

# 基于粒子群优化与 SVR-ADLA 算法的 MIMO 系统识别研究<sup>①</sup>

杨发权<sup>②\*</sup> 李 赞<sup>\*\*</sup> 郝本建<sup>\*\*</sup> 樊 耘<sup>\*</sup>

(<sup>\*</sup> 佛山科学技术学院电子与信息工程学院 佛山 528000)

(<sup>\*\*</sup> 西安电子科技大学 综合业务网理论及关键技术国家重点实验室 西安 710071)

**摘要** 针对现有基于径向基函数(RBF)网络对多输入多输出(MIMO)系统识别中存在收敛速度慢、系统识别稳定性不高的问题,提出了一种新的MIMO系统识别方法:采用支持向量回归(SVR)算法建立RBF网络初始化结构,确定初始化网络参数;采用退火动力学习(ADL)算法对系统识别网络进行训练,在训练过程中采用粒子群优化(PSO)迭代算法选出最佳学习率组合,使识别网络实现对MIMO系统的识别。对一个两输入输出系统进行了识别仿真,仿真结果表明,用该识别方法重建的识别系统性能优于目前RBF网络参数优化过程中常用的最小平方算法或梯度下降法算法。RBF网络识别系统易于实现,在MIMO系统识别中具有广泛的应用前景。

**关键词** 多输入多输出(MIMO)系统识别, 径向基函数(RBF)网络, 支持向量回归(SVR), 退火动力学习(ADL), 粒子群优化(PSO)

## 0 引言

多输入多输出(MIMO)系统利用MIMO发射接收天线增加空间自由度,使系统容量大幅度提高,同时由于采用空时编码技术综合空间分集和时间分集,获得的分集增益和编码增益较高,系统的频谱利用率大幅度提高,它作为4G系统的关键技术,在民用和军用通信中有着广泛的应用,因而对MIMO系统的监控、识别、确认有重要的意义<sup>[1]</sup>。

对MIMO系统的检测识别,主要包括对MIMO系统输入输出天线数目识别及对系统各调制方式的正确识别。为此,国内外专家学者进行了大量的研究,目前较为传统的常用研究方法是采用最大似然(maximum likelihood, ML)算法、迫零(zero forcing, ZF)算法、最小均方误差(minimum mean square error, MMSE)算法、连续干扰抵消(successive interfer-

ence cancellation, SIC)算法和并行干扰抵消(parallel interference cancellation, PIC)算法等。ML算法检测识别过程中没有功率损失,但计算复杂度较大;ZF算法将接收信号分为独立数据流进行检测识别,每一子数据流的分集增益还不是很理想,因而影响了识别效率;MMSE算法能最小化由噪声和干扰信号引起的误差,误码率性能优于ZF算法,但它仍然存在分集增益不理想而影响识别效率的问题;SIC算法与PIC算法的检测识别性能相对有所提高,但也存在计算复杂的问题<sup>[2]</sup>。为了降低计算复杂度,进一步提高系统正确识别率,文献[3,4]分别提出利用分层最小平方算法、支持向量回归(support vector regression, SVR)综合最小平方算法及采用神经反向动力非线性回归模型对MIMO系统进行识别。文献[5]介绍了径向基函数(radial basis function, RBF)网络,RBF网络由于其收敛速度快,已广泛应用于包括MIMO系统在内的线性及非线性系统的识

<sup>①</sup> 国家自然科学基金(61072070, 61301179), 教育部博士学科点基金(20110203110011), 教育部基础科研业务费(72124338), 陕西省自然基金重点项目(2012JZ8002)和高等学校学科创新引智计划(B08038)资助项目。

<sup>②</sup> 男, 1965年生, 博士, 副教授; 研究方向: 无线通信信号的检测与识别技术; 联系人, E-mail: yafaquan.fosu@163.com  
(收稿日期: 2014-03-24)

别,并且取得一定的成效,但对于 RBF 网络隐含层数、初始的网络内核参数、初始网络权值等,需要根据经验设定或者随机确定。另外在网络参数优化过程中,通常采用的最小平方算法、梯度下降法算法以及遗传算法等,其中最小平方算法易于实现,但精度不高;梯度下降法其优点是工作量少,存储变量较少,初始点要求不高,但收敛速度慢,效率不高,有时达不到最优解。遗传算法则对新空间的探索能力是有限的,容易收敛于局部极小点,因此上述三种算法当初始化选择不恰当时会导致参数优化过程中收敛速度变慢及网络识别性能变差<sup>[6-8]</sup>。在网络学习训练过程中,学习率的选择十分重要,通常是选定非时变常量作为学习率<sup>[9]</sup>,使网络学习过程得以实现,但同样也存在收敛速度慢以及系统稳定性高等问题。为此本文提出用基于支持向量回归算法确立(RBF)网络结构及初始参数包括网络隐含层数、初始的网络内核参数、初始网络权值等,采用退火动力学习(annealing dynamic learning, ADL)算法对(RBF)网络进行训练,在训练中学习率采用时变量,影响学习率的各参数取值采用粒子群优化(particle swarm optimization, PSO)算法进行优化,从而能提高收敛速度、改善网络识别性能和保持系统识别稳定性。

