

全矢样本熵在高速列车故障诊断中的应用^{*}

李亚兰, 金炜东

(西南交通大学电气工程学院 成都, 611756)

摘要 为了有效提取高速列车转向架振动信号的故障特征以及针对单通道采集的信息难以完善地反映出列车运行状态的问题,提出了一种基于全矢样本熵(full vector sample entropy,简称 FVSE)算法的故障特征提取方法。首先,使用噪声辅助多元经验模态分解(noise assisted multivariate empirical mode decomposition,简称 NAMEMD)方法对振动信号进行分解,得到一系列多元本征模态函数;其次,根据相关系数法选择与原始信号最相关的本征模态函数分别进行样本熵和全矢样本熵特征提取;最后,将得到的特征向量分别作为支持向量机的输入对列车状态进行识别。实验结果表明,采用全矢样本熵算法的故障识别率普遍比采用样本熵算法提高了 6 个百分点,最高达到了 98%以上,验证了噪声辅助多元经验模态分解方法结合全矢样本熵算法对高速列车故障诊断的有效性。

关键词 高速列车转向架;全矢样本熵;噪声辅助多元经验模态分解;本征模态函数;支持向量机

中图分类号 TH165⁺.3; TP206⁺.3

引言

高速列车转向架是列车的重要组成部分,其故障将会严重影响车辆的动力学性能和安全运行^[1],因此对转向架关键部件的故障检测尤为重要。为了保证高速列车在长期服役过程中的稳定性和安全性,通常在车体和构架的前、中、后 3 个部位放置传感器来监测各个方向的位移和加速度信号,由此对列车的运行状态进行评估,给列车的安全预警和健康维护工作提供基础。如何利用采集到的信号数据精确评估高速列车的运行状态是很有研究价值的工作。

Rehman 等^[2]提出多元经验模态分解(multivariate empirical mode decomposition,简称 MEMD)方法是将传统的经验模态分解(empirical mode decomposition,简称 EMD)方法从一维拓展到多维,可对多通道信号进行处理,很大程度上改善了使用 EMD 方法带来的模态混叠问题,并将 MEMD 应用到脑电信号^[3]、超声波^[4]及多普勒雷达^[5]等多通道信号的处理分析上,取得了较好的效果。张浩等^[6]利用 MEMD 对管道阻塞声信号进行多通道同步自适应分解,通过计算筛选出的本征模态函数(intrinsic mode functions,简称 IMFs)的能量占比作为特征向量,有效识别出管道的运行状态和阻塞程度。刘源^[7]针对脑机接口信号提出了 MEMD 和区间最

大功率相结合的特征提取方法,验证了 MEMD 算法在处理多通道非平稳脑电数据的有效性。

样本熵是由 Richman 等^[8]提出的一种系统复杂度的测度方法,是取条件概率的自然对数,该方法不进行自我匹配度计算,可以克服在计算近似熵时会出现的偏差^[9],其优点是较少依赖数据长度,计算速度更快且精度更高,非常适合机械振动信号的分析。赵志宏等^[10]将小波包变换和样本熵相结合用于滚动轴承的故障诊断,得到了较好的分类效果。文静等^[11]结合 EMD 和样本熵,有效区分出弯管信号和泄露信号,解决了弯管噪声引发的多个相关峰的定位不准确问题。

针对高速列车振动信号特征,笔者提出一种基于 FVSE 算法的高速列车转向架故障特征提取方法。首先,将高速列车转向架的振动信号进行 NAMEMD;其次,利用相关系数法选取与原始信号最相关的 IMFs 进行 FVSE 特征提取作为特征向量;最后,将特征向量作为支持向量机的输入对列车运行状态进行识别,实验分析验证了该方法的有效性。

