

人工智能在气象预报中的突破性进展与科学价值

毕馨元¹, 代刊^{2*}

1. 首都师范大学数学科学学院, 北京 100048

2. 国家气象中心, 北京 100081

* 联系人, E-mail: daikan@cma.gov.cn

气象预报是应对自然环境变化、保障生命财产安全和促进经济社会可持续发展的重要科技手段。近几年, 人工智能(AI)在该领域取得突破, 正深刻改变着传统气象预报的发展范式^[1]。2023年, *Science*将“人工智能模型为全球精准天气预报带来了新的突破”评为世界科学十大进展^[2], 同年我国主导的AI模型在精细化天气预测中的应用入选“中国科学十大进展”, 这些成果表明气象预报已成为AI研究应用最活跃、成果最显著的领域之一。

2023年, 华为发布的盘古气象模型(Pangu-Weather)首次在预报精度上超越传统数值模式, 将全球预报的计算时间从数小时缩短至数分钟, 并在温度、气压、风速等关键要素上超越了欧洲中期天气预报中心(ECMWF)的模式^[3], 体现了计算效率的质的飞跃和全新的预报方法论。与此同时, 清华大学与国家气象中心联合开发的NowcastNet(业务上又称“风雷”模型)将强对流天气预报时效由1 h延长至3 h, 与传统线性外推方法相比, 在天气系统生消发展的关键难题上有了显著改善^[4]。此外, Google研发的MetNet系列模型将短时预报分辨率提升至1 km、时间精度达到2 min, 展示了AI在高分辨率气象预报中的独特优势^[5]。

这些进展推动了气象预报发展范式的深刻变革。传统方法依靠求解大气运动物理方程, 而AI则通过数据驱动直接构建大气状态演变规律, 开启了认知气象科学的新途径, 并展示了从海量观测数据中自主学习和发现复杂大气物理过程的前所未有的潜力^[3]。这种范式转变不仅体现在预报技术革新上, 也反映了人类认知和理解大气系统方式的根本改变^[1]。值得注意的是, AI与传统物理机制的深度融合正形成新的科学研究模式: 深度学习算法(如Transformer架构)在处理时空序列数据、捕捉大气运动长程依赖关系方面展现出独特优势, 而将物理约束引入模型设计则既保持了长时效预测能力, 又确保了结果的物理合理性^[6]。随着“AI for Science”理念的深入, 气象预报与AI的深度融合必将为应对气候变化和防范自然灾害创造新机遇, 其科学价值和长远影响值得深入探讨。



代刊 国家气象中心副主任, 正高级工程师, 中国气象局首席气象专家, 国家重点研发计划项目“典型灾害天气公里级滚动预报关键技术与示范应用”负责人, 担任WMO业务预报系统专家组成员, 人工智能临近预报示范项目AINPP联合主席。主导国家级数字智能预报系统建设, 研究领域为人工智能气象应用、集合天气预报、天气预报检验评估等。

1 气象预报AI应用的重要进展

1.1 短临预报领域的突破性进展

临近(0~2 h)与短时(2~24 h)预报对于强对流天气防御至关重要, 是气象预报中最具挑战性的领域之一。在这些时间尺度内, 强对流系统往往呈现复杂的中小尺度结构, 若仅依赖人工特征识别或统计经验, 难以充分捕捉观测数据中的细微差异与演化。近年来, 以MetNet系列^[5,7,8]和NowcastNet^[4]为代表的深度学习模型在该领域取得了一系列突破性进展, 实现了预报能力的快速提升。

MetNet系列模型的发展集中体现了AI在高分辨率气象预报方面的重要突破。2020年Google发布的MetNet首次将降水预报的空间分辨率提升至1 km², 时间精度达到2 min, 实现了对未来8 h降水的精细化预报^[7]。2021年, MetNet-2进一步将预报时效扩展至12 h, 其预报效果超越了美国最先进的HREF数值集合预报系统^[8]。这一进展通过创新性的深度学习架构, 将预报计算时间从传统方法的数小时缩减至分钟级别, 为业务应用奠定了基础。2023年11月进一步推出了MetNet-3模型^[9], 能够提供长达24 h的预测, 并涵盖更多气象变量, 如地面温度、风速和露点。该模型通过将传统数据同化与模拟过

