

基于等变化自适应源分离算法的滚动轴承故障信号自适应盲提取

孙瑾铃 张伟涛* 楼顺天

(西安电子科技大学电子工程学院 西安 710071)

摘 要: 针对复杂工况下滚动轴承故障信号盲提取问题, 该文提出一种独立分量分析(ICA)中非线性函数自适应选择方法, 解决了等变化自适应源分离算法(EASI)在多元振动源共存的情况下无法分离轴承故障信号的问题。此外, 为了解决在线盲分离算法稳态误差与收敛速率的平衡问题, 提出基于模糊逻辑的自适应迭代步长选择方法, 极大地提高了学习算法的收敛速度, 且稳态误差更小。轴承故障数据的盲提取仿真结果验证了算法的性能。

关键词: 盲信号分离; 故障检测; 超高斯; 亚高斯; 模糊逻辑

中图分类号: TN911.7

文献标识码: A

文章编号: 1009-5896(2020)10-2471-07

DOI: 10.11999/JEJT190722

Adaptive Blind Extraction of Rolling Bearing Fault Signal Based on Equivariant Adaptive Separation via Independence

SUN Jinling ZHANG Weitao LOU Shuntian

(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

Abstract: For the problem of blind extraction of rolling bearing fault signals under complex working conditions, an adaptive selection method of non-linear functions in Independent Component Analysis (ICA) is proposed, which solves the problem that Equivariant Adaptive Separation via Independence(EASI) can not separate bearing fault signals when multiple vibration sources coexist. In addition, in order to balance the steady-state error and convergence rate of the online blind separation algorithm, an adaptive iterative step selection method based on fuzzy logic is proposed, which improves greatly the convergence speed of the learning algorithm and reduces the steady-state error. The simulation results of blind extraction of bearing fault data verify the performance of the proposed algorithm.

Key words: Blind signal separation; Fault detection; Super-Gaussian; Sub-Gaussian; Fuzzy logic

1 引言

轴承状态对整个机械装置的运行状况有着至关重要的影响, 据统计, 对于占总设备80%的旋转机械而言, 30%的故障由其核心部件轴承故障引起^[1]。所以对轴承早期微弱故障进行实时预测与诊断是非常必要的, 可有效预防设备因轴承故障而突然失效。然而机械系统结构复杂, 部件繁多, 采集到的设备振动信号往往是多个振动源的混合, 并且振动源到传感器的传递路径具有不确定性, 导致无法对采集的振动信号进行准确建模, 因此如何从设备振

动信号中提取出微弱的轴承故障信号是轴承故障检测的关键。

盲信号分离是在未知源信号和传输路径的情况下, 仅利用观测信号以及源信号的统计独立性假设来恢复源信号的一种技术。由于盲信号分离仅要求源信号相互独立就可以有效地实现系统辨识与源信号恢复, 因此它具有重要的实际应用价值。目前盲信号分离在生物医学信号分析, 语音增强, 宽带无线通信, 计量经济学以及雷达目标识别等领域已有广泛应用^[2-5], 它在机械故障诊断领域的应用也初显成效^[6-9], 陈恩利等人^[10]将奇异值分解技术和盲信号分离技术结合用于滚动轴承故障诊断, 验证了盲分离技术应用于单一故障检测的可行性; 许同乐等人^[11]采用基于LMD-ICA降噪的振动信号特征提取算法解决了欠定模型下滚动轴承故障源分离问题; 席剑辉等人^[12]研究将盲分离技术中的JADE算法应用于滚动轴承故障信号的盲分离, 实现了轴承多故障源的分离。上述算法均为批处理算法, 其计

收稿日期: 2019-09-17; 改回日期: 2020-04-29; 网络出版: 2020-05-13

*通信作者: 张伟涛 zhwt-work@foxmail.com

基金项目: 国家自然科学基金(61571339), 陕西省创新人才推进计划-青年科技新星项目(2018KJXX-019)

Foundation Items: The National Natural Science Foundation of China (61571339), The Innovative Talents Promotion Program of Shaanxi Province (2018KJXX-019)

