

CastNet: 深度学习定量降水临近预报模型

曾小团¹ 谭肇² 沈玉伟³ 范娇¹ 黄荣成¹ 周弘媛⁴ 梁潇² 黄大剑²

1 广西壮族自治区气象台, 南宁 530022

2 北京思湃德信息技术有限公司, 北京 100081

3 绍兴市气象台, 绍兴 312030

4 绍兴市柯桥区气象局, 绍兴 312030

摘要: 为了提高降水临近预报的准确性, 提出一种深度神经网络相结合的对抗神经网络模型 CastNet。该模型借助循环神经网络 (RNN) 捕捉雷达回波数据的时空特征, 运用对抗神经网络 (GAN) 模拟云团生消变化, 再将光流约束融入神经网络引导模型训练, 加速神经网络的学习过程并增强模型的时空一致性, 有效地解决了预报模糊性问题, 提升降水强度与位置的准确性。对 2023 年 5 月至 10 月广西及周边区域 ($20.90^{\circ} \sim 26.49^{\circ} \text{ N}$, $104.41^{\circ} \sim 112.08^{\circ} \text{ E}$) 的 9 次主要降水过程进行检验, 结果表明: 在各降水强度 (≥ 0.1 、 ≥ 2 、 ≥ 7 、 ≥ 15 、 ≥ 25 、 $\geq 40 \text{ mm}\cdot\text{h}^{-1}$) 下, SWAN 2.0 的平均 TS 评分分别为 0.458、0.27、0.085、0.034、0.014 和 0.003; SWAN 3.0 的平均 TS 评分分别为 0.452、0.402、0.225、0.129、0.085 和 0.048; CastNet 模型的平均 TS 评分分别为 0.439、0.397、0.225、0.139、0.104 和 0.073; 即: CastNet 在 $\geq 7 \text{ mm}\cdot\text{h}^{-1}$ 及以上高强度降水中评分均高于 SWAN 2.0 和 SWAN 3.0。此外, 随着预报时效延长, CastNet 的相对优势更为明显。

关键词: 短时强降水, 定量降水预报, 深度学习模型, 循环神经网络, 对抗神经网络

CastNet: Deep Learning-Based Model for Quantitative

Precipitation Nowcasting

ZENG Xiaotuan¹ TAN Zhao² SHEN Yuwei³ FAN Jiao¹ HUANG Rongcheng¹ ZHOU
Hongyuan⁴ LIANG Xiao² HUANG Dajian²

1 Guangxi Meteorological Observatory, Nanning 530022

2 Beijing Spider Information Technology Co., Ltd., Beijing 100081

3 Shaoxing City Meteorological Observatory, Shaoxing 312030

4 Keqiao District Meteorological Bureau of Shaoxing City, Shaoxing 312030

Abstract: To improve the accuracy of precipitation nowcasting, this paper proposes an adversarial neural network model named CastNet that combines deep neural networks. This model utilizes the Recurrent Neural Network (RNN) to capture the spatio-temporal features of radar echo data, employs the Adversarial Neural Network (GAN) to simulate the generation and dissipation changes of cloud clusters, and then integrates the optical flow constraint into the neural network to guide the model training, which accelerates the learning process of the neural network and enhances the spatio-temporal consistency of the model, effectively solving the problem of forecast ambiguity and significantly improving the accuracy of precipitation intensity and location. Tests were conducted on 9 major precipitation processes in Guangxi and its surrounding areas (104.41° E - 112.08° E , 20.9° N - 26.49° N) from May to October 2023. The results show that under various

*广西智能网格预报服务创新团队专项、广西自然科学基金项目 (2022GXNSFAA035482)、桂气科 2024Z01 共同资助

第一作者: 曾小团, 主要从事短时临近预报技术研究和系统开发, Email: 158083890@qq.com

通讯作者: 谭肇, 从事人工智能与气象技术研究, Email: 504523121@qq.com

precipitation intensities (≥ 0.1 , ≥ 2 , ≥ 7 , ≥ 15 , ≥ 25 , ≥ 40 mm·h⁻¹), the average TS scores of SWAN 2.0 are 0.458, 0.27, 0.085, 0.034, 0.014 and 0.003 respectively; the average TS scores of SWAN 3.0 are 0.452, 0.402, 0.225, 0.129, 0.085 and 0.048 respectively; and the average TS scores of the CastNet model are 0.439, 0.397, 0.225, 0.139, 0.104 and 0.073 respectively. Its scores are higher than those of SWAN 2.0 and SWAN 3.0 under high-intensity precipitation of ≥ 7 mmh⁻¹ and above. In addition, as the forecast lead time extends, the relative advantage of CastNet becomes more obvious.

Key words: Short-duration heavy precipitation, quantitative precipitation forecast, deep learning model, recurrent neural network, generative adversarial network

引言

短时强降水灾害性天气在复杂的山河地貌和地形条件下,常常引发洪涝、滑坡和泥石流等次生灾害,对人民生命安全和经济社会发展构成严重威胁。为了有效防范和减轻这些灾害的影响,气象学者长期以来致力于短时临近定量降水预报方法的研究,旨在提高预报的准确性并取得了一定的阶段性成果。0~1h 临近预报方面,外推方法作为主要手段已被广泛应用,研究从最初的回波质心跟踪法(乔春贵等,2006)发展到交叉相关法(陈明轩等,2007;万齐林等,2005)、改进的交叉相关追踪法(COTREC)等(Li et al,1995;陈雷等,2009;罗义等,2022;符式红等,2012)以及更先进的光流法等轨迹外推算法(韩雷等,2008;张智察等,2022;曹春燕等,2015;Pulkkinen et al,2019),这些方法在 0-1h 的降水外推预报中表现出了良好的有效性和可用性(曾小团等,2010;田刚等,2021;朱智慧等,2016)。然而,交叉相关法和光流法等主要侧重于水平方向的外推,未能充分考虑垂直方向的变化,导致 1h 以上的雷达回波外推结果与实际情况之间存在较大偏差,进而影响了定量降水预报的准确性。

为了突破以上瓶颈,国内外学者开展了大量的探索研究,其中,深度学习等人工智能技术在降水预报中的应用逐渐获得关注并取得成果。庄潇然等(2023)基于深度学习的融合降水临近预报方法,成功实现了中国东部地区极端强降水的临近预报;陈锦鹏等(2024)采用 LightGBM 集成学习和动态融合算法预报短时强降水,并取得一定效果;袁凯等(2022)结合四种深度学习算法,开展了人工智能技术在武汉地区临近预报中的应用研究;尹麒名等(2021)提出了一种改进的循环神经网络雷达图像外推算法,使得雷达回波的分布更接近于真实雷达扫描图像;Qiu et al(2017)建立的多任务卷积神经网络模型在改善短时临近降水预报方面表现优异;Bromberg et al(2019)基于深度图像分割网络 U-Net 架构的预报效果超越了传统的光流法;胡家晖等(2022)通过对抗神经网络优化构建的 TAGAN 深度学习模型,显示出相较于传统光流法,尤其在长时间预报时的优势;Cao et al(2022)基于 U-Net 卷积神经网络模型的降水预测,表现出比光流法和 NOAA-HRRR 系统更高的准确性;郭瀚阳等(2019)通过改进的循环神经网络算法,构建了自编码模型,成功应用于强对流高分辨率临近预报;DeepMind 和英国气象局开发的深度生成模型 DGMR (Ravuri et al,2021)方法能够生成时空一致的预报,提前时间长达 90min,并有效捕捉混沌对流的细节,同时考虑集合预报的不确定性;曹伟华等(2022)基于深度学习网络模型 RainNet 建立的算法获得比传统外推预报法更高的准确率;王善昊等(2024)研究表明,结合物理量的卷积长短期记忆网络(ConvLSTM)外推模型能有效提升雷达回波外推的准确性;薛丰昌等(2024)提出基于自注意力机制和门控循环神经网络(GRU)的雷达回波外推算法,能够在一定程度上提高模型的外推性能;清华大学与中国气象局合作的 NowcastNet (Zhang et al,2023)模型,考虑了降水背后的物理规律,通过神经网络大模型训练未来不同时间的光流分量,提供了出色的技巧性预报;田付友等(2024)的研究认为物理理解与模糊逻辑人工智能相融合方法具有广泛

适用性的本质，可以表征产生特定强对流天气现象的环境配置的多样性和复杂性。这些研究表明，深度学习模型在短时临近降水预报方面展现出很大的潜力，能够提取复杂的非线性特征，是传统外推法和数值预报方法的重要补充。

广西区气象台在短时临近业务中开展了光流法外推等智能技术研发与应用，为 0~2h 降水预报提供了客观支撑。然而，现有预报结果仍面临一些问题，如大量级降水的漏报、小量级降水的空报率较高、弱回波降水的预报困难等，与实际业务需求存在一定差距。为进一步提高预报准确性，本文提出了一种基于对抗神经网络的短时临近外推预报模型 CastNet。该模型集成了光流引导神经网络模型学习大气物理规律，并利用循环神经网络（RNN）捕捉雷达回波数据的时空特征，同时运用对抗神经网络（GAN）来提升对于云团的生成和消散过程的模拟。该研究方案充分发挥了深度学习强大的拟合能力，不仅在外推过程中综合考虑了时间与空间信息，还能够揭示时空变化规律。CastNet 模型的设计有效地弥补了传统外推方法如 COTREC 和光流法存在的不足，尤其在面对雷达回波的生消、发展、移动和形变等复杂特性时，展现出了一定优势和潜力，能够取得更好的预报效果。

1 资料来源

本研究使用了特定时段的历史资料，涵盖 2018 年 1 月 1 日至 2023 年 12 月 31 日期间的逐 6min 雷达数据和逐 5min 地面观测站降水数据，以及中国气象局强对流天气短时临近预报系统 (SWAN) 在广西业务化运行的雷达拼图实况数据，其经纬度范围设定为：20.90° ~26.49° N、104.41° ~112.08° E。地面观测站降水数据来源于广西气象大数据云平台，涵盖了超过 4000 个地面观测站，经过全面的数据清理，对存疑、错误和缺失的数据进行剔除，最终保留了 3069 个地面观测站的降水数据。经进一步匹配与筛选流程，构建了约 36 万个历史样本数据集。