1 噪声辅助 MEMD 方法

高速列车数据是非线性、非平稳的,而传统的信号处理方法存在一定的局限性。MEMD 方法可将多个通道信号联合在一起进行分析,保证了各通道

^{*} 国家自然科学基金重点资助项目(61134002)
收稿日期:2018-10-22;修回日期:2018-12-20

分解出来的 IMF 分量在个数和频率上相匹配,有效缓解了模态混叠问题,其算法步骤^[12]如下。

设一个 n 维向量组为 $\mathbf{m}(t) = \{m_1(t), m_2(t), \dots, m_n(t)\}$, $\mathbf{D}^{\alpha_k} = \{d_1^{\alpha_k}, d_2^{\alpha_k}, \dots, d_n^{\alpha_k}\}$ 为在 $n-1$ 维球面上对应角 $\alpha^k = \{\alpha_1^k, \alpha_2^k, \dots, \alpha_{n-1}^k\}$ 的方向向量集。若要在球面空间建立 K 个方向向量,则 $k=1, 2, \dots, K$ 。

1) 利用 Hammersley 序列采样法选择一组合适的方向向量 \mathbf{D} ;

2) 针对所有 k , 计算沿着第 k 个方向向量 \mathbf{D}^{α_k} 的输入信号 $\mathbf{m}(t)$ 的第 k 个投影 $p^{\alpha_k}(t)$;

3) 找出对应所有 k 的投影信号的最大值 $p^{\alpha_k}(t)$ 的时刻 $t_i^{\alpha_k}$;

4) 在 $[t_i^{\alpha_k}, \mathbf{m}(t_i^{\alpha_k})]$ 上使用多元样条插值函数内插, 获得所有 k 的多维包络 $\mathbf{E}^{\alpha_k}(t)$;

5) 计算均值

$$s(t) = \frac{1}{K} \sum_{k=1}^K \mathbf{E}^{\alpha_k}(t) \quad (1)$$

6) 计算 $\mathbf{d}(t) = \mathbf{m}(t) - s(t)$ 。如果 $\mathbf{d}(t)$ 满足多元 IMF 的迭代终止条件, 则将 $\mathbf{d}(t)$ 定义为 IMF, 并对 $\mathbf{m}(t) - \mathbf{d}(t)$ 从步骤 2 开始重复, 直到得到新的 IMF; 如果不满足, 则对 $\mathbf{d}(t)$ 从步骤 2 开始重复。

噪声辅助多元经验模态算法^[13]是在原始 n 维信号中添加 m 维高斯白噪声通道信号做 $(n+m)$ 维 MEMD 分解, 剔除 m 维噪声通道分解的结果, 保留原始 n 维信号的分解结果。

2 全矢样本熵算法

2.1 全矢谱理论

假设有同一截面上相互垂直的两个方向上的传感器采集到的离散信号 $\{x_n\}$ 和 $\{y_n\}$ ($n=0, 1, \dots, N-1$), 其快速傅里叶变换 (fast Fourier transform, 简称 FFT) 为 $\{X_k\}$ 和 $\{Y_k\}$ ($k=0, 1, \dots, N-1$), 得到 X_k 的实部和虚部分别为 $X_{\text{Re}k}$ 和 $X_{\text{Im}k}$, Y_k 的实部和虚部分别为 $Y_{\text{Re}k}$ 和 $Y_{\text{Im}k}$ 。得到 $\{x_n\}$ 和 $\{y_n\}$ 中的第 k 阶谐波在 x 方向的振幅和相位分别为

$$A_{xk} = \sqrt{X_{\text{Re}k}^2 + X_{\text{Im}k}^2} \quad (2)$$

$$\varphi_{xk} = \arctan \frac{X_{\text{Im}k}}{X_{\text{Re}k}} \quad (3)$$

同理可得第 k 阶谐波在 y 方向的振幅和相位分别为

$$A_{yk} = \sqrt{Y_{\text{Re}k}^2 + Y_{\text{Im}k}^2} \quad (4)$$

$$\varphi_{yk} = \arctan \frac{Y_{\text{Im}k}}{Y_{\text{Re}k}} \quad (5)$$

根据文献^[14], 谐波的融合能量等于基于谐波轨迹主振矢 R_{lk} 和副振矢 R_{sk} 的融合强度能量之和,

且谐波轨迹的主振矢和副振矢的平方和与信号在 x, y 方向的幅值平方和相等, 即

$$R_{lk}^2 + R_{sk}^2 = A_{xk}^2 + A_{yk}^2 \quad (6)$$

将 $A_k = \sqrt{A_{xk}^2 + A_{yk}^2}$ 作为幅值, 分别将 φ_{xk} 和 φ_{yk} 作为相位, 得到以下新的序列

$$X_{k'} = A_k (\cos \varphi_{xk} + j \sin \varphi_{xk}) \quad (7)$$

$$Y_{k'} = A_k (\cos \varphi_{yk} + j \sin \varphi_{yk}) \quad (8)$$

再对序列进行快速傅里叶反变换 (inverse fast Fourier transform, 简称 IFFT), 得到一组新的离散时间信号 $\{x_{k'}\}$ 和 $\{y_{k'}\}$ ($k'=0, 1, \dots, N-1$)。

