

基于深度学习的京津冀地区精细尺度降水 临近预报研究*

曹伟华 南刚强 陈明轩 程丛兰 杨璐 吴剑坤
宋林烨 刘瑞婷

CAO Weihua NAN Gangqiang CHEN Mingxuan CHENG Conglan YANG Lu WU Jiankun
SONG Linye LIU Ruiting

北京城市气象研究院, 北京, 100089

北京城市气象工程技术研究中心, 北京, 100089

Institute of Urban Meteorology, China Meteorological Administration, Beijing 100089, China

Beijing Urban Meteorological Engineering Research Center, Beijing 100089, China

2021-08-02 收稿, 2022-03-07 改回。

曹伟华, 南刚强, 陈明轩, 程丛兰, 杨璐, 吴剑坤, 宋林烨, 刘瑞婷. 2022. 基于深度学习的京津冀地区精细尺度降水临近预报研究. 气象学报, 80(4): 546-564

Cao Weihua, Nan Gangqiang, Chen Mingxuan, Cheng Conglan, Yang Lu, Wu Jiankun, Song Linye, Liu Ruiting. 2022. A study on fine scale precipitation nowcasting in Beijing-Tianjin-Hebei region based on deep learning. *Acta Meteorologica Sinica*, 80(4):546-564

Abstract Precipitation nowcasting on fine scale is of great significance to improve the ability of early warning of flood and waterlogging disasters in modern cities. As a new method, deep learning has more advantages in mining the internal characteristics and physical laws of data. In recent years, the application of deep learning in the field of meteorological radar image has achieved preliminary results. In order to improve the effectiveness of nowcasting on fine scale, a deep convolutional neural network-RainNet is used to propose two ways of rolling approach for precipitation nowcasting. Experiments and comparative analysis are carried out in Beijing-Tianjin-Hebei region on 1 km resolution. Compared with the traditional extrapolation based on Tracking Radar Echoes by Correlation (TREC), the results show that the mean absolute error and correlation coefficient of 1 h nowcasting can be improved. The prediction in 10–50 min in thresholds of 1.04 mm/(10 min) and below is better than that of traditional prediction. Temporal and spatial evolution of precipitation extinction process is better described by deep learning compared with that by traditional extrapolation. The rolling approach with two RainNet models combined outperforms one single model in precipitation nowcasting.

Key words Precipitation, Nowcasting, Deep learning, TREC, Extrapolation

摘要 精细尺度降水的临近预报对于提升现代城市内涝和山洪地质灾害预警能力具有重要意义。深度学习作为一种新兴方法,在挖掘数据内部特征及物理规律方面更具优势,近年来在天气雷达图像领域的应用已初见成效。为进一步提升精细尺度降水的临近预报能力,基于深度学习网络模型 RainNet,研究建立了两种滚动预报方式,开展了京津冀地区 1 km 分辨率精细尺度降水滚动式临近预报试验和对比分析。试验结果表明:与传统基于交叉相关的外推预报相比,深度学习网络模型 RainNet 总体可以明显改进降水 1 h 临近预报的绝对误差和相关系数;两个 RainNet 相结合的滚动预报方式对 1.04 mm/(10 min) 及以下阈值降水,在 10–50 min 预报性能一致优于传统的交叉相关外推预报。深度学习模型对降水消亡过程的时、空演变趋势刻画更好,尤其更适用于降水消亡过程的临近预报。采用两个 RainNet 模型相结合的滚动式预报方式优于单一模型滚动预报方式。

* 资助课题:北京市自然科学基金项目(8192016、8204060)、国家自然科学基金项目(41801022)、国家重点研发计划项目(2017YFC1502104、2018YFC1507504)。

作者简介:曹伟华,主要从事临近预报与灾害风险研究。E-mail: whcao@ium.cn

关键词 降水, 临近预报, 深度学习, 交叉相关, 外推

中图法分类号 P456.9

1 引言

降水临近预报对城市内涝和山洪地质灾害预警及应急响应至关重要。传统降水临近预报方法主要是基于雷达回波的外推预报, 其中基于雷暴单体追踪的外推预报和基于区域追踪的外推预报是应用最广的两种方法。基于雷暴单体追踪的外推预报主要针对对流性降水, 能够给出雷暴单体演变的特征信息, 代表性算法有 TITAN、SCIT(Dixon, et al, 1993; Johnson, et al, 1998)。基于区域追踪的外推预报, 是在假设满足拉格朗日守恒的条件下, 通过追踪雷达前面连续时刻移动矢量进而对未来短时间的演变进行外推预报, 主要有基于交叉相关的追踪算法(Tracking Radar Echoes by Correlation, TREC)(Rinehart, et al, 1978; Li, et al, 1995)、半拉格朗日外推算法(Staniforth, et al, 1991; Germann, et al, 2002)。尽管这些外推预报技术已在多国业务系统中得到应用(Mueller, et al, 2003; 陈明轩等, 2010; Haiden, et al, 2011), 但由于方法仍存在局限, 其外推预报的能力随预报时效延长会迅速下降, 且对于非平流性降水的预报效果要弱于平流性降水, 尤其是针对非平流导致的局地雷暴生长和消亡过程, 其预报能力存在明显不足(Wilson, et al, 1998)等。另外, 一些新的技术方法, 比如统计、外推预报与数值预报融合技术、传统机器学习等也逐渐在降水临近预报中开始应用(Sokol, et al, 2013; Sun, et al, 2014; Chen, et al, 2017; Han, et al, 2017)。但由于精细尺度降水本身包含复杂的非线性过程, 并且非平流降水的生消演变问题也仍然是预报的难点, 因此目前这些传统的方法对非平流性降水的临近预报也存在诸多困难。

近年来, 人工智能技术迎来第三次发展浪潮, 深度学习作为新兴方法被引入气象领域(Shi, et al, 2015; 孙健等, 2021)。深度学习是一种深层的机器学习模型, 对于挖掘数据内部特征及物理规律更有优势, 而且在高时空分辨率雷达图像临近预报方面已初见成效。Shi 等(2015)首次提出使用卷积长短期记忆网络(ConvLSTM)做香港地区降水临近预报, 试验证实其临近预报效果优于传统光流法。Chen 等(2020)通过改进 ConvLSTM 模型在上海及

周边地区雷达回波预测中取得较好效果。Ayzel 等(2019, 2020)研究提出的全卷积神经网络模型(DozhdyaNet)及 RainNet 网络模型对雷达回波临近预报比光流法预报更优。郭瀚阳等(2019)应用改进的循环神经网络(GRU)对京津冀地区 1 h 雷达回波演变特征的预测表明, 其预报评分高于传统的临近预报方法。韩丰等(2019)采用循环神经网络进行 1 h 雷达反射率临近预报试验表明, 其对反射率强度变化有一定预报能力。以上研究表明, 深度学习方法在多个地区的雷达回波临近预报方面已初步表现出一定的应用潜力。

京津冀地区北靠燕山山脉, 西倚太行山, 地形复杂, 对流旺盛。目前, 北京市气象局研发的快速更新多尺度分析和预报系统之集成子系统(RMAPS-IN)已实现京津冀地区高时空分辨率三维网格气象要素客观分析和 0—12 h 地面要素及降水的业务快速更新预报。然而其对于降水的临近预报依然是假设在满足拉格朗日守恒条件下, 采用交叉相关方法基于前面连续时刻降水分析场的演变规律进行传统的外推预报(程丛兰等, 2019; 曹伟华等, 2019), 因而该业务系统对非平流(如热对流)导致的局地降水生消演变过程的临近预报能力还比较有限。为进一步提升京津冀地区强降水临近预报能力, 本研究引入滚动式的深度学习 RainNet 模型, 研究建立两种滚动预报方式, 通过与传统外推预报方法进行对比, 分析了深度学习 RainNet 模型在京津冀地区精细尺度降水临近预报中的性能。

2 数据

研究数据采用 2017—2020 年 6—9 月 1 km 分辨率逐 10 min 间隔的 10 min 累积降水分析场, 覆盖京津冀地区 581 km×511 km。降水分析场是根据京津冀地区 8 部新一代天气雷达(北京、天津、石家庄、秦皇岛、沧州、邯郸 S 波段及张北和承德 C 波段雷达)拼图的反射率(图 1), 通过采用本地化的 Z-R 关系(陈明轩等, 2010)计算获得雷达定量降水估计, 并进一步融合京津冀地区 3000 余个自动气象站雨量计降水观测资料生成降水分析场, 该资料时空分辨率高、质量稳定, 在业务中有很好的应用效果。

通过对原始降水分析场进行整理获得深度学

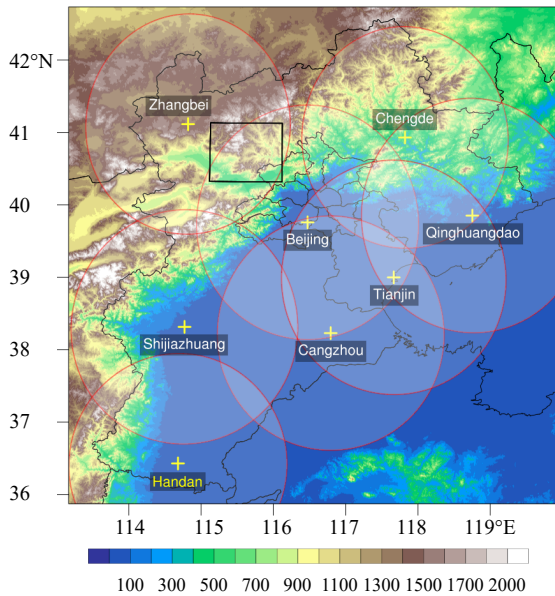


图1 京津冀地区地形海拔高度(单位:m)及8部天气雷达位置(“+”表示)

Fig. 1 Surface elevation (unit: m) around the study area in contiguous North China and the eight radar sites of the operational China Next Generation Weather Radar network are displayed (+ symbols)

表1 模型数据集信息
Table 1 Main parameters of the datasets

年份	训练集			测试集
	2017	2018	2019	2020
样本数	2852	3199	2957	3266
总计	9008			3266

习模型的数据集,如表1所示,将576 km×496 km范围作为降水临近预报试验的研究区域(图2)。采用2017—2019年6—9月的降水分析场作为深度学习网络模型训练集,用于训练和优化深度学习网络模型;采用2020年6—9月的降水分析场作为独立样本测试集,用于检验深度学习模型的预报性能,其中,剔除了无降水的样本防止非降水数据对模型训练的影响。数据进行标准化转换是深度学习的常见做法,对原始降水数据 X 进行对数变换获得标准化数据 X_{nor}

$$X_{\text{nor}} = \ln(X + 0.01) \quad (1)$$

3 方法

3.1 深度学习 RainNet 模型

图3给出京津冀地区降水临近预报的深度学习




图2 研究区域范围(虚线矩形框为原始降水分析场的覆盖范围581 km×511 km,实线矩形为裁剪后研究范围576 km×496 km)

Fig. 2 Study domain (the dotted rectangle is the domain of 581 km×511 km for original precipitation analysis, the rectangle within the solid line is the final study domain of 576 km×496 km)

习 RainNet 模型的网络结构,该模型是在 U-Net 和 SegNet 模型基础上进行改进设计 (Ayzel, et al, 2020)。整个 RainNet 模型分为编码和解码两部分,编码器通过卷积-池化操作来学习输入数据的特征并逐步缩小其空间分辨率,解码器通过上采样方式将学习到的特征逐步放大到更高的空间分辨率,并附加卷积层进一步深化特征的提取。每个编码器和解码器之间存在跳跃连接,以保证不同特征之间的语义连接。RainNet 模型是一个全卷积网络,包括 20 个卷积层、4 个池化层、4 个上采样层和 4 个跳跃连接层,并在最后两个编码器中加入 Dropout 层以降低过拟合进而提升模型的泛化能力。卷积层中统一使用 3×3 的卷积核,这是因为较大的卷积核会导致过拟合和增加模型预测的不确定性。RainNet 模型的编码部分包含 4 次 2×2 最大池化,故输入数据的大小必须为 16 的整数倍,因此将原始降水数据处理成 576 km×496 km 大小作为模型的输入数据(图2)。

RainNet 模型通过 10 min 降水分析场进行未来 10—60 min 滚动式临近预报的关键是进行模型训练和优化,其过程为:首先针对训练集数据读取 3 个连续时刻($t-20$ 、 $t-10$ 、 t)的降水分析场作为模型的输入,采用未来某一时刻的降水分析场作为模型真值,进而根据模型降水输入数据进行降水预