依据模型训练集与测试集隔离准则，本研究选定了 2018 年至 2022 年的数据作为模型训练集，样本量约为 30 万；以 2023 年的数据作为测试集，样本量约为 6 万。上述数据作为本研究的数据基础，确保了研究结果的准确性与可靠性，能够有效验证模型在不同时间段的数据上的表现。

2 深度学习神经网络的外推模型 CastNet

总体来说，CastNet 可以看作一个条件概率模型，基于已发生的雷达或降水格点实况数据 X ，预测未来雷达或降水格点预报数据 X' ，其算法如下：

$$P(X' | X) = \int P(X' | Z, X, \theta) P(Z | X) dZ \quad (1)$$


式中， θ 代表深度学习的可训练参数； Z 代表模型的输入隐变量，不同的 Z 值会导致不同的预测结果 (Ravuri et al, 2021)。可见，CastNet 模型不但可以用于生成确定性预测结果，也可以采用多成员的方式形成概率预测模型。

在应对复杂多变的气象环境时，深入探究局地降水过程的时空变化特性尤为关键。本研究在模型设计阶段融入如下理念以构建模型架构：

- (1) 借助短时记忆，锁定降水相关要素的空间特征，学习其形态变化规律；
- (2) 结合长时记忆功能，捕捉预报要素在时间进程中的一致性规律，以此为基础实现对降水过程在时间轴上的长期趋势预测与规律把握；
- (3) 引入对抗神经网络模块，辅助模型捕获气象因子的增强与减弱规律，以应对不断变化的气象条件，提升对气象动态变化的即时响应能力；
- (4) 采用时空特征反复叠加的方法，进一步扩展神经网络的深度，使其能够更加精细地拟合气象变化的动态特征，进而精准描绘气象变化的复杂细节与微妙差异；

(5) 凭借卷积神经网络的广阔视野，充分引入周边范围内微观气象因素的影响，进一步提升模型对气象现象的全面理解与预测能力，为精准气象预报提供更丰富、全面的信息支持。

本文提出的 CastNet 模型分为两个部分：RNN 网络和 GAN 判别网络。其中 RNN 网络的设计延续了 ConvLSTM (Shi et al, 2017) 的思路，采用了卷积神经网络 (CNN) 的长短时记忆模型，神经网络架构如图 1 所示。其中 H 表示隐藏层，C 表示记忆单元，t 表示时间序列。X_{t-1}, X_t 等代表 t 时刻雷达数据输入，Y_{t+1}, Y_{t+2} 等代表输出，Z_{t+1}, Z_{t+2} 等代表模型的输入隐变量，本文在模型实现时，采用随机采样的微扰变量作为输入，形成概率预报模型；或采用确定的光流约束因子作为输入，形成确定性预报模型。蓝色模块代表卷积神经网络编解码单元，紫色虚线代表卷积视野，R 代表残差连接路径。



注：紫色虚线：卷积视野；H：隐藏层，C：记忆单元，R：残差连接路径，t：时间序列；X_t, Z_{t+1}, Y_{t+1} 等分别表示 t 或 t+1 时刻雷达数据输入、隐变量输入、模型输出。

图 1 CastNet 架构示意图：RNN 网络部分

Fig.1 Schematic of the CastNet architecture: RNN Network

借鉴 He et al (2016) ResNet 方法中的残差思想，将部分层级的训练目标从未来具体回波（或降水）数据值转化为偏差预测。这种通过学习相对偏差而非具体网格值的转变，有助于神经网络更好地提取特征，同时能够极大地减少梯度消失或梯度爆炸的潜在影响。参考 Wang et al (2017; 2023) PredRNN 方法，采用残差方式将上一时次输出与下一时次输入模块连接起来，建立梯度捷径。这一策略增强了神经网络的训练能力，提升了预测的准确性。上述思路的引入旨在优化神经网络结构，以期更有效地处理预测任务，提高模型的预测精度。

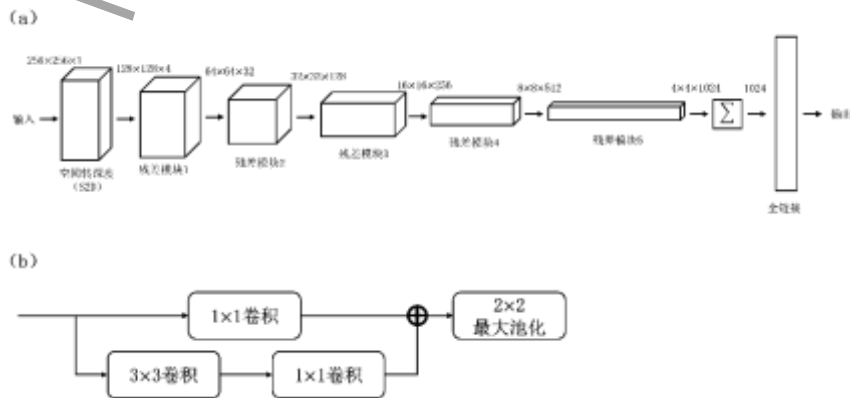


图 2 CastNet 架构示意图：GAN 判别网络部分

(a) 判别网络, (b) 残差模块

Fig.2 Schematic of the CastNet architecture: GAN Discriminator Network

(a) Discriminator Network, (b) Residual Block

参考 Ravuri et al (2021) DGMR 方法时空一致性思想, 在训练过程中利用 GAN 强迫模型参数回归到更为合理的状态。独立的 RNN 模型在时空预测中常常出现预测结果模糊以及大雨强度预测削弱的现象。为了解决这一问题, 本文将 RNN 作为 GAN 的生成网络, 通过增加对抗判别网络, 从而获得与真实雷达回波或降水时空特征更为一致的预报结果。

首先, 各通道借助空间转深度 (S2D) 算法 (Li et al, 2023) 将输入数据的高度与宽度缩减至原来的 1/2, 降低网络计算资源的消耗; 接着, 利用 5 层卷积与池化层的组合操作, 进一步将输入数据的高度和宽度压缩为原始数据的 1/64; 完成上述操作后, 对数据进行求和, 并运用全连接网络计算各通道的得分, 最终将所有通道的得分汇总为累计得分 (如图 2)。在训练过程中, 输入的隐变量 Z 可以从高斯空间随机采样而来, 有助于提升模型的多成员概率预报能力。

损失函数 (Loss) 由 RNN 生成网络 G_θ 和 GAN 判别网络的两部分损失组成。生成网络采用的损失函数 L_G 被进一步细分为两个部分: 预测样本判别器 (D) 和 RNN 损失函数 (L_R) 的输出结果。具体公式见式 (2) 和式 (3)。其中, X 为输入样本, X' 为与预报时刻一致的实况样本, Z 为输入隐变量, θ 为 RNN 模型参数, ω 动态样本平衡因子权重系数, y 为回波 dBZ 强度, γ 为平衡权重, E_X 是基于输入样本 X 的数学期望, E_Z 是基于输入隐变量 Z 的数学期望。

$$L_G(\theta) = E_Z \left[E_X \left[\log D(G_\theta(Z; X)) - \gamma L_R(\theta) \right] \right] \quad \#(2)$$

$$L_R(\theta) = E_X \left[(E_Z[G_\theta(Z; X)] - X') \odot \omega(X') \right] \quad \#(3)$$

$$\omega = \begin{cases} (y - 20)^{0.8}, & y \geq 20 \\ 1, & y < 20 \end{cases} \quad \#(4)$$

尽管在样本预处理中采用了样本增强技术, 但大雨样本的数量仍远少于小雨样本。这种样本不平衡的问题可能导致模型对大雨区域, 尤其是大雨强度和落区上的预测偏差。然而, 在短时临近降水预报中, 大量级降水的预测尤为重要。因此, 为了解决训练过程中小雨样本与大雨样本不平衡的问题, 本文使用的 RNN 损失函数 (L_R) 设计借鉴了 Focal Loss (Lin et al, 2017) 的思想, 以 L1 Loss 为基础, 并引入一个动态样本平衡因子权重系数 ω , 详见式 (4)。这一设计旨在应对不平衡样本带来的挑战, 从而提高模型对大雨区域预测的关注度和准确性。生成对抗网络 (GAN) 判别网络的 Loss 包括实况样本判别 Loss 和预测样本 Loss。两部分 Loss 通过 ReLU 函数进行计算后相加, 增加模型的鲁棒性。计算过程如式 (5) 所示。在进行概率预报模型的训练或推理时, 本文采用基于高斯分布的蒙特卡洛方法, 隐变量 Z 采用随机采样生成微扰变量作为输入。通过这种方式, 模型能够生成多个预报成员, 构成概率预报结果的基础。

$$L_D(\varphi) = E_X \left[E_Z \left[\text{ReLU} \left(1 - D_\varphi(X') \right) + \text{ReLU} \left(1 + D_\varphi(G(Z; X)) \right) \right] \right] \quad \#(5)$$

式中: X 为输入样本, X' 为与预报时刻一致的实况样本, φ 为 GAN 判别模型参数。

本文设计的短时临近预报模型 CastNet 将光流矢量场数据引入到神经网络中, 将输入隐变量数据 Z 从随机采样生成的微扰变量替换为光流场, 通过光流约束神经网络外推, 有效替代了传统模式中直接使用雷达回波数据进行光流外推的方式 (图 1)。具体流程如下: 采用变分光流法 (Laroche and Zawadzki, 1995) 结合半拉格朗日外推, 将光流外推结果与上一时段神经网络输出结果 Y 进行叠加, 作为下一时段神经网络的输入。例如, 光流法输出的

t+2时次结果中的 Z_{t+2} 将与神经网络输出的t+1时次结果 Y_{t+1} 进行叠加(本文采用 concatenate 方式), 共同作为 t+2 时次的输入。这一创新方法通过交叉融合光流因子和回波数据, 能够有效利用光流因子运动矢量场的特性引导神经网络模型的训练。该方法不仅能加速神经网络的学习过程, 还能提高神经网络外推结果的准确性, 在降水量级和落区的预测上具有较好的检验结果。通过引入不同类型数据的训练方式, 雷达回波数据与光流数据形成了共生机制。这种端到端的神经网络训练与预测模型有效地弥补了传统外推方法(如 COTREC 和光流法)的不足, 提升了预报的准确率。该创新策略为短临预报领域带来了新的可能性, 能够有效改进复杂气象条件下的预报表现, 具有广泛的应用潜力。

