

The Prediction of ENSO Indexes Based on Time Series LSTM Model

Fu Chen¹, Fan Duo²

¹Physical Oceanography Laboratory, Ocean University of China, Qingdao Shandong

²Jacobs School of Engineering, University of California San Diego, San Diego California

Email: 1162202607@qq.com

Received: Apr. 25th, 2019; accepted: May 7th, 2019; published: May 14th, 2019

Abstract

To improve the prediction ability of El Niño-Southern Oscillation (ENSO), we use the Niño 3.4 and Southern Oscillation indexes during 1951-2008 to build time series long short-term memory (LSTM) model, and forecast that during 2009-2018. The analysis shows the time series LSTM model has a good forecasting ability for Niño 3.4 index in advance of 1 - 12 months, though underestimates the amplitude of the super El Niño event during 15/16 year. While time series LSTM model can only predict the SOI in advance of 1 - 3 months to a certain extent, because of the high frequency seasonal variability in SOI index. Further experiment proves that the 7-month run-mean SOI is also can be predicted well by time series LSTM model, similar with the Niño 3.4 index. Comparing with other statistical forecasting models, the time series LSTM model is efficient and convenience with advantages in ENSO prediction.

Keywords

ENSO, LSTM, Deep Neural Network, Time Series Prediction

基于时间序列LSTM模型的ENSO指数 预报试验

陈 福¹, 朵 凡²

¹中国海洋大学物理海洋实验室, 山东 青岛

²加州大学圣地亚哥分校雅各布斯工程学院, 加利福尼亚 圣地亚哥

Email: 1162202607@qq.com

收稿日期: 2019年4月25日; 录用日期: 2019年5月7日; 发布日期: 2019年5月14日

摘要

为了提高ENSO事件的预报能力, 本文利用1951~2008年Niño 3.4和南方涛动指数(Southern Oscillation index, 简称SOI)时间序列数据, 建立了关于ENSO指数预报的时间序列LSTM模型, 并对2009~2018年期间Niño 3.4或SOI指数进行预测。结果表明, 对于Niño 3.4指数, 时间序列LSTM模型在1~12个月预报时效内都具有很好的预报能力, 尽管模型对15/16年间超强厄尔尼诺事件的振幅预测仍有一定的误差。而对于SOI指数, 模型仅在1~3个月的短预报时效内有一定的预报能力, 原因是SOI中高频的季节内信号使SOI指数不具备长期的可预测性。实验结果也证明, 在经过7个月的滑动平均后, 模型在不同预报时效下对SOI指数的预报能力都有显著的提升, 与Niño 3.4指数接近。而相对其他方法, 时间序列LSTM模型具有一定预报能力优势, 且具有建模方便, 可同时得到不同时间预测结果等优点。

关键词

ENSO, LSTM, 深度神经网络, 时间序列预报

Copyright © 2019 by author(s) and Hans Publishers Inc.

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

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



Open Access

1. 引言

热带太平洋是全球气候变化的最重要区域之一, 其中厄尔尼诺 - 南方涛动(El Niño-Southern Oscillation, 简称 ENSO)是其中最强的信号。尽管 ENSO 事件发生在热带太平洋, 但其发生发展会通过大气遥相关等途径影响全球气候变化, 引发多种气象灾害, 造成重大的经济损失和社会影响。因此, ENSO 事件的准确预测也成为各国气象学家密切关注的问题。

目前, ENSO 的预报主要分为动力学模型和统计学模型两大类。动力学模型通过对 ENSO 相关的物理过程进行建模与数值计算, 逐步积分得到预报结果。自 20 世纪 80 年代以来, 国内外许多机构研制了许多 ENSO 预报模式[1], 已经具备了 6~12 个月的预报可信度。但动力学模式预报结果仍存在许多不足之处, 例如春季预报障碍、误差累积、以及不同模式预报结果存在显著差异等。统计学模型通过挖掘历史数据信息, 对其反应的物理规律进行建模并预测。研究表明, 利用典型相关分析 [2]、支持向量机[3], 奇异谱分解[4]等模型预测 ENSO 事件, 都取得了较好效果。但由于 ENSO 事件是复杂的非线性物理过程, 而许多统计学模型对 ENSO 非线性作用的建模能力有限。

