

<https://doi.org/10.3799/dqkx.2022.865>



数值天气预报的未来是人工智能与数学物理模型的融合？

李双林^{1,2}, 张仲石^{2,3}, 王惠²

1. 中国科学院大气物理研究所, 北京 100029

2. 中国地质大学环境学院, 湖北武汉 430068

3. 南通大学地理科学学院, 江苏南通 226007

20 世纪初, 美国气象学家 C. Abbe 和挪威气象学家 V. Bjerknes 分别提出通过求解控制大气运动的数学物理方程组来制作天气预报的设想, 为利用数值计算方法开展天气预报——数值天气预报开辟了道路. 之后, 经过 L. F. Richardson 和 J. G. Charney 等人的不懈努力, 数值天气预报逐渐发展成熟, 进入天气预报业务系统, 成为 20 世纪人类最伟大的科技成就之一 (Bauer *et al.*, 2015).

以欧洲中期天气预报中心 (ECWMWF) 为领头羊的数值天气预报模型发展日新月异, 已形成按动力框架静力平衡或不平衡、按空间离散方案谱展开或网格化、按预报对象空间全球或区域等不同方式的多层级预报模式. 数值天气预报产品, 既有每日多次、千米分辨率的短期天气预报, 也有每月一次的几十千米分辨率的全球季节预测. 目前数值天气预报能提前 10 天做出有技巧的大气环流形势预报.

气象业务朝着“三精”(观测精确、预报精准、服务精细) 方向发展, 对数值天气预报技巧水平提出了更高的要求. 尽管科学界在计算方法、模式初值获取、模式分辨率提高、物理过程参数化改进、预报结果不确定性控制及模式产品后处理等问题上取得了诸多进展, 但仍然面临很大的挑战 (Gimeno, 2013).

近 10 年来, 以数据挖掘、深度学习为代表的人工智能已经被应用到许多领域, 并产生了巨大的影响. 人工智能本质上是一种算法, 它吸收信息以执行具有人类智能特征任务的能力, 已被用于气温、降水、厄尔尼诺等的预测 (Ham *et al.*, 2019; Xia *et al.*, 2020) 以及极端天气事件的检测中. 人工智能为应对数值天气预报面临的挑战提供了部分解决方案.

1 数学物理模型与人工智能的融合： 未来数值天气预报的范式

深度学习可以为未来更高精度预报提供一种“轻量级”的方式 (利用更少的计算资源) (Schultz *et al.*, 2021), 它可以在初值、物理过程、偏差校正等方面解决数值天气预报领域面临的难题.

在初值方面, 虽然大量的数据被同化到物理模式中, 但模式的预测能力并没有随着数据量增加而迅速提高. 与传统数据同化相比, 深度学习可以从数据中找到更多、更高阶的物理联系. Brajard *et al.* (2020) 在数据同化中采用结合深度学习的算法, Bonavita and Laloyaux (2020) 采用人工神经网络 (ANN) 构造模式初值, 均取得了很好的预报效果.

作者简介: 李双林 (1966—), 男, 教授, 博士生导师, 长期从事气候动力学 (海气相互作用方向) 和气候变化的研究. E-mail: shuanglin.li@mail.iap.ac.cn

引用格式: 李双林, 张仲石, 王惠, 2022. 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, 47(10): 3919—3921.

Citation: Li Shuanglin, Zhang Zhongshi, Wang Hui, 2022. Will the Future of Numerical Weather Prediction be a Fusion of Artificial Intelligence and Mathematical and Physical Modeling? *Earth Science*, 47(10): 3919—3921.




图1 人工智能(AI)与数学物理模型的深度融合:未来数值天气预报构想

在物理过程方面,物理模式和深度学习的结合可以提高模式的模拟能力.例如,混合物理-卷积模型(Rasp *et al.*, 2018)可以模拟次网格以下的过程.机器学习还能改进物理过程参数化方案.例如,Becker *et al.*(2017)利用深度学习从高分辨率模型中析出对流有效粗尺度物理参数,得到新的参数化方案能更好地表达热带对流过程.

此外,深度学习还可对数值天气预报的输出结果进行偏差订正,特别是非线性偏差等.它自动从数据中提取并识别偏差模态,有助于对模式中未表现的模态进行理解,进而改进物理模式和订正模式偏差.还可以将基于人工智能的预测结果与物理模型的预测结果融合,以得到更有技巧的预报(Reichstein *et al.*, 2019).

虽然数学物理建模和机器学习通常被视为两个不同的领域,具有非常不同的科学范式(理论驱动与数据驱动),但这两种方法具有互补性.物理建模可以从理论上直接解释现象,并提供超越观测时效的预报潜力,而数据驱动的机器学习在发现数据内在联系方面优势明显,且具有高度的灵活性.未来可以通过数学物理模式与人工智能的动态融合,构建全新的数值天气预报系统(图1).

该系统不同于现有的利用人工智能去改进物理模型的某一个或某几个组件的做法,而是在物理模型积分过程中,把物理模型积分产生的新的中间变量和预报数据,融合进入不断更新累积的最新观测变量数据和先前的模式数据,供机器学习建立变

量网络.利用学习的结果去更新模式组件,达到动态学习、动态改进的效果.