3 二源融合估测降水格点实况方法

为了获得更准确的降水格点实况, 本文提出了一种雷达估测降水与地面观测站降水实况融合的方法, 其主要技术方案如下: ①基于雷达回波与定量降水(Z-R)的关系, 通过滑动窗口动态回归方法计算 a、b 系数, 结合实时雷达资料进行定量降水估测; ②利用地面观测站的降水实况, 对雷达定量估测降水进行修正和校准。本方案中采用的实时雷达资料来自广西及周边地区组网雷达, 这些雷达资料经过吴涛等(2013)提出的质量控制算法, 去除孤立噪声和地物回波, 并利用模糊逻辑对雷达回波特征量进行建模, 得到超折射回波识别指数, 去除超折射回波。

3.1 基于滑窗回归转换的雷达定量降水估测

雷达定量降水估测一般采用 Z-R 幂指数关系将雷达回波强度转换为地面降水值, 其公式为式(6):

$$Z = aR^b \quad (6)$$

其中 Z 是回波强度, R 是降水量, a, b 为转化模型参数。实际应用时, 采用分贝反射率因子 dBZ, 以上公式变形式为(7):

$$dBZ = 10(\lg a + b \lg R) \quad (7)$$

基于雷达回波反射率因子的特性, 参数 a 和 b 的具体取值受到多种因素的影响, 存在时空差异, 具有鲜明的地域和季节特征。例如, 江淮、广东、广西等沿海地区夏季降水雨滴谱特征接近海洋性降水, 而华北地区降水雨滴谱则更倾向于大陆性降水, 两者的云物理过程存在差异。因此, 参数 a 和 b 的选取应随着不同时间、不同区域而调整, 甚至在同一地区(如广西)内, 这些参数也会随着不同月份、甚至不同日期的变化而有所不同。时间一致性方面, 对于站点降水强度较大(超过 $3 \text{ mm} \cdot \text{min}^{-1}$)的样本, 若前后相邻时间均无观测数据, 则该分钟数据可疑, 予以排除。空间一致性方面, 统计 5km 范围内的站点观测数据样本, 若存在差异较大的离群样本, 予以排除。考虑到风场对降水的影响, 数据样本可能存在落区误差, 站点观测值也存在精度误差, 因此需要对数据再次进行清洗操作, 本文采用固定 b 值估算 a 值的方法, 排除 a 值不在区间范围(30~1000)内的样本。

在进行数据融合时, 为保持站点观测数据和雷达组合反射率的时间尺度一致, 需要考虑雷达完成一轮体扫所需的时间, 且回波反演的降水为空中雨量, 降落到地面也需要一段时间。因此, 在对站点观测进行统计时, 本文选择以雷达扫描开始时间后的 10min 作为时间窗口, 计算该时间段内的累计观测降水量。由于 Z-R 关系转换结果为降水强度(单位 $\text{mm} \cdot \text{h}^{-1}$), 因此, 需再将累计降水量换算为降水强度。

在参数拟合时, 降水值取对数, 采用公式(7)将原来的指数方程转化为线性方程, 提高拟合效率并减少拟合误差。根据实际样本统计发现, 分段拟合可提升模型适应性, 因此可将样本按照 dBZ 大小分为三组, 分别对应小雨、中雨、大雨的样本, 最终拟合得到对应三组 a、b 参数(图 3)。采用滑动窗口方式收集并整理数据, 拟合程序每天定时运行一次, 采用滑动步长为 1 天, 即用最近 1 天的新样本替换离当前时间最远的历史样本, 重新进行拟合,

并应用于雷达组合反射率与定量降水估测的转换关系。

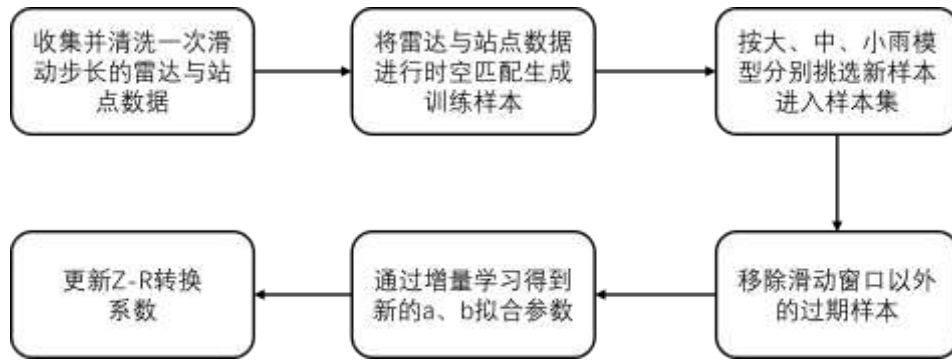


图3 滑动窗口 Z-R 参数动态更新流程图

Fig.3 Sliding Window Z-R Parameter Dynamic Update Process Diagram

3.2 实时偏差订正

为进一步提高定量降水估测的准确性,本文参考 NOAA 关于美国/加拿大气象雷达与地面站点二源融合产品 (MRMS) 的订正思路 (Zhang et al, 2016; Smith et al, 2016), 利用能够实时收集到的分钟级站点降水数据 (离散数据) 对基于动态 Z-R 公式转换生成的雷达定量降水估测数据 (格点数据) 进行区域偏差校正, 通过雷达定量降水估测与站点降水的融合, 最终获得二源融合估测格点降水实况。具体方法参考 Ware (2005) 方案, 步骤如下:

- (1) 计算站点数据与对应位置格点数据的偏差;
- (2) 通过反距离加权平均方案将偏差插值到所有格点位置;
- (3) 使用雷达定量降水 (QPE) 场减去插值差异场。

方案中, 采用反比距离权重插值方法 (Lu and Wong, 2008), 其权重 W 定义为 $W=1/r^k$, 其中 r 是规范与 MRMS 网格点之间的距离, 指数 k 从 0.5 到 3 不等, 由交叉验证确定。通过验证可以最小化每小时特定区域内雷达规范差异的插值误差, 简化公式描述如下:

$$X^a = X^b + W(X^{obs} - X^b) \quad \#(8)$$

$$W_n = D_{i,j,n} / \sum_{n=0}^N D_{i,j,n} \quad \#(9)$$

式中: X^a 为订正后格点的雨量, X^b 为背景场雨量, X^{obs} 为雨量计雨量, W_n 为雨量站和雷达估测降水格点 (i, j) 的距离权重, $D_{i,j,n}$ 为第 n 个雨量站距离格点 (i, j) 的距离。

4 0~2h 定量降水预报方案

利用广西多普勒雷达回波拼图和地面观测站降水资料, 采用光流法与深度神经网络相结合的方法实现每 6min 滚动更新未来 0~1h、1km 分辨率、逐 6min 涵盖广西区域的定量降水预报, 具体步骤为: (1) 基于滑动窗口动态回归雷达回波与定量降水 Z-R 关系的 a 、 b 系数来估测实时雷达定量降水 (QPE); (2) 采用 Ware (2005) 方法来订正实时雷达定量降水估测, 得到更为准确的二源融合估测降水 (融合 QPE); (3) 根据雷达回波与定量降水 Z-R 关系将实时的二源融合估测降水反演为雷达回波; (4) 将二源融合估测降水反演的雷达回波作为输入数据, 基于 CastNet 深度神经网络模型外推未来 0~2h 逐 6min 雷达回波; (5) 基于前述由历史资料回归得到的 Z-R 关系 a 、 b 系数, 使用未来 0~2h 雷达回波预报来反演雷达定量降水 (QPF), 流程见图 4。

雷达回波由于受地物遮挡、杂波干扰等因素的影响, 常出现部分回波缺失或回波强度无法准确反映实际情况的现象。为解决这一问题, 本研究采用了二源融合的方法, 将降水数据

与雷达回波信息进行融合，并利用融合后的降水数据反演雷达回波，进行外推预报。与传统的基于原始雷达回波的外推方法相比，该方法利用实时站点降水数据对雷达回波进行修正，可弥补回波本身存在的缺陷。

由于 Z-R 转换公式具有可逆性质，即从反射率因子到降水量的转换以及从降水量到反射率因子的转换均具有唯一结果，因此在本文的实际操作中，在同一次预报中采用了相同的 Z-R 关系参数 (a、b 系数) 进行回波和降水量之间的转换。这样的操作避免了由于不同参数带来的计算误差，确保了预报过程的准确性。

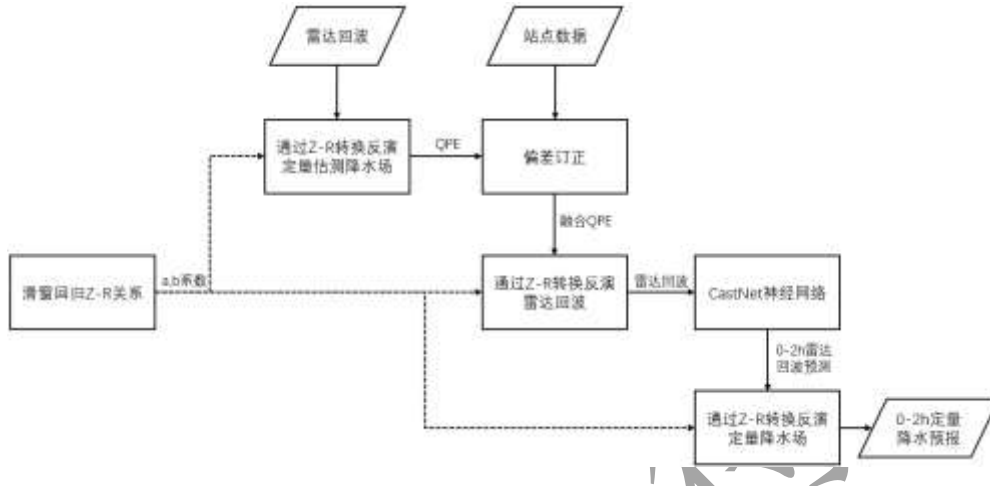


图 4 定量降水外推预报流程图

Fig.4 Quantitative Precipitation Extrapolation Forecast Process Diagram

5 模型检验

本文从空间与时间两个维度对预报与实况数据进行采样，构建测试集。空间维度上，选取了涵盖国家级观测站以及区域自动站在内的 3069 个站点 (20.90° ~ 26.49° N、104.41° ~ 112.08° E)，通过就近插值方法将格点预报数据映射到所选站点，作为待检验的预报数据样本，同时提取对应站点的分钟观测降水数据作为实况数据样本。时间维度上，挑选出 2023 年 5 月至 10 月广西地区的主要降水过程 (以下简称主要降水过程) 共 9 次 (表 1)，以每 30min 为间隔进行抽样，将其设定为起报时间，进而选取起报时间之后 30、60、90、120min 的预报数据作为待检验的预报数据样本，同时把各预报时刻前 6min 的累计观测降水量换算为 1h 降水量，以此作为该预报时刻对应的实况数据样本。最终，计算所有检验样本的临界成功指数评分 (TS)，实现对整体数据的综合评价。

