

利用 LSTM 对赤道太平洋海表面温度短期预报

张桃^{1,2}, 林鹏飞^{1,2*}, 刘海龙^{1,2}, 郑伟鹏^{1,2}, 王鹏飞^{1,2},
徐天亮³, 李逸文^{1,2}, 刘娟⁴, 陈铖⁵

1 中国科学院大气物理研究所大气科学与地球物理流体动力学数值模拟国家重点实验室, 北京 100029

2 中国科学院大学地球与行星科学学院, 北京 100049

3 哈尔滨工业大学电子与信息工程学院, 哈尔滨 150001

4 北京应用气象研究所, 北京 100029

5 西北工业大学航海学院, 陕西 710072

摘要 海表面温度作为海洋中一个最重要的变量, 对全球气候、海洋生态等有很大的影响, 因此十分有必要对海表面温度 (SST) 进行预报。深度学习具备高效的数据处理能力, 但目前利用深度学习对整个赤道太平洋的 SST 短期预报及预报技巧的研究仍较少。本文基于最优插值海表面温度 (OISST) 的日平均 SST 数据, 利用长短期记忆 (LSTM) 网络构建了未来 10 天赤道太平洋 (10°S-10°N, 120.0°E-280°E) SST 的逐日预报模型。LSTM 预报模型利用 1982-2010 年的观测数据进行训练, 2011-2020 年的观测数据作为初值进行预报和检验评估。结果表明: 赤道太平洋东部地区预报均方根误差 (RMSE) 大于中、西部, 东部预报第 1 天 RMSE 为 0.6℃ 左右, 而中、西部均小于 0.3℃。在不同的年际变化位相, 预报 RMSE 在拉尼娜出现时期最大, 正常年份次之, 厄尔尼诺时期最小, RMSE 在拉尼娜时期比在厄尔尼诺时期可达 20%。预报偏差整体表现为东正、西负。相关预报技巧上, 中部最好, 可预报天数基本为 10 天以上, 赤道冷舌附近可预报天数为 4-7 天, 赤道西边部分地区可预报天数为 3 天。预报模型在赤道太平洋东部地区各月份预报技巧普遍低于西部地区, 相比较而言各区域 10、11 月份预报技巧最低。总的来说, 基于 LSTM 构建的 SST 预报模型能很好地捕捉到 SST 在时序上的演变特征, 在不同案例中预报表现良好。同时该预报模型依靠数据驱动, 能迅速且较好预报未来 10 天以内的日平均 SST 的短期变化。

关键词 海表面温度; LSTM; 短期预报; 赤道太平洋

文章编号

doi:10.3878/j.issn.1006-9895.2302.22128

收稿日期 **网络预出版日期**

作者简介 张桃, 男, 1999 年 8 月出生, 硕士研究生, 主要从事动力和智能预报研究。E-mail: zhangtao22@mailsucas.ac.cn

通讯作者 林鹏飞, 主要从事海洋模式发展与应用研究, E-mail: linpf@mail.iap.ac.cn

资助项目 国家重点基础科学发展计划(批准号:2020YFA0608902)、国家自然科学基金(批准号:41976026、41931183)和中科院重点部署项目(批准号: KGFZD-145-22-07)

Funded by the National Key Program for Developing Basic Sciences of China (Grant No. 2020YFA0608902), the National Natural Science Foundation of China (Grant Nos. 41976026 and 41931183), and the Chinese Academy of Sciences key deployment project (Grant No. KGFZD-145-22-07)

Short-term sea surface temperature forecasts in the equatorial Pacific based on LSTM

Tao Zhang^{1,2}, Pengfei Lin^{1,2*}, Hailong Liu^{1,2}, Weipeng Zheng^{1,2}, Pengfei Wang^{1,2},

Tianliang Xu³, Yiwen Li^{1,2}, Juan Liu⁴, Cheng Chen⁵

¹State Key Laboratory of Numerical Modeling for Atmospheric Sciences and Geophysical Fluid Dynamics (LASG), Institute of Atmospheric Physics, Chinese Academy of Sciences, Beijing 100029, China

²College of Earth and Planetary Sciences, University of Chinese Academy of Sciences, Beijing 100049, China

³School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150001, China

⁴Beijing Institute of Applied Meteorology, Beijing, 100049, China

⁵School of Marine Science and Technology, Northwestern Polytechnical University, Shaanxi 710072, China

Abstract: As one of the essential variables in the ocean, sea surface temperature (SST) and its change significantly impact global climate and marine ecology, so it is necessary to forecast the sea surface temperature. Deep learning is highly efficient at data processing, but it is rarely used in short-term forecasting of equatorial Pacific SST pattern. Based on Long Short-term Memory (LSTM) network, this paper constructs a daily forecast model of SST in the tropical Pacific Ocean (10°S-10°N, 120.0°E-280°E) in the next ten days. Using observations from 1982-2010 as a train set and data from 2011-2020 as a test set, the model forecasts the SST. The results show that the forecast Root Mean Square Error (RMSE) in the eastern equatorial Pacific region is larger than that in the central and western areas. The RMSE of the east basin is about 0.6°C on the first day of the forecast, while the west and central regions are less than 0.3°C. The forecast skill is examined for different phases of ENSO, RMSE is the largest in the La Niña period, followed by normal years, and the smallest in the El Niño period. RMSE in the La Niña period is more than 20% in some regions than in the El Niño period. The forecast error is positive in the east and negative in west. The number of predictable days is more than ten days. Specifically, the number of predictable days near the equatorial cold tongue is 4-7 days, and the number of predictable days in the western equator regions is three days. It shows lower forecast skills in the eastern equatorial Pacific regions than in the western regions. For the skills at different months, the skill is lower in the October and November than the other months. In general, the SST forecast model based on LSTM can well capture the evolution characteristics of SST time series, and the forecast performance is high in the pan-tropical Pacific regions. Furthermore, the running time of the proposed data-driven forecast model is very fast and more efficient than traditional dynamical models in predicting the daily average SSTs in the next ten days.

