· 180 ·

JOURNAL OF ELECTRONIC MEASUREMENT AND INSTRUMENTATION

DOI: 10. 13382/j. jemi. B2306199

# 基于自适应调频模态追踪方法的铣削颤振识别\*

张壮壮'王红军<sup>1,2,3</sup> 王 楠'王增新<sup>4</sup> 王星河<sup>5</sup>

(1.北京信息科技大学机电工程学院 北京 100192;2.高端装备制造智能感知与控制北京市国际 科技合作基地 北京 100192;3.北京信息科技大学机电系统测控北京市重点实验室 北京 100192;
4.超同步股份有限公司 北京 101500;5.北京机械工业自动化研究所有限公司 北京 100120)

摘 要:在铣削加工工程中,产生颤振,严重影响产品的加工精度和表面质量。为了有效避免铣削过程中发生颤振,提出了基于 自适应调频模态追踪(adaptive chirp mode pursuit, ACMP)的铣削颤振监测和识别方法。该方法综合考虑了振动信号的带宽和 微弱特性, ACMP 在递归框架中逐个捕获信号模式,在该算法中,不需要输入信号模式的个数,而是可以通过评估残差信号的能 量来学习,这样就可以避免由于分解层数不确定带来的模态混叠或者过度分解的问题。首先使用仿真信号验证了该算法对颤 振信号具有很高的识别精度;然后基于现场的铣削实验数据证明该方法及时有效地对颤振进行识别;最后从 ACMP 处理后的 信号中提取功率谱熵值作为颤振识别特征。该方法解决了经验模态分解(empirical mode decomposition, EMD)算法的模态混合 和伪分量问题,又降低了变分模态分解(variational mode decomposition, VMD)的精度不稳定的影响,可以准确快速地识别到颤 振,对提高加工质量具有重要意义。

关键词: ACMP;颤振;功率谱熵;铣削

中图分类号: TG54; TN9 文献标识码: A 国家标准学科分类代码: 460.25

### Milling chatter identification based on adaptive chirp mode pursuit

Zhang Zhuangzhuang<sup>1</sup> Wang Hongjun<sup>1,2,3</sup> Wang Nan<sup>1</sup> Wang Zengxin<sup>4</sup> Wang Xinghe<sup>5</sup>

School of Mechanical and Electrical Engineering, Beijing Information Science & Technology University, Beijing 100192, China;
 Beijing High-End Equipment Intelligent Perception and Control International Cooperation Base, Beijing 100192, China;
 Beijing Key Laboratory of Measurement and Control of Mechanical and Electrical System, Beijing Information Science & Technology University, Beijing 100192, China; 4. CTB Co., Ltd., Beijing 101500, China; 5. Beijing Machinery Industry Automation Research Institute Co., Ltd., Beijing 100120, China)

**Abstract**: In milling machining engineering, chattering is generated, which seriously affects the machining accuracy and surface quality of products. In order to effectively avoid chattering during milling, a milling chattering monitoring and identification method based on Adaptive chirp mode pursuit (ACMP) is proposed. The method integrates the bandwidth and faint characteristics of vibration signals, and ACMP captures the signal modes one by one in a recursive framework. In this algorithm, we do not need to input the number of signal modes, but can learn them by evaluating the energy of the residual signal, so that we can avoid the problems of modal mixing or over-decomposition due to the uncertainty of the number of decomposition layers. Firstly, the algorithm is verified to have high recognition accuracy for chattering signals using simulated signals; then the method is demonstrated to be effective in recognizing chattering in time based on field milling experimental data; finally, the power spectrum entropy value is extracted from the ACMP processed signals as chattering recognition features. This method solves the modal mixing and pseudo-component problems of empirical mode decomposition (EMD) algorithm, and reduces the influence of unstable accuracy of variational mode decomposition (VMD), which can accurately and quickly identify the chattering and is of great significance to improve the machining quality. **Keywords**; ACMP; chatter; power spectrum entropy; milling

