渠海峰,何光鑫,康志明,等,2023. CAST-LSTM:一种用于雷达回波外推的时空 LSTM 模型[J]. 气象,49(12):1481-1494. Qu H F,He G X,Kang Z M, et al,2023. CAST-LSTM: a spatio-temporal LSTM model for radar echo extrapolation[J]. Meteor Mon,49(12):1481-1494(in Chinese).

CAST-LSTM:一种用于雷达回波外推 的时空 LSTM 模型*

渠海峰1,2 何光鑫1,2 康志明3 程 勇1 王 军1 庄潇然3 李远禄1

1 南京信息工程大学,南京 210044

2 中国气象局广州热带海洋气象研究所,广东省区域数值天气预报重点实验室,广州 510640

3 江苏省气象台,南京 210008

提 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,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,通过试验对比分析,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了更好的预测性能。在外推 60 min,阈值为 10、20、40 dBz 的条件下,临界成功指数和 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 中图分类号: P456,P409 文献标志码: A

DOI: 10.7519/j.issn.1000-0526.2023.083101

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

QU Haifeng^{1,2} HE Guangxin^{1,2} KANG Zhiming³ CHENG Yong¹ WANG Jun¹ ZHUANG Xiaoran³ LI Yuanlu¹

1 Nanjing University of Information Science and Technology, Nanjing 210044

2 Guangzhou Institute of Tropical and Marine Meteorology, CMA/Guangdong Provincial

Key Laboratory of Regional Numerical Weather Prediction, Guangzhou 510640

3 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 severe 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 network based on context fusion and attention mechanism achieves better prediction performance through experimental comparison and analysis. Under the conditions of 60 min

第一作者:渠海峰,主要从事深度学习下的短时临近预报研究. E-mail: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.E-mail:kangzm@cma.gov.cn

^{*} 国家自然科学基金项目(41975183、41875184)、广东省"珠江人才计划"引进创新创业团队项目(2019ZT08G669)共同资助 2022 年 10 月 21 日收稿; 2023 年 6 月 12 日收修定稿

extrapolation and the thresholds of 10, 20 and 40 dBz, the critical success index (CSI) and heidke skill score (HSS) reach 0.7611, 0.5326, 0.2369 and 0.7335, 0.5735, 0.3075, respectively, which effectively improved the prediction accuracy.

Key words: radar echo extrapolation, deep learning, precipitation forecast, long short-term memory (LSTM)

引 言

降水短时临近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(通常是 0~2 h)的降雨量进行预测(Singh et al,2017),准确 的短时临近预报可以在暴雨、雷暴等恶劣天气提供 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,如何利用雷达回波外推 技术获取精准、快速的天气短时临近预报,成为气象 研究方面的热点问题。

降水短时临近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 and Palmer,1948)转换为降雨强度,作为最终短时临近 预报。传统的雷达回波外推方法主要有交叉相关法 (Rinehart and Garvey, 1978; Zou et al, 2019)、单体 质心法(Chung and Yao, 2020; Lakshmanan et al, 2009)和光流法(Ayzel et al, 2019; Woo and Wong, 2017)。交叉相关法是将整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,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。

近年来,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, 2021)、交通

流预测(Tian and Chan, 2021; Yin et al, 2022; Zhao et al,2022)和降水短时临近预报(陈锦鹏等,2021; 郭瀚阳等,2019;顾建峰等,2020;黄骄文等,2021;黄 兴友等,2021;尹麒名等,2021;周康辉等,2021;袁凯 等,2022;陈鹤等,2022)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,以便从大量先 前的雷达回波序列中自适应地学习降水量变化的规 律。例如,Shi et al(2015)提出了将卷积神经网络 (CNN)和长短期记忆网络(LSTM)相结合的卷积 LSTM(ConvLSTM)模型用于降水预测,LSTM 用 于提取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空间信息。Wang et al(2017)提出了 ST-LSTM 单元(spatio-temporal LSTM),通过在 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 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(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。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 史记忆状态相互作用。但由于集成的 3D 卷积,使 E3D-LSTM 的计算负载非常高。Wang et al (2019b)提出了 MIM(memory 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) 提出了一种新的 PFST-LSTM 单元 (pseudo flow spatio-temporal LSTM),其开发的空 间存储单元和位置对齐模块,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 CEMA-LSTM,引入多头注意机制块(MAB)

