

基于 EMD-SVM 的钛合金铣削过程刀具磨损监测*

谢振龙¹, 岳彩旭¹, 刘献礼¹, 严复钢¹, 刘智博¹, 穆殿方¹, 梁越昇²

(1. 哈尔滨理工大学先进制造智能化技术教育部重点实验室 哈尔滨, 150080)

(2. 佐治亚理工学院乔治·W·伍德拉夫机械工程学院 亚特兰大, 30332)

摘要 以硬质合金刀具铣削 Ti-6Al-4V 为研究对象, 提出了一种基于经验模态分解 (empirical mode decomposition, 简称 EMD) 及支持向量机 (support vector machine, 简称 SVM) 的刀具磨损阶段识别方法。首先, 将原始加速度信号及力信号分解为一系列模态分量 (intrinsic mode function, 简称 IMF), 选择了有效的 IMF 来组合一个新的信号; 其次, 计算新信号的多评价指标矩阵, 将得到的多指标矩阵 (I-kazTM、功率谱熵及均方根) 作为输入特征向量, 得到了基于线性分类器的刀具磨损识别模型; 最后, 将检测信号输入模型中进行识别, 对刀具磨损阶段的识别精度达到了 99.17%。EMD-SVM 相较于 SVM、BP 神经网络及小波包-SVM 模型, 运算时间减少, 运算精度提高。实验结果表明, 该模式对钛合金铣削过程中的刀具磨损具有良好的识别效果, 为刀具磨损状态的监测提供了一种新方法。

关键词 经验模态分解; 支持向量机; 刀具磨损监测; 切削力信号; 振动信号

中图分类号 TH164; V262.3⁺³

引言

智能制造是包括原材料、加工及测量检测等一系列环节的生产过程, 刀具是其中非常关键的环节^[1]。刀具磨损作为最主要的刀具失效形式, 关乎着制造的精度及产品的表面质量, 如何精确识别刀具磨损已成为一个研究热点。

近些年, 专家们提出了许多刀具磨损识别的方法, 主要分为直接观察法和间接观察法。直接观察法就是测量刀具磨损量来衡量刀具磨损程度, 包括监测磨损宽度、磨损面大小等。常用的方法有接触法、辐射法和光学检测法。它存在 2 个主要缺陷: ①不能对刀具磨损状态进行实时监测; ②停机检测极大降低工作效率。间接观察法就是通过检测刀具铣削时产生的信号, 构建基于信号的刀具磨损模型, 从而监测刀具磨损的方法。此方法不对加工过程造成干扰, 且可以连续监测加工过程, 更适合于在线监测。常用的方法有切削力监测^[2]、声发射监测^[3]、振动监测^[4]、电流与功率监测^[5]、超声波监测^[6]和温度监测^[7]。然而单纯采集铣削时的信号不能准确反应刀具状态, 机器学习及信号处理技术为刀具磨损识别提供了新的思路。Rizal 等^[8]提出了一种结合多传感器信号和马氏田口系统的检测刀具磨损的方法,

并提出马氏距离作为识别刀具磨损的评价指标。Bhuiyan 等^[9]对切削时的声发射及振动信号进行研究, 探究刀具磨损与信号之间的关系。Wu 等^[10]通过多信号融合探究刀具剩余寿命, 揭示信号与刀具磨损之间的关系。Chen 等^[11]通过深度置信网络学习模型融合刀具力信号、振动信号及声发射信号对刀具磨损进行识别。谢峰云等^[12]提出的广义 BP 神经网络识别模型, 提取了振动信号广义均方根、广义功率谱密度均方根及小波包系数均方根为特征值, 将特征值输入 BP 神经网络中识别铝合金铣削时的颤振。甘梓舜等^[13]通过对机床的各种信号进行监测从而监测刀具磨损。陈刚等^[14]通过 BP 神经网络对振动及切削力信号进行学习从而识别刀具磨损。但是由于深度学习及其他学习模型所需数据量大、运算速度慢, BP 神经网络准确性相对不稳定, 而 SVM 由于其算法简单以及具有优秀的“学习”能力^[15], 所以笔者采用 SVM 对数据进行学习, 从而达到刀具磨损识别的效果。

利用信号对刀具磨损状态识别会面临一个问题, 即采取的信号往往掺杂着噪声, 所以对信号进行处理至关重要。Plaza 等^[16]通过对比不同的信号处理方法, 选择小波包与神经网络结合的方式对信号进行处理监测表面质量, 但是由于小波包基有选择

* 国家重点研发计划资助项目 (2018YFB2002201); 国家自然科学基金资助项目 (51720105009)

收稿日期: 2020-07-02; 修回日期: 2020-10-12

困难的局限,选用小波包基会花费较长的时间且监测的信号会出现非线性、非平稳的现象。为了解决这个问题,Huang等^[17]提出了经验模态分解,该方法对于分析信号非线性与非平稳具有明显的优越性,同时克服了小波包基选择困难的特点。在处理信号时选择EMD将会简化数据的计算且不会失去数据原有的特性,因此将EMD引用到信号监测中对信号进行处理。

