

DOI:10.19322/j.cnki.issn.1006-4710.2023.04.009

<https://xuebao.xaut.edu.cn>

引文格式:张晓晖,白文奇,杨松楠,王晓娟. 基于差分 Causal LSTM 模型的气象图像短时预测研究[J]. 西安理工大学学报, 2023,39(4):529-535.

ZHANG Xiaohui, BAI Wenqi, YANG Songnan, WANG Xiaojuan. Research on short-time prediction of meteorological images based on differential-Causal LSTM Model[J]. Journal of Xi'an University of Technology, 2023,39(4): 529-535.

# 基于差分 Causal LSTM 模型的气象 图像短时预测研究

张晓晖, 白文奇, 杨松楠, 王晓娟

(西安理工大学 自动化与信息工程学院, 陕西 西安 710048)

**摘要:** 为解决气象图像序列在短时预测时预测精度低的问题,利用一种具有级联记忆单元的 Causal LSTM,将图像梯度差分惩罚因子引入训练过程,来提高预测模型对短序列动态和突变的建模能力,提出了差分 Causal LSTM 模型。研究首先通过循环神经网络建立气象图像短时预测模型,然后分析了 ConvLSTM 模型对气象雷达回波图与卫星云图序列的预测效果,对于 ConvLSTM 模型预测气象图像存在严重模糊的问题,使用差分 Causal LSTM 模型进行优化,结果表明改进的模型能够有效改善模糊,提升预测结果的准确性。改进后的差分 Causal LSTM 模型在 HKO-7 数据集的测试样本中,关键成功指数(CSI)提高了 0.019,在气象云图数据集中提高了 0.078,模糊程度有所减弱。

**关键词:** ConvLSTM; Causal LSTM; 端到端模型; 图像梯度差分损失

**中图分类号:** P456.1      **文献标志码:** A      **文章编号:** 1006-4710(2023)04-0529-07

## Research on short-time prediction of meteorological images based on differential-Causal LSTM Model

ZHANG Xiaohui, BAI Wenqi, YANG Songnan, WANG Xiaojuan

(Faculty of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China)

**Abstract:** Due to the low accuracy of meteorological image sequences' short-term prediction, we propose a differential-Causal LSTM model by using Causal LSTM with cascaded memory units, which is an introduction to the image gradient difference penalty term into the training process to improve the prediction model's ability to capture the dynamics and abrupt changes of short-time sequences. We first establish the meteorological image short-time prediction model by the recurrent neural network and then analyze the prediction effect by the ConvLSTM model on weather radar echogram and satellite cloud sequences. The results show that the improved model in this paper can effectively reduce the blurring and improve the accuracy of prediction results. The differential-Causal LSTM model improves the critical success index (CSI) by 0.019 in the HKO-7 dataset, CSI also improved by 0.078 in the meteorological cloud image dataset, and the blurring is reduced.

**Key words:** ConvLSTM; Causal LSTM; end-to-end module; gradient difference loss

收稿日期: 2022-08-07; 网络首发日期: 2022-10-10

网络首发地址: <http://kns.cnki.net/kcms/detail/61.1294.N.20221009.1728.002.html>

基金项目: 陕西省自然科学基金基础研究计划资助项目(2021JLM-58)

第一作者: 张晓晖,男,博士,教授,研究方向为智能信息系统及检测与自动化装置。E-mail: xhzhang@xaut.edu.cn

通信作者: 白文奇,男,博士生,研究方向为机器学习与人工智能。E-mail: bayouenyq@outlook.com

气象预报主要利用当前与较早前气象数据与资料,实现对降雨量、气温、气压、风力等气象条件的预测,其在农业、文旅、交通、采矿和电力等行业中发挥了极其重要的作用。伴随大数据时代的到来,气象观测数据量迎来爆炸式的增长,如何利用海量的数据挖掘有效的气象信息,实现对气象条件的准确估计和预测<sup>[1]</sup>仍有待于进一步的研究。得益于人工智能的发展,学者们寻求利用人工智能算法分析气象数据,为天气的预报提供依据,人工智能模型相较于传统的物理模型,无需考虑复杂的大气现象及物理变化,提高了气象数据的利用效率。