使用位置和信道注意机制来捕获雷达回波的全局特征。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征,实现了更精确的对流 降水预报。

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,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。

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(CAST-LSTM)。首先, 提出了上下文融合模块,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。将这两个模块集成到网络单 元中,性能显著提高,尤其是在强降雨地区。

1 数 据

1.1 Moving MNIST 数据集

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,几个数字 随机移动,具有一些运动模式,包括旋转缩放、亮度 变化等。每 20 个连续帧划分为一个序列。其中 10 帧用于输入,10 帧用于预测,每帧的大小为 64×64。 训练集包括 10 000 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 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。

1.2 雷达数据集

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 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,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。数据取值范围为 0~70 dBz,水平分辨 率为 0.01°(约 1 km),时间间隔为 6 min,单时次数 据(即单张图片)的网格尺寸为 480×560 像素。

在本文中,将数据集中每 20 张间隔为 6 min 的 雷达图像作为一个序列样本。在每个序列样本中, 前 10 张回波图像作为输入,后 10 张作为实际输出, 即根据过去一小时的观察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,其中训练样本含 21 103 组,检验样 本含 5275 组,使用训练样本对网络模型进行训练, 使用检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算 法的学习能力和预报效果。

使用江苏 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。

2 算法描述

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 CAST-LSTM 模型 的整体外推结构。

2.1 上下文融合模块

在基于 LSTM 的模型(如 ConvLSTM、Pred-RNN等)中具有由输入门、遗忘门、输入调制门和输 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_{t-1}中分别学习新的输入特征和先 前特征,X_t 和 H^t_{t-1}之间不仅在时间上存在先后关 系,在空间上也存在着低层和高层的关系。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,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失。 因此,本文提出了一种上下文融合模块,如图 1 所示。



注:X, 和 H_{t-1}表示上下文信息,其中 X, 表示当前时刻输入, H_{t-1}表示先前时刻隐藏状态;"σ"表示 Sigmoid 函数。

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

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 络模型充分的提取特征。因此,本文提取上下文不 同尺度时空特征如式(1)所示:

 $X'_{t} = \text{Concat}(W^{k \times k}_{x} * X_{t})$ k = 1,3,5 $H'_{t-1} = \text{Concat}(W^{k \times k}_{h} * H'_{t-1})$ k = 1,3,5 (1) 式中:"*"表示二维卷积(下同),"Concat"表示通道 拼接, $W^{k \times k}_{x}$ 表示二维卷积(下同),"Concat"表示通道 拼接, $W^{k \times k}_{x}$ 表示二维卷积(下同),"Concat"表示通道 有接, $W^{k \times k}_{x}$ 表示二维卷积(下同),"Concat"表示通道 有卷积核, $k \times k$ 表示卷积核尺寸,t 表示时刻,l 表示层。 首先,将当前输入 X_{t} 和先前隐藏状态 H'_{t-1} 分别进 行卷积核为1×1、3×3、5×5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入 X'_{t} 和先前隐藏 状态 H'_{t-1} 。

然后,将当前输入 X[']_t 和先前隐藏状态 H[']_{t-1}进 行融合,为了控制信息的融合率,两个融合门如下式 所示:

$$U_{x} = \sigma(W_{xu} * X'_{t})$$

$$U_{h} = \sigma(W_{hu} * H'_{t-1})$$
(2)

