

# APSO\_SVR 模型在我国大豆价格预测的应用研究

何朋飞, 李 静, 张冬青

(南京农业大学 工学院, 江苏 南京 210031)

**摘要:**国内大豆价格受到多重因素影响,如大豆进口量、国内大豆供给量、中国居民消费价格指数等,因此呈现非线性等特点。大豆价格的剧烈波动会对农户的种植结构和国家政策产生影响,因此准确预测大豆价格具有重要意义。支持向量回归(SVR)因其优越的寻优能力和较高的预测精确度而被广泛应用于非线性时间序列回归中。本文提出一种自适应粒子群算法(APSO)优化的SVR模型来预测我国大豆价格,该模型通过将现实空间内的数据映射到高维空间内,在高维空间内构造线性回归函数,从而判别原有空间内数据之间的关系。在SVR模型参数优化时,由于粒子群算法易陷入局部最优解,因此采用惯性权重更新和适应度变异的粒子群算法(APSO)对预测模型参数进行优化。采用2009年1月–2016年12月的国内大豆价格月度数据进行预测,结果表明APSO优化的SVR模型在大豆价格预测中精度较高,且能准确反应大豆价格的未来趋势,为从事大豆种植者及经营者提供决策依据。

**关键词:**SVR预测模型; 自适应; 粒子群算法; 大豆

中图分类号:F224.7

文献标识码:A

DOI:10.11861/j.issn.1000-9841.2017.04.0632

## Predicting Chinese Soybean Price Based on APSO\_SVR

HE Peng-fei, LI Jing, ZHANG Dong-qing

(College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

**Abstract:** Soybean price was influenced by many factors, such as soybean imports, domestic soybean outputs, consumer price index etc. The characteristics of soybean price is non-linearity, randomness etc. The fluctuation of soybean price would influence farming structure and national policy of soybean. Exact predicting soybean price is significant for farmers and soybean policy. Support vector machine was widely used in nonlinear time series because of its superior search capability and high accuracy. In this paper, SVR model optimized with adaptive particle swarm optimization (APSO) was used to predict soybean price. In this model, the data was mapped to high-dimensional space from real space. The linear regression function was constructed in the high dimensional space to distinguish the data relations in the real space. The parameters of SVR model was optimized with particle swarm optimization (PSO), but the PSO was usually trapped local optimization results. Therefore, adaptive strategy of fitness mutation and inertia weight updated was used to structure APSO. The data of soybean price from Jan. 2009 to Dec. 2016 were used to forecast. The results indicated that APSO and SVR model was accurate and effective. The SVR model can accurately reflect future trend of soybean price and provide decision basis for soybean farmers and soybean businessman.

**Keywords:** SVR predicting model; Adaptive; PSO; Soybean

作为主要粮食和油料作物的大豆影响着农户种植结构和粮食价格。由于国内大豆价格受到国家政策、国内供给以及国际市场等多方面因素的共同影响,其波动幅度较大,且具有非线性等特点。大豆价格的波动会影响大豆种植者和经营者的信心<sup>[1]</sup>,从而导致农户的种植规模发生改变。近年来国际大豆市场的剧烈变化也导致国内大豆价格出现持续波动的趋势。在这种背景下,对大豆价格进行准确的预测能够有效指导我国大豆生产以及有

效估算大豆进口量等数据,从而保障大豆种植者和经营者的收入,对稳定国家经济具有重要意义。

大豆价格预测的相关研究比较广泛。张冬青等<sup>[2]</sup>采用Q-RBF神经网络对国内大豆价格进行预测。灰色预测模型也被用于大豆价格的预测<sup>[3]</sup>。部分学者采用ARIMA模型对大豆价格进行预测<sup>[4-5]</sup>。但这些预测研究不能很好地实现结构风险最小化且易陷入局部最优,而支持向量回归(SVR)预测模型可以较好地避免这一问题。

支持向量回归(SVR)作为一种人工智能方法在农产品预测研究中应用广泛。段青玲等<sup>[6]</sup>利用遗传算法优化的SVR预测模型对时间序列的水产品价格进行了准确的预测。Lasso和支持向量回归组成的组合预测方法也被用于粮食价格的预测当中<sup>[7]</sup>。Gandhi等<sup>[8]</sup>利用支持向量机对水稻的产量进行预测。Yousefi等<sup>[9]</sup>利用SVR模型对水稻生产中能量的输出进行预测。Su等<sup>[10]</sup>采用基于支持向量机的开放作物模型对中国的水稻生产进行研究。这些研究表明支持向量机能够较好地反映农产品价格或产量的变化规律,预测比较准确。

