

基于粒子群优化 LS-SVM 的车刀磨损量识别技术研究*

李威霖, 傅攀, 张尔卿

(西南交通大学机械工程学院, 成都 610031)

摘要: 刀具的磨损状态直接影响产品加工质量、成本和效率, 对刀具磨损量的实时监测识别具有重要意义。针对刀具磨损状态先验样本少和常规神经网络识别模型收敛速度慢、易陷入局部极小值等问题, 提出了基于最小二乘支持向量机 (LS-SVM) 的刀具磨损识别方法, 并针对支持向量机的惩罚因子和核参数对模型识别精度影响较大的问题, 提出一种根据个体适应度来调整惯性权重的自适应粒子群算法进行自动参数寻优。以车削加工为研究对象, 采集加工过程中的切削力信号, 应用小波包分析技术提取反映刀具磨损状态的特征信息作为识别模型的输入, 然后利用训练好的自适应粒子群算法优化后的 LS-SVM 识别模型进行刀具磨损量识别。实验结果表明, 该自适应粒子群优化算法比标准粒子群优化算法参数寻优能力更强; 粒子群优化 LS-SVM 模型能高效地实现刀具磨损量识别, 与 BP 神经网络相比具有更高的精度, 且所需样本数较少, 训练速度更快。

关键词: 刀具状态监测; 小波包分析; 粒子群优化; 最小二乘支持向量机

中图分类号: TP277 **文献标志码:** A **文章编号:** 1001-3695(2014)04-1094-04

doi:10.3969/j.issn.1001-3695.2014.04.033

Application of particle swarm optimization-least square support vector machine in tool wear monitoring

LI Wei-lin, FU Pan, ZHANG Er-qing

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Tool wear state directly affects the product quality, cost and efficiency. The real-time condition monitoring system for tool wear would be significant. The prior samples for monitoring model were limited, and the conventional neural networks recognition model had some drawbacks such running into local minimum value easily, slow convergence rate and so on. In view of these situations, it proposed a tool wear monitoring method based on least squares support vector machine (LS-SVM). Meanwhile, it proposed the adaptive particle swarm optimization (APSO) algorithm to search optimum value of the kernel function parameter and error penalty factor which affected the precision of the LS-SVM significantly. The cutting force signals were measured as monitoring signals. Features extracted by wavelet package decomposition as model inputs. Tool wear degree could be got by the trained APSO-LS-SVM model. The experiment result shows APSO algorithm can find the better parameters of LS-SVM model than standard PSO algorithm; APSO-LS-SVM carry out an accurate tool wear assessment, unlike BP neural networks, the algorithms have higher accuracy, faster learning ability and needs less training samples.

Key words: tool condition monitoring; wavelet packet analysis; particle swarm optimization; least squares support vector machine

0 引言

刀具智能状态监测技术是先进制造技术的重要组成部分, 刀具磨损监测作为其主要监测内容, 可以降低制造成本, 避免刀具过度磨损造成对工件加工表面质量和尺寸精度的影响, 在降低生产成本以提高劳动生产率、实现加工过程自动化等方面具有重要意义^[1-3]。国内外许多学者致力于刀具磨损在线监测和刀具剩余寿命预算方法的研究, 其中 Teti 等人^[3]与 Roth 等人^[4]分别从传感信号选择、信号处理与模式识别等角度总结了刀具磨损状态监测技术的发展现状。

刀具状态监测方法一般包括直接测量和间接测量两种。

间接测量法引入模式识别方法实现高准确率快速识别, 因而更有利于刀具磨损状态在线监测^[5]。本文采用基于三轴切削力的间接测量方式。刀具监测信号带有很强的背景噪声, 尤其是刀具早期磨损或故障时, 故障信息可能完全淹没在噪声中。采用小波分析方法可以有效地抑制信号噪声, 得到具有较高灵敏性的信号特征值^[2]。因此本文采用小波包频带能量特征提取技术提取信号特征信息。

目前刀具磨损状态的识别方法主要采用包括人工神经网络、聚类分析等传统模式识别方法^[3,4]。这些方法对先验学习样本的需求量大, 而在实际加工过程中, 传感器采集的信号受到加工要素、工件材料、刀具材料和尺寸等多种外界因素的影

收稿日期: 2013-06-13; **修回日期:** 2013-07-22 **基金项目:** 国家科技重大专项基金资助项目(2010ZX04015-011); 中央高校基本科研业务费专项基金资助项目(SWJTU12CX039)

