

基于长短期记忆神经网络的西太平洋暖池变化预测

林琪凡¹, 耿旭朴^{2*}, 谢婷², 胡利平³

(1. 北京大学物理学院大气与海洋科学系, 北京 100871; 2. 厦门大学海洋与地球学院, 近海海洋环境科学国家重点实验室(厦门大学), 福建 厦门 361102; 3. 电磁散射重点实验室, 北京 100854)

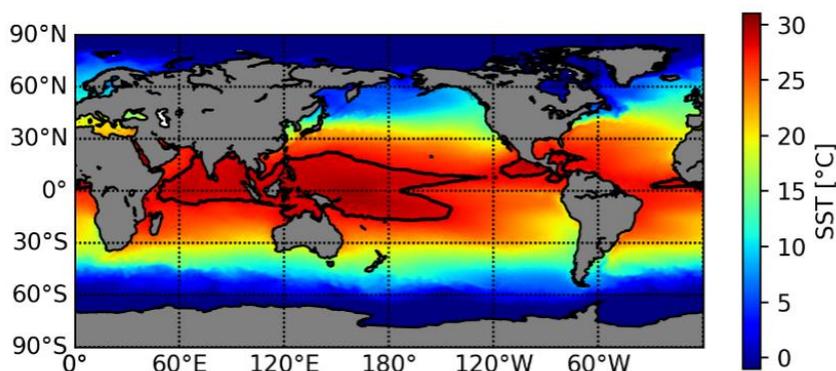
摘要: 西太平洋暖池是热带太平洋西部由海表温度 28 °C 等温线所划定的海域, 是全球海表温度最高的区域, 也是热带太平洋海洋和大气之间大尺度变化现象——厄尔尼诺-南方涛动 (ENSO) 的重要组成部分。本文采用暖池面积、暖池强度、暖池质心纬度和暖池质心经度 4 个指数来表征暖池大小和位置, 在此基础上构建了长短期记忆神经网络 (LSTM) 模型, 通过优化序列长度、学习率和迭代次数 3 个超参数, 对未来 10 年暖池面积、强度、质心位置的变化进行预测。经巴特沃斯滤波器平滑后发现, 暖池各个指数低频变化与多变量 ENSO 指数 (MEI) 之间存在相关关系, 使用预测结果对 2019—2028 年 ENSO 事件的发生做出判断, 演示了该模型的合理性。预测结果认为, 2019 年底—2020 年将出现厄尔尼诺现象, 这与现实情况中 2019 年底发生的厄尔尼诺现象相吻合。

关键词: 西太平洋暖池; 长短期记忆神经网络; 时间序列预测; 厄尔尼诺-南方涛动

中图分类号: P 732.6

文献标志码: A

暖池在印度洋、太平洋和大西洋均有分布, 在西太平洋的部分称为西太平洋暖池 (Western Pacific warm pool, WPWP), 用以区分东印度洋暖池和西半球暖池^[1]。由于研究问题的差异以及研究利用的海表温度 (sea surface temperature, SST) 数据的全球分布情况, 西太平洋暖池的划定有所不同。基于 1981—2018 年各年全球年平均 SST 分布, 本文选取 28 °C 等温线作为暖池边界, 如图 1 所示, 黑线内的西太平洋海域即为本文的研究区域。



收稿日期: 2020-07-01 **录用日期:** 2021-02-23

基金项目: 国家自然科学基金(41961144011,91858202,41630963,41476007); 国家海洋局全球变化与海气相互作用项目 (GASI-IPOVAI-01-04,GASI-02-PAC-YGST2-02)

***通信作者:** gengxp@xmu.edu.cn

图 1 2018 年全球年平均海表温度分布（黑色实线表示 28 °C 等温线）

Fig. 1 Global annual average SST distribution of 2018 (solid black line represents 28 °C isotherm)

西太平洋暖池广阔的海域面积、突出的海表温度、丰富的热含量^[2]，使这里的海气相互作用在气候系统中具备更显著的影响力。一直以来，科学界都将西太平洋暖池与厄尔尼诺-南方涛动（El Niño-Southern Oscillation, ENSO）事件紧密联系在一起^[3-6]。西太平洋暖池作为 ENSO 事件的重要组成部分^[3]，它们之间的关系一直是科学研究的热点问题。厄尔尼诺（El Niño）是每隔 3~7 年发生在赤道中、东太平洋的大规模表层海水持续（6 个月以上）异常偏暖现象；反之，持续异常偏冷的现象称为拉尼娜（La Niña）^[7]。厄尔尼诺作为 ENSO 事件的暖现象，是全球气候波动的突出贡献者，对世界生态系统的稳定和人类社会的发展有着重要影响。根据 Philander^[8]的统计与分析，20 世纪 80 年代以来，平均每隔 4 年发生一次厄尔尼诺，每隔 10 年发生一次强厄尔尼诺。厄尔尼诺增加了极端天气事件发生频率，可能给各地带来干旱和洪涝等灾害，影响东太平洋沿岸渔业，造成重大的人员和财产损失。因此，对 ENSO 事件、厄尔尼诺现象的预警尤为重要。但是，因为缺失对气候扰动源头的了解，准确预测 ENSO 事件的发生存在一定困难^[4]。

从 20 世纪 80 年代至今，研究者对暖池的定义、特征、多尺度变异进行了深入探索。Philander^[8]首次提出西太平洋暖池重心的概念，用于研究西太平洋暖池中的海气相互作用，发现了暖池重心东向移动与厄尔尼诺现象的关系。Yan 等^[2]和 Ho 等^[9]使用卫星观测到的 SST 数据追踪 1982-1991 年各年西太平洋暖池温度和大小的变化情况，建立暖池面积、体积、质心、东边界等参数，得出西太平洋暖池水平尺度远大于垂直尺度的结论。Kidwell 等^[5]曾使用集成经验模式分解法（EEMD）和 Hilbert-Huang 谱分析方法发现西太平洋暖池的面积和形心具备从季节到年代际等多个时间尺度的变异特征，探究不同类型厄尔尼诺现象与暖池长期变化趋势的关系。Ho^[9]和 Yan^[4]等人计算并分析了暖池形心的运动，探究海洋、大气与厄尔尼诺现象之间的关系。方立新等^[10]在此基础上进行改进，引入暖池质心的概念。Kidwell 等^[6]进一步发现了西太平洋暖池三维形心、热含量和体积在年代际尺度上与 ENSO 事件的相关关系。但是，关于暖池数值模拟的研究进展缓慢。胡石建^[11]认为目前的海气耦合数值模式不能很好地模拟西太平洋暖池，原因在于对西太平洋暖池形成和维持机制的不充分认识。对西太平洋暖池基本动力学方面知识的缺失，使得利用数值模拟对西太平洋暖池未来的变化情况进行预测存在一定困难。

