

中图法分类号: P731.11 文献标识码: A 文章编号: 1006-8961(2026)05-1451-27

论文引用格式: He Q, Tao M X, Zhu Z H, Song W and Du Y L. 2026. A review of data-driven methods for predicting sea surface temperature. Journal of Image and Graphics, 31(5):1451-1477(贺琪, 陶梦鑫, 朱姿杭, 宋巍, 杜艳玲. 2026. 数据驱动的海表面温度预测方法综述. 中国图象图形学报, 31(5):1451-1477)[DOI:10.11834/jig.250496]

## 数据驱动的海表面温度预测方法综述

贺琪<sup>1</sup>, 陶梦鑫<sup>1</sup>, 朱姿杭<sup>2</sup>, 宋巍<sup>1\*</sup>, 杜艳玲<sup>1</sup>

1. 上海海洋大学信息学院, 上海 201306; 2. 国网山东省电力公司威海供电公司, 威海 264200

**摘要:** 海表面温度(sea surface temperature, SST)是刻画海洋热状态、反映全球气候变化的关键基础变量。SST的精准预测对于海洋天气与气候预报、渔业资源优化研判、海洋生态保护及沿海区域经济发展具有重要意义。现阶段SST预测方法主要分为数值模式与数据驱动两大类,其中数据驱动方法凭借灵活高效的特性,已成为提升预测精度的核心技术路径,尤其适用于中短期预报与区域尺度研究。本文主要围绕数据驱动SST预测技术展开系统性综述,构建了全面的研究框架。明确数值模式与数据驱动两类预测方法的核心特征、物理机制与应用定位,通过对比凸显数据驱动方法在复杂非线性关系捕捉上的优势;遵循“统计模型——传统机器学习——浅层神经网络——深度学习(含海洋大模型)”的技术演进脉络,系统梳理各类模型的核心原理、优势局限及典型应用场景,揭示技术发展规律;结合观测、遥感、再分析等多源数据集的时空分辨率、可靠性等特征,深入对比不同模型的适配性与预测效果,为数据和模型匹配提供实践参考;聚焦当前研究面临的模型可解释性不足、多源数据尺度适配困难等核心挑战,提出物理信息融合、可解释性架构设计、多分辨率特征学习等解决方案,并展望三维次表层海温结构建模、中长期预测优化等未来发展方向。本文通过多维度分析与案例验证,构建了数据驱动SST预测的完整技术体系,为相关领域的深入研究与业务化应用提供系统性参考。

**关键词:** 海洋环境;海表面温度(SST);数据驱动;深度学习;时空特征

## A review of data-driven methods for predicting sea surface temperature

He Qi<sup>1</sup>, Tao Mengxin<sup>1</sup>, Zhu Zihang<sup>2</sup>, Song Wei<sup>1\*</sup>, Du Yanling<sup>1</sup>

1. College of Information Technology, Shanghai Ocean University, Shanghai 201306, China;

2. State Grid Shandong Electric Power Company Weihai Power Supply Company, Weihai 264200, China

**Abstract:** Sea surface temperature (SST) is a key variable that characterizes the thermal state of the ocean and reflects global climate change. Accurate prediction of SST is a fundamental cornerstone for numerous critical applications, including marine weather and climate forecasting, the sustainable assessment of fishery resources, the protection of marine ecosystems, and the socioeconomic development of coastal regions. As a result, SST prediction becomes a focal point of research in oceanography and atmospheric science. Currently, SST prediction methodologies are predominantly categorized into two paradigms: numerical and data-driven models. Numerical models, grounded in the fundamental principles of fluid dynamics and thermodynamics, solve complex partial differential equations with specified initial and boundary conditions to generate forecasts. They offer distinct advantages such as clear physical interpretability and the ability to reveal underlying oceanic processes, yet their performance is highly dependent on the accuracy of initial and boundary settings and

收稿日期: 2025-10-13; 修回日期: 2026-01-06; 预印本日期: 2026-01-13

\* 通信作者: 宋巍 wsong@shou.edu.cn

基金项目: 国家自然科学基金项目(42376194)

Supported by: National Natural Science Foundation of China(42376194)

imposes substantial demands on computational resources. By contrast, data-driven methods have emerged as a core technical pathway to enhance prediction accuracy. By leveraging statistical modeling and machine learning algorithms, they automatically extract spatiotemporal patterns and evolutionary laws of the marine environment from massive volumes of historical and real-time observational data. Requiring minimal prior physical knowledge, these methods excel at capturing intricate nonlinear relationships between oceanic variables, demonstrating remarkable flexibility and efficiency—particularly in short-to-medium-term forecasts (approximately 1–30 days) and regional-scale studies. With the rapid advancement of data acquisition technologies, including satellite remote sensing, buoy observations, and reanalysis techniques, the quality (e. g., precision and spatiotemporal continuity) and coverage of SST-related data have been significantly improved, laying a solid foundation for the development of sophisticated data-driven models. This paper presents a comprehensive and systematic review of data-driven SST prediction methods. An integrated research framework is constructed to synthesize state-of-the-art progress in the field. The analysis begins by clarifying the core characteristics and physical mechanisms of numerical and data-driven methods. Through detailed comparative analysis, this study highlights the unique advantages of data-driven approaches. These methods excel at capturing complex nonlinear relationships and adapting to diverse regional characteristics. At the same time, this review acknowledges the complementary value of numerical models. These models remain essential for long-term climate simulations and physical process interpretation. This study then follows a clear technical evolution trajectory. It covers the transition from statistical models and traditional machine learning to shallow neural networks and deep learning. Early research focused on statistical models such as canonical correlation analysis and autoregressive integrated moving average model (ARIMA). These models provided foundational contributions to SST anomaly and El Niño-southern oscillation (ENSO) prediction. Traditional machine learning models, including support vector regression and random forest, are also analyzed. This review explores their ability to handle nonlinear marine processes through feature engineering and hyperparameter optimization. The evolution continues into shallow neural networks like artificial neural network and adaptive neuro-fuzzy inference system. These models mine potential correlations between various marine environmental factors. They distinguish between single- and multi-factor synergetic frameworks to improve accuracy. Currently, deep learning represents the cutting edge of data-driven research. This review covers temporal sequence models such as long short-term memory (LSTM), gated recurrent unit (GRU), and temporal convolutional network (TCN). It also examines spatiotemporal fusion models like ConvLSTM and vision transformers. Special attention is paid to emerging large marine models, including WenHai, FengWu, and XiHe. These models integrate deep oceanographic domain knowledge into their architectures. They have achieved breakthroughs in high-resolution ( $\approx 3$  km) and long-horizon forecasting. Furthermore, they effectively preserve fine-scale oceanic structures such as eddies and fronts. Beyond model architectures, this study conducts an in-depth analysis of multisource datasets. These datasets include in-situ observations from array for real-time geostrophic oceanography (ARGO) buoys and satellite remote sensing data like NOAA's optimum interpolation sea surface temperature (OISST). This study also incorporates reanalysis data such as ERA5 and CMIP6 model simulations. These sources are compared on the basis of their spatiotemporal resolution and reliability. This review discusses how data quality and scale directly affect model performance. Through case studies in regions like the tropical Pacific and Chinese coastal waters, it evaluates model adaptability. This evaluation provides practical guidance for data-model matching in specific scenarios. For instance, remote sensing data isare highly suitable for regional field prediction using spatiotemporal models. By contrast, reanalysis data offer critical support for long-term climate trend analysis. This study further identifies the core challenges facing this research field. The most significant obstacle is the lack of model interpretability. Deep learning architectures often function as “black boxes”, which limits their scientific credibility. To address this limitation, this review proposes three promising solutions. First, it advocates for physics-informed machine learning to embed oceanic equations into loss functions. Second, it discusses inherently interpretable architectures like the Kolmogorov-Arnold network. Third, it explores post-hoc explanation methods such as shapley additive explanations (SHAP) and partial dependence plots (PDP). Large marine models also enhance interpretability by mapping latent variables to known physical modes, including patterns like the Pacific decadal oscillation. Another key challenge is the scale adaptation of multisource data. Datasets often exhibit inconsistencies in spatial resolution and temporal frequency. These inconsistencies lead to feature misalignment and reduced model generalization. This study advocates for a two-stage strategy to solve this issue. The

first stage involves preprocessing steps like hierarchical data fusion to unify scales. The second stage emphasizes multiresolution feature learning during training. This approach helps the model exploit hierarchical information and compensate for data loss. Finally, this paper outlines future development directions for the global community. One primary goal is to expand to three-dimensional subsurface temperature structure modeling. This shift is necessary to capture vertical energy exchange processes. This review also emphasizes advancing interannual to decadal prediction capabilities. It suggests further integrating physical constraints to enhance model robustness. Ultimately, data-driven methods will play an increasingly pivotal role in advancing prediction accuracy. This comprehensive system serves as a systematic reference for research and technological innovation. It contributes to international collaboration in oceanography and climate science.

**Key words:** marine environment; sea surface temperature(SST); data-driven model; deep learning; spatio-temporal feature

## 0 引言

海表面温度(sea surface temperature, SST)是地球气候系统中一个非常重要的变量,也是区域海洋生态系统健康的重要贡献者,SST预测一直是海洋学和大气学研究的一个活跃领域(Gentemann, 2014; Zhang等, 2020a; Xiao等, 2019b)。一方面,基于SST预测结果可以计算海表面温度异常(sea surface temperature anomalies, SSTA)。SSTA显著影响海表面盐度、降水和海洋环流(Gholikandi等, 2018; Huang等, 2008),并直接影响干旱等极端水文事件(Gholikandi等, 2018; Salles等, 2016),且与飓风的发生之间存在强烈相关性(Gholikandi等, 2018; Jiang等, 2018; Patil和Deo, 2018)。另一方面,通过预测SST变化,可以评估海洋和大气之间的热交换、水生物种的行为模式。研究表明,SST的变化会导致物种分布的纬度变化,影响珊瑚礁生长和海洋渔业,而在全球变暖加速期和间歇期,我国海域SST的变化速度快于全球SST变化速度,这代表我国海域是全球气候的敏感区域。因此,SST变化的准确预测对我国沿海区域经济发展和生态环境保护起着重要作用(蔡榕硕和谭红建, 2024)。

SST的预测方法大体上可分为两类:数值模式与数据驱动方法。数值模式依托动力学与热力学方程构建模型,通过求解给定初始与边界条件下的复杂偏微分方程计算预测结果。其核心优势在于具备明确的物理机制解释力,能揭示结果背后的海洋过程,预报可信度较高,但其局限性同样显著,如预测结果高度依赖初始条件与边界设定,同时对计算资源提出较高要求。数据驱动方法则以数据为核心,通过统计建模或机器学习算法,从大量历史与实时观测数据中自动学习海洋环境的时空规律,进而推

断未来SST。该方法无需依赖大量先验物理知识,即可捕捉复杂的海洋变量关系,因此具备更强的灵活性,尤其适合中短期预报(约1~30天)与区域尺度研究。随着数据采集技术的发展,数据的质量(如精度、时空连续性)与覆盖广度显著提升,为数据驱动模型的开发提供了核心支撑,基于不同算法(如机器学习、深度学习)与多源观测数据的驱动模型也随之不断涌现,在区域适应性与模型多样性上表现出突出优势。

图1梳理了两类方法在SST预测研究中的发展历程:二者在海洋观测技术进步与理论演进的推动下,始终呈现并行发展态势。综上所述,本文在简要介绍数值模式方法核心原理的基础上,重点综述数据驱动方法的研究进展,并结合不同数据类型的特征,探讨各类模型的性能表现及应用适用性。

为清晰呈现SST预测方法的体系架构、核心分支及技术演进脉络,图2系统梳理了各类模型的归属关系与关键特征,为后续各节深入分析各类方法的优势与局限提供可视化框架支撑。另外,为了方便读者理解,表1列出了本文涉及的专业术语和缩略语的中英文对照。

## 1 海洋数值模式

海洋数值模式的发展历程大体经历了3个阶段:从早期的低阶海洋环流模式,到三维海洋环流模式,再到新一代海洋动力系统数值模式。一些代表性的海洋数值模式及其特点如表2所示。

早期,由于计算资源极度匮乏,只能用低分辨率、少层数或解析/半解析方法,如Stommel(1948)、Munk(1950)的风生环流解析模型。1969年,Bryan(1969)基于低阶有限差分方法构建了第1个基于原




图1 预测SST模型发展线

Fig. 1 Timeline of SST prediction model development

始方程的全球刚盖(rigid-lid)海洋模式,但严重依赖刚盖假设,网格粗(几百 km)。该阶段对于SST的计算通常采用“强迫—恢复”(haney-type restoration)方式,SST完全被“钳制”在观测气候态附近,无法自由演变,海气热通量不真实,无法用于真正耦合气候模式。

三维海洋环流模式基于完整原始方程组构建,采用自由表面或隐式自由表面处理方案。通过逐步引入真实地形、湍流混合参数化方案及热盐强迫等物理过程,模式水平分辨率由低分辨率量级逐步精细化至 $1^{\circ}\sim 0.25^{\circ}$ ,垂直分层20~50层。并形成了当今主流的 $z$ 坐标、等密度坐标、混合坐标三大体系。这一阶段,SST成为真正的预报变量之一,CMIP1(coupled model intercomparison project phase)—CMIP3海洋模式能够实现SST弱恢复;GFDL(geophysical fluid dynamics laboratory)(Marsooli等,2017)、HadCM3(Hadley centre coupled model)(Pope等,2000)、MPI-OM(Max Planck Institute—ocean model)(Marsland等,2003)等海气耦合模式能够由海气能量完全决定SST。MOM(modular ocean model)(Griffies等,2015)、NEMO(nucleus for European modeling of the ocean)(Gurvan等,2017)、MIT-gcm(Massachusetts institute of technology general circulation model)(Adcroft等,1999)等模型引入短波辐射穿透、湍流混合改进以及河流径流等,显著改善了

对SST季节循环和年际变率ENSO(El Niño-southern oscillation)的模拟,但系统性偏差较大(如赤道冷舌区海表温度偏低或偏高)。

新一代海洋动力系统数值模式通过无结构网格、自适应网格或多分辨率嵌套技术,以及更精细的海气耦合和海陆气耦合,极大地提升了数值模式的能力。例如,MOM6(GFDL modular ocean model)将波浪、湍流模式相结合,减小了热带西太平洋和印度洋暖池SST冷偏差,MPAS-Ocean(model for prediction across scales-ocean)(Hoch等,2020)、FESOM2(finite element sea ice-ocean model)(Koldunov等,2019)、ICON-O(icosahedral non-hydrostatic-ocean)(Korn等,2022)采用多分辨率或无结构网格局部加密技术,能再现上升流区、气旋冷尾等高频现象。

总体来看,尽管海洋模型在避免复杂偏微分方程的直接求解上具有优势,但在模拟复杂、非线性且具混沌特性的海洋温度场系统时,提升预报精度往往需要增加模式复杂性与数据同化策略。同时,边界与初始场误差易在积分过程中累积,影响模拟的长期稳定性与精度。因此,单纯数值模拟在海表温的高精度重现与细尺度过程刻画方面仍有待提升。当前SST数值模拟研究正向高分辨率化、耦合化与智能化方向发展。一方面,通过改进混合垂直坐标和湍流混合参数化、加强海气耦合过程刻画;另一方




