



## 基于ConvLSTM融合RMAPS-NOW数据的雷达回波外推研究

王善昊 胡志群 王福增 陈杰鑫

### A study on radar echo extrapolation based on ConvLSTM fusion of RMAPS-NOW data

WANG Shan hao, HU Zhi qun, WANG Fu zeng, CHEN Ji exin

在线阅读 View online: <https://doi.org/10.11676/qxxb2024.20230135>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于自注意力和门控循环神经网络的雷达回波外推算法研究

Improving radar echo extrapolation algorithms based on self-attention and gated recurrent neural networks

气象学报. 2024, 82(1): 127–135 doi: [10.11676/qxxb2024.20230053](https://doi.org/10.11676/qxxb2024.20230053)

#### 基于深度学习的天气雷达回波序列外推及效果分析

Extrapolation and effect analysis of weather radar echo sequence based on deep learning

气象学报. 2021, 79(5): 817–827 doi: [10.11676/qxxb2021.041](https://doi.org/10.11676/qxxb2021.041)

#### 结合中尺度模式物理约束的雷达回波临近外推预报方法研究

A study on radar echo extrapolation nowcasting method combined with physical constraints of mesoscale model

气象学报. 2022, 80(2): 257–268 doi: [10.11676/qxxb2022.020](https://doi.org/10.11676/qxxb2022.020)

#### 利用深度学习开展偏振雷达定量降水估测研究

A study on polarization radar quantitative precipitation estimation using deep learning

气象学报. 2022, 80(4): 565–577 doi: [10.11676/qxxb2022.046](https://doi.org/10.11676/qxxb2022.046)

#### 基于深度学习的强对流高分辨率临近预报试验

High resolution nowcasting experiment of severe convections based on deep learning

气象学报. 2019, 77(4): 715–727 doi: [10.11676/qxxb2019.036](https://doi.org/10.11676/qxxb2019.036)

#### 基于深度学习的京津冀地区精细尺度降水临近预报研究

A study on fine scale precipitation nowcasting in Beijing–Tianjin–Hebei region based on deep learning

气象学报. 2022, 80(4): 546–564 doi: [10.11676/qxxb2022.027](https://doi.org/10.11676/qxxb2022.027)



扫码关注公众号，获取更多信息！

# 基于 ConvLSTM 融合 RMAPS-NOW 数据的 雷达回波外推研究\*

王善昊<sup>1,2</sup> 胡志群<sup>2,3</sup> 王福增<sup>1</sup> 陈杰鑫<sup>2,4</sup>  
WANG Shanhao<sup>1,2</sup> HU Zhiqun<sup>2,3</sup> WANG Fuzeng<sup>1</sup> CHEN Jiexin<sup>2,4</sup>

1. 成都信息工程大学电子工程学院, 成都, 610225
2. 中国气象科学研究院灾害天气国家重点实验室, 北京, 100081
3. 中国气象局大气探测重点开放实验室, 成都, 610225
4. 成都信息工程大学大气科学学院, 成都, 610225

1. School of Electronic Engineering, Chengdu University of Information Technology, Chengdu 610225, China

2. State Key Lab of Severe Weather, Chinese Academy of Meteorological Sciences, Beijing 100081, China

3. Key Laboratory of Atmosphere Sounding, CMA, Chengdu 610225, China

4. School of Atmospheric Sciences, Chengdu University of Information Technology, Chengdu 610225, China

2023-09-20 收稿, 2024-01-16 改回.

王善昊, 胡志群, 王福增, 陈杰鑫. 2024. 基于 ConvLSTM 融合 RMAPS-NOW 数据的雷达回波外推研究. 气象学报, 82(4): 554-567

Wang Shanhao, Hu Zhiqun, Wang Fuzeng, Chen Jiexin. 2024. Extrapolation of radar echo based on ConvLSTM with fusion of RMAPS-NOW data. *Acta Meteorologica Sinica*, 82(4):554-567

**Abstract** Radar echo extrapolation is one of the main reference criteria for nowcasting, weather modification operation and evaluation of its effectiveness. Therefore, rapid and accurate echo extrapolation technology is always a research hotspot in the field of radar meteorology. In recent years, deep learning-based spatiotemporal sequence prediction models have been widely applied in radar echo extrapolation. However, most of the inputs to these extrapolation networks are only grayscale images converted from the radar echo intensity products shown with 16-level color code pseudo colors, and thus some echo details are lost. The error inevitably increases with the extrapolation time. The initiation, disappearance, movement, and evolution of echoes are closely related to weather background. Based on this consideration, some physical products in the initial zero field of the rapid-refresh multi-scale analysis and prediction system-nowcasting (RMAPS-NOW) developed by the Institute of Urban Meteorology, CMA, are integrated with the raw data of the North China radar mosaic to construct multiple radar cells. Based on convolutional long short-term memory (ConvLSTM) network, a multi-channel radar echo extrapolation (MR-ConvLSTM) network is designed by using the radar cells as inputs. In addition, considering the smoothness of the convolutional algorithm, a self-defined loss function is designed to increase the spatiotemporal weight of the echo intensity for spatiotemporal attenuation correction. A total of 13000 samples of radar mosaic and RMAPS-NOW data during June–September from 2018 to 2021 over the area of (40.65°–41.65°N, 114°–115.4°E) are selected. 80% of the samples, i.e., 10400 samples, are used as the training data; and 20% of the samples, i.e. 2600, are used as the test data. The introduced physical products include  $u$ ,  $v$  wind (1350 m), relative humidity (150 m), and horizontal divergence (1350 m), etc. at multiple altitude levels. Based on ConvLSTM and MR-ConvLSTM with the self-defined loss function, 5 extrapolation models are

\* 资助课题: 广东省重点领域研发计划(2020B1111200001)、海南省南海气象防灾减灾重点实验室开放基金项目(SCSF202301)、中国气象局大气探测重点开放实验室开放课题(U2021Z05)、国家重点研发计划(2022YFC3003900)。

作者简介: 王善昊, 主要从事雷达气象研究。E-mail: wangshanhao0205@163.com

通信作者: 胡志群, 主要从事人工智能气象应用与雷达气象研究。E-mail: huzq@cma.gov.cn

then trained respectively. Using critical success index (CSI), hit rate (POD), and false alarm rate (FAR) as evaluation indexes, the models are evaluated by the test data. At the values of reflectivity threshold 20, 30, and 35 dBz, the average values of CSI calculated by the MR-ConvLSTM-based and the self-defined function models with integrated physical products are 4.67%, 13.8%, 5.98% higher and the average values of POD are 3.1%, 7.68%, 8.38% higher, while average values of FAR are 6.37%, 8.54%, 10.17% lower than those by the ConvLSTM-based model without integrated physical products, respectively. The model with three physical products introduced (RH,  $u$ -wind,  $v$ -wind) performs the best for all the indexes, and average CSI and POD are respectively 16.01% and 13.38% higher while FAR is 14.88% lower than those without physical products. From the visualization cases of model application, it can also be seen that the introduction of physical quantities effectively improves the accuracy of radar echo extrapolation. These results indicate that the MR-ConvLSTM models and self-defined loss function have robust generalization ability.

**Key words** Radar echo extrapolation, Deep learning, RMAPS-NOW, MR-ConvLSTM network, Self-defined loss function

**摘要** 雷达回波外推是临近预报、人工影响天气作业及效果评估的主要参考依据之一,快速准确的回波外推技术一直是雷达气象领域的研究热点。近年来,基于深度学习的时空序列预测模型在雷达回波外推中得到了广泛应用。然而,这些外推网络架构的输入大多用 16 级伪彩色雷达回波强度产品转化而来的灰度图,丢失了许多回波细节,并且随着外推时间延长,误差不可避免地增大。回波的生消、移动、演变与天气背景紧密相关,因此,将北京城市气象研究院研发的新一代快速更新多尺度资料分析和预报系统的临近数值预报子系统(RMAPS-NOW)初始零场的部分物理量产品融入华北雷达拼图原始数据,构建多个雷达单元(Radar cells),并将这些雷达单元作为输入,基于卷积长短期记忆网络(ConvLSTM),设计了一个多通道雷达回波外推网络架构(MR-ConvLSTM)。另外,考虑到卷积算法的平滑性,构建了自定义损失函数,增加回波强度的时空权重进行时空衰减订正。选取(40.65°—41.65°N, 114°—115.4°E)内 2018—2021 年的 6—9 月共 13000 组华北雷达组合反射率因子拼图及 RMAPS-NOW 初始零场数据,其中的 80% 共 10400 组为训练集,20% 共 2600 组为测试集。引入的物理量包括多个高度层的  $u$ 、 $v$  风(1350 m),相对湿度(RH, 150 m),水平散度(1350 m)等,基于 ConvLSTM 及 MR-ConvLSTM 加自定义损失函数,分别训练得到 5 个雷达回波外推模型。采用临界成功指数(CSI)、命中率(POD)、虚警率(FAR)作为评价指标,利用测试集对所有模型进行评估。基于引入物理量的 MR-ConvLSTM 训练得到的模型在 20、30、35 dBz 反射率阈值下,比未引入物理量的基于 ConvLSTM 的外推模型 CSI 值平均高 4.67%、13.8%、5.98%,POD 值平均高 3.1%、7.68%、8.38%,FAR 值平均低 6.37%、8.54%、10.17%,同时引入 3 种物理量(RH、 $u$ 、 $v$ )的外推模型在不同阈值的各项指标中综合表现最好,其 CSI、POD 值在 3 种不同阈值下比未引入物理量模型平均高 16.01%、13.38%,FAR 值平均低 14.88%。从模型应用的个例可视化也可以看出,引入物理量后有效提升了雷达回波外推的准确度,证明基于 MR-ConvLSTM 架构训练的雷达回波外推模型有较强的泛化能力。

