

范 娇,曾小团,黄荣成,等.深度学习在降水预报中的研究和应用进展[J].气象研究与应用,2024,45(3):1-11.  
FAN Jiao, ZENG Xiaotuan, HUANG Rongcheng, et al. Research and application progress of deep learning in precipitation forecasting [J]. Journal of Meteorological Research and Application, 2024, 45(3): 1-11.

## 深度学习在降水预报中的研究和应用进展

范 娇<sup>1,2</sup>, 曾小团<sup>1\*</sup>, 黄荣成<sup>1</sup>, 黄增俊<sup>2</sup>

(1.广西壮族自治区气象台, 南宁 530022; 2.南宁市气象局, 南宁 530029)

**摘要:**主要总结气象领域常用深度学习算法特征、纯数据驱动的深度学习降水预报技术和深度学习与数值天气预报耦合技术在临近、短时、中短期、气候降水预报中的探索成果,同时对气象业务预报中深度学习的应用进行简单回顾。传统深度学习算法的优缺点不同,在实际应用中,需要根据具体的气象数据特性和业务需求来选择合适的模型和方法。临近预报方面,常使用深度学习算法建立降水预报模型从而进行强降水云团空间特征提取和时间演变分析。长时间序列降水预报,则主要通过初始场资料同化、模式改进、模式预报后处理等方面优化数值模式降水预报效果。深度学习在解决降水预报技术方面有巨大潜力,部分成果已经实现业务应用,尤其在临近降水方面,对于更长时效的降水预测应用还有待进一步研究。

**关键词:**深度学习;降水预报;数值天气预报;模式耦合

**中图分类号:** P456 **文献标识码:** A **doi:** 10.19849/j.cnki.CN45-1356/P.2024.3.01

IPCC第六次评估报告指出,最近50 a气候变暖正在以过去2 000 a以来未有之速度变化。根据NOAA的数据显示,2023年7月,全球平均气温已飙升至前所未有的17.2 °C,美国航天局表示,这已成为自1880年有全球气温记录以来平均气温最高的月份。在此态势下,气候系统不稳定性不断加剧,全球极端天气气候事件高发、频发,多地雨强刷新历史极值<sup>[1-3]</sup>,给人类社会、经济发展带来灾难性影响。世界气象组织发布的综合报告显示,过去50 a中,世界范围内44%的灾害与洪水有关。可见,精准的降水预报对保障经济社会的安全发展起到至关重要的作用。

近年来,人工智能在各个领域都有广泛的应用和发展<sup>[4-6]</sup>。人工智能算法研究高度依赖于丰富的数据和案例,而气象数据作为一种具有长期连续性、多元观测要素以及深度融入社会生产生活信息的“大型数据集”<sup>[7]</sup>,其特性与人工智能高度适配,二

者结合为降水预报的发展提供新途径<sup>[8-10]</sup>。各国为推动人工智能在气象领域的发展相继开展大量的工作。2021年初,欧洲中期天气预报中心发布人工智能未来10 a路线图,提出未来人工智能将完全融入数值天气预报和气候服务中,并在工作流程等诸多方面改进预测及其释用技术。美国大气科学研究中心、Google和IBM等大幅增加财年预算投入AI天气预报应用。中国气象局关于《人工智能气象应用工作方案(2023—2030年)》提出加快布局国产人工智能气象应用技术体系建设,推动人工智能技术在气象领域的深度融合应用和发展。众多气象学者纷纷对人工智能技术的应用进行探讨。据Web of Science平台SCI-E数据库统计显示,2000—2018年“气象与大气科学”类发表的“人工智能”主题文献发文数量呈现显著增长趋势<sup>[7]</sup>,2017年涉及人工智能相关算法的论文数比2008年提高7倍<sup>[11]</sup>,人工智能在天气预报中的作用不断被挖掘。人工

收稿日期:2024-02-15

基金项目:广西自然科学基金项目(2022GXNSFAA035482)、广西气象科研计划项目(桂气科2022QN05、桂气科2020QN03)

第一作者:范娇(1993-),工程师,主要从事数值天气预报研究。E-mail:742895059@qq.com

\*通讯作者:曾小团,正高级工程师,主要从事天气预报技术研究和系统开发工作。E-mail:158083890@qq.com

智能核心内容包括传统的机器学习方法和新兴的深度学习方法,深度学习方法在挖掘数据内在规律方面具有突出优势,可以自动提取强天气演变的非线性特征<sup>[12-14]</sup>,在降水预报领域已取得初步进展。本文针对深度学习方法在降水预报中的应用和发展进行回顾,同时对气象部门基于业务需求展开的深度学习预报研究进行简单总结,以期更清晰地了解深度学习在业务降水预报应用中存在的问题与面临的机遇,以及相应的建议对策。

## 1 深度学习方法概述

深度学习作为目前的新兴方法,已成为解决部

分天气预报技术瓶颈的关键。由于传统深度学习模型优缺点不同、适用场景不同(如表1),在实际应用中,应针对算法特性选择其擅长的领域来开展相应研究。当前,大部分深度学习模型结构是基于卷积神经网络(Convolution Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)建立。卷积神经网络可以通过卷积和池化操作构建层的特征提取器,通过反向传播算法优化参数,让网络自动学习到图像的特征。循环神经网络(RNN)的隐藏状态是随时间步更新的,并作为下一时间步的输入之一,这种循环连接使得RNN具有记忆能力,能捕捉序列中的长距离依赖关系,最后利用历史信息预测未来的输出。

