

激光与光电子学进展

基于变分模态分解-长短时记忆网络-宽度学习系统混合模型的东海海温预测

韩莹¹, 孙凯强¹, 闫加宁¹, 董昌明^{2*}¹南京信息工程大学自动化学院, 江苏 南京 210044;²南京信息工程大学海洋科学学院, 江苏 南京 210044

摘要 海表温度(SST)是重要的海洋水文参数。对其进行精准预测在海洋相关领域中至关重要。深度学习强大的分析能力使其近年来广泛应用于 SST 预测中,但 SST 时间序列波动性和随机性的特点使其精准预测仍然具有挑战性。首先,采用变分模态分解(VMD)作为去噪模块,降低 SST 序列噪声对预测结果的影响。进而,为了解决深度模型在 SST 预测中存在的滞后现象,采用迁移学习的方法,将长短时记忆网络(LSTM)与宽度学习系统(BLS)相结合,使用 LSTM 作为 BLS 的特征映射结点,提高了预测精度。最终,提出了一种基于 VMD-LSTM-BLS 的 SST 预测模型。选取我国东海海温进行实例验证。通过与基准模型支持向量机、LSTM、门控循环单元以及现有的深度模型进行比较,证明了提出模型在 SST 预测中具有相对稳定、高效的优势,为 SST 预测的发展提供了新思路。

关键词 大气光学与海洋光学; 海表温度; 变分模态分解; 长短时记忆网络; 宽度学习系统

中图分类号 P731.3

文献标志码 A

DOI: 10.3788/LOP213371

Surface Temperature Prediction of East China Sea Based on Variational Mode Decomposition-Long-Short Term Memory-Broad Learning System Hybrid Model

Han Ying¹, Sun Kaiqiang¹, Yan jianing¹, Dong Changming^{2*}¹*School of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, Jiangsu, China;*²*School of Marine Science, Nanjing University of Information Science and Technology, Nanjing 210044, Jiangsu, China*

Abstract Sea surface temperature (SST) is an important marine hydrologic parameter, and its accurate prediction is critical in marine-related fields. Deep learning has been widely and increasingly used for SST prediction in recent years because of its strong analytical ability. However, the volatility and randomness of SST time series still constitute a challenge for accurate prediction. In this study, variational mode decomposition (VMD) is first introduced as a denoising module to reduce the influence of SST sequence noise on the prediction results. Then, to solve the lag phenomenon of depth models in SST prediction, the method of transfer learning is adopted to combine the concepts of long-short term memory (LSTM) and broad learning system (BLS). LSTM is used as the feature mapping node of BLS to improve the prediction accuracy. As a result, an SST prediction model based on VMD, LSTM, and BLS is proposed. The SST of the East China Sea is selected as an example for verification. By comparing with benchmark models, support vector regression (SVR), LSTM, gate recurrent unit (GRU), and existing deep models, it is shown that the proposed model is relatively stable and efficient in SST prediction, which provides a new idea for the development of SST prediction.

Key words atmospheric optics and ocean optics; sea surface temperature; variational modal decomposition; long-short term memory network; broad learning system

收稿日期: 2021-12-28; 修回日期: 2022-01-25; 录用日期: 2022-01-28; 网络首发日期: 2022-02-17

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

通信作者: *cmdong@nuist.edu.cn

1 引言

海洋约占地球表面积的 7/10,其热能变化在调节全球气候和生态系统方面发挥着至关重要的作用。海表温度(SST)是衡量海洋热能的一个重要参数。研究表明,SST与陆地的炎热天气息息相关^[1],并且对季节性气候预测^[2]和海产养殖^[3]也有重要影响。SST预测不仅能使人类更好地了解全球气候和海洋生态系统,而且还是海洋相关应用的重要组成部分。因此,实现SST准确预测具有重大意义。