近年来, 随着人工智能技术的飞速发展, 神经网络模型也被广泛应用各个领域。神经网络通过训练出一个庞大的线性与非线性函数的组合, 从而可以拟合任意的复杂函数。很多学者也尝试使用神经网络进行海洋气象要素或现象预报[5] [6] [7], 或者是 ENSO 事件的预报研究[8], 取得了很好的结果。但由于 ENSO 指数观测数据较短等原因, 少有研究仅利用 ENSO 相关指数的时间序列, 通过深度学习研究方法研究其可预报性。而最近, 谷歌提出了一种基于时间序列的长短记忆神经网络模型(Long short-term memory, 简称 LSTM), 可以对较短的时间序列进行建模并预测, 在金融等领域上取得了较好的效果。因此, 本文将基于时间序列 LSTM 模型, 研究 ENSO 事件相关指数的可预报性, 并探讨造成不同指数间预报能力差异的原因。

2. 模型介绍

深度神经网络(Deep neural network, 简称 DNN)是一种模仿动物神经网络, 进行分布式并行信息处理的算法模型。DNN 通常有一个输入层, 一个或多个隐藏层及输出层组成, 在上层神经元的值通过连接权重加权求和, 并通过非线性函数(如 Sigmoid 函数, Tanh 函数, ReLU 函数等)激活, 然后输入下一层神经元并进行非线性处理作为当前层的输出, 重复直到输出最终结果。DNN 的参数训练采用了反向传播算法, 其过程简单来说, 首先随机设置网络参数的初始值, 并将当前输出与目标输出之间的差异, 定义为损失函数, 并通过链式法则, 逐层计算损失函数对各层参数的偏导数, 并将其乘以学习率加到原始参数上, 得到更新后的模型, 反复迭代这一过程, 直至模型收敛达到稳定。

但对于 ENSO 等时间序列数据, 传统的 DNN 并不能较好学习数据特征, 原因是因为模型无法处理数据之间的时间依赖性。为了利用神经网络处理序列问题, Hopfield 等人[9]提出了循环神经网络(Recurrent Neural Network, 简称 RNN), 在传统的神经网络中引入环状结构, 即在每层神经元彼此之间的序列连接, 从而可以将上一时间点的输入以记忆的形式存在网络中, 并作为下一个时间点的输入之一。如图 1 所示, 传统深度神经网络仅是将当前层神经元与下一层神经元进行全连接, 而没有考虑同一隐藏层内神经元的时序关系, 而 RNN 通过将同一层内神经元顺序相连, 每个神经元同时接受上一层相同时刻与当前层之前时刻的输入, 从而达到对数据的时序关系建模的目的。但 RNN 在网络训练的过程中, 采用时间反向传播算法, 即在同一隐藏层内, 沿时间步进行误差的反向传播与参数更新, 但由于误差梯度的反向传播在时间维为累乘, 非常容易发生梯度消失或爆炸现象, 无法有效更新参数。为了解决这一问题, 有学者提出了 LSTM 单元结构[10], 将反向传播过程中梯度由累乘转为累加, 从而一定程度上避免了梯度消失或爆炸问题。LSTM 模型也是一种 RNN 结构, 每个隐藏层由一连串相同参数的 LSTM 单元组成, 每个 LSTM 单元将上一个步的输出结果与当前步骤的输入数据一起作为输入, 并当前处理结果传递到下一个 LSTM 单元, 如此循环直至最终输出结果。每个 LSTM 神经元内数据处理过程如公式 1 所示:

$$\begin{aligned}
 i_t &= \sigma(W_i x_t + U_i h_{t-1} + b_i) \\
 f_t &= \sigma(W_f x_t + U_f h_{t-1} + b_f) \\
 u_t &= \tanh(W_u x_t + U_u h_{t-1} + b_u) \\
 o_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o) \\
 c_t &= f_t \odot c_{t-1} + i_t u_t \\
 h_t &= o_t \odot \tanh(c_t)
 \end{aligned} \tag{1}$$

