

基于时频分析的高速列车转向架混合故障盲分离

针对高速列车同时发生两种故障的问题,提出了一种基于短时傅里叶变换(Short-Time Fourier Transform, STFT)和时频比的高速列车转向架混合故障盲分离算法。首先对观测数据进行STFT线性时频变换,再运用混合信号的时频比(Time-Frequency Ratio of Mixtures, TIFROM)估计单源域,得到分离矩阵;然后对源信号和分离后的估计信号分别提取矢量特征,用于盲分离准确度评价;最后用支持向量机(Support Vector Machine, SVM)识别盲分离的正确率。

谷千伟 金炜东 余志斌/西南交通大学电气工程学院



谷千伟/硕士研究生

关键词/Keywords

STFT ·
时频比 ·
盲分离 ·
特征提取 ·
SVM分类 ·

盲源分离(Blind Source Separation, BSS)是指从混合或观察信号中分离、提取原始信号波形而不知道源信号以及传输信道的信号特征。盲信号分离是在目标函数下的无监督学习算法,“盲”体现在源信号的形式是未知的,并且源信号的混合方式也未知。目前BSS常用的分析方法有很多,如独立成分分析(ICA)、核独立成分分析(KICA)、稀疏成分分析(SCA)、非负矩阵分解(NMF)和时频成分分析(TFCA)等,其中时频分析从时间和频率两个维度上描述了信号,具有更好的时频聚集性。目前时频分析方法大体分为两类^[1]:一类是基于WVD的方法;另一类是基于线性时频变换的方法。基于独立分量分析原理的WVD算法需要两步方法实现,该算法会出现严重的交叉项干扰,在算法实现上需要大量的矩阵运算,步骤繁琐,

容易产生误差。在此基础上改进的基于负熵最大化的快速独立分量分析算法能取得较好的效果,但分离信号的幅度、相位等参数较源信号发生了变化,导致这些算法的应用领域受到了一定限制。针对上述算法存在的问题,本文提出了一种基于短时傅里叶变换(Short-Time Fourier Transform, STFT)时频比的盲分离算法,它用一步方法实现了盲信号分离,具有较低的运算复杂度,寻找单源域更简单,更能准确有效地实现信号的盲源分离。

安全性是列车运行最重要、最基本的要求,如今高速列车的运行速度达到或超过300 km/h,列车一旦发生故障必定会带来严重的后果,因此列车运行状态实时监测与故障诊断变得更加重要。转向架是高速列车走行部最重要的组成部分,转向架上关键部件的失效往往会导致列车各部位振动加剧、性能下降,甚至会导致脱轨翻车等严重事故^[2]。因此开展基于识别列车运行状态的列车故障诊断研究具有重要意义,并且仍存在诸多尚未解决的问题。

高速列车按照故障类型可以分为单故障和混合故障,其中单故障的解决方法有集合经验模态分解、小波分析、奇异谱分析及分数阶傅里叶变换等,效果很好且已经很成熟。高铁混合故障由于影响因素多、数学模型复杂及先验知识缺乏等因素,目前有较少有效的解决办法。文献[3]中采用单通道解决高速铁路混合故障算法较复杂,但分离后信号的

国家自然科学基金重点项目(61134002)。

幅度和相位较源信号发生了变化。本文将时频盲源分离用在高铁混合信号分离上,从多通道角度处理混合故障,以达到分离混合故障的目的,并提取时频域高维特征矢量,将其用于高速列车转向架故障状态识别,通过支持向量机分类识别验证上述方法的有效性。

原理与方法

1. 盲源分离模型

近年来,盲信号分离的研究发展十分迅速,但过去提出的一系列方法大多都是基于独立分量的假设条件进行分析的,具体如下:

首先以两路信号混合情形说明算法原理,混合模型为

$$\begin{aligned} x_1(t) &= a_{11}s_1(t) + a_{12}s_2(t) \\ x_2(t) &= a_{21}s_1(t) + a_{22}s_2(t) \end{aligned} \quad (1)$$

将观测信号做如下的线性组合,即

$$y(t) = x_1(t) - cx_2(t) \quad (2)$$

结合式(1)和式(2),消去系数 c ,满足 $c_1 = a_{11}/a_{21}$, $c_2 = a_{12}/a_{22}$ 。则能使观测信号消去 $s_1(t)$ 或 $s_2(t)$,得到的 $y(t)$ 就是仅有幅度改变的源信号。显然,如果找到这样的时间 t_n ,且能满足 $s_1(t_n) \neq 0$ 、 $s_2(t_n) \neq 0$,则

$$\begin{aligned} x_1(t_n) &= a_{11}s_1(t_n) \\ x_2(t_n) &= a_{21}s_1(t_n) \end{aligned} \quad (3)$$

