

# CAST-LSTM: 一种用于雷达回波外推的时空 LSTM 模型

渠海峰<sup>1,2</sup> 何光鑫<sup>1,2</sup> 康志明<sup>3\*</sup> 程勇<sup>1</sup> 王军<sup>1</sup> 庄潇然<sup>3</sup> 李远禄<sup>1</sup>

<sup>1</sup> 南京信息工程大学, 南京 210044

<sup>2</sup> 中国气象局广州热带海洋气象研究所, 广州 510640

<sup>3</sup> 江苏省气象台, 南京 210008

**摘要:** 基于循环神经网络的雷达回波外推算法的预报结果随时间逐渐模糊失真, 同时难以预报强回波区域。针对上述问题, 本文提出一种上下文融合和注意力机制的时空长短期记忆网络模型。该方法通过上下文融合模块充分提取雷达图像不同尺度的短期上下文信息; 通过注意力模块拓宽预测单元的时间感受域, 使模型感知更多的时间动态。以 2019-2021 年 4-9 月江苏省气象雷达数据为样本, 通过实验对比分析, 基于上下文融合和注意力机制的时空长短期记忆网络取得更好的预测性能。在外推 60 分钟, 阈值为 10、20、40dBZ 的条件下, 临界成功指数 (Critical Success Index, CSI) 和 Heidke Skill Score (HSS) 分别达到 0.7611、0.5326、0.2369 和 0.7335、0.5735、0.3075, 有效提高了预测精度。

**关键词:** 雷达回波外推; 深度学习; 降水预报; 长短期记忆

## CAST-LSTM: A Spatio-Temporal LSTM Model for Radar Echo Extrapolation

QU Haifeng<sup>1,2</sup> HE Guangxin<sup>1,2</sup> Kang Zhiming<sup>3\*</sup> CHENG Yong<sup>1</sup> Wang Jun<sup>1</sup>  
Zhuang Xiaoran<sup>3</sup> LI Yuanlu<sup>1</sup>

<sup>1</sup> Nanjing University of Information Science & Technology, Nanjing 210044

<sup>2</sup> Institute of Tropical and Marine Meteorology/Guangdong Provincial Key Laboratory of Regional Numerical Weather Prediction, Guangzhou 510640

<sup>3</sup> Jiangsu Meteorological Observatory, Nanjing 210008

**Abstract:** The forecast results of radar echo extrapolation algorithm based on recurrent neural network are gradually blurred and distorted with time, and it is difficult to forecast the high echo area. To solve the above problems, this paper proposes a spatio-temporal long short-term memory network model based on context fusion and attention mechanism. The method fully extracts the short-term context information of different scales of radar image through the context fusion module. The attention module broadens the time perception domain of the prediction unit, so that the model perceives more time dynamics. Taking the weather radar data of Jiangsu Province from April to September in 2019-2021 as a sample, the spatio-temporal long short-term memory

广东省“珠江人才计划”引进创新创业团队项目 (2019ZT08G669)、国家自然科学基金资助项目 (41975183, 41875184) 资助

第一作者: 渠海峰, 主要从事深度学习下的短临预报研究. Email: 2504931080@qq.com

通讯作者: 康志明, 主要从事集合预报和定量降水预报等研究. Email: kangzm@cma.gov.cn

34 network based on context fusion and attention mechanism achieves better prediction performance  
35 through experimental comparison and analysis. The Critical Success Index (CSI) and Heidke Skill  
36 Score (HSS) reached 0.7611, 0.5326, 0.2369 and 0.7335, 0.5735, 0.3075, respectively, under the  
37 conditions of 60 minutes of extrapolation and thresholds of 10, 20 and 40 dBZ, which effectively  
38 improved the prediction accuracy.  
39 **Key words:** radar echo extrapolation; deep learning; precipitation forecast; long short term  
40 memory

## 41 引言

42 降水短临预报一直是气象预报的一项重要任务,通常是指对某一地区未来短时间内(通  
43 常是 0-2h)的降雨量进行预测(Singh et al, 2017),准确的短临预报可以在暴雨、雷暴等恶劣  
44 天气提供预防作业(如为农业、航海等提供天气指导),减少人员伤亡和财产损失。因此,如  
45 何利用雷达回波外推技术获取精准、快速的天气短临预报,成为气象研究方面的热点问题。

46 降水短临预报可以看作是一种时空序列预测问题。预测雷达图通过 Z-R 关系(Marshall  
47 and Palmer, 1948)转换为降雨强度,作为最终短临预报。传统的雷达回波外推方法主要有交  
48 叉相关法(Rinehart and Garvey, 1978; Zou et al, 2019)、单体质心法(Chung and Yao, 2020;  
49 Lakshmanan et al, 2009)和光流法(Ayzel et al, 2019; Woo and Wong, 2017)。交叉相关法是将整  
50 个数据区域划分成若干小区域,然后在相邻时刻雷达回波图像的小区域之间计算相关系数,  
51 通过最大相关系数确定相邻时刻图像中的区域对应关系,进而确定回波区域的平均运动。但  
52 是,在强对流天气中,跟踪失败的情况就会显著增加。单体质心法是将雷暴视为三维单体进  
53 行识别、分析和追踪,对雷暴进行拟合外推来做临近预报。该方法在雷达回波较为零散或出  
54 现合并、分裂现象时,准确度将会大大下降。而光流法本质上是通过计算雷达回波的光流场  
55 得到回波的运动矢量场,并基于运动矢量场对雷达回波进行外推,但光流法在计算光流矢量  
56 和外推两步时存在累计误差。雷达回波图像数据作为一类序列图像数据,以上三种传统方法  
57 没有充分学习海量雷达数据内部蕴含的复杂天气变化规律,存在外推准确率低的问题。

58 近年,深度学习是机器学习中发展最为迅速的技术,针对传统方法存在的问题,越来越  
59 多的人尝试采用深度学习方法来解决视频预测(Bei et al, 2021; Chang et al, 2021; Tamaru et al,  
60 2021)、交通流预测(Tian and Chan, 2021; Yin et al, 2022; Zhao et al, 2022)和降水短临预报(陈  
61 锦鹏等, 2021; 郭瀚阳等, 2019; 顾建峰等, 2020; 黄骅文等, 2021; 黄兴友等, 2021; 尹麒名等,  
62 2021; 周康辉等, 2021)等时空序列预测问题。深度学习方法可以处理复杂的时空关系,以便  
63 从大量先前的雷达回波序列中自适应地学习降雨量变化的规律。例如, Shi et al(2015)提出了

64 将卷积神经网络(Convolutional Neural Network, CNN)和长短期记忆网络(Long Short-Term  
65 Memory, LSTM)相结合的卷积 LSTM (ConvLSTM) 模型用于降水预测, LSTM 用于提取  
66 时间动态信息并存储在时间记忆单元中, CNN 则负责提取空间信息。因此, 该网络可以对  
67 时空信息进行更好的学习和建模。基于循环神经网络的预报方法, 采用堆叠网络单元的方式  
68 搭建整体网络架构, 考虑到 ConvLSTM 只关注了时间信息, 而忽略了来自不同单元层之间的  
69 的空间信息。Wang et al(2017)提出了 ST-LSTM 单元(Spatiotemporal LSTM), 通过在  
70 ConvLSTM 中添加一个新的并行的空间记忆单元, 来保存每个单元层的空间特征并将其应  
71 用在新的端到端模型 PredRNN 上。Wang et al(2018)进一步将双记忆单元采用级联的方式构  
72 建 Causal-LSTM 单元, 并加入梯度高速公路单元(Gradient Highway Unit, GHU) 缓解梯度消  
73 失问题, 形成新的端到端模型 PredRNN++。Wang et al(2019a)提出了一种新的模型 E3D-LSTM  
74 (Eidetic 3D LSTM), 将 3D 卷积集成到 RNN 中, 使存储单元能够存储更好的短期特征。  
75 对于长期关系, 通过门控制的自注意力机制使当前记忆状态与其历史记录相互作用。但由于  
76 集成的 3D 卷积, 使 E3D-LSTM 的计算负载非常高。Wang et al(2019b)提出了 MIM (Memory  
77 In Memory), 可以捕捉雷达回波图像中的非平稳和近似平稳特性。Luo et al(2021)提出了一  
78 种新的 PFST-LSTM 单元 (Pseudo Flow Spatiotemporal LSTM), 其开发的存储单元和位置  
79 对齐模块, 解决了位置不匹配和缺少空间外观保护器的问题。Yang et al(2023)提出了  
80 CEMA-LSTM, 引入多头注意机制块 (MAB) 使用位置和信道关注机制来捕获雷达回波的  
81 全局特征。Geng et al(2022)提出了一种注意力融合时空残差网络 (AF-SRNet) 来精确预测  
82 对流降水的弱连续性。具体而言, 时空残差网络用于提取雷达回波和降水数据的深层时空特  
83 征, 实现了更精确的对流降水预报。