将实际问题映射到高维空间是SVR预测模型的一个特点,SVR通过在高维特征空间中构造线性回归决策函数来实现原空间中的非线性决策函数,在这一过程中,SVR模型能够寻找出全局最优解。由于大豆价格具有较强的非线性特征,SVR预测模型能够很好的处理非线性特征序列<sup>[11-12]</sup>,因此本文采用SVR预测模型对我国的大豆价格进行预测。SVR预测模型中,3个合适的参数(核函数参数、惩罚因子和损失参数)是影响预测模型准确性的关键。粒子群算法(PSO)是一种群智能算法,通过此算法能够寻找出SVR预测模型的最优参数。由于普通粒子群算法容易陷入局部最优解<sup>[13]</sup>,因此本文采用自适应粒子群算法(APSO)对SVR预测模型进行参数优化。

粒子群算法(PSO)是一种群智能算法,通过此算法能够寻找出SVR预测模型的最优参数。由于普通粒子群算法容易陷入局部最优解<sup>[13]</sup>,因此本文采用自适应粒子群算法(APSO)对SVR预测模型进行参数优化。

## 1 支持向量回归 SVR

支持向量机(SVM)是由Vapnik教授提出,SVR作为SVM的一类,是基于结构风险最小化的原则,通过调节参数有效地避免预测模型产生过学习或欠学习的现象,同时能够很好地解决小样本、非线性、高维度以及局部最小问题。SVR预测模型通过非线性映射关系( $\theta(x)$ )将输入参数映射到高维空间,通过在高维空间中构造线性函数来判别在原空间中的非线性关系,如图1,将X空间内的数据输入通过 $\theta(x)$ 映射到高维空间F中,进而可以将X空间内数据的非线性函数关系转化为F空间内的线性函数关系,从而可以在F空间内实现线性回归。

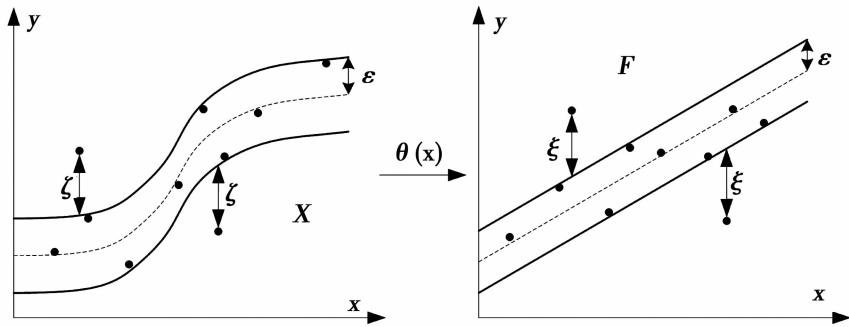


图1 支持向量回归示意图

Fig. 1 Graph of SVR

在训练样本集合 $\{(x_i, y_i)\} \subset R^n \times R, i = 1, 2, \dots, m$ 中, $x$ 为输入值, $y$ 为输出值。非线性映射方程被采用将原空间数据映射到高维空间中,在高维空间中通过 $f(x) = [w^\top \theta(x)] + b$ 进行回归,其中 $b$ 为阈值, $w$ 为权值矢量。根据SVR预测模型的结构风险最小化原则,SVR预测模型的学习过程被转化为一个凸优化。

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (1)$$

$$\text{s. t. } \begin{cases} y^i - w^\top \varphi(x) - b \leq \varepsilon + \xi_i \\ w^\top \varphi(x) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \end{cases} \quad (2)$$

式中: $\xi_i, \xi_i^*$ :松弛变量; $C$ :惩罚因子; $\varepsilon$ :不敏感损失函数。

为了有效地处理上述模型,对偶理论,拉格朗日乘子 $\alpha_i, \alpha_i^*$ 以及核函数被利用,因此上述问题被转化为它的对偶问题:

$$\max -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (a_i - a_i^*) (a_j - a_j^*) K(x_i, x_j) +$$

$$\sum_{i=1}^n a_i^* (y_i - \varepsilon) - \sum_{i=1}^n a_i (y_i - \varepsilon) \quad (3)$$

$$\text{s. t. } \sum_{i=1}^n (a_i - a_i^*) = 0 \quad 0 \leq a_i, a_i^* \leq C \quad (4)$$

式中, $K(x_i, x_j)$ 为SVR的核函数,通过核函数使得在高维空间的内积运算可以采用输入空间的函数实现,有效地避免了维数灾难。在SVR的应用中,高斯径向基核函数(RBF)被经常用做核函数。

$$K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / \sigma^2) \quad (5)$$

构造的SVR回归函数为:

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) K(x_i, x_j) + b \quad (6)$$

