

DOI:10.3969/j.issn.1001-4551.2022.12.017

基于 VMD 能量权重法与 BWO-SVM 的 铣刀磨损状态监测^{*}

赵小惠, 杨文彬, 胡 胜, 谭 琦, 潘 杨
(西安工程大学 机电工程学院, 陕西 西安 710048)

摘要:针对铣刀磨损状态监测中信号噪声大、监测效率低等问题,提出了一种基于能量权重法的变分模态分解(VMD)与黑寡妇(BWO)-支持向量机(SVM)的铣刀磨损状态监测方法。首先,运用 VMD 将铣削时产生的振动信号分解成若干固有模态函数(IMF)分量,并通过能量加权合成峭度指标自适应提取出了包含磨损状态特征的 IMF 分量,并进行了信号重构,对重构信号进行了特征提取;然后,利用 BWO 算法优化 SVM 的参数,构建了 BWO-SVM 铣刀磨损状态监测模型;最后,为了验证上述方法的有效性,以某公司真实加工现场的 PHM Society 2010 铣刀全寿命周期的振动数据进行了实验,并且又通过实际的工程案例对此进行了验证。研究结果表明:通过所提方法自适应提取有效分量并进行信号重构后,降噪效果明显,并通过与遗传算法(GA)和粒子群算法(PSO)优化的 SVM 相比,经过 BWO 优化的 SVM 的训练时间缩短至 25.142 s,同时监测精度达到 97.246%;采用该方法对铣刀磨损状态进行监测,能够获得更快的识别速度与更高的准确性,提高了铣刀磨损状态监测的效率。

关键词:机械摩擦与磨损;变分模态分解;黑寡妇-支持向量机;固有模态函数分量;能量加权合成峭度;磨损状态监测模型

中图分类号:TH117.1;TG714

文献标识码:A

文章编号:1001-4551(2022)12-1762-08

Milling cutter wear monitoring based on VMD energy weighting method and BWO-SVM

ZHAO Xiao-hui, YANG Wen-bin, HU Sheng, TAN Qi, PAN Yang

(School of Mechanical and Electrical Engineering, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: Aiming at the problem of large signal noise and low monitoring efficiency in milling cutter wear state monitoring, a method of milling cutter wear state monitoring based on the energy weighting method of variational modal decomposition (VMD) and black widow optimization (BWO)-support vector machine (SVM) was proposed. Firstly, VMD was used to decompose the vibration signal generated during milling into a number of inherent modal function (IMF), and the IMF components containing wear state features were adapted to extract the signal reconstruction by energy-weighted synthetic cliff metrics, and features were extracted from the reconstructed signal. Then, the parameters of the SVM were optimized using the BWO algorithm to construct a BWO-SVM milling tool wear state monitoring model. Finally, experiments were carried out with the vibration data of the PHM Society 2010 milling cutter throughout its life cycle and verified by engineering cases. The results show that the proposed method is effective in noise reduction after adaptively extracting the effective components for signal reconstruction, and the training time of the optimized SVM by BWO is shortened to 25.142 s compared with the SVM by genetic algorithm (GA) and particle swarm optimization algorithm (PSO), and the monitoring accuracy reaches 97.246%. The wear condition monitoring of milling cutters by this method can obtain faster recognition speed and higher accuracy, and improves the efficiency of milling cutter wear monitoring.

Key words: mechanical friction and wear; variational modal decomposition (VMD); black widow optimization-support vector machine (BWO-SVM); intrinsic mode function (IMF) components; energy-weighted composite kurtosis; wear state monitoring model

收稿日期:2022-04-11

基金项目:国家自然科学基金资助项目(72001166);陕西省科技计划项目(2022JQ-721);陕西省教育厅专项科研计划项目(18JK0324);陕西省社科联重大项目(20ZD195-95)

作者简介:赵小惠(1970-),女,陕西西安人,博士,教授,主要从事智能制造系统理论及应用方面的研究。E-mail:xhuizhao@xpu.edu.cn

0 引言

作为数控铣床生产加工过程中的重要部件,铣刀的磨损状态对设备的加工性能和加工工件的质量有着直接影响。当采用磨损达到一定程度的铣刀进行加工时,不仅会使加工对象表面粗糙度增大,加工精度降低,甚至导致工件报废^[1,2]。

