



# 基于深度学习的灾害性天气雷达 外推临近预报方法研究

闵锦忠、耿焕同、戚友存、庄潇然等  
南京信息工程大学

2023年08月10日 宁夏银川

# 汇报 提纲

一

研究背景

二

技术进展

三

关键新技术

四

检验评估

五

业务应用

六

影响和评价

# 一、研究背景

## 前沿问题

### 研究背景



短时强降水




雷暴大风



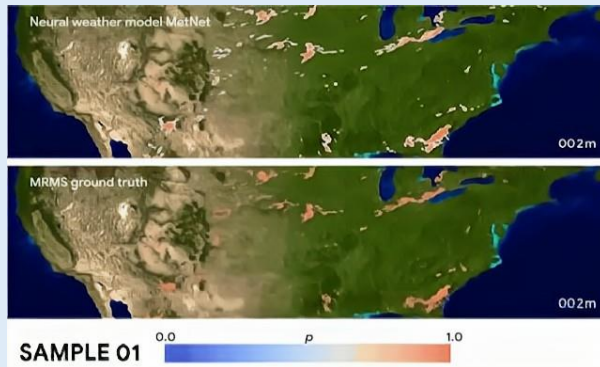
冰雹

短时强对流天气局地性强、发展迅速，预报难度大



临近预报

深度学习



短时预报

有效结合数值天气预报

### 存在问题

#### 数据层面

多源观测、模式  
预报数据众多



不同时空尺度数  
据如何有效融合

#### 算法层面

不同预报任务  
需求不同



如何优选深度学  
习算法

#### 可用性层面

深度学习模型缺  
乏可解释性



如何开展可解释  
性研究


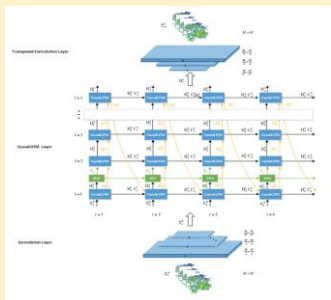
深度学习模型存  
在潜在不确定性



如何引入物理过  
程模式

# 二、技术进展

# 发展历程



**Spatiotemporal Model Based on Deep Learning for ENSO Forecasts**  
by Huantong Geng and Tianlei Wang  
School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China  
Academic Editor: Seontae Kim  
Atmosphere 2021, 12(7), 810; <https://doi.org/10.3390/atmos12070810>  
Received: 20 May 2021 / Revised: 18 June 2021 / Accepted: 21 June 2021 / Published: 23 June 2021  
(This article belongs to the Section Atmospheric Techniques, Instruments, and Modeling)



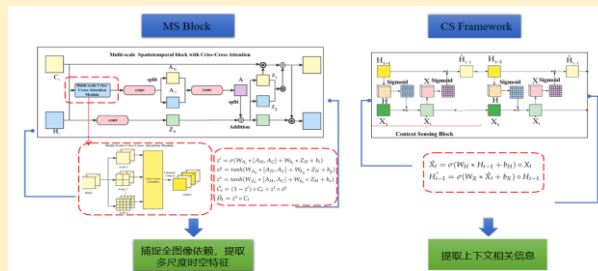
## 中国气象局探测中心0-2h雷达回波智能外推项目验收报告

### 一代 2020年T-PredRNN++

- ☑ 全国雷达拼图资料回波外推
- ☑ 模型输入形状可以为任意形状
- ☑ 实时滚动更新的0-2h雷达回波外推系统

### 一代 2019年T-PredRNN


- ☑ 单资料雷达回波外推
- ☑ 模型输入形状需为正方形
- ☑ 蛇线运动趋势推演



**MCCS-LSTM: Extracting Full-Image Contextual Information and Multi-Scale Spatiotemporal Feature for Radar Echo Extrapolation**  
by Huantong Geng and Liangchao Geng  
School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China  
Academic Editor: Stephan Havemann  
Atmosphere 2022, 13(2), 192; <https://doi.org/10.3390/atmos13020192>  
Received: 10 December 2021 / Revised: 15 January 2022 / Accepted: 20 January 2022 / Published: 25 January 2022  
(This article belongs to the Topic Advanced Research in Precipitation Measurements)

### 二代 2021年MCCS-LSTM

- ☑ 华南地区雷达拼图资料回波外推
- ☑ 模型输入形状可以为任意形状
- ☑ 有效提取多尺度时空信息和上下文相关信息，建立全图像依赖，延长有效预报时间
- ☑ 模型具有一定的泛化性，CIKM和华南地区数据集上均取得良好外推效果



**短时短期气象要素精细化网格预报项目合同验收**

项目负责人: 闵锦忠

委托单位: 江苏省气象探测中心  
开发单位: 南京信息工程大学  
承担单位: 南京满星数据科技有限公司

研发期限: 2021.07.01-2022.01.21

### 二代 2021年GAN-rcLSTM

- ☑ 雷达拼图资料回波外推
- ☑ 模型输入形状可以为任意形状
- ☑ 有效改善雷达回波外推结果不清晰模糊，雷达高回波区域被低估问题，实现精细化预测
- ☑ 模型泛化能力强
- ☑ 实现降水精细化预测



# 二、技术进展

# 发展历程

Open Access Article  
**AF-SRNet: Quantitative Precipitation Forecasting Model Based on Attention Fusion Mechanism and Residual Spatiotemporal Feature Extraction**  
 by Liangchao Geng<sup>1,\*</sup>, Huantong Geng<sup>1</sup>, Jinzhong Min<sup>1</sup>, Xiaoran Zhuang<sup>2</sup> and Yu Zheng<sup>3</sup>

<sup>1</sup> School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China  
<sup>2</sup> Jiangsu Meteorological Observatory, Nanjing 210008, China  
<sup>3</sup> CMA Key Laboratory of Transportation Meteorology, Nanjing Joint Institute for Atmospheric Sciences, Nanjing 210041, China  
 \* Author to whom correspondence should be addressed.

Remote Sens. 2022, 14(20), 5106; <https://doi.org/10.3390/rs14205106>

Received: 21 August 2022 / Revised: 30 September 2022 / Accepted: 3 October 2022 /

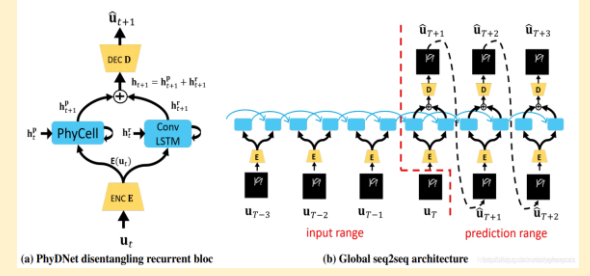
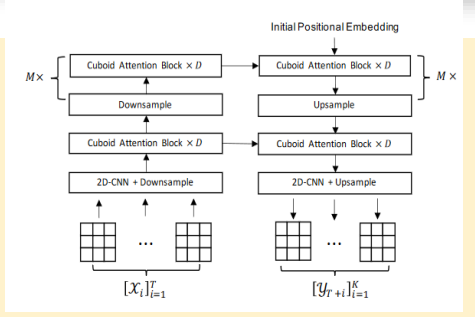
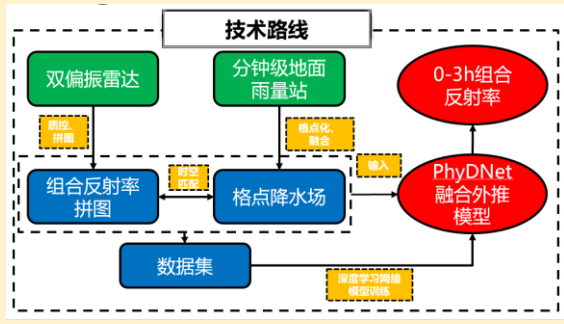
Open Access Article  
**GAN-rcLSTM: A Deep Learning Model for Radar Echo Extrapolation**  
 by Huantong Geng<sup>1</sup>, Tianlei Wang<sup>1,\*</sup>, Xiaoran Zhuang<sup>2</sup>, Du Xi<sup>2</sup>, Zhongyan Hu<sup>1</sup> and Liangchao Geng<sup>1</sup>

<sup>1</sup> School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China  
<sup>2</sup> Jiangsu Meteorological Observatory, Nanjing 210008, China  
 \* Author to whom correspondence should be addressed.

Academic Editor: Alexei Dmitriev  
 Atmosphere 2022, 13(5), 684; <https://doi.org/10.3390/atmos13050684>  
 Received: 2 March 2022 / Revised: 15 April 2022 / Accepted: 20 April 2022 / Published: 24 April 2022

山东省气象局冰雹识别算法优化项目  
 结题检查报告

“基于GAN-rcLSTM模型的雷达回波外推算法”  
 委托单位: 北京象元气象观测技术研究院  
 开发单位: 南京信息工程大学



## 四代 2023年研究计划

## 三代 2022年SGAN+PhyDNet

- 提出能兼顾系统移动和局地演变的人工智能算法 **PhyDNet**用于回波外推
- 将生成对抗网络 (GAN) 与PhyDnet进行结合, 解决外推模糊问题
- 提出频域匹配的SGAN算法, 能显著增强对于不同尺度、尤其是小尺度强回波的判别能力, 起到维持预测评分的功效

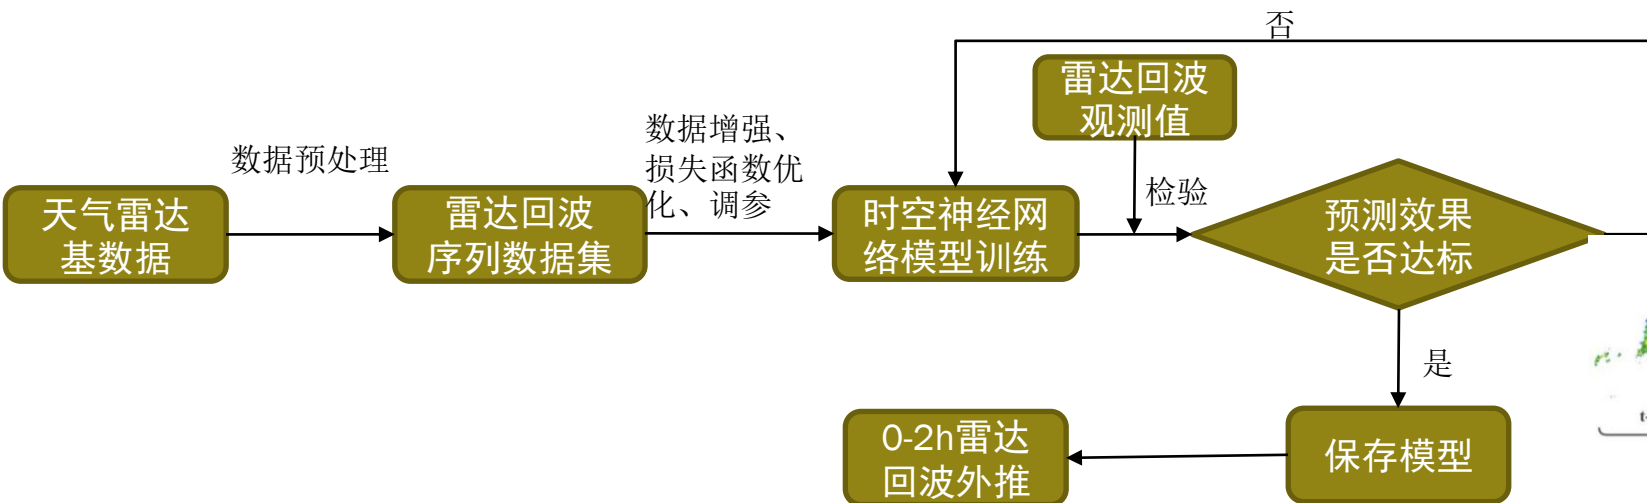
## 二代 2022年SGAN-rcLSTM

- 在GAN-rcLSTM模型的基础上引入正则化项构建综合损失函数, 稳定了GAN训练过程
- 基于注意力机制构建了雷达定量降水预报模型 **AF-SRNet**
- 基于编解码ConvLSTM构建了数值模式温度预报订正模型
- 发展了基于迁移学习及rcLSTM的小样本的雷达回波外推模型

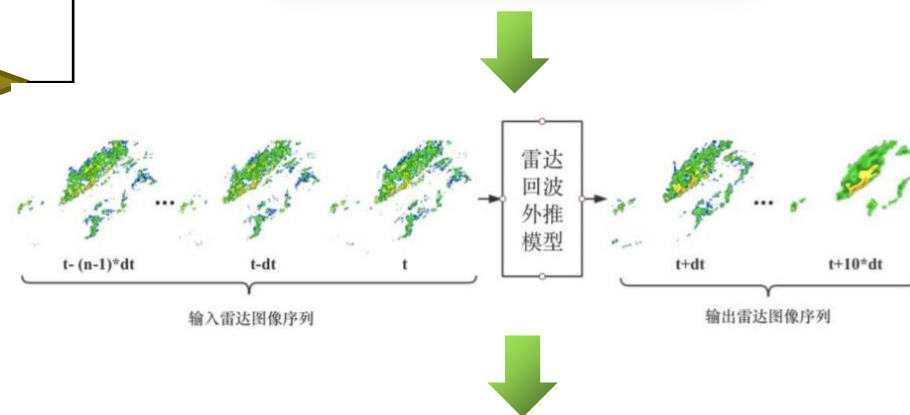
- 发展基于Transformer框架的雷达回波外推模型
- 基将物理机制及气象机理引入降水临近预报中, 建立降水系统的微物理约束
- 基于三维雷达回波资料、自动站观测资料及模式预报结果, 结合深度学习, 构建多源资料有效融合方法, 发展精准化、精细化的短临预报技术 (包括短时强降水、雷暴大风、闪电、冰雹的预报)
- 研究短临预报及数值模式预报的有效融合方案, 提高短期预报效果

## 二、技术进展

### 雷达回波AI外推建模



### 雷达回波外推任务



- ◆ 首先对天气雷达基数据进行预处理，得到可用于神经网络模型训练的**雷达回波序列数据集**
- ◆ 然后输入到**时空神经网络模型**中进行训练，采用统计损失函数的累计误差方法进行反向传播。
- ◆ 模型训练完成后，需利用验证集数据进行效果检验，预测效果合格的模型会被保存起来用于**0-2小时雷达回波外推**，否则将继续迭代训练。


根据过去  $J$  小时的雷达回波图像，来外推未来  $K$  小时回波图像。图像序列间隔为 6 分钟。将这个问题转为条件概率事件，在已知  $t$  时刻前  $J$  个时次的数据条件下，最大程度计算  $t$  时刻后  $K$  个时次长度的数据概率分布。

$$\tilde{\mathcal{X}}_{t+1}, \dots, \tilde{\mathcal{X}}_{t+K} = \arg \max_{\mathcal{X}_{t+1}, \dots, \mathcal{X}_{t+K}} p(\mathcal{X}_{t+1}, \dots, \mathcal{X}_{t+K} | \hat{\mathcal{X}}_{t-J+1}, \hat{\mathcal{X}}_{t-J+2}, \dots, \hat{\mathcal{X}}_t)$$

时空序列预测问题

### 问题一：雷达外推结果随预报时长呈衰弱趋势

1



现有的ConvLSTM类模型为了追求高拟合能力，通常需要堆叠多层串联。当网络超过4层后，梯度消失问题会非常明显，观测值得信息很难传递到输出层。具体的表现结果为高强度回波在长时次预报中呈现快速衰弱趋势。如个例中右上角的黄色色标回波在10个时次后迅速衰减到30dbz以下。

## 二、技术进展

## 发展历程

### residual convolutionLSTM模型框图 (简记为rcLSTM)

$$\begin{pmatrix} g_t \\ i_t \\ f_t \end{pmatrix} = \begin{pmatrix} \tanh \\ \sigma \\ \sigma \end{pmatrix} W_1 * [\mathcal{X}_t + \mathcal{H}_t^{k-2}, \mathcal{H}_{t-1}^k, \mathcal{C}_{t-1}^k]$$

$$\mathcal{C}_t^k = f_t \odot \mathcal{C}_{t-1}^k + i_t \odot g_t$$

$$\begin{pmatrix} g'_t \\ i'_t \\ f'_t \end{pmatrix} = \begin{pmatrix} \tanh \\ \sigma \\ \sigma \end{pmatrix} W_2 * [\mathcal{X}_t + \mathcal{H}_t^{k-2}, \mathcal{C}_t^k, \mathcal{M}_t^{k-1}]$$

$$\mathcal{M}_t^k = f'_t \odot \tanh(W_3 * \mathcal{M}_t^{k-1}) + i'_t \odot g'_t$$

