

DOI: 10.13382/j.jemi.2017.12.002

# 非线性时间序列粒子群优化 B 样条网络预测模型\*

龚小龙 孔玲爽 袁川来 肖会芹

(湖南工业大学 电气与信息工程学院 株洲 412007)

**摘要:**为了提高非线性时间序列的预测精度,建立一种粒子群优化 B 样条网络预测模型。在设计网络结构时,设置样条基函数节点作为独立变量,然后使其与权值参数在网络训练过程中一同优化,并且使用预测误差平方和评价训练效果。采用粒子群算法与适当的搜索策略作为训练算法,对 B 样条基函数最优节点的分布进行搜索,同时寻优权值参数,使网络结构得到优化,进而对非线性时间序列进行预测。仿真结果表明,粒子群优化 B 样条网络预测模型具有良好的泛化性能,同时所用算法对网络进行了有效的优化,所建预测模型结构简单且预测精度较高。

**关键词:** B 样条网络;粒子群算法;非线性时间序列;预测模型

**中图分类号:** TP274; TN911.72 **文献标识码:** A **国家标准学科分类代码:** 520.2060

## Nonlinear time series prediction model based on particle swarm optimization B-spline network

Gong Xiaolong Kong Lingshuang Yuan Chuanlai Xiao Huiqin

(School of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou 412007, China)

**Abstract:** In order to improve the prediction accuracy of nonlinear time series, a prediction model based on particle swarm optimization B-spline network is proposed. In designing the structure of the network, the nodes of B-spline basis functions which are considered to be independent variables and every correlative weight parameter are to be optimized together in the network training process. And the forecasting error square sum is adopted to evaluate the training effect of the network. A particle swarm optimization algorithm with an appropriate search strategy is used as the training algorithm to search the distribution of optimal nodes of B-spline basis functions and find the optimal weight parameters, so that the structure of the network is optimized. Then, the nonlinear time series is predicted by the network. The simulation results indicate that the prediction model based on particle swarm optimization B-spline network has a fine generalization performance, and the algorithm optimizes the network effectively. The proposed prediction model is not only simple in structure, but also has higher prediction accuracy.

**Keywords:** B-spline networks; particle swarm algorithm; nonlinear time series; prediction model

## 0 引 言

时间序列是按照时间的顺序对记录的某种观测值进行排列得到的一组数据。对于时间序列的研究,要通过分析历史数据所包含的一些信息,找到时间序列反映出的变化规律与特点,再建立数学模型进行时间序列分析

和整理,研究和总结其发展特性,从而依据模型预测下一时间的数据<sup>[1]</sup>。时间序列预测常用的方法有用于线性时间序列的自回归滑动平均(ARMA)模型和用于非线性时间序列的非线性自回归滑动平均(NARMA)模型<sup>[2]</sup>等。然而,这些传统的时间序列预测模型大多是基于统计学原理来进行建模的,并且一般只适用在输入与输出是线性对应关系和一些很简单的非线性映射关系中,实际应

收稿日期:2017-05 Received Date: 2017-05

\* 基金项目:国家自然科学基金(61203136)、湖南省自然科学基金(2015JJ5025)资助项目

用中的许多时间序列呈现很强的非线性特性,用线性函数方法往往达不到预期的效果<sup>[3]</sup>。近年来,研究人员发现这些模型的很多局限性越来越明显,因此将时间序列当作非线性来进行处理,进而对预测模型进行改进和优化,这也是对时间序列处理的一种趋势。

目前,神经网络是人们常用的非线性时间序列的建模方法,其通过对训练数据进行反复训练来调整网络的结构与参数,从而预测以后的数值<sup>[4-5]</sup>。理论上,倘若神经网络有足够数量的隐层神经元,就能够非常逼近非线性系统,即以任意精度来近似输入对输出的映射关系,因此神经网络具有良好的近似性能<sup>[6-7]</sup>。后来研究者提出了一种模糊联想记忆神经网络,它是基于网格的结构,表示为关于基函数的线性组合,这种近似非线性系统的网络很容易理解。这种网络有多种可供选择的基函数,其中径向基核函数最为常用,但是它存在这样的问题,就是很难找到径向基核函数的宽度数与中心值<sup>[8-10]</sup>。

