

# 基于小波变换和 LSTM 神经网络的格陵兰岛近海海域海平面变化预测

赵 健, 刘仁强

(中国石油大学(华东) 海洋与空间信息学院, 山东 青岛 266580)

**摘要:** 海平面变化包含多种不同时间尺度信息, 传统的预测方法仅对海平面变化趋势项、周期项进行拟合, 难以利用海平面变化的不同时间尺度信号, 使得预测精度不高。本文基于深度学习的预测模型, 提出一种融合小波变换(wavelet transform, WT)与 LSTM(long short-term memory, LSTM)神经网络的海平面异常组合预测模型。首先利用小波分解得到反映海平面变化总体趋势的低频分量和刻画主要细节信息的高频分量; 然后通过 LSTM 神经网络对代表不同时间尺度的各个分量预测和重构, 实现海平面变化的非线性预测。基于该模型的海平面变化预测的均方根误差、平均绝对误差和相关系数分别为 12.76 mm、9.94 mm 和 0.937, 预测精度均优于 LSTM 和 EEMD-LSTM 预测模型, WT-LSTM 组合模型对区域海平面变化预测具有较好的应用价值。

**关键词:** 海平面异常; 小波变换; 长短时记忆网络; 海平面变化; 预测

中图分类号: P727      文献标识码: A      文章编号: 1000-3096(2023)8-0007-10

DOI: 10.11759/hyxx20220413002

海平面上升是由气候变暖、极地冰川融化、上层海水热膨胀等引起的全球性环境问题, 是全球气候变化的重要指标。2019 年发布的《气候变化下的海洋和冰冻圈》<sup>[1]</sup>表明: 全球海平面上升速率从 1901—1990 年的 1.4 mm/a 增加到 1993—2015 年的 3.2 mm/a。而 NASA(National Aeronautics and Space Administration)、AVISO(Archivage, Validation et Inter-prétation des données des Satellites Océanographiques)等机构所确定的 1993 年至今的全球平均海平面变化速率约为 3.3~3.5 mm/a, 不确定度约为 0.4 mm/a<sup>[2]</sup>。作为一种缓发性灾害, 海平面持续升高会造成沿海地区海水入侵、土壤盐渍化、海岸侵蚀等, 同时会破坏沿海国家和地区的生态环境, 成为制约经济发展的重要因素。因此准确掌握海平面变化规律并合理预测海平面变化, 对人口众多、经济发达的沿海地区具有极其重要的科学和现实意义。

海平面异常(sea level anomaly, SLA)是经过一系列大气逆气压、电离层、对流层、潮汐改正的卫星观测瞬时海平面与平均海平面的差值, 可有效反映海平面变化规律, 是海平面变化和中尺度涡研究的重要数据来源。目前海平面变化预报的方法可概括为两类: 气候模型和传统数理统计方法。气候模型主要是利用影响海平面变化的驱动机制, 通过全

球海、气、陆及海冰耦合模式实现大尺度海平面变化研究; 传统数理统计方法依据海平面变化的规律进行拟合外推, 多用于区域海平面研究。海平面变化通常可以分为趋势项、周期项、剩余随机项和白噪声等 4 部分<sup>[3]</sup>, 针对海平面变化的各部分需要采用不同方法进行拟合或分离。传统数理统计方法多采用最小二乘拟合海平面变化的趋势项<sup>[4-6]</sup>, 周期项可以通过经验模态分解、集合经验模态分解、小波分解、奇异谱分析等方法提取<sup>[7-9]</sup>, 剩余随机项可以通过自回归滑动平均<sup>[3, 9-10]</sup>等模型进行预测。近年来, 随着深度学习算法的深入发展, 各种神经网络因其良好的非线性拟合能力被广泛应用于海平面变化非线性预测中, 如 BP(back-propagation)、RBF(radial basis function)、LSTM(long short-term memory)等神经网络<sup>[5, 10-13]</sup>。孙文等<sup>[14]</sup>利用 20 年的卫星测高数据对人工神经网络、支持向量机、自回归滑动平均、摆动灰色模型等方法的预报结果进行对比, 结

收稿日期: 2022-04-13; 修回日期: 2022-10-01

基金项目: 国家重点研发计划项目(2016YFA0600102)

[Foundation: The National Key Research and Development Program of China, No. 2016YFA0600102]

作者简介: 赵健(1981—), 男, 山东齐河人, 博士, 副教授, 主要研究方向为卫星大地测量数据处理, E-mail: zhjianupc@163.com

果表明神经网络对于海平面预测具有更好的适应性。顾小丽等<sup>[7]</sup>利用 RBF 神经网络延拓原始数据,较好地抑制了经验模态分解(empirical mode decomposition, EMD)的端点效应。集合经验模态分解(ensemble empirical mode decomposition, EEMD)的提出有效改善了 EMD 分解中的模态混叠现象<sup>[15]</sup>,赵健等<sup>[11]</sup>提出了 EEMD-BP 组合模型,可较好地分解出海平面变化中存在的不同时间尺度信号,有效提高预测精度。Zhao 等<sup>[16]</sup>提出的 SSA-LSTM 组合模型,通过引入 LSTM 神经网络使得海平面非线性变化预测精度明显提高。虽然已有研究人员对海平面变化的驱动机制进行了较为深入的探讨,但是使用不同数据和预测方法会导致海平面变化的预测结果存在一定差异,还需进一步加强海平面变化预测的相关研究。