图 2 整体架构图

Fig 2 Overall architecture diagram

表 1 相关术语中英文对照  
Table 1 Relevant terms: Chinese-English comparison

| 中文术语                       | 英文术语                                                            | 英文缩略          |
|----------------------------|-----------------------------------------------------------------|---------------|
| 海表面温度                      | sea surface temperature                                         | SST           |
| 海表面温度异常                    | sea surface temperature anomalies                               | SSTA          |
| 三维海下温度结构                   | subsurface temperature                                          | ST            |
| 海洋热浪                       | marine heatwave                                                 | MHW           |
| 厄尔尼诺—南方涛动                  | El Niño-Southern Oscillation                                    | ENSO          |
| 耦合模式比较计划                   | coupled model intercomparison project                           | CMIP          |
| 美国地球物理流体动力学实验室模块化海洋模型      | GFDL modular ocean model                                        | MOM           |
| 美国地球物理流体动力学实验室模块化海洋模型第 6 版 | GFDL modular ocean model version 6                              | MOM6          |
| 普林斯顿海洋模型                   | Princeton ocean model                                           | POM           |
| 区域海洋模拟系统                   | regional ocean modeling system                                  | ROMS          |
| 代尔夫特 3D 模型(河口海岸综合模型)       | Delft3D model                                                   | Delft3D       |
| 高级环流模型                     | advanced circulation model                                      | ADCIRC        |
| 河口—海岸—海洋模型                 | estuarine, coastal and ocean model                              | ECOM          |
| 环境流体动力学模型                  | environmental fluid dynamics code                               | EFDC          |
| 有限体积海岸海洋模型                 | finite volume coastal ocean model                               | FVCOM         |
| 并行海洋程序(海洋环流模型)             | parallel ocean program                                          | POP           |
| 混合坐标海洋模型                   | hybrid coordinate ocean model                                   | HYCOM         |
| 麻省理工学院通用环流模型               | Massachusetts Institute of Technology general circulation model | MITgcm        |
| 欧洲海洋模拟核心模型                 | nucleus for European modeling of the ocean                      | NEMO          |
| 欧洲海洋模拟核心模型(1/12°分辨率版本)     | nucleus for European modeling of the ocean (1/12° resolution)   | NEMO 1/12°    |
| 中国科学院大气物理研究所 LASG 气候系统海洋模型 | LASG/IAP climate system ocean model                             | LICOM         |
| 跨尺度预测模型—海洋分量               | model for prediction across scales—ocean                        | MPAS-O        |
| 第 2 代有限元海冰—海洋模型            | finite element sea ice-ocean model version 2                    | FESOM2        |
| 20 面体非静力海洋模型               | icosahedral non-hydrostatic—ocean                               | ICON-O        |
| 美国国家海洋和大气管理局               | National Oceanic and Atmospheric Administration                 | NOAA          |
| 最优插值海表面温度数据集               | optimum interpolation sea surface temperature                   | OISST         |
| 欧洲中期天气预报中心                 | European centre for medium-range weather forecasts              | ECMWF         |
| 欧洲海洋环境监测服务                 | Copernicus marine environment monitoring service                | CMEMS         |
| 世界气候研究计划                   | world climate research programme                                | WCRP          |
| 英国气象局                      | United Kingdom meteorological office                            | UK Met Office |

面,结合数据同化和机器学习方法以优化模型初始场和参数、进行误差校正等,提高 SST 模拟的精度与时空适应性。

2 数据驱动视角下的海表面温度预测模型

随着观测技术和数据获取手段的不断进步,尤

其是卫星遥感、浮标观测以及再分析和同化技术的发展,支撑 SST 预测的数据基础得到了极大丰富和完善。早期的 SST 研究主要依赖站点观测,受限于空间分布稀疏和覆盖范围有限,难以在大尺度或精细化水平上满足预测需求。近年来,多源观测手段逐步形成了“空—天—地—海”的立体化监测体系(朱柏和叶沅鑫,2024),不仅显著扩展了数据的时空覆盖范围,也为数据驱动建模方法的快速发展提供

表 2 海洋数值模式分类  
Table 2 Classification of marine numerical models

| 阶段                        | 代表性方法                                                                                                                                                                                                                                                         | 特点                       |
|---------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------|
| 低阶模式(1950s—1970s)         | 解析模型(Anon、Munk)、Bryan & Cox 刚盖模式                                                                                                                                                                                                                              | 简化物理、粗分辨率                |
| 三维海洋环流模式(1980s—2000s)     | MOM、POM (Ezer 和 Mellor, 2000),<br>ROMS(Wu 等, 2019)、POM(Yang 等, 2018b)、<br>Delft3D(沈淇 等, 2011)、ADCIRC(罗锋 等, 2012)、<br>ECOM(沈淇 等, 2011)、EFDC(罗锋 等, 2012)<br>FVCOM(Chen 等, 2003)、MOM、POP(Smith 等, 1992)<br>HYCOM(Bleck, 2002)、MITgcm、NEMO、<br>LICOM(Liu 等, 2012) | 原始方程、1°~0.25°、涡参数化       |
| 新一代海洋动力系统模式<br>(2010s—至今) | MOM6、MPAS-O、FESOM2、ICON-O、NEMO                                                                                                                                                                                                                                | 涡分辨/亚中尺度许可、非静力、无<br>结构网格 |

了坚实支撑。

在这一背景下,针对 SST 预测可利用的数据主要包括站点观测数据、遥感数据、再分析数据和模式数据。不同类型的数据在空间分辨率、时间长度、可靠性和可获得性等方面各具优缺点,共同构成了支撑数据驱动建模研究的多样化数据来源。其中,遥感数据凭借覆盖范围广、时效性强和连续性好的特点(郑向涛 等, 2024),已成为 SST 预测中最常用的输入,尽管其在时间长度和观测精度上仍存在一定局限,需要通过数据插值和融合等手段进行改进。

在数据层面逐渐丰富的推动下,建模方法也从传统的统计方法逐渐演进至机器学习、神经网络和深度学习等更为复杂的方式。与基于物理的数值模式相比,数据驱动方法具有计算成本低、灵活性强和对复杂非线性特征建模能力突出的优势(Konar, 2018)。越来越多的研究表明,得益于人工智能的发展,数据驱动模型能够有效识别海温变化的复杂时空模式,并为 SST 的中短期预报乃至长期气候趋势研究提供新的可能性(Yaseen 等, 2019; Sharafati 等, 2020; Sharafati 等, 2021)。

基于数据驱动 SST 预测模型的技术演进路径与核心技术特征,本文以特征提取方式、网络结构复杂度(隐藏层数)及训练模式为关键区分依据,将现有模型划分为统计模型、传统机器学习模型、浅层神经网络模型和深度学习模型 4 类,各类模型的核心特点、结构参数、训练特性及典型算法如表 3 所示。该分类清晰呈现了不同模型从手工特征依赖到自动特征学习、从浅层结构到深层网络、从非端到端训练到端到端优化的演进规律,为后续模型选择与改进提

供了明确的参考框架。

基于以上逻辑,本节将首先介绍各类数据集的特点和应用价值,随后讨论 4 类常见的数据驱动模型在 SST 预测中的应用情况,最后总结常用的评估指标与研究趋势。

2.1 数据类型与特点

在 SST 预测研究中,数据采集手段的进步极大推动了建模方法的发展。早期研究主要依赖于站点观测数据,其精度和可靠性较高,如中国国家海洋观测站数据、ARGO (array for real-time geostrophic oceanography) 浮标资料在长期序列研究中应用广泛。

随着卫星遥感技术的发展,研究者能够获取覆盖广、分辨率高且空间连续性优良的 SST 数据(崔雪森等, 2013)。典型代表包括 NOAA 的最优插值海表面温度数据集,其日或周尺度产品在 1980 年代以来的 SST 监测中应用广泛;欧洲海洋环境监测服务 CMEMS 提供的高分辨率产品也在区域预测中具有优势。遥感数据的优点是时效性强、覆盖全面,但其时间序列较短,且易受云层、大气条件影响,需要利用插值或多源融合方法进行修正。

模式数据则为未来预测研究提供了关键支撑。典型代表是耦合模式比较计划第 6 阶段 CMIP6 输出数据,涵盖多种气候情景下的长时间序列模拟,为极端气候事件、长期变暖趋势和未来 SST 变化研究提供重要依据。

再分析数据结合了观测资料与数值模式的优势,在要素多样性和时间连续性上表现出显著潜力。以 ERA5(由欧洲中期天气预报中心 ECMWF 发布)

表 3 数据驱动 SST 预测模型分类及区分依据

Table 3 Classification and distinguishing criteria of data-driven SST prediction models

| 类别       | 特点                | 隐藏层数 | 端到端训练   | 典型算法                                                     |
|----------|-------------------|------|---------|----------------------------------------------------------|
| 统计模型     | 手工特征 + 统计规律建模     | 0    | ×       | CCA、AR/ARMA/ARIMA、LSTAR                                  |
| 传统机器学习模型 | 手工特征 + 非线性拟合      | 0    | ×       | SVM/SVR、RF、GBM、CEEMD-SVM                                 |
| 浅层神经网络模型 | 自动基础特征 + 要素关联挖掘   | 1~2  | ×(半端到端) | ANN、MLP-BP、RBFN、NAR、ANFIS                                |
| 深度学习模型   | 自动复杂时空特征 + 复杂过程建模 | ≥ 3  | √       | LSTM/GRU、ConvLSTM、3DCNN、Transformer、<br>海洋大模型(WenHai、风乌) |

为代表的再分析产品提供了多源观测同化后的全球一致性资料,具备较长时间序列和多参数特性。

在 SST 预测研究中,基于站点观测、卫星遥感、模式模拟及再分析等不同手段获取的数据集,从数据特征与应用场景维度来看,研究中常用的数据类型主要可分为时序数据和时空数据两类,前者聚焦 SST 在时间维度的演变规律,后者则承载其时空维度的耦合分布信息。

表 4 对不同数据集进行了总结,以便更直观地比较其在 SST 预测中的适用性。

2.2 基于历史观测数据的统计模型

20 世纪 90 年代,统计模型在 SST 预测中得到了广泛应用,其预测结果可为计算海温异常 SSTA 和 ENSO 现象提供帮助。统计模型通常以概率论为基础,采用数学统计方法建立模型。对于某些复杂海洋过程难以用理论分析方法导出其模型,可以通过实验测定数据,经过数理统计法求得各变量之间的函数关系。在 SST 预测问题上,常用的统计模型方法包括典型相关分析法(canonical correlation analysis, CCA)和时间序列分析法(time series analysis, TSA)等。

CCA 是一种用于分析两组变量之间关系的统计学方法。1987 年,CCA 首次用于分析海洋预测中变量的双重空间模式之间的相关性:一个表示预报因子的空间模式,另一个表示预报量的空间模式(Barnett 和 Preisendorfer, 1987)。1992 年, Barnston 和 Ropelewski(1992)将 CCA 模型应用在对热带太平洋和印度洋区域的 3 个月平均海温的预测问题上,实验结果表明 CCA 模型的预测效果优于之前的数值模型,并且数据中所记录的年份越多,预测的准确性就越高。在此基础上, Barnston 和 Smith(1996)又开

展了一项以海温预测气温和降水的研究,通过不同海域的预测性能分析,发现统计预测方法具有可重复性。CCA 在异常海温的预测方面也体现出了优越性(Colman 和 Davey, 2003; Collins 等, 2004; Repelli 和 Nobre, 2004)。Landman 和 Mason(2001)将 CCA 用于对全球 SST 的预测,以之前几个月的平均 SST 预测下个月 SST,对 ENSO 发展阶段,当预测提前期超过一个季节时,CCA 方法的预测技巧显著优于持续异常方法。Colman 和 Davey(2003)结合 CCA、简单持续方法和近邻回归 3 种统计方法对 SSTA 进行了预测,研究表明组合模型预测效果优于单一模型,且 CCA 模型占优势。Repelli 和 Nobre(2004)通过经验正交函数(empirical orthogonal function, EOF)对预测变量序列进行分解,再使用 CCA 提取主成分变量,用于预测热带大西洋 SSTA。该方法在赤道太平洋和热带大西洋区域内提前 3~4 个月预测热带大西洋的海温异常,并且北大西洋的预测误差小于 0.5℃,南大西洋的预测误差约为 1℃。每个网格的预测结果均优于持久性预测结果,这表明典型相关统计方法预测的准确性。

TSA 是一种利用历史观测数据中变量随时间变化规律进行建模与预测的统计方法。在 SST 预测中,它通过分析海洋表面温度序列的季节性、年际变化及长期趋势等特征,刻画其时间演变规律,用以预测未来的海温变化。在实际应用中,传统的统计型时间序列模型包括自回归模型(autoregressive model, AR)、移动平均模型(moving average model, MA)、自回归移动平均模型(autoregressive moving average model, ARMA)以及自回归综合移动平均模型(autoregressive integrated moving average model, ARIMA)等。这些模型结构相对简单、计算效率高,

表 4 常见 SST 数据集及其特点  
Table 4 Common SST datasets and their characteristics

| 机构名称          | 提供的 SST 相关数据集                                                                                                                                 | 时间分辨率   | 空间分辨率                                   |
|---------------|-----------------------------------------------------------------------------------------------------------------------------------------------|---------|-----------------------------------------|
| 国家海洋科学数据中心    | CORA v2.0 冰—海耦合再分析 SST 产品                                                                                                                     | 3 小时、逐时 | 9 km (约 0.08°)、站点级                      |
|               | 中国海洋站 SST 标准化数据集                                                                                                                              |         |                                         |
|               | 下载链接: <a href="https://mds.nmdis.org.cn/">https://mds.nmdis.org.cn/</a>                                                                       |         |                                         |
| 中国科学院大气物理研究所  | LICOM3.0 变分辨率海洋模式 SST 产品                                                                                                                      | 月尺度     | 南海区域 0.02°, 其他区域 0.1°                   |
|               | 下载链接: <a href="https://earthlab-data.iap.ac.cn/">https://earthlab-data.iap.ac.cn/</a>                                                         |         |                                         |
| 国家海洋局第一海洋研究所  | 全球海洋多源遥感 SST 融合产品                                                                                                                             | 每日      | 0.1° × 0.1°                             |
|               | 下载链接: <a href="https://www.fio.org.cn/">https://www.fio.org.cn/</a>                                                                           |         |                                         |
| NOAA          | OISST                                                                                                                                         | 每日      | 0.25° × 0.25°                           |
|               | 下载链接: <a href="https://www.ncei.noaa.gov/products/optimum-interpolation-sst">https://www.ncei.noaa.gov/products/optimum-interpolation-sst</a> |         |                                         |
| ECMWF         | ERA5 海表温度产品                                                                                                                                   | 小时级     | 0.25° × 0.25°                           |
|               | 下载链接: <a href="https://cds.climate.copernicus.eu/">https://cds.climate.copernicus.eu/</a>                                                     |         |                                         |
| CMEMS         | 区域高分辨率 SST 分析产品                                                                                                                               | 每日      | 西北太平洋 0.125° × 0.125°, 全球 0.25° × 0.25° |
|               | 下载链接: <a href="https://marine.copernicus.eu/">https://marine.copernicus.eu/</a>                                                               |         |                                         |
| WCRP          | CMIP6 多情景海温模拟数据集                                                                                                                              | 日尺度/月尺度 | 0.25° ~ 1°                              |
|               | 下载链接: <a href="https://esgf-node.llnl.gov/esg-search/">https://esgf-node.llnl.gov/esg-search/</a>                                             |         |                                         |
| 国际 ARGO 计划办公室 | ARGO 浮标 SST 观测资料                                                                                                                              | 10 天/次  | 100 ~ 300 km 网格                         |
|               | 下载链接: <a href="https://argo.ucsd.edu/data/">https://argo.ucsd.edu/data/</a>                                                                   |         |                                         |
| UK Met Office | OSTIA 全球 SST 与海冰分析产品                                                                                                                          | 每日      | 1/20° (约 5 km)                          |
|               | 下载链接: <a href="https://ghrsst-pp.metoffice.gov.uk/ostia-website/index.html">https://ghrsst-pp.metoffice.gov.uk/ostia-website/index.html</a>   |         |                                         |

适用于变化平稳、自相关性强的海洋变量。由于海洋具有巨大的质量和热容量,其变化过程通常较为缓慢,因此海洋的长期变化常被认为是近似线性的 (IPCC, 2007),时间序列方法在预测此类稳定且持续变化的海洋特征时表现良好。

TSA 在早期的应用中,自回归与线性时间序列模型是最常用的工具。张玉荣 (1992) 利用自回归方程实现了逐日海温趋势预测,为 SST 定量预测提供了初步实践。随后,ARMA 与 ARIMA 等经典线性模型广泛用于区域性的海域预测研究,表现出较好的稳定性和可解释性。例如,Shirvani 等人 (2015) 对波斯湾 SST 进行建模,结果显示 ARIMA 模型能够有效捕捉局地海温变化趋势;Salles 等人 (2016) 在热带大

