

# 基于熵特征的高速列车故障诊断方法<sup>\*</sup>

朱 明<sup>1,2</sup>, 吴思东<sup>2</sup>, 付克昌<sup>1</sup>

(1. 成都信息工程学院控制工程学院 成都, 610225) (2. 西南交通大学电气工程学院 成都, 610031)

**摘要** 高速列车运行状态正常与否对列车系统的安全性和舒适度有重要影响,为分析高速列车运行状态,根据高速列车振动加速度信号的特点,提出了分割能量熵和奇异熵的故障诊断方法。首先,分析列车振动信号随速度变化的特点,对不同速度下的信号进行不同频率范围的分析;其次,对分析范围内信号分割成  $N$  个区间,计算分割能量熵和奇异熵,将分割能量熵特征和奇异熵组成特征向量;最后,利用支持向量机进行故障分类识别。实验数据仿真分析结果表明,车体中、后部横向加速度信号特征对四种典型工况在不同速度下分类识别率均较高,达到 95% 以上,说明该方法能有效识别出高速列车故障状态。

**关键词** 高速列车; 振动加速度信号; 分割能量熵; 奇异熵; 支持向量机

**中图分类号** U283.2

## 引 言

随着铁路运行大规模提速,高速列车的投入运行,高速列车运行的安全性和舒适性受到广泛关注。分布在高速列车各个位置的传感器能实时检测到海量的数据,这些数据蕴含了大量反映列车故障状态和故障程度的信息。利用这些数据,提取出可以反映故障状态同时具有普遍适应性的特征,以特征分析的方式表征高速列车的安全性态,对故障诊断具有重要意义。

列车在高速运行时,其关键部件可能产生故障<sup>[1]</sup>,高速列车上的传感器监测的振动信号可以反映运行状态正常与否<sup>[2]</sup>。列车的关键部件发生故障时,相对于正常状态,频带能量分布会发生变化。而熵特征是用来描述系统的不确定性度和复杂度的特征,熵值越大表明系统复杂度越高,越紊乱。因此,提取振动信号的熵特征能反映高速列车的运行状况。

现分析四种工况下振动信号的特征,针对振动信号的特征,提出一种分割能量熵特征,并提取信号的奇异熵特征,再用支持向量机(support vector machine, 简称 SVM)进行故障诊断。实验结果表明,该特征提取方法能有效提取列车关键部件的故障特征,且故障识别率较高。

## 1 高速列车的振动信号分析

车辆在运行中会受到轨道不平顺激励<sup>[3]</sup>,这是各种振动产生的主要根源,随着速度的提高,列车的振动幅度增大<sup>[4]</sup>。列车在正常运行时,转向架各位置的振动都呈现出较强的规律性,当转向架关键部件出现故障和失效时,这种规律振动会改变,从而呈现出在故障状态下特有的振动规律,并且不同的故障位置振动规律是有区别的<sup>[5-9]</sup>。

选取高速列车转向架的正常状态和三种典型故障状态(横向减振器失效、抗蛇形减振器失效<sup>[10]</sup>、空气弹簧失气<sup>[11]</sup>)进行对比试验,分析试验采集的高速列车转向架各部件振动信号。图 1 为 4 种工况的车体前部横向加速度在 160 km/h 时的时域图和频域图,其中采样频率为 243 Hz。

由于车体振动多为低频振动,所以选择巴特沃斯滤波器将 25 Hz 以上的信号滤掉。由图 1 可以看出,列车转向架前部抗蛇形减振器故障时横向加速度最大,振动频率集中在 2 Hz 左右;动车横向减振器故障在 1~2 Hz 左右有较敏感的振动频率;空气弹簧失气故障与正常工况的差异表现不太明显,但是在 1 Hz 左右频率振动幅值也明显比正常工况大。因此可以对四种典型工况振动信号在频域进行特征提取,从而诊断出不同的列车故障,保障高速列车运

<sup>\*</sup> 国家自然科学基金重点资助项目(61134002);四川省科技厅科技支撑计划资助项目(2014GZ0009);四川省科技厅应用基础研究资助项目(2015JY0257)中国博士后基金资助项目(2012M511939);航空科学基金资助项目(201210P8003);四川省教育厅自然科学基金重点资助项目(14ZA0171)