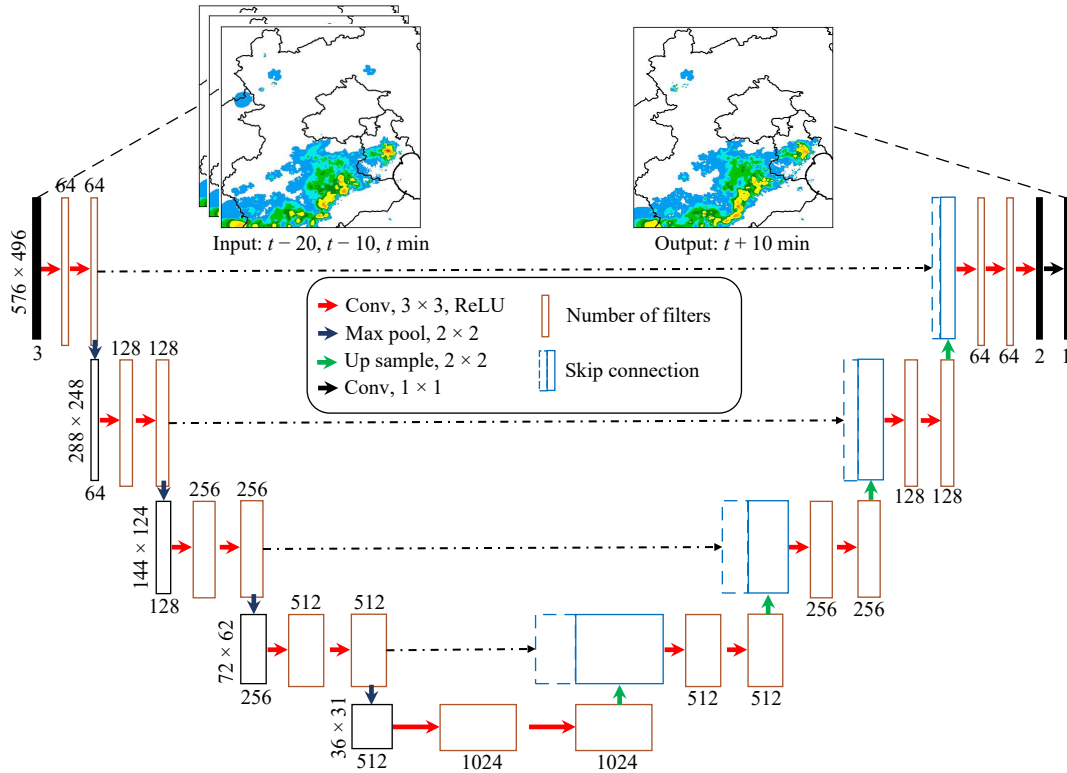


图3 深度学习网络模型的结构

Fig. 3 Illustration of the RainNet architecture

测；进一步，计算损失函数以刻画模型预测与真值间的偏离程度；最后使用 Adam 优化器通过反向传播算法来优化网络参数 (Kingma, et al, 2015)。模型的损失函数使用降水预测偏差的双曲余弦的对数 (Log-Cosh 函数)，如式 (2)、(3)

$$\text{Loss} = \frac{1}{n} \sum_{i=1}^n \ln(\cosh(F_i - O_i)) \quad (2)$$

$$\cosh(x) = \frac{1}{2}(e^x + e^{-x}) \quad (3)$$

式中， F_i 、 O_i 分别表示第 i 个格点的模型预测值和实际观测值， n 是降水场格点数。训练完成后，根据优化后的深度学习模型参数，采用测试集样本数据 3 个连续时刻 ($t-20$ 、 $t-10$ 、 t) 的降水分析场作为 RainNet 模型的输入，通过滚动式预报方式实现逐 10 min 滚动更新的降水预测。

3.2 滚动式预报方式

RainNet 模型采用的滚动式预报方式是将上一个时刻的预报场作为预报下一个时刻降水场的一项输入，该方式简洁、预报灵活高效。以往是采用单一 RainNet 模型进行连续的滚动预报 (Ayzel, et

al, 2020)。但随着预报时效延长，预报值作为输入引入模型的误差将逐渐增大，预报性能下降。为改进单一模型滚动方式的不足，提升连续滚动预报能力，将采用两个 RainNet 模型相结合的滚动预报方式，具体原理是：第 1 个模型采用 3 个连续时刻 $t-20$ 、 $t-10$ 、 t 的降水分析场作为模型输入来预测 $t+10$ min 的降水，由该模型滚动 2 次预报 20—30 min 的降水，原理如图 4a 所示；第 2 个模型同样采用 $t-20$ 、 $t-10$ 、 t 降水分析场作为模型输入，但预测 $t+40$ min 的降水，并由该模型滚动 2 次预测 50—60 min 的降水，如图 4b 所示。作为对比，单一模型对 10—60 min 的连续滚动预报结果将参与对比分析，具体是以 $t-20$ 、 $t-10$ 、 t 时刻降水分析场作为模型输入连续预测 $t+10$ min 后的降水，其连续滚动 5 次预报 20—60 min 的降水，如图 4c 所示。下文图中，统一将两个模型相结合的滚动预报结果记为 RainNet，将单一模型预报结果记为 RainNet_ori。

3.3 传统外推预报方法

基于交叉相关追踪降水或雷达回波的移动矢量进行半拉格朗日外推是一种常用的传统外推预

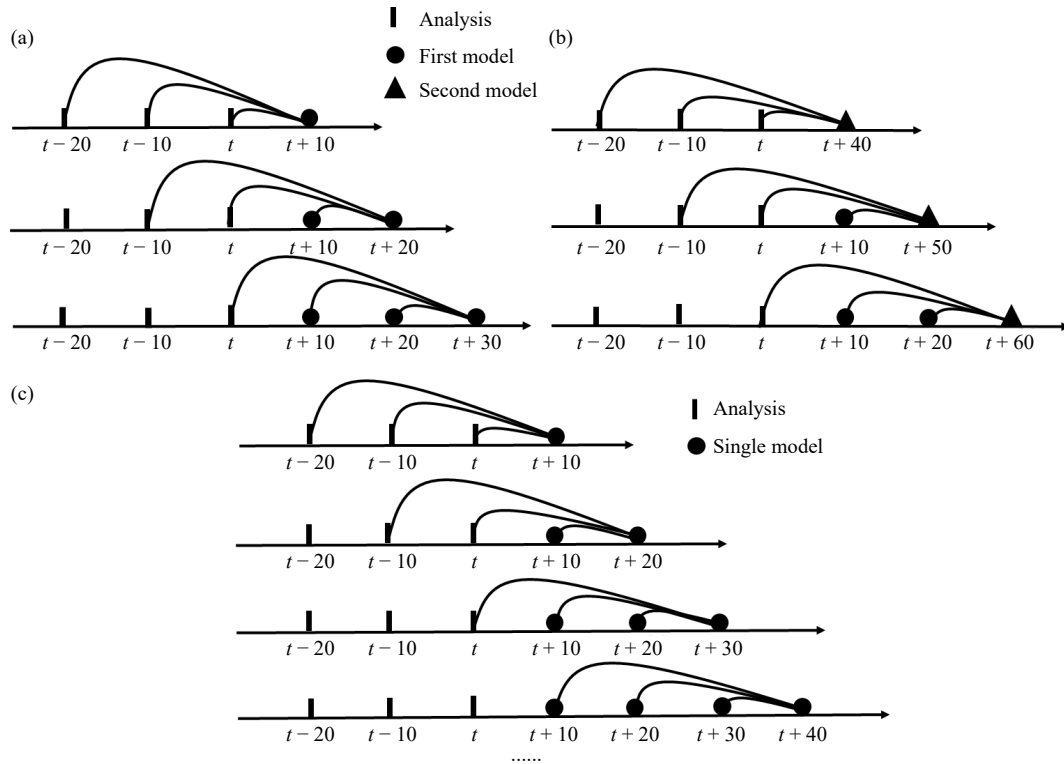


图 4 基于深度学习网络模型的滚动式临近预报原理示意

Fig. 4 Schematic diagram of rolling nowcast based on deep learning network model

报方法。首先,采用最近两个时次的降水分析场(或雷达回波)通过交叉相关算法(Li, et al, 1995; 王改利等, 2007)计算初始的降水移动矢量场,原理如图 5 所示。进一步将生成的降水移动矢量场通过与数值模式 500 和 700 hPa 的风场进行比较约束,过滤掉不符合实际的伪矢量,从而获得质量控制后的

高质量降水移动矢量场(程丛兰等, 2019; 曹伟华等, 2019)。最后,根据上一步质量控制后的降水移动矢量场采用半拉格朗日平流方案(Staniforth, et al, 1991)对最新观测的降水分析场进行未来 1 h 的逐 10 min 外推预报。

降水外推预报方案虽对刻画风暴物理机制存在局限(Germann, et al, 2002),但由于其简单实用,且对稳定性降水预报可以取得较好的效果,因而已在京津冀地区临近预报业务系统中得到应用。作为对比,本研究将其与深度学习模型进行对比试验,其预报结果记为 TREC。

3.4 检验方法

采用平均绝对误差(MAE)衡量降水预报与降水分析(实况)的差距,采用相关系数(COR)度量降水预报与观测的相似程度,公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad (4)$$

$$COR = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (5)$$




图 5 交叉相关方法示意(图 a、b 分别代表 t 、 $t+\Delta t$ 时刻降水场;黑色矩形框代表求交叉相关的像素点区域, r 代表搜索半径,黑色矢量为 TREC 矢量,所指向终点代表所匹配的具有最大相关系数的矩形中心)

Fig. 5 Schematic diagram showing the computation of the TREC (Fig. 5a and Fig. 5b represent precipitation analysis at time t and $t+\Delta t$ respectively, r is search radius, the black vector is the TREC vector, the end point of which is the centre of the array at time $t+\Delta t$ with maximum correlation coefficient)

式中, F_i 、 O_i 分别是降水预报值和降水分析值, \bar{F} 、 \bar{O} 分别是 F_i 、 O_i 的平均值, n 是有效样本量。

同时,采用 CSI 评分检验两种方法对不同强度降水的预报性能 (Wilks, 2011), CSI 范围为 0—1, 1 代表预报效果最佳, 公式如下

$$\text{CSI} = \frac{\text{hits}}{\text{hits} + \text{false alarms} + \text{misses}} \quad (6)$$

式中, hits 代表命中次数, 表示预报不小于降水阈值且实况也不小于该阈值的频率; false alarms 代表空报次数, 表示预报不小于降水阈值而实况小于该阈值的频率; misses 代表漏报次数, 表示预报小于降水阈值而实况不小于该阈值的频率。

4 试验检验

4.1 误差空间分布

从京津冀地区 2020 年 6—9 月基于交叉相关外

推预报和由两个 RainNet 模型相结合进行降水临近预报在 10—60 min 预报时效的绝对误差空间分布 (图 6) 可以看出, RainNet 模型预报在各预报时效下的绝对误差明显低于交叉相关外推预报的绝对误差, 尤其是京津冀南部地区相对于降水外推预报的绝对误差改善更加明显。总体来看, 相对于交叉相关外推预报, 深度学习 RainNet 模型对京津冀地区 1 h 内降水临近预报误差更小, 且随着预报时效的延长, RainNet 对绝对误差的改进越明显。

从京津冀地区两种临近预报方法在 2020 年 6—9 月 10—60 min 预报时效下降水预报场与分析场的相关系数空间分布 (图 7) 可以看出, 两种预报方法的相关系数空间分布趋势整体一致, 呈东北—西南走向, 在京津冀平原地区降水预报与实况的相关系数较大, 即平原地区两者更加接近, 而在西北山区的相关系数较小。对比来看, 深度学习 RainNet

