

# 基于 Q-RBF 神经网络模型的国产大豆价格预测研究

张冬青,刘欢,张云清

(南京农业大学工学院,江苏南京 210031)

**摘要:**大豆是重要的经济作物,同时也是我国市场化和国际化程度最高的大宗农产品,对其价格进行预测具有重要意义。采用 Q-RBF 神经网络模型对国产大豆价格进行预测,该模型具有如下两个特点:(1)通过分位数回归功能来描述大豆在不同价格水平下的分布特征;(2)通过 RBF 神经网络结构来刻画大豆价格的非线性关系。在模型参数优化时,由于遗传算法是一种全局搜索优化方法,但是搜索速度慢、对初始值具有一定依赖性;而梯度下降法具有收敛快,对初始值没有特定要求等优点,所以本文提出遗传算法与梯度下降法相结合的混合改进算法,其基本思想是利用梯度下降法的局部寻优能力加快遗传算法的收敛速度。采用 2010 年 1 月 - 2015 年 12 月的国产大豆月度价格数据进行预测研究,结果表明,算法收敛速度较快,模型预测精度较高,是可以泛化应用的预测模型。

**关键词:**预测;Q-RBF 神经网络;梯度下降法;遗传算法;概率密度函数

**中图分类号:**F224.7      **文献标识码:**A      **DOI:**10.11861/j.issn.1000-9841.2017.01.0143

## Forecasting Chinese Domestic Soybean Price Based on Q-RBF Neural Network Model

ZHANG Dong-qing, LIU Huan, ZHANG Yun-qing

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

**Abstract:** Soybean is an important cash crop, and it is also the most important agricultural product with the highest degree of marketization and internationalization character in China. So it is essential to forecast the soybean price. A Quantile-RBF (Q-RBF) neural network model is proposed to predict Chinese domestic soybean price in this paper. The model has two characteristics as follows: (1) Quantile regression models describe the distribution over the range of the soybean price; (2) RBF neural networks approximate the nonlinear part of soybean price. The parameters of Q-RBF neural network model can be optimized through the genetic algorithm (GA) and the gradient descent method. GA is a global optimization method, however, it might be slow in convergence. On the contrary, the gradient descent method quickly converges to an optimal solution, but may converge to a local minimum or maximum and is not efficient in discontinuous problems. Therefore, an improved algorithm combining GA with gradient descent method is proposed in this paper. In the improved algorithm, the gradient descent method is used to improve the convergence efficiency of GA. The data of monthly soybean price from Jan. 2010 to Dec. 2015 were analyzed. Experimental results demonstrated that the Q-RBF neural network model and improved algorithm were accurate and effective.

**Keywords:** Forecasting; Quantile regression-radial basis function (Q-RBF) neural network; Gradient descent method; Genetic algorithm; Probability density function

大豆是重要的经济作物,作为目前我国市场化和国际化程度最高的大宗农产品,在国民经济中具有重要地位<sup>[1]</sup>。近年来,国产大豆价格表现出总体上涨、波动频繁的基本走势,且其波动造成的影响扩散快、波及面广、复杂性高,冲击农业经济平稳局面。因而,有效预测大豆价格,有利于大豆经营者获得最优效益,保障居民生活稳定,对国民经济发展具有重要意义。

很多学者对大豆价格预测进行研究,张婷<sup>[2]</sup>以大豆为例采用 ARIMA 模型对国际粮食短期价格进行预测;朱婧等<sup>[3]</sup>采用改进 GM(1,1)模型预测国产大豆价格;程文晓<sup>[4]</sup>分别采用主成分回归和指数平滑模型对国产大豆期货价格进行预测;石波等<sup>[5]</sup>采用改进 RBF 神经网络对我国大豆价格进行预测;毛

