

基于 3D-Unet 的多模式融合定量降水 预报技术研究*

栗 晗^{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

摘要: 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 5mm 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), 5mm h^{-1} 和 10mm h^{-1} 量级 TS 评分较 OFM 分别提高了约 70.0% 和 26.8%。24h 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 模式分别提高约 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 区域模式中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 全球模式中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 深度学习, 多模式融合, 时空特征, 可解释性, 降水预报订正

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

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
第一作者: 栗晗, 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

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 and the CMA-SH9 regional model, and introduces the Integrated Gradients (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 mm h^{-1} precipitation. Real-time operational verification shows that the DL model 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 scores of precipitation forecasts of the DL model at the 5 mm h^{-1} and 10 mm h^{-1} thresholds are improved by approximately 70.0% and 26.8%, respectively. For the 24 h accumulated precipitation, the DL model 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 model, at the longer lead time of 60 h and 72 h, TS scores of the DL model for torrential rain forecasts are improved by about 42.7% and 24.3%, respectively. The DL model 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 model 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 regional model, 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 model.

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

引言

数值天气预报模式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）——空间分辨率细至公里级、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）。

考虑到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（OTS）、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预报降水落区预报效果（代刊等，2018；Snook et al，2020；张华龙等，2022）。总体而言，这些技术提高了业务降水预报水平，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，可显著提升不同降水等级的定量预报技巧（Zhou et al,2022；熊文睿等，2025）。相较于二维模型，3D-Unet 能够更好的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，在小时及累计降水量预报中均展现出的潜力。

另一方面，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（如仅小时或仅日累计降水），尚缺乏在统一框架下同时评估小时降水细节与 24 h 累计降水量级表现的研究；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（Integrated Gradients, 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有效手段。

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 24h 累计降水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性分析,以期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 数据说明

选取欧洲中心 ECMWF-IFS 全球模式(以下简称 EC 模式)和中国气象局 CMA-SH9 区域模式 2019—2023 年的预报产品作为深度学习模型(Deep Learning Model, 以下简称 DL)和最优权重融合方法(Optimal Weighted Fusion Method, 以下简称 OFM)的输入数据。两家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 24h 累计降水量)。EC 模式为全球模式,在大尺度环流演变和长时效预报方面性能较为稳定;CMA-SH9 模式为区域模式,对中小尺度对流降水过程的捕捉能力较强,但预报偏差也更容易受局地热力、动力过程影响,两家模式水平分辨率均为 0.1° (9 公里)。已有研究表明,EC 模式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优势互补。

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 小时,空间分辨率为 0.05° ;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 年河南省内 1618 个国家级和区域自动气象站的逐小时降水量观测作为实况参考。

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 错误!未找到引用源。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 $31.25 \sim 36.5^{\circ} \text{N}$ 、 110.2

~116.75 ℃，网格大小为 132×106。采用 2019-2021 年每年汛期（5—9 月）数据作为 DL 训练集；为了更好地评估模型对于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	层次
EC	温度、湿度、 u 风、 v 风	200 hPa、500 hPa、850 hPa、1000 hPa
	降水量、10m u 风、10m v 风、2m 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、10m u 风、10m v	
	风、2m 温度、地面气压、对流有效位能、	/
	对流抑制能量、2m 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 $\geq 20\text{mm h}^{-1}$ 或有效降水 ($\geq 0.1\text{mm h}^{-1}$) 格点数 > 800 ，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最小值归一化处理，消除量级差异。

针对卷积类深度学习模型的定量降水预报技术容易出现空间落区平滑、强降水预报偏弱的现象，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 30d 滑动训练期对 DL 预报逐小时降水量和 24h 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 24h 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 24h 累计降水量在逐格点上按照比例重新分配至 1h，得到新的逐小时降水预报结果（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,其对于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高度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、地面等不同高度层次气象要素作为特征因子，将所有因子的 0~72h