## 1 MIMO 系统模型

MIMO 系统是多输入、多输出系统,由输入层、隐含层及输出层三部分组成。其模型可用径向基函数(RBF)网络表示,如图 1 所示。其中隐含层  $G_1, G_2, \dots, G_L$  相当于 MIMO 通信系统的发射天线,各输出层相当于接收天线。在 RBF 网络中隐含层选用高斯函数  $G_1, G_2, \dots, G_L$  作为 RBF 即内核函数,则系统输出为

$$\hat{y}_j(t+1) = \sum_{i=1}^L G_i w_{ij} = \sum_{i=1}^L w_{ij} \exp\left(-\frac{\|x - m_i\|^2}{2\sigma_i^2}\right), \quad j = 1, 2, \dots, p \quad (1)$$

其中  $x(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$  是输入矢量,  $\hat{y}(t) = [\hat{y}_1(t), \hat{y}_2(t), \dots, \hat{y}_p(t)]$  是输出矢量,而  $w_{ij}, m_i, \sigma_i, L$  则分别为对应的网络权值、均值、

高斯函数的方差、隐含层神经元数。因此对 MIMO 系统的识别问题,实质上是对 RBF 网络参数  $w_{ij}, m_i, \sigma_i, L$  的准确估计问题。

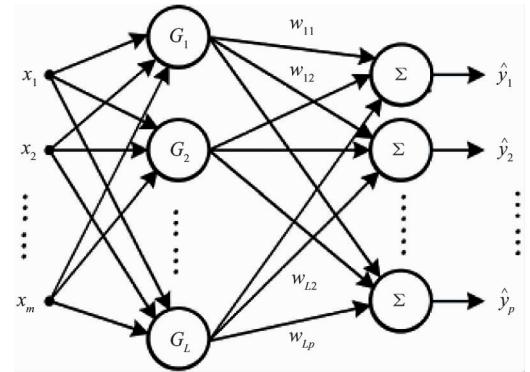


图 1 MIMO 系统模型

## 2 MIMO 系统识别原理

为实现 MIMO 系统类型识别,首先根据图 1 所示的 MIMO 系统模型,采用支持向量回归(SVR)算法建立 RBF 网络初始化结构,以确定网络参数  $w_{ij}, m_i, \sigma_i, L$  的初始值,然后采用退火动力学习(ADL)算法。对 RBF 网络系统识别网络进行训练,在训练过程中,采用粒子群优化(PSO)迭代算法对学习率进行优化组合,使 RBF 网络系统识别网络性能大幅度提高。

### 2.1 基于 SVR 的 RBF 网络初始化网络的建立

给定一系列训练输入、输出矢量对:  $(\mathbf{x}^{(k)}, \mathbf{y}^{(k)})$ ,  $k = 1, 2, K, N$ , 其中:  $\mathbf{x}^{(k)}(t) = [\mathbf{x}_1^{(k)}, \mathbf{x}_2^{(k)}, \dots, \mathbf{x}_m^{(k)}]^T$ ,  $\mathbf{y}^{(k)}(t) = [\mathbf{y}_1^{(k)}, \mathbf{y}_2^{(k)}, \dots, \mathbf{y}_p^{(k)}]^T$ , 对于给定的 RBF 网络,其神经元作用权值系数  $w_{ij}$  及阀值  $\theta_j$  一定时,则第  $j$  个输出与输入的关系为  $\mathbf{y}_j^{(k)} = \mathbf{F}(\mathbf{x}_j^{(k)})$ , 其中  $\mathbf{F}(\cdot)$  为转移函数,第  $j$  个输出对应的输入矢量加权和为

$$\mathbf{x}_j^{(k)} = \sum_{i=1}^m \mathbf{x}_i w_{ij} - \theta_j \quad (2)$$

根据 SVR 算法,RBF 网络  $w_{ij}, m_i, \sigma_i, L$  网络参数值需要识别的问题就转化为对照式(2)进行拓展的线性函数  $f(\mathbf{x}, \boldsymbol{\theta})$  相关参数的识别问题,其中拓展的线性函数  $f(\mathbf{x}, \boldsymbol{\theta})$  如下式所示:

$$f(\mathbf{x}, \boldsymbol{\theta}) = \sum_{l=1}^M \boldsymbol{\theta}_l g_l(\mathbf{x}) + b \quad (3)$$