其中, W_i 、 W_u 、 W_f 、 U_i 、 U_f 、 U_o 、 b_i 、 b_f 、 b_u 等是权重参数, 每个隐藏层内 LSTM 单元的这些参数是完全相同, 且在训练过程中不断调整。 σ 为 sigmoid 函数, 每个 σ 也可以看作一个“门”, 通过非线性变换将数据压缩成 0~1 之间的概率值, 因此也被分别称为输入门(Input Gate), 更新门(Update Gate)和输出门(Output Gate)。 \odot 为两个向量对应元素点乘, x_t 、 h_{t-1} 和 h_t 分别是当前 LSTM 单元的输入与输出, 其中 h_t 既可以作为历史信息传递到下一个 LSTM 单元继续计算, 也可以作为模型在当前时刻的输出结果传递到下一层或者计算最终输出。

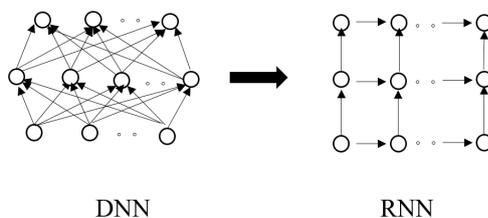


Figure 1. The schematic diagram of DNN and RNN
图 1. DNN 与 RNN 的模型结构示意图

3. 实验过程

3.1. 数据介绍

ENSO 是一种发生在热带太平洋的海气相互作用过程, 因此有许多定义从不同角度来描述了 ENSO 事件。在海洋中, 最具代表性的描述是 Niño 3.4 指数, 其定义是 $5^{\circ}\text{N}\sim 5^{\circ}\text{S}$, $170^{\circ}\text{W}\sim 120^{\circ}\text{W}$ 区域海表面温度距平场的空间平均。而在大气中, 最具有代表性的描述是南方涛动指数(Southern Oscillation index, 简称 SOI), 其定义为达尔文岛和塔希提岛标准化海平面气压异常场的差值(塔希提岛-达尔文岛)。因此, 本文采用了由美国国家大气研究中心(National Center for Atmospheric Research, 简称 NCAR)提供的 Niño 3.4 指数, 作为海洋中 ENSO 事件的指标, 和来自美国海洋与大气中心(National Oceanic and Atmospheric Administration, 简称 NOAA)提供的 SOI 指数, 作为大气中 ENSO 事件的衡量指标。两种指数的起止时间均为 1951 年 1 月至 2018 年 12 月。

为了评价模型预测能力, 我们将数据分为两个部分。其中 1951 年 1 月至 2008 年 12 月, 共 708 个月数据作为训练集, 用于模型训练与拟合测试。而 2009 年 1 月至 2018 年 12 月的十年间的数据作为测试集, 用于独立评估模型预测能力, 不参与建模过程。图 2 展示了在两种指数在训练集与测试集中的部分统计特征, 可以发现, Niño 3.4 和 SOI 指数在测试集的均值和方差都较训练集有一定的上升, 且测试集中二者的最大值(即 15/16 年超强厄尔尼诺事件)也超过历史训练集, 这可能与全球变暖背景下, 热带太平洋海温平均气候态上升, ENSO 事件强度增强, 极端厄尔尼诺事件频率上升有关[11] [12]。训练集和测试集间的差异可能会对模型预测能力造成一定的影响。

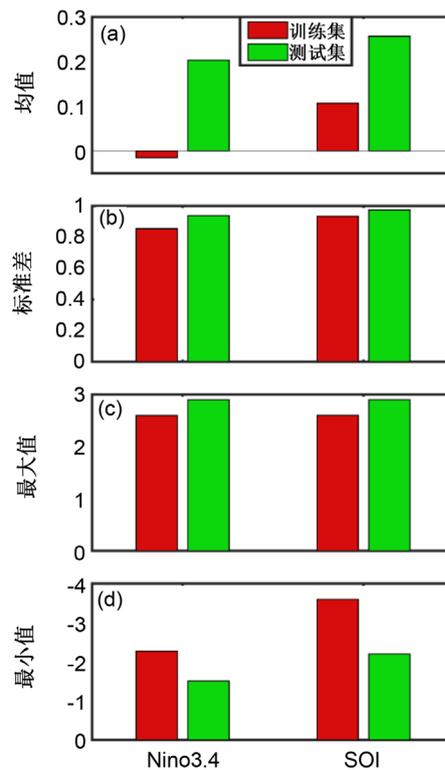


Figure 2. The mean (a), standard deviation (b), maximum (c), minimum (d) in train (red) and test (green) set of Niño 3.4 and SOI index

