

陈生,黄启桥,谭金凯,等. 基于多尺度特征深度学习的短临降水预报[J]. 热带气象学报,2023,39(6):799-806.

文章编号: 1004-4965(2023)06-0799-08

基于多尺度特征深度学习的短临降水预报

陈生^{1,2},黄启桥^{1,2},谭金凯^{2,3},梁振清⁴,吴翀⁵

(1.中国科学院西北生态环境资源研究院/甘肃省遥感重点实验室/中国科学院黑河遥感试验研究站,甘肃 兰州 730000;

2.南方海洋科学与工程广东省实验室(珠海),广东 珠海 519082;

3.中山大学大气科学学院热带大气海洋系统科学教育部重点实验室,广东 珠海 519082;

4.广西区气象技术装备中心,广西 南宁 530022;

5.中国气象科学研究院,北京 100081)

摘 要: 雷达回波外推是短临降水预报的一种重要方法。针对雷达回波外推中随着外推时间的增加而出现回波演变信息丢失这一问题,本文提出一种多尺度特征融合的深度学习短临降水预报模型(以下简称为MSF2)。首先,采用多尺度的卷积核对网络的浅层信息进行特征提取,弥补单一特征检测带来的不足。其次,将不同维度的特征信息进行拼接及通道混洗,进一步增强特征图通道之间的信息流通和信息表达能力。最后,将特征图中的多尺度信息进行融合,从而有效保留不同尺度的特征信息。利用华南雷达回波拼图资料数据,在3种不同降水强度(5 mm/h、10 mm/h和25 mm/h)下进行降水预报研究,并与光流法和ConvLSTM两种主流算法进行了对比。结果显示,在3种不同降水强度条件下,MSF2在所有评价指标(命中率POD、临界成功指数CSI、误报率FAR)中表现最优,这表明引入多尺度机制能改善模型的特征提取能力。相比于目前主流的光流法和ConvLSTM,本文提出的模型对于短临降水预报具有较好的适用性和较高的预报精度,而且实现了业务化运行。

关 键 词: 短临预报;深度学习;多尺度特征;光流法;ConvLSTM

中图分类号: P457.6 文献标志码: A Doi: 10.16032/j.issn.1004-4965.2023.069

1 引 言

短临降水预报通常指未来短期内对某一地区的降水强度进行预报,在气象灾害防御中具有极为重要的地位^[1]。目前,短临预报的主要手段是基于雷达回波数据资料的雷达回波外推技术,常用的回波外推方法主要包括单体质心法^[2]和交叉相关法(TREC)^[3]。单体质心法首先要识别出单体,并计算其质心位置,然后在相邻时刻的雷达回波中心进行单体匹配,最后通过连续多时刻的匹配追踪外推雷达回波。交叉相关法将雷达回波区域

化,然后计算各个区域相邻时刻的交叉相关系数,进而得到回波移动矢量的方向和大小。虽然上述两种方法不断改进,但相关研究表明,这两种方法仅适用于变化缓慢的降水系统,对快速增长或消散的强对流的预报效果并不理想^[4-6]。

近年来,以深度学习为代表的智能算法具有较强的自主学习、推断和记忆能力,并被广泛应用于图像分割、目标检测和气象预报等领域。作为一种非线性数学模型,深度学习通过多层的网络结构和非线性变换来提取底层特征,形成更加抽象的网络空间结构,可很好地进行特征挖掘及特征表示,因此该方法具有优异的非线性特征学习

收稿日期:2023-04-17;修订日期:2023-11-01

基金项目:中国科学院高层次人才计划项目(E2290702);广西重点研发项目(2021AB40108、2021AB40137);国家自然科学基金项目(41875182);广东省基础与应用基础研究基金项目(2020A1515110457);中国博士后科学基金面上资助(2021M693584);北部湾环境演变与资源利用教育部重点实验室(南宁师范大学)开放基金(NNNU-KLOP-K2103)共同资助

