

海洋极端天气现象预测方法研究进展

刘安安¹, 李天宝¹, 宋丹¹, 李文辉¹, 孙正雅², 袁春鑫³

(1. 天津大学电气自动化与信息工程学院, 天津 300072; 2. 中国科学院自动化研究所, 北京 100190; 3. 中国海洋大学数学科学学院, 青岛 266100)

摘要: 海洋极端天气对沿海地区影响重大。研究人员利用海洋大数据, 结合深度学习算法, 在海洋极端天气现象预测方面取得了重要进展。本文首先以典型的多尺度海洋极端天气现象——厄尔尼诺、台风及短临降雨为例, 介绍了近年来主流的海洋极端天气现象预测算法, 即基于模式计算的方法和基于人工智能的算法。然后分析了海洋极端天气现象智能预测的挑战和机遇, 详细总结了各类方法的研究进展, 并且通过数据和实验讨论了现有算法的优点和不足。最后展望了基于海洋大数据的海洋极端天气现象智能预测的发展方向。

关键词: 海洋大数据; 人工智能; 海洋极端气象预测; 厄尔尼诺; 台风; 短临降雨

中图分类号: TP391 **文献标志码:** A

Research on Marine Extreme Meteorology Forecast

LIU An'an¹, LI Tianbao¹, SONG Dan¹, LI Wenhui¹, SUN Zhengya², YUAN Chunxin³

(1. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China; 2. Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China; 3. School of Mathematical Sciences, Ocean University of China, Qingdao 266100, China)

Abstract: Extreme marine weather phenomena have an important impact on the coastal area. Researchers have made great progress in marine extreme meteorology prediction with the help of marine big data and deep learning algorithms. In this paper, taking typical multi-scale marine extreme weather phenomena—El Niño, typhoon, short-term precipitation as examples, we firstly introduce the mainstream marine extreme meteorology forecast algorithms in recent years, which are mainly divided into numerical model-based methods and artificial intelligence-based algorithms. Then, we analyze the challenges and opportunities of marine extreme meteorology prediction, and summarize the research advances of various methods in detail. And, we discuss the advantages and disadvantages of existing algorithms through experiments. Finally, we briefly look forward to the development direction of marine intelligent meteorology prediction based on marine big data.

Key words: marine big data; artificial intelligence; marine extreme meteorology forecast; El Niño; typhoon; short-term precipitation

引言

海洋覆盖了地球表面的70.8%，在全球气候调节中发挥着核心作用，同时海洋也是全球经济的主要推动力，世界90%以上的贸易都依托于海洋。而海洋极端天气的发生，会对沿海地区的社会经济活动产生重大影响，因此准确预测海洋极端天气对人类社会的发展具有重要意义。海洋数据具有巨系统、多尺度和跨维度的特征，然而现在的大数据技术很难对跨尺度、多模态数据进行融合分析计算，导致处理海洋数据的智能化水平不足，难以满足现实问题的需求。深度学习在文本理解、图像识别等诸多领域都有不俗的表现，在处理大数据问题上也表现出很大的优势。基于海洋大数据的海洋极端天气现象智能预测方法通过对数值、文本、图像等多模态数据进行协同综合处理，可以得到不同模态数据间的相关联系，从而实现跨模态数据关联，以达到准确预测海洋极端天气的目的。

典型的海洋极端天气包括厄尔尼诺与南方涛动(El Niño-southern oscillation, ENSO)现象、台风现象和极端降雨等。ENSO现象是地球上最强、最显著的年际极端气候现象，表现为赤道中、东太平洋地区海表温度出现大范围、长时间、高强度的偏暖，是热带海气相互作用的产物，经常会直接或间接地导致全球气候异常和区域气象灾害^[1]，准确预测ENSO现象，是提高全球气候预测水平和防灾减灾的关键。台风是一种灾难性的天气尺度低压系统，起源于赤道附近的热带或亚热带海洋，台风及其带来的暴雨、强风等恶劣天气往往会在沿海地区造成巨大的经济损失甚至人员伤亡^[2]，及时准确地预测台风运行轨迹及其中心强度，对于全球自然灾害防治与预防工作具有建设性作用，对保护沿海地区人民生命财产安全具有重大意义。降雨与海洋有着密切联系，随着海洋气候变化的加剧，极端降水事件强度与频率也在不断增加^[3]，对局部地区强降雨进行短时序的预报，建立预报预警机制，在防灾减灾以及重大活动保障等方面具有重要意义。

本文根据海洋极端天气现象发生的时间尺度，针对年际气候现象ENSO、月度级别的台风现象、小时级别的极端降雨3种典型海洋极端天气现象预测任务及对应的智能预测方法，介绍了海洋极端天气现象预测的具体任务，总结了海洋极端天气预测的研究进展，并通过相关数据与实验对多种海洋极端天气预测任务进行分析和评价。最后，讨论了海洋极端天气预测任务现在仍面临的挑战，并展望了其未来可能的发展方向。

1 研究进展

海洋极端天气预测方法主要分为基于模式计算的方法和基于人工智能的方法两大类，其中基于模式计算的方法主要利用海洋-大气耦合模型来对海洋极端天气进行预测，而基于人工智能的方法主要依靠机器学习算法挖掘海洋多模态数据与极端天气现象的内在联系，以达到准确预测海洋极端天气的目的。

1.1 基于模式计算的海洋极端天气现象预测方法

1.1.1 基于模式计算的ENSO预测方法

ENSO具有强烈的“海气耦合”特点，因此其数值模拟研究与预测往往需要基于大气和海洋的耦合模型，而模型预报会带来误差，这主要包括由于机理认知的不全面和数值离散带来的模式误差，以及强非线性海气耦合系统对初值异常敏感带来的初值误差^[4]。目前较为常用的是集合预报方法，其主要思路是将多组随机扰动叠加在初始场上产生多组预报的结果，然后根据这些结果估计预报的概率密度分布，从而评估预报结果的误差和不确定性。集合预报的方法不仅可以用来评估不确定性，还可以改善模式对ENSO的预报结果。改善方法主要包括如下3类：第1类方法主要是减小初值不确定性影响的集合预报方法，旨在将观测数据同化到数值模式中以减轻初值误差的影响，例如Chen等^[5]提出将海面

风应力同化到了数值模式中, Ji等^[6]将海表面温度和次表层温度同化到数值模式中, 这些方法都使得模拟效果得到了增强; 第2类方法主要是减小模式不确定性影响的集合预报方法, 旨在将多个海洋模式的预报结果进行多模式集合预报, 例如文献[7-8]都使用多模式集合预报取得了较好的结果; 第3类方法同时考虑了初值误差和模式误差及其相互作用对预报结果的影响, 即多初值集合预报、多模式集合预报以及多模式参数集合预报的方法^[9], 能较好地改善两种误差, 成为较为常用的预测 ENSO 的方法。