表1 传统深度模型的特征及应用场景

方法	特征	优点	缺点	适用场景
卷积神经网络	通过多个卷积层、池化层和全连接层来提取图像中的特征。	可以降低模型的复杂度和参数数量,提高模型的泛化能力。	受限于卷积核大小,只能提取到有限范围且固定的信息,导致缺乏处理序列数据的能力。	充分考虑到空间结构的相关,适用于处理图像类数据。
循环神经网络	核心组成部分是循环层和全连接层。能够在网络中传递信息,从而捕捉序列中的时序依赖关系。	可以高效学习序列的非线性特征,具有记忆效应。	依赖上一时间步的输出,难以捕捉数据时间序列的长期关系;无法学习格点数据固有的多维空间特征;容易受到噪声干扰。	在时间维度上进行有效学习,适用于处理时间序列数据。
深度信念网络	由多个受限玻尔兹曼机(RBM)堆叠而成的深度学习算法,并具有逐层提取特征和无监督学习的特点。	具有强大的特征学习和抽象能力,能够从未标记或半标记数据中学习数据的分布和结构,具有较好的扩展性和灵活性。	容易过拟合;对输入数据有较高的要求,对于缺失或异常的数据需要进行额外的处理或筛选。	适用于处理多维复杂数据。
生成对抗网络	包含生成网络(Generator)和判别网络(Discriminator),通过最小化对抗性损失函数来学习数据的真实分布。	可以利用无标签数据进行学习;能生成逼真的天气数据;计算效率高。	模型不稳定;对训练数据依赖性强,存在过拟合风险。	可以生成新的数据样本,用于训练其他模型。
Transformer	引入自注意力机制(Attention Mechanism)和位置编码。	相比RNN或CNN等,具有更高的并行性和计算效率;可以捕捉序列中不同位置之间的依赖关系。	参数调优复杂;数据稀疏性对Transformer的训练和预测结果影响较大;存在梯度消失或爆炸的问题。	适用于处理非线性和长期依赖关系以及非图像类数据。
自编码器	由编码器和解码器组成,通过最小化输入数据与重建数据之间的差异来进行学习。	能从大量无标签数据中学习数据的低维表示和特征,自动提取和表达数据的特征。	参数调优复杂;模型训练不稳定。	适用于数据降维、压缩、可视化、异常检测等任务。

为了最大限度发挥各种神经网络方法的优势,传统深度学习技术得到不断发展和改进,逐渐衍生出不同的变体。例如,He等<sup>[15]</sup>提出一种基于残差学习模块的CNN模型,解决深度网络训练难以收敛的问题。Ronneberger等<sup>[16]</sup>提出基于编码解码结构像素级预测的U-Net模型,使用“跳跃连接”技术将高级的特征信息直接传输到低级网络,从而避免梯度消失的问题。Han等<sup>[17]</sup>基于U-Net提出改进的CU-Net模型,张延彪等<sup>[18]</sup>又在CU-Net模型基础上引入稠密卷积,同时融合多源数据构建Fuse-CU-Net。1997年,Hochreiter和Schmidhuber<sup>[19]</sup>在RNN基础上,引入额外机制以更好地处理序列数据中的长距离依赖关系,提出长短期记忆网络(Long Short Term Memory, LSTM)。2017年,Vaswani等<sup>[20]</sup>引入具有更少参数和更简单结构的门控循环单元(Gated Recurrent Unit, GRU),显著提升训练速度、降低硬件需求,二者在一定程度上均能解决梯度消失或梯度爆炸问题。

Wang等<sup>[21-22]</sup>基于RNN先后提出预测循环神经网络(Predictive Recurrent Neural Network, PredRNN)和时空预测循环神经网络(Recurrent Network for Spatiotemporal Predictive, PredRNN++),可以自适应学习时空序列中的短期和长期特征信息。Goodfellow等<sup>[23]</sup>基于GAN模型引入额外信息作为约束条件,提出条件生成对抗网络(Conditional Generative Adversarial Nets, CGAN),解决GAN模型训练难收敛、生成样本单一且不可控等问题。Wang等<sup>[24]</sup>、Singh等<sup>[25]</sup>提出捕捉高频功率谱的信息能力较强的增强超分辨率GAN模型(Enhanced Super-Resolution Generative Adversarial Networks, ESRGAN),这类方法是统计降尺度上的典型模型。除了模型的改进,模型的混合也是深度学习的主要应用方式,混合型深度学习模型可以有效结合多个模型的优点,在计算过程中进行知识转移、知识互补,在不同的时间和空间域上协同工作,增强鲁棒性,提高预测性能(如表2)。

表2 混合型深度学习模型的特征

方法	特征	解决的问题
分层序列预测模型 <sup>[26]</sup>	具有记忆和预测功能,可将数据分解为多个时间尺度,并使用RNN和CNN来处理这些时间尺度上的数据。	更好地捕捉序列数据中的长期依赖关系和局部特征。
轨迹门控循环单元神经网络 <sup>[27]</sup>	可以主动学习递归连接的位置和时间变量结构。	捕捉不同位置的时空相关性特征。
3D-CNN (3D Convolution Neural Network)与LSTM融合的混合模型 <sup>[28]</sup>	具有多维图像特征提取能力,通过重塑向量的形式处理提取的高阶特征信息。	解决了样本量维度有限,模型过拟合和特征学习不充分的问题。
LSTM与卷积编解码网络(U-Net)结合的混合模型 <sup>[29]</sup>	同时具备LSTM处理序列数据的能力和U-Net处理图像数据的能力。	捕捉时空相关性,解决风速集合预报中的预测不确定性和提高预测精度的问题。
综合使用卷积、LSTM、注意力机制等方法构建MetNet模型 <sup>[30]</sup>	不依赖于大气动力学领域的物理定律,通过使用空间下采样器,减少了输入面片的空间维度,考虑像素之间的全局依赖性,可融合局部和全局的信息。	减少了内存消耗并缓解了深度神经网络训练过程中的梯度消失问题,具有高度的区域和时间结构,存在长距离依赖性。
RainNet <sup>[31]</sup> (一种基于深度学习的图像超分辨率重建方法)	采用自注意力机制(Self-Attention Mechanism)模拟和提取图像中的长程依赖关系,通过残差连接直接将高级的特征信息传输到低级网络。	能够在不降低计算效率的情况下实现高保真度的图像超分辨率重建。

## 2 深度学习在降水预报中的应用研究

业务上,降水预报可以按预报时长分为临近预报、短时预报、短期预报、中期预报、延伸期预报以及气候预测等<sup>[32-33]</sup>。本节从不同时间尺度上分析深

度学习在降水预报中发挥的作用。

### 2.1 深度学习在临近降水预报中的应用

临近降水预报是指对未来2h内降水量、降水强度、降水类型及降水持续时间等进行预测,具有

准确性、及时性和精细化的特征,其预报关键在于结合时间序列外推技术进行定量降水估计(Quantitative Precipitation Estimation, QPE),QPE的精度决定短临降水预报的精准度。业务上主要使用多源实况资料,采用单体质心法(Storm cell identification and Tracking, SCIT)、TITAN(Thunderstorm identification, Tracking, Analysis and Nowcasting)、交叉相关法(Racking radar echoes by correlation, TREC)、光流法等对强天气系统进行识别、追踪,从而实现外推预报<sup>[34-35]</sup>。近年来雷达回波外推方法持续优化,短临预报效果不断提升,但由于对风暴动力学、热力学等因素的考虑不足,导致系统发展难把握、降水预报水平难提升<sup>[34,36-37]</sup>。而高分辨率中尺度数值预报模式虽能实现天气系统发展趋势预报,但模式本身存在“spin-up”时间,临近几小时的预报效果差,往往无法达到实际预报需求<sup>[38]</sup>。

