

多元混沌时间序列的加权极端学习机预测

韩 敏[†], 王新迎

(大连理工大学 电子信息与电气工程学部, 辽宁 大连 116023)

摘要: 针对多元混沌时间序列具有强非线性, 难以建立数学模型进行准确预测的问题, 本文提出一种加权极端学习机预测算法。首先对多元混沌时间序列进行相空间重构, 并根据相空间中输入数据对预测误差的影响施加不同的权重。然后, 提出一种支持向量极端学习机预测模型, 具有支持向量机的核映射表达能力以及极端学习机的一步快速训练能力, 因此训练简便且具有较好的泛化性能。所提算法具有和训练样本三次方成正比的计算复杂度, 因此适用于 $10^2 \sim 10^3$ 样本规模的平稳时间序列。基于Lorenz混沌时间序列和年太阳黑子和黄河年径流混沌时间序列预测的仿真结果证明所提算法的有效性。

关键词: 时间序列; 预测; 极端学习机; 支持向量机; 样本加权

中图分类号: TP183 文献标识码: A

Multivariate chaotic time series prediction based on weighted extreme learning machine

HAN Min[†], WANG Xin-ying

(Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian Liaoning 116023, China)

Abstract: Considering the strong nonlinear property of the multivariate chaotic time series and difficulties in mathematical model building for accurate prediction, we propose a weighted extreme learning machine (ELM) prediction model. Firstly, the multivariate chaotic time series are reconstructed in the phase space, and the instances in prediction window are weighted according to their influence on the prediction errors. A support-vector extreme learning machine prediction model is proposed, which combines both the kernel mapping ability of support-vector machines and the one-step fast training advantage of extreme learning machine, so that it is easy to conduct and has good generalization performance. The computational complexity of the proposed algorithm is proportional to the cube of the training sample. Therefore, it is suitable for stationary time series with $10^2 \sim 10^3$ sample size. The effectiveness of the proposed model are demonstrated by simulation results based on Lorenz chaotic time series, annual sunspots, and the runoff of the Yellow River chaotic time series.

Key words: time series; prediction; extreme learning machine; support-vector machines; weighted instances

1 引言(Introduction)

混沌时间序列预测是目前非线性科学研究领域的一个研究热点, 并已在复杂系统建模和非线性系统预测控制等方面取得了成功地应用^[1-3], 如电力系统短期负荷预测^[4]、短期交通流预测^[5]、税收预测^[6]。同时, 与单元时间序列相比, 多元时间序列包含更多的系统动态特征^[7-8]。因此, 对多元混沌时间序列进行建模预测已成为科学和工程领域的一个研究重点^[9-11]。

神经网络因具有较强的非线性处理能力, 已成为混沌时间序列预测的一种有效方法^[12-15]。然而神经网络的预测建模精度及更广泛的应用一直制约于其本身存在的训练速度慢、易陷入局部最优等缺陷。极

端学习机(extreme learning machine, ELM)^[16]是最近发展起来的一种有效的神经网络学习方法, 克服了传统神经网络的缺陷, 在混沌时间序列建模预测等领域取得了较好的应用^[17]。

极端学习机网络隐含层节点个数对其建模预测效果具有较大的影响, 通常需采用试错法或交叉检验等方法对其进行选择, 计算量通常较大。另一方面, 支持向量机(support vector machine, SVM)作为非线性建模领域中的另一类重要方法, 采用核函数隐式表达特征空间中的内积, 并可将其求解表征为凸优化问题, 克服了传统神经网络存在的隐含层节点难以选择和局部最小等问题^[18-19], 但支持向量机在某些情况下也

收稿日期: 2013-03-06; 收修改稿日期: 2013-05-22。

[†]通信作者. E-mail: minhan@dlut.edu.cn; Tel.: +86 411-84708719.

