

基于 PSO 优化 LSSVM 的股价时间序列预测

王国俊

(上海理工大学 管理学院, 上海 200093)

摘要:现实中的金融时间序列存在非线性、不确定性等特点,利用传统的预测方法难以获得满意的结果。提出了一种基于 PSO 优化 LSSVM 模型参数的股价时间序列预测方法。利用 PSO 算法的收敛速度快和全局收敛能力,优化 LSSVM 的惩罚因子和核函数参数。利用该方法应用于金融市场中的股价序列预测,与传统方法对比表明,该模型能够提高金融时间序列的预测精度,其具有更好的泛化能力,这对国内投资者进行股票投资具有现实的借鉴意义。

关键词:时间序列预测;最小二乘支持向量机;ARIMA 模型;交叉验证;粒子群算法

中图分类号:F224 **文献标志码:**A **文章编号:**1671-1807(2017)10-0132-06

1990 年底,上海证券交易所和深圳证券交易所成立,中国拥有了自己的股票,我国的股票市场正式形成。由于股票投资具有高收益与高风险并存的特性,因此它吸引着越来越多的投资者投身其中。股票投资随着市场的发展而愈演愈烈,其中股票价格的变化直接反映着股票市场的状态,若能够准确预测股价序列的走势,不仅对投资者进行投资能给予指导意见,而且对政府的相关经济决策也能提供参考依据。但现实中,股价的变化受政府政策、利率、汇率等众多因素的影响^[1],我们要想预测其走势变得愈发困难。因此,如何较为准确的预测股票价格在未来的发展趋势已经成为股票投资中较为关注的热点之一。

传统的时间序列预测模型以统计理论为基础,需要序列数据满足平稳、线性等假设条件,这与现实中的金融时间序列一般是非平稳、非线性的特性相悖离,因此将传统的时间序列模型应用于实际中时存在诸多限制^[2-3]。随着计算机技术的发展,将人工智能应用于时间序列的预测问题,给众多研究者提供了一个新视角^[4]。由于这些方法没有传统时间序列模型的假设条件,属于非线性预测模型,近年来逐渐得到众多学者的关注。支持向量机(Support Vector Machines, SVM)^[5],以统计学习理论为基础,由于它建立的模型具有结构风险最小和全局最优的性质,较好地解决了小样本、非线性、高维数等实际问题,受到越来越多学者的青睐。1997 年, Vapnik 将基于分类领域中的 SVM 推广到回归领域,提出了支持向量回归机(Support Vector Regression, SVR)^[6],该方法本

质上是将回归问题转变成分类问题,从而最后的求解过程与 SVM 无重大差别,目前它已广泛应用于各种回归问题之中。Suykens J. A. K 采用最小二乘线性系统作为模型的损失函数,提出了最小二乘支持向量机(Least Squares Support Vector Machines, LSSVM)^[7-8],这种方法将 SVM 中的不等式约束条件变成了等式约束条件,求解过程从求解一个二次规划问题变成求解一个等式方程组,求解速度大大加快,在实际的模式识别和非线性函数估计中取得了不错的应用潜力。

在 LSSVM 模型的实际应用中,首先涉及到核函数的选取,虽然只要满足 Mercer 条件的函数在理论上均可以作为模型的核函数,但不同的核函数,其建立的模型所产生的性能是不一样的。常见的核函数有线性核函数、多项式核函数、sigmoid 核函数、径向基核函数(RBF)。由于 RBF 核函数结构简单,需要确定的参数较少,泛化能力强。无论是大样本还是小样本,高维还是低维, RBF 函数均适用,因而在现实中使用较为广泛。它的推广预测能力很大程度上依赖于惩罚参数 γ 和核函数参数 σ 。因此,确定合适的参数 γ 和 σ 是利用 LSSVM 进行建模和预测时所要解决的关键问题。到目前为止,还没有公认的 LSSVM 参数选择的好方法,且也没有比较专业的规律可循,这很可能导致模型参数选择不当而最终使得预测精度不高^[9]。Chappelle 等提出使用梯度下降法来优化参数^[10],该算法虽然在效率上有了明显的改善,但是梯度下降法对初始点要求较高,且易陷入局部极值