由于采取的信号数据量大,直接输入信号进行学习及判断会增加模型运算时间,所以应当提取信号特征值来对数据进行简化。刀具磨损时,加工过程中的时、频域和能量分布将发生变化。为了有效地监测信号的变化,选取的特征值应当囊括以上特征。标准差可以反映信号能量的变化,它的值随信号幅度的增大而增大。功率谱熵^[18]是一个无量纲指标,其可以反映不同频率在频带内的分布。当频率分量广泛分布在频带上时,分布的不确定度最大,其所对应的功率谱熵最大;相反,当频率分量分布在一定频带上时,频率分布的不确定性最小,其所对应的功率谱熵最小。I-kazTM是一种多分辨率分析方法,能准确得出信号的变化^[19]。因此,将标准差、功率谱熵和I-kazTM作为信号的特征值。

基于以上分析,笔者针对钛合金切削过程中的刀具磨损识别问题,提出了一种基于EMD及SVM刀具磨损阶段识别方法。首先,将原始加速度信号及力信号分解为一系列IMF,选择有用的IMF来组合一个新的信号;其次,计算新信号的特征值,将得到的特征值矩阵作为SVM的输入;最后,得到了刀具磨损识别模型,能对刀具磨损阶段进行准确识别。

1 信号处理及特征值的选取

1.1 EMD分解思想

EMD方法假设任何信号都由不同IMF组成,每个IMF可以是线性的,也可以是非线性的。IMF分量必须满足2个条件:①其极值点个数和过零点数相同或最多相差1个;②其上下包络关于时间轴局部对称。

EMD分解过程基于以下假设:

- 1) 信号最少有2个极值,即1个极大值和1个极小值;
- 2) 时域特性由极值间隔决定;
- 3) 如果数据序列完全缺乏极值但仅包含拐点,那么它也可以通过1次或多次求导来表示极值点,

而最终结果可以由这些成分求积分来获得。

具体方法是由一个“筛选”过程完成。

首先,找出信号 $s(t)$ 所有的极大值点并将其用3次样条函数拟合成原数据序列上的包络线,再找出所有的极小值点并将其用3次样条函数拟合成原数据^[20]。

其次,计算上下包络线的均值,记为 $m_1(t)$,并将原数据序列 $s(t)$ 减去该均值即可得到1个去掉低频的新数据序列 h_1

$$s(t) - m_1(t) = h_1(t) \quad (1)$$

因为 $h_1(t)$ 一般不是1个IMF分量序列,为此需要对它重复进行上述处理过程 k 次,直到 $h_1(t)$ 符合IMF的定义要求:所得到的均值趋于零。这样就得到了第1个IMF分量 $c_1(t)$,它代表信号 $s(t)$ 中最高频率的分量

$$h_{1(k-1)}(t) - m_{1k}(t) = h_{1k}(t) \quad (2)$$

$$c_1(t) = h_{1k}(t) \quad (3)$$

然后,将 $c_1(t)$ 从 $s(t)$ 中分离出来,即得到1个去掉高频分量的差值信号 $r_1(t)$ 。将 $r_1(t)$ 作为原始数据,重复以上步骤,得到第2个IMF分量 $c_2(t)$,重复 n 次,得到 n 个IMF分量^[21]

$$\begin{cases} r_1(t) - c_2(t) = r_2(t) \\ r_2(t) - c_3(t) = r_3(t) \\ \vdots \\ r_{n-1}(t) - c_n(t) = r_n(t) \end{cases} \quad (4)$$

最后,当 $c_n(t)$ 或 $r_n(t)$ 满足给定的终止条件(通常 $r_n(t)$ 成为一个单调函数)时,循环结束。由式(3)和式(4)得到

$$s(t) = \sum_{j=1}^n c_j(t) + r_m(t) \quad (5)$$

1.2 信号特征值的选取

1.2.1 I-kazTM

I-kazTM是由I-kaz指数演化出来的,其主要思想是将动态信号分解为3个频率范围,其中:低频(LF)范围为 $0 \sim 0.25 f_{\max}$;高频(HF)范围为 $0.25 f_{\max} \sim 0.5 f_{\max}$;极高频(VF)范围为大于 $0.5 f_{\max}$ 。为了测量数据分布的散射,计算了每个频带的方差 σ^2

$$\sigma_L^2 = \frac{\sum_{i=1}^N (x_i^L - \mu_L)^2}{N} \quad (6)$$

$$\sigma_H^2 = \frac{\sum_{i=1}^N (x_i^H - \mu_H)^2}{N} \quad (7)$$

$$\sigma_v^2 = \frac{\sum_{i=1}^N (x_i^v - \mu_v)^2}{N} \quad (8)$$

其中： $\sigma_L^2, \sigma_H^2, \sigma_V^2$ 和 x_i^L, x_i^H, x_i^V 分别为LF, HF和VF范围内时域的方差和数据； μ_L, μ_H, μ_V 分别为每个频率的平均值； N 为数据点的数目。

由于I-kazTM方法是基于数据质心的数据发散概念发展起来的，所以I-kazTM的系数可以用 Z^∞ 来表示

$$Z^\infty = \sqrt{(\sigma_L^2)^2 + (\sigma_H^2)^2 + (\sigma_V^2)^2} \quad (9)$$

将式(6)~(8)代入式(9)，得到

$$Z^\infty = \sqrt{\frac{\sum_{i=1}^N (x_i^L - \mu_L)^2}{N^2} + \frac{\sum_{i=1}^N (x_i^H - \mu_H)^2}{N^2} + \frac{\sum_{i=1}^N (x_i^V - \mu_V)^2}{N^2}} \quad (10)$$