引用格式: 毕馨元, 代刊. 人工智能在气象预报中的突破性进展与科学价值. 科学通报, 2025, 70: 4638–4645

Bi X, Dai K. Breakthrough progress and scientific value of artificial intelligence in weather forecasting (in Chinese). Chin Sci Bull, 2025, 70: 4638–4645, doi: 10.1360/TB-2025-0128

程合并为一个单一步骤,从而实现更高精度和更全面的天气预测。

2023年发表的NowcastNet在临近预报领域实现了新的突破^[4]。该模型首次将降水临近业务预报的时效从传统的1~2 h延长至3 h,同时保持了较高的预报准确度。在与DGMR^[10](deep generative models of radar,深度生成雷达模型)、PredRNN^[11](predictive recurrent neural network)等国际主流模型的对比中,NowcastNet在约71%的强天气案例中表现最优。这一成果的关键在于创新性地将物理方程引入深度学习框架设计,既保持了模型对复杂天气系统的表达能力,又确保了预报结果的物理合理性。NowcastNet采用了守恒定律约束算子、中尺度演变网络、受控生成机制、对流尺度生成网络等新颖的深度学习架构,具备多尺度预报能力,能够有效处理极端降水事件。在2024年7月,NowcastNet通过中国气象局的业务化评审,更名为“风雷”,成为全球首个正式业务化运行的深度学习临近预报模型。该模型不仅在降水强度和位置预测方面表现出色,还在极端天气事件中显示出更高的准确性。例如,在对超过16 mm/h降水强度的降水事件中,NowcastNet的CSI(临界成功指数)指数达到了0.30,显著优于传统数值天气预报(numeric weather predication, NWP)模式。图1给出了人工智能驱动的气象短临预报领域模型发展时间线,展示了从早期基于回归和卷积神经网络的初始探索,逐步发展为融合注意力机制、生成式建模、多模态输入和时空联合建模的复杂系统。整体趋势体现为模型结构日益复杂、数据输入更加多样、生成能力不断增强,同时向高分辨率、不确定性建模和业务可用性方向演进。

未来,短临AI预报的发展需要在三个方向持续突破:一是强化多源数据的融合应用,特别是新一代天基、地基观测数据的有效利用;二是深化物理机制与深度学习的结合,在保持模型灵活性的同时增强物理约束;三是提升模型的自适

应能力,使其能够更好地应对气候变化背景下天气系统的新特征。这些方向的突破将进一步提升短临预报水平,为防灾减灾提供更可靠的科技支撑。

1.2 中短期预报的革命性进步

中短期天气预报一直以数值预报为主导,被称为“宁静的革命”^[12]。随着AI技术的快速发展,这一领域正在经历新一轮革命性变革。从2021年Rasp和Thuermer^[13]以及Weyn等人^[14]利用卷积神经网络CNN进行纯数据驱动模型预报的初步探索,到2022年FourCastNet接近ECMWF预报水平^[15],再到2023年盘古气象模型首次超过传统数值模式,AI驱动的中短期预报展现出前所未有的发展潜力。图2给出了人工智能驱动的气象中短期全球预报模型发展时间线,体现了从2022年初期Transformer模型的探索起步,逐步过渡到基于图神经网络、混合物理机制、生成式建模等多技术融合的新阶段。表S1给出全球主流气象AI模型性能综合对比表,可见模型精度持续逼近甚至超越传统NWP系统,预报时效延长至15天以上,整体趋势呈现出从单一模型到多模型竞合、从预测能力提升到业务化部署推进的演进态势。

盘古气象模型(Pangu-Weather)的突破具有里程碑意义^[3]。该模型创新设计三维地球专用Transformer架构,采用分层时间聚合预报推理算法,首次在多个关键预报要素上超越了ECMWF的预报水平。这一成果不仅证实了AI取代传统数值模式的可能性,更开创了一种新的计算范式:通过深度学习直接从历史数据中获取大气演变规律,避开了传统数值模式中复杂的物理方程求解过程。这种范式的转变为提升预报效率和精度开辟了新途径。

2023年底发布的GraphCast在深度学习网络结构方面实现了重要创新^[16]。该模型采用图神经网络架构,一种特别适合处理空间结构数据的机器学习架构,加上采用多尺度网格




