

文章编号: 1000-582X(2011)09-009-08

功率信息互相关法的刀具破损在线监测

贺晓辉, 鄢萍, 张佳毅, 刘飞

(重庆大学机械传动国家重点实验室, 重庆 400044)

摘要: 为了在数控机床加工中对刀具破损进行有效监测以避免对工件及机床造成损坏, 提出了一种利用机床加工功率特征信息和互相关算法的刀具破损在线监测方法。该方法通过 Mallat 多分辨分析小波算法提取工件正常加工时的主轴功率变化特征序列作为监测刀具状态的特征参考模板, 在工件批量加工时采用改进的实时小波算法提取在加工工件的特征向量序列并与特征参考模板序列进行局部实时广义互相关系数计算, 当刀具发生破损失效时, 与正常情况相比在采样点计算时窗内的两特征向量序列的相关性显著降低, 将表征序列相关性的广义互相关系数定义为刀具状态系数 (Tool Condition Index, TCI), 对该系数设定合理的门限值即可监测刀具状态的异常。该方法在几种典型刀具破损的在线监测中均能准确识别刀具失效, 实验结果表明其具有一定的实用性。

关键词: 刀具状态; 在线监测; 主轴功率; 小波变换; 互相关算法

中图分类号: TH164

文献标志码: A

On-line tool breakage monitoring method based on power information and cross-correlation algorithm

HE Xiao-hui, YAN Ping, ZHANG Jia-yi, LIU Fei

(The State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044, P. R. China)

Abstract: In order to reliably monitor unexpected tool failure and prevent workpiece or machine tool from possible damages in batch machining, a tool breakage on-line monitoring method based on power information and cross-correlation algorithm is proposed. In this method, wavelet coefficients of spindle-power signal are used as the characteristic vector of machining information, and then the vector sequence extracted from a normal machining process via Mallat wavelet is defined as the reference template for monitoring cutting tool condition. In batch machining, real-time characteristic vector of the workpiece in machining process is extracted via an improved real-time wavelet algorithm. The correlation of two vector sub-sequences within a sampling time window, which is described by generalized cross-correlation coefficient, decreases apparently when the tool is broken. The generalized cross-correlation coefficient is defined as tool condition index (TCI), and tool breakage can be detected by monitoring the TCI with a threshold value. Experiments show that the method can accurately identify tool breakage failures in normal machining condition, and thus it is practical.

Key words: cutting tools' condition; condition on-line monitoring; motor power; wavelet transforms; cross-correlation algorithm

收稿日期: 2011-04-23

基金项目: 国家自然科学基金资助项目(50775228); 教育部“新世纪优秀人才支持计划”资助项目(NCET-07-0907); 重庆市重大科技攻关项目(CSTC2007AA2013); 中央高校基本科研业务费资助项目(CDJZR10110013)

作者简介: 贺晓辉(1978-), 男, 重庆大学博士研究生, 主要从事网络化制造相关研究。

鄢萍(联系人), 女, 重庆大学教授, 博士生导师, (E-mail) yp@cqmi.cn。

刀具状态监测是保证机械加工系统可靠运行和产品加工质量的关键技术之一。据统计,由刀具失效引起的加工系统故障占总体故障的 30% 左右^[1],刀具失效不仅会延误生产、报废工件,甚至会损坏加工设备。如何对刀具状态进行有效的监测,国内外学者做了大量的研究,提出了多种间接监测刀具状态的方法,包括利用电流、声发射和振动等多种传感器信号^[2-3],通过时域/频谱分析^[4-5]、小波分析等方法提取刀具故障特征信息,对特征信息进行识别并判断刀具的状态。但这些方法存在加工适用条件受限、高精度传感器成本高、性价比差^[6]及系统安装不便甚至需改变机床结构等缺点,相关研究成果多限于试验或初步应用阶段。而目前自动化加工系统上仍然广泛采用通过刀具寿命管理的方法来防止刀具的失效^[7]。虽然这种方法在提高生产效率与控制生产成本方面能够保持较好的平衡,但却无法对加工中随机发生的刀具破损、断刀等故障及时做出响应,而这往往导致严重的生产延误甚至设备损坏。