西洋研究中进一步验证了 ARIMA 模型在短期预测中优于随机游走等基准方法。这一阶段的研究主要集中在气候时间尺度的海温变化分析与趋势估计,重点在于理解海洋的温度演变规律。

随着研究从线性平稳过程向气候系统的复杂动力特征与极端事件预测扩展,状态转移与非线性时间序列模型逐渐被引入。例如, Xue 和 Leetmaa (2000) 利用马尔可夫模型构建 SST 状态转移过程,实现了热带太平洋 SST 在 9 个月尺度内的中期预测;Hall 等人 (2001) 提出平滑转移自回归模型 (logistic smooth transition autoregressive, LSTAR),用于刻画厄尔尼诺事件发生的非平稳性特征;Ubilava 和 Helmers (2013) 进一步基于 STAR 模型改进了 SSTA

预测,表明其在短期和中期预报中均优于数值模型。这一时期的研究体现了时间序列方法在气候事件发生机理与突变型过程预测中的拓展,标志着 SST 时间序列分析由“趋势预测”向“过程解析”的转变。

进入新阶段后,研究重点进一步转向多源数据融合与统计回归框架的构建。例如,Kug 等人(2004)通过结合印度洋与太平洋海温的滞后关系及数值模拟结果,构建了基于多源信息的线性回归模型,显著提升了 SST 预测精度;Laepplé 和 Jewson(2007)利用回归模型成功捕捉热带大西洋的 SST 变化特征,其在适宜时段内的表现甚至优于某些气候模式;吉进喜等人(2010)将经验正交函数分解、自回归模型与 Kalman 滤波相结合,进一步增强了 SST 预测的动态稳定性和随时间更新能力。这一阶段的研究更多关注统计模型的结构融合与参数自更新机制,为后续机器学习方法的发展奠定了数据驱动的基础。

这些方法通过 CCA 和 TSA 两类技术,有效应对了 SST 数据的非线性和不确定性,提高了预测的准确性和可靠性。这些研究的意义延伸到海洋生态学、渔业和气象预测等多个领域。

### 2.3 面向海洋非线性过程的传统机器学习模型

SST 的预测在空间和时间上具有显著挑战,这是由于其演变所体现出的复杂非线性特征以及海洋系统本身的高度不确定性(Corchado 和 Fyfe, 1999; de Paz 等, 2012)。传统的数学和统计模型在预测过程中往往受到局限,这类方法过于依赖经验判断,难以适应大尺度、复杂性强的海洋问题(Corchado 和 Aiken, 2002)。随着计算能力的提升,机器学习(machine learning, ML)作为人工智能的重要分支逐渐引入 SST 预测研究,并展现出良好的应用潜力。机器学习通过从大量历史数据中自动学习潜在规律与非线性关系,而无需显式地建立物理方程,从而能够对复杂系统进行建模与预测。它主要包括支持向量机(support vector machine, SVM)、随机森林(random forest, RF)和梯度提升树(gradient boosting machine, GBM)等多种算法框架。与传统的数值模式相比,机器学习方法不仅能够获得相当好的预测性能,同时在计算效率和泛化能力上也具有优势(张世杰, 2021; Wolff 等, 2020)。

在传统机器学习方法中,SVM 及其扩展形式支持向量回归(support vector regression, SVR)在非线

性建模中优势更为突出(Aguilar-Martinez 和 Hsieh, 2009; Imani 等, 2014)。Lins 等人(2013)基于热带大西洋 PIRATA 浮标的 SSTA 数据,利用 SVM 并分别采用原始值、斜率与曲率 3 种特征进行年度预测。结果显示,曲率特征在提升预测精度方面略优于原始值与斜率形式,预测误差总体较小(平均绝对百分比误差(mean absolute percentage error, MAPE) < 2%,平均绝对误差(mean absolute error, MAE) < 0.37 °C)。Jiang 等人(2018)则将纬度、经度和水深信息作为空间变量引入,利用高斯径向基函数核(radial basis function, RBF 核)的 SVR,通过手工设计的空间变量与 SST 时序特征,将非线性数据映射到高维空间以完成拟合,实现对加拿大神湾区域的高分辨率 SST 场预测,展示了该方法在区域建模中的有效性。

除单一方法外,融合统计分解与机器学习的混合模型在提升预测性能方面也表现突出。例如,Li 等人(2017)提出的 CEEMD-SVM 模型,通过互补集合经验模态分解(complete ensemble empirical mode decomposition, CEEMD)对 SST 信号进行分量提取与重构,再结合 SVM 进行预测,显著改善了东北太平洋 SST 的预报精度。该成果显示,模型融合既能提升预测结果的稳定性,也有助于克服单一模型在特征提取或时序依赖方面的不足。

模型的预测精度不仅与输入变量对 SST 的表达能力有关,也受到超参数的影响。查铖等人(2020)提出了一种基于时间序列相似性度量的海表面温度预测方法(dynamic time warping + SVM + LSPSO (local learch particle swarm optimization), DSL),其整体框架如图 3 所示。该方法首先利用动态时间规整(dynamic time warping, DTW)从历史数据中挖掘与当前趋势相似的子序列,以此形成参考模式与类比模式,并通过前  $k$  个最相似的类比序列构建 SVM 预测模型输入;其次,引入基于局部搜索改进的粒子群优化算法(LSPSO)对模式的长度和间隔步长两个关键参数进行双目标优化,在保证预测精度的同时大幅提升运行效率;最后,将优化后的参数配置应用于 DSL 模型,对未来 5 天的 SST 进行预测。实验结果表明,该方法预测性能甚至优于深度学习的长短期记忆网络(long short-term memory, LSTM)。

总体而言,传统机器学习模型在应对海洋过程的非线性特征时展现出一定优势。例如,SVM 能够捕捉复杂的输入—输出映射关系,而混合模型则在




图3 基于时间序列相似性度量的海表面温度预测算法流程图(查铖等, 2020)

Fig. 3 Flowchart of the sea surface temperature prediction algorithm based on time-series similarity metrics(Zha et al., 2020)

特征分解与长时序预测中更具稳健性。然而,这类方法的性能仍高度依赖于数据的充分性与输入因子的合理构建(Ahmad, 2019)。随着数据获取能力和计算手段的不断发展,传统机器学习方法的探索不仅证明了其在 SST 预测中的可行性,也为进一步引入深度学习模型,突破对非线性和多尺度特征的刻画瓶颈提供了基础。

#### 2.4 基于海洋要素特征建模的浅层神经网络模型

神经网络是由大量相互连接的处理单元组成的非线性自适应信息处理系统,它模拟了人类神经系统信息传递的过程。虽然浅层人工神经网络属于传统机器学习的范畴,但随着人工神经网络结构和训练算法的不断演进,它已经逐渐形成了相对独立的研究分支。早在 1998 年, Hsieh 和 Tang (1998) 就分析了神经网络在大气和海洋中的应用前景,并提出了基于神经网络的预测模型,证明了神经网络在大气和海洋预测方面具有科学性,从而引起了对神经网络方法在预测 SST 问题上的广泛关注。

由于海表面温度的变化是一个极其复杂的现象,它与大气—海洋要素以及外部驱动因素都存在着强烈的关联性。因此,本节重点关注利用海洋要

素潜在关联性的神经网络预测模型及其应用研究。

##### 2.4.1 单要素特征的海表温时序预测

在以 SST 为唯一预测因子的建模中,研究者们主要依托 SST 时间序列自身的静态值、滞后特征、多尺度变化以及空间独立性开展预测。最直接的方式是利用历史 SST 值作为输入,通过人工神经网络 (artificial neural network, ANN) 进行建模 (Barrows 和 Juggins, 2005; Hayes 等, 2005)。类似地, Aparna 等人 (2018) 和 Wei 等人 (2020) 通过输入历史 SST 值完成不同海区的预测,验证了基于 SST 单一要素建模的普适性。Nooteboom 等人 (2018) 则将 ARMA 与人工神经网络 (ANN) 结合,用混合模式预测 ENSO 现象,结果表明,其在未来 6 个月的预测中略优于美国国家环境预测中心的 CFSv2 (climate forecast system) 集合预测。

在滞后特征的利用方面,研究者普遍将历史 SST 序列的滞后值作为预测因子,用于未来月尺度或季节性变化的推断。Patil 等人 (2016) 采用非线性自回归神经网络 (nonlinear autoregressive model, NAR) 提升了北印度洋区域的年际预测表现; Mahongo 和 Deo (2013) 在比较 FFNN (feedforward neural network)、RBFN (radial basis function network)、

GRNN(general regression neural network)与 ARIMAX (autoregressive integrated moving average with exogenous variables)模型时发现,基于滞后 SST 值输入的 FFNN 效果更佳;Liao 等人(2017)通过滞后值驱动的输入方法及 RBFN 模型验证了 ANN、RBFN 的优越性能。滞后特征的价值也延伸到跨领域应用中,Modaresi 等人(2016)以波斯湾和地中海 SST 的滞后值为输入,成功预测了伊朗 Karkheh 流域的春季流量,为 SST 单要素模型的应用范围提供了新视角。

针对 SST 时间序列中普遍存在的非平稳与多尺度特征,不少研究尝试在建模前进行信号分解与预处理。Patil 等人(2016)以及 Patil 和 Deo(2017)将小波变换与神经网络结合,显著改善了预测与实测之间的线性相关性;Patil 和 Deo(2017)进一步提出小波神经网络实现未来 5 日站点级 SST 的预测,但也指出该方法难以适应月尺度的短序列预测问题。Wu 等人(2019)在北太平洋研究中比较了 CEEMD-BPNN (ensemble empirical mode decomposition-back propagation neural network)与 EEMD-BPNN (complementary ensemble empirical mode decomposition-back propagation neural network),两种方法均有效提升了非平稳数据预测性能,其中,CEEMD-BPNN 更具稳定性。

SST 单要素的空间独立性特征也被用于建模尝试。Guo 等人(2017)首次应用自组织映射(self-organizing map, SOM)预测太平洋 SST,强调了不同

空间位置点在时间序列上的独立模式学习;Jafari Nodoushan (2018)结合 FFNN 与贝叶斯神经网络(Bayesian neural network, BNN)预测夏威夷海岸檀香山区域海温,更好地刻画了预测的不确定性;Foroozand 等人(2018)则通过集成模型预测热带太平洋 SST,进一步提升了预测的稳定性。

单要素特征的海表温预测研究充分挖掘了 SST 自身的值特征、滞后特征、多尺度变化以及空间独立性,并依托各类神经网络及其扩展方法开展建模。在不同区域的实践表明,该类方法能够有效刻画 SST 的非线性演变规律,但模型性能高度依赖于 SST 特征提取和网络结构设计,这也为后续多要素融合研究提供了关键技术铺垫。

为量化统计模型、传统机器学习及浅层神经网络在 SST 预测中的实际性能,本研究以 7 天历史观测数据预测 1 天 SST 为核心场景,基于东海、黄海站点实测数据开展对比实验,结果如表 5(Yu 等, 2020)所示。结果显示,3 类模型呈现明显性能梯度:传统机器学习中的 SVR 与浅层神经网络中的门控循环单元(gated recurrent unit, GRU)表现最优,ACC (accuracy correlation coefficient)最高达 0.956 8、均方根误差(root mean square error, RMSE)最低至 1.080 2、MAE 最小为 0.430 0,且在远海温度稳定站点的预测稳定性更突出;ARIMA 等统计模型受线性假设限制,难以适配 SST 的复杂非线性特征,表现相对受限;整体趋势印证了从统计模型到机器学习、再到神经网络的技术演进,有效提升了 SST 预测的精度与适应性。

表 5 使用站点数据几类模型进行 SST 预测的结果  
Table 5 Results of SST prediction by several types of models using station data

| 模型           | 东海站点数据  |         |         | 黄海站点数据  |         |         |
|--------------|---------|---------|---------|---------|---------|---------|
|              | RMSE    | MAE     | ACC     | RMSE    | MAE     | ACC     |
| SVR          | 1.080 2 | 0.430 0 | 0.956 8 | 1.178 0 | 0.513 7 | 0.948 2 |
| SVM          | 1.793 2 | 0.653 0 | 0.938 0 | 1.461 8 | 0.845 7 | 0.936 0 |
| ARIMA        | 1.618 2 | 0.603 5 | 0.939 5 | 1.430 7 | 0.814 7 | 0.939 8 |
| BPNN         | 3.729 4 | 3.874 5 | 0.849 1 | 3.624 1 | 3.713 8 | 0.850 3 |
| RBFNN        | 2.827 4 | 2.610 2 | 0.869 1 | 2.817 3 | 2.501 5 | 0.871 1 |
| RNN          | 2.810 4 | 2.173 9 | 0.871 8 | 3.007 1 | 2.463 0 | 0.854 8 |
| GRU          | 1.528 1 | 1.598 1 | 0.932 5 | 1.081 4 | 1.876 8 | 0.928 7 |
| LSTM         | 1.710 2 | 1.729 1 | 0.928 3 | 1.827 1 | 2.391 5 | 0.919 4 |
| CEEMDAN-LSTM | 1.539 7 | 1.540 2 | 0.936 8 | 1.827 4 | 2.074 6 | 0.901 7 |

#### 2.4.2 多海洋环境因子协同预测

与单要素驱动的预测方法相比,多因子协同输入能够更全面地刻画海气耦合与时空动力过程,从而在SST预测任务中往往表现出更高的精度和更好的解释力。早期研究普遍从有限多变量神经网络的思路出发。例如,Ali等人(2004)将净地表热通量、辐射、风应力、历史SST以及动态高度等联合输入MLP(multi-layer perceptron)-BP(back propagation)模型,对阿拉伯海区域进行预测,实验证明多个物理量协同作用显著提升了模型性能。Garcia-Gorriz和Garcia-Sanchez(2007)在地中海西部利用FFNN同时引入气象条件和海洋因子进行SST预测,不仅改善了季节与年际尺度的预测精度,还揭示了1980年西阿尔伯兰环流的存在。这些尝试表明,多要素模型在提升拟合精度的同时,也能反映出关键的海洋过程。

后续研究不断拓展输入变量的范围与类型。例如,Huang等人(2008)在我国台湾海域的实验证实中,将盐度和温度作为关键因子输入模糊推理系统(fuzzy inference system, FIS)也能取得较高的准确性。Awan和Bae(2016)进一步将标准化降水指数(standardized precipitation index, SPI)、SST与SSTA整合到自适应神经模糊推理系统(adaptive neuro-fuzzy inference system, ANFIS)中,结果凸显出多要素输入能更好地捕捉气候相关海温的非线性关联。Bhaskaran等人(2010)引入经纬度与水深等空间因子,利用MLP刻画了印度洋环境因子与SST的关系。

针对海洋动态系统内部的不确定性,融合滤波的建模框架逐渐出现。Ouala等人(2018)基于双向神经网络(bidirectional neural network, Bi-NN)构造了多种卡尔曼滤波(Kalman filter, KF)组合模型(包括Bi-NN-KF、Bi-NN-NNKF-EOF),在南非和红海SST预测中均表现出显著优于传统方法的结果。Casas(2018)探索了使用数据同化神经网络(data assimilation neural network, DA-NN)和集成卡尔曼滤波器来处理大西洋区域的多要素输入数据,结果显示DA-NN对复杂海气动态过程的刻画更具优势,也突出了多因子引入新型变量的重要性。

综上所述,多要素驱动的SST预测研究从最初的“气象与海洋变量+神经网络”逐步扩展到“模糊逻辑/混合智能模型”,再到“滤波方法”。这些工作展示了不同类型多变量输入的潜力,也为多区域的

