

基于近似熵及 EMD 的高铁故障诊断

赵晶晶¹ 杨燕¹ 李天瑞¹ 曾京² 魏来²

(西南交通大学信息科学与技术学院 成都 610031)¹

(西南交通大学牵引动力国家重点实验室 成都 610031)²

摘要 抗蛇行减振器故障、横向减振器故障、空气弹簧故障是高铁的3种典型故障。针对高铁的3种常见故障的非线性、非平稳特性,本次研究中将近似熵和经验模态分解应用到高铁故障诊断中进行故障特征提取,并使用BP神经网络作为高铁故障诊断模型进行高铁的故障诊断。实验证明,该方法能够准确有效地进行高铁故障诊断。此外,通过对比实验表明,融合近似熵特征和EMD分解后的第一个模态分量的能量特征比单个特征更有利于高铁故障诊断。

关键词 特征提取,近似熵,经验模态分解,神经网络

中图分类号 TP181 文献标识码 A

Fault Diagnosis of High-speed Rail Based on Approximate Entropy and Empirical Mode Decomposition

ZHAO Jing-jing¹ YANG Yan¹ LI Tian-rui¹ ZENG Jing² WEI Lai²

(School of Information Science and Technology, Southwest Jiaotong University, Chengdu 610031, China)¹

(Traction Power State Key Laboratory, Southwest Jiaotong University, Chengdu 610031, China)²

Abstract The faults of anti-yaw damper, lateral damper and air spring are three kinds of common faults of high-speed rail. According to the non-stationary and nonlinear characteristic of three kinds of common faults of high-speed rail, approximate entropy and empirical mode decomposition were introduced to extract the feature of high-speed rail faults, and BP neural network was used as the model for the fault diagnosis of high-speed rail. The experimental results show that the proposed method is effective. In addition, the comparison experiment indicates that the fault diagnosis based on the combination of approximate entropy and empirical mode decomposition obtains better result than the fault diagnosis based on only one feature.

Keywords Feature extraction, Approximate entropy, Empirical mode decomposition, Neural network

1 引言

进入新世纪以来,我国高铁得到飞速发展,然而高铁事故时有发生,高铁的安全问题不断出现。高速铁路速度快,行车密度高,一旦发生故障,不仅会扰乱整个铁路网的行车调度,还会威胁到乘客和工作人员的生命安全,带来灾难性的后果。减振器是列车中用来减少或消除外部振动及冲击影响的重要部件,对于突然冲击引起的振动,减振器能使振动振幅的衰减更迅速以改善列车的行驶平顺性,提高列车的舒适性和安全性。抗蛇行减振器、横向减振器和空气弹簧是列车中的重要减振器。抗蛇行和横向减振器主要是车辆系统阻尼元件,抗蛇行可以起到抑制转向架蛇行运动的作用,提高列车的安全性;横向减振器主要对车体横向振动起抑制作用,可以改善运行平稳性和提高蛇行运动稳定性;空气弹簧位于车体和转向架,起到承载车体和二系隔振作用,可以获得较高的动刚度,

提高乘坐舒适度。因此,它们对维护列车的安全起着不可忽视的作用,及时发现抗蛇行减振器、横向减振器和空气弹簧故障并进行维护是列车安全运行的前提。本文将针对上述3种故障,利用采集的信号进行故障识别研究。

故障诊断包括3个阶段:信号采集、特征提取和状态识别。其中特征提取是故障诊断中的重要阶段,因为特征提取过程不仅能降低数据维度,从而降低计算复杂度,而且提取的特征的优劣将直接影响到状态识别的准确率。近似熵(Approximate Entropy,简称ApEn)是Pincus^[1]在1991年提出的用来衡量信号复杂度的非线性指标。它不仅对比较短的数据能得出比较稳健的估计值(所需数据点数大致是100~5000点),还具有良好的抗噪和抗干扰能力,此外,不论是随机信号还是确定性信号都可以使用^[2]。近年来,近似熵被广泛应用到各个领域,特别是在生物医学^[3]领域。在故障诊断领域,近似熵也在发挥着它的作用。胡红英等^[4]根据信号经局域波分

到稿日期:2013-06-03 返修日期:2013-08-15 本文受国家自然科学基金(61134002,61170111,61175047),西南交通大学牵引动力国家重点实验室自主研究课题(2012TPL_T15),中央高校基本科研业务费专项资金资助项目(SWJTU11ZT08)资助。

