

Grey LS-SVM Forecasting with Parameter Optimized by Genetic Algorithm

Deqiang Zhou

Department School of Information and Mathematic, Yangtze University, Jingzhou

Email: zdqmfk@yahoo.com.cn

Received: Oct. 5th, 2011; revised: Nov. 6th, 2011; accepted: Nov. 8th, 2011.

Abstract: This paper utilized the accumulation generation operation of grey prediction to produce accumulated data, and accumulated data were used to construct grey LS-SVM. At the same time the parameters for LS-SVM were pretreated through genetic algorithms to get the optimum parameter values, then the optimized LS-SVM based on genetic algorithms was used to small samples forecasting. A typical example was taken to be analyzed and compared with GM (1, 1) and LS-SVM method. The result shows that the method forecast effect is better, and the prediction model has better generalization ability.

Keywords: Grey Least Square Support Vector Machines; GM (1, 1) Model; Genetic Algorithms; Parameter Selection; Small Samples Forecasting

基于遗传算法优选参数的灰色 LS-SVM 预测

周德强

长江大学信息与数学学院, 荆州

Email: zdqmfk@yahoo.com.cn

收稿日期: 2011 年 10 月 5 日; 修回日期: 2011 年 11 月 6 日; 录用日期: 2011 年 11 月 8 日

摘要: 利用灰色预测方法中累加生成运算形成累加数据, 将累加数据作为训练样本构造灰色 LS-SVM, 并利用遗传算法对灰色 LS-SVM 自身的参数进行优选, 然后将基于遗传算法优选参数的灰色 LS-SVM 用于小样本预测。选取了典型例子进行验证, 并与传统 GM(1, 1)和 LS-SVM 方法进行对比。结果表明本文所提出的方法预测效果良好, 且预测模型具有更好的泛化能力。

关键词: 灰色 LS-SVM; GM(1, 1)模型; 遗传算法; 参数优选; 小样本预测

1. 引言

目前, 对时间序列的预测有很多种方法, 从传统的 ARMA 模型到智能化的神经网络模型, 这些方法的核心在于建立一个好的预测模型^[1]。但是由于实际应用中时间序列具有不规则、混沌等非线性特性, 加之样本的有限性, 很难对系统建立理想的预测模型, 因此, 往往难以获得精确的预测结果。

将不同机理的预测方法相结合, 为提高预测精度提供了新的途径。文献[2]提出一种串联灰色神经网络, 将神经网络和灰色预测方法结合, 互相取长补短, 避免了 GM(1, 1)模型存在的理论缺陷^[2]。但是, 该方

法仍然遗留了常规神经网络存在的缺陷, 比如学习方法采用经验风险最小化(ERM)^[3]准则, 即最小化训练样本点误差, 因而不可避免地出现过拟合现象, 影响了模型的泛化能力。文献[1]提出灰色支持向量机预测方法, 将支持向量机(SVM)和灰色预测方法结合, 发挥了灰色预测方法中“累加生成”的优点, 弱化了原始序列中随机扰动因素的影响, 增强了数据的规律性, 不仅避免了灰色预测方法及模型存在的理论缺陷, 而且克服了神经网络模型中存在的局部极小问题。然而该方法也仍然遗留了常规支持向量机存在的缺陷, 比如, 模型中核函数以及模型参数的选择凭经验选取,

容易导致参数选择不准确而使最后的预测精度低于目标精度^[4,5]。另一方面 SVM 在处理二次寻优问题上比较耗时, 收敛速度较慢^[6]。

Suykens 在 SVM 的优化函数中引入方差项, 并将 SVM 中的不等式约束条件改为等式约束, 提出了一种以二次等式约束条件为基础的改进型向量机, 即最小二乘支持向量机(LS-SVM)^[7], LS-SVM 通过方差项的引入, 将经典 SVM 优化函数的不等式约束改成了只有等式约束, 这样 LS-SVM 的求解问题从标准 SVM 的二次函数寻优问题转换为线性方程求解问题, 而且不再需要指定逼近精度 ε , 大大简化了问题的复杂性, 求解速度相对加快^[5,6]。

通过分析灰色预测与 LS-SVM 预测各自的优缺点及互补性, 本文将两种小样本预测技术结合, 构造灰色 LS-SVM, 并利用遗传算法^[5,8,9]对灰色 LS-SVM 自身的参数进行自动搜索和确定, 再利用经寻优预处理的灰色 LS-SVM 模型进行预测。计算实例表明本文的方法是可行的且有效的, 比传统方法预测精度高, 可用于小样本预测。