基函数的另一种常用选择是 B 样条基函数,而 B 样条函数是用分段多项式的形式来进行表示的,将 B 样条基函数作为神经网络的基函数,这种网络称为 B 样条网络<sup>[11-12]</sup>。B 样条网络的结构是由基函数的线性组合来表示的。在设计 B 样条网络结构过程中,节点位置会影响网络的预测效果,因此选择出好的节点位置对网络很重要<sup>[13]</sup>。在以往的很多研究中,因为缺乏如何选择最佳节点的理论,所以节点位置常常是预先设置的,只是改变权值参数,因此网络有时达不到预期效果<sup>[14]</sup>。在许多情况下,B 样条网络性能表现不佳的主要原因是节点的不良配置。因此,研究者又通过增加节点数目来进行改善,提高网络的近似性能,但增加节点可能会将不必要的节点引入网络,这又会对网络性能造成影响<sup>[15]</sup>。网络节点仍然没有实现最优配置,因此 B 样条网络的近似精度往往达不到预想要求。

本文建立一种非线性时间序列粒子群优化 B 样条网络预测模型,设计各个节点作为独立变量,使其与权值参数在网络训练过程中一同进行优化。在网络训练过程中,为了避免出现局部极小,设计一种全局寻优算法,即粒子群算法与适当的搜索策略,进而使网络结构也得到优化。用该网络对某冶金厂氧化铝配料过程的质量数据进行训练并预测,仿真实验的结果表明,与相同要求条件下的径向基函数网络相比,粒子群优化 B 样条网络预测模型有更好的预测效果,同时也验证了所用算法对网络优化的有效性。

## 1 B 样条优化网络预测模型

### 1.1 B 样条函数

B 样条函数是一个用分段多项式表示的函数,即为

一组 B 样条基函数线性组合的形式。先来分析一维的 B 样条函数。

一组定义在  $[a, b]$  上的节点可以表示为:

$$x_{-m+1} < \dots < x_{-1} < a = x_0 < x_1 < \dots < x_k = b < x_{k+1} < \dots < x_{k+m-1} \quad (1)$$

节点向量为  $\mathbf{x} = (x_{-m+1}, x_{-m+2}, \dots, x_{k+m-1})^T$ , 其中  $x_i$  为第  $i$  个节点,  $k$  和  $m$  均是正整数。

在  $[a, b]$  范围上的  $m$  阶样条基函数形成一个集合, 表示为  $\{\phi_{-m+1,m}, \phi_{-m+2,m}, \dots, \phi_{k-1,m}, \phi_{k,m}\}$ 。

$m$  阶的 B 样条基函数表示为  $\phi_{i,m}(x, \mathbf{x})$ , 基函数的定义为:

$$\phi_{i,1}(x, \mathbf{x}) = \begin{cases} 1, & x = [x_i, x_{i+1}] \\ 0, & \text{其他} \end{cases} \quad (2)$$

$$\phi_{i,m}(x, \mathbf{x}) = \frac{x - x_i}{x_{i+m-1} - x_i} \phi_{i,m-1}(x, \mathbf{x}) + \frac{x_{i+m} - x}{x_{i+m} - x_{i+1}} \phi_{i+1,m-1}(x, \mathbf{x}), m > 1 \quad (3)$$

