

一种基于深度学习的海表温度混合预测方法

韩莹, 孙凯强, 张栋, 王乐豪, 谈昊然

(南京信息工程大学 自动化学院, 江苏 南京 210044)

摘要: 海表温度 (SST) 是海洋水文的重要参数, 准确预测 SST 对海洋经济发展与极端天气的预防都有重大意义。首先, 针对 SST 序列数据的多噪声特点, 采用变分模态分解方法 (VMD) 预处理, 以减少噪声对预测结果的影响。其次, 将卷积神经网络 (CNN) 与长短时记忆网络 (LSTM) 结合, 同时提取 SST 序列的空间与时间特征, 以提高预测精度。最后, 本文提出了一种基于深度学习并融合了去噪模块的 SST 预测模型, 选取我国东海海域的 SST 进行实证研究。通过与基线模型、现有模型的对比, 证明了本文模型不但在 SST 的预测精度方面提升明显, 而且具有较好的鲁棒性。

关键词: 海表温度; 变分模态分解; 长短时记忆网络; 卷积神经网络

中图分类号: P731.3

文献标识码: A

文章编号: 1007-6336(2022)05-0791-08

A hybrid sea surface temperature predicting method based on deep learning

HAN Ying, SUN Kai-qiang, ZHANG Dong, WANG Le-hao, TAN Hao-ran

(School of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Sea surface temperature (SST) is an important parameter of ocean hydrology, and accurate prediction of SST is of great significance for ocean economic development and extreme weather prevention. For the characteristics of SST series with multiple noises, variational model decomposition (VMD) is used to pre-process the SST series and reduce the influence of noise on the prediction results. Furthermore, the convolutional neural network (CNN) is combined with the long short-term memory network (LSTM) extracting both spatial and temporal features in SST sequences to improve the prediction accuracy. Finally, a SST prediction model based on deep learning with incorporating the denoising module is proposed in this paper. The SST of China's East China Sea waters is selected for empirical study. Through comparison and analysis with the baseline models and existing models, it is proved that the model in this paper not only improves the SST prediction accuracy significantly, but also has better robustness.

Key words: sea surface temperature; variational modal decomposition; long short-term memory network; convolutional neural network

海洋对气候变化、生态系统发展具有重要影响。作为反映海水冷热状况的物理量, 海表温度 (sea surface temperature, SST) 不但可以影响大气与海洋之间的能量交换, 而且与热带气旋的形成^[1]、区域气候的变化^[2]都密切相关。研究 SST

的时间分布规律, 对其进行精准预测, 不仅是海洋学的重要内容, 而且对气象、航海等学科影响深远^[3]。

目前 SST 的预测方法可以概括为两类, 一类是数值预报方法, 需要依靠专业知识建立复杂的

收稿日期: 2021-08-02, 修订日期: 2022-03-21

基金项目: 南方海洋科学与工程广东省实验室(珠海)基金项目(SML2020SP007); 国家自然科学基金项目(62076136)

作者简介: 韩莹(1978—), 女, 辽宁沈阳人, 副教授, 博士, 主要研究方向为大数据处理方法及其应用, E-mail: hanyingcs@163.com

热力和物理学方程来进行 SST 的预测^[4];另一类是基于数据驱动的方法,不同于数值预报方法,不需要专业知识构建方程。基于数据驱动的方法,通过模型学习数据的内在特征和规律,实现对 SST 的精准预测。张玉荣等^[5]建立自回归模型对海温变化趋势进行预测。此外,支持向量机(support vector regression, SVR)^[6]、人工神经网络^[7]、多层感知机^[8]也被用于 SST 预测。上述基于数据驱动模型无法充分捕捉 SST 序列的非线性关系。特别在处理大规模数据时,预测效果不尽如人意。近年来,随着深度学习的流行,循环神经网络及其扩展——长短时记忆网络(long-short term memory, LSTM)^[9]、门控循环单元(gate recurrent unit, GRU)^[10]成为 SST 预测的研究热点。