收稿日期:2017-06-24

作者简介:王国俊(1991—),男,安徽铜陵人,上海理工大学,硕士研究生,研究方向:金融统计与计算。

点。段青玲,张磊等^[11]将支持向量机应用于水产品价格预测中,利用遗传算法来优化 LSSVM 参数,虽然遗传算法不依赖于问题的数学模型,但它编程实现比较复杂,在求解问题的过程中它要经历编码、解码两个过程,后期收敛速度慢。近年来,神经网络等智能算法由于具有大规模并行处理、良好的自组织学习能力等特点,开始应用于金融时间序列的预测,且基于神经网络的模型取得了不错的效果^[12-13],但是传统的神经网络的学习过程具有黑箱性,它不能解释模型的推理过程和推理依据,且它具有收敛速度较慢、过拟合、易陷入局部最优等特点,当数据不充分时,神经网络就无法工作。

粒子群优化算法(Particle Swarm Optimization, PSO)^[14-15]是近些年发展起来的一种新型的启发式进化算法,它具有简单、容易实现、精度高、收敛速度快等特点,且有很多措施可以避免陷入局部最优,可调参数少,非常适用于求解非线性模型参数优化问题。本文针对 LSSVM 模型参数难以确定的缺点,引入 PSO 算法来优化模型的参数 γ 和 σ ,建立 PSO-LSSVM 混合预测模型。最后采用 PSO-LSSVM 模型对平安银行、中国人寿日收盘价数据进行实证分析发现:相对于其他模型,该混合模型对股价序列能够获得更好的预测精度。

1 PSO-LSSVM 混合预测模型

1.1 最小二乘支持向量机

相对于 SVM 算法需要求解一个凸二次规划问题,计算速度慢的缺点,LSSVM 算法以误差的二范式来表示模型的损失函数,约束条件由不等式约束变成了等式约束,大大提高了收敛速度。

设训练数据集 $(x_i, y_i), i = 1, 2, \dots, n, x_i \in \mathbb{R}^n$ 是第 i 个样本输入, $y_i \in \mathbb{R}$ 是第 i 个样本输出,用非线性映射 $\varphi(\cdot)$ 把样本集从输入空间映射到特征空间,在高维特征空间中建立线性回归方程:

$$y(x) = \omega^T \varphi(x) + b \quad (1)$$

根据结构风险最小化原理,优化问题就变成:

$$\min J(\omega, \xi) = \frac{1}{2} \|\omega\|^2 + \frac{\gamma}{2} \sum_{i=1}^n \xi_i^2 \quad (2)$$

$$\text{s. t. } y_i = \omega^T \varphi(x_i) + b + \xi_i, n = 1, 2, \dots, n \quad (3)$$

式中, $\gamma > 0$ 为惩罚系数; ξ_i 为松弛因子; b 为偏置变量; $\varphi(\cdot): \mathbb{R}^n \rightarrow \mathbb{R}^{n_f}$ 为核空间映射函数。

引入拉格朗日函数求解优化函数,我们得到:

$$L = J(\omega, \xi) - \sum_{i=1}^n \alpha_i \{\omega^T \varphi(x_i) + b + \xi_i - y_i\} \quad (4)$$

其中的 α_i 为拉格朗日乘子。

对式(4)求偏导并令其偏导数为零,根据 KKT 条件,可将求解的优化问题转化为求解一个线性方程组,即:

$$\begin{bmatrix} 0 & q^T \\ q & PP^T + c^{-1}I \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad (5)$$