算复杂度高且只能应用于大样本的情况,无法实现轴承故障的实时监测。与批处理算法相比,自适应算法计算简单,能根据信号变化情况自动调整算法参数和结构,适合实时在线故障监测。本文主要研究多种类型振动源共存的复杂工况下轴承故障信号的在线提取问题。

当振动源类型单一时,传统的自适应盲信号分离算法如Infomax^[13],EASI算法^[14]以及基于CCA的自适应源提取方法^[15]都能成功地实现多个源的分离,但在机械设备及现场环境十分复杂的实际工况下,超高斯、高斯以及亚高斯等多种类型振动源往往同时存在,上述自适应算法的性能将急剧下降,甚至失效。为了使盲分离算法能够应用于滚动轴承故障信号的提取,本文在EASI算法基础上提出了一种非线性函数自适应选择的方法,解决了自适应盲分离算法对多种类型振动源分离失效的问题。另一方面,本文提出了基于模糊逻辑的自适应迭代步长选择方法,解决了在线盲分离算法稳态误差与收敛速率的平衡问题,使算法的性能得到了进一步提高。

2 问题描述

盲信号分离的混合信号模型可以表示为

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

其中 $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$ 为 m 维观测信号向量, $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T$ 为 n 维源信号向量, $\mathbf{A}$ 为 $m \times n$ 维混合矩阵。在盲信号分离问题中,源信号和传输信道的参数均是未知的。假定源信号是统计独立的,且混合矩阵 $\mathbf{A}$ 是列满秩的($m \geq n$)。在此假设条件下,盲信号分离的目标是仅利用观测数据估计一个分离矩阵 $\mathbf{W} \in \mathbb{R}^{n \times m}$,使

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) = \mathbf{W}\mathbf{A}\mathbf{s}(t) = \mathbf{G}\mathbf{s}(t) \quad (2)$$

为源信号 $\mathbf{s}(t)$ 的一个估计,即混合分离总响应矩阵 $\mathbf{G}$ 为广义置换矩阵(每行和每列只有1个非0元素)。

为了获得源信号的估计 $\mathbf{y}(t)$,Cardoso等人^[14]提出以互信息为代价函数的等变化自适应分离算法EASI,互信息定义为

$$\begin{aligned} I(y_1, y_2, \dots, y_n) &= \sum_{i=1}^n H(y_i) - H(\mathbf{y}) \\ &= \sum_{i=1}^n H(y_i) - \lg |\det \mathbf{W}| - H(\mathbf{x}) \end{aligned} \quad (3)$$

其中, $H(\mathbf{x}) = -\int p(\mathbf{x}) \lg p(\mathbf{x}) d\mathbf{x}$ 为 $\mathbf{x}$ 的信息熵, $I(y_1, y_2, \dots, y_n) \geq 0$ 。当联合熵与边缘熵满足关系 $p(\mathbf{y}) = \prod_{i=1}^N p(y_i)$ 时,互信息 $I(y_1, y_2, \dots, y_n) = 0$,

即 $\mathbf{y}$ 中各分量彼此独立。以互信息为代价函数,采用自然梯度优化方法,得到分离矩阵 $\mathbf{W}(t)$ 的归一化迭代公式为

$$\begin{aligned} \mathbf{W}(t+1) &= \mathbf{W}(t) - \lambda \left[\frac{\mathbf{y}(t)\mathbf{y}^T(t) - \mathbf{I}}{1 + \lambda \mathbf{y}^T(t)\mathbf{y}(t)} \right. \\ &\quad \left. + \frac{\mathbf{g}(\mathbf{y}(t))\mathbf{y}^T(t) - \mathbf{y}(t)\mathbf{g}^T(\mathbf{y}(t))}{1 + \lambda |\mathbf{y}^T(t)\mathbf{g}(\mathbf{y}(t))|} \right] \mathbf{W}(t) \end{aligned} \quad (4)$$

其中, λ 为算法的迭代步长, $\mathbf{I}$ 表示单位矩阵, $\mathbf{g}(\cdot) = [g_1, g_2, \dots, g_n]^T$ 为非线性函数,它与源信号的分布密切相关,在实际使用时,EASI算法对源信号均取相同的非线性函数,例如 $g_i(x) = \tanh(x)$, $i = 1, 2, \dots, n$,这使算法只能分离出某一种类型的源信号,例如超高斯分布信号,从而导致算法在多种类型源信号同时存在时失效。