通讯作者:陈生,男,广西壮族人,研究员,博士研究生导师,研究方向:水文气象遥感与大数据。E-mail: chensheng@nieer.ac.cn

能力^[5]。为了提高雷达回波外推的预报精度,已有学者将深度学习技术运用至气象短临预报领域。例如,Shi等^[7]提出卷积长短期记忆网络模型(convolutional long short-term memory network, ConvLSTM),并与光流法和全连接长短期记忆网络(FC-LSTM)进行对比,从而验证该模型的有效性。Ayzel等^[8]提出精简深度神经网络的降水预报模型,并探究不同数据预处理方法、损失函数以及卷积核尺寸对预报精度的影响。Agrawal等^[9]将短临预报视为图像预报问题,并利用U-Net网络构建短临降水预报模型,其预报效果优于光流法和快速更新系统(HRRR)。郭瀚阳等^[1]将短临预报抽象成时、空序列预测问题,采用改进的循环神经网络预报未来1 h的强对流雷达回波演变,结果表明可以有效地提高短临预报准确率。施恩等^[6]提出动态卷积神经网络模型(DCNN-I),通过增加动态子网络和概率预测层,使网络能够准确捕捉到输入特征图的变化特征;相比传统雷达回波外推方法,该模型预测准确率更高且能有效延长外推时间。

综上所述,深度学习方法在雷达回波外推预报取得了一定成果。但是,目前较少研究提及通过多尺度特征融合的方法来提高雷达回波外推准确率。因此,本文将以南南雷达回波拼图资料为研究数据,提出一种结构化的短临降水预报网络。首先,利用训练集样本训练网络;其次,在测试集上测试网络模型;最后,采用气象预报业务中的主流算法光流法和ConvLSTM作为对比方法,对比3种方法的预报准确率。

2 短临降水预报模型

2.1 多尺度特征融合模块

雷达回波外推技术是进行短临降水预报的重要技术手段,根据气象雷达探测到的回波数据,确定回波的强度及回波的方向和移动速度。但在局部强对流天气中,回波特征演变较快,会出现随着外推时间增加而出现回波特征信息丢失的问题。若采用单一的特征检测,受限于感受野大小,不利于检测交错、复杂的雷达回波特征。为此,本文结合多维度卷积核与深度可分离卷积,构建一种Xception结构^[10],改善深度神经网络的特征提取能力,同时降低网络计算成本。

深度可分离卷积将传统卷积分成两个操作:首先是对输入特征图的每一个通道进行2维卷积,这一过程称为深度卷积;然后是采用 1×1 卷积核融合通道特征,该操作称为点卷积。通过这两步操作,可以降低网络的参数量,使网络更加轻量化且保持特征检测效率。假设输入特征图大小为 $d_f \times d_f$,输入通道数为 m ,卷积核尺寸为 $d_k \times d_k$,卷积步长1,输出通道数为 n ,则深度可分离卷积的参数量params和计算量FLOPs分别如下式(1)和式(2)。

$$\text{params} = d_k \times d_k \times m + m \times n \quad (1)$$

$$\text{FLOPs} = d_k \times d_k \times m \times d_f \times d_f + m \times n \times d_f \times d_f \quad (2)$$

由式(1)和式(2)可知,深度可分离卷积的参数数目及计算复杂度与卷积核尺寸 $d_k \times d_k$ 、输出通道数 n 密切相关。式(1)中,点卷积操作的数目为 $m \times n$,该操作仍占据算法总参数中的绝大部分;参照Gao等^[11]的方法,利用Channel-Wise卷积替换深度可分离卷积的点卷积;通过输入和输出连接的稀疏化,使 1×1 卷积核在通道维度上滑动,实现模型的进一步压缩加速。Channel-Wise卷积的参数为 $d_c \times d_k \times d_k$,一般取 $d_c \leq m$,其中 d_c 表示一次采样的输入通道数。替换后的深度可分离卷积的参数量params和计算量FLOPs分别为:

$$\text{params} = d_k \times d_k \times m + d_c \quad (3)$$

$$\text{FLOPs} = d_f \times d_f \times m \times d_k \times d_k + d_c \times n \times d_f \times d_f \quad (4)$$

本文采用 1×1 、 3×3 、 5×5 和 7×7 的卷积核构建多尺度特征提取模块,如图1所示。实际应用中,尺寸较大的卷积核如 5×5 和 7×7 等,可通过使用多个 3×3 卷积核的级联结构进行替换,在保证感受域相同的同时,能够大幅度减少参数量。通过对多尺度特征进行拼接,然后使用卷积核变换特征图的通道,使得模块输出的特征图融合多尺度特征信息。此外,本文引入通道混洗(Channel-Shuffle)^[12],将拼接的特征图沿通道维度进行随机打乱,增强特征图通道间的特征交互能力,进一步提高模型的泛化能力。

