

DOI:10.19651/j.cnki.emt.1802194

基于 EEMD-SVD-LTSA 的高速列车 蛇行演变特征提取框架*

冉伟 宁静 陈杨 陈春俊
(西南交通大学机械工程学院 成都 610031)

摘要: 高速列车一旦出现蛇行失稳,列车的运行安全会受到严重威胁。在出现蛇行失稳前,高速列车会进入小幅蛇行发散状态,因此监测列车小幅蛇行演变趋势可以预测列车的运行状况,然而现有的文献鲜有对小幅蛇行演变特征进行研究,为此,提出一种基于 EEMD-SVD-LTSA 的高速列车特征提取框架,识别其演变趋势是小幅发散还是小幅收敛,进而预测列车运行状况。通过在线实验数据验证表明,提出的框架能成功提取高速列车小幅收敛、小幅发散的运行特征,且使用 LSSVM 的识别率达到 100%,从而及时预测高速列车的运行状态,保障列车的运行安全。

关键词: 蛇行运动;集合经验模态分解(EEMD);奇异值分解(SVD);局部切空间排列(LTSA);最小二乘法支持向量机(LSSVM)

中图分类号: U216.3;TH17;TN98 文献标识码: A 国家标准学科分类代码: 460.4030

High-speed train small hunting evolution feature extraction based on EEMD-SVD-LTSA framework

Ran Wei Ning Jing Chen Yang Chen Chunjun

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Once the high-speed train is unstable, the operation safety of the train will be seriously threatened. Before the high-speed train appears to be unstable, it will enter a small hunting divergence state. Therefore, monitoring the train's evolutionary trend of small hunting can predict the running status of trains. However, the existing literature rarely studies the evolution characteristics of small hunting, therefore, this paper proposes a high-speed train feature extraction framework based on EEMD-SVD-LTSA method, to identify whether the evolution trend is small divergence or small convergence, and then predict the train running status. The verification of online experimental data shows that the framework proposed in this paper can successfully extract the small convergence and small divergence operating characteristics of high-speed trains, and the recognition rate of using LSSVM can reach 100%, so as to predict the running status of high-speed trains in time and ensure the safety of trains.

Keywords: hunting instability; ensemble empirical mode decomposition(EEMD); singular value decomposition(SVD); local tangent space alignment(LTSA); least square support vector machine(LSSVM)

0 引言

高速列车在中国发展迅速,截至 2018 年,中国是世界上高铁通车里程和在建里程最多的国家,高铁给人民出行带来了便利,但随着高铁速度的提高,其运行安全性成为了关注的焦点。

Stephenson^[1]首先注意到了车辆系统的蛇行现象,由于机车轮对具有一定的锥度,当其沿着钢轨运动并当速度

达到某一临界值时,外界激励频率与列车系统频率接近,从而产生共振,此时轮对绕着轨道中心线一边横移一边摇头向前运动,即蛇行运动^[2]。当列车发生蛇形运动时,如果不对列车的速度加以限制,列车的蛇行摆动振幅会不断增大,发生蛇行失稳,轻则影响乘坐的舒适性,重则导致列车的脱轨,蛇行运动是制约高速列车安全运行的一个关键因素。

目前,国内外对列车蛇行运动失稳做了大量研究。Pater^[3]首次将车辆的蛇行运动考虑为运动学的运动稳定

收稿日期:2018-10-09

* 基金项目:国家自然科学基金(51475387)、中央高校基本业务费专项基金(2682014CX033)、四川省科技创新苗子工程(2015102)项目资助

性问题。《高速动车组整车试验规范》^[4]规定当转向架横向加速度经 10 Hz 滤波后的峰值连续 6 次以上(含 6 次)达到或超过极限值 8~10 m/s² 时,则判定蛇行失稳。Polach^[5]在进行横向稳定性对比研究时,提出小幅蛇行相关理论,即指轮对小位移移动时,产生的构架横向加速度信号中并未达到或超过安全极限的部分。根据小幅蛇行运动的发展,将小幅蛇行分为两类:小幅收敛与小幅发散^[6]。高速列车小幅收敛状态会慢慢收敛到正常运行状态,而高速列车小幅发散状态的横向振动振幅则会不断扩大,直至演变为蛇行失稳,从而对高速列车运行造成巨大伤害。因此,及时分辨小幅蛇行的这两个阶段对于列车运行稳定性至关重要。

