

# 基于改进 GA 参数优化的 SVR 股价预测模型<sup>①</sup>

孙秋韵, 刘金清, 刘 引, 吴庆祥

(福建师范大学 光电与信息工程学院, 福州 350007)

**摘 要:** 针对股票价格的动态性及非线性等特点, 提出了基于改进遗传算法(Genetic Algorithm, GA)优化参数的支持向量回归机(Support Vector Regression, SVR)股价预测模型. 首先将选取的股票价格样本进行小波去噪处理, 然后将经过改进 GA 优化参数的 SVR 模型对去噪后的数据进行预测及评价. 结果证明, 改进小波-GA-SVR 模型具有良好的预测效果, 对股票价格的预测研究具有一定的意义.

**关键词:** 小波去噪; 遗传算法; 支持向量机回归; 股价预测

## Stock Price Prediction Model Based on SVR with Parameters Optimized by Improved GA

QIU Yun-Sun, LIU Jin-Qing, LIU Yin, WU Qing-Xiang

(College of Photonic and Electronic Engineering, Fujian Normal University, Fuzhou 350007, China)

**Abstract:** Aiming to the dynamics and nonlinearities of stock price, a stock price prediction model that based on support vector regression (SVR) with parameters optimized by improved genetic algorithm (GA) was proposed. First, the wavelet was used to de-noise the samples of stock price. Then the SVR model whose parameters were optimized by improved GA was utilized to predict and assess the data de-noised by wavelet. The result demonstrated that the improved wavelet-GA-SVR model has good prediction effect, and it is significant to the study of the prediction of stock price.

**Key words:** wavelet denoising; genetic algorithm (GA); support vector regression(SVR); stock price prediction

股票价格的数据预测系统是一个动态、非线性的系统. 影响股票价格的因素不胜枚举, 价格波动的变化也显得异常复杂. 因此, 如何有效地进行股票价格的预测, 最大程度的规避股票风险, 成为当今国内外学者的研究方向. 目前, 常见的股票价格的预测方法有文献[1]利用 K 线图法分析股票市场, 能预测股票大致走势, 但这种图形分析法属于定性方法, 无法预测具体的股票价格. 文献[2]利用自回归移动平均模型等时间序列模型, 较好地解决了线性平稳的预测问题, 但对于非线性和非平稳的预测问题解决得不够理想. 由于股票价格的非线性, 价格预测的研究方向逐渐从传统时间序列分析方法向人工智能分析方法进行转变.

近年来, 具有自组织、自学习和良好非线性逼近能力的神经网络被引入到股市预测的研究中<sup>[3,4]</sup>, 但神经网络存在收敛速度慢和容易陷入局部极小值的缺点.

而 Vapnik 基于结构风险最小化原则提出的支持向量机(Support Vector Machine, SVM)作为一种新型神经网络因具有全局最优解, 从而能较好地解决了这一问题<sup>[5]</sup>. 基于 SVM 衍生的支持向量回归机(Support Vector Regression, SVR)主要是通过空间升维后, 在高维空间中构造线性决策函数来实现线性回归<sup>[6]</sup>. SVR 具有全局最优、结构简单、推广能力强等优点, 但由于此算法的核心在于用核函数代替线性方程中的线性项进行非线性回归, 直接应用于股票预测领域容易存在参数难以选择的问题.

本文针对 SVR 存在参数难以选择的问题, 提出了一种基于改进遗传算法(genetic algorithm, GA)优化的 SVR 模型用于股票价格预测. 首先对股票价格时间序列进行小波去噪, 消除其中的噪声, 并充分保留原信号的有效特征; 使用改进 GA 对 SVR 模型所涉及的参

<sup>①</sup> 基金项目:国家自然科学基金(61179011);福建自然科学基金(2010J01327)

收稿时间:2015-02-27;收到修改稿时间:2015-04-02

数进行优化;最后利用优化后的参数来训练 SVR 模型,而得到改进小波-GA-SVR 模型.通过对比预测值与实际值,验证了该模型的有效性.不仅能够减少反复实验的盲目性,还能有效的提高最优参数选取的成功率和效率,进而提高 SVR 模型的预测精度.