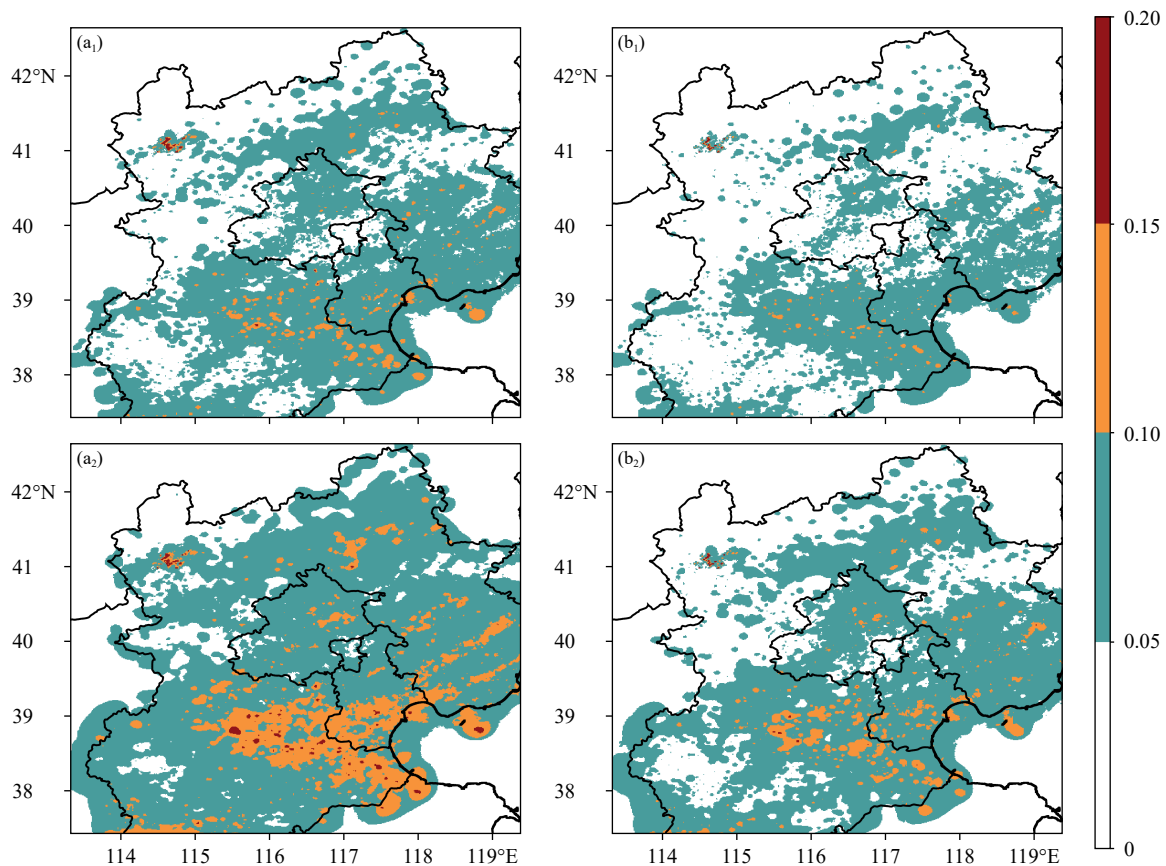
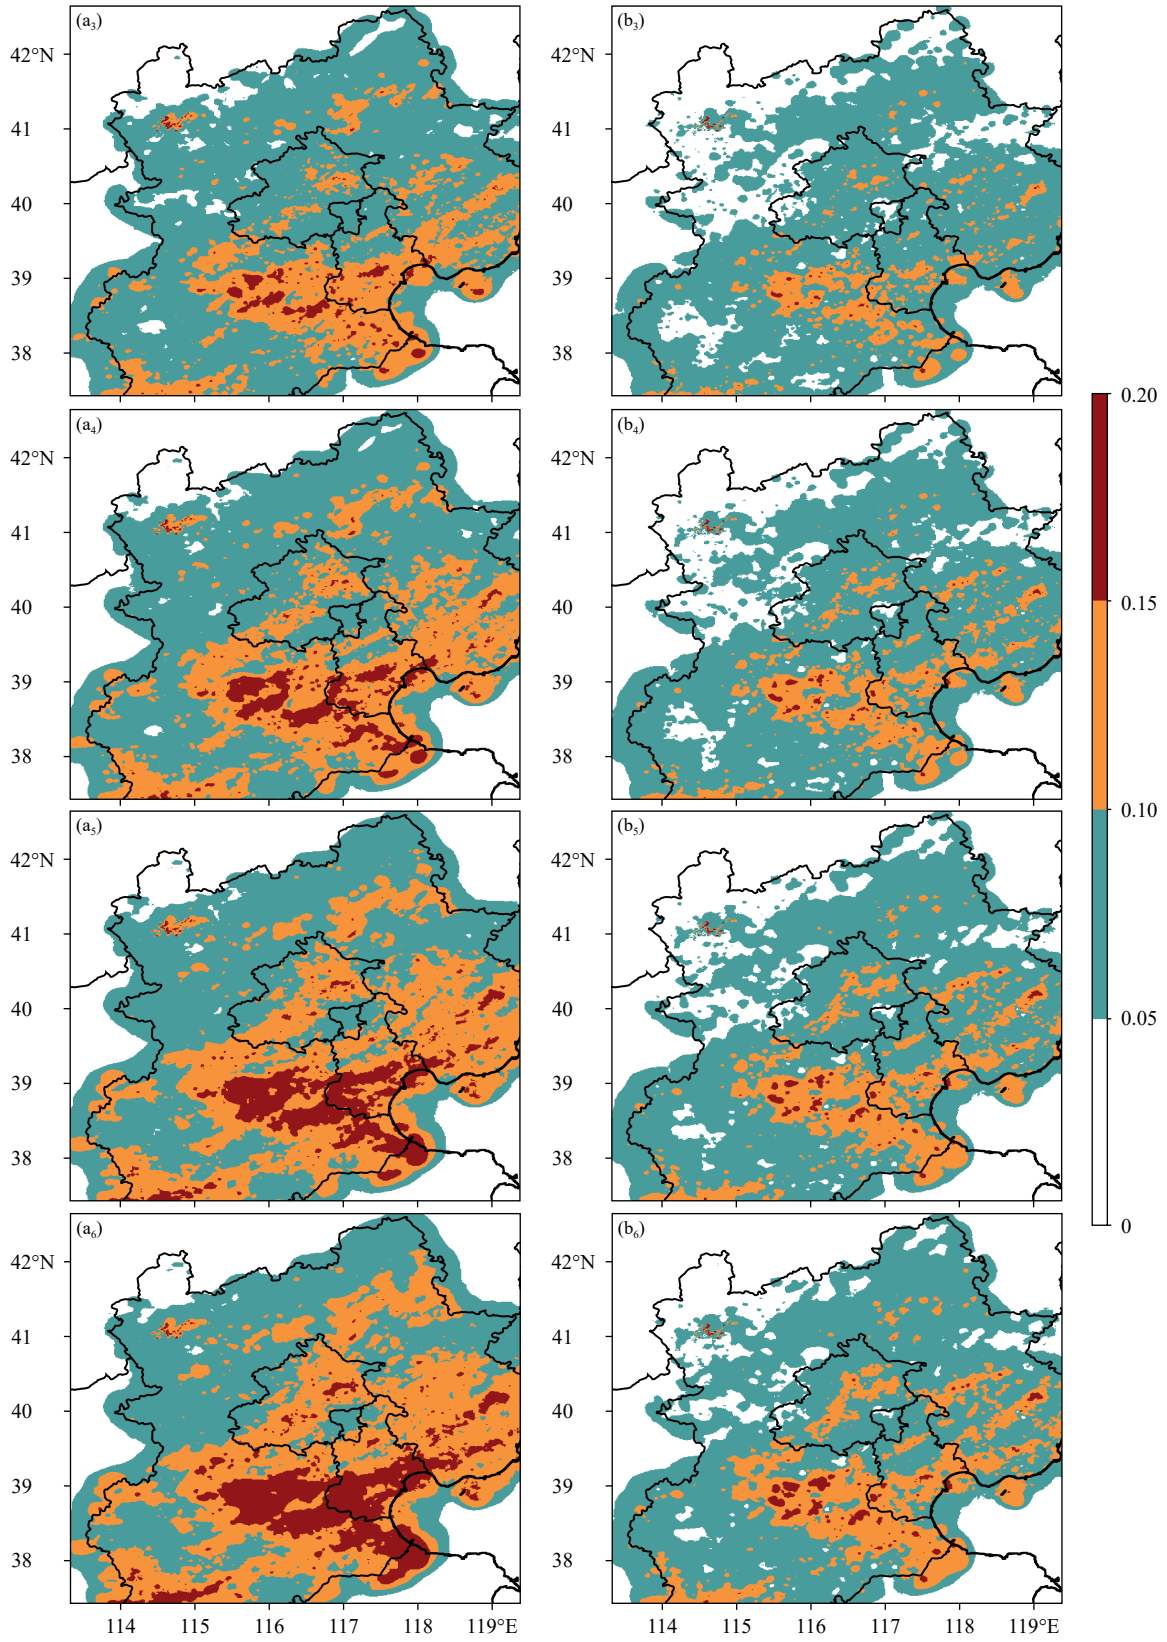


图 6 2020 年 6—9 月的绝对误差空间分布 (单位: mm/(10 min)); a. 基于交叉相关的外推预报 (TREC) 绝对误差, b. 两个深度学习模型相结合的滚动预报 (RainNet) 绝对误差; 下标 1—6 分别表示预报时效为 10、20、30、40、50、60 min

Fig. 6 Spatial distributions of mean absolute error (MAE) during June to September 2020 (unit: mm/(10 min)); a. TREC predictions, b. two rolling RainNet predictions; 1—6 represents the forecast time in 10, 20, 30, 40, 50 and 60 min, respectively)