可以看出, 以上变换不会改变原始信号的相位, 只是融合了原始信号的振幅, 得到的新序列也更加完善地反映出两个通道采集的信息。

2.2 FVSE 算法

FVSE 算法是先通过全矢谱技术对同源双通道采集到的信号做信息融合处理, 获得相位不变、信息更完善的全矢信号, 再对全矢信号进行样本熵计算。样本熵通常用来描述时间序列的复杂度和规则性, 但只能对单一传感器的振动信号进行特征提取, 得到的结果具有片面性^[15]。全矢谱技术的优势在于可以融合不同通道的信息, 保证信号的完整性, 最大程度地包含故障信号的振动信息, 增加了故障诊断的可靠性。将离散时间信号 $\{x_{k'}\}$ 和 $\{y_{k'}\}$ ($k'=0, 1, \dots, N-1$) 分别作为样本熵的输入时间序列来计算全矢样本熵。全矢样本熵的计算步骤如下:

1) 设在 n 种工况下测得相互垂直方向上的振动信号为 $\{x_n\}$ 和 $\{y_n\}$ ($n=0, 1, \dots, N-1$), 记做 V_1, V_2, \dots, V_n ;

2) 采用全矢谱算法对 V_1, V_2, \dots, V_n 做信息融合, 得到融合后新的时间序列 $\{x_{k'}\}$ 和 $\{y_{k'}\}$ ($k'=0, 1, \dots, N-1$), 记做 $V_1, V_2, \dots, V_{k'}$;

3) 设定样本熵算法中参数嵌入维数 $m=2$, 相似容限 r 取 0.2 倍的数据标准差^[16], 对新的时间序列进行样本熵计算, 得到全矢样本熵值。

两组新的时间序列得到的结果是融合了两个通道信息后的结果, 相比于单一通道, 全矢样本熵能反映出更完善的信息。图 1 为全矢样本熵算法流程图。

3 全矢样本熵实验

3.1 数据来源与预处理

数据由 SIMPACK 仿真软件仿真所得, 转向架

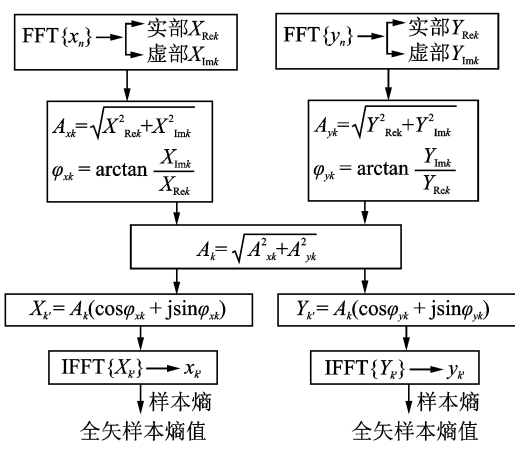


图1 全矢样本熵算法流程图

Fig. 1 Flowchart of full vector sample entropy algorithm

故障工况包括8个抗蛇形减振器单个失效的8种单点故障工况、列车正常工况、横向减振器全拆工况、抗蛇形减振器全拆工况、空簧失气工况与3种单故障工况的两两混合工况(空簧失气+横向减振器全拆工况、空簧失气+抗蛇形减振器全拆工况、抗蛇形减振器全拆工况+横向减振器全拆工况)。仿真数据记录了安装在转向架上的58个传感器反馈到各部位在不同速度下的振动信号。针对笔者提出的基于FVSE算法的转向架故障特征提取方法,实验选取各同源双通道采集的信号做处理分析。图2为8个抗蛇形减振器单个失效时的时频域图。可以看出,各工况的时频域图区别不大,仅从时频域分析是不能区分出这8种工况的。

