

文章编号: 1001-0920(2012)07-1057-04

基于混沌和二阶对角递归网络的船舶横摇的直接多步预测方法

李占英^{1,2}, 王科俊¹, 张明君², 徐亮³

(1. 哈尔滨工程大学 自动化学院, 哈尔滨 150001; 2. 大连理工大学城市学院 电子与自动化学院,
辽宁 大连 116600; 3. 大连中远船务工程有限公司 船体车间, 辽宁 大连 116113)

摘要: 在对船舶横摇预测研究的基础上, 提出一种基于混沌和在隐层具有 2 个反馈权值的二阶对角递归神经网络的直接多步预测模型; 给出了易于实现的动量梯度学习算法, 并对其收敛性进行了验证。仿真结果表明, 直接多步预测不依赖于单步预测的结果, 对比单步预测模型能快速、准确地预测船舶横摇运动时间序列, 具有更好的预测精度及较长的预测时间。

关键词: 船舶横摇运动; 对角递归神经网络; 动量梯度学习算法; 时间序列预测; 混沌

中图分类号: TP183

文献标识码: A

Direct multi-step prediction approach of ship rolling based on chaotic and second order diagonal recurrent neural network

LI Zhan-ying^{1,2}, WANG Ke-jun¹, ZHANG Ming-jun², XU Liang³

(1. College of Automation, Harbin Engineering University, Harbin 150001, China; 2. School of Electronic Engineering and Automation, City Institute of Dalian University of Technology, Dalian 116600, China; 3. Cosco Dalian Shipyard Co Ltd, Hull Workshop, Dalian 116113, China. Correspondent: LI Zhan-ying, E-mail: mzzyxl@yahoo.cn)

Abstract: A direct multi-step prediction model based on chaotic and second order diagonal recurrent neural network with two recurrent weights in hidden layer is proposed. A generalized dynamic back-propagation(DBP) algorithm is applied to training, and the convergence of DBP is derived. Simulation results show that, direct multi-step prediction does not depend on the results of single-step prediction, and the proposed network can make a rapid and accurate prediction of the ship rolling time series, and provides more prediction accuracy and more prediction time by comparing to single-step prediction.

Key words: ship rolling motion; diagonal recurrent neural network; dynamic back-propagation; time series prediction; chaos

1 引言

船舶在航行过程中, 不可避免地发生摇荡运动, 在船舶的 6 个自由度摇荡运动中, 横摇对船舶的运动影响最大, 若能准确地预报船舶横摇运动将具有重要的意义。然而由于船舶的摇荡运动的非平稳性、非线性等特性, 用传统的线性预报方法, 很难得到满意的结果。混沌理论利用相空间重构技术来处理历史数据, 使得系统的内部特性能被很好地体现。已有文献证明, 船舶运动具有一定的混沌特性^[1-3], 因此, 利用混沌理论进行船舶运动的预测将会有很大的改进。而神经网络作为一种数据驱动的模型, 能预测高度复杂、非线性、稳定性差的系统, 在时间序列预测方面

具有很大的优越性。本文利用神经网络具有学习能力和非线性逼近能力, 将递归神经网络结合混沌理论应用于船舶横摇运动时间序列。

以往船舶横摇的预测都是基于一步预测的方法, 对于多步预测问题须将得到的预测值作为信息加入到原时间序列中并再次调用该模型, 显然这种方法计算量大, 且存在误差累积效应。为此, 本文在对船舶横摇运动研究的基础上, 提出一种基于混沌和改进的对角递归网络的直接多步预测模型, 直接利用测量数据, 而不是利用单步模型预测的迭加, 所以理论上有更高的预测精度, 而且避免了误差累积效应。

收稿日期: 2010-12-03; 修回日期: 2011-04-01。

基金项目: 国家自然科学基金项目(60975022); 国家863计划项目(2008AA01Z148)。

作者简介: 李占英(1979-), 女, 讲师, 从事智能控制、时间序列预测的研究; 王科俊(1962-), 男, 教授, 博士生导师, 从事人工智能控制、神经网络等研究。