学峰等<sup>[6]</sup>采用动态特征定价模型和误差修正模型分析得出中国大豆、豆油和豆粕 3 种产品价格之间存在长期均衡关系;Berwald 等<sup>[7]</sup>采用状态空间方程模型对大豆及制品的期货价格和现货价格进行预测研究;Arnade 等<sup>[8]</sup>采用误差修正模型分析大豆及制成品的现货和期货价格之间关系;Adrang 等<sup>[9]</sup>研究了美国大豆、豆制品和豆油三者期货价格变动关系。上述研究大多是以均值来描述大豆价格整体变化,不能很好刻画大豆价格处于高位或低位情况,而且经典均值回归需要满足较严格的条件,如等方差性,随机误差正态分布等;当数据分布是重尾或有异常值时,结果稳健性较差;特别是对于大量数据,均值回归只能得到一条回归曲线,其所能提供的信息有限。而分位数回归能很好地解决这

一问题,其使用条件更为宽松,挖掘信息更丰富,它不仅可以度量解释变量在分布中心的影响,而且还可以度量解释变量在分布上尾和下尾的影响,即捕捉整个条件分布的特征。最常用的分位数回归是将自变量与因变量关系表达为线性范式,但是社会经济行为往往表现为非线性关系,因此本文将采用分位数回归(quantile regression)与径向基函数(RBF)神经网络相结合的Q-RBF神经网络预测模型,该模型具有如下两个特点:一方面,通过其分位数回归功能来揭示响应变量整个条件分布特征,即描述大豆分别在不同价格水平下的分布特征;另一方面,通过RBF神经网络结构,来模拟经济系统中的非线性结构,即刻画大豆价格的非线性关系。对国产大豆价格进行有效预测,为政府制定大豆相关政策提供理论依据,为大豆生产者和经营者提供理论指导。

## 1 Q-RBF神经网络预测模型

### 1.1 分位数回归

在社会科学研究领域,非对称、非中心位置往往是其研究关注点。为了弥补均值回归的缺陷,1978年,Koenker等<sup>[10]</sup>提出分位数回归模型,它是均值回归模型的自然扩展。

在一组数据中,若某一数值超过 $\tau$ 比例并小于 $1-\tau$ 比例则称该数值为第 $\tau$ 分位数。设 $F(x) = P(X \leq x)$ 为实值随机变量 $X$ 的分布函数,则对任意 $\tau \in [0, 1]$ ,有

$$F^{-1}(\tau) = \inf\{x: F(x) \geq \tau\} \quad (1)$$

则称式(1)为 $x$ 的第 $\tau$ 分位数,记作 $Q(\tau|x)$ ,并定义

$$Q(\tau|x) = x^T \beta(\tau) \quad (2)$$

式中, $Q(\tau|x)$ 为第 $\tau$ 分位数函数; $\beta(\tau)$ 为系数向量,随着 $\tau$ 变化而不同。分位数回归本质是通过 $\tau$ 在 $[0, 1]$ 之间任意取值来调节回归平面的位置和方向,让因变量对自变量产生不同分位数下的响应变化。

给定一组随机样本 $Y = \{y_1, \dots, y_i\}$ 。可通过最小化绝对残差总和估计参数 $\beta(\tau)$ ,即

$$\arg \min_{\beta \in R} \left[ \sum_{y_k \geq x_k^T \beta} \tau |y_k - x_k^T \beta| + \sum_{y_k < x_k^T \beta} (1 - \tau) |y_k - x_k^T \beta| \right] \quad (3)$$

### 1.2 Q-RBF神经网络

式(2)为线性分位数回归模型,即自变量和因变量为线性关系。但是社会系统本质是非线性,人工神经网络能够很好地刻画这种非线性关系,Taylor结合分位数回归与神经网络的优点,提出分位数-神经网络模型<sup>[11]</sup>,该模型可分为两个阶段。

(1)第一阶段:建立从输入层到隐含层的连接。

$$G_j(\tau|X) = \sum_{i=1}^n g_1[v_{ij}(\tau)x_i], j=1, \dots, m \quad (4)$$

其中 $G_j(\tau|X)$ 为第 $j$ 个隐含层节点输出值, $X = \{x_i\}, i=1, \dots, n$ 为输入层的 $n$ 维向量, $v_{ij}(\tau)$ 为输入层第 $i$ 个输入节点到隐含层第 $j$ 个节点连接权值, $g_1$ 为隐含层节点核函数。