## 1 小波去噪处理

### 1.1 小波理论简析

小波分析的概念最初由 Hear 在 20 世纪初提出,直到 20 世纪 80 年代末法国学者 Mallat 提出了多分辨率分析的概念,统一了各种具体小波基的构造方法,小波分析在信号处理、图像分析、非线性科学等领域已有重大突破,成为 20 世纪最辉煌的科学成就之一<sup>[7]</sup>.

任意函数  $f(t) \in L^2(R)$  在小波基  $\Psi_{a,b}(t)$  下进行展开,称作函数  $f(t)$  的连续小波变换,其表达式为:

$$(W_a f)(a,b) = \langle f(t), \psi_{a,b}(t) \rangle = |a|^{-1/2} \int_{-\infty}^{\infty} f(t) \overline{\psi(\frac{t-b}{a})} dt \quad (1)$$

其中,  $a$  为尺度因子,  $b$  为平移量.由表达式可以得出,在连续变化的  $a, b$  值下,  $\Psi_{a,b}(t)$  具有很强的关联性,因此,小波变换系数的信息量是冗余的,而冗余信息不利于对信号的分析 and 处理,所以对尺度和时移参数进行离散化后,再进行小波重构.通常使用的离散化方法是:

尺度参数的离散化:  $a = a_0^j, j \in Z$  (通常  $a_0$  的值为 2,称为二进小波).

时移参数的离散化(取决于尺度参数):  $b = k \times a_0^j, j, k \in Z$ .

则函数  $f(t)$  离散化后的小波变换的表达式为:

$$(W_a f)(j,k) = \langle f(t), \psi_{j,k}(t) \rangle = |a_j|^{-1/2} \int \psi(a_j^{-1}t - k) dk \quad (2)$$

### 1.2 小波去噪原理

根据信号中 有用信号和噪声的时频特性的不同,通过将离散化后的小波分解成  $j$  层,此时有用信号在时域上表现为低频信号或者较为平稳的信号.但是由于噪声在时域分布的全局性,需要从第一层到第  $j$  层,每层选择一个阈值,同时对高频系数进行量化处理.最后对经过阈值消噪处理后的各层高频系数和小波分解后的低频系数进行小波重构,恢复去噪后的原始信号估计值.

含噪声的数据信号  $f(t)$  表示为:

$$f(t) = s(t) + \varepsilon e(t) \quad (3)$$

其中,  $s(t)$  是原始信号,  $e(t)$  是一个标准的高斯白噪声,

即  $e(t) \sim N(0,1)$ ,  $\varepsilon$  是噪声级.从含噪声的数据信号  $f(t)$  中恢复原始信号  $s(t)$ ,需要以下 3 个步骤:

1) 选取合适的小波基函数,对原始信号进行小波分解,得到各层的小波系数.若  $f(k)$  为信号  $f(t)$  的离散采样数据,则信号  $f(t)$  的正交小波变换分解公式为:

$$\begin{cases} c_{j,k} = \sum_n c_{j-1,n} h_{n-2k} \\ d_{j,k} = \sum_n d_{j-1,n} g_{n-2k} \end{cases} \quad (4)$$

其中,  $c_{j,k}$  为尺度系数,  $d_{j,k}$  为小波系数,  $h, g$  为一对正交镜像滤波器组;  $j$  为分解层数,  $N$  为离散采样点数.运用上式将含噪信号  $f(t)$  进行小波分解至  $j$  层,得到相应的小波分解系数.

