

参数自适应VMD与CNN-BiGRU耦合的海平面变化预测

廖强强^{1,2*}, 章重阳^{3#}, 周平⁴, 陈汉清⁵

¹广东省国土资源测绘院, 广东 广州

²自然资源部华南热带亚热带自然资源监测重点实验室, 广东 广州

³清远市测绘地理信息中心, 广东 清远

⁴江西水利电力大学水利工程学院, 江西 南昌

⁵广东海洋大学海洋工程与能源学院, 广东 湛江

收稿日期: 2026年9月28日; 录用日期: 2026年10月21日; 发布日期: 2026年10月28日

摘要

月平均海平面预测是海岸带风险管理与海洋环境预报的重要依据。针对现有方法难以兼顾海平面序列多尺度非平稳特性与时序依赖关系、预测精度有限的问题, 本文构建参数自适应VMD与CNN-BiGRU混合预测模型。基于南海北部闸坡验潮站实测数据, 依托样本熵与灰狼优化算法自适应优化VMD参数, 解耦非平稳海平面时序分量; 利用CNN提取局部波动特征, 结合BiGRU挖掘双向长程时序关联, 实现月尺度海平面精准预测。试验结果表明, 相较于传统熵准则, 样本熵优化的VMD分解性能更优, 预测均方误差降低15%以上、平均绝对误差降低9.3%。特征步长为6个月时CNN-BiGRU性能最优, 可精准捕捉序列突变特征, 全周期预测结果稳健, 季风转换时段误差可控, 可为海岸带防灾减灾与海洋环境预报提供技术支撑。

关键词

平均海平面, 变分模态分解, 熵, 卷积神经网络, 双向门控循环单元

Sea Level Change Prediction Based on Coupled Parameter-Adaptive VMD and CNN-BiGRU Model

Qiangqiang Liao^{1,2*}, Chongyang Zhang^{3#}, Ping Zhou⁴, Hanqing Chen⁵

¹Surveying and Mapping Institute Lands and Resource Department of Guangdong Province, Guangzhou Guangdong

²Key Laboratory of Natural Resources Monitoring in Tropical and Subtropical Area of South China, Ministry of

*第一作者。

#通讯作者。

文章引用: 廖强强, 章重阳, 周平, 陈汉清. 参数自适应VMD与CNN-BiGRU耦合的海平面变化预测[J]. 测绘科学技术, 2026, 14(4): 314-326. DOI: 10.12677/gst.2026.144032

Natural Resources, Guangzhou Guangdong

³Qingyuan Geomatics Center, Qingyuan Guangdong

⁴College of Water Conservancy, Jiangxi University of Water Resources and Electric Power, Nanchang Jiangxi

⁵College of Ocean Engineering and Energy, Guangdong Ocean University, Zhanjiang Guangdong

Received: September 28, 2026; accepted: October 21, 2026; published: October 28, 2026

Abstract

Monthly mean sea level prediction is an essential basis for coastal zone risk management and marine environmental forecasting. Aiming at the deficiencies of existing methods in balancing the multi-scale non-stationary characteristics and temporal dependence of sea level sequences with limited prediction accuracy, this study constructs a hybrid prediction model combining parameter adaptive variational mode decomposition (VMD) and CNN-BiGRU. Based on the measured data from the Zhapo tide gauge station in the northern South China Sea, the sample entropy and grey wolf optimization algorithm are adopted to adaptively optimize VMD parameters and decouple non-stationary sea level time series components. CNN is used to extract local fluctuation features, and BiGRU is applied to explore bidirectional long-term temporal correlations to realize accurate monthly sea level prediction. The results show that VMD optimized by sample entropy outperforms traditional entropy criteria, reducing the mean square error by more than 15% and the mean absolute error by 9.3%. The CNN-BiGRU framework achieves optimal performance at an input step size of six months, effectively capturing sequence mutation features. The model presents robust full-cycle prediction with controllable errors during monsoon transition periods, providing technical support for coastal disaster prevention and marine environmental forecasting.