一般来说,SST的预测方法主要有两大类^[4]:一类是数值预报方法;另一类是数据驱动方法。前者利用动力学和热力学方程建立预测模型^[5],但计算复杂且预测精度有限。后者使用统计方法从数据中学习特征和规律,从而实现准确预测。此外,支持向量机(SVR)^[6]、人工神经网络^[7]、多层感知机^[8]等机器学习算法也被广泛应用于SST预测中。然而,传统机器学习方法在特征筛选方面耗时多,且在数据量大时表现不佳,具有一定局限性。

近些年,基于深度学习的方法在SST预测中成为研究热点,长短时记忆网络(LSTM)^[9]和门控循环单元(GRU)^[10]广泛应用在SST预测中。Yang等^[11]将时间与空间信息相结合,提出了一个基于卷积和全连接的长短时记忆网络(CFCC-LSTM)模型对未来海温进行预测。Zhang等^[12]使用多层卷积LSTM模型来预测三维海洋温度。Xiao等^[13]构建了LSTM与自适应提升算法(AdaBoost)的组合模型,对我国东海海域取点进行预测。上述方法将循环神经网络与其他模型相结合,克服了单一模型学习能力弱的局限性,提高了预测精度。但在数据方面受到很大限制,很难完整获取预测地区的空间数据和其他气候数据,仍具有一定局限性。

一方面考虑到获取完整的多特征数据困难,另一方面考虑到SST的非线性、多噪声特点^[14]。Lin等^[15]提出了多通道的长短时记忆网络(MC-LSTM)预测模型,采用小波分解的方法,将分解后代表趋势、周期和扰动的多个序列,输送到并行的LSTM模型中训练,提高了预测精度。贺琪等^[16]通过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(STL)对SST序列进行预处理来提高预测精度。此外,贺琪等^[17]引入消除噪声的数据预处理模块,通过经验模态分解(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。但由于分解模态过多,会导致最终的预测精度降低。

此外,深度学习网络通过增加隐藏层的个数,不断深化网络结构,从而实现目标值的逼近。但随着网络加深,参数过多、训练速度慢、易陷入局部最优等问题逐渐产生。宽度学习系统(BLS)^[18]将网络由深度方向

向宽度方向转变,在不增加网络层数的基础上,通过多次非线性变换,提取抽象且丰富的特征,提高了网络的运行速度和精度。

综上,考虑到SST序列的时空特性和噪声影响,本文首先采用变分模态分解(VMD)进行数据预处理,将初始SST序列进行分解,通过控制带宽抑制了EMD模态混叠的现象。且VMD分解可以选择模态分解个数,极大降低了噪声的影响。接着采用LSTM对分解后的各子序列进行特征提取,然后通过BLS进行预测,解决了预测滞后的现象,最终将各分量预测结果加权求和。选取我国东海海域进行验证,将提出的VMD-LSTM-BLS模型分别与基线模型和现有模型对比验证。结果表明,在选取的平均绝对误差(MAE)和均方根误差(RMSE)评价指标上本文模型表现最佳。且在不同时间步长下,亦优于其他模型,具有很好的鲁棒性。

2 模型结构

2.1 VMD模型

VMD是一种完全非递归的模态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可以确定模态分解的个数,并自适应地搜寻每种模态的最佳中心频率和有限带宽,实现固有模态分量(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,原理如式(1)~(8)所示^[19],具体步骤如下。

1) 构造变分问题。

$$x(t) = \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \exp(-j\omega_k t), \quad (1)$$

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

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

式(1)和式(2)是关于 $\{u_k\}$ 、 $\{\omega_k\}$ 的多元函数,式(3)为各模态的约束条件。式中: f 是初始信号; K 是分解模态的个数; $\{u_k\}$ 和 $\{\omega_k\}$ 是分解后的第 k 个模态分量和中心频率; $\delta(t)$ 为狄拉克函数;*为卷积运算。

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,引入增广拉格朗日函数,将构造的约束变分问题转化为非约束变分问题,得到增广拉格朗日表达式为

$$g(t) = \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle, \quad (4)$$

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t x(t) \right\|_2^2 + g(t), \quad (5)$$

