

基于深度学习的南海海表面温度的 智能化预测研究*

谢博闻^{1,3} 张丛^{2①} 杨树国¹ 冯忠琨^{1,3} 孙贵民^{3,4}

(1. 青岛科技大学数理学院 山东青岛 266061; 2. 山东省海洋科学研究院 山东青岛 266104; 3. 中国科学院海洋研究所 海洋环流与波动重点实验室 山东青岛 266071; 4. 中国科学院大学 北京 100049)

摘要 海表面温度(sea surface temperature, SST)是影响海洋和气候变化的重要因素之一,准确预测 SST 的变化对于海洋生态环境、气象和航行等至关重要。传统的 SST 预测方法通常依赖于数值模式,但是其计算成本较高。该文基于深度学习模型(3D U-Net),将 SST、海表面高度异常(sea surface height anomalies, SSHA)以及海表面风(sea surface wind, SSW)作为输入变量成功构建了南海 SST 的快速化智能预报模型。结果表明,与卷积长短时记忆(convolutional long short-term memory, ConvLSTM)模型相比,3D U-Net 模型在所有预测时间中均显示出更高的准确度,其均方根误差(RMSE)为 0.53 °C,皮尔逊相关系数(R)达到 0.96。在不同季节和南海不同区域,3D U-Net 模型均表现出较小的预测误差,而且在季风盛行期间也具有较强的鲁棒性。此外,3D U-Net 模型在预测 2021 年南海的海洋热浪(marine heatwave, MHW)事件时,大部分海域的准确率达到 80% 以上,总体上精确率和召回率分别为 0.89 和 0.45。敏感性实验结果表明,SSHA 和 SSW 对模型的预测性能有显著影响,并在不同的预报阶段中发挥着不同的作用。综上所述,结合多源海表数据的 3D U-Net 模型能够快速准确地预测出南海 SST,并为预测 MHW 事件提供了新方法。

关键词 海表面温度; 3D U-Net 模型; 深度学习; 南海; 海洋热浪

中图分类号 P731.31 doi: 10.11693/hyhz20240200032

海表面温度(sea surface temperature, SST)作为重要的海洋环境因素,其在海洋与大气之间的能量交换中发挥着至关重要的作用(Namias *et al.*, 1981)。而且一个海域的 SST 变化不仅影响该区域的气候变化,还能对其他区域产生间接的影响,包括极端低温和降水异常的发生(冀蕊等, 2023; 张萍等, 2023)。因此,准确地预测 SST 对于监测海洋极端事件和提高对海洋气候变化的理解具有极其重要的意义。然而,由于海气界面存在复杂的动力学和热力学过程,所以快速准确地预测 SST 仍然面临巨大挑战。

南海(South China Sea, SCS)位于亚洲大陆东南

部,是我国的一个半封闭的边缘海。由于其位置处于印度-太平洋暖池中,所以南海的 SST 在全球气候变化中扮演着重要的角色(Liu *et al.*, 2004)。因为其独特的地理位置和季风的影响,南海的环流系统较为复杂(王东晓等, 2019),这也导致南海 SST 表现出复杂的时空变化(如图 1a 所示)。南海多年气候态平均的 SST 呈现出由西北至东南递增的分布特征,在中部存在着一个明显的 SST 梯度锋(孙伟富等, 2018)。南海的地理位置和环流系统也使其 SST 变化对于区域气候有着显著的影响。例如,南海 SST 的升高会导致季风活动的增强,进而影响其他区域的降水情况(Vaid *et al.*,

*中央引导地方科技发展资金项目, YDZX2022022 号; 山东省自然科学基金项目, ZR2021MD022 号。谢博闻, 硕士研究生, E-mail: bwxie@mails.qust.edu.cn

① 通信作者: 张丛, 助理研究员, E-mail: zhangcong01@shandong.cn

收稿日期: 2024-02-06, 收修改稿日期: 2024-03-06

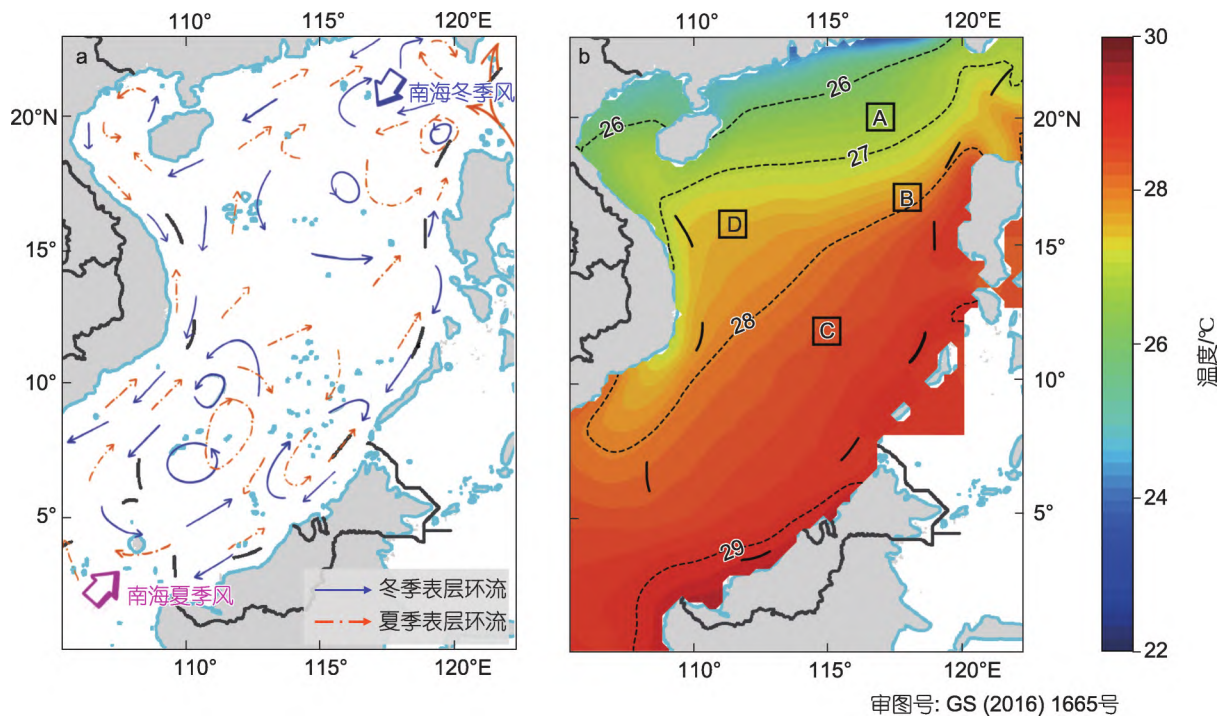


图1 南海的表层环流的示意图(a)和长期平均的海表面温度(SST)的分布图(b)

Fig.1 The schematic diagram of the surface circulation (a) and the distribution map of long-term mean SST (b) in the SCS
 注: 长期平均的 SST 数据是对来自美国国家海洋和大气管理局(National Oceanic and Atmospheric Administration, NOAA)每日最佳插值海表温度(optimum interpolation SST, OISST)数据进行的, 时间跨度为 1982 年 1 月 1 日至 2021 年 12 月 31 日; A, B, C, D 是 4 个代表性区域; b 中空白处为非研究区域, 对其数据进行了掩码处理

2018)。此外, SST 的升高还会导致南海珊瑚白化现象的发生(陆永强等, 2022), 进而对该区域的生态环境产生重要的影响。因此, 准确地预测南海的 SST, 对于深入理解气候变化以及海洋生态环境保护至关重要。

目前, 对于 SST 的预测方法主要分为两类: 一类是基于传统海洋数值模式, 另一类是基于数据驱动的方法。基于数值模式的方法能够较为准确的预测 SST, 但这类模式的计算需求往往较为庞大, 原因在于它们需要综合考虑海洋中诸多复杂的热力学和动力学过程(马继瑞等, 2002; Stockdale *et al*, 2006; Li *et al*, 2008; 何忠杰等, 2010; 沈红等, 2014; 刘娜等, 2018)。与之相比, 基于数据驱动的方法, 特别是统计方法和机器学习方法, 也逐渐被应用于 SST 的预测。这些方法主要包括马尔可夫模型(Xue *et al*, 2000)、线性回归(Kug *et al*, 2004)以及支持向量机(support vector machine, SVM)(Lins *et al*, 2013)等, 它们主要依靠历史数据来预测未来 SST 的变化。尽管数据驱动的方法在计算上更为快速, 但这些方法往往缺乏数值模式所具有的物理过程和复杂性, 主要集中于从数据中统计推断, 这也限制了它们捕捉海洋动力过程中非线性特征的能力, 从而导致其预测精度不如基于数值模式的方法。