1.1.2 基于模式计算的台风预测方法

数值模拟预报是当前台风预报的重要手段之一^[10-11]。研究表明, 通过改善初始场信息, 采用集合预报方法可以很大程度上改善台风路径的预报, 而改善模式对提高台风的强度预报也极其重要^[12-13], 因此如何同时改善初始误差和模式误差是提高模式预报准确率的重要问题。

目前欧洲中期天气预报中心、美国国家环境预报中心和中国国家气象中心等单位均发布了基于数值模拟的台风预报产品。欧洲中期天气预报中心采用集合预报方法发布的海面以上 10 m 高度处风预报产品的空间分辨率最高已达 $0.125^\circ \times 0.125^\circ$, 预报时效长达 10 d, 其中前 72 h 的时间分辨率为 3 h, 72 h 后的时间分辨率为 6 h, 在台风预报中得到了较为广泛的应用^[14]; 美国国家环境预报中心全球预报系统发布的台风数据最高分辨率可以达到 $0.25^\circ \times 0.25^\circ$, 时间分辨率为 3 h, 此外其下设的美国国家飓风中心发布了水平分辨率 2 km 的包含台风路径、强度和结构的预报产品; 中国国家气象中心基于其最新的 T639 数值预报模式发布全球的大风预报产品, 分辨率为 $0.3^\circ \times 0.3^\circ$, 时间分辨率为 3 h, 后又基于 GRAPES-MESO 模式将中国近海台风预报的分辨率提升为 $0.15^\circ \times 0.15^\circ$, 时效为 120 h。

1.2 基于人工智能的海洋极端天气现象预测方法

1.2.1 基于人工智能的 ENSO 预测方法

现有的基于模式计算的 ENSO 数值预测方法, 由于采用数学物理方程和积分控制偏微分方程来预测未来 Nino3.4 指数, 对初始条件和边界条件高度依赖, 并且对海洋物理量有范围非常广泛的需求, 阻碍了数值预测方法在 ENSO 长期预报中的应用。

随着深度学习技术的发展, 研究者开始挖掘物理量内在相关性并设计神经网络来预测天气要素, 如卷积神经网络(Convolutional neural networks, CNN)^[15-16]、长短时记忆网络(Long short-term memory, LSTM)^[17-18]、卷积长短时记忆网络(Convolutional LSTM, ConvLSTM)^[19]、图神经网络(Graph neural networks, GNN)^[20]和 Transformer^[21]等。最具开创性的工作是由 Ham 等设计的基于 CNN 的 ENSO 长期预测模型^[16], 该模型使用连续 3 个月的 $0^\circ \sim 360^\circ\text{E}$ 、 $55^\circ\text{S} \sim 60^\circ\text{N}$ 区域的海温和热含量异常图作为预测输入数据, 使用 Nino3.4 指数作为预测输出, 实现了长达 1.5 年的 ENSO 事件的精确预测。随后, Ye 等^[1]提出了 MS-CNN 网络, 通过自适应地调整卷积核的大小来捕获不同尺度的信息, 构建了异构体系结构的并行深度 CNN 来对 ENSO 现象进行预测。Hu 等^[15]在 CNN 模型的基础上引入 dropout 技术和残差连接模块提高了模型的性能和稳定性, 从而设计了 Res-CNN 模型, 并使用同质迁移学习技术, 进一步提高了预测能力, 提前 20 个月预测了 ENSO 事件。Ye 等^[21]提出了一个基于 Transformer 模型的 ENSOTR 框架, 首次将 Transformer 引入 ENSO 预测工作, ENSOTR 结合了卷积核学习局部特征的能力和 Transformer 学习远程表示的能力, 提高了模型预测的效果。

1.2.2 基于人工智能的台风预测方法

(1) 台风定强分析

CNN 凭借其强大的图像处理能力, 能够从卫星云图中提取台风云型结构的多种特征, 实现对台风强度的估计。Pradhan 等^[22]将 CNN 应用于台风强度估算, 展示了 CNN 处理卫星图像、估算台风强度的潜力。Chen 等^[23]提出了 CNN-TC 模型, 根据卫星云图和台风结构特点修改了 CNN 结构, 去掉了池化

层和Dropout模块,最大限度地保留台风云型结构特征,在整合的数据集上验证了算法的有效性。2019年, Lee等^[24]考虑到台风的非对称三维结构,采用二维卷积神经网络(Two-dimensional CNN, 2D-CNN)和三维卷积神经网络(Three-dimensional CNN, 3D-CNN)分析多光谱静止卫星图像与台风(Tropical cyclone, TC)强度的关系。2021年, Chen等^[25]针对台风强度的实时性问题,将生成对抗网络(Generative adversarial network, GAN)用于台风强度估算,利用GAN网络生成器与鉴别器相互竞争的特性,生成较高质量的被动微波降雨率(Passive micro-wave rainrate, PMW)图像和可见光(Visible light, VIS)图像,不仅可以极大地降低强度预测频率,还能保证多通道数据的输入,减小误差,将台风估算频率降低到了15 min以下。

(2) 台风路径预报

基于深度学习实现对台风路径预报已经取得一定的发展, Lian等^[26]考虑气象变量与热带气旋路径在属性和时间维度上的复杂相关性,提出了基于CNN-门控循环单元(Gated recurrent unit, GRU)的模型, CNN学习和提取相关时间范围内气象变量和热带气旋轨迹的隐含特征, GRU挖掘深层时间特征以实现台风路径的预测。Sophie等^[27]基于CNN,提出一个融合历史轨迹数据和三维风场和压力场数据的24 h轨迹预测模型。Xu等^[2]提出基于通道注意力的AM-ConvGRU模型,采用基于残差结构的通道注意力以更好地获取再分析位势数据的深层非线性特征和台风在不同等压面的特征差异,利用Deep & Wide结构融合二维台风路径序列信息与三维位势特征。Liu等^[28]提出一种有效融合多模态特征的双分支时空融合网络DBF-Net,包含1个从热带气旋一维固有特征中提取时间特征的热带气旋特征分支和1个从分析二维气压场中提取时空特征的气压场分支,通过基于编码器-解码器的架构和高效的特征融合。Dong等^[29]提出一种基于ConvLSTM的编码预测(SAN-EFS)模型,该模型能够充分提取热带气旋的空间和时间特征,基于遥感图像中台风中心与背景之间边界的模糊性,将台风中心位置转化为高斯混合的密度图与遥感图像作为双通道的输入,通过级联的ConvLSTM网络和空间注意力模块提取时序与空间特征得到预测值的密度图,实现对台风路径的预报。Hong等^[30]认为遥感卫星图像中云层的形状和台风的运动轨迹密切相关,因此提出利用多层卷积神经网络在遥感图像中提取云层特征,并从中学习得到台风中心坐标,预测台风的运动轨迹。Moradi等^[31]认为台风路径信息是一个马尔可夫时间序列,并设计了一个稀疏循环神经网络进行台风路径预测。

