

基于泛函连接网络和差分进化算法的后非线性混叠信号盲分离方法

高 鹰^{①②} 谢胜利^①

^①(广州大学信息学院计算机科学与技术系 广州 510405)

^②(华南理工大学电子与信息学院 广州 510641)

摘 要 把后非线性混叠信号盲分离的分离系统用泛函连接网络来建模,对分离系统的输出应用高阶统计量独立性准则作为测度,然后利用差分进化算法对泛函连接网络的权值进行学习,从而获得了一种后非线性混叠信号盲分离算法。由于泛函连接网络是一种单层神经网络,具有学习参数少、收敛速度快和非线性逼近能力强的特点;而差分进化算法控制参数少、易于选择、具有全局寻优能力和快速的收敛特性;因而与其它的后非线性混叠信号盲分离方法相比,该文提出的分离算法具有计算简单、收敛速度快、较高的精度和稳定性好的特点。仿真结果显示了这种方法是可行和有效的。

关键词 盲信号分离, 后非线性混叠, 泛函人工神经网络, 差分进化算法

中图分类号: TN911.72

文献标识码: A

文章编号: 1009-5896(2006)01-0050-05

Blind Source Separation of Nonlinear Mixtures Based on Functional Link Artificial Neural Networks and Differential Evolution Algorithm

Gao Ying^{①②} Xie Sheng-li^①

^①(Dept. of Computer Science and Technology, Guangzhou University, Guangzhou 510405, China)

^②(College of Electronic & Information Engineering, South China University of Technology, Guangzhou 510641, China)

Abstract In this paper, a post nonlinear blind sources separation method is proposed. The demixing system of the post nonlinear mixtures is modeled using a functional link artificial neural network whose weights can be determined under the criterion of independence of its outputs. A criterion of independence based on higher order statistics is used to measure the statistical dependence of the outputs of the demixing system, and the differential evolution algorithm is utilized to minimize the criterion. The proposed method takes advantage of less learning parameters, high learning convergence rate of parameters, nonlinear approximation capability of the functional link artificial neural network, and few easily chosen control parameters, global optimization capability of the differential evolution algorithm. Compared to conventional post nonlinear blind sources separation approaches, the proposed approach for post-nonlinear blind source separation is characterized by less computational load, high convergence rate, high accuracy and robustness. Simulation results show that the proposed approach is capable of separating independent sources from their post-nonlinear mixtures.

Key words Blind signal separation, Post nonlinear mixtures, Functional artificial neural network, Differential evolution algorithm

1 引言

所谓盲信号分离(BSS)问题,就是在未知混叠参数的情况下,仅仅根据观测到的混叠信号恢复出原始源信号。信号源盲分离是一种功能强的信号处理方法,有着许多潜在的用途,特

别是在无线通信、医学分析、语音识别、图像处理等方面。目前,信号源盲分离问题已经成为国际上信号处理和神经网络等学科领域的一个研究热点,虽然对线性混叠信号盲分离问题的研究已取得了丰硕成果,但对更为实际的非线性混叠信号盲分离问题的研究和线性情况相比则相差甚远。由于非线性混叠情况比线性混叠情况复杂许多,使得这方面的研究深度,广度和成果均不及线性混叠情况。1999年,Hyvarinen^[1]从理论上讨论了非线性混叠信号模型解的存在性和唯一性问题,从理论上说明了对于非线性混叠信号盲分离问题,仅根据源信号独立

2004-08-02 收到, 2005-07-11 改回

国家自然科学基金(60274006),国家杰出青年基金(60325310),中国博士后科学基金(2003034062),广东省自然科学基金博士科研启动基金(04300015),广东省教育厅自然科学研究项目,广州市科技计划项目(2004J1-C0323)和广州市属高校科技计划项目(2055)资助课题