图1 人工智能驱动的气象短临预报领域模型发展时间线

Figure 1 Timeline of AI-driven nowcasting model development in meteorology




图2 人工智能驱动的气象中短期全球预报模型发展时间线

Figure 2 Timeline of AI-driven global medium-range weather forecasting model development

表示大气运动, 这使得模型能够在不同空间尺度上捕捉大气过程, 从而提高预报的灵活性和准确性。特别是, GraphCast在处理如台风、大气河流、极端温度等灾害性天气事件时展现出优良的性能, 为解决传统数值模式在这一领域的局限提供了新思路。

2024年6月中国气象局与清华大学联合发布了“风清”全球天气预报模型。该模型采用AI技术与预报原理机制深度融合的原創架构Transitor, 实现了四个方面的重要创新: 首创多尺度隐空间投影机制, 将大气时空交互转换为物理可解释的状态转移^[17]; 设计能量守恒损失函数, 通过哈密顿守恒系统约束预报结果^[18]; 开发可扩展的多时效优化策略, 有效降低累积误差; 实现完全自主可控, 基于39年CRA再分析数据训练出具有3B参数的模型。“风清”能够在3 min内生成未来15天、逐6 h、25 km分辨率的全球预报产品, 涵盖地面和13个气压层的69个气象要素, 有效预报天数达10.5天, 性能位于全球AI模型第一梯队。

2 关键科学问题

AI气象预报的突破不仅带来了技术革新, 更引发了对传统气象预报科学理论体系的深刻思考。在科学基础方面, 如何实现数据驱动与物理驱动的有机统一是首要挑战^[19]。AI方法直接从数据中学习大气演变规律带来了新的科学问题: 数据中蕴含的物理规律是否完备? 学习到的模式是否符合物理定律? 可学习气候模型(learnable climate model, LCM)的理论框架为AI与数值模式的融合提供了思路^[20], 该框架主张将深

度学习算法与传统物理模型视为协同组件, 通过软、硬物理约束的引入, 实现两种范式的有机统一。这一思想在最新的全球AI天气预报模型中有所体现, 如图3所示, 包括三个主要的方向: 物理引导的深度学习架构设计、物理约束的损失函数构建和物理-AI混合建模。在架构设计方面, 如NowcastNet结合物理演化方案和条件学习, 实现了多尺度预报能力; 在损失函数构建方面, “风清”模型设计的能量守恒损失函数通过哈密顿守恒系统约束预报结果, 不仅有助于模型学习到更符合物理规律的大气演变过程, 尤其重要的是, 这种物理约束能够显著提升模型在长时间积分时的稳定性和物理真实性, 避免模型发散或产生明显违背物理常识的预测结果; 在混合建模方面, NeuralGCM由大气动力学求解器和神经网络学习物理过程模块组成, 显著提高了预报清晰度^[21]。

可解释性问题是AI气象预报面临的另一重要挑战^[22]。尽管当前AI模型在预报效果上已超越传统方法, 但其内部运行机制仍较难解释, 限制其在实际应用中的可信度。GraphCast模型使用图神经网络将全球网格看作图节点, 每个节点包含多种气象要素状态, 边表示邻近网格点之间的大气相互作用, 这种设计类似数值模式求解网格点之间的方程, 在一定程度上保留了质量、能量守恒等物理约束特征, 使得模型不会产生明显违背物理定律的预报预测, 有助于提高结果的可信度和部分可解释性; 尽管如此, 由于整个演算过程仍由深度神经网络决定, 缺乏显式方程约束, 使得模拟天气变量之间的关系的物理意义尚未完全明确^[16]。NeuralGCM模型框架通过反向传播训练, 使神经网络学到最优的参数化, 同时物理核




图3 (网络版彩色)人工智能与气象物理机制融合的主要路径与策略示意图

Figure 3 (Color online) Main pathways and strategies for integrating artificial intelligence with meteorological physical mechanisms

提供了基本的稳定性和守恒保障,使得模型的内部过程更透明,通过追踪AI模块输出参数,并对比传统对流参数化物理量,可分析AI学到的新关系,增强了AI模型的可解释性^[21]. 可以看到, GraphCast和NeuralGCM分别通过“软约束”和“硬约束”融入物理概念,表现出一定的可解释性,但未来还需建立起更加完整的可解释理论框架增强模型的透明度. 除了通过模型架构设计和物理约束融入来提升可解释性外,对于广泛应用于气象AI模型的Transformer等架构,其内在的注意力机制也为理解模型提供了可能途径;通过可视化注意力权重,研究者可以分析模型在进行预测时,对输入序列的不同时间步或空间区域的关注程度,例如在预测未来某区域降水时,注意力图谱可能揭示模型重点关注了哪些上游的天气系统或关键的气象要素场,这为理解模型的内部工作机制和诊断潜在问题提供了线索,从而增强模型的透明度和可信度.

