DOI: 10.3901/JME.2015.20.001

基于支持向量机的颤振在线智能检测*

钱士才 孙宇昕 熊振华

(上海交通大学机械系统与振动国家重点实验室 上海 200240)

摘要: 为了检测车削过程中的颤振, 提出一种颤振在线智能检测方法。使用最小二乘一类支持向量机, 训练出描述特征矢量集的超球面, 通过计算被测样本与超球面的距离来判断其是否颤振。基于相干准则和分块矩阵求逆, 构造了在线稀疏结构的最小二乘一类支持向量机, 将特征信息存储于特征库(字典)中, 通过更新特征库实现检测模型的在线进化。在颤振检测的应用中, 首先使用小波包分解, 得到第三层节点能量的比例作为特征矢量, 以离线数据构造特征矢量作为输入, 训练得到初始检测模型以及特征库, 在线检测中不断更新特征库, 实现检测模型的在线进化。试验结果表明, 在车削颤振识别中, 在线进化的检测模型的识别效果更好, 颤振预报准确率高达至 99.04%, 优于离线模型的预报准确率 96.74%。

关键词: 颤振; 最小二乘; 相干准则; 在线进化; 特征库

中图分类号: TH17; TP181

Support Vector Machine Based Online Intelligent Chatter Detection

QIAN Shicai SUN Yuxin XIONG Zhenhua

(State Key Laboratory of Mechanical System and Vibration, Shanghai Jiao Tong University, Shanghai 200240)

Abstract: In order to detect chatter in the process of turning, an online intelligent chatter detection method is proposed. In this method, least squares one class support vector machine(LS-OC-SVM) is used to extract a hyper plane as an optimal description of training objects. Chatter is detected by computing the distance between the sample to be tested and the hyper plane. Sparse online LS-OC-SVM is proposed based on coherence criterion and partitioned matrix inversion, so that features information can be stored in the feature library which is also called dictionary. The detection model can be evolved continuously through the online update of feature library. In the application of chatter detection, firstly, feature vector is constructed for chatter detection based on node energy ratios of the third level of wavelet packet decomposition. Then, initial detection model and feature library are trained by using offline feature vectors as input. In the online detection scheme, the detection model is evolved while feature library is updated. The experimental results show that the online evolution model performs better than offline model in the cutting chatter detection. Chatter detection accuracy of the online evolution model is 99.04%, which is better than offline model whose detection accuracy is 96.74%.

Key words: chatter; least squares; coherence criterion; online evolution; feature library

0 前言

切削颤振是机床闭环切削系统的动态不稳定现象,它是发生在切削刀具与工件之间的剧烈振动。颤振的发生会影响生产效率以及加工质量,同时还可引起过度噪声,刀具损坏等,对产品质量、刀具及机床设备等的危害已毋庸置疑。随着现代制造业向高度自动化和精密化方向发展的不断深入,妥善解决加工过程中引发的颤振问题,发展切削颤振的控制技术已成为生产工程界广泛关注的热点之

—[1-2]。

为了有效地控制颤振,很多学者做过颤振控制方面的研究,如可变的阻尼^[3]或开放式控制器^[4],然而有效颤振控制必须依靠可靠的颤振检测。由于机床主轴磨损,工作温度变化,工件刚度变化等因素导致加工过程的是非平稳的,因此,在线的颤振检测就更加重要。很多学者做过颤振检测方面的研究,主要可分为以下三类:第一类是信号频率域的分析^[5-7],如傅里叶变换,小波分解和希尔伯特变换等;第二类是统计学方法^[8-10],如排列熵、近似熵等,这类方法中熵的计算具有较高的计算复杂度。第三类是模式识别方法^[11-13],主要有神经网络、案例推理、支持向量机等,这种方法将颤振问题转