然而,单一循环神经网络预测模型的学习能力弱,易产生过拟合现象。已有研究表明^[11],混合模型有助于提高预测精度。一方面,研究者尝试将循环神经网络与其他预测模型结合,以提高预测精度。Xiao 等^[12]构建了 LSTM 与自适应提升算法(adaptive boosting, AdaBoost)的组合模型,对我国东海水域取点进行预测。针对循环神经网络只考虑时间特性,而忽略了空间特性的缺点,Xiao 等^[13]将卷积神经网络(convolutional neural network, CNN)与 LSTM 结合,用于提高基于海温图像的 SST 预测精度。另一方面,考虑到 SST 呈现非线性、多噪声的特点^[14],研究者尝试在 SST 预测模型中加入消除噪声的数据预处理模块来提高预测精度。贺琪等^[15]在循环神经网络中引入基于局部加权回归的周期趋势分解法(seasonal-trend decomposition procedure based on Loess, STL)对 SST 序列进行预处理来提高预测精度。贺琪等^[16]通过经验模态分解(empirical mode decomposition, EMD)进行信号主成分分析,分别提出了基于 EMD-GRU 和 EMD-LSTM 的 SST 复合预测模型,提高了 GRU 和 LSTM 的预测精度。

通过上述分析,有鉴于至今未见同时综合考虑 SST 序列时空特性和噪声影响的 SST 预测模型,并考虑到变分模态分解(variational mode decomposition, VMD)通过控制带宽抑制了 EMD 方法的模态混叠现象,具备鲁棒性,本文提出了

一种新的 VMD-CNN-LSTM 的海温预测混合模型。首先,模型对 SST 序列进行 VMD 分解,减弱噪声的影响;其次,将分解后的分量输送到 CNN-LSTM 中,相对于单一模型, CNN-LSTM 可以更好地提取序列中的时空特性,减少过拟合。为了证明模型的有效性和实用性,选取我国东海水域进行 SST 预测实例验证。结果表明,在预测精度方面,本文模型在选取的 MAE、RMSE 评价指标上不但优于 SVR、LSTM、GRU 等基线模型,也优于现有 SST 预测的 EMD-LSTM、EMD-GRU、STL-GRU、STL-LSTM 等混合模型。通过不同时间步长下预测精度的对比分析,进一步证明了本文算法的鲁棒性。

1 材料与方法

1.1 研究区域

本文研究区域为我国东海(23°00'N—33°10'N, 117°11'E—131°00'E)。东海蕴含着丰富的石油资源和鱼类资源,不仅是重要的海上贸易航道,还是我国重要的海洋战略要地。对东海的 SST 进行精准预测,对我国海上贸易和战略巡防都有着重要的现实意义。为了验证该预测方法在不同海洋环境的适用性,本文分别从东海陆架浅海区域 [T1(32.13°N, 122.87°E); T6(26.7°N, 122.13°E)]、岛屿周边区域 [T3(31.87°N, 127.93°E); T5(28.13°N, 127.65°E); T7(25.31°N, 124.78°E)]以及开阔外海区域 [T2(31.07°N, 124.93°E); T4(28.26°N, 124.85°E)]随机选择 7 个点进行研究。

1.2 数据描述

本文数据来自 Remote Sensing Systems (REMSS),可在 www.remss.com 获得。REMSS 提供了两种最佳插值 SST 日常产品,一种是 25 km 分辨率的微波数据(microwave, MW),另一种使用分辨率为 9 km 的微波和红外数据(microwave and infrared, MW_IR)。本文采用的是 MW_IR 数据集,选取了 2002 年 6 月 1 到 2020 年 12 月 31 日每日 SST。每处标记点包含 6785 天的海温数据。

