

# 基于缩减策略的混沌时间序列 LSSVM 预测模型\*

熊胜华, 周翠英

(中山大学工学院, 广东 广州 510275)

**摘要:** 由于混沌时间序列具有样本大等特点, 使用最小二乘支持向量机(LSSVM)建立其预测模型具有内存开销大、训练速度慢等缺点, 因此, 在混沌序列数据特性的基础上, 利用样本集分割与样本相关性的思想, 提出一种基于缩减策略的混沌时间序列 LSSVM 预测模型。该模型利用混沌时间序列的平均周期将大样本数据分解成不同的子集, 把最后一个子集之外的其他子集利用拉格朗日乘子的值缩减一部分非支持向量, 将缩减后样本与最后一个子集合并, 利用相关系数缩减法缩减合并后的样本集, 并利用最小二乘支持向量机进行回归预测。最后通过相关实验, 验证了本模型在基本不损失预测精度的基础上具有较快的计算速度。

**关键词:** 混沌时间序列; 最小二乘支持向量机; 缩减策略; 相关系数; 样本集分割

**中图分类号:** TD853.34 **文献标志码:** A **文章编号:** 0529-6579(2011)01-0053-06

## LSSVM Prediction Model for Chaotic Time Series Based on Reduction Strategy

XIONG Shenghua, ZHOU Cuiying

(School of Engineering, Sun Yat-sen University, Guangzhou 510275, China)

**Abstract:** As chaotic time series are large, least squares support vector machines (LSSVM) have disadvantages of bigger memory spending and slower training speed on prediction. According to data characteristic of large chaotic time series, it adopts ideas of data sets partition and data correlation coefficient to propose a LSSVM prediction model for large chaotic time series based on new reduction strategy. The model partitions large chaotic time series is split up into several different subsets based on the mean cycle of chaotic time series. Some non-support vectors from all subsets is reduced except the end based on the values of Lagrange multipliers. The reduced data sets combines with the end subset based on the correlation coefficients, and is used to regress and predict by LSSVM method. The proposed model is applied to the forecast of large chaotic time series on correlative experiments, and the results show it hardly loses prediction precision and takes quicker training speed.

**Key words:** chaotic time series; least squares support vector machines; reduction strategy; correlation coefficient; data sets partition

混沌时间序列的建模与预测是当今混沌理论研究的重要方向之一, 而基于统计学习理论的最小二乘支持向量机(Least Squares Support Vector Ma-

chines, 简称 LSSVM), 由于其采用结构风险最小原则能最大程度地提高泛化能力和较好地解决非线性、高维数和局部极小值等实际问题, 因此在混沌

\* 收稿日期: 2009-12-19

基金项目: 国家自然科学基金重点资助项目(41030747); 国家自然科学基金面上资助项目(40672194); 国家 863 高技术计划资助项目(2007AA11Z112); 教育部博士学科点基金资助项目(20060558060, 20090171110044); 广东省自然科学基金重点资助项目(06104932, 013188); 广东省科技计划资助项目(2010A030200007); 广东省高层次人才计划项目; 广州市科技支撑计划项目, 中山大学后备重点课题(1132169)

作者简介: 熊胜华(1983年生), 男, 博士研究生; 通讯作者: 周翠英; E-mail: zhoucey@mail.sysu.edu.cn

时间序列预测方面也具有较好的应用前景<sup>[1]</sup>。与支持向量机 (Support Vector Machines, 即 SVM) 相比<sup>[2-3]</sup>, LSSVM 把最优化问题中的求解二次规划问题转化为求解线性方程组问题, 提高了算法的计算速度。但针对混沌时间序列的大样本学习, LSSVM 法与 SVM 法一样, 具有内存开销大、训练速度慢等缺点。因此, 为了解决大样本学习的问题, 许多学者对此开展了研究, 主要研究可以概述为二类:

一类是利用某种缩减算法从整个大样本集的学习序列中找出少量的有效的支持向量集, 去除大量的对样本学习贡献较少的非支持向量集, 缩短支持向量机的训练时间。如: 罗瑜等<sup>[4]</sup>提出了一种利用类别质心去除非支持向量对应的样本, 缩小样本集的方法, 该方法在不损失分类正确率的情况下具有更快的收数速度; 杨晓伟等<sup>[5]</sup>针对最小二乘支持向量机丧失稀疏性的问题, 提出了一种高效的剪枝算法, 在训练的过程中, 根据一些特定的剪枝条件利用块增量学习和逆学习交替进行的方法自动形成一个小的支持向量集, 并利用此集合构造最终的分类器; 骆世广等<sup>[6]</sup>考虑到 SMO (Sequential Minimal Optimization, 序贯最小优化) 算法对大样本数据训练速度比较慢的问题, 根据在 SVM 的优化过程中并不是所有样本都影响优化进展的思路, 提出了两种删除样本的策略, 一种是基于距离, 另一种是基于拉格朗日乘子的值, 从而大大缩短 SMO 的训练时间; 另外还有田新梅等<sup>[7]</sup>、李红莲等<sup>[8]</sup>也做出过相应的研究。

另一类是利用某种分组算法将大样本的训练集进行细分, 从而减少支持向量机每一次的存储空间和计算时间, 再利用带有记忆功能的块增量学习法进行整体学习, 从而达到缩短支持向量机的整体训练时间的目的。如: 张浩然等<sup>[9]</sup>根据分块矩阵计算公式和核函数矩阵本身的特点设计了支持向量机的增量式学习算法和在线学习算法, 该算法能充分利用历史的训练结果, 减少存储空间和计算时间; 张永等<sup>[10]</sup>基于数据分割和邻近对策略, 利用  $c$ -均值聚类分别对数据集中的正负类进行聚类, 把大数据集分割成互不相交的子集合, 然后来自正负类的子集合两两组合形成多个二分类问题, 并用 SMO 算法求解, 最后用邻近对策略对未知数据进行识别; Boser B 等<sup>[11]</sup>提出了一种选块算法解决大样本数据下 SVM 的训练速度问题, 利用若干任意样本构成小规模训练集求解二次规划问题, 得到一组支持向量, 再将这些支持向量并入其它若干样本中再

次训练, 又得到一组支持向量, 循环这个过程, 直到所有样本都计算完毕。

综上所述, 无论采用哪一类方法都可以达到减少大样本训练时间的目的, 但也都存在一些不足: 第一类方法的训练精度过分依赖于有效的支持向量集的选择, 如果缩减算法选择不当, 所选择的支持向量集并不能概括大样本训练集的重要发展规律, 从而影响支持向量机的训练精度; 第二类方法精度在于分组算法的选择, 如果选择不当, 同样对支持向量机的训练精度产生较大的影响。因此为了结合两类大样本的支持向量机快速算法的优点, 同时为了克服它们的不足, 本文提出一种针对混沌时间序列的基于新的缩减策略的 LSSVM 预测模型: 该模型利用混沌时间序列的平均周期将大样本数据分解成不同的子集, 将最后一个子集之外的其他子集利用拉格朗日乘子的值缩减一部分非支持向量, 并将缩减后样本与最后一子集进行合并, 利用相关系数缩减法缩减合并后的样本集, 并利用最小二乘支持向量机方法进行回归预测。

## 1 基于缩减策略的混沌时间序列的 LSSVM 预测模型的构建方法

设样本训练集,  $(x_1, y_1), \dots, (x_i, y_i), \dots, (x_n, y_n)$ , 其中  $x_i \in \mathbf{R}^m, y_i \in \mathbf{R}, i = 1, \dots, n, x_i$  为输入向量,  $y_i$  为输出向量。

混沌时间序列的预测问题主要是解决函数回归估计问题, 它是通过对训练集训练后找到一个函数  $f$ , 使得对训练集以外的任一测试样本  $x_d$ , 能够找到与其对应的  $y_d = f(x_d)$ , 并使  $y_d$  与其真值  $y$  的偏差最小。