赵晶晶(1988—),女,硕士生,主要研究方向为智能信息处理;杨燕(1964—),女,教授,主要研究方向为数据挖掘、计算智能、集成学习等,E-mail:yyang@home.swjtu.edu.cn(通信作者);李天瑞(1969—),男,教授,主要研究方向为智能信息处理、粗糙集与粒计算、云计算等;曾京(1963—),男,教授,主要研究方向为机车车辆设计理论与结构可靠性、机车车辆耦合系统动力学与控制;魏来(1989—),男,博士生,主要研究方向为车辆系统动力学。

解后所得各基本模式分量的特性,提出了用各分量的近似熵来描述各模式分量的复杂程度,从而量化故障特征。He等^[5]对经EMD分解后的各个模式分量提取近似熵特征,形成旋转机械信号的特征向量。

经验模态分解(Empirical Mode Decomposition,简称EMD)方法是由Huang等^[6]提出的一种针对非线性、非平稳信号的时频域分析方法。传统的频谱分析方法,是目前应用最成熟的特征提取方法之一。然而频谱分析法是基于待分析的信号是线性、平稳的信号这一前提,因此,它对非线性、非平稳信号不能很好地分析。而在实际工程中,当机械设备发生异常时,其相应的振动信号一般呈非线性、非平稳特性^[7-9]。EMD根据信号本身的尺度特征将信号分解为若干个固有模态函数(Intrinsic Mode Function,简称IMF),分解出的每个IMF突出了数据的局部特征,可更准确有效地反映原数据信息。EMD分解过程中不涉及参数的设置,具有很高的信噪比。分解得到的IMF的个数及其频率不仅与采样频率有关,还随信号本身的变化而变化。因此,经验模态分解方法具有很好的自适应性和多分辨率特性,非常适用于非线性、非平稳信号的分析^[10]。EMD在生物医学^[11]、机械故障诊断^[12]、声音识别^[13]等领域都被广泛应用,促进了非线性非平稳信号分析的发展。

为了更全面地分析列车状态,信号的采集往往是通过多个传感器采集的。此外,每个传感器采集不同位置或不同方向上的振动信号,这些振动信号对某个工况的反应程度也不一样,因此单个传感器采集的振动信号一般不能全面地反映故障发生时的信息。基于神经网络理论的数据融合方法优于传统的基于统计理论的分析方法,尤其是当输入数据为不完整数据和噪声数据时^[14]。此外,高铁故障中导致故障原因的机理缺乏完备性,故障与故障征兆之间并不是严格的一一对应的关系,没有确定的映射关系。因此,高铁故障诊断中存在大量不确定因素,而具有非线性、自学习、自适应性和自容错等特点的神经网络能很好地应用到高铁故障诊断中^[15]。

针对机械故障信号的非线性、非平稳特性,对故障信号进行时频域分析已成为分析非线性非平稳信号的常用方法。然而当列车的抗蛇行减振器、横向减振器或空气弹簧发生故障时,列车的振动程度不同,因此不同故障下采集的信号复杂度不同。因此,本文拟将对各故障信号进行时域和时频域分析。提取振动信号的近似熵和EMD分解后的第一个模态函数的能量来量化高铁故障特征,并以此特征作为高铁故障的特征向量输入BP神经网络模型中进行高铁的故障诊断。对比实验结果表明,融合的时域和时频域特征比单个域的特征能更有效地提取故障信息,提高了故障诊断正确率。

2 相关理论知识

2.1 近似熵方法

近似熵是用一个非负数来表示某时间序列的复杂性,越复杂的时间序列对应的近似熵越大^[16]。近似熵的算法步骤如下:

(1) 设采集到的原始信号是一长度为 N 的一维时间序列 $\{u(i), i=0, 1, \dots, N\}$,根据 $u(i)$ 按照式(1)重构一组 m 维矢量:

$$X(i)=[u(i), u(i+1), \dots, u(i+m-1)] \quad (1)$$

其中, $i=1 \sim N-m+1$ 。

(2) 对每一个 i 值计算矢量 $X(i)$ 与其余矢量 $X(j)$ 间的距离:

$$d[X(i), X(j)]=\max_{k=0 \sim m-1} [|u(i+k)-u(j+k)|] \quad (2)$$

(3) 给定阈值 r ,对每个矢量 $X(i)$ 统计 $d[X(i), X(j)] < r$ 的数目,并记此数目与距离总数 $N-m$ 的比值为 $C_i^m(r)$,即:

$$C_i^m(r)=\frac{1}{N-m} \{d[X(i), X(j)] < r \text{ 的数目}\} \quad (3)$$

(4) 先将 $C_i^m(r)$ 取对数,再求其对所有 i 的平均值,记作 $\phi^m(r)$,即:

$$\phi^m(r)=\frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \ln C_i^m(r) \quad (4)$$

(5) 再将维数 m 加1变成 $m+1$,重复步骤(1)-(4),得到 $C_i^{m+1}(r)$, $\phi^{m+1}(r)$,得到近似熵为:

$$ApEn(m, r)=\lim_{N \rightarrow \infty} [\phi^m(r) - \phi^{m+1}(r)] \quad (5)$$

(6) 对于有限长时间序列,即 N 有限时按照上述步骤得出的是近似熵的估计值,记作:

$$ApEn(m, r, N)=\phi^m(r) - \phi^{m+1}(r) \quad (6)$$

式(6)可通过变形简化为:

$$\begin{aligned} ApEn(m, r, N) &= -[\phi^{m+1}(r) - \phi^m(r)] \\ &= -\left[\frac{1}{N-m+1} \sum_{i=1}^{N-m} \ln \frac{C_i^{m+1}(r)}{C_i^m(r)} \right] \end{aligned} \quad (7)$$

近似熵的值显然与 m 和 r 的取值有关。根据实践^[1],通常取 $m=2, r=0.1 \sim 0.25SD(u\{i\})$,其中 $SD(u\{i\})$ 表示序列 $\{u(i)\}$ 的标准差。因此,本文中近似熵计算采用 $m=2, r=0.2SD(u\{i\})$ 。

2.2 经验模态分解

EMD建立在原始信号至少存在两个极值点(一个最大值和一个最小值)的假设上。此外,每个IMF都要满足以下两个条件:(1)在整个数据段内,极值点的个数和零交叉点的个数必须相等或相差最多不能超过一个;(2)在任何一点,由局部极大值点形成的包络线和由局部极小值点形成的包络线的平均值为零^[17]。EMD的具体算法^[18]如下:

(1) 提取信号 $x(t)$ 的所有局部极值点,包括极大值和极小值;

(2) 用三次样条插值法将所有的极大值、极小值点连接起来分别形成上、下包络 $x_{\pm}(t), x_{\mp}(t)$;

(3) 用原始信号减去上、下包络线的均值 $x_0(t)$,即

$$y_1(t)=x(t)-x_0(t) \quad (8)$$

(4) 判断 $y_1(t)$ 是否为IMF。若 $y_1(t)$ 满足IMF条件,则记 $y_1(t)$ 为第一个IMF,继续执行步骤(4);否则将 $y_1(t)$ 作为原始信号,重复步骤(1)到(3);

(5) 将 $y_1(t)$ 记为 $c_1(t)$,并将 $c_1(t)$ 从 $x(t)$ 中分离出来,

$$r_1(t)=x(t)-c_1(t) \quad (9)$$

将 $r_1(t)$ 作为原始数据,重复步骤(1)到(3),得到第二个IMF,记作 $c_2(t)$,重复以上步骤直到剩下的 $r(t)$ 不可分解或其研究意义不大。最终得到 n 个IMF即 $c_1(t), c_2(t), \dots, c_n(t)$ 和一个残量 $r_n(t)$ 。

$$\begin{aligned} r_1(t)-c_2(t) &= r_2(t) \\ r_2(t)-c_3(t) &= r_3(t) \\ &\vdots \end{aligned} \quad (10)$$

$$r_{n-1}(t)-c_n(t)=r_n(t)$$

由以上计算可得到

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (11)$$

由式(11)可知,通过经验模态分解,可以将一个信号分解为 n 个 IMF 分量和一个残量 $r_n(t)$ 。其中 n 个 IMF 即 $c_1(t)$, $c_2(t)$, \dots , $c_n(t)$ 分别包含了信号从高到低不同频率段的成分,每一频率段所包含的频率成分不同,且随着信号本身的变化而变化。

