

DOI:10.11992/tis.201706015

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20170831.1058.010.html>

基于递归神经网络的风暴潮增水预测

雷森¹, 史振威¹, 石天阳¹, 高松², 李亚茹², 钟山²

(1. 北京航空航天大学 宇航学院图像处理中心, 北京 100191; 2. 国家海洋局 北海预报中心, 山东 青岛 266000)

摘要: 风暴潮增水的准确预测能极大地减少人员伤亡和经济损失, 具有重要的实用价值。传统的风暴潮预报方法主要包括经验和数值预报, 很难建立起相对准确的模型。现有的基于机器学习风暴潮预报方法大都只提取出静态数据间的关系, 并没有充分挖掘出风暴潮数据背后的时序关联特性。文中提出了一种基于递归神经网络的风暴潮增水预测方法。本文对风暴潮时序数据进行特定的处理, 并设计合适结构的递归神经网络, 从而完成时序数据的预测。相较于传统的 BP 神经网络, 递归神经网络能更好地应对时序数据的预测问题。将该方法用于潍坊水站的增水预测中, 结果表明, 相对于 BP 神经网络, 递归神经网络能得到更好的预测结果, 误差更小。

关键词: 风暴潮增水; 预测; 数值预报; 机器学习; 静态数据; 时序特性; BP 神经网络; 递归神经网络

中图分类号: TP751 **文献标志码:** A **文章编号:** 1673-4785(2017)05-0640-05

中文引用格式: 雷森, 史振威, 石天阳, 等. 基于递归神经网络的风暴潮增水预测[J]. 智能系统学报, 2017, 12(5): 640-644.

英文引用格式: LEI Sen, SHI Zhenwei, SHI Tianyang, et al. Prediction of storm surge based on recurrent neural network[J]. CAAI transactions on intelligent systems, 2017, 12(5): 640-644.

Prediction of storm surge based on recurrent neural network

LEI Sen¹, SHI Zhenwei¹, SHI Tianyang¹, GAO Song², LI Yaru², ZHONG Shan²

(1. Image Processing Center, School of Astronautics, Beihang University, Beijing 100191, China; 2. Beihai Forecast Center of State Oceanic Administration, Qingdao 266000, China)

Abstract: Accurately forecasting storm surges can greatly reduce personnel injuries and economic losses, and so has great practical value. Traditional methods for predicting storm surge mainly involve experience and numerical forecasting, which makes it very hard to establish accurate models. Most of today's storm surge forecast methods based on machine learning only extract the relationships among static data and fail to identify the relevant time series properties of these data. In this paper, we propose a storm surge forecast method based on the recurrent neural network. The storm surge data is rearranged with particular treatments, and an appropriate recurrent neural network is designed to perform the prediction of the time series. Compared with traditional BP neural networks, the recurrent neural network can better forecast time series data. In this study, we used a recurrent neural network to predict surges at the Weifang gauge station. The results show that the recurrent neural network produces a better prediction with a smaller error than the BP neural network.

Keywords: storm surge; prediction; numerical forecast; machine learning; static data; temporal properties; BP neural networks; recurrent neural network

风暴潮(storm surge)是一种由于强烈大气扰动,如热带气旋(台风、飓风)、温带气旋等,引起的海面异常升高现象。它具有数小时至数天的周期,通常叠加在正常潮位之上,而风浪、涌浪(具有数秒的周期)则叠加在风暴潮和正常潮位之上。它们的

结合所引起的沿岸海水暴涨常常酿成巨大潮灾^[1]。风暴潮灾害的及时预报能极大地减少其对沿海地区带来的人员伤害和经济损失,具有很强的实用价值。

传统的风暴潮预报方法主要分为两大类:经验预报方法和数值预报方法。经验预报方法通常是指预报员的主观经验和经验统计预报方法,而数值

收稿日期:2017-06-07. 网络出版日期:2017-08-31.