(2)第二阶段:建立从隐含层到输出层的连接。

$$Q_k(\tau|X) = \sum_{j=1}^m g_2[w_{jk}(\tau)G_j(\tau|X)], k=1, \dots, l \quad (5)$$

式中, $Q_k(\tau|X)$ 为输出层第 $k$ 个节点输出值, $w_{jk}(\tau)$ 为隐含层第 $j$ 个节点到输出层第 $k$ 个节点连接权值, $g_2$ 为输出层节点核函数。根据式(4)和式(5),分位数-神经网络模型可表示为:

$$Q(\tau|X) = F(X, V(\tau), W(\tau)), \tau \in [0, 1] \quad (6)$$

其中, $F(X, V(\tau), W(\tau))$ 是由权值向量 $V(\tau) = [v_{ij}]^T, W(\tau) = [w_{jk}]^T, i=1, \dots, n; j=1, \dots, m; k=1, \dots, l$ 复合而成的分位数 $\tau$ 下非线性函数。 $F(X, V(\tau), W(\tau)) = \{f_k(X, V(\tau), W(\tau))\}, k=1, \dots, l$ ,对于网络输出 $l$ 维向量,其表达式为:

$$f_k(X, V(\tau), W(\tau)) = \sum_{j=1}^m g_2\{w_{jk}(\tau) \sum_{i=1}^n g_1[v_{ij}(\tau)x_i]\}, k=1, \dots, l \quad (7)$$

Taylor提出分位数-神经网络模型的框架,本文选取RBF神经网络作为该模型具体网络结构,建立Q-RBF神经网络模型。RBF神经网络属于前向型神经网络,输入层节点直接输入到隐含层,隐含层采用径向基函数构造映射空间,输出层采用线性输出模式,故式(7)中 $V_{ij}(\tau) = 1, g_1$ 为径向基函数, $g_2$ 为简单线性函数,则Q-RBF神经网络模型的表达式为:

$$Q(\tau|X) = F(X, W(\tau)) \quad (8)$$

式中 $F(X, W(\tau)) = \{f_k(X, W(\tau))\}, k=1, \dots, l$ 。用 $\varphi$ 代替隐含层节点核函数 $g_1$ ,则Q-RBF神经网络输出 $l$ 维向量的表达式为:

$$f_k(X, W(\tau)) = \sum_{j=1}^m w_{jk}(\tau) \left[ \sum_{i=1}^n \varphi_j(x_i) \right] = \sum_{j=1}^m w_{jk}(\tau) \varphi_j(\tau|X), k=1, \dots, l \quad (9)$$

本文 $\varphi$ 采用高斯核函数,即 $\varphi(\tau|X) = \exp(-\|X - C(\tau)\|^2 / 2\sigma^2)$ , $C(\tau)$ 为隐含层节点中心, $\sigma$ 为扩展常数。

根据分位数回归参数估计原理,Q-RBF神经网络模型参数可由最小化误差函数得到,即

$$\min(E(\tau)) = \min \left( \sum_{Y_k \geq f(X_k, W)} \tau |Y_k - F(X_k, W(\tau))| + \sum_{Y_k < f(X_k, W)} (1 - \tau) |Y_k - F(X_k, W(\tau))| \right) \quad (10)$$

1.3 概率密度预测

类比于均值回归模型对响应变量的条件均值进行预测,分位数回归模型则对响应变量的整个条件分布进行预测。但面对数量众多有效信息,如何利用不同分位数下  $Q(\tau)$  值获得精度较高预测结果则是 Q-RBF 神经网络预测模型的核心问题。

