

DOI:10.19651/j.cnki.emt.2417301

基于增强 PredRNN 的雷达回波外推方法*

谢梦¹ 刘丽丽¹ 杨春蕾¹ 王艳¹ 顾明剑^{1,2}

(1. 中科学技术物理苏州研究院 苏州 215000; 2. 云遥动力科技(苏州)有限公司 苏州 215000)

摘要: 针对样本失衡和预报准确率低的问题,提出一种增强预测循环神经网络 EN_PredRNN。首先,对雷达数据进行预处理并筛选样本以构建高质量的雷达回波数据集;然后,通过深度融合时空长短时记忆单元与动态卷积,设计动态卷积时空长短时记忆模块 DC_STLSTM,实时调整卷积参数以精准捕捉雷达回波的瞬时变化特征。然后,通过堆叠 5 层 DC_STLSTM,提取雷达回波的更深层次特征,并使用梯度高速公路缓解梯度消失,提高预报精度。实验结果表明,相比于 PredRNN,EN_PredRNN 在 25、35、45、65 dBZ 阈值下的临界成功指数分别提升了 19.3%、17.3%、16.5%、14.0%,虚警率分别下降了 28.3%、27.5%、26.7%、24.9%,有效学习了雷达数据的时空变化特征,准确预测雷达回波强度和位置。

关键词: 雷达回波外推;循环神经网络;动态卷积;梯度高速公路

中图分类号: TN95;TN959.4 **文献标识码:** A **国家标准学科分类代码:** 520.2040

Radar echo extrapolation method based on enhanced PredRNN

Xie Meng¹ Liu Lili¹ Yang Chunlei¹ Wang Yan¹ Gu Mingjian^{1,2}

(1. Suzhou Institute of Science and Technology Physics, Suzhou 215000, China; 2. Yunyao Power Technology (Suzhou) Co., Ltd., Suzhou 215000, China)

Abstract: In response to the problems of imbalanced samples and low prediction accuracy, an enhanced predictive recurrent neural network EN_PredRNN is proposed. Firstly, the radar data is preprocessed and samples are selected to construct a high-quality radar echo dataset; then, deep fusion of spatiotemporal long short-term memory units and dynamic convolution is used to design a dynamic convolution combined with spatio-temporal long short-term memory module DC_STLSTM, which adjusts convolution parameters in real-time to accurately capture the instantaneous changes in radar echoes. Then, stack 5 layers of DC_STLSTM to extract deeper features of radar echoes, and use gradient highways to alleviate gradient vanishing, improving the model's generalization ability and prediction accuracy. The experimental results showed that EN_PredRNN performed the best, significantly improving the critical success index and reducing false alarm rates. Compared with PredRNN, it increased the critical success index by 19.3%, 17.3%, 16.5% and 14.0% at 25, 35, 45 and 65 dBZ, respectively, while reducing false alarm rates by 28.3%, 27.5%, 26.7% and 24.9%, effectively. This model effectively learned the spatiotemporal variation characteristics of radar data and accurately predicted the radar echo intensity and location.

Keywords: radar echo extrapolation; recurrent neural network; dynamic convolution; gradient highway unit

0 引言

近年来,全球气候变化导致灾害性天气频发。因此,如何实现更精确和更长预警提前降水临近预报成为了全球的关注点。降水临近预报是指对未来 0~2 h 内降雨量或强对流天气进行预报。由于天气雷达探测资料具有较高的时间和空间分辨率,因此,气象业务中主要使用雷达回波外

推方法实现降水临近预报。传统的雷达回波外推方法主要包括交叉相关法、单体质心法和光流法。传统雷达外推方法往往依赖于简单的物理模型或统计模型,难以准确描述降水系统的复杂性和非线性动态变化,显著降低了降水预测的精度。

近年来,深度学习为代表的人工智能技术在图像识别和视频领域取得了突破性进展^[1-3],并在大气科学领域得到

收稿日期:2024-11-07

* 基金项目:苏州市科技项目(SYG202135)、苏州市社会发展项目(2023ss17)资助

广泛应用^[4-7]。针对上述传统方法存在的问题,将神经网络引入以雷达回波外推,神经网络模型凭借着挖掘海量数据和非线性建模的优秀能力,能充分学习海量雷达回波数据中潜在的天气演变规律,并已在准确率上超越了传统方法,且在短时临近预报业务中取得良好的成果^[8-9]。

虽然长、短时记忆单元(long short-term memory, LSTM)在时序数据处理上表现出色,但无法直接提取空间特征信息。为克服这一局限,文献[10]开创性地提出了卷积长短期记忆单元网络(convolutional LSTM, ConvLSTM),通过将卷积结构整合到 LSTM 中,实现了时空特征的融合,显著提升了雷达回波预测的准确率,相较于光流法展现出明显优势。文献[11]提出预测循环神经网络(predictive recurrent neural network, PredRNN),通过结合空间卷积层与 LSTM,增强了同时捕获时间动态和空间相关性的能力,有效提高了降水临近预报的准确率,但存在梯度消失问题,限制了预测精度的进一步提升。为此,文献[12]又提出 PredRNN+ 算法,基于 PredRNN 架构引入具有级联双记忆结构的 LSTM 和梯度高速公路单元(gradient highway unit, GHU),提高模型对短期空间动态的建模能力及解决梯度消失问题。