表 1 2023 年 5—10 月主要降水过程

Table 1 Major Precipitation Events from May to October 2023

主要降水过程	影响系统
5 月 10 日—13 日桂北桂东强对流天气过程	切变线、冷空气
6 月 7 日—9 日暴雨过程	热带扰动影响
6 月 13 日—14 日暴雨过程	低涡切变、地面冷空气
6 月 19 日—25 日暴雨过程	高空槽、低涡切变
7 月 17 日—20 日台风泰利过程	泰利台风
8 月 4 日—8 日强降雨过程	北部湾季风低压
9 月 2 日—5 日台风过程	台风苏拉
9 月 10 日—14 日台风残涡过程	台风海葵残留组织
10 月 19 日—22 日台风过程	台风三巴

5.1 检验结果

图 5 展示了 2023 年 9 月 14 日台风海葵残涡影响下的降水过程分析,选取当日 10:00(北京时间,下同)起报的 CastNet 模型预报结果与 SWAN 3.0 和 SWAN 2.0 系统中 0~2h 降水临近预报产品进行对比。图中给出了三种模型的预报结果,并给出了相应的站点实况(图 5a~图 5d)。为评估模型在不同雨量等级上的预报效果,检验时采用了 6 个降水强度(≥ 0.1 、 ≥ 2 、 ≥ 7 、 ≥ 15 、 ≥ 25 、 ≥ 40 $\text{mm}\cdot\text{h}^{-1}$)的 TS 评分。

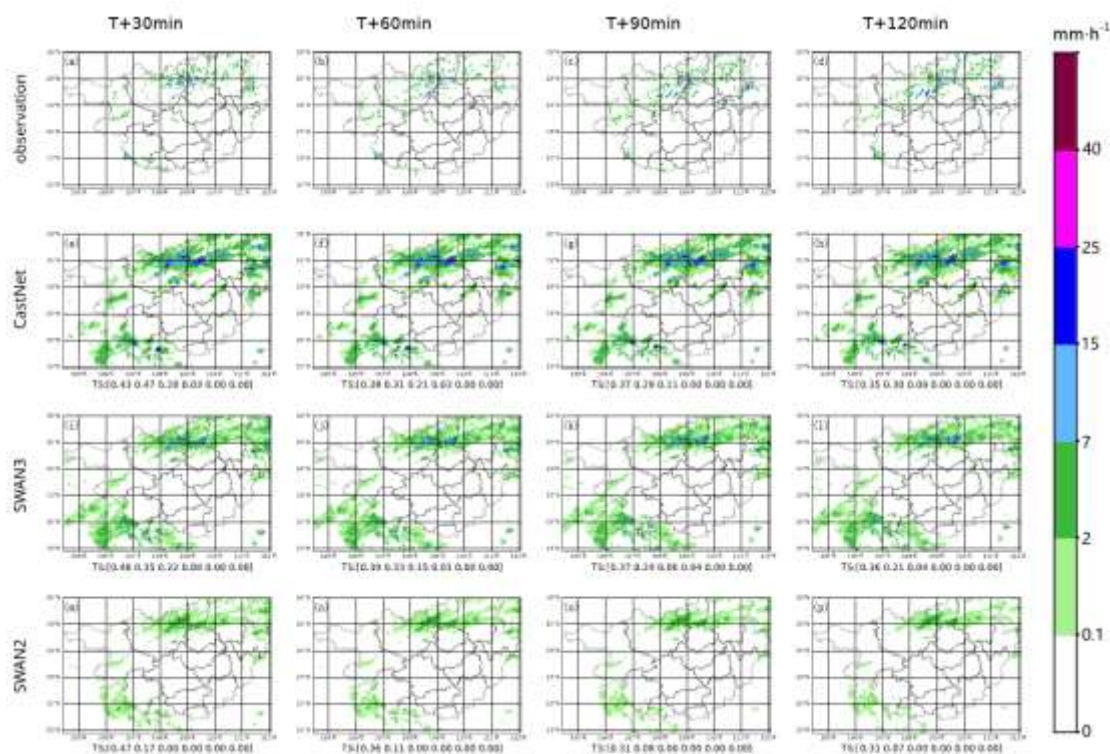


图 5 CastNet、SWAN 3.0、SWAN 2.0 的不同预报时效预报结果与降水实况: 2023 年 9 月 14 日台风残涡影响下的降水过程

Fig.5 The forecast results of CastNet, SWAN 3.0, and SWAN 2.0 with different lead times and the actual precipitation: The precipitation process affected by the typhoon residual vortex on September 14, 2023

实况数据显示在 (22° N、 107° E) 附近的崇左西南地区存在较强的降水,从预报结果来看, CastNet 和 SWAN 3.0 的预报明显优于 SWAN 2.0。在 30min 以上的预报时效,相较于 SWAN 3.0, CastNet 预报的中到大雨区域位置和范围与实况数据更为接近;随着预报时效的增加, CastNet 和 SWAN 3.0 的预报在落区上均存在一定偏差,且偏差幅度相似。从降水强度上看, CastNet 的预报与实况更加一致,优于 SWAN 3.0。在贺州北部地区 (25° N、 111.5° E) 附近,实况数据显示存在 ≥ 7 $\text{mm}\cdot\text{h}^{-1}$ 以上的降水。CastNet 成功准确预报了该地区的强降水,而 SWAN 3.0 和 SWAN 2.0 在降水落区和强度上均存在偏差,未能有效捕捉到该降水区域。另外, CastNet、SWAN3.0、SWAN2.0 均成功捕捉到柳州中部地区 (25° N、 109.5° E) 的强降水天气,其中 CastNet 的强度和落区预报最优。从 ≥ 7 $\text{mm}\cdot\text{h}^{-1}$ 以上量级的 TS 评分结果分析,不同预报时效的 CastNet 预报评分结果多数高于 SWAN 3.0 和 SWAN 2.0。

图 6 展示了 2023 年 7 月 18 日台风泰利过境引发强降水过程的分析结果。选取当日 08:30 起报的数据,检验方法同图 5。结果显示,与 SWAN 2.0 相比, CastNet 和 SWAN 3.0 在预报能力上具有较为明显的优势。

在 (108.5° E、22° N) 附近的崇左、南宁、钦州和防城港交界地区, 30min 及以上的预报时效的结果表明, CastNet 对 $\geq 7 \text{ mm}\cdot\text{h}^{-1}$ 及以上降水强度的落区位置、范围和强度的预报较 SWAN 3.0 更接近实况数据。随着预报时效的增加, 台风风眼向西略微偏移, CastNet 能够较好地捕捉了这一趋势, 风眼位置变化较小, 预报结果更接近实况。相比之下, SWAN 3.0 的预报表现出明显偏移, 风眼位置向西南方向移动; SWAN 2.0 未能有效反映台风风眼的实际变化趋势, 对该地区的降水强度和落区预报存在较大误差。从 $\geq 15 \text{ mm}\cdot\text{h}^{-1}$ 以上量级的 TS 评分结果分析, 60、90、120min 的 CastNet 预报评分结果均高于 SWAN 3.0 和 SWAN 2.0。

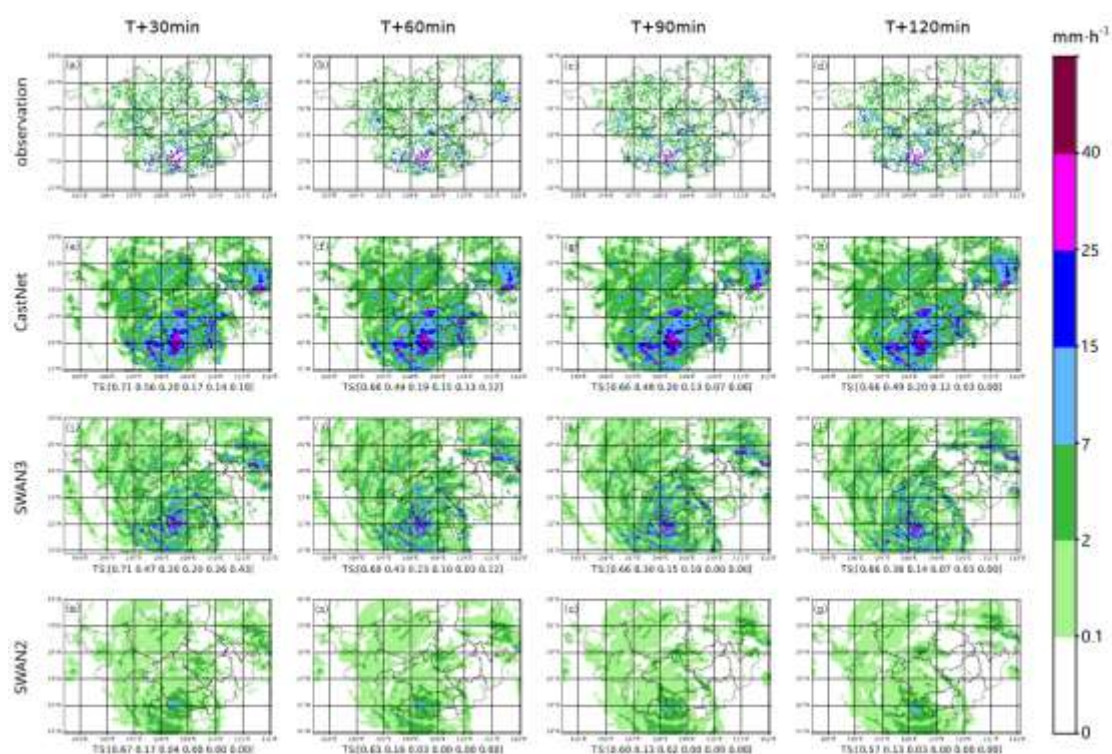


图 6 CastNet、SWAN 3.0、SWAN 2.0 的不同预报时效预报结果与降水实况: 2023 年 7 月 18 日泰利台风过境时的强降水过程

Fig.6 The forecast results of CastNet, SWAN 3.0, and SWAN 2.0 with different lead times and the actual precipitation: The heavy precipitation process during the passage of Typhoon Talim on July 18, 2023

