

栗哈,马蕴琦,代刊,等,2026.基于 3D-Unet 的多模式融合定量降水预报技术研究[J].气象,52(10):1202-1217. Li H, Ma Y Q, Dai K, et al, 2026. Multi-model fusion for quantitative precipitation forecasting based on 3D-Unet[J]. Meteor Mon, 52(10): 1202-1217(in Chinese).

基于 3D-Unet 的多模式融合定量降水预报技术研究*

栗 哈^{1,2} 马蕴琦^{1,2} 代 刊³ 张 霞^{1,2}

1 河南省气象台,郑州 450003

2 中国气象局·河南省农业气象保障与应用技术重点开放实验室,郑州 450003

3 国家气象中心,北京 100081

提 要: 基于 3D-Unet 深度学习模型及 ECMWF-IFS 全球模式(简称 EC)、CMA-SH9 区域模式预报产品,研发了多模式融合定量降水预报技术,并引入综合梯度(IG)方法增强模型可解释性。结果表明:3D-Unet 能够有效提升模式原始降水预报性能,且多模式融合深度学习预报模型(DL)对于 $5\text{ mm} \cdot \text{h}^{-1}$ 降水预报 TS 评分明显优于单模式订正模型。实时业务检验结果表明,DL 降水预报性能显著优于原始模式和传统最优权重融合方法(OFM), $5\text{ mm} \cdot \text{h}^{-1}$ 和 $10\text{ mm} \cdot \text{h}^{-1}$ 量级 TS 评分较 OFM 分别提高了约 70.3% 和 26.5%。24 h 累计降水量预报检验结果显示,DL 对中雨、大雨、暴雨量级的 TS 评分均优于单一模式和 OFM 产品;尤其在 60 h 和 72 h 的较长预报时效,其对暴雨的 TS 评分较 EC 分别提高了约 42.7% 和 24.3%。DL 能够有效订正模式原始预报较大尺度雨带的形态和位置误差,但对局地极端强降水存在范围偏大的倾向。采用 IG 算法分析特征因子重要性发现,DL 能够识别不同模式中相同因子的作用差异,CMA-SH9 中与边界层过程和局地动力热力结构相关的因子(如 CAPE 和近地层风场)具有更高的重要性,而 EC 中与天气尺度环流背景和气团热力状态相关的因子(如地面气压和 2 m 气温)贡献更为突出。

关键词: 3D-Unet 深度学习模型,多模式融合,时空特征,可解释性,降水预报订正

中图分类号: P456

文献标志码: A

DOI: 10.7519/j.issn.1000-0526.2026.072201

Multi-Model Fusion for Quantitative Precipitation Forecasting Based on 3D-Unet

LI Han^{1,2} MA Yunqi^{1,2} DAI Kan³ ZHANG Xia^{1,2}

1 Henan Meteorological Observatory, Zhengzhou 450003

2 Henan Key Laboratory of Agrometeorological Support and Applied Technology, CMA, Zhengzhou 450003

3 National Meteorological Centre, Beijing 100081

Abstract: This study develops a multi-model fusion quantitative precipitation forecast technique based on the 3D-Unet deep learning model and forecast products from the ECMWF-IFS global model (abbreviated as EC) and the CMA-SH9 regional model, and introduces the integrated gradient (IG) method to enhance model interpretability. The results indicate that the 3D-Unet can effectively improve the performance of raw precipitation forecasts, and the multi-model fusion deep learning model (DL) significantly outperforms the single-model correction model in terms of the TS score for $5\text{ mm} \cdot \text{h}^{-1}$ precipitation. Real-time operational verification shows that the DL can produce substantially better precipitation forecasts than both the original model and the traditional optimal fusion method (OFM). Compared with that of OFM, the TS

* 国家重点研发计划(2023YFC3209301)、河南省科技攻关计划(252102320025)、中国气象局气象能力提升联合研究专项(24NLTSZ004)和全国暴雨研究开放基金(BYKJ2024Q14)共同资助

2025 年 11 月 25 日收稿; 2026 年 7 月 22 日收修定稿

第一作者:栗哈,主要从事暴雨机理分析和智能预报技术研究. E-mail: hanli_1005@163.com

scores of precipitation forecasts of the DL model at the $5 \text{ mm} \cdot \text{h}^{-1}$ and $10 \text{ mm} \cdot \text{h}^{-1}$ thresholds are improved by approximately 70.3% and 26.5%, respectively. For the 24 h accumulated precipitation, the DL forecast achieves higher TS scores than a single model and OFM products for moderate rain, heavy rain and torrential rain categories. In particular, relative to that of the EC, at the longer lead time of 60 h and 72 h, TS scores of the DL for torrential rain forecasts are improved by about 42.7% and 24.3%, respectively. The DL can effectively correct the morphology and location errors of large-scale rain belts in raw forecasts, but it tends to overestimate the spatial extent of local extreme heavy precipitation. Feature importance analysis with the IG algorithm reveals that the DL can distinguish the different roles of the same factors in different models. Factors related to boundary layer processes and local dynamic-thermodynamic structures (e. g., CAPE and near-surface wind) possess higher importance in the CMA-SH9, while factors associated with synoptic-scale circulation background and air mass thermal state (e. g., surface pressure and 2 m temperature) contribute more prominently in the EC.

Key words: 3D-Unet deep learning model, multi-model fusion, spatio-temporal characteristic, interpretability, precipitation forecast correction

引 言

数值天气预报是现代天气预报的基础,主导着定量降水预报(QPF)业务水平的提高(李泽椿等,2019;湛芸等,2021)。近年来,区域高分辨率数值预报业务迅速发展(徐同等,2019;黄丽萍等,2022)——空间分辨率细至千米级、时间分辨率达到小时级的模式相继投入业务并发挥作用(陈昊明等,2021;刘静等,2022)。但数值模式仍难以准确预报每一个中小尺度对流过程,小时降水的可预报性仍然较低(姚秀萍和李若莹,2023)。

由于模式预报长期存在初始场不确定性、边界条件误差、动力框架和物理参数化局限等导致的系统偏差,在模式降水预报基础上结合统计客观方法进行偏差订正成为提高降水预报准确率的重要途径(杨绚等,2022;沈文强等,2023)。例如,最优 TS 评分、频率匹配等方法(吴启树等,2017;Zhu and Luo, 2015;智协飞和吕游,2019;高星星等,2023;刘会军等,2024)可以通过订正模式降水预报量级或落区范围进而改善 TS 评分。进一步结合集合预报或多模式预报信息能够一定程度上改进模式原始降水落区预报效果(代刊等,2018;Snook et al, 2020;张华龙等,2022)。总体而言,这些技术虽可提高降水预报水平,但大多仍主要依赖模式自身的降水预报结果,未充分利用模式预报的风场、温度、湿度等多源气象要素信息,因而订正效果很大程度上受制于模式原始降水预报性能。