据统计,由铣刀失效导致的加工故障可以占到数控铣床故障总数的 75%,并且数控铣床约 20% 的停机时间与铣刀失效有关^[3]。因此,为了减少生产加工时的残次品数和提高数控铣床加工效率^[4],对铣刀磨损状态精准监测的研究就具有重要的实际意义。

HUANG N E 等人^[5]提出了经验模态分解(empirical mode decomposition, EMD)方法,能够将复杂的振动信号进行自适应分解,并且无需先验知识。孙巍伟等人^[6]利用 EMD 对生产加工过程中产生的振动信号进行了处理,并利用离散隐马尔科夫方法,对刀具进行了磨损故障诊断。DRAGOMIRETSKIY K 等人^[7]提出了基于变分模态分解(VMD)的自适应分解方法,该方法具有完备的数学基础及求解方式,在处理非平稳信号时,取得了较好的效果。王向阳等人^[8]使用 VMD 方法,处理铣削时产生的振动信号,并通过提取各模态的频率特征和能量特征,对铣刀的磨损状态进行了检测。

目前,在状态监测过程中,已有学者对支持向量机(SVM)的使用进行了大量研究。

SUN J 等人^[9]对声发射信号进行了处理,采用支持向量机(SVM),对刀具磨损状态进行了多特征识别。皮俊等人^[10]通过遗传算法,对 SVM 的惩罚参数和核函数进行了优化,完成了对航空发动机磨损故障的诊断。

在上述研究中,在信号处理方面,EMD 在分解信号过程中常出现模态混叠等问题,而 VMD 在分解过程中能够将原始信号中的固有模态分量及中心频率同时分解出来,但对于微弱信号,其分解出的固有模态中会包含大量噪声,并且难以提取出有效特征。

对于状态监测方面,支持向量机已成为小样本数据模式识别的有利方法^[11,12],但 SVM 的识别准确率很大程度上依赖于参数的选择,而最优参数的选取是一个难点^[13]。因此,需要通过引入群体智能算法对 SVM 的参数进行优化,现阶段常用的遗传、粒子群等算法虽然能对 SVM 参数进行优化,但存在寻优速度慢和局部极值等缺点。

综上所述,笔者提出一种基于 VMD 能量权重法与 BWO 优化 SVM 的铣刀磨损状态监测方法。

笔者通过能量加权合成峭度指标,对 VMD 分解

得到的 IMF 分量进行自适应优选,然后提取不同时期磨损状态特征,并构建特征向量,最后利用 BWO-SVM 模型对铣刀磨损状态进行监测。

1 铣刀磨损振动信号降噪原理

1.1 基于 VMD 的振动信号分解

笔者将采集到的铣刀磨损振动信号 $x(t)$ 经过 VMD 分解成 K 个中心频率不同的调幅-调频信号 $u_k(t)$, $k=1,2,\dots,K$ 。其表达式如下:

$$x(t) = \sum_{k=1}^K u_k(t) = \sum_{k=1}^K A_k(t) \cos(\varphi_k(t)) \quad (1)$$

式中: $A_k(t)$ —瞬时幅值; $\varphi_k(t)$ —瞬时频率; K —模态分解个数。

根据 VMD 的约束模型公式,笔者对每个模态信号 $u_k(t)$ 进行处理:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_k u_k(t) = f(t) \end{cases} \quad (2)$$

式中: $\delta(t)$ —脉冲函数; u_k —第 k 个模态分量; ω_k —各模态所对应的中心频率。

在经过 VMD 约束模型处理后的信号 $u_k(t)$ 中,笔者引入增广 Lagrange 函数的 $\lambda(t)$ 算子及二次惩罚因子 α ,即:

$$\begin{aligned} L = (\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \langle \lambda(t), \\ & f(t) - \sum_k u_k(t) \rangle + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \\ & \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (3)$$

笔者用交替方向乘子法迭代更新 u_k 、 ω_k 和 λ_k 的第 $n+1$ 个值,求得 Lagrange 函数的鞍点,最终结束迭代,得到多个 IMF 分量,完成铣刀磨损振动信号的分解。

