

文章编号: 2095-2163(2019)06-0059-06

中图分类号: TH133.3;TP274

文献标志码: A

基于回归离散傅里叶级数的车辆轴承 多普勒信号校正方法

余晨钟, 方宇, 胡定玉
(上海工程技术大学, 上海 201620)

摘要: 由于道旁麦克风与运动车辆之间具有相对运动, 导致采集的信号存在多普勒效应, 从而增加了轴承声学故障诊断的难度。针对此问题, 提出了一种基于回归离散傅里叶级数的车辆轴承多普勒信号校正方法。该方法通过建立车辆运动学模型, 得到车辆发声时刻序列和麦克风收声时刻序列; 对麦克风采集到的信号进行时间变换, 并对经时间变换的信号进行离散回归傅里叶级数非线性拟合; 最后通过 Tihonov 正则化求解得到校正信号频谱图。相比传统校正方法, 本文提出的方法可直接获取校正信号的频域信息, 在道旁声学轴承故障诊断中有良好的应用前景。

关键词: 多普勒畸变; 滚动轴承; 离散回归; Tihonov 正则化

Vehicle bearing doppler signal correction method based on regression discrete fourier series

YU Chenzhong, FANG Yu, HU Dingyu

(Shanghai University of Engineering Science, Shanghai 201620, China)

【Abstract】 The relative motion between the microphone and the moving vehicle produces doppler effect, which increases the difficulty of bearing acoustic fault diagnosis. To solve this problem, a method of vehicle bearing doppler signal correction based on regression discrete Fourier series is proposed. Firstly, the vehicle sound generating time series and microphone sound receiving time series are obtained through the vehicle kinematics model. Secondly, the signal collected by the microphone is transformed by time, and the time-transformed signal is fitted by discrete regression Fourier series nonlinear fitting. Finally, the corrected signal spectrum is obtained by Tihonov regularization solution. This method can directly obtain the frequency domain information of the correction signal, and can effectively correct the doppler signal.

【Key words】 doppler distortion; rolling bearing; discrete regression; tihonov regularization

0 引言

滚动轴承不但支撑着车辆整体重量, 而且是车辆高速旋转的关键部件, 其状态的好坏直接影响着车辆运行的安全性^[1]。据美国有关权威部门统计, 每年约有 50 起与轴承相关的车辆发生脱轨事故^[2]。因此, 实时监控车辆滚动轴承的运行状态并对其产生的故障进行诊断, 对车辆的安全运行意义重大。

轴承声音监测系统形成于 20 世纪 80 年代^[3]。由于采集信号时, 麦克风与轴承声源存在着一段不可忽略的垂直距离, 导致轴承声源相对麦克风存在横向速度, 最终采集到的信号发生了多普勒畸变。这种多普勒畸变信号在信号频域存在频率偏移、频带展拓等问题。因此对麦克风采集的信号进行校正正是轴承声音监测系统的重点。

为解决多普勒畸变的问题, 国内外学者对此进行了深入研究。Stojanovic 等^[4]提出了锁相环技术对多普勒声信号进行校正, 随后 Johnson 等^[5]在此基础上提出了将 DFE 算法与锁相环技术相结合的方法, 实现了多普勒校正, 该方法适用于通信级别的信号校正。杨殿阁等^[6]提出了非线性时间映射法, 通过建立声场的运动学关系, 在时域对多普勒效应进行消除。然而该方法在建立运动学关系时需要诸多预知参数, 其适用范围受到限制。张海滨等^[7]提出一种基于伪时频分析的方法, 对信号的时间中心和特征频率进行估计, 进而实现对多普勒信号的校正, 但这种方法运算量较大。张翱等^[8]提出运用能量重心法来对瞬时频率进行估计, 然后对多普勒信号进行校正, 但这种方法在噪声大时提取瞬时频率非常困难, 参数估计也会因此产生较大偏差。

作者简介: 余晨钟(1994-), 男, 硕士研究生, 主要研究方向: 机械设备状态监测与故障诊断。

通讯作者: 方宇 Email: fangYu_hit@126.com

收稿日期: 2019-09-20

为了增强在多普勒校正过程中对噪声的鲁棒性,减少在信号处理过程中的谱泄露。本文提出一种基于回归离散傅里叶级数的多普勒校正方法。该方法首先对麦克风采集到的信号进行幅值校正;然后对幅值校正后的信号进行时间变换;最后通过回归离散傅里叶级数进行非线性拟合,并用 Tihonov 正则化逆求解直接得到校正后的信号频谱。