收稿日期:2013-09-17;修回日期:2013-11-25

行的安全性。

随着列车运行速度的提高,列车的振动幅值都会有相应的增大,而频谱能量也会相应增大。图2

为四种工况的车体前部横向加速度在80,120,160,200 km/h 种速度下的频率幅值图,4种速度下频率范围分别为0~10 Hz,0~15 Hz,0~20 Hz和

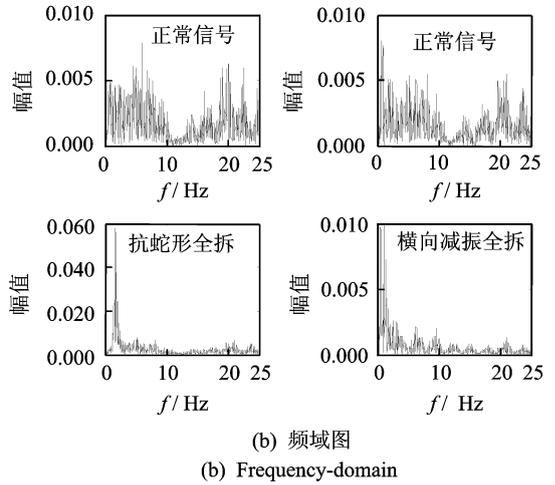
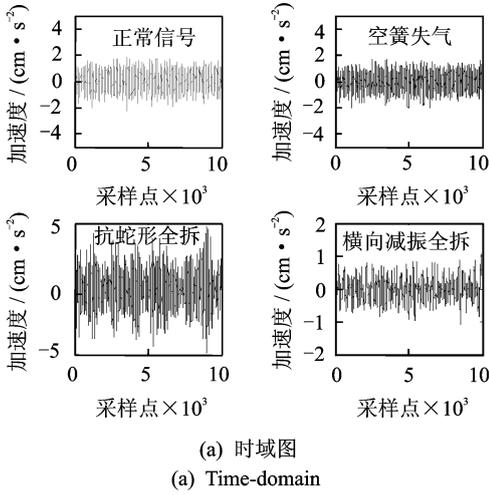