随着人工智能技术的快速发展及海洋数据的不断积累, 深度学习模型凭借其卓越的处理非线性特征的能力, 在海洋温盐结构以及关键层结反演的研究领域已取得不错的成果(Qi *et al*, 2022, 2023a, 2023b, 2023c, 2024)。其中, Qi 等(2023b)通过将卷积注意力模块(convolutional block attention module, CBAM)引入到卷积神经网络(convolutional neural networks, CNN)模型中, 建立了基于 CBAM-CNN 的印度洋温盐结构反演模型, 发现注意力机制的添加有助于提高 CNN 模型在同时反演印度洋温盐结构的准确性。而在太平洋将多个模型通过集成学习的方法对三维温度场进行反演, 发现集成学习能够有效地提高模型的反演性能(Qi *et al*, 2023c)。深度学习模型因为能够有效地捕捉复杂的数据关系, 也被逐渐应用到预测领域, 李亚蒙等(2022)通过利用长短时记忆网络(long short-term memory, LSTM)模型对太平洋浮标的历史数据进行分析, 建立了一种 24 h 短期海表面风速预测模型, 显著提高了预测的准确性。此外, LSTM 模型在海表面高度异常(sea surface height anomalies, SSHA)预测(江璟瑜等, 2021)和风暴潮预测(苗庆生等, 2022)领域同样展现出较好的性能。赵宏凯等(2023)则是采用

了基于外部输入的非线性自回归 (nonlinear autoregressive model with exogenous inputs, NARX) 神经网络,并引入了动态延时和反馈机制来预测极端风暴潮事件,结果表明准确的风速、风向以及压强等数据对模型预测性能具有显著的影响。谢文鸿等(2022)通过卷积长短时记忆 (convolutional long short-term memory, ConvLSTM) 模型建立了轻量化的风暴潮预报模型,即使在缺少边界条件、地形和径流等关键信息的情况下,也能在短临预报中较准确地复现数值模式的模拟结果。深度学习模型在预测全球重要的海洋气候现象,如厄尔尼诺事件与南方涛动(周佩等, 2021)、印度洋偶极子(刘俊等, 2022)等方面,也展现出了巨大的潜力,进一步证实了深度学习模型在预测领域的有效性。在 SST 预测方面也已有多种深度学习模型显示出了较好的预测性能,其中包括反向传播神经网络(back propagation neural network, BPNN) (Aparna *et al*, 2018)、CNN 模型(Liu *et al*, 2021)以及 LSTM 模型(李竞时等, 2023)。为进一步提升模型预测的准确度,越来越多的复合架构模型被提出,例如,Xiao 等(2019)将 AdaBoost 模型与 LSTM 模型相结合,应用于东海的 SST 异常(SST anomalies, SSTA)预测,其性能超过了传统的支持向量回归(support vector regression, SVR)模型和 BPNN 模型。Yang 等(2018)通过将 LSTM 与卷积层相结合,提高了 SST 预测的精度,该方法同样优于传统的 SVR 模型和仅与全连接层相结合的 LSTM 方法。此外,将二维卷积和 LSTM 相结合的 U-net-LSTM 模型被证实可以有效地用于月平均 SST 的预测,并有助于预测厄尔尼诺现象(Taylor *et al*, 2022)。查铖等(2020)将注意力机制引入到 ConvLSTM 模型中,利用注意力机制为特征信息分配权重,以提高模型对时间序列数据的敏感度和预测能力。而张雪薇等(2022)将 CNN 与门控循环单元(gated recurrent unit, GRU)相结合,充分利用空间和时间特征之间的内在联系,提高了模型的区域性效果。相比之下,王丽娜等(2023)将图卷积(graph convolution, GC)和具有注意力机制的 GRU 模型相融合,通过图形拓扑结构捕捉空间关系,并通过注意力机制增强对时间序列数据的处理能力,从而提升了 SST 预测的准确性。尽管深度学习模型在 SST 预测中已取得了一定的进展,针对南海 SST 预测的研究还较少,而且大多数研究依赖于单变量预测方法,忽略了不同海洋变量间的相互作用,进而可能会限制模型的物理意义和整体准确性(Song *et al*, 2020; Hao *et al*,

2023; 杜家豪等, 2023)。已有研究表明,采用多变量输入往往能够取得更好的预测结果。例如,Shao 等(2021)开发了一个将多元经验正交函数和具有一维卷积的 LSTM(Conv1D-LSTM)相结合的深度学习模型,并考虑到不同变量之间的相关性,使用 SSHA 和 SST 数据作为驱动因子进行短期预测,该模型在正常和极端天气条件下均表现出色。最近,Miao 等(2023)也得出了类似的结论,他们的研究使用基于多变量的 CNN 模型,通过结合 SSTA、风速和表层海流速度作为输入变量,实现了 SSTA 的准确预测。

综上所述,尽管深度学习模型被广泛应用到 SST 预测领域,但是其在南海地区的研究仍然有限。现有的模型通常专注于单一站点或单一变量的预测,忽视了不同变量和区域间的复杂相互作用,这可能降低了模型的准确性。为了克服这些限制,本文提出了一种基于 3D U-Net 架构的深度学习模型,用于预测南海的 SST。该模型旨在有效地捕捉多个海洋表面变量之间的复杂关联,并提取时空特征,从而能够更准确地预测南海的 SST。

1 数据和方法

1.1 数据

本文选取南海海域(105°~122.5°E 以及 0°~23°N)作为研究区域(图 1)。为了降低苏禄海和苏拉威西海对预测的结果产生影响,本文对这两个海域的数据实施了掩码处理,确保其不纳入研究数据范围内。基于前人的研究结果(Shao *et al*, 2021; Miao *et al*, 2023),本文选择了 SST、海表面风(sea surface wind, SSW)和 SSHA 作为本研究的输入参数,用于预测南海的 SST。

本文所采用的 SST 数据来自 NOAA 提供的每日 OISST 2.1 版本的数据集(Huang *et al*, 2021),其空间分辨率为 0.25°。该数据集融合了多个来源的 SST 数据,并通过使用最优插值方法填补了缺失值,形成了网格化的数据。其包含了从 1981 年 9 月 1 日至今的全球尺度的 SST 数据(http://apdrc.soest.hawaii.edu/dods/public_data/NOAA_SST); SSW 数据来自于交叉校准多平台(Cross-Calibrated Multi-Platform, CCMP) v2.0 版本的数据集(Atlas *et al*, 2011),包括东向风(eastward SSW, ESSW)和北向风(northward SSW, NSSW),时间范围从 1987 年 7 月 10 日至今,时间分辨率为 6 h,空间分辨率为 0.25°,其可以从 <https://www.remss.com/measurements/ccmp> 获得。SSHA 数据来自法国的 CLS 公司(Collecte Localisation

Satellites), 现由欧盟哥白尼海洋与环境监测服务 (Copernicus Marine and Environmental Monitoring Service, CMEMS) 提供。该数据集整合了覆盖全球海洋的多个卫星测高仪的数据, 提供了从 1993 年 1 月 1 日至 2022 年 8 月 4 日的每日 SSHA 数据, 空间分辨率同样为 0.25° , 详细信息见 <https://doi.org/10.48670/moi-00148>。

考虑到海表面数据可获取的时间范围, 本文选择了 1993 年 1 月 1 日至 2021 年 12 月 31 日作为研究的时间范围。其中, 1993 年 1 月 1 日至 2020 年 12 月 31 日的数据被用于模型训练, 随机选取 80% 的数据作为训练集, 剩余 20% 用于验证。选取 2021 年 1 月 1 日至 2021 年 12 月 31 日之间的数据作为测试集, 以评估模型在预测南海 SST 方面的表现。为了方便计算和模型的训练, 原本时间分辨率为 6 h 的 SSW 数据被处理成日均值数据。最终, 模型的所有输入变量的空间分辨率为 0.25° 、时间分辨率为 1 d。研究区域和数据的详细描述见表 1。在模型训练前, 研究区域内的陆地部分数据被填充为零, 并对海洋数据进行了标准化处理, 标准化公式如下

$$x' = \frac{x - m}{s} = \frac{x - \frac{\sum_{i=1}^n x_i}{n}}{\sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}}, \quad (1)$$

其中, x' 代表标准化后的数据点; x 为原始数据点; \bar{x} 表示数据的均值; s 代表数据的标准差; 第 i 个数据点表示为 x_i ; n 为数据点的总数量。

表 1 数据总结和区域信息

Tab.1 Data summary and regional information

标签	信息
区域	$105^\circ \sim 122.5^\circ \text{E}$, $0^\circ \sim 23^\circ \text{N}$ 南海
SST	1993~2021 年 NOAA
SSHA	1993~2021 年 CMEMS
数据 SSW (ESSW, NSSW)	1993~2021 年 CCMP
训练集时间范围	1993.01.01~2020.12.31
测试集时间范围	2021.01.01~2021.12.31

