

基于盲分离技术的机械噪声分离法的研究

吴作伦¹, 杨世锡²

(1. 浙江科技学院 科技处, 浙江 杭州 310012; 2. 浙江大学 机械与能源工程学院, 浙江 杭州 310027)

摘要: 基于互信息最小原理, 详细推导了自然梯度法的盲信号处理的计算方法, 并通过一个仿真实例说明运用该方法对噪音分离的可行性, 从而为机械设备的故障诊断和监测提供了一个新的方法。

关键词: 噪声; 盲分离技术; 互信息最小化; 自然梯度法

中图分类号: TN911.7

文献标识码: A

文章编号: 1671-8798(2003)04-0219-05

通过对机械设备噪声的监察和分析, 再根据噪声的声级和频率的变化可以判别其故障的预兆和产生。因此, 机械噪声的测试分析成为故障诊断中的一个重要手段和方法, 从而得到广泛的应用。在用噪声进行故障诊断时, 往往遇到这样的问题, 多台机械设备同时放置在一个空间, 各自发出不同的噪声信号。这些噪声信号瞬时混叠使传感器检测得到的信号是多个噪声源叠加的结果, 这就影响了故障诊断的准确性和可靠性。因此, 研究基于相互干涉环境情况下的噪声源信号分离的故障诊断方法, 具有很重要的意义。

信号盲分离技术(BSS)则可以在假定各源信号相互统计独立的情况下, 从混合信号样本出发, 分离出各个源信号的估计。本文利用该技术把混叠的噪声分离成为互不相关的信号, 从而为某个具体设备的噪声监测与诊断提供了依据。

1 互信息最小化原理

设有 m 个信号源和传感器, 测量信号和源信号之间有如下的基本关系^[1],

$$x(t) = AS(t) + n(t) \quad (1)$$

其中观察信号

$$X(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T, \quad (2)$$

它是 n 个未知源信号 $S(t) = [S_1(t), S_2(t), \dots, S_n(t)]^T$ 的瞬时线性混叠。 $S(t)$ 为源信号矩阵, 其中, $i = 1, 2, \dots, n$ 为 n 个相互独立的随机信号, 混合矩阵 $A = a_{ij}$, 其中 $i = 1, 2, \dots, m; j = 1, 2, \dots, n$ 。

(1) 式中 $n(t)$ 为在源信号上叠加的噪声干扰信号, 由于噪声存在时的盲源分离是困难的, 本文研究时暂不考虑它的影响。

混叠系统模型及分离框图如图 1 所示。

源分离问题就是估计系统 W , 使 $X(t)$ 通过 W 时的输出 $Y(t)$ 为源信号的估计, 即

$$Y(t) = WX(t) = \hat{S}(t) \quad (4)$$

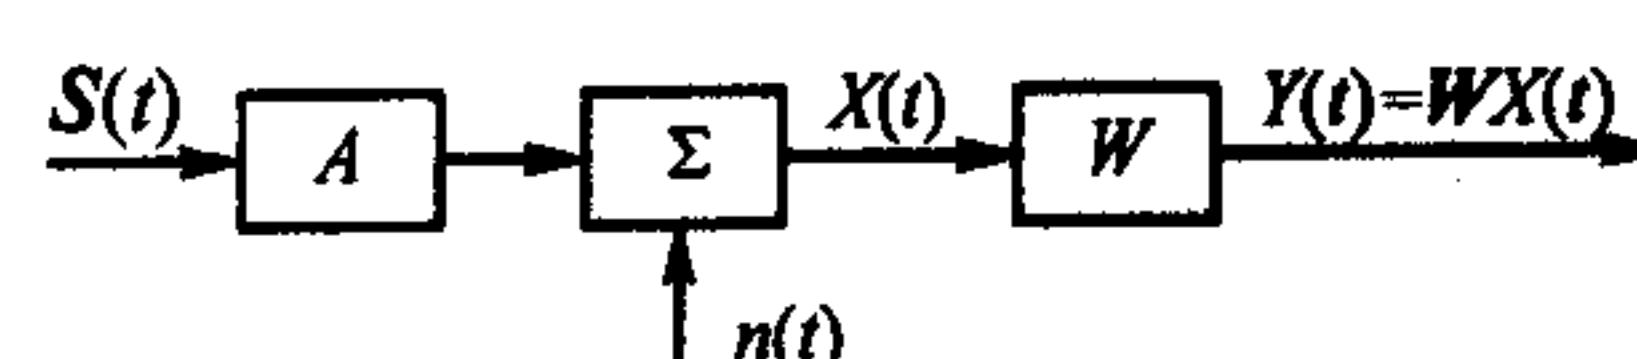


图 1 混叠系统模型及分离框图

收稿日期: 2003-06-25

基金项目: 浙江省自然科学基金资助项目(501004)

