

DMLSTM: 动态注意力与记忆增强 LSTM 的雷达回波外推^①



卢奇玮^{1,2}, 戈文一¹, 胡靖¹, 魏敏^{1,2}

¹(成都信息工程大学 计算机学院, 成都 610255)

²(成都信息工程大学 四川省医疗虚拟现实与增强现实工程试验中心, 成都 610255)

通信作者: 魏敏, E-mail: weimin@cuit.edu.cn

摘要: 雷达回波外推被广泛用于降水预测和气象灾害预警等任务, 近年来结合深度学习的时序预测模型有效提升了预测效果, 但是仍然存在着全局依赖建模不足、预报图像模糊等问题. 为了提升预测精度, 提出一种融合动态窗口注意力与长短期记忆网络的雷达回波外推模型 DMLSTM (dynamic window attention memory-enhanced LSTM). 首先, 通过动态双缩放窗口注意力精准捕捉多尺度气象结构; 同步采用记忆增强型滑动窗口维持时空连续演化; 再由自适应残差门控单元抑制长程特征衰减并增强突变响应; 最终, 借梯度对齐型多尺度注意力损失函数保持关键气象结构的物理运动约束. 实验结果表明, 在深圳雷达回波数据集上, 相较最优基线模型 (SwinLSTM-B), 本研究模型参数量小幅增加, 经结构优化后, 单轮推理耗时增加 5%, 但均方误差 (MSE) 降低了 10.3%, 结构相似性 (SSIM) 提升了 1.4%. 在 Moving MNIST 数据集上, MSE 降低 14.9%, SSIM 达 0.926. 实验结果验证了该模型在雷达回波外推任务的先进性及其泛化能力.

关键词: 雷达回波外推; 时序预测; 窗口注意力机制; 长短期记忆网络; 图像处理

引用格式: 卢奇玮, 戈文一, 胡靖, 魏敏. DMLSTM: 动态注意力与记忆增强 LSTM 的雷达回波外推. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10137.html>

DMLSTM: Radar Echo Extrapolation with Dynamic Attention and Memory-enhanced LSTM

LU Qi-Wei^{1,2}, GE Wen-Yi¹, HU Jing¹, WEI Min^{1,2}

¹(School of Computer Science, Chengdu University of Information Technology, Chengdu 610255, China)

²(Sichuan Provincial Medical Virtual Reality and Augmented Reality Engineering Experimental Center, Chengdu University of Information Technology, Chengdu 610255, China)

Abstract: Radar echo extrapolation is widely used in tasks such as precipitation forecasting and meteorological disaster warning. In recent years, temporal prediction models combined with deep learning have effectively improved forecasting performance. However, several challenges still remain, including insufficient global dependency modeling and blurred forecast images. To improve prediction accuracy, this study proposes a radar echo extrapolation model, DMLSTM, which integrates dynamic window attention memory (DM) with long short-term memory (LSTM) networks. First, dynamic dual-scale window attention is applied to accurately capture multi-scale meteorological structures. Meanwhile, a memory-enhanced sliding window is employed to maintain continuous spatiotemporal evolution. Subsequently, an adaptive residual gating unit suppresses long-range feature attenuation and enhances responsiveness to sudden changes. Finally, a gradient-aligned multi-scale attention loss function is introduced to preserve the physical motion constraints of key meteorological structures. Experimental results indicate that, on the Shenzhen radar echo dataset, compared with the best

① 基金项目: 中央在川高校院所“聚源兴川”项目 (2024ZHCG0190); 四川省科技成果转化示范项目 (2024ZHCG0176); 四川省科技计划青年科技创新研究团队项目 (2024NS-FTD0044)

收稿时间: 2025-09-25; 修改时间: 2025-10-14, 2025-11-21; 采用时间: 2025-12-01; csa 在线出版时间: 2026-03-02

baseline model (SwinLSTM-B), the proposed model slightly increases the number of parameters. After structural optimization, the single-round inference time increases by 5%, while the mean squared error (MSE) decreases by 10.3% and the structural similarity (SSIM) increases by 1.4%. On the Moving MNIST dataset, the MSE is reduced by 14.9% and the SSIM reaches 0.926. These experimental results demonstrate the advanced performance and strong generalization capability of the proposed model in radar echo extrapolation tasks.

Key words: radar echo extrapolation; temporal prediction; windows attention mechanism; long short-term memory (LSTM) network; image processing

随着气象预报技术的不断发展, 雷达回波外推作为短期天气预测的重要手段, 在降水预测、风暴预警及其他气象灾害防范中发挥着关键作用^[1]. 雷达回波外推是指根据雷达回波序列数据, 预测未来一段时间内回波数据的空间分布、强度变化及运动趋势^[2], 来预判未来气象演变态势, 这一过程需要精确捕捉回波的空间形态和时间演变规律. 传统雷达回波外推研究方法主要包括交叉相关法^[3]、单体质心法^[4]和光流法^[5]. 交叉相关法通过计算相邻时刻雷达回波子区域相关系数确定移动矢量以外推预报, 可以有效跟踪层状云降雨系统, 但对于回波变化快的强对流过程, 追踪准确度较低. 单体质心法基于回波图中风暴单体的空间特征定位质心, 通过连续扫描匹配单体位置计算移动矢量进行预测, 能有效地识别和跟踪风暴单体, 但依赖单体分割准确性, 无法准确表征单体内部结构变化. 光流法通过估算雷达回波图像序列中每个像素的运动矢量场实现外推, 能捕捉复杂形变运动, 但对于热带降水系统尤其是台风系统, 光流法没有考虑雷达回波的旋转性, 导致预测效果不佳.

传统的雷达回波外推方法大多依赖经典的物理模型, 通常基于回波的平移、扩散等特性进行预测^[6,7]. 但是这些方法往往难以处理回波的非刚性运动特征、精确捕捉回波强度的微小变化^[8,9]. 基于深度学习的时序预测模型, 能够通过从大量历史数据中自动学习对象的空间-时间的变化趋势^[10], 正在降水预测^[11-14]、视频预测^[15-17]和交通预测^[18-20]等领域被大面积使用. 利用其预测的优势与雷达回波外推结合^[21,22], 在处理复杂气象系统、极端天气事件等雷达回波外推预测任务中相较于传统方法展现出了显著的优势.