**关键词** 雷达回波外推,深度学习,RMAPS-NOW,MR-ConvLSTM 网络架构,自定义损失函数

**中图分类号** P49

## 1 引言

雷达回波外推是临近预报、人工影响天气作业及效果评估的主要参考依据之一(Ravuri, et al, 2021)。快速准确的回波外推技术,一直是雷达气象领域的研究热点(俞小鼎, 2013)。雷达回波外推是由前面多个时刻的雷达数据构成的一个时间序列,根据回波分布、移动速度和方向变化趋势,通过一定的算法预测一定时间后的回波状态(Shi, et al, 2017),在 0—2 h 内,相比数值天气预报更加快速精确。

传统的雷达回波外推主要技术有交叉相关法(Rinehart, et al, 1978)和单体质心法(Johnson, et al, 1998)。交叉相关法将回波划分为多个区域,通

过计算相邻不同区域的相关确定运动矢量。Rinehart 等(1978)提出了交叉跟踪回波算法(Tracking Radar Echoes by Correlation, TREC),该算法将不同区域的回波图像通过最强相关关系得到回波特征。但这些算法预测的回波都存在随预测时长的延长而衰弱。Li 等(1995)对 TREC 矢量中的噪声进行了消除,并使用变分方法对 TREC 矢量进行约束,提出 COTREC (Continuity of TREC)方法,提升了回波外推的性能。在深度学习出现之前,光流法(Horn, et al, 1981)是回波外推的主流方法之一,它通过计算回波图像像素的瞬时速度,利用相邻之间的关系,来对下一帧进行预测(伊凡, 2013; 张蕾等, 2014; 曹春燕等, 2015),并进一步发展出 Lucas-Kanade 光流法(Lucas, et al, 1981)、Farneback 光流法

(Farneback, 2001; Farneback, 2002)等。Ayzel等(2019)研发了Rainymotion光流平台,后有学者提出DeepFlow(Weinzaepfel, et al, 2013)和PCAFlow(Wulff, et al, 2015)等改进光流法,实现自适应光流参数,相比TREC方法在空间平滑性、多尺度处理和时空一致性方面有明显改善。但是,光流法也一直面临数据特性不匹配、稀疏性、噪声、速度变化等算法难以解决的实际问题。

深度学习为计算机视觉和人工智能带来了革命性的进步,近年来,全世界在人工智能领域不断取得重大突破(Jing, et al, 2020)。深度学习也很快被用于雷达回波外推研究。Shi等(2015)结合卷积神经网络提取的空间特征与长短期记忆网络(LSTM)提取的时间特征特点,提出了卷积长短记忆神经网络(Convolutional Long Short-Term Memory Network, ConvLSTM),首次实现基于深度学习的雷达回波外推。之后,基于ConvLSTM衍生出多种改进的外推模型。Du等(2020)提出一种基于时间注意力编码器-解码器和双向长短记忆网络(Bi-LSTM)自适应学习多元时间特征和隐藏相关特征,提升了外推性能。Bonnet等(2020)使用VPDL PredRNN++预测巴西圣保罗未来1h的反射率图像序列,对降水临近预报有明显改进。黄兴友等(2021)利用多年的雷达探测资料构建数据集,基于ConvLSTM神经网络,同时使用带权重的损失函数进行模型训练,外推结果优于光流法,且对层云降水预报的效果比对流云好。He等(2022)提出了一种改进的卷积门控循环单元(M-ConvGRU)模型,该模型将GRU网络的输入数据和先前输出执行卷积操作,能更好地捕捉雷达回波图中时空相关的特征。Yang等(2023)提出了自注意力机制并将全局时空特征保存到原始时空LSTM中,构建自注意力集成ST-LSTM循环单元(SAST-LSTM),再将多个循环单元堆叠起来构建雷达回波外推网络SAST-Net,试验结果表明比其他模型外推性能表现得更好。方巍等(2023)提出了一种以ConvLSTM为循环单元,构造基于全局通道注意力的预测网络(GCA-ConvLSTM),提高了外推图像的清晰度,有效减轻了外推后期的模糊问题。Guo等(2023)提出一种具有extractor-forecaster架构的3D-UNet-LSTM模型,采用三维UNet从输入雷达图像中提取时空特征,设计Seq2Seq

网络提取特征,对强回波具有较好的时空建模能力。Zheng等(2023)在时空过程强化网络GAN-argcPredNet v1.0基础上,通过强化先前输入信息来减少损失,有效提升了强降雨的预测效果。Lu等(2023)提出多源(MS-ConvLSTM)模型,在数据集中加入了回波顶高(ET)、垂直累积液态水含量(VIL)以及不同高度的雷达反演风场数据来提高降水预报的准确度。

以上模型的输入大多是由16级伪彩色雷达回波强度产品转换的灰度图,不可避免地丢失了许多回波细节信息。另外,回波的生消演变与天气背景息息相关,纯粹用雷达数据驱动的外推模型缺乏大气动力、热力、微物理等物理约束,因此,随着时间的推移,误差会越来越大,特别是缺乏对回波新生、消亡的预测能力,而且这一问题无法通过算法改进来解决。

得益于综合气象观测系统、多源实况融合分析技术和多尺度数值预报模式的快速发展,中国北京、上海和广东等区域气象中心分别建立了时间分辨率10—12 min,空间分辨率1 km×1 km的快速更新分析与预报系统,这些系统的初始零场能够描述天气背景实况信息,而且基本上达到了与雷达探测相同的时、空分辨率,因此,如果能够有效地将这些天气实况信息引入到深度学习回波外推中,将雷达回波融合天气背景的物理量可能极大地提升回波外推模型的准确度。此外,为了减少卷积算法的平滑作用,本研究还自定义损失函数,给予长时序和强回波更恰当的权重,进一步提升模型的外推能力。

## 2 资料来源及数据预处理

所用数据包括华北雷达组合反射率拼图及北京城市气象研究院新一代快速更新多尺度资料分析和预报系统(RMAPS)的临近数值预报子系统(RMAPS-NOW)的初始零场。因本研究主要探讨融合天气背景对雷达回波外推改进的可行性,受算力所限,仅选取(40.65°—41.65°N, 114°—115.4°E)范围(图1左上角黑色框区)数据训练建模。该范围地形、地貌复杂,一些纵贯中国东部南北、横穿中国北方东西的地质构造线在这里交汇,中国几个大的自然地理单元也在这里交界,使该范围内拥有高原、山地、盆地、河川等地貌类型和内陆、外流两

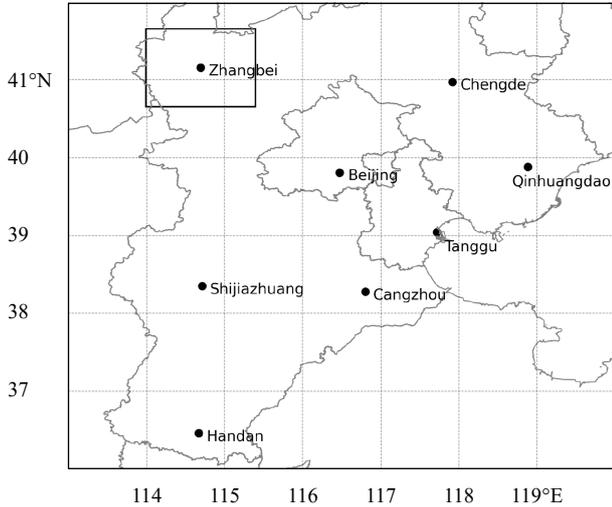


图 1 RMAPS-NOW 预报场(全图)及本研究模型训练、测试及个例 1—3 所选数据范围(左上黑色线框区)(黑点为业务布网的雷达站点)

Fig. 1 RMAPS-NOW forecast field (full image) and data range selected for model training, testing, and cases 1 to 3 in this study (with a black box in the upper left) (black dots represent radar stations deployed for the operational network)

