

基于小波降噪和EMD-SVM的 加工中心主轴系统状态监测技术*

李国发¹,王大川²,张新戈¹,杜乐¹,董精华¹

(1. 吉林大学机械工业数控装备可靠性技术重点实验室, 长春 130025;

2. 北京北一机床股份有限公司, 北京 101300)

[摘要] 主轴系统是数控机床的重要功能部件,其运行状态直接影响机床的可靠性与加工精度。为了实现状态实时监测、故障预警和维修策略优化,针对加工中心主轴系统,设计了状态监测方案,研制和搭建了加工中心状态监测平台的硬件系统和软件系统。集成小波降噪方法和经验模态分解-支持向量机(EMD-SVM)算法对采集信号处理与分析,实现加工中心主轴系统的状态实时监测,进而对主轴系统典型故障状态进行识别与诊断。基于研制的加工中心主轴状态监测系统,进行了主轴系统皮带松动故障监测试验分析,验证其对主轴系统的典型故障状态识别的准确度。

关键词: 主轴系统; 状态监测; 经验模态分解(EMD); 支持向量机(SVM); 故障识别

DOI:10.16080/j.issn1671-833x.2019.06.047



李国发

教授、博士生导师,吉林省“中青年科技领军人才”入选者。主要研究方向为机电装备可靠性技术等;发表学术论文60余篇,获国家授权发明专利23项,获吉林省科技进步一等奖1项。

主轴系统是数控机床的重要功能部件,其运行状态直接影响数控机床的可靠性与加工精度^[1-2]。为实现主轴系统的故障预警和维修策略优化,针对主轴状态监测技术进行研究具有重要的意义,特别是对数控机床主轴状态监测系统的研究,一直是该领域的研究热点。周玉清等^[3]开发了一种基于主轴电机电流的主轴状态监测系统,实现了主轴机械组件的故障诊断和主轴运行能力的评估。Xue等^[4]以轴向位移、振动、转速、温度为电主轴的状态特征态量,基于传感器和通用系统软件(Monitor and Control Generated System, MCGS),设计了数控机床电主轴的多状态参数在线监控系统。Abele等^[5]通过在数控机床电主轴上集成振动和主

轴受力测试系统、轴向位移和轴承损伤预防性监测系统,研制了主轴多状态信息融合监测系统。

数控机床主轴状态监测系统研究的关键是对采集的状态信号进行分析处理。张邦基等^[6]提出粗集理论和小波变换相结合的主轴状态特征参数获取方法。Law等^[7]提出了一种基于小波包分解和Hilbert-Huang变换的主轴轴承状态监测方法。王民等^[8]将阶次分析和试验模态测试技术结合,主要研究了电主轴运行时的振动状态。

众所周知,机械系统状态监测的目的之一是进行故障识别并预警,但是对数控机床主轴状态监测方法及系统进行研究时,主轴系统故障识别算法是基础和关键。虽然经验模态分解(EMD)与支持向量机(SVM)算法在机械系统状态监测与故障诊

* 基金项目: 国家科技重大专项资助项目(2014ZX04002031, 2018ZX04007043); 吉林省科技发展计划项目(20170204007GX, 20180312042ZG)。

断过程中具有良好的效果^[9-10],但是将 EMD-SVM 算法相融合应用于加工中心主轴系统状态监测和故障识别的研究未见报道,本文在设计加工中心主轴系统状态监测方案的基础上,研制并搭建硬件系统和软件系统,提出集成小波降噪方法和 EMD-SVM 算法对采集信号进行处理与分析,实现加工中心主轴系统的状态监测,进而对加工中心主轴系统的典型故障进行准确识别。

加工中心主轴状态监测方案

加工中心主轴系统的主要故障往往通过振动、转速、电机电流及温度等参数的异常变化来反映,但加工中心数控系统本身不能直接提供这些参数,将上述 4 个特征参数作为监测对象,主要利用相应的传感器对其进行测量。加工中心主轴状态监测系统的总体结构如图 1 所示,主要包括硬件系统与软件系统。借助硬件系统采集被监测参数的信号信息;软件系统实现参数设置和信号显示,以及信号存储、信号处理与分析等。

