
极端天气事件和天气气候一体化预报技术的现状及展望

肖子牛 潘宝祥

中国科学院大气物理研究所, 北京 100029

提 要: 极端天气事件对社会经济的发展有重要的影响, 极端天气的发生往往是大气环流形态与大尺度气候背景态叠加作用的结果, 体现了天气和气候的统一性。本文从天气、气候的内在联系出发, 分析了极端天气事件预报面临的困难和挑战, 讨论了天气气候一体化模式、多圈层耦合同化和集合技术、基于深度学习和 AI 的同化概率预报技术给极端天气预报带来的机遇, 指出了天气气候学科融合和天气气候一体化预报业务建立的重要意义。

关键词: 天气气候一体化, 极端天气事件, 多圈层耦合, 气候概率分布, 深度学习

Extreme Weather Events and Integrated Forecasting Techniques for Weather and Climate: Current Status and Prospect

XIAO Ziniu PAN Baoxiang

Institute of Atmospheric Physics, Chinese Academy of Sciences, Beijing 100029

Abstract: Extreme weather events have an important impact on economic and social development. The extreme weather events often result from superimposed influence of multi-factor and multi-scale abnormal signals of climate environment. Thus, extreme weather events embody the unity of weather and climate. This paper analyzes the difficulties and challenges of extreme weather event prediction from the perspective of the internal relationship between weather and climate, and also discusses the opportunities of extreme weather forecasting which are gained from the weather and climate integration models, multi-loop coupling assimilation and ensemble technology as well as the assimilation probability prediction technology based on deep learning and AI. Finally, the significance of the integration of weather and climate disciplines and the establishment of weather and climate integrated forecasting operation system is pointed out.

Key words: weather and climate integration, extreme weather event, multi-loop coupling, climate state probability distribution, deep learning and AI

引言

极端天气事件无疑是当今天气预报业务中最为关心的问题, 如何提高极端天气事件的预报能力也是气象科研的焦点问题。与此同时, 对气候异常的监测预测, 是气候业务的基本工作。在气象预测预报业务中人们可以注意到, 不少极端天气事件的发生往往都有特殊的气候背景。对极端天气事件的研究和归因分析启示我们, 如果追寻极端天气事件的源头, 将其时间线延长到气候范围的时效, 将有利于更好地发现极端天气发生的关键信号, 从而提高极端天气事件的预报能力。但遗憾的是, 由于长期以来形成的业务分工, 我们习惯把天气预报和气候预测分成了两个领域, 这种分割也许正成为阻碍极端

天气预报能力提高的重要因素之一。而事实上，天气和气候无论在科研上还是在技术上，都已经为天气气候业务的一体化奠定了基础。打破天气气候的时间隔断，发展天气气候一体化的业务，很有可能是突破极端天气事件预报瓶颈的重要途径。

1、极端天气：天气中的气候意义

极端天气 (extreme weather) 是相对罕见的，且对人类社会和生态系统产生破坏的天气现象的统称。全球气候变暖的背景下，极端天气事件频繁发生，给社会经济的发展带来极大的影响。据世界气象组织的统计，21 世纪以来，全球各种极端事件造成的损失较过去增加了一倍以上 (Eckstein et al, 2021)。与 1980—1999 年相比，2000—2019 年的极端温度事件从 130 次增加到 432 次，洪涝事件从 1389 次增加到 3254 次，极端风暴事件从 1457 起增加到 2043 起 [Centre for Research on the Epidemiology of Disasters (CRED) and United Nations Office for Disaster Risk Reduction (UNDRR), 2020]。各种极端天气气候事件给社会经济活动和居民生命财产安全造成了极大的影响。根据大部分数值模式和理论对未来气候的预估结果，未来全球的极端高温天气会越来越普遍，降水的分布在时间和空间上会变得更加不均匀，同时复合型极端事件 (Masson-Delmotte et al, 2023) 的影响将会急剧增强，极端天气事件正在成为人类社会面临的重大挑战，对极端天气的预报成为当今世界最为关注的科学问题之一。

自 20 世纪中叶以来，天气预报能力得到了长足的提高。尤其是 20 世纪 70 年代以后基于卫星探测技术建立了全球天、地、空观测体系，以及不断提升的全球数值预报技术，显著提高了天气预报水平，天气预报的可用时效 (以大气 500 hPa 位势高度异常相关系数计量) 平均每十年提高一天 (图 1; Ritchie, 2024)。进入 21 世纪后，天气预报数值模式在 3 天内的天气预报准确性可达 90% 以上，5 天内的预测精度也达到 80% 以上，短期天气预报已经成为人们日常活动的可靠参考。尽管如此，定量天气预报仍然存在较大的困难，尤其是强对流、强转折性天气、强降水过程等极端天气的预报技巧仍然较低。世界气象组织的世界气候计划 (World Climate Research Programme, WCRP) 将极端事件的预测预报作为大气科学亟需解决的科学问题。

长期以来，因为天气和气候关注时效长度不同，常常会被认为是两个相对独立的次级学科及业务领域。气候关心的是气象要素在给定时间和空间范围内的平均值，以及该平均值与历史多年平均观测值的偏差是多少；而天气预报关心的则是一次具体的气象现象发生过程。造成这一区分的根源来自我们在求解大气流体力学方式时做了不同的简化：天气预报简化为求解初值问题，而将气候预测简化为外源强迫约束下的边界条件问题。此外，由于大气流体的混沌性会迅速放大初始场测量中固有的不确定性，直到确定性预报与现实气候演变轨迹完全脱离。因此，将天气预报和气候预测根据预报时效分为两个不同的技术路线成为必然的选择。大气系统演变的混沌性使得预报随着时效的延长最终只剩下概率性信息。在实践上，这一现象迫使我们不断收集观测数据 (同化)，以更新对天气状态的估计和预报 (天气预报)；同时进行多样本模拟，在观测或预测到的外强迫条件下对可能的大气状态范围进行充分采样 (集合预报和气候预测)。这一现象为研究预报大气系统小概率极端事件给出了两条截然不同的方向：一是建立基于对大气演变过程及其各