SST预测提供了丰富案例。通过这些方法,多因子输入不仅提升了精度,也使得预测结果更具物理意义,但如何选择合适的因子组合仍是亟需解决的问题。

#### 2.5 复杂海洋时空过程的深度学习模型

复杂时空数据(时空SST数据)普遍具有多尺度特性——时间维度涵盖短时波动与长期演变,空间维度包含局部细节差异与大范围整体格局,且变量间存在强非线性依赖,导致传统方法(浅层神经网络、传统机器学习、经典统计模型)难以有效捕捉其深层动态规律与潜在结构,建模能力受限。深度学习凭借对复杂特征的自动提取能力与对非线性关系的强大表达能力,成为突破传统技术瓶颈、实现复杂时空数据高效建模的核心技术路径,尤其在SST预测等序列任务中展现出关键价值,相关模型的发展与优化也构成了该领域的重要研究方向。

在SST预测研究中,深度学习模型可围绕两类核心维度展开。一类是捕获海洋现象时序演变的预测模型,通过时间序列模型挖掘SST的时序演变规律,实现未来SST预测;另一类是融合时空特征的区域海温场预测模型,依托同时包含时间动态与空间分布差异的SST时空序列数据,通过时空序列模型融合时空双重信息,完成区域海温场预测。两类模型分别从时序单一维度与时空复合维度,为复杂海洋时空过程建模提供技术路径。

##### 2.5.1 捕获海洋现象时序演变的预测模型

在SST预测研究中,深度学习方法的发展大体经历了从经典循环序列模型到新型网络结构与融合方法的演进。早期研究主要聚焦于循环神经网络(recurrent neural network, RNN)的应用,例如许柏宁等人(2017)提出了一种基于RNN编码—解码(encoder-decoder)框架的Seq2Seq(sequence-to-sequence)模型,在SSTA预测中取得了良好效果;Zhang等人(2017)将长短期记忆网络(LSTM)应用于中国沿海区域的SST预测,利用日、周及月尺度数据在渤海开展实验。结果表明,基于LSTM的深度神经网络在捕捉时间序列特征方面优于传统前馈网络。在此基础上,Liu等人(2018)进一步提出了时间依赖的LSTM(temporal dependence-based LSTM, TD-LSTM)以缩短训练所需的输入序列,提高建模效率,而Broni-Bedaiko等人(2019)则在2019年首次尝试将此类方法扩展至全球尺度,比较了LSTM与多输

入多输出 (multiple-input multiple-output, MIMO) 结构的性能,结果显示 LSTM 在预测精度上更具优势。随着研究的深入,学者们开始探索更为多样化的网络结构,包括基于局部搜索策略的 SSTP (sea surface temperature prediction) 模型 (He 等, 2020)、深度图卷积网络 (deep graph convolutional network, DGCnetwork) 模型 (Yu 等, 2020)、门控循环单元 (GRU) 模型 (Zhang 等, 2020b) 以及时序卷积网络 (temporal convolutional network, TCN) 模型 (Feng 等, 2021), 这些方法不仅能够更好地捕捉时间规律,还能够增强空间特征的表征能力,从而提升预测的准确性和稳定性。同时,一些研究提出了融合不同方法的改进思路,例如结合三次 B 样条插值、注意力机制与 LSTM 的模型 (Liu 等, 2021), 基于经验模态分解与 GRU 的组合模型 (贺琪 等, 2021), 以及其他修订方法 (Liu 等, 2022), 这些方案在不同气候条件与预测需求下展现出更强的灵活性与适应性。而注意力机制的引入也成为推动 SST 预测模型精度提升的重要方向, 例如 Qiao 等人 (2022) 提出的 Attention-LSTM 方法, 以 5 变量单点时间序列作为输入, 在赤道太平洋浮标站的 72 小时 SST 预报中实现了  $MAE = 0.29\text{ }^{\circ}\text{C}$  的结果, 预测曲线与观测值高度契合, 进一步验证了深度学习在时间序列 SST 预测领域的潜力与前景。

总的来说,在 SST 预测问题中,时间序列数据是深度学习提取特征的一种重要数据形式,通过深度学习模型的不断优化和完善,深度学习在提高 SST 预测准确性和稳定性方面具有非常大的潜力和前景。

### 2.5.2 融合时空特征的区域海温场预测模型

在早期的研究中,深度学习方法主要集中于单点或区域的纯时间序列预测,然而,纯时间序列方法存在明显局限性:1) 仅依赖时间维度信息容易忽略 SST 在大尺度环流和区域动力过程中的空间联系;2) SST 演变往往受邻近区域热量输送、气候模态和多尺度相互作用的影响,这些复杂过程难以通过一维时序建模充分捕捉。因此,随着研究的深入,研究者们逐渐意识到必须在模型中同时引入时序与空间特征,以更完整地刻画 SST 的变化机理,并推动了从单一时序预测向时空预测的转变。

自 2017 年以来,研究者逐步将循环神经网络扩展到能够刻画空间特征的卷积结构,例如 Yang 等人 (2018) 提出的组合全连接卷积长短期记忆网络

(combined fully connected convolutional LSTM, CFCC-LSTM) 和 Xiao 等人 (2019a) 提出的卷积 LSTM 模型,在中国东海岸和渤海区域实现了有效预测。贺琪等人 (2020, 2022b) 进一步尝试模型融合与改进,如将 LSTM 与 AdaBoost (adaptive boosting) 结合,以及在卷积神经网络 (convolutional neural network, CNN) 中引入注意力机制构建 CA-ConvLSTM (channel attention convolutional long short-term memory) 和 CRA-ConvLSTM (convolutional LSTM with residual spatio-temporal attention) 模型,均有效提升了预测的准确性与稳定性。与此同时,研究者还利用 CNN 直接提取 SST 的时空特征。例如, Han 等人 (2019) 应用卷积网络于厄尔尼诺预测并提出全季节卷积模型 (all-season convolutional neural network, A\_CNN), 李孝涌等人 (2022) 基于深度 CNN 结合 CMIP6 模式与 GODAS 资料进行厄尔尼诺预测。此外,还有诸多卷积与循环结构结合的探索,如 Xu 等人 (2020) 提出的区域卷积 LSTM (regional convolutional LSTM, RC-LSTM), 以及张雪薇和韩震 (2022) 构建的 ConvGRU 模型,这些方法均表明卷积与循环结合能够更好地刻画 SST 的时空相关性,从而输出更细致的预测结果。

然而, LSTM 和 CNN 网络仍存在超长时间序列建模和远距依赖捕捉难的问题。研究者逐渐引入模态分解、注意力与多尺度机制以增强模型性能。例如, Xu 等人 (2020) 利用变分模态分解 (variational mode decomposition, VMD) 与记忆网络 (memory-in-memory, MIM) 构建预测模型,在南海获得精细的温度场结果;在一种结合残差时空注意力机制的海面温度预测方法 (CRA-ConvLSTM) (贺琪 等, 2022b) 中 (其模型框架如图 4 所示), 特定区域的 SST 变化被组织成二维时间序列,首先利用卷积层编码局部特征,随后,在时间维度上引入残差时间注意力模块,以自适应方式为不同时刻的特征分配权重,提取关键的长期依赖信息;在空间维度上设计残差空间注意力模块,为不同位置的特征赋予差异化权重,突出对预测最相关的区域信号。最后,经过 ConvLSTM 单元对加权特征进行时序建模,输出未来多步 SST 预测结果。CRA-ConvLSTM 在 1 天与 5 天预测中的 RMSE 分别达到  $0.19\text{ }^{\circ}\text{C}$  和  $0.37\text{ }^{\circ}\text{C}$ , 相关系数  $> 98\%$ , 显著优于 SVR、LSTM、ConvLSTM、CNN-ConvLSTM 等方法,验证了残差时空注意力机制在提升区域型




图4 CRA-ConvLSTM模型流程图(贺琪等,2022b)

Fig. 4 Flowchart of the CRA-ConvLSTM model(He et al., 2022b)

SST预测精度与鲁棒性方面的有效性。

近年来,新的网络范式也被引入 SST 预测,如 Liu 等人(2025)提出结合深度置信网络(deep belief network, DBN)与支持向量回归(SVR)的混合方法并引入时空二次校准(spatiotemporal secondary calibration, SSC),在印度洋与北太平洋 60 日预测实验中保持了 RMSE 低于  $0.9^{\circ}\text{C}$  的稳定表现。此外, Sun 等人(2023)提出的 CNN 结合余弦距离损失(convolutional neural network with cosine distance loss, CNN-CD)能够提前一年有效预测赤道太平洋 SSTA 的经向分布,并在 ENSO 预测中显著优于动力模型。

为量化上述不同建模方法在 SST 时空预测中的性能差异,同时结合观测技术立体化与人工智能技术的迭代趋势(如引入 ViT(vision Transformer)等新型网络范式,以捕捉更精细的特征关联),Yuan 等人(2023)在太平洋区域( $5^{\circ}\text{S}$ — $5^{\circ}\text{N}$ ,  $170^{\circ}\text{W}$ — $120^{\circ}\text{W}$ ),以 7 天历史长度为输入,对 CNN、CNN-ConvLSTM、ViT 及融合物理信息的 PINN(physics-informed neural network)系列模型开展了 1 天、5 天、10 天多时长预测实验,结果如表 6 所示。各模型的平均绝对误差(MAE)、均方误差(mean squared error, MSE)和相关系数  $r$  表现可总结为:纯 CNN 模型随预测天数增加误差呈波动上升、相关性略有下降;融合 ConvLSTM 的 CNN-ConvLSTM 模型因时空特征融合,各时长下的 MAE、MSE 显著低于纯 CNN 且  $r$  明显更高;

ViT 性能介于 CNN 与 CNN-ConvLSTM 之间,体现了自注意力机制在长程依赖捕捉上的潜力。而引入物理信息的 PINN 系列模型(PINN-CNN、PINN-CNN-ConvLSTM、PINN-ViT)整体表现最优,1 天预测时 MAE 低至  $0.284\sim 0.286^{\circ}\text{C}$ ,  $r$  接近  $0.975\sim 0.976$ ,且在 5 天、10 天预测中仍保持低误差与高相关性,其中, PINN-ViT、PINN-CNN-ConvLSTM 在 MSE 上更具优势,说明物理信息与先进网络结构(ViT、ConvLSTM)的融合进一步强化了对 SST 复杂时空演变过程的刻画。整体而言,所有模型随预测天数增加, MAE、MSE 呈上升趋势,  $r$  呈下降趋势,但 PINN 系列模型在长时序预测中仍展现出较强鲁棒性,这与其融合物理约束以捕捉 SST 演变机理的特性密切相关。

### 2.5.3 数据驱动海洋大模型在 SST 预测中的实践

随着数据驱动技术在海洋预测领域的应用深化,传统深度学习模型虽然在计算效率上优于物理数值模型,但常因未能充分适配海洋独特动力特性(如中尺度涡旋变率、海气相互作用),在海表面温度(SST)等关键变量的精细化预测中精度受限,亟需能融合海洋领域知识的专用大模型。例如,国内已涌现一批融合海洋领域知识的专用大模型:中国海洋大学、崂山实验室联合中国科学技术大学等研发的问海(WenHai)(Cui 等, 2025),以全球  $1/12^{\circ}$  ( $\approx 9\text{ km}$ ) 涡分辨率海洋数据实现 10 天预报,覆盖 SST、温盐剖面等要素,通过 Swin-Transformer 骨干架构嵌入块体

表6 数据驱动模型在太平洋区域的模型预测性能  
Table 6 Prediction performance of data-driven models in the Pacific Ocean region

| 模型                | 1天        |          |       | 5天        |          |       | 10天       |          |       |
|-------------------|-----------|----------|-------|-----------|----------|-------|-----------|----------|-------|
|                   | RMSE/(°C) | MAE/(°C) | ACC   | RMSE/(°C) | MAE/(°C) | ACC   | RMSE/(°C) | MAE/(°C) | ACC   |
| CNN               | 0.692     | 0.784    | 0.809 | 0.735     | 0.897    | 0.766 | 0.728     | 0.880    | 0.760 |
| CNN-ConvLSTM      | 0.351     | 0.202    | 0.958 | 0.444     | 0.321    | 0.935 | 0.445     | 0.337    | 0.928 |
| ViT               | 0.596     | 0.571    | 0.868 | 0.693     | 0.762    | 0.850 | 0.690     | 0.742    | 0.867 |
| PINN-CNN          | 0.284     | 0.297    | 0.975 | 0.360     | 0.245    | 0.945 | 0.459     | 0.409    | 0.907 |
| PINN-CNN-ConvLSTM | 0.286     | 0.137    | 0.975 | 0.361     | 0.247    | 0.945 | 0.460     | 0.410    | 0.900 |
| PINN-ViT          | 0.285     | 0.134    | 0.976 | 0.362     | 0.244    | 0.946 | 0.460     | 0.407    | 0.901 |

公式海气通量模块,搭配“预训—微调”两阶段策略,10天SST预测RMSE较GLO12v4降8.94%,CRPS(continuous ranked probability score)较同类AI模型降24.5%~31.4%,且涡旋区SST变率保留能力突出;中国科学院海洋研究所的琅琊1.0(Yang等,2024)则以相同1/12°分辨率实现7天温盐流预报,引入LLM(large language model)时间嵌入模块并设计温跃层自适应损失函数,有效改善中尺度涡旋区SST梯度预测,避免SST过度平滑。

在高分辨率维度,青岛海洋科技中心的羲和(Wang等,2024)模型达到1/36°(≈3km)超高分辨率,可实现5天“海—气—浪”全要素预报,能精准捕捉近岸上升流冷中心、河口暖舌等SST小尺度特征,5天近岸SST预报RMSE较1/12°模型降12%~18%。

聚焦跨尺度协同的伏羲(Huang等,2025)模型,构建“30km大气+0.25°海洋”架构实现15天海浪、风暴潮预报,其海气模块深度联动,可精准预测风暴潮中大气强风对SST的冷却效应,台风过境时SST降温幅度预测误差较非耦合模型缩小25%以上;另有中国海洋大学与崂山实验室合作的AI-GOMS(AI-driven global ocean modeling system)(Xiong等,2023),以1/12°分辨率开展7天温盐流预报,采用Transformer非对称架构与傅里叶神经算子(adaptive Fourier neural operator, AFNO)注意力机制,通过“骨干—下游”微调范式,使黑潮延伸体等SST强梯度区域的7天预报精度较通用模型提升10%~15%。这些模型通过差异化技术路径,共同推动SST预测从通用拟合向海洋领域知识深度适配跨越。

与传统深度学习模型相比,面向海洋业务的大

模型正在完成从局部卷积/循环的单尺度拟合器向多变量、多尺度、跨分辨率的基础模型的范式跃迁:它们借助分层Transformer与频谱算子(如Swin-Transformer、AFNO)对全球海洋场进行时空token化表示,结合长时序记忆与跨变量多任务解码头,在1/12°~1/36°分辨率下依然能够较好保持涡旋、锋面等细尺度能谱和结构信息(Cui等,2025;Wang等,2024;Xiong等,2023)。这种架构升级并非孤立发生,而是与训练目标中的物理一致性共同驱动:模型在训练—推理链路中显式注入海气通量块体公式、混合层热收支、地形与海陆掩膜边界条件、稳定性/光滑度正则等约束,或采用物理残差、能量守恒损失与同化样式的限制,从而显著降低物理不一致与漂移风险,并提升对极端过程的可预报性(Huang等,2025;Yang等,2024;de Bézenac等,2019;Yuan等,2023)。在此基础上,学习范式也由区域/任务特定的从头监督训练转为预训练—微调的跨域迁移:通过在多源长时序上开展自监督/多任务预训练,海洋大模型能够以少样本完成跨海盆、跨分辨率、跨提前期与跨要素的快速适配,在基于CRPS与可靠性曲线等指标的概率性检验中,其性能普遍优于传统数值模式,体现出对分布外情景与极端事件的更强稳健性(Cui等,2025)。因此,海洋大模型并非对传统方法的简单替代,而是以基础模型、物理约束和迁移学习的新范式,弥补了传统模型在远距依赖、能谱保持与跨尺度泛化方面的短板,为SST短中期业务化预报与极端事件感知提供了更高的上限。

