

梁振清,陈生.基于深度学习和雷达观测的华南短临预报精度评估[J].气象研究与应用,2020,41(1):41–47.

Liang Zhenqing, Chen Sheng. Accuracy evaluation of nowcasting in South China based on deep learning and radar observation [J]. Journal of Meteorological Research and Application, 2020, 41(1):41–47.

# 基于深度学习和雷达观测的华南短临预报精度评估

梁振清<sup>1</sup>, 陈 生<sup>\*2,3</sup>

(1.南宁师范大学地理科学与规划学院, 南宁 530001; 2.中山大学大气科学学院, 广东 珠海 519082;  
3.广东省气候变化与自然灾害研究重点实验室, 广州 510275)

**摘要:** 利用最新的深度学习算法,即卷积长短期记忆(Convolution Long–Short Term Memory)神经网络,构建基于深度学习的人工智能短临预报系统,以广州地区2019年3–5月雷达观测的数据为输入进行训练,然后进行短期1 h内的降水预报。利用常用的统计评分指标(探测率POD、误报率FAR、临界成功指数CSI,相关系数CC)检验模型。结果表明,预报结果与实际观测的相关系数在1 h内预报均保持在0.6以上,在1 h内预报探测率均保持在80%以上,临界成功指数在降水强度为 $10\text{mm}\cdot\text{h}^{-1}$ 时,基本保持在60%,误报率均小于40%。

**关键词:** 深度学习;神经网络;降水短临预报;精度评估

中图分类号: P457.6

文献标识码:A

doi: 10.19849/j.cnki.CN45-1356/P.2020.1.09

## 引言

降水是水循环过程的一部分,它是诱发山洪,泥石流等自然灾害的重要因素之一。2019年“4.11”深圳短时极端强降水,仅仅持续30min,导致深圳全市多个区域突发洪水,使得福田区、罗湖区多处产生暗渠、暗涵,造成10人死亡,1人失联。因此,对降水预报的准确性对于保护人民生命与财产安全具有重要意义。目前主流的短临降水预报的方法有数值天气预测模式、外推方法、神经网络方法<sup>[1]</sup>。数值模式预报是基于降水的物理形成机制的一种预报方法,需要大量的数据以及复杂的计算量,因此需要大型计算机来支撑<sup>[2]</sup>,并且对初始条件非常敏感<sup>[1-3]</sup>。

基于对象的降水外推预报方法较常见的有SCIT(the Storm Cell Identification and Tracking), TITAN(Thunderstorm Identification, racking, Analysis, and Nowcasting)等方法,基于区域的外推预报方法常见有TREC(Tracking of Radar Echoes by Corre-

lation)、光流法。TITAN、SCIT都属于单体质心法,与TREC方法相比,这种方法计算量更小,能够较好的识别和追踪较小的孤立单体,并且能够提供单体的更详尽的数据,TREC算法对较大的回波有较好的识别和追踪效果,对相互距离较近的多个单体,其识别和追踪的效果较差<sup>[4]</sup>,光流法在对快速发展的强对流系统的追踪时有更好的效果<sup>[1,3]</sup>,然而这些外推方法无法预测风暴的形成与消退<sup>[5]</sup>。

随着计算机硬件的不断提升,机器学习的理论和应用得到迅速发展,已经产生了有不少的适用于气象领域的神经网络的方法<sup>[5-13]</sup>。比较常见的网络有人工神经网络(Artificial Neural Network, ANN)和卷积神经网络(Convolutional Neural Network, CNN)。段婧等人实验表明了人工神经网络比HLAFS(高分辨率有限区域预报系统)的降水预报准确率由原来的66.7%提高到88.2%<sup>[6]</sup>。通过Lei Han的研究可以得知,DNB(deep belief network)可以对对流风暴的移动和发展产生合理的预报结果<sup>[7]</sup>。En Shi等人基

收稿日期: 2020-01-02

基金项目: 国家自然科学基金项目(41875182)、广州科技局计划项目(201904010162)、中山大学“百人计划”项目(74110-18841203)、广西自然科学基金项目(2018JJA150110)、南宁师范大学-高校高层次人才和教师素质提升(6020303890216)、广西自然科学基金项目(2018GXNSFAA050130)

作者简介: 梁振清(1994-),男,在读硕士研究生,研究方向:地图学与地理信息系统。E-mail:liangzhenqing163@163.com

通信作者: 陈生(1979-),男,广西北流人,教授,研究方向:遥感定量降水产品的不确定分析。E-mail: chensheng@mail.sysu.edu.cn

CNNs (convolutional neural networks) 网络创建了 RDCNN(Recurrent Dynamic CNNs), 该方法与传统方法相比取得了较高的外推精度<sup>[8]</sup>, 以及其他基于 CNN 的短临降水预报的研究也取得了不错的预报效果<sup>[9-12]</sup>。

