

基于 SCAM-LSTM 的雷达回波外推方法

张 望¹

ZHANG Wang

摘 要

雷达回波外推对于气象预报和灾害预警具有重要意义。为了提升预测模型的性能,提出一种新型的雷达回波外推模型——SCAM-LSTM,通过将时空协同注意机制引入长短期记忆网络,增强对时空特征的捕捉能力。时空协同注意机制通过精确编码通道关系和长期依赖关系,分解全局池化为一维特征编码操作,使模型能够在水平和垂直两个方向上分别聚合特征。实验结果表明,SCAM-LSTM 在评估指标(如 critical success index (CSI) 和 Heidke skill score (HSS)) 上均表现出色,预测的雷达回波图像与真实观测图像高度一致,尤其在复杂气象环境中表现卓越,显示出较高的鲁棒性和准确性。

关键词

长短期记忆网络; 降水预报; 雷达回波外推; 时空协同注意机制; 神经网络

doi: 10.3969/j.issn.1672-9528.2024.11.024

0 引言

降水短临预报是一种短时天气预报技术,主要用于预测未来几小时内的降水情况。这种预报通常覆盖的时间范围为 2 h 内,因而被称为短临预报。降水短临预报在气象学中有着许多应用,特别是对于预防和应对突发性的强降水天气,如暴雨、雷暴、冰雹等具有重要意义。

传统的数值天气预报(numerical weather prediction, NWP)将给定时间内气象要素的空间分布作为初始值^[1],在一定的边界条件下建立复杂的物理状态方程,并利用计算机模拟未来的大气运动。NWP 方法在短程和中程预测操作中非常成熟,但它们需要较高的计算资源和时间,因此在部分场景中受限。

随着人工智能技术的发展,深度学习神经网络被应用于降水短临预报,使用雷达回波数据进行预测的技术成为一种常见且发展前景广阔的方法。雷达回波外推的目标是根据过去观测到的雷达回波图,预测某一区域未来固定时间长度内的雷达回波图^[2]。通过优化算法,神经网络模型可以学习大量数据,利用深度学习算法有效记录雷达数据在高时空分辨率序列中的内部相关特征,捕捉演变规律和雷达回波的运动状态。

长短期记忆网络(long short-term memory, LSTM)是一种特殊的递归神经网络(recurrent neural network, RNN),主要用于处理和预测时间序列数据^[3]。LSTM 通过设计记忆单元和激活机制,能有效捕捉和利用长期相关信息,从而克

服传统 RNN 处理长时间序列数据时出现的梯度丢失和突发性问题。在雷达回波外推中,LSTM 利用其强大的时间序列建模能力,捕捉雷达回波随时间变化的复杂模式。传统的物理模型可能难以准确捕捉所有的气象现象,而 LSTM 等数据驱动模型可以通过大量历史数据的训练,自动学习复杂的模式和关系,提供高精度的预测。

然而,尽管现有的神经网络模型在很多方面表现出色,但在雷达回波外推中仍然存在一些问题和挑战。

(1) 预测精度问题:随着预测步数的增加,模型的误差会逐步累积,导致预测结果偏离真实情况^[4]。

(2) 空间细节问题:雷达回波图像中包含许多细节和复杂的空间结构,模型在捕捉这些细节方面可能存在不足,尤其是在处理高分辨率雷达数据时。

(3) 计算资源问题:模型复杂,计算资源需求较高。

为此,本文提出了一种融入时空协同注意机制(spatio-temporal collaborative attention mechanism, SCAM)的 LSTM 模型,通过将定位信息纳入通道注意力,为模型增加了一种新的注意力机制。与此同时,通道的注意力被分解成两个一维特征编码过程,每个过程都沿两个空间方向聚集特征。沿垂直和水平方向聚合的特征图被编码为一对方向和位置敏感的注意力图,通过将这两个互补的注意力图应用于输入特征图,改进了感兴趣对象的表示。时空协同注意机制(SCAM)的应用大大提高了雷达回波外推的预测性能。