图1 4种工况时频域

Fig.1 Time-domain and frequency-domain graph of four working conditions

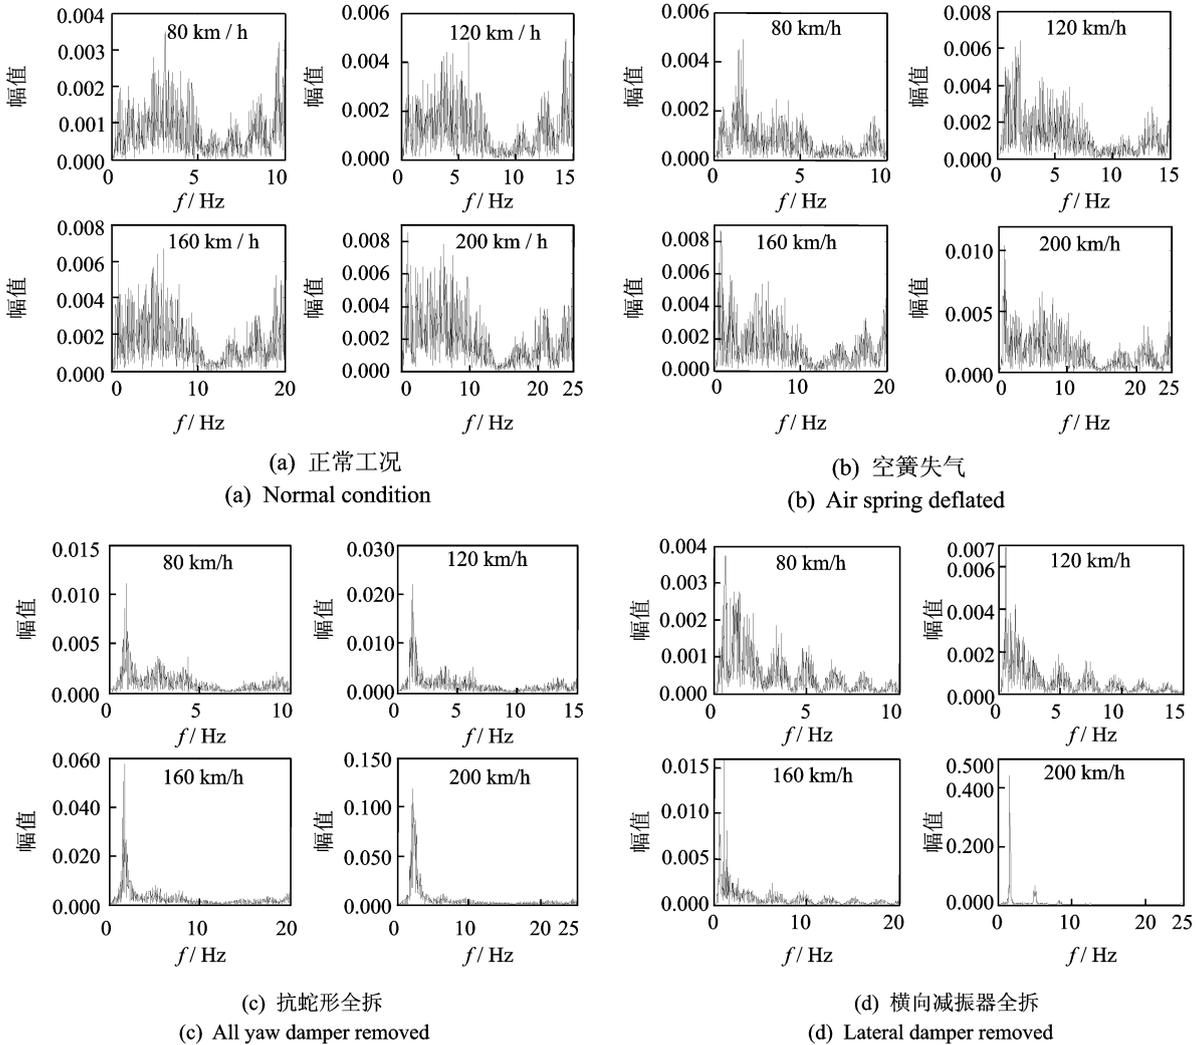


图2 4种工况不同速度频谱

Fig.2 Frequency-domain graph of four conditions in different speed

0~25 Hz。可以看出,随着速度提高,频率范围线性增加。

由图 2 可看出,随着速度提高,正常工况下的信号频率幅值会整体增大,并且振动频率也会线性增加,而其他 3 种故障工况都明显的峰值频率。表 1 是 3 种故障工况在不同速度下的幅值峰值所在频率。

表 1 不同工况不同速度下峰值频率

Tab. 1 Peak frequency of different working conditions in different speed Hz

运行速度/ (km · h <sup>-1</sup> )	80	120	160	200
空簧失气	1.738 3	2.080 1	0.878 9	0.878 9
抗蛇形减振故障	0.947 3	1.362 3	1.796 9	2.246 1
横向减振故障	0.625 0	0.678 3	1.171 9	1.684 6

由表 1 和图 2 可以看出,空气弹簧失气故障时,在 1~2 Hz 左右频域幅值增加明显,其他频率幅值有所增长,但相比 1~2 Hz 增长较小;抗蛇形减振器故障时,随着速度增长,峰值频率线性增大,其他频率幅值有所增长,但相对于峰值增长较小;横向减振故障时,随着速度增长,能谱峰值也有增大,同时其他频率处的幅值也有所增长,但相对于峰值增长较小。由此可见,在不同速度下,针对转向架各位置的振动信号在不同的频率范围内的频域图,可以实现不同工况的有效区分。为了便于分析,本文设定频率取值范围  $f_1$  有:  $f_1/v_1=10$  Hz/80 km/h。

## 2 熵特征提取

### 2.1 分割能量熵

信息熵是 Shannon 在 1948 年提出的概念<sup>[12]</sup>,信息熵可以表示信息的不确定性大小。列车系统振动与行车速度和路径有关,是复杂的耦合关系。通过分析可知,当转向架关键部件发生异常时,振动信号的频域会在某个频率范围产生与正常工况时不同的规律。不同的部件发生故障,振动变化的规律也有区别。因此,将信号频率划分为  $N$  个区间,提取分割区间频域信号的能量熵特征。下面给出具体的算法步骤。

