

基于 MCGAN 模型的降水临近预报^①



刘蕊¹, 杜景林², 许梦¹

¹(南京信息工程大学 计算机学院, 南京 210044)

²(南京信息工程大学 人工智能学院, 南京 210044)

通信作者: 杜景林, E-mail: jldu@nuist.edu.cn

摘要: 在降水临近预报领域中, 现有基于深度学习的雷达回波外推方法存在一些缺点. 在图像质量方面, 预测图像模糊并缺乏小尺度细节, 在预测精度方面, 降水结果不够准确. 本文提出了一个多尺度生成对抗 (MCGAN) 模型, 该模型由多尺度卷积生成器和全卷积的判别器组成. 生成器部分采用编码器-解码器架构, 主要包含了多尺度卷积块和下采样门控单元. MCGAN 模型使用动态时空变异性损失函数在生成对抗网络 (GAN) 框架下训练, 以达到更精准和更清晰的回波强度和分布预测效果. 模型的性能在上海市公共雷达数据集上进行了验证, 与主流深度学习模型相比, 本文所提模型在图像质量评估中的 *MSE* 指标上下降了 11.15%, 在 *SSIM* 指标和 *PSNR* 指标上分别增加了 8.99%、2.95%; 在预测精度评估中, *CSI* 指标、*POD* 指标、*HSS* 指标上平均提高了 11.92%、15.89%、9.01%, *FAR* 指标平均降低了 14.81%. 此外, 本文通过消融实验证明了 MCGAN 模型每个部件的作用.

关键词: 深度学习; 雷达回波外推; 降水临近预报; 多尺度; 生成对抗网络

引用格式: 刘蕊, 杜景林, 许梦. 基于 MCGAN 模型的降水临近预报. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9673.html>

Precipitation Nowcasting Based on MCGAN Model

LIU Rui¹, DU Jing-Lin², XU Meng¹

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

²(School of Artificial Intelligence, Nanjing University of Information Science & Technology, Nanjing 210044, China)

Abstract: In the field of precipitation nowcasting, the existing radar echo extrapolation methods based on deep learning have some shortcomings. In terms of image quality, the prediction images are indistinct and deficient in small-scale details, while in terms of prediction accuracy, the precipitation results are not accurate enough. This study proposes a multi-scale generative adversarial (MCGAN) model, which consists of a multi-scale convolutional generator and a fully convolutional discriminator. The generator part adopts an encoder-decoder architecture, which mainly includes multi-scale convolutional blocks and downsampling gating units. Using the dynamic spatiotemporal variability loss function, the MCGAN model is trained under the generative adversarial network (GAN) framework to achieve more accurate and clearer predictions of echo intensity and distribution. Verified in the Shanghai public radar dataset, the performance of the model in this study decreases by 11.15% in the *MSE* index in image quality evaluation, and increases by 8.99% and 2.95% in the *SSIM* index and *PSNR* index compared with the mainstream deep learning models, respectively. In the evaluation of prediction accuracy, the *CSI*, *POD*, and *HSS* indexes increase by 11.92%, 15.89%, and 9.01% on average, and the *FAR* index decreases by 14.81% on average. In addition, the role of each component of the MCGAN model is demonstrated by ablation experiments.

Key words: deep learning; radar echo extrapolation; precipitation nowcasting; multi-scale; generative adversarial network (GAN)

^① 基金项目: 国家自然科学基金 (41575155)

收稿时间: 2024-04-22; 修改时间: 2024-05-20; 采用时间: 2024-05-31; csa 在线出版时间: 2024-09-24

降水临近预报通常是指未来短时间内的详细降雨预报,用于预测特定区域的降水强度和位置等,这种预报以分钟级、千米级或者街道级的频率展现^[1].准确的预报可以为公众提供及时的天气通知,对保护人民的生命财产安全起着重大作用.

在气象雷达中,雷达回波是指天气雷达通过发射电磁波探测降水粒子返回雷达并形成的回波图像,气象预报员则可以根据回波图像分析降水的位置、强度和分布.随着气象观测技术的发展,多普勒天气雷达以其探测范围广,时间间隔短等优势逐渐成为测量云、降水和强对流天气主要工具^[2,3].雷达回波外推则是利用过去一段时间探测到的雷达回波数据预测未来雷达回波强度变化,从而直观的呈现未来天气状况,已经发展为主要的降水临近预报方式.

雷达回波外推方法可分为两类:传统的雷达回波外推方法、深度学习的雷达回波外推方法.传统的雷达回波外推方法是比较基础的预报手段,通常有单质心法^[4,5]、互相关法^[6,7]和光流法^[8,9]等.单质心法主要使用记忆方式跟踪三维雷达,适用于强雷暴单体,当面临局部对流变化快的天气情况时预测效果较差^[10].互相关法通过计算相邻时空内降水回波的相关性推断回波运动信息,在强对流天气下会逐渐失去跟踪有效性.光流法通过计算相邻帧之间对应像素点的瞬时运动速度生成下一帧的预测,它依赖于线性外推原理且计算成本较高,因此难以满足实时预报的需求.

近年来,深度学习技术在时间序列预测方面做出了巨大的贡献,它把短程降水预报视为时间序列预测问题,利用历史时间序列样本预测未来时空变量^[11].基于卷积的递归神经网络(convolutional recurrent network, ConvRNN)和卷积神经网络(convolutional neural network, CNN)在降水临近预报领域应用的最多. Shi 等人^[12]提出 ConvLSTM 模型,使用卷积结构捕获时间和空间信息.之后, Shi 等人^[13]又改进了 ConvLSTM 模型中的卷积递归结构,提出了具有可学习卷积的 TrajGRU 模型. Wang 等人^[14]基于 ConvLSTM 模型提出了 PredRNN 模型,使用之字形的信息流结构扩展了神经网络的感受野. Wang 等人^[15]又提出 MIM 模型,使用两个对称的 MIM-N 和 MIM-S 替换了遗忘门,并将两者的差分信息作为输入以便学习时空运动的非平稳状态.以上模型均建立在 ConvRNN 上,这种模型都存在两个明显的问题.首先是回波特征衰减,这类模型使用固定的尺

度提取时空特征只能实现单次的数据预测,不能以并行的方式实现训练和预测,从而忽略了时空运动的复杂性^[16].随着预测提前期的增加,不同时刻固定尺度的存储单元之间的误差逐渐累积,使得最终外推结果慢慢低于真实值.其次是预测模糊问题,由于卷积算子对平移不变性的归纳偏倚使得模型难以捕捉降水场的时空特征而逐渐产生了偏差^[17,18].这种空间变异性表示的缺失不仅使得预测图像变得模糊,还会导致下游应用的误差扩大.

