

# 控制与决策

Control and Decision

## 基于随机配置网络的非线性系统智能建模方法

陶金梅, 牛宏, 张亚军, 李旭生

引用本文:

陶金梅,牛宏,张亚军,李旭生. 基于随机配置网络的非线性系统智能建模方法[J]. *控制与决策*, 2022, 37(10): 2559–2564.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0436>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [有理模型辨识的两类新方法——混合迭代与柔性最小二乘法](#)

Two novel identification methods for rational models—Compound iterative algorithm and flexible least squares algorithm

*控制与决策*. 2022, 37(1): 58–66 <https://doi.org/10.13195/j.kzyjc.2020.0935>

#### [基于KRLS的非均匀采样非线性系统辨识](#)

Identification of non-uniformly sampled nonlinear systems based on KRLS

*控制与决策*. 2021, 36(12): 3049–3055 <https://doi.org/10.13195/j.kzyjc.2020.0962>

#### [基于数据驱动的非线性网络系统自适应迭代学习控制](#)

Data driven adaptive learning control of nonlinear network system

*控制与决策*. 2021, 36(6): 1523–1528 <https://doi.org/10.13195/j.kzyjc.2019.1182>

#### [一种改进的紧格式无模型自适应控制方法](#)

An improved compact form model free adaptive control method

*控制与决策*. 2021, 36(2): 436–442 <https://doi.org/10.13195/j.kzyjc.2019.0635>

#### [基于神经动态优化的非线性系统近似最优跟踪控制](#)

Approximate optimal tracking control for nonlinear systems based on neurodynamic optimization

*控制与决策*. 2021, 36(1): 97–104 <https://doi.org/10.13195/j.kzyjc.2020.0056>

# 基于随机配置网络的非线性系统智能建模方法

陶金梅<sup>1</sup>, 牛宏<sup>1†</sup>, 张亚军<sup>2</sup>, 李旭生<sup>1</sup>

(1. 辽宁石油化工大学理学院, 辽宁抚顺 113001;  
2. 东北大学流程工业综合自动化国家重点实验室, 沈阳 110004)

**摘要:** 针对一类非线性离散动态系统, 研究非线性系统的智能建模方法. 首先, 采用带遗忘因子的递推最小二乘法对低阶模型的未知参数进行辨识; 然后, 对高阶非线性部分采用随机配置网络进行估计; 最后, 利用两种辨识方法在外部误差准则下对系统进行交替辨识, 进而提出一种改进的非线性系统交替辨识的智能建模方法. 将随机配置网络与递推最小二乘算法相结合, 可有效提高非线性系统的辨识精度, 并且通过数值仿真实验进行对比分析以验证所提出算法的有效性.

**关键词:** 非线性系统; 高阶非线性项; 递推最小二乘法; 随机配置网络; 智能建模

中图分类号: TP273 文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0436

引用格式: 陶金梅, 牛宏, 张亚军, 等. 基于随机配置网络的非线性系统智能建模方法[J]. 控制与决策, 2022, 37(10): 2559-2564.

## An intelligent modeling method for nonlinear systems based on random Configuration networks

TAO Jin-mei<sup>1</sup>, NIU Hong<sup>1†</sup>, ZHANG Ya-jun<sup>2</sup>, LI Xu-sheng<sup>1</sup>

(1. College of Sciences, Liaoning Petrochemical University, Fushun 113001, China; 2. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110004, China)

**Abstract:** For a class of nonlinear discrete-time dynamic systems, the intelligent modeling method of the nonlinear system is studied. Firstly, the forgetting factor recursive least square method is used to identify the unknown parameters of the lower-order model, and then the stochastic configuration networks are used to estimate the higher-order nonlinear part. Finally, the two identification methods are used to identify the system alternately under the external error criterion. Furthermore, an improved intelligent modeling method for alternating identification of nonlinear systems is proposed. The combination of the stochastic configuration networks and the recursive least square algorithm can effectively improve the identification accuracy of nonlinear systems, and the effectiveness of the proposed algorithm is verified by comparative analysis of numerical simulation experiments.