格陵兰海和挪威海是沟通北冰洋和大西洋海水交换的主要通道,该区域海平面变化直接反映了北冰洋和大西洋的海水交换情况,对于掌握北冰洋与北大西洋水文要素、研究高纬地区海平面变化机制具有重要意义。在目前的海平面变化研究中,大多集中在中低纬度地区,对于高纬地区海平面变化的研究相对较少。Rose 等<sup>[17]</sup>通过再处理北极卫星数据进行海平面变化研究发现,1991—2018 年波弗特环流区和格陵兰岛近海海域海平面显著上升,而挪威海近岸海域海平面上升最为明显,北极海平面整体以 1.54 mm/a 的速率上升。金波文等<sup>[18]</sup>利用新奥尔松地区验潮站和 GNSS(Global Navigation Satellite System)

数据分析得出该区域 1993—2018 年的绝对海平面变化速率为  $0.78 \pm 0.41$  mm/a,海平面变化存在明显的周期性和季节性。江伟伟等<sup>[19]</sup>对格陵兰岛近海海域进行相关研究发现该区域 1992—2010 年海平面变化速率约为 1.7 mm/a,且冰岛附近海域海平面上升速率最高。目前,高纬地区海平面变化的研究仅局限于北极区域的数据再处理和历史数据的变化分析。本文基于我国首套自主研发的全球海洋气候数据集产品,在对格陵兰岛近海海域海平面异常数据进行深入分析的基础上,对比不同预测模型的预测精度,构建基于小波变换和 LSTM 网络的 WT-LSTM 组合模型,并对该区域 2016—2020 年海平面变化趋势进行预测。

## 1 研究区域及数据来源

### 1.1 研究区域

格陵兰岛近海海域主要由格陵兰海和挪威海组成( $60^{\circ}\text{N} \sim 82^{\circ}\text{N}$ ,  $45^{\circ}\text{W} \sim 27^{\circ}\text{E}$ ),其西邻格陵兰岛,东接欧洲斯堪的纳维亚半岛,南北分别与北冰洋和北大西洋相接,如图 1 所示。该区域是北冰洋的边缘海之一,同时也是沟通北冰洋和大西洋海水交换的重要通道。受格陵兰寒流和挪威暖流影响,北冰洋海水流出总量的 83%从格陵兰岛东部流出,流入总量 78%的海水从该海域东部流入北冰洋<sup>[20]</sup>。研究格陵兰岛近海海域的海平面变化规律,对掌握北冰洋和大西洋海水交换情况及北极气候变化具有重要意义。

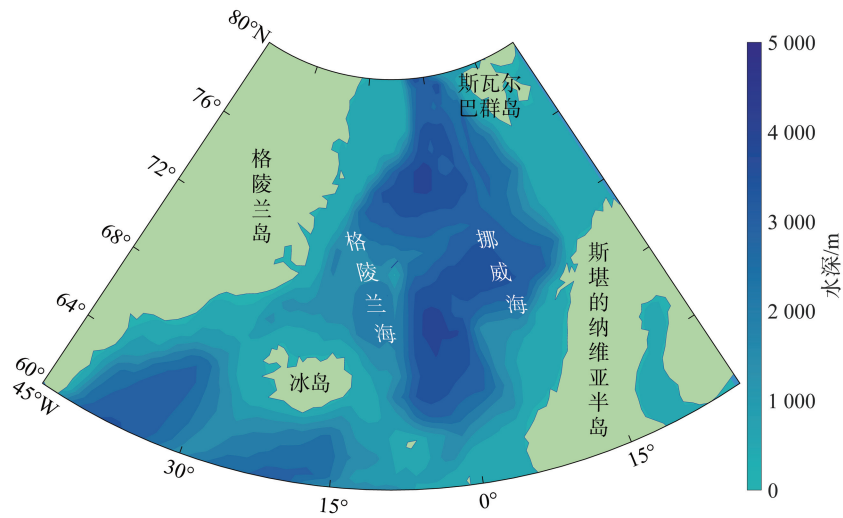


图 1 研究区域示意图

Fig. 1 Map of the study area

## 1.2 数据来源

本文采用的 SLA 数据来源于自然资源部第一海洋研究所研制的我国首套全球海洋气候数据集 (Climate Data Records, CDRs) 产品, 该数据集融合了 T/P、GFO、ERS-1/2、Jason-1/2、Envisat、Cryosat-2、HY-2A、Saral、Sentinel-3 等多颗卫星的测高数据<sup>[21-22]</sup>, 空间分辨率为  $0.25^\circ \times 0.25^\circ$ , 时间分辨率为 1 个月。由于获取 CDRs 数据的限制, 本文选取研究区域 1993 年 1 月—2015 年 12 月的 SLA 数据进行分析。