表 1 列出了选取的 7 个标记点 SST 的基本统计数据,可以清晰地观测到 SST 的范围、大小、波动趋势等。从表 1 我们可以看到,这些标

记点既存在相似又存在差异。随着纬度的增高,标记点的平均温度逐渐降低,由于东海整体处在北回归线以北,所以各标记点的最高温度相差不大。但各标记点的最小值和其他指标存在较大差异,这些差异并不是离群值的表现,而是受极端天气、洋流以及海陆冷、热交换的影响,反而真实反映出不同区域 SST 的变化规律。T1 处纬度偏高,且靠近内陆,受到海陆冷、热交换的影响,温度变化幅度较大。

表1 各标记点的统计数据(°C)
Tab.1 Statistical data of each marker (°C)

地点	平均值	标准差	最小值	50%	最大值
T1	18.12	5.44	9.35	17.41	30.96
T2	21.52	4.24	14.42	21.13	31.22
T3	21.14	4.27	12.45	20.65	31.32
T4	21.16	4.19	13.75	20.87	30.01
T5	23.56	3.73	15.88	23.51	31.04
T6	25.39	2.67	20.01	25.43	30.62
T7	25.82	2.53	21.09	25.82	31.01

1.3 VMD 模型

VMD 是一种完全非递归的模式变分和信号处理方法,解决了 EMD 对噪声和采样信号敏感的限制性。VMD 可以确定模式分解的个数,并自适应地搜寻每种模式的最佳中心频率和有限带宽,实现固有模式分量(intrinsic mode functions, IMF)的有效分离和信号的频域划分。VMD 的核心思想是构建和求解变分问题,具体步骤如下。

步骤 1: 构造变分问题

$$x(t) = [(\delta_t + j/\pi t) * u_k(t)] e^{-j\omega_k t} \quad (1)$$

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \|\partial_t x(t)\|_2^2 \right\} \quad (2)$$

$$s.t. \sum_{k=1}^K u_k = f \quad (3)$$

式中: f 是初始信号; k 是分解模式的个数; $\{u_k\}$ 、 $\{\omega_k\}$ 是分解后的第 k 个模式分量和中心频率; δ_t 为狄拉克函数; $*$ 为卷积运算。

式(1)和式(2)是关于 $\{u_k\}$ 、 $\{\omega_k\}$ 的多元函数,式(3)为各模式的约束条件。

步骤 2: 求解变分问题

利用二次惩罚项和拉格朗日乘子法的优势,引入增广 Lagrange 函数,将构造的约束变分问题

转化为非约束变分问题,得到增广 Lagrange 表达式如式(4)所示:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \|\partial_t x_{it}\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (4)$$

式中: λ 为拉格朗日乘法算子; α 为二次惩罚因子,可以降低高斯噪声的干扰。然后利用交替方向乘子迭代算法结合傅里叶等距变换,优化得到各模式分量和中心频率,并搜寻增广拉格朗日函数的鞍点,交替寻优迭代后的 $\{u_k\}$ 、 $\{\omega_k\}$ 和 λ 的表达式如式(5)(6)(7)所示。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (5)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (6)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \gamma \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (7)$$

式中: γ 为噪声容忍度,以确保信号分解后不失真; $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{f}(\omega)$ 和 $\hat{\lambda}(\omega)$ 分别是原信号 $u_k^{n+1}(t)$ 、 $u_i(t)$ 、 $f(t)$ 、 $\lambda(\omega)$ 对应的傅里叶变换。最后根据最优解将初始信号分解为 K 个模式分量。