基金项目: 国家自然科学基金资助项目(61074096)。

存在训练较为复杂的问题。基于以上分析，本文将极端学习机与支持向量机相结合，将支持向量机中的核函数映射替换为极端学习机中的隐含层映射，构造一种支持向量极端学习机预测模型，避免隐含层节点的选择问题并保留极端学习机模型的训练简便优点。同时考虑到多元混沌序列预测时间窗内样本点可能来自于不同的底层分布^[11]，对时间窗内的样本点施加不同的权重，以进一步提高建模预测精度。

2 多元混沌时间序列和极端学习机(Multivariate chaotic time series and extreme learning machine)

2.1 多元混沌时间序列相空间重构(Multivariate chaotic time series phase space reconstruction)

给定 M 维多元混沌时间序列 $x(1), x(2), \dots, x(N)$ ，其中 $x(i) = (x_1(i), x_2(i), \dots, x_M(i))$, $i = 1, 2, \dots, N$ 。对该多元时间序列进行相空间重构有

$$\begin{aligned} D(n) = & \\ & \{x_1(n), x_1(n - \tau_1), \dots, x_1(n - (d_1 - 1)\tau_1), \\ & x_2(n), x_2(n - \tau_2), \dots, x_2(n - (d_2 - 1)\tau_2), \dots, \\ & x_M(n), x_M(n - \tau_M), \dots, x_M(n - (d_M - 1)\tau_M)\}, \end{aligned} \quad (1)$$

其中 $\tau_i, d_i (i = 1, \dots, M)$ 是 i 维混沌时间序列的延迟时间和嵌入维数。由嵌入延时定理^[20]可知：若 d 或 d_i 充分大，则存在一个映射 $F : \mathbb{R}^d \rightarrow \mathbb{R}^d (d = \sum_{i=1}^M d_i)$ 使得

$$D(n+1) = F(D(n)). \quad (2)$$

上式也可写为

$$\begin{cases} x_1(n+1) = F_1(D(n)), \\ x_2(n+1) = F_2(D(n)), \\ \vdots \\ x_M(n+1) = F_M(D(n)). \end{cases} \quad (3)$$

由式(3)，延迟时间 $\tau_i (i = 1, \dots, M)$ 和嵌入维数 d_i 确定好以后，重构相空间内的多变量数据即可用于建模预测。可采用信息熵^[21]等方法确定延迟时间 τ 和嵌入维数 d 。

2.2 极端学习机(Extreme learning machine)

极端学习机^[16]是一种新的前馈神经网络模型。图1给出了相应的结构示意图。数学表达式如下式所示：

$$o_k = w^T g(W_{\text{in}} \cdot x_k + b), \quad k = 1, 2, \dots, N, \quad (4)$$

其中： W_{in} 为输入权值， b 为隐含层偏置值， w 为输出权值， g 为激活函数，一般取Sigmoid函数， N 为样本个数， x_k 为 m 维输入向量， o_k 为输出向量，本文采用单输出形式。输入权值 W_{in} 和偏置值 b 随机初始化，并在训

练过程中保持不变。输出权值 w 是唯一需要训练确定的参数，可采用如下算法确定：

$$w = H^{\dagger} T, \quad (5)$$

其中： \dagger 为广义逆运算，

$$H = \begin{bmatrix} g(W_{\text{in}} x_1 + b_1) & \cdots & g(W_{\text{in}} x_1 + b_n) \\ \vdots & \ddots & \vdots \\ g(W_{\text{in}} x_N + b_1) & \cdots & g(W_{\text{in}} x_N + b_n) \end{bmatrix}_{N \times n}$$

为极端学习机的隐含层输出矩阵； $T = (t_1, t_2, \dots, t_N)^T$ 为期望输出向量。

由式(5)可知，极端学习机的训练过程即一个简单的线性回归过程，其有效克服了传统神经网络固有的缺陷。

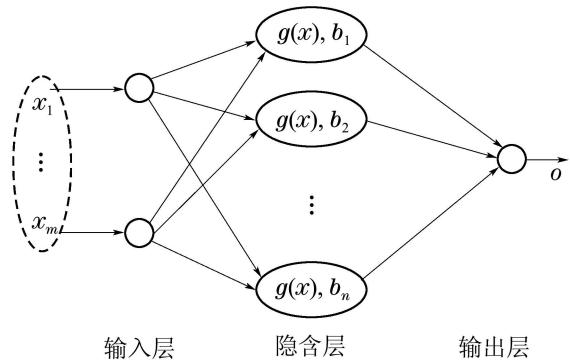


图1 极端学习机结构示意图

Fig. 1 Structure of extreme learning machine

3 加权极端学习机(Weighted extreme learning machine)