由于降水过程非常复杂, 每个地区都有不同的气候和降水特征, 各种不同的方法在不同地区适用性不同, 应对不同的天气类型也各有优势。本研究运用由 Xingjian Shi 等人<sup>[13]</sup>基于 LSTM 网络创造的用于短时降水预报 ConvLSTM 对广州地区的 4 个降水过程进行预报评估, 检验该网络在广州地区的适用程度。

## 1 研究区域降水气候概况

实验研究区域为广东省, 经度从  $108^{\circ}30'E$  到  $118^{\circ}E$ , 纬度从  $18^{\circ}12'36''N$  到  $27^{\circ}N$  的区域。广东省属于亚热带季风气候, 处于东亚季风区, 降水的时空分布不均匀, 年降水量和暴雨有三个最大值中心; 年降水变率普遍在 10~20%; 降水的成因, 主要与大型天气系统的移动和地形作用有关<sup>[14]</sup>。近 57a(1961~2017 年)来, 广东共出现 1211 次区域性暴雨过程, 平均每年 21.2 次, 主要出现在 4—9 月; 广东区域性暴雨过程的次数和强度存在明显的月际、年际和年代际变化, 次数最多出现在 5 月, 强度最大出现在 6 月; 强和较强等级的广东区域性暴雨过程次数呈显著增加趋势, 较弱等级区域性暴雨次数呈显著减少趋势<sup>[15]</sup>。因此, 本实验选择 3 月份到 5 月份之间的 4 个降水过程检验 ConvLSTM 网络在此区域的对降水预报的能力。

## 2 数据和方法

### 2.1 数据来源

研究数据取自 2008 年国家气象中心和广东、湖北、安徽等十多个省(市)气象部门于 2008 年联合研发的, 具有我国自主知识产权的灾害天气短时临近预报系统 (Severe Weather Automatic Nowcast System, SWAN)<sup>[1]</sup>。该系统是面向短时临近监测、分析、预报、预警制作等功能为一体的业务平台<sup>[14,15]</sup>。本研究取该系统提供的组合反射率数据经过 SWAN 提供的公式换算后得到的降水量数据, 裁剪经度为  $108^{\circ}30'E$  到  $118^{\circ}E$ , 纬度为  $18^{\circ}12'36''N$  到  $27^{\circ}N$  的区域进行实验。

### 2.2 ConvLSTM 的基本原理

卷积长短时记忆模型 ConvLSTM (Convolu-

tional Long Short-Term Memory) 由 Xingjian Shi 等人拓展循环神经网络 FC-LSTM (Fully Connected Long Short-Term Memory) 模型得到。FC-LSTM 能够适用于处理时间序列上的问题, 但是该网络无法捕捉数据的空间上的相关性<sup>[13]</sup>。如图 1 所示, ConvLSTM 采用与 FC-LSTM 的内部细胞结构一样的结构连接, 不同的地方在于特征的提取方式, ConvLSTM 在特征提取的时候采用的是卷积的方式, FC-LSTM 采用的则是全连接, 其中没有空间信息被编码<sup>[13]</sup>。

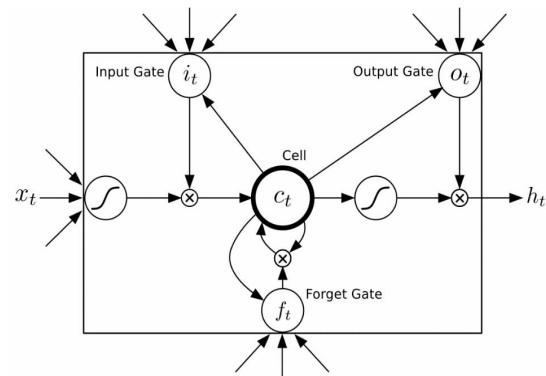


图 1 LSTM 内部细胞结构图<sup>[18]</sup>

从图中可以看到, LSTM 通过遗忘门  $f_t$  (Forget Gate), 输入门  $i_t$  (Input Gate), 输出门  $O_t$  (Output Gate) 控制着数据在细胞内部的交流。各个门控制着数据参与到细胞状态的更新, 通过门来选择性的增加或舍弃信息。它们之间的传递关系可以用公式(1)<sup>[13]</sup>表达:

$$\begin{aligned} i_t &= \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \\ f_t &= \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \\ c_t &= f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \\ o_t &= \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \\ h_t &= o_t \odot \tanh(c_t) \end{aligned} \quad (1)$$

