

非线性混合模式的语音盲分离算法

胡亚龙[†] 李双田

(中国科学院声学研究所 北京 100080)

摘要 本文针对 FIR 非线性混合模型, 基于最大熵算法, 提出了一种以高斯混合模式概率密度函数估计替代传统对数化概率密度估计的盲分离算法, 以偶函数为非线性激活函数, 采用最大期望 (EM) 迭代算法推导了分离算法的权向量迭代公式, 通过模拟仿真实验结果与传统的最大熵和高阶累积量方法比较, 新算法提高了收敛速度, 并有效地完成了非线性语音分离任务, 抑制了干扰语音信号的影响, 提高了输出信噪比。

关键词 盲分离, 非线性, 高斯混合模式, 最大期望

Blind source separation for nonlinear speech mixture

HU Ya-Long LI Shuang-Tian

(Institute of Acoustics, Chinese Academy of Sciences, Beijing 100080)

Abstract Based on the FIR nonlinear mixture model and the Maximizing Entropy principle, another speech separation batch processing algorithm is proposed by using the Gaussian Mixture Model probability density function (PDF) estimation in stead of the logarithm PDF estimation. On applying even nonlinear function, an iterative algorithm based on Expectation-Maximization is provided. Computer simulation shows that this algorithm can separate source effectively. Based on the comparison of the different algorithms, It can be concluded that the proposed separation algorithms has good convergence and is robust. The outputs' signal-noise-ratios are improved.

Key words Blind separation, Nonlinear, Gaussian Mixture Model, Expectation-Maximization

1 引言

盲源分离^[1] (Blind Source Separation, BSS) 的研究从 20 世纪 90 年代初发展以来, 已成为信号处理领域一个热点问题。盲源分离

是指在不知源信号和传输信道参数的情况下, 根据输入源信号的统计特性, 仅由观测信号恢复出源信号的各个独立成分的过程, 此过程又称为独立分量分析^[2] (Independent Component Analysis, ICA)。

2004-11-08 收稿; 2005-11-29 定稿

作者简介: 胡亚龙 (1976-), 男, 山东青岛人, 博士研究生, 主要从事语音信号处理研究。

李双田 (1964-), 男, 研究员, 博士, 博士生导师。

[†] 通讯联系人 Email: huyalong@qcn.com.cn

目前大多数盲信号分离算法是基于输入独立信号源的线性、瞬时混合模式的, 其数学模型:

$$X = HS \quad (1)$$

其中 $S = [s_1, s_2, \dots, s_N]^T$ 为 M 个互相独立的信号源, X 为系统的 N 个观测输入信号, H 为一个阶数为 $M \times N$ 的线性变换矩阵, 其中 $N \geq M$, 一般选择 $N = M$ 。

盲分离问题就是求一分离矩阵 W , 通过该矩阵仅从观测信号 X 恢复出源信号 S , 设 Y 为源信号的估计矢量, 则分离系统的数学模型表示如下:

$$Y = WX \quad (2)$$

其中 $Y = [y_1, y_2, \dots, y_N]^T$ 为系统分离输出信号向量。

真实环境中, 混合信号是源及其滤波和延迟的混迭信号的线性组合, 通常称为卷积混迭。无噪声卷积混迭信号的数学描述如下:

$$X(t) = HS(t) = \sum_{k=-\infty}^{+\infty} H(k)S(t-k) \quad (3)$$

针对这种情况, 盲反卷积方法就是通过观测信号 $X(t)$, 估计通道冲激响应 $H(k)$ 进而恢复源信号, 这样得到如下分离系统, 也称作盲均衡系统:

$$Y(t) = \sum_{k=-\infty}^{+\infty} W(k)X(t-k) \quad (4)$$

常用的盲分离和盲反卷积的方法有最大熵算法^[3] (ME), 独立分量分析 (ICA) 法以及基于高阶累积量^[4] 的方法。ME 方法首先假定源信号的密度函数, 当实际信号的密度函数逼近假定形式, 就能获得分离; ICA 方法约束了源信号的密度函数等于观测的边缘密度函数; 基于高阶累积量的方法则是把源信号密度函数按泰勒级数展开为标准的高斯密度函数和一系列简单的多项式的乘积。