在多种间接式的刀具状态监测方法中,功率监测法因简单实用等特点得到了广泛的应用。该方法的原理是利用刀具磨损或破损时切削功率出现异常,通过测量负荷功率变化以达到检测刀具故障的目的,具有信号测量简便,监测装置易于安装等优点。但传统功率监测法也存在着一些不足:首先,功率信号随切削条件和切削参数而变化,存在随机干扰较大,时域信号特征不明显及敏感度较低等缺点;其次,功率监测法一般是采用阈值函数决策进行故障判断^[8],阈值通常根据经验和加工条件确定,具有较大的不确定性,对复杂加工环境的通用性较差。

通过分析机床加工功率信号模型,对机床正常加工过程与刀具破损加工过程时功率信号的频谱特征进行对比,依据刀具破损时功率信号与正常加工的频谱差异,利用小波变换提取功率信号不同频率尺度下的特征信号分量来描述刀具的加工状态。在线加工时对正常加工功率特征信号与实时加工功率特征信号进行互相关运算,根据互相关系数变化识别刀具的异常状态,可解决基于时域特征的功率监测法存在的问题。

1 刀具破损监测模型及算法

1.1 监测原理及模型

对数控车床等数控类加工系统,通过定量的数学推导可知^[9],工件加工时机床主轴输入功率的变化可以定量描述为时间的函数,加工参数相同的同种工件其加工过程具有相似的主轴功率/时间曲线,通过对信号进行多维空间的一个映射可提取出反映

加工内容的信号变化特征。当刀具在加工过程中出现破损时,随着刀具和工件间的断裂碎片相互挤压粘结或脱离,刀具与工件间的接触异常,切削力出现较大变化,机床主轴输入功率损耗会随之发生异常波动,与正常加工时功率信号之间的相似性被破坏,这种变化可以用一组与加工过程相关的功率特征信息的互相关系数描述:工件正常加工时,两者的互相关系数高,而刀具破损时两者的互相关系数低。据此,在工件加工时,实时提取加工过程中的主轴功率变化信息,用定长的滑动时间窗以固定的时间间隔来截取功率特征信息并与正常加工时的参考功率特征信息进行互相关运算,根据互相关系数大小即可监测刀具状态的异常并及时报警。刀具状态异常监测模型如图 1 所示。




图 1 刀具状态异常监测模型

系统通过提取正常加工过程中主轴功率变化特征建立监测加工过程的特征参考序列。在监测阶段,实时采集加工过程中的主轴功率信息并生成实时特征序列,与先前建立的特征参考序列进行局部互相关运算并根据互相关系数的变化识别加工过程的异常变化,从而监测刀具的异常状态并报警。

1.2 加工功率特征的提取方法

受载荷大小、信号干扰及加工系统正常功率波动(与加工条件相关)影响,功率信号中的刀具破损变化信息容易被噪声信号掩盖,导致其时域特征难以直接获取;而对非恒线速度加工(如端面及锥面加工等)及刀具的切入、切出等工况,基于功率微分值及信号方差的特征量则容易误判。同样直接对功率时域信号进行互相关运算也存在信号干扰大、变化复杂使得互相关系数难以区分,为了提取功率信号中与加工条件及过程相关的特征成分,需对功率信号做进一步的分析。

考虑典型的单主轴加工系统,机床主轴输入功率实质上是机床不同运行状态的功率特性的反映,当机床处于动态变化的运行状态时,机床主轴的输入功率信号模型可表示为^[9]

$$P_i = P_u + P_a + P_c + \frac{dE_s}{dt}, \quad (1)$$

式中: P_c 表示切削功率; dE_s/dt 表示系统的广义能量变化; P_0 为机床空载功率; P_a 表示机床附加载荷功率; P_0+P_a 总称机床的损耗总功率。式(1)表明机床主轴输入功率信号 P_i 由静态信号分量 $P_0+P_a+P_c$ 及动态信号分量 dE_s/dt 构成。机床稳态运行加工时, dE_s/dt 由机床加工系统的固有特征、加工载荷动态变化及信号噪声等确定,因此功率观测信号 P_i 呈现多频率信号源瞬时混叠的特点。如图2即为一段数控车床外圆车削时采集的主轴电动机有功功率信号,信号可看作由直流分量及交流分量组成,与式(1)描述一致。