续图 6

Fig. 6 Continued

模型在各时效的相关系数一致高于交叉相关外推预报的相关系数,而且随着预报时效延长 RainNet 模型的相关系数提升更加明显。

4.2 误差箱线图及不同预报时效的预报性能

图 8、9 分别给出了 2020 年 6—9 月绝对误差和相关系数的时间序列箱线图,图中黑盒子的上、

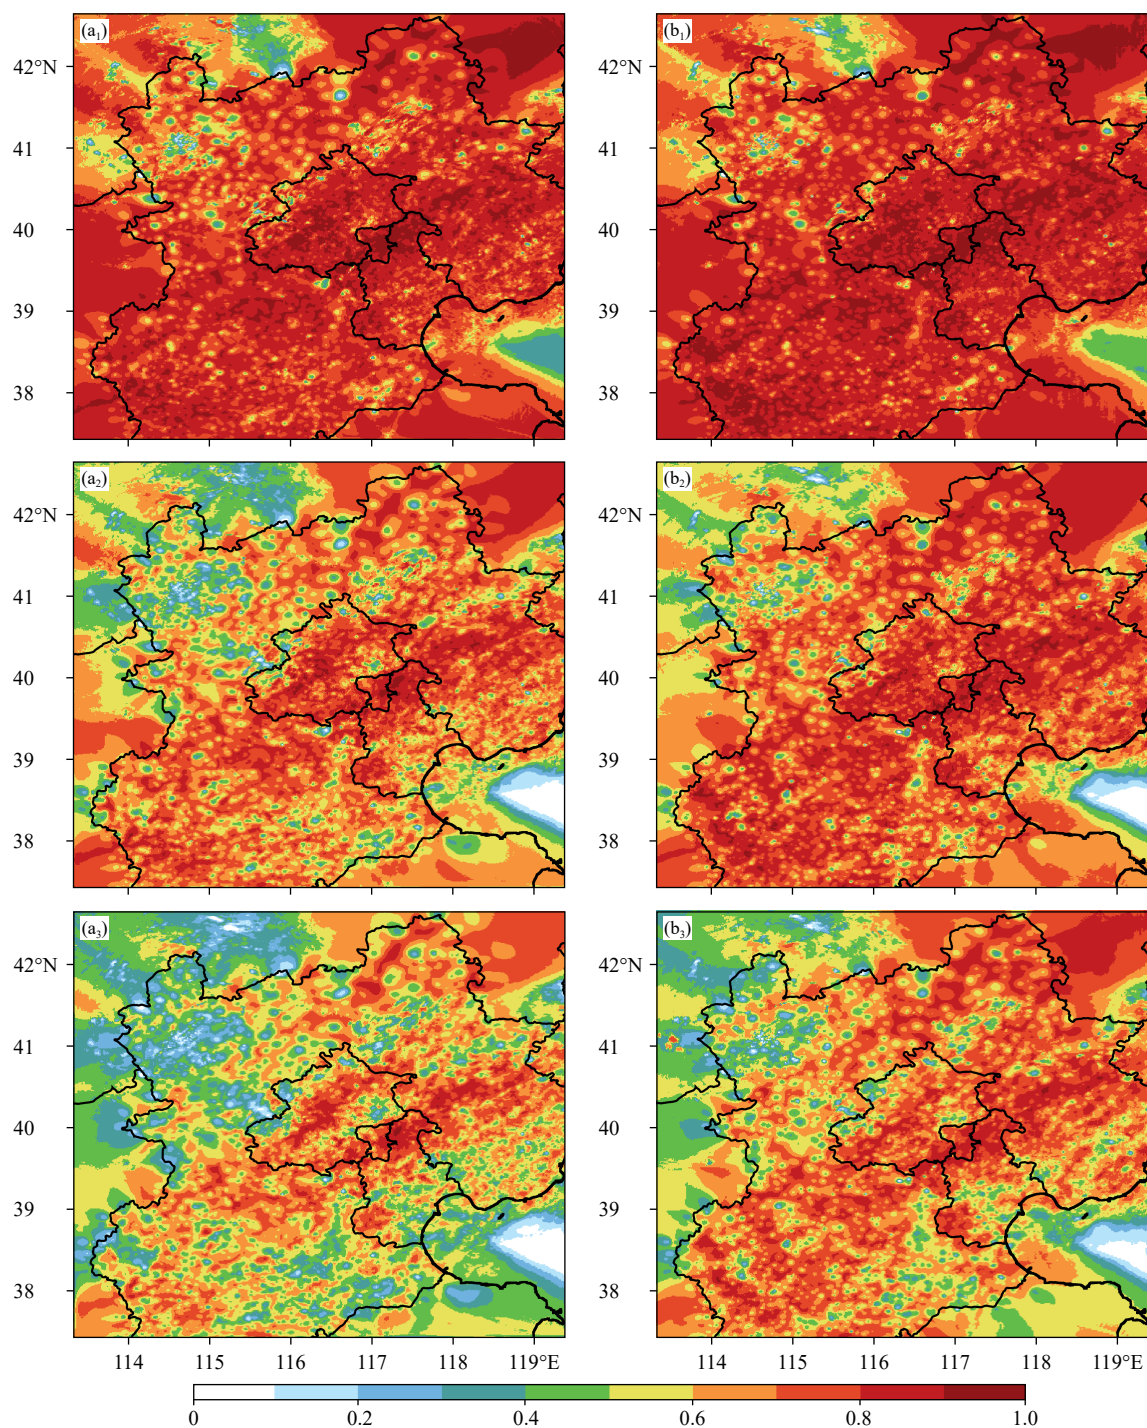
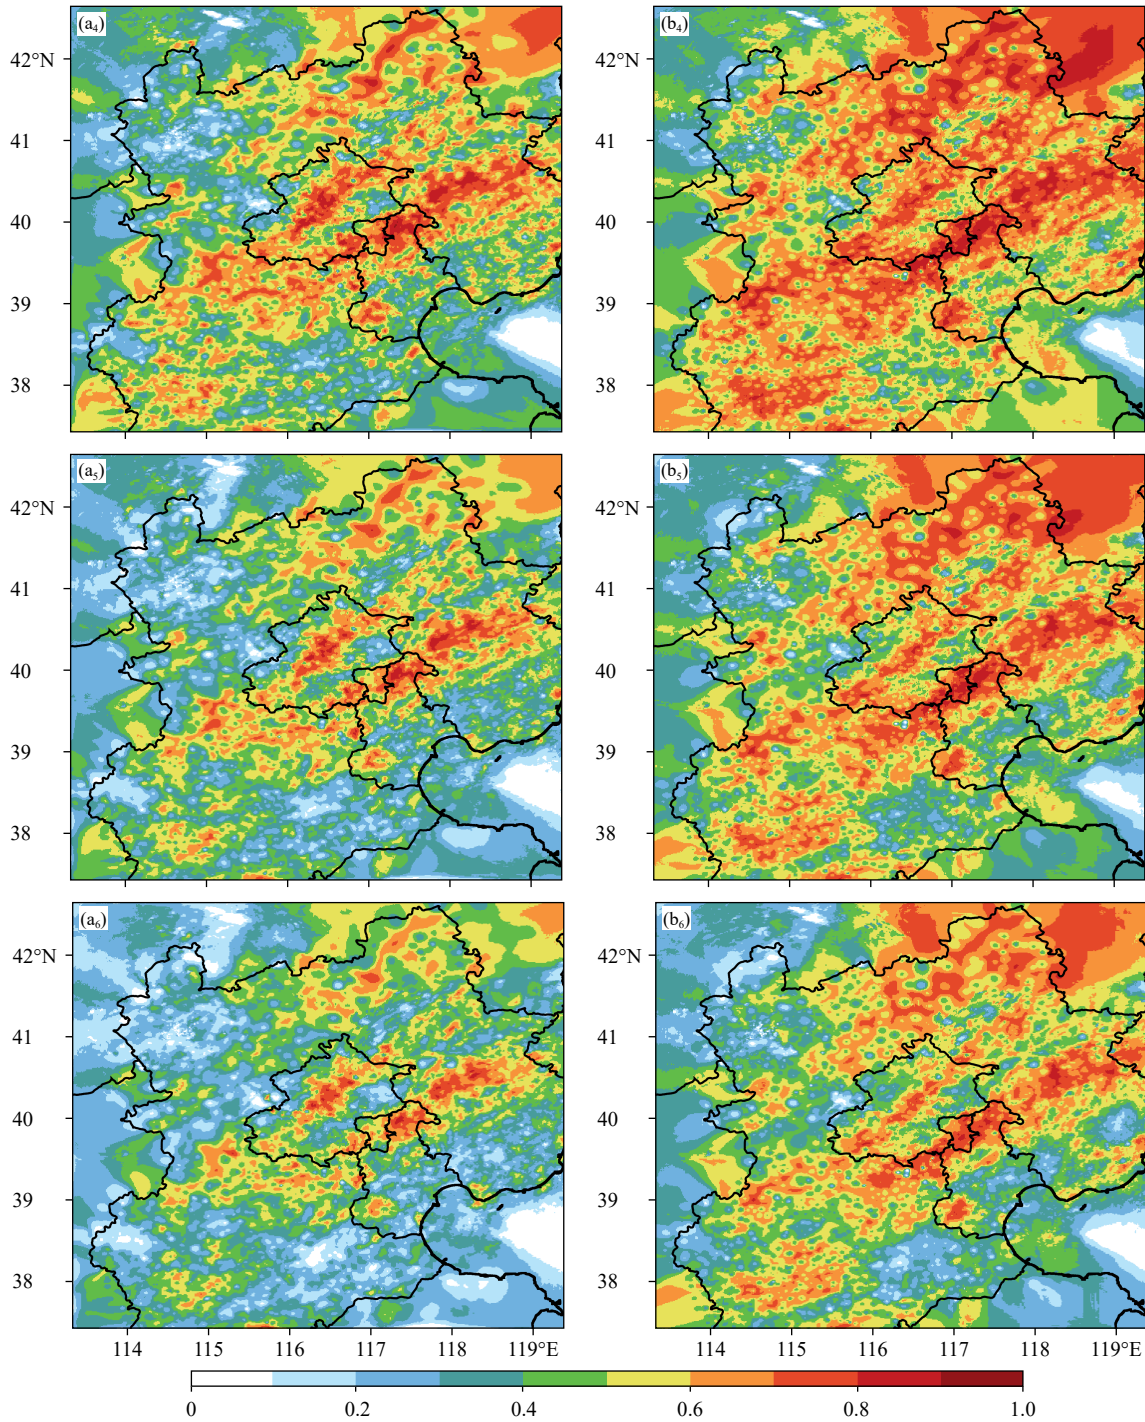


图 7 2020 年 6—9 月京津冀地区的相关系数空间分布 (a. 基于交叉相关的外推预报 (TREC) 相关系数, b. 两个深度学习模型相结合滚动预报 (RainNet) 的相关系数; 下标 1—6 分别表示预报时效为 10、20、30、40、50、60 min)

Fig. 7 Spatial distributions of correlation coefficient during June to September 2020 (a. TREC predictions, b. RainNet predictions; 1—6 represents the forecast time in 10, 20, 30, 40, 50 and 60 min, respectively)



续图 7

Fig. 7 Continued

下边界和白色线分别代表绝对误差的 75%、25%、50% 分位数, 上须和下须分别代表了 90%、10% 分位数。从图 8 可以看出, 在 10—60 min 的各预报时效下, 深度学习 RainNet 模型降水预报的绝对误差 90%、75%、50% 分位数明显低于传统交叉相关外

推预报场对应分位数。从图 9 的相关系数来看, 深度学习 RainNet 降水预报场相关系数的 90%、75%、50%、25% 和 10% 分位数相比传统交叉相关外推预报均有所提升。

图 10 给出了 2020 年 6—9 月降水预报与实况




图 8 绝对误差的时间序列箱线图 (黑色方框的上、下边界为 75%、25% 分位数, 上须和下须分别是 90% 和 10% 分位数, 黑盒子中的白线和白三角分别是中位数和均值; a—f. 分别是预报时效为 10、20、30、40、50、60 min 的结果)

Fig. 8 Box plots of mean absolute error (the upper and lower of the black box are the quantiles of 75% and 25%, the upper and lower whiskers are 90% and 10% quantiles, the white line and triangle in the black box show the median and mean values, respectively; a—f. the forecast time is 10, 20, 30, 40, 50 and 60 min, respectively)

的相关系数和绝对误差随着预报时效的变化曲线, 图中 RainNet 表示由两个深度学习模型相结合进行滚动预报 (图 4a、b) 的结果, RainNet_ori 表示单一深度学习模型完成 60 min 的滚动预报 (图 4c) 结果。由相关系数 (图 10a) 来看, 10—60 min 各预报时效下, 深度学习预报的相关系数均明显高于交叉相关外推预报, 且两个深度学习模型相结合进行滚动预报与实况的相关关系更好。随着预报时效延长, 深度学习相关系数的提升幅度逐渐增加, 在 10、20、30、40、50、60 min 时效下, 两个深度学习模型相结合的降水预报相比交叉相关外推预报提升幅度分别达到 4.0%、8.9%、13.3%、19.6%、24.5%、27.8%。从绝对误差 (图 10b) 来看, 10—60 min 各预报时效深度学习的绝对误差一致低于交叉相关外推的绝对误差, 且同样两个深度学习模型相结合的绝对误差最小。随着外推时效延长, 深度学习对绝对误差的改进幅度增大, 10—60 min 两个深度学习模型相结合的绝对误差比交叉相关外推的绝对误差分别降低 13.6%、17.5%、20.9%、24.3%、

26.3%、26.2%。通过对 2020 年 6—9 月降水过程整体检验发现, 深度学习对降水 1 h 的临近预报性能整体优于交叉相关外推预报性能, 采用两个深度学习模型相结合的滚动预报优于单一模型的滚动预报。

4.3 不同强度降水的预报检验

为进一步了解不同强度降水的临近预报性能, 分别计算不同量级降水的 CSI 评分 (式 (6))。结合北京 24 h 暴雨蓝色、黄色、橙色预警阈值, 将 10 min 降水量检验阈值设定为 0.02、0.49、0.69、1.04 mm, 给出不同降水阈值时的评分结果 (图 11), RainNet_ori 为单一深度学习模型的滚动预报结果, 代表改进前的 RainNet 滚动预报; RainNet 为两个深度学习模型相结合的预报结果, 代表改进后的 RainNet 滚动预报。可以看出, 采用两个 RainNet 模型相结合的滚动预报优于单一模型的滚动预报, 在 40—50 min 的降水预报得到明显提升, 其中 0.49 mm/(10 min) 阈值下, 40 min 预报时效时改进前、后的 CSI 评分分别为 0.36 和 0.40, 其对应 50 min 预报时效改进