许多研究者试图使用基于端到端的 CNN 网络解决 ConRNN 中的信息丢失问题. Trebing 等人^[19]提出了 SmaAt-UNet 模型,利用可分离卷积释放算力,并在 U-Net 模型中增加了注意力机制. Gao 等人^[20]提出 SimVP 模型,使用 Inception 模块和群卷积捕获时空信息.与使用堆叠方式的 ConvRNN 相比,端到端的卷积时空预测模型能够更好地预防信息流传过程中的回波衰减,并且实现了多步预测.然而,基于 CNN 的模型更偏向于空间维度的建模,无法对时间特征精准建模,会丢失不同尺度的时间特征信息.

面对预测模糊,目前常用 GAN^[21]网络来缓解. Jing 等人^[22]提出一种 AENN 模型,该模型是基于 ConvLSTM 和卷积神经网络的生成对抗性外推模型. Tian 等人^[17]提出了 GA-ConvGRU 模型,该模型将 ConvGRU 作为生成器进行优化,但容易受到训练不稳定的影响. Gong 等人^[23]提出 AGAN 网络,试图增添雷达回波局部空间的变异性表示能力,但该模型没有考虑到预测结果会在训练过程中产生动态变化,只使用固定的权重让模型变得难以收敛.与基于 ConvRNN 方法的模型相比,使用 ConvRNN 作为生成器 CNN 作为判别器的模型经过训练,可以生成更好的预测图像.然而, GAN 网络采用对抗性损失进行训练,无法衡量真实图像和生成图像之间的差距.

综上,现有的使用深度学习方式计算的时空相关性只能从固定的局部空间中学习相邻帧中有限的回波特征,从而导致预测图像失去时空可变性.而 GAN 网络存在严重的梯度消失问题,模型训练困难.因此,本文基于 CNN 和 GAN 提出了一种多尺度生成对抗模型(MCGAN).本文的主要工作如下.

(1) 提出了一种基于编码器-解码器架构的多尺度卷积时空预测模型来构建生成器,并利用设计的多尺度卷积块完成了对多个时间和空间尺度的统一建模.

另外, 本文设计了一个下采样门控单元以避免在下采样过程中产生的上下文信息丢失和重影问题。

(2) 本文提出了一种动态时空变异性损失函数. 首先分析每个回波帧的数据分布, 为每个回波区间分配权重, 然后将权重赋予沿时空维度计算的变异系数, 并将其作为正则化项. 动态时空变异性损失在训练过程中实现了正则化, 具有表示时空变异性的特征。

(3) 利用上海市公共雷达数据集验证了本文所提模型的有效性. 实验结果表明, 与 ConvLSTM 模型、TrajGRU 模型、PredRNN 模型和 MIM 模型相比, MCGAN 模型有用更准确、更清晰的预测效果。

1 数据来源

本文使用的数据集时来自 Chen 等人^[24]提供的上海市公共雷达回波数据集. 该数据集由双偏振天气监视雷达—1988 多普勒雷达 (WSR-88D) 收集的复合反射率数据组成, 覆盖了上海浦东地区. 该数据集的时间范围是自 2015 年 10 月—2018 年 7 月, 时间间隔是 6 min, 使用体积扫描的方式生成了 170 000 张经过线性转换的雷达回波灰度图像, 存储为 PNG 格式, 图像大小为 501×501. 为方便训练, 首先要过滤掉非连续的帧, 接着使用滑动窗口生成了 76 779 个长度为 20 的雷达回波图像样本, 训练集包含 53 745 个序列样本, 测试集包含 23 034 个序列样本. 每组样本的前 10 帧作为输入帧, 时间间隔为 6 min, 后 10 帧作为预测帧, 时间间隔为 12 min, 即使用前 1 h 的历史回波图预测未来 2 h 的预测回波

图. 另外, 本文将数据集中每帧的基本反射率阈值都控制在 0–70 dBZ 之间。

2 分析方法

2.1 生成对抗网络 (GAN)

GAN^[21]由 Goodfellow 等人提出, 其目的是使生成目标尽可能地近似于真实目标的分布. 它由生成器和判别器组成, 两者皆是深度神经网络. 生成器学习输入变量的潜在信息而努力生成真实的数据分布, 判别器则是努力判断生成目标的真实性, 因此两者是互相对抗的关系. GAN 通过玩最大最小值游戏实现目标的优化, 表示为:

$$\min_G \max_D V(D, G) = E_{X \sim p_{\text{data}}(X)} [\log(D(X))] + E_{Z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

其中, G 表示生成器, D 表示判别器. $p_{\text{data}}(X)$ 是真实目标 X 的分布, $p_z(z)$ 是输入噪声的先验分布. 当在输入数据充分的情况下, 生成器和判别器以实现纳什均衡为目的不断交替训练. 在降水临近预报领域, 生成器输入的不是随机噪声, 而是时间序列雷达图像。

2.2 MCGAN 模型

本文提出的 MCGAN 模型架构如图 1 所示. 历史雷达回波图像序列进入生成器生成预测图像, 再与对应时间点的地面观测图像组成样本对, 输入判别器进行判断. 生成器和判别器协同工作, 最终通过对抗性损失来优化整个网络。