在回归估计问题方面, LSSVM 方法在非线性、高维数和局部极小值等实际问题具有明显的优点。在 LSSVM 原理中, 它采用如下形式的函数对未知函数进行估计<sup>[12-14]</sup>:

$$y(x) = w^T \Phi(x) + b \quad (1)$$

其中  $\Phi: \mathbf{R}^m \rightarrow H, \Phi$  称为特征映射,  $H$  称为特征空间,  $w$  这空间  $H$  中的权向量,  $b \in \mathbf{R}$  为偏置。为了有效地解决上述回归估计问题, LSSVM 通过引入损失函数将回归估计问题转化为损失函数的风险最小化问题, 同时采用结构化风险最小原则进行风险最小化分析, 得出如下优化问题<sup>[12-14]</sup>:

$$\min J(w, e) = (w^T \cdot w) / 2 + \gamma \left( \sum_{k=1}^n e_k^2 \right) / 2 \quad (2)$$

约束条件:

$$y_k = w^T \Phi(x_k) + b + e_k \quad k = 1, 2, \dots, n \quad (3)$$

式中,  $\gamma$  为可调正则化参数,  $e_k$  为误差变量。

由于直接求解 (2) 比较困难, 因此采用对偶理论求解并建立 Lagrange 方程:

$$L(w, b, e, \alpha) = \frac{1}{2} w^T \cdot w + \frac{1}{2} \gamma \left( \sum_{i=1}^n e_k^2 \right) - \sum_{i=1}^n \alpha_i [w^T \Phi(x_i) + b + e_i - y_i] \quad (4)$$

其中  $\alpha_i$  为 Lagrange 乘子, 优化条件为<sup>[7]</sup>

$$\frac{\partial L}{\partial w} = 0, \frac{\partial L}{\partial \alpha} = 0, \frac{\partial L}{\partial b} = 0, \frac{\partial L}{\partial e} = 0 \quad (5)$$

为了求解 (5) 式, 在 LSSVM 原理中, 根据 Mercer 条件认为存在核函数  $K(x_k, x_l)$ , 使得

$$K(x_k, x_l) = \Phi^T(x_k) \Phi(x_l) \quad (6)$$

求解优化条件式 (5), 消去  $w$  与  $e_i$ , 并将  $K(x_k, x_l)$  替换  $\Phi^T(x_k) \Phi(x_l)$ , 最终将优化问题转化为求解一个线性方程组:

$$\begin{bmatrix} 0 & 1 & \cdots & 1 \\ 1 & K(x_1, x_1) + \frac{1}{\gamma} & \cdots & K(x_1, x_n) \\ M & M & O & M \\ 1 & K(x_n, x_1) & \cdots & K(x_n, x_n) + \frac{1}{\gamma} \end{bmatrix} \cdot \begin{bmatrix} b \\ \alpha_1 \\ M \\ \alpha_n \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ M \\ y_n \end{bmatrix} \quad (7)$$

其中  $\alpha_i$  为拉格朗日 (Lagrange) 乘子, 如果拉格朗日乘子的绝对值非常小, 则对模型的回归贡献非常少, 其对应的样本称为非支持向量, 其他情况下拉格朗日乘子所对应的样本称为支持向量。

LSSVM 算法采用最小二乘法求解式 (7) 表示的线性方程组, 避免了标准支持向量机算法中求解凸二次规划问题, 比传统的支持向量机方法具有更快的训练速度和更优的预测性能。因此, 在求解混沌时间序列问题时采用 LSSVM 算法解决非线性回归问题。

本文通过对大样本混沌序列数据特性的分析, 根据样本集分割与样本相关性的思想, 建立了混沌时间序列的 LSSVM 预测模型, 其构建方法表述如下:

1) 重构相空间, 建立混沌时间序列的学习样本集及测试样本集: 重构相空间是混沌时间序列的基础, 其关键是求出混沌时间序列的嵌入维数  $m$  及时延  $\tau$ 。目前来说, 单独求时延方法有自相关法<sup>[15]</sup>、互信息法等<sup>[16]</sup>, 单独求嵌入维的 G-P 算