收稿日期: 2023-01-13 Received Date: 2023-01-13

<sup>\*</sup>基金项目:北京市科技计划项目(Z201100008320004)资助

### 0 引 言

随着我国逐步由工业大国到工业强国的逐步转变, 人们对产品的加工精度和加工效率要求逐步提高,高速 铣削逐步在各个行业中得到广泛的应用。但高速铣削加 工中的颤振问题是难以解决的,颤振问题源于自激振动。 当发生颤振时,刀具-工件系统的某一模态受到切削力的 激励,颤振频率接近机械结构的固有频率<sup>[1]</sup>。颤振会降 低表面质量和生产效率,还会导致刀具磨损<sup>[2]</sup>。切削振 动通常是非平稳和非线性的[3]。因此,振动信号在时域 和频域的统计特性随着振动的变化而变化,这种变化往 往受到背景噪声的干扰。为了更好地分析颤振状态的特 征,周航等<sup>[4]</sup>提出了基于二次互补集合经验模态分解 (CEEMD)与时域特征分析的去噪方法,为了克服原始模 态分解需要预先设定参数的缺陷,鄢小安等<sup>[5]</sup>提出了一 种参数自适应的特征模态分解方法。李尧等[6]基于小波 变换和 Hilbert-Huang 变换从能量频域分布与幅值概率统 计分布两方面提取信号特征值对数控铣削颤振进行诊 断。李香服等<sup>[7]</sup>利用神经网络和 PLD,通过控制工件夹 具的方式来抑制颤振的产生。Liu 等<sup>[8]</sup>提出了基于多传 感器颤振监测系统的小波分析方法,并将小波分解得到 的统计参数应用于基于神经网络的人工智能分类系统来 检测颤振。李宏坤等[9]利用小波包分解采集的声压数 据,并把频域占能比作为特征来监测颤振。近年来,由 Chen 等<sup>[10]</sup>提出的变分非线性调频模式分解(VNCMD) 算法引起了各个领域的广泛关注。这是因为 VNCMD 可 以从时域中分解出具有多种相似模态的宽带非线性信 号,即使在噪声环境下也具有良好的收敛性能。在 VNCMD 的基础上,提出了一种改进的 VNCMD<sup>[11]</sup>,利用 互相关系数法确定适当的模式分解数,该方法已成功地 应用于车削过程中的加速度信号分析。虽然前人对现有 的信号处理方法进行了一定的改进,但是并不能从根本 上解决信号处理方法本身的问题,比如 EMD 的模态混 叠、端点效应,小波分析中母小波选取的困难,VMD分析 中参数选择困难等问题。

针对切削颤振特征较弱、难以提取的情况,研究了一些新的特征提取方法。例如,李忠群等<sup>[12]</sup>提取了时域信号的 Rényi 熵作为颤振的特征来识别颤振。Pan 等<sup>[13]</sup>将分形维度作为特征来识别颤振。Lu 等<sup>[14]</sup>利用方差和显性频率作为颤振指标,虽然可以作为颤振识别的特征有很多,但是与其他指标相比,功率谱熵和能量熵与频率和能量分布直接相关,因此对颤振相对敏感<sup>[15-16]</sup>。由于适应调频模态追踪(ACMP)算法不需要预先输入模态个数并且可以从根本上解决由于分解层数不确定带来的模态 混叠或者过度分解的问题。所以本文利用 ACMP 算法和 功率谱熵对铣削颤振的检测与识别进行了研究。

### 1 自适应调频模态追踪的铣削颤振识别

基于 ACMP 和功率谱熵的颤振识别方法如图 1 所示。首先对信号进行 ACMP 降噪和分解,确定合理的分解层数;将获得的各层分解信号分量进行重构生成新的信号;对重构信号进行分析计算其功率谱熵。与根据机床的动态特性计算的颤振阈值进行比较,识别并预测是否产生颤振。通过仿真信号对方法进行分析验证其可行性和有效性,获得合适的阈值。采集来自机床工作台的振动信号,采用该方法进行识别,验证了该方法的有效性。



图 1 基于 ACMP 和功率谱熵的颤振检测识别方法流程 Fig. 1 Process of chatter detection and identification method based on ACMP and power spectrum entropy

### 1.1 ACMP 的算法原理

Cao 等<sup>[17]</sup> 认为任何信号都是由几个本征模函数 (IMFs)组成的。一个信号在任何时候都可以包含几个 本征模函数。基于 ACMP 算法,采用递归框架逐个提取 信号模式,将非线性信号自适应分解为一系列具有调幅 (AM)和调频(FM)特性的 IMFs。信号的本征模函数可 以表示为:

$$x(t) = \sum_{m=1}^{M} x_m(t) = \sum_{m=1}^{M} a_m(t) \cos\left(2\pi \int_0^t f_m(s) \, \mathrm{d}s + \varphi_m\right)$$
(1)