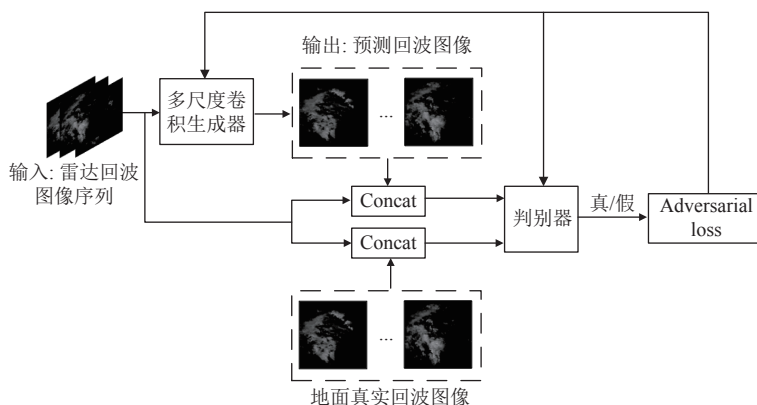


图 1 MCGAN 模型架构

2.2.1 多尺度卷积生成器

本文的生成器结构如图 2 所示, 采用了对称式的编码器-解码器架构, 搭建成端到端的时空与预测模型,

利用多尺度卷积块增加模型的感受野, 提取不同时间尺度和空间尺度下的时空运动特征, 实现多尺度的时空信息建模。

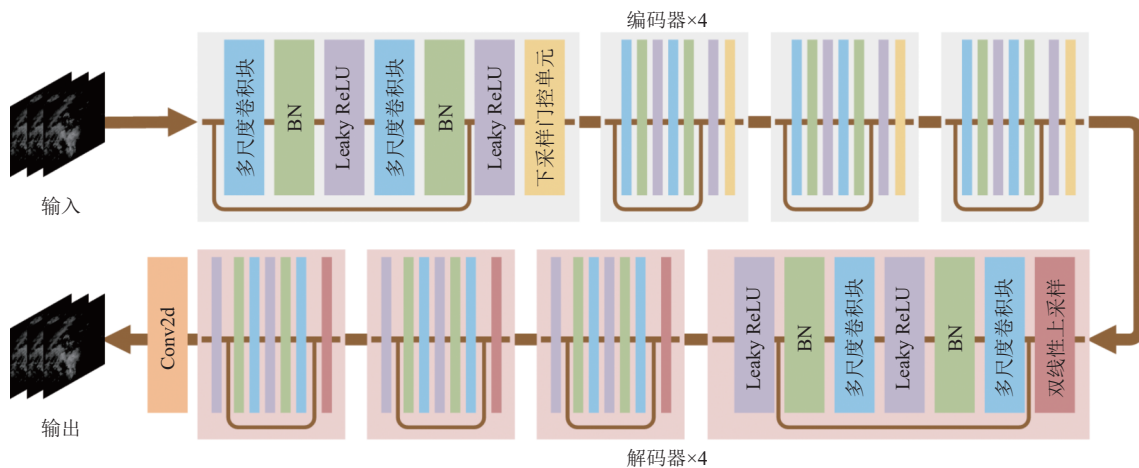


图2 多尺度卷积生成器结构

编码器由4个编码块组成,各编码块都有两个多尺度卷积块和一个下采样门控单元.当输入特征经过每个编码块时,其时空分辨率会缩小至原来的一半,通道数增加到原来的一倍.解码器由4个解码块组成,各解码块有两个多尺度卷积块和一个双线性上采样层.输入数据经过每个解码块时,其时空分辨率会以两倍的方式恢复.另外,编码器和解码器部分还使用了残差的方式来提高模型性能,每个卷积核都使用了批量归一化和斜率为0.2的泄露整流线性单元.生成器的最后一层只使用了普通的二维卷积转换通道数.

多尺度卷积块:多尺度卷积块用于捕捉输入特征中的多尺度时空运动变化,其结构如图3所示.本文构建了拥有3个尺度的空间单元和时间单元,使用不

同大小的卷积核和不同的位置分布来捕捉输入特征的时空依赖性.在多尺度空间特征提取单元中,卷积核的大小为 (1×1) 、 (3×3) 、 (5×5) ,在多尺度时间特征提取单元中,卷积核的大小为 (3×3) 、 (5×5) 、 (7×7) .由于二维卷积最多能处理四维数据,因此需要将拥有5个维度的输入数据([批量大小,序列长度,通道数,高,宽])转换成4个维度([批量大小 \times 序列长度,通道数,高,宽]),第1维度是[批量大小 \times 序列长度].在经过多尺度空间特征提取单元获取空间特征 S 后,将 S 转换成[批量大小,序列长度 \times 通道数,高,宽]以便在多尺度时间特征提取单元中捕获时间特征 T ,然后再转换回[批量大小 \times 序列长度,通道数,高,宽],并沿通道维度拼接获得时空特征 ST .

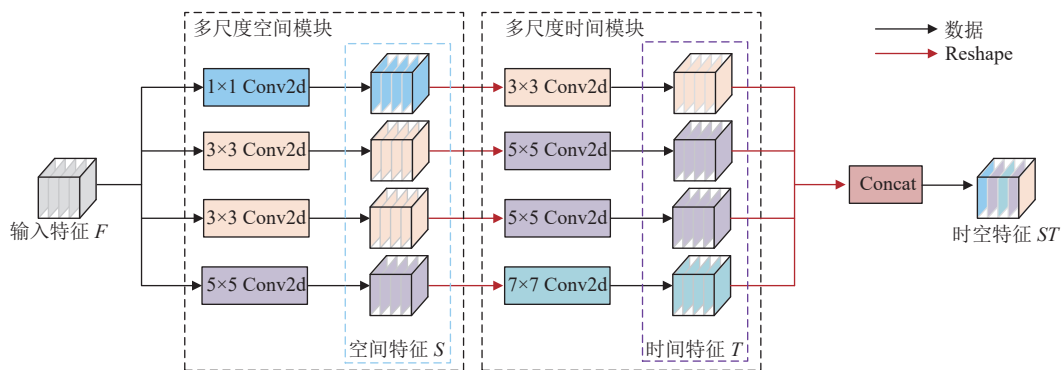


图3 多尺度卷积块

下采样门控单元:为了获取更多的特征信息以及降低计算复杂度,许多采用编码器-解码器架构的模型使用下采样的方式处理高维信息,又为补充下采样造

成的信息丢失引入了跳跃链接,而解码器重建的是未来时刻的图像,因此采用跳跃连接这种简单的映射会因时空位置的偏移而产生重影效应.为了解决在下采

样过程中造成的上下文信息丢失和重影问题, 本文设计了一个下采样门控单元, 其结构如图 4 所示. 使用门控机制让最大值下采样和平均值下采样进行信息交互, 省略了跳跃链接从而避免引入冗余信息. 其计算过程如下.

$$ST' = \sigma(|M_{ST} - A_{ST}|) \quad (2)$$

$$F' = ST' \odot M_{ST} + (1 - ST') \odot A_{ST} \quad (3)$$

其中, M_{ST} 和 A_{ST} 分别表示经过最大池化和平均池化后的特征, ST' 表示 M_{ST} 和 A_{ST} 之差的绝对值经过 Sigmoid 函数, ST' 中所有之的范围被控制在 $[0.5, 1]$ 之间, F' 表示自适应学习的特征.




图 4 下采样门控单元

2.2.2 判别器

判别器的结构如图 5 所示. 本文的判别器是一个全卷积的网络, 可以减少模型参数量, 降低过拟合的风险. 输入图像依次经过 6 层卷积层, 然后使用 Sigmoid 函数生成最终表示来自真实图像的概率, 因此, 判别器可以看作一个二元分类器. 判别器中各层的参数设置如表 1 所示.