随着近年来人工智能在气象领域的快速发展,深度学习凭借其非线性映射能力和对时空多维气象信息的特征提取能力,已成为提高降水预报准确率的新途径之一(杨绚等,2022;蒋鸿儒和方巍,2024)。在数值模式降水后处理领域,卷积神经网络(CNN)、U-Net 及其三维扩展结构(3D-Unet)因其在处理空间-时间复杂维度特征建模方面的优势,逐渐成为主流模型框架(陈锦鹏等,2021;Liu et al, 2023;周莉等,2024;曾小团等,2025;张亚萍等,2025)。已有研究表明,基于 3D-Unet 融合温度、风、湿度、位势高度等多层次气象要素,可显著提升不同等级的定量降水预报技巧(Zhou et al, 2022;熊文睿等,2025)。相较于二维模型,3D-Unet 能够更好地处理降水相关气象要素的多维度特征,有助于刻画降水演变过程的连续性与动态特征,在小时和累计降水量预报中均展现出潜力。

另外,单一数值模式难以全面刻画复杂大气过程,不同模式在动力框架、物理参数化及资料同化方案等方面存在显著差异,通过联合利用多模式预报信息,可进一步提升降水预报的稳定性和泛化能力(Tang et al, 2022; Fang et al, 2023)。然而,现有研究多聚焦于单一时间尺度(如仅小时或仅 24 h 累计降水量),尚缺乏在统一框架下同时评估小时降水细节与 24 h 累计降水量表现的研究;同时,对多模式、多要素融合建模过程中各类气象因子作用机制的分析也相对缺乏。

此外,深度学习模型在降水预报中的应用仍面临物理可解释性不足的问题。为缓解“黑箱”特性带

来的不确定性,近年来可解释人工智能方法逐渐被引入气象研究领域(Başagaoglu et al, 2022; Mu et al, 2024)。其中,积分梯度(IG)作为一种基于梯度归因的解释方法,具有理论完备、实现简单且适用于复杂深度网络结构等优点(Sundararajan et al, 2017; Mamalakis et al, 2022)。通过 IG 方法可以定量评估不同输入气象要素在模型预测中的相对贡献,为理解深度学习模型提取的物理信息及其作用路径提供参考。

鉴于此,本文以 3D-Unet 深度学习模型为核心框架,在输入端融合二维空间和一维时间维度的多层次气象要素,构建融合不同模式、多特征因子的降水预报订正模型,并评估其对小时降水量和 24 h 累计降水量两类不同尺度降水预报的改进效果。同时,通过引入 IG 方法对模型特征因子的重要性进行评估,尝试对深度学习模型中关键气象因子的贡献及其物理作用机制进行解释,以期在深度学习在多模式融合降水预报领域的应用提供新思路。

1 数 据

选取欧洲中心 ECMWF-IFS 全球模式(以下简称 EC)和中国气象局 CMA-SH9 区域模式(以下简称 CMA-SH9)2019—2023 年的预报产品作为深度学习模型(DL)和最优权重融合方法(OFM)的输入数据。两个模式涵盖高空和地面多层次基本气象要素(风场、温度、湿度等)以及模式自身的定量降水预报(小时降水量和 24 h 累计降水量)。EC 在大尺度环流演变和长时效预报方面性能较为稳定;CMA-SH9 对中小尺度对流降水过程的捕捉能力较强,但也更容易受局地热力、动力过程影响出现预报偏差,

两家模式水平分辨率均为 $0.1^\circ(9\text{ km})$ 。已有研究表明,EC 对强对流性降水往往预报偏弱(干偏差),但在较长预报时效上保持一定优势,而 CMA-SH9 模式对短时强降水更敏感(命中率高),但易出现降水偏强、偏多的倾向(湿偏差)(陈昊明等, 2025; 徐同等, 2025)。本文尝试利用两家模式各自优势,通过深度学习模型实现互补。

本研究采用国家气象信息中心提供的地面-卫星-雷达融合逐小时降水分析产品(CMPA_Hourly V2.1)作为 DL 训练时的降水真值(潘旻等, 2018)。该资料时间分辨率为 1 h,空间分辨率为 $0.05^\circ(5\text{ km})$,能够较准确地反映降水的时空演变特征。在独立检验阶段,为更贴近业务预报检验方式,选取 2023 年河南 1618 个国家级和区域级自动气象观测站的逐小时降水量观测资料作为实况。文中所用时间均为北京时。

2 研究方法

2.1 深度学习模型数据预处理

深度学习模型输入特征因子如表 1 所示。采用双线性插值将 EC 和 CMA-SH9 降水预报产品空间分辨率统一为 0.05° 。研究目标区域为 $31.25^\circ\sim 36.5^\circ\text{N}$ 、 $110.2^\circ\sim 116.75^\circ\text{E}$,网格大小为 132×106 。采用 2019—2021 年汛期(5—9 月)数据作为 DL 训练集;为了更好地评估模型对主汛期强降水预报的泛化能力,将 2022 年 5—6 月作为验证集,7—9 月作为测试集,模型的最终有效性由 2023 年 6—9 月的业务运行检验结果加以验证。

表 1 深度学习模型中输入的特征因子

Table 1 Feature variables input to the deep learning model

模式	特征因子	高度
EC	温度、湿度、纬向风、经向风	200、500、850、1000 hPa
	降水量、10 m 纬向风、10 m 经向风、2 m 温度、地面气压、海平面气压、整层可降水量、对流有效位能	
CMA-SH9	降水量、组合反射率、10 m 纬向风、10 m 经向风、2 m 温度、地面气压、对流有效位能、对流抑制能量、2 m 湿度	

由于降水样本具有典型的偏态分布特征,需筛选有效降水训练样本。当最大降水阈值 $\geq 20\text{ mm}\cdot\text{h}^{-1}$ 或有效降水($\geq 0.1\text{ mm}\cdot\text{h}^{-1}$)格点数 >800 个,

判定为有效样本并用于构建模型训练数据集,同时对各输入特征因子进行最大值和最小值归一化处理,消除量级差异。

卷积类深度学习模型的定量降水预报易出现空间落区平滑、强降水预报偏弱,针对这一现象,本文采用传统频率订正和时间拆分方法对 DL 输出降水预报产品进行后处理,并与 DL 原始预报进行对比,具体步骤如下:(1)采用 30 d 滑动训练期对 DL 预报逐小时降水量和 24 h 累计降水量分别进行频率订正;(2)基于订正后产品逐格点构建 24 h 内逐小时降水量的时间变化曲线,基于该变化曲线对偏差订正后的 24 h 累计降水量在逐个格点上按照比例重新分配至 1 h,得到新的逐小时降水量预报(DL-P)。