其中“ $\sigma$ ”为 sigma 激活函数, “ $\odot$ ”表示矩阵与对应元素相乘, 即 Hadamard 乘积。遗忘门可以控制信息的遗忘, 把认为没有用的信息丢弃, 以及保留有用的信息用于更新的细胞状态。输入门处于激活的状态时, 会把新输入的数据累积到细胞中。而输出门作用是进一步决定最新的细胞输出是否会传播到最终状态。因此 LSTM 的网络结构可以运用累积的历史数据和新输入的数据进行学习。这样的结构使得 LSTM 具有强大的能力在处理时间序列等问题上, 但它包含了太多的空间数据冗余。为了解决这个问题, Xinjian Shi 等人把神经元内部状态与状态传递的计算方法由矩阵乘法运算改为卷积计算, 使其能

够捕捉空间特征信息,如公式(2)所示:

$$\begin{aligned} i_t &= \sigma(W_{xi} * x_t + W_{hi} * h_{t-1} + W_{ci} * c_{t-1} + b_i) \\ f_t &= \sigma(W_{xf} * x_t + W_{hf} * h_{t-1} + W_{cf} * c_{t-1} + b_f) \\ c_t &= f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc} * x_t + W_{hc} * h_{t-1} + b_c) \\ o_t &= \sigma(W_{xo} * x_t + W_{ho} * h_{t-1} + W_{co} * c_t + b_o) \\ h_t &= \sigma_t \odot \tanh(c_t) \end{aligned} \quad (2)$$

其中“\*”代表卷积计算,加上卷积操作之后,ConvLSTM不仅能够捕获到时序上的相关性,还能够像卷积层一样抓取空间特征。

### 2.3 评价指标定义

对降水过程的预报效果进行评估,通常把它看成一个二元事件。即预报的结果与观测都划分为有雨水或者无雨水的两种情况,观测的数据有降水,而预报的数据无降水则判定为漏报。观测数据有降水,而预报数据无降水则为错误预报。如果观测数据与预报结果都没有降水,则判定无降水。通过设定阈值来判定是否有降水,如果降水强度大于所设定的阈值,则判定为有降水发生,如果强度小于所设定的阈值则无降水发生。如下表1所示,

表 1 降雨事件二元分类比对

	观测结果有降水	观测结果无降水
预报结果有降水	H	F
预报结果无降水	M	Z

首先计算相关系数,然后引用水文气象研究中比较常用的探测率(probability of detection, POD)、

误报率(false to alarm, FAR)、临界成功指数(critical success index, CSI)三个指标评价 ConvLSTM 网络的降水预报的能力。

探测率越高表明,在所设定的降水强度以上的正确预报的数量在观测中的占比越多;误报率越低表明,在所设定的降水强度以上的错误预报的数量越少;临界成功指数越高表明,正确的预报在所有可能发生降水的情况中的占比越高。它们的计算公式如下所示:

$$POD = H / (H+M) \quad (3)$$

$$FAR = F / (H+F) \quad (4)$$

$$CSI = H / (H+F+M) \quad (5)$$

## 3 结果分析

图2表示4场降水过程的预报结果与实际观测的相关系数随着预报时间的变化曲线图。从图中可以得知,随着预报时间的增加,相关系数越来越低。ConvLSTM 在预报 60min 的时候表现优良,相关系数基本都保持在 0.6 以上。

所有降水过程在 6min 到 42min 的相关系数下降趋势比较稳定,42min 后第一个降水过程相关系数下降减缓,第三个降水过程模型表现最优,在 60min 的时候仍然具有接近 0.75 的最高相关性。相对其他降水过程,第一个降水过程在前 54min,模型的表现相对较差。54min 后,第 4 个降水过程相关系数最低。