利用图1a和1b的多尺度特征融合模块构建深层网络时,网络层数的增加容易造成深层网络的梯度消失或爆炸现象,使神经网络难以训练,从而导致模型发生退化。He等^[13]提出的残差网络思想,用于解决深层网络模型退化问题。本文借鉴

He等^[13]的思路,通过将多尺度特征信息与输入特征图进行融合,尝试缓解网络训练过程中梯度消

失或爆炸的问题,同时为后续解码模块保留丰富的输入特征信息。




图1 多尺度特征融合(MFF)结构

2.2 雷达回波外推方法结构

结合U-Net架构^[14]和图1中的多尺度特征融合结构(MFF),构建短临降水预报模型(MSF2),如图2所示。U-Net网络架构由编码网络和解码网络两部分组成,主要用于数据特征检测和提取,通过结合图1中的多尺度特征融合模块(MFF),进一

步增强网络的特征提取和学习能力,提高雷达回波的预报精度。因此,本文提出的模型主要包括3个模块:多尺度特征融合模块,下采样模块及上采样模块;其中,下采样和上采样采用参数共享机制^[15],进一步降低网络的参数数量并增强网络的泛化能力。




图2 MSF2短临降水预报模型

3 实验与分析

3.1 数据来源

本文实验采用从中国气象局官方网站(<http://data.cma.cn/data/online/t/4>)下载的华南地区CINRAD多普勒天气雷达回波拼图资料数据,时间为2018—2020年的3—8月份。下载的数据样本为600行×800列,空间分辨率约为2.15 km,每张图像的时间间隔为6 min^[16]。由于下载的图像

包含行政区域、字体、河流等地图标记,需要先进行质量控制,消除这些地图标记,然后采用Cressman插值算法对这些地图标记掩盖的区域进行修补填充^[17]。因为研究区域主要为珠三角及周边地区,为降低深度神经网络计算成本,提高计算机的运行效率,对原始图像进行裁剪,裁剪后的图像范围如图3所示的红色方框区域。裁剪后的图像网格数量为400行×400列,作为模型的输入进行训练和预报。




图3 研究区域(图中红色方框区域)

3.2 数据预处理

(1) 气象雷达每6分钟完成一次体扫获得降水的雷达回波数据,受山体,建筑物等低空地物影响,在低仰角区域往往会产生虚假回波。为减少噪声对雷达回波外推模型的影响,采用局部均值滤波算法对图像去噪。然后采用通用的Z-R关系($Z = 300R^{1.4}$)将雷达反射率转换成降水量^[18]。

(2) 数据归一化:由于雷达回波反射率具有数值差异的特点,若将反射率图像数据直接输入深度神经网络模型,使得深度神经网络难以收敛。因此,首先利用最大最小值方法对回波反射率资料数据进行归一化处理,经过归一化处理后,数据的值都在[0,1]内,将无雷达回波区域的降水量设为0,取值将归一化后的数据输入深度神经网络模型进行训练。

3.3 评估方法

实验采用气象预报业务中的命中率(probability of detection, POD)、临界成功指数(critical success index, CSI)和误报率(false alarm rate, FAR)作为回波外推模型的评估标准。在计算上述指标得分时,首先需要设定一个降水强度值,若图像中某个像素点的值大于该强度值,则判定该像素对应区域的预报值是活跃的,否则判定该像素的预报值为不活跃。对于单个像素的预测分为成功、漏报、和空报,本文以TP、FN和FP分别表示成功、漏报和空报的点数,POD、CSI和FAR的计算公式如下:

$$POD = \frac{TP}{TP + FN} \quad (5)$$

$$CSI = \frac{TP}{TP + FN + FP} \quad (6)$$

$$FAR = \frac{FP}{TP + FP} \quad (7)$$

3.4 损失函数

短临降水预报属于回归问题,为了定量地描述降水预报的准确性,本研究采用均方误差(Mean Squared Error, MSE)作为ConvLSTM和本文所提方法训练的损失函数,其计算公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (8)$$