影响极端学习机预测建模性能的一个重要参数即隐含层节点个数，通常需要根据训练任务的不同，采用较为繁琐的交叉检验方法进行选择。Schrauwen和Williams等学者已经证明^[22-23]：具有无穷个隐节点的神经网络与支持向量机方法是等价的，而具有有限隐节点的神经网络可看作是支持向量机方法的低维逼近。为避免极端学习机模型中隐节点选择问题，本文将支持向量机中的核函数映射 $\varphi(x)$ 由极端学习机中的隐含层节点映射 $h(x)$ 替代，对支持向量机进行低维逼近，以此构建支持向量极端学习机模型。如果隐层特征映射 $h(x)$ 是未知的，可对极端学习机定义如下的核矩阵：

$$\begin{aligned} \Omega_{\text{ELM}} &= HH^T : \\ \Omega_{\text{ELM}i,j} &= h(x_i) \cdot h(x_j) = K(x_i \cdot x_j), \end{aligned} \quad (6)$$

相应的输出函数可以重写为

$$\begin{aligned} f(x) &= h(x)H^T \left(\frac{I}{C} + HH^T \right)^{-1} T = \\ & \left[\begin{array}{c} K(x \cdot x_1) \\ \vdots \\ K(x \cdot x_N) \end{array} \right]^T \left(\frac{I}{C} + \Omega_{\text{ELM}} \right)^{-1} T, \end{aligned} \quad (7)$$

其中 C 为正则化系数, 以平衡模型精度和模型复杂度.

在该极端学习机的特殊核实现中, 隐层特征映射 $h(x)$ 可以是未知的, 但通常给出相应的核 $K(u, v)$ (例如 $K(u, v) = \exp(-\gamma \|u - v\|^2)$). 因此, 不再需要确定隐层节点数 L (隐层特征空间的维数).

在传统时间序列预测方法中, 预测时间窗内的样本点对预测点的影响是相同的. 然而, 实际情况下, 预测时间窗内的样本点对预测点的影响是具有差异的, 尤其是在多元混沌时间序列预测建模中, 预测时间窗内的样本点通常来自于不同的底层分布, 具有异方差性. 基于此, 本文考虑对这些样本点施加不同的权重, 以进一步提高建模预测的精度.

通过权重因子 v_k 对支持向量极端学习机中误差变量 $e_k = \alpha_k/C$ 进行加权, 得到加权极端学习机(weighted extreme learning machine, WELM)的优化问题:

$$\min J(w^*, e^*) = \frac{1}{2} w^{*\top} w^* + \frac{1}{2} C \sum_{k=1}^N v_k e_k^{*2}. \quad (8)$$

由式(7)可得

$$f(x) = \begin{bmatrix} K(x \cdot x_1) \\ \vdots \\ K(x \cdot x_N) \end{bmatrix}^T (V_C + \Omega_{\text{ELM}})^{-1} T, \quad (9)$$

其中 $V_C = \text{diag}\{\frac{1}{Cv_1}, \dots, \frac{1}{Cv_N}\}$.

在本文中, 权重因子 v_k 选为

$$v_k = \frac{\hat{\sigma}}{|e_k|}, \quad (10)$$

其中: $e_k = y_k - f(x_k)$ 为真实值与预测值之间的残差, $\hat{\sigma} = \sqrt{\frac{1}{n} \sum_{k=1}^n e_k^2}$ 为样本噪声的标准差估计.

式(9)给出了加权极端学习机的模型方程, 与式(7)的支持向量极端学习机相比, 每个样本点被施加了不同的权重.

因此, 基于加权极端学习机的多元混沌时间序列预测算法可以总结如下:

步骤1 对多元混沌时间序列进行归一化预处理, 并确定合适的重构参数进行相空间重构.

步骤2 确定 $K(u, v)$, 初始化支持向量极端学习机.

步骤3 按照式(10)对样本进行加权, 确定训练和测试样本集.

步骤4 利用加权的训练样本集对支持向量极端学习机进行训练.

步骤5 判断

$$\frac{1}{n} \sum_{i=1}^n |(e_i^{\text{old}} - e_i)/e_i^{\text{old}}| \leq 10^{-3}$$

是否成立, 若成立转步骤6, 否则转步骤3.

步骤6 利用训练好的支持向量极端学习机在测试样本上进行预测.

步骤7 对预测结果进行反归一化, 计算预测误差.