式中: U_x 为当前时刻 X'_t 的融合门, U_h 为先前时刻 H'_{t-1} 的融合门," σ "表示 Sigmoid 函数(下同), W_{xu}

表示 X'_{i} 的卷积核, W_{hu} 表示 H'_{i-1} 的卷积核。通过 两个门控进行融合, 如下式所示,

$$X_{t} = U_{x} \odot (W_{xx} * X'_{t}) + (1 - U_{x}) \odot (W_{hx} * H'_{t-1})$$

$$\hat{H}_{t-1} = U_{h} \odot (W_{hh} * H'_{t-1}) + (1 - U_{h}) \odot (W_{xh} * X'_{t})$$
(3)

式中:"⊙"表示矩阵的 Hadamard 积(下同),"W"表示对应的卷积核。

由上述公式可见,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。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。

2.2 注意力模块

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}^{-1} 和历史时刻空间状态 $M_{t-\tau,t-1}^{t-1}(\tau=5)$ 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。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,进一步将长期记忆信息 C_{att} 和短时记忆信息 C_{t-1} 融合为最终的增强记忆单元 C_{emu} 。

首先,当前空间状态 M_t^{l-1} 分别与历史空间状态 $M_{t-\tau,t-1}^{l-1}(\tau=5)$ 之间的相关性注意力分数,如式(4)



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

所示:

$$M' = W_m * M_t^{l-1}$$

$$\alpha_t = \text{Softmax}(M_t^{l-1} \dots \bullet M') \quad \tau = 5$$

$$(4)$$

式中:当l=1时, $M_{l}^{l-1}=X_{t}$, $M_{l-\tau_{tl-1}}^{l-1}=M_{l-\tau_{tl-1}}$ ($\tau=5$)。其中, W_{m} 表示 M_{l}^{l-1} 的卷积核,"•"表示矩阵的点乘,先对 M_{l}^{l-1} 进行卷积运算得到M',其次将M'分别与历史多个时间步的空间记忆 $M_{l-\tau_{tl-1}}^{l-1}$ ($\tau=5$)点乘运算,然后使用 Softmax 激活函数进一步归 一化为注意力分数 α_{i} 。

为了帮助空间信息在时域内对历史时间信息 *C*^{*l*}_{*t*-1}进行监督,将注意力得分*α*_{*j*}应用于相应的时间 记忆单元,如式(5)所示:

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

式中 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史空间状态 之间相关性所得的注意力分数可以更好地、有选择 性地保留历史时间记忆单元的信息。

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

$$U_{f} = \sigma(W_{f} * C'_{t-1})$$

$$C_{emu} = U_{f} \odot C'_{t-1} + (1 - U_{f}) \odot C_{att}$$
(6)

式中:W_f表示短时运动信息 C^{*l*}_{*t*-1}的卷积核。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息保留的百分比,得 到最终的增强记忆单元 C_{emu}。

2.3 CAST-LSTM 单元

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 $C_{t-\tau,t-1}^{l}$ 、历史空间记忆集 $M_{t-\tau,t-1}^{l-1}$ 和隐藏状态 H_{t-1}^{l} 。当前输入 X_t 和隐藏状态 H_{t-1}^{l} 首先通过上下文融合块提取不同尺度的细 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-1}^{l} 。当前空间记忆单元 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:

$$X_{t} \cdot H_{t-1}^{l} = FM(X_{t}, H_{t-1}^{l})$$

$$i_{t} = \sigma(W_{xi} * \hat{X}_{t} + W_{hi} * \hat{H}_{t-1}^{l} + b_{i})$$

$$g_{t} = \tanh(W_{xg} * \hat{X}_{t} + W_{hg} * \hat{H}_{t-1}^{l} + b_{g})$$

$$f_{t} = \sigma(W_{xf} * \hat{X}_{t} + W_{hf} * \hat{H}_{t-1}^{l} + b_{f})$$

$$C_{t}^{l} = i_{t} \odot g_{t} + f_{t} \odot Att(C_{t-1}^{l}, C_{t-\tau;t-1}^{l}, M_{t-1}^{l-1}, M_{t-\tau;t-1}^{l-1})$$

