

## 人工智能技术在未来改进天气预报中的作用

黄建平<sup>1,2\*</sup>, 陈斌<sup>1,2</sup>

1. 西部生态安全省部共建协同创新中心, 兰州 730000;
2. 兰州大学大气科学学院, 兰州 730000

\* 联系人, E-mail: [hjp@lzu.edu.cn](mailto:hjp@lzu.edu.cn)

天气预报一直是一个复杂而充满挑战的领域。由于大气系统是高度非线性, 即使极其微小的变化也可能对大气运动产生不可预知的扰动, 这种大气中普遍存在的“蝴蝶效应”也正是天气预报的难点所在<sup>[1]</sup>。长期以来, 天气预报主要依赖于传统的数值天气预报模型。随着具有非线性学习能力的深度学习技术的崛起, 气象领域开始应用人工智能模型。人工智能 (artificial intelligence, AI) 模型在短时预报、气象图像处理以及气候模拟等在内的多个气象领域的应用均有重要的突破<sup>[2,3]</sup>。

人工智能模型本质就是大数据模型<sup>[4]</sup>, 当数据量不足时, 模型结果容易受到输入数据的微小变化而产生较大波动, 降低模型的可靠性。由于极端天气事件相对较少, 缺乏足够的训练数据将会导致 AI 模型无法准确捕捉和模拟极端事件突变过程, 从而增加了预测结果的不确定性。与 AI 模型不同, 大气动力模型是基于物理定律的大气运动方程组来预测大气状况, 能够更好地捕捉到大气中各种物理过程和突变过程的演变<sup>[5]</sup>。

本文解读 2023 年度 Science10 大科学突破中的“AI 辅助天气预报的发展”, 探讨大气动力模型和人工智能模型的深度融合范式, 并建议发挥两者的优势, 提高对极端天气和气候预测的准确性。

### 1 人工智能在天气预报中的应用和挑战

人工智能旨在理解智能的本质, 生产一种能以人类智能相似的方式做出反应的智能机器, 是模拟和扩展人类智能的理论方法及应用的新兴科学。人工智能大致历经了五个发展阶段, 从 20 世纪 40 年代的起步发展期, 符号主义和联结主义

---

等算法被提出。由于计算力和理论匮乏导致 AI 陷入低谷，到 20 世纪 70 年代进入反思发展期。再到 20 世纪 80 年代的应用发展期，这个阶段专注于专家系统和机器学习，例如贝叶斯网络和卷积神经网络等。直到 2010 年以前，AI 一直是平稳发展期，涌现了支持向量机、长短期记忆神经网络和随机森林等算法。2011 年至今，随着大数据、云计算和物联网的兴起，深度学习理论取得了显著突破，AI 进入了蓬勃发展期，代表算法包括 AlphaGo、ChatGPT、Claude-3 和 SORA 等。

1984 年，两个灾害性雷暴预报系统标志着人工智能技术成功用于天气预报，一个是美国国家海洋和大气管理局的 WILLARD 用于预报美国中部的灾害性雷暴，另一个是加拿大环境局的 SWIFT 系统<sup>[6]</sup>。随着气象观测数据和数值天气预报模式（数据中包含大气物理机制）数据的爆炸性增长，循环神经网络、卷积神经网络和 Transformer 等深度学习架构在捕捉大气物理量之间的时间依赖、时空关联和中长期特征建模上展现出优越的性能，在应对复杂、多变的大气系统中具备优势，AI 模型为精准天气预报和气象领域研究提供了新的视角<sup>[7~9]</sup>。

“气象学家们利用现代计算机技术模拟大气未来状态，开创了依托大量计算能力求解控制大气的流体动力学方程的现代数值天气预报学。然而，AI 开始改变了这一局面。谷歌、华为和英伟达在内的科技公司训练出能够预测未来天气的 AI 气象大模型，其准确度能够与传统模型相媲美，甚至超过传统数值模型”<sup>[10]</sup>。目前，全球主流的 AI 气象大模型主要集中于中短期天气预报，以提供更为精细的短期天气预测结果，包括华为云的 Pangu-Weather、英伟达的 FourCastNet、谷歌 DeepMind 的 GraphCast、清华大学和中国气象局的 NowcastNet、复旦大学开发的伏羲模型和上海人工智能实验室的风乌模型等。

华为云的盘古气象大模型（Pangu-Weather，结构如图 1 所示）是首个精度超过传统数值预报方法的 AI 模型，且速度提高了 1 万倍以上；Pangu-Weather 基于三维神经网络的气象预报系统，采用了标准的编码器-解码器设计结构，分别从 1、3、6 和 24 h 的时间尺度进行超前预测<sup>[11]</sup>。不过盘古气象大模型在不同气候条件下的泛化能力还没得到全面验证。英伟达提出的 FourCastNet 是一种基于傅里叶变换的 token 混合方法和 ViT（Vision Transformer，视觉自注意力模型）的神经网络预测模型，其以 0.25 分辨率生成全球关键大气变量的数据驱动预测