作者简介: 李威霖(1986-), 男, 四川成都人, 博士, 主要研究方向为智能化状态监测与故障诊断 (weilin@my.swjtu.edu.cn); 傅攀(1961-), 男, 教授, 博士, 主要研究方向为设备故障诊断; 张尔卿(1984-), 男, 博士研究生, 主要研究方向为故障预测与健康管理。

响,在特定加工条件下获得的训练样本非常有限,因此必须解决小样本下的刀具磨损量识别问题。基于统计学习理论的支持向量机是一种专门研究小样本情况下的机器学习方法,它在很大程度上解决了模型选择、过学习和欠学习、局部最优解、维数灾难等问题^[6],广泛应用于设备故障诊断领域。最小二乘支持向量机(LS-SVM)算法作为 SVM 的改进算法,降低了模型求解时间与空间成本。文献[7~9]研究了其在刀具状态监测中的应用,但 LS-SVM 的惩罚因子和核参数取值对模型识别精度影响较大,不同参数下的刀具磨损量识别精度差别大,且其取值具有一定的盲目性。如何选择合适的 LS-SVM 参数用于刀具磨损量识别尤为关键。

粒子群优化算法是一种种群的随机优化方法,可以同时搜索待优化目标函数解空间中的较多区域,具有简单、快速、易实现等优点。诸多研究者将粒子群优化算法用于 LS-SVM 模型的参数选择中^[10~13],克服了人为参数选择的盲目性,在全局优化与收敛速度方面具有较大优势。但这些算法收敛速度较慢,且容易出现粒子早熟收敛现象。针对这个问题,本文在标准粒子群的基础上,采用自适应粒子群优化算法,粒子在迭代过程中根据个体适应度来调整惯性权重,使其在优化 LS-SVM 参数中更具优势,并将优化后的模型用于刀具磨损状态识别中。

1 粒子群优化 LS-SVM 基本理论

1.1 LS-SVM 基本原理

支持向量机模型可以有效地实现对基于小样本的高维非线性系统精确拟合,并且采用结构风险最小原则,具有很好的推广性。最小二乘支持向量机(LS-SVM)算法是标准 SVM 的变形,将 SVM 求解二次规划问题转换成求解线性方程组,避免采用不敏感损失函数,大大降低了计算的复杂性。

LS-SVM 算法的具体推导过程^[14]如下:

给定 N 个训练样本 $\{(x_i, y_i), \dots, (x_N, y_N)\}$, 其中 x_i 为 n 维的训练样本输入, y_i 为训练样本输出。

LS-SVM 算法的目标优化函数为

$$\left. \begin{aligned} J_1(\mathbf{w}, e) &= \frac{\mu}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 \\ \text{s. t. } y_i &= \mathbf{w}^T \varphi(x_i) + b + e_i, i=1, \dots, N \end{aligned} \right\} \quad (1)$$

其中: $\varphi(\cdot)$ 为核空间映射函数; $\mathbf{w}$ 为权矢量; e_i 为误差变量; b 为偏置量; μ, γ 为可调参数。

为求解函数的最小值,构造 Lagrange 函数:

$$L = J(\mathbf{w}, e) - \sum_{i=1}^N \alpha_i \{ \mathbf{w}^T \varphi(x_i) + b + e_i - y_i \} \quad (2)$$

其中: α_i 为拉格朗日乘子。

对式(1)求偏导可得

$$\left. \begin{aligned} \frac{\partial L}{\partial \mathbf{w}} &= 0 \rightarrow \mathbf{w} = \sum_{i=1}^N \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial b} &= 0 \rightarrow \sum_{i=1}^N \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} &= 0 \rightarrow \alpha_i = \gamma e_i \\ \frac{\partial L}{\partial \alpha_i} &= 0 \rightarrow \mathbf{w}^T \varphi(x_i) + b + e_i - y_i \end{aligned} \right\} \quad (3)$$

其中: $i=1, \dots, N$ 。

通过消去 $\mathbf{w}$ 和 e , 求解的优化问题转换为求解线性方程:

$$\begin{bmatrix} 0 & \mathbf{1}_v^T \\ \mathbf{1}_v & \Omega + \frac{1}{\gamma} I_N \end{bmatrix} \times \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (4)$$