2) 对分解得到的小波系数进行阈值处理,其阈值的处理方法有 2 种:

硬阈值法:  $\hat{x} = T_\tau(Y, t) = \begin{cases} Y & |Y| \geq t \\ 0 & |Y| < t \end{cases} \quad (5)$

软阈值法:  $\hat{x} = T_\tau(Y, t) = \begin{cases} \text{sgn}(Y)(|Y| - t) & |Y| \geq t \\ 0 & |Y| < t \end{cases} \quad (6)$

软阈值法能够使估计信号实现最大均方误差最小化,即去噪后的估计信号是原始信号的近似最优估计.因此本文选择软阈值法进行小波去噪.

3) 把去噪处理后的小波系数进行小波重构,得到去噪后的数据.小波重构过程是分解过程的逆运算,相应的重构公式为:

$$c_{j-1,n} = \sum_n c_{j,n} h_{k-2n} + \sum_n d_{j,n} g_{k-2n} \quad (7)$$

将经阈值处理过的小波系数用上式重构,得到恢复的原始信号估计值.小波去噪流程图如图 1 所示:

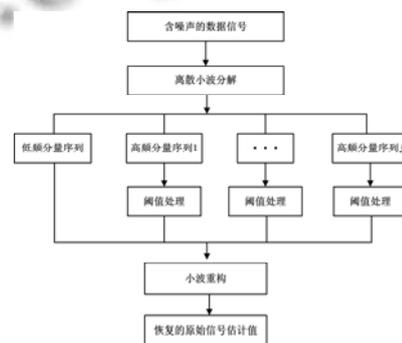


图 1 小波去噪流程图

## 2 构建改进GA-SVR模型

### 2.1 改进遗传算法

遗传算法是模仿自然界“适者生存”的生物进化原理发展起来的随机全局搜索和优化方法,根据个体在

问题域中的适应度值和从自然遗传学中借鉴来的再造方法进行个体选择, 经过多代繁殖进化, 获得适应值最好的个体作为问题的全局最优解<sup>[8,9]</sup>. 然而标准遗传算法在优化参数的过程中存在收敛慢的问题, 本文提出一种改进遗传算法, 简化了标准遗传算法中变异、交叉概率需要反复试验才能得到较精确结果的步骤, 同时提高了遗传算法的收敛性. 与标准的遗传算法相比, 改进遗传算法的交叉概率与变异概率不再是一个固定值, 而是按种群的适应度进行自动调整. 改进遗传算法中交叉概率及变异概率的具体运算公式如下:

$$p_c = \begin{cases} p_{c1} - (p_{c1} - p_{c2})(f' - f)/(f_{\max} - f_a), & f' \geq f_a \\ p_{c1}, & f' < f_a \end{cases} \quad (8)$$

$$p_m = \begin{cases} p_{m1} - (p_{m1} - p_{m2})(f_{\max} - f)/(f_{\max} - f_a), & f \geq f_a \\ p_{m1}, & f < f_a \end{cases} \quad (9)$$

其中交叉概率  $p_{c1}$ ,  $p_{c2}$  及变异概率  $p_{m1}$ ,  $p_{m2}$  均为给定值,  $f'$  为要交叉的两个体中较大的适应度值,  $f$  是被选择为变异个体的适应度值,  $f_a$  为每代群体的平均适应度值,  $f_{\max}$  为群体中最大的适应度值. 群体中的较优个体拥有更高的交叉概率与变异概率, 为了保证每一代的最优个体不被破坏, 采用最优精英策略, 将其直接复制到下一代中.

## 2.2 支持向量回归机

支持向量机模型是一种能够实现结构风险最小化思想的较好方法. 通过引入核函数将非线性矢量映射到高维空间, 避免了非线性拟合出现局部最优, 保证了较高的拟合精度, 得到全局最优解. 同时, 随着 Vapnik 将不敏感损失函数的引入, 替代了高维空间中的内积运算, 并且将该方法推广到回归问题, 提出了支持向量回归机模型. SVR 模型具有较好的推广能力和非线性处理能力, 尤其在处理高维数据时, 能有效地解决“维数灾难”问题.

