曾康,闵锦忠,庄潇然,等.2023. 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, xx(x):xxx-xxx. ZENG kang, MIN Jinzhong, ZHUANG Xiaoran. 2023. Severe convection nowcasting based on generative adversarial network and its application evaluation in eastern China [J]. Chinese Journal of Atmospheric Sciences (in Chinese), xx(x):xxx-xxx. doi:10.3878/j.issn.1006-9895.2310.23094

# 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

曾康1, 闵锦忠1, 庄潇然2, 康志明2

1.南京信息工程大学,南京,210004
 2.江苏省气象台,南京,210009

摘要 为了缓解深度学习雷达回波外推预报中普遍存在的"模糊"问题,发展了一种有机融合 PhyDNet 和频域匹配生成对 抗网络的雷达回波外推预报方法(PhyDNetSGAN),能够预测江苏及其上游地区未来 3h 的雷达组合反射率因子,通过 对比 PhyDNetSGAN、PhyDNet(未使用生成对抗网络)、PhyDNetGAN和 Sprog(改进的光流法)验证了新方法在强对 流天气临近预报中的适用性。结果表明: (1)与光流法 Sprog 相比,深度学习方法能更好地体现强回波的非线性发展 演变过程。(2)增加生成对抗网络的 PhyDNetGAN和 PhyDNetSGAN 较其他两组试验能够得到更精细且符合预报员主 观认知的雷达回波外推结果,缓解"模糊"问题。(3)新提出的 PhyDNetSGAN 不仅能够改善预报精细度,还能更好地捕 获强回波的形态、位置和中心强度,从而获得更优的预报技巧表现,延长有效预报时长。(4)新提出的综合 TS、Bias 和 FID 的综合评分指标较 TS 能够更好地反应与预报员主观体验相一致的临近预报检验效果。

关键词 生成对抗网络 雷达回波外推 "模糊"问题 综合评分指标

文章编号

doi:10.3878/j.issn.1006-9895.2310.23094

中图分类号

文献标识码 A

# Severe convection nowcasting based on generative adversarial network and its application evaluation in eastern China

收稿日期 2023-07-09; 网络预出版日期 xxxx-xx-xx

作者简介 曾康,男,1999年出生,硕士研究生,主要从事人工智能气象应用研究。E-mail:20211201003@nuist.edu.cn 通信作者 闵锦忠,主要从事中尺度数值模拟与资料同化、集合预报等方面的研究。E-mail:minjz@nuist.edu.cn 资助项目 江西省重点研发计划项目(20223BBG71019)、中国气象局创新发展专项(CXFZ2023J008)、中国气象局重点创新团队(CMA2022ZD04)、国家自然科学基金(42105008)、中国气象局能力提升联合研究专项(22NLTSZ001)。

**Funded by** Key Research Program of Jiangxi Province (Grant 20223BBG71019), China Meteorological Administration Innovation development project (Grant CXFZ2023J008), China Meteorological Administration key innovation team (Grant CMA2022ZD04), National Natural Science Foundation of China (Grant 42105008), China Meteorological Administration Joint Research Project on Capacity Enhancement(Grant 22NLTSZ001)

#### ZENG Kang<sup>1</sup> MIN Jinzhong<sup>1</sup> ZHUANG Xiaoran<sup>2</sup> KANG Zhiming<sup>2</sup>

1. Nanjing University of Information Science and Technology, Nanjing, 210004

#### 2. Jiangsu Meteorological Observatory, Nanjing 210009



Abstract In order to alleviate the common "fuzzy" problem in deep learning radar echo extrapolation prediction, a radar echo extrapolation prediction method (PhyDNetSGAN) with organic fusion of PhyDNet and frequency-domain matching generative adversarial network was developed, which can predict the combined radar reflectance factor in Jiangsu and its upstream region in the future 3h. By comparing PhyDNetSGAN, PhyDNet (without generative adversarial network), PhyDNetGAN and Sprog (improved optical flow method), the applicability of the new method in severe convection weather prediction was verified. The results show that: (1) Compared with Sprog, the deep learning method can better reflect the nonlinear evolution of strong echoes. (2) PhyDNetGAN and PhyDNetSGAN with the addition of generative adversarial network can obtain more refined radar echo extrapolation results in line with the subjective cognition of forecasters than the other two groups of experiments and alleviate the "fuzzy" problem. (3) The newly proposed PhyDNetSGAN can not only improve the forecast precision, but also better capture the form, position and central intensity of strong echoes, so as to obtain better prediction skills and extend the effective forecast time. (4) Compared with TS, the newly proposed comprehensive score index of TS, Bias and FID can better reflect the test effect of approaching forecast which is consistent with the subjective experience of forecasters.