$$i_{t}^{\prime} = \sigma(W_{xi}^{\prime} * \hat{X}_{t} + W_{mi} * M_{t}^{l-1} + b_{f}^{\prime})$$

$$g_{t}^{\prime} = \tanh(W_{xg}^{\prime} * \hat{X}_{t} + W_{mg} * M_{t}^{l-1} + b_{g}^{\prime})$$

$$f_{t}^{\prime} = \sigma(W_{xf}^{\prime} * \hat{X}_{t} + W_{mf} * M_{t}^{l-1} + b_{g}^{\prime})$$

$$f_{t}^{\prime} = \sigma(W_{xg}^{\prime} * \hat{X}_{t} + W_{mf} * M_{t}^{l-1} + b_{g}^{\prime})$$

$$M_{t}^{l} = i_{t}^{\prime} \odot g_{t}^{\prime} + f_{t}^{\prime} \odot M_{t}^{l-1}$$

$$o_{t} = \sigma(W_{xo} * \hat{X}_{t} + W_{ho} * \hat{H}_{t-1}^{l} + W_{mo} * C_{t}^{l} + W_{mo} * M_{t}^{l} + b_{o})$$

$$H_{t}^{l} = o_{t} \odot \tanh(W_{1\times1} * [C_{t}^{l}, M_{t}^{l}])$$
(7)

式中:"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, o_t 为输出门, C'_t 表示更新的时 间记忆单元, M'_t 表示更新的空间记忆单元,W表示



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 long short-term memory unit of context fusion attention

对应的卷积核,*b* 表示对应的偏差值。"tanh"表示 双曲正切激活函数,*τ* 是历史时间步数。特别地,在 Att 方程中,当 l = 1 时, $M_{t}^{l-1} = X_{t}$, $M_{t-\tau,t-1}^{l-1} = M_{t-\tau,t-1}(\tau=5)$ 。

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} 。

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分别进 行试验,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际业务中的可用



图 4 CAST-LSTM 网络模型结构 Fig. 4 CAST-LSTM network model structure

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,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,卷积核大小设置为 5×5。所有模型均在基 于 Pytorch 框架上进行训练和测试,试验在 NVIDIA A10 GPU 上实现,输入图像的大小受硬件 设备限制(如 GPU 显存),本文试验中占用显存约 21Gb。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。为了稳定训练过程, 在 CAST-LSTM 中的每个卷积层之后使用层归一 化。

3.1 Moving MNIST 试验

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

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 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,保持了随时间变化的清晰 度。相比较之下,ConvLSTM、PredRNN 网络预测 结果很快变得模糊,逐渐丢失细节信息;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 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。

表 1 不同方法在移动 MNIST 数据集 (10 桢→10 桢)中的结果

Table 1 Results of different methods for moving MNIST

datasets (10 frames \rightarrow 10 frames)

方法	MSE/桢↓	SSIM/ 桢 ♦
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
CAST-LSTM	29.7	0.938

3.2 雷达数据集试验

本试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。本文使用数据集为间隔 6 min 的连续雷达资料,即根据过去一小时的观察 结果预测未来一小时的结果。

3.2.1 评估指标

在评估方面,本文使用临界成功指数(CSI)和 HSS(heidke skill score)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* 转换为反射率 dBz,如式(8)所示:

$$\mathrm{dBz} = p \times 95/255 - 10 \tag{8}$$

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。若雷达回波值大于给定阈值,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=0,真值=0)和假阴性预测数 FN (预测=0,真值=1)。

表	2	列联表
Table 2	Co	ntingency table

	预测	预测
真实	TN(真阴性)	FP(假阳性)
真实	FN(假阴性)	TP(真阳性)