Key words: Sea surface temperature; LSTM; Short-term forecasts; Equatorial Pacific Ocean

1 引言

海表面温度 (SST) 在海-气相互作用中起非常重要作用, 是全球气候变化一个关键要素 (Wentz et al., 2000)。SST 变化会影响全球降水的分布, 导致极端干旱或者旱涝事件发生 (Rauscher et al., 2015; Salles et al., 2016); 近期的海洋热浪频发已经严重破坏全球的海洋生态系统 (Cane et al., 1997; Friedel, 2012; Castro et al., 2016; Chaidez et al., 2017; Bouali et al., 2017)。因此 SST 的预测与预报显得尤为重要, 是一个热点研究问题。SST 预测指对未来 SST 较长时期 (延伸期、月、季、年) 的统计特征做出预测, SST 预报指对未来较短时间内 (10 天左右) SST 状态做出预报。

在热带太平洋, 经常出现 SST 冷热交替的厄尔尼诺和拉尼娜事件, 这种冷热交替构成了 El Niño Southern Oscillation (ENSO) 循环 (Neelin et al., 1998; Capotondi et al., 2015), ENSO 循环对全球气候、生态系统、经济、人类活动等有很大的影响 (McPhaden et al., 2006)。因此有必要提高 ENSO 的预测技巧, 研究人员采用了传统的统计预测、基于物理过程的动力模式预测以及最近兴起的深度学习预测 (Latif et al., 1994; Jin et al., 2008; Tippett et al., 2012; Tang et al., 2018; Ham et al., 2019; Zhao et al., 2020)。ENSO 预测为季节和年际时间尺度的预测, 一般以月平均要素为单位, 如月平均 SST。而 SST 更短时间尺度 (天为单位) 的变化 (本文称为短期变化) 对 ENSO 和气候系统有重要影响, Edwards et al. (2006) 研究指出赤道太平洋开尔文波 (Kelvin) 可以将热带大气季节内振荡 (MJO) 或者西风异常和 ENSO 暖事件联系起来; 赤道东太平洋的热带不稳定波 (TIWs) 可能会影响 ENSO 的不规则性和可预报性 (Holmes et al., 2019)。海洋表面短期热事件 (HE) 的堆积, 在暖 SST 的背景下, 易产生气候影响 (Wirasatriya et al., 2020)。同时, SST 短期变化也会影响海洋生态系统, 持续的高海温可能导致鱼类的死亡, 给渔业造成严重的经济损失 (Kim et al., 2020)。

随着计算机进一步发展, 深度学习方法在面对海量数据时表现出较好的效果, 该方法捕获 SST 不同尺度变化特征也展现出一定优势。不同的深度学习算法和模型结构被用于改进 ENSO 预测 (He et al., 2019; Mu et al., 2019; Yan et al., 2020; Geng et al., 2021; 刘俊等, 2022), 如 Ham et al. (2019) 利用卷积神经网络 (CNN) 算法构建的深度学习模型可以提前 18 个月实现对 ENSO 预测, 而动力模式只能提前 12 个月预测。在 SST 短期预报方面, 基于长短期记忆网络 (LSTM), 门循环单元 (GRU) 算法构建的预报模型也被应用到不同的海域特定站点, 如中国东海、中国南海、印度洋等, 其结果均优于支持回归机 (SVR)、自回归移动平均模型 (ARIMA) 和循环神经网络 (RNN) 等算法 (Zhang et al., 2017; Xiao et al., 2019; Sarkar et al., 2020; Jia et al., 2022)。

这些研究表明深度学习用于 SST 预报是可行的和有一定优势。但是, 上述研究所使用的 LSTM 和 GRU 算法都是针对特定地点的, SST 短期预报局限于少数几个站点。由于不同海域不同地点的 SST 变化有很大的差异, 对于 LSTM 算法在 SST 预报中对数据的兼容性和稳定性还有待进一步研究。在赤道太平洋, 基于深度学习应用 SST 短期预报上仍较少, 一个原因是关注点主要集中在 ENSO 预测上。最近, 深度学习方法在该区域应用, Zheng et al. (2020) 利用 CNN 算法构建 5 天热带东太平洋 SST 预报模型预报 TIWs。已有一些研究表明, CNN 算法不能很好的提取到时序特征, 在赤道太平洋地区所构建的 SST 短期预报模型还有待改善。