基金项目:国家自然科学基金项目(61671037).

通信作者:史振威.E-mail:shizhenwei@buaa.edu.cn.

预报方法主要包括诺模图方法和数值预报方法^[2]。曾德美^[3]研究了青岛港的风暴潮概况,提出了青岛港极值增减水的经验公式。谢亚力和黄世昌^[4]将风暴潮经验预报与动力线性模型相结合,建立了经验预报方程,并在钱塘江风暴潮预报中取得了不错的效果。高清清等^[2]通过研究位于长江入海口的南通单站历史水文气象资料,分析该站的风暴增水特征,提出了针对该站台风风暴潮经验预报公式。

从20世纪80年代以来,基于数值模拟方法的风暴潮预报技术取得了较大的发展和进步。朱建荣和朱首贤^[5]将原正交的 ECOM 模式改进为非正交曲线坐标系下模式,以更好地拟合河岸线的形状,应用于长江河口、杭州湾及邻近海区,取得了不错的效果。黄世昌等^[6]基于河口海岸水动力二维数值模型,建立起了风暴潮与天文潮相互耦合的数值模式,可用于浙江沿海增水预测。王培涛等^[7]提出了一种基于高级环流模型(ADCIRC)适合台湾海峡及福建沿海区域的精细化台风风暴潮数值预报模式。

然而,基于经验和数值的传统风暴潮预报通常需要研究员对风暴潮的动力学规律具有非常深入的研究,操作复杂难懂,并且很难建立起相对准确的模型。后来,随着计算机技术的发展和大数据时代的到来,许多学者将基于海量数据的机器学习方法用于风暴潮预报中。T. L. Lee^[8]将风速、风向、压强等要素作为输入训练前馈神经网络(feedforward neural network, FNN),用来进行风暴潮的预测。S. Rajasekaran 等^[9]则使用支持向量回归(support vector regression, SVR)来对风暴潮进行预报。

现存的基于机器学习的风暴潮预测方法虽不需要引入风暴潮动力学先验,直接通过数据本身进行预测,但大都只提取出风暴潮数据间的静态关系,并没有充分挖掘其背后的时序关联特性。递归神经网络^[10-12](recurrent neural network, RNN)中隐藏层神经元间相互连接构成有向图,网络状态随时间变化,耦合了时间参数,非常适合分析具有时序特征的数据。受此启发,本文基于递归神经网络来进行风暴潮增水预测。风暴潮是随时间变化发展的,得到的风暴潮数据明显具有时序特性。相比于传统的机器学习方法,递归神经网络更加适用于风暴潮预报问题。本文采用递归神经网络进行风暴潮增水过程预测,并在真实数据上进行了实验验证。

1 原理说明

1.1 前馈神经网络

人工神经网络(artificial neural network, ANN)

是一种常用的进行预报的方法。它是一种应用类似于大脑神经连接的结构进行信号处理的数学模型,广泛应用于语音识别、自然语言处理、图像处理等领域^[13-15]。目前,在大数据分析中主要采用前馈神经网络来提取静态数据之间的关系。

前馈神经网络^[16]是一种具有前向结构的人工神经网络,一般是多层结构,包含输入层、隐含层以及输出层,隐含层可以有多层。每一层神经元的输入是上一层的输出,并通过全连接将其输出传递给下一层,且整个网络中没有反馈。每一个神经元可以是多输入的,但是只有一个输出。多层前馈神经网络是感知器的推广,只要有一层包含足够多神经元的隐含层就能够以任意精度逼近任意复杂度的连续函数^[17]。以3层前馈神经网络为例,结构如图1所示。