种水系,而且该范围涵盖北京冬季奥林匹克运动会张家口赛区,因此地面资料较多、较全。数据资料时间为 2018 年至 2021 年的 6—9 月。

### 2.1 雷达拼图数据

雷达拼图数据来自于国家气象信息中心气象大数据云平台“天擎”,数据空间分辨率为  $0.01^\circ \times 0.01^\circ$ ,时间分辨率为 6 min。将回波强度小于 0 dBz 的数据设置为 0,大于 70 dBz 设置为 70,由式(1)对数据进行归一化。

$$V_{\text{norm}} = \frac{V_i - V_{\text{min}}}{V_{\text{max}} - V_{\text{min}}} \quad (1)$$

式中,  $V_{\text{norm}}$  为归一化后的参量,  $V_i$  为原数据参量,  $V_{\text{max}}$  和  $V_{\text{min}}$  分别为设置的最大值和最小值。

经挑选后,共有 13000 个时刻(帧)的雷达拼图数据,其中 80% 共 10400 帧作为训练集,20% 共 2600 帧作为测试集。每 120 min 共 20 帧作为一个子集,前 60 min 的 10 帧为输入,后 60 min 的 10 帧为标签用于预测。

### 2.2 RMAPS-NOW 数据

天气背景数据来自北京城市气象研究院新一代快速更新多尺度资料分析和预报系统(RMAPS)的临近数值预报子系统(RMAPS-NOW),该系统实时融合 2000 多个地面自动气象站 5 min 观测和

RMAPS-ST 中尺度数值模式结果,能够提供 10 min 快速更新循环的区域高分辨率大气三维热、动力场的实时快速分析,以及逐 10 min 间隔的 0—2 h 临近数值预报。RMAPS 覆盖范围为 ( $35.840^\circ - 42.840^\circ\text{N}$ ,  $112.648^\circ - 120.351^\circ\text{E}$ ),经向分辨率  $0.036^\circ$ ,纬向分辨率  $0.026^\circ$ 。为了避免回波外推结果受限于模式预报准确率,本研究仅用近似于实况的 RMAPS-NOW 初始零场资料,选用的物理量如表 1 所示。

表 1 选用的物理量名称、单位、高度层以及归一化设置的最大、最小值

Table 1 Introduced physical quantities, altitude levels, and maximum and minimum values for normalization

物理量名称	单位	最大值	最小值	高度层
$u$ (东西向风速分量)	m/s	20	-18	1350 m
$v$ (南北向风速分量)	m/s	20	-18	1350 m
RH(相对湿度)	%	100	0	150 m
div(水平散度)	$10^{-3} \text{ s}^{-1}$	3	-3	1350 m

为了避免日变化的影响,对相对湿度需要减去气候平均态。气候平均态利用 1988—2017 年共 30 a 的 ERA5 资料对试验范围内的相对湿度进行逐时、逐格点历年平均计算得到。并且利用式(1)最大、最小值法进行归一化处理,各物理量的最大、最小值设置见表 1。

### 2.3 数据匹配

RMAPS 睿图数据和雷达数据时、空分辨率不同,雷达拼图的空间分辨率更高,采用双线性插值法将 RMAPS 数据匹配到与雷达空间分辨率一致。即使用雷达格点周围 4 个点的 RMAPS 数据加权平均,距离目标点越近的已知点其权重越大,从而计算出雷达格点位置的物理量值。

由于雷达回波的变化往往滞后于天气背景信息,为了避免插值带来的误差,雷达与 RMAPS 数据在时间上不进行插值匹配,直接用前 100 min 的 10 个 RMAPS-NOW 零场匹配前 60 min 的 10 个雷达拼图数据。

## 3 网络架构设计与模型训练

### 3.1 深度学习架构 ConvLSTM

雷达回波不仅在时间上有相互联系,更重要的是还存在空间上的相关。因此,本研究基于有较好时、空特征提取能力的 ConvLSTM 架构,设计融入

天气背景的网络架构。ConvLSTM是一种结合了卷积神经网络(CNN)和LSTM的神经网络模型(Shi, et al, 2015)。LSTM是一种RNN变体,处理序列数据时具有较强的长期依赖建模能力,它通过使用门控单元来选择性遗忘和更新信息,从而能更好地捕捉时间序列中的长期依赖,ConvLSTM是LSTM的扩展,引入了卷积操作,使其可以同时处理空间信息和时间信息(式(2))。

$$\begin{cases} i_t = \sigma(W_f[H_{t-1}, X_t] + b_i) \\ f_t = \sigma(W_f[H_{t-1}, X_t] + b_f) \\ O_t = \sigma(W_o[H_{t-1}, X_t] + b_o) \\ \tilde{C}_t = \tanh(W_c[H_{t-1}, X_t] + b_c) \\ C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \\ H_t = O_t * \tanh(C_t) \end{cases} \quad (2)$$

式中, \* 为卷积操作,  $i_t$  为  $t$  时间步的输入门,  $X_t$  为  $t$  时间步的输入数据(通常是卷积后的特征图);  $f_t$  为  $t$  时间步的遗忘门, 参数与输入门类似;  $O_t$  为  $t$  时间步的输出门;  $C_t$  和  $C_{t-1}$  分别为  $t$  和  $t-1$  时间步的细胞状态;  $\tilde{C}_t$  为  $t$  时间步的融合信息;  $H_t$  和  $H_{t-1}$  分别为  $t$  和  $t-1$  时间步的隐藏状态;  $W$  为对应的卷积核参数;  $b$  为偏置项;  $\sigma$  为 sigmoid 激活函数, 其可以避免梯度消失, 并有较好的收敛性和计算效率;  $\tanh$  为双曲正切激活函数, 其非线性变换特点使网络拥有对复杂关系的学习能力。

### 3.2 融入物理量的雷达单元 (Radar cell)

将某一物理量(如相对湿度、散度等), 乘上一个初始设定的权重, 与对应的雷达回波强度矩阵堆叠, 构建成一个融合单个物理量信息的雷达单元(图2)。权重值在模型训练过程中自动优化。

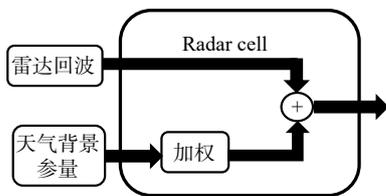


图2 雷达单元结构

Fig. 2 Radar cell structure diagram

每个物理量分别选取1—3个不同高度层的格点场(详见表1), 通过比例调节参数(Scale)调整不同物理量的权重, 与对应的雷达回波序列融合生成多个包含不同天气背景信息的雷达单元, 加权并归一化每个单元后, 构建基于雷达单元的ConvLSTM

单元(ConvLSTMcell), 作为ConvLSTM的输入序列。对 $H_{t-1}$ 和输入的ConvLSTMcell进行批归一化处理, 提升模型泛化能力的同时还缓解了梯度消失或者爆炸问题, 有效地提高训练效率和模型性能。ConvLSTMcell作为输入门, 执行前向传播, 使用卷积操作让具有空间依赖性的信息在时间步长之间流动, 通过对各种门和单元状态进行计算和激活。最后引入SELayer(Squeeze-and-Excitation Layer)神经网络层, 返回注意力加权的隐藏状态( $H_t$ )和新的细胞状态( $C_t$ )。对隐藏状态进行自注意力机制操作可以增强通道重要特征的学习, 提高模型的表征能力。

### 3.3 MR-ConvLSTM 网络架构

借鉴Shi等(2017)的研究方法, 使用编码器和解码器(Encoder-Decoder)结构来预测时空序列。将前文融入RMAPS-NOW的多个雷达单元构建的ConvLSTMcell作为循环单元放入解码-编码结构中, 进一步构建MR-ConvLSTM网络架构(图3)。其中编码器由3个下采样层和3个ConvLSTMcell层组成, 将输入的隐藏状态转换成固定长度的向量, 其中包含了输入序列的信息; 再将编码最后一步隐藏状态用于初始化解码阶段的隐藏状态。每一次解码后通过下采样层卷积将输入的ConvLSTMcell信息缩小, 并对其中重要的空间特征进行提取, 使得ConvLSTMcell层能够不断更好地学习融入天气背景的雷达回波特征; 每次的ConvLSTMcell层后进行批归一化处理, 提升模型的泛化能力。激活函数使用Leaky-ReLU(式(3)), 避免了ReLU在负半区神经元不学习的问题。

$$f(x) = \begin{cases} x & x > 0 \\ ax & x \leq 0 \end{cases} \quad (3)$$

解码预报模块由采样层和ConvLSTMcell层各3个组成, 在每个ConvLSTMcell层的输入端引入SELayer层来增强编码器和解码器之间的跳跃连接。解码器接受编码器输出的上下文向量, 用编码输入的最后一帧作为第一个输入, 通过注意力机制及逆行特征学习生成目标序列, 实现对未来时空的预测。每一次编码后通过上采样层进行反卷积(Deconvolution)将其输入的特征图扩大(增大分辨率), 从而使ConvLSTMcell层对上采样后的特征进行学习, 并把学习到的回波特征反向构成未来时