本文首先基于 LSTM 测试了单点 SST 的训练和短期预报效果, 在单点确定好 LSTM 网络和参数后, 逐点学习, 构建了赤道太平洋的 SST 短期预报模型。利用构建的模型对赤道太平洋 SST 进行训练和短期 (10 天) 预报, 利用均方根误差 (RMSE)、皮尔逊相关系数 (R)、偏差 (Bias) 作为评价指标评估了模型在赤道太平洋地区 SST 短期 (10 天以内) 预报技巧。具体而言, 本文先挑选东中西三个点测试模型以确定模型参数, 然后在区域上各点分别训练模型。利用训练好的模型, 在所选区域试报十年, 利用均方根误差 (RMSE)、预报相关 (R)、预报偏差 (Bias) 作为评价指标分别评估了该预报模型在赤道太平洋地区不同月份、不同区域的表现。我们基于 LSTM 构建的深度学习模型成功对赤道太平洋 SST 进行短期 (10 天) 预报, 并利用不同评价指标对结果评测。我们的研究表明深度学习方法在海洋要素预报中具有强大潜力。

2 方法, 数据、试验和评估方法

2.1 LSTM 介绍

本文采用 LSTM 来进行研究, 因为 LSTM 网络具有长时记忆、学习速度快等优点, 在时序数据的预测上表现良好, 部分改善早期网络存在的长期依赖特点, 以及解决在长期预测时容易产生的梯度消失问题。本文采用的 LSTM 深层神经网络是以 Keras 为后端 (Francois, 2015), 使用 TensorFlow 2.1 (Abadi et al., 2016) 实现的。关于 LSTM 网络, 详情参见原文 (Hochreiter et al., 1997)。

基于 LSTM 网络结构, 本文构建了 5 层深度学习神经网络模型预测海表面温度短期变化 (图 1)。首先设定 5 层网络初始结构, 在不同层设置不同神经元个数进行试验, 如第一个 LSTM 层神经元个数分别设置为 40, 50, ..., 100, 其他层设置类似, 得到不同的参数设置组合。为了防止模型过拟合以及提高模型拟合效果, 以训练集和测试集均方误差 (MSE) 相近和测试集 MSE 尽可能小为原则, 挑选得到最终网络结构和参数如下。LSTM 网络包括一个输入层, 两个 LSTM 层, 两个全连接层。输入数据为过去 10 个时间步 SST 数据, 其中第一 (二) 个 LSTM

M 层分别有 70 个和 50 个神经元，为防止过拟合，分别在 LSTM 层进行 Dropout 方法正则化，各层神经元失活（不起作用）概率为 0.2。第一（二）个全连接层分别为 40 个和 10 个神经元。训练的输入层为一个合成三维数组，数组中包括输入的变量个数，本文为 1 个，为去掉季节循环后的 SST（记为 SSTA），预测时间输入长度，本文设为 10 天，以及输入训练的样本数。模型的输出层为一个二维数组，分别是样本数及其相对应的未来 10 天 SSTA 的预报值（加上季节循环还原为 SST）。




图 1 基于 LSTM 构建的网络结构 ($X_t, X_{t-1}, \dots, X_{t-n+1}$ 表示过去 n 天 SST, $X_{t+1}, X_{t+2}, \dots, X_{t+10}$ 表示未来 10 天 SST; P 为正则化层神经元失活（不起作用）概率; 括号内数字为各层神经元个数)

Fig.1 Network structure based on LSTM ($X_t, X_{t-1}, \dots, X_{t-n+1}$ represents the last n days SST, $X_{t+1}, X_{t+2}, \dots, X_{t+10}$ indicates the SST of the next ten days; P is the probability of deactivation (non-function) of neurons in the regularization layer; The number in each layer is the number of neurons in each layer)

2.2 数据

本文所用的数据为美国国家海洋和大气管理局（NOAA）第 2 版的日最优插值海表面温度（OISST, version 2） $1/4^\circ$ (Reynolds et al., 2007)。OISST 的时间范围为 1981 年 9 月到 2022 年 3 月，空间分辨率为全球 0.25° 。我们的研究区域为赤道太平洋，范围为 10°S - 10°N , 120.0°E - 280°E 。数据的时间范围为 1982 年至 2021 年。因为 LSTM 基于单点进行训练，为了节省训练的成本，空间上间隔 2.5° 选取一个点。

为了研究年际变化强弱事件对预报结果的影响，利用基于 HadlSST1 资料的 Niño 3.4 指数 (Rayner et al., 2003) 大小来判断厄尔尼诺年、拉尼娜年或者正常年份，当 Niño 3.4 指数分别大于 0.5°C /小于 -0.5°C 连续达到 6 个月以上为标准来判断厄尔尼诺年和拉尼娜年，在 -0.5°C 和 0.5°C 间则为正常年。Niño 3.4 指数通过利用区域 5°S - 5°N 和 170°W - 120°W 的 averages 的 SST 异常计算得到，SST 异常通过减去 1981 至 2010 年的气候月平均态计算得到。

2.3 试验

2.3.1 设计

首先选择 (89.975°W, 0.125°N), (169.875°W, 0.125°N), 和 (125.125°E, 0.125°N) 三个点开展训练和预报试验来测试赤道东、中、西太平洋三位置 SST 的预报技巧。