2 二阶对角递归神经网络的算法收敛性

Ku 等^[4]首次提出的对角递归神经网络(DRNN).既具有一般动态网络易于处理动态非线性问题的特点,也具有结构简单、容易构造训练算法的优点.所以,DRNN 神经网络在系统辨识和时间序列预测等方面都得到了广泛的应用^[5-15].然而 DRNN 神经网络的反馈权重只能由当前的状态更新,而不能更多地利用以前的状态,这样对动态系统的实时预测会存在一定的误差.因此 Kazemy 等^[16]在 DRNN 的研究基础上提出了具有 2 个反馈权重的二阶对角递归神经网络(SDRNN),该网络能将更多的历史神经元融入到学习中,并通过实验验证了 SDRNN 比 DRNN 具有更快速、更精确的辨识.

DRNN 神经网络训练中应用最多的一种学习方法是动态 BP 算法(DBP 算法),它是对 BP 算法的一种改进,充分考虑了递归单元对算法的影响.网络的参数通常用梯度下降法来进行调整. DBP 算法在进行参数更新时,参数学习率 η 的选择非常重要.如果 η 较小,则算法的收敛性能够得到保证,但训练速度将非常缓慢;如果 η 太大,则算法不稳定,因而收敛性得不到保证.

在文献[4,17]中,作者利用李雅普诺夫稳定性定理分析了学习率 η 对于 DBP 算法收敛性的影响,并给出了有价值的学习率的调整范围.对于 SDRNN,本文也给出了 η 的调整范围.简单起见,考虑多输入单输出的神经网络,定义离散李雅普诺夫函数为

$$E(k) = \frac{1}{2}(O_d(k) - O(k))^2 = \frac{1}{2}[e(k)]^2. \quad (1)$$

其中: $O_d(k)$ 为理想输出, $O(k)$ 为当前时刻输出, $e(k) = O_d(k) - O(k)$ 为学习过程中的误差.在训练过程中,李雅普诺夫函数的变化为

$$\Delta E(k) = E(k+1) - E(k) = \frac{1}{2}[e^2(k+1) - e^2(k)], \quad (2)$$

则基于李雅普诺夫函数的各层权所通用的学习速率调整算法有如下的收敛定理.

定理 1 令 η_I 为学习率,有

$$0 < \eta_I < \frac{2}{g_{L \max}^2}. \quad (3)$$

其中

$$g_{L \max} = \max_k \|\mathbf{g}_I(k)\|, \quad \mathbf{g}_I(k) = \frac{\partial \mathbf{O}(k)}{\partial \mathbf{W}_I(k)}, \quad (4)$$

$\|\cdot\|$ 定义为欧几里德范数, $\mathbf{W}_I(k)$ 为一个 n 维向量,是网络所有权值所组成的权值矩阵.

定理证明可参见文献[16].

设 $\mathbf{W}_I^I, \mathbf{W}_I^O$ 分别表示网络的输入层权矩阵和输出层权矩阵, $\mathbf{W}_I^{D_1}$ 和 $\mathbf{W}_I^{D_2}$ 表示网络回归层的权矩阵,有

$$\begin{aligned} \mathbf{W}_I &= [[\mathbf{W}_I^I]^T [\mathbf{W}_I^{D_1}]^T [\mathbf{W}_I^{D_2}]^T [\mathbf{W}_I^O]^T]^T, \\ \mathbf{W}_I^I &= [[\mathbf{W}_{I,1}^I]^T [\mathbf{W}_{I,2}^I]^T [\mathbf{W}_{I,3}^I]^T \cdots [\mathbf{W}_{I,p}^I]^T]^T, \\ \mathbf{W}_I^{D_1} &= [[\mathbf{W}_{I,1}^{D_1}]^T [\mathbf{W}_{I,2}^{D_1}]^T \cdots [\mathbf{W}_{I,q}^{D_1}]^T]^T, \\ \mathbf{W}_I^{D_2} &= [[\mathbf{W}_{I,1}^{D_2}]^T [\mathbf{W}_{I,2}^{D_2}]^T \cdots [\mathbf{W}_{I,q}^{D_2}]^T]^T, \\ \mathbf{W}_I^O &= [\mathbf{W}_{I,1}^O]^T. \end{aligned}$$