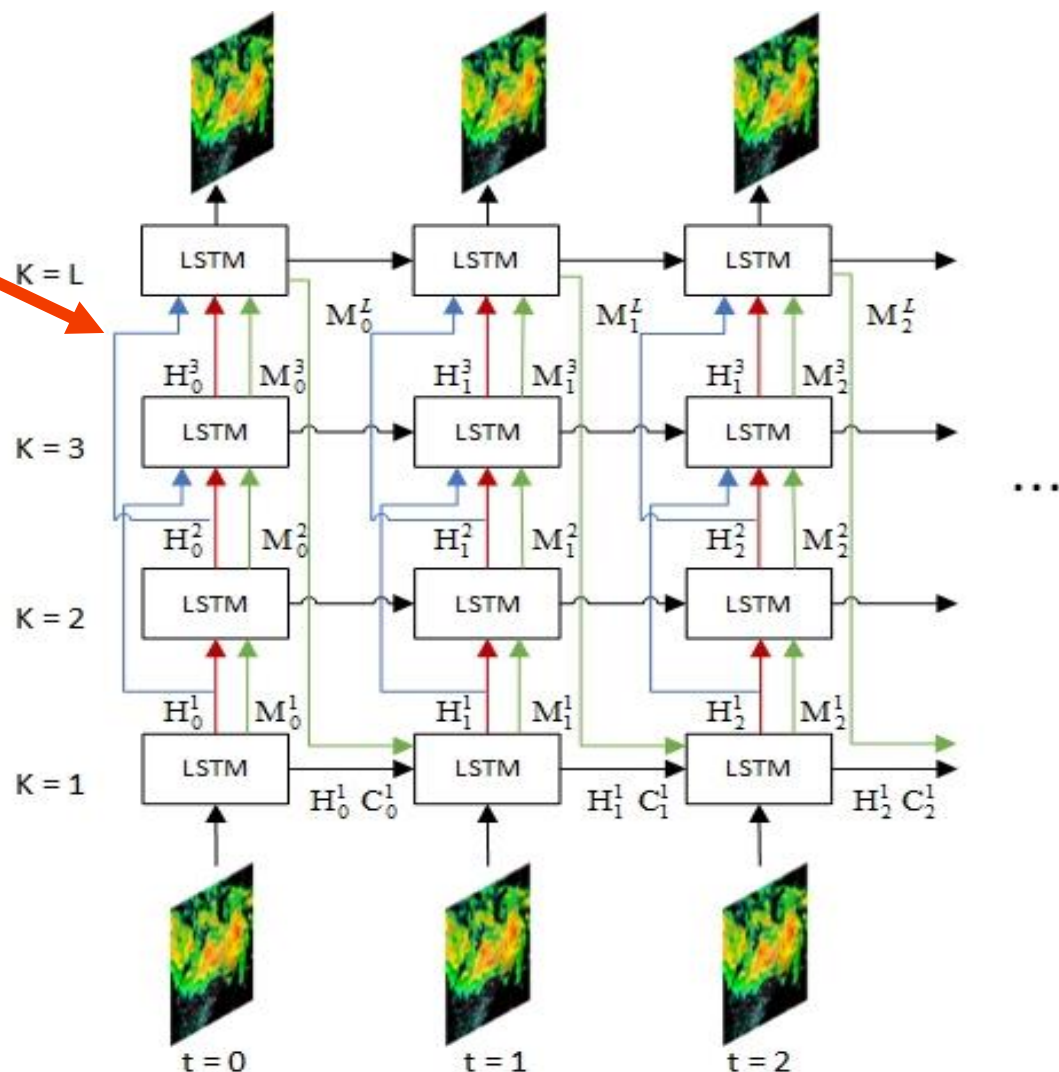
$$o_t = \tanh(W_4 * [\mathcal{X}_t, \mathcal{C}_t^k, \mathcal{M}_t^k])$$

$$\mathcal{H}_t^k = o_t \odot \tanh(W_5 * [\mathcal{C}_t^k, \mathcal{M}_t^k]),$$

$$\frac{\partial loss}{\partial x_l} = \frac{\partial loss}{\partial x_L} \cdot \frac{\partial x_L}{\partial x_l} = \frac{\partial loss}{\partial x_L} \cdot \left( 1 + \frac{\partial}{\partial x_L} \sum_{i=l}^{L-1} F(x_i, W_i) \right)$$

改进后的思路为**增加底层至顶层的梯度传播路线**。将前两层的输出相加后作为后一层的输入，这样求偏导的时候会有短路机制保证梯度几乎永远不为0，也就大大降低了梯度消失问题。

右图蓝色箭头为每层LSTM间的残差模块。

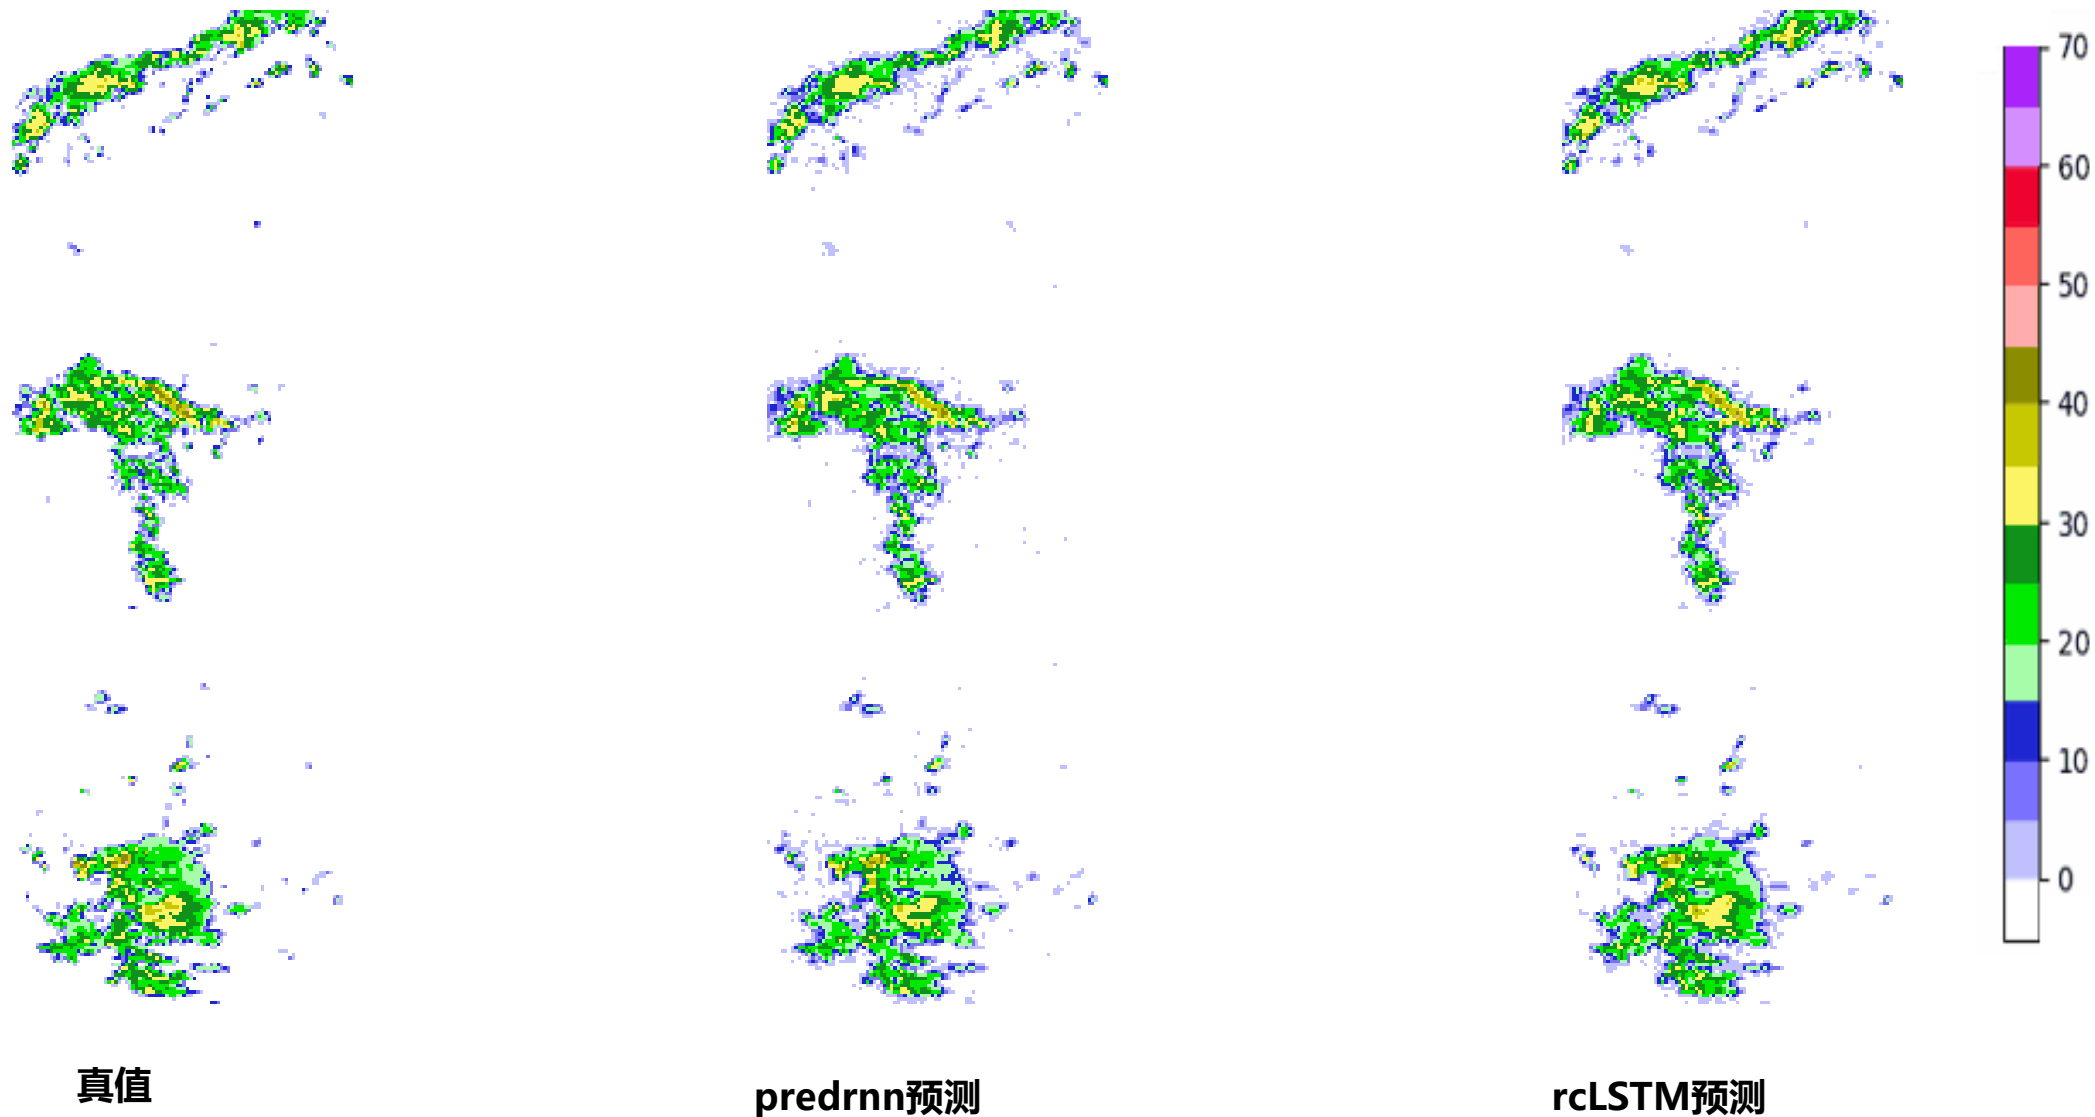


## 二、技术进展

## 发展历程

### rcLSTM模型预测效果

1



从图像中可以看出，rcLSTM对于高强度的雷达回波留存和有效预报时间更长




## 二、技术进展

## 发展历程


### 客观指标对比

	rcLSTM	PredRNN
MSE	15.83	16.04
CSI-10	0.67	0.66
CSI-20	0.60	0.58
CSI-30	0.38	0.32


从客观指标角度，rcLSTM模型取得了更高的CSI技巧评分和更低的MSE。随着阈值的提高，rcLSTM的优势更加明显。




阈值10



阈值20



阈值30

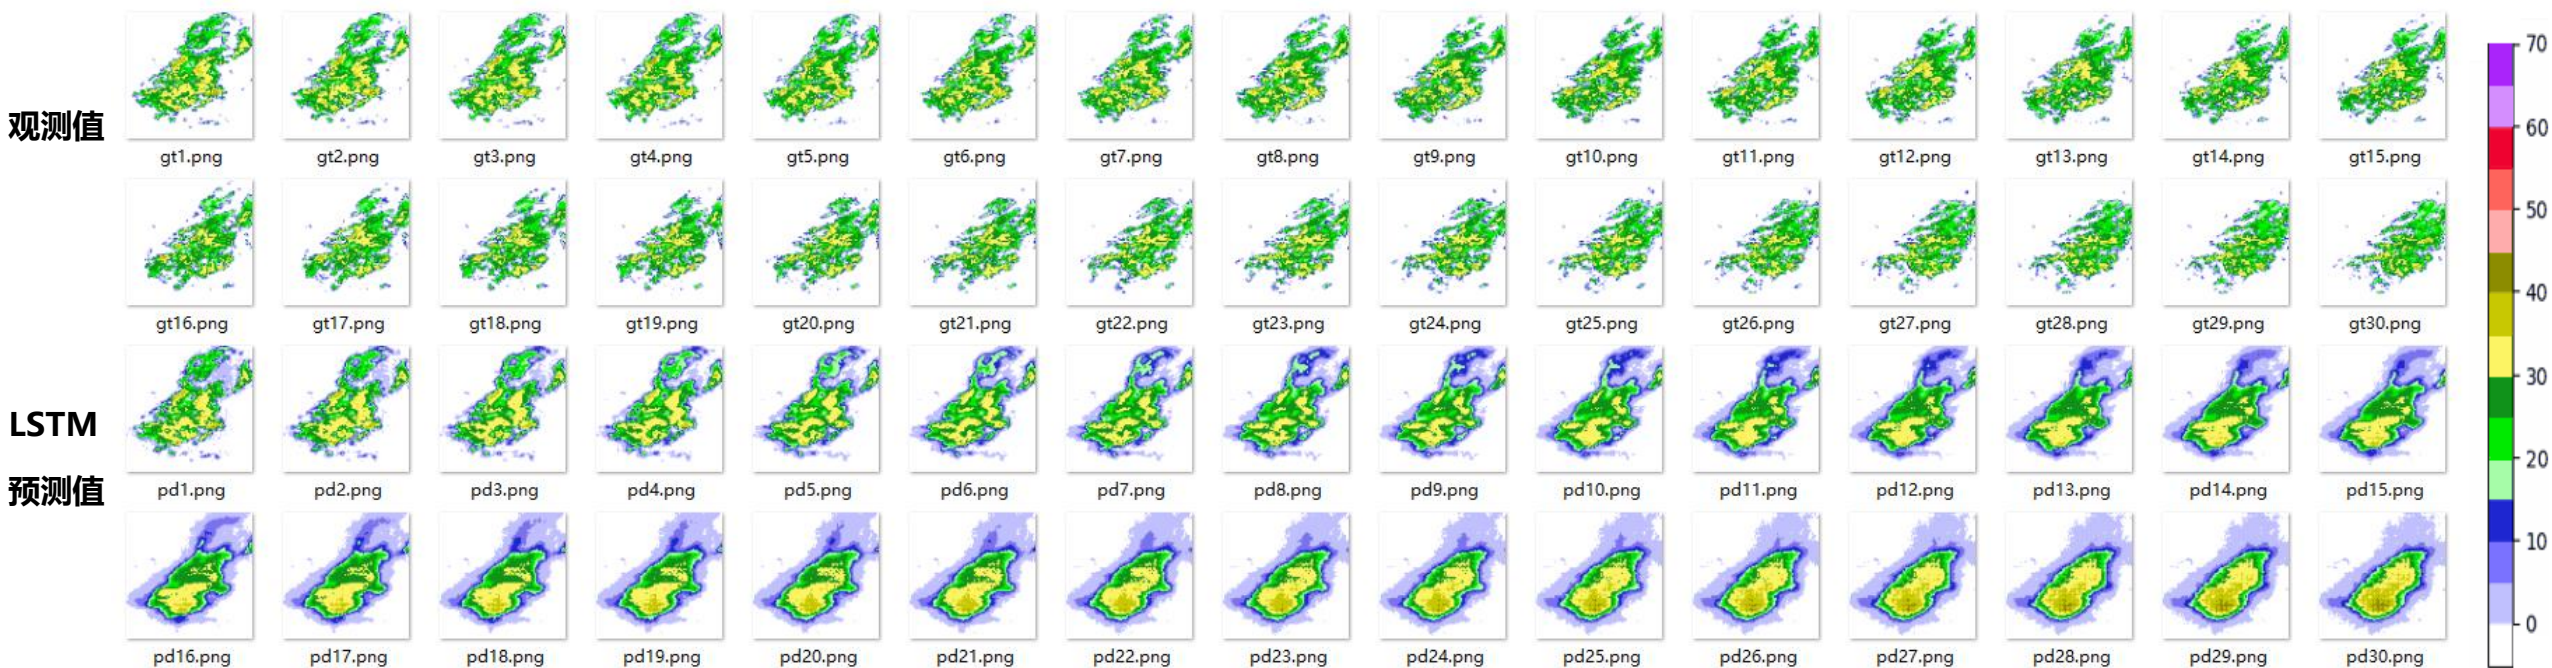


MSE

## 二、技术进展

## 发展历程

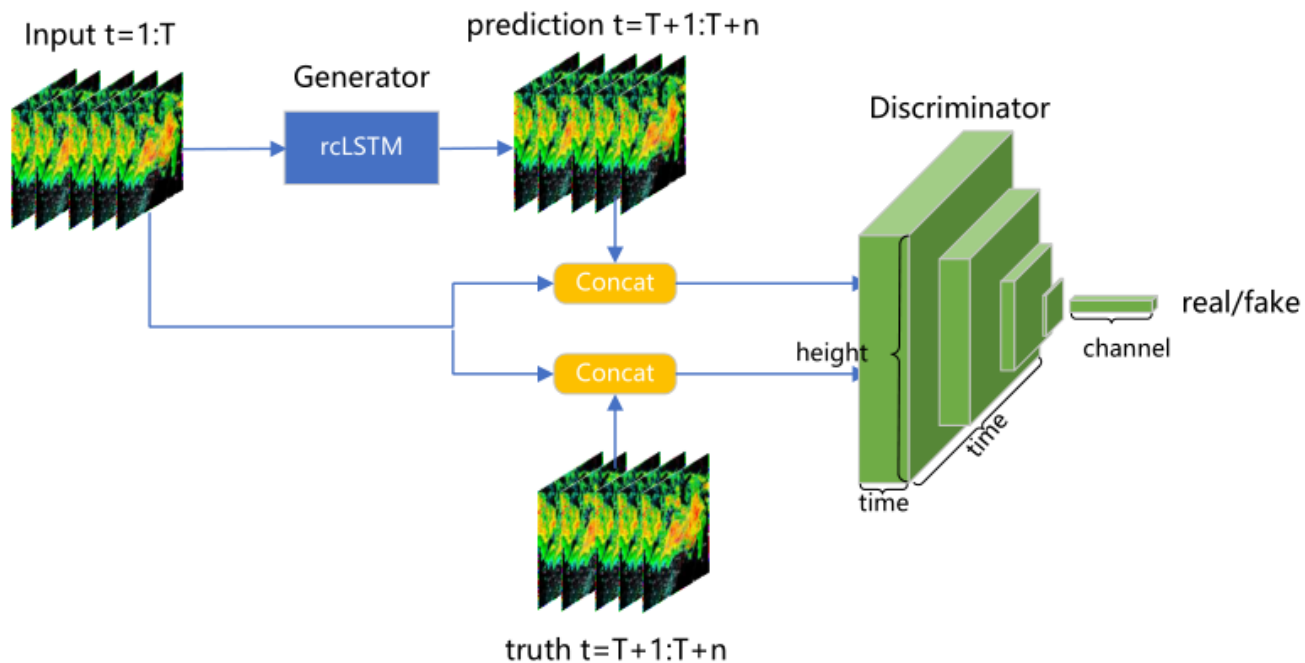
### 问题二：长时次外推模糊问题



$$\ell(x, y) = L = \{l_1, \dots, l_N\}^\top, \quad l_n = (x_n - y_n)^2$$

传统LSTM类网络是将前一时次的预测作为后一时次的输入，这种**训练方式没有将预报序列作为一个整体**，而是逐时次独立计算均方误差后求平均值。训练时，**神经网络会为了追求更低的均方差得分而越来越多的牺牲回波细节**。在长时次预报中，外推图像会逐渐模糊化而失去意义。