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，最终输出为 0~72h 逐小时降水量预报。

本文构建的 DL 模型结构如图 1 所示，该模型结构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。




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 不同量级的降水对应的权重

Table 2 Weights for different precipitation intensity levels

量级 (mm)	0~1.0	1.0~2.0	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

模型训练过程中，采用 4 张 Nvidia RTX 3090 (GPU)，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 TS 评分 ($\geq 0.1 \text{ mm h}^{-1}$) 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以在 2min 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 24h 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 30d,下同)建立 EC、CMA-SH9 模式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 进行小时定量降水预报对比,将 OFM 24 h 累计降水按照 CMA-SH9 小时降水预报时间变化曲线逐格点拆分,保证 24 h 累计降水量预报结果不变。

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,本文也采用空间邻域检验(Fractional Skill Score, FSS)方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 13~72h。

2.5 因子敏感性分析方法

作为数据驱动的非线性模型,DL 模型本质上仍是一个“黑箱模型”,难以明确其在降水预报订正中学习到的物理机制。本文尝试采用 IG 算法评估 DL 模型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。为了便于分析,对结果进行了归一化处理。

3 不同建模方案评估结果分析

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 所示。 0.1mm h^{-1} 和 2mm h^{-1} 较弱降水量级 TS 评分显示,经过深度学习模型订正后的 DL-EC、DL-SH9 均明显优于两模式原始预报结果,但融合两个模式的 DL 则与 DL-EC 基本相当。对于 5mm 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，13-72h 综合 TS 评分为 0.078，高于 DL-SH9 的 0.056 和 DL-EC 的 0.036。对于 10mm h^{-1} 较强量级降水，CMA-SH9、DL-SH9 和 DL 三者综合 TS 评分均在 0.02 左右，预报性能接近。总体来看，DL 模型相较于单一模式建模更好的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。后续章节将基于实际业务应用对 DL 模型展开系统评估，以考察其在不同降水过程中的适用性与泛化能力。




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 time from 08:00 BT 1

July to 20:00 BT 30 September 2022

4 2023 年 6-9 月总体评估结果分析

4.1 逐 1h 降水预报评估

OFM 产品在 0.1mm h^{-1} 、 5mm h^{-1} 和 10mm h^{-1} 量级预报 TS 评分均优于两家模式原始预报，且对于 10mm 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（图 3b），但 2mm h^{-1} 和 20mm h^{-1} 量级 TS 评分分别低于模式原始预报。DL 模型在 $0.1\sim 10\text{mm h}^{-1}$ 不同量级均展示出相较于模式原始预报或 OFM 的明显优势， 5mm h^{-1} 和 10mm h^{-1} 量级 TS 评分较 OFM 分别提升 70%（0.074 提升至 0.126）、26.8%（0.034 提升至 0.043）。从 BIAS 评分来看，DL 模型也表现出了类似于 EC 模式的特点，如 5mm h^{-1} 及以下量级存在湿偏差，更强量级则存在明显干偏差，表明其对于小时降水强度仍存在明显低估。订正后的

DL_P 产品在 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 20mm 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预报但幅度有限，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预报能力，但对于强降水预报仍存在弱报，结合后处理技术有助于改进 DL 对于小时强降水的预报能力。




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

Fig.3 (a) TS and (b) BIAS scores of hourly precipitation forecasts with 13~72 h lead time from 08:00

BT 1 June to 20:00 BT 30 September 2023

4.2 逐 24h 累计降水预报评估

相较于模式原始预报，OFM 产品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 评分评估结果来看，DL 模型在不同预报时效、各个预报量级均优于模式原始预报以及 OFM 产品，以暴雨量级为例，对于 60h 和 72h 预报时效，DL 模型仍较 EC 模式分别提高 42.7% ($0.206 \rightarrow 0.294$)、24.3% ($0.222 \rightarrow 0.276$)，这表明尽管本文构建的 DL 模型输入特征为小时尺度气象信息，但其不仅有效订正了逐小时降水量预报，同时也提升了时段累计降水量的预报效果。但 DL 模型对于暴雨预报 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 左右，明显高于 OFM 产品，该现象在大暴雨量级表现更加明显。DL_P 产品在 BIAS 评分上较 DL 模型有所改善，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 产品在 36h 和 72h 预报时效上 TS 评分下降明显、存在明显过报，这可能是由于模型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 24h 累计降水量预报范围偏大，这也说明现有 DL 模型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。