1 算法概述

本节聚焦于 SCAM-LSTM 网络模型,首先分析说明时空协同注意机制,然后阐释 SCAM-LSTM 内部单元。

1. 安徽建筑大学电子与信息工程学院 安徽合肥 230601

1.1 时空协同注意机制

时空协同注意模块可以看作一个计算单元，旨在提升神经网络的特征表达能力。它可以接受任意中间特征张量 $\mathbf{X}=\{X_1, X_2, \dots, X_c\} \in \mathbf{R}^{C \times H \times W}$ 作为输入，并输出一个增强表示的变换张量 $\mathbf{Y}=\{Y_1, Y_2, \dots, Y_c\}$ ，其大小与 $\mathbf{X}$ 相同。模块示意图如图 1 所示。




图 1 时空协同注意模块

时空协同注意模块通过精确的位置信息编码通道关系和长期依赖关系，涉及坐标信息嵌入和协同注意生成。为了在空间上捕捉长期信息并使用精确的定位信息，注意力模块将全局分组分解为一维特征编码操作^[5]。给定输入 $\mathbf{X}$ ，每个通道根据水平和垂直坐标进行编码，分别使用聚类核的两个空间区域 $(H, 1)$ 和 $(1, W)$ 。因此，第 c 个通道在高度 h 处的输出可以表示为：

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (1)$$

同样，宽度为 w 的第 c 个通道的输出也可以写成：

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (2)$$

上述两种变换结合了两个空间方向的特征，生成了一对方向特征图。这些变换使时空协同注意模块能够捕捉一个空间方向上的长期依赖关系，同时保留另一个方向上的精确定位信息，帮助网络更准确地识别雷达图像中的强降水区域。

1.2 SCAM-LSTM 内部单元

SCAM-LSTM 的内部单元结构如图 2 所示，其中 X_t 为输

入， H_{t-1}^l 为隐藏状态， C_{t-1}^l 为时间记忆单元， M_{t-1}^l 为空间记忆单元。 i_t 为输入门， g_t 为输入调制门， f_t 为遗忘门，对应 LSTM 神经网络模型的三扇门结构。




图 2 SCAM-LSTM 内部单元

SCAM-LSTM 的计算公式为：

$$\begin{aligned} g_t &= \tanh(W_{xg} * X_t + W_{hg} * H_{t-1}^l + b_g) \\ i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1}^l + b_i) \\ f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1}^l + b_f) \\ C_t^l &= \text{Attention}(f_t \odot C_{t-1}^l) + i_t \odot g_t \\ g_t' &= \tanh(W_{xg'} * X_t + W_{mg'} * M_{t-1}^{l-1} + b_{g'}) \\ i_t' &= \sigma(W_{xi'} * X_t + W_{mi'} * M_{t-1}^{l-1} + b_{i'}) \\ f_t' &= \sigma(W_{xf'} * X_t + W_{mf'} * M_{t-1}^{l-1} + b_{f'}) \\ M_t^l &= f_t' \odot M_{t-1}^{l-1} + i_t' \odot g_t' \\ o_t &= \sigma(W_{xo} * X_t + W_{ho} * H_{t-1}^l + W_{co} * C_t^l + W_{mo} * M_t^l + b_o) \\ H_t^l &= o_t \odot \tanh(W_{1 \times 1} * [C_t^l, M_t^l]) \end{aligned} \quad (3)$$

隐藏状态 H_{t-1}^l 经过遗忘门之后，与当前的时间记忆单元 C_{t-1}^l 在时空协同注意模块中进行特征融合，得到更新的时间记忆单元 C_t^l 。

1.3 SCAM-LSTM 整体结构

SCAM-LSTM 的整体结构是一个多层堆叠的时空 LSTM 网络，用于处理雷达回波数据，如图 3 所示。




图 3 SCAM-LSTM 整体结构

每一层中，输入包括上一层的输出以及 t 时刻的输入。SCAM-LSTM 网络的每层都计算记忆单元状态和隐藏状态，并逐层向上传递。跨层间存在跳跃连接，以强化不同层次之间的信息交互。

2 数据集

雷达回波数据集是通过气象雷达系统收集的用于描述和分析大气现象的详细数据集。雷达回波数据主要包括回波强度、速度数据、谱宽和反射率因子等重要参数。回波强度表示降水的强度和分布，单位通常为分贝（dBZ），是评估降水量的关键指标；速度数据则记录了降水颗粒相对于雷达的运动速度，通常以米每秒（m/s）为单位，用于分析风速和风向；谱宽反映了回波频率的宽度，表示降水颗粒或气流的运动状态，通常也是以米每秒（m/s）为单位；反射率因子则关联到降水颗粒的浓度，有助于估算降水量。