### GAN-rcLSTM模型结构



$$\max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log(D(x_{1:T+n}))] + E_{x \sim p_{\text{data}}(x)} [\log(1 - D([x_{1:T}, G(x_{1:T})]))]$$

$$\max_G V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log(D([x_{1:T}, G(x_{1:T})]))]$$


我们引入了近些年无监督学习领域的生成式对抗网络 (Generative Adversarial Networks) 来解决模糊问题。我们将原来生成器替换为rcLSTM，将原来的噪声替换成历史雷达观测值作为输入。判别器由若干3D卷积和一个全连接层组成，每层之间插入Layernorm层。其中，生成器用来产生未来T个时次的回波序列，之后与前T个时次真实值拼接为一个整体。判别器用来分辨是完整真实值还是生成值。损失函数为二元交叉熵 (Binary Cross Entropy)，优化流程可表示如下。通过迭代交替训练生成器和判别器，使得外推回波序列更清晰。应用阶段，只需保留生成器。

## 二、技术进展

## 发展历程

### GAN-rcLSTM预测效果

1



观测值

LSTM预测

GAN-rcLSTM预测

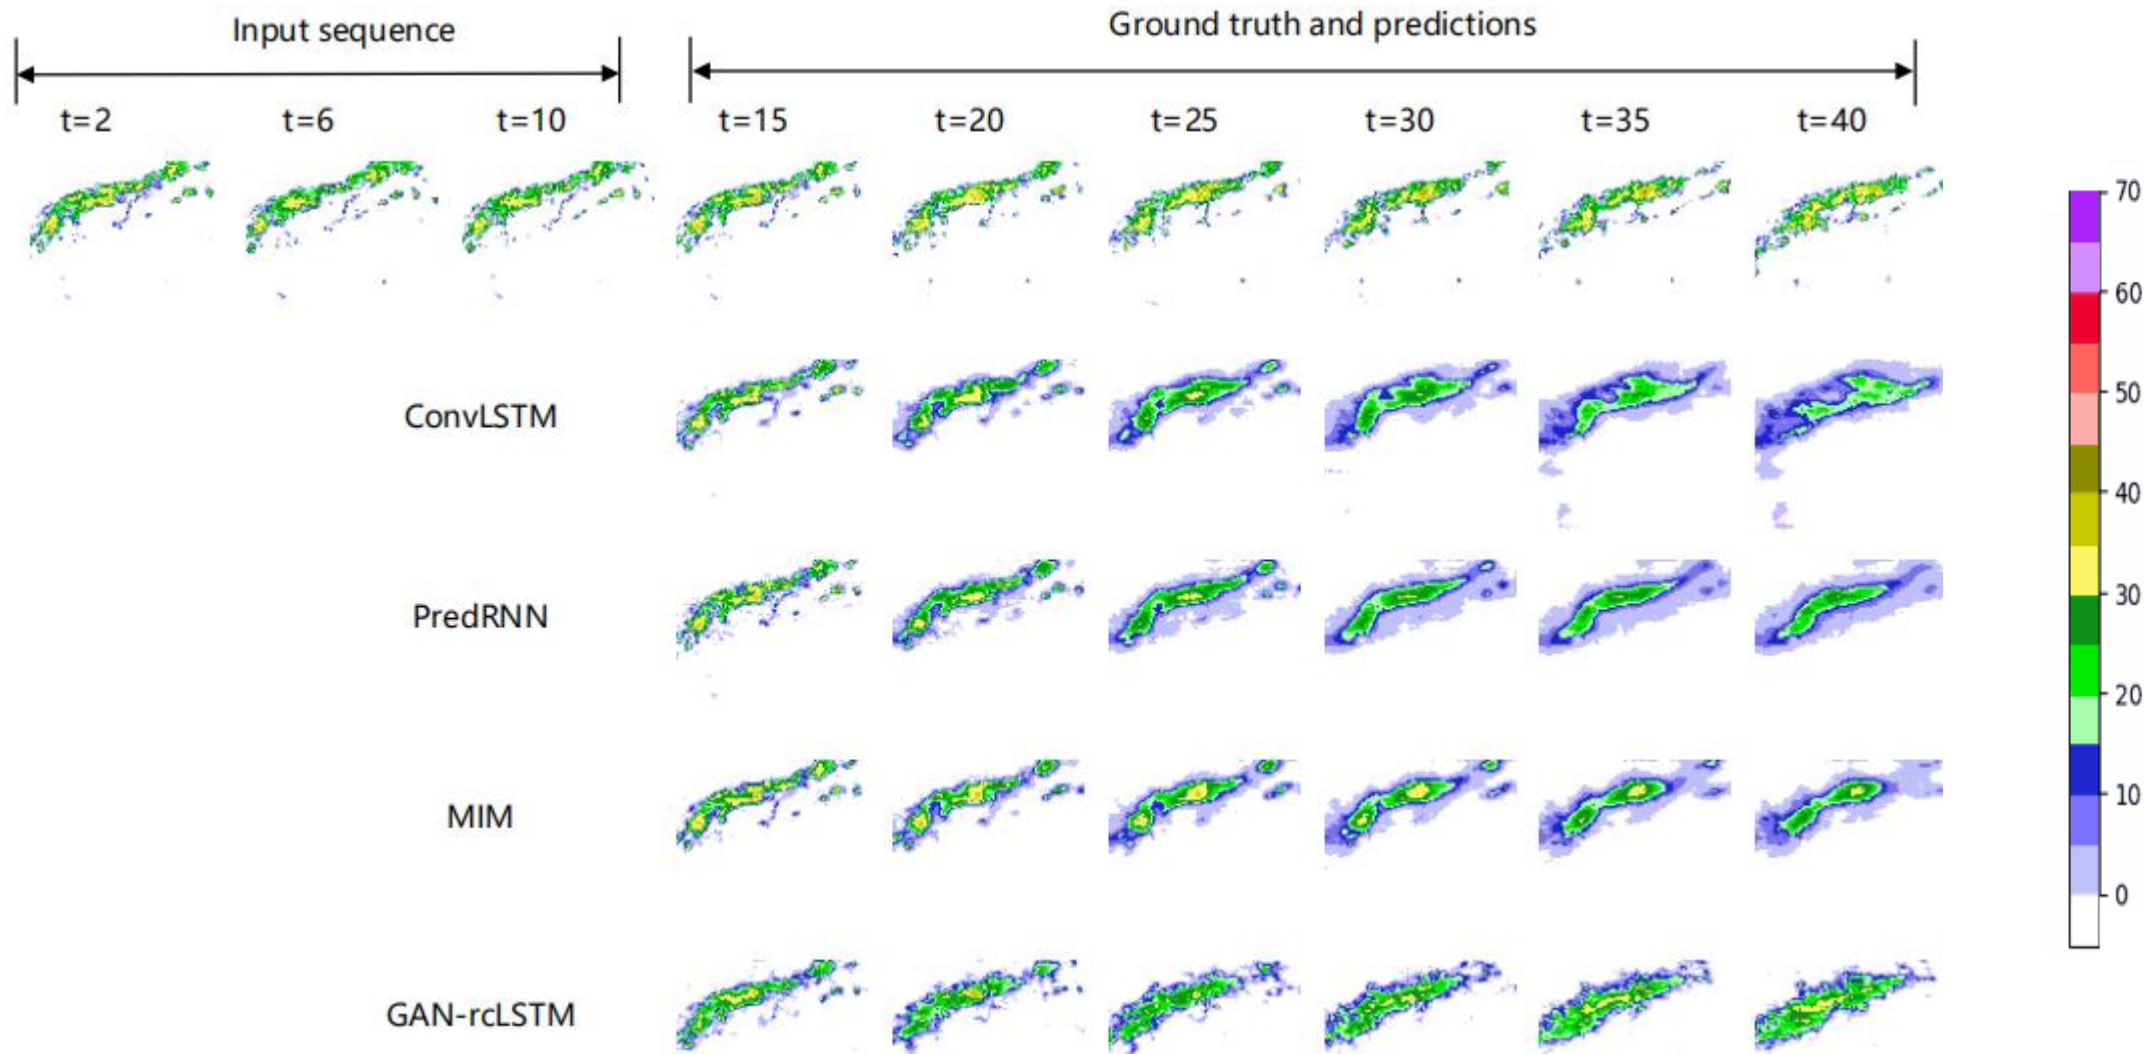
可以看出，传统的LSTM预测结果在10个时次之后就迅速模糊，而GAN-rcLSTM网络可以始终维持图像的清晰



## 二、技术进展

## 发展历程

### GAN-rcLSTM预测效果





## 二、技术进展

## 发展历程

### 准确性客观指标对比

201907010000_201907032012_cbi_cr_ld.npy	2.67GB
201907040324_201907042100_cbi_cr_ld.npy	708.00MB
201907042318_201907051154_cbi_cr_ld.npy	508.00MB
201907052136_201907211542_cbi_cr_ld.npy	14.77GB
201907220242_201907221418_cbi_cr_ld.npy	468.00MB
201907230212_201907240200_cbi_cr_ld.npy	956.00MB
201907240212_201907282354_cbi_cr_ld.npy	4.60GB
202007010000_202007081530_cbi_cr_ld.npy	7.17GB
202007081806_202007092354_cbi_cr_ld.npy	1.17GB
202007100148_202007130206_cbi_cr_ld.npy	2.83GB
202007130218_202007140512_cbi_cr_ld.npy	1.05GB
202007140542_202007162354_cbi_cr_ld.npy	2.59GB
202007180000_202007201036_cbi_cr_ld.npy	2.29GB
202007201054_202007211418_cbi_cr_ld.npy	1.07GB
202008010000_202008030112_cbi_cr_ld.npy	1.93GB
202008030336_202008040718_cbi_cr_ld.npy	1.09GB
202009020000_202009021342_cbi_cr_ld.npy	552.00MB
202009030536_202009031800_cbi_cr_ld.npy	500.00MB
202009060200_202009060854_cbi_cr_ld.npy	280.00MB
202009070848_202009072354_cbi_cr_ld.npy	608.00MB
202009080112_202009081142_cbi_cr_ld.npy	424.00MB
202009090000_202009091148_cbi_cr_ld.npy	476.00MB
202009091712_202009092354_cbi_cr_ld.npy	272.00MB
202009100006_202009101236_cbi_cr_ld.npy	504.00MB
202009101624_202009102354_cbi_cr_ld.npy	304.00MB

日期	原样本个数	筛选后样本个数
2019	6030	6022
2020	5703	5608
2021	14235	11987

数据集为江苏地区及部分海域雷达资料



经度:116.64°E ~ 121.75°E

纬度:30.20°N ~ 35.31°N

经过质控后, 共得到23617个回波序列,  
将其按照8:2的比例划分为训练集和测试集

Model	MSE	CSI	POD	FAR
ConvLSTM	34.629	0.323	0.360	0.268
PredRNN	33.508	0.373	0.424	0.298
MIM	<b>31.366</b>	0.356	0.395	<b>0.235</b>
GAN-rcLSTM	32.662	<b>0.402</b>	<b>0.472</b>	0.259

GAN-rcLSTM在三个小时的预报中可以**保持稳定的清晰度**, 同时取得了**最高的CSI和POD得分**。而其他所有模型在半个小时后都开始变得非常模糊。



## 二、技术进展

## 发展历程

不同指标的计算公式:

1. 基于像素的灰度查分绝对值之和法 (SMD)

$$SMD(I) = \sum_m^M \sum_n^N \{|f(m+1, n) - f(m, n)| + |f(m, n+1) - f(m, n)|\}$$

2. 基于梯度幅值的Tenengrad方法

$$s_x = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} \quad s_y = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix}$$

$$S(m, n) = \sqrt{[G_x(m, n)]^2 + [G_y(m, n)]^2} \quad TEN(I) = \sum_m^M \sum_n^N [S(m, n)]^2$$

3. 是基于二阶导数的Laplacian梯度法

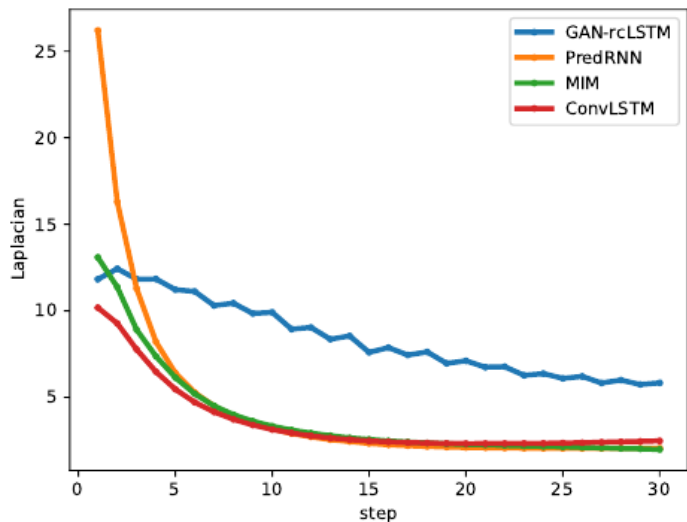
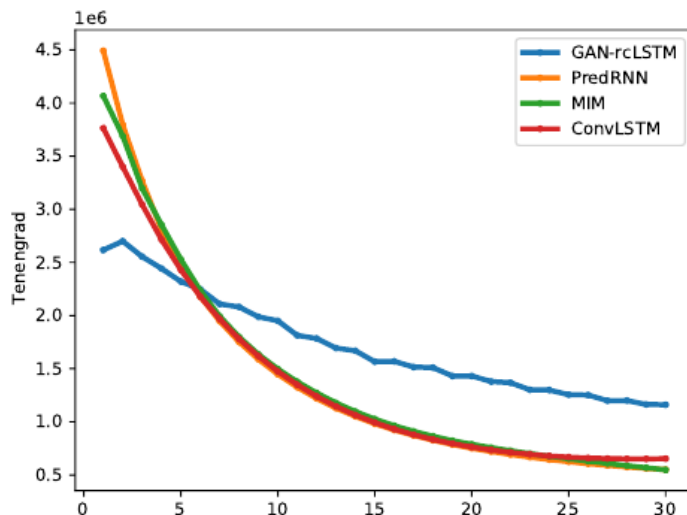

$$LAP(I) = \sum_m^M \sum_n^N |L(m, n)|$$

$$L = \frac{1}{6} \begin{pmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{pmatrix} \quad LAP\_VAR(I) = \sum_m^M \sum_n^N [|L(m, n)| - L]^2$$

$$L = \frac{1}{NM} \sum_m^M \sum_n^N |L(m, n)|$$

Model	SMD	Tenengrad	Laplacian
ConvLSTM	7582	1370620	3.582
PredRNN	7534	1394062	4.441
MIM	7300	1408276	3.824
GAN-rcLSTM	8356	1719049	8.406

### 模糊程度的客观定量指标对比



GAN-rcLSTM在三个小时的预报中可以保持稳定的清晰度，而其他所有模型在半个小时后都开始变得非常模糊。模糊程度的客观指标也表明，**SMD、Tenengrad和Laplacian** 指标均表明**GAN-rcLSTM清晰度全面优于现有模型。**

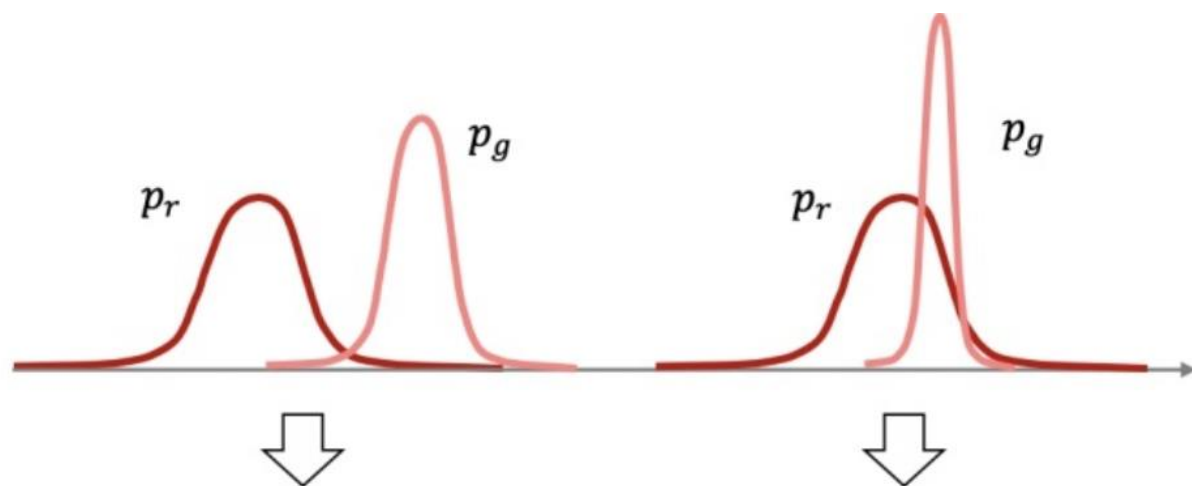
# SGAN-rcLSTM模型-针对GAN训练不稳定问题

### 模式崩溃的原因：

判别器:  $J(D) = E_{z \sim p_z} [\log D(G(z))] - E_{x \sim p_r} [\log(D(x))]$

生成器:  $J(G) = -E_{z \sim p_z} [\log D(G(z))]$

1. 生成器生成了不真实的样本。对应于那些不真实的样本,  $P_g(X) > 0$  但  $Pr(X) \approx 0$ , 此时KL散度中间的被积项将会趋于 $\infty$ ;
2. 生成器没能生成真实的样本。对应于没能生成的那些真实样本,  $pr(x) > 0$  但  $pg(x) \approx 0$ , 此时KL散度中间的被积项将会趋于0。而不生成更多不同的真实样本。因此生成器完全有可能只生成单一的真实样本生成单一的真实样本已经足够欺骗判别器, 生成器没有必要冒着失真的风险生成多样化的样本。