考虑到不同网格对应的实际面积大小会受到不同纬度的影响, 利用式(1)进行网格数据区域加权处理, 进而获取研究区域海平面变化的整体趋势。区域加权处理后的格陵兰岛近海海域 1993 年 1 月—2015 年 12 月的 SLA 时间序列如图 2 所示, 由图 2 可以发现, 格陵兰岛近海海域海平面具有明显的季节性变化特征, 每年春季(2—4 月)为季节性低海平面期, 秋季(9—11 月)为季节性高海平面期, 海平面变化表现出较为明显的上升趋势, 线性趋势约为  $2.12 \text{ mm/a}$ , 低于  $3.2 \text{ mm/a}$  的同期全球海平面变化上升速率<sup>[1]</sup>。

$$\bar{h}_k = \frac{\sum_i \sum_j h_{ijk} \cos(\phi_j)}{\sum_i \sum_j \cos(\phi_j)}, \quad (1)$$

式(1)中,  $\bar{h}_k$  表示  $k$  时刻的区域加权后的 SLA 值,  $i, j$  表示网格点位置,  $h_{ijk}$  表示  $k$  时刻  $(i, j)$  位置的 SLA 观测值,  $\phi_j$  表示取样点的纬度。




图 2 1993—2015 年区域平均后 SLA 时间序列

Fig. 2 Sea level anomaly time series of regional average processing from 1993 to 2015

## 2 WT-LSTM 组合预测模型

由于海平面变化存在不同时间尺度的信号特征, 如年周期、半年周期等, 通过小波变换的原理可知<sup>[23]</sup>,

利用小波函数可分解出一组包含不同周期的海平面变化信号。LSTM 神经网络可不需要了解海平面变化的驱动机制实现非线性预测, 但是海平面变化规律较为复杂, 单一的 LSTM 网络难以学习到不同时间尺度信号的历史规律。因此本文提出一种融合小波变换和 LSTM 神经网络的组合预测模型, 通过小波变换提取海平面变化的年周期、半年周期和季节内周期等, 并对每个时间尺度的信号建立 LSTM 预测模型进行海平面变化非线性预测。WT-LSTM 组合模型预测流程如下:

### (1) 小波基与分解层数的确定

目前小波基和分解层深的选择没有确切的标准, 小波基应选择与原信号近似的函数, 使得小波变换后的数据平滑; 分解层数不能太大或太小, 分解层数太大会造成信号的信息损失, 分解层数过少会造成去噪效果不明显, 影响精度。本文小波变换为实现海平面变化趋势的提取, 选用 2 层分解即可。常用的基小波有 Haar 小波、db 小波、sym 小波、bior 小波等, db6 小波是 db 小波族中常用的小波之一。由于 db6 小波分解出的 SLA 低频信号较为平滑且高频分量的周期与海平面变化存在的主要周期一致, 所以选用 db6 小波进行 2 层分解。

### (2) 离散小波分解

Mallat 算法<sup>[24]</sup>是一种利用低通和高通滤波器划分频带范围, 实现信号的分解与重构的简易算法。本文利用该算法对 SLA 信号进行离散小波分解, 分解过程如式(2)—(3)所示:

$$d_i = Ha_{i-1}, \quad (2)$$

$$a_i = Ga_{i-1}, \quad (3)$$

式(2)—(3)中,  $i$  表示分解层深,  $H$  和  $G$  分别是小波对应的低通和高通滤波器。经过第一次分解得到一个高频系数  $d_1$  和一个低频系数  $a_1$ , 第二次分解对低频系数  $a_1$  进行分解, 最后分解得到 2 个高频系数  $d_1, d_2$  和 1 个低频系数  $a_2$ 。

### (3) 小波系数重构

小波系数长度随分解层数的增加而变短, 因此需对分解的小波系数进行重构, 使得各系数长度与原序列长度相同, 重构算法如式(4)所示。

$$A_i = H^* a_{i+1} + G^* d_{i+1}, \quad (4)$$

式(4)中,  $H^*$  和  $G^*$  分别是  $H$  和  $G$  的对偶算子。重构得到海平面变化高频分量  $D_1, D_2$  和低频分量  $A_2$ , 且重构后的分量满足  $X = D_1 + D_2 + A_2$ 。

### (4) LSTM 模型构建

本文构建的 LSTM 网络包含输入层、隐含层和

输出层 3 部分, 其中隐含层神经元个数为 100, 时间步长为 1, 即前一个月 SLA 数据通过输入层输入, 经一层隐含层和全连接层输出后一个月预测值<sup>[25]</sup>。优化器选取自适应矩估计(Adam), 该优化器具有实现简单、参数更新不受梯度变换影响等特点<sup>[26]</sup>。将重构分量  $D_1$ ,  $D_2$ ,  $A_2$  输入到 LSTM 神经网络进行预测, 对应的预测值为  $\tilde{D}_1$ ,  $\tilde{D}$ ,  $\tilde{A}_2$ 。

### (5)海平面变化预测

将步骤(4)的预测结果  $\tilde{D}_1$ ,  $\tilde{D}$ ,  $\tilde{A}_2$  相加得到研究区域的海平面变化预测值  $\tilde{X}$ , 即  $\tilde{X} = \tilde{D}_1 + \tilde{D}_2 + \tilde{D}_3$ 。

