

基于深度学习的气象预报模型研究综述

王嫒, 霍鹏, 韩毅, 陈嗽, 汪祥, 温辉

引用本文

王嫒, 霍鹏, 韩毅, 陈嗽, 汪祥, 温辉. [基于深度学习的气象预报模型研究综述](#)[J]. 计算机科学, 2025, 52(3): 112-126.

WANG Yuan, HUO Peng, HAN Yi, CHEN Tun, WANG Xiang, WEN Hui. [Survey on Deep Learning-based Meteorological Forecasting Models](#) [J]. Computer Science, 2025, 52(3): 112-126.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[一种基于TVM的自动调度搜索优化方法](#)

Automatic Scheduling Search Optimization Method Based on TVM

计算机科学, 2025, 52(3): 268-276. <https://doi.org/10.11896/jsjcx.240100126>

[生成式任务网:基于大模型的自主任务规划与执行范式](#)

Generative Task Network: New Paradigm for Autonomic Task Planning and Execution Based on LLM

计算机科学, 2025, 52(3): 248-259. <https://doi.org/10.11896/jsjcx.241100068>

[大模型金融场景能力评测框架研究](#)

Study on Evaluation Framework of Large Language Model's Financial Scenario Capability

计算机科学, 2025, 52(3): 239-247. <https://doi.org/10.11896/jsjcx.240900123>

[基于元学习的半监督声音事件检测方法](#)

Semi-supervised Sound Event Detection Based on Meta Learning

计算机科学, 2025, 52(3): 222-230. <https://doi.org/10.11896/jsjcx.240100191>

[基于注意力机制与对比损失的单视图草图三维重建](#)

3D Reconstruction of Single-view Sketches Based on Attention Mechanism and Contrastive Loss

计算机科学, 2025, 52(3): 77-85. <https://doi.org/10.11896/jsjcx.240200102>

基于深度学习的气象预报模型研究综述

王 媛¹ 霍 鹏¹ 韩 毅² 陈 瞰² 汪 祥² 温 辉¹

1 天津科技大学人工智能学院 天津 300457

2 国防科技大学气象海洋学院 长沙 410073

(wangyuan23@tust.edu.cn)

摘 要 实时准确的气象预报关乎人民生计、环境生态以及军事决策,受到各界人士的广泛关注和重点研究。数值气象预报是当前的主流预报方法,经过长期发展,其预报精确性和可靠性不断提高,但仍然面临系统误差无法避免、历史观测数据难以利用,以及计算开销巨大等重大挑战。随着深度学习技术的快速兴起,数据驱动的人工智能方法逐渐应用于气象预报领域,为应对上述挑战提供了全新技术手段。基于上述背景,文中全面总结了数值气象预报和深度学习气象预报的研究现状,系统梳理了深度学习气象预报模型的相关概念和输入数据,详细阐述了应用于各类气象预报任务的代表性模型,深入对比了不同模型的技术架构和性能指标,并且分析讨论了该领域目前面临的挑战和未来发展的方向,旨在为相关研究提供参考。

关键词: 气象预测;深度学习;大模型;AI4Science

中图分类号 TP391

Survey on Deep Learning-based Meteorological Forecasting Models

WANG Yuan¹, HUO Peng¹, HAN Yi², CHEN Tun², WANG Xiang² and WEN Hui¹

1 College of Artificial Intelligence, Tianjin University of Science and Technology, Tianjin 300457, China

2 College of Meteorology and Oceanography, National University of Defense Technology, Changsha 410073, China

Abstract Accurate and timely weather forecasting is crucial for people's livelihoods, environmental ecology, and military decision-making, attracting extensive attention and focused research from various sectors. Numerical weather prediction (NWP) is currently the mainstream forecasting method. Over long-term development, the accuracy and reliability of NWP have continuously improved. However, it still faces significant challenges, such as unavoidable systematic errors, ineffective utilization of historical observation data, and substantial computational costs. With the rapid rise of deep learning, data-driven artificial intelligence methods are gradually being applied to the field of weather forecasting, offering novel techniques to overcome these challenges. Against this backdrop, this paper comprehensively summarizes the current research status of NWP and deep learning-based weather forecasting. It systematically reviews the relevant concepts and input data for deep learning-based weather forecasting models, thoroughly explains representative models applied to various weather forecasting tasks, and provides a detailed comparison of the technical architectures and performance metrics of different models. Additionally, it analyzes and discusses the existing challenges and the future directions in this field. The ultimate purpose of this survey is to provide reference information for related research.

Keywords Weather forecasting, Deep learning, Large model, Artificial intelligence for science

1 引言

气象预报可以预警防范自然灾害、指导行业生产活动、辅助军事决策行动^[1],在农业管理^[2]、交通运输^[3]、国防军事^[4]等领域均起到重要作用。受到地理位置、大气环流和大气系统等多种因素的影响,气象变化往往难以准确预测。随着近年极端天气事件的频繁发生以及气候条件的显著变化,人们对于准确气象预报的需求与日俱增^[5]。

传统数值气象预报^[6]方法基于数理方程模拟大气运动

状态及其能量传递过程,并根据收集到的气象数据,通过数值模拟方法求解方程来预测未来天气情况^[7]。随着高性能计算、资料同化、预报模式、集合预报等相关技术的发展,数值气象预报已成为当前最重要的气象预报手段^[8],但其仍然面临计算资源需求过高、系统误差难以避免、历史数据利用不充分等诸多挑战^[9]。

1.1 数值气象预报发展的历程

数值气象预报经历了多个关键发展阶段。1922年Richardson等^[10]首次尝试使用有限差分法进行天气预报,但因

到稿日期:2024-09-14 返修日期:2024-11-28

基金项目:国家自然科学基金(62372460);湖南省自然科学基金(2024JJ4042);国防科技大学青年自主创新科学基金(ZK24-53)

This work was supported by the National Natural Science Foundation of China(62372460), Natural Science Foundation of Hunan Province, China(2024JJ4042) and Youth Independent Innovation Science Fund of the National University of Defense Technology(ZK24-53).

通信作者:韩毅(hanyi12@nudt.edu.cn)

计算能力有限,导致预报效果不佳。50 年代,伴随着计算机的发展,气象学家开发了更复杂的数值模式,并通过利用电子计算机求解大气方程,首次实现了北美地区未来 24 小时的天气预报^[11]。80 年代,卫星观测的应用大幅提升了全球观测数据的覆盖率,结合变分同化技术显著提高了气象预报初始条件的准确性^[12]。2000 年,高分辨率区域模式和集合预报方法^[13-14]的引入,进一步提升了局地天气现象预报水平^[15]。目前,国内外具有代表性的数值天气预报模式包括中国气象局的 GRAPES(Global/Regional Assimilation and Prediction Enhanced System)^[16]、欧洲中期天气预报中心的 IFS(Integrated Forecasting System)^[17]、美国国家环境预报中心的 GFS(Global Forecast System)^[18]等。这些模式在不同的气象机构中广泛应用,结合先进的数据同化技术和复杂的物理过程模拟,成为全球和区域天气预报的可靠工具。伴随着深度学习和人工智能技术的发展,数据同化、后处理、模式识别和降尺度等方面的精度和时效性得到了进一步改善。通过设计基于深度学习的模型,在不依托数理方程的前提下准确完成高精度、高时效的气象预报任务成为当前领域的热点课题。

1.2 数值气象预报面临的挑战

尽管数值气象预报方法在精度和效率方面取得了显著进展,但仍然面临多方面的挑战,具体表现为以下 3 点。

1) 系统误差的累积与不确定性问题

大气系统是典型的非线性混沌系统,对初始条件高度敏感^[19]。即便观测数据的质量和覆盖范围有所提升,初始条件的微小误差仍可能导致预报结果在长时间尺度下急剧偏离。此外,该问题还涉及模型参数化方案的局限性,即当前的数值预报模型对一些复杂物理过程(如对流、降水等)的参数化仍不完善,致使其预报精度难以提升。如何在保留大气系统复杂性的前提下,减少初始误差带来的不确定性并优化参数化方案,是一项重要的研究课题。

2) 历史观测数据的有效利用问题

现有数值预报模型大多仅使用当前时刻的观测数据作为输入,忽略了大量历史观测数据的潜在价值。然而,这些历史数据中蕴含着丰富的大气状态变化信息,对于某些极端天气事件的预报,可以提供更加全面的背景信息^[20]。如何通过改进数据同化技术和模型架构,有效整合利用这些历史数据,并避免因过多数据带来的计算负担仍是一大挑战。

3) 计算资源与模型复杂性之间的权衡问题

数值天气预报的计算需求极大,尤其是对于高分辨率预报模型,其计算资源与分辨率间呈指数关系增长^[21]。当前数值预报模型依赖于大规模高性能计算集群和海量内存,需要耗费巨大成本来维持。因此,如何引入新型算法优化预报过程,从而在保证预报精度的前提下降低计算复杂性和资源需求,成为当前亟需解决的难题。

1.3 深度学习在气象预报领域的应用

随着近几年深度学习技术^[22]的快速兴起和广泛应用,人工智能正作为全新范式(Artificial Intelligence for Science, AI4Science)有力推动着自然科学的发展^[23]。深度学习模型具备在未知实际物理过程及方程的前提下,基于图形处理器(Graphics Processing Unit, GPU)从海量训练数据中自动挖掘潜在物理规律,从而实现精确预报的潜力^[24]。当训练数据

达到一定量级时,还会出现尺度定律现象(Scaling Laws)^[25],即模型性能随着数据规模的增大而持续提升,这意味着基于深度学习方法充分利用海量历史数据以提高预报准确度成为可能。图像数据与气象数据在维度方面存在极大相似性^[26],许多以计算机视觉模型为架构、以海量历史数据为驱动的气象预报模型被相继提出。相比数值气象预报模型,这类模型不仅在算力成本和计算速度方面有量级改善,而且具有上手门槛低、偏差累积小、预报精度高等优势^[27]。

虽然深度学习气象预报方法发展潜力巨大,但目前相关研究仍处于起步阶段^[28],缺乏详细脉络梳理和深入分析总结。现有综述重点讨论早期深度学习预报模型的相关研究^[28-30],未涵盖近几年(2022 年及以后)发布的重要气象预报大模型,而这些大模型在预报精度、计算效率和可扩展性等方面均超过传统数值预报方法,对气象预报领域产生了革命性影响,值得重点关注。此外,现有综述也未细分讨论不同预报任务类型,未对比分析不同模型的性能差异,因此难以为深度学习气象预报模型的未来发展提供可行的研究思路和最新参考信息。基于此,本文在收集整理了大量相关文献和现有开源资源的基础上,讨论了深度学习气象预报任务的定义及分类,阐述了常用于模型训练的再分析数据集及其构建过程,调研总结了不同类型的深度学习气象预报模型,对比分析了不同模型间的性能差异,并总结了未来研究方向和发展趋势。