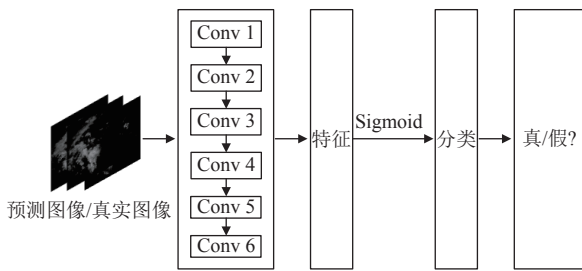


图 5 判别器结构

表 1 判别器的参数设置

名称	卷积核	步长	填充	输入/输出通道数
Conv 1	3×3	2×2	1×1	1/32
Conv 2	3×3	2×2	1×1	32/64
Conv 3	3×3	2×2	1×1	64/128
Conv 4	3×3	2×2	1×1	128/256
Conv 5	3×3	2×2	1×1	256/512
Conv 6	3×3	1×1	0×0	512/1

2.3 动态时空变异性损失函数

GAN 使用二元交叉熵函数作为损失函数, 如式 (1) 所示, 但该函数存在梯度消失问题. 当预测值趋近于 1 时, $\log(D(X))$ 会趋近于 1, 而当预测值趋近于 0 时, $\log(1 - D(G(z)))$ 则会趋近于 0, 那么损失函数的梯度就接近于 0. 这种情况尤其在使用 Sigmoid 激活函数后更为严重. 为解决上述问题, 本文使用动态时空变异性损失函数来训练模型, 该函数引入了一个额外的正则化项, 即变异系数. 变异系数在应用统计学中的定义是观测样本的标准差除以平均值. 该指标多应用于气候科学和水文领域中来表述不同地区和降水场的降雨量变化^[25], Gong 等人^[23]首次将其作为正则化项应用于短临预报领域.

本文利用上海市雷达回波数据集, 分析了雷达回波反射率值的分布情况. 从具有强回波值的输入样本中随机选取 6 组样本作为数值统计, 每组样本含有 20 帧连续的雷达回波图像. 将划分阈值设置为 30 dBZ 和 40 dBZ, 每个范围的阈值占比如图 6 所示.




图 6 多个样本中每个阈值范围的百分比

由于较大比重的低回波样本对模型预测强回波样本会产生很大干扰, 使得模型的模糊问题越来越严重, 因此, 需要一个合理的动态分配权重的方案. 本文使用具有动态权重的变异系数来表示不同强度的回波值的时空变异性. 动态权重按照式 (4) 计算, 如式 (5) 所示, 标准差和平均值沿时间维度和空间维度计算. 判别器和生成器的损失函数分别如式 (6) 和式 (7) 所示.

$$W_{t,h,w} = \begin{cases} 1, & 0 \leq R_{t,h,w} < 15 \text{ dBZ} \\ 2, & 15 \text{ dBZ} \leq R_{t,h,w} < 25 \text{ dBZ} \\ 5, & 25 \text{ dBZ} \leq R_{t,h,w} < 35 \text{ dBZ} \\ 10, & 35 \text{ dBZ} \leq R_{t,h,w} < 45 \text{ dBZ} \\ 20, & 45 \text{ dBZ} \leq R_{t,h,w} < 55 \text{ dBZ} \\ 30, & 55 \text{ dBZ} \leq R_{t,h,w} \leq 70 \text{ dBZ} \end{cases} \quad (4)$$

$$DySC_v(X_t) = \frac{\sigma_{t,h,w}(X_t)}{mean_{t,h,w}(X_t)} \times W_{t,h,w} \quad (5)$$

$$\mathcal{L}_D = -\frac{1}{N} \sum_{t=1}^N [\log(D(X_t)) + \log(1 - D(\hat{X}_t))] \quad (6)$$

$$\mathcal{L}_G = -\frac{1}{N} \sum_{t=1}^N \log(1 - D(\hat{X}_t)) + \lambda [DySC_v(X_t) - DySC_v(\hat{X}_t)] \quad (7)$$

其中, $R_{t,h,w}$ 表示坐标 (t, h, w) 处的雷达回波反射率值, $W_{t,h,w}$ 表示坐标处的权重. X_t 和 \hat{X}_t 分别为第 t 时刻观测雷达回波图像和预测雷达图像, $mean$ 表示在坐标轴 (t, h, w) 处图像的平均值, σ 是其标准差.

3 实验和结果

3.1 实验细节

在 MCGAN 网络的训练中, 批量大小设置为 10, 总迭代数为 500 轮, 生成器的学习率设置为 1×10^{-4} , 判别器的学习率设置为 5×10^{-5} , 采用多步方案设置, 将学习率在第 50 轮、100 轮、200 轮和 300 轮迭代时减半. 使用式 (7) 中的损失函数训练生成器. 其中 $\lambda = 5 \times 10^{-3}$. 生成器和判别器使用 Adam 优化器进行训练, 其中 $\beta_1 = 0.9$, $\beta_2 = 0.99$. 本文所做实验均在 PyTorch 框架下实现, 并使用 NVIDIA GeForce RTX 3090 Ti 运行训练.

3.2 评估指标

从两个方面来评估所提模型的性能, 分别是图像质量评估和预测精度评估. 首先, 在图像质量评估中采用了 3 种指标: 均方误差 (mean squared error, MSE)、结构相似性 (structural similarity index, $SSIM$) 和峰值信噪比 (peak signal-to-noise ratio, $PSNR$).