除了上述线性瞬时混合和卷积混迭情况

外, 实际系统中还存在更复杂的非线性混迭信号, 现在还只是对几类特殊模型进行研究, 对一般的非线性混迭信号的可分离性以及分离的充要条件需要进一步研究。由于非线性混迭盲分离问题的复杂性, 现在的研究算法都是在线性混迭基础上加以拓展, 使之适用非线性混迭的情况。

较早进行非线性混迭信号的盲分离研究的是 Burel^[5], 他用一个两层感知器和基于误差后向传输思想的无监督训练算法通过梯度下降算法优化统计独立的测度函数, 得到一种非线性盲分离算法。

T.W.Lee 等^[6] 采用的非线性混合和解混合模型如式 (5) 表示, 他认为系统的混合输入信号为独立源信号经线性、瞬时混合后, 再经过一个非线性传输函数形成的。

$$\begin{cases} X = f(HS) \\ Y = Wg(X) \end{cases} \quad (5)$$

相应的解混合模型是先估计一个逆传输函数, 然后对混合信号进行逆处理后, 再经线性解混合矩阵变换而最终完成非线性盲信号分离。这种方法由于难以获得逆传输函数 $g(x)$ 的准确估计, 故不能较好地完成相应的语音分离任务。

H.H.Yang 和 Amari^[7] 利用类似于多层感知器 MLP 的网络结构, 通过最大熵和最小互信息作为测度独立的代价函数, 提出了信息后向传输的训练方法。只有合理选择非线性函数时该算法才可以分离出一些特定非线性混迭的源信号。

在 T.W.Lee 模型的基础上, J.Lin 等^[8] 采取一种更为通用的非线性瞬时混合和解混合模型, 如下式表示:

$$\begin{cases} X = F(S) \\ Y = G(X) \end{cases} \quad (6)$$

其中 F 是未知的非线性混合函数矩阵, G 是解混合非线性变换函数矩阵。如果 F, G 仅为线性

变换矩阵时, 式 (6) 就简化为线性瞬时混合模型。J.Lin 等采用自组织映射 (Self-organization Map-SOM) 来分离式 (6) 的非线性混合模型离散数字源信号, 但当其采用语音源信号时则会增加网络的复杂性并且算法性能会明显下降。P.Pajunen^[9] 同样采用 SOM 网络来实现非线性瞬时混合亚高斯信号的盲信号分离算法, 其算法复杂度同样随 SOM 网络的维数呈指数增长且在分离连续源时存在严重的插值误差, 并且其算法仅适用于亚高斯信号, 但大多数语音信号是超高斯, 因而此算法有很大的局限性。

在上述算法的基础上, 我们提出的非线性盲分离算法, 以 FIR 神经网络^[10] 逼近非线性传递函数, 与 MLP 神经网络相比, FIR 神经网络增加了层与层之间非线性神经元输出的时延项, 从形式上更接近神经元的工作原理, 并可以用较少的权向量系数完成非线性时间序列的预测任务, 减少了算法复杂度; 该算法与 Lee 模型比较, 避免了求取非线性逆函数, 减少了不准确的估计; 另外, 本算法基于 ME 算法, 引入了高斯混合模式 (Gaussian Mixture Model: GMM)^[11] 来逼近任意信号源的概率密度函数, 比传统的对数化概率密度, 更接近于真实的语音概率密度, 所以获得了更优越的算法性能; 采用偶函数作为非线性激活函数, 以最大期望 (EM) 迭代算法推导分离算法中的权向量迭代公式, 提高了算法收敛速度和稳定性, 此算法可以更好地完成分离任务。

2 本文算法介绍

我们采用基于 FIR 神经网络的非线性模型, 基于传统最大熵 ME 理论, 引入高斯混合模型进行源信号的概率密度估计, 采用一种迭代的最大期望 (EM) 算法^[11], 推导了分离模型的权向量公式。

2.1 算法数学模型

本算法的混合模型^[12] 如下式表示, 就是将干扰语音信号经非线性传递函数 F_{ij} 后的输

出与本通道的所需语音源信号混合

$$\begin{cases} x_1(t) = s_1(t) + F_{21}(s_2(t)) \\ x_2(t) = s_2(t) + F_{12}(s_1(t)) \end{cases} \quad (7)$$