2.2 3D-Unet 深度学习模型架构

3D-Unet 最早由 Çiçek et al(2016)提出,其具有多维度数据特征提取能力,能够更有效捕捉与降水有关气象要素的时空多维度特征间的复杂演变关系,从而更好地订正模式降水预报。不同于以往以气象要素单一层次和平面分布作为三维空间数据特征的研究,为了更好地再现逐小时降水的时空演变特征,本文将 3D-Unet 的三维数据特征定义为二维平面及一维时间,即将模式预报的高空、地面等不同高度的气象要素作为特征因子,将所有因子的 0~72 h 时效逐小时一维时间演变和二维空间分布共三维数据特征作为输入,以格点实况降水场作为真值进行模型训练,最终输出 0~72 h 时效逐小时降水量预报。

本文构建的 DL 结构如图 1 所示,该模型由编

码器和解码器组成,编码器用于提取输入降水数据的特征,而解码器用于将提取的特征重建为订正后的降水预报结果。模型通过多层卷积和池化操作实现特征提取,同时利用反卷积和上采样操作进行特征重建。针对定量降水预报回归问题,模型采用了加权 L1 损失(即加权平均绝对误差)作为损失函数,通过设置不同量级小时降水样本权重(表 2),增强模型训练过程中对于较强量级降水的关注度。

模型训练过程中,采用 4 张 NVIDIA RTX 3090 显卡,使用 Adam 优化器(学习率 1.0×10^{-4} ,权重衰减 1.0×10^{-5}),单卡批次大小为 4,共设置 100 个迭代周期,采用早停策略,当基于独立验证集的评估结果显示模型预测 $\geq 0.1 \text{ mm} \cdot \text{h}^{-1}$ 降水 TS 评分连续 10 个迭代周期停止增长时则自动停止,并保存当前模型作为最优权重。模型推理测试结果表明,在 0.05° 分辨率上,单次覆盖河南区域的预报可在 2 min 内完成,可以满足业务化应用要求。

2.3 多模式最优权重融合方法

在单一模式 24 h 累计降水量预报强度订正的基础上,利用滑动训练期内各模式订正后降水预报产品动态评估,确定权重系数得到 OFM 降水预报产品。具体步骤如下:(1)采用 1 年期的准对称滑动训练期(当年预报日之前和上年预报日之后各 30 d,下同)建立 EC、CMA-SH9 降水预报频率订正模型,得到相应的降水强度订正产品;(2)基于训练期




图 1 3D-Unet 深度学习模型结构示意图

Fig. 1 Schematic diagram of the 3D-Unet deep learning model architecture

表 2 不同量级小时降水量对应的权重

Table 2 Weights for different hourly precipitation levels

量级/mm	0~1.0	1.0~2.5	2.5~5.0	5.0~10.0	10.0~20.0	≥ 20.0
权重系数	1	1	2.5	5	10	20

各模式分级降水预报 TS 评分确定权重系数,得到基础权重融合降水预报产品;(3)采用概率匹配算法将两家模式降水强度订正产品在基础权重融合降水预报产品空间格点上分别进行降水落区重构;(4)对重构产品在训练期内计算分级降水 TS 评分,并在每个分级区间内进行产品分级优选拼接形成最终的 OFM 产品。上述方案中 24 h 累计降水量分级阈值均为 0.1、10、25、50、70、100 mm。

为了与 DL 进行小时降水量预报对比,将 OFM 的 24 h 累计降水量按照 CMA-SH9 小时降水量预报时间变化曲线进行逐个格点拆分,保证 24 h 累计降水量不变。

2.4 模型评估方法

模型评估指标包括 TS 评分、Bias 评分、空报率 (FAR)、命中率 (POD) (陈昊明等, 2025; 徐同等, 2025)。此外,本文采用空间邻域检验 (FSS) 法评估各产品在不同空间尺度上的预报性能 (Mittermaier and Roberts, 2010; 王新敏和栗晗, 2020)。因数值模式预报产品到达业务平台均存在时间滞后,为符合实际预报业务需求,本文评估的降水预报产品时效均为 13~72 h。

2.5 因子敏感性分析方法

作为数据驱动的非线性模型,DL 本质上仍是一个“黑箱模型”,难以明确其在降水预报订正中的物理机制。本文尝试采用 IG 算法评估 DL 中不同特征因子的重要性,进而对模型预测因子进行敏感性分析。该方法通过将输入特征从基线平滑过渡到当前值,计算模型输出对每个特征的梯度贡献,从而得出每个特征对输出结果的影响。特征重要性结果以每个输入通道的归一化值呈现,表示其对模型预测目标的相对贡献。

3 不同建模方案小时降水量预报评估

为验证 3D-Unet 深度学习模型在多模式融合应用方面的能力,基于 2022 年 7—9 月测试集设计了 3 组试验,并与模式原始预报进行对比。其中 DL-EC、DL-SH9 分别为基于 EC 和 CMA-SH9 单模式物理因子作为输入特征的模型预报结果,DL 则是将两个模式全部物理因子作为输入特征的预报结果,物理因子的选择参照表 1。0.1 mm·h⁻¹ 和 2 mm·h⁻¹ 的较弱降水量级 TS 评分显示 (图 2a, 2b),




图 2 2022 年 7 月 1 日 08 时至 9 月 30 日 20 时 13~72 h 时效不同量级小时降水量 TS 评分

Fig. 2 TS scores of hourly precipitation forecasts at different levels with 13–72 h lead times from 08:00 BT 1 July to 20:00 BT 30 September 2022

经过 DL 订正后的 DL-EC、DL-SH9 均明显优于两家模式原始预报结果,但融合两个模式的 DL 则与 DL-EC 基本相当。对于 $5 \text{ mm} \cdot \text{h}^{-1}$ 中等量级降水, DL 模型在较多时效上均表现出明显优势(图 2c), 13~72 h 时效 TS 评分为 0.078, 高于 DL-SH9 的 0.056 和 DL-EC 的 0.036。对于 $10 \text{ mm} \cdot \text{h}^{-1}$ 的较强量级降水(图 2d), CMA-SH9、DL-SH9 和 DL 的 TS 评分均在 0.02 左右, 预报性能接近; DL-EC 均为 0。总体来看, 相较于单一模式建模, DL 更好地提升了中等量级小时降水的预报能力, 同时对于较弱和较强小时降水预报性能则与最优单模式订正模型相当。下文将基于实际业务应用对 DL 展开系统评估, 以考察其不同降水过程中的适用性与泛化能力。