在核心预报问题方面,灾害性天气的AI预报能力取得了显著进展. 如Pangu-Weather和GraphCast等全球气象AI模型在台风路径预报方面展现了卓越的性能. Pangu-Weather在台风路径预测中,3天和5天的路径误差分别比欧洲中期天气预报中心(ECMWF)的高分辨率系统降低了26%和28%,显著优于传统数值模式^[3]. 尽管如此,对于复杂极端天气系统(如极端暴雨、台风或气旋强度、雷暴大风、龙卷等)的预报仍面临重要挑战. 极端天气事件通常具有非线性 and 高度复杂的特征,加上样本占比小, AI模型缺乏对因果关系的深层理解,使得AI模型预报极端事件的强度普遍偏弱,并随预报时效的延长偏向平均态^[23]. 此外,在全球变暖背景下,极端天气事件呈现出新的特征,例如更强的降水强度、更快的台风增强速度等,这些对AI模型的泛化能力提出了更高要求^[24].

不确定性量化方面也取得了新的实践突破^[25]. 传统集合预报通过扰动初始场来表征预报不确定性,计算成本高昂. 此外,传统方法在处理复杂非线性天气系统时,可能无法充分捕捉多尺度不确定性. AI方法则开辟了新的途径,通过概率生成模型, AI能够直接学习天气变量的概率分布,从而在降低计算成本的同时提高不确定性量化的精度. 例如, DGMR模型能够在降水预报中同时给出最可能的预报场和不确定性估计^[10]. GenCast模型基于条件扩散模型^[26],在97.2%的场景中,其预测准确性超过了ECMWF的集合预报系统. 尽管如此,如何保证这种不确定性估计的物理合理性,以及如何与传统集合预报方法进行有效融合,仍需深入探讨^[27].

3 重要科学价值

AI气象预报的突破性进展不仅带来了预报能力的提升,更深层次的科学价值在于推动了气象学科基础理论和研究范式的革新. 这种影响将随着技术的深入发展愈发显著.

AI将促进气象科学新发现的潜力. 随着对地球大气的了解加深和观测数据的增加,传统方法面临诸多挑战,比如过度依赖专家经验、模型误差明显、不同尺度作用机制仍有不清楚. 通过人工智能模型能够更好地理解知识、进行复杂的推理并使用各种工具,有望在发现气象科学新规律方面带来机遇. 例如,“风清”模型通过多尺度隐空间投影机制揭示的大气状态转移规律^[17],为理解大气运动提供了新视角. GraphCast模型由于其图结构,在预测过程中自动学习到了长距离的空间关联^[16],相比传统经验方法, AI可以量化这些相关性的时空特征,从而为理论提供定量支撑. 此外,人工智能在气候研究中可通过深度网络揭示非常规的因果关系,也可

以通过生成对比场景来分析极端天气成因,探索AI在极端事件归因等方面的潜力^[28]。例如,可以借鉴生成对抗网络(GANs)或扩散模型(diffusion models)等生成式AI技术,构建“反事实”气候情景;通过生成在不同强迫因子(如仅自然变率影响下的情景vs.包含人为温室气体排放影响的实际情景)下的气候模拟或天气事件样本,AI模型能够帮助量化评估人类活动(如温室气体排放)对特定极端天气事件(如极端暴雨、持续性热浪)发生概率或强度的影响。这类方法有望为传统的基于多模式比较的归因研究提供新的视角和工具,但其在物理过程的真实表征、不确定性量化以及结果的可靠性验证等方面仍需深入探索。上述发现推动了气象科学理论创新的速度和深度。