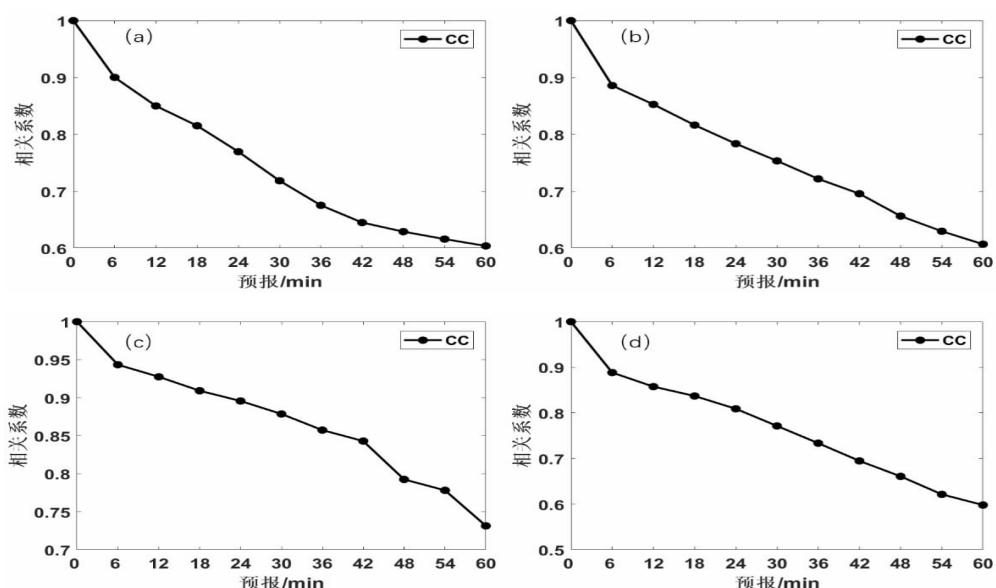


图 2 a,b,c,d 分别为起报时刻在 2019 年 3 月 4 日 11 时 54 分、2019 年 4 月 12 日 00 时 48 分、2019 年 4 月 27 日 06 时 18 分、2019 年 5 月 8 日 06 时 42 分的四场不同的降水过程

总体来说,ConvLSTM 模型在 60min 内基本能够预测到降水过程发展的趋势。

图 3 展示的是第一个降水过程在不同阈值下的 POD、FAR、CSI 随着时间的变化。从图中可以看到,随着预报时间的增加,以及降水强度升高,ConvLSTM 对降水的预报能力越来越差。首先,POD 基本不受阈值的影响并且保持在 80% 以上,但在阈值大于  $10\text{mm}\cdot\text{h}^{-1}$  以后有明显的下降。图中的 CSI 随着时间和阈值的增加呈现出下降的变化趋势,在预报 60min 以内,降水强度小于  $10\text{mm}\cdot\text{h}^{-1}$ ,CSI 均保持

在 60% 以上。在阈值为  $10\text{mm}\cdot\text{h}^{-1}$ ,60min 处预报结果的 CSI 开始接近 40%。当阈值为  $15\text{mm}\cdot\text{h}^{-1}$ ,60min 处的 CSI 接近 20%。FAR 基本呈现出与 CSI 相反的变化方向,随着预报时间的前移,阈值的升高,误报的数量不断增加。在阈值为  $10\text{mm}\cdot\text{h}^{-1}$ ,随着预报时间变长,FAR 将超过 CSI,越是升高阈值,FAR 超过 CSI 的时间点会来得更快。可以看出,随着时间的增加,ConvLSTM 对本次降水过程中强度较高的降水预报不佳,但对强度较低的降水预报能力较优。