4 2023 年 6—9 月总体预报结果评估

4.1 小时降水量预报评估

由图 3 可见, OFM 在 0.1 、 5 和 $10 \text{ mm} \cdot \text{h}^{-1}$ 量级预报的 TS 评分均优于两家模式原始预报, 且对于 $10 \text{ mm} \cdot \text{h}^{-1}$ 以上量级降水较好地控制了 Bias 评分, 明显改善了 CMA-SH9 的湿偏差, 但 $2 \text{ mm} \cdot \text{h}^{-1}$ 和 $20 \text{ mm} \cdot \text{h}^{-1}$ 量级 TS 评分均低于 EC 原始预报。DL 在 $0.1 \sim 10 \text{ mm} \cdot \text{h}^{-1}$ 量级均展示出相较于模式原始预报或 OFM 的明显优势, $5 \text{ mm} \cdot \text{h}^{-1}$ 和 $10 \text{ mm} \cdot \text{h}^{-1}$ 量级 TS 评分较 OFM 分别提升 70.3% (由 0.074 提升至 0.126)、26.5% (由 0.034 提升至 0.043)。从 Bias 评分来看, DL 也表现出了类似于 EC 的特点, 如 $5 \text{ mm} \cdot \text{h}^{-1}$ 及以下量级存在湿偏差, 更强量级则存在明显干偏差。订正后的 DL-P 在

Bias 评分上有明显改善, 尽管由于湿偏差减少导致了命中率下降进而降低了弱降水的 TS 评分, 但 $20 \text{ mm} \cdot \text{h}^{-1}$ 量级降水预报能力有所提升。综上, 传统 OFM 算法虽然能够较原始模式改进小时降水量预报, 但改进幅度有限, DL 算法融合更多模式预报信息, 可大幅度提升模式小时降水量预报能力, 但对于小时强降水预报仍存在弱报。

4.2 24 h 累计降水量预报评估

相较于模式原始预报, OFM 的优势集中在暴雨以上量级, 且对 CMA-SH9 暴雨以上量级存在的明显湿偏差现象也有所改善(图 4)。仅从 TS 评分来看, DL 在不同预报时效、各个预报量级均优于模式原始预报以及 OFM。以暴雨量级为例, 对于 60 h 和 72 h 预报时效, DL 仍较 EC 分别提高 42.7% (由 0.206 提升至 0.294)、24.3% (由 0.222 提升至 0.276), 这表明尽管本文构建的 DL 输入特征为小时尺度气象信息, 但其不仅有效订正了小时降水量预报, 同时也提升了时段累计降水量的预报效果。但 DL 对于暴雨预报 TS 评分的提升也来自于一定程度上的强降水过报, 表现为 Bias 评分在 1.3~1.4, 明显高于 OFM, 该现象在大暴雨量级表现更加明显。DL-P 在 Bias 评分上较 DL 有所改善, 尽管由于命中率降低导致暴雨 TS 评分略有下降, 但在大多数预报时效上 DL-P 仍保持了相较于其他产品的预报优势。对于大暴雨量级, DL-P 在 36 h 和 72 h 预报时效 TS 评分下降明显, 存在明显过报, 这可能是由于模型在训练过程中对损失函数权重进行了调整, 导致模型在小时尺度上倾向于预报较强量级降水, 从而引起 24 h 累计降水量预报范围偏大,




图 3 2023 年 6 月 1 日 08 时至 9 月 30 日 20 时 13~72 h 时效小时降水量的 (a) TS 和 (b) Bias 评分

Fig. 3 (a) TS and (b) Bias scores of hourly precipitation forecasts with 13–72 h lead times
from 08:00 BT 1 June to 20:00 BT 30 September 2023




图 4 2023 年 6 月 1 日 08 时至 9 月 30 日 20 时不同时效 24 h 累计
降水量的(a)TS 和(b)Bias 评分

Fig. 4 (a) TS and (b) Bias scores of 24 h accumulated precipitation with different lead times
from 08:00 BT 1 June to 20:00 BT 30 September 2023

这也说明现有 DL 对于极端降水预报能力仍稍显不足,其需要通过一定程度上的空报才能够维持较高的 TS 评分。

5 典型个例预报结果评估

选取 2023 年 7 月 28—31 日“杜苏芮”台风暴雨和 8 月 26—27 日西南涡暴雨典型个例,进一步评估深度学习模型的订正效果。

5.1 2023 年 7 月 28—31 日“杜苏芮”台风暴雨

由表 3 可见,对于中等强度降水($5 \text{ mm} \cdot \text{h}^{-1}$)预报,DL 的 TS 评分较 OFM 提升 67.5%,但湿偏差明显。DL-P 明显改善了该现象,Bias 评分降至 1.5 左右,且 TS 评分仍保持较 OFM 产品 45.5%的提升幅度。对于较强量级($10 \text{ mm} \cdot \text{h}^{-1}$)降水,OFM 的 TS 和 Bias 评分最优,DL 和 DL-P 对较强降水预报均存在明显的干偏差。FSS 评分显示(图 5a~5c),对

表 3 2023 年 7 月 28 日 08 时至 8 月 1 日 08 时实况对应的 13~72 h 时效
小时降水量预报的 TS 和 Bias 评分

模式/模型	0.1 mm		5 mm		10 mm	
	TS	Bias	TS	Bias	TS	Bias
EC	0.376	2.246	0.047	0.175	0.010	0.044
CMA-SH9	0.379	1.882	0.074	1.834	0.036	1.926
OFM	0.373	1.806	0.077	0.738	0.043	0.648
DL	0.432	2.068	0.129	2.021	0.033	0.418
DL-P	0.450	1.896	0.112	1.525	0.019	0.408

注:红色代表指标表现好,下同。




图 5 2023 年 7 月 28 日 08 时至 8 月 1 日 08 时实况对应(a~c)13~72 h 时效小时
降水量预报和(d~f)36~72 h 时效 24 h 累计降水量预报的 FSS 评分
Fig. 5 FSS scores of (a—c) hourly precipitation forecasts with 13—72 h lead times and (d—f) 24 h
accumulated precipitation forecasts with 36—72 h lead times corresponding to
the observation from 08:00 BT 28 July to 08:00 BT 1 August 2023

于 $5\text{ mm}\cdot\text{h}^{-1}$ 量级,DL 在 50 km 空间尺度明显优于其他产品,表明其具备更好的降水落区位置预报能力。此次过程在河南区域内多表现为分散的对流降水特征(图 6),DL 因存在一定程度的预报模糊现象,导致其对小时较强降水空间细节解析能力不足,该特征也在 TS、Bias 及 FSS 评分中有所体现。

从 24 h 累计降水量预报来看(表 4),对于大雨和暴雨量级,DL 同样在 60 h 预报时效内 TS 评分优于 EC、CMA-SH9。DL-P 对于 DL 的湿偏差有明显改善,但除 36 h 预报时效外,其他预报时效暴雨