式中, $P = [\varphi(x_1)^T y_1, \varphi(x_2)^T y_2, \dots, \varphi(x_n)^T y_n]$; $q = [y_1, y_2, \dots, y_n]^T$; $1 = [1, 1, \dots, 1]^T$; I 为单位矩阵。

根据 Mercer 条件,核函数可写为:

$$K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (6)$$

通过联立求解式(5)和(6),可得到 LSSVM 回归函数:

$$y(x) = \sum_{i=1}^n \alpha_i K(x, x_i) + b \quad (7)$$

对于 LSSVM 回归函数(7),本文采用径向基核函数 RBF,为 $K(x, x_i) = \exp\{-\|x - x_i\|^2 / \sigma^2\}$ 。因此,需要确定 γ 和 σ 两个参数, $\gamma > 0$ 为正则化系数,即惩罚系数; σ 是核函数系数,表示径向基核函数的宽度。

1.2 粒子群算法

粒子群算法由 Eberhart 和 Kennedy 两位博士于 1995 年提出的一种基于群智能的优化算法,它的基本概念源于对鸟群捕食行为的研究。该算法的基本思想是通过群体中所有个体之间不断的信息传递及信息共享来寻找全局最优解。

PSO 算法首先初始化一群随机粒子,通过多次迭代搜索全体最优解。在每一次迭代中,粒子通过跟踪 2 个“极值点”来更新自己的速度和位置:个体极值点 p_{best} 和群体极值点 g_{best} 。个体极值点是一个粒子曾经经过的最优位置,群体极值点是所有个体粒子极值点的最优位置。粒子根据上述 2 个极值点更新自己的速度从而改变自己当前的位置。在找到 2 个最优位置时,粒子根据下面两式更新自己的速度和位置:

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_{1j}(t)(p_{ij}(t) - x_{ij}(t)) + c_2 r_{2j}(t)(g_{ij}(t) - x_{ij}(t)) \quad (8)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (9)$$

上面两式中, $i = 1, 2, \dots, M$ 表示第 i 个粒子, M 是群体中粒子的总数; $j = 1, 2, \dots, D$ 表示粒子的第 j 维,算法需要优化的参数共有 D 个; ω 为惯性权重系数,其值非负, ω 值越大,越有利于算法跳出局部最小点, ω 值越小,越有利于算法收敛, ω 值的大小直接影响群体寻优能力; t 为算法迭代的次数; $v_{ij}(t)$ 表示 t

代时粒子 i 在 j 维的空间速度; c_1 和 c_2 为学习因子, c_1 值较小会使粒子缺失认知能力, c_2 值较小会降低粒子间的信息共享能力, 它们通常在 $0 \sim 2$ 之间取值; r_{1j} 和 r_{2j} 服从 $[0, 1]$ 上的均匀分布, 为两个相互独立的随机数; $p_{ij}(t)$ 为粒子 i 所优化的第 j 个参数中的历史最优解, 它是个体 i 历史最优的第 j 维值; $g_{ij}(t) = \min\{p_{ij}(t)\}$ 为所有粒子所优化的第 j 个参数中的历史最优解, 它是所有个体历史最优的第 j 维值; $x_{ij}(t)$ 为 t 时刻粒子 i 的空间位置的第 j 维值, 它受粒子上一个时刻第 j 维的位置和当前时刻第 j 维速度的共同影响。PSO 优化算法的具体步骤如图 1。