常用的海洋数据预测方法主要分为两类：一类是基于物理学原理的数值模型，另一类是基于数据的数据驱动模型^[12]。数值模型使用一系列微分方程描述海洋中的各类水文现象，需要具备对特定海域、特定水文现象产生和维持机制的深刻理解，一般计算复杂、难度较高；而以深度神经网络为代表的驱动模型，可以从大批量原始数据中学习特征，对未来进行预测，摆脱了物理机制的限

制，弥补了部分海洋领域数据缺失和理论薄弱的不足^[13]。在传统海洋数据数量多、变化复杂、特征不突出的背景下，深度学习在海洋数据重构、海洋图像分类识别、海洋时间序列数据预测等方面表现良好^[17]。在深度学习领域，循环神经网络（recurrent neural network, RNN）和长短期记忆神经网络（long short-term memory, LSTM）可以满足时间序列数据的预测需求。RNN 通过建立层内信息循环和无效数据遗忘的功能，实现了神经网络对数据的记忆，但 RNN 在实际使用中存在长期依赖问题，在长序列训练中存在梯度消失和梯度爆炸的问题，因此只具有短期记忆。LSTM 是特殊的 RNN，通过改进算法一定程度解决了这种长期依赖问题，因此对于长时间序列事件的处理和预测达到了更好的预测效果。

本文基于 LSTM，利用日平均海表温度数据对西太平洋暖池面积、暖池强度、暖池质心经度和暖池质心纬度 4 个暖池指数的时间序列进行训练、测试和预测，并在此基础上探究暖池指数多尺度变异特征与 ENSO 事件之间的关系，进而对未来 10 年（2019—2028 年）ENSO 事件的发生进行判断。

1 数据与方法

1.1 数据来源

本文利用美国国家海洋和大气管理局(National Oceanic and Atmospheric Administration, NOAA)、海洋与大气研究室(Oceanic and Atmospheric Research, OAR)、地球系统研究所(Earth System Research Laboratory, ESRL)、物理科学部(Physical Sciences Division, PSD)提供的高分辨率每日平均最优插值海表温度(high-resolution daily optimum interpolation SST)数据和多变量 ENSO 指数(multivariate ENSO index, MEI)。

SST 数据的时间跨度从 1981 年 9 月 1 日—2018 年 12 月 31 日，共 38 a (13 636 d)。数据覆盖全球海洋(89.875° S~89.875° N, 0.125° E~359.875° E)，经纬度网格大小为 0.25°×0.25°，总计 1 440×720 个格点。

ENSO 事件产生于大气、海洋及多种气候系统的相互作用，成因多样且复杂。多变量 ENSO 指数充分考虑大气和海洋的双重影响，结合多种参数进行分析，被视为监测和反映 ENSO 事件最全面的指数^[14]。

1.2 研究方法

LSTM 是一类特殊的 RNN，用于处理和预测时间序列中间隔和延迟相对较长的重要事件。当数

据输入 LSTM 中，根据一定规则判断信息是否有用，有用信息留下，无用信息则通过遗忘门丢弃。通过这种方法，LSTM 一定程度上解决了 RNN 存在的长期依赖问题。

1.2.1 数据预处理

本文对 SST 数据首先进行了月平均，得到 SST 的月平均数据。在实际问题中，需要对模型输入具备多个特征的样本数据，但这些特征的量级和量纲可能不一致。通过标准化处理，可以使不同特征具有相同的尺度，使得不同特征对参数的影响程度一致。数据标准化的表达式为：

$$X^* = \frac{X - \mu}{\sigma} \quad (1)$$

其中， μ 为序列的均值， σ 为序列的标准差。除此之外，LSTM 对输入数据的规模（范围）很敏感，特别是在使用激活函数 sigmoid、tanh 时。经过对未进行标准化的原始数据进行试验后发现程序运行速度非常缓慢，同时，在某些数值较大、变化范围较大的变量训练时（例如暖池面积），甚至出现无法成功运行的情况。因此对数据进行标准化处理也能够加快神经网络的训练和权重参数的收敛，否则可能阻止神经网络有效学习这个问题。

还需要将数据变为 Pytorch 框架中 LSTM 模型可接受的形式。输入数据的格式必须为 3 维的张量，第一维是序列（sequence）长度，代表用于预测的时间长度，本研究设置为 50，即使用 1~50 个月份的数据预测第 51 个月。第二维是批次（batch）大小，代表每次进入模型的数据大小，本文采用的是批量梯度下降法，每一次迭代时使用所有样本来进行梯度的更新，因此批次大小为样本集的大小。第三维是输入数据的特征数量，本研究设置为 1，即一次只进行一种指数的训练和预测。

1.2.2 训练、测试与预测

整个数据集需要划分为训练集（training set）和测试集（test set），在数据量有限并保证测试数据足够的基础上，为了最大化训练数据的数量，划分比例为 8:2，时间长度上前 80% 的数据用于训练，剩余 20% 用作测试。训练集和测试集中都包含用于预测的输入数据、预期得到的实际数据。在训练时，这两部分数据都将放进模型，而在测试时，只将用于预测的输入数据放入模型。

训练集用于训练模型、确定模型的参数^[15]。将训练集输入一个初始化模型，按照前向传输的方式进行前馈运算，然后计算模型输出的预测值和实际值之间的均方根误差，将误差在模型中通过反向传输的方式进行反馈运算，对每个节点之间的权重进行修改，使得下一次训练得到更好的结果。训练以权重为任意值开始，训练的目的在于不断调整权重，在学习完训练样本后，使误差尽可能小，即神经网络模型通过训练而“学习”到的内容是蕴含在“权重”这一参数中的。通过训练得出最优模型后，需要使用测试集对模型进行检验，衡量模型的泛化能力^[15]。在测试时，向模型输入的数据仅包含用于预测的输入数据，人为比较模型的预测值和测试集中的实际数据，以判断模型对新鲜样本的

预测能力。

为了判断模型是否存在超前预测的能力，文中对该模型输入测试集进行了预测。与测试不同的是，这一步得到的每一个预测值的输入序列都是真实值和先前预测值的组合，例如，使用第 1~50 个数据预测第 51 个数据后，使用 2~51 个数据预测第 52 个数据的时候，加入预测得到的第 51 个数据。一般情况下，预测的准确度会随着预测的进行不断下降。最后，使用已知的时间序列对未来数据进行预测。最优模型构建流程见图 2。

在 LSTM 神经网络模型训练前，需要定义 3 个超参数：序列（sequence）长度、学习率（learning rate）、迭代次数（epochs）。序列长度代表用于预测的时间长度，本研究中 4 个指数预测的序列长度都设置为 50。学习率表示每次梯度下降的步长，本研究既有设置学习率随迭代次数的增加而减缓，也有设置固定学习率进行训练。迭代次数表示整个训练过程的工作次数，一次迭代将会使用所有数据、所有批次进行前向和反向传播计算来更新模型参数，本研究设置的迭代次数均在一万以上。