其中  $\boldsymbol{\theta} = (\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \mathbf{K}, \boldsymbol{\theta}_M)$  和  $b$  分别为待识别的矢量和常量,  $g_l(x), l = 1, 2, K, M$  为基函数。同时根据 SVR 算法, 为找到合适的  $\theta, b, g_l(x)$ , 必须使此时系统损耗均值

$$R(\theta) = \frac{1}{N} \sum_{k=1}^N L_\varepsilon(y_l^{(k)} - f(x^{(k)}, \theta)) \quad (4)$$

最小<sup>[10]</sup>, 其约束条件为  $\|\theta\|^2 < C$ , 式中  $L_\varepsilon(\cdot)$  为迟钝系数为  $\varepsilon$  时的损耗函数

$$L_\varepsilon(e) = \begin{cases} 0, & |e| \leq \varepsilon, \\ |e| - \varepsilon, & \text{其它} \end{cases} \quad (5)$$

利用拉格朗日乘法原理, 式(4)最小值的求解就变为下式的优化问题<sup>[11]</sup>:

$$\begin{aligned} \text{Minimize } Q(\alpha, \alpha^*) &= \varepsilon \sum_{r=1}^N (\alpha_r + \alpha_r^*) - \sum_{r=1}^N y_r (\alpha_r - \alpha_r^*) \\ &+ \frac{1}{2} \sum_{r,s=1}^N (\alpha_r^* - \alpha_r)(\alpha_s^* - \alpha_s) \sum_{l=1}^M g_l(x_r) g_l(x_s) \end{aligned} \quad (6)$$

约束条件为  $\|\theta\|^2 < C$ ,  $0 < \alpha_r^*$ ,  $\alpha_r < C$

在式(6)中函数  $g_l(x_r)$  的内积由内核函数代替, 即  $k(x_r, x_s) = \sum_{l=1}^M g_l(x_r) g_l(x_s)$ , 故式(6)变为

$$\begin{aligned} \text{Minimize } Q(\alpha, \alpha^*) &= \varepsilon \sum_{r=1}^N (\alpha_r + \alpha_r^*) - \sum_{r=1}^N y_r (\alpha_r - \alpha_r^*) \\ &+ \frac{1}{2} \sum_{r,s=1}^N (\alpha_r^* - \alpha_r)(\alpha_s^* - \alpha_s) k(x_r, x_s) \end{aligned} \quad (7)$$

式(7)的解为下面内核函数的线性组合:

$$f(x, \alpha, \alpha^*) = \sum_{l=1}^M (\alpha_l^* - \alpha_l) k(x, x_l) + b \quad (8)$$

令  $\lambda_l = \alpha_l^* - \alpha_l$ , 其对应向量称支持向量(support vectors, 简称 SVs), 对应向量数为 Lsv, 同时由于文中选用高斯函数作为内核函数, 所以式(8)可变为

$$f(x, \lambda) = \sum_{l=1}^{Lsv} \lambda_l \exp\left(-\frac{\|x - x_l\|^2}{2\sigma_l^2}\right) + b \quad (9)$$

对比式(1)知, 式(9)中的  $\lambda_l, x_l, \sigma_l, Lsv$  分别为 RBF 网络初始化参数  $w_{ij}, m_i, \sigma_i, L$ 。

## 2.2 RBF 网络系统识别训练

通过初始化, 确定了 RBF 网络的初始结构, 接着需要对网络进行训练以实现对 MIMO 系统的识别功能。文中采用 ADL 算法对 RBF 网络识别网络进行训练, 定义 ADL 算法的损失函数为

$$\begin{aligned} J_j(h) &= \frac{1}{N} \sum_{k=1}^N \rho[e_j^{(k)}(h); \beta(h)], \\ j &= 1, 2, \dots, p \end{aligned} \quad (10)$$

$$\begin{aligned} e_j^{(k)}(h) &= \overline{y_j^{(k)}} - \hat{y}_j^{(k)} \\ &= \overline{y_j^{(k)}} - \sum_{i=1}^L w_{ij} \exp\left(-\frac{\|x_i^{(k)} - m_i\|^2}{2\sigma_i^2}\right) \end{aligned} \quad (11)$$

其中:  $h$  为网络神经元数,  $\beta(h)$  为退火时刻选择的阀值点,  $e_j^{(k)}(h)$  为 RBF 网络对 MIMO 系统识别训练时, 网络第  $j$  个输出数据期望值与输出值之差,  $\rho(\cdot)$  为逻辑损失函数<sup>[12]</sup>, 且有:

$$\begin{aligned} \rho[e_j^{(k)}(h), \beta(h)] &= \frac{\beta}{2} \ln[1 + \frac{(e_j^{(k)})^2}{\beta}], \\ j &= 1, 2, \dots, p \end{aligned} \quad (12)$$