图 1 PSO 优化算法流程图

1.3 基于 PSO 的 LSSVM 算法

股票价格序列走势的预测问题实质上是一个回归问题, 本文选取基于结构风险最小化的 LSSVM 算法进行建模, 一方面能使得经验误差较小, 增强模型的拟合能力, 另一方面模型中的惩罚系数 γ 保证了模型的泛化能力, 提升了模型的预测性能。对于 LSSVM 算法, 需要优化的参数为 γ 和 σ , 因此 PSO 算法中 $D=2$; PSO 算法对群体规模 M 的大小并不十分敏感, 一般取 $10 \sim 40$, 本文取 $M=20$; 迭代次数不宜过大, 也不能太小, 本文取 $t=500$; 对于学习因子, 根据以往文献和调试经验, 本文取 $c_1=1.5$, $c_2=1.7$; 对于惯性权重因子 ω , 本文取为 1; 对于 γ 和 σ , 根据历史经验, 设定 $\gamma \in [1, 1000]$, $\sigma^2 \in (0, 1]$ 。针对本文需要优化的参数 $u_i = [\gamma_i, \sigma_i^2]$, $i=1, 2, \dots, 20$, 采用学习样本均方根误差 RMSE 作为 PSO 算法的适应度函数, 同时作为 PSO-LSSVM 模型的一个目标函数来衡量该模型的预测精度。

$$RMSE = \left\{ \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \right\}^{0.5} \quad (10)$$

式中, y_i 为实际观察值, $\hat{y}_i$ 为预测值, N 为预测样本数量。当 PSO-LSSVM 模型的 RMSE 最小时, 对应

的 γ 和 σ 值为最优参数。PSO-LSSVM 模型具体优化步骤如下:

Step1: 初始化粒子群参数。主要是初始化各粒子的位置、速度, 设定模型的终止条件;

Step2: 将粒子初始位置作为参数 γ 和 σ^2 代入 LSSVM 模型, 可得到训练样本的预测值, 根据式 (10) 计算各粒子的适应度, 得到粒子最优适应度值和群体最优适应度值, 且得到个体极值点 p_{best} 和群体极值点 g_{best} ;

Step3: 利用式 (8) 更新粒子的速度, 根据式 (9) 更新粒子的位置, 重复 Step2, 将粒子当前的适应度值与自身最优适应度值作比较, 得到粒子新的最优适应度值; 将所有粒子的新最优适应度值与群体最优适应度值作比较, 得到群体最优适应度值。另外, 可以得到各粒子新的个体极值点 p_{best} 和群体极值点 g_{best} ;

Step4: 检查是否满足终止条件, 若满足则计算结束并输出最优的 γ 和 σ^2 , 否则返回 Step3 继续计算;

Step5: 将优化参数 γ 和 σ^2 代入式 (7) 预测股价序列。

2 实证分析

2.1 数据的选取

由于金融股具有整体股价不高, 增量资金介入明显, 技术形态良好等特点, 它的市场号召力和对资金的吸引力近几年正逐步显现出来。本文选取金融股中的平安银行 (000001) 和中国人寿 (601628) 的日收盘价数据来验证 PSO-LSSVM 模型的有效性, 以 2015.10.21—2016.2.17 的 80 个日收盘价作为样本内数据, 以 2016.2.18—2016.3.30 的 30 个日收盘价作为样本外数据。本文对两只股票日收盘价进行的是短期预测研究, 并且采用的是单步预测。单步预测能够防止前期误差累积而造成的预测精度下降的问题。对于样本外的第 1 个数据, 我们用 80 个样本内数据建模进行预测; 对于样本外的第 2 个数据, 我们用 80 个样本内数据和第 1 个样本外数据建模进行预测。依这样的方式一直预测到样本外第 30 个数据。

2.2 评价准则

为评价预测性能, 本文使用均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 作为模型的评价准则。RMSE 的定义见式 (10), MAPE 的定义为:

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (11)$$

式中, y_i 为实际观察值, $\hat{y}_i$ 为预测值, N 为预测样本

数量。显然, RMSE 和 MAPE 越小, 则模型的预测精度越好。

2.3 基于 PSO-LSSVM 进行股价时间序列预测

为了对比, 本文还运用了传统的 ARIMA、CR-LSSVM(交叉验证最小二乘支持向量机)对股价时间序列进行学习预测。ARIMA(p, d, q)模型全称为差分自回归移动平均模型(Autoregressive Integrated Moving Average Model, 简记 ARIMA), AR 是自回归, p 为自回归项; MA 为移动平均, q 为移动平均项数, d 为时间序列成为平稳时所做的差分次数。它的基本思想是将预测对象随时间推移而形成的数据序列视为一个随机序列, 用一定的数学模型来近似描述这个序列, 这个模型一旦被识别就可以从时间序列的过去及现在值来预测未来值; 基于交叉验证方法的最小二乘支持向量机(CR-LSSVM)的主要思想是首先确定正则化参数集 $S_c = \{c_1, \dots, c_N\}$ 和核参数集 $S_\sigma = \{\sigma_1^2, \dots, \sigma_N^2\}$, 然后从参数集中选取参数分别进行组合, 对支持向量机进行训练, 并用一定的测试样本对得到的模型进行验证, 将效果最好的模型对应的一组参数作为最后的参数。本文采用交叉验证中的 LOO(leave one out)法对参数进行寻优, LOO 称为留一交叉验证, 每次只留一个样本用于测试, 其余样本用于训练, 所以训练和测试的次数就是样本数。将三个模型同时对两支股票的价格序列进行训练, 三个模型的预测结果见图 2、图 3。




图 2 三种模型对平安银行股价序列的预测

由图 2、图 3 我们大致能看出, PSO-LSSVM 对股价序列的预测性能要优于 ARIMA、CR-LSSVM




图 3 三种模型对中国人寿股价序列的预测

模型, 其预测的股价序列与实际的股价序列偏差较小。接着, 本文考察三种模型预测的残差序列是否为白噪声。白噪声的定义如下

如果一个序列 $\{X_t\}$ 满足: $E(X_t) = \mu; Var(X_t) = \sigma^2; Cov(X_t, X_s) = 0, \forall t \neq s$, 则称 $\{X_t\}$ 为白噪声序列(White Noise), 记为 $X_t \sim WN(\mu, \sigma^2)$ 。如果 X_t 还服从正态分布, 则称为高斯白噪声。

由白噪声的定义可知它具有性质:

$$\rho_k = 0, \forall k$$

显然, 对于 3 个模型, 若预测的残差序列为白噪声, 那么该模型的预测性能为优。

Ljung-Box 检验常常被用来检验一个时间序列是否存在滞后相关的一种统计检验。它是基于一系列滞后阶数, 判断序列总体的相关性或者说随机性是否存在。该检验的原假设是时间序列的数据之间都是相互独立的, 不存在相关性; 备择假设是时间序列的数据不是独立的, 存在相关性。构造的统计量是:

$$Q = n(n+2) \sum_{k=1}^h \frac{\rho_k^2}{n-k} \tag{12}$$

其中 n 是样本数量, ρ_k^2 是样本 k 阶滞后的相关系数; h 为考察滞后的最大阶数, 是人为给定的一个数。该统计量服从自由度为 h 的卡方检验。给定显著性水平 α (本文设定为 0.05), 则拒绝域是 $Q > \chi^2_{1-\alpha, h}$ 。对两支股价序列, 建立 ARIMA、CR-LSSVM、PSO-LSSVM 模型, 得到 6 个残差序列, 对它们分别进行 Ljung-Box 检验 (h 设定为 12), 结果如下:

表 1 平安银行 3 个残差序列的 Ljung-Box 检验结果

平安银行					
ARIMA		CR-LSSVM		PSO-LSSVM	
Q-stats	p-value	Q-stats	p-value	Q-stats	p-value
0.718	0.397	6.524	0.011	0.308	0.579
2.959	0.228	6.743	0.034	0.866	0.648
4.802	0.187	7.373	0.061	0.880	0.830