表7总结了部分国内外海洋气候大模型。

表 7 国内外相关海洋气候大模型  
Table 7 Domestic and international large-scale ocean-climate models

| 模型名称                              | 国家/机构                                                             | 分辨率/时效                          | 主要输出变量                   |
|-----------------------------------|-------------------------------------------------------------------|---------------------------------|--------------------------|
| 琅琊 1.0(Yang 等, 2024)              | 中国科学院海洋研究所                                                        | 1/12°(≈ 9 km)/7 天               | 温度、盐度、海流                 |
| 风乌(Chen 等, 2023)                  | 上海 AI Lab + 中国科学技术大学 + 上海交通大学 + 南京信息工程大学 + 中国科学院大气物理研究所 + 上海中心气象台 | 0.25°/10 天                      | SST、风场、气压                |
| 伏羲(Huang 等, 2025)                 | 复旦大学 + 上海人工智能研究院 + 中国气象局                                          | 30 km 大气 + 0.25°海洋/15 天         | 海浪、风暴潮                   |
| 羲和(Wang 等, 2024)                  | 国防科技大学 + 复旦大学 + 中南大学                                              | 1/36°(≈ 3 km)/5 天               | 海—气—浪全要素                 |
| 问海 WenHai(Cui 等, 2025)            | 中国海洋大学 + 崂山实验室 + 中国科学技术大学等                                        | 全球 1/12°(≈ 9 km)/最多 10 天        | SST、温盐剖面、SSH、海流(0~643 m) |
| AI-GOMS(Xiong 等, 2023)            | 清华大学 + 中国科学技术大学                                                   | 1/12°/7 天                       | 温盐流                      |
| IFS-NEMO(DestinE)(Rackow 等, 2025) | ECMWF 联盟                                                          | 9 km 大气 + 1/12°海洋/1950—2050 年情景 | 全要素极端事件“故事线”             |
| SPEAR-Ocean(Delworth 等, 2020)     | NOAA GFDL                                                         | 0.25°~1/12°/7 个月                | SST、热含量、海流               |
| ICON-Ocean(Korn 等, 2022)          | 德—奥—瑞等多机构                                                         | 5 km/季节                         | 海—冰—气同步                  |
| FourCastNet-Ocean(Pathak 等, 2022) | NVIDIA + LLNL                                                     | 0.25°/10 天                      | SST、SSH                  |

3 海表温预测模型的应用

海表面温度(SST)预测模型的应用范畴已不再局限于单一的温度数值预测本身,其功能边界正持续拓展,进一步延伸至海洋热浪的特征分析与风险评估(厄尔尼诺—南方涛动)(ENSO)现象的机理研究与趋势研判,以及海洋锋面的精细化识别与动态追踪等海洋科学关键领域,成为多维度海洋过程研究的重要技术支撑。

在大尺度气候模态与 ENSO 应用方面, SST 预测为异常气候研究提供了关键支撑, Mu 等人(2021)提出的 ENSO-ASC (ENSO deep learning forecast model with a multivariate air-sea coupler)模型结合图卷积和注意力机制,将多变量海—气要素与 SST 融合建模,显著提升了 ENSO 事件的可预测性,展示了深度学习在复杂气候动力学建模中的潜力。许壮壮(2024)提出以信息散度为损失函数的二维协同聚类算法,突破传统聚类单维度分析局限,可同步捕捉 SST 时间与空间关联性。

值得注意的是,海洋热浪(marine heatwave, MHW)预测已经成为 SST 预测中最具代表性的应用之一。由于 MHW 对生态和经济具有严重影响,其专项预测尤为关键。例如, Qiao 等人(2025)通过多元经验正交函数(multivariate empirical orthogonal function, MV-EOF)分析,将西北太平洋夏季 MHW 划分为两种主要模式:厄尔尼诺事件后的低纬度广泛升温型和厄尔尼诺发展期的东北—西南三角型,并发现这两类模式分别与太平洋—日本遥相关、热带—北印度洋 SST 梯度及北太平洋涛动密切相关。他们进一步构建基于物理约束的实证预测模型,并利用 1982—2022 年的数据开展交叉验证。结果表明,这两类模式均具有较高的可预测性(PC1(principal component 1)相关系数 0.65, RMSE 0.77 °C; PC2(principal component 2)相关系数 0.55, RMSE 0.84 °C),能够较好地捕捉 MHW 的峰值强度和空间分布,说明 MHW 预测正在从区域走向大尺度的模式化和机制化,其成果为未来预警系统的建立提供了重要参考。贺琪等人(2022a)提出基于限定 motif 的关联规则挖掘方法,针对海表面温度(SST)时间

序列变化的细微规律进行了结构化建模。该方法利用 STAMP (scalable time series anytime matrix profile) 算法实现高效的 motif 提取,并基于最小描述长度 (minimum description length, MDL) 评分策略对候选序列进行分割与评价,从而构建出能够表达热浪发生前后 SST 变化趋势的关联规则。结果表明,此方法能够捕捉中国近海 MHW 事件的升降温趋势,并实现约 78% 的预测准确率。

除此之外, SST 预测在海洋生态与锋面研究中同样承担着重要作用。小尺度层面上, SST 结合深度学习方法 (如 DCENet (dense contextual ensemble network)、Inception) 能够实现海洋锋面的精准识别与演变趋势分类,而基于贝叶斯框架与时序特征的 BFD-MSA (Bayesian framework with dynamic time warping and multi-scale attention) 方法则有效降低了过检率并提升跟踪连续性 (He 等, 2024; Yang 等, 2022; Wang 等, 2025)。徐慧芳等人 (2021) 针对海洋锋弱边缘性导致传统梯度阈值及边缘检测方法精度较低的问题,提出了一种改进的 Mask R-CNN 自动检测模型,实现对海洋锋像素级的高精度识别与定位。

在大尺度层面,长期 SST 序列与 CMIP6 模式资料的联合应用,不仅绘制了全球大洋生态系统的持续锋面图谱,还揭示了在气候变暖背景下 SST 变化与叶绿素浓度的协同演化关系 (Xing 等, 2024; Yang 等, 2023),为跨尺度海洋生态过程分析提供了关键支撑。

## 4 海表温预测模型中的挑战

随着数据驱动方法在 SST 预测中的广泛应用,研究范式正经历从基于统计规律的传统模型到机器学习与深度学习模型的持续演进。尽管这些方法在预测精度、时空分辨率以及对非线性特征的刻画上取得了显著进展,但在模型可解释性、评估体系构建以及数据尺度适配等方面仍存在显著挑战。具体而言,这些挑战主要体现在两个层面:1) 模型机理可解释性不足。深度学习等高复杂度模型在强大性能的背后,其内部特征提取与决策过程仍难以直观解析,导致预测结果缺乏物理可理解性,削弱了模型在科学研究和业务化应用中的可信度,而面对这个挑战的解决方案目前分为两种,一是通过将数据驱动与物理机理相结合;二是通过模型自身的可解释性进

行解释。2) 多源数据尺度适配问题突出。当前 SST 数据来源复杂,包括浮标观测、卫星遥感及再分析产品,不同数据集在空间、时间及垂向尺度上的不一致性增加了数据融合与插值处理的难度,从而影响模型的泛化能力与预测可靠性。

### 4.1 数据驱动与物理机理相结合

一种重要的研究思路是将物理知识与数据驱动方法进行有机结合,形成物理信息机器学习 (physics-informed machine learning, PIML) 框架下的混合模型。其基本理念是利用数值模式或物理约束作为先验条件,引导深度学习模型的训练与预测。例如,将海洋环流方程、热盐平衡方程、热通量守恒关系或潮汐动力学过程嵌入神经网络框架,使模型不仅能够学习数据中的统计规律,同时也遵循海洋物理过程的基本机理。由此,预测结果不仅在数值上更加精确,也具备了物理学意义上的解释性。

物理信息神经网络 (PINN) 是上述思路的典型代表 (Cai 等, 2021)。PINN 通过构建包含数据损失和物理残差损失的复合损失函数  $L_{\text{total}} = \alpha \cdot L_{\text{data}} + b \cdot L_{\text{physics}}$  ( $L_{\text{total}}$ : 复合损失、 $L_{\text{data}}$ : 数据损失、 $L_{\text{physics}}$ : 物理损失), 将物理定律直接嵌入神经网络的训练过程。这种设计确保模型输出既符合观测数据,又满足基本的物理规律,在数据稀缺或质量较低的情况下尤为有效。物理约束能够增强数据的信息含量,帮助模型捕捉更合理的解,从而在提高预测精度的同时显著提升模型的可解释性和鲁棒性。在海洋领域尤其是海表面温度 (SST) 预测中, PINN 的范式已有具体落地应用,例如 Yuan 等人 (2023) 提出的时空 PDE 引导神经网络 (spatiotemporal partial differential equation network, STPDE-Net), 该模型通过引入混合层热预算方程 (描述 SST 变化的核心热力学方程), 将其作为可调参数融入 PINN 的复合损失函数,而非固定方程项,在最小化预测值与观测值误差的同时完成方程参数化,最终能够解释日尺度 SST 变化背后的热力学过程。最新研究显示, PINN 与图神经网络 (graph neural network, GNN) 或长短期记忆网络 (LSTM) 的结合,进一步提升了对复杂海洋动力过程的模拟能力。

除了建立复合损失函数这种方法外,还可通过架构设计或功能模块整合,将物理规律显式嵌入模型结构,实现物理知识与数据驱动的深度融合。例如, de Bézénac 等人 (2019) 基于描述流体输运的平

流扩散方程,设计了可模拟平流—扩散传输过程的翘曲方案(warping scheme),并将其与卷积神经网络(CNN)结合,通过CNN估计SST运动场、翘曲方案维持空间物理一致性,最终在预测SST演变时兼顾物理合理性与数值精度;此外,Meng等人(2024)以生成式对抗网络(generative adversarial network, GAN)为框架,先从HYCOM(hybrid coordinate ocean model)海洋数值模型数据中学习海表与次表层温度梯度关联等基础物理规律,再结合历史观测数据提取隐含物理特征并嵌入网络,有效提升了SST时空变化预测的合理性;再者,Shi等人(2024)提出的PANN(physics-guided attention-based neural network)模型,通过多模块协同整合物理机制:以ConvLSTM结构捕捉SST的时空动态相关性,融合数据同化方法模拟流体中的动力学传输过程,同时借助注意力机制聚焦关键物理区域信号,最终在欧洲大陆架SST短期预测实验中显著降低误差。研究结果表明,这些将物理知识与数据驱动方法结合的思路能够在保持高精度的同时揭示SST变化的主要驱动力,使预测结果更具科学合理性。

总体而言,物理与数据驱动的结合不仅是一种提高预测性能的技术路径,更是解决数据驱动模型“黑箱问题”的有效途径。通过在模型中显式引入物理约束,研究人员能够在数值输出之外,进一步解释预测背后的物理机制,从而增强模型的透明度、可信度和科学价值。

#### 4.2 数据驱动的海表温模型的可解释性

与数值驱动模型在结构上天然具备物理透明性不同,数据驱动模型在海表温预测中因其强大的非线性建模能力与时空特征提取能力而得到广泛采用。其中,海表温异常升高事件(持续大于5天且超过当地季节气候阈值的90%)的预测模型,其可解释性对理解气候响应机制至关重要。然而,深度神经网络结构复杂、推理路径不可见,导致其缺乏自然的可解释性,限制了在海表温相关科学研究与政策支持中的应用推广。近年来,研究者围绕提升数据驱动模型可解释性的目标,主要沿两条技术路径展开:一是设计具备内在可解释结构的模型;二是结合事后可解释性方法对已有模型的海表温预测机制进行反向分析。

在内在可解释性结构设计方面,KAN(Kolmogorov-Arnold network)为深度预测模型提供

了新的理论框架。KAN通过将多元函数分解为单变量函数的叠加,实现了模型计算过程的数学可解释性。在近期研究中,Shu等人(2025)将KAN引入多变量时间序列预测任务,发展为混合专家(mixture-of-experts, MOE)结构的MMK(multi-layer mixture-of-KAN)模型。该模型通过门控网络动态分配变量至不同KAN专家,实现了结构可解释性与预测性能的兼顾,在多个气候与能量相关数据集上表现优异,实现了高效的结构表达与可解析的推理路径。

类似地,Gao等人(2025)在太阳辐射预测中使用KAN模型,证实其在保持性能稳定的同时,能够量化网络计算的每个步骤,从而增强整体可解释性。这些特性使KAN在处理SST预测中的高维输入和强非线性耦合问题时具有显著优势。

另一方面,事后可解释性方法为已训练的深度学习模型提供了“打开黑箱”的技术手段。例如,He等人(2022)针对海草分布预测问题引入集成学习模型,结合SHAP(shapley additive explanations)和PDP(partial dependence plots)分析环境变量在不同区域的贡献差异,为生态响应机制提供定量解释。这类方法不仅能识别关键特征,还能揭示多变量交互作用对模型输出的影响,为实际生态和气候决策提供参考依据。在更复杂的海洋气候系统中,梯度类可解释方法同样展现出潜力。以ENSO驱动的河流径流预测为例,Liu等人(2023)使用基于显著图的可解释深度学习方法(explainable deep learning, XDL),从全球SST场中提取与河流响应相关的关键区域和依赖结构。结果表明,该方法能够识别超越传统ENSO指数的SST信息,挖掘更多潜在驱动区域,并结合复杂网络构建方法,增强对全球遥相关结构的理解。这一策略迁移至海洋热浪预测模型中,可帮助识别热浪发生的遥相关气候背景(如极地—中纬度温度梯度变化)与区域风险源(如北极海冰消融区)。

数据驱动模型在海表温预测中通过引入可解释性机制,正逐步克服“黑箱”结构带来的信任壁垒与科学解释瓶颈。本节中,部分工作虽然未直接面向海表温预测任务(如太阳辐射预测、海草分布预测),但其采用的数据驱动模型在处理高维输入、强非线性耦合以及观测数据不均衡等特征上,与海表温预测任务高度相似。这些研究中关于可解释性方法的

设计思路与实验策略,为构建可解释的海表温预测模型提供了重要借鉴。

#### 4.3 大模型下的可解释性解决方案

可解释性亦可借力大模型自身特性获得系统性提升:其超大参数空间与多模态预训练天然形成低维潜变量,这些潜变量经稀疏回归或注意力探针即可与 ENSO、PDO (Pacific decadal oscillation) 以及中尺度涡等已知物理模态建立高对应关系,从而将原本黑箱的映射链路转化为可追踪的物理指标;同时,大模型通过概率输出或深度集成直接给出预测方差,实现不确定性即解释。由此,模型在输出 SST 的同时,也提供了何处不可信以及为何不可信的显式指引,使可解释性从传统的事后可视化转变为事前和事中即可感知的内在属性。

#### 4.4 海洋数据尺度问题

在当前海表面温度 (SST) 预测研究中,模型性能的优化正围绕空间维度的立体拓展、时间维度的能力延伸与数据输入的质量优化三大核心方向推进,三者相互支撑、协同作用,共同构成突破现有技术瓶颈的关键路径。

海洋作为典型的多尺度耦合系统,其热力过程兼具水平与垂向的复杂关联性:水平维度上,经纬度间的海流输运、海气交换遥相关效应主导区域尺度 SST 分布;垂向维度上,表层与次表层存在显著温度梯度,二者的能量耦合直接调控 SST 的动态演变。然而,当前多数 SST 预测模型仍局限于二维平面尺度,难以完整刻画海洋热储能量的垂向分布特征及内在演变机制。因此,未来需在现有二维预测基础上,进一步拓展至三维次表层海温结构的时空预测,通过整合卫星遥感(表层 SST)、浮标观测(垂向温度剖面)与再分析资料(三维温盐场),构建覆盖表层与次表层的多源数据输入体系,开展跨尺度建模,以更全面揭示表层与次表层的能量交互规律。这一拓展不仅能深化对海洋热力过程的物理认知,更能增强模型对水下关键动态信号(如温跃层波动)的捕捉能力,进而改善对短周期海洋过程(如中尺度涡旋)、局地极端事件(如海洋热浪)的预测稳定性与普适性。