本文所提算法的主要计算量在 $(V_C + \Omega_{\text{ELM}})$ 的求逆计算, 计算复杂度为 $O(N^3)$, 其中 N 为样本个数. 本文算法在 $10^2 \sim 10^3$ 数量级平稳时间序列数据中具有较好的运算效率, 对于 10^4 数量级以上大规模时间序列数据可采用图2所示的滑动时间窗方法进行局部预测.

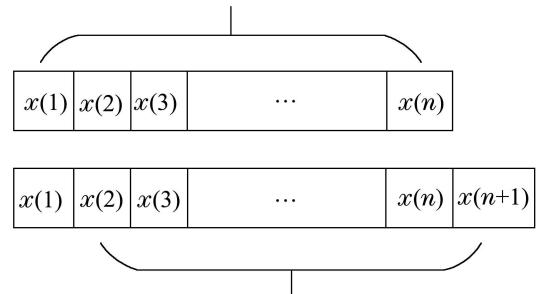


图2 时间序列预测的滑动时间窗方法

Fig. 2 Sliding window method for time series prediction

4 仿真实例(Simulation examples)

为验证本文所提方法的有效性, 将本文所提基于加权极端学习机的多元混沌时间序列预测方法分别应用于Lorenz三元混沌系统和年太阳黑子-黄河年径流二元混沌时间序列预测中. 为对不同建模方法的预测性能进行定量比较, 引入均方根误差(root mean square error, RMSE):

$$\text{RMSE} = \left(\frac{1}{S-1} \sum_{t=1}^S [P_t - O_t]^2 \right)^{1/2},$$

其中: S 为样本个数, O_t 为实际观测值, P_t 为预测输出值. 仿真实验中, 正则化系数 C 初始化为1.

4.1 Lorenz混沌时间序列(Lorenz chaotic time series)

式(11)为三维Lorenz混沌方程, 当取参数 $a = 10$, $b = 8/3$, $c = 28$ 和初始值 $x(0) = y(0) = z(0) = 1.0$ 时, 系统产生混沌. 本文采用四阶Runge-Kutta法迭代产生相应的三元混沌时间序列, 如图3所示.

采用 $x(t)$, $y(t)$ 和 $z(t)$ 序列共同分别预测 $x(t+1)$, $y(t+1)$, $z(t+1)$.

$$\begin{cases} \dot{x} = a(y - x), \\ \dot{y} = (c - z)x - y, \\ \dot{z} = xy - bz. \end{cases} \quad (11)$$

仿真实验的参数设置如表1所示. 表2给出了本文所提方法和其他最新提出的混沌时间序列预测方法

的比较,从表2中可以看出文献[24]提出的将高斯过程与回声状态网络相结合的回声状态高斯过程(echo state Gaussian process, ESGP)方法、文献[25]提出的具有核形式的极端学习机(extrem learning machine with kernels, ELMK)方法以及文献[26]提出的将支持向量机与回声状态网络相结合的支持向量回声状态机(support vector echo state machine, SVESM)方法和本文所提方法取得的预测精度在同一数量级上。而在4种方法中,本文所提方法预测取得了最小的预测误差,说明本文所提方法更具有有效性。