* 国家重点基础研究发展计划资助项目(973 计划, 2013CB035804)。20141015 收到初稿, 20150413 收到修改稿

化为分类问题,可利用多个特征综合判断颤振的发生,同时这类方法易将人工智能理论引入到颤振检测中,使检测系统具有自适应能力。然而这类方法很难实现在线检测,对这类智能方法的在线策略进行深入研究十分必要。

一类支持向量机 (One class support vector machine, OC-SVM)由 TAX 等^[14]提出的一种单值分类方法,也叫支持向量数域描述(Support vector data description, SVDD),其在小样本,非线性分类中有明显的优势,有效地解决神经网络中过学习的问题。OC-SVM 的基本思想是把要描述的对象作为一个整体,建立一个封闭而紧凑的区域,使被描述的对象全部或尽可能多地包容在该区域内。只需要正常样本数据,而不需要故障样本数据。由于故障检测中确定的故障样本数据很难获得,故 OC-SVM 在机械部件的故障检测中有广泛的应用。PAN 等^[15]基于提升小波变换将 SVDD 应用于轴承部件的性能分析中,根据数据集的边界构造了 HI 指标参数。WANG 等^[16]基于 SVDD 的增量式训练模型提出了机械故障在线检测框图,使检测模型实时更新,并使用网格搜索法优化核函数参数。ZHU 等^[17]使用把粗糙集和 SVDD 结合起来使用,并构造增量式算法来在线评估轴承性能。

由于 OC-SVM 在故障检测中有明显优势,这类方法在颤振检测已有应用,YAO 等^[11]使用小波包分解后第三层能量的混乱度和方差构造特征矢量,训练 SVM 模型进行加工状态分类。吴石等^[18]使用 SVDD 分别构造稳定、颤振孕育和颤振三个超球模型,使用距离来判断被测数据属于哪一类。尽管其成功应用,但存在三个问题。

(1) 应用于颤振检测的 SVM 均是离线训练,模型不能实时更新,只反应一个历史时刻的系统状态,不能实时反应加工状态的变化。

(2) 模型训练需要精确标签的样本,一般文献中训练 SVM 模型需要人工给定训练样本的类别,这种标签的给定依靠人为识别,不具有智能性。

(3) 虽然已有 OC-SVM 应用于一些在线检测,但其没有考虑 OC-SVM 的训练时间,难以达到实时性要求,检测模型的进化更新也缺乏关注。

本文基于最小二乘结构的一类支持向量机 (Least squares one class support vector machine, LS-OC-SVM)^[19]构造了颤振在线智能检测系统。使用稳定车削加工数据训练 LS-OC-SVM 模型,构造一个超球面,将颤振看成加工过程中出现的异常点,使用距离来判断颤振。结合 LS-OC-SVM 的求解特点,提出了增量式在线更新方法,比传统的

OC-SVM 计算效率更高,保证在线检测的实时性要求。同时,基于相干准则构造数集的字典,通过字典控制在线模型的复杂度。随着时间推进,不断更新数集的字典从而更新颤振检测模型,使检测模型根据环境的变化而改变,从而有更高的颤振预报准确率。

1 数学基础

1.1 最小二乘一类支持向量机

LS-OC-SVM 是在最小二乘的意义下得到描述未知数据集的超平面,假设现有输入数据集 $\mathbf{X}=\{\mathbf{x}_i|i=1, 2, \dots, n\}$, 并定义一个非线性映射 $\phi(\cdot)$, 将输入空间数据 $\mathbf{x}_i$ 映射到特征空间 $\mathbf{Z}$, 使用核函数代替特征空间的内积,即 $\kappa(\mathbf{x}_i, \mathbf{x}_j)=\langle\phi(\mathbf{x}_i), \phi(\mathbf{x}_j)\rangle$ 。特征空间内的超平面可表达为

$$f(\mathbf{x})=\langle\boldsymbol{\omega}, \phi(\mathbf{x})\rangle-\rho \quad (1)$$