由于雷达回波图像具有旋转、放缩及生消等动态特性,模型在处理复杂动态特性时存在局限性,从而导致在长时间预测中误差的累积和细节的丢失。针对该局限性,近年来的研究者提出了多种改进方法。文献[13]提出 MotionRNN 模型,使用 MotionGRU 单元用于统一建模整体运动趋势与瞬时变化, Motion Highway 用于平衡移动与非移动部分,提高了模型对复杂时空运动的适应能力,更好地学习雷达回波运动过程中的“生消动变”。文献[9]提出 SwinAt-UNet 模型,能自适应地学习雷达回波资料中的短期和长期动态变化信息,通过引入深度可分离卷积和卷积块注意力模块提高预报准确率;文献[14]为解决固定核大小的局限性限制了模型无法进行局部特征提取,提出一种增强 ConvLSTM2D 架构,通过利用混合内核大小使模型能够有效地捕获详细信息和更广泛的空间关系,提高了模型的预测能力和计算效率。

此外,雷达回波外推方法在降水预测过程中面临样本不平衡的难题。强降水事件在整体样本中占比相对较低,导致模型难以充分学习到强降水相关的关键特征,从而影响降水预测精度。文献[15]用 Causal-LSTM 单元组成的神经网络模型,使用权重损失函数实现雷达回波的外推,有效消除降水的不平衡性和提高强回波预报的准确度。

虽然上述循环神经模型在降水预测方面表现尚优,但是随着外推时间延长,易出现误差累积和细节丢失现象,导致预测信息的准确性和清晰度逐渐降低,进而限制了预警提前提升。同时,还普遍存在虚警率偏高,直接削弱了降水预测的精准度。此外,循环神经模型通常具有较高的计算复杂度,在处理雷达回波数据时,需要消耗大量的计算资

源和时间,限制了实时应用的可能性。

因此,本文针对样本失衡、预测精度低等问题,提出一种增强预测循环神经网络(enhanced predictive recurrent neural network, EN_PredRNN),旨在提升雷达回波预测的精度。该网络一方面改进了普通卷积局部不变性参数结构在应对局部变化的雷达图像时的局限性,构建了动态卷积时空长短期记忆模块,实现对雷达图像中局部特征的复杂天气动态变化特征的捕捉。另一方面堆叠 5 层动态卷积时空长短期记忆模块,提取雷达数据的更深层次特征,并使用梯度高速公路缓解梯度消失,从而提高训练效率和预报精度。

1 方法介绍

1.1 研究基础

PredRNN^[11]是一种针对时空序列预测任务的循环神经网络模型,旨在通过长短期记忆单元(spatio-temporal long short-term memory, ST_LSTM)提取记忆时空表象,如图 1 所示。PredRNN 的核心创新是锯齿形记忆流,这种记忆流在所有层中自下而上和自上而下的方向传播,使得 RNN 的不同层学习到的动态视觉信息能够相互通信。ST_LSTM^[11]在 LSTM 的基础上进行改进,以同时捕捉数据中的空间和时间依赖关系。通过引入额外的门控机制,以便更有效地处理时空信息。因此,ST_LSTM 能更好地处理具有时空特征的数据如气象数据、雷达数据等,使得模型能够更准确地学习和预测具有复杂时空动态的数据。

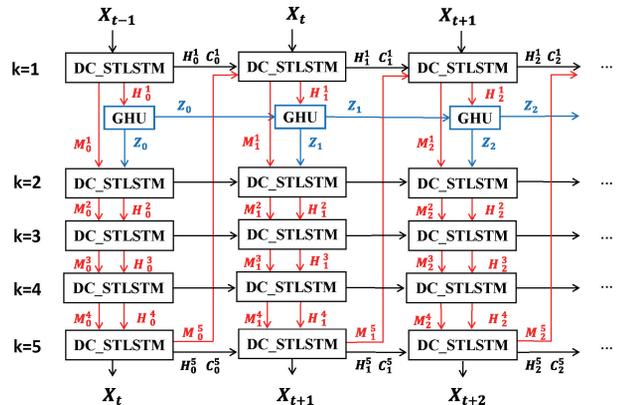


图 1 EN_PredRNN 模型结构

Fig. 1 EN-PredRNN model structure

1.2 EN_PredRNN

EN_PredRNN 模型结构如图 1 所示,由 5 层动态卷积时空长短期记忆模块(dynamic convolution combined with spatio-temporal long short-term memory, DC_STLSTM)模块堆叠而成,并在模型第 1 层和第 2 层之间引入梯度高速公路单元。其主要创新点:1)基于 PredRNN 的关键架构,通过深度融合 ST_LSTM 与动态卷积,搭建 DC_STLSTM 模块,能实时调整卷积参数以精准捕捉雷达回波的瞬时变

化特征,显著增强模型对复杂动态特征的捕捉能力;2)通过深化网络结构,扩大模型感受野,提取雷达回波的更高层次特征,以增强降水预测精度与细节捕捉;3)为缓解梯度消失,引入梯度高速公路单元于模型前两层,促进雷达回波深层特征的学习,从而提升短临降水预报的精准度和可靠性。