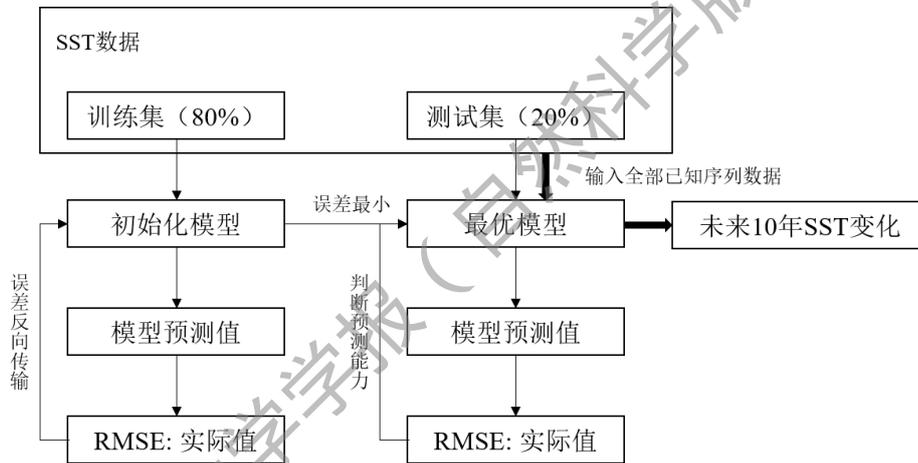


图 2 LSTM 神经网络训练、预测流程图

Fig. 2 LSTM neural network training, prediction flow chart

1.2.3 暖池指数的建立

本文将建立暖池面积、暖池强度、暖池质心经度和暖池质心纬度 4 个指数来表征暖池的时空变化。

在西太平洋（经度范围为 120°E-180°-120°W），暖池面积为暖池内（28 °C 等温线内）0.25°×0.25° 网格数量乘以网格对应面积得到。参考国家气候中心监测业务关于暖池强度的定义^[6]，暖池强度表达式为：

$$SST_Sum = \sum_i (SST_i - 28^{\circ}C) (SST_i \geq 28^{\circ}C) \quad (2)$$

其中， SST_i 为暖池内各个格点的 SST。将累加得到的时间序列经过 Z-Score 标准化，得到暖池强度。

暖池质心反映了暖池的位置及其变化情况。参考非均质物体的质心公式^[10]，在计算暖池质心时

考虑 SST 差异的影响，引入温度权重 w ，表达式为：

$$w_i = \frac{SST_i - SST_{min}}{SST_{max} - SST_{min}} \quad (SST_i \geq 28^\circ\text{C}) \quad (3)$$

其中， SST_i 为暖池内各个格点的 SST， $SST_{min} = 28^\circ\text{C}$ ， SST_{max} 为每日暖池内 SST 的最大值。暖池质心经纬度的计算公式分别为：

$$x = \frac{\sum_i w_i \times x_i}{\sum_i w_i}, \quad y = \frac{\sum_i w_i \times y_i}{\sum_i w_i} \quad (4)$$