加工中心主轴状态监测系统搭建

根据上述主轴状态监测系统的设计方案,搭建包括传感器、采集卡和上位机的硬件系统;利用 LabVIEW 软件完成数据采集软件系统的编写。

硬件系统主要用于实现对主轴转速和振动、主轴电机电流和温度等信号的测量和采集。分别选择 HC-1F 频率变送器、KZW/P 201S 贴片式温度传感器、TA22-200 型电流互感器、356A15 通用型 ICP 加速度传感器用于特征参数信号的获取,图 2 所示为硬件系统装置及其连接。传感器安装在加工中心主轴上,并连接到 PCI 数据采集卡;采集到的信号通过 RS232 接口由数据采集卡传

输至上位机,通过上位机实现对信号的显示、处理与分析。

软件系统主要由基本信息管理模块、信号采集模块、信号存储模块、状态监测模块、信号处理与算法实现模块组成。软件系统的操作、显示主界面如图 3 所示。其中,基本信息管理模块主要包括使用者注册、操作者登录、后台信息管理等;信号采集及存储模块分别用于信号的实时采集和存储;状态监测模块实现对上述

特征参数的实时监测;信号处理与算法实现模块用于对原始试验信号进行滤波、基于 EMD 的特征信号提取和基于 SVM 的故障信号识别等功能。

主轴状态监测信号的处理与分析

1 信号的降噪处理

主轴状态监测系统所采集的原始信号中往往含有一定量的干扰信

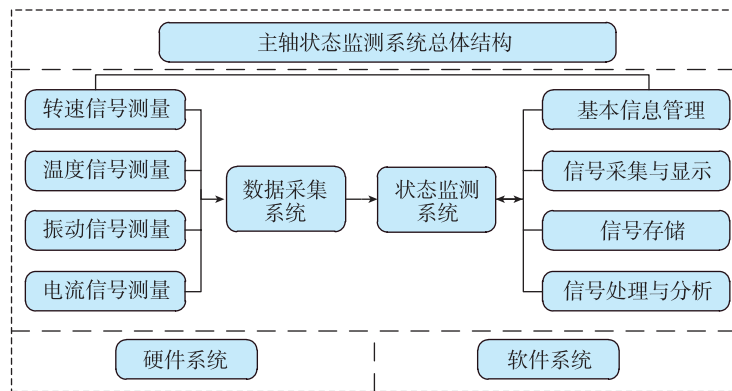


图1 加工中心主轴状态监测系统的结构

Fig.1 Structure of status monitoring system for machining center spindle




图2 硬件系统装置

Fig.2 Experimental setup of hardware system

号,特别是振动信号,其中含有大量成分复杂的干扰信号,需要通过降噪处理来去除干扰成分,从而获得真实信号。对于采集到的原始振动信号的降噪处理分别采用了基于 Birge-Massart 阈值的小波降噪方法与低通滤波降噪方法,降噪的对比效果如图 4 所示,可以看出,采用基于 Birge-Massart 阈值的小波降噪方法优于低通滤波降噪方法,降噪效果明显。因此,本文采用小波降噪方法对主轴状态监测系统采集到的振动信号进行降噪处理,进而为后续的经验模态分解以及特定故障模式的识别奠定基础。

2 基于EMD的特征信号提取

对降噪处理后的信号进行特征值提取是实现主轴系统状态识别的重要环节之一。由于经验模态分解(EMD)方法具有信噪比高、自适应性强等特点,采用 EMD 方法进行非线性周期信号特征提取时,往往具有良好的效果^[11]。基于 EMD 的特征信号提取时,首先将经过降噪处理后的信号进行分解,得到一系列有不同特征表述的数据序列——内在模态函数(Intrinsic Mode Function, IMF)分量,如图 5 所示。

其中,各 IMF 分量表示信号不同频率段所对应的成分,当原始信号发生变化时,每个 IMF 分量的频率特征会产生相应的改变,具有很强的自适应性。分解得到的前几个 IMF 分量为主要分量,体现了信号的主要特征。将提取出的几个主要分量的能量值与峰度系数组成一个特征矩阵,将该矩阵作为 SVM 分类器的输入。