Shi 等^[23]提出的卷积长短期记忆 (ConvLSTM) 模型首次将卷积神经网络 (convolutional neural network, CNN) 和长短期记忆 (long short-term memory, LSTM)

网络相结合, 通过 CNN 编码空间结构, LSTM 建模时间动态, 由此构建的端到端降水临近预报模型性能显著超越传统方法. 但是考虑到 ConvLSTM 仅关注时间信息而忽略了层间空间信息, Wang 等^[24]提出 PredRNN 模型, 引入时空长短期记忆单元 (ST-LSTM), 通过增设垂直方向的空间记忆流与原始时间记忆流并行运作, 建立跨层记忆传递机制, 显著提升空间特征的层级连续性. Wang 等^[25]进一步提出 PredRNN-V2 模型, 通过级联双记忆单元构建因果记忆单元 (Causal-LSTM) 增强状态容量, 同时引入梯度高速公路单元 (gradient highway unit, GHU) 建立跨层快捷路径缓解梯度消失问题, 在雷达回波预测任务中达到先进水平. Wang 等^[26]提出 MIM 网络 (memory in memory network) 设计差分记忆单元捕捉回波突变特征, 结合自适应滤波记忆单元处理渐变过程, 可以捕捉雷达回波图像中的非平滑和近平滑特征.

注意力机制的引入显著提升了时空预测模型性能^[27]. Wang 等^[28]提出的 Eidetic 3D LSTM (E3D-LSTM) 融合了 3D 卷积与 LSTM, 通过三维卷积增强短期特征提取能力, 并设计门控自注意力机制建模长期历史依赖, 但集成 3D 卷积导致了高昂计算负荷. Tan 等^[29]提出 TAU 模型, 通过时空注意力解耦框架实现高效时空分离建模, 帧内静态注意力采用小核深度卷积与扩张卷积捕捉空间长程依赖, 帧间动态注意力专注处理时序演化, 然而多分支结构增加训练复杂度且对运动突变适应性不足. 为突破传统卷积的局部感受野限制, Tang 等^[30]提出 SwinLSTM, 以 SwinTransformer^[31]的层次化窗口注意力实现全局时空依赖建模, 彻底取代卷积操作. 在多个基准任务中, 其无需额外优化策略即显著超越 PredRNN-V2、E3D-LSTM 等模型, 验证了窗口注意力机制在时空预测中的核心优势. 但因其固定窗口划分破坏气象场的空间连续性、原始简单的 LSTM 架构难以建

模复杂的雷达回波的非线性物理演化过程以及纯 MSE 损失模糊关键特征表达等不足,削弱了其在雷达回波外推任务中的预测效果. Tang 等^[32]设计的 VMRNN 创新融合了 Vision Mamba Blocks 的线性复杂度优势与 LSTM 架构,在降低计算开销的同时扩展感受野,展现出处理复杂动态系统的潜力,但其还未被广泛用于雷达回波外推任务中.

尽管深度学习时序预测模型显著提升了雷达回波外推性能,但现有最优模型仍受限于 3 个关键瓶颈.其一,固定窗口划分机制破坏气象场的空间连续性,难以建模台风旋转等非刚性形变的长程依赖;其二,全局注意力受强回波主导导致弱信号目标特征退化,阻碍关键气象结构识别;其三,纯数据驱动范式缺乏物理约束,易生成虚假涡旋或断裂锋面等非物理解.这些缺陷源于现有架构在空间感知粒度僵化、时序状态割裂及物理规律失准方面的根本局限,还需协同优化注意力与记忆机制的设计范式.

为了克服现有基于注意力机制和长短期记忆网络模型在雷达回波外推中的局限性,本文提出动态双缩放窗口注意力模块,通过可学习缩放因子动态调节局部和全局感知粒度,显著提升对气象多尺度特征的适应性;设计记忆增强型滑动窗口模块,构建跨时刻门控状态传递网络,解决传统滑动窗口的时序割裂问题,保障气象系统运动的连续演化;设计自适应残差门控记忆单元,利用通道注意力加权关键气象要素并动态优化遗忘机制,实现气象演化特征的高效长程传递;利用梯度对齐多尺度损失函数,在梯度空间强化锋面、涡旋等关键气象结构的物理约束.本模型将注意力机制的空间感知优势与记忆网络时序建模能力与雷达回波外推任务深度协同,显著提升预测精度.

1 模型设计

本节介绍模型设计和操作流程,分为 3 个部分.

(1) 输入帧通过针对雷达回波图设计的动态双缩放窗口注意力模块进行特征识别,再经过记忆增强型滑动窗口模块结合历史特征记忆,进行全局和局部的特征提取.

(2) 将上述中的输出特征经过自适应残差门控视窗记忆单元进行门控分解,更新记忆细胞状态,生成预测数据.

(3) 把输出帧和目标帧通过 3 种特征加权融合的

损失函数调整模型参数,迭代训练,达到最佳的预测效果.算法整体实现架构图如图 1 所示.

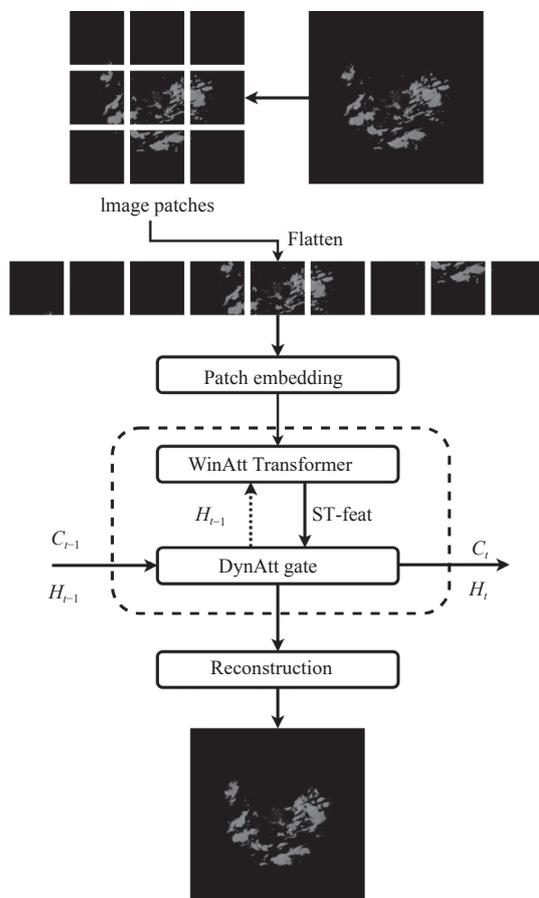


图 1 算法整体实现框架图

1.1 动态双缩放窗口注意力模块

本文设计的窗口注意力机制让模型更准确地关注回波的关键区域及其运动趋势的预测优先级.引入独立温度参数实现各注意力头的自适应调节,模型能够更灵活地处理强度差异巨大的回波值,避免强回波过度主导注意力而忽略重要弱信号.设计了对数缩放因子初始化策略,其核心优势在于匹配雷达回波强度的固有对数特性,有效规避了线性或指数初始化在应对巨大动态范围时的不足,从而缓解注意力得分过早饱和的问题,并提升了对早期弱对流系统的识别能力.同时,在计算查询向量与键向量的相似度前执行标准化处理,有效削弱了雷达回波本身强度差异过大带来的干扰,让模型更专注于回波的真实移动趋势和结构变化.