84 尽管上述方法有了重大改进, 但这些网络仍存在一些缺陷: (1) 输入数据和隐藏状态之  
85 间的上下文特征相关性较弱, 不能相互帮助识别和保存重要信息。(2) 随着预测时间增加,  
86 会出现记忆单元中存储信息逐渐衰减的问题, 即当前时刻记忆单元很难有效回忆起先前时刻  
87 存储记忆。这些问题导致在雷达回波外推任务中, 随着预测时间的增加, 雷达回波预测图像  
88 逐渐模糊, 反射率较高的雷达回波区域有消失的趋势, 这大大影响了预测精度。

89 针对上述问题, 本文提出了上下文融合和注意力机制的时空 LSTM 模型 (Spatiotemporal  
90 LSTM Model with Context Fusion and Attention Mechanism, CAST-LSTM)。首先, 本文提出  
91 了上下文融合模块, 有效地提取图像多尺度时空信息并提高上下文相关性。然后, 提出了一  
92 种注意力模块, 通过拓宽网络模型的时间感受域, 使模型感知更多的时间信息。将这两个模  
93 块集成到网络单元中, 性能显著提高, 尤其是在强降雨地区。

94 本文其余章节安排如下：第 1 节介绍实验所用的标准 Moving MNIST 数据集和真实雷达  
95 回波数据集。第 2 节介绍本文提出的方法。第 3 节试验分析，对数据集测试的结果进行对比  
96 分析。第 4 节对本文总结得出结论，并且对未来的研究工作进行了展望。

## 97 1 数据

### 98 1.1 Moving MNIST 数据集

99 Moving MNIST 数据集是时空序列预测任务中使用最广泛的数据集，在有限的范围内，  
100 几个数字随机移动，具有一些运动模式，包括旋转、重缩放、照明变化等。每 20 个连续帧  
101 划分为一个序列。其中 10 帧用于输入，10 帧用于预测，每个帧的大小为  $64 \times 64$ 。训练集包  
102 括 10000 个序列，验证集为 2000 个序列，测试集为 3000 个序列。本文通过 Moving MNIST  
103 数据集初步检验改进模型对时空序列预测任务的性能。使用训练集对网络进行训练；使用验  
104 证集调整模型结构和超参数，使模型性能达到最佳；最后使用测试集检验模型的性能。

### 105 1.2 雷达数据集

106 本文使用江苏气象雷达数据集来评估模型在真实场景下的雷达回波外推性能。数据集为  
107 2019-2021 年 4-9 月对江苏多部 S 波段气象雷达质量控制及组网拼图后得到的实际观测数据，  
108 覆盖整个江苏省区域面积，该数据集由江苏省气象台制作，以灰度图形式存储。数据取值范  
109 围为 0-70（单位：dBZ），水平分辨率为  $0.01^\circ$ （约 1 公里），时间间隔为 6 分钟，单时次数  
110 据（即单张图片）的网格尺寸为  $480 \times 560$  像素。

111 在本文中，将数据集中每 20 张间隔为 6 分钟的雷达图像作为一个序列样本。在每个序  
112 列样本中，前 10 张回波图像作为输入，后 10 张作为实际输出，即根据过去一个小时的观察  
113 结果预测未来一小时的结果。将所有序列样本按 4:1 的比例划分为训练样本和检验样本，其  
114 中训练样本包含 21103 组，检验包含 5275 组，使用训练样本对网络模型进行训练，使用检  
115 验样本进行测试评估。由于检验样本没有参与算法的训练和参数调整，因此可以客观地衡量  
116 算法的学习能力和预报效果。

117 使用江苏省 2022 年 4-9 月雷达数据资料，采用与上文相同的处理方式，从中挑选并划  
118 分出 5143 组序列样本用于检验算法的泛化性能及在实际业务中的可用性。

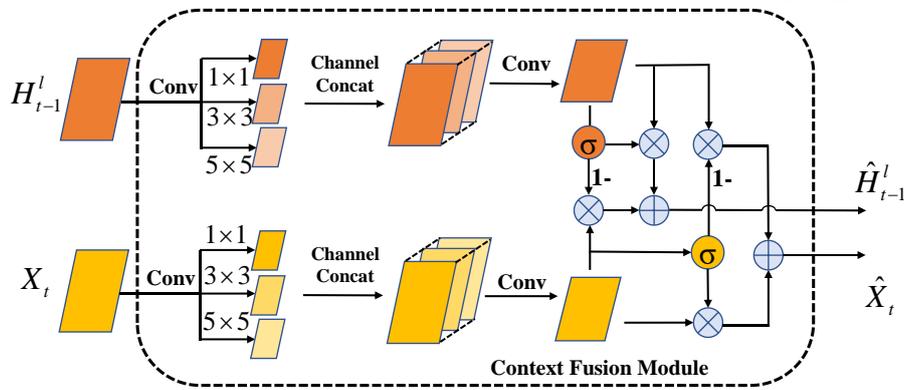
## 119 2 算法描述

120 本节详细介绍 CAST-LSTM 模型。首先介绍上下文融合模块，然后阐述注意力模块，并  
121 描述如何将上下文融合模块和注意力模块嵌入到 ST-LSTM 单元中。最后，将介绍所提出的

122 CAST-LSTM 模型的整体外推结构。

123 2.1 上下文融合模块

124 在基于 LSTM 的模型（如 ConvLSTM、PredRNN 等）中具有由输入门、遗忘门、输入  
 125 调制门和输出门组成的门控结构，这些门控在当前输入  $X_t$  和先前隐藏状态  $H_{t-1}^l$  中分别学习  
 126 新输入特征和先前特征， $X_t$  和  $H_{t-1}^l$  之间不仅在时间上存在先后关系，在空间上也存在着低  
 127 层和高层的关系。因此，这种上下文间的密切联系对预测结果的准确性至关重要。而现有网  
 128 络当前输入和先前隐藏状态之间仅仅通过卷积层和加法操作单独交互。随着模型深度的增加，  
 129 当前输入和先前隐藏状态之间的上下文关系会逐步减弱，这将导致模型的短期相关性信息丢  
 130 失。因此，本文提出了一种上下文融合模块，如图 1 所示。



131

132

133

图 1 上下文融合模块  
 Fig.1 Context fusion module

134 图中  $X_t$  和  $H_{t-1}^l$  表示上下文信息，其中  $X_t$  表示当前输入， $H_{t-1}^l$  表示先前隐藏状态；“Conv”  
 135 表示卷积操作，“ $\sigma$ ”表示 sigmoid 函数，“Channel Concat”表示通道拼接。

136 在卷积操作中，卷积核大小代表着感受野的范围大小。卷积核偏小时，每次滑动提取信  
 137 息的范围更小，偏向于捕捉较小范围间变化较慢的信息；卷积核偏大时，每次滑动提取信  
 138 息的范围更大，偏向于捕捉较大范围间变化较快的信息。因此，不同尺寸的卷积运算相结合可  
 139 以充分提取雷达回波图像中更全面的多尺度时空演变特征，而好的预测结果需要网络模型充  
 140 分的提取特征。因此，本文提取上下文不同尺度时空特征如公式（1）所示：

141

$$\begin{aligned} X_t' &= \text{Concat}(W_x^{k \times k} * X_t), k = 1, 3, 5 \\ H_{t-1}^{l'} &= \text{Concat}(W_h^{k \times k} * H_{t-1}^l), k = 1, 3, 5 \end{aligned} \quad (1)$$

142

其中“\*”表示二维卷积，“Concat”表示通道拼接， $W_x^{k \times k}$  表示  $X_t$  的卷积核， $W_h^{k \times k}$  表示  $H_{t-1}^l$  的

143

卷积核， $k \times k$  表示卷积核尺寸。首先，将当前输入  $X_t$  和先前隐藏状态  $H_{t-1}^l$  分别进行卷积

144 核为  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$  的卷积操作，提取上下文信息中不同尺度的细节时空特征。然后分  
 145 别进行通道拼接，然后再对其进行卷积操作使通道还原，得到带有多尺度特征信息的当前输  
 146 入  $X_t^l$  和先前隐藏状态  $H_{t-1}^l$ 。

147 然后，将当前输入  $X_t^l$  和先前隐藏状态  $H_{t-1}^l$  进行融合，为了控制信息的融合率，两个融  
 148 合门如公式（2）所示：

$$149 \quad \begin{aligned} U_x &= \sigma(W_{xu} * X_t^l) \\ U_h &= \sigma(W_{hu} * H_{t-1}^l) \end{aligned} \quad (2)$$

150 其中  $U_x$  表示当前时刻  $X_t^l$  融合门， $U_h$  表示先前时刻  $H_{t-1}^l$  融合门，“ $\sigma$ ”表示 sigmoid 函数，  
 151  $W_{xu}$  表示  $X_t^l$  的卷积核， $W_{hu}$  表示  $H_{t-1}^l$  的卷积核。通过两个门控进行融合，如公式（3）所示，

$$152 \quad \begin{aligned} \hat{X}_t &= U_x \odot (W_{xx} * X_t^l) + (1 - U_x) \odot (W_{hx} * H_{t-1}^l) \\ \hat{H}_{t-1} &= U_h \odot (W_{hh} * H_{t-1}^l) + (1 - U_h) \odot (W_{xh} * X_t^l) \end{aligned} \quad (3)$$