采用单输入单输出的两层 FIR 神经网络来逼近相应的非线性传递函数 F_{ij} , 即根据信号的前期输入数据来预测估计当前时刻的输入, 那么系统的语音分离输出信号由下式表示:

$$\begin{cases} y_1(t) = x_1(t) - FIR_2(y_2(t-1)) \\ y_2(t) = x_2(t) - FIR_1(y_1(t-1)) \end{cases} \quad (8)$$

其中 $\begin{cases} FIR_i(y_i(t-1)) = \sum C^T A \\ a_i = f(W^T Y + bias_i) \end{cases}$, f 是 FIR 神经元的非线性激活函数, W 为第一层 FIR 网络权向量, C 是第二层网络权向量, A 是 t 时刻第一层神经元的输出矢量, $bias$ 是偏置向量。

当 FIR1 和 FIR2 预测器能够有效的估计出 7 式中对应的非线性传递函数 F_{ij} 时, 输出 Y 就等于 S , 混合信号也就分离开来。

2.2 基于最大熵 (ME) 的分离算法

ME 算法的主要思想是, 将系统的分离输出信号 Y 经过一个非线性神经元处理, 利用非线性激活函数 $G(y)$, 将系统输出变换为 $Z = G(y)$, 假设输出信号完成分离任务时, 语音分离系统的输出信号应互相独立, 则神经元输出 Z 的各个成分相互独立, 此时 Z 的互熵最大。根据梯度下降算法, 可以推导出相应的盲分离算法迭代核函数。

传统的 ME 算法设定了非线性激活函数为 sigmoid 函数, 这相当于预先限定了源信号的分布, 只适用于源信号为超高斯的, 鉴于此, Te-Won Lee 等人对 ME 方法进行了补充和完善, 那就是以合适的函数来估计传递函数, 也就是对源信号的概率密度作更好的估计。

根据 ME 算法以及最大似然法^[14] 的基本理论, 直接利用系统输出分离语音信号概率密度估计函数估计 $p(y_i)$, 依据梯度下降算法推导, 得到 FIR 神经网络的非线性语音分离算法

的 2 层 FIR 连接权向量 W , C 以及偏置向量的迭代公式如下表示:

$$\Delta W \propto \frac{\partial \sum_i \ln[p(y_i(t))]}{\partial W} = \sum_i \left(\frac{1}{p(y_i(t))} \cdot \frac{\partial p(y_i(t))}{\partial y_i(t)} \cdot \frac{\partial y_i(t)}{\partial W} \right) \quad (9)$$

$$\Delta C \propto \frac{\partial \sum_i \ln[p(y_i(t))]}{\partial C} = \sum_i \left(\frac{1}{p(y_i(t))} \cdot \frac{\partial p(y_i(t))}{\partial y_i(t)} \cdot \frac{\partial y_i(t)}{\partial C} \right) \quad (10)$$

$$\Delta bias \propto \frac{\partial \sum_i \ln[p(y_i(t))]}{\partial bias} = \sum_i \left(\frac{1}{p(y_i(t))} \cdot \frac{\partial p(y_i(t))}{\partial y_i(t)} \cdot \frac{\partial y_i(t)}{\partial bias} \right) \quad (11)$$

由上边三式可以定义梯度矢量函数

$$\varphi(y_i) = -\frac{1}{p(y_i(t))} \cdot \frac{\partial p(y_i(t))}{\partial y_i(t)} \quad (12)$$

2.3 高斯混合概率密度估计

在盲信号分离中, 常用的方法都是假设源信号的密度函数已知或者由某一类函数来逼近, 本文采用了高斯混合模式^[11] 概率密度函数估计输出语音信号边缘概率密度函数, 来推导相应的语音分离算法中的权向量迭代公式, 这是由于高斯混合模式可以用来逼近任意概率分布函数, 并且 D.A.Reynolds 利用高斯混合模式概率密度函数估计不同语音信号的特征向量的概率密度函数, 用于说话人识别, 取得较好的试验效果。

