

基于经验模态分解-门控循环模型的海表温度预测方法

贺琪¹, 胡泽煜¹, 徐慧芳^{1,2*}, 宋巍¹, 杜艳玲¹¹上海海洋大学信息学院, 上海 201306;²上海建桥学院信息技术学院, 上海 201306

摘要 海表温度(SST)是平衡地表能量及衡量海水热量的重要指标, SST 的高精度预测对全球气候、海洋环境及渔业具有重要意义。极端气候条件下, SST 序列呈现明显的非平稳性, 传统方法进行海表温度预测(SSTP)时难度大, 且精度较低。基于经验模态分解(EMD)算法分解后的 SST 子序列非平稳性明显降低, 且门控循环(GRU)神经网络作为一种常见的机器学习预测模型, 参数较少、收敛速度更快, 不易在训练过程中出现过拟合现象。结合 EMD 模型和 GRU 模型的优势, 提出了一种基于 EMD-GRU 的 SST 预测模型。为验证所提模型预测效果, 对 5 条不同长度的 SST 序列进行了多组对比实验。实验结果表明: 与直接使用循环神经网络(RNN)、长短期记忆模型(LSTM)、门控循环神经网络(GRU)的模型相比, 所提模型预测结果的多尺度复杂度更低; 所提模型预测结果的均方差(MSE)和平均绝对误差(MAE)均有不同程度的降低。为验证数据序列长度对预测精度的影响, 设计了补充实验。实验结果表明: 预测长度越长精度效果越差; 通过 EMD 算法对序列进行处理后, 效果均得到了提升, 且在预测长度变长的情况下, 效果提升较为明显。

关键词 机器视觉; 海表面温度序列; 海表温度预测; 经验模态分解算法; 门控循环神经网络

中图分类号 TP302.1

文献标识码 A

doi: 10.3788/LOP202158.2415005

Sea Surface Temperature Prediction Method Based on Empirical Mode Decomposition-Gated Recurrent Unit Model

He Qi¹, Hu Zeyu¹, Xu Huifang^{1,2*}, Song Wei¹, Du YanLin¹¹College of Information Technology, Shanghai Ocean University, Shanghai 201306, China;²College of Information Technology, Shanghai Jian Qiao University, Shanghai 201306, China

Abstract Sea surface temperature (SST) is an important indicator for balancing the surface energy and measuring the sea heat, the high-precision prediction of SST is of great significance to global climate, marine environment, and fisheries. Under extreme climatic conditions, the SST sequence presents obvious non-stationarity, traditional methods are difficult to predict sea surface temperature (SSTP) and have low accuracy. The non-stationarity of the SST subsequence decomposed based on the empirical mode decomposition (EMD) algorithm is significantly reduced, and the gated recurrent unit (GRU) neural network, as a common machine learning prediction model, has fewer parameters and faster convergence speed, so it is not easy to over fit in the training process. Combining the advantages of the EMD model and the GRU model, a SST prediction model based on EMD-GRU is proposed. In order to verify the prediction effect of the proposed model, several groups of comparative experiments were carried out on five SST sequences with different lengths. Experimental results show that the multi-scale complexity of the prediction results of the proposed model is lower in comparison with directing application of recurrent neural network (RNN), long-short term memory (LSTM), and GRU models, and the mean square error (MSE) and mean absolute error (MAE) of the prediction results of the proposed model have been reduced. In order to verify the

收稿日期: 2021-01-18; 修回日期: 2021-02-18; 录用日期: 2021-03-08

基金项目: 上海市教育发展基金(AASH2004)、上海市科委地方能力建设项目(20050501900)、海洋大数据分析预报技术研发基金(2016YFC1401902)

通信作者: *17069@gench.edu.cn

influence of data sequence length on prediction accuracy, a supplementary experiment is designed. The longer the prediction length, the worse the accuracy effect; after the sequence is processed by EMD algorithm, the effect is improved, and the effect is improved obviously when the prediction length becomes longer.