与空间维度的立体建模需求相呼应,SST 预测在时间尺度上存在显著的能力偏向性问题:当前数据驱动型模型在短期尺度(数天至数月)表现突出,可有效捕捉 SST 的短期波动(如周内温度起伏)与季节性特征(如夏季升温、冬季降温),但在支撑气候变

化趋势研判的中长期尺度(年际至年代际)预测上存在明显短板,即难以精准刻画厄尔尼诺—南方涛动 (ENSO) 的年际循环、全球变暖背景下的长期温变率等慢变信号。这一瓶颈的突破依赖于长序列建模技术的创新:例如基于 Transformer 结构的 Informer、Autoformer 等新型时序深度模型,可通过优化的时间注意力机制,有效捕捉大规模 SST 序列中的远程依赖关系与周期性规律,为突破“短期预测瓶颈”提供核心技术支撑。未来需进一步结合气候系统的物理周期性(如季节循环、太阳辐射年变化),优化模型对慢变信号的提取能力,持续提升中长期 SST 变化趋势的预判精度与可靠性。

无论是空间维度的三维次表层海温建模,还是时间维度的中长期预测,其实现均高度依赖高质量的输入数据,而多源数据的异质性已成为制约模型训练效率与泛化能力的关键瓶颈。当前 SST 预测的数据源涵盖 4 类核心类型:浮标观测(时间频率高但空间覆盖有限)、卫星遥感(空间覆盖连续但易受云层遮挡)、再分析数据(提供三维时空分布但受模式假设与插值误差影响)和模式模拟结果(支持情景预测但存在系统偏差)。这些数据集在空间分辨率(如  $0.1^\circ \times 0.1^\circ$  遥感产品 vs  $0.25^\circ \times 0.25^\circ$  再分析数据)、时间分辨率(小时级浮标数据 vs 日级遥感数据)与观测深度(表层卫星数据 vs 垂向浮标剖面)上差异显著,直接导致模型输入的尺度不一致,引发特征分布失配 (feature misalignment) 问题,削弱模型稳定性。针对这类问题,相关研究(聂婕等,2022)强调了跨模态关联建模的重要性,通过建立统一的特征表示,可以更有效地挖掘各物理量间的时空耦合关系,从而提高复杂海况下 SST 预测的稳健性。

为解决多源数据异质性问题,需按预处理阶段—建模阶段分步骤优化,明确各阶段技术手段的核心目标,避免概念混淆:在预处理阶段,核心任务是通过多源数据尺度适配与层次化数据融合消除输入异质性:一方面采用降采样、插值(如克里金插值)、重网格 (regriding) 等手段,将不同尺度数据统一至目标分辨率(如统一为  $0.25^\circ \times 0.25^\circ$  空间分辨率、日级时间分辨率),解决数据格式不兼容问题;另一方面通过层次化融合(如按数据可靠性赋予权重:浮标观测 > 卫星遥感 > 再分析数据),整合多源信息以降低单一数据源的误差影响。需要注意的是,传统预处理手段存在局限即降采样易丢失近岸小尺度细节(如河

口暖舌),插值可能改变观测场的能量谱结构,对短周期过程与极端事件的预测精度存在潜在影响。

在建模阶段,核心任务是通过多分辨率特征学习(multi-resolution feature learning)充分挖掘统一尺度数据中的多层级信息:无需依赖预处理的额外操作,通过多尺度卷积(浅层捕捉局部特征如近岸温度梯度、深层捕捉大尺度特征如黑潮延伸体)、模态分解(如变分模态分解VMD拆分不同频率信号)等技术,自动提取小尺度与大尺度的关联特征,弥补预处理阶段的信息损失。同时,需在建模中引入物理一致性约束(如热量守恒、能量守恒定律),在融合多尺度特征时减少偏差,确保模型输出符合海洋热力过程的基本物理规律。

此外,地球系统气候大模型(large foundation model for Earth system)的兴起为多源数据质量优化提供了新路径:其通过多模态预训练,融合气象、海洋和遥感等数据,依托超大参数规模实现跨要素统一建模,这样既能提升预处理阶段的多源数据尺度适配效率(自动匹配不同数据源的时空尺度),又能强化建模阶段的多分辨率特征提取能力(内置跨尺度注意力机制),为空间三维ST建模与时间中长期预测提供更高质量的数据支撑,推动SST预测向更精准、更全面和更具物理一致性的方向发展。

## 5 结 语

本综述围绕海表面温度(SST)精准预测这一海洋天气与气候预报、渔业资源研判以及海洋生态保护等领域的核心需求,对当前SST预测方法展开全面梳理与深度分析,明确了“数值模式预测”与“数据驱动预测”两大技术路径的定位,重点聚焦数据驱动方法的研究进展与应用价值,形成了系统性的综述框架与结论。

首先,本综述厘清了两类SST预测方法的核心特征与发展脉络:数值模式方法以海洋动力学、热力学方程为基础,通过求解偏微分方程实现预测,具备明确的物理机制解释力与较高预报可信度,但高度依赖初始/边界条件且计算资源消耗大;数据驱动方法则以多源观测数据为核心,通过统计建模或机器学习算法自动学习SST时空规律,无需大量先验物理知识即可捕捉复杂的非线性关系,在中短期(1~30天)预报与区域尺度研究中展现出灵活性与高效

性,且随着“空—天—地—海”立体化监测体系的完善,其数据支撑能力与模型多样性持续提升。

其次,本综述针对数据驱动方法展开分层剖析:从数据基础来看,系统归纳了站点观测(如ARGO浮标)、卫星遥感(如NOAA-OISST、CMEMS高分辨率产品)、再分析数据(如ECMWF-ERA5)、模式数据(如CMIP6)4类核心数据源的时空分辨率、可靠性与适用场景,明确遥感数据因覆盖广、时效性强成为当前主流输入,而再分析数据与模式数据则为长期趋势研究提供关键支撑;从模型演进来看,按技术成熟度依次梳理了4类核心模型——统计模型(典型相关分析CCA、时间序列分析TSA的AR/ARMA/ARIMA等,早期在ENSO、SSTA预测中发挥重要作用)、传统机器学习模型(支持向量机SVM/SVR、混合模型如CEEMD-SVM,擅长刻画非线性过程)、浅层神经网络模型(单要素驱动的ANN/NAR、多要素协同的MLP-BP/ANFIS,挖掘海洋要素关联性)和深度学习模型(时序预测的LSTM/GRU/TCN、时空融合的ConvLSTM/3DCNN、海洋大模型如WenHai/风乌,突破复杂时空特征捕捉瓶颈),并通过典型案例(如CRA-ConvLSTM模型在区域SST预测中RMSE低至0.19℃)验证了各类方法的优势与局限性。

再者,本综述拓展了SST预测的应用边界,指出数据驱动模型已从单纯的SST数值预测,延伸至海洋热浪(MHW)特征识别(如基于限定motif关联规则实现78%预测准确率)、厄尔尼诺—南方涛动(ENSO)机理研判(如ENSO-ASC模型提升事件可预测性)、海洋锋面动态追踪(如DCENet实现多类锋面精准检测)等关键领域,成为多维度海洋过程研究的技术支撑。

最后,本综述直面当前研究挑战并指明未来方向:针对模型“黑箱”问题,提出物理信息机器学习(PIML)框架(如PINN嵌入海洋物理方程)、内在可解释结构(如KAN网络)和事后解释方法(如SHAP/PDP分析)三大解决方案,尤其强调海洋大模型通过潜变量与物理模态关联实现“不确定性即解释”的创新路径;针对多源数据尺度适配问题,指出需发展多分辨率特征学习与物理一致性约束,破解数据异质性(如浮标高时效vs遥感广覆盖)导致的“特征分布失配”;同时明确,未来SST预测研究将向“物理机理—数据驱动深度融合”、“多源数据尺度协同”“模型可解释性与精度并重”三大方向突破,而数据驱动

方法作为提升SST中短期预测精度、适配区域尺度研究的核心路径,其深化应用将为海洋科学与气候研究提供更高效的技术支撑。

## 参考文献 (References)

- Adcroft A J, Hill C N and Marshall J C. 1999. A new treatment of the coriolis terms in C-grid models at both high and low resolutions. *Monthly Weather Review*, 127(8): 1928-1936 [DOI: 10.1175/1520-0493(1999)127<1928:ANTOTC>2.0.CO;2]
- Aguilar-Martinez S and Hsieh W W. 2009. Forecasts of tropical pacific sea surface temperatures by neural networks and support vector regression. *International Journal of Oceanography*, 2009: #167239 [DOI: 10.1155/2009/167239]
- Ahmad H. 2019. Machine learning applications in oceanography. *Aquatic Research*, 2(3): 161-169 [DOI: 10.3153/AR19014]
- Ali M M, Swain D and Weller R A. 2004. Estimation of ocean subsurface thermal structure from surface parameters: a neural network approach. *Geophysical Research Letters*, 31(20): #L20308 [DOI: 10.1029/2004GL021192]
- Aparna S G, D'Souza S and Arjun N B. 2018. Prediction of daily sea surface temperature using artificial neural networks. *International Journal of Remote Sensing*, 39(12): 4214-4231 [DOI: 10.1080/01431161.2018.1454623]
- Awan J A and Bae D H. 2016. Drought prediction over the East Asian monsoon region using the adaptive neuro-fuzzy inference system ali-matond the global sea surface temperature anomalies. *International Journal of Clogy*, 36(15): 4767-4777 [DOI: 10.1002/joc.4667]
- Barnett T P and Preisendorfer R. 1987. Origins and levels of monthly and seasonal forecast skill for United States surface air temperatures determined by canonical correlation analysis. *Monthly Weather Review*, 115(9): 1825-1850 [DOI: 10.1175/1520-0493(1987)115<1825:OALOMA>2.0.CO;2]
- Barnston A G and Ropelewski C F. 1992. Prediction of ENSO episodes using canonical correlation analysis. *Journal of Climate*, 5(11): 1316-1345 [DOI: 10.1175/1520-0442(1992)005<1316:POEEUC>2.0.CO;2]
- Barnston A G and Smith T M. 1996. Specification and prediction of global surface temperature and precipitation from global SST using CCA. *Journal of Climate*, 9(11): 2660-2697 [DOI: 10.1175/1520-0442(1996)009<2660:SAPOGS>2.0.CO;2]
- Barrows T T and Juggins S. 2005. Sea-surface temperatures around the Australian margin and Indian Ocean during the Last Glacial Maximum. *Quaternary Science Reviews*, 24(7/9): 1017-1047 [DOI: 10.1016/j.quascirev.2004.07.020]
- Bhaskaran P K, Rajesh Kumar R, Barman R and Muthalagu R. 2010. A new approach for deriving temperature and salinity fields in the Indian Ocean using artificial neural networks. *Journal of Marine Science and Technology*, 15(2): 160-175 [DOI: 10.1007/s00773-009-0081-2]
- Bleck R. 2002. An oceanic general circulation model framed in hybrid isopycnic-Cartesian coordinates. *Ocean Modelling*, 4(1): 55-88 [DOI: 10.1016/S1463-5003(01)00012-9]
- Bryan K. 1969. A numerical method for the study of the circulation of the world ocean. *Journal of Computational Physics*, 4(3): 347-376 [DOI: 10.1016/0021-9991(69)90004-7]
- Broni-Bedaiko C, Katsriku F A, Unemi T, Atsumi M, Abdulai J-D, Shinomiya N, et al. 2019. El Niño-Southern Oscillation forecasting using complex networks analysis of LSTM neural networks. *Artif Life Robotics* 24: 445-451 [DOI: 10.1007/s10015-019-00540-2]
- Casas C A Q. 2018. Fast ocean data assimilation and forecasting using a neural-network reduced-space regional ocean model of the north Brazil Current. London: Imperial College London
- Cai R S and Tan H J. 2024. Progress on the evolutionary characteristics and climatic causes for warming and marine heatwaves in the coastal China seas. *Chinese Journal of Atmospheric Sciences*, 48(1): 121-146 (蔡榕硕, 谭红建. 2024. 中国近海变暖 and 海洋热浪演变特征及气候成因研究进展. *大气科学*, 48(1): 121-146) [DOI: 10.3878/j.issn.1006-9895.2308.23313]
- Cai S Z, Mao Z P, Wang Z C, Yin M L and Karniadakis G E. 2021. Physics-informed neural networks (PINNs) for fluid mechanics: a review. *Acta Mechanica Sinica*, 37(12): 1727-1738 [DOI: 10.1007/s10409-021-01148-1]
- Chen C S, Liu H D and Beardsley R C. 2003. An unstructured grid, finite-volume, three-dimensional, primitive equations ocean model: application to coastal ocean and estuaries. *Journal of Atmospheric and Oceanic Technology*, 20(1): 159-186 [DOI: 10.1175/1520-0426(2003)020<0159:AUGFVT>2.0.CO;2]
- Chen K, Han T, Gong J C, Bai L, Ling F H, Luo J J, et al. 2023. FengWu: pushing the skillful global medium-range weather forecast beyond 10 days lead [EB/OL]. [2025-12-26]. <https://arxiv.org/pdf/2304.02948.pdf>
- Collins D C, Reason C J C and Tangang F. 2004. Predictability of Indian Ocean sea surface temperature using canonical correlation analysis. *Climate Dynamics*, 22(5): 481-497 [DOI: 10.1007/s00382-004-0390-4]
- Colman A W and Davey M K. 2003. Statistical prediction of global sea-surface temperature anomalies. *International Journal of Climatol-ogy*, 23(14): 1677-1697 [DOI: 10.1002/joc.956]
- Corchado J M and Aiken J. 2002. Hybrid artificial intelligence methods in oceanographic forecast models. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 32(4): 307-313 [DOI: 10.1109/TSMCC.2002.806072]
- Corchado J M and Fyfe C. 1999. Unsupervised neural method for temperature forecasting. *Artificial Intelligence in Engineering*, 13(4): 351-357 [DOI: 10.1016/S0954-1810(99)00007-2]
- Cui X S, Yang S L, Wu Y M, Dai Y and Fan X M. 2013. Structural