其中: $y = [y_1, \dots, y_N]$, $\mathbf{1}_v = [1, \dots, 1]$, $\alpha = [\alpha_1, \dots, \alpha_N]$, $\Omega = \varphi(x_i)^T \varphi(x_i) = K(x_i, x_i)$, $i, l=1, \dots, N$ 。

通过求解式(4)可以得到 α 和 b , 那么用于函数估计的 LS-SVM 为

$$y(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (5)$$

其中: $K(x, x_i)$ 为核函数, 本文采用径向基核函数。

$$K(x_i, x_j) = \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right) \quad \sigma > 0 \quad (6)$$

基于径向基核函数的 LS-SVM, 需确定惩罚因子 γ 和核参数 σ 两个参数。

1.2 自适应粒子群优化基本原理

粒子群优化算法是由 Kennedy^[15]提出的一种基于迭代的演化算法。粒子群算法的数学描述如下:

假设在一个 D 维的搜索空间内, 由 N 个粒子组成一个群体 $x = (x_1, x_2, \dots, x_N)$ 。其中, 第 i 个粒子的位置表示为向量 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, $i=1, 2, \dots, N$; 其速度也是一个 D 维的向量, 记 $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$; 第 i 个粒子到目前为止搜索到的最优位置称为个体极值, 记 $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$; 整个粒子群到目前为止搜索到的最优位置称为全局极值, 记 $\mathbf{p}_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 。在找到这两个极值后, 粒子通过式(7)~(9)来更新其速度和位置, 即

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t)) \quad (7)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (8)$$

$$\begin{cases} v_{id} = v_{\max} & v_{id} > v_{\max} \\ v_{id} = -v_{\max} & v_{id} < -v_{\max} \end{cases} \quad (9)$$

式中: c_1, c_2 是非负数, 被称为学习因子或加速常数, 取值范围一般为 $[0, 2]$; r_1, r_2 为介于 $(0, 1)$ 内相互独立的随机函数; $v_{id}(t), x_{id}(t)$ 分别是粒子 i 于第 t 次迭代中第 d 维度的速度和位置, 是粒子 i 于第 d 维度个体极值的位置; p_{gd} 是群体在第 d 维度全局极值的位置。

ω 为惯性权重。实验研究表明: ω 对 PSO 算法的收敛性影响大, 较小时其局部寻优性能强; 较大时其全局寻优性能强。所以, 惯性权重具有平衡全局与局部寻优能力。

惯性权重 ω 取值方式一般有固定式和动态式。固定式是采用给定常数作为权重, 该方式下, 粒子寻优迭代中惯性权重保持不变, PSO 寻优性能相当, 也称做标准粒子群优化算法; 动态式是指在寻优过程中自适应地变化权重, 使其在不同迭代步骤中具有不同寻优性能。本文采用自适应的惯性权重取值方式, 更新方程定义为

$$\omega = \begin{cases} \omega_{\min} - \frac{(\omega_{\max} - \omega_{\min}) \times (f - f_{\min})}{(f_{\text{avg}} - f_{\min})} & f \leq f_{\text{avg}} \\ \omega_{\max} & f > f_{\text{avg}} \end{cases} \quad (10)$$

式中: $\omega_{\max}, \omega_{\min}$ 为 ω 的最大值和最小值; $f, f_{\text{avg}}, f_{\min}$ 表示当前粒子的适应度值、适应度的平均值和最小值。

从上述非线性的自适应惯性权重公式可以看出, 惯性权重是跟随粒子的目标函数适应度的变化而不断自动改变, 如果当前粒子的目标函数值不大于平均值时, 则表示目标值趋于一致或局部最优, 惯性权重将增大, 使得粒子向好的搜索区域靠近; 如果当前粒子的目标函数值大于平均值时, 则表示粒子较为分散, 惯性权重将减小, 从而保护了该粒子。

1.3 自适应粒子群优化 LS-SVM 算法

本文提出运用粒子群优化算法对 LS-SVM 中的正则化参

数 γ 和核函数宽度 σ 进行自动调整,以达到最佳组合值,使刀具磨损量识别精度更高。

假设已建立了系统的样本集 $\{(x_i, y_i), \dots, (x_N, y_N)\}$, PSO 优化 LS-SVM 过程中的 LS-SVM 模型的优劣采用平均绝对预测误差 (MAE) 来衡量:

$$f = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (11)$$

式中: y_i 为已知样本输出; y'_i 为 LS-SVM 的预测输出,即模型输出值。

如果在 PSO 优化过程中直接采用 MAE 作为适应度值,会造成优化结果为当前训练集的最佳回归拟合,但是模型也会因此变得泛化能力很差,没有实用价值。为了提高算法的泛化性能,本文在参数优化时采用了交叉验证 (cross validation, CV) 中的留一验证思想,即在 PSO 的每次迭代过程中,对当前 γ 和 σ 所确定的 LS-SVM 进行交叉验证,将交叉验证的平均 MAE 作为 PSO 迭代的适应度值。