1.2 基于能量加权合成峭度的 IMF 筛选指标

为了从 VMD 分解信号中,自适应地提取出包含磨损特征最多的 IMF,笔者将能量加权合成峭度指标应用于 IMF 分量的自适应提取上。

在筛选最优 IMF 分量方面,峭度指标、相关系数等应用最为广泛^[14,15]。当仅用峭度作为选取分量的依据时,由于会受到冲击信号分布密度的影响,并且未考虑到信号周期性的问题,最终导致错选或者漏选某些分量。而相关系数是描述变量之间相关程度的指标^[16],经过 VMD 分解得到的 IMF 分量与原始信号越相似,其与原始信号的相关系数越高。当铣刀产生局部磨损时,

其振动信号经过分解得到的各个分量所蕴含的能量是不同的,分量中含有铣刀磨损特征越多其能量值越大。

因此,笔者构建了一种能量加权合成峭度指标,该指标是由相关系数、频域内峭度和能量算子组成的加权指标。

其具体步骤如下:

(1) 计算各分量 $u_k(t)$ 与原信号 $x(t)$ 之间的相关系数:

$$\rho_k = \frac{\text{cov}(u_k(t), x(t))}{\delta_{uk} \delta_x} \quad (4)$$

(2) 计算频域内各分量 u_{vk} 的峭度指标,并进行归一化处理:

$$K(u_{vk}) = \frac{1}{N} \sum_{n=1}^N \left(\frac{u_{vk}(n)}{\delta_{vk}} \right)^2 \quad (5)$$

$$K_{ni} = \frac{K(u_{vk}) - \min K(u_{vk})}{\max K(u_{vk}) - \min K(u_{vk})} \quad (6)$$

(3) 计算各分量 $u_k(t)$ 的能量比:

$$E_k = \frac{\int_0^T u_k^2(t) dt}{\sum_{k=1}^K \int_0^T u_k^2(t) dt} \quad (7)$$

(4) 计算能量加权合成峭度指标:

$$W = \rho_k \cdot K_{ni} \cdot E_k \quad (8)$$

式中: $K(u_{vk})$ —各分量频域内的峭度; K_{ni} —归一化处理后频域内的峭度; ρ_k —分量 $u_k(t)$ 和铣刀磨损原始振动信号 $x(t)$ 之间的相关系数; E_k —各分量的能量比; W —能量加权合成峭度指标。

1.3 基于 VMD 能量权重法的振动信号降噪

笔者运用能量加权合成峭度指标,对通过 VMD 分解的铣刀磨损振动信号进行处理,能够避免因噪声造成的铣刀磨损状态特征难以提取的问题。其具体步骤如下:

(1) 将铣刀磨损时产生的振动信号 $x(t)$ 通过 VMD 算法进行分解,得到 K 个 IMF 分量;

(2) 通过式(4)计算出各 IMF 分量与原始信号的相关系数 ρ_k ,将各分量进行傅里叶变换,并通过式(5)计算在频域内各分量的峭度后由式(6)进行归一化处理得到频峭度 K_{ni} ;再根据式(7)得到各分量的能量比 E_k ,最后进行乘法加权得到能量加权合成峭度指标 W ;

(3) 选取出 W 指标大于平均值的各分量进行重构,完成铣刀磨损原始振动信号的处理。

2 改进 SVM 的铣刀磨损状态监测

2.1 黑寡妇算法

黑寡妇算法(BWO)是 2020 年 PENA-DELGADO

A F 等人^[17]受到黑寡妇蜘蛛独特交配行为的启发而提出的。

该算法模拟了黑寡妇蜘蛛的生命周期,通过 51 个不同的基准函数和 3 种工程算法验证了其在获得最优解方面的有效性。BWO 算法通过初始化种群、运动行为和信息素来更新出适应度最佳的黑寡妇^[18]。具体详述如下:

(1) 初始化种群。在 BWO 算法中,可以将黑寡妇蜘蛛视为一个一维数组,其中,每只黑寡妇蜘蛛表示为每个问题的一个解:

$$\text{Widow} = [X_1, X_2, \dots, X_{N_{\text{var}}}] \quad (9)$$

式中: N_{var} —特征的维度。

每只黑寡妇都有适应度,通过集合中每只黑寡妇的适应度函数,以计算出黑寡妇的适应度:

$$\text{fitness} = f(\text{Widow}) = f(X_1, X_2, \dots, X_{N_{\text{var}}}) \quad (10)$$

