

基于深度学习的天气雷达回波序列外推及效果分析*

黄兴友^{1,2} 马玉蓉² 胡苏蔓²
HUANG Xingyou^{1,2} MA Yurong² HU Suman²

1. 南京信息工程大学气象灾害预报预警与评估协同创新中心, 南京, 210044

2. 南京信息工程大学, 南京, 210044

1. *Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters, Nanjing University of Information Science and Technology, Nanjing 210044, China*

2. *Nanjing University of Information Science and Technology, Nanjing 210044, China*

2021-01-15 收稿, 2021-04-30 改回.

黄兴友, 马玉蓉, 胡苏蔓. 2021. 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, 79(5): 817-827

Huang Xingyou, Ma Yurong, Hu Suman. 2021. Extrapolation and effect analysis of weather radar echo sequence based on deep learning. *Acta Meteorologica Sinica*, 79(5):817-827

Abstract Weather radar data is the main reference for nowcasting of severe convective weather. To address the problems of insufficient data utilization and limited extrapolation time in the radar echo extrapolation method widely used in China, the neural network is applied to radar echo extrapolation. The predictive neural network model gives 2 h prediction results of radar echo variation. The essence of radar echo extrapolation problem is the spatiotemporal sequence prediction problem. The network has long and short time memory unit (Long Short-Term Memory, LSTM) to solve the time memory problem and convolutional layers to extract spatial features. The training and testing datasets are constructed using radar data from Fujian, Jiangsu and Henan for several years. Considering the fact that the frequencies of different rainfall levels are highly imbalanced, the network is trained by weighted loss function to improve the prediction accuracy of strong echoes. The test set and individual case evaluation show that CSI (Critical Success Index) and POD (Probability Of Detection) of predictive neural network are higher than that of optical flow method and FAR (False Alarm Ratio) is lower than that of optical flow method under the same extrapolation aging and reflectivity threshold. Among different precipitation types, the SSIM (structural similarity) value of the predictive neural network is higher than that of the optical flow method, and the SSIM value of the stratiform-cloud precipitation is larger than that of the convective-cloud precipitation. Therefore, the predictive neural network has a better ability to predict strong echoes than optical flow. In terms of the timeliness of forecasting, the predictive neural network model has certain advantages, and it is more accurate in forecasting stratiform-cloud precipitation than forecasting convective-cloud precipitation.

Key words Nowcasting, Recurrent neural network, Convolutional neural network, Loss function, Deep learning

摘要 天气雷达探测资料是进行强对流天气临近预报的主要参考数据。针对传统雷达回波外推方法中存在资料信息利用率不足和外推时效有限的问题, 文中利用神经网络进行雷达回波的外推、利用预测神经网络模型进行 2 h 以内的回波变化预报。回波外推问题的关键是回波时、空序列预测问题, 该网络具有解决时间记忆问题的长、短时记忆单元 (Long Short-Term Memory, LSTM) 和提取空间特征的卷积模块。应用福建、江苏和河南多年的雷达探测资料构造训练和测试数据集。为消除降水的不平衡和提高对强回波的预报准确率, 网络采用带权重的损失函数进行训练。对光流法和预测神经网络进行测试集检验以及个例分析, 结果表明, 在相同外推时效和检验反射率阈值的情况下, 预测神经网络的临界成功指数、命中率均高于光流法, 虚警率低

* 资助课题: 国家重点研发计划项目“重大自然灾害监测预警与防范”(2018YFC1506102)、中国航空工业集团公司雷华电子技术研究所项目(MJ-2018-S-28)。

作者简介: 黄兴友, 主要从事大气探测及雷达气象研究。E-mail: huangxy@nuist.edu.cn, hxyradar@126.com

于光流法。不同类型降水预测神经网络的 SSIM 值 (structural similarity) 均高于光流法, 且层状云降水的 SSIM 值比对流云降水的大。因此, 预测神经网络对强回波的预报能力高于光流法; 在预报时效性上, 预测神经网络模型具有一定的优越性; 预测神经网络对层状云降水预报的准确率比对流云降水的高。

关键词 雷达临近预报, 循环神经网络, 卷积神经网络, 损失函数, 深度学习

中图法分类号 P407.8

1 引言

临近预报是指对 0—2 h 的短时间内天气现象变化的预报 (Browning, 1982)。天气雷达探测资料具有较高的时间和空间分辨率, 成为临近预报的主要工具。传统的雷达回波外推方法主要有交叉相关算法 (Tracking Radar Echoes by Correlation, TREC) (Li, et al, 1995)、单体质心法 (The Storm Cell Identification and Tracking, SCIT) (Witt, et al, 1993) 和光流法 (Optical Flow) (Ayzel, et al, 2019)。TREC 是通过计算雷达回波资料在连续时次的空间最优相关, 得到对流系统不同位置的移动矢量特征, 并基于这些获得的移动矢量对雷达回波进行外推预报 (陈明轩等, 2007), 该方法对变化较快的对流性降水的预报效果差, 张亚萍等 (2006) 提出了一种基于差分图像的相关方法追踪雷达回波运动 (Difference Image based Tracking Radar Echo by Correlations, DITREC), 消除了 TREC 矢量场中由于回波快速变化而导致的无序矢量, 在使用导出的 DITREC 场预报降水场时, 其精度依赖于所采用的 Z-I 关系。SCIT 主要用于雷暴单体的识别追踪, 其在识别了三维雷暴单体后对单体质心路径进行追踪, 适用于对强雷暴单体的追踪和临近预报 (俞小鼎等, 2012), 但丢失了弱回波信息。光流法是通过计算雷达回波的光流场得到回波的运动矢量场, 并基于运动矢量场对雷达回波进行外推。该方法与交叉相关算法不同之处在于光流法立足于变化, 而不是选定不变特征 (曹春燕等, 2015), 但是其在计算光流矢量和外推两步时存在累积误差。这些方法仅根据若干个时刻的雷达回波图像推测下一时刻的回波位置, 且忽略了实际情况下雷达回波中的中小尺度大气系统的运动非线性, 存在对历史雷达资料利用率不足和外推时效较短的局限。

针对上述传统方法存在的问题, 引入神经网络进行雷达回波的外推, 神经网络模型具有强大的非线性映射能力, 且对数据的利用率大幅度提高 (高隼, 2003)。将神经网络应用于临近预报, 目前还处