AI有助于打破地球科学学科壁垒,推动科学研究的产学研用。大气科学、海洋、生态、地理、水文和环境等领域发展相对独立,存在一定程度的知识隔阂和重复研究。现在,数据驱动的人工智能方法能够统一处理这些不同学科的数据,通过广泛的搜索和优化,更好地整合地球系统不同领域的信息,揭示它们之间的复杂关系,促进跨学科的合作和创新^[29]。同时,气象模型发展也能直接支持水文、环境和海洋等相关领域的研究,提供更精准的初始条件或边界条件,帮助这些学科实现更精确的数值模拟。此外,气象信息对于社会的正常运作以及能源、农业、交通和水利等关键行业至关重要,人工智能气象模型在理解知识、高效推理和灵活开发方面的优势,能够帮助产业界快速获取完整的气象信息,部署预报预测模型,并开发适合产业需求的应用模型,从而缩小研究与产业的距离,推动社会经济的绿色转型。

AI与气象科学的深度融合不仅推动气象预报能力提升,也为AI技术本身的发展提供了重要牵引。当前基于尺度扩展规律的人工智能模型遇到了一些问题,比如难以模拟复杂的物理现象、泛化能力不强、需要大量标注数据以及解释性差。与计算机视觉、自然语言处理等领域不同,气象预报面临的是一个具有严格物理约束、高度非线性、多尺度耦合的复杂系统^[27]。这种特殊性对AI技术提出了新的挑战:如何提升模型在复杂物理系统中的泛化能力?如何实现高效学习和准确预测?如何增强模型的可解释性?这些问题的解决将从根本上推动AI技术的进步,有望在高效学习方法、复杂系统建模、因果推理等方面取得关键性突破。

4 总结与展望

在AI与气象预报科学深度融合的背景下,传统学科体系面临重构,需要从基础理论研究、学科发展、应用推广、人才培养等方面进行前瞻性布局。

在基础理论层面,首要任务是探索AI与传统物理机制深度融合的新范式。包括开展可微分物理建模技术,将物理方程直接嵌入深度学习架构;探索基于神经常微分方程的混合建模方法,通过学习动力学系统演化规律提升长时效预报能

力;构建多尺度耦合的物理-AI融合框架,有效处理从对流尺度到行星尺度的大气运动。这一融合思想也开始向更长期的气候预测与模拟领域延伸,例如利用深度学习(如LSTM、Transformer架构)构建AI气候模型,探索其在长期气候变量预测方面的潜力。虽然这类AI气候模型在计算效率和捕捉复杂非线性过程上可能展现优势,但在长期积分的稳定性、物理一致性、对气候反馈机制的准确刻画以及极端气候事件的模拟能力等方面仍面临巨大挑战^[30,31]。此外,正如Huang等人^[20]所指出,还需进一步探索此类融合的理论完备性,需要从数学物理的层面,建立连接AI与传统物理方程的理论桥梁,形成新的科学认知框架。特别是,需要研究如何将深度学习的统计特性与物理定律的确定性有机统一,这可能需要发展新的数学工具和物理理论。其次,构建新天气预报理论体系是另一个重要方向。传统预报理论建立在确定性物理方程基础上,而AI方法引入了概率统计的视角。这种范式转变要求我们重新思考预报理论的基本问题:什么是预报的本质?如何定义和度量预报的不确定性?如何在新框架下理解大气的可预报性?这些问题的解答将推动预报理论的革新,形成更完备的理论体系。

在学科发展层面,需要加强跨学科交叉研究。AI气象预报的发展涉及气象学、数学、计算机科学、物理学等多个领域,需要建立有效的学科交叉机制。建议重点支持三个方向的交叉研究:一是AI基础理论与大气物理的交叉,探索机器学习在复杂物理系统中的应用基础;二是计算数学与气象模拟的交叉,发展新型数值方法;三是信息科学与天气预报的交叉,推动预报技术的革新。基础理论创新是推动学科发展的关键。当前需要重点突破三个方向:一是发展适应气象特点的AI理论,包括物理信息引导的深度学习(如引入物理守恒律作为损失函数或网络层约束,以增强预报的物理一致性和长期稳定性)、面向时空序列的新型网络结构(如Transformer及其变种在捕捉长程时空依赖中的应用),以及增强模型透明度和可信度的可解释性AI技术(如注意力机制可视化、因果推断方法在AI气象模型中的应用探索)等;二是构建预报不确定性的数学理论,统一确定性动力学与概率预报;三是建立数据驱动的科学发现方法论,为利用AI发现新的大气物理规律提供理论指导。