本文第 2 章讨论了气象预测的任务定义与任务分类;第 3 章介绍了深度学习气象预测模型的输入数据集,说明了气象再分析数据的构建过程,并梳理了两种常见的再分析数据集;第 4 章阐述了基于深度学习的气象单指标预测模型和多指标预测模型;第 5 章对比了不同预测模型的技术路线、模型架构和性能指标,并讨论了各类方法的优缺点和目前存在的局限;第 6 章展望了未来发展方向,提出了该领域目前面临的挑战以及未来可能的发展趋势;最后对全文内容进行总结。总体而言,本文旨在通过对深度学习气象预测研究进行系统分析和详细讨论,为相关研究提供思路和参考。

2 气象预报的任务定义及模型分类

本章将对气象预报任务的定义进行说明,探讨气象预报任务的建模过程,并按照预测变量数对气象预报模型进行分类,从而为后续章节的论述和分析比较奠定基础。

2.1 气象预报任务的定义

气象预报任务指利用观测数据、数值模拟和机器学习等方式,对大气和地球系统的动态变化进行模拟和预测,以提供未来一段时间内的天气现象、气候变化、自然灾害等信息,通常可以按照预报的时间范围和预报内容进行划分^[32]。基于数值模型的气象预报任务的建模过程可定义为:给定一个气象观测数据集,通过构建一个预报模型对未来时间点的气象现象或气象要素进行预测。由于全球范围内的大气数据规模庞大,现阶段气象预报模型通常无法以一步式方式完成中长时间的气象预报任务。为遵循大气演变规律,模型通过逐个预测下一个时间间隔的气象变量变化,以多步自回归的方式实现对中长时间的气象预报。

按照时间范围可以将气象预报任务划分为临近、短时、中短期及延伸期 4 类^[33]。短期预报是针对未来几小时到三天

内的天气情况进行预报,通常用于日常生活中的天气预报、航空航海、灾害预警等;中期预报针对未来三天到十天的天气趋势和变化,可以帮助规划农业、交通、旅游等方面的活动;延伸期预报聚焦未来十天以上的长期变化趋势,用于研究气候周期和季节性变化,对长期决策进行指导。由于预报时间跨度较大且需要考虑更多气象因素和不确定性,中长期天气预报往往更具挑战性。按照预报内容可以将气象预报任务划分为天气预报、气候预测及自然灾害预警三大类:天气预报主要关注近期温度、湿度、风速、降水等天气要素,包括对天气现象、天气系统的移动和演变等方面的预报;气候预测主要关注未来一段时间内的气候特征和长期趋势,如气温、降水量、季风强度等长期气候趋势;自然灾害预警预测地震、洪涝、台风等自然灾害事件的发生时间、地点和影响范围,以提前采取预防和救援措施。

2.2 气象预报模型的分类

根据预报变量数可以将气象预报模型分为单指标预报与多指标预报两类,本文后续将按照该分类标准分别论述其代表性模型。单指标预报针对特定气象变量进行预测,如温度、降水量、风速或气压等,其特点在于仅针对单个变量进行预报,因此模型复杂性相对较低,结果也易于解释,适用于对某一气象因素有较高精度需求的预测场景。然而,单指标预报仅关注单一变量而忽略了其他气象因素之间的相互作用,可能导致信息利用不充分、预报结果不全面的问题。

多指标预报则指同时预报多个气象变量,这类任务虽更加复杂,但能更全面地反映大气系统的整体全貌,通常应用于需要全面了解和综合评估未来天气状况的场景,例如综合天气预报或灾害预警。多指标预报的特点在于其全面性,能够捕捉不同变量间的相互作用,从而提高预报结果的准确性和可靠性。然而其也存在模型复杂性高、处理数据维度大、计算资源与时间开销高等挑战。

2.3 深度学习气象预报模型的建模过程

基于深度学习模型的气象预报任务建模过程如图 1 所示。首先,收集并处理大气再分析数据,并通过编码嵌入方法压缩输入数据维度,将其表示为深度学习模型可以处理的特征向量;其次,根据具体应用需求,构建并训练合适的深度学习模型;最后,解码模型输出的特征向量,生成与原始数据维度相同的最终预测结果。本文将在后续章节按照上述过程,分别对模型输入数据、具体框架及预测结果进行逐一讨论。




图 1 基于深度学习模型的气象预报任务建模过程

Fig. 1 Modeling process of weather forecasting task based on deep learning model

3 深度学习气象预报模型的输入数据

气象数据是记录和描述气象现象的数字化信息集合^[34],包括各种气象要素的观测值,如温度、湿度、气压、风速、降水量等,这些数据通常直接来自各种观测平台记录的实时观测信息,如气象站、卫星、雷达、浮标等。深度学习方法基于数据驱动,极度依赖训练数据的数量和质量,利用数据同化技术^[35]处理生成的再分析数据集具有较高的连续性、一致性和可靠性,从而能够提高模型的泛化能力和预测准确性,因此现有的大多数深度学习气象预报模型均选择再分析数据进行训练和测试。本章将首先介绍气象数据的特征,然后阐述再分析数据的构建过程,最后介绍两种常用的再分析数据集。

3.1 气象数据特性

数据的特性决定了其建模的难度。气象数据具有时空依赖、多尺度和多模态等特性,为有效捕捉天气系统的运动规律,需要基于以上特性探讨模型构建方式。本节将概述气象数据的关键特征及其对应的建模处理方法。

3.1.1 时空特性

气象数据具有强烈的时空依赖性。天气系统的演化不仅依赖于单一地点的时间序列数据,还受到周围区域及全球范围内大气循环和地理位置的影响。如何有效建模这些时空关系是提高气象预报精度的关键。现有研究提出了多种时空关系建模方法,例如,基于循环神经网络(Recurrent Neural Network, RNN)的时间序列建模能够捕捉天气变量在时间维度上的依赖,而卷积神经网络(Convolutional Neural Networks, CNN)则通过提取气象数据中的空间特征(如气旋、温度梯度等),有效应对气象数据的空间复杂性。此外,最近的研究还探讨了时空图神经网络^[36],通过将空间格点表示为图结构并结合时间维度,来捕捉全球气候系统的复杂动态演化。

3.1.2 多尺度特性

天气系统的变化通常存在多种尺度,从小时级短时天气变化到几个月甚至几年的气候态变化。不同尺度的气象现象(如局地雷暴、全球大气环流)对预报的要求各不相同。研究者在模型设计中多采用多尺度卷积网络或注意力机制来捕捉不同尺度的气象特征。例如, CNN 可以处理局部的气象现象,但难以捕捉大尺度天气系统中的远距离依赖关系。而 Vision Transformer(ViT)可通过自注意力机制捕捉气象图像中的多尺度特征,尤其适合处理远程依赖关系,例如厄尔尼诺现象对全球气候的影响。

3.1.3 多模态特性

气象数据来源多样,涵盖再分析、卫星图像、雷达回波、气象站观测等多模态数据,如何在模型中有效融合这些多源数据是提升气象预报精度的重要方向。近年来相关研究逐渐兴起,如引入多模态融合模型,基于深度卷积生成对抗网络^[37]和多模态注意力机制,同时建模图像、时间序列和数值特征,从而提升复杂天气现象预报能力。

针对气象预报数据的时空特征、多尺度特征和多模态特征,目前已有许多有针对性的建模方法。本文后续将对这些研究进行详细的回顾与探讨,并展望未来气象预报模型在时空关系建模和多模态融合方面的发展方向。

3.2 再分析数据构建过程

数据同化技术将来自气象站、卫星、雷达等多种观测途径

的数据与数值模型的输出数据进行融合,同时考虑了动力学约束,以产生对真实大气状态更准确的估计^[38]。基于数据同化构建再分析数据的过程如图2所示。首先对观测数据和数值模型预报数据进行预处理操作,包括插值、格点匹配和坐标转换,以确保它们具有相同的空间分辨率和时间步长。其次利用观测算子将观测数据映射到模型状态空间,实现不同数据源信息的匹配和转化,保证它们的一致性。同时根据观测数据的信噪比、模型输出的误差估计等因素,为观测数据和模型输出数据赋予权重,反映它们的相对置信度和精度。然后

通过卡尔曼滤波^[39]或变分同化^[40]等方法将观测数据和模型输出实现数据融合。最后对观测数据与数值模型的预报结果之间的误差进行比较,将其视为最优化问题,通过调整状态向量值最小化模型输出与观测数据之间的差异,使模型的预报结果与观测数据尽可能拟合。这一过程可以通过梯度下降^[41]或共轭梯度^[42]等最优化方法来实现。观测数据经过数据同化技术处理后生成的再分析数据集,能够包含更加完整、精确和可靠的模拟结果,为深度学习模型的高质量训练提供保障。




图2 再分析数据构建过程

Fig. 2 Reanalysis data construction process

3.3 常用的再分析数据集

3.3.1 ERA5 再分析数据集

ERA5 (European Centre for Medium-Range Weather Forecasts Reanalysis 5)是由欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)发布的全球再分析数据集^[43],时间范围为1950年1月至今,时间分辨率为小时级,数据映射在地球经纬度网格上的空间分辨率为 0.25° ,并将地表到海拔80 km的大气垂直高度分割成137层分量,涉及要素包括温度、湿度、降水量、风场等。ERA5¹⁾包含大气和地表的多方面要素,并且其时空分辨率和数据质量较高,是当前深度学习气象预报大模型的重要训练和测试资源。

3.3.2 WeatherBench 再分析数据集

WeatherBench^[44-45]由谷歌公司推出,用于评估和比较各种天气预报模型的标准化框架,能够横向对比不同模型的预报效果,从而为模型的改进提供思路和依据。WeatherBench系列^{2),3)}由ERA5再分析数据集插值构建而成,它除了具备ERA5自身的各项优势外,还提供了不同空间分辨率(0.25° , 1.40625° , 2.8125° 和 5.625°)下的数据,以满足不同的研究需求。

4 基于深度学习的气象预报模型

近年来,深度学习技术对众多领域起到不可估量的推进

作用,科学研究便是其中作用最为显著的领域之一^[46-47]。AI4Science作为第五范式正在不断加速自然科学研究进程,其通过处理多维度、多模态的大数据,将科学研究方法逐渐从传统的实验科学和理论科学范式扩展到全新的数据驱动科研领域,帮助科学家解决复杂的科学问题,探索以往难以触及的科学领域^[48-50]。