式(10)可以用峰度和标准差表示出来，峰度 K 的公式为

$$K = \frac{1}{Ns^4} \sum_{i=1}^N (x_i - \mu)^4 \quad (11)$$

其中： N 为数据的数量； s 为标准偏差。

因此，根据峰度 K 和标准偏差 s 可得

$$Z^\infty = \frac{1}{N} \sqrt{K_L s_L^4 + K_H s_H^4 + K_V s_V^4} \quad (12)$$

其中： K_L, K_H 和 K_V 分别为LF, HF和VF范围中的信号的峰度； s_L, s_H, s_V 分别为LF, HF和VF范围内的信号的标准差。

根据I-kazTM来提取适应EMD分解的方法，其不同于I-kazTM，即信号不需要分解为三差分。EMD处理完信号后，选择有效的模态分量，分别计算其峰度及标准偏差，最终计算I-kazTM系数。因此，I-kazTM系数可以写成如下形式

$$Z_n^\infty = \frac{1}{N} \sqrt{K_1 s_1^4 + K_2 s_2^4 + \dots + K_i s_i^4 + \dots + K_n s_n^4} \quad (13)$$

其中： N 为有效分解模态的数目； K_i 为分解后模态的峰度； s_i 为第 i 个分解信号的标准偏差。

1.2.2 功率谱熵

功率谱熵(power spectral entropy, 简称PSE)是“信息熵”在频域中的扩展，其与频率分量的分布有关。具体计算步骤如下。

1) 根据式(14)获得信号 $x(t)$ 的功率谱

$$s(f) = \frac{1}{2\pi N} |X(\omega)|^2 \quad (14)$$

其中： N 为数据长度； $X(\omega)$ 为 $X(t)$ 的傅里叶变换。

2) 功率谱的概率密度函数可以通过对所有频

率分量的归一化来计算

$$p_i = \frac{s(f_i)}{\sum_{k=1}^N s(f_k)} \quad (i=1, 2, \dots, N) \quad (15)$$

其中： $s(f_i)$ 为频率分量 f_i 的光谱能量； p_i 为相应的概率密度； N 为快速傅里叶变换中频率分量的总数。

3) 相应的功率谱熵定义为

$$H = - \sum_{i=1}^N p_i \log(p_i) \quad (16)$$

为了比较不同的工作条件，结果由因子 $\log N$ 标准化，得

$$E = \frac{H}{\log N} = \frac{- \sum_{i=1}^N p_i \log(p_i)}{\log N} \quad (17)$$

功率谱熵 E 是在 $[0, 1]$ 的范围内的无量纲指示符，其中1表示频率分量分布不确定度最大，0表示分布不确定度最小。

1.2.3 标准差

标准差(standard deviation, 简称SD)能很客观准确地反映一组数据的离散程度，其计算公式为

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (18)$$

2 基于EMD-SVM刀具磨损识别模式

SVM是一种二分类模型，其基本模型是定义在特征空间上的间隔最大的线性分类器^[22]。SVM学习的基本想法是求解能够正确划分训练数据集并且几何间隔最大的分离超平面，其将空间的点进行划分并根据划分的直线对点进行识别，如图1所示。对于线性可分的数据来说，这样的超平面有无穷多个(即感知机)，但是几何间隔最大的分离超平面却是唯一的。由于信号特征值相对于信号整体来说，数据量小，易于学习，所以采用SVM对信号进行学习。

在选择核函数时，若对给出的数据没有先验知识，径向基函数(radial basis function, 简称RBF)就是最好的选择，而且RBF核的支持向量机可以获得非常平滑的估计^[23]，所以笔者采用高斯核函数作为SVM的核函数。

为了消除噪声和其他无关的信号，首先，利用EMD将加速度信号分解为多个IMF，将分解完的信号重构为新信号；其次，将新信号划分成一系列段，




图1 支持向量机

Fig.1 Support vector machine

分别计算每个分段的 I-kazTM、功率谱熵及均方根,得到铣削状态的特征向量矩阵;最后,以特征向量矩阵为输入特征,建立以 SVM 为基础的刀具磨损识别模型。根据该模型可以判断刀具磨损阶段。刀具磨损阶段识别的流程如图 2 所示。