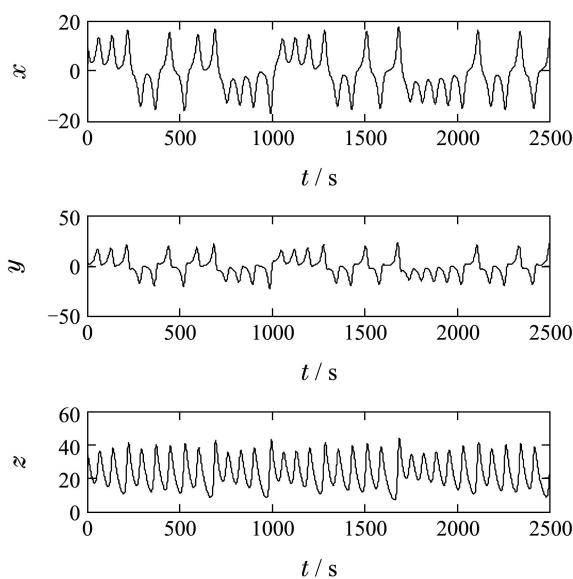


图3 Lorenz三元混沌时间序列

Fig. 3 Lorenz three variables chaotic time series

表1 Lorenz- $x(t)$ 仿真参数设置

Table 1 Lorenz- $x(t)$ simulation parameter settings

延迟时间	嵌入维数	训练	测试
$\tau_{1,2,3} = 19, 13, 12$	$m_{1,2,3} = 3, 5, 7$	2000	428

表2 Lorenz- $x(t)$ 仿真预测结果比较

Table 2 Lorenz simulation prediction results

RMSE	ESGP ^[24]	ELMK ^[25]	SVESM ^[26]	WELM
Lorenz- $x(t)$	0.0017	0.0016	0.0018	0.0015

图4~6分别给出了仿真实际曲线和本文所提方法的预测曲线以及相应的预测误差曲线,从图中可以看出,所提方法的预测曲线在测试数据上较好地拟合了实际曲线。

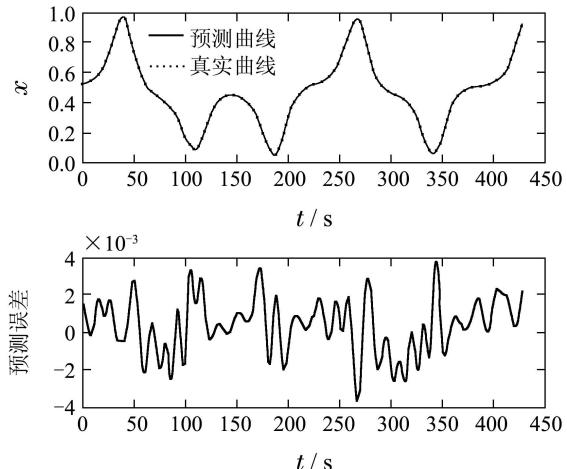


图4 Lorenz- $x(t)$ 预测(RMSE = 0.0015)与误差曲线
Fig. 4 Lorenz- $x(t)$ prediction (RMSE = 0.0015) and error curves

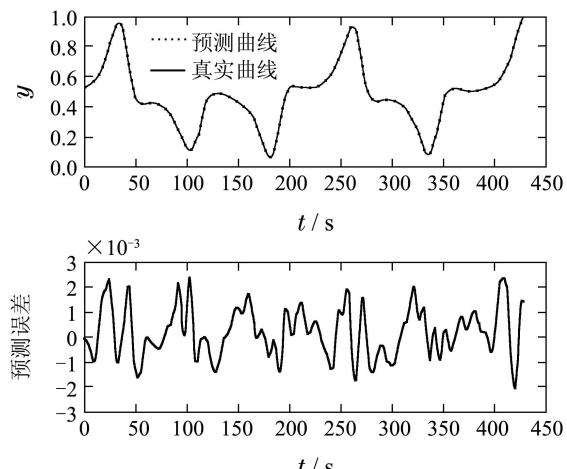


图5 Lorenz- $y(t)$ 预测(RMSE = 0.0018)与误差曲线
Fig. 5 Lorenz- $y(t)$ prediction (RMSE = 0.0018) and error curves

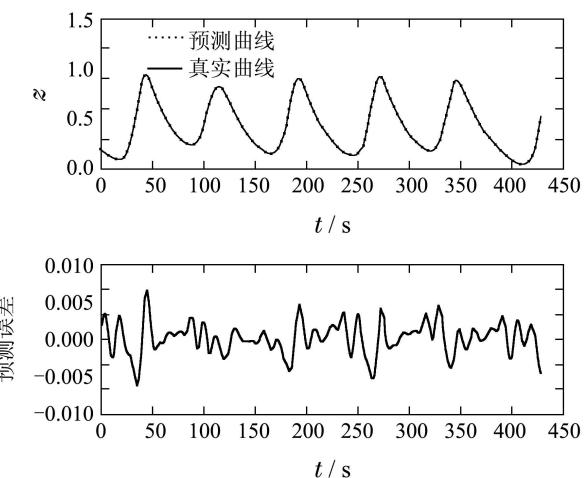


图6 Lorenz- $z(t)$ 预测(RMSE = 0.0022)与误差曲线
Fig. 6 Lorenz- $z(t)$ prediction (RMSE = 0.0022) and error curves

4.2 年太阳黑子-黄河年径流混沌时间序列 (Annual sunspots and runoff of the Yellow River chaotic time series)

将所提方法应用到年太阳黑子和黄河径流二元混沌时间序列的预测中, 样本区间为1700年~2003年太阳黑子与黄河径流二元混沌时间序列数据, 如图7.