留一验证是交叉验证的一种常用方式,使用原始样本中的一项目来做测试集,而剩余的则留下来当做训练集。这个步骤一直持续到每个样本都被当做一次测试集。该方法有两个明显的优点:每一回合中几乎所有的样本皆用于训练模型,因此最接近原始样本的分布,这样评估所得的结果比较可靠;实验过程中没有随机因素会影响实验数据,确保实验过程是可以被复制的。基于粒子群优化 LS-SVM 算法的刀具磨损量识别步骤如下:

a) 准备模型训练数据,将刀具状态监测的归一化特征作为 LS-SVM 模型输入数据,刀具磨损量大小作为输出。

b) 初始化 PSO 算法参数,包括群体规模 N 、学习因子 c_1 和 c_2 、最大迭代次数、惯性权重的最大值 $\omega_{\max}$ 与最小值 $\omega_{\min}$ 、初始化惯性权重、粒子的初始速度 v_{id} 和位置 x_{id} 。

c) 将 LS-SVM 的正则化参数 γ 和核函数宽度平方 σ^2 作为每个粒子的二维坐标,根据训练数据训练 LS-SVM,并进行留一交叉验证,计算粒子的适应度 f 。

d) 对每个粒子,将适应度 $f(x_i)$ 与自身最优值进行比较,更新其自身最好适应值;将每个粒子的最好适应值与全局最好值进行比较,更新种群的全局最好适应值。

e) 按式 (7) ~ (9) 更新粒子速度 v_{id} 及位置 x_{id} 。

f) 按式 (10) 更新惯性权重 ω ,并更新计算适应度的平均值 f_{avg} 和最小值 $f_{\min}$ 。

g) 判断是否满足结束条件,若满足则输出最佳分类精度,若不满足则跳转到步骤 b)。一般设定结束条件为到达最大迭代次数或适应度小于给定精度。

h) 选出最优化参数 γ 和 σ^2 ,建立 LS-SVM 识别模型。

i) 利用模型进行磨损量识别。

2 刀具磨损监测实验及特征提取

2.1 刀具磨损监测实验

实验在 CK6143 铣削加工中心进行。实验过程使用工控机、力传感器、数控机床等构建了一个自动测控系统。监测的信号通过放大器处理后,经过 A/D 转换送入工控机进行相应的计算和处理,计算机给出刀具磨损识别结果。

力传感器为瑞士 Kistler 公司生产的 Kistler 9257B 测力仪,采样频率为 10 KHz。传感器由三个圆形压电晶体板组成,以实现三向切削力的准确测量。传感器安装图如图 1 所示。实

验材料为奥氏体不锈钢 304 L,长度为 254 mm;刀具为肯纳 KC5010 车刀片。为了加快刀具磨损速度,采用均匀设计方法设计如表 1 所示的切削条件。采用表 1 的切削条件对四把车刀进行全寿命磨损实验。实验中为了方便,每一走刀结束后进行一次磨损量测量,故文中采用走刀数来衡量切削时间的大小。

表 1 刀具磨损监测实验的工况

组号	切削速度/m/min	背吃刀量/mm	进给量/mm/r
1	180	1.6	0.29
2	210	1.8	0.33
3	240	1.4	0.13
4	260	1.2	0.17




图 1 刀具磨损监测系统安装图

2.2 小波频带能量敏感特征提取

在加工过程中,切削材料的非均匀、加工过程的复杂性,导致采集的动态信号具有很大的非平稳性。基于多分辨率分析的小波包分析能在非平稳成分中提取能反映刀具磨损状态变化的特征信息。以第一组实验为例,图 2 绘出了其 X 轴切削力监测信号的时域图。




图 2 切削力信号时域波形图

从图 2 可知,从时域很难分辨出不同状态下切削力信号的区别,需要进一步处理。本文对切削力信号采用 db9 小波基进行五层小波包分解,大于 3 000 Hz 的频率成分认为是噪声,故仅取前 16 个频带作为刀具磨损状态监测特征。因此,用于反映刀具磨损状态的监测特征值是一个 48 维的向量。

