

集成奇异谱分析和长短期记忆网络的 区域海平面变化预测

赵 健¹, 蔡瑞阳², 孙伟富³

(1. 中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266580; 2. 江苏满运物流信息有限公司, 江苏 南京 210012;
3. 自然资源部第一海洋研究所, 山东 青岛 266061)

摘要: 基于我国首套高精度全球海洋气候数据集(CDRs), 选取季节变化较为明显的黄海作为研究区域, 利用奇异谱分析(SSA)对黄海海域海平面异常(SLAs)数据进行了时间序列与时空序列的分解去噪, 并结合长短期记忆(LSTM)网络构建了SSA-LSTM组合模型, 对黄海海域海平面变化趋势进行预测。结果表明:SSA-LSTM组合模型对时间序列的预测精度显著提高, 预测长度5年的均方根误差最小为35.04 mm; 在对时空序列的预测中, 预测第1年的均方根误差最小为19.68 mm。同时, 利用空间模态进行了海平面变化时空分异规律研究, 发现黄海海域海平面变化趋势具有高度一致性, 并且与季节、纬度显著相关。预计2016年—2025年黄海海域海平面将以每年 3.65 ± 0.79 mm的速率持续上升。

关键词: 海平面异常(SLA); 时空序列; 奇异谱分析(SSA); 长短期记忆(LSTM)网络; 黄海海域

中图分类号: P228

文献标志码: A

Regional Sea Level Change Prediction with Integration of Singular Spectrum Analysis and Long-short-term Memory Network

ZHAO Jian¹, CAI Ruiyang², SUN Weifu³

(1. College of Oceanography and Space Informatics, China University of Petroleum (East China), Qingdao 266580, China; 2. Jiangsu Manyun Logistics Information Co., Ltd., Nanjing 210012, China; 3. First Institute of Oceanography, the Ministry of Natural Resources, Qingdao 266061, China)

Abstract: In this paper, the China's first global ocean climate data records (CDRs) are used to analyze and predict the sea level changes in the Yellow Sea with obvious seasonal changes. Based on the singular spectrum analysis (SSA), the time and spatio-temporal series of sea

level anomalies (SLAs) in the Yellow Sea are decomposed and de-noised. Then the SSA-long short-term memory (LSTM) network (SSA-LSTM combined model) is established to predict the sea level trends of the Yellow Sea. Compared with the traditional methods, the prediction accuracy of the SSA-LSTM combined model is significantly improved with 35.04 mm of the minimum root-mean-square error for the SLAs time series prediction length of 5 years. For the first-year prediction of spatial-temporal series of SLAs, the minimum root-mean-square error is only 19.68 mm. The law of spatial-temporal differentiation of the sea level change in the Yellow Sea is also analyzed by the spatial modes. It is found that the sea level trend of the Yellow Sea is highly consistent and significantly related to the season and latitude. According to the SSA-LSTM combined model, the sea level rise rate of the Yellow Sea will remain at 3.65 ± 0.79 mm per year from 2016 to 2025.

Key words: sea level anomaly (SLA); spatio-temporal series; singular spectrum analysis (SSA); long short-term memory (LSTM) network; the Yellow Sea

气候变暖背景下全球平均海平面呈持续上升趋势, 给人类社会的生存和发展带来严重挑战, 已成为当今国际社会普遍关注的全球性热点问题^[1]。海平面上升是一个缓慢但持续的过程, 其长期累积的结果将对沿岸地区构成严重威胁^[2]。1970年—2015年, 全球平均海平面上升了0.93 m^[3]。近40年来中国沿海海平面变化总体呈波动上升趋势, 1980年—2021年中国沿海海平面上升速率为每年3.4 mm, 远高于每年2.0 mm的全球平均上升速率^[4]。

收稿日期: 2021-01-28

基金项目: 国家重点研发计划(2016YFA0600102)

第一作者: 赵 健(1981—), 男, 副教授, 硕士生导师, 工学博士, 主要研究方向为卫星大地测量学。

E-mail: zhjianupc@163.com



论文
拓展
介绍

我国约70%以上的大中城市和一半以上的人口集中分布在东部沿海地区,该区域人口密集、经济发达,但由于地势较低和地质沙质等原因,该区域也是受海平面上升影响最为严重的脆弱区域^[5]。王龙等^[6]利用卫星高度计数据研究东海海平面变化的线性趋势,赵健等^[7]提出一种反向传播(BP)神经网络组合模型研究东海海域海平面长期变化趋势,Wang等^[8]构建了多模态融合的神经网络模型以预测南海海域海平面变化。目前,针对我国近海海域海平面变化的研究大多集中于海平面信号变化较为丰富的南海以及东海海域,中高纬度黄渤海海域的相关研究则较少。