对于确定分位数  $\tau$ ,  $Q(\tau)$  描述第  $\tau$  分位数预测值,当  $\tau$  在  $[0,1]$  连续取值,  $Q(\tau)$  描述随  $\tau$  变化的分位数曲线,即分位数函数。根据分位数回归定义可知,假设  $F$  是一个响应变量  $Y$  的累积分布函数,则<sup>[10]</sup>

$$F(Q(\tau)) = F(F^{-1}(\tau)) = \tau \tag{11}$$

许启发等<sup>[12]</sup>证明概率密度函数可根据如下公式求得,

$$f(Q(\tau)) = d\tau/dQ(\tau) \tag{12}$$

对式(12)关于  $X$  条件化,即可得到  $Y$  的条件概率密度  $f(Q(\tau|X))$ ,从而进行预测。

1.4 预测模型

大豆价格属于多维输入单维输出的预测问题,具体结构如图 1 所示。其中 Q-RBF 模型为  $p$ - $n$ - $m$ -1 结构的叠加型 RBF 神经网络,  $p$  为分位数  $\tau$  在  $[0,1]$  范围内取值个数,  $\Delta$  为分位数取值间隔,则预测模型由  $p$  个具有  $n$ - $m$ -1 基本结构的 RBF 神经网络叠加组成。对于给定任一  $\tau$  分位数,预测模型都能获得 1 个具有  $n$  个输入层节点、 $m$  个隐含层节点、1 个输出层节点的 RBF 神经网络,如图 1 中虚线框所示。因而,当分位数  $\tau$  取不同值时,可通过优化方法获得随  $\tau$  变化结构和参数的 Q-RBF 神经网络模型,每一模型都具有满足误差条件的最优结构和参数。当获得  $p$  个网络输出值  $Q(\tau|X)$  后,由条件概率密度函数  $f(Q(\tau|X))$  计算每一  $Q(\tau|X)$  的概率密度,并以最大概率密度对应的  $\hat{Q}(\tau|X)$  值作为最终预测值。

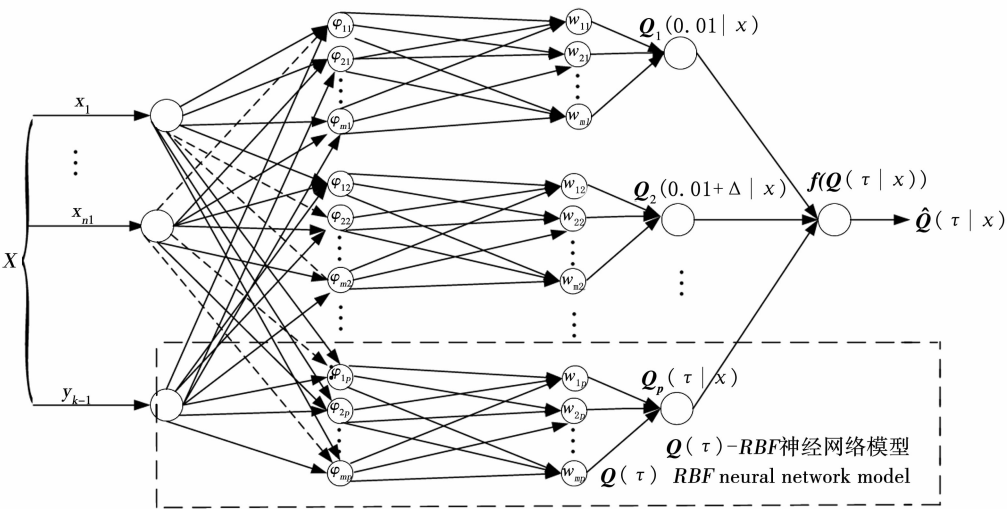


图 1 Q-RBF 神经网络预测模型

Fig. 1 Q-RBF neural network prediction model

值得注意的是,本文模型输入  $X$  由两部分组成:  $\{x_i\}, (i=1, \cdots, n1)^T$  为  $n1$  维影响因素,每一维影响因素是否作为最终输入是不定的,在预测中由优化算法确定,虚线表示不输入影响因素  $x_i$ ,实线表示输入影响因素  $x_i$ ;  $y_{t-q}$  为研究对象延迟  $q$  阶的历史数据,作为固定输入。

2 Q-RBF 神经网络预测模型改进算法设计

Q-RBF 神经网络模型要用于预测,需要确定合理的结构与参数,它直接影响到模型泛化能力和预测精度。目前分位数神经网络研究较少, Cannon<sup>[13]</sup> 和何耀耀等<sup>[14]</sup> 采用梯度下降法来优化模型参数。梯度下降法具有搜索速度快、对初始值没有特定要求等优点,但是容易陷入局部最优;遗传算法(GA)

