

## 基于特征融合的刀具磨损监测方法\*

杨林 李圣怡 梁建成 吴学忠

(国防科技大学机械电子工程与仪器系 长沙 410073)

**摘要** 提出了一种基于特征融合的刀具磨损监测方法,将该方法应用于铣刀磨损监测取得了较好的效果,文中论述了特征融合方法的基本思想,多传感器信号的特征关联、抽取及正规化处理,作为融合中心的神经网络的构造及训练等内容。实验分析表明,该方法实现刀具磨损监测是行之有效的。

**关键词** 刀具磨损,特征融合,神经网络,监测

**分类号** TH161

## A Tool Wear Monitoring Method Based on Feature Fusion

Yang Lin Li Shengyi Liang Jiancheng Wu Xuezhong

(Department of Electromechanics and Instrumentation, NUDT, Changsha, 410073)

**Abstract** This paper presents a tool wear monitoring method based on feature fusion via neural networks. The basic principle of this method, feature association, feature extraction, data normalization and neural networks construction of the method are discussed. The experimental results show that the proposed method for tool wear monitoring is reliable and effective.

**Key words** tool wear, feature fusion, neural networks, monitoring

刀具磨损一方面会引起工件尺寸误差,影响工件表面质量,同时也会诱发切削系统颤振,恶化切削过程的稳定性。因此,对于精密切削过程,尤其是无人参与的智能化加工过程,刀具磨损监测研究显得十分重要。

从国内国外的资料来看,刀具磨损监测的方法很多,但是作为真正的实用化技术大都还显得不很成熟,切削过程的随机性、复杂性使得这些刀具磨损监测方法的适应性不

\* 国家自然科学基金资助项目

1996年3月25日收稿

强，即环境中的随机因素和切削过程的参数变化对于监测效果影响很大。

近年来，越来越多的研究者倾向于采用多传感器融合技术来实现对加工过程的监测，本文采用声发射传感器和三向测力传感器对铣刀的切削状态进行监测，运用特征融合方法，通过神经网络建立了传感器信号特征与铣刀磨损量之间的映射关系。

## 1 特征融合方法

特征融合方法在结构上可分为四级：信号级、模型级、特征级和融合级。

在信号级使用多传感器（如力、声发射、振动等传感器）对加工过程的状态进行监测，并转换成相应的物理量。这一级的特点是还没有形成能充分描述过程特性的合适数学模型，需要解决的问题是如何根据被监测对象选择合适的传感器以及如何提高多传感器的监测效能。

在模型级将多传感器获得的信号进行处理，建立各自的过程模型，这里的过程模型指的是能反映被监测对象特性或对被监测对象敏感的表达式，如常用的功率谱分析、时序建模分析等。

在特征级主要是对模型级提供的信息特征进行关联配准并抽取，然后在此基础上对具有不同物理概念的特征数据进行归一化处理，为后面的融合处理提供一致性的特征数据。

融合级根据前面几级处理的结果，通过神经网络进行融合处理，从而对被监测对象进行有效的识别与估计。

## 2 特征关联、抽取与正规化处理

### 2.1 特征关联

切削过程较为复杂，会受到各种确定性因素及不确定性因素的影响。对于刀具磨损监测而言，传感器检测的信号，既有可能是由于刀具磨损造成的，也可能是由于其它切削条件发生了变化而引起的。因此就需要对传感器信号特征与其它切削条件（如切削参数）的相关程度作出评价。本文提出以下特征关联分析方法。

这里假设对特征  $b$  进行关联分析。

定义切削条件集合： $C = (c_1, c_2, \dots, c_k)$ ；

假设刀具磨损对应切削条件  $c_1$ ，有  $N$  种磨损状态；

对于切削条件  $c_j$ ，( $c_j \in C$ )，假设该切削条件有  $M$  种状态，保持其余切削条件  $C_l$ ， $l \neq j$  不变；

特征参数  $b$  遍历切削条件  $C_{j,i}$ ， $1 \leq i \leq M$  的均值定义为

$$\bar{b}_{c_j} = \frac{1}{M} \sum_{i=1}^M b_{c_j,i} \quad (1)$$

特征参数  $b$  对于切削条件  $c_j$  的关联度定义为

$$\sigma_{c_j} = \left[ \frac{1}{M} \sum_{i=1}^M (b_{c_j,i} - \bar{b}_{c_j})^2 \right]^{\frac{1}{2}} \quad (2)$$

特征参数  $b$  对于刀具磨损的关联度定义为

$$\sigma_{c_1} = \left[ \frac{1}{N} \sum_{i=1}^N (b_{c_1,i} - \bar{b}_{c_1})^2 \right]^{\frac{1}{2}} \quad (3)$$