2.3 BP 神经网络

BP 神经网络是一种多层前向网络,由一个输入层、一个输出层和一个或多个隐藏层组成。但一个三层的前馈网络即一个输入层、一个输出层和一个隐藏层就具有映射任意函数关系的能力^[19]。其中输入层和输出层节点数根据输入个数和输出个数确定,隐藏层节点数一般参照美国科学家 Hebb 提出的经验公式选取:

$$h = \sqrt{a+b} + \sigma \quad (12)$$

式中, a 、 h 、 b 分别为输入层、隐藏层、输出层的节点数, σ 为 1~10 之间的常数。按照上式,选取 $h=8$ 。图 1 所示即为一个输入层、隐藏层和输出层的神经元数分别为 2、8 和 4 的 BP 神经网络结构。

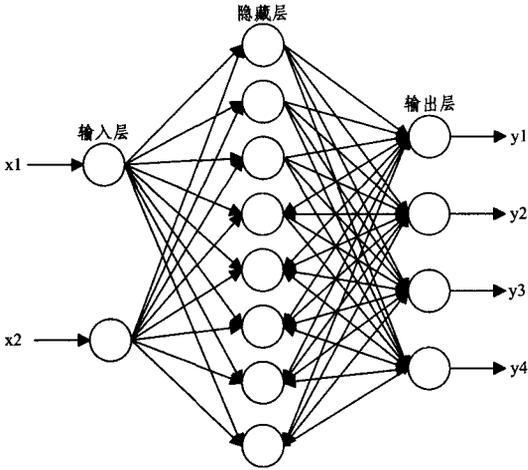


图 1 三层 BP 神经网络结构

BP 神经网络包括正向传播和反向传播两个阶段。在正向传播阶段,数据从输入层输入,逐层逐个节点地计算每一个节点的输出,直至计算结束,如果在输出层的输出与期望输出相差较大,则开始反向传播过程;反向传播阶段根据输出与期望输出的误差,对网络节点间的各个连接权值进行修改,使得输出与期望输出的误差最小,首先让各节点的输出保持不变,再从输出层开始,反向逐层逐个节点地计算各连接权值的修改量,以修改各连接的权值,直到输入层为止。总之,BP 神经网络就是通过不断地进行正向传播和反向传播的计算过程,最终使得网络输出层的输出值与期望值趋于一致。

BP 神经网络的学习规则就是使得错误最小,模型的计算描述如下^[20,21]。

(1) 对于隐藏层和输出层的输出分别是:

$$h_j = f\left(\sum_{i=1}^n w_{ji} x_i - \theta_j\right) \quad (13)$$

$$y_k = f\left(\sum_{j=1}^p v_{kj} h_j - \theta_k\right) \quad (14)$$

式中, x_i 、 h_j 和 y_k 分别是输入层的第 i 个节点、隐藏层的第 j 个节点和输出层的第 k 个节点, w_{ji} 是第 i 个输入层神经元到第 j 个隐藏层神经元的权值, v_{kj} 是第 j 个隐藏层神经元到第 k

个输出层神经元的权值。

(2) 假设输出层节点 k 的期望输出是 t_k ,网络的误差函数是输出层的每个节点的实际输出与期望输出误差平方的和,即:

$$E = \frac{1}{2} \sum_{k=1}^m (t_k - y_k)^2$$

$$= \frac{1}{2} \sum_k (t_k - f(\sum_j v_{kj} f(\sum_i w_{ji} x_i - \theta_j) - \theta_k))^2 \quad (15)$$