法或 FNN (Flase Nearest Neighbors) 法等<sup>[17-18]</sup>; 同时求时延与嵌入维的方法有嵌入窗法<sup>[19]</sup>、C-C 方法等<sup>[20]</sup>。本文采用 C-C 法同时求嵌入维与时延。假设混沌时间序列表示为  $\{x_1, x_2, x_3, \dots, x_n\}$ , 其中,  $x_i$  为混沌时间序列的实际值。求得的嵌入维数为  $m$  以及时延为  $\tau$ , 则重构相空间后得到的样本集如式 (8) 所示:

$$X = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(m-1)\tau} \\ M & M & O & M \\ x_{n-(m-1)\tau} & x_{n-(m-1)\tau+1} & \cdots & x_{n-1} \end{bmatrix}, \quad Y = \begin{bmatrix} x_{2+(m-1)\tau} \\ x_{3+(m-1)\tau} \\ M \\ x_n \end{bmatrix} \quad (8)$$

2) 利用快速傅立叶变换求解混沌时间序列的平均周期  $T$ , 利用平均周期将大样本学习数据集分解成多个不同的样本子集, 样本子集个数为  $n$ , 每个样本子集的个数最大为  $T/m$  的取整数;

3) 初始选取正则化参数  $C$  及核参数  $\delta$ , 也可以通过多次组合比较预测结果来选取合适的正则化参数  $C$  及核参数  $\delta$ ;

4) 对子集序号为 1 到  $n-1$  的样本子集建立不同的 LSSVM 模型, 利用拉格朗日乘子  $|\alpha_i| < \theta_1$  时对模型的回归贡献非常少的原理, 从对应的样本子集中缩减其对应的非支持向量; 并将缩减后的样本子集与最后一个样本子集合并构成新的学习样本集  $X'$ ;

5) 利用某种规则选取学习样本集  $X'$  的中心样本  $\bar{X}'$ , 本文采用均值中心的方式选取中心样本  $\bar{X}'$ ;

6) 利用相关系数公式定义样本集  $X'$  中任一样本  $X_i'$  与中心样本  $\bar{X}'$  之间的相关距离  $d_i'$ , 如 (9) 式所示:

$$d_i' = 1 - r_i^2 \quad (9)$$

$$r_i = \frac{Cov(X_i', \bar{X}')}{\sqrt{DX_i'} \sqrt{D\bar{X}'}} \quad (10)$$

其中  $r_i$  表示样本  $X_i'$  与中心样本  $\bar{X}'$  之间的相关系数值,  $Cov(X_i', \bar{X}')$  表示  $X_i'$  与  $\bar{X}'$  的协方差,  $DX_i'$  表示  $X_i'$  的均方差,  $D\bar{X}'$  表示  $\bar{X}'$  的均方差;

7) 利用相关系数缩减法缩减相关距离  $|d_i'| < \theta_2$  的对应学习样本, 将余下样本组成新的学习样本集  $X_{end}$ ;

8) 利用初始选取的正则化参数  $C$  及核参数  $\delta$

对学习样本集  $X_{\text{end}}$  建立 LSSVM 回归模型, 对测试样本集进行非线性回归分析, 最终输出相应的预测结果。

9) 为了衡量算法的预测精度, 对测试数据采用均方误差 MSE 作为评价标准:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n |y(i) - \hat{y}(i)| \quad (11)$$

## 2 仿真实验及结果分析

实验一: 采用典型的混沌时间序列 Lorenz 方程验证本模型<sup>[21]</sup>:

$$\begin{cases} x' = -\sigma x + \sigma y \\ y' = -xz + rx - y \\ z' = xy - bz \end{cases} \quad (12)$$

$$\sigma = 16 \quad r = 45.92 \quad b = 4$$

取初始值为  $(-1, 0, 1)$ , 积分步长为 0.01, 利用四阶 Runge-Kutta 算法求出 Lorenz 方程的数值解, 为了从其数值解中取出具有明显混沌特性的数据点, 本文正是从 8 000 个数据点后取出 5 000 个数据点进行仿真实验。

将取出的 5 000 个数据点的  $x$  分量进行预测分析, 其中前 4 000 个数据点的  $x$  分量作为训练数据, 后 1 000 个数据点的  $x$  分量作为测试数据。其混沌时间序列的 LSSVM 预测模型的建立过程可描述如下:

首先对  $x$  样本序列进行归一化处理; 利用 C - C 方法求得嵌入维数  $m = 6$  及时延  $\tau = 11$ ; 重构相空间, 建立如 (8) 式所示的学习与测试样本集; 利用快速傅立叶变换求得  $x$  混沌时间序列平均周期  $T = 500$ , 求得样本子集个数为  $n = 8$ ; 然后选取 LSSVM 模型的初始化正则化参数  $C = 100$  及核参数  $\delta = 10$ , 对子集序号为 1 到  $n - 1$  的样本子集建立不同的 LSSVM 模型, 利用拉格朗日乘子  $|\alpha_i| < \theta_1$  从对应的样本子集中缩减相应的非支持向量, 其中  $\theta_1$  定义为  $|\alpha_i|$  平均值的  $1/8$  倍; 将缩减后的样本子集与最后一个样本子集合并构成新的学习样本集  $X'$ , 采用均值中心的方式从样本集  $X'$  选取中心样本  $\bar{X}'$ , 利用相关系数缩减法缩减相关距离  $|d_i'| < \theta_2$  的对应学习样本, 将余下样本组成新的学习样本集  $X_{\text{end}}$ , 其中  $\theta_2$  定义为  $|d_i'|$  平均值; 最后利用初始选取的正则化参数  $C$  及核参数  $\delta$  对学习样本集  $X_{\text{end}}$  建立 LSSVM 回归模型, 对测试样本集进行非线性回归分析, 最终输出相应的预测结果。预测结果图如图 1 所示。




图 1 Lorenz 函数的混沌时间序列的预测图

Fig. 1 Prediction of large chaotic time series of Lorenz function

将标准 LSSVM 模型对本文数据进行同样的预测, 其模型的初始化正则化参数  $C = 100$  及核参数  $\delta = 10$ , 将其预测结果与本文模型进行比较, 比较结果如表 1 所示。

表 1 Lorenz 函数的混沌时间序列预测结果对照表

Table 1 Comparison on prediction results of large chaotic time series

| 预测方法    | 样本数   | 缩减后<br>样本数 | 学习时<br>间/s | 均方误差<br>MSE/% |
|---------|-------|------------|------------|---------------|
| LSSVM 法 | 3 944 | 3 944      | 443.98     | 4.95          |
| 本文方法    | 3 944 | 1 423      | 43         | 3.53          |

实验二: 具有混沌特性的 Mackey-Glass 时滞微分方程定义为<sup>[21]</sup>

$$\frac{dx}{dt} = \frac{ax(t-\tau)}{1+x(t-\tau)^{10}} - bx(t)$$

$$a = 0.2, \tau = 17, b = 0.1 \quad (13)$$

本文取初始值为 1.2, 步长取 0.1, 通过四阶龙格 - 库塔方法求解产生混沌时间序列, 从 2 000 个数据点后取出 5 000 个数据点进行仿真实验。

将取出的 5 000 个数据点的  $x$  分量进行预测分析, 其中前 4 000 个数据点的  $x$  分量作为训练数据, 后 1 000 个数据点的  $x$  分量作为测试数据。其混沌时间序列的 LSSVM 预测模型的建模过程与实验一类似, 其预测结果图如图 2 所示。

将标准 LSSVM 模型对本文数据进行同样的预测, 其模型的初始化正则化参数  $C = 100$  及核参数  $\delta = 10$ , 将其预测结果与本文模型进行比较, 比较结果如表 2 所示。




图 2 Mackey-Glass 函数的混沌时间序列的预测图

Fig. 2 Prediction of large chaotic time series of Mackey-Glass function

表 2 Mackey-Glass 函数的混沌时间序列预测结果对照表

Table 2 Comparison on prediction results of large chaotic time series

| 预测方法    | 样本数   | 缩减后<br>样本数 | 学习时<br>间/s | 均方误差<br>MSE/% |
|---------|-------|------------|------------|---------------|
| LSSVM 法 | 3 944 | 3 944      | 510.6      | 5.65          |
| 本文方法    | 3 944 | 1 230      | 50         | 4.23          |