本文通过分析主要降水过程, 对模型的综合应用效果进行了全面检验, 从降水起止时间、量级预报精准度及模型适应性等方面进行深入剖析。同时, 借用现有模型进行横向对比, 从准确率、运行效率以及强降水处理能力等多个维度总结优劣势, 为模型优化和预报能力提升提供参考依据。图 7 和图 8 展示了不同降水强度等级下的 TS 评分结果。




图7 CastNet、SWAN 3.0、SWAN 2.0对2023年5—10月主要降水过程的不同降水强度预报 TS 评分
Fig.7 TS scores of precipitation forecasts with different intensities by CastNet, SWAN 3.0, and SWAN 2.0 for major precipitation processes from May to October 2023

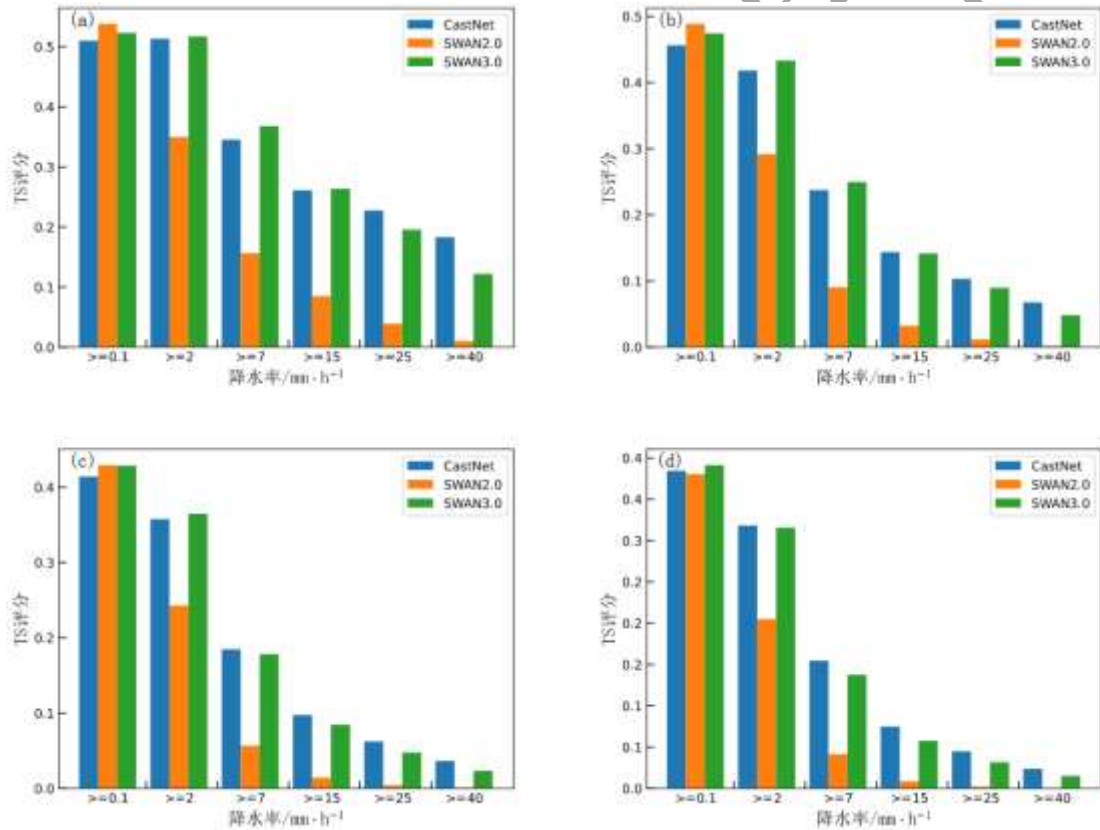


图8 CastNet、SWAN 3.0、SWAN 2.0对2023年5—10月主要降水过程在不同预报时效下的不同降水强度预报 TS 评分

(a) 0~30min, (b) 30~60min, (c) 60~90min, (d) 90~120min

Fig.8 TS scores of precipitation forecasts for different magnitudes at various lead times during major precipitation events from May to October 2023 by CastNet, SWAN 3.0, and SWAN 2.0: (a) average TS score for 0~30 min, (b) average TS score for 30~60 min, (c) average TS score for 60~90 min, and (d) average TS score for 90~120 min.

图 7 是 2023 年 5—10 月主要降水过程总体 TS 评分结果。依据不同降水等级展开分别统计,并对所有预报时效进行了平均计算。SWAN 2.0 的平均 TS 评分分别为 0.458、0.27、0.085、0.034、0.014 和 0.003; SWAN 3.0 分别为 0.452、0.402、0.225、0.129、0.085 和 0.048; CastNet 模型则为 0.439、0.397、0.225、0.139、0.104 和 0.073。总体来说,SWAN 2.0 降水量预报偏低。在 $\geq 0.1 \text{ mm}\cdot\text{h}^{-1}$ 量级的降水预报中,SWAN 2.0 和 SWAN 3.0 预报表现均优于 CastNet; 随着降水量级升至 $\geq 2 \text{ mm}\cdot\text{h}^{-1}$ 及以上,SWAN 2.0 的评分大幅下降, CastNet 模型的 TS 评分则逐步上升进而超越 SWAN 2.0,并在 $\geq 15 \text{ mm}\cdot\text{h}^{-1}$ TS 评分中追上 SWAN 3.0;在 $\geq 15 \text{ mm}\cdot\text{h}^{-1}$ 及以上量级的降水预报中, CastNet 表现尤为出色,这一趋势与前述案例分析的结果一致。

图 8 进一步将预报时效分别统计。结果显示,在 0~30min 的 TS 评分结果中, CastNet 在降水强度为 $\geq 25 \text{ mm}\cdot\text{h}^{-1}$ 和 $\geq 40 \text{ mm}\cdot\text{h}^{-1}$ 时优于 SWAN 3.0;在 60~90min 的 TS 评分结果中, CastNet 在 $\geq 7 \text{ mm}\cdot\text{h}^{-1}$ 以上的所有量级均优于 SWAN 3.0。可见随着预报时效的增加, CastNet 的优势愈发明显。

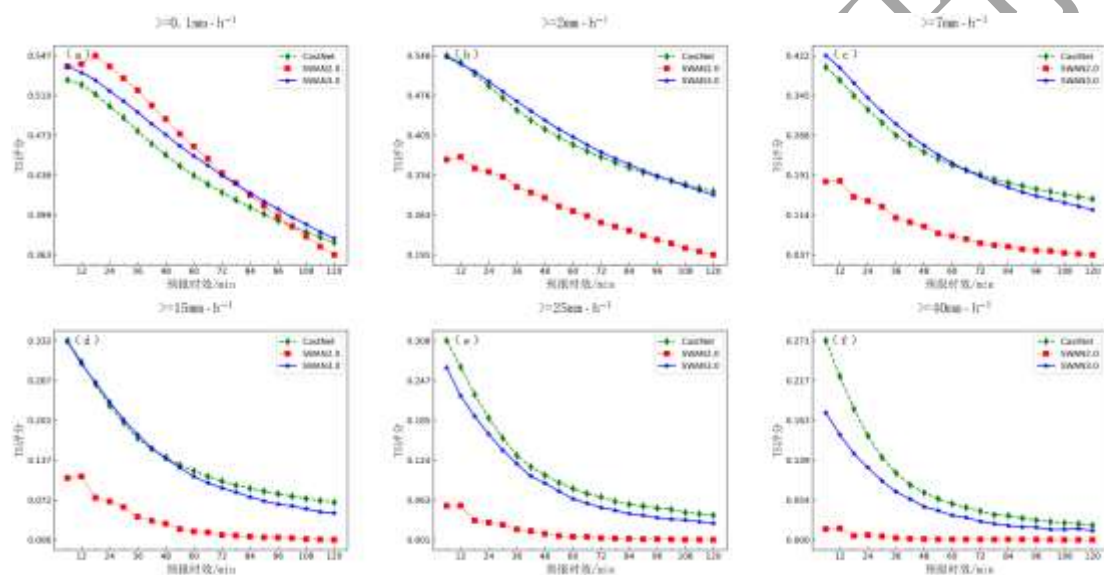


图 9 CastNet、SWAN 3.0、SWAN 2.0 对 2023 年 5—10 月主要降水过程的不同预报时效 TS 评分
Fig.9 The TS scores of CastNet, SWAN 3.0, and SWAN 2.0 for major precipitation processes from May to October 2023 under different forecast time horizons

图 9 展示了主要降水过程在不同量级下平均 TS 评分随预报时效推移的变化趋势(横轴为预报时效,纵轴为平均 TS 评分)。对于 $\geq 0.1 \text{ mm}\cdot\text{h}^{-1}$ 量级的降水(图 a),SWAN 2.0 的表现最佳,SWAN 3.0 次之, CastNet 稍显不足。对于 $\geq 2 \text{ mm}\cdot\text{h}^{-1}$ 和 $\geq 7 \text{ mm}\cdot\text{h}^{-1}$ 量级的降水(图 b/c),SWAN 2.0 的评分迅速下降,而 SWAN 3.0 和 CastNet 的表现则各有优势。在短时预报中 SWAN 3.0 相对较好,而在长时预报中 CastNet 逐渐占优。在 $\geq 15 \text{ mm}\cdot\text{h}^{-1}$ 量级中(图 d),初期 CastNet 与 SWAN 3.0 的 TS 评分较为接近,从左起第 8 个预报时效点(即 48min)开始, CastNet 的 TS 评分超越了 SWAN 3.0 并保持领先。对于 $\geq 25 \text{ mm}\cdot\text{h}^{-1}$ 和 $\geq 40 \text{ mm}\cdot\text{h}^{-1}$ 降水量级, CastNet 的 TS 评分在所有时效预报中均优于 SWAN 3.0 和 SWAN 2.0。这表明 CastNet 不但在强降水预报中表现出一定的优势,并且在较长时效预报具有稳定的表现。

SWAN 2.0(韩丰和沃伟峰,2018)以交叉相关法计算回波运动矢量进行外推,并结合分雨团技术优化雷达降水估测算法的适用性。SWAN 3.0(韩丰等,2023)则使用 DIS 光流法计算回波运动场,通过最优插值融合站点雨量数据,同时优化了分雨团、时间拆分和动态 Z-R