1) DC_STLSTM 模块

DC_STLSTM 模块如图 2 所示,该模块有 4 个输入:当前输入 X_t 、隐藏状态 H_{t-1}^1 、细胞状态 C_{t-1}^1 和时空记忆流 M_{t-1}^1 ,输出包括隐藏状态 H_t^1 、细胞状态 C_t^1 、时空记忆流 M_t^1 。由于雷达回波图像展现出复杂多变的特性如旋转、放缩及生消,普通卷积中卷积核邻域与被卷积目标位置对应关系是固定的,难以灵活应对雷达回波图像局部特征的动态变化。因此,该模块使用动态卷积(dynamic convolution)动态调整卷积核参数,更好提取雷达回波的瞬时变化。最后将来自不同方向的记忆连接在一起,然后使用一个 1×1 的卷积层进行降维,使隐藏状态 H_t^1 与记忆单元的维度相同。DC_STLSTM 通过深度融合时空长短记忆单元与动态卷积的自适应特性,能有效处理雷达回波时间序列。

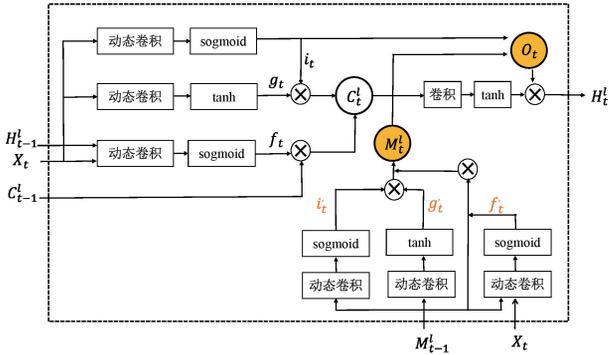


图 2 DC_STLSTM

Fig. 2 DC_STLSTM

DC_STLSTM 模块的具体数学表达为:

$$g_t = \tanh(W_{xg} * X_t + W_{hg} * H_{t-1}^1 + b_g) \quad (1)$$

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1}^1 + b_i) \quad (2)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1}^1 + b_f) \quad (3)$$

$$C_t^1 = f_t \odot C_{t-1}^1 + i_t \odot g_t \quad (4)$$

$$g'_t = \tanh(W'_{xg} * X_t + W'_{hg} * M_{t-1}^1 + b'_g) \quad (5)$$

$$i'_t = \sigma(W'_{xi} * X_t + W'_{hi} * M_{t-1}^1 + b'_i) \quad (6)$$

$$f'_t = \sigma(W'_{xf} * X_t + W'_{hf} * M_{t-1}^1 + b'_f) \quad (7)$$

$$M_t^1 = f'_t \odot M_{t-1}^1 + i'_t \odot g'_t \quad (8)$$

$$O_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1}^1 + W_{co} * C_t^1 + W_{mo} * M_t^1 + b_o) \quad (9)$$

$$H_t^1 = O_t \odot \tanh(W_{1 \times 1} * [C_t^1, M_t^1]) \quad (10)$$

其中, σ 是 sigmoid 函数, \tanh 是双曲正切激活函数。* 表示动态卷积操作, \odot 表示点积操作。 X_t 是 t 时刻的输入, H_{t-1}^1 是 $t-1$ 时刻的隐藏状态, C_{t-1}^1 是 $t-1$ 时

刻的细胞状态, M_{t-1}^1 是 $t-1$ 时刻的时空记忆流。 g_t 、 i_t 、 f_t 和 O_t 分别表示输入门、遗忘门、输出门。

2) 深度网络融合梯度高速公路

浅层网络局限于低层次特征,通常更深的网络结构具有更强的学习能力和表达能力,更合适处理更复杂的数据和任务。因此,EN_PredRNN 模型中堆叠 5 层 DC_STLSTM,构建深层次的网络架构,旨在通过增加从输入到输出的循环状态的数量,显著提升模型在学习短期动态方面的能力。然而,深层网络易受梯度消失困扰,模型难以有效学习复杂特征。因此,在模型第 1 层和第 2 层之间引入梯度高速公路单元。

GHU 如图 3 所示,其为梯度在反向传播过程中提供了一条“高速公路”,使得梯度能够更快速、更稳定地传播到网络的前端。这不仅有助于减少梯度在深层网络中的衰减,还显著提升训练效率,使模型能够更高效地收敛至最优解^[12]。GHU 的引入促进了雷达回波深层特征的学习,使得模型在捕捉雷达回波长期与短期特征方面展现出更高的自适应性。因此,GHU 在增强模型性能的同时,还提升训练的稳定性与可靠性,降低过拟合的风险。

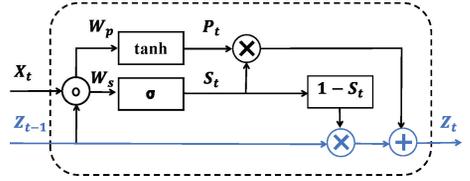


图 3 梯度高速公路单元^[12]