[12]。这项成果使得 AI 气象模型首次能够与传统物理模型（欧洲天气中心的 IFS 系统）进行直接比较，但是其预报精度仍然大幅落后于数值预报方法。谷歌 Deepmind 发布了一种以图神经网络为骨干网络的天气预报大模型 GraphCast（图 2），将原始经纬度网格的输入数据映射到多网格的学习特征中，设计了基于物理动力学的空间交互模式，大幅提升气象物理量预测精度的同时，也较为有效地预测极端重要事件<sup>[13]</sup>。GraphCast 的性能主要受气象数据质量的影响，数据的缺失或不准确可能影响其预测结果。

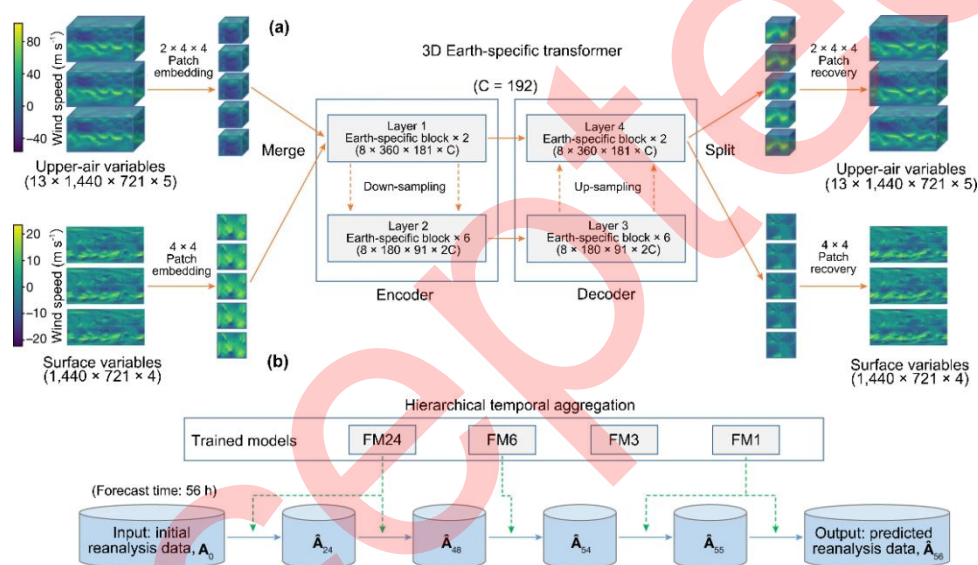


图 1 Pangu-Weather 的 3DEST（3D Earth-Specific Transformer，适应地球坐标系统的三维神经网络）架构。（a）3DEST 架构。3DEST 利用编解码器和块技术处理三维天气数据，并使用针对地球数据优化的位置偏差来加快模型收敛速度。（b）分层时间聚合算法。FM1、FM3、FM6 和 FM24 分别表示提前期为 1、3、6 和 24 h 的预测模型。将 56 h 预测简化为 2 次 24 h、1 次 6 h 及 2 次 1 h 模型运算以减少迭代次数<sup>[11]</sup>

Figure 1 Pangu-Weather's 3DEST (3D Earth-Specific Transformer). (a) 3DEST architecture. The 3DEST processes 3D weather data using codecs and block techniques and utilizes positional biases optimized for Earth data to accelerate model convergence. (b) Hierarchical temporal aggregation algorithm. Forecast models FM1, FM3, FM6, and FM24 correspond to lead times of 1, 3, 6, and 24 h, respectively. The 56 h forecast is streamlined by using two 24 h, one 6 h and two 1 h model runs, thus minimizing the number of iterations<sup>[11]</sup>

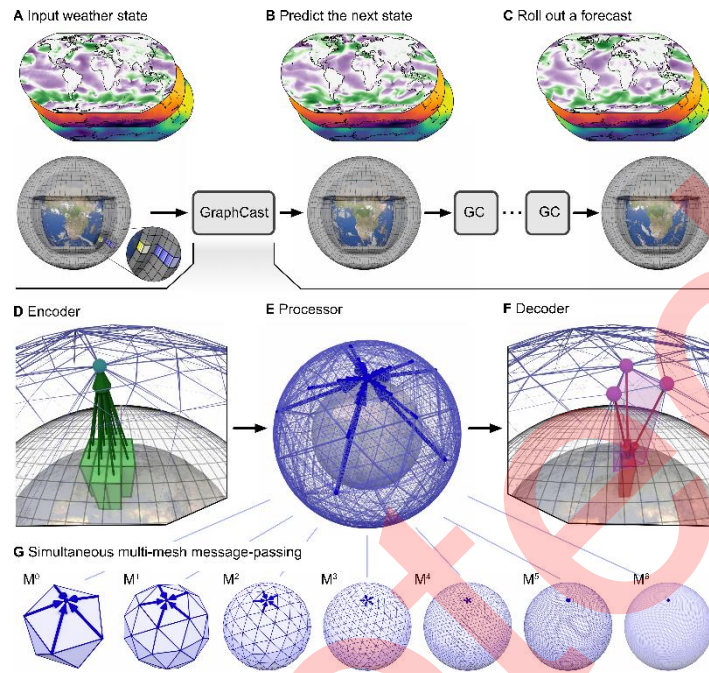


图 2 Deepmind 的 GraphCast 架构。GraphCast 使用图神经网络（Graph Neural Network, GNN）模型，将原始经纬度网格的输入数据映射到多网格上的学习特征中。该模型 60 s 内可预测 10 d 内的天气状况<sup>[13]</sup>