**Keywords:** nonlinear systems; higher order nonlinear term; recursive least square; stochastic configuration networks; intelligent modeling

## 0 引言

系统辨识是生产过程中最常用的辨识方法<sup>[1]</sup>. 但是, 由于非线性系统的复杂性, 非线性系统辨识一直没有普适化的成熟的辨识方法, 更多的是随着不同系统的特殊性而建立一个相对独立的辨识模型. 如文献[2]通过求解稀疏参数向量估计一类具有未知时滞的闭环系统的时滞与参数, 该方法的优点是不依赖于大量的采样数据也能给出较好的辨识效果, 但只适用于离线辨识.

近年来, 随着计算机科技的进步, 系统辨识在原有辨识算法的基础上与专家系统、神经网络和模糊技术等人工智能方法(机器学习、深度神经网络)综合使用, 使得系统辨识不仅在线辨识, 而且能够应对的辨识对象范围增大了, 应用范围更广<sup>[3-7]</sup>. 文献[8]用神经网络逼近未知和期望控制输入函数, 采用较少学习参数的方法可以有效地减少计算量, 但在强非线性系统下的逼近效果不够理想; 文献[9]提出了智能优化决策系统的发展目标及愿景; 文献[10]建立了功

收稿日期: 2021-03-16; 录用日期: 2021-07-05.

基金项目: 国家重点研发计划项目(2020YFB1713602); 国家自然科学基金项目(61773107, 61991402, 61866021, 61890923, 61833004, 61973202); 辽宁省自然基金指导计划项目(2019-ZD-0054).

†通讯作者. E-mail: niuhong@lnpu.edu.cn.

率变化率与电流控制系统输出电流之间由线性项和未知非线性项组成的动态模型,准确预报电熔镁群炉需量变化趋势,但在大时滞系统应用上稍显不足;文献[11]针对化工过程的强非线性及数据维度较高的特征,使用PLS方法从数据中提取主成分,并采用稳定学习算法更新模型参数;文献[12-13]采用随机神经网络算法对高炉炼铁过程中铁水质量指标模型建模,取得了较好的效果,但算法稍显复杂;文献[14-15]提出了一种由改进的投影算法与未建模动态估计算法组成的交替辨识算法,对复杂工业过程中运行指标进行预报,但该算法所用BP神经网络需人为设定网络节点数和基函数,且最佳网络节点数与基函数需经过大量重复实验方可获得,实际应用较为繁杂。

针对以上问题,本文结合智能建模方法与理论方面研究的进展,提出一种新的基于随机配置网络的非线性系统智能建模方法。随机配置神经网络因具有无需人为设定网络节点数和基函数的优势而被广泛用于系统辨识和非线性建模。因此,本文提出将随机配置网络(stochastic configuration networks, SCNs)与带遗忘因子的递推最小二乘法(forgetting factor recursive least square, FFRLS)相结合的智能建模方法,以提高辨识系统的精度。通过采用数值仿真进行实验验证,并与已有的辨识方法进行比较,对比实验结果验证了所提出方法的有效性。

## 1 问题描述

复杂工业过程动态系统模型可以表示为

$$y(k) = f[\varphi(k-d)]. \quad (1)$$

其中:  $\varphi(k-d) = [-y(k-1), \dots, -y(k-n_A), u(k-d), \dots, u(k-d-n_B)]^T$  为  $n_A + n_B + 1$  维向量,  $y(k)$  为系统输出,  $u(k)$  为系统输入,  $n_A$  和  $n_B$  分别为系统的输出阶数和输入阶数,  $d (d \geq 1)$  为时滞,  $f(\cdot) \in R$  表示未知的非线性函数。

考虑到系统一般都在工作点附近运行,故将系统模型在工作点附近进行Taylor展开,展开式系数为

$$a_i = \left. \frac{\partial f[\varphi(k-d)]}{\partial y(k-i)} \right|_{y=0, u=0}, \quad i = 1, \dots, n_A; \quad (2)$$

$$b_j = \left. \frac{\partial f[\varphi(k-d)]}{\partial u(k-d-j)} \right|_{y=0, u=0}, \quad j = 0, \dots, n_B. \quad (3)$$