Fig. 3 Gradient highway unit^[12]

GHU 的数字表达如下:

$$P_t = \tanh(W_{px} * \chi_t + W_{pz} * Z_{t-1}) \quad (11)$$

$$S_t = \sigma(W_{sx} * \chi_t + W_{sz} * Z_{t-1}) \quad (12)$$

$$Z_t = S_t \odot P_t + (1 - S_t) \odot Z_{t-1} \quad (13)$$

其中, S_t 是开关门,它能够在转换后的输入 P_t 和隐藏状态 Z_{t-1} 之间进行自适应学习。 P_t 是输入, Z_t 是 t 时刻的隐藏状态, Z_{t-1} 是 $t-1$ 时刻的隐藏状态, * 是卷积操作, \odot 是点积操作, χ_t 是当前时间步的输入, W_{px} 、 W_{sx} 、 W_{sz} 均是权重, \tanh 是双曲正切激活函数, σ 是 sigmoid 激活函数。

上述的公式可以简化为:

$$Z_t = \text{GHU}(\chi_t, Z_{t-1}) \quad (14)$$

其中, t 表示时间, χ_t 是 t 时间的输入, Z_t 是 t 时刻的隐藏状态, Z_{t-1} 是 $t-1$ 时刻的隐藏状态, GHU 是梯度高速公路单元。

EN_PredRNN 的数学表达为:

$$H_t^1, C_t^1, M_t^1 = \text{C_STLSTM}_{k=1}(X_t, H_{t-1}^1, C_{t-1}^1, M_{t-1}^1) \quad (15)$$

$$Z_t = \text{GHU}(H_t^1, Z_{t-1}) \quad (16)$$

$$H_t^2, C_t^2, M_t^2 = \text{DC_STLSTM}_{k=2}(Z_t, H_{t-1}^1, C_{t-1}^1, M_{t-1}^1) \quad (17)$$

$$H_t^3, C_t^3, M_t^3 = DC_STLSTM_{k=3}(H_t^2, H_{t-1}^3, C_{t-1}^3, M_t^2) \quad (18)$$

$$H_t^4, C_t^4, M_t^4 = DC_STLSTM_{k=4}(H_t^3, H_{t-1}^4, C_{t-1}^4, M_t^3) \quad (19)$$

$$H_t^5, C_t^5, M_t^5 = DC_STLSTM_{k=5}(H_t^4, H_{t-1}^5, C_{t-1}^5, M_t^4) \quad (20)$$

其中, t 表示时间, GHU 表示梯度高速公路单元, Z_t 表示 t 时刻的隐藏状态, Z_{t-1} 表示 $t-1$ 时刻的隐藏状态, X_t 是 t 时间步的输入。 H_t^1, C_t^1, M_t^1 分别表示第 1 层的 t 时刻的隐藏状态、细胞状态、时空记忆流, 其他依次类推; H_{t-1}^1, C_{t-1}^1 分别表示第 1 层的 $t-1$ 时刻的隐藏状态、细胞状态; M_{t-1}^5 表示第 5 层的 $t-1$ 时刻时空记忆流, 其他依次类推; $DC_STLSTM_{k=1}$ 表示第 1 层动态卷积时空长短时记忆模块, 其中, k 表示模型的层数, 其他依次类推。

2 实验结果与分析

2.1 数据准备

1) 数据预处理

选取安徽省的雷达数据, 时间范围从 2016 年 5 月~2016 年 9 月。首先, 遍历整个雷达回波数据, 将所有缺省值以及基本反射率小于或等于 0 dBZ 的数值, 统一替换为 0。同时, 对于所有大于 70 dBZ 的数值, 将它们设置为 70 dBZ, 以确保数据值严格限定在 0~70 dBZ。然后, 对经过预处理的数据进行归一化处理。通过将每个数据点除以 70, 从而将原始数据映射到 0~1 的区间内, 这有利于提升模型的收敛速度。最后, 使用双三次插值将雷达回波图像大小统一缩放为 256×256 。

2) 高质量雷达数据集制作

利用滑窗法在雷达回波图像序列上进行分割, 窗口长度为 20, 步长为 1。即每 20 个连续的雷达图像是 1 个样本, 前 10 个雷达图像为模型的输入, 后 10 个雷达图像为标签, 样本间没有时间重叠, 共有 1 836 个样本。为确保数据集间的独立性, 将数据集划分为训练集、验证集和测试集。其中, 5~8 月的样本为训练集, 用于训练雷达外推模型。9 月上旬样本为验证集, 用于模型调优。9 月下旬的样本为测试集, 用于评估最终性能。

为减少无雨天气对模型训练的影响, 在数据集制作过程中使用雷达回波覆盖率筛选策略进行样本筛选, 得到高质量的数据集。由于降水回波的反射率一般在 15 dBZ 以上, 所以在连续 20 帧图像中的前 10 帧至少有 1 帧的雷达有效探测范围内回波面覆盖率(基本反射率 > 15 dBZ)的面积大于 10%。这有效地减少数据集中的噪声和不平衡性, 使模型训练中更加聚焦于学习强降水相关的关键信息, 进而提高模型对强降水事件的预测能力。经过样本筛选后, 训练集、验证集和测试集分别有 551、103 和 91 个样本。