Keywords

Mean Sea Level, Variational Mode Decomposition, Entropy, Convolutional Neural Network, Bidirectional Gated Circulation Unit

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

海平面变化是气候系统多圈层相互作用的关键指示因子，其长期上升趋势与极端波动对沿海地区生态安全与经济社会可持续发展构成显著威胁[1]。广东省阳江市海陵岛闸坡验潮站位于南海北部陆架区，受东亚季风、黑潮入侵及冬季陆架波等多重动力过程叠加影响，其月平均海平面序列呈现显著的非线性、非平稳特征，传统线性预测方法难以准确捕捉其复杂演变规律。因此，发展适用于该海域特点的高精度海平面预测模型，对提升区域风暴潮预警能力与海岸带风险管理水平具有重要的科学价值和现实意义。

“先分解、后预测”是处理非平稳海平面时序数据的主流技术范式。然而，经验模态分解及其改进方法存在模态混叠与端点效应[2][3]。小波分解效果高度依赖基函数选择和边界处理策略[4]。奇异谱分析对窗口长度敏感且抗噪性不足[5]。变分模态分解(Variational Mode Decomposition, VMD)通过构建约束变分模型实现信号自适应分解，在抗噪性与模态保真度方面具有显著优势[6]，但其性能高度依赖于模态数 K 与惩罚因子 α 的预设组合，人工经验选取易导致欠分解或过分解。现有研究多采用遗传算法、粒子群优化等智能算法进行参数寻优[7]-[9]，但关于适应度函数的选择缺乏系统论证，不同信息熵准则对 VMD

分解质量及后续预测精度的影响机制尚不明确。

在预测建模方面,传统机器学习方法普遍存在局限性。支持向量机对核函数设置敏感[10]。随机森林易出现过拟合,且对长期趋势的泛化能力较弱[11]。极限梯度提升法对极端事件响应不足,预测偏差较大[12]。近年来,深度学习方法在海平面预测研究中受到广泛关注。长短期记忆网络(Long Short-Term Memory, LSTM)和门控循环单元(Gated Recurrent Unit, GRU)能够有效捕捉时间序列的长程依赖关系[13][14]。此外,双向 LSTM (Bi-LSTM)通过前向与后向信息建模,进一步增强了对复杂时序特征的表达能力[15]。然而,上述模型主要聚焦于时间维度,对海平面演变过程中隐含的多尺度空间结构特征挖掘不足。近年来,卷积神经网络(CNN)与循环神经网络的组合架构在提取时空特征方面展现出潜力,但针对该类模型在海平面预测中的适用性及其与 VMD 分解的协同优化机制,尚缺乏深入探讨。

针对上述问题,本文以闸坡验潮站 1959~2024 年月平均海平面序列为研究对象,提出一种融合参数自适应分解与深度学习的海平面混合预测框架。该框架的核心创新在于:(1) 系统对比包络熵(EnVeEn)、排列熵(PeEn)、模糊熵(FuzzyEn)、样本熵(SpEn)四种信息熵准则,揭示不同熵函数对 VMD 参数优化的导向机制,优选出最适配海平面非平稳特征的适应度函数;(2) 构建卷积神经网络与双向门控循环单元(Convolutional Neural Network and Bidirectional Gated Recurrent Unit, CNN-BiGRU)组合模型,利用 CNN 提取局部波动特征,借助 BiGRU 捕捉双向长程依赖关系,实现分解分量时空特征的协同建模;(3) 通过特征时间步长敏感性实验,阐明模型输入长度与海平面内在周期特征的匹配关系。本研究旨在发展高精度、高鲁棒性的海平面预测方法,为南海北部海岸带气候适应与防灾减灾提供科学支撑。

2. 区域概况

闸坡验潮站坐落于广东阳江海陵岛($21^{\circ}35'N$, $111^{\circ}50'E$),隶属于南海北部陆架海域。受东亚季风、黑潮支流与冬季陆架波共同作用,区域海平面演化呈现明显非线性、非平稳及多尺度演变特征[16]。月均海平面序列兼具海水热膨胀、陆地水储量变化带来的长期趋势,以及季风环流、ENSO 扰动诱发的季节-年际振荡,常规单一模型难以全面表征序列复杂异质性。

本文采用英国永久平均海平面服务中心 1959 年 1 月~2024 年 11 月闸坡站逐月海平面观测资料,数据完整率 98.9%,空缺数据借助邻近插值补全(图 1)。数据集按时序拆分:1959 年 1 月至 2011 年 12 月作为训练样本,2012 年 1 月至 2024 年 11 月作为测试样本,用于验证所建模型的预报性能。