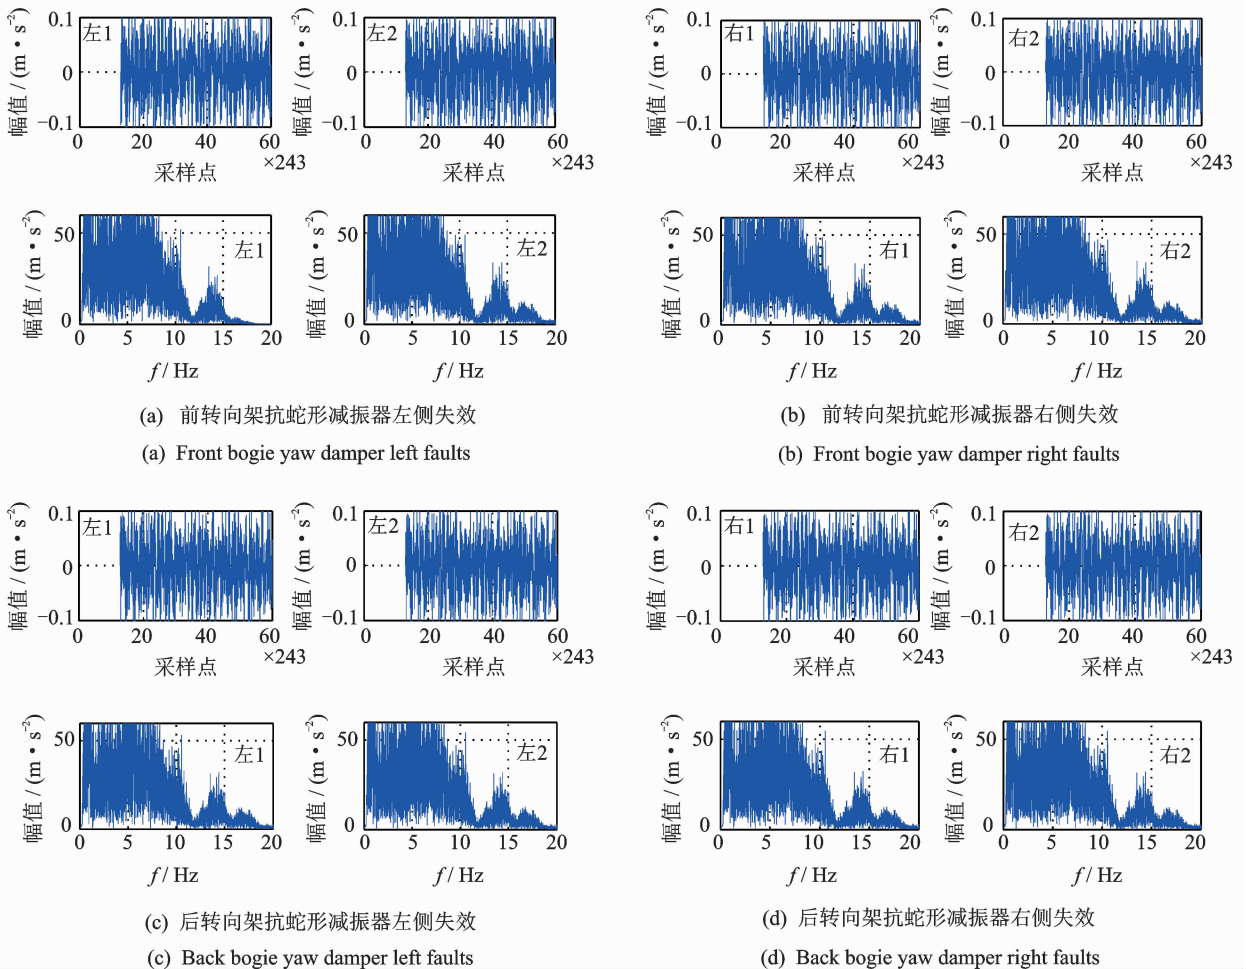


图2 抗蛇形减振器8种故障工况的时频域图

Fig. 2 Time and frequency domain diagrams of eight fault conditions of yaw damper