海平面变化预测方法主要有数理统计分析和气候模式预测。气候模式预测多用于全球及大范围预测,对区域海平面变化的预测能力有限;数理统计分析则是将海平面变化分为确定性趋势项、确定性周期项、剩余分量和白噪声序列等,再逐个对原始序列进行拟合和外推,多受制于历史观测数据的长度、质量等因素^[9]。随着人工智能技术的快速发展,各种深度学习算法不断更新,许多研究者尝试利用神经网络实现长时间序列的分类预测^[10-12]。作为深度学习算法的典型代表,长短期记忆(long short-term memory, LSTM)网络的应用也日益成熟^[13]。LSTM网络是一种时间循环神经网络,能够很好地针对序列数据长期依赖问题进行建模^[14]。作为一种数字信号处理技术,奇异谱分析(SSA)能从时间序列中提取观测数据的非线性趋势,特别适合分析和预测有周期震荡的时间序列数据^[15-16]。

为进一步加强对中国近海中高纬度海域海平面变化的研究,以便全面掌握中国沿海海平面变化规律,选取中国黄海海域作为研究区域,利用1993年—2015年的海平面异常(SLA)时空序列,将SSA与LSTM网络构建的组合模型(下文简称SSA-LSTM组合模型)应用到黄海海域海平面变化多尺度预测中,以验证SSA-LSTM组合模型的有效性。最后,利用1993年—2015年的海平面异常数据,基于SSA-LSTM组合模型预测2016年—2025年黄海海域海平面异常变化趋势。

1 研究区域与数据

黄海是太平洋西部的一个边缘海(见图1),位于中国大陆与朝鲜半岛之间(122°E—127°E,37°N—40°N以及119°E—127°E,31°N—37°N)。黄海是以旅顺口至蓬

莱的连线为北边界、以济州岛至长江口的连线为南边界的半封闭陆架浅海,平均水深44 m。黄海由山东半岛成山角和朝鲜长山串之间的连线分为北黄海和南黄海两部分,北黄海东西两侧被陆地包围,南黄海东侧通过对马海峡与日本海相通^[17]。受太阳辐射、降雨、入海径流及风应力等因素的影响,黄海平均海平面振幅变化较大,季节性差异明显^[18-19]。




图1 研究区域

Fig.1 Study area

海洋气候数据集(CDRs)是“可用于确定气候变率和气候变化,具有足够时间长度、一致性和连续性的长时间序列数据,是开展全球气候变化研究的有效数据集”^[20-21]。自然资源部第一海洋研究所融合我国自主发射卫星的遥感数据,形成了国内首套具有自主知识产权、长时间序列、高时空分辨率和连续的全球海洋CDRs,为海洋环境变化监测以及全球气候变化研究提供了科学依据^[21]。利用CDRs中的海平面异常数据进行黄海海域海平面变化预测研究,海平面异常数据的时间范围为1993年—2015年,时间分辨率为1个月,空间分辨率为25 km,经与验潮站数据考核比较,精度指标为每年0.2 mm。区域平均后的黄海海域1993年—2015年海平面异常数据时间序列如图2所示,线性拟合可得该时间段黄海海域海平面上升速率约为每年3.67 mm,与前人研究结果一致^[22]。

2 原理与方法

2.1 奇异谱分析

奇异谱分析是在K-L变换分解理论基础上发展




图2 区域平均后的黄海海域1993年—2015年海平面异常时间序列

Fig.2 SLA time series of the Yellow Sea from 1993 to 2015 after regional average

起来的,与经验正交函数有关^[23]。奇异谱分析构造了一维非线性时间序列的轨迹矩阵,可以分解和重建该矩阵以提取原始时间序列的各个组成部分,如长期趋势、周期项或噪声^[24]。分解和重建是互补的阶段,先将具有显著震荡的分量提取出来,再选择其中有意义的分量进行重建,具体步骤如下^[25]:

步骤1 嵌入。选择合适的窗口长度 L 将原始序列 (x_1, x_2, \dots, x_N) 进行滞后排列,得到轨迹矩阵 X ,如下所示:

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_{N-L+1} \\ x_2 & x_3 & \cdots & x_{N-L+2} \\ \vdots & \vdots & & \vdots \\ x_L & x_{L+1} & \cdots & x_N \end{bmatrix} \quad (1)$$

式中: N 为序列长度。一般 $L < N/2$,通常为序列周期的最小公倍数。

步骤2 分解。对轨迹矩阵的协方差矩阵 $S = XX^T$ 进行奇异值分解,得到特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$ 和对应的特征向量 $U = (U_1, U_2, \dots, U_L)$, U_i 称为时间正交函数,记作TEOF。令 $V_i = X^T U_i / \sqrt{\lambda_i}$ ($i = 1, \dots, L$),则矩阵 X 的奇异值分解可以写为

$$X = X_1 + \dots + X_d \quad (2)$$

式中: $d = \max \{i, \lambda_i > 0\}$ 。 $(\sqrt{\lambda_i}, U_i, V_i)$ 称为 X 的特征三元组。