于起步阶段, 中外学者在这方面展开了一定的探索。冯汉中等 (2004) 运用支持向量机 (Support Vector Machine, SVM) 实现了降水量的预报。陈家慧等 (2000) 尝试将 BP 神经网络模型应用于雷达回波的临近预报中, BP 模型较好的记忆联想功能展现了运用神经网络进行雷达资料外推的可行性。郭尚瓚等 (2017) 将多层感知器 (Multilayer Perceptron, MLP) 和光流法两个模式集成后实现了预测某区域 36 min 内的降雨概率。郭瀚阳等 (2019) 使用卷积 GRU (Gated Recurrent Unit, 门控循环单元) 对雷达回波进行外推, 并与传统雷达回波区域跟踪外推临近预报方法 (TREC) 进行效果对比, 结果表明, 深度学习模型更具有优势。Klein 等 (2015) 在传统卷积神经网络 (Convolutional Neural Networks, CNNs) 结构上增加了动态卷积层, 生成两个预测概率向量实现对降水回波的预测。施恩等 (2018) 在 Klein 等 (2015) 提出的动态卷积层的基础上加入循环神经网络 (Recurrent Neural Network, RNN) 构建了循环动态卷积神经网络 (Recurrent Dynamic Convolutional Neural Networks, RDCNN), 该网络在预报准确率和预报时效两方面均取得较好效果。传统的长、短时记忆单元 (Long Short-Term Memory, LSTM) 无法实现对空间特征的提取, 针对这个问题, Shi 等 (2015) 将输入到状态及状态到状态之间的变化改为卷积操作, 提出了卷积 LSTM (ConvLSTM) 网络, 为了适应实际情况中大部分运动的非时、空恒定, Shi 等 (2017) 改进了模型, 引入具有可学习卷积的 TrajGRU (轨迹 GRU) 模型。Singh 等 (2017) 也通过在循环神经网络的基础上增加卷积结构来适应雷达回波图像的时、空依赖性, 实现了基于雷达回波图像序列的预测。韩丰等 (2019) 对采用神经网络和相关交叉算法进行雷达临近预报的长期和个例检验结果表明, 神经网络在 20 dBz 和 30 dBz 检验项上的准确率显著提高。Wang 等 (2017) 提出了基于 LSTM 单元改进的 ST-LSTM 单元 (Spatiotemporal LSTM), 并将其应用于一个新的端到端模型 Predrnn。Agrawal 等 (2019)

将降水预报看作由图片至图片的转换问题, 并利用一种 U-net 结构的卷积神经网络来实现预报目的, 是一种利用数据驱动、完全不使用大气物理模型来建立的短时临近降水预报模型。Sønderby 等 (2020) 开发的模型 MetNet 可以预测未来 8 h 内的降水量。神经网络模型具有一定的通用性, 雷达回波外推问题同时可以类比于视频帧画面内容的预测问题, Lotter 等 (2016) 提出的采用 CNN+LSTM 结构设计的 PredNet, 可以很好地学习视频的特征、并可用于雷达回波的外推预报。Wang 等 (2019) 将三维卷积和 RNN 集成为 Eidetic 3D LSTM 单元, 使得该网络具有较好的对早期活动的识别能力。张德正等 (2019) 通过加深由卷积门控循环单元 (GRU) 构成的神经网络中的卷积层来提升对空间结构信息细节的表征能力, 该网络不仅可以实现视频帧的预测还可以实现对雷达回波的外推预测。

本研究采用带有 Causal-LSTM 单元组成的神经网络模型 (Wang, et al, 2018) 作为网络架构实现雷达回波的外推。为消除降水的不平衡和提高对强回波的预测准确率, 使用带权重的损失函数训练网络模型, 在训练过程中赋予强回波较大的权重来提升对强回波区域的预报能力, 并通过测试集和 4 个个例对该预测神经网络和光流法进行对比评估。

2 方法

2.1 循环神经网络

循环神经网络是一类以序列数据为输入, 在序列的演进方向进行递归且所有节点 (循环单元) 按链式连接的递归神经网络 (Goodfellow, et al, 2016)。该网络包括前馈通路和反馈通路, 由于反馈通路的存在, 神经元的输出信号经过一个或几个时间步长之后能够重新作为其他神经元或自身输入, 进而增强了网络处理时间序列的能力。图 1 为一个简单的循环神经网络结构。

图中, x 是神经网络的输入, y 是神经网络的输出, h 是神经网络隐含层的输出, u 是输出层到隐含层的权重矩阵, v 是隐含层到输出层的权重矩阵, w 是记忆单元到隐含层的权重矩阵。计算公式如下

$$h_t = f(u \cdot x_t + w \cdot h_{t-1}) \quad (1)$$

$$y_t = g(v \cdot h_t) \quad (2)$$




图 1 循环神经网络

Fig. 1 Recurrent neural network

式中, f 、 g 表示激励函数, x_t 是当前时刻的输入, h_{t-1} 是前一时刻隐含层的输出, h_t 是当前时刻隐含层的输出, y_t 是当前时刻网络的输出。

2.2 网络模型

本研究采用带有 Causal LSTM 单元组成的神经网络模型作为网络架构。Causal LSTM 单元包含两个记忆状态: 时间记忆单元 (C_t^k) 和空间记忆单元 (M_t^k), Causal LSTM 由三个级联部分组成, 第 1 个级联用于更新时间记忆单元, 第 2 个级联用于更新空间记忆单元, 之后将更新后的 C_t^k 、 M_t^k 和输入 x_t 共同传入第 3 个级联后输出该时刻的隐含层 H_t^k 。

与传统 LSTM 单元相比, 其优点在于: ①输入与状态以及状态与状态的转化改变为卷积操作, 整个网络就可以在解决时间依赖问题的同时提取图像的空间特征; ②三个级联的形式加深了网络的深度, 增加更多的非线性操作使得特征放大, 更有利于捕捉短期动态变化和突发情况。

除了短期的动态变化特性外, 由于较长的传播, Causal LSTM 会遭受梯度反向传播的困扰, 时间记忆单元 (C_t^k) 可能会忘记过去的空间特征。为解决这一问题, 网络模型中加入梯度高速公路单元 (Gradient Highway Unit, GHU) 解决梯度消失的问题。GHU 的输入为目前的更低一层的输出和前一个时刻 GHU 的输入, 即 GHU 连接了当前时刻以及前一个时刻的输入。GHU 的加入使梯度不再是一条线传播, 而是直接在第 1 层与第 2 层之间有个高速的传播。换言之, 传播的距离缩短了。基于此, 整个网络能够自适应地捕捉长期和短期的特征并且能够建立较深的网络进行学习。

2.3 损失函数

雷达回波外推的主要目的是实现降水回波特征变化的临近预报, 利用深度学习进行雷达回波外推虽然取得了一些令人惊喜的结果, 但仍旧处于起

步阶段,行业内尚未达成对该种模型评判的统一标准。在现有的神经网络预测降水模型中,多使用单一阈值判别降雨与否(Shi, et al, 2015)。不同强度的降水对人类活动产生的影响程度均不同,例如强降水出现的频率低但是影响较大,考虑到这种不平衡性,Shi等(2017)将雨强划分为6个等级,并给不同强度的降水赋予不同的权重。