1.2 方法

本文提出的基于多源海洋表面变量的 3D U-Net 模型, 旨在快速预测南海未来 30 d 的 SST。尽管 U-Net 模型已在多种预测任务中得到广泛应用 (Ren *et al*, 2023; Wang *et al*, 2023), 最初由 Ronneberger 等 (2015) 提出的 U-Net 架构主要是针对二维数据 (例如图像) 的

处理, 用于空间信息特征的提取, 在设计时并未考虑到在预测任务中关于时间信息的提取。因此, 本研究将 U-Net 模型中的二维的操作转换为与之相对应的三维操作, 从而构建了使用多源海洋表面变量对 SST 进行预测的 3D U-Net 模型。这一改进使得该模型不仅能够有效处理空间维度上的信息, 同时也能在时间维度上提取关键的特征信息。具体来说, 这种结构使卷积层中的特征图能够与前一层的多个时间序列相关联, 从而获取并利用这些时间序列的特征信息。形式上, 第 i 层的第 j 个特征图上 (x, y, z) 位置的值表示为

$$v_{ij}^{xyz} = \tanh \left(b_{ij} + \sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{ijm}^{pqr} v_{(i-1)m}^{(x+p)(y+q)(z+r)} \right), \quad (2)$$

其中, $\tanh(\cdot)$ 是双曲正切函数; b_{ij} 项代表与给定特征图的偏置; R_i 代表卷积核在时间维度上的大小; 而 P_i 和 Q_i 分别对应于卷积核的高度和宽度; w_{ijm}^{pqr} 表示卷积核在位置 (p, q, r) 的权重值; m 是特征图的索引。通过在多个维度上应用卷积计算, 3D U-Net 模型能够同时提取包括 SST、SSW 和 SSHA 等多个变量的特征信息。这种多维卷积方法的应用, 使得模型在预测 SST 的过程中可以综合考虑多种海洋环境变量, 同时保持这些变量在时间上的连续性和完整性。这也是 3D U-Net 模型的一个重要优势, 有利于提高预测的准确性。

本文所使用的 3D U-Net 模型结构如图 2 所示。由于模型结构和硬件的限制, 在进行多次实验后, 本文确定使用历史 64 d 的 SST、SSHA、ESSW 和 NSSW 数据来预测未来 30 d 的 SST。3D U-Net 模型的编码器部分在空间和时间维度上进行卷积和池化操作来捕捉不同区域和不同时间的海表变量的变化, 使其能够有效地学习相关特征。随后, 解码器部分使用编码器识别的特征进行反卷积和上采样过程, 将这些特征映射回其原始的空间大小和时间尺度, 生成未来时间段的 SST, 从而完成南海 SST 的预测。

为了全面评估 3D U-Net 模型的表现, 本文还选择了广泛认可的 ConvLSTM 模型进行比较 (图 2)。ConvLSTM 模型由 Shi 等 (2015) 提出, 用于解决 LSTM 模型在提取二维空间信息方面的不足。通过在 LSTM 模型中添加卷积操作, ConvLSTM 能够同时学习和提取时间和空间维度上的特征。该模型是将当前输入信息和过去的状态信息相结合进行预测的, 主要

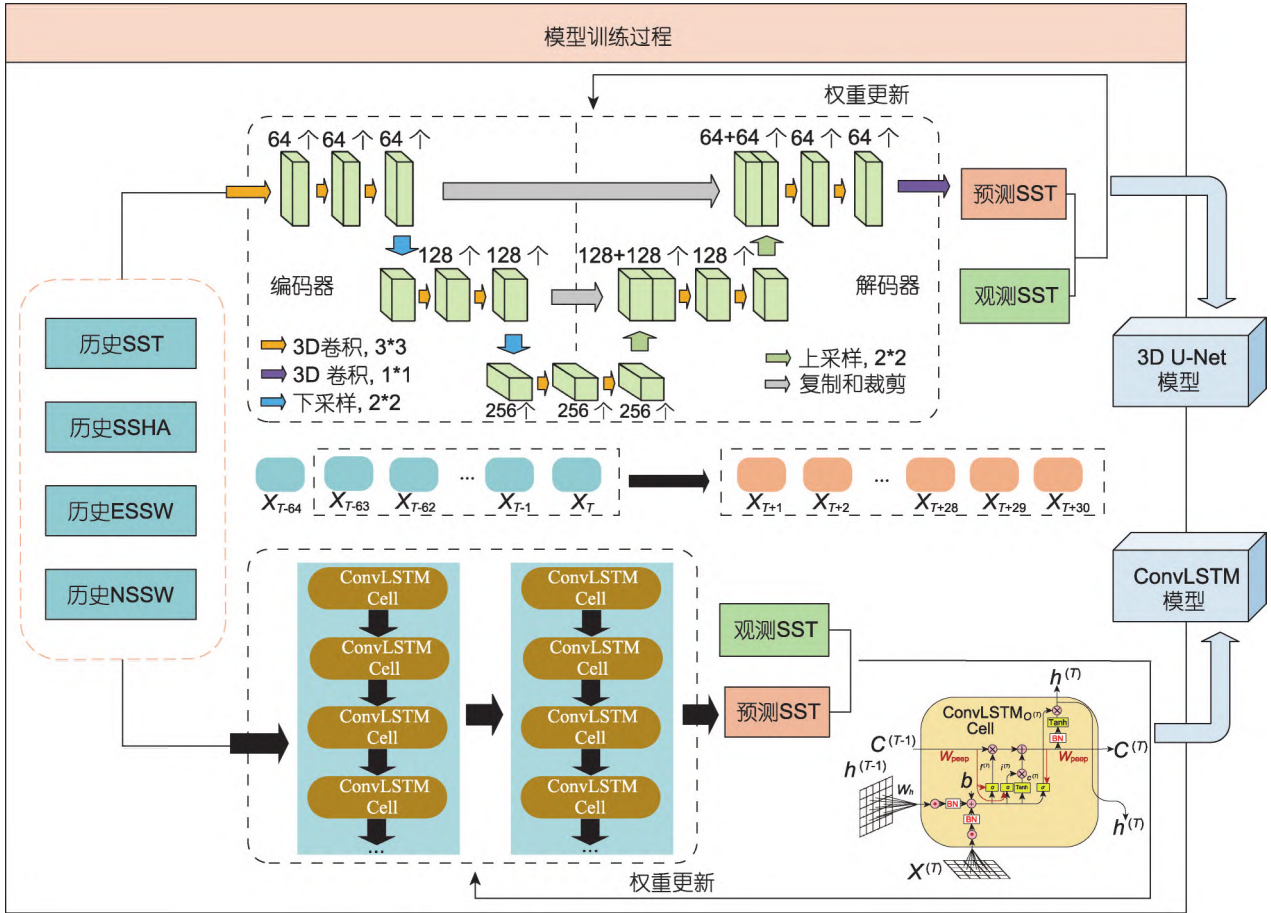


图2 3D U-Net模型和ConvLSTM模型的结构及训练过程

Fig.2 The structure and training process of the 3D U-Net model and the ConvLSTM model

注:第 T 天的数据表示为 X_T ;在解码器和编码器中如下 3D 卷积后面的数字代表的是卷积核的参数,该数字没有单位; $X^{(T)}$ 表示当前时刻的输入数据; $C^{(T-1)}$ 和 $C^{(T)}$ 分别为前一时刻和当前时刻记忆单元的状态; $h^{(T-1)}$ 和 $h^{(T)}$ 分别为前一时刻和当前时刻的隐藏状态; $f^{(T)}$ 、 $i^{(T)}$ 和 $o^{(T)}$ 分别代表当前时刻遗忘门、输入门和输出门的状态; W_h 和 W_{peep} 为当前单元的权重系数; b 为当前单元的偏置

是由输入门 i_t 、遗忘门 f_t 和输出门 o_t 控制记忆单元 C_t 和其最终状态 H_t 实现的,这个过程的主要方程如下

$$\begin{aligned}
 i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i), \\
 f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f), \\
 C_t &= f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c), \quad (3) \\
 o_t &= \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \circ C_t + b_o), \\
 H_t &= o_t \circ \tanh(C_t),
 \end{aligned}$$

其中, σ 代表 sigmoid 激活函数,它可以将值映射到 0 到 1 的范围内,* 表示引入模型的卷积运算,符号 \circ 代表哈达玛积, X_t 表示为在 t 时刻的输入向量,而 W_{xi} 、 W_{hi} 、 W_{ci} 、 W_{xf} 、 W_{hf} 、 W_{cf} 、 W_{xc} 、 W_{hc} 、 W_{xo} 、 W_{ho} 和 W_{co} 分别为作用于输入向量、隐藏状态和细胞状态的权重系数, b_i 、 b_f 、 b_c 和 b_o 分别为偏置向量。虽然 ConvLSTM 模型在处理时空数据方面具有其优势,但本研究提出的 3D U-Net 模型则引入了一种新的多变量整合方法来