2.2 实验参数

本实验基于 Pytorch 深度框架, 学习率为 0.000 1, 优化

器为 Adam, batch size 为 4, 迭代次数为 6 000 次。损失函数使用 L1 + L2 损失。由实验知, 当堆叠 5 层 DC_STLSTM 的时候, 模型效果最优。

2.3 评价指标

为了全面评估模型在不同降水强度下的综合表现, 选取了 3 个不同降水强度对应的基本反射率作为阈值, 分别为 25、35、45 和 65 dBZ。预报时长为 1 h, 每个预报时间步长为 6 min, 采用临界成功指数(critical success index, CSI)、命中率(probability of detection, POD)、虚警率(false alarm rate, FAR)和均方根误差(root mean squared error, RMSE)指标对雷达回波外推结果进行定量化评价, 具体的计算公式为:

$$CSI = \frac{hits}{hits + misses + false\ alarms} \quad (21)$$

$$POD = \frac{hits}{hits + misses} \quad (22)$$

$$FAR = \frac{false\ alarms}{hits + false\ alarms} \quad (23)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (pred(i) - obs(i))^2}{N}} \quad (24)$$

其中, CSI 为临界成功指数; POD 为命中率; FAR 为空报率; $hits$ 表示命中点(预测值=1、真实观测值=1); $misses$ 表示漏报点(预测值=0、真实观测值=1); $false\ alarms$ 表示空报点(预测值=1、真实观测值=0)。RMSE 为均方根误差, obs 是真实的雷达回波图像, $pred$ 是预测的雷达回波图像。均方根差值越小, 预测的效果越好; 命中率和临界成功指数越高表示雷达回波预测的越精准; 虚警率越低表示模型越精准。

2.4 测试集检验

1) 不同降水强度下的综合表现

本实验是根据过去 1 h 的历史雷达回波数据预测未来 1 h 的雷达回波结果。为了全面评估 En_PredRNN、PredRNN、MotionRNN 模型在不同降水强度下的综合表现, 在 0~1 h 外推时长下选择基本反射率 25、35、45 和 65 dBZ 作为阈值, 并采用临界成功指数、虚警率、命中率和均方根误差对雷达回波测试集进行定量化评价。所有模型均在相同的数据集和环境下进行训练、验证和测试。

表 1 中每一行记录了各个模型在不同评价指标下的平均值, 并加粗显示最优效果。↑代表该指标数值越高, 模型性能越好, ↓代表该指标数值越小, 模型性能越好。由表 1 可知, 在相同预报时效的情况下, En_PredRNN 模型在 4 个反射率阈值的临界成功指数和虚警率均为最优。在 25、35、45 和 65 dBz 的阈值下, 对比 PredRNN, En_PredRNN 模型的临界成功指数分别提升了 19.3%、17.3%、16.5% 和 14.0%, 虚警率分别下降了 28.3%、27.5%、26.7% 和 24.9%, 均方根误差分别下降了 18.3%、17.1%、16.8% 和

15.9%。En_PredRNN 模型比 MotionRNN 在临界成功指数上分别高出 3.6%、4.2%、3.2%和 2.9%，虚警率分别降低了 8.3%、8.5%、8.1%和 7.6%，均方根误差分别下降了 3.5%、3.7%、3.4%和 3.4%。测试集在 0~1 h 内各个评

价指标的平均值如图 4 所示,其中图 4(a)、(b)、(c)分别是不同阈值下的临界成功指数、虚警率、命中率,可发现 En_PredRNN 模型显著提升了临界成功指数,降低了虚警率,有效提升降水预报的准确率。

表 1 各个模型在不同基本反射率阈值下的评价结果

Table 1 Evaluation results of various models at different basic reflectance thresholds

基本反射率/dBZ	模型	CSI ↑	POD ↑	FAR ↓	RMSE ↓
25	PredRNN	0.482	0.892	0.488	0.489
	MotionRNN	0.639	0.859	0.288	0.341
	En_PredRNN	0.675	0.815	0.205	0.306
35	PredRNN	0.447	0.857	0.517	0.502
	MotionRNN	0.578	0.805	0.327	0.368
	En_PredRNN	0.620	0.770	0.242	0.331
45	PredRNN	0.408	0.812	0.547	0.518
	MotionRNN	0.541	0.780	0.361	0.384
	En_PredRNN	0.573	0.737	0.280	0.350
65	PredRNN	0.343	0.733	0.606	0.536
	MotionRNN	0.454	0.701	0.433	0.411
	En_PredRNN	0.483	0.662	0.357	0.377