在应用推广层面,人工智能将为联合国“全民早期预警”倡议提供重要支撑已成为共识,但如何实现人工智能气象模型的全球各区域适用还面临挑战,包括:观测数据的不均匀分布,使得数据稀疏区域的预报误差显著高于数据密集区域;气候背景的区域差异,不同地区的天气系统具有独特特征,这些差异使得针对特定区域优化的模型难以在全球范围内保持一致的性能;计算资源的平衡,高分辨率模型的训练需要海量计算资源。为此,需要加强以下方向的研究:一是发展面向数据稀疏地区的半监督学习方法,减少对标记数据的依赖;二是构建具有气候区域自适应能力的模型架构,自动调

整对不同气候区域的处理策略；三是开发分层建模框架，平衡全球一致性与区域特异性。这些方向的突破将显著提升AI气象模型的全球应用能力，为构建真正全球一体化的智能预报系统奠定基础。

人才培养体系的创新也亟需关注。传统的气象人才培养以物理和数学为基础，而AI时代需要复合型人才。需要从三个方面改革人才培养体系：一是强化数理基础，特别是概率统计和机器学习理论的教育；二是加强计算思维训练，提升

程序设计和数据分析能力；三是注重科学素养培养，培养学生发现问题、提出问题的能力。同时，要建立灵活的人才培养机制，促进不同学科背景人才的交流与合作。

展望未来，AI将持续深刻影响气象科学的发展。要抓住这一历史机遇，既要保持战略定力，扎实推进基础理论研究，又要有创新勇气，积极探索新的科学范式。只有坚持理论创新与技术革新并重，才能推动气象科学在AI时代实现新的跨越，为人类更好地认识和预测天气气候变化提供科学支撑。

致谢 感谢国家自然科学基金气象联合基金(U2342217)、国家重点研发计划(2021YFC3000905)和中国气象局重点创新团队智能预报技术团队项目(CMA2022ZD04)资助。

推荐阅读文献

- Huang J, Chen B. How artificial intelligence is transforming weather forecasting for the future (in Chinese). *Chin Sci Bull*, 2024, 69: 2336–2343 [黄建平, 陈斌. 人工智能技术在未来改进天气预报中的作用. *科学通报*, 2024, 69: 2336–2343]
- Mu M, Qin B, Dai G. A commentary of “Artificial intelligence models bring new breakthroughs in global accurate weather forecasting”: top 10 scientific advances of 2023, China. *Fundamental Res*, 2024, 4: 690–692
- Bi K, Xie L, Zhang H, et al. Accurate medium-range global weather forecasting with 3D neural networks. *Nature*, 2023, 619: 533–538
- Zhang Y, Long M, Chen K, et al. Skilful nowcasting of extreme precipitation with NowcastNet. *Nature*, 2023, 619: 526–532
- Espeholt L, Agrawal S, Sønderby C, et al. Deep learning for twelve hour precipitation forecasts. *Nat Commun*, 2022, 13: 1
- Ebert-Uphoff I, Hilburn K. The outlook for AI weather prediction. *Nature*, 2023, 619: 473–474
- Sønderby C K, Espeholt L, Heek J, et al. MetNet: a neural weather model for precipitation forecasting. *Adv Neural Inf Process Syst*, 2020, 33: 12933–12944
- Sønderby C K, Espeholt L, Heek J, et al. MetNet-2: neural weather forecasting for 12-hour lead time. 2021, arXiv: 2105.03426
- Andrychowicz M, Espeholt L, Li D, et al. Deep learning for day forecasts from sparse observations. 2023, arXiv: 2306.06079
- Ravuri S, Lenc K, Willson M, et al. Skilful precipitation nowcasting using deep generative models of radar. *Nature*, 2021, 597: 672–677
- Shi X, Chen Z, Wang H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting. *Adv Neural Inf Process Syst*, 2015, 28: 802–810
- Bauer P, Thorpe A, Brunet G. The quiet revolution of numerical weather prediction. *Nature*, 2015, 525: 47–55
- Rasp S, Thuerey N. Data-driven medium-range weather prediction with a resnet pretrained on climate simulations: a new model for weatherbench. *J Adv Model Earth Syst*, 2021, 13: e2020MS002405
- Weyn J A, Durran D R, Caruana R, et al. Sub-seasonal forecasting with a large ensemble of deep-learning weather prediction models. *J Adv Model Earth Syst*, 2021, 13: e2021MS002502
- Pathak J, Subramanian S, Harrington P, et al. FourCastNet: a global data-driven high-resolution weather model using adaptive Fourier neural operators. 2022, arXiv: 2202.11214
- Lam R, Sanchez-Gonzalez A, Willson M, et al. Learning skillful medium-range global weather forecasting. *Science*, 2023, 382: 1416–1421
- Wu H, Hu T, Luo H, et al. Solving high-dimensional PDEs with latent spectral models. In: *Proceedings of the 40th International Conference on Machine Learning*, Hawaii, 2023
- Xing L, Wu H, Ma Y, et al. HelmFluid: learning Helmholtz dynamics for interpretable fluid prediction. In: *Proceedings of the 41st International Conference on Machine Learning*, Vienna, 2024
- Reichstein M, Camps-Valls G, Stevens B, et al. Deep learning and process understanding for data-driven Earth system science. *Nature*, 2019, 566: 195–204
- Huang G, Wang Y, Ham Y G, et al. Toward a learnable climate model in the artificial intelligence era. *Adv Atmos Sci*, 2024, 41: 1281–1288
- Kochkov D, Yuval J, Langmore I, et al. Neural general circulation models for weather and climate. *Nature*, 2024, 632: 1060–1066
- Yang R. Interpretable machine learning for weather and climate prediction: a survey. 2024, arXiv: 2403.18864
- Ben Bouallège Z, Clare M C A, Magnusson L, et al. The rise of data-driven weather forecasting: a first statistical assessment of machine learning-based weather forecasts in an operational-like context. *Bull Am Meteorol Soc*, 2024, 105: E864–E883