预测 SST。对比结果不仅有助于揭示每个模型的独特特点,而且能够为南海 SST 预测模型的适用性提供一个更加全面和深入的理解。

在深度学习模型的训练过程中,模型参数的选择是至关重要的。为了确保 3D U-Net 模型能够高效率准确地运行,本文进行了一系列的实验以优化模型参数。通过这些实验,最终确定了模型所采用的最优参数配置,如表 2 所示。

为了评价模型的表现,本文使用均方根误差(root mean square error, RMSE)、皮尔逊相关系数(Pearson correlation coefficient, R)、对称平均绝对百分比误差(symmetric mean absolute percentage error, SMAPE)和中值绝对误差(median absolute error, MedAE)等指标来评估模型的预报性能,其公式如下表示

表 2 模型参数

Tab.2 The model parameter information

模型	参数
ConvLSTM	批次大小: 12 个, 激活函数: elu, 验证频率: 每一个轮, 损失函数: mse, 优化器: radam, 学习率: 0.01, 初始训练轮数: 1 000 轮, 使用早停法(连续 15 轮损失不下降停止训练)
3D U-Net	编码器层数: 3 层, 层解码器层数: 3 层, 3D 卷积核大小: 3, 隐藏层的维度: [64,128,256], 池化大小: 2, 3D 卷积时填充: 1

$$\begin{aligned}
 RMSE &= \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}, \\
 R &= \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}}, \\
 SMAPE(y, \hat{y}) &= \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2},
 \end{aligned} \tag{4}$$

$$MedAE(y, \hat{y}) = \text{median}(|y_1 - \hat{y}_1|, \dots, |y_n - \hat{y}_n|),$$

其中, y_i 是观测到的 SST, \hat{y}_i 代表 3D U-Net 模型预测的 SST, 而 \bar{y} 和 $\bar{\hat{y}}$ 分别代表观测值的平均值和预测值的平均值; median 表示对相关数据进行取中位数处理。

2 结果

2.1 3D U-Net 模型与 ConvLSTM 模型的对比

为了评估 3D U-Net 模型在预测南海 SST 方面的表现, 本文将其与 ConvLSTM 模型进行了详细的对比。首先, 图 3 给出了在 2021 年测试集中 3D U-Net 模型和 ConvLSTM 模型在不同预测超前时间的预测性能的比较结果。

在 30 d 的预报时间内, 3D U-Net 模型和 ConvLSTM 模型在 SST 预测方面均有不错的表现, 都具有较高相关性(最小的 R 值超过 0.9)和较低的误差(最大的 RMSE 小于 $0.8\text{ }^\circ\text{C}$)(图 3)。随着预测超前时间从 1 d 增加到 30 d, 两种模型的预测结果均表现出 R 值逐渐下降和 RMSE 相应增加的变化趋势。这表明观测值和预测值之间的相关性逐渐减弱, 预报误差随着预测超前时间的增加而增加。然而, 在所有预测超前时间的对比中, 可以发现 3D U-Net 模型始终优于 ConvLSTM 模型, 保持了更高的 R 值和更低的 RMSE 值。凸显了 3D U-Net 模型在预报南海 SST 方面准确性更好。

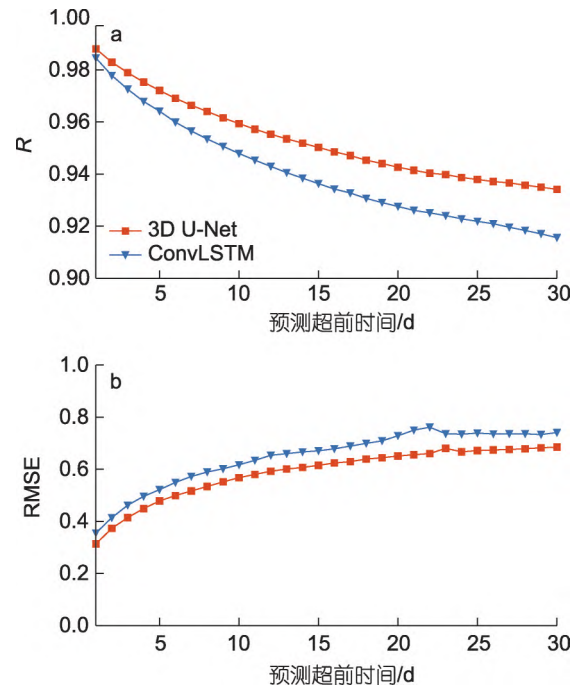


图 3 3D U-Net 模型与 ConvLSTM 模型在测试集 SST 预测的性能比较

Fig.3 The comparative performance of 3D U-Net and ConvLSTM models in predicting SST on the test dataset
注: a: 皮尔逊相关系数 R; b: 均方根误差 RMSE

图 4 通过散点图进一步展示了 3D U-Net 模型与 ConvLSTM 模型预测的 SST 与实际观测的 SST 之间的关系。虽然两种模型的预测结果均表现出与观测值之间具有正相关性, 但 3D U-Net 模型的 RMSE 仅为 $0.53\text{ }^\circ\text{C}$, 而 ConvLSTM 模型的 RMSE 较高, 为 $0.68\text{ }^\circ\text{C}$ 。此外, 3D U-Net 模型的散点图更加密集, 显示出更强的一致性, 其 R 达到了 0.96, 而 ConvLSTM 模型的 R 则为 0.94。此外, 其他的统计指标也展示出相似的结果(表 3)。当预报超前时间为 1 d 时, 3D U-Net 模型表现优异, 其 SMAPE 为 0.83%, 相比之下, ConvLSTM 模型的 SMAPE 为 0.95%。在 MedAE 指

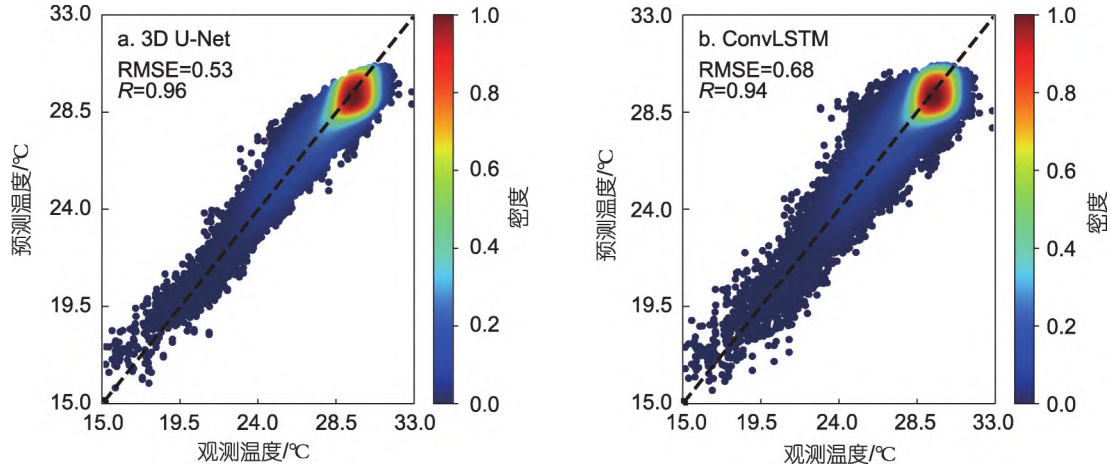


图 4 3D U-Net 模型与 ConvLSTM 模型在测试集上预测的 SST 与实际观测值的散点图比较

Fig.4 The comparison of scatter plots between predicted and observed SST in 3D U-Net and ConvLSTM models on the test dataset

标方面,3D U-Net 模型(0.18 °C)也要优于 ConvLSTM 模型(0.21 °C)。值得注意的是,随着预测超前时间延长至 7,14 和 30 d,模型误差也逐渐增加,但 3D U-Net 模型在所有指标上始终体现出更好的性能。特别是在第 30 d,即预测信息损失最严重的时候,3D U-Net 模型的 SMAPE 和 MedAE 分别为 1.90% 和 0.44 °C,仍然优于 ConvLSTM 模型的 2.02% 和 0.45 °C 的结果。显然,3D U-Net 模型具有更好的预测效果。

表 3 ConvLSTM 和 3D U-Net 模型在不同预测超前时间的 SST 预测结果的统计指标的对比

Tab.3 The comparison of statistical metrics for SST forecast results of ConvLSTM and 3D U-Net models at different leading times

