

韩丰, 龙明盛, 李月安, 等. 循环神经网络在雷达临近预报中的应用. 应用气象学报, 2019, 30(1): 61-69.

DOI: 10.11898/1001-7313.20190106

# 循环神经网络在雷达临近预报中的应用

韩 丰<sup>1)\*</sup> 龙明盛<sup>2)</sup> 李月安<sup>1)</sup> 薛 峰<sup>1)</sup> 王建民<sup>2)</sup>

<sup>1)</sup>(国家气象中心, 北京 100081)

<sup>2)</sup>(清华大学软件学院, 北京 100084)

## 摘 要

该文将循环神经网络(recurrent neural network, RNN)应用于雷达临近预报。使用预测循环神经网络(predictive RNN)架构, 利用雷达历史组合反射率因子建模, 给出雷达组合反射率因子未来 1 h 的预报结果。预测循环神经网络的核心是在长短时记忆单元(long short-term memory, LSTM)中增加时空记忆模块, 能够提取雷达回波不同尺度的空间特征, 配合循环神经网络架构, 可以有效解决反射率因子预测问题。北京大兴雷达和广州雷达长时间序列的独立检验结果和 2 个强对流天气个例检验结果表明: 该方法和传统的基于交叉相关法的 1 h 雷达外推临近预报相比, 在 20 dBZ 和 30 dBZ 检验项目内, 临界成功指数(CSI)可以提升 0.15~0.30, 命中率(POD)提高 0.15~0.25, 虚警率(FAR)降低 0.15~0.20, 该方法对反射率因子强度变化有一定预报能力。

**关键词:** 雷达临近预报; 循环神经网络; 深度学习

## 引 言

雷达外推临近预报是气象临近预报业务中的重要手段<sup>[1-2]</sup>。目前, 已经投入业务应用的此类方法主要有交叉相关(COTREC)法<sup>[3]</sup>和光流法<sup>[4-6]</sup>等。交叉相关法和光流法主要是在假设雷达反射率因子的运动满足拉格朗日守恒的基础上, 通过分析前后两个时次的反射率因子分布, 求解得到反射率因子的运动矢量, 并将反射率因子按照该运动矢量的规律进行 1~3 h 外推。基于拉格朗日守恒的外推方法在稳定性降水预报中可以取得较好效果<sup>[7]</sup>, 但在局地强对流天气中, 回波发展演变较快, 无法满足守恒条件, 预报效果会随时间快速下降<sup>[8-9]</sup>。

深度学习的概念起源于人工神经网络, 含有多层神经元, 具有优异的特征学习能力, 与传统的人工神经网络相比, 可以通过组合低层特征形成更加抽

象的高层特征表示属性或特征, 以更好地发现数据的有效特征表示<sup>[10-11]</sup>。目前, 人工智能技术在气象领域已取得一定应用成果。陆虹等<sup>[12]</sup>使用粒子群-神经网络构建非线性统计集合模型, 显著提高严重低温雨雪过程的预报能力。卢新玉等<sup>[13]</sup>使用后向传播神经网络建立 TRMM 月降水产品在新疆地区的订正模型, 取得较好的订正效果。

连续的雷达观测是一种时序数据。外推时要达到较好效果, 需要充分考虑雷达反射率因子相邻时次的时序相关性, 这在深度学习网络中正符合 LSTM-RNN(long short-term memory-recurrent neural network, 具有长短时记忆单元的循环神经网络)的基本特点。LSTM-RNN 网络已在语音识别、自然语言翻译和手写识别等领域取得很好的应用效果<sup>[14]</sup>。

目前将 LSTM-RNN 应用于雷达外推预报的研究还处于起步阶段, Shi 等<sup>[15]</sup>提出使用带有卷积层

2018-06-06 收到, 2018-08-08 收到再改稿。

资助项目: 国家重点研究发展计划重点专项(2016YFB1000700)

\* 邮箱: hanfeng\_nuist@163.com

的 LSTM 单元(ConvLSTM)组成 RNN,并将其应用到雷达外推预报中。通过与中国香港天文台研发的小涡旋系统(Short-range Warning of Intense Rainstorms in Localized System, SWIRLS)<sup>[16]</sup>中的光流外推算法(Real-time Optical flow by Variational method for Echoes of Radar, ROVER)的对比分析发现,对  $0.5 \text{ mm} \cdot \text{h}^{-1}$  以上的降水,该方法预报准确率有明显提升,取得了不错的应用效果。