1 车辆的道旁声学运动学模型

车辆道旁声学运动学模型如图 1 所示。被测车辆轴承声源在 $t = 0$ 时刻从相距麦克风水平距离 S 处出发,相对于空气介质以速度 V 沿图示方向运动。现对麦克风测得的声源由 A 到 C 之间的信号进行分析。由于车辆车速较高,被研究的信号时间较短,可将 A 到 C 的 a 车辆轴承声源速度 V 近似视为恒定的。




图 1 车辆道旁声学运动学模型

Fig. 1 Acoustic kinematics model of vehicle roadside

假设声源在 t_r 时刻到达 B 点,此时声源振幅为 P ,声源与麦克风距离为 R ,该声信号经过 $dt = R/c$ (c 为声音在空气中的传播速度) 时间到达麦克风 O 点,到达时刻为:

$$t_s = t_r + R/c, \quad (1)$$

其中, R 可由几何关系计算:

$$R = \sqrt{(S - Vt)^2 + Y^2} = \sqrt{(S - Vt_r)^2 + Y^2}, \quad (2)$$

令 $M = \frac{V}{c}$, 将(1)带入式(2)得:

$$R = \frac{M(S - Vt_s) + \sqrt{(S - Vt_s)^2 + (1 - M^2)Y^2}}{1 - M^2}, \quad (3)$$

将(3)式带入(1)式,可得

$$t_r = t_s - \frac{M(S - Vt_s) + \sqrt{(S - Vt_s)^2 + (1 - M^2)Y^2}}{(1 - M^2)c}, \quad (4)$$

在车辆速度为亚声速的情况下,考虑车辆轴承声源为单级子点声源,并且传播介质为理想流体,即不

存在粘滞性,没有能量损耗。根据莫尔斯声学理论,从波动方程和运动关系出发可以推导出以下公式:

$$P = \frac{q'[t - R/c]}{4\pi R(1 - M\cos\theta)^2} + \frac{q[t - R/c][\cos\theta - M]V}{4\pi R^2(1 - M\cos\theta)^3}, \quad (5)$$

其中: P 为麦克风处采集到的声压; q 为单级子点声源质量总流率; $q' = \partial q / \partial t$, t 为运行时刻; Y 为声源运动直线与麦克风的垂直距离; R 为发声时刻声源与麦克风的距离; c 为声音在空气中的传播速度; θ 为发声时刻声源和麦克风连线与声源运动方向之间的夹角; V 为声源的速度, $M = V/c$ 为马赫数。式中第二项为小项,可忽略不计。因此,麦克风接收到的声压为:

$$p = \frac{q'[t - R/c]}{4\pi R(1 - M\cos\theta)^2}, \quad (6)$$

式(6)麦克风接收到的声压可表示为:

$$p = AB, \quad (7)$$

其中:

$$A = \frac{Y}{R(1 - M\cos\theta)^2}, \quad (8)$$

$$B = \frac{q'[t - R/c]}{4\pi Y}. \quad (9)$$

式(8)中 A 为因声源相对麦克风运动而产生的声压幅值调制函数,式(9)中 B 表示当声源静止在距离声源 Y 处的声压函数。 R/c 表示声波从声源处传播到麦克风需要的时间。

2 回归离散傅里叶级数(RDFS)

回归离散傅里叶级数(RDFS)拟合方法能够用来处理非均匀的离散数据。相比于经典离散傅里叶变换的方法,回归方法在处理间隔数据中能够降低谱泄露^[9]。

回归离散傅里叶级数拟合方法运用最小二乘的方法,将通用的离散傅里叶模型用来拟合非均匀的间隔数据。其表达式为:

$$x(t_n) = \sum_{k=-p}^p X_k W_{nk} + \varepsilon_n, n = 1, \dots, N, \quad (10)$$

其中:

$$W_{nk} = \exp(-i2\pi k t_n / \varphi); n = 1, \dots, N; K = -p, \dots, p; \quad (11)$$

$$\varepsilon_n = \varepsilon(t_n); n = 1, \dots, N. \quad (12)$$

式(10)中, p 为离散傅里叶级数的频率线; W_{nk} 为系数矩阵; X_k 为待求矩阵; ε_n 是实际工况中无法消除的噪声扰动项。式(11)中, φ 为离散傅里叶级

数的周期。

3 基于 RDFS 的多普勒校正方法

Tihonov 正则化是为了求解反问题的一种逼近方法,这些反问题无法或者难以求得精确解。因此,通过施加约束,使得问题在约束条件下允许 0 误差内可求解。本文通过 L 曲线来平衡约束值带来的放大误差,以及近似解与精确解的误差来获取适合的参数值。