初始化黑寡妇种群时,生成一个 N 维的矩阵,通常需要预先设定种群大小,通常选取 30、50 等。

(2) 运动行为。黑寡妇蜘蛛在网格内按照线性和螺旋的方式进行运动,其位置更新为:

$$X_i(t+1) = \begin{cases} X_{\text{best}} - mX_{r_1}(t) & m \in [0.4, 0.9] \\ X_{\text{best}} - \cos(2\pi\beta)X_i(t) & \beta \in [-1, 1] \end{cases} \quad (11)$$

式中: $X_i(t+1)$ —更新后的黑寡妇位置; X_{best} —当前黑寡妇的最优位置; m, β —初始化种群时随机产生的浮点数; $X_{r_1}(t)$ —选择的第 r_1 个黑寡妇的位置; $X_i(t)$ —当前黑寡妇的位置。

(3) 信息素。同大多数昆虫一样,雌性的生理状况越好,其所散发的信息素越浓郁,生育能力越强。所以雄性会依据信息素的浓度来选择配偶。

黑寡妇的信息素率表达式如下:

$$\text{Pheromone}(i) = \frac{\text{fitness}_{\text{max}} - \text{fitness}(i)}{\text{fitness}_{\text{max}} - \text{fitness}_{\text{min}}} \quad (12)$$

当低信息素值等于或者小于 0.3 时,在雌性中低信息素水平的蜘蛛代表饥饿的食人蜘蛛。此时的雌性蜘蛛将被另一个蜘蛛取代,并更新黑寡妇位置,即:

$$X_i(t) = X_{\text{best}} + \frac{1}{2} [X_{r_1} - (-1)^r X_{r_2}[t]] \quad (13)$$

式中: $X_i(t)$ —雌性体内低信息素水平的黑寡妇位置; r_1, r_2 —种群数量在 $[1, N]$ 范围内的数; $\tau \in [0, 1]$ 的随机二进制数。

2.2 基于 BWO-SVM 铣刀磨损状态监测

利用 BWO 算法选取 SVM 的 C 和 g 的关键在于 BWO 的适应度值。笔者选择径向基核函数作为 SVM 的核函数,并通过 SVM 输出的准确率来检验优化方法的有效性。

其具体步骤如下:

- (1) 首先将收集到的铣刀磨损时产生的振动信号进行 VMD 与能量加权合成峭度处理,并提取铣刀磨损状态特征,建立训练样本集和测试样本集;
- (2) 初始化黑寡妇蜘蛛算法的参数,黑寡妇种群大小 $n=100$ 、最大迭代次数 $T=200$ 、维度 $\text{dim}=2$ 、随机参数 $m \in [0.4, 0.9]$ 、 $\beta \in [-1.0, 1.0]$ 以及预设 SVM 的核函数参数 $g \in [0.01, 1000]$ 、惩罚因子 $C \in [0.01, 100]$;
- (3) 根据式(11)计算黑寡妇的位置信息,通过式(12)计算每只黑寡妇的信息素并由式(13)更新信息素低的黑寡妇;
- (4) 计算新搜索到的黑寡妇位置的适应度值,找到最优黑寡妇位置及最优适应度值;
- (5) 判断步骤(4)中的黑寡妇位置的适应度是否满足要求,若迭代次数、最优黑寡妇和预设的精度水平满足终止条件时,则停止循环,否则返回步骤(3)重新进行迭代计算;
- (6) 将输出的黑寡妇最优解(参数 C 、 g)与 SVM 建立铣刀磨损状态监测模型。利用该模型对测试样本集进行测试,完成铣刀磨损状态监测。

3 铣刀磨损状态监测流程

基于上述理论分析,笔者将原始信号进行 VMD 分解后,通过能量加权合成峭度,自适应筛选出最优 IMF,并使用 BWO 优化 SVM 中的参数 C 及 g 进行铣刀磨损状态监测,构建出数控机床铣刀磨损状态监测模型。其整体流程如图 1 所示。




图 1 铣刀磨损状态监测流程图

4 全寿命周期实验信号验证

笔者采用 PHM Society 2010 年的铣刀磨损数据集进行实验^[19]。

实验装置由铣刀、加速度传感器、AE 传感器、测

力计及工件等构成,如图 2 所示。




图 2 铣刀全寿命周期实验装置

加工设备采用 Roders Tech RFM760 高速数控机床,刀具为 3 刃球头硬质合金铣刀,加工材料为不锈钢 HRC52。

机床铣削参数设置如表 1 所示。

表 1 实验切削参数

主轴转速/ ($r \cdot \text{min}^{-1}$)	进给速度/ ($\text{mm} \cdot \text{min}^{-1}$)	径向深度/ mm	轴向深度/ mm	走刀量/ mm
10 400	1 555	0.125	0.2	0.001

