

基于鲸鱼算法优化 LSSVM 的铣刀磨损监测

张庆华, 龙 伟, 李炎炎, 林 懿
(四川大学机械工程学院, 成都 610065)

摘 要: 为解决铣刀磨损状态监测问题, 提出一种改进的鲸鱼算法优化最小二乘支持向量机的状态识别方法. 首先, 采用变分模态分解处理铣削过程中的振动信号, 分解得到的固有模态分量进行特征提取; 然后, 针对鲸鱼算法易陷入局部最优解、收敛精度低的问题, 引入混合反向学习算法和非线性收敛因子进行改进, 并采用基准测试函数验证改进后的鲸鱼算法的有效性; 最后, 将改进的鲸鱼算法优化 LSSVM 模型应用于铣刀磨损状态识别仿真实验. 实验结果表明, 相较于粒子群算法与传统鲸鱼算法, 改进的鲸鱼算法优化 LSSVM 具有更高的识别精度.

关键词: 刀具磨损; 鲸鱼算法; 反向学习; 最小二乘支持向量机

中图分类号: TP277 **文献标识码:** A **DOI:** 10.19907/j.0490-6756.2022.012005

Milling cutter wear monitoring based on whale algorithm optimized LSSVM

ZHANG Qing-Hua, LONG Wei, LI Yan-Yan, LIN Yi
(College of Mechanical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: In order to solve the problem of monitoring the wear status of milling cutters, an improved whale algorithm is proposed to optimize the state recognition method of least squares support vector machine. Firstly, variational modal decomposition is used to process the vibration signal in the milling process, and the characteristics of the inherent modal functions obtained by decomposition is extracted; then, to tackle the problem that whale algorithm is easy to fall into local optimal solution and low convergence accuracy, a hybrid reverse learning algorithm and the nonlinear convergence factor is introduced, and benchmark functions are used to verify the effectiveness of the improved whale algorithm; finally, the improved whale algorithm optimized LSSVM model is applied to the simulation experiment of milling cutter wear status recognition. The experimental results show that, compared with particle swarm algorithm and traditional whale algorithm, the improved whale algorithm optimized LSSVM has higher recognition accuracy.

Keywords: Tool wear; Whale algorithm; Reverse learning; Least squares support vector machine

1 引 言

智能制造作为新一轮产业升级的重要方向,正在给全球制造业带来深刻的变革. 在机械加工制造中,设备的故障诊断是重点研究领域^[1],刀具的磨

损状态对工件的质量有着直接的影响^[2],当刀具磨损到一定程度时,如果继续使用,则会引起切削力、切削温度及切削振动等明显变化,降低切削性能,甚至导致工件报废^[3]. 研究表明^[4,5],刀具的磨钝和破损会导致生产加工的时间成本与经济成本的

收稿日期: 2021-05-09
基金项目: 国家绿色制造系统集成项目(工信部节函[2017]327); 2020 年第一批工业互联网试点示范项目(101)
作者简介: 张庆华(1997—), 男, 江西抚州人, 硕士研究生, 研究方向为刀具磨损监测. E-mail: zhangqinghuascdx@163.com
通讯作者: 龙伟. E-mail: scdxlongwei@yeah.net

上升,刀具磨损状态监测技术可以提高生产效率,降低生产成本,具有重要意义。

刀具磨损状态可以通过直接法和间接法进行监测^[6]。接触测量法和机器视觉测量法^[7]常用于直接监测刀具的磨损。由于直接法的实施成本过高,不适合实际应用,目前主要采用间接法实现刀具磨损状态的监测。加工过程中,切削力、振动等信号与刀具磨损量密切相关,间接法通过分析这些信号实现对刀具磨损状态的间接监测,其过程可分为信号采集、特征提取和模式识别^[8]。