令 $\eta_I^I, \eta_I^{D_1}, \eta_I^{D_2}, \eta_I^O$ 分别为输入层、隐层及输出层的学习率,有

$$\eta_I = \begin{bmatrix} \eta_I^I \\ \eta_I^{D_1} \\ \eta_I^{D_2} \\ \eta_I^O \end{bmatrix}.$$

定理 2 令 $\eta_I^I, \eta_I^{D_1}, \eta_I^{D_2}$ 和 η_I^O 表示 SDRNN 中各权值矢量 $\mathbf{W}_I^I, \mathbf{W}_I^{D_1}, \mathbf{W}_I^{D_2}, \mathbf{W}_I^O$ 对应的学习率,为保证 DBP 收敛,如果取

$$0 < |\mathbf{W}_{I,j}^{D_1}| < 1, \quad 0 < |\mathbf{W}_{I,j}^{D_2}| < 1, \quad j = 1, 2, \dots, q,$$

则各个学习率按如下方式选择:

$$0 < \eta_I^O < \frac{2}{q}, \quad (5)$$

$$0 < \eta_I^{D_1} < \frac{2}{q} \left[\frac{1}{W_{L \max}^O \Omega_{L \max}} \right], \quad (6)$$

$$0 < \eta_I^I < \frac{2}{p \cdot q} \left[\frac{1}{W_{L \max}^O I_{L \max} \Omega_{L \max}} \right]. \quad (7)$$

其中: p 为输入数, q 为递归神经元个数, $\eta_I^{D_2}$ 同 $\eta_I^{D_1}$,

$$W_{L \max}^O = \max_k \|\mathbf{W}_I^O(k)\|, \quad I_{L \max} = \max_k \|\mathbf{I}_I(k)\|,$$

$$\Omega_{L \max} = \max_k \|\boldsymbol{\Omega}_I(k)\|, \quad \|\mathbf{W}_I^O(k)\| = \max_j |\mathbf{W}_{I,j}^O(k)|,$$

$$\|\boldsymbol{\Omega}_I(k)\| = \max_j |\boldsymbol{\Omega}_{I,j}(k)|,$$

$$\boldsymbol{\Omega}_{I,j}(k) = \frac{|\mathbf{W}_{I,j}^D(k)| \boldsymbol{\Omega}_{I,j}(k-1) + 1}{2}, \quad \boldsymbol{\Omega}_{I,j}(0) = 0,$$

$\mathbf{I}_I(k)$ 为系统在时刻 k 的输入矢量, $\|\cdot\|$ 为欧几里德范数, $j = 1, 2, \dots, q, k = 1, 2, \dots$.

证明 由式(2),令

$$\mathbf{g}_I(k) = \frac{\partial \mathbf{O}(k)}{\partial \mathbf{W}_I(k)} = \mathbf{Z}^I(k),$$

$$\mathbf{Z}^I(k) = [Z_1^I, Z_2^I, \dots, Z_q^I]^T. \quad (8)$$

其中: Z_j^I 为隐层的第 j 个神经元的输出, $0 < Z_j^I < 1, j = 1, 2, \dots, q$. 根据定理 1, $\|\mathbf{g}_I(k)\| < \sqrt{q}$ 且 $g_{L \max}^2 = q$, 则 $0 < \eta_I^O < 2/q$ 成立. 其余证明类似, 此处略. \square