3 基于SVM的信号分类和识别

由上述 EMD 方法处理获得采集到的非线性信号的一个特征矩阵,该矩阵表示一系列待识别的主轴系统工作状态。对比现有的信号分类和状态识别的算法发现,SVM 算法是基于非线性变换,将样本数据映射到高维空间,接着计算高维空间的最优线性分类面,将该平面作为

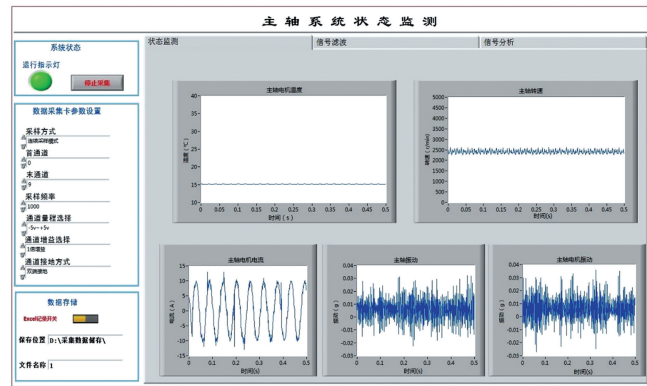




图3 软件系统主界面


Fig.3 Main interface of software system



(a) 主轴振动原始信号



(b) 基于 Birge-Massart 阈值的小波降噪处理后的信号



(c) 低通滤波降噪处理后的信号

图4 不同降噪方法处理的振动信号对比

Fig.4 Comparison of vibration signal with different de-noising methods

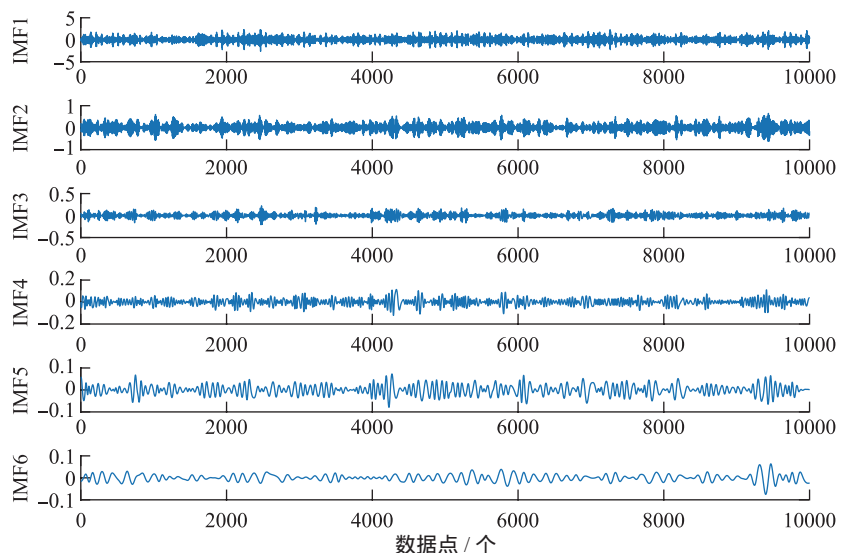


图5 EMD分解后的IMF分量

Fig.5 IMF components by EMD decomposition

训练样本的分离最优参考平面,实现该参考平面与训练样本点之间的距离范围最大化,在解决非线性信号的状态识别问题上具有很好的效果^[12-13]。

假设样本集为 $\{(x_i, y_i), i=1, 2, \dots, k\}$, $x_i \in \mathbf{R}$, x_i 是输入向量, $y_i \in \{-1, +1\}$, 是期望输出向量; k 是样本数目。针对非线性映射函数 $\psi(x)$, 在高维输入空间内创建最优分类面:

$$f(x) = \omega \psi(x) + b = 0 \quad (1)$$

其中 $\omega \psi(x) = \sum_{j=1}^k \omega_j \psi(x_j)$; ω 是权值向量; b 是阈值。该最优分类面应满足以下条件:

$$y_i f(x_i) \geq 1, i=1, 2, \dots, k \quad (2)$$

引入松弛变量 ε_i 表征支持向量机输出值与实际值 y_i 的距离, 则上述问题可转化为求下列函数极小值的问题。

$$\begin{cases} \phi(\omega, \varepsilon) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^k \varepsilon_i, \\ i=1, 2, \dots, k \\ \text{s.t.} \begin{cases} y_i (\omega x_i + b) \geq 1 - \varepsilon_i \\ \varepsilon_i \geq 0 \end{cases} \end{cases} \quad (3)$$