2. GM(1, 1)和 LS-SVM 的比较

2.1. GM(1, 1)预测方法

设 $X^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n))$ 表示原始数据序列。对原始序列作一阶累加生成得到新序列

$$X^{(1)} = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)),$$

其中 $x^{(1)}(k) = \sum_{j=1}^k x^{(0)}(j), (k = 1, 2, \dots, n)$ 。对新序列的预测值 $\hat{X}^{(1)}$ 利用逆累加生成得到原始序列 $X^{(0)}$ 的灰色预测值, 表示为

$$\hat{X}^{(0)}(k+1) = X^{(1)}(k+1) - X^{(1)}(k) = (1 - e^{-a}) \left[X^{(0)}(1) - \frac{u}{a} \right] e^{-ak}, k = 1, 2, \dots$$

这里, 规定 $\hat{X}^{(0)}(1) = X^{(0)}(1)$, 其中 a, u 为 GM(1, 1)模型参数。

GM(1, 1)预测方法所需样本数较少, 该模型通过原始数据的累加可以消除一定的随机性, 但它并不是一种万能方法, 对于有些数据模型的解并不合理, 理论上要求原始数据累加生成近似指数型序列, 对于具

有波动性变化的非线性序列, 其预测精度往往不能令人满意, 适用范围受到很大限制^[1,2,10]。

2.2. LS-SVM 预测方法

对于训练样本 $\{(x_k, y_k)\}_{k=1}^n, x_k \in \mathbf{R}^n, y_k \in \mathbf{R}$, 用非线性映射 $\phi(x)$ 将样本从原空间映射到一个维数为 k 的高维特征空间 Z 中, LS-SVM 的目标是在该空间中构造最优的线性回归函数

$$f(x) = w^T \phi(x) + b, \quad (1)$$

式中 $w \in \mathbf{R}^k$ 为权向量, $b \in \mathbf{R}$ 为偏移量。

根据 SRM 原则, LS-SVM 算法表述为^[7]

$$\begin{aligned} \min_{w, b, \xi} & \frac{1}{2} \|w\|^2 + \frac{\lambda}{2} \sum_{k=1}^n \xi_k^2 \\ \text{s.t.} & y_k = w^T \phi(x_k) + b + \xi_k, k = 1, 2, \dots, n \end{aligned} \quad (2)$$

其中 ξ_k 为误差项, λ 是一个调节因子, 当 λ 为无穷大时, 所得的解为最小二乘解。实际计算中, 不需要知道非线性变换 $\phi(x)$ 的具体形式, 可用核函数 $K(x_i, x_j)$ 来实现算法的线性化。

为求解回归函数, 引入如下拉格朗日函数

$$\begin{aligned} L(w, b, \xi, \alpha) &= \frac{1}{2} \|a\|^2 + \frac{\lambda}{2} \sum_{k=1}^n \xi_k^2 - \sum_{k=1}^n \alpha_k [w^T \phi(x_k) + b + \xi_k - y_k] \end{aligned} \quad (3)$$

式中 α_k 为拉格朗日乘子。根据 KKT 优化条件有

$$\frac{\partial L}{\partial a} = 0, \frac{\partial L}{\partial b} = 0, \frac{\partial L}{\partial \xi_k} = 0, \frac{\partial L}{\partial \alpha} = 0, \quad (4)$$

得到如下等式约束条件

$$\begin{cases} w = \sum_{k=1}^n \alpha_k \phi(x_k), \\ \sum_{k=1}^n \alpha_k = 0, \\ \alpha_k = \lambda \xi_k, \\ w^T \phi(x_k) + b + \xi_k - y_k = 0 \end{cases} \quad (5)$$

消去 w 和 ξ , 问题归结为求解如下线性方程组

$$\begin{bmatrix} 0 & e^T \\ e & \Omega + \frac{I}{\lambda} \end{bmatrix}_{n \times n} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

式中 e 为元素为 1 的 $(n-1) \times 1$ 向量, I 为 $(n-1) \times (n-1)$ 的单位阵, $\alpha = [\alpha_2, \alpha_3, \dots, \alpha_n]^T, y = [y_2, y_3, \dots, y_n]^T$, $\Omega = \left(k(x_i, x_j) \right)_{(n-1) \times (n-1)}$ 。

求方程组(6)的最小二乘解为

$$\begin{bmatrix} b^* \\ \alpha^* \end{bmatrix} = \left(\begin{bmatrix} 0 & e^T \\ e & \Omega + \frac{I}{\lambda} \end{bmatrix}_{n \times n}^{-1} \begin{bmatrix} 0 & e^T \\ e & \Omega + \frac{I}{\lambda} \end{bmatrix}_{n \times n} \right) \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (7)$$