Figure 1. Information of the study area

图 1. 研究区域信息

3. 理论基础

3.1. 混合预测框架

针对海平面序列的多尺度非平稳特性, 本文构建自适应信号分解、时空特征提取、模态重构的三阶段混合预测框架(图 2)。该框架以信息熵作为 VMD 分解质量的量化准则, 利用灰狼优化算法(Grey Wolf Optimization, GWO)自适应搜索模态数与惩罚因子的最优组合, 将原始海平面序列解耦为不同频率尺度的本征模态函数(Intrinsic Mode Function, IMF)分量。继而将各 IMF 分量输入 CNN-BiGRU 网络, 通过卷积运算提取局部波动特征, 借助双向门控循环机制捕捉时序长程依赖关系; 最终叠加重构各分量预测结果, 输出原始序列的预测值。采用均方根误差(RMSE) [17]、平均绝对误差(MAE) [18]、平均绝对百分比误差(MAPE) [19]以及纳什-萨特克利夫效率系数(NSE) [20]指标评估海平面预测模型性能。




Figure 2. Framework of the sea level change prediction scheme

图 2. 海平面变化预测方案框架

3.1.1. 基于样本熵的 VMD 参数自适应优化

VMD 的分解质量高度依赖于模态数 K 与惩罚因子 α 的协同配置。 K 决定分解尺度, 过小导致模态混叠, 过大引入虚假高频分量。 α 控制带宽约束强度, 过大平滑有效信息, 过小则噪声残留。传统人工试凑或固定参数组合难以适应海平面序列的时变特性, 亟需引入智能优化算法实现参数自适应寻优。

灰狼优化(GWO)算法因其全局搜索能力强、收敛速度快、需调节参数少等特点, 适用于 VMD 参数空间的多峰寻优。该算法模拟灰狼的社会等级与狩猎行为, 通过最优狼、次优狼和第三优狼引导种群向最优解区域收敛, 避免陷入局部极值。将 K 与 α 作为决策变量纳入狼群搜索空间, 以分解分量的信息复杂度最小化为优化目标, 可引导 VMD 在噪声抑制、模态分离与分量平稳性之间取得平衡。

适应度函数的选取是 GWO 优化成功的关键。样本熵通过计算相似容限内的模板匹配数, 能够同时捕捉海平面变化的局部波动特征与长期记忆特性。本文选定样本熵作为 GWO 的适应度函数, 以熵值最小化为导向搜索最优 K 与 α 值组合。此外, 还系统对比包络熵、排列熵和模糊熵三种熵准则的设计逻辑与适用边界。

3.1.2. CNN-BiGRU 时空特征协同提取

经 VMD 分解后, 各 IMF 分量呈现差异化的波动特性。为充分挖掘这些异质性分量的预测信息, 采

用 CNN-BiGRU 组合架构来实现空间局部特征与时序依赖关系的协同建模。

CNN 模块实现时序局部特征提取。一维卷积核(宽度为 3)沿各 IMF 分量滑动滤波,捕获时段内峰谷、周期等局部时序模式;池化运算压缩特征维度,在保留关键变化规律的基础上削减计算量,提升模型对相位扰动的抗干扰能力。

BiGRU 模块用于时序依赖建模。单向循环网络仅依托历史数据外推,无法表征海平面演化的滞后关联与反向作用;BiGRU 由正向、反向两层 GRU 并行构成,沿时序正反双向提取特征并拼接隐层输出,融合前后时段全局信息。依托内置门控自适应筛选历史信息,有效抑制长时序预测的梯度消失,相较 LSTM 具备参数轻量化优势。模型以 CNN 提取局部波动特征、BiGRU 捕获长周期时序依赖,双模块耦合适配海平面变化物理规律,提升预报精度。

3.2. 参数设置

所提的海平面变化混合预测方案中,GWO 算法的种群规模设为 30,最大迭代次数设为 200。VMD 分解的模式数 K 优化范围为 3 至 10,惩罚因子 α 优化范围为 1000 至 3000,噪声容限 τ 设为 0,收敛准则容差 tol 设为 $1e-7$ 。CNN-BiGRU 网络的 CNN 层采用大小为 3,卷积核为 16 个,池化窗口和宽度为 2,激活函数为 ReLU。BiGRU 层的隐含层神经元数为 128,模型训练的批次大小为 64,训练轮数为 120,优化器采用 Adam (学习率 0.001),损失函数采用 RMSE。