SVR 主要是通过下列 4 个损失函数来实现回归: Quadartic 损失函数、Laplace 损失函数、Huber 损失函数及  $\epsilon$ -不敏感损失函数. 由于  $\epsilon$ -不敏感损失函数可以忽略真实值在某个上下范围内的误差, 其解以函数的最小化为特征, 使计算得到的对偶向量具有稀疏性, 确保全局最小解的存在和可靠泛化界的优化. 因此本文采取非线性的  $\epsilon$ -SVR, 其构造原理<sup>[10]</sup>如下:

给出一组数据点的集合  $G = \{(x_i + y_i)\}_i^n$ , 其中  $x_i$  是输入特征向量,  $y_i$  是目标值,  $n$  是样本量. 非线性 SVR 的基本思想是透过一个非线性映像  $\phi$ , 将数据  $x$  映像到高维特征空间, 并在这个空间进行线性回归. 即:

$$f(x) = w^T \phi(x) + b \quad (10)$$

$$\phi: R^n \rightarrow F, w \in F$$

其中变量  $w$  反映了函数的复杂度,  $b$  为偏置值,  $\phi$  是高维特征空间, 它是输入空间  $x$  的非线性映像.

为了能估计  $w$  和  $b$ , 所需要解决的优化问题由以下方程得出:

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} w^T w + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (11)$$

$$\begin{cases} w^T \phi(x_i) + b - y_i \leq \epsilon + \xi_i \\ y_i - w^T \phi(x_i) - b \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 1, L, n \end{cases} \quad (12)$$

其中  $C$  为惩罚参数,  $\xi_i$ ,  $\xi_i^*$  为松弛变量,  $\epsilon$  为不敏感损失函数,  $\epsilon$  的引入提高了估计的稳健性.

为了求解以上问题, 通常采用对偶理论, 将其转化为凸二次规划问题. 对上式进行拉格朗日变换, 可得:

$$L = \frac{1}{2} w^T w + C \sum_{i=1}^l (x_i + x_i^*) - \sum_{i=1}^l (\lambda_i (e + x_i - y_i + w^T x_i + b) - \sum_{i=1}^l (\eta_i (e + x_i + y_i - w^T x_i - b) - \sum_{i=1}^l (\lambda_i x_i + \lambda_i^* x_i^*)) \quad (13)$$

其中  $\lambda_i, \lambda_i^*, \eta_i, \eta_i^* \geq 0, i = 1, L, n$ , 拉格朗日函数相对于变量  $w, b, \xi_i, \xi_i^*$  的导数为 0.

最后, 导入拉格朗日算子和优化的限制式, 式(13)的决策函数变为:

$$f(x) = \sum_{i=1}^l (-\lambda_i + \lambda_i^*) k(x_i + x) + b \quad (14)$$

其中,  $k(x_i + x)$  为 SVM 的核函数. 只有当核函数满足 Mercer 条件时, 才能得到低维空间对应的非线性计算. 而常用的核函数主要有三种: 多项式核函数、Gauss 径向基(RBF)核函数及多层感知机核函数. 在以上三种核函数中, RBF 不需要先验知识, 对任意样本能够表现出较好的泛化性能和较强的学习能力, 所以本文选择将 RBF 作为核函数.

SVR 模型中, RBF 核函数引入的参数  $\sigma$ 、惩罚因子  $C$  及  $\epsilon$ -不敏感损失函数中的参数  $\epsilon$  的选择及优化直接影响 SVR 模型的准确性, 若参数选取不当, 将会导致 SVR 模型的过学习或欠学习现象. 目前 SVR 参数选择的方法中, 主要有经验确定法和网格搜索法. 其中经验确定法要求使用者有较深厚的 SVR 理论基础; 而网格搜索法的计算量较大, 并且两种方法都不能对参数进行优化及保证找到全局最优解. 为此, 引入改进遗传算法对支持向量回归模型参数进行优化, 以保证股价预测模型的准确性.