作者简介: 吴作伦(1945—), 男, 浙江宁波人, 教授, 主要从事科研管理、机械设计与制造的教学和科研工作。

对于这样一个模型,若没有关于 A 和源信号的先验信息,仅从观察信号 $X(t)$ 恢复出 $S(t)$ 的条件是不够的,须找出一些信号分离的条件,而输出量之间的互信息最小化正是使独立混叠信号得到分离的有效方法。

最小互信息^[2](MMI: minimum mutual information)的基本思想是选择合适的神经网络权矩阵 W ,使输出 y 的各个分量之间的相依性最小化,在理想情况下直至趋向于零,达到分离的目的。由此我们可以用熵来表达信号之间的相依性。

根据联合信息源熵的定义^[3],在二维情况下,

$$H(y, W) = - \sum_{n=1}^N \sum_{j=1}^M P(y_i, W_j) \log P(y_i, W_j) \quad (5)$$

在多维条件下我们得到输出向量 y 的联合熵与边缘熵分别定义为:

$$H(y, W) = - E\{\log P_y(y, W)\} = P_y(y, W) \log P_y(y, W) dy \quad (6)$$

$$H(y_i, W) = - E\{\log P_i(y_i, W)\} = P_i(y_i, W) \log P_i(y_i, W) dy \quad (7)$$

由此可用熵表示互信息:

$$I(W) = H(y, W) + \sum_{n=1}^N H(y_i, W) \quad (8)$$

互信息为非负值,即 $I(W) \geq 0$,Pierrre Common 在 1994 年就证明互信息是独立分量分析的对比函数,即:

$$I(W) = 0 \quad \text{if } W = \Lambda P A^{-1}$$

这说明,当 $Y(t) = WX(t) = \Lambda P A^{-1} X(t)$ 的各分量独立时,互信息 $I(W)$ 等于零。则有

$$Y(t) = WX(t) = \Lambda P S(t) = \hat{S}(t)$$

在这里 Λ 为任一可逆对角阵, P 为任一置换阵。

2 基于自然梯度法的盲信号处理

如何得到合适的 W 是盲分离技术的关键,我们将选择自然梯度法,来加速求得 W 。很明显,输出 y 的概率密度 $P_y(y, W)$ 与输出 x 的概率密度函数 $P_x(x)$ 之间存在以下的函数关系,

$$P_y(y, W) = \frac{P_x(x)}{|J|} \quad (9)$$

(9) 式中, $|J|$ 表示神经网络的 Jacobian 值 J 的绝对值,并且 J 与权矩阵 W 的关系为:

$$J = \det \begin{bmatrix} \frac{\partial y_1}{\partial x_1} & \Lambda & \frac{\partial y_1}{\partial x_n} \\ M & O & M \\ \frac{\partial y_n}{\partial x_1} & \Lambda & \frac{\partial y_n}{\partial x_n} \end{bmatrix} = \det(W) \quad (10)$$

由此,可以根据(6)式和(9)式得到:

$$H(y, W) = - E\{\log P_y(y, W)\} + E\{\log |J|\} = H(x) + E\{\log |J|\} \quad (11)$$

由于 z 是 y 的各个分量的非线性变换,故 z 的联合熵为:

$$\begin{aligned} H(z, W) &= H(y, W) + \sum_{i=1}^N \int P_i(y_i, W) \log g_i(y_i) dy_i = \\ &= H(x) + E\{\log |J|\} + \sum_{i=1}^N E\{\log g_i'(y_i)\} = \\ &= H(x) + E\{\log |\det(W)|\} + \sum_{i=1}^N E\{\log g_i'(y_i)\} \end{aligned} \quad (12)$$