深度学习的强大性能同样为解决气象预报问题提供了全新思路:首先,深度学习模型具有较强的非线性建模能力,可有效处理大气系统的复杂特性,从而减小系统误差的累积效应^[51];其次,深度学习模型能够更充分地挖掘数据中的信息,并有效地将历史观测数据融入到预测过程中,从而提高预测的稳定性和准确性^[52];最后,深度学习模型的计算成本相对较低,并可通过多卡并行计算高效实现复杂模拟任务,从而缓解数值预报模型运行复杂数值模拟时所面临的计算资源限制^[53]。本章将介绍气象预报领域中常用的4种深度学习模型,并分别对单指标预报模型和多指标预报模型进行分类总结。

4.1 气象预报领域中常用的深度学习模型

目前,已有许多通过不同的深度学习模型实现各类气象预报任务的成果,本节将介绍其中最常见的4类深度学习模型框架:CNN, RNN, GNN和ViT。

4.1.1 基于CNN的气象预报模型

CNN善于处理分析具有网格结构的数据,其核心思

¹⁾ <https://cds.climate.copernicus.eu/datasets>

²⁾ <https://github.com/pangeo-data/WeatherBench>

³⁾ <https://github.com/google-research/weatherbench2>

想是通过卷积层、池化层和全连接层等模块提取和学习数据特征,从而发掘数据中的隐藏规律^[54]。CNN 模型在处理复杂数据时具有很强的表征能力和泛化能力,能够从海量气象观测数据中建模学习气象系统的复杂时空关系,识别气象图中的气旋、降水等特征,进而改善气象预报模型的效果。

4.1.2 基于 RNN 的气象预报模型

RNN 常用于处理分析具有时间关联性的序列数据,其核心思想是通过循环结构对序列数据进行逐时间步的处理,并在过程中保持上一状态信息^[55]。气象预报涉及大量时空数据,如特定天气变量在不同地点和时间的变化,而 RNN 的循环结构能够有效处理此类数据,实现短期天气预报、气象事件预警和气候模拟预测等任务。

4.1.3 基于 GNN 的气象预报模型

图神经网络(Graph Neural Network,GNN) 适用于图结构数据,其核心思想是通过图卷积操作完成节点间的信息传递与更新,在考虑全局特征的前提下捕捉节点间的复杂交互关系,常用于复杂关系、建模节点分类、图分类、链接预测等任务^[56]。基于以上能力,GNN 能够对流体系统进行图结构建模,捕捉系统内部的复杂时空关联关系和动态演化规律,并

允许数据在任意范围空间内进行交互,从而解决经纬度格网不均匀分布等问题。

4.1.4 基于 ViT 的气象预报模型

ViT 主要用于处理具有图像特征的数据,其核心思想是通过自注意力机制^[57]和全连接层^[58]构建多层神经网络,而对输入数据进行特征提取和学习^[59]。基于 ViT 的气象预报模型可以通过注意力机制捕捉图像的远距离关系,并在全局范围内对图像特征进行建模,弥补 CNN 受限于局部感受野的问题,因此适用于捕捉气象系统的遥相关特征。

4.2 基于深度学习的气象单指标预报模型

气象单指标预报模型旨在对单个气象要素在特定时空范围内的变化趋势进行预报^[60],常见的气象单指标预报任务包括温度变化预报、降水量预报等,模型预报结果可用于气象灾害预警、农业生产、交通运输等领域的决策和规划^[61]。由于不需要考虑多个变量之间的复杂关系,此类预报任务的建模相对简单,使用的深度学习模型架构规模也相对较小^[62]。本节将介绍基于深度学习的气象单指标预报模型相关研究进展,着重讨论降水预测、近海岸海温预报、台风浪预报及滑坡易发性预测这 4 类较为典型的气象单指标预报任务,相关模型的基本信息对比如表 1 所列。

表 1 气象单指标预报模型基本信息对比						
Table 1 Single-index data-driven weather forecasting model basic information comparson						
任务类型	文献	预报对象	预报时长	预报区域	核心框架	预测性能
降水预报	Lebedev et al. (2019) ^[68]	降水	1h	美国	基于 U-Net 编解码器框架	预报准确率超越数值预报与光流预报方法
	Agrawal et al. (2019) ^[71]	降水	0~6h	俄罗斯	在 U-Net 基础上引入基于卷积的上下采样模块	预报准确率在 90% 以上,超越了对比方法
	Wu et al. (2021) ^[73]	雷达回波 (反映降水情况)	2h	上海和广州	将 MotionGRU 模块嵌入 LSTM 层间用于复杂运动建模	显著提升了临界成功指数
	Wu et al. (2022) ^[76]	降水率	1h	吉林省	在 CNN 和反向传播神经网络的基础上引入注意力机制	在 3 个站点的预报准确率均为 80% 以上
近海岸 海温预报	Chen et al. (2019) ^[85]	近岸站点 海表温度	24h	粤东海域	基于含有 100 个隐含层单元的 LSTM	日均海温预报的 RMSE 平均值为 0.45℃
	Gong et al. (2022) ^[86]	近岸站点 海表温度	24 h	南海海域	基于一维 CNN 搭建的双层卷积模型	日均海温预报的 RMSE 为 0.47℃
台风浪 预报	Reichenbach et al. (2018) ^[90]	台风浪高	1h	南海海域	基于前馈型误差反向传播神经网络	有效波高计算值与观测值的 RMSE 小于 0.3 m
	Tian et al. (2020) ^[91]	极短期波浪时序	100s	上海船舶运输 科学研究所 实验区域	使用 LSTM 替代 GAN 中的生成器,判别器帮助模型自动学习频谱特征	相较于传统时序分析方法,在 MSE 上平均提升了 11%
滑坡易发性 预报	Hao et al. (2016) ^[93]	滑坡可能发生的 高危险区域	—	福建省蔡源 流域以及四川省 北川县	基于前馈型误差反向传播神经网络	蔡源流域:预测精度平均值为 81.60% 北川县:预测精度平均值为 77.45%
	Hao et al. (2014) ^[94]	阶跃型滑坡的位移	10 年	三峡库区的 八字门滑坡	在 CNN 和 Bi-LSTM 的基础上引入注意力机制	累积位移量预测结果的 RMSE 分别为 6.196 mm 和 4.941 mm

4.2.1 降水预报任务

降水预报是气象单指标预报任务中最为重要且最具代表性的任务之一^[63],除极特殊的干旱地区外,地球上大多区域都有降水预报的需要^[64],因此这类预报模型发展迅速且应用广泛,具有较多现有成果^[65-66]。降水属于强对流天气现象^[67],具有较强突发性,这要求模型兼具准确率和高效性,因此相关研究多采用 U-Nets,RNN 和 CNN 等结构相对简单的经典深度学习框架。

1)基于 U-Nets 的短时降水预测。Lebedev 等^[68]提出了

基于 U-Nets^[69]的短期降水预报方法。该方法将卫星图像、太阳高度等多因素作为输入,将输出的预报图像与光流算法^[70]进行结合,实现了短期降水预测。合并的卫星数据图像能够为未被地面雷达覆盖的地区提供临近降水预报,其预报质量与基于雷达的预报接近。

Agrawal 等^[71]对 U-Nets 架构进行了改进,在预测过程中使用每个像素的交叉熵损失来替代光流算法。该模型使用美国国家海洋和大气管理局提出的多雷达多传感器 MRMS 数据集^[72]进行验证,实验结果表明其在短时降水预测任务上

比传统数值方法性能更佳,这表明深度学习方法在短期降水预测任务上存在取代部分数值预报方法的可能。

2)基于 RNN 的时空降水预测模型。Wu 等^[73]基于 RNN 提出了一个轻量化模型 MotionRNN,该模型相比 C-LSTM^[74]以及 PredRNN^[75]等时间序列预测模型具备更强的时空信息传递能力,能够更好地捕捉并处理雷达回波中云团的产生、消散、位移、形变等难以预测的复杂运动。该模型基于上海与广州两地的雷达回波观测资料进行未来两小时的天气预测实验,实验结果表明该模型能够提供恶劣天气的精确预测,在预测准确率上大幅超过其他基准模型。

3)基于 CNN 的临近降水预测模型。Wu 等^[76]充分利用 CNN 中的多层卷积和池化以逐级提取数据特征,并提出了一种基于 CNN 的降水预测模型。模型通过在 CNN 的隐藏层中引入注意力机制来捕捉气压、风速、气温等特征,将其转化为更高层次、更有意义的特征表示,以更好地反映输入数据对降水事件发生的影响程度,提高模型对降水预测的准确性^[77]。最后将降维后的特征向量输入至反向传播神经网络^[78]以完成最终的临近降水预测。该模型对吉林省代表性站点的夏季降水发生进行了预测实验,实验结果表明该模型在所有站点的降水预测准确率均达到 80% 以上。

4.2.2 近海岸海温预报任务

与降水预测不同,近海岸海温预报任务除了需考虑大气及地表变量外,还需考虑近海岸海洋变量,因此模型要考虑更多的约束并挖掘更深层次的物理规律^[79],是海洋预报领域的一大难题^[80]。例如,近海岸海温预报任务会受多种因素影响,包括气候变化、海洋流动等,其预测过程具有高度的复杂性和不确定性。深度学习方法可以利用大量的海洋观测数据,直接从数据中学习海洋变量之间的复杂关系,从而捕捉海洋系统中的非线性和不确定性^[81-82],这种数据驱动的方法为提高近海岸海温预报的准确性提供了新的机遇。近海岸海温预报任务中常用的深度学习方法包括基于 LSTM 的粤东近岸海温预报模型和基于 CNN 的近岸表层海温预报模型。

1)基于 LSTM 的粤东近岸海温预报模型。Lin 等^[83]提出了一种基于 LSTM 的近海岸海温预报模型,使用粤东沿岸各海洋站点的海温观测数据和区域大气模式(Weather Research and Forecasting, WRF)气象预报数据进行训练。实验结果表明,当实验日海温均方变化较小时,该模型能够与当日观测值进行直接比较,并保证误差不超过 0.05℃。值得关注的是,该方法并未对 LSTM 架构进行过多调参,仅针对模型中的层数、丢弃率等进行微调,使用周期为一年的观测数据训练就已实现了较好的预测效果。这意味着在低分辨率、短时间周期近岸海温预报任务上,深度学习模型具有较好的发展前景。

2)基于 CNN 的近岸表层海温预报模型。Weng 等^[84]聚焦于小范围短时的海温预报,将近岸台站定点海温预报转换为多元时间序列预测任务,进而实现智能化海温预报。该模型通过 CNN 对表层海温的时间变化趋势进行建模,预报近岸台站的每日最高海温、最低海温和平均海温。实验结果表明,该模型相较于人工经验预报方法,对全年日最高海温预报

的平均绝对误差减小了 0.36℃,均方根误差减小了 0.49℃。这不仅证明了深度学习模型在近岸海平面温度预报中的可行性,还表明这类模型在中长期海洋变量预报方面同样具有潜力。