式中: x(t) 是 M 个调频模态  $x_m(t)$  的叠加,  $a_m(t)$  是 m 阶 模态的非负包络,  $f_m(t) > 0$  是瞬时频率,  $\varphi_m$  表示初始 相位。 将式(1)重写去调频的形式为:

$$\alpha_m(t) = a_m(t) \cos\left(2\pi \int_0^t (f_m(s) - \tilde{f}_m(s)) \, \mathrm{d}s + \varphi_m\right)$$
(3)

$$\boldsymbol{\beta}_{m}(t) = -a_{m}(t)\sin\left(2\pi\int_{0}^{t}(f_{m}(s) - \widetilde{f}_{m}(s)) \,\mathrm{d}s + \boldsymbol{\varphi}_{m}\right)$$
(4)

式中: $\alpha_m(t)$ 和 $\beta_m(t)$ 是两个去调频信号,  $\tilde{f}_m(t)$ 是去调频因子  $\cos\left(2\pi\int_0^t \tilde{f}_m(s) ds\right)$ 和  $\sin\left(2\pi\int_0^t \tilde{f}_m(s) ds\right)$ 的频率函数。当 $f_m(t) = \tilde{f}_m(t)$ 时,  $\alpha_m(t)$ 和 $\beta_m(t)$ 将会变成 慢变基带信号。

由于同时估计所有信号模式是困难的,并且可能受 到稳定性问题的影响。在类似匹配追踪的方法<sup>[18]</sup>的激 励下,ACMP采用递归框架逐个提取信号模式。具体地 说,为了提取第*M*个信号模式,ACMP 解决了以下问题:

 $\min_{\substack{\alpha_{m},\beta_{m},\ \widetilde{f}_{m} \\ x_{m}(t) \|_{2}^{2} \}}} \| \alpha_{m}''(t) \|_{2}^{2} + \| \beta_{m}''(t) \|_{2}^{2} + \tau \| x(t) - x_{m}(t) \|_{2}^{2} \}$   $x_{m}(t) \|_{2}^{2} \}$  (5)

 $x_m(t) = \alpha_m(t) \cos(2\pi \int_0^t \tilde{f}_m(s) \, \mathrm{d}s + \beta_m(t)$ 

$$\sin\left(2\pi\int_{0}^{s}\tilde{f}_{m}(s)\,\mathrm{d}s\right) \tag{6}$$

其中,前两项对两个去调频信号  $\alpha_m(t)$  和  $\beta_m(t)$  施 加平滑性约束,第 3 项表示残差信号的能量, $\tau > 0$  为加 权因子。本质上,式(5)表示了一种类似于匹配追踪的 贪婪算法,它通过最小化剩余能量来找到期望的模式。

假设信号是在离散时间  $t = t_0, \dots, t_{N-1}$  中观察到的, 其中 N 是样本数。然后,将式(6)代入式(5)得到以下矩 阵形式的目标函数为:

$$\boldsymbol{J}_{\boldsymbol{\tau}}(\boldsymbol{y}_{m},\boldsymbol{f}_{m}) = \|\boldsymbol{\varPhi}\boldsymbol{y}_{m}\|_{2}^{2} + \boldsymbol{\tau} \|\boldsymbol{x} - \boldsymbol{K}_{m}\boldsymbol{y}_{m}\|_{2}^{2}$$
(7)  

$$\boldsymbol{\ddagger} \quad \boldsymbol{\varPhi}, \quad \boldsymbol{x} = [\boldsymbol{x}(t_{0})\cdots\boldsymbol{x}(t_{N-1})]^{\mathrm{T}},\boldsymbol{f}_{m} =$$

$$| \widetilde{f}_{m}(t_{0})\cdots\widetilde{f}_{m}(t_{N-1}) |^{\mathrm{T}}; \mathbf{y}_{m} = [\boldsymbol{\alpha}_{m}^{\mathrm{T}} \boldsymbol{\beta}_{m}^{\mathrm{T}}]^{\mathrm{T}} \not\equiv \boldsymbol{\mu} \cdot \boldsymbol{\alpha}_{m} = [\boldsymbol{\alpha}_{m}(t_{0})\cdots\boldsymbol{\alpha}_{m}(t_{N-1})]^{\mathrm{T}}, \boldsymbol{\beta}_{m} = [\boldsymbol{\beta}_{m}(t_{0})\cdots\boldsymbol{\beta}_{m}(t_{N-1})]^{\mathrm{T}}, \mathbf{\beta}_{m} = [\boldsymbol{\beta}_{m}(t_{N-1})]^{\mathrm{T}}, \mathbf{\beta}_{m} = [\boldsymbol{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})]^{\mathrm{T}}, \mathbf{\beta}_{m} = [\boldsymbol{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1})^{\mathrm{T}}, \mathbf{\beta}_{m}(t_{N-1$$

$$\boldsymbol{C}_{m} = diag\left[\cos\left(\theta_{m}(t_{0})\right) \cdots \cos\left(\theta_{m}(t_{t-1})\right)\right]$$
(9)

$$\boldsymbol{S}_{m} = diag[\sin(\theta_{m}(t_{0})) \cdots \sin(\theta_{m}(t_{t-1}))] \qquad (10)$$