**Figure 2** Deepmind's GraphCast architecture. GraphCast utilizes a Graph Neural Network (GNN) to convert input data from raw latitude and longitude grids into derived features across multiple grids. It efficiently predicts weather conditions for a 10-d forecast in 60 s<sup>[13]</sup>

清华大学和中国气象局提出的 NowcastNet 大模型，模型的核心是端到端建模降水物理过程的神经演变算子，实现了深度学习与物理规律的无缝融合。基于六年的雷达观测资料，完成极端降水临近预报大模型的训练，可以对强降水的强度、落区和运动形态等给出清晰、准确的预报结果<sup>[14]</sup>。伏羲大模型由复旦大学人工智能研究院推出，采用了一种级联的 U-Transformer 架构，能提供 15 天全球预报，将 AI 天气预报精度提升到 ECMWF 集合平均相当的预报水平<sup>[15]</sup>。然而其预报时间在 9 d 后便会出现性能下降的情况，且伏羲的预测依赖于 ECMWF 的 ERA5 再分析数据集，无法完全独立于传统的数值天气预报模型。上海人工智能实验室联合发布的全球中期天气预报大模型“风鸟”（FengWu），通过将多个气象要素视为不同的模态，利用基于 Transformer 的多模态网络和多任务训练模式

---

实现不同模态之间的信息共享，实现了 30 s 内生成未来 10 d 的全球高精度预报结果，并在 80% 的评估指标上超越 DeepMind 发布的模型 GraphCast<sup>[16]</sup>。和其他 AI 模型一样，风乌也面临着数据和计算的挑战，而且随着气候的不断变化，风乌需要持续的更新以保持准确性。

自盘古大模型在中短期天气预报的精度首次超过传统数值模型后，挖掘人工智能大模型在气象领域的潜力成为当前研究趋势。人工智能的优势和价值体现在以下几个方面：（1）自动化处理大规模数据：人工智能技术实现了对大规模数据的自动处理<sup>[17]</sup>，这一优势对于现代社会日益增长的数据量至关重要。（2）强大的泛化能力：模型的泛化能力是衡量人工智能算法性能的关键指标，强大的泛化能力意味着模型在面对新数据时能够做出准确的预测，而不仅仅依赖于已知数据的表现。（3）自主学习能力强：通过不断接收新数据并调整模型参数，人工智能系统能够自我优化和改进，逐步提高性能水平，这种自主学习的过程使得系统更具适应性，能够应对非线性和动态的问题，适应于多样化的任务和环境<sup>[18, 19]</sup>。

当然，人工智能在气象预测中也面临着一些局限和挑战：

（1）缺乏可解释性：正如 *Science* 报道“和大多数人工智能模型一样，人们并未真正了解它们所学习到的模式是什么”。人工智能模型在学习过程中可能会捕捉到数据中复杂的非线性关系和交互效应，而这些关系很难通过简单的规则或公式来表示。缺乏可解释性会降低人们对人工智能模型的信任度，尤其是在涉及到重要决策或安全问题时。尝试开发融合物理可解释的模型以解决该问题，还可以结合外部解释性技术来分析模型的预测结果，以便理解模型的决策过程。

（2）数据的不确定性：由于监测设备故障或维护问题导致的数据缺失，气象数据可能存在缺失、不准确或不完整的情况，还可能受到环境干扰或技术限制而带有噪声，这会干扰模型的学习过程，影响模型的训练和预测准确性。使用数据清洗技术和校正算法来处理噪声和缺失值，可以提高数据的质量。目前，AI 模型以海量数据为基础，华为盘古、谷歌 Deepmind 和伏羲等模型均依靠 ECMWF 的 ERA5 再分析数据训练模型，无法完全独立于传统的数值天气预报模型。整合多源数据，以弥补单一数据源的不足，也能提高数据的完整性和准确性。

（3）模型可迁移性：气象领域的数据和问题多种多样，当我们面对不同区

---

域和时间的天气预报和气候变化问题，模型需要具备足够的可迁移性和泛化能力。目前 AI 模型难以做到像数值模式一样开展全要素、全时空的模拟和预测。不同地区的气象现象可能表现出不同的特点，训练好的模型可能无法有效适应新的地区。此外，气象现象的变化具有不同的时间尺度，模型难以同时从小时、季节和年代际尺度的同时进行预测。可以根据不同地区的气象特点，调整模型参数或结构，开发能够处理不同时间尺度的模型，以提高模型的多尺度泛化能力和预测准确性。