步骤3 分组。根据提取信息的频率等成分判断,将 X 分为 m 个不相交的组 I_1, I_2, \dots, I_m ,代表不同的趋势成分。以第 j 组为例, $I_j = (i_1, \dots, i_o)$,有

$$X_{I_j} = X_{i_1} + \dots + X_{i_o} \quad (3)$$

则 X 表示为

$$X = X_{I_1} + \dots + X_{I_m} \quad (4)$$

步骤4 重构。计算轨迹矩阵 X 在 U_m 上的投影,如下所示:

$$a_{i,m} = X_i U_m \quad (5)$$

式中: $a_{i,m}$ 为 X_i 所反映的时间正交函数在原序列时段上的权重,称为时间主成分,记作TPC。根据时间正交函数TEOF和时间主成分TPC进行对角平均,重建得到 $x_{i,k}$,如下所示:

$$x_{i,k} = \begin{cases} \frac{1}{i} \sum_{j=1}^i a_{i-j,k} U_{k,j}, & 1 \leq i \leq L-1 \\ \frac{1}{L} \sum_{j=1}^L a_{i-j,k} U_{k,j}, & L \leq i \leq N-L+1 \\ \frac{1}{N-i+1} \sum_{j=i-N+L}^L a_{i-j,k} U_{k,j}, & N-L+2 \leq i \leq N \end{cases} \quad (6)$$

2.2 LSTM网络

LSTM网络是一种特殊的递归神经网络^[26],在隐藏层中使用存储单元代替神经元来解决梯度消失或梯度爆炸问题。LSTM网络是由每个长短期记忆结构单元串接而成,包括控制门单元和输出门单元,控制门单元又是忘记门单元和输入门单元的加和组成。具体步骤如下^[14]:

(1)决定从细胞状态丢弃什么信息。通过忘记门读取 h_{t-1} 和 x_t ,输出一系列0到1之间的数 f_t ,计算式如下所示:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (7)$$

(2)决定往细胞状态存放什么信息。首先通过输入门决定更新信息 i_t ,然后通过tanh层创建一个新的候选值向量 \tilde{C}_t ,计算式如下所示:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (8)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (9)$$

(3)将旧细胞状态 C_{t-1} 与 f_t 相乘,再加上 $i_t \tilde{C}_t$,根据更新状态的程度进行变化,计算式如下所示:

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (10)$$

(4)决定输出什么信息。首先,通过输出门决定输出信息 O_t ,然后通过tanh层将此时的细胞状态 C_t

和输出信息 O_t 相乘得到确定输出部分 h_t , 计算式如下所示:

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (11)$$

$$h_t = O_t \tanh C_t \quad (12)$$

式中: x_t, h_t 分别为 t 时刻网络的输入与输出; f_t, i_t, O_t, C_t 分别为忘记门、输入门、输出门和记忆细胞的输出; W_f, W_i, W_o, W_c 分别为对应的权重矩阵; b_f, b_i, b_o, b_c 分别为对应的偏置; σ 为 Sigmoid 激活函数。

2.3 SSA-LSTM 组合模型

海平面变化的非平稳性严重影响着预测模型的效果, SSA-LSTM 组合模型对区域海平面变化的预测主要包括: ①海平面异常序列的奇异谱分解, 降低原始序列的复杂度; ②分解后时间模态子序列的 LSTM 网络预测, 基于 LSTM 网络完成模型预测; ③预测结果的重构, 利用奇异谱分析的特点实现海平面时间序列、时空序列的双预测。奇异谱分析可把随时间变化的海洋要素场分解为空间模态和时间模态两部分: 空间模态包含要素场的空间分布信息, 该部分是不随时间变化的; 时间模态则由空间点的线性组合所构成, 称为主分量^[27]。针对时间模态建立 LSTM 网络预测模型, 可有效改善 LSTM 网络预测带来的滞后问题, 弥补数据分解存在的模式混叠现象。时空序列预测与时间序列预测的不同在于: 轨迹矩阵的创建, 前者将海平面网格数据视为分解对象, 窗口长度由研究区域经度的跨度决定; 预测数据的重构, 分解后前者选取时间模态进行 LSTM 网络预测, 预测结果再与之前存储的空间模态相乘即得到时空矩阵(最终预测结果), 无需进行对角平均来重构序列。

SSA-LSTM 组合模型通过改变轨迹矩阵的创建方式, 实现网格数据时空方向上的分解; 引入 LSTM 网络, 应用于海平面变化预测, 针对不同需求可以实现时间序列、时空序列的双预测, 同时可以保证较高的预测精度。

3 结果与分析

3.1 区域海平面异常序列分析

(1) 海平面时间序列分析

海平面变化的影响因素较多, 是非线性、非平稳性且多尺度变化的时间序列, 分解重构方法能有效降低原始序列的复杂性, 从而提高预测模型的精度^[28]。在对黄海海域海平面异常时间序列进行奇异值分解时, 根据该区域年周期信号显著的特点选择 12 为窗口长