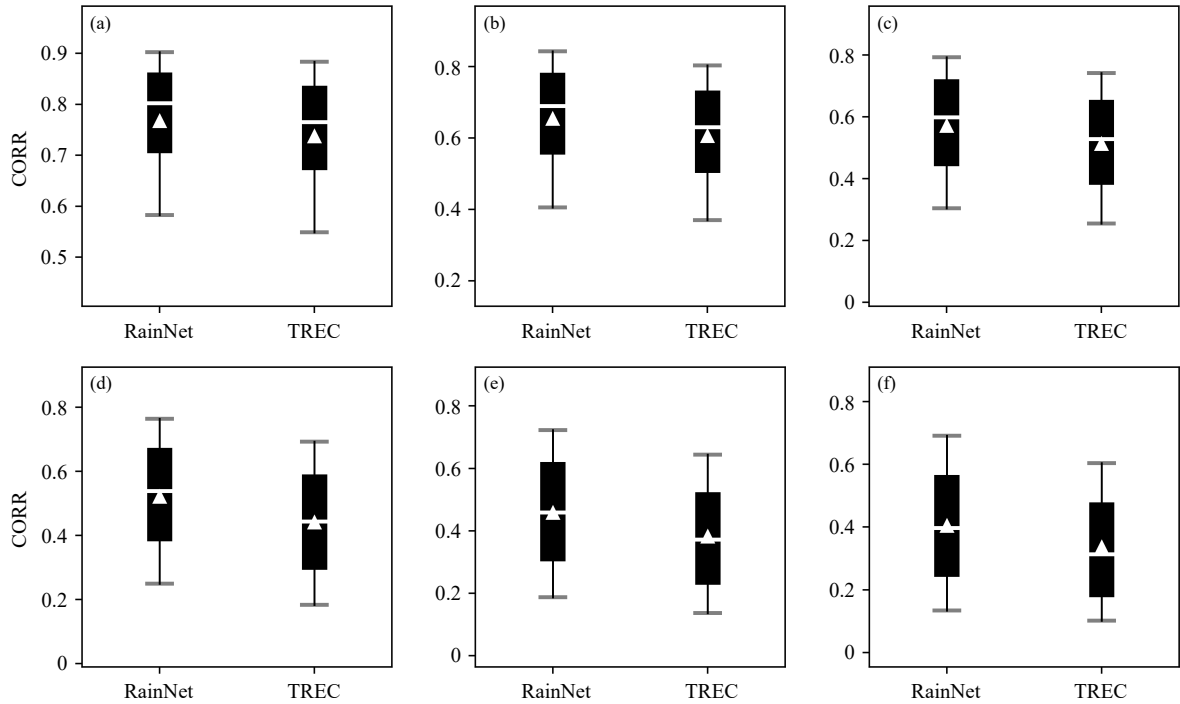


图 9 相关系数的时间序列箱线图 (黑色方框的上、下边界为 75%、25% 分位数, 上须和下须分别是 90% 和 10% 分位数, 黑盒子中的白线和白三角分别是中位数和均值; a—f. 分别是预报时效为 10、20、30、40、50、60 min 的结果)

Fig. 9 Box plots of correlation coefficient (the upper and lower of the black box are the quantiles of 75% and 25%, the upper and lower whiskers are 90% and 10% quantiles, the white line and triangle in the black box show the median and mean values, respectively; a—f. the forecast time is 10, 20, 30, 40, 50 and 60 min, respectively)

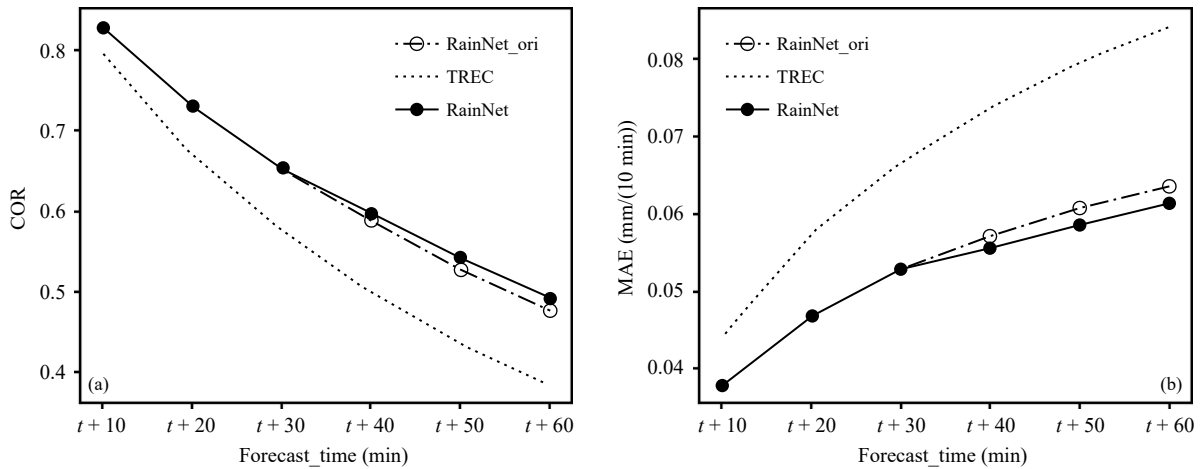


图 10 2020 年 6—9 月降水临近预报的相关系数 (a) 和绝对误差 (b) 曲线

Fig. 10 Mean absolute errors (a) and correlation coefficients (b) during June to September 2020

前、后 CSI 评分为 0.30、0.34; 0.69 mm/(10 min) 阈值下, 40 min 预报时效改进前、后的 CSI 评分为 0.31、0.35, 其对应 50 min 预报时效改进前、后的 CSI 评分分别为 0.26、0.29。可见, 改进后采用两个 RainNet 模型相结合的滚动预报可以较好地改善 40、50 min 时效的降水临近预报能力, 这主要是

因为调整了深度学习 RainNet 模型在 40、50 min 的模型输入。另外, 与交叉相关外推预报相比, 4 个降水阈值下, 两个 RainNet 模型相结合的滚动预报方式在 10—50 min 的降水预报性能均优于交叉相关外推预报。

综合来看, RainNet 模型采用滚动的预报方式

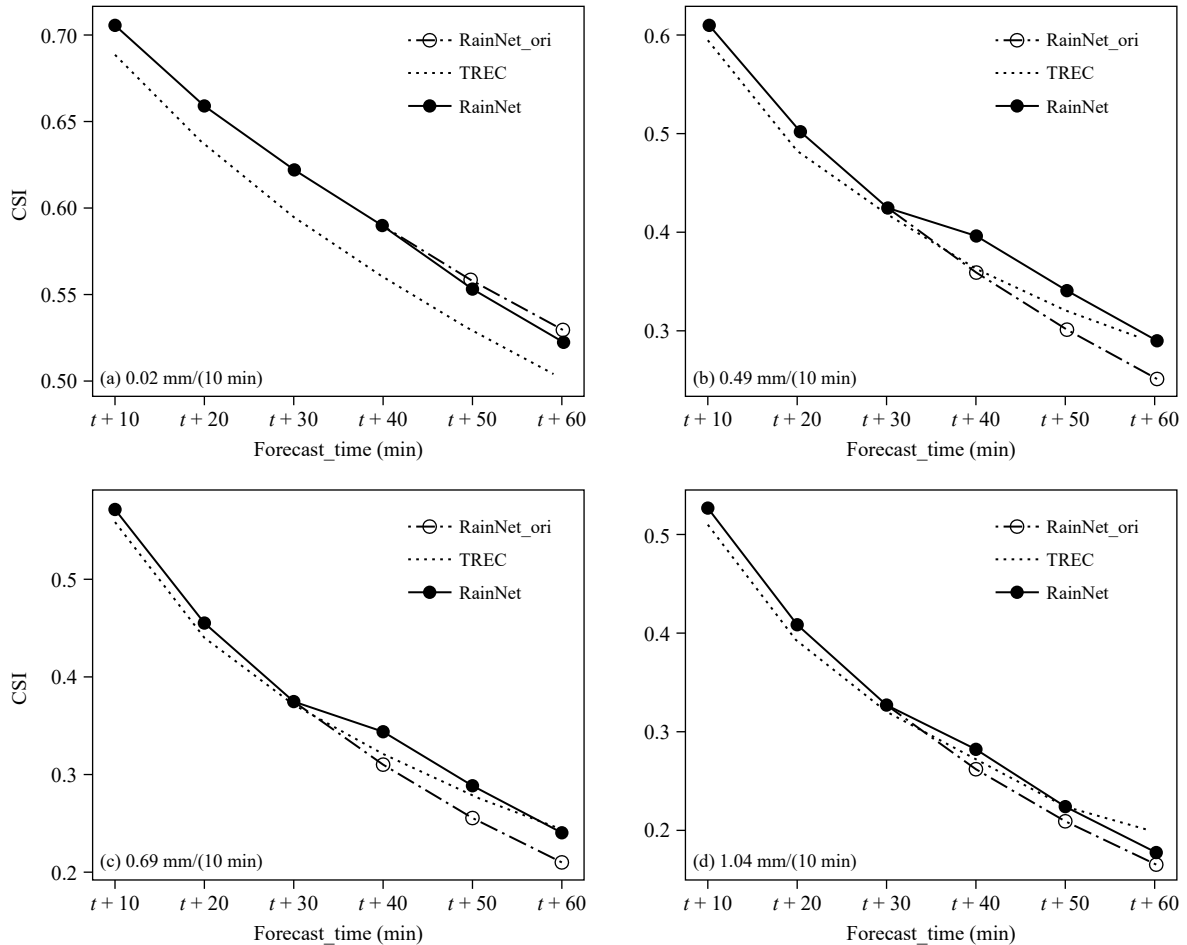


图 11 2020 年 6—9 月不同降水阈值 (a—d) 的 CSI 评分曲线

Fig. 11 Critical success indexes (CSI) for four different intensity thresholds (a—d) during June to September 2020

随着滚动次数增加对预报性能影响较大。由于将上一时刻的预报值作为下一时刻预报的模型输入因子,因而随着预报时效的延长引入模型的误差将随之增大,造成预报性能下降,这是其不足之处。但当模型训练完成以后,其滚动次数可以灵活调整,且无需重新训练优化模型,而且 RainNet 模型结构简洁,便于训练。因而结合其特性,设计的两个 RainNet 模型相结合的滚动式预报方式改善了 40—50 min 的降水预报性能。

4.4 个例分析

上述分析给出了降水外推预报和深度学习预报的整体检验,以及不同强度降水的预报性能。下面将结合降水个例分析不同模型的临近预报表现。

4.4.1 2020 年 7 月 31 日个例

图 12 给出 2020 年 7 月 31 日 11 时 20 分(世界时,下同)起报的未来 10—60 min 的降水临近预报

结果及对应降水实况。

在 11 时 20 分由交叉相关降水外推预报显示,未来 1 h(11 时 30 分—12 时 20 分)京津冀南部地区有降水,降水的落区和强度与当前情况基本保持不变,降水中心的强度为 5—10 mm/(10 min);深度学习模型对未来 1 h 逐 10 min 的滚动预报显示,11 时 20 分—12 时 20 分降水落区变化不大但降水强度呈明显减弱的趋势。通过与降水实况对比(图 12c)对比,交叉相关外推的降水预报场偏强(图 12a),对降水过程的减弱趋势反映不够明显,而深度学习的预报结果则与实际降水强度演变趋势更吻合(图 12b)。整体来看,深度学习模型能够更好地体现 1 h 内逐 10 min 降水强度随时间的演变特征。