动态位置编码机制通过建立空间坐标与运动矢量的映射关系,实现对雷达回波中运动目标的精准定位.

采用多层感知机 (multilayer perceptron, MLP) 生成动态位置偏置, 以强化模型的空间感知能力. 通过深层网络结构将原始坐标映射为高维隐空间表示, 克服了传统固定位置编码的表征局限. 引入可学习缩放系数并结合激活函数对位置偏置进行非线性变换, 实现了位置信息的自适应加权. 动态调整的位置感知机制有效提升了模型对回波空间分布特征的提取能力, 为模型分析回波数据的移动轨迹和形态演变提供了关键支撑.

最后, 根据是否采用了窗口位移策略来决定是否引入掩码 (MASK) 机制, 以屏蔽位移后非连通区域之

间无效的注意力计算, 确保不同区域的窗口之间信息能充分传递的同时剔除冗余数据, 增强模型的特征提取能力. 动态双缩放窗口注意力模块结构如图 2 所示.

1.2 记忆增强型滑动窗口模块

由于雷达回波具有时空演化的连续性与历史依赖性, 设计了记忆增强型滑动窗口模块, 通过隐状态传递与特征级联操作, 将历史关键信息动态融合至当前输入. 在空间维度提取局部特征关联, 在时间维度建立跨时刻状态交互, 显著提升模型对回波系统动态演变规律的建模能力, 模块结构如图 3 所示.

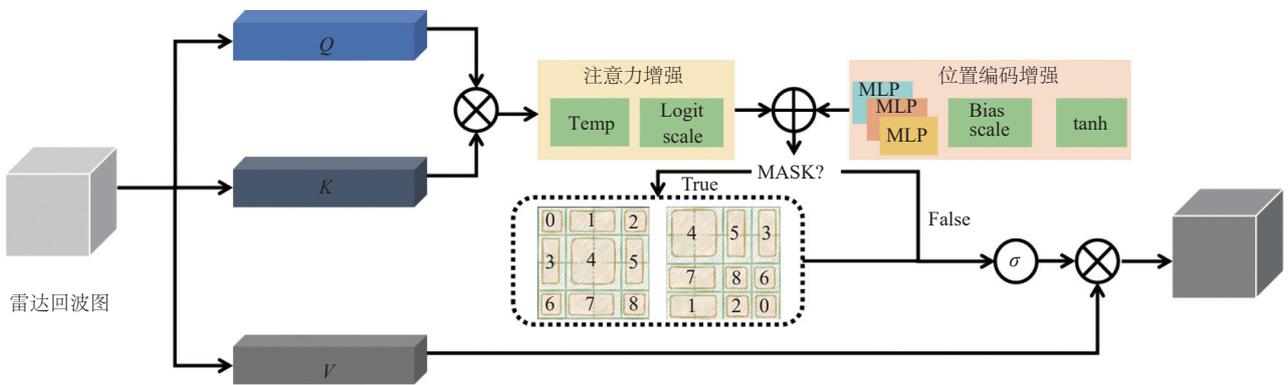


图 2 动态双缩放窗口注意力模块

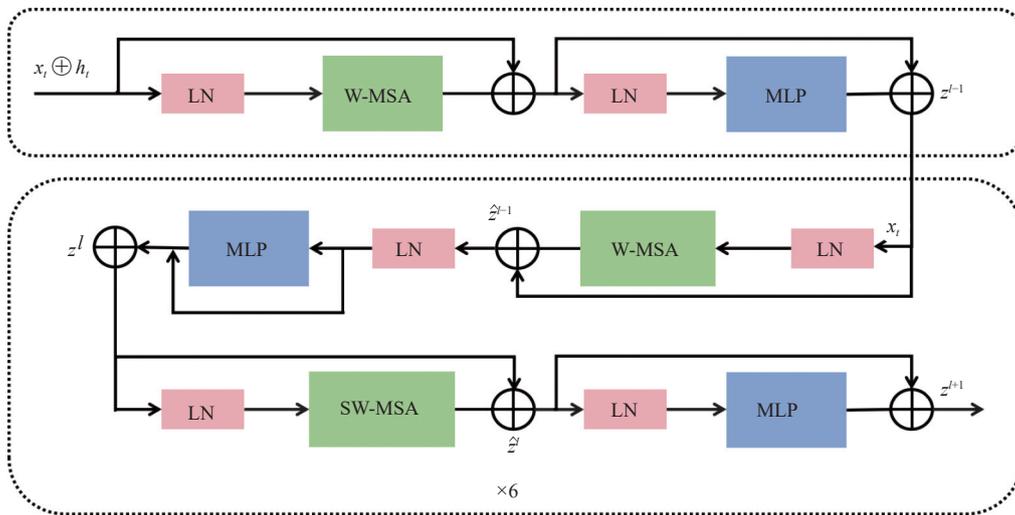


图 3 记忆增强型滑动窗口模块

基于层级堆叠的交替处理架构, 采用无位移层 W-MSA (历史-当前特征级联融合) 与位移层 SW-MSA (局部时空特征提取) 的协作机制, 构建双向信息传递路径. 经过实验验证, 采用 6 层循环设计有效保持了回波空间特征的完整性, 并通过历史状态的渐进式深度

融合克服了传统递归网络的梯度衰减问题. 其结合滑动窗口的高计算效率, 实现了对长时间序列回波演变过程的精确建模. 同时 6 层设计可提供 30 km 的时空感受野, 精准匹配了深圳雷达回波中风暴 10-20 km/h 的典型移动速度, 甚至涵盖特殊情况下 30 km/h 的极端

情况, 结合 50 min 的预测周期, 模型能完整覆盖风暴在此期间的动态移动范围. 这一结构在兼顾计算效率的前提下, 全面捕捉常规风暴移动特征并增强极端天气适应能力, 最终达成预测精度与计算效率的协同优化.

1.3 自适应残差门控视窗记忆单元

针对雷达回波数据的时空动态特性和复杂非线性演变规律, 通过整合多层窗口注意力机制的结果, 提升模型在局部与全局特征协同提取的能力, 再引入由通道注意力 (C-Attn) 增强的门控系统, 通过对雷达回波特征通道的差异化加权, 实现灾害敏感区域的特征增强与干扰信息抑制, 显著提升强对流关键目标的识别精度与预测稳定性.