度来创建轨迹矩阵, 并利用奇异谱分析对其进行分解; 根据奇异值差分谱进行筛选并按照各自的主周期进行合并分组, 最终得到 5 个时间模态子序列(REC1—REC5)和 1 个残差序列(REC6), 如图 3 所示。奇异谱分析后的时间模态子序列频域稳定, 由频谱分析可知, 各子序列的主周期几乎没有重叠在同一频率上, REC1—REC5 的主周期分别对应 11.96 个月、30.56 个月、5.978 个月、3.986 个月和 2.957 个月, 表现为明显的年际变化、2~3 年周期变化、半年变化和季节变化。REC2 还存在 137.5 个月(约 11 年)、91.67 个月、68.75 个月等周期, 准 11 年的周期反映了太阳黑子的影响, 4~7 年的周期通常认为与厄尔尼诺-南方涛动事件有关^[29]。海平面不同周期的振荡在不同时间段交叉, 导致其上升、下降振幅的不稳定性。

(2) 海平面时空序列分析

时空序列数据反映了区域内多个随机变量随时间不断变化的趋势, 除了时间和空间特征, 时空数据还包含属性特征, 因而呈现出多维、动态和时空相关等复杂性^[30]。以黄海海域海平面网格数据为分解对象, 构建 36×32 大小的轨迹矩阵, 利用奇异谱分析进行分解, 获取空间分布形态以及对应的时间变化特征。结果表明, 第一模态和第二模态的累计贡献率达到 86.69%, 如图 4 所示, 这很好地诠释了 1993 年—2015 年黄海海域海平面异常数据的分布类型。

图 4a 为第一模态空间分布场, 其方差贡献率为 82.24%, 远高于其他模态的贡献率, 是黄海海域海平面异常数据的主要空间分布形式。可以看出, 特征值均为正值, 表明 1993 年—2015 年黄海海域的海平面变化趋势具有高度一致性, 高值中心主要位于渤海黄海分界处。

图 4b 为第二模态空间分布场, 其方差贡献率为 4.65%, 也是黄海海域海平面异常数据的典型空间分布形式。以 36°N 左右为界, 向北为负值区, 向南为正值区, 结合时间系数判断春夏季多为负相关, 即春夏两季海平面异常高度由南向北递增; 秋冬季多为正相关, 即秋冬两季海平面异常距平由南向北递减。

为了获取黄海海域海平面异常数据随纬度和时间的变化规律, 求得该区域 1993 年—2015 年共 23 年的每月及分纬度的海平面异常数据均值, 构建海平面异常数据均值的时间-纬度分布图^[31], 如图 5 所示。可以看到, 黄海海域海平面高度极大值出现在秋季 9 月—10 月, 极小值则出现在春季 3 月—4 月。秋冬两季, 纬度越高海平面异常距平值越小; 春夏两季, 纬