在雷达定量测量降水的过程中,雷达反射率因子与雨强存在统计关系: $Z=AI^b$, 其中 I 为雨强, 单位 mm/h, A 、 b 为两个统计常数。 Z - I 关系不仅随地点、季节以及降水类型而变,即使在同一次降水过程中, A 、 b 值也是随时间和空间而变化的。降雨预测的准确度依赖于雷达回波外推的准确度,即对降水预测模型的评估归结为对雷达反射率因子外推准确率的评估。在雷达气象学中,一般层状云降水的雷达反射率因子在 20—30 dBz, 对流云降水一般不低于 40 dBz, 因此,参考 Shi 等(2017)的雨强分级方案,对不同区间的雷达反射率因子赋予不同的权重,即根据每个像素点的雷达反射率因子大小分配权重。为消除降水的不平衡并提高对强回波的预报能力,对强回波赋予更大的权重以提高其在拟合过程中的影响程度,使其达到更好的收敛。

雷达图像每个像素点的回波强度(单位: dBz)的有效预测数值在 $[0, 75]$ 。将雷达图像有效预测数值划分为 5 个等级,第 1 级的取值区间为 $[0, 20]$ (无雨或毛毛雨);第 2 级的对应取值区间为 $(20, 30]$ (小雨);第 3 级的取值区间为 $(30, 40]$ (中雨);第 4 级的取值区间为 $(40, 50]$ (大雨、暴雨);第 5 级的取值区间为 $(50, 75]$ (特大暴雨)。对不同级别的雷达反射率因子分配不同的权重。在此采用的权重为

$$w(x) = \begin{cases} 1 & x \in [0, 20] \\ 10 & x \in (20, 30] \\ 15 & x \in (30, 40] \\ 30 & x \in (40, 50] \\ 50 & x \in (50, 75] \end{cases} \quad (3)$$

式中, $w(x)$ 表示权重大小, x 表示像素点的回波数值。

本研究的预测神经网络采用的损失函数为带权重的均方误差 (E_s) 和带权重的平均绝对误差 (E_a), 表达式如下

$$E_s = \frac{1}{n} \sum_{n=1}^N \sum_{i=1}^{400} \sum_{j=1}^{400} w_{n,i,j} (x_{n,i,j} - \hat{x}_{n,i,j})^2 \quad (4)$$

$$E_a = \frac{1}{n} \sum_{n=1}^N \sum_{i=1}^{400} \sum_{j=1}^{400} w_{n,i,j} |x_{n,i,j} - \hat{x}_{n,i,j}| \quad (5)$$

式中, N 为外推的总时间步长(每个步长是 6 min), $w_{n,i,j}$ 表示第 n 时刻第 (i, j) 像素点的权重, $x_{n,i,j}$ 表示真实值, $\hat{x}_{n,i,j}$ 表示预测值。

在实际试验中,采用的损失函数为 E_s 与 E_a 之和。

3 数据集构造

3.1 数据质量控制

试验使用福建、江苏、河南的新一代 S 波段多普勒天气雷达探测资料,该雷达有效探测距离为 230 km, 波束宽度为 1.0° , 反射率因子的距离库长为 1 km。为确保样本数据的质量,首先对体扫反射率因子数据进行质量控制,质量控制包括滤除孤立噪声点与填补缺测值、剔除地物杂波和滤波平滑(庄薇等, 2012; 黄兴友等, 2018; 马雷, 2018)三个方面。

3.2 雷达数据格点化

新一代天气雷达基数据采用极坐标的存储方式,空间分辨率不均匀,近距离的空间分辨率高,远距离的空间分辨率低。为了方便后续的研究,首先根据肖艳姣(2006)提到的方法将极坐标存储下的数据采用径向和方位上的最近邻居法与垂直线性内插法插值到三维笛卡尔坐标系下,网格水平分辨率为 $1 \text{ km} \times 1 \text{ km}$, 垂直分辨率也为 1 km, 生成的 CAPPI 图像分辨率为 460×460 。考虑到对流层中代表性平均引导气流的高度,其样本选用垂直高度为 3 km 处的 CAPPI 图像。

3.3 样本数据集的生成

训练时采用灰度图像可以提升训练的效率,因此将 CAPPI 图像处理为 PNG 格式存储的灰度图像,再对 CAPPI 灰度图像进行裁剪处理,保留图像中心的 400×400 区域。由于样本质量会对训练结果造成影响,面积过小的回波一般弱且演变快,对预报工作无太强指导意义,因此在样本数据集构造过程中,对个例进行筛选,将雷达有效探测范围内回波面积覆盖率大于 $1/10$ 的个例选入样本数据集。样本中每个时次保存为一张 PNG 格式的 CAPPI 回波强度灰度图像,每组样本覆盖时长为 4 h (输入时长 2 h, 预测时效 2 h), 每组样本中图像的时间间隔为 6 min, 即每组样本共有 40 幅雷达图像 $\{x_1, x_2, x_3, \dots, x_{20}, y_1, y_2, y_3, \dots, y_{20}\}$, 其中 $\{x_1, x_2, x_3, \dots, x_{20}\}$ 为输入

图像序列, $\{y_1, y_2, y_3, \dots, y_{20}\}$ 为预测图像的标签。雷达回波的数据范围是 0—75 dBz。图 2 为数据集构造

流程。图 3 为数据集中一组样本可视化后的图像, x_1-x_{20} 是输入图像, y_1-y_{20} 是对照标签。

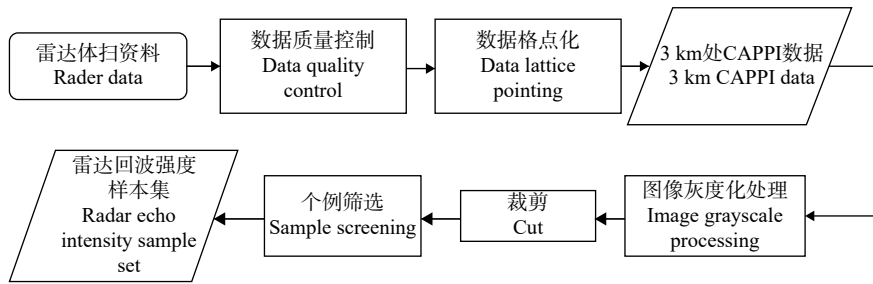


图 2 数据集构造流程

Fig. 2 Process of constructing data sets




图 3 数据集中一组样本可视化后图像

Fig. 3 A group of visualized sample images in the dataset

4 试验结果与分析

4.1 模型评价指标

对测试集的检验采用分阈值和预报时效的评估方法, 使用 20、30、40、50 dBz 作为判别阈值, 预报时长为 120 min, 每个预报时间步长为 6 min, 使用的评价指标为临界成功指数 (CSI)、命中率 (POD)、虚警率 (FAR)。将预测值与观测值进行逐点对比, 判别每个像素点是命中点 (预测值与真值均大于判别阈值)、空报点 (预测值大于判别阈值而真实值小于判别阈值) 或漏报点 (预测值小于判别阈值而真实值大于判别阈值)。a、b、c 分别表示预测图像中的命中数、空报数和漏报数, 三个评估指标的计算公式如下

$$CSI = \frac{a}{a+b+c} \quad (6)$$

$$POD = \frac{a}{a+c} \quad (7)$$

$$FAR = \frac{b}{a+b} \quad (8)$$

在个例检验中采用结构相似性 (SSIM) (Wang, et al, 2004) 来衡量两幅图像的相似度, SSIM 从灰度、对比度和结构三个方面来估计降质图像的视觉质量。SSIM 的计算公式如下