3 基于混沌和二阶对角递归网络的直接多步预测模型

对于具有混沌特性的船舶运动系统,利用传统的时间序列分析方法(如 AR 模型等)很难得到满意的结果,可以利用相空间重构的技术把一维的时间序列重构到具有最佳嵌入维和延迟时间的相空间中,从而在合适的高维相空间中保留系统的演化信息,体现出相

点的运动规律。根据混沌理论进行预测的实质, 即是拟合出相点的演化规律。相点的演化规律具有复杂的非线性, 因而运用具有较好的非线性映射能力的神经网络解决这种问题成为最佳选择。

所谓相空间是指系统中独立变量构成的空间。根据 Takens 嵌入定理, 对于任一 N 点标量时间序列 $x_1, x_2, \dots, x_{N-1}, x_N$, 如果能适当选定嵌入维数 m 和时间延迟 τ , 则重构的相空间为

$$X_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}), i = 1, 2, \dots, M,$$

$$M = N - (m-1)\tau.$$

相空间重构的关键是从时间序列中寻找反映系统动力学特性的参数 m 和 τ 。这 2 个参数的选取比较困难, 方法也各异。经过计算比较, 结合文献 [18] 的方法, 提出计算 m 和 τ 的方法如下: 根据 Grassberger-Procaccia 算法计算出时间序列的关联维 d , 再由 Takens 定理选取嵌入维数 $m = 2d + 1$, 则可根据船舶运动姿态时间序列的关联维数 $D(m)$ 和嵌入维数 m 的关系曲线得知, 当 $m = 8$ 时 $D(m)$ 达到饱和, 此时的 m 即为能够完全展开吸引子结构的最小嵌入维数。对于时间延迟 τ , 通过用互信息法计算可得到最佳延迟时间为 $\tau = 2$ 。

预测步骤如下:

1) 根据上述相空间重构参数的选取, 建立混沌时间序列的多维相空间, 构成学习样本和教师值。

2) 确定二阶对角递归神经网络的结构。输入层神经元数等于嵌入维 m , 输出层神经元数取决于直接预测的步数 q , 隐层神经元数 h 通过实验可得, 也可通过如下经验公式获得:

$$h = \sqrt{m+q} + \alpha, \alpha \text{ 为常量.}$$

3) 网络的学习和训练。 $X_i(m)$ 作为网络的输入, $X_i(m+l)$ ($l = 1, 2, \dots, q$) 作为样本输出进行训练, 直到误差控制在允许范围内。

4) 模型的预测。选取 m 个相点作为输入, 则相应的 $m+l$ ($l = 1, 2, \dots, q$) 即为输出。

鉴于此, 本文所用的基于混沌和二阶对角递归神经网络的直接多步预测的模型如图 1 所示。输出为线性神经元。

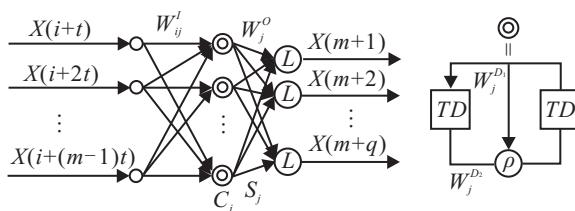


图 1 直接多步预测模型

4 仿真实验

以某舰船横摇运动时间序列预测为例, 以 Matlab7.1 为平台, 用基于混沌和二阶对角递归神经网络直接多步预测模型对船舶横摇运动时间序列进行预测仿真。所用数据取自我国某型船舶在 90° 横浪航行情况的实验数据, 共 1013 个数据, 取前 800 个样本作为训练集, 后 213 个数据用来测试。如第 3 节中所述嵌入维取 $m = 8$, $\tau = 2$, 隐层神经元数为 10, 多步预测以 30 步直接预测为例, 单步预测结果和预测相对误差如图 2 和图 3 所示。