该数据集共分为 6 组,每组数据包含 315 次走刀过程中 X 、 Y 、 Z 3 个方向的铣削力信号、振动信号以及声信号。

根据 ISO 标准规定以 1/2 背吃刀量的后刀面测定的磨损带宽度为铣刀的实际磨损量 VB 。笔者采用第 1 组数据中 X 、 Y 、 Z 方向振动信号进行分析。

其中,铣刀的磨损值变化曲线如图 3 所示。




图 3 铣刀磨损变化曲线

根据铣刀平均磨损值的变化情况,可将铣刀磨损分为初期磨损、中期磨损和后期磨损 3 种不同的磨损状态。其中,由于前期铣刀表面不平滑以及后刀面与工件接触面小,造成切削面存在较大应力的问题,使得初期磨损相对较快、经历时间短。

在初期磨损过程中,铣刀与工件的接触稳定性逐渐增加,达到一定程度时,铣刀将进入中期磨损阶段,该阶

段的铣刀与工件的切削面平整,接触面应力较小,磨损值降低;随着磨损量不断的增加,磨损带宽增加,刀具变钝,又由于温度上升造成磨损加剧从而使铣刀进入后期磨损阶段,最终达到铣刀磨损极限造成刀具失效。

具体的铣刀磨损阶段划分如表 2 所示。

表 2 铣刀磨损等级划分

磨损状态	走刀次数	磨损量/ μm
初期磨损	0 ~ 120	[0, 100]
中期磨损	121 ~ 280	[100, 150]
后期磨损	281 ~ 315	[150, + ∞]

笔者以铣刀 X 方向的原始振动信号为例,其初期磨损、中期磨损和后期磨损的时域波形,如图 4 所示。




图 4 铣刀不同磨损状态振动信号

从图 4 可以看出:原始信号中包含大量噪声,并且调制特征不明显,无法根据原始信号波形进行铣刀磨损状态监测。

4.1 信号降噪

对铣刀初期磨损振动信号进行 VMD 分解,当 $K = 5$ 时,分解得到的 IMF 分量,如图 5 所示。

通过计算各 IMF 的能量加权合成峭度 W 值,自适应选取包含铣刀磨损状态信息的最优分量,如表 3 所示。

表 3 各模态分量的加权合成峭度指标

IMF _i	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅
W	0.30	0.17	0.41	0.60	0.23

其中:IMF₃ 和 IMF₄ 的能量加权合成峭度值是大




图 5 铣刀初期磨损信号 VMD 分解结果

于平均值的,即选取 IMF₃ 和 IMF₄ 为最佳模态分量,并进行信号重构。

笔者采用同样的方式选取出中期和后期磨损的最优分量并重构,重构结果如图 6 所示。




图 6 铣刀不同磨损状态重构信号

从图 6 可以看出:进行重构之后的信号仅含有少量的噪声并且呈现出明显的周期性冲击。

4.2 特征向量提取

笔者对重构信号提取均值、均方根等 9 个时域特征,和频域均方根、频域偏态等 9 个频域特征,以及 15 个尺度范围内的排列熵,共得到 33 个特征。但是提取的多个特征并非都与磨损量有关而且维数也相对较高。

为了减少不必要的计算,笔者应用主成分分析对提取的多个特征进行融合,再将融合后的特征向量作为支持向量机的样本输入;对 180 组振动信号以及 33 个特征进行组合,得到一个 180 行 33 列的矩阵 M ,其表达式如下:

$$M = [m_1 \quad m_2 \quad \cdots \quad m_{33}] \tag{14}$$

式中: m_n —180×1 的列向量。

计算数据样本的协方差,其公式如下:

$$Cov(M) = \frac{1}{33} \sum_{n=1}^{33} (m_n - \bar{m})(m_n - \bar{m})^T \tag{15}$$