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (9)$$

式中, x 、 y 为两张图像的像素值, μ_x 为 x 的均值, μ_y 为

y 的均值, σ_x^2 为 x 的方差, σ_y^2 为 y 的方差, σ_{xy} 为 x 和 y 的协方差, $C_1 = (K_1L)^2$ 、 $C_2 = (K_2L)^2$, L 是像素值的动态范围, 文中的变化范围是0—75, $K_1 = 0.01$, $K_2 = 0.03$ 。结构相似性的范围为0到1, SSIM值越大, 表明两幅图越相似, 当两张图一模一样时, SSIM=1。

4.2 测试集检验

试验的数据集由训练集和测试集组成, 采用的试验数据集为福建2018年6—9月、2019年6—9月, 江苏2018年6—9月、2019年6—9月, 河南2017年5—9月、2018年6—9月、2020年6—9月SA雷达体扫资料。表1给出了光流法和预测神经网络在测试集上的指标评估结果。两个网络分别在30、60、90、120 min外推时效下对20、30、40、50 dBz这4个反射率阈值进行检验。由表1可知, 在相同预报时效的情况下, 4个反射率检验阈值的临界成功指数、命中率均表现为: 预测神经网络优于光流法, 虚警率表现为预测神经网络优于光流法。随着预报时效的延长, 两个模型在相同检验阈值的情况下, 均表现为临界成功指数、命中率随着时间延长而下降, 虚警率随着时间延长而上升, 这表明随着时间的推移, 两个模型的预报准确率都在下降。从表1中也可以看出, 同一模型在相同预报时效的情况下, 对越强回波的预报准确率越低, 但

是使用带权重的损失函数训练的预测神经网络模型在40 dBz和50 dBz检验阈值项上, 临界成功指数、命中率较光流法均有所提高, 虚警率有所下降, 表明预测神经网络对强回波的预报能力高于光流法。

4.3 个例分析

4.3.1 层状云降水过程1

个例为河南2017年5月3日发生的一次层状云降水过程, 运用前2 h的雷达图像预报2 h降水情况。图4为预报时效为6、30、60、90、120 min的地面实况、光流法预测结果和预测神经网络的外推结果, 从地面实况(图4a—c)可以看出, 随着时间的推移, 降水过程的30 dBz回波面积略有减小, 光流法(图4f—j)在预报过程中, 回波形态基本没有变化, 而预测神经网络的回波(图4k—o)体现出了30 dBz回波略有减小的趋势。从两个模型预测图像与地面实况图像的结构相似性对比结果(图5)可以看出, 在最初的约12 min内光流法的预报效果优于预测神经网络, 但是其预测准确率下降较快, 而预测神经网络在预测准确率上一直保持着相对较高的水平。

4.3.2 层状云降水过程2

个例为河南2018年6月18日发生的一次层状云降水过程, 运用前2 h的雷达图像预报2 h降水情

表1 测试集指标检验
Table 1 Quantitative result of testing set

评估指标 模型	临界成功指数		命中率		虚警率		
	光流法	预测神经网络	光流法	预测神经网络	光流法	预测神经网络	
30 min	20 dBz	0.524	0.678	0.665	0.791	0.307	0.174
	30 dBz	0.369	0.534	0.519	0.678	0.451	0.285
	40 dBz	0.172	0.255	0.277	0.322	0.693	0.449
	50 dBz	0.022	0.156	0.038	0.255	0.936	0.713
60 min	20 dBz	0.404	0.588	0.551	0.713	0.423	0.229
	30 dBz	0.246	0.394	0.379	0.572	0.604	0.441
	40 dBz	0.075	0.134	0.136	0.262	0.855	0.785
	50 dBz	0.005	0.052	0.011	0.161	0.983	0.828
90 min	20 dBz	0.329	0.513	0.472	0.667	0.504	0.310
	30 dBz	0.181	0.301	0.296	0.548	0.691	0.599
	40 dBz	0.042	0.056	0.082	0.093	0.915	0.876
	50 dBz	0.002	0.018	0.005	0.026	0.992	0.944
120 min	20 dBz	0.272	0.475	0.311	0.582	0.569	0.346
	30 dBz	0.140	0.231	0.244	0.393	0.749	0.641
	40 dBz	0.027	0.042	0.058	0.072	0.943	0.908
	50 dBz	0.001	0.006	0.003	0.011	0.996	0.986

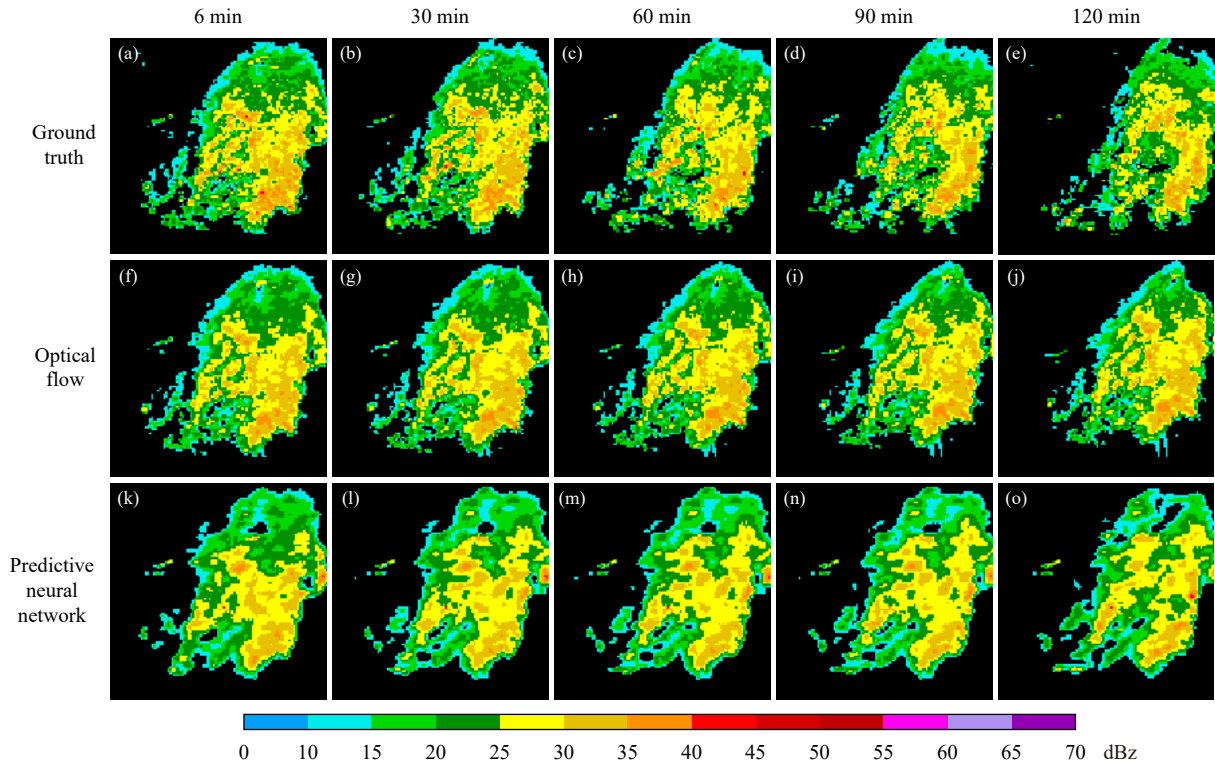


图4 2017年5月3日层状云降水地面实况与模型预报结果
 Fig. 4 Comparison between ground truth and forecast on 3 May 2017