深度学习由于能提取复杂的非线性特征,在处理分析强降水回波或强降水云团空间特征及其时间演变的问题上具有显著优势<sup>[39]</sup>,是外推法和数值预报方法的有效补充<sup>[13]</sup>。Agrawal等<sup>[40]</sup>使用基于图像分割任务的U-Net模型进行临近降水预报,预报效果优于光流法。郭瀚阳等<sup>[41]</sup>使用深度学习方法构建一个高时效、易拓展的卷积GRU临近预报模型,其预报结果比传统雷达回波外推方法有明显提高,能有效预测未来1 h回波演变特征。曹伟华等<sup>[42]</sup>基于深度学习网络模型RainNet建立两种滚动预报方式,并在京津冀地区开展分辨率为1 km的精细尺度降水滚动式临近预报试验,结果显示,10—50 min内,深度学习模型对 $1.04 \text{ mm} \cdot (10 \text{ min})^{-1}$ 及以下阈值降水的预报性能优于传统交叉相关外推方法,CSI评分最大增加0.04。胡家晖等<sup>[43]</sup>使用优化对抗神经网络构建的TAGAN深度学习模型进行临近预报,在10~40 dBZ阈值下的临界成功指数、命中率和HSS评分TAGAN基本高于传统光流法,而虚警率FAR则低于传统光流法,并且其预测时间越长,预报效果较传统光流法越好。Cao等<sup>[44]</sup>使用U-net卷积神经网络模型进行 $1 \text{ km} \times 1 \text{ km}$ 高分辨临近1 h降水预报,模式表现优于光流法和NOAA-HRRR系统1 h降水预报。夏侯杰等<sup>[45]</sup>基于雷达资料和地面实况要素融合训练的CNN-LSTM模型,可以较好解决临近降水预报中雨带生消变化预报较差的问题,该模型预报的0~2 h降水准确率高于雷达回波外推SDL模型和CMA-SH3高分辨率数值模式。从以上

研究可见,深度学习模型在解决短时临近降水预报问题上具有巨大的潜力。

短临降水预测从深度学习模型的角度可归为时空序列预测问题<sup>[12]</sup>,RNN模型到全连接的长短期记忆递归神经网络(Fully Connected Long Short-Term Memory, FC-LSTM)均为解决时空序列预测问题的有效方法,但它包含太多冗余的空间数据,对空间相关性的考虑缺乏。Shi等<sup>[12]</sup>拓展FC-LSTM模型得到能更好捕获时空相关性的卷积长短期记忆神经网络(Convolutional Long Short-Term Memory, ConvLSTM)并用其构建降水预报模型,在 $0.5 \text{ mm} \cdot \text{h}^{-1}$ 降水率阈值下预报效果优于FC-LSTM和传统光流法。林青等<sup>[46]</sup>使用ConvLSTM模型结合Z-R关系计算未来3 h雷达反射率因子矩阵,从而进行降水预报,预报的空漏报率均低于SWAN业务系统的定量降水预报结果。然而,基于ConvLSTM的模型中卷积递归结构位置是不变的,而自然运动通常位置可变,且低降水率阈值下的性能不足以证明算法的整体性能<sup>[47]</sup>。为了解决上述问题,Shi等<sup>[27]</sup>提出一个新的降水预报模型轨迹门控循环单元神经网络(TrajGRU),该模型可以主动学习递归连接的位置变量结构,在捕捉时空相关性方面比卷积门控循环单元神经网络(ConvGRU)更有效。张智察等<sup>[48]</sup>评估卷积门控循环单元神经网络在临近预报中的适用性时发现,ConvGRU无法表征回波的精细化运行规律和演变特征,其原因正是在获取时空相关性时,ConvGRU或者其他ConvRNNs模型的超参数固定,即所有位置的连接结构和权值保持不变,这与不同位置有不同邻域集的运动模式相悖,从而导致模拟结果差强人意。为了解决以上问题,Wang等<sup>[21]</sup>在递归过程中的相邻时间步之间增加额外的连接,提出带有时空LSTM(ST-LSTM)单元的预测递归神经网络(PredRNN),在此基础上,又进一步提出PredRNN++解决深时困境和序列建模问题<sup>[24]</sup>,其预测性能在实际降水预报应用中取得明显提升<sup>[49]</sup>。另外,在进行数据驱动模式预报时,模型训练为了使损失函数最小化,选择的算法策略会削弱对要素峰值的预测,导致大量级降水预报易出现严重低估的现象<sup>[50]</sup>。2020年,Jing等<sup>[26]</sup>提出一种用于雷达回波外推的分层序列预测模型,该模型包含长程RNN模块和一个短程RNN模块,采用分层预测策略和递归细化机制,对其进行评估发现,与其他方法相比(ConvLSTM、PredRNN和TrajGRU),HPRNN可以预

测回波的演化和移动,外推更长时间的回波使其保持详细的外观,并提高降水实况的预报质量,这归因于分层预测策略和细化机制。2021年,Ravuri等<sup>[13]</sup>开发能较好捕捉环流系统强度和结构的基于CGAN算法的临近降水预报模型,该模型在所有降水量级上都有比平流法(PySTEPS)更高的预报准确率,在大量级降水上比U-Net算法更接近实况。

## 2.2 深度学习在短时及中短期降水预报中的应用

2 h以上时效的降水预报业务多依赖于数值模式。由于数值模式在资料同化方法、模式动力框架以及物理参数化方案等方面存在不足,导致其难以真实描绘强对流等中小尺度天气系统的结构特征,从而产生模式分析和预报误差,随着预报时间的延长,这种误差会以指数形式增长,导致天气可预报性显著降低<sup>[51]</sup>。而深度学习(数据驱动)虽与数值模式(理论驱动)具有不同的科学范式,但二者从理论基础、算力成本、稳定性、可解释性、不确定性量化等方面<sup>[22]</sup>来看,在一定程度上却是互补相通的<sup>[52]</sup>。深度学习可以基于数据特征进行提取、归类、推演等高效的优化统计计算,同时将不确定性量化,充分发挥海量实况和预测数据在天气预报中的作用,弥补数值天气预报模式在数据融合、算力成本、不确定性量化等方面的缺陷。深度学习与数值天气预报技术的耦合,可充分发挥二者的优势,通过局部优化、局部替代、全局替代等多种方式优化数值模式降水预报效果。