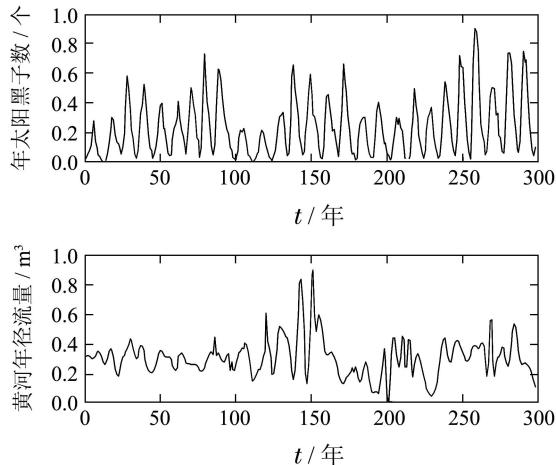


图7 年太阳黑子和黄河年径流时间序列

Fig. 7 Annual sunspots and runoff of the Yellow River chaotic time series

仿真实验的参数设置如表3所示. 表4给出了本文所提方法和其他最新提出的混沌时间序列预测方法的比较, 从表4中可以看出, 在太阳黑子序列中, 本文所提方法与ELMK和SVESM方法取得了几乎相近的预测结果, 其中SVESM方法取得了最好的预测精度, 而ESGP方法取得预测误差较大. 在黄河年径流序列中, ESGP与SVESM方法预测结果相近, 而本文所提方法和ELMK方法相近且预测误差要小于ESGP和SVESM方法, 其中本文所提方法在4种方法中取得了最小的预测误差. 以上预测仿真结果比较分析说明本文所提方法的有效性.

表3 年太阳黑子和黄河年径流仿真参数设置
Table 3 Annual sunspots and runoff of Yellow River simulation parameter settings

延迟时间	嵌入维数	训练	测试
$\tau_{1,2} = 19, 13$	$m_{1,2} = 3, 5$	200	52

表4 年太阳黑子和黄河年径流仿真预测结果比较
Table 4 Annual sunspots and runoff of Yellow River simulation prediction results

RMSE	ESGP ^[24]	ELMK ^[25]	SVESM ^[26]	WELM
太阳黑子/个	20.5946	15.950	15.404	15.946
黄河径流/ m^3	44.259	27.558	48.569	26.077

图8-9分别给出了实际曲线和本文所提方法的仿真预测曲线以及相应的预测误差曲线, 从图中可以看

出, 所提算法的预测曲线在测试数据上较好地拟合了实际值, 证明所提方法的有效性.