笔者对协方差矩阵进行特征分解,分解后的前 K 阶特征值对应的特征向量组成的新矩阵,就是经过主成分分析后的结果。

笔者最终将特征压缩至 12 维。

4.3 铣刀磨损状态监测

该实验采集铣刀初期磨损、中期磨损和后期磨损 3 种磨损状态的振动信号,共 180 组数据,每组 4 000 个数据点。

笔者将 3 种磨损状态作为分类器的输出,1、2、3 表示铣刀初期磨损、中期磨损和后期磨损;随机选择 90 组样本用于模型训练,剩余 90 组作为测试样本。

经过 BWO-SVM 对样本进行识别,结果如图 7 所示。




图 7 铣刀磨损状态监测结果

为了更好地突出 BWO-SVM 分类效果,笔者将其与粒子群优化的 SVM,及遗传算法优化的 SVM 的模型进行对比。为保障测试结果更加客观,笔者使用相同的数据,对各算法的参数设置保持一致,种群大小设为

100,最大迭代次数设为 200。

3 种模型在训练集上的适应度变化曲线,如图 8 所示。




图 8 3 种模型适应度变化曲线

从图 8 可以看出:虽然 3 种模型都能在 200 次迭代内达到最优适应度,但 BWO-SVM 在第 3 次迭代时就达到最高值,而且高于其他两种模型。

这说明 BWO-SVM 能用更短时间和更少的迭代次数寻找到 SVM 的最优参数。

笔者将铣刀磨损特征的测试集投入到 3 种方法训练好的 SVM 中进行识别,其结果如表 4 所示。

表 4 识别方法的比较结果

分类器	惩罚因子 C	核参数 g	准确率/%	迭代时间/s
BWO-SVM	3.364 2	10.706	97.246	25.142
PSO-SVM	5.800 1	21.313	90.702	49.183
GA-SVM	9.450 5	15.856	82.635	63.941

通过对比分析可知:经过笔者所提方法优化后的 SVM 不仅在识别的准确率上高于其他算法,而且在迭代时间上也具有明显优势。

5 实际工程案例验证

为进一步验证上述方法的有效性,笔者以某公司真实加工现场的立铣刀磨损数据为例进行验证。

笔者将工厂前期采集到的少量经验数据进行整理分析,并根据 ISO 标准划分出立铣刀初期、中期和后期磨损,其磨损图如图 9 所示。

笔者对所提出的模型进行训练,检查铣刀并进行测量后发现立铣刀处于中期磨损阶段,已知设定的采样频率为 10 kHz,工件材料为 45 号钢,进给速度是 764.4 mm/min 的干切。选择分析的数据点数为 4 000 个。

由于环境因素的影响,原始工程信号时域波形中无法观察到周期性冲击特征,如图 10 所示。

因此,笔者通过 VMD 能量权重法对工程信号进行降噪重构处理,结果如图 11 所示。




图 9 工程信号立铣刀磨损变化曲线




图 10 工程实例原始信号




图 11 信号重构图

通过图(10,11)可知:笔者所提方法能够对原始工程信号进行降噪重构处理,并且能够突出铣刀的特征频率。

笔者将处理后的信号提取出多个特征进行特征融合,并输入到训练好的 BWO-SVM 模型,结果如图 12 所示。




图 12 工程信号监测结果

根据图 12 监测结果可知,基于 VMD 与 BWO-SVM 的方法完全能够实现对铣刀磨损状态的监测。

6 结束语

由于在铣刀磨损状态监测过程中存在信号噪声大、监测效率低等问题,笔者提出了一种基于 VMD 与 BWO-SVM 的铣刀磨损状态监测方法。

笔者首先采用 VMD 对铣削振动信号进行了分解,并通过能量加权合成峭度指标自适应地筛选出了最优分量,并进行了重构;然后,提取了重构信号的时域、频域及多尺度排列熵等特征,经主成分分析融合成了多维特征向量,并引入 BWO 算法对 SVM 参数进行了优化,得到了 BWO-SVM 的优化模型;最后,以某真实铣刀全寿命周期的振动数据,及实际的工程案例对该模型的有效性与准确性进行了验证。

研究结论如下:

(1)采用 VMD 方法分解振动信号后使用能量加权合成指标选取最优分量,能够避免出现模态混叠及末端效应,并能够自适应的剔除多余或者虚假信号,具有一定的降噪功能,又提高了之后识别的运行效率;

(2)黑寡妇算法优化 SVM,提高了铣刀磨损状态监测的效率;相比于其他方法对 SVM 进行优化,采用黑寡妇算法优化 SVM 能够避免出现局部最优和过拟合的问题,并且在 25.142 s 就能寻找到最优参数组;