### 2.3 改进遗传算法优化 SVR 模型原理

改进遗传算法优化参数过程分为四个步骤: 对参数进行编码、初始化群体、计算适应度函数和遗传操作。

Step1: 采用二进制编码方法对 SVR 参数( $C, \sigma, \epsilon$ )进行编码, 并随机产生初始种群;

Step2: 计算适应度值. 适应度函数通常根据求解问题的目标函数来选取, 本文选取的适应度函数为均方误差 MSE, 它是从交叉验证(cross validation, CV)机制中验证子集产生的均方误差, 在回归问题中能有效地衡量染色体优劣, 并且经过交叉验证后可以避免或减轻过拟合现象. 其公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i^* - y_i)^2 \quad (15)$$

其中  $y_i$  为真实值,  $y_i^*$  为预测值,  $n$  为训练集样本量. 该适应度值越小, 表示个体效果越优, 被选择的概率也越大.

Step3: 遗传操作. 运用选择、交叉和变异算子进行遗传操作, 计算由交叉和变异生成的新个体的适应度值, 新个体与父代一起组成新一代群体.

选择操作: 按照轮盘赌选择方法选择  $N(N$  为偶数) 个个体, 计算群体的平均适应度值  $f_a$  和最大适应度值  $f_{max}$ .

交叉、变异操作: 将群体个体随机配对, 对每个个体, 根据公式(8)和(9)计算自适应交叉概率  $p_c$  和变异概率  $p_m$ , 以  $p_c$  和  $p_m$  为概率分别进行交叉操作及变异操作.

Step4: 判断适应度值是否达到终止条件(以最大迭代次数为终止条件), 未达到终止条件, 转入 Step2; 继续执行优化算法, 直到满足终止条件, 最终以进化过程中最小适应度的个体作为最优解, 把得到的最优参数( $C, \sigma, \epsilon$ )带入 SVR 模型进行预测. 改进 GA-SVR 流程图如图 2 所示:

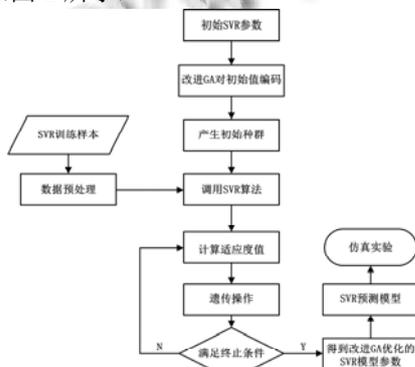


图 2 改进 GA-SVR 流程图

## 3 实证分析

### 3.1 实验数据选取及实验环境

本文选取上证 A 股指数为实验对象, 并选取收盘价, 开盘价, 最高价, 最低价, 成交价及成交量为预测模型的特征值. 在数据区间上, 选取 2013 年 1 月 4 日至 2013 年 12 月 31 日之间的 238 个交易日线数据, 其样本量大小为 1428, 构成 238\*6 矩阵, 所有数据均来源于大智慧数据库. 其中, 前 180 组数据样本为训练集, 后 58 组数据样本为测试集.

在 MATLAB2010b 的环境下, 实现改进小波-GA-SVR 模型对股票样本的回归和预测, 并使用相关系数( $R^2$ )和均方误差(MSE)作为回归模型的评价依据, 与单一的 SVR 模型、GA-SVR 模型、BP 神经网络模型和标准小波-GA-SVR 模型进行对比分析.

### 3.2 数据的归一化及小波去噪细节

为了消除指标之间的量纲影响, 对数据进行归一化处理, 使得数据较容易进行处理比较. 本文通过对数据的归一化处理, 将数据映射到[-1, 1]区间内. 经过归一化处理后的原始数据, 其各项指标均处于同一数量级, 适合进行综合对比评价.

数据归一化后, 对数据样本进行小波去噪处理, 以充分保留数据的有效特征. 由于小波基类型和小波分解层数的不同会使小波去噪产生不同的效果, 所以需要确定适合本文研究对象, 即股票价格序列的小波基类型和小波分解层数.