经NAMEMD分解后得到一系列多元IMFs,为了从中选取出有效的IMFs,采用相关系数法求出各IMF分量与原始信号的互相关系数。表1为8种工况的IMF分量与原始信号的互相关系数。

可以看出,8种工况的前6个IMF分量与原始信号的互相关系数比其他分量,因此选取 $IMF_1 \sim IMF_6$ 。这6个分量做进一步特征提取,可以反映出原始信号的大部分信息。

表 1 8 种工况的 IMF 分量与原始信号的互相关系数

Tab. 1 Correlation of IMF components and original signals of eight working conditions

分量	抗蛇形减振器失效类型							
	前转向架左 1 失效	前转向架左 2 失效	前转向架右 1 失效	前转向架右 2 失效	后转向架左 1 失效	后转向架左 2 失效	后转向架右 1 失效	后转向架右 2 失效
IMF ₁	0.126 8	0.129 1	0.060 8	0.083 7	0.092 0	0.111 0	0.068 4	0.086 0
IMF ₂	0.751 3	0.73 19	0.700 7	0.717 8	0.737 5	0.743 5	0.659 2	0.677 8
IMF ₃	0.650 1	0.668 2	0.704 8	0.688 8	0.667 3	0.661 5	0.730 3	0.720 7
IMF ₄	0.301 9	0.311 2	0.329 6	0.316 0	0.301 9	0.299 4	0.359 9	0.334 7
IMF ₅	0.129 6	0.134 5	0.144 6	0.135 5	0.131 0	0.127 0	0.153 8	0.141 4
IMF ₆	0.053 4	0.055 8	0.059 4	0.054 2	0.051 3	0.054 5	0.066 2	0.060 1
IMF ₇	0.015 9	0.017 7	0.019 5	0.017 6	0.016 6	0.016 9	0.022 5	0.019 2
IMF ₈	0.004 8	0.005 1	0.005 1	0.005 0	0.004 3	0.004 8	0.006 2	0.004 9

3.2 基于 FVSE 的特征提取和分类

3.2.1 抗蛇形减振器单个失效的特征提取和分类

将 8 种工况在 200 km/h 速度下的数据分为 100 组,每组 486 个采样点,分别采用样本熵算法和 FVSE 算法得到 8 种工况 IMF₁~IMF₆ 这 6 个分量的特征值。分别提取 2 种算法下得到的 IMF₁~IMF₃ 分量和 IMF₄~IMF₆ 分量的特征值作为三维特征向量集的取值。图 3 为 8 种工况下两种特征的三维空间散点图。图 3(a)和图 3(b)分别为采用 2 种算法得到 IMF₁~IMF₃ 分量的特征值构成的特

征空间分布图。可以看出,根据其特征分布可以较好地分辨出前转向架抗蛇形减振器左一失效、左二失效和右一失效工况,且采用全矢样本熵算法得到的特征值组成的特征空间能更好的聚类,各工况特征也分得更开。图 3(c)和图 3(d)分别为采用 2 种算法得到 IMF₄~IMF₆ 分量的特征值构成的特征空间分布图。可以看出,根据其特征分布可以较好地分辨出前转向架抗蛇形减振器右二失效、后转向架抗蛇形减振器左一失效、左二失效工况,且采用 FVSE 算法得到的特征值还可以较好地区分后转向架抗蛇形减振器右一失效、右二失效工况。可见,采