Key words machine vision; sea surface temperature sequence; sea surface temperature prediction; empirical mode decomposition algorithm; gated recurrent unit neural network

OCIS codes 150.1135; 100.3008; 100.5010; 100.4996

1 引言

海表面温度(SST)作为平衡地表能量及衡量海水热量的重要指标,对海洋气候及生态系统的改变有着重大的影响。研究表明 SST 异常与多种极端海洋气候及自然灾害,例如厄尔尼诺、娜尼拉以及赤潮等具有密切的关系。因此,深度挖掘 SST 变化规律,完成 SST 准确预测是进行安全海洋作业、航海及海洋防灾减灾的关键^[1]。

目前 SST 预测已取得很多研究成果,常用方法主要分为数值模型和数据驱动模型两种类型。数值模型主要基于物理、化学以及海洋中的一些重要指标及这些指标之间复杂的相互作用来建立数学模型,来描述和拟合 SST 的变化规律,并按照规律来对 SST 进行预测^[2]。该类模型适用于相对较低分辨率的 SST 数据,且鲁棒性较差。针对不同海域 SST,往往需要重新对海域进行建模分析,计算量较大,精度低。数据驱动模型方法是从现有的 SST 数据中挖掘,获取 SST 的变化规律并进行预测。相比于数值模型,该类模型不需要研究者具备丰富的海洋以及气象知识,且能够对高分辨率的 SST 数据进行预测,但仅限于在较小尺度上进行。数据驱动模型包含了传统的统计方法、线性预测模型以及深度学习方法。传统的线性预测模型,例如自回归模型(AR)、滑动平均模型(MA)以及自回归滑动模型^[3]等在时间序列的预测上并不能够满足实际应用的需求。随着深度学习在自然语言处理、股票预测、图像处理及目标检测等领域的广泛应用,基于深度学习的方法进行 SST 预测成为目前研究的热点,并呈现出预测精度高、鲁棒性较好的优势。Aparna 等^[4]提出了一种人工神经网络(ANN)对阿拉伯海东北部的 SST 进行预报,预报模型平均绝对误差(MAE)不超过 $\pm 0.5^{\circ}\text{C}$ 。由于 SST 序列是一种典型的长时间序列,循环神经网络(RNN)可以更好地捕捉到 SST 序列上的时间特征。由于 RNN 具有“梯度消失”等不足之处^[5],综合考虑 LSTM 的循环特性,Zhang 等^[6]基于长短期记忆模型(LSTM)对 SST 进行建模,并利用全连接层将 LSTM 层的输出映射

到最终的预报结果中,很好地捕捉到数据在时间维度上的特征。除神经网络之外,支持向量机(SVM)也被用于 SST 预报。

受极端气候及监测设备的影响,SST 序列呈现非平稳性,并存在一定的误差,尤其是一些特殊气候条件下的 SST 序列,非平稳性效果更为明显。传统的基于数值和数据驱动方法挖掘 SST 变化变化规律及有效地分析预测难度大,且精度低。经验模态分解(EMD)作为一种典型的波分解算法,由 Huang 等^[7]于 1998 年提出,该算法可以将原始 SST 序列分解为若干个本征模函数(imf)以及一个剩余分量之和(res)子序列,降低数据的非平稳性。EMD 算法的分解过程不需要设定任何基函数,可按照自身的时间尺度特征进行分解,可以处理任何领域和类型的信号,尤其适用于处理非线性和非平稳的信号。而门控循环(GRU)神经网络作为一种常见的机器学习预测模型,基于 LSTM 改进得到,训练过程更加容易^[8],拟合速度更快,且更不容易产生过拟合。