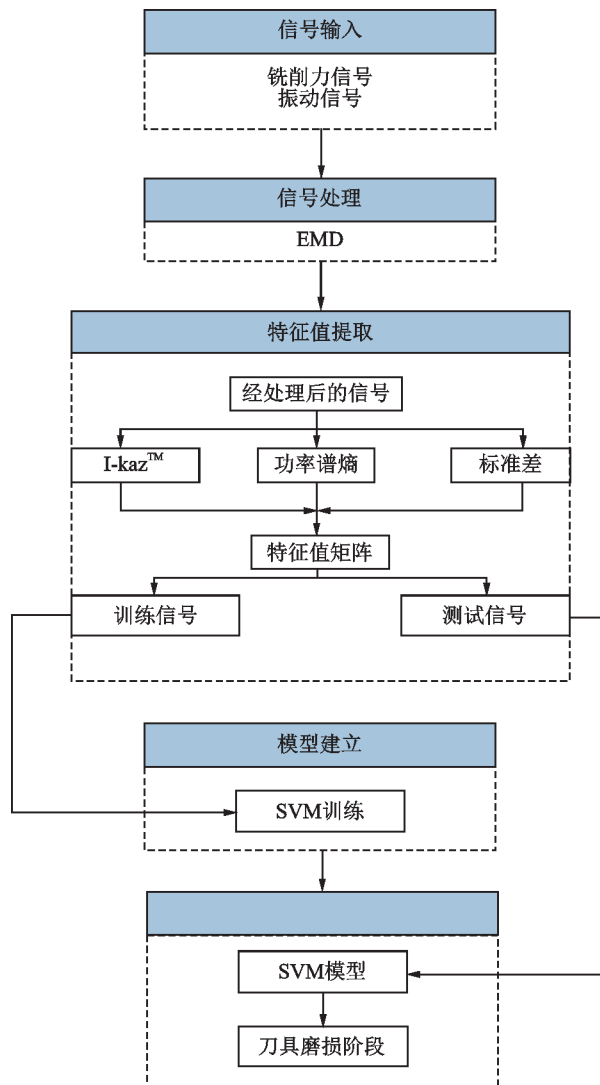


图2 基于EMD-SVM的刀具磨损阶段识别流程

Fig.2 Process of tool wear stage based on EMD-SVM

3 钛合金铣削实验及信号分析

3.1 实验设备

实验在三轴机床 VDL-1000E 进行,实验工件材料为 Ti-6Al-4V (TC4),实验刀具为无涂层硬质合金四齿铣刀,刀具螺旋角、前角、后角分别为 75°, 8° 和 9°。采用 PCB 加速度传感器及 Kister9171A 旋转式测力仪对加速度信号及铣削力信号进行采集。采用东华 DHDAS 动态信号采集分析系统对加速度信号及力信号进行处理,采样频率为 1 kHz。图 3 所示为铣削加工实验现场,旋转测力仪安装在刀柄处对加工实验的 3 向力信号进行测量,将加速度传感器连接在工件上对加速度信号进行测量,选取有效的信号点作为 2 种信号的共同起始点。




图3 铣削加工实验现场

Fig.3 The milling experiment site

3.2 实验方案及数据分析

3.2.1 实验方案

为了验证该方法,实验准备获取在不同刀具磨损情况下的力及加速度信号,实验参数如表 1 所示。

表 1 实验参数

Tab.1 Experimental parameters

| 序号 | 转速/ (r·min ⁻¹) | 切深/ mm | 切宽/ mm | 进给速度/ (mm·min ⁻¹) |
|----|-------------------------------|-----------|-----------|----------------------------------|
| 1 | 2 000 | 6 | 0.3 | 400 |

如果要对刀具磨损阶段进行划分,就要先确定刀具磨损曲线。在本研究实验参数下进行实验,取 3 次走刀的平均磨损值作为 1 次磨损取值,建立如图 4 所示的刀具磨损曲线。表 2 为刀具磨损状态分类表,根据磨损率变化情况将刀具磨损过程分为 3 个

阶段,即初期磨损阶段[0 mm, 0.12 mm)、正常磨损阶段 [0.12 mm, 0.17 mm) 和 急剧磨损阶段 [0.17 mm, 0.30 mm)。预先将 3 个磨损阶段标记为 1, 2, 3 以输入 SVM 中。




图4 刀具磨损过程

Fig.4 Tool wear process

表 2 刀具磨损状态分类表

Tab.2 Classification of tool wear status

| 磨损值/mm | 磨损状态 | 标记 |
|--------------|------|----|
| [0, 0.12) | 初期磨损 | 1 |
| [0.12, 0.17) | 正常磨损 | 2 |
| [0.17, 0.30) | 急剧磨损 | 3 |

3.2.2 特征值提取及数据分析

在实验中很难根据原始的加速度及力信号来判断铣削状态。特征提取的目的是为了减少原始加工信号的尺寸,同时保持所提取的特征中具有刀具状态的相关信息。本节主要以加速度信号为例进行数据分析。

选取 1 组铣削时检测的初期振动信号,经过频域变换处理后的加速度信号及频域分布见图 5。





图5 加速度信号及其频域

Fig.5 Acceleration signal and its frequency domain


图 5 所示的加速度信号经 EMD 分解得到的时域和频域如图 6 所示。图 6(a)中,从左到右依次为 $IMF_1, IMF_2, \dots, IMF_6$ 。从图 6(b)可以看出,第 4~6 个模态固有函数的频域极其相近且主频过小,此时的模态固有函数为虚假分量,没有实际意义,可以忽略不计,所以计算时值采取 $IMF_1 \sim IMF_3$ 。图中为无