定义

$$A(z^{-1}) = 1 + a_1 z^{-1} + \dots + a_{n_A} z^{-n_A}, \quad (4)$$

$$B(z^{-1}) = b_0 + b_1 z^{-1} + \dots + b_{n_B} z^{-n_B}, \quad (5)$$

于是,模型(1)可等价地表示为

$$A(z^{-1})y(k) = B(z^{-1})u(k-d) + v[\varphi(k-d)], \quad (6)$$

其中  $v[\varphi(k-d)]$  为未建模动态。

将式(6)看作一个受控自回归模型(controlled auto-regressive model, CARM),则可将其改写为

$$y(k+d) = \varphi^T(k)\theta + v[\varphi(k)], \quad (7)$$

$$\begin{cases} \varphi(k) = [-y(k+d-1), \dots, -y(k+d-n_A), \\ u(k), \dots, u(k-n_B)]^T, \\ \theta = [a_1, a_2, \dots, a_{n_A}, b_0, \dots, b_{n_B}]^T. \end{cases} \quad (8)$$

其中:  $\varphi^T(k)\theta$  为线性部分,  $\varphi(k)$  为数据向量,  $\theta$  为待估参数向量,  $v[\varphi(k)]$  为未建模动态。

## 2 智能建模

根据式(7),本文提出改进的交替辨识算法进行智能建模。线性部分参数辨识采用FFRLS,未建模动态部分采用SCNs进行非线性辨识,建模结构如图1所示。




图1 智能建模结构

图1中,  $\hat{y}(k+d)$  表示输入  $\varphi(k)$  经过FFRLS参数辨识后得到的线性辨识结果,即

$$\hat{y}(k+d) = \varphi^T(k)\hat{\theta}(k). \quad (9)$$

参数向量  $\hat{\theta}(k)$  可由下式递推而得:

$$\begin{cases} \hat{\theta}(k) = \\ \hat{\theta}(k-1) + \mathbf{K}(k)[y(k+d) - \varphi^T(k)\hat{\theta}(k-1)], \\ \mathbf{K}(k) = \frac{\mathbf{P}(k-1)\varphi(k)}{\lambda + \varphi^T(k)\mathbf{P}(k-1)\varphi(k)}, \\ \mathbf{P}(k) = \frac{1}{\lambda}[\mathbf{I} - \mathbf{K}(k)\varphi^T(k)]\mathbf{P}(k-1). \end{cases} \quad (10)$$

其中: 遗忘因子  $\lambda$  须选择接近于1的正数,通常不小于0.9;  $\hat{\theta}(k)$  为参数向量估计值;  $\mathbf{K}(k)$  为预测误差的加权矩阵,是修正系数;  $\mathbf{P}(k)$  为可逆的协方差矩阵;  $\mathbf{I}$  为与  $\mathbf{P}$  同维的单位阵;  $\mathbf{P}(0)$ 、 $\hat{\theta}(0)$  为参数的初值,该初值需要在启动算法时预先给定,本文选定初值的方法为

$$\begin{cases} \mathbf{P}(0) = \alpha \mathbf{I}, \\ \hat{\theta}(0) = \varepsilon. \end{cases}$$

这里:  $\alpha$  为充分大的正实数 ( $10^4 \sim 10^{10}$ ),  $\varepsilon$  为零向量

或充分小的正实向量。

图1中 $\bar{v}[\varphi(k)]$ 是包含了线性辨识误差的未建模动态,与式(7)中 $v[\varphi(k)]$ 表示的含义有所不同,即

$$\begin{aligned} \bar{v}[\varphi(k)] &= y(k+d) - \hat{y}(k+d) = \\ & \varphi^T(k)\theta(k) + v[\varphi(k)] - \varphi^T(k)\hat{\theta}(k) = \\ & \varphi^T(k)[\theta(k) - \hat{\theta}(k)] + v[\varphi(k)] = \\ & e(k) + v[\varphi(k)], \end{aligned} \quad (11)$$