生成不真实的样本, 惩罚  
巨大 (判别器过强)

生成器没能生成真实的样本  
(生成器生成的样本单一)

正则化项为训练GAN提供了一个良性循环。它鼓励生成器探索图像空间, 并增加生成次要模式样本的机会。另一方面, 判别器被迫关注从次要模式生成的样本。

## 二、技术进展

## 发展历程

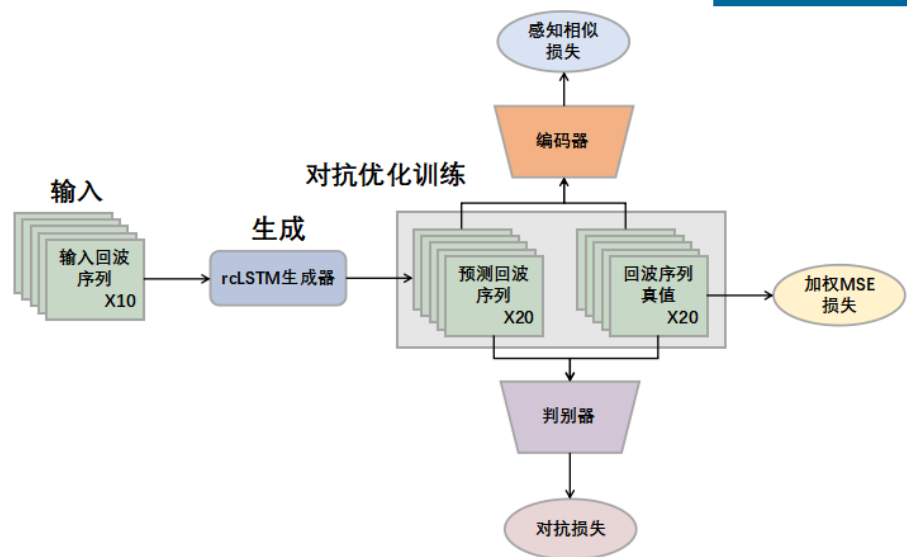


图1 SGAN-rcLSTM数据流图

- 首先，输入雷达回波序列到rcLSTM网络中生成预测回波图像；
- 其次，预测的回波序列与真值序列分别送入判别器中进行判别，得到**判别器以及生成器损失**；预测的回波序列与真值之间计算加权均方根误差，得到**重构损失**；将预测的回波序列与真值分别送入一个编码器，得到两者的编码向量后，计算两者的均方根误差，得到**感知相似性损失**，并作为正则项保证生成对抗网络训练**稳定**；
- 最后，综合上述所有损失，构建**综合损失函数**，对网络进行对抗优化训练，得到具有最优参数的生成器模型，用于雷达回波外推。

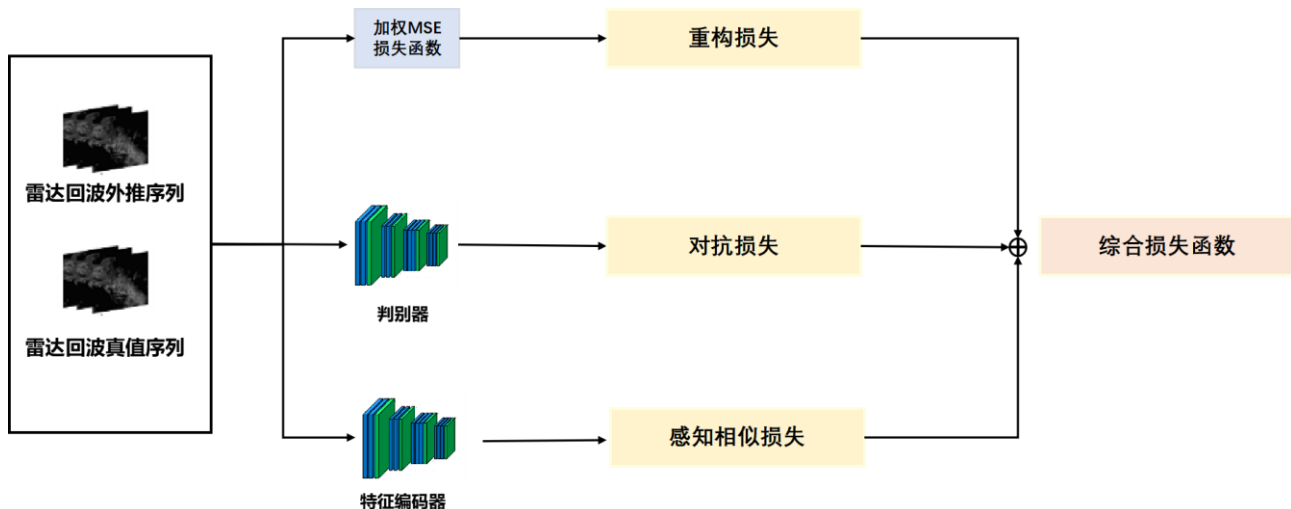


图2 综合损失函数构成图

### 重构损失：

$$L_{MSE} = 1 / (\text{length} * \text{height} * \text{width}) \sum_t \sum_j \sum_k W(Y_t[j, k]) * (Y_t[j, k] - \hat{Y}_t[j, k])^2$$

### 对抗损失：

$$\mathcal{L}_{GAN(D)} = - \sum_{t=2}^T [\log(D(x_t)) + \log(1 - D(\hat{x}_t))]$$

$$\mathcal{L}_{GAN(G)} = - \sum_{t=2}^T [\log(D(\hat{x}_t))]$$

### 感知相似性损失：

$$\mathcal{L}_{ps} = \sum_{t=1}^T \|E(\hat{x}_t) - E(x_t)\|_2^2$$

### 综合损失函数：

$$\mathcal{L}_{total} = \mathcal{L}_{MSE} + \lambda_1 \mathcal{L}_{GAN(G)} + \lambda_2 \mathcal{L}_{ps}$$

# SGAN-rcLSTM与GAN-rcLSTM实验对比方案

### 【“2022江苏气象AI算法挑战赛”气象雷达数据集】

气象雷达数据集是雷达回波数据的时间序列，其物理含义为3公里等高面的基本反射率因子。本数据集是对江苏多部S波段气象雷达质量控制及组网拼图后得到的，覆盖整个江苏省区域面积。数据取值范围为0-70（单位：dBZ），水平分辨率为 $0.01^\circ$ （约1公里），**时间分辨率为6分钟**，单时次数据（即单张图片）的网格尺寸为 **$480 \times 560$ 像素**。由于计算资源的限制将其下采样成 **$120 \times 140$ 像素大小**。处理后划分训练集、验证集、测试集。

### 【实验方案设置】

GAN-rcLSTM模型与SGAN-rcLSTM模型均使用相同的实验参数，设置patch为4以减少计算资源的消耗，隐藏层节点均设置为**“64,64,64,64”**，batch size均设置为8，卷积运算的卷积核大小为 **$5 \times 5$** ，使用10个时次作为输入，预测未来**20**个时次。总共训练**80000 iterations**，均保存最好的模型参数用于测试。

### 【评价指标】

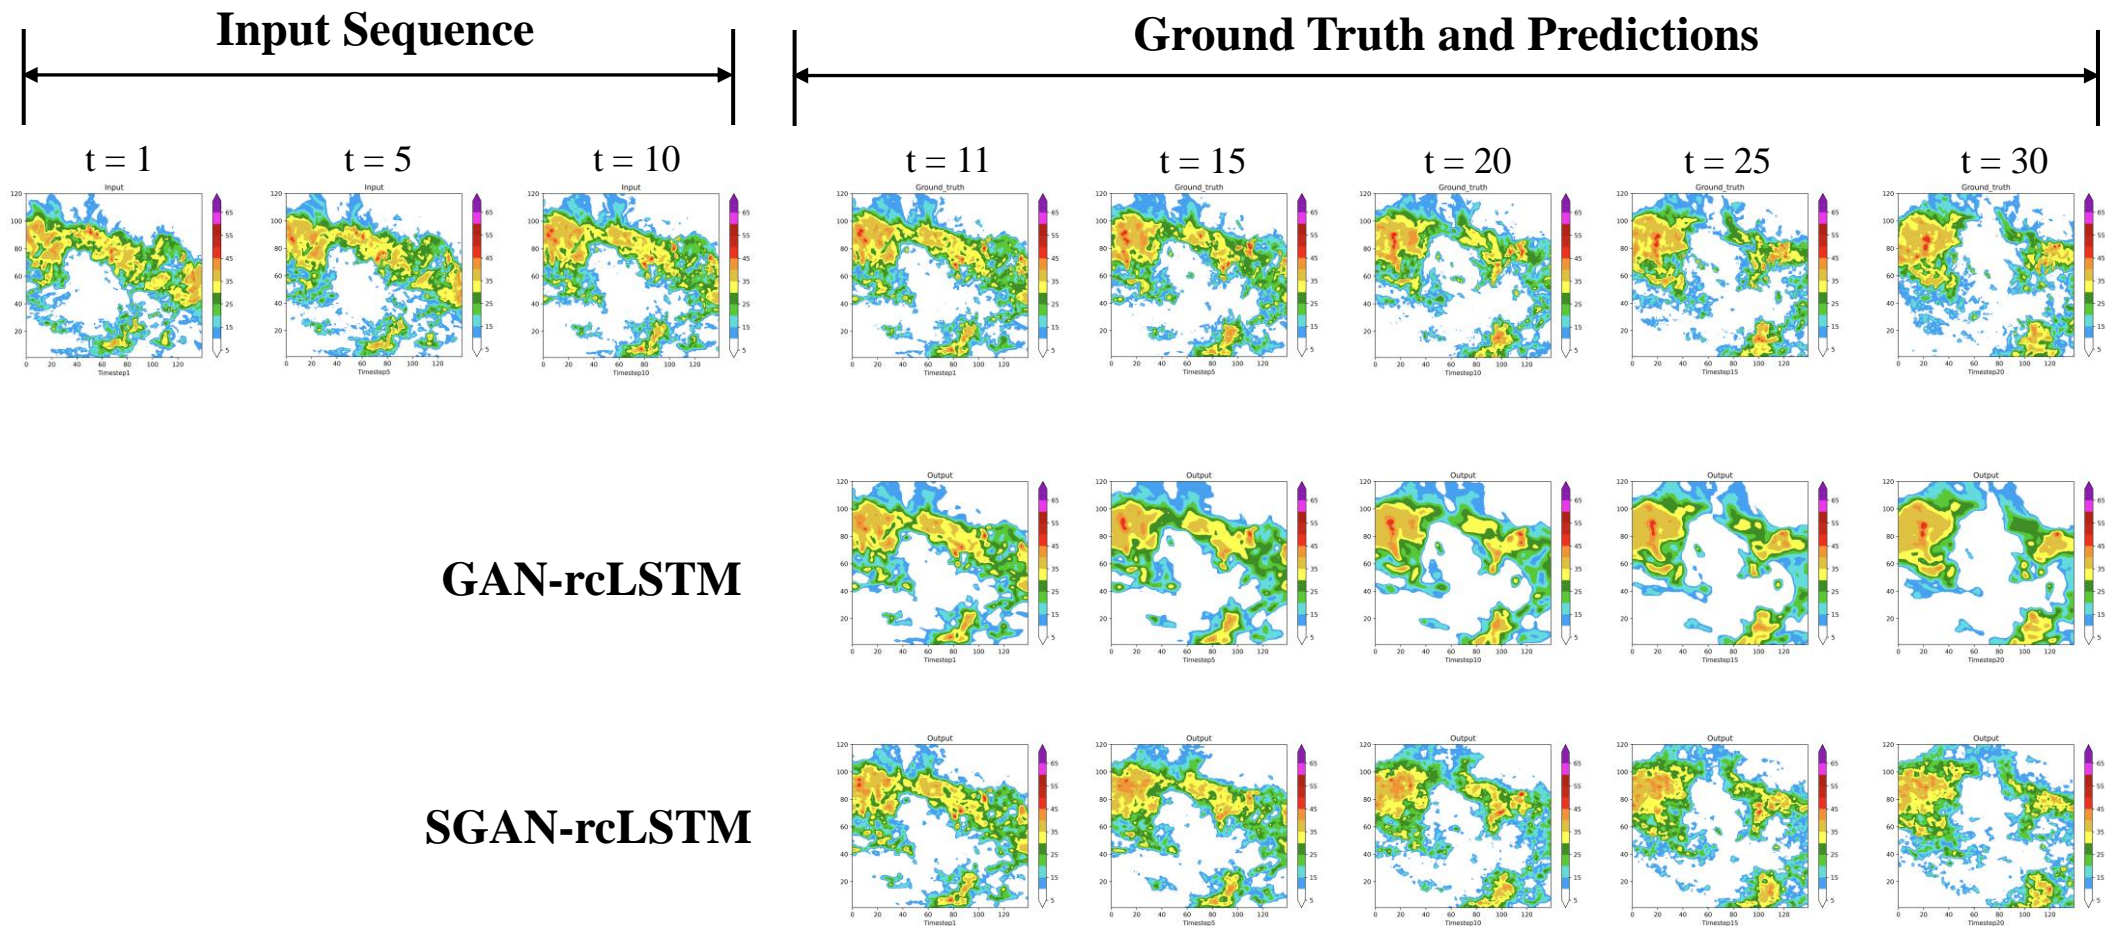
使用准确度指标**临界成功指数CSI**、**虚警率FAR**、**命中率POD**，使用清晰度指标**结构相似性SSIM**。



## 二、技术进展

## 发展历程

# SGAN-rcLSTM与GAN-rcLSTM实验对比方案




采用10帧作为输入，预测未来20帧， $t$ 代表第几帧

从可视化结果来看，SGAN-rcLSTM外推结果明显清晰于GAN-rcLSTM


## 二、技术进展

## 发展历程

### 问题三：如何进行多要素融合改进外推效果 (1+1>2)



- (a) 迎风坡上升
- (b) 气团的局部阻塞
- (c) 蒸发冷却诱发下坡风
- (d) 背风坡辐合
- (e) 太阳辐射触发对流
- (f) 机械动力抬升至自由对流高度以上而触发对流,
- (g) 播种—供给云降水机制



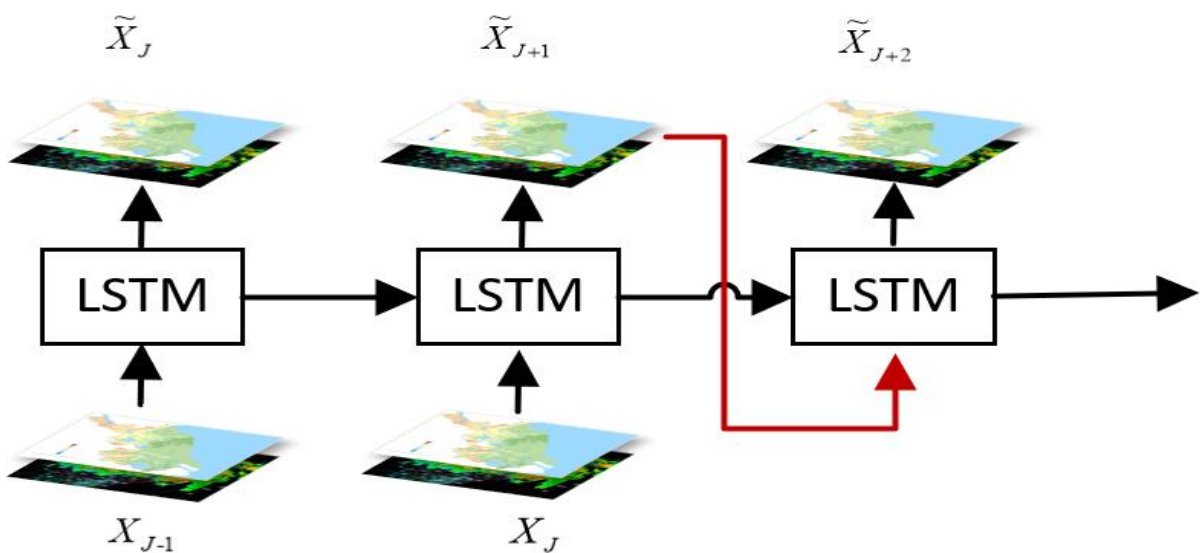
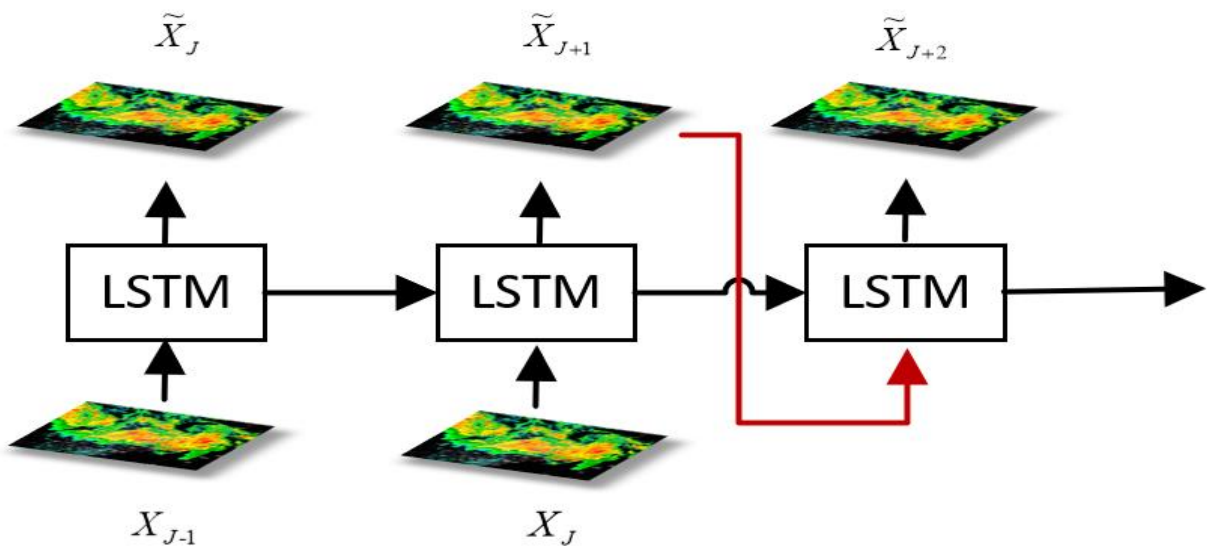
大量研究已证明<sup>[1,2]</sup>, 地形与雷达回波的运动发展有密不可分的关系, 因此在雷达外推网络中, **需要将地形数据作为一个静态背景融入学习**。如何将多源要素与时序型神经网络结合是一个需要解决的问题。

[1]钟水新.地形对降水的影响机理及预报方法研究进展[J].高原气象,2020,39(05):1122-1132.