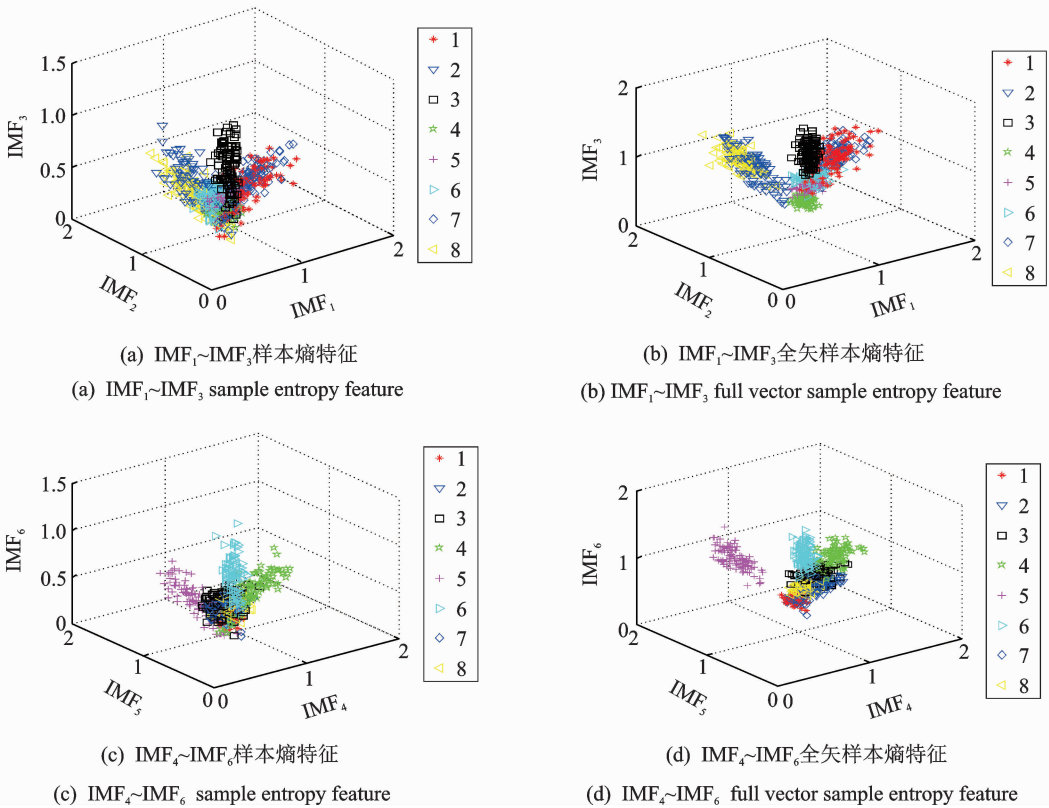


图 3 8 种工况下两种特征的三维空间散点图

Fig. 3 Scatter diagram of two features in 3-D space at eight working conditions

用 FVSE 算法在三维空间中能看到更好的类内聚集性和类间分离性。

支持向量机是针对有限的样本训练和分类的机器学习方法,是根据结构风险最小化的原则而提出的^[17]。统计学习理论在传统统计学上做了补充,可以有效解决小样本量和高维模式识别等问题,广泛应用于数据挖掘、人脸识别及回归分析等领域。实验分别提取 $IMF_1 \sim IMF_6$ 。这 6 个分量的样本熵特征和全矢样本熵特征作为支持向量机的输入,截取 48 600 个采样点,每 486 个采样点为一组,共分为 100 组。对每种工况都选择 100 组样本,其中 80 组用来训练,20 组用来测试。8 种工况一共得到 800 组样本,640 组用来训练,160 组用来测试。实验选择的核函数为径向基核函数。表 2 为两种特征提取算法的正确识别率。

表 2 两种特征提取算法的正确识别率


Tab. 2 Correct recognition rate of two feature extraction algorithms %

监测信号	NAMEMD+样本熵	NAMEMD+ FVSE
车体加速度	76.25	82.50
车体位移	71.25	78.75
轴箱 1	80.00	83.75
构架 1 架加速度	85.625	91.875
构架 2 架加速度	82.50	98.125
构架 2 架位移	73.125	79.375

分析表 2 可知,基于 NAMEMD+样本熵算法的识别率总体在 70% 以上,最高可达到 85% 左右,对于抗蛇形减振器单个失效工况识别来说是比较满意的结果,因为 8 种工况的时频域图是较难区分开这几种故障工况的。基于 NAMEMD+ FVSE 特征提取算法效果总体上都优于基于 NAMEMD+样本熵,普遍提高了约 6 个百分点,且某些通道的识别率在 90% 以上。其中,构架 2 加速度信号的识别率有大幅度提高,达到了约 16 个百分点,且几乎能够百分百识别。这也验证了笔者提出方法的有效性。可见,在实际监测过程中通过分析识别率较高的通道采集信息,可以较准确地得到列车的运行状态。