种影响因子相互作用、过程层面的预报模型；二是建立基于对气候系统演变中相似概率特性、系统层面的预报模型。

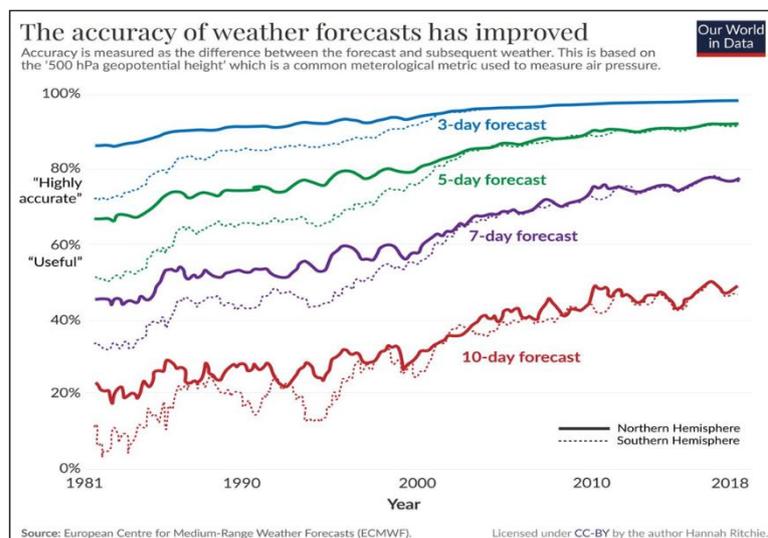


图 1 不同时期数值模式的预报技巧 (Ritchie, 2024)

Fig.1 Evolution of numerical weather prediction skill over different periods (cited from Ritchie, 2024)

事实上，在极端天气事件的诊断和预报中，我们是把一次具体的极端气象事件过程放到过往的历史记录及其平均中去比较，从而评估其极端性。因此，考察一个极端天气过程，完全与气候业务的视角类似，我们需要知道过去有气象记录以来此类事件的平均状态和特征，以及本次事件与同类事件多年平均的偏差。简单地说，研究极端天气事件就是用气候的视野去探究天气过程。因此我们可以认为，极端天气的预报就是具有气候意义的天气预报。同时，极端天气本身也是气候监测的重要内容，因为极端天气频率、强度和时空尺度的演变也在塑造气候的性质，并表征了气候状态的变化特征。

2、极端天气气候事件预报面临的挑战

极端天气气候过程虽然是小概率发生的事件，但由于极端天气气候过程是对气候平均态的严重偏离，对社会经济造成影响和损失巨大，因而广受关注。对大多数极端天气气候事件，我们至今还不能做出完全及时、准确、高精度的预报，因此，有效预报极端天气气候事件是目前气象学科和气象行业面临的重大挑战，

2.1 多圈层因子和多时间尺度的共同影响

极端天气气候事件的预报困难来源于多个方面。首先，气候系统是包含大气、海洋、冰雪、陆地、生态等多圈层的复杂系统，每一个大气状态都是多圈层相互作用的结果。尽管我们可以把一次极端天气事件归结为某种大气环流型配置下大气运动的结果，但异常大气环流型的形成不仅涉及到大气内部各种时间尺度的内部变率，还涉及到海洋、冰雪、陆面等多圈层外强迫因

子的影响。因此，一个极端天气过程的发生，不仅仅决定于大气初始状态和大气自身的演变过程，还会受到海洋、冰雪、陆面等多圈层状态及其异常的影响，而这些异常通常具有不同的时间尺度特征。更为重要的是，极端天气事件是小概率事件，极端天气事件及其气候背景的样本较少，被观测记录到的就更为稀少，从概率统计难以得到其发生演变的先验特征和规律描述。因而，对极端天气事件发生机制的研究，以及极端事件的预报都十分困难。

极端天气气候事件往往是多种要素和多时空尺度异常相互叠加组合的结果，包括大气系统自身变率信号，也包括 ENSO 型海温等其他气候系统的自然演变，还包括全球变暖长时间趋势的影响。在全球气候变暖的背景下，异常海温、青藏高原热力状态、北极海冰、平流层极涡等气候系统不同圈层关键指标都出现了不同于过去的异常变化。因此，以过去历史数据统计建立的因果关系可能失效，以数值模式为基础的动力预报方法在对热浪、热带气旋等极端事件的预测中也面临着新考验（杜钧等，2014，Sukovich et al, 2014）。例如，超强 El Niño 事件的发生频率在增加，极端 El Niño 事件增加了 50%，其中主要是中部型 El Niño 事件增加显著（Cai et al, 2014; 2018）。这些气候背景的变化对极端降水、极端高温事件的时空变化特征都有明显的影响。近年来的分析研究表明，北极海冰快速减少通过影响海气相互作用，助推了高温和风暴等极端事件的频繁发生（Kug et al, 2015; Overland et al, 2016）；而北极极涡分裂和偏移，常常导致北半球中高纬度地区的极端冷事件的发生（Mitchell et al, 2013）。北大西洋涛动（north Atlantic oscillation, NAO）等气候模态可通过改变急流位置影响欧洲寒潮的发生概率（Ferranti et al, 2018），这些现象反映了天气-气候的跨尺度反馈机制。分析还表明，全球变暖导致了西北太平洋、印度洋和西南太平洋强热带气旋的发生频数和占比大幅增加（Webster et al, 2005）；南极海冰变化导致索马里急流从南半球对北半球的物质输送增强，进而影响了中亚和东亚的极端降水异常（Li et al, 2023）。因此，全球气候变暖和不同圈层的要素异常，对极端天气事件有显著的影响。极端天气事件的预报必须要考虑气候背景等多种因子的影响。

2.2 大气和外强迫异常的相互作用和大气的非线性混沌效应

此外，在极端天气过程的演变过程中，大气异常状态和海洋、冰雪、陆面等多圈层还存在相互作用。例如，海洋热力状态对热带气旋活动具有重要的作用，但热带气旋的活动对海面温度、乃至次表层海温也会产生影响。因此，在热带气旋的发生发展过程中，海气系统具有耦合作用并对热带气旋的演变发展具有重要影响。在区域干旱极端事件中，降水的异常偏少会显著影响区域的蒸散发、土壤、植被等陆面状况（Li and Xue, 2010; Teuling et al, 2013），而陆面状态对于干旱事件过程中也会产生耦合反馈。例如，土壤湿度的负异常使得陆面向大气的感热输送显著增加，造成抬升凝结高度增加和大气湿静力能降低，从而更加抑制对流降水的发生，加速干旱过程的发展（Ren et al, 2021; Wang and Yuan, 2022）。由于极端天气事件过程的这种多因子、多时空尺度的相互作用和影响，系统且完整地揭示其演变机理有待进一步的深入研究。