3.3. VMD 参数优化性能

在 GWO 算法执行空间寻优过程中,不同信息熵通过差异化的复杂度度量准则,引导 VMD 生成具有多样性的分解结构,进而对后续时序预测精度产生显著影响。为系统揭示各类信息熵准则对 VMD 参数优化的内在导向机制,本文以 CNN-BiGRU 作为统一预测模型,设定时序特征长度为 6,分别选取包络熵、排列熵、模糊熵与样本熵作为适应度函数开展对比实验。




Figure 3. Prediction performance of various entropy functions on the test set
图 3. 各种熵函数在测试集的预测性能

图 3 展示了 2012~2024 年测试期内四种熵函数优化 VMD 后的预测曲线与原始月平均海平面数据的

对比。原始数据呈现显著的年际周期性波动，周期约为 12 个月。样本熵优化后的预测曲线与实测数据的峰谷值及波动节奏贴合度最高，能够有效追踪数据中的突变特征。这一现象源于样本熵通过度量序列自相似性，对海平面变化的局部波动特征与长期记忆特性具有较强分辨能力，使得 GWO 算法能够搜索到将原始信号分解为规则性最强、模态混叠最少、噪声干扰最弱的参数组合。

排列熵优化模型预测波动幅度整体偏小，存在明显低估问题。该方法仅依据数值排序特征度量序列复杂度，忽略振幅信息，致使优化过程过度平滑序列，无法有效保留海平面季节波动幅度。包络熵拟合趋势偏平缓，对极值峰值捕捉能力不足。由于包络熵基于希尔伯特解调求解，对脉冲波动更为敏感，难以适配海平面缓变周期特征，无法有效区分季节正常峰值与异常扰动。模糊熵预测峰谷偏差显著、优化稳定性较差，受隶属度与相似容限参数影响，短序列优化过程易陷入局部最优。




Figure 4. Prediction quality of various entropy functions in local time periods

图 4. 各种熵函数在局部时间段的预测质量

图 4 为 2023 年 1 月~2024 年 11 月的局部预测结果。样本熵优化模型与实测序列贴合度最优，精准复现了 2023 年 10 月峰值、2024 年 4 月谷值及后期回升趋势，整体残差波动最小，多数时段误差控制在 ± 20 mm 以内。其余三种熵准则均存在关键拐点预测偏差：包络熵将春季季风转换波动误判为噪声并过度平滑，2023 年 3 月误差达 60 mm；排列熵因缺失振幅信息，2024 年 5 月峰值低估误差近 40 mm；模糊熵参数敏感性在极端变化时段被放大，2024 年 8 月误差超 40 mm，误差稳定性较差。

表 1 为四种信息熵准则在测试集的定量评价结果。相较于排列熵、包络熵和模糊熵，样本熵优化 VMD 的模型综合预测性能最优，其 RMSE 低于 15 mm，极端误差控制效果良好；MAE 整体偏低，预测稳定性优异；NSE 趋近于 1，表明模型可精准解释海平面序列的数值变异特征。上述性能差异源于不同熵准则

对 VMD 分解的优化机制不同：样本熵通过模板匹配概率量化序列自相似性，可有效提升信号分解规整度、抑制模态混叠。而排列熵存在振幅信息缺失问题、包络熵易过度平滑缓变序列、模糊熵参数敏感性较强，三者的 VMD 分解优化效果均弱于样本熵。

Table 1. Objective evaluation index performance of various entropies (unit: mm)
表 1. 各种熵的客观评价指标性能(单位: mm)

	RMSE	MAE	MAPE	NSE
PeEn	19.666	14.677	0.206	0.971
SpEn	14.707	12.204	0.172	0.984
FuzzyEn	17.269	13.448	0.189	0.977
EnVeEn	22.712	17.882	0.253	0.961

3.4. 预测模型对比分析

为验证不同深度学习模型在海平面变化时间序列预测任务中的性能差异，本文以样本熵作为适应度函数，时序特征长度为 6，选取 LSTM、GRU、CNN-BiLSTM 以及 CNN-BiGRU 作为对比模型展开实验分析。从长时序预测效果、局部时段预测细节及量化指标对比三个维度，逐层剖析各模型架构的优劣，以体现 CNN-BiGRU 的时空协同优势。