具有全局寻优能力,但搜索效率低,且对初始值具有一定依赖性<sup>[15]</sup>。因此本文提出将 GA 与梯度下降法相结合的混合改进算法,其基本思想是先利用梯度下降法快速收敛缩小最优解范围,并将迭代一定次数后的参数作为 GA 初始种群,再利用 GA 进行训练,以获得满足误差要求的最优解。

Q-RBF 神经网络模型由分位数回归与 RBF 神经网络复合而成,因而模型结构参数包括两部分: RBF 神经网络的结构与参数;分位数回归结构(不涉及参数估计)。其中分位数回归结构即分位数个数  $p$  取决于分位数取值间隔,由计算复杂度和预测精度共同确定; RBF 神经网络输入维度  $n$  根据研究对象影响因素定性分析和经验分析初步确定,然后和隐含层节点数  $m$ 、径向基函数中心  $C$ 、扩展常数  $\sigma$

及输出层权值  $W$  一起由优化算法来确定。

算法具体流程如图 2 所示：

- (1)采用归一化法对原始数据进行预处理；
- (2)确定 Q-RBF 神经网络模型结构与参数的初始取值范围；
- (3)编码,输入维度  $n$  采用二进制编码,隐含层节点数  $m$ 、径向基函数中心  $C$ 、扩展常数  $\sigma$  及输出层权值  $W$  采用实值编码；
- (4)初始种群,确定种群规模；
- (5)初步优化,采用梯度下降法对 Q-RBF 神经网络模型参数进行初步优化,并将优化后参数作为 GA 的初始值；

- (6)适应度计算,采用误差函数  $E(\tau)$  的倒数  $1/E(\tau)$  作为适应度函数；
- (7)选择,采用随机遍历抽样法对父代个体进行选择；
- (8)交叉,对实值编码采用离散重组交叉,对二进制编码采用单点交叉；
- (9)变异,对实值编码采用实值变异,对二进制编码采用基本位变异；
- (10)终止条件,判断误差是否小于目标值或者遗传操作是否满足迭代次数,如果满足返回最优解,否则返回第(5)步。

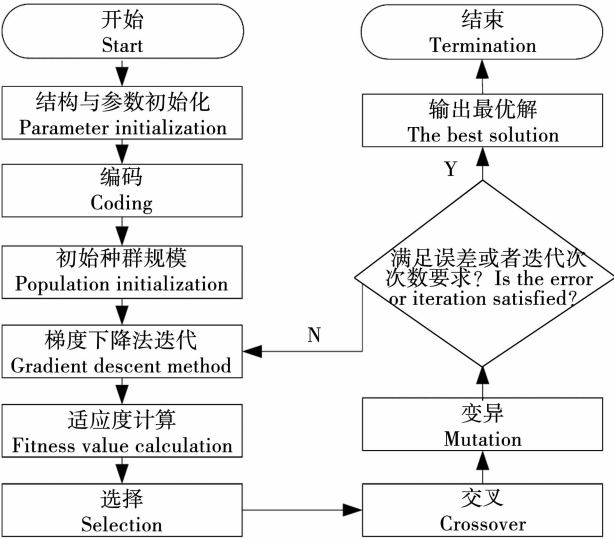


图 2 改进算法流程

Fig. 2 General process of improved algorithm

3 实证分析

3.1 数据选取及来源

基于刘欢和张冬青的研究<sup>[16]</sup>并结合调查分析,国产大豆价格的可能影响因素如下:国产大豆自给量  $x_1$  ( $10^6\text{t}$ ),中国大豆进口量  $x_2$  ( $10^6\text{t}$ ),世界大豆产量  $x_3$  ( $10^6\text{t}$ ),国内大豆需求量  $x_4$  ( $10^6\text{t}$ ),居民消费价格指数  $x_5$ ,消费者信心指数  $x_6$ ,货币供应量  $x_7$  (亿元),进口大豆到港分销价格  $x_8$  ( $\text{元}\cdot\text{t}^{-1}$ ),延迟  $q$  阶的国产大豆价格  $y_{t-q}$  ( $\text{元}\cdot\text{t}^{-1}$ )。