当参数( $a_i - a_i^*$ )不为零时,其对应的训练样本被称为支持向量。

## 2 自适应粒子群优化模型参数

在 SVR 模型中,惩罚系数  $C$ 、RBF 核的宽度系数  $\sigma$  和不敏感损失函数  $\varepsilon$  三者的选取对预测的精度影响较大。当  $C$  较大时,会导致模型产生过学习,而  $C$  较小时,又会导致对数据的训练误差变大。 $\sigma$  影响数据样本在高维空间中的分布复杂性, $\sigma$  较小时,会导致模型的推广能力得不到保证,较大时则很难达到预设精度。 $\varepsilon$  反映了模型对输入噪声的敏感性, $\varepsilon$  较小时,模型的学习能力较差,较大则会导致模型无法得到较好的推广。SVR 中的模型参数的选取是一个寻优过程,因此本文采用的优化算法能够在一定范围内选取支持向量回归参数的最优组合,从而获得预测结果较好的 SVR 预测模型。粒子群算法是一种群智能算法,能够有效地寻找全局最优解。它的基本思想是随机初始化一群粒子的位置和速度,在每次迭代中,通过粒子位置、速度的不断更新进而寻找出最优解。由于粒子间存在交互,因此每个粒子都会根据自身极值和全局极值来更新自身的位置和速度。

在本文中,每个解都被一个粒子  $i$  表示,粒子  $i$  的位置用  $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$  表示,速度为  $V_i = (v_{i1}, v_{i2}, \dots, v_{in})$ 。因此所有粒子  $i$  的状态更新方程为:

$$\begin{aligned} v_{id}^{k+1} &= wv_{id}^k + c_1 rand_1^k (pbest_{id}^k - x_{id}^k) + c_2 rand_2^k \\ (gbest_{id}^k - x_{id}^k) \end{aligned} \quad (7)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (8)$$

式中, $k$ : 粒子进化次数; $c_1, c_2$ : 粒子的学习因子,一般取为  $c_1 = c_2 = 2.05$ ; $w$ : 惯性权重; $rand_1^k, rand_2^k$ :  $[0,1]$  之间的随机数; $pbest_{id}^k$ : 粒子  $i$  极值在  $d$  维位置; $gbest_{id}^k$ : 群体全局极值点的  $d$  维位置。

### 2.1 惯性权重更新规则

在粒子每次迭代更新中, $w$  的大小都对算法的全局和局部搜索能力的平衡起决定作用。PSO 在初期寻优过程中需要对全局进行搜索,需要较强的全局搜索能力,而在后期搜索中算法逐步收敛,此时算法应侧重局部搜索能力。因此在本文中,将  $w$  设置为随着迭代次数增加而线性递减,进而可以满足粒子在不同寻优阶段的要求。因此  $w$  和  $n$  的关系如下:

$$w = w_{\max} - n \frac{w_{\max} - w_{\min}}{n_{\max}} \quad (9)$$

式中, $w_{\max}$ : 最大惯性权重; $n$ : 当前迭代次数; $w_{\min}$ : 最小惯性权重; $n_{\max}$ : 最大迭代次数。

### 2.2 自适应变异

在前人对粒子群算法的研究中,传统的粒子群算法易在前期陷入局部最优解。本文采用基于全体平均适应度方差的自适应变异方法对全局极值  $gbest$  进行变异,从而使得 PSO 能够有效地跳出局部最优解,从而寻找全局最优解。其中算法的变异规则基于徐进等<sup>[13]</sup>。

$$W^2 = \frac{1}{n} \sum_{i=1}^n \left( \frac{f_i - f_{avg}}{\max\{|f_i - f_{avg}|}\right)^2 \quad (10)$$

$$f_{avg} = \frac{1}{n} \sum_{i=1}^n f_i \quad (11)$$

式中, $W^2$ : 群体平均适应度方差; $n$ : 粒子数目; $f_i$ : 粒子  $i$  的适应度; $f_{avg}$ : 粒子群当前平均适应度。

全局极值的变异概率为:

$$p_m = \begin{cases} k, W^2 < W_d^2 \\ 0, \text{其它} \end{cases} \quad (12)$$

式中, $k \in [0.3, 0.6]$ ,  $W_d^2 = 0.05$ 。

### 2.3 目标函数

支持向量回归利用训练样本进行训练的目的在于发现参数使得真实值和预测值的偏差最小,在本文选用真实值和预测值的均方误差作为目标函数。

$$Obj = \frac{1}{n} \sum_{i=1}^n (y_i^* - y_i)^2 \quad (13)$$

式中, $y_i^*$  为 SVR 预测模型的预测值, $y_i$  为真实大豆价格。

### 2.4 优化步骤

基于 APSO 优化 SVR 参数建模过程,其具体步骤为:

(1) 对测试样本和训练样本进行归一化处理;

(2) 对 APSO 的迭代次数、种群规模、 $w_{\min}, w_{\max}$  等进行初始化,其中粒子  $i$  的位置被定义为  $(C_i, \sigma_i, \varepsilon_i)$ ,速度为  $(\Delta C_i, \Delta \sigma_i, \Delta \varepsilon_i)$ , $i = 1, 2, \dots, n$ , 初始化粒子的位置范围以及最大最小速度;