153 其中“ $\odot$ ”表示矩阵点乘运算， $W$  表示对应的卷积核。

154 上述公式可见，通过对上下文信息进行不同尺寸的卷积来提取更精细的多尺度时空特征。  
 155 使用融合门来控制上下文融合过程，提高了当前输入和先前隐藏状态的上下文相关性。

## 156 2.2 注意力模块

157 为了进一步提高模型的长期依赖能力，减少信息在传递中的遗忘问题。本文提出了一种  
 158 注意力模块，如图 2 所示。该模块根据当前时刻空间状态  $M_t^{l-1}$  和历史时刻空间状态  
 159  $M_{t-\tau}^{l-1} (\tau=1,2,\dots,5)$  的相关系数分配注意力权重，相关系数越大表明两者的关系密切程度越大。  
 160 基于注意力权重对历史时间记忆信息给予不同程度的注意力，并将历史时间记忆信息聚合为  
 161 长期记忆信息  $C_{att}$ 。因此，预测单元可以从更宽的感受域感知更多的时间动态。然后，进一  
 162 步将长期记忆信息  $C_{att}$  和短时记忆信息  $C_{t-1}^l$  融合为最终的增强记忆信息  $C_{emu}$ 。

163 首先，当前时间空间状态  $M_t^{l-1}$  与历史时间空间状态  $M_{t-\tau}^{l-1} (\tau=1,2,\dots,5)$  之间的相关性注意  
 164 力分数，如公式（4）所示：

$$165 \quad \begin{aligned} M^j &= W_m * M_t^{l-1} \\ \alpha_j &= \text{Softmax}(M_{t-\tau}^{l-1} \cdot M^j), \tau=1, 2, \dots, 5 \end{aligned} \quad (4)$$

166 特别地，当  $l=1$  时， $M_t^{l-1} = X_t$ ， $M_{t-\tau}^{l-1} = X_{t-\tau}$ 。其中， $W_m$  表示  $M_t^{l-1}$  的卷积核，“ $*$ ”表示卷

167 积运算，“ $\cdot$ ”表示点积运算，先对  $M_t^{l-1}$  进行卷积运算得到  $M'$ ，其次将  $M'$  分别与历史多个  
 168 时间步的空间记忆  $M_{t-\tau}^{l-1} (\tau=1,2,\dots,5)$  点积运算，然后使用 Softmax 激活函数进一步归一化为  
 169 注意力分数  $\alpha_j$ 。

170 为了帮助空间信息在时域内对历史信息  $C_{t-j}^l$  进行监督，将注意力得分  $\alpha_j$  应用于相  
 171 应的记忆单元，如公式 (5) 所示：

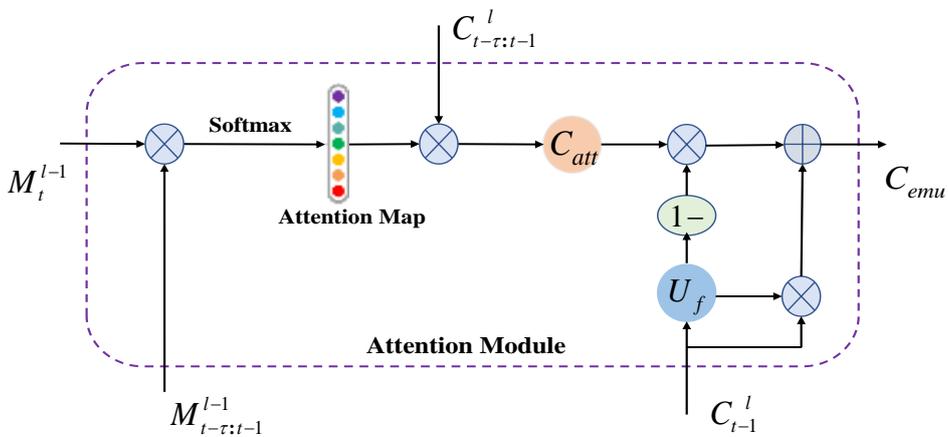
$$172 \quad C_{att} = \sum_{j=1}^{\tau} \alpha_j \cdot C_{t-j}^l, (\tau=5) \quad (5)$$

173 其中， $C_{att}$  可以表示为时间注意力信息，代表一种长期的运动趋势。通过当前空间状态与历  
 174 史空间状态之间相关性所得的注意力分数可以更好的、有选择性地保留历史信息单元的  
 175 信息。

176 为了有效的聚合长期运动趋势信息  $C_{att}$  和短时运动信息  $C_{t-1}^l$ ，通过设置一个融合门  $U_f$  来  
 177 控制两者间的融合率，如公式 (6) 所示：

$$178 \quad \begin{aligned} U_f &= \sigma(W_f * C_{t-1}^l) \\ C_{emu} &= U_f \odot C_{t-1}^l + (1-U_f) \odot C_{att} \end{aligned} \quad (6)$$

179 其中  $W_f$  表示短时运动信息  $C_{t-1}^l$  的卷积核，“ $\odot$ ”表示矩阵点乘运算，“ $\sigma$ ”表示 sigmoid 激活  
 180 函数。通过  $U_f$  来控制短时运动状态信息保留的百分比，通过  $(1-U_f)$  控制长期的运动趋势信  
 181 息保留的百分比，得到最终的增强运动信息  $C_{emu}$ 。



182 图 2 嵌入模型的注意力模块  
 183 Fig.2 Attention module embedded in model  
 184

185 2.3 CAST-LSTM 单元

186 在本小节中，将介绍 CAST-LSTM 单元的内部结构。如图 3 所示，CAST-LSTM 单元的  
 187 输入包括当前输入  $X_t$ 、空间记忆单元  $M_t^{l-1}$ 、时间记忆单元  $C_{t-1}^l$ 、历史时间记忆集  $C_{t-\tau:t-1}^l$ 、历  
 188 史空间记忆集  $M_{t-\tau:t-1}^{l-1}$  和隐藏状态  $H_t^{l-1}$ 。当前输入  $X_t$  和隐藏状态  $H_t^{l-1}$  首先通过上下文融合块  
 189 提取不同尺度的细节时空特征后进行信息融合，得到新的输入  $\hat{X}_t$  和隐藏状态  $\hat{H}_t^{l-1}$ 。当前空  
 190 间记忆单元  $M_t^{l-1}$ 、历史空间记忆集  $M_{t-\tau:t-1}^{l-1}$ 、时间记忆单元  $C_{t-1}^l$ 、历史时间记忆集  $C_{t-\tau:t-1}^l$  作为  
 191 注意力模块的输入，得到增强的记忆单元  $C_{emu}$ 。CAST-LSTM 单元的计算如式 (7) 所示：

$$\begin{aligned}
 & \hat{X}_t, \hat{H}_t^{l-1} = FM(X_t, H_t^{l-1}) \\
 & i_t = \sigma(W_{xi} * \hat{X}_t + W_{hi} * \hat{H}_t^{l-1} + b_i) \\
 & g_t = \tanh(W_{xg} * \hat{X}_t + W_{hg} * \hat{H}_t^{l-1} + b_g) \\
 & f_t = \sigma(W_{xf} * \hat{X}_t + W_{hf} * \hat{H}_t^{l-1} + b_f) \\
 & C_t^l = i_t \odot g_t + f_t \odot Att(C_{t-1}^l, C_{t-\tau:t-1}^l, M_t^{l-1}, M_{t-\tau:t-1}^{l-1}) \\
 & i_t' = \sigma(W_{xi}' * \hat{X}_t + W_{mi}' * M_t^{l-1} + b_i') \\
 & g_t' = \tanh(W_{xg}' * \hat{X}_t + W_{mg}' * M_t^{l-1} + b_g') \\
 & f_t' = \sigma(W_{xf}' * \hat{X}_t + W_{mf}' * M_t^{l-1} + b_f') \\
 & M_t^l = i_t' \odot g_t' + f_t' \odot M_t^{l-1} \\
 & o_t = \sigma(W_{xo} * \hat{X}_t + W_{ho} * \hat{H}_t^{l-1} + W_{co} * C_t^l + W_{mo} * M_t^l + b_o) \\
 & H_t^l = o_t \odot \tanh(W_{kl} * [C_t^l, M_t^l])
 \end{aligned} \tag{7}$$

193 其中，“FM”表示上下文融合模块，“Att”表示注意力模块， $i_t$  为第一输入门， $g_t$  为第一输  
 194 入调制门， $f_t$  为第一遗忘门， $i_t'$  为第二输入门， $g_t'$  为第二输入调制门， $f_t'$  为第二遗忘门，  
 195  $o_t$  为输出门， $C_t^l$  表示更新的时间记忆单元， $M_t^l$  表示更新的空间记忆单元， $W$  表示对应的  
 196 卷积核， $b$  表示对应的偏差值。“\*”表示 2D 卷积运算，“ $\odot$ ”表示矩阵点乘运算，“ $\sigma$ ”表  
 197 示 sigmoid 激活函数， $\tanh$  表示双曲正切激活函数， $\tau$  是历史时间步数。特别地，在 Att 方  
 198 程中，当  $l=1$  时， $M_t^{l-1} = X_t$ ， $M_{t-\tau}^{l-1} = X_{t-\tau}$ 。