4.2.3 台风浪预报任务

台风浪预报需要综合考虑风速、湿度等天气变量以及海平面高度、海洋流速等海洋变量^[85],然而传统的数值预报模型在处理多变量输入时会出现计算开销大、耗时长等问题。相比之下,深度学习预报模型能够显著减少计算量、提高计算效率^[86-87]。台风浪预报任务常用的深度学习方法有基于人工神经网络的台风浪高快速计算方法以及基于改进 LSTM 神经网络的极短期波浪时序预报模型。

1)基于人工神经网络的台风浪高快速计算方法。Zhou 等^[88]基于前馈型误差 BP 神经网络方法建立了能够快速准确预测各浮标站台风浪高度的模型,将 2010 至 2017 年南海范围内 5 个浮标波高观测资料中的热带气旋中心坐标、中心最低气压、近中心最大风速、热带气旋中心与浮标之间的距离共 4 个参数作为模型输入。实验结果表明,该模型能够很好地拟合观测数据进行预报,各浮标有效波高计算值与观测值之间的均方根误差小于 0.3 m,平均相对误差在 6% 左右,证明了该模型的可靠性。此外,测试结果显示在台风“山竹”登陆期间,除预报最大值的出现时间与实际观测情况存在一定偏差外,该模型的有效波高最大预报值与观测值基本吻合,进一步验证了模型的准确性。

2)基于改进 LSTM 神经网络的极短期波浪时序预报模型。Shang 等^[89]提出了一种基于生成式对抗思想改进的 LSTM 架构,将波浪的频谱特性与频域领域中的先验知识通过与生成式对抗网络融合后作为模型输入,增强了神经网络对频谱特性的捕捉能力,实现了时域与频域信息融合的耦合预报。实验结果表明,该模型在波浪极短期时序预报上优于传统预报方法和传统 LSTM,与实际观测值相比平均提升 11% 左右。

4.2.4 滑坡易发性预报任务

滑坡易发性预报任务通常过度依赖先验经验,且容易受到土壤、湿度和温度等主观因素的影响,导致预测结果存在较大的不稳定性^[90]。基于深度学习的预报模型能够通过数据驱动的方法应对该挑战,减少主观因素及先验经验对预测结果的影响。常用方法包括基于人工神经网络的滑坡易发性预测模型和基于时序分析及 CNN-BiLSTM-AM 的阶跃型滑坡位移预测模型。

1)基于人工神经网络的滑坡易发性预测模型。Tian 等^[91]通过对福建省南平市蔡源流域的预测精度、稳定性和数据量敏感性进行深入比较,探究了 BP 人工神经网络模型在滑坡易发性分析中的效果。经过大量实验发现,模型的预测精度随着训练样本数量的增加而提高,证明数据驱动的深度学习模型能够有效从训练数据中学习特征,并提升模型预测精度。对预测结果进行验证后发现,该模型的验证精度均值在 70% 以上,尽管与实际观测值存在差异,但已接近实际滑坡的空间分布。

2)基于时序分析及 CNN-BiLSTM-AM 的阶跃型滑坡位移预测模型。Yang 等^[92]提出了一种基于组合模型提升阶跃型滑坡位移预测能力的方法,以 120 个月的位移监测数据作为模型输入,通过水库水位和降雨量两种数据对模型的预测结果进行验证。实验结果表明,该模型的预测值与实际观测值间的 RMSE 为 5 mm 左右,这证实了结合注意力机制的 CNN-BiLSTM 组合预测模型能够充分提取输入数据的局部特征,并通过注意力机制在捕捉以上特征的同时,克服 BiLSTM 的长期依赖问题,从而提升模型的整体预报性能。

4.3 基于深度学习的气象多指标预报模型

气象多指标预报针对多个气象要素的同步预报,在气象灾害预警、农业生产、能源规划、城市规划等领域具有重要应用价值^[93-94]。多指标预报模型不仅要关注单个气象变量的未来趋势,还要综合考虑多个气象要素之间的复杂关系^[95]。因此该类模型需要拥有更大的参数量和更深的模型架构,才能更全面地捕捉不同天气变量间的潜在变化规律和相互影响方式^[96]。

现阶段的基于深度学习的气象多指标预报模型根据输入数据类别的不同主要分为两类,即再分析数据驱动的气象预报大模型与观测数据驱动的气象同化大模型,本节将分别进行讨论。

4.3.1 再分析数据驱动的气象预报大模型

近年来,诸多再分析数据驱动的气象预报大模型被提出,这类模型基于 ERA5 再分析数据进行训练,能够充分挖掘利用历史观测数据,且具备更快的预报速度和更高的预报精度。

FourCastNet^[97]是 Kurth 等基于自适应傅里叶神经算子(Adaptive Fourier Neural Operators, AFNO)^[98]和 ViT 设计的气象预报大模型。该模型通过空间混合及卷积操作将输入数据转化为连续的全局特征,利用傅里叶变换对特征进行跨空间和信道维度的建模,从而将空间复杂度降低至 $O(N \log N)$,以减少模型计算开销,使其适用于高分辨率预测任务。FourCastNet 选取 5 个垂直分层、每层 20 个变量作为模型输入,在不添加任何物理约束的条件下即可实现 0.25° (约相当于实际距离 37 km)空间分辨率的全球气象预报。实验结果表明该模型 48 小时内的预报结果在均方根误差与异常相关系数两个评价指标上与 IFS-HRES 模式接近,首次实现了数据驱动模型与数值预报模型预报的直接比较。此外,该模型还具备大气河形成、台风行进路径等极端天气事件的预报能力,但其预报结果在 48 小时之后呈明显下降趋势,随着预报时间的推移与 IFS-HRES 间的精度差距逐渐增大,证明其虽已初步具备短期预报能力,但在中长期的气象预报任务上仍有较大提升空间。

Pangu^[99-100]是 Bi 等基于 3D 神经网络构建的中期全球天气预报模型,该模型将不同经度、纬度与海拔高度的气象信息统一合并,组成三维数据作为模型输入。为同时处理复杂不均的三维气象特征,Pangu 基于 Swin Transformer^[101]提出 3D Earth-Specific Transformer(3DEST)模块,用于捕捉各类气象变量在 3D 空间上的关联关系。Pangu 还引入了层次化时域聚合策略,通过减少预报迭代次数的方式减小迭代误差。

具体而言,首先训练好预报时间为 1 小时、3 小时、6 小时及 24 小时的 4 个独立模型。当给定预报目标周期时,系统将采用贪心算法最小化模型调用次数,从而减少模型预报成本及误差累积。例如,对于 7 天预报,系统将对 24 小时预报模型进行 7 次迭代;对于 23 小时预报,则对 6 小时模型迭代 3 次、3 小时迭代 1 次、1 小时迭代 2 次。实验结果表明,Pangu 首次在所有测试的天气变量和全部时间范围内(从 1 小时到 1 周)均优于 IFS-HRES,实现了深度学习模型在气象预报领域的巨大突破。

GraphCast^[102-103]是 Lam 等基于 GNN 设计的一种“编码器-处理器-解码器”架构气象预报大模型。首先,该模型构造多网格(将二十面体迭代 6 次)有向边 GNN,将原始经纬度网格的输入数据映射到多网格上进行特征学习。随后,利用另一个 GNN 在多网格上进行信息传递的学习,在确保空间连通性的同时,允许信息在任意长度的空间上进行有效传播。最后,解码器将多网格表示映射回原始经纬度网格,执行节点更新输出最终预报结果。与 Pangu 相似,GraphCast 同样设计了一种 12 小时的自回归微调策略来减少模型误差累积。该策略分别训练预报时间为 1 小时、2 小时、4 小时、6 小时、8 小时及 12 小时的 6 个模型,并将这些模型的预报结果重新作为输入返回模型中参与后续预报。实验结果显示,GraphCast 在 252 个变量中有 99.2% 的预报结果超过了 Pangu,并在 2760 个变量中有 90% 的预报结果超过了 IFS-HRES。GraphCast 的出现不仅提高了天气预报的准确性,同时也为整个行业带来了新的发展机遇,最关键的是为气象预报大模型提供了新的发展契机。

FengWu^[104]是 Chen 等提出的基于多模态融合的气象预报大模型。多模态模型^[105-106]能够从不同格式的数据中提取出更加丰富、全面的特征,从而提高模型性能和泛化能力。气象预报大模型的输入数据包含多种类型的天气变量,如地表、位势、湿度、温度状态及风向状态的经纬向分量等,因此可被视为一种多模态数据。FengWu 模型的架构分为 3 个主要部分:1)编码器,将上述 6 个不同的大气变量视为相互独立的模态数据,分别输入至对应的专属模态编码器进行特征提取;2)特征融合模块,基于跨模态 Transformer 进行多模态特征融合,生成包含不同模态特征间相互作用的联合表示;3)模态拆分,通过特定的模态解码器分别预报每个变量的未来状态。为了减少模型在长期预报时由于自回归过程产生的较大误差累积,FengWu 设计了重放缓冲区机制。该机制通过存储中间预报结果,并将其与原始数据集共同作为模型输入进行后续预报,来提升长期预报水平。例如,存储在重放缓冲区中第 $i+1$ 时刻的预报会与原始数据集共同作为模型输入,进行第 $i+2$ 时刻的预报,并将其预报结果存储在重放缓冲区中作为下一时刻输入。这一过程通过上述步骤迭代进行,能够迫使模型在预报过程中纠正自回归误差,从而减少误差累积、延长预报时长。此外,重放缓冲区仅在 CPU 上存储数据,减少了 GPU 显存开销,提高了模型训练效率。实验结果表明,FengWu 首次将预报时长延长至 10.75 天,并且 80% 的预报结果优于 GraphCast。这证明了 FengWu 在多模态数据处理和

长期气象预报方面的显著优势。

FuXi^[107]是Chen等基于U-Transformer结构提出的大模型,能将预报时长提升至15天。现有大多气象预报大模型均采用自回归方式实现中长期气象预报,由于误差累积问题,10天以上的预报结果仍然误差较大。为解决上述问题,FuXi基于Swin Transformer V2^[108]和U-Net构建模型,并通过级联策略对不同时间段进行优化,从而在短前置时间和长前置时间上均达到较好的预报效果。具体而言,该策略在预报时长为5天的条件下进行微调以确保在不同预报周期上均能达到最佳。例如要进行15天气象预报,可以通过微调3个时间步长为5天的FuXi模型进行级联,通过这3个模型共同实现预报。实验结果显示,FuXi在进行15天预报时仍能够与IFS-EM^[109]性能相当,而IFS-EM是ECMWF的集合预报系统,通常比IFS-HRES更为准确。该结果进一步证明了气象大模型的强大性能和巨大潜能。