CSI和HSS的具体公式如式(9)所示:

$$CSI = \frac{TP}{TP + FN + FP}$$

$2(TP \times TN - FN \times FP)$

 $\overline{(TP+FN)(FN+TN) + (TP+FP)(FP+TN)}$ (9)

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。

3.2.2 结果与分析

表 3 显示了在 2019—2021 年 4—9 月江苏省雷 达数据集不同方法的对比结果。可以看到本文提出 的 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,模型的优势变得越 来越明显。特别是,当阈值为 40 dBz 时,评估的 CSI 和 HSS 指标达到 0.2369 和 0.3075,分别比 PredRNN 算法提高了 30.5%和 31.5%,比 PFST-LSTM 算法高 9.9%和 8.6%。这意味着开发的上

表 3 2019—2021 年 4—9 月江苏省雷达数据集不同方法的 CSI 和 HSS 评分结果 Table 3 Scoring results of CSI and HSS under different methods for dataset of

Jiangsu radar from April to September of 2019-2021								
方法	CSI 🕇				HSS↑			
	10 dBz	20 dBz	40 dBz	平均	10 dBz	20 dBz	40 dBz	平均
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
CAST-LSTM	0.7611	0.5326	0.2369	0.5102	0.7335	0.5735	0.3075	0.5382

下文融合模块和注意力模块有助于提高对强降水区域的预测效果。

为了更好地说明结果,描述了图 6 所示的在 2019—2021 年 4—9 月江苏省雷达数据中检验样本 集不同阈值的 CSI 和 HSS 变化曲线,以显示各种模 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 40 dBz 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,CAST-LSTM 可以更好地保留预测结果的细节性,在强回 波区域的预测结果也表现得更出色。此外,Pred-RNN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 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,由于伪流位置对齐模块的设计,PFST-LSTM 取 得了第二的性能。至于 ConvLSTM 模型,其性能在 试验中表现最差。

为了更好地比较和理解结果,在图 7 中可视化 了 2021 年 5 月 15 日 02:06—03:00 江苏省雷达数 据不同方法下的预测结果。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 强度变得更高,位置也随之变化,且主要回波区域向 图像右侧移动。在 02:18 之前,各个模型之间的预 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,同时预报图像的细节也开始减少。在02:36,尽管每个模型的预测结果中都丢失了一些细节,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,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只关注时间信息而忽略了来自不同单元层之间的空间信息。Pred-RNN在最后时刻尽管保留了部分红色区域,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息丢失问题,因此随时间增加强回波逐步衰减。与上述方法相比,PFST-LSTM和CAST-LSTM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题,且多尺度上下文融合模块可以更好地帮助网络在预测中保持较多的细节性。

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 月雷达数据进行验证。在三个阈值条件下进行外推时长为 1 h 的试验,表 4 显示了使用不同模型的试验结果。



图 6 2019—2021 年 4—9 月江苏省雷达数据集中检验样本集 不同阈值下的(a,c,e)CSI 和(b,d,f)HSS 变化曲线

Fig. 6 Variation curves of (a, c, e) CSI and (b, d, f) HSS at different thresholds for the test sample of dataset of Jiangsu radar from April to September of 2019-2021



其他行为不同模型下的预测结果。

图 7 2021 年 5 月 15 日 02:06—03:00 江苏省雷达数据集不同方法下的预测结果

Fig. 7 Prediction results under different methods for dataset of Jiangsu radar from 02:06 BT to 03:00 BT 15 May 2021

表 4	2022年4	—9月江苏省雷达数据集在不同方法下外推 60分钟的 CSI和 HSS 评分结果
	Table 4	Scoring results of CSI and HSS under different methods for dataset of

Jiangsu radar from April to September 2022

方法	CSI 🕇				HSS∱			
	10 dBz	20 dBz	40 dBz	平均	10 dBz	20 dBz	40 dBz	平均
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
CAST-LSTM	0.7634	0.5278	0.2331	0.5081	0.7357	0.5624	0.3037	0.5339