式中:  $i = -m + 1, -m + 2, \dots, k$ 。

对于任意  $m \geq 1$ , B 样条基函数满足:

$$\phi_{i,m}(x, \mathbf{x}) = 0, x \in (-\infty, x_i] \cup [x_{i+m}, \infty) \quad (4)$$

$$\phi_{i,m}(x, \mathbf{x}) > 0, x \in (x_i, x_{i+m}) \quad (5)$$

$$\frac{m}{x_{i+m} - x_i} \int_{x_i}^{x_{i+m}} \phi_{i,m}(x, \mathbf{x}) dx = 1 \quad (6)$$

式中:  $i = -m + 1, -m + 2, \dots, k$ 。

在某种意义上,基函数是对单位 1 的分割,则:

$$\sum_{i=-m+1}^k \phi_{i,m}(x, \mathbf{x}) = 1, \forall x \in [a, b] \quad (7)$$

当  $m \geq 3$  时,样条基函数在  $(-\infty, +\infty)$  上是光滑的。一个  $m$  阶的一维 B 样条函数表达式为  $\phi(x, \mathbf{x})$ , 即:

$$\phi(x, \mathbf{x}) = \sum_{i=-m+1}^k c_i \phi_{i,m}(x, \mathbf{x}) \quad (8)$$

式中:  $c_i$  是待定常数,  $i = -m + 1, \dots, k$ 。

### 1.2 非线性时间序列 B 样条优化网络

对于一组非线性时间序列  $\{y_1, y_2, y_3, \dots, y_n\}$ , 预测函数设为  $f(\cdot)$ , 则

$$y_{n+1} = f(y_1, y_2, \dots, y_n) + \varepsilon_{n+1} \quad (9)$$

式中:  $\varepsilon_{n+1}$  表示函数的预测误差。

采用多维 B 样条函数近似预测函数  $f(\cdot)$ , 一个  $n$  维 B 样条网络预测函数可表示为一维 B 样条基函数的张量积, 即:

$$f(\mathbf{c}, \mathbf{X}; s_1, s_2, \dots, s_n) = \sum_{j_1, j_2, \dots, j_n=-m+1}^k c_{j_1, j_2, \dots, j_n} \phi_{j_1, m}(s_1; \mathbf{x}^1) \cdot \phi_{j_2, m}(s_2; \mathbf{x}^2) \cdots \phi_{j_n, m}(s_n; \mathbf{x}^n) \quad (10)$$

式中:  $\phi_{j_1, m}(s_1; \mathbf{x}^1), \phi_{j_2, m}(s_2; \mathbf{x}^2), \dots, \phi_{j_n, m}(s_n; \mathbf{x}^n)$  是式 (2) 和 (3) 所表示的 B 样条基函数;  $\mathbf{x}^j = (x_{k+m+1}^j, \dots, x_{k+m-1}^j)$  为第  $j$  维变量的节点矢量;  $\mathbf{X} = (\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^n)$  是

节点矩阵;  $s_i(j = 1, 2, \dots, n)$  为第  $j$  维值域中的值。

$$c = (c_{-m+1, -m+1, \dots, -m+1}, \dots, c_{k, -m+1, \dots, -m+1}, \dots, c_{-m+1, k, \dots, k}, \dots, c_{k, k, \dots, k}) \in \mathbf{R}^{(k+m)^*} \quad (11)$$

式中:  $c_{j_1, j_2, \dots, j_n}$  是待定常数。

## 2 网络算法

在以往的很多研究中,研究者首先设定 B 样条网络结构中的各个节点位置,把连接权值参数看作变量,因此网络结构是固定的,所得到的网络性能往往不如人意。为此,将网络结构中的各个权值参数与节点位置同时作为独立变量进行结构优化,采用粒子群算法与适当的搜索策略进行全局寻优。

### 2.1 算法原理

粒子群算法先随机设置一群在可行解范围内的粒子,每一个粒子都表示待求解问题的一个可能的最好结果,用粒子速度、位置以及适应度来反映粒子的特点,而适应度可通过适应度函数得到,并且适应度可以反映粒子的好坏<sup>[16-17]</sup>。