续表 1					
平安银行					
ARIMA		CR-LSSVM		PSO-LSSVM	
7.501	0.112	7.450	0.114	1.796	0.773
7.919	0.161	8.660	0.123	1.949	0.856
10.977	0.089	10.644	0.100	2.331	0.887
12.601	0.082	14.945	0.037	3.866	0.795
12.757	0.120	15.971	0.043	3.931	0.863
14.021	0.122	16.068	0.065	4.135	0.902
14.021	0.172	16.619	0.083	4.482	0.923
14.886	0.188	16.791	0.114	4.603	0.949
14.887	0.248	16.792	0.158	4.614	0.970

表 2 中国人寿 3 个残差序列的 Ljung-Box 检验结果

中国人寿					
ARIMA		CR-LSSVM		PSO-LSSVM	
Q-stats	p-value	Q-stats	p-value	Q-stats	p-value
2.246	0.134	6.337	0.012	0.317	0.573
4.268	0.118	6.813	0.033	0.474	0.789
11.323	0.010	12.440	0.006	6.064	0.109
11.618	0.020	14.948	0.005	6.536	0.163
12.434	0.029	14.950	0.011	6.899	0.228
12.895	0.045	15.222	0.019	7.988	0.239
14.613	0.041	15.443	0.031	8.590	0.283
15.097	0.057	15.457	0.051	8.880	0.353
15.514	0.078	15.517	0.077	10.033	0.348
15.625	0.111	15.535	0.113	10.940	0.362
15.909	0.145	15.540	0.159	11.008	0.443
15.916	0.195	15.970	0.193	11.219	0.510

对于表中的 p 值,它的含义为 $Q > Q-stats$ 的概率,可见,当 $p < 0.05$ 时,拒绝原假设。由表 1 知,ARIMA、PSO-LSSVM 模型的预测结果均较优,残差序列数据间不相关,为白噪声;而 CR-LSSVM 模型的预测残差在滞后 1、2、7、8 期时没有通过 Ljung-Box 检验,其残差序列数据间不独立,为非白噪声。由表 2 知,只有 PSO-LSSVM 模型对应的残差序列为白噪声, p 值均大于 0.05;此时对于 ARIMA 模

型,其滞后 3~7 期均没有通过 Ljung-Box 检验,也就是说,该序列滞后 3~7 期的数据是相关的;此时 CR-LSSVM 模型滞后 1~8 期均没有通过白噪声检验,其残差序列数据间相关,不是白噪声。

因此,结合表 1、表 2 来看,相对于 ARIMA、CR-LSSVM 模型,PSO-LSSVM 模型具有更好的预测性能。

表 3 各种模型预测的结果对比

模型	评价标准							
	平安银行(000001)				中国人寿(601628)			
	RMSE	排名	MAPE	排名	RMSE	排名	MAPE	排名
ARIMA	0.177	2	1.295	2	0.739	2	2.482	2
CR-LSSVM	0.228	3	1.723	3	1.504	3	4.543	3
PSO-LSSVM	0.117	1	0.729	1	0.451	1	1.278	1

由表 3,从模型的评价准则 RMSE 和 MAPE 来看,PSO-LSSVM 模型相对于 ARIMA 和 CR-LSS-

VM 均显示出更强的预测精度,甚至 PSO-LSSVM 模型提高了很多,说明该算法是切实有效的,可以作

为金融市场上股价序列预测的一种强有力的研究方法。

3 结束语

本文将 PSO 与 LSSVM 进行结合,构建了预测股价时间序列的 PSO-LSSVM 模型。与其他方法相比,该方法具有以下特点:

1) 基于结构风险最小化的非线性预测模型 SVM,它能对非线性、局部最小点、小样本和高维数问题给出较好的解决方法,而 LSSVM,该模型不但保留了 SVM 的所有优点,而且它求解过程要简便很多——将 SVM 中不等式约束的凸二次规划问题转化为只有等式约束的凸二次规划问题,寻优时间大大缩短。

2) 在对 LSSVM 进行参数寻优时,由于 PSO 算法具有较强的全局搜索、实现方便和收敛速度快等特性,将二者相结合,克服了参数选取的随机性,提高了 LSSVM 的泛化能力。这为复杂的金融时间序列的预测提供了一个极有吸引力的新途径。