根据 ADL 算法, 网络系统权值  $w_{ij}$ 、中心均值  $m_i$ 、高斯函数方差  $\sigma_i$  按以下式更新:

$$\Delta w_{ij} = -\eta_{w_j} \frac{\partial J_j}{\partial w_{ij}} = -\frac{\eta_{w_j}}{N} \sum_{k=1}^N \varphi_j(e_j^{(k)}, \beta) \frac{\partial e_j^{(k)}}{\partial w_{ij}} \quad (13)$$

$$\Delta m_i = -\eta_c \frac{\partial J_j}{\partial m_i} = -\frac{\eta_c}{N} \sum_{j=1}^p \sum_{k=1}^N \varphi_j(e_j^{(k)}, \beta) \frac{\partial e_j^{(k)}}{\partial m_i} \quad (14)$$

$$\Delta \sigma_i = -\eta_\sigma \frac{\partial J_j}{\partial \sigma_i} = -\frac{\eta_\sigma}{N} \sum_{j=1}^p \sum_{k=1}^N \varphi_j(e_j^{(k)}, \beta) \frac{\partial e_j^{(k)}}{\partial \sigma_i} \quad (15)$$

其中  $\eta_{w_j}, \eta_c, \eta_\sigma$  分别为  $w_{ij}$ 、中心均值  $m_i$ 、高斯函数方差  $\sigma_i$  的学习率,  $\varphi(\cdot)$  为影响函数, 式为

$$\varphi_j(e_j^{(k)}, \beta) = \frac{\partial \rho(e_j^{(k)}, \beta)}{\partial e_j^{(k)}} = \frac{e_j^{(k)}}{1 + (e_j^{(k)})^2 / \beta(h)} \quad (16)$$

式(13)~(15)中, 如果各学习率为常数时, 系统会在一局部优化点附近停滞, 此时收敛速度较慢, 不利于寻找全局最优解, 为此, ADL 算法采用了非线性时变迭代方法, 即在神经元取最大值时让各学习率  $\eta_{w_j}, \eta_c, \eta_\sigma$  分别从相应最大值  $\eta_{\max}$  非线性减小至最小值  $\eta_{\min}$ , 因此学习率  $\eta_{w_j}, \eta_c, \eta_\sigma$  函数为非线性时变函数, 表达式如下:

$$\eta_{w_j} = \eta_{\min} + (1 - \frac{h}{epoch_{\max}})^{pw_j} (\eta_{\max} - \eta_{\min}) \quad (17)$$

$$\eta_c = \eta_{\min} + (1 - \frac{h}{epoch_{\max}})^{pc} (\eta_{\max} - \eta_{\min}) \quad (18)$$

$$\eta_\sigma = \eta_{\min} + (1 - \frac{h}{epoch_{\max}})^{p\sigma} (\eta_{\max} - \eta_{\min}) \quad (19)$$

其中  $epoch_{\max}$  为神经元数目的最大值,  $h$  为当前的神经元数目。在式(17)、(18)、(19)中  $pw_i$ 、 $pc$ 、 $p\sigma$  的取值, 对学习率  $\eta_{w_j}$ 、 $\eta_c$ 、 $\eta_\sigma$  的影响很大, 在 RBF 网络训练过程中, 学习率的不同取值对系统的识别性能影响又很大, 因此如何选取  $pw_i$ 、 $pc$ 、 $p\sigma$  优化组合值十分重要, 文中采用 PSO 迭代算法选出  $pw_i$ 、 $pc$ 、 $p\sigma$  的最佳组合值。

### 2.3 PSO 算法

粒子群优化 (PSO) 算法, 由 James Kennedy 和 Russell Eberhart 在 1995 年通过观察鱼群、鸟群觅食行为而提出的一种基于群体协作的随机搜索优化算法<sup>[13]</sup>。本文采用 PSO 方法是为了寻找  $pw_i$ 、 $pc$ 、 $p\sigma$  的最优组合值, 首先通过编码的方法把  $pw_i$ 、 $pc$ 、 $p\sigma$  等参数值看作为鱼群、鸟群粒子不同个体的位置。为此设定粒子群位置:

$$\begin{aligned} \mathbf{P} &= [\mathbf{p}_1, \dots, \mathbf{p}_p, \mathbf{p}_{p+1}, \mathbf{p}_{p+2}] \\ &= [pw_1, \dots, pw_p, pc, p\sigma] \end{aligned} \quad (20)$$

同时选择适应度函数。在 MIMO 系统识别中, 系统的识别性能由系统的理想输出与训练输出的误差来决定, 因此, 选择适应度 (fitness) 函数如下:

$$Fitness = \sqrt{\sum_{j=1}^p (\sigma_j)^2} + \sqrt{\frac{1}{p} \sum_{j=1}^p (\sigma_j - \bar{\sigma})^2} \quad (21)$$

系统输出均方误差为

$$\sigma_j = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_j^{(k)} - \hat{y}_j^{(k)})^2}, \quad j = 1, 2, \dots, p \quad (22)$$