其中 $e(k)$ 为线性辨识误差。

$\hat{v}[\varphi(k)]$ 表示输入 $\varphi(k)$ 经过SCNs非线性辨识后得到的结果,并将其与未建模动态比较所得误差 $\varepsilon(k)$ 反馈至FFRLS处。

### 2.1 SCNs非线性辨识方法

SCNs网络结构与单隐层前馈神经网络结构类似,如图2所示。




图2 SCNs网络结构

在图2中,SCNs网络结构分为输入层、隐藏层和输出层。其中:输入层的输入节点数为 $k+1$ 个,包含 $k$ 个输入数据和一个恒为1的偏置修正输入,本文以 $\varphi(1), \varphi(2), \dots, \varphi(k)$ 为输入数据;隐藏层由根据给定规则<sup>[16]</sup>生成的随机基函数组成,其节点个数根据监控机制<sup>[16]</sup>自动增加;输出层节点与输入层一一对应。各层之间的信息传播遵循BP神经网络的信息传播方法,即周而复始地进行信号前向传播与误差反向传播,以不断调整权值并分配基函数,直到网络构建完成。

#### 2.1.1 构造网络

假设式(7)线性部分已知,则未建模动态为

$$v[\varphi(k)] = y(k+d) - \varphi^T(k)\theta. \quad (12)$$

由于 $v[\varphi(k)]$ 是一种与 $\varphi(k)$ 相关的强非线性函数,若要用SCNs估计该非线性项,则需将 $\varphi(k)$ 作为网络的输入, $v[\varphi(k)]$ 作为网络的输出。此时,令 $M = [X, T]$ 为网络待使用数据集,即数据集 $M$ 由输入向量 $X =$

$[\varphi(1), \varphi(2), \dots, \varphi(k)]^T$ 和输出向量 $T = [v[\varphi(1)], v[\varphi(2)], \dots, v[\varphi(k)]]^T$ 组成。将其按照采样时刻的奇偶性分为奇数集 $M_1$ 与偶数集 $M_2$ 。 $X_1$ 和 $T_1$ 分别为奇数集的输入与输出向量, $X_2$ 和 $T_2$ 分别为偶数集的输入与输出向量。其中

$$M_1 = [X_1, T_1], \quad (13)$$

$$M_2 = [X_2, T_2]; \quad (14)$$

$$X_1 = [\varphi(1), \varphi(3), \dots, \varphi(2k-1)]^T, \quad (15)$$

$$T_1 = [v[\varphi(1)], v[\varphi(3)], \dots, v[\varphi(2k-1)]]^T; \quad (16)$$

$$X_2 = [\varphi(2), \varphi(4), \dots, \varphi(2k)]^T, \quad (17)$$

$$T_2 = [v[\varphi(2)], v[\varphi(4)], \dots, v[\varphi(2k)]]^T. \quad (18)$$

假设当前时刻为 $k$ ,且目标函数为 $V: \mathbf{R}^{k/2} \rightarrow \mathbf{R}^{k/2}$ 。将奇数集 $M_1$ 作为网络训练集,偶数集 $M_2$ 作为网络测试集。在网络第 $N-1$ 次增加节点之后,SCNs训练的结果 $V_{N-1}$ 为

$$V_{N-1}(X_1) = \sum_{i=1}^{N-1} \beta_i \cdot g_i(\mathbf{w}_i^T \cdot X_1 + \mathbf{b}_i). \quad (19)$$

其中: $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{ij}]^T$ 为输入权值向量, $w_{ij}$  ( $i = 1, 2, \dots, N-1, j = 1, 2, \dots, k$ )为输入向量中的第 $j$ 个值所对应的第 $i$ 个节点的权值; $\mathbf{b}_i$  ( $i = 1, 2, \dots, N-1$ )为偏差向量,指第 $i$ 个节点的偏差值; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{ij}]^T$  ( $i = 1, 2, \dots, N-1$ )为输出权值向量,表示第 $i$ 次增加节点时所对应第 $j$ 个输出的输出层相应权值; $g_i$ 为第 $i$ 次增加节点时根据给定规则生成的随机基函数。