式中, $\boldsymbol{\omega}$ 和 ρ 是待确定的参数。相应的优化问题可表达为

$$\begin{aligned} \min J(\boldsymbol{\omega}, \rho) &= \frac{1}{2}\|\boldsymbol{\omega}\|^2 - \rho + \frac{1}{2}C\sum_{i=1}^n \xi_i^2 \\ \text{s.t. } \langle\boldsymbol{\omega}, \phi(\mathbf{x}_i)\rangle &= \rho - \xi_i, \quad i=1, 2, \dots, n \end{aligned} \quad (2)$$

式中, ξ_i 是松弛变量, C 是对松弛变量的惩罚系数。其相应的拉格朗日方程为

$$L(\boldsymbol{\omega}, \rho, \xi_i, \alpha_i) = J - \sum_{i=1}^n \alpha_i (\langle\boldsymbol{\omega}, \phi(\mathbf{x}_i)\rangle - \rho + \xi_i) \quad (3)$$

式中, α 是拉格朗日乘子,可表示为 $\alpha=(\alpha_1, \alpha_2, \dots, \alpha_n)^T$ 。对式(3)中各个优化分量求偏导数,并令偏导数为 0,可以得到

$$\begin{cases} \frac{\partial L}{\partial \boldsymbol{\omega}} = 0 & \Rightarrow \boldsymbol{\omega} = \sum_{i=1}^n \alpha_i \phi(\mathbf{x}_i) \\ \frac{\partial L}{\partial \xi_i} = 0 & \Rightarrow C\xi_i = \alpha_i \\ \frac{\partial L}{\partial \rho} = 0 & \Rightarrow \sum_{i=1}^n \alpha_i = 1 \\ \frac{\partial L}{\partial \alpha_i} = 0 & \Rightarrow \boldsymbol{\omega}^T \phi(\mathbf{x}_i) - \rho + \xi_i = 0 \end{cases} \quad (4)$$

消去式(4)中的 ξ_i 和 $\boldsymbol{\omega}$ 可得

$$\begin{pmatrix} 0 & \mathbf{e}^T \\ \mathbf{e} & \mathbf{K} + \frac{1}{C}\mathbf{I} \end{pmatrix} \begin{pmatrix} -\rho \\ \boldsymbol{\alpha} \end{pmatrix} = \begin{pmatrix} \mathbf{I} \\ \mathbf{0} \end{pmatrix} \quad (5)$$

式中, $\mathbf{K}$ 是 $n \times n$ 维正定的核函数矩阵(Gram 矩阵),且 $K_{ij}=\kappa(\mathbf{x}_i, \mathbf{x}_j)$; $\mathbf{I}$ 是与 $\mathbf{K}$ 同维的单位阵; $\mathbf{e}$ 和 $\mathbf{0}$ 分别是 n 维全 1 和全 0 的列矢量。求解式(5)可以得到超平面方程为

$$f(\mathbf{x}) = \sum_{i=1}^n \alpha_i \kappa(\mathbf{x}, \mathbf{x}_i) - \rho = 0 \quad (6)$$

被测样本 $\mathbf{x}$ 到超平面的距离为

$$r(\mathbf{x}) = \frac{|f(\mathbf{x})|}{\|\boldsymbol{\alpha}\|} = \frac{|\sum_{i=1}^n \alpha_i \kappa(\mathbf{x}, \mathbf{x}_i) - \rho|}{\|\boldsymbol{\alpha}\|} \quad (7)$$

式中, $r(\mathbf{x})$ 可作为故障检测指标^[19], 距离绝对值越大, 表明被测样本与训练样本的相似程度越低, 训练样本的最大距离可作为超平面的近似半径^[20]。

1.2 LS-OC-SVM 增量求解

在线训练中, 训练样本数据会不断增加。假设当前时刻 t 有 n 个训练样本, 通过分块矩阵求逆可得到式(5)的解, 即

$$\begin{pmatrix} -\rho_n & \boldsymbol{\alpha}_n \end{pmatrix} = \begin{pmatrix} 1 & \mathbf{H}_n^{-1} \mathbf{e} \\ \mathbf{e}^T \mathbf{H}_n^{-1} \mathbf{e} & \mathbf{e}^T \mathbf{H}_n^{-1} \mathbf{e} \end{pmatrix} \quad (8)$$