Figure 5. Long-term prediction capability of various deep learning models on the test set
图 5. 各深度学习模型在测试集的长时序预测能力

图 5 显示，测试集的 2012~2024 年预测中，CNN-BiGRU 模型的预测曲线与原始月平均海平面数据贴合度最优，对 2017 年 9 月、2020 年 8 月等峰谷值的趋势拐点捕捉最精准。这一优势源于其架构设计的时空协同机制。CNN 层通过一维卷积核滑动提取局部波动形态，相当于局部模式滤波器，能够识别海平面序列中的峰谷结构与周期片段。BiGRU 层并行处理前向与后向时序信息，整合历史演变与未来趋势约束，有效捕捉具有滞后相关性的海平面变化因素的物理过程。

LSTM 因单向记忆局限表现较弱, 其仅利用历史信息预测未来的结构难以刻画海平面变化中存在的反向因果关联, 且随着序列长度增加, 梯度消散导致长期依赖信息丢失, 在部分时段出现明显偏离。BiGRU 的双向结构部分缓解了单向记忆的局限, 对复杂时序特征的表达能力优于 LSTM, 但缺乏显式的空间特征提取机制, 对局部波动形态的刻画能力不足, 在极端波动或复杂周期处拟合偏差仍较明显。CNN-BiLSTM 引入卷积层后整体趋势跟踪能力较好, 但其 LSTM 单元的门控结构较 GRU 更为复杂, 在相同参数量下特征提取效率偏低, 且海平面序列季节节律明显, LSTM 的误差在季节转折时段相对集中。遗忘门本是为缓解长期依赖问题而设计, 把 LSTM 的性能局限归因于对季节性信息的过滤还缺乏直接证据, 具体成因尚需借助门控状态分析等手段进一步查证。




Figure 6. Prediction quality of various deep learning models in local time periods
图 6. 各种深度学习模型在局部时间段的预测质量

图 6 显示了 2023 年 1 月至 2024 年 11 月局部时段的预测细节。CNN-BiGRU 在该时段内预测性能显著优于 LSTM、BiGRU、CNN-BiLSTM, 精准捕捉 2023 年 10 月峰值、2024 年 8 月谷值及后期回升趋势, 曲线与原始数据贴合度最高, 残余误差波动最小。这一细节表现验证了卷积提取局部特征双向门控刻画时序依赖的架构优势。CNN 层对局部波动的锚定使模型对关键拐点敏感, BiGRU 层的双向绑定使趋势转折预判更为准确。

其他深度预测模型拟合偏差明显, 残差多次超 30 mm, 暴露各自架构局限。LSTM 在 2024 年 5 月峰值预测中产生滞后偏差, 源于单向记忆衰减对近期突变响应迟缓。BiGRU 因缺乏空间滤波受高频噪声干扰, 在 2024 年 10 月峰值处出现振幅高估。CNN-BiLSTM 在海平面变化的峰值与谷值预测中多次出现显著偏差, 2024 年 5 月峰值残差达 55 mm, 2024 年 8 月谷值残差近 -40 mm, 源于 LSTM 复杂门控机制导致信息传递损耗, 使模型对趋势转折响应延迟, 难以同步捕捉局部波动形态与长程依赖特征。

表 2 显示, 四种深度学习模型预测性能随架构迭代逐步提升。LSTM 因单向记忆局限表现最弱。BiGRU 双向结构使时序依赖捕捉能力增强。CNN-BiLSTM 引入卷积层后实现空间特征提取, 但 LSTM 复杂门控

制约信息传递效率。CNN-BiGRU 各项误差指标均为最优，RMSE 较 CNN-BiLSTM 降低 21.0%，MAE 降低 17.1%，MAPE 从 0.207 降至 0.172。这种优势性能源于局部特征的提取与双向捕捉长时序能力，二者级联实现空间滤波与时序绑定的互补。此外，GRU 替代 LSTM 后简化门控结构，使卷积特征能够高效双向传播，避免信息损耗。这种架构演进揭示：海平面预测需同步解决多尺度形态提取与双向趋势关联两个问题，单一循环网络仅具时序建模能力，卷积 - 双向循环组合方能实现时空特征协同，而 GRU 的轻量化设计更适配海洋时序的周期特性。