的假设不足以分离出源信号。然而, 在非线性混叠信号模型中, 有一类被称做后非线性混叠信号模型, 对于这种混叠信号模型, Taleb^[2,3]等首先从理论上说明了该模型是可分的, 其解的不确定性几乎和线性混叠情况解的不确定性一样。

对于后非线性混叠信号模型(图1所示), 其分离系统由非线性解混和线性解混两部分组成, 如图2所示。由于后非线性混叠信号模型的可分离性, 研究人员对其进行了研究和讨论, 提出了一些方法。Taleb首先给出了一种盲分离方法, 非线性部分用多层感知器逼近非线性混叠函数的逆, 而线性部分用于更新线性分离参数, 采用互信息作为独立性测度, 多层感知器参数和线性分离参数均采用梯度下降算法进行学习。之后, Tan^[4]给出了一种用径向基函数网络逼近非线性混叠函数逆的方法, 采用最大熵作为独立性测度, 径向基函数的参数采用梯度下降算法进行学习, 而线性分离参数采用自然梯度算法进行学习。而在文献[5]中, Tan采用一个神经网络作为分离系统, 其带参数的隐层激活函数用于逼近非线性混叠函数的逆, 网络权值用于更新线性分离参数, 独立性测度采用高阶统计量, 利用遗传算法对隐层激活函数的参数和网络权值进行学习的方法。2002年, Rojas^[6]给出了一个用齐次多项式逼近非线性混叠函数的逆, 用互信息作为独立性测度, 齐次多项式的系数采用遗传算法进行学习而线性分离参数采用自然梯度算法进行学习的方法。在这些方法中, 除了线性分离参数需要进行学习外, 还分别有多层感知器的参数、径向基函数的参数、隐层激活函数参数和齐次多项式的系数需要进行学习, 这无疑增加了学习参数的数量和计算量。另外, 采用梯度下降算法进行学习收敛精度较差, 易陷入局部极值; 而采用遗传算法进行学习需进行编解码操作, 遗传参数的选择比较困难等不足。因而, 这些方法总体性能还是不能令人满意的。本文采用泛函连接网络^[7,8]作为后非线性混叠信号盲分离的分离系统, 对于分离系统的输出应用高阶统计量独立性准则作为测度, 利用差分进化算法^[9,10](Differential Evolution Algorithm DEA)对泛函连接网络的权值进行学习, 从而获得了一种后非线性混叠信号盲分离算法。由于泛函连接网络是一种单层神经网络, 具有很强的非线性逼近能力、收敛速度快和学习参数少; 而差分进化算法有少的、易于选择的控制参数, 与其它进化算法如遗传算法相比, 差分进化算法具有全局寻优能力和快速的收敛特性, 优化过程效率高。仿真结果显示了这种方法是可行和有效的。

2 基于泛函连接网络的后非线性混叠信号盲分离系统

对于线性混叠形式, 其数学模型可表示为: $\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t)$, 其中 $\mathbf{s}(t)$ 是 n 维源信号矢量, $\mathbf{x}(t)$ 是 m 维的观察信号矢量,

\mathbf{A} 是 $m \times n$ 维的混叠矩阵, 其中, $\mathbf{s}(t) = [s_1(t) \ s_2(t) \ \cdots \ s_n(t)]^T$ 表示源信号矢量, $\mathbf{x}(t) = [x_1(t) \ x_2(t) \ \cdots \ x_m(t)]^T$ 表示混叠信号矢量。

然而, 用线性混叠模型模拟实际混叠情况太简单, 一般化的非线性混叠信号模型可描述如下:

$$\mathbf{x}(t) = \mathbf{F}(\mathbf{s}(t)) \quad (1)$$

即 $x_i(t) = f_i(s_1(t), s_2(t), \dots, s_n(t))$, $i = 1, 2, \dots, m$, $\mathbf{F} = [f_1(\cdot), f_2(\cdot), \dots, f_n(\cdot)]^T$ 。