4.4.2 2020 年 8 月 1 日个例

图 13 给出 2020 年 8 月 1 日 13 时 50 分起报的未来 10—60 min 降水临近预报结果及对应的降水

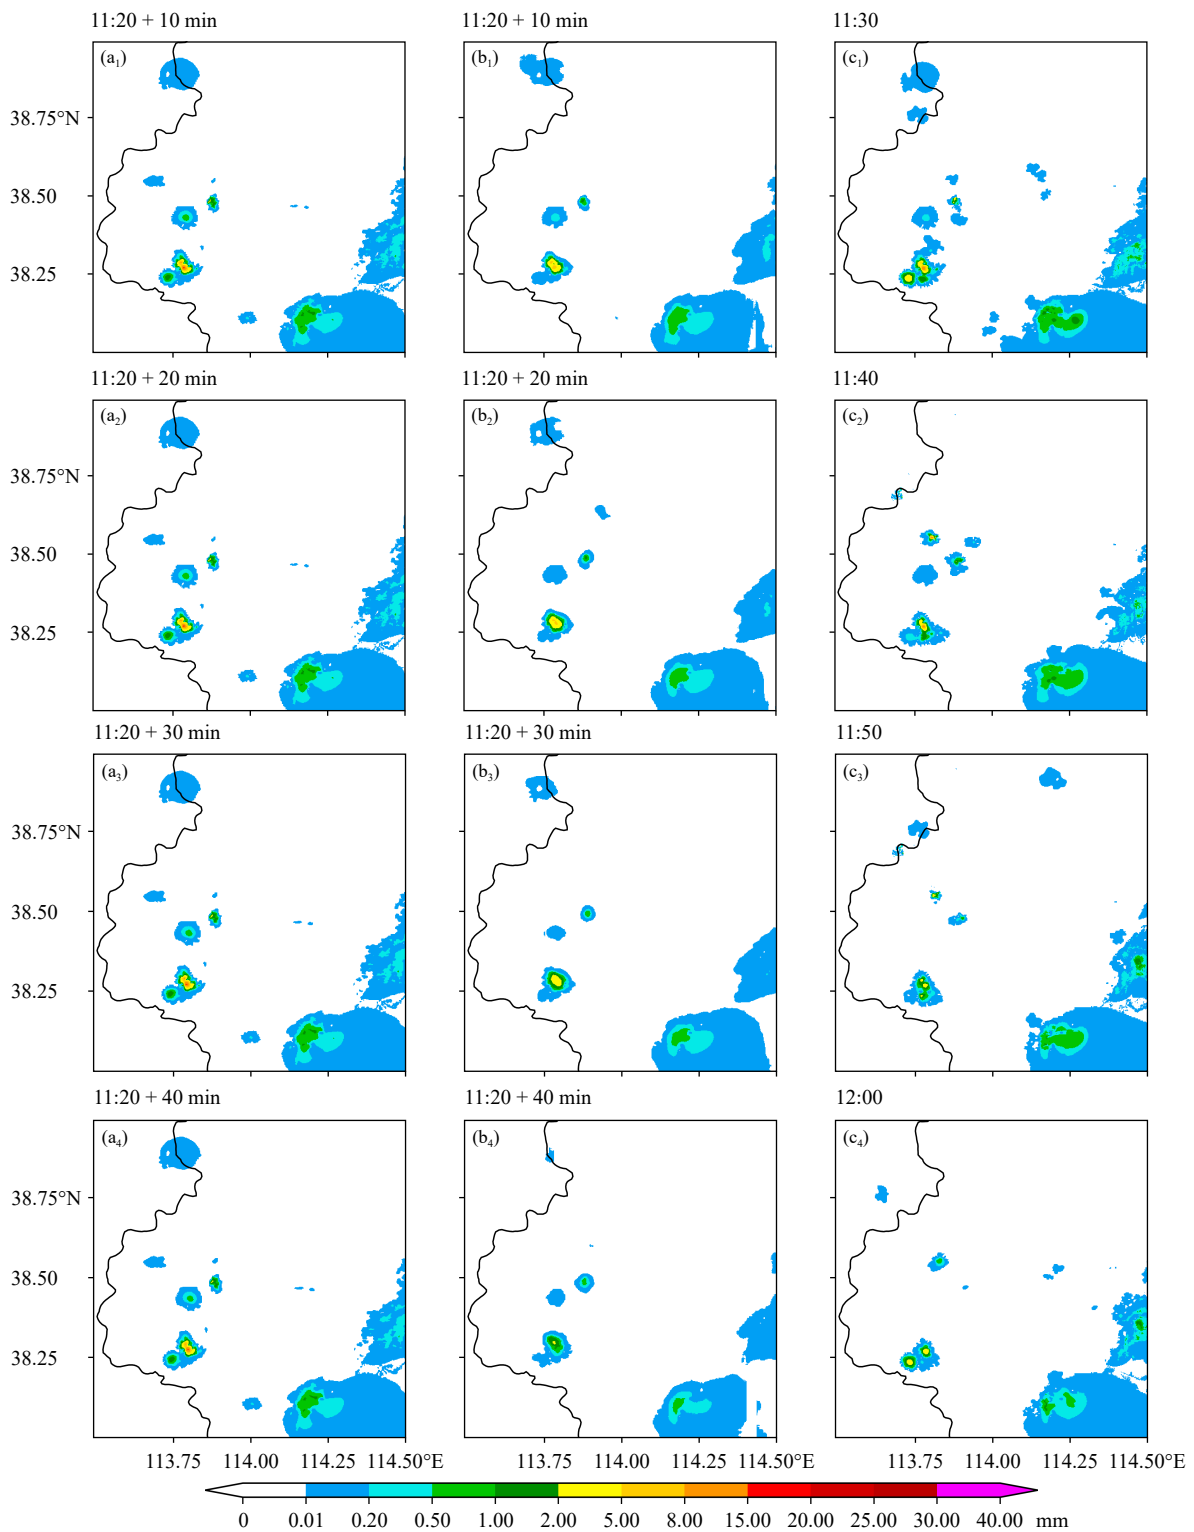
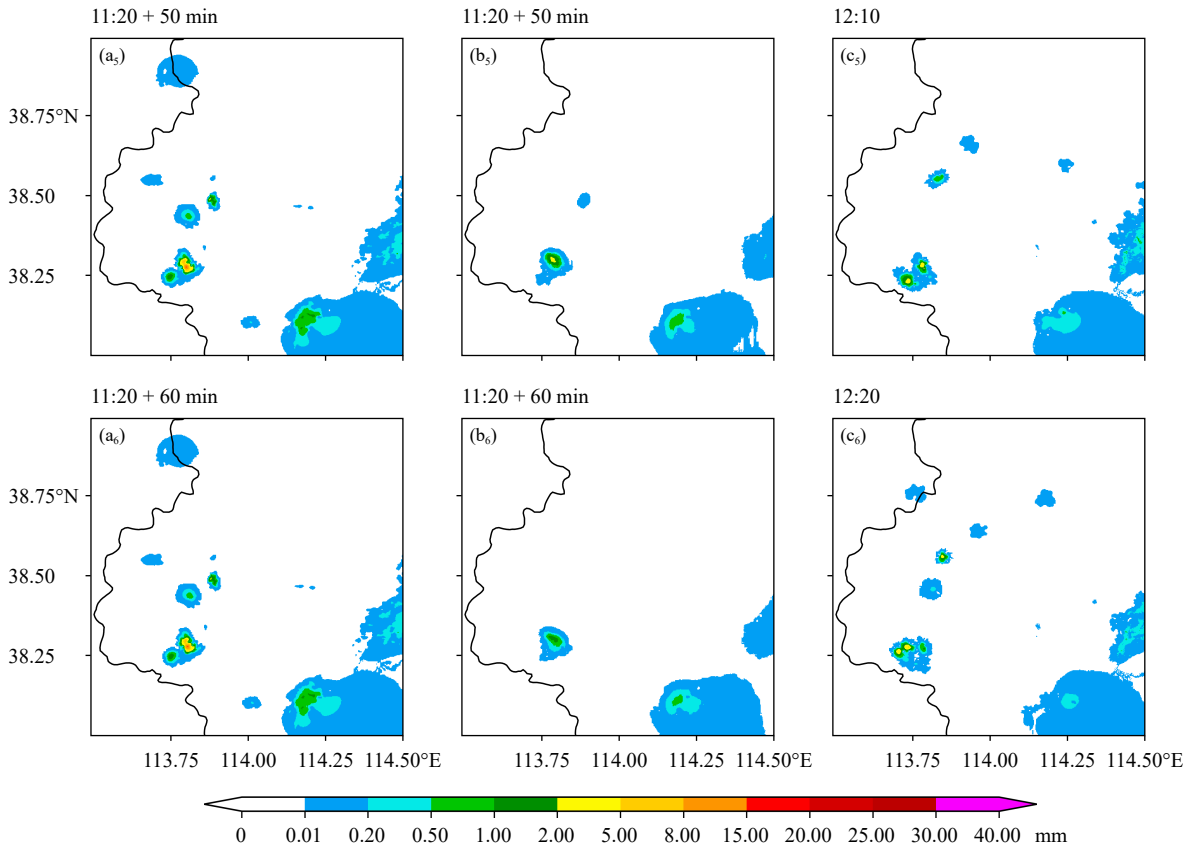


图 12 2020 年 7 月 31 日 11 时 20 分起报 10—60 min (a₁—a₆、b₁—b₆) 降水临近预报结果及降水实况(c₁—c₆) (a. 交叉相关外推预报, b. 深度学习 RainNet 预报, c. 相应时间的降水实况)

Fig. 12 Predictions of TREC (a₁—a₆) and RainNet (b₁—b₆) as well as corresponding observations (c₁—c₆) at 11:20 UTC 31 July 2020 (1—6 represents the forecast time in 10, 20, 30, 40, 50 and 60 min, respectively)



续图 12

Fig. 12 Continued

实况。两种方法在 13 时 50 分均预报未来 1 h (14 时 00—50 分) 京津冀南部将有明显的降水过程。从降水范围预报来看, 小量级降水 (0.2 mm/(10 min)) 的预报范围两者基本一致, 基于交叉相关外推预报对 2—5 mm/(10 min) 量级降水 (图中浅黄色) 的预报范围比实际略偏大 (图 13a、c), 而深度学习对 2—5 mm/(10 min) 降水范围预报结果与实况更加接近 (图 13b、c)。从降水的移动发展趋势来看, 逐 10 min 交叉相关外推预报显示出 14 时 00—50 分雨带将逐渐向东北方向发展移动, 而降水强度在未来 1 h 基本维持不变; 但深度学习逐 10 min 预报显示 14 时 00—50 分雨带整体将偏向东南方向移动, 而降水强度呈逐渐减弱的趋势 (图 13b), 这与实况降水的时空演变 (图 13c₁—c₆) 更吻合。可以看出, 深度学习可以更好地反映降水衰减过程的发展方向、强度变化和降水范围。但相比传统交叉相关外推预报, 深度学习的降水预报场比较平滑, 这主要是由于深度学习模型基于卷积运算产生了平滑

效应。总体来看, 深度学习 RainNet 对本次降水过程的降水范围、空间移动趋势以及降水强度随时间演变的临近预报表现更好。

4.4.3 2020 年 8 月 15 日个例

图 14 给出 2020 年 8 月 15 日 03 时起报 10—60 min 降水外推预报结果。从交叉相关外推预报 (图 14a) 结果来看, 03 时 10 分—04 时 00 分降水向东北方向移动, 在移动过程中降水强度变化不大; 而深度学习模型的预报 (图 14b) 则显示, 降水落区基本保持不变、空间移动不明显, 但降水强度呈现明显减弱的趋势。结合相应时间的降水实况 (图 14c) 来看, 03 时 10 分—04 时 00 分京津冀东南部地区有明显降水, 且降水落区变化不大, 但强度随时间逐渐减弱, 整体来看, 降水实况与深度学习的临近预报结果比较一致。