MSE 衡量了预测结果与其真实结果的平均平方方差. MSE 的值越小, 表示模型的预测效果越好. 计算方式如式 (8), X 表示观测雷达回波图像, \hat{X} 表示预测雷达回波图像, H 是图像的高度, W 是图像的宽度.

$$MSE(X, \hat{X}) = \frac{\sum_i^H \sum_j^W (X_{i,j} - \hat{X}_{i,j})^2}{HW} \quad (8)$$

$SSIM$ 通过比较两个图像的亮度、对比度和结构来计算两幅图像的相似性, 取值范围是 $[-1, 1]$, $SSIM$ 越接近 1, 表示两幅图像越相似, 那么图像质量就越高. 计算方法如式 (9), 其中 μ 代表平均值, σ 表示协方差, c_1 和 c_2 是两个常量.

$$SSIM(X, \hat{X}) = \frac{(2\mu_X\mu_{\hat{X}} + c_1)(2\sigma_{X\hat{X}} + c_1)}{(\mu_X^2 + \mu_{\hat{X}}^2 + c_1)(\sigma_X^2 + \sigma_{\hat{X}}^2 + c_2)} \quad (9)$$

$PSNR$ 比较了原始图像和经过处理的图像之间的信噪比, 以分贝 (dB) 为单位, 其值越大表示图像质量越高. 计算方法如式 (10), MAX_X^2 表示图像中最大的像素值.

$$PSNR = 10 \log_{10} \left(\frac{MAX_X^2}{MSE} \right) \quad (10)$$

另外, 在预测精度评估中, 本文采用了 4 种在气象领域常用的降水临近预报指标: 检测概率 (probability of detection, POD)、误报率 (false alarm rate, FAR)、关键成功指数 (critical success index, CSI) 和海德克技能得分 (Heidke skill score, HSS). 为了更全面地评估模型性能, 本文设置了多个不同的评估阈值, 分别为 25 dBZ、35 dBZ 和 45 dBZ. 用于计算评估指标的混淆矩阵如表 2 所示.

表 2 某阈值下的混淆矩阵

类型	预测为正	预测为负
正样本	TP	FN
负样本	FP	TN

根据表 2, 可以使用式 (11)–(14) 得到 POD 、 FAR 、 CSI 和 HSS :

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

$$FAR = \frac{FP}{FP + TP} \quad (12)$$

$$CSI = \frac{TP}{TP + FP + FN} \quad (13)$$

$$HSS = \frac{2 \times (TP \times TN - FN \times FP)}{(TP + FN)(FN + TN) + (TP + FP)(FP + TN)} \quad (14)$$

3.3 实验结果

为了分析 MCGAN 在雷达回波外推中的优势, 本文衡量了 25 dBZ、35 dBZ、45 dBZ 阈值下的预测效果, 并且选取了 4 个主流模型作为比较模型, 分别是 ConvLSTM、PredRNN、TrajGRU 和 MIM. 在实验中, 利用前 10 帧时间间隔为 6 min 的历史雷达回波图像预测后 10 帧时间间隔为 12 min 的未来雷达回波图像, 即预测提前期为 2 h.

首先, 在图像质量评价指标上进行了评估, 结果如表 3 所示, 使用粗体显示最佳结果.

从表 3 中可以看出, MCGAN 模型在所有指标中

都取得了最好的结果. 在图像质量方面, MCGAN 模型相比排名第 2 的 MIM 模型在 *MSE* 指标上下降了 11.15%, 在 *SSIM* 指标上增加了 8.99%, 在 *PSNR* 指标上增加了 2.95%. 很显然, 这代表 MCGAN 模型能够生成更加清晰的图像. 此外, 为了更清楚地观察 MCGAN 模型在每个时间节点的性能, 本文绘制了 *MSE*、*SSIM* 和 *PSNR* 指标的折线图, 如图 7 所示, 展示了测试集上 5 种模型每帧平均评估值. 可以得出, MCGAN 模型在不同时间步下, 预测图像的清晰度明显优于其他模型.

为了对算法的预测精度性能进行全面评估, 本文还给出了不同降雨量对应的多个阈值的预测精度评估分数. 测试结果如表 4 所示, 使用粗体显示最佳结果. 从重要的 *CSI* 和 *HSS* 得分来看, MCGAN 与其他模型

相比拥有更加准确的与预测性能. MCGAN 模型在所有预测精度指标上都取得了最好的临近预报分数, 尤其在强回波阈值上有明显改善. 比如, 在 45 dBZ 阈值下, MCGAN 模型的 *CSI* 值比 MIM 模型增加 25.42%, 比 PredRNN 模型增加 34.55%, *HSS* 值也分别增加了 12.59%、22.58%. 很明显, MCGAN 模型即使在强降雨中也具有更好的预测精度.

表 3 雷达回波预测的图像质量比较

模型	<i>MSE</i>	<i>SSIM</i>	<i>PSNR</i> (dB)
ConvLSTM	51.723	0.514	28.411
TrajGRU	43.354	0.675	29.013
PredRNN	41.412	0.771	29.551
MIM	40.745	0.801	29.853
MCGAN	36.203	0.873	30.733




图 7 测试数据集上 *MSE* 值、*SSIM* 值、*PSNR* 值的逐帧比较

表 4 不同模型在 25 dBZ、35 dBZ、45 dBZ 反射率阈值下 2 h 外推检验结果

反射率阈值	模型	<i>CSI</i>	<i>POD</i>	<i>FAR</i>	<i>HSS</i>
$\tau = 25$ dBZ	ConvLSTM	0.393	0.407	0.486	0.301
	TrajGRU	0.405	0.418	0.421	0.355
	PredRNN	0.417	0.451	0.407	0.387
	MIM	0.426	0.428	0.330	0.407
	MCGAN	0.451	0.434	0.292	0.423
$\tau = 35$ dBZ	ConvLSTM	0.101	0.178	0.632	0.082
	TrajGRU	0.127	0.191	0.608	0.089
	PredRNN	0.232	0.213	0.572	0.130
	MIM	0.236	0.234	0.551	0.156
	MCGAN	0.274	0.257	0.485	0.187
$\tau = 45$ dBZ	ConvLSTM	0.053	0.094	0.773	0.043
	TrajGRU	0.087	0.102	0.758	0.075
	PredRNN	0.110	0.103	0.727	0.124
	MIM	0.118	0.112	0.707	0.135
	MCGAN	0.148	0.205	0.576	0.152

图 8 进一步显示了 2 h 提前期下测试数据集在不同指标下的平均评估分数. 可以看出 *CSI* 和 *HSS* 得分具有相似的趋势, 并且都随着预测提前期的增加而下降. 从评估指标来看, 不管是不同的提前期还是不同的

降雨强度, MCGAN 模型总能优于基线模型, 而基线模型的临近预报性能随着提前期的增加而下降得更快. 为了方便观察 MCGAN 模型与其他模型对雷达回波强度和分布的预测效果, 本文选择了两组降雨示例作为展示. 图 9 是一次对流降雨的生消过程, 对流降雨具有局部性, 降雨强度高, 分布不均匀的特性, 使得预测任务非常艰巨. 图 9 通过对比 5 种模型未来 2 h 的对流降雨结果, 展现了 MCGAN 模型优越的性能, 该模型预测效果最接近原始的雷达回波图像. ConvLSTM 模型和 TrajGRU 模型在超过 1 h 提前期的情况下, 预测效果衰减剧烈, 并且在总体回波区域上出现严重的预测模糊问题, 无法对强回波做到准确预测. PredRNN 模型和 MIM 模型虽然在预测提前期上优于以上两个模型, 但是对强回波的预测能力也比较弱, 只能预测回波的整体轮廓, 对局部的回波细节预测仍然不够准确. 然而, MCGAN 却能达到更高的预测效果, 随着时间的增加, 比较模型都逐渐失去了正确的预测轨迹, 而 MCGAN 却保留了较多的回波信息.