后非线性混叠信号模型是非线性混叠信号模型的一种特例, 即

$$\mathbf{x}(t) = \mathbf{f}(\mathbf{A}\mathbf{s}(t)), \quad x_i(t) = f_i\left(\sum_{j=1}^n a_{i,j}s_j(t)\right), \quad i = 1, 2, \dots, m \quad (2)$$

其中 $\mathbf{A} = (a_{i,j})$ 是未知非奇异线性混叠矩阵; $\mathbf{f}(\cdot) = [f_1(\cdot), f_2(\cdot), \dots, f_n(\cdot)]^T$

图1表示的是后非线性混叠信号模型, 图2表示的是后非线性混叠信号模型分离系统。对于后非线性混叠信号模型式(2), Taleb^[2,3]等首先从理论上探讨了该模型的可分离性, 指出: 对分离系统的输出采用独立性准则可分离出源信号, 其解的不确定性几乎与线性混叠情况解的不确定性一样, 即

$$\mathbf{y}(t) = \mathbf{P}\mathbf{D}\mathbf{s}(t) + \mathbf{t} \quad (3)$$

其中 \mathbf{P} 是置换矩阵, \mathbf{D} 是对角矩阵, \mathbf{t} 是一个常量矢量。




图1 后非线性混叠信号模型
Fig.1 Model of post-nonlinear mixture




图2 后非线性混叠信号模型分离系统
Fig.2 Separation system of post-nonlinear mixture

我们用泛函连接网络来对分离系统建模, 如图3所示。图3所示的泛函连接网络的输出可表示为

$$y_i(t) = \rho\left(\sum_{j=1}^n w_{i,j}\varphi_j(\mathbf{x}(t))\right), \quad i = 1, 2, \dots, m \quad (4)$$

其中非线性函数 $\rho(\cdot)$ 取为 $\rho(x) = \tanh(x) = (1 - e^{-2x}) / (1 + e^{-2x})$, $\varphi_i (i = 1, \dots, n)$ 为基函数, 基函数应是线性独立的, 这里, 我们采用 Chebyshev 多项式^[8]。

独立性测度采用文献[5]的非线性函数独立性测度:

$$J(W) = \sum_{i=1}^n \sum_{j \neq i}^n [M(h_1(y_i), h_2(y_j))]^2 + \alpha C_1 + \beta C_2 \quad (5)$$

其中 W 表示分离系统的参数集, 即泛函连接网络的权值




图3 基于泛函连接网络的后非线性混叠信号盲分离模型

Fig. 3 Blind signals separation model of post-nonlinear mixture based on functional artificial neural network

$w_{i,j}$; $h_1(\cdot)$ 和 $h_2(\cdot)$ 是非线性函数, $C_1 := \sum_{i=1}^m E(y_i)^2 = 0$ 和 $C_2 := \sum_{i=1}^m [E(y_i^2) - 1] = 0$ 是两个常规的基本约束; 而 α 和 β 是两个正的加权常数。

由图3所示的分离系统可知, 采用泛函连接网络所需学习的参数比较少, 仅为 $w_{i,j} (i=1,2,\dots,n, j=1,2,\dots,m)$ 。

3 基于差分进化算法的盲分离方法

由于独立性测度式(5)的复杂性, 采用通常的梯度下降方法来寻优是困难的甚至是不可能的, 在此, 我们采用差分进化算法^[9,10]来对目标函数式(5)进行优化。差分进化算法是一种新的基于群体的全局优化方法, 能够处理不可微、非线性和多模态的目标函数。它的控制参数少, 而且容易选取。实验结果表明它有很好的收敛特性, 性能优于其它的进化算法^[9,10]。差分进化算法通过迭代搜寻最优值, 系统初始化为一组随机解。假设在一个 D 维的目标搜索空间中, 有 N 个个体组成一个种群, 其中第 i 个个体表示为一个 D 维的向量 $\mathbf{a}^{(i)} = (a_1^{(i)}, a_2^{(i)}, \dots, a_D^{(i)})$, $i=1,2,\dots,N$, 第 g 代种群表示为 $P(g) = \{\mathbf{a}^{(1)}(g), \mathbf{a}^{(2)}(g), \dots, \mathbf{a}^{(N)}(g)\}$ 。