综合个例的预报结果来看, 基于交叉相关的降水外推预报由于采用前面时刻的降水移动矢量进行外推, 降水预报场基本保持空间平移, 而强度变

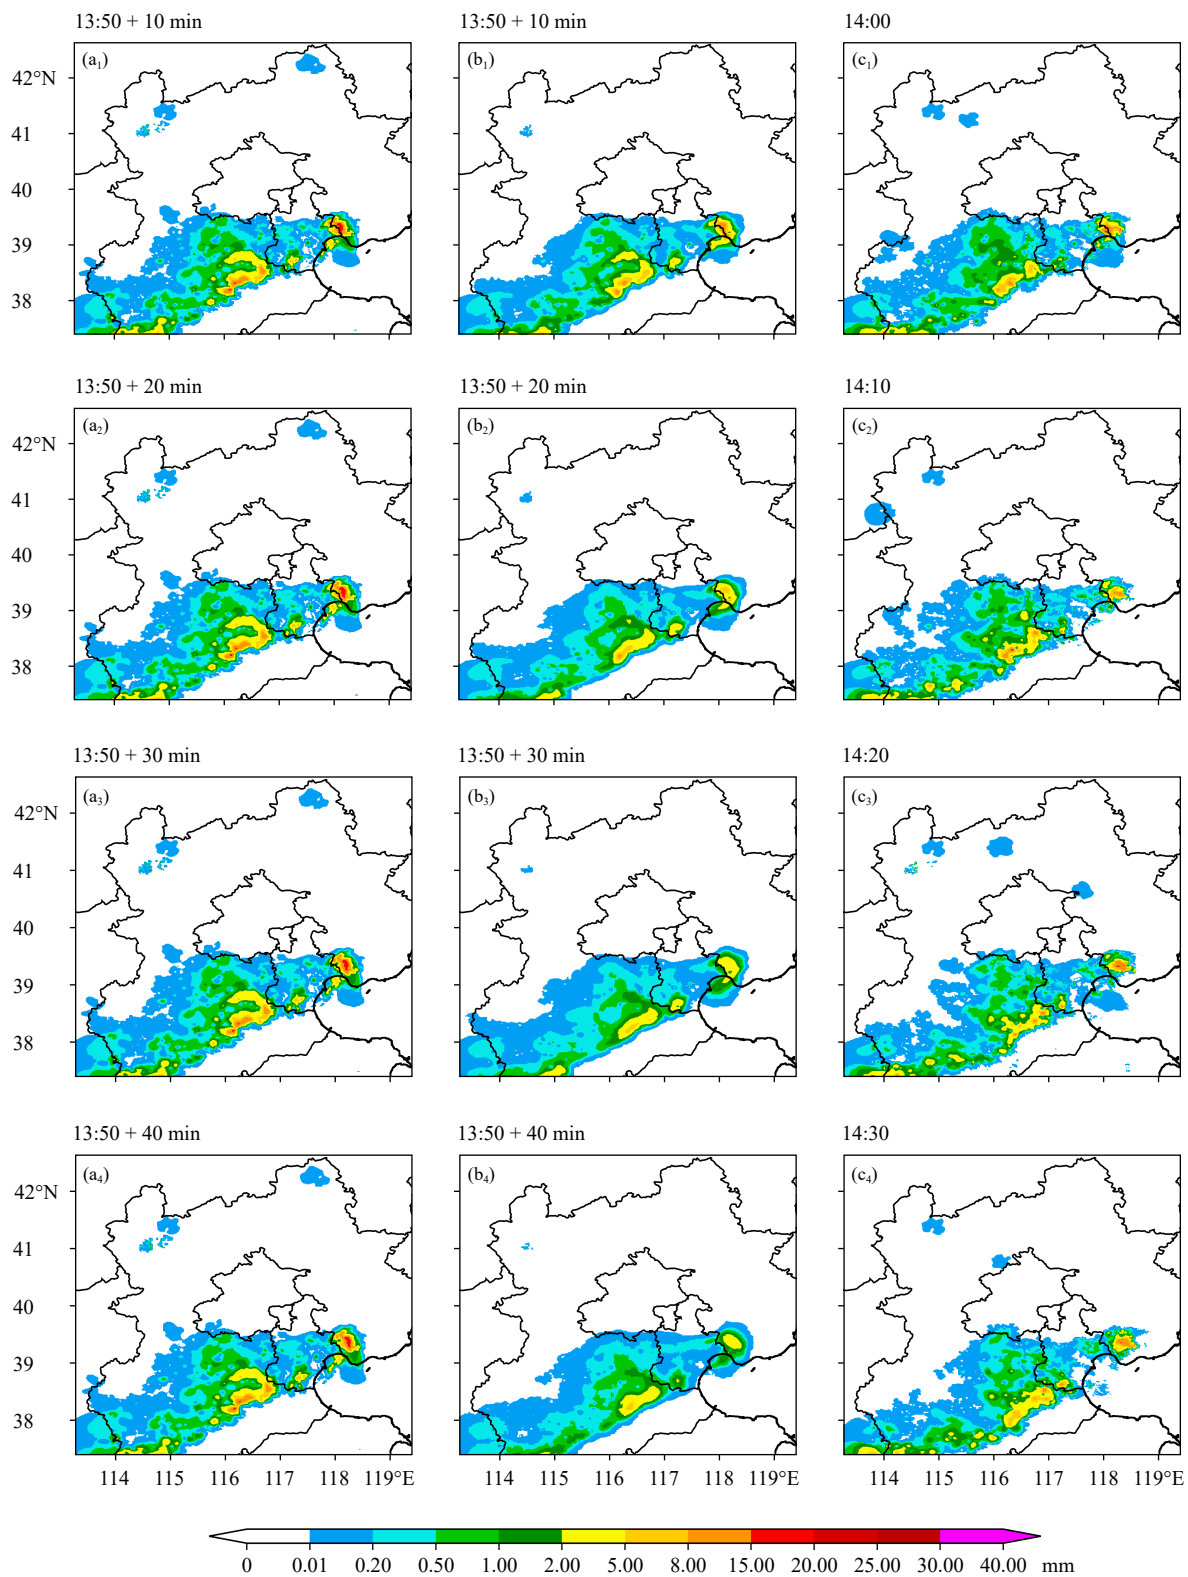
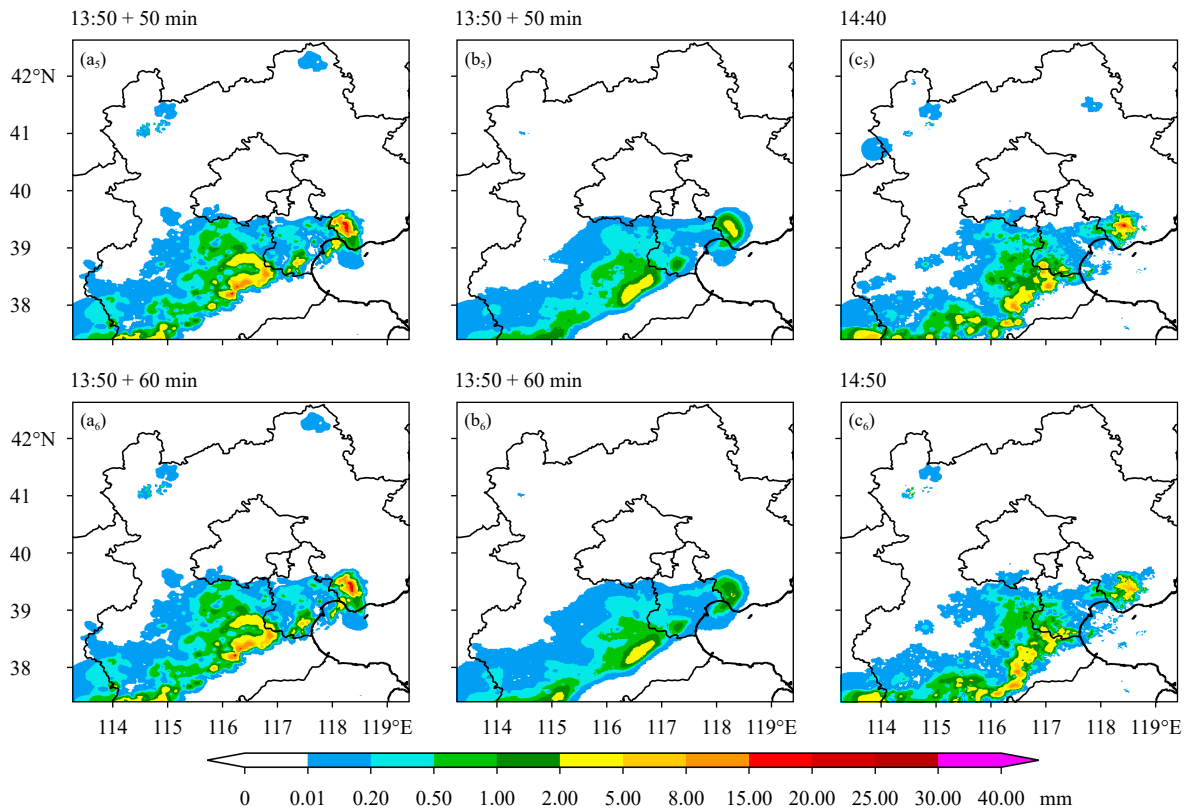


图 13 2020 年 8 月 1 日 13 时 50 分起报 10—60 min (a_1 — a_6 、 b_1 — b_6) 降水临近预报结果及降水实况 (c_1 — c_6) (a. 交叉相关外推预报, b. 深度学习 RainNet 预报, c. 相应时间的降水实况)

Fig. 13 Predictions of TREC (a_1 — a_6) and RainNet (b_1 — b_6) as well as corresponding observations (c_1 — c_6) at 13:50 UTC 1 August 2020 (1—6 represents the forecast time in 10, 20, 30, 40, 50 and 60 min, respectively)



续图 13

Fig. 13 Continued

化不大,更适用于范围较大的稳定性降水。相对而言,深度学习 RainNet 可以更好地反映降水消亡过程中的时、空演变趋势和强度变化,对降水消亡阶段的临近预报具有一定优势。

5 结论与讨论

为改进精细尺度降水临近预报能力,采用 2017—2020 年 6—9 月高时、空分辨率降水资料,基于深度学习模型 RainNet 开展了京津冀地区降水临近预报试验,与传统交叉相关外推预报方法进行对比分析。试验结果发现:

(1)从 2020 年 6—9 月降水临近预报的绝对误差和相关系数空间分布来看,深度学习 RainNet 模型的整体表现明显优于基于交叉相关的外推预报,尤其对京津冀南部地区降水预报绝对误差改善更加明显。基于 RainNet 模型预报的相关系数与交叉相关外推预报的相关系数空间分布趋势比较一致,沿着东北—西南方向的平原地区的相关系数较大,西北部山区的相关系数相对较小,但深度学习的相关系数整体明显优于交叉相关外推预报的相关系数。

(2)深度学习 RainNet 的滚动预报方式对预报性能影响较大。单一模型连续进行 60 min 滚动预报时,30 min 后模型预报性能衰减较快,而通过两个模型相结合的滚动预报方式改善了模型在 40、50 min 预报的输入因子,因而提升了 RainNet 模型在 40、50 min 的临近预报性能。

(3)从不同预报时效上看,10—60 min 各预报时效上,深度学习预报的绝对误差和相关系数均稳定超过交叉相关外推预报,且随着预报时效延长,深度学习对绝对误差和相关系数的改进幅度逐渐增大,采用两个 RainNet 模型相结合进行滚动预报的绝对误差和相关系数均表现最好。

(4)从不同量级降水的预报性能来看,在 0.02、0.49、0.69、1.04 mm/(10 min) 的降水阈值下,采用两个 RainNet 模型相结合的滚动预报方式,10—50 min 各时效的临近预报一致优于交叉相关外推预报,同时,相对于单一 RainNet 模型在 40—50 min 滚动预报也有明显提升。