当前时刻残差 $e_{N-1}$ 定义为

$$e_{N-1} = V - V_{N-1} = [e_{N-1,1}, \dots, e_{N-1,k}]^T,$$

其中 $e_{N-1,j}$  ( $j = 1, 2, \dots, k$ )表示 $N-1$ 次增加节点后前 $k$ 个时刻的残差。假设当前时刻 $e_{N-1}$ 没有满足预先给定的误差准则,则系统会自动增加一个新的隐藏节点,并对输出权值进行评估,使得下一个模型有一个改进的残差,即

$$V_N(X_1) = V_{N-1}(X_1) + \beta_N \cdot g_N(\mathbf{w}_N^T \cdot X_1 + \mathbf{b}_N). \quad (20)$$

#### 2.1.2 配置输入权值与偏差

在增加新的隐藏节点时,会生成一个新的随机基函数,表示为 $g_N$ ,则当前新增隐层节点输出 $g_N$ 应为

$$g_N = g_N(\mathbf{w}_N^T \cdot X_1 + \mathbf{b}_N),$$

其中 $g_N$ 为随机基函数。为了满足普遍逼近性质,令张成的空间( $\Gamma$ )在 $L_2$ 空间中是稠密的, $\forall g \in \Gamma, 0 < g < b_g$ 。对于某些 $b_g$ ,给定学习参数 $0 < r < 1$ 和非负实数

序列  $\{\mu_N\}$ , 其中  $\lim_{L \rightarrow +\infty} \mu_N = 0$  且  $\mu_N \leq (1-r)$ . 令

$$\delta_{N,j} = (1-r-\mu_N) \|e_{N-1,j}\|^2, \quad j = 1, 2, \dots, k,$$

其中  $\mu_N = (1-r)/(N+1)$ ,  $0 < r < 1$ .

随机基函数的生成满足下列不等式:

$$\langle e_{N-1,j}, g_N \rangle^2 \geq b_g^2 \delta_{N,j}, \quad j = 1, 2, \dots, k.$$

输入权值  $w_N$  与偏差  $b_N$  的分配方法具有下列监督机制<sup>[16]</sup>(不等式约束):

$$\sum_{j=1}^k \langle e_{N-1,j}, g_N^* \rangle^2 \geq \|g_N^*\|^2 \delta_N. \quad (21)$$

其中

$$\begin{aligned} \delta_N &= (1-r-\mu_N) \|e_{N-1}\|^2, \\ \mu_N &= (1-r)/(N+1), \quad 0 < r < 1. \end{aligned}$$

### 2.1.3 输出权值的评估算法

如果  $e_{N-1}$  没有达到预定义的容差水平, 则系统会自动增加一个新的隐藏节点, 并对输出权值  $\beta_N$  进行评估, 即新增隐藏节点与每一个输出值对应的输出权值  $\beta_{N,j}$  都会由下式评估生成:

$$\beta_{N,j} = \frac{\langle e_{N-1,j}, g_N^* \rangle}{\|g_N^*\|^2}, \quad j = 1, 2, \dots, k. \quad (22)$$

### 2.1.4 判断误差

给定  $0 < \varepsilon < 1$ , 令

$$J_0 = \|e_N\| \leq \varepsilon, \quad (23)$$

其中  $\varepsilon$  为训练容忍度, 表示网络训练过程中能够忍耐的最大误差.

### 2.1.5 增加隐层节点

判断  $e_N$  是否满足式(24)给定的误差准则: 若满足, 则 SCNs 模型训练完成; 反之, 则继续增加新的隐藏节点, 即通过随机配置算法选择基函数, 并配置输入权值与偏差, 根据输出权值评估算法计算输出权值. 最后判断误差, 直到其满足误差准则时完成网络训练.