其中,  $y_j^{(k)}$  代表系统理想输出,  $\hat{y}_j^{(k)}$  代表系统训练数据输出,  $\bar{\sigma}$  为输出均方误差  $\sigma_j$ ,  $j = 1, 2, \dots, p$  时的均值。

在 PSO 算法中, 每次迭代, 粒子的速率与位置更新原则是先用全局 PSO 找到大致的结果, 然后, 再用局部 PSO 进行搜索<sup>[14,15]</sup>。在快速全局搜索的同时, 避免陷入局部最优, 其中粒子速率更新与位置

更新用以下两式表示:

$$\begin{aligned} V(i+1) &= w(i+1) \cdot V(i) + C_1(i+1) \cdot r_1 \\ &\quad + (\mathbf{P}^{lbest}(i) - \mathbf{P}(i)) + C_2(i+1) \\ &\quad \cdot r_2 \cdot (\mathbf{P}^{gbest} - \mathbf{P}(i)) \end{aligned} \quad (23)$$

$$\mathbf{P}(i+1) = \mathbf{P}(i) + V(i+1) \quad (24)$$

上式中,  $\mathbf{P}(i)$ 、 $\mathbf{P}(i+1)$  分别表示在第  $i$  次和第  $i+1$  次迭代时粒子的位置;  $V(i)$ 、 $V(i+1)$  分别表示在第  $i$  次和第  $i+1$  次迭代时粒子的速率;  $w(i+1)$  表示在第  $i+1$  次迭代时对应的惯性权值;  $C_1(i+1)$ 、 $C_2(i+1)$  分别表示在第  $i+1$  次迭代时的认知参数和群体参数;  $\mathbf{P}^{lbest}(i)$  为第  $i$  次迭代时的局部最优解;  $\mathbf{P}^{gbest}$  则是全局最优解。

式(23)中的惯性权值  $w$  代表粒子的惯性程度, 是表示平衡局部搜索与全局搜索之间的参数。在刚开始迭代时, 选择较高的惯性权值, 使粒子具有较高的全局搜索能力, 对解空间进行大范围积极搜索。当大范围搜索发现越来越接近最优解时, 在后面的迭代中, 通过调节惯性权值  $w$ , 使其越来越小, 搜索策略由大范围粗略搜索转变为小范围精细搜索, 确保找到全局最优解。因此, 在算法迭代过程中, 惯性权值与迭代次数之间成线性关系, 如下式所示:

$$w(i+1) = w_{\max} - \frac{w_{\max} - w_{\min}}{\gamma_{\max}} \gamma \quad (25)$$

其中  $\gamma_{\max}$ 、 $\gamma$  分别为搜索过程中最大的迭代次数和当前的迭代次数,  $w_{\max}$ 、 $w_{\min}$  分别为搜索过程中惯性权值的最大值和最小值。

式(23)中的认知参数  $C_1$ 、群体参数  $C_2$  分别表示在随机加速条件下, 促使粒子成为局部最优和全局最优粒子的权值参数。在刚开始迭代时, 认知参数  $C_1$  取较高的参数值, 群体参数  $C_2$  取较小的参数值, 目的是先对解的空间范围进行搜索, 当逐步确定最优解的空间范围时, 在后面的迭代中, 认知参数  $C_1$  取较小的参数值, 群体参数  $C_2$  由取较大的参数值, 使粒子转向全局最优。因此, 在算法迭代过程中, 认知参数  $C_1$ 、群体参数  $C_2$  分别与迭代次数之间成线性关系如下式所示:

$$C_1(i+1) = C_{1\max} - \frac{C_{1\max} - C_{1\min}}{\gamma_{\max}} \gamma \quad (26)$$

$$C_2(i+1) = C_{2\min} - \frac{C_{2\min} - C_{2\max}}{\gamma_{\max}} \gamma \quad (27)$$

其中,  $C_{1\max}, C_{1\min}$  分别为认知参数在搜索过程中的最大和最小取值;  $C_{2\max}, C_{2\min}$  分别为群体参数在搜索过程中的最大和最小取值。