图 2. 在训练集(红色)和测试集(绿色)中, Niño 3.4 和 SOI 指数的均值(a), 标准差(b), 最大值(c)和最小值(d)

3.2. 模型训练

目前, 有许多成熟的开源深度学习框架, 可以方便使用者进行深度神经网络的学习与使用, 如 TensorFlow, Pytorch, Keras 等, 本文采用了由谷歌开源的 TensorFlow Time Series (简称 TFTS) 进行时间序列 LSTM 建模。相对于其他深度学习框架, TFTS 在时间序列问题上做了专门的优化, 如采用时间点+观测值的输入方式, 使模型可用于不均匀间隔的时间序列建模或预测, 以及使用截断的反向传播算法, 使利用小样本进行超长序列的模型训练时也可以有效更新参数等。此外, 由于本文中数据量与模型相对较小, 因此无需使用 GPU 进行训练加速。

本文采用了如图 1 所示的 RNN 模型结构, 其中每个神经元为 LSTM 单元, 其中模型的隐藏层为 4 层, 窗口长度为 60。由于是回归类预测任务, 模型的目标函数为均方根误差, 学习率为 $1e^{-3}$, 优化器为 Adam。每个模型最大训练 2000 轮。在预测时, 我们将预测起点之前的历史数据输入模型, 并从当前时间开始进行预测, 并将预测结果作为当前输入, 向后逐点预测 12 个月。此外, 由于模型要求时间序列的连续性, 模型训练过程中无法进行交叉检验, 为了确保预报结果的可靠性, 本文通过独立重复 5 次模型的训练与预测, 并对预测结果进行多模型平均作为最终预报结果。

4. 结果分析

图 3 展示了自 2010 年 1 月至 2018 年 12 月期间(由于无法对 09 年数据进行 12 个月的提前预测, 因此 09 年预报结果统一不参与比较), 模型在预测时效为 1、3、6 和 12 个月预报时效下的预测结果与实际 Niño 3.4 指数的比较, 图 5 展示了模型预测结果与实际 Niño 3.4 指数的相关系数及均方根误差。可以发现, 时间序列 LSTM 模型在 1~6 个月预报时效下, 可以准确预测实际 Niño 3.4 指数的变化(相关系数超过 0.94, 均方根误差小于 0.2)。在 7~12 个月预报时效下, 尽管模型的预报能力有所降低, 但模型仍然可以较好地把握 Niño 3.4 指数的变化趋势(相关系数超过 0.85, 均方根误差小于 0.45), 说明 Niño 3.4 指数对 ENSO 事件的物理过程已经有较为完整的反映, 具备一定的可预报性。从图 3 还可以发现, 多数时间内, 模型在 1~12 个月预报时效内的预报结果与观测值比较吻合, 但对于 15/16 年间超强厄尔尼诺事件, 模型的短期预报结果存在一定的振幅偏差, 且预报误差随预报时效的延迟逐步增大, 表明模型对于训练数据中并没有发生过极端厄尔尼诺或拉尼娜事件, 模型的预测能力仍有一定的不足。

我们比较了时间序列 LSTM 模型与其他部分统计学预报模型的预报能力。文献[4]利用神经网络和谱分解方法进行了 Niño 3.4 指数的预测, 其在 3 个月和 6 个月预报时效内的相关系数分别为 0.76 与 0.61; 文献[3]利用小波分析和最小二乘 SVM 模型预报了 Niño 区域温度距平场, 其相关系数分别为 0.97 和 0.89; 文献[8]采用了多变量的 Seq2seq2 神经网络模型, 进行了 Niño 3.4 指数预测, 其相关系数分别为 0.81 和 0.65。而本文的时间序列 LSTM 模型在 3 个月和 6 个月预报时效内的相关系数分别是 0.96 和 0.94, 表明时间序列 LSTM 对 Niño 3.4 指数的预报有一定的预报能力优势。