3 基于近似熵及 EMD 的高铁故障诊断方法

基于近似熵及 EMD 的高铁故障诊断方法总体框图如图 2 所示。

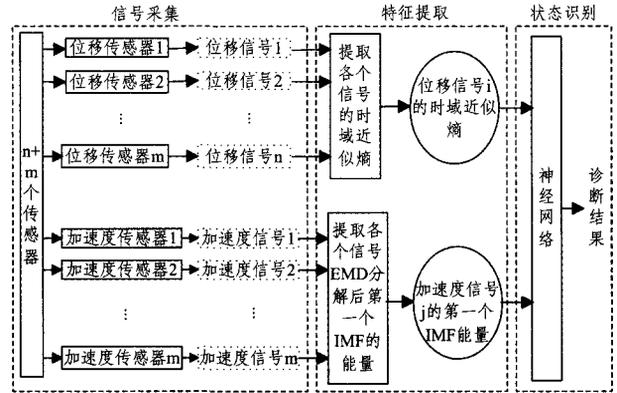


图 2 基于近似熵及 EMD 的高铁故障诊断总体方法框图

3.1 振动信号采集

振动信号的采集包括信号的获取以及对信号的预处理。高铁故障诊断是通过分析多个传感器传回的振动信号来进行故障判别的。通过在列车上安装 n 个位移传感器和 m 个加速度传感器来分别采集列车的不同位置或某个位置的不同方向上的 n 个位移信号和 m 个加速度信号,这些信号从不同角度反映列车的性能。通过各个传感器实测的振动信号并不能直接用于分析,因为这些实测振动信号中不可避免地包含噪声等。由于噪声会扰乱甚至覆盖有用信息,因此在提取故障特征之前应对振动信号进行预处理以净化信号。

3.2 特征提取

高铁故障诊断往往是通过分析各传感器传回的信号来进行故障识别的,但每个传感器采集的是列车不同位置或某个位置不同方向上的振动信号,每个振动信号对高铁故障的反应能力有强有弱。如果对所有信号都分析,则不仅会降低故障诊断速率,而且有些冗余信号还会干扰故障诊断结果,降低诊断正确率。因此,应选择最能反映故障信息的信号作为分析信号。

特征提取是指从模式样本的原始信息中提炼出最有利于模式分类的有效信息这一过程。当列车出现故障时,振动信号呈现非平稳、非线性特性。近似熵能够通过一个非负数来表示某时间序列的复杂性;EMD 分解能够将原始信号分解为若干个 IMF 和一个残量,这些 IMF 更好地描述了信号中的非平稳成分,且 EMD 方法分解出来的前几个 IMF 分量集中了原信号中最显著、最重要的信息。对列车处于各种工况下的 n 个位移信号分别计算近似熵,将 m 个加速度信号分别进行 EMD 分解,并提取第一个 IMF 能量特征;对比选取最能体现各种工况特征的位移信号 $i(1 \leq i \leq n)$ 和加速度信号 $j(1 \leq j \leq m)$ 作为后续分析信号。

将位移信号 i 的时域近似熵和加速度信号 j 进行 EMD 分解后的第一个 IMF 能量作为高铁故障特征向量 T 。

3.3 状态识别

BP 神经网络是应用最为广泛的人工神经网络,本文选取三层 BP 神经网络作为分类器。根据特征个数和待识别的工况个数设置输入层和输出层的节点数,根据式(12)合理选取隐藏层的节点数。在网络训练阶段,每种工况随机选取大约 2/3 的样本进行网络训练,并用训练好的神经网络对剩下的样本进行分类识别,根据识别的正确率来判断故障诊断方法是否有效。

4 实验结果与分析

4.1 实验设计

4.1.1 实验数据

本系统总体设计数据来源于某高铁研究项目组对抗蛇行减振器故障、横向减振器故障、空气弹簧故障对某型号动车进行的模拟试验。该模拟试验共设置了 4 种工况,如表 1 所列。模拟实验通过 58 个传感器即 16 个位移传感器和 42 个加速度传感器分别采集了 16 个位移信号和 42 个加速度信号,即图 2 中的 n, m 分别取 16、42。

表 1 模拟实验中设置的 4 种工况

工况名称	意义
1 抗蛇形减振器全拆	只拆除列车的抗蛇形减振器
2 横向减振器全拆	只拆除列车的横向减振器
3 空簧失气	只使列车的空气弹簧完全失气
4 原车	正常的列车

此外,在每种工况下都使列车分别以速度 $V=220\text{km/h}$ 、 $V=200\text{km/h}$ 、 $V=160\text{km/h}$ 、 $V=140\text{km/h}$ 、 $V=120\text{km/h}$ 、 $V=80\text{km/h}$ 和 $V=40\text{km/h}$ 运行来采集不同工况下不同速度下的振动信号。本文将对每个速度下的列车处于各个工况时的 58 个振动信号都分割为 40 段,形成 40 个样本数据,即在每种速度下共有 $4 \times 58 \times 40$ 个样本数据。