式中, C 是惩罚因子。核函数为 $k(x_i, y_i) = \psi(x_i) \psi(x_j)$, 当其满足 Mercer 条件时, 式(3)可以转换为:

$$\begin{cases} \max Q(\alpha) = \sum_{i=1}^k \alpha_i - \\ \frac{1}{2} \sum_{i,j=1}^k \alpha_i \alpha_j y_i y_j K(x_i + x_j) \\ \text{s.t.} \sum_{i=1}^k \alpha_i y_i = 0; \alpha_i \geq 0, i=1, 2, \dots, k \end{cases} \quad (4)$$

式中, α_i 是 Lagrange 系数; α_i 数据点即为支持向量, 其在整体样本中所占比例较小。根据式(4)可得到最优分类函数:

$$f(x) = \text{sgn} \left(\sum_{i,j=1}^m a_i y_i K(x_i, x_j) + b \right) \quad (5)$$

将需要分类的样本数据输入训练后的 SVM, 一般多个中间层结点

的组合结果值可以使用最优分类函数计算得到, 且每一节点都是输入与 SVM 的内积。基于 SVM 的状态识别如图 6 所示, 即用数字 1 和 2 代表两种状态, 当对比的两个特征矩阵为不同状态时, 测试集标签与预测集标签重合; 如果两个特征矩阵状态相同时, 测试集标签与预测集标签分离。对于一组待识别的数据, 首先利用部分数据进行训练学习, 其中具体组数通过识别率与训练组数关系图获得, 再利用剩下的数据进行状态识别, 实现对特定故障模式实时监测与诊断。

试验与讨论

加工中心主轴电机与主轴之间为带传动, 经常发生皮带松动故障。因此, 皮带松动是加工中心主轴系统的典型故障之一, 通过皮带松动试验可以很好地验证本文提出的主轴状态监测方法的有效性。为了验证状态监测系统的功能, 本文设计了在正常工作状态下与人为皮带松动(松动 1mm)状态下的对比试验, 通过采集主轴振动状态信号进行该故障的识别与诊断。

分别在主轴空转和切削加工两种不同条件下进行了试验, 通过对主轴系统不同位置的振动采集和比较分析, 发现电机底座的振动状态最能反映皮带松动故障的特征。因此, 对电机底座的振动状态进行监测, 利用加工中心主轴状态监测系统里的状态信号处理模块对不同振动状态进行识别, 每次状态识别的数据 40 组。然后, 利用 EMD 算法提取的信号特征值作为 SVM 的输入。具体情况如下: 首先利用部分数据进行训练, 再利用剩余的数据进行识别, 其中具体的训练组数根据状态识别率确定, 最后获得识别正确率和识别分析时间。

在正常工作状态下与人为皮带松动条件下, 进行主轴空运转

(转速 1500r/min) 试验时, 两种不同状态的识别如图 7 所示(以训练组数为 6 组时为例), 数字 1 和 2 分别代表正常工作状态和皮带松动状态, 当对比的两组数为不同状态时, 测试集标签与预测集标签重合。主轴空转条件下, 电机底座处振动状态识别率与训练组数关系如图 8 所示, 当训练组数为 9 组时, 识别率方可达到 100%。如图 9 所示, 分析时间与训练组数成正比, 但是分析时间基本控制在 3~5s 之间, 分析时间满足工程使用条件。

在正常工作状态条件下与皮带松动条件下, 进行切削加工试验时, 电机底座处振动状态识别率与训练组数的关系如图 10 所示, 识别率与训练组数成正比, 直到训练组数达到 21 组时, 识别率为 100%。如图 11 所示, 随着训练组数增加分析时间整体呈现增长趋势, 并且分析时间在 3~5s 之间波动, 可以满足工程使用的识别精度要求。