(3) 台风强度预报

将深度学习技术应用于台风强度预报极大提高了预报的准确性和及时性。Pan等^[32]利用循环神经网络(Recurrent neural network, RNN)预测台风强度,依靠历史观测数据,构建完全数据驱动的台风强度预测模型。Zhou等^[33]构建了基于GCN和LSTM的台风强度预测和分类模型,利用GCN有效处理卫星云图的不规则空间结构,并利用LSTM网络学习卫星云图随时间变化的特征。Zhang等^[34]提出了一种专门用于热带气旋强度预测的神经网络框架TC-PRED,引入大气数据、海洋数据和降水数据的多源环境变量,建立更加全面立体的台风环境场以捕捉多源环境场与TC强度变化的时空相关性,针对多源环境变量的特点,设计了一种新的特征提取和聚合方法,并创新性地引入了序列到序列的结构来进行细粒度预测。Xu等^[35]将风速分为经度方向和纬度方向上的分量,构建基于空间注意力的三路卷积融合网络,提取不同等压面的高风速响应特征,获得台风风场的三维特征。利用Wide & Deep结构,融合基于CLIPER特性的台风强度二维时序表征和台风三维风场特征两种异构模态,实现对台风强度的短期预测(24 h)。Wu等^[36]提出TCL & TIE-Net,利用GAN实现台风路径和强度的多任务预报,该模型主要分为预测模块和估计模块。预测模块采用Cycle-GAN来生成未来不同时间步长的红外图像;估计模块分为TIENet和TCLNet: TIENet采用Beaufort风量表,即风力等级作为输出, TCLNet通过将Cycle GAN生成的预测图像转化为热图获得台风中心位置的估计值。Lee等^[37]认为台风云图的水平

垂直结构和其风力强度密切相关,因此设计了一种多维 CNN 模型来学习多光谱对地静止卫星图像与台风强度之间的关系。Chaudhuri 等^[38]认为台风的强度与台风中心压力、最大表面风速、压力差及海表温度等因素相关,因此将台风的上述参数取值构建为 1 个输入矩阵,进而训练 1 个 MLP 模型来输出台风的强度等级。

1.2.3 基于人工智能的短临降雨预测方法

目前基于深度学习的短临降雨预测方法主要分为两类:基于时序预测模型的方法和基于 UNet 编码解码网络的方法。时序预测模型将短临降水预报视为一个时空序列预测问题,如 LSTM、ConvLSTM 和 TrajGRU 等^[39];基于 UNet 的编码解码网络具有良好的空间学习能力,可以有效地学习降水的空间分布特征,如 UNet、SmaAt-UNet 和 AA-TransUNet 等^[40]。

基于 ConvLSTM 的短临降水预测方法,使用 CNN 来处理输入数据,进而将输入特征在时序模型中传播。Shi 等^[39]认为临近时刻的雷达图像具有较强的时空关联,因而通过 CNN 和 LSTM 的结合体来建模时空特征,在 FC-LSTM 的基础上,提出了采用 ConvLSTM 模块来搭建预测网络,建立了短临降水预测问题的端到端的可训练模型,用历史的雷达回波序列预报未来时刻的雷达图,进行降水预报。针对 ConvLSTM 模型存在的无法捕捉旋转和向四周耗散运动问题,Shi 等^[41]提出了可以学习光流运动的 TrajGRU 模型,在继承 ConvGRU 模型对时序和空间特征良好敏感性的基础上,可以学习到真实的光流运动,进而模拟自然界中云层的真实运动,提高模型外推的性能。

基于 UNet 的编码解码在众多深度学习任务中取得了成功,2021 年 Han 等^[40]把短临降雨预报问题视为图像到图像的转换问题,将 UNet 模型应用于降水预测。该模型包括编码器和解码器两个部分:编码器通过卷积和最大池化来减小图像的大小,增大感受野,提取低级特征;解码器通过分层上采样将输出恢复到原始大小,提取高级特征。Trebing 等^[42]提出 SmaAt-UNet 模型,该网络在 UNet 基础上进行改进,采用了 CBAM(Convolutional block attention module)注意力机制来提高编码效果,采用深度可分离卷积(Depthwise separable convolution, DSC)替代传统卷积^[43-44]减少参数量以提高算法效率。Yang 等^[3]提出 AA-TransUNet 网络,结合了 UNet 模型像素级预测的优势和 Transformer 模型学习长时序特征的优点,极大地提高了模型预测的准确性和效率。

1.3 海洋极端天气现象预测典型数据集及相关评价指标

1.3.1 海洋极端天气现象预测典型数据集

(1) 基于深度学习的 ENSO 预报数据集

基于深度学习的 ENSO 预报数据集由 Ham 等^[16]于 2019 年提出,数据集中存放了 $0^{\circ}\sim 360^{\circ}\text{E}$ 和 $55^{\circ}\text{S}\sim 60^{\circ}\text{N}$ 区域的海表温度异常值和海水热含量异常值,数据采集的空间分辨率为 $5^{\circ}\times 5^{\circ}$,标签为 Nino 3.4 指数,如表 1 所示。该数据集整合了来自耦合模式相互比较项目第 5 期(CMIP5)^[45]、简单海洋数据同化(SODA)^[46]和全球海洋数据同化系统(GODAS)^[47]的数据,其中 CMIP5 包含了

表 1 基于深度学习的 ENSO 预报数据集

Table 1 Deep learning based ENSO forecasting dataset

数据集	模式	类型	时期
CMIP5	21	历史模拟数据	1863—2003 年
SODA	1	历史观测数据	1873—1972 年
GODAS	1	历史观测数据	1984—2017 年

1863—2003 年的 21 个模式的历史模拟数据,SODA 包含了 1873—1972 年的观测数据,GODAS 包含了 1984—2017 年的观测数据。在实验分析过程中,CMIP5 被划分为训练集,SODA 被划分为验证集,GODAS 被划分为为测试集。

(2) 国际台风最佳轨迹数据集

国际台风最佳轨迹(International best track archive for climate stewardship, IBTrACS)数据集^[48]是当前全球最完整的热带气旋集合。该数据集融合了来自多个国家和机构的历史和当前的台风数据,提供从19世纪40年代以来大约每3 h的台风位置和强度,同时还提供了自1980年以来东太平洋、北大西洋、北印度、南大西洋、南印度、南太平洋和西太平洋8个海域台风的最大风半径、环境压力、飓风风力半径等数据。