使用动态遗忘偏置 (f-bias) 调节历史记忆衰减程度, 使系统对正在加强的风暴重点跟踪, 对已经消散的云团快速忽略. 该机制配合多层次归一化特征稳定方案, 通过输入特征、隐藏状态和细胞状态三重归一化层, 分层稳定特征分布, 增强模型训练稳定性和梯度流动效率, 在回波强度剧烈波动时维持物理规律的合理性输出, 避免传统方法中常见的虚假回波生成与强度断层现象, 确保极端天气下推演结果的可靠性与预警时效性; 面对台风眼墙更替、对流合并等突发剧变, 结合自适应残差系数 (LRC) 动态平衡最新状态与历史状态, 大幅提升预测系统对天气突变的响应灵敏度. 自适应残差门控视窗记忆单元结构如图 4 所示.

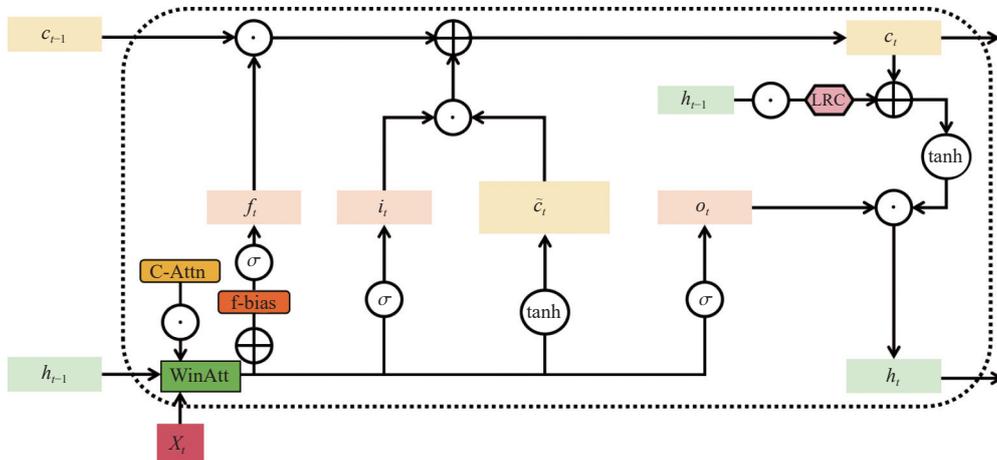


图 4 自适应残差门控视窗记忆单元

1.4 梯度对齐型多尺度注意力损失

本文的损失函数包括 3 个部分.

1.4.1 基础损失

模型整体使用了基于均方误差的基础损失函数, 通过逐像素计算预测值与真实值之差的平方的平均值, 构建了整体数据分布的一致性约束, 如式 (1) 所示:

$$L_{\text{base}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (1)$$

1.4.2 多尺度结构注意力损失

设计了一种融合双模态注意力的多尺度加权损失来解决关键气象特征分布不均匀的问题. 通过多尺度梯度算子提取不同尺度的气象轮廓特征, 再进行动态归一化与非线性变换生成空间权重分布, 最后引入通道注意力机制生成双模态加权回波图, 使模型在强回波区域和复杂天气系统结构上具有更强的特征重建能

力, 计算公式如式 (2):

$$W_{\text{multi}} = \sum_{k=1}^3 \lambda_k [4\sigma(5\tilde{G}_k - 2.5) + 0.5] \quad (2)$$

其中, \tilde{G}_k 是第 k 尺度 (共 3 个尺度) 下归一化到 [0, 1] 的梯度幅值 (值为 0 表示平滑区域, 1 表示强边缘), 计算公式如式 (3):

$$\tilde{G}_k = \frac{G_{\text{mag}}^{(k)} - \min_{h,w} G_{\text{mag}}^{(k)}}{\max_{h,w} G_{\text{mag}}^{(k)} - \min_{h,w} G_{\text{mag}}^{(k)} + \varepsilon} \quad (3)$$

其中, $G_{\text{mag}}^{(k)}$ 表示当前批次所有样本在第 k 尺度下的各像素的梯度强度, $\max_{h,w} G_{\text{mag}}^{(k)}$ 和 $\min_{h,w} G_{\text{mag}}^{(k)}$ 分别表示该范围内的最大值和最小值, 计算公式如式 (4):

$$G_{\text{mag}}^{(k)} = \sqrt{(G_x^{(k)}(I))^2 + (G_y^{(k)}(I))^2} + \varepsilon \quad (4)$$

其中, $G_x^{(k)}(I)$ 表示由 Sobel 算子计算得到的水平方向梯

度. 同理, $G_y^{(k)}(I)$ 表示垂直方向上的梯度, 公式如式(5):

$$G_x^{(k)} = I \times S_x^{(k)}, G_y^{(k)} = I \times S_y^{(k)} \quad (5)$$

其中, I 表示真实图像特征, $S_x^{(k)}$ 为第 k 尺度对应的水平梯度算子, $S_y^{(k)}$ 为第 k 尺度对应的垂直梯度算子. Sobel算子核尺寸与尺度 k 对应分别为3、5、7.

在雷达回波外推任务中, 首先通过系数5与偏移量2.5将归一化梯度的气象关键特征对齐至Sigmoid函数高响应区; 再经过非线性增强, 将权重范围扩大, 使强梯度区获得最高4.5倍损失权重, 同时弱梯度区保持0.5倍基础权重. λ 的取值为0.3、0.3、0.4, 它的比例基于气象系统的物理特性设计: 较小尺度的 3×3 算子捕捉5–10 km的突发对流边界, 中等尺度的 5×5 算子平衡10–20 km的中尺度特征, 而较大尺度的 7×7 算子则聚焦30 km的大范围系统运动. 整体优化模型使小尺度捕捉细节、大尺度提取主体轮廓, 最终生成适应图像结构的边缘感知权重图 W_{multi} .

结合双模态注意力机制, 通过协同通道与空间信息强化关键区域. 首先, 计算 W_{multi} 的全局均值和最大值, 分别用来反映整体重要性和捕获最显著特征, 二者的乘积生成通道注意力因子, 该因子用来量化整个雷达回波场的活跃程度. 然后, 将注意力因子与原始空间权重逐元素相乘, 形成双模态权重, 使模型在损失计算中聚焦于“强回波核心区”和“大范围运动系统”的协同演化, 显著提升外推的预测敏感度, 计算公式如式(6):

$$A_c(n) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W W_{\text{multi}} \odot \max_{\substack{1 \leq i \leq H \\ 1 \leq j \leq W}} W_{\text{multi}} \quad (6)$$

最终空间多尺度注意力损失为:

$$L_{\text{msca}} = W_{\text{multi}} \odot A_c(n) \quad (7)$$

1.4.3 多尺度梯度对齐损失

针对雷达回波边缘结构连续性高保真需求, 设计了一种多尺度梯度对齐损失, 提升了预测时处理中锋面、涡旋等关键结构边缘模糊问题的效果. 通过在3个特征尺度上同步计算预测结果与真实数据的空间梯度差异, 构建水平和垂直方向的结构对齐约束, 确保雷达回波外推过程中保持准确的整体轮廓特征, 计算公式如式(8):

$$\mathcal{L}_{\text{grad}} = \frac{1}{2} \sum_k \lambda_k \left(\left\| G_x^{(k)}(\hat{I}) - G_x^{(k)}(I) \right\|_1 + \left\| G_y^{(k)}(\hat{I}) - G_y^{(k)}(I) \right\|_1 \right) \quad (8)$$

其中, λ 是第 k 尺度下的权重, 与多尺度结构注意力损失的取值相同, I 表示真实图像, \hat{I} 表示预测图像, $G_x^{(k)}(I)$ 表示由Sobel算子计算得到的水平方向梯度, 同理, $G_y^{(k)}(I)$ 表示垂直方向上的梯度, 计算方法同式(5).