由 Anh 等<sup>[2]</sup>提出了一种基于小波变换和人工神经网络的改进降雨预测模型,分析了研究月降水量的方法。Chandra 等<sup>[3]</sup>提出了建立 CNN、RNN-LSTM 和双向 LSTM 的集成模型来预测印度钦奈地区的每日降雨量数据。杨芮等<sup>[4]</sup>提出了使用集合经验模态分解算法和门控循环单元两种方法相结合的组合模型对风速进行预测。Krivec 等<sup>[5]</sup>提出了一种基于高斯过程(GPs)的动态的、概率的、非参数化的模型用于低层大气动力学建模,能够实现天气变量的短期和长期预测。Guo 等<sup>[6]</sup>提出将主成分分析(PCA)与 ARMA 结合来实现长期天气的预测。Nandi 等<sup>[7]</sup>提出了一种基于注意力的模型 ALTF Net 解决循环神经网络在气温的长期预测问题中出现的梯度爆炸与梯度消失问题。Lee 等<sup>[8]</sup>将多层感知器、循环和卷积神经网络用于日平均、最低和最高温度预测,并评估了它们对温度预测性能的影响。Kuang 等<sup>[9]</sup>提出了一种新的网络模型 MetPGNet 用于气温预测,通过多维注意力分支的设计,提高了时空学习任务中模型对流体元素产生和分散特征的捕捉能力。

以上实现天气预测的模型方法总体上分为三类:物理模型<sup>[5]</sup>、统计学模型<sup>[10]</sup>和人工智能模型<sup>[11]</sup>,其中物理模型是应用物理量和物理规则来模拟大气动力学环境,并完成天气状况估计,模型求解过程通常复杂,严重依赖计算资源。统计学模型只适合处理线性平稳数据,而人工智能模型往往能够在非线性、非平稳的数据集中表现更好。气象观测资料来源于地面气象观测、高空气象观测、大气遥感探测、气象卫星探测等观测过程,其中存在着大量的图像观测数据。对于真实的大气系统,制约其的外部条件时刻发生着复杂的变化,大气基本状态随时间的改变导致大气过程平稳性的改变,因而大气系统的动力学本质是非平稳的<sup>[12]</sup>。大气系统的这种非平稳性直观反映在各种气象观测图像资料中,以气象

雷达回波图像为例,图像序列中存在空间相关性、局部像素值的空间依赖性等低阶非平稳因素和雷达回波的积累、变形、消散等高阶非平稳因素<sup>[13]</sup>。

传统模型难以实现对图像序列的有效预测,而在深度学习领域,以长短期记忆(LSTM)和门循环单元(GRU)为代表的循环神经网络在处理非平稳序列预测问题中已经取得了令人满意的结果。ConvLSTM 通过将 LSTM 的全连接层替换为卷积层,从而获得了对空间特征的提取能力,其已被广泛应用于各种时空序列预测任务中,但在实际任务中,模型预测产生的图像序列往往带有严重模糊。研究利用一种具有级联记忆单元的 Causal LSTM,并且在训练过程中引入图像梯度差分惩罚项,提出了差分 Causal LSTM 模型。通过在两个数据集上的测试,验证了改进后的差分 Causal LSTM 模型的有效性。

## 1 问题描述

气象图像的短时预测能够被视为一种具有高阶非平稳特征的时空序列预测问题,循环卷积神经网络在其中被广泛应用。将已经观测到的气象图像序列作为模型输入,训练端到端的神经网络,从而实现对未来短时图像序列的预测。

将  $t$  时刻下的某一种大小为  $M \times N$  且具有  $P$  个通道数的气象图像矩阵记为  $X_t$ ,训练模型利用截止  $t$  时刻前已获取的  $J$  帧图像  $X_{t-J+1}, X_{t-J+2}, \dots, X_t$ , 预测出之后  $K$  帧图像  $\tilde{X}_{t+1}, \dots, \tilde{X}_{t+K}$ , 使预测的图像尽可能地接近真实获取的图像  $X_{t+1}, \dots, X_{t+K}$  :

$$\tilde{X}_{t+1}, \dots, \tilde{X}_{t+K} = \underset{X_{t+1}, \dots, X_{t+K}}{\operatorname{argmax}} p(X_{t+1}, \dots, X_{t+K} | X_{t-J+1}, X_{t-J+2}, \dots, X_t) \quad (1)$$