能否准确地提取与刀具磨损相关的特征直接关系到刀具磨损状态识别的结果好坏。常用的特性提取方法有:时域分析、频域分析、小波分解和经验模态分解(Empirical Mode Decomposition, EMD)等。时域分析与频域分析是分别对信号进行时频域处理,获得时域特征与频域特征,不能兼顾信号在时域和频域中的变化,对于非平稳信号效果不佳。Somkiat 等^[9]提出了一种基于小波变换的刀具磨损监测系统,利用小波变换区分刀具磨损信号与噪声。孙巍伟等^[10]利用 EMD 处理机加工过程产生的振动信号,并结合隐马尔可夫模型进行刀具磨损故障诊断。Dragomiretskiy 等^[11]提出了一种完全非递归的变分模态分解(Variational Mode Decomposition, VMD)方法, VMD 解决了 EMD 出现的模态分量混叠问题^[12]。王向阳等^[13]使用 VMD 方法处理铣削加工产生的振动信号,提取每个固有模态分量(Intrinsic Mode Function, IMF)的中心频率和能量作为特征向量,结果表明相较于 EMD 方法, VMD 更加适用于铣刀破损检测。因此,本文采用 VMD 对振动信号进行特征提取。

在磨损状态识别方面,关山等^[14]采用最小二乘支持向量机(Least Squares Support Vector Machines, LSSVM)实现了刀具磨损量的测量,证明了该方法相比于神经网络算法,拥有更高的精度。但是, LSSVM 方法对参数的取值非常敏感,模型参数的取值对识别精度的影响大^[15]。为了解决 LSSVM 的参数选择问题,刘成颖等^[16]引入粒子群算法(Particle Swarm Optimization, PSO)优化 LSSVM 模型的惩罚因子和核参数,但是该算法存在局部极值,易早熟收敛等缺点。本文针对上述问题,提出一种基于改进的鲸鱼算法优化最小二乘支持向量机的刀具磨损监测方法。首先,采用 VMD 对振动信号进行分解,提取每个模态的能量熵和时频域特征,归一化处理后作为特征向量。然后,采用

改进的鲸鱼算法优化 LSSVM 模型的惩罚因子和核参数。最后,将本文提出的模型应用于刀具磨损状态监测,结果表明,该方法具有更高的识别精度。

2 鲸鱼优化算法

鲸鱼优化算法(Whale Optimization Algorithm, WOA),是一种模拟座头鲸群体捕食行为的智能优化算法^[17,18]。在该算法中,鲸鱼种群相当于待求解问题的解空间,每个鲸鱼个体代表一个可行解,鲸鱼在全局中的最优位置表示 WOA 算法中的最优解。由于初始状态下,全局最优位置是未知的,故先找出当前鲸鱼种群中适应度值最优的个体,将其视为目标猎物,其他鲸鱼个体通过收缩包围、气泡网捕食和随机搜索三种方式更新自身位置,其过程如下。

2.1 收缩包围

在收缩包围阶段,鲸鱼首先识别目标猎物并将其包围,种群中的其他个体均向目标猎物位置移动,位置更新公式如下。

$$D = |CX^*(t) - X(t)| \quad (1)$$

$$X(t+1) = X^*(t) - AD \quad (2)$$

式中, $A = 2ar - a$; $C = 2r$; t 表示当前的迭代次数; r 表示 $[0, 1]$ 的随机数; a 表示收敛因子,初始值为 2,之后线性递减为 0。

2.2 气泡网捕食

气泡网捕食过程中,鲸鱼通过螺旋更新位置和收缩包围进行捕食,二者是同步进行的,为了模拟这一过程,引入概率 p 在二者之间选择,当 $p < 0.5$ 时,鲸鱼通过式(2)收缩包围;当 $p \geq 0.5$ 时,搜索代理通过螺旋模型更新位置,其数学模型如下。

$$X(t+1) = D'e^{il} \cos(2\pi l) + X^*(t) \quad (3)$$

式中, b 为对数螺旋形状常数; l 为区间 $[-1, 1]$ 中的随机数。

2.3 随机搜索

当 $|A| \geq 1$ 时,搜索代理不再基于目标猎物更新位置,而是根据彼此的位置进行全局搜索,以便增强 WOA 的全局搜索能力,随机选择当前种群中的一个搜索代理,表示为 $X_{\text{rand}}(t)$,随机搜索公式表述为

$$X(t+1) = X_{\text{rand}}(t) - AD \quad (4)$$

3 改进的鲸鱼优化算法

传统鲸鱼算法的优点在于调节参数少,可以较好的平衡开发与勘探能力^[19],然而由于线性收敛

因子的存在,使得 WOA 算法在迭代过程的前期,具有一定的全局搜索能力,而迭代的后期,陷入局部最优解的可能性大,影响 WOA 算法的收敛精度.