本文国产大豆价格  $y_k$  及相关影响因素均是月数据,样本范围为 2010 年 1 月 - 2015 年 12 月 (共 72 个样本)。将样本分为训练集与测试集,训练集为 2010 年 1 月 - 2015 年 4 月,用来训练模型;测试集为 2015 年 5 月 - 2015 年 12 月,用来检验模型预测效果。其中,国产大豆价格数据根据历年《饲料广角》期刊所提供《大豆市场回顾及行情展望》,对国内主要批发市场国产大豆价格整理所得;供给与需求因素来源于美国农业部 USDA 大豆月度供需报

告 (<http://www.usda.gov>),宏观经济因素来源于东方财富网 (<http://www.eastmoney.com>)。

- 3.2 基于 Q-RBF 神经网络模型的大豆价格预测
- 3.2.1 初始参数选取 由 1.4 节可知,模型输入  $X = \{x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, y_{k-i}\}^T$ 。影响因素维度  $n1$  取值范围为  $[1, 8]$  内的整数;历史数据延迟阶数根据经验确定,本文取延迟 1 阶 ( $q = 1$ ) 的历史数据作为模型固定输入。隐含层节点数  $m$  初始值,根据经验公式在  $[5, 13]$  上随机取整数值;径向基函数中心  $C$  初始取值范围为  $[0, 1.5]$ ;扩展常数  $\sigma$  初始取值范围为  $[0, 2]$ ;输出层权值  $W$  的初始取值范围为  $[0, 1]$ 。除了  $q$  为确定值外,影响因素维度  $n1$ 、隐含层节点数  $m$ 、径向基函数中心  $C$ 、扩展常数  $\sigma$ 、输出层权值  $W$  均需要通过算法进一步优化。此外,梯度下降步长均取 0.001 5,运行次数为 3 次;GA 初始种群规模为 80,交叉概率为 0.9,变异概率为 0.1,迭代次数为 150 次,误差要求  $E(\tau)$  为 0.03。
- 3.2.2 预测 根据第 2 节算法,输入训练样本进行学习,获得各分位数下 Q-RBF 预测模型。图 3 分别

为 $\tau=0.1,0.3,0.6,0.9$  预测模型的拟合值,4 条拟合曲线与真实样本曲线趋势基本一致,拟合效果较好,且按分位数大小排列,符合分位数思想,具有合理性和有效性。




图3 第 0.1,0.3,0.6,0.9 分位数 Q-RBF 神经网络模型训练拟合曲线

Fig.3 Fitting curves of 0.1,0.3,0.6,0.9 quantile Q-RBF neural network model

采用训练后 Q-RBF 神经网络对 2015 年 5 - 12 月国产大豆价格(测试样本)进行预测,结果见表 1 和图 4。由表 1 可知,所有月份预测相对误差绝对值均小于 1.8%,平均相对误差 MAPE 为 1.11%,表明该模型预测精度较高。从图 4 可以看出,预测值与真实值的趋势基本一致,拟合效果较好,说明 Q-RBF 模型外推性能好、泛化能力强。

表 1 Q-RBF 神经网络模型预测结果

Table 1 Predicted values and errors based on the Q-RBF neural network model

结果 Result	时间 Time/( year. month)							
	2015.5	2015.6	2015.7	2015.8	2015.9	2015.10	2015.11	2015.12
真实值 Actual value/(yuan · t <sup>-1</sup> )	3990	4030	4015	4130	4204	4056	3759	3800
预测值 $\hat{y}_k$ Predicted value/(yuan · t <sup>-1</sup> )	4011	3998	3964	4056	4180	4122	3701	3772
相对误差 Relative error/%	0.53	-0.79	-1.27	-1.79	-0.57	1.63	-1.54	-0.74
平均相对误差 MAPE/%	1.11							