WT-LSTM 组合模型具体预测流程如图 3 所示。

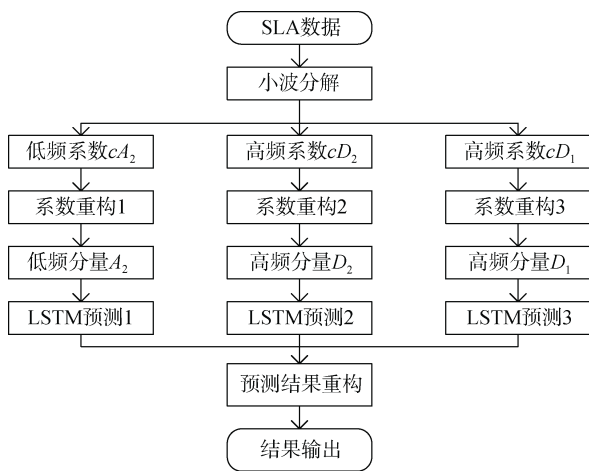


图 3 WT-LSTM 组合模型预测流程

Fig. 3 Prediction process of wavelet transform-long short-term memory combined model

## 3 实验及结果分析

### 3.1 评价指标

本文采用均方根误差(root mean square error, RMSE, 记为  $E_R$ )、平均绝对误差(mean absolute error, MAE, 记为  $E_{MA}$ )、相关系数  $R$  等评价指标对组合模型预测精度进行评价。 $E_R$ 、 $E_{MA}$  和  $R$  的计算公式如下<sup>[11]</sup>:

$$E_R = \sqrt{\frac{1}{n} \sum_{i=1}^n (h_i - \tilde{h}_i)^2}, \quad (5)$$

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |h_i - \tilde{h}_i|, \quad (6)$$

$$R = \frac{\sum_{i=1}^n ((h_i - \bar{h}_i)(\tilde{h}_i - \bar{\tilde{h}}_i))}{\sqrt{\sum_{i=1}^n (h_i - \bar{h}_i)^2 \sum_{i=1}^n (\tilde{h}_i - \bar{\tilde{h}}_i)^2}}, \quad (7)$$

式(5)–(7)中,  $h_i$  表示 SLA 观测值,  $\tilde{h}_i$  表示 SLA 预测值,  $\bar{h}_i$  和  $\bar{\tilde{h}}_i$  分别表示 SLA 观测值和预测值的平均值。

### 3.2 WT-LSTM 组合预测模型精度分析

为检验本文构建的 WT-LSTM 组合模型预测精度, 利用文献[11]构建 EEMD-LSTM 组合模型与 WT-LSTM 模型进行预测效果对比。分别采用 EEMD 和 WT 方法对格陵兰岛近海海域 1993—2015 年的 SLA 时间序列进行分解, 再构建 LSTM 神经网络模型进行海平面变化预测。

EEMD 分解时设置高斯白噪声标准偏差为 0.4, 加入白噪声次数为 100。格陵兰岛近海海域 1993 年 1 月—2015 年 12 月的 SLA 时间序列经 EEMD 分解后得到 7 个 IMF 分量和 1 个趋势项, 如图 4(a)–(h) 所示, 由于 EEMD 分解出的 IMF6、IMF7 分量未通过 95% 显著性检验<sup>[27]</sup>, 认为这两个分量是包含物理意义较少的白噪声成分, 在后续利用 LSTM 网络进行预测时不考虑 IMF6、IMF7。经功率谱分析发现 IMF1—IMF5 分量对应的主要周期分别为 3.99 个月、11.96 个月、11.96 个月、55 个月、91.67 个月。其中 3.99 个月周期(IMF1)为海平面季节内变化, 11.96 个月周期(IMF2、IMF3)为海平面年变化, 55 个月周期(IMF4)可能与北大西洋涛动 4~5 a 的年际振荡有关, 91.67 个月周期(IMF5)则与海平面年代际变化相关。由图 4(c)、(d)、(e)等可以看出, 虽然 EEMD 分解可以很好地分离出海平面变化过程中不同时间尺度信号, 但是存在一定程度的模态混叠现象。

利用 db6 小波对格陵兰岛近海海域 1993 年 1 月—2015 年 12 月的 SLA 时间序列进行 2 层离散小波分解, 分解得到低频小波系数  $a_2$  和高频小波系数  $d_1$  和  $d_2$ , 并对小波分解得到的系数进行重构, 得到重构后的小波分量, 如图 5 所示。图 5 中  $D_1$  为高频小波系数  $d_1$  的重构成分;  $D_2$  和  $A_2$  分别为第二次分解得到的高频和低频小波系数的重构分量, 对比低频分量  $A_2$  和原始观测值信号可以看出分解出的低频分量能够较好地拟合海平面的整体变化趋势。通过对获取的各分量进行功率谱分析发现, 低频分量  $A_2$  的显著周期为 11.96 个月, 对应海平面年变化; 高频分量  $D_1$  的显著周期为 3.99 个月, 对应海平面季节内变化; 高频分量  $D_2$  的显著周期为 5.98 个月, 对应海平面半年变化。格陵兰岛近海海域海平面具有显著的年变化、半年变化和季节内变化特点。




图 4 1993—2015 年格陵兰岛近海海域 SLA 时间序列 EEMD 分解结果

Fig. 4 Ensemble empirical mode decomposition results of sea level anomaly time series of Greenland offshore waters from 1993 to 2015




图 5 1993—2015 年格陵兰岛近海海域 SLA 时间序列小波重构结果

Fig. 5 Wavelet reconstruction results of sea level anomaly time series of Greenland offshore waters from 1993 to 2015