3) 基于 PSO-LSSVM 的股价时间序列预测的实证分析可知:相比于其他模型,PSO-LSSVM 模型预测精度更高,表明该模型具有更好的泛化能力。对于目前金融市场股价数据变化较大的情况下是具有优势的,另外这对国内投资者进行股票投资也具有现实的借鉴意义。

参考文献

[1] 袁磊. 基于 ARIMA-LSSVM 混合模型的股指预测研究[D]. 哈尔滨:哈尔滨工业大学, 2015.
[2] LEE T S, CHEN N J. Investigating the information content of non-cash index futures using neural networks [J]. Expert Systems with Applications, 2002, 22: 225—234.
[3] LEE T S, CHEN N J, CHIU C C. Forecasting the opening

cash price index using grey forecasting and neural networks: evidence from the SGX-DT MSCI Taiwan index futures contracts[M]//WANG P, CHEN S S (Eds). Computational intelligence in economics and finance, Springer, 2003: 151—170.
[4] 戴稳胜, 吕奇杰, DAVID PITT. 金融时间序列预测模型——基于离散小波分解与支持向量回归的研究[J]. 统计与决策, 2007, 14(51): 4—7.
[5] VAPNIK V N. Statistical Learning Theory[M]. New York: John Wiley, 1995.
[6] VAPNIK V N, DRUCKER H, BURGESS C J C, et al. Support vector regression machines[J]. Advances in Neural Information Processing Systems, 1997(9): 155—161.
[7] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers [J]. Neural Processing Letters (S1370—4621), 1999, 9(3): 293—300.
[8] SUYKENS J A K, VAN G T, DE B. Least squares support vector machines[M]. Singapore: World Scientific, 2002.
[9] 郭辉, 刘贺平, 王玲. 最小二乘支持向量机参数选择方法及其应用研究[J]. 系统仿真学报, 2006, 18(7): 2033—2036.
[10] CHAPPELLE O, VAPNIK V, BOUSQUET O. Choosing multiple parameters for support vector machines[J]. Machine Learning, 2002, 46(1): 131—160.
[11] 段青玲, 张磊, 魏芳芳, 等. 基于时间序列 GA-SVR 的水产品价格预测模型及验证[J]. 农业工程学报, 2017, 33(1): 308—314.
[12] 张冬青, 马宏伟, 宁宜熙. 基于结构可变的 RBF 神经网络的时间预测序列[J]. 中国管理科学, 2010, 18(3): 83—89.
[13] 王书平, 胡爱梅, 吴振信. 基于多尺度模型铜价预测研究[J]. 中国管理科学, 2014, 22(8): 21—28.
[14] KANNAN S, SLOCHANAL S M R, SUBBARAJ P, et al. Application of particle swarm optimization technique and its variants to generation expansion planning problem[J]. Electric Power Systems Research, 2004, 70(3): 203—210.
[15] 龙文, 梁昔明, 肖金红, 等. 一种动态分级的混合粒子群优化算法[J]. 控制与决策, 2009, 24(10): 1513—1516.

Time Series Forecast of Stock Price Based on the PSO-LSSVM Predict Model

WANG Guo-jun

(Business School, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Because of the nonlinear and uncertain characteristics of the financial time series, it is difficult to obtain satisfactory results by using traditional forecasting methods. This investigation proposes a method to predict the stock price time series based on the LSSVM model which uses PSO algorithm to optimize its parameters. The PSO algorithm is used to optimize the penalty factor and kernel function parameter of LSSVM with fast convergence speed and global convergence ability. This proposed model can improve the prediction accuracy of financial time series and has better generalization ability when using it to predict time series of stock price in financial market compared with the traditional methods.

Key words: time series forecasting; least squares support vector machine; arima model; cross validation; particle swarm optimization