其中: $\theta_m = 2\pi \int_0^t \tilde{f}_m(s) ds$ ; $\boldsymbol{\Phi} = \begin{bmatrix} \boldsymbol{D} & \boldsymbol{\theta} \\ \boldsymbol{\theta} & \boldsymbol{D} \end{bmatrix}$ , $\boldsymbol{\theta}$ 表示零矩阵, $\boldsymbol{D}$ 表示一个尺寸为(N - 2) × N的二阶差分矩阵,表示为:

$$\boldsymbol{D} = \begin{bmatrix} 1 & -2 & 1 & 0 & 0 & \cdots & 0 \\ 0 & 1 & -2 & 1 & 0 & \cdots & 0 \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 0 & \cdots & 0 & 1 & -2 & 1 & 0 \\ 0 & \cdots & 0 & 0 & 1 & -2 & 1 \end{bmatrix}$$
(11)

为了使目标函数(7)最小化,开发了交替更新去调频信号和瞬态频率的迭代算法,首先通过将梯度设置为 0来更新向量 y<sub>m</sub>:

$$\mathbf{y}_{m}^{n} = \begin{bmatrix} \boldsymbol{\alpha}_{m}^{n} \\ \boldsymbol{\beta}_{m}^{n} \end{bmatrix} = \left(\frac{1}{\tau}\boldsymbol{\Phi}^{\mathrm{T}}\boldsymbol{\Phi} + (\boldsymbol{K}_{m}^{n})^{\mathrm{T}}\boldsymbol{K}_{m}^{n}\right)^{-1} (\boldsymbol{K}_{m}^{n})^{\mathrm{T}}x \quad (12)$$

其中,上标 n 代表迭代计数器。然后,目标信号模态 可恢复为:

$$\boldsymbol{x}_{m}^{n} = \boldsymbol{K}_{m}^{n} \boldsymbol{y}_{m}^{n} \tag{13}$$

瞬时频率增量可以通过反正切解调获得:

$$\Delta \tilde{f}_{m}^{n}(t) = -\frac{1}{2\pi} \frac{\mathrm{d}}{\mathrm{d}t} \left( \arctan\left(\frac{\beta_{m}^{n}(t)}{\alpha_{m}^{n}(t)}\right) \right)$$
(14)

#### 1.2 功率谱熵算法原理

功率谱熵的概念是 Shannon 熵在频域的推广,它与频率分量的分布有关<sup>[19]</sup>。给定信号的功率谱熵由以下步骤:

1) 功率谱信号可以由式(15) 获取:

$$s(f) = \frac{1}{2\pi N} |X(w)|^2$$
(15)

式中:*N* 是信号 *x*(*t*)的长度,*X*(*w*)是用快速傅里叶变换 (FFT)对 *x*(*t*)进行的傅里叶变换。

2)可以通过归一化所有频率分量来估计频谱的概率 密度函数:

$$p_i = s(f_i) / \sum_{k=1}^{N} s(f_k), i = 1, 2, 3, \dots, N$$
(16)

式中: $s(f_i)$  是频率分量的谱能量, $f_i$ , $p_i$ 是对应的概率密度,以及 FFT 中频率分量的总数  $N_o$ 

3)相应的功率谱熵定义为:

$$H = -\sum_{k=1}^{N} p_i \cdot \log p_i \tag{17}$$

为了比较不同的工况条件,采用因子 logN 对结果进行归一化,即:

$$E = \frac{H}{\log N} = \frac{-\sum_{k=1}^{N} p_i \cdot \log p_i}{\log N}$$
(18)