纲量单位。



(a) 分解信号时域图

(a) Decomposition signal time domain diagram



(b) 分解信号频域图

(b) Decomposition signal frequency domain diagram

图 6 EMD 分解时域及频域

Fig.6 EMD decomposition time domain and frequency domain diagram

图 7 为 3 个刀具磨损阶段的力信号,刀具磨损量分别为 0.05, 0.15 及 0.25 mm。由图可知,当后刀面磨损处于正常磨损时切向力及径向力分别为 270 和 160 N,而当后刀面磨损处于急剧磨损阶段时,2 种力信号的幅值急剧增加,比例分别为 41% 及 27%,这是因为刀具后刀面磨损后,作用在后面的法向力及摩擦力都增大,故切向力及径向力增加,而轴向力却未有较大的变化。

图 8 为刀具在初期磨损、中期磨损及急剧磨损的特征值随时间的变化图,其中特征值为无量纲单位。由图可以看出,在不同的刀具磨损情况下,刀具磨损的特征值趋于一个稳定值,且 3 个阶段的特征值不同,由此可以得出选取的特征值对信号变化敏感,可以用于模型的学习。

通过对初期、中期及急剧磨损阶段的加速度信号进行对比发现:急剧磨损阶段的加速度信号相较于初期及中期磨损阶段来说,均方根及功率谱熵指数增大而 I-kazTM 减小,即刀具磨损时信号能量增加,信号的分散性变高。

为了验证上述结论的有效性,重建加速度信号的形态特征、时域能量和频率分量,对信号进行了深入分析。图 9 为在不同刀具磨损情况下加速度信号的形态特征及频域分布图,其中频域分布图中的频