Table 2. Objective evaluation index performance of various deep learning models (unit: mm)

表 2. 各种深度学习模型的客观评价指标性能(单位: mm)

	RMSE	MAE	MAPE	NSE
LSTM	23.511	17.864	0.250	0.958
BiGRU	21.256	16.342	0.229	0.966
CNN-BiLSTM	18.575	14.712	0.207	0.974
CNN-BiGRU	14.707	12.204	0.172	0.984

4. 实验与分析

4.1. 时间步长的周期性

为探究特征输入长度对融合模型预测性能的影响，本文以样本熵为适应度函数，基于 CNN-BiGRU 模型，设置 3、6、12、18 个月的月尺度特征输入步长展开实验，结果如图 7 所示。我们从预测性能规律、最优步长物理机制、模型设计启示及参数选择验证四个维度，探讨时间步长的周期性意义，说明实验参数的有效选择契合海平面变化周期特性。

图 7 显示，6 个月步长时 RMSE 低于 15 mm，NSE 超 0.98，MAE 和 MAPE 达最小值，残差分布集中，中位数为-2.525，极端误差最少。3 个月因周期关联捕捉不足，RMSE、MAE 显著放大。12 个月时 RMSE 达峰值，NSE 最低，表明冗余信息干扰预测精度。18 个月残差波动加剧，箱体扩张，中位数偏移至-11.910，长期记忆衰减导致系统性偏差。这一结果突出显示了海平面变化数据驱动预测中特征工程的关键性。




Figure 7. Prediction performance under different time-step feature inputs

图 7. 不同时间步长的特征输入下的预测性能

从季节变化机制分析,6个月特征步长与南海北部海平面变化固有周期高度匹配。该海域受东亚季风主导,冬、夏季风交替转换的周期约为6个月。6个月输入序列可覆盖完整季风循环,使模型充分学习冬夏海平面的季节响应特征,既保证了历史趋势信息充足,又规避了长序列带来的信息冗余。3个月步长仅包含半季风周期,无法完整刻画季风转换过程,缺乏物理机制约束,预测误差显著增大;12个月步长虽包含完整年周期,但引入大量弱相关历史重复信息,降低模型对近期海平面变化的敏感度;18个月步长纳入复杂非平稳的年际变化信号,过长的输入序列导致模型特征聚焦能力下降,长期记忆衰减引发系统性预测偏差。

综上,模型输入步长应匹配研究对象的优势物理周期,而非盲目增大序列长度。针对具有显著季节节律的月均海平面序列,6个月步长可实现周期特征捕捉与局部波动拟合的最优平衡。该结果表明,验潮站海平面预测的特征长度需结合区域海气作用的时间尺度自适应选取,不宜采用固定取值,可为同类海岸带预测模型参数设置提供参考。

4.2. 模型的月尺度特征验证

为验证组合模型预报效果,对测试集2012年1月至2024年11月的预测质量开展系统性分析,从月际波动幅度、季节性变化规律及极端事件特征等维度,对比不同熵优化方案的月度预测稳定性。




Figure 8. Prediction performance of various entropy functions at the monthly statistical scale
图 8. 各种熵函数在月统计尺度上的预测性能

图 8 结果表明,样本熵优化模型全年拟合最优,可精准捕捉 10 月峰值与季节波动;包络熵在春秋季节风转换期整体偏移。月度 RMSE 显示:样本熵各月误差小且平稳;排列熵、模糊熵误差中等、季节性波动突出;包络熵在 3、9 月误差骤升,稳定性最差。

月度差异源于各熵函数对周期信号的解析能力。样本熵依托自相似性甄别平缓周期，VMD 可有效拆分趋势与季节分量，适配季风转折时段；包络熵易抹平极值，排列熵缺失振幅信息，模糊熵受参数干扰造成月度精度不稳。综上，样本熵优化可减少模态混叠，抑制相位偏移。




Figure 9. Prediction performance of various prediction models at the monthly statistical scale