### (1) 初始场资料同化

资料同化可以将多源实况资料融合到数值模式中作为初始场的调整,从而提高初始条件精度,是改善模式初值质量的有效方法。深度学习可以利用多源数据集,通过自主学习预报量与其他要素之间的非线性关系<sup>[44]</sup>优化模式初始场,其作用在地球系统科学中与资料同化高度相似<sup>[53-54]</sup>。利用神经网络技术近似偏微分方程(PDE)解的能力,2018年,Cintra等<sup>[55]</sup>使用人工神经网络(NN)代替区域集合变换卡尔曼滤波方法(Local Ensemble Transform Kalman Filter, LETKF)进行资料同化,试验表明,NN和LETKF方法的分析结果接近并具有更好的计算效率。2020年,Brajard等<sup>[56]</sup>发展EnKF资料同化方法与CNN模型双向互反馈耦合的新方案,该方案有利于模拟复杂的动力过程,在短期预报中有较好的效果,同时也促进了资料同化和深度学习相结合的混合方法的发展。2021年,Peyron等<sup>[57]</sup>也通过深度

学习进行潜在空间数据同化,并提出一种新的集合变换卡尔曼滤波方法(Ensemble Transform Kalman Filter, ETKF),新算法(ETKF-Q-Latent)在潜在空间中具有模型误差,可以准确表示观测到的动力学潜在结构,比现有技术算法(ETKF-Q)既降低计算成本,又提供更好的精度。

### (2) 预报模式改进

数值天气预报模式中的次网格过程是描述大气演变特征的重要方式,其参数化方案包含近似函数和大量可调参数,是造成数值模式预报误差的重要因素之一<sup>[58-59]</sup>。为了弥补不足,可以使用大量观测值训练深度学习模型替换原子模块。Pal等<sup>[60]</sup>在超参数化能量精确地球系统模式(SP-E3SM)中使用深度神经网络(Deep Neural Networks, DNN)模拟短波和长波辐射传输计算,模拟结果与原始参数化方案质量相当。Wang等<sup>[61]</sup>利用WRF模式的输出来训练DNN替换行星边界层参数化方案(PBL),可以成功模拟整个昼夜循环内边界层中的风速、温度和水汽垂直分布。Scher等<sup>[62]</sup>设计一种深层CNN完全模拟并替代物理大气环流模型(General Circulation Model, GCM),学习仿真其动力学框架并重复将预测结果反馈给模型的输入,最后可以在成功预测未来几个时间步长天气的同时保证气候稳定。Rasp等<sup>[63]</sup>训练深度学习替代GCM中所有传统子网格参数化,它与解析的动力和表面通量方案自由交互,不仅长时间预测结果稳定,在极端降水等方面也起到关键作用。Brenowitz等<sup>[64]</sup>训练深度学习模型替换次网格的物理参数化方案,分析其线性化响应可见高层大气湿度和降水之间的强相关性。

### (3) 模式后处理

目前较多研究围绕降水预报后处理开展,后处理包括订正数值天气预报模式输出结果与真值可能存在的偏差、优化集合预报结果、对模式结果进行统计降尺度处理等。例如:Schaumann等<sup>[65]</sup>提出一种神经网络降水统计方法,将雷达数据和高分辨率数值预报产品融合,优化6 h范围内的降水预报。Liu等<sup>[66]</sup>基于BCoP深度学习算法构建自适应时空尺度选择(Spatiotemporal Scale Adaptive Selection, SSAS)模型进行降水数值预报后处理,与11种已发表的BCoP方法相比,SSAS性能最佳,尤其是在强降水情况下。陈锦鹏等<sup>[67]</sup>在2019年模拟业务数据集上使用基于CNN的逐时降水分级订正模型进行订正试验,结果显示,CNN模型对晴雨、 $0.1 \sim 15 \text{ mm} \cdot \text{h}^{-1}$

的弱降水以及  $30 \text{ mm} \cdot \text{h}^{-1}$  以上的强降水订正效果显著。Sayeed 等<sup>[68]</sup>研究卷积神经网络的使用,将其作为一种后处理技术通过对几个气象参数进行偏差校正来改进中尺度天气和研究预报的一天预报(时间分辨率 1 h)输出,有效减小预报站点的地面风、降水、温度等气象要素偏差。Ghazvinian 等<sup>[69]</sup>和 Scheuerer 等<sup>[70]</sup>提出一种基于 ANN 算法的后处理方案,对中短期降水集合预报进行订正,有效提高降水概率预报可靠性。在统计降尺度方面,深度学习由于擅长挖掘数据间非线性映射关系,目前已经被广泛应用<sup>[71-73]</sup>。长短期记忆循环神经网络(RNN-LSTM)<sup>[71]</sup>、CNN<sup>[72]</sup>、深度统计降尺度技术(Deep Statistical Downscaling, DeepSD)<sup>[74]</sup>等算法均能通过统计降尺度较好的改善模式降水预报效果。Sha 等<sup>[75-76]</sup>使用改进后的 U-Net 模型(UNet-AE)可以将气温和降水的网格间距从  $0.258^\circ$  降低到 4 km,同时将预报值的平均绝对误差降低 10% 以上。为了进一步对多步预测结果进行偏差订正,Sha 等<sup>[77]</sup>将模拟集成(AnEn)、最小散度 Schaake-Shuffle (MDSS) 和 CNN 方法相结合,提出一种集合降水预报后处理方法(AnEn-CNN),可将全球集合预测系统(GEFS) 3 h 降水量预测的集合平均值作为输入,产生偏差校正、概率校准和物理现实的 7 d 网格降水量预测序列,这项工作与传统统计后处理和神经网络的首次结合。在进行统计降尺度时也有学者融合多源实况资料进行研究,例如,Leinonen 等<sup>[78]</sup>和 Price 等<sup>[79]</sup>引入卫星云图和雷达资料作为约束条件构建 CGAN 模型,实现降水预报的降尺度,其预报性能优于 CNN 降尺度模型。

#### (4) 纯数据驱动的预报模型

随着多源实况观测数据、高分辨数值预报产品数量和质量的提升以及深度学习算法的发展完善,已经有学者对纯数据驱动模型在短时、中短期预报中的应用展开一系列研究。Sønderby 等<sup>[30]</sup>提出的深度学习降水预报模型 MetNet,将雷达、卫星数据以及预报提前量作为输入,生成降水概率图,评估其在各降水阈值下(空间分辨率 1 km,时间分辨率 2 min)的性能发现, MetNet 在美国大陆范围内长达 7~8 h 的预报优于数值天气预报。Hernández 等<sup>[80]</sup>提出一种包含用于减少和捕捉属性之间非线性关系的自动编码器以及用于预测任务的多层感知器的深度学习预报模型,该模型预报第 2 天累积日降水量的能力较其他方案有明显提高。为了较好地