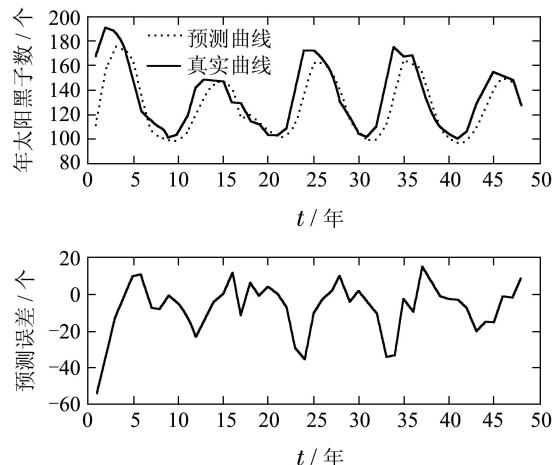


图8 年太阳黑子预测($RMSE = 15.946$)与误差曲线

Fig. 8 Annual sunspots prediction ($RMSE = 15.946$) and error curves

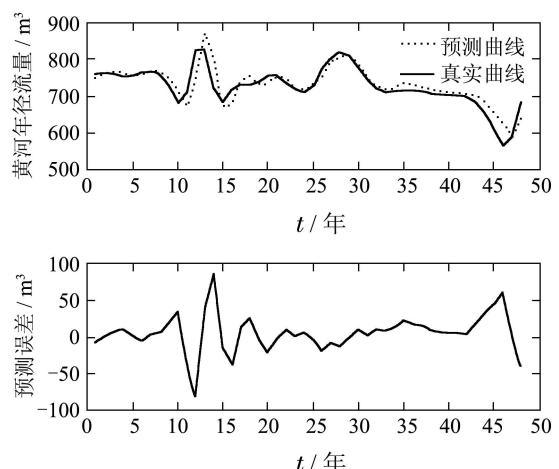


图9 黄河年径流预测($RMSE = 26.077$)与误差曲线

Fig. 9 Runoff of the Yellow River prediction ($RMSE = 26.077$) and error curves

5 结论(Conclusion)

本文针对多元混沌时间序列预测问题, 提出一种加权极端学习机预测模型, 克服了传统神经网络预测模型训练困难和容易陷入局部最优的问题, 并避免了极端学习机模型难以确定隐节点个数的不足. 为进一步提高预测精度, 对预测时间窗内的样本点施加不同的权重. 基于Lorenz和年太阳黑子-黄河年径流的多元混沌时间序列预测仿真实验证明所提方法的有效性.

参考文献(References):

- [1] 穆朝絮, 张瑞民, 孙长银. 基于粒子群优化的非线性系统最小二乘支持向量机预测控制方法 [J]. 控制理论与应用, 2010, 27(2): 164–168.
(MU Chaoxu, ZHANG Ruimin, SUN Changyin. LS-SVM predictive control based on PSO for nonlinear system [J]. Control Theory & Application, 2010, 27(2): 164–168.)