功率谱熵 *E* 为[0,1]范围内的无量纲指标,其中 1 对应于频率分量分布相对均匀且不确定的谱,0 对应于 分布不确定度最小的谱。

### 2 颤振识别方法的仿真验证验证

为了验证上述方法的有效性,对一个具有颤振特征 的铣削信号进行了仿真。参考刘氏公式<sup>[20]</sup>,给出仿真信 号如下,

 $x_1 = 4\sin(40 \times \pi \times t)$   $x_2 = 5\cos(160 \times \pi \times t)$  $x_3 = A \times (1 + 0.6 \times \sin(30 \times \pi \times t)) \times \cos(300 \times \# + 1.5 \times \sin(15 \times \pi \times t))$ 

 $Sig = x_1 + x_2 + x_3 + noise$  (19)

仿真信号由 5 部分组成, $x_1$  是 20 Hz 的角频率,代表 低频和稳态信号。 $x_2$  是 80 Hz 的角频率代表高频和稳态 振动信号。 $x_3$  是具有幅相耦合函数的模型耦合频率分量 模拟颤振频率,通过改变 A 的幅度来调整颤振频率的幅 值,这里把 A 值设为 0.5。Noise 是一个功率为 10 dbW 的高斯白噪声信号。仿真信号的时域波形图 2 如所示, 添加噪声后和没加噪声仿真信号的短时傅里叶变换如所 图 3 示。



由图 3 可以看到,由于添加了一定强度的白噪声, 颤振信号被淹没在噪声中,通过 FFT 不能识别到颤振 信号。利用所提出的 ACMP 对仿真信号进行分解,成 功的提取了 3 种信号模式(为了方便看清曲线,只展示 1 s 的信号)如图 4 所示,从图 4 中可以看到,分解得到 的信号 C1、C2 都可以完美的与原信号 x<sub>2</sub>、x<sub>1</sub> 重合。把 分解后的 C1~C3 这 3 种模式重新合成为新的信号,对 新合成的信号进行 FFT 分析,结果如图 5 所示,可以看 到,ACMP 可以准确地分离了 3 种信号,并无损的提取 到颤振信号,并有效地消除了噪声。同时从图 6、7 的 时频分析对比中可以更清楚的看到 ACMP 对噪声的抑 制效果。



# 颤振识别方法的实际铣削工况验证分析

### 3.1 切削颤振实验

3

铣削试验是在高速加工中心 VDL600A 上进行的。 工件材料为夹紧在工作台上的 2A12 铝合金块。刀具为 两槽硬质合金立铣刀,直径 10 mm。将加速度计安装在 工件上,测量铣削过程中的振动信号,采样频率为 5.12 kHz。加速度传感器为三向加速度传感器,传感器



Fig. 6 Time and frequency diagram of the original signal



Fig. 7 Reconstructed signal time-frequency diagram

参数如表1所示,铣削条件为顺铣,实验示意图如图8 所示。

表 1 加速度传感器参数 Table 1 Acceleration sensor parameters

Tuble	receieration sensor parameters		
型号	方向	灵敏度/(mV/g)	
	X	100. 993	
INV9832-50	Y	101.736	
	Ζ	102. 930	



Fig. 8 Schematic diagram of the experiment

由于颤振与主轴转速和切削深度密切相关,所以在 不同切削速度和切削深度下进行了实验。为了获得从稳 态到颤振的振动信号,应用全离散化方法<sup>[21]</sup>得到稳定性 叶瓣图来确定近似切削参数。通过模态试验和铣削实验 获得稳定性叶瓣图的相关参数如表 2 所示,并绘制稳定 性叶瓣图如图 9 所示。

表 2 主轴-刀具系统的模态参数

 Table 2
 Modal parameters of the spindle-tool system

模态频率 f/Hz	模态质量 m <sub>t</sub> /kg	阻尼比 <i>ξ/%</i>		
988. 336	0.125 4	0.018		
$5.0 \\ 4.5 \\ 4.0 \\ 3.5 \\ 3.0 \\ 2.5 \\ 2.0 \\ (4 000. \\ 1.5 \\ 0.5 \\ 0 \\ 3 000 \\ 0.5 \\ 0 \\ 3 000 \\ 0.5 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0$	1.10     (5 000.0.50)     (6 000.0.5       4 000     5 000     6 000       转速/rpm     图 9 稳定性叶瓣图	7 000 8 000		
Fig. 9 Stability leaf flap diagram				