图 4 2023 年 6 月 1 日 08 时至 9 月 30 日 20 时 24h 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 from 08:00 BT 1 June to 20:00

BT 30 September 2023

5 典型个例评估结果分析

选择 2023 年 7 月 28-31 日“杜苏芮”台风暴雨和 8 月 26-27 日西南涡暴雨两个典型个例深度学习模型的订正效果做进一步评估。

5.1 2023 年 7 月 28—31 日“杜苏芮”台风暴雨

对于中等强度降水 (5mm h^{-1}) 预报 (

表 3), DL 模型 TS 评分较 OFM 产品提升 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 (10mm h^{-1}) 降水, OFM 产品 TS 和 BIAS 评分最优, DL 模型及 DL_P 订正产品对较强降水预报均存在明显的干偏差。FSS 评分显示 (图 5a-c), 对于 5mm h^{-1} 及以下量级,

DL 模型在 50km 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 模型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 24h 累计降水量预报来看（表 4），对于大雨和暴雨量级，DL 模型同样在 60h 以内 TS 评分优于 EC、CMA-SH9。DL_P 对于 DL 模型的湿偏差有明显改善，但除 36h 预报时效以外，其他预报时效暴雨量级 TS 评分均有所下降。FSS 评分结果也表明，DL 模型能够在 50km 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，但仍较实况降水明显偏弱偏少，CMA-SH9 则在 60 h、72h 时效预报强降水落区明显偏南，OFM 产品预报落区位置和降水强度介于两者之间，DL 模型能有效订正雨带位置，但同时也存在暴雨、大暴雨落区预报范围偏大的现象。

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

Table 3 TS and BIAS scores of hourly precipitation forecasts with 13–72 h lead time corresponding to the observation from 08:00 BT 28 July to 08:00 BT 1 August 2023

时效	模式	TS-0.1	BIAS-0.1	TS-5	BIAS-5	TS-10	BIAS-10
13-72h	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


表 4 2023 年 7 月 28 日 08 时至 8 月 1 日 08 时实况对应的 36~72h 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 time corresponding to the observation from 08:00 BT 28 July to 08:00 BT 1 August 2023

时效	模式	TS-10	BIAS-10	TS-25	BIAS-25	TS-50	BIAS-50
36h	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

	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
48h	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
	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
60h	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
	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
72h	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

261



262

263 图 5 2023 年 7 月 28 日 08 时至 8 月 1 日 08 时实况对应的 (a~c) 13~72h 时效小时降水量预报和 (d~f)

264

36~72h 时效 24h 降水量预报的 FSS 评分

265

Fig.5 FSS scores of (a-c) hourly precipitation forecasts with 13-72 h lead time and (d-f) 24 h accumulated

266

precipitation forecasts at with 36-72 h lead time corresponding to the observation from 08:00 BT 28 July to 08:00

267

BT 1 August 2023

268




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

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

2023




图 7 2023 年 7 月 29 日 08 时至 30 日 08 时 24h 累计降水量实况和 36~72 时效预报

Fig.7 The 24 h accumulated precipitation observation and forecasts with 36–72 h lead time from 08:00 BT 29

to 08:00 BT 30 July 2023

5.2 2023 年 8 月 26 至 27 日西南涡暴雨

此次过程中 OFM 产品的 5mm h^{-1} 和 10mm h^{-1} 量级预报 TS 评分优于 EC 和 CMA-SH9 (表 5)。DL 模型对于 0.1mm h^{-1} 、 5mm h^{-1} 、 10mm h^{-1} 降水量级预报 TS 评分较 OFM 分别提升 20%、69.8%、157.1%，但其对于 5mm h^{-1} 、 10mm h^{-1} 的湿偏差特征也较各模式及 OFM 产品更加明显。DL_P 有效改善了 DL 模型的 BIAS 评分，且 TS 评分仍明显优于 OFM 及模式原始预报产品。从落区位置预报评估来看，对于 5mm h^{-1} 、 10mm h^{-1} 量级，DL 模型在 40km 以内空间邻域 FSS 评分优于其他产品 (图 8b-c)，且表现出与实况主要降水雨带较好的时空一致性 (图 9)。