图2 车床切削功率信号

对几种不同工况下的车削功率信号去直流后进行傅里叶变换以分析加工功率信号动态分量的频域特征,如图3是几种不同工况下功率信号频谱对比图。通过对大量加工功率信号分析发现,由于机床主传动系统的惯性系统特性,主轴功率信号的动态分量频率集中在低频段($f < 10$ Hz)且随加工条件而变化。




图3 几种不同工况下正常切削时功率频谱图

而在相同加工条件下功率信号的频率组成则是基本相同的。当加工过程中发生刀具破损时,功率

信号异常变化,与正常加工时相比其频谱特征也将发生改变,这也可以看作是正常加工与刀具破损2种不同工况下功率信号的变化。图4是相同加工条件下刀具正常加工与刀具破损2种不同加工过程的对比时频图,加工条件及参数见后面实验部分。

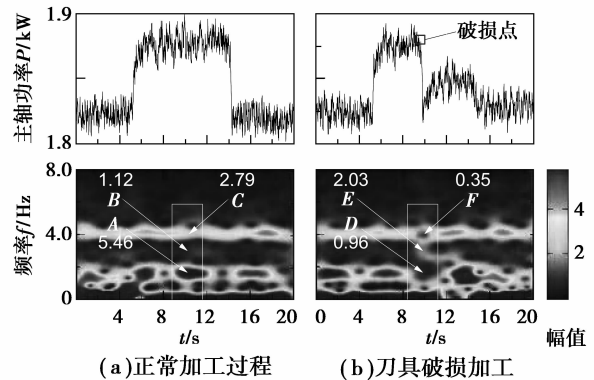


图4 正常加工与刀具破损功率信号时频图

图4(b)在加工到10 s左右时刀具发生破损失效。当刀具破损前,功率信号的时频谱在主要频段上基本一致并随加工过程变化;而当刀具破损时,部分包含在正常加工信号中的部分频率成分变弱甚至消失(如图4时频图中对比标记A/D和C/F),而其他部分频率成分与正常相比在幅值及范围上则强化(如图4时频图中对比标记B/E),表明功率信号的时频特征与加工条件相关并呈现多频率成分混叠的特点,且实际采集的功率信号还带有噪声及干扰信号,这些信号与功率信号动态分量混叠在一起,使得主轴功率信号具有时变非线性特征,传统的低通滤波与带通滤波的方法不能精确反映细微加工特征及工况的变化特征^[10]。为了提取反映加工过程及刀具故障时的主轴功率特征信息,应采用非平稳信号处理方法如经验模式分解,小波分析等^[11]。

小波变换是采用合适的基函数与信号进行变换^[12],可自适应地将信号分解为多个时频尺度上的基函数特征信号分量,在不同尺度下描绘信号的变化特征。高频尺度的信号分量体现信号的细节特征,低频尺度的信号分量体现的是信号的缓变特征。针对机床主轴功率信号具有多频率成分混叠且主要集中在低频部分的特点,多分辨小波变换可以分析并提取出反映正常加工过程的信号分量,从多个加工特征频带信号分量观察信号的变化特征并利用互相关算法判断刀具的状态,具体算法如下。

1.3 多分辨分析小波变换

小波变换是将能量有限平方可积函数空间 $L^2(R)$ 分解为一系列依次嵌套的函数子空间的和。每一子空间的基底由一系列正交小波基构成。该小波基函数的表达式为

$$\varphi_{a,b}(x) = |a|^{-1/2} \varphi\left(\frac{x-b}{a}\right), \quad (2)$$

$$a, b \in R, a \neq 0.$$

式中: φ 为小波母函数, 尺度参数 a 决定小波在频率空间中的位置; 平移参数 b 决定小波在时域空间中的位置。不同的 a 和 b 对应于不同的分辨率尺度。

利用 Mallat 快速小波分解与重构算法^[13] 可将信号自下至上按不同尺度将功率信号进行逐层分解和重构, 每层分解都将上层分解得到的低频信号进一步分解为低频(近似部分)和 高频部分(细节部分), 同时分解信号的频带区间减半, 如图 5 所示。