(3) 令每个粒子的初始状态为该粒子最优状态。根据式(7)和(8)更新每个粒子的位置和速度;

(4) 根据式(13)计算每个粒子的适应值,对每个粒子的最优解  $pbest_i^k$  以及  $gbest^k$  进行更新。

(5) 根据式(10)、(11)和(12)对粒子进行自适应变异,并根据式(9)调整惯性系数。

(6) 判别终止条件,若  $n > n_{\max}$ , 迭代结束并输出最优结果,否则转步骤(3)继续迭代。

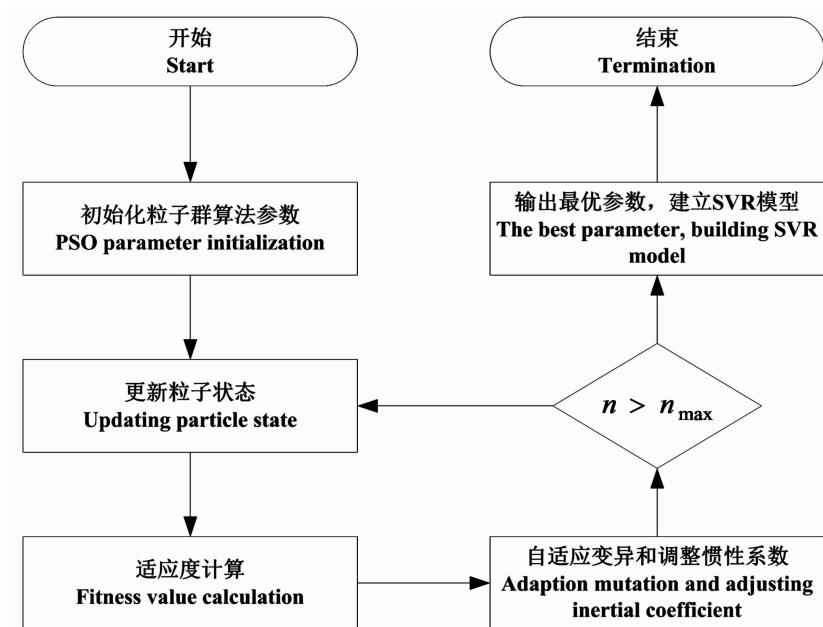


图 2 APSO 流程

Fig. 2 General process of APSO

### 3 实例分析

在本文中,国内大豆的批发价格受到国内大豆供给量、中国大豆进口量、世界大豆产量、国内需求量、中国居民消费价格指数、中国消费者信心指数、进口大豆到港分销价格以及中国货币供应量的 8 个因素影响<sup>[14]</sup>,并将这 8 个影响因素作为输入自变量。本文采用的数据来源于美国农业部 USDA 大豆月度供需报告(<http://www.usda.gov>)、中国统计年鉴、东方财富网、大豆网(<http://bean.100ppi.com/>)以及中国农产品价格调查年鉴。在本文中,大豆价格和影响因素的月份数据被采用,数据样本范围为 2009 年 1 月 – 2016 年 12 月,其中 2009 年 1 月到 2015 年 12 月的数据被用来作为训练集,余下的 2016 年 1 – 12 月的数据作为测试集。

#### 3.1 数据预处理

本文采用 MATLAB 中 Mapminmax 函数对所有的样本数据进行归一化处理,处理的目的是缩小不同属性数据之间存在的数量级差异,归一化公式如下:

$$y_i = (y_{\max} - y_{\min}) (x_i - x_{\min}) / (x_{\max} - x_{\min}) + y_{\min} \quad (14)$$

式中  $x_i$  为原始数据,  $x_{\min}$  为  $x_i$  序列中最小值,  $x_{\max}$  为序列中的最大值,  $y_i$  为归一化处理后输出数据,  $y_{\min}$  和  $y_{\max}$  为常数, 在本文中,  $y_{\min} = 1$ ;  $y_{\max} = 2$ 。归一化处理后的数据  $y_i \in [1, 2]$ 。

#### 3.2 参数设置及结果输出

粒子群算法参数设置如下: 种群规模为 30; 最

大迭代次数为 300;  $w_{\max}$  为 1.2;  $w_{\min}$  为 0.8; 粒子的学习因子  $c_1 = c_2 = 2.05$ 。SVR 中采用 RBF 核函数,采用 APSO 对 SVR 预测模型中的  $C$ 、 $\sigma$  和  $\varepsilon$  进行优化,其中  $C$  的初始优化区间为  $[0.001, 300]$ ,  $\sigma$  的初始取值范围为  $[0.001, 50]$ ,  $\varepsilon$  的取值范围为  $[0.01, 10]$ 。

根据第 2 节和第 3 节的预测方法输入 84 个训练样本进行学习。如图 3 所示,采用 APSO 优化的 SVR 预测模型的大豆价格拟合值和真实样本具有相同的趋势,样本训练  $R^2$  为 0.994, 表明 APSO 优化的 SVR 预测模型的拟合效果较好,其中  $C = 128.1$ ,  $\sigma = 0.039$ ,  $\varepsilon = 0.03$ 。