为克服 WOA 算法存在的上述缺陷,笔者提出一种改进的鲸鱼算法(Improved Whale Optimization Algorithm, IWOA). 相比于传统鲸鱼算法, IWOA 在迭代中引入混合反向学习策略,同时改进收敛因子,以提升算法的全局搜索能力和收敛速度. 具体的改进措施如下.

3.1 混合反向学习算法

反向学习用于初始化种群,可提高初始种群搜索代理的质量^[19],然而高质量的初始种群并不总能引导算法找到全局最优解,在之后的每次迭代过程中,算法依然可能陷入局部最优解. 本文采用混合反向学习算法,在每次迭代鲸鱼种群的位置更新之后,将当前种群个体按适应度排序,取适应度较大的一半个体,计算其反向种群,将得到的反向种群与原鲸鱼种群比较,保留适应度较优个体. 并且在计算反向种群时引入反向学习因子,以加强算法的全局探索能力. 假设在第 t 次迭代中,鲸鱼种群为 $P(t)=\{x_{i,j}\}, i=1,2,\cdots,N; j=1,2,\cdots,D$ (其中 N 为鲸鱼种群的规模; D 为可行解的维数),反向种群 $P'(t)=\{x'_{i,j}\}$,则可以通过以下公式计算出反向种群.

$$x'_{i,j}=l(x_{\min,j}+x_{\max,j}-x_{i,j}) \tag{5}$$

其中, l 为反向学习因子,是区间 $[0,2]$ 上的随机数; $x_{\max,j}$ 和 $x_{\min,j}$ 分别为搜索代理 x_i 的第 j 维元素最大值和最小值. 然后,计算当前种群个体适应度 $fitness(i)$ 与反向种群个体适应度 $fitness'(i)$,若反向种群适个体应度优于当前种群个体,则用反向种群个体代替当前种群个体.

3.2 非线性收敛因子

标准鲸鱼算法的全局探索与局部开发能力依赖于系数 A ,而系数 A 的值是由收敛因子 a 确定的,收敛因子是线性递减的,使得鲸鱼算法在迭代前期收敛因子较大,因而具有较强的全局探索能力,在迭代后期,收敛因子较小,算法倾向于进行局部开发,这使得算法在复杂的非线性搜索过程中收敛速度慢,容易陷入局部最优解. 因此,本文提出一种分段的非线性收敛因子,具体公式如下.

$$a=\begin{cases} 2\cos(\frac{t}{T}\pi), & t\leq\frac{T}{2} \\ 2\cos(\frac{t}{T}\pi)+2, & t>\frac{T}{2} \end{cases} \tag{6}$$

在整个迭代过程中,非线性收敛因子分别在前半段和后半段从 2 减小到 0,并且前半段下降的速度逐渐增大,后半段下降的速度逐渐减小,使得改进后的鲸鱼群算法可以更好地适应复杂的搜索过程. IWOA 算法流程如下.