特征参数  $b$  对于刀具磨损与切削条件  $c_j$  的关联度比定义为

$$R(c_1, c_j) = \frac{\sigma_{c_1}^2}{\sigma_{c_j}^2} = \frac{M \sum_{i=1}^N (b_{c_1,i} - \bar{b}_{c_1})^2}{N \sum_{i=1}^M (b_{c_j,i} - \bar{b}_{c_j})^2} \quad (4)$$

选取合适的  $\xi$ ,  $\lambda$ ,

$R(c_1, c_j) \geq \xi$ , 说明特征参数  $b$  较强地依赖于刀具磨损的变化, 而对切削条件  $c_j$  不敏感。

$R(c_1, c_j) < \lambda$ , 说明切削条件  $c_j$  发生变化时, 特征参数  $b$  有较强的表现, 从而有可能导致无法辨别是刀具发生磨损还是切削条件  $c_j$  发生了变化。因此特征参数  $b$  将不作为待选特征。

$\lambda \geq R(c_1, c_j) < \xi$ , 说明特征  $b$  对于刀具磨损与切削条件  $c_j$  的相关性都较强, 因此构造合适的加权函数  $w(c_j)$ , 该函数与切削条件  $c_j$  有关, 特征  $b$  以  $w(c_j)b$  替换, 从而尽量削弱  $c_j$  的影响。

## 2.2 特征抽取

在刀具状态监测的研究中, 目前较为广泛使用的传感器有声发射和力传感器。研究表明, AE (声发射) 和切削力信息与刀具磨损的不同程度有关。声发射对与塑性变形和切削区裂变有关的微观活动 (应力波) 敏感, 切削力谱对由于后刀面磨损而导致的刀具与工件间的振动敏感。使用 AE 和切削力传感器的优点是, 它们能提供与刀具磨损的微观 (应力波) 和宏观 (振动) 特性有关的信息。

大量切削实验表明, 随着刀具磨损量的不断增加, 三向切削力信号的功率谱特性发生变化, 并且分布在不同的频段, 文中以频段能量作为待选取的特征。

频段能量定义为:

$$\Delta E_{mm} = \sum_{i=m}^n P(i\omega), m \leq i \leq n, m \leq n \leq \frac{N}{2}, \omega = \frac{2\pi \cdot f_s}{N}, \quad (5)$$

式中  $R(i\omega)$  为功率谱密度,  $f_s$  为采样率,  $N$  为样本长度。

对于声发射信号, 采用时间序列建模方法进行处理。切削过程中刀具磨损导致信号发生变化时模型参数随之变化, 可据此跟踪刀具磨损变化, 但不是所有模型参数都对刀具磨损敏感。如果一些模型参数随刀具磨损变化不显著, 或模型的阶次太高导致分析困难, 就需去除某些不重要的模型参数。

对任一刀具状态 “ $t_1$ ”, 第  $i$  个特征参数均值被定义为与时间有关的均值:

$$\bar{b}_{i,t_1} = \frac{1}{M} \sum_{k=1}^M b_{i,t_1}(k), M \text{ 为时间步长总数。} \quad (6)$$

描述刀具状态的第  $i$  个特征参数类内离散度定义如下:

$$S_{i,t_1} = \left[ \frac{1}{M} \sum_{k=1}^M (b_{i,t_1}(k) - \bar{b}_{i,t_1})^2 \right]^{\frac{1}{2}} \quad (7)$$

为了评价参数  $b_i$  区分刀具磨损状态  $t_1, t_2$  的能力, 描述刀具状态的第  $i$  个特征参数

类间差定义如下:

$$Q_i[t_1, t_2] = |b_{i,t_1} - \overline{b_{i,t_1}}| \quad (8)$$

辨别任意两种刀具状态  $t_1, t_2$  的指标  $J_i(t_1, t_2)$  可由标准化的  $Q_i(t_1, t_2)$  与  $S_{i,t_1}, S_{i,t_2}$  获得:

$$J_i(t_1, t_2) = \frac{Q_i(t_1, t_2)}{(S_{i,t_1}, S_{i,t_2})^{\frac{1}{2}}}, t_1, t_2 = 1, 2, \dots, N_i, t_1 \neq t_2 \quad (9)$$

式中  $N_i$  为刀具磨损状态的模式总数, 可根据需要确定其具体数值。

$J_i(t_1, t_2)$  越大, 对应的第  $i$  个特征参数辨别刀具磨损状态的能力则越强。因此,  $J_i(t_1, t_2)$  将被作为特征抽取的依据。重要的特征参数具有较大的  $J_i(t_1, t_2)$  值, 具有较小的  $J_i(t_1, t_2)$  值的特征参数将被去除。