量级 TS 评分较 DL 均有所下降。FSS 评分结果也表明,DL 能够在 50 km 以内空间尺度上更好地捕捉暴雨的空间分布特征,有效改善原始模式预报落区偏差(图 5f)。天气学检验对比表明(图 7),EC 预报降水强度随时效临近逐渐增强,但仍较实况明显偏弱,CMA-SH9 则在 60 h、72 h 时效预报强降水落区明显偏南,OFM 预报落区位置和降水强度介于两者之间,DL 能有效订正雨带位置,但同时也存在暴雨、大暴雨预报范围明显偏大的现象。




图 6 2023 年 7 月 28 日 08 时起的 43~47 h 时效小时降水量预报和实况

Fig. 6 Observations and hourly precipitation forecasts with 43—47 h lead times initiated at 08:00 BT 28 July 2023

表 4 2023 年 7 月 28 日 08 时至 8 月 1 日 08 时实况对应 36~72 h 时效
24 h 累计降水量预报的 TS 和 Bias 评分

Table 4 TS and Bias scores of 24 h accumulated precipitation forecasts with 36—72 h lead times
corresponding to the observation from 08:00 BT 28 July to 08:00 BT 1 August 2023

时效/h	模式/模型	10 mm		25 mm		50 mm	
		TS	Bias	TS	Bias	TS	Bias
36	EC	0.589	1.164	0.448	0.690	0.304	0.363
	CMA-SH9	0.541	1.234	0.399	1.117	0.284	0.894
	OFM	0.581	1.395	0.514	1.034	0.363	0.626
	DL	0.679	1.191	0.565	1.108	0.459	1.336
	DL-P	0.648	0.874	0.550	0.829	0.466	1.044
48	EC	0.584	1.126	0.374	0.514	0.151	0.175
	CMA-SH9	0.526	1.285	0.379	1.216	0.246	1.138
	OFM	0.489	1.228	0.343	0.795	0.197	0.451
	DL	0.609	1.103	0.521	1.083	0.400	1.232
	DL-P	0.599	0.923	0.509	0.979	0.285	0.779
60	EC	0.536	1.098	0.309	0.508	0.061	0.112
	CMA-SH9	0.512	1.388	0.391	1.487	0.238	1.662
	OFM	0.501	1.295	0.256	0.596	0.099	0.248
	DL	0.605	1.259	0.487	1.245	0.328	1.421
	DL-P	0.582	1.019	0.460	1.013	0.252	0.980
72	EC	0.583	1.225	0.387	0.669	0.125	0.177
	CMA-SH9	0.501	1.456	0.337	1.579	0.186	1.891
	OFM	0.572	1.466	0.472	1.059	0.266	0.554
	DL	0.576	1.407	0.443	1.478	0.264	1.746
	DL-P	0.563	1.231	0.441	1.347	0.218	1.242




图 7 2023 年 7 月 29 日 08 时至 30 日 08 时 24 h 累计降水量实况和 36~72 h 时效预报
Fig. 7 The 24 h accumulated precipitation observation and forecasts with 36—72 h lead times
from 08:00 BT 29 to 08:00 BT 30 July 2023

表 5 2023 年 8 月 26 日 08 时至 28 日 08 时实况对应 13~72 h 时效
小时降水量预报的 TS 和 Bias 评分

Table 5 TS and Bias scores of hourly precipitation forecasts with 13—72 h lead times corresponding to the observation from 08:00 BT 26 to 08:00 BT 28 August 2023						
模式/模型	0.1 mm		5 mm		10 mm	
	TS	Bias	TS	Bias	TS	Bias
EC	0.621	1.528	0.129	2.404	0.029	2.343
CMA-SH9	0.529	1.006	0.120	1.505	0.027	2.434
OFM	0.556	1.105	0.172	1.812	0.056	2.880
DL	0.652	1.368	0.292	2.827	0.144	2.909
DL-P	0.667	1.209	0.313	1.478	0.113	1.273

5.2 2023 年 8 月 26—27 日西南涡暴雨

由表 5 可见,此次过程中 OFM 的 $5\text{ mm}\cdot\text{h}^{-1}$ 和 $10\text{ mm}\cdot\text{h}^{-1}$ 量级预报 TS 评分优于 EC 和 CMA-SH9。DL 对于 0.1 、 5 、 $10\text{ mm}\cdot\text{h}^{-1}$ 降水量级预报 TS 评分较 OFM 分别提升 17.3% 、 69.8% 、 157.1% ,但其对于 $5\text{ mm}\cdot\text{h}^{-1}$ 、 $10\text{ mm}\cdot\text{h}^{-1}$ 的湿偏差特征也较各模式及 OFM 更加明显。DL-P 有效改善了 DL 的 Bias 评分,且 TS 评分仍明显优于 OFM 及模式原始预报。从落区位置预报评估来看,对于 $5\text{ mm}\cdot\text{h}^{-1}$ 、 $10\text{ mm}\cdot\text{h}^{-1}$ 量级,DL 在 40 km 以内 FSS 评分优于其他产品(图 8b,8c),且表现出与实况雨带较好的时空一致性(图 9)。

从不同时效的 24 h 累计降水量预报对比来看(表 6),OFM 在 60 h、72 h 时效的暴雨预报 TS 评分较 EC 分别提高 10% 、 13% ,DL 则较 OFM 进一步提升,其 TS 评分在 60 h、72 h 预报时效分别较 OFM 提高 15.1% 、 11.5% ,DL-P 则较 DL 有效改善了 Bias 评分。FSS 评分显示,DL 对于暴雨以下量级预报在所有空间尺度上均明显优于其他产品,暴雨量级预报仅次于 DL-P(图 8f)。从降水落区对比也可以看出(图 10),DL 对暴雨落区和范围进行了有效调整,但仍然存在大暴雨范围预报明显偏大的特点,DL-P 明显改善了 DL 的空报,其能够为实际预报业务提供更符合预报员主观预期的参考产品。




图 8 2023 年 8 月 26 日 08 时至 28 日 08 时实况对应的 (a~c) 13~72 h 时效小时降水量预报和 (d~f) 36~72 h 时效 24 h 累计降水量预报的 FSS 评分

Fig. 8 FSS scores of (a~c) hourly precipitation forecasts with 13~72 h lead times and (d~f) 24 h accumulated precipitation forecasts with 36~72 h lead times corresponding to the observation from 08:00 BT 26 to 08:00 BT 28 August 2023




图 9 2023 年 8 月 25 日 08 时起报的 50~54 h 时效的小时降水量预报和实况

Fig. 9 Observations and hourly precipitation forecasts with 50~54 h lead times initiated at 08:00 BT 25 August 2023

表 6 2023 年 8 月 26 日 08 时至 28 日 08 时实况对应的 36~72 h 时效
24 h 累计降水量预报的 TS 和 Bias 评分
Table 6 TS and Bias scores of 24 h accumulated precipitation forecasts with 36—72 h lead times
corresponding to the observation from 08:00 BT 26 to 08:00 BT 28 August 2023