本文提出使用带有 ST-LSTM(spatiotemporal LSTM)<sup>[17]</sup>单元组成的预测循环神经网络(PredRNN,简称预测网络)作为神经网络架构,选取北京大兴雷达和广州雷达作为试验对象,通过对长时序历史数据的建模,分别得到两个雷达站点组合反射率因子的演变模型,并基于该演变模型进行组合反射率因子的预报试验。最后将该方法和 SWAN(Severe Weather Automatic Nowcasting,强对流天气短时临近预报)系统中的交叉相关法进行对比检验,给出长时间序列的独立检验结果和两个强对流天气个例检验。

## 1 方法

### 1.1 预测循环神经网络架构

雷达临近预报本质上是一个时序数据的预测问题,神经网络需要根据不同时次雷达反射率因子的分布规律,预测未来一段时间内反射率因子的位置。其中的关键点是使不同时次的神经网络能够获得部分前序神经网络的记忆,这是一个典型的循环神经网络(RNN)解决的问题。

目前,最成功的 RNN 架构是 LSTM-RNN,由首先 Hochreiter 等<sup>[18]</sup>提出。相比常规的 RNN 单元,LSTM 单元增加了 3 个控制门(遗忘门、输入门、输出门),可以有效解决学习过程中的梯度膨胀或梯度消失问题,使神经网络学习到长期的依赖关系。该模型在语音识别、自然语言翻译和手写识别等场景中均取得了很好的应用效果<sup>[19-20]</sup>。

全场的雷达反射率因子临近预报,以格点作为最小预报单位,逐格点进行预测。在实际天气过程中,雷达反射率因子是在天气系统驱动下发展变化的,所以在进行预测时,不仅需要考虑该格点的反射率因子时间变化规律,还需要考虑该格点周围的天气

形势,在雷达观测中表现为格点周围的反射率因子特征。这使得在构造 RNN 时,不仅需要考虑时间信息的记忆,还要考虑空间信息的记忆。

本文提出使用由 ST-LSTM 单元组成的预测网络进行雷达组合反射率因子临近预报试验。预测网络采用多层 RNN 架构,在时间记忆模块循环的基础上,增加了空间记忆模块的传播路线,强化了空间信息在不同层次和不同时间的神经元中的传播。在雷达临近预报中,该架构更有利于让模型学习不同尺度雷达反射率因子特征以及它们在时间线上的发展演变规律。

### 1.2 ST-LSTM 单元

ST-LSTM 单元是 LSTM 单元的一种扩展。在 ST-LSTM 单元中包含两种记忆模块,即时间记忆模块和空间记忆模块。其中,时间记忆模块是前  $n$  时刻同一层神经元的记忆累计,空间记忆模块是前  $n$  时刻不同层神经元的记忆累计。与 LSTM 类似,两个记忆模块分别有各自的 3 个控制门:遗忘门控制模块中需要被遗忘的记忆内容,输入门决定当前时刻的输入需要被模块记住的内容,输出门决定隐层输出内容。最后将两个记忆模块的内容融合成单元的隐层输出。

在雷达回波临近预报中,ST-LSTM 单元和传统 LSTM 单元相比的优势主要体现在两点:①将状态累计和隐层输出的运算过程由前馈式计算替换为卷积形式。其核心本质与 LSTM 一致,将上一层的输出作为下一层的输入。不同之处在于加入卷积操作后,神经元不仅能够得到时序关系,还可以提取空间特征。②增加空间记忆模块,有助于不同维度的空间特征信息在 RNN 中传播。

## 2 数据

### 2.1 数据集

为了测试算法地域适用性,本文选择北京大兴 SA 波段雷达( $39.809^{\circ}\text{N}, 116.472^{\circ}\text{E}$ )和广州 SA 波段雷达( $23.004^{\circ}\text{N}, 113.355^{\circ}\text{E}$ )作为试验对象,分别构造学习数据集和独立检验数据集。两部雷达皆为多普勒天气雷达,采用 VCP21 观测方式,径向分辨率为 1 km。数据集信息如表 1 所示。

表 1 数据集信息  
Table 1 Information of dataset

站点	型号	学习数据集	独立检验数据集
北京大兴	SA	2014-04-01—10-31	2017-07-01—08-31
		2015-04-01—10-31	
		2016-04-01—10-31	
		2017-04-01—06-31	
广州	SA	2016-01-01—2017-07-31	2017-08-01—10-30

## 2.2 雷达资料预处理

本文使用雷达组合反射率因子进行临近预报试验。雷达观测受大气环境和硬件性能等影响,观测结果中可能包含非气象目标物产生的噪声、大气湍流造成的回波脉动、干扰回波等,对预报结果影响较大。所以需要雷达资料进行预处理,减小杂波的影响。预处理的主要内容如下:①构造奇异点滤波器和双边滤波器在值域和空间域进行滤波,在保留回波特性的前提下,可以有效消除脉动和杂波<sup>[21]</sup>;②构造反射率因子垂直递减率滤波器,过滤地物回波和部分超折射回波<sup>[22]</sup>;③计算年平均反射率因子