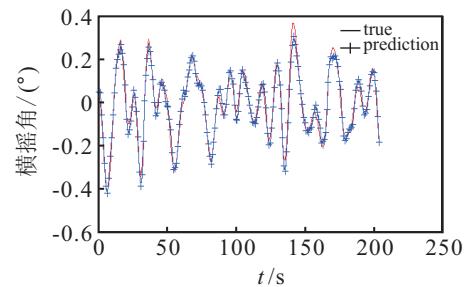


图 2 船舶横摇单步预测分析

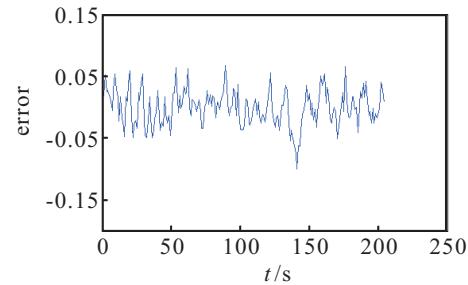


图 3 船舶横摇单步预测相对误差

为了清楚地对比 2 种预测方法的预测效果, 放大单步预测的前 30 个样本, 效果见图 4。如果用于直接 30 步预测, 则预测结果如图 5 所示。

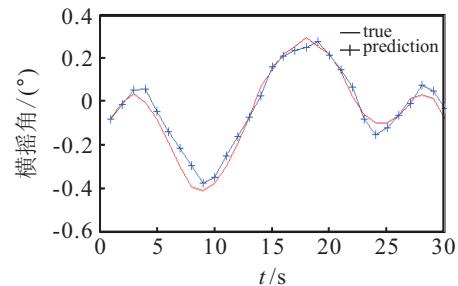


图 4 单步预测的前 30 个预测样本

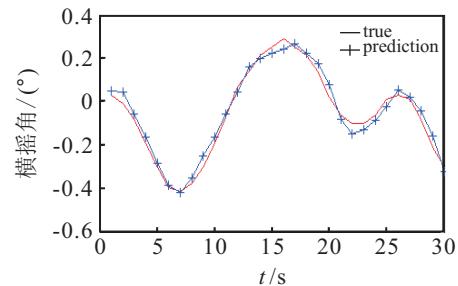


图 5 直接 30 步预测效果

由图 4 和图 5 可知, 直接多步预测的效果明显好于单步预测的效果.

为了对上述模型预测结果进行定量分析, 本文还给出了模型预测的均方根误差对比, 定义如下:

$$\text{RMS} = \sqrt{\sum_{i=1}^T (y_{id} - y_i)^2 / T}. \quad (9)$$

其中: y_{id} 为预测值, y_i 为实测值, T 为预测步数.

与单步迭代预测方法对比, 预测结果分析如表 1 所示. 表 1 中预测均方根误差的对比分析表明, 随着预测步数的增加, 预测误差加大, 可见不适宜长期预测; 同一预测步数时, 直接多步预测的预测精度明显好于单步预测.

表 1 预测结果定量对比

预测步数	10	20	30
直接多步预测 (RMS)	0.01	0.0102	0.012
单步预测 (RMS)	0.0102	0.014	0.0263

5 结 论

本文针对船舶横摇运动时间序列预测, 提出了一种基于混沌和二阶对角递归神经网络的新的直接多步预测方法. 该方法将混沌理论与对角递归神经网络相结合, 利用相空间重构技术重构船舶横摇序列的历史数据, 作为二阶对角递归网络的输入. 经过训练后, 将所构建的模型用于船舶横摇的直接多步预测, 实验结果显示所提出的方法对比单步预测有较高的预测精度, 具有很好的实用性. 本文所用的方法也适用于其他船舶摇荡预测. 鉴于混沌序列不可长期预测, 在未来的研究中仍需要进行深入研究和探讨, 选取更有效的模型延长预测时间.