#### 1) 信号预处理

设振动信号为  $S$ ,利用巴特沃斯滤波器将 25 Hz 以上的信号滤掉,把  $S$  通过 FFT 变换到频域,得到频域信号  $F(i), i=1, 2, \dots, n$ ,为方便处理,提取  $n=1\ 024$ 。

#### 2) 计算分割区间能量

将信号  $F$  划分成  $N$  个区间,区间划分个数不能太多也不能太少,太多会使得能量熵特征对信号的

变化过于敏感,太少又会导致能量熵特征对信号的变化不敏感,这都会导致故障诊断识别的不准确。经过大量实验,划分区间  $s_e=8$ ,每个区间数  $n_u=128$  时,熵特征效果较好。求各个区间的能量

$$E(j) = \sum_{i=1}^{n_u} F(i+(j-1) \cdot n_u)^2 \quad (j=1, 2, \dots, s_e) \tag{1}$$

#### 3) 求分割能量熵值

设  $p_j=E(j)/E$ ,且  $E = \sum_{j=1}^{s_e} E(j)$ ,则熵值计算公式为

$$W_E = - \sum_j p_j \log p_j \tag{2}$$

得到分割能量熵  $W_E$ ,同时记录  $mP = \max(p_j)$  值,得到特征向量  $C=[W_E, mP]$ 。

## 2.2 奇异熵

奇异熵是基于奇异值分解理论,将信号频域划分区间的不同频率矩阵分解为能够反应区间能量基本特征的奇异值,利用信息熵对奇异值集合的不确定性进行分析,从而对信号频域的复杂程度给出的度量<sup>[13]</sup>。下面给出具体步骤。

#### 1) 信号预处理

设振动信号为  $S$ ,利用巴特沃斯滤波器将 25 Hz 以上的信号滤除掉,把  $S$  变换到频域,得到频域信号  $F(i), i=1, 2, \dots, n$ ,其中  $n=1\ 024$ 。

#### 2) 区间频率矩阵

将信号  $F$  划分为  $s_e=8$  个区间,每个区间数为  $n_u=128$ ,构成一个  $s_e \cdot n_u$  的矩阵  $M$

$$M = \begin{bmatrix} F(1) & F(2) & \dots & F(n_u) \\ F(n_u+1) & F(n_u+2) & \dots & F(2 \cdot n_u) \\ \vdots & \vdots & \vdots & \vdots \\ F((s_e-1) \cdot n_u+1) & F((s_e-1) \cdot n_u+1) & \dots & F(s_e \cdot n_u) \end{bmatrix} \tag{3}$$

#### 3) 求奇异熵

设  $p_j = -(\lambda_j / \sum_{j=1}^l \lambda_j) \log(\lambda_j / \sum_{j=1}^l \lambda_j)$ ,假设  $\sigma$  为 MMH 的特征值,则  $\lambda = \sqrt{\sigma}$  为奇异值,其中  $\lambda_j$  为第  $j$  行奇异值,  $l=8$ 。计算得到奇异熵  $W_{SE}$

$$W_{SE} = - \sum_{j=1}^l p_j \tag{4}$$

## 3 算例分析

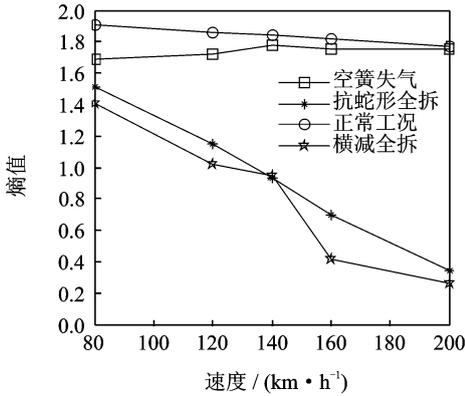
### 3.1 试验数据的熵特征

为了分析高速列车转向架关键部件故障状态,

全部试验数据均来自西南交通大学牵引动力实验室。数据为某型号动车组转向架振动故障仿真数据,记录了包括车体、构架、轴箱上各个位置纵向、横向以及垂向 3 个方向的振动加速度和车体、构架、轮对、一系、二系各部委 3 个方向的振动位移,共 58 个通道数据。转向架工况包括:正常工况(无故障状态)、横向减振器故障、空气弹簧失气、抗蛇形减振器故障四种情况。每种工况下运行速度按 80, 120,