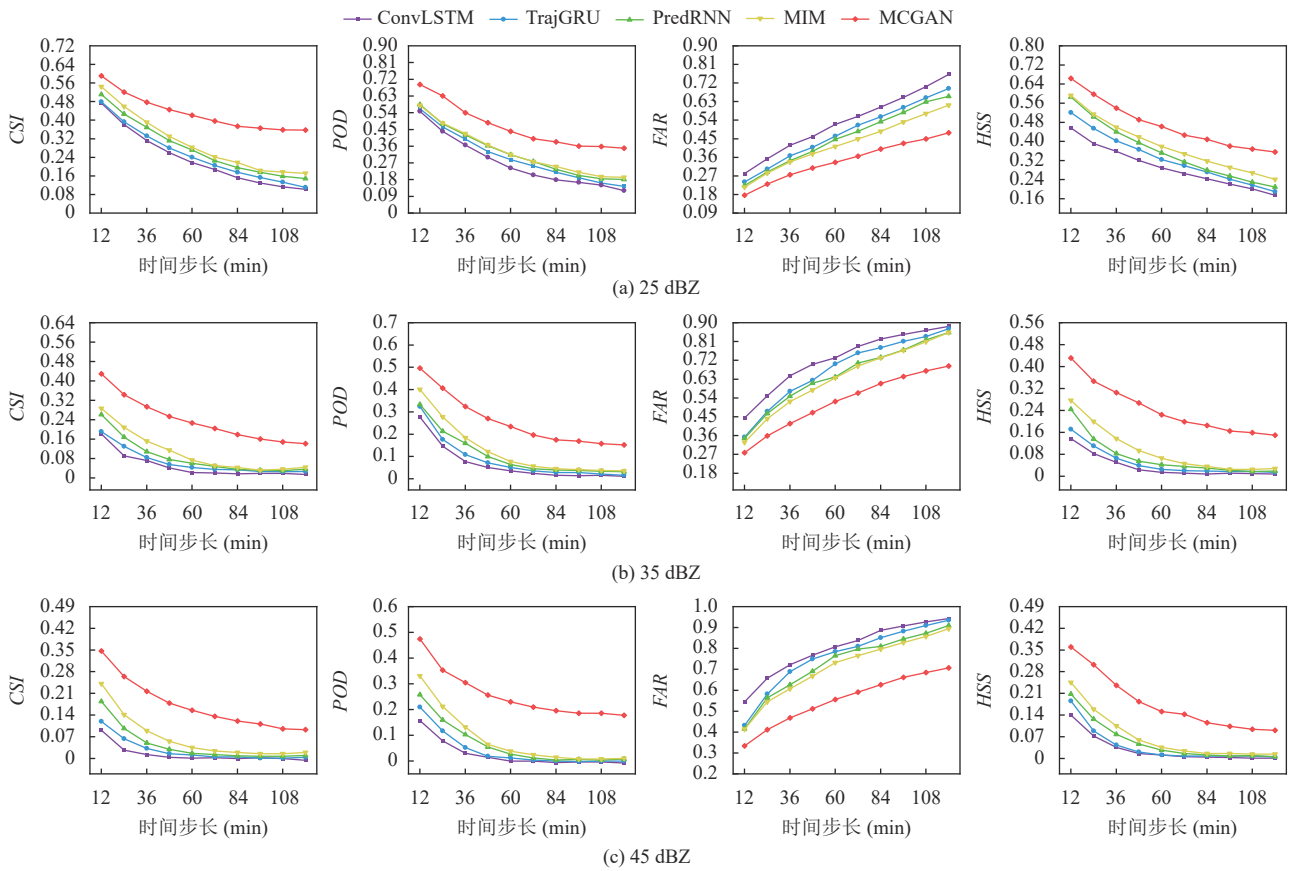


图8 不同模型在 25 dBZ、35 dBZ、45 dBZ 基本反射率阈值下逐帧评估比较

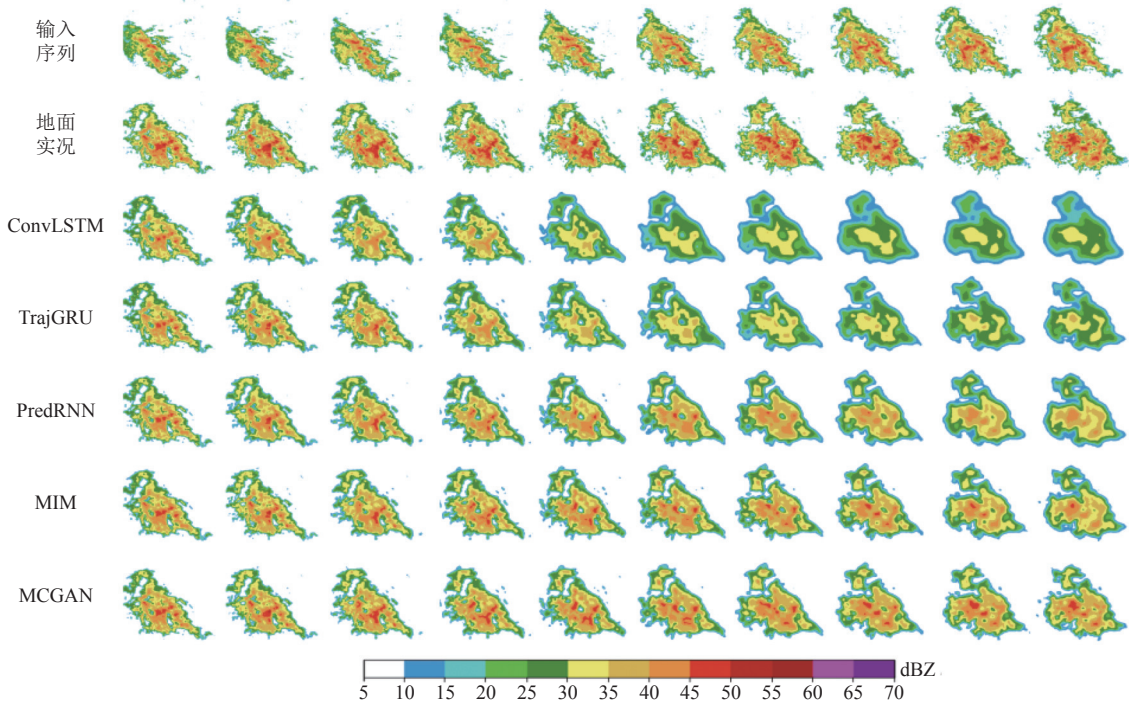


图9 对流降水情景下模型预测结果的可视化示例

与变化迅速的对流降水相比,稳定的降水结构通常是连续的,降水强度较小,但覆盖范围相对广阔.图10显示了在稳定降水结构中MCGAN模型与其他模型之间的比较.ConvLSTM模型和TrajGRU模型只能做到