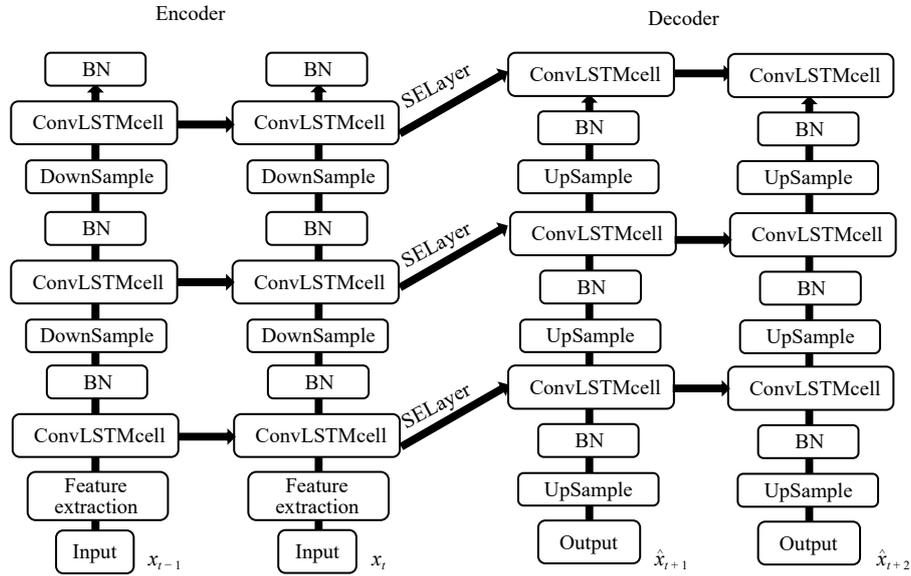


图 3 MR-ConvLSTM 回波外推网络结构  
Fig. 3 MR-ConvLSTM Echo extrapolation model network

刻雷达回波的预测序列。同样，每个 ConvLSTMcell 层后进行批归一化处理。

最后模型将输出序列进行堆叠和维度转换，并通过 CNN 在解码器的最后阶段对特征进行卷积处理，以进一步调整特征维度和增强模型的表达能力，生成预测输出。反复迭代此过程得到最终的雷达回波外推序列。

### 3.4 自定义损失函数

深度学习模型往往使用均方误差 (MSE) 或平均绝对误差 (MAE) (式 (4) 和 (5)) 作为损失函数来计算损失，并反向传播调整权重参数，式中  $M$  为样本数量， $\hat{V}_t$  为预测值， $V_t$  为真实值。

$$MSE = \frac{1}{M} \sum_{t=1}^M (\hat{V}_t - V_t)^2 \quad (4)$$

$$MAE = \frac{1}{M} \sum_{t=1}^M |\hat{V}_t - V_t| \quad (5)$$

由于 CNN 算法本身的平滑性，随着预测时间的延长，回波强度逐渐平滑衰减。因此，本研究对损失函数进行了优化，设计了自定义损失函数 (式 (6))。根据雷达回波的时间序列特性，充分利用时间维度信息并考虑雷达回波的空间相关，即相邻位置数据存在相似的变化趋势，引入了空间维度的权重，强化相邻位置数据的学习能力。统计回波强度在不同区间出现的次数，针对低值回波出现频率

高、高值回波出现频率低的特点，引入具有时空特征的权重矩阵改进回波平滑衰减问题。在模型训练过程中，通过反复测试，最终得出权重矩阵如表 2 所示。该矩阵纵向为预测时间序列，横向为回波强度区间。

$$l(t) = \sum_{i=0}^{H-1} \sum_{j=0}^{W-1} w_{i,j,t} |y_{\text{pred},i,j,t} - y_{\text{gd},i,j,t}| + \sum_{i=0}^{H-1} \sum_{j=0}^{W-1} w_{i,j,t} (y_{\text{pred},i,j,t} - y_{\text{gd},i,j,t})^2 \quad (6)$$

式中， $l(t)$  为损失值， $w_{i,j,t}$  为回波格点  $(i,j)$  在  $t$  时刻的权重 (详见表 2)， $y_{\text{pred}}$  和  $y_{\text{gd}}$  为归一化后的预测值和实际值。通过损失函数加权方法，有效增强模型的拟合能力，提升雷达回波的外推效果。

### 3.5 模型训练

为了验证引入天气背景参量对雷达回波外推的有效性，分别训练基于 MR-ConvLSTM 和未引入物理量的 ConvLSTM 架构的雷达回波外推模型。初始学习率设置为 0.0001，批量大小为 5，最大迭代次数为 400 且设置了早停机制 (Early Stopping)，如果连续 30 个 epoch 的指标不再提升，则停止迭代，保存并输出模型，从而避免过拟合；使用 Adam 优化损失函数。

共训练得到 5 个外推模型，分别为：(1) 基于 ConvLSTM，未引入物理量模型；(2) 引入 1350 m

表2 自定义损失函数权重矩阵

Table 2 Self-defined loss function weight matrix

$t(\text{min})$	(0, 15 dBz]	(15 dBz, 30 dBz]	(30 dBz, 45 dBz]	(45 dBz, 60 dBz]	(60 dBz, 70 dBz]
6	1	3	6	8	60
12	2	6	12	16	120
18	3	9	18	24	180
24	4	12	24	32	240
30	5	15	30	40	300
36	6	18	36	48	360
42	7	21	42	56	420
48	8	24	48	64	480
54	9	27	54	72	520
60	10	30	60	80	600

散度模型; (3)引入 150 m 相对湿度模型; (4)引入 1350 m 的  $u$ 、 $v$  模型; (5)引入 1350 m 的  $u$ 、 $v$  及 150 m 相对湿度模型。

### 3.6 评定指标

使用气象业务中常用的基于预定阈值的二元分类模型来评估模型性能。反射率阈值分别选取 20、30、35 dBz, 预报时间间隔为 6 min。使用命中率(POD)评价模型正确预测能力, 虚警率(FAR)评价错误预测实际未发生的事件, 临界成功指数(CSI)用来衡量模型的整体性能(式(7))。式(7)中各值通过混淆矩阵(表3)计算, 其中的命中点(TP), 表示预测值与真值均大于判别值; 空报点(FN), 表示预测值大于判别值而真实值小于判别值; 漏报点(FP), 表示预测值小于判别值而真实值大于判别值; 真阴性(TN), 表示预测值与真值均小于判别值。

表3 混淆矩阵

Table 3 Confusion Matrix

	预测	真实
TP	1	1
FN	0	1
FP	1	0
TN	0	0

通过比较每个格点的预测值与观测值, 得出各个点的分类, 进而计算出评估指标。POD、FAR 和 CSI 的计算方法如式(7)所示, POD 和 CSI 的值越大代表预测越精准, 而 FAR 的值越小则代表预测越精准。

$$\begin{cases} \text{POD} = \frac{\text{TP}}{\text{TP} + \text{FN}} \\ \text{FAR} = \frac{\text{FP}}{\text{TP} + \text{FP}} \\ \text{CSI} = \frac{\text{TP}}{\text{TP} + \text{FN} + \text{FP}} \end{cases} \quad (7)$$

## 4 模型检验

使用 2600 组测试数据集, 分别对基于 ConvLSTM、MR-ConvLSTM 训练得到的 5 个模型进行回波外推, 并选择 20、30、35 dBz 作为阈值, 图 4、5、6 为 5 个模型在测试集逐 6 min 外推结果的 POD、FAR、CSI 结果, 5 个模型在测试集 1 h 外推平均 POD、FAR、CSI 见表 4。通过图 4、5、6 和表 4 可以看出, POD 和 CSI 是随着检验阈值的增大而减小, FAR 则是增大。在相同的阈值下, 基于 MR-ConvLSTM 的外推模型指标值大部分都要优于未引入物理量的基于 ConvLSTM 的外推模型。其中引入物理量模型的 CSI 值在 3 种不同阈值下比未引入物理量模型平均高 4.67%、13.8%、5.98%, POD 值平均高 3.1%、7.68%、8.38%, FAR 值平均低 6.37%、8.54%、10.17%, 说明引入物理量对回波外推的效果有很大程度的提升。

由表 4 可以看出, 同时引入 3 个物理量(RH、 $u$ 、 $v$ )的外推模型在不同阈值的各项指标中综合表现最好, CSI、POD 值在 3 种不同阈值下比未引入物理量模型平均高 16.01%、13.38%, FAR 值平均低 14.88%。表明引入复杂物理量对于不同回波强度的外推能力有所提高。