图1 多层感知器

Fig.1 Multi-layer perceptron

图1中, L_{in} 表示输入层, $\mathbf{x} = [x_1 \ x_2 \ x_3]^T$ 是多层感知器输入; L_{hidden} 表示隐含层,包含4个神经元,表示为 $\mathbf{h} = [h_1 \ h_2 \ h_3 \ h_4]^T$; L_{out} 是输出层,输出维数为3($\mathbf{y} = [y_1 \ y_2 \ y_3]^T$)。前向传播是指数据从输入到输出这个传播过程,可以用式(1)表示:

$$\begin{aligned} \mathbf{h} &= f(\mathbf{W}_1^T \mathbf{x} + \mathbf{b}_1) \\ \mathbf{y} &= f(\mathbf{W}_2^T \mathbf{h} + \mathbf{b}_2) \end{aligned} \quad (1)$$

式中: $\mathbf{W}_1 \in \mathbb{R}^{3 \times 4}$ 表示输入层和隐含层之间的连接权重, $\mathbf{b}_1 \in \mathbb{R}^{4 \times 1}$ 为隐含层的偏置, $\mathbf{W}_2 \in \mathbb{R}^{4 \times 3}$ 表示隐含层和输出层之间的连接权重, $\mathbf{b}_2 \in \mathbb{R}^{3 \times 1}$ 为输出层的偏置。对于激活函数,通常采用双曲正切函数、logistic函数或sigmoid函数,来使网络获得逼近非线性函数的能力。对于多层前馈神经网络的训练,通常采用著名的误差反向传播(back propagation, BP)算法^[18],因此也常将多层前馈神经网络直接称为BP网络。

虽然多层前馈神经网络能够一定程度上解决非线性问题,但其仍然属于静态网络,网络当前时刻的输出与上一时刻的输入无关,因此对于具有时

序特征的数据无能为力。为了解决输入之间前后关联的问题,多层前馈神经网络的隐含层不仅需要接收当前的输入,也要接收上一时刻的输出,由此产生了递归神经网络。

1.2 递归神经网络

为了克服前馈神经网络无法处理序列数据的问题,递归神经网络将隐含层之间的节点相互连接,使得隐含层的输入不仅仅是当前时刻输入层的输出还包括了上一时刻隐含层的输出。通过这种方式,递归神经网络可以将当前时刻以前的信息记忆在网络之中^[19]。如图2所示,递归神经网络与前馈神经网络的结构大致相同,不同之处在于隐含层之间的连接关系,即增加了隐含层间的权重 W_h 。




图2 递归神经网络

Fig.2 Recurrent neural networks

若 L_{hidden} 隐含层包含 m 个神经元,则 W_h 为 $m \times m$ 维的权重矩阵。递归神经网络的传播过程可以用式(2)表示:

$$\begin{aligned} h_t &= f(W_1^T x + W_h^T h_{t-1} + b_1) \\ y &= f(W_2^T h_t + b_2) \end{aligned} \quad (2)$$

式中: W_1 表示输入层和隐含层之间的连接权重; W_2 表示隐含层和输出层之间的连接权重; b_1 和 b_2 分别表示隐含层和输出层的偏置; x_t 、 h_t 和 y_t 分别表示第 t 时刻网络的输入、隐含层输出和网络的输出; h_{t-1} 表示第 $t-1$ 时刻隐含层的输出。激活函数一般是双曲正切函数或者 Relu 函数。

此外,递归神经网络还可以展开成相对应的多层前馈神经网络,从而可以使用 BPTT (back-propagation through time) 算法^[20]进行训练,展开过程如图3所示。

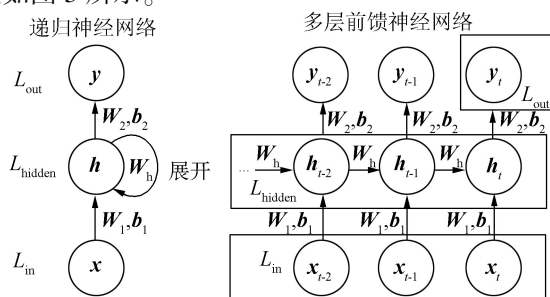


图3 递归神经网络展开过程

Fig.3 The unfolding of recurrent neural networks

若训练样本中包含 T 个时刻的数据,则递归神经网络将展开成一个包含 T 个隐含层的前馈神经网络。理论上来说,递归神经网络可以处理任意长度的序列数据,但是当处理无限长的序列数据时,展开的多层前馈神经网络也是无限层的。因此,在实际应用中通常只假设当前状态与之前有限个状态相关,以降低复杂度。与传统的前馈神经网络不同的是,展开的递归神经网络有如下特点。