3 刀具磨损监测模型建立

下文以第一组实验为例介绍粒子群优化 LS-SVM 模型建立过程。在第一组实验条件下,车刀经过 72 次切削后,磨损量达到 0.19 mm,其磨损曲线如图 3 所示。




图 3 刀具磨损曲线

采用上文特征提取方法提取切削力信号的特征向量,图 4 绘出了第一组实验的 X 轴切削力的前四个归一化频带特征

值。从图4可见特征值与刀具磨损量存在复杂的非线性关系,需要建立特征向量与刀具磨损量的识别模型。本文研究基于粒子群优化的 LS-SVM 模型。




图4 归一化刀具状态监测频带能量特征

为了体现方法的优越性,等间隔取其中32个磨损状态,每个磨损量下的4个重复样本的归一化特征向量用于模型训练。各个状态下的磨损量数值作为 LS-SVM 的目标输出。

确定了训练数据后,进行粒子群优化算法的初始化工作。进化次数为150;种群规模为30; γ 的最大化值和最小值为1000和0.1;迭代速度范围为 $[-0.2 \times 1000, 0.2 \times 1000]$; σ^2 最大化值和最小值分别为300和0.1;迭代速度范围为 $[-0.2 \times 300, 0.2 \times 300]$ 。

下面分别讨论自适应权重及固定惯性权重下的粒子群优化 LS-SVM 刀具磨损识别模型建立。实验表明, ω 在 $[0.8, 1.2]$ 之间 PSO 有更快的收敛速度,将 ω 设置为从0.8~0.4的线性下降使得 PSO 在开始时探索较大的区域,较快地定位最优解的最大位置;随着 ω 逐渐减小,粒子速度减慢,开始精细的局部搜索。因此,惯性权重固定时,设其值为 $\omega = 0.8$;自适应权重时,设其最大值和最小值分别为0.8、0.4;经过150次迭代,在学习因子 c_1 和 c_2 取不同数值情况下,优化结果如表2所示。

表2 不同学习因子下的粒子群优化结果

	标准粒子群优化			
	$c_1=2$ $c_2=2$	$c_1=2$ $c_2=1$	$c_1=1$ $c_2=2$	$c_1=1$ $c_2=1$
γ	155.380	121.330	157.737	139.839
σ^2	11.804	10.978	10.648	10.821
MAE(10^{-3})	4.0733	4.0685	4.0741	4.0710
	自适应粒子群优化			
	$c_1=2$ $c_2=2$	$c_1=2$ $c_2=1$	$c_1=1$ $c_2=2$	$c_1=1$ $c_2=1$
γ	118.711	129.276	118.184	120.322
σ^2	11.151	11.144	11.126	11.133
MAE(10^{-3})	4.0661	4.0674	4.0664	4.0662

从表2可知,不同学习因子对优化最终结果影响不大;自适应粒子群优化算法所得参数的交叉验证误差比标准优化算法更小。

图5绘出了两种算法迭代过程中适应度的变化曲线。从图5可知,在相同迭代步数下,本文的自适应优化算法比标准粒子群优化算法所得误差更小、收敛速度更快,提高了 PSO 算法的性能。

根据上述优化结果,先用误差最小的一组参数作为最终优化参数 $\gamma = 118.711$, $\sigma^2 = 11.151$ 。为了验证粒子群优化 LS-SVM 模型的泛化能力和识别精度,将上述训练数据和优化所得参数用于建立 LS-SVM 磨损量识别模型;并利用第一组实验的全部72走刀数据(每走刀10个样本),一共720个样本,用做测试样本,测试模型的有效性。




图5 不同粒子群优化算法的适应度变化曲线

同时,为了展示粒子群优化 LS-SVM 模型相对于常规神经网络的优越性,此处将其与常用的 BP 神经网络识别结果进行对比。采用48-97-1的三层 BP 网络结构:隐藏神经元个数为97个;训练输出刀具的磨损量,维数为1。