1.4.4 损失融合

3种损失需要按照一定的比例进行分配, 公式如式(9):

$$L_{\text{total}} = \alpha \times L_{\text{base}} + \beta \times L_{\text{msca}} + \gamma \times L_{\text{grad}} \quad (9)$$

其中, 各参数取值如式(10):

$$\alpha = 0.7, \beta = 0.25, \gamma = 0.05 \quad (10)$$

目的是优先强化关键结构特征的学习, 同时兼顾梯度对齐精度和基础像素保真度. 这种权重分配特别针对气象预测中降水区边缘等关键结构的精确建模需求, 通过加权机制突出快速变化区域的识别重要性.

2 实验及分析

2.1 数据集

为检验模型在雷达回波外推中的效果及其时序预测适应性, 实验基于两种类型数据展开, 分别是来自深圳雷达站的实测回波数据集和标准动态样本集Moving MNIST.

1) 雷达回波数据集: 深圳雷达站以10 min为时间分辨率采集数据, 其有效探测范围覆盖水平半径350 km、垂直高度100 km的立体空间. 原始雷达基数据在球坐标系(斜距-方位角-仰角)中定位目标, 经坐标插值转换后, 将120 dBZ范围内的回波强度按比例转换为8位灰度像素值(0–255), 最终生成 256×256 像素的灰度图序列. 序列以10帧为单元连续采样, 前5帧作输入, 后5帧作为验证. 训练集整合构造1080帧分段连续的时序数据, 得益于深圳天然的地理优势, 数据集完整涵盖汛期(强对流主导)与非汛期(层状云降雨为主)的差异化回波特征, 并且数据集的强对流为主、非汛期相对较少的分布特点更贴合现实场景和防灾预警的核心需求, 同时季节性特征也有效提升了模型的泛化能力. 测试集则包含90帧独立时段样本, 包含了相同比例的强对流天气和层状云降水天气对应的回波数据.

2) Moving MNIST数据集: 作为经典时序预测基准集, 其包含10000个动态序列样本. 每序列含20帧 64×64 像素图像, 呈现两位手写数字的非规则运动模

式. 其高效批量生成机制支持大规模训练样本供给. 为保障跨模型评估一致性, 实验采用固定训练、测试集.

2.2 实验环境

实验环境采用 Ubuntu 20.04 操作系统, 搭载 Intel Xeon Gold 6330 (2.00 GHz) 处理器及 NVIDIA RTX 3090 (24 GB 显存) 显卡. 开发基于 PyTorch 框架, 选用 Adam 优化器并设定 0.0001 的学习率. 考虑到显存限制与序列数据特性, 雷达回波数据集的训练及验证批次规模均设置为 1, Moving MNIST 数据集配置保持与基线模型一致.

2.3 实验分析

2.3.1 在雷达回波数据集上的实验

针对气象雷达外推任务, 本研究构建横向评测体系以验证模型效能. 参考领域内成熟解决方案框架, 选定 4 种模型进行对比分析: 从卷积长短期记忆网络 ConvLSTM 到升级的多级记忆流 PredRNN-V2, 再到最新的注意力增强架构 SwinLSTM, 包括其基础架构 (SwinLSTM-B) 和增强模型 (SwinLSTM-D).

每个模型各训练 10 000 轮, 单个模型完整训练时间平均约为 10 h, 使用均方误差 (MSE) 和结构相似性

(SSIM) 双指标评估外推性能. MSE 直接量化回波强度误差, 保障物理量预测可靠性; SSIM 则评估回波结构相似性, 反映形态演变保真度, 二者结合可同时保障数值精确性与灾害天气系统的视觉可解释性.

经过实验验证, SwinLSTM-B 模型是目前对该雷达回波数据集预测效果最好的现有模型. 它是 SwinLSTM 的一个子模型, 另外一个子模型 SwinLSTM-D 虽然在 Moving MNIST 的测试中优于前者, 但是在雷达回波外推任务中, 其深层稠密连接具备长程建模能力, 却因复杂的层级堆叠导致对回波噪声过拟合, 造成预测的注意点失焦, 对核心的风暴降水等密集地区的关注度不足导致准确度降低. 因此, 本研究选取 SwinLSTM-B 作为最优对比基准模型.

图 5 展示了测试集中的典型强回波场景, 其主要特征为反射率超过 50 dBZ 的区域高度密集. 此类场景能够有效表征极端天气系统如台风或强风暴等的大尺度回波的演化机制规律. 相较而言, 非汛期可供分析的有效回波数据量仅为汛期风暴数据的一半甚至更低, 其预测结果与基准模型的性能差异较小, 因此, 本研究选择图 5 作为典型案例进行说明.