4.3.2 观测数据驱动的气象同化大模型

现有气象预报大模型均基于再分析数据集进行训练,而再分析数据的构建需要通过资料同化技术及数值预报模式才能完成,这使得数据驱动的大模型始终无法摆脱对物理动力模式的依赖。因此,发展基于人工智能的数据同化方法,在大模型内部完成观测数据同化步骤,实现端到端的深度学习预报模型成为热门研究方向。本小节将介绍3个观测数据驱动的气象同化大模型:FengWu-Adas, FengWu-4DVar和FuXi-DA。

FengWu-Adas^[110]是Chen等基于FengWu大模型设计的首个端到端气象预报大模型,其中FengWu模型负责生成短期天气预报结果,作为同化模型的背景状态输入;Adas模块则通过门控卷积^[111]和门控交叉注意模块处理稀疏观测数据,并结合置信矩阵评估观测数据的可用性和质量,生成高质量的分析数据作为下一个时间步的初始状态,从而形成一个自我纠正的循环预报框架。该架构不仅克服了传统四维变分(Four-Dimensional Variational, 4DVar)算法需要复杂误差反推的问题,还通过时间聚合策略减少了前向积分误差,从而提高了同化精度。

FengWu-4DVar^[112]是Xiao等基于FengWu大模型和4DVar数据同化算法^[113]设计的一种能够在不依赖物理模型的情况下实现自我纠正的循环气象预报系统。该系统利用深度学习模型的自动微分能力,避免了传统4DVar算法中需要误差反推的复杂问题,并采用时间聚合策略减少了前向积分误差,从而提高了同化精度。实验结果表明,FengWu-4DVar在多个气象变量上的同化结果比传统方法更精确,且该系统在单个A100 GPU上能够在半分钟内完成未来6小时的同化,极大提升了同化速度。

FuXi-DA^[114]是Xu等基于FuXi大模型设计的同化大模型,该模型的输入数据包括先验背景场数据和处理后的实时观测数据,通过同化模块可将观测数据的分辨率与背景场数据匹配,从而减少不确定性。FuXi-DA通过U-Net架构中的上、下采样模块实现不同数据源之间的交互,从而简化了数据同化的预处理步骤,降低了计算资源的消耗。

5 气象预报大模型的性能评测与对比

气象预报大模型在近年取得了重大突破,然而现阶段仍然缺乏对此类模型的综合对比与分析。针对该问题,本章说明了主要的气象预报性能评价指标,介绍了主要的开源资源和评测基准,并从预报性能、模型架构与算力开销等层面,对重要气象预报大模型进行全面总结和综合对比。

5.1 气象预报性能评价指标

气象预报注重模型的实用性,因此评测指标侧重于评估模型在实际应用场景中的预报效果,如关注预报值与观测值之间的差异、预报和观测在异常模式上的一致性。本节将介绍气象预报任务中最常用的两个评价指标:均方根误差和异常相关系数。

5.1.1 均方根误差

均方根误差(Root Mean Square Error, RMSE)是衡量预报值与实际观测值之间差异的一种常用指标,能够确保计算单位与实际数据单位相同,便于理解和解释。其计算式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2}$$

其中, N 是样本总量, F_i 是第 i 个样本的预报值, O_i 是第 i 个样本的观测值。 $RMSE$ 可以评估模型预报结果的整体情况,其值越小,说明预报结果与实际观测值之间的差异越小,模型预报精度越高;反之则模型可能存在较大的预报误差,需要进一步优化模型架构或改进预报方法。

5.1.2 异常相关系数

异常相关系数(Anomaly Correlation Coefficient, ACC)常用于评估气象预报模型对气象现象异常变化的预报能力,其计算式如下:

$$ACC = \frac{\sum_{i=1}^N (F_i - C_i)(O_i - C_i)}{\sqrt{\sum_{i=1}^N (F_i - C_i)^2} \sqrt{\sum_{i=1}^N (O_i - C_i)^2}}$$

其中, N 是样本总量, F_i 是第 i 个样本的预报值, O_i 是第 i 个样本的观测值, C_i 是第 i 个样本对应的气候态值。 ACC 衡量的是预报与观测在异常变化模式上的相似性,而不是绝对值的精确度,因此其能够评估预报模型在捕捉异常变化方面的能力。其值较大时表示模型异常变化预报能力强,反之则较弱。

5.2 气象预报大模型性能比较

本节将从气象预报大模型的输入要素、技术架构和预报能力3个方面入手,对现阶段主要的深度学习气象预报大模型进行比较和分析。

5.2.1 大模型输入要素对比

表2列出了现有气象预报大模型的输入数据集划分、输入维度、输入变量数、输入天数等对比情况,表中模型均采用分辨率为 0.25° 的ERA5再分析数据集进行训练,因此其输入、输出维度均为 1440×721 的标准经纬度格网。不同模型在天气变量数和输入天数上略有不同。其中,FourCastNet的输入维度为 $1 \times 20 \times 1440 \times 721$,表示20个经度为1440、纬度为721的天气变量作为模型输入,这些变量包括14个高空

大气变量、5 个地表变量和 1 个总水汽柱变量;Pangu 的输入变量数为 $13\times5+4$,表示在选取的 13 个压力层中每层抽取 5 个高空大气变量,共计 65 个高空大气变量,外加 4 个地表

变量,合并后作为模型输入;FuXi 将输入天数设置为 t 与 $t-1$ 两天,即模型需要参考前两天的天气状况以实现后续预报,这也意味着相同输入变量条件下,输入维度扩大了两倍。

表 2 气象预报大模型输入变量对比
Table 2 Data-driven weather forecasting model input variables comparison

模型	输入数据集划分			输入维度、变量数及天数		
	训练集	验证集	测试集	输入维度	输入变量数	输入天数
FourCastNet	1979—2015	2016—2017	2018—2021	$1\times20\times721\times1440$	$14+5+1(20)$	t
Pangu	1979—2017	2019	2018,2020—2021	$1\times69\times721\times1440$	$13\times5+4(69)$	t
GraphCast	1979—2015	2016—2017	2018	$1\times227\times721\times1440$	$37\times6+5(227)$	t
FengWu	1979—2015	2016—2017	2018	$1\times189\times721\times1440$	$37\times5+4(189)$	t
FuXi	1979—2015	2016—2017	2018	$2\times70\times721\times1440$	$13\times5+5(70)$	$t-1,t$

5.2.2 大模型技术架构对比

表 3 列出了现有深度学习气象大模型的模型架构、降维方法及推理策略等信息的对比情况。在模型架构方面,大多数气象大模型采用 ViT 及其变体作为基础框架,这表明当前计算机视觉领域的各类模型同样具有迁移应用至气象预报领域的巨大潜力。在降维方法方面,由于气象数据分辨率高、数据量大,为降低计算开销、提升运算效率,特征提取与数据降维过程十分重要,常用方法包括 Cube Embedding、下采样等。在推理策略支持方面,由于气象预报大模型多采用自回归

迭代推理,推理误差会随推理步骤的增多而不断累积,因此需要在推理过程中引入改进策略,以缓解误差积累、提升预报时长。例如 Pangu 的层级时域聚合策略和 GraphCast 中的自回归步数微调策略等,均通过减少模型迭代次数来减少误差累积;FengWu 的重放缓冲区机制则利用前期预报结果作为先验知识纠正模型预报结果;FuXi 的级联设计则将最大预报时间延长至 15 天。综上可知,如何设计出一种合理科学的模型架构和策略方法,帮助模型降低算力需求、减小自回归误差是该领域当前重要的研究方向。

表 3 气象预报大模型技术架构对比
Table 3 Data-driven weather forecasting model technical architecture comparison

模型	模型架构	特征提取与降低维度方法	提高模型预报精度策略
FourCastNet	ViT, AFNO	Patch and Position Embedding	—
Pangu	3D Earth-Specific Transformer	Patch Embedding	层级时域聚合
GraphCast	GNN	—	自回归步数微调
FengWu	Cross-Modal Transformer	Modal-Customized Encoders extract features independently	重放缓冲区机制
FuXi	U-Net, Swin-Transformer	Cube Embedding and Down Block	级联设计

5.2.3 大模型性能表现对比

表 4 对现有气象预报大模型的预报时长、预报分辨率、预报效果及预报能力进行了整合比较。由表中内容可知,大模型的预报时长在短期内从 7 天提升至 15 天,其预报耗时均为秒级,相比数值预报方法提升了多个数量级,且大多数大模型的预报效果均已达到甚至超过最先进数值预报业务系统 IFS,可见其优越性能和巨大潜能。此外,大模型均具备一定的极端天气预报能力,如台风行进路线预报、大气层河流预报、热点气旋跟踪、极端降水预报等。然而,极端天气成因的复杂性和不确定性、极端天气数据的稀缺性和不平衡性,以及深度学习模型的不完备性和过平滑性^[97],导致现有气象预报大模型在极端天气预报方面仍有巨大提升空间。图 3 横向

比较了不同气象预报大模型与业务预报系统 IFS 在预报周期(横坐标)为 1~10 天时,对不同天气变量的预报结果,这些变量包括 500 hPa 位势高度(Z500)、500 hPa 温度(T500)、地面径向风分量(V500)、500 hPa 径向风分量(U500)以及地表 2 米温度(T2M);评价标准包括 ACC 和 RMSE。为便于直观比较,IFS 作为基准用黑色虚线表示。由图 3 可知,现阶段的气象预报大模型在诸多变量上呈现出较好的预报性能,已初步达到甚至超越传统数值方法的预报能力。此外,随着预报时间的推移,大多数大模型的预报精度下降程度小于 IFS,这意味着气象预报大模型能够通过不同的策略在一定程度上减小自回归过程中产生的误差,从而缓解数值预报模型系统误差大、历史观测数据利用率低等问题。

表 4 气象预报大模型预报性能对比
Table4 Data-driven weather forecasting model forecast performance comparison

模型	预报时长及分辨率	算力条件	预报效果	极端天气预测能力
FourCastNet	7 天 0.25°	在单台 NVIDIA Tesla-A100 GPU 设备上,需 0.28 秒完成 24 小时预报推理	两天内的预报变量超过 IFS-HRES	台风行进路径、大气层河流和极端降水
Pangu	7 天 0.25°	在单台 NVIDIA Tesla-V100 GPU 设备上,需 1.4 秒完成 24 小时预报推理	7 天内的绝大多数预报变量超过 IFS-HRES	台风行进路线、寒潮观测、热带气旋跟踪
GraphCast	10 天 0.25°	在单台 Cloud TPU v4 设备上,需 60 秒完成 10 天内的预报推理	7 天内 90%的预报变量大幅度超过 IFS-HRES 及 Pangu	台风行进路径、大气层河流
FengWu	10, 75 天 0.25°	在单 GPU 设备上,需 30 秒完成 10 天内的预报推理	10 天内 80%的预报变量超过 GraphCast	台风行进路径
FuXi	15 天 0.25°	—	在 80%的预报变量上超过 IFS-EM	台风行进路径、极端降水