图 9. 各预测模型在月统计尺度上的预测性能

图 9 显示，CNN-BiGRU 在全周期内的自适应能力显著优于各对比模型。其月度 RMSE 分布更为集中、峰值更低，即便在 10 月误差高值期仍能维持较高预测精度。LSTM 在夏秋季预测误差持续放大，单向记忆衰减易造成明显相位滞后。BiGRU 虽在春季误差水平较低，但进入秋季后波动显著增大，因缺少空间滤波环节，季风转换期的噪声干扰更为突出。CNN-BiLSTM 对整体趋势的跟踪效果较好，然而 LSTM 复杂的门控结构易产生信息损耗，导致其在 5 月、11 月等季节转换节点出现响应延迟。

该结果直观揭示，CNN-BiGRU 的稳健性源于时空协同架构对月尺度双重特性的适配。CNN 层提取的局部波动形态捕捉了月内热力与动力过程的快速变化，BiGRU 层双向绑定的长程依赖有效追踪了季风驱动的季节相位演进。这种设计使模型既能感知当月局地强迫，又能整合前后月份的趋势约束，在季风转换期实现相位精准锁定。单一循环网络仅依赖历史记忆，难以同步处理转折期的双向信息。CNN-BiLSTM 虽具备卷积空间特征提取能力，但 LSTM 门控机制带来的相位信息传递损耗，仍制约了其在关键转换期的预测表现。

5. 结束语

本文以广东省阳江市海陵岛闸坡验潮站为试点，构建融合参数自适应变分模态分解与 CNN-BiGRU

的混合预测框架。探究了信息熵准则优选、深度学习架构设计及特征时间步长优化等关键问题。结论如下：

(1) 样本熵作为 VMD 参数优化的适应度函数具有显著优势。通过度量序列自相似性，对月尺度海平面缓变周期的规则性更为敏感，GWO 算法能够搜索到模态混叠最少、噪声干扰最弱的分解参数组合，为后续预测提供高质量的输入特征。

(2) CNN-BiGRU 架构在时空特征协同提取方面表现最优。CNN 层通过一维卷积提取局部波动形态，BiGRU 层双向捕捉长程时序依赖，二者级联实现空间滤波与时序绑定的互补，较 LSTM、BiGRU 及 CNN-BiLSTM 在极端误差控制和预测稳定性方面均有显著提升。

(3) 特征时间步长为 6 个月时模型性能达到最佳。该长度与南海北部季风转换周期高度吻合，既覆盖完整的冬夏季风循环以保留物理约束，又避免过长序列引入冗余信息，实现了周期关联捕捉与细节波动保留的平衡；该步长由闸坡站实测数据的对比试验确定，与南海北部季风转换周期密切相关，用于动力环境差异较大的其他站点时需重新优选。

(4) 月尺度统计特征方面，所提的混合方案的预测曲线与真实月平均海平面贴合度最高，精确捕捉季节性波动节点，预测变化差异小且各月性能稳定，表明混合模型在月统计预测中动态追踪能力更强，预测误差更小、更稳定。

综上，本文提出的参数自适应 VMD 与 CNN-BiGRU 耦合框架，为月平均海平面预测提供了新的技术路径，适用于海岸带风险研判与海洋业务预报。该方法可进一步扩展应用于其他海洋时序参数(如潮位、海表温度等)的预测研究。本文的建模与验证均基于闸坡站实测资料，所得最优参数组合带有南海北部海域的特点，各验潮站的动力环境差异较大，相关结论用于其他站点时需谨慎；下一步将把该框架应用于南海不同岸段及其他代表性验潮站，开展多站点对比验证，并结合卫星测高资料检验其适用范围。后续可引入气温、风速、气压等气象因子，依托多变量输入与注意力机制优化极端天气预报。结合季节气候预测模式输出，发展动力-统计混合预报方法，有望改善年际异常年份的月度预报能力。最后，针对海岸带防灾减灾的精细化需求，未来可探索多时间尺度融合研究，将月平均预测结果与高频观测数据相结合，为海洋环境安全保障提供更可靠的决策支持。