反映区域降水的变化趋势,张鹏程等<sup>[81]</sup>提出一种基于深度信念网络的降雨量预报模型,该模型分为多层受限玻尔兹曼机和顶层 BP 网络两大部分,模型的输入向量包含与日降水量相关的 7 个环境因子,输出向量为未来 24 h 降水,实验证明该模型可以较好地降水趋势进行预测,对整个曲线的升降幅度的拟合也较为精确。Pathak 等<sup>[82]</sup>构建基于傅里叶变换的神经网络预报模型(Fourier Forecasting Neural Network, FourCastNet),是一个全球数据驱动的天气预测模型,可提供  $0.25^\circ$  空间分辨率的全球中短期地面风速、降水量预报,在包含降水在内的具有复杂精细结构的变量中,其预测精度优于 ECMWF 的高分辨率综合预测系统(Integrated Forecasting System, IFS),极大改善概率天气预测效果,能够以很低的成本生成大量的子模型进行集合预测,实现几秒内生成未来 7 d 的预报。

#### 2.3 深度学习在气候降水预测中的应用

由于深度学习自身的特点,目前主要进行的是临近、短时、中短期天气预测,但国内外也开始尝试将深度学习应用于气候预测。已有多项研究表明深度学习用于气候模型建立的可行性<sup>[83-84]</sup>。例如: Rasp 等<sup>[63]</sup>训练深度神经网络来表示气候模型中的所有大气子网格过程,稳定再现云解析模拟的平均气候。Ham 等<sup>[85]</sup>使用气候数据训练的 CNN 模型克服了动态预测模型的弱点,模型预测 Nino3.4 指数的全季节相关性技巧远高于当前最先进的动态预测系统,可以提前 1.5 a 对 1984 年以来的厄尔尼诺现象做出预报。针对现有次季节降水预报误差较大的问题,潘乐等<sup>[86]</sup>提出基于改进的 U-Net 模型的次季节降水预报订正方法,订正结果相较于原始预报误差明显降低,CRPS 降低 14%,概率预报的采样均值在 10 mm 日降水量阈值的 TS 评分提升 48%。张丽婷等<sup>[87]</sup>构建多类别输入输出模式变化的深度学习 LSTM 神经网络方法,对扬州市区月降水量进行预测,结果显示, LSTM 多输入单输出动态模式和多类 LSTM (multi-category LSTM, M-LSTM) 多输入多输出静态模式预测准确度均高于 LSTM 多输入多输出静态模式。Wang 等<sup>[88]</sup>设计一组可以从云解析模型输出中学习参数化方案的残差深度神经网络模型(Residual-Deep Neural Networks, ResDNNs),其具有强非线性拟合能力,能实现高性能和长期模拟,在实际陆地-海洋边界条件下,混合深度学习的大气物理环流模式(GCM)可以很好地模拟降水的空间

分布,提高极端降水的频率,并实现多年稳定气候模拟,展示深度学习参数化方案在气候模拟中的新兴潜力。在更广泛的背景下,基于深度学习的地球系统模型开发可能在减少未来 10 a 气候预测的不确定性方面发挥关键作用<sup>[63]</sup>。

### 3 深度学习在业务降水预报中的应用

深度学习技术的突破,为解决降水预报的不确定性问题提供新思路。近年来,各地气象部门也开始探索深度学习在业务预报中的应用。国家气象中心与高校合作,通过分布式深度学习框架、时空记忆深度循环网络算法,使雷达外推预报准确率较以往平均提升 40%,有利于提高 0~2 h 降水预报精准度<sup>[89]</sup>。Zhou 等<sup>[90]</sup>基于数值天气预报(NWP)数据建立并训练 6 层 CNN 模型应用于强对流天气的客观预报,与其他传统方法相比,深度学习算法对强降水和冰雹的分类精度更高,其客观预测也显示出比预报员的主观预测更好的预测技能,预报产品已在业务预报中得到应用<sup>[91-92]</sup>。重庆市气象局与百度公司合作,采用 TrajGRU、U-net 等技术,建立强对流天气雷达回波智能临近预报模型并业务化,其降水预报较 SWAN 有一定程度提高,且时效越长预报提升效果越显著<sup>[38]</sup>。除此以外,上海、福建、广东等地气象部门也将深度学习应用于业务降水预报<sup>[93]</sup>。近期,华为团队和清华大学已分别研发出盘古气象(Pangu-Weather)<sup>[94]</sup>和 NowcastNet<sup>[95]</sup>两款大语言模型应用于业务降水预报中,盘古气象预测准确率可以与全球最佳数值天气预报系统“欧洲中期天气预报中心的综合预报系统”相媲美,同时,在相同的空间分辨率下,盘古气象比数值天气预报系统快 10000 多倍。而 NowcastNet 能够在 2048 km × 2048 km 范围内提前 3 h 进行高分辨率的降水预测,在预测降水强度方面有着很大的优势,其作用在极端降水事件预测中尤为突出。两款模型的问世,也意味着深度学习在降水预报应用中取得较大进步,为天气预报技术的发展增强信心。

### 4 总结与展望

随着深度学习技术的快速发展和算力资源的持续增强,以纯数据驱动的深度学习和与数值天气预报耦合的深度模型在降水预报中得到广泛应用,前者在临近预报中的作用较为突出,后者则主要通过初始场资料同化、模式改进、模式预

报后处理等方面优化长时效的数值模式降水预报性能。已有研究表明,深度学习在解决降水预报方面表现出巨大潜力,部分成果如 NowcastNet 预报模型等已经实现业务应用,在实践中崭露头角。但由于降水是非线性的,深度学习利用统计方法建立的数据间非线性关系难以解释天气系统中的物理机制<sup>[50]</sup>,同时,由于深度学习算法众多,在降水业务预报中如何针对不同的场景需求选择合适的算法,如何避免海量的多源数据伴随的各种噪声、不确定性和缺失等问题<sup>[53]</sup>,均是未来研究中必须解决的难点。

针对这些难点问题,未来将主要从以下几个方面开展:①加强具有物理约束能力的深度模型研究,提升预测能力的同时一定程度上增强深度学习模型的可解释性<sup>[96-97]</sup>;②通过将预报员累积的经验作为先验知识融入到深度学习模型算法;③通过深度学习挖掘数据规律和局地特征,实现深度学习的精细化应用;④在深度学习的降水预报应用方面加大研发投入力度,培养稳定的研发团队,在业务中不断优化模型。