本文还研究了时间序列 LSTM 模型对大气中 SOI 指数的预报能力。图 4 展示了相同时间段内, LSTM 模型在预测时效为 1、3、6 和 12 个月预报时效下的 SOI 指数预报结果与预报值的比较, 图 5 展示了预报结果与实际 SOI 指数的相关系数与均方根误差分布。可以发现, 在 1~3 个月短的预报时效下, 模型对 SOI 的变化有一定的预测能力(相关系数大于 0.69, 均方根小于 0.53), 对 10/11 年间的拉尼娜事件和 15/16 年间的厄尔尼诺事件也有一定的反映能力。然而随着预报时效延长, 模型的预报能力快速下降, 在 12 个月预报时效下, 尽管模型仍可以一定程度上反映出 SOI 的变化趋势(相关系数为 0.41), 然而的预报值普遍较小, 与观测的均方根误差达到 0.93。从图 4 的 Niño 3.4 指数与 SOI 指数的对比也可以看出, 模型对 SOI 指数的预报能力远低于对 Niño 3.4 指数的预报能力, 因此, 也鲜有研究关注 SOI 指数的可预报性。

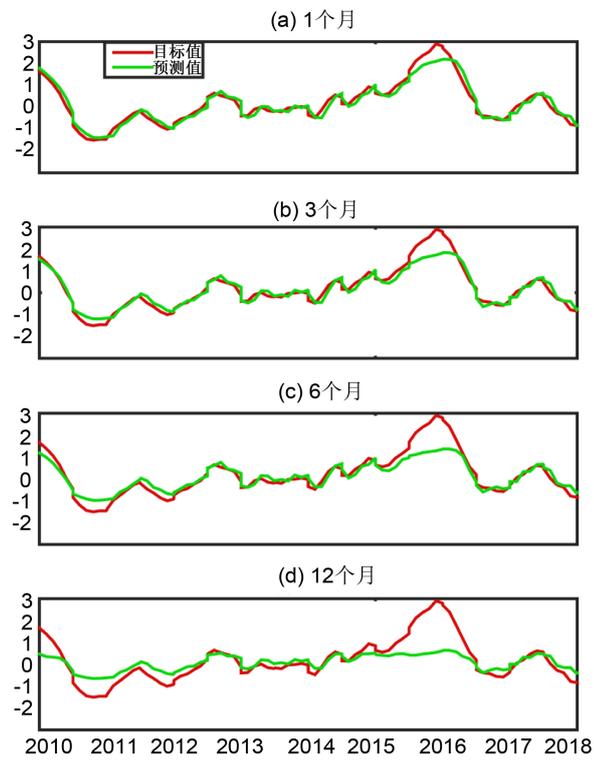


Figure 3. Prediction results and observed Niño 3.4 index
图 3. Niño 3.4 指数的预报值与观测值