Keywords Generative adversarial network, Radar echo extrapolation, The "fuzzy" problem, Comprehensive scoring index

#### 1引言

基于天气雷达等稠密观测资料的 0~3h 临近 预报是强对流天气监测预警业务的主要手段之 一(俞小鼎等, 2012; 郑永光等, 2015),随 着气象技术的快速发展,时间提前量已成为当 前业务场景下衡量预警有效性的主要标准。传 统建立在雷达回波线性演变假设基础上的风暴 追踪 (Johnson et al, 1998; 韩雷等, 2007)、 交叉相关(Tuttle et al, 1990)以及光流 (Germann and Zawadzki, 2002; Bowler et al, 2004;程丛兰等,2013)等外推方法不能刻画 对流系统生消演变等非线性过程,因此在实际 应用中存在较大局限性。相较之下,近年来在 气象领域得到快速发展的人工智能,尤其是深 度学习技术已被发现能够更好地处理对流系统 的时空变化及其内在关联,成为了改进强对流 天气临近预报的新手段(周康辉等, 2021)。

早在 2015 年 Shi et al (2015) 尝试将深度 学习用于雷达回波临近预报任务,并发现利用 时空卷积神经网络 ConvLSTM 构建的临近预报 模型对中国香港地区的预报技巧优于光流法; Wang et al (2017; 2018; 2019) 在此基础上先 后提出了 PredRNN 及其改良版本 PredRNN++和 PredRNN-v2, 重点解决了 ConvLSTM 中不同层 次空间信息相互独立的问题; 庄潇然等(2022) 尝试了具有物理约束功能的时空卷积神经网络 PhyDNet, 发现该模型较 INCA (Haiden et al 2010)和其他深度学习模型能够更好地刻画强 降水的快速增强过程,并得到最优的预报技巧 表现。除了上述基于循环神经网络(RNN, recurrent neural network)的时空序列网络,卷 积神经网络(CNN, convolutional neural network)也在雷达回波临近预报研究中取得了 广泛应用,这当中最具代表性的是图像分割领

域广泛应用的全卷积网络 Unet, Azyel et al (2020)发现通过 Unet 构建的雷达回波预测模 型在前 60min 预测技巧优于光流法;曹伟华等 (2022)通过 Unet 研究建立了京津冀地区降水 滚动预报模型,结果表明深度学习技术较交叉 相关能够改进 1h 降水预报的绝对误差和相关系 数;Pan et al (2021)基于 Unet 建立了结合雷达 回波和双偏振参量的回波预测模型,与光流法 相比更能体现对流风暴发展的过程。

以上研究均一定程度上阐明了深度学习技 术在强对流临近预报中的有效性,但近期陆续 有研究指出该类技术普遍存在"模糊"问题 (Tian et al, 2020; Ravuri et al, 2021)。"模 糊"问题是一种随着预报时效的延长,预报结果 趋于"回归到均值"的现象,在预报结果上的表 现为大面积的预报结果近似相同且在均值附近, 这种问题的存在将大幅度降低产品的可用性。

Tran and Song (2019)在深度学习框架下提出 了一种基于结构相似性的损失函数,较传统均 方根误差(MSE)和平均绝对误差(MAE)损 失函数更好地改善了对流系统结构的预测能力, 一定程度上可以减弱"模糊"问题,相似的结论 在 Yin et al (2021)也得到了印证。另一类更普 遍的可用于缓解模糊问题的方法是生成对抗网 络(GAN),尽管多项研究已发现GAN能够得 到更加清晰的雷达回波预测结果(Ravuri et al, 2021; Zheng et al, 2022),但其优势却难以体 现在传统的客观评分中(Ravuri et al, 2021; Hu et al, 2022)。近期,Hu et al (2022)提出 了一种基于频域匹配的生成对抗网络 (Spectrum GAN, SGAN),通过将模型输入 的雷达回波场分解到不同的频域再进行鉴别, 在提升了深度学习模型预测清晰度的基础上还 优化了预报技巧评分,但Hu et al (2022)采用 的深度学习网络是 Unet, 庄潇然等(2022)发 现,在相近的配置下,物理约束网络 PhyDNet 较 Unet 在中国东部地区的强对流临近预报中有 着更优异的表现。本文将提出一种有机融合物 理约束网络 PhyDNet 和 SGAN 的 0~3h 雷达回波 临近预报模型,并进一步发展一种针对强对流 临近预报场景的客观评估方法,通过 2022 年暖 季不同类型的强对流天气过程对新模型开展全 面评估, 意在讨论两个问题: (1) SGAN 能否 在缓解"模糊"问题的基础上进一步提升预报技 巧评分? (2) 如何从更加科学和全面的角度对 强对流临近预报进行评估? 文章的章节安排如 下: 第2节介绍数据集, 第3节介绍深度学习 模型及试验设置,第4节给出试验结果,第5节 对全文进行总结和讨论。