时效/h	模式/模型	10 mm		25 mm		50 mm	
		TS	Bias	TS	Bias	TS	Bias
36	EC	0.862	1.110	0.845	1.048	0.618	0.968
	CMA-SH9	0.904	1.071	0.851	1.093	0.680	1.326
	OFM	0.855	1.157	0.833	1.169	0.646	1.394
	DL	0.902	1.082	0.885	1.083	0.681	1.375
	DL-P	0.845	0.886	0.799	0.881	0.662	0.968
48	EC	0.905	1.045	0.863	1.030	0.517	0.799
	CMA-SH9	0.881	1.067	0.849	1.042	0.678	1.296
	OFM	0.892	1.086	0.862	1.104	0.673	1.356
	DL	0.916	1.045	0.885	1.074	0.667	1.401
	DL-P	0.905	0.965	0.880	0.987	0.700	1.128
60	EC	0.879	0.957	0.798	0.927	0.531	0.885
	CMA-SH9	0.876	1.063	0.785	1.050	0.481	1.110
	OFM	0.890	1.043	0.850	1.070	0.584	1.343
	DL	0.902	1.071	0.869	1.082	0.672	1.411
	DL-P	0.830	0.864	0.799	0.874	0.666	1.038
72	EC	0.825	1.144	0.780	1.103	0.478	1.268
	CMA-SH9	0.811	1.050	0.716	1.110	0.474	1.178
	OFM	0.822	1.190	0.726	1.241	0.540	1.486
	DL	0.851	1.172	0.797	1.251	0.602	1.629
	DL-P	0.888	1.114	0.837	1.145	0.607	1.342




图 10 2023 年 8 月 26 日 08 时至 27 日 08 时 24 h 累计降水量实况和 36~72 h 时效预报
Fig. 10 The 24 h accumulated precipitation observation and forecasts with
36—72 h lead times from 08:00 BT 26 to 08:00 BT 27 August 2023

6 模型特征因子敏感性分析

第 3 节和第 4 节的对比分析表明,DL 相较于模

式原始预报在 TS 评分上有较明显的提升,且在更
长预报时效上优势更加明显,但同时存在强降水预
报范围偏大、预报落区不够精细等特点。本节基于
2022 年 7—9 月测试集,采用 IG 算法分析不同特征

因子对模型预报效果的影响。

从所有输入特征因子的相对贡献来看(图 11), 模型对于 CMA-SH9 的降水量预报依赖最大, 其次为 CMA-SH9 的 10 m 经向风, EC 预报的地面气压、2 m 气温和 1000 hPa 经向风分别排第 3~5 名。排名前 15 的特征因子中仅有 4 个高空气象要素, 地面附近气象要素占比达 73%。对比两个模式相同特征因子的差异, 除地面气压、2 m 气温以外, 对于 10 m 经向风/纬向风、CAPE 等特征因子, CMA-SH9 的重要性排序均优于 EC。这可能是由于地面气压、2 m 气温在一定程度上能够表征地面气旋、锋面移动或大尺度环境热力场的变化, 模型更加信任 EC 对于上述因子的预报能力。地面风场以及 CAPE 等能够一定程度上反映边界层辐合线、对流潜势等与强降水发生发展密切相关的中小尺度物理

机制, CMA-SH9 对此解析能力更强, 这可能是其预报同类因子重要性排序优于 EC 的主要原因。

对比经向风、纬向风、相对湿度、温度等 4 个基本气象要素不同层次特征因子重要性排序差异(图 12)。地面与 500 hPa 温度的重要性要高于其他层次, 这可能体现了地面增暖与中层冷空气侵入所形成的上下层系统配置对形成降水的重要性。纬向风以 850 hPa 最为重要, 这可能表征了东西风向变化带来的冷暖切变线的发展和加强对降水的影响。从经向风来看, 地面、1000 hPa 和 200 hPa 的重要性高于 850 hPa 和 500 hPa, 200 hPa 经向风的显著变化可能预示高空急流轴的偏转和急流出口辐散区的变化, 进而影响对降水发生发展关键的高层动力抽吸作用, 地面和近地面经向风则可能表征了边界层内水汽输送强度变化对降水的影响。




图 11 EC 和 CMA-SH9 不同特征因子在 DL 中的重要性排序

Fig. 11 Importance ranking of feature variables for the EC and CMA-SH9 in DL




图 12 EC 预报的不同高度特征因子重要性排序

Fig. 12 Importance ranking of feature variables with different heights for the EC

7 结论与讨论

本文基于 3D-Unet 深度学习架构, 融合 EC 和 CMA-SH9 的多维预报信息, 研发了一种多模式融合的定量降水预报订正技术。通过与 OFM 对比, 评估了多模式融合深度学习预报模型 DL 对 2019—2023 年及典型暴雨个例的预报性能, 并结合 IG 算法对模型中不同特征因子重要性进行分析, 主要结论如下:

(1) DL 对小时降水量和 24 h 累计降水量预报较单一模式模型均表现出优越性。在 2023 年 6—9 月

的独立检验中,DL 对于 $5 \text{ mm} \cdot \text{h}^{-1}$ 和 $10 \text{ mm} \cdot \text{h}^{-1}$ 量级降水的 TS 评分较传统 OFM 方法分别提升约 70.3% 和 26.5%,24 h 中雨、大雨、暴雨 TS 评分也均为最高,尤其在较长预报时效(60~72 h)对暴雨的订正效果显著(TS 评分提升 20% 以上),而 OFM 仅对部分降水等级有小幅改进。上述结果表明 DL 可以有效利用多模式预报的互补信息,进一步提高降水预报准确率。

(2)对于台风“杜苏芮”残涡引发的豫北极端暴雨过程,各模式原始预报的雨带位置和强度存在较大偏差,DL 能够融合 EC 提供的大尺度环流场信息和 CMA-SH9 提供的局地中小尺度信息,有效订正模式雨带落区南北位移偏差;对于西南涡暴雨过程,DL 成功订正了暴雨中心的位置和范围,预报雨带与实况更加吻合,显著提升了降水强度预报;但模型对暴雨及以上量级降水范围预报偏大,存在一定程度的降水过报现象。

(3)IG 算法的特征重要性分析显示,DL 赋予了 CMA-SH9 降水预报因子最高权重,表明模型相当程度上依赖中尺度模式提供的降水信息来修正全球模式;不同模式的相同地面气象因子的重要性结果差异反映了不同模式能够提供的可预报信息尺度差异,例如模型对于与天气尺度环流密切相关的地面气压和 2 m 气温更信赖 EC,CMA-SH9 则为模型提供了与局地触发和不稳定机制相关的近地面风场和对流有效位能信息,这种因子权重分配与两个模式的物理尺度也是相适应的。不同层次气象要素的重要性排序揭示了模型可能捕捉到的降水发生机制,例如模型对低层辐合与水汽输送、垂直温度层结变化以及高空急流相关动力条件具有较高敏感性,这与典型降水系统的多层耦合特征相一致。然而,模型是否显式地学习了完整的降水因果链条,仍有待通过更具针对性的诊断分析和独立验证进一步确认。