高斯混合模型是通过概率来描述不同的高斯成分在源信号中所起的作用, 在非线性语音分离任务中, 系统分离输出信号 $y_j(t)$ 在某一时刻可以看成是一个随机变量, 则相应的高斯混合模式概率密度函数如下表示:

$$P(y_j|\lambda) = \sum_{i=1}^M P_i b_i(y_j) \\ \lambda = \{m^M, \sigma^M, p^M\} \quad (13)$$

其中 P_i 是混合加权系数, $b_i(y_j)$, $i = 1, 2, \dots, M$ 表示 M 个高斯概率密度函数, 服从均值 m_i 和

方差 σ_i^2 的高斯分布

$$b_i(y_j) = \frac{1}{(2\pi)^{1/2} \sigma_i} \exp \left(-\frac{(y_j - m_i)^2}{2\sigma_i^2} \right) \quad (14)$$

若 n 个源信号是相互独立的, 则输出语音分离信号 $y_j(t)$ 的联合概率密度函数表示为

$$P(y_j|\lambda) = \prod_{i=1}^n p(y_i|\lambda) \prod_{i=1}^n \sum_{i=1}^M P_i b_i(y_j) \quad (15)$$

为了得到更准确的输出信号的概率密度估计, 因此, 本文以高斯概率密度估计来代替传统最大熵算法的对数化概率密度估计, 采用收敛较快的 EM 迭代算法, 推导出了新的盲分离算法迭代公式。

2.4 基于高斯概率密度估计的 FIR 非线性混合盲分离算法

基于 ME 和最大似然算法的基本理论, 当采用高斯混合概率密度函数估计时, (12) 式的非线性语音分离算法的梯度矢量函数如下式表示

$$\varphi(y) = \left\{ \sum_{i=1}^M - \left[\frac{(y - m_i)}{\sigma_i^2} \frac{p_i}{\sqrt{2\pi}\sigma_i} \cdot \exp \left(-\frac{(y - m_i)^2}{2\sigma_i^2} \right) \right] \right\} \\ \cdot \left\{ \sum_{i=1}^M \frac{p_i}{\sqrt{2\pi}\sigma_i} \exp \left(-\frac{(y - m_i)^2}{2\sigma_i^2} \right) \right\}^{-1} \quad (16)$$

本文采用 Dempster^[15] 以及 Neal & Hinton^[13] 提出的期望最大化算法 (EM 算法) 来求取 (16) 式中的参数 $\lambda = \{m^M, \sigma^M, p^M\}$ 。在给定源信号的 N 个观测数据后, EM 算法就是以最大化这些数据所构成的对数似然函数 (如式 17), 获得参数的迭代算法。

$$L(\lambda) = \ln \prod_{t=1}^N p(y_i|\lambda) \\ = \sum_{t=1}^N \sum_{i=1}^n \ln \left(\sum_{i=1}^M P_i b_i(y_j) \right) \quad (17)$$

EM 算法一般分为 2 步, E 步: 根据初始值或前一次迭代值来计算似然函数的期望; M 步: 最大化这个似然函数来获得新的参数值, 不断重复这两个步骤直到收敛。

高斯混合模型参数的 EM 算法标准迭代公式如下表示^[16]

$$\begin{aligned} p_i^{k+1} &= \frac{\sum_{t=1}^N h_i^k(t)}{N} \\ m_i^{k+1} &= \frac{\sum_{t=1}^N y_i(t) h_i^k(t)}{\sum_{t=1}^N h_i^k(t)} \\ \sigma_i^{2k+1} &= \frac{\sum_{t=1}^N h_i^k(t) * (y_i(t) - m_i^k)^2}{\sum_{t=1}^N h_i^k(t)} \end{aligned} \quad (18)$$

其中,

$$h_i^k(t) = \frac{p_i^k P(y_j(t) | m_i^k, \sigma_i^k)}{\sum_{i=1}^M p_i^k P(y_j(t) | m_i^k, \sigma_i^k)}$$