(3) 中国气象局台风最佳路径数据集

中国气象局台风最佳路径(China Meteorological Administration tropical cyclone best track, CMA-TC-Best-track)数据集^[49]数据来自中国气象局热带气旋数据中心,包含了1949年至今西北太平洋(赤道以北、东经180°以西、含南海)海域热带气旋的每6 h的位置和强度。基本数据包括热带气旋中心的纬度、经度和最低海平面气压等。

(4) 网格化卫星数据集

网格化卫星(Gridded satellite data, GridSat)数据集^[50]是地球静止气象卫星观测的长期数据集,包含红外(Infrared, IR)、水蒸气(Water vapor, WV)和可见光(Visible light, VIS)三通道数据。每个通道的图像大小为5 143像素×2 000像素,空间分辨率为0.07°纬度/经度,时间分辨率是3 h。时间范围从1981年至今,每季度更新一次数据,覆盖70°N至70°S的纬度范围。

(5) 四通道卫星图像数据集

四通道卫星图像(Dataset of tropical cyclone for image-to-intensity regression, TCIR)数据集^[25]时间分辨率为3 h,空间分辨率为0.07°纬度/经度。TCIR共包含西北太平洋、东北太平洋和大西洋海域861个热带气旋,共计47 916帧图像。每帧数据有201×201个数据点,每两个数据点的距离约为4 km。

(7) 荷兰降雨数据集

荷兰降雨数据集^[42]数据来自荷兰皇家气象研究所。该数据集包含荷兰地区和邻国2016—2019年的420 000多张降雨图,具有2.4 km的空间分辨率和5 min的时间分辨率。为了便于研究,根据数据集中目标图像具有的最小雨像素百分比创建了额外的2个数据集NL-20和NL-50,分别表示数据集中样本至少有20%或50%的含雨像素。

(8) 社区地球系统模型

社区地球系统模型(Community earth system model, CESM)^[51]是一套高分辨率的气候模拟模型,包括一个500年的工业化前控制模拟和一个1850—2100年的历史和未来气候模拟。其中,大气和陆地模型的标称水平分辨率为0.25°,海洋和海冰模型的标称水平分辨率为0.1°。在如此高分辨率下,该模型支持对热带气旋和海洋中尺度涡等现象的研究,并且支持对这些天气和中尺度现象与大尺度环流之间相互作用的研究。

1.3.2 海洋极端天气现象预测相关评价指标

(1) 时间异常相关系数

时间异常相关系数度量的是预测值和观测值之间的线性相关性,表达式为

$$\text{Corr}_t = \sum_{m=1}^{12} \frac{\sum_{l=s}^e (Y_{t,m} - \bar{Y}_m)(P_{t,m,l} - \bar{P}_{m,l})}{\sqrt{\sum_{l=s}^e (Y_{t,m} - \bar{Y}_m)^2 \sum_{l=s}^e (P_{t,m,l} - \bar{P}_{m,l})^2}} \quad (1)$$

式中: P 和 Y 分别为预测值和观测值; $\bar{P}_{m,l}$ 和 \bar{Y}_m 为 P 和 Y 的平均值, $m=1\sim 12$ 为日历月;标签 t 为预测

目标年; s 和 e 分别表示起始年和结束年。

(2) 平均绝对误差

平均绝对误差(Mean absolute error, MAE)表示预测值与真实值之间的差异,表达式为

$$\text{MAE} = \frac{1}{N} \sum_{i=0}^N |\hat{y}_i - y_i| \quad (2)$$

式中: N 表示样本数量; \hat{y}_i 、 y_i 分别表示预测值和真实值。

(3) 均方根误差

均方根误差(Root mean square error, RMSE)表示预测值和真实值之间差异的样本标准差,表达式为

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=0}^N (|\hat{y}_i - y_i|)^2} \quad (3)$$

(4) 均方误差

均方误差(Mean square error, MSE)表达式为

$$\text{MSE} = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N} \quad (4)$$

(5) 平均位置误差

平均位置误差(Average position error, APE)表示预测位置与实际位置之间的平均距离误差,表达式为

$$\begin{cases} \text{APE} = \frac{1}{N} \sum_{i=1}^N 2R \arcsin \sqrt{M_1 + (\cos lat_{p_i} \cos lat_{r_i} M_2)} \\ M_1 = \sin^2 \left(\frac{lat_{p_i} - lat_{r_i}}{2} \right), M_2 = \sin^2 \left(\frac{lon_{p_i} - lon_{r_i}}{2} \right) \end{cases} \quad (5)$$

式中: R 为地球半径; lon_{p_i} 和 lat_{p_i} 分别表示第 i 个样本经度和纬度的预测值; lon_{r_i} 和 lat_{r_i} 分别表示第 i 个样本经度和纬度的实际值。

(6) 准确率

准确率(Accuracy, Acc)表示被预测正确的区域占总体区域的比重,表达式为

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FN} + \text{FP} + \text{TN}} \quad (6)$$

式中:TP(True positive)表示正样本被正确预测为正样本;TN(True negative)表示负样本被正确预测为负样本;FN(False negative)表示负样本被错误预测为正样本;FP(False positive)表示负样本被错误预测为正样本。

(7) 召回率

以降雨任务为例,召回率(Recall)表示被正确预测为有降水的区域占总体降水区域的比例,表达式为

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (7)$$

(8) 误报率

以降雨任务为例,误报率(False alarm rate, FAR)表示在预报有降水的区域中,实际没有降水的区

域占总预报降水区域的比例,表达式为

$$FAR = \frac{FP}{TP + FP} \quad (8)$$

1.4 海洋极端天气现象预测方法实验性能分析

1.4.1 ENSO 预测方法实验性能分析

在预测 Nino3.4 指标时挑选了数值预测和深度学习等几种代表性方法进行比较。数值预测方法包括尺度相互作用实验前沿 (Scale interaction experiment-FRCGC, SINTEX-F)^[52] 和北美多模态集合 (North American multi-model ensemble, NMME)^[53], 其中 NMME 包括 CanCM3、CanCM4、CCSM3、CCSM4、GFDL-aer04、GFDL-FLOR-A06 和 GFDL-FLOR-B01。深度学习方法由多集成模型 CNN^[16]、单模型多尺度 CNN 并行深度网络 (Multiple scale-CNN, MS-CNN)^[1]、集成模型 ENSOTR^[21] 和 Transformer 组成。图 1 展示了不同模型对 1984—2017 年 Niño3.4 指数预报的时间异常相关系数 Corr。