图 3, 图 4 分别上证 A 股指数去噪前后图, 由图看出, 去噪后的数据较去噪前的数据平滑很多. 同时经过反复调试, 将 sym4 小波定为小波基类型, 并且最佳小波分解层数为三层.

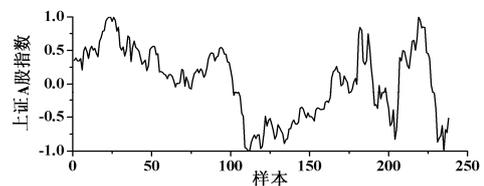


图 3 小波去噪前

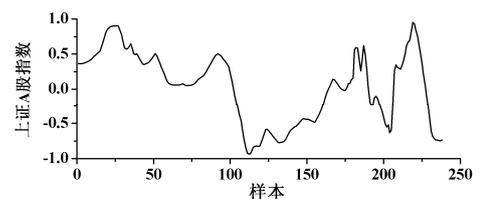


图 4 小波去噪后

### 3.3 实验参数设置及结果

在改进小波-GA-SVR 的模型环境下,通过实验平台的反复测试,最终将各参数设置为:进化次数为100代,群体大小  $N$  为 50,  $p_{c1}=0.9$ ,  $p_{c2}=0.6$ ,  $p_{m1}=0.1$ ,  $p_{m2}=0.001$ , 适应度函数为进行 3 折 CV 的 MSE. 实验得出的最优化参数惩罚因子  $C=2.2741$ , RBF 核函数参数  $\sigma=0.9621$ , 不敏感损失函数  $\varepsilon=0.0697$ .

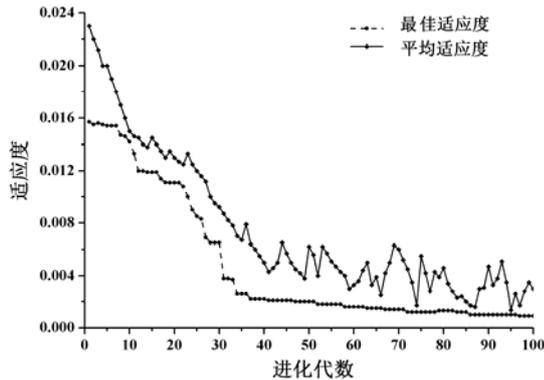


图5 适应度曲线

图5为适应度曲线的寻优结果,反映了逐代的平均适应度和最佳适应度的进化过程.可以看出,平均适应度逐渐收敛到一个较小的值,慢慢接近最佳适应度.这不仅说明了改进GA的收敛性较好,也意味着种群在逐渐接近最优解,满足目标优化控制的精度要求.

### 3.4 模型预测与比较

为了验证本文提出的改进小波-GA-SVR 模型在股票价格预测中的有效性和优势,本节从三个方面进行对比实验:(1)不经过小波去噪处理,直接运用单一的SVR模型和GA-SVR模型对股票价格时间序列进行预测分析,并和改进小波-GA-SVR模型进行对比验证;(2)使用BP神经网络模型对股票价格时间序列进行预测分析,并将BP神经网络,同改进小波-GA-SVR模型进行对比验证.(3)使用标准小波-GA-SVR模型对股票价格时间序列进行预测分析,并和改进小波-GA-SVR模型进行对比验证.预测结果分别如图6~10.

图6为单一的SVR模型预测结果图,图7为GA-SVR模型预测结果图,图8为BP神经网络模型预测结果图,图9为小波-GA-SVR模型预测结果图,图10为改进小波-GA-SVR模型.我们可以从图中直观的观察出,标准小波-GA-SVR模型和单一的SVR模型及BP神经网络模型相比,在数据上较为平滑,而且在预测精度上也有明显地提高.然而,对比以上模型,改

进小波-GA-SVR 模型得到的预测结果与实际结果在数值上更加接近,模型预测取得较优的效果.