$x_1(t_n)/x_2(t_n) = a_{11}/a_{21}$,于是得到 c_1 ,同理可得到 c_2 。构造矩阵

$$\tilde{A}^{-1} = \begin{pmatrix} 1 & 1 \\ \frac{1}{c_1} & \frac{1}{c_2} \end{pmatrix}^{-1} \quad (4)$$

即可得到

$$y(t) = \tilde{A}^{-1}x(t) = \begin{pmatrix} a_{11}s_1(t) & a_{12}s_2(t) \end{pmatrix}^T \quad (5)$$

然而,仅在时间轴上很难找到 t_n ,但利用线性时频变换却可以解决这一问题。

首先对观测信号做线性时频变换,即

$$X_i(t, \omega) = \int_{-\infty}^{\infty} x_i(\tau)h(\tau - t)e^{-j\omega\tau} d\tau \quad (6)$$

记STFT的比为

$$\alpha(t_j, \omega_k) = \frac{X_1(t_j, \omega_k)}{X_2(t_j, \omega_k)} \quad (7)$$

由式(1)和式(6)可知

$$\alpha(t_j, \omega_k) = \frac{a_{11}s_1(t_j, \omega_k) + a_{12}s_2(t_j, \omega_k)}{a_{21}s_1(t_j, \omega_k) + a_{22}s_2(t_j, \omega_k)} \quad (8)$$

因此,只要有一个源信号在一个TF窗 (t_j, ω_k) 上独立出现, $\alpha(t_j, \omega_k)$ 就得到多要求的消去系数。

2. 混合信号的时频比

基本的混合信号的时频比(TIFROM)方法首先计算 $x_1(t)$ 与其他单独一路观测信号 $x_i(t)$ STFT_s的比,如取 $i=2$,则

$$\alpha_i(t, \omega) = \frac{x_1(t, \omega)}{x_2(t, \omega)} = \frac{\sum_{m=1}^n a_{1m}s_m(t, \omega)}{\sum_{m=1}^n a_{2m}s_m(t, \omega)} \quad (9)$$

在每一个分析域中,计算均值之后再计算方差,即

$$\begin{aligned} |\bar{\alpha}_i|(t, \omega) &= \frac{1}{m} \sum_{p=1}^m |\alpha_i(t_p, \omega)| \\ \text{var}(t, \omega) &= \frac{1}{m} \sum_{p=1}^m \left\| |\alpha_i| - |\bar{\alpha}_i| \right\|^2 \end{aligned} \quad (10)$$

将所有分析域的方差按升序排列,最小的一个就是要找的第一个单源分析域,由式(9)和式(10)得到与此单源域对应的 $x_1(t)$ 与其他观测信号TF变换比值的均值 $|\bar{\alpha}_i|(t, \omega)$ 。 $|\bar{\alpha}_i|(t, \omega)$ 确定了分离矩阵的第一列,之后依次考察后续的分析域,如果它所对应的 $|\bar{\alpha}_i|(t, \omega)$ 与之前得到的分离矩阵列之间的距离均大于某一定义的门限值 ε ,则保留此分析域对应的 $|\bar{\alpha}_i|(t, \omega)$ 作为分离矩阵的一列,直到找到足够的列。流程如图1所示。




图1 TIFROM流程

3. 盲分离准确度评价

均值(平均数、平均值)表示的是某个变量

所有取值的集中趋势或平均水平。若一组数据 $x_1, x_2, \dots, x_n$ 代表一个大小为 n 的有限样本, 则其均值为 $\bar{x} = (\sum_{i=1}^n x_i) / n$ 。

均方差也叫标准差, 在概率统计中常作为统计分布程度上的测量。若一组数值 $x_1, x_2, \dots, x_n$ 皆为实数, 其平均值为 μ , 标准差 $\sigma = \sqrt{[\sum_{i=1}^n (x_i - \mu)^2] / n}$ 。