4.1.2 实验方案

列车模拟试验结果显示,列车以 $V=220\text{km/h}$ 、 $V=200\text{km/h}$ 、 $V=160\text{km/h}$ 、 $V=140\text{km/h}$ 、 $V=120\text{km/h}$ 、 $V=80\text{km/h}$ 和 $V=40\text{km/h}$ 运行时,列车发生故障时没有晃动或轻微晃动,而当列车以速度为 $V=220\text{km/h}$ 运行时,当列车发生抗蛇行减振器故障、横向减振器故障时都会出现失稳等现象,其振动信号包含丰富的故障信息,有利于有效地提取正确的故障特征。本文首先在 $V=220\text{km/h}$ 下,将各种工况下的 16 个位移信号都提取近似熵特征,将 42 个加速度信号都进行 EMD 分解,并提取第一个 IMF 能量特征,通过对比选取出最能反映故障特征的位移信号 16 和加速度信号 15 作为后续分析的信号,即图 2 中 i, j 分别取 16、15;接着在 $V=220\text{km/h}$ 、 $V=200\text{km/h}$ 、 $V=160\text{km/h}$ 、 $V=140\text{km/h}$ 、 $V=120\text{km/h}$ 、 $V=80\text{km/h}$ 和 $V=40\text{km/h}$ 下,分别提取各种工况的位移信号 16 的时域近似熵和加速度信号 15 的 EMD 分解后的第一个 IMF 能量作为高铁故障特征向量 T ;最后将各个速度下的 4 种工况的 T 作为 BP 神经网络的输入来进行分类识别研究。

为了同基于多个特征的故障诊断进行对比,设置对比实验,即将各个速度下的 4 种工况的位移信号 16 的时域近似熵和加速度信号 15 的 EMD 分解后的第一个 IMF 能量分别作为 BP 神经网络的输入来进行故障诊断。

4.2 实验结果与分析

将位移信号 16 的时域近似熵记作 input1 ,加速度信号 15 进行 EMD 分解后第一个 IMF 的能量值记作 input2 ,求出特征向量 $T=[\text{input1}, \text{input2}]$ 。采用三层 BP 神经网络作为分类器,分别将每种速度下的抗蛇行减振器全拆、横向减振器全拆、空簧失气和原车的 T 作为神经网络的输入,输出分别对应抗蛇行减振器全拆、横向减振器全拆、空簧失气和原车 4 种工况模式,即输入层有 2 个节点,输出层有 4 个节点,根据式(12)设置隐藏层包含 8 个节点,即网络结构为 $2 \times 8 \times 4$ 。每种模式随机选取 25 个样本作为训练样本进行网络训练,训练截止误差为 0.001,其中 BP 训练算法的学习速率为 0.01。网络训练至收敛即停止,并用训练好的神经网络对剩余的 15 个样本进行分类识别,取多次诊断结果的平均值记录在表 2 中。

为了进行比较,设置 BP 神经网络的输入层节点数为 1,分别将 input1 和 input2 作为 BP 神经网络的输入进行故障诊断,并取多次诊断结果的平均值记录在表 2 中。

表 2 不同速度下的基于近似熵和 EMD 的高铁故障诊断结果

实验	神经网络 的输入	诊断正确率						
		$V=220\text{km/h}$	$V=200\text{km/h}$	$V=160\text{km/h}$	$V=140\text{km/h}$	$V=120\text{km/h}$	$V=80\text{km/h}$	$V=40\text{km/h}$
1	input1	72.973%	68.750%	66.146%	51.239%	53.906%	51.953%	52.5%
2	input2	87.853%	76.250%	90.364%	82.187%	90.234%	77.734%	75.938%
3	input1+input2	95.342%	94.687%	93.230%	86.313%	90.234%	86.278%	87.5%