对上述 EEMD 和 WT 分解得到的格陵兰岛近海域 SLA 时间序列各分量, 分别建立 LSTM 神经网络进行预测。考虑到海平面变化存在明显的年周期变化, 将研究区域的 SLA 时间序列按年份分为两部分, 前 216 个月(1993 年 1 月—2010 年 12 月)的数据作为训练集, 后 60 个月(2011 年 1 月—2015 年 12 月)的数据作为测试集。为防止数据泄露, 测试集数据不参与训练, 仅用来验证模型预测效果。通过不断调试为 LSTM 神经网络选取最优学习率、迭代次数等参数, 以达到模型最优预测精度。2011 年 1 月—2015 年 12 月 EEMD 和 WT 分解得到的各分量预测结果与实际观测值对比如图 6—图 7 所示。由图 6 可以看到, 对于具有明显周期性变化的 IMF2 和 IMF4 分量, LSTM 神经网络预测效果更好。由于 EEMD 分解得到的 IMF 分量存在不同程度的模态混叠现象, IMF3 和 IMF5 的预测效果相对较差。由图 7 可以发现, WT 分解得到的  $A_2$  和  $D_2$  分量主要包含海平面变化的趋

势、年周期和半年周期, LSTM 神经网络可以较好地对这些信息进行学习并有效预测; 而对于周期小于 6 个月的高频分量, 比如 EEMD 分解得到的 IMF1 分量和 WT 分解得到的  $D_1$  分量, LSTM 神经网络预测效果相对较差。

除上述 EEMD-LSTM 和 WT-LSTM 两种组合模型之外, 本文还构建了 LSTM 神经网络模型对研究区域 SLA 观测值进行直接预测。LSTM、EEMD-LSTM 和 WT-LSTM 三种模型的预测值与相同时间段原始观测值的对比结果如图 8 所示。从图 8 中可以看出, LSTM 模型预测结果的极值点与真实值相差较大; EEMD-LSTM 模型通过分解得到多个时间尺度分量, 再对各分量进行预测, 拟合效果较 LSTM 模型明显提高; 而 WT-LSTM 模型的预测结果与观测值最为吻合。三种模型的预测结果均与 SLA 实际观测值较为吻合, 能够较好地模拟出海平面变化的整体趋势。




图 6 EEMD 分解各分量预测效果与观测值对比

Fig. 6 Ensemble empirical mode decomposition of the prediction effect of each component and comparison of observed values

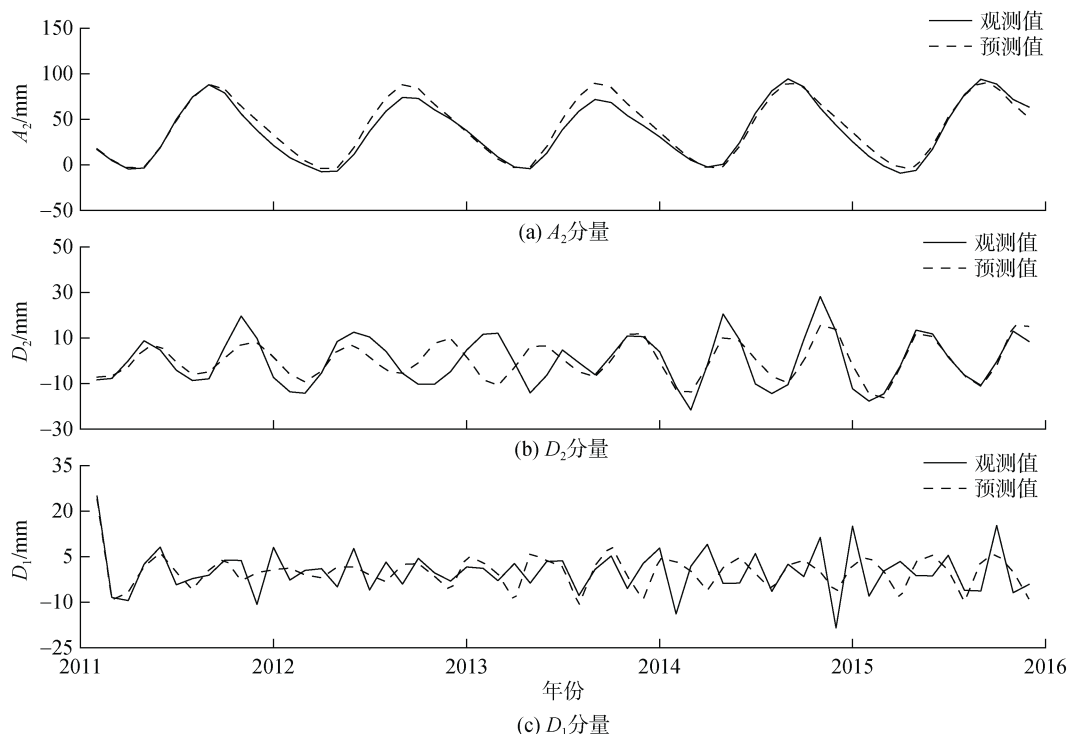


图 7 小波重构各分量预测效果与观测值对比

Fig. 7 Comparison between the prediction effect of each component of wavelet reconstruction and observed values