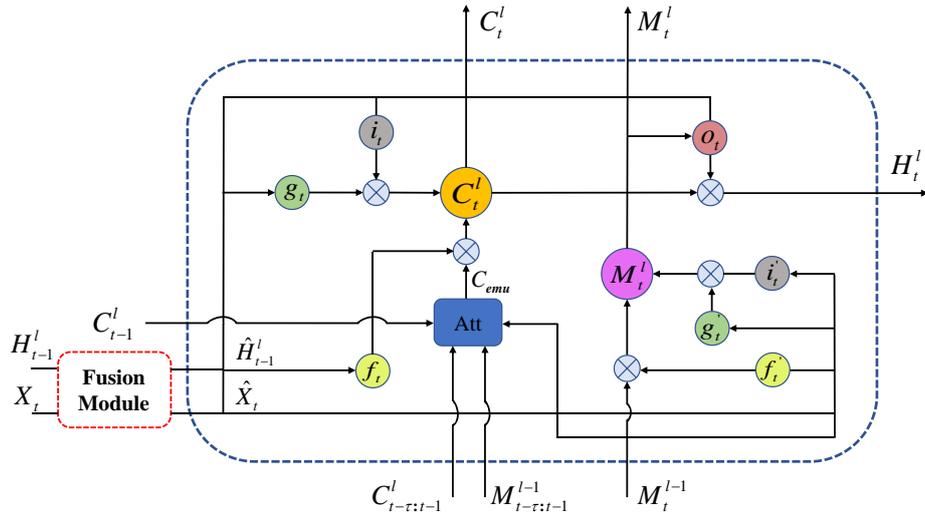


图3 上下文融合注意力长短期记忆单元内部结构图

Fig.3 Internal structure diagram of context fusion attention long short-term memory unit

### 2.4 CAST-LSTM 网络结构

CAST-LSTM 模型的网络结构如图4所示。通过堆叠四层CAST-LSTM单元以构建网络，在网络中，沿“之”字形方向更新空间存储单元M(如橘色线所示)，并在水平方向更新时间存储单元C(如蓝色线所示)，顶层输出预测结果 $\hat{X}_t$ 。

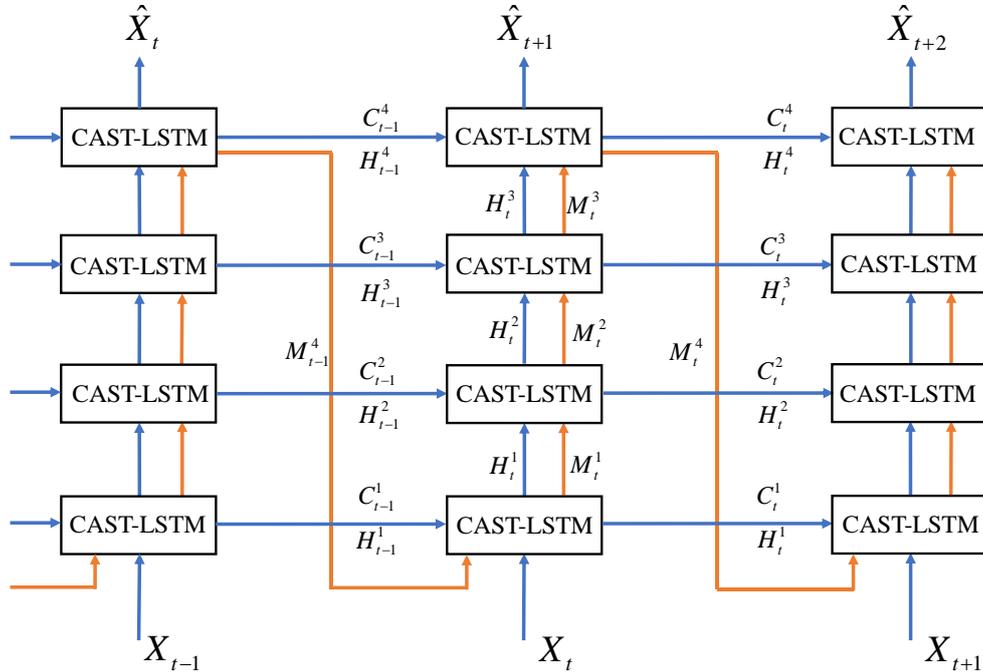


图4 CAST-LSTM 网络模型结构

Fig.4 CAST-LSTM network model structure

## 3 试验分析

在本章节，将分别在 Moving MNIST 数据集和 2019-2021 年 4-9 月江苏省气象雷达数据

211 分别进行实验，在 2022 年 4-9 月江苏省气象雷达数据上进一步检验算法的泛化性能及在实  
 212 际业务中的可用性，并与现有模型对比分析。按照图 4 所示应用了四层 CAST-LSTAM 单元，  
 213 每个单元的通道数设置为 64，通道数即预测单元中进行卷积操作时的卷积核数量，卷积核  
 214 大小设置为  $5 \times 5$ 。所有模型均在基于 Pytorch 框架上进行训练和测试，实验在 NVIDIA A10  
 215 GPU 上实现，输入图像的大小受硬件设备限制(如 GPU 显存)，本文实验中占用显存约 21Gb。  
 216 选择 Adam 优化器进行优化，其学习率设置为 0.0001，而批大小设置为 4。为了稳定训练过  
 217 程，在 CAST-LSTM 中的每个卷积层之后使用层归一化。

### 218 3.1 Moving MNIST 实验

#### 219 3.1.1 结果与分析

220 为了评估性能，本文采用了两种常用的指标，包括均方误差(Mean Square Error, MSE)、  
 221 结构相似性指数(Structural Similarity Index, SSIM)。较低 MSE 及较高的 SSIM 表示更好  
 222 的预测性能，如表 1 所示。

223 表 1: 不同方法在移动 MNIST 数据集(10 frames  $\rightarrow$  10 frames)上的结果

224 Table 1 : Results of different methods on moving MNIST datasets ( 10 frames  $\rightarrow$  10 frames )

Method	MSE/frame↓	SSIM/frame↑
ConvLSTM	102.3	0.725
PredRNN	55.8	0.866
PredRNN++	45.6	0.895
MIM	44.1	0.905
E3D-LSTM	40.3	0.913
PFST-LSTM	35.3	0.924
<b>CAST-LSTM</b>	<b>29.7</b>	<b>0.938</b>

225 本文提出的 CAST-LSTM 显著优于其他方法，尤其是在最后两个时间步中的预测，如图  
 226 5 所示。CAST-LSTM 网络很好地保留了数字的变化细节，特别是处理重叠的轨迹，保持了  
 227 随时间变化的清晰度。想比较之下，ConvLSTM、PredRNN 网络预测结果很快变得模糊，逐  
 228 渐丢失细节信息；而其他方法虽然也能取得一定的预测结果，但在最后时间步的预测结果中  
 229 CAST-LSTM 可以保留更多的细节信息，在位置精度和空间外观方面更有优势。

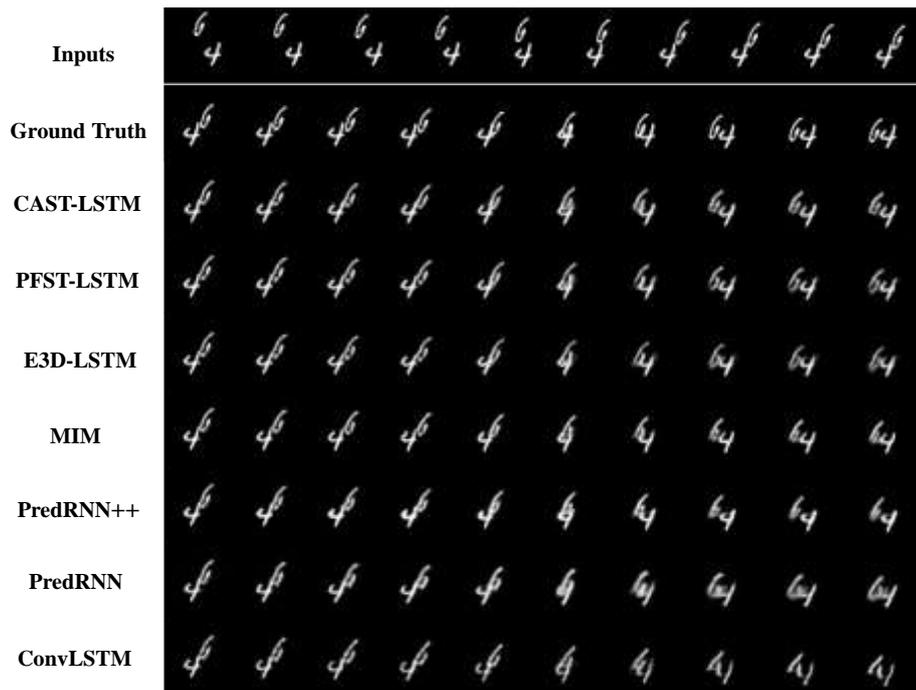


图 5 不同方法在移动 MNIST 数据集上的结果

Fig.5 Results of different methods on mobile MNIST dataset

230  
231  
232

### 3.2 雷达数据集实验

234 本实验实现以过去十个时间步的观察结果来预测未来十个时间步的结果。本文使用数据  
235 集为间隔 6 分钟的连续雷达资料，即根据过去一个小时的观察结果预测未来一小时的结果。