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




图4 Q-RBF 神经网络模型预测结果

Fig.4 Predicted bean prices based on the Q-RBF neural network model

3.2.3 结果比较 为了考察改进算法性能,本文对算法改进前后预测精度与收敛效率进行比较。简洁起见,只采用 GA 优化 Q-RBF 神经网络模型结构与参数称为 GA,而用梯度下降法和 GA 相结合的混合算法简称为改进算法。两种方法的平均相对误差和收敛效率分别见表 2 和表 3。表 2 所示,改进算法最大相对误差绝对值和平均相对误差分别为 1.79%、1.11%,均优于改进前 3.17%、1.77%。说明基于 GA 和梯度下降法的混合算法预测效果更

佳。表 3 给出固定误差  $E(\tau) = 0.025$  时  $\tau = 0.1, 0.3, 0.6, 0.9$  算法改进前后最终迭代次数,除个别点以外,5 次运算中改进算法达到误差要求的迭代次数均要小于改进前。因而可认为,在开始阶段使用梯度下降法迭代求解,并将迭代一定次数后参数作为遗传算法初始值,能够加快优化的收敛效率。

综上可知改进算法无论在预测精度还是在收敛效率方面都具有明显优势。

表 2 算法改进前后的预测值与预测误差

Table 2 Comparison of the performance between GA and the improved algorithm

方法 Method	时间 Time ( year. month)									
	2015. 5	2015. 6	2015. 7	2015. 8	2015. 9	2015. 10	2015. 11	2015. 12	MAPE	
GA	真实值 $y_k$ Actual value/( yuan·t <sup>-1</sup> )	3990	4030	4015	4130	4204	4056	3759	3800	
	预测值 $\hat{y}_k$ Predicted value/( yuan·t <sup>-1</sup> )	3952	3994	3968	3999	4109	4090	3890	3746	
	相对误差 Relative error/%	-0.95	-0.89	-1.17	-3.17	-2.26	0.84	3.48	-1.42	1.77
改进算法 Improved algorithm	预测值 $\hat{y}_k$ Predicted value/( yuan·t <sup>-1</sup> )	4011	3998	3964	4056	4180	4122	3701	3772	
	相对误差 Relative error/%	0.53	-0.79	-1.27	-1.79	-0.57	1.63	-1.54	-0.74	1.11

表 3 算法改进前后收敛效率对比

Table 3 Contrast of convergence efficiency based on GA and improved algorithm

测试次数 Test times	$\tau$	满足误差的代数 Number of iterations to meet specified error		测试次数 Test times	$\tau$	满足误差的代数 Number of iterations to meet specified error	
		GA	改进算法			GA	改进算法
			Improved algorithm				Improved algorithm
1	0.1	21	16	4	0.6	297	81 *
	0.3	250	128 *		0.9	6	9
	0.6	282	260 *		0.1	17	15 *
	0.9	25	18 *		0.3	288	153 *
2	0.1	13	24 *	5	0.6	153	80 *
	0.3	277	131 *		0.9	18	15 *
	0.6	N	95 *		0.1	24	20 *
	0.9	9	13		0.3	103	N
3	0.1	13	16		0.6	238	35 *
	0.3	N	113 *		0.9	19	16 *

\* 表示改进算法在这一参数上优于改进前; N 表示迭代 300 次后无法满足误差要求。  
\* means improved algorithm is better than GA on the indicator; N means the model doesn't meet error limit after 300 iterations.

#### 4 结论与讨论

针对国产大豆价格具有非对称性、非线性特点,本文采用 Q-RBF 神经网络模型对其进行预测。该模型由两部分组成:模型外部框架为分位数回归结构,内部核心为 RBF 神经网络结构。同时,本文提出梯度下降法与 GA 结合的混合算法来同步优化模型结构与参数。国产大豆价格预测结果表明本

文模型与算法的有效性,在预测精度和收敛效率两方面均具有明显优势,是可以进行泛化应用的预测模型。

目前,国产大豆价格预测方法主要有灰色理论<sup>[3]</sup>、时间序列法<sup>[2]</sup>、回归分析<sup>[4]</sup>等。灰色理论和时间序列预测法都只利用研究对象本身历史数据信息,而回归分析仅考虑影响因素信息,且是以均值来描述大豆价格整体变化。本文提出采用 Q-