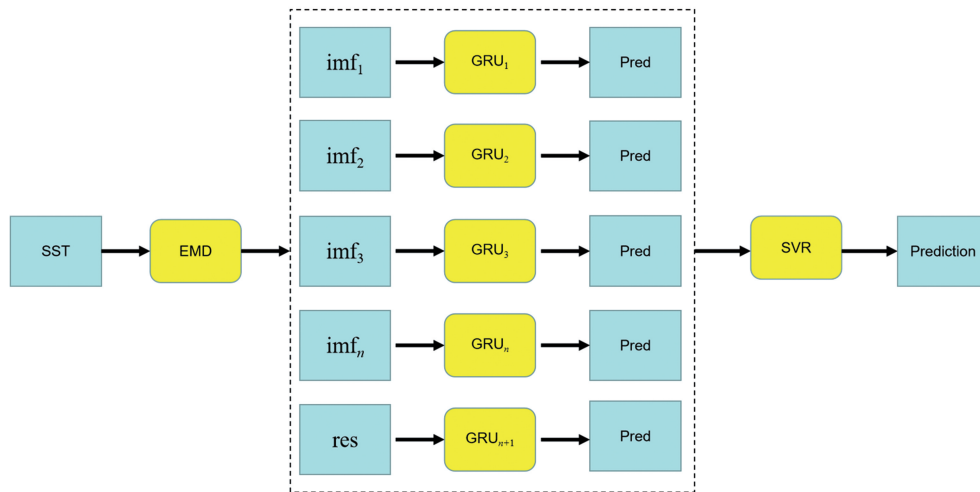
基于以上考虑,本文综合运用 EMD 和 GRU 神经网络优势,提出一种基于 EMD-GRU 的海面温度预测模型。首先使用 EMD 对 SST 序列进行分解处理,降低 SST 的非平稳性,再将处理得到的子序列分别输入 RNN、LSTM 和 GRU 网络进行实验,对预测结果与利用原始序列直接输入 3 种神经网络的预测精度进行对比。实验结果表明,所提 EMD-GRU 模型效果最优,与单一神经网络预测模型相比,均方差(MSE)与 MAE 均得到了一定程度的降低。

2 EMD-GRU 预测方法

SST 序列是由若干个温度数据($T_1, T_2, T_3, \dots, T_n$)组成的一组时间序列,在很多情况下,SST 序列具有明显的非平稳性。由复杂性系统理论可知,被观测系统拥有较低的复杂度,说明被观测系统更有可能遵循某一确定的变化规律,数据则更容易被挖掘和预测^[9]。时间序列的复杂度越低,即非平稳性越低,时间序列越容易被预测。为进一步提升预测结果的精度,所提算法首先采用 EMD 算法将 SST 序列分解为若干子序列,改善了 SST 序

列的非平稳性;然后利用 GRU 神经网络对各子序列分别进行预测;最后合并每条子序列的预测结果,

并进行误差消除处理。所提预测模型结构如图 1 所示。



imf: Intrinsic Mode Function; SVR: Support Vector Regression; res: Residue; Pred: Prediction

图 1 所提预测模型结构

Fig. 1 Structure of proposed prediction model

2.1 经验模态分解方法

在海表温度预测(SSTP)中,影响 SST 变化的因素很多,如盐度、气旋、季节变化、全球变暖等。在各种因素的干扰下,SST 的变化变得复杂和缺乏规律性。使用现有单一模型进行数据拟合时,预测效果较差。为此,将非平稳性较高的 SST 序列分解为若干分量,提高数据预测效果。

EMD 算法是一种依据数据自身的时间尺度特征来进行信号分解的算法,与傅里叶分解与小波分解不同,EMD 无需设定基函数,适用于任何类型信号的分解,尤其在处理非平稳性以及非线性数据上,具有显著的优势^[10]。由 EMD 生成的 imf 应满足以下要求:

1) imf 的极值点数目与零点数目必须相等或最多相差 1;

2) 在 imf 的任意点,局部最大值定义的包络线的平均值和局部最小值定义的包络线的平均值应等于 0。

所提算法首先使用 EMD 处理数据,使 SST 序列自适应地分解为若干子序列,随后将子序列输入神经网络进行训练并评估模型效果。

2.2 GRU 神经网络

GRU 作为一种特殊的循环神经网络,与 LSTM 相同,更好地保留时间跨度较长的信息,更好地避免了长期依赖性问题。相比 LSTM,GRU 由 Sigmoid 运算单元和 tanh 运算单元来共同决定信息的输出,GRU 的最终模型要比标准的 LSTM 模

型简单,训练参数比 GRU 少 1/3。因此 GRU 更不容易过拟合。GRU 的运算过程为

$$z_t = \sigma(\mathbf{W}_z \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t]), \quad (1)$$

$$r_t = \sigma(\mathbf{W}_r \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t]), \quad (2)$$

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W} \cdot [\mathbf{r}_t \times \mathbf{h}_{t-1}, \mathbf{x}_t]), \quad (3)$$

$$\mathbf{h}_t = (1 - z_t) \times \mathbf{h}_{t-1} + z_t \times \tilde{\mathbf{h}}_t \quad (4)$$