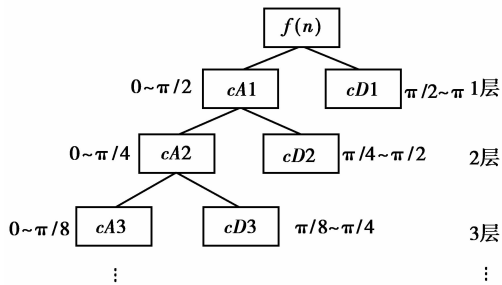


图 5 Mallat 小波变换分解图(采样频率 2π)

图中 cA_i 和 cD_i 分别代表 i 层分解的低频及高频小波系数, 设对应的重构信号为 $A_i(n)$ 和 $D_i(n)$, 分解层数为 L , 对原始信号 $f(n)$ 有

$$f(n) = A_i(n) + \sum_{j \leq L} D_j(t), \quad (3)$$

$$A_L = \sum D_j(t) = \sum \sum c(j, k) \varphi_{j,k}(t), \quad (4)$$

式中 $c(j, k)$ 为对应的小波系数。

式(3)表明信号可以用不同尺度上的细节部分信号与最大尺度近似部分信号的加权和来描述, 小波系数即为相应的权系数。

由于典型的 Mallat 算法是将所有数据从底向上计算, 只有当底层计算完成之后才能计算高层, 无法适应刀具状态的实时监测, 在刀具实际监测时必须采用改进的实时小波算法。考虑到尺度函数与小波函数都是有限支撑的, 同样进行小波分解与重构的高、低滤波器的支撑长度有限, 其所能卷积的数据也是有限的^[14]。在线监测时采用基于有限支撑的实时小波算法对功率信号进行处理, 只需要少量的低层数据就可以计算高层, 而不必等到所有低层

计算完成, 以适应刀具监测的实时性需求。具体算法实现请参考文献[15]。

1.4 互相关算法

在信号处理中, 互相关函数描述 2 个随机过程在不同时刻的关联, 而互相关系数表征 2 个信号线性相似程度。由 1.1 加工过程中刀具在不同状态时功率信号相似性的变化, 借助互相关系数所表征的信号相似程度可以判断刀具的异常状态。

定义 对于 2 个平稳随机序列 x, y , 其互相关系数为

$$\rho(x, y) = \frac{\text{Cov}(x, y)}{\sqrt{\text{Var}(x) \cdot \text{Var}(y)}}. \quad (5)$$

式中: $\text{Cov}(x, y)$ 为 x 与 y 的协方差; Var 为方差。互相关系数的绝对值介于 $0 \sim 1$ 之间。 $|\rho|$ 越趋近于 1, 则两序列的线性相关程度越高; $|\rho|$ 越趋近于 0, 则线性相关程度越低。

在实际刀具监测过程中, 采用小波变换进行特征提取得到的是由多个尺度小波重构信号与采样时间点构成的多维向量时间序列, 因此式(5)并不适用。考虑到互相关系数是由方差定义, 用多维向量协方差矩阵的迹(Trace)作为广义方差, 利用广义方差计算 2 组多维随机向量的广义互相关系数^[16]。在线监测时, 采用滑动时窗算法对功率信号实时特征序列与特征参考序列时窗内的数据进行互相关运算并判断当前加工状态与正常加工时的相似程度, 具体算法如下。