## 2 数据集介绍

数据集采用由江苏省气象台制作的强对流 应用数据集,具体制作方式可参见庄潇然等 (2022),选用其中雷达组合反射率因子和降 水变量用于本文的深度学习建模,单一时次数 据尺寸为 480×560,水平分辨率为 0.01°(约 1km),时间分辨率为 6min,覆盖了江苏及其 上游安徽的部分地区(庄潇然等,2022)。筛 选 2018-2022 年的 4-9 月区域内有超过 5%雨量 站点有雨(>0.1mm/h)的时次用于数据集制作, 划分 2018-2021 年 4-9 月共计 38011 组数据样本 选为训练集,2022 年 4-6 月 5711 组样本作为检 验集,同年 7-9 月的 6443 组数据样本作为测试 集。

#### 3 试验设置

#### 3.1 PhyDNet 介绍

PhyDNet 是由 Guen and Thome (2020)提 出的一种具有物理约束功能的深度学习网络, 其物理约束体现在 PhyDNet 体现了特定运动方 程描述的自然界物理运动规律与深度学习结合 的思想。PhyDNet 具有物理单元 PhyCell 和基础 时空卷积单元 ConvLSTM 的双分支架构,可通 过残差网络设计将能够通过偏微分方程描述的 物理动力学项和非物理因子项(如图像的纹理、 新生细节等非线性扰动项)分开,在雷达回波 临近预报任务中,前者可用于体现对流系统的 系统性移动变化,后者用于描述系统的局地变 化,PhyDNet 的具体介绍可见于 Guen and Thome (2020)、庄潇然等(2022)。

## 3.2 基于频域匹配的生成对抗网络(SGAN)

在传统的 GAN 中,鉴别器用于在平面空 间上对二维预测场进行鉴别,而生成器则试图 让鉴别器认定其输出内容为真值,在二者不断 "博弈"的过程中,最终的输出结果得以逐渐 趋于真实。尽管传统的 GAN 能够一定程度鉴 别预测对象的形态、颜色等基本空间特征,但 是缺乏对其中高频(小尺度)信息的鉴别能力 (Chen et al, 2020),天气系统本身就具有复 杂多尺度特征,以雷达回波场为例,层状云回 波时空尺度大,可预报性高,而对流云造成的 强回波则具有时空尺度小,可预报性偏低的特 征,因此,将多尺度系统组成的复杂图形结构 进行等价化处理在气象学意义上缺乏合理性。 针对该问题,本文提出一种有机考虑雷达回波 多尺度信息的频域匹配 GAN 技术(Spectrum GAN,简称 SGAN),将由生成器得到的回波 预测场和真值场进行尺度分解,分解后的低频 域场对应较低强度、大尺度回波,高频域场则 对应高强度、小尺度回波,进而通过鉴别器进 行综合判别。

一般情况下,GAN 判别器的空间损失函数 可表示为:

 $L_{GAN} = E_{x \sim Pdata(x)}[\log D(x)] + E_{x \sim Pg(x)} \left[ \log \left( 1 - D(G(x)) \right) \right]$ (1)

式(1)中G为生成器,D是鉴别器,用于鉴别 输入图片序列在二维空间上的真实性,GAN的 训练过程可简单理解为生成器G不断进行目标 极小化训练,并生成尽可能符合真值的图片序 列G(x),与此同时,鉴别器D则试图对其进行 最大化,并不断判识G(x)和真值场之间的差异, 从而鉴别图像中的每一个格点值是真或假(图 1a)。在SGAN中,采用离散余弦变换(DCT, Discrete Cosine Transform)技术(庄潇然等, 2016)将二维回波场转换到谱空间(图 2), 并在二维谱空间中进行对抗学习(图 1b),与 Hu et al (2022)采用的快速傅里叶变换(FFT) 相比,DCT 能够避免有限区域的侧边界误差, SGAN的判别器频域损失函数可用下式表示:

$$L_{SGAN} = E_{x \sim Pdata(x)} [\log D^{200km} (F(x))] + E_{x \sim Pg(x)} \left[ \log \left( 1 - D^{200km} (G(F(x))) \right) \right] (2)$$

$$F(x) = \alpha(u) \sum_{x=0}^{N-1} f(x) \cos \frac{(2x+1)u\pi}{2N}$$

$$u = 0, 1, ..., N - 1 \qquad (3)$$

$$\alpha(u) = \begin{cases} \sqrt{1/N}, u = 0\\ \sqrt{2/N}, u = 1, 2, \dots, N - 1 \end{cases}$$
(4)

式(2)中G为生成器, D<sup>200km</sup>是鉴别器, x~Pdata(x)指x从预测值中采样, x~Pg(x)表 示x从真值中采样, F(x)为DCT变换,计算公 式如(3)和(4)所示,其中f(x)为二维回波 场,N为二维回波场数据长宽的长度。考虑到 强对流天气主要以中小尺度系统为主,造成中 国东部地区强对流天气的系统以中β尺度飑线 和中γ尺度的对流单体为主,因此在训练时仅 保留中β以下尺度(≤200km),使 SGAN 能