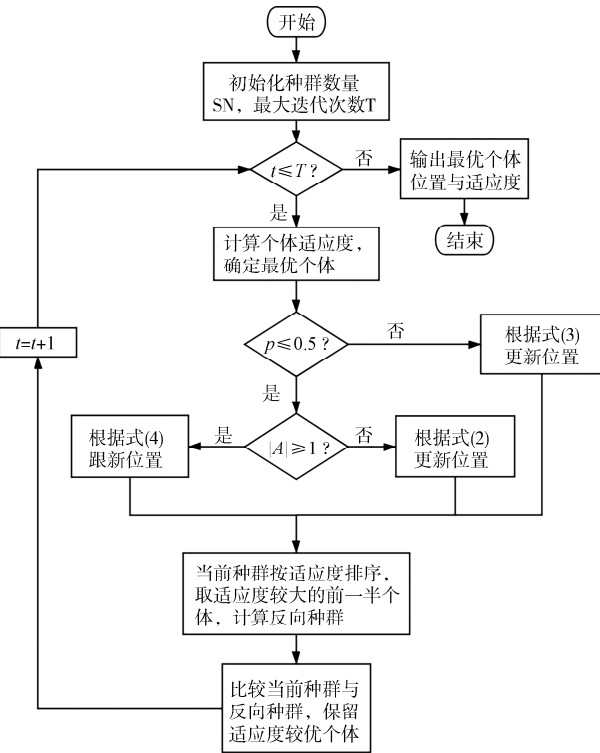


图 1 IWOA 算法流程图

Fig. 1 Flow chart of IWOA algorithm

4 IWOA 算法性能测试

采用 4 个基准测试函数(如表 1)验证 IWOA 算法的性能,其中 f_1 和 f_2 为单峰基准函数, f_3 和 f_4 为多峰基准函数. 在进行对比测试时,将本文提出的 IWOA 算法与 WOA 算法、灰狼优化算法(Grey Wolf Optimizer, GWO)、引力搜索算法(Gravitational Search Algorithm, GSA)、粒子群算法(Particle Swarm Optimization, PSO)法进行对比,为使测试结果更加客观,所有算法的设置保持一致,种群规模均设置为 30,最大迭代次数均设置为 500,测试结果见图 2~图 5.

表 1 4 个基准测试函数
Tab. 1 Four benchmark test functions

函数名	表达式	维度	范围	理论最优
Sphere	$f_1 = \sum_{i=1}^{Dim} x_i^2$	30	$[-100, 100]$	0
Quartic	$f_2 = \sum_{i=1}^{Dim} ix_i^4 + \text{random}[0,1)$	30	$[-1.28, 1.28]$	0
Schwefel	$f_3 = 418.9829Dim - \sum_{i=1}^{Dim} x_i \sin(\sqrt{ x_i })$	30	$[-500, 500]$	0
Griewank	$f_4 = \frac{1}{4000} \sum_{i=1}^{Dim} x_i^2 - \prod_{i=1}^{Dim} \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	$[-600, 600]$	0




图 2 f_1 函数优化曲线
Fig. 2 The optimization curve of f_1 function




图 3 f_2 函数优化曲线
Fig. 3 The optimization curve of f_2 function




图 4 f_3 函数优化曲线
Fig. 4 The optimization curve of f_3 function




图 5 f_4 函数优化曲线
Fig. 5 The optimization curve of f_4 function

通过对 4 个基准测试函数的仿真结果可以看出,在优化单峰函数与多峰函数时,IWOA 算法的收敛精度与收敛速度明显优于其他 4 种对比算法.在对 f_4 函数的优化中,IWOA 算法与 WOA、GWO 算法均能收敛到全局最优,而 IWOA 的收敛速度要优于 WOA 与 GWO,这验证了 IWOA 算法的可行性与高效性.故将本文提出的 IWOA 算法用于优化 LSSVM 模型,对惩罚因子 γ 和核参数 σ 寻优,以提高模型的识别率.

5 实验分析

实验采用 PHM Society 2010 年提供的铣刀磨损数据集,该数据集共分为 6 组,每组数据包含 X、Y、Z 三个方向的铣削力信号和振动信号以及声发射信号的均方根值,本文采用第 6 组数据中 X、Y、Z 三个方向的振动信号进行实验.首先使用 VMD 分解信号,得到 IMF 分量,提取 IMF 分量的时域特征与能量熵作为特征向量.在进行 VMD 分解时,分解数 K 的确定对分解效果至关重要,以 X