图3 数据驱动气象预报模型与数值气象预报模型的性能比较

Fig. 3 Performance comparison of data-driven weather forecasting model and numerical weather forecasting model

通过对气象预报大模型的比较可以看出,大模型在预报精度、预报周期、预报耗时等方面均具备相当大的发展潜力,但同样还存在诸多不足之处,例如大模型的建模过程缺乏数学物理机理进行约束,存在模型难解释、预报结果与物理规律难协调等问题;大模型依托再分析数据作为训练数据,需要依赖数据同化等技术作为支撑,难以直接利用观测数据;大模型的训练过程以最小化全局 RMSE 为目标,可能导致过平滑问题,对暴雨、台风、干旱、寒潮等极端天气事件的预报能力仍然存在较大的突破空间等。

5.3 开源资源与评测基准

随着深度学习在气象预报领域的广泛应用,为推动研究的透明性、可复现性和对比公平性,近年来多个开源数据集、模型代码库和评估框架被相继提出。通过这些资源,研究者可以方便地获取历史训练数据,复现已有的模型,并基于统一标准客观公平地评估模型的性能。我们整理了深度学习气象预报领域常用的开放资源平台、测试基准(Benchmarks)以及基线模型(Baselines)。

5.3.1 开源资源平台

开放资源平台可以提高研究的可复现性,使研究人员可以在已有成果的基础上进行创新和改进,从而加速深度学习气象预报模型的进步与应用。智能气象预报常用的开放资源平台如下:

PaperswithCode 平台上的 Weather-forecasting 项目¹⁾汇总了深度学习气象预报领域的最新研究模型、代码实现及其对应的 Benchmarks,研究者可以通过该平台复现和对比现有模型。

GitHub 上也有许多与气象预报相关的资源,为研究者提供了广泛的参考文献和实现示例。例如 Awesome-LWMs²⁾汇总了大量气象预报大模型的最新成果和开源项目,涵盖了 FourCastNet, Pangu 等多个气象预报模型的原文、代码及数据。

5.3.2 Benchmarks

Benchmark 指用来评估和比较不同模型或算法性能的标准数据集、任务和评测指标。它们提供了一致的测试条件,帮助研究人员公平地比较不同模型在预测任务中的表现。通过对比模型的得分情况,研究者可以直观地比较不同模型在各类气象预报任务中的表现。

ERA5 作为全球最全面的再分析数据集之一,不仅被广泛用于训练深度学习气象预报模型,而且是模型性能评估的标准数据集。其高分辨率和长时间序列为中长期气象预报提供了强大的数据支持,适用于大尺度气象事件预测、台风路径预测、热带气旋预报,以及全球气候模式预报等任务。

WeatherBench 和 WeatherBench2.0 是专用于评估比较智能预报模型的基准框架,它们以 ERA5 数据集为测试真值,参照气象预报机构及世界气象组织的评估方式,选取多种预报指标和评估指标,构建了全面衡量天气预报质量的记分卡,并提供了评测代码以及代表性模型的得分对比情况。

5.3.3 Baselines

现有常用于气象预报模型间性能比较的 Baseline 包括 IFS, FourCastNet, Pangu, 以及 GraphCast 等。

IFS 是当前最先进的数值天气预报业务系统之一,该系统由 ECMWF 研发,能够提供全球范围内的高精度天气预报。IFS 常被选为对比深度学习模型相较于传统模型性能表现的 baseline,性能超过 IFS 意味着深度学习方法已经能在基于 ERA5 初始场的气象预报中达到甚至超过传统数值方法,是深度学习气象预报模型发展的重要里程碑。

FourCastNet 是早期重要的气象预报大模型,该模型将 ViT 架构与 AFNO 结合,显著提升了预报精度和效率,因此常被选为基线模型用于性能对比,尤其是对比模型的短期预报效果。

Pangu 以及 GraphCast 是重要的气象预报大模型,二者

¹⁾ <https://paperswithcode.com/task/weather-forecasting>

²⁾ <https://github.com/jaychempan/Awesome-LWMs>

分别基于 ViT 框架和 GNN 两种典型框架构建,并且分别发表于顶级学术期刊 Nature 与 Science,代表气象预报大模型的顶尖水平,因此常被选为基线模型。

6 未来研究方向

气象预报是 AI4Science 领域中的重要挑战之一,随着人工智能技术的快速发展与日趋成熟,基于深度学习的气象预报模型已经在短、中期的多种天气变量预报任务上取得丰硕成果,并在预报精度、预报时长、推理效率和数据利用率上展现出巨大发展潜力,逐步成为与传统数值方法并驾齐驱、相互补充的重要手段。但在提升模型的长期预报精度、实时性和应对复杂气象现象的能力方面,仍然存在诸多挑战。因此,如何更有效地结合物理约束条件、实现多种技术架构联合、直接利用观测数据,以及提升对突发气象事件的预报能力,将成为推动气象预报模型进一步发展的关键。本章从上述角度出发,探讨了未来基于深度学习的气象预报模型的 4 个重要研究方向。

6.1 物理约束与数据驱动融合的预报模型

当前预报方法主要依赖数据驱动,基于大规模历史观测数据训练深度学习模型。然而深度学习模型的本质黑盒属性、数据驱动模式下对物理约束的忽略,以及物理机理的时空耦合关联复杂特征,导致模型输出结果具有不可解释性和物理规律不协调性等问题。此外,在长时间跨度的气象预报中,不符合现实物理约束的预报结果可能造成误差随时间逐渐积累,导致长时间跨度预报精度下降。为解决上述问题,物理约束条件的引入成为研究热点。

物理规律驱动数值气象海洋要素预报是现代天气预报的重要支撑,而利用纯数据驱动的智能预报模式则是当前预报领域的前沿热点。联合二者优势,实现物理约束与数据驱动充分结合、相互耦合、深度融合的气象海洋预报,是未来重要的研究方向。

物理约束的融合可以通过多种方式实现,例如将物理气象模型中的守恒定律(如质量、动量和能量守恒)作为约束条件,嵌入深度学习模型的损失函数中^[115-116]。而该融合方向的研究挑战在于如何有效平衡数据驱动方法的灵活性与物理约束的精确性。未来或将通过设计新的网络结构、约束方法以及优化策略,实现数据与物理规律的深度融合,提升模型在长期预报中的稳健性、物理协调性以及可解释性。

6.2 多架构联合的预报模型

现有的气象预报模型大多基于单一的神经网络架构,如 CNN 或 ViT 等。虽然这些模型在特定任务上表现出色,但其性能易受到架构设计的限制。例如,CNN 善于捕捉空间特征,但在时间维度上的表现较弱,而 RNN 或 LSTM 等时间序列模型虽然可以处理时序信息,但在长时间依赖的建模上仍存在局限。

为提升模型的综合性能,越来越多的研究开始探索多架构联合的方案。例如,结合 CNN 和 RNN 的混合模型可以同时捕捉天气数据中的时间和空间依赖关系,提升对复杂天气系统的理解。将 GNN 与 ViT 模型进行结合能够在处理空间格网不均匀数据以建模大尺度气象现象的同时,基于全局自

注意力机制有效捕捉远距离依赖关系,从而解决极端天气事件预报和气候预报问题。

6.3 直接利用观测数据的预报模型

现阶段的气象预报模型大多依赖再分析数据进行训练,这类数据通过复杂的数值天气模式和数据同化技术生成,其构建过程需要大量的计算资源,且往往存在一定的时滞。因此,研究者们开始探讨如何直接利用实时的观测数据进行预报。

直接基于观测数据的同化模型可以减少再分析过程中的误差引入,并提高模型的实时性,但其开发难点在于多源异构数据的处理以及融合模型的构建。首先,观测数据的高效处理是一个关键挑战。与再分析数据相比,实时观测数据的质量往往不均衡,因此需引入异常检测、噪声过滤等预处理技术。其次,需要开发能够处理多源、异构、实时数据的高效模型架构,构建多模态学习模型,自动融合学习雷达、卫星、气象站等多种观测数据源。

6.4 针对突发气象事件与气候态变化的预报模型

突发气象事件(如台风、暴雨、寒潮等)以及中长期气候态的预报(如厄尔尼诺现象、气候变暖趋势、季风系统变化等)对于气候适应性决策、农业生产、能源规划和灾害防控等领域的发展具有重要意义。当前,深度学习气象预报模型在短期天气预报中表现出色,但在应对突发事件和中长期气候态变化方面仍存在较大挑战。突发事件往往伴随着复杂的气象动力过程,对其预测要求模型能够捕捉气象变量的微小变化,并对非线性系统中的突变行为作出反应。中长期气候态具有多尺度、长期累积的变化特性,对其预测需要模型能够有效建模大气环流、海气相互作用等复杂的多时间尺度过程。

为解决上述问题,近年来出现了多种先进的模型架构。例如,CNN 与 LSTM 结合的模型能够有效捕捉空间和时间上的气象变化特征,从而更好地处理突发气象事件预测问题。这类模型在台风路径预测、暴雨强度估计等应用中表现出色,因为它们能够同时建模大尺度天气系统的时空演化和局地天气特征。另一方面,基于 GNN 与变分自编码器结合的模型能够有效处理全球或区域气候模式的复杂空间依赖性和时间延迟性,适合处理中长期气候态的预报问题。这些模型能够通过图结构捕捉气候系统中的多尺度关联,从而在气候变化、厄尔尼诺现象和季风变化的长期预测中取得一定的进展。

未来研究需要在上述模型的基础上,进一步探索更高分辨率的预报模型,通过增加数据源(如卫星遥感、大气再分析数据等)和提高计算能力等方式进一步提升突发气象事件与中长期气候态变化的预报精度和可靠性。此外,不确定性量化和风险评估模型的引入或许将提高气象预报的实用性,特别是在极端天气事件和气候变化带来的潜在风险评估中。

结束语 本文在全面调研相关文献成果的前提下,详细说明了气象预报任务的定义以及气象预报模型的分类,充分介绍了深度学习气象预报模型的常用数据集及其构建过程,全面总结了应用于各类气象预报任务的典型深度学习模型框架,综合对比了各气象预报大模型的性能表现,分析展望了深度学习气象预报模型的未来重点发展方向,旨在为相关研究提供研究思路和参考。总而言之,深度学习已被广泛应用于

自然科学中的气象海洋预报领域,各类预报模型正在高速发展并且日趋成熟,但在可解释性、物理机理协调性、观测数据直接融入、极端气象事件预测等方面仍然存在提升空间和发展需要。