对于时刻 $t+1$, 新增一个样本 $\mathbf{x}_{n+1}$, 此时若仍按照式(8)计算, 则需要计算逆矩阵 $\mathbf{H}_{n+1}^{-1}$, 计算量大, 不能满足实时性要求。通过分块矩阵求逆公式可实现逆矩阵的在线增量式计算

$$\mathbf{H}_{n+1}^{-1} = \begin{pmatrix} \mathbf{H}_n & \boldsymbol{\kappa}_{n+1} \\ \boldsymbol{\kappa}_{n+1}^T & \kappa_{n+1} + \frac{1}{C} \end{pmatrix}^{-1} = \begin{pmatrix} \mathbf{H}_n^{-1} + \mathbf{H}_n^{-1} \boldsymbol{\kappa}_{n+1} B^{-1} \boldsymbol{\kappa}_{n+1}^T \mathbf{H}_n^{-1} & -\mathbf{H}_n^{-1} \boldsymbol{\kappa}_{n+1} B^{-1} \\ -B^{-1} \boldsymbol{\kappa}_{n+1}^T \mathbf{H}_n^{-1} & \kappa_{n+1} + \frac{1}{C} \end{pmatrix}^{-1} \quad (9)$$

$$B = (\kappa_{n+1} + \frac{1}{C}) - \boldsymbol{\kappa}_{n+1}^T \mathbf{H}_n^{-1} \boldsymbol{\kappa}_{n+1}$$

$$\kappa_{n+1} = \kappa(\mathbf{x}_{n+1}, \mathbf{x}_{n+1})$$

式中, $\boldsymbol{\kappa}_{n+1}$ 是一个 n 维列矢量, 第 i 个元素为 $\kappa(\mathbf{x}_i, \mathbf{x}_{n+1})$ 。基于式(8)、(9)即可实现 LS-OC-SVM 的在线增量求解。

1.3 在线稀疏 LS-OC-SVM

实际运用中, 随着时间的推移, 在线增量求解中 $\mathbf{H}$ 矩阵的维数不断增加, 不利于在线数据的存储和实时计算。本节基于字典和相干准则的概念, 提出一种 LS-OC-SVM 的稀疏近似解。

字典相当于数据集被非线性映射 $\phi(\cdot)$ 到高维特征空间后的基矢量, 以较少数据的字典来近似含有大量数据的数据集^[21-22]。对于数据集 $\mathbf{X} = \{\mathbf{x}_i | i=1, 2, \dots, n\}$, 假设存在一个字典 $\mathbf{D} \subset \mathbf{X}$, $\mathbf{D} = \{\mathbf{x}_d | d=1, 2, \dots, m; m \ll n\}$, 使用字典 $\mathbf{D}$ 中的数据即可表示 $\mathbf{X}$ 中数据的分布特性。式(4)中第一个表达式可以用字典元素近似为

$$\boldsymbol{\omega} = \sum_{d=1}^m \beta_d \phi(\mathbf{x}_d) \quad (10)$$

式中, β_d 是使用字典重新训练 LS-OC-SVM 得到的拉格朗日乘子。被测数据 $\mathbf{x}$ 到超平面的距离改写为

$$r_D(\mathbf{x}) = \frac{\left| \sum_{d=1}^m \beta_d \kappa(\mathbf{x}, \mathbf{x}_d) - \rho \right|}{\|\boldsymbol{\beta}\|} \quad (11)$$