差分进化算法的变异操作根据下式进行: $\mathbf{v}^{(i)} = \mathbf{a}^{(r_1)} + \mu(\mathbf{a}^{(r_2)} - \mathbf{a}^{(r_3)})$, $i=1,2,\dots,N$ 。其中 $r_1, r_2, r_3 \in \{1,2,\dots,N\}$ 互不相同亦不同于 i , $\mu \in [0,2]$ 是实常数。

差分进化算法的交叉操作结合 $\mathbf{v}^{(i)} = (v_1^{(i)}, v_2^{(i)}, \dots, v_D^{(i)})$ 和 $\mathbf{a}^{(i)} = (a_1^{(i)}, a_2^{(i)}, \dots, a_D^{(i)})$ 产生 $\mathbf{b}^{(i)} = (b_1^{(i)}, b_2^{(i)}, \dots, b_D^{(i)})$, 由下式进行:

$$b_j^{(i)} = \begin{cases} v_j^{(i)}, & (\text{randb}(j) \leq \text{CR}) \text{ or } (j = \text{mbr}(i)) \\ a_j^{(i)}, & (\text{randb}(j) > \text{CR}) \text{ and } (j \neq \text{mbr}(i)) \end{cases}$$

$$i=1,2,\dots,N; j=1,2,\dots,D$$

其中 $\text{randb}(j) \in [0,1]$ 是均匀分布的随机数, $\text{mbr}(i) \in \{1,2,\dots,D\}$ 被随机选取, $\text{CR} \in [0,1]$ 是交叉参数。

差分进化算法的选择操作按下式进行:

$$\begin{cases} \mathbf{a}^{(i)}(g+1) := \mathbf{b}^{(i)}(g), & f(\mathbf{b}^{(i)}(g)) < f(\mathbf{a}^{(i)}(g)) \\ \mathbf{a}^{(i)}(g+1) := \mathbf{a}^{(i)}(g), & f(\mathbf{b}^{(i)}(g)) \geq f(\mathbf{a}^{(i)}(g)) \end{cases}$$

$i=1,2,\dots,N$ 。其中 $f(\cdot)$ 是个体的适应度函数。

迭代中止条件根据具体问题一般选为最大迭代次数或(和)种群个体迄今为止搜索到的最优位置满足预定最小适应阈值。对于上述非线性混叠信号盲分离问题, 我们把泛函连接网络的权值 \mathbf{W} 看作种群个体, 选用目标函数 $J(\mathbf{W})$ 值作为种群个体的适应度值。由此可得到基于差分进化算法的非线性混叠信号盲分离算法如下:

(1) 选择泛函连接网络的基函数 $\varphi(\cdot)$, 确定 α, β, μ , 交叉参数 CR 和种群中个体的数目 N 。

(2) 初始化种群, 即泛函连接网络的权值 $\mathbf{W}^{(k)} = (w_{i,j}^{(k)})$, $i=1,2,\dots,n, j=1,2,\dots,m; k=1,2,\dots,N$ 。

(3) 按下式进行变异操作, 产生个体 $\mathbf{v}^{(k)} = (v_{i,j}^{(k)}), i=1,2,\dots,n, j=1,2,\dots,m; k=1,2,\dots,N$: $\mathbf{v}^{(k)} = \mathbf{W}^{(r_1)} + \mu(\mathbf{W}^{(r_2)} - \mathbf{W}^{(r_3)})$, $k=1,2,\dots,N$ 。其中 $r_1, r_2, r_3 \in \{1,2,\dots,N\}$ 互不相同亦不同于 k 。