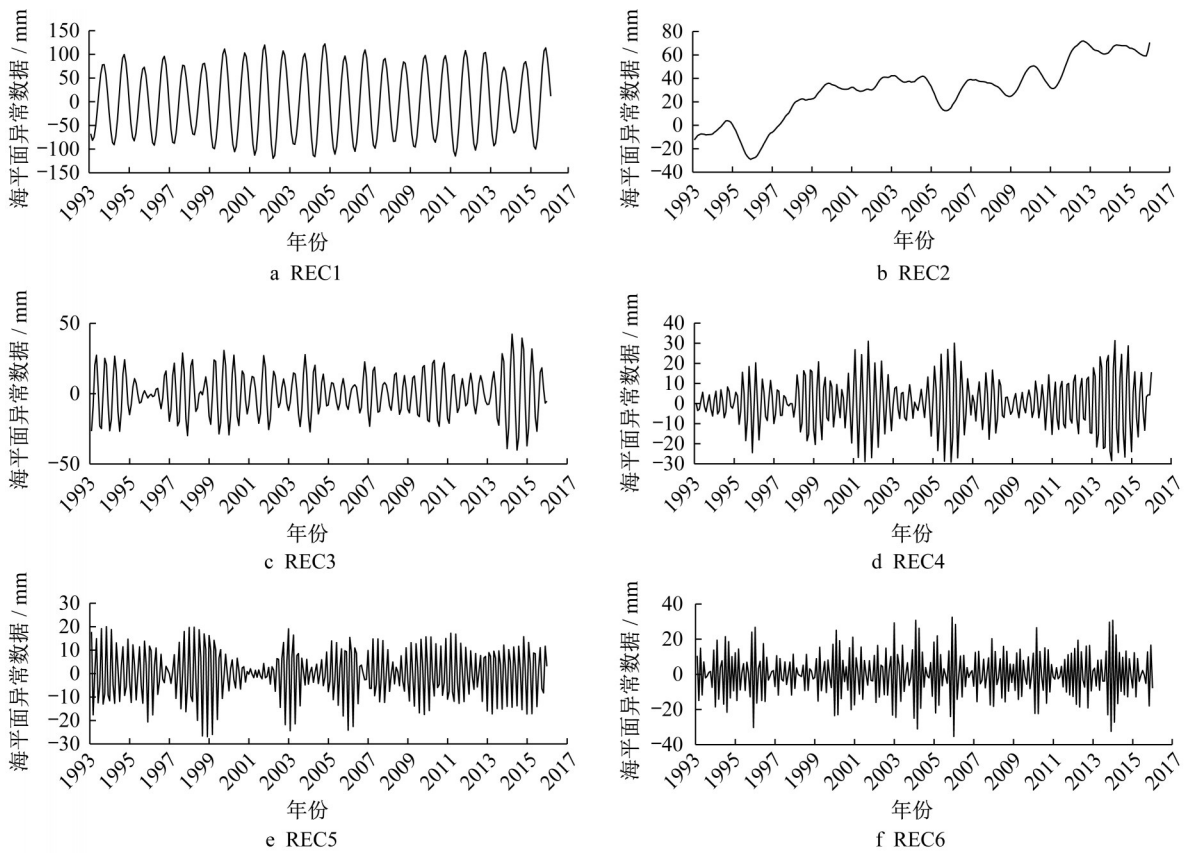


图3 黄海海域海平面异常时间序列SSA分解结果

Fig.3 SSA decomposition results of SLA time series in the Yellow Sea

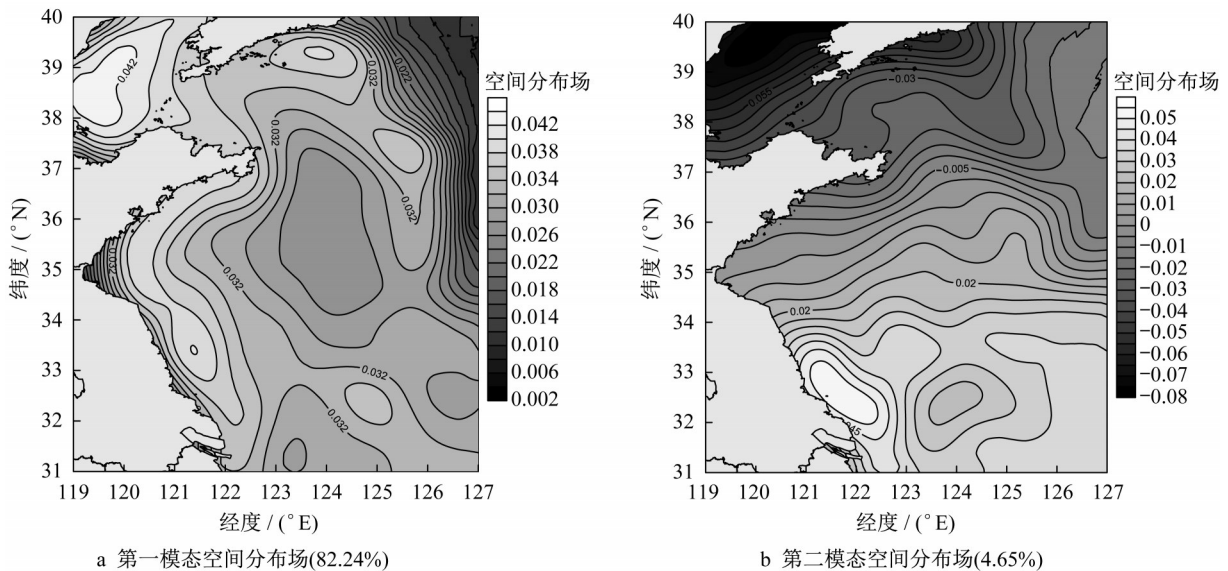


图4 黄海海域海平面异常数据正交函数空间分布

Fig.4 EOF spatial distribution of SLAs in the Yellow Sea

度越高则海平面异常距平值越大;在 33°N 和 39°N 左右出现海平面异常极值点。

3.2 区域海平面变化预测模型构建

(1)海平面时间序列预测

采用LSTM网络与SSA-LSTM组合模型对黄

海海域1993年—2015年的海平面异常时间序列进行预测。经奇异谱分析后得到的各时间模态子序列有显著的主周期特性,将主周期特性作为输入并利用LSTM网络进行预测。将原始海平面异常数据分为两部分:数据总量的前80%作为训练数据(1993




图5 黄海海域海平面异常数据均值的时间-纬度分布
Fig.5 Time-latitude distribution of mean SLAs in the Yellow Sea

年1月至2011年6月),数据总量的后20%作为检验数据(2011年7月至2015年12月),此时Dropout对小数据防止过拟合有很好的效果。整组实验中,优化算法均采用了自适应估计的Adam (adaptive moment estimation),而学习率与衰落因子根据各子序列的不同需要在训练中不断进行修正,通过经验调试以平方误差最小为评价准则来确定LSTM网络的最优参数。