利用训练后的 SVR 模型对 2016 年 1 月到 2016 年 12 月的大豆价格进行预测,并将其与未经粒子群算法优化的 SVR 和普通粒子群(迭代过程中粒子惯性权重恒定且无自适应变异)优化的 SVR 进行预测结果比较。由表 1 可知,3 种预测模型中 APSO 优化 SVR 模型的预测效果最优,所有测试数据的相对误差均小于 1%,且平均相对误差 MAPE 为 0.38%,而普通粒子群优化 SVR 模型的预测结果中 MAPE 为 0.81%,普通 SVR 模型的预测结果中 MAPE 为 1.12%。上述预测结果表明 SVR 预测模型对于大豆价格的预测精度较高,且采用粒子群优化 SVR 模型参数的预测模型的预测结果优于普通 SVR(未经智能算法优化)预测模型。如图 4 所示,当 SVR 参数被 APSO 优化时,结果明显优于普通 SVR 预测模型以及 PSO 优化的 SVR 预测模型,从中可以看出 APSO 优化的 SVR 模型的外推性和泛化能力较强。

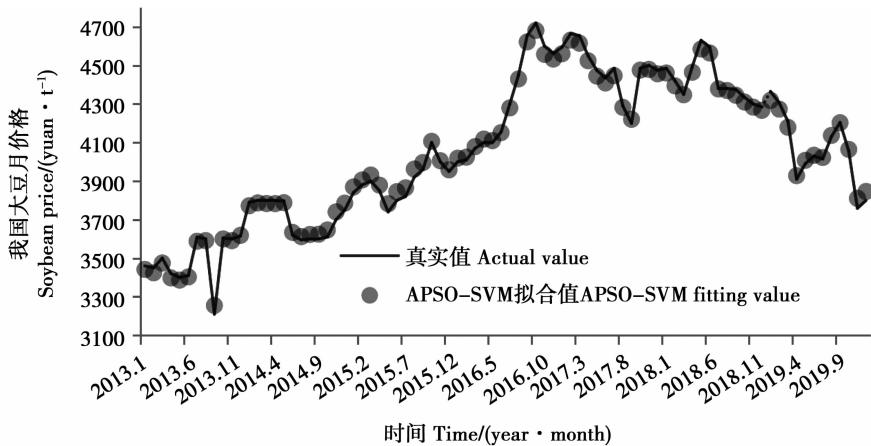


图3 训练样本拟合图  
Fig. 3 The fitting graph of testing sample

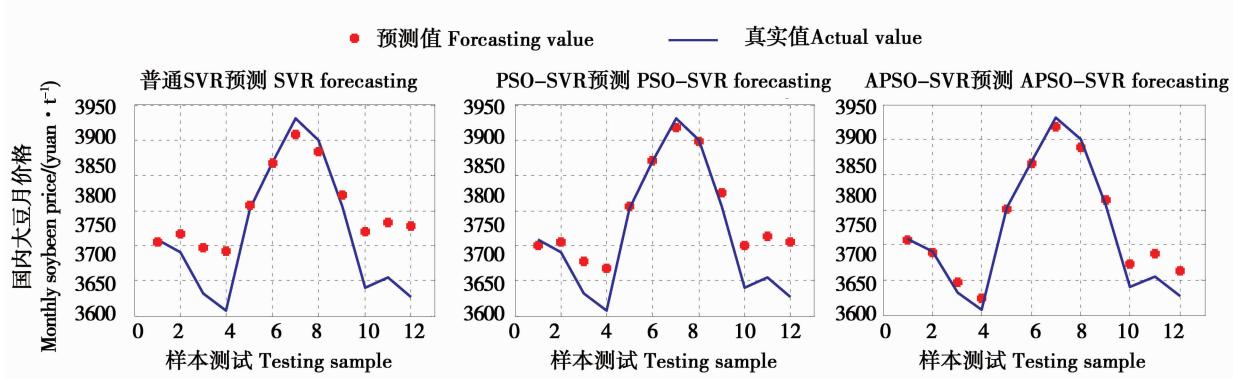


图4 SVR 模型预测结果  
Fig. 4 Predicted results based on the SVR model  
表1 SVR 模型预测结果  
Table 1 Predicted value based on the SVR model