本文采用集合经验模态分解(ensemble empirical mode decomposition, EEMD)^[7]、奇异值分解(singular value decomposition, SVD)^[8]相结合的方法对高速列车运行信号进行分析,结合流形学习^[9]的局部切空间排列(local tangent space alignment, LTSA)^[10]对能量矩阵进行降维,并使用最小二乘法支持向量机(least square support vector machine, LSSVM)^[11]进行验证,成功将高速列车正常运行、小幅收敛、小幅发散和大幅蛇行 4 种运行状态分开,及时准确检测高速列车的运行状态,保障列车运行安全。

1 小幅蛇行演变特征提取框架

1.1 EEMD

EEMD 方法是针对经验模态分解(empirical mode decomposition, EMD)^[12]方法的改进,其基本思想是通过向原始信号添加白噪声,利用筛分过程将信号分解为若干个仅含单一变量的固有模态分量(intrinsic mode function, IMF)。它们是幅值和频率变化的振荡函数,且必须满足以下两个条件:1)对于整个 IMF 序列,极值点的个数与过零点的个数必须相等或者最多相差 1;2)在任何一点,由局部极大值确定的信号包络和局部最小值确定的信号包络的平均值为 0。

对于原始信号 $a(t)$,使用 EEMD 将其分解成 IMF 的具体步骤如下。

1)通过给原始 $a(t)$ 添加一组高斯白噪声 $\omega(t)$ 获得总体信号。

$$a'(t) = a(t) + \omega(t) \quad (1)$$

2)将总体信号按照 EMD 方法进行分解,得到各阶 IMF 分量 c_i , 则:

$$a'(t) = \sum_{i=1}^n c_i + r \quad (2)$$

式中: i 表示第 i 个 IMF 分量; r 为残差项; n 为分解出的 IMF 个数。

3)每次加入相同幅值的不同白噪声序列 $\omega_i(t)$, 重复步骤 1~2), 可得:

$$a'_j(t) = \sum_{i=1}^n c_{ij} + r_j \quad (3)$$

式中: c_{ij} 为第 i 次加入白噪声分解出的第 i 个 IMF 分量; r_j 为第 j 次加入噪声分解出的残差值。

4)利用高斯白噪声频率的零均值原理,可以消除白噪声带来的影响,原始信号对应的 IMF 分量可以表示为:

$$c_i(t) = \frac{1}{N} \sum_{j=1}^N c_{ij}(t) \quad (4)$$

式中: N 表示加入白噪声的次数; c_i 表示对原始信号进行 EEMD 分解得到的第 i 个 IMF 分量。

1.2 SVD 降维

EEMD 分解得到的 IMF 分量存在模态混叠和白噪声残留,从而导致特征提取的不准确。针对此问题,本文提出对 IMF 分量进行奇异值分解,从而消除模态混叠和去除残留白噪声。但由于 IMF 分量均为一维信号,SVD 则是一种对二维信号进行处理的方法,鉴于此,本文首先使用 Hankel 矩阵^[13]将一维 IMF 分量转换成二维矩阵,之后再对二维矩阵进行奇异值分解,保留奇异值矩阵中前 k 个较大的奇异值,从而达到消噪的目的。

1.3 IMF 能量特征

降噪 IMF 分量为 $c'_i = [c'_i(1), \dots, c'_i(M)]$, 能量特征为:

$$e_i = \sum_j [c'_i(j)]^2 \quad (5)$$

一个振动信号的所有 IMF 分量组成一个特征能量向量 $e = [e_1, e_2, \dots, e_n]$, 为 $1 \times n$ 矩阵, n 为 IMF 分量的个数。

所有振动信号的特征能量向量即可以组成能量矩阵 E 。能量矩阵 E 的维数较高,特征不明显,无法进行特征识别。鉴于此,本文使用 LTSA 对能量矩阵 E 降维。

1.4 LTSA 降维

LTSA 是机器学习中流形学习的一种方法,其可以在充分保留数据的局部结构的前提下实现过程数据的低维流形提取,进行非线性降维。LTSA 基本思想是利用样本点邻域的切空间来表示局部几何性质,然后将这些局部切空间排列起来构造流形的全局坐标。