采用相同的训练样本和测试样本,得到粒子群优化 LS-SVM 模型及 BP 神经网络模型的刀具磨损量识别结果如图6和图7所示。




图6 刀具磨损量的 LS-SVM识别结果




图7 刀具磨损量的 BP网络识别结果

从图6、7可知,粒子群优化 LS-SVM 模型的全部测试样本的总磨损量识别误差为6.2525 mm,BP神经网络总识别误差为9.7557 mm;LS-SVM 识别结果波动性较 BP 神经网络小,在刀具正常磨损阶段尤为明显。对其他三个工况的磨损状态监测可得到相同效果,因此,本文方法的识别精度明显优于传统神经网络。

4 结束语

最小二乘支持向量机(LS-SVM)具有很强的学习能力和良好的泛化性能,能较好地解决小样本非线性及局部极小值问题,为刀具磨损状态监测提供了新途径,但其识别精度受模型参数影响较大。粒子群算法作为一种仿生智能算法,具有并行性好、鲁棒性强和全局搜索等特点。本文在标准粒子群优化算法的基础上,提出基于自适应粒子群优化 LS-SVM 的刀具磨损量识别方法。以车削加工为研究对象,选择切削力为监测信号,采用小波包分解技术提取信号特征,从刀具全寿命实验的监测结果可得如下结论:

a) LS-SVM 惩罚因子和核参数对刀具磨损量识别结果有较大影响,通过粒子群优化算法进行自动产生寻优,克服了 LS-SVM 磨损量识别模型参数选择的盲目性,本文的自适应粒子群优化算法比标准粒子群算法参数寻优能力更强。

b) 粒子群优化 LS-SVM 方法用于刀具磨损量识别在实例计算中优于 BP 神经网络方法。

c) 基于粒子群优化 LS-SVM 刀具磨损量 (下转第1101页)

地对观测数据进行监控。

参考文献:

- [1] JACKSON J E. A user's guide to principal components[M]. New York: Wiley, 1991.
- [2] KOURTI T, MACGREGOR J F. Process analysis, monitoring and diagnosis, using multivariate projection methods[J]. *Chemometrics and Intelligent Laboratory Systems*, 1995, 28(1): 3-21.
- [3] WANG X Z. Data mining and knowledge discovery for process monitoring and control [C]//Advances in Industrial Control. London: Springer, 1999: 1-251.
- [4] NOMIKOS P, MACGREGOR J F. Monitoring batch processes using multiway principal component analysis[J]. *American Institute of Chemical Engineers Journal*, 1994, 40(8): 1361-1375.
- [5] NOMIKOS P, MACGREGOR J F. Multi-way partial least squares in monitoring batch processes[J]. *Chemometrics and Intelligent Laboratory Systems*, 1995, 30(1): 97-108.
- [6] NOMIKOS P, MACGREGOR J F. Multivariate SPC charts for monitoring batch processes[J]. *Technometrics*, 1995, 37(1): 41-59.
- [7] YU Jie, QIN S J. Multi-way Gaussian mixture model based multiphase batch process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2009, 48(18): 8585-8594.
- [8] ZHAO Chun-hui, WANG Fu-li, MAO Zhi-zhong, et al. Improved batch process monitoring and quality prediction based on multiphase statistical analysis[J]. *Industrial & Engineering Chemistry Research*, 2008, 47(3): 835-849.
- [9] ZHAO C, WANG F. Adaptive monitoring method for batch processes based on phase dissimilarity updating with limited modeling data[J]. *Industrial & Engineering Chemistry Research*, 2007, 46(14): 4943-4953.
- [10] CAMACHO J, PICO J. Multi-phase principal component analysis for batch processes modeling[J]. *Chemometrics and Intelligent Laboratory Systems*, 2006, 81(2): 127-136.
- [11] YU Jie. Nonlinear bioprocess monitoring using multiway kernel localized Fisher discriminate analysis[J]. *Industrial and Engineering Chemistry Research*, 2011, 50(6): 3390-3402.
- [12] TIAN Xue-min, ZHANG Xiao-ling, DENG Xiao-gang, et al. Multiway kernel independent component analysis based on feature samples for batch process monitoring[J]. *Neurocomputing*, 2009, 72(7~9): 1584-1596.
- [13] ZHANG Ying-wei, ZHOU Hong, QIN S J. Decentralized fault diagnosis of large-scale process using multi block kernel principal component analysis[J]. *Acta Automatica Sinica*, 2010, 36(4): 593-597.
- [14] ZHAO Chun-hui, GAO Fu-rong, WANG Fu-li. Nonlinear batch process monitoring using phase-based kernel-independent component analysis-principal component analysis (KICA-PCA) [J]. *Industrial and Engineering Chemistry Research*, 2009, 48(20): 9163-9174.
- [15] YANG Jian, ZHANG D, FRANGI A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2004, 26(1): 131-137.
- [16] 韩柯, 朱秀昌. 基于二维PCA的人脸识别方法研究[J]. *杭州电子科技大学学报*, 2007, 27(1): 69-72.
- [17] 李艳芳, 费洪晓. 基于2DGabor小波与2DPCA的人脸识别方法[J]. *湖南科技学院学报*, 2008, 29(8): 72-74.
- [18] 袁宁, 吴小俊, 王士同, 等. 一种模块化2DPCA和CSLDA相结合的人脸验证算法[J]. *计算机研究与发展*, 2008, 30(3): 286-289.
- [19] 吴清江. 一种基于2D-DWT和2D-PCA的人脸识别方法[J]. *计算机应用*, 2006, 26(9): 59-78.