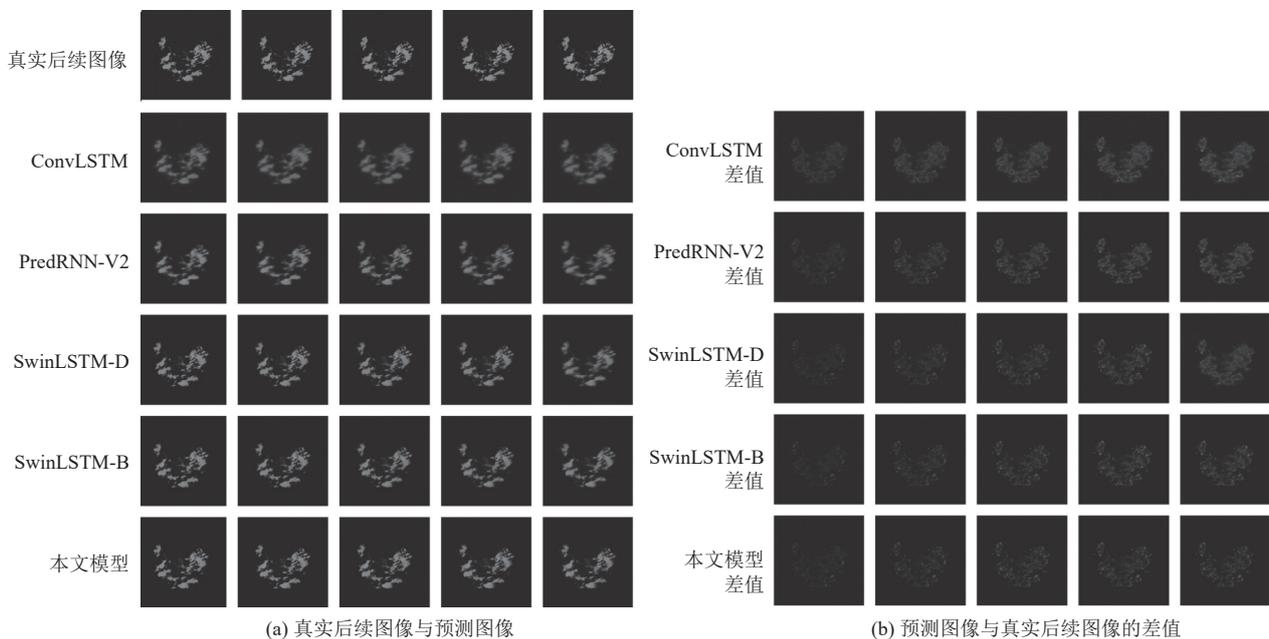


图 5 各模型基于雷达回波数据集的预测结果

由图 5 可知, 本文模型在清晰度上以及差值的准确度效果都优于其他模型, 尤其是在最后两帧的预测效果表现优异, 体现了本文模型优异的长序建模能力. 数据评估方面, 本实验采用对测试集各预测轮次全部

误差指标进行积分累加的统计方法, 更进行预测能力的系统性综合对比. 由表 1 所示, ConvLSTM 受限于局部卷积运算, 难以建模长程时空依赖; PredRNN-V2 虽改进递归结构, 但对回波复杂动态变化的适应性仍

不足,导致二者预测效果最差. SwinLSTM-B 虽通过窗口注意力增强全局建模能力,但其固定的窗口划分限制了跨区域运动交互效率,且未针对时序动态优化门控机制,虽然预测效果有较大提升但是仍然存在不足. 本文模型针对雷达回波预测任务进行优化,相较最优基线模型 (SwinLSTM-B) 参数量小幅增加,在雷达回波数据集上,单轮推理耗时增加 5%,但是均方误差进一步降低约 10.3%,结构相似性提升了 1.4%. 本文表格中加粗字体均表示最优结果.

表 1 基于雷达回波数据集的各模型的预测数据

模型	MSE	SSIM
ConvLSTM	1 221.7	0.798
PredRNN-V2	834.5	0.889
SwinLSTM-D	756.9	0.919
SwinLSTM-B	626.2	0.929
本文模型	561.8	0.942

2.3.2 在 Moving MNIST 数据集上的实验

为了验证模型的时序预测泛化能力,在 Moving MNIST 基准数据集上开展对比实验. 结果如图 6 所示.

实验采用统一设定,所有模型基于相同的 10 000 个固定序列训练,每序列含 20 帧图像数据,前 10 帧作为输入,后 10 帧为模型预测图像,将真实后续图像与预测图像进行比较来量化模型的预测泛化能力. 模型各经 20 000 轮训练,耗时 5-10 h,沿用 MSE 和 SSIM 作为评价指标.

在 Moving MNIST 的时序预测任务中,基础模型 ConvLSTM 的预测误差较大,结构相似度最低,表明其难以捕捉数据的复杂运动规律. PredRNN-V2 通过改进记忆机制实现了重大突破, MSE 降低了 53%, SSIM 提升 26%.

同样使用在雷达回波数据集上展现出明显优势的 SwinLSTM-B 模型在 Moving MNIST 和本模型进行性能对比. 由表 2 可知, SwinLSTM-B 融合 Transformer 模块后,指标是当前已有模型中的最优. 但是本文模型凭借动态建模机制取得全面突破,将 MSE 降至 34.2,较 SwinLSTM-B 再降 14.9%, SSIM 提升至 0.926. 该结果进一步验证了本模型在时序预测任务中的泛化能力.

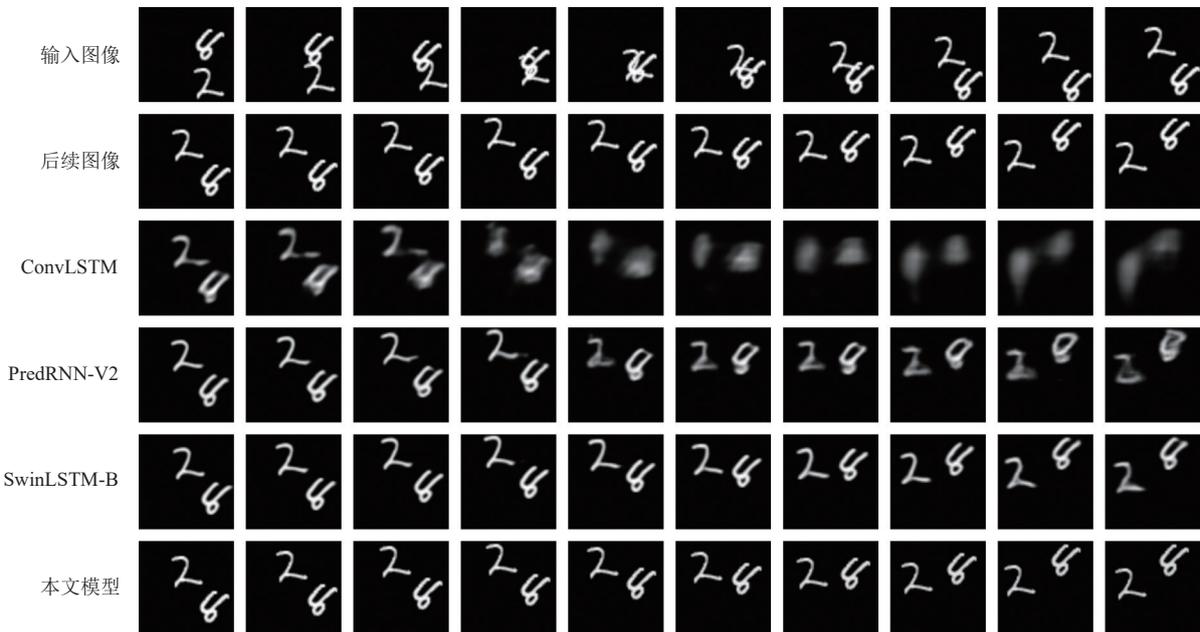


图 6 各模型基于 Moving MNIST 数据集的预测结果

表 2 基于 Moving MNIST 数据集的各模型预测数据

模型	MSE	SSIM
ConvLSTM	103.3	0.707
PredRNN-V2	48.4	0.891
SwinLSTM-B	40.2	0.914
本文模型	34.2	0.926

2.4 消融实验

采用深圳雷达回波实测数据,通过系统性消融实验评估各模块贡献度,验证本文方法的有效性.