(4) 对极端事件预测准确度不足：AI 需要大量的历史气象数据作为训练样本，以了解不同的天气情况和模式。然而，极端天气事件的发生相对较少，可用于训练模型的数据相对有限。这意味着模型可能没有足够的样本来学习和理解这些极端天气事件的复杂性。因此，在极端天气和突发天气的场景中，AI 大模型还需要其他模型的辅助。可利用小样本平衡策略和物理机制——生成式模型扩充极端天气等特殊条件下的大气样本，提高 AI 模型的天气预报准确度。

## 2 数值模式和人工智能的融合

数值天气预报（NWP）长期是天气预报领域的基石，它是基于大气动力模型和计算机技术，将大气动力偏微分方程在有限的网格上离散化进行数值化处理，提前数天到数周预测天气的状况，是一种现代化和科学化的天气预报方法。与传统的天气学方法相比，数值天气预报是以大气动力模型为基础，通过对大气和海洋等要素进行数值计算，预测未来一段时间内的天气变化。大气动力模型是基于 Navier-Stokes 方程、热力学方程、及质量、动量和能量守恒等物理定律，它为数值天气预报模式（数值模式）提供了可靠的数理框架。从早期的简单一维模型到复杂的三维全球模型，数值天气预报模型不断提升对大气复杂性的解析能力，为天气预报提供了坚实的理论基础。

早在 20 世纪 50 年代，顾震潮<sup>[20]</sup>就指出“数值天气预报存在一个比较根本性的缺陷，就是只使用一个时刻的资料，大量的历史资料没有用”。近年来不断发展的 AI 技术，通过学习历史气象资料，在天气预报领域中表现优异<sup>[21]</sup>。这两种技术各有优势和局限性，未来的研究应该致力于充分发挥两者的优势，将数值天气预报与人工智能相融合，以提高天气预报预测的精度和准确性。数值模式和人

---

工智能相互融合可以从以下 4 个方面展开.

## 2.1 利用 AI 技术优化数值模式

气象系统具有多时空尺度的复杂性,尤其是云、辐射和降水等细小尺度物理过程。数值模式的半经验参数化方案(即次网格过程,尺度小于最小离散网格间距)简化了对这些复杂物理过程,这样带来很大的近似误差和不确定性。这些参数化方案的制定需要从大量历史观测数据的规律中提取和学习,面临着计算任务密集、数据时空尺度多样以及气象过程的非线性优化等问题。而人工智能技术,尤其是深度学习等方法,能够更准确地捕捉这些大气微观尺度过程的复杂特征。已有学者在对流参数化<sup>[22,23]</sup>、云微物理学过程<sup>[24,25]</sup>和辐射传输<sup>[26,27]</sup>等参数化方案中应用了神经网络等深度学习方法,证实了 AI 融入数值模式参数化的可行性和潜力。人工智能技术的优势不仅在于能够精确捕捉复杂气象过程的细节,还在于提供了处理大规模复杂数据的工具和框架,以实现复杂系统的快速学习和自我优化。

传统数值预报模型的预报精度受到许多因素的影响,例如初始条件、边界条件和物理参数化方案的选择等,这些因素都会导致预报误差。而 AI 可以自动学习历史气象数据中的规律和趋势,发现数据中存在的隐含错误,对数值预报结果进行精准的订正和优化。但是,这种方法也存在一些挑战,例如需要大量的数据和计算资源,需要对模型中的许多参数进行调整和优化等,同时需要验证和测试模型的实际效果。未来的研究应该不断完善深度学习模型等 AI 技术在气象参数化和数值预报误差订正等方面应用,以推动 AI 辅助数值模式对细小尺度过程的精确参数化取得更大的突破和进展。

## 2.2 更高精度的数据同化技术

1963 年,美国气象学家洛伦兹通过对描述大气热对流的非线性偏微分方程组进行傅里叶展开,并大胆地对其截断,最终导出了描述垂直速度、上下温差的三维自治动力系统(式(1))<sup>[1]</sup>,这一发现揭示了混沌动力学在大气科学中的重要性。

$$\begin{cases} \dot{x} = P(y - x) \\ \dot{y} = Rax - y - xz, \\ \dot{z} = xy - bz \end{cases} \quad (1)$$

式中,  $x$  表示大气流体运动的强度,  $y$  和  $z$  分别表示水平和垂直方向的温度梯度,  $P$  是普兰特数 (Prandtl 数),  $Ra$  是瑞利数 (Rayleigh 数),  $b$  是系统参数和几何形状相关。




图 3 利用  $R-T$  方法根据式(1)计算得到的洛伦兹混沌系统“蝴蝶效应”的示意图, 其中  $P=10$ ,  $Ra=28$ ,  $b=8/3$

Figure 3 Schematic of the “Butterfly Effect” in a Lorenzian chaotic system. This is calculated using the  $R-T$  method based on Eq. (1), with parameters  $P=10$ ,  $Ra=28$ , and  $b=8/3$