#### 参考文献:

- [1] 董良鹏,张萍萍. 2020年湖北省两次低涡型极端降水气象因子异常特征对比[J]. 气象与环境学报, 2022, 38(6): 20-28.
- [2] 张霞,杨慧,王新敏,等. “21·7”河南极端强降水特征及环流异常性分析[J]. 大气科学学报, 2021, 44(5): 672-687.
- [3] 刘国忠,覃月凤,覃卫坚,等. 2022年广西极端“龙舟水”暴雨过程环境场特征分析[J]. 气象研究与应用, 2023, 44(1): 7-13.
- [4] 方楠,谢国权,阮小建,等. 长短期记忆神经网络(LSTM)模型在低能见度预报中的应用[J]. 气象与环境学报, 2022, 38(5): 34-41.
- [5] 周维勋. 基于深度学习特征的遥感影像检索研究[J]. 测绘学报, 2023, 52(1): 167.
- [6] 滕琳,王斌,冯前进. 头颈癌放疗计划剂量分布的预测方法:基于深度学习的算法[J]. 南方医科大学学报, 2023, 43(6): 1010-1016.
- [7] 张萌,贾朋群,王小光. 人工智能技术在大气科学领域的应用及其发展态势[J]. 科学观察, 2020, 15(1): 22-29.
- [8] 张梦涵,魏进,卞海丁. 基于机器学习的边坡稳定性分析方法—以国内 618 个边坡为例[J]. 地球科学与环境学报, 2022, 44(6): 1083-1095.

- [9] 杨玲, 魏静, 许子伏. 基于平滑先验法-麻雀搜索算法-支持向量机回归模型的滑坡位移预测——以三峡库区八字门和白水河滑坡为例[J]. 地球科学与环境学报, 2022, 44(6): 1096-1110.
- [10] 黄兴友, 马玉蓉, 胡苏蔓. 基于深度学习的天气雷达回波序列外推及效果分析[J]. 气象学报, 2021, 79(5): 817-827.
- [11] 唐伟, 周勇, 董昊, 等. S22-气象应用人工智能的现状和影响分析[C]//中国气象学会年会. 第35届中国气象学会年会 S22 供给侧结构性改革与气象高质量发展. 2018.
- [12] SHI X J, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [C]//Advances in Neural Information Processing Systems. 2015: 802-810.
- [13] RAVURI S, LENC K, WILLSON M, et al. Skilful precipitation nowcasting using deep generative models of radar [J]. Nature, 2021: 672-677.
- [14] 方巍, 齐媚涵. 基于深度学习的高时空分辨率降水临近预报方法[J]. 地球科学与环境学报, 2023, 45(3): 706-718.
- [15] HE K M, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition. 2016.
- [16] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]//International Conference on Medical image computing and computer-assisted intervention. 2015.
- [17] HAN L, CHEN M X, CHEN K K, et al. A deep learning method for bias correction of ECMWF 24-240 h forecasts [J]. Advances in Atmospheric Sciences, 2021, 38(9): 1444-1459.
- [18] 张延彪, 陈明轩, 韩雷, 等. 数值天气预报多要素深度学习融合订正方法[J]. 气象学报, 2022, 80(1): 153-167.
- [19] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997: 1735-1780.
- [20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]// Advances in Neural Information Processing Systems. 2017.
- [21] WANG Y B, LONG M S, WANG J M, et al. Predrnn: Recurrent neural networks for predictive learning using spatiotemporal lstms [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems (NeurIPS). 2017.
- [22] WANG Y B, GAO Z F, LONG M S, et al. PredRNN++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning [C]//Proceedings of the 35th International Conference on Machine Learning. 2018.
- [23] GOODFELLOW I J, POUGET-ABADIE J P, MIRZA M, et al. Generative adversarial nets [C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. 2014.
- [24] WANG X T, YU K, WU S X, et al. ESRGAN: Enhanced super-resolution generative adversarial networks [C]//Proceedings of the 15th European Conference on Computer Vision. 2018.
- [25] WHITE B L, SINGH A, ALBERT A. Downscaling numerical weather models with GANs [C]//Proceedings of the 9th International Workshop on Climate Informatics. 2019.
- [26] JING J R, LI Q, PENG X, et al. HPRNN: A hierarchical sequence prediction model for long-term weather radar echo extrapolation [C]//IEEE International Conference on Acoustics, Speech, and Signal Processing. 2020.
- [27] SHI X J, GAO Z H, LAUSEN L, et al. Deep learning for precipitation nowcasting: A benchmark and a new model [C]//Conference on Neural Information Processing Systems. 2015.
- [28] 吴昆, 申妍燕, 王书强. 基于3D卷积神经网络的区域降雨量预报[J]. 图像与信号处理, 2018, 7(4): 200-212.
- [29] ZAMO M, BEL L, MESTRE O. Sequential aggregation of probabilistic forecasts — application to wind speed ensemble forecasts [J]. Journal of the Royal Statistical Society Series C—applied Statistics, 2021: 202-225.
- [30] SONDERBY C K, ESPEHOLT L, HEEK J, et al. MetNet: A neural weather model for precipitation forecasting [J/OL]. 2020.
- [31] AYZEL G, SCHEFFER T, HEISTERMANN M. RainNet v1.0: a convolutional neural network for radar-based precipitation nowcasting [J]. Geoscientific Model Development, 2020, 13(6): 2631-2644.
- [32] 周康辉, 郑永光, 韩雷, 等. 机器学习在强对流监测预报中的应用进展[J]. 气象, 2021, 47(3): 274-289.
- [33] 董琪如, 邱晓滨, 王莹, 等. 循环同化雷达资料对一次飑线系统临近预报的改进作用[J]. 气象与环境学报, 2021, 37(3): 1-11.
- [34] 郑永光, 周康辉, 盛杰, 等. 强对流天气监测预报预警技术进展[J]. 应用气象学报, 2015, 26(6): 641-657.
- [35] 孙继松, 戴建华, 何立富, 等. 强对流天气预报的基本原理与技术方法[M]. 北京: 气象出版社, 2014.
- [36] 王丹, 王改利, 刘黎平, 等. 基于雷达回波外推和中尺度模式预报的短时降水对比分析[J]. 高原气象, 2014, 33(3): 811-822.