假如在  $d$  维的搜索区域中,  $n$  个粒子形成了一个粒子群  $\mathbf{x} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$ , 其中第  $i$  个粒子表示  $d$  维的所求问题解向量  $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{id})^T$ , 即表示第  $i$  个粒子在  $d$  维的可搜索区域中的位置,也就是一个潜在的解。依据目标函数,计算每个粒子位置  $\mathbf{x}_i$  所对应的适应度。 $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{id})^T$  表示为第  $i$  个粒子的速度,  $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{id})^T$  表示为第  $i$  个粒子个体极值,  $\mathbf{p}_g = (p_{g1}, p_{g2}, \dots, p_{gd})^T$  表示为种群极值。

在迭代的过程中,粒子依据个体和群体的极值来更新位置和速度,满足下列关系:

$$v_{ij}^{k+1} = \omega v_{ij}^k + c_1 r_1 (p_{ij}^k - x_{ij}^k) + c_2 r_2 (p_{gj}^k - x_{ij}^k) \quad (12)$$

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} \quad (13)$$

式中:  $i = 1, 2, \dots, n, j = 1, 2, \dots, d, k$  表示迭代的次数,  $\omega$  表示惯性权重,  $c_1$  和  $c_2$  表示正的常数,  $r_1$  和  $r_2$  表示 0~1 的随机数。

如果  $c_1$  和  $c_2$  的选取不恰当,就会使得粒子陷入局部最小值,因此对粒子更新速度进行调整。

$$v_{ij}^{k+1} = \varphi \{ v_{ij}^k + c_1 r_1 (p_{ij}^k - x_{ij}^k) + c_2 r_2 (p_{gj}^k - x_{ij}^k) \} \quad (14)$$

$$\varphi = \frac{2}{|2 - c - \sqrt{c^2 - 4c}|}, c = c_1 + c_2 \quad (15)$$

采用适当的搜索策略对 B 样条网络结构中的各个节点位置进行选取,设计网络的第  $j$  维的第  $i$  个节点  $x_i^j$  为  $(x_{i-1}^j, x_{i+1}^j)$  范围内的随机值,即节点的选取满足以下条件:  $s = x_{i+1}^j - x_{i-1}^j, x_i^j = x_{i-1}^j + s \cdot \text{rand}(1)$ , 从而搜索到使网络性能更好的节点。

### 2.2 算法流程与步骤

预测模型所采用的算法流程如图 1 所示,根据初始化条件,计算出非线性时间序列的实际值与预测值的误差平方和,记最小值作为最优值,此时的权值与节点记为最优,依据粒子群算法与适当的搜索策略更新节点与权值,重新计算预测误差平方和,若其小于最优值,替换其作为最优值,否则返回重新搜索直到满足。再判断最优值是否满足终止条件,若满足则输出结果,否则返回训练。