模型	超前时间/d	指标	
		SMAPE	MedAE
ConvLSTM	1	0.95%	0.21
	7	1.53%	0.33
	14	1.81%	0.40
	30	2.02%	0.45
3D U-Net	1	0.83%	0.18
	7	1.39%	0.31
	14	1.65%	0.37
	30	1.90%	0.44

注: SMAPE 表示对称平均绝对百分比误差;MedAE 表示中值绝对误差;表中粗体数据表示较优的指标

2.2 3D U-Net 模型的性能评估

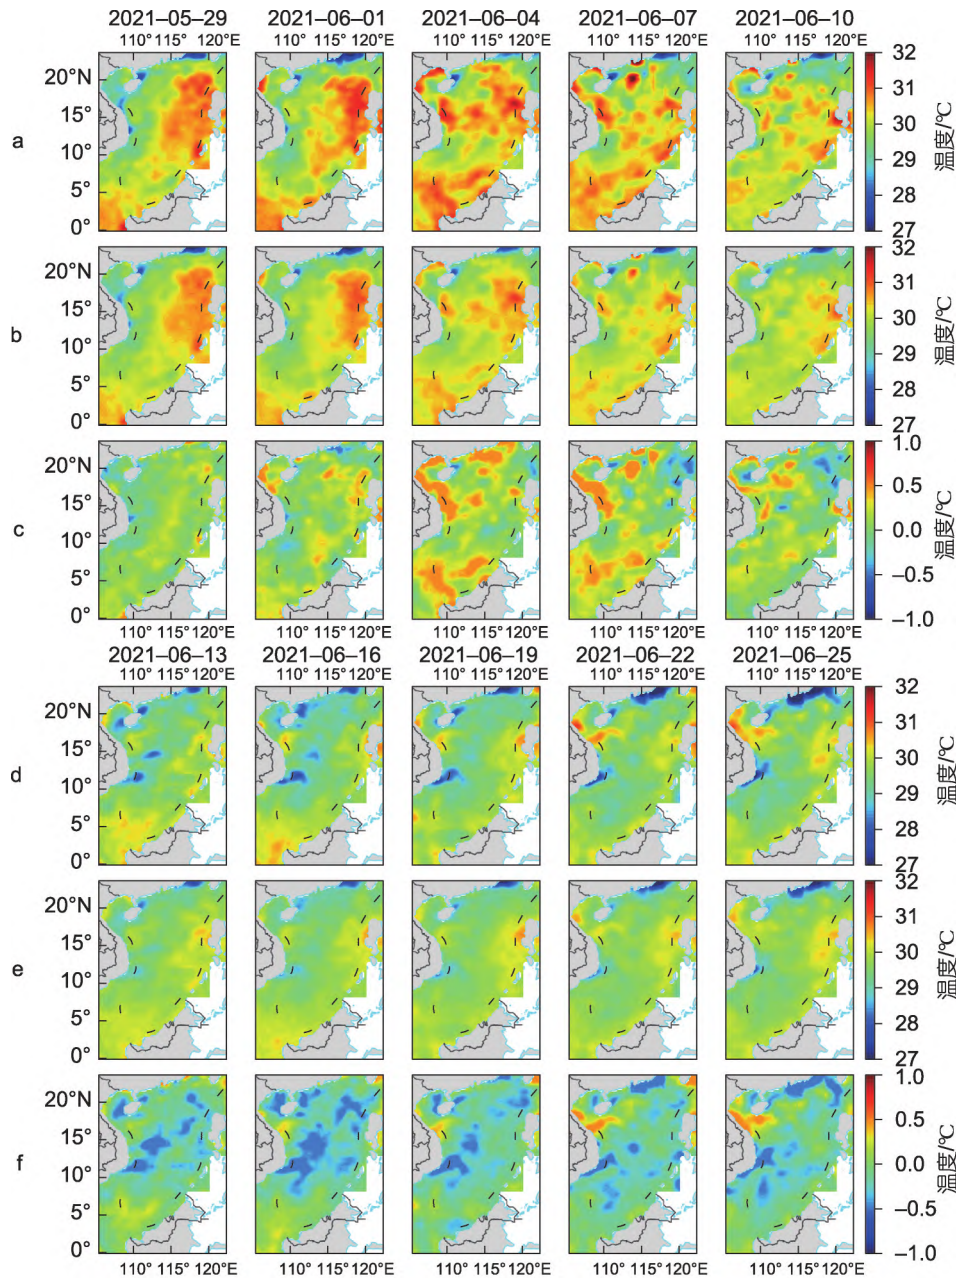
为进一步验证 3D U-Net 模型的表现,图 5 给出了 3D U-Net 模型在 2021 年南海夏季风建立(5 月 29 日)、暴发(6 月 1 日)及其暴发后期的预测结果。从上到下依次给出观测到的 SST、3D U-Net 模型的预测值,以

及它们之间的差值(即观测值减去预测值)。从图 5 中可以直观地看出,观测值与预测结果之间的差异较小,处于可接受的范围内。这表明,在南海夏季风期间,3D U-Net 模型对 SST 的预测表现较好,展示了其在复杂气象条件下具有较强的鲁棒性。

此外,本文还选择 2 月(冬季)、5 月(春季)、8 月(夏季)和 11 月(秋季)的预测结果,来验证 3D U-Net 模型在不同季节的表现。模型在四个季节预测误差(观测值减去预测值)的分布如图 6 所示。虽然 3D U-Net 模型在不同季节中存在一定程度的高估或低估情况,但是大部分误差集中在±0.5 °C 的范围内,并且其分布在 0 °C 附近,这表明尽管季节变化可能影响 SST 的预测准确性,3D U-Net 模型仍然显示出了整体上良好的季节适应性和预测准确性。

为了评估 3D U-Net 模型在南海不同区域的性能,本文还选取了四个代表性区域进行分析,如图 1b 所示,区域 A (116.5°~117.5°E, 19.5°~20.5°N)位于中国南部大陆架附近,区域 B (117.5°~118.5°E, 16.5°~17.5°N)则与西吕宋涡旋区域相对应。区域 C (114.5°~115.5°E, 11.5°~12.5°N)位于南海中南部附近,而区域 D(111°~112°E, 15.5°~16.5°N)位于东越南涡旋区域。

图 7 以直方图的形式展示了测试集中 3D U-Net 模型在南海四个不同区域预测的 SST 值与实际观测值的分布情况。结果表明,即使在 30 d 的预测期内,该模型的预测结果也能较为准确地反映出与实际观测 SST 相似的分布特征。四个区域预测误差的高斯核密度曲线均呈现出近似正态分布的特征,如图 8 所示,其中心大多位于 0 °C 附近。尤其是在区域 C 和区域 D 中,高斯核密度曲线分布更加密集,这两个区域的预测



审图号: GS(2016)1665 号

图 5 3D U-Net 模型在 2021 年南海季风盛行期的 SST 预测结果展示

Fig.5 The prediction results of SST by 3D U-Net model in the SCS during the 2021 monsoon season
注: a 和 d 为观测的 SST; b 和 e 为预测的 SST; c 和 f 为观测与预测之间的偏差

误差更小。四个区域的 RMSE 分别为 0.50、0.50、0.37、0.36 °C,而相应的 R 分别为 0.98、0.97、0.96 和 0.98,上述结果表明,3D U-Net 模型在南海不同的区域也具有较好的预测效果。

除了 RMSE 和 R 之外,3D U-Net 模型在四个区域的其他统计结果也有不错的表现,主要体现为较低的误差(表 4)。值得注意的是,虽然随着预测超前时间的增加,模型的性能略有下降,但 3D U-Net 模型的性

能在整体上仍然维持在较好的范围内。这一结果证明了该模型在南海各个区域的准确性,即使在较长时间范围的预测中也能保持较好的性能。

为了进一步评价 3D U-Net 模型的表现,本文还评估了其在预测 2021 年南海海洋热浪 (marine heatwave, MHW)事件的能力。首先是通过迭代的方式,以 30 d 为一个周期预测出 2021 年的 SST,然后根据阈值法对南海的 MHW 事件进行了间接的预测。根




图 6 3D U-Net 模型在不同季节的 30 d 预测结果的误差

Fig.6 The error in 30-day forecast results of the 3D U-Net model for different seasons

注：纵坐标表示预测误差在不同区间分布的个数

表 4 3D U-Net 模型在四个选定区域的不同超前时间的预测统计结果

Tab.4 The prediction statistics for 3D U-Net model at different leading times in four selected regions