如图 3 所示, 事物发展既有规律又充满变数, 初始条件对问题解的影响极其敏感。在动态系统中, 微小的初始条件变化可导致截然不同的事件发展, 形成巨大链式反应。大气混沌性使得数值天气预报对初始条件具有极高的敏感度, 尽管现代动力模型已经融合了较为复杂的数据同化技术, 但仍然需要提高数据同化的精度以减少初始条件误差。一些研究人员已经尝试将神经网络等深度学习技术与传统的卡尔曼滤波器<sup>[28]</sup>以及四维变分同化等技术<sup>[29]</sup>相结合, 以达到更高效的数据同化效果。通过利用人工智能技术识别关键的气象或环境特征, 并进行不同时空尺度的数据插值和空间降维, 可以提高数据同化的效率和准确性。将观测数据的信息融入到物理模型中, 并通过模型的预测结果来解释观测数据。数据同化的精度是影响 NWP 准确性的关键因素之一, 深度学习和人工智能技术的发展为改



---

善 NWP 的初始条件提供了新的思路，未来的研究需要继续优化和改进这些新型的数据同化技术，尤其是在处理海量、高维、动态变化的气象数据上，人工智能有着巨大的潜力和应用前景<sup>[30,31]</sup>。

### 2.3 基于 AI 的集合预报

不同数值模型的物理假设和参数化方案差异导致预报结果存在差异，而训练数据的局限性、模型结构和超参数选取的区别也使得不同的 AI 预报模型对不同尺度天气系统预测表现不一。多模式集合预报通过统计和分析预报解之间的差异来量化预报的不确定性。借鉴数值预报的多模式集合预报策略，基于 AI 的集合预报方法能够进一步提高集合预报的准确性和可信度。生成模型方法可以从历史观测和预报数据中学习数据的分布和结构，然后生成多个合成的预报结果。模型集成方法根据不同的初始条件或参数扰动设置，训练多个独立的机器学习模型或深度学习模型，将它们进行融合以获得更可靠和准确的集合预报。增强学习方法通过训练智能代理来优化模型参数，根据预报的反馈信息调整模型参数，并输出最优的预报结果，更好地反映预报的不确定性<sup>[32]</sup>。

基于 AI 的集合预报方法能够提升表征不确定性的能力，改进预报的精度和可靠性。然而，这些方法在应用时面临处理大规模数据、模型的训练和校准、算法和参数的选择等挑战。在实际应用中，需要结合实际需求和数据特点，选择合适的方法，并进行充分的评估和验证。

### 2.4 大气动力模式与 AI 相结合的模式

人工智能在进行短期或平稳的预测方面具有优势，但无法对于极端天气进行的准确预测，尤其是成因复杂的极端天气过程。图 4 给出了大气中最经典的纬向环流向经向环流的突变过程。这种突变过程是 Charney<sup>[33]</sup>在 1979 年提出的高截谱模式，它是 Lorenz 模型的进一步改进，这个模型尽管简单，却抓住了大气非线性过程，大气中的所有极端天气过程基本上是这种突变过程的结果。虽然 AI 模型也许可以很好预测突变前和突变后的天气，却无法精确捕捉和预测突变过程本身。正如 *Science* 指出：“AI 模型并非完美，它们在预测飓风强度等重要特征方面仍存在困难”<sup>[10]</sup>，这主要是由于 AI 模型擅长预测时间序列的连续变化问题，

难以处理这种非连续突变问题。




图 4 根据 Charney 的 6 截谱模型<sup>[33]</sup>计算得到，该模型能够根据热力过程和动力过程等因素的变化模拟大气中的突变过程，其中  $\psi_k$  反映了海陆热力差异的变化。(a) 海陆热力差异弱时为典型的纬向环流；(b) 随着  $\psi_k$  变化，纬向环流向经向环流转变的突变过程；(c) 海陆热力差异强时为典型的经圈环流

**Figure 4** Derived from Charney's 6-intercept spectral model<sup>[33]</sup>, which simulates abrupt atmospheric processes influenced by thermal and dynamical factors, with  $\psi_k$  reflecting changes due to sea-land thermal differences. (a) Typical latitudinal circulation under weak sea-land thermal differences. (b) A rapid transition from latitudinal to meridional circulation as  $\psi_k$  changes. (c) Typical meridional circulation under strong sea-land thermal differences

为此，如何将大气动力模型和 AI 模型相结合进行天气预报是有待深入探讨的问题。丑纪范最早在国际上提出了在数值天气预报中使用历史资料来考虑场演变的时间连续性问题<sup>[34]</sup>。黄建平和衣育红<sup>[35]</sup>给出了结合数学建模和人工智能例子，他们利用观测资料反演了 Lorenz 非线性模型。此外，黄建平等人<sup>[36,37]</sup>提出将动力和统计方法相结合的相似-动力模式，并经过改进提升了中期预报水平<sup>[38]</sup>。王会军等人<sup>[39]</sup>提出年际增量气候预测方法，通过叠加前一年观测信息，很好地解决了年代际趋势问题，显著改进了中国东北地区夏季气温季节性预测<sup>[40]</sup>。