分布,确定遮挡方位角,并进行线性内插填补;④构造高通滤波器去除 15 dBZ 以下的反射率因子,只保留与降水相关的反射率因子;⑤为了避免零度层亮带的干扰,在合成组合反射率因子产品时,只使用仰角为 0.5°, 1.5°, 2.5°, 3.4° 和 4.3° 的反射率因子<sup>[23-24]</sup>。

图 1 给出的是组合反射率因子预处理结果。其中,图 1a 为原始组合反射率因子,图 1b 为预处理后的组合反射率因子,图中红圈处的杂波已得到有效抑制,雷达站西南方向的衰减径向也得到有效填补。同时,回波形态基本得到完整保留。




图 1 雷达资料预处理

(a)原始组合反射率因子,(b)预处理后的组合反射率因子

Fig. 1 Result of radar data pre-processing

(a)original composite reflectivity,(b)composite reflectivity after processing

以预测网络为架构,开展循环神经网络在雷达临近预报中的应用研究。使用训练集数据,分别对广州和北京大兴雷达进行建模。其中一组试验输入包括 10 个连续时次的雷达观测,预测网络会给出未来 10 个连续时次的回波预测。采用监督学习的方式进行,试验的真值为后续 10 个时次的雷达观测。模型代价函数为全场逐格点的均方根误差。

## 3 检验

### 3.1 检验方法

本文设计了预测网络法和交叉相关法的对比试验,其中交叉相关法为在 SWAN2.0 中集成推广的算法<sup>[25]</sup>。选用命中率(POD)、虚警率(FAR)和临界

成功指数(CSI)对预报结果进行量化评估,并以交叉相关法为基准,给出预测网络法的技巧评分( $E$ ), $E$ 为预测网络法和交叉相关法的CSI之差。

在计算命中数、空报数和漏报数时,采用逐格点的计算方式,即选用同一个格点的预报值和观测值进行对比。在处理作为真值的观测数据时,使用和预报试验同样的数据预处理方法。

预报产品分辨率为 $0.01^\circ \times 0.01^\circ$ ,预报时间步长为6 min,预报时效最长为60 min,即预报给出6 min,12 min,18 min,24 min,30 min,36 min,42 min,48 min,54 min和60 min之后的组合反射率因子的强度和位置。采用分预报时效和分阈值的检验方法,预报时效共10个,阈值分别为20 dBZ,30 dBZ和50 dBZ,检验组合反射率因子不小于阈值的格点,共30组检验结果。

### 3.2 长期检验结果

使用第2章介绍的独立检验集,对北京大兴和广州两个雷达站分别进行长时间序列独立检验。表2、表3分别给出北京大兴雷达和广州雷达30 min和60 min预报时效的3个反射率因子阈值检验结果。由表2、表3可知,预测网络法在两部雷达的试验中,在3个检验阈值CSI均高于交叉相关法;预测网络法在两部雷达的试验中,在3个检验阈值,POD均高于交叉相关法,FAR均低于交叉相关法;预测网络法和交叉相关法的预报能力随预报时间的延长而下降,具体表现为CSI和POD随时间下降,FAR随时间上升;预测网络法和交叉相关法预报能力随组合反射率因子上升而下降,对强度超过50 dBZ的区域,预报能力都显得不足。

图2分别给出两个站技巧评分随预报时效的变

表2 北京大兴雷达检验集对比检验

Table 2 Quantitative result of Daxing radar in Beijing

检验指标	方法	30 min 预报时效			60 min 预报时效		
		20 dBZ	30 dBZ	50 dBZ	20 dBZ	30 dBZ	50 dBZ
CSI	预测网络	0.63	0.43	0.14	0.52	0.32	0.05
	交叉相关	0.41	0.27	0.04	0.30	0.17	0.01
POD	预测网络	0.78	0.59	0.23	0.70	0.47	0.10
	交叉相关	0.64	0.45	0.09	0.53	0.33	0.03
FAR	预测网络	0.18	0.26	0.40	0.25	0.33	0.45
	交叉相关	0.35	0.40	0.48	0.44	0.47	0.59

表3 广州雷达检验集对比检验

Table 3 Quantitative result of Guangzhou radar

检验指标	方法	30 min 预报时效			60 min 预报时效		
		20 dBZ	30 dBZ	50 dBZ	20 dBZ	30 dBZ	50 dBZ
CSI	预测网络	0.69	0.55	0.14	0.60	0.44	0.08
	交叉相关	0.40	0.26	0.02	0.29	0.17	0.01
POD	预测网络	0.82	0.69	0.23	0.76	0.60	0.15
	交叉相关	0.63	0.45	0.03	0.53	0.33	0.01
FAR	预测网络	0.15	0.20	0.37	0.20	0.26	0.40
	交叉相关	0.30	0.37	0.49	0.41	0.44	0.50