在进行深度学习研究时, 训练样本和预报样本严格分开。训练样本选定为 1982-2010 年共 29 年的数据, 数据前 90% 作为训练集, 后 10% 作为验证集, 用于调整网络结构和参数。预报采用 2011-2020 年的日数据 (共 3650 天) 进行预报, 每天均往前预报 10 天, 将预报结果与 OISS T 对应的日数据进行比较, 计算了 Bias、RMSE、R 以评估预报结果。

本文还比较了预报结果在不同月份上的差异, 通过比较沿赤道 (南北纬 2° 作平均) 和不同经度 (沿着 130.125°E, 179.875°W, 139.875°W) 预报误差变化来展示其变化。

2.3.2 数据前处理

在将海温数据输入训练时, 先对原始 SST 数据作去季节循环处理, 然后将去季节循环后的时序数据归一化处理。已有研究表明, 将输入模型的数据去季节循环后再训练可以提高模型的性能 (Nelson et al., 1999)。将数据归一化可以加快梯度下降求最优解的速度, 同时还可以提高模型的精度 (Singh and Singh, 2020)。其中对时序序列去季节循环可由原始数据减去多年月平均得到, 本文多年月平均以 1982 年至 2011 年计算得到。

将每个去季节趋势后的数据 SSTA 输入模型训练前用归一化处理, 将数据映射到 $[a, b]$ 区间。计算公式如下:

$$X_{std} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

$$X_{scaled} = X_{std} * (b - a) \quad (2)$$

其中 X_{min} 、 X_{max} 为输入序列的最小值和最大值, a 、 b 为数据映射区间的最小、最大边界值, 本文 $a = 0, b = 1$ 。

2.4 评估指标

为评估模型的预报技巧, 本文采用 Bias, RMSE 以及 R 来进行。这些指标定义如下:

$$Bias = SSTA'_i - SSTA_i \quad (3)$$

$$RMSE_M = \sqrt{\frac{\sum_{j=1}^n (SSTA_{M_j} - SSTA'_{M_j})^2}{n}} \quad (4)$$

$$R = \frac{\sum_{i=1}^n (SSTA_i - \overline{SSTA})(SSTA'_i - \overline{SSTA'})}{\sqrt{\sum_{i=1}^n (SSTA_i - \overline{SSTA})^2} \sqrt{\sum_{i=1}^n (SSTA'_i - \overline{SSTA'})^2}} \quad (5)$$

上面三式中, $SSTA_i$ 与 $SSTA'_i$ 分别对应观测 $SSTA$ 以及所对应时刻模型预报值, $\overline{SSTA}$ 与 $\overline{SSTA'}$ 分别是观测数据的平均值与预报数据的平均值。 $RMSE_M$ 表示预报模型中预报第 M 天时所对应的RMSE。 n 为预报的总样本数, 本文如没有特别说明为 3650, $SSTA_{M_j}$ 为预报第 M 天所对应的观测 $SSTA$ 值, $SSTA'_{M_j}$ 为模型预报第 M 天的值。

3 结果

3.1 运行时间

在进行 SST 预报时, 往往要求在较短时间内完成预报, 因此有必要对所构建的模型预报时间进行测评。我们在测试好模型参数后, 对模型训练所需时间以及模型训练结束后预报时间进行了测试。我们的测试的硬件环境为英伟达 RTX3070Ti(8G), 软件环境为 TensorFlow 2.1 框架。表 1 给出了训练预报模型和在不同初始场下的运行时间。所选研究区域共 1088 个格点, 其中有效格点为 1055 个, 陆地或缺测格点为 33 个。用于模型训练的训练集共 10854 个样本, 模型测试共 3650 个样本。模型训练共花费 4 小时 47 分, 平均每个样本花费 1.57 秒完成一次模型参数更新。模型训练结束后, 对 3650 个样本进行了试预报总共用时 1 小时 42 分钟, 平均每个样本花费 1.69 秒, 即预报模型仅需要 1.69 秒就可以预报未来 10 天赤道太平洋地区 SST 变化情况。经过上述分析, 所构建的模型能迅速的对短期内 SST 变化做出预报。

表 1 模型训练集和测试集运行时间

	总格点数	样本数	单样本运行时间	总运行时间
训练集	1055	10954	1.57 秒	4 小时 47 分
测试集	1055	3650	1.69 秒	1 小时 42 分

3.2 单点预报技巧

图 2 显示赤道太平洋东、中、西三个点 SST 预报模型不同预报天数的 RMSE, 随着预报天数的增加, RMSE 呈现单调增加的趋势。从 RMSE 差异来看, 中西赤道太平洋的预报效果好, 表现为 RMSE 较小, 10 天内均小于 0.5°C , 第 1 天的 RMSE 小于 0.3°C ; 而赤道太平洋东预报差, RMSE 较大第 1 天预报误差接近 0.45°C 。与预报偏差结合可以看到, LSTM 预报的赤道太平洋东部点从第 1-10 天的预报偏差均为正, 随预报天数增加递增, 中、西部的点则比较小, 因此通过调整网络和参数可能会改进赤道太平洋东部点的预报偏差甚至 RMSE。