从不同时效 24h 累计降水量预报对比来看 (表 6)，OFM 产品在 60h、72h 预报时效的暴雨预报 TS 评分较 EC 分别提高 10%、13%，DL 模型则较 OFM 产品进一步提升了暴雨预报性能，其 TS 评分在 60、72h 预报时效分别较 OFM 提高 15.1%、11.5%，DL_P 产品则较 DL 模型有效改善了 BIAS 评分。FSS 评分显示 DL 模型对于暴雨预报在所有空间尺度上均明显优于其他产品。降水落区对比也可以看出 (图 10)，DL 模型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 产品明显改善了 DL 模型的空报，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。

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

Table 5 TS and BIAS scores of 1 h hourly precipitation forecasts with 13–72 h lead time corresponding to the observation from 08:00 BT 26 to 08:00 BT 28 August 2023

时效	模式	0.1mm		5mm		10mm	
		TS	BIAS	TS	BIAS	TS	BIAS
13-72h	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

表 6 2023 年 8 月 26 日 08 时至 28 日 08 时实况对应的 36-72h 时效 24h 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 lead time corresponding to the observation from 08:00 BT 26 to 08:00 BT 28 August 2023

时效	模式	10mm		25mm		50mm	
		TS-10	BIAS-10	TS-25	BIAS-25	TS-50	BIAS-50
36h	EC	0.862	1.110	0.845	1.048	0.618	0.968




图 8 2023 年 8 月 26 日 08 时至 28 日 08 时实况对应的 (a~c) 13~72h 时效小时降水量预报和 (d~f) 36~72h 时效 24h 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 time and (d~f) 24 h accumulated precipitation forecasts with 36~72 h lead time, 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 50~54h 时效的小时降水量预报和实况

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

2023




图 10 2023 年 8 月 26 日 08 时至 27 日 08 时 24h 累计降水量实况和 36~72 时效预报

Fig.10 The 24 h accumulated precipitation observation and forecasts with 36~72 h lead time 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 模型相较于模式原始预报在 TS 评分表现上有较

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 10m 经向风速，EC 预报的地面气压、2m 气温和 1000 hPa 经向
风速分别排名第 3 至 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、2m 气温以外，对于 10m
经向/纬向风速、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、2m 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例
如边界层辐合线、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。

对比经向风速、纬向风速、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 层次
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、加强对降水的影响。从经
向风来看，地面、1000 hPa 和 200 hPa 经向风的重要性要高于 850h Pa 和 500 hPa 经向风，
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 模式不同特征因子重要性排序

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




图 12 EC 预报的特征因子重要性排序

Fig.12 Importance ranking of feature variables for the EC model

7 结论与讨论

本文基于 3D-Unet 深度学习架构，融合 ECMWF-IFS 全球模式和 CMA-SH9 区域中尺度模式的多维预报信息，研发了一种多模式融合的定量降水预报订正技术。通过与传统最优权重融合方法（OFM）对比，评估了深度学习模型对 2019–2023 年及典型暴雨个例的预报性能，并结合积分梯度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）多模式融合 DL 模型对小时降水量和 24 小时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 模型对于 5 mm h^{-1} 和 10 mm h^{-1} 量级降水的 TS 评分较传统 OFM 方法分别提升约 70% 和 26.8%，24h 中雨、大雨、暴雨 TS 评分也均为最高，尤其在较长预报时效（60–72h）上对暴雨的订正效果显著（TS 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“杜苏芮”台风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 模型能够融合 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 模型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 模型赋予了 CMA-SH9 模式的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 2m 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 融合模型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,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模型本身改进加以提升。

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 模型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).
- 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).
- 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, Shen Y, Zhang X D, et al, 2019. Development and perspectives on torrential rain forecasting operation in National Meteorological Center[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).

潘旻, 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, 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).

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).

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 P, 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).

谌芸, 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. Shen 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).

Başağaoğlu 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, Greece: 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, doi: 10.3390/rs15174160.

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, doi: 10.1007/s11600-022-00877-6.

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.