| 时间<br>Time<br>(year. month) | 真实值<br>$y_k$<br>Actual value | 方法 Method  |                                    |  |                                    |  |                                    |
|-----------------------------|------------------------------|--|------------------------------------|--|------------------------------------|--|------------------------------------|
|                             |                              | SVR  |                                    | PSO_SVR  |                                    | APSO_SVR   |                                    |
|                             |                              | 预测值 $\hat{y}_k$<br>/(yuan·t⁻¹)<br>Predicted value<br>/(yuan·t⁻¹) | 相对误差<br>/%<br>Relative error<br>/% | 预测值 $\hat{y}_k$<br>/(yuan·t⁻¹)<br>Predicted value<br>/(yuan·t⁻¹) | 相对误差<br>/%<br>Relative error<br>/% | 预测值 $\hat{y}_k$<br>/(yuan·t⁻¹)<br>Predicted value<br>/(yuan·t⁻¹) | 相对误差<br>/%<br>Relative error<br>/% |
| 2016. 1                     | 3759                         | 3755. 028  | -0. 11                             | 3749. 697  | -0. 25                             | 3757. 584  | -0. 04                             |
| 2016. 2                     | 3741                         | 3766. 136  | 0. 67                              | 3754. 361  | 0. 36                              | 3739. 121  | -0. 05                             |
| 2016. 3                     | 3682                         | 3747. 001  | 1. 77                              | 3727. 151  | 1. 23                              | 3696. 679  | 0. 40                              |
| 2016. 4                     | 3658                         | 3741. 736  | 2. 29                              | 3716. 91   | 1. 61                              | 3673. 959  | 0. 44                              |
| 2016. 5                     | 3802                         | 3807. 149  | 0. 14                              | 3805. 612  | 0. 09                              | 3801. 415  | -0. 02                             |
| 2016. 6                     | 3870                         | 3868. 198  | -0. 05                             | 3871. 231  | 0. 03                              | 3865. 917  | -0. 11                             |
| 2016. 7                     | 3931                         | 3908. 533  | -0. 57                             | 3918. 613  | -0. 32                             | 3918. 909  | -0. 31                             |
| 2016. 8                     | 3900                         | 3883. 213  | -0. 43                             | 3897. 917  | -0. 05                             | 3889. 477  | -0. 27                             |
| 2016. 9                     | 3806                         | 3822. 596  | 0. 44                              | 3825. 217  | 0. 50                              | 3813. 875  | 0. 21                              |
| 2016. 10                    | 3690                         | 3770. 053  | 2. 17                              | 3750. 689  | 1. 64                              | 3722. 693  | 0. 89                              |
| 2016. 11                    | 3705                         | 3782. 929  | 2. 10                              | 3762. 982  | 1. 56                              | 3736. 77   | 0. 86                              |
| 2016. 12                    | 3677                         | 3777. 995  | 2. 75                              | 3754. 913  | 2. 12                              | 3712. 005  | 0. 95                              |
| MAPE                        |                              |  | 1. 12                              |  | 0. 81                              |  | 0. 38                              |

$$\text{Relative error} = \frac{\hat{y}_k - y_k}{y_k}; \text{MAPE} = \frac{1}{n} \sum_{k=1}^n \left| \frac{\hat{y}_k - y_k}{y_k} \right| \times 100\%.$$

### 3.3 结果分析

为了体现 APSO 算法的性能,本文对普通 PSO 和 APSO 的优化能力进行对比。表 1 给出了两种算法优化的 SVR 模型的预测值,PSO 优化的 SVR 模型的预测精度明显低于 APSO 优化的 SVR 模型。为了避免算法随机性带来的影响,本文对两种算法优化的 SVR 模型分别进行 20 次样本测试集预测,如

表 2 PSO 和 APSO 效率对比

Table 2 Contrast efficiency of PSO and APSO

| 测试次数<br>Test times | MAPE/%  |          | 测试次数<br>Test times | MAPE/%  |          |
|--------------------|---------|----------|--------------------|---------|----------|
|                    | PSO_SVR | APSO_SVR |                    | PSO_SVR | APSO_SVR |
| 1                  | 1.09    | 0.55 *   | 11                 | 0.84    | 0.45 *   |
| 2                  | 0.47    | 0.38 *   | 12                 | 0.58    | 0.49 *   |
| 3                  | 0.85    | 0.69 *   | 13                 | 0.49    | 0.49     |
| 4                  | 0.49    | 0.56     | 14                 | 0.60    | 0.67     |
| 5                  | 0.54    | 0.54     | 15                 | 1.05    | 0.58 *   |
| 6                  | 1.11    | 0.49 *   | 16                 | 0.68    | 0.49 *   |
| 7                  | 0.49    | 0.48 *   | 17                 | 0.92    | 0.54 *   |
| 8                  | 0.42    | 0.61     | 18                 | 0.49    | 0.48 *   |
| 9                  | 0.91    | 0.63 *   | 19                 | 1.1     | 0.71 *   |
| 10                 | 0.77    | 0.53 *   | 20                 | 0.77    | 0.60 *   |

\* 表示 APSO\_SVM 在预测精度上优于前者。

\* means APSO\_SVM is better than PSO in the accuracy.