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,优化得到各模态分量和中心频率,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 的表达式为

$$\hat{u}_k^{n+1}(\omega) \leftarrow \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2}, \quad (6)$$

$$\omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega}, \quad (7)$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + r \left[\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right], \quad (8)$$

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

2.2 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, 实现学习长期特征。图 1 为 LSTM 的结构图。其中, X_t 、 h_{t-1} 为 t 时刻的输入值和 $t-1$ 时刻的输出值, 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(9)~(14)^[20]所示:

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f), \quad (9)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i), \quad (10)$$

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

$$C_{t1} = \tanh(W_c \cdot [h_{t-1}, X_t] + b_c), \quad (12)$$




图 2 BLS 结构图

Fig. 2 BLS structure diagram

$$Z_i = \varphi(XW_{ei} + \beta_{ei}), i = 1, \dots, n, \quad (15)$$

$$E_j = \zeta(z_n W_{hj} + \beta_{hj}), j = 1, \dots, m, \quad (16)$$

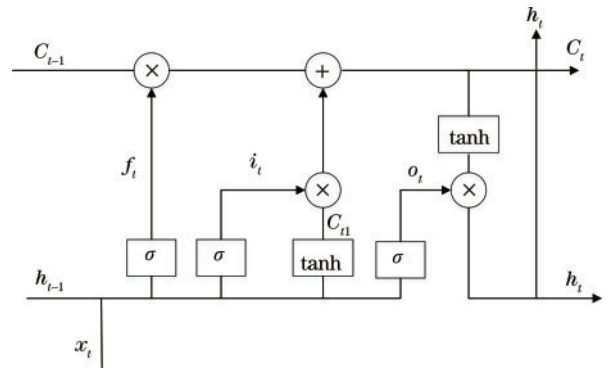


图 1 LSTM 结构图

Fig. 1 Structure diagram of LSTM

$$C_t = C_{t-1} \otimes f_t + i_t \otimes C_{t1}, \quad (13)$$

$$h_t = o_t \otimes \tanh(C_t), \quad (14)$$

式中: W_f 、 W_i 、 W_o 、 W_c 分别为遗忘门、输入门、输出门、细胞状态候选值的权重; b_f 、 b_i 、 b_o 、 b_c 、 f_t 、 i_t 、 o_t 、 C_{t1} 分别为对应的偏置和输出值; σ 为激活函数 Sigmoid; \otimes 是矩阵的 Hadamard 积; C_{t-1} 为 $t-1$ 时刻细胞状态; 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。

2.3 BLS 原理

BLS 针对深度学习易陷入局部最优的缺点, 将模型结构展宽, 实现模型运行速度和预测精度的提高, 并且提供了很好的泛化能力。图 2 为 BLS 的结构图, 原理如式(15)~(17)^[21]所示。BLS 首先通过式(15)建立输入数据到特征结点的映射, 经过激活函数非线性变换后, 得到的特征节点表示为 $z_n = [Z_1, \dots, Z_n]$, 接着通过式(16)生成增强节点 $e_m = [E_1, \dots, E_m]$, 其中 n 表示特征节点的窗口个数, m 表示增强节点的个数, 最后通过式(17)输出预测结果。

$$Y = [Z_1, \dots, Z_n | E_1, \dots, E_m] W = [z_n | e_m] W = HW, \quad (17)$$

式中: W_{ei} 、 W_{hj} 和 β_{ei} 、 β_{hj} 是随机生成的权重和偏置; φ 和

ζ 是激活函数; H 是输入特征; W 为输出权重。

2.4 迁移学习

迁移学习方法就是把为任务 A 开发的模型作为初始点, 重新使用在为任务 B 开发模型过程中的方法。考虑到 BLS 的输入权重和偏置是随机生成的, 输出权重是计算求解得出的, 而深度学习的权重是经过反向传播迭代更新的, 因此无法直接结合进行训练。故采