[2]王凌梓,苗峻峰,韩芙蓉.近10年中国地区地形对降水影响研究进展[J].气象科技,2018,46(01):64-75.

## 二、技术进展

### 发展历程



### 多要素融合方案

**雷达对照组：**输入和输出均为单要素雷达回波，前J个时次输入为观测值，后K个时次使用上一时刻预测值作为输入

**通道叠加方案：**每层卷积核组的卷积核数量翻倍，多要素在通道上叠加。通过先卷积后相加的方式融合。这种方式需要预测所有要素，并不考虑要素之间的差异，如“地形”是静态的，短期内不会改变。由于雷达回波和需要预报的要素处于同等地位，结果往往会出现“喧宾夺主”的情况，模型更倾向于预测其他要素。




# 二、技术进展

# 发展历程


个例(通道输出: 雷达回波)

Pre为降水, CR为组合反射率, 后带小数为loss权重, 模型GAN-rcLSTM


真实值




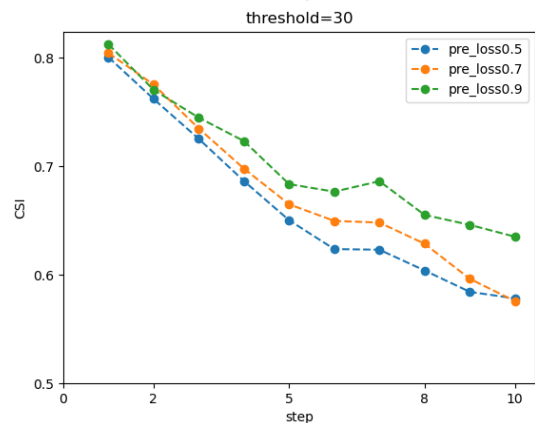
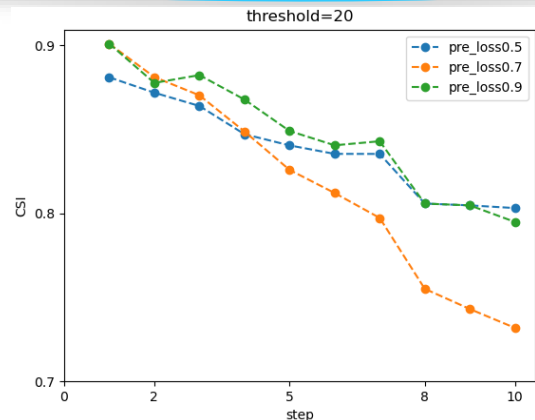


Pre 0.5  
CR 0.5




Pre 0.7  
CR 0.3




Pre 0.9  
CR 0.1




真实值



Pre 0.5+CR 0.5



Pre 0.7+CR 0.3



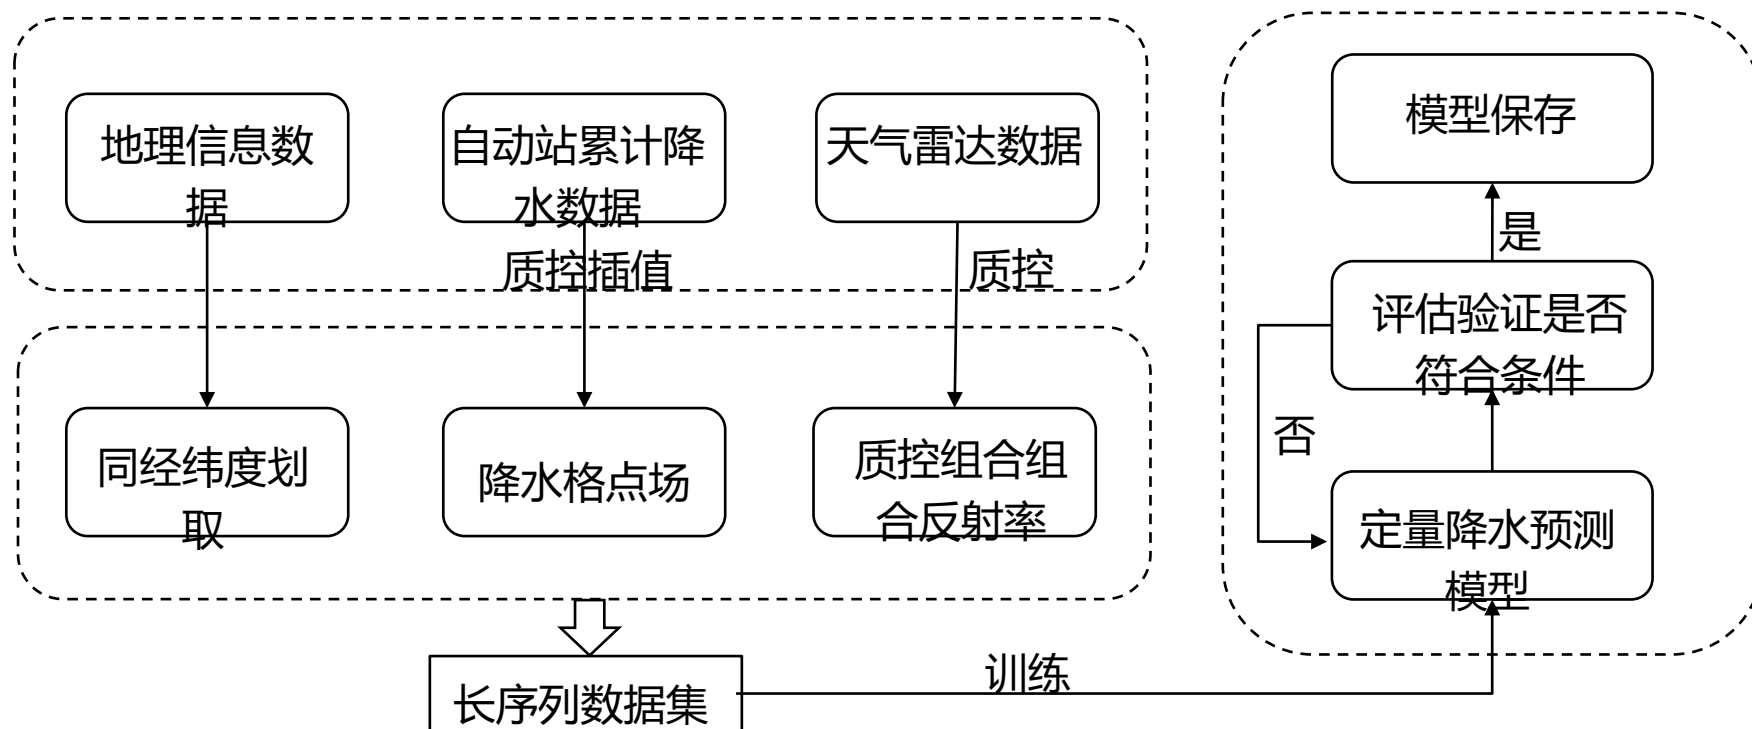
Pre 0.9+CR 0.1

阈值	pre_loss0.5	pre_loss0.7	pre_loss0.9
≥20dBZ	0.84	0.82	0.85
≥30dBZ	0.66	0.68	0.70

CSI评分

## 二、技术进展

### 定量降水外推

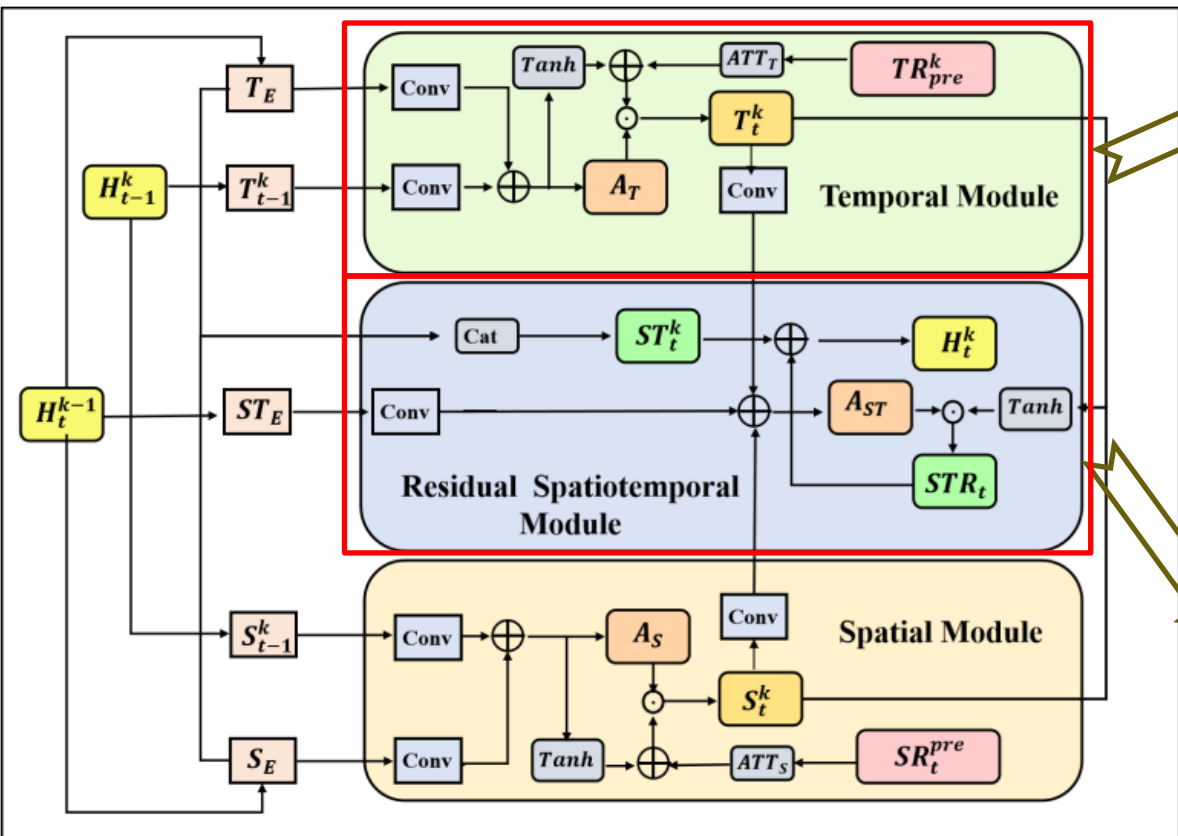


#### 拟解决的关键科学问题

- 在从降水系统中提取时空信息，会丢失一些特征，难以实现精确的临近预报。
- 雷达和降水没有得到有效的融合，难以提取微观物理特征，导致了对高强度降水区域的低估。



# 定量降水外推—模型结构



时间模块联合利用多个时态得到输出状态 $T_t^k$

$$T_t^k = \left( \tanh(W_{T_E} T_E + W_{T_{t-1}^k} T_{t-1}^k) + ATT_T(TR_{pre}^k) \right) \odot A_T$$

$$A_T = \sigma(W_{T_E} T_E + W_{T_{t-1}^k} T_{t-1}^k),$$

其中 $A_T$ 表示时间残差门,  $\tanh(W_{T_E} T_E + W_{T_{t-1}^k} T_{t-1}^k)$ 表示当前的时间信息,  $ATT_T(TR_{pre}^k)$ 表示从t之前的时间步长中保留的时间信息。特别是,  $ATT_T(\cdot)$ 是由卷积层构造的时间注意力网络, 可以根据重要程度帮助融合多个时间状态。

空间模块与时间模块类似得到输出状态 $S_t^k$   
残差时空模块将所有的时空信息聚合到最终的隐藏状态 $H_t^k$

$$A_{ST} = \sigma(W_{ST_{S_E}} ST_{S_E} + W_{T_t^k} T_t^k + W_{S_t^k} S_t^k)$$

$$ST_t^k = W_{1 \times 1} * [T_E, S_E]$$

$$STR_t = A_{ST} \odot \tanh(W_{1 \times 1} * [T_t^k, S_t^k])$$

$H_t^k = S T_t^k + STR_t$ ,  
其中,  $A_{ST}$ 为残差门, 用于聚合预测的时间和空间残差信息。 $ST_t^k$ 表示时空输入特征,  $STR_t$ 表示前帧和未来帧之间的时空残差特征。

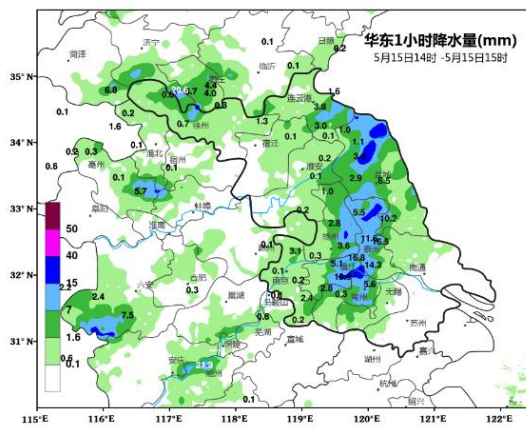
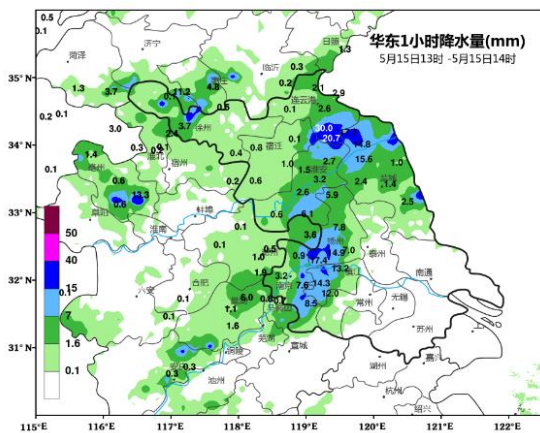
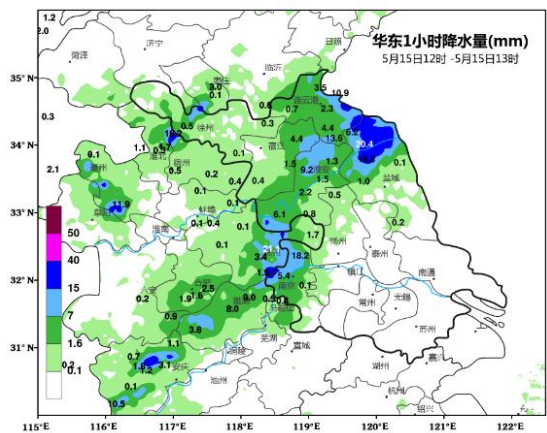
为了进一步提取更有效的深度时空特征, 通常将四个SRU堆叠到一个编码器中。

提出**时空残差单元 (SRU)**, 是为了解决时空数据会相互影响难以提取出复杂的运动特征的问题。




它由三个模块组成: **时间模块**、**空间模块**和**残差时空模块**。每个模块都包括一个残差的结构。它们可以有效地利用先前的时空状态信息, 使特征提取具有更宽的时空接受域。