除了本文提出的 CAST-LSTM 模型之外,还采 用了 ConvLSTM、PredRNN、PredRNN++、MIM、 E3D-LSTM 和 PFST-LSTM 先进模型进行对比。 可以看到 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 势变得越来越明显。特别是,当阈值为40 dBz 时, 评估的 CSI 和 HSS 指标达到 0.2331 和 0.3037,分 别比 PredRNN 算法提高了 29.3%和 30.6%,比 PFST-LSTM 算法高 8.7% 和 8.2%。这意味着提出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。

为了更直观地观察外推中数据变化过程,对 2022年4—9月江苏省雷达数据在不同阈值条件下 CAST-LSTM模型与 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,结果如图 8 所示。从图中可以看出本模型整体







上优于其他模型,尤其是对强回波的预测能力,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 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衰减问题。

为了更好地展示试验结果,在图 9 中可视化了 2022 年 7 月 28 日 07:36—08:30 江苏雷达数据不 同方法下的预测结果。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: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 07:48,各个模型之间的 预测结果差异较小,且非常接近实况。在 07:48 以 后,ConvLSTM 的预测结果中强回波区域开始衰 退。在 08:12,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 可以更好地预 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。



注:第一行为预测时输入的 2022 年 7 月 28 日 06:36—07:30 的雷达图像,第二行为 07:36—08:30 实际观测图像; 其他行为不同模型下的预测结果。

图 9 2022 年 7 月 28 日 07:36—08:30 江苏省雷达数据集不同方法下的预测结果 Fig. 9 Prediction results under different methods for dataset of Jiangsu radar from 07:36 BT to 08:30 BT 28 July 2022

4 结 论

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。

(1) 在 Moving MNIST 数据集中, CAST-LSTM 算法的 MSE 为最低、SSIM 最高, 与几种现 有算法相比,性能得到明显提升; 在可视化实例中, CAST-LSTM 算法具有更好的预测结果, 很好地保 留了数字的移动轨迹和变化细节。

(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,在强回波区域的预测结果也表现得更出色。

(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 且强度持续增加的地区。

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,探索更有效的算法进一步提 高降水短时临近预报的预测能力。

参考文献

陈鹤,蔡荣辉,陈静静,等,2022. 基于深度学习方法的气温预报技术 应用与评估[J]. 气象,48(11):1373-1383. Chen H, Cai R H, Chen J J, et al. 2022. Application and evaluation of temperature forecast based on deep learning method[J]. Meteor Mon, 48 (11):1373-1383(in Chinese).

- 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, Meng W G,et al,2021. A correction method of hourly precipitation forecast based on convolutional neural network[J]. Meteor Mon,47(1):60-70(in Chinese).
- 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, Zhou G B, Liu B J, et al, 2020. Study on artificial intelligence technology and its application to Chongqing operational nowcasting[J]. Meteor Mon,46(10):1286-1296(in Chinese).
- 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 X, Han L, et al, 2019. High resolution nowcasting experiment of severe convections based on deep learning[J]. Acta Meteor Sin, 77(4):715-727(in Chinese).
- 黄骄文,蔡荣辉,姚蓉,等,2021. 深度学习网络在降水相态判识和预 报中的应用[J]. 气象,47(3):317-326. Huang J W, Cai R H, Yao R, et al, 2021. Application of deep learning method to discrimination and forecasting of precipitation type[J]. Meteor Mon,47(3):317-326(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[J]. 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[J]. Acta Meteor Sin,79(5):817-827(in Chinese).
- 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. Yin Q M,Gan J H,Qi H,et al,2021. An improved algorithm of radar image extrapolation based on recurrent neural network[J]. Meteor Sci Technol, 49(1):18-24,45(in Chinese).
- 袁凯,李武阶,李明,等,2022.四种机器深度学习算法对武汉地区雷 达回波临近预报的检验和评估[J]. 气象,48(4):428-441. Yuan K,Li W J,Li M,et al,2022. Examination and evaluation of four machine deep learning algorithms for radar echo nowcasting in Wuhan Region[J]. Meteor Mon,48(4):428-441(in Chinese).
- 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, et al,2021. Advances in application of machine learning to severe convective weather monitoring and forecasting[J]. Meteor Mon,47(3):274-289(in Chinese).
- Ayzel G, Heistermann M, Winterrath T, 2019. Optical flow models as an open benchmark for radar-based precipitation nowcasting (rainymotion v0. 1)[J]. Geosci Model Dev, 12(4):1387-1402.
- Bei X Z, Yang Y C, Soatto S, 2021. Learning semantic-aware dynamics for video prediction [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville:IEEE:902-912.
- 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 Information Processing Systems. NeurIPS: 26950-26962.