用迁移学习的方法, 通过深度学习学习特征, 通过宽度学习进行预测。

2.5 VMD-LSTM-BLS 模型

考虑到初始 SST 序列的非线性、多噪声特点, 本文采用 VMD 模块进行数据预处理, 并将深度学习与宽度学习相结合, 解决了深度学习模型预测滞后的现象。图 3 为模型整体框架图。

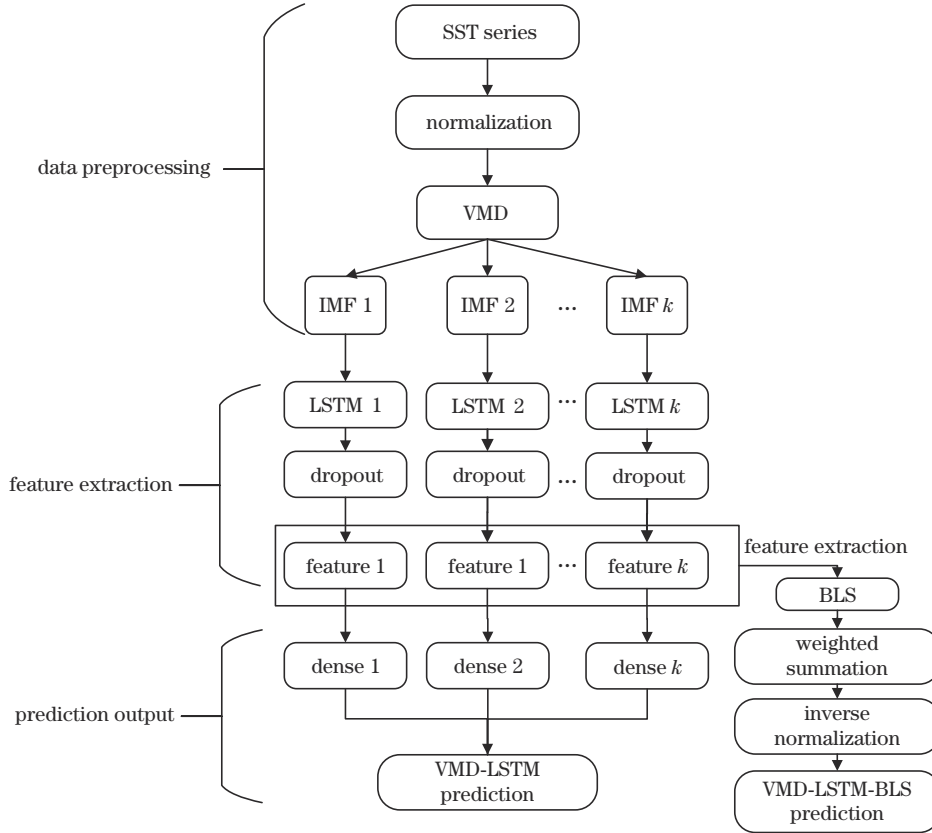


图 3 VMD-LSTM-BLS 模型整体框架图

Fig. 3 Overall framework of VMD-LSTM-BLS model

其中本文模型包含 3 部分:

1) 数据预处理模块。对初始的 SST 序列, 进行归一化操作, 加速收敛。通过 VMD 分解获取不同频率的子序列, 使得序列变得平滑, 减少噪声影响。

2) 特征提取模块。将预处理的数据进行特征学习, 并通过 dropout 策略, 减少过拟合。

3) 预测输出模块。包含 dense 和 BLS 两个预测模块, 其中 BLS 克服了深度学习的缺点, 具有运行速度快、预测精度高的优点。通过加权求和和反归一操作, 最终输出模型预测结果。

具体的步骤如下:

1) 原始的 SST 时间序列大小为 $M \times Q$, 其中 M 为样本数量, Q 为标记点个数, 每次仅将一处标记点进行训练。利用式 (18) 对每处标记点 SST 序列进行归一化操作。