## 2.2 改进的交替辨识算法

假设模型(7)中线性部分未知, 则算法步骤如下.

step 1: 由给定的数据集  $M$ , 利用行列式比定阶法<sup>[17]</sup> 获得模型结构参数  $(n_A, n_B, d)$ , 此时可确定数据向量  $\varphi(k)$  的值; 由 FFRLS 根据式(10)对系统进行参数估计, 可得当前参数向量估计值  $\hat{\theta}(k)$ ; 再通过式(9)计算获得线性部分估计输出  $\hat{y}(k+d)$ .

step 2: 根据式(11)得到包含线性辨识误差的未建模动态值  $\bar{v}[\varphi(k)]$ , 作为 SCNs 网络训练输出数据.

step 3: 利用 SCNs 训练构建网络, 并估计未建模动态, 得到估计值  $\hat{v}[\varphi(k)]$ .

step 4: 将未建模动态  $\bar{v}[\varphi(k)]$  与网络估计结果  $\hat{v}[\varphi(k)]$  相比较, 将比较结果返回给 FFRLS 并继续重复上述步骤, 如此循环交替辨识, 直到满足给定的外部误差准则为止. 其中外部误差准则为

$$J = \sum_{k=1}^L \varepsilon^2(k). \quad (24)$$

若目标函数  $J > \delta$  ( $\delta$  取极小值且  $\delta < 0.001$ ), 则将误差返回给 FFRLS 并从 step 1 开始重复上述步骤, 如此循环往复, 直到  $J \leq \delta$ .

## 3 数值仿真

为说明本文所提出算法的有效性, 分别使用 FFRLS、SCNs、文献[14]和本文所提出方法对相同系统进行仿真建模实验, 每组实验重复进行 100 次以增强实验可靠性; 对实验结果做出对比分析, 对比结果通过图表等可视化形式辅以文字进行说明展示.

设非线性系统为

$$\begin{aligned} y(k) = & a_1 e^{-(u(k)-b_1)/c_1} + a_2 e^{-(u(k)-b_2)/c_2} + \\ & a_3 e^{-(u(k)-b_3)/c_3} + a_4 e^{-(u(k)-b_4)/c_4}. \end{aligned}$$

其中:  $a = [a_1, a_2, a_3, a_4] \in [0.1, 1]$ ,  $b = [b_1, b_2, b_3, b_4] \in [0.1, 1]$ ,  $c = [c_1, c_2, c_3, c_4] \in [0.01, 0.1]$ , 在各自范围内由计算机随机赋值.

参考输入信号为  $u(k) = \sin(2\pi k/15)/L + \sin(2\pi k/25)/L + \sin(2\pi k/35)/L + \sin(2\pi k/45)/L$ ,  $L$  为步长.

模型结构参数  $n_A = 3, n_B = 2$ , 则 FFRLS 模拟输出为  $y_m(k+1) = \hat{y}(k+1) = \varphi^T(k)\hat{\theta}(k)$ . 为实验方便, 令时滞  $d = 1$ , 所得结果如图 3~图 6 所示.

图 3 为 FFRLS 算法经过 140 步辨识所得结果与误差. 经过多次实验发现, 在  $\lambda = 0.925$  时系统能得到最佳仿真效果, 但误差收敛较慢, 达到的最高精度有限.




图 3 采用 FFRLS 算法辨识的结果及误差

图4为SCNs算法经过网络训练后得到的测试结果. 模型结构参数不变,将FFRLS仿真步长为140步的输入输出数据作为网络输入和输出数据集,从中分别抽取两组数据,步长数为奇数的70组数据作为SCNs的训练集数据,步长数为偶数的70组数据作为测试集数据,最大隐藏节点数为100,训练忍耐度为网络训练可以容忍的训练最大误差,将其设为 $1 \times 10^{-9}$ . 此时可获得网络节点数目为94,测试结果误差在 $4 \times 10^{-8}$ 以内,均方误差(mean square error, MSE)为 $7.06 \times 10^{-7}$ ,网络规模略大,但好处是测试误差小且无需人为设置网络节点数及基函数.