稳定叶瓣图根据切削轴向深度和主轴转速的不同组 合来区分稳定和不稳定切削操作的区域。理论上,当切 削轴向深度和主轴转速在稳定凸角下选择时,切削过程 是稳定的(无颤振)。否则,切削过程将不稳定(颤振)。 根据图9在铣削实验中选择了转速分别为4000、5000、 6000 rpm3种不同的铣削条件。每个铣削条件的每齿进 给量为0.02 mm,径向深度分别设为4 mm。轴向切深从 0~5 mm 线性增加,如图10 所示,加速度传感器对加速度



Fig. 10 Milling condition

由于从垂直于进给方向的工件获得的加速度信号对 颤振的识别优于进给方向,所以这里只分析垂直于铣削 方向的信号。图 11显示了 3 种铣削条件下的时域信号, 可以看到 3 种铣削条件下均发生了颤振,根据发生颤振 的时间可以计算出发生颤振时的铣削深度,根据稳定叶 瓣图得到的铣削深度与实际测到的铣削深度如表 3 所 示,结果表明在主轴转速为 4 000 和 6 000 mp 时稳定叶 瓣图预测的极限切深与实际切深几乎一致,但是在主轴 转速为 5 000 mp 时误差达到了 44.44%,结果也表明了 实际切削状态与理论分析的稳定波瓣并不完全一致。其 原因是整个切削系统的紧耦合性和时变性。这也说明用 解析法预测加工状态还存在一定的挑战。



Fig. 11 Time domain signals at different speeds



Table 3Chattering depth error

铣削转速	理论颤振铣削深度	实际颤振铣削深度	误差/%
4 000	1.10	1.16	5.17
5 000	0.50	0.90	44.44
6 000	0.55	0.53	3.77

### 3.2 实验结果信号分析

图 11 表明采集到的 3 个信号都可以看到由平稳信 号到颤振信号的过度,可以随机选取一组数据进行分析, 这里选取 6 000 rmp 的数据进行切削颤振分析。为了准 确反映切削过程中的变化及发生颤振的适合,从刀具刚 接触到工件开始截取了 25 s 的振动信号。时频信号如图 11(c)所示,刀齿刚接触到工件时开始产生振动信号,几 秒后切削信号开始变的稳定,到4.4 s 左右振幅开始突然 变大并发生颤振。将该信号做 FFT 变换,图 12 显示了该 段信号的频谱。从图 12 可以看到频率分量主要有 3 种, 即颤振频率、过齿频率(tooth passing frequency, *w<sub>i</sub>*)及其 周期性过齿激励效应引起的谐波(harmonics, *kw<sub>i</sub>*),其中 *k* 为正整数。而颤振频率分量在频带内起主导作用。



利用上述的 ACMP 方法对目标信号进行分析,考虑 到脉冲分量包含在目标样本中,需要选择适当的带宽惩 罚因子来提取信号的本征模函数。因此,时频滤波器的 带宽惩罚因子 α 应选择较大,这将有助于 ACMP 算法找 到正确的 IMFs, 而瞬时频率的带宽惩罚因子  $\beta$  应选择较 小,这将有助 ACMP 算法的收敛。 $\alpha$  和 $\beta$  的参数应由信 号的特性决定。经过几次测试,参数  $\alpha$  被设置为 1×10<sup>-6</sup>, 参数β被设置为1×10<sup>-9</sup>。由于分解层数设置超过4层后 剩余的信号能量会低于残差能量,所以最终确定 IMFS 的 个数为4。目标样本分解后的 IMFS 分量如图 13 所示. 对应模态分量的 FFT 变换如图所示, C2 模态的振幅随时 间逐步增大,并且从图 14 中可以看到,它的振动频率为 957.124 Hz,该频率与刀尖的一阶模态 988.336 Hz 接近, 可以认为该频率为颤振频率,C2、C3、C4 模态的频率分别 为757.196、557.225 和1157.13 Hz,这些频率之间的差 值近似为齿通过频率 200 Hz,所以这些频率可以认为是 颤振频率的附增频率,也可以认为是颤振频率。从图中 可以看到,ACMP 方法可以很好的过滤掉噪声和过齿频 率,从而只保留颤振频率。



Fig. 13 Fourth-order IMFs time domain signal





### 4 颤振识别预测

虽然在第3节中已经将振动信号从强噪声背景中分 离出来,但颤振阶段仍然难以区分。在切削加工过程中, 切削颤振需要关注的两个问题是是否发生了颤振以及颤 振发展到什么程度。为了准确识别切削颤振是否产生, 需要从固有模态函数的时域和频域提取颤振特征,利用 相关统计方法获得特征向量。因此,利用功率谱熵从实 验信号的目标样本和验证样本中提取特征。功率谱熵可 以反映非频域特性的变化。在稳定切削状态下,各频率 范围内的频率分布均匀,导致功率谱熵值达到最大值。 然而,当颤振逐渐增大时,颤振频率分量在频带内起主导 作用,这意味着颤振频率的幅值将逐渐增大,其他频率分 量可以忽略,从而导致功率谱熵减小。