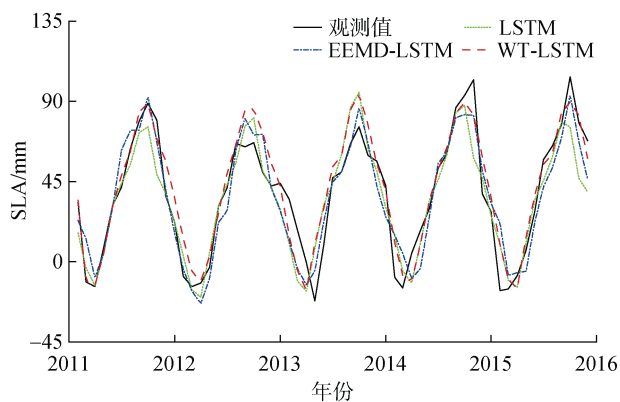


图 8 LSTM、EEMD-LSTM、WT-LSTM 模型预测结果对比  
Fig. 8 Prediction results of long short-term memory (LSTM), ensemble empirical mode decomposition-LSTM, and wavelet transform-LSTM models

表 1 为 LSTM、EEMD-LSTM、WT-LSTM 等三种模型 2011—2015 年预测值与原始观测值的误差统计。从表 1 可以看出, LSTM 模型仅学习了海平面变化的整体趋势, 无法准确把握海平面变化中不同时间尺度的变化信息, 预测结果相对较差。EEMD-LSTM 模型精度相对较低, 主要是因为 EEMD 分解得到的部分 IMF 分量对海平面变化影响较小, 在预测结果重构时导致误差累积; 其次, EEMD 分解结果中存在

的模态混叠也会影响预测精度。WT-LSTM 模型通过对小波分解得到的主要周期信号进行预测, 很好的把握海平面变化的趋势和周期信号, 同时减少了误差累积, 均方根误差( $E_R$ )、平均绝对误差( $E_{MA}$ )和相关系数( $R$ )三个指标均表现最为优异。

表 1 LSTM、EEMD-LSTM、WT-LSTM 模型预测误差比较

Tab. 1 Prediction errors of long short-term memory (LSTM), ensemble empirical mode decomposition-LSTM, and wavelet transform-LSTM models

模型	$E_R$ /mm	$E_{MA}$ /mm	$R$
LSTM	15.04	11.17	0.902
EEMD-LSTM	13.28	10.80	0.924
WT-LSTM	12.76	9.94	0.937

### 3.3 基于 WT-LSTM 组合模型的 2016—2020 年格陵兰岛近海海域海平面变化预测

基于上述分析, 本文采用 WT-LSTM 组合模型对格陵兰岛近海海域 2016 年 1 月—2020 年 12 月的海平面变化进行预测, 并与 AVISO(Archiving Validation and Interpretation of Satellite Oceanographic)提供的同期实测数据进行对比, 结果如图 9 所示。图 9

中黑色实线为研究区域 1993 年 1 月—2015 年 12 月的 SLA 观测值, 红色实线为基于 WT-LSTM 组合模型的格陵兰岛近海海域 2016 年 1 月—2020 年 12 月 SLA 预测结果, 蓝色虚线为研究区域 AVISO 同期实测数据。WT-LSTM 组合模型预测结果显示 1993—2020 年格陵兰岛近海海域海平面变化呈持续上升趋势, 线性速率约为 2.64 mm/a。基于 AVISO 网站提供的 SLA 实测数据得到的该海域 1993—2020 年海平面上升线性趋势约为  $2.65 \pm 0.49$  mm/a。从图 9 中可以看出, WT-LSTM 组合模型预测结果与 AVISO 实测数据非常吻合, 预测结果较为可靠。




图 9 基于 WT-LSTM 组合模型的格陵兰岛近海海域 2016—2020 年 SLA 预测结果与实测数据的比对

Fig. 9 Comparison of sea level-anomaly prediction results and measured data of Greenland offshore waters from 2016 to 2020 based on the wavelet transform-long short-term memory combined model

## 4 结论

本文基于我国首套自主研发的海洋 CDRs 产品, 利用格陵兰岛近海海域 1993—2015 年的 SLA 数据, 构建了 WT-LSTM 组合模型对该区域 2016—2020 年的海平面变化趋势进行预测, 主要结论为:

(1) WT-LSTM 组合模型不仅能够获取海平面变化的整体趋势, 还可提取半年变化、季节变化等海平面变化的细节信息, 从而掌握区域海平面变化中不同时间尺度信号的变化。WT-LSTM 组合模型 5a 期预测的均方根误差( $E_R$ )和平均绝对误差( $E_{MA}$ )分别为 12.76 mm 和 9.94 mm, 均低于 LSTM 和 EEMD-LSTM 模型, 表明该组合模型具有较高的预测精度。

(2) 基于我国首套海洋 CDRs 产品中的 SLA 数据, 利用 WT-LSTM 组合模型对格陵兰岛近海海域 2016—2020 年的海平面变化趋势进行了预测, 结果表明