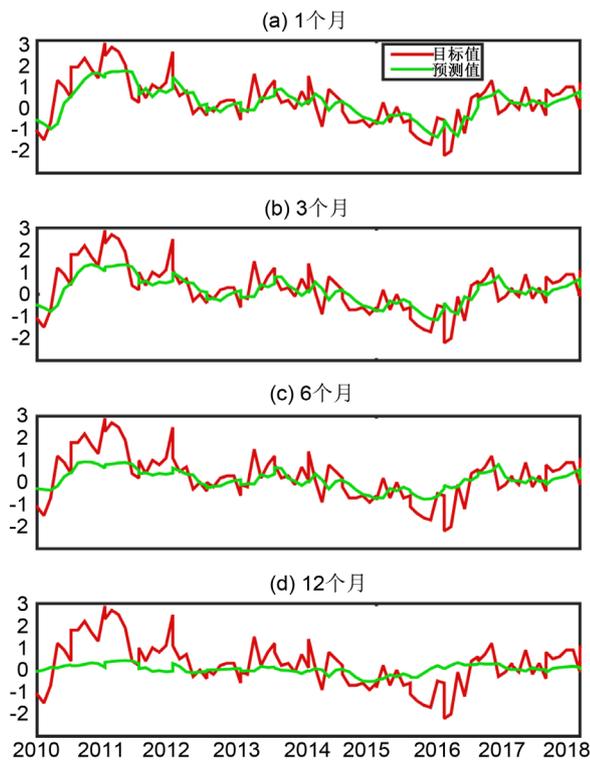


Figure 4. Prediction results and observed SOI index
图 4. SOI 指数的预报值与观测值

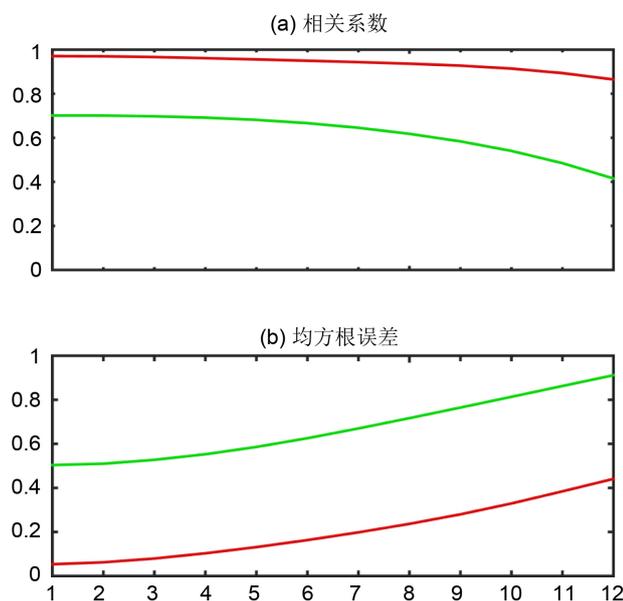


Figure 5. The correlation coefficient and root-mean-square error between prediction results and observed Niño 3.4 index or SOI
图 5. Niño 3.4 指数(红色)与 SOI 指数(绿色)的预报值与观测值的相关系数和均方根误差

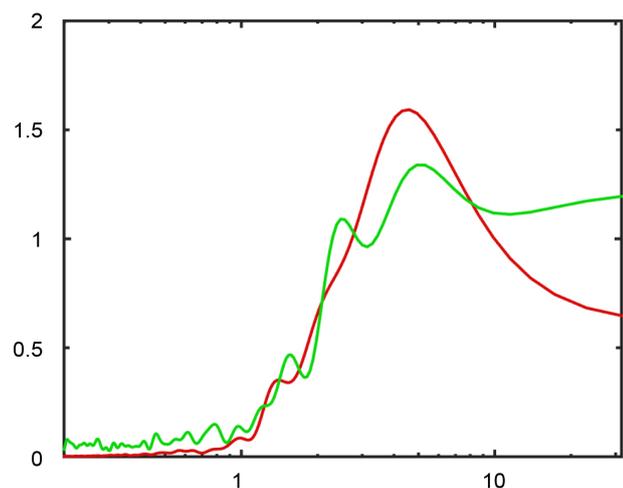


Figure 6. The power spectra density of Niño 3.4 (red) and SOI (green) index
图 6. Niño 3.4 指数(红色)与 SOI 指数(绿色)的功率谱密度

为了研究模型对 Niño 3.4 指数与 SOI 指数预报能力差异的主要来源,我们利用 pwelch 方法,对 Niño 3.4 指数与 SOI 指数进行了功率谱分析,结果如图 6 所示。可以发现,尽管 Niño 3.4 指数与 SOI 指数在时域上接近,二者间的相关系数达到-0.71。然而二者在频域特征上仍然有显著的差别。Niño 3.4 指数在 3~6 年内有显著的年际准周期的谱峰,这是由于海洋中决定厄尔尼诺现象的赤道开尔文波和罗斯贝波在太平洋海盆完成调整的时间大约是 2 年[13]。而南方涛动作为海洋中厄尔尼诺事件在大气中的响应,SOI 的频谱也具有与 Niño 3.4 指数近似周期的年际准周期谱峰。然而,由于大气比热容较小,海平面气压场的热力学性质除了受下垫面海洋的影响外,受季节尺度的高频变化影响也非常显著,因此 SOI 在 1 年以