式中: \mathbf{h}_{t-1} 表示上一时刻神经元的输出值; \mathbf{x}_t 表示当前时刻神经元的输入值;更新门 z_t 决定了当前信息需要丢弃或更新的个数;重置门 r_t 表示用于决定过去信息需要被遗忘的个数; \mathbf{W}_z 表示更新门的权值矩阵; \mathbf{W}_r 表示重置门的权值矩阵; \mathbf{W} 表示共享矩阵。(1)~(4)式中的 $[\mathbf{f}, \mathbf{g}]$ 类型的式子表示由向量 \mathbf{f} 与向量 \mathbf{g} 组合而成的矩阵。

2.3 EMD-GRU 模型

采用 EMD-GRU 模型进行 SST 序列的预测,该预测由多尺度分解和多序列预测 2 部分组成。

2.3.1 多尺度分解

采用 EMD 方法对原始的时间序列进行自适应地分解后,产生的多条 imf 和一条 res 的复杂度较低,相比原始序列的非平稳性也较低,更加具有可预测性。

EMD 算法的输入为一组时间序列,输出为若干子序列,包括若干 imf 和一个 res。具体步骤如下。

1) 根据输入序列 $i(t)$ 求极大值点与极小值点;

2) 分别根据极大值点与极小值点画出输入序列的上下包络线;

3) 根据上下包络线的均值画出均值包络线 $h(t)$;

4) 用输入序列 $i(t)$ 减去均值包络线 $h(t)$, 得到中间序列 $m(t)$, 即 $m(t) = i(t) - h(t)$;

5) 若 $m(t)$ 满足 imf 的条件, 则 $m(t)$ 就是一个 imf, 否则令 $i(t) = m(t)$, 并返回执行步骤 1);

6) 当 $m(t)$ 为一个 imf 分量时, 令 $i(t) = i(t) - m(t)$, 并返回执行步骤 1), 直至分解完毕得到若干个 imf 和一个余波 res。

输入序列 $i(t)$ 与最终得到的 imf 分量和 res 余量之间的关系为

$$i(t) = \sum \text{imf}_i + \text{res}. \quad (5)$$

2.3.2 多序列预测

采用 GRU 神经网络对 imf 和 res 进行训练和预测时, 相比其他模型, GRU 神经网络具有预测精度高、收敛速度快, 不易产生过拟合的优势, GRU 的神经元结构如图 2 所示。GRU 首先对每一条 imf 和 res 进行处理得到预测结果, 并利用(5)式将各子序列得到的预测值进行叠加求和, 获得原始序列的初始预测值。其次, 为了进一步提升实验预测结果的精度, 添加 SVR 层做误差消除处理, 步骤如下。




图 2 GRU 神经元结构

Fig. 2 Structure of GRU neuron

1) 在训练中, 利用 GRU 得到预测值之后, 对预测值进行叠加得到初始预测值;

2) 将初始预测值作为输入, 真实值作为输出构建数据集, 输入 SVR 层进行训练。

3 实验

3.1 实验准备

实验使用的数据为卫星遥感中国近海的 SST 实测数据。数据采集于中国近海, 区域内共采集了 80×40 条数据。所提算法选取了其中 5 条 SST 序列, 分别为 SST06-01, SST40-12, SST61-23, SST70-

09, SST80-01, 并依次编号为 SST1、SST2、SST3、SST4、SST5。每条 SST 数据时间跨度为 2004 年 1 月 1 日至 2016 年 12 月 31 日, 每天记录一次, 共 4749 天, 其中训练集长度为 3167 天, 验证集长度为 1582 天。模型为输入连续的前 10 天 SST 预测后 5 天的 SST。另外, 为说明模型的有效性, 增加利用 7 天 SST 序列数据预测 1 天, 15 天 SST 序列数据预测 7 天补充实验。实验使用的 5 条数据如图 3 所示, 5 条 SST 序列按照传感器站点与海岸的距离由远及近的情况随机选取, 5 条数据中海温的波动性逐渐增大, 复杂度也逐渐增大, 其中 SST4 与 SST5 的变化情况最大, 预测难度也最大。