其中, $\hat{y}_i$ 为模型的预测值, y_i 为对应的实际观测值。

3.5 实验结果分析

本研究模型通过输入历史1 h的10帧图像,对未来1.5 h的降水量进行预报;即模型的通过输入历史的10帧图像 $X = \{x_{t-9}, x_{t-8}, \dots, x_t\}$,预报未来1.5 h内逐6 min的15帧图像 $Y = \{y_{t+1}, y_{t+2}, \dots, y_{t+15}\}$ 。本研究选取2018—2019年的3—8月的数据作为训练集和验证集,通过对原始的序列数据使用长度为25的滑动窗口以步长为1进行采样,可得到时间连续的25帧图像的序列样本集 $\{X, Y\}$,得到训练集和验证集包含的样本个数为84 024个样本。本研究采用交叉验证法对训练集和验证集进行划分,得到训练集包含75 624个样本,验证集包含8 400个样本。选取2020年的数据作为测试集,使用长度为25的滑动窗口以步长为10进行采样,可得到时间连续的25帧图像的测试序列样本集 $\{X, Y\}$,得到测试集的样本个数为4 212个样本。

实验选用Pytorch深度学习框架,采用Nadam(Nesterov Adam optimizer)作为ConvLSTM和本文所提方法的优化器,经过反复调试,学习率设为0.002 5;网络训练采取批训练的方式,每次输入32个样本。且ConvLSTM和MSF2模型训练过程中,采用早停机制,即当验证集的误差小于0.025时,模型的训练停止。

本文采用半拉格朗日外推的光流法(Optical flow)^[19]和ConvLSTM^[7]两种主流算法作为对比方法。下图4展示了不同外推算法的可视化结果。尽管模型能够给出未来1.5 h的15帧图像,限于篇幅,本文进行了间隔取样;即从第3张图样开始,每间隔2张进行取样,得到的可视化样本对应5幅图像。从图4可以看出,随着预报时间的增加,本文

方法预报降水落区形态与实际吻合较好,而光流法的外推预报出现了明显形变。基于深度学习的ConvLSTM和本文方法外推图像越往后越模糊且更平滑,这符合多步预测累计误差规律。但随着预报时间的增加,ConvLSTM预报的细节出现不同程

度丢失,特别在降水量大于等于25 mm/h时,外推图像出现了较为明显的模糊、平滑现象。由于光流法遵循灰度不变性假设,而实际的雷达回波存在生消演变,对于移速较快和生消演变迅速的降水过程,随着预报时间的增加,其预报效果逐渐降低。




图4 可视化降水预报结果

a. 预报序列一起报时刻为2020年6月22时42分;

b. 序列二起报时刻为2020年08月05日04时42分。

为进一步定量对比评估光流法、ConvLSTM以及本文提出MSF2算法的预报技巧,本文用常用的评价指标POD、CSI以及FAR进行评估。在降

水量预报对比实验中,通过多重降水量评估和预报结果。实验选取5 mm/h、10 mm/h和25 mm/h的3个降水量阈值,对比分析3种算法的降水预报

效果。表1—表3给出了3种模型在1.5 h内的各评估指标的均值,图5给出了不同降水量条件下各个评价指标的变化过程。

表1 降水量大于等于5 mm/h的预报结果

预报方法	CSI	FAR	POD
Flow	0.403 3	0.399 7	0.456 1
ConvLSTM	0.440 3	0.365 7	0.493 8
MSF2	0.479 8	0.323 2	0.5279

表2 降水量大于等于10 mm/h的预报结果

预报方法	CSI	FAR	POD
Flow	0.313 9	0.431 6	0.341 0
ConvLSTM	0.358 4	0.390 0	0.383 4
MSF2	0.402 7	0.326 7	0.444 7

表3 降水量大于等于25 mm/h的预报结果

预报方法	CSI	FAR	POD
Flow	0.214 2	0.560 4	0.234 5
ConvLSTM	0.261 6	0.491 9	0.279 7
MSF2	0.310 4	0.412 3	0.338 2

从表1—表3和图4可以看出,随着预报时间和降水强度的增加,3种算法预报结果的POD和CSI逐渐降低,FAR逐渐增加。在不同降水强度对应的统计结果中,本文方法的CSI和POD评分在