内频段上的功率谱密度显著强于 Niño 3.4 指数。这种高频的随机噪声严重降低了模型对 SOI 指数的预报能力。进一步的实验结果也表明, 在对 SOI 指数进行 7 个月的滑动平均, 以去除高频随机信号, 时间序列 LSTM 模型对不同预报时效下, 对 SOI 指数的预报能力有了显著的提升。如图 7 所示, 滑动平均后的 SOI 至于与 Niño 3.4 指数相关系数为 -0.75 , 较原始序列有所提高。在 1~3 个月预报时效内, 模型的预报结果与观测较为接近, 而在 6~12 个月内, 模型也能较好地反映出 SOI 指数的变化趋势。此外, 模型在 3 个月和 6 个月预报时效内, 预报结果的相关系数(均方根误差)分别达到了 0.96 (0.24)和 0.87 (0.40), 接近 Niño 3.4 指数的预报水平。

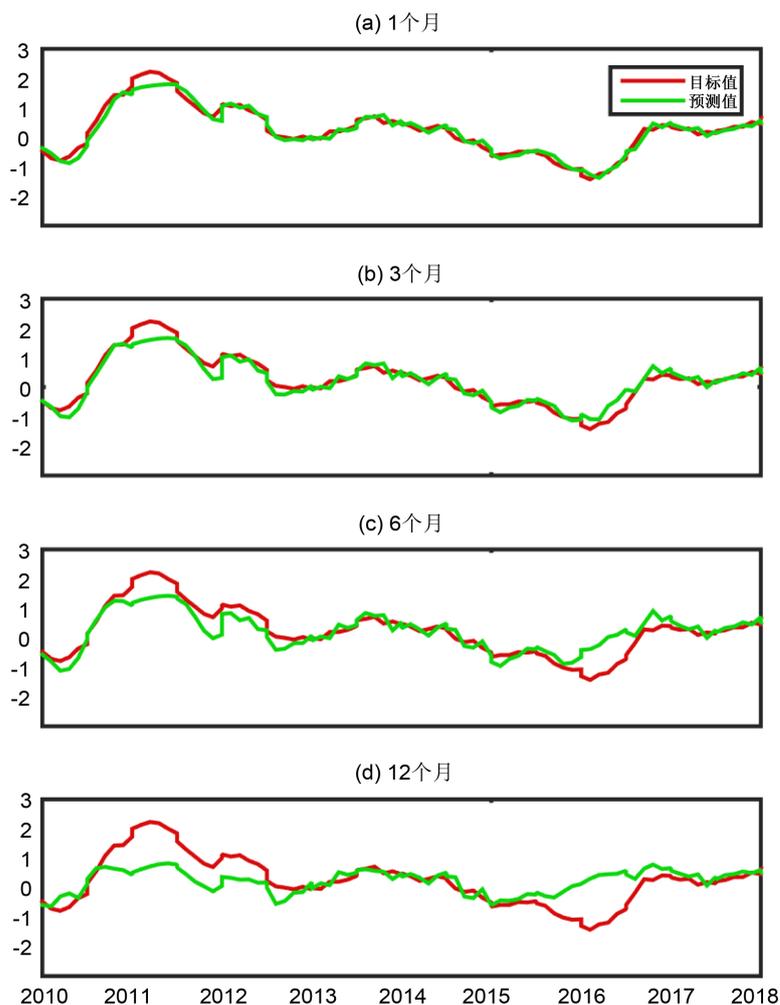


Figure 7. Prediction results and observed 7-months run-mean SOI index
图 7. 7 个月滑动平均的 SOI 指数的预报值与观测值

5. 结语

本文基于时间序列 LSTM 模型, 进行了 ENSO 事件在海洋中的 Niño 3.4 指数的预报研究。结果表明, 尽管对于 15/16 年超强厄尔尼诺事件的预报上存在一定的偏差, 时间序列 LSTM 模型对 Niño 3.4 指数在 1~12 个月预报时效内都有较强的预报能力, 与其他统计预报模型的对比结果表明, 时间序列 LSTM 模型预报能力也具有一定的优势。另外, 许多统计学模型在预测不同时间段的数据时, 往往需要更新数据并重新训练, 工作量大。而本文使用的时间序列 LSTM 模型。仅需要训练一次模型便可进行不同时间内的