构建端到端的预测网络时使用的编码器-解码器结构<sup>[16]</sup>见图 1。

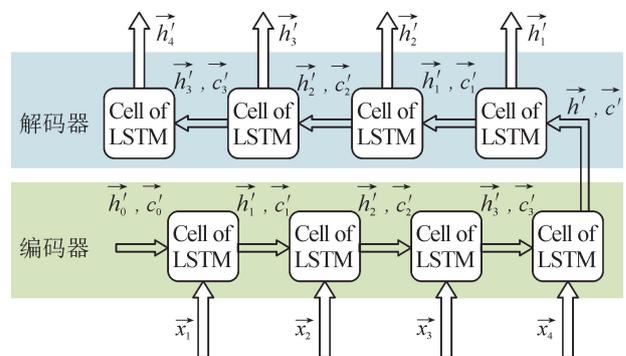


图 1 编码器-解码器结构图

Fig. 1 Encoder-decoder structure diagram

其中,由编码器网络对输入图像序列进行特征提取,编码器网络在完成对输入的最后一帧图像序列的编码后,将隐状态与输出矩阵传递到解码器网络中,由解码器网络实现对未来几帧图像的预测。

多层网络能够在不同的视野范围下对图像的特征进行提取,由于模型的输入与输出为相同维度的

气象图像,因而本研究将各层网络的输出特征图通过一层卷积核大小为  $1 \times 1$  的卷积层进行特征图的融合得到最终的输出图像。同一般的卷积神经网络类似,循环卷积神经网络同样能够通过层叠式的结构设计,提升网络的特征提取能力,将多层神经网络进行堆叠,结构见图 2。

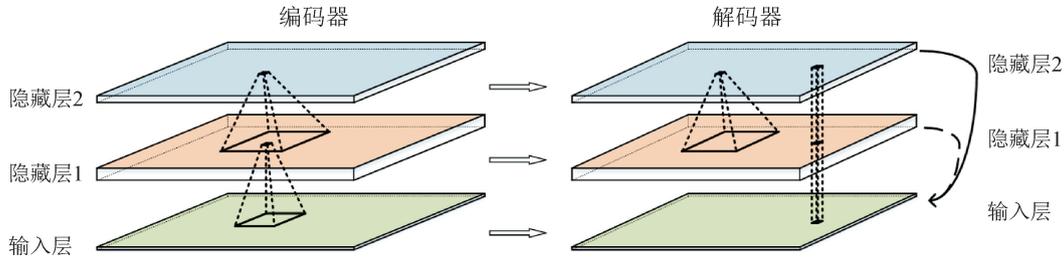


图 2 多层网络结构示意图

Fig. 2 Diagram of multi-layer network structure

## 2 模型构建

### 2.1 ConvLSTM 网络模型

长短期记忆网络 (LSTM)<sup>[17]</sup> 最早于 1997 年提出,相较于标准前馈神经网络,其具有的反馈连接在输入序列的时序上建立了关联,因而被广泛应用于各类时序问题的处理,图 3 为 LSTM 的细胞结构图。

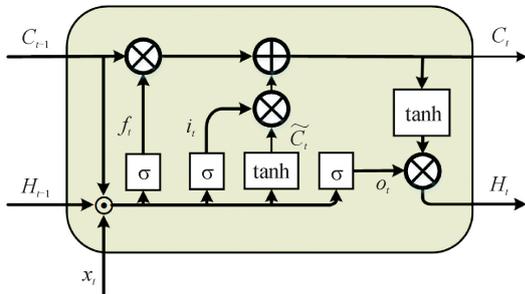


图 3 LSTM 的细胞结构图

Fig. 3 Cell structure of LSTM

图 3 中  $f$ 、 $i$ 、 $o$ 、 $\tilde{C}$  分别表示 LSTM 的遗忘门、输入门、输出门结构以及一个中间隐层,LSTM 的细胞在每一时刻输入上一时刻的细胞状态和隐层状态  $C_{t-1}$  和  $H_{t-1}$  以及输入状态  $x_t$ , 首先对上一时刻的隐层状态  $H_{t-1}$ 、细胞状态  $C_{t-1}$  和输入状态  $x_t$  进行拼接,将拼接结果分别通过  $i$ 、 $o$ 、 $f$  和  $\tilde{C}$  所对应的四个全连接层以及激活函数,之后由  $i$ 、 $f$  的输出结果分别与上一时刻的细胞状态  $C_{t-1}$  和中间隐层状态  $\tilde{C}_t$  作 Hadamard 积,完成细胞状态  $C_t$  的更新,最后将该状态经过双曲正切激活函数,并与  $o_t$  作 Hadamard 积,获得当前时刻的隐层状态  $H_t$ , 该状态同