AI 技术能够建立数据驱动的模式，通过充分学习历史数据捕捉过去天气中的模态和趋势，弥补数值模式无法考虑历史数据的不足。动力模式或物理知识为约束的预报模块的引入，能够使得 AI 在训练和预测过程中遵循物理规律，提高模型的可解释性。大气动力模式与 AI 模式的结合是天气预报和气候预测领域未

---

来研究的一个重要方向。

### 3 结语

人工智能的迅速发展引发了广泛关注，其优异的算力和应用前景让人们充满期许和关切，为突破现有天气预报瓶颈提供了新的契机。由理论驱动的动力模型和由数据驱动的人工智能模型通常被视为两个不同的领域，事实上这些技术是互补的<sup>[41]</sup>。在未来，天气预报技术需要深度融合动力模型和 AI 模型，并借助智算中心和多学科交叉研究等解决现有的难题。

气象学和信息科学之间的跨学科合作有利于推动数值模式和人工智能的融合发展。建议设立共同的研究项目和建立跨学科团队等，解决复杂的大气科学和气候变化的问题<sup>[42]</sup>。同时，建立数据集、模型和新型工具的共享机制，整合不同学科的专业知识和技能，推动各学科成果在气象领域的转化，为气象预测研究提供新动能。

未来的天气预报系统将朝向更为个性化、实时更新和自动化的方向发展。通过将大气动力模型与 AI 模型深度融合，不仅可以进一步显著提升天气预报的准确率和效率，还能为用户提供可靠且定制化的气象信息分析和决策建议。这种融合范式，将为大气学科理论的创新和更精准与精细化天气预报创造机会，是实现气象事业高质量发展的关键推动力。我们期待大气学科不断突破，迈向新的高峰。

**致谢** 感谢国家自然科学基金（42041004）资助。

---

## 参考文献

1. Lorenz E N. Deterministic nonperiodic flow. *J Atmos Sci*, 1963, 20: 130–141
2. 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
3. Bird L J, Bodeker G E, Clem K R. Sensitivity of extreme precipitation to climate change inferred using artificial intelligence shows high spatial variability. *Commun Earth Environ*, 2023, 4: 469
4. Dolan E, Goulding J, Marshall H, et al. Assessing the value of integrating national longitudinal shopping data into respiratory disease forecasting models. *Nat Commun*, 2023, 14: 7258
5. Majda A J, Moore M N J, Qi D. Statistical dynamical model to predict extreme events and anomalous features in shallow water waves with abrupt depth change. *Proc Natl Acad Sci U S A*, 2019, 116: 3982-3987
6. Zeng X M. A review of the application of foreign artificial intelligence technology in weather predictions. *Meteor Sci Technol*, 1999, (1): 5-12 [曾晓梅. 国外人工智能技术在天气预报中的应用综述. *气象科技*, 1999, (1): 5-12]
7. Chen B, Hu J S, Wang Y X. Synergistic observation of FY-4A&4B to estimate CO concentration in China: combining interpretable machine learning to reveal the influencing mechanisms of CO variations. *npj Clim Atmos Sci*, 2024, 7: 9
8. Zhang Y, Li Z Q, Bai K X, et al. Satellite remote sensing of atmospheric particulate matter mass concentration: Advances, challenges, and perspectives. *Fundamental Res*, 2021, 1: 240-258
9. Huang G, Wang Y, Ham Y-G, et al. Toward a Learnable Climate Model in the Artificial Intelligence Era. *Adv Atmos Sci*, 2024, 41: 1-7
10. Couzin-Frankel J, Hand E, Langin K, et al. Runners-Up. *Science*, 2023, 382: 1228-1233
11. Bi K F, Xie L X, Zhang H H, et al. Accurate medium-range global weather forecasting with 3D neural networks. *Nature*, 2023, 619: 533-538
12. Pathak J, Subramanian S, Harrington P Z, et al. FourCastNet: A Global Data-driven High-resolution Weather Model using Adaptive Fourier Neural Operators. *ArXiv*, 2022, abs/2202.11214
13. Lam R, Sanchez-Gonzalez A, Willson M, et al. Learning skillful medium-range global weather forecasting. *Science*, 2023, 382: 1416-1421
14. Zhang Y C, Long M S, Chen K Y, et al. Skilful nowcasting of extreme precipitation with NowcastNet. *Nature*, 2023, 619: 526-532
15. Chen L, Zhong X H, Zhang F, et al. FuXi: a cascade machine learning forecasting system for 15-day global weather forecast. *npj Clim Atmos Sci*, 2023, 6: 190
16. Chen K, Han T, Gong J C, et al. FengWu: Pushing the Skillful Global