区域	超前时间/d	指标	
		SMAPE	MedAE
A	1	0.91%	0.20
	7	1.84%	0.41
	14	2.23%	0.52
	30	2.67%	0.62
B	1	0.99%	0.22
	7	1.77%	0.41
	14	2.12%	0.48
	30	2.07%	0.48
C	1	0.67%	0.15
	7	1.28%	0.29
	14	1.56%	0.39
	30	1.63%	0.39
D	1	0.74%	0.17
	7	1.27%	0.29
	14	1.51%	0.34
	30	1.68%	0.41

注：SMAPE 表示对称平均绝对百分比误差；MedAE 表示中值绝对误差

据定义(Hobday *et al*, 2016),将 MHW 事件的相对阈值定义为对应位置的 30 年以上的平均 SST 的第 90 个百分点数。为此,本文利用 1982~2020 年的 OISST 数据来计算气候态的基准温度,阈值是以每日为中心的 11 d 的 SST 计算的,并进行 31 d 的滑动平均。如果当 SST 超过阈值至少连续 5 d 时,则被认定为 MHW 事件。此外,如果连续 MHW 事件之间的间隔少于 2 d,它们被视为同一事件。图 9 展示了 2021 年 3D U-Net 模型在预测南海 MHW 事件方面的准确率。3D U-Net 模型在南海的大部分区域预测准确率达到 80% 以上,表现出了较好的预测效果。然而,也有一些准确率较低的区域,这些区域主要集中在南海的北部,尤其是受黑潮影响较大的区域。在这些区域,复杂的动力学和热力学过程可能是导致预测准确率较低的主要因素。此外,我们对 3D U-Net 模型在预测 MHW 事件的性能进行了进一步的评估,其结果见表 5。计算结果显示,3D U-Net 模型的精确率达到了 0.89,这意味着在 3D U-Net 模型预测的 MHW 事件中,绝大多数预测结果都与实际发生的事件相符,体现了模型在识别真正 MHW 事件方面的准确性。同时,模型的召回率为 0.45,这说明尽管模型在捕捉实际发生的 MHW 事件

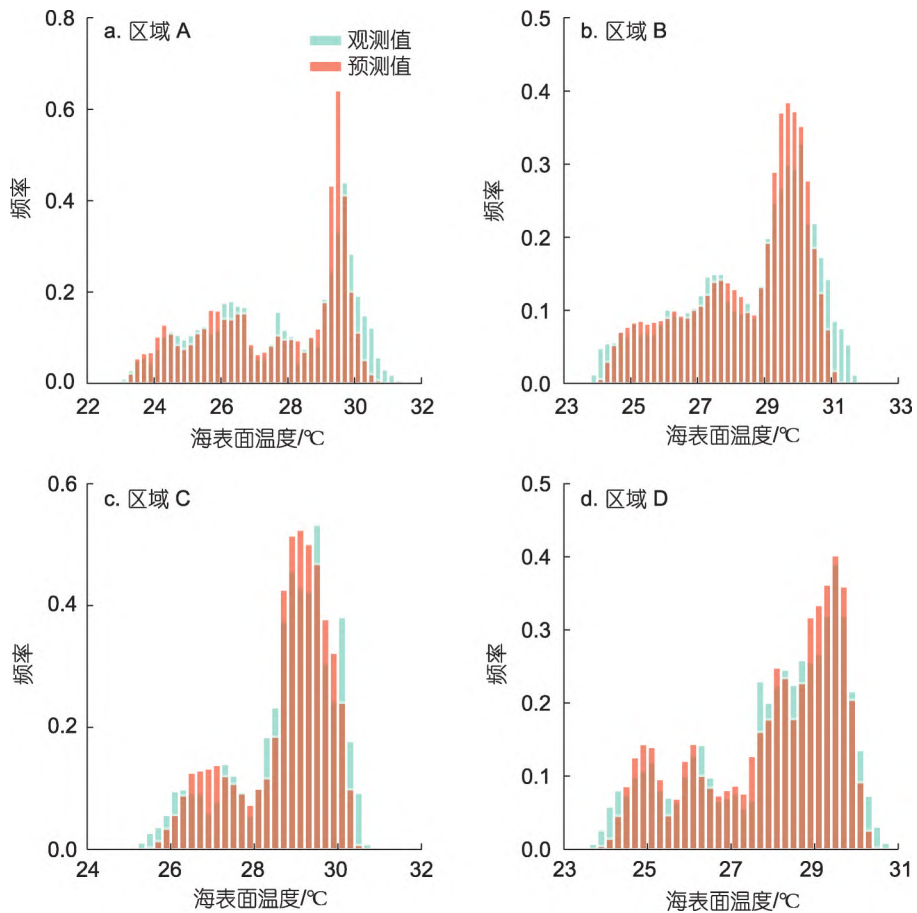


图 7 3D U-Net 模型在不同区域的预测的 SST 与观测的 SST 的直方图的对比

Fig.7 The comparison of histogram of SST predictions by the 3D U-Net model with observed SST in different regions

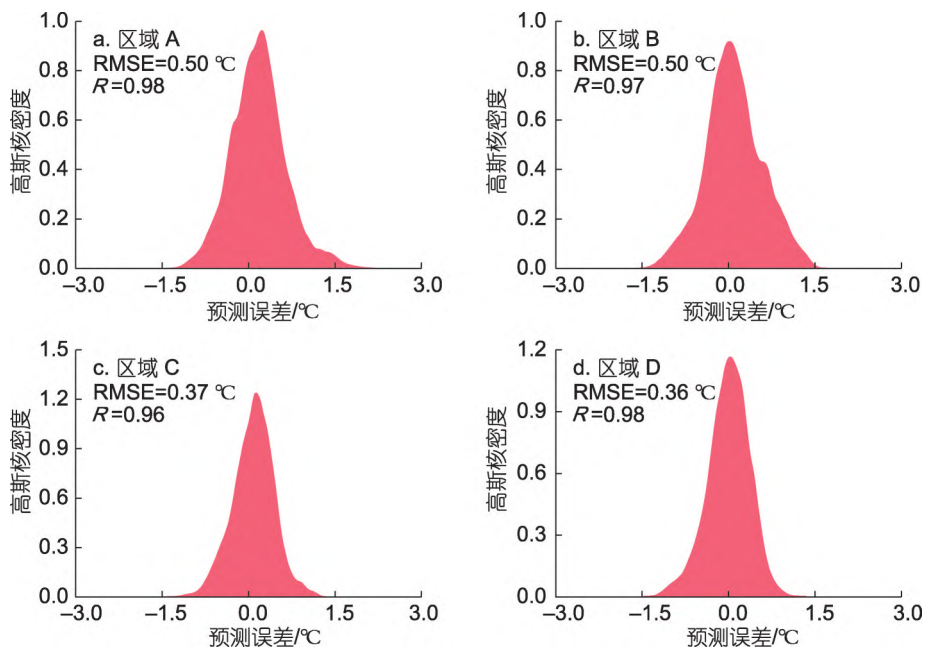


图 8 3D U-Net 在不同区域的预测误差的高斯核密度估计的结果


Fig.8 The Gaussian kernel density estimation of prediction errors by 3D U-Net in different regions
注: RMSE 和 R 是由每个区域所有的测试集的数据计算得到的

表 5 3D U-Net 模型预测 2021 年南海 MHW 事件的总体
的精准率和召回率

Tab.5 The precision and recall of the 3D U-Net model in
predicting MHW events in the SCS in 2021

模型	指标	数值
3D U-Net 模型	精确率	0.89
	召回率	0.45

注: 精确率的计算公式为 $\frac{TP}{TP+FP}$, 召回率的计算公式为 $\frac{TP}{TP+FN}$, TP 表示 MHW 发生且模型预报发生, FN 表示 MHW 发生



审图号: GS(2016)1665 号

图 9 3D U-Net 模型预测 2021 年南海 MHW 事件的准确率
Fig.9 The accuracy of the 3D U-Net model in predicting the
MHW events in the SCS in 2021

注: 准确率的计算公式为 $\frac{TN+TP}{TN+TP+FN+FP}$, TN 表示 MHW 未发生且模型预报未发生, TP 表示 MHW 发生且模型预报发生, FN 表示 MHW 发生而模型预报未发生, FP 表示 MHW 未发生而模型预报发生

方面存在一定的局限性,但仍能有效地预测出相当比例的 MHW 事件。总体而言,3D U-Net 模型展示了在南海区域较好的预测性能,这表明该模型能够以相对较低的计算成本有效预测南海的 MHW 事件。

为了探究不同海表面变量对南海 SST 预测和 MHW 事件检测的相对贡献,基于 3D U-Net 模型,本文设计了一系列的敏感性实验。图 10 展示了敏感性实验的四组配置及其结果。在第一组实验中,不仅使用了 SST 作为输入变量,还引入了 SSHA 和 SSW。第二组实验选择了 SST 和 SSW 作为预测 SST 的预测因子。而在第三组中,使用了 SST 和 SSHA。最后,在第四组实验中仅使用 SST 作为模型的输入变量。从图 10 中可以发现,在结合 SST、SSHA 和 SSW