## 4 结论与展望

大豆价格对于农户合理安排种植计划以及大豆进口量等数据的估算具有重要意义,准确地预测大豆价格在不同因素影响下的发展趋势是至关重要的。因此本文采用 SVR 预测模型对国内大豆的月价格进行预测,APSO 对 SVR 模型中的惩罚系数  $C$ 、RBF 核的宽度系数  $\sigma$  和不敏感损失函数  $\varepsilon$  进行优化,利用样本测试集对优化后的 SVR 预测模型进行检验,结果表明,采用 APSO 优化的 SVR 预测模型相对于采用 PSO 算法优化的 SVR 模型在预测精度上存在明显优势。因此本文提出的算法和预测模型能够准确地预测大豆的价格,进而为种植结构等决策提供参考依据。

国内大豆价格预测研究中较多采用灰色理论、时间序列、回归分析等方法,这些预测方法很难处理非线性、多维度的预测问题。近年来采用的神经网络虽能处理上述问题,但预测精度不高。本文采用的支持向量回归预测模型能够同时考虑大豆价格的影响因素以及不同因素的历史信息,从而使其在预测过程中充分发掘信息。在下一阶段将会针对大豆价格的不同影响因素进行分析,并采用支持向量机对不同大豆价格的影响因素进行分类研究,

表 2 所示,APSO 优化 SVR 预测模型在样本测试集中优于 PSO 优化的 SVR 预测模型。75% 的测试中,APSO 优化的 SVR 模型优于 PSO 优化的 SVR 模型,表明 APSO 相对于 PSO 具有更强的搜索能力,能够调出局部最优解,从而寻找到更优解。因此认为 APSO 在优化 SVR 预测大豆价格上具有明显优势。

进而发掘影响大豆价格的深层次因素。

## 参考文献

- [1] 朱婧,范亚东,徐勇. 基于改进 GM(1,1) 模型的中国大豆价格预测 [J]. 大豆科学, 2016, 35(2): 315-319. (Zhu J, Fan Y D, Xu Y. Soybean price prediction in China based on modified GM (1,1) model [J]. Soybean Science, 2016, 35(2): 315-319.)
- [2] 张冬青, 刘欢, 张云清. 基于 Q-RBF 神经网络模型的国产大豆价格预测研究 [J]. 大豆科学, 2017, 36 (1): 143-149. (Zhang D Q, Liu H, Zhang Y Q. Forecasting Chinese domestic soybean price based on Q-RBF neural network model [J]. Soybean Science, 2017, 36(1): 143-149.)
- [3] 范震, 马开平, 姜顺婕, 等. 基于改进 GM(1,N) 模型的我国大豆价格影响因素分析及预测研究 [J]. 大豆科学, 2016, 35 (5): 847-852. (Fan Z, Ma K P, Jiang S J, et al. Influence factors analysis and price prediction of soybean in China based on improved GM (1,N) model [J]. 2016, 35(5): 847-852.)
- [4] 张婷. 基于 ARIMA 模型的国际粮食短期价格分析预测——以大豆为例 [J]. 价格月刊, 2016(7): 28-32. (Zhang T. Analysis and forecast of temporary price of international grain based on ARIMA model-taken soybean as example [J]. Prices Monthly, 2016(7): 28-32.)
- [5] 李剑, 宋长鸣, 项朝阳. 中国粮食价格波动特征研究——基于 X-12-ARIMA 模型和 ARCH 类模型 [J]. 统计与信息论坛, 2013(6): 16-21. (Li J, Song C M, Xiang C Y. Analysis on the price fluctuation of grain product in China: Based on the X-12-