设 $\mathbf{X}(i), \mathbf{Y}(i)$ 分别表示标准小波变换信号和实时小波变换信号序列, 定义 $\mathbf{X}(k, w) = (\mathbf{X}(k-w), \mathbf{X}(k-w+1), \dots, \mathbf{X}(k)), \mathbf{Y}(k, w) = (\mathbf{Y}(k-w), \mathbf{Y}(k-w+1), \dots, \mathbf{Y}(k))$ 为在采样点 k 处长度为 w 的滑动时窗范围内 $\mathbf{X}(i), \mathbf{Y}(i)$ 特征向量的子序列, 则采样点 k 处 2 个子序列的相似程度由广义互相关系数 $\rho(k) = \rho(\mathbf{X}(k, w), \mathbf{Y}(k, w))$ 描述, 对式(5)进行修改

$$\rho(k) = \rho(\mathbf{X}(k, w), \mathbf{Y}(k, w)) = \frac{\text{tr}[\text{Cov}(\mathbf{X}(k, w), \mathbf{Y}(k, w))]}{(\text{tr}[\text{Cov}(\mathbf{X}(k, w))] \cdot \text{tr}[\text{Cov}(\mathbf{Y}(k, w))])^{1/2}}, \quad (6)$$

$$k = w, w+1, \dots, n.$$

式中: 符号 $\text{tr}[\]$ 表示矩阵迹运算; $\text{Cov}(\mathbf{X}(k, w)), \text{Cov}(\mathbf{Y}(k, w)), \text{Cov}(\mathbf{X}(k, w), \mathbf{Y}(k, w))$ 为协方差矩阵运算。

由于机床加工过程是一个变载荷过程, 主轴的启动及加工过程存在一些不确定因素, 信号采集系

统的采样精度以及采样时间也存在误差等原因,计算获得的实时小波系数和标准小波系数之间存在着一定的时延,计算 $\rho(k)$ 时需要考虑时延参数:

$$\rho(k) = \rho(\mathbf{X}(k, \omega), \mathbf{Y}(k, \omega), j) = \text{Max}\{\rho(\mathbf{X}(k+j, \omega), \mathbf{Y}(k, \omega))\},$$

$$j = -M, -M+1, \dots, 0, 1, \dots, M. \quad (7)$$

式中: j 表示时延对应的采样点数; M 表示最大时延范围,广义互相关系数取在 $-M$ 到 M 时延范围内得到的广义互相关系数绝对值最大的值。随着新采集点的加入,移动计算时窗就可得到实时加工功率广义互相关系数序列 $\rho(k)$, $k = \omega, \omega+1, \dots, n$ 。由于广义互相关系数无法明确表示刀具的状态,因此定义刀具状态系数 TCI(Tool Condition Index)来表征刀具的状态,令

$$\text{TCI} = 1 - |\rho|, -1 < \rho < 1. \quad (8)$$

则 TCI 将广义互相关系数所表示的刀具状态归范到 $0 \sim 1$,当加工正常时,TCI接近 0 ;而刀具破损失效时 TCI 则接近 1 。根据刀具正常加工下的 TCI 值设定合适的门限值 Δ_{th} ,当 $\text{TCI} > \Delta_{th}$ 时,表示刀具状态异常。

2 监测步骤及流程

监测前通过对工件进行试加工,利用典型 Mallat 算法计算对正常加工过程功率信号进行分解,提取代表加工功率变化特征的频带分量序列作为加工参考序列;在实际加工监测过程中,采用实时小波变换算法提取功率特征信息组成实时特征向量序列,并与参考模板序列在采样点计算时窗内进行局部广义互相关系数校验,并对刀具异常状态进行判别,具体步骤如下:

1)对正常加工功率信息进行分析,确定功率信号小波变换信号分解层数并选取代表加工功率变化特征的特征向量 \mathbf{X} ;

2)对工件进行试加工,获取完整的加工功率序列并进行标准小波变换,提取代表加工功率变化特征的信号分量,得到特征向量参考模板序列 $\mathbf{X}(i)$, $i = 1, 2, \dots, n$;

3)正常加工时对刀具状态进行监测,获取实时功率采样值并计算实时小波特征向量序列 $\mathbf{Y}(i)$, $i = 1, 2, \dots, k, k < n, k$ 为实时采样计算点;