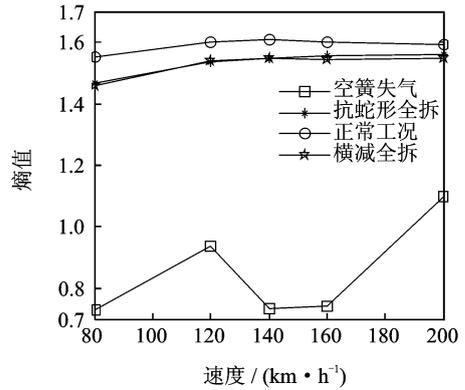
140, 160, 200 km/h, ..., 递增,直至失稳停机。采样频率为 243 Hz。

利用上述特征提取方法对每种速度下四种不同工况的 30 个加速度通道信号进行特征提取,得到其对应的特征向量  $Cv = [W_E, mP, W_{SE}]$ , 每种速度下,每个通道的 4 种工况可以得到 125 组特征向量。图 3 是车体前部横向加速度和中部垂向加速度在不同速度下的特征均值图。



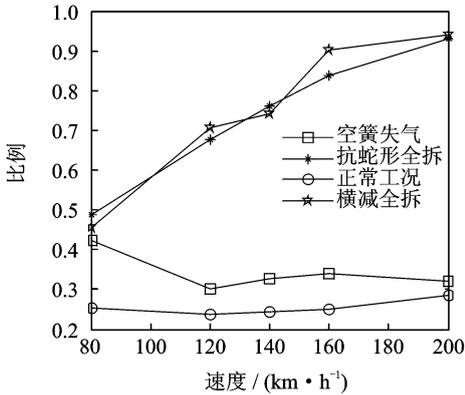
(a) 1通道分割能量熵

(a) Segmentation-energy entropy of channel 1



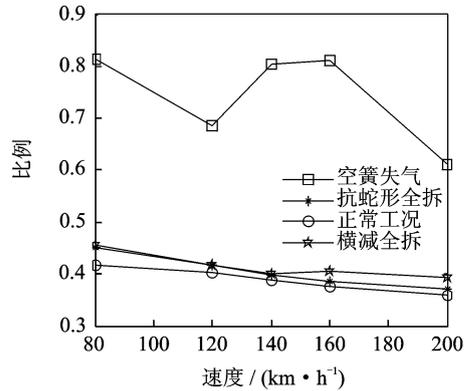
(b) 4通道分割能量熵

(b) Segmentation-energy entropy of channel 4



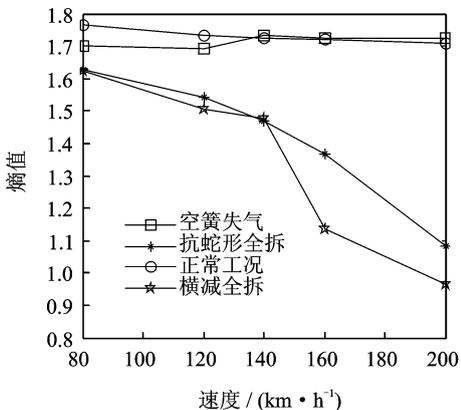
(c) 1通道最大能量比例

(c) Largest proportion of energy of channel 1



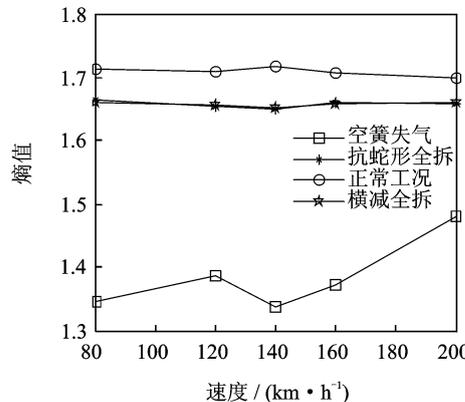
(d) 4通道最大能量比例

(d) Largest proportion of energy of channel 4



(e) 1通道奇异熵

(e) Singular entropy of channel 1



(f) 4通道奇异熵

(f) Singular entropy of channel 4

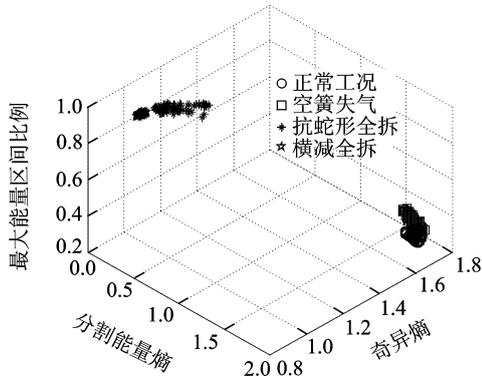
图 3 不同速度下熵特征均值

Fig. 3 Mean of entropy feature value in different speed

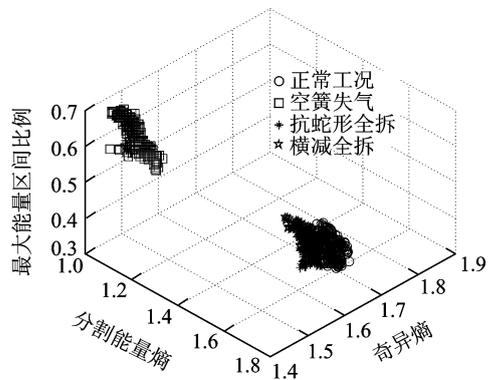
由图 3 可以看出,对于车体前部横向加速度特征,正常工况和空气弹簧失气故障 3 种特征都比较接近,而且随着速度增加,特征稳定性较高;抗蛇形减振器全拆和横向减振器全拆故障比较接近,并且随着速度增加,特征变化较大。结合图 2 知,特征变化较大主要是由于随着速度增加,这两种故障工况峰值频谱幅值增长比其他频率快,使得复杂度减小,熵值也减小。同时,图 3 也表示了车体中部垂向加速度特征,通过比较横向和垂向加速度特征,正常工

况特征都比较稳定,与正常工况相比,抗蛇形减振器全拆故障和横向减振器全拆故障在横向加速度特征上差异较大,而空气弹簧失气故障则在垂向加速度特征上差异较大。

图 4 是 200 km/h 下两种不同通道信号的特征向量分布图。从图 4 可以看出,在熵特征中,各个故障状态下得到的特征值是不尽相同的,这也说明了各种工况下的信号复杂度是不同的。