在本文中，数据集分为训练样本和测试样本。训练样本包含 20 000 张雷达图像，测试样本包含 5000 张雷达图像。训练样本用于训练 SCAM-LSTM 模型，测试样本用于评估模型的性能。每 20 张雷达图像作为一组图像序列，前 10 张为模型输入，后 10 张为实际输出，即真实观测图像。每张雷达图像之间的间隔为 6 min，每 10 张则为 1 h 的雷达数据。模型经过训练之后，可以根据前 10 张雷达图像预测后 10 张雷达图像，从而实现前 1 h 预测后 1 h 的降水量。

3 实验设计与结果

SCAM-LSTM 模型基于 PyTorch 框架，训练和测试过程均在 NVIDIA A100 GPU 上进行，占用显存约 25 GB，批大小设置为 4，学习率设置为 0.0001，优化器选择 Adam 优化器。

3.1 评估指标

CSI（critical success index）和 HSS（Heidke skill score）是气象学中常用的评估指标，用于评估天气预报模型或降水预报的准确性。

CSI 于评估二分类预测的效果（例如降水是否发生）。它是一个综合指标，衡量了预测正确与否的能力，特别是在考虑了预测中的漏报和误报的情况下。CSI 的计算公式为：

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

(4)

式中：TP 是真阳性（即正确预测为事件发生的次数，例如正确预测了降水的区域），FP 是假阳性（即错误预测为事件发生的次数，例如预测了降水但实际没有降水），FN 是假阴性（即漏报的次数，例如预测没有降水但实际有降水）^[6]。

Heidke 技巧评分（heidke skill score, HSS）是衡量天气预报模型准确性的重要指标，它通过比较模型预报与实际观测的吻合程度，评估模型在随机猜测基础上改进的效果。在雷达回波外推中，HSS 用于评估模型对降水区域的预报准确性和稳定性，帮助分析模型在短时降水预报中的有效性。高 HSS 值表示模型能有效捕捉降水的空间分布和演变趋势，是评价雷达回波外推模型性能的重要参考。HSS 的计算公式为：

$$HSS = \frac{2(TP \times TN - FP \times FN)}{(TP + FN)(FN + TN) + (TP + FP)(FP + TN)}$$

(5)

式中：TN 是真阴性（即正确预测为事件未发生的次数）。CSI 的值范围从 0 到 1，值越高表示预测的成功率越高。HSS 的值通常在负值到 1 之间。值为 1 表示完美预测，0 表示与随机预测没有改进，负值则表示预测效果比随机预测还差。

3.2 结果分析

表 1 显示了模型分别在阈值 10 dBZ、20 dBZ、35 dBZ 时的 CSI 评测结果，并与其他先进方法进行对比。按均值对比，SCAM-LSTM 的 CSI 值对比 ConvLSTM^[7] 提升 6.44%，对比 PredRNN^[8] 提升 3.82%，对比 MIM^[9] 提升 2.87%。

表 1 CSI 评估结果

模型	10 dBZ	20 dBZ	35 dBZ	均值
ConvLSTM	0.722 6	0.485 3	0.409 3	0.539 1
PredRNN	0.751 4	0.495 5	0.411 2	0.552 7
MIM	0.753 0	0.500 8	0.419 7	0.557 8
SCAM-LSTM	0.761 1	0.523 8	0.436 6	0.573 8

表 2 显示了在 3 个阈值下的 HSS 评价结果，同样按均值对比，SCAM-LSTM 的 HSS 值对比 ConvLSTM 提升 5.40%，对比 PredRNN 提升 3.97%，对比 MIM 提升 2.68%。

表 2 HSS 评估结果

模型	10 dBZ	20 dBZ	35 dBZ	均值
ConvLSTM	0.713 8	0.536 6	0.463 8	0.571 4
PredRNN	0.719 5	0.543 8	0.474 4	0.579 2
MIM	0.727 8	0.556 9	0.475 6	0.586 8
SCAM-LSTM	0.740 8	0.578 2	0.487 6	0.602 2