- detail-reserving method of sampling and reconstruction of remote sensing SST image. *Journal of Image and Graphics*, 18(11): 1497-1503 (崔雪森, 杨胜龙, 伍玉梅, 戴阳, 范秀梅. 2013. 保留结构细节的遥感海表温度图像的采样与重构. *中国图象图形学报*, 18(11): 1497-1503) [DOI: 10.11834/jig.20131114]
- Cui Y Z, Wu R H, Zhang X, Zhu Z Q, Liu B, Shi J, et al. 2025. Forecasting the eddying ocean with a deep neural network. *Nature Communications*, 16(1): #2268 [DOI: 10.1038/s41467-025-57389-2]
- de Bézenac E, Pajot A and Gallinari P. 2019. Deep learning for physical processes: incorporating prior scientific knowledge. *Journal of Statistical Mechanics: Theory and Experiment*, 2019(12): #124009 [DOI: 10.1088/1742-5468/ab3195]
- de Paz J F, Bajo J, González A, Rodríguez S and Corchado J M. 2012. Combining case-based reasoning systems and support vector regression to evaluate the atmosphere-ocean interaction. *Knowledge and Information Systems*, 30(1): 155-177 [DOI: 10.1007/s10115-010-0368-y]
- Delworth T L, Cooke W F, Adcroft A, Bushuk M, Chen J H, Dunne K A, et al. 2020. SPEAR: the next generation GFDL modeling system for seasonal to multidecadal prediction and projection. *Journal of Advances in Modeling Earth Systems*, 12(3): #e2019MS001895 [DOI: 10.1029/2019MS001895]
- Ezer T and Mellor G L. 2000. Sensitivity studies with the North Atlantic sigma coordinate Princeton ocean model. *Dynamics of Atmospheres and Oceans*, 32(3/4): 185-208 [DOI: 10.1016/S0377-0265(00)00047-6]
- Feng Y, Sun T Y and Li C. 2021. Study on long term sea surface temperature (SST) prediction based on temporal convolutional network (TCN) method//*Proceedings of the ACM Turing Award Celebration Conference — China*. Hefei, China: ACM: 28-32 [DOI: 10.1145/3472634.3472641]
- Foroozand H, Radić V and Weijs S. 2018. Application of entropy ensemble filter in neural network forecasts of tropical pacific sea surface temperatures. *Entropy*, 20(3): #207 [DOI: 10.3390/e20030207]
- Gao Y, Hu Z H, Chen W A, Liu M Z and Ruan Y J. 2025. A revolutionary neural network architecture with interpretability and flexibility based on Kolmogorov-Arnold for solar radiation and temperature forecasting. *Applied Energy*, 378: #124844 [DOI: 10.1016/j.apenergy.2024.124844]
- Garcia-Gorritz E and Garcia-Sanchez J. 2007. Prediction of sea surface temperatures in the western Mediterranean Sea by neural networks using satellite observations. *Geophysical Research Letters*, 34(11): #L11603 [DOI: 10.1029/2007GL029888]
- Gentemann C L. 2014. Three way validation of MODIS and AMSR-E sea surface temperatures. *Journal of Geophysical Research: Oceans*, 119(4): 2583-2598 [DOI: 10.1002/2013JC009716]
- Gholikandi G B, Beklar B I and Amouamouha M. 2018. The technical and economical assessment of the different electrode materials for pH recovery in the anaerobic baffled reactor on a lab-scale. *Desalination and Water Treatment*, 113: 18-27 [DOI: 10.5004/dwt.2018.22261]
- Griffies S M, Stouffer R J, Adcroft A J, Bryan K, Dixon K W, Hallberg R, et al. 2015. A historical introduction to MOM [EB/OL]. [2025-12-26]. [https://www.gfdl.noaa.gov/wp-content/uploads/files/model\\_development/ocean/mom\\_history\\_v15.09.05.pdf](https://www.gfdl.noaa.gov/wp-content/uploads/files/model_development/ocean/mom_history_v15.09.05.pdf)
- Guo Y Y, Ting M F, Wen Z P and Lee D E. 2017. Distinct patterns of tropical pacific SST anomaly and their impacts on North American climate. *Journal of Climate*, 30(14): 5221-5241 [DOI: 10.1175/JCLI-D-16-0488.1]
- Gurvan M, Bourdallé-Badie R, Bouttier P A, Bricaud C, Bruciaferri D, Calvert D, et al. 2017. NEMO ocean engine [EB/OL]. [2025-12-26]. <https://zenodo.org/record/3248739>
- Hall A D, Skalin J and Teräsvirta T. 2001. A nonlinear time series model of El Niño. *Environmental Modelling & Software*, 16(2): 139-146 [DOI: 10.1016/S1364-8152(00)00077-3]
- Han M X, Feng Y, Zhao X L, Sun C J, Hong F and Liu C. 2019. A convolutional neural network using surface data to predict subsurface temperatures in the Pacific Ocean. *IEEE Access*, 7: 172816-172829 [DOI: 10.1109/ACCESS.2019.2955957]
- Hayes A, Kucera M, Kallel N, Sbaffi L and Rohling E J. 2005. Glacial Mediterranean sea surface temperatures based on planktonic foraminiferal assemblages. *Quaternary Science Reviews*, 24(7/9): 999-1016 [DOI: 10.1016/j.quascirev.2004.02.018]
- He B H, Zhao Y H and Mao W. 2022. Explainable artificial intelligence reveals environmental constraints in seagrass distribution. *Ecological Indicators*, 144: #109523 [DOI: 10.1016/j.ecolind.2022.109523]
- He Q, Gong B, Song W, Du Y L, Zhao D F and Zhang W B. 2024. DCENet: a dense contextual ensemble network for multiclass ocean front detection. *IEEE Geoscience and Remote Sensing Letters*, 21: #1505305 [DOI: 10.1109/LGRS.2024.3477460]
- He Q, Hu Z Y, Xu H F, Song W and Du Y L. 2021. Sea surface temperature prediction method based on empirical mode decomposition-gated recurrent unit model. *Laser and Optoelectronics Progress*, 58(24): #2415005 (贺琪, 胡泽煜, 徐慧芳, 宋巍, 杜艳玲. 2021. 基于经验模态分解—门控循环模型的海表温度预测方法. *激光与光电子学进展*, 58(24): #2415005) [DOI: 10.3788/LOP202158.2415005]
- He Q, Kong L B, Zhao D F, Huang D M and Du Y L. 2022a. Discovery of marine heatwave event patterns based on restricted motif association rules. *Marine Environmental Science*, 41(6): 937-946 (贺琪, 孔令斌, 赵丹枫, 黄冬梅, 杜艳玲. 2022a. 基于限定 motif 关联规则的海洋热浪事件模式发现研究. *海洋环境科学*, 41(6): 937-946) [DOI: 10.13634/j.cnki.mes.2022.06.003]
- He Q, Li W L, Song W, Du Y L, Huang D M and Geng L J. 2022b. Sea surface temperature prediction algorithm combined with residual spatial-temporal attention mechanism. *Journal of Graphics*, 43(4):

- 677-684 (贺琪, 李汶龙, 宋巍, 杜艳玲, 黄冬梅, 耿立佳. 2022b. 结合残差时空注意力机制的海面温度预测算法. 图学学报, 43(4): 677-684) [DOI: 10.11996/JG.j.2095-302X.2022040677]
- He Q, Zha C, Song W, Hao Z Z, Du Y L, Liotta A, et al. 2020. Improved particle swarm optimization for sea surface temperature prediction. *Energies*, 13(6): #1369 [DOI: 10.3390/en13061369]
- He Q, Zha C, Song W, Qi F M, Hao Z Z and Huang D M. 2020. Sea surface temperature prediction algorithm based on STL model. *Marine Environmental Science*, 39(6): 918-925 (贺琪, 查铖, 宋巍, 戚福明, 郝增周, 黄冬梅. 2020. 基于STL的海表面温度预测算法. 海洋环境科学, 39(6): 918-925) [DOI: 10.13634/j.cnki.mes.2020.06.015]
- Hoch K E, Petersen M R, Brus S R, Engwirda D, Roberts A F, Rosa K L, et al. 2020. MPAS — ocean simulation quality for variable-resolution North American coastal meshes. *Journal of Advances in Modeling Earth Systems*, 12(3): #e2019MS001848 [DOI: 10.1029/2019MS001848]
- Hsieh W W and Tang B Y. 1998. Applying neural network models to prediction and data analysis in meteorology and oceanography. *Bulletin of the American Meteorological Society*, 79(9): 1855-1870 [DOI: 10.1175/1520-0477(1998)079<1855:ANNMTP>2.0.CO;2]
- Huang Q S, Niu Y, Zhong X H, Guo A B Y, Chen L, Zhang D J, et al. 2025. FuXi-Ocean: a global ocean forecasting system with sub-daily resolution [EB/OL]. [2025-12-26]. <https://arxiv.org/pdf/2506.03210.pdf>
- Huang Y P, Kao L J and Sandnes F E. 2008. Discriminating important ocean salinity and temperature patterns in Argo data//Proceedings of 2008 IEEE International Conference on Systems, Man and Cybernetics. Singapore, Singapore: IEEE: 2677-2682 [DOI: 10.1109/ICSMC.2008.4811700]
- Imani M, You R J and Kuo C Y. 2014. Forecasting Caspian Sea level changes using satellite altimetry data (June 1992 — December 2013) based on evolutionary support vector regression algorithms and gene expression programming. *Global and Planetary Change*, 121: 53-63 [DOI: 10.1016/j.gloplacha.2014.07.002]
- IPCC. 2007. *Climate Change 2007: The Physical Science Basis*. Cambridge, USA: Cambridge University Press
- Jafari Nodoushan E. 2018. Monthly forecasting of water quality parameters within Bayesian networks: a case study of Honolulu, Pacific Ocean. *Civil Engineering Journal*, 4(1): 188-199 [DOI: 10.28991/cej-030978]
- Ji J X, Zhang L F and Guo Y. 2010. Prediction of sea surface temperature by Kalman filtering. *Marine Forecasts*, 27(3): 59-65 (吉进喜, 张立凤, 郭渊. 2010. Kalman滤波技术在海表温度预测中的应用. 海洋预报, 27(3): 59-65) [DOI: 10.3969/j.issn.1003-0239.2010.03.011]
- Jiang G Q, Xu J and Wei J. 2018. A deep learning algorithm of neural network for the parameterization of typhoon-ocean feedback in typhoon forecast models. *Geophysical Research Letters*, 45(8): 3706-3716 [DOI: 10.1002/2018GL077004]
- Koldunov N V, Aizinger V, Rakowsky N, Scholz P, Sidorenko D, Danilov S, et al. 2019. Scalability and some optimization of the finite-volume sea ice-ocean model, Version 2.0 (FESOM2). *Geoscientific Model Development*, 12(9): 3991-4012 [DOI: 10.5194/gmd-12-3991-2019]
- Konar A. 2018. *Artificial Intelligence and Soft Computing: Behavioral and Cognitive Modeling of the Human Brain*. Boca Raton, USA: CRC Press [DOI: 10.1201/9781315219738]
- Korn P, Brüggemann N, Jungclaus J H, Lorenz S J, Gutzjahr O, Haak H, et al. 2022. ICON-O: the ocean component of the ICON earth system model—global simulation characteristics and local telescoping capability. *Journal of Advances in Modeling Earth Systems*, 14(10): #e2021MS002952 [DOI: 10.1029/2021MS002952]
- Kug J S, Kang I S, Lee J Y and Jhun J G. 2004. A statistical approach to Indian Ocean sea surface temperature prediction using a dynamical ENSO prediction. *Geophysical Research Letters*, 31(9): #L09212 [DOI: 10.1029/2003GL019209]
- Laepple T and Jewson S. 2007. Five year ahead prediction of sea surface temperature in the Tropical Atlantic: a comparison between IPCC climate models and simple statistical methods [EB/OL]. [2025-12-26]. <http://arxiv.org/pdf/physics/0701165.pdf>
- Landman W A and Mason S J. 2001. Forecasts of near-global sea surface temperatures using canonical correlation analysis. *Journal of Climate*, 14(18): 3819-3833 [DOI: 10.1175/1520-0442(2001)014<3819:FONGSS>2.0.CO;2]
- Li Q J, Zhao Y, Liao H L and Li J K. 2017. Effective forecast of North-east Pacific sea surface temperature based on a complementary ensemble empirical mode decomposition — support vector machine method. *Atmospheric and Oceanic Science Letters*, 10(3): 261-267 [DOI: 10.1080/16742834.2017.1305867]
- Li X Y, Chen K Y and Li X C. 2022. Application of convolutional neural network in ENSO prediction. *Journal of Chengdu University of Information Technology*, 37(1): 81-87 (李孝涌, 陈科艺, 李熙晨. 2022. 卷积神经网络在ENSO预报中的应用. 成都信息工程大学学报, 37(1): 81-87) [DOI: 10.16836/j.cnki.jcuit.2022.01.014]
- Liao Z H, Dong Q, Xue C J, Bi J W and Wan G T. 2017. Reconstruction of daily sea surface temperature based on radial basis function networks. *Remote Sensing*, 9(11): #1204 [DOI: 10.3390/rs9111204]
- Lins I D, Araujo M, Moura M D C, Silva M A and Drogue E L. 2013. Prediction of sea surface temperature in the tropical Atlantic by support vector machines. *Computational Statistics and Data Analysis*, 61: 187-198 [DOI: 10.1016/j.csda.2012.12.003]
- Liu H L, Lin P F, Yu Y Q and Zhang X H. 2012. The baseline evaluation of LASG/IAP climate system ocean model (LICOM) version 2. *Acta Meteorologica Sinica*, 26(3): 318-329 [DOI: 10.1007/s13351-012-0305-y]
- Liu J, Zhang T, Han G J and Gou Y. 2018. TD-LSTM: temporal dependence-based LSTM networks for marine temperature predic-

- tion. *Sensors*, 18(11): #3797 [DOI: 10.3390/s18113797]
- Liu J J, Jin B G, Yang J K and Xu L Y. 2021. Sea surface temperature prediction using a cubic B-spline interpolation and spatiotemporal attention mechanism. *Remote Sensing Letters*, 12 (5) : 478-487 [DOI: 10.1080/2150704X.2021.1897182]
- Liu Y B, Zhao Z C, Zhang Z and Yang Y. A novel sea surface temperature prediction model using DBN-SVR and spatiotemporal secondary calibration. *Remote Sensing*, 2025, 17(10): #1681 [DOI: 10.3390/rs17101681]
- Liu J J, Yang J K, Liu K X and Xu L Y. 2022. Improving the performance of sea surface temperature predictions using a revised method. *Remote Sensing Letters*, 13(2): 173-183 [DOI: 10.1080/2150704X.2021.2005269]
- Liu Y M, Duffy K, Dy J G and Ganguly A R. 2023. Explainable deep learning for insights in El Niño and river flows. *Nature Communications*, 14(1): #339 [DOI: 10.1038/s41467-023-35968-5]
- Luo F, Liao G H, Sheng J M and Yang C H. 2012. Seasonal characteristics of marine environment and water exchange in Yueqing bay. *Water Resources Protection*, 28(5): 48-51 (罗锋, 廖光洪, 盛建明, 杨成浩. 2012. 乐清湾海洋环境季节特征及水交换过程研究. *水资源保护*, 28(5): 48-51) [DOI: 10.3969/j.issn.1004-6933.2012.05.010]
- Mahongo S B and Deo M C. 2013. Using artificial neural networks to forecast monthly and seasonal sea surface temperature anomalies in the western Indian Ocean. *The International Journal of Ocean and Climate Systems*, 4(2): 133-150 [DOI: 10.1260/1759-3131.4.2.133]
- Marsland S J, Haak H, JungCLAUS J H, Latif M and Röske F. 2003. The Max-Planck-Institute global ocean/sea ice model with orthogonal curvilinear coordinates. *Ocean Modelling*, 5 (2) : 91-127 [DOI: 10.1016/S1463-5003(02)00015-X]
- Marsooli R, Orton P M and Mellor G. 2017. Modeling wave attenuation by salt marshes in Jamaica Bay, New York, using a new rapid wave model. *Journal of Geophysical Research: Oceans*, 122 (7) : 5689-5707 [DOI: 10.1002/2016JC012546]
- Meng Y X, Gao F, Rigall E, Dong J Y and Du Q. 2024. Physical knowledge analytic framework for sea surface temperature prediction. *IEEE Transactions on Geoscience and Remote Sensing*, 62: #4211216 [DOI: 10.1109/TGRS.2024.3469238]
- Modaresi F, Araghinejad S and Ebrahimi K. 2016. The combined effect of Persian Gulf and Mediterranean Sea surface temperature on operational forecast of spring streamflow for Karkheh basin, Iran. *Sustainable Water Resources Management*, 2(4): 387-403 [DOI: 10.1007/s40899-016-0068-1]
- Mu B, Qin B and Yuan S J. 2021. ENSO-ASC 1.0.0: ENSO deep learning forecast model with a multivariate air-sea coupler. *Geoscientific Model Development*, 14(11): 6977-6999 [DOI: 10.5194/gmd-14-6977-2021]
- Munk W H. 1950. On the wind-driven ocean circulation. *Journal of Meteorology*, 7 (2) : 80-93 [DOI: 10.1175/1520-0469(1950)007<0080:OTWDOC>2.0.CO;2]
- Nie J, Zuo Z J, Huang L, Wang Z G, Sun Z Y, Zhong G Q, et al. 2022. Marine oriented multimodal intelligent computing: challenges, progress and prospects. *Journal of Image and Graphics*, 27(9): 2589-2610 (聂婕, 左子杰, 黄磊, 王志刚, 孙正雅, 仲国强, 等. 2022. 面向海洋的多模态智能计算: 挑战、进展和展望. *中国图象图形学报*, 27 (9) : 2589-2610) [DOI: 10.11834/jig.211267]
- Nooteboom P D, Feng Q Y, López C, Hernández-García E and Dijkstra H A. 2018. Using network theory and machine learning to predict El Niño. *Earth System Dynamics*, 9(3): 969-983 [DOI: 10.5194/esd-9-969-2018]
- Ouala S, Fablet R, Herzet C, Chapron B, Pascual A, Collard F, et al. 2018. Neural network based Kalman filters for the spatio-temporal interpolation of satellite-derived sea surface temperature. *Remote Sensing*, 10(12): #1864 [DOI: 10.3390/rs10121864]
- Pathak J, Subramanian S, Harrington P, Raja S, Chattopadhyay A, Mardani M, et al. 2022. FourCastNet: a global data-driven high-resolution weather model using adaptive Fourier neural operators [EB/OL]. [2025-12-26]. <https://arxiv.org/pdf/2202.11214.pdf>
- Patil K and Deo M C. 2017. Prediction of daily sea surface temperature using efficient neural networks. *Ocean Dynamics*, 67 (3/4) : 357-368 [DOI: 10.1007/s10236-017-1032-9]
- Patil K and Deo M C. 2018. Basin-scale prediction of sea surface temperature with artificial neural networks. *Journal of Atmospheric and Oceanic Technology*, 35(7): 1441-1455 [DOI: 10.1175/JTECH-D-17-0217.1]
- Patil K, Deo M C and Ravichandran M. 2016. Prediction of sea surface temperature by combining numerical and neural techniques. *Journal of Atmospheric and Oceanic Technology*, 33 (8) : 1715-1726 [DOI: 10.1175/JTECH-D-15-0213.1]
- Pope V D, Gallani M L, Rowntree P R and Stratton R A. 2000. The impact of new physical parametrizations in the Hadley centre climate model: HadAM3. *Climate Dynamics*, 16 (2/3) : 123-146 [DOI: 10.1007/s003820050009]
- Qiao B Y, Wu Z Q, Tang Z and Wu G. 2022. Sea surface temperature prediction approach based on 3D CNN and LSTM with attention mechanism//Proceedings of the 24th International Conference on Advanced Communication Technology (ICACT). PyeongChang Kwangwoon\_Do, Korea(South): IEEE: 342-347 [DOI: 10.23919/ICACT53585.2022.9728889]
- Qiao L F, Tang H S and Huang G. 2025. Drivers and predictability of summer marine heatwaves in the Northwest Pacific. *Journal of Geophysical Research: Atmospheres*, 130 (6) : #e2024JD042994 [DOI: 10.1029/2024JD042994]
- Rackow T, Pedruzo-Bagazgoitia X, Becker T, Milinski S, Sandu I, Aguridan R, et al. 2025. Multi-year simulations at kilometre scale with the integrated forecasting system coupled to FESOM2.5 and NEMOv3.4. *Geoscientific Model Development*, 18 (1) : 33-69