该区域海平面变化呈现缓慢上升趋势, 速率约为 2.64 mm/a。

(3) WT-LSTM 组合模型对海平面变化的极值预测效果相对较差, 且极值预测存在一定的超前和滞后性, 在今后的研究中还需针对极值预测问题展开研究。

(4) 由于条件所限, 本文收集到的 CDRs 产品时间范围相对较短, 仅获取到格陵兰岛近海海域 1993—2015 年的 SLA 数据。而基于 WT-LSTM 组合模型的海平面变化预测是基于历史海平面变化规律对未来海平面变化趋势预测, 如能获取到更长时间范围的 SLA 数据, WT-LSTM 组合模型预测结果会更为准确。

### 参考文献:

- [1] IPCC. Summary for policymakers [M/OL]//IPCC. IPCC special report on the ocean and cryosphere in a changing climate, 2019[2019-11-03]. <https://www.ipcc.ch/srocc/>.
- [2] 金涛勇, 刘文轩, 姜卫平, 等. 卫星测高确定全球海平面变化研究进展[J]. 测绘地理信息, 2022, 47(3): 1-8. JIN Taoyong, LIU Wenxuan, JIANG Weiping, et al. Research progress on global sea level change determined by satellite altimetry[J]. Journal of Geomatics, 2022, 47(3): 1-8.
- [3] 牛余朋, 郭金运, 袁佳佳, 等. 集成奇异谱分析和自回归滑动平均预测日本近海海平面变化[J]. 地球物理学报, 2020, 63(9): 3263-3274. NIU Yupeng, GUO Jinyun, YUAN Jiajia, et al. Prediction of sea level change in Japanese coast using singular spectrum analysis and auto regression moving average[J]. Chinese Journal of Geophysics, 2020, 63(9): 3263-3274.
- [4] 孙文, 王庆宾. 基于最小二乘与 ARMA 组合模型的海平面异常预报[J]. 大地测量与地球动力学, 2012, 32(5): 91-94. SUN Wen, WANG Qingbin. Sea level anomaly forecasting based on combined model of least square and ARMA[J]. Journal of Geodesy and Geodynamics, 2012, 32(5): 91-94.
- [5] 赵健, 樊彦国, 丁宁. 基于最小二乘与径向基函数神经网络的海平面变化预测[J]. 海洋科学, 2018, 42(5): 92-97. ZHAO Jian, FAN Yanguo, DING Ning. Sea level anomaly forecasting using least square and the radial basis function neural network[J]. Marine Sciences, 2018, 42(5): 92-97.
- [6] ZHAO J, FAN Y, MU Y. Sea level prediction in the Yellow Sea from satellite altimetry with a combined Least Squares-Neural Network approach[J]. Marine Geodesy, 2019, 42(4): 344-366.