- [37] 龙清怡, 刘海文, 顾建峰, 等. 雷达资料与中尺度数值预报的融合方法研究及其在临近预报中的应用[J]. 气象, 2014, 40(10): 1248–1258.
- [38] 顾建峰, 周国兵, 刘伯骏, 等. 人工智能技术在重庆临近预报业务中的初步研究与应用[J]. 气象, 2020, 46(10): 1286–1296.
- [39] 张亚萍, 张焱, 翟丹华, 等. 深度学习方法在强降水临近预报技术中的应用及其改进思考[J]. 暴雨灾害, 2022, 41(5): 506–514.
- [40] AGRAWAL S, BARRINGTON L, BROMBERG C, et al. Machine learning for precipitation nowcasting from radar Images[J/OL]. 2019.
- [41] 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.
- [42] 曹伟华, 南刚强, 陈明轩, 等. 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, 2022, 80(4): 546–564.
- [43] 胡家晖, 卢楚翰, 姜有山, 等. 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, 2022, 46(4): 805–818.
- [44] CAO Y, CHEN L, ZHANG D C, et al. Hybrid weighting loss for precipitation nowcasting from radar images [C]// IEEE International Conference on Acoustics, Speech, and Signal Processing. 2022.
- [45] 夏侯杰, 肖安, 聂道洋. 基于观测的短时强降水深度学习预报模型[J]. 高原气象, 2023, 42(4): 1005–1017.
- [46] 林青, 潘宁, 刘铭. 光流法以及结合机器学习在临近预报中的应用[J]. 海峡科学, 2017(12): 17–20.
- [47] WOO W C, WONG W K. Operational application of optical flow techniques to radar-based rainfall nowcasting[J]. Atmosphere, 2017.
- [48] 张智察, 罗玲, 陈列, 等. 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, 2022, 48(11): 1361–1372.
- [49] WANG Y B, WU H X, ZHANG J J, et al. PredRNN: A recurrent neural network for spatiotemporal predictive learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(2): 2208–2225.
- [50] 杨绚, 代刊, 朱跃建. 深度学习技术在智能网格天气预报中的应用进展与挑战[J]. 气象学报, 2022, 80(5): 649–667.
- [51] 马雷鸣, 林红, 储海, 等. 上海强对流智能预报业务新技术研究进展[J]. 地球科学进展, 2023, 38(2): 111–124.
- [52] 马雷鸣. 天气预报中的人工智能技术进展[J]. 地球科学进展, 2020, 35(6): 551–560.
- [53] 李扬, 刘玉宝, 许小峰. 基于深度学习改进数值天气预报模式和预报的研究及挑战[J]. 气象科技进展, 2021, 11(3): 103–112.
- [54] GEER A J. Learning earth system models from observations: Machine learning or data assimilation? [J]. Philosophical Transactions of The Royal Society. Mathematical, Physical and Engineering Sciences, 2021.
- [55] CINTRA R, VELHO H F D C. Data assimilation by artificial neural networks for an atmospheric general circulation model[M]. 2018.
- [56] BRAJARD J, CARASSI A, BOCQUET M, et al. Combining data assimilation and machine learning to emulate a dynamical model from sparse and noisy observations: a case study with the Lorenz 96 model[J]. Journal of Computational Science, 2020.
- [57] PEYRON M, FILLION A, GUROL S, et al. Latent space data assimilation by using deep learning [J]. Quarterly Journal of the Royal Meteorological Society, 2021, 147(740): 3759–3777.
- [58] STENSRUD D J. Parameterization Schemes: Keys to understanding numerical weather prediction models [M]. Cambridge: Cambridge University Press, 2007.
- [59] SCHNEIDER T, TEIXEIRA J, BRETHERTON C S, et al. Climate goals and computing the future of clouds [J]. Nature Climate Change, 2017.
- [60] PAL A, MAHAJAN S, NORMAN M R. Using deep neural networks as cost-effective surrogate models for superparameterized E3SM radiative Transfer [J]. Geophysical Research Letters, 2019, 46(11): 6069–6079.
- [61] WANG J L, BALAPRAKASH P, KOTAMARTHI R. Fast domain-aware neural network emulation of a planetary boundary layer parameterization in a numerical weather forecast model [J]. Geoscientific Model Development, 2019.
- [62] SCHER S. Toward data-driven weather and climate forecasting: Approximating a simple general circulation model with deep learning [J]. Geophysical Research Letters, 2018.
- [63] RASP S, PRITCHARD M S, GENTINE P, et al. Deep learning to represent subgrid processes in climate models [J]. Proceedings of the National Academy of Sciences of the United States of America, 2018, 115(39): 9684–9689.
- [64] BRENOWITZ N D, BRETHERTON C S. Spatially extended tests of a neural network parametrization trained by coarse-graining [J]. Journal of Advances in Modeling Earth Systems, 2019, 11(8): 2728–2744.
- [65] SCHAUMANN P, HESS R, REMPEL M, et al. A cali-