- 
- Medium-range Weather Forecast beyond 10 Days Lead. ArXiv, 2023, abs/2304.02948:
17. Li X, Su J B. Towards good governance of data: A case study in geoscience data governance (in Chinese). *Chin Sci Bull*, 2024, 69: 1149-1155 [李新, 苏建宾. 走向数据善治:以地球科学数据治理为例. *科学通报*, 2024, 69: 1149-1155]
  18. Ling F H, Luo J J, Li Y, et al. Multi-task machine learning improves multiseasonal prediction of the Indian Ocean Dipole. *Nat Commun*, 2022, 13: 7681
  19. Nie Y B, Sun J Q, Ma J H. Seasonal prediction of summer extreme precipitation frequencies over Southwest China based on machine learning. *Atmos Res*, 2023, 294: 106947
  20. Gu Z C. Achievements in numerical prediction in China(in Chinese). *Acta Meteorol Sin*, 1959, (3): 237-242 [顾震潮. 我国数值预报的成就. *气象学报*, 1959, (3): 237-242]
  21. He W P, W L, W S Q, et al. Evolutionary modeling for dryness and wetness prediction (in Chinese). *Acta Phys Sin*, 2012, 61: 548-555 [何文平, 王柳, 万仕全, 等. 旱涝预测的演化建模方法. *物理学报*, 2012, 61: 548-555]
  22. Chen M X, Fu H H, Zhang T, et al. ResU-Deep: Improving the Trigger Function of Deep Convection in Tropical Regions with Deep Learning. *J Adv Model Earth Syst*, 2023, 15: e2022MS003521
  23. Krasnopolsky V, Fox-Rabinovitz M, Belochitski A. Using Ensemble of Neural Networks to Learn Stochastic Convection Parameterizations for Climate and Numerical Weather Prediction Models from Data Simulated by a Cloud Resolving Model. *Adv Artif Neural Syst*, 2013, 2013: 485913
  24. Han Y L, Zhang G J, Huang X M, et al. A Moist Physics Parameterization Based on Deep Learning. *J Adv Model Earth Syst*, 2020, 12: e2020MS002076
  25. Rasp S, Pritchard M S, Gentine P. Deep learning to represent subgrid processes in climate models. *Proc Natl Acad Sci USA*, 2018, 115: 9684-9689
  26. Letu H S, Ma R, Nakajima T Y, et al. Surface Solar Radiation Compositions Observed from Himawari-8/9 and Fengyun-4 Series. *Bull Amer Meteorol Soc*, 2023, 104: E1772-E1789
  27. Veerman M A, Pincus R, Stoffer R, et al. Predicting atmospheric optical properties for radiative transfer computations using neural networks. *Philos Trans R Soc A-Math Phys Eng Sci*, 2021, 379: 20200095
  28. Kim S, Petrunin I, Shin H S. A Review of Kalman Filter with Artificial Intelligence Techniques. 2022 ICNS Conference, 2022, 1-12
  29. Chennault A, Popov A A, Subrahmanya A N, et al. Adjoint-Matching Neural Network Surrogates for Fast 4D-Var Data Assimilation. Arxiv, 2022, abs/2111.08626
  30. Wang Y Y, Shi X M, Lei L L, et al. Deep Learning Augmented Data Assimilation: Reconstructing Missing Information with Convolutional

- 
- Autoencoders. *Mon Weather Rev*, 2022, 150: 1977-1991
31. Boukabara S A, Krasnopolsky V, Stewart J Q, et al. Leveraging Modern Artificial Intelligence for Remote Sensing and NWP: Benefits and Challenges. *Bull Amer Meteorol Soc*, 2019, 100: ES473-ES491
  32. Ayzel G, Scheffer T, Heistermann M. RainNet v1.0: a convolutional neural network for radar-based precipitation nowcasting. *Geosci Model Dev*, 2020, 13: 2631-2644
  33. Charney J G, DeVore J G. Multiple Flow Equilibria in the Atmosphere and Blocking. *J Atmos Sci*, 1979, 36: 1205-1216
  34. Chou J F. The use of past information in numerical weather prediction (in Chinese). *Sci Sin*, 1974, 06: 635-644 [丑纪范. 天气数值预报中使用过去资料的问题. *中国科学*, 1974, 06: 635-644]
  35. Huang J P, Yi Y H. Inversion of nonlinear dynamical models with observation data. *Sci China Ser B-Chem (in Chinese)*, 1991, 21: 331-336 [黄建平, 衣育红. 利用观测资料反演非线性动力模型. *中国科学 B 辑: 化学 生命科学 地学*, 1991, 21: 331-336]
  36. Huang J P, Chou J F. Studies on the analogous rhythm phenomenon in coupled ocean-atmosphere system. *Sci China Ser B-Chem*, 1990, 33: 851-860
  37. Huang J P, Wang S W. The experiment of seasonal prediction using the analogy-dynamical model. *Sci China Ser B-Chem*, 1992, 35: 207-216
  38. Ren H L, Chou J F. Introducing multiple reference state updates in dynamically similar forecasts (in Chinese). *Acta Meteorol Sin*, 2006, 64: 315-324 [任宏利, 丑纪范. 在动力相似预报中引入多个参考态的更新. *气象学报*, 2006, 64: 315-324]
  39. Wang H J, Zhou G Q, Zhao Y. An effective method for correcting the seasonal—interannual prediction of summer climate anomaly. *Adv Atmos Sci*, 2000, 17: 234-240
  40. Fan K, Wang H J. Seasonal Prediction of Summer Temperature over Northeast China Using a Year-to-Year Incremental Approach. *J Meteorol Res*, 2010, 24: 269-275
  41. Li S L, Zhang Z S, W H. Is the future of numerical weather prediction the fusion of artificial intelligence and mathematical-physical modeling (in Chinese)? *Earth Sci*, 2022, 47: 3919-3921 [李双林, 张仲石, 王惠. 数值天气预报的未来是人工智能与数学物理模型的融合? *地球科学*, 2022, 47: 3919-3921]
  42. Zhou T J, Chen X L W B. Frontier issues on climate change science for supporting Future Earth (in Chinese). *Chin Sci Bull*, 2019, 64: 1967 - 1974 [周天军, 陈晓龙, 吴波. 支撑“未来地球”计划的气候变化科学前沿问题. *科学通报*, 2019, 64: 1967 - 1974]