为了全面评价SSA-LSTM组合模型的预测效果,对研究区域海平面异常时间序列分别采用LSTM网络与SSA-LSTM组合模型2种方法进行对比分析,2种方法的预测结果与原始观测数据的对比如图6所示。为避免与原始观测数据比较时产生偏差,首先对奇异谱分析后的时间模态子序列进行归一化处理,再将全部时间模态子序列的预测结果叠加重构,最终得到SSA-LSTM组合模型的预测结果。从图6可以看出,虽然LSTM网络预测结果的峰值和谷值与原始观测数据均较为接近,但由于延迟原因导致误差相对较大,易出现极值偏差;利用SSA-LSTM组合模型进行预测时,奇异谱分析能很好地对原始序列进行平稳化及降噪处理,模拟出更接近原始序列的趋势,预测结果优于LSTM网络预测结果,与原始观测数据最为吻合。

为进一步分析上述2种方法的预测效果,采用相关系数(R)、平均绝对误差(e_{MAE})和均方根误差(e_{RMSE})等指标对预测结果进行定量评价,如表1所




图6 SSA-LSTM组合模型与LSTM网络预测结果对比
Fig.6 Comparison of prediction results between SSA-LSTM combined model and LSTM network

示。LSTM网络在模拟原始序列趋势时表现出良好的优越性,相关系数 R 较大,但存在极值预测偏差大的问题, e_{RMSE} 也较大。SSA-LSTM组合模型能很好地模拟原始观测数据的趋势变化,同时极值预测能力显著提高,预测结果与原始观测数据最为吻合,预测效果最佳。

表1 SSA-LSTM组合模型与LSTM网络的预测误差
Tab.1 Prediction error of SSA-LSTM combined model and LSTM network

模型	R	e_{RMSE}/mm	e_{MAE}/mm
LSTM网络	0.89	46.29	38.45
SSA-LSTM组合模型	0.89	35.04	26.41

(2)海平面时空序列预测

在对海平面时空序列进行预测建模时,考虑到空间模态的基本不变性,即短时间内空间模态稳定不可变,故只需对时间模态进行建模^[32]。利用奇异谱分析将研究区域时空序列分解为空间模态和时间模态以及奇异值的乘积,再利用LSTM网络对时间模态进行预测,预测结果如图7所示。最后,将预测结果与空间模态及奇异值进行重建得到时空序列各网格点的最终预测结果。表2为基于SSA-LSTM组合模型的黄海海域海平面异常数据时空预测误差,在为期4年的海平面异常数据时空预测中,以年为单位分别对每个时段的时空预测结果进行误差统计。可以发现,随着预测时间的增加,时空预测精度也逐渐降低,尤其是第三预测年份(2013年6月至2014年6月)预测结果存在较大偏差。通过海平面异常原始观测数据发现,2013年11月黄海海域海平面异常数据较2012年同期低约200 mm,造成极值点偏差较大,从而导致预测精度较低。海平面异常时空序列预测精度略低于时间序列预测精度,主要

是因为在奇异谱分解重构时,包含信息较少的残差随机序列被舍弃,而且在对各时间模态分解后的重复性预测操作容易造成误差累积。




图7 时间模态预测值与真实值对比

Fig.7 Comparison of time mode between predicted and true values

表2 基于SSA-LSTM组合模型的黄海海域海平面异常时空预测误差

Tab.2 Spatio-temporal prediction error of SLAs in the Yellow Sea with SSA-LSTM combined model

预测时间/年	R	e_{RMSE}/mm	e_{MAE}/mm
1	0.97	19.68	15.69
2	0.94	30.48	22.37
3	0.83	43.49	32.43
4	0.85	40.74	30.18

将SSA-LSTM组合模型与现有方法进行比较,可以更好地理解该模型的预测能力。Yavuzdoğan等^[33]于2021年提出了基于Coplula函数的预报方法,该方法能够以高精度反映海平面异常数据的空间相关性,误差介于22~41 mm之间;2021年周玮辰等^[34]基于U-Net网络通过非线性的方法叠加上下采样过程中不同尺度的空间特征,实现了均方根误差为39 mm的预报效果。综上,SSA-LSTM组合模型仍有优异表现,可以作为海平面异常时空预测的有力模型。

3.3 未来10年黄海海域海平面变化预测

基于SSA-LSTM组合模型,利用1993年—2015年的黄海海域海平面异常数据,在对黄海海域海平面异常时空序列预测的基础上再进行区域空间平均,预

测黄海海域未来10年的海平面变化趋势,结果如图8所示。经线性拟合,2016年—2025年黄海海域海平面变化速率约为每年 3.65 ± 0.79 mm,黄海海域海平面将呈持续上升趋势。2021年中国海平面公报研究表明,1980年—2021年黄海沿海海平面上升速率为每年3.2 mm,预计未来30年黄海沿海海平面将上升60~160 mm^[4]。利用我国自主研发的海洋CDRs数据分析黄海海域海平面变化趋势,研究结果与上述公报结论基本相符,表明SSA-LSTM组合模型具有很好的应用价值,同时也验证了海洋CDRs的有效性。