(4)尽管 DL 在预报准确率及运行效率上表现优异,但仍存在一些局限。首先,模型对极端降水(如特大暴雨)的预报能力不足,训练样本有限时倾向于扩大雨区来提高 TS 评分,在部分案例中可能导致强降水过度空报;其次,模型输出的降水空间细节仍较模糊,对于孤立小尺度强对流系统的定位精度不如人工主观预报。这些问题在一定程度上可以

通过事后校正(如本文的 DL-P)缓解,但从长远看仍然需要通过对模型本身加以改进来提升。

总之,本研究证明了深度学习在多模式降水预报融合中的巨大潜力:通过充分利用全球与区域模式的互补信息,DL 显著改进了定量降水预报效果;同时借助可解释性技术初步揭示了模型学习的物理规律与误差订正机制,为新一代“物理引导+数据驱动”融合预报系统研发提供参考。未来可在模型中引入多源实况数据、扩充极端天气样本或使用生成对抗网络等技术进行数据增强,降低对模式原始降水预报的过度依赖,弥补对极端事件欠采样导致强度预报不足等问题,提高模型对小样本事件的适应能力(姚秀萍和李若莹,2023)。此外,在业务应用层面,还需进一步检验模型对于样本权重系数的敏感性以及不同地域、不同季节降水的适用性,并结合预报员意见不断优化模型输出形式和解释工具,提高模型产品的实用价值。

参考文献

- 陈昊明,李建,李普曦,等,2025. 中国数值模式评估方法的研究进展综述[J]. 气象学报,83(3):566-581. Chen H M, Li J, Li P X, et al, 2025. A review of research progress on numerical model verification and evaluation in China[J]. Acta Meteor Sin, 83(3): 566-581 (in Chinese).
- 陈昊明,李普曦,赵妍,2021. 千米尺度模式降水的检验评估进展及展望[J]. 气象科技进展,11(3):155-164. Chen H M, Li P X, Zhao Y, 2021. A review and outlook of verification and evaluation of precipitation forecast at convection-permitting resolution[J]. Adv Meteor Sci Technol, 11(3):155-164 (in Chinese).
- 陈锦鹏,冯业荣,蒙伟光,等,2021. 基于卷积神经网络的逐时降水预报订正方法研究[J]. 气象,47(1):60-70. Chen J P, Feng Y R, Meng W G, et al, 2021. A correction method of hourly precipitation forecast based on convolutional neural network[J]. Meteor Mon, 47(1):60-70 (in Chinese).
- 湛芸,曹勇,孙健,等,2021. 中央气象台精细化网格降水预报技术的发展和思考[J]. 气象,47(6):655-670. Chen Y, Cao Y, Sun J, et al, 2021. Progress of fine gridded quantitative precipitation forecast technology of National Meteorological Centre [J]. Meteor Mon, 47(6):655-670 (in Chinese).
- 代刊,朱跃建,毕宝贵,2018. 集合模式定量降水预报的统计后处理技术研究综述[J]. 气象学报,76(4):493-510. Dai K, Zhu Y J, Bi B G, 2018. The review of statistical post-process technologies for quantitative precipitation forecast of ensemble prediction system [J]. Acta Meteor Sin, 76(4):493-510 (in Chinese).
- 高星星,潘留杰,娄盼星,等,2023. 一种改进的频率匹配法在网格降水预报订正中的应用[J]. 气象,49(11):1371-1383. Gao X X, Pan L J, Lou P X, et al, 2023. Application of an improved