2.4.1 动态双缩放窗口注意力模块的消融实验

在保持 6 层记忆增强型滑动窗口模块、自适应残

差门控视窗记忆单元结构以及纯 MSE 损失函数不变的前提下,仅改变模型的窗口注意力缩放级别参数,并与一组基于 Swin-Transformer 基础窗口注意力模块实验数据进行对比.表 3 中缩放 1 对应的对数缩放结合独立温度参数,缩放 2 对应动态位置编码结合可学习的缩放系数,两者的作用分别是增强注意力机制和增强位置编码,因此单独作为一个整体子模块进行消融实验.此外,双缩放组合特指同时应用缩放 1 和缩放 2 来验证协同增强注意力和位置编码对预测能力的影响.

表 3 不同缩放模块组合的消融实验

不同缩放组合	MSE	SSIM
基础窗口注意力	602.6	0.918
缩放1+基础窗口注意力	586.3	0.923
缩放2+基础窗口注意力	582.1	0.926
双缩放+基础窗口注意力	571.8	0.936

由表 3 可知,两种缩放均优于原始窗口注意力.由此得出,注意力增强机制通过自适应调节多尺度特征的权重分布,强化了对雷达回波中局部风暴结构的敏感性;动态位置编码增强机制则提升了空间感知能力,使模型更精准地捕捉多尺度目标的几何演变.两者结合后效果达到最好,结果表明,这两个核心策略针对雷达回波的特点大幅提升了外推效果.

2.4.2 记忆增强型滑动窗口模块的消融实验

实验通过改变模块堆叠层数验证层级式循环记忆增强机制的有效性,其他模块保持不变.由表 4 可知,层级深度显著改善时空建模能力:当层数从 1 增至 6 时, MSE 由 1560.1 大幅降至 571.8, SSIM 从 0.845 跃升至 0.936.这种提升源于窗口会循环提取局部时空特征、关联历史时刻状态依赖,再通过交替式位移与无位移操作,在历史状态融合与当前特征提取间达到最优平衡.进一步分析可知,当层数增至 8 时,验证指标出现回撤,过深的结构导致历史特征过度平滑,削弱了对近期突变状态的敏感性.

表 4 使用不同堆叠层数的滑动窗口的消融实验

层数	MSE	SSIM
1	1560.1	0.845
2	900.6	0.885
4	720.3	0.898
6	571.8	0.936
8	575.8	0.934

2.4.3 自适应残差门控视窗记忆单元的消融实验

其他条件不变,交叉使用基础窗口注意力和双缩

放窗口注意力机制,此处基础窗口注意力和双缩放窗口注意力同表 3.门控系统使用单门控耦合结构,即共享门控信号同时控制输入、遗忘和输出.与自适应残差门控视窗记忆单元进行消融实验.

由表 5 可知,自适应残差门控和原始窗口注意力搭配取得了大幅提升,再结合针对雷达回波设计的双缩放窗口, MSE 降到了最低,这是由于增强门控通过四门解耦、通道注意力与动态遗忘偏置实现了气象特征的长短期精细化调控.

表 5 不同门控组合的消融实验

不同门控组合	MSE	SSIM
单门控+基础窗口注意力	627.1	0.904
单门控+双缩放注意力	611.4	0.909
新门控+基础窗口注意力	602.6	0.918
新门控+双窗口注意力	571.8	0.936

2.4.4 自定义损失函数的消融实验

其他模块保持不变,单独进行损失函数的消融实验.如表 6 所示,将 MSE 作为损失函数的基础锚点.引入多尺度结构注意力损失强化了关键气象结构,预测效果有小幅提升.多尺度梯度一致性损失能够很好地保障回波系统移动的时空连续性,尤其是对最末几帧的预测效果有小幅的提升.三者按照权重进行损失组合,同时结合了对回波关键区域进行精度提升以及提升运动连续性预测, MSE 下降了 1.7%, SSIM 也有部分提升.

表 6 不同损失函数组合的消融实验

不同损失函数组合	MSE	SSIM
MSE	571.8	0.936
MSE+多尺度结构注意力	565.2	0.940
MSE+多尺度梯度一致性	564.5	0.937
3种损失权重组合	561.8	0.942

3 总结

本文针对雷达回波外推中动态特征建模不足、长时序依赖断裂及物理一致性缺失等核心问题,提出融合动态窗口注意力与长短期记忆网络的架构 DMLSTM.通过动态双缩放窗口注意力机制自适应捕捉多尺度回波结构,结合记忆增强型滑动窗口实现跨时刻状态传递以精准刻画气象演化规律;进一步设计自适应残差门控单元优化历史信息保留策略,并改进梯度对齐损失函数强化关键气象结构的物理约束.实验结果表明,

该模型在雷达回波外推任务中显著提升预测精度并验证了其泛化能力,为强对流天气系统的精细化预报提供了有效解决方案。

接下来的研究将向提升雷达回波外推计算效率、长时外推的准确性等方面开展,如进一步将 Vision Mamba Blocks^[32]的线性复杂度优势应用于雷达回波外推任务,以显著提升预测效率并降低计算复杂度;建立多阶段预测模型,第1阶段完成基础序列外推后,第2阶段基于物理约束对结果进行精细化重建,期望实现有效外推时段至少延长至当前模型的2倍,并保持预测精度。