此外，由于大气气候系统是一个高维复杂的非线性系统，从某一个大气状态的确定初值出发，大气的演变随着时间的推移必然进入混沌状态。因此，

当预报时效延长到两周以后，确定性的预报、确定时间和地点的事件过程预报变为不可达到的奢望。在中长期预报中，目前的目标是对未来偏离长期气候态的趋势做出预测判断，以取得基本可用的预测效果。图 2 给出了不同时效预报的技巧变化与初值和外强迫的影响程度。需要注意的是，图中所指的天气预报、次季节预测和季节预测的预测目标是不一样的。从图 2 可以看到，确定性的天气尺度预报在时效超过 2 周以后技巧变得很差，预报时效 20 天已经完全丧失预报技巧；主要基于外强迫因子对大气异常型约束和锁定的季节尺度预测的预报目标为均值偏差，季节尺度预测在 3~4 个月内可以达到有参考意义的中等技巧；而目标为天气事件过程的次季节预测的技巧最差，其可预报性来源主要为大气的一些低频振荡特性，技术上利用多成员的集合预报来提高捕捉信息的成功率。但遗憾的是，如热带大气季节内振荡（Madden-Julian oscillation, MJO）等大气内在的低频振荡往往在数值模式中最难以再现，大多数数值模式都不能对其准确模拟（Ling et al, 2017）。

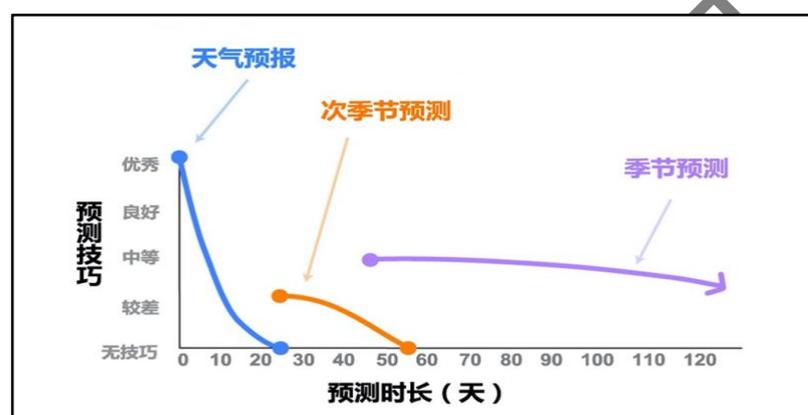


图 2 不同预报时效下的气象预报技巧示意图

Fig.2 Schematic diagram of meteorological forecast skill across different lead time

2.3 数值预报模式的不完备和局限性

众所周知，现代的天气预报的基础是数值模式预报。20 世纪 50 年代以后，数值模式预报技术得到了迅速的发展。90 年代后期开始，数值预报在业务上得到了广泛的认可和应用。目前数值模式对一般气象要素的预报已经超过了人工预报技巧，数值预报已经成为气象预报不可或缺的基础。但是，数值预报模式对真实大气运动的描述仍然是近似和不完备的。数值模式除了众多经验性指数不准确、物理过程不清晰、参数化方案替代较多以外，我们在数值模式预报中还默认了两个假定：第一，假定在短期天气预报的时效内影响天气系统演变的主要是大气初始状态，大气系统以外的气候环境在短期时效内是基本恒定或少有变化的；第二，假定在中长期预报中，大气初始状态的扰动信息经过一段时间（一个月）已经完全耗散，大气状态主要受到气候系统环境的约束而确定。依据这两个假定，长期以来数值模式预报对短期的天气预报和长期的气候预测采用了两个不同策略。天气预报数值模式注重改善对初值的同化来提升预报技巧，而中长期的气候预测主要考虑用更多的气候系统分量模式耦合来改进预测效果。但事实上，虽然在季节以下较短

的时间尺度内预测更多地受到初值的影响和控制，而在季节以上较长的时间尺度上主要受到外强迫源的约束和调控，但大气系统始终受到初始场和外强迫的影响（如图 3 所示）。例如，热带太平洋海温等关键气候特征出现异常（如 ENSO）时，短时间尺度的天气演变也必然受其影响，且往往容易导致极端天气事件的出现（李崇银等，2019）。ENSO 事件是否出现，目前已经成为重大天气预报会商不可或缺的参考。相反，季节以上的长时间预测也需要考虑初始场以及初始场的同化问题，当然，这种初始同化是包括了海洋、陆面和冰雪等气候系统各圈层的“同化”。

同时，即使预报系统的数值预报模式是完美模式，但同化数据的扩容、集合成员的增加和更多气候系统分量模式的耦合，都需要大大增加模拟预测的算力资源消耗。当我们用更准确的物理过程取代近似的参数方案，用更精确的地形来替代粗略的近似地形，就需要增加数值模式的分辨率，其代价是算力消耗的指数增加，这显然会给高精度预报模式的业务化和应用带来很大的压力和阻碍。



图 3 初值和外强迫对不同预报时效影响示意图

Fig.3 Schematic diagram of the influence of initial conditions and external forcing on forecasts across different lead time

3、天气气候一体化预报技术

由于理论和技术的局限性，长期以来，天气和气候在业务和科学界都被分割为两个不同的领域。但由上可见，天气的演变受到多种气候背景的影响，尤其是极端天气事件，其本身就蕴含着重要气候特征，而气候态特征也会因高频出现的极端天气事件而改变。气候系统的多尺度相互作用理论和现象表明，短期天气波动（如极端降水）的统计特征塑造和构建了长期尺度的气候态特征，而气候背景（如海温异常）又调控着极端天气事件的发生频率和强度。目前，天气预报技术已经不满足只考虑大气的初始状态，海洋、陆面等下垫面的信息，乃至大气化学成分、气溶胶的信息，越来越成为天气预报重要的依据。同时，中长期的气候预测，正在把同化技术和观测约束的方法用于改进气候预测的可用性。因此，天气和气候两个学科的融合和一体化发展，是大气学科发展的内在必然，也是满足极端天气事件预报需求的有效途径。

3.1 天气气候一体化数值模式的发展

天气气候一体化数值模式的发展是近年来地球系统科学领域的重要突破，其核心在于通过统一框架实现天气尺度（小时至周）与气候尺度（月至百年）的无缝模拟。这一发展正在深刻改变着传统观念中气象与气候在科学研究和业务应用中分离的格局。美国国家大气研究中心（National Center for