4)按公式(6)–(8)计算 $\mathbf{X}(i, k)$ 与 $\mathbf{Y}(i, k)$ 的广义互相关系数 $\rho(k)$ 及刀具状态值 TCI,当 $\text{TCI} > \Delta_{th}$ 时报警。

刀具状态监测过程的完整流程如图6所示。

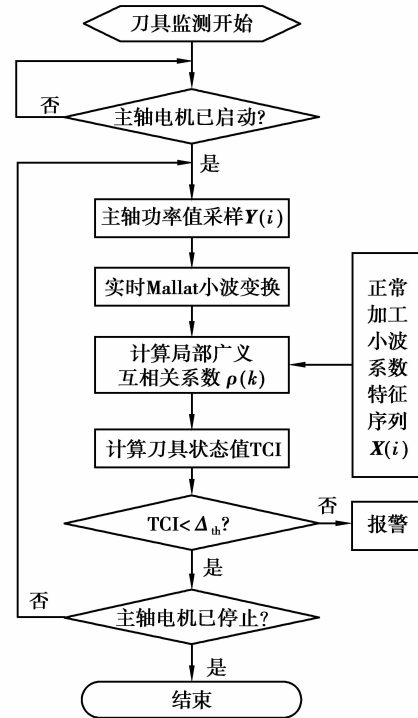


图6 实时刀具破损监测流程图

3 实验及结果分析

3.1 刀具监测系统

为了验证该算法的有效性,以CK6136数控机床为目标系统建立加工实验平台,如图7所示。主轴功率信号采集系统由功率变送器、A/D转换模块及负责数据处理的信息交互终端等几个部分组成。功率变送器装在数控机床的主轴电动机变频器的输入端,负责采集机床主轴输入功率信号;A/D采集模块负责将模拟信号转换为数字信号得到工件加工的功率值信息,并将转换结果实时发送给信息交互终端,采样频率取 48 Hz ,精度为 12 位。

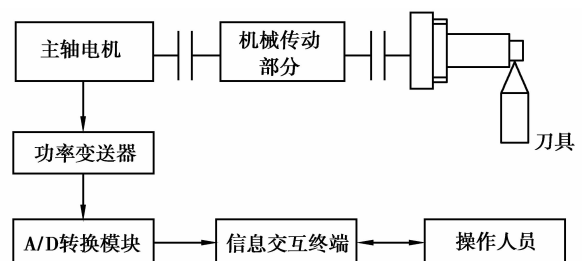


图7 系统结构图

验证实验采用硬质合金刀具对直径 40 mm 铝合金棒进行外圆切削实验,并通过在加工材料中嵌入硬质合金点的方法模拟实际加工中的刀具破损情况。通过信息终端实时记录正常加工及刀具破损失效情况下的功率信息,对刀具破损监测算法进行验

证,加工参数见表1。

表1 车削加工实验测试条件

进给速度 /(mm·r ⁻¹)	切削深度 /mm	切削速度 /(r·min ⁻¹)
0.20	3.0	400
0.12	1.0	700
0.10	0.4	1 000

由于 Daubechies 小波具有正交紧支、高正规性及具备 Mallat 快速算法等特点,适用于信号的异常检测,结合 1.1 中功率信号的频谱特征,采用 Daubechies 小波族中的 DB4 小波算法对功率信号进行 4 层分解重构,对多组正常加工进行相关验证后选取反映加工过程功率变化特征的 $D_2 \sim D_4$ 、 A_4 等 4 个小波重构信号作为主轴功率信号的特征向量。最后组成功率信息特征向量 $\mathbf{X} = (A_4, D_1, D_2, D_3)^T$ 。实时监测时计算时窗长度 M 取 100,时延系数取 $M/2$ 。

3.2 刀具失效形式及监测

通过大量的实验及研究分析,实验发现刀具破损或断刀失效时机床主轴功率变化主要包括几种情况:1)功率信号出现持续增加;2)功率信号突然下降到空载功率;3)功率信号先上升后又迅速下降到空载功率。图 8 是正常加工与几种典型刀具失效时的机床主轴功率曲线对比。