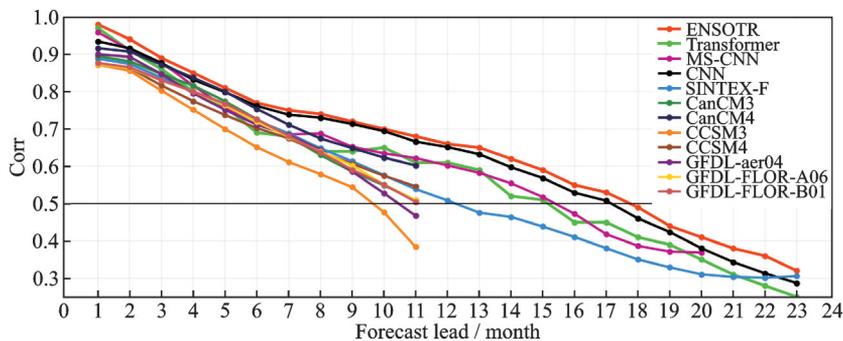


图 1 ENSO 预测方法实验性能对比

Fig.1 Comparison of ENSO forecasting methods

对比图 1 结果可以观察到以下结论:

(1) 数值预测与深度学习方法结果对比。所有的深度学习方法 (如 Res-CNN、MS-CNN 和 Transformer 等) 都优于数值预测方法 (如 SINTEX-F 和 NMME)。数值预测方法是通过建立各种方程来预测 ENSO 事件, 用复杂的计算过程挖掘复杂的变化, 而海气耦合系统内部振荡机制复杂, 气候变率具有混乱性, 经验模型具有认知局限性并且其关键参数优化不确定性较大, 导致越来越多的预测误差阻碍了数值模型在长期预测中的应用, 因此这些模型大多数只能较好地预测不超过 6 个月的 ENSO。而深度学习的方法在处理具有空间结构的多维数组数据方面能力较强, 依靠数据驱动可以自动探索 EI Nino-Southern 振荡的变化特征, 可以提供长期可靠的预测, 在 ENSO 事件预测上优于所有最先进的动态预测系统。最先进的动态预报系统 SINTEX-F5 在领先 17 个月时为 0.37, 而深度方法模型中 Niño3.4 指数的全季相关技能在前置 15 个月时均在 0.5 以上。

(2) 基于 CNN 方法与基于 Transformer 方法结果对比。单尺度 CNN 模型的 Corr 在 13 个月预测领先时大于 0.5, 而 MS-CNN 的 Corr 在 15 个月预测领先时大于 0.5, 说明不同尺度卷积核大小利用多个接受野能获得更好的区域相关性。集成模型 CNN 优于单尺度 MS-CNN, 说明集成学习可以大幅度改善 ENSO 预测效果。此外, 基于 Transformer 的方法 (如 Transformer 和 ENSOTR) 采用注意机制进行空间交互, 容易获得全局相关性; 同时 ENSOTR 的大部分表现均优于 Transformer, 也说明直接使用 Transformer 模型效果不佳, 而 ENSO 结合了 CNN 的局部特征学习能力和变压器的远程表示学习能力, 获得了更好的预测性能。

1.4.2 台风预测方法实验性能分析

(1) 台风定强分析

台风强度估计模型 CNN-TC 和 GAN-CNN 在 TCIR 数据集的性能如表 2 所示。观察表 2 可知:① CNN-TC 以 IR1 和 PMW 双通道卫星图像为输入,台风强度估计频率在 3 h 左右,在测试集 RMSE 为 8.39 kts,性能优于传统的 ADT 和 SATCON 技术;② GAN-CNN 以 IR1 和 WV 双通道卫星图像为输入,实现台风强度估计频率在 15 min 以下,但是 RMSE 高于 CNN-TC 模型和 SATCON 技术,性能有所下降。结果说明 GAN 的应用虽然使得模型实时性得到提升,但是损害了模型的性能,使得 GAN 生成的 PMW 和 VIS 图像的质量有待提高。

(2) 台风路径与强度预报

对台风路径预报模型 AM-ConvGRU 和 SAN-EFS,台风强度预报模型 SAF-Net 和 TC-PRED,以及路径强度多任务预报模型 TCL&TIE-Net 所用数据集和性能进行总结,结果如表 3 所示。观察表 3 可得:① 对于台风的路径和强度预报,基于深度学习的预测模型性能已经得到明显的提高,例如 SAN-EFS 模型在测试集上对路径短期(24 h)预报的性能优于欧洲中期天气预报中心和国家环境预测中心全球预报系统的高分辨率预报性能;对于台风强度预报,TC-PRED 模型在测试集上对强度的短期预报平均绝对误差低于 4 m/s。② 当前基于深度学习的台风定强、路径与强度预报业务引入降水数据、大气数据和海洋数据等多源环境变量建立全面的环境场,能够捕捉多源环境变量与台风路径与强度变化复杂的时空相关性。但是对于弱引导气流下路径的转向和调整,台风强度的快速增强等问题还存在不足,模型的性能仍有待提高。

表 2 CNN-TC 和 GAN-CNN 模型在数据集 TCIR 上的性能比较

Table 2 Comparison of CNN-TC and GAN-CNN models on TCIR dataset

模型	RMSE/kts		频率
	验证集	测试集	
ADT ^[54]	12.65		30 min
SATCON ^[55]	8.59		≈3 h
CNN-TC ^[23]	8.74	8.39	≈3 h
GAN-CNN ^[25]	9.01	9.33	≤15 min

表 3 台风路径与强度预报模型

Table 3 Typhoon track and intensity forecast model

模型	数据集			MAE/(m·s ⁻¹)	APE/km
	IBTrACS	CMA-BST	GridSat		
AM-ConvGRU ^[2]		✓			144.05
SAN-EFS ^[29]	✓		✓		66.39
SAF-Net ^[35]		✓		4.30	
TC-PRED ^[34]		✓		3.98	
TCL&TIE-Net ^[36]			✓	13.06	116.00

1.4.3 短临降雨预测方法实验性能分析

对短临降雨预报模型 UNet、SmaAt-UNet 以及 AA-TransUNet 模型在荷兰降水 NL50 数据集上的性能进行对比,结果如表 4 所示。每一个序列包含 18 帧图片,每帧间隔 5 min,前 12 帧为输入数据,最后 1 帧为预测数据。数据集分成训练集(2016—2018 年)和测试集(2019 年)。此外,对于每一次训练迭代,随机选择 10% 的训练集作为验证集,观察实验结果可得:(1) 基于深度学习的短临降水预报性能明显高于基准模型,证明了将深度学习应用在降水预报领域的有效性和可行性;(2) SmaAt-UNet 采用 DSC 代

替传统卷积,在性能上虽然略逊于UNet,但是参数量远小于UNet,方便移动端使用,更具备实用性;(3)AA-TransUNet在实验指标MSE、Acc及精度上均取得最优,证明了Transformer的编码器有利于特征提取,UNet网络与Transformer网络的结合有利于短临降水预报精度的提高。