时作为 LSTM 模型当前时刻的输出状态,计算过程如下:

$$i_t = \sigma(W_{xi} \circ x_t + W_{hi} \circ H_{t-1} + W_{ci} \circ C_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(W_{xf} \circ x_t + W_{hf} \circ H_{t-1} + W_{cf} \circ C_{t-1} + b_f) \quad (3)$$

$$\tilde{C}_t = \tanh(W_{xc} \circ x_t + W_{hc} \circ H_{t-1} + W_{cc} \circ C_{t-1} + b_c) \quad (4)$$

$$o_t = \sigma(W_{xo} \circ x_t + W_{ho} \circ H_{t-1} + W_{co} \circ C_{t-1} + b_o) \quad (5)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tilde{C}_t \quad (6)$$

$$H_t = o_t \circ \tanh(C_t) \quad (7)$$

ConvLSTM 用卷积层替换了 LSTM 中的全连接层,ConvLSTM 的计算过程如下:

$$i_t = \sigma(W_{xi} * x_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i) \quad (8)$$

$$f_t = \sigma(W_{xf} * x_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f) \quad (9)$$

$$\tilde{C}_t = \tanh(W_{xc} * x_t + W_{hc} * H_{t-1} + W_{cc} \circ C_{t-1} + b_c) \quad (10)$$

$$o_t = \sigma(W_{xo} * x_t + W_{ho} * H_{t-1} + W_{co} \circ C_{t-1} + b_o) \quad (11)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tilde{C}_t \quad (12)$$

$$H_t = o_t \circ \tanh(C_t) \quad (13)$$

相较于 LSTM 模型,ConvLSTM 重新通过卷积层实现四个门控结构,这样的结构设计赋予了模型捕捉像素点运动规律的能力,较大的卷积核具有较大的感受野范围,用于捕捉具备较快运动速度的目标特征,而较小的卷积核捕捉具备较慢运动速度

的目标特征。

### 2.2 Causal LSTM 网络模型

相较于 ConvLSTM, Causal LSTM<sup>[18]</sup> 是一种更为复杂的模型, 其大大增加了结构深度, 提高了模型学习时空动态变化特征的能力, Causal LSTM 的结构见图 4。

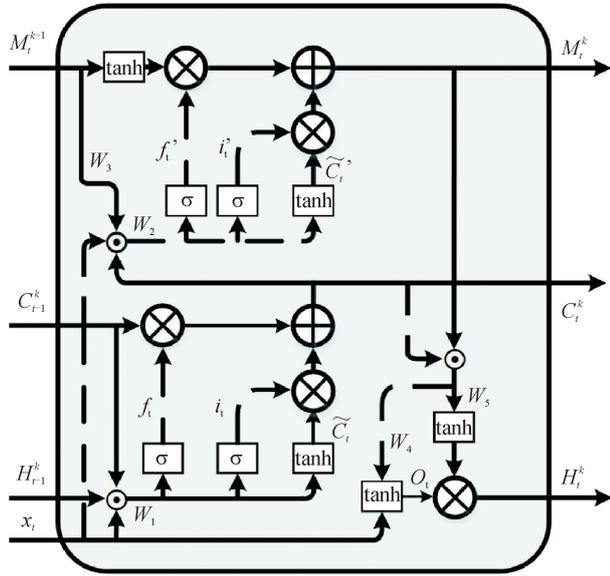


图 4 Causal LSTM 的细胞结构  
Fig. 4 Cell structure of Causal LSTM

Causal LSTM 采用一种级联结构, 在原先的隐层状态  $H$  与通过时间域进行传播的细胞状态  $C$  的基础之上, 增加了一个在不同网络层之间进行传播的空间状态  $M$ , 过程表示如下:

$$\begin{pmatrix} \tilde{C}_t \\ i_t \\ f_t \end{pmatrix} = \begin{pmatrix} \tanh \\ \sigma \\ \sigma \end{pmatrix} W_1 * [x_t, H_{t-1}^k, C_{t-1}^k] \quad (14)$$