由表 2 可以看出:(1)实验 1 的故障诊断准确率低于实验 2 的诊断正确率,即基于 EMD 提取的高铁故障特征优于基于近似熵提取的高铁故障特征,而实验 3 的故障诊断正确率最高,这表明融合 input1 、 input2 作为故障特征更有利于进行故障诊断;(2)在所有速度下,故障诊断正确率都在 85% 以上,表明各个速度下,基于近似熵和 EMD 的故障诊断方法都能在一定程度上准确有效地识别高铁故障。但表 2 也反映出随着速度的减小,故障诊断正确率呈下降趋势,这是因为在速度较小时,各工况下列车的性能差异也呈减小趋势,故障信息很弱,提取的特征对高铁故障的反映能力也减弱;(3)相比 $V=140\text{km/h}$ 、 $V=120\text{km/h}$ 时的故障诊断正确率反而更高,这是由于列车以 $V=120\text{km/h}$ 运行时当发生抗蛇行减振器全拆和

横向减振器全拆故障时会出现晃动,故障信息较 $V=140\text{km/h}$ 时丰富,提取的特征中包含的故障信息较丰富,有利于进行故障诊断。

结束语 本文提出一种基于近似熵和 EMD 的高铁故障诊断方法,即使用近似熵和 EMD 方法对高铁故障进行特征提取,并结合 BP 神经网络进行高铁故障诊断。本文首先在 $V=220\text{km/h}$ 下,通过对比选取出 58 个振动信号中最能反映故障特征的位移信号 16 和加速度信号 15 作为后续分析的信号;在 $V=220\text{km/h}$ 、 $V=200\text{km/h}$ 、 $V=160\text{km/h}$ 、 $V=140\text{km/h}$ 、 $V=120\text{km/h}$ 、 $V=80\text{km/h}$ 和 $V=40\text{km/h}$ 时,分别提取各种工况的位移信号 16 的时域近似熵和加速度信号 15 的 EMD 分解

(下转第 99 页)

- [4] Wang S, Siskind J M. Image segmentation with ratio-cut[J]. IEEE Transactions on Pattern Analysis Machine Intelligence, 2003(6):675-690
- [5] Ding C H Q, He Xiaofeng, Zha Hongyuan. A Min-max Cut Algorithm for Graph Partitioning and Data Clustering [C]//Proceeding of the 2001 IEEE International Conference on Data Mining. 2001
- [6] Sarkar S, Boyer K L. Quantitative Measures of Change Base on Feature Organization; Eigenvalues and Eigenvectors[C]//Proc IEEE Conf Computer Vision and Pattern Recognition, 1996
- [7] Grady L, Schwartz E L. Isoperimetric Graph Partitioning for Image Segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(3):469-475
- [8] 石殿国. 基于图论的灰度图像分割[D]. 武汉: 武汉理工大学, 2009
- [9] 刘建龙. 基于图论的图像分割算法研究[D]. 黑龙江: 哈尔滨工业大学理学院物理系, 2006
- [10] 闫成新, 桑农, 张天序. 基于图论的图像分割研究进展[J]. 计算机工程与应用, 2006, 42(5):11-14
- [11] 曹建农, 方丹霞. 基于图论的图像分割方法及其局限性研究[J]. 测绘技术装备, 2006, 8(2):12-14
- [12] Xie Feng, Shen Yi, He Xiao-fei. K-way Min-max Cut for Image Clustering and Junk Images Filtering from Google Images[C]//Proceeding of the International Conference on Multimedia. New York, USA, 2010:803-806
- [13] Nie Fei-ping, Ding C, Luo Di-jun. Improved Min-Max Cut Graph Clustering with Nonnegative Relaxation[C]//Proceeding of the 2010 European Conference on Machine Learning and Knowledge Discovery in Data Bases. Berlin, 2010:451-466
- [14] 陶文兵, 金海. 一种新的基于图谱理论的图像阈值分割方法[J]. 计算机学报, 2007(1):110-119
- [15] 陈彦至, 黄永锋. Neut 在图像分割中的应用[J]. 计算机技术与发展, 2009, 19(1):228-233
- [16] 陈应良. 图像谱方法分割的研究及应用[J]. 计算机应用, 2008:67-82
- [17] 程正兴. 小波分析算法与应用[M]. 西安: 西安交通大学出版社, 1998

(上接第 94 页)

后的第一个 IMF 能量作为高铁故障特征向量 T , 将各个速度下的 4 种工况的 T 作为 BP 神经网络的输入进行分类识别研究。实验结果表明, 不管是在速度较大还是速度较小时, 该故障诊断方法都能有效识别高铁故障, 但随着速度的减小, 该故障诊断方法的诊断正确率呈下降趋势。此外, 通过同基于单个特征的故障诊断实验的对比, 表明融合后的特征比单个特征更能全面反映高铁故障信息, 能有效提高高铁故障诊断性能。