- ARIMA model and the a RCH-type models [J]. Statistics & Information Forum, 2013(6): 16-21.)
- [6] 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. (Duan Q L, Zhang L, Wei F F, et al. Forecasting model and validation for aquatic product pricebased on time series GA-SVR[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33(1): 308-314.)
- [7] 喻胜华, 龚尚花. 基于 Lasso 和支持向量机的粮食价格预测 [J]. 湖南大学学报(社会科学版), 2016, 30(1): 71-75. (Yu S H, Gong S H. A study price prediction based on Lasso and support vector machine [J]. Journal of Hunan University (Social Sciences), 2016, 30(1): 71-75.)
- [8] Gandhi N, Petkar O, Armstrong L J, et al. Rice crop yield prediction in India using support vector machines[C]//Computer Science and Software Engineering (JCSE), 2016 13th International Joint Conference on. IEEE, 2016: 1-5.
- [9] Yousefi M, Khoshnevisan B, Shamshirband S, et al. Support vector regression methodology for prediction of output energy in rice production[J]. Stochastic environmental research and risk assessment, 2015, 29(8): 2115-2126.
- [10] Su Y, Xu H, Yan L. Support vector machine-based open crop model (SBOCM): Case of rice production in China[J]. Saudi Journal of Biological Sciences, 2017, 24(3): 537-547.
- [11] 陈荣, 梁昌勇, 谢福伟. 基于 SVR 的非线性时间序列预测方法应用综述[J]. 合肥工业大学学报(自然科学版), 2013, 36(3): 369-374. (Chen R, Liang C Y, Xie F W. Application of nonlinear time series forecasting methods based on support vector regression [J]. Journal of Hefei University of Technology(Natural Science), 2013, 36(3): 369-374.)
- [12] 林树宽, 杨攻, 乔建忠等. 一种非线性非平稳时间序列预测建模方法[J]. 东北大学学报(自然科学版), 2007, 28(3): 325-328. (Lin S K, Yand M, Qiao J Z, et al. Prediction modelling method for non-linear and nonstationary time series [J]. Journal of Northeastern University(Natural Science), 2007, 28(3): 325-328.)
- [13] 徐进, 费少梅, 张树有等. 自适应粒子群求解资源动态分配项目调度问题[J]. 计算机集成制造系统, 2011, 17(8): 1790-1797. (Xu J, Fei S M, Zhang S Y, et al. Adaptive particle swarm optimization for the project scheduling problem with dynamic allocation of resource [J]. Computer Integrated Manufacturing Systems, 2011, 17(8): 1790-1797.)
- [14] 刘欢, 张冬青. 基于分位数回归的国产大豆价格影响因素分析[J]. 大豆科学, 2014, 33(5): 759-763. (Liu H, Zhang D Q. Analysis on influencing factors of domestic soybean price based on quantile regression [J]. Soybean Science, 2014, 33(5): 759-763.)

## (上接第 597 页)

- [15] 郑小波, 王帅帅, 陆辰晨, 等. 一种检测胶孢炭疽菌的环介导等温扩增引物组合物及其应用: 中国, 201510030095.6[P]. 2015-05-13. (Zheng X B, Wang S S, Lu C C, et al. A primer combination for detecting *Colletotrichum gloeosporioide* using loop-mediated isothermal amplification(LAMP) assays and its application: China, 201510030095.6[P]. 2015-05-136.)
- [16] Xu M, Ye W W, Zeng D D, et al. Rapid diagnosis of wheat head blight caused by *Fusarium asiaticum* using a loop-mediated isothermal amplification assay[J]. Australasian Plant Pathology, 2017, 46(3): 261-266.
- [17] Zeng D D, Ye W W, Xu M, et al. Rapid diagnosis of soybean root rot caused by *Fusarium culmorum* using a loop-mediated isothermal amplification assay [J]. Journal of Phytopathology, 2017, 165(4): 249-256.
- [18] Lu C C, Zhang H F, Wang Y C, et al. Rapid diagnosis of *Fusarium* root rot in soybean caused by *Fusarium equiseti*, or *Fusarium graminearum*, using loop-mediated isothermal amplification (LAMP) assays [J]. Australasian Plant Pathology, 2015, 44(4): 437-443.
- [19] Lu C C, Dai T T, Zhang H F, et al. Development of a loop-mediated isothermal amplification assay to detect *Fusarium oxysporum* [J]. Journal of Phytopathology, 2015, 163(1): 63-66.
- [20] 许苗, 叶文武, 王淑琛, 等. 快速检测马铃薯干腐病病原接骨木镰孢的环介导等温扩增技术[J]. 植物病理学报, 2017. DOI: 10.13926/j.cnki.apps.000038. (Xu M, Ye W W, Wang S C, et al. Rapid diagnose of potato dry rot caused by *Fusarium sambucinum* using a loop-mediated isothermal amplification assay [J]. Acta Phytopathologica Sinica, 2017. DOI: 10.13926/j.cnki.apps.000038.)
- [21] 曾丹丹. 拟枝梗镰孢、黄色镰孢、雪松疫霉、栗黑水疫霉及大豆种传病原菌的 LAMP 检测[D]. 南京: 南京农业大学, 2017. (Zeng D D. LAMP detection of *Fusarium Verticillioides*, *F. Culorum*, *Phytophthora Lateralis*, *P. Cambivora* and seed-borne pathogens on soybean[D]. Nanjing: Nanjing Agricultural University, 2017.)
- [22] Lu C C, Song B, Zhang H F, et al. Rapid diagnosis of soybean seedling blight caused by *Rhizoctonia solani* and soybean charcoal rot caused by *Macrophomina phaseolina* using LAMP assays [J]. Phytopathology, 2015, 105(12): 1612.
- [23] Dai T T, Shen H, Zheng X B. Establishment and evaluation of aTEF1- $\alpha$ , based loop-mediated isothermal amplification assay for detection of *Phomopsis longicolla*[J]. Australasian Plant Pathology, 2016, 45(3): 335-337.
- [24] Dai T T, Lu C C, Lu J, et al. Development of a loop-mediated isothermal amplification assay for detection of *Phytophthora sojae* [J]. FEMS Microbiology Letters, 2012, 334(1): 27-34.