参考文献(References)

- [1] Nayfeh A H, Khdeira A. Nonlinear rolling of ships in regular beam seas[J]. Int Shipbuilding Progress, 1986, 33(379): 40-49.
- [2] 欧阳茹荃, 朱继懋. 船舶非线性横摇运动与混沌[J]. 中国造船, 1999, 2(1): 21-28.
(Ouyang R Q, Zhu J M. Nonlinear oscillations and chaos of ship rolling motion[J]. Shipbuilding of China, 1999, 2(1): 21-28.)
- [3] Feng Cai, Aiguo Shi, Lin Wan. Chaotic dynamics analysis of ship swaying motion[J]. J of Dalian Naval Academy, 2006, 29(5): 36-39.
- [4] Ku Chao-Chee, Lee Kwang. Diagonal recurrent neural networks for dynamic systems control[J]. IEEE Trans on Neural Networks, 1995, 6(1): 144-156.
- [5] 王科俊. 神经网络几十理论问题的研究及其在船舶横摇运动建模与预报中应用[D]. 哈尔滨: 哈尔滨工程大学自动化学院, 1995.
(Wang K J. Study of several problems in theory of neural networks and its application in ship roll modelling and predication[D]. Harbin: Harbin Engineering University, 1995.)
- [6] 王科俊, 李国斌. DRNN 神经网络用于船舶横摇运动的时间序列预报[J]. 哈尔滨工程大学学报, 1997, 18(1): 39-45.
(Wang K J, Li G B. Time series prediction of ship roll using diagonal recurrent neural network[J]. J of Harbin Engineering University, 1997, 18(1): 39-45.)
- [7] Liu Sheng, Du Yan-chun, Li Wan-long, et al. Sonar array servo system based on diagonal recurrent neural network[C]. IEEE Int Conf Mechatronics and Automatic. Ontario: IEEE, 2005: 1912-1917.
- [8] Shaosheng F, Xiao Hui. Diagonal recurrent neural network based predictive control for active power filter[C]. 2004 Int Conf on Power System Technology-PowerCon. Singapore: IEEE, 2004: 759-762.
- [9] Bambang R T, Yacoub R R, Uchida K. Identification of secondary path in ANV using diagonal recurrent neural networks with EKF algorithm[C]. The 5th Asian Control Conf on Melbourne. Australia: IEEE, 2004: 665-673.
- [10] Ku C C, Lee K Y, Edwards R M. Improved nuclear reactor temperature control using diagonal recurrent neural networks[J]. IEEE Trans on Nuclear Science, 1992, 39(6): 2298-2308.
- [11] Jayawardhana B, Xie Li-hua, Yuan Shuq-ing. Active control of sound based on diagonal recurrent neural network[C]. Conf on the Society of Instrument and Control Engineers. Osaka: IEEE, 2002: 2666-2671.
- [12] Cho J S, Kim Y W, Park D J. Identification of nonlinear dynamic systems using higher order diagonal recurrent neural network[J]. Electronic Letters, 1997, 33(25): 2133-2135.
- [13] Wang Xuesong, Peng Guang-zheng, Xue Yang. Internal model controller with diagonal recurrent neural network for pneumatic robot servo system[C]. IEEE Int Symp Comput Int in Robotics and Automat. Kobe: IEEE, 2003: 1064-1069.
- [14] Mastorocostas P A, Theocharis J B. On stable learning of block diagonal recurrent neural networks, Part I: The renncom algorithm[C]. IEEE Int Joint Conf on Neural Networks. Budapest: IEEE, 2004: 815-820.
- [15] Mastorocostas P A, Theocharis J B. On stable learning of block diagonal recurrent neural networks, Part II: Application to the analysis of lung sounds[C]. IEEE Int Joint Conf on Neural Networks. Budapest: IEEE, 2004: 821-826.

(下转第 1065 页)