- [7] 顾小丽, 李培良, 谭海涛, 等. 基于 RBF 神经网络的 EMD 方法在海平面分析中的应用[J]. 海洋与湖沼, 2009, 40(5): 532-539.  
GU Xiaoli, LI Peiliang, TAN Haitao, et al. Sea level variation analysis with RBF neural network based EMD method[J]. *Oceanologia et Limnologia Sinica*, 2009, 40(5): 532-539.
- [8] ZHAO J, CAI R, FAN Y. Prediction of sea level nonlinear trends around Shandong Peninsula from satellite altimetry[J]. *Sensors*, 2019, 19(21): 4770.
- [9] 刘进宇, 汪海洪, 欧阳玉华. 基于 SSA 和 ARMA 的海平面变化短期预测[J]. 测绘地理信息, 2021, 46(S01): 305-307.  
LIU Jinyu, WANG Haihong, OUYANG Yuhua. Short-term prediction of sea level change based on SSA and ARMA[J]. *Journal of Geomatics*, 2021, 6(S1): 305-307.
- [10] SHEN Y, GUO J, LIU X, et al. Long-term prediction of polar motion using a combined SSA and ARMA model[J]. *Journal of Geodesy*, 2018, 92(3): 333-343.
- [11] 赵健, 樊彦国, 张音. 基于 EEMD-BP 组合模型的区域海平面变化多尺度预测[J]. 系统工程理论与实践, 2019, 39(10): 2713-2722.  
ZHAO Jian, FAN Yanguo, ZHANG Yin. Multi-scale prediction of regional sea level variations based on EEMD-BP combined model[J]. *Systems Engineering - Theory & Practice*, 2019, 39(10): 2713-2722.
- [12] LIU H, HE B, QIN P, et al. Sea level anomaly intelligent inversion model based on LSTM-RBF network[J/OL]. *Meteorology and Atmospheric Physics*, 2021, 133(2): 245-259.
- [13] 张雪薇, 韩震, 郭鑫. 深度学习在海洋信息探测中的应用: 现状与展望[J]. 海洋科学, 2022, 46(2): 145-155.  
ZHANG Xuewei, HAN Zhen, GUO Xin. Research progress in the application of deep learning to ocean information detection: status and prospect[J]. *Marine Sciences*, 2022, 46(2): 145-155.
- [14] 孙文, 王庆宾, 周睿, 等. 海平面异常序列预报方法的比较与分析[J]. 测绘通报, 2014, 60(1): 46-49.  
SUN Wen, WANG Qingbin, ZHOU Rui, et al. A comparison and analysis of methods of sea level anomaly time series forecasting[J]. *Bulletin of Surveying and Mapping*, 2014, 60(1): 46-49.
- [15] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. *Advances in Adaptive Data Analysis*, 2009, 1(1): 1-41.
- [16] ZHAO J, CAI R, SUN W. Regional sea level changes prediction integrated with singular spectrum analysis and long-short-term memory network[J]. *Advances in Space Research*, 2021, 68(11): 4534-4543.
- [17] ROSE S K, ANDERSEN O B, PASSARO M, et al. Arctic Ocean sea level record from the complete radar altimetry era: 1991–2018[J]. *Remote Sensing*, 2019, 11(14): 1672-1701.
- [18] 金波文, 王慧, 张建立, 等. 北极新奥尔松地区海平面变化和陆地垂直运动分析[J]. 武汉大学学报: 信息科学版, 2021, 46(4): 503-509.  
JIN Bowen, WANG Hui, ZHANG Jianli, et al. Sea level change and vertical land motion along Ny-Alesund coast in Arctic[J]. *Geomatics and Information Science of Wuhan University*, 2021, 46(4): 503-509.
- [19] 江伟伟, 李磊, 王春晖, 等. 格陵兰岛附近海域海平面变化的初步研究[J]. 中国海洋大学学报(自然科学版), 2011, 41(10): 10-16.  
JIANG Weiwei, LI Lei, WANG Chunhui, et al. A preliminary analysis on sea level change in the seas near the Greenland[J]. *Periodical of Ocean University of China (Natural Science)*, 2011, 41(10): 10-16.
- [20] 江伟伟. 格陵兰岛附近海域的海平面变化及影响因素研究[D]. 青岛: 中国海洋大学, 2011.  
JIANG Weiwei. Study on the sea level variations and influence factors in the seas near the Greenland[D]. Qingdao: Ocean University of China, 2011.
- [21] 张杰, 孙伟富, 杨俊钢, 等. 海洋气候数据集生成与分析简介[J]. 海洋科学进展, 2019, 37(2): 325-331.  
ZHANG Jie, SUN Weifu, YANG Jungang, et al. Brief introduction to the first global ocean climate data records (CDRs) of China[J]. *Advances in Marine Science*, 2019, 37(2), 325–331.
- [22] 孙伟富, 张杰, 孟俊敏, 等. 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, 2018, 36(3): 402-411.  
SUN Weifu, ZHANG Jie, MENG Junmin, et al. SST analysis of temporal and spatial distribution and change characteristics in the South China Sea and its adjacent waters[J]. *Advances in Marine Science*, 2018, 36(3): 402-411.
- [23] 贺国光, 马寿峰, 李宇. 基于小波分解与重构的时间序列预测法[J]. 自动化学报, 2002, 28(6): 1012-1014.  
HE Guoguang, MA Shoufeng, LI Yu. A study on forecasting for time series based on wavelet analysis[J]. *Acta Automatica Sinica*, 2002, 28(6): 1012-1014.
- [24] MALLAT S G. A theory for multiresolution signal decomposition: the wavelet representation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 1989, 11(7): 674-693.
- [25] 李亚蒙, 孙宝楠, 丁军航, 等. 基于 LSTM 的海洋表面短期风速预测研究[J]. 海洋科学, 2022, 46(11): 55-66.  
LI Yameng, SUN Baonan, DING Junhang, et al. Short-term wind-speed prediction of ocean surface based on LSTM[J]. *Marine Sciences*, 2022, 46(11): 55-66.
- [26] 周玮辰, 韩震, 张雪薇. 基于融合 U-Net 及 ConvLSTM 的海面高度异常预报方法研究[J]. 海洋通报, 2021,

40(4): 410-416.

ZHOU Weichen, HAN Zhen, ZHANG Xuwei. Research on sea level anomaly prediction based on U-Net structure and ConvLSTM layers[J]. Marine Science Bulletin, 2021, 40(4): 410-416.

[27] WU Z, HUANG N E. A study of the characteristics of white noise using the empirical mode decomposition method[J]. Proceedings of the Royal Society of London, Series A: Mathematical, Physical and Engineering Sciences, 2004, 460(2046): 1597-1611.

## Prediction of sea level change based on wavelet transform and LSTM neural network near Greenland

ZHAO Jian, LIU Ren-qiang

(College of Oceanography and Space Informatics, China University of Petroleum (East China), Qingdao 266580, China)

**Received:** Apr. 13, 2022

**Key words:** sea level anomaly; wavelet transform; long short-term memory network; sea level change; prediction

**Abstract:** The information on sea-level change data spans several time scales. The traditional prediction methods only fit the trend and periodic terms of sea level change, making it difficult to decompose the signals of different time scales, thereby resulting in low prediction accuracy. This paper proposes a combined prediction model of sea level anomalies based on deep learning prediction models that integrate wavelet transform (WT) and long short-term memory (LSTM) neural networks. Firstly, wavelet decomposition is performed to obtain the low-frequency component reflecting the overall trend of sea level change and the high-frequency component reflecting the main features; each component is then predicted and reconstructed by an LSTM neural network to realize the nonlinear prediction of sea level change. The root mean square error, mean absolute error, and correlation coefficient of sea-level change prediction based on this model are 12.76 mm, 9.94 mm, and 0.937, respectively, and the prediction accuracy is better than that of the LSTM and ensemble empirical mode decomposition-LSTM prediction models. Therefore, WT-LSTM combined model has better application potential for regional sea-level change prediction.

(本文编辑: 丛培秀)