方向振动信号为例,当 $K=5$ 时,出现了模态交叠现象(IMF4 与 IMF5,如图 6 所示),因此取 $K=4$ 。

采用同样的方法,可以确定分解 Y 方向振动信号、Z 方向振动信号时, K 的值取 3 可以较好地分解信号。

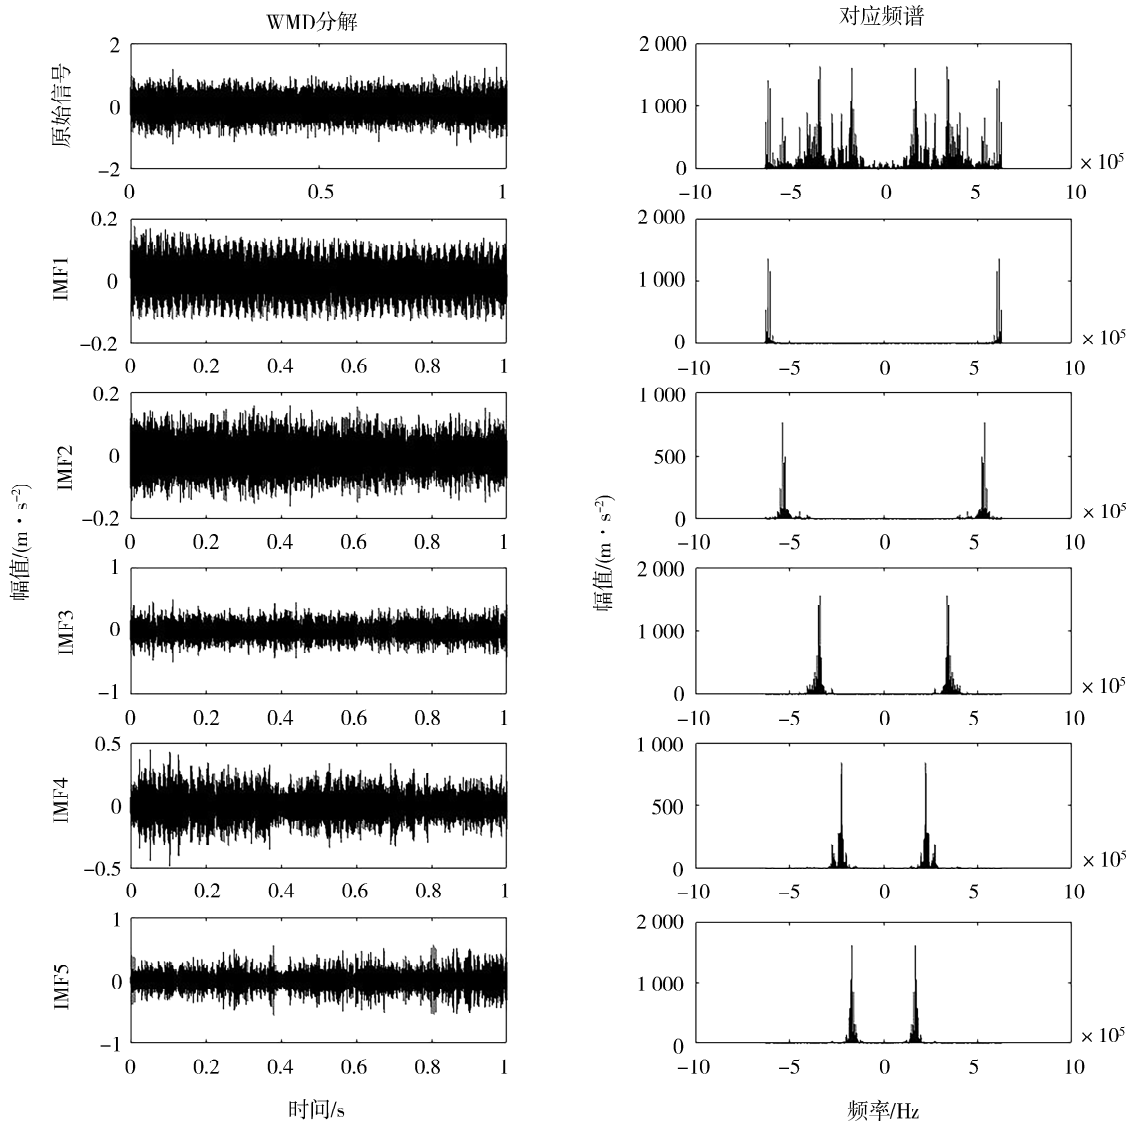


图 6 $K=5$ 时的 VMD 分解结果
Fig. 6 VMD decomposition result when $K=5$

5.1 特征选择

X、Y、Z 三个方向振动信号经 VMD 分解后,共得到 10 个 IMF 分量,提取每个 IMF 分量的 17 个时域特征与能量熵,所以总共得到 180 个特征。这些特征并非都与磨损量相关,为了避免不必要的计算,提高模型识别率,需要进行特征选择^[20],本文采用相关系数法与灰色关联度分析法进行特征选择。