(a) 1通道-车体前部横向加速度信号  
(a) Lateral acceleration signal of car body



(b) 4通道-车体中部垂向加速度信号  
(b) Vertical acceleration signal of car body

图 4 不同位置信号的特征分布

Fig. 4 Feature distribution of different position signals

### 3.2 基于 SVM 的故障诊断

由于 SVM 对解决小样本、非线性的特征分类有很大的优势<sup>[14]</sup>,为验证对高速列车转向架故障信号提取的特征的有效性,故选取 OISVM(on-line independent support vector machines)<sup>[15]</sup>对特征数据进行分类识别。其中核函数类型选为径向基核函数,考虑计算效率和诊断精确度两个因素,经过试验发现容差系数取 0.01 能获得满意结果。对部分车体、构架、轴箱的横向加速度信号在不同速度下利用 SVM 进行分类,得到各信号不同工况时不同速度时识别结果,如表 2~5 所示。

拆和抗蛇形减振全拆在横向加速度特征上能获得较高的识别率,但是随着速度降低,横向减震器在轴箱加速度上识别率降低很快。空气弹簧失气故障时,车体加速度识别率均较高,构架加速度识别率较车体加速度低,而在轴箱加速度特征上则基本识别不出来。

另选取 200 km/h 时速的 4 种故障状态下 30 个加速度通道信号各一组,每个通道每种工况下 200 个特征向量,共 800 个特征向量,输入 SVM 进行识别,其中,每种工况随机选择 60% 的样本作为训练样本,其他 40% 作为测试样本。得到各个通道的信号识别结果如表 6 所示。

由表 2~5 可以看出,200 km/h 时,横向减振全

表 2 正常工况横向加速度识别率

Tab. 2 Recognition rate of lateral acceleration in normal condition

速度/ (km · h <sup>-1</sup> )	车体加速度			构架加速度			轴箱加速度			
	前部	中部	后部	1 位	4 位	中部	一轴	二轴	三轴	四轴
80	100	100	100	100	100	100	100	100	100	100
120	100	100	100	100	100	100	80.88	100	100	100
140	100	100	100	88.89	100	87.5	100	100	100	100
160	100	100	100	100	98.68	90.79	100	100	100	100
200	92.5	91.25	98.75	87.5	100	98.75	100	100	100	93.75