够更加聚焦对中小尺度强回波的判别能力,继 而起到维持强回波预测评分的作用。在损失函 数方面,设计加权平均绝对误差(Weighted L1) (式 5,表 1)、SGAN 判别器频域损失(式 2) 相结合的综合损失函数(式 6):

# Weighted $L1 = \frac{1}{N} \sum_{i=1}^{N} (w(y_i^p) \left| \widehat{y_i^p} - y_i^p \right| +$

- $w(y_i^r)|\widehat{y_i^r} y_i^r|) \tag{5}$
- $L = Weighted L1 + L_{SGAN}$ (6)



图1(a)GAN中空间鉴别器示意图,(b)SGAN中频域鉴别器示意图

Fig. 1 (a) Diagram of GAN Spatial discriminator, (b) Diagram of SGAN frequency domain discriminator



图 2 DCT 频域分解示意图,(a)图为原始雷达回波场,(b)图为其对应的频域空间分布量化图,(c)为滤 除≥200km 波长后的回波场。

Fig. 2 DCT frequency domain decomposition diagram, figure (a) shows the original radar echo field, figure (b) shows its corresponding quantization map of spatial distribution in frequency domain, and figure (c) shows the echo field after filtering wavelengths ≥200km.

式(5)中, $\hat{y}_{i}^{p}$ 和 $\hat{y}_{i}^{r}$ 分别代表模型的降水和雷达反射率因子的预报场, $y_{i}^{p}$ 和 $y_{i}^{r}$ 分别代表降水

和雷达反射率因子的观测场, N 代表所有预报时次所有格点的样本总和。



表1 雷达反射率因子和降水的权重设置

Fig. 3 Diagram of the PhyDNetSGAN model. (a) diagram of the PhyDNet model in PhyDNetSGAN; (b) diagram of the overall structure of the PhyDNetSGAN model.

#### 3.3 试验设置

选取过去 2h(即起报时刻前 2h)逐 6min 的雷达组合反射率因子拼图(*X*<sup>Radar</sup>t-19, *X*<sup>Radar</sup>t-18, ..., *X*<sup>Radar</sup>t) 和降水场(*X*<sup>Prec</sup>t-19, *X*<sup>Prec</sup>t-18, ..., *X*<sup>Prec</sup>t) 作为模型输入,将 PhyDNet 做 为生成器得到未来 3h 的回波预测结果,并与未 来 3h 回波真值输入鉴别器 SGAN,通过计算综 合损失函数,输出经过鉴别的 3h 回波预测结果, 实现对未来 3h 逐 6min 的雷达组合反射率因子 (*X*<sup>Radar</sup>t+1, *X*<sup>Radar</sup>t+2, ..., *X*<sup>Radar</sup>t+30)进行预测 (图 3)。数据预处理方面,在训练开始前将 原始雷达回波和降水均 Min-Max 归一化至[0,1] 区间,模型的具体训练参数设置详见于表 2。 将上述 PhyDNet 与 SGAN 相结合的模型命名为 PhyDNetSGAN,并设置三组对照试验:第一组 对照试验为 STEPS 系统(Bowler et al, 2004, 2007; Pulkkinen et al, 2019)提供的改进光流 法 Sprog (Seed, 2003),用以对比深度学习方 法与传统光流法的差异;第二组对照试验为未 加入生成对抗网络、直接采用 PhyDNet 输入雷 达回波、降水场双通道建模,得到的雷达回波 预测输出(庄潇然等, 2023);第三组对照试 验为加入传统 GAN 的 PhyDNetGAN,通过对比 三组深度学习试验可以直观地揭示增加生成对 抗网络在雷达回波临近预报中的作用,并阐明 本文提出的 SGAN 较传统 GAN 能否进一步提升 预测能力。



表 2 模型参数设置

Table 2	Model	parameters	setting
---------	-------	------------	---------

参数名称	预设值	说明
初始学习率	0.0001	控制模型权重在每次迭代中的更新幅度,过小权
		重更新越慢或者陷入局部最优解,过大会导致模
)		型不稳定,使其难以收敛。
批量大小	4	一次代入训练模型的样本个数,过小可能导致模
		型的收敛性和稳定性降低,过大可能导致模型过
		拟合。
最大迭代轮次	50	一个最大迭代轮次代表所有样本送入网络中完成
		了一次前向计算和反向传播的过程。
生成器中 SGAN	1:10	在 SGAN 中,损失函数由鉴别器的损失和生成器
Loss 和 Weighted		的损失组成。鉴别器的损失使用二元交叉熵损失
L1Loss 的权重比例		函数。生成器的损失使用 SGAN Loss 和 Weighted
		L1Loss.其比例为1:10。SGAN Loss 比例过大训
		练难以收敛,比例过小难以取得优化效果。