表4 基于UNet框架的网络模型在数据集NL50上的性能比较

Table 4 Performance comparison of the UNet based model on NL50 dataset

模型	MSE	Acc	精度	Recall	FAR
基准模型	0.024 8	0.756	0.678	0.643	0.321
UNet ^[40]	0.012 3	0.826	0.719	0.867	0.280
SmaAt-UNet ^[42]	0.012 1	0.817	0.699	0.882	0.300
AA-TransUNet ^[3]	0.011 4	0.828	0.725	0.857	0.274

2 面临挑战与发展趋势

2.1 面临挑战

2.1.1 基于模式计算方法面临的挑战

基于模式计算的海洋极端天气现象预测方法取得了重要的进展,但是在面对各种复杂海洋极端天气现象预测任务时,仍然面临一些挑战。极端天气通常具有雷诺数大、非线性强以及多尺度动力学现象耦合的特点,具有很高的复杂度,而且针对这些极端天气的观测数据较少且有片面性。这就导致目前对极端天气的动力学机制,包括生成、演变以及消亡的过程和影响因素的认识存在很多不足,演变的机理并不完全清楚,致使目前采用的模型都存在一定程度的误差。另一方面,目前的模式计算方法需要采用参数化方案来刻画次网格尺度的动力学现象所带来的能量变化,而参数化方案在极端天气的数值模拟和数值预报方面表现不尽如人意,需要改善现有的方案或者构建新的参数化方案来解决这个问题。

2.1.2 基于人工智能方法面临的挑战

得益于海洋气象大数据的推动和深度学习算法的广泛应用,基于数据驱动的海洋极端气象预测方法取得了较大的成功,但是在面临海洋大数据场景下的多种极端气象预测任务中,基于人工智能的方法仍然存在着较大的挑战,具体如下:

(1) ENSO 预报面临着两大重要挑战:春季预报障碍和非平稳的气候变率。春季预报障碍(Spring predictability barrier, SPB)指的是由于春季是海-气耦合系统最脆弱的季节,是气候态转换的重要时期,系统的“信噪比”最低,最易受外界干扰,因此春季预报障碍成为了 ENSO 事件预测研究重大阻碍。此外由于 ENSO 是热带太平洋海气相互作用现象的一种具有不规则周期性年际变化,真实的大气-海洋耦合系统表现出变率信号和高频噪声,其内部存在复杂振荡机制和混乱的气候变率,极大地增加了 ENSO 预测中的偏差和不确定性,同时也对于长时间 ENSO 的提前预报提出了挑战。

(2) 台风预测任务的难点在于至今难以建立台风动力学、热力学和海气相互作用等复杂机制的准确表征。研究指出,台风的移动不仅受到大尺度环境背景流场的影响,也与海陆差异、地形影响以及其他天气系统等因素有关。台风强度预报更是依赖于对台风内核动热力过程的清晰认识及其与周围环境场关系的把握,是一个复杂的多尺度问题。如何提高基于统计动力预报方法的台风预测的准确性,构建高精度、全方位的台风预报体系是当前研究的重点和难点。

(3) 深度学习算法在短临降雨方面的应用有效提高了预测的准确性和精度,现有的短临降雨预测任务主要专注于对雷达回波图像数据和降雨量数据的分析,而中国正不断推进建设精密气象监测系

统,高精度、智能化探测装备为海洋极端天气预测中海量气象数据的采集和储备奠定了基础。如何利用人工智能算法对多模态的海量气象大数据进行分析和挖掘,并与数值计算方法相结合以提高深度学习算法的可解释性,是目前短临降雨预测任务的研究重点和难点。

2.2 发展趋势

2.2.1 海洋大数据协同表示学习

多物理场、多时空分辨率及跨圈层海洋大数据的协同表示是海洋-大气动力过程演变机理认知的前提。海洋环境中数据的多样性、各物理场数据的多分变率性以及物理场信息间的差异性,导致当前的人工智能方法与硬件计算架构无法充分利用海洋大数据优势,严重制约了对海洋科学知识的智能化认知。未来针对海洋极端气象预测任务的多物理场尺度一致性研究可以从以下几个方面开展:研究多尺度对抗生成理论,构建空间多尺度联合生成与时序差异一致性编码模型,设计时空对抗网络约束物理场数据的尺度一致性,提升海洋多物理场共嵌空间特征提取能力;针对尺度一致的多物理场海洋数据,研究自注意力引导的多物理场协同表示方法,挖掘物理场内在信息特性以及多物理场间信息的关联关系,为海洋大数据认知计算建立一致的特征表示空间。

2.2.2 海洋大数据知识推理

海气相互作用是长期天气和气候变化的重要因素,是研究和预报海洋状况的关键依据。然而,分辨率较高的大气和海洋模型耦合产生的多尺度相互作用对极端事件的触发机理和演变作用仍然存在很多未解之谜,迫切需要为高分辨率、多尺度的地球系统构建更精准的预测模型,提高模拟和预测未来极端事件变化的能力。知识驱动的人工智能方法可以充分融合定性关系逻辑、定量物理方程和动态原型知识,构建高精度、高效率和高可信的海洋中尺度现象分析预测模型,探索复杂机理造成的认知难题的新理论。

海洋知识图谱能够有效描述海洋环境要素与复杂现象数据的各种概念,并呈现各要素沿时间线的动态关系或交互作用。随着海洋现象在空间和时间维度的连续变化,需要及时捕获该过程从产生、发展、消弱到消亡的变化特征。研究海洋知识图谱构建和海洋现象原型学习,是海洋认知计算的推理基础。针对海洋环境要素复杂动态交互造成的机理认知局限性,研究在统一时空维度下海洋要素与典型现象的内在逻辑关联与结构化表达,实现海洋科学知识全维度完备性表征;研究海洋复杂过程数字化表达、量化关联、数值模拟与大数据挖掘知识的集成、融合和关联,形成海洋现象时空演化规律和控制因素的快速计算机制。针对海洋大数据预测变量的统计特性随时间推移分布规律发生改变的现象,研究利用误差驱动技术的数据典型性自动学习方法,通过动态确定短期或者长期的有代表性的历史样本来捕获当前向量化数据的语义标签。

3 结束语

本文从海洋极端天气现象预测的角度出发,首先面向 ENSO 预测、台风预报和短临降雨预报的具体研究任务,从传统基于数值方程的模式计算方法和基于数据驱动的人工智能方法两方面详细总结了海洋极端天气现象预测任务的研究进展。然后通过数据和实验对多种海洋极端天气预测任务进行了分析和评价。最后,讨论了现阶段海洋极端天气预测任务面临的挑战,并从海洋大数据协同表示学习和海洋大数据知识推理两个方面展望了海洋极端天气现象预测任务未来的发展方向。

参考文献:

- [1] YE M, NIE J, LIU A, et al. Multi-year ENSO forecasts using parallel convolutional neural networks with heterogeneous architecture[J]. *Frontiers in Marine Science*, 2021. DOI: 10.3389/fmars.2021.717184.