实验运行环境为 Windows10, Intel Core i7, 2.6 GHz, 16 GB RAM, 算法使用 python 实现, 采用 Keras 框架搭建神经网络预测模型。Keras 是一个深度学习的框架, 有许多模块包, 方便构建模型。

降低数据非平稳性是提高 SST 预测精度的关键。为判断 EMD 分解后的序列非平稳性情况, 所提算法采用了多尺度复杂度的衡量标准评估分解后的子序列的非平稳性, 并进而得到分解后序列组的综合非平稳性。测量多尺度复杂度的步骤如下。

1) 使用熵值分析法计算每个 imf 和 res 序列的复杂度 C_i 。

首先, 将时间序列由时域映射到相空间上^[11]。

$$X_j = \{x_j, x_{j+1}, \dots, x_{j+(m-1)}\}, \quad j = 1, 2, \dots, T - (m - 1). \quad (6)$$

其次, 利用二阶差分来捕捉短期噪声波动造成的不均匀性细微变化^[12]。

$$Z_j = (\Delta^2 X_j) / |\overline{X_j}| \quad (7)$$

最后, 计算熵度量^[13-14]。

$$C_i = - \sum_{g=1}^u P_g \ln P_g \quad (8)$$

其中, P_g 是第 g 组的概率分布且满足

$$\sum_{g=1}^u P_g = 1, u \leq T - (m - 1). \quad (9)$$

2) 对步骤 1) 得到的子序列的复杂度进行加权求和。

$$C_{EMD} = \sum_{i=1}^n \omega_i \times C_i, \quad (10)$$

式中: C_{EMD} 表示经过 EMD 分解后结果的多尺度复杂度; C_i 表示第 i 条经过 EMD 分解出来的波的复杂度; ω_i 表示对应第 i 条波的权重(权重是由振幅百分比表示而成)。经过以上步骤计算后, 若复杂度比原始序列低, 则证明平稳性得到提升^[15]。




图 3 五个站点的 SST 序列数据

Fig. 3 SST sequence data of five sites

为有效评估算法预测效果,所提算法使用 MSE 和 MAE 作为预测结果的评价指标。

$$E_{MSE} = \frac{1}{N} \sum_{n=1}^N (y_n - \tilde{y}_n)^2, \quad (11)$$

$$E_{MAE} = \frac{1}{N} \sum_{n=1}^N |y_n - \tilde{y}_n|, \quad (12)$$

式中: N 表示预测得到的时间序列的长度; y_n 表示

预测值; \tilde{y}_n 表示真实值。以上两个指标越小表示实验效果越好,预测精度越高。

3.2 实验结果与分析

为验证所提算法的有效性,从以下两部分进行实验:1)按照 SST 序列的复杂度由低到高选取序列进行预测;2)针对模型设置不同的输入输出进行补充实验。为降低 SST 序列的非平稳性,首先使用

EMD 将原始的 SST 序列自适应地分解为若干个 imf 及一个 res。图 4 为 5 条 SST 序列经过 EMD 分解之后的 imf 和 res 序列。并对原始的 SST 序列和经过 EMD 分解之后的 SST 序列进行复杂度评估和对比,如图 5 所示。




图 4 五条 SST 序列经过 EMD 分解之后的序列
Fig. 4 Sequences of five SST sequences after EMD decomposition

从图 5 中可以看出,SST 序列在经过 EMD 算法处理之后,多尺度复杂度均得到了降低,即数据的非平稳性得到了降低,提高了 SST 序列的可预测性。

3.2.1 模型预测结果

经过 EMD 算法处理后,SST 序列被自适应地分解为若干条 imf 和一条 res。首先,使用多尺度度量方法对 SST 序列及分解之后的子序列进行测

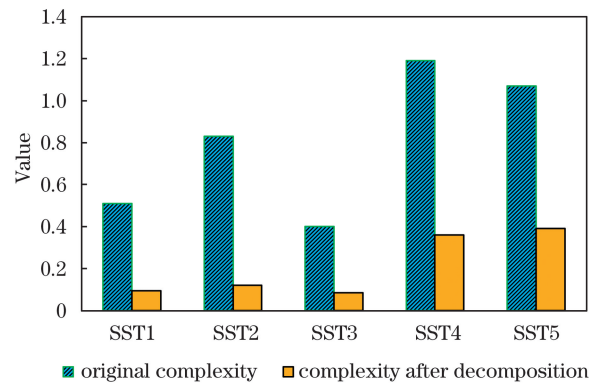


图 5 原始序列的复杂度与分解后的多尺度复杂度对比
Fig. 5 Comparison between complexity of original sequence and multi-scale complexity after decomposition