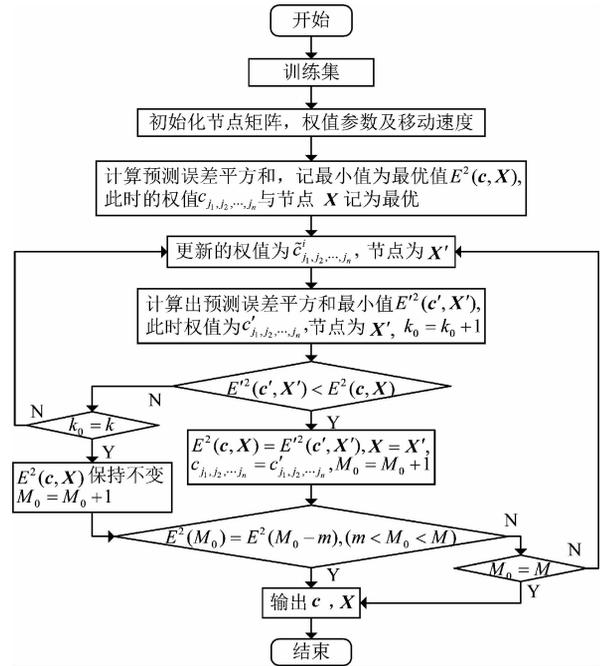


图 1 网络算法流程

Fig. 1 Flow chart of network algorithm

预测模型具体算法步骤如下。

1) 取一组序列记为  $Y = (y_1, y_2, \dots, y_n, \dots, y_N)$ , 设置  $a = \min(Y), b = \max(Y)$ , 在超立方体  $[a, b]^n$  上, 随机初始化节点矩阵  $\mathbf{X} = (\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^n)$ , 每一维节点都满足式(1)的关系; 设最大训练次数为  $M$ , 令  $M_0 = 0$ , 设定正的常数  $m$ 。

2) 设定一个正的常数  $c$ , 随机初始化粒子种群规模为  $n$  的权值参数  $c_{j_1, j_2, \dots, j_n}^i$ , 其中  $i = 1, 2, \dots, n$ 。按照式(11)的形式可记为  $\mathbf{c}^i$ , 使得各个权值参数  $c_{j_1, j_2, \dots, j_n}^i$  都在  $(-c, c)$  范围内, 随机初始化权值参数的移动速度为  $v_{j_1, j_2, \dots, j_n}^i$ ; 设置最大迭代次数为  $k$ , 令  $k_0 = 0$ 。

3) 选取预测误差平方和作为适应度函数, 可由式(9)计算得到, 即:

$$E^2(\mathbf{c}, \mathbf{X}) = \sum_{k=n+1}^N (y_{n+1} - f(\mathbf{c}, \mathbf{X}; y_{k-n}, y_{k-n+1}, \dots, y_{k-1}))^2 \quad (16)$$

分别计算出  $n$  组权值和节点用于网络的预测误差平

方和,保存预测误差平方和最小值为  $E^2(\mathbf{c}, \mathbf{X})$ , 此时节点最优记为  $\mathbf{X}$ , 最优权值为  $c_{j_1, j_2, \dots, j_n}$ 。

4) 随机取节点  $x_i^j$ , 使得  $x_i^j$  在  $(x_{i-1}^j, x_{i+1}^j)$  范围上, 即  $s = x_{i+1}^j - x_{i-1}^j$ ,  $x_i^j = x_{i-1}^j + s \cdot \text{rand}(1)$ , 更新节点矩阵记为  $\mathbf{X}'$ ; 用式(13)~(15)来更新各个权值参数, 产生新的权值为  $\tilde{c}_{j_1, j_2, \dots, j_n}^i$ 。

5) 重新计算出更新的权值和节点用于网络的预测误差平方和最小值  $E'^2(\mathbf{c}', \mathbf{X}')$ , 此时的权值为  $c'_{j_1, j_2, \dots, j_n}$ , 节点为  $\mathbf{X}'$ ,  $k_0 = k_0 + 1$ , 记  $\Delta = E'^2(\mathbf{c}', \mathbf{X}') - E^2(\mathbf{c}, \mathbf{X})$ , 若  $\Delta \geq 0$ , 返回步骤 4) 重新训练直到  $k_0 = k$ ; 若  $\Delta < 0$ , 则取  $E^2(\mathbf{c}, \mathbf{X}) = E'^2(\mathbf{c}', \mathbf{X}')$ ,  $c_{j_1, j_2, \dots, j_n} = c'_{j_1, j_2, \dots, j_n}$ ,  $\mathbf{X} = \mathbf{X}'$ , 此时  $M_0 = M_0 + 1$ 。

6) 若  $E^2(M_0) = E^2(M_0 - m)$ , ( $m < M_0 < M$ ), 则终止训练, 其中  $E^2(M_0)$  表示第  $M_0$  个  $E^2(\mathbf{c}, \mathbf{X})$  值,  $m$  为常数, 否则返回步骤 4) 继续训练, 直到  $M_0 = M$ 。