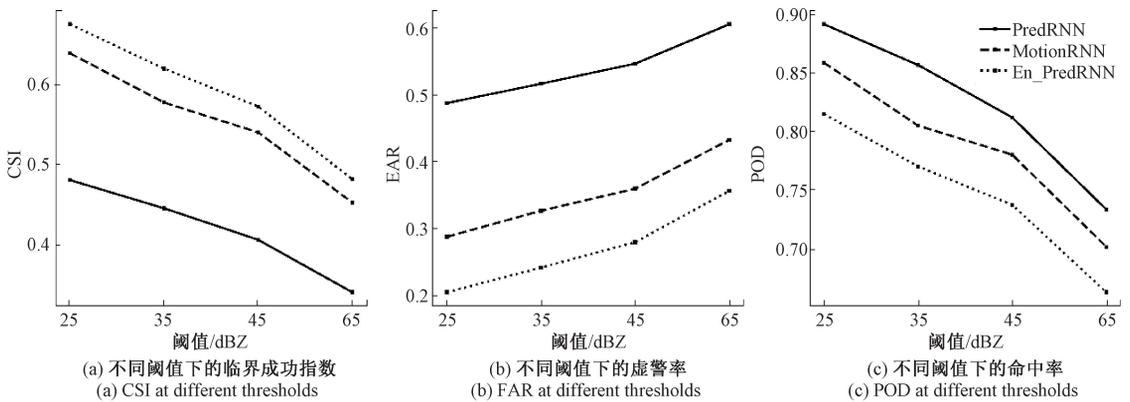


图 4 测试集在 0~1 h 内各个评价指标的平均值

Fig. 4 The average value of each evaluation index in the test set within 0~1 h

各个模型在 0~1 h 内的雷达回波外推结果如图 5 所示,可看出各个模型在第一个时刻都进行了准确的预测。但随着时间的推移,模型之间出现明显的差异。PredRNN 从第 3 帧开始倾向于夸大降水的预测范围和强度,出现明显的误报情况,且无法正确估计中高回波内部的强度分布。MotionRNN 从第 3 帧开始低估降水的强度,对中高回波强度的预测误差很大。En_PredRNN 模型的雷达回波强度和位置与对应的雷达观测实况较为一致,并能准确预测出中高回波的强度和移动趋势。En_PredRNN 模型显著增强了雷达回波的特征提取能力,有效地捕捉雷达数据中的长期依赖关系和重要信息,学习到强对

流演变的时间和空间特征,从而准确预测出雷达回波的强度和移动位置。

2) 预报时效表现

为更直观地观察各模型的预报时效表现,绘制各个模型在 25、35、45 和 65 dBz 基本反射率阈值下 0~1 h 内临界成功指数的情况,时间间隔 6 min,如图 6(a)~(d)所示,可看出随预报时效的延长,所有模型的临界成功指数均呈下降趋势,预报能力逐渐减弱。但相比其他模型,En_PredRNN 在 4 个基本反射率阈值下的临界成功指数最高,性能最优。这一结果表明 En_PredRNN 有效提高了降水预测的准确性。

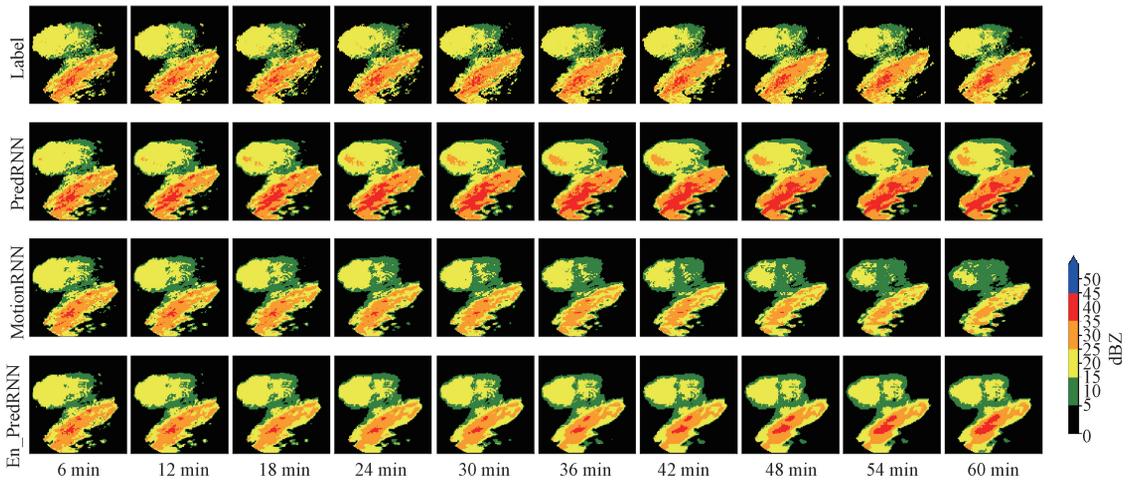


图 5 各模型 0~1 h(时间步长 6 min)的雷达回波外推结果

Fig. 5 Extrapolation results of radar echoes for each model within 0~1 h (with a time step of 6 min)