粗略预测降水范围.在视觉上产生模糊的效果.PredRNN模型和MIM模型在预测局部雷达回波强度方面不太敏感.总体来说,MCGAN在稳定降水场中拥有更加准确、全面、清楚的整体和局部回波状态.

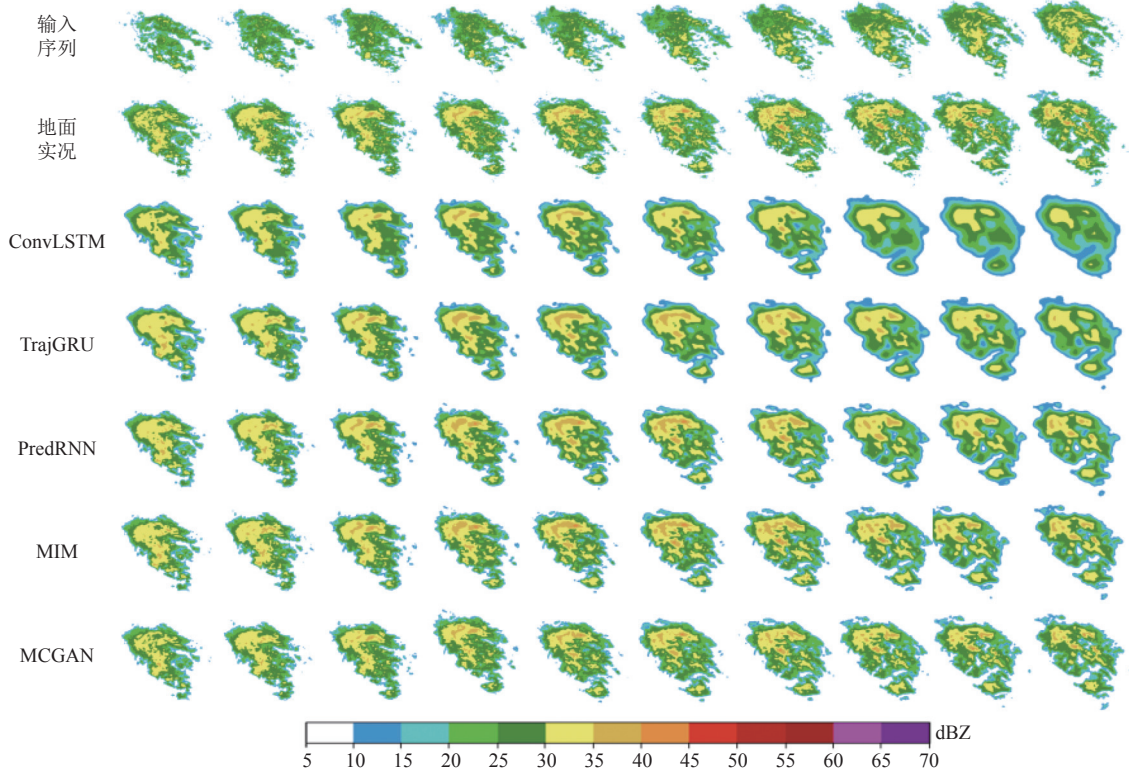


图10 稳定情景下模型预测结果的可视化示例

3.4 消融实验

为了验证MCGAN模型各个模块对最终预测效果的作用,进行了消融实验,表5显示了模型的定量分析结果.从表5中可以看出,完整的MCGAN模型拥有最强的拟合雷达回波运动变化的能力.在图像质量评估指标上,MSE的得分低于其余3种情况下的模型,这表明MCGAN模型的预测图像更接近真实图像,相应的像素差异较小.基于SSIM和PSNR的指标得分更高,那么预测图像在亮度、对比度和结构上也趋于接近真实图像.当模型中去掉多尺度卷积块使用单一的结构时,会造成模型无法获得多个时间尺度和空间尺度的

运动状态,只能传递固定尺度的时空特征,从而增加了模型陷入梯度消失和错误累加的风险.当模型中去掉下采样门控单元采用传统的跳跃连接的方式时,这种直接映射的方式使得模型丢失了一些上下文特征,从而产生重影问题,使得预测图像的清晰度和精确度下降.当模型在训练过程中不使用动态时空变异性损失函数时,MCGAN模型得到更低的CSI值和HSS值,以及更高的MSE值;SSIM值和PSNR值也有所下降,并且比缺失其他模块的模型得到预测效果更差.这表明本文使用的损失函数可以通过拟合预测图像和观测图像之间时空变异性差距来增强预测效果.

表5 消融实验结果

模型情况	CSI				HSS				MSE	SSIM	PSNR (dB)
	25 dBZ	35 dBZ	45 dBZ	Avg.	25 dBZ	35 dBZ	45 dBZ	Avg.			
MCGAN无多尺度卷积块	0.566	0.352	0.127	0.348	0.558	0.435	0.158	0.384	38.874	0.855	30.421
MCGAN无下采样门控单元	0.542	0.348	0.114	0.335	0.547	0.401	0.136	0.361	38.215	0.841	30.257
MCGAN无正则化项	0.536	0.327	0.109	0.324	0.532	0.398	0.117	0.349	39.532	0.832	30.032
MCGAN	0.571	0.384	0.148	0.368	0.573	0.465	0.187	0.408	36.203	0.873	30.733