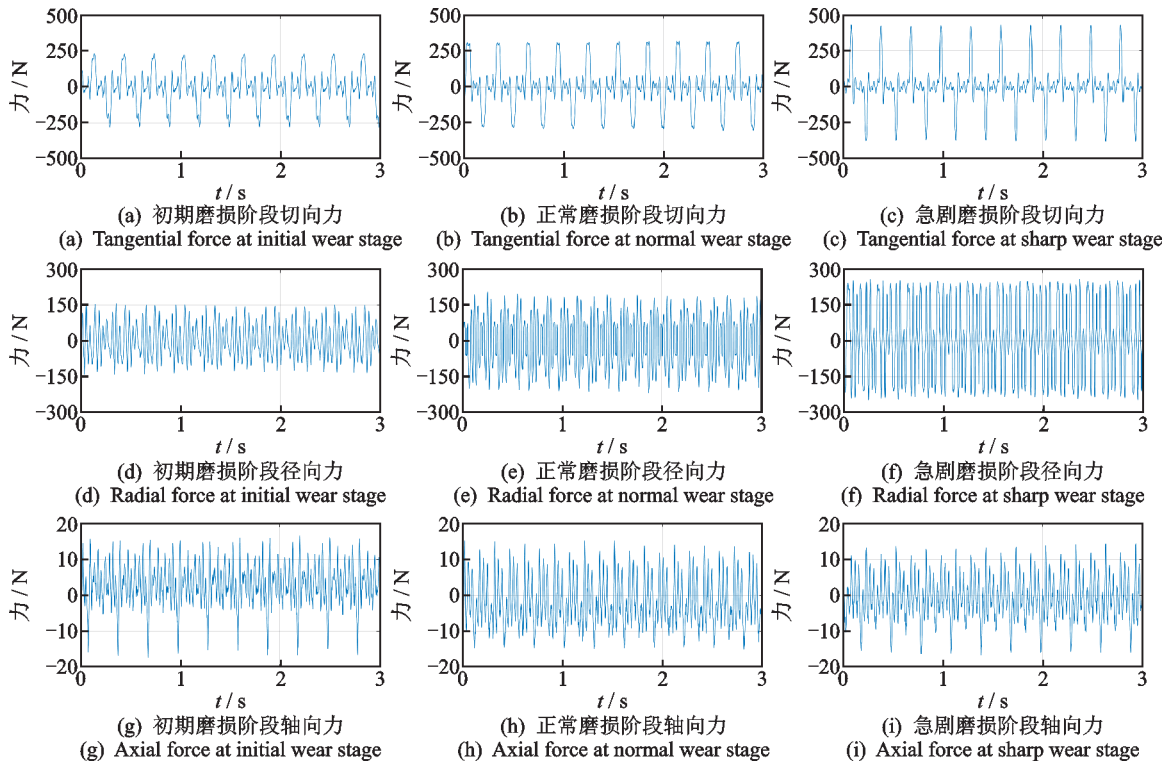


图 7 不同阶段力变化图

Fig.7 Force variations at different stages

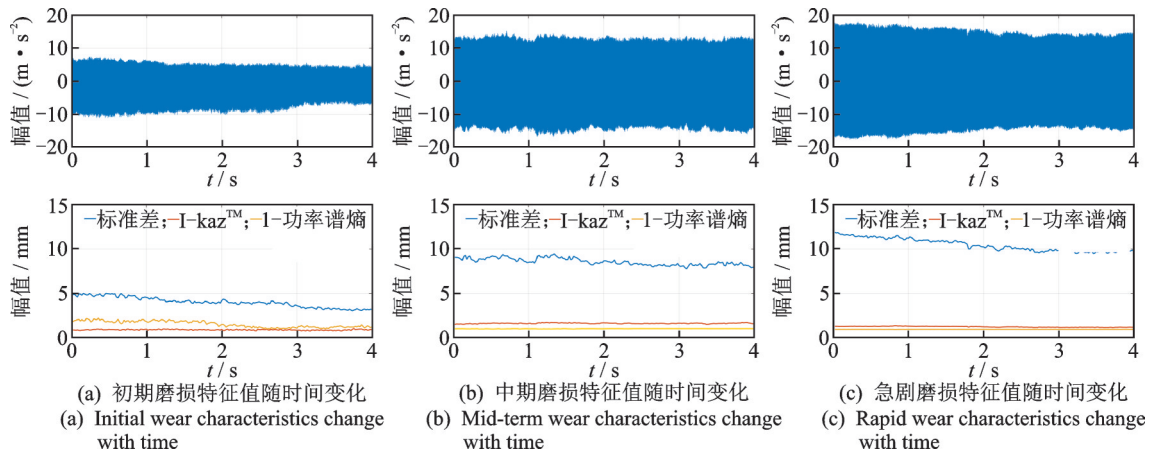


图 8 不同阶段加速度信号及其特征值变化图

Fig.8 Acceleration signal and its eigenvalue change in different stages

率分量是由刀齿通过频率(270 Hz)和谐波组成。对比不同刀具磨损情况下的频域分布发现:随着刀具磨损的增加,信号的频域由低频向高频部分转移,高次谐波增加,这是因为切削力随刀具磨损的增加而增加进而引起信号的变化;信号呈现周期性波动,这是刀具切入切出的接触特性发生了变化引起的。

监测的特征值信号以加速度信号特征值为主,建立加速度信号与力信号特征值特征矩 $[I-L, E-L, s-L, I-Z, E-Z, s-Z]$ 作为线性分类器的输入,其中: I, E, s 分别为 I-kazTM、功率谱熵和标准差; L, Z 分别为

力信号和加速度信号。图 10 所示为加速度信号构成的特征值空间,由于 PSE 为接近 0 的数,为了可以直观地看出特征值在空间的分布,采用 $1-PSE$ 作为 z 轴,图中为无量纲单位。由图可见,不同刀具磨损情况下的特征值相互独立且相同刀具磨损阶段下的特征值集中在一起。

将每个刀具磨损阶段的 160 组数据作为训练集,将其余 40 组数据作为测试集。最后,得到 1 个大小为 160 的训练集和 1 个大小为 40 的测试集的数据集对 EMD-SVM 模式进行训练及测试。

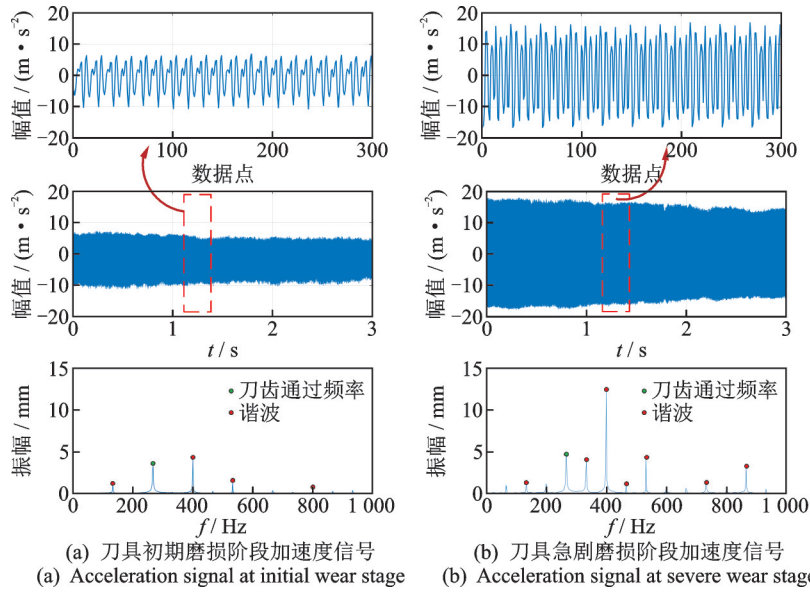


图 9 不同刀具磨损情况下的加速度信号及其频域

Fig.9 Acceleration signal and frequency domain under different tool wear conditions




图 10 特征值空间

Fig.10 The feature space

为进一步验证建立模型的准确度及运算速度,使用同 1 组数据作为输入,建立 SVM, BP 神经网络、EMD-SVM 及小波包-SVM 这 4 种模型进行对比。

对于 SVM 模型及 BP 神经网络模型,将实验所获取的信号直接输入学习模型中进行训练,然后将测试信号输入到学习好的模型中进行判断。对于小波包-SVM,先将信号进行小波处理后输入 SVM 构建刀具磨损模型,然后将检测信号输入模型中进行判别。通过对 4 种模型进行训练后得到了 4 种模型的混淆矩阵,其准确率对比如图 11 所示。其中:混淆矩阵纵坐标为预期判断的刀具磨损阶段;横坐标为实际判断出的刀具磨损阶段;两者相交的黑色对角线为预测正确的测试数据。表 3 为 4 种模型输入训练信号进行训练及输入检测信号进行识别的运算时间及精度。