Tihonov 正则化方法是针对不确定问题提出的,针对公式(11),定义 Tihonov 泛函:

$$J_{\alpha}(x) = \|WX - x\|^2 + \|L_{\alpha}X\|^2, \quad X \in R^n \quad (13)$$

其中, $\alpha > 0$ 称为正则化参数,考虑下面的极小化问题求 $X^{\alpha} \in R^n$ 使得:

$$X^{\alpha} = \arg \min_{X \in R^n} J_{\alpha}(X), \quad (14)$$

极小化问题(14)可等价求解矩阵方程:

$$(W^T W + \alpha^2 I)X_{\alpha} = W^T x, \quad (15)$$

式中, $\text{rank}(W) = r$ 。矩阵 W 通过奇异值分解后,正则化解 X_{α} 为:

$$x_{\alpha} = \sum_{i=1}^r \sigma_i \left(\frac{u_i^T x}{\sigma_i^2 + \alpha^2} + \frac{u_i^T \varepsilon}{\sigma_i^2 + \alpha^2} \right) v_i. \quad (16)$$

式中: u_i 和 v_i 分别表示矩阵 W 的左奇异向量和右奇异向量; σ 为矩阵 W 经奇异值分解后的奇异值;正则化参数 α 通常在 $[\sigma_r, \sigma_1]$ 之间选取,且 α 的选取直接关系到正则解 x_{α} 与精确解 x 的近似程度。

设麦克风采集到的信号数据为 (t_s, x_s) , 经幅值解调后的信号为 (t_s, x_r) 。而麦克风在 t_s 时刻采集到的信号是由声源在 t_r 时刻发出的,因此再将经幅值解调后的信号转换为 (t_r, x_r) , 从而得到一组非线性的数据。本文多普勒校正方法的关键在于通过这组非线性的数据直接求得多普勒信号校正的频谱。通过回归离散傅里叶变换将非线性数据进行拟合,最后通过 Tihonov 正则化进行逆求解直接得到校正频谱。

对麦克风接收到的信号进行多普勒校正分为四个步骤:麦克风信号的幅值校正;经幅值校正后信号的时间还原;基于回归离散傅里叶级数的非线性拟合;基于 Tihonov 正则化的校正频谱逆求解。本文提出方法的流程如图 2 所示。首先运用道旁运动学模型推导的幅值调制参数对麦克风信号进行幅值解调,再将采样时间变换为声源发声时间,从而得到一组离散的非线性数据序列,运用离散回归傅里叶级

数对其进行非线性拟合并利用 Tihonov 正则化求解,可得到去除了多普勒效应的信号频谱。




图 2 多普勒效应校正流程

Fig. 2 Flow chart of doppler effect correction

4 仿真分析

4.1 仿真信号

为了使多普勒畸变效果更突出,本文采用 3 个频率相近的信号 ($f_1 = 700 \text{ Hz}$, $f_2 = 800 \text{ Hz}$, $f_3 = 900 \text{ Hz}$) 进行仿真。仿真 $t = 0$ 时刻从相距麦克风水平距离 $S = 10 \text{ m}$, 麦克风到声源垂直距离 $Y = 2 \text{ m}$, 声速 $c = 340 \text{ m/s}$, 声源运动速度 $v = 20 \text{ m/s}$, 采样频率为 5 kHz 。

4.2 仿真结果分析

仿真信号的时域图如图 3 所示。从图中可以看出幅值随声源运动时间先增大后减小。图 4(a) 为仿真信号频谱图,可以看出带有多普勒效应的仿真信号频率分布在 600 Hz 至 1000 Hz 之间,其主要频宽 $\Delta f = 288 \text{ Hz}$ 。由图 4(b) 原始信号 STFT 时频谱也可看出,原始信号的频率偏移以及频带展拓。因此,仿真信号发生了多普勒畸变。首先对仿真信号进行幅值还原,再将信号均匀发声时间序列变换为非均匀发声时间序列,对由非均匀发声时间序列和幅值还原后的幅值序列构成的信号进行回归离散傅里叶级数非线性拟合,最后利用 Tihonov 正则化求解,得到校正信号的频谱以及 STFT 时频谱,如图 4(c) 和图 4(d) 所示。从图 4(c) 可以看到频率偏移以及频带展拓已经消失。从图 4(d) 可以看到在频率 700 Hz , 800 Hz , 900 Hz 处分别出现了一条固定不变的频带。因此,利用本文方法可以消除多普勒效应对原始信号的影响。由表 1 可以看出,频率 700 Hz 的相对误差为 0.014% ; 频率 800 Hz 的相对误差为 0.013% ; 频率 900 Hz 的相对误差为 0% ; 相对误差相对都很小,从而验证了本方法的可行性。相比于