得 LS-SVM 线性回归函数为

$$f(x) = \sum_{k=1}^n \alpha_k^* K(x_k, x) + b^* \quad (8)$$

支持向量机严格的数学基础使其在理论上有较大优势, 但与其理论研究相比, 应用研究则相对滞后^[1]。同时, LS-SVM 预测精度在很大程度上依赖于训练集的选择^[11]。核函数以及模型参数的选取至今没有一定的理论做指导^[1]。研究者往往凭经验和有限的实验给定一组参数^[4]。

2.3. GM(1, 1)与 LS-SVM 预测方法的互补性

灰色预测适合处理“小样本”、“贫信息”的数据, LS-SVM 适合处理“小样本”、“非线性”的数据。两种方法都适合解决小样本的预测问题, 这是共性, 然而预测方法却存在较大差异, 但分析各自特点, 存在以下互补性:

1) 灰色预测方法是一种不严格的系统方法, 它避开系统结构分析环节, 直接通过对原始数据的累加构建指数增长模型, 寻找系统的整体规律, 但不适合逼近复杂的非线性函数。LS-SVM 则具有逼近任意函数的能力。

2) LS-SVM 虽然对样本数量依赖性弱, 但 LS-SVM 预测精度在很大程度上依赖于训练集的质量, 而灰色预测方法适合处理“贫信息”的数据, 对数据集要求不高。

3) LS-SVM 的预测性能对于参数的选择比较敏感^[4], 利用灰色预测方法中“累加生成”的优点, 削弱原始数据序列中随机扰动因素的影响, 使离乱的原始

数据中蕴涵的规律充分显露出来, 增强数据的规律性, 得到便于 LS-SVM 学习的具有单调增长规律的新序列^[1], 也同时便于用优化方法寻找核函数的参数。灰色预测方法中的参数 a, u 对 GM(1, 1) 预测精度也有较大影响^[1], 利用 LS-SVM 算法建立预测模型, 不再求解 GM(1, 1) 模型中的参数, 可避免 GM(1, 1) 模型求解参数的理论缺陷。

因此, 在灰色预测和 LS-SVM 预测都适合解决小样本问题的共性下, 将两种方法结合, 取长补短, 形成性能更好的预测方法具有可行性。

3. 灰色 LS-SVM 预测方法

3.1. 灰色 LS-SVM 模型

根据上述对 GM(1, 1) 和 LS-SVM 特点的分析, 本文提出仅保留灰色预测方法中“累加生成”和“累减还原”运算, 利用 LS-SVM 算法建立灰色 LS-SVM 预测模型, 不再求解 GM(1, 1) 模型中的参数。具体算法设计如下,

1) 对原始数据序列 $X^{(0)} = (x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)})$ 作累加生成: $x_k^{(1)} = \sum_{j=1}^k x_j^{(0)}, (k = 1, 2, 3, \dots, n)$, 得到生成序列 $X^{(1)} = (x_1^{(1)}, x_2^{(1)}, \dots, x_n^{(1)})$, 并构成训练样本 $\{(k, x_k^{(1)}), k = 1, 2, \dots, n\}$ 。

2) 选择核函数 $K(i, j)$, 利用训练样本构造灰色 LS-SVM 模型, 表示为

$$\min_{a, b, \xi} \frac{1}{2} \|w\|^2 + \frac{\lambda}{2} \sum_{k=1}^n \xi_k^2 \quad (9)$$

$$\text{s.t. } x_k^{(1)} = w^T \varphi(k) + b + \xi_k, k = 1, 2, \dots, n$$

3) 利用 LS-SVM 算法求解模型(9), 构造回归函数, $\hat{x}_k^{(1)} = \sum_{j=1}^n \alpha_j^* K(j, k) + b^*$ 。

4) 利用累加序列的预测值 $\hat{x}^{(1)}$, 进行“累减还原”得到原始序列的灰色预测值 $\hat{x}^{(0)}$ 。

3.2. 基于遗传算法优化求解灰色 LS-SVM 参数

目前研究最多的核函数主要有三类: 多项式核函数、径向基核函数(RBF)、Sigmoid 核函数。此外, 核函数自身的参数和调节参数 λ 的选取对应用结果也有较大影响, 为达到最佳预测效果, 以 RBF 核函数

$K(x_i, x_j) = \exp\left(-\|x_i - x_j\|_2^2 / \sigma^2\right)$ 为例说明利用遗传算法^[11-13]对灰色 LS-SVM 的参数 σ 和 λ 进行优选。