式中, $\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_m)^T$ 。

基于相干准则可以构造字典, 在 LS-OC-SVM 的在线学习中, 当有一个新元素 $\mathbf{x}_{n+1}$ 时, 可以计算出其与字典元素的相干系数

$$\lambda = \max_{d \in D} |\kappa(\mathbf{x}_{n+1}, \mathbf{x}_d)| \quad (12)$$

相干系数也是 Gram 矩阵非对角元素的最大值, 特征空间内相互正交的元素的相干系数为 0, 相同的元素的相干系数为 1。比较 λ 和用户设定的阈值 λ_0 可知道新元素 $\mathbf{x}_{n+1}$ 是否可以通过字典中的元素近似。相应地, 有以下两种情况。

(1) $\lambda > \lambda_0$ 。新样本在非线性映射后 $\phi(\mathbf{x}_{n+1})$ 可以用原先字典的样本表示, 新的数据不需要加入字典中, 模型不用更新。

(2) $\lambda \leq \lambda_0$ 。新样本加入字典, Gram 矩阵增加一维, 可以使用式(9)计算增加后的 $\mathbf{H}_{n+1}^{-1}$ 。

阈值 $\lambda_0 \in [0, 1]$ 决定了字典的复杂程度, 已有学者^[22]证明了对于一个紧支的子空间, 随着 n 趋于无穷大, 基于相干准则得到的字典数据个数是有限的。

2 颤振在线智能检测系统

颤振检测属于机械故障检测, 在线检测过程中, 如果能根据输出结果实时调整和进化检测模型, 以反映系统最新的状态, 检测系统就具有一定智能性。一个有效的在线智能检测系统应具有如下特征^[23]。

(1) 检测故障: 在线故障检测系统能很好地评价机械部件的性能并检测出故障。

(2) 较少的用户设定参数: 用户设定的参数应尽量少, 同时这些参数可以通过优化来获取。

(3) 适应性: 故障智能检测系统应该能在检测中不断更新模型, 即可以在线学习。

(4) 计算复杂度: 为了适应在线检测的需要, 检测机制的计算复杂度应该尽可能的小, 可以在线训练, 即先使用部分离线数据训练模型, 然后逐渐加入数据更新出新的模型。

基于以上几个特征, 结合颤振检测的应用需求, 本文设计了基于稀疏结构 LS-OC-SVM 的颤振在线智能检测系统。系统结构如图 1 所示, 图 1 中主要包括以下几个步骤。

(1) 离线训练 LS-OC-SVM。根据历史稳定加工

信号, 提取出特征矢量, 对特征矢量组成的数据集, 训练出颤振 LS-OC-SVM 模型, 包括超平面方程和半径(第 1.1 节), 并得到最初的数据集的特征库——字典。

(2) 在线颤振识别。在实时加工过程中, 随着时间的推移, 得到一个新的特征矢量 x_{n+1} , 按照式(11)计算与超平面的距离。通过与半径(阈值 1)比较, 判断是否发生颤振。

(3) 模型更新与进化。如果发生颤振, 则控制相关机构抑制颤振。如果没有发生颤振, 判断其是否是绝对稳定状态(阈值 2), 对于确定的稳定样本。

根据相干准则更新模型的字典, 得到新的特征库来更新 LS-OC-SVM 模型。这样随着时间推移, 检测数据不断增多, 模型特征库不断充实, 达到模型进化的效果。

本文颤振识别系统中设置双阈值, 阈值 1 是由式(7)确定的超球面半径, 用于判断颤振, 保证总体颤振误报率最低, 它使两个方面的误差最小。阈值 2 对稳定数据的判断更加严格, 避免那些已经发生颤振但没有识别出来的数据通过相干准则加入字典, 从而字典不会被误报的数据所污染。

图 1 颤振智能检测框图

3 试验与结果分析

3.1 试验方案

为了验证本文提出的颤振智能检测算法的有效性, 本文搭建了如图 2 所示的试验系统, 在南通数控车床上进行车削试验。试验中使用三爪卡盘将工件固定在机床主轴上, 并使用力传感器实时测量加工过程中的切削力, 刀具安装在力传感器上。加工过程中的动态力信号经过放大器放大后, 通过便携式数据采集器采样到计算机中。试验中采样频率设置为 10 kHz。试验仪器设备的型号如表 1 所示。