所有降水强度下均比光流法都高,FAR为最低。在本文方法和ConvLSTM的对比中,当降水量大于等于5 mm/h,本文方法的CSI和POD得分较ConvLSTM算法分别提高0.039 5和0.071 8,FAR下降了0.042 5;降水量大于等于10 mm/h时,本文方法的CSI和POD比ConvLSTM分别高出0.044 3和0.061 3,FAR下降了0.063 3;当降水量大于等于25 mm/h时,本文方法的CSI和POD比ConvLSTM算法分别高出0.048 8和0.058 5,FAR下降0.079 6。在降水量大于等于5 mm/h时,此时包含的信息量最大,因此,本文方法和ConvLSTM的CSI和POD的评分均较高。但随着降水强度的增大,过滤掉的回波演变信息更多,光流法和ConvLSTM的CSI和POD评分逐渐降低,FAR的评分逐渐增高;特别是在降水量大于等于25 mm/h条件下,光流法和ConvLSTM的CSI和POD评分降低显著,FAR的评分增高明显。实验结果证明,通过引入多尺度特征提取机制能够改善模型的特征提取能力,有助于提升回波外推模型的预报精度。实验结果表明,本文提出的基于多尺度特征检测的回波外推算法比光流法和ConvLSTM能获得更好的效果。




图5 降水预报技巧变化曲线图

4 结 论

本文选取2018—2020年的3—8月华南地区天气雷达逐6 min回波数据,结合多尺度融合与深度可分离卷积,构建短临降水预报的深度学习模型。实验结果表明,本文模型可有效预报未来1.5 h的雷达回波演变特征,该模型的预报效果优于光流法和ConvLSTM。

通过多维度特征提取,拓宽了网络宽度,使网络能够学习到雷达回波的位置移动和演变特征。并综合考虑预报精度、网络参数量和计算量,构建端到端的编码、解码结构:(1)通过多尺度特征提取与融合,拓宽网络的宽度,提高网络模型的特征检测效果;随着网络宽度和网络层数的增加,网络的参数和计算量也大幅增加。(2)引入深度可分

离卷积和通道混洗,实现特征图通道信息交互并进一步降低模型的参数数目和计算成本。实验结果显示,基于海量的高时空分辨率雷达回波数据资料,本文模型能够给出未来1.5 h的准确预报。

深度学习作为一种新的短临预报技术,在数据量的爆发式增长的环境下,能够从海量的气象数据中捕获丰富的特征信息,从而推理并发现降水特征和强对流天气运动规律,提高了短临降水预报技巧。本文通过引入多尺度特征融合机制,采用多尺度卷积核提取更加丰富的特征信息,在一定程度上缓解了回波演变信息丢失的问题。但是本文方法也存在不足之处,采用卷积神经网络进行特征提取操作,随着预报时间的变化,输出图像出现平滑、模糊现象。下一步将从深度神经网络的结构出发进行更深入的改进,进一步解决外推预报平滑和模糊的问题。

参 考 文 献:

- [1] 郭瀚阳,陈明轩,韩雷,等.基于深度学习的强对流高分辨率临近预报试验[J].气象学报,2019,77(4): 715-727.
- [2] JOHNSON J T, MACKEEN P L, WITT A, et al. The storm cell identification and tracking algorithm: An enhanced WSR-88D algorithm[J]. Weather and forecasting, 1998, 13(2): 263-276.
- [3] RINEHART R E, GARVEY E T. Three-dimensional storm motion detection by conventional weather radar[J]. Nature, 1978, 273(5660): 287-289.
- [4] 陈训来,刘军,郑群峰,等.基于卷积门控循环单元神经网络的临近预报方法研究[J].高原气象,2021,40(2): 411-423.
- [5] 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[J].应用气象学报,2019,30(1): 61-69.
- [6] 施恩,李骞,顾大权,等.基于卷积神经网络的雷达回波外推方法[J].计算机应用,2018,38(3): 661-665、676.
- [7] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[J]. arXiv preprint arXiv: 1506.04214, 2015.
- [8] AYSEL G, SCHEFFER T, HEISTERMANN M. RainNet v1. 0: a convolutional neural network for radar-based precipitation nowcasting[J]. Geoscientific Model Development, 2020, 13(6): 2 631-2 644.
- [9] AGRAWAL S, BARRINGTON L, BROMBERG C, et al. Machine learning for precipitation nowcasting from radar images[J]. arXiv preprint arXiv:1912.12132, 2019.
- [10] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 1 251-1 258.
- [11] GAO H, WANG Z, JI S. Channelnets: Compact and efficient convolutional neural networks via channel-wise convolutions[J]. arXiv preprint arXiv: 1809.01330, 2018.
- [12] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 6 848-6 856.
- [13] HE K M, ZHANG X G, REN S Q, et al. Deep Residual Learning for Image Recognition[C].//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.