$$C_t^k = f_t \circ C_{t-1}^k + i_t \circ \tilde{C}_t \quad (15)$$

$$\begin{pmatrix} \tilde{C}'_t \\ i'_t \\ f'_t \end{pmatrix} = \begin{pmatrix} \tanh \\ \sigma \\ \sigma \end{pmatrix} W_2 * [x_t, C_t^k, M_{t-1}^k] \quad (16)$$

$$M_t^k = f'_t \circ \tanh(W_3 * M_{t-1}^k) + i'_t \circ \tilde{C}'_t \quad (17)$$

$$o_t = \tanh(W_4 * [C_t^k, M_t^k]) \quad (18)$$

$$H_t^k = o_t \circ \tanh(W_5 * [C_t^k, M_t^k]) \quad (19)$$

不同于 ConvLSTM 中原本存在的细胞状态  $C$  (时间状态) 的信息流向为同层网络的下一个时间节点, 空间状态  $M$  在不同层网络之间进行空间传递, 如果当前已经到达最后一层网络, 则空间状态  $M$  返回至第一层网络并向下一时间节点传递, 在一个三层结构的 Causal LSTM 模型中, 状态矩阵的传递过程见图 5。

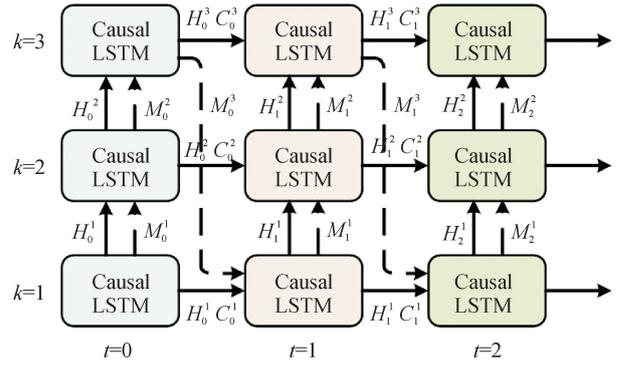


图 5 三层网络结构示意图  
Fig. 5 Diagram of three-layer network structure

图 5 中 Causal LSTM 模型细胞间的黑色连接线表示 ConvLSTM 中本身存在的沿时间方向传递的细胞状态  $C$  与隐层状态  $H$ , 灰色线表示新增加的空间状态  $M$ , 通过空间状态的补充, 底层网络能够获取高层网络对特征图像的高级别抽象结果<sup>[19]</sup>, 增加了多层网络的信息利用效率。

### 2.3 图像梯度差分损失 (GDL)

为了降低以均方误差作为损失函数导致的预测结果的模糊, 研究将图像梯度差分损失<sup>[20]</sup> (gradient difference loss, GDL) 引入训练过程当中, GDL 的定义为:

$$L_{\text{gdl}}(\hat{X}, X) = \sum_{i,j} ||X_{i,j} - X_{i-1,j}| - |\hat{X}_{i,j} - \hat{X}_{i-1,j}||^\alpha + \quad (20)$$

$$||X_{i,j-1} - X_{i,j}| - |\hat{X}_{i,j-1} - \hat{X}_{i,j}||^\alpha$$

最终的损失函数是:

$$L_{\text{img}} = L_p(x_{t+k}, \hat{x}_{t+k}) + L_{\text{gdl}}(x_{t+k}, \hat{x}_{t+k}) \quad (21)$$

式中:  $L_p$  为均方误差;  $L_{\text{gdl}}$  为图像梯度误差。在该组合当中,  $L_p$  约束预测序列像素灰度值的均值接近于真实序列,  $L_{\text{gdl}}$  约束预测序列像素灰度值与邻近像素之间的差值接近于真实序列像素灰度值与邻近像素之差, 通过两种损失函数的结合, 有利于降低预测序列的模糊程度。

## 3 实例分析

### 3.1 卫星云图数据集

卫星云图用于捕获大范围的云运动, 云图观测与降水具有相关性且其空间观测范围大, 通过对气象云图的预测, 能够获得未来短时云的分布与覆盖范围, 进而对降水预报提供依据。

本研究通过国家气象科学数据中心收集了风云 2C 大气静止卫星红外波段的中国大陆地区云图, 时

间范围为 2005 年 5 月 30 日至 2009 年 6 月 17 日,选取卫星云图并以陕西省为主要范围的地区作为目标区域对原图像进行裁剪,对裁剪后的卫星云图进行归一化处理,采用半径为 10 的卷积核进行圆形均值滤波,使用像素面积关系进行重采样,采样后的卫星云图长宽均为 100,最后为去除图像当中的噪声信息,采用 NL-means 滤波,取过滤器强度为 10,得到最终的卫星云图。