通过对比图 8 与图 10 可知, 在空运转条件下故障状态识别率较高, 训练组数需求较少, 更易实现故障状




图6 状态识别
Fig.6 Status recognition




图7 两种振动状态识别
Fig.7 Recognition of two kinds of vibration status




图8 主轴空转条件下训练组数与识别率关系

Fig.8 Relation of training group numbers with recognition rate under spindle idle status




图10 切削试验条件下训练组数与识别率关系

Fig.10 Relation of training group numbers with recognition rate under cutting status




图9 主轴空转条件下训练组数与分析时间关系

Fig.9 Relation of training group numbers with analysis time under spindle idle status




图11 切削试验条件下训练组数与分析时间关系

Fig.11 Relation of training group numbers with analysis time under cutting status

态识别。这是由于主轴空转时 振动和干扰均较小,容易进行信号特征的分,因此空转状态可实现更快速、更准确的故障状态识别。针对切削加工状态,只需增加训练组数就可以实现良好的状态监测效果和准确的典型故障识别。但是,本文提出的方法适应于单一型典型故障,当其他故障同时发生耦合在一起,该方法还无法识别出具体属于哪种故障模式,需要进一步深入研究。

结论

本文设计了一种基于小波降噪和 EMD-SVM 的加工中心主轴状态监测系统,搭建了硬件系统和软件系统,并进行了状态监测和典型故障状态识别的试验,得到如下结论:

(1) 设计了数控机床主轴状态监测系统方案。硬件系统由传感器、PCI 数据采集卡及上位机等组成,可以实现对主轴转速和振动、主轴电机

电流和温度等信号进行测量和采集;采用了 LabVIEW 完成系统软件的设计,可以实现对状态信号的采集、存储、处理、分析和状态识别。

(2) 采用了小波降噪方法,对采集到的状态信号进行滤波处理,将处理后的信号通过 EMD 方法提取出特征信号并组成一个特征矩阵,最后将该矩阵输入到 SVM 分类器中,实现主轴系统的状态实时监测和典型故障状态的识别。

(3) 分别在主轴系统空运转和切削加工条件下,进行了主轴系统皮带松动故障的状态监测及识别试验,通过对 40 组数据进行分析处理,得出在主轴系统空运转条件下,使用 9 组数据进行训练学习,故障识别率达到 100%;在主轴系统切削加工条件下,使用 21 组数据进行训练学习,故障状态识别率达到 100%。试验结果表明该系统具有良好的状态监测效果,可以实现典型故障模式的准确识别。

参考文献

- [1] 邢智刚,李威霖,陈锋,等.基于虚拟仪器的旋转机械主轴故障在线监测系统研究[J].机电工程,2016,33(6):722-726.
BING Zhigang, LI Weilin, CHEN Feng, et al. Research on on-line monitoring system of rotating machinery spindle fault based on virtual instrument[J]. Electrical and Mechanical Engineering, 2016, 33(6): 722-726.
- [2] 李茂胜,高荣.数控机床高速电主轴状态信号处理[J].淮阴工学院学报,2012,21(3):25-29.
LI Maosheng, GAO Rong. On signal test of motor spindle based on wavelet transform[J]. Journal of Huaiyin Institute of Technology, 2012, 21(3): 25-29.
- [3] 周玉清,孙挪刚,黎玉刚,等.基于电动机电流的数控机床主轴状态监测系统研究[J].制造技术与机床,2011(3):71-73.
ZHOU Yuqing, SUN Nuogang, LI Yugang, et al. Research of spindle state monitoring system of CNC machine tool based on motor current[J]. Manufacturing Technology and

Machine Tools, 2011(3): 71-73.

[4] XUE Y G, WANG H, LUO X Q, et al. Monitor system design for machine electric spindle based on MCGS[C]//Proceedings of International Conference on Information Engineering. New York: IEEE Computer Society, 2010.

[5] ABELE E, WÖRN A. Chameleon in the sphere of machine tool engineering. Reconfigurable multi-technology machine (RMM)[J]. ZWF Zeitschrift fuer Wirtschaftlichen Fabrikbetrieb, 2004, 99(4): 152-156.

[6] 张邦基, 于德介, 杨胜. 基于小波变换与粗集理论的滚动轴承故障诊断[J]. 中国机械工程, 2008, 19(15): 1793-1795.