- [14] 张辉, 朱家明, 唐文杰. 基于聚类和改进型水平集的图像分割算法[J]. 计算机科学, 2017, 44(Z1): 198-201.
- [15] 高晗, 田育龙, 许封元, 等. 深度学习模型压缩与加速综述[J]. 软件学报, 2021, 32(01): 68-92.
- [16] BAI L Q, CHEN G X, HUANG L. Image processing of radar mosaics for the climatology of convection initiation in South China[J]. J App Meteor Climat, 2020, 59(1): 65-81.
- [17] 唐菁, 陈生, 李峙, 等. 基于雷达观测的华南夏季降水类型日变化的时空分布特征[J]. 气象, 2023, 49(3): 307-318.
- [18] FULTON R A, BREIDENBACH J P, SEO D J, et al. The WSR-88D rainfall algorithm[J]. Weather and forecasting, 1998, 13(2): 377-395.
- [19] AYSEL G, HEISTERMANN M, WINTERRATH T. Optical flow models as an open benchmark for radar-based precipitation nowcasting (rainymotion v0.1) [J]. Geoscientific Model Development Discussions, 2018: 1-23.

SHORT-TERM PRECIPITATION NOWCASTING BASED ON MULTI-SCALE FEATURE DEEP LEARNING

CHEN Sheng^{1,2}, HUANG Qiqiao^{1,2}, TAN Jinkai^{2,3}, LIANG Zhenqing⁴, WU Chong⁵

- (1. Key Laboratory of Remote Sensing of Gansu Province, Heihe Remote Sensing Experimental Research Station, Northwest Institute of Eco-Environment and Resources, Chinese Academy of Sciences, Lanzhou 730000, China;
2. Southern Marine Science and Engineering Guangdong Laboratory (Zhuhai), Zhuhai, Guangdong 519082, China;
3. School of Atmospheric Sciences (Sun Yat-sen University), Key Laboratory of Tropical Atmosphere-Ocean (Ministry of Education), Zhuhai, Guangdong 519082, China;
4. Meteorological Technical Equipment Center of Guangxi Zhuang Autonomous Region, Nanning 530022, China;
5. Chinese Academy of Meteorological Sciences, Beijing 100081, China)

Abstract: Radar echo extrapolation is an important method precipitation nowcasting. To address the problem of the loss of characteristic evolution information in echo extrapolation prediction with the increase of echo intensity and prediction time, this paper proposes a deep learning model for precipitation nowcasting based on multi-scale feature fusion (MSF2). Firstly, the multi-scale convolution kernel is used to extract the features of the shallow information of the network to offset the shortcomings caused by the single feature detection. Secondly, the feature information of different dimensions is spliced and the channels are shuffled to further enhance the information circulation and information expression capabilities between the feature map channels. Finally, the multi-scale information in the feature map is fused in order to effectively keep the channel information after the fusion of the feature map. With the South China radar echo data, the fusion experiment was carried out under three different precipitation intensities, and compared with two mainstream algorithms, i. e., ConvLSTM and optical flow. The experimental results show that MSF2 performs best in terms of all evaluation indexes under the conditions of precipitation rates 5 mm/h, 10 mm/h and 25 mm/h. It can be concluded that the introduction of a multi-scale mechanism can improve the feature extraction ability of the nowcasting model. Compared with the current radar echo extrapolation algorithm ConvLSTM and optical flow, the proposed model MSF2 has better potentials in operational applications and higher forecast accuracy for precipitation nowcasting.

Key words: nowcasting; deep learning; multi-scale features; optical flow; convLSTM