系数等方法，提升了预报精度。相比之下，CastNet 在某些场景中表现更优的原因可能与其精细化的神经网络架构设计密切相关。CastNet 基于卷积神经网络提取空间特征，能够广泛捕捉空间中微观气象因素的影响，同时，循环神经网络的时序建模方法增强了模型对时间维度上气象现象变化规律的捕捉能力，使其在时空动态特征的解析上更加全面。此外，通过堆叠不同空间尺度下的 RNN 结构，CastNet 扩展了神经网络深度，进一步提高了对复杂气象变化的表征能力。模型还融合了光流因子，引导神经网络学习大气物理规律，强化了物理一致性。更进一步地，CastNet 引入对抗神经网络，模拟云团的生成和消散过程，从而提高了短时强降水事件的预报准确度。为了更好地适应短时强降水过程的预报需求，CastNet 在损失函数的设计上进行了优化，特别针对中到大雨量级的降水过程进行了调优。这一策略使得模型在训练过程中更加倾向于“关注”中到大雨落区的位置与强度特征，从而在短时强降水事件的预报中展现出更为出色的表现。

5.2 二源融合消融试验

图 10 以 2023 年 6 月 24 日 09:30 广西区域的降水为例，对比分析三种方法：固定 Z-R 关系 ($a=300$, $b=1.4$) (图 10b)、滑窗回归 Z-R 关系 (图 10c)，以及滑窗回归 Z-R 关系融合站点观测值 (图 10d) 计算的定量降水估测场与实况 (图 10a) 的差异。结果显示，滑窗回归 Z-R 关系在中到大雨的降水落区和强度相比固定 Z-R 关系表现更优，也即滑窗回归法得到的 Z-R 关系能够更准确地反映当前区域和时段内雷达回波与降水量之间的定量转换关系。另一方面，站点数据的融合提高了所有雨量等级的评分，说明通过地面降水观测对降水场进行偏差订正，可以有效减少雷达回波转换过程的模型误差和观测误差。

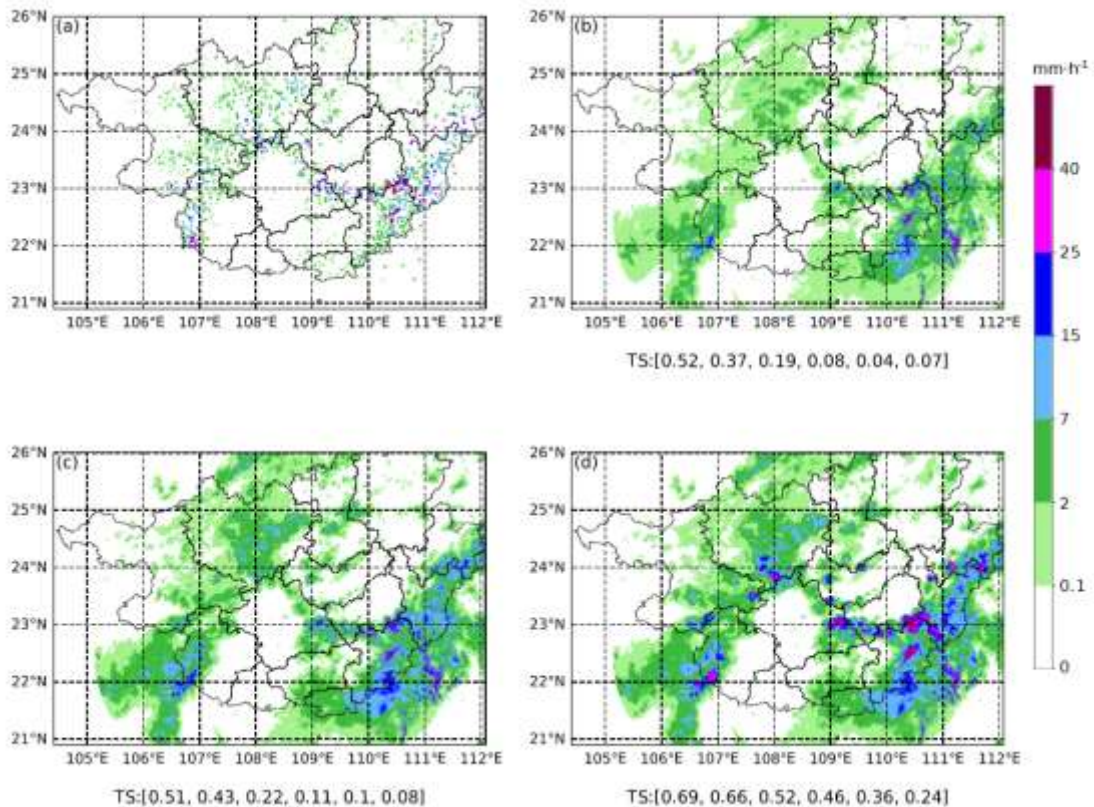


图 10 2023 年 6 月 24 日 09:30 (b~d) 定量降水估测场与 (a) 实况对比

(b) 固定 Z-R 关系, (c) 滑窗回归 Z-R 关系, (d) 滑窗回归 Z-R 关系融合站点观测值

Fig. 10 Comparison of quantitative precipitation estimation fields (b~d) with observations (a) at 09:30 AM on June 24, 2023: (b) Fixed Z-R relationship, (c) Sliding-window regression Z-R relationship, (d) Sliding-window regression

5.3 生成对抗模块消融试验

本节通过对比仅使用循环神经网络（RNN）的 CastNet 模型与结合生成对抗模块（GAN）的 CastNet 模型的预测结果，分析 GAN 模块在提升时空一致性方面的作用。图 11 展示了 2023 年 5 月 24 日 08:00 雷达回波组合反射率 0~2h 预测结果，包括采用 RNN 与 GAN 相结合的标准 CastNet 模型的预测（图 11e~图 11h）、从标准 CastNet 模型中移除 GAN 模块后的预测（图 11i~图 11l）、以及雷达回波实况（图 11a~图 11d）。为评估不同回波强度等级的预测效果，分别计算了 15、25、30 dBZ 的临界成功指数（CSI）。

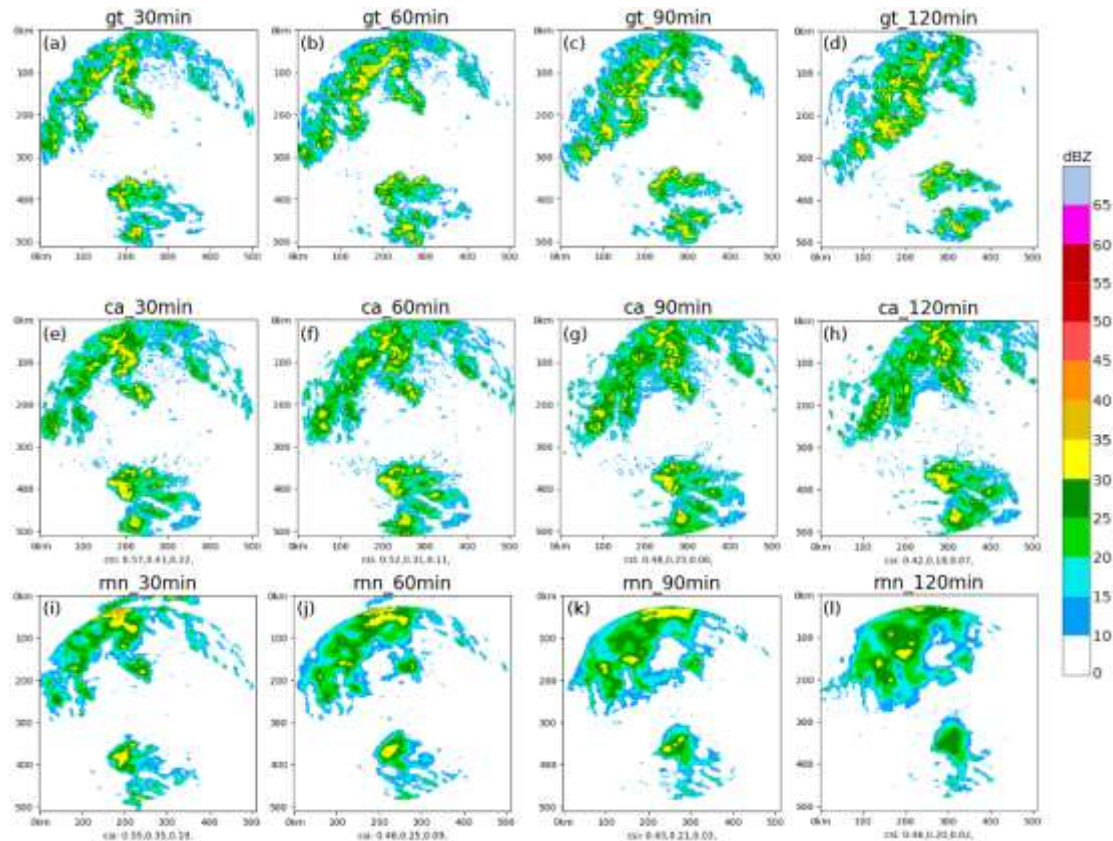


图 11 CastNet、RNN 模型在 2023 年 5 月 24 日 08:00 起报的不同时效预报结果与实况对比
Fig.11 Comparison between the forecast results at different lead times starting from 08:00 on May 24, 2023 by the CastNet and the RNN model, and the actual situation

结果表明，仅使用循环神经网络（RNN）的 CastNet 模型能够有效捕捉雷达回波云团的运动规律，其预测的移动方向和速度与实际观测结果较为一致。然而，与 ConvLSTM、TrajGRU 和 PredRNN 等循环神经网络模型类似，随着预测时间的延长，RNN 预测模型的输出结果逐渐模糊。这一现象源于神经网络本质上的概率性：随着预测时间的增长，模型的不确定性逐渐降低，多个可能性的叠加最终导致预测结果出现模糊效应。而引入生成对抗网络（GAN）模块后，模型的训练过程得到有效约束，消除了预测结果的模糊效应，增强了时空一致性。具体表现为，经过 GAN 模块整合后的 CastNet 模型，其在时间序列和地理空间上的变化更加协调、连贯。如图 11 所示，结合 GAN 模块的 CastNet 模型在整体云团移动情况上与仅使用 RNN 的模型相似，但预测结果的模糊程度明显降低，边缘轮廓更清晰，与实际回波观测一致。此外，预测结果还呈现出微妙的形态变化以及回波增强或减弱的特征。