- frequency matching method in grid precipitation forecast correction[J]. Meteor Mon, 49(11):1371-1383(in Chinese).
- 黄丽萍, 邓莲堂, 王瑞春, 等, 2022. CMA-MESO 关键技术集成及应用[J]. 应用气象学报, 33(6):641-654. Huang L P, Deng L T, Wang R C, et al, 2022. Key technologies of CMA-MESO and application to operational forecast[J]. J Appl Meteor Sci, 33(6):641-654(in Chinese).
- 蒋鸿儒, 方巍, 2024. 深度学习在气象数据订正中的应用综述[J]. 计算机应用, 44(12):3930-3940. Jiang H R, Fang W, 2024. Survey of application of deep learning in meteorological data correction[J]. J Comp Appl, 44(12):3930-3940(in Chinese).
- 李泽椿, 湛芸, 张夕迪, 等, 2019. 中央气象台暴雨预报业务的发展及思考[J]. 暴雨灾害, 38(5):407-415. Li Z C, Chen Y, Zhang X D, et al, 2019. Development and perspectives on torrential rain forecasting operation in National Meteorological Centre[J]. Torr Rain Dis, 38(5):407-415(in Chinese).
- 刘会军, 吴启树, 危国飞, 等, 2024. 数值模式降水预报 OTS 订正法的实现技术[J]. 大气科学, 48(5):1891-1900. Liu H J, Wu Q S, Wei G F, et al, 2024. Implement technology of optimal threat score correction method for numerical model precipitation forecast[J]. Chin J Atmos Sci, 48(5):1891-1900(in Chinese).
- 刘静, 任川, 赵梓淇, 等, 2022. 多区域高分辨率模式强降水预报检验分析[J]. 气象, 48(10):1292-1302. Liu J, Ren C, Zhao Z Q, et al, 2022. Comparative analysis on verification of heavy rainfall forecasts in different regional models[J]. Meteor Mon, 48(10):1292-1302(in Chinese).
- 潘旸, 谷军霞, 徐宾, 等, 2018. 多源降水数据融合研究及应用进展[J]. 气象科技进展, 8(1):143-152. Pan Y, Gu J X, Xu B, et al, 2018. Advances in multi-source precipitation merging research[J]. Adv Meteor Sci Technol, 8(1):143-152(in Chinese).
- 沈文强, 钱浩, 马昊, 等, 2023. 浙江梅汛期暴雨预报的客观订正方案对比分析[J]. 气象, 49(6):697-707. Shen W Q, Qian H, Ma H, et al, 2023. Objective correction schemes on the forecast of torrential rain during the Meiyu period in Zhejiang[J]. Meteor Mon, 49(6):697-707(in Chinese).
- 王新敏, 栗晗, 2020. 多数值模式对台风暴雨过程预报的空间检验评估[J]. 气象, 46(6):753-764. Wang X M, Li H, 2020. Spatial verification evaluation of typhoon rainstorm by multiple numerical models[J]. Meteor Mon, 46(6):753-764(in Chinese).
- 吴启树, 韩美, 刘铭, 等, 2017. 基于评分最优化的模式降水预报订正算法对比[J]. 应用气象学报, 28(3):306-317. Wu Q S, Han M, Liu M, et al, 2017. A comparison of optimal-score-based correction algorithms of model precipitation prediction[J]. J Appl Meteor Sci, 28(3):306-317(in Chinese).
- 熊文睿, 张恒德, 陆振宇, 等, 2025. 基于多要素 3D 特征提取的短期定量降水预报技术研究[J]. 南京信息工程大学学报, 17(1):125-137. Xiong W R, Zhang H D, Lu Z Y, et al, 2025. Short-term quantitative precipitation forecasting based on multi-factor 3D feature extraction[J]. J Nanjing Univ Inform Sci Technol, 17(1):125-137(in Chinese).
- 徐同, 王琴, 漆梁波, 等, 2025. CMA-MESO 和 CMA-SH9 模式对中国东部地区降水预报的性能检验[J]. 气象, 51(2):167-181. Xu T, Wang Q, Qi L B, et al, 2025. Verification of CMA-MESO and CMA-SH9 models for precipitation forecast in eastern China[J]. Meteor Mon, 51(2):167-181(in Chinese).
- 徐同, 杨玉华, 李佳, 等, 2019. SMS-WARMS V2.0 模式对中国西南地区降水预报能力的客观检验[J]. 气象, 45(8):1065-1074. Xu T, Yang Y H, Li J, et al, 2019. An objective verification of forecasting ability of SMS-WARMS V2.0 model precipitation in Southwest China[J]. Meteor Mon, 45(8):1065-1074(in Chinese).
- 杨绚, 代刊, 朱跃建, 2022. 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, 80(5):649-667. Yang X, Dai K, Zhu Y J, 2022. Progress and challenges of deep learning techniques in intelligent grid weather forecasting[J]. Acta Meteor Sin, 80(5):649-667(in Chinese).
- 姚秀萍, 李若莹, 2023. 河南“21.7”极端暴雨的研究进展[J]. 气象学报, 81(6):853-865. Yao X P, Li R Y, 2023. Progress in research of the July 2021 extreme precipitation event in Henan Province, China[J]. Acta Meteor Sin, 81(6):853-865(in Chinese).
- 曾小团, 谭肇, 沈玉伟, 等, 2025. CastNet:深度学习定量降水临近预报模型[J]. 气象, 51(4):400-416. Zeng X T, Tan Z, Shen Y W, et al, 2025. CastNet: deep-learning-based model for quantitative precipitation nowcasting[J]. Meteor Mon, 51(4):400-416(in Chinese).
- 张华龙, 程正泉, 肖柳斯, 等, 2022. 集合百分位融合法在广东台风降水预报中的改进[J]. 气象, 48(1):84-95. Zhang H L, Cheng Z Q, Xiao L S, et al, 2022. Improvement of the optimal percentile fusion method based on ensemble forecast of typhoon rainfall in Guangdong Province[J]. Meteor Mon, 48(1):84-95(in Chinese).
- 张亚萍, 刘伯骏, 庞玥, 等, 2025. 基于深度学习网络显著目标检测算法的强降水落区临近预报技术[J]. 气象学报, 83(2):334-349. Zhang Y P, Liu B J, Pang Y, et al, 2025. A technique for nowcasting heavy rainfall locations using salient object detection algorithm based on deep learning network[J]. Acta Meteor Sin, 83(2):334-349(in Chinese).
- 智协飞, 吕游, 2019. 基于频率匹配法的中国降水多模式预报订正研究[J]. 大气科学学报, 42(6):814-823. Zhi X F, Lü Y, 2019. Calibration of the multimodel precipitation forecasts in China using the frequency matching method[J]. Trans Atmos Sci, 42(6):814-823(in Chinese).
- 周莉, 许霖, 陈鹤, 等, 2024. 基于改进 U-Net 模型的湖南地区定量降水预报订正试验[J]. 热带气象学报, 40(6):1005-1017. Zhou L, Xu L, Chen H, et al, 2024. Research on quantitative precipitation correction forecasting based on the improved U-Net model in Hunan[J]. J Trop Meteor, 40(6):1005-1017(in Chinese).
- Başagaoglu H, Chakraborty D, Do Lago C, et al, 2022. A review on interpretable and explainable artificial intelligence in hydroclimatic applications[J]. Water, 14(8):1230.
- Çiçek Ö, Abdulkadir A, Lienkamp S S, et al, 2016. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]//

- 19th International Conference on Medical Image Computing and Computer-Assisted Intervention-MICCAI 2016. Athens; Springer International Publishing; 424-432.
- Fang W, Qin H, Liu G J, et al, 2023. A method for spatiotemporally merging multi-source precipitation based on deep learning[J]. *Remote Sens*, 15(17):4160.
- Liu Q, Lou X, Yan Z W, et al, 2023. Deep-learning post-processing of short-term station precipitation based on NWP forecasts[J]. *Atmos Res*, 295:107032.
- Mamalakis A, Barnes E A, Ebert-Uphoff I, 2022. Investigating the fidelity of explainable artificial intelligence methods for applications of convolutional neural networks in geoscience[J]. *Artif Intell Earth Syst*, 1(4):e220012.
- Mittermaier M, Roberts N, 2010. Intercomparison of spatial forecast verification methods: identifying skillful spatial scales using the fractions skill score[J]. *Wea Forecasting*, 25(1):343-354.
- Mu B, Wang X, Yuan S J, et al, 2024. A deep learning-based global tropical cyclogenesis prediction model and its interpretability analysis[J]. *Sci China Earth Sci*, 67(12):3671-3695.
- Snook N, Kong F Y, Clark A, et al, 2020. Comparison and verification of point-wise and patch-wise localized probability-matched mean algorithms for ensemble consensus precipitation forecasts[J]. *Geophys Res Lett*, 47(12):e2020GL087839.
- Sundararajan M, Taly A, Yan Q Q, 2017. Axiomatic attribution for deep networks[C]// *Proceedings of the 34th International Conference on Machine Learning*. Sydney: JMLR. org:3319-3328.
- Tang Y H, Wu Q, Soomro S E H, et al, 2022. Comparison of different ensemble precipitation forecast system evaluation, integration and hydrological applications[J]. *Acta Geophys*, 71(1):405-421.
- Zhou K H, Sun J S, Zheng Y G, et al, 2022. Quantitative precipitation forecast experiment based on basic NWP variables using deep learning[J]. *Adv Atmos Sci*, 39(9):1472-1486.
- Zhu Y J, Luo Y, 2015. Precipitation calibration based on the frequency-matching method[J]. *Wea Forecasting*, 30(5):1109-1124.

(本文责编:张芳)