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (18)$$

2) 将归一化的 SST 序列进行 VMD 分解, 分解为 k 个 $M \times \tau \times D$ 的时间序列, 其中 τ 为时间步长, D 为标记点特征个数。

3) 通过并行的 LSTM 模块对分解后的 k 个模态分量进行特征提取, 并采用 dropout 进行优化, 最终得到 k 个特征序列。

4) 利用提取的特征序列, 通过 dense 层对各子序列进行预测, 最终得到训练好的 VMD-LSTM 模型。

5) 基于迁移学习, 提取 VMD-LSTM 模型训练出的特征序列作为 BLS 的输入, 即将 LSTM 与 BLS 相承接, 通过 BLS 进行预测。

6) 将各序列的预测结果加权求和并反归一, 最终得到 VMD-LSTM-BLS 模型预测结果。

模型的主要参数如表 1 所示。其中, Layers 为隐藏层层数, Neurons 为隐藏层神经元个数, N1 为每个窗口特征结点的个数, N2 为特征结点的窗口个数, N3 为增强结点的个数。

表1 算法参数
Table 1 Algorithm parameters

Model	Parameter	Value
VMD	k	3
	Alpha	1
	Tol	10^{-6}
LSTM	Layers	3
	Neurous	{64, 32, 16}
Dropout	P	0.2
	S	0.9
BLS	C	10^{-4}
	N1, N2, N3	{16, 30, 280}
Dense	Layers	2
	Neurous	{10, 1}
	Batch_size	128
	Epoch	300

3 分析与讨论

3.1 数据描述和评价指标

本文的研究区域是中国东海(23°00'N-33°10'N, 117°11'E-131°00'E), 区域选取了 5 个代表性的地点 [分别标记为 T1(32.13°N, 122.87°E)、T2(31.87°N, 127.93°E)、T3(31.07°N, 124.93°E)、T4(28.13°N, 127.65°E)、T5(26.7°N, 122.13°E)] 进行研究分析, 其

中, T1、T5 靠近内陆海岸, 温度变化幅度最大, T2、T4 靠近岛屿, T3 处于海域中央。本文采用分辨率为 9 km 的微波红外海温数据, 数据可在网站 www.remss.com 上获得。其中数据包含了 2002 年 6 月 1 日到 2020 年 12 月 31 日每日的 SST 数据。每个标记点包含了 6780 天的海温数据, 将前 80% 的数据作为训练集, 后 20% 作为测试集, 并以时间步长为 5 进行预测。

$$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_i - x_i|, \quad (19)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2}, \quad (20)$$

采用 e_{MAE} 和 e_{RMSE} 作为评价指标, 对模型的预测误差和精度进行评价, 其中, y_i 为预测值, x_i 为初始值, N 为样本个数。

3.2 VMD 分解模块分析

对初始 SST 序列归一化后, 采用 VMD 分解进行数据处理, 以 T1 标记点为例, 图 4 为 VMD 分解图。最终将原始海温序列分解为 3 个模态分量, 其中 IMF0 表示季节变化趋势, IMF1 表示误差项, IMF2 表示趋势变化。从图中可以看出, 原始海温序列具有明显的周期性特征, 但在波峰和波谷处存在大量噪声, 温度波动较大, 所以直接对原始序列进行预测会导致精度降低。故采用 VMD 分解的方法, 凸显序列特征, 从而提高模型的预测效果。




图4 T1 标记点的 VMD 分解图

Fig. 4 VMD decomposition diagram of mark point T1

图 5~7 分别是 VMD 分解后各模态分量测试集的拟合效果图, 从图中可以清晰地看出, 模型对于低频分量, 即季节变化趋势具有较好的预测效果。对于误差分量和趋势分量也能基本拟合, 但分量波动剧烈, 仅能预测出变化趋势, 无法精确预测出变化幅值, 存在一定误差。