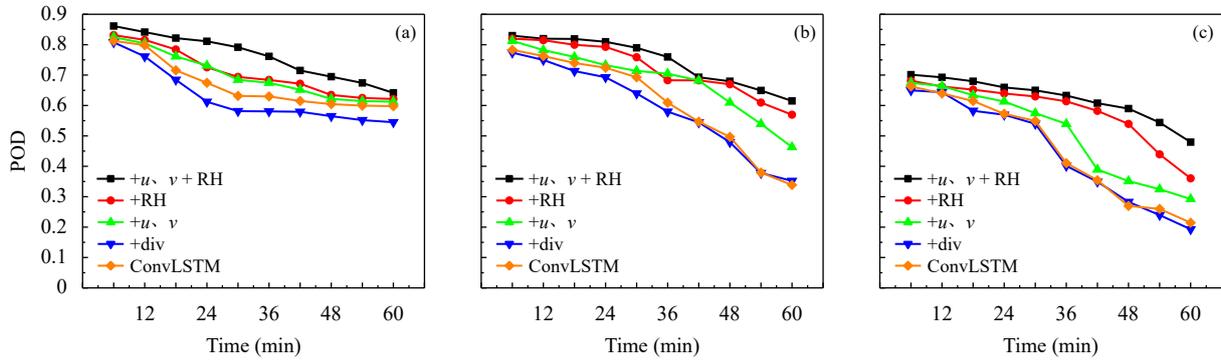


图 4 不同外推模型在测试集反射阈值为 20 (a)、30 (b)、35 dBz (c) 的逐 6 min POD 变化曲线  
 Fig. 4 POD curves of 6-minute values for different extrapolation models at reflectivity thresholds of 20 (a), 30 (b), and 35 dBz (c) in the test suite consisting of 10 predicted time series (60 min)

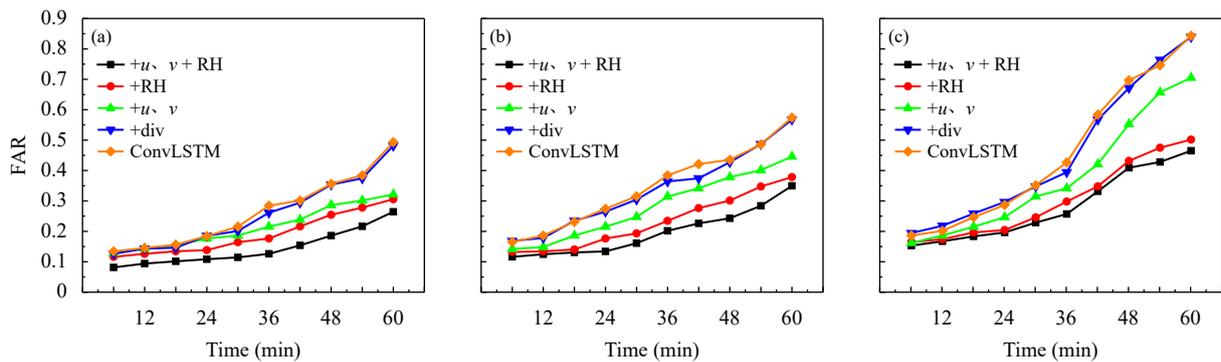


图 5 不同外推模型在测试集反射率阈值为 20 (a)、30 (b)、35 dBz (c) 的逐 6 min FAR 变化曲线  
 Fig. 5 FAR curves of 6-minute values for different extrapolation models at reflectivity thresholds of 20 (a), 30 (b), and 35 dBz (c) in the test suite consisting of 10 predicted time series (60 min)

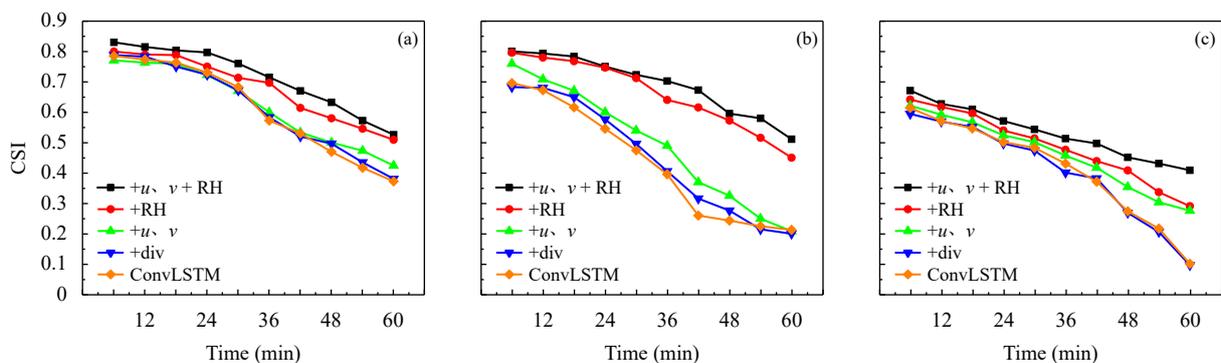


图 6 不同外推模型在测试集反射阈值为 20 (a)、30 (b)、35 dBz (c) 的逐 6 min CSI 变化曲线  
 Fig. 6 CSI curves of 6-minute values for different extrapolation models at reflectivity thresholds of 20 (a), 30 (b), and 35 dBz (c) in the test suite consisting of 10 predicted time series (60 min)

## 5 模型应用

### 5.1 个例一

2019 年 7 月 25 日, 受高空槽、切变线影响, 张家口出现了一次小到中雨天气过程, 康保的东井子最大过程降水量 27.5 mm, 14—15 时最大小时雨量

23.8 mm。图 7 为输入的前 10 个时序的雷达回波以及物理量数据(文章篇幅所限, 后面的个例不再给出输入的物理量), 图 8 为后 10 个时序逐 12 min 的回波实况与外推结果。在 30 min 前, 各个模型预测效果差别不明显, 整体都呈现一个强回波逐渐减

表4 模型在 20、30、35 dBz 反射率阈值测试集 1 h 外推各指标平均值

Table 4 1 h average values of each index for the models with reflectivity thresholds of 20, 30, and 35 dBz, respectively

反射率阈值	Model	POD	FAR	CSI
20 dBz	ConvLSTM	0.6678	0.2657	0.6113
	+div	0.6269	0.2569	0.6148
	+u、v	0.6982	0.2153	0.6233
	+RH	0.7088	0.1913	0.6803
	+u、v+RH	<b>0.7614</b>	<b>0.1445</b>	<b>0.7137</b>
30 dBz	ConvLSTM	0.6092	0.3475	0.4359
	+div	0.5921	0.3373	0.4514
	+u、v	0.6819	0.2822	0.4939
	+RH	0.7218	0.2316	0.6614
	+u、v+RH	<b>0.7482</b>	<b>0.1973</b>	<b>0.6928</b>
35 dBz	ConvLSTM	0.4566	0.4573	0.4114
	+div	0.4469	0.4554	0.4043
	+u、v	0.5076	0.3805	0.4617
	+RH	0.5818	0.3042	0.4862
	+u、v+RH	<b>0.6254</b>	<b>0.2823</b>	<b>0.5326</b>

注: 黑体为最佳。

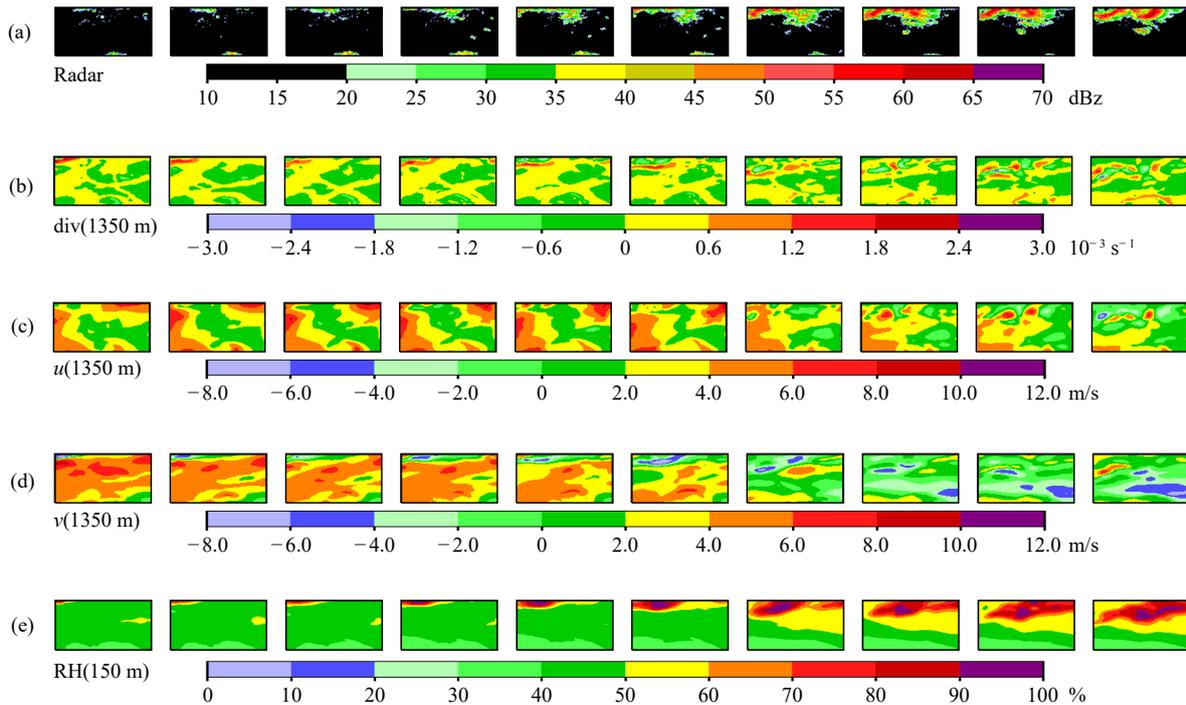


图7 个例一输入的前 10 个时序数据 (a. 雷达回波, b. div (1350 m), c. u (1350 m), d. v (1350 m), e. RH (150 m))