图4 采用SCNs算法辨识的结果及误差

图5为采用文献[14]算法的辨识所得结果与误差. 其中:  $v(k)$  为未建模动态,  $v_m(k)$  为未建模动态估计值. 线性部分采用改进的投影算法进行参数辨识,未建模动态部分采用BP神经网络进行辨识. 经过多次实验得出,隐层节点为100,学习率为0.015,动量因子为0.5,迭代次数达到10000,可以得出如图5所示的最佳仿真效果.




图5 采用文献[14]算法的辨识结果及误差

图6为采用本文算法辨识的结果及误差. 其中:  $v(k)$  为未建模动态,  $v_m(k)$  为未建模动态估计值. 将FFRLS仿真步长为140步的输入和线性误差作为本

文算法的输入和输出数据集,其他参数与SCNs算法保持一致. 与图4对比可以发现,图6的误差范围缩小到了 $2 \times 10^{-11}$ 以内,说明本算法确实可以做到补偿线性误差以达到提高非线性系统辨识精度的目的;与图5对比发现,其误差收敛速度更快,且预设误差同样为 $1 \times 10^{-9}$ ,但网络节点数目为70,缩小了网络规模;与图5对比还可以发现,其收敛精度更高,实验过程也无需人为设定网络结构参数.




图6 采用本文算法的辨识结果及误差

### 4 结论

针对一类非线性离散动态系统,本文提出了一种改进的基于随机配置网络的非线性系统混合智能建模方法. 该算法在利用带遗忘因子的最小二乘法进行线性模型参数辨识的基础上,采用随机配置网络估计未建模动态,并补偿系统的非线性特征及线性辨识误差,实现了非线性系统的混合智能建模,并达到给定的建模精度. 采用数值仿真结果进行对比分析,实验结果表明,所提出的算法的确具有提升非线性模型参数辨识精度的优点.

### 参考文献(References)

- [1] 庞中华, 崔红. 系统辨识与自适应控制 Matlab 仿真[M]. 第3版. 北京: 北京航空航天大学出版社, 2017: 11-55.  
(Pang Z H, Cui H. System identification and adaptive control Matlab simulation[M]. The 3rd edition. Beijing: Beijing University of Aeronautics & Astronautics Press, 2017: 11-55.)
- [2] Chen Y, Liu Y J, Chen J, et al. A novel identification method for a class of closed-loop systems based on basis pursuit de-noising[J]. IEEE Access, 2020, 8: 99648-99654.
- [3] Wang Y G, Chai T Y, Fu J, et al. Adaptive decoupling switching control of the forced-circulation evaporation system using neural networks[J]. IEEE Transactions on Control Systems Technology, 2013, 21(3): 964-974.