其中， x_i 、 y_i 分别为暖池各个格点的经、纬度， x 、 y 分别为质心的经、纬度。

2 结果与分析

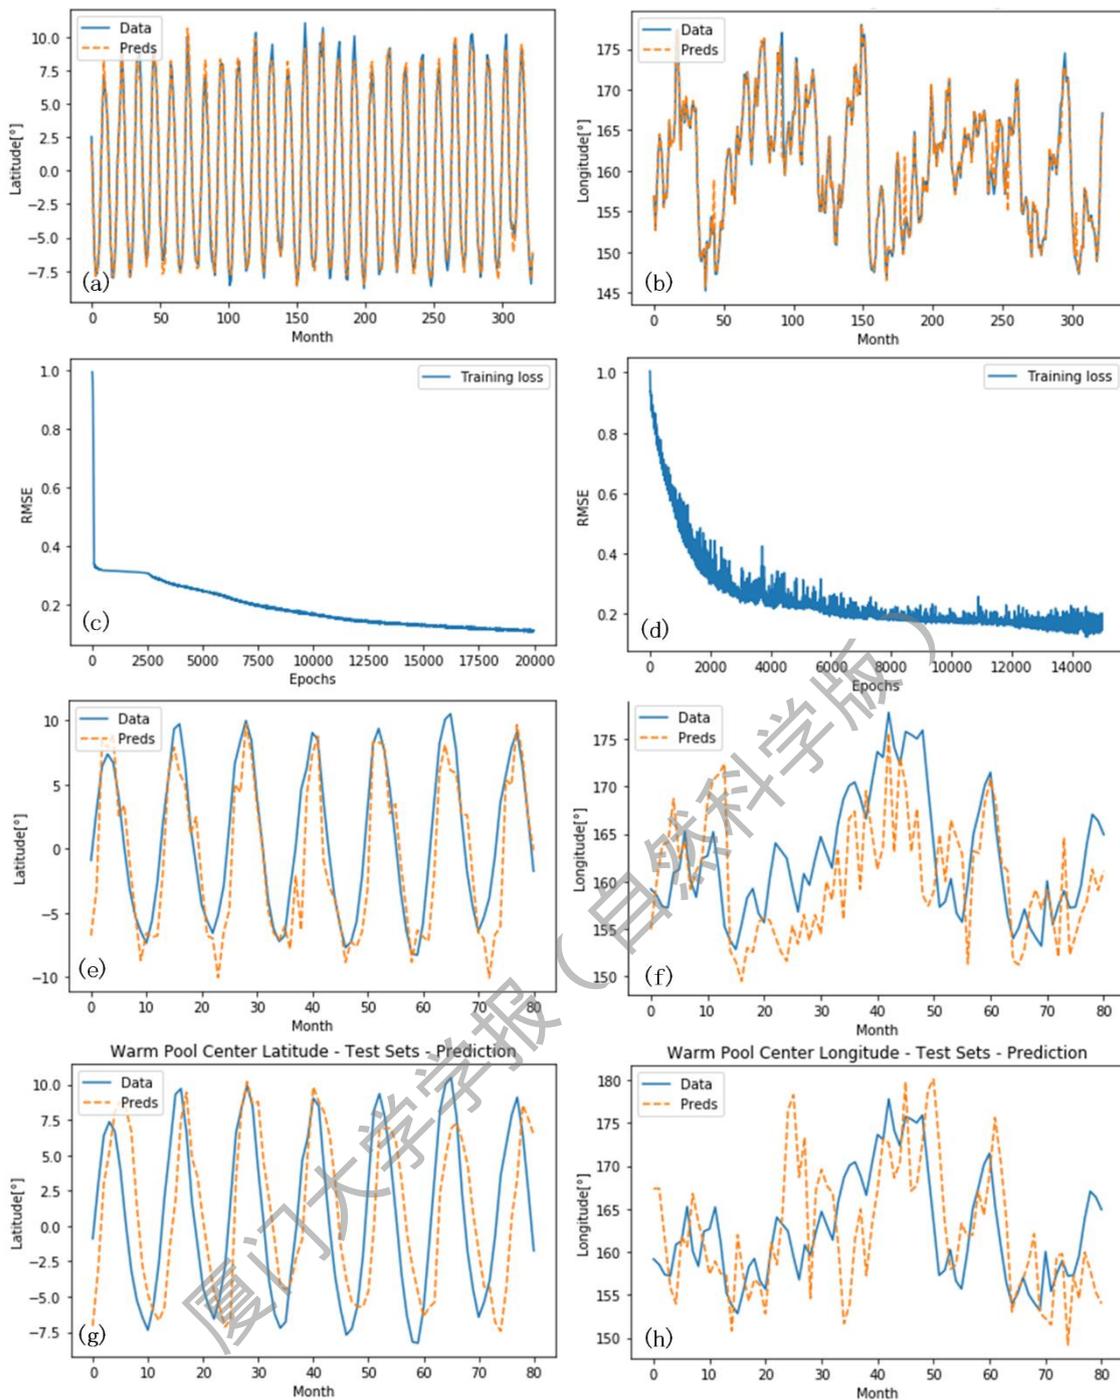
2.1 训练和测试结果

本文对暖池面积、暖池强度、暖池质心经度和暖池质心纬度 4 个模型进行了训练和测试，找到最适的超参数，实现了模型在训练损失、测试损失和预测结果中均表现良好的目的，成功构建 LSTM 最优模型。各个暖池模型的超参数设定如表 1 所示，预测序列长度均为 50，除暖池强度学习率固定外，其他 3 个模型均采用学习率随迭代次数增加不断下降的方法，迭代次数都设定在 10 000 以上。下面以暖池质心纬度、经度模型的训练和测试结果为例，展示 LSTM 模型的合理性和适用性。

表 1 各个暖池模型超参数设定

Tab.1 Parameters setting of warm pool models

	序列长度	学习率	迭代次数
暖池面积	50	$0.005/(1+0.0005*t)$	10 000
暖池强度	50	0.005	10 000
暖池质心纬度	50	$0.001/(1+0.0001*t)$	20 000
暖池质心经度	50	$0.01/(1+0.0007*t)$	15 000



(a)、(c)、(e)和(g)为暖池质心纬度模型，(b)、(d)、(f)和(h)为暖池质心经度模型。

图 3 暖池模型训练结果(a~b)、模型训练损失收敛情况(c~d)、模型测试结果(e~f)和模型测试集预测结果(g~h)

Fig. 3 Warm pool training results (a-b), training loss (c-d), testing results (e-f) and model test sets predict results (g-h)

图 3(a)和(b)分别表示暖池质心纬度和经度模型在特定超参数下训练的结果，图中蓝色实线表示实际值，橙色虚线为预测值，实际值与预测值基本吻合，说明通过训练，模型能够很好的学习输入数据。

图 3(c)和(d)为训练过程中使用标准化数据计算得到的损失值。可以看出随着迭代次数的增加，

损失值不断减小，达到 0.2 以下，在迭代次数达到 8 000 次之后能够很好的收敛，得到稳定的训练结果。最终模型训练的均方根误差分别为 0.15 和 0.11。

图 3(e)和(f)是对模型进行测试的结果。模型测试的均方根误差分别为 0.55 和 0.89，反标准化后计算得到的均方根误差分别为 3.25、6.50。与训练的均方根误差相比，测试的均方根误差要来得大，说明模型的预测结果不能完全和实际值相吻合。但是在测试时，预测值在趋势上与实际值基本吻合，模型的预测结果有一定的准确度。

图 3(g)和(h)是对模型输入测试集进行预测的结果。模型测试的均方根误差分别为 0.84 和 0.98，反标准化后计算得到的均方根误差分别为 5.00 和 7.19，稍大于测试结果，但预测结果与实际值变化趋势基本吻合，说明模型在一定程度上存在 80 个月超前预测的能力。基于模型在测试集的预测结果（80 个月）中表现良好，文中利用 LSTM 模型对暖池进行了十年（120 个月）的预测，认为其具有一定的合理性。

2.1 暖池面积预测

基于最优暖池面积模型，对未来 10 年暖池面积的变化进行预测。图 4 中蓝线是 1981—2018 年暖池面积的变化情况，红线是未来 120 个月暖池面积的预测结果。可以看出，预测结果震荡频率过快，许多年份出现 4 个峰值，不符合暖池面积的实际变化情况^[10]。对其进行 6 个月低通滤波除去这一信号后预测结果如图 3(c~d)，未来 120 个月暖池面积将在 $2.3 \times 10^7 \sim 3.6 \times 10^7 \text{ km}^2$ 的范围内变化，但是模型没有学习到暖池面积不断增长的长期趋势。

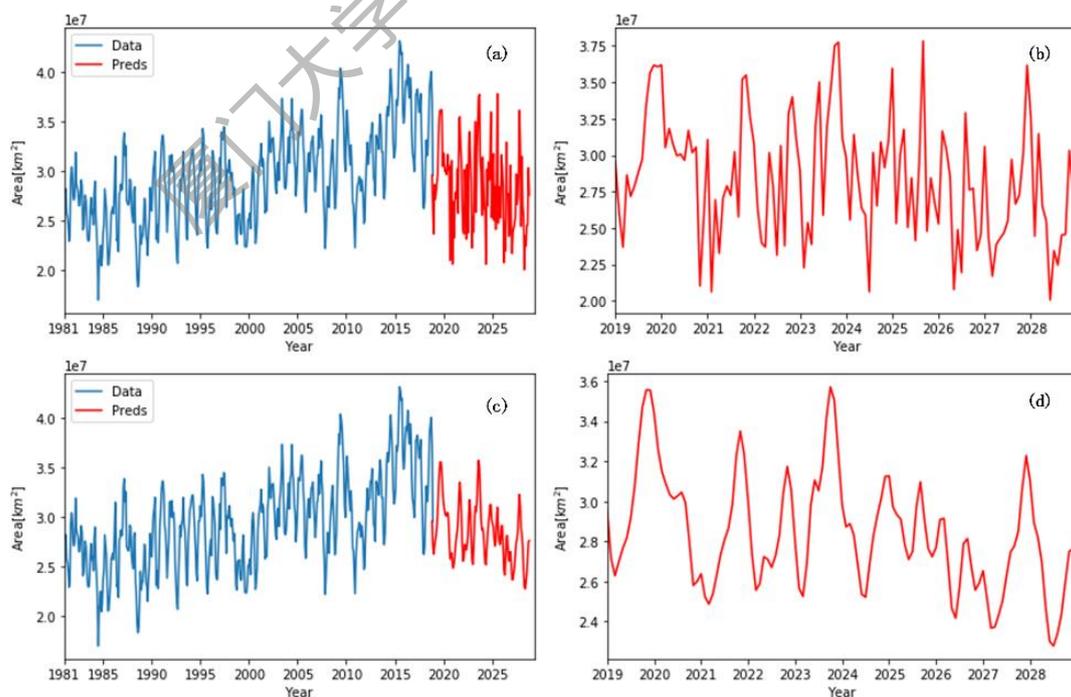


图 4 1981—2028 年暖池面积变化(a)、未来 120 个月暖池面积预测(b)、1981—2028 年暖池面积变化(6 个月低通滤波) (c)和未来 120 个月暖池面积预测(6 个月低通滤波) (d)