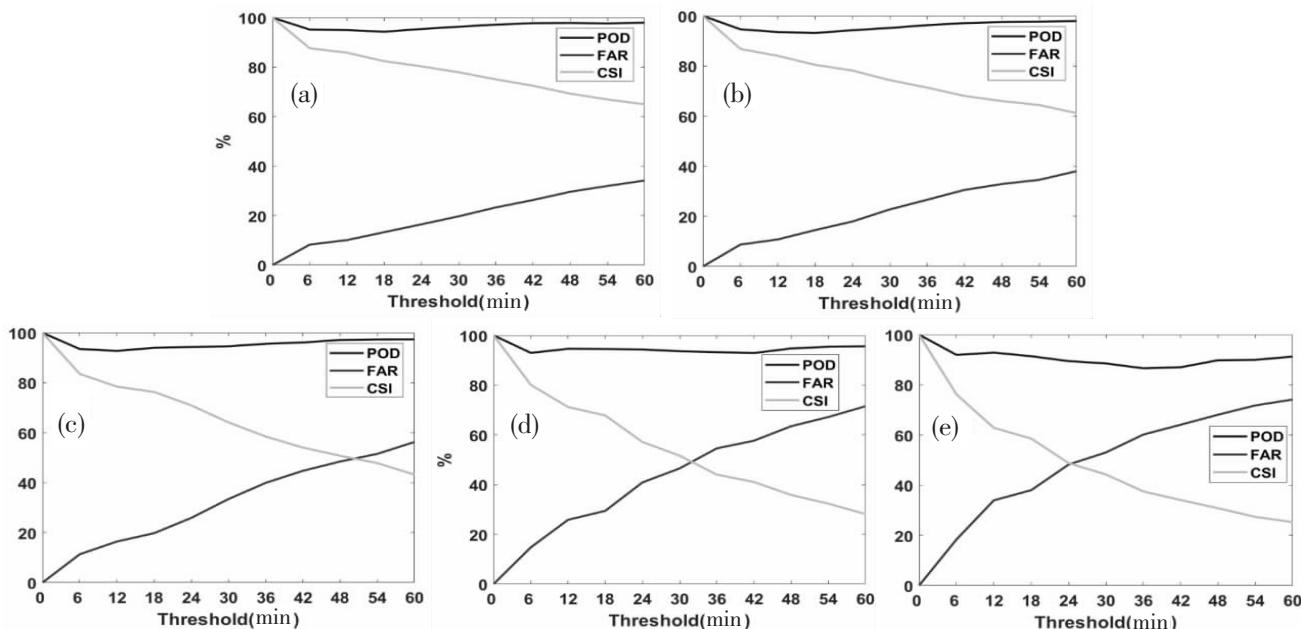


图 3 起报时刻为 2019 年 3 月 4 日 11 时 54 分,探测率、误报率、临界成功指数在 1h 内的变化曲线

a-e 阈值分别为  $1\text{mm}\cdot\text{h}^{-1}$ 、 $5\text{mm}\cdot\text{h}^{-1}$ 、 $10\text{mm}\cdot\text{h}^{-1}$ 、 $15\text{mm}\cdot\text{h}^{-1}$ 、 $20\text{mm}\cdot\text{h}^{-1}$

图 4 给出了不同降水强度阈值下随着时间的变化对第二个降水过程 POD、FAR、CSI 的影响。首先,随着降水强度的升高,POD 将越来越低,但会保持在 80% 以上。当降水强度阈值小于  $15\text{mm}\cdot\text{h}^{-1}$ ,CSI 始终保持在 50% 以上,当降水强度高于  $15\text{mm}\cdot\text{h}^{-1}$ ,CSI 低于 50%。当降水强度小于  $15\text{mm}\cdot\text{h}^{-1}$ ,FAR 总是小于 CSI。当降水强度大于  $15\text{mm}\cdot\text{h}^{-1}$  之后,误报数量逐渐增加,FAR 在 60min 处高于 50%,超过 CSI。随着降水越来越强,误报数量随着预报时间的推进越来越多。在此降水过程中,ConvLSTM 对强度高于  $15\text{mm}\cdot\text{h}^{-1}$  的降水,预报能力随着预报时间的增加逐渐下降。

图 5 所示是第三个降水过程的 POD、FAR、CSI

在不同降水强度和预报时间的变化曲线。可以看到三个评价指标在不同的降水强度下几乎没有明显变化。在整个预报时间内以及所有的设定强度阈值,CSI 从第一个时刻大于 80% 开始随着时间递减,但在规定的预报时间内始终保持在 60% 以上。FAR 随着时间递增,在 60min 时大约增至 30% 以上。ConvLSTM 在本次降水过程规定时间内,实际降水强度远远高于所设定的阈值时,对各个降水强度的预报能力表现良好。

图 6 反映的是不同的降水强度和预报时间下,第四个降水过程的 POD、FAR、CSI 的变化。如图所示,当降水强度小于  $15\text{mm}\cdot\text{h}^{-1}$ ,在第一个时刻均能保持 80% 的 POD,但预报时间越长,POD 越来越低。