为后验概率密度估计, k 表示第 k 次迭代。

EM 迭代完成之后, 就得到了参数 λ , 代入 (16) 式, 得到梯度矢量函数。

不失一般性, 针对两输入非线性混合模型, 将梯度矢量函数代入 (9)~(11) 式, 结合 (8) 式, 可以推导出权向量 C 的迭代公式如下:

$$\begin{cases} \Delta C_1 \propto \eta \cdot \varphi(y_2(t)) \cdot A_1 \\ \Delta C_2 \propto \eta \cdot \varphi(y_1(t)) \cdot A_2 \end{cases} \quad (19)$$

A 是 t 时刻隐层神经元的输出组成矢量

$$\{a_i = f(W^T Y + bias_i)\}$$

同样的方法推导出隐层神经元的偏置向量 $bias$ 和权向量 W 的迭代公式

$$\begin{cases} \Delta bias_1 \propto \eta \cdot \varphi(y_2(t)) \cdot C_1^T f'(temp_1) \\ \Delta bias_2 \propto \eta \cdot \varphi(y_1(t)) \cdot C_2^T f'(temp_2) \end{cases} \quad (20)$$

$$\begin{cases} \Delta W_1 \propto \eta \cdot \varphi(y_2(t)) \cdot C_1^T f'(temp_1) \cdot Y_1 \\ \Delta W_2 \propto \eta \cdot \varphi(y_1(t)) \cdot C_2^T f'(temp_2) \cdot Y_2 \end{cases} \quad (21)$$

其中 $f'(*)$ 是 FIR 神经元中非线性激活函数 $f(*)$ 的导函数, η 称为步长或者学习速度,

$temp$ 是算法迭代过程的临时矢量, 也就是隐层 FIR 神经元的输入向量

$$temp_i = W_i Y_i^T + bias_i \quad (22)$$

非线性激活函数 f 的选择, 一般都选用 $\tanh(*)$ 或者 sigmoid 函数, 周毅^[16] 研究了非线性函数对收敛特性的影响, 因而新算法中的非线性激活函数选择为偶函数, 使得算法具有更好的收敛性。

综上所述, 引入高斯混合概率密度估计的 FIR 非线性盲信号语音分离算法概括如下

(1) 求取梯度矢量: 采用 EM 算法迭代, 对混合语音信号 $x_i(t)$ 的高斯混合概率密度函数的参数 λ 作出估计, 作为分离语音信号 $y_i(t)$ 高斯混合概率密度函数的初始值, 代入 (18) 式, 得到梯度矢量

(2) 初始化: 选取 FIR 神经网络中各层神经元的非线性激活函数 $f(y)$, 并且设置相应 FIR 连接的横向滤波器结构的阶数以及隐层 FIR 神经元的个数, 初始化权向量参数 $W, C, bias$ 和步长因子 η

(3) 由混合语音信号 $x_i(t)$, 利用式 (8) 迭代计算系统语音分离输出 $y_i(t)$, 利用式 (19)~(22) 进行 FIR 神经网络中权向量 W 的迭代, 并计算梯度矢量的方差, 调整步长因子 η 。

(4) 对分离信号序列 $y_i(t)$, 利用 EM 算法, 估计新的分离输出信号 $y_i(t)$ 的高斯混合模式概率密度函数参数向量

(5) 利用式 (25), 系统输出信号的均方误差, 判断系统是否收敛, 若尚未收敛, 则从步骤 3 开始。

3 计算机仿真结果

为了验证此算法的有效性, 采用不同的非线性混合传递函数, 利用基于 FIR 神经网络的高斯混合模式概率密度函数的非线性盲信号分离算法进行求解, 模拟实验结果表明新算法能够较好的完成非线性分离任务, 具有较好的算

法性能。

3.1 实验

实验采用 2 条汉语语音信号作为系统的独立源输入信号, 其中一为男声“院子里的葡萄熟了”, 一为女声“那达慕是草原的传统节日”, 信号采样率为 8kHz, 时长取为 1.5s。

采用式 (23) 的非线性卷积混合模式混合,

$$\begin{cases} x_1(t) = S_1(t) + 0.3 \tanh(S_2(t-1)) \\ \quad + 0.4 \tanh(S_2(t-3)) \\ x_2(t) = S_2(t) + 0.2 \tanh(S_1(t-2)) \\ \quad + 0.6 \tanh(S_1(t-4)) \end{cases} \quad (23)$$