4 结论与展望

本文基于对雷达回波外推算法的研究提出了一个MCGAN模型。由于主流的深度学习模型只能提取和传输固定尺度的时空特征,使得模型对资料的利用率不足,因此MCGAN模型根据时空运动的复杂性特征构建了多个尺度的空间卷积块和时间卷积块来增强时空预测模型的建模能力。另外,针对许多采用编码器-解码器架构的模型使用跳跃连接而造成的重影问题,MCGAN模型设计了一种下采样门控机制,从而减少信息丢失。最后,为了解决深度学习模型在预测过程中因丢失空间变异性而产生的模糊问题,本文将MCGAN模型在GAN网络框架下进行训练,并使用动态时空变异系数作为正则化项设计了一个新的损失函数。

以上方法均在实验中进行了证明,MCGAN模型无论是在图像质量评估(MSE、SSIM、PSNR)方面还是在预测精度评估(CSI、POD、FAR、HSS)方面都优于主流的深度学习方法。消融实验同时也证明了各个模块对总体模型的影响。虽然本文提出的模型拥有更高的预测精度和更多的回波细节,但是仅使用雷达回波图像数据作为外推的主要目标具有一定的局限性。未来,可以通过引入环境场信息和卫星产品来增强外推模型的可靠性,并进一步增加外推的提前期。

参考文献

- 1 Gneiting T, Raftery AE. Weather forecasting with ensemble methods. *Science*, 2005, 310(2746): 248–249.
- 2 Ochoa-Rodriguez S, Wang LP, Willems P, *et al.* A review of radar-rain gauge data merging methods and their potential for urban hydrological applications. *Water Resources Research*, 2019, 55(8): 6356–6391. [doi: 10.1029/2018WR023332]
- 3 Fulton RA, Breidenbach JP, Seo DJ, *et al.* The WSR-88D rainfall algorithm. *Weather and Forecasting*, 1998, 13(2): 377–395. [doi: 10.1175/1520-0434(1998)013<0377:TWRA>2.0.CO;2]
- 4 Crane RK. Automatic cell detection and tracking. *IEEE Transactions on Geoscience Electronics*, 1979, 17(4): 250–262. [doi: 10.1109/TGE.1979.294654]
- 5 Fang W, Zhang FH, Sheng VS, *et al.* SCENT: A new precipitation nowcasting method based on sparse correspondence and deep neural network. *Neurocomputing*, 2021, 448: 10–20. [doi: 10.1016/j.neucom.2021.02.072]
- 6 Laroche S, Zawadzki I. Retrievals of horizontal winds from single-doppler clear-air data by methods of cross correlation and variational analysis. *Journal of Atmospheric and Oceanic Technology*, 1995, 12(4): 721–738. [doi: 10.1175/1520-0426(1995)012<0721:ROHWFS>2.0.CO;2]
- 7 Zou HB, Wu SS, Shan JS, *et al.* A method of radar echo extrapolation based on TREC and Barnes filter. *Journal of Atmospheric and Oceanic Technology*, 2019, 36(9): 1713–1727. [doi: 10.1175/JTECH-D-18-0194.1]
- 8 Bowler NEH, Pierce CE, Seed A. Development of a arecipationation nowcasting algorithm based upon optical flow techniques. *Journal of Hydrology*, 2004, 288(1-2): 74–91. [doi: 10.1016/j.jhydrol.2003.11.011]
- 9 Woo WC, Wong WK. Operational application of optical flow techniques to radar-based rainfall nowcasting. *Atmosphere*, 2017, 8(3): 48. [doi: 10.3390/atmos8030048]
- 10 Lanpher AS. Evaluation of the storm cell identification and tracking algorithm used by the WSR-88D [Honors Thesis]. New York: Cornell University, 2012. <https://ecommons.cornell.edu/server/api/core/bitstreams/5bd186cd-8008-4483-ad96-19a4af0164dc/content>.
- 11 Hu Y, Chen L, Wang ZB, *et al.* Towards a more realistic and detailed deep-learning-based radar echo extrapolation method. *Remote Sensing*, 2021, 14(1): 24. [doi: 10.3390/rs14010024]
- 12 Shi XJ, Chen ZR, Wang H, *et al.* Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Proceedings of the 28th International Conference on Neural Information Processing Systems*. Cambridge: MIT Press, 2015. 802–810.
- 13 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: Curran Associates Inc., 2017. 5617–5627.
- 14 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: Curran Associates Inc., 2017. 879–888.
- 15 Wang YB, Zhang JJ, Zhu HY, *et al.* Memory in memory: A predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics. *Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Long Beach: IEEE, 2019. 9146–9154.
- 16 Ye YK, Gao F, Cheng W, *et al.* MSSTNet: A multi-scale spatiotemporal prediction neural network for precipitation

- nowcasting. *Remote Sensing*, 2023, 15(1): 137.
- 17 Tian L, Li XT, Ye YM, *et al.* A generative adversarial gated recurrent unit model for precipitation nowcasting. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(4): 601–605. [doi: [10.1109/LGRS.2019.2926776](https://doi.org/10.1109/LGRS.2019.2926776)]
- 18 Fang W, Pang L, Yi WN, *et al.* AttEF: Convolutional LSTM encoder-forecaster with attention module for precipitation nowcasting. *Intelligent Automation & Soft Computing*, 2021, 30(2): 453–466.
- 19 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](https://doi.org/10.1016/j.patrec.2021.01.036)]
- 20 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 (CVPR)*. New Orleans: IEEE, 2022. 3170–3180.
- 21 Goodfellow IJ, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets. *Proceedings of the 27th International Conference on Neural Information Processing Systems*. Montreal: MIT Press, 2014. 2672–2680.
- 22 Jing JR, Li Q, Ding XY, *et al.* AENN: A generative adversarial neural network for weather radar echo extrapolation. *Proceedings of the 2019 International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Nanjing: ISPRS, 2019. 89–94.
- 23 Gong AF, Li RD, Pan BX, *et al.* Enhancing spatial variability representation of radar nowcasting with generative adversarial networks. *Remote Sensing*, 2023, 15(13): 3306. [doi: [10.3390/rs15133306](https://doi.org/10.3390/rs15133306)]
- 24 Chen L, Cao Y, Ma LM, *et al.* A deep learning-based methodology for precipitation nowcasting with radar. *Earth and Space Science*, 2020, 7(2): e2019EA000812. [doi: [10.1029/2019EA000812](https://doi.org/10.1029/2019EA000812)]
- 25 Thangjai W, Niwitpong SA, Niwitpong S. Confidence intervals for the common coefficient of variation of rainfall in Thailand. *PeerJ*, 2020, 8: e10004. [doi: [10.7717/peerj.10004](https://doi.org/10.7717/peerj.10004)]

(校对责编: 孙君艳)