ZHANG Bangji, YU Dejie, YANG Sheng. Roller bearing fault diagnosis approach based on wavelet transform and rough set theory[J]. China Mechanical Engineering, 2008, 19(15): 1793-1795.

[7] LAW L S, KIM J H, LIEW W Y H, et al. An approach based on wavelet packet decomposition and Hilbert-Huang transform (WPD-HHT) for spindle bearings status monitoring[J]. Mechanical Systems & Signal Processing, 2012, 33(2): 197-211.

[8] 王民, 张晋欣, 管涛, 等. 数控加工中心高速电主轴运行状态测试[J]. 振动、测试与诊断, 2013, 33(4): 660-663.

WANG Min, ZHANG Jinxin, ZAN Tao, et al. The running status monitoring and diagnosis of a high-speed electric spindle on CNC machining center[J]. Journal of Vibration, Measurement & Diagnosis, 2013, 33(4): 660-663.

[9] 时培明, 梁凯, 赵娜, 等. 基于深度学习特征提取和粒子群支持向量机状态识别的齿轮智能故障诊断[J]. 中国机械工程, 2017, 28(9): 1056-1061, 1068.

SHI Peiming, LIANG Kai, ZHAO Na, et al. Intelligent fault diagnosis for gears based on deep learning feature extraction and particle swarm optimization SVM state identification[J]. China Mechanical Engineering, 2017, 28(9): 1056-1061, 1068.

[10] 赵宇, 李可, 宿磊, 等. 基于假设检验和支持向量机的旋转机械故障诊断方法[J]. 中国机械工程, 2017, 28(7): 823-829.

ZHAO Yu, LI Ke, SU Lei, et al. Fault diagnosis method based on hypothesis testing and SVM for status diagnosis of rotating machinery[J]. China Mechanical Engineering, 2017, 28(7): 823-829.

2017, 28(7): 823-829.

[11] 杨宇. 基于EMD和支持向量机的旋转机械故障诊断方法研究[D]. 长沙: 湖南大学, 2005.

YANG Yu. Research on rotating machinery fault diagnosis method based on EMD and support vector machine[D]. Changsha: Hunan University, 2005.

[12] 董精华. 基于支持向量机的加工中心主轴系统状态监测技术研究[D]. 长春: 吉林大学, 2017.

DONG Jinghua. Condition monitoring technology research of machining center spindle system based on support vector machine[D]. Changchun: Jilin University, 2017.

[13] 张艳秋, 王蔚. 利用遗传算法优化的支持向量机垃圾邮件分类[J]. 计算机应用, 2009, 29(10): 2755-2757.

ZHANG Yanqiu, WANG Wei. E-mail classification by SVM optimized with genetic algorithm[J]. Journal of Computer Applications, 2009, 29(10): 2755-2757.

通讯作者: 张新戈, 博士、副教授, 主要研究方向为先进制造技术及装备, E-mail: zhangxingge@jlu.edu.cn.

Status Monitoring Technology for Machining Center Spindle System Based on Wavelet De-Noising and EMD-SVM Algorithms

LI Guofa¹, WANG Dachuan², ZHANG Xin'ge¹, DU Le¹, DONG Jinghua¹

(1. Key Laboratory of Reliability Technology for CNC Equipment of Machinery Industry, Jilin University, Changchun 130025, China;

2. Beijing NO.1 Machine Tool Co., Ltd., Beijing 101300, China)

[ABSTRACT] The Spindle system is an important functional component of CNC machine tool, and its operating status directly affect the reliability of machine tool and the machining accuracy of parts. In order to achieve real-time monitoring, fault warning and maintenance strategy optimization, a status monitoring scheme was designed for machining center spindle system, and the hardware and software systems of status monitoring platform were developed and built. The wavelet de-noising method and empirical mode decomposition (EMD)-support vector machine (SVM) algorithms were used to process and analyze the signals, so as to achieve the status real-time monitoring and diagnosis of typical fault status for the machining center spindle system. Based on the spindle status monitoring system, the spindle belt looseness fault status monitoring test was carried out, and the accuracy of recognizing the typical fault status of the spindle system was verified.

Keywords: Spindle system; Status monitoring; Empirical mode decomposition (EMD); Support vector machine (SVM); Fault recognition

(责编 逸飞)