3.3 与基线模型对比

为了验证本文模型的有效性, 对选取的 5 个标记点进行验证, 首先与传统的基线模型 SVR、LSTM、GRU 进行比较, 以 5 天时间步长进行预测, 图 8 为本文模型与基线模型的对比结果图。从图中可以清晰地看出, SVR 模型的 MAE 值和 RMSE 值均为最高, 模型表




图 5 IMF0 测试集拟合图
Fig. 5 IMF0 test set fitting diagram




图 6 IMF1 测试集拟合图
Fig. 6 IMF1 test set fitting diagram




图 7 IMF2 测试集拟合图
Fig. 7 IMF2 test set fitting diagram

现最差, LSTM 模型和 GRU 模型预测精度相近, 但 LSTM 模型略优于 GRU 模型。本文提出的 VMD-LSTM-BLS 模型效果最好, 以 T1 标记点为例, 其 MAE 值比 SVR、LSTM、GRU 分别减少了 85.18%、

78.09%、79.25%, RMSE 值分别减少了 84.30%、78.01%、78.86%, 预测结果明显优于传统模型。

接着选取 5 天时间步长, 将 T1 点的模型预测值进行可视化操作, 并与基线模型 LSTM 进行对比验证,

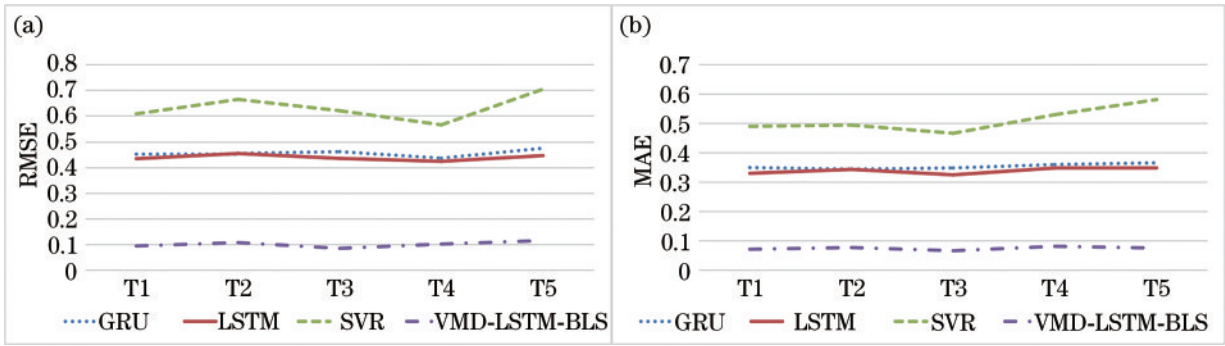


图 8 与基线模型对比结果图。(a)RMSE;(b)MAE

Fig. 8 Comparison result graph with baseline models. (a) RMSE; (b) MAE

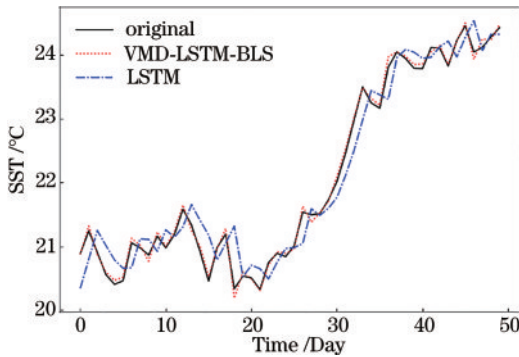


图 9 SST 拟合效果对比图

Fig. 9 Comparison diagram of SST fitting effect

图 9 为本文模型的海温拟合效果对比图。从图中可以看出,相较于真实海温序列,LSTM 的预测曲线在图

中略微向右偏移,具有滞后性。而本文模型的预测曲线可以很好地契合真实值,滞后程度较低,且在评价指标上仍具有较好表现。

3.4 与消融模型对比

进一步,选取 5 天时间步长对 5 个标记点进行验证,将本文模型与其消融模型进行比较,图 10 为本文模型与消融模型对比结果图。从图中可以看出,本文模型的 MAE 和 RMSE 指标均表现最优,消融模型 LSTM-BLS 表现最差。由 VMD-LSTM 模型与 LSTM-BLS 模型比较可知,通过 VMD 分解进行序列处理,极大减小了模型的预测误差。此外,与 VMD-LSTM 模型对比可知,本文模型在 T1 点的 MAE 值和 RMSE 值分别减小了 37.65% 和 33.36%,证明了 BLS 模块预测的有效性和准确性。