1) 每个隐含层的输入都由两部分组成,即对应时刻输入层的输出和上一时刻隐含层的输出。而传统前馈神经网络的输入只能是上一层(隐含层或输入层)的输出。

2) 如图3所示,展开的递归神经网络相同位置的参数 W_1 、 b_1 、 W_2 、 b_2 、 W_h 是共享的,而传统前馈神经网络则是非共享的,这也大大地降低了网络所要学习的参数。

3) 对于递归神经网络,每一个时刻都会给出一个输出,但是并不是必要的,只有 t 时刻的输出 y_t 才是模型的预测结果,其余的输出结果都保存在了隐含层中。

1.3 递归神经网络用于风暴潮增水预测

风暴潮增水数据是一维的时间序列,基于递归神经网络进行预报的具体做法如下。

假设样本数据为 $d = \{d_1, d_2, \dots, d_T\}$, 利用前 k 个数据作为特征预测下一个数据,则可以组成训练样本 X 和标签 y :

$$\begin{aligned} X &= \{x_1, x_2, \dots, x_{T-k}\} = \\ &= \{\{d_1, d_2, \dots, d_k\}, \{d_2, d_3, \dots, d_{k+1}\}, \dots, \{d_{T-k}, d_{T-k+1}, \dots, d_{T-1}\}\} \\ y &= \{y_1, y_2, \dots, y_{T-k}\} = \{d_{k+1}, d_{k+2}, \dots, d_T\} \end{aligned}$$

一般假设当前状态只和前 l 个状态有关,因此再将 X 和 y 进一步按照状态数目分割,制作最终的训练样本 \hat{X} 和相应标签 \hat{y} 。利用 \hat{X} 和 \hat{y} 即可对递归神经网络进行训练。同理,预测时,按照上述步骤制作测试样本,输入到递归神经网络中获得预测值,由此实现风暴潮增水预测。

$$\begin{aligned} \hat{X} &= \{\{x_1, x_2, \dots, x_l\}, \{x_2, x_3, \dots, x_{l+1}\}, \dots, \\ &\quad \{x_{T-k-l+1}, x_{T-k-l+2}, \dots, x_{T-k}\}\} \\ \hat{y} &= \{\{y_1, y_2, \dots, y_l\}, \{y_2, y_3, \dots, y_{l+1}\}, \dots, \\ &\quad \{y_{T-k-l+1}, y_{T-k-l+2}, \dots, y_{T-k}\}\} \end{aligned}$$

2 实验结果

本文的实验数据集是潍坊水站从 2008 ~ 2014 年记录的风暴潮增水过程数据。每个增水过程共历时 3 天,每隔 1 h 记录 1 个水位数据,总计 72 个数据。图4展示了 2008 年里的 2 个增水过程。




图4 风暴潮增水过程

Fig.4 The process of storm surge

使用递归神经网络进行预测时,时间延迟选3,即输入层的神经元数目为3,隐含层的神经元数目为15。训练时,为了避免因为数据的数量级差别而造成递归神经网络预测误差较大,首先对输入数据进行归一化处理,将它们归一化到区间 $[0,1]$ 之中,采用的归一化公式如下:

$$\hat{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

式中: \hat{x} 表示数据归一化后的值; x 为原始数据的值; x_{\max} 和 x_{\min} 分别表示原始数据中最大值和最小值。网络隐含层神经元的激活函数选用双曲正切函数,输出层神经元的激活函数选用线性函数。