可以证明:

$$\frac{\partial \log |\det(W)|}{\partial W} = W^{-T} \quad (13)$$

(13) 式中, $W^{-T} = (W^{-1})^T$, 并且

$$\frac{\partial \sum_{i=1}^n \log g_i'(y_i)}{\partial W} = -\phi(y)x^T \quad (14)$$

式中,

$$\phi(y) = \left[-\frac{g_1'(y_1)}{g'(y_1)}, \Lambda \frac{g_n''(y_1)}{g''(y_n)} \right] \quad (15)$$

这里 $g_i'(y_i)$ 和 $g_i''(y_i)$ 分别表示 $g_i(y_i)$ 的一阶和二阶导数,联合熵 $H(z, W)$ 相对于权矩阵 W 的梯度可以写作:

$$\frac{\partial H(z, W)}{\partial W} = W^{-T} - E\{\phi(y)x^T\} \quad (16)$$

于是,更新矩阵 W 的梯度算法为:

$$\frac{dW}{dt} = \eta \frac{\partial H(z, W)}{\partial W} = \eta(W^{-T} - E\{\phi(y)x^T\}) \quad (17)$$

梯度算法中的期望项 $E\{\phi(y)x^T\}$ 用瞬时值 $\phi(y)x^T$ 代替,则随机梯度算法变为

$$\frac{dW}{dt} = \eta[W^{-T} - \phi(y)x^T] \quad (18)$$

本式的随机梯度优化方法是收敛速度比较慢。已经证明^[4],如果将一可逆矩阵 G^{-1} 作用于随机梯度算法中,即:

$$\frac{dW}{dt} = \eta G^{-1} \frac{\partial H(z, W)}{\partial W} \quad (19)$$

则算法的收敛性能和数值稳定性都将有明显的提高。Yang 与 Amari 从矩阵 W 的参数空间的 Riemann 结构出发,证明了矩阵 G 的自然选择为:

$$G^{-1} \frac{\partial H(z, W)}{\partial W} = \frac{\partial H(z, W)}{\partial W} W^T W \quad (20)$$

于是,随机梯度算法可以改进为:

$$\frac{dW}{dt} = \eta[W^{-T} - \phi(y)x^T] W^T W = \eta[I - \phi(y)y^T] W \quad (21)$$

相对于一般梯度 $\frac{\partial H(z, W)}{\partial W}$,梯度 $\frac{\partial H(z, W)}{\partial W} W^{-T} W$ 称为自然梯度,这种算法称为自然梯度法。上式所示的学习规则不仅容易计算,而且非常有效。

自然梯度算法的关键是函数 $\phi(y)$ 的计算。在文献[5]中对这一关键函数进行了研究,得到了以下的计算公式:

$$\phi(y) = f(k_3, k_4)oy^2 + g(k_3, k_4)oy^3 \quad (22)$$

式中, $aob = [a_1b_1, K a_nb_n]^T$ 表示向量 a 和 b 的 Hadamard 乘积,并且

$$y^k = [(y_1)^k, \dots, (y_n)^k]^T, k = 2, 3 \quad (23)$$

$$f(k_3, k_4) = [f(k_3^1, k_4^1), f(k_3^n, k_4^n)]^T \quad (24)$$

$$g(k_3, k_4) = [g(k_3^1, k_4^1), \Lambda g(k_3^n, k_4^n)]^T$$

并且函数 $f(x, y)$ 和 $g(x, y)$ 分别为:

$$f(x, y) = -\frac{1}{2}x + \frac{9}{4}xy \quad (25)$$

$$g(x, y) = -\frac{1}{6}y + \frac{3}{2}x^2 + \frac{3}{4}y^2 \quad (26)$$

另外,第 i 个输出分量的三阶累积量 k_3' 和四阶累积量 k_4' 可以自适应估计如下:

$$\frac{dk_3'}{dt} = -\mu[k_3' - (y_i)^3] \quad i = 1, \Lambda n \quad (27)$$

$$\frac{dk_4'}{dt} = -\mu[k_4' - (y_i)^4] \quad i = 1, \Lambda n \quad (28)$$

(28) 式中 μ 是更新输出分量高阶累积量的学习速率。

3 算法流程

根据算法,将盲信号分离实现按以下步骤实行:

步骤 1 将未混合的两单独源信号波形文件打开,取一定数量、等间隔的采样点数(本例为 512 点)分别做出未混合前的两源信号在时域上的波形图。

步骤 2 从源信号和混合矩阵 A 混合后的信号波形图中取相同数量的采样点数,作出混合后的时域波形图。

步骤 3 初始化随机梯度算法的权矩阵 $W(0)$,选择算法的控制参数,如学习速率 η 、梯度算法迭代次数 REC 等。

步骤 4 进入循环。计算瞬时分离结果 $\hat{Y} = W(i)X$ 。

步骤 5 根据 \hat{Y} ,计算 $\phi(\hat{y})$;根据 $\phi(y)$,计算 ΔW 。

步骤 6 更新权值 $W(i+1) = W(i) + \Delta W$ 。

步骤 7 判断循环次数。如果循环次数 $i \leq REC$,转到步骤 4。如果循环次数 $i > REC$,转到步骤 9。

步骤 8 根据循环后保存下来的权值 W ,计算分离结果 $Y = WX$ 。

步骤 9 作盲分离后的时域波形图,以便于和混合前的时域波形图作比较。

步骤 10 程序结束。

4 基于盲分离技术的自然梯度法仿真分析

根据以上算法,应用盲分离的自然梯度法进行仿真实验,由计算机产生一正弦波信号 $s_1 = \sin(20\pi i)$ 与一随机噪声信号 $s_2 = 2.0 \times \text{rand}() / \text{RAND_MAX} - 1.0$,如图 2(a) 和(b) 所示,经和混合矩阵 $A = [0.818\ 293 \quad -0.089\ 083\ 5]$
 $[0.842\ 536 \quad 0.328\ 349]$ 混合所产生的混迭信号的波形如图 2(c) 和(d) 中所示, A 为 $[0,1]$ 之间均匀分布的随机数。

对每路信号取 512 个样本(横坐标),然后选择合适的学习速率 $\eta = 0.001\ 6$,经 6 000 次循环迭代,并对混叠的信号进行分离,得到分离后的输出信号如图 2(e) 和(f) 所示。