## 2.4 MIMO 系统识别模型

MIMO 系统识别模型方框如图 2 所示。

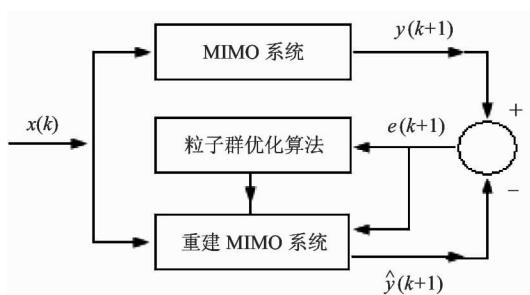


图 2 MIMO 系统识别模型方框图

图中  $x(k)$  为输入信号,  $y(k+1)$  和  $\hat{y}(k+1)$  分别为待识别 MIMO 系统输出和重建 MIMO 训练系统输出, 重建 MIMO 系统是上述采用支持向量回归 (SVR) 算法进行初始化, 采用退火动力学习 (ADL) 算法进行训练的 RBF 网络系统, 即 MIMO 系统识别目标, 通过粒子群算法, 不断地迭代, 进行全局和局部搜索, 优化  $pw_i$ 、 $pc$ 、 $p\sigma$  的组合参数值, 从而优化网络系统各学习率及对应权值参数, 当训练输出  $\hat{y}(k+1)$  与待识别输出  $y(k+1)$  误差函数  $e(k+1)$  接近零时, 重建的 MIMO 系统与待识别的 MIMO 系统基本一致, 即实现了 MIMO 系统的分类识别。

## 3 MIMO 系统识别仿真结果及其性能分析

用 MATLAB 进行仿真实验, 选择待识别 MIMO 系统为两输入两输出系统, RBF 网络系统识别网络学习率函数(式(17)、(18)、(19))中最大神经元数目  $epoch_{\max}$  取 500, 参数  $pw_i$ ( $pw_1, pw_2$ )、 $pc$  及  $p\sigma$  的取值在 0.1 ~ 5 的范围,  $\eta_{\max}, \eta_{\min}$  值分别取 2.5、0.02。粒子群优化算法将粒子总数、最大迭代次数均取 100; 式(24)中惯性权值的最大值  $w_{\max}$  和最小值  $w_{\min}$  分别取 0.9 和 0.2; 式(25)中认知参数的最大  $C_{1\max}$  和最小取值  $C_{1\min}$  分别取 2.5 和 0.5; 式(26)中群体参数最大  $C_{2\max}$  和最小取值  $C_{2\min}$  分别取 2.5 和 0.5。

实验中两输入两输出 MIMO 系统根据信道干扰程度的不同分别用两种模式表示, 若以加性噪声干扰为主, 乘性干扰不严重时该系统以模式 1 表示; 若信道干扰除加性噪声干扰外, 还存在有较严重的乘性噪声干扰时则系统以模式 2 表示<sup>[16]</sup>。

模式 1: 两输入两输出 MIMO 非线性系统的输入输出关系为

$$\begin{bmatrix} y_1(k+1) \\ y_2(k+2) \end{bmatrix} = \begin{bmatrix} \frac{y_1(k)}{1+y_2^2(k)} \\ \frac{y_1(k)y_2(k)}{1+y_2^2(k)} \end{bmatrix} + \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} \quad (28)$$

当采用 SVR 算法确定 RBF 网络识别网络结构与初始化参数时, 设定式(5)中与迟钝损耗函数相关的系数  $\varepsilon$  值, 通过 ADL 算法对 RBF 网络识别网络进行训练以及用 PSO 迭代算法选取与学习率相关的参数  $pw_i$ ( $pw_1, pw_2$ )、 $pc$  及  $p\sigma$  的最优组合, 从而使重建识别系统的均值方差最小, 当  $\varepsilon$  取值分别为 0.3 和 0.5 时, 系统识别性能仿真如图 3、图 4 所示。

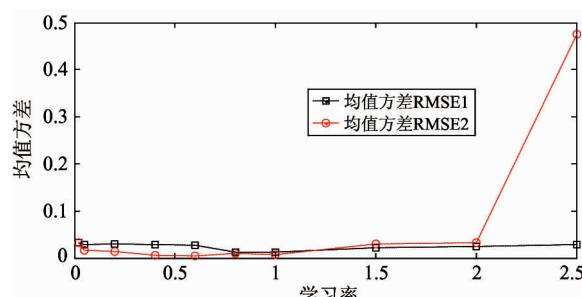


图 3  $\varepsilon$  取值为 0.3 时, 模式 1 系统识别性能仿真

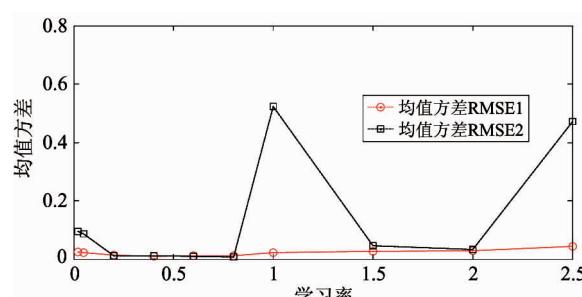


图 4  $\varepsilon$  取值为 0.5 时, 模式 1 系统识别性能仿真

图 3 表明当  $\varepsilon$  取值为 0.3 时, 采用上述的初始化 SVR 算法、ADL 训练算法、PSO 参数优化算法, 在优化学习率  $\eta = 1$  时, 重建识别模式 1 对应的 MIMO 非线性系统, 两输出均值方差最小, 约分别为 0.0121 和