选取时间相邻的卫星云图,组成长度固定的图像序列构建数据集。图像序列长度为 24,相邻序列的时间间隔为 1 小时,允许时间间隔误差小于 3 分钟,最终整理出的数据集包含 23 923 个长度为 24 帧的序列。按照 5 : 1 将数据划分为训练集与测试集,在显卡型号 GeForce RTX 2080Ti,内存大小 11G 的 GPU 服务器上进行模型训练,模型输入序列的前 12 帧图像,用以对之后的 12 帧图像进行预测。改进前的模型以均方误差作为损失函数,改进后以混合误差作为损失函数,三层网络卷积核数分别为 64,64,16,卷积核尺度全部为 3 \* 3,优化器为 Adam,batch 设定为 2,训练次数为 50 000 次,图 6 为各个模型对一随机选取的测试序列的预测图像对比结果。

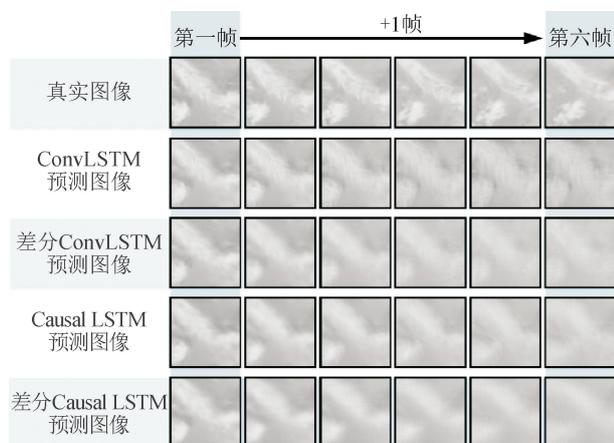


图 6 各个模型在气象云图中的预测结果  
Fig. 6 Prediction of each model in the meteorological cloud images

利用阈值分割标记出预测图像序列与真实图像序列的前景与背景,采用深度学习领域常用评价指标 CSI(关键成功指数)和 FAR(误报率)对结果进行评价,评价指标的计算公式为:

$$C = \frac{h}{h + m + f} \quad (22)$$

$$F = \frac{f}{h + f} \quad (23)$$

式中:真实与预测的图像中对应位置像素均为前景

时标记为 hit,总数为  $h$ ;真实图像为前景,而预测图像中对应像素为背景时标记为 miss,总数为  $m$ ;真实图像为背景,而预测图像中对应像素为前景时标记为 falsealarm,总数为  $f$ 。通过对图像矩阵的遍历计算出 CSI 与 FAR,计算测试集的平均 CSI 与 FAR,结果见表 1。

表 1 各个模型在气象云图中的预测指标  
Tab. 1 Prediction index of each model in the meteorological cloud images

模型	ConvLSTM	差分 ConvLSTM	Causal LSTM	差分 Causal LSTM
CSI	0.811	0.876	0.871	0.889
FAR	0.113	0.113	0.102	0.096

由结果可知,模型从 ConvLSTM 到 Causal LSTM 的变化极大地增加了预测结果的准确性,改进模型的预测效果普遍好于原始模型,反映在 CSI 的提升与 FAR 的降低,值得注意的是,利用图像梯度差分损失进行模型的改进对于其中较为简单的模型 ConvLSTM 提升较大,通过对改进前的 ConvLSTM 模型预测序列的观察,随着序列越向后,模糊现象越明显,而改进后的差分 ConvLSTM 模型在图像序列的末尾三帧对模糊的抑制尤其显著。

### 3.2 HKO-7 数据集

HKO-7 数据集<sup>[21]</sup>是一个由雷达回波数据构成的数据集,雷达回波数据主要是通过天气雷达往四周发射电磁波并通过云层的反射得到,国内所用的多为多普勒雷达。HKO-7 数据集来源于香港天文台,覆盖了香港周边的雷达回波数据,数据集中图像为灰度图,每间隔 12 分钟收集一张,涵盖了从 2009 年到 2015 年下雨天的数据。本研究中以 2009 年到 2014 年的数据作为训练集,2015 年的数据用作测试,剔除其中不连续的部分,每次从随机位置开始,抽取连续的 24 张雷达回波数据,以前 12 张图像作为输入用以预测后 12 张图像。