取合适的  $\eta$  值为选择特征参数的检测门限,  $J_i(t_1, t_2) \geq \eta$  选定;  $J_i(t_1, t_2) < \eta$  去除。

### 2.3 特征值的正规化处理

正规化处理的目的是将关联、抽取后的特征向量进行标准化处理, 因为经过预处理和特征抽取后的特征向量, 其幅值一般都很不一致, 经过正规化处理后, 便于分析和比较。同时, 作为神经网络的输入向量, 经正规化处理后会避免训练过程中特征参数过大或过小而导致的网络作用函数的饱和现象。文中采用以下正规化公式:

$$x = \frac{x' - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

$x'$  为正规化前的特征参数  $x_{\max} = \max(x)$ ,  $x_{\min} = \min(x)$ ;  $x$  为正规化后的特征参数。

经过这样的标准化处理以后, 特征参数被压缩到  $[0, 1]$  区间。

## 3 特征融合中心—神经网络的构造

本文采用 3 层 BP 网络作为特征融合的中心。理论上讲, 一个 3 层 FNN (前馈神经网络), 只要具有足够的隐层节点, 就能以期望的精度逼近任一非线性函数。本文中网络的输入层节点数对应于特征抽取后的特征维数。输出层节点数对应于铣刀的刀刃数。隐层节点数的选择合适与否直接影响到神经网络的融合效果。隐层节点数太少, 势必将输入层传过来的信息过分压缩, 导致映射逼近能力的下降; 隐层节点数太多, 网络的非线性过于复杂, 计算所需的时间大大加长。

网络结构确定以后, 即可通过大量样本对网络进行训练。训练时, 神经网络的输入为多维特征参数, 输出为铣刀的实际磨损测量值。训练学习结束后, 当对网络输入一新样本时, 网络的输出对应于新输入样本的刀具磨损估计值。

## 4 实验分析

刀具磨损监测实验过程是: 在一定的切削条件下, 使用九把磨损程度不一的三刃铣刀进行铣削加工, 分别记录多组切削力信号和 AE 信号, 离散测量每把铣刀的磨损量, 刀具的测试结果经正规化处理后作为神经网络训练时的期望输出。依据特征关联、抽取方法, 选取 X, Y 两方向切削力信号的 8 个频段能量, 将 AE 信号的两个 AR 模型系数及残差作为特征融合的输入。

为了在有限的实验数据情况下验证特征融合监测方法的有效性,根据惯用的方法,采用循环抽样验证方法是合理的,即在九把铣刀中任意抽样 8 把刀作为训练刀具,从而建立特征与磨损量之间的神经网络模型。余下的一把刀作为被监测对象,通过已建立的模型估计该刀的磨损值。

本研究针对一把刀的刀磨损进行监测,将声发射与测力传感器组合的特征融合监测,与单传感器的特征融合监测的效果进行了比较,实验结果表明两传感器的监测效果比单传感器的效果好,限于篇幅这里仅给出声发射与测力传感器的信号特征进行融合监测的结果(见表 1)。

表 1

样本号 刀刃	1	2	3	4	5	6	7	8	9	10	实际 磨损量
A	0.660	0.651	0.657	0.651	0.658	0.669	0.664	0.658	0.649	0.661	0.6
B	0.747	0.735	0.730	0.728	0.735	0.754	0.747	0.741	0.731	0.745	0.6
C	0.816	0.820	0.816	0.812	0.811	0.811	1.813	0.810	0.813	0.818	0.7

## 5 结论及展望

采用多传感器能够获取充分反映加工过程本质的特征信息,神经网络方法能够综合各因素对切削过程的影响以及切削过程所表现出的多方面信息,从而建立切削状态(刀具磨损、表面粗糙度等)与多传感器特征信息之间的非线性映射关系。总之,本文介绍的特征融合方法应是解决未来加工过程建模及监测问题的最有希望的研究方向之一,必将为发展 PMS、CIMS 工程,乃至 21 世纪全新概念的智能制造技术作出重要贡献。

## 参考文献

- 1 Rangwala S, Donfeld D A. Sensor intergration using neural networks for intelligent tool condition monitoring. *Journal of engineering for industry*, 1990, 112: 219~228
- 2 Donfeld D A. Neural networks sensor fusion for tool condition monitoring. *Annals of the CIRP*. 1990, 39(1): 101~105
- 3 Chryssolours C, Domroses M. An Eexperimental study of stratehies for intergratin sensor informa-tion in machining. *Annals of the CIRP*, 1989, 38(1): 425~428

(责任编辑 卢天凯)