图8 基于SSA-LSTM组合模型的黄海海域2016年—2025年海平面异常预测结果

Fig.8 Prediction results of SLAs in the Yellow Sea with SSA-LSTM combined model from 2016 to 2025

4 结论

(1)SSA-LSTM组合模型改善了LSTM网络的滞后现象,极值问题得到缓解。奇异谱分析解决了常见分解算法中出现的模式混叠现象,在考虑空间信息的情况下使预测结果更接近原始观测数据,组合模型具有很好的应用价值。

(2)基于我国首套自主研发的海洋CDRs,发现黄海海域海平面异常具有高度一致性,并且与纬度、时间存在一定相关性。预计2016年—2025年黄海海域海平面变化呈持续上升趋势,上升速率约为每年 3.65 ± 0.79 mm,与中国海平面公报研究结果一致,验证了SSA-LSTM组合模型和CDRs数据的有效性。

作者贡献声明:

赵 健:论文总体设计,论文审阅与修改。

蔡瑞阳:数据处理,论文初稿撰写。

孙伟富:海洋气候数据集数据处理与分析。

参考文献:

[1] KARIMI A A, DENG Xiaoli. Estimating sea level rise around

- Australia using a new approach to account for low frequency climate signals [J]. *Advances in Space Research*, 2020, 65(10): 2324.
- [2] ZHAO Jian, FAN Yanguo, MU Yuxiang. 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.
- [3] OPPENHEIMER M, GLAVOVIC B, HINKEL J, *et al.* Sea level rise and implications for low lying islands, coasts and communities [R/OL]. [2019-09-24]. <https://www.ipcc.ch/srocc/home>.
- [4] 自然资源部. 2021年中国海平面公报[EB/OL]. [2022-04-08]. http://gi.mnr.gov.cn/202205/t20220507_2735509.html. Ministry of Natural Resources. China sea level bulletin 2021 [EB/OL]. [2022-04-08]. http://gi.mnr.gov.cn/202205/t20220507_2735509.html.
- [5] 丁宁. 山东半岛近海海域海平面变化预测研究[D]. 青岛: 中国石油大学(华东), 2018.
DING Ning. Research on the coastal waters of Shandong Peninsula sea level change prediction [D]. Qingdao: China University of Petroleum (East China), 2018.
- [6] 王龙, 王晶, 杨俊钢. 东海海平面变化的综合分析[J]. *海洋学报*, 2014, 36(1): 28.
WANG Long, WANG Jing, YANG Jungang. The comprehensive analysis of sea-level change in the East China Sea [J]. *Acta Oceanologica Sinica*, 2014, 36(1): 28.
- [7] 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.
ZHAO Jian, FAN Yanguo, ZHANG Yin. Multi-scale prediction of regional sea level variations based on EEMD-BP combined model [J]. *System Engineering Theory and Practice*, 2019, 39(10): 2713.
- [8] WANG G, WANG X, WU X, *et al.* Multimodal fusion for sea level anomaly forecasting [J/OL]. [2020-10-21]. <https://arxiv.org/abs/2006.08209v1>.
- [9] 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.
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.
- [10] SHI X, CHEN Z, WANG H, *et al.* Convolutional LSTM network: a machine learning approach for precipitation nowcasting [J]. *Neural Information Processing Systems*, 2015, 28(1): 802.
- [11] MA C, LI S, WANG A, *et al.* Altimeter observation-based eddy nowcasting using an improved conv-LSTM Network [J]. *Remote Sensing*, 2019, 11(7): 783.
- [12] ZHAO Jian, CAI Ruiyang, FAN Yanguo. Prediction of sea level nonlinear trends around Shandong Peninsula from satellite altimetry [J]. *Sensors*, 2019, 19: 4770.
- [13] 冉祥栋. 基于深度学习的交通时间预测模型与方法研究[D]. 北京: 北京科技大学, 2019.
RAN Xiangdong. Deep learning-based models and methods for travel time prediction [D]. Beijing: University of Science and Technology Beijing, 2019.
- [14] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. *计算机应用*, 2018, 38(S2): 1.
YANG Li, WU Yuxi, WANG Junli, *et al.* Research on recurrent neural network [J]. *Journal of Computer Applications*, 2018, 38(S2): 1.
- [15] 王解先, 连丽珍, 沈云中. 奇异谱分析在GPS站坐标监测序列分析中的应用[J]. *同济大学学报(自然科学版)*, 2013, 41(2): 282.
WANG Jiexian, LIAN Lizhen, SHEN Yunzhong. Application of singular spectral analysis to GPS station coordinate monitoring series [J]. *Journal of Tongji University (Natural Science)*, 2013, 41(2): 282.
- [16] 郭金运, 高文宗, 于红娟, 等. 基于奇异谱分析的静态相对重力观测重力固体潮提取[J]. *地球物理学报*, 2018, 61(10): 3889.
GUO Jinyun, GAO Wenzong, YU Hongjuan, *et al.* Gravity tides extracted from relative gravimetric data with singular spectrum analysis [J]. *Chinese Journal of Geophysics*, 2018, 61(10): 3889.
- [17] 胡莹英. 黄、东海水温季节和年际变化特征分析[D]. 青岛: 中国海洋大学, 2013.
HU Yingying. Seasonal and interannual variations of the water temperature in the Yellow Sea and East China Sea [D]. Qingdao: Ocean University of China, 2013.
- [18] 刘雪源, 刘玉光, 郭琳, 等. 渤海海平面的变化及其与ENSO的关系[J]. *海洋通报*, 2009, 28(5): 34.
LIU Xueyuan, LIU Yuguang, GUO Lin, *et al.* Mean sea level change in East China Sea and its response to ENSO [J]. *Marine Science Bulletin*, 2009, 28(5): 34.
- [19] 张静. 近20年中国和全球海域海平面上升趋势特征分析及相互关系的初步研究[D]. 青岛: 中国海洋大学, 2014.
ZHANG Jing. Features and connection studies of the sea level trends of the China seas and global oceans for the past 20 years [D]. Qingdao: Ocean University of China, 2014.
- [20] 梁顺林, 唐世浩, 张杰, 等. 全球气候数据集生成及气候变化应用研究[J]. *遥感学报*, 2016, 20(6): 1491.
LIANG Shunlin, TANG Shihao, ZHANG Jie, *et al.* Production of the global climate data records and applications to climate change studies [J]. *Journal of Remote Sensing*, 2016, 20(6): 1491.
- [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.
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.