(4) 按下式进行交叉操作, 产生个体 $\mathbf{b}^{(k)} = (b_{i,j}^{(k)}), i=1,2,\dots,n, j=1,2,\dots,m; k=1,2,\dots,N$ 。

$$b_{i,j}^{(k)} = \begin{cases} v_{i,j}^{(k)}, & (\text{randb}(i,j) \leq \text{CR}) \text{ or } ((i,j) = \text{mbr}(k)) \\ w_{i,j}^{(k)}, & (\text{randb}(i,j) > \text{CR}) \text{ and } ((i,j) \neq \text{mbr}(k)) \end{cases}$$

$$i=1,2,\dots,n; j=1,2,\dots,m, k=1,2,\dots,N$$

$\text{randb}(i,j) \in [0,1]$ 是均匀分布的随机数, $\text{mbr}(k) \in \{1,2,\dots,n\} \times \{1,2,\dots,m\}$ 被随机选取。

(5) 计算个体 $\mathbf{W}^{(k)}, \mathbf{b}^{(k)} (k=1,2,\dots,N)$ 的适应度值, 按下式进行选择操作:

$$\begin{cases} \mathbf{W}^{(k)}(g+1) := \mathbf{b}^{(k)}(g), & f(\mathbf{b}^{(k)}(g)) < f(\mathbf{W}^{(k)}(g)) \\ \mathbf{W}^{(k)}(g+1) := \mathbf{W}^{(k)}(g), & f(\mathbf{b}^{(k)}(g)) \geq f(\mathbf{W}^{(k)}(g)) \end{cases}$$

$$k=1,2,\dots,N$$

(6) 不满足迭代中止条件, 重复(3)–(5), 否则转向(7)。

(7) 中止迭代操作, 输出适应度值(即目标函数值)最好的个体 \mathbf{W} , 由式(4)计算出分离信号。

4 算法仿真

对本文给出的后非线性混叠信号盲分离算法及 Taleb^[3], Tan^[4,5] 和 Rojas^[6] 给出的分离算法, 我们进行了计算机仿真比较, 仿真用 Matlab6.5 在 P4 计算机上完成。在仿真中, 对于目标函数式(5)中的非线性函数 $h_i(\cdot), i=1,\dots,n$, 采用 $h_i(y_i) = \alpha_i(\kappa_3^i, \kappa_4^i)y_i^2 + \beta_i(\kappa_3^i, \kappa_4^i)y_i^3$, 其中 $\kappa_3^i = E[y_i^3]$, $\kappa_4^i = E[y_i^4] - 3$, 而 $\alpha_i(\kappa_3^i, \kappa_4^i) = -\frac{1}{2}\kappa_3^i + \frac{9}{4}\kappa_3^i\kappa_4^i$, $\beta_i(\kappa_3^i, \kappa_4^i) = -\frac{1}{6}\kappa_4^i + \frac{3}{2}(\kappa_3^i)^2 + \frac{3}{4}(\kappa_4^i)^2$ 。差分进化算法中种群的数目 $N=30$, 泛函连接网络的权值 $\mathbf{W}^{(k)}, k=1,2,\dots,N$ 随机产生, $\mu=0.5$, $\text{CR}=0.2$ 。为评价算法的收敛性能, 进化次数设为 200, 独立运行 50 次所得平均值作为

算法性能的衡量指标。下面是仿真实例。

仿真实例 1 4 个源信号如图 4 所示。4×4 非奇异非线性混叠矩阵 $A=(a_{i,j})$ 被随机产生; 非线性混叠函数 $f_1(x)=0.1x+0.1x^3$, $f_2(x)=0.3x+\tanh(3x)$, $f_3(x)=\tanh(2x)$, $f_4(x)=x^3$ 。图 5 是算法的分离结果, 表 1 是源信号和分离信号的相关系数。由表 1 和图 5 可知本文算法的分离效果是比较好的。