3 非线性函数自适应选择

在复杂的实际工况下,传感器采集的信号往往是多种类型振动源的混合,主轴旋转振动信号的幅值一般为高斯分布,当轴承各部件出现损伤时会产生冲击脉冲,使得大幅值的概率密度增加,因此故障轴承的振动信号幅值通常呈超高斯分布,且振动信号中也可能存在其他机械部件的振动干扰,例如油泵振动干扰信号,双转子航空发动机中低压转子振动信号对高压转子的干扰等,其幅值大多为亚高斯分布。

为了使EASI算法能够应用于复杂工况下的轴承故障信号提取,在迭代过程中应根据振动源信号的分布类型分别对每一路分离输出信号选择相应的非线性函数。若 g_i 取

$$g_i = \frac{\partial}{\partial y_i} \lg p_i(y_i) = \frac{p'_i(y_i)}{p_i(y_i)}, i = 1, 2, \dots, n \quad (5)$$

其中 p_i 为第 i 个源信号的概率密度函数,那么最大熵,最小互信息以及极大似然准则之间是相互等价的,通过式(5)可以看出,非线性函数 $g_i(\cdot)$ 应由源信号的概率密度函数确定,但源信号的概率密度函数一般是未知的。在实际应用中,非线性函数 $g_i(\cdot)$ 的选择更多地取决于源信号的分布类型,而与源信号的概率密度关系不大,因为对同一分布类型的源信号,计算得到的非线性函数 $g_i(\cdot)$ 在信号大部分取值范围内区别较小,而不同分布类型的源信号, $g_i(\cdot)$ 输出区别很大。源信号的分布类型可以由其峰度 κ_4 来确定,一个零均值信号 y 的峰度定义为

$$\kappa_4(y) = E[y^4] - 3E^2[y^2] \quad (6)$$

当峰度大于0时认为信号为超高斯类型,等于0时为高斯类型,小于0时为亚高斯类型。

通常对于超高斯分布的源信号, 取 $\lg p_i(y_i) = \lg \cosh(y_i)$, 对于亚高斯分布的源信号, 取 $\lg p_i(y_i) = \frac{1}{4}y_i^4$, 对于高斯分布的源信号, 取 $\lg p_i(y_i) = -e^{-y_i^2/2}$ 。根据式(5)计算偏导数得到非线性函数 $g_i(y_i)$ 为

$$g_i(y_i) = \begin{cases} \tanh(y_i), & y_i \text{ 为超高斯分布} \\ y_i e^{-y_i^2/2}, & y_i \text{ 为高斯分布} \\ y_i^3, & y_i \text{ 为亚高斯分布} \end{cases} \quad (7)$$

为使这种非线性函数选取方法可以应用于EASI算法, 本文采用递归算法在线估计源信号的峰度 κ_4

$$\kappa_4[y_i(t)] = m_4[y_i(t)] - 3m_2^2[y_i(t)] \quad (8)$$

其中 m_4 和 m_2 表示信号的4阶矩和2阶矩, 它们可以按照式(9)和式(10)更新公式递推计算。

$$m_4[y_i(t)] = (1 - \alpha)m_4[y_i(t-1)] + \alpha y_i^4(t) \quad (9)$$

$$m_2[y_i(t)] = (1 - \alpha)m_2[y_i(t-1)] + \alpha y_i^2(t) \quad (10)$$

其中 α 满足 $0 < \alpha < 1$, 一般取 $\alpha = 0.99$ 。式(4)结合式(7)–式(10)共同组成了本文提出的轴承故障信号自适应盲提取算法。

4 迭代步长的自适应确定方法

虽然本文提出的算法能够实现多类振动源共存时的轴承故障信号提取, 但它仍属于LMS型自适应算法, 迭代步长 λ 的选择较困难, 若 λ 取值较大, 算法虽收敛快, 但稳态误差较大, 甚至算法发散; 若 λ 取值较小, 则稳态误差小, 而算法收敛速度很慢。因此, 应在迭代初始阶段使用较大的迭代步长以获得较快的收敛速度, 而在算法接近收敛时使用较小的迭代步长以获得较好的分离性能。