- brated and consistent combination of probabilistic forecasts for the exceedance of several precipitation thresholds using neural networks [J]. *Weather and Forecasting*, 2021, 36(3): 1079–1096.
- [66] LIU Y Q, ZHANG J P, CHEN L, et al. SSAS: Spatiotemporal scale adaptive selection for improving bias correction on precipitation [J]. *IEEE Transactions on Cybernetics*, 2022, 52(11): 12175–12188.
- [67] 陈锦鹏, 冯业荣, 蒙伟光, 等. 基于卷积神经网络的逐时降水预报订正方法研究[J]. *气象*, 2021, 47(1): 60–70.
- [68] SAYEED A, CHOI Y, JUNG J, et al. A deep convolutional neural network model for improving WRF simulations [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(2): 750–760.
- [69] GHAZVINIAN M, ZHANG Y, SEO D J, et al. A novel hybrid artificial neural network-parametric scheme for post-processing medium-range precipitation Forecasts [J]. *Advances in Water Resources*, 2021.
- [70] SCHEUERER M, SWITANEK M B, WORSNOP R P, et al. Using artificial neural networks for generating probabilistic subseasonal precipitation forecasts over california [J]. *Monthly weather review*, 2020, 148(8): 3489–3506.
- [71] MISRA S, SARKAR S, MITRA P. Statistical downscaling of precipitation using long short-term memory recurrent neural networks[J]. *Theoretical and Applied Climatology*, 2018, 134(3/4): 1179–1196.
- [72] PAN B X, HSU K, AGHAKOUCHAK A, et al. Improving precipitation estimation using convolutional neural network [J]. *Water Resources Research*, 2019, 55 (3): 2301–2321.
- [73] BANO-MEDINA J, MANZANAS R, GUTIERREZ J M. Configuration and intercomparison of deep learning neural models for statistical downscaling[J]. *Geoscientific Model Development*, 2020, 13(4): 2109–2124.
- [74] KUMAR B, CHATTOPADHYAY R, SINGH M, et al. Deep learning-based downscaling of summer monsoon rainfall data over Indian region [J]. *Theoretical and Applied Climatology*, 2021, 143(3/4): 1145–1156.
- [75] SHA Y K, GAGNE II D J, WEST G, et al. Deep-learning-based gridded downscaling of surface meteorological variables in complex terrain. Part I : Daily maximum and minimum 2-m temperature [J]. *Journal of Applied Meteorology and Climatology*, 2020, 59(12): 2057–2073.
- [76] SHA Y K, GAGNE D J II, WEST G, et al. Deep-learning-based gridded downscaling of surface meteorological variables in complex terrain. Part II : Daily precipitation [J]. *Journal of Applied Meteorology and Climatology*, 2020, 59 (12): 2075–2092.
- [77] SHA Y K, GAGNE II D J, WEST G, et al. A hybrid analog-ensemble-convolutional-neural-network method for post-processing precipitation forecasts [J]. *Monthly Weather Review*, 2022.
- [78] LEINONEN J, NERINI D, BERNE A. Stochastic super-resolution for downscaling time-evolving atmospheric fields with a generative adversarial network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7211–7223.
- [79] PRICE I, RASP S. Increasing the accuracy and resolution of precipitation forecasts using deep generative models [C]//*International Conference on Artificial Intelligence and Statistics*. 2022.
- [80] HERNANDEZ E, SANCHEZ-ANGUIX V, JULIAN V, et al. Rainfall prediction: A deep learning approach [C]//*Proceedings of the 11th International Conference on Hybrid Artificial Intelligence Systems*. 2016.
- [81] 张鹏程, 张雷, 王继民. 一种基于深度网络的多环境因素降水量预报模型[J]. *计算机应用与软件*, 2017, 34 (9): 241–245, 261.
- [82] PATHAK J, SUBRAMANIAN S, HARRINGTON P, et al. FourCastNet: A global data-driven high-resolution weather model using adaptive fourier neural operators [J/OL]. 2022.
- [83] 周佩, 黄颖婕, 胡冰逸, 等. 基于 LSTM 深度学习的 ENSO 预测及其春季预报障碍研究[J]. *北京大学学报 (自然科学版)*, 2021, 57(6): 1071–1078.
- [84] 张星, 关悦, 党鑫鑫, 等. 基于遗传算法-长短期记忆神经网络的月降水量预测研究[C]//2021年(第七届)全国大学生统计建模大赛获奖论文集(二). 2023.
- [85] HAM Y G, KIM J H, LUO J J. Deep learning for multi-year ENSO forecasts[J]. *Nature*, 2019.
- [86] 潘乐, 郑子华, 游立军, 等. 基于改进 U-Net 模型的次季节降水预报订正[J]. *福建师范大学学报 (自然科学版)*, 2023, 39(6): 63–71, 92.
- [87] 张丽婷, 李鹏飞, 庞文静, 等. 基于季节性自回归积分滑动平均与深度学习长短期记忆神经网络的降水量预测[J]. *科学技术与工程*, 2022, 22(9): 3453–3463.
- [88] WANG X, HAN Y, XUE W, et al. Stable climate simulations using a realistic GCM with neural network parameterizations for atmospheric moist physics and radiation processes[J]. *Geoscientific Model Development*, 2021.
- [89] 金荣花, 代刊, 赵瑞霞, 等. 我国无缝隙精细化网格天气预报技术进展与挑战[J]. *气象*, 2019, 45(4): 445–

- 457.
- [90] ZHOU K H, ZHENG Y G, LI B, et al. Forecasting different types of convective weather: A deep learning approach [J]. *Journal of Meteorological Research*, 2019.
- [91] 张小玲, 杨波, 盛杰, 等. 中国强对流天气预报业务发展[J]. *气象科技进展*, 2018, 8(3): 8–18.
- [92] 孙健, 曹卓, 李恒, 等. 人工智能技术在数值天气预报中的应用[J]. *应用气象学报*, 2021, 32(1): 1–11.
- [93] 唐伟, 周勇, 董昊, 等. 我国气象领域应用人工智能技术的现状和国际对比[J]. *气象科技进展*, 2019, 9(5): 55–56, 62.
- [94] BI K F, XIE L X, ZHANG H H, et al. Accurate medium-range global weather forecasting with 3D neural networks [J]. *Nature*, 2023.
- [95] ZHANG Y C, LONG M S, CHEN K Y, et al. Skilful nowcasting of extreme precipitation with nowcastnet [J]. *Nature*, 2023.
- [96] WILLARD J, JIA X, XU S, et al. Integrating physics-based modeling with machine learning: A survey [J]. *ACM Computing Surveys*, 2021, 55(4): 1–37.
- [97] 庄潇然, 郑玉, 王亚强, 等. 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*, 2023, 81(2): 286–303.

## Research and application progress of deep learning in precipitation forecasting

FAN Jiao<sup>1,2</sup>, ZENG Xiaotuan<sup>1\*</sup>, HUANG Rongcheng<sup>1</sup>, HUANG Zengjun<sup>2</sup>

(1. Guangxi Meteorological Observatory, Nanning 530022, China; 2. Nanning Meteorological Bureau, Nanning 530029, China)

**Abstract:** This article summarizes the characteristics of commonly used deep learning algorithms in the meteorological field, as well as the exploration results of pure data-driven deep learning precipitation forecasting technology and deep learning coupled with numerical weather forecasting technology in near, medium-short-term, and extended period precipitation forecasting. At the same time, a brief review is made on the application of deep learning in meteorological operational forecasting. The advantages and disadvantages of traditional deep learning algorithms are different. In practical applications, it is necessary to choose appropriate models and methods based on specific meteorological data characteristics and business needs. In terms of proximity prediction, deep learning algorithms are often used to establish precipitation prediction models for extracting spatial features and analyzing temporal evolution of heavy precipitation cloud clusters; Long time series (medium to short term, extended period) precipitation forecasting mainly optimizes the numerical model precipitation forecasting effect through initial field data assimilation, model improvement, and model prediction post-processing. At present, meteorological departments in various regions have applied deep learning algorithms in business forecasting. In the future, specific problems still need to be addressed, a large amount of related work needs to be carried out to further promote the development of precipitation forecasting.

**Key words:** deep learning; precipitation forecast; numerical weather forecasting; modes coupling