图 4 4 个源信号

Fig.4 Four source signals




图 5 本文算法分离信号

Fig.5 Separated signals of proposed algorithm

表 1 源信号和分离信号的相关系数

Table 1 Correlation coefficients between each Source signal and every signal separated

源信号	分离信号			
	y_1	y_2	y_3	y_4
s_1	0.94	-0.06	0.08	-0.11
s_2	0.05	0.92	0.03	-0.07
s_3	-0.04	0.12	0.93	0.06
s_4	0.08	-0.06	0.05	0.90

仿真实例 2 与 Taleb^[3]算法的比较, 两个源信号如图 6 第 1 排所示。2×2 非奇异非线性混叠矩阵 $A=[-2.29\ 0.49; 1.84\ 0.41]$; 非线性混叠函数 $f_1(x)=0.1(x+x^3)$, $f_2(x)=0.3x+\tanh(3x)$ 。图 6 第 2 排是 Taleb^[3]算法的分离结果, 图 6 第 3 排是本文算法的分离结果, 表 2 是源信号和分离信号的相关系数。由表 2 和图 6 可知本文算法的分离效果比 Taleb^[3]算法的分离结果略好。




图 6 源信号, Taleb^[3]的算法和本文算法分离结果

Fig.6 Source signals, Separation results of Taleb^[3]algorithm and proposed algorithm

表 2 源信号和分离信号的相关系数

Table 2 Correlation coefficients between each source signal and every signal separated

源信号	Taleb 算法分离信号		本文算法分离信号	
	y_1	y_2	y_1	y_2
s_1	0.2305	0.9688	0.9757	0.1128
s_2	0.9716	0.2171	0.1088	0.9859

仿真实例 3 和 Tan^[4]算法的比较, 两个源信号如图 7 第 1 排所示。2×2 非奇异非线性混叠矩阵 $A=[0.72\ 0.18; -0.18\ 0.53]$; 非线性混叠函数 $f_1(x)=0.1x+0.1x^3$, $f_2(x)=0.5x+\tanh(0.3x)$ 。图 7 第 2 排是 Tan^[4]算法的分离结果, 图 7 第 3 排是本文算法的分离结果, 表 3 是源信号和分离信号的相关系数。由表 3 和图 7 可知本文算法和 Tan^[4]算法的分离效果差不多。




图 7 源信号, Tan^[4]算法和本文算法分离结果

Fig.7 Source signals, Separation results of Tan^[4]algorithm and proposed algorithm

表 3 源信号和分离信号的相关系数

Table 3 Correlation coefficients between each source signal and every signal separated

源信号	Tan ^[4] 算法分离信号		本文算法分离信号	
	y_1	y_2	y_1	y_2
s_1	0.1501	0.9892	0.9816	0.1915
s_2	0.9812	0.1285	0.1382	0.9821

仿真实例 4 和 Tan^[5]算法的比较, 两个语音信号如图 8 第 1 排所示。2×2 非奇异非线性混叠矩阵 $A=(a_{i,j})$ 被随机产生; 非线性混叠函数 $f_1(x)$ 、 $f_2(x)$ 选择单调非线性变换函数。图 8 第 2 排是 Tan^[5]算法的分离结果, 图 8 第 3 排是本文算法的分离结果, 表 4 是源信号和分离信号的相关系数。由表 4 和图 8 可知本文算法比 Tan^[5]算法的分离效果好。




图 8 源信号, Tan^[5]算法和本文算法分离结果

Fig.8 Source signals, Separation results of Tan^[5]algorithm and proposed algorithm

表4 源信号和分离信号的相关系数
Table 4 Correlation coefficients between each source signal and every signal separated

源信号	Tan ^[5] 算法分离信号		本文算法分离信号	
	y_1	y_2	y_1	y_2
s_1	0.9705	0.2073	0.0852	0.9872
s_2	0.2124	0.9712	0.9845	0.1309