此外, 由式(4)可以看出, 分离矩阵 $\mathbf{W}$ 的每一个输出分量事实上使用了相同的迭代步长, 但由于不同的独立分量其收敛特性往往有较大区别, 因此对每一个输出分量应使用不同的学习速率, 则式(4)可推广为

$$\begin{aligned} \mathbf{W}_{t+1} = & \mathbf{W}_t - \mathbf{A}_t \{ [\mathbf{y}_t \mathbf{y}_t^T - \mathbf{I}] \oslash [(e + \|\mathbf{y}_t\|^2 \boldsymbol{\lambda}_t) \mathbf{e}^T] \\ & + [\mathbf{g}(\mathbf{y}_t) \mathbf{y}_t^T - \mathbf{y}_t \mathbf{g}^T(\mathbf{y}_t)] \oslash [(e + \mathbf{y}_t^T \mathbf{g}(\mathbf{y}_t) \boldsymbol{\lambda}_t) \mathbf{e}^T] \} \\ & \cdot \mathbf{W}_t \end{aligned} \quad (11)$$

其中 $\oslash$ 为矩阵对应元素的除法运算, $\boldsymbol{\lambda}_t = [\lambda_1(t), \lambda_2(t), \dots, \lambda_n(t)]^T$ 表示所有独立成分的迭代步长形成的列向量, $\mathbf{A}(t) = \text{diag}(\boldsymbol{\lambda}_t)$ 为所有迭代步长形成的对角矩阵, $\mathbf{e} = [1, 1, \dots, 1]^T$ 为 n 个1形成的列向量。

为了解决在线盲分离算法稳态误差与收敛速率的平衡问题, 本文使用模糊逻辑来确定每次迭代的迭代步长。基本思路为: 在迭代的初始阶段, 分离输出信号之间的相关性较大, 此时应使用较大的迭

代步长以获得较大的收敛速率, 而随着迭代的进行, 当分离输出信号接近独立时, 算法接近收敛, 应该使用较小的迭代步长来减小稳态误差。基于上面的思路, 本文提出一个两输入的模糊逻辑系统, 其中输入 D 反映分离信号的独立性, 另一个输入 μ 与迭代次数有关, 系统的输出为固定步长的比例因子 ω 。以 $\omega_i(t), i = 1, 2, \dots, n$ 的确定为例来描述提出的模糊逻辑系统。

定义信号 y_i 和 $y_j, j = 1, 2, \dots, n$ 的2阶相关系数 r_{ij} 为

$$r_{ij} = \frac{c_{ij}}{\sqrt{c_{ii}c_{jj}}} \quad (12)$$

其中 $c_{ij} = E\{(y_i - \bar{y}_i)(y_j - \bar{y}_j)\}$ 为信号 y_i 和 y_j 的互协方差, $\bar{y}_i = E\{y_i\}$ 。那么 y_i 与其它信号的2阶相关测度定义为

$$R_i = \frac{1}{n-1} \sum_{j \neq i} r_{ij}^2, \quad i = 1, 2, \dots, n \quad (13)$$

由于2阶相关测度 R_i 由分离输出的样本估计得到, 往往存在估计误差, 不宜直接作为模糊系统的输入, 本文对其进行非线性变换得到模糊系统的输入

$$D_i = \frac{2}{1 + e^{-\beta R_i}} - 1 \quad (14)$$

其中 β 为常数。由于本文考虑盲信号分离的自适应算法, 因此盲分离输出信号的互协方差 c_{ij} 须递归计算。令 $\mathbf{C} = \{c_{ij}\}$, 其递归公式为

$$\mathbf{m}_y(t) = \eta \mathbf{m}_y(t-1) + (1 - \eta) \mathbf{y}(t) \quad (15)$$

$$\mathbf{C}(t) = \eta \mathbf{C}(t-1) + (1 - \eta) [\mathbf{y}(t) - \mathbf{m}_y(t)] [\mathbf{y}(t) - \mathbf{m}_y(t)]^T \quad (16)$$