图 10 与消融模型对比结果图。(a)MAE;(b)RMSE

Fig. 10 Comparison result graph with ablation models. (a) MAE; (b) RMSE

3.5 与现有模型对比

最后,选取 5 天时间步长,将本文模型与现有模型 STL-LSTM、MC-LSTM、EMD-LSTM 在 5 个标记点进行比较,对比结果如表 2 所示。相较于单一的 LSTM,现有模型均有一定的提升,在 T1 点处其 MAE 值分别减少了 18.59%、22.18%、39.19%,RMSE 值分别减少了 19.15%、26.33%、42.75%,现有模型中 EMD-LSTM 表现最佳,STL-LSTM 表现最差。相较于现有模型,本文模型 VMD-LSTM-BLS 采用自适应信号处理模块,并采用 BLS 向目标值逼近,其 MAE 值分别减少了 73.14%、71.77%、63.87%,RMSE 值分

别减少了 72.79%、70.23%、61.58%,在两个评价指标上均为最优,证明了本文模型的优越性。

3.6 不同时间步长预测效果分析

此外为了证明本文模型的稳定性,对 T1 点采用 1 天和 7 天的时间步长进行补充验证,表 3 为不同时间步长下模型的预测精度。从表中可以清晰地看出,随着时间步长的增加,大多数模型的预测误差会逐渐提高,但本文模型在 7 天时间步长下的预测误差反而有所下降,与其他模型相比预测精度提高更为显著。总体而言,本文模型在不同时间步长下仍有较好表现,具有较好的鲁棒性。

表 2 与现有模型的精度比较
Table 2 Accuracy comparison with existing models

Model	Metrics	T1	T2	T3	T4	T5
STL-LSTM	MAE	0.2694	0.2772	0.2909	0.2870	0.2647
	RMSE	0.3518	0.3588	0.3678	0.3345	0.3240
EMD-LSTM	MAE	0.2012	0.2130	0.1988	0.2136	0.1823
	RMSE	0.2491	0.2612	0.2439	0.2564	0.2349
MC-LSTM	MAE	0.2575	0.2645	0.2472	0.2578	0.2524
	RMSE	0.3215	0.3264	0.3124	0.3278	0.3164
VMD-LSTM-BLS	MAE	0.0727	0.0784	0.0676	0.0826	0.0766
	RMSE	0.0957	0.1089	0.0864	0.1032	0.1166

表 3 不同时间步长模型预测精度对比
Table 3 Comparison of prediction accuracy of models with different time steps

Model	MAE (1,5,7)			RMSE (1,5,7)		
LSTM	0.2545	0.3309	0.3956	0.2845	0.4351	0.4956
GRU	0.2589	0.3504	0.4015	0.3104	0.4527	0.5046
SVR	0.3145	0.4908	0.6804	0.4112	0.6096	0.8063
EMD-LSTM	0.0865	0.2012	0.2735	0.1187	0.2491	0.3045
STL-LSTM	0.1364	0.2694	0.2954	0.1854	0.3518	0.3845
MC-LSTM	0.2036	0.2575	0.2978	0.2342	0.3215	0.3521
VMD-LSTM	0.0627	0.1166	0.1709	0.0854	0.1436	0.1963
LSTM-BLS	0.2366	0.2785	0.3587	0.2688	0.3847	0.4423
VMD-LSTM-BLS	0.0457	0.0727	0.0669	0.0742	0.0957	0.0885