### 3 仿 真

随着近年来社会的快速发展, 生活中的各个方面都有铝制材料的使用, 因此注意到铝制材料的生产。在某冶金厂氧化铝配料的工业生产过程中, 由于技术各方面的原因, 对氧化铝配料过程中的原料质量检测结果非常滞后, 进而不能对氧化铝配料过程进行及时指导, 因此研究如何通过时间序列预测未来的原料质量很有意义。

将粒子群优化 B 样条网络用于冶金配料过程中, 对冶金配料中的氧化铝原料质量数据进行训练, 并对其进行实时预测。选取 200 组某原料质量数据用于仿真实验, 其中, 取 160 组质量数据用于粒子群优化 B 样条网络的训练。对网络的参数进行设置, 样条基函数为 3 阶基函数, 样条网络为二维, 网络训练次数为 10 000, 取  $m = 100$ 。粒子群算法的参数设置为种群规模为 30, 迭代次数为 1 000,  $c_1 = c_2 = 2.05$ 。当网络完成训练后, 用剩余的 40 组数据验证 B 样条网络预测模型的泛化性能。仿真结果如图 2 所示。

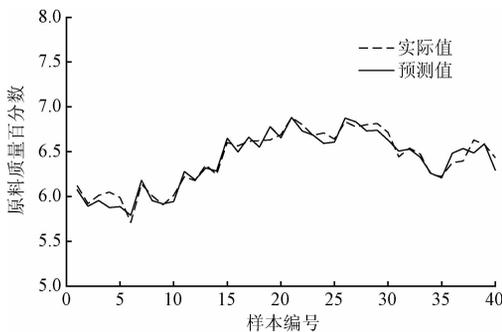


图 2 B 样条网络预测结果

Fig. 2 Prediction results of B-spline network

图 2 表示粒子群优化 B 样条网络对氧化铝质量测试集的预测结果, 从仿真结果图中可以看出, 测试集的预测结果很接近实际数据, 表明该预测模型有良好的预测效果。

为了更进一步说明这种预测模型的性能, 将所提出的粒子群优化 B 样条网络与径向基函数网络相比较。在相同粒子群算法条件下, 使用文献[10]中传统径向基函数网络对数据进行训练并预测, 所得到的结果如图 3 所示。

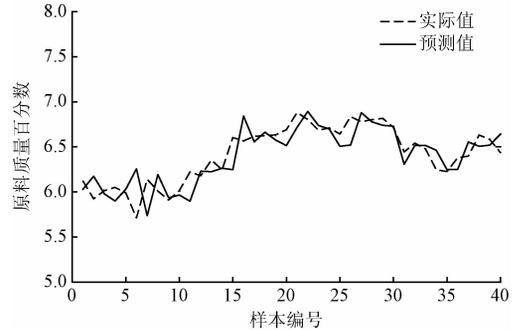


图 3 径向基函数网络预测结果

Fig. 3 Prediction results of radial basis function network

使用氧化铝质量的实际值与预测值的最大相对误差、均方根误差两种方法来评价网络模型的性能。

最大相对误差:

$$E_{\max} = \max(|y_i - \bar{y}_i|/y_i) \quad (17)$$

均方根误差:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (18)$$

式中:  $y_i$  和  $\bar{y}_i$  分别表示实际值和预测值。

计算出两种方法预测的最大相对误差和均方根误差, 结果如表 1 所示。从表 1 的数据可看出所提出的粒子群优化 B 样条网络的最大相对误差和均方根误差都较小一些, 因此其预测效果更好, 同时也说明了使用的优化算法对网络结构优化的有效性。