模型在同一服务器上进行模型训练,三层网络的卷积核数分别为 64,64,16,卷积核尺度全部为 3 \* 3,优化器为 Adam,batch 设定为 2,训练次数为 50 000 次。结果见图 7。仍然选取 CSI 和 FAR 作为评价指标,结果见表 2。

测试结果表明,本研究在 ConvLSTM 模型下的改进对 CSI 与 FAR 的影响较小,改进前的 Causal LSTM 模型对雷达回波图的预测结果与实际结果相差较大,改进后的差分 Causal LSTM 模型预测效果明显好于改进前。总体上,通过对 ConvLSTM 模

型与 Causal LSTM 模型引入差分梯度损失,均增强了预测的图像序列边界轮廓的清晰度,降低了预测序列的模糊程度。

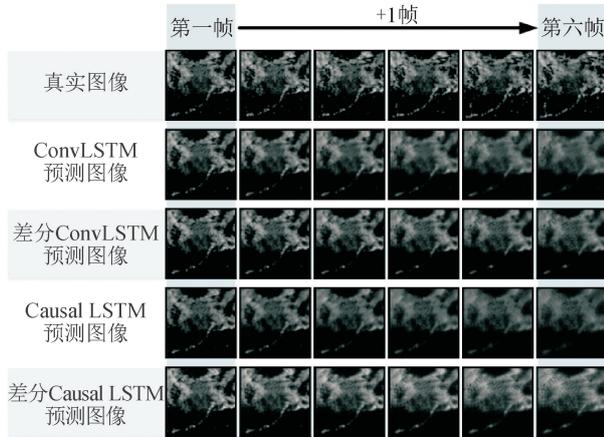


图 7 各个模型在 HKO-7 数据集上的预测结果

Fig. 7 Prediction of each model in the HKO-7 dataset

表 2 各个模型在 HKO-7 数据集上的预测指标

Tab. 2 Prediction index of each model in the HKO-7 dataset

模型	ConvLSTM	差分 ConvLSTM	Causal LSTM	差分 Causal LSTM
CSI	0.666	0.670	0.589	0.685
FAR	0.178	0.179	0.144	0.240

## 4 结 论

本研究以端到端的循环卷积神经网络模型实现了对气象图像序列的短时预测,针对 ConvLSTM 模型对图像运动特征捕捉能力的不足以及预测图像序列出现的模糊现象,一方面通过具有更多线性过程的 Causal LSTM 模型提高建模能力,另一方面在训练过程中引入图像梯度差分项。在具有等间隔采样的卫星气象云图与雷达回波图序列上进行训练与测试,以 CSI 和 FAR 作为评价指标。通过对比改进前后的效果,未引入图像梯度差分项的情况下, Causal LSTM 模型相较于 ConvLSTM 模型在气象云图数据中取得了更好的效果,CSI 提高了 0.06,但在雷达回波图数据中,ConvLSTM 模型效果更好,而引入梯度差分项之后,差分模型相较于原始模型在气象云图数据和雷达回波图数据中的预测效果均有所提升,差分 Causal LSTM 在两个数据集的测试中均取得了最好的效果,对比 ConvLSTM 模型,CSI 在气象云图数据集中提高了 0.078, FAR 降低了 0.017,而在雷达回波图数据集中,CSI 提高了 0.019,但 FAR 同时也有所上升。考虑到大气运动的突变性与复杂性,本研究的改进尚难以应对由于