Atmospheric Research, NCAR) 的 MPAS-A (The Model for Prediction Across Scales) 模式通过非结构化网格实现千米级分辨率全球模拟 (Skamarock et al, 2008; Bacmeister, 2012); 中国气象局全球同化预报系统(CMA-GFS)(原 GRAPES-GFS)采用自适应网格加密技术,暴雨和台风预报体现了较好的性能(宫宇等,2018;王新敏和栗晗,2020)。物理过程和参数化方案可以通过尺度自适应实现天气气候尺度的通用,在耦合信息处理技术的支持下数值模式预报系统可以实现大气-海洋-陆面快速高效的耦合(Craig et al, 2017)。

天气过程和气候演变是相互影响的同一个事物的两个方面,天气和气候异常信号存在广泛的跨尺度相互作用。天气气候一体化的数值模式能更好地刻画不同尺度系统的相互影响,尤其有助于提高对多尺度异常信号叠加下产生的极端天气事件的预报能力。欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)的综合预报系统(Integrated Forecasting System, IFS)和 NCAR 的通用地球模拟模式(Community Earth System Model, CESM)等现代数值模式通过提升分辨率(从百千米级到千米级)和耦合多圈层过程(大气-海洋-陆面-冰冻圈),已经逐步打破天气与气候模式的界限。ECMWF 将季节预测系统(Seasonal Forecast System, SEAS5)与天气预报系统 IFS 整合,使热带气旋生成位置预测提前量达 21 天(Schreck III et al, 2023)。IFS 模式凭借引入海洋-大气-陆地双向耦合,有效延长了季节预测的时效,而日本气象厅的新世代系统实现台风路径 72 小时预报误差降低,相对于上一代预报业务改进了 20%。对 2021 年河南暴雨的数值模拟表明,传统数值模式对最大降水低估达 36%,而一体化模式通过 3 km 嵌套准确捕捉中尺度对流系统(Sun et al, 2024),从而改进极端降水的模拟。

天气气候一体化模式代表当今数值预报技术发展的前沿。从天气、气候数值模式根据各自的需求分别发展,到融合为覆盖全尺度的天气气候一体化数值模式,既是预报技术发展的必然之路,也是天气气候预报业务服务的要求(中国气象局, 2023)。

3.2 多圈层耦合同化和集合预报

数值模式是目前天气预报预测重要的技术基础,图 4 给出了影响天气预报准确性的误差来源,包含以下四个方面:(1)气候系统数值模式不同模块在初始场不协调的初始化冲击;(2)缺乏观测导致初始化不确定;(3)数值模式不完备带来的误差;(4)样本不足和信息缺失导致的预测结果的不全面。数值预报模式的改进和完善一直是人们努力的方向,近年来,数值模式框架、物理过程不断得到改进,模式系统也从单一的大气模式,发展为海洋-大气耦合模式,并进而向多圈层耦合模式发展。与此同时,数值预报模式同化技术和集合预报技术的发展,也在有效地解决上述的(1)、(2)和(4)环节带来的预报误差,并将在未来成为亟需关注和发展的关键领域。

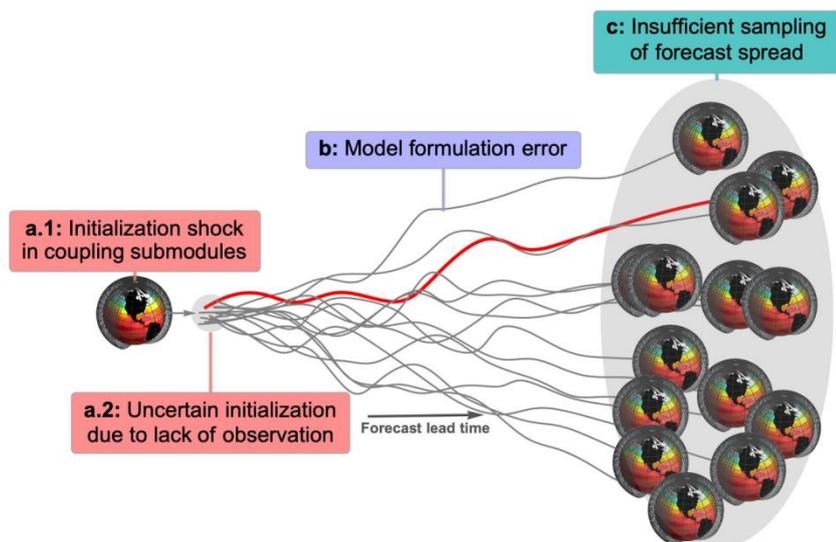


图 4 影响数值天气预报准确性的误差来源

Fig. 4 Sources of errors affecting the accuracy of numerical weather prediction

气候系统由大气、海洋、陆面、冰冻圈和生物圈等五大圈层构成，天气气候的演变过程与各圈层间的能量、动量和物质交换紧密关联。例如，海洋表面温度影响大气环流，而积雪覆盖通过反照率效应调节陆气相互作用。当我们假定在较短的时间内大气的演变主要由大气自身的状态决定时，可以把其他圈层状态固定为多年平均的恒定值，其变化可忽略不计，通过大气要素的同化力求取得模式大气状态和真实大气状态的一致。但事实上，海洋表面的温度、陆面土壤的含水量、水和冰雪覆盖状态在天气演变的过程中均在发生变化。因此，传统单一的大气模式和同化难以捕捉跨圈层的反馈和影响，而多圈层耦合模式（如 CESM、EC-Earth）可以通过对完整物理过程的刻画，有效改善气候和天气的模拟能力，从而提高预测的准确性。

数值模式对初始条件的敏感性是误差主要来源之一。根据 Lorenz 混沌理论，大气系统具有非线性特征使得初始条件的微小误差会随积分时间呈指数级增长。在过去数值预报技术发展的数十年内，人们不遗余力地通过数据同化技术融合观测与数值模式模拟来优化初始条件，有效地提升了天气预报的技巧。随着人们对多圈层相互作用机理的认识，以及对高质量预报结果需求的增加，针对多圈层系统模式的耦合数据同化（coupled data assimilation, CDA）应运而生，以实现跨圈层变量的同步协调。例如，大气-海洋耦合模型中，海表通量的误差需要在大气、海洋两个圈层中协同修正，避免“初始冲击”（initialization shock）。研究表明，CDA 相比单圈层同化能显著改进跨圈层变量的协调性，从而改善 MJO 等关键大气系统的模拟（Zhang et al, 2021; Kim et al, 2021）。如果进一步耦合同化土壤、植被、冰雪覆盖等更多跨圈层的要素，很可能会更好地反映各圈层间能量、动量和物质交换及其对天气演变过程的影响，从而不断提高天气预报技巧，尤其是提高由多种异常强迫影响导致的极端天气事件的预报能力，并大幅度提高长时效。例如，ECMWF 的“集成地球系统同化系统”（CERA）利用集合卡尔曼滤波（EnKF）和四维变分（4D-Var），耦合同化大气、海洋和海冰状态，可以将季节预测技巧提升约 20%（Hersbach et al, 2020）。