- [DOI: 10.5194/gmd-18-33-2025]
- Repelli C A and Nobre P. 2004. Statistical prediction of sea-surface temperature over the tropical Atlantic. *International Journal of Climatology*, 24(1): 45-55 [DOI: 10.1002/joc.982]
- Salles R, Mattos P, Iorgulescu A M D, Bezerra E, Lima L and Ogasawara E. 2016. Evaluating temporal aggregation for predicting the sea surface temperature of the Atlantic Ocean. *Ecological Informatics*, 36: 94-105 [DOI: 10.1016/j.ecoinf.2016.10.004]
- Sharafati A, Haghbin M, Motta D and Yaseen Z M. 2021. The application of soft computing models and empirical formulations for hydraulic structure scouring depth simulation: a comprehensive review, assessment and possible future research direction. *Archives of Computational Methods in Engineering*, 28(2): 423-447 [DOI: 10.1007/s11831-019-09382-4]
- Sharafati A, Tafarjnoruz A, Shourian M and Yaseen Z M. 2020. Simulation of the depth scouring downstream sluice gate: the validation of newly developed data-intelligent models. *Journal of Hydro-Environment Research*, 29: 20-30 [DOI: 10.1016/j.jher.2019.11.002]
- Shen Q, Zhu J R, Duan Y H and Sun M H. 2011. Simulation of circulation and sea temperature in the Northwest Pacific. *Journal of East China Normal University (Natural Science)*, (6): 26-35 (沈淇, 朱建荣, 端义宏, 孙明华. 2011. 西北太平洋环流和海温数值模拟. *华东师范大学学报(自然科学版)*, (6): 26-35) [DOI: 10.3969/j.issn.1000-5641.2011.06.004]
- Shi B Y, Feng L, He H L, Hao Y J, Peng Y, Liu M, et al. 2024. A physics-guided attention-based neural network for sea surface temperature prediction. *IEEE Transactions on Geoscience and Remote Sensing*, 62: #4210413 [DOI: 10.1109/TGRS.2024.3457039]
- Shirvani A, Nazemosadat S M J and Kahya E. 2015. Analyses of the Persian Gulf sea surface temperature: prediction and detection of climate change signals. *Arabian Journal of Geosciences*, 8(4): 2121-2130 [DOI: 10.1007/s12517-014-1278-1]
- Shu R Q, Gao Y, Wu H, Gou R J, Wang K, Xiang Y F, et al. 2025. Ocean-E2E: hybrid physics-based and data-driven global forecasting of extreme marine heatwaves with end-to-end neural assimilation [EB/OL]. [2025-12-26]. <https://arxiv.org/pdf/2505.22071.pdf>
- Smith R D, Dukowicz J K and Malone R C. 1992. Parallel ocean general circulation modeling. *Physica D: Nonlinear Phenomena*, 60(1/4): 38-61 [DOI: 10.1016/0167-2789(92)90225-C]
- Stommel H. 1948. The westward intensification of wind-driven ocean currents. *Eos, Transactions American Geophysical Union*, 29(2): 202-206 [DOI: 10.1029/TR029i002p00202]
- Sun M, Chen L, Li T and Luo J J. 2023. CNN-based ENSO forecasts with a focus on SSTA zonal pattern and physical interpretation. *Geophysical Research Letters*, 50(20): #e2023GL105175 [DOI: 10.1029/2023GL105175]
- Ubilava D and Helmers C G. 2013. Forecasting ENSO with a smooth transition autoregressive model. *Environmental Modelling and Software*, 40: 181-190 [DOI: 10.1016/j.envsoft.2012.09.008]
- Wang X, Wang R Z, Hu N Z, Wang P Q, Huo P, Wang G H, et al. 2024. XiHe: a data-driven model for global ocean eddy-resolving forecasting [EB/OL]. [2025-12-26]. <https://arxiv.org/pdf/2402.02995.pdf>
- Wang Y S, Zhou F, Meng Q C, Zhou M P, Hu Z J, Zhang C Q, et al. 2025. An ocean front detection and tracking algorithm [EB/OL]. [2025-12-26]. <https://arxiv.org/pdf/2502.15250.pdf>
- Wei L, Guan L and Qu L Q. 2020. Prediction of sea surface temperature in the South China Sea by artificial neural networks. *IEEE Geoscience and Remote Sensing Letters*, 17(4): 558-562 [DOI: 10.1109/LGRS.2019.2926992]
- Wolff S, O'Donncha F and Chen B. 2020. Statistical and machine learning ensemble modelling to forecast sea surface temperature. *Journal of Marine Systems*, 208: #103347 [DOI: 10.1016/j.jmarsys.2020.103347]
- Wu Z Y, Jiang C B, Conde M, Deng B and Chen J. 2019. Hybrid improved empirical mode decomposition and BP neural network model for the prediction of sea surface temperature. *Ocean Science*, 15(2): 349-360 [DOI: 10.5194/os-15-349-2019]
- Xiao C J, Chen N C, Hu C L, Wang K, Gong J Y and Chen Z Q. 2019a. Short and mid-term sea surface temperature prediction using time-series satellite data and LSTM-AdaBoost combination approach. *Remote Sensing of Environment*, 233: #111358 [DOI: 10.1016/j.rse.2019.111358]
- Xiao C J, Chen N C, Hu C L, Wang K, Xu Z W, Cai Y P, et al. 2019b. A spatiotemporal deep learning model for sea surface temperature field prediction using time-series satellite data. *Environmental Modelling and Software*, 120: #104502 [DOI: 10.1016/j.envsoft.2019.104502]
- Xing Q W, Yu H Q and Wang H. 2024. Global mapping and evolution of persistent fronts in large marine ecosystems over the past 40 years. *Nature Communications*, 15(1): #4090 [DOI: 10.1038/s41467-024-48566-w]
- Xiong W, Xiang Y F, Wu H, Zhou S Y, Sun Y Z, Ma M Y, et al. 2023. AI-GOMS: large AI-driven global ocean modeling system [EB/OL]. [2025-12-26]. <https://arxiv.org/pdf/2308.03152.pdf>
- Xu B N, Jiang J R, Hao H Q, Lin P F and He D D. 2017. A deep learning model of ENSO prediction based on regional sea surface temperature anomaly prediction. *e-Science Technology and Application*, 8(6): 65-76 (许柏宁, 姜金荣, 郝卉群, 林鹏飞, 何丹丹. 2017. 一种基于区域海表面温度异常预测的 ENSO 预报深度学习模型. *科研信息化技术与应用*, 8(6): 65-76) [DOI: 10.11871/j.issn.1674-9480.2017.06.008]
- Xu H F, Huang D M, He Q, Du Y L and Qin X B. 2021. Ocean front detection method based on improved Mask R-CNN. *Journal of Image and Graphics*, 26(12): 2981-2990 (徐慧芳, 黄冬梅, 贺琪, 杜艳玲, 覃学标. 2021. 改进 Mask R-CNN 模型的海洋锋检测. *中国图象图形学报*, 26(12): 2981-2990) [DOI: 10.11834/jig.

- 200599]
- Xu L Y, Li Q, Yu J, Wang L, Xie J and Shi S X. 2020. Spatio-temporal predictions of SST time series in China's offshore waters using a regional convolution long short-term memory (RC-LSTM) network. *International Journal of Remote Sensing*, 41 (9): 3368-3389 [DOI: 10.1080/01431161.2019.1701724]
- Xu Z Z. 2024. Discovery of Spatiotemporal Patterns of Sea Surface Temperature Based on Co-Clustering. Shanghai, China: Shanghai Ocean University (许壮壮. 2024. 基于协同聚类的大海表面温度时空模式发现. 上海: 上海海洋大学)
- Xue Y and Leetmaa A. 2000. Forecasts of tropical Pacific SST and sea level using a Markov model. *Geophysical Research Letters*, 27(17): 2701-2704 [DOI: 10.1029/1999GL011107]
- Yang K, Meyer A, Strutton P G and Fischer A M. 2023. Global trends of fronts and chlorophyll in a warming ocean. *Communications Earth and Environment*, 4(1): #489 [DOI: 10.1038/s43247-023-01160-2]
- Yang N, Wang C, Zhao M H, Zhao Z M, Zheng H L, Zhang B, et al. 2024. LangYa: revolutionizing cross-spatiotemporal ocean forecasting [EB/OL]. [2025-12-26]. <https://arxiv.org/pdf/2412.18097.pdf>
- Yang Y T, Dong J Y, Sun X, Lima E, Mu Q Q and Wang X H. 2018. A CFCC-LSTM model for sea surface temperature prediction. *IEEE Geoscience and Remote Sensing Letters*, 15(2): 207-211 [DOI: 10.1109/LGRS.2017.2780843]
- Yang Y T, Lam K M, Sun X, Dong J Y and Lguensat R. 2022. An efficient algorithm for ocean-front evolution trend recognition. *Remote Sensing*, 14(2): #259 [DOI: 10.3390/rs14020259]
- Yaseen Z M, Ebtehaj I, Kim S, Sanikhani H, Asadi H, Ghareb M I, et al. 2019. Novel hybrid data-intelligence model for forecasting monthly rainfall with uncertainty analysis. *Water*, 11(3): #502 [DOI: 10.3390/w11030502]
- Yu X, Shi S X, Xu L Y, Liu Y Y, Miao Q S and Sun M. 2020. A novel method for sea surface temperature prediction based on deep learning. *Mathematical Problems in Engineering*, 2020: #6387173 [DOI: 10.1155/2020/6387173]
- Yuan T K, Zhu J X, Wang W X, Lu J Z, Wang X, Li X Y, et al. 2023. A space-time partial differential equation based physics-guided neural network for sea surface temperature prediction. *Remote Sensing*, 15(14): #3498 [DOI: 10.3390/rs15143498]
- Zha C, He Q, Song W, Hao Z Z, Huang D M and Hu Z Y. 2020. Regional sea surface temperature prediction algorithm combined with attention mechanism. *Marine Science Bulletin*, 39(2): 191-199 (查铨, 贺琪, 宋巍, 郝增周, 黄冬梅, 胡泽煜. 2020. 结合注意力机制的区域型海表面温度预报算法. 海洋通报, 39(2): 191-199) [DOI: 10.11840/j.issn.1001-6392.2020.02.006]
- Zhang K, Geng X P and Yan X H. 2020a. Prediction of 3-D ocean temperature by multilayer convolutional LSTM. *IEEE Geoscience and Remote Sensing Letters*, 17(8): 1303-1307 [DOI: 10.1109/LGRS.2019.2947170]
- Zhang Q, Wang H, Dong J Y, Zhong G Q and Sun X. 2017. Prediction of sea surface temperature using long short-term memory. *IEEE Geoscience and Remote Sensing Letters*, 14(10): 1745-1749 [DOI: 10.1109/LGRS.2017.2733548]
- Zhang S J. 2021. Application of machine learning in stock market prediction with big data. *Journal of Guiyang University (Social Sciences)*, 16(4): 43-48 (张世杰. 2021. 大数据下的机器学习在股市预测中的应用. 贵阳学院学报(社会科学版), 16(4): 43-48) [DOI: 10.16856/j.cnki.52-1141/c.2021.04.007]
- Zhang X W and Han Z. 2022. Prediction of sea surface temperature based on ConvGRU deep learning network model. *Journal of Dalian Ocean University*, 37(3): 531-538 (张雪薇, 韩震. 2022. 基于ConvGRU深度学习网络模型的海表面温度预测. 大连海洋大学学报, 37(3): 531-538) [DOI: 10.16535/j.cnki.dlhyxb.2021-137]
- Zhang Y R. 1992. A study on the method of predicting safe overwintering seawater temperature for juvenile abalone in the waters near Dalian. *Marine Environmental Science*, 11(1): 34-38 (张玉荣. 1992. 大连附近海域幼鲍安全越冬海水温度预报方法的研究. 海洋环境科学, 11(1): 34-38)
- Zhang Z, Pan X L, Jiang T, Sui B K, Liu C X and Sun W F. 2020b. Monthly and quarterly sea surface temperature prediction based on gated recurrent unit neural network. *Journal of Marine Science and Engineering*, 8(4): #249 [DOI: 10.3390/jmse8040249]
- Zheng X T, Xiao X L, Chen X M, Lu W X, Liu X Y and Lu X Q. 2024. Advancements in cross-domain remote sensing scene interpretation. *Journal of Image and Graphics*, 29(6): 1730-1746 (郑向涛, 肖欣林, 陈秀妹, 卢宛萱, 刘小煜, 卢孝强. 2024. 跨域遥感场景解译研究进展. 中国图象图形学报, 29(6): 1730-1746) [DOI: 10.11834/jig.240009]
- Zhu B and Ye Y X. 2024. Multimodal remote sensing image registration: a survey. *Journal of Image and Graphics*, 29(8): 2137-2161 (朱柏, 叶沅鑫. 2024. 多模态遥感图像配准方法研究综述. 中国图象图形学报, 29(8): 2137-2161) [DOI: 10.11834/jig.230737]

## 作者简介

贺琪,女,教授,主要研究方向为海洋大数据分析、大数据存储、工作流与业务流程管理、服务计算。

E-mail:qihe@shou.edu.cn

宋巍,通信作者,女,教授,主要研究方向为计算机视觉和海洋数据分析。E-mail:wsong@shou.edu.cn

陶梦鑫,男,硕士研究生,主要研究方向为极端海表温预测。E-mail:taomengxin1210@163.com

朱姿杭,男,硕士,主要研究方向为海洋热浪的可解释性。

E-mail:zhujerry1998@163.com

杜艳玲,女,副教授,主要研究方向为时空数据挖掘和海洋涡旋轨迹预测。E-mail:yldu@shou.edu.cn