1.4 CNN 原理

CNN 在序列模型和自然语言领域应用广泛,与循环神经网络相比, CNN 更擅长捕捉空间特征。其基本原理由式(8)—(10)给出。

$$y_i^{l+1}(j) = K_i^l * x^l(j) + b_i^l \quad (8)$$

$$a_i^{(l+1)}(j) = f(y_i^{(l+1)}(j)) \quad (9)$$

$$p_i^{l+1}(j) = \max_{(j-1)W+1 \leq t \leq jW} \{a_i^l(t)\} \quad (10)$$

式中: $*$ 为卷积操作; K_i^l 、 b_i^l 分别表示 l 层中第 i 个滤波器的权值和偏置; $x^l(j)$ 表示 l 层中第 j 个区域; $y_i^{l+1}(j)$ 表示 $l+1$ 层中第 i 个滤波器、第 j 个神经元的输入; $a_i^{(l+1)}(j)$ 是 $y_i^{l+1}(j)$ 的激活值; f 为激活函数; W 为池化内核的宽度; $p_i^{l+1}(j)$ 表示池化后的神经元值。

1.5 LSTM 原理

LSTM 针对循环神经网络短时记忆的缺点,引入门的结构,实现长期特征的学习。图1为 LSTM 的结构图。其中, x_t 、 h_{t-1} 为 t 时刻的输入值和 $t-1$ 的输出值,门结构通过 Sigmoid 层和逐

点乘法运算组成, LSTM 结构中包含了遗忘门、输入门、输出门, 以此对输入信息进行选择性遗忘和输出信息选择性记忆。LSTM 原理如式 (11)~(16) 所示:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (11)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (12)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (13)$$

$$C_{t1} = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (14)$$

$$C_t = C_{t-1} \cdot f_t + i_t \cdot C_{t1} \quad (15)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (16)$$

式中: W_f 、 W_i 、 W_o 、 W_c 为遗忘门、输入门、输出门、细胞状态候选值的权值; b_f 、 b_i 、 b_o 、 b_c 、 f_t 、 i_t 、 o_t 、 C_{t1} 为对应的偏置和输出值; σ 为激活函数 sigmoid; C_{t-1} 为 $t-1$ 时刻的细胞状态; C_t 为 t 时刻细胞状态更新后的值; h_t 为 t 时刻的输出值。




图 1 LSTM 结构

Fig. 1 LSTM structure

1.6 基于 VMD-CNN-LSTM 的 SST 预测模型

本文采用滑动窗口进行预测。对于选定的标记点, 每一处都包含 1 个 SST 序列, 通过指定步长的滑动窗口生成观测窗口和预测窗口, 进而从原始时间序列中提取历史、未来海温序列, 最终将提取到的海温数据输入 VMD-CNN-LSTM 模型中进行预测。图 2 为 VMD-CNN-LSTM 海温预测模型整体框架图。具体步骤如下。

步骤 1: 数据归一化

由于季节变化和气候影响, SST 温度变化较大且短时间变化剧烈。因此, 利用式 (17) 对初始 SST 序列归一化, 将 SST 值限制在 $[0, 1]$ 内, 有利于模型快速收敛:

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (17)$$

式中: x 为初始的 SST 序列; $x_{\min}$ 、 $x_{\max}$ 为初始 SST 序列的最小值和最大值。




图 2 预测模型框架

Fig. 2 Frame diagram of prediction model

步骤 2: 数据分解去噪

将归一化的数据输入 VMD 模块进行分解, 经过分解, 得到多个模态分量, 每个分量代表不同频率的时间序列, 同时具备不同的物理意义, 能够减少噪声对预测模型的影响。

步骤 3: 基于 CNN-LSTM 的分量预测

CNN-LSTM 神经网络由 CNN 层、LSTM 层、Dropout 层和 Dense 层共同组成。由于各模态分量的幅值差别较大, 所以将各分量分别进行训练, 通过 CNN、LSTM 进行特征提取, 最后经过 Dense 层输出预测结果。

步骤 4: 预测结果输出

各模态分量的权值均为 1, 故将各模态分量的预测结果进行累加, 并进行反归一化, 最终得到 SST 序列的预测结果。

1.7 参数设置及评价指标

本文选取 7 条 SST 序列, 该序列每天记录 1 次, 共 6785 d。模型为输入连续的前 5 天 SST 预测后 1 天的 SST。每处标记点的数据维度为 6785×1 , 通过滑动步长进行数据处理后, 模型的输入维度为 $6780 \times 5 \times 1$, 输出维度为 6780×1 ,