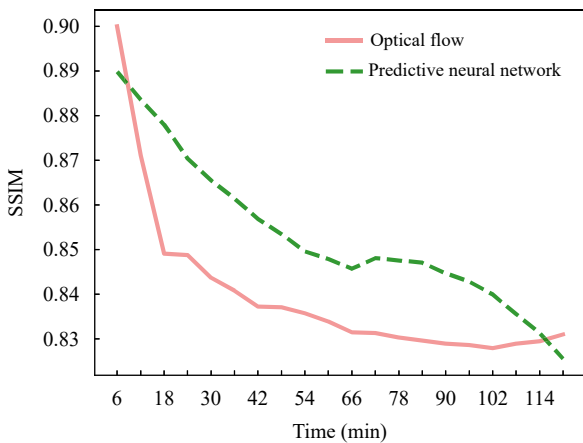


图5 模型预报结果与地面实况的SSIM
 Fig. 5 SSIM of model predicted results and ground truth

况。图6给出预报时效为6、30、60、90、120 min的地面实况、光流法预测结果和预测神经网络的外推结果，由于层状云降水回波变化较为缓慢，在预报30 min时间内，两个模型的预报准确率均较高。可以从地面实况(图6a—e)中看出左下角的小面积回波随着时间推移存在分裂现象，光流法的预报结果(图6f—j)并未体现这种变化的趋势，但是预测

神经网络(图6k—o)成功预报出了这种回波的变化趋势。从两个模型预测图像与地面实况图像的结构相似性对比结果(图7)可以看出，在最初24 min预报时效内，光流法的预报结果要优于预测神经网络，但是在预报时效30 min后准确率下降幅度较大，而预测神经网络的预报准确率虽然随着预报时效的推移有所下降，但SSIM一直保持在0.8左右。从预报时效上看，预测神经网络较光流法更具有优越性。

4.3.3 对流云降水过程1

选取河南2020年6月24日发生的一次飑线天气过程，运用前2 h的雷达图像预报2 h降水情况。图8为预报时效为6、30、60、90、120 min的地面实况、光流法预测结果和预测神经网络的外推结果，通过对比预测图像与地面实况(图8a—e)，预测神经网络(图8k—o)与实况相态上的相似度较高，光流法(图8f—j)在半小时后形变较为严重，且该方法预测的回波位置较实际偏右，而预测神经网络在预报位置上与地面实况对应较好。从两个模型预测图像与地面实况图像的结构相似性对比结果(图9)可以看出，两个模型在最初的18 min内都具

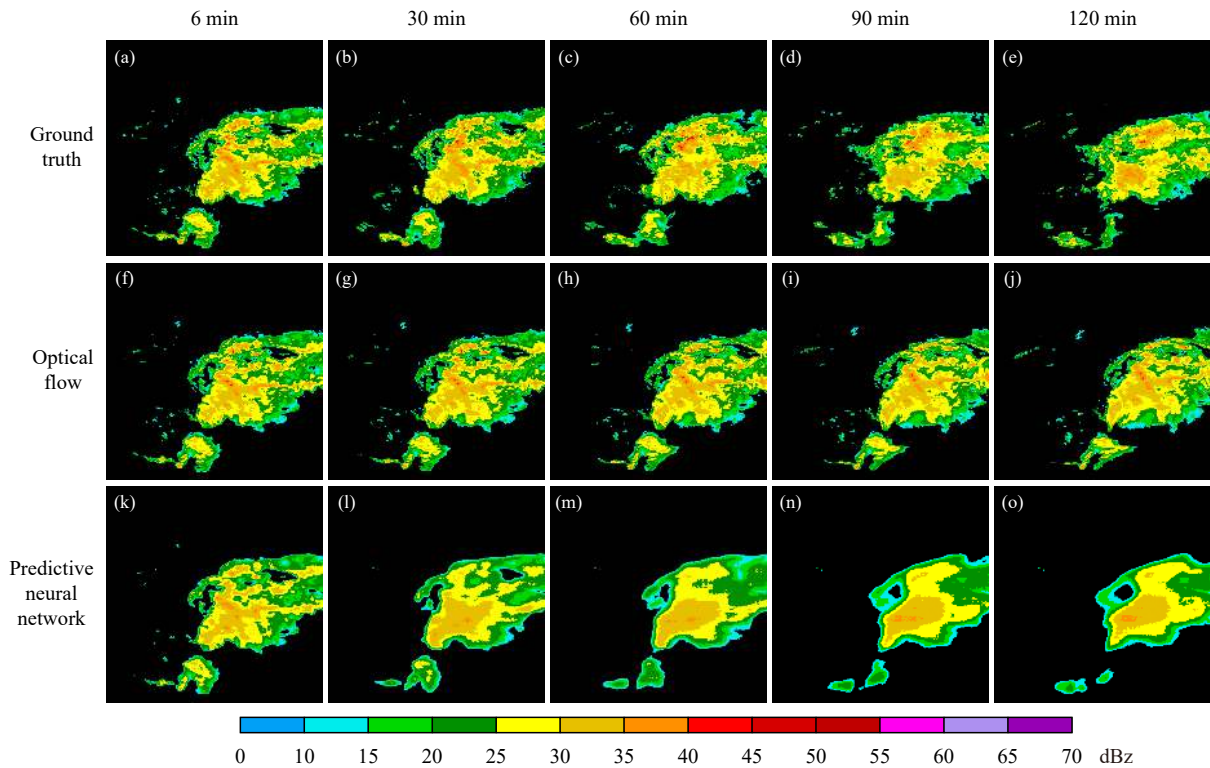


图6 2018年6月18日层状云降水地面实况与模型预报结果
Fig. 6 Comparison between ground truth and forecast on 18 June 2018