- 24 Rackow T, Koldunov N, Lessig C, et al. Robustness of AI-based weather forecasts in a changing climate. 2024, arXiv: 2409.18529
 - 25 Schreck J S, Gagne D J, Becker C, et al. Evidential deep learning: enhancing predictive uncertainty estimation for Earth system science applications. 2024, arXiv: 2309.13207
 - 26 Price I, Sanchez-Gonzalez A, Alet F, et al. Probabilistic weather forecasting with machine learning. *Nature*, 2025, 637: 84–90
 - 27 Mu M, Qin B, Dai G. Predictability study of weather and climate events related to artificial intelligence models. *Adv Atmos Sci*, 2025, 42: 1–8
 - 28 Chen D L, Tan X C, Peng Z, et al. Opportunities and challenges of artificial intelligence in climate research and services (in Chinese). *Clim Change Res*, 2024, 20: 669–681 [陈德亮, 谭显春, 彭喆, 等. 人工智能在气候研究和服务中的机遇与挑战. *气候变化研究进展*, 2024, 20: 669–681]
 - 29 Zhao T, Wang S, Ouyang C, et al. Artificial intelligence for geoscience: progress, challenges, and perspectives. *Innovation*, 2024, 5: 100691
 - 30 Wu H, Gao Y, Shu R, et al. Advanced long-term earth system forecasting by learning the small-scale nature. 2025, arXiv: 2505.19432
 - 31 Zhang G, Rao M, Yuval J, et al. Seasonal prediction with neural GCM and simplified boundary forcings: large-scale atmospheric variability and tropical cyclone activity. 2025, arXiv: 2505.01455
-

补充材料

表S1 全球主流气象AI模型性能综合对比表

本文以上补充材料见网络版csb.scichina.com. 补充材料为作者提供的原始数据, 作者对其学术质量和内容负责.