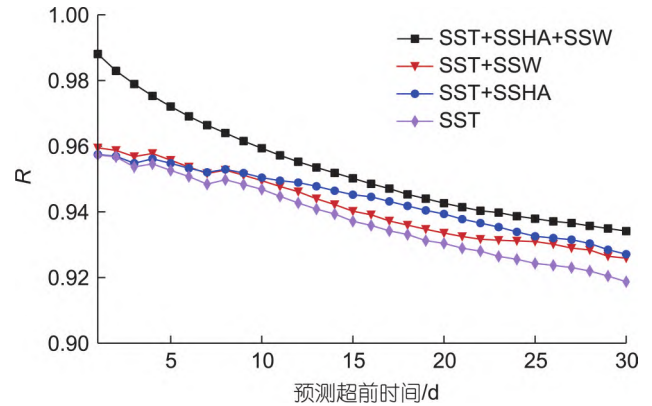


图 10 使用不同的输入变量组合的敏感性实验的结果
Fig.10 The results of sensitivity experiments using different
combinations of input variables

注: SST 表示海表面温度;SSHA 表示海表面高度异常;
SSW 表示海表面风场

进行 SST 预测的实验(第一组)中,在各个预报超前时间均显示了最高的 R 值,表明了其是最佳的预测性能。相反,仅依赖于 SST 的模型(第四组)的表现最为不佳。这两组结果表明,SSHA 和 SSW 在 SST 预测和 MHW 事件检测中起着至关重要的作用。通过第二组与第三组的比较,可以发现在预测 SST 的早期阶段,SSW 对模型的影响更为显著,而随着时间的推移,SSHA 的影响逐渐增强。敏感性实验表明,将 SSHA 和 SSW 作为模型输入变量可以显著提高 3D U-Net 模型在预测南海 SST 方面的准确性,并且 SSHA 和 SSW 在模型预测 SST 的不同阶段发挥着不同的作用。

3 结论

SST 作为海洋重要的环境参数,对其进行准确地预测至关重要。为了有效地结合多源海表数据对南海 SST 进行预测,本文提出了一个基于 3D U-Net 框架的深度学习模型。通过与 ConvLSTM 模型的对比分析,3D U-Net 模型始终展示出更好的预测效果。在从 1 d 到 30 d 的预测超前时间中,3D U-Net 模型无论是在误差还是相关性方面始终优于 ConvLSTM 模型。其预测结果的散点图在等值线附近分布更为密集, RMSE 为 $0.53\text{ }^{\circ}\text{C}$, R 为 0.96,这两个指标均优于 ConvLSTM 模型的 $0.68\text{ }^{\circ}\text{C}$ 和 0.94。在 2021 年南海夏季风建立、暴发及其暴发后期,3D U-Net 模型预测结果均表现出较小的预测误差,显示了其在复杂气象条件下具有较强的鲁棒性。在南海不同季节的预测中,大部分误差集中在 $\pm 0.5\text{ }^{\circ}\text{C}$ 的范围内,并且多数分

布在 $0\text{ }^{\circ}\text{C}$ 附近,表明模型具有不错的季节表现。此外,在南海的不同区域,模型的预测值与观测值具有相似分布特征,预测误差的高斯核密度曲线均在 $0\text{ }^{\circ}\text{C}$ 附近呈现近似正态分布,其 RMSE(R) 分别为 $0.50\text{ }^{\circ}\text{C}$ (0.98)、 $0.50\text{ }^{\circ}\text{C}$ (0.97)、 $0.37\text{ }^{\circ}\text{C}$ (0.96) 和 $0.36\text{ }^{\circ}\text{C}$ (0.98)。此外,3D U-Net 模型在 2021 年对南海大部分区域的 MHW 事件预测的准确率达到 80%,而总体上的精确率和召回率分别为 0.89 和 0.45,显示出 3D U-Net 模型能够以较低的计算成本有效预测南海 MHW 事件。敏感性实验结果表明,除了 SST 外,SSHA 和 SSW 对模型的预测性能有显著影响,并可以提高预测准确性。尤其在预测的早期阶段,SSW 对 SST 预测有显著影响,而随着预测时间的增加,SSHA 的作用逐渐增强。

总之,本文所提出的基于 3D U-Net 框架的深度学习模型在南海 SST 的预测中具有良好的表现,并且可以作为 MHW 事件预报的新方法。3D U-Net 模型的优势在于其结构简单,能够直接提取多源海面变量的特征信息,避免了破坏数据的时间连续性,同时更充分地考虑了变量之间的相互作用。然而,作为数据驱动模型,其存在一定的局限性,尤其是在 SST 和 MHW 事件的预测中可能受到海洋动力学和热力学过程的影响。此外,南海 SST 的变化还受其他环境因素影响,包括降水、辐射和叶绿素浓度等,以及与其他海域的相互作用。因此,未来的研究可以考虑纳入更多海洋变量,并使用更大范围海域来预测南海 SST,这不仅有助于模型更具有物理意义,也有助于更准确地模拟 SST 的演变规律,从而提升对 SST 和 MHW 预测的精确度。

参 考 文 献

马继瑞, 韩桂军, 李冬, 2002. 变分伴随数据同化在海表面温度预报中的应用研究[J]. 海洋学报, 24(5): 1-7.

王东晓, 王强, 蔡树群, 等, 2019. 南海中深层动力格局与演变机制研究进展[J]. 中国科学: 地球科学, 49(12): 1919-1932.

王丽娜, 宋悦, 王旭东, 等, 2023. 融合图卷积和注意力机制的 GRU 海面温度预测模型[J]. 海洋科学, 1-18(2023-09-23). <http://kns.cnki.net/kcms/detail/37.1151.P.20230922.1230.004.html>

刘俊, 唐佑民, 宋迅殊, 等, 2022. 深度学习在印度洋偶极子预报中的应用研究[J]. 大气科学, 46(3): 590-598.

刘娜, 王辉, 凌铁军, 等, 2018. 一个基于 MOM 的全球海洋数值同化预报系统[J]. 海洋通报, 37(2): 139-148.

江璟瑜, 徐丹亚, 韩宁生, 等, 2021. 基于 LSTM 的海表面高度异常预测方法[J]. 舰船电子工程, 41(2): 97-99.

孙伟富, 张杰, 孟俊敏, 等, 2018. 中国南海及邻近海域 SST 时空

分布和变化特征分析[J]. 海洋科学进展, 36(3): 402-411.

杜家豪, 聂婕, 叶敏, 等, 2023. 基于全局跨尺度时空注意力的深度神经网络海表面温度预测模型[J]. 海洋环境科学, 42(6): 944-954.

李亚蒙, 孙宝楠, 丁军航, 等, 2022. 基于 LSTM 的海洋表面短期风速预测研究[J]. 海洋科学, 46(11): 55-66.

李竞时, 匡晓迪, 李琼, 等, 2023. 基于主成分分析和 LSTM 神经网络的海温预报模型[J]. 海洋预报, 40(2): 1-10.

何忠杰, 韩桂军, 李威, 等, 2010. 中国海及邻近海域卫星观测资料同化试验[J]. 中国海洋大学学报, 40(9): 1-7.

沈红, 韩君, 曹丽霞, 等, 2014. 基于 POMgcs 模式中国海及邻近海域三维温盐流数值预报海面温度的检验分析[J]. 海洋通报, 33(1): 45-55.

张萍, 段安民, 2023. 热带海表面温度及中纬度大气环流对青藏高原 9 月降水异常的共同影响[J]. 中国科学: 地球科学, 53(3): 598-612.

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[J]. 大连海洋大学学报, 37(3): 531-538.

陆永强, 陈正华, 余克服, 等, 2022. 1985-2019 年南海诸岛珊瑚礁区热压力时空变化研究分析[J]. 海洋学报, 44(11): 179-190.

苗庆生, 徐珊珊, 杨锦坤, 等, 2022. 长短期记忆神经网络在厦门风暴潮预报中的应用[J]. 中国海洋大学学报, 52(9): 10-19.

周佩, 黄颖婕, 胡冰逸, 等, 2021. 基于 LSTM 深度学习的 ENSO 预测及其春季预报障碍研究[J]. 北京大学学报(自然科学版), 57(6): 1071-1078.

赵宏凯, 迟万清, 杨洁, 等, 2023. 基于 NARX 神经网络的极端风暴潮事件预报研究[J]. 海洋预报, 40(3): 11-18.

查铖, 贺琪, 宋巍, 等, 2020. 结合注意力机制的区域型海表面温度预报算法[J]. 海洋通报, 39(2): 191-199.