此外，合理的初始扰动能够使数值模式展示出天气演变的多种可能性。集

合预报系统 (Ensemble Prediction System) 通过扰动初始条件或不同的模型参数构建产生不同的预报结果, 从而捕捉到天气演变的各种可能性。如果集合预报的成员足够完备, 覆盖全部不确定性来源, 就有可能得到大气演变的所有潜在可能性和样本, 从而揭示未来天气完整的概率分布。目前全球各气象预报业务中心的集合预报成员通常为 50~100 个, 有限的集合预报成员难以覆盖所有不确定性来源 (Buizza et al, 2005)。为提高极端天气的命中率, 集合预报未来需要向多圈层初始场扰动扩展, 覆盖多圈层系统中不确定性来源。例如, 在热带气旋的预报中, 考虑海洋温度、海洋温盐结构的扰动集合, 从而覆盖其通过耦合作用影响热带气旋路径的各种可能性。跨圈层扰动方法已经在美国国家海洋大气局 (National Oceanic and Atmospheric Administration, NOAA) 的“地球系统预测集合” (Environmental Satellite Processing Center, ESPC) 得到尝试, 其采用“随机物理倾向扰动” (stochastically perturbed parameterization tendencies) 技术, 在耦合模型中同时扰动大气和海洋参数, 改进了厄尔尼诺预测效果 (Shin et al, 2021)。而第六次国际耦合模式比较计划 (Coupled Model Intercomparison Project, CMIP6) 结果分析也表明, 多模式集合可降低单一模型结构偏差, 提升极端事件预测可靠性。

耦合数据同化与集合预报相辅相成, 两者结合的协同效应可以更有效地提高预报的技巧。例如, 美国航空航天局 (National Aeronautics and Space Administration, NASA) “地球系统同化与预测” 的地球静止环境业务卫星 (Geostationary Operational Environmental Satellite, GEOS) 框架, 用集合卡尔曼滤波 (EnKF) 生成的集合初始场直接驱动集合预报, 并将在同化过程中更新的误差协方差反馈至预报成员权重, 形成动态不确定性传递循环。这种协同效应可以使 NAO 的周预测技巧显著提高 (Senan et al, 2024; Abid et al, 2023)。

多圈层耦合同化与集合预报很可能是未来改进数值模式预报系统的重要途径, 其发展将推动从天气到气候尺度的预测能力跃升。但多圈层耦合模型的高分辨率与多成员集合规模将消耗海量的超算资源, 造成巨额成本。深度学习 (deep learning) 和人工智能 (artificial intelligence, AI) 技术的应用, 例如 Transformer 加速参数化模型、数据驱动 Diffusion 模型, 可能会在这一领域取得突破性的进展。

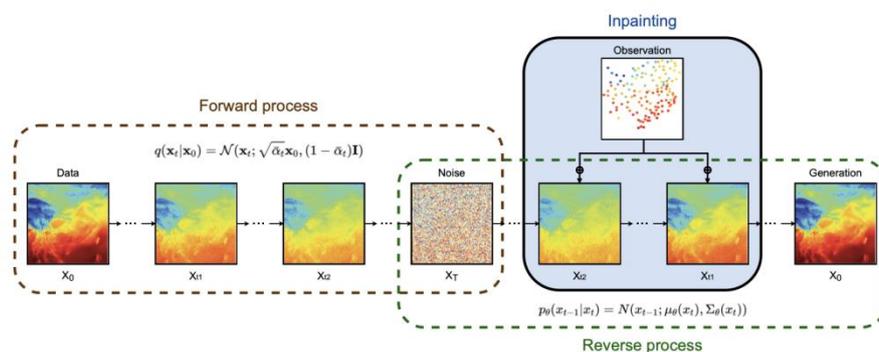
3.3 基于深度学习和 AI 预报技术的同化概率预报

从上述对天气气候演变的多因子驱动、非线性演变和预报的不确定性特点分析, 我们可以看到: 尽管可以通过完善数值模式, 加强观测数据的多圈层同化, 以及利用多成员的集合预报来尽量减少预报结果的不确定性, 但随着预报时效的延长, 预报结果也只能是一个某个范围的概率分布。更为重要的是, 更复杂的模式、更完备的耦合同化和更多的集合预报成员, 将使传统的数值天气预报面临指数增加的计算成本。近年来, 深度学习和 AI 技术被广泛应用于气象领域。与传统模式预测相比, 其对算力资料的要求大幅度降低。基于深度学习的概率同化预测技术展现出了全新的路径和惊人的潜力。

数据同化的实质是通过融合观测数据与模型先验信息, 估计系统状态的概率分布的过程, 深度学习依据观测与状态间的复杂关系直接建模。例如, 生成对抗网络 (Generative Adversarial Network, GAN) 可生成更真实的集合成员, 从而提升初始条件的不确定性表征 (Ravuri and Vinyals, 2020; Ravuri et

al, 2021)。还有一些研究使用深度神经网络 (Deep Neural Network, DNN) 替代整个同化流程, 提出直接从观测数据推断系统状态的概率同化模型 (Bonavita et al, 2021)。理想概率预报旨在输出包含全部可能性的未来状态的概率分布, 而非单一确定性结果。集合生成技术可以利用随机神经网络 (如 MC Dropout) 或生成模型 (如 GAN、VAE), 生成覆盖各概率的多样化预报集合, 并量化不确定性 (Abbasi et al, 2020); 通过时空序列建模, 卷积长短期记忆网络 (ConvLSTM) 和 Transformer 模型能捕捉到气象场的时空相关性, 从而提升极端事件的预测概率 (Garg et al, 2022); 此外, 将具有物理意义的约束嵌入模型, 可以使预报结果更符合物理规律 (Gulian et al, 2019)。ECMWF 开发了基于深度学习的概率预报系统, 通过训练 DNN 生成多个初始扰动, 显著降低集合预报的计算成本, 同时保持与 EnKF 相当的技巧 (Hatfield et al, 2021)。谷歌的 MetNet-3 使用 Transformer 预报未来 24 小时降水的空间概率分布, 可以得到 1 km 高分辨率的预报结果并优于传统数值模式预报性能 (Sønderby et al, 2020)