表 1 两种网络的预测性能对比

Table 1 Prediction performance comparison of two kinds of networks

氧化铝质量预测误差	粒子群优化 B 样条网络	径向基函数网络
最大相对误差	0.028 6	0.099 6
均方根误差	0.074 7	0.196 8

### 4 结 论

本文建立了一种粒子群优化 B 样条网络预测模

型,用该网络模型对非线性时间序列进行训练与预测,粒子群算法和适当的搜索策略优化了权值参数与节点位置,使得网络结构也得到了优化。仿真实验结果表明,对于非线性时间序列的预测,所提出的网络有较好的泛化性能,是一个很有效的预测方法,同时也说明了所采用的算法对网络优化的有效性。与同等条件下的径向基函数网络相比,所建预测模型结构简单且预测精度较高。

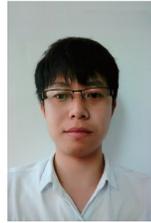
## 参考文献

- [1] 张美英,何杰. 时间序列预测模型研究综述[J]. 数学的实践与认识,2011,41(18):189-195.  
ZHANG M Y, HE J. Summary on time series forecasting model [J]. Journal of Mathematics in Practice and Theory, 2011, 41(18): 189-195.
- [2] 林屹,严洪森,周博. 基于多维泰勒网的非线性时间序列预测方法及其应用[J]. 控制与决策,2014,29(5):795-801.  
LIN Y, YAN H S, ZHOU B. Nonlinear time series prediction method based on multi-dimensional Taylor network and its applications [J]. Control and Decision, 2014, 29(5): 795-801.
- [3] 杨臻明,岳继光,王晓保,等. 基于独立模型的非线性时间序列多步超前预测[J]. 上海交通大学学报,2013,47(10):1626-1631.  
YANG ZH M, YUE J G, WANG X B, et al. Multistep-ahead independent prediction of nonlinear time series based on independent model [J]. Journal of Shanghai Jiaotong University, 2013, 47(10): 1626-1631.
- [4] 杨娟丽,徐梅,王福林,等. 基于BP神经网络的时间序列预测问题研究[J]. 数学的实践与认识,2013,43(4):158-164.  
YANG J L, XU M, WANG F L, et al. Research based on BP neural network time series forecasting [J]. Journal of Mathematics in Practice and Theory, 2013, 43(4): 158-164.
- [5] 洪嘉灏,李雄英,王斌会. 基于人工神经网络和随机游走模型的汇率预测[J]. 经济数学,2016,33(1):30-35.  
HONG J H, LI X Y, WANG B H. Exchange rate forecast based on artificial neural network and random walk model [J]. Journal of Quantitative Economics, 2016, 33(1): 30-35.
- [6] 张大斌,李红燕,刘肖,等. 非线性时间序列的小波-模糊神经网络集成预测方法[J]. 中国管理科学,2013,21(S2):647-651.  
ZHANG D B, LI H Y, LIU X, et al. A integrated prediction method of wavelet-fuzzy neural network for nonlinear time series [J]. Chinese Journal of Management Science, 2013, 21(S2): 647-651.
- [7] 李哲敏,许世卫,崔利国,等. 基于动态混沌神经网络的预测研究:以马铃薯时间序列价格为例[J]. 系统工程理论与实践,2015,35(8):2083-2091.  
LI ZH M, XU SH W, CUI L G, et al. Prediction study based on dynamic chaotic neural network: Taking potato time-series prices as an example [J]. System Engineering-Theory & Practice, 2015, 35(8): 2083-2091.
- [8] 李光,杨韵. 基于RBF神经网络的柔性机械臂位置控制[J]. 湖南工业大学学报(自然科学版),2014,28(3):41-46.  
LI G, YANG Y. Flexible manipulation position control based on RBF neural network [J]. Journal of Hunan University of Technology (Natural Science), 2014, 28(3): 41-46.
- [9] 裴世鑫,李仲怡,崔芬萍,等. 基于RBF人工神经网络的X级以上太阳耀斑预报研究[J]. 西北师范大学学报(自然科学版),2014,50(6):26-32.  
PEI SH X, LI ZH Y, CUI F P, et al. A study of the prediction for x-class and above flares based on RBF artificial neural network [J]. Journal of Northwest Normal University (Natural Science), 2014, 50(6): 26-32.
- [10] 马尽文,青慈阳. 对角型广义RBF神经网络与非线性时间序列预测[J]. 信号处理,2013,29(12):1609-1614.  
MA J W, QING C Y. Diagonal generalized RBF neural network and nonlinear time series prediction [J]. Journal of Signal Processing, 2013, 29(12): 1609-1614.
- [11] 张浩,张代远. 基于三次样条权函数神经网络的股价预测[J]. 计算机技术与发展,2014,24(6):28-31.  
ZHANG H, ZHANG D Y. Stock prediction based on neural networks with cubic spline weight functions [J]. Computer Technology and Development, 2014, 24(6): 28-31.
- [12] 杨海楠,张代远. 基于样条权函数神经网络的传感器故障诊断[J]. 计算机技术与发展,2014,24(6):204-207.  
YANG H N, ZHANG D Y. Fault diagnosis of sensor based on spline weight function neural network [J]. Computer Technology and Development, 2014, 24(6): 204-207.
- [13] 王世东,王焕宝. 基于SOM网络的三次B样条曲线重建[J]. 计算机工程与应用,2012,48(15):192-194,244.  
WANG SH D, WANG H B. Cubic B-spline curve