本文选取了2008~2013年记录到的31个增水过程当作训练数据,训练得到递归神经网络的参数,并将2014年记录的5个增水过程当作测试数据,对3h后的水位进行预测。如图5所示,实线表示真实的观测值,虚线表示用训练好的递归神经网络预测出的结果。为了便于分析实验结果,将测试数据中的5个增水过程串联在一起进行显示。为了更好地验证递归神经网络对风暴潮增水预测的效果,图6展示了使用BP神经网络进行预测的结果。BP神经网络采用与递归神经网络一样的结构,也是3个输入层单元,15个隐含层单元。

从图5和图6可以看出,相比于BP神经网络,递归神经网络的3h预测结果更加接近真实的观测

值。对于增水过程中的峰值预报,递归神经网络的预测结果较BP神经网络偏离得更小。整体而言,BP神经网络的预测结果波动很大,而递归神经网络的预测结果则相对平滑。




图5 递归神经网络3h预测结果

Fig.5 The prediction of recurrent neural network for 3 hour later




图6 BP神经网络3h预测结果

Fig.6 The prediction of back propagation network (multilayer perceptron) for 3 hour later

本文采用平均绝对误差(mean absolute error, MAE)来定量地评价预测误差,如下式所示:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

式中 y_i 和 \hat{y}_i 分别表示第 i 时刻风暴潮增水的真值和预测值。

从表1中可以看出,随着预测时间的延长,递归神经网络和BP神经网络的预测误差是逐渐升高的。但不管预测时间是多少,递归神经网络的预测精度都优于BP神经网络的预测精度。从中可以看出,相当于BP神经网络,递归神经网络更加适合于对风暴潮增水进行预测。

表1 2014年增水过程预测的平均绝对误差

Table 1 The mean absolute error of the prediction of storm surge in 2014

预测时间/h	1	2	3	4	5	6
递归神经网络/cm	4.71	10.0	15.7	21.0	26.0	30.3
BP神经网络/cm	6.33	15.1	25.2	34.0	40.5	44.5

3 结束语


本文采用递归神经网络对风暴潮增水进行预测。传统的BP神经网络只能用来提取静态数据之间的关系,而由于增添了反馈连接,递归神经网络就更加适合用于时序数据的处理。本文在真实的数据集上进行了验证,结果表明,相对于BP神经网络,递归神经网络能更好地对风暴潮增水进行预测,误差精度更低。

在实验中发现,随着预测时间的增加,递归神经网络预测误差会逐步加大,并且预测结果与真实测量值的相位差会越来越来大。如何采取有效的措施对这一现象进行缓解,是作者下一步需要研究的工作。


参考文献:

- [1] 王喜年. 风暴潮预报知识讲座[J]. 海洋预报, 2001, 18(1): 73-78.
- [2] 高清清, 曹兵, 高鑫鑫, 等. 南通沿海台风风暴潮分析及其经验预报初探[J]. 海洋预报, 2014, 31(1): 29-35.
GAO Qingqing, CAO Bing, GAO Xinxin, et al. Analysis of the typhoon storm surge in the Nantong coastal zone and the forecasting formulas[J]. Marine forecasts, 2014, 31(1): 29-35.
- [3] 曾德美. 青岛港风暴潮经验统计预报[J]. 海洋预报, 1992, 9(3): 66-73.
ZENG Demei. A statistical forecasting of storm surge in qingdao harbor[J]. Marine forecasts, 1992, 9(3): 66-73.
- [4] 谢亚力, 黄世昌. 钱塘江河口风暴潮经验预报[J]. 海洋预报, 2006, 23(1): 54-58.
XIE Yali, HUANG Shichang. Effects on watercourse and hydrological factor in downstream nanxi river due to water diversion[J]. Marine forecasts, 2006, 23(1): 54-58.
- [5] 朱建荣, 朱首贤. ECOM模式的改进及在长江河口、杭州湾及邻近海区的应用[J]. 海洋与湖沼, 2003, 34(4): 364-373.
ZHU Jianrong, ZHU Shouxian. Improvement of the ECOM with application to the changjiang river estuary, Hangzhou bay and adjacent waters[J]. Oceanologia Et limnologia sinica, 2003, 34(4): 364-373.
- [6] 黄世昌, 李玉成, 赵鑫, 等. 浙江沿海超强台风作用下风暴潮增水数值分析[J]. 海洋工程, 2008, 26(3): 58-64.
HUANG Shichang, LI Yucheng, ZHAO Xin, et al. Numerical analysis of storm surge due to a super typhoon in coastal region of Zhejiang province[J]. The ocean engineering, 2008, 26(3): 58-64.
- [7] 王培涛, 于福江, 刘秋兴, 等. 福建沿海精细化台风风暴潮集合数值预报技术研究及应用[J]. 海洋预报, 2010, 27(5): 7-15.
- [8] LEE T L. Neural network prediction of a storm surge[J]. Ocean engineering, 2006, 33(3): 483-494.
- [9] RAJASEKARAN S, GAYATHRI S, LEE T L, et al. Support vector regression methodology for storm surge predictions[J]. Ocean engineering, 2008, 35(16): 1578-1587.
- [10] WILLIAMS R J, ZIPSER D. A learning algorithm for continually running fully recurrent neural networks[J]. Neural computation, 1989, 1(2): 270-280.
- [11] ELMAN J L. Finding structure in time[J]. Cognitive science, 1990, 14(2): 179-211.
- [12] BOTVINICK M M, PLAUT D C. Short-term memory for serial order: a recurrent neural network model[J]. Psychological review, 2006, 113(2): 201-233.
- [13] SAINATH T N, KINGSBURY B, SAON G, et al. Deep convolutional neural networks for large-scale speech tasks[J]. Neural networks, 2015, 64: 39-48.
- [14] SARIKAYA R, HINTON G E, DEORAS A, et al. Application of deep belief networks for natural language understanding[J]. IEEE transactions on audio, speech, and language processing, 2014, 22(4): 778-784.
- [15] KRIZHEVSKY A, SUTSKEVER I, HINTON G E, et al. ImageNet classification with deep convolutional neural networks[C]//International Conference on Neural Information Processing Systems. Nevada, America, 2012: 1097-1105.
- [16] SVOZIL D, KVASNICKA V, POSPICHAL J, et al. Introduction to multi-layer feed-forward neural networks[J]. Chemometrics and intelligent laboratory systems, 1997, 39(1): 43-62.
- [17] HORNIK K, STINCHCOMBE M B, WHITE H, et al. Multilayer feedforward networks are universal approximators[J]. Neural networks, 1989, 2(5): 359-366.
- [18] RUMELHART D E, HINTON G E, WILLIAMS R J, et al. Learning representations by back-propagating errors[J]. Nature, 1988, 323(6088): 533-536.
- [19] KOSMATOPOULOS E B, POLYCARPOU M M, CHRISTODOULOU M A, et al. High-order neural network structures for identification of dynamical systems[J]. IEEE transactions on neural networks, 1995, 6(2): 422-431.
- [20] WERBOS P J. Backpropagation through time: what it does and how to do it[J]. Proceedings of the IEEE, 1990, 78(10): 1550-1560.

作者简介:



雷森,男,1992年生,博士研究生,主要研究方向为图像处理、机器学习、遥感影像质量提升。



史振威,男,1977年生,教授,博士生导师,博士,主要研究方向为图像处理、模式识别、机器学习、遥感影像处理。发表SCI国际期刊检索论文70余篇。



石天阳,男,1994年生,硕士研究生,主要研究方向为机器学习和人工智能。