相关系数(Correlation Coefficient)用于衡量变量之间关系密切程度,其中,皮尔逊相关系数广泛应用于衡量两个变量之间的线性关系^[21],其公式如下。

$$\rho_{X,Y} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)} \sqrt{E(Y^2) - E^2(Y)}} \quad (7)$$

式中, E 表示期望。 $|\rho_{X,Y}|$ 的取值范围为 $[0,1]$,相关系数越接近 1,说明 X、Y 线性相关性越好,反之,线性相关性越差。

灰色关联度分析(Grey Relation Analysis, GRA)是一种多因素统计分析方法^[22],其通过确定参考列和比较列的几何形状相似程度来衡量二者之间的关联程度,它反映了参考列与比较列非线性关系。假设比较列为 x_i ,参考列为 x_0 ,灰色关联系数为 $\zeta_i(k)$ 。

$$\zeta_i(k)=\frac{\min_i\min_k|x_0(k)-x_i(k)|+\rho\alpha_{\max}}{|x_0(k)-x_i(k)|+\rho\alpha_{\max}}\quad(8)$$

$$\alpha_{\max}=\max_i\min_k|x_0(k)-x_i(k)|\quad(9)$$

式中, ρ 为分辨系数, 一般取 0.5. 对每个维度进行计算, 得到一个新的序列, 这个序列中的每个点就代表着该子序列与母序列对应维度上的关联性. 根据灰色关联系数可得到关联度, x_i 与 x_0 的关联度

公式如下.

$$r_i=\frac{1}{n}\sum_{k=1}^n\zeta_i(k)\quad(10)$$

利用皮尔逊相关系数与灰色关联度分析特征向量与刀具磨损之间的相关性, 以皮尔逊相关系数大于 0.9 并且关联度大于 0.9 为标准对特征向量进行选择, 最终筛选出 16 个特征, 如表 2 所示.

表 2 特征选择结果

Tab. 2 Feature selection results

方向	特征选择结果
X 方向	IMF4 峰值、IMF4 最大值、IMF4 最小值
Y 方向	IMF1 峰值、IMF1 最大值、IMF1 最小值、IMF1 方根幅值、IMF1 方差、IMF1 标准差、IMF1 均值、IMF1 平均幅值、IMF1 能量熵
Z 方向	IMF1 能量熵、IMF2 方差、IMF2 标准差、IMF2 均值




图 7 部分特征随走刀次数变化

Fig. 7 Some features changing with moves

5.2 磨损状态识别

铣刀磨损数据共有 315 组, 分别包含球头铣刀 X、Y、Z 三个方向的磨损量, 本文取 X、Y、Z 三个方向磨损量的平均数作为铣刀的磨损值. 然后使用 K 均值聚类法将磨损状态分为 5 类, 第一类为 1~27; 第二类为 28~80; 第三类为 81~208; 第四类为 209~259; 第五类为 260~315. 随机选择数据样本的 80% 作为训练样本, 剩下 20% 作为测试样本, 并采用 5 折交叉验证法, 以避免模型过拟合与欠拟合. 运行 10 次, 取平均分类正确率为评价标准.

仿真实验在 MATLAB 2016a 平台上进行, 为了验证本文提出的算法的有效性, 分别采用 WOA 算法、GWO 算法、GSA 算法与 PSO 算法优化 LSSVM 作为对比, 仿真结果如表 3 所示.

表 3 实验仿真结果

Tab. 3 Experimental simulation results

算法	训练样本 平均正确率/%	测试样本 平均正确率/%
WOA 优化 LSSVM	97.2	95.1
GWO 优化 LSSVM	97.3	95.7
GSA 优化 LSSVM	95.4	92.9
PSO 优化 LSSVM	96.5	92.8
IWOA 优化 LSSVM	98.3	96.2

6 结 论

本文提出了一种 IWOA 算法优化 LSSVM 模型, 采用 VMD 方法对铣削振动信号进行分解, 提取 IMF 分量的时域特征与能量熵构成特征向量, 引入混合反向学习算法和非线性收敛因子对鲸鱼

算法进行改进,并采用 4 种基准测试函数验证了改进后的鲸鱼算法的性能,将其应用于铣刀磨损状态监测,识别结果与 WOA-LSSVM、GWO-LSSVM、GSA-LSSVM 和 PSO-LSSVM 模型对比.结果表明,IWOA-LSSVM 模型具有更高的识别精度,为铣刀磨损状态的在线监测提供了一种新方法.