由于 BP 网络预测精度不稳定,SVM 的泛化能力不稳定,容易出现过拟合,小波包分解由于挑选小

表 3 不同模型运算时间表

Tab.3 Operating time of different models

| 模式 | 运算时间/s | 识别精度/% |
|---------|-----------|--------|
| SVM | 3.176 826 | 89.08 |
| BP 神经网络 | 3.733 512 | 84.17 |
| EMD-SVM | 1.082 446 | 99.17 |
| 小波包-SVM | 2.258 022 | 95.00 |

波包基困难和其对非平稳及非线性数据上的劣势,训练时间较长;而 EMD-SVM 由于对信号进行预处理,提取的特征值能更好地表达样本特征,不容易出现过拟合现象且计算效率相对于其他模型高,所以模型准确度较高,泛化能力强,学习所用时间较其他机器学习模型短。对比后发现 EMD-SVM 的精度最高,运算速度最快。相对于 BP 神经网络,同 1 组数据的运算时间节省 60%,精度提高了 15.12%,对刀具磨损状态有很高的灵敏性,能监测刀具磨损的发生。

精度:99.17%

| | | | |
|------|--------------|-------------|--------------|
| 初期磨损 | 100.0% 39 | 2.4% 1 | 0.0% 0 |
| 正常磨损 | 0.0% 0 | 97.6% 40 | 0.0% 0 |
| 严重磨损 | 0.0% 0 | 0.0% 0 | 100.0% 40 |

初期磨损 正常磨损 严重磨损

(a) EMD-SVM 混淆矩阵

(a) The confusion matrix of EMD-SVM

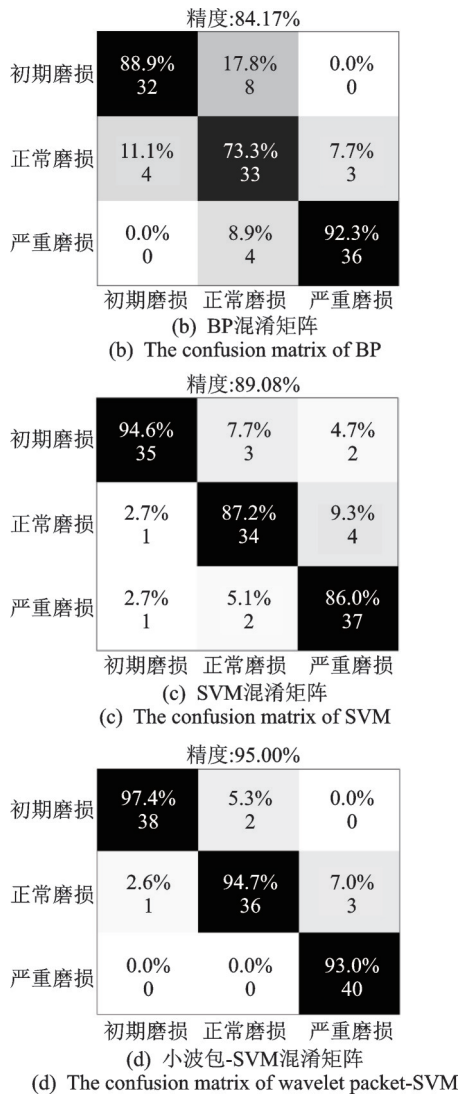


图 11 4 种模型准确率对比图
Fig.11 The confusion matrix of three models

4 结 论

1) 刀具发生磨损时,加工信号的时频域发生变化,频域会由低频转向高频,同时信号的时域部分能量会增大。刀具后刀面磨损后,切向力及径向力增加,而轴向力却未有较大的变化。

2) 设计了 EMD-SVM 的刀具识别模式,采用 EMD 方法对信号进行重构,对重构后的信号进行特征提取并组成特征值矩阵,将不同刀具磨损阶段特征值矩阵输入 SVM 中,能对刀具磨损进行识别。

3) 选用 160 组每个刀具磨损阶段的特征值矩阵对本研究提出的刀具磨损识别模式进行训练,选用 40 组特征值矩阵进行验证,对刀具磨损阶段的识别成功率达到了 99.17%。实验结果表明,该模式具有良好的识别效果,可以准确实现刀具磨损阶段的

识别。

4) 通过对比 BP 神经网络模型,本研究提出的 EMD-SVM 模式运算时间提高 60% 以上,识别精度提高 15.12%,对钛合金铣削过程中刀具磨损阶段具有较高的敏感度,能准确识别刀具磨损的发生。

参 考 文 献

[1] 孙庆丰. 伊斯卡,用智造改变制造[J]. 金属加工(冷加工), 2016(3):5-6.
SUN Qingfeng. ISCAR, changing manufacturing with intelligence [J]. Metal Working (Metal Cutting), 2016(3):5-6. (in Chinese)

[2] BYRNE G, DORNFELD D, DENKENA B. Advancing cutting technology[J]. CIRP Annals, 2004, 52(2): 483-507.

[3] ROGERS L M. The application of vibration analysis and acoustic emission source location to on-line condition monitoring of anti-friction bearings[J]. Tribology International, 1979, 12(2):51-59.

[4] JI Y, WANG X, LIU Z, et al. Early milling chatter identification by improved empirical mode decomposition and multi-indicator synthetic evaluation[J]. Journal of Sound and Vibration, 2018, 433:138-159.