偏度是统计数据分布偏斜方向和程度的度量, 也是统计数据分布非对称程度的数字特征, 表征概率分布密度曲线相对于平均值不对称程度的特征数。直观看来, 偏度就是密度函数曲线尾部的相对长度。对于 n 个样本值, 偏度SK的公式为

$$SK = \frac{n \sum (x_i - \bar{x}_i)^3}{(n-1)(n-2)s_d^3} \quad (11)$$

式中, x_i 为第 i 个样本; s_d 为样本标准差。

峰度表征概率密度分布曲线在平均值处峰值高低的特征数。直观看来, 峰度反映了尾部的厚度。峰度BK的公式为

$$BK = \frac{\sum_{i=1}^n (y_i - \bar{y})^4}{(n-1)s^4} \quad (12)$$

式中, y_i 为样本测定值; $\bar{y}$ 为样本 n 次测定值的平均值; s 为样本标准差。

对信号小波变换进行单支重构, 得到各个频带内信号的小波能量矩。计算公式为

$$M_j = \sum_{k=1}^n (k\Delta t) |S_j(k\Delta t)|^2$$

式中, Δt 为采样时间间隔; n 为总的采样点数。

小波能量矩不仅考虑了能量的大小, 还考虑了能量随时间 t 的分布情况, 更有利于信号特征的提取, 步骤如下:

- 1) 将采样信号进行小波分解, 根据信号自身的特征选择适宜的小波基和分解层数。设 S 代表原始信号, 用 X_{jk} 表示第 j 分解尺度下 k 时刻信号的小波分解系数, 其中 $j = 1, 2, \dots, J, J+1$ 。
- 2) 对小波分解系数进行重构, 提取各频带范围的信号 S_{jk} 。
- 3) 求取各频带信号 S_{jk} 的小波能量矩 M_j 。
- 4) 构造特征矢量, 以归一化的能量矩为元素

可以构造一个特征矢量 T , 即

$$T = \frac{1}{\sum_{j=1}^{J+1} M_j^2} [M_1, M_2, \dots, M_{J+1}] \quad (13)$$

4. 算法流程

以两路混合信号为例, 算法流程如图2所示。首先对采集的两个传感器混合信号 x_1 和 x_2 分别滤波、归一化预处理; 然后用时频盲源分离方法估计混合矩阵, 得到源信号的估计 $\hat{S}_1$ 、 $\hat{S}_2$, 对源信号 S_1 、 S_2 以及源信号的估计 $\hat{S}_1$ 、 $\hat{S}_2$ 分别提取特征 (如均值、方均差、偏度、峰度和小波能量矩等); 最后用分类器识别正确率, 其中源信号的特征作为训练, 估计信号作为测试。




图2 算法流程

实验和仿真

1. 仿真信号

为了验证算法的可行性, 首先用简单的仿真进行信号测试。采样频率为300 Hz, 采样点数为14 580, 源信号 S_1 和 S_2 , 混合矩阵为 A , 具体如下

$$\begin{aligned} S_1 &= \text{sawtooth}(40\pi t) + \cos(40t) \\ S_2 &= \sin(30t) + \cos(40t) \\ A &= \begin{pmatrix} 1 & 0.4 \\ 0.5 & 1 \end{pmatrix} \end{aligned} \quad (14)$$

源信号 S_1 和 S_2 都含有余弦分量, 不是相互独立的两个函数, 其时域图和频域图如图3所示。通过混合矩阵 A 混合之后得到 x_1 和 x_2 , 其时域图和频域图如图4所示。对混合后的信号进行时频盲源分离得到源信号的估计 S'_1 和 S'_2 , 如图5所示。

为了对比源信号和分离得到的源信号估计信号, 分别提取两组信号的小波能量矩, 对信号进行小波包4层分解, 得到16个频段, 每个频段占9.375 Hz, 取




图3 源信号时频图




图4 混合信号时频图




图5 源信号的估计时频图

前5个频段0~9.375 Hz、9.375~18.75 Hz、18.75~28.125 Hz、28.125~37.5 Hz和37.5~46.875 Hz,对5个频段求取小波能量矩,如图6所示。最后用支持向量机分类器进行分类,其中源信号 S_1 和 S_2 取30个样本的特征矢量(30×5 的矢量)作为训练,源信号的估计 S'_1 和 S'_2 取30个样本的特征矢量(30×5 的矢量)作为测试,正确率均达100%。