2 优势

有望提升预报极端天气事件的能力.现有的数值天气预报系统在降水预报方面,普遍缺乏对极端降水事件的预报能力,暴雨、大暴雨、特大暴雨等漏报的几率大,对于像2021年7月郑州特大暴雨那样的破历史记录的暴雨事件更是无能为力.从分析来看,尽管原因复杂,数据中极端事件出现概率低,缺乏观测样本供研究和建模是一个重要原因.融合人工智能的数值天气模型在理论上将使用能获得到的所有数据,既包括历史观测和模式数据,也包括实时最新观测数据及实时模式运行数据,大大增加了资料中极端事件的潜在样本数.

将减小预报效果对气候背景的依赖.现有的数值天气预报系统的预报技巧表现出年际和年代际变化,其中的一个原因是不论是物理过程表达或参数化方案,还是同化系统的检验,都是基于历史观测数据总结分析得到的,因此与分析数据时段的气候背景有关.大气运动包含的时空尺度很广,从分子尺度的热传导到几千千米尺度的大型天气过程,不同尺度的大气运动之间存在着相互作用.当背景改变时,将通过不同尺度相互作用放大异常,导致以前方案的实用性降低.在融合模型中,通过深度学习及时把最新的观测信息和模式变量中间信息

引入到模式组件,增强了新的气候背景的表达,因此有望改进模式技巧的背景依赖。

增加了应用多源观测数据的灵活性。现有的资料同化系统,每隔几小时或几天同化一次日数据量达到 10^7 量级的各种常规和非常规观测数据,以得到全球范围内从地面到大气层中间层(80 km 高空)时空协调的模式初值。即便如此,现有的同化系统用到的观测资料依然有限。据估计卫星观测资料被同化使用到的概率大概只占 5%,其他非常规的、更多样化的资料使用率更低。融合模型在同化系统中应用深度学习,使用多源观测资料的灵活性大大增加。

3 应用前景

物理模型从理论高度上解释和描述现象,并提供超越观测时效的预报潜力,而数据驱动的人工智能在发现数据高阶内在联系方面独具优势,且具有高度的灵活性。人工智能与物理模型的融合模型结合了二者的长处,为数值天气预报的发展提供了新的思路,有助于部分解决目前所面临的挑战。值得指出的是,这里提出的构想还很粗浅。如何发展融合模型,还有许多问题尚待研究。

参考文献

- Bauer, P., Thorpe, A., Brunet, G., 2015. The Quiet Revolution of Numerical Weather Prediction. *Nature*, 525(7567): 47–55. <https://doi.org/10.1038/nature14956>
- Becker, T., Stevens, B., Hohenegger, C., 2017. Imprint of the Convective Parameterization and Sea-Surface Temperature on Large-Scale Convective Self-Aggregation. *Journal of Advances in Modeling Earth Systems*, 9(2): 1488–1505. <https://doi.org/10.1002/2016MS000865>
- Bonavita, M., Laloyaux, P., 2020. Machine Learning for Model Error Inference and Correction. *Journal of Advances in Modeling Earth Systems*, 12(12):e2020MS002232.
- Brajard, J., Carrassi, A., Bocquet, M., et al., 2020. Combining Data Assimilation and Machine Learning to Emulate a Dynamical Model from Sparse and Noisy Observations: A Case Study with the Lorenz 96 Model. *Journal of Computational Science*, 44: 101171.
- Gimeno, L., 2013. Grand Challenges in Atmospheric Science. *Frontiers in Earth Science*, 1(1):1–5. <https://doi.org/10.3389/feart.2013.00001>
- Ham, Y. G., Kim, J. H., Luo, J. J., 2019. Deep Learning for Multi-Year ENSO Forecasts. *Nature*, 573(7775): 568–572. <https://doi.org/10.1038/s41586-019-1559-7>
- Rasp, S., Pritchard, M. S., Gentile, P., 2018. Deep Learning to Represent Subgrid Processes in Climate Models. *Proceedings of the National Academy of Sciences of the United States of America*, 115(39): 9684–9689. <https://doi.org/10.1073/pnas.1810286115>
- Reichstein, M., Camps-Valls, G., Stevens, B., et al., 2019. Deep Learning and Process Understanding for Data-Driven Earth System Science. *Nature*, 566(7743): 195–204. <https://doi.org/10.1038/s41586-019-0912-1>
- Schultz, M. G., Betancourt, C., Gong, B., et al., 2021. Can Deep Learning Beat Numerical Weather Prediction? *Philosophical Transactions Series A, Mathematical, Physical, and Engineering Sciences*, 379(2194): 20200097. <https://doi.org/10.1098/rsta.2020.0097>
- Xia, J. J., Li, H. C., Kang, Y. Y., et al., 2020. Machine Learning-Based Weather Support for the 2022 Winter Olympics. *Advances in Atmospheric Sciences*, 37(9): 927–932. <https://doi.org/10.1007/s00376-020-0043-5>