# 定量降水外推—成效展示

观测

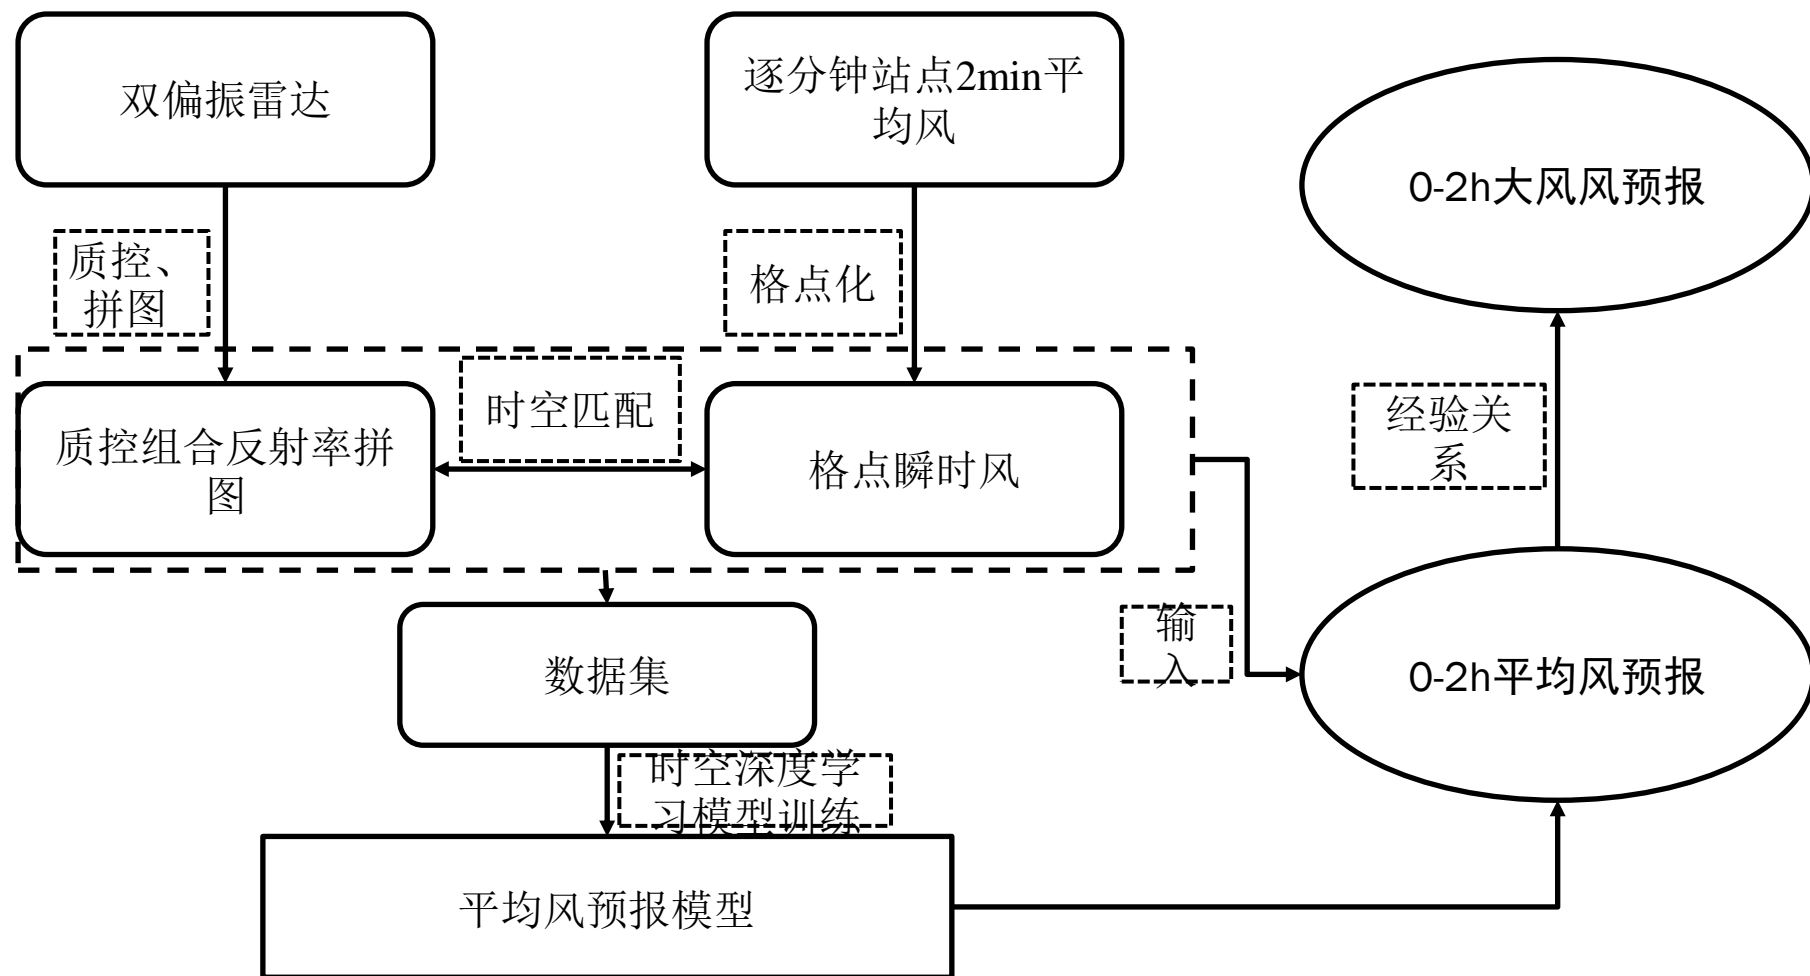


预测结果



## 二、技术进展


## 大风外推



- 构建双因子深度学习模型，平均风因子和组合反射率因子相互进行物理约束。



# 阵风外推—模型结构

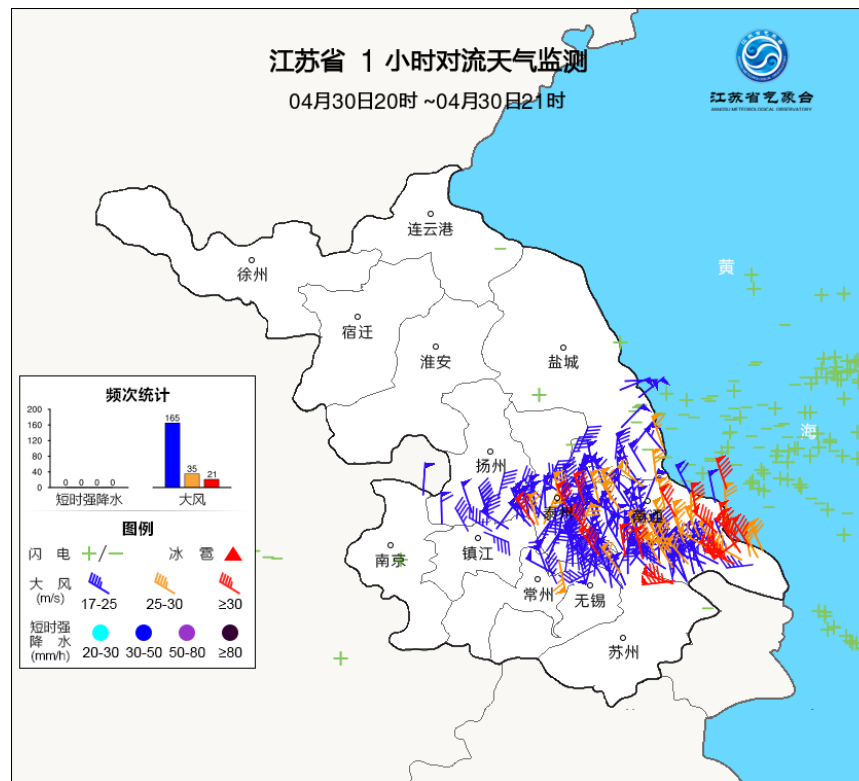




- 采用PhyDnet时空卷积神经网络模型，可充分训练雷暴大风这一类小样本事件，并具有一定物理考量；

构建了风速观测和雷达回波的双通道输入

# 阵风外推—成效展示

## 430南通大风案例



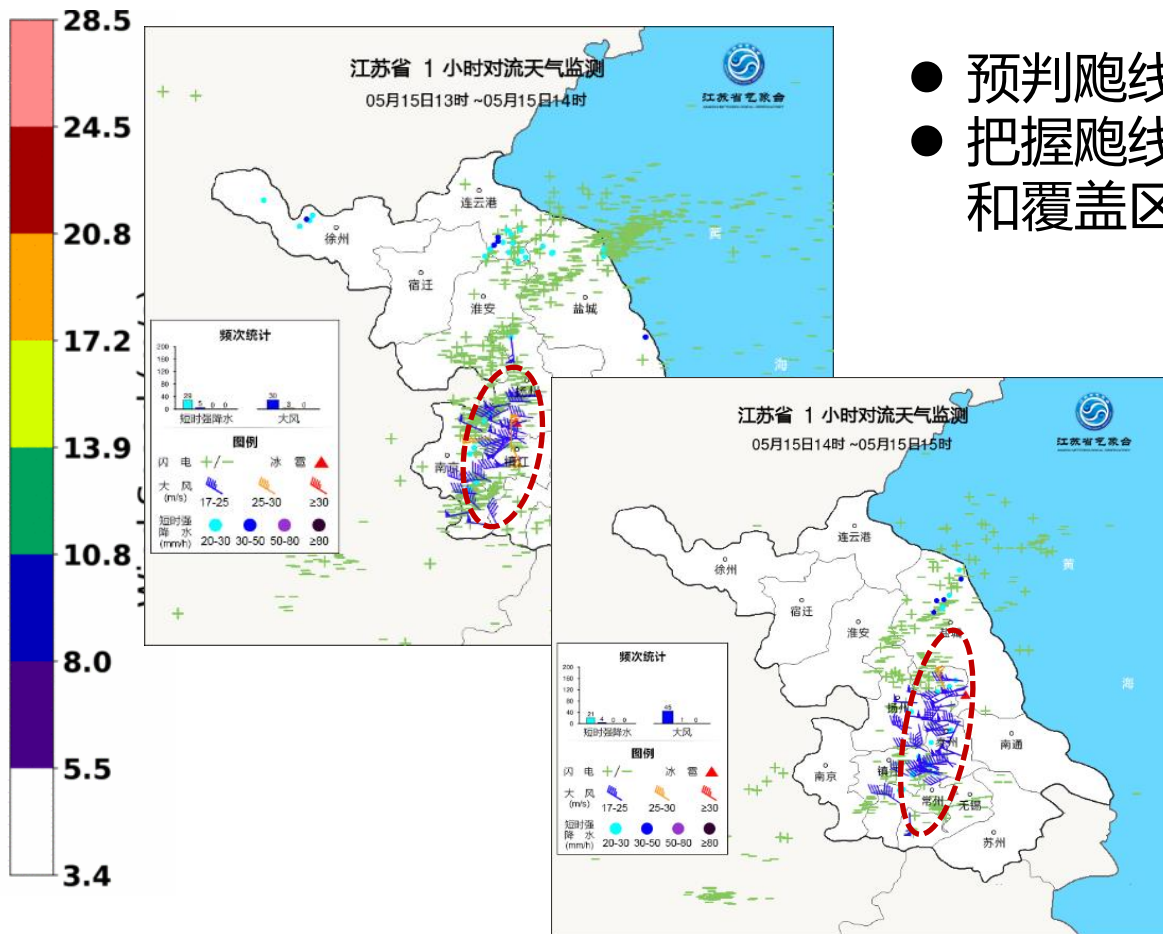

● 提前1.5h指示  
通州湾大风



# 阵风外推—成效展示

## 515飊线大风案例

2021-05-15 13:00:00 + 006min (CANS\_JSMO\_NUIST)



- 预判飊线大风的生成;
- 把握飊线大风的走向和覆盖区域



### 三、关键新技术

### 存在问题

### 模糊问题:

1. 干扰预报员判断;
2. 客观评分虚高。

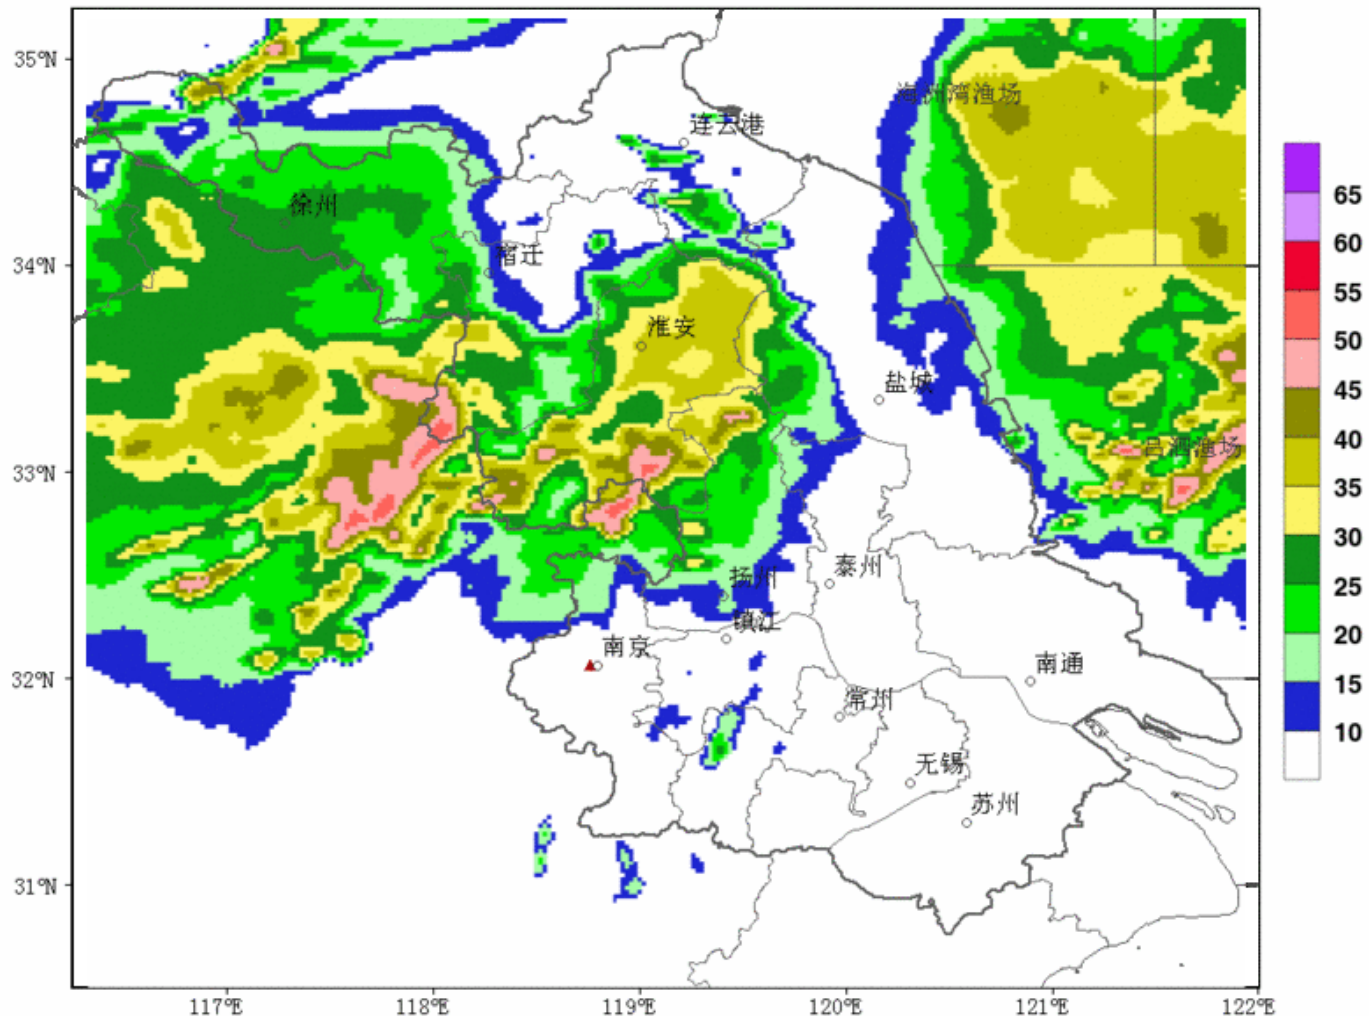


GAN

### 难于收敛, 体现为:

1. 预测场失真
2. TS评分降低

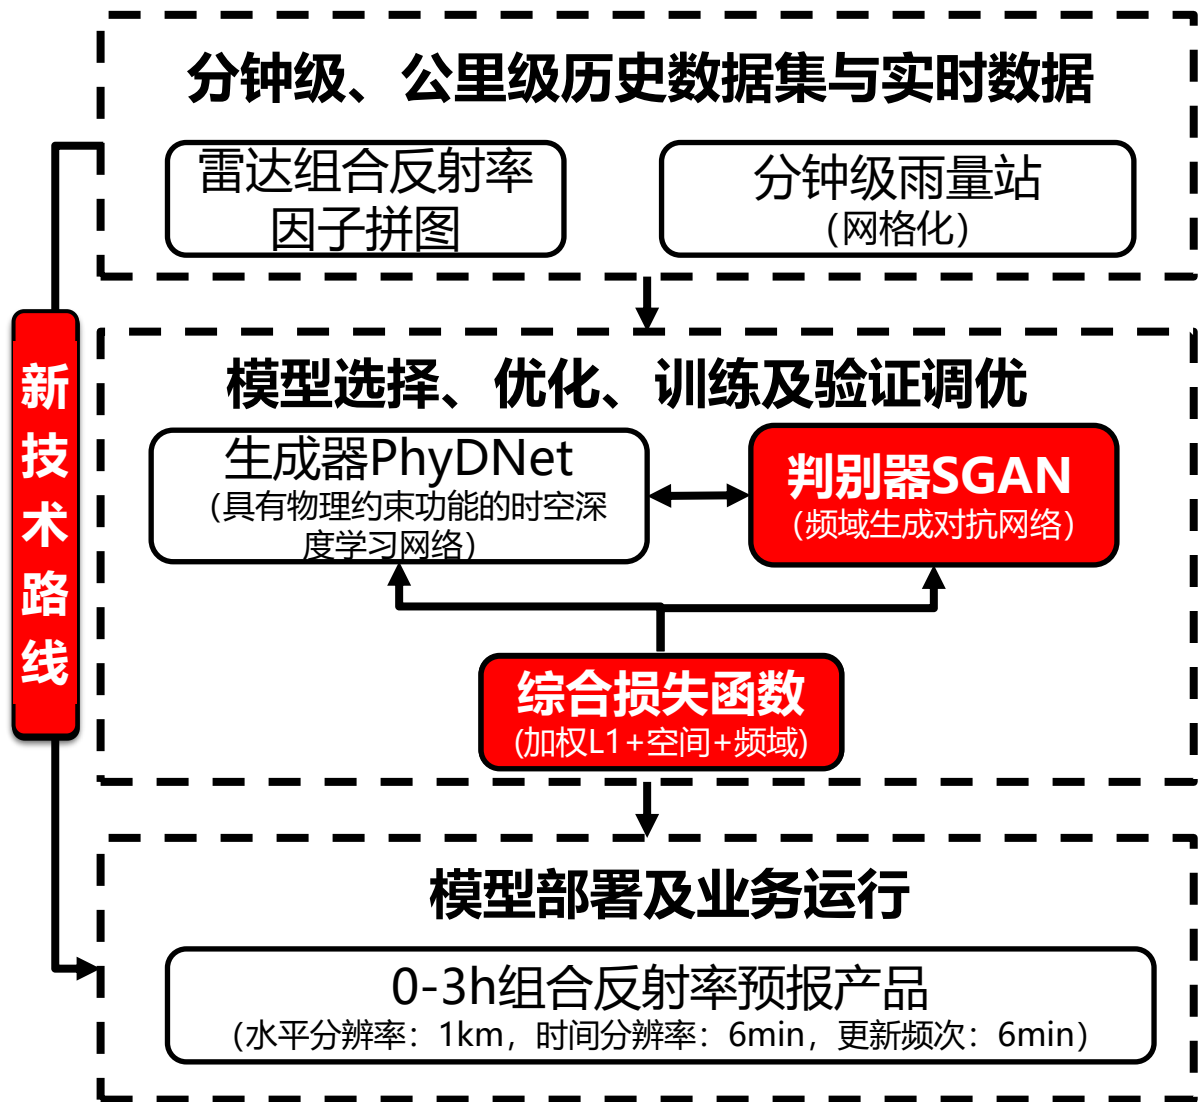
CANS(NJIAS) 组合反射率 ( dbZ ) 202207101848+6MIN->101854