#### 3.2.1 评估指标

237 在评估方面，本文使用临界成功指数 (Critical Success Index, CSI) 和 Heidke Skill Score  
238 (HSS) 指标来评估结果。为此，应用以下变换将地面实况和预测回波图的像素值  $p$  转换为  
239 反射率 dBZ，如公式 (8) 所示：

$$240 \quad dBZ = p^{95 / 255} \quad (8)$$

241 通过设置阈值将预测回波图和地面实况图转换为二进制矩阵。如果雷达回波值大于给定  
242 阈值，则将相应的值设置为 1；否则设置为 0。类比到气象上如表 2 所示，计算真阳性预测  
243 数 TP (预测=1, 真值=1)、假阳性预测数 FP (预测=1, 真值=0)、真阴性预测数 TN (预测  
244 =0, 真值=0) 和假阴性预测数 FN (预测=0, 真值=1)。

245  
246

表 2 列联表

Table 2 contingency table

	预测	预测
真实	TN (True negative)	FP (False positive)
真实	FN (False negative)	TP (True positive)

247 CSI 和 HSS 的具体公式如公式 (9) 所示:

$$\begin{aligned}
 248 \quad CSI &= \frac{TP}{TP + FN + FP} \\
 HSS &= \frac{2(TP \times TN - FN \times FP)}{(TP + FN)(FN + TN) + (TP + FP)(FP + TN)}
 \end{aligned}
 \tag{9}$$

249 具体来说, 分别选择 10、20 和 40 dBZ 作为阈值。CSI 和 HSS 是综合度量, 考虑了检测概  
 250 率和虚警率, 可以直接反映模型的优劣。CSI 和 HSS 越大, 性能越好。

251 3.2.2 结果与分析

252 表 3 显示了在江苏省雷达数据集不同方法的对比结果。可以看到本文提出的  
 253 CAST-LSTM 模型在所有阈值下的 CSI 和 HSS 性能最佳, 并且随着阈值的增加, 模型的优  
 254 势变得越来越明显。特别是, 当阈值为 40dBZ 时, 评估的 CSI 和 HSS 指标达到 0.2369 和  
 255 0.3075, 分别比 PredRNN 算法提高 30.5% 和 31.5%, 比 PFST-LSTM 算法高 9.9% 和 8.6%。  
 256 这意味着开发的上下文融合模块和注意力模块有助于提高对强降雨区域的预测效果。

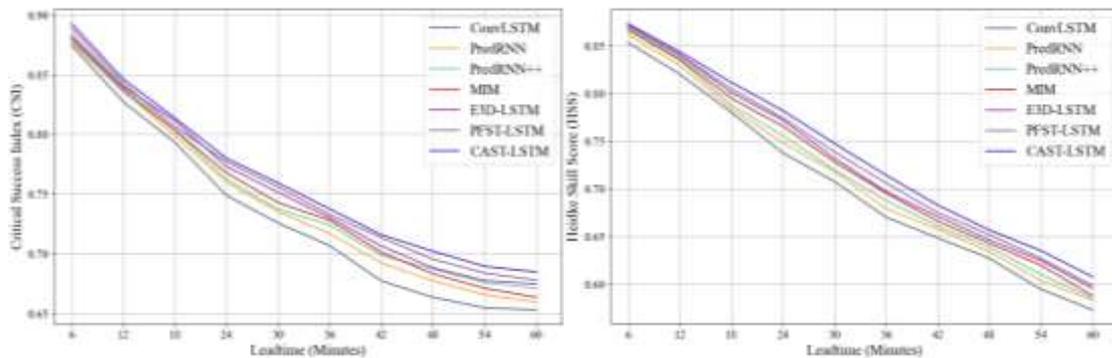
257 表 3 不同方法下外推 60 分钟的 CSI 和 HSS 评分结果

258 Table 3 Scoring results of CSI and HSS under different methods

dBZ Threshold	CSI↑				HSS↑			
	10	20	40	avg	10	20	40	avg
ConvLSTM	0.7331	0.4914	0.1545	0.4597	0.7119	0.5291	0.2193	0.4868
PredRNN	0.7415	0.5054	0.1815	0.4761	0.7172	0.5446	0.2338	0.4985
PredRNN++	0.7472	0.5173	0.1893	0.4846	0.7162	0.5516	0.2589	0.5089
MIM	0.7479	0.5117	0.2026	0.4874	0.7213	0.5501	0.2785	0.5166
E3D-LSTM	0.7528	0.5145	0.1738	0.4804	0.7259	0.5472	0.2275	0.5002
PFST-LSTM	0.7561	0.5207	0.2156	0.4975	0.7294	0.5588	0.2832	0.5238
<b>CAST-LSTM</b>	<b>0.7611</b>	<b>0.5326</b>	<b>0.2369</b>	<b>0.5102</b>	<b>0.7335</b>	<b>0.5735</b>	<b>0.3075</b>	<b>0.5382</b>

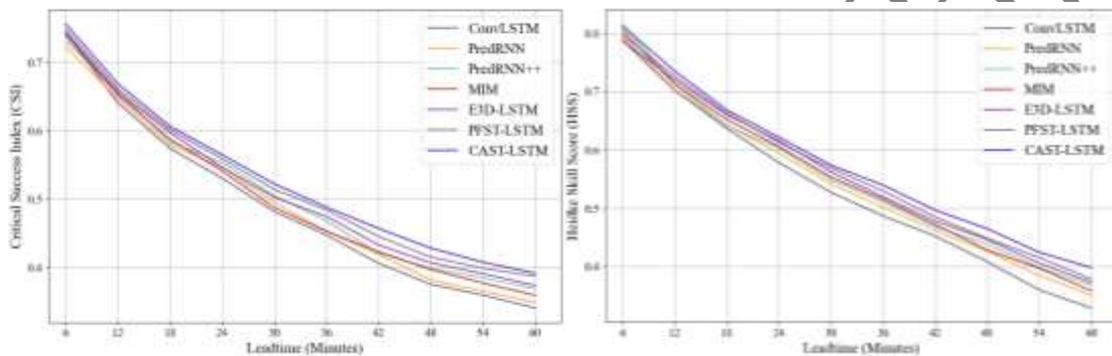
259 为了更好的说明结果, 描述了图 6 所示的 CSI 和 HSS 在不同预报时刻的变化曲线, 以  
 260 显示各种模型在不同时间步下的性能。可以看到, 本文提出的模型整体上优于其他模型, 在  
 261 40dBZ 时差距最为明显, 原因是 CAST-LSTM 融入了上下文融合模块和注意力模块, 上下文  
 262 融合模块充分提取不同尺度时空信息, 提高上下文相关性; 注意力模块可以从更宽的感受域  
 263 感知更多的时间动态, 减少了信息丢失, 这更好地模拟了短期和长期依赖关系。因此,  
 264 CAST-LSTM 可以更好的保留预测结果的细节性, 在强回波区域的预测结果也表现的更出色。  
 265 此外, PredRNN 的结果总是比本文提出的模型差, 尤其是在高阈值下。这是因为 PredRNN  
 266 存在没有充分提取上下文相关性信息和记忆单元信息丢失的问题。此外, 由于伪流位置对齐

267 模块的设计, PFST-LSTM 取得了第二的性能。至于 ConvLSTM 模型, 它的性能在实验中表  
 268 现最差。



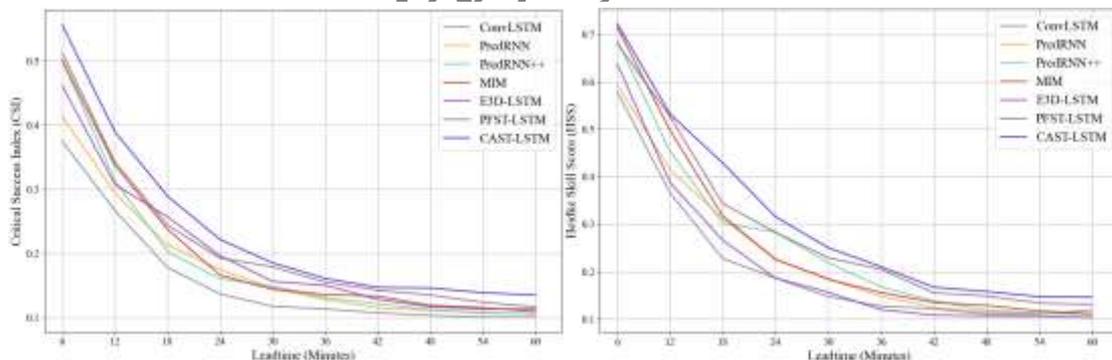
269 (1) 阈值为 10 的 CSI 变化  
 270 (a) The CSI as threshold=10  
 271