Fig. 7 Previous 10 times input data for case 1 (a. radar echoes, b. div (1350 m), c. u (1350 m), d. v (1350 m), e. RH (150 m))

弱的趋势,且雷达回波图上部分强回波逐渐分裂开来。从 30—60 min 的预测图来看,引入物理量的效果逐渐体现出来。未引入物理量模型的上半部分的强回波随着预测时长的增加,对强回波的预测效果逐渐降低。引入了  $u$ 、 $v$  和 RH 的外推模型,在预

测中长时序回波依赖关系的表征能力明显要优于其他模型,且在时间维度上有更强的鲁棒性。

为了直观地比较和观察各个模型的外推精度,将逐 6 min 20、30、35 dBz 反射率阈值预测的 10 个时间步长的 CSI 评价指标绘制变化曲线如图 9(为

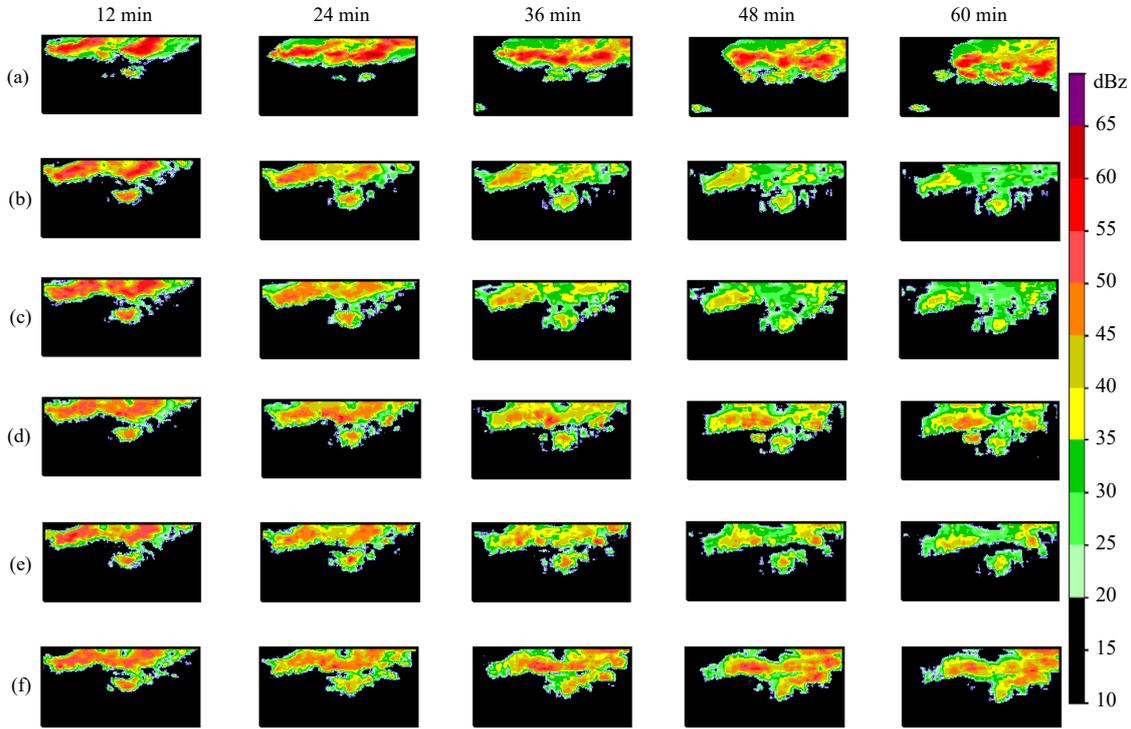


图 8 2019 年 7 月 25 日 15 时 36 分—16 时 36 分, 不同模型逐 12 min 回波外推结果 (a. 回波实况, b. 基于 ConvLSTM 模型, c. 引入 div 的 MR-ConvLSTM 模型, d. 引入  $u, v$  的 MR-ConvLSTM 模型, e. 引入 RH 的 MR-ConvLSTM 模型, f. 引入  $u, v$  和 RH 的 MR-ConvLSTM 模型)

Fig. 8 Echo extrapolation results at 12-minute intervals for different models from 15:36 to 16:36 BT 25 July 2019 (a. echo reality, b. ConvLSTM-based, c. MR-ConvLSTM-based with div, d. MR-ConvLSTM-based with  $u, v$ , e. MR-ConvLSTM-based with RH, f. MR-ConvLSTM based with  $u, v$  and RH)

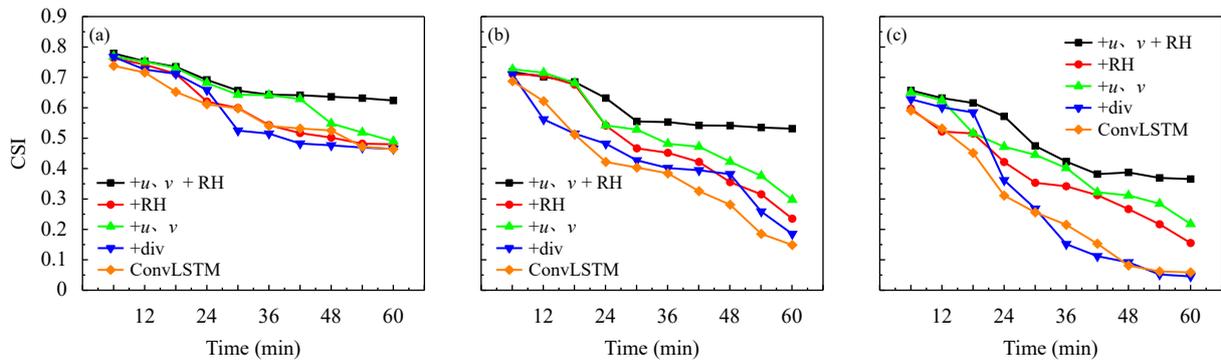


图 9 同图 6, 但为个例一

Fig. 9 Same as Fig. 6 except for case 1

节省文章篇幅, 不再给出 POD 与 FAR 曲线)。在不同的预测步长上, 相同反射阈值下, 引入物理量的模型都要优于未引入物理量的模型, 且 CSI 值都是随着预测步长的增大而降低。CSI 值在 20、30、35 dBz 的反射率阈值下平均高 9.4%、15.3%、19.6%。随着预测步长的增大, 各模型预测的能力都在逐渐下降, 但是引入了物理量的模型的预测效果要下降

得更慢, 外推结果明显优于未引入物理量模型。

### 5.2 个例二

受高空切变线影响, 2020 年 8 月 25 日 18—20 时张家口西部的张北、尚义、万全、康保出现了分散性阵雨或雷阵雨, 雨量分布不均, 沽源九连城区域自动气象站降水量最大为 20.8 mm, 18—19 时最大小时雨量 17.2 mm。实况回波和模型预测结果

如图 10 所示。与个例一相似,在 30 min 后,所有模型对于强回波区域的预测都呈现减弱的趋势。未引入物理量的和引入了 div 的外推效果下降较为明显。而引入  $u$ 、 $v$  模型的外推下降趋势较为缓慢,对于强回波预测区域仍有小部分的强回波存在。引入 RH 的模型对整个外推回波覆盖区域要更加清晰一些。引入  $u$ 、 $v$  和 RH 模型对于整体强回波演变的预测效果目前最好,在 30 min 后相比其他模型的外推效果更加明显,呈现出更完整和更清晰的强回波形态和强度。但是随着外推时长的增加,对于预测

回波周围细节也存在一定的缺失。

在 20、30、35 dBz 的反射率值条件下,各个模型逐 6 min 的 10 个时间步长的 CSI 评价指标的变化曲线如图 11 所示。引入了物理量模型要比未引入物理量模型的测试效果好,且引入 RH 和  $u$ 、 $v$  的模型预测效果最好,其 CSI 值均高于未引入物理量的模型,在反射率阈值较大的情况下,仍然有较好的预测效果。CSI 值比未引入物理量模型平均高 8.4%、9.1%、5.6%,说明引入物理量的外推具有更稳定的外推能力。