预报模型在位于东部的点上预报 RMSE 随时间增加增长较快, 第一天为 0.45°C , 第 5 天为 1.0°C 。相比之下, 赤道太平洋中、西两个点 RMSE 增长比较缓慢, 第 1 天预报 RMSE 接近 0.25°C , 到第 10 天预报 RMSE 仅 0.45°C 左右, 但中西部两点偏差随预报时间增加呈现也有所不同, 中、西部点偏差一直较小, 西部点偏差约为 -0.01°C , 中部点偏差约为 -0.05°C , 随预报时间增加变化不大。

对于预报 SST 和观测 SST 相关系数的预报技巧而言, 三个点表现也不同。总体而言, 中部点前 10 天的相关系数均大于 0.6, 相关系数到第 10 天仍较高, 约为 0.9, 西部点相关系数从第

1 天的 0.9 降低为第 9 天的低于 0.6，而东部点相关系数从第 1 天的 0.95 降低为第 6 天的低于 0.6。上面说明，预报技巧较高的是中部点，其次是西部点，最后是东部点。




图 2 不同点构建的 10 天预报模型所对应不同 Lead Time 的 (a) : RMSE, (b) : Bias, (c) : R; P1: (125.125°E, 0.125°N) , P2: (169.875°W, 0.125°N) , P3: (89.975°W, 0.125°N)

Fig.2 The 10-day forecast model constructed at different points corresponds to (a): RMSE, (b): Bias, (c): R; P1: (125.125°E, 0.125°N), P2: (169.875°W, 0.125°N), P3: (89.975°W, 0.125°N)

3.3 区域预报技巧

图 3 显示了预报模型在赤道太平洋预报的区域 RMSE 和 Bias。区域 RMSE 和 Bias 显示的结果与单点结果基本一致，误差随预报时间变长增加，预报模型在赤道太平洋中部预报误差较小，西部预报效果次之，东部预报误差最大。第 1 天，RMSE 最大位于赤道东太平洋和秘鲁沿岸，最大约为 0.6°C，与太平洋冷舌位置重合，该大 RMSE (0.4°C) 可以延伸到 130°W，第 5 天，RMSE 超过 0.4°C 延伸到 170°E，最大中心超过 1.2°C，第 10 天，最大中心超过 1.4°C，超过 1.4°C 和西太平洋超过 0.4°C 连在一起。除了东太平洋 RMSE 较大外，在 10°N, 90°W 附近，RMSE 从第 1 天开始就比较大，RMSE 大于 0.4°C，随着预报时间变长 RMSE 增加，从第 5 天到 0.8°C，第 10 天出现 1.0°C。在西太平洋，第 1 天的 RMSE 稍大于 0.2°C，第 5 天 RMSE 增大并往东扩展，稍大于 0.4°C，第 10 天 RMSE 略微增大，范围扩大。RMSE 最小 (<0.2°C) 的位置位于 5°S-10°S, 160°W-110°W 和 5°N-10°N, 170°E-150°W，且太平洋北部的小 RMSE 范围明显小。

结合偏差图说明，赤道东太平洋 RMSE 大与刚开始出现较大偏差有关，第 1 天出现明显的偏差正负相间的结构，可能与 TIWs 有关；随着时间增加，赤道东太平洋的偏差以正偏差为主，从秘鲁沿岸一直扩展到赤道上，第 5 天的偏差在 140°W 以东均超过 0.2°C，第 10 天偏差进一步向西扩展到 150°W 和向南扩展。在赤道中太平洋，日界线附近，偏差随预报时间变长一直保持在 -0.1°C 左右，负的偏差范围略有缩小，受东太平洋暖偏差影响。太平洋 7°N-10°N, 140°

W-110°W, 也存在一定负的偏差范围, 这个范围也变化不大。西太平洋的偏差较小, 150° E 以西的南赤道太平洋偏差约在 0.1℃。




图 3 10 天预报模型预报十年 (2011-2020 年) 对应不同 Lead Time (a, b, c: RMSE 分布图, 单位: °C; d, e, f: Bias 分布图, 单位: °C), 分别对应 1、5、10 天

Fig.3 The 10-day forecast model forecasts for ten years (2011-2020) corresponding to different Lead Time (a, b, c: RMSE distribution map, unit: °C; d, e, f: Bias distribution map, unit: °C), corresponding to 1, 5, and 10 days, respectively

大尺度年际变化与局地 SST 短期变化往往存在相互作用, 这同时会导致短期预报初值场的改变。因此, 了解在不同年际事件下误差分布情况, 对于进一步提高模型预报的准确率是十分有必要的。依据不同年际事件发生时段, 将测试集 (2011-2020 年) 分成拉尼娜时期, 厄尔尼诺时期, 正常年份 3 个类别分别计算 RMSE 空间分布 (图 4)。在不同年际事件时期, RMSE 空间分布整体形态一致, 均表现为东高西低。在不同年际事件时期, 误差大小则有较大差异。具体而言, 拉尼娜时期最大, 正常年份次之, 厄尔尼诺时期最小。误差大小差异随预报天数增加逐渐明显, 预报 1 天时, 3 个类别误差空间分布以及误差大小基本一致, 但拉尼娜时期稍大, 厄尔尼诺时期稍小; 预报 5 天时, 拉尼娜时期误差明显高于其他两个时期, 拉尼娜时期比厄尔尼诺时期的 RMSE 在一些区域超过 20%; 预报 10 天时, 误差进一步增加, 差异更加明显。总而言之, 相较于厄尔尼诺时期, 拉尼娜时期误差更大, 可预报性更低。这个结果与物理过程相对应, 在拉尼娜时期 TIWs 和赤道东太平洋洋流活动加强, 经向 SST 梯度也会增加 (Yu & Liu, 2003)。而厄尔尼诺期间经向 SST 梯度减小, TIWs 活动减弱 (Vialard et al., 2001)。