运动的突变导致误差在序列间的不断累积,最终在后续图像帧的预测结果中出现较大程度的偏移现象,这将作为后续对模型进行改进的重点。

## 参考文献:

- [1] 杨函. 基于深度学习的气象预测研究[D]. 哈尔滨:哈尔滨工业大学, 2017.  
YAN Han. Research on weather forecasting based on deep learning[D]. Harbin: Harbin Institute of Technology, 2017.
- [2] ANH D T, DANG T D, VAN S P. Improved rainfall prediction using combined pre-processing methods and feed-forward neural networks [J]. J, 2019, 2(1): 65-83.
- [3] CHANDRA M V, CHITRA P, HARIHARA S M, et al. A deep learning ensemble model for short-term rainfall prediction[C]//2022 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET). IEEE, 2022: 135-138.
- [4] 杨芮, 徐虹, 文武. 基于 EEMD-GRU 网络模型的短期风速预测[J]. 计算机系统应用, 2022, 31(6): 231-237.  
YANG Rui, XU Hong, WEN Wu. Short-term wind speed prediction based on EEMD-GRU network model [J]. Computer Systems & Applications, 2022, 31(6): 231-237.
- [5] KRIVEC T, KOCIJAN J, PERNE M, et al. Data-driven method for the improving forecasts of local weather dynamics[J]. Engineering Applications of Artificial Intelligence, 2021, 105: 104423.
- [6] GUO Shudong, QIAO Weisong, CHEN Binbin, et al. Prediction and abnormality analysis of climate change based on PCA-ARMA and PCC[C]//2020 IEEE International Conference on Networking, Sensing and Control (ICNSC). IEEE, 2020.
- [7] NANDI A, DE A, MALLICK A, et al. Attention based long-term air temperature forecasting network: ALTF Net [J]. Knowledge-Based Systems, 2022, 252: 109442.
- [8] LEE S, LEE Y-S, SON Y. Forecasting daily temperatures with different time interval data using deep neural networks [J]. Applied Sciences, 2020, 10(5): 1609.
- [9] KUANG Qiuming, YU Tingzhao. MetPGNet: meteorological prior guided network for temperature forecasting[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1004305.
- [10] HUFFMAN G J, BOLVIN D T, NELKIN E J, et al. The TRMM multisatellite precipitation analysis (TM-

- PA): quasi-global, multiyear, combined-sensor precipitation estimates at fine scales [J]. *Journal of hydrometeorology*, 2007, 8(1): 38-55.
- [11] HAN Lei, LIANG He, CHEN Haonan, et al. Convective precipitation nowcasting using U-Net model [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 4103508.
- [12] 杨培才, 周秀骥. 气候系统的非平稳行为和预测理论 [J]. *气象学报*, 2005, 63(5): 556-570.  
YANG Peiai, ZHOU Xiuji. On nonstationary behaviors and prediction theory of climate systems [J]. *Acta Meteorologica Sinica*, 2005, 63(5): 556-570.
- [13] WANG Yunbo, ZHANG Jianjin, ZHU Hongyu, et al. Memory in memory: a predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2019.
- [14] 冉茂亮, 陈彦如, 杨新彪. 基于 EEMD-LMD-LSTM-LEC 深度学习模型的短时物流需求预测 [J]. *控制与决策*, 2022, 37(10): 2513-2523.  
RAN Maoliang, CHEN Yanru, YANG Xinbiao. Short-term logistics demand forecasting based on EEMD-LMD-LSTMLEC deep learning model [J]. *Control and Decision*, 2021, 37(10): 2513-2523.
- [15] TIWARI S K, KUMARASWAMIDHAS L A, GAUTAM C, et al. An auto-encoder based LSTM model for prediction of ambient noise levels [J]. *Applied Acoustics*, 2022, 195: 108849.
- [16] SRIVASTAVA N, MANSIMOV E, SALAKHUDINOV R. Unsupervised learning of video representations using lstms [C]//International Conference on Machine Learning. PMLR, 2015: 843-852.
- [17] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [18] WANG Y, GAO Z, LONG M, et al. Predrnn++: towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning [C]//International Conference on Machine Learning. PMLR, 2018: 5123-5132.
- [19] WANG Yunbo, LONG Mingsheng, WANG Jianmin, et al. Predrnn: recurrent neural networks for predictive learning using spatiotemporal LSTMs [J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [20] MATHIEU M, COUPRIE C, LECUN Y. Deep multi-scale video prediction beyond mean square error [J/OL]. *arXiv: 1511.05440*, 2015. <https://arxiv.org/abs/1511.05440>.
- [21] SHI Xingjian, GAO Zhihan, LAUSEN L, et al. Deep learning for precipitation nowcasting: a benchmark and a new model [J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [22] POP L, SOKOL Z, MINÁŘOVÁ J. Nowcasting of the probability of accumulated precipitation based on the radar echo extrapolation [J]. *Atmospheric Research*, 2019, 216: 1-10.
- [23] 龙英伟. 多普勒雷达技术在气象观测中的应用 [J]. *数字技术与应用*, 2021, 39(12): 71-73.

(责任编辑 王绪迪)