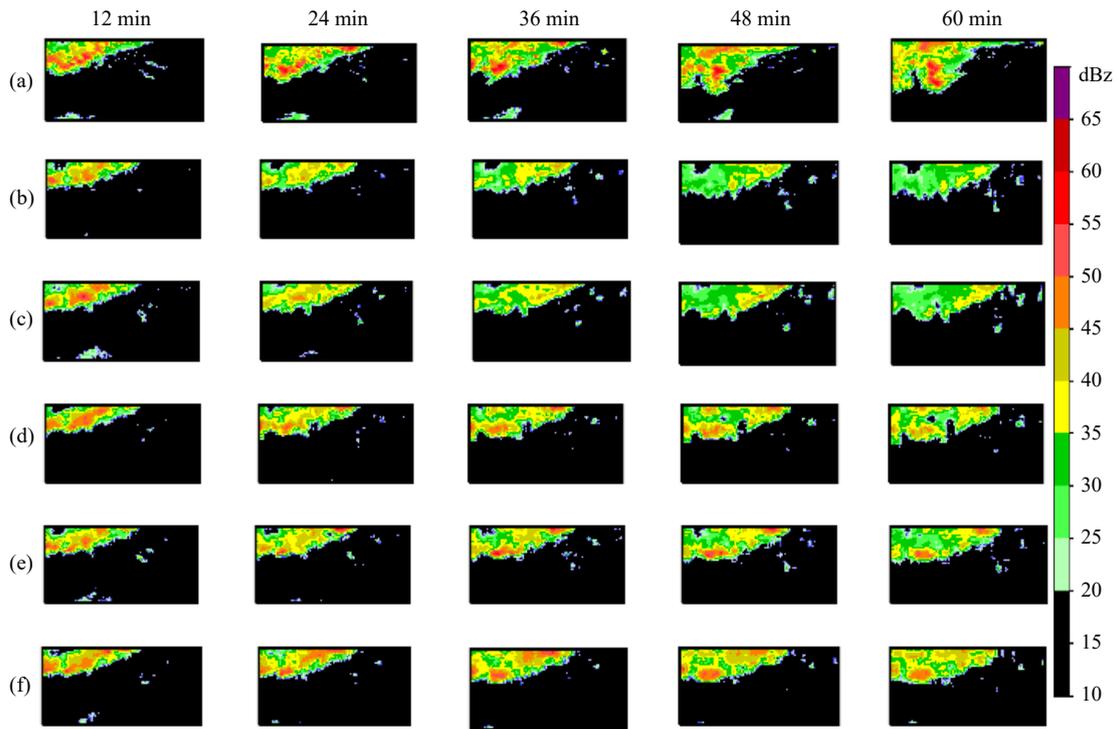


图 10 同图 8, 但为个例二的 2020 年 8 月 25 日 18 时 36 分—19 时 36 分  
Fig. 10 Same as Fig. 8 but for case 1 in 18:36 to 19:36 BT 25 August 2020

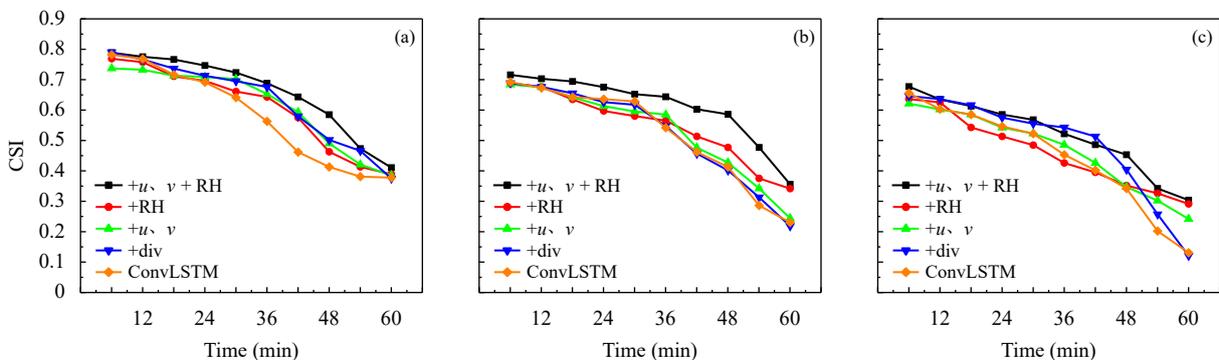


图 11 同图 6, 但为个例二  
Fig. 11 Same as Fig. 6 except for case 2

### 5.3 个例三

受北涡南槽影响, 2020年8月30日18—20时张家口自西向东出现了阵性降雨天气过程, 雨量分布不均, 17—18时万全镇区域自动气象站降水量最大为30.4 mm。逐12 min回波实况与模型预测如图12所示。整体的外推效果与个例一、二相似, 30 min前所有模型的预测效果相差不大, 未引入物理量和引入div的模型在30 min后对右侧强回波

比较稀疏。引入 $u$ 、 $v$ 和RH的模型对整体回波的上半部分和下半部分均有预测, 与实况比较接近。

在20、30、35 dBz的反射率阈值条件下, 不同模型逐6 min CSI评价指标的变化如图13所示。从折线图整体的走势看, 引入物理量的模型都要优于未引入物理量模型。且随着预测步长的增大, 引入物理量后更能避免回波的误报。引入了 $u$ 、 $v$ 和RH的模型在个例三不同的反射阈值和时间步长的CSI值都是最大的, 比未引入物理量的模型的个例三测试效果平均高3.8%、8.2%、5.9%。

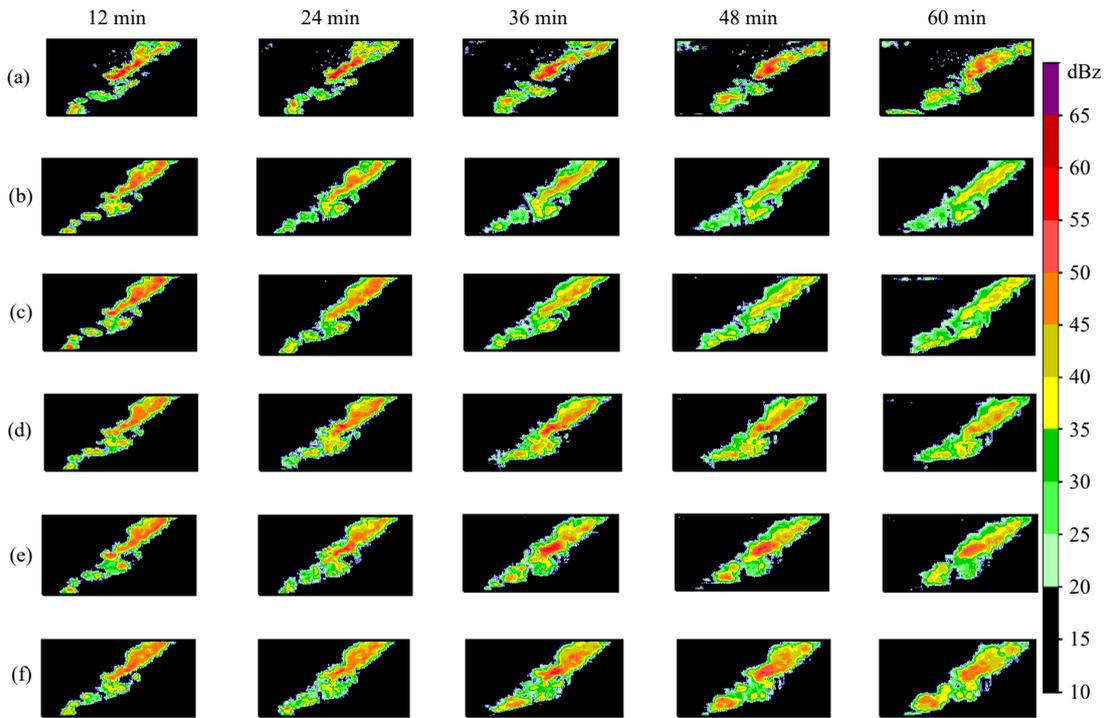


图12 同图8, 但为个例三的2020年8月30日18时36分—19时36分  
Fig. 12 Same as Fig. 8 but for case 3 in 18:36 to 19:36 BT 30 August 2020