(2) 阈值为 10 的 HSS 变化  
 (b) The HSS as threshold=10



272 (3) 阈值为 20 的 CSI 变化  
 273 (c) The CSI as threshold=20  
 274

(4) 阈值为 20 的 HSS 变化  
 (d) The HSS as threshold=20



275 (5) 阈值为 40 的 CSI 变化  
 276 (e) The CSI as threshold=40  
 277

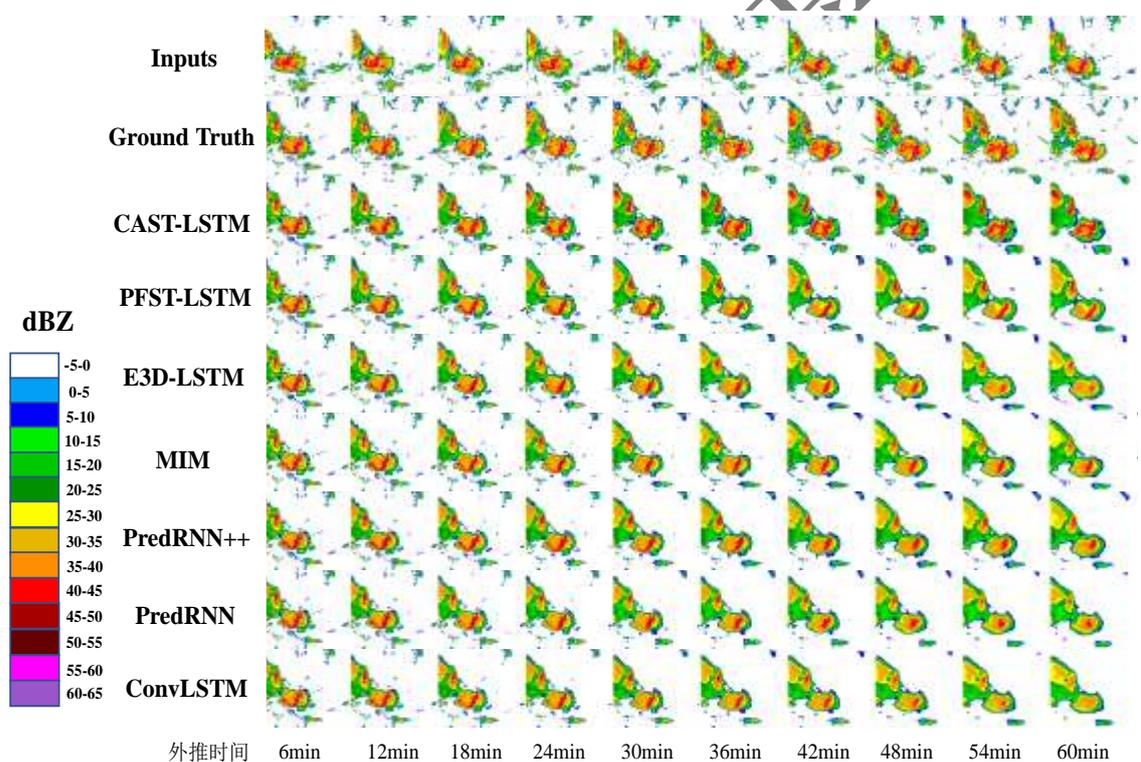
(6) 阈值为 40 的 HSS 变化  
 (f) The HSS as threshold=40

278 图 6 各算法在不同阈值下回波预报的 CSI 和 HSS 分数

279 Fig.6 CSI and HSS scores of echo prediction of each algorithm under different thresholds

280 为了更好的比较和理解结果, 在图 7 中可视化了由不同方法生成的外推 60 分钟的预测  
 281 示例。从地面真值序列中看到, 回波图像有三个主要的强回波区域, 回波区域的强度变得更  
 282 高, 位置也随之变化, 且主要回波区域向图像右侧移动。在第 18 分钟内, 各个模型之间的  
 283 预测结果差异较小, 且非常接近实况。然后, 随着预测时间的增加, 强回波开始衰减, 同时

284 预报图像的细节也开始减少。第 36 分钟，尽管每个模型的预测结果中都丢失了一些细节，  
 285 但仍可以大致预测回波的整体轮廓和变化趋势，其中 CAST-LSTM 的预测效果最好。随着预  
 286 测时间继续增加，ConvLSTM 的外推结果逐渐变得模糊，强回波区域逐渐变小甚至消失，  
 287 整个预测边界区域也逐渐平滑，只能预测出回波的大致轮廓。这是因为 ConvLSTM 只关注  
 288 时间信息而忽略了来自不同单元层之间的空间信息。PredRNN 在最后时刻尽管保留了部分  
 289 红色区域，但回波强度仍被大大低估了。同样的问题也出现在 PredRNN++、E3D-LSTM 和  
 290 MIM 的外推图像中。尽管这些方法同时关注了时空信息，但这些网络在预测过程中存在信  
 291 息丢失问题，因此随时间增加回波逐步衰减。与上述方法相比，PFST-LSTM 和 CAST-LSTM  
 292 的外推图与观测结果更相似，但只有 CAST-LSTM 模型更好地保留三个强回波区域，且预测  
 293 结果的细节性也较高。这是因为 CAST-LSTM 的时空感知注意力机制能有效改善信息丢失问  
 294 题，且多尺度上下文融合模块可以更好的帮助网络在预测中保持较多的细节性。



295 外推时间 6min 12min 18min 24min 30min 36min 42min 48min 54min 60min  
 296 图 7 不同方法下外推 60min 的预测结果。第一行为每次预测时输入的一个时次雷达图像，第二行为实际输出。  
 297 其他行为不同模型下的预测结果

298 Fig.7 Prediction results of 60 min extrapolation under different methods. The first line is input and the second line  
 299 is live output. The other lines are predictions under different models

300 此外，为了说明模型的泛化性及在业务中的实际可用性，本文使用江苏省 2022 年 4-9  
 301 月雷达数据进行验证。本文在 3 个阈值条件下进行外推时长为 1h 的实验，表 4 显示了使用  
 302 不同模型的实验结果。

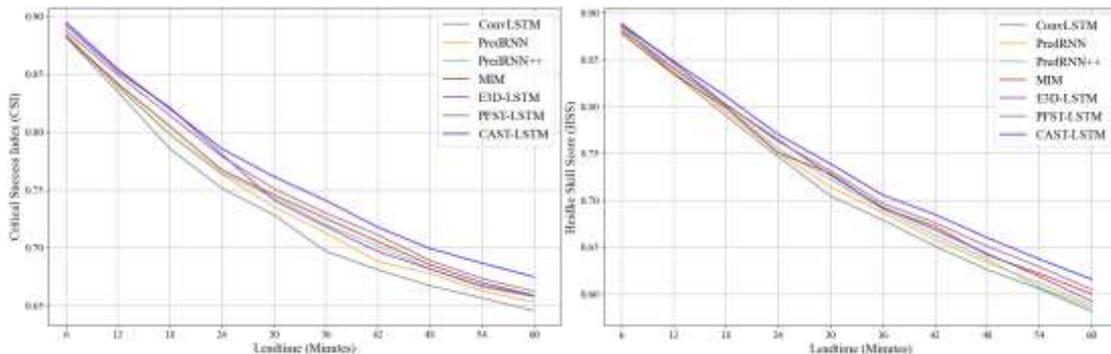
303  
304  
305

表 4 不同方法下外推 60 分钟的 CSI 和 HSS 评分结果  
Table 4 Scoring results of CSI and HSS under different methods

dBZ Threshold	CSI↑				HSS↑			
	10	20	40	avg	10	20	40	avg
ConvLSTM	0.7328	0.4849	0.1518	0.4565	0.7105	0.5215	0.2158	0.4826
PredRNN	0.7412	0.4936	0.1803	0.4717	0.7158	0.5453	0.2325	0.4979
PredRNN++	0.7454	0.5056	0.1869	0.4793	0.7182	0.5519	0.2554	0.5085
MIM	0.7485	0.5133	0.2011	0.4876	0.7216	0.5584	0.2763	0.5188
E3D-LSTM	0.7508	0.5067	0.1827	0.4801	0.7242	0.5468	0.2308	0.5006
PFST-LSTM	0.7545	0.5223	0.2144	0.4971	0.7275	0.5563	0.2806	0.5215
<b>CAST-LSTM</b>	<b>0.7634</b>	<b>0.5278</b>	<b>0.2331</b>	<b>0.5081</b>	<b>0.7357</b>	<b>0.5624</b>	<b>0.3037</b>	<b>0.5339</b>

306 除了本文提出的 CAST-LSTM 模型之外,还采用了 ConvLSTM、PredRNN、PredRNN++、  
307 MIM、E3D-LSTM 和 PFST-LSTM 先进模型进行对比。可以看到本文提出的 CAST-LSTM 模  
308 型在所有阈值下的 CSI 和 HSS 性能最佳,并且随着阈值的增加,模型的优势变得越来  
309 显。特别是,当阈值为 40dBZ 时,评估的 CSI 和 HSS 指标达到 0.2316 和 0.2917,分别比  
310 PredRNN 算法提高 29.3%和 30.6%,比 PFST-LSTM 算法高 8.7%和 8.2%。这意味着提出  
311 的上下文融合模块和注意力模块有助于提高对强回波区域的预测效果。