黄建平，中国科学院院士，发展中国家科学院院士。长期专注于半干旱气候变化研究，历经十余年建成了国际领先的半干旱气候综合观测系统，并在半干旱气候变化及其机理研究等方面取得了一系列基础性强、具有国际影响力的原创性研究成果，提出相似-动力模式天气预测方法。

---

## How artificial intelligence is transforming weather forecasting for the future

Jianping Huang<sup>1,2\*</sup> & Bin Chen<sup>1,2</sup>

Jianping Huang<sup>1,2\*</sup> & Bin Chen<sup>1,2</sup>

<sup>1</sup> Collaborative Innovation Center for Western Ecological Safety, Lanzhou 730000, China;

<sup>2</sup> College of Atmospheric Sciences, Lanzhou University, Lanzhou 730000, China

\* Corresponding author, E-mail: [hjp@lzu.edu.cn](mailto:hjp@lzu.edu.cn)

Weather forecasting is a complex and challenging task. Numerical Weather Prediction (NWP), grounded in atmospheric dynamics, has long supported modern forecasting efforts. However, traditional NWP models often fall short due to the nonlinear nature of atmospheric systems. Enter Artificial Intelligence (AI): With its capacity for nonlinear learning, AI is transforming weather forecasting by introducing precise, data-driven approaches. Notably, Science named “The AI weather forecaster arrives” as one of the top ten scientific breakthroughs of 2023. It highlighted how meteorologists use advanced computing to model atmospheric futures, a practice that previously depended on vast computational resources to solve complex hydrodynamic equations. AI is revolutionizing this field by adeptly handling large datasets, learning autonomously, and generalizing across different scenarios, thus efficiently managing the complexities of atmospheric systems. Prominent tech companies like Google, Huawei, and NVIDIA have developed sophisticated AI models that now forecast weather with an accuracy that meets or surpasses that of traditional models, all while reducing computational demands.

Despite these advancements, AI’s role in weather forecasting is not without its challenges. As noted by Science, AI models do not directly solve atmospheric equations but rather rely on decades of historical data, which can limit their effectiveness in predicting extreme weather events. These models often struggle with interpretability, data uncertainty, transferability, and the precise prediction of severe conditions. They cannot yet operate independently of numerical models. While AI can effectively predict stable conditions and moderate changes, capturing and forecasting



---

sudden, severe weather events remains a challenge. In contrast, numerical models, with their solid mathematical and theoretical bases, are better suited to understanding the physical processes behind these abrupt changes, although they too have limitations in accuracy.

Numerical models and AI models each contribute unique strengths to weather forecasting, and the future of this field lies in effectively integrating both approaches. By incorporating AI techniques, we can refine the semi-empirical parameterization used in numerical models, thus enhancing both the efficiency and accuracy of data assimilation processes. Additionally, AI can facilitate the development of integrated forecasting methods that leverage multiple models for more robust predictions.

AI's data-driven capabilities are particularly valuable in compensating for the limitations of numerical models, which may not effectively incorporate historical data. Introducing dynamic models can also enhance the interpretability of these forecasts. By combining the principles of atmospheric dynamics with AI methodologies, we can significantly improve both the accuracy and efficiency of weather predictions.

This article explores *Science* review of the progress in AI-assisted weather forecasting, emphasizing the importance of further integrating dynamic systems and AI technologies. It identifies specific areas where these integrations can occur and outlines prospective advancements. Fueled by interdisciplinary collaboration and advancements in AI, future weather forecasting systems are poised to become more customized, provide real-time updates, and function autonomously. Such evolution will lead to significantly improved accuracy in predicting extreme weather and climate, enabling more precise weather forecasts.

**artificial intelligence, weather forecasting, atmospheric dynamics model, numerical weather prediction, extreme weather**