图 4 10 天预报模型在不同事件下 RMSE 分布图 (a, b, c: 拉尼娜; d, e, f: 厄尔尼诺; g, h, i: 正常时期)

Fig. 4 RMSE distribution of 10-day forecast model under different events (a, b, c: La Niña period; d, e, f: El Niño period; g, h, i: normal period)

根据预报和观测 SST 相关系数在预报第几天仍大于 0.6 来确定该预报点的预报技巧, 称为可预报天数, 如图 5 所示。赤道太平洋地区不同位置可预报天数有所不同, 赤道太平洋大部分地区可预报天数可达到 10 天以上, 在 160°E 以东, 仅在赤道冷舌位置 130°W 以东 (2°S-5°N 范围), 可预报天数不足 7 天, 最小只有 4 天。在 160°E 以西, 130°E 以东的赤道西太平洋, 可预报天数一般不超过 10 天, 赤道北侧可预报天数约为 6-8 天, 130°E 以西, 可预报天数约 3 天; 赤道附近以及南侧, 可预报天数很低, 有些甚至不到 3 天, 120°E-140°E, 5°S-10°S, 可预报天数有所升高, 最大可以达 7 天左右。




图 5 预报和观测 SST 的相关系数 (R) 大于 0.6 的天数

Fig.5 The number of days that the correlation coefficient (R) of the forecast and observation SST is greater than 0.6

3.4 不同月份预报技巧

不同月份 SST 通常表现出不同的特征，因此为探究模型在不同特征初始场上预报表现，根据不同月份的观测值以及对应的预报值得到不同类型的 RMSE 空间分布。图 6 (a) 展示了沿赤道平均随经度和月份变化的 RMSE，结果显示在赤道上太平洋东部 RMSE 明显大于西部，即西部预报误差小于东部预报误差。RMSE 较小 ($<0.6^{\circ}\text{C}$) 的范围在北半球 3-5 月最小，在 10、11 月份，大的 RMSE ($>0.6^{\circ}\text{C}$) 范围最大。在赤道太平洋西部地区 (图 6b)，南半球 10、11 月份 RMSE 出现大值中心，RMSE 为 0.6°C 。中部地区 (图 6c)，赤道地区在 1、2 月份预报 RMSE 较大，RMSE 达到 0.6°C 。东部地区 (图 6d)，赤道地区各月份预报 RMSE 均大于 0.4°C ，在 1、2、10、11 月份预报 RMSE 超过 0.8°C ，4-6 月预报 RMSE 较小。总的来说，SST 区域预报模型在赤道太平洋东部地区各月份预报技巧普遍低于西部地区，所构建的模型在不同月份表现有较大的差异。




图 6 不同月份 RMSE (单位: $^{\circ}\text{C}$) 随经纬度分布 (a): RMSE 随经度变化 (南北纬 2° 平均) (b): RMSE 随纬度变化 (沿 130.125°E , 0.125°N) (c): RMSE 随纬度变化 (沿 179.875°E , 0.125°N) (d): RMSE 随纬度变化 (沿 139.875°W , 0.125°N)

Fig.6 Distribution of RMSE with latitude and longitude in different months (unit: $^{\circ}\text{C}$) (a): RMSE with longitude (2° average north-south latitude) (b): RMSE with latitude (along 130.125°E , 0.125°N)

(c): RMSE with latitude (along 179.875°E, 0.125°N) (d): RMSE with latitude (along 139.875°W, 0.125°N)

4 总结与讨论

本文基于 LSTM 网络结构构建了未来 10 天海表面温度 (SST) 的深度学习预报模型, 该预报模型依靠数据驱动, 仅需过去 10 天 SST 数据就可在 2 秒以内获得未来 10 天海表面温度。利用该预报模型在赤道太平洋地区 (10°S-10°N, 120.0°E-280°E) 进行预报试验, 探究了该预报模型在热带太平洋地区的预报效果。结果表明:

(1) 单点模型的预报误差在赤道太平洋东西分布上存在明显差异, 赤道中、西位置的误差差异不大, 且远小于赤道东边的 RMSE, 同时中、西点预报偏差远小于东点预报偏差。随着预报天数的增加, 中、西点的误差增长很慢, 到第 10 天增长约 0.2°C, 东点误差增长很快, 到第 5 天增长了 0.5°C; 中、西点偏差很小, 随预报天数增加基本保持不变, 东点偏差为正随预报天数增加而增加。中部相关预报技巧最好、东部相关预报技巧最差。