Check_val_rate	0.5	进行模型验证的周期。训练1个 epoch 验证2次
		是 0.5, 验证次数过多导致模型的训练速度减慢,
		可能导致模型精度降低。
Save monitor	TS_45dBZ	训练时模型验证比较的指标。用于保存模型训练
		时对 45dBZ 以上雷达回波预报效果最好的模型权
		重。
优化器	Adam	优化器是用于优化模型权重的算法,其作用是根
		据损失函数的梯度,更新模型的权重,使其逐步
		接近最优解。
Teacher forcing ratio	初始概率为 0,每增	训练过程中的每个时刻,有一定概率使用上一时
	加一个迭代轮次,则	刻预测的雷达回波作为输入,也有一定概率使用
	增加10%的概率使用	观测的雷达回波作为输入,用于提高模型的泛化
	上时刻输出作为输入	能力。
	上的刻柳山下刃柳八	
字习率衰减策略	目适应调整字习率	字习率设定忠路是前期一个较大的字习率米确保
	(Reduce LR On	加速收敛,后期用较小的学习率保证稳定,逼近
	Plateau)	最优模型。

#### 3.4 评估方法

区别于短时(0-24h)和短期(1-3d)预报 场景中的数值预报评估,强对流天气临近预警 场景更加侧重考察预报产品的精细度,考虑到 业务常用的点对点评分方法存在"双重惩戒" 等局限性,本文从"预报技巧评分"、"预报 平衡性"和"预报真实性"三个角度提出一种 新的评分办法,较传统单一"点对点"评分方 法更加适用于临近预报预警场景。在新的评分 规则中,用 TS 和 BIAS 衡量预报技巧和平衡性, 采用 FID (Frechet Inception Distance score)

(Heusel et al, 2018)衡量预报图像的真实性, FID 是计算真实图像分布和生成图像分布之间 距离的一种度量,数值越小代表生成的分布越 贴近于真实分布:  $FID = \|\mu_r - \mu_g\|^2 + T_r(\sum r + \sum g - 2(\sum r \sum g)^{0.5})$  (6)

 上式中 $\mu_r$ 和 $\mu_g$ 分别为真值场和预测场的特征均

 值,  $\sum r \pi \sum g$ 则分别代表真值场和预测场的协方差矩阵, Tr 为矩阵的迹。为最大可能贴合现

 行业务评价标准,设计了融合 TS、BIAS 和 FID

 的综合评分:

$$Score = TS * \exp(-abs(1 - BIAS)) ** 0.2$$
$$* \exp(-\frac{fid}{100}) ** 0.2$$
(7)

其中 TS 作为业务常用的预报技巧衡量手段在式 中作为基准分数, BIAS 是评价预报结果"平衡 性"的手段,其数值越接近于 1 越好,因此在 式中 BIAS 偏离 1 越多则会对基准分数造成越多 衰减,同样地,如果预报结果精细度越低,则 FID 数值越大,会对 TS 造成较多衰减。

#### 4 试验结果

### 4.1 综合评估结果

图 4 给出四组试验在测试集时段内(2022 年 7-9 月)的 0-3h 总体客观评分表现,在 TS 评 分方面(图 4a), 三组深度学习试验在各检验 阈值上均优于 Sprog,对比 PhyDNetGAN 和 PhyDNet 发现直接增加 GAN 之后 25 和 35dBZ 的 TS 评分略有降低,但对于 45dBZ 阈值增加 GAN 后 TS 评分提高约 13%,这说明通过 GAN 改善预测精度的同时还能优化强回波预测技巧, 采用了频域对抗的 PhyDNetSGAN 在各阈值均 取得了最优的 TS 表现; FID 直观体现出各组试 验中存在的"模糊"问题(图 4c),可以看到 Sprog和PhyDNet受影响较大,增加生成对抗网 络的两组试验可得到改善;较高阈值回波场明 显低于 1(图 4b),相较之下,PhyDNetGAN 和 PhyDNetSGAN 均呈现出较好的纠偏能力。 总的来看,PhyDNetSGAN在TS、Bias、FID 三 个指标上均取得了较好的表现,因此在最终的 综合评分上表现也明显优于其他三组试验(图 4d)。



Fig 4 Radar echo prediction evaluation for four sets of tests (a. TS, b. Bias, c. FID, d. Score)



图 5 四组试验雷达回波预测的时间序列评估(a-c. TS、d-f. Bias、g-i. Score、j. FID)

Fig. 5 Time series evaluation of four sets of experimental radar echo predictions (a-c. TS, d-f. Bias, g-i. Score,

j. FID)

在时间序列方面,各组试验的 TS 均随预报 时效明显降低(图 5),其中,线性外推 Sprog 下降速度快于其他三组深度学习试验,尤其对 于≥45dBZd 强回波阈值,Sprog 在接近 1h 的预 报时效内就几乎丧失 TS 技巧,相较之下,三组 深度学习试验的 TS 则能维持到近 2h,反映出 深度学习具备对强对流系统强度演变的刻画能 力,这一特点在 Bias、FID 和综合评分上也得 到了类似的体现。 值得注意的是,单就传统关注的 TS 评分而 言,增加生成对抗网络难以得到更好的评分表 现, PhyDNetSGAN 的整体评分仅略优于 PhyDNet,而 PhyDNetGAN 甚至在较低阈值回 波场的 TS 表现甚至明显低于 PhyDNet,体现在 时间序列上(图 5a)可以看到随着预报时效增 加 PhyDNet 评分优势愈发明显,但实际上深度 学习造成的"模糊"问题往往是随预报步长的 增加而愈发明显,因此会出现客观评分与预报 员 主 观体验相 悖的情况。相较之下, PhyDNetSGAN在本文新提出的综合评分中的表 现则优于 PhyDNet, 与预报员的主观体验更为一致。