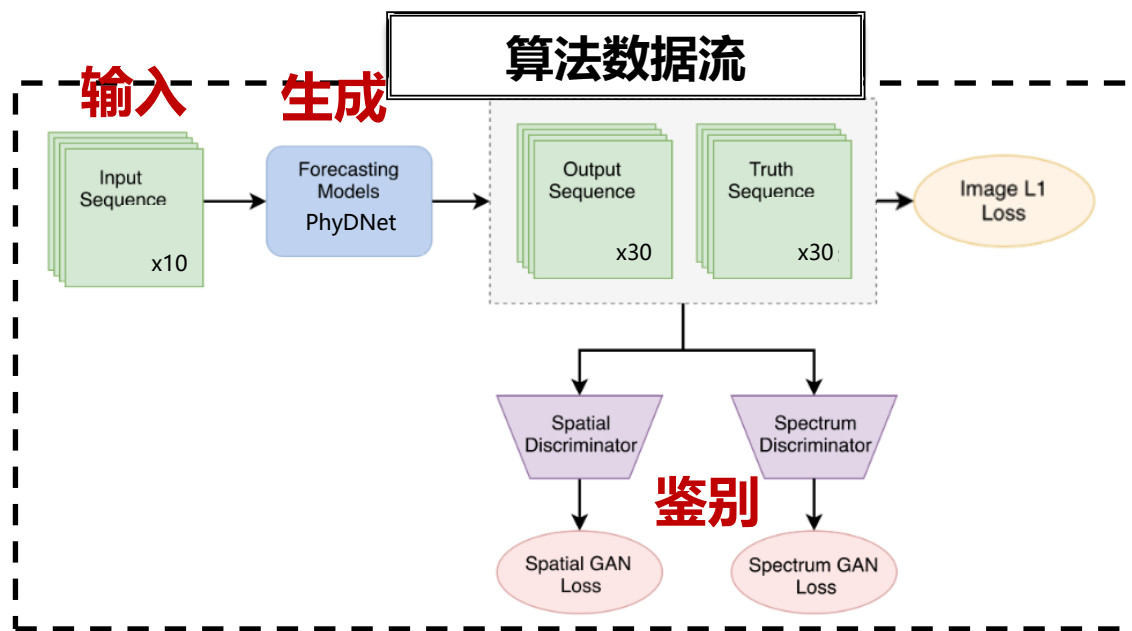
# 三、关键新技术

## 新技术路线



### 优化举措:

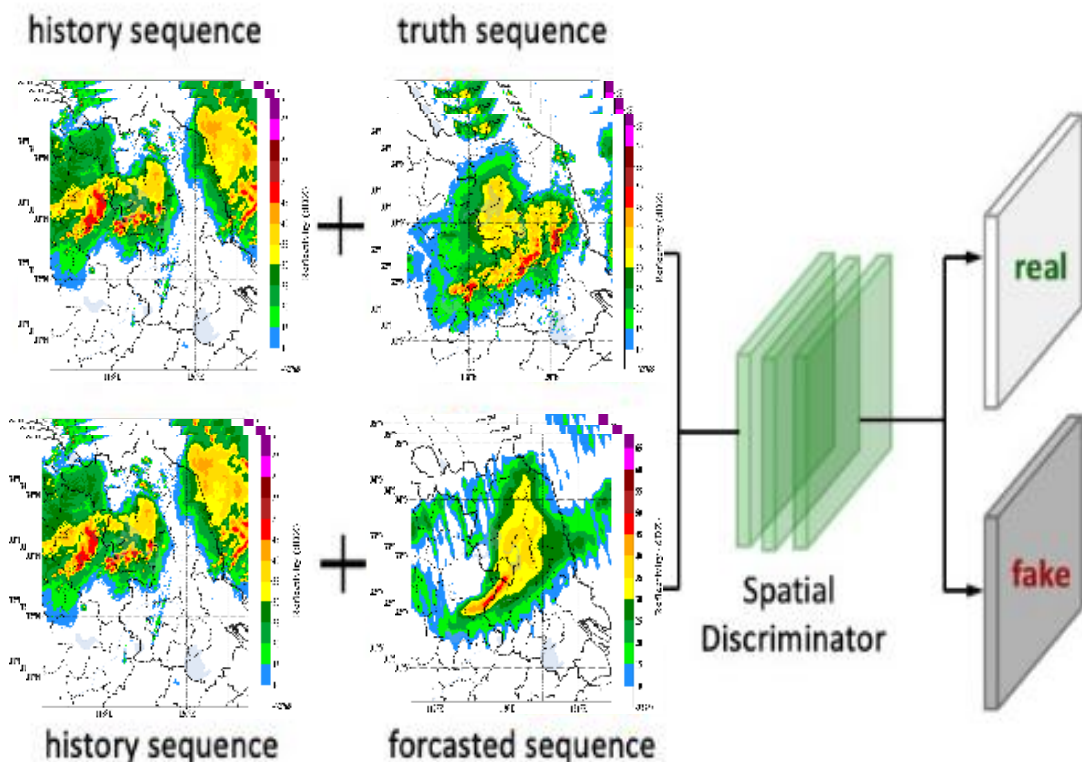
- 1) 提出频域匹配生成对抗网络SGAN (Spectrum GAN) : 对传统GAN进行优化, 使其适用于雷达回波预测任务;
- 2) 优化深度学习模型: PhyDNet与SGAN有机结合;
- 3) 优化损失函数: 建立综合损失函数;
- 4) 优化训练策略: 改善GAN不易收敛的问题。