仿真实例5和Rojas^[6]的算法比较,两个源信号如图9第1排所示。 2×2 非奇异非线性混叠矩阵 A 随机产生;非线性混叠函数 $f_1(x) = \tanh(x)$, $f_2(x) = \tanh(0.8x)$ 。图9第2排是Rojas^[6]算法的分离结果,图9第3排是本文算法的分离结果。表5是源信号和分离信号的相关系数。由表5和图9可知本文算法的分离效果是比较好的。




图9 源信号, Rojas^[6]算法和本文算法分离结果

Fig.9 Source signals, Separation results of Rojas^[6] algorithm and proposed algorithm

表5 源信号和分离信号的相关系数
Table 5 Correlation coefficients between each source signal and every signal separated

源信号	Rojas ^[6] 算法分离信号		本文算法分离信号	
	y_1	y_2	y_1	y_2
s_1	0.9681	0.2469	0.1419	0.9851
s_2	0.1635	0.9706	0.9874	0.1519

5 结束语

本文对后非线性混叠信号盲分离问题进行了讨论,把后非线性混叠信号盲分离的分离系统用泛函连接网络来建模,对分离系统的输出应用高阶统计量独立性准则作为测度,然后利用差分进化算法对泛函连接网络的权值进行学习,从而获得了一种后非线性混叠信号盲分离算法。这种算法结合了泛函连接网络学习参数少、非线性逼近能力强和差分进化算法控制参数少、易于选择、全局寻优能力强的特性;具有比较好的分离性能。

与 Taleb^[3], Tan^[4,5]和 Rojas^[6]的后非线性混叠信号盲分离方法进行了仿真比较,结果显示了这种方法是可行和有效的。

参考文献

- [1] Hyvarinen A, Pajunen P. Nonlinear independent component analysis: Existence and uniqueness results. *Neural Networks*, 1999, 12(3): 429–439.
- [2] Taleb A, Jutten C S, Xichocki A. Information back-propagation for blind separation of sources from non-linear mixtures: An entropy-based algorithm. in Proc of ICASSP, Washinton, 1998: 2089–2092.
- [3] Taleb A, Jutten C. Source separation in post-nonlinear mixtures. *IEEE Trans. on Signal Processing*, 1999, 47(10): 2807–2820.
- [4] Tan Y, Wang J. Nonlinear blind source separation using an RBF network Model. ISCAS2000-IEEE International Symposium on Circuits and Systems, Geneva, Switzerland, May 28-31, 2000: 634–637.
- [5] Tan Y, Wang J. Nonlinear blind source separation using Higher order statistical and a genetic algorithm. *IEEE Trans. on Evolutionary Computation*, 2001, 5(6): 600–612.
- [6] Rojas F, Puntonet C G, Rojas I, Ortega J, Prieto A. Nonlinear blind source separation using genetic algorithm. ICA2001, San Diego, USA, 2001: 400–405.
- [7] Pao Y H, et al.. Neural-net computing and intelligent control systems. *Int J. Control*, 1992, 56 (2): 263–289.
- [8] Lee T T, et al.. The Chebyshev polynomials based unified model neural networks for function approximation. *IEEE Trans. on SMC-28*, 1998: 925–935.
- [9] Storn R, Price K. Differential evolution—a simple and efficient adaptive scheme for global optimization over continuous spaces. *Journal of Global Optimization*, 1997, 11(2): 341–359.
- [10] Price K. An introduction to differential evolution. In D. Corne, M. Dorigo, and F. Glover, editors, *New Ideas in Optimization*, London, UK, McGraw-Hill, 1999: 79–108.

高 鹰: 男, 1963年生, 博士后, 教授, 硕士生导师, 主要研究领域为自适应信号处理、盲信号处理、人工神经网络和进化计算等。已发表论文30余篇。

谢胜利: 男, 1957年生, 教授, 博士生导师, 主要研究领域为盲信号处理、非线性系统学习控制等。