%

表 3 空簧失气故障横向加速度识别率

Tab. 3 Recognition rate of lateral acceleration in air spring fault condition %

速度/ (km·h <sup>-1</sup> )	车体加速度			构架加速度			轴箱加速度			
	前部	中部	后部	1 位	4 位	中部	一轴	二轴	三轴	四轴
80	100	100	100	100	100	98	0	0	0	0
120	100	100	100	100	100	100	0	0	0	0
140	87.5	100	100	58.33	98.61	81.94	0	0	0	0
160	71.05	93.42	100	13.16	82.89	46.05	5.26	0	0	0
200	73.75	100	92.5	36.25	95	87.5	88.75	0	43.75	2.5

表 4 抗蛇形减振全拆故障横向加速度识别率

Tab. 4 Recognition rate of lateral acceleration in anti-yaw damper fault condition %

速度/ (km·h <sup>-1</sup> )	车体加速度			构架加速度			轴箱加速度			
	前部	中部	后部	1 位	4 位	中部	一轴	二轴	三轴	四轴
80	78	100	100	100	100	100	100	100	100	100
120	79.41	100	98.53	100	100	100	100	100	100	100
140	72.22	100	100	100	100	100	100	100	100	100
160	100	100	100	100	100	100	82.89	84.21	53.95	100
200	100	100	100	96.25	87.5	81.25	87.5	88.75	100	100

表 5 横向减振全拆故障横向加速度识别率

Tab. 5 Recognition rate of lateral acceleration in lateral damper fault condition %

速度/ (km·h <sup>-1</sup> )	车体加速度			构架加速度			轴箱加速度			
	前部	中部	后部	1 位	4 位	中部	一轴	二轴	三轴	四轴
80	100	100	100	0	0	0	0	0	52	0
120	91.18	100	100	100	100	100	0	0	83.82	0
140	50	100	100	100	100	100	0	13.89	30.56	0
160	60.53	100	100	89.47	96.05	93.42	57.89	53.95	64.47	53.95
200	100	100	100	100	100	100	100	100	100	100

表 6 各传感器通道的识别率

Tab. 6 Recognition rate of all sensors %

通道	1	2	3	4	5	6	7	8	9	10
识别率	91.56	97.81	97.81	56.25	94.06	94.37	80	55.94	95.63	63.75
通道	11	12	13	14	15	16	17	18	19	20
识别率	91.87	72.81	83.44	72.19	86.56	73.44	96.88	80.31	85.31	94.06
通道	21	22	23	24	25	26	27	28	29	30
识别率	48.44	96.56	72.19	25	90.63	85.94	25	94.06	74.06	25

由表 6 可知,不同位置信号识别效果参差不齐,可以看出 2,3,9,17,22 通道信号的识别率较高,均高于 95%,分别对应车体后部横向加速度、车体中部横向加速度、构架一架 4 位横向加速度、构架二架中部横向加速度、轴箱二轴纵向加速度。

为了研究列车运行速度对识别率的影响,对 200 km/h 下识别率高于 95%的通道信号,分别计算列车运行速度在 80,120,140,160 和 200 km/h 下的正确识别率,见表 7。

表 7 识别率受运行速度影响情况

Tab. 7 Different recognition rate affected by running speed %

速度/ (km·h <sup>-1</sup> )	80	120	140	160	200
通道 2	100	100	100	98.36	97.81
通道 3	100	99.63	100	100	97.81
通道 9	75	100	99.65	94.41	95.63
通道 17	54.5	90.44	92.36	77.3	96.88
通道 22	57.5	90.44	70.14	97.37	96.56

由表7可以得出,随着列车运行速度的提高,识别率变化不一,如2,3通道信号,随着速度变化,识别率基本稳定,并且都很高,均在95%以上,而17和22通道则识别率会在某一速度时急剧下降。这主要是因为,在提取特征时,随着速度变化,不同故障工况频谱特征变化特点不一,在保证正常工况特征稳定的情况下,不同工况可能会在某一速度范围时,频域复杂度和分布都很接近,使得出现不可分情况,引起识别率急剧下降。