中国科学院大气物理研究所潘宝祥研究团队讨论探索了一种基于无监督生成模型技术的同化概率预报 (Generative Assimilation and Prediction, GAP) 模型, 为实现天气气候一体化预报提供了新思路。GAP 模型首先需要构建天气气候的先验分布并给出大气瞬时状态估计 (图 5), 通过使用无监督生成模型扩散模型 (diffusion model), 从气候再分析数据和数值模式模拟数据中学习气候分布, 之后通过将观测信息与学习到的先验概率分布相结合, 得到一个最优化的、概率意义上的覆盖所有可能的气象状态估计 (Chao et al, 2025)。其生成式模型的强大拟合能力突破了传统方法中误差表征受限于高斯假设的局限, 能够更准确地刻画复杂的误差结构和依赖关系。



注: 该方法利用概率扩散模型中的嵌入 (inpainting) 技术, 通过预定义的正向高斯过程将目标气候变量的分布转化为先验分布, 即标准高斯分布; 经过训练的反向高斯过程则将先验分布转化为目标气候变量的分布; 在反向高斯过程的过程中对稀疏观测数据进行“修复”, 以获得目标变量的空间模式估计。

图 5 天气气候的先验分布构建和瞬时状态估计技术示意图 (Chao et al, 2025)

Fig. 5 Schematic illustration of prior distribution construction and instantaneous state estimation techniques in weather and climate (cited from Chao et al, 2025)

基于这一思路, 可以建立新型的概率同化集合预报系统。通过集合预报能

够尽可能全面地捕获大气的状态。该系统利用概率扩散模型, 从高保真气候数据中学习气候概率分布, 从而得到气候态完全的概率分布。在得到一个最优化的、概率意义上覆盖所有可能的气象状态估计之后, 通过预报模型将状态估计推演到下一时间步骤, 为下一轮同化提供预报场输入。然后与下一时间步骤观测信息再进行同化融合, 生成同时契合观测和背景预报的集合成员, 形成完整的顺序同化循环。基于这种同化生成的集合成员, 可以利用数值模式或数据驱动模型进行推演, 生成未来时间步的概率预报结果。由于有先验学习的预测场和初始条件的约束, 可以确保大气状态与真实气候态符合, 使生成的集合成员表现出更高的极端事件过程覆盖率, 以及物理一致性更好的能谱结构, 并使得数据驱动天气预报能够更接近理论可预测性极限 (Nai et al, 2024)。图 6 给出了 GAP 和中国几个 AI 模型对台风“杜苏芮”的路径和中心位置误差预报结果。从图中可以看到, GAP 集合预报的台风路径与 ERA5 数据有较好的一致性, 台风中心位置平均误差在 5 天 (120 小时) 预报时效内低于 100 千米。

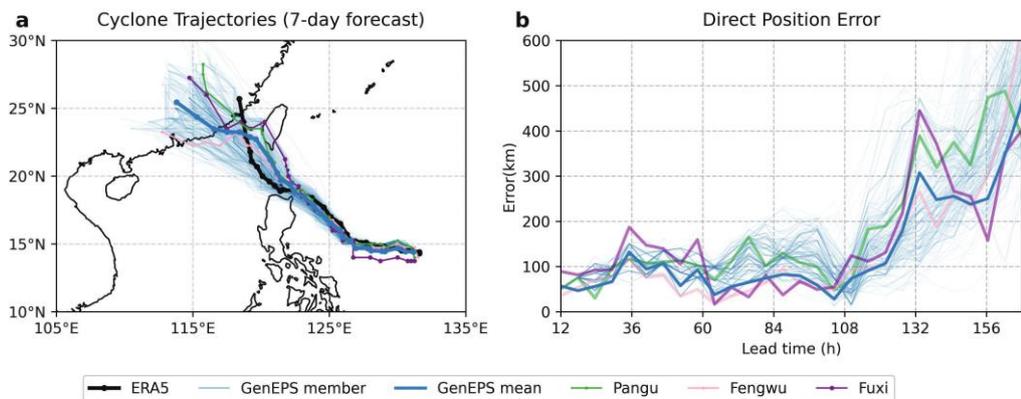


图 6 GAP 集合预报和盘古、风乌和伏羲 AI 模型对台风“杜苏芮”的 (a) 台风路径预报和 (b) 台风中心位置的预报误差 (Nai et al, 2024)

Fig.6 (a) Track forecast and (b) central position forecast errors of Typhoon Doksuri by the GAP ensemble prediction system, and the Pangu, FengWu and Fuxi AI models (cited from Nai et al, 2024)

ECMWF 的基于贝叶斯神经网络的概率预报系统 (AIFS-Pro) 开展了集合预报试验, 其集合离散度较传统方法增加了 42%, 能更准确地反映极端天气事件的不确定性。GAP 同化概率预报模型基于对大气气候态概率分布的准确刻画, 其集合与预报的发散都能够更好地覆盖未来天气的全部可能性, 包括小概率的极端天气事件, 同时通过循环同化过程, 有效约束天气事件演变轨线, 并量化未来天气状态的不确定性。

在给定观测初始场和外部强迫约束的情况下, 通过给出并量化气候状态的概率分布 (Nai et al, 2024)。这样就可以突破初始和外强迫造成的天气预报和气候预测的割裂。构建完整的观测-同化-预报闭环系统, 真正将观测信息、动力约束和统计规律有机结合, 实现了对天气-气候系统更全面的描述和预测。其所具有的这种优势有助于形成天气气候一体化的预报理论和技术方法, 并提升对极端天气事件的预报能力。

最近的一些分析研究表明, 使用卷积神经网络 (CNN) 和长短期记忆网络 (LSTM) 结合卫星图像和再分析数据 (如 ERA5), 对热带气旋 (24~72 小时) 的路径预测相比传统数值模型 (如 ECMWF) 误差减少了 10%~20% (Kim et al, 2019; Zhuo and Tan, 2021)。Google DeepMind 的 DGMR (Deep Generative

Model of Rainfall) 模型, 基于 GAN 对 1~2 小时短时临近强降水预测效果优于传统外推法(如光流法)和 WRF 数值模式预报(Ravuri et al, 2021)。而在基于 3D-CNN 分析多普勒雷达数据(如反射率、速度场等)的检测结果的龙卷风预警预报中(Cintineo et al, 2020), AI 模型的预警时间比传统方法提前 15~30 分钟, 误报率降低了 20%。