参 考 文 献

- [1] MURPHY A H. What is a good forecast? an essay on the nature of goodness in weather forecasting[J]. *Weather and Forecasting*, 1993, 8(2): 281-293.
- [2] ZHANG Q J, HONG G, WU D L, et al. Development Status, Problems and Prospects of Agrometeorological Observation Operation in China[J]. *Chinese Journal of Agrometeorology*, 2023, 44(8): 735-749.
- [3] XIANG Y, CONG D M, ZHANG Y, et al. Two-Stream Neural Network Fusion Model for Highway Fog Detection[J]. *Journal of Southwest Jiaotong University*, 2019, 54(1): 173-179.
- [4] QIU S M, WANG X K, DU X L. Evaluation of Military Communication Effectiveness in Meteorological Environment Based on Optimized BP Neural Network[J]. *Fire Control & Command Control*, 2022(3): 89-96.
- [5] KENDON E J, ROBERTS N M, FOWLER H J, et al. Heavier summer downpours with climate change revealed by weather forecast resolution model[J]. *Nature Climate Change*, 2014, 4(7): 570-576.
- [6] LORENC A C. Analysis methods for numerical weather prediction[J]. *Quarterly Journal of the Royal Meteorological Society*, 1986, 112(474): 1177-1194.
- [7] TAO S Y, ZHAO S X, ZHOU X P, et al. 2003: The Research Progress of the Synoptic Meteorology and Synoptic Forecast [J]. *Chinese Journal of Atmospheric Sciences*, 2003, 27(4): 451-467.
- [8] SHEN X S, SU Y, HU J L, et al. Development and operation transformation of GRAPES global middle-range forecast system [J]. *Appl Meteor Sci*, 2017, 28(1): 1-10.
- [9] BAUER P, THORPE A, BRUNET G. The quiet revolution of numerical weather prediction [J]. *Nature*, 2015, 525(7567): 47-55.
- [10] RICHARDSON L F. *Weather prediction by numerical process* [M]. Cambridge: Cambridge University Press, 1922.
- [11] MU M, CHEN B Y, ZHOU F F, et al. Methods and Uncertainties of Meteorological Forecast [J]. *Meteor Mon*, 2011, 37(1): 1-13.
- [12] SHEN X S, WANG J J, LI Z C, et al. China's independent and innovative development of numerical weather prediction [J]. *Acta Meteorologica Sinica*, 2020, 78(3): 451-476.
- [13] BUIZZA R, MILLEER M, PALMER T N. Stochastic representation of model uncertainties in the ecmwf ensemble prediction system [J]. *Quarterly Journal of the Royal Meteorological Society*, 1999, 125(560): 2887-2908.
- [14] GNEITING T, RAFTERY A E. Weather forecasting with ensemble methods [J]. *Science*, 2005, 310(5746): 248-249.
- [15] SCHER S, MESSORI G. Predicting weather forecast uncertainty with machine learning [J]. *Quarterly Journal of the Royal Meteorological Society*, 2018, 144(717): 2830-2841.
- [16] SONG J Q, WU X J, ZHANG L L, et al. A Study of the Two Helmholtz Solvers in the GRAPES Model Using GCR and GMRES [J]. *Computer Engineering & Science*, 2011, 33(11): 65-70.
- [17] RÉMY S, KIPLING Z, FLEMMING J, et al. Description and evaluation of the tropospheric aerosol scheme in the european centre for medium-range weather forecasts (ecmwf) integrated forecasting system (ifs-aer, cycle 45r1) [J]. *Geoscientific Model Development*, 2019, 12(11): 4627-4659.
- [18] YANG F, PAN H L, KRUEGER S K, et al. Evaluation of the ncep global forecast system at the arm sgp site [J]. *Monthly Weather Review*, 2006, 134(12): 3668-3690.
- [19] SMITH D M, CUSACK S, COLMAN A W, et al. Improved surface temperature prediction for the coming decade from a global climate model [J]. *Science*, 2007, 317(5839): 796-799.
- [20] GROVER A, KAPOOR A, HORVITZ E. A deep hybrid model for weather forecasting [C] // *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2015: 379-386.
- [21] LYNCH P. The origins of computer weather prediction and climate modeling [J]. *Journal of Computational Physics*, 2008, 227(7): 3431-3444.
- [22] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [23] BERDEJO-ESPINOLA V, AMANO T. AI tools can improve equity inscience [J]. *Science*, 2023, 379(6636): 991-991.
- [24] HUANG X M, LIN Y L, XIONG W, et al. Research on international developments of AI large meteorological models in numerical forecasting [J]. *Trans Atmos Sci*, 2024, 47(1): 46-54.
- [25] ALABDULMOHSIN I M, NEYSHABUR B, ZHAI X. Revisiting neural scaling laws in language and vision [J]. *Advances in Neural Information Processing Systems*, 2022, 35: 22300-22312.
- [26] SHI X, CHEN Z, WANG H, et al. Convolutional lstm network: A machine learning approach for precipitation nowcasting [C] // *Proceedings of the 28th International Conference on NEURAL Information Processing Systems*. 2015: 802-810.
- [27] MARKOVICS D, MAYER M J. Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction [J]. *Renewable and Sustainable Energy Reviews*, 2022, 161: 112364.
- [28] REN X, LI X, REN K, et al. Deep learning-based weather prediction: A survey [J]. *Big Data Research*, 2021, 23: 100178.
- [29] JASEENA K U, KOVOOR B C. Deterministic weather forecasting models based on intelligent predictors: A survey [J]. *Journal of King Saud University-computer and Information Sciences*, 2022, 34(6): 3393-3412.
- [30] ABDALLA A M, GHAITH I H, TAMIMI A A. Deep learning weather forecasting techniques: literature survey [C] // *2021 International Conference on Information Technology (ICIT)*. IEEE, 2021: 622-626.
- [31] YANG X, DAI K, ZHU Y J. Progress and challenges of deep learning techniques in intelligent grid weather forecasting [J]. *Acta Meteorologica Sinica*, 2022, 80(5): 649-667.

[32] LAZO J K, MORSS R E, DEMUTH J L. 300 billion served: Sources, perceptions, uses, and values of weather forecasts[J]. Bulletin of the American Meteorological Society, 2009, 90(6): 785-798.

[33] SUN J, CAO Z, LI H, et al. Application of artificial intelligence technology to numerical weather prediction[J]. Journal of Application Meteorological Science, 2021, 32(1): 1-11.

[34] ESTÉVEZ J, GAVILÁN P, GIRÁLDEZ J V. Guidelines on validation procedures for meteorological data from automatic weather stations[J]. Journal of Hydrology, 2011, 402(1/2): 144-154.

[35] CARRASSI A, BOCQUET M, BERTINO L, et al. Data assimilation in the geosciences: An overview of methods, issues, and perspectives [J]. Wiley Interdisciplinary Reviews: Climate Change, 2018, 9(5): e535.

[36] WANG X, MA Y, WANG Y, et al. Traffic flow prediction via spatial temporal graph neural network[C]// Proceedings of the Web Conference 2020. 2020: 1082-1092.

[37] GAO F, YANG Y, WANG J, et al. A deep convolutional generative adversarial networks (DCGANs)-based semi-supervised method for object recognition in synthetic aperture radar(SAR) images[J]. Remote Sensing, 2018, 10(6): 846.

[38] WANG B, ZOU X, ZHU J. Data assimilation and its applications [J]. Proceedings of the National Academy of Sciences, 2000, 97(21): 11143-11144.

[39] KHODARAHMI M, MAIHAMI V. A review on kalman filter models[J]. Archives of Computational Methods in Engineering, 2023, 30(1): 727-747.

[40] COURTIER P, ANDERSSON E, HECKLEY W, et al. The ECMWF implementation of three-dimensional variational assimilation(3D-var). I: Formulation[J]. Quarterly Journal of the Royal Meteorological Society, 1998, 124(550): 1783-1807.

[41] AMARI S I. Backpropagation and stochastic gradient descent method[J]. Neurocomputing, 1993, 5(4/5): 185-196.

[42] FLETCHER R, REEVES C M. Function minimization by conjugate gradients[J]. The Computer Journal, 1964, 7(2): 149-154.

[43] HERSBACH H, BELL B, BERRISFORD P, et al. The era5 global reanalysis[J]. Quarterly Journal of the Royal Meteorological Society, 2020, 146(730): 1999-2049.

[44] RASP S, DUEBEN P D, SCHER S, et al. Weatherbench: a benchmark data set for data-driven weather forecasting[J]. Journal of Advances in Modeling Earth Systems, 2020, 12(11): e2020MS002203.

[45] RASP S, HOYER S, MEROSE A, et al. Weatherbench 2: A benchmark for the next generation of data-driven global weather models[J]. Journal of Advances in Modeling Earth Systems, 2024, 16(6): e2023MS004019.

[46] JUMPER J, EVANS R, PRITZEL A, et al. Highly accurate protein structure prediction with alphafold [J]. Nature, 2021, 596(7873): 583-589.

[47] SINGHAL K, AZIZI S, TU T, et al. Large language models encode clinical knowledge[J]. Nature, 2023, 620(7972): 172-180.

[48] ABRAMSON J, ADLER J, DUNGER J, et al. Accurate structure prediction of biomolecular interactions with alphafold 3[J]. Nature, 2024, 630: 493-500.

[49] MERCHANT A, BATZNER S, SCHOENHOLZ S S, et al. Scaling deep learning for materials discovery [J]. Nature, 2023, 624(7990): 80-85.

[50] KHARE D, CHEN Z, GULOTTY R, et al. Probabilistic physics-integrated neural differentiable modeling for isothermal chemical vapor infiltration process [J]. NPJ Computational Materials, 2024, 10(1): 120.

[51] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven earth system science[J]. Nature, 2019, 566(7743): 195-204.

[52] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-127.

[53] LI M, ZHANG T, CHEN Y, et al. Efficient mini-batch training for stochastic optimization[C]// Proceedings of the 20th ACM SIGKDD International Conference on KNOWLEDGE Discovery and Data Mining. 2014: 661-670.

[54] LI Z, LIU F, YANG W, et al. A survey of convolutional neural networks: analysis, applications, and prospects[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33(12): 6999-7019.

[55] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673-2681.

[56] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(1): 4-24.

[57] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 11(4): 6000-6010.

[58] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

[59] HAN K, WANG Y, CHEN H, et al. A survey on vision transformer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(1): 87-110.

[60] ZHU Y, TOTH Z, WOBUS R, et al. The economic value of ensemble-based weather forecasts[J]. Bulletin of the American Meteorological Society, 2002, 83(1): 73-84.

[61] GLAHN H R, RUTH D P. The new digital forecast database of the national weather service[J]. Bulletin of the American Meteorological Society, 2003, 84(2): 195-202.

[62] RODRIGUES E R, OLIVEIRA I, CUNHA R, et al. Deepdownscale: A deep learning strategy for high-resolution weather forecast[J]. arXiv:1808.05264, 2018.