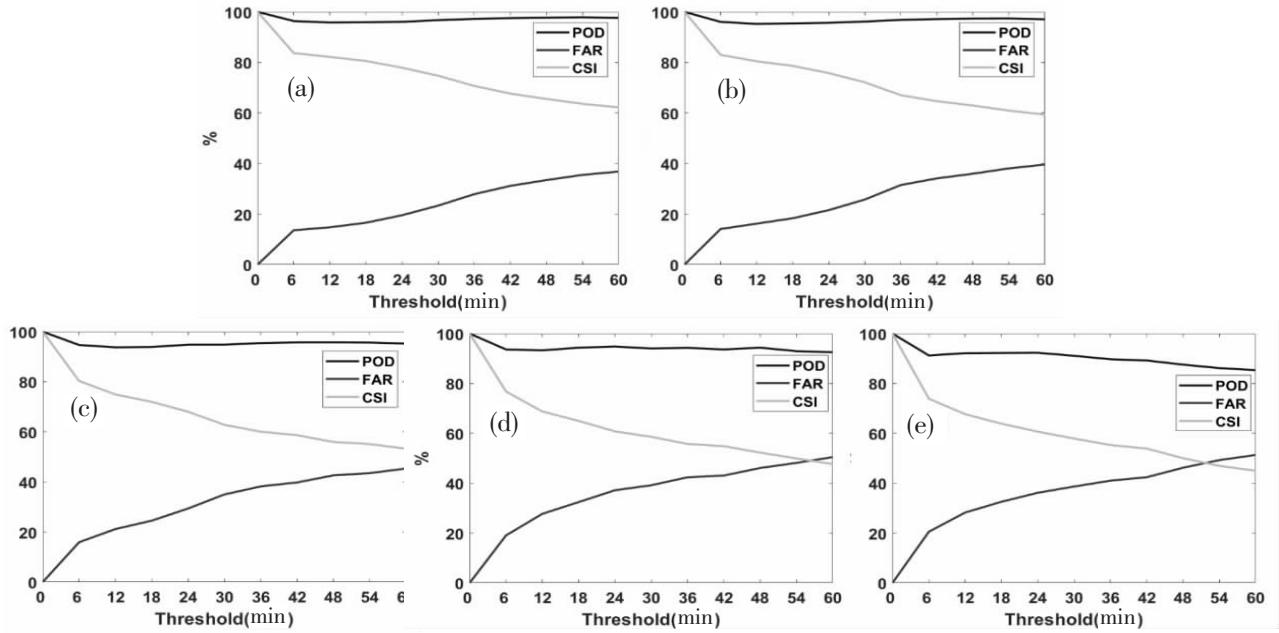


图4 起报时刻为2019年4月12日00时48分,探测率、误报率、临界成功指数在1h内的变化曲线  
a-e 阈值分别为 $1\text{mm}\cdot\text{h}^{-1}$ 、 $5\text{mm}\cdot\text{h}^{-1}$ 、 $10\text{mm}\cdot\text{h}^{-1}$ 、 $15\text{mm}\cdot\text{h}^{-1}$ 、 $20\text{mm}\cdot\text{h}^{-1}$

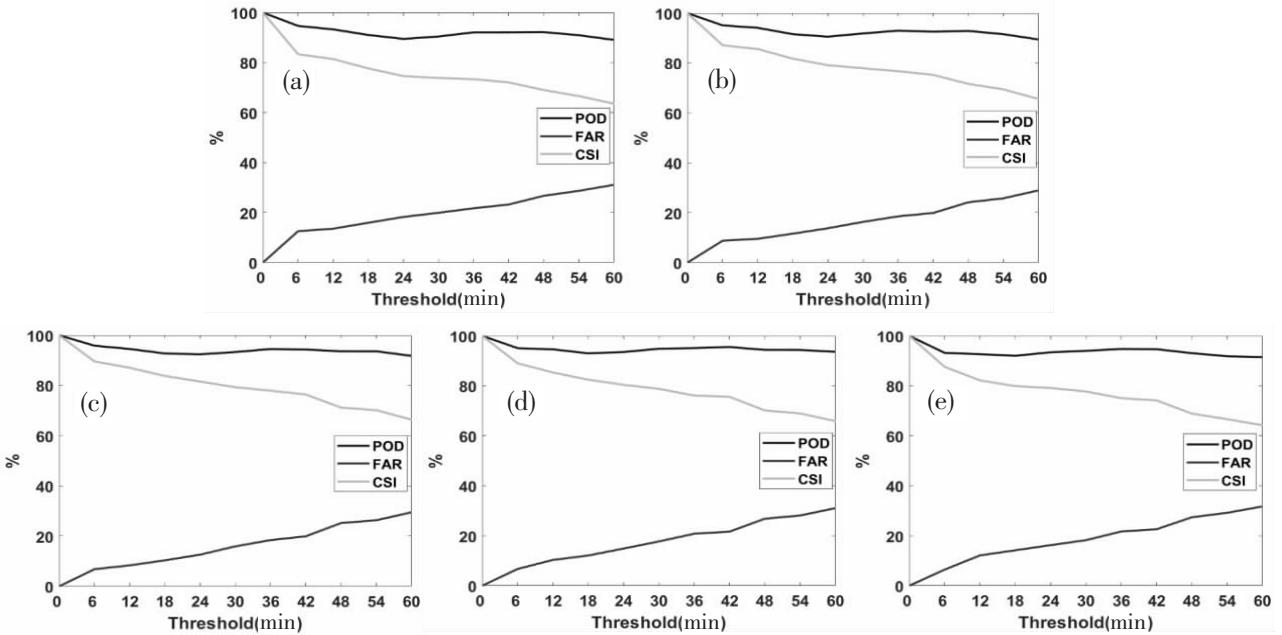


图5 起报时刻为2019年4月27日06时18分,探测率、误报率、临界成功指数在1h内的变化曲线  
a-e 阈值分别为 $1\text{mm}\cdot\text{h}^{-1}$ 、 $5\text{mm}\cdot\text{h}^{-1}$ 、 $10\text{mm}\cdot\text{h}^{-1}$ 、 $15\text{mm}\cdot\text{h}^{-1}$ 、 $20\text{mm}\cdot\text{h}^{-1}$