图8 不同刀具状态下车削时主轴功率变化曲线

在大量加工试验基础上,对加工过程中几种典型的刀具失效进行算法验证如下。

1) 刀具失效时主轴功率持续增加:当刀具发生严重磨损或破损时,对比正常情况机床主轴功率持

续增加,如图 8(b),这种变化也体现在各层小波系数中。图 9(a)、(b)是正常刀具加工与破损刀具车削加工到 7 s 时窗内的实时小波系数对比,此时根据式(4)计算的监测点时窗内数据的广义互相关系数不到 0.5,而正常加工时的广义互相关系数在 0.9 左右,由此时两曲线的相关程度较低可判断加工异常。图 9(c)是完整的加工监测过程刀具加工状态系数(TCI)曲线图。




图9 刀具失效时功率波动异常监测

2) 刀具失效时功率突然下降:当刀具破损失效使切削深度有较大的减小或空切时,主轴功率消耗减小。图 10(a)、(b)中当车削加工到 9 s 左右,主轴功率随刀具破损出现下降,通过实时计算的小波系数 A_4 、 $D_1 \sim D_4$ 等对比正常加工过程在 9 s 附近都出现了异常,根据广义互相关系数计算的刀具故障状态值 TCI 接近于 0.9。图 10(c)是实时加工监测过程刀具状态系数(TCI)曲线图。

3) 刀具失效时功率上升后又下降:在图 8(c)的刀具失效中,功率值先上升后又降低。这通常由两种刀具失效引起:一是由于刀具破损时碎片塞挤在刀具和工件之间引起功率骤升,随后碎片脱落又使功率下降;二是刀具发生断刀失效引起功率变化。图 11(a)、(b)是功率值突变时刻的功率值小波变换

系数,与正常加工的小波系数进行互相关计算得到广义互相关系数绝对值为 0.04,说明两者完全不相关,此时加工状态值 TCI 在功率值突变时接近于 1,完整的监测过程如图 11(c)所示。




图 10 刀具失效时功率下降异常监测




图 11 刀具失效时功率先上升后下降异常监测

3.3 分析讨论

以上是几种典型刀具破损失效的监测情况,通过对多种不同加工条件测试发现算法对刀具状态识别率受门限值 Δ_{th} 的选取及刀具破损程度影响较大,实验表明正常加工过程中功率特征序列与参考加工特征序列的实时广义互相关系数取值范围在 0.70~0.95 之间,而当刀具急剧磨损(后面磨损量 $VB > 0.35 \text{ mm}$)或出现破损情况时的广义互相关系数不足 0.6,发生断刀失效时广义互相关系数低于 0.1。表 2 是车床半精加工与粗加工条件下几种门限值下正常刀具与破损刀具对比加工的识别率及误判率,结果表明在监测门限值 Δ_{th} 设为 0.3~0.4 时识别率较高($>95\%$)且误判率较低。

表 2 车床加工刀具破损识别

门限值 Δ_{th}	识别率/%	误判率/%
0.2	99	12
0.3	96	4
0.4	95	3
0.5	91	2

4 结 论

1)提出了一种利用机床主轴加工功率信息对刀具破损进行监测的方法:该方法利用小波变换算法对主轴功率信号进行多尺度分解,提取代表正常加工过程功率变化特征的频带分量序列作为加工参考模板;在正常加工时,采集主轴功率信号并进行实时小波变换,在采样点计算时窗内对实时特征向量序列与参考模板序列进行广义互相关运算,当刀具破损时,与正常情况相比,由广义互相关系数表征的序列相关度显著降低,将广义互相关系数定义为刀具状态系数(TCI),设定门限值监测该系数的变化就可以确定刀具的状态是否异常并报警。

2)基于互相关算法的刀具状态识别避免了一般阈值决策法的不确定性。通过实验分析表明,该方法可有效地在线监测刀具破损故障。

3)利用主轴功率监测刀具状态的方法,具有通用性较好、成本低、简单可靠易于实施等优点,目前该方法已集成到课题组开发的车间制造过程信息化平台中,并已应用于多个制造车间中。