将用 ACMP 分解后的 4 个 IMFS 分量重新组合成新

的信号,提取重新组成的信号的功率谱熵,结果如图 15 所示。从图中可以看出前 4.7 s 功率谱上的数值大概在 0.75 左右,在4.7 s 以后,功率谱熵值突然下降到 0.52 左 右,稍微维持稳定一段时间,随后有稍微上升达到最大值 0.56 后有下降。从图中可以明显的看到在 4.7 s 左右发 生颤振。从图 11(c)可以看到信号振幅突然增加的时间 大概在 4.4 s 左右,由此可以表明,该方法可以快速、准确 的识别到颤振的发生。



在实际铣削加工中,要准确地检测颤振,就必须根据 功率谱熵确定可靠的颤振阈值(即稳定边界)。理论上, 在稳定的切割下,采用较高的功率谱熵值可以更快的检 测出颤振,为了确定可靠的颤振阈值水平,进行了铣削 实验,选择稳定边界。将加速度信号作为被研究的信 号。图 16 给出了不同转速下发生颤振时的功率谱熵 值,由图可以看到,在不同转速下功率谱熵值在 0.65~ 0.75 波动,所以本文确定功率谱熵值 0.65 作为颤振监 测阈值。





### 5 结 论

针对铣削过程振动信号易受噪声干扰和信噪比低的 问题,提出了用 ACMP 和功率谱熵的颤振识别方法,该方 法可以准确地确定信号分量数。与普通窄带信号分解算 法相比,该改进算法能有效地消除噪声干扰,提取信号的 特征分量。该方法具有较好的弱特征提取能力,可以大 大提高切削颤振识别的精度。把分解得到的 IMFs 分量 合成新的信号,计算新合成信号的功率谱熵,得到功率谱 熵曲线,根据这个指标可以快速准确的识别铣削颤振。

### 参考文献

 [1] 曹宏瑞,李登辉,刘金鑫,等.智能主轴高速铣削颤振的模糊控制方法研究[J].机械工程学报,2021, 57(13):55-62.

CAO H R, LI D H, LIU J X, et al. Research on fuzzy control method of intelligent spindle high-speed milling chatter [J]. Journal of Mechanical Engineering, 2021, 57(13):55-62.

- [2] UEKITA M, TAKAYA Y. Tool condition monitoring technique for deep-hole drilling of large components based on chatter identification in time-frequency domain [J]. Measurement, 2017, 103: 199-207.
- [3] 籍永建,王西彬,刘志兵,等.包含刀具-工件多重交互 与速度效应的铣削颤振稳定性分析[J].振动与冲击, 2021,40(17):14-24,54.

JI Y J, WANG X B, LIU ZH B, et al. Stability analysis of milling chatter including multiple tool-workpiece interactions and velocity effects [J]. Vibration and Shock, 2021, 40(17):14-24, 54.

[4] 周航,丁建,林川,等.基于二次 CEEMD 与时域特征分析的去噪方法[J/OL].电子测量与仪器学报:1-9 [2023-04-13].

ZHOU H, DING J, LIN CH, et al. A denoising method based on quadratic CEEMD with time-domain feature analysis[J/OL]. Journal of Electronic Measurement and Instrumentation:1-9[2023-413].

[5] 鄢小安,贾民平.基于参数自适应特征模态分解的滚动轴承故障诊断方法[J]. 仪器仪表学报,2022,43(10):252-259.

YAN X AN, JIA M P. A rolling bearing fault diagnosis method based on parametric adaptive eigenmodal decomposition [J]. Chinese Journal of Scientific Instrument, 2022, 43 (10) : 252-259.

[6] 李尧,刘强. 基于小波包及 Hilbert-Huang 变换的数控 铣削颤振诊断技术[J]. 计算机集成制造系统, 2015, 21(1):204-216. LI Y, LIU Q. Diagnosis technique of CNC milling chatter based on wavelet packet and Hilbert-Huang transform [J]. Computer Integrated Manufacturing Systems, 2015, 21(1): 204-216.