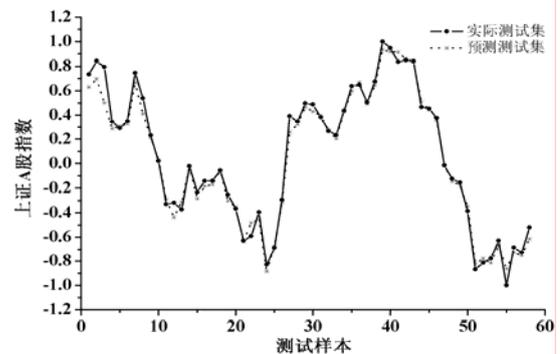


图6 SVR模型预测结果图

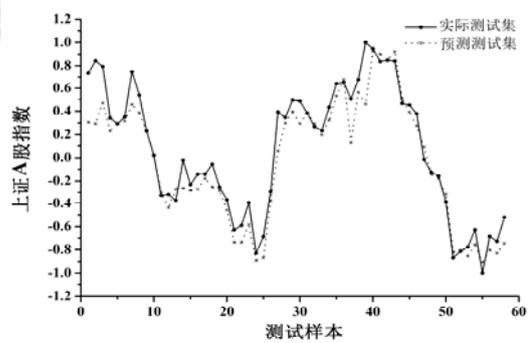


图7 GA-SVR模型预测结果图

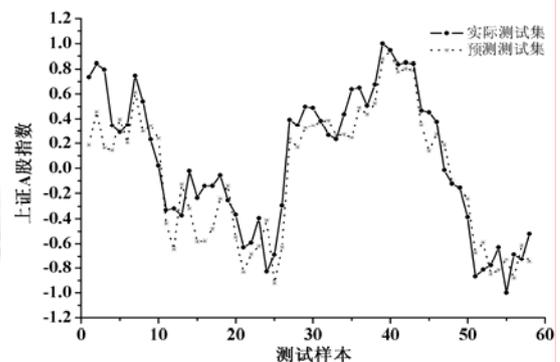


图8 BP神经网络模型预测结果图

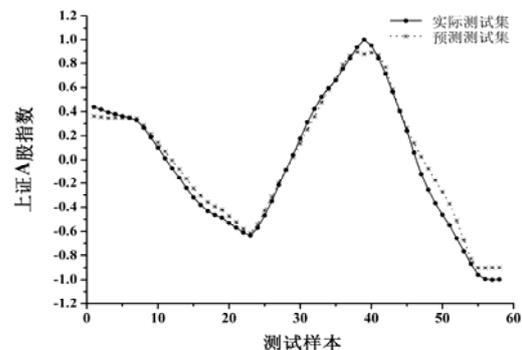


图9 小波-GA-SVR模型预测结果图

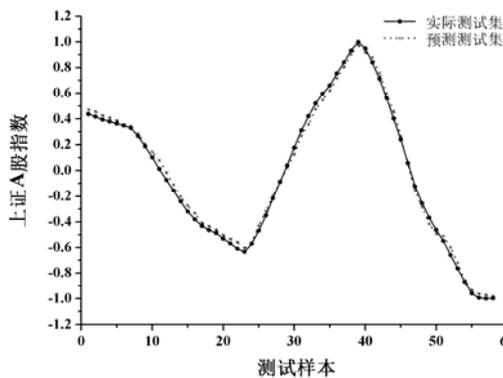


图 10 改进小波-GA-SVR 模型预测结果图

此外,表 1 给出了 BP 神经网络模型、单一的 SVR 模型, GA-SVR 模型、标准小波-GA-SVR 及改进小波-GA-SVR 的 MSE 及  $R^2$  的结果. 通过改进遗传算法对 SVR 参数的优化, 改进了遗传操作中的交叉, 变异算子, 不再是需要反复试验的单一固定值, 而是按种群的适应度进行自动调整, 大大提高了收敛性, 有效避免了标准 GA 收敛慢的问题, 因此改进小波-GA-SVR 模型较标准小波-GA-SVR 模型的预测精确度更高, 误差更小. 此外, 未经过小波去噪处理的 GA-SVR 模型对股票样本的预测结果在性能指标上与标准小波-GA-SVR 模型较为接近, 而相比之下, 标准小波-GA-SVR 模型 MSE 较小, 而  $R^2$  相对较大, 进而说明了采用小波去噪方法的有效性, 可以进一步提高拟合度和预测精度. 而单一的 SVR 模型预测结果不管在均方误差 MSE 还是在相关系数  $R^2$  上都远不如改进小波-GA-SVR 模型的预测结果, 进一步表明了 SVR 模型的参数选择问题对预测结果的重要影响. 此外, BP 神经网络的实验结果相对不理想. 通过和多种回归模型的对比试验, 体现出了本文所建立的改进小波-GA-SVR 模型对于股票价格序列的回归预测的准确性和优势.

表 1 各模型的回归结果对比

模型	MSE	$R^2$
BP	0.0912	0.8571
SVR	0.0778	0.8843
GA-SVR	0.0360	0.9329
标准小波-GA-SVR	0.0111	0.9686
改进小波-GA-SVR	0.0092	0.9813

## 4 结论

本文选取上证 A 股指数 2013 年的 238 个交易日日线数据为样本, 针对 SVR 存在参数难以选择的问题, 使用改进 GA 对 SVR 所涉及参数的动态过程进行优化, 此外, 使用小波变换对原始数据进行小波去噪处理, 从而建立了改进小波-GA-SVR 股票预测模型, 并将其同单一的 SVR 模型, GA-SVR 模型, 标准小波-GA-SVR 模型及 BP 神经网络模型进行了预测对比. 