Fig. 4 Changes of warm pool area 1981-2028 (a), warm pool area prediction for the next 120 months (b), changes of warm pool area 1981—2028 (6 months low pass filtering) (c), and warm pool area prediction for the next 120 months (6 months low pass filtering) (d)

为了探究暖池与 ENSO 事件之间的关系，本文将各个暖池指数的原始数据减去年循环，得到暖池指数的距平值，再将距平值通过巴特沃斯滤波器进行 365 d 低通滤波，得到各个暖池指数的低频变化，由此排除了季节内变化和季节变化的影响。通过计算暖池面积的低频变化与 MEI 指数之间的相关系数，得到暖池面积与 ENSO 事件的相关性。暖池面积的低频变化和 MEI 指数之间的相关系数为 0.38， P 值小于 0.05，在 95% 的置信度下认为暖池面积和 ENSO 事件存在相关性。相关系数为正值但并不接近 1，表明具备较弱的正相关关系。Kidwell 等^[5]曾经发现，在 1982—2011 年 30 年间，暖池面积增加了 18%，具备不断增长的长期趋势。因此，将暖池面积通过 1700 天高通滤波除去长期变化趋势的影响后，计算得到的相关系数为 0.74， P 值小于 0.05，表明暖池面积在除去长期趋势的影响后与 ENSO 事件存在更为显著的正相关关系。图 5(a)中灰柱表示 MEI 指数，正值对应厄尔尼诺现象，负值对应拉尼娜现象，蓝线为 1981—2018 年除去长期趋势的暖池面积低频变化，红线为暖池面积预测结果。2019 年年初，暖池面积达到极小值，之后不断增长在 2019 年冬季达到极大值，此次增长持续时间长。根据暖池面积与 ENSO 事件之间的正相关关系，模型预测结果表明，2019 年冬季将出现厄尔尼诺现象并持续到 2020 年年底。如图 5(b)所示：在 2023 年冬季和 2027 年冬季，暖池面积出现较明显的极大值，可能出现一次较弱的厄尔尼诺现象；在 2021 年初、2024 年、2028 年，暖池面积出现极小值，可能出现拉尼娜现象。根据暖池面积的低频变化对未来 10 年 ENSO 事件的发生进行预测的结果符合过去“厄尔尼诺平均每隔 4 年发生一次，每隔 10 年发生一次强厄尔尼诺”的研究结论^[8]。

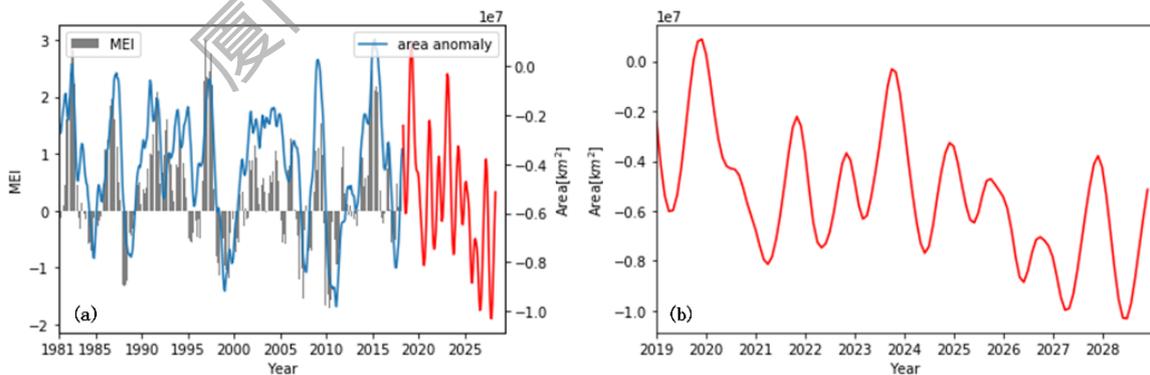


图 5 1981—2028 年暖池面积预测低频变化（无长期趋势）与 MEI 指数(a)，以及未来 120 个月暖池面积预测低频变化（无长期趋势）(b)

Fig. 5 MEI index and low frequency variation prediction based on warm pool area (removal of long-term trend) during 1981—2028 (a), and low frequency variation prediction based on warm pool area (removal of long-term trend) for the next 120 months (b)

2.2 暖池强度预测

暖池强度模型对未来 10 年暖池强度的预测结果表明，未来 120 个月暖池强度将在-1.5~1.0 的范围内变化，与暖池面积模型类似，暖池强度模型没有学习到不断增长的长期趋势（图 6）。

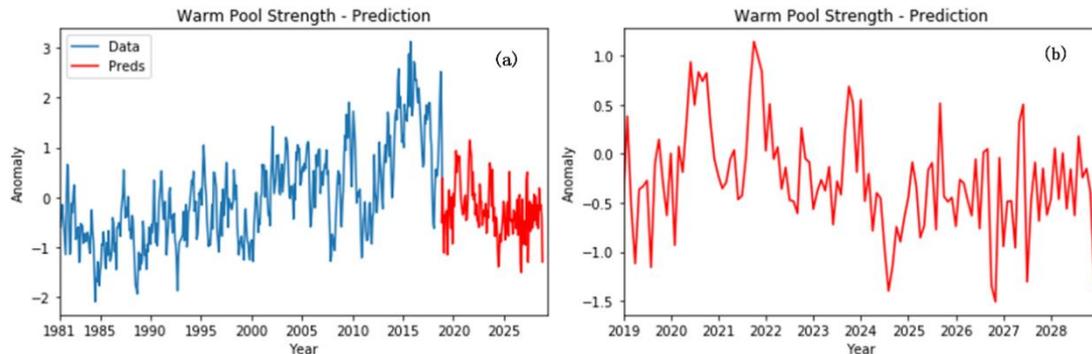


图 6 1981—2028 年暖池强度变化(a)和未来 120 个月暖池强度预测(b)

Fig. 6 Changes of warm pool intensity 1981—2028 (a) and warm pool intensity prediction for the next 120 months (b)