- [7] 李香服,张文灼,温彬彬,等. 基于小波神经网络 PID 控制的主动夹具铣削颤振研究[J].组合机床与自动 化加工技术,2021(1):49-52,56.
  LI X F, ZHANG W ZH, WEN B B, et al. Research on active fixture milling chatter based on wavelet neural network PID control[J]. Combined Machine Tools and Automatic Machining Technology,2021(1):49-52,56.
- [8] LIU C, ZHU L, NI C. The chatter identification in end milling based on combining EMD and WPD [J]. The International Journal of Advanced Manufacturing Technology, 2017, 91(9): 3339-3348.
- [9] 李宏坤,周帅,魏兆成,等. 基于占能比的铣削加工颤 振在线监测研究[J]. 振动. 测试与诊断,2018,38(5): 979-984,1082.
  LI H K, ZHOU SH, WEI ZH CH, et al. Study on online monitoring of chattering in milling based on duty cycle[J]. Vibration. Testing and Diagnosis,2018,38(5):979-984, 1082.
- [10] CHEN S, DONG X, PENG Z, et al. Nonlinear chirp mode decomposition: A variational method [J]. IEEE Transactions on Signal Processing, 2017, 65 (22): 6024-6037.
- [11] NIU J, NING G, SHEN Y, et al. Detection and identification of cutting chatter based on improved variational nonlinear chirp mode decomposition [J]. The International Journal of Advanced Manufacturing Technology, 2019, 104(5): 2567-2578.
- [12] 李忠群,刘浪,段林升,等. 基于 Rényi 熵的铣削过程稳定性预测研究[J]. 湖南工业大学学报,2022,36(3):
   16-21.
   LI ZH Q, LIU L, DUAN L SH, et al. Research on

stability prediction of milling process based on Rényi entropy[J]. Journal of Hunan University of Technology, 2022,36(3):16-21.

- [13] PAN J, LIU Z, WANG X, et al. Boring chatter identification by multi-sensor feature fusion and manifold learning [J]. The International Journal of Advanced Manufacturing Technology, 2020, 109(3): 1137-1151.
- [14] LU K, LIAN Z, GU F, et al. Model-based chatter stability prediction and detection for the turning of a flexible workpiece [J]. Mechanical Systems & Signal Processing, 2018, 100(1):814-826.
- [15] LI K, HE S, LI B, et al. A novel online chatter detection method in milling process based on multiscale

entropy and gradient tree boosting [J]. Mechanical Systems and Signal Processing, 2020, 135: 106385.

- [16] XI S, CAO H, ZHANG X, et al. Zoom synchrosqueezing transform-based chatter identification in the milling process [J]. The International Journal of Advanced Manufacturing Technology, 2019, 101(5): 1197-1213.
- [17] CAO H, LEI Y, HE Z. Chatter identification in end milling process using wavelet packets and Hilbert-Huang transform[J]. International Journal of Machine Tools and Manufacture, 2013, 69: 11-19.
- [18] HOU T Y, SHI Z. Data-driven time-frequency analysis[J]. Applied and Computational Harmonic Analysis, 2013, 35(2): 284-308.
- [19] CAO H, ZHOU K, CHEN X. Chatter identification in end milling process based on EEMD and nonlinear dimensionless indicators [J]. International Journal of Machine Tools and Manufacture, 2015, 92: 52-59.
- [20] LIU C, ZHU L, NI C. Chatter detection in milling process based on VMD and energy entropy [J]. Mechanical Systems and Signal Processing, 2018, 105: 169-182.
- [21] TANG X, PENG F, YAN R, et al. Accurate and efficient prediction of milling stability with updated full-

discretization method [J]. The International Journal of Advanced Manufacturing Technology, 2017, 88: 2357-2368.

### 作者简介



张壮壮,现为北京信息科技大学硕士 研究生,主要研究方向为智能制造、故障 诊断。

E-mail: zzzhs1996@163.com

Zhang Zhuangzhuang now is a M. Sc.

candidate at Beijing Information Science and

Technology University. His main research interests include smart manufacturing and fault diagnosis.



**王红军**(通信作者),2005 年于北京理 工大学获得博士学位,现为北京信息科技大 学教授、博导,主要研究方向为高端装备智 能感知与控制、故障诊断与维护。

E-mail: wanghj86@163.com

Wang Hongjun (Corresponding author) received her Ph. D. degree from Beijing Institute of Technology in 2005. Now she is a professor at Beijing Information Science and Technology University. Her main research interests include highend equipment intelligent perception and control, fault diagnosis and maintenance.