1.5 特征提取流程

对信号进行 EEMD 分解,为了进一步减少模态混叠以及消除信号采集过程中的噪声,对 EEMD 分解成的 IMF 进行 SVD 降噪处理,再处理得到 IMF 能量特征,并对能量特征 LTSA 降维处理,小幅蛇行特征提取框架流程如图 1 所示。

2 高速列车小幅蛇行演变诊断方法

2.1 实验数据获取

本文数据来源于某型动车组科学实验,信号采样频率为 2 500 Hz,列车速度信息由车载无线定位系统提供,加速度信息由 2 车 1 位构架横向加速度传感器提供。线路采用德国博格式无砟轨道技术,钢轨为定长 100 m 的国产钢轨。其中列车时间-速度曲线与转向架构架时间-加速度曲线如图 2 所示,时间全长为 2 491 s,经观察,该实验列车在速度 330~350 km/h 时,反复出现蛇行失稳。

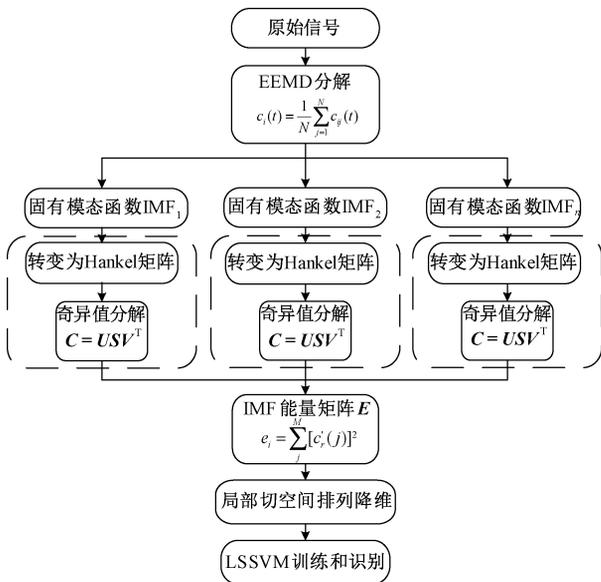


图 1 小幅蛇行特征提取框架流程

的能量矩阵 E , 由于能量特征维数为 9, 维数太高导致能量特征不好识别。

2.4 流形学习降维

针对能量矩阵维数太高不好识别, 本文对数据进行 LTSA 降维处理, 将数据降到三维, 并将特征投影到三维界面。并且, 本文引入 3 种其他基于 EEMD 的识别方法作为对比, 效果对比如图 3~6 所示。

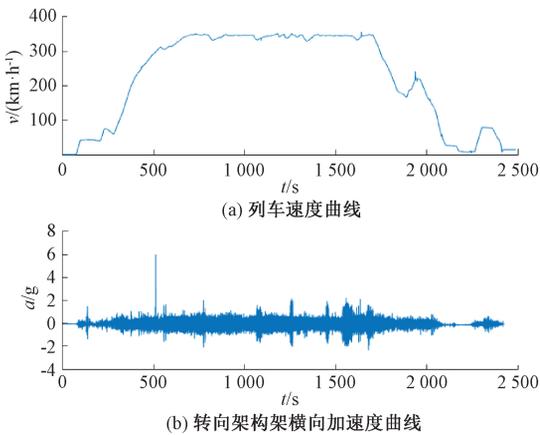


图 2 列车速度曲线、转向架构架横向加速度曲线

从转向架构架传感器得到的原始数据比较粗糙, 需要对其做一定的预处理。由于高速列车蛇行运动的频率为 2~12.07Hz^[14], 对原始数据进行 2~12.07 Hz 的带通滤波, 以有效地消除原始信号中大量的干扰信号, 提高特征识别的准确度和效率, 并根据香农采样定理^[15], 对原始数据进行采样频率为 250 Hz 的重采样, 之后对数据零均值化、消除趋势项以及平滑处理, 从而得到平滑准确的原始数据。

2.2 EEMD 分解

选取高速列车运行速度在 330~350 km/h 时, 正常运行、小幅收敛、小幅发散、大幅蛇行 4 种状态各 20 个样本, 合计 80 个样本。结合实际, 本文选择样本长度为 500, 采样时间为 2 s。