- [4] Li Y M, Tong S C, Li T S. Composite adaptive fuzzy output feedback control design for uncertain nonlinear strict-feedback systems with input saturation[J]. IEEE Transactions on Cybernetics, 2015, 45(10): 2299-2308.
- [5] Li Y M, Sui S, Tong S C. Adaptive fuzzy control design for stochastic nonlinear switched systems with arbitrary switchings and unmodeled dynamics[J]. IEEE Transactions on Cybernetics, 2017, 47(2): 403-414.
- [6] Wang W, Li Y M, Tong S C. Adaptive fuzzy event-triggered control for leader-following consensus of high-order nonlinear systems[J]. IEEE Transactions on Fuzzy Systems, 2020, 28(10): 2389-2400.
- [7] Li Y M, Li K W, Tong S C. Adaptive neural network finite-time control for multi-input and multi-output nonlinear systems with positive Powers of odd rational numbers[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(7): 2532-2543.
- [8] Li H Y, Wu Y, Chen M. Adaptive fault-tolerant tracking control for discrete-time multiagent systems via reinforcement learning algorithm[J]. IEEE Transactions on Cybernetics, 2021, 51(3): 1163-1174.
- [9] 丁进良, 杨翠娥, 陈远东, 等. 复杂工业过程智能优化决策系统的现状与展望[J]. 自动化学报, 2018, 44(11): 1931-1943.  
(Ding J L, Yang C E, Chen Y D, et al. Research progress and prospects of intelligent optimization decision making in complex industrial process[J]. Acta Automatica Sinica, 2018, 44(11): 1931-1943.)
- [10] 杨杰, 柴天佑, 张亚军, 等. 数据与模型驱动的电熔镁群炉需量预报方法[J]. 自动化学报, 2018, 44(8): 1460-1474.  
(Yang J, Chai T Y, Zhang Y J, et al. Data and model driven demand forecasting method for fused magnesium furnace group[J]. Acta Automatica Sinica, 2018, 44(8): 1460-1474.)
- [11] 王魏, 柴天佑, 赵立杰. 带有稳定学习的递归神经网络动态偏最小二乘建模[J]. 控制理论与应用, 2012, 29(3): 337-341.  
(Wang W, Chai T Y, Zhao L J. Dynamic partial least squares modeling with recurrent neural networks of stable learning[J]. Control Theory & Applications, 2012, 29(3): 337-341.)
- [12] 李温鹏, 周平. 高炉铁水质量鲁棒正则化随机神经网络建模[J]. 自动化学报, 2020, 46(4): 721-733.  
(Li W P, Zhou P. Robust regularized RVFLNs modeling of molten iron quality in blast furnace ironmaking[J]. Acta Automatica Sinica, 2020, 46(4): 721-733.)
- [13] 周平, 张丽, 李温鹏, 等. 集成自编码与PCA的高炉多元铁水质量随机神经网络建模[J]. 自动化学报, 2018, 44(10): 1799-1811.  
(Zhou P, Zhang L, Li W P, et al. Autoencoder and PCA based RVFLNs modeling for multivariate molten iron quality in blast furnace ironmaking[J]. Acta Automatica Sinica, 2018, 44(10): 1799-1811.)
- [14] 张亚军, 柴天佑, 杨杰. 一类非线性离散时间动态系统的交替辨识算法及应用[J]. 自动化学报, 2017, 43(1): 101-113.  
(Zhang Y J, Chai T Y, Yang J. Alternating identification algorithm and its application to a class of nonlinear discrete-time dynamical systems[J]. Acta Automatica Sinica, 2017, 43(1): 101-113.)
- [15] 牛宏, 陶金梅, 张亚军. 一种新的数据驱动的非线性自适应切换控制方法[J]. 自动化学报, 2020, 46(11): 2359-2366.  
(Niu H, Tao J M, Zhang Y J. A new nonlinear adaptive switching control method based on data driven[J]. Acta Automatica Sinica, 2020, 46(11): 2359-2366.)
- [16] Wang D H, Li M. Stochastic configuration networks: Fundamentals and algorithms[J]. IEEE Transactions on Cybernetics, 2017, 47(10): 3466-3479.
- [17] 刘党辉, 蔡远文, 苏永芝, 等. 系统辨识方法及应用[M]. 北京: 国防工业出版社, 2010: 70-123.  
(Liu D H, Cai Y W, Su Y Z, et al. System identification method and application[M]. Beijing: National Defense Industry Press, 2010: 70-123.)

### 作者简介

陶金梅(1995—), 女, 硕士, 从事非线性系统自适应控制与系统辨识的研究, E-mail: tao\_jinmei@hotmail.com;

牛宏(1979—), 女, 讲师, 博士, 从事非线性系统的自适应控制和变结构控制等研究, E-mail: niuhong@lnpu.edu.cn;

张亚军(1979—), 男, 副教授, 博士, 从事非线性模糊自适应控制理论、广义预测控制、多模型切换控制、智能解耦控制等研究, E-mail: yajunzhang@mail.neu.edu.cn;

李旭生(1993—), 男, 硕士生, 从事广义预测控制与切换控制的研究, E-mail: lxs842884305@163.com.

(责任编辑: 李君玲)