表 1 仪器型号表

设备名称	型号
力传感器	Kistler9257B
放大器	Kistler5070
数据采集器	HRU-1212MA
机床	南通数控车床
计算机	海尔 T86G

图 2 试验系统布置图

1. 力传感器 2. 计算机 3. 数据采集器 4. 放大器

试验中加工工件是一个 $\phi 80 \text{ mm} \times 200 \text{ mm}$ 圆柱体, 材料为不锈钢。为了激励出颤振, 试验中采用变切深外圆车削的方法, 随着切削深度变大, 工件切削动态力变大, 当达到一定的临界条件, 使工件刀具系统产生在其固有频率附近的剧烈振动。通过多次试验, 当采用表 2 所示的切削参数进行加工时, 出现了明显的颤振状态。

表 2 试验参数设置表

项目	参数
切削长度/mm	60
切削深度/mm	0~6(渐变)
主轴转速/(r/min)	400
进给速度/(mm/r)	0.15

由于颤振反映在切削力的相对波动中而非其绝对值大小。图 3、4 分别给出了是切削力减去其均值后得到力的波动信号和工件加工后表面形貌，从图 3、4 可以看出，开始加工阶段的力波动较小，相应工件表面纹理为幅度较小周向纵纹，属于正常的加工纹理；力的波动在 25.6 s 后突然变大，工件表面产生的幅值较大的轴向横纹。由以上分析可知，前 25.6 s 为稳定加工部分，25.6 s 后为颤振部分。

图 3 切削力相对波动

图 4 工件表面形貌

3.2 特征矢量的提取

在智能检测系统中，特征矢量的提取时非常重要的一步，一个有效的特征矢量应该能够抵抗外界环境的干扰。小波包变换是一种非常有效的故障信息提取方法^[11,18]，通过低通和高通滤波器的迭代滤波，信号被分解到不同的频带中。对于三层小波包变换，原始信号被分解到 8 个节点中，每个节点对应一个频带，其结构示意图如图 5 所示。

图 5 小波包变换示意图

小波包节点能量是一种具有较强鲁棒性的信号表达指标，其定义为每个小波包节点系数中存储的能量

$$E_j^i = \int_{-\infty}^{\infty} f_j^i(t)^2 dt \quad (13)$$

式中， $f_j^i(t)$ 和 E_j^i 分别是第 j 层第 i 个节点的小波系数和节点能量。原始信号的能量分布反应在各个节点能量所占的能量比例

$$P_i = E_j^i / \sum_{i=1}^n E_j^i \quad (14)$$

由于颤振发生时，某个特定频带的能量和幅值会急剧增加^[11,24]，因此小波包节点能量是很有潜力的颤振检测特征矢量。为了验证小波包节点能量的有效性，从第 3.1 节中的稳定加工部分和颤振部分各选取一段力信号，信号长度均为 512 个点。其小波包节点能量分布如图 6 所示。从图 6 中可以看出，在稳定加工时，信号能量随机分布在各个节点，而在颤振阶段，第 7 个节点的能量明显高于其他几个节点，说明信号在此频率段有频率集中现象。小波包节点能量分布可作为有效的颤振检测特征矢量。

图 6 稳定和颤振阶段特征矢量对比

本文使用小波包分解数据单元含有 512 数据点，试验中有效数据长度 53.398 s，共计可得到 1 042 个特征矢量，其中稳定加工部分有 502 个特征矢量。

3.3 基于离线模型的颤振检测

本文首先使用离线模型在线检测的方法，其中离线模型有两种，分别是 OC-SVM 和 LS-OC-SVM。离线训练均是使用稳定加工部分的前 100 个特征矢

量作为训练样本,得到超球面模型后,计算后来 942 个特征矢量与超球面的距离,通过与阈值比较来检测颤振。两种模型采用高斯核函数,核函数参数为 ($\sigma=0.2$, $C=5$)。两种模型的混淆矩阵如表 3 所示,表 4 给出了两种模型的性能对比。