以误差平方和最小化为目标, 即

$$\min_{\sigma, \lambda} \sum_{k=2}^n \left(\hat{x}^{(0)}(k) - x^{(0)}(k) \right)^2 \quad (10)$$

其中 $\hat{x}^{(0)}(k)$ 为灰色 LS-SVM 模型预测值, 设计求解最优 σ 和 λ 的遗传算法如下^[5,12]:

1) 编码表示。将参数 $\sigma \in (0, +\infty)$ 和 $\lambda \in (0, +\infty)$ 表示为 n 位二进制串 (n 的大小可根据 σ 和 λ 的精度来确定)。

2) 构造初始群体。取种群大小 N , 在 $(0, +\infty)$ 上随机生成 N 对 σ 和 λ (染色体) 作为初始种群 $P(0) = \{[\sigma(1,0), \lambda(1,0)], [\sigma(2,0), \lambda(2,0)], \dots,$

$$[\sigma(N,0), \lambda(N,0)]\}$$

3) 对每个染色体解码, 采用如下适应度函数 $\text{Fit}(\sigma(i,k), \lambda(i,k)) = 1 / \sum_{j=1}^n \left(\hat{x}_{\sigma, \lambda(i,k)}^{(0)}(j) - x^{(0)}(j) \right)^2$ 计算群体 $P(k)$ 中每个染色体 $\sigma(i,k), \lambda(i,k)$ (其中 $k \leq K$ 表示代数, K 为最大进化代数) 的适应度。其中 $\hat{x}_{\sigma, \lambda(i,k)}^{(0)}(j)$ 表示由参数 $\sigma(i,k), \lambda(i,k)$ 得到的 GM(1, 1) 模型的预测值。

4) 对种群进行遗传操作。计算每代中各个个体的生存概率 $p_i^{(k)} = \text{Fit}(\sigma(i,k), \lambda(i,k)) / \sum_{j=1}^M \text{Fit}(\sigma(j,k), \lambda(j,k))$ M 表示第 k 代种群规模。设计一个随机选择策略(如“赌盘选择”), 使每个个体被选择进行繁殖的概率为 $p_i^{(k)}$, 将繁殖生成的个体组成父代 $P(k+1)$ 。

以概率 P_c 对新一代个体进行交叉换位, 产生新的个体, 再对新个体以概率 P_m 进行变异操作。

5) 反复执行步骤(3)~(4), 直至得到满意解或已达到了预设的最大代数为止。

4. 基于遗传算法优选参数的灰色 LS-SVM 的预测方法

通过上述分析, 提出基于遗传算法优选参数的灰色 LS-SVM 的预测方法, 具体算法设计如下,

1) 对原始数据序列 $X^{\pi(0)} = (x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)})$ 作累加生成: $x_k^{(1)} = \sum_{j=1}^k x_j^{(0)}, (k = 1, 2, 3, \dots, n)$, 得到生成序列

$X^{(1)} = (x_1^{(1)}, x_2^{(1)}, \dots, x_n^{(1)})$, 并构成训练样本 $\{(k, x_k^{(1)}), k = 1, 2, \dots, n\}$ 。

2) 选择核函数 $K(i, j)$ (比如 RBF 核), 利用训练样本构造灰色 LS-SVM 模型(9)。

3) 利用遗传算法求解式(10), 对灰色 LS-SVM 回归模型(9)中的参数进行寻优预处理。

4) 对经过优化参数的灰色 LS-SVM, 依据 LS-SVM 算法求解, 构造回归函数 $\hat{x}_k^{(1)} = \sum_{j=1}^n \alpha_j^* K(j, k) + b^*$ 。

5) 利用累加序列的预测值 $\hat{x}^{(1)}$, 进行“累减还原”得到原始序列的灰色预测值 $\hat{x}^{(0)}$ 。

5. 实例分析

利用文[13]中给出的 1997 年到 2003 年火灾伤人率数据进行预测, 1997~2000 年火灾伤人率数据作为样本集, 2001~2003 年火灾伤人率数据作为测试集, 见表 1。

分别用本文方法(简称累加 LS-SVM), 原始序列 LS-SVM 模型(简称原始 LS-SVM)进行建模。为具有可比性, 用遗传算法优化累加 LS-SVM 模型和原始 LS-SVM 模型的参数时, 控制参数设置为相同的, 种群大小 $N = 50$, 二进制编码长度为 20, 交叉概率为 0.95, 变异概率为 0.08, 最大进化代数 $K = 250$ 。用遗传算法求得累加 LS-SVM 模型的参数为 $\sigma = 12.028$, $\lambda = 897.17$, 原始 LS-SVM 模型的参数 $\sigma = 21.019$, $\lambda = 637.04$ 。利用平均绝对相对误差作为评价指标, 与 GM(1, 1)模型的拟合结果进行比较, 结果见表 2。