量。结果表明,5 条序列在经过 EMD 算法处理之后的非平稳性均得到了降低。其次,将分解后的子序列作为神经网络的输入进行训练,并将得到的每一个子序列的预测值进行叠加。最后,将叠加后的预测值输入 SVR 层进行误差消除处理并得到最终的预测值。首先针对使用 10 天预测 5 天的情况设计了两组对比实验,网络训练迭代次数为 500 次。

比较了不同序列在单一 RNN、LSTM、GRU 模型下的预测结果,如图 6 所示。结果表明,直接使用神经网络进行 SSTP 时,GRU 与 LSTM 的结果优于 RNN。




图 6 五条实验数据在 3 种神经网络的预测结果对比
Fig. 6 Comparison of prediction results of five experimental data in 3 neural networks

由第 1 组实验的结果可知,LSTM 与 GRU 针对不同的 SST 序列的预测精度均优于 RNN,但是 GRU 与 LSTM 针对不同 SST 序列的预测精度相差不大。因此,对比分析了 LSTM、GRU、EMD-LSTM、EMD-GRU 模型对 5 条 SST 序列的预测精度,结果如表 1 和图 7 所示。

表 1 基于 EMD 的机器学习模型预测结果与直接使用机器学习的预测模型结果对比

Table 1 Comparison between prediction results of EMD based on machine learning model and those of direct machine learning models

| SST | Parameter | LSTM | EMD-LSTM | GRU | EMD-GRU |
|------|-----------|--------|----------|--------|---------|
| SST1 | MSE | 0.1963 | 0.1077 | 0.1721 | 0.0706 |
| | MAE | 0.3269 | 0.2040 | 0.3203 | 0.1965 |
| SST2 | MSE | 0.2355 | 0.1463 | 0.2092 | 0.0692 |
| | MAE | 0.3666 | 0.2804 | 0.3583 | 0.1978 |
| SST3 | MSE | 0.4896 | 0.3040 | 0.2924 | 0.0964 |
| | MAE | 0.3733 | 0.2371 | 0.3898 | 0.2333 |
| SST4 | MSE | 0.3896 | 0.2656 | 0.4537 | 0.2609 |
| | MAE | 0.4759 | 0.3967 | 0.5067 | 0.3891 |
| SST5 | MSE | 0.8724 | 0.3810 | 0.8744 | 0.2366 |
| | MAE | 0.6507 | 0.4419 | 0.6911 | 0.3710 |

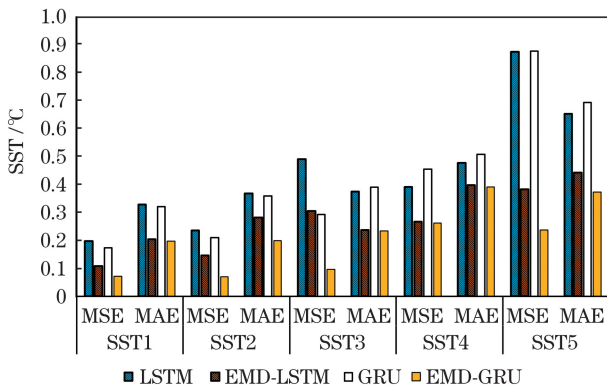


图 7 基于 EMD 的机器学习模型与直接使用机器学习模型的实验结果对比

Fig. 7 Comparison of experimental results between EMD based on machine learning model and direct machine learning models

由图 7 可知,针对不同 SST 序列,EMD-LSTM 与 EMD-GRU 的预测精度均优于单一 LSTM 与 GRU 模型的预测精度;相比 EMD-LSTM 模型,EMD-GRU 模型的预测效果更好。

为验证所提算法的有效性,设计实验并给出具体的预测结果。在 SST5 验证集数据中随机抽取了连续 10 天的 SST 数据,输入 LSTM、EMD-LSTM、GRU、EMD-GRU 4 种模型进行预测,分别得到 5 天的预测值。图 8 为在 4 种模型预测下的 SST 与实际 SST 的对比。由图 8 可知,基于 EMD-GRU 模型得到的预测结果更接近实际的 SST 值。

