast[J]. Water Resour Hydropower Eng, 54(1): 24-41 (in Chinese).
- 苑希民, 兰卓青, 王丽娜, 等, 2024. 极端天气城市特大暴雨洪涝灾害特征再分析及应对策略[J]. 水利学报, 55(11): 1298-1308. Yuan X M, Lan Z Q, Wang L N, et al, 2024. Reanalysis of the characteristics of extreme rainstorm and flood disaster in urban areas and coping countermeasures[J]. J Hydraulic Eng, 55(11): 1298-1308 (in Chinese).
- 曾康, 闵锦忠, 庄潇然, 等, 2024. 基于生成对抗网络的强对流临近预报方法及其在中国东部地区的应用评估[J]. 大气科学, 48(6): 2316-2328. Zeng K, Min J Z, Zhuang X R, et al, 2024. Severe convection nowcasting method based on a generative adversarial

- network and its application evaluation in eastern China[J]. *Chin J Atmos Sci*, 48(6): 2316-2328 (in Chinese).
- 曾小团, 谭肇, 沈玉伟, 等, 2025. CastNet: 深度学习定量降水临近预报模型[J]. *气象*, 51(4):400-416. Zeng X T, Tan Z, Shen Y W, et al, 2025. CastNet: deep-learning-based model for quantitative precipitation nowcasting[J]. *Meteor Mon*, 51(4):400-416 (in Chinese).
- 郑永光, 周康辉, 盛杰, 等. 2015. 强对流天气监测预报预警技术进展[J]. *应用气象学报*, 26(6):641-657. Zheng Y G, Zhou K H, Sheng J, et al. Advances in techniques of monitoring, forecasting and warning of severe convective weather[J]. *J Appl Meteor Sci*, 2015, 26(6): 641-657 (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, 闵锦忠, 蔡沅辰, 等, 2017. 风暴尺度集合预报最优侧边界条件扰动方法设计: 个例分析[J]. *气象科学*, 37(1): 21-29. Zhuang X R, Min J Z, Cai Y C, et al, 2017. Optimal design of lateral boundary condition perturbation method in storm-scale ensemble forecast: a case study[J]. *J Meteor Sci*, 37(1): 21-29 (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).
- 庄潇然, 刘梅, 蔡凝昊, 等, 2025. 基于深度学习的降水临近预报方法及其在2023年江苏汛期中的应用评估[J]. *暴雨灾害*, 44(1): 1-8. Zhuang X R, Liu M, Cai N H, et al, 2025. Evaluation of deep learning-based precipitation nowcasting methods during the 2023 flood season in Jiangsu Province[J]. *Torr Rain Dis*, 44(1): 1-8 (in Chinese).
- Das P, Posch A, Barber N, et al, 2024. Hybrid physics-AI outperforms numerical weather prediction for extreme precipitation nowcasting[J]. *npj Clim Atmos Sci*, 7(1):1-15.
- Ha J, Lee H, 2023. A deep learning model for precipitation nowcasting using multiple optical flow algorithms[J]. *Wea Forecasting*, 39, 41-53.
- Han D, Im J, Shin Y, et al, 2023. Key factors for quantitative precipitation nowcasting using ground weather radar data based on deep learning[J]. *Geosci Model Dev*, 16, 5895-5914.
- Karnwar A, Wang O, 2020. MSG-GAN: multi-scale gradients for generative adversarial networks[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE.
- Le Guen V, Thome N, 2020. Disentangling physical dynamics from unknown factors for unsupervised video prediction[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 11471-11481.
- Ravuri S, Lenc K, Willson M, et al, 2021. Skilful precipitation nowcasting using deep generative models of radar[J]. *Nature*, 597(7878):

672-677.

- Reulen E, Shi J, Mehrkanoon S, 2024. GA-SmaAt-GNet: generative adversarial small attention GNet for extreme precipitation nowcasting[J]. Knowl-Based Syst, 305: 112612.
- 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 28th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 802-810.
- Shi X J, Gao Z H, Lausen L, et al, 2017. Deep learning for precipitation nowcasting: a benchmark and a new model[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 5622-5632.
- Tan J K, Huang Q Q, Chen S, 2024. Deep learning model based on multi-scale feature fusion for precipitation nowcasting[J]. Geosci Model Dev, 17, 53–69.
- 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 International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 879-888.
- 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]//Proceedings of the 35th International Conference on Machine Learning. Stockholm: PLMR, 80: 5123-5132.
- 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.
- Zhou K H, Zheng Y G, Dong W S, et al, 2020. A deep learning network for cloud-to-ground lightning nowcasting with multisource data[J]. J Atmos Ocean Technol, 37, 927-942.