实验结果表明, 改进小波-GA-SVR 模型不仅解决了标准遗传算法收敛速度慢及 SVR 模型参数难以选择的问题, 还在结合小波去噪技术之后, 进一步提高了模型的稳定性及预测精度, 说明改进小波-GA-SVR 模型是有效可行的. 同时, 小波去噪技术最大限度地保留了真实的信号系数, 从而进一步提高了预测结果的正确性. 本文提出的改进小波-GA-SVR 模型在股价预测的理论研究中具有重要意义, 在实际应用中还有待我们进一步的完善.

### 参考文献

- 1 王伟钧,袁正伟,谢文吉,杨晋浩.股市 K 线组合的关联规则挖掘.成都大学学报(自然科学版),2009,28(3):268-271.
- 2 郑伟伦.上证综合指数股票价格短期预测--基于 ARIMA 模型的研究分析.经济研究导刊,2014,(16):136-137.
- 3 Guresen E, Kayakutlu G, Daim TU. Using artificial neural network models in stock market index prediction. Expert Systems with Applications, 2011, 38(8): 10389-10397.
- 4 张秋明,朱红莉.灰色神经网络在股价预测中的应用研究. Computer Engineering and Applications, 2013, 49(12).
- 5 Cortes C, Vapnik V. Support-vector networks. Machine Learning, 1995, 20(3): 273-297.
- 6 董美双,何欢,童晓星.基于  $\epsilon$ -SVR 的粮食产量预测模型及应用.浙江大学学报(农业与生命科学版),2009,35(4):439-443.
- 7 Demirel H, Anbarjafari G. Image resolution enhancement by using discrete and stationary wavelet decomposition. IEEE Trans. on Image Processing, 2011, 20(5): 1458-1460.
- 8 田建立,晁学鹏.求解 0-1 背包问题的混沌遗传算法.计算机应用研究,2011,28(8):2838-2839.
- 9 Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II. IEEE Trans. on Evolutionary Computation, 2002, 6(2): 182-197.
- 10 吴德会.基于 SVR 的非线性动态系统建模方法研究.计算机应用,2007,27(9):2253-2255.