RBF 神经网络预测模型,能同时考虑影响因素和研究对象历史信息,使用条件更为宽松,挖掘信息更丰富;不仅可以度量解释变量在分布中心的影响,而且描述大豆在不同价格水平下的分布特征。在模型参数优化时,Cannon<sup>[13]</sup> 和何耀耀等<sup>[14]</sup> 采用梯度下降法来优化模型参数,但是梯度下降法可能陷入局部最优,为此本文利用遗传算法全局寻优特点,对算法进行改进。

参考文献

[1] 奚晓菁. 我国大豆价格波动影响因素分析[D]. 昆明: 云南财经大学, 2013. (Xi X J. Analysis on the influencing factors of soybean price fluctuation in China[D]. Kunming: Yunnan University of Finance and Economics, 2013. )

[2] 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, (470): 28-32. (Zhang T. Analysis and prediction of short term international grain price based on ARIMA model: A case study of soybean[J]. Prices Monthly, 2016, (470): 28-32. )

[3] 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. )

[4] 程文晓. 我国大豆期货价格的预测分析[D]. 兰州: 兰州大学, 2014. (Cheng W X. Forecasting of soybean futures prices in China[D]. Lanzhou: Lanzhou University, 2014. )

[5] 石波, 张冬青, 马开平, 等. 改进 RBF 神经网络在我国大豆价格预测中的应用研究[J]. 大豆科学, 2016, 35(2): 310-314. (Shi B, Zhang D Q, Ma K P, et al. Soybean price prediction in China based on improved RBF neural network[J]. Soybean Science, 2016, 35(2): 310-314. )

[6] 毛学峰, 贾伟. 大豆及制成品动态特征价格的实证研究[J]. 农业技术经济, 2016(7): 73-80. (Mao X F, Jia W. An empirical study on the price of dynamic characteristics of soybean and manufactured goods [J]. Journal of Agrotechnical Economics, 2016(7): 73-80. )

[7] Berwald D, Havenner A. Evaluating state space forecasts of soybean complex prices [M]// Aoki M, et al . Applications of computer aided time series modeling. New York: Springer-Verlag, Inc. 1997.

[8] Arnade C, Hoffman L. The impact of price variability on cash/futures market relationships: Implications for market efficiency and price discovery[J]. Journal of Agricultural & Applied Economics, 2015, 47(4): 539-559.

[9] Adrangi B, Chatrath A, Raffiee K. Price discovery in the soybean futures market[J]. Journal of Business & Economics Research, 2011, 4(6): 77-88.

[10] Koenker R, Bassett G W. Regression quantiles[J]. Econometric, 1978, 46:33-50.

[11] Taylor J W. A quantile regression neural network approach to estimating the conditional density of multiperiod returns[J]. Journal of Forecasting, 2000, 19(4): 299-311.

[12] 许启发, 蒋翠侠. 分位数局部调整模型及应用[J]. 数量经济技术经济研究, 2011(8): 115-133. (Xu Q F, Jiang C X. Quantile partial adjustment model and its application [J]. The Journal of Quantitative & Technical Economics, 2011(8): 115-133. )

[13] Cannon A J. Quantile regression neural networks: Implementation in R and application to precipitation downscaling[J]. Computers & Geosciences, 2011, 37: 1277-1284.

[14] 何耀耀, 许启发, 杨善林等. 基于 RBF 神经网络分位数回归的电力负荷概率密度预测方法[J]. 中国电机工程学报, 2013, 33(1): 93-98. (He Y Y, Xu Q F, Yang S L, et al. A power load probability density forecasting method based on RBF neural network quantile regression[J]. Proceedings of the CSEE, 2013, 33(1): 93-98. )

[15] Mok T K, Liu H M, Ni Y X, et al. Tuning the fuzzy damping controller for UPFC through genetic algorithm with comparison to the gradient descent training[J]. Electrical Power and Energy Systems, 2005, 27: 275-283.

[16] 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. )