#### 4.2 典型个例分析

系统性的评估结果表明增加生成对抗网络 可以明显改善 PhyDNet 的 FID 指标,其中 PhyDNet-SGAN 还能在此基础上进一步优化 TS 和 Bias 评分,尤其是对于≥45dBZ 的强回波, PhyDNetSGAN 较 Sprog、 PhyDNet 和 PhyDNetGAN分别提升 35%、123%和 18%。为 了更直观地呈现各组试验的表现,选取发生在 2022 年的 1 次典型强对流天气个例进行重点分 析。



图 6 7 月 20 日强对流天气实况: (a) 9:00-12:00 最大风速, (b) 9:00-12:00 累积降水, (c) 9:00-12:00 闪电分布, (d) 12:00-15:00 最大风速, (e) 12:00-15:00 累积降水, (f)12:00-15:00 闪电分布 Fig 6 July 20 Strong convection weather conditions: (a) 9:00-12:00 maximum wind speed, (b) 9:00-12:00 accumulated precipitation, (c) 9:00-12:00 lightning distribution, (d) 12:00-15:00 maximum wind speed, (e) 12:00-15:00 accumulated precipitation, (f) 12:00-15:00 lightning distribution

2022年7月20日,受高空槽、地面气旋、 低涡共同作用, 江苏省自北向南出现一次大范 围强对流天气过程。本次过程对江苏的影响分 为两个阶段,在中午 12:00 前,850hPa 低涡东 南侧暖式切变线给江苏淮北地区造成较强降水 影响(图 6b),并伴有雷电过程,随着低涡持 续东移,约中午12:00开始,低涡西南侧冷切附 近自北向南陆续出现 8-10 级雷暴大风(图 6df)。为了检验四种雷达临近预报方法对 12:00 开始陆续发生强对流大风过程的预报效果,选 取12:00起报时次进行重点分析。需要指出的是, 12:00、12:20 和 12:50 连云港、淮安和盐城响水 先后出现 EF2、EF1 和 EF3 级龙卷,但这 3 次龙 卷均未被自动站监测到,且当前的外推预报精 度尚不足以覆盖造成龙卷的小尺度回波,因此 不在本文的讨论。

图 7 第 1 行给出 7 月 20 日 12:00 起报的输入雷达回波序列,可以看出此时回波正处于快速非线性增强阶段,且对应测站尚未观测到 8 级以上的大风天气。图 7 第 2 行给出 3h 预报时效内间隔 30min 的雷达回波拼图实况,可以看到受低涡尾部冷空气影响,局地零散强回波逐渐发展成东北一西南走向的线状强回波带,并逐渐向东南方向移动。Sprog采用 11:54 和 12:00 两帧雷达回波场的风矢量差,并通过半拉格朗日外推方法线性外推,因此未能体现线状强回波的组织化演变(图 7 第 3 行),值得注意的是,由于 Sprog 仅用到相邻两帧的回波风矢量, 因此呈现出东北向移动,而实况强回波带在 12:00 后主要向东南方向移动,这凸显了传统基于线性假设的外推方法在强回波非线性演变过程中的局限性。

与 Sprog 相比, 三组深度学习试验均能更 好地描述线状强回波形成过程中的形态及移动 方向(图7第4-6行),此外,注意到PhyDNet 从 90min 开始呈现出比较明显的"模糊"问题, 体现为预测场≥20dBZ 回波面积明显大于观测 拼图,这一特征在 Bias 上可以得到较为清晰的 印证(图 8d): PhyDNet 对≥25dBZ 和≥ 35dBZ 量级回波预测的 Bias 明显偏高。与 PhyDNet 相比, 增加传统 GAN 的 PhyDNetGAN 能够修正≥25dBZ 和≥35dBZ 的预报 Bias,但 对≥45dBZ 强回波的预测表现不佳,这可能是 由于 PhyDNetGAN 中的空间鉴别器对高频强回 波的鉴别能力较弱,相较之下,PhyDNetSGAN 不仅有效改善的各个阈值预报结果的 Bias 表现, 还获得了最优的 TS 评分。在 FID 指标方面, Sprog 由于采用了尺度分离,因此 FID 随预报时 效持续增加。图 9 第一行给出 14:06 (即 2h 预 报时效左右)中尺度对流系统尾部雷达回波实 况和四组试验预测结果,该时间点南京和镇江 交界处局地出现 10 级雷暴大风, Sprog 由于不 具备对强回波演变的描述能力,因此未能有效 预报,相较之下三组深度学习试验均预测出位 于江苏西南部的强回波区,而 PhyDNetSGAN 在此基础上进一步准确预报出了回波的形态, 且高值区与雷暴大风发生站点的位置相匹配; 图 9 第二行给出 14:48 观测和预报的对比图,