2.3 SVD 与能量特征矩阵

将 EEMD 分解后的 IMF 转换成 Hankel 矩阵, 之后进行 SVD 降维, 并提取 IMF 能量特征, 可以得到一个 80×9

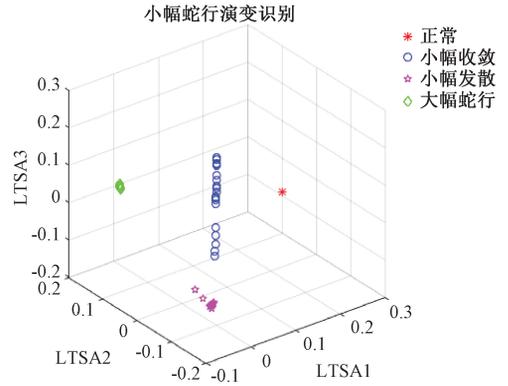


图 3 EEMD-SVD-LTSA 聚类效果

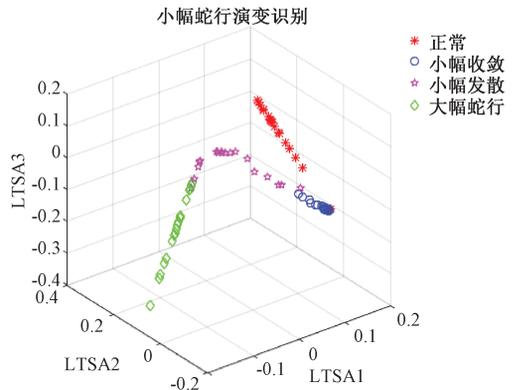


图 4 EEMD-LTSA 聚类效果

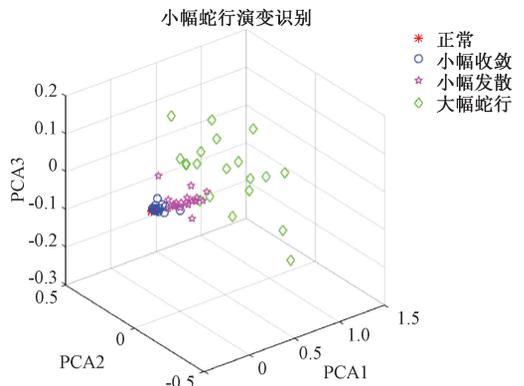


图 5 EEMD-SVD-PCA 聚类效果

图 3 所示为 EEMD-SVD-LTSA 聚类效果图, 图 4 所示

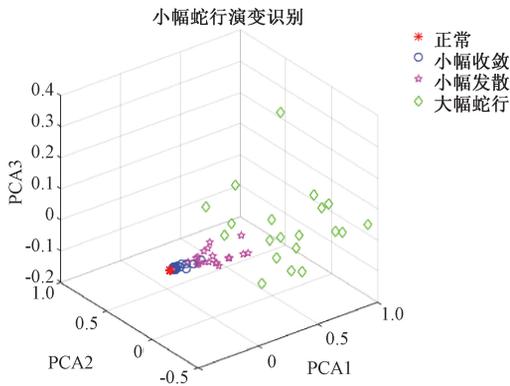


图 6 EEMD-PCA 聚类效果

为 EEMD-LTSA 聚类效果图。可以看出, 在使用了 EEMD、SVD、LTSA 对数据进行处理后的图 3 中, 4 种状态信号高度分离, 特征信息集中, 聚类效果良好, 可以很轻易地分辨出高速列车小幅收敛、小幅发散状态; 而在只使用了 EEMD、LTSA 对数据进行处理后的图 4 中, 4 种运行状态特征没有完全分开, 小幅发散特征与小幅收敛特征、大幅蛇行特征都有重叠, 而且 4 种运行状态特征的聚类效果都不好, 信息极为散乱, 显然是受到 EEMD 分解致使的模式混叠和白噪声残留的影响。图 3 和 4 也证明了本文提出框架的准确性和优越性, 这是因为列车在非平稳运行中有很多噪声信号, 使用 EEMD 对收集到的数据进行处理时也会遭到模式混叠, 双重作用下对数据造成了很大的污染, 因此本文使用 Hankel-SVD 对数据进行降噪处理, 降低了外界噪声以及 EEMD 分解时模式混叠对数据提取的影响, 最后使用流形学习的 LTSA 降维, 故可以得到较好的特征提取结果。