其中 η 满足 $0 < \eta < 1$, 一般取 $\eta = 0.99$ 。

模糊系统的另一输入 μ 定义为

$$\mu = e^{-vt} \quad (17)$$

其中 t 表示迭代次数, v 为衰减速率, 一般取经验值0.001。

可以发现模糊系统的输入 D_i 和 μ 取值均在 $[0, 1]$ 之间, 且迭代初始阶段 D_i 和 μ 值较大接近于1, 算法收敛阶段值接近于零。在算法迭代初始和中期阶段, 输入 D_i 应起主要作用, 而在算法收敛阶段, 输入 μ 应起主要作用以减小稳态误差。因此, 将模糊系统的输入 D_i 和 μ 分别模糊化为4个语义值: $[S1, S2, M, B]$, 模糊系统的输出 ω_i 模糊化为6个语义值: $[S1, S2, M1, M2, B1, B2]$, 因此模糊系统具有 $4 \times 4 = 16$ 条模糊推理规则, 如表1所示。

表1的模糊推理规则可描述为(例如): if D_i is $S2$ and μ is M , then ω_i is $M1$ 。模糊逻辑系统的输

入输出变量的隶属度函数以及输入输出关系曲面如图1所示。

一旦由模糊系统的输出得到固定步长的比例因子 $\omega_i \in [0, 1.5]$ ，盲分离算法的第 i 个输出分量的迭代步长便可由式(18)给出

$$\lambda_i(t) = \omega_i(t)\theta \tag{18}$$

其中 θ 为常数，在自适应盲信号分离的应用中，我们一般取 $\theta = 0.01$ 即可。

由于提出的模糊逻辑系统能够根据分离信号的独立性程度和迭代所处的阶段自动地调节迭代步长，因此采用基于模糊逻辑的自适应迭代步长选择方法后，本文算法的收敛速度和稳态精度都将得到极大地提高。

5 仿真结果


盲信号分离的性能通常由干信比(Interference to Signal Ratio, ISR)来评价，定义为^[16]

$$\text{ISR} = \frac{1}{N} \left[\sum_{i=1}^N \left[\sum_{j=1}^N \frac{|g_{ij}|}{\max_k |g_{ik}|} - 1 \right] + \sum_{j=1}^N \left[\sum_{i=1}^N \frac{|g_{ij}|}{\max_k |g_{kj}|} - 1 \right] \right] \tag{19}$$

其中 $\mathbf{G} = \mathbf{W}\mathbf{A} = \{g_{ij}\}$ 为混合分离总响应矩阵。ISR

表 1 模糊推理规则

	$\mu = S1$	$\mu = S2$	$\mu = M$	$\mu = B$
$D_i = S1$	$S1$	$S1$	$S2$	$M2$
$D_i = S2$	$S1$	$S2$	$M1$	$M2$
$D_i = M$	$M1$	$M1$	$M2$	$B1$
$D_i = B$	$M2$	$M2$	$B1$	$B2$



(a) 隶属度函数

充分考虑了盲信源分离的两种不确定性，其值越小表示分离性能越好，反之则性能越差。


为了验证本文方法的有效性，采用 $n = 3$ 个源信号：分别是取值在 $[-1, +1]$ 之间的均匀白噪声、滚动轴承外圈故障信号以及滚动轴承正常信号。其中滚动轴承信号来自美国Case Western Reserve University轴承数据中心网站，电动机转速为1797 rpm，采样率12 kHz，根据轴承型号和转速计算得到外圈故障信号特征频率为107 Hz，3个源信号的时域波形及其幅值的概率分布如图2所示。

使用 $m = 5$ 个传感器得到5路观测信号，用本文算法对观测信号进行盲分离。包络谱是工程中常用的轴承振动信号分析方法，为了验证算法的有效性，对分离前后的信号分别进行包络谱分析，如图3所示。

由图3(a)可以看出，观测信号被干扰和噪声湮没，故障频率107 Hz不容易辨识，无法有效地分辨故障类型。对观测信号用本文提出的算法进行分离，得到的3个通道分离信号包络谱如图3(b)所示，通道3可以看出明显的转频29 Hz，通道2可以看出明显的故障频率107 Hz及其谐波成分，由此可以判断轴承的外圈存在缺陷。