Summary for “人工智能在气象预报中的突破性进展与科学价值”

Breakthrough progress and scientific value of artificial intelligence in weather forecasting

Xinyuan Bi¹ & Kan Dai^{2*}

¹ School of Mathematical Sciences, Capital Normal University, Beijing 100048, China

² National Meteorological Center, Beijing 100081, China

* Corresponding author, E-mail: daikan@cma.gov.cn

The field of weather forecasting is undergoing a profound paradigm shift, driven by rapid advancements in artificial intelligence (AI) that challenge the dominance of traditional numerical weather prediction (NWP). This review provides a comprehensive synthesis of the breakthrough progress of data-driven weather forecasting in meteorology, critically examining its technical foundations, scientific implications, and future potential. The motivation for this transformation stems from the escalating societal demand for more accurate, timely, and computationally efficient forecasts to mitigate the impacts of severe weather extremes, a need amplified by a changing global climate. While NWP models rely on the explicit numerical integration of atmospheric governing equations, data-driven AI models learn the complex, non-linear dynamics of atmospheric evolution directly from vast repositories of historical reanalysis and observational data. This fundamental change in methodology has yielded orders-of-magnitude improvements in computational speed, enabling rapid-update cycles, high-resolution outputs, and large-ensemble generation at a fraction of the traditional cost.

Significant achievements have been documented across all forecast timescales. In the nowcasting (0–2 h) and short-range (2–24 h) domains, deep learning architectures have delivered unprecedented performance gains. Models such as Google’s MetNet series and the CMA-Tsinghua “Fenglei” (NowcastNet) have established new benchmarks. MetNet-3 provides precipitation forecasts at 1 km spatial resolution with 2-minute temporal updates for up to 24 h. Concurrently, Fenglei, the first operational deep-learning nowcasting model at National Meteorological Center, extends the skillful prediction of extreme precipitation from the conventional 1–2 h limit to 3 hours by uniquely embedding physical constraints within a multi-scale generative framework. These models substantially outperform traditional extrapolation and NWP-based systems in capturing the genesis, evolution, and decay of rapidly developing severe weather events.

For medium-range (3–15 d) global forecasting, a cohort of landmark AI models—including Huawei’s Pangu-Weather, Google DeepMind’s GraphCast, Shanghai AI Lab’s FengWu, and the CMA-Tsinghua “Fengqing”—has demonstrated the capacity to match or exceed the skill of the world’s leading NWP systems, such as the ECMWF Integrated Forecasting System (IFS). Pangu-Weather and GraphCast, for instance, deliver 10-day global forecasts in minutes, with superior accuracy in key metrics like RMSE and ACC for critical variables and demonstrating remarkable skill in tropical cyclone track prediction. The operational deployment of ECMWF’s AIFS and CMA’s Fengqing signals the formal entry of AI into the global operational forecasting landscape.

This technological leap forwards raises pivotal scientific questions. A central challenge is the optimal integration of physical principles with data-driven architectures. Promising pathways include the design of physics-informed network structures, the incorporation of physical conservation laws (e.g., energy conservation) into loss functions to enhance long-term stability, and the development of hybrid models that couple neural networks with traditional physics cores. The inherent “black box” nature of deep learning also necessitates advances in interpretability, for which model designs like GraphCast’s graph neural network and the analysis of attention mechanisms in Transformers offer promising avenues. Furthermore, while AI models excel at predicting certain extreme phenomena, accurately forecasting their intensity and lifecycle, especially under non-stationary climate conditions, remains a formidable challenge. Concurrently, AI-based generative and diffusion models are revolutionizing uncertainty quantification, offering computationally inexpensive, high-skill probabilistic ensembles that challenge traditional methods, although their physical consistency requires rigorous verification.

The scientific value of these breakthroughs extends far beyond improved forecast skill. AI models serve as new instruments for atmospheric science, capable of revealing previously obscured statistical-physical relationships, enabling novel counterfactual experiments for climate attribution studies, and facilitating an integrated Earth system science approach by breaking down disciplinary barriers. The demanding nature of weather prediction, with its complex, multi-scale, and physically constrained dynamics, simultaneously acts as a powerful catalyst for fundamental AI research. To fully realize this potential, future efforts must focus on establishing a robust theoretical foundation for physics-AI integration, developing comprehensive methods for uncertainty quantification, and fostering a new generation of interdisciplinary talent. This convergence of AI and atmospheric science is poised not only to revolutionize weather and climate prediction but also to advance the fundamental understanding of the Earth system, thereby strengthening global resilience to environmental hazards.

data-driven weather forecasting, artificial intelligence, numerical weather prediction, physical–AI integration, uncertainty quantification, operational meteorology

doi: [10.1360/TB-2025-0128](https://doi.org/10.1360/TB-2025-0128)