- [22] 徐曜. 多代卫星测高数据处理及其在海平面变化监测中的应用[D]. 杭州: 杭州师范大学, 2017.
XU Yao. The processing of multi-generation altimeter data and its application in sea level changes monitoring [D]. Hangzhou: Hangzhou Normal University, 2017.
- [23] HARRIS T J, YUAN H. Filtering and frequency interpretations of singular spectrum analysis [J]. *Physica D: Nonlinear Phenomena*, 2010, 239(20/22): 1958.
- [24] VAUTARD R, GHIL M. Singular spectrum analysis in nonlinear dynamics, with applications to paleoclimatic time series [J]. *North-Holland*, 1989, 35(3): 395.
- [25] HOSSEIN H. Singular spectrum analysis: methodology and comparison [J]. *Journal of Data Science*, 2007, 5(2): 239.
- [26] HOCHREITERS S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735.
- [27] 迟永祥. 中国近海海平面季节变化研究[D]. 青岛: 中国海洋大学, 2013.
CHI Yongxiang. Study on the seasonal variations of sea level changes in China marginal seas [D]. Qingdao: Ocean University of China, 2013.
- [28] 李享, 王珏, 王震, 等. 基于时间序列分解与重构的能源价格分析研究[J]. *中国石油大学学报(社会科学版)*, 2019, 35(4): 1.
LI Xiang, WANG Jue, WANG Zhen, *et al.* Construction study on application of decomposition and reconstruction for energy price analysis [J]. *Journal of China University of Petroleum (Edition of Social Sciences)*, 2019, 35(4): 1.
- [29] 王慧, 刘克修, 张琪, 等. 中国近海海平面变化与 ENSO 的关系[J]. *海洋学报*, 2014, 36(9): 65.
WANG Hui, LIU Kexiu, ZHANG Qi, *et al.* The relationship between sea level change of China's coast and ENSO [J]. *Acta Oceanologica Sinica*, 2014, 36(9): 65.
- [30] 黎维, 陶蔚, 周星宇, 等. 时空序列预测方法综述[J]. *计算机应用研究*, 2020, 37(10): 2881.
LI Wei, TAO Wei, ZHOU Xingyu, *et al.* Survey of spatio-temporal sequence prediction methods [J]. *Application Research of Computers*, 2020, 37(10): 2881.
- [31] 李艳艳, 董庆, 任永政, 等. 印度洋及太平洋海表盐度时空特征分析[J]. *遥感学报*, 2020, 24(10): 1193.
LI Yanyan, DONG Qing, REN Yongzheng, *et al.* Spatiotemporal characteristics of sea surface salinity of Indian and Pacific Oceans [J]. *Journal of Remote Sensing*, 2020, 24(10): 1193.
- [32] 杨立宁, 李艳婷. 基于 SVD 和 ARIMA 的时空序列分解和预测[J]. *计算机工程*, 2021, 47(3): 53.
YANG Lining, LI Yanting. Spatio-temporal sequence prediction based on singular value decomposition and ARIMA [J]. *Computer Engineering*, 2021, 47(3): 53.
- [33] YAVUZDOĞAN A, TANIR KAYIKÇI E. A copula approach for sea level anomaly prediction: a case study for the Black Sea[J]. *Survey Review*, 2021, 53(380): 436.
- [34] 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.
ZHOU Weichen, HAN Zhen, ZHANG Xuewei. Research on sea level anomaly prediction based on U-Net structure and ConvLSTM layers [J]. *Marine Science Bulletin*, 2021, 40(4): 410.