表 3 OC-SVM 和 LS-OC-SVM 的混淆矩阵对比

方法		稳定(实际)	颤振(实际)
OC-SVM	稳定(预测)	466	2
	颤振(预测)	36	538
LS-OC-SVM	稳定(预测)	470	2
	颤振(预测)	32	538

表 4 OC-SVM 和 LS-OC-SVM 的分类性能对比

方法	预报精度(%)	训练时间/ms
OC-SVM	96.35	928.2
LS-OC-SVM	96.74	149.2

通过表 3 和表 4 的结果可以发现,LS-OC-SVM 与 OC-SVM 具有相似的分类性能。但由于 LS-OC-SVM 将求解二次规划的问题转换为线性方程组的求解,提高了计算效率,故其训练时间远小于 OC-SVM。同时,LS-OC-SVM 可结合分块矩阵求逆的方法,实现在线增量式求解更新,减少在线求解的时间。故本文以下离线模型均指基于 LS-OC-SVM 的离线模型。

3.4 在线进化模型的检测结果

根据本文第 2 节提出的模型在线进化的智能检测系统,同样使用前 100 个特征矢量训练的 LS-OC-SVM 模型,得到描述稳定数据集的超球,并且得到数据集的初始字典(71 个矢量)。然后利用离线训练得到的 LS-OC-SVM 模型在线检测颤振,并进化模型,模型进化的阈值 2 为颤振检测阈值的 70%。随着新的特征矢量的加入,检测系统不断检测其是否发生颤振,同时判断更新数据集的字典。图 7 给出了基于离线模型和在线进化模型的检测结果对比。从图 7 中可以看出,在线进化的模型对稳定状态的样本描述更好,使得颤振段与稳定段相对距离区分更大。

图 8 给出了在线检测过程中数据集字典的变化。随着加工环境等偏差的影响,初始 LS-OC-SVM 模型不能反映当前加工状态,故字典的样本数目不断增加,即特征库不断充实,最终稳定在 88 个矢量,新增的字典样本反映加工过程中的加工环境偏差等带来的模型偏差,这体现出 LS-OC-SVM 模型可以不断进化的能力。

(a) 切削力

(b) 离线模型

(c) 在线进化模型

图 7 两种模型检测效果

图 8 在线进化模型字典矢量的变化

为了更进一步地比较两种分类器的性能,本文采用二分类器的接收者操作特征曲线(Receiver operating characteristic curve, ROC)^[25]来对比两种分类器。图 9、10 分别给出了离线模型和在线进化模型的 ROC 曲线。图 9、10 可以看出,在线进化模型分类的有效性更高。从表 5 的分类性能对比中可以看出,在线进化模型的 ROC 曲线的 AUC 值为 0.996 8,高于离线模型的 0.990 8,同时在线进化模型的颤振预报准确率为 99.04%,高于离线模型的预报准确率 96.74%。

表 5 离线与在线模型分类性能对比

方法	颤振预报准确率(%)	AUC 值
离线模型	96.74	0.990 8
在线进化模型(本文)	99.04	0.996 8

图 9 离线模型的 ROC 曲线

图 10 在线进化模型的 ROC 曲线(本文的)

本文使用的在线进化模型需要不断更新, 基于分块矩阵乘法实现了 LS-OC-SVM 的在线增量式求解, 每 51.2 ms 为一个更新周期。使用 Matlab(2010a) 软件编写程序, 在中央处理器主频为 3.2 GHz 的计算机上运行本文所提出的在线进化算法, 一次检测更新的时间为 4.9 ms, 满足在线实时检测的要求。