时域插值重采样的方法,本文的方法能够在对多普勒信号校正后直接得出校正后的频谱,而不需要通过校正后的时域信号得到频谱。






图3 仿真信号

Fig. 3 The simulation signal




(a) 原信号频谱

(a) Primary signal spectrum




(b) 原信号 STFT 时频谱

(b) STFT Time spectrum of the original signal



(c) RDFS 校正信号频谱

(c) Corrected signal spectrum



(d) RDFS 校正信号 STFT 时频谱

(d) RDFS correction of signal STFT time spectrum

图4 原信号与校正信号

Fig. 4 Original signal and correction signal

表1 仿真参数值与拟合值的相对误差对照表

Tab. 1 The relative error comparison table of simulation parameter value and fitting value

	仿真值	拟合值	相对误差/%
f_1 /Hz	700	700.1	0.014
f_2 /Hz	800	799.9	0.013
f_3 /Hz	900	900	0

5 试验验证

为进一步有效验证本方法的可行性,本文对车辆滚动轴承内圈故障信号进行试验验证。轴承型号为 SKF6016,其相关参数如表 2 所示。图 5(a)为静态轴承故障实验台,图 5(b)为扬声器放置位置。轴承在 2N 的负载下,设置电机转速为 158r/min(对应实验车辆 48 km/h 的车速)产生声音信号。动态试验使用型号为 INV3060V 的数据采集设备,采集软件为 DASP-V10,采样频率为 10.24 kHz。实验将扬声器固定在移动的汽车上,麦克风与汽车行驶直线的垂直距离为 1.5 m,汽车以恒定 $V = 48$ km/h 速度行驶,用固定的麦克风采集扬声器产生的声音信号。图 6 为动态试验现场图。

表2 SKF6016 轴承参数

Tab. 2 SKF6016 bearing parameters

内径	外径/mm	滚子直径/mm	轴承宽度/mm	滚子个数
80	125	14	22	14

本文分析麦克风采集信号中心时刻前后 0.6 s 的信号。根据轴承故障特征频率计算公式,求得内圈故障特征频率理论值为 20.97 Hz。由于内圈故障特征频率理论值较小,因此本文只分析信号频率范围为 $[0, 100$ Hz]。

图 7 为采集到的内圈故障信号。图 7(a)为故

障信号时域图,图 7(b)为故障信号频域图,图 7(c)为故障信号时频图。由图 7 可以看出信号发生了多普勒畸变。在图 7(b)中可以观察出在内圈特征频率 20.97 Hz 附近出现了 $\Delta f = 1.96$ Hz 的频带展拓。



(a) 轴承实验台
(a) Bearing bench




(b) 扬声器放置位置
(b) Speaker placement


图 5 静态试验现场
Fig. 5 Static test site




图 6 动态试验现场
Fig. 6 Dynamic test site



(a) 故障信号时域图
(a) Fault signal time domain diagram



(b) 故障信号频谱图
(b) Spectrum diagram of fault signal




(c) 故障信号时频图
(c) Time frequency diagram of fault signal

图 7 内圈故障信号

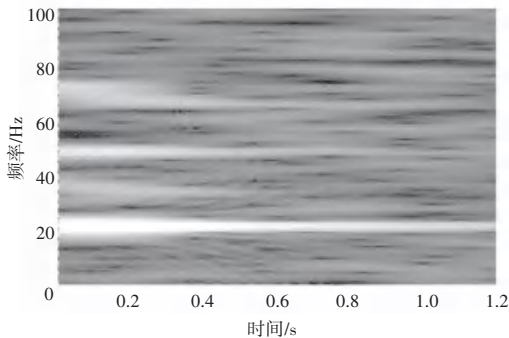
Fig. 7 Inner ring fault signal

通过本文校正方法进行校正,由图 8(a)可以观察到校正后信号的频谱图中出现了内圈故障特征频率 $f_0 = 20.94$ Hz, 与理论值 20.97 Hz 很接近;图 8(b)校正信号时频图也可看出信号的多普勒效应已被有效去除。试验结果表明了本文方法的有效性。