4 结 论

SST 对海洋气候变化和海上航行等活动有重要影响,针对 SST 序列非平稳和多噪声的特性,本文提出了一种基于 VMD-LSTM-BLS 的模型,利用 VMD 分解使序列平稳,降低噪声影响,通过 LSTM 进行特征挖掘,采用 BLS 加快收敛速度和预测精度。

为了证明模型的有效性,对我国东海海域进行抽样验证,首先通过基线模型 LSTM、GRU、SVR 进行预测,结果表明深度学习模型优于机器学习模型,且 LSTM 的预测精度略优于 GRU。接着训练 VMD-LSTM 模型,与采用其他分解方法的模型相比,模型预测精度得到提升,但仍无法摆脱深度模型预测滞后的现象,于是引入宽度学习,将 VMD-LSTM 模型学习到的特征输送到 BLS 进行预测,最终得到的模型的效果在 VMD-LSTM 的基础上又取得大幅提高,明显优于现有模型,且在不同时间步长下仍具有有效性和稳定性。

本文采用了新的信号分解方法和预测模块,可以准确地对 SST 进行预测。此外,对于其他复杂的时间序列,模型也同样具有适用性。未来将会融合多因素特征,采用多尺度特征提取模块,剖析深层时空特性,实现精准预测。

参 考 文 献

- [1] McKinnon K A, Rhines A, Tingley M P, et al. Long-lead predictions of eastern United States hot days from Pacific Sea surface temperatures[J]. *Nature Geoscience*, 2016, 9(5): 389-394.
- [2] Sun X, Zhang M, Dong J Y, et al. A deep framework for eddy detection and tracking from satellite sea surface height data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7224-7234.
- [3] Muhling B A, Tommasi D, Ohshimo S, et al. Regional-scale surface temperature variability allows prediction of Pacific bluefin tuna recruitment[J]. *ICES Journal of Marine Science*, 2018, 75(4): 1341-1352.
- [4] 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.
- [5] 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.
Zhang X D, Zhang W L, Li Y B. Characteristics of the sea temperature in the North Yellow Sea[J]. *Marine Forecasts*, 2015, 32(5): 89-97.
- [6] Lins I D, Araujo M, Moura M D C, 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] Wie L, Guan L, Qu L Q, et al. Prediction of sea surface temperature in the South China sea by artificial neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 17(4): 558-562.
- [9] 朱贵重, 胡松. 基于 LSTM-RNN 的海水表面温度模型研究[J]. *应用海洋学报*, 2019, 38(2): 191-197.
Zhu G Z, Hu S. Study on sea surface temperature model based on LSTM-RNN[J]. *Journal of Applied Oceanography*, 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] Yang Y T, Dong J Y, Sun X, et al. A CFCC-LSTM model for sea surface temperature prediction[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(2): 207-211.
- [12] Zhang K, Geng X P, Yan X H. Prediction of 3-D ocean temperature by multilayer convolutional LSTM[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(8): 1303-1307.
- [13] 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.
- [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.
Cheng Z M. The characteristics and influencing factors of SST variation along the South China coast during the period 1960-2013[D]. Qingdao: Ocean University of China, 2015: 20-23.
- [15] Lin Y D, Zhong G Q. A multi-channel LSTM model for sea surface temperature prediction[J]. *Journal of Physics: Conference Series*, 2021, 1880(1): 012029.
- [16] 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.
He Q, Zha C, Song W, et al. Sea surface temperature prediction algorithm based on STL model[J]. *Marine Environmental Science*, 2020, 39(6): 918-925.
- [17] 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.
He Q, Hu Z Y, Xu H F, et al. Sea surface temperature prediction method based on empirical mode decomposition-gated recurrent unit model[J]. *Laser & Optoelectronics Progress*, 2021, 58(24): 2415005.
- [18] Chen C L P, Liu Z L, Feng S. Universal approximation capability of broad learning system and its structural variations[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(4): 1191-1204.
- [19] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [20] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [21] Chen C L P, Liu Z L. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(1): 10-24.