(5)个例分析发现,深度学习对降水消亡过程的时、空演变趋势预报表现更好,可以更好地刻画

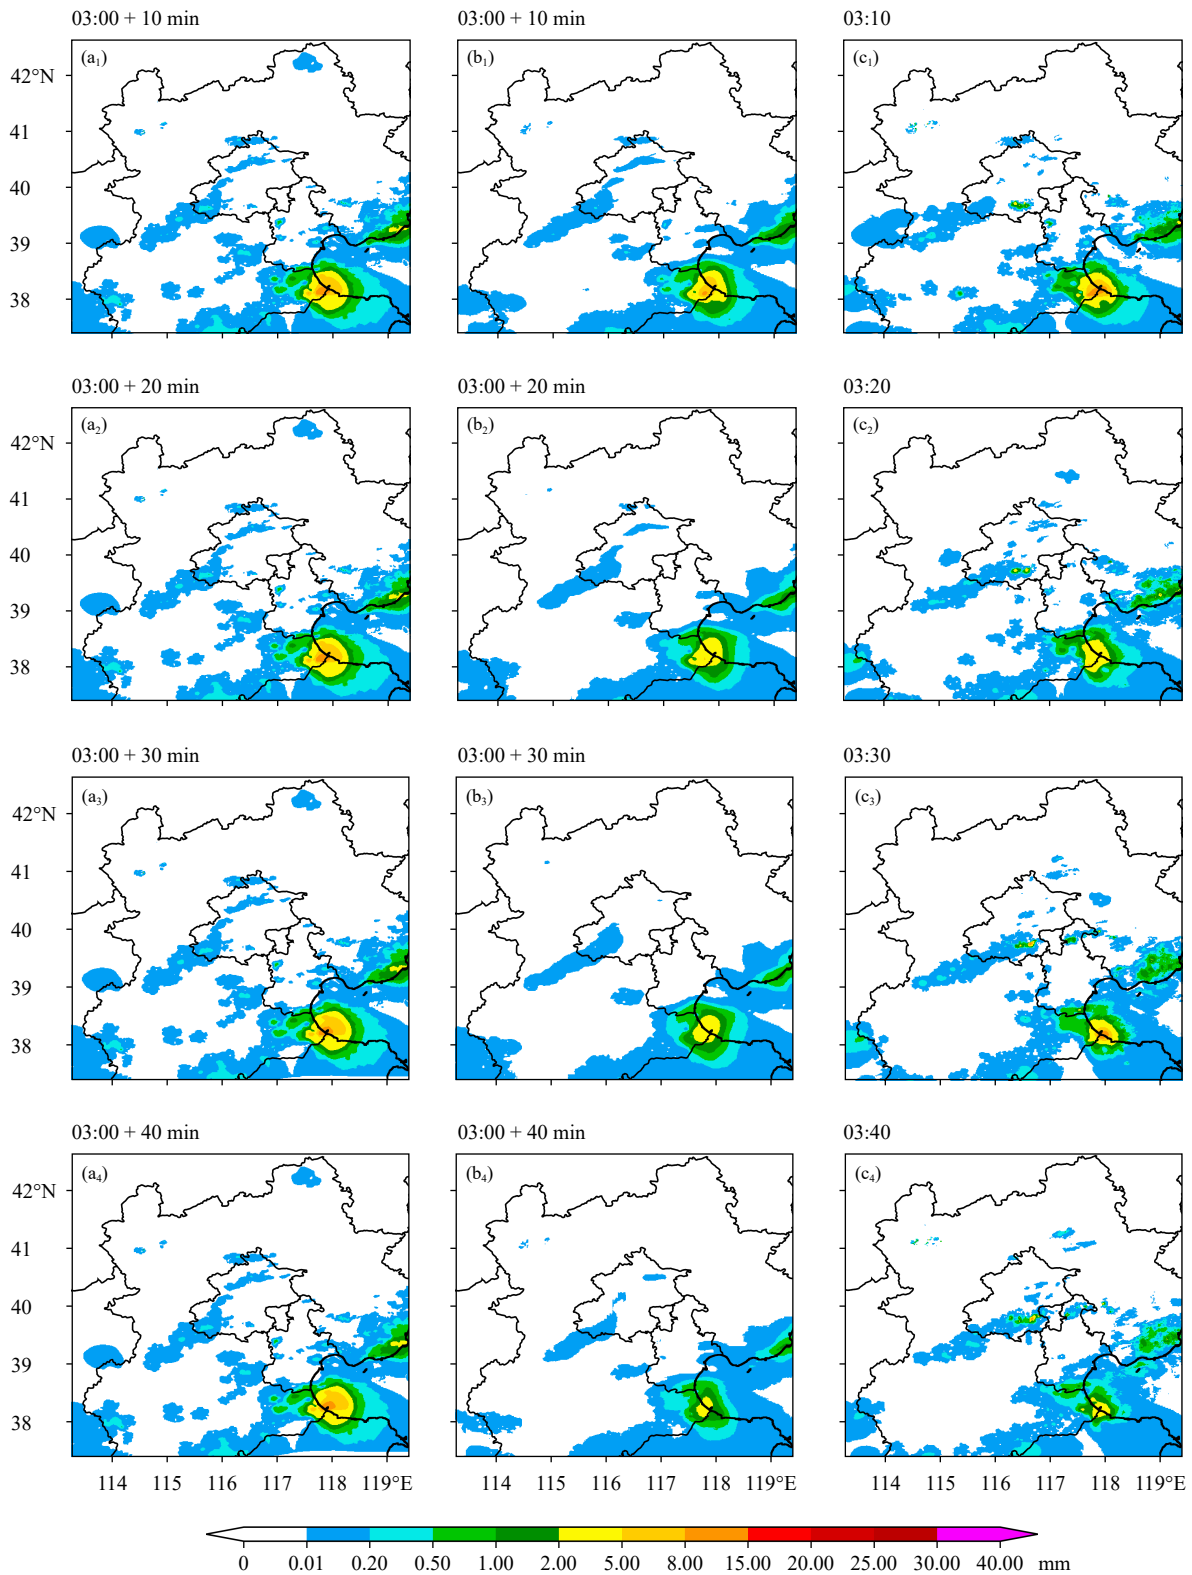
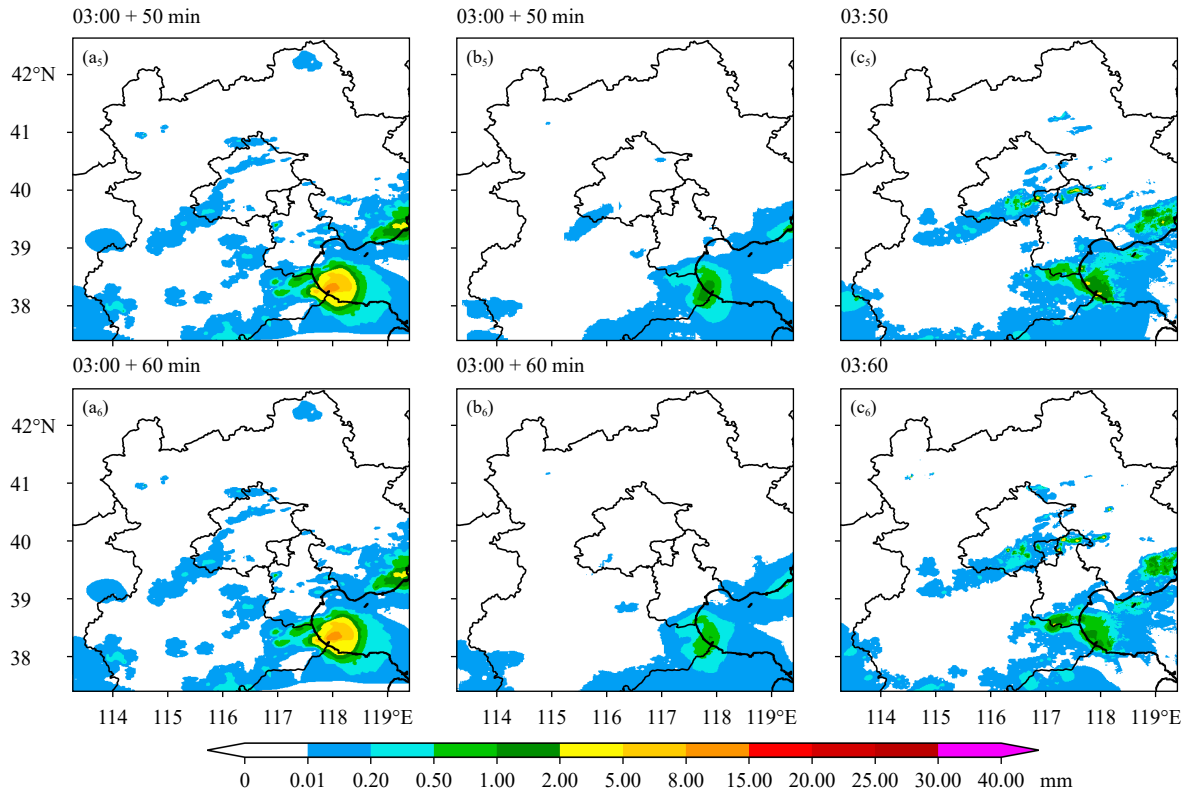


图 14 2020 年 8 月 15 日 03 时 00 分起报 10—60 min (a_1 — a_6 、 b_1 — b_6) 降水临近预报结果及降水实况 (c_1 — c_6) (a. 交叉相关外推预报, b. 深度学习 RainNet 预报, c. 相应时间的降水实况)

Fig. 14 Predictions of TREC (a_1 — a_6) and RainNet (b_1 — b_6) as well as corresponding observations (c_1 — c_6) at 03:00 UTC 15 August 2020 (1—6 represents the forecast time in 10, 20, 30, 40, 50 and 60 min, respectively)



续图 14

Fig. 14 Continued

降水衰减过程的移动方向、强度变化及降水范围，这与其滚动式预报方式有关，而交叉相关外推预报更适用于发展变化不剧烈的稳定降水。

此外，深度学习 RainNet 模型应用于降水临近预报还有待于继续深入完善。RainNet 模型采用的滚动式预报方式优缺点并存，一方面由于其将上一个时刻的预报结果作为下一个时刻预报的输入因子将引入误差，不利于保持长时效滚动预报的准确性，另一方面该滚动预报方式灵活可变，模型便于训练，因而如何合理设计模型的滚动预报方式将影响其预报能力。另外，深度学习降水预报场相对平滑，这方面也有待于进一步改进。

参考文献

- 曹伟华, 陈明轩, 高峰等. 2019. 雷暴区域追踪矢量与雷暴单体追踪矢量融合临近预报研究. *气象学报*, 77(6): 1015-1027. Cao W H, Chen M X, Gao F, et al. 2019. A vector blending study based on object-based tracking vectors and cross correlation tracking vectors. *Acta Meteor Sinica*, 77(6): 1015-1027 (in Chinese)
- 陈明轩, 高峰, 孔荣等. 2010. 自动临近预报系统及其在北京奥运期间的应用. *应用气象学报*, 21(4): 395-404. Chen M X, Gao F, Kong R, et al. 2010. Introduction of auto-nowcasting system for convective storm and its performance in Beijing Olympics meteorological service. *J Appl Meteor Sci*, 21(4): 395-404 (in Chinese)
- 程丛兰, 陈敏, 陈明轩等. 2019. 临近预报的两种高时空分辨率定量降水预报融合算法的对比试验. *气象学报*, 77(4): 701-714. Cheng C L, Chen M, Chen M X, et al. 2019. Comparative experiments on two high spatiotemporal resolution blending algorithms for quantitative precipitation nowcasting. *Acta Meteor Sinica*, 77(4): 701-714 (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)
- 韩丰, 龙明盛, 李月安等. 2019. 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)
- 孙健, 曹卓, 李恒等. 2021. 人工智能技术在数值天气预报中的应用. *应用气象学报*, 32(1): 1-11. Sun J, Cao Z, Li H, et al. 2021. Application of artificial intelligence technology to numerical weather prediction. *J Appl Meteor Sci*, 32(1): 1-11 (in Chinese)
- 王改利, 刘黎平, 阮征. 2007. 多普勒雷达资料在暴雨临近预报中的应用. *应*

- 用气象学报, 18(3): 388-395. Wang G L, Liu L P, Ruan Z. 2007. Application of doppler radar data to nowcasting of heavy rainfall. *J Appl Meteor Sci*, 18(3): 388-395 (in Chinese)
- Ayzel G, Heistermann M, Sorokin A, et al. 2019. All convolutional neural networks for radar-based precipitation nowcasting. *Procedia Comput Sci*, 150: 186-192
- Ayzel G, Scheffer T, Heistermann M. 2020. RainNet v1.0: A convolutional neural network for radar-based precipitation nowcasting. *Geosci Model Dev*, 13(6): 2631-2644
- Chen L, Cao Y, Ma L M, et al. 2020. A deep learning-based methodology for precipitation nowcasting with radar. *Earth Space Sci*, 7(2): e2019EA000812
- Chen M, Bica B, Tüchler L, et al. 2017. Statistically extrapolated nowcasting of summertime precipitation over the Eastern Alps. *Adv Atmos Sci*, 34(7): 925-938
- Dixon M, Wiener G. 1993. TITAN: Thunderstorm identification, tracking, analysis, and nowcasting: A radar-based methodology. *J Atmos Oceanic Technol*, 10(6): 785-797
- Germann U, Zawadzki I. 2002. Scale-dependence of the predictability of precipitation from continental radar images. Part I: Description of the methodology. *Mon Wea Rev*, 130(12): 2859-2873
- Haiden T, Kann A, Wittmann C, et al. 2011. The integrated nowcasting through comprehensive analysis (INCA) system and its validation over the eastern Alpine region. *Wea Forecasting*, 26(2): 166-183
- Han L, Sun J Z, Zhang W, et al. 2017. A machine learning nowcasting method based on real-time reanalysis data. *J Geophys Res*, 122(7): 4038-4051
- Johnson J T, MacKeen P L, Witt A, et al. 1998. The storm cell identification and tracking algorithm: An enhanced WSR-88D algorithm. *Wea Forecast*, 13(2): 263-276
- Kingma D P, Ba J. 2015. Adam: A method for stochastic optimization//Proceedings of the 3rd International Conference on Learning Representations. San Diego: ICLR
- Li L, Schmid W, Joss J. 1995. Nowcasting of motion and growth of precipitation with radar over a complex orography. *J Appl Meteorol Climatol*, 34(6): 1286-1300
- Mueller C, Saxen T, Roberts R, et al. 2003. NCAR auto-nowcast system. *Wea Forecast*, 18(4): 545-561
- Rinehart R E, Garvey E T. 1978. Three-dimensional storm motion detection by conventional weather radar. *Nature*, 273(5660): 287-289
- 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: MIT Press, 802-810
- Sokol Z, Kitzmiller D, Pesice P, et al. 2013. Comparison of precipitation nowcasting by extrapolation and statistical-advection methods. *Atmos Res*, 123: 17-30
- Staniforth A, Côté J. 1991. Semi-Lagrangian integration schemes for atmospheric models: A review. *Mon Wea Rev*, 119(9): 2206-2223
- Sun J Z, Xue M, Wilson J W, et al. 2014. Use of NWP for nowcasting convective precipitation: Recent progress and challenges. *Bull Amer Meteor Soc*, 95(3): 409-426
- Wilks D S. 2011. *Statistical Methods in the Atmospheric Sciences*. 3rd ed. Boston: Academic Press, 309-310
- Wilson J W, Crook N A, Mueller C K, et al. 1998. Nowcasting thunderstorms: A status report. *Bull Amer Meteor Soc*, 79(10): 2079-2100