化规律,技巧评分大于0,表示预测网络法的预报能力超过交叉相关法。由图2可知,预测网络法在两部雷达的试验中,在全部检验项目内,CSI均超过交叉相关法;在20 dBZ和30 dBZ检验项目内,技巧评分随预报时效的增长而上升,这说明在这两个反射率因子区间内,预测网络法的预报能力随预报时效的延长下降更慢;在50 dBZ检验项目内,技巧评分相对最低,但考虑到这一区间内的两种方法的CSI

评分均较低,0.05的技巧也带来明显提升。

### 3.3 个例检验

#### 3.3.1 飑线天气过程

2017年7月7日京津冀地区受东移南下的飑线影响,部分地区出现雷阵雨天气,并伴有雷暴大风、冰雹等灾害性天气,地面自动气象站观测瞬时风力达9级。图3a给出了7日22:54(北京时,下同)的组合反射率因子实况产品。图3b为预测网络法

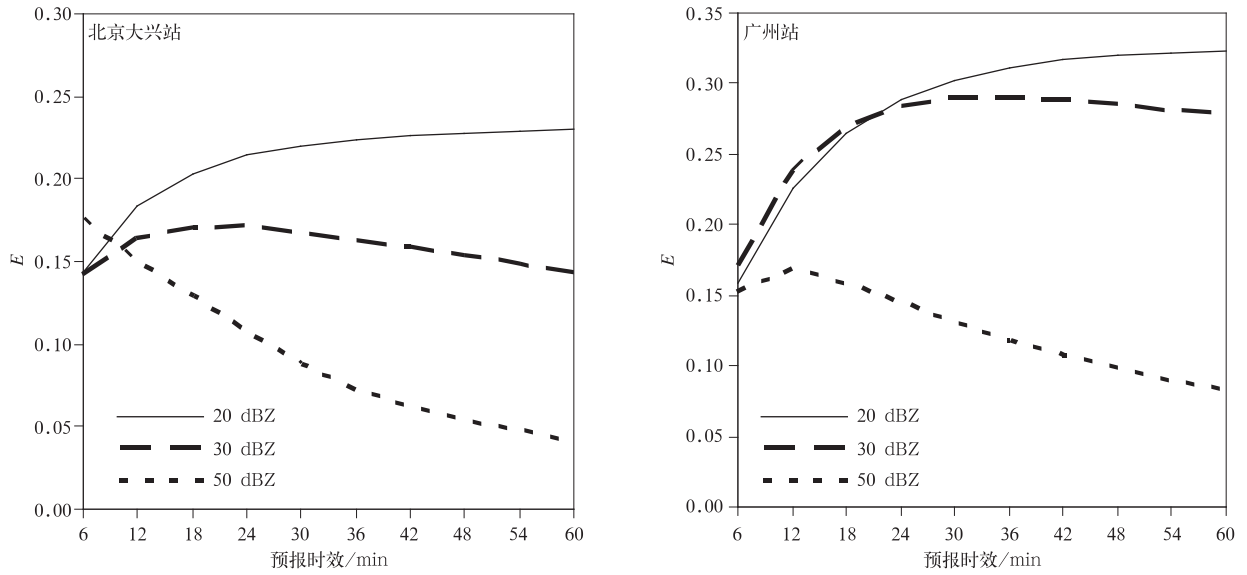


图 2 技巧评分

Fig. 2 Difference between CSI of two methods

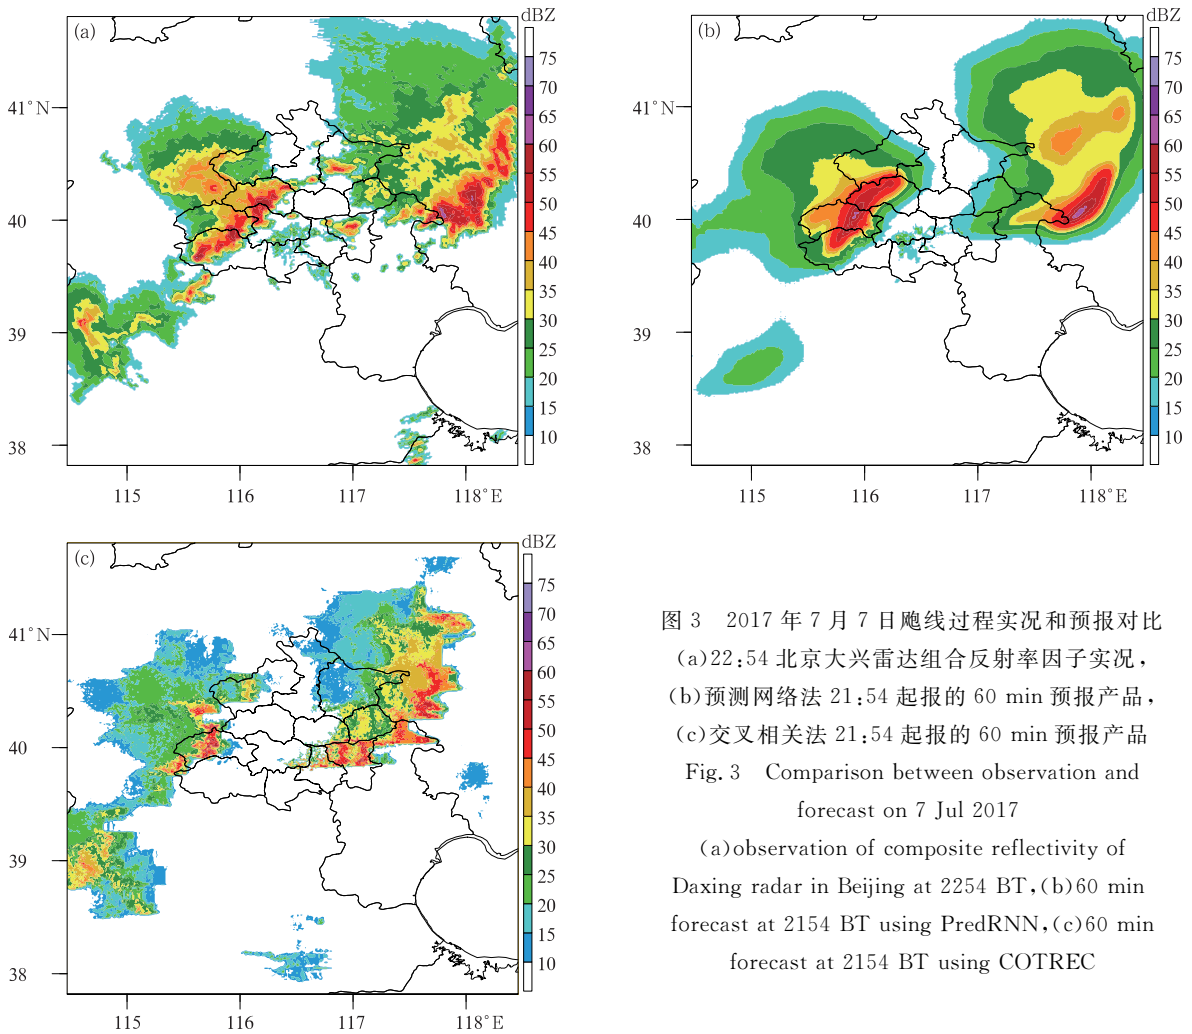


图 3 2017 年 7 月 7 日飚线过程实况和预报对比  
(a)22:54 北京大兴雷达组合反射率因子实况,  
(b)预测网络法 21:54 起报的 60 min 预报产品,  
(c)交叉相关法 21:54 起报的 60 min 预报产品

Fig. 3 Comparison between observation and forecast on 7 Jul 2017

(a)observation of composite reflectivity of Daxing radar in Beijing at 2254 BT, (b)60 min forecast at 2154 BT using PredRNN, (c)60 min forecast at 2154 BT using COTREC

21:54起报的60 min临近预报。对比图3a和图3b可以看到,预测网络法60 min预报的组合反射率因子位置和分布与实况基本一致,正确预报出位于北京西部和天津东北部的两条强回波带。其中天津东北方向的强回波带中,两个强中心团得到分离,与实况基本一致。在强度变化方面,北京西部的强回波带范围有所扩大,强度略加强,说明模型学习到了组合反射率因子发展的规律,强度加强判断正确;但在河北西部偏南地区次强回波中心的预报中,预测网

络法给出强度减弱的错误判断。这说明预测网络法可以根据不同的组合反射率因子特征,给出不同的强度变化预测。对比图3a和图3c可以看到,交叉相关法对于快速运动的飊线天气过程,出现外推结果明显失真问题。

表4给出了两种方法的客观检验结果。由表4可知,与长时间序列检验结果类似,预测网络法和交叉相关法相比,前者CSI高,POD高,FAR低,说明预测网络法在此次飊线天气过程中预报能力更强。