0.0076。而图 4 表明,当  $\varepsilon$  取值为 0.5 时,在优化学习率  $\eta \approx 0.8$  附近,重建识别 MIMO 非线性系统,两输出均值方差最小,约分别为 0.0122 和 0.0077。

模式 2:两输入两输出 MIMO 非线性系统的其输入输出关系为

$$\begin{bmatrix} y_1(k+1) \\ y_2(k+2) \end{bmatrix} = \begin{bmatrix} \frac{y_2(k)}{1+y_1^2(k)} \\ \frac{y_1(k)}{1+y_1^2(k)} \end{bmatrix} + \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} \quad (29)$$

同理,当  $\varepsilon$  取值分别为 0.3 和 0.5 时,系统识别性能仿真如图 5、图 6 所示:

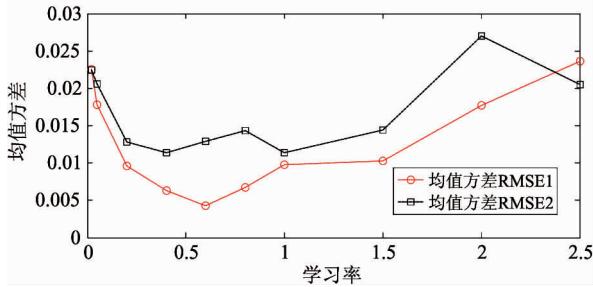


图 5  $5\varepsilon$  取值为 0.3 时,模式 2 系统识别性能仿真

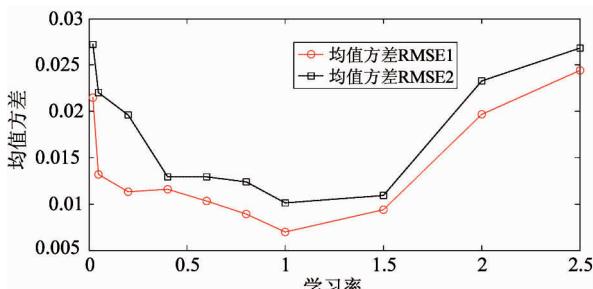


图 6  $\varepsilon$  取值为 0.5 时,模式 2 系统识别性能仿真

图 5 表明,当  $\varepsilon$  取值为 0.3 时,采用上述的初始化 SVR 算法、ADL 训练算法、PSO 参数优化算法,在优化学习率  $\eta \approx 0.6$  时,重建识别模式 2 对应的 MIMO 非线性系统,两输出均值方差最小,约分别为 0.0045 和 0.0129。而图 6 表明,当  $\varepsilon$  取值为 0.5 时,在优化学习率  $\eta = 1$  时,重建识别 MIMO 非线性系统,两输出均值方差最小,约分别为 0.0070 和 0.0100。

在上述研究的 MIMO 系统识别方案中,若在网络参数优化过程中,不是采用 PSO 参数优化算法而

是分别采用目前常用的最小平方算法、梯度下降法算法,其它识别方法步骤不变,对于第二种模式 MIMO 系统,当  $\varepsilon$  取值为 0.5 时,系统识别性能仿真结果如图 7 所示。结果表明:在优化学习率  $\eta = 0.6$  时,重建识别 MIMO 系统两输出均值方差最小,约分别为 0.0132 和 0.0141,但和图 6 本文采用 PSO 参数优化算法比较两输出均值方差大,系统识别性能差些,主要是在网络参数优化过程中与 PSO 算法比较,采用的最小平方算法存在精度不高,采用梯度下降法算法其收敛速度相对较慢的缘故。

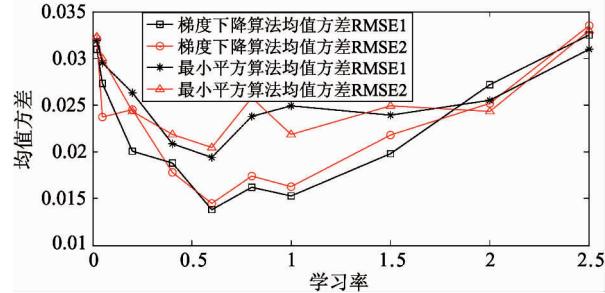


图 7 最小平方算法、梯度下降法算法,  $\varepsilon$  取值为 0.5 时,模式 2 系统识别性能仿真

## 4 结 论

本文提出基于支持向量回归(SVR)算法确立径向基函数(RBF)网络结构及初始参数包括网络隐含层数、初始网络内核参数、初始网络权值等,采用退火动力学习(ADL)算法对 RBF 网络进行学习训练,采用粒子群优化(PSO)算法对影响学习率的各参数取值进行优化,来提高 RBF 网络在识别多输入多输出(MIMO)系统中的收敛速度,改善网络识别性能,保持系统识别稳定性。仿真结果表明,用这种方法对两种不同模式的两输入两输出非线性系统的识别切实可行,识别输出均值方差较小。