3.2.2 7 种混合工况的特征提取和分类

列车在实际运行中不会只出现单个减振器故障的情况,因此实验选取了列车正常工况、横向减振器全拆工况、抗蛇形减振器全拆工况、空簧失气工况与 3 种单故障工况的两两混合工况,共 7 种混合工况作为研究对象进行实验验证。对 7 种混合工况在 200 km/h 的数据进行 NAMEMD,计算得到各 IMF 分量与原始信号的互相关系数。结果表明,前 6 个 IMF 分量与原始信号的相关性最大,计算前 6 个 IMF 分量的 FVSE 值作为特征向量。图 4 为 7 种



(a) $IMF_1 \sim IMF_3$ 全矢样本熵特征

(a) $IMF_1 \sim IMF_3$ full vector sample entropy feature



(b) $IMF_4 \sim IMF_6$ 全矢样本熵特征

(b) $IMF_4 \sim IMF_6$ full vector sample entropy feature

图 4 7 种工况下全矢样本熵特征的三维空间分布

Fig. 4 Scatter diagram of full vector sample entropy in 3-D feature space at seven working conditions

工况下全矢样本熵特征的三维空间分布。图 4(a)和图 4(b)分别为 $IMF_1 \sim IMF_3$ 和 $IMF_4 \sim IMF_6$ 分量的全矢样本熵值构成的特征空间分布。从图 4(a)可以看出,根据其特征分布可以较好地分辨出正常工况、空簧失气工况和横向减振器全拆工况。从图 4(b)可以看出,根据其特征分布可以较好地分辨出抗蛇形减振器全拆工况、空簧失气+横向减振器全拆工况和空簧失气+抗蛇形减振器全拆工况。可见,采用全矢样本熵值作为特征值的识别效果很好。表 3 为 7 种混合工况在 200 km/h 速度下不同通道的正确识别率。

表 3 7 种混合工况不同通道的正确识别率

Tab. 3 Recognition rate of seven working states in different channel %

监测信号	NAMEMD+样本熵	NAMEMD+ FVSE
车体加速度	86.428 6	93.571 4
车体位移	85	90
构架 1 架加速度	84.285 7	88.571 4
构架 2 架加速度	90	96.428 6
构架 2 架位移	87.857 1	92.857 1

从表 3 可以看出,结合 NAMEMD+样本熵算法对这 7 种混合工况的识别率较高,基本在 85% 以上,说明了样本熵特征提取算法的可行性。采用

NAMEMD+ FVSE 算法的结果普遍提高了 6 个百分点左右,基本都能达到 90% 以上的识别率,验证了该算法对 7 种混合工况故障识别的有效性。

笔者提出的基于 FVSE 算法的高速列车转向架故障特征提取方法充分考虑了信号之间的信息融合,更能将各通道信号之间的特征反映出来,从而获得更高的识别率。由于目前许多故障检测都将对多个传感器采集到的信号进行处理,因此将全矢样本熵特征提取方法应用于其中更具有现实意义。

4 结束语

笔者针对多通道信号处理,考虑到传统样本熵算法对高速列车状态识别的有效性,以及传统算法对于单通道传感器的振动信号处理的片面性,提出了一种基于 FVSE 算法的高速列车转向架故障特征提取方法。首先,通过 NAMEMD 方法将高速列车 8 个抗蛇形减振器单个失效工况的振动信号数据进行分解,得到一系列的多元 IMF_s;其次,根据相关系数法选择前 6 个 IMF 分量计算其全矢样本熵值构成支持向量机分类器的 6 维输入信号,对列车的运行状态进行识别,和传统样本熵相比得到了更高的识别率,采用全矢样本熵的结果平均提高了约 6 个百分点,最高可以达到 98% 以上,说明了对蛇形减振器单个失效工况识别的有效性。同时采用 NAMEMD+ FVSE 算法在 7 种混合工况的识别也取得了令人满意的效果。实验结果证明, FVSE 算法在处理多通道信号上有一定的优势,在高速列车故障检测中具有应用价值。