表4 2017年7月7日北京大兴雷达检验结果

Table 4 Quantitative result of Daxing radar in Beijing on 7 Jul 2017

检验指标	方法	60 min 预报时效		
		20 dBZ	30 dBZ	50 dBZ
CSI	预测网络	0.51	0.32	0.06
	交叉相关	0.24	0.11	0.01
POD	预测网络	0.71	0.49	0.11
	交叉相关	0.47	0.23	0.03
FAR	预测网络	0.29	0.35	0.45
	交叉相关	0.48	0.51	0.75

### 3.3.2 短时强降水天气过程

2017年8月22日广东受台风天鸽(1713)外围云系影响<sup>[26]</sup>,出现短时强降水天气过程,部分地区降水超过 $20 \text{ mm} \cdot \text{h}^{-1}$ 。图4a为22日21:30的广

州雷达的组合反射率因子实况产品,图4b为预测网络法20:30起报的60 min临近预报,图4c为交叉相关法20:30起报的60 min临近预报。此次过程雷达强回波团在台风外围环流形势的影响下,向西

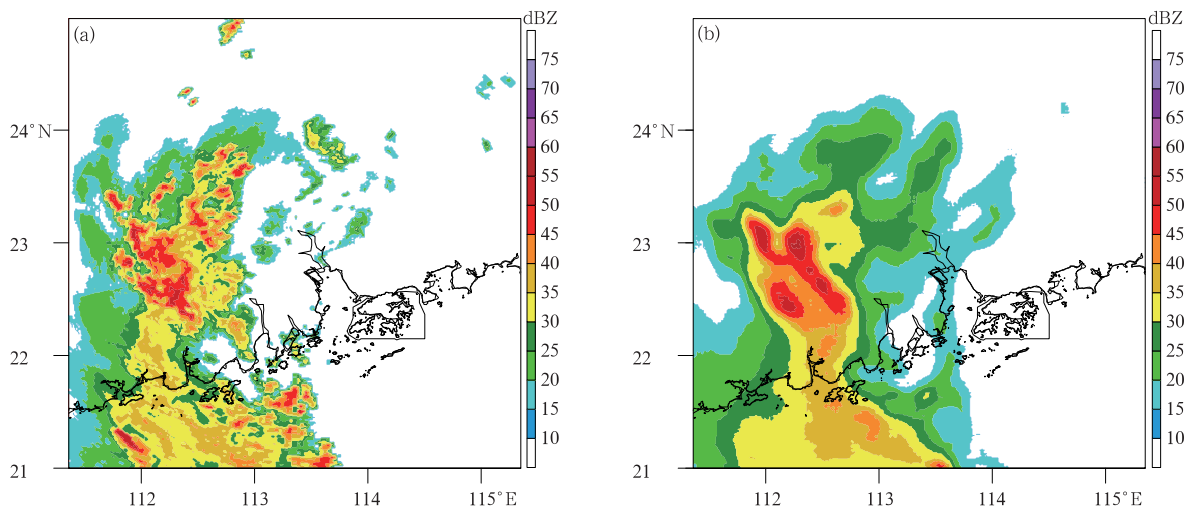


图4 2017年8月22日个例实况和预报对比

(a)21:30 广州雷达组合反射率因子,(b)预测网络法20:30起报的60 min 预报产品,

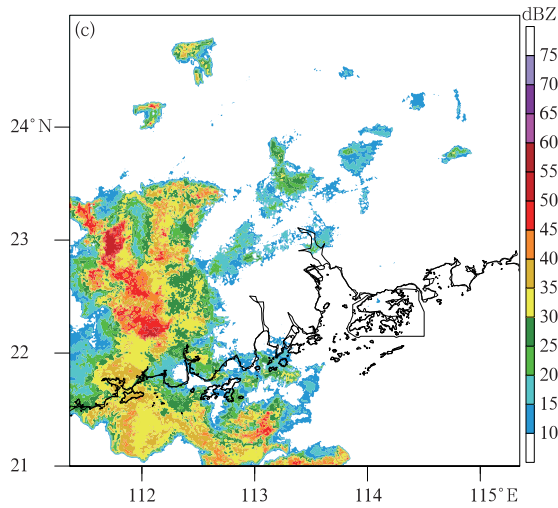
(c)交叉相关法20:30起报的60 min 预报产品

Fig. 4 Comparison between observation and forecast on 22 Aug 2017

(a)observation of composite reflectivity at 2130 BT,(b)60 min forecast at 2030 BT using PredRNN,