从两个不同实验的混沌时间序列预测结果对照表可以看出, 与标准的 LSSVM 预测模型相比, 本文模型在选择合适的临界参数  $\theta_1$ 、 $\theta_2$  后, 大大缩减了原始的学习样本, 使模型学习速度得到大大提高, 同时保证了预测精度基本不损失, 有时会反而更好。这为混沌时间序列的预测提供了一种新的快速途径。

### 3 结 论

最小二乘支持向量机是一种基于统计学习理论, 采用结构风险最小原则, 具有较强的泛化能力的机器学习方法, 在混沌时间序列预测方面具有较好的应用前景。但针对大样本数据的学习, 最小二乘支持向量机方法具有内存开销大、训练速度慢等缺点。因此, 本文通过对大样本混沌序列数据特性的分析, 根据样本集分割与样本相关性的思想, 建立了基于缩减策略下的混沌时间序列的 LSSVM 模型, 通过相应的仿真实验验证了本模型可以在预测精度基本不损失的基础上具有较快的计算速度, 为大样本的混沌时间序列的问题研究与预测提供了一种新的途径。通过研究得到以下两点认识:

1) 混沌时间序列的预测问题, 只要预测方法选择合适, 预测参数选择合理, 可以同时得到较好的预测效果和较快的计算速度;

2) 本文模型充分利用了最小二乘向量机具有较强的推广预测能力和较好的预测精度的特点, 且采用了样本集分割与样本相关性的思想, 使其在基本不损失预测精度的基础上大大提高了其计算速度, 通过实例证明本模型的实用性。

### 参考文献:

- [1] 江田汉, 束炯. 基于 LSSVM 的混沌时间序列的多步预测[J]. 控制与决策, 2006, 21(1): 77-80.
- [2] 刘德地, 陈晓宏. 基于偏最小二乘回归与支持向量机耦合的咸潮预报模型[J]. 中山大学学报: 自然科学版, 2007, 46(4): 89-92.
- [3] 陈振洲, 李磊, 姚正安. 基于 SVM 的特征加权 KNN 算法[J]. 中山大学学报: 自然科学版, 2005, 44(1): 17-20.
- [4] 罗瑜, 易文德, 王丹珠, 等. 大规模数据集下支持向量机训练样本的缩减策略[J]. 计算机科学, 2007, 34(10): 211-213.
- [5] 杨晓伟, 路节, 张广全. 一种高效的最小二乘支持向量机分类器剪枝算法[J]. 计算机研究与发展, 2007, 44(7): 1128-1136.
- [6] 骆世广, 骆昌日. 加快 SMO 算法训练速度的策略研究[J]. 计算机工程与应用, 2007, 43(13): 184-187.
- [7] 田新梅, 吴秀清, 刘莉. 大样本情况下的一种新的 SVM 迭代算法[J]. 计算机工程, 2007, 33(8): 205-207.
- [8] 李红莲, 王春花, 袁保宗. 一种改进的支持向量机 NN-SVM[J]. 计算机学报, 2003, 26(8): 1015-1020.
- [9] 张浩然, 汪晓东. 回归最小二乘支持向量机的增量和在线式学习算法[J]. 计算机学报, 2006, 29(3): 400-406.
- [10] 张永, 杨晓伟. 基于数据分割和近邻对的快速 SVM 分类算法[J]. 科学技术与工程, 2007, 7(21): 5563-5566.
- [11] BOSER B, GUYON I, VAPNIK V. A training algorithm for optimal margin classifiers[C] // Haussler D. Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory. ACM Press, 1992.
- [12] 董瑶, 潘国峰, 夏克文, 等. 一种改进的 LS-SVM 算法及其应用[J]. 石油地球物理勘探, 2007, 42(6): 673-677.
- [13] 夏克文, 董瑶, 杜红斌. 基于改进 PSO 算法的 LS-SVM 油层识别模型[J]. 控制与决策, 2007, 22(12): 1385-1389.