将本文算法与原始的EASI算法(非线性函数分别选择 $g(\cdot) = \tanh(\cdot)$ 以及 $g(\cdot) = (\cdot)^3$)进行比较，本文算法分别采用固定步长以及模糊逻辑步长。对其性能均进行了实验测试，图4给出了算法的性能比较(1000次独立实验)。

在每次独立运行中，混合矩阵 $\mathbf{A}$ 中的元素是取值在 $[-1, +1]$ 之间均匀分布的随机数。对于EASI算法，其步长取经验值 $\lambda = 0.001$ ；对于本文算法，式(9)和式(10)中 m_4, m_2 的初值取0，当采用固定步



(b) 输入输出关系曲面

图 1 模糊系统的输入与输出




图2 源信号波形及其幅值分布




图3 观测信号及分离信号包络谱




图4 算法的性能比较

长时，步长取值与EASI算法相同，当采用模糊逻辑步长时，式(14)中 $\beta = 25$ ，式(15)、式(16)中 m_y, C 的初值取0。由图4可以看出原始EASI算法都收敛

到很差的干扰信号比，分离失效，而本文算法可以收敛到较小的ISR。但采用固定步长时，其开始阶段的收敛特性与EASI算法基本相同，这是因为它使用了与EASI相同的迭代步长，并且收敛后稳态误差较大。而本文算法采用使用模糊逻辑步长时，收敛速度很快，且稳态误差也比使用固定步长时要小，这很好地验证了基于模糊逻辑的自适应迭代步长选择方法的高效性。对于实验的成功与失败，本文定义为：当迭代终止后 $ISR < 1$ 的实验为成功，否则为失败，表2给出了算法的成功率的比较。

由表2可以看出当多种类型的振动源同时存在时，非线性函数固定为 $g(\cdot) = (\cdot)^3$ 和 $g(\cdot) = \tanh(\cdot)$ 的EASI算法几乎失效，这是意料之中的，正如第2节所述，这两种非线性函数选取都无法分离超高斯分布和亚高斯分布同时存在的源信号。实验中发现，当同时存在多类信号时，只有与选择的非线性函数对应的信号能够被分离出来，而其余信号仍然混合

表 2 算法的成功率比较

算法名称	成功率(%)
EASI, $g(x) = x^3$	0
EASI, $g(x) = \tanh(x)$	12
本文算法, 使用固定步长	88
本文算法, 使用模糊逻辑步长	97

在一起, 造成了整体ISR很大, 无法有效分离。相比之下, 本文算法采用固定步长时成功率为88%, 这说明本文算法能够有效分离3种类型的信号。当采用模糊逻辑的步长选择时, 成功率提高到了97%, 很好地验证了模糊逻辑步长选择方法的性能提升。

将本文算法(采用模糊逻辑步长)与SOBI和FastICA等批处理方法进行比较, 1000次独立实验的ISR性能总结于表3。可以看出, SOBI算法的ISR性能最好, 这是由于SOBI利用观测信号相关矩阵的特殊代数结构来分离独立源信号, 没有非线性函数选取的问题。但SOBI算法中多个相关矩阵的计算需要批量样本数据, 且后续的联合对角化操作需要多次迭代才能收敛。FastICA性能与提出的算法ISR性能相近, 但FastICA算法计算分离矩阵需要对批量数据求平均, 且分离矩阵的更新需要不断迭代完成。因此SOBI及FastICA算法在滚动轴承故障诊断中的实时性将受制于其处理方式的限制。

表 3 算法的性能比较

算法	ISR
SOBI	0.069
FastICA, $g(\cdot) = \tanh(\cdot)$	0.140
FastICA, $g(\cdot) = (\cdot)^3$	0.170
FastICA, $g(\cdot) = (\cdot) \exp(-(\cdot)^2/2)$	0.160
本文算法, 使用模糊逻辑步长	0.110

设备故障实时诊断对缺陷检测算法的计算时间有很高的要求, 实验中分析了算法在matlab中运行的时间。本文算法采用固定步长时处理每个样本的平均时间为34 μs , 当采用模糊逻辑步长时处理时间为119 μs 。如将算法移植到专用信号处理平台, 其运行时间将极大缩减, 一般能达到 μs 量级, 完全能够满足实验中12 kHz采样率下的实时处理要求, 故提出的算法可以应用于滚动轴承故障的实时监测与诊断。