(c)60 min forecast at 2030 BT using COTREC





续图 4

南方向移动。对比图 4a 和图 4b 可以看到,预测网络法 60 min 预报的广东省内组合反射率因子形态完整,位置和实况基本一致,回波强度也与实况比较接近。其中,强回波中心分裂成两个相对独立的中心,与实况基本相符。在强度变化方面,广东省内的强回波范围略扩大,强度略加强和实况基本一致。但对于海上的回波,预测网络法给出了强度减弱的错误判断。对比图 4a 和图 4c 可以看到,根据交叉相关法预报结果,强回波中心已向西到达 112°E 附近,明显过快估计组合反射率因子的移动速度。

表 5 给出了两种方案的客观检验结果。同 3.3.1 节客观检验结果相似,对比检验两种方法发现,预测网络法在全部检验项目中表现更佳,CSI 高,POD 高且 FAR 低。

表 5 2017 年 8 月 22 日广州雷达检验结果

Table 5 Quantitative result of Guangzhou radar on 22 Aug 2017

检验指标	方法	60 min 预报时效		
		20 dBZ	30 dBZ	50 dBZ
CSI	预测网络	0.58	0.42	0.02
	交叉相关	0.38	0.25	0.01
POD	预测网络	0.74	0.57	0.04
	交叉相关	0.57	0.42	0.01
FAR	预测网络	0.21	0.27	0.43
	交叉相关	0.34	0.39	0.50

#### 4 小 结

本文详细介绍了预测网络模型,并以该模型为基础,进行雷达临近预报试验,并与交叉相关法进行对比,得到以下主要结论:

1) 预测网络模型是传统 LSTM-RNN 的改进版。通过加入卷积计算和空间记忆模块,预测网络模型具有较好的空间特征提取能力,是一种适合雷达临近预报应用的 RNN 网络架构。

2) 对比试验表明:相比于交叉相关法,预测网络法在 0~60 min 的雷达临近预报中,对于 20 dBZ 和 30 dBZ 检验项目,CSI 评分可以提升 0.15~0.30,POD 提高 0.15~0.25,FAR 降低 0.15~0.20。

3) 个例检验表明,预测网络法对于组合反射率因子变化有一定的预报能力。

同时,预测网络法做为一种非线性统计模型,还存在以下局限性:①该模型建立在大量历史数据的拟合上,对历史数据的数量有一定要求。而冰雹、短

时强降水、龙卷等强对流天气的历史个例不多。故该方法对于强对流天气的预报能力还需要进一步提高。②该方法的预报能力随预报时间的延长迅速下降,60 min 的预报准确率下降明显,尤其是对于强回波中心的预报准确率不高。

今后需要对预测网络模型进行进一步优化。考虑在模型的输入中增加数值预报环境场,使模型对天气形势的认识更加丰富,提高模型在回波强度演变特征方面的预测精度。另外,考虑更新 RNN 的成本函数,使用与反射率因子强度成正比的带权重的代价函数,通过提高强回波在拟合过程中的权重,提高模型对于强回波区的预报能力。

#### 参 考 文 献

- [1] 陈明轩,俞小鼎,谭晓光,等. 对流天气临近预报技术的发展与研究进展. 应用气象学报,2004,15(6):754-766.
- [2] 石宝灵,王红艳,刘黎平. 云南多普勒天气雷达网探测冰雹的覆盖能力. 应用气象学报,2018,29(3):270-281.
- [3] 陈雷,戴建华,陶岚. 一种改进后的交叉相关法(COTREC)在降水临近预报中的应用. 热带气象学报,2009,25(1):117-122.