进一步分析大量样本发现，加入生成对抗模块 GAN 后，CastNet 模型的输出普遍表现出了这样的特征。这一转变可以解释为：GAN 模块的整合使模型从单纯的预测模型转变为生成模型，通过输入特定的微扰采样，生成针对未来多种可能性的具体预测。

5.4 神经网络模型与传统光流模型对比讨论

传统的短时临近预报外推模型经历了从 COTREC 方法到光流法和半拉格朗日外推方法的演变。这些模型凭借其稳定的预报性能，已成为相关领域的主流方法。在此基础上，人工智能方法的兴起得益于神经网络通过对大量样本的训练，捕捉复杂气象条件下的时空变化特征，从而提升预报精度。

为了定量评估神经网络模型与传统光流模型的预报性能，本节选用三项检验指标：MAE（平均绝对误差）、SSIM（结构化相似度指数）和 PSNR（峰值信噪比）对 2023 年 9 月 22 日 17:30 起报（逐 6min 预报）的 30、60、90、120min 时效的预报结果进行对比（图 12）。这三项指标均基于雷达回波实况与预报数据进行计算，以全面衡量模型在不同时间尺度上的预报效果。

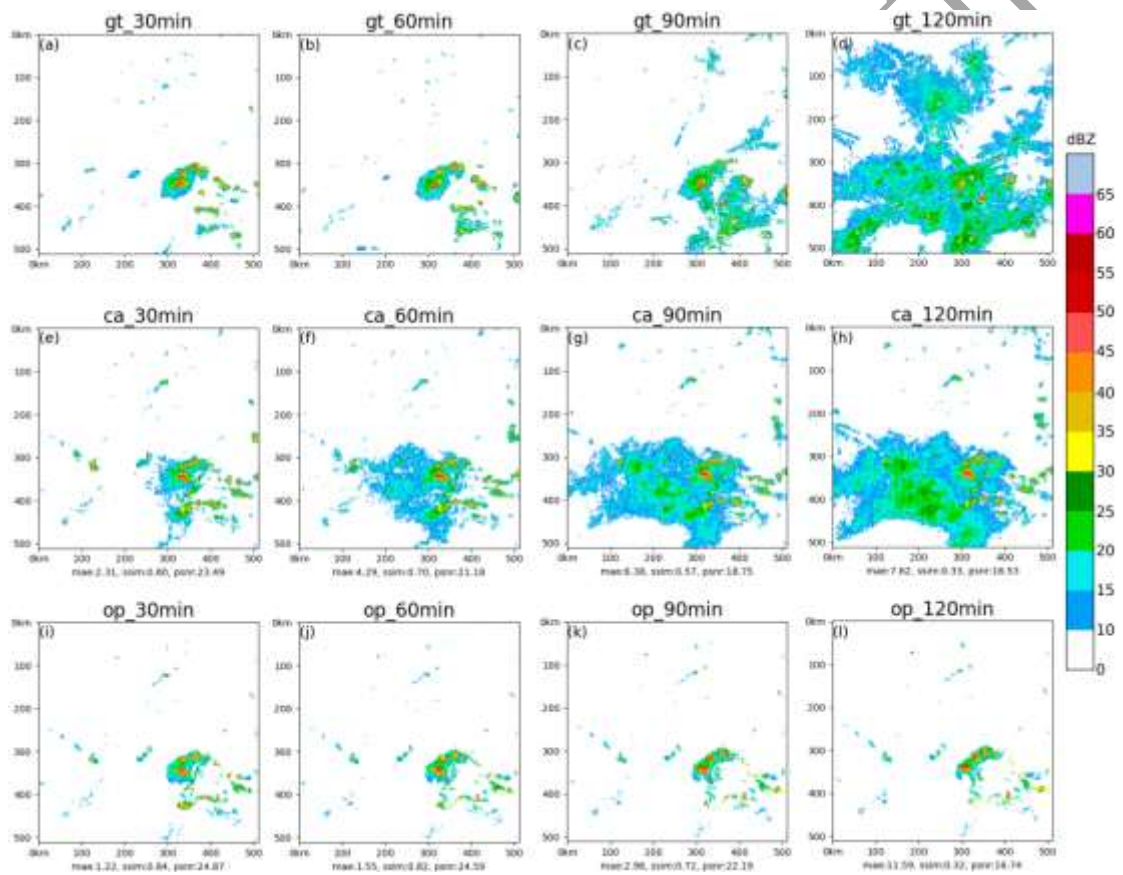


图 12 CastNet、光流法模型在 2023 年 9 月 22 日 17:30 起报的不同时效预报结果与实况对比
Fig.12 Comparison between the forecast results at different lead times starting from 17:30 on September 22, 2023 by the CastNet and the optical flow method model, and the actual situation

图 12 展示了 2023 年 9 月 22 日 17:30 雷达回波组合反射率 0~2h 预测结果，包括 CastNet 模型的预测（图 11e~图 11h）、光流法模型预测（图 11i~图 11l）、以及雷达回波实况（图 11a~图 11d）。实况强回波仅集中在部分核心区域，光流法的预报结果主要呈现回波的位移变化，其覆盖范围基本保持稳定，整体表现较为平稳。而 CastNet 模型的预测结果则表现出回波范围不断扩大的趋势，能够在一定程度上反映出回波随时间推移的生长与演变过程。

造成这种差异的原因主要有两点：（1）CastNet 模型基于循环神经网络（RNN）构建，每个训练样本包含长达 24 个时次（总计 144min）的时间序列信息，使得模型能够捕捉到一定程度的长期记忆以及时间维度上的潜在规律，进而在预测过程中更好地反映回波的动态变化；（2）CastNet 模型整合了生成对抗网络（GAN）模块，该模块赋予模型生成式特性，使其在预测过程中能够产生比传统方法更具动态性的推测。这一特性使得模型在个例中能够展现出回波范围逐渐扩大的预测结果。

6 结论

本文提出了一种针对短临外推设计的对抗神经网络模型 CastNet，应用于广西地区，并与 SWAN 3.0 和 SWAN 2.0 预报产品进行了对比检验。主要有以下结论：

（1）CastNet 模型通过循环神经网络（RNN）捕捉雷达回波的时空特征，并借助生成对抗网络（GAN）模拟云团的生成与消散，有效缓解了短临预报中的模糊性问题，提升了降水强度和位置预测的准确性。

（2）滑窗回归 Z-R 关系能够更准确地反映当前区域和时段内雷达回波与降水量之间的定量转换关系，融合地面降水观测数据可以有效减少雷达回波转换过程的模型误差和观测误差。

（3）在 0~2h 格点降水预报中，CastNet 模型的 TS 评分整体优于 SWAN 2.0；与 SWAN 3.0 相比，大雨级别的 TS 评分略有提升，而小雨级别则稍显逊色。

尽管 CastNet 相比传统气象预测方法展现出诸多优势，但其本质为数据驱动模型，依赖大量历史数据学习并挖掘统计规律，在应用上具有一定局限性。首先，历史样本的范围和多样性有限，难以涵盖所有气象场景，尤其在罕见天气过程中，模型预测准确性可能急剧下降。其次，神经网络模型的“黑箱”特性使得其缺乏可解释性，增加了优化和调整的难度。基于这些问题，未来的研究可从以下几个方向进行提升：

（1）大模型扩展，借鉴 GPT、盘古等大模型的设计思路，扩大模型参数规模至百亿级，同时利用更多历史数据进行训练。大模型在应对复杂气象规律的推断能力方面或能展现出更强的潜力。

（2）物理规律融合，结合基于物理规律的数值预报模式，特别是时间和空间分辨率优于全球模式的区域模式，将其大气环流因子等输出结果与 AI 模型结合，可能成为一种可行的方案。

（3）神经网络内部逻辑研究，深入理解神经网络内部作用逻辑，探索其在长短时记忆中学习到的物理规律。这将为有针对性地优化模型提供理论支持，从而更好地解决复杂气象条件下雷达回波运动、生成与消散等预测问题。

尽管 CastNet 模型目前还存在一些不足之处，但它蕴含很大的潜力。在未来，通过扩大模型规模、结合物理规律以及加强对神经网络内部机制的研究，CastNet 有望进一步提升短临外推预报的精准性和效率。

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[J]. 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[J]. Acta Meteor Sin, 73(3): 471-480 (in Chinese).
- 曹伟华, 南刚强, 陈明轩, 等, 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[J]. 气象学报, 80(4): 546-564. Cao W H, Nan G Q, Chen M X, et al, 2022. A study on fine scale precipitation nowcasting in Beijing-Tianjin-Hebei region based on deep learning[J]. Acta Meteor Sin, 80(4): 546-564 (in Chinese).
- 陈锦鹏, 黄奕丹, 朱婧, 等, 2024. 集成学习和动态融合算法在福建省短时强降水预报中的应用[J]. 气象, 50(1): 48-58. Chen J P, Huang Y D, Zhu J, et al, 2024. Application of ensemble learning and dynamic fusion for short-time severe rainfall forecasting in