数据预测。

本文还利用时间序列 LSTM 模型, 研究了 ENSO 事件在大气中的 SOI 指数的预报研究, 结果表明模型对 SOI 指数并不具备中长期的可预报性。进一步的研究表明, 尽管 Niño 3.4 指数与 SOI 指数高度相关, 然而 SOI 指数还受到季节内高频变化的影响, 其功率谱分析具有显著的季节内随机噪声特征, 这是造成模型对 SOI 指数预报误差的主要来源。实验结果也证明, 模型对 7 个月滑动平均的 SOI 指数也有与 Niño 3.4 指数接近的预报能力。

致 谢

感谢中国海洋大学物理海洋实验室陈显尧老师对本文的意见与支持。

基金项目

本文由中央高校基本科研业务费专项(201841014)资助。

参考文献

- [1] Branston, A.G. and Vandendool, H.M. (1994) Long Lead Seasonal Forecasts—Where Do We Stand? *Bulletin of the American Mathematical Society*, **75**, 2097-2114. [https://doi.org/10.1175/1520-0477\(1994\)075<2097:LLSFDW>2.0.CO;2](https://doi.org/10.1175/1520-0477(1994)075<2097:LLSFDW>2.0.CO;2)
- [2] 丁裕国, 程正泉, 程炳岩. MSSA-SVD 典型回归模型及其用于 ENSO 预报的试验[J]. 气象学报, 2002, 60(3): 361-368.
- [3] 刘科峰, 张军, 陈奕德, 等. 基于小波分解和支持向量机的 ENSO 预测试验[J]. 解放军理工大学学报: 自然科学版, 2011, 12(5): 531-535.
- [4] 严军, 刘建文. 基于神经网络——奇异谱分析的 ENSO 指数预测[J]. 大气科学, 2005, 29(4): 620-626.
- [5] 刘鑫达. 基于深度学习的气象温度预测研究[D]: [硕士学位论文]. 宁夏: 宁夏大学, 2016.
- [6] Feng, Q.Y., Vasile, R., Segond, M., *et al.* (2016) Climate Learn: A Machine-Learning Approach for Climate Prediction Using Network Measures. *Geoscientific Model Development Discussions*, 1-18.
- [7] Zhang, Q., Wang, H., Dong, J.Y., *et al.* (2017) Prediction of Sea Surface Temperature Using Long Short-Term Memory. *IEEE Geoscience and Remote Sensing Letters*, **14**, 1745-1749. <https://doi.org/10.1109/LGRS.2017.2733548>
- [8] 许柏宁, 姜金荣, 郝卉群, 等. 一种基于区域海表面温度异常预测的 ENSO 预报深度学习模型[J]. 科研信息化技术和应用, 2017, 8(6): 65-76.
- [9] Hopfield, J.J. (1982) Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences*, **79**, 2554-2558. <https://doi.org/10.1073/pnas.79.8.2554>
- [10] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [11] Cai, W., Santoso, A., Wang, G., *et al.* (2015) ENSO and Greenhouse Warming. *Nature Climate Change*, **5**, 849-859. <https://doi.org/10.1038/nclimate2743>
- [12] Cai, W., Wang, G., Dewitte, B., *et al.* (2018) Increased Variability of Eastern Pacific El Niño under Greenhouse Warming. *Nature*, **564**, 201-206. <https://doi.org/10.1038/s41586-018-0776-9>
- [13] 刘秦玉, 谢尚平, 郑小童. 热带海洋 - 大气相互作用[M]. 北京: 高等教育出版社, 2013: 42-50.

知网检索的两种方式：

1. 打开知网页面 <http://kns.cnki.net/kns/brief/result.aspx?dbPrefix=WWJD>
下拉列表框选择：[ISSN]，输入期刊 ISSN：2168-5711，即可查询
2. 打开知网首页 <http://cnki.net/>
左侧“国际文献总库”进入，输入文章标题，即可查询

投稿请点击：<http://www.hanspub.org/Submission.aspx>

期刊邮箱：ccrl@hanspub.org