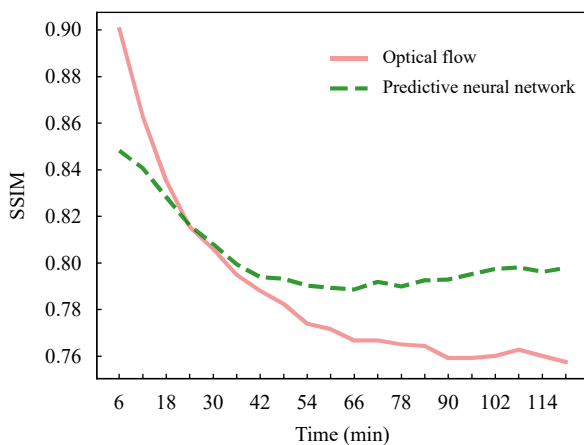


图7 模型预报结果与地面实况的 SSIM
Fig. 7 SSIM of model predicted results and ground truth

有较高的预测准确率,但随着预测时间的推移,预测神经网络的 SSIM 始终高于光流法。

4.3.4 对流云降水过程 2

选取 2018 年 8 月 18 日发生在福建的一次对流云降水过程,运用前 2 h 的雷达图像预报后 2 h 的降水情况。图 10 给出预报时效为 6、30、60、90、120 min 的地面实况、光流法预测结果和预测神经

网络的外推结果,本次的对流云降水雷达回波强度最强超过 50 dBz,且持续时间较长。从地面实况(图 10a—e)可以看出,强回波为块状且面积一直保持一定的大小。光流法预测的图像(图 10f—j)中,在预报时效 60 min 时,就出现了较大的形变,呈现出明显的分支状,但此时预测神经网络外推的雷达回波(图 10k—o)中强回波为块状且保持一定的面积大小。但是预测神经网络在 90、120 min 预报时间段内强回波预测的位置较实际偏右,说明该预测神经网络虽然在强回波的预测上较光流法有所提升,但预报准确率的提升仍有一定的限制。从两个模型预测图像与地面实况图像的结构相似性对比结果(图 11)可以看出,预测神经网络的预测图像与地面实况的相似度总体高于光流法。由于强回波变化较快,两个模型对其预测结果的准确率均低于层状云降水预测结果。

5 总结与讨论

文中介绍了神经网络在雷达回波外推上的应用,并使用带有 Causal-LSTM 单元组成的网络模型作为架构,在此基础上使用带权重的损失函数训练

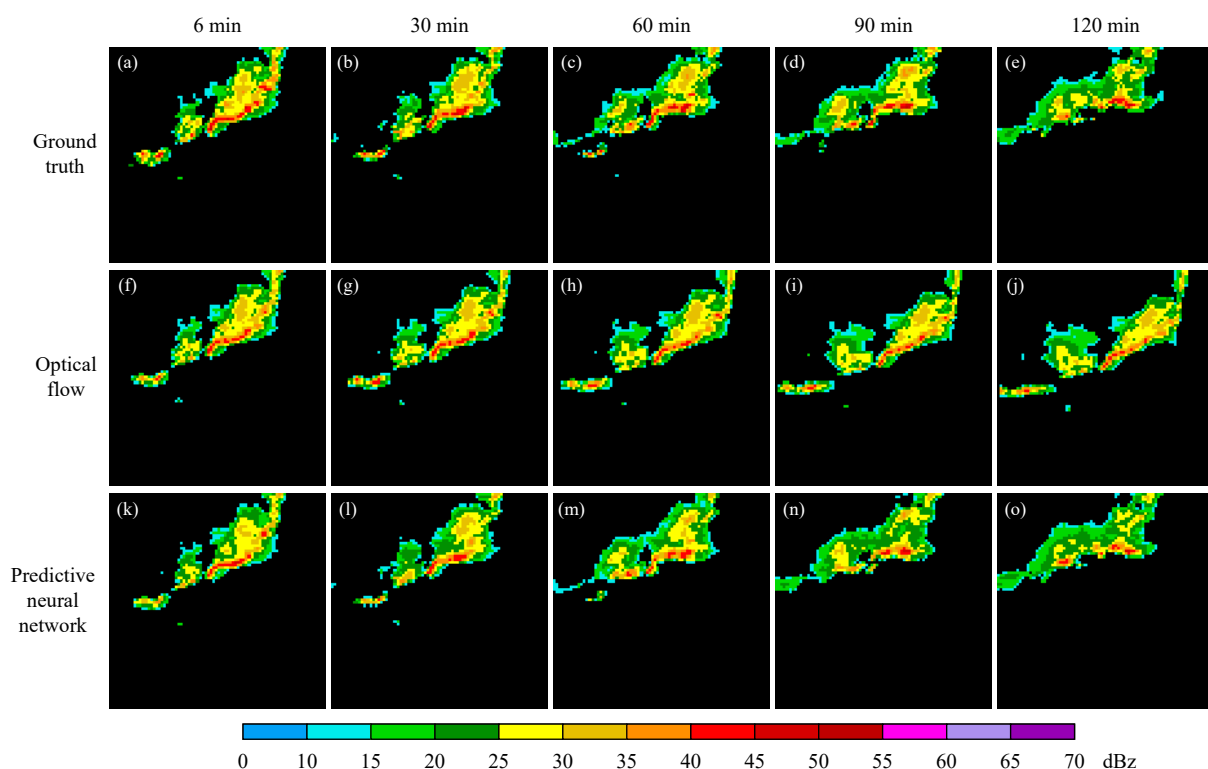


图 8 2020 年 6 月 24 日对流云降水地面实况与模型预报结果
Fig. 8 Comparison between ground truth and forecast on 24 June 2020

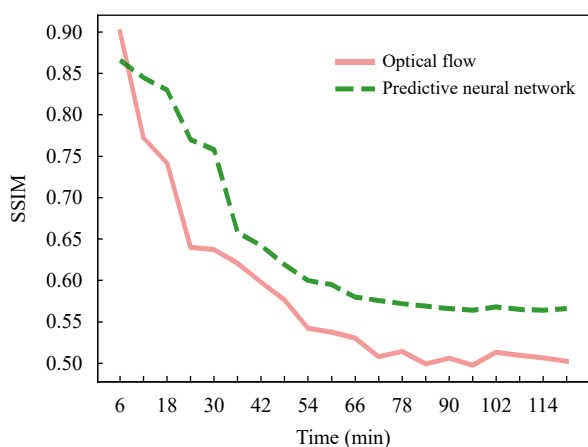


图 9 模型预报结果与地面实况的 SSIM
Fig. 9 SSIM of model predicted results and ground truth

网络模型以消除降水的不平衡性和提高强回波预报的准确度,并与光流法的预报结果进行比较,得出以下结论:

(1) 雷达回波外推的本质是时、空序列的预测问题,神经网络具有较强的非线性映射能力,可以充分利用大量的历史数据对雷达回波进行非线性外推。文中使用的预测网络模型具有提取空间特

征的卷积模块和解决时间记忆问题的改进后的 LSTM 结构单元。结果表明预测神经网络对雷达回波外推的效果优于光流法。

(2) 考虑到不同降水强度出现的频率不同,强降水对人类活动影响较大,网络在训练过程中赋予强回波较大的权重以提高对强回波的预报能力。测试集检验结果表明,预测神经网络 2 h 的回波外推在 40 和 50 dBz 检验阈值项上,临界成功指数、命中率较光流法均有所提高,虚警率有所下降,表明该网络对强回波的预报能力高于光流法。