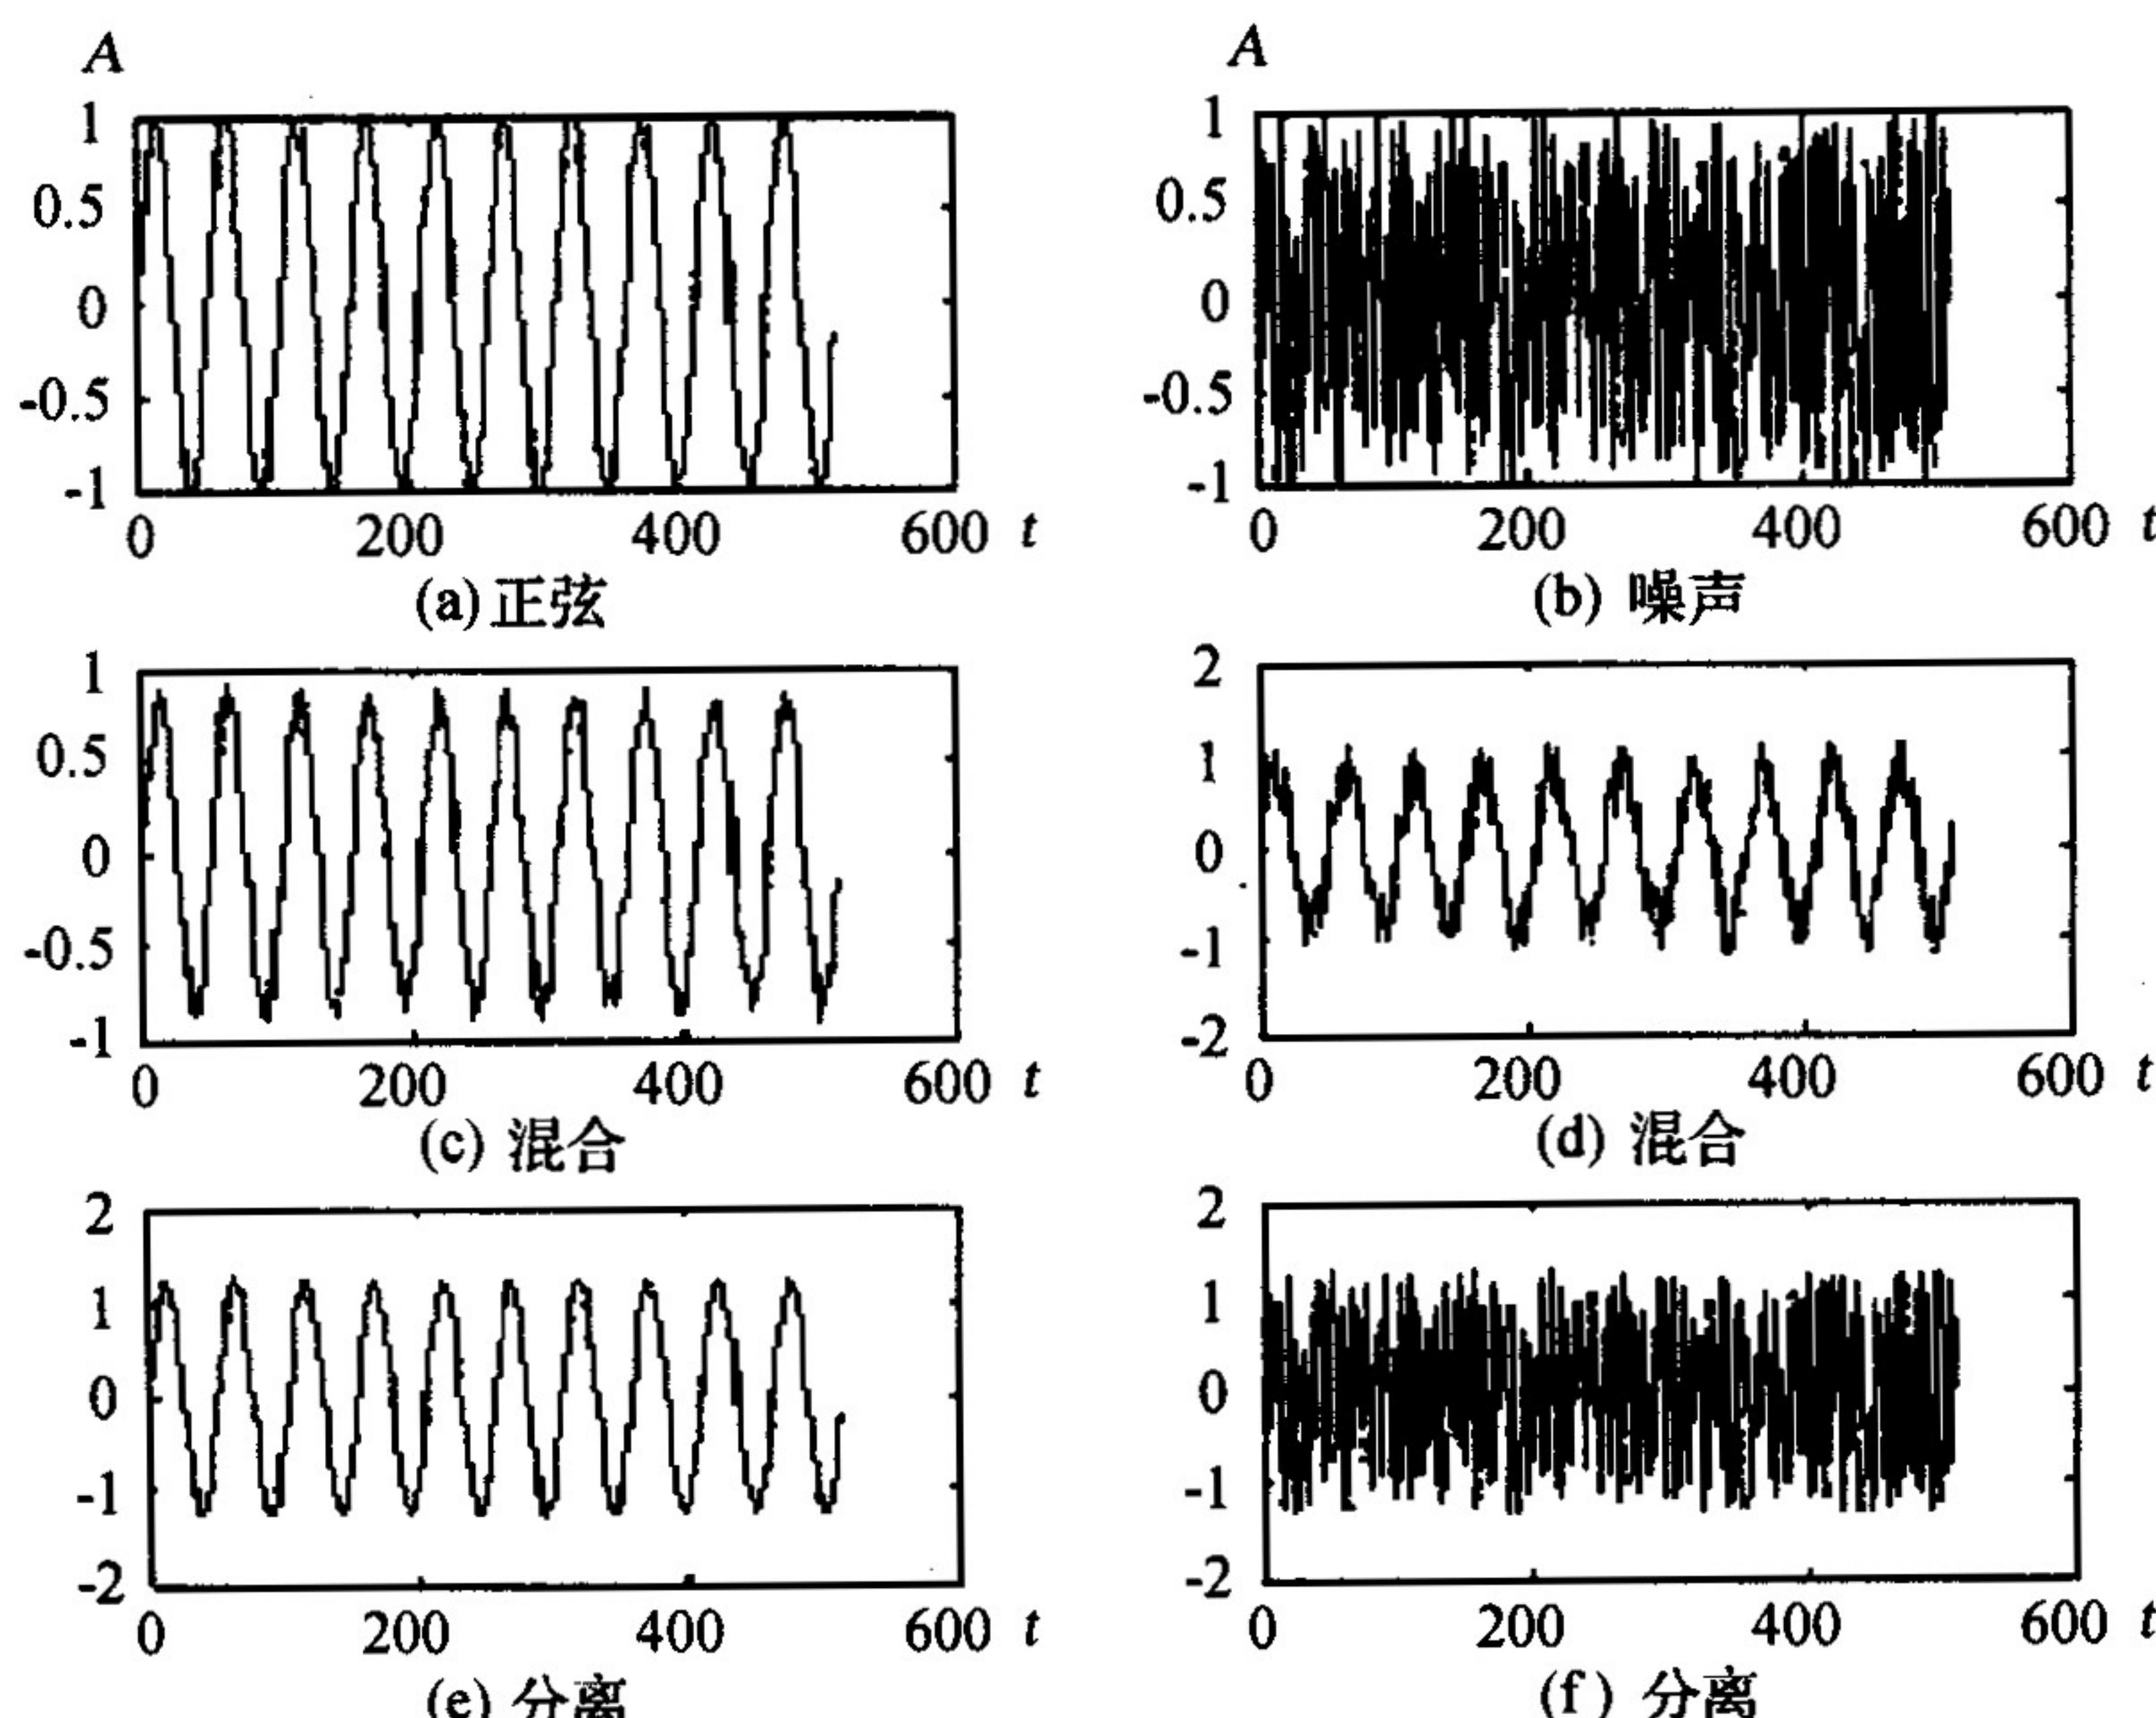


图 2 正弦波与噪声信号盲分离

盲分离算法完成了分离的任务,分离效果比较明显。同时,图形也展现了盲分离算法的又一优点,即可以滤掉背景噪声的影响来提取有用信号,为现场机械噪声的分离提供了依据。用本计算方法对真实混合的声音信号进行分离,并将分离后的声信号波形与源信号波形比较,取得了良好的分离效果。

5 结 论

实验表明,采用盲分离技术分离混叠的噪声成为互不相关的信号,其方法是可行的,用自然梯度法有效地提高运算速度。这为机械设备的噪声监测与诊断提供了一个有效的计算方法。

参考文献:

- [1] 刘 瑙,梅良模,何振亚.一种盲信号分离的信息理论方法[J].山东大学学报,1998,133(4):398 - 399.
- [2] 张贤达.现代信号处理[M].北京:清华大学出版社,1995.
- [3] 卢文祥,杜润生.机械工程测试·信号·信号分析[M].武汉:华中理工大学出版社,1999.
- [4] Howard Hua Yang, Shun-ichi Amari. Adaptive online learning algorithms for blind separation, maximum entropy and minimum mutual information[J]. Neural Computation, 1997, (9):1457 - 1482.