与暖池面积变化相同，暖池强度具备不断增长的长期变化趋势。将原始数据减去年循环、通过 12 个月低通滤波得到暖池强度的低频变化，并通过 1 300 d 高通滤波除去长期变化趋势的影响后，暖池强度和 MEI 指数之间的相关系数为 0.59， P 值小于 0.05，表明暖池强度与 ENSO 事件存在正相关关系。在图 7(b)中，2019 年初，暖池强度达到极小值，从 2019 年中旬开始不断增长，在 2020 年达到极大值，增长持续时间长，根据暖池强度低频变化与 ENSO 事件之间的正相关关系，模型预测结果表明，2020 年将出现厄尔尼诺现象，可能持续到 2022 年，甚至是 2023 年。在 2024 年，暖池强度出现极小值，可能出现拉尼娜现象。

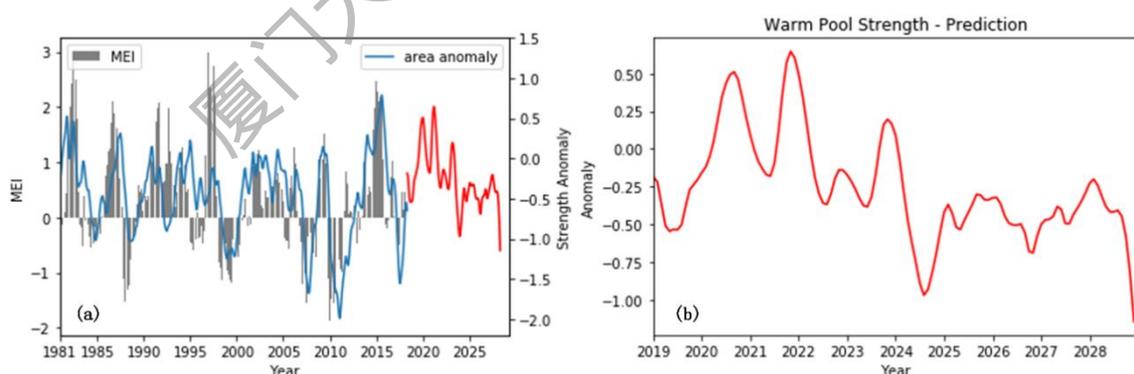


图 7 1981—2028 年暖池强度预测低频变化（无长期趋势）与 MEI 指数(a)和未来 120 个月暖池强度预测低频变化（无长期趋势）(b)

Fig. 7 MEI index and low frequency variation prediction based on warm pool intensity (removal of long-term trend) during 1981—2028 (a), and low frequency variation prediction based on warm pool intensity (removal of long-term trend) for the next 120 months (b)

2.3 暖池质心纬度预测

暖池质心纬度模型对未来 10 年暖池质心纬度的预测结果表明（图 8）：未来 120 个月暖池质心将在 $10^{\circ}\text{S}\sim 10^{\circ}\text{N}$ 的范围内南北移动；在 2024 年之前，预测结果具备明显的周期性变化规律，但 2024 年之后，预测结果不再符合暖池质心纬度的变化规律，准确度较低。

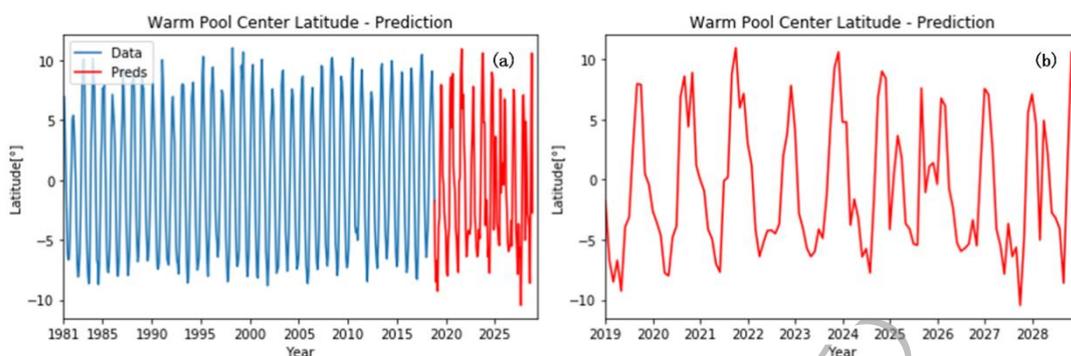


图 8 1981-2028 年暖池质心纬度变化(a)和未来 120 个月暖池质心纬度预测(b)

Fig. 8 Changes of the warm pool centroid latitude 1981-2028 (a) and the warm pool centroid latitude prediction for the next 120 months (b)

因为暖池质心的纬度变化不具备明显的长期变化趋势，无需进行高通滤波。同时暖池质心纬度的季节变化规律非常明显，但模型预测的季节变化规律与实际变化不完全一致，减去实际值年循环后不能有效除去季节变化信号，所以将预测值进行 40 个月低通滤波得到低频变化，保留了与 ENSO 事件相同周期的信号。计算得到暖池质心纬度和 MEI 指数之间的相关系数为-0.46， P 值小于 0.05，在 95% 的置信度下认为暖池质心南北方向的移动和 ENSO 事件存在相关性。相关系数为负值但并不接近-1，表明具备较弱的负相关关系。模型预测结果表明，2019 年和 2020 年上半年将出现厄尔尼诺事件，2021 年出现拉尼娜现象，2022 年和 2023 年将出现较弱的厄尔尼诺现象，2024—2025 年将出现一场持续时间较长的拉尼娜事件，随后，2026 年开始，厄尔尼诺现象持续发力，在 2027 年达到最强（图 9）。

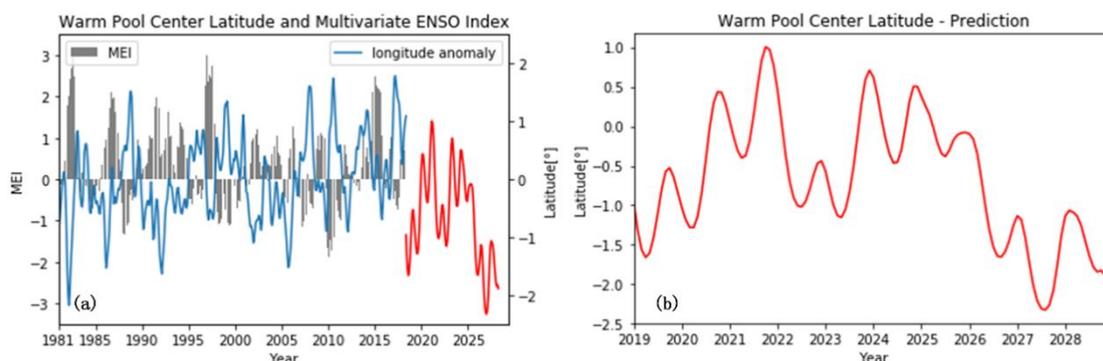


图 9 1981-2028 年暖池质心纬度预测低频变化与 MEI 指数(a)和未来 120 个月暖池质心纬度预测低频变化(b)