(3) 4 个降水过程个例表明,光流法和预测神经网络对层状云降水过程的预报准确率均高于对流云降水,主要是由于层状云降水回波变化缓慢,对流云降水强回波变化较快。尽管两种临近预报方案的预报效果随预报时间的延长而下降,但是预测神经网络比光流法仍具有优越性。

(4) 基于深度学习外推的 4 个降水个例的预测雷达回波在后期出现模糊现象,可能的原因是雷达回波的预测具有不确定性,随着时间的推移,对细节的预测难度更大,因此网络会更注重回波整体形态上的演变,而丢失了细节性的纹理。

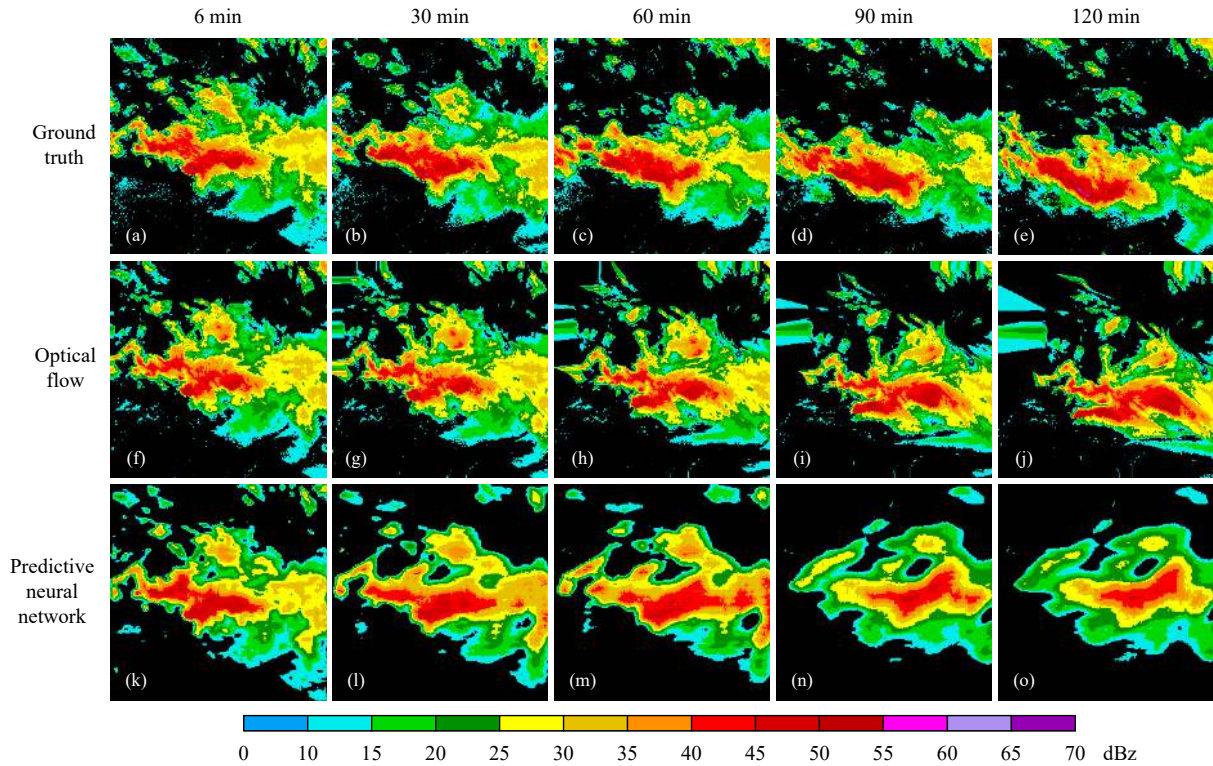


图 10 2018 年 8 月 18 日对流云降水地面实况与模型预报结果
 Fig. 10 Comparison between ground truth and forecast on 18 August 2018

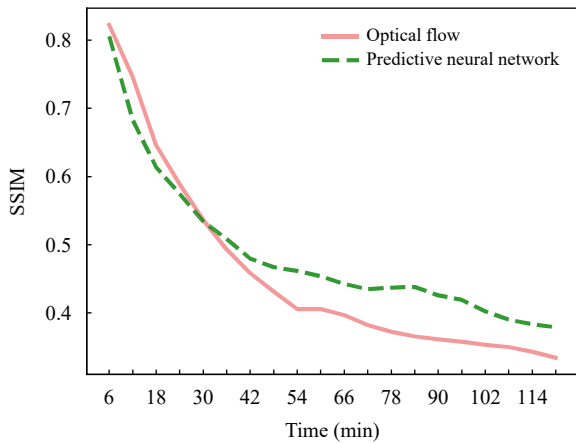


图 11 模型预报结果与地面实况的 SSIM
 Fig. 11 SSIM of model predicted results and ground truth

现在使用的预测神经网络模型的输入仅为多个时刻雷达图像的反射率因子信息,可以考虑加入风场信息及数值预报环境场,使得网络可以学习到更多的物理变化机制,对天气系统的演变可能有更好的认识,进一步提高预报的准确度。同时,类 LSTM 单元或卷积模块也可以进一步优化,可以通过加深卷积等来获取更丰富抽象的变化特征。

参考文献

曹春燕,陈元昭,刘东华等. 2015. 光流法及其在临近预报中的应用. 气象学报, 73(3): 471-480. Cao C Y, Chen Y Z, Liu D H, et al. 2015. The optical flow method and its application to nowcasting. Acta Meteorologica Sinica, 73(3): 471-480 (in Chinese)

陈家慧,张培昌. 2000. 用天气雷达回波资料作临近预报的 BP 网络方法. 南京气象学院学报, 23(2): 283-287. Chen J H, Zhang P C. 2000. The back propagation network method for nowcasting using weather radar data. J Nanjing Inst Meteor, 23(2): 283-287 (in Chinese)

陈明轩,王迎春,俞小鼎. 2007. 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, 18(5): 690-701. Chen M X, Wang Y C, Yu X D. 2007. Improvement and application test of TREC algorithm for convective storm nowcast. J Appl Meteor Sci, 18(5): 690-701 (in Chinese)

冯汉中,陈永义. 2004. 处理非线性分类和回归问题的一种新方法(II): 支持向量机方法在天气预报中的应用. 应用气象学报, 15(3): 355-365. Feng H Z, Chen Y Y. 2004. A new method for non-linear classify and non-linear regression II: Application of support vector machine to weather forecast. J Appl Meteor Sci, 15(3): 355-365 (in Chinese)

高隼. 2003. 人工神经网络原理及仿真实例, 2 版. 北京: 机械工业出版社, 13-14. Gao J. 2003. Principle and Simulation of Artificial Neural Network, 2nd ed. Beijing: Machinery Industry Press, 1-4 (in Chinese)