图 7 2022 年 7 月 20 日强对流天气过程,第 1 行为模型输入,第 2 行为观测实况,第 3-6 行为当日 12:00 起报的 4 组试验预报结果。

Fig. 7 Strong convective weather process on July 20, 2022, row 1 is the model input, row 2 is the o bserved reality, and rows 3-6 are the results of four sets of experimental forecasts reported from 12:00 on that day.

该时刻盐城南部多站出现 10级雷暴大风,对比各组试验的强回波预报结果,同样可以看到 PhyDNetSGAN的预测强回波中心与雷暴大风位





Bias, g-i. Score, j. FID)

Fig. 8 Time series of TS, BIAS, FID and Score for each group of trials Forecasted from 12:00 on July 20, 2022 (a-c. TS, d-f. Bias, g-i. Score, j. FID)

5 结论和讨论 为了缓解深度学习雷达回波外推预报中普 遍存在的"模糊"问题,本文发展了一种有机 融合物理约束深度学习模型(PhyDNet)和频 域匹配生成对抗网络(SGAN)的雷达回波外 推预报技术,可以提供江苏及其上游地区未来 3h、水平分辨率 0.01°、时间分辨率 6min 的雷达回波预报结果,并从不同角度对新技术开展

了评估,得到如下结论: (1)与光流法 Sprog 相比,深度学习方法能更好地体现强回波的非



图 9 (a) 起报 126min 后 14:06 (31°N -33°N, 118°E-120°E) 雷达拼图叠加散点最大风速, (b-e) 四 组试验在对应区域和时间的预测图, (f) 起报 168min 后 14:48 左右 (32°N -34°N, 119°E -121°E) 雷 达拼图叠加散点最大风速(泰州和盐城交界处应该会有超过 25m/s 的风速), (g-j) 四组试验在对应 区域和时间的预测图

Fig. 9 (a) Maximum wind speed at 14:06 (31°N -33°N, 118°E -120°E) of the radar puzzle superimposed on the scattered points 126 min after the start, (b-e) predicted maps of the four tests in the corresponding area and time, (f) maximum wind speed at 14:48 (32°N -34°N, 119°E -121°E) of the radar puzzle superimposed on the scattered points around 168 min after the start (the border of Taizhou and Yancheng should have more than 25m/s wind speed), (g-j) prediction maps of four sets of tests in the corresponding areas and times

线性发展演变过程。(2)增加生成对抗网络的 PhyDNetGAN 和 PhyDNetSGAN 较其他两组试 验能够得到更精细且符合预报员主观认知的雷 达回波外推结果,缓解"模糊"问题。(3)新 提出的 PhyDNetSGAN 不仅能够改善预报精细 度,还能更好地捕获强回波的形态、位置和中 心强度,从而获得更优的预报技巧表现,延长 有效预报时长。(4)新提出的综合 TS、Bias 和 FID 的综合评分指标较 TS 能够更好地反应与 预报员主观体验相一致的临近预报检验效果。 本研究结果表明通过设计更具气象意义的生成 对抗网络不仅能够改善深度学习雷达回波外推

预报中的"模糊"问题,还能兼顾预报技巧, 这为业务强对流临近预警的深度研发提供了新 思路,未来研究中将尝试将文章提出的生成对 抗网络技术直接应用于强降水和阵风风速的预 报中。

### 参考文献(References)

程丛兰,陈明轩,王建捷,等.2013. 基于雷达外推 临近预报和中尺度数值预报融合技术的短时 定量降水预报试验[J]. 气象学报,71(3): 397-415. CHENG Conglan, CHEN Mingxuan, WANG Jianjie, et al. 2013. Short-term quantitative precipitation forecast experiments based on blending of nowcasting with numerical weather prediction[J]. Acta Meteorologica Sinica, 71(3): 397-415.