从上述可见, 深度学习和 AI 技术在数据同化和集合预报领域有广泛的应用前景, 并在极端事件的预报中展现了优势潜力。此外, 由于基于深度学习和 AI 的预报模型预报计算的效率相比传统数值模式预报呈指数级下降, 使其在天气气候一体化的高分辨率、高精度预报模型在业务上应用也具有巨大的优势。诚然, 尽管 AI 在极端气象预报中表现突出, 但仍面临可解释性、小样本学习(极端事件数据少)和物理一致性问题。而传统的数值模式具有较强的物理可解释性和一致性, 另外数值模式的大样本模拟在某种程度上也可以丰富和补充极端气象事件的样本。因此, AI 和传统数值预报结合和相互融合发展, 将是今后气象预报技术重要的发展趋势。

4、展望

目前的天气预报是基于当前天气状况的有限观测和不完善的预报模型给出的未来天气演变的轨迹, 气候预测是在多种外源强迫情景下得到物理约束下未来气候变化状态。事实上, 天气和气候都同时受到大气初始条件和外强迫边界条件的不同影响, 而大气运动的混沌性质又导致了确定性天气的极限和气候预测的不确定性。因此, 大气演变所具有的高维度、多时间尺度、非线性的性质, 使得天气和气候预报预测成为最具挑战的科学难题之一。但令人鼓舞的是, 深度学习和 AI 技术正在重塑概率同化与预报的技术路径。通过高效的非线性建模、不确定性量化及物理约束融合, 深度学习和 AI 在气象领域的应用可以显著提升预测的准确性, 并展现出强大的实用潜力。我们可以预见: (1) 未来天气和气候的学科将进一步相互影响, 最终走向融合发展; (2) 数值模式的发展和 AI 技术将进一步相互渗透, 数值模式和 AI 的结合将是未来气象预报的最优技术解决方案; (3) 天气气候学科的融合, 天气气候一体化数值模式的发展, 尤其是深度学习 AI 的赋能, 将为天气气候一体化预报业务的建立奠定理论和技术基础, 并成为攻克极端天气预报的难题的阶梯。

参考文献:

- 杜钧, Grumm R H, 邓国, 2014. 预报异常极端高影响天气的“集合异常预报法”: 以北京 2012 年 7 月 21 日特大暴雨为例[J]. 大气科学, 38(4): 685-699. Du J, Grumm R H, Deng G, 2014. Ensemble anomaly forecasting approach to predicting extreme weather demonstrated by extremely heavy rain event in Beijing[J]. Chin J Atmos Sci, 38(4): 685-699 (in Chinese).
- 宫宇, 代刊, 徐珺, 等, 2018. GRAPES-GFS 模式暴雨预报天气学检验特征[J]. 气象, 44(9): 1148-1159. Gong Y, Dai K, Xu J, et al, 2018. Synoptic verification characteristics of operational GRAPES-GFS model heavy rain event forecast[J]. Meteor Mon, 44(9): 1148-1159 (in Chinese).
- 李崇银, 杨辉, 赵晶晶, 2019. 大气环流系统组合性异常与极端天气气候事件发生[J]. 大气科学学报, 42(3): 321-333. Li C Y, Yang H, Zhao J J, 2019. Combinational anomalies of atmospheric circulation system and occurrences of extreme weather/climate events[J]. Trans Atmos Sci, 42(3): 321-333 (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).
- 中国气象局, 2021. “十四五”数值预报业务发展规划[N]. 中国气象报, 2021-10-12(1). China Meteorological Administration, 2021. The 14th five-year plan for the development of operational numerical weather prediction[N]. China Meteorological News, 2021-10-12(1) (in Chinese).
- Abbasi M, Rajabi A, Gagné C, et al, 2020. Toward adversarial robustness by diversity in an ensemble of specialized deep neural networks[C]//Proceedings of the 33rd Canadian Conference on Artificial Intelligence on Advances in Artificial Intelligence. Ottawa: Springer: 1-14.
- Abid M A, Kucharski F, Molteni F, et al, 2023. Predictability of Indian Ocean precipitation and its North Atlantic teleconnections during early winter[J]. npj Climate Atmos Sci, 6(1): 17.
- Bacmeister J T, 2012. Weather prediction models[M]//Rasch P J. Climate Change Modeling Methodology: Selected Entries from the Encyclopedia of Sustainability Science and Technology. New York: Springer: 89-114.
- Bonavita M, Arcucci R, Carrassi A, et al, 2021. Machine learning for earth system observation and prediction[J]. Bull Am Meteor Soc, 102(4): E710 - E716.
- Buizza R, Houtekamer P L, Pellerin G, et al, 2005. A comparison of the ECMWF, MSC, and NCEP global ensemble prediction systems[J]. Mon Wea Rev, 133(5): 1076 - 1097.
- Cai W J, Borlace S, Lengaigne M, et al, 2014. Increasing frequency of extreme El Niño events due to greenhouse warming[J]. Nat Climate Change, 4(2): 111 - 116.
- Cai W J, Wang G J, Dewitte B, et al, 2018. Increased variability of eastern Pacific El Niño under greenhouse warming[J]. Nature, 564(7735): 201 - 206.
- Centre for Research on the Epidemiology of Disasters (CRED), United Nations Office for Disaster Risk Reduction (UNDRR), 2020. The human cost of disasters: an overview of the last 20 years (2000 - 2019) [R/OL]. (2020-10-13) [2025-2-10]. <https://www.undrr.org/publication/human-cost-disasters-overview-last-20-years-2000-2019>.
- Chao J, Pan B X, Chen Q L, et al, 2025. Learning to infer weather states using partial observations[J]. J Geophys Res Mach Learn Comput, 2(1):

e2024JH000260.