Test_size 选取 0.2, 将前 80% 的数据作为训练集, 后 20% 作为测试集。经过 VMD 进行分解后得到 3 个 $6780 \times 5 \times 1$ 的时间序列, 然后采用 CNN 进行特征提取, 维度变为 $6780 \times 5 \times 32$, 接着通过三层 LSTM 训练后, 维度依次变为 $6780 \times 5 \times 32$ 、 $6780 \times 5 \times 32$ 、 6780×16 , 最后通过 Densec 层进行预测, 输出维度依次为 6780×10 、 6780×1 , 最终将 3 个模态分量的预测结果相加, 得到模型实际预测结果。其中模型的主要参数如表 2 所示。

表 2 算法参数表
Tab.2 Algorithm parameter table

模型名称	参数名称	参数值
VMD	K	3
	Alpha	1
	Tol	1e-6
CNN	Kernel_size	5
	Filters	32
LSTM	Layers	3
	Neurous	{32, 32, 16}
Dropout	P	0.2
	Layers	2
Dense	Neurous	{10, 1}
	Batch_size	128
	Epoch	200

本文采用 MAE [式(18)] 和 $RMSE$ [式(19)] 作为评价指标, 对模型的预测误差和精度进行评价。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - x_i| \quad (18)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2} \quad (19)$$

式中: y_i 为预测值; x_i 为初始值; N 为样本个数。

2 结果与讨论

2.1 VMD 分解模块分析

经过数据预处理后, 对标记点 T1 进行 VMD 分解, 选取前 1000 天数据绘图展示。图 3 为 T1 标记点 VMD 分解图。其中, Signal input 为 T1 标记点预处理后的 SST 序列, IMF0、IMF1、IMF2 为分解后的模态分量, IMF0 反应 SST 的季节变化趋势, IMF1、IMF2 为余项, 表示各种残差噪声。从图 3 可以看出, 季节分量变化幅度最大, 其对应的频谱值最大, 振动频率最小, 残差余项 IMF1 变化幅度最小, 振幅最大。

图 4 为 IMF0 分量的拟合效果图, 从图 4 可以看出, 神经网络对低频分量的预测效果较好, 由于 IMF0 基本反应了初始数据的状况, 并且它剔除了残差噪声, 使得序列变得平滑, 所以便于预测。从图 5、图 6 可以看出, 高频分量的波动大, 模型很难精准预测温度变化趋势, 拟合效果欠佳。表 3 为不同模态分量预测效果, 从表 3 可以看出, 仅将 IMF0 作为预测结果会导致较大的误差, 而将不同分量的预测结果累加, 模型会取得较高的预测精度。




图 3 T1 标记点的 VMD 分解图

Fig. 3 VMD decomposition diagram of T1 marker




图4 IMF0 测试集拟合图

Fig. 4 IMF0 test set fitting diagram




图5 IMF1 测试集拟合图

Fig. 5 IMF1 test set fitting diagram




图6 IMF2 测试集拟合图

Fig. 6 IMF2 test set fitting diagram

表3 不同模态分量预测效果

Tab.3 Prediction effect of different modal components

模态分量	MAE	REMSE
IMF0	0.2639	0.3548
IMF0+IMF1	0.2318	0.3104
IMF0+IMF1+IMF2	0.1261	0.1607

最后为了证明 VMD 去噪模块的重要性和有效性,将本文模型与消融模型 CNN-LSTM 进行对比验证。对比结果如表 4 所示,加入 VMD 分解后,其 $RMSE$ 和 MAE 分别降低了 58.37% 和 54.77%,模型的预测精度取得有效提高。