(3)笔者以 PHM Society 2010 数据以及工程案例验证了基于 VMD 能量权重法为信号处理方法和 BWO-SVM 铣刀磨损状态监测模型。通过与其他方法对比分析,结果显示 BWO 优化的 SVM 铣刀磨损状态监测模型准确率能够达到 97.246%。

采用该模型进行铣刀磨损状态监测,能够将多种特征进行融合并能更快速地实现铣刀磨损状态的监测,且精度较高。

在未来的研究中,可以考虑在监测到不同铣刀磨损状态的同时,对该状态的铣刀剩余使用寿命进行预测分析。

参考文献 (References):

- [1] 郝碧君,陈 妮,李 亮,等. 基于小波包分析和 LS-SVM 的钻削刀具状态识别研究[J]. 工具技术,2019,53(12): 3-9.
- [2] 许钟允,张 挺. 基于声发射技术的超精密切削状态监测试验研究[J]. 机电工程,2021,38(8):1070-1075.

(下转第 1783 页)

本文引用格式:

赵小惠,杨文彬,胡 胜,等. 基于 VMD 能量权重法与 BWO-SVM 的铣刀磨损状态监测[J]. 机电工程,2022,39(12):1762-1768,1783.

ZHAO Xiao-hui, YANG Wen-bin, HU Sheng, et al. Milling cutter wear monitoring based on VMD energy weighting method and BWO-SVM[J]. Journal of Mechanical & Electrical Engineering, 2022,39(12):1762-1768,1783.

《机电工程》杂志: <http://www.meem.com.cn>

- 起重机防摆研究[J]. 中国工程机械学报, 2019(2): 112-116.
- [4] 卢凤娇, 刘海江, 油磊, 等. 桥式起重机防摇控制算法综述[J]. 船舶与海洋工程, 2020, 36(1): 1-7.
- [5] OUYANG H, HU J, ZHANG G, et al. Sliding-mode-based trajectory tracking and load sway suppression control for double-pendulum overhead cranes[J]. **IEEE Access**, 2018, PP(99): 1-9.
- [6] 唐伟强, 黄小丽, 龙文莹, 等. 基于模型预测控制的桥式起重机防摇设计[J]. 兰州理工大学学报, 2020, 46(2): 92-96.
- [7] SOLIHIN MI, LEGOWO A, AKMELIAWATI R. Robust PID Anti-swing Control of Automatic Gantry Crane based on Kharitonov's Stability[C]//IEEE 2009 4th IEEE Conference on Industrial Electronics and Applications (ICIEA). Xian, China; [s. n.], 2009: 275-280.
- [8] SANO H., OHISHI K., KANEKO T, et al. Anti-sway Crane Control based on Dual State Observer with Sensor-delay correction[C]//IEEE 2010 11th IEEE International Workshop on Advanced Motion Control (AMC). Nagaoka, Japan; [s. n.], 2010: 679-684.
- [9] ISMAIL R., HA Q P. Trajectory Tracking and Anti-sway Control of Three-dimensional Offshore Boom Cranes using Second-order sliding Modes [C]//IEEE 2013 IEEE International Conference on Automation Science and Engineering (CASE 2013). Madison, WI, USA; [s. n.], 2013: 996-1001.
- [10] AHMAD M A, ISMAIL R, RAMLI M S. Input Shaping Techniques for Anti-sway Control of a 3-D Gantry Crane System [C]//IEEE 2009 International Conference on Mechatronics and Automation (ICMA). Changchun, China; [s. n.], 2009: 2876-2881.
- [11] 胡艳丽, 杨国诗, 季学斌, 等. 模糊自适应 PID 控制在桥式起重机智能防摆中的应用[J]. 重庆工商大学学报: 自然科学版, 2015, 32(6): 60-64.
- [12] 刘辉, 黄国健, 勉智. 非线性优化 PID 控制在桥式起重机防摆中的应用[J]. 自动化与信息工程, 2014, 35(3): 21-26.
- [13] 温馨, 石红瑞. 积分过程的二自由度 PID 控制及应用[J]. 控制工程, 2013, 20(S1): 206-208.
- [14] 王刚, 宋英杰, 唐武生, 等. 基于迭代学习的三自由度机械臂轨迹跟踪控制[J]. 吉林大学学报: 自然科学版, 2021, 39(4): 389-396.
- [15] 李帆. 基于防摇控制的桥式起重机路径规划研究[D]. 大连: 大连理工大学机械工程学院, 2021.
- [16] 王佳奕. 岸边集装箱起重机自动防摇控制的研究[D]. 上海: 上海交通大学机械与动力工程学院, 2012.
- [17] 时宇环. 基于自适应模糊神经网络控制的起重机吊载防摇研究[D]. 青岛: 中国石油大学控制科学与工程学院, 2018.
- [18] 何航, 宛西原, 胡宇. 起重机模糊神经网络防摇控制仿真研究[J]. 自动化仪器仪表, 2014(1): 10-14.
- [编辑: 李辉]