## 4 结束语

监测高速列车振动加速度数据,可以为故障诊断提供依据,笔者分析振动加速度信号的特征,提出用分割能量熵和奇异熵的特征提取方法,对四种典型工况进行诊断分类,并且通过不同速度下对频率范围调整,保证正常工况特征稳定性。试验结果表明,车体横向加速度信号对三种故障工况是最敏感的且随着速度增加,四种工况差异依然明显,其他加速度信号只对某一种或者两种工况比较敏感,或者在某些速度下,只对某一种或者某两种工况比较敏感。车体中、后部横向加速度信号在不同速度下四种工况平均识别率均在95%以上,说明该特征提取方法所提取特征能有效对信号四种工况进行分类,对高速列车安全预警和健康维护具有重要意义。

### 参 考 文 献

- [1] 张兵. 列车关键部件安全监测理论与分析研究[D]. 成都:西南交通大学,2007.
- [2] 张馨,李会. 基于垂向振动的车体加速度分析[J]. 线路/路基, 2011,12(10):8-10.  
Zhang Xin, Li Hui. Analysis on accelerations of vehicle body during vertical vibration [J]. Railway Standard Design, 2011,12(10):8-10. (in Chinese)
- [3] 任晋峰. 高铁车辆车体振动基础性研究[D]. 大连:大连交通大学,2012.
- [4] 史红梅,余祖俊,周佳亮. 不同线路条件及运行速度下高速列车振动性能分析[J]. 北京交通大学学报, 2012,36(1):112-116.  
Shi Hongmei, Yu Zujun, Zhou Jialiang. Vibration analysis of high-speed vehicles under the conditions of various speed and lines [J]. Journal of Beijing Jiaotong University, 2012,36(1):112-116. (in Chinese)
- [5] 高浩,罗仁,池茂儒,等. 车辆系统空气弹簧失气安全性分析[J]. 交通运输工程学报, 2012,12(3):60-

66.  
Gao Hao, Luo Ren, Chi Maoru, et al. Safety analysis of railway vehicle in leakage process of airspring [J]. Journal of Traffic and Transportation Engineering, 2012,12(3):60-66. (in Chinese)
- [6] 包学海. 高速客车车体和构架结构振动研究[D]. 成都:西南交通大学,2009.
- [7] 黄彩虹. 高速车辆减振技术研究[D]. 成都:西南交通大学,2012.
- [8] 方松. 高速铁路客车振动特性研究[D]. 成都:西南交通大学,2012.
- [9] 池茂儒,张卫华,曾京,等. 蛇形运动对铁道车辆平稳性的影响[J]. 振动工程学报, 2008,21(6):639-643.  
Chi Maoru, Zhang Weihua, Zeng Jing, et al. Influence of hunting motion on ride quality of railway vehicle [J]. Journal of Vibration Engineering, 2008,21(6):639-643. (in Chinese)
- [10] 蔡里军. 基于FPGA的高速列车转向架蛇形失稳检测装置[D]. 成都:西南交通大学,2012.
- [11] 刘增华. 铁道车辆空气弹簧动力学特性及其主动控制研究[D]. 成都:西南交通大学,2007.
- [12] Shannon C E. A mathematical theory of communication[J]. Bell System Technical Journal, 1948,27:379-423.
- [13] 陈小勤. 基于小波熵测度的电力暂态信号检测与分类方法研究[D]. 成都:西南交通大学,2006.
- [14] 艾娜,吴作伟,任江华. 支持向量机与人工神经网络[J]. 山东理工大学学报:自然科学版, 2005,19(5):45-49.  
Ai Na, Wu Zuowei, Ren Jianghua. Support vector machine and artificial neural network [J]. Journal of Shandong University of Technology: Sci & Tech, 2005,19(5):45-49. (in Chinese)
- [15] Francesco O, Claudio C, Barbara C, et al. On-line independent support vector machines[J]. Pattern Recognition, 2010,43(4):1402-1412.



**第一作者简介:**朱明,男,1978年4月生,博士后、教授。主要研究方向为智能信息处理、模式识别与进化计算等。曾发表《基于时频原子方法的雷达辐射源信号特征提取》(《电波科学学报》2007年第22卷第3期)等论文。  
E-mail:zhuming@126.com