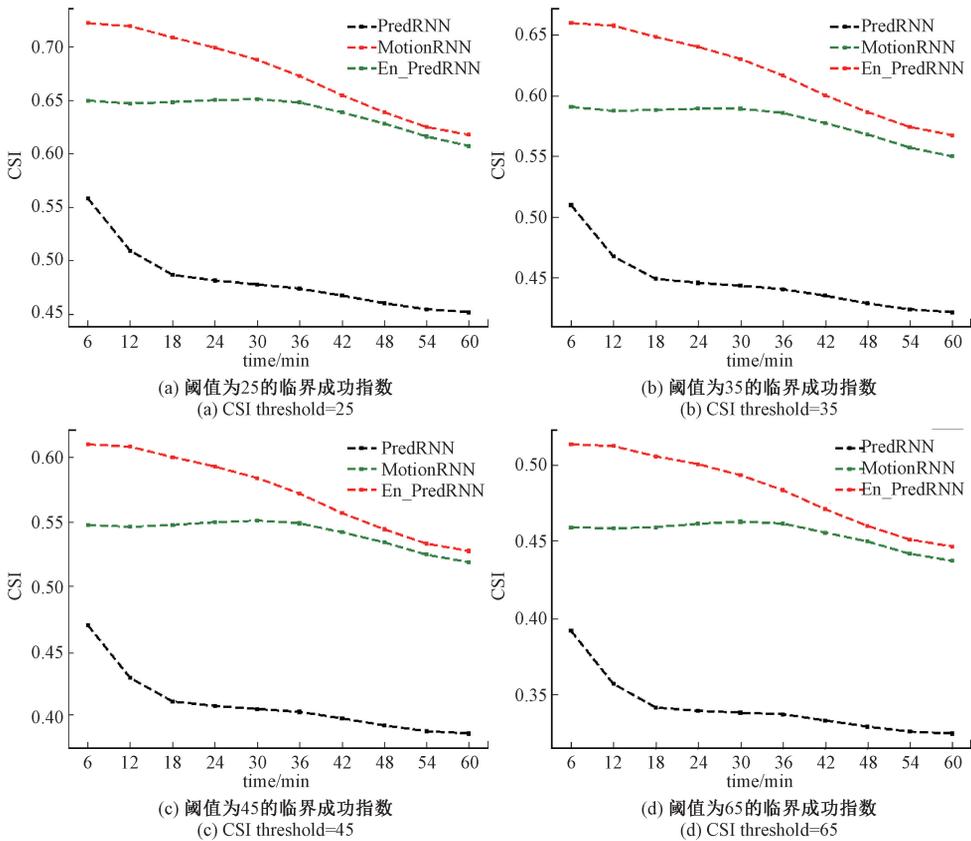


图 6 不同基本反射率阈值下各个模型的临界成功指数变化情况

Fig. 6 Changes in critical success index of various models under different basic reflectance thresholds

3) 消融实验

为了验证 En_PredRNN 模型各项改进的有效性,在相同实验条件下进行 3 组消融实验,消融实验结果如表 2 所示。表 2 中可看出,动态卷积操作和 GHU 对预测结果均有很大的提升。第 1 组实验是基准模型 PredRNN;第 2 组

是在第 1 组的基础上加入 DC_STLSTM 模块,在基本反射率为 25、35、45 和 65 dBZ 时 CSI 分别提升了 14%、11.9%、11.9%和 10.0%,FAR 分别降低了 18.2%、17.4%、16.9%和 15.7%,RMSE 分别降低了 13.5%、12.4%、12.4%和 11.7%;因此,动态卷积操作优于普通卷积操作。第 3 组实

验是在第 2 组的基础上加入 GHU,在基本反射率为 25、35、45 和 65 dBZ 时,比第 2 组实验的 CSI 分别提高了 5.3%、5.4%、4.6% 和 4.0%, FAR 分别降低了 10.1%、10.1%、

9.8% 和 9.2%, RMSE 分别降低了 4.8%、4.7%、4.4% 和 4.2%。因此,DC-STLSTM 模块和 GHU 的加入显著降低了虚警率和均方根误差,提高了临界成功指数。

表 2 消融实验

Table 2 Ablation experiment

基本反射率/dBZ	实验组	模型	CSI ↑	POD ↑	FAR ↓	RMSE ↓
25	G1	PredRNN	0.482	0.892	0.488	0.489
	G2	+DC-STLSTM	0.622	0.854	0.306	0.354
	G3	+GHU	0.675	0.815	0.205	0.306
35	G1	PredRNN	0.447	0.857	0.517	0.502
	G2	+DC-STLSTM	0.566	0.803	0.343	0.378
	G3	+GHU	0.620	0.770	0.242	0.331
45	G1	PredRNN	0.408	0.812	0.547	0.518
	G2	+DC-STLSTM	0.527	0.775	0.378	0.394
	G3	+GHU	0.573	0.737	0.280	0.350
65	G1	PredRNN	0.343	0.733	0.606	0.536
	G2	+DC-STLSTM	0.443	0.696	0.449	0.419
	G3	+GHU	0.483	0.662	0.357	0.377

3 结 论

本文提出一种增强预测循环神经网络 EN_PredRNN,解决了样本不平衡、虚警率过高和预报精度低的问题。实验结果表明,在相同预报时效的情况下,相比于经典模型 PredRNN、MotionRNN,En_PredRNN 模型在 4 个基本反射率阈值的临界成功指数、虚警率和均方根误差均为最优。因此,该模型能有效提高雷达数据的利用率,减少信息损失,并增强雷达回波的细节捕捉能力,显著降低了虚警率和提升短临降水预报的准确率,能更加精准地预测出真正的强对流天气事件,避免因错误预警而触发的非必要应急响应和资源浪费,为应对极端天气提供了更为可靠和高效的决策支持。