- Chung K S, Yao I A, 2020. Improving radar echo Lagrangian extrapolation nowcasting by blending numerical model wind information: statistical performance of 16 typhoon cases[J]. Mon Wea Rev, 148(3):1099-1120.
- Geng L C, Geng H T, Min J Z, et al, 2022. AF-SRNet: quantitative precipitation forecasting model based on attention fusion mechanism and residual spatiotemporal feature extraction[J]. Remote Sens,14(20):5106.
- Lakshmanan V, Hondl K, Rabin R, 2009. An efficient, general-purpose technique for identifying storm cells in geospatial images [J]. J Atmos Oceanic Technol, 26(3):523-537.
- Luo C Y, Li X T, Ye Y M, 2021. PFST-LSTM: a SpatioTemporal LSTM model with pseudo-flow prediction for precipitation nowcasting[J]. IEEE J Sel Top Appl Earth Obs Remote Sens, 14: 843-857.
- Marshall J S, Palmer W M K, 1948. The distribution of raindrops with size[J]. J Meteor, 5(4):165-166.
- Rinehart R E, Garvey E T, 1978. Three-dimensional storm motion detection by conventional weather radar[J]. 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 [C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal: MIT Press: 802-810.
- Singh S, Sarkar S, Mitra P, 2017. A deep learning based approach with adversarial regularization for Doppler weather radar ECHO prediction[C] // 2017 IEEE International Geoscience and Remote Sensing Symposium(IGARSS). Fort Worth: IEEE: 5205-5208.
- Tamaru R, Siritanawan P, Kotani K, 2021. Interaction aware relational representations for video prediction [C] // 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Melbourne: IEEE: 2089-2094.
- Tian C Y, Chan W K, 2021. Spatial-temporal attention wavenet: a deep learning framework for traffic prediction considering spatial-temporal dependencies[J]. IET Intell Trans Syst, 15(4): 549-561.
- 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 learning [C] // 35th International Conference on Machine Learning. Stockholmsmassan;PMLR;5110-5119.
- 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 on Learning Representations. New Orleans: Open-Review. net.
- Wang Y B, Long M S, Wang J M, et al, 2017. PredRNN; recurrent neural networks for predictive learning using spatiotemporal LSTMs[C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach; Curran

Associates Inc. :879-888.

- 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 from spatiotemporal dynamics [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach; IEEE:9146-9154.
- Woo W C, Wong W K, 2017. Operational application of optical flow techniques to radar-based rainfall nowcasting[J]. Atmosphere, 8(3):48.
- Yang Z Y, Liu Q, Wu H, et al, 2023. CEMA-LSTM: enhancing contextual feature correlation for radar extrapolation using fine-grained echo

datasets[J]. Comput Model Eng Sci,135(1):45-64.

- 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 Trans Syst, 23(6):4927-4943.
- Zhao J L, Liu Z B, Sun Q X, et al, 2022. Attention-based dynamic spatial-temporal graph convolutional networks for traffic speed forecasting[J]. Expert Syst Appl,204:117511.
- 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 Technol, 36(9):1713-1727.

(本文责编:俞卫平)