(a) 校正信号频谱图

(a) Calibration of signal spectrum



(b) 校正信号时频图

(b) Calibration of signal time-frequency diagram

图8 内圈故障校正信号

Fig. 8 Inner ring fault correction signal

6 结束语

本文提出了一种基于回归离散傅里叶级数的车辆轴承多普勒信号校正方法。首先对仿真结果分析,从校正后的频域图可以看到频率偏移以及频带展拓已经消失。通过试验证明,校正后信号的频谱

图中出现了内圈故障特征频率 $f_0 = 20.94$ Hz,与理论值 20.97 Hz 很接近。因此仿真和试验表明该方法完全可以运用于车辆轴承多普勒信号的校正中,且能对多普勒信号有效校正。

参考文献

- [1] ZHANG S, HE Q, ZHANG H, et al. Doppler Correction Using Short-Time MUSIC and Angle Interpolation Resampling for Wayside Acoustic Defective Bearing Diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(4):671-680.
- [2] FIRDAUSI D.Irani, 吴朝院. 先进道旁车辆状态监视系统的开发和应用[J]. 国外铁道车辆, 2002(2):39-43+45.
- [3] 刘方, 沈长青, 何清波, 等. 基于时域多普勒校正和 EEMD 的列车轴承道旁声音监测故障诊断方法研究[J]. 振动与冲击, 2013, 32(24):104-109.
- [4] STOJANOVIC M, CATIPOVIC J A, PROAKIS J G. Phase-coherent digital communications for underwater acoustic channels [J]. Oceanic Engineering IEEE Journal of, 1994, 19(1):100-111.
- [5] JOHNSON M, FREITAG L, STOJANOVIC M. Improved Doppler Tracking and Correction for Underwater Acoustic Communications [C]// IEEE International Conference on Acoustics, Speech, and Signal Processing. IEEE Computer Society, 1997:575.
- [6] 杨殿阁, 罗禹贡, 李兵, 等. 基于时域多普勒修正的运动声全息识别方法[J]. 物理学报, 2010, 59(7):4738-4747.
- [7] 张海滨, 陆思良, 何清波, 等. 多普勒畸变声学信号的伪时频分析及校正[J]. 振动与冲击, 2016, 35(5):14-20.
- [8] 张翔, 胡飞, 沈长青, 等. 基于能量重心法的列车轴承多普勒畸变故障声信号校正诊断研究[J]. 振动与冲击, 2014, 33(5):1-7.
- [9] ARRUDA J R F. Analysis of non-equally spaced data using a regressive discrete fourier series [J]. Journal of Sound and Vibration, 1992, 156(3):571-574.
- [5] 基于遗传算法的属性约简方法在股票预测中的应用研究[D]. 湖南大学, 2013.
- [6] 黄秋萍, 周霞, 甘宇健, 韦宇. SVM 与神经网络模型在股票预测中的应用研究[J]. 微型机与应用, 2015, 34(5):88-90.
- [7] 沈金榕. 基于决策树的逐步回归算法及在股票预测上的应用[D]. 广东工业大学, 2017.
- [8] VANSTONE B, FINNIE G. Enhancing stockmarket trading performance with ANNs [J]. Expert Systems with Applications, 2010, 37(9):6602-6610.
- [9] 陈祥一. 基于卷积神经网络的沪深 300 指数预测[D]. 北京邮电大学, 2018.
- [10] 韩山杰, 谈世哲. 基于 TensorFlow 进行股票预测的深度学习模型的设计与实现[J]. 计算机应用与软件, 2018, v.35(6):267-271.
- [11] MIKOLOV T, SUTSKEVER I, KAI C, et al. Distributed representations of words and phrases and their compositionality [J]. Advances in Neural Information Processing Systems, 2013, 26:3111-3119.
- [12] 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6):1229-1251.
- [13] MAO J, XU W, YANG Y, et al. Deep Captioning with Multimodal Recurrent Neural Networks (m-RNN) [J]. Eprint Arxiv, 2014.
- [14] 陈卫华. 基于深度学习的上证综指波动率预测效果比较研究[J]. 统计与信息论坛, 2018, 33(5):99-106.

(上接第 58 页)

改进:首先本文用到的数据是美股道琼斯指数和相关新闻数据,道琼斯指数是大盘指数,今后会考虑用各支股票的数据进行学习 and 训练并进行开盘价的预测;其次,本文的重点是对新闻特征进行建模,下一阶段尝试融入更多金融专业知识对股价做特征提取与计算,让 NLP 技术和金融市场更好地衔接起来。

参考文献