[63] BAI C, SUN F, ZHANG J, et al. Rainformer: Features extraction balanced network for radar-based precipitation nowcasting [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.

[64] RAVURI S, LENC K, WILLSON M, et al. Skilful precipitation nowcasting using deep generative models of radar[J]. Nature, 2021, 597(7878): 672-677.

[65] ANDRYCHOWICZ M, ESPEHOLT L, LI D, et al. Deep learning for day forecasts from sparse observations[J]. arXiv:2306.

- 06079,2023.
- [66] GAO Z,SHI X,WANG H,et al. Earthformer:Exploring space-time transformers for earth system forecasting[J]. *Advances in Neural Information Processing Systems*,2022,35:25390-25403.
 - [67] MOON S H,KIM Y H,LEE Y H,et al. Application of machine learning to an early warning system for very short-term heavy rainfall[J]. *Journal of Hydrology*,2019,568:1042-1054.
 - [68] LEBEDEV V,IVASHKIN V,RUDENKO I,et al. Precipitation nowcasting with satellite imagery[C]// *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2019:2680-2688.
 - [69] RONNEBERGER O,FISCHER P,BROX T. U-net:Convolutional networks for biomedical image segmentation[C]// *Medical Image Computing and Computer-assisted Intervention-MICCAI 2015:18th International Conference,Munich,Germany,October 5-9,2015,Proceedings, Part III*. Springer, 2015: 234-241.
 - [70] SUN D,ROTH S,BLACK M J. A quantitative analysis of current practices in optical flow estimation and the principles behind them[J]. *International Journal of Computer Vision*,2014,106:115-137.
 - [71] AGRAWAL S,BARRINGTON L,BROMBERG C,et al. Machine learning for precipitation nowcasting from radar images[J]. *arXiv*:1912.12132,2019.
 - [72] ZHANG J,HOWARD K,LANGSTON C,et al. Multi-radar multi-sensor(mrms) quantitative precipitation estimation:Initial operating capabilities[J]. *Bulletin of the American Meteorological Society*,2016,97(4):621-638.
 - [73] WU H,YAO Z,WANG J,et al. Motionrnn:A flexible model for video prediction with spacetime-varying motions[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021:5435-15444.
 - [74] ZHOU C,SUN C,LIU Z,et al. A c-lstm neural network for text classification[J]. *arXiv*:1511.08630,2015.
 - [75] WANG Y,WU H,ZHANG J,et al. Predrnn:A recurrent neural network for spatiotemporal predictive learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,2022,45(2):2208-2225.
 - [76] WU X H,HUA Y J,GUAN Y H,et al. Application of CNN-Attention-BP to precipitation forecast[J]. *Journal of Nanjing University of Information Science & Technology*,2022,14(2):148-155.
 - [77] PAN B,HSU K,AGHAKOUCHAK A,et al. Improving precipitation estimation using convolutional neural network[J]. *Water Resources Research*,2019,55(3):2301-2321.
 - [78] WERBOS P J. Backpropagation through time:what it does and how to do it[J]. *Proceedings of the IEEE*,1990,78(10):1550-1560.
 - [79] SHIN S I,NEWMAN M. Seasonal predictability of global and north american coastal sea surface temperature and height anomalies[J]. *Geophysical Research Letters*, 2021, 48(10): e2020GL091886.
 - [80] SANDERY P A,SAKOV P. Ocean forecasting of mesoscale features can deteriorate by increasing model resolution towards the submesoscale[J]. *Nature Communications*,2017,8(1):1566.
 - [81] ZHANG Q,WANG H,DONG J,et al. Prediction of sea surface temperature using long short-term memory[J]. *IEEE Geoscience and Remote Sensing Letters*,2017,14(10):1745-1749.
 - [82] YANG Y,DONG J,SUN X,et al. A cfcc-lstm model for sea surface temperature prediction[J]. *IEEE Geoscience and Remote Sensing Letters*,2017,15(2):207-211.
 - [83] LIN X G,WANG Z Y,LI J S,et al. Sea temperature forecasting based on LSTM neural network along the coast of eastern Guangdong[J]. *Marine Forecasts*,2022,39(5):27-36.
 - [84] WENG S J,CAI J H,PANG Y X,et al. Application of convolutional neural network to sea surface temperature prediction in the coastal waters[J]. *Journal of Tropical Oceanography*,2024,43(1):40-47.
 - [85] CHEN W B,CHEN H,HSIAO S C,et al. Wind forcing effect on hind-casting of typhoon-driven extreme waves[J]. *Ocean Engineering*,2019,188:106260.
 - [86] GONG Y,DONG S,WANG Z. Forecasting of typhoon wave based on hybrid machine learning models[J]. *Ocean Engineering*,2022,266:112934.
 - [87] CHEN S T. Probabilistic forecasting of coastal wave height during typhoon warning period using machine learning methods[J]. *Journal of Hydroinformatics*,2019,21(2):343-358.
 - [88] ZHOU S H,HONG X,LIANG C X,et al. A method of tropical cyclone wave height calculation based on artificial neural network[J]. *Journal of Tropical Oceanography*, 2020,39(4): 25-33.
 - [89] SHANG F C,LI C Q,ZHAN K,et al. Application of Improved LSTM Neural Network in Time-Series Prediction of Extreme Short-Term Wave[J]. *Journal of Shanghai Jiao Tong University*,2023,57(6):659-665.
 - [90] REICHENBACH P,ROSSI M,MALAMUD B D,et al. A review of statistically-based landslide susceptibility models[J]. *Earth-science Reviews*,2018,180:60-91.
 - [91] TIAN N M,LAN H X,WU Y M,et al. Performance Comparison of BP Artificial Neural Network and CART Decision Tree Model in Landslide Susceptibility Prediction[J]. *Journal of Geoinformation Science*,2020,22(12):2304-2316.
 - [92] YANG J K,DANG J W,YANG J Y,et al. Displacement prediction of step-like landslide based on temporal analysis and CNN-BiLSTM-AM[J]. *Foreign Electronic Measurement Technology*, 2024,43(1):126-134.
 - [93] HAO Z,HAO F,SINGH V P. A general framework for multivariate multi-index drought prediction based on multivariate ensemble stream-flow prediction(mesp)[J]. *Journal of Hydrology*,2016,539:1-10.
 - [94] HAO Z,AGHAKOUCHAK A. A nonparametric multivariate multi-index drought monitoring framework[J]. *Journal of Hydrometeorology*,2014,15(1):89-101.
 - [95] NGUYEN T,BRANDSTETTER J,KAPOOR A,et al. Climax: A foundation model for weather and climate[J]. *arXiv*:2301.10343,2023.
 - [96] SCHULTZ M G,BETANCOURT C,GONG B,et al. Can deep learning beat numerical weather prediction? [J]. *Philosophical*

Transactions of the Royal Society A, 2021, 379 (2194): 20200097.

[97] KURTH T, SUBRAMANIAN S, HARRINGTON P, et al. Fourcastnet: Accelerating global high-resolution weather forecasting using adaptive fourier neural operators[C] // Proceedings of the Platform for Advanced Scientific Computing Conference, 2023: 1-11.

[98] GUIBAS J, MARDANI M, LI Z, et al. Adaptive fourier neural operators: Efficient token mixers for transformers[J]. arXiv: 2111.13587, 2021.

[99] BI K, XIE L, ZHANG H, et al. Pangu-weather: A 3D high-resolution model for fast and accurate global weather forecast[J]. arXiv: 2211.02556, 2022.

[100] BI K, XIE L, ZHANG H, et al. Accurate medium-range global weather forecasting with 3D neural networks[J]. Nature, 2023, 619(7970): 533-538.

[101] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021: 10012-10022.

[102] LAM R, SANCHEZ-GONZALEZ A, WILLSON M, et al. Graphcast: Learning skillful medium-range global weather forecasting[J]. arXiv: 2212.12794, 2022.

[103] LAM R, SANCHEZ-GONZALEZ A, WILLSON M, et al. Learning skillful medium-range global weather forecasting[J]. Science, 2023, 382(6677): 1416-1421.

[104] CHEN K, HAN T, GONG J, et al. Fengwu: Pushing the skillful global medium-range weather forecast beyond 10 days lead[J]. arXiv: 2304.02948, 2023.

[105] RADFORD A, KIM J W, HALLACY C, et al. Learning transferable visual models from natural language supervision[C] // International Conference on Machine Learning. PMLR, 2021: 8748-8763.

[106] CHERTI M, BEAUMONT R, WIGHTMAN R, et al. Reproducible scaling laws for contrastive language-image learning[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 2818-2829.

[107] CHEN L, ZHONG X, ZHANG F, et al. Fuxi: A cascade machine learning forecasting system for 15-day global weather forecast[J]. Npj Climate and Atmospheric Science, 2023, 6(1): 190.

[108] LIU Z, HU H, LIN Y, et al. Swin transformer v2: Scaling up capacity and resolution[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 12009-12019.

[109] MAGNUSSON L, BIDLOT J R, BONAVIDA M, et al. Ecmwf activities for improved hurricane forecasts[J]. Bulletin of the American Meteorological Society, 2019, 100(3): 445-458.

[110] CHEN K, BAI L, LING F, et al. Towards an end-to-end artificial intelligence driven global weather forecasting system[J]. arXiv: 2312.12462, 2023.

[111] YU J, LIN Z, YANG J, et al. Free-form image inpainting with gated convolution[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019: 4471-4480.


[112] XIAO Y, BAI L, XUE W, et al. Fengwu-4Dvar: Coupling the data-driven weather forecasting model with 4D variational assimilation[J]. arXiv: 2312.12455, 2023.

[113] FABLET R, CHAPRON B, DRUMETZ L, et al. Learning variational data assimilation models and solvers[J]. Journal of Advances in Modeling Earth Systems, 2021, 13(10): e2021MS002572.


[114] XU X, SUN X, HAN W, et al. Fuxi-da: A generalized deep learning data assimilation framework for assimilating satellite observations[J]. arXiv: 2404.08522, 2024.

[115] KASHINATH K, MUSTAFA M, ALBERT A, et al. Physics-informed machine learning: case studies for weather and climate modelling[J]. Philosophical Transactions of the Royal Society A, 2021, 379(2194): 20200093.

[116] ARCOMANO T, SZUNYOGH I, WIKNER A, et al. A hybrid approach to atmospheric modeling that combines machine learning with a physics-based numerical model[J]. Journal of Advances in Modeling Earth Systems, 2022, 14(3): e2021MS002712.



WANG Yuan, born in 1989, Ph.D, associate professor. Her main research interests include intelligent science and natural language processing.



HAN Yi, born in 1993, Ph.D, assistant researcher. His main research interests include intelligent forecasting of meteorology and oceans, and knowledge graphs.

(责任编辑:何杨)