参考文献:

- [1] 彭跃湘. 数控机床故障诊断及维护[M]. 北京:清华大学出版社,2006.
- [2] KUNPENG Z, WONGA Y S, HONG G S. Wavelet analysis of sensor signals for tool condition monitoring: a review and some new results[J]. International Journal of Machine Tools and Manufacture, 2009, 49(7/8): 537-553.
- [3] 高中涛, 刘仁龙. 印刷电路板数控机床断刀检测系统[J]. 重庆大学学报, 2008, 31(3): 290-293.
GAO ZHONG-TAO, LIU REN-LONG. Data controlling on break detect system of machine tool base on the print circuit board [J]. Journal of Chongqing University, 2008, 31(3): 290-293.
- [4] AMER W, GROSVENOR R I, PRICKETT P W. Sweeping filters and tooth rotation energy estimation (TREE) techniques for machine tool condition monitoring[J]. International Journal of Machine Tools and Manufacture, 2006, 46(9): 1045-1052.
- [5] YESILYURT I. End mill breakage detection using mean frequency analysis of scalogram [J]. International Journal of Machine Tools and Manufacture, 2006, 46(3/4): 450-458.
- [6] ZHANG J Z, CHEN J C. Tool condition monitoring in an end-milling operation based on the vibration signal collected through a microcontroller-based data acquisition system [J]. The International Journal of Advanced Manufacturing Technology, 2008, 39(1): 118-128.
- [7] 周凯, 刘成颖. 现代制造系统[M]. 北京:清华大学出版社, 2005.
- [8] SHAO H, WANG H L, ZHAO X M. A cutting power model for tool wear monitoring in milling [J]. International Journal of Machine Tools and Manufacture, 2004, 44(14): 1503-1509.
- [9] 刘飞, 刘军, 何彦. 基于参考功率曲线的大型工件加工进度状态信息的自动采集新方法[J]. 机械工程学报, 2009, 45(10): 111-117.
LIU FEI, LIU JUN, HE YAN. Automatic collection method of machining progress information for large-size workpieces based on reference power curve[J]. Chinese Journal of Mechanical Engineering, 2009, 45(10): 111-117.
- [10] MAO X Y, LIU H Q, LI B. Time-frequency analysis and detecting method research on milling force token signal in spindle current signal[J]. Science in China Series E: Technological Sciences, 2009, 52(10): 2810-2813.
- [11] HE Z J, CAO H R, LI Z, et al. The principle of second generation wavelet for milling cutter breakage detection[J]. Science in China Series E: Technological Sciences, 2009, 52(5): 1312-1322.
- [12] 胡友强, 柴毅, 李鹏华. 在线多尺度滤波多变量统计过程的适时监测 [J]. 重庆大学学报, 2010, 33(6): 128-133.
HU YOU-QIANG, CHAI YI, LI PENG-HUA. Real-time monitoring for multivariate statistical process with on-line multiscale filtering [J]. Journal of Chongqing University, 2010, 33(6): 128-133.
- [13] MALLAT S, HWANG W. Singularity detection and processing with wavelets [J]. IEEE transactions on information theory, 1992, 38(2): 617-643.
- [14] AKOJWAR S G, PATRIKAR R M. Real time classifier for industrial wireless sensor network using neural networks with wavelet preprocessors [C] // IEEE International Conference on Industrial Technology, December 15-17, 2006, Mumbai. [S. l.]: IEEE, [2007-06-18]: 512-517.
- [15] 张佳毅. 数控机床批量加工过程异常状况的功率监测技术研究[D]. 重庆:重庆大学, 2009.
- [16] 林文元, 林春土. 广义相关系数和若干极值[J]. 高校应用数学学报: A辑, 1991, 6(2): 222-228.
LIN WEN-YUAN, LIN CHUN-TU. Generalized correlation coefficients and some extremes [J]. Applied Mathematics: A Journal of Chinese Universities, 1991, 6(2): 222-228.

(编辑 张 苹)