CSI 在降水强度小于  $15\text{mm}\cdot\text{h}^{-1}$  的第一个时刻高达 80%。在降水强度小于  $5\text{mm}\cdot\text{h}^{-1}$ , ConvLSTM 的表现最佳, 在 60min 处的 CSI 略低于 60%, 但随着强度阈值的升高, 预报能力逐渐下降, 在降水强度大于  $10\text{mm}\cdot\text{h}^{-1}$ , 在 60min 处, CSI 低于 40%, 当降水强度大于  $15\text{mm}\cdot\text{h}^{-1}$  之后, 第一个时刻的 CSI 开始从 80% 锐减到 60%, 在 60min 处的 CSI 接近于 20%。随着降

水强度的升高和预报时间长度的增加, 误报数量不断加大。FAR 在降水强度为  $10\text{mm}\cdot\text{h}^{-1}$ , 预报 48min 处高达 60%。当降水强度大于  $15\text{mm}\cdot\text{h}^{-1}$ , 有接近 80% 的 FAR。在本次降水过程中, ConvLSTM 对大于  $10\text{mm}\cdot\text{h}^{-1}$  强度的降水预报能力较弱, 在半个小时内的预测结果较优。

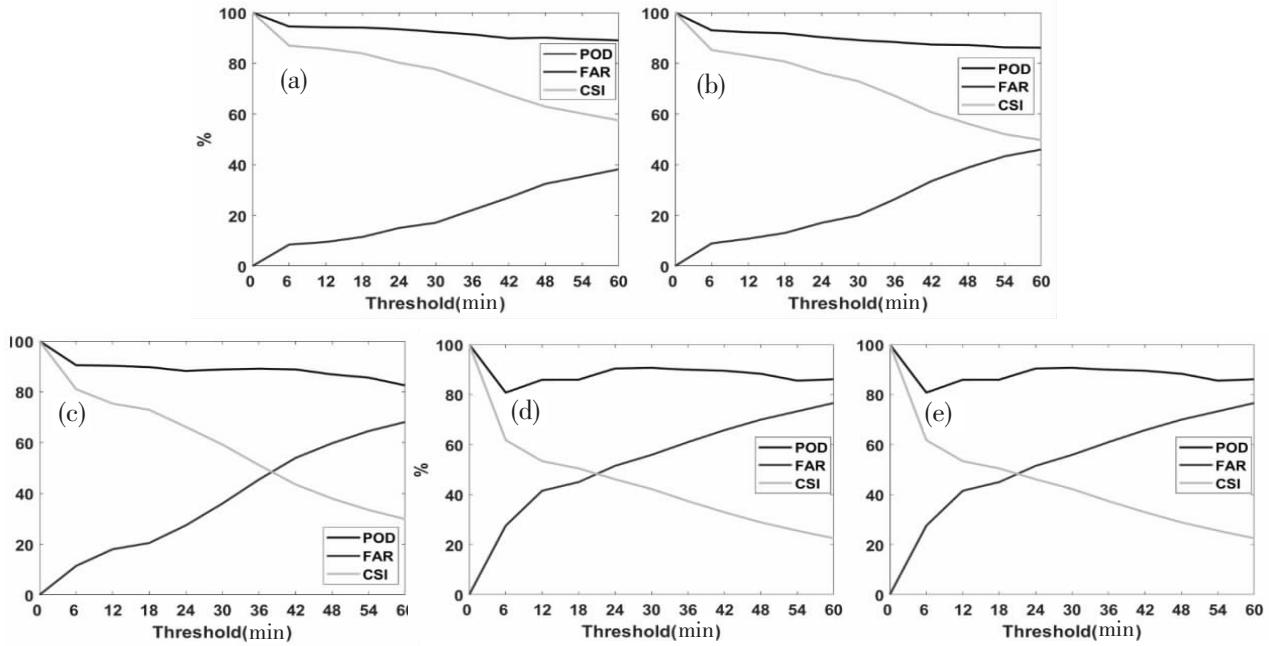


图 6 起报时刻为 2019 年 5 月 8 日 06 时 42 分, 探测率、误报率、临界成功指数在 1h 内的变化曲线

a-e 阈值分别为 1mm/h、5mm/h、10mm/h、15mm/h、20mm/h

## 4 结论

本研究运用了国家气象局的 SWAN 提供的 2019 年 3—5 月 4 个时刻的组合反射率数据, 检验了 ConvLSTM 网络对广东区域的降水预报能力。

由于降水发展的过程复杂, 降水的预报存在很多不确定因素, 包括数据以及神经网络的最优状态的影响, 都有可能对降水预报产生意想不到的结果, 运用已有的检验方法, 从所做的实验结果来看, ConvLSTM 网络在 1h 内表现较为良好, 预报结果与实际观测在一个预报小时内的相关系数高于 0.6。能够在总体上预报降水的变化趋势, 对较低强度的降水预报效果非常好, 但对高强度降水预报会有相对高的误报量。