参 考 文 献

- [1] Pincus S M. Approximate entropy as a measure of system complexity[J]. Proceedings of the National Academy of Sciences, 1991, 88(6):2297-2301
- [2] Fleisher L A, Pincus S M, Rosenbaum S H. Approximate entropy of heart rate as a correlate of postoperative ventricular dysfunction[J]. Anesthesiology, 1993, 78(4):683-692
- [3] Pincus S M. Approximate entropy (ApEn) as a complexity measure. Chaos[J]. An Interdisciplinary Journal of Nonlinear Science, 1995, 5(1):110-117
- [4] 胡红英, 马孝江. 局域波近似熵及其在机械故障诊断中的应用[J]. 振动与冲击, 2006, 25(4):38-40
- [5] He Yong-yong, Huang Jun, Zhang Bo. Approximate entropy as a nonlinear feature parameter for fault diagnosis in rotating machinery[J]. Measurement Science and Technology, 2012, 23(4):1-14
- [6] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London, 1998, 454(1971):903-995
- [7] Banerjee T P, Das S, Roychoudhury J, et al. Implementation of a new hybrid methodology for fault signal classification using short-time fourier transform and support vector machines[C]//International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO). 2010:219-225
- [8] Rosero J, Romeral J A O, Romeral L, et al. Short circuit fault detection in PMSM by means of empirical mode decomposition (EMD) and wigner ville distribution (WVD)[C]//International Conference on Applied Power Electronics Conference and Exposition (APEC). Austin, TX, England, 2008:98-103
- [9] Saravanan N, Ramachandran K I. Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN)[J]. Expert systems with applications, 2010, 3(37):4168-4181
- [10] 杨俊燕, 张优云, 赵荣珍. 支持向量机在机械设备振动信号趋势预测中的应用[J]. 西安交通大学学报, 2005, 39(9):950-953
- [11] Wu Jian-da, Tsai Y J. Speaker identification system using empirical mode decomposition and an artificial neural network[J]. Expert System with Application, 2011, 38(5):6112-6117
- [12] Yadav S K, Kalra P K. Fault diagnosis of internal combustion engine using Empirical Mode Decomposition[C]//International Conference on Image and Signal Processing and Analysis. Salzburg, Austria, 2009:40-46
- [13] Huang N E, Adib A, Larb S D, et al. A blind digital audio watermarking scheme based on EMD and UISA techniques[J]. Multimedia Tools and Application, 2013, 64(3):809-829
- [14] 乔新勇, 刘建敏, 张小明. 基于神经网络信息融合的发动机失火故障诊断[J]. 内燃机工程, 2009, 30(2):74-79
- [15] Zhang Lie-ping, Wang Shou-feng. Fault Diagnosis of Induction Motor Rotor Based on BP Neural Network and D-S Evidence Theory[C]//International Conference on Intelligent Control and Automation. Beijing, China, 2012:3292-3297
- [16] 王琦, 汪同庆, 叶庆卫. 轻轨锚固螺杆振动信号 EMD 处理研究[J]. 振动与冲击, 2008, 27(6):178-181
- [17] Zhang Hai-yong, Gai Qiang. Research on Properties of Empirical Mode Decomposition Method[J]. Intelligent Control and Automation, 2006, 2:10001-10004
- [18] 赵林海, 蔡伯根, 邱宽民. 基于 HHT 和 DBWT 的无绝缘轨道电路补偿电容故障诊断[J]. 铁道学报, 2011, 33(3):49-54
- [19] 吴蒙, 贡璧, 何振亚. 人工神经网络和机械故障诊断[J]. 振动工程学报, 1993, 6(2):153-162
- [20] Yu Jian-li, Niu Xiao-juan, Han Yang, et al. The Fault Diagnosis of Transformer Based on BP Neural Network[C]//International Conference on Information Management, Innovation Management and Industrial Engineering. Sanya, China, 2012, 1:487-489
- [21] Zhou Fang, Ji Jian-heng, Feng De-zhen. The Application of BP Neural Network on Mechanical Failure Classification[M]. Intelligent Systems and Applications, 2009:1-3