- 韩雷,郑永光,王洪庆,等. 2007. 基于数学形态学的三维风暴体自动识别方法研究[J]. 气象学报, 65(5): 805-814. Han Lei, Zheng Yongguang, Wang Hongqing, Lin Yinjing, et al. 2007. 3D
  STORM AUTOMATIC IDENTIFICATION BASED ONMATHEMATICAL MORPHOLOGY[J]. Acta Meteorologica Sinica, 65(5): 805-814.
- 俞小鼎, 周小刚, 王秀明. 2012. 雷暴与强对流临 近天气预报技术进展[J]. 气象学报, 70(3): 311-337. YU Xiaoding, ZHOU Xiaogang, WANG Xiuming. 2012. The advances in the nowcasting techniques on thunderstorms and severe convection[J]. Acta Meteorologica Sinica, 70(3): 311-337.
- 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 Yongguang, Zhou Kanghui, Sheng Jie, et al. 2015. Advances in techniques of monitoring, forecasting and warning of severe convective weather. J Appl Meteor Sci[J], 26(6): 641-657.
- 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 Kanghui, ZHENG Yongguang, HAN Lei, et al, 2021. Advances in Application of Machine Learning to Severe Convective Weather Monitoring and Forecasting. Meteorological Monthly[J], 47(3): 274-289.
- 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 Xiaoran, Zheng Yu, Wang Yaqiang, et al. 2023. A deep learning-based precipitation nowcast model and its application over East China. Acta Meteorologica Sinica[J], 81(2): 286-303.

- Ayzel G, Scheffer T, Heistermann M. 2020.
  RainNet v1. 0: a convolutional neural network for radar-based precipitation nowcasting[J].
  Geoscientific Model Development, 13(6): 2631-2644.
- Bowler N E H, Pierce C E, Seed A. 2004. Development of a precipitation nowcasting algorithm based upon optical flow techniques[J]. Journal of Hydrology, 288(1-2): 74-91.
- Bowler N, Pierce C, See A. 2007. STEPS: A probabilistic precipitation forecasting scheme which merges an extrapolation nowcast with downscaled NWP[J]. Q J R Meteor Soc, 132(620): 2127-2155.
- Chen Y, Li G, Jin C, et al. 2021. SSD-GAN: measuring the realness in the spatial and spectral domains[C]. Proceedings of the AAAI Conference on Artificial Intelligence. 35(2): 1105-1112.
- Germann U, Zawadzki I. 2002. Scale-dependence of the predictability of precipitation from continental radar images. Part I: Description of the methodology[J]. Monthly Weather Review, 130(12): 2859-2873.
- Haiden T, Kann A, Wittmann C, et al. 2010. The integrated nowcasting trough comprehensive analysis (INCA) system and its validation over the eastern Alpine region[J]. Wea Forecasting, 26,

166-183.

- Heusel M, Ramsauer H, Unterthiner T, et al. 2017.Gans trained by a two time-scale update rule converge to a local nash equilibrium[J].Advances in neural information processing systems, 30.
- Hu Y., L. Chen, Z. Wang, X. Pan, H. Li. 2022. Towards a more realistic and detailed deeplearning-based radar echo extrapolation method[J]. Remote sensing, 14(1): 24.
- Johnson J, MacKeen P, Witt A, et al. 1998. The storm cell identification and tracking algorithm: An enhanced WSR-88D algorithm[J]. Wea Forecasting, 13(2): 263-276.
- Pan X, Lu Y, Zhao K, Huang H, Wang M, Chen H. 2021. Improving nowcasting of convective development by incorporating polarimetric radar variables into a deep learning model[J]. Geophysical Research Letters, 48(21), e2021GL095302.
- Pulkkinen S, Nerini D, Pérez Hortal, et al. 2019. Pysteps: An open-source Python library for probabilistic precipitation nowcasting (v1.0) [J]. Geosci Model Dev, 12(10): 4185-4219.
- Ravuri, S., Lenc, K., Willson, M. et al. 2021. Skilful precipitation nowcasting using deep generative models of radar[J]. Nature, 597(7878): 672-677.
- Shi X, Chen Z, Wang H, et al. 2015. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[J]. Advances in neural information processing systems, 28.
- Seed A W. 2003. A dynamic and spatial scaling approach to advection forecasting[J]. J Appl Meteorol, 42(3): 381-388.
- Tian L, Li X, Ye Y, et al. 2019. A generative adversarial gated recurrent unit model for

precipitation nowcasting[J]. IEEE Geoscience and Remote Sensing Letters, 17(4), 601–605.

- Tuttle J, Foote G. 1990. Determination of the boundary layer airflow from a single Doppler radar[J]. Journal of Atmospheric and oceanic Technology, 7(2): 218-232.
- Tran Q K, Song S K. 2019. Computer vision in precipitation nowcasting: Applying image quality assessment metrics for training deep neural networks[J]. Atmosphere, 10(5), 244.
- Wang Y, Long M, Wang J, et al. 2017. Predrnn: Recurrent neural networks for predictive learning using spatiotemporal lstms[J]. Advances in neural information processing systems, 30.
- Wang Y, Gao Z, Long M, et al. 2018. Predrnn++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning[C]. International Conference on Machine Learning. PMLR, 5123-5132.
- Wang Y, Wu H, Zhang J, et al. Predrnn: 2022. A recurrent neural network for spatiotemporal predictive learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 45(2): 2208-2225.
- Zheng K, Liu Y, Zhang J, et al. 2022. GANargcPredNet v1.0: a generative adversarial model for radar echo extrapolation based on convolutional recurrent units[J]. Geosci Model Dev, 15(4): 1467-1475.