- [4] 张蕾,魏鸣,李南,等.改进的光流法在回波外推预报中的应用.科学技术与工程,2014,32:133-137.
- [5] Neill E H B, Clive E P, Alan S. Development of a precipitation nowcasting algorithm based upon optical flow techniques. *J Hydrol*, 2004, 288: 74-91.
- [6] 郑永光,周康辉,盛杰,等.强对流天气监测预报预警技术进展.应用气象学报,2015,26(6):641-657.
- [7] Germann U, Zawadzki I. Scale-dependence of the predictability of precipitation from continental radar images. Part I: Description of the methodology. *Mon Wea Rev*, 2002, 130: 2859-2873.
- [8] 王改利,赵翠光,刘黎平,等.雷达回波外推预报的误差分析.高原气象,2013,32(3):874-883.
- [9] 陈明轩,王迎春,俞小鼎.交叉相关外推算法的改进及其在对流临近预报中的应用.应用气象学报,2007,18(5):690-701.
- [10] 孙志远,鲁成详,史忠植,等.深度学习研究与进展.计算机科学,2016,43(2):1-8.
- [11] 余凯,贾磊,陈雨强,等.深度学习的昨天、今天和明天.计算机研究与发展,2013,50(9):1799-1804.
- [12] 陆虹,翟盘茂,覃卫坚,等.低温雨雪过程的粒子群-神经网络预报模型.应用气象学报,2015,26(5):513-524.
- [13] 卢新玉,魏鸣,王秀琴. TRMM月降水量产品在新疆地区的订正.应用气象学报,2017,28(3):379-384.
- [14] 金莲文,钟卓耀,杨钊,等.深度学习在手写汉字识别中的应用综述.自动化学报,2016,42(8):1124-1141.
- [15] Shi X, Chen Z, Wang H, et al. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. NIPS, 2015: 802-810.
- [16] Li P W, Wong W K, Chan K Y, et al. SWIRLS—An Evolving Nowcasting System. Technical Note, 100. Hongkong Observatory, 2000.
- [17] Wang Y, Long M, Wang J, et al. PredRnn: Recurrent Neural Networks for Predictive Learning Using Spatiotemporal LSTM. Advances in Neural Information Processing Systems, 2017: 879-888.
- [18] Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735-1780.
- [19] Sutskever I, Vinyals O, Le Q V. Sequence to Sequence Learning with Neural Networks. NIPS, 2014: 3104-3112.
- [20] Pascanu R, Mikolov T, Bengio Y. On the Difficulty of Training Recurrent Neural Networks. ICML, 2013: 310-318.
- [21] 韩丰,魏鸣,李南,等.反射率因子和径向速度共同约束反演多普勒雷达风场.遥感学报,2013,17(3):584-589.
- [22] 吴涛,万玉发,沃伟峰,等. SWAN系统中雷达反射率因子质量控制算法及其应用.气象科技,2013,41(5):809-817.
- [23] 孙赫敏.雷达回波中零度层亮带的研究.北京:中国气象科学研究院,2014.
- [24] 曹杨,陈洪滨,苏德斌. C波段双线偏振天气雷达零度层亮带识别和订正.应用气象学报,2018,29(1):84-96.
- [25] 韩丰,沃伟峰. SWAN2.0系统的设计与实现.应用气象学报,2018,29(1):25-34.
- [26] 谢超,马学款. 2017年8月大气环流和天气分析.气象,2017,43(11):1446-1452.



## The Application of Recurrent Neural Network to Nowcasting

Han Feng<sup>1)</sup> Long Mingsheng<sup>2)</sup> Li Yuean<sup>1)</sup> Xue Feng<sup>1)</sup> Wang Jianmin<sup>2)</sup>

<sup>1)</sup> (National Meteorological Center, Beijing 100081)

<sup>2)</sup> (School of Software, Tsinghua University, Beijing 100084)

### Abstract

Radar extrapolation is an important means in nowcasting. The radar extrapolation methods widely used in China include COTREC and Optical Flow, by which two consecutive echoes are used to diagnose the advection velocity within rain analyses, involving the solution of Lagrangian persistence equation. A new method RNN (recurrent neural network) is applied in nowcasting. Using PredRNN (predictive RNN), by modeling historical radar data, the prediction of radar echo in the next hour is given. PredRNN consists of ST-LSTM unit, which is an improvement of LSTM. One advantage of using PredRNN is the operation of the state accumulation and the hidden layer output is replaced by convolution. Therefore, the neurons not only can get timing relationships, but also extract spatial features like convolutional layers. Another advantage is the addition of new spatial memory, which can enhance the transportation of the spatial feature information in different layers. In order to test the model performance, two radars of Daxing District of Beijing and Guangzhou are analyzed. The radar echo is pre-processed through quality controlling to remove isolated echo, abnormal echo, invalid radial and echo below 15 dBZ and ground echo, and then the combined reflectivity (CR) is made by 0–5 layers of data. To examine the applicability of the PredRNN, a contrast experiment is designed between PredRNN and COTREC, including an independent verification over months of each radar and two severe convective cases analysis. The test is carried out by point by point in three different reflectivity thresholds: 20 dBZ, 30 dBZ and 50 dBZ. Indexes of verification are CSI, POD and FAR. The time range of the test is 0–1 h by 6 min. Results show that PredRNN has better forecast performance in all the verification items especially in 20 dBZ and 30 dBZ, when the CSI can be raised by 0.15–0.30, POD can be raised by 0.15–0.25, and FAR can be reduced by 0.15–0.20. This effect of improvement enhances with time. Although forecast performances of both PredRNN and COTREC fall with time, the performance of PredRNN method descends more slowly. The forecast performances of both PredRNN and COTREC fall with the increase of the combined reflectivity factor strength, which shows the insufficient of prediction ability for the region with intensity over 50 dBZ. Two cases show that the PredRNN method has predictive ability for the change of reflectivity factor intensity. In summary, PredRNN is suitable for nowcasting, and its forecast performance is much better than COTREC.

**Key words:** nowcasting; recurrent neural network; deep learning