reconstruction based on SOM[J]. Computer Engineering and Applications, 2012, 48(15): 192-194,244.

- [14] YIU K F, WANG S, TEO K L, et al. Nonlinear system modeling via knot-optimizing B-spline networks [J]. IEEE Transaction on Neural networks, 2001, 12(5): 1013-1022.
- [15] WANG S, SHAO Q, ZHOU X. Knot-optimizing spline networks(KOSNETS) for nonparametric regression [J]. Journal of Industrial and Management Optimization, 2008, 4(1): 33-52.
- [16] 赵婷婷,程奇峰,王志丰. 改进粒子群算法优化的非线性模型预测控制[J]. 辽宁工程技术大学学报(自然科学版),2015,34(4):517-522.  
ZHAO T T, CHENG Q F, WANG ZH F. Nonlinear model predictive control optimization with improved particle swarm algorithm [J]. Journal of Liaoning Technical University( Natural Science), 2015, 34(4): 517- 522.
- [17] 李蓉,沈云波,刘坚. 改进的自适应粒子群优化算法[J]. 计算机工程与应用,2015,51(13):31-36.  
LI R, SHEN Y B, LIU J. Improved adaptive particle swarm optimization algorithm[J]. Computer Engineering and Applications, 2015, 51(13): 31-36.

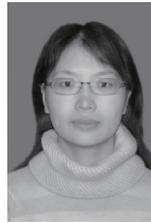
## 作者简介



**龚小龙**,1989年出生,2014年于洛阳理工学院获得学士学位,现为湖南工业大学硕士研究生,主要研究方向为复杂过程建模、控制与优化。

E-mail:1018806258@qq.com

**Gong Xiaolong** was born in 1989, received B. Sc. from Luoyang Institute of Science and Technology in 2014. Now he is a M. Sc. candidate in Hunan University of Technology. His main research direction is modeling, control and optimization of complex processes.



**孔玲爽**(通信作者),1979年出生,2005、2010年于中南大学获得硕士学位和博士学位,现为湖南工业大学教授,主要从事复杂工业过程建模与优化控制方面的研究。

E-mail:konglingsh@126.com

**Kong Lingshuang** (Corresponding author) was born in 1979, received M. Sc. and Ph. D. from Central South University in 2005 and 2010, respectively. Now she is a professor in Hunan University of Technology. Her main research direction is modeling and optimization control of complex industrial processes.