混合语音信噪比如 (24) 式的计算,

$$SNR_i = 10 \log_{10} \frac{\sum_{t=1}^N S_i(t)^2}{\sum_{t=1}^N [S_i(t) - y_i(t)]^2} \text{db} \quad (24)$$

分别有

$$SNR_1 = 2.346\text{db}, SNR_2 = 3.268\text{db}$$

输出均方误差:

$$MSE_i = \frac{1}{N} \sum_{t=1}^N [y_i(t) - s_i(t)]^2 \quad (25)$$

本文针对 FIR 非线性混合模型, 提出的算法参数选择如下: $M = 8, L = 10$, 也就是说用 8 个高斯概率密度函数的混合加权和估计表示分离语音信号的概率密度函数, 每次迭代过程中进行 10 次 EM 算法迭代求取新的高斯混合模式的概率密度函数估计参数向量 λ , 重复迭代 50 次观测信号, 得到的分离信号。

(1) 分离输出信噪比的比较

作为比较, 对上述混合语音, 分别采用传统最大熵算法, 高阶累积量算法和本文基于 FIR 神经网络的非线性语音分离算法进行分离, 根据 (24) 式分别计算三种分离算法得到的分离输出信噪比如表 1 所示。

通过仿真实验对非线性混合语音进行分离, 本文算法与传统 ME 算法和高阶累积量算法相比, 信噪比有较大提高, 从试听效果以及

分离波形来看, 本文算法能够成功分离混合信号。

表 1

分离算法	SNR_1	SNR_2
线性最大熵算法	5.659db	6.323db
高阶累积量	5.254db	6.831db
本文提出算法	10.528db	11.748db




图 1 线性最大熵的分离输出语音




图 2 为本文方法的分离输出语音

(2) 步长因子的选择

由于采用高斯混合概率密度函数估计, 所以步长因子 η 应除以梯度矢量函数的方差, 作用在于归一化步长因子的变化。为了提高算法的收敛性能, 步长因子还乘以一个指数递减因子。因而本算法中调整步长变化为 $\eta = 0.002 \cdot$

0.99ⁿ。

(3) 权向量迭代收敛性的比较

如图 3 所示, 横坐标为迭代次数, 纵坐标为输出信号的均方误差, 虚线为传统最大熵算法, 实线为本文算法, 可以看出, 本文算法有更快的收敛速度, 在迭代 30 次的时候均方误差在 0.03 附近, 趋于平衡。




图 3 输出均方误差-迭代次数曲线

(4) 非线性函数的选取对收敛性的比较

在非线性的选取上, 文献 16 中的作者证明了非线性激活函数为偶函数比奇函数收敛性能好, 因而我们做了如下比较。分别选取如下函数

$$\begin{aligned} f_1(y_i) &= \frac{1}{[1 + \exp(-y_i)]^2} \\ f_2(y_i) &= \tanh(y_i), \\ f_3(y_i) &= \tanh(y_i^2), \end{aligned}$$

重复迭代 50 次, 得到的分离信号, 利用式 25 计算均方误差分别为 $MSE_1 = 0.08$, $MSE_2 = 0.06$, $MSE_3 = 0.03$ 。这说明非线性激活函数选择为偶函数, 具有较好的迭代收敛性。

因而本算法中非线性激活函数选择为

$$f_3(y_i) = \tanh(y_i^2)$$

3.2 结果分析

根据数学理论, 高斯混合密度估计可以估计任意随机信号的概率密度函数。本文用高斯混合模型来逼近任意分布的源信号密度函数, 从实验仿真结果上也得到了验证, 比常用的对数化概率密度估计, 更容易逼近真实环境下的

语音。

同时, 我们对非线性激活函数也做了不同选择, 实验数据表明, 非线性激活函数采用偶函数, 可以保证迭代过程的稳定性和收敛性。

正如 Neal & Hinton^[13] 所证明的, EM 算法每一次迭代都能增加似然度, 因此保证了似然函数的收敛性, 仿真表明, EM 算法收敛很快。

4 结论

本文以 FIR 神经网络逼近非线性混合模型, 基于最大熵和最大似然的基本理论, 采用高斯混合概率密度函数估计输出语音信号的边缘概率密度函数, 来推导该非线性模型的盲分离权向量迭代公式, 有效地完成了分离任务。