图6 仿真信号特征分布

2. 高速列车转向架混合故障诊断

实验数据来自西南交通大学牵引动力国家重点实验室,采用动力学仿真分析的多体动力学分析软件包。针对某型号动车组中动车转向架机械故障进行了大量的仿真实验,转向架故障工况主要涉及横向减振器故障、抗蛇形减振器故障、空气弹簧失气和原车方案。每种工况下运行速度按40 km/h、80 km/h、120 km/h、140 km/h、160 km/h和200 km/h递增。每种速度下运行约3.6 min,采样频率为243 Hz。

高速列车实测的空气弹簧失效、抗蛇形减振器失效和空气弹簧失效+抗蛇形减振器混合故障数据作为实测信号。高速列车蛇形运动失稳往往分为一次蛇形失稳和二次蛇形失稳,车辆的蛇形运动失稳通常是由抗蛇形减振器、空气弹簧失效故障引起的,并且还与列车运行速度有关,随着速度的增加,发生蛇形失稳的概率加大。其特征是转向架上有持续、较大的横向加速度,有较窄频宽的能量分布突出点。两个传感器实测的混合故障数据构成多通道观测数据,然后对多通道观测数据进行TOFROM盲源分离研究,并提取特征来评价分离后的单故障估计信号和实测的单故障信号的相似度。

传感器采集数据位置为1号转向架构架1位横向位移和1号转向架构架1位垂向位移。采样点数选取48 600,并选取速度160 km/h,实测横向和垂向的混合数据时域图如图7所示;在短时傅里叶变换基础上,经基于时频比的盲源分离得到抗蛇形减振器失效的估计和空气弹簧失气的估计,时域

图如图8所示；实测的抗蛇形减振器失效和空气弹簧失气时域图如图9所示。




图7 抗蛇形减振器失效和空气弹簧失气混合时域




图8 抗蛇形减振器失效和空气弹簧失气的估计




图9 实测的抗蛇形减振器失效和空气弹簧失气

为了验证实测单故障源信号和估计的单故障信号的相似度，提取均值、均方差、偏度、峰度和小波能量矩等特征，并选用对小样本分类识别具有优势的支持向量机来实现故障诊断。高速列车故障信息主要体现在低频段，对信号进行小波包7层分解，得到128个频段，每个频段占0.95 Hz，取前6个频段0~0.95 Hz、0.95~1.9 Hz、1.9~2.85 Hz、2.85~3.8 Hz和3.8~4.75 Hz。每个样本时域特征和时频域特征共组成一个10维矢量 T 依次为

$$T=[\text{均值} \text{ 均方差} \text{ 偏差} \text{ 峰度} \text{ 能量矩1} \text{ 能量矩2} \text{ 能量矩3} \text{ 能量矩4} \text{ 能量矩5} \text{ 能量矩6}] \quad (15)$$

采样点数为48 600，486个点作为一个样本，共100个样本，最后每个故障得到一个 100×10 的矩阵。因此将实测的抗蛇形减振器失效和空气弹簧失气单故障组成的 200×10 矩阵特征作为训练，将分离得到抗蛇形减振器失效的估计和空气弹簧失气的估计组成 200×10 的矩阵特征作为测试，每个速度下分离正确识别率如表1和表2所示。随着速度下降，识别率有一定的下降趋势符合实际。

表 1

传感器位置	200	160	140	120	80
1构架1位Y	100	100	100	99	100
1构架1位Z	100	100	100	100	68

表 2

传感器位置	200	160	140	120	80
1构架中部Y	98	93	99	100	99
1构架中部Z	100	100	100	98	69

结束语

该算法主要研究的是源信号为线性瞬时混合系统，传感器位置满足取横向位置和垂向位置的条件，能较好地恢复源信号，从特征提取识别角度评价实测信号和源信号估计信号的相似度，得到了理想的效果。然而高速列车车体、构架、轴箱和轮轨等部位有较多的传感器，如何准确选择传感器还没有一个统一的标准。当观测信号数目小于源信号时，欠定盲源分离在高速列车混合故障诊断中的应用也是一个尚需研究的难题。

参考文献

[1] 刘力伟，等．基于STFT时频比算法的跳频信号盲分离[J]．微计算机信息，2010，26(5)：154-156.
[2] 秦娜，金炜东，等．基于EEMD的高速列车转向架故障诊断[J]．计算机工程，2013，39(12)：1-4.
[3] 谷千伟，金炜东，余志斌．基于EEMD和ICA的单通道列车信号盲分离[J]．计算机应用研究，2014，31(5)：1551-1553.

(收稿日期：2014-12-16) EA