对于 CSI 和 HSS 指标，本文所提出的 SCAM-LSTM 对比其他先进方法均有提升，由于时空协同注意模块的加入，模型在雷达回波外推中的预测性能变得更佳。为了更直观地

展示实验结果,图4将SCAM-LSTM所得到的外推图像与其他模型的结果进行对比。




图4 雷达回波外推结果

从图4可以看到,本文提出的SCAM-LSTM方法在雷达回波外推任务中的表现尤为出色。与真实观测图像相比,SCAM-LSTM的外推结果在细节保真度和降水强度分布的保持上表现优秀。尤其是对于复杂的雷达回波结构,SCAM-LSTM能够精确地捕捉小尺度的细节变化,使得预测结果与真实图像的形状和强度分布更加接近。相比之下,MIM和PredRNN尽管在结构上引入了记忆机制,但它们的时空特征交互能力有限,未能有效捕捉小尺度的细节变化,导致图像模糊,细节丢失。ConvLSTM的结构简单,仅依赖卷积和递归来捕捉时空特征,因此在复杂的降水场景中容易丢失空间细节和动态变化。它的局限性导致生成的图像模糊且与真实观测有较大偏差。

4 结论

在本文中,提出了一种新型的雷达回波外推模型——SCAM-LSTM,将时空协同注意机制引入到长短期记忆网络中,以提升雷达回波外推的性能。通过在模型中引入SCAM,能够更有效地捕捉雷达回波数据中的时空特征,从而显著提升了预测的准确性和稳定性。

时空协同注意机制将全局分组分解为一维特征编码操作,用精确的位置信息对信道关系和长程依赖关系进行编码,分别从水平和垂直两个方向对特征进行分组。这样,SCAM不仅能捕捉一个方向上的长程依赖关系,还能保留另一个方向上的精确位置信息,使模型对雷达回波图像的空间特征和动态变化更加敏感。

通过一系列实验验证,SCAM-LSTM在评估指标(critical success index, CSI和Heidke skill score, HSS)上均表现出色。具体来说,SCAM-LSTM在捕捉降水分布和强度变化方面具有显著优势,与真实观测图像的高度一致性表明了其在时空特征提取和降水演变模拟方面的卓越性能。

进一步分析表明,SCAM-LSTM模型在各种天气条件下均能保持较高的预测精度,特别是在复杂的气象环境中,其

表现尤为突出。这表明,时空协同注意机制不仅提高了模型的整体性能,还增强了模型的鲁棒性和适应性。

参考文献:

- [1] 徐宗学,初祁,王昊,等.基于陆气耦合的城市雨洪模拟技术研究进展[J].北京师范大学学报(自然科学版),2022,58(3):434-446.
- [2] 陆冰凌,李玲,麦雄发.基于亚像素的金字塔光流法的雷达回波外推预报[J].南宁师范大学学报(自然科学版),2023,40(2):40-49.
- [3] 花凡,李莉,蔡鑫楠,等.长短期记忆网络在气温预测中的应用[J].智能计算机与应用,2022,12(11):92-95+102.
- [4] 张梦凡,丁兵兵,贾国栋,等.基于TCN-BiLSTM与LSTM模型对比预测北洛河径流[J].北京林业大学学报,2024,46(4):141-148.
- [5] 金传,童常青.融合CNN与Transformer结构的遥感图像分类方法[J].激光与光电子学进展,2023,60(20):233-242.
- [6] 钟宇璐.风云四号卫星定量降水估计产品的检验评估[J].农业灾害研究,2021,11(3):96-98.
- [7] SHI X J, CHEN Z R, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[C]//Advances in Neural Information Processing Systems. Red hook NY: Curran Associates Inc., 2015:802-810.
- [8] WANG Y B, LONG M S, WANG J J, et al. Predrnn: Recurrent neural networks for predictive learning using spatiotemporal lstms[C]//NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems. Red hook NY: Curran Associates Inc., 2017: 879-888.
- [9] WANG Y B, ZHANG J J, ZHU H Y, et al. Memory in memory: a predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics[C]//2019 IEEE/CVP Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2019:9146-9154.

【作者简介】

张望(2002—),男,湖北监利人,硕士,研究方向:深度学习在气象预报中的应用、降水短临预报。

(收稿日期:2024-07-26)