图 5 所示为 EEMD-SVD-PCA 聚类效果, 图 6 所示为 EEMD-PCA 聚类效果。和图 3、4 相比, 可以看出, 当使用主成分分析 (principal components analysis, PCA) 降维时, EEMD 方法和 EEMD-SVD 方法得到的特征聚类效果均不太理想, 这是因为如 PCA 的传统降维方法在处理平稳信号时具有良好的效果, 但是对于高速列车振动信号这种非线性、非平稳信号, PCA 等传统降维方法往往不能有效地处理。

2.5 LLSVM 验证

将 LTSA 降维特征作为 LSSVM 的输入, 验证特征提取的准确性。将数据分为训练和测试两类, 每类各 40 组数据 (10 组正常运行、10 组小幅收敛、10 组小幅发散、10 组大幅蛇行)。作为对比, 本文将其他方法生成的特征也一并放入 LLSVM 里面, 一半作为训练, 另一半作为测试, 生成的结果如表 1 所示。

从表 1 可以看到, 由于采用 SVD 方法去除了 EEMD 导致的模式混叠和白噪声残留, 并利用流形学习中的 LTSA 成功降维, 本文提出的方法的识别率是最高的, 达到了 100%, 这也证明了本文框架的准确性和优越性。

表 1 4 种方法识别结果对比

方法	识别率/%
EEMD-Hankel-LTSA	100
EEMD-LTSA	95
EEMD-Hankel-PCA	72.5
EEMD-PCA	72.5

3 结 论

高速列车在出现蛇行失稳前, 会进入小幅蛇行发散状态, 因此监测列车小幅蛇行演变可以提前预测列车的运行状况。本文提出的基于 EEMD-SVD-LTSA 的高速列车小幅蛇行演变特征提取框架能够很好地对高速列车不同演变趋势的小幅蛇行信号进行特征提取, 并且利用机器学习 LSSVM 方法对特征提取效果进行验证, 结果表明, 本文提出方法能成功预测高速列车是否会出现大幅蛇行的失稳状态, 有助于提高列车监测的准确性和时效性。

参考文献

- [1] STEPHENSON G. Observations on edge and tram railways[Z]. 1821.
- [2] 张卫华, 李艳, 宋冬利. 高速列车运动稳定性设计方法研究[J]. 西南交通大学学报, 2013, 48(1): 1-9.
- [3] PATER A D D. The approximate determination of the hunting movement of a railway vehicle by aid of the method of Krylov and Bogoljubov [J]. Applied Scientific Research, 1961, 10(1): 205.
- [4] 铁道部运输局. 高速动车组整车试验规范: 铁运[2008] 28 号文[S]. 2008.
- [5] POLACH O. Characteristic parameters of nonlinear wheel/rail contact geometry [J]. Vehicle System Dynamics, 2010, 48(S1): 19-36.
- [6] JING N, WANLI C, CHUANJIE C, et al. Feature recognition of small amplitude hunting signals based on the MPE-LTSA in high-speed trains [J]. Measurement, 2018, doi:10.1016/j.measurement.2018.08035.
- [7] WU Z, HUANG N E, CHEN X. The multi-dimensional ensemble empirical mode decomposition method [J]. Advances in Adaptive Data Analysis, 2009, 1(3): 339-372.
- [8] GOLUB G H, VAN LOAN C F. Matrix computations[M]. 3rd ed. Matrix Computations, 1996.
- [9] WANG Y, XU G, LIANG L, et al. Detection of weak transient signals based on wavelet packet transform and manifold learning for rolling element bearing fault diagnosis [J]. Mechanical Systems and Signal Processing, 2015, 54-55: 259-276.