4 结论

(1) 研究了一类支持向量机在最小二乘意义下的形式, 将求解二次规划问题转化为线性方程组求解的问题, 提高了计算效率。同时基于分块矩阵求逆的实现了 LS-OC-SVM 的增量求解, 减少了在线求解的时间。

(2) 基于相干准则实现 LS-OC-SVM 的稀疏化, 有效的控制了 LS-OC-SVM 模型的复杂度。同时构建了数据集的特征库——字典, 以包含较少数据的字典来近似原数据集。

(3) 构建了模型在线进化的颤振智能检测系

统, 在线检测颤振的过程中实时更新数据集的特征库。随着检测进行, 特征库不断扩充, 使检测模型不断进化。试验结果表明, 在线进化的检测模型有更高的颤振预报准确率。

参 考 文 献

- [1] QUINTANA G, AIURAN J. Chatter in machining processes: A review[J]. International Journal of Machine Tools and Manufacture, 2011, 25(5): 363-376.
- [2] 王跃辉, 王民. 金属切削过程颤振控制技术的研究进展[J]. 机械工程学报, 2010, 46(7): 166-174.
WANG Yuehui, WANG Min. Advances on machining chatter suppression research[J]. Journal of Mechanical Engineering, 2010, 46(7): 166-174.
- [3] MEI D, KONG T, ALBERT J. Magnetorheological fluid-controlled boring bar for chatter suppression[J]. Journal of Materials Processing Technology, 2009, 209(4): 1861-1870.
- [4] 李茂月, 韩振宇, 富宏亚, 等. 基于开放式控制器的铣削颤振在线抑制[J]. 机械工程学报, 2012, 48(17): 172-182.
LI Maoyue, HAN Zhenyu, FU Hongya, et al. Online milling chatter suppression based on open architecture controller[J]. Journal of Mechanical Engineering, 2012, 48(17): 172-182.
- [5] SHAO Qiang, FENG Changjian. Pattern recognition of chatter gestation based on hybrid PCA-SVM[J]. Applied Mechanics and Materials, 2011, 120: 190-194.
- [6] BERGER B S, MINIS I, HARLEY J, et al. Wavelet based cutting state identification[J]. Journal of Sound and Vibration, 1998, 213(5): 813-827.
- [7] TANGJITSITCHAROEN S, PONGSATHORNWIWAT N. Development of chatter detection in milling processes[J]. The International Journal of Advanced Manufacturing Technology, 2013, 65: 1-9.
- [8] NAIR U, KRISHNA B M, NAMBOOTHIRI V, et al. Permutation entropy based real-time chatter detection using audio signal in turning process[J]. The International Journal of Advanced Manufacturing Technology, 2010, 46: 61-68.
- [9] GOVEKAR E, BAUS A, GARDISEK J, et al. A new method for chatter detection in grinding[J]. CIRP Annals-Manufacturing Technology, 2002, 51(1): 267-270.
- [10] PEREZ-CANALS D, ALVAREZ-RAMIREZ J, JAUREGUI-CORREA J, et al. Identification of dynamic instabilities in machining process using the approximate

- entropy method[J]. International Journal of Machine Tools and Manufacture, 2011, 51(6): 556-564.
- [11] YAO Zhehe, MEI Deqing, CHEN Zichen. On-line chatter detection and identification based on wavelet and support vector machine[J]. Journal of Materials Processing Technology, 2010, 210(5): 713-719.
- [12] KULJANIC E, TOTIS G, SORTINO M. Development of an intelligent multisensor chatter detection system in milling[J]. Mechanical Systems and Signal Processing, 2009, 23(5): 1704-1718.
- [13] TANGJITSITCHAROEN S, ANGSUMALIN S. Comparison of in-process cutting state detection in CNC turning using different neural network systems[J]. Applied Mechanics and Materials, 2012, 121: 1942-1946.
- [14] TAX D, DUIN R. Support vector data description[J]. Machine Learning, 2004, 54: 45-66.
- [15] PAN Yuna, CHEN Jin, GUO