表4 消融模型对比

Tab.4 Ablation model comparison


模型	MAE	REMSE
VMD-CNN-LSTM	0.1261	0.1607
CNN-LSTM	0.2788	0.3860

2.2 基线模型对比

为了证明本文模型的有效性,对选取的 7 个标记点分别进行 SST 预测,并将预测结果与传统基线模型 SVR^[6]、LSTM^[9]、GRU^[10] 进行比较。以 5 d 时间步长预测结果为例,其中各标记点 $RMSE$ 和 MAE 的结果如图 7 所示。以 T1 标记点为例,本文模型的 $RMSE$ 比 SVR、LSTM、GRU 分别减少了 73.64%、63.07%、64.5%, MAE 分别减少了 74.31%、61.89%、64.01%。结果表明,本文模型表现最优, LSTM 表现略微优于 GRU, SVR 表现最差,本文模型在 T1 标记点表现明显优于其他传统基线模型,并且在选取的其他 6 个标记点上仍表现最优,证明了本文模型具有较好的鲁棒性和预测效果。



(a) MAE



(b) RMSE

图7 与基线模型对比结果

Fig. 7 Comparison result graph with baseline models

2.3 现有模型对比

考虑到 SST 时间序列的周期性和非线性特征,现有模型同样从信号分解的角度出发,对初始 SST 序列进行分解,主要为 STL 和 EMD 两种分解方法。同样对选取的 7 个标记点进行 SST 预测,将本文模型对比 STL-GUR^[15]、STL-LSTM^[15]、EMD-GRU^[16]、EMD-LSTM^[16] 等模型,并将预测结果进行展示,以 5 d 时间步长预测结果为例,其中各标记点 *RMSE* 和 *MAE* 的结果如图 8 所示。以 T1 标记点为例,本文模型比 EMD-LSTM、EMD-GUR、STL-GRU 和 STL-LSTM 模型的 *RMSE* 分别减少了 35.49%、46.02%、59.77% 和 54.32%,*MAE* 分别减少了 37.33%、50.18%、56.38% 和 53.19%。通过信号分解的方法,相比单一模型均得到了提升,其中 EMD 分解优于 STL 分解,本文采用的 VMD 分解预测结果最优,相比 EMD 分解,VMD 的低频分量更容易表现出 SST 波动变化,有利于模型预测。





图 8 与现有模型对比结果

Fig. 8 Comparison result graph with existing models

最后,选取测试集的部分预测结果进行可视化操作,以 T1 标记点为例,图 9 为本文模型与现有模型的预测效果图。从图 9 可以看出,在前 20 d 海温上升阶段,本文模型的拟合效果最佳,后 30 d 海温波动上升,特别在最后 5 d 海温骤增,与其他模型相比,只有本文模型能达到较好的拟合程度。

2.4 不同时间步长预测效果分析

选取 1 d、5 d、7 d 时间步长进行对比验证,以 T1 标记点为例,各模型的 *RMSE* 和 *MAE* 如表 5 所示。从表 5 可以看出,随时间步长的增加,各模型的预测效果随之降低。但本文模型在选取的时间步长上均表现最优,尤其是当时间步长延长时,其预测精度的优势更为显著。






图9 模型预测效果对比

Fig. 9 Model prediction effect comparison diagram

表5 不同时间步长模型预测精度对比

Tab.5 Algorithm parameter table

模型结构	MAE(1,5,7)			RMSE(1,5,7)		
LSTM ^[9]	0.2545	0.3309	0.3956	0.2845	0.4351	0.4956
GRU ^[10]	0.2589	0.3504	0.4015	0.3104	0.4527	0.5046
SVR ^[6]	0.3145	0.4908	0.6804	0.4112	0.6096	0.8063
EMD-LSTM ^[16]	0.0865	0.2012	0.2735	0.1187	0.2491	0.3045
EMD-GRU ^[16]	0.1448	0.2531	0.2965	0.1654	0.2977	0.3425
STL-GRU ^[15]	0.1856	0.2891	0.3623	0.2340	0.3995	0.4621
STL-LSTM ^[15]	0.1364	0.2694	0.2954	0.1854	0.3518	0.3845
CNN-LSTM	0.1744	0.2788	0.3274	0.2177	0.3860	0.4234
VMD-CNN-LSTM	0.0545	0.1261	0.1645	0.0886	0.1607	0.2316