3.2.2 数据序列长度对预测精度影响分析

为了进一步验证实验结果的有效性,针对复杂度较高的 SST5,设计了两组补充实验。两组补充实验中数据集的输入输出长度分别为 7 天预测 1 天及 15 天预测 7 天,表 2 和图 9 为 SST5 在不同预测长度下的结果。




图 8 在 4 种不同的预测模型下预测值与真实值的对比

Fig. 8 Comparison between predicted value and real value under 4 different prediction models

表 2 补充实验结果

Table 2 Supplementary experimental results

| In-out | Parameter | GRU | EMD-GRU |
|--------|-----------|--------|---------|
| 7-1 | MSE | 0.2569 | 0.1748 |
| | MAE | 0.3753 | 0.3282 |
| 10-5 | MSE | 0.8744 | 0.2366 |
| | MAE | 0.6911 | 0.3710 |
| 15-7 | MSE | 1.0459 | 0.6309 |
| | MAE | 0.7767 | 0.6062 |

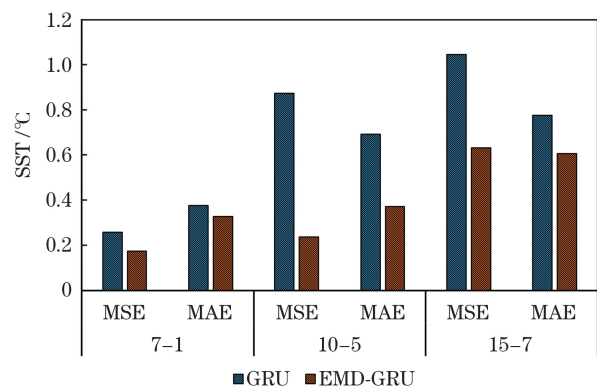


图 9 SST5 的补充实验结果对比

Fig. 9 Comparison of supplementary experimental results of SST5

从图 9 中可以看出:预测长度越长精度效果越差;通过 EMD 算法对序列进行处理后,效果均得到了提升,且在预测长度变长的情况下,效果提升较为明显。

4 总 结

SST 序列具有明显的非平稳性,尤其是一些特殊气候条件下的 SST 序列(厄尔尼诺,拉尼娜等),非平稳性更强。传统 SST 序列预测方法未考虑 SST 序列的非平稳性,使得预测精度低。基于此,提出了一种基于 EMD-GRU 的预测模型,该模型充分利用 EMD 降低序列非平稳性及 GRU 收敛速度快,易训练等优势,提高了 SST 序列预测精度,对于非平稳性较强的 SST 序列预测精度提升更为显著。

为验证所提模型的有效性,将 5 条不同的 SST 序列作为 EMD-GRU 模型的样本输入,设计多组对比实验。首先,将 SST 序列分别作为 RNN、LSTM、GRU 网络的输入进行训练,实验结果表明,LSTM 与 GRU 在 SST 预测方面明显优于 RNN。其次,将 LSTM、GRU 分别与 EMD 算法相结合为 EMD-LSTM 模型、EMD-GRU 模型,对 5 组 SST 序列进行训练和预测,实验结果表明,EMD-GRU 模型预测精度稍优于 EMD-LSTM。为进一步验证模型的有效性,设计不同输入输出长度的模型做补充实验。实验结果表明,EMD-GRU 模型在 SST 预测中的精度均优于直接使用 GRU 进行预测的。

综上所述:1)所提模型,在数据越不平稳、多尺度复杂度越大的情况下,精度与稳定性提升越大。2)在经过 EMD 算法对原始 SST 序列进行预处理之后,SST 序列的多尺度复杂度得到了降低,SST 的非平稳性降低,从而使预测难度降低,充分体现出了基于 EMD 的预测模型的优势。

所提 EMD-GRU 模型尤其适用于极端气候条件下的 SST 预测,极大提升 SST 的预测精度。准确地预测出 SST 的变化,对于厄尔尼诺、拉尼娜等自然灾害的预报具有重大的意义^[16]。在实际的海洋气象预报中,绝大部分海洋气象的数据具有更加明显的非平稳性及较高的复杂度,数学方法或者直接使用机器学习方法预测难度较大,因此所提模型在海洋气象预报和实际生活中具有广泛的应用价值和前景。