[5] PRITSCHOW G, BRETSCHNEIDER J, FRITZ S. Reconstruction of process forces within digital servodrives systems, production engineering[J]. Annals of the German Academic Society for Production Engineers, 1999, 6(1):73-78.

[6] COKER S A, SHIN Y C. In-process control of surface roughness due to tool wear using a new ultrasonic system [J]. International Journal of Machine Tools & Manufacture, 1996, 36(3): 411-422.

[7] LAURO C H, BRANDÃO L C, BALDO D. Monitoring and processing signal applied in machining processes-a review[J]. Measurement, 2014, 58:73-86.

[8] RIZAL M, GHANI J A. Cutting tool wear classification and detection using multi-sensor signals and Mahalanobis-Taguchi system[J]. Wear, 2017, 376: 1759-1765.

[9] BHUIYAN M S, CHOUDHURY I A, DAHARI M, et al. Monitoring the tool wear, surface roughness and chip formation occurrences using multiple sensors in turning[J]. Journal of Manufacturing Systems, 2014, 33(4): 476-487.

[10] WU J, SU Y, CHENG Y, et al. Multi-sensor information fusion for remaining useful life prediction of machining tools by adaptive network based fuzzy

- inference system [J]. *Applied Soft Computing*, 2018, 68:13-23.
- [11] CHEN Y, JIN Y, JIRI G, et al. Predicting tool wear with multi-sensor data using deep belief networks [J]. *The International Journal of Advanced Manufacturing Technology*, 2018, 99(5): 1917-1926.
- [12] 谢锋云, 江伟文, 陈红年, 等. 基于广义BP神经网络的切削颤振识别研究[J]. *振动与冲击*, 2018, 37(5): 65-70, 78.
XIE Fengyun, JIANG Weiwen, CHEN Hongnian, et al. Cutting chatter recognition based on generalized BP neural network [J]. *Journal of Vibration and Shock*, 2018, 37(5): 65-70, 78. (in Chinese)
- [13] 甘梓舜, 王鹏宇, 赵文祥, 等. 基于多传感器融合的机床监测系统研制及数据处理[J]. *新技术新工艺*, 2018(7): 26-30.
GAN Zishun, WANG Pengyu, ZHAO Wenxiang, et al. Machine tool monitoring systems and data processing based on multi-sensor fusion [J]. *New Technology & New Process*, 2018(7): 26-30. (in Chinese)
- [14] 陈刚, 焦黎, 颜培, 等. 基于多传感器数据融合的刀具磨损状态监测研究[J]. *新技术新工艺*, 2017(11): 23-28.
CHEN Gang, JIAO Li, YAN Pei, et al. Research on tool wear condition monitoring based on multi-sensor data fusion [J]. *New Technology & New Process*, 2017(11): 23-28. (in Chinese)
- [15] BHAT N N, DUTTA S, VASHISTH T, et al. Tool condition monitoring by SVM classification of machined surface images in turning [J]. *The International Journal of Advanced Manufacturing Technology*, 2016, 83(9): 1487-1502.
- [16] PLAZA E G, LOPEZ P J, GONZALEZ E M, et al. Multi-sensor data fusion for real-time surface quality control in automated machining systems [J]. *Sensors*, 2018, 18(12): 4381.
- [17] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903-995.
- [18] CAO H R, ZHOU K, CHEN X F. Chatter identification in end milling process based on EEMD and nonlinear dimensionless indicators [J]. *International Journal of Machine Tools and Manufacture*, 2015, 89: 52-59.
- [19] RIZAL M, GHANI J A, NUAWI M Z, et al. The application of I-kazTM-based method for tool wear monitoring using cutting force signal [J]. *Procedia Engineering*, 2013, 68: 461-468.
- [20] 何振鹏, 朱志琪, 谢海超, 等. 线性外推法和相似极值法耦合抑制EMD端点效应 [J]. *机械科学与技术*, 2018, 37(8): 1200-1206.
HE Zhenpeng, ZHU Zhiqi, XIE Haichao, et al. The coupling of linear extrapolation method and similar extreme extension method to restrain boundary effect of EMD [J]. *Mechanical Science and Technology for Aerospace Engineering*, 2018, 37(8): 1200-1206. (in Chinese)
- [21] 卢荣军, 高伟. 风机转子轴心轨迹的经验模态分解滤波与提纯 [J]. *风机技术*, 2010(5): 73-76.
LU Rongjun, GAO Wei. Method of experience mode decomposition, filtering and extracting of axis track of fan rotor [J]. *Chinese Journal of Turbomachinery*, 2010(5): 73-76. (in Chinese)
- [22] 路勇, 姚英学. 模糊神经网络在刀具磨损检测中的应用 [J]. *机械制造*, 2003(3): 47-49.
LU Yong, YAO Yingxue. Application of fuzzy neural network in tool wear detection [J]. *Machinery*, 2003(3): 47-49. (in Chinese)
- [23] KIVINEN J, SMOLA A J, WILLIAMSON R C, et al. Online learning with kernels [J]. *IEEE Transactions on Signal Processing*, 2004, 52(8): 2165-2176.



第一作者简介: 谢振龙, 男, 1996年5月生, 硕士生。主要研究方向为铣削稳定域建模及信号监测。

E-mail: 1765693385@qq.com