该神经网络对降水的移动变化趋势预报表现优秀, 但对降水强度细节上存在一定的低估, 未来可以针对降水强度预报进行研究并适当地改进训练, 可考虑通过加入生成对抗网络, 使得预报结果更加合理逼真。

### 参考文献:

- [1] 张小玲, 杨波, 盛杰, 等. 中国强对流天气预报业务发展[J]. 气象科技进展, 2018, 8(3):8–18.
- [2] 张鹏程, 贾旸旸. 一种基于多层感知器的动态区域联合短时降水预报方法[J]. 计算机应用与软件, 2018, 35(11): 159–164+189.
- [3] 郑永光, 张小玲, 周庆亮, 等. 强对流天气短时临近预报业务技术进展与挑战[J]. 气象, 2010, 36(7):33–42.
- [4] 韩雷, 王洪庆, 谭晓光, 等. 基于雷达数据的风暴体识别、追踪及预警的研究进展[J]. 气象, 2007, 33(1):5–12.
- [5] NAGARAJAN, Aditya. Explorations into Machine Learning Techniques for Precipitation Nowcasting [DB/OL]. https://scholarworks.umass.edu/masters\_theses\_2/480, 2017.
- [6] 段婧, 苗春生. 人工神经网络在梅雨期短期降水分级预报中的应用[J]. 气象, 2005, 31(8):31–36.
- [7] Han L, Dai J, Zhang W, et al. A deep belief network approach using VDRAS data for nowcasting [C]// International Conference on Graphic & Image Processing. Ninth International Conference on Graphic and Image Processing (ICGIP 2017), 2018.
- [8] Shi E, Li Q, Gu D, et al. A Method of Weather Radar Echo Extrapolation Based on Convolutional Neural Networks [M]// MultiMedia Modeling Springer Cham 2018.
- [9] Jiang L, Zhang W, Han L. Strong convective storm nowcasting using a hybrid approach of convolutional neural network and hidden Markov model [C]// Ninth International Conference on Graphic and Image Processing, 2018.
- [10] Pan B, Hsu K, AghaKouchak A, et al. Improving precipitation estimation using convolutional neural network [J]. Water Resources Research, 2019, 55(3): 2301–2321.
- [11] Zhang W, Han L, Sun J, et al. Application of Multi-

- channel 3D –cube Successive Convolution Network for Convective Storm Nowcasting [C]. 2019 IEEE International Conference on Big Data (Big Data), 2017: 1705–1710.
- [12] Ayzel G, et al. All convolutional neural networks for radar-based precipitation nowcasting [J]. Procedia Computer Science, 2019, 150: 186–192.
- [13] Xingjian S H I, Chen Z, Wang H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [C]//Advances in neural information processing systems. 2015: 802–810.
- [14] [1] 李琨, 武麦凤. 基于 SWAN 数据的定量降水预报 (QPF) 研究 [C]//中国气象学会: 第 30 届中国气象学会年会论文集, 2013: 1–5.
- [15] 韩丰, 沃伟峰. SWAN2.0 系统的设计与实现 [J]. 应用气象学报, 2018, 29(1): 27–36.
- [16] 黄奇章. 广东降水气候特征及其成因分析 [J]. 热带地理, 1990, 10(2): 113–124.
- [17] 伍红雨, 邹燕, 刘尉. 广东区域性暴雨过程的定量化评估及气候特征 [J]. 应用气象学报, 2019(2): 233–244.
- [18] Graves A. Generating Sequences With Recurrent Neural Networks [J]. Computer Science, 2013.

## Accuracy evaluation of nowcasting in South China based on deep learning and radar observation

Liang Zhenqing<sup>1</sup>, Chen Sheng<sup>\*2,3</sup>

(1.School of Geography and Planning, Nanning Normal University, Nanning 53001;  
2. School of Atmospheric Sciences, Sun Yat-sen University, Zhuhai Guangdong 519082;  
3. Guangdong Province Key Laboratory of Climate Change and Natural Disasters, Guangzhou 510275)

**Abstract:** The latest deep learning algorithm, namely convolution long-term short-term memory neural network, is used to construct an artificial intelligence short-time prediction forecast system. The radar observation data from March to May 2019 in Guangzhou is used as input for training, and then the short-time precipitation forecast within 1 hour is carried out. The commonly used statistical scoring indicators (POD, FAR, CSI, CC) were used to test the model. The results show that: 1) the CC between the prediction results and the actual observation are kept above 0.6; 2) All the POD are above 80%; 3) the CSI are basically kept at 60% when the precipitation intensity is 10mm/h; 4) All FAR are less than 40%.

**Key Words:** deep learning; neural network; short-time precipitation forecast; accuracy assessment