Fig. 9 MEI index and low frequency variation prediction based on the warm pool centroid latitude during 1981—2028 (a), and low frequency variation prediction based on the warm pool centroid latitude for the next 120 months (b)

2.4 暖池质心经度预测

暖池质心经度模型对未来 10 年的暖池质心经度进行预测的结果表明（图 10）：未来 120 个月暖池质心将在 $145^{\circ}\text{E}\sim 175^{\circ}\text{W}$ 的范围内东西移动；2019 年年初，暖池质心不断向西移动，在 2020 年向东移动且向东偏移的态势一直持续到 2022 年中旬，之后暖池质心向西移动至最西端约 145°E ，并在之后的几年呈现缓慢东移的趋势，于 2028 年达到最东端。

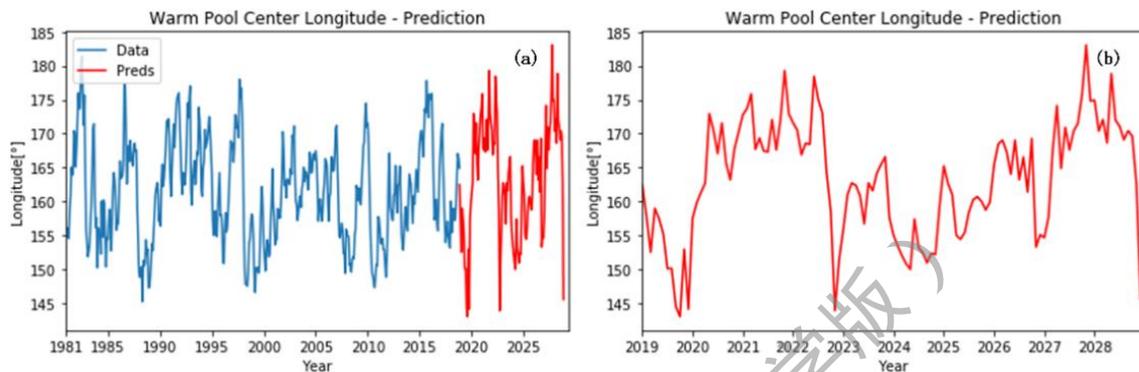


图 10 1981—2028 年暖池质心经度变化(a)和未来 120 个月暖池质心经度预测(b)

Fig. 10 Changes of the warm pool centroid longitude during 1981—2028 (a) and the warm pool centroid longitude prediction for the next 120 months (b)

将预测值减去 1981-2018 年暖池质心经度的年循环、通过 365 天低通滤波，得到暖池质心经度的低频变化。计算得到暖池质心经度和 MEI 指数之间的相关系数为 0.88， P 值小于 0.05，相关系数为正值且接近 1，表明暖池质心东西方向的移动和 ENSO 事件具备显著的正相关关系。在图 11 中可以看到，暖池质心经度数据的负峰值非常突出，可能会错误判断拉尼娜事件的发生和强度。模型预测结果表明，2020—2022 年将出现一场持续时间久、强度大的厄尔尼诺事件，2024 年可能出现一次较弱的拉尼娜现象，从 2025 年年底开始，厄尔尼诺现象持续发力，在 2027 年达到最强。

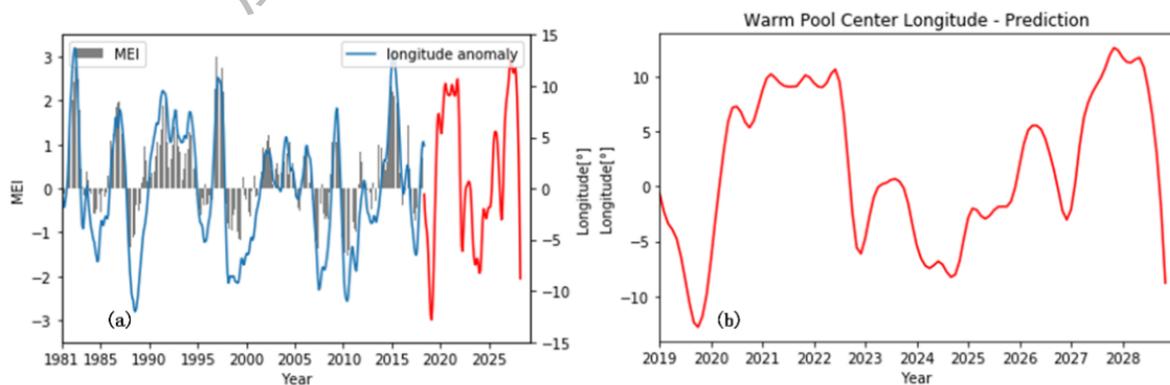


图 11 1981-2028 年暖池质心经度预测低频变化与 MEI 指数(a)和未来 120 个月暖池质心经度预测低频变化(b)

Fig. 11 MEI index and low frequency variation prediction based on the warm pool centroid longitude during 1981—2028 (a), and low frequency variation prediction based on the warm pool centroid longitude for the next 120 months (b)

3 讨论与结论

本文将深度学习技术应用于海洋科学研究，利用长短期记忆神经网络（LSTM）成功构建 4 个用于预测暖池指数时间序列的模型，通过设定序列长度、学习率和迭代次数 3 个超参数，达到了模型在训练、测试和预测中都表现良好的目的。预测结果展现了未来 10 年（2019—2028 年）暖池大小、强度和位置的变化情况，并通过暖池指数对 ENSO 事件进行了预测。

从暖池面积、暖池强度、暖池质心经度和暖池质心纬度 4 个 LSTM 神经网络模型的预测结果可以看出，4 个暖池模型都很好的预测到暖池指数的多尺度变异特征，包括季节内变化、季节变化和低频变化，但暖池面积模型多学习了实际数据并不存在的半年尺度变异特征，暖池面积模型和暖池强度模型没有学习到不断增长的长期变化趋势，这说明即使是具备长期记忆能力的 LSTM 神经网络模型，在学习和训练较长的时间序列数据时仍然存在问题。同时，根据暖池质心纬度模型的预测结果，5 年以上的预测结果准确度会大大下降。

本文还结合 4 个暖池指数与 MEI 指数相关关系对未来 10 年 ENSO 事件的发生进行了预测。4 个模型都认为在 2019 年年底到 2020 年将出现厄尔尼诺现象，暖池强度模型和暖池质心经度模型结果表明这场厄尔尼诺现象将持续到 2023 年，而暖池面积模型和暖池质心纬度模型结果表明在 2021 年中会出现拉尼娜现象，之后将再出现较弱的厄尔尼诺现象。4 个模型都认为在 2024 年将出现明显的拉尼娜现象，而 2027 年冬季将再次出现厄尔尼诺现象。4 个 LSTM 神经网络模型在对 ENSO 事件是否发生的判断上具有高度一致性，预测结果与 2019 年底发生的厄尔尼诺现象相符，表明了预测的有效性。