- [2] XU G, XIAN D, FOURNIER-VIGER P, et al. AM-ConvGRU: A spatio-temporal model for typhoon path prediction[J]. *Neural Computing and Applications*, 2022, 34(8): 5905-5921.
- [3] YANG Y, MEHRKANOON S. AA-transunet: Attention augmented transunet for nowcasting tasks[C]//*Proceedings of 2022 International Joint Conference on Neural Networks (IJCNN)*. Padua, Italy: IEEE, 2022: 1-8.
- [4] PALMER T N, BUIZZA R, MOLTENI F, et al. Singular vectors and the predictability of weather and climate[J]. *Philosophical Transactions of the Royal Society of London. Series A: Physical and Engineering Sciences*, 1994, 348(1688): 459-475.
- [5] CHEN D, ZEBIAK S E, BUSALACCHI A J, et al. An improved procedure for El Nino forecasting: Implications for predictability[J]. *Science*, 1995, 269(5231): 1699-1702.
- [6] JI M, KUMAR A, LEETMAA A. An experimental coupled forecast system at the National Meteorological Center: Some early results[J]. *Tellus A*, 1994, 46(4): 398-418.
- [7] BARNSTON A G, TIPPETT M K, RANGANATHAN M, et al. Deterministic skill of ENSO predictions from the North American multimodel ensemble[J]. *Climate Dynamics*, 2019, 53: 7215-7234.
- [8] LANDSEA C W, KNAFF J A. How much skill was there in forecasting the very strong 1997-98 El Nino?[J]. *Bulletin of the American Meteorological Society*, 2000, 81(9): 2107-2120.
- [9] BECKER E, DEN DOOL H, ZHANG Q. Predictability and forecast skill in NMME[J]. *Journal of Climate*, 2014, 27(15): 5891-5906.
- [10] DEMARIA M, SAMPSON C R, KNAFF J A, et al. Is tropical cyclone intensity guidance improving?[J]. *Bulletin of the American Meteorological Society*, 2014, 95(3): 387-398.
- [11] EMANUEL K, ZHANG F. On the predictability and error sources of tropical cyclone intensity forecasts[J]. *Journal of the Atmospheric Sciences*, 2016, 73(9): 3739-3747.
- [12] YAMAGUCHI M, MAJUMDAR S J. Using TIGGE data to diagnose initial perturbations and their growth for tropical cyclone ensemble forecasts[J]. *Monthly Weather Review*, 2010, 138(9): 3634-3655.
- [13] MUNSELL E B, SIPPEL J A, BRAUN S A, et al. Dynamics and predictability of Hurricane Nadine (2012) evaluated through convection-permitting ensemble analysis and forecasts[J]. *Monthly Weather Review*, 2015, 143(11): 4514-4532.
- [14] 连喜虎, 刘桂艳, 高松, 等. EC 细网格 10 m 风场产品在渤海、黄海海域的预报能力检验与评估[J]. *海洋预报*, 2020, 37(6): 74-82.
- LIAN Xihu, LIU Guiyan, GAO Song, et al. Evaluation of the ECMWF forecast skills for the 10 m wind field in the Bohai Sea and the Yellow Sea[J]. *Marine Forecasts*, 2020, 37(6): 74-82.
- [15] HU J, WENG B, HUANG T, et al. Deep residual convolutional neural network combining dropout and transfer learning for ENSO forecasting[J]. *Geophysical Research Letters*, 2021, 48(24): e2021GL093531.
- [16] HAM Y G, KIM J H, LUO J J. Deep learning for multi-year ENSO forecasts[J]. *Nature*, 2019, 573(7775): 568-572.
- [17] ZHOU L, ZHANG R H. A hybrid neural network model for ENSO prediction in combination with principal oscillation pattern analyses[J]. *Advances in Atmospheric Sciences*, 2022, 39(6): 889-902.
- [18] BRONI-BEDAICO C, KATSRUKU F A, UNEMI T, et al. El Nino-southern oscillation forecasting using complex networks analysis of LSTM neural networks[J]. *Artificial Life and Robotics*, 2019, 24: 445-451.
- [19] GUPTA M, KODAMANA H, SANDEEP S. Prediction of ENSO beyond spring predictability barrier using deep convolutional LSTM networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 19: 1-5.
- [20] CACHAY S R, ERICKSON E, BUCKER A F C, et al. Graph neural networks for improved El Nino forecasting[EB/OL]. (2021-02-12)[2022-11-30]. <https://arxiv.org/abs/2012.01598v1>.
- [21] YE F, HU J, HUANG T Q, et al. Transformer for El Nino-southern oscillation prediction[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 1-5.
- [22] PRADHAN R, AYGUN R S, MASKEY M, et al. Tropical cyclone intensity estimation using a deep convolutional neural network[J]. *IEEE Transactions on Image Processing*, 2017, 27(2): 692-702.
- [23] CHEN B, CHEN B F, LIN H T. Rotation-blended CNNs on a new open dataset for tropical cyclone image-to-intensity regression[C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*.