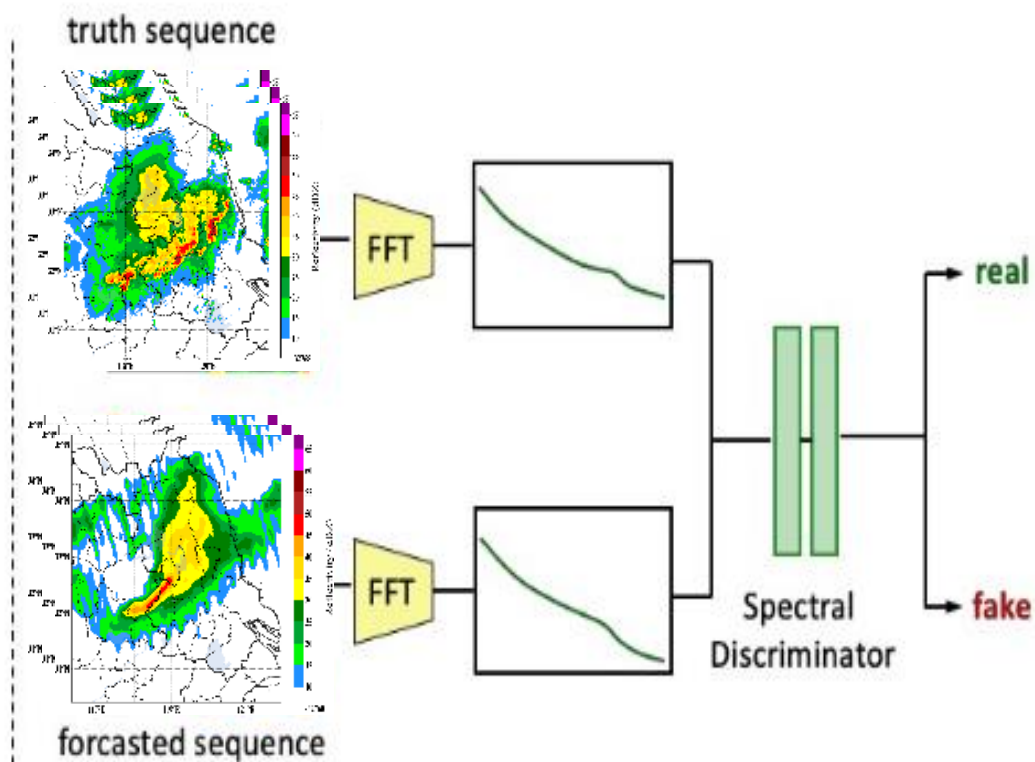
# 三、关键新技术

## 技术路线评述GAN→SGAN

### 传统GAN



### 频域匹配GAN

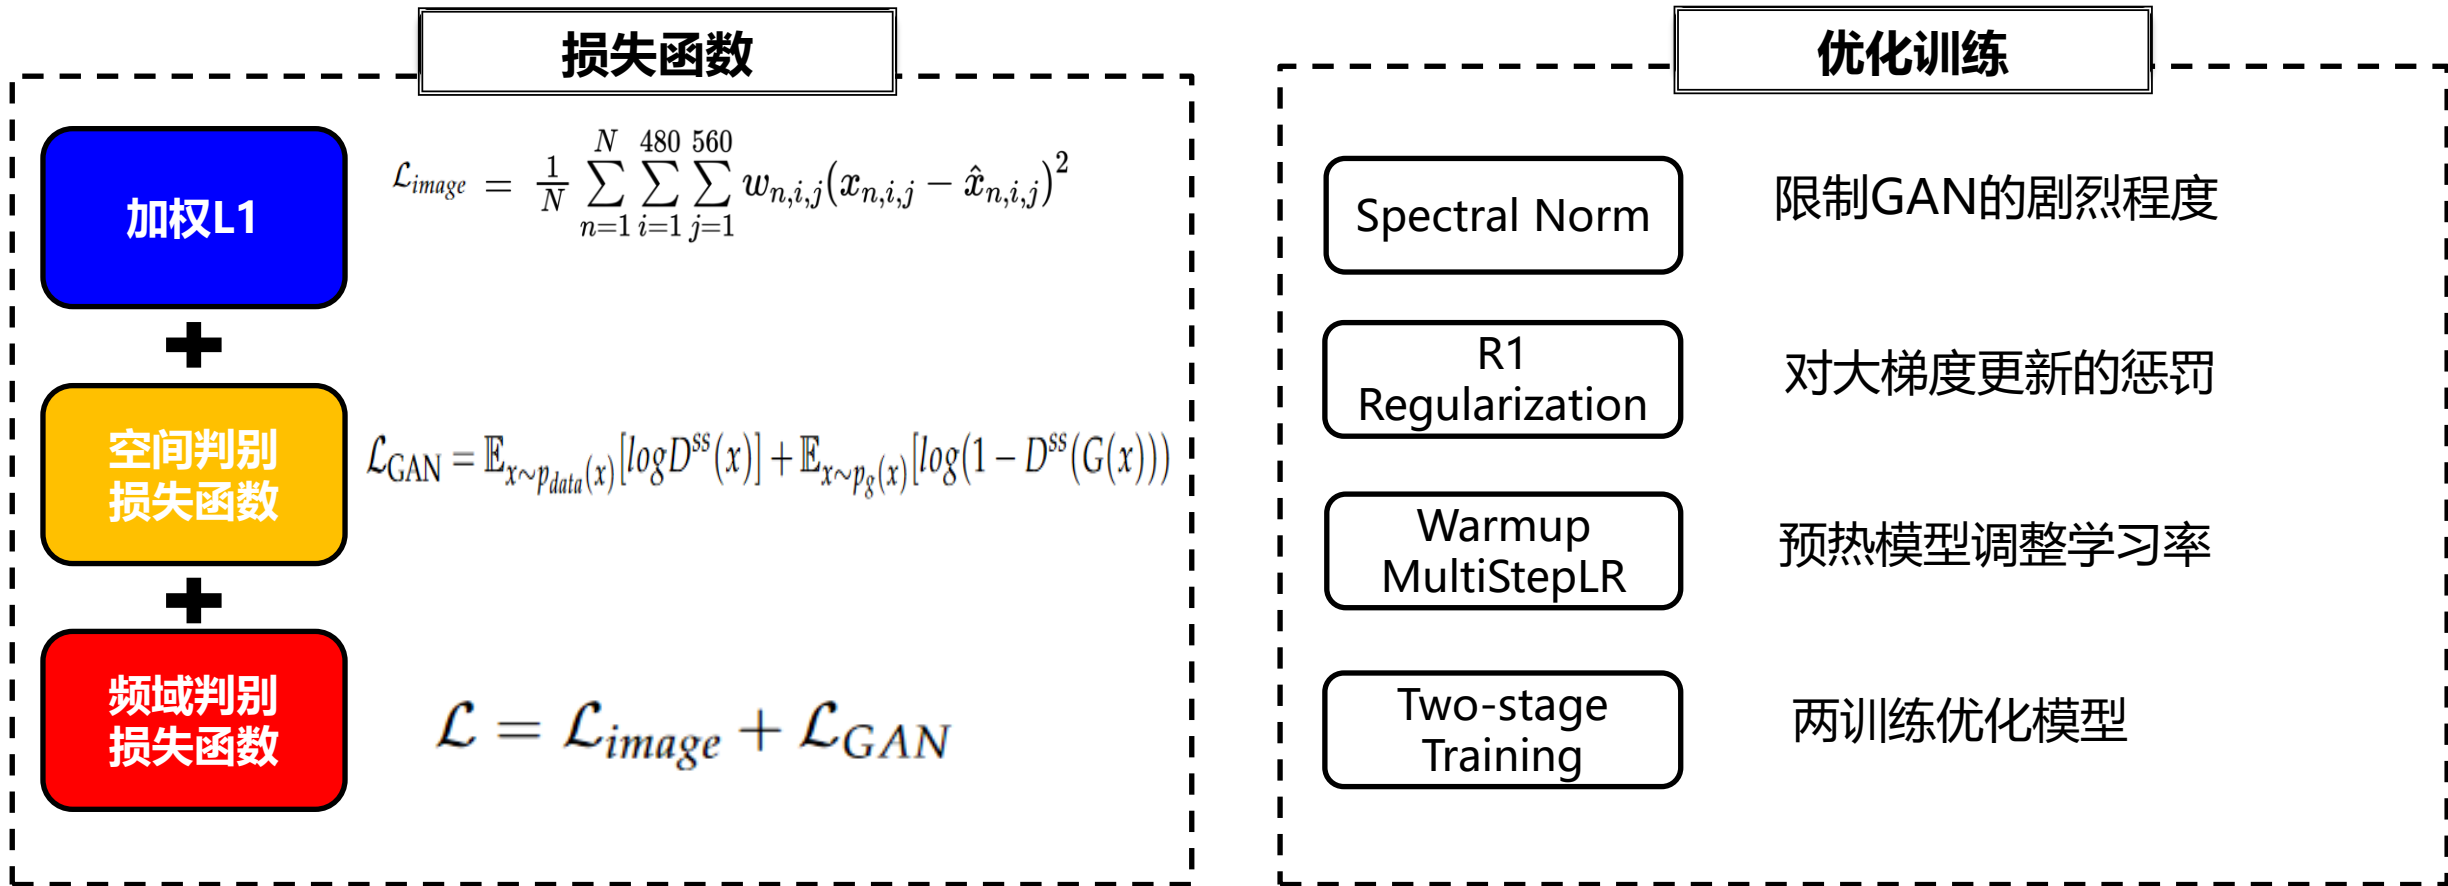


低频域对应较低阈值和大尺度回波，高频域对应于高阈值和小尺度回波



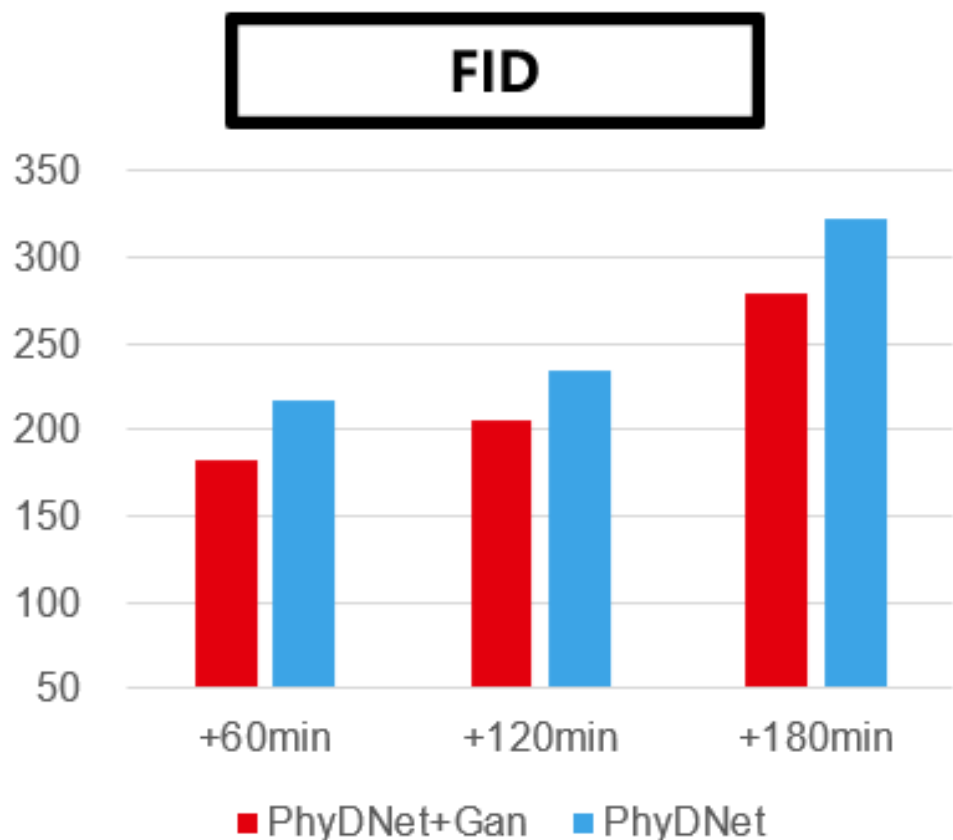
# 三、关键新技术

## 技术路线评述：损失函数优化







SGAN+PhyDNet深度学习新模型既改善“模糊”问题，又优化预测评分

## 四、检验评估 | 客观评分



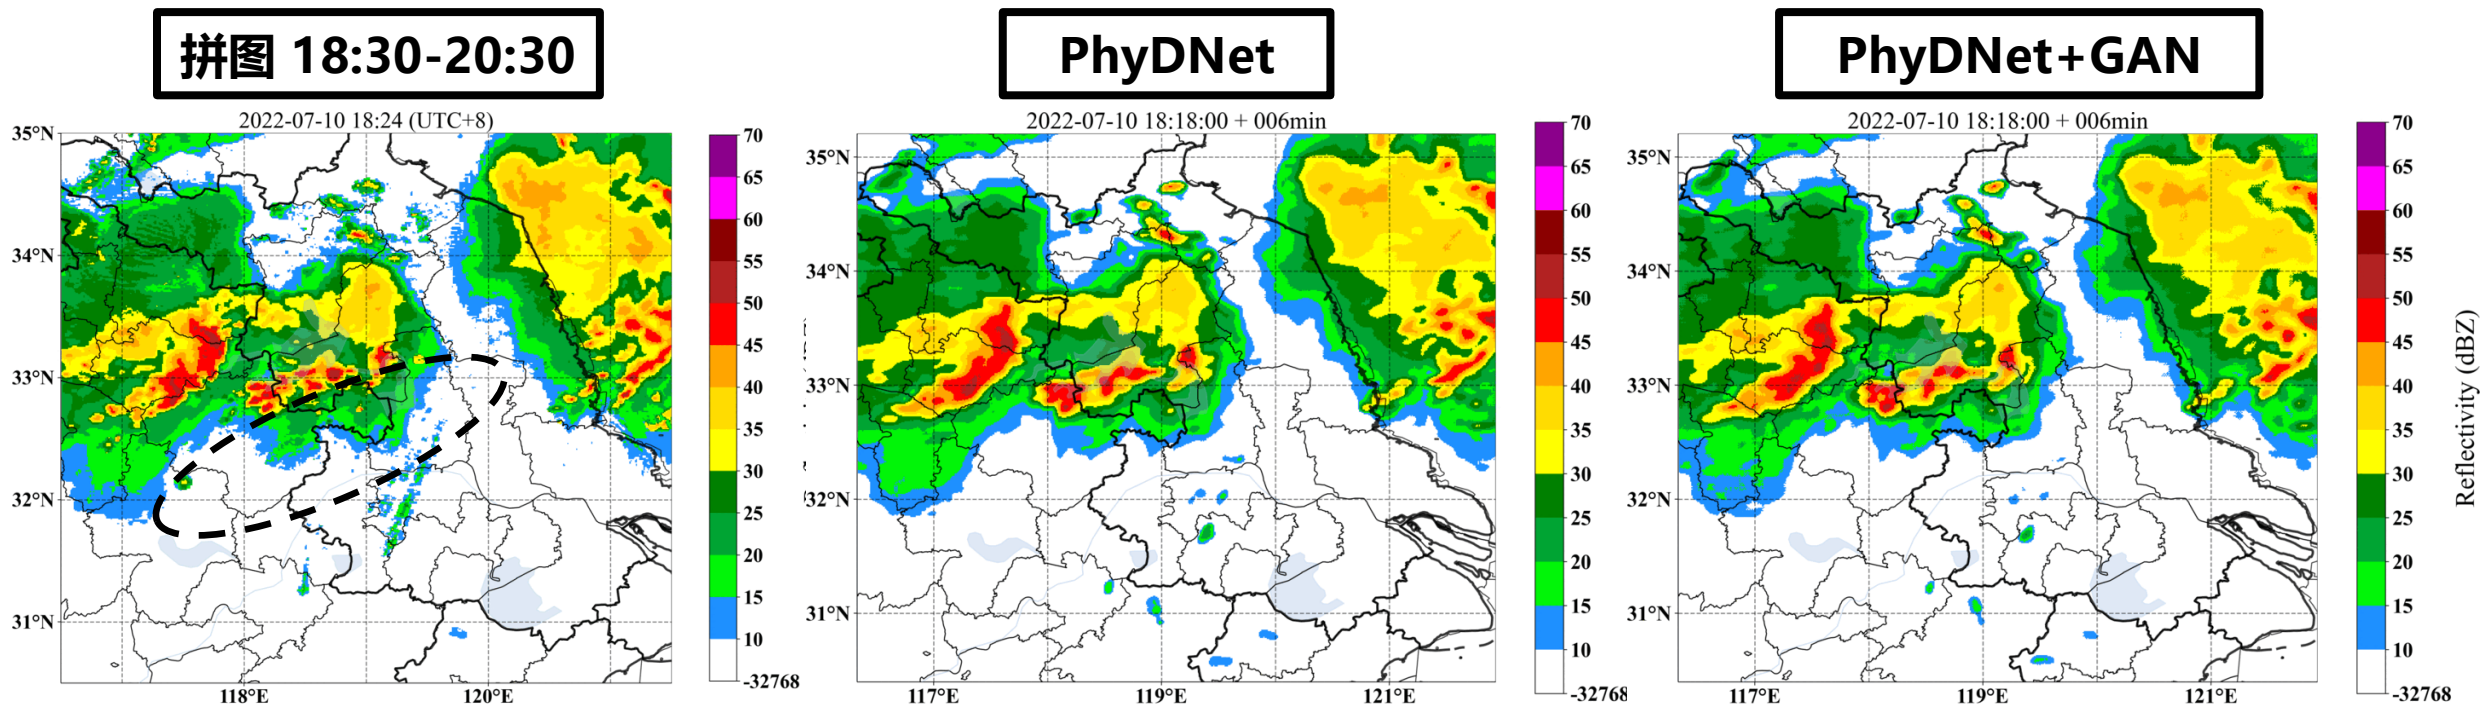
克服“模糊”问题：FID降低



优化评分表现：提升高阈值TS

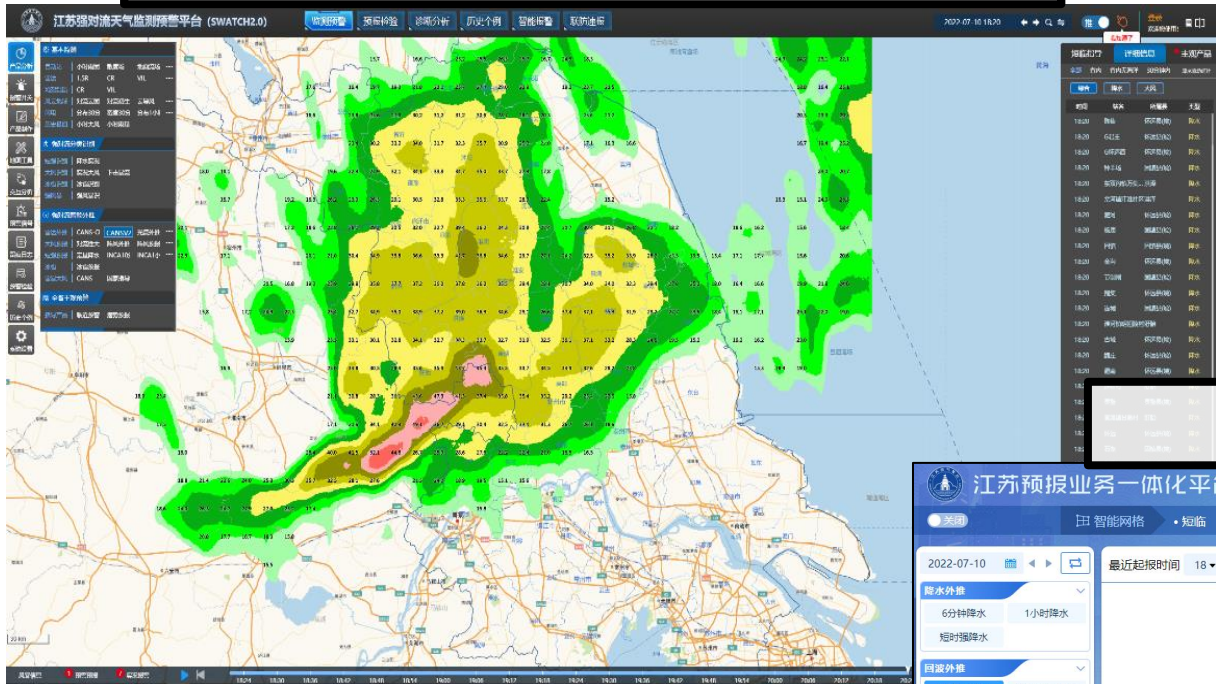
# 四、检验评估 | 典型案例

## 2022年7月10日飊线大风案例

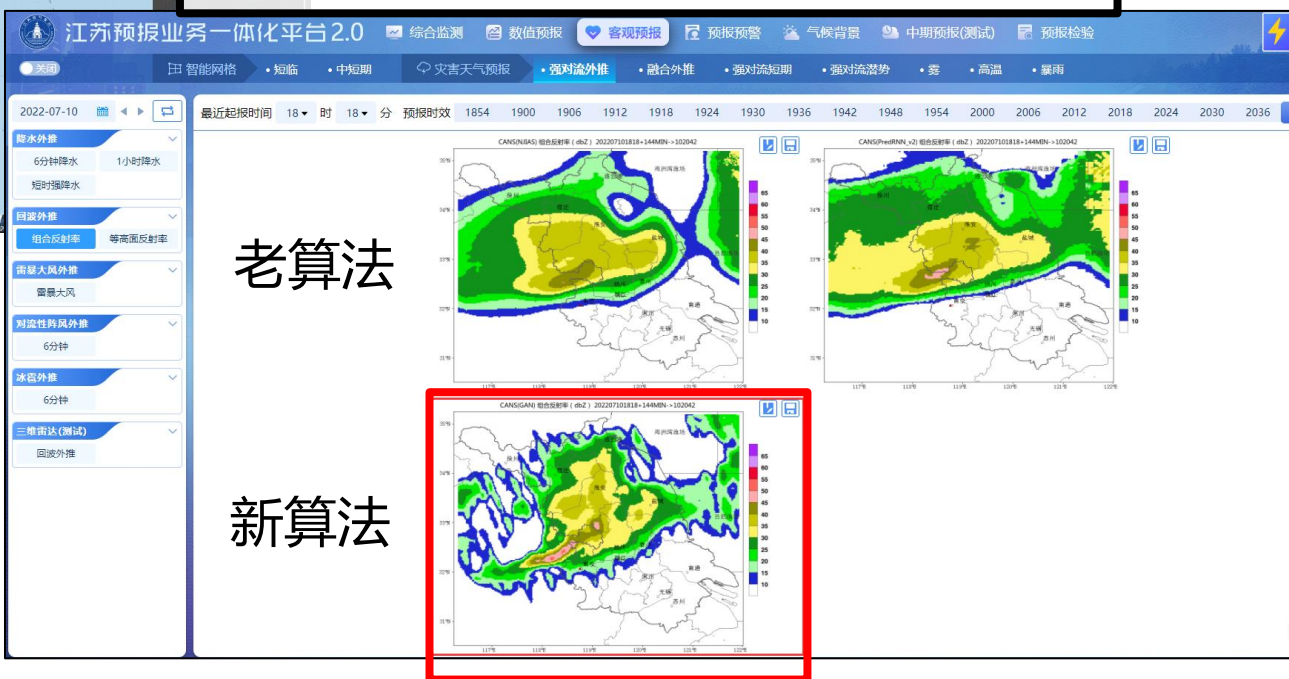


# 五、业务应用

## 江苏强对流监测预警平台 SWATCH2.0



## 江苏预报业务一体化平台





# 六、影响和评价

## 创新成果-论文发表

### 发明专利和SCI论文发表（Atmosphere, 2022年）

- rcLSTM&GAN-rcLSTM模型

Open Access Article

#### GAN-rcLSTM: A Deep Learning Model for Radar Echo Extrapolation

by  Huantong Geng<sup>1</sup>,  Tianlei Wang<sup>1,\*</sup>,  Xiaoran Zhuang<sup>2</sup>,  Du Xi<sup>2</sup>,  Zhongyan Hu<sup>1</sup> and  Liangchao Geng<sup>1</sup>

<sup>1</sup> School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China

<sup>2</sup> Jiangsu Meteorological Observatory, Nanjing 210008, China

\* Author to whom correspondence should be addressed.

Academic Editor: Alexei Dmitriev

Atmosphere 2022, 13(5), 684; <https://doi.org/10.3390/atmos13050684>

Received: 2 March 2022 / Revised: 15 April 2022 / Accepted: 20 April 2022 / Published: 24 April 2022



耿焕同等：一种基于天气雷达的短临智能外推方法

[1] Geng, H.; Wang, T.; Zhuang, X.; Xi, D.; Hu, Z.; Geng L. GAN-rcLSTM: A Deep Learning Model for Radar Echo Extrapolation [J]. Atmosphere, 2022, 13(5), 684. <https://doi.org/10.3390/atmos13050684> (SCI)

[2] Huantong Geng and Liangchao Geng. MCCS-LSTM: Extracting Full-Image Contextual Information and Multi-Scale Spatiotemporal Feature for Radar Echo Extrapolation [J]. Atmosphere, 2022, 13(2), 192, <https://doi.org/10.3390/atmos13020192> (SCI)



# 六、影响和评价



Article

## Towards a More Realistic and Detailed Deep-Learning-Based Radar Echo Extrapolation Method

Yuan Hu <sup>1,\*,†</sup>, Lei Chen <sup>1,†</sup>, Zhibin Wang <sup>1</sup>, Xiang Pan <sup>1,2</sup> and Hao Li <sup>1</sup>

<sup>1</sup> DAMO Academy, Alibaba Group, Beijing 100102, China; fanjiang\_@alibaba-inc.com (J.C.); zhibin\_wang@alibaba-inc.com (Z.W.); panxiang@small.njtu.edu.cn (X.P.); lihao\_li@alibaba-inc.com (H.L.)  
<sup>2</sup> Key Laboratory of Mesoscale Severe Weather/MOR, School of Atmospheric Sciences, Nanjing University, Nanjing 210033, China  
 \* Correspondence: lavenderhy@alibaba-inc.com; Tel.: +86-816-9963  
 † These authors contributed equally to this work.

**Abstract:** Deep-learning-based radar echo extrapolation methods have achieved remarkable progress in the precipitation nowcasting field. However, they suffer from a common notorious problem—they tend to produce blurry predictions. Although some efforts have been made in recent years, the blurring problem is still under-addressed. In this work, we propose three effective strategies to assist deep-learning-based radar echo extrapolation methods to achieve more realistic and detailed prediction. Specifically, we propose a spatial generative adversarial network (GAN) and a spectrum GAN to improve image fidelity. The spatial and spectrum GANs aim at penalizing the distribution discrepancy between generated and real images from the spatial domain and spectral domain, respectively. In addition, a masked style loss is devised to further enhance the details by transferring the detailed texture of ground truth radar sequences to extrapolated ones. We apply a foreground mask to prevent the background noise from transferring to the outputs. Moreover, we also design a new metric termed the power spectral density score (PSDS) to quantify the perceptual quality from a frequency perspective. The PSDS metric can be applied as a complement to other visual evaluation metrics (e.g., FPIPS) to achieve a comprehensive measurement of image sharpness. We test our approaches with both ConvLSTM baseline and U-Net baseline, and comprehensive ablation experiments on the SEVIR dataset show that the proposed approaches are able to produce much more realistic radar images than baselines. Most notably, our methods can be readily applied to any deep-learning-based spatiotemporal forecasting models to acquire more detailed results.

**Keywords:** realistic radar echo extrapolation; generative adversarial networks; style loss; power spectral density



Citation: Hu, Y.; Chen, L.; Wang, Z.; Pan, X.; Li, H. Towards a More Realistic and Detailed Deep-Learning-Based Radar Echo Extrapolation Method. *Remote Sens.* **2022**, *14*, 24. <https://doi.org/10.3390/rs14010024>

Academic Editors: Yanguan Chen, Subhas Mukhopadhyay, Nunzio Cornaro, V. Jara, Deen, Janssep Lee and Simone Marais

Received: 29 November 2021  
 Accepted: 21 December 2021  
 Published: 22 December 2021

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

### 1. Introduction

Precipitation nowcasting, especially very-short-term (e.g., 0–3 h) forecasting, has attracted much research interest in recent years, as it is beneficial to many practical applications such as thunderstorm alerting, flight arrangement, public decision making, etc. Precipitation nowcasting is mostly performed based on extrapolation of observation data, such as radar echo maps [1,2]. Traditionally, the extrapolation of radar echo images is conducted either by storm-tracking methods [3–5] or optical flow-based methods [6,7]. These methods often work well for capturing simple advection characteristics, whereas they struggle to predict more complex evolution of the precipitation system (e.g., convective development).

Recently, with strong power to extract features from ever-increasing streams of geospatial data [8], deep learning (DL) has been successfully applied to solving remote sensing problems, like vegetation detection [9] and building extraction [10]. For precipitation nowcasting, DL-based methods have also achieved noticeably good performance, and significantly surpass numerical weather prediction (NWP) and traditional extrapolation

1. Hu Yuan, **Chen Lei\***, Wang Zhibin, et al.2022. Towards a More Realistic and Detailed Deep-Learning-Based Radar Echo Extrapolation Method. *Remote Sensing*, 14 (24) , doi.org/10.3390/rs14010024 (SCI二区)
2. **Zeng K, J. Z. Min\***, and X. R. Zhuang, 2022. A GAN based radar echo nowcasting model and its application in Eastern China for days of active convection.(To be Submitted)
3. 庄潇然, 郑玉, 陈昊, 等. 江苏海陆一体化分类强对流概率预报系统. 2021SR1853971. (软件著作权)


Observing studies



©Vaisala



Ensemble forecasting



Data Assimilation

敬请各位专家指正!