(2) 区域 RMSE 和偏差的结果与单点结果基本一致, 预报模型在赤道太平洋中部预报误差较小, 西部预报效果次之, 东部预报误差最大。RMSE 最大位于赤道东太平洋和秘鲁沿岸, 最大约为 0.6°C, 与太平洋冷舌位置重合。赤道东太平洋 RMSE 大与刚开始出现较大偏差有关, 随着时间增加, 该区域偏差逐渐增大。在不同的年际振荡事件中, 误差大小有较大差异。具体而言, RMSE 拉尼娜时期最大, 正常年份次之, 厄尔尼诺时期最小; RMSE 在拉尼娜时期比在厄尔尼诺时期大, 可达 20%。

(3) SST 区域预报模型在赤道太平洋东部地区各月份预报技巧普遍低于西部地区; 西部地区南半球在 10、11 月份预报技巧较差; 中部地区模型表现较好, 1、2 月份预报技巧相对较差; 东部赤道地区各月预报表现均较差, 其中 1、2、10、11 月份表现最差。依据深度学习方法构建的预报模型表现有较大的月差异。

对于赤道太平洋大部分区域而言, 该 10 天 SST 区域预报模型在不同预报初值下均能对未来 10 天 SST 做出较好的预测。该预报模型与 Zheng et al. (2020) 利用 CNN 构建的海表面温度预报模型, 均在太平洋东部赤道表现出较大的预报 RMSE。整体而言, 利用 LSTM 构建的预报模型与基于 CNN 构建的预报模型在赤道太平洋地区预报 RMSE 空间形态一致, 大小基本相同。本文所构建的 LSTM 预报模型和 Zheng et al. (2020) 对于太平洋东部赤道地区预报误差均比中西太平洋大。在以后的工作中将对太平洋东部赤道区域单独研究, 以期提高该区域的 SST

311 预报效果。短期预报偏差与年际变化的振荡事件有关，厄尔尼诺/拉尼娜事件可能会导致冷/暖
312 偏差，年际变化与短期预报误差的关系值得进一步研究。

313 参考文献 (References)

- 314 Abadi M, Barham P, Chen J, et al. {TensorFlow}: A System for {Large-Scale} Machine Learning[C]//12th USENIX sym-
315 posium on operating systems design and implementation (OSDI 16). 2016: 265-283.
- 316 Bouali M, Sato O T, Polito P S. 2017. Temporal trends in sea surface temperature gradients in the South Atlantic
317 Ocean[J/OL]. Remote Sensing of Environment, 194: 100-114.
- 318 Cane M A, Clement A C, Kaplan A, et al. 1997. Twentieth-Century Sea Surface Temperature Trends[J/OL]. Science,
319 275(5302): 957-960.
- 320 Capotondi A, Wittenberg A T, Newman M, et al. 2015. Understanding ENSO Diversity[J/OL]. Bulletin of the American
321 Meteorological Society, 96(6): 921-938.
- 322 Castro S L, Wick G A, Steele M. 2016. Validation of satellite sea surface temperature analyses in the Beaufort Sea using
323 UpTempO buoys[J/OL]. Remote Sensing of Environment, 187: 458-475.
- 324 Chaidez V, Dreano D, Agusti S, et al. 2017. Decadal trends in Red Sea maximum surface temperature[J/OL]. Scientific
325 Reports, 7(1): 8144.
- 326 Edwards, L. A., Houseago - Stokes, R. E., & Cipollini, P. (2006). Altimeter observations of the MJO/ENSO connection t
327 hrough Kelvin waves. International Journal of Remote Sensing, 27(6), 1193 - 1203.
- 328 Francois, C., 2015. Keras. Github. <https://github.com/keras-team/keras>.
- 329 Friedel M J. 2012. Data-driven modeling of surface temperature anomaly and solar activity trends[J/OL]. Environmental
330 Modelling & Software, 37: 217-232.
- 331 Geng H, Wang T. 2021. Spatiotemporal Model Based on Deep Learning for ENSO Forecasts[J/OL]. Atmosphere, 12(7):
332 810.
- 333 Ham Y G, Kim J H, Luo J J. 2019. Deep learning for multi-year ENSO forecasts[J/OL]. Nature, 573(7775): 568-572.
- 334 He D, Lin P, Liu H, et al. 2019. DLENZO: A Deep Learning ENSO Forecasting Model[M/OL]//NAYAK A C, SHARMA
335 A. PRICAI 2019: Trends in Artificial Intelligence: Vol. 11671. Cham: Springer International Publishing: 12-
336 23[2022-05-16].
- 337 Hochreiter S, Schmidhuber J. 1997. Long Short-Term Memory[J/OL]. Neural Computation, 9(8): 1735-1780.
- 338 Holmes, R. M., McGregor, S., Santoso, A., & England, M. H. (2019). Contribution of tropical instability waves to ENSO
339 irregularity. Climate Dynamics, 52(3-4), 1837-1855.
- 340 Jia X, Ji Q, Han L, et al. 2022. Prediction of Sea Surface Temperature in the East China Sea Based on LSTM Neural
341 Network[J/OL]. Remote Sensing, 14(14): 3300.
- 342 Jin E K, Kinter J L, Wang B, et al. 2008. Current status of ENSO prediction skill in coupled ocean-atmosphere moels[J/OL].
343 Climate Dynamics, 31(6): 647-664.
- 344 Kim, M., Yang, H., & Kim, J. (2020). Sea Surface Temperature and High Water Temperature Occurrence Prediction Using
345 a Long Short-Term Memory Model. Remote Sensing, 12(21), 3654.
- 346 Latif, M., Barnett, T.P., Cane, M.A. et al. A review of ENSO prediction studies. Climate Dynamics 9, 167-179 (1994).
- 347 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. LIU Jun,
348 TANG Youmin, SONG Xunshu, et al. 2022. Prediction of the Indian Ocean Dipole using Deep Learning Method
349 [J]. Chinese Journal of Atmospheric Sciences (in Chinese), 46(3): 590-598.
- 350 McPhaden, M. J., Zebiak, S. E., & Glantz, M. H. (2006). ENSO as an Integrating Concept in Earth Science. Science,
351 314(5806), 1740-1745.