- Cintineo J L, Pavolonis M, Sieglaff J M, et al, 2020. NOAA ProbSevere v2.0-ProbHail, ProbWind, and ProbTor[J]. *Wea Forecasting*, 35(4):1523-1543.
- Craig A, Valcke S, Coquart L, 2017. Development and performance of a new version of the OASIS coupler, OASIS3-MCT_3.0[J]. *Geosci Model Develop Discuss*, 10(9): 3297 - 3308.
- Eckstein D, Künzel V, Schäfer L, 2021. Global Climate Risk Index 2021: Who Suffers Most from Extreme Weather Events? Weather-Related Loss Events in 2019 and 2000 to 2019[M]. Bonn: Germanwatch.
- Ferranti L, Magnusson L, Vitart, et al, 2018. How far in advance can we predict changes in large-scale flow leading to severe cold conditions over Europe?[J]. *Quart J Roy Meteor Soc*, 144(715): 1788-1802.
- Garg S, Rasp S, Thuerey N, 2022. WeatherBench probability: a benchmark dataset for probabilistic medium-range weather forecasting along with deep learning baseline models[J]. arXiv: 2002.00469.
- Gulian M, Raissi M, Perdikaris P, et al, 2019. Machine learning of space-fractional differential equations[J]. *SIAM J Sci Comput*, 41(4): A2485-A2509.
- Hatfield S, Chantry M, Dueben P, et al, 2021. Building tangent-linear and adjoint models for data assimilation with neural networks[J]. *J Adv Model Earth Syst*, 13(9): e2021MS002521.
- Hersbach H, Bell B, Berrisford P, et al, 2020. The ERA5 global reanalysis[J]. *Quart J Roy Meteor Soc*, 146(730): 1999-2049.
- Kim H, Vitart F, Waliser D E, 2021. MJO Prediction: Current Status and Future Challenges[M]. Hackensack:World Scientific Publishing Co.:289-299.
- Kim S, Kim H, Lee J, et al, 2019. Deep-hurricane-tracker: tracking and forecasting extreme climate events[C]//Proceedings of the 2019 IEEE Winter Conference on Applications of Computer Vision (WACV). Waikoloa: IEEE: 1761-1769.
- Kug J S, Jeong J H, Jang Y S, et al, 2015. Two distinct influences of Arctic warming on cold winters over North America and East Asia[J]. *Nat Geosci*, 8(10): 759-762.
- Li Q, Xue Y K, 2010. Simulated impacts of land cover change on summer climate in the Tibetan Plateau[J]. *Environ Res Lett*, 5(1): 015102.
- Li Z Q, Xiao Z N, Ling J, 2023. Impact of extremely warm Tibetan Plateau in spring on the rare rainfall anomaly pattern in the regions west and east to Plateau in late summer 2022[J]. *Atmos Res*, 290: 106797.
- Ling J, Li C Y, Li T, et al, 2017. Challenges and opportunities in MJO studies[J]. *Bull Am Meteor Soc*, 98(2): ES53 - ES56.
- Masson-Delmotte V, Zhai P M, Pirani A, et al, 2023. Climate change 2021: the physical science basis: Working Group I contribution to the 6th assessment report of the Intergovernmental Panel on Climate Change[R]. Cambridge: Cambridge University Press.
- Mitchell D M, Gray L J, Anstey J, et al, 2013. The influence of stratospheric vortex displacements and splits on surface climate[J]. *J Climate*, 26(8): 2668-2682.
- Nai C, Chen X, Yang S, et al, 2024. Boosting weather forecast via generative superensemble[J]. arXiv: 2412.08377.
- Nai C Y, Pan B X, Chen X, et al, 2024. Reliable precipitation nowcasting using probabilistic diffusion models[J]. *Environ Res Lett*, 19(3): 034039.
- Overland J E, Dethloff K, Francis J A, et al, 2016. Nonlinear response of mid-latitude weather to the changing Arctic[J]. *Nat Climate Change*, 6(11):

- Ravuri S, Vinyals O, 2020. Classification accuracy score for conditional generative models[C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. Vancouver: Curran Associates Inc.: 12268-12279.
- Ravuri S, Lenc K, Willson M, et al, 2021. Skilful precipitation nowcasting using deep generative models of radar[J]. *Nature*, 597(7878): 672-677.
- Ren Y L, Yue P, Zhang Q, et al, 2021. Influence of land surface aridification on regional monsoon precipitation in East Asian summer monsoon transition zone[J]. *Theor Appl Climatol*, 144(1): 93-102.
- Ritchie H, (2024-03-12). Weather forecasts have become much more accurate; we now need to make them available to everyone[EB/OL]. <https://ourworldindata.org/weather-forecasts>.
- Senan R, Balmaseda M A, Molteni F, et al, 2024. The relative role of Indian and Pacific tropical heating as seasonal predictability drivers for the North Atlantic Oscillation[J]. *J Geophys Res: Atmos*, 129(18):e2024JD041233.
- Schreck III C J, Vitart F, Camargo S J, et al, 2023. Advances in tropical cyclone prediction on subseasonal time scales during 2019-2022[J]. *Trop Cyclone Res Rev*, 12(2): 136-150.
- Shin S I, Sardeshmukh P D, Newman M, et al, 2021. Impact of annual cycle on ENSO variability and predictability[J]. *J Climate*, 34(1): 171-193.
- Skamarock W C, Klemp J B, Ringler T, et al, 2008. A hexagonal C-grid atmospheric core formulation for multiscale simulation on the sphere[C]//AGU Fall Meeting Abstracts. Washington: AGU, A31H-01.
- Sønderby C K, Espeholt L, Heek J, et al, 2020. MetNet: a neural weather model for precipitation forecasting[J]. arXiv: 2003.12140.
- Sukovich E M, Ralph F M, Barthold F E, et al, 2014. Extreme quantitative precipitation forecast performance at the weather prediction center from 2001 to 2011[J]. *Wea Forecasting*, 29(4): 894-911.
- Sun W, Jian L, Yu R C, et al, 2024. Exploring changes of precipitation extremes under climate change through global variable-resolution modeling[J]. *Sci Bull*, 69(1):237-247.
- Teuling A J, Van Loon A F, Seneviratne S I, et al, 2013. Evapotranspiration amplifies European summer drought[J]. *Geophys Res Lett*, 40(10): 2071-2075.
- Wang Y M, Yuan X, 2022. Land-atmosphere coupling speeds up flash drought onset[J]. *Sci Total Environ*, 851: 158109.
- Webster P J, Holland G J, Curry J A, et al, 2005. Changes in tropical cyclone number, duration, and intensity in a warming environment[J]. *Science*, 309(5742): 1844-1846.
- Zhang Y W, Chen G W, Ling J, et al, 2021. A case study on MJO energy transport path in a local multi-scale interaction framework[J]. *Adv Atmos Sci*, 38(11): 1929-1944.
- Zhuo J Y, Tan Z M 2021. Physics-augmented deep learning to improve tropical cyclone intensity and size estimation from satellite imagery[J]. *Mon Wea Rev*, 149(7): 2097-2113.