参 考 文 献

- [1] Sun C C. Correlation analysis of SST anomaly with sea surface wind and China's climate based on satellite observations [D]. Qingdao: Ocean University of China, 2015.
- 孙从从. 基于卫星数据的海表温度异常与海面风场及中国气候的相关性分析[D]. 青岛: 中国海洋大学, 2015.
- [2] Xu L Y, Fang X J, Xu R J, et al. Time-fusion based on time-series mining and application of sea surface temperature forecast [J]. Journal of Shanghai University (Natural Science Edition), 2007, 13(5): 550-553, 559.
- 徐凌云, 方晓君, 徐仁杰, 等. 基于时序挖掘的时间融合算法及在海表面温度预测中的应用[J]. 上海大学学报(自然科学版), 2007, 13(5): 550-553, 559.
- [3] Zhang L X, Zhao M, Jiang X S. The change trend of happened frequency and the R/S forecast of frequently happened year for red tide in China[J]. Marine Science Bulletin, 2010, 29(1): 72-77.
- 张丽旭, 赵敏, 蒋晓山. 中国赤潮发生频率的变化趋势及其多发年份的 R/S 预测[J]. 海洋通报, 2010, 29(1): 72-77.
- [4] Aparna S G, D' Souza S, Arjun N B. Prediction of daily sea surface temperature using artificial neural networks [J]. International Journal of Remote Sensing, 2018, 39(12): 4214-4231.
- [5] Gers F A, Schmidhuber J, Cummins F. Learning to forget: continual prediction with LSTM [J]. Neural Computation, 2000, 12(10): 2451-2471.
- [6] Zhang Q, Wang H, Dong J Y, et al. Prediction of sea surface temperature using long short-term memory [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10): 1745-1749.
- [7] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [8] Liu T B, Zhang L T, Yu W T, et al. Hierarchical LSTM-based audio and video emotion recognition with embedded attention mechanism [J]. Laser & Optoelectronics Progress, 2021, 58(2): 0210017.
- 刘天宝, 张凌涛, 于文涛, 等. 基于嵌入注意力机制层级 LSTM 的音视频情感识别[J]. 激光与光电子学进展, 2021, 58(2): 0210017.
- [9] Tang L, Lü H, Yang F M, et al. Complexity testing techniques for time series data: a comprehensive literature review [J]. Chaos, Solitons & Fractals, 2015, 81: 117-135.
- [10] Yang H L, Lin H C. An Integrated Model Combined ARIMA, EMD with SVR for Stock Indices

[1] Sun C C. Correlation analysis of SST anomaly with sea

- Forecasting [J]. *International Journal of Artificial Intelligence Tools*, 2016, 25(02):1650005.
- [11] Tang L, Wang S, He K J, et al. A novel mode-characteristic-based decomposition ensemble model for nuclear energy consumption forecasting [J]. *Annals of Operations Research*, 2015, 234(1): 111-132.
- [12] Shannon C E. A mathematical theory of communication[J]. *Bell System Technical Journal*, 1948, 27(3): 379-423.
- [13] Zhu Q M, Azar A T. *Complex system modelling and control through intelligent soft computations* [M]. Cham: Springer, 2015.
- [14] Chen W T, Zhuang J, Yu W X, et al. Measuring complexity using FuzzyEn, ApEn, and SampEn[J]. *Medical Engineering & Physics*, 2009, 31(1): 61-68.
- [15] Wu Y, Zhou Y C, Saveriades G, et al. Local Shannon entropy measure with statistical tests for image randomness [J]. *Information Sciences*, 2013, 222: 323-342.
- [16] Ren H L, Wang R, Zhai P M, et al. Upper-ocean dynamical features and prediction of the super El Niño in 2015/2016: A comparison with 1982/1983 and 1997/1998[J]. *Acta Meteorologica Sinica*, 2017, 75(1): 1-18.
- 任宏利, 王润, 翟盘茂, 等. 超强厄尔尼诺事件海洋学特征分析与预测回顾[J]. *气象学报*, 2017, 75(1): 1-18.