参考文献:

- [1] 余臻,付江梦,刘利军.基于 FFT 的概率神经网络故障诊断模型[J].四川大学学报:自然科学版,2020,57:909.
- [2] Bhattacharyya P, Sengupta D, Mukhopadhyay S. Cutting force-based real-time estimation of tool wear in face milling using a combination of signal processing techniques [J]. Mech Syst Signal Pr, 2007, 21: 2665.
- [3] 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,2018,54:45.
- [4] Tönshoff H K, Wulfsberg J P, Kals H J J, *et al.* Developments and trends in monitoring and control of machining processes [J]. CIRP Ann-Manuf Techn, 1988, 37: 611.
- [5] Mehrabi M G, Koren A G U. Reconfigurable manufacturing systems; Key to future manufacturing [J]. J Intell Manuf, 2000, 11: 403.
- [6] 石朝.基于力和振动融合的刀具磨损状态辨识方法研究[D].成都:西南交通大学,2019.
- [7] 王利强,李绍朋,吕志杰.基于轮廓提取的刀具磨损量检测研究[J].制造技术与机床,2019,689:88.
- [8] Dimla D E. Sensor signals for tool-wear monitoring in metal cutting operations—a review of methods [J]. Int J Mach Tool Manu, 2000, 40: 1073.
- [9] Somkiat T, Haruetai L. Intelligent monitoring and prediction of tool wear in CNC turning by utilizing wavelet transform [J]. Int J Adv Manuf Tech, 2018, 99: 2219.
- [10] 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,2017,45:178.
- [11] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE T Signal Proces, 2014, 62: 531.
- [12] 李宏,李定文,朱海琦,等.一种优化的 VMD 算法及其在语音信号去噪中的应用[J].吉林大学学报:理学版,2021,59:1219.
- [13] 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,2020,39:135.
- [14] 关山,闫丽红,彭昶. LS-SVM 回归算法在刀具磨损量预测中的应用[J].中国机械工程,2015,26:217.
- [15] 左言言,宋文兵,陆怡,等.基于 LSSVM-样本熵的车内噪声声品质预测[J].江苏大学学报:自然科学版,2020,41:1.
- [16] 刘成颖,吴昊,王立平,等.基于 PSO 优化 LS-SVM 的刀具磨损状态识别[J].清华大学学报:自然科学版,2017,57:975.
- [17] Mirjalili S, Lewis A. The whale optimization algorithm [J]. Adv Eng Softw, 2016, 95: 51.
- [18] 孙二华,胡云冰.基于鲸鱼优化和深度学习的平衡大数据分类算法[J].西南师范大学学报:自然科学版,2021,46:127.
- [19] 牛培峰,吴志良,马云鹏,等.基于鲸鱼优化算法的汽轮机热耗率模型预测[J].化工学报,2017,68:1049.
- [20] 吴晓燕,刘笃晋.基于樽海鞘群与粒子群混合优化算法的特征选择[J].重庆邮电大学学报:自然科学版,2021,33:844.
- [21] Ying C, Dexing Y, Yuning G. Laser ultrasonic damage detection in coating-substrate structure via Pearson correlation coefficient [J]. Surf Coat Tech, 2018, 353: 339.
- [22] 刘思峰,党耀国,方志耕,等.灰色系统理论及其应用[M].5版.北京:科学出版社,2010:62.

引用本文格式:

中 文:张庆华,龙伟,李炎炎,等.基于鲸鱼算法优化 LSSVM 的铣刀磨损监测[J].四川大学学报:自然科学版,2022,59:012005.

英 文:Zhang Q H, Long W, Li Y Y, *et al.* Milling cutter wear monitoring based on whale algorithm optimized LSSVM [J]. J Sichuan Univ: Nat Sci Ed, 2022, 59: 012005.