(上接第1097页)识别方法具有需求训练样本少、训练时间短、诊断速度快等优点,为小样本下的刀具磨损状态在线监测与剩余寿命预测提供了有效的解决方案,具有较高实用价值。

d) 刀具磨损量识别精度还取决于学习样本的代表性,随着学习样本数量的增加,预测精度将进一步提高。针对时序监测结果波动性大的问题,可以考虑对时序观察结果进行滤波。

参考文献:

- [1] Jr VALLEJO A G, NOLAZCO-FLORES J A, MORALES-MENENDEZ R, et al. Tool-wear monitoring based on continuous hidden Markov models[C]//Proc of the 10th Iberoamerican Congress Conference on Progress in Pattern Recognition, Image Analysis and Applications. Berlin: Springer, 2005: 880-890.
- [2] LI Wei-lin, FU Pan, CAO Wei-qing. Tool wear states recognition based on frequency-band energy analysis and fuzzy clustering[C]//Proc of the 3rd International Workshop on Advanced Computational Intelligence. 2010: 162-167.
- [3] TETI R, JEMIELNIAK K, O'DONNELL G, et al. Advanced monitoring of machining operations[J]. *CIRP Annals-Manufacturing Technology*, 2010, 59(2): 717-739.
- [4] ROTH J T, DIURDIANOVIC D, YANG Xiao-ping, et al. Quality and inspection of machining operations; tool condition monitoring[J]. *Journal of Manufacturing Science and Engineering*, 2010, 132(4): 1-16.
- [5] SNR D, DIMLA E. Sensor signals for tool-wear monitoring in metal cutting operations: a review of methods[J]. *International Journal of Machine Tools and Manufacture*, 2000, 40(8): 1073-1098.
- [6] 王国锋, 李启铭, 秦旭达, 等. 支持向量机在刀具磨损多状态监测中的应用[J]. *天津大学学报*, 2011, 44(1): 35-39.
- [7] 关山, 王龙山, 聂鹏. 基于EMD与LS-SVM的刀具磨损识别方法[J]. *北京航空航天大学学报*, 2011, 37(2): 144.
- [8] SHI Dong-feng, GINDY N N. Tool wear predictive model based on least squares support vector machines[J]. *Mechanical Systems and Signal Processing*, 2007, 21(4): 1799-1814.
- [9] WIDODO A, YANG B S. Support vector machine in machine condition monitoring and fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2007, 21(6): 2560-2574.
- [10] 李文元, 闫海华, 姚宏杰. 粒子群优化的最小二乘支持向量机在通信装备故障预测中的应用[J]. *微电子学与计算机*, 2013, 30(2): 99-102.
- [11] 姚全珠, 蔡婕. 基于PSO的LS-SVM特征选择与参数优化算法[J]. *计算机工程与应用*, 2010, 46(1): 134-136.
- [12] 宋宏耀, 宋宏兵, 崔秀政. 基于PSO优化最小二乘支持向量机的热工系统辨识[J]. *电力科学与工程*, 2009, 25(10): 43-46.
- [13] 李文莉, 李郁侠. 基于粒子群最小二乘支持向量机的水文预测[J]. *计算机应用*, 2012, 32(4): 1188-1190.
- [14] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers[J]. *Neural Processing Letters*, 1999, 9(3): 293-300.
- [15] KENNEDY J, EBERHART R. Particle swarm optimization[C]//Proc of International Conference on Neural Networks. 1995: 1942-1948.