- [S.l.]: [s.n.], 2018: 90-99.
- [24] LEE J, IM J, CHA D H, et al. Tropical cyclone intensity estimation using multi-dimensional convolutional neural networks from geostationary satellite data[J]. *Remote Sensing*, 2019, 12(1): 108.
- [25] CHEN B, CHEN B F, CHEN Y N. Real-time tropical cyclone intensity estimation by handling temporally heterogeneous satellite data[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. [S.l.]: AAAI, 2021: 14721-14728.
- [26] LIAN J, DONG P, ZHANG Y, et al. A novel data-driven tropical cyclone track prediction model based on CNN and GRU with multi-dimensional feature selection[J]. *IEEE Access*, 2020, 8: 97114-97128.
- [27] GIFFARD-ROISIN S, YANG M, CHARPIAT G, et al. Tropical cyclone track forecasting using fused deep learning from aligned reanalysis data[J]. *Frontiers in Big Data*, 2020. DOI: 10.3389/fdata.2020.00001.
- [28] LIU Z, HAO K, GENG X, et al. Dual-branched spatio-temporal fusion network for multihorizon tropical cyclone track forecast [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 3842-3852.
- [29] DONG P, LIAN J, YU H, et al. Tropical cyclone track prediction with an encoding-to-forecasting deep learning model[J]. *Weather and Forecasting*, 2022. DOI: <https://doi.org/10.1175/WAF-D-21-0116.1>.
- [30] HONG S, KIM S, JOH M, et al. GlobeNet: Convolutional neural networks for typhoon eye tracking from remote sensing imagery[EB/OL]. (2017-08-11)[2022-11-30]. <https://arxiv.org/abs/1708.03417>.
- [31] MORADI K M, GORJI S M, HOMAIFAR A. A sparse recurrent neural network for trajectory prediction of atlantic hurricanes [C]//*Proceedings of the Genetic and Evolutionary Computation Conference 2016*. Denver, CO, USA: ACM, 2016: 957-964.
- [32] PAN B, XU X, SHI Z. Tropical cyclone intensity prediction based on recurrent neural networks[J]. *Electronics Letters*, 2019, 55(7): 413-415.
- [33] ZHOU J, XIANG J, HUANG S. Classification and prediction of typhoon levels by satellite cloud pictures through GC-LSTM deep learning model[J]. *Sensors*, 2020, 20(18): 5132.
- [34] ZHANG Z, YANG X, SHI L, et al. A neural network framework for fine-grained tropical cyclone intensity prediction[J]. *Knowledge-Based Systems*, 2022, 241: 108195.
- [35] XU G, LIN K, LI X, et al. SAF-Net: A spatio-temporal deep learning method for typhoon intensity prediction[J]. *Pattern Recognition Letters*, 2022, 155: 121-127.
- [36] WU Y, GENG X, LIU Z, et al. Tropical cyclone forecast using multitask deep learning framework[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 1-5.
- [37] LEE J, IM J, CHA D H, et al. Tropical cyclone intensity estimation using multi-dimensional convolutional neural networks from geostationary satellite data[J]. *Remote Sensing*, 2019, 12(1): 108.
- [38] CHAUDHURI S, DUTTA D, GOSWAMI S, et al. Intensity forecast of tropical cyclones over North Indian Ocean using multilayer perceptron model: Skill and performance verification[J]. *Natural Hazards*, 2013, 65(1): 97-113.
- [39] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [J]. *Advances in Neural Information Processing Systems*, 2015, 28: 802-810.
- [40] HAN L, LIANG H, CHEN H, et al. Convective precipitation nowcasting using U-Net model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 1-8.
- [41] SHI X, GAO Z, LAUSEN L, et al. Deep learning for precipitation nowcasting: A benchmark and a new model[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 5622-5632.
- [42] TREBING K, STAŃCZYK T, MEHRKANOON S. SmaAt-UNet: Precipitation nowcasting using a small attention-UNet architecture[J]. *Pattern Recognition Letters*, 2021, 145: 178-186.
- [43] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//*Proceedings of the European Conference on Computer Vision (ECCV)*. [S.l.]: SpringerLink, 2018: 3-19.
- [44] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, HI, USA: IEEE, 2017: 1251-1258.
- [45] BELLENGER H, GUILYARDI É, LELOUP J, et al. ENSO representation in climate models: From CMIP3 to CMIP5[J]. *Climate Dynamics*, 2014, 42(7): 1999-2018.
- [46] 张雅乐, 俞永强, 段晚锁. 四个耦合模式 ENSO 后报试验的“春季预报障碍”[J]. *气象学报*, 2012, 70(3): 506-519.

- ZHANG Yale, YU Yongqiang, DUAN Wansuo. The spring prediction barrier of ENSO in retrospective prediction experiments as shown by the four coupled ocean-atmosphere models[J]. *Acta Meteorologica Sinica*, 2012, 70(3): 506-519.
- [47] ZHANG Z, REN B, ZHENG J. A unified complex index to characterize two types of ENSO simultaneously[J]. *Scientific Reports*, 2019, 9(1): 8373.
- [48] KNAPP K R, KRUK M C, LEVINSON D H, et al. The international best track archive for climate stewardship (IBTrACS) unifying tropical cyclone data[J]. *Bulletin of the American Meteorological Society*, 2010, 91(3): 363-376.
- [49] LU X, YU H, YING M, et al. Western north Pacific tropical cyclone database created by the China Meteorological Administration[J]. *Advances in Atmospheric Sciences*, 2021, 38: 690-699.
- [50] KNAPP K R, ANSARI S, BAIN C L, et al. Globally gridded satellite observations for climate studies[J]. *Bulletin of the American Meteorological Society*, 2011, 92(7): 893-907.
- [51] CHANG P, ZHANG S, DANABASOGLU G, et al. An unprecedented set of high-resolution earth system simulations for understanding multiscale interactions in climate variability and change[J]. *Journal of Advances in Modeling Earth Systems*, 2020, 12(12): e2020MS002298.
- [52] LUO J J, MASSON S, BEHERA S K, et al. Extended ENSO predictions using a fully coupled ocean-atmosphere model[J]. *Journal of Climate*, 2008, 21(1): 84-93.
- [53] KIRTMAN B P, MIN D, INFANTI J M, et al. The North American multimodel ensemble: Phase-1 seasonal-to-interannual prediction; phase-2 toward developing intraseasonal prediction[J]. *Bulletin of the American Meteorological Society*, 2014, 95(4): 585-601.
- [54] OLANDER T L, VELDEN C S. The advanced Dvorak technique: Continued development of an objective scheme to estimate tropical cyclone intensity using geostationary infrared satellite imagery[J]. *Weather and Forecasting*, 2007, 22(2): 287-298.
- [55] VELDEN C S, HERNDON D C. Update on the SATellite CONsensus (SATCON) algorithm for estimating TC intensity [EB/OL]. (2014-04-01)[2022-11-30]. <https://ams.confex.com/ams/31Hurr/webprogram/Paper243759.html>.

作者简介:



刘安安(1982-),男,教授,博士生导师,研究方向:海洋大数据分析、人工智能, E-mail: anan0422@gmail.com。



李天宝(1996-),男,博士研究生,研究方向:数据驱动的海洋气象预测, E-mail: litianbao@tju.edu.cn。



宋丹(1992-),通信作者,女,副教授,硕士生导师,研究方向:海洋大数据分析、人工智能, E-mail: dan.song@tju.edu.cn。



李文辉(1991-),男,讲师,硕士生导师,研究方向:海洋大数据分析、三维大数据分析, E-mail: liwenhui@tju.edu.cn。



孙正雅(1982-),女,副研究员,硕士生导师,研究方向:统计关系学习、近似推理、演化数据学习, E-mail: zhengya.sun@ia.ac.cn。



袁春鑫(1991-),男,副教授,硕士生导师,研究方向:物理海洋数学交叉学科、数值模拟、人工智能海洋学, E-mail: yuanchunxin@ouc.edu.cn。

(编辑:张黄群)