基金项目

国家自然科学基金项目(42201029)；广东省重点领域研发计划项目(2023B1111050013)；江西省教育厅科学技术研究项目(GJJ2401401)。

参考文献

- [1] 周健, 于道德, 李琼, 等. 海平面上升的灾害效应、风险评估及应对策略[J]. 海洋科学, 2025, 49(2): 67-80.
- [2] Sun, Q., Wan, J., Liu, S., Jiang, J. and Muhammad, Y. (2023) A New Decomposition Model of Sea Level Variability for the Sea Level Anomaly Time Series Prediction. *Journal of Oceanology and Limnology*, **41**, 1629-1642. <https://doi.org/10.1007/s00343-022-1418-5>
- [3] 熊思亦, 熊永良. 基于 CEEMDAN-LSTM 组合方法的海平面变化预测分析[J]. 大地测量与地球动力学, 2023, 43(9): 899-903.
- [4] 赵健, 刘仁强. 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[J]. 海洋科学, 2023, 47(8): 7-16.
- [5] 赵健, 蔡瑞阳, 孙伟富. 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[J]. 同济大学学报(自然科学版), 2022, 50(10): 1508-1516.
- [6] 陈红康, 鲁铁定, 孙喜文, 等. 一种改进的 VMD-XGBoost 验潮站月海面高序列预测模型[J]. 海洋测绘, 2023, 43(5): 17-21.
- [7] 叶玉龙, 张研, 袁普龙, 等. 基于优化变分模态分解的大坝变形组合预测模型: 以丰满水电站为例[J]. 科学技术

- 与工程, 2024, 24(26): 11401-11408.
- [8] Xing, W.Y., Bai, Y.L., Ding, L., Yu, Q.H. and Song, W. (2022) Application of a Hybrid Model Based on GA-ELMAN Neural Networks and VMD Double Processing in Water Level Prediction. *Journal of Hydroinformatics*, **24**, 818-837. <https://doi.org/10.2166/hydro.2022.016>
- [9] 李博, 李欣, 芮红, 等. 基于变分模态分解和灰狼优化极限学习机的隧道口边坡位移预测[J]. 吉林大学学报(工学版), 2023, 53(6): 1853-1860.
- [10] Balogun, A.L. and Adebisi, N. (2021) Sea Level Prediction Using ARIMA, SVR and LSTM Neural Network: Assessing the Impact of Ensemble Ocean-Atmospheric Processes on Models' Accuracy. *Geomatics, Natural Hazards and Risk*, **12**, 653-674. <https://doi.org/10.1080/19475705.2021.1887372>
- [11] Rosencranz, J.A., Thorne, K.M., Buffington, K.J., Overton, C.T., Takekawa, J.Y., Casazza, M.L., *et al.* (2019) Rising Tides: Assessing Habitat Vulnerability for an Endangered Salt Marsh-Dependent Species with Sea-Level Rise. *Wetlands*, **39**, 1203-1218. <https://doi.org/10.1007/s13157-018-1112-8>
- [12] 李祯. 优化 XGBoost 算法的 GNSS 高程和海平面高时序预测研究[D]: [硕士学位论文]. 抚州: 东华理工大学, 2023.
- [13] 蔡瑞阳. 中国黄海海平面变化时空分析及非线性预测研究[D]: [硕士学位论文]. 东营: 中国石油大学(华东), 2022.
- [14] Tumse, S. and Alcansoy, U. (2025) Statistical and Deep Learning Approaches in Estimating Present and Future Global Mean Sea Level Rise. *Natural Hazards*, **121**, 10377-10404. <https://doi.org/10.1007/s11069-025-07203-5>
- [15] 朱湘杰, 刘娉婷, 韩任智, 等. 融合改进优化算法与深度学习的海平面变化预测[J]. 广东海洋大学学报, 2024, 44(6): 66-72.
- [16] 周晨, 李君益, 郑全安, 等. 南海北部冬季陆架波特征[J]. 广东海洋大学学报, 2023, 43(3): 89-97.
- [17] 陈建珩, 许东峰, 姚志雄. 利用机器学习模型预测中国沿海海平面变化[J]. 海洋学研究, 2024, 42(3): 108-118.
- [18] 杨一琳. 南海北部海平面多尺度分析及预测[D]: [硕士学位论文]. 南京: 南京信息工程大学, 2023.
- [19] Alenezi, N., Alsulaili, A. and Alkhalidi, M. (2023) Prediction of Sea Level in the Arabian Gulf Using Artificial Neural Networks. *Journal of Marine Science and Engineering*, **11**, Article 2052. <https://doi.org/10.3390/jmse11112052>
- [20] Uluocak, I. (2025) Comparative Study of Multivariate Hybrid Neural Networks for Global Sea Level Prediction through 2050. *Environmental Earth Sciences*, **84**, Article No. 79. <https://doi.org/10.1007/s12665-025-12090-x>.