(下转第 63 页)

## 5 总 结

在 PVPC 系统中, 电流控制的主要任务是根据并网电流指令去控制功率开关器件的通断, 从而将光伏阵列产生的电能注入到电网中, 同时进行无功补偿和谐波抑制, 因而并网逆变器输出电流的跟踪控制是整个控制系统的重点。文章提出并网电流的快速无静差跟踪控制方法, 提高了系统并网电流的跟踪性能和并网电流质量。仿真和实验结果都证明了该控制方法的合理性, 可靠性和实用性。

### 参考文献:

- [1] AKAGI H, NABAE A, ATOH S. Control strategy of active power filters using multiple voltage-source PWM converter[J]. IEEE Trans. on Industry Appl., 1986, 22(3): 460 - 465.
- [2] 王兆安, 杨君, 刘进军, 等. 谐波抑制和无功功率补偿[M]. 2 版. 北京: 机械工业出版社, 2005.
- [3] 汪海宁, 苏建徽, 丁明, 等. 光伏并网功率调节系统[J]. 中国电机工程学报, 2007, 27(2): 75 - 79.
- [4] 郑诗程, 刘伟. 光伏并网发电系统及其控制策略的研究与仿真[J]. 系统仿真学报, 2009, 21(19): 6161 - 6165.
- [5] ABEYYASEKERA T, JAHNSON C M, ATKINSON D J, et al. Suppression of line voltage related distortion in current controlled grid connected inverter[J]. IEEE Trans on PE, 2005, 20(6): 1393 - 1401.
- [6] 陈晓高, 付青, 余世杰. 基于自抗扰控制的光伏并网功率调节系统[J]. 中山大学学报: 自然科学版, 2009, 48(2): 49 - 53.
- [7] KUOYeongchau, LIANGTsong juu, CHENJiannfuh. A high-efficiency single-phase three-wire photovoltaic energy conversion system[J]. IEEE Trans Ind Appl, 2003, 50(1): 116 - 122.
- [8] TAN P C, JUSOH A, SALAM Z. A single-phase hybrid active power filter connected to a photovoltaic array[C]// The 3rd IET International Conference on Power Electronics, Machines and Drives, 2006: 85 - 89.
- [9] SHIMIZU T, WADA K, NAKAMURA N. A flyback-type single phase utility interactive inverter with low-frequency ripple current reduction on the DC input for an AC photovoltaic module system[C]// IEEE Proc of 33<sup>rd</sup> Annual PESC, 2002, 3: 1483 - 1488.
- [10] 顾绳谷. 电机及拖动基础[M]. 北京: 机械工业出版社, 1992.
- [11] 唐欣, 罗安, 谭甜源. 有源电力滤波器的比例递推积分控制[J]. 控制理论与应用, 2004, 21(4): 631 - 634.
- [12] 茆美琴, 余世杰, 苏建徽. 带有 MPPT 功能的光伏阵列 Matlab 通用仿真模块[J]. 系统仿真学报, 2005, 17(5): 1248 - 1251.
- [14] 王旭辉, 黄圣国, 曹力, 等. 基于 LS-SVM 的航空发动机气路参数趋势在线预测[J]. 吉林大学学报: 工学版, 2008, 38(1): 239 - 244.
- [15] KANTZ H, SCHREIBER T. Nonlinear time series analysis [M]. Cambridge: Cambridge University Press, 1997.
- [16] FRASER A M, SWINNEY H L. Independent coordinates for strange attractors form time series[J]. Phys Rev A, 1986, 33: 1134 - 1140.
- [17] GRASSBERGER P, PROCACCIA I. Measuring the strangeness of strange attractors[J]. Physica D, 1983, 9: 189 - 208.
- [18] KENNEL M B, BROWN R, ABARBANEL H D I. Determining embedding dimension for phase-space reconstruction using a geometrical construction[J]. Phys Rev A, 1992, 45: 3403.
- [19] KUGIURMTZIS D. State space reconstruction parameters in the analysis of chaotic times series-the role of the time window length[J]. Physica D, 1996, 95: 13 - 28.
- [20] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics delay times and embedding windows[J]. Physica D, 1999, 127: 48 - 60.
- [21] 王永生, 范洪达, 尚崇伟, 等. 混沌时间序列的神经网络预测研究[J]. 海军航空工程学院学报, 2008, 23(1): 21 - 25, 32.

(上接第 57 页)