参考文献

- 1 陶天友,邓鹏,王浩,等.基于机器学习的极端风场短时预测研究进展与思考.空气动力学学报,2025,43(5):78-91. [doi: 10.7638/kqdlxxb-2025.0041]
- 2 罗健文,邹茂扬,杨昊,等.面向降雨预报的雷达回波预测序列外推方法.计算机应用研究,2024,41(4):1138-1142. [doi: 10.19734/j.issn.1001-3695.2023.07.0377]
- 3 Zou HB, Wu SS, Shan JS, *et al.* A method of radar echo extrapolation based on TREC and Barnes filter. Journal of Atmospheric and Oceanic Technology, 2019, 36(9): 1713-1727. [doi: 10.1175/JTECH-D-18-0194.1]
- 4 Chung KS, Yao IA. Improving radar echo Lagrangian extrapolation nowcasting by blending numerical model wind information: Statistical performance of 16 typhoon cases. Monthly Weather Review, 2020, 148(3): 1099-1120. [doi: 10.1175/MWR-D-19-0193.1]
- 5 Ayzel G, Heistermann M, Winterrath T. Optical flow models as an open benchmark for radar-based precipitation nowcasting (rainymotion v0.1). Geoscientific Model Development, 2019, 12(4): 1387-1402. [doi: 10.5194/gmd-12-1387-2019]
- 6 吴其亮,王兴,苗子书,等.基于特征条件扩散模型的雷达回波外推算法.科学技术与工程,2024,24(22):9498-9509. [doi: 10.12404/j.issn.1671-1815.2306011]
- 7 方巍,庞林,张飞鸿,等.对抗型长短期记忆网络的雷达回波外推算法.中国图象图形学报,2021,26(5):1067-1080. [doi: 10.11834/jig.200316]
- 8 张文鹏,黎湘,刘永祥.雷达目标微动表征、估计与识别研究.中国科学:信息科学,2023,53(8):1469-1489. [doi: 10.1360/SSI-2023-0040]
- 9 He W, Xiong TS, Wang H, *et al.* Radar echo spatiotemporal sequence prediction using an improved ConvGRU deep learning model. Atmosphere, 2022, 13(1): 88. [doi: 10.3390/atmos13010088]
- 10 程勇,钱坤,康志明,等.一种雷达回波外推的注意力融合和信息回忆的LSTM方法.热带气象学报,2023,39(5):653-663. [doi: 10.16032/j.issn.1004-4965.2023.057]
- 11 Luo CY, Li XT, Ye YM. PFST-LSTM: A spatiotemporal LSTM model with pseudoflow prediction for precipitation nowcasting. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 843-857. [doi: 10.1109/JSTARS.2020.3040648]
- 12 宋毅,张晗奕,孙丰,等.PPNet:基于预先预测的降雨短时预测模型.电子与信息学报,2024,46(2):492-502. [doi: 10.11999/JEIT230547]
- 13 胡强,高雅婷,尹宾礼,等.MDA-MIM:一种融合多尺度特征与双重注意力机制的雷达回波图预测模型.通信学报,2025,46(3):248-257. [doi: 10.11959/j.issn.1000-436x.2025053]
- 14 许梦,杜景林,刘蕊.S-UNet:基于U-Net和LSTM的短临降水预报网络.计算机系统应用,2024,33(11):48-57. [doi: 10.15888/j.cnki.csa.009683]
- 15 Tamaru R, Siritanawan P, Kotani K. Interaction aware relational representations for video prediction. Proceeding of the 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Melbourne: IEEE, 2021. 2089-2094. [doi: 10.1109/SMC52423.2021.9658846]
- 16 莫晨,邵洁.基于自注意力的多模态LSTM的动作预测.计算机工程与设计,2022,43(4):1083-1088. [doi: 10.16208/j.issn1000-7024.2022.04.025]
- 17 张汉琦,黄聪宇,王晶,等.基于注意力机制的多用户全景视频视口预测.信号处理,2025,41(2):302-311. [doi: 10.12466/xhcl.2025.02.009]
- 18 Yin XY, Wu GZ, Wei JZ, *et al.* Deep learning on traffic prediction: Methods, analysis, and future directions. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(6): 4927-4943. [doi: 10.1109/TITS.2021.3054840]
- 19 邴其春,赵盼盼,任参政,等.基于时序数据分解重构的短时交通流预测方法.交通信息与安全,2024,42(6):112-122. [doi: 10.3963/j.jssn.1674-4861.2024.06.012]
- 20 杨永鹏,杨震,杨真真.基于时序分解和注意力图神经网络的交通预测.数据采集与处理,2025,40(2):417-430. [doi: 10.16337/j.1004-9037.2025.02.011]
- 21 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.气象学报,2021,79(5):817-827. [doi: 10.11676/qxxb2021.041]
- 22 渠海峰,何光鑫,康志明,等.CAST-LSTM:一种用于雷达回波外推的时空LSTM模型.气象,2023,49(12):1481-1494 [doi: 10.7519/j.issn.1000-0526.2023.083101]

- 23 Shi XJ, Chen ZR, Wang H, *et al.* Convolutional LSTM network: A machine learning approach for precipitation nowcasting. Proceedings of the 29th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2015. 802–810.
- 24 Wang YB, Gao ZF, Long MS, *et al.* PredRNN++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning. Proceedings of the 35th International Conference on Machine Learning. Stockholm: PMLR, 2018. 5123–5132.
- 25 Wang YB, Wu HX, Zhang JJ, *et al.* PredRNN: A recurrent neural network for spatiotemporal predictive learning. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(2): 2208–2225. [doi: [10.1109/TPAMI.2022.3165153](https://doi.org/10.1109/TPAMI.2022.3165153)]
- 26 Wang YB, Zhang JJ, Zhu HY, *et al.* Memory in memory: A predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics. Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 9154–9162.
- 27 魏敏, 姚鑫. 基于多尺度与注意力机制的两阶段风暴单体外推研究. 图学学报, 2024, 45(4): 696–704. [doi: [10.11996/JG.j.2095-302X.2024040696](https://doi.org/10.11996/JG.j.2095-302X.2024040696)]
- 28 Wang YB, Jiang L, Yang MH, *et al.* Eidetic 3D LSTM: A model for video prediction and beyond. Proceedings of the 7th International Conference on Learning Representations. New Orleans: OpenReview.net, 2019
- 29 Tan C, Gao ZY, Wu LR, *et al.* Temporal attention unit: Towards efficient spatiotemporal predictive learning. Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023. 18770–18782. [doi: [10.1109/CVPR52729.2023.01800](https://doi.org/10.1109/CVPR52729.2023.01800)]
- 30 Tang S, Li C, Zhang P, *et al.* SwinLSTM: Improving spatiotemporal prediction accuracy using swin Transformer and LSTM. Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2023. 13470–13479. [doi: [10.1109/ICCV51070.2023.01239](https://doi.org/10.1109/ICCV51070.2023.01239)]
- 31 Liu Z, Lin YT, Cao Y, *et al.* Swin Transformer: Hierarchical vision Transformer using shifted windows. Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021. 10012–10022. [doi: [10.1109/ICCV48922.2021.00986](https://doi.org/10.1109/ICCV48922.2021.00986)]
- 32 Tang YJ, Dong PJ, Tang ZH, *et al.* VMRNN: Integrating vision Mamba and LSTM for efficient and accurate spatiotemporal forecasting. Proceedings of the 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle: IEEE, 2024. 5663–567. [doi: [10.1109/CVPRW63382.2024.00575](https://doi.org/10.1109/CVPRW63382.2024.00575)]

(校对责编: 李慧鑫)