- Fujian Province[J]. Meteor Mon, 50(1): 48-58 (in Chinese).
- 陈雷, 戴建华, 陶岚, 2009. 一种改进后的交叉相关法(COTREC)在降水临近预报中的应用[J]. 热带气象学报, 25(1): 117-122. Chen L, Dai J H, Tao L, 2009. Application of an improved TREC algorithm (COTREC) for precipitation nowcast[J]. J Trop Meteor, 25(1): 117-122 (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[J]. 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]. J Appl Meteor Sci, 18(5): 690-701 (in Chinese).
- 符式红, 钟青, 寿绍文, 2012. 对多普勒雷达集合交叉相关外推技术的构造与实例检验[J]. 气象, 38(1): 47-55. Fu S H, Zhong Q, Shou S W, 2012. Construction and case verification on Doppler radar ensemble extrapolation of cross-correlation[J]. Meteor Mon, 38(1): 47-55 (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[J]. 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[J]. Acta Meteor Sin, 77(4): 715-727 (in Chinese).
- 韩丰, 沃伟峰, 2018. SWAN2.0 系统的设计与实现[J]. 应用气象学报, 29(1): 25-34. Han F, Wo W F, 2018. Design and implementation of SWAN2.0 platform[J]. J Appl Meteor Sci, 29(1): 25-34 (in Chinese).
- 韩丰, 唐文苑, 周楚炫, 等, 2023. 基于 SWAN 系统的降水临近预报算法改进和应用评估[J]. 气象学报, 81(2): 304-315. Han F, Tang W Y, Zhou C X, et al, 2023. Improving a precipitation nowcasting algorithm based on the SWAN system and related application assessment[J]. Acta Meteor Sin, 81(2): 304-315 (in Chinese).
- 韩雷, 王洪庆, 林隐静, 2008. 光流法在强对流天气临近预报中的应用[J]. 北京大学学报(自然科学版), 44(5): 751-755. Han L, Wang H Q, Lin Y J, 2008. Application of optical flow method to nowcasting convective weather[J]. Acta Sci Nat Univ Pek, 44(5): 751-755 (in Chinese).
- 胡家晖, 卢楚翰, 姜有山, 等, 2022. 深度学习模型 TAGAN 在强对流回波临近预报中的应用[J]. 大气科学, 46(4): 805-818. Hu J H, Lu C H, Jiang Y S, et al, 2022. Application of deep learning model TAGAN in nowcasting of strong convective echo[J]. Chin J Atmos Sci, 46(4): 805-818 (in Chinese).
- 罗义, 梁旭东, 王刚, 等, 2022. 自适应尺度的雷达回波交叉相关跟踪算法研究[J]. 气象, 48(3): 372-385. Luo Y, Liang X D, Wang G, et al, 2022. A study of the adaptive-scale tracking Radar echoes by correlation method[J]. Meteor Mon, 48(3): 372-385 (in Chinese).
- 乔春贵, 郑世林, 杨立志, 等, 2006. 质心法雷达回波外推的原理及应用[J]. 河南气象, (3): 29-30. Qiao C G, Zheng S L, Yang L Z, et al, 2006. Principle and application of centroid method of Radar echo extrapolation[J]. Meteor Environ Sci, (3): 29-30 (in Chinese).
- 田付友, 郑永光, 孙建华, 等, 2024. 融合物理解与模糊逻辑的分类强对流客观短期预报系统: (1)系统构成[J]. 气象, 50(5): 521-531. Tian F Y, Zheng Y G, Sun J H, et al, 2024. Forecasting system for short-term multi-category convective phenomena combining physical understanding and fuzzy logic Part I: system construction[J]. Meteor Mon, 50(5): 521-531 (in Chinese).
- 田刚, 陈良华, 魏凡, 等, 2021. 基于光流法雷达外推的2020年长江致洪降水临近预报检验评估[J]. 暴雨灾害, 40(3): 316-325. Tian G, Chen L H, Wei F, et al, 2021. Evaluation of flood-producing rainfall nowcasting based on radar extrapolation with the variational optical flow method in the Yangtze River Basin in 2020[J]. Torr Rain Dis, 40(3): 316-325 (in Chinese).
- 万齐林, 薛纪善, 陈子通, 等, 2005. 雷达 TREC 风的三维变分同化应用与实验[J]. 热带气象学报, 21(5): 449-457. Wan Q L, Xue J S, Chen Z T, et al, 2005. The test of applying radar TREC wind in three-dimensional variational assimilation[J]. J Trop Meteor, 21(5): 449-457 (in Chinese).
- 王善昊, 胡志群, 王福增, 等, 2024. 基于 ConvLSTM 融合 RMAPS-NOW 数据的雷达回波外推研究[J]. 气象学报, 82(4): 554-567. Wang S H, Hu Z Q, Wang F Z, et al, 2024. Extrapolation of radar echo based on ConvLSTM with fusion of RMAPS-NOW data[J]. Acta Meteor Sin, 82(4): 554-567 (in Chinese).
- 吴涛, 万玉发, 沃伟峰, 等, 2013. SWAN 系统中雷达反射率因子质量控制算法及其应用[J]. 气象科技, 41(5): 809-817. Wu T, Wan Y F, Wo W F, et al, 2013. Design and application of Radar reflectivity quality control algorithm in SWAN[J]. Meteor Sci Technol, 41(5): 809-817 (in Chinese).
- 薛丰昌, 章超钦, 王文硕, 等, 2024. 基于自注意力和门控循环神经网络的雷达回波外推算法研究[J]. 气象学报, 82(1): 127-135.

- Xue F C, Zhang C Q, Wang W S, et al, 2024. Improving radar echo extrapolation algorithms based on self-attention and gated recurrent neural networks[J]. *Acta Meteor Sin*, 82(1): 127-135 (in Chinese).
- 尹麒名, 甘建红, 漆慧, 等, 2021. 一种改进的循环神经网络雷达图像外推算法[J]. *气象科技*, 49(1): 18-24, 45. Yin Q M, Gan J H, Qi H, et al, 2021. An improved algorithm of radar image extrapolation based on recurrent neural network[J]. *Meteor Sci Technol*, 49(1): 18-24, 45 (in Chinese).
- 袁凯, 李武阶, 李明, 等, 2022. 四种机器深度学习算法对武汉地区雷达回波临近预报的检验和评估[J]. *气象*, 48(4): 428-441. Yuan K, Li W J, Li M, et al, 2022. Examination and evaluation of four machine deep learning algorithms for radar echo nowcasting in Wuhan Region[J]. *Meteor Mon*, 48(4): 428-441 (in Chinese).
- 曾小团, 梁巧倩, 农孟松, 等, 2010. 交叉相关算法在强对流天气临近预报中的应用[J]. *气象*, 36(1): 31-40. Zeng X T, Liang Q Q, Nong M S, et al, 2010. Application test of TREC algorithm to severe convective storm nowcasting[J]. *Meteor Mon*, 36(1): 31-40 (in Chinese).
- 张智察, 罗玲, 陈列, 等, 2022. 卷积门控循环单元神经网络与光流法在临近预报中的适用性研究[J]. *气象*, 48(11): 1361-1372. Zhang Z C, Luo L, Chen L, et al, 2022. Applicability of convolutional gated recurrent unit neural network and optical flow method in nowcasting[J]. *Meteor Mon*, 48(11): 1361-1372 (in Chinese).
- 朱智慧, 黄宁立, 陈义, 2016. 光流法在强降水过程预报检验中的应用[J]. *气象科技*, 44(4): 596-604, 611. Zhu Z H, Huang N L, Chen Y, 2016. Application of optical flow method to heavy precipitation forecast verification[J]. *Meteor Sci Technol*, 44(4): 596-604, 611 (in Chinese).
- 庄潇然, 郑玉, 王亚强, 等, 2023. 基于深度学习的融合降水临近预报方法及其在中国东部地区的应用研究[J]. *气象学报*, 81(2): 286-303. Zhuang X R, Zheng Y, Wang Y Q, et al, 2023. A deep learning-based precipitation nowcast model and its application over East China[J]. *Acta Meteor Sin*, 81(2): 286-303 (in Chinese).
- Bromberg C L, Gazen C, Hickey J J, et al, 2019. Machine learning for precipitation nowcasting from radar images[C]//Proceedings of the Machine Learning and the Physical Sciences Workshop at the 33rd Conference on Neural Information Processing Systems (NeurIPS). Vancouver: 1-4.
- Cao Y, Chen L, Zhang D C, et al, 2022. Hybrid weighting loss for precipitation nowcasting from radar images[C]//ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Singapore: IEEE: 3738-3742.
- He K M, Zhang X Y, Ren S Q, et al, 2016. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE: 770-778.
- Laroche S, Zawadzki I, 1995. Retrievals of horizontal winds from single-Doppler clear-air data by methods of cross correlation and variational analysis[J]. *J Atmos Oceanic Technol*, 12(4): 721-738.
- Li J L, Yuan C L, Wang X F, 2023. Real-time instance-level detection of asphalt pavement distress combining space-to-depth (SPD) YOLO and omni-scale network (OSNet)[J]. *Automat Constr*, 155: 105062.
- Li L, Schmid W, Joss J, 1995. Nowcasting of motion and growth of precipitation with radar over a complex orography[J]. *J Appl Meteor Climatol*, 34(6): 1286-1300.
- Lin T Y, Goyal P, Girshick R, et al, 2017. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE: 2999-3007.
- Lu G Y, Wong D W, 2008. An adaptive inverse-distance weighting spatial interpolation technique[J]. *Comput Geosci*, 34(9): 1044-1055.
- Pulkkinen S, Nerini D, Pérez Hortal A A, et al, 2019. Pysteps: an open-source Python library for probabilistic precipitation nowcasting (v1.0)[J]. *Geosci Model Dev*, 12(10): 4185-4219.
- Qiu M H, Zhao P L, Zhang K, et al, 2017. A short-term rainfall prediction model using multi-task convolutional neural networks[C]//2017 IEEE International Conference on Data Mining (ICDM). New Orleans: IEEE: 395-404.
- Ravuri S, Lenc K, Willson M, et al, 2021. Skilful precipitation nowcasting using deep generative models of radar[J]. *Nature*, 597(7878): 672-677.
- Shi X J, Gao Z H, Lausen L, et al, 2017. Deep learning for precipitation nowcasting: a benchmark and a new model[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc.: 5622-5632.

- Smith T M, Lakshmanan V, Stumpf G J, et al, 2016. Multi-Radar Multi-Sensor (MRMS) severe weather and aviation products: initial operating capabilities[J]. Bull Amer Meteor Soc, 97(9): 1617-1630.
- Wang Y B, Long M S, Wang J M, et al, 2017. PredRNN: recurrent neural networks for predictive learning using spatiotemporal LSTMs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc.: 879-888.
- Wang Y B, Wu H X, Zhang J J, et al, 2023. PredRNN: a recurrent neural network for spatiotemporal predictive learning[J]. IEEE Trans Pattern Anal Mach Intell, 45(2): 2208-2225.
- Ware E C, 2005. Corrections to radar-estimated precipitation using observed rain gauge data[D]. Ithaca: Cornell University: 879-888.
- Zhang J, Howard K, Langston C, et al, 2016. Multi-Radar Multi-Sensor (MRMS) quantitative precipitation estimation: initial operating capabilities[J]. Bull Amer Meteor Soc, 97(4): 621-638.
- Zhang Y C, Long M S, Chen K Y, et al, 2023. Skilful nowcasting of extreme precipitation with NowcastNet[J]. Nature, 619(7970): 526-532.