- [10] ZHANG Z Y, ZHA H Y. Principal manifolds and nonlinear dimensionality reduction via tangent space alignment[J]. Journal of Shanghai University, 2004, 8(4):406-424.
- [11] 孙永奎,余志斌,金炜东.基于多重分形与 SVM 的高速列车运行状态识别方法[J].西南交通大学学报,2015, 50(1):7-12.
- [12] 崔万里,宁静,种传杰,等.EMD-ISOMAP 高速列车小幅蛇行异常特征提取[J].中国测试,2016,42(12):105-110.
- [13] 宋旭霞.一类块 Hankel 行列式性质的研究[J].呼伦贝尔学院学报,2017,25(6):125-133.
- [14] 蔡里军.基于 FPGA 的高速列车转向架蛇行失稳检测装置[D].成都:西南交通大学,2012.
- [15] 杨伟.基于牛顿插值法的模拟信号采样与重构研究[D].兰州:兰州大学,2017.

作者简介

冉伟,硕士研究生,主要研究方向为结构设计、故障诊断、数据处理。

E-mail: ranwei@my.swjtu.edu.cn

宁静(通信作者),副教授、工学博士,主要研究方向为机电系统数字化设计与控制、精密测控技术与系统。

E-mail: ningjing@swjtu.edu.cn

罗德与施瓦茨的 R&S® RTE、R&S® RTO 及 R&S® RTP 示波器 标配 16 bit 高分辨率模式

在德国纽伦堡举办的嵌入式世界 2019 展会上,罗德与施瓦茨宣布 R&S® RTO 和 R&S® RTP 示波器即日起标配 16 bit 高分辨率模式。用户将以相同的价格受益于更高的测试性能。更高分辨率的波形可以针对原本可能被噪声掩盖的信号细节进行更精确的分析。高分辨率模式将垂直分辨率提升至 16 bit。该模式现已成为所有新的 R&S® RTO 和 R&S® RTP 示波器的标配,无需额外成本。在此之前,该模式已成为 R&S® RTE 示波器的标配功能。

低通滤波器的带宽可针对实测信号特征在 10 kHz~2 GHz 可调。滤波器带宽越低,信噪比提升越高。以更高分辨率采集的波形将显示原本可能被噪声淹没的信号细节。得益于低噪声模拟前端及高精度单核 A/D 转换器,罗德与施瓦茨示波器具备优异的动态范围和测量精度。

由于实时的硬件低通滤波,示波器的波形采集和处理速率依然很高,且很快得到测量结果。所有的分析工具,包括自动测量、FFT 和历史模式均可在高分辨率模式下使用。

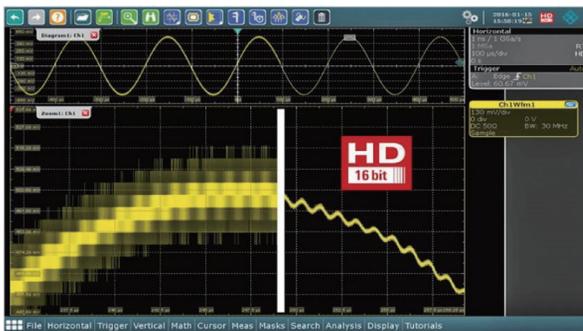
针对最小信号细节实时触发

高分辨率模式可显示最小信号细节。罗德与施瓦茨的高灵敏度数字触发系统可使用户轻松隔离此类信号细节并具体分析。每个高达 16 bit 的采样点都将与触发条件相对并在满足触发条件时触发示波器。这意味着示波器可以针对最小信号幅度进行触发。

无混叠

高分辨率模式下不会有意想不到的混叠效应。因为高分辨率模式并非基于样点抽取,分辨率的提升并不是由降低采样率得到的。打开高分辨率模式后,可设置示波器的最高采样率,以确保最佳时间分辨率。

2019 年 2 月 26 日至 28 日期间,在德国纽伦堡举办的嵌入式世界 2019 展会 4 厅 218 展台上,罗德与施瓦茨展示了配备高分辨率模式的 R&S® RTE、R&S® RTO 和 R&S® RTP 示波器。欲了解更多示波器产品信息,请访问: www.rohde-schwarz.com/oscilloscopes。



利用 16 bit 垂直分辨率精确测量

在功率电子领域,用户经常对小信号细节以及高幅度信号感兴趣,比如:对开关电源进行特性分析。高垂直分辨率在测量幅度高达几百伏的信号上的细节时十分有用。罗德与施瓦茨示波器在 A/D 转换器之后使用基于硬件的低通滤波器对信号进行滤波来实现该功能。该滤波器可降低噪声功率,有效提高信噪比并将分辨率提升至 16 bit。