本文引用格式:

卢凯, 王挺. 吊装机械臂末端吊具防摇控制的实验研究[J]. 机电工程, 2022, 39(12): 1776-1783.

LU Kai, WANG Ting. Experimental research on anti-sway control of hoisting manipulator end spreader[J]. Journal of Mechanical & Electrical Engineering, 2022, 39(12): 1776-1783.

《机电工程》杂志: <http://www.meem.com.cn>

(上接第 1768 页)

- [3] MEHRABI M G, KOREN A G U. Reconfigurable manufacturing systems: key to future manufacturing [J]. **Journal of Intelligent Manufacturing**, 2000, 11(3): 403-419.
- [4] 刘献礼, 刘强, 岳彩旭, 等. 切削过程中的智能技术[J]. 机械工程学报, 2018, 54(6): 45-61.
- [5] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis[J]. **Proceedings of the Royal Society A: Mathematical Physical and Engineering Sciences**, 1998, 454(5): 903-995.
- [6] 孙巍伟, 黄民, 高延. 基于 EMD-HMM 的机床刀具磨损故障诊断[J]. 机床与液压, 2017, 45(7): 178-181.
- [7] DRAGOMIRETSKIY K, ZOZZO D. Variational Mode Decomposition [J]. **IEEE Transactions on Signal Processing**, 2014, 62(3): 531-544.
- [8] 王向阳, 何岭松, 王平江, 等. 基于 VMD 的铣刀破损检测[J]. 振动与冲击, 2020, 39(5): 135-140, 162.
- [9] SUN J, RAHMAN M, WONG Y S, et al. Performance comparison of conventional and wiper ceramic inserts in hard turning through artificial neural network modeling [J]. **International Journal of Advanced Manufacturing Technology**, 2011, 52(3): 101-114.
- [10] 皮骏, 马圣, 贺嘉诚, 等. 遗传算法优化的 SVM 在航空发动机磨损故障诊断中的应用[J]. 润滑与密封, 2018, 43(10): 89-97.
- [11] GUO H, WANG W. An active learning-based SVM multiclass classification model [J]. **Patten Recognition**, 2015, 48(5): 1577-1597.
- [12] GAUDIOSO M, GORGONE E, LABBE M, et al. Lagrangian relaxation for SVM feature selection [J]. **Computers & Operations Research**, 2017, 87(1): 137-145.
- [13] 王二化, 刘颀. WPD 和 SVM-PSO 在微铣刀磨损在线监测中的应用[J]. 机械科学与技术, 2021, 32(6): 1-10.
- [14] 王海峰, 刘德平, 高建设. BFA 优化 EEMD 的刀具故障诊断[J]. 现代制造工程, 2020(7): 135-139, 82.
- [15] 吴瀚, 赵亦希, 田昂. 基于粒子群优化的螺纹刀具磨损状态监测模型[J]. 机械设计与研究, 2021, 37(3): 132-136.
- [16] 吕震宇. 刀具磨损特征参数提取与状态识别方法[J]. 组合机床与自动化加工, 2019(7): 92-96, 100.
- [17] PENA-DELGADO A F, JUAN H, CRUZ N T, et al. A novel bio-inspired algorithm applied to selective harmonic elimination in a three-phase eleven-level inverter [J]. **Mathematical Problems in Engineering**, 2020, 459(22): 1-10.
- [18] 李郅琴, 杜建强, 聂斌, 等. 基于黑寡妇算法的特征选择方法研究[J]. 计算机工程与应用, 2021, 13(5): 1-44.
- [19] PHM SOCIETY. 2010 phm society conference data challenge [EB/OL]. [2010-02-13]. <https://www.phmsociety.org/COMPETITION/PHM/10>.
- [编辑: 李辉]