- control based on PSO for nonlinear systems [J]. *Control Theory & Applications*, 2010, 27(2): 164 – 168.)
- [2] 部传厚, 漆令, 陈积明, 等. 复杂高炉炼铁过程的数据驱动建模及预测算法 [J]. 自动化学报, 2009, 35(6): 725 – 730.
(GAO Chuanhou, JIAN Ling, CHEN Jiming, et al. Data-driven modeling and predictive algorithm for complex blast furnace ironmaking process [J]. *Acta Automatica Sinica*, 2009, 35(6): 725 – 730.)
- [3] 高鹰, 谢胜利. 一种变步长LMS自适应滤波算法及分析 [J]. 电子学报, 2001, 29(8): 1094 – 1097.
(GAO Ying, XIE Shengli. A variable step size LMS adaptive filtering algorithm and its analysis [J]. *Acta Electronica Sinica*, 2001, 29(8): 1094 – 1097.)
- [4] 吕金虎, 张锁春. 加权一阶局部法在电力系统短期负荷预测中的应用 [J]. 控制理论与应用, 2002, 19(5): 767 – 770.
(LV Jinhu, ZHANG Suochun. Application of adding-weight one-rank local-region method in electric power system short-term load forecast [J]. *Control Theory & Applications*, 2002, 19(5): 767 – 770.)
- [5] 齐驰, 侯忠生. 自适应单指数平滑法在短期交通流预测中的应用 [J]. 控制理论与应用, 2012, 29(4): 465 – 469.
(QI Chi, HOU Zhongsheng. Application of adaptive single-exponent smoothing for short-term traffic flow prediction [J]. *Control Theory & Applications*, 2012, 29(4): 465 – 469.)
- [6] 张绍秋, 胡跃明. 基于BP神经网络的税收预测模型 [J]. 华南理工大学学报(自然科学版), 2006, 34(6): 55 – 58.
(ZHANG Shaoqiu, HU Yueming. Taxation forecasting model based on BP neural network [J]. *Journal of South China University of Technology(Natural Science Edition)*, 2006, 34(6): 55 – 58.)
- [7] CAO L, MEES A, JUDD K. Dynamics from multivariate time series [J]. *Physica D: Nonlinear Phenomena*, 1998, 121(1/2): 75 – 88.
- [8] 席剑辉, 韩敏. 主成分分析与神经网络的结合在多变量序列预测中的应用 [J]. 控制理论与应用, 2007, 24(5): 719 – 724.
(XI Jianhui, HAN Min. Prediction of multivariate time series based on principal component analysis and neural networks [J]. *Control Theory & Applications*, 2007, 24(5): 719 – 724.)
- [9] CHAKRABORTY K, MEHROTRA K, MOHAN C K, et al. Forecasting the behavior of multivariate time series using neural networks [J]. *Neural Networks*, 1992, 5(6): 961 – 970.
- [10] POPESCU F. Robust statistics for describing causality in multivariate time series [J]. *Journal of Machine Learning Research*, 2011, 12: 30 – 64.
- [11] YOON H, YANG K, SHAHABI C. Feature subset selection and feature ranking for multivariate time series [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2005, 17(9): 1186 – 1198.
- [12] 黎明, 张化光. 基于粗糙集的神经网络建模方法研究 [J]. 自动化学报, 2002, 28(1): 27 – 33.
(LI Ming, ZHANG Huaguang. Research on the method of neural network modeling based on rough sets theory [J]. *Acta Automatica Sinica*, 2002, 28(1): 27 – 33.)
- [13] JAMSHIDI A A, KIRBY M J. Modeling multivariate time series on manifolds with skew radial basis functions [J]. *Neural Computation*, 2011, 23 (1): 97 – 123.
- [14] 徐耀玲, 戴汝为. 人工神经元网络在系统辨识中的应用 [J]. 自动化学报, 1991, 17(1): 91 – 94.
- (XU Yaoling, DAI Ruwei. An application of artificial neural network to system identification [J]. *Acta Automatica Sinica*, 1991, 17(1): 91 – 94.)
- [15] 张冬青, 宁宣熙, 刘雪妮. 基于RBF神经网络的非线性时间序列在线预测 [J]. 控制理论与应用, 2009, 26(2): 151 – 155.
(ZHANG Dongqing, NING Xuanxi, LIU Xueni. On-line prediction of nonlinear time series using RBF neural networks [J]. *Control Theory & Applications*, 2009, 26(2): 151 – 155.)
- [16] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. *Neurocomputing*, 2006, 70(1/2/3): 489 – 501.
- [17] SINGH R, BALASUNDARAM S. Application of extreme learning machine method for time series analysis [J]. *International Journal of Computer Systems Science and Engineering*, 2007, 2(4): 256 – 262.
- [18] KREJNICK M, TYUTIN A. Reproducing kernel Hilbert spaces with odd kernels in price prediction [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, 23(10): 1564 – 1573.
- [19] SAPANKEVYCH N, SANKAR R. Time series prediction using support vector machines: a survey [J]. *IEEE Computational Intelligence Magazine*, 2009, 4(2): 24 – 38.
- [20] TAKENS F. Detecting strange attractors in turbulence [M] //RAND D, YOUNG L S. *Dynamical Systems and Turbulence*, Warwick 1980. Heidelberg, Berlin: Springer, 1981: 366 – 381.
- [21] 张春涛, 马千里, 彭宏. 基于信息熵优化相空间重构参数的混沌时间序列预测 [J]. 物理学报, 2010, 59(11): 7623 – 7629.
(ZHANG Chuntao, MA Qianli, PENG Hong. Chaotic time series prediction based on information entropy optimized parameters of phase space reconstruction [J]. *Acta Physica Sinica*, 2010, 59(11): 7623 – 7629.)
- [22] HERMANS M, SCHRAUWEN B. Recurrent kernel machines: computing with infinite echo state networks [J]. *Neural Computation*, 2012, 24(1): 104 – 133.
- [23] WILLIAMS C K I. Computation with infinite neural networks [J]. *Neural Computation*, 1998, 10(5): 1203 – 1216.
- [24] CHATZIS S P, DEMIRIS Y. Echo state gaussian process [J]. *IEEE Transactions on Neural Networks*, 2011, 22(9): 1435 – 1445.
- [25] HUANG G B, ZHOU H, DING X, et al. Extreme learning machine for regression and multiclass classification [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2012, 42(2): 513 – 529.
- [26] SHI Z, HAN M. Support vector echo-state machine for chaotic time-series prediction [J]. *IEEE Transactions on Neural Networks*, 2007, 18(2): 359 – 372.

作者简介:

韩 敏 (1959–), 女, 教授, 博士生导师, 研究方向为神经网络、
S3系统及混沌序列分析, E-mail: minhan@dlut.edu.cn;
王新迎 (1987–), 男, 博士研究生, 研究方向为神经网络和时间序
列预测, E-mail: xinying@mail.dlut.edu.cn.