312 为了更直观地观察外推中数据变化过程,对不同阈值条件下 CAST-LSTM 模型与  
313 ConvLSTM、PredRNN 等其他主流算法在 10 个时序(1h)中各项指标变化进行统计,结果  
314 如图 8 所示。从图中可以看出我们的模型整体上优于其他模型,尤其是对强回波的预测能力,  
315 特别是在最后几个时序中,CAST-LSTM 模型实现了更好的预测结果。这是因为 CAST-LSTM  
316 模型更关注上下文特征信息的有效提取,并且通过注意力机制有效缓解了信息传递过程中的  
317 衰减问题。

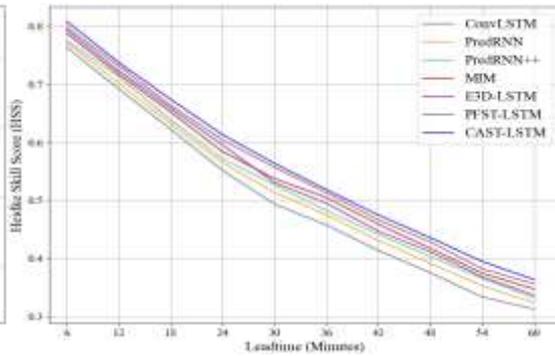
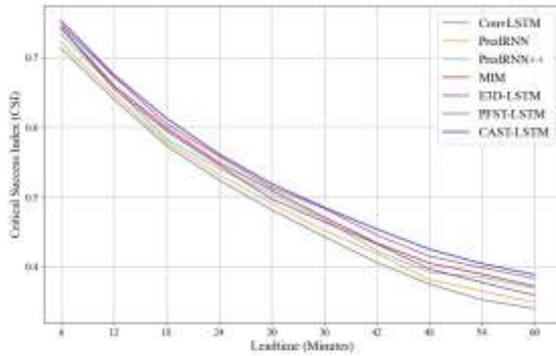


318

319  
320

(1) 阈值为 10 的 CSI 变化  
(a) The CSI as threshold=10

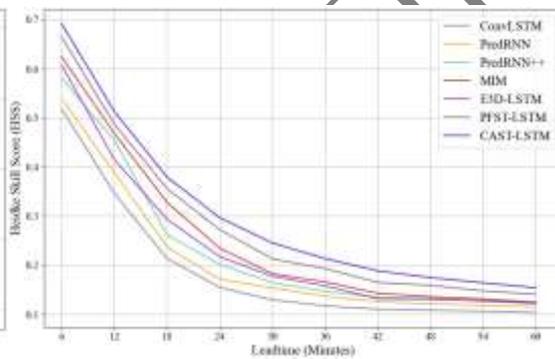
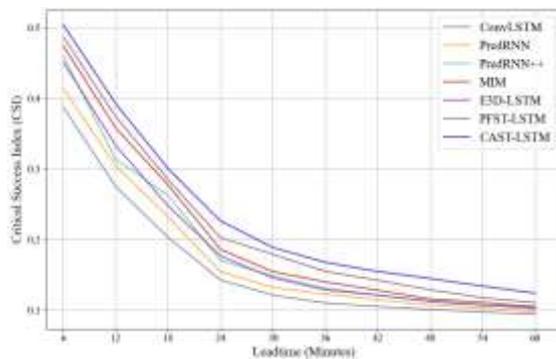
(2) 阈值为 10 的 HSS 变化  
(b) The HSS as threshold=10



321  
322  
323

(3) 阈值为 20 的 CSI 变化  
(c) The CSI as threshold=20

(4) 阈值为 20 的 HSS 变化  
(d) The HSS as threshold=20



324  
325  
326

(5) 阈值为 40 的 CSI 变化  
(e) The CSI as threshold=40

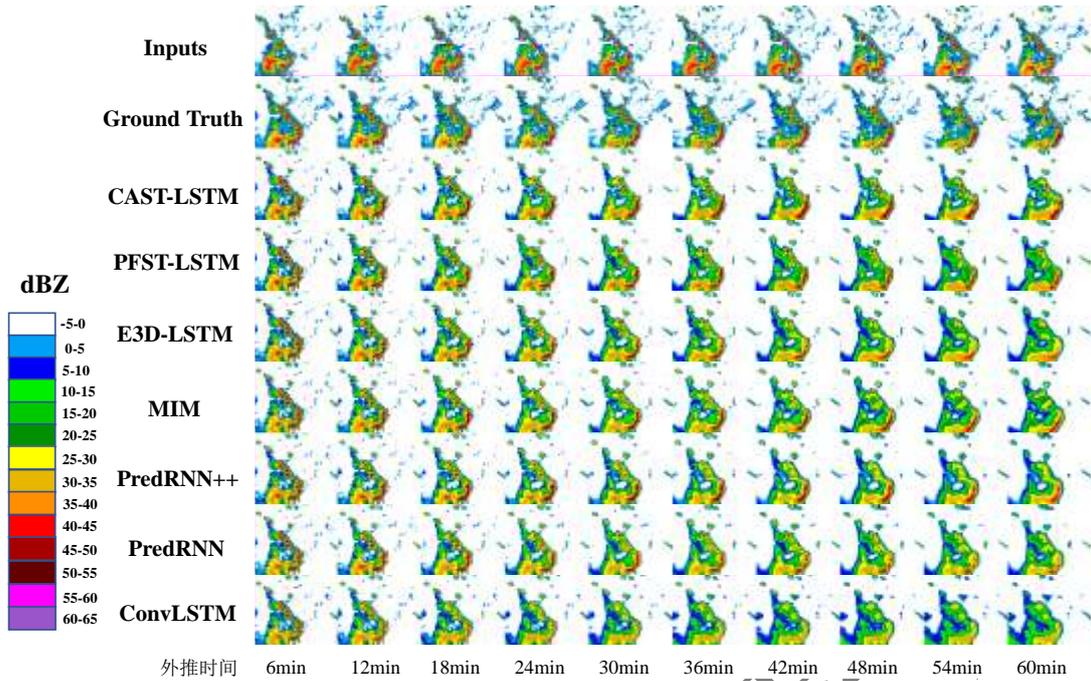
(6) 阈值为 40 的 HSS 变化  
(f) The HSS as threshold=40

图 8 各算法在不同阈值下回波预报的 CSI 和 HSS 分数

Fig.8 CSI and HSS scores of echo prediction of each algorithm under different thresholds

327  
328  
329  
330  
331  
332  
333  
334  
335  
336  
337  
338  
339  
340

为了更好的展示实验结果，在图 9 中可视化了由不同方法生成的外推 60 分钟的预测示例。从地面真值序列中看到，随着时间推移，回波图像有两个主要的强回波区域：其中，中下方的强回波区域向图像下方移动，且强度逐渐减弱；右侧带状强回波区域向图像右下方移动。从预测结果来看，所有模型都成功地预测了雷达回波的整体运动趋势，但外推图像在一些细节（如边界、回波强度）上仍存在差异。在预测时间第 18 分钟，各个模型之间的预测结果差异较小，且非常接近实况。第 18 分钟以后，ConvLSTM 的预测结果中强回波区域开始衰退。第 42 分钟，ConvLSTM 无法有效预测强回波区域的演变趋势，其他模型仍可以预测强回波区域的位置和雷达回波的部分细节。随着预报时间继续增加，其他模型相较于 ConvLSTM 保留了更多的高回波信息，其中 PredRNN 和 E3D-LSTM 在最后几个时刻中强回波区也逐渐消散，PredRNN++、MIM 外推结果有所改善，但对强回波的预测仍存在偏差。只有 PFST-LSTM 和 CAST-LSTM 可以更好的预测强回波区域，其中 CAST-LSTM 更能预测强回波区域的强度和位置，也可以很好地预测回波变化趋势且细节效果也更好。



341 外推时间 6min 12min 18min 24min 30min 36min 42min 48min 54min 60min  
 342 图9 不同方法下外推 60min 的预测结果。第一行为每次预测时输入的一个时次雷达图像，第二行为实际输出。  
 343 其他行为不同模型下的预测结果  
 344 Fig.9 Prediction results of 60 min extrapolation under different methods. The first line is input and the second line  
 345 is live output. The other lines are predictions under different models

#### 346 4 结论

347 本文提出了一种新的雷达回波外推方法，即 CAST-LSTM。使用 Moving MNIST 数据集  
 348 和 2019-2021 年 4-9 月江苏省气象雷达数据资料进行测试检验，并使用 2022 年 4-9 月江苏省  
 349 雷达数据进行实际验证。通过与几种现有算法的对比分析，得出以下结论：