本文的方法在测试集上的平均相对误差为仅为 7.10%, 比用 GM(1, 1)和 LS-SVM 方法所得的平均相

Table 1. Data of fire injury rate of China from 1997-2003
表 1. 我国 1997-2003 年火灾伤人率数据(10⁻⁶)

年份	1997	1998	1999	2000	2001	2002	2003
伤人率	4	3.9	3.7	3.5	2.96	2.66	2.38

Table 2. Analysis and prediction of fire injury rate of China
表 2. 我国 1997-2003 年火灾伤人率预测分析

平均绝对相对误差(%)	样本集	测试集
累加 LS-SVM 模型	2.40	7.10
原始 LS-SVM 模型	0.15	21.67
GM(1, 1)模型	4.58	12.20

对误差分别降低 5.10% 和 14.57%，预测精度得到极大的改善。虽然原始序列适合 GM(1, 1) 模型，GM(1, 1) 模型能够描述数据内部变化的本质，但传统的 GM(1, 1) 模型本身存在理论缺陷，使得模型并没有显示良好的推广能力，而本文的模型发挥了灰色预测方法中“累加生成”的优点，削弱了原始数据中的随机性，增强了规律性，相对直接利用 LS-SVM 模型显示更好的推广能力，同时避免了 GM(1, 1) 方法本身存在的理论缺陷，预测结果显示模型发挥了 GM(1, 1) 和 LS-SVM 两种小样本技术的优势。

6. 结论

综上所述，可得如下结论：

1) 将 GM(1, 1) 和 LS-SVM 这两种“小样本”技术结合形成灰色 LS-SVM，可集成 2 种技术在处理小样本数据上的优点，使单一 LS-SVM 方法和 GM(1, 1) 各自的不足得到互补。

2) 在灰色 LS-SVM 模型参数的选择上，利用遗传算法对模型自身的参数进行自动搜索和确定，可克服传统 LS-SVM 参数选择方法中存在的缺点，保证最终的预测模型具有更好的泛化能力。

3) 理论分析和实际应用表明本文提出的方法是可行的且有效的，可用于小样本预测。

参考文献 (References)

- [1] 唐万梅. 基于灰色支持向量机的新型预测模型[J]. 系统工程学报, 2006, 21(4): 410-413.
- [2] 张大海, 毕研秋, 毕研霞等. 基于串联灰色神经网络的电力负荷预测方法[J]. 系统工程理论与实践, 2004, 12: 128-132.
- [3] V. N. Vapnik. The nature of statistical learning theory. Heidelberg: Springer Verlag, 1995.
- [4] 吴景龙, 杨淑霞, 刘承水. 基于遗传算法优化参数的支持向量机短期负荷预测方法[J]. 中南大学学报(自然科学版), 2009, 40(1): 180-184.
- [5] 周辉仁, 郑丕谔, 赵春秀. 基于遗传算法的 LS-SVM 参数优选及其在经济预测中的应用[J]. 计算机应用, 2007, 27(6): 1418-1419, 1429.
- [6] 王宇红, 黄德先, 高东杰等. 基于 LS-SVM 的非线性预测控制技术[J]. 控制与决策, 2004, 19(4): 383-387.
- [7] J. A. K. Suykens, J. Vandewalle. Least squares support vector machine classifiers. Neural Processing Letters, 1999, 9(3): 293-300.
- [8] J. H. Holland. Genetic algorithms. Scientific American, 1992, 4: 44-50.
- [9] P. J. Denning. Genetic algorithms. Journal of Parallel and Computing, 1992, 80(1): 354-360.
- [10] 李伟, 韩力. 组合灰色预测模型在电力负荷预测中的应用[J]. 重庆大学学报, 2004, 27(1): 36-39.
- [11] 席裕庚, 耿晓军, 陈虹. 预测控制性能研究的新进展[J]. 控制理论与应用, 2000, 17(4): 469-475.
- [12] 何文章, 宋国乡. 基于遗传算法估计灰色模型中的参数[J]. 系统工程学报, 2005, 20(4): 432-436.
- [13] 陈子锦, 王福亮, 陆守香. 灰色预测模型 GM(1, 1) 的适用性分析及在火灾风险预测中的应用[J]. 中国工程科学, 2007, 9(5): 91-94.