## 参 考 文 献

- [1] 禹化龙. 基于空时分组码的接收天线选择对 MIMO 系统性能的影响研究. 中国电子科学研究院学报,2013, 38(3):321-326
- [2] 杨远. MIMO 系统中的检测算法研究:[博士学位论文]. 西安:西安电子科技大学通信工程学院,2009. 15-30
- [3] 刘玉广,罗宁,马林华等. 级联 LDPC 编码的协作 MI-

- MO 系统研究. 空军工程大学学报(自然科学版), 2013, 14(3):78-82
- [ 4 ] Fu Y Y, Wu C J, Jeng J T, et al. Identification of MIMO systems using radial basis function networks with hybrid learning algorithm. *Applied Mathematics and Computation*, 2009, 213(5):184-196
- [ 5 ] Camps-valls G, Munoz-marli J. Learning non-linear time-scales with kernel c-filters. *Neurocomputing*, 2009, 72(8):1324-1328
- [ 6 ] 高飞, 周长林, 党力明. 侯雪梅基于径向基函数网络的 H.264 全零块检测算法. *计算机应用*, 2013, 35(1):65-68
- [ 7 ] Majhi B, Panda G. Development of efficient identification scheme for nonlinear dynamic systems using swarm intelligence techniques. *Expert Systems with Applications*, 2012, 47(1):535-547
- [ 8 ] Rouss V, Charon W. Multi-input and multi-output neural model of the mechanical nonlinear behaviour of a PEM fuel cell system. *Journal of Power Sources*, 2008, 175(6):1-17
- [ 9 ] Mehdi K, Ali Z, Hamadani. A novel hybrid classification model of artificial neural networks and multiple linear regression models. *Expert Systems with Applications*, 2012, 38(39):2606-2620
- [ 10 ] Kim Y, Langari R, Hurlebaus S. MIMO fuzzy identification of building-MR damper systems. *Journal of Intelligent & Fuzzy Systems*, 2011, 22(3):185-205
- [ 11 ] Ghiassi M, Burnley C. Measuring effectiveness of a dynamic artificial neural network algorithm for classification problems. *Expert Systems with Applications*, 2010, 37(5):3118-3128
- [ 12 ] Hsieh S T, Sun T Y. Effective learning rate adjustment of blind source separation based on an improved particle swarm optimizer. *IEEE Transactions on Evolutionary Computation*, 2010, 12(2):242-251
- [ 13 ] Glavan C, Holban S. A Model for determining the number of negative examples used in training a MLP. *Innovations in Computing Sciences and Software Engineering*, 2010, 55(2):537-542
- [ 14 ] Anh H P H, Phuc N H. Inverse neural MIMO NARX model identification of nonlinear system optimized with PSO. In: Proceeding of the 5th IEEE international symposium on electronic design, test and application, Ho Chi Minh, Vietnam, 2010, 1:144-149
- [ 15 ] Chen S, Hong X, Luk B L. Non-linear system identification using particle swarm optimization tuned radial basis function models. *International Journal Bio-Inspired Computation*, 2009, 1(4):246-258
- [ 16 ] Yu Y, Yu X C, Li Y S. Solving engineering optimization problem by augmented lagrange particle swarm optimization. *Journal of Mechanical Engineering*, 2012, 45(12):167-172

## Identification of MIMO Systems based on particle swarm optimization, support vector regression and annealing dynamic learning

Yang Faquan\*, Li Zan\*\*, Hao Benjian\*\*, Fan Yun\*

(\* School of Electronics and Information Engineering, Foshan University, Foshan 528000)

(\*\* State Key Laboratory of Integrated Service Networks, Xidian University, Xian 710071)

### Abstract

The identification of a multiple-input multiple-out-put (MIMO) system based on a radial basis function (RBF) network was studied, and a new identification method was put forward to solve the problems of slow convergence rate and low identification stability in current identification. The new method uses the support vector regression (SVR) algorithm to establish the initialized structure of a RBF network and set the parameters of the initialized network, and then adopts the annealing dynamic learning (ADL) algorithm to train the system's identification network, and in the training, uses the iteration of particle swarm optimization (PSO) to select the best learning rate combination to make the MIMO system recognized by the identification network. The identification simulation for a two-input and two-output, system was conducted, and the simulation results showed that the system identification performance of the proposed method was better than the least square algorithm and the gradient descent algorithm frequently-used in the current process of optimizing RBF network parameters. The identification system based on a RBF network is easy to implement and it has a wide application prospect in MIMO system identification.

**Key words:** multiple-input multiple-out-put (MIMO) system identification, radial basis function (RBF) network, support vector regression (SVR), annealing dynamic learning (ADL), particle swarm optimization (PSO)