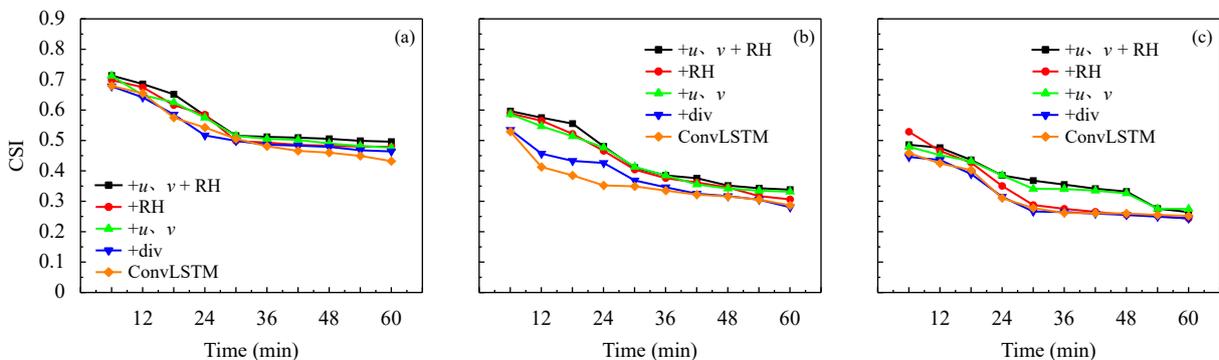


图13 同图6, 但为个例三  
Fig. 13 Same as Fig. 6 except for case 3

基于天气背景参量数据与雷达回波数据的结合可以用于0—1 h的雷达回波外推的实现。通过对3个不同个例的定性和定量分析,可视化结果分析可以得出引入物理量的外推模型对于雷达回波外推是优于未引入物理量的外推模型,且引入的物理量越复杂的雷达回波外推模型对于外推的效果越好,对于不同的回波阈值区间依然有一定的外推能力。

## 6 结论与讨论

目前,基于深度学习的雷达回波外推主流算法无论如何改进,因为作为基础的卷积算法本身具有平滑性,不可避免地,回波随时间延长越来越平滑,这也是目前雷达回波外推被广大预报员最为诟病的缺陷。此外,雷达回波的生消演变实际上是天气背景过程相互作用的结果,随着技术的进步,各种时、空分辨率的探测数据大量涌现,而深度学习的最大优势就是基于大数据建模。不能仅仅着眼于算法,如何充分利用好包括雷达探测资料在内的大量实时观测资料应该是气象学界应用深度学习的优势所在。

文中利用2018—2021年6—9月的华北组合反射率拼图数据和北京城市气象研究院研发的一代快速更新多尺度资料分析和预报系统的临近数值预报子系统(RMAPS-NOW)初始零场的部分物理量产品,设计了多通道回波外推网络架构MR-ConvLSTM,同时构建了减少时空衰减的自定义损失函数,减轻CNN算法随着外推时长增加带来的回波强度平滑,训练得到多个融合了天气背景物理量的雷达回波外推模型。通过对比分析测试集与3个模型应用个例表明,融合天气背景参量后,雷达回波外推模型准确率有较为明显的提升,外推时间越长、引入的物理量越多效果越明显,并且有更好的泛化能力。

虽然因算力所限,文中仅试验了比较小的一个区域,并且仅引入了3种物理量,但是结果却令人鼓舞,表明将高分辨率快速同化天气背景场融入雷达基数据的回波外推模型是一个正确的、有很大潜力的研究方向。如果融入更多不同高度层的气象要素,并加入地形、下垫面等地理因素,将不同气候背景的区域分别建模后,再融合为一个模型,

将极大提升雷达回波外推效果,从而改进短时临近预报精度。

**致谢:**感谢北京城市气象研究院、雄安市气象台提供睿图-临近数值预报系统(RMAPS-NOW)数据。

## 参考文献

- 曹春燕,陈元昭,刘东华,等. 2015. 光流法及其在临近预报中的应用. *气象学报*, 73(3): 471-480. Cao C Y, Chen Y Z, Liu D H, et al. 2015. The optical flow method and its application to nowcasting. *Acta Meteor Sinica*, 73(3): 471-480 (in Chinese)
- 方巍,沈亮,邹立尧,等. 2023. 基于GCA-ConvLSTM预测网络的短临降水雷达回波外推方法. *暴雨灾害*, 42(4): 427-436. Fang W, Shen L, Zou L Y, et al. 2023. Extrapolation method of precipitation nowcasting radar echo based on GCA-ConvLSTM prediction network. *Torrential Rain Disaster*, 42(4): 427-436 (in Chinese)
- 黄兴友,马玉蓉,胡苏蔓. 2021. 基于深度学习的天气雷达回波序列外推及效果分析. *气象学报*, 79(5): 817-827. Huang X Y, Ma Y R, Hu S M. 2021. Extrapolation and effect analysis of weather radar echo sequence based on deep learning. *Acta Meteor Sinica*, 79(5): 817-827 (in Chinese)
- 伊凡. 2013. 基于半拉格朗日方法的雷达图像运动分析[D]. 青岛: 中国海洋大学. Yi F. Motion analysis based on semi-Lagrangian in radar images [D]. Qingdao: Ocean University of China (in Chinese)
- 俞小鼎. 2013. 短时强降水临近预报的思路与方法. *暴雨灾害*, 32(3): 202-209. Yu X D. 2013. Nowcasting thinking and method of flash heavy rain. *Torrential Rain Disaster*, 32(3): 202-209 (in Chinese)
- 张蕾,魏鸣,李南,等. 2014. 改进的光流法在回波外推预报中的应用. *科学技术与工程*, 14(32): 133-137, 148. Zhang L, Wei M, Li N, et al. 2014. Improved optical flow method application to extrapolate radar echo. *Sci Technol Eng*, 14(32): 133-137, 148 (in Chinese)
- Ayzel G, Heistermann M, Winterrath T. 2019. Optical flow models as an open benchmark for radar-based precipitation nowcasting (rainymotion v0.1). *Geosci Model Dev*, 12(4): 1387-1402
- Bonnet S M, Evsukoff A, Morales Rodriguez C A. 2020. Precipitation nowcasting with weather radar images and deep learning in São Paulo, Brasil. *Atmosphere*, 11(11): 1157
- Du S D, Li T R, Yang Y, et al. 2020. Multivariate time series forecasting via attention-based encoder-decoder framework. *Neurocomputing*, 388: 269-279
- Farneback G. 2001. Very high accuracy velocity estimation using orientation tensors, parametric motion, and simultaneous segmentation of the motion field//Proceedings of the 8th IEEE International Conference on Computer Vision. Vancouver, BC, Canada: IEEE, 171-177
- Farneback G. 2002. Polynomial Expansion for Orientation and Motion Estimation[D]. Sweden: Linköping University Sweden
- Guo S Q, Sun N L, Pei Y L, et al. 2023. 3D-UNet-LSTM: A deep learning-

- based radar echo extrapolation model for convective nowcasting. *Remote Sens*, 15(6): 1529
- He W, Xiong T S, Wang H, et al. 2022. Radar echo spatiotemporal sequence prediction using an improved ConvGRU deep learning model. *Atmosphere*, 13(1): 88
- Horn B K P, Schunck B G. 1981. Determining optical flow. *Artif Intell*, 17(1-3): 185-203
- Jing J R, Li Q, Peng X, et al. 2020. HPRNN: A hierarchical sequence prediction model for long-term weather radar echo extrapolation// ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Barcelona, Spain: IEEE, 4142-4146
- Johnson J T, MacKeen P L, Witt A, et al. 1998. The storm cell identification and tracking algorithm: An enhanced WSR-88D algorithm. *Wea Forecasting*, 13(2): 263-276
- Li L, Schmid W, Joss J. 1995. Nowcasting of motion and growth of precipitation with radar over a complex orography. *J Appl Meteor*, 34(6): 1286-1300
- Lu M Y, Li Y C, Yu M Z, et al. 2023. Spatiotemporal prediction of radar echoes based on ConvLSTM and multisource data. *Remote Sens*, 15(5): 1279
- Lucas B D, Kanade T. 1981. An iterative image registration technique with an application to stereo vision// Proceedings of the 7th International Joint Conference on Artificial Intelligence. Vancouver, BC, Canada: Morgan Kaufmann Publishers Inc
- Ravuri S, Lenc K, Willson M, et al. 2021. Skilful precipitation nowcasting using deep generative models of radar. *Nature*, 597(7878): 672-677
- Rinehart R E, Garvey E T. 1978. Three-dimensional storm motion detection by conventional weather radar. *Nature*, 273(5660): 287-289
- Shi X J, Chen Z R, Wang H, et al. 2015. Convolutional LSTM network: A machine learning approach for precipitation nowcasting// Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press
- Shi X J, Gao Z H, Lausen L, et al. 2017. Deep learning for precipitation nowcasting: A benchmark and a new model// Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, California, USA: Curran Associates Inc
- Weinzaepfel P, Revaud J, Harchaoui Z, et al. 2013. DeepFlow: Large displacement optical flow with deep matching// Proceedings of 2013 IEEE International Conference on Computer Vision. Sydney, NSW, Australia: IEEE, 1385-1392
- Wulff J, Black M J. 2015. Efficient sparse-to-dense optical flow estimation using a learned basis and layers// Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 120-130
- Yang Z Y, Wu H, Liu Q, et al. 2023. A self-attention integrated spatiotemporal LSTM approach to edge-radar echo extrapolation in the internet of radars. *ISA Trans*, 132: 155-166
- Zheng K, Tan Q, Ruan H, et al. 2023. GAN-argcPredNet v2. 0: A radar echo extrapolation model based on spatiotemporal process intensification. *Geoscientific Model Development Discussions*, 1-25