参考文献

- [1] 李天放,孙一宸,于明鑫,等. 结合语义分割与跨模态差分特征补偿的红外与可见光图像融合方法[J]. 电子测量与仪器学报,2024,38(7):34-45.
LI T F, SUN Y CH, YU M X, et al. Infrared and visible light image fusion method combining semantic segmentation and cross modal differential feature compensation[J] Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 34-45.
- [2] 陈广秋,尹文卿,温奇璋,等. 基于双重注意力机制生成对抗网络的偏振图像融合[J]. 电子测量与仪器学报,2024,38(4):140-150.
CHEN G Q, YIN W Q, WEN Q ZH, et al. Polarization image fusion based on dual attention

mechanism generative adversarial network[J] Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 140-150.

- [3] 吴卓升,张巍,林艳,等. 动态概率卷积神经网络在雷达回波外推中的应用[J]. 计算机应用研究,2021,38(7):2125-2129.
WU ZH SH, ZHANG W, LIN Y, et al. Application of dynamic probability convolutional neural network in radar echo extrapolation[J]. Computer Application Research, 2021, 38(7): 2125-2129.
- [4] 尹传豪,秦华旺,戴跃伟,等. GLnet:融合全局和局部信息的短临降雨预报网络[J]. 电子测量技术,2023,46(17):102-108.
YIN CH H, QIN H W, DAI Y W, et al. GLnet: A short-term rainfall forecast network integrating global and local information [J]. Electronic Measurement Technology, 2023, 46(17): 102-108.
- [5] 包广斌,罗瞳,彭璐,等. 3DuA-Net:融合 3D 卷积和注意力的雷达回波外推预报[J]. 电子测量技术,2024,47(15):153-160.
BAO G B, LUO T, PENG L, et al. 3DuA Net: Radar echo extrapolation prediction integrating 3D convolution and attention[J]. Electronic Measurement Technology, 2024, 47(15): 153-160.
- [6] 许小峰. 从物理模型到智能分析—降低天气预报不确定性的新探索[J]. 气象,2018,44(3):341-350.
XU X F. From physical models to intelligent analysis: A new exploration of reducing weather forecast

- uncertainty[J]. *Meteorology*, 2018, 44(3): 341-350.
- [7] 张敬林, 薛珂, 杨智鹏, 等. 人工智能与物联网在大气科学领域中的应用[J]. *地球物理学进展*, 2022, 37(1): 94-109.
ZHANG J L, XUE K, YANG ZH P, et al. Application of artificial intelligence and internet of things in atmospheric science [J]. *Advances in Geophysics*, 2022, 37(1): 94-109.
- [8] 陈训来, 刘军, 郑群峰, 等. 基于卷积门控循环单元神经网络的临近预报方法研究[J]. *高原气象*, 2021, 40(2): 411-423.
CHEN X L, LIU J, ZHENG Q F, et al. Research on proximity prediction method based on convolutional gated recurrent unit neural network [J]. *Plateau Meteorology*, 2021, 40(2): 411-423.
- [9] 方巍, 齐媚涵. 基于深度学习的高时空分辨率降水临近预报方法[J]. *地球科学与环境学报*, 2023, 45(3): 706-718.
FANG W, QI M H. High spatiotemporal resolution precipitation forecasting method based on deep learning [J]. *Journal of Earth Science and Environment*, 2023, 45(3): 706-718.
- [10] SHI X J, CHEN ZH R, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[J]. *Advances in Neural Information Processing Systems*, 2016, 28, DOI:10.1007/978-3-319-21233-3_6.
- [11] WANG Y B, WU H X, ZHANG J J, et al. PredRNN: A recurrent neural network for spatiotemporal predictive learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(2): 2208-2225.
- [12] WANG Y B, GAO ZH F, LONG M SH, et al. PredRNN++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning[C]. *The 35th International Conference on Machine Learning*, Stockholm, Sweden, 2018: 5123-5132.
- [13] WU H X, YAO ZH Y, WANG J M, et al. MotionRNN: A flexible model for video prediction with spacetime-varying motions [C]. *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, USA, 2021: 15430-15439.
- [14] NAZ F, SHE L, SINAN M, et al. Enhancing radar echo extrapolation by ConvLSTM2D for precipitation nowcastings[J]. *Sensor*, 2024, 24, 459.
- [15] 黄兴友, 马玉蓉, 胡苏蔓. 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*, 2021, 79(5): 817-827.
HUANG X Y, MA Y R, HU S M. Extrapolation and effect analysis of weather radar echo sequence based on deep learning[J]. *Journal of Meteorology*, 2021, 79(5): 817-827.

作者简介

谢梦, 硕士研究生, 助理工程师, 主要研究方向为人工智能、遥感气象图像处理等。

E-mail: 15262036926@163.com

刘丽丽(通信作者), 硕士研究生, 助理工程师, 主要研究方向为人工智能、遥感气象图像处理等。

E-mail: 2932361426@qq.com