郭瀚阳,陈明轩,韩雷等. 2019. 基于深度学习的强对流高分辨率临近预报

- 试验. 气象学报, 77(4): 715-727. Guo H Y, Chen M X, Han L, et al. 2019. High resolution nowcasting experiment of severe convections based on deep learning. *Acta Meteor Sinica*, 77(4): 715-727 (in Chinese)
- 郭尚瓚, 肖达, 袁行远. 2017. 基于神经网络和模型集成的短时降雨预测方法. *气象科技进展*, 7(1): 107-113. Gao S Z, Xiao D, Yuan X Y. 2017. A short-term rainfall prediction method based on neural networks and model ensemble. *Adv Meteor Sci Technol*, 7(1): 107-113 (in Chinese)
- 韩丰, 龙明盛, 李月安等. 2019. 循环神经网络在雷达临近预报中的应用. *应用气象学报*, 30(1): 61-69. Han F, Long M S, Li Y A, et al. 2019. The application of recurrent neural network to nowcasting. *J Appl Meteor Sci*, 30(1): 61-69 (in Chinese)
- 黄兴友, 李盈盈, 张帅等. 2018. 基于模糊逻辑的地物回波识别方法及效果检验. *热带气象学报*, 34(3): 305-313. Huang X Y, Li Y Y, Zhang S, et al. 2018. The algorithm and verification of ground clutter identification based on fuzzy logic. *J Trop Meteor*, 34(3): 305-313 (in Chinese)
- 马雷. 2018. 双偏振雷达反射率因子数据质量控制及在拼图中的应用 [D]. 南京: 南京信息工程大学, 19-28. Ma L. 2018. Data quality control for weather radar reflectivity factor and its application in regional radar composite[D]. Nanjing: Nanjing University of Information Science and Technology, 19-28 (in Chinese)
- 施恩, 李骞, 顾大权等. 2018. 基于卷积神经网络的雷达回波外推方法. *计算机应用*, 38(3): 661-665, 676. Shi E, Li Q, Gu D Q, et al. 2018. Weather radar echo extrapolation method based on convolutional neural networks. *J Comput Appl*, 38(3): 661-665, 676 (in Chinese)
- 肖艳姣, 刘黎平. 2006. 新一代天气雷达网资料的三维格点化及拼图方法研究. *气象学报*, 64(5): 647-657. Xiao Y J, Liu L P. 2006. Study of methods for interpolating data from weather radar network to 3-D grid and mosaics. *Acta Meteor Sinica*, 64(5): 647-657 (in Chinese)
- 俞小鼎, 周小刚, 王秀明. 2012. 雷暴与强对流临近天气预报技术进展. *气象学报*, 70(3): 311-337. Yu X D, Zhou X G, Wang X M. 2012. The advances in the nowcasting techniques on thunderstorms and severe convection. *Acta Meteor Sinica*, 70(3): 311-337 (in Chinese)
- 张德正, 翁理国, 夏旻等. 2019. 基于深度卷积长短时神经网络的视频帧预测. *计算机应用*, 39(6): 1657-1662. Zhang D Z, Weng L G, Xia M, et al. 2019. Video frame prediction based on deep convolutional long short-term memory neural network. *J Comput Appl*, 39(6): 1657-1662 (in Chinese)
- 张亚萍, 程明虎, 夏文梅等. 2006. 天气雷达回波运动场估测及在降水临近预报中的应用. *气象学报*, 64(5): 631-646. Zhang Y P, Cheng M H, Xia W M, et al. 2006. Estimation of weather radar echo motion field and its application to precipitation nowcasting. *Acta Meteor Sinica*, 64(5): 631-646 (in Chinese)
- 庄薇, 刘黎平, 余燕群等. 2012. 雷达地物回波模糊逻辑识别法的改进及效果检验. *气象学报*, 70(3): 576-584. Zhuang W, Liu L P, Yu Y Q, et al. 2012. Improvement of the fuzzy logic technique for identifying ground clutter and its verification. *Acta Meteor Sinica*, 70(3): 576-584 (in Chinese)
- Agrawal S, Barrington L, Bromberg C, et al. 2019. Machine learning for precipitation nowcasting from radar images//Proceedings of the 33rd Conference on Neural Information Processing Systems. Vancouver, Canada, 1-6
- Ayzel G, Heistermann M, Winterrath T. 2019. Optical flow models as an open benchmark for radar-based precipitation nowcasting (rainmotion v0.1). *Geosci Model Dev*, 12(4): 1387-1402
- Browning K A. 1982. Nowcasting. London: Academic Press, 20-23
- Goodfellow I, Bengio Y, Courville A. 2016. Deep Learning. Cambridge: MIT Press, 367-425
- Klein B, Wolf L, Afek Y. 2015. A dynamic convolutional layer for short rangeweather prediction//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 4840-4848
- Li L, Schmid W, Joss J. 1995. Nowcasting of motion and growth of precipitation with radar over a complex orography. *J Appl Meteor Climatol*, 34(6): 1286-1300
- Lotter W, Kreiman G, Cox D. 2016. Deep predictive coding networks for video prediction and unsupervised learning. *Proc. Int. Conf. Learn. Representations*, 1-18
- Shi X J, Chen Z R, Wang H, et al. 2015. Convolutional LSTM network: A machine learning approach for precipitation nowcasting//Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press, 802-810
- Shi X J, Gao Z H, Lausen L, et al. 2017. Deep learning for precipitation nowcasting: A benchmark and a new model//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, California, USA: Curran Associates Inc., 5617-5627
- Singh S, Sarkar S, Mitra P. 2017. Leveraging convolutions in recurrent neural networks for doppler weather radar echo prediction//Proceedings of the 14th International Symposium on Neural Networks. Muroran, Hokkaido, Japan: Springer, 310-317
- Sonderby C K, Espeholt L, Heek J, et al. 2020. MetNet: A neural weather model for precipitation forecasting. arXiv: 2003.12140
- Wang Y B, Long M S, Wang J M, et al. 2017. PredRNN: Recurrent neural networks for predictive learning using spatiotemporal LSTMs//Proceedings of the 31st Conference on Neural Information Processing Systems. Long Beach, CA, USA, 879-888
- Wang Y B, Gao Z F, Long M S, et al. 2018. PredRNN++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning//Proceedings of the 35th International Conference on Machine Learning. Stockholm, Sweden: PMLR, 5123-5132
- Wang Y B, Jiang L, Yang M H, et al. 2019. Eidetic 3D LSTM: A model for video prediction and beyond//Proceedings of the ICLR 2019. 1-14
- Wang Z, Bovik A C, Sheikh H R, et al. 2004. Image quality assessment: From error visibility to structural similarity. *IEEE Trans Image Process*, 13(4): 600-612
- Witt A, Johnson J T. 1993. An enhanced storm cell identification and tracking algorithm//26th Int. Conf. on Radar Meteorology, 24-28 May, Norman, Oklahoma, 514-521