6 结论

在滚动轴承故障信号盲提取问题中, 因为机械设备及现场工况的复杂, 非线性函数的选择对于分离算法的收敛特性以及稳定性起着至关重要的作

用。当多类振动源共存时, 传统的等变化自适应源分离算法无法分离轴承故障信号, 本文提出了一种非线性函数自适应选择方法, 可以解决多类振动源共存时EASI算法性能较差甚至失效的问题。同时, 为了加快提出算法的收敛速度, 并且提高算法的稳态性能, 本文还提出了一种基于模糊逻辑的自适应迭代步长选择方法。最终, 算法的收敛速度、稳态精度及分离成功率均得到了提高。实验表明, 本文提出的算法信号处理时间能达到 μs 量级, 完全可以满足机械振动信号典型采样率下的实时处理要求。

参 考 文 献

- [1] 郝如江, 卢文秀, 褚福磊. 声发射检测技术用于滚动轴承故障诊断的研究综述[J]. 振动与冲击, 2008, 27(3): 75–79. doi: 10.3969/j.issn.1000-3835.2008.03.019.
HAO Rujiang, LU Wenxiu, and CHU Fulei. Review of diagnosis of rolling element bearings defaults by means of acoustic emission technique[J]. *Journal of Vibration and Shock*, 2008, 27(3): 75–79. doi: 10.3969/j.issn.1000-3835.2008.03.019.
- [2] HYVÄRINEN A, KARHUNEN J, and OJA E. Independent Component Analysis[M]. New York: Wiley, 2001: 9–11. doi: 10.1007/978-0-387-73003-5_305.
- [3] 李扬, 张伟涛, 楼顺天. 基于联合对角化的声信号深度卷积混合盲分离方法[J]. 电子与信息学报, 2019, 41(12): 2951–2956. doi: 10.11999/JEIT190067.
LI Yang, ZHANG Weitao, and LOU Shuntian. Deep convolution blind separation of acoustic signals based on joint diagonalization[J]. *Journal of Electronics & Information Technology*, 2019, 41(12): 2951–2956. doi: 10.11999/JEIT190067.
- [4] 陈雷, 韩大伟, 郭艳菊, 等. 基于回溯搜索优化的卷积混合语音盲分离[J]. 计算机工程与应用, 2017, 53(15): 137–143.
CHEN Lei, HAN Dawei, GUO Yanju, et al. Speech convolutive blind separation algorithm based on backtracking search optimization[J]. *Computer Engineering and Applications*, 2017, 53(15): 137–143.
- [5] 龚晓峰, 毛蕾, 林秋华, 等. 基于四阶累积量张量联合对角化的多数据集联合盲源分离[J]. 电子与信息学报, 2019, 41(3): 509–515. doi: 10.11999/JEIT180414.
GONG Xiaofeng, MAO Lei, LIN Qiuhua, et al. Joint blind source separation based on joint diagonalization of fourth-order cumulant tensors[J]. *Journal of Electronics & Information Technology*, 2019, 41(3): 509–515. doi: 10.11999/JEIT180414.
- [6] 刘嘉辉, 董辛旻, 李剑飞. 基于全矢谱时间固有尺度分解和独立分量分析盲源分离降噪的滚动轴承故障特征提取[J]. 中国机械工程, 2018, 29(8): 943–948. doi: 10.3969/j.issn.1004-132X.2018.08.009.
LIU Jiahui, DONG Xinmin, and LI Jianfei. Fault feature