谢文鸿, 徐广珺, 董昌明, 2022. 基于 ConvLSTM 机器学习的风暴潮漫滩预报研究[J]. 大气科学学报, 45(5): 674-687.

冀蕊, 贾英来, 吴一非, 等, 2023. 冬季黑潮延伸体区海表面温度异常对山东半岛极端低温的可能影响[J]. 中国海洋大学学报, 53(1): 18-31.

APARNA S G, D' SOUZA S, ARJUN N B, 2018. Prediction of daily sea surface temperature using artificial neural networks [J]. International Journal of Remote Sensing, 39(12): 4214-4231.

ATLAS R, HOFFMAN R N, ARDIZZONE J, *et al*, 2011. A cross-calibrated, multiplatform ocean surface wind velocity product for meteorological and oceanographic applications [J]. Bulletin of the American Meteorological Society, 92(2): 157-174.

HAO P, LI S, SONG J B, *et al*, 2023. Prediction of sea surface temperature in the South China Sea based on deep learning [J]. Remote Sensing, 15(6): 1656.

HOBDAY A J, ALEXANDER L V, PERKINS S E, *et al*, 2016. A hierarchical approach to defining marine heatwaves [J]. Progress in oceanography, 141: 227-238.

HUANG B Y, LIU C Y, BANZON V, *et al*, 2021. Improvements of the daily optimum interpolation sea surface temperature

- (DOISST) version 2.1 [J]. *Journal of Climate*, 34(8): 2923-2939.
- KUG J S, KANG I S, LEE J Y, *et al*, 2004. A statistical approach to Indian Ocean sea surface temperature prediction using a dynamical ENSO prediction [J]. *Geophysical Research Letters*, 31(9): L09212.
- LI W, XIE Y H, HE Z J, *et al*, 2008. Application of the multigrid data assimilation scheme to the China Seas' temperature forecast [J]. *Journal of Atmospheric and Oceanic Technology*, 25(11): 2106-2116.
- LINS I D, ARAUJO M, MOURA M D C, *et al*, 2013. Prediction of sea surface temperature in the tropical Atlantic by support vector machines [J]. *Computational Statistics & Data Analysis*, 61: 187-198.
- LIU J, TANG Y M, WU Y L, *et al*, 2021. Forecasting the Indian Ocean Dipole with deep learning techniques [J]. *Geophysical Research Letters*, 48(20): e2021GL094407.
- LIU Q Y, JIANG X, XIE S P, *et al*, 2004. A gap in the Indo-Pacific warm pool over the South China Sea in boreal winter: Seasonal development and interannual variability [J]. *Journal of Geophysical Research: Oceans*, 109(C7): C07012.
- MIAO Y L, ZHANG C C, ZHANG X F, *et al*, 2023. A multivariable convolutional neural network for forecasting synoptic-scale sea surface temperature anomalies in the South China Sea [J]. *Weather and Forecasting*, 38(6): 849-863.
- NAMIAS J, CAYAN D R, 1981. Large-scale air-sea interactions and short-period climatic fluctuations [J]. *Science*, 214(4523): 869-876.
- QI J F, LIU C Y, CHI J W, *et al*, 2022. An ensemble-based machine learning model for estimation of subsurface thermal structure in the South China Sea [J]. *Remote Sensing*, 14(13): 3207.
- QI J F, QU T D, YIN B S, 2023a. Meta-learning-based estimation of the barrier layer thickness in the tropical Indian Ocean [J]. *Environmental Research Communications*, 5(9): 091005.
- QI J F, SUN G M, XIE B W, *et al*, 2024. Deep learning to estimate ocean subsurface salinity structure in the Indian Ocean using satellite observations [J]. *Journal of Oceanology and Limnology*, 42(2): 377-389.
- QI J F, XIE B W, LI D L, *et al*, 2023b. Estimating thermohaline structures in the tropical Indian Ocean from surface parameters using an improved CNN model [J]. *Frontiers in Marine Science*, 10: 1181182.
- QI J F, ZHANG L L, YIN B S, *et al*, 2023c. Advancing ocean subsurface thermal structure estimation in the Pacific Ocean: A multi-model ensemble machine learning approach [J]. *Dynamics of Atmospheres and Oceans*, 104: 101403.
- REN Y B, LI X F, 2023. Predicting the daily sea ice concentration on a sub-seasonal scale of the pan-arctic during the melting season by a deep learning model [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 4301315.
- RONNEBERGER O, FISCHER P, BROX T, 2015. U-net: Convolutional networks for biomedical image segmentation [C]// *Proceedings of the Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015*. Munich: Springer: 234-241.
- SHAO Q, LI W, HAN G J, *et al*, 2021. A deep learning model for forecasting sea surface height anomalies and temperatures in the South China Sea [J]. *Journal of Geophysical Research: Oceans*, 126(7): e2021JC017515.
- SHI X J, CHEN Z R, WANG H, *et al*, 2015. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [C]// *Proceedings of the 28th International Conference on Neural Information Processing Systems*. Cambridge: MIT Press: 820-810.
- SONG T, JIANG J Y, LI W, *et al*, 2020. A deep learning method with merged LSTM neural networks for SSHA prediction [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 2853-2860.
- STOCKDALE T N, BALMASEDA M A, VIDARD A, 2006. Tropical Atlantic SST prediction with coupled ocean-atmosphere GCMs [J]. *Journal of Climate*, 19(23): 6047-6061.
- TAYLOR J, FENG M, 2022. A deep learning model for forecasting global monthly mean sea surface temperature anomalies [J]. *Frontiers in Climate*, 4: 932932.
- VAID B H, PREETHI B, KRIPALANI R H, 2018. The asymmetric influence of the South China Sea biweekly SST on the abnormal Indian monsoon rainfall of 2002 [J]. *Pure and Applied Geophysics*, 175(12): 4625-4642.
- WANG Y H, YUAN X J, REN Y B, *et al*, 2023. Subseasonal prediction of regional Antarctic sea ice by a deep learning model [J]. *Geophysical Research Letters*, 50(17): e2023GL104347.
- XIAO C J, CHEN N C, HU C L, *et al*, 2019. Short and mid-term sea surface temperature prediction using time-series satellite data and LSTM-AdaBoost combination approach [J]. *Remote Sensing of Environment*, 233: 111358.
- XUE Y, LEETMAA A, 2000. Forecasts of tropical Pacific SST and sea level using a Markov model [J]. *Geophysical Research Letters*, 27(17): 2701-2704.
- YANG Y T, DONG J Y, SUN X, *et al*, 2018. A CFCC-LSTM model for sea surface temperature prediction [J]. *IEEE Geoscience and Remote Sensing Letters*, 15(2): 207-211.

INTELLIGENT PREDICTION OF SEA SURFACE TEMPERATURE IN THE SOUTH CHINA SEA BASED ON DEEP LEARNING

XIE Bo-Wen^{1,3}, ZHANG Cong², YANG Shu-Guo¹, FENG Zhong-Kun^{1,3}, SUN Gui-Min^{3,4}

(1. *School of Mathematics and Physics, Qingdao University of Science and Technology, Qingdao 266061, China*; 2. *Marine Science Research Institute of Shandong Province, Qingdao 266104, China*; 3. *Key Laboratory of Ocean Circulation and Waves,*

Institute of Oceanology, Chinese Academy of Sciences, Qingdao 266071, China;

4. *University of Chinese Academy of Sciences, Beijing 100049, China*)

Abstract Sea surface temperature (SST) is one of the crucial factors affecting ocean and climate change, and accurately predicting SST variations is vital for marine ecological environments, meteorology, and navigation. Traditional SST prediction methods typically rely on numerical models, which have high computational costs. A rapid and intelligent forecasting model for SST in the South China Sea (SCS) is developed based on a deep learning model (3D U-Net), using SST, sea surface height anomalies (SSHA), and sea surface wind (SSW) as input variables. Results indicate that compared to the convolutional long short-term memory (ConvLSTM) model, the 3D U-Net model shows higher accuracy across all prediction times, with a root mean square error (RMSE) of 0.53 °C and a Pearson correlation coefficient (R) of 0.96. In various seasons and regions of the SCS, the 3D U-Net model exhibits consistently smaller prediction errors and maintains robust performance during monsoon seasons. Moreover, in predicting marine heatwave (MHW) events in the SCS in 2021, the model achieves over 80% accuracy in most sea areas. The overall precision and recall rates are 0.89 and 0.45 respectively. Sensitivity experiments reveal that SSHA and SSW significantly influence the model's predictive performance, playing different roles at various forecasting stages. Therefore, the 3D U-Net model, combined with multi-source sea surface data, can predict SST in the SCS quickly and precisely, offering a new method for predicting MHW events.

Key words sea surface temperature; 3D U-Net model; deep learning; South China Sea; marine heatwave