3 结论

(1) 本文提出了结合 VMD 分解算法的 CNN-LSTM 组合预测模型。为减少噪声对于模型预测的影响, 本文对初始 SST 的时间序列进行 VMD 分解, 采用 CNN-LSTM 算法对分解的多个模态分量进行特征提取, 以加快模型的收敛速度, 提高预测精度。

(2) 以我国东海海域的海温为例, 对模型采

用不同时间步长和不同标记点进行验证。结果表明, 本文模型的预测精度优于其他模型, 在时间和空间上具有很好的鲁棒性。

参考文献:

- [1] 王利亚. 海表面温度对热带气旋的影响[J]. 集成电路应用, 2021, 38(4): 182-183.
- [2] 周倩, 凌铁军, 李响, 等. 中国周边海域海面温度日变化对区域气候的影响[J]. 气候与环境研究, 2019, 24(2): 214-226.
- [3] 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.
- [4] 张绪东, 张苑伦, 李云波. 北黄海海温分布变化的数值模拟分析[J]. 海洋预报, 2015, 32(5): 89-97.
- [5] 张玉荣. 大连附近海域幼鲍安全越冬海水温度预报方法的研究[J]. 海洋环境科学, 1992, 11(1): 34-38.
- [6] LINS I D, ARAUJO M, DAS CHAGASMOURA M, et al. Prediction of sea surface temperature in the tropical Atlantic by support vector machines[J]. Computational Statistics & Data Analysis, 2013, 61: 187-198.
- [7] PATIL K, DEO M C. Basin-Scale prediction of sea surface temperature with artificial neural networks[J]. Journal of Atmospheric and Oceanic Technology, 2018, 35(7): 1441-1455.
- [8] WEI L, GUAN L, QU L Q. Prediction of sea surface temperature in the south China sea by artificial neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(4): 558-562.
- [9] 朱贵重, 胡松. 基于 LSTM-RNN 的海表面温度模型研究[J]. 应用海洋学报, 2019, 38(2): 191-197.
- [10] ZHANG Z, PAN X L, JIANG T, et al. Monthly and quarterly sea surface temperature prediction based on gated recurrent unit neural network[J]. Journal of Marine Science and Engineering, 2020, 8(4): 249.
- [11] XU H F, CHAI L, LUO Z M, et al. Stock movement predictive network via incorporative attention mechanisms based on tweet and historical prices[J]. Neurocomputing, 2020, 418: 326-339.
- [12] XIAO C J, CHEN N C, HU C L, et al. Short and mid-term sea surface temperature prediction using time-series satellite data and LSTM-AdaBoost combination approach[J]. Remote Sensing of Environment, 2019, 233: 111358.
- [13] XIAO C J, CHEN N C, HU C L, et al. A spatiotemporal deep learning model for sea surface temperature field prediction using time-series satellite data[J]. Environmental Modelling & Software, 2019, 120: 104502.
- [14] 程泽梅. 1960~2013 年华南沿海 SST 变化特征的相关分析[D]. 青岛: 中国海洋大学, 2015: 20-23.
- [15] 贺琪, 查铖, 宋巍, 等. 基于 STL 的海表面温度预测算法[J]. 海洋环境科学, 2020, 39(6): 918-925.
- [16] 贺琪, 胡泽煜, 徐慧芳, 等. 基于经验模态分解-门控循环模型的海表温度预测方法[J]. 激光与光电子学进展, 2021, 58(24): 2415005.