- extraction of rolling bearings based on noises reduced by full vector spectrum ITD-ICA blind source separation[J]. *China Mechanical Engineering*, 2018, 29(8): 943–948. doi: [10.3969/j.issn.1004-132X.2018.08.009](https://doi.org/10.3969/j.issn.1004-132X.2018.08.009).
- [7] HE Jun, CHEN Yong, ZHANG Qinghua, *et al.* Blind source separation method for bearing vibration signals[J]. *IEEE Access*, 2018, 6: 658–664. doi: [10.1109/ACCESS.2017.2773665](https://doi.org/10.1109/ACCESS.2017.2773665).
- [8] HUANG Xiangdong, JIN Xukang, and FU Haipeng. Short-sampled blind source separation of rotating machinery signals based on spectrum correction[J]. *Shock and Vibration*, 2016, 2016: 9564938. doi: [10.1155/2016/9564938](https://doi.org/10.1155/2016/9564938).
- [9] 胡纯直. 风机齿轮箱多故障诊断问题研究[D]. [硕士论文], 浙江大学, 2017.
- HU Chunzhi. The research on multi-fault diagnosis of wind turbine gearbox[D]. [Master dissertation], Zhejiang University, 2017.
- [10] 陈恩利, 张玺, 申永军, 等. 基于SVD降噪和盲信号分离的滚动轴承故障诊断[J]. *振动与冲击*, 2012, 31(23): 185–190. doi: [10.3969/j.issn.1000-3835.2012.23.034](https://doi.org/10.3969/j.issn.1000-3835.2012.23.034).
- CHEN Enli, ZHANG Xi, SHEN Yongjun, *et al.* Fault diagnosis of rolling bearings based on SVD denoising and blind signals separation[J]. *Journal of Vibration and Shock*, 2012, 31(23): 185–190. doi: [10.3969/j.issn.1000-3835.2012.23.034](https://doi.org/10.3969/j.issn.1000-3835.2012.23.034).
- [11] 许同乐, 王营博, 郑店坤, 等. 基于LMD-ICA降噪的滚动轴承故障特征提取方法研究[J]. *北京邮电大学学报*, 2017, 40(1): 111–116.
- XU Tongle, WANG Yingbo, ZHENG Diankun, *et al.* Research of the rolling bearing fault signal feature extraction Method based on the LMD-ICA noise reduction[J]. *Journal of Beijing University of Posts and Telecommunications*, 2017, 40(1): 111–116.
- [12] 席剑辉, 崔健驰, 蒋丽英. 基于JADE-ICA的滚动轴承多故障信号盲源分离[J]. *振动与冲击*, 2017, 36(5): 231–237. doi: [10.13465/j.cnki.jvs.2017.05.037](https://doi.org/10.13465/j.cnki.jvs.2017.05.037).
- XI Jianhui, CUI Jianchi, and JIANG Liying. JADE-ICA-based blind source separation of multi-fault signals of rolling bearings[J]. *Journal of Vibration and Shock*, 2017, 36(5): 231–237. doi: [10.13465/j.cnki.jvs.2017.05.037](https://doi.org/10.13465/j.cnki.jvs.2017.05.037).
- [13] BELL A J and SEJNOWSKI T J. An information-maximization approach to blind separation and blind deconvolution[J]. *Neural Computation*, 1995, 7(6): 1129–1159. doi: [10.1162/neco.1995.7.6.1129](https://doi.org/10.1162/neco.1995.7.6.1129).
- [14] CARDOSO J F and LAHELD B H. Equivariant adaptive source separation[J]. *IEEE Transactions on Signal Processing*, 1996, 44(12): 3017–3030. doi: [10.1109/78.553476](https://doi.org/10.1109/78.553476).
- [15] ZHANG Weitao, LOU Shuntian, and FENG Dazheng. Adaptive quasi-newton algorithm for source extraction via CCA approach[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2014, 25(4): 677–689. doi: [10.1109/TNNLS.2013.2280285](https://doi.org/10.1109/TNNLS.2013.2280285).
- [16] KARHUNEN J, PAJUNEN P, and OJA E. The nonlinear PCA criterion in blind source separation: Relations with other approaches[J]. *Neurocomputing*, 1998, 22(1/3): 5–20. doi: [10.1016/s0925-2312\(98\)00046-0](https://doi.org/10.1016/s0925-2312(98)00046-0).
- 孙瑾铃: 女, 1995年生, 博士生, 研究方向为盲信号处理.
- 张伟涛: 男, 1983年生, 副教授, 硕士生导师, 研究方向为盲信号处理.
- 楼顺天: 男, 1962年生, 教授, 博士生导师, 研究方向为神经网络信息处理与应用、模糊信息处理与应用、盲信号处理、现代信号智能处理、智能控制技术.

责任编辑: 余蓉