参 考 文 献

- [1] 李潭. 基于分形理论的高速列车状态分析与故障诊断研究[D]. 成都:西南交通大学, 2015.
- [2] REHMAN N, MANDIC D P. Multivariate empirical mode decomposition[J]. Proceedings of the Royal Society A, 2010, 466(2117): 1291-1302.
- [3] PARK C, LOONEY D, Ur REHMAN N, et al. Classification of motor imagery BCI using multivariate empirical mode decomposition[J]. IEEE Transactions on Neural Systems & Rehabilitation Engineering a Publication of the IEEE Engineering in Medicine & Biology Society, 2013, 21(1):10-22.
- [4] MINSUNG K, DANILO P M, ANTHONY G C. Theory of digital filter banks realized via multivariate empirical mode decomposition[J]. Advances in Adaptive Data Analysis, 2014, 6(1): 1450001.
- [5] MOSTAFANEZHADI I, YAVARI E, BORIC-LUBECKE O, et al. Cancellation of unwanted Doppler radar sensor motion using multivariate empirical mode decomposition[J]. IEEE Sensors Journal, 2013, 13(5): 897-1904.
- [6] 张浩, 邹金慧, 冯早. 基于 MEMD 的管道阻塞声信号特征提取与识别方法[J]. 传感器与微系统, 2017, 36(12): 57-60.
- [7] ZHANG Hao, ZOU Jinhui, FENG Zao. Feature extraction and recognition method of pipeline blockage acoustic signal based on MEMD [J]. Transducer and Microsystem Technologies, 2017, 36(12):57-60. (in Chinese)
- [7] 刘源. 基于多元 EMD 的 BCI 信号处理研究[D]. 秦皇岛:燕山大学, 2013.
- [8] RICHMAN J S, LAKE D E, MOORMAN J R. Sample entropy[J]. Methods in Enzymology, 2004, 384(384): 172-184.
- [9] 秦娜. 高速列车转向架故障的信息熵测度特征分析方法研究[D]. 成都:西南交通大学, 2014.
- [10] 赵志宏, 杨绍普. 基于小波包变换与样本熵的滚动轴承故障诊断[J]. 振动、测试与诊断, 2012, 32(4): 640-644.
- [11] ZHAO Zhihong, YANG Shaopu. Roller bearing fault diagnosis based on wavelet packet transform and sample entropy[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(4): 640-644. (in Chinese)
- [11] 文静, 张敏姿, 张恒. 90°弯管存在下的供水管道泄漏定位研究[J]. 振动与冲击, 2018, 37(6):92-98.
- [12] WEN Jing, ZHANG Minzi, ZHANG Heng. Water supply pipeline leakage location in the presence of 90° bend[J]. Journal of Vibration and Shock, 2018, 37(6):92-98. (in Chinese)
- [12] ZHAO X M, PATEL T H, MING J. Multivariate EMD and full spectrum based condition monitoring for rotating machinery[J]. Mechanical Systems and Signal Processing, 2012, 27: 712-728.
- [13] 吴志丹. 基于 MEMD 的高速列车安全性态评估应用研究[D]. 成都:西南交通大学, 2017.
- [14] 韩捷, 石来德. 旋转机械的全信息能量谱分析方法研究[J]. 机械强度, 2003(4):364-368.
- [15] HAN Jie, SHI Laide. Study of full information energy spectrum analysis method of rotary machinery [J]. Journal of Mechanical Strength, 2003(4):364-368. (in Chinese)
- [15] 陈磊. 基于全矢谱的设备故障预测方法研究[D]. 郑州:郑州大学, 2018.
- [16] 王新沛, 杨静, 李远洋, 等. 基于样本熵快速算法的心音信号动力学分析[J]. 振动与冲击, 2010, 29(11): 115-118.
- [17] WANG Xinpei, YANG Jing, LI Yuanyang, et al. Dynamic analysis of heart sound signal with a sample entropy fast algorithm [J]. Journal of Vibration and Shock, 2010, 29(11): 115-118. (in Chinese)
- [17] VAPNIK V. The nature of statistical learning theory [M]. New York: Springer, 1995: 1-188.



第一作者简介:李亚兰,女,1995年4月生,硕士生。主要研究方向为智能信息处理及模式识别。
E-mail:liyalan_lyl@163.com