- Mu B, Peng C, Yuan S, et al. 2019. ENSO Forecasting over Multiple Time Horizons Using ConvLSTM Network and Rolling Mechanism[C/OL].//2019 International Joint Conference on Neural Networks (IJCNN). Budapest, Hungary: IEEE: 1-8[2022-05-16].
- Neelin J D, Battisti D S, Hirst A C, et al. 1998. ENSO theory[J/OL]. *Journal of Geophysical Research: Oceans*, 103(C7): 14261-14290.
- Nelson M, Hill T, Remus W, et al. 1999. Time series forecasting using neural networks: should the data be deseasonalized first?[J/OL]. *Journal of Forecasting*, 18(5): 359-367.
- Rauscher S A, Jiang X, Steiner A, et al. 2015. Sea Surface Temperature Warming Patterns and Future Vegetation Change[J/OL]. *Journal of Climate*, 28(20): 7943-7961.
- Rayner N. A., D. E. Parker, E. B. Horton, et al. 2003. Global analyses of sea surface temperature, sea ice, and night marine air temperature since the late nineteenth century, *J. Geophys. Res.*, 108 (D14), 4407.
- Reynolds, Richard W., Thomas M. Smith, et al. 2007. Daily High-Resolution-Blended Analyses for Sea Surface Temperature. *J. Climate*, 20, 5473-5496.
- Salles R, Mattos P, Iorgulescu A M D, et al. 2016. Evaluating temporal aggregation for predicting the sea surface temperature of the Atlantic Ocean[J/OL]. *Ecological Informatics*, 36: 94-105.
- Sarkar P P, Janardhan P, Roy P. 2020. Prediction of sea surface temperatures using deep learning neural networks[J/OL]. *SN Applied Sciences*, 2(8): 1458.
- Singh D, Singh B. 2020. Investigating the impact of data normalization on classification performance[J/OL]. *Applied Soft Computing*, 97: 105524.
- Tang Y, Zhang R H, Liu T, et al. 2018. Progress in ENSO prediction and predictability study[J/OL]. *National Science Review*, 5(6): 826-839.
- Tippett M K, Barnston A G, Li S. 2012. Performance of Recent Multimodel ENSO Forecasts[J/OL]. *Journal of Applied Meteorology and Climatology*, 51(3): 637-654.
- Wentz F J, Gentemann C, Smith D, et al. 2000. Satellite Measurements of Sea Surface Temperature Through Clouds[J/OL]. *Science*, 288(5467): 847-850.
- Vialard, J., Menkes, C., Boulanger, J.-P., Delecluse, P., Guilyardi, E., McPhaden, M. J., & Madec, G. (2001). A Model Study of Oceanic Mechanisms Affecting Equatorial Pacific Sea Surface Temperature during the 1997–98 El Niño. *Journal of Physical Oceanography*, 31(7), 1649–1675.
- Wirasatriya, A., Hosoda, K., Setiawan, J. D., & Susanto, R. D. (2020). Variability of Diurnal Sea Surface Temperature during Short Term and High SST Event in the Western Equatorial Pacific as Revealed by Satellite Data. *Remote Sensing*, 12(19), 3230.
- Xiao C, Chen N, Hu C, Wang K, Gong J, et al. 2019. Short and mid-term sea surface temperature prediction using time-series satellite data and LSTM-AdaBoost combination approach[J/OL]. *Remote Sensing of Environment*, 233: 111358.
- Yan J, Mu L, Wang L, et al. 2020. Temporal Convolutional Networks for the Advance Prediction of ENSO[J/OL]. *Scientific Reports*, 10(1): 8055.
- Yu, J.-Y., and Liu, W. T. (2003), A linear relationship between ENSO intensity and tropical instability wave activity in the eastern Pacific Ocean, *Geophys. Res. Lett.*, 30, 1735.
- Zhang Q, Wang H, Dong J, et al. 2017. Prediction of Sea Surface Temperature Using Long Short-Term Memory[J/OL]. *IEEE Geoscience and Remote Sensing Letters*, 14(10): 1745-1749.
- Y. Zhao, D. Yang, Z. He, C. Liu, R. Hao and J. He, "Statistical Methods in Ocean Prediction," *Global Oceans 2020: Singapore – U.S. Gulf Coast*, Biloxi, MS, USA, 2020, pp. 1-7.
- Zheng G, Li X, Zhang R H, et al. 2020. Purely satellite data-driven deep learning forecast of complicated tropical instability waves[J/OL]. *Science Advances*, 6(29): eaba1482.