- [5] Howard Hua Yang, Shun-ichi Amari, Andrzej Cichocki. Information-theoretic approach to blind Separation of sources in non-linear mixture[J]. Signal Processing, 1998, (64):291 - 300.

Study on mechanical noise separation based on technique of blind source

WU Zuo-lun¹, YANG Shi-xi²

(1. Section of Science and Technology, Zhejiang University of Science and Technology, Hangzhou 310012, China;

2. College of Mechanical and Energy Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: Based on the principle of the minimum mutual information (MMI), calculation method of blind source separation (BSS) on the natural gradient was deduced in this paper. A simulation example proves the feasibility of this method for noise separation. A new Method for monitoring and diagnosis of mechanical equipment is provided.

Key words: noise; technique of blind source separation; minimum mutual information; natural gradient method

·科技简讯·

含氟医药中间体——3,5-双(三氟甲基)苯甲酰氯

3,5-双(三氟甲基)苯甲酰氯是在医药、农药及各种功能材料等方面有着广泛用途和良好前景的重要有机合成中间体。3,5-双(三氟甲基)用于合成以3,5-双(三氟甲基)苯甲酰基为结构特征的神经激肽拮抗药物,以及含氯除草剂,也可用于合成一种高效的锗烷类脱氢催化剂,其钠盐还是一种优良的防老剂。

由浙江科技学院生物与化学工程学系周孝瑞高级工程师等承担的3,5-双(三氟甲基)苯甲酰氯的小试合成工艺研究已经完成,该项目还同时建立了相应的质量分析检测手段。小试样品纯度高达99%以上,完全符合外商的要求。小试工艺适于工业化放大。