- 350 (1) 在 Moving MNIST 数据集中，CAST-LSTM 算法的 MSE 为最低、SSIM 最高，与几  
 351 种现有算法相比，性能得到明显提升；在可视化实例中，CAST-LSTM 算法具有更  
 352 好的预测结果，很好地保留了数字的移动轨迹和变化细节。
- 353 (2) 在江苏省气象雷达数据中，CAST-LSTM 算法有效提高了预测精度；在可视化实例  
 354 中，CAST-LSTM 算法在较长的时间内有效提高预测结果的准确性，在强回波区域  
 355 的预测结果也表现的更出色。
- 356 (3) 本文提出的上下文融合模块有效提高网络单元的上下文相关性，提取多尺度特征信  
 357 息；注意力模块可以从拓宽的感受域中感知更多的时间动态，减少信息丢失。通过  
 358 将两个模块添加到网络模型中，可以进一步提高预报精度，特别是对于降雨量大且  
 359 强度持续增加的地区。

360 目前深度学习算法使雷达回波外推效果得到了很大的提升，但距离真实实况仍有一定的

361 差距。在后续的研究中,将研究如何在雷达回波外推任务中考虑更多的气象因素,探索更有  
362 效的算法进一步提高降水短临预报的预测能力。

## 363 参考文献

- 364 陈锦鹏, 冯业荣, 蒙伟光, 等, 2021. 基于卷积神经网络的逐时降水预报订正方法研究[J]. 气象, 47(1): 60-70. Chen J P, Feng Y R,  
365 Meng W G, et al, 2021. A correction method of hourly precipitation forecast based on convolutional neural network[J]. Meteor Mon,  
366 47(1): 60-70 (in Chinese).
- 367 顾建峰, 周国兵, 刘伯骏, 等, 2020. 人工智能技术在重庆临近预报业务中的初步研究与应用[J]. 气象, 46(10): 1286-1296. Gu J F,  
368 Zhou G B, Liu B J, et al, 2020. Study on artificial intelligence technology and its application to Chongqing operational  
369 nowcasting[J]. Meteor Mon, 46(10): 1286-1296 (in Chinese).
- 370 郭瀚阳, 陈明轩, 韩雷, 等, 2019. 基于深度学习的强对流高分辨率临近预报试验[J]. 气象学报, 77(4): 715-727. Guo H Y, Chen M  
371 X, Han L, et al, 2019. High resolution nowcasting experiment of severe convections based on deep learning[J]. Acta Meteor Sin,  
372 77(4): 715-727 (in Chinese).
- 373 黄骅文, 蔡荣辉, 姚蓉, 等, 2021. 深度学习网络在降水相态判别和预报中的应用[J]. 气象, 47(3): 317-326. Huang J W, Cai R H,  
374 Yao R, et al, 2021. Application of deep learning method to discrimination and forecasting of precipitation type[J]. Meteor Mon,  
375 47(3): 317-326 (in Chinese).
- 376 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[J]. 气象学报, 79(5): 817-827. Huang X Y, Ma  
377 Y R, Hu S M, 2021. Extrapolation and effect analysis of weather radar echo sequence based on deep learning[J]. Acta Meteor Sin,  
378 79(5): 817-827 (in Chinese).
- 379 尹麒名, 甘建红, 漆慧, 等, 2021. 一种改进的循环神经网络雷达图像外推算法[J]. 气象科技, 49(1): 18-24, 45, doi:  
380 10.19517/j.1671-6345.20200019. Yin Q M, Gan J H, Qi H, et al, 2021. An improved algorithm of radar image extrapolation based  
381 on recurrent neural network[J]. Meteor Sci Technol, 49(1): 18-24, 45, doi: 10.19517/j.1671-6345.20200019 (in Chinese).
- 382 周康辉, 郑永光, 韩雷, 等, 2021. 机器学习在强对流监测预报中的应用进展[J]. 气象, 47(3): 274-289. Zhou K H, Zheng Y G, Han L,  
383 et al, 2021. Advances in application of machine learning to severe convective weather monitoring and forecasting[J]. Meteor Mon,  
384 47(3): 274-289 (in Chinese).
- 385 Ayzel G, Heistermann M, Winterrath T, 2019. Optical flow models as an open benchmark for radar-based precipitation nowcasting  
386 (rainymotion v0.1)[J]. Geosci Model Dev, 12(4): 1387-1402.
- 387 Bei X Z, Yang Y C, Soatto S, 2021. Learning semantic-aware dynamics for video prediction[C]//Proceedings of the IEEE/CVF  
388 Conference on Computer Vision and Pattern Recognition. Nashville: IEEE: 902-912.
- 389 Chang Z, Zhang X F, Wang S S, et al, 2021. MAU: a motion-aware unit for video prediction and beyond[C]//35th Conference on Neural

390 Information Processing Systems. 26950-26962. (查阅网上资料, 未找到本条文献出版信息, 请确认并补充)

391 Chung K S, Yao I A, 2020. Improving radar echo Lagrangian extrapolation nowcasting by blending numerical model wind information:  
392 statistical performance of 16 typhoon cases[J]. *Mon Wea Rev*, 148(3): 1099-1120.

393 Geng L C, Geng H T, Min J Z, et al, 2022. AF-SRNet: quantitative precipitation forecasting model based on attention fusion mechanism  
394 and residual spatiotemporal feature extraction[J]. *Remote Sens*, 14(20): 5106.

395 Lakshmanan V, Hondl K, Rabin R, 2009. An efficient, general-purpose technique for identifying storm cells in geospatial images[J]. *J*  
396 *Atmos Oceanic Technol*, 26(3): 523-537.

397 Luo C Y, Li X T, Ye Y M, 2021. PFST-LSTM: a SpatioTemporal LSTM model with pseudo-flow prediction for precipitation  
398 nowcasting[J]. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 14: 843-857.

399 Marshall J S, Palmer W M K, 1948. The distribution of raindrops with size[J]. *J Meteor*, 5(4): 165-166.

400 Melis G, Kočiský T, Blunsom P, 2020. Mogrifler LSTM[C]//8th International Conference on Learning Representations. Addis Ababa:  
401 OpenReview.net.

402 Rinehart R E, Garvey E T, 1978. Three-dimensional storm motion detection by conventional weather radar[J]. *Nature*, 273(5660):  
403 287-289.

404 Shi X J, Chen Z R, Wang H, et al, 2015. Convolutional LSTM network: a machine learning approach for precipitation  
405 nowcasting[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal: MIT Press:  
406 802-810.

407 Singh S, Sarkar S, Mitra P, 2017. A deep learning based approach with adversarial regularization for Doppler weather radar ECHO  
408 prediction[C]//2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Fort Worth: IEEE: 5205-5208.

409 Tamaru R, Siritanawan P, Kotani K, 2021. Interaction aware relational representations for video prediction[C]//2021 IEEE International  
410 Conference on Systems, Man, and Cybernetics (SMC). Melbourne: IEEE: 2089-2094.

411 Tian C Y, Chan W K, 2021. Spatial-temporal attention wavenet: a deep learning framework for traffic prediction considering  
412 spatial-temporal dependencies[J]. *IET Intell Trans Syst*, 15(4): 549-561.

413 Wang Y B, Long M S, Wang J M, et al, 2017. PredRNN: recurrent neural networks for predictive learning using spatiotemporal  
414 LSTMs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran  
415 Associates Inc.: 879-888.

416 Wang Y B, Gao Z F, Long M S, et al, 2018. PredRNN++: towards a resolution of the deep-in-time dilemma in spatiotemporal predictive  
417 learning[C]//35th International Conference on Machine Learning. Stockholmssmassan: PMLR: 5110-5119.

418 Wang Y B, Jiang L, Yang M H, et al, 2019a. Eidetic 3D LSTM: a model for video prediction and beyond[C]//7th International Conference  
419 on Learning Representations. New Orleans: OpenReview.net.

- 420 Wang Y B, Zhang J J, Zhu H Y, et al, 2019b. Memory in memory: a predictive neural network for learning higher-order non-stationarity  
421 from spatiotemporal dynamics[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long  
422 Beach: IEEE: 9146-9154.
- 423 Woo W C, Wong W K, 2017. Operational application of optical flow techniques to radar-based rainfall nowcasting[J]. Atmosphere, 8(3):  
424 48.
- 425 Yang Z Y, Liu Q, Wu H, et al, 2023. CEMA-LSTM: enhancing contextual feature correlation for radar extrapolation using fine-grained  
426 echo datasets[J]. Comput Model Eng Sci, 135(1): 45-64.
- 427 Yin X Y, Wu G Z, Wei J Z, et al, 2022. Deep learning on traffic prediction: methods, analysis, and future directions[J]. IEEE Trans Intell  
428 Trans Syst, 23(6): 4927-4943.
- 429 Zhao J L, Liu Z B, Sun Q X, et al, 2022. Attention-based dynamic spatial-temporal graph convolutional networks for traffic speed  
430 forecasting[J]. Expert Syst Appl, 204: 117511.
- 431 Zou H B, Wu S S, Shan J S, et al, 2019. A method of radar echo extrapolation based on TREC and Barnes filter[J]. J Atmos Ocean  
432 Technol, 36(9): 1713-1727.