现在的非线性混迭信号的盲分离方法研究, 只是在特殊混合模型下的非线性混迭, 采用的是纯数字信号处理的方法, 如何充分利用人耳的听觉感知特性, 对更一般的非线性混迭信号的可分离性以及分离的充要条件需要进一步的研究。

参 考 文 献

- 1 Jutten C, Herault. *Signal Processing*, 1991, 24(1):1~10.
- 2 Comon P. *Signal Processing*, 36(3):287~314.
- 3 Bell A J, Sejnowski T J. *Neural Computation*, 1995, (7):1129~1159.
- 4 Comon P. *IEEE Signal Processing Letters*, 1997, (3):1129~1159.
- 5 Burel G. *Neural Networks*, 1992, 5(6):937~947.
- 6 Lee T W, Bell. *Proceeding of IEEE International Workshop on Neural Networks for Signal Processing*, 1997, (9):406~408.
- 7 Yang H H. *Signal Processing*, 1998, (64):291~300.
- 8 Lin J, Cowan J. *Neural Computation*, 1997, (119):1305~1320.
- 9 Pajunen P, Hyvarinen A, Karhunen J. *Neural Information Processing. Proc. of the International Conference on Neural Information Processing*, 1996, (2):1207~1210.

“多通道数字成像超声探伤设备”项目简介

高波阻介质下面多层低波阻抗介质的界面脱粘检测是长期以来国内外一直没有解决的世界性难题, 称为“二界面问题”。困难主要有两点: 其一、高波阻介质与低波阻介质之间的界面两侧波阻抗相差较大, 前一介质表面上接收到的界面脱粘反射信号相对入射信号而言是经过了 4 次镜面屏蔽作用之后的十分微弱的信号; 其二、声波在高波阻介质内的多次反射强信号淹没了低波阻介质表面反射的信号。对于高低波阻介质界面间脱粘的超声检测, 犹如光学中看到一面镜子后面的物体一样。

李明轩研究员领导的项目组, 经过几十年的艰辛努力, 尤其是从 1992 年至今, 在多项国家自然科学基金项目和科学院创新工程项目的支持下, 逐步形成建立了适用于“二界面”检测的共振匹配理论, 在理论指导下发明了 6 项关键技术, 并获得发明专利权, 通过技术集成研制出全新的检测设备, 实现了多通道、数字

化、智能化、自动扫描、自动识别、实时成像、全方位立体显示等检测功能。该设备改变了原有的探伤观念, 实现了超声检测技术的跨越式发展。通过定型已获得应用。

与该项目有关, 从 1972 年至 2005 年共发表论文 145 篇, 其中核心论文 32 篇, 另获发明专利一项。1980 年至 2002 年 SCI 收录 17 篇 (SCI 他人引用 21 次), EI 收录 11 篇; 2002 年至 2005 年 SCI 收录 4 篇, EI 收录 7 篇, 其中一篇并获第一届中国科协期刊优秀论文奖。

学术评价、鉴定委员会认为这是一项集理论研究、科技发明、设备研制与应用为一体的拥有自主知识产权的重大成果, 具有创新性, 处于国际领先水平。

经 2005 年 12 月 26 日国务院批准, 获 2005 年度国家科技进步二等奖, 2006 年 1 月 9 日在人民大会堂全国科技大会上受奖。

(亮 宇)

10 Back A D, Tsoi A C. *Neural Computation*, 1991, (3):375~385.

11 王惠刚, 梁红, 李志舜. 信号处理, 2002, 4(18):151~154.

12 虞晓, 胡光锐. 上海交大学报. 2000, 34(2):177~180.

13 Neal R M, Hinton G. A new view of the EM algorithm that justifies incremental, sparse, and other

variants. In Jordan M I (editor), *Learning in Graphical Models*, 1998. 355~368.

14 Cardoso J F. *IEEE Signal Processing Letters*, 1997, 4(4):112~114.

15 Dempster A, Laird N, Rubin D. *J. Royal Statistical Society Series B*, 1997, 39:1~38.

16 周毅, 徐柏龄. 声学学报, 2002, 27(3):241~248.