然而，本研究仅使用 LSTM 神经网络实现了暖池 4 个指数在时间尺度上的预测，无法了解它们在空间尺度上的变化情况。Yang 等^[18]曾在 LSTM 提取时间尺度信息的基础上增加一个卷积层提取空间信息，实现了海表温度的时空预测。除此之外，许柏宁等^[19]提出使用序列到序列（sequence to sequence, Seq2Seq）模型结合卷积长短期记忆神经网络（convolutional long short-term memory, ConvLSTM）预测区域海表温度异常，之后的研究证实这一方法在长期预报中优于 LSTM 模型^[20-21]。

此外，目前的大部分研究仅根据海表温度等温线或者固定区域划定暖池。实际上，暖池并不是二维平面的，而是一个具有三维结构的水体^[22-23]。厄尔尼诺事件的发生和暖池下层水体的运动情况息息相关。如果能够得到海表以下的海水温度分布情况，使用等温面划定暖池，增加考虑暖池深度这一参数，可能更有利于了解暖池的变化情况，提高 ENSO 事件预测的准确度。

参考文献:

- [1] 胡石建, 胡敦欣. 西太平洋暖池研究综述[J]. 海洋科学集刊, 2016(1):37-48.

- [2] YAN X H, HO C R, ZHENG Q, et al. Temperature and size variabilities of the western Pacific warm pool[J]. *Science*, 1992, 258(5088):1643-1645.
- [3] PHILANDER S G. El Nino and La Nina[J]. *Journal of the Atmospheric Sciences*, 1989, 42(23): 2652-2662.
- [4] YAN X H, HE Y, LIU W, et al. Centroid motion of the western Pacific warm pool during three recent El Nino-Southern Oscillation events[J]. *Journal of Physical Oceanography*, 1997, 27(5):837-845.
- [5] KIDWELL A, JO Y H, YAN X H. A closer look at the central Pacific El Nino and warm pool migration events from 1982 to 2011[J]. *Journal of Geophysical Research Oceans*, 2014, 119(1):165-172.
- [6] KIDWELL A, HAN L, JO Y H, et al. Decadal western Pacific warm pool variability: a centroid and heat content study[J]. *Scientific Reports*, 2017, 7(1):13141.
- [7] 冯士筵, 李凤歧, 李少菁. 海洋科学导论[M]. 高等教育出版社, 1999.:267-268.
- [8] WUNSCH C. El Nino, La Nina, and the Southern Oscillation[M]. San Diego: Academic Press, 1989: 293.
- [9] HO C R, YAN X H, ZHENG Q N. Satellite observations of upper layer variabilities in the western Pacific warm pool[J]. *Bulletin of the American Meteorological Society*, 1995, 76(5):669-679.
- [10] 方立新, 陈戈, 方朝阳, 等. 基于 AVHRR/SST 的西太平洋暖池近期变化研究[J]. *中国海洋大学学报(自然科学版)*, 2004, 34(1):103-108.
- [11] 胡石建. 西太平洋暖池变异及其机制研究[D]. 北京: 中国科学院研究生院(海洋研究所), 2013.
- [12] PATIL K, DEO M C, RAVICHANDRAN M. Prediction of sea surface temperature by combining numerical and neural techniques[J]. *Journal of Atmospheric and Oceanic Technology*, 2016, 33(8):1715-1726.
- [13] 徐凌宇, 张高唯, 江湾湾, 等. 深度学习神经网络及其在海洋环境信息挖掘预测中的应用[J]. *海洋信息*, 2018, 235(01):21-27+39.
- [14] MAZZARELLA A, GIULIACCI A, SCAFETTA N. Quantifying the Multivariate ENSO Index (MEI) coupling to CO2 concentration and to the length of day variations[J]. *Theoretical and Applied Climatology*, 2013, 111(3-4):601-607.
- [15] Fulkerson, B. Pattern Recognition and Neural Networks[J]. *Technometrics*, 1997, 39(2), 233-234.
- [16] 国家气象局国家气候中心. 海洋状况指数检测 [EB/OL]. [2020-06-30] https://cmdp.ncc-cma.net/Monitoring/cn_nino_index.php?product=cn_nino_index_pa.
- [17] 孙苗, 符昱, 吕憧憬, 等. 深度学习在海洋大数据挖掘中的应用[J]. *科技导报*, 2018, 36(17):83-90.
- [18] YANG Y, DONG J, SUN X, et al. A CFCC-LSTM model for sea surface temperature prediction [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 15(2):1-5.
- [19] 许柏宁, 姜金荣, 郝卉群, 等. 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[J]. *科研信息化技术与应用*, 2017, 8(6):65-76.
- [20] 何丹丹, 姜金荣, 郝卉群, 等. 基于深度学习的 ENSO 预报方法研究[J]. *科研信息化技术与应用*, 2019, 10(1):38-47.
- [21] HE D, LIN P, LIU H, et al. DLENSO: A deep learning ENSO forecasting model[M]//Trends in artificial intelligence. [S.l.]:PRICAI, 2019.
- [22] WYRTKI K. Some thoughts about the west Pacific warm pool[C]//Western Pacific International Meeting & Workshop on Toga Coare Proceedings. [S.l.]:ORSTOM, 1989.
- [23] PHILANDER S G. El Nino, La Nina, and the Southern Oscillation[M]. [S.l.]:Academic Press, 1990.

Trend prediction of Western Pacific warm pool based on the long short-term memory neural networks

LIN Qifan¹, GENG Xupu^{2*}, XIE Ting², HU Liping³

(1. Department of Atmospheric and Oceanic Sciences, School of Physics, Peking University, Beijing 100871, China; 2. College of Ocean and Earth Sciences, State Key Laboratory of Marine Environmental Science, Xiamen University, Xiamen 361102, China; 3. Science and Technology on Electromagnetic Scattering Laboratory, Beijing 100854, China)

Abstract: The Western Pacific Warm Pool is the sea area defined by the isotherm of sea surface temperature above 28 °C in the west of tropical Pacific Ocean, which is an important component of a large-scale phenomenon, El Niño-Southern Oscillation (ENSO), between the ocean and the atmosphere in the tropical Pacific Ocean. This paper applies four indexes of warm pool area, warm pool intensity, warm pool centroid latitude and warm pool centroid longitude to characterize the size and position of warm pool, and the long short-term memory (LSTM) model is established based on it. Moreover, the paper predicts the change of warm pool area, warm pool intensity and the position of warm pool centroid by optimizing the sequence length, learning rate and epochs in the following decade. After the smoothing by butterworth filter, the results find that there is a correlation between low frequency variation of the warm pool and MEI. The rationality of the model is demonstrated by successful predictions of the occurrence of ENSO events in the following decade. According to the prediction results, there will be an El Niño events from the end of 2019 to 2020, which is consistent with the actual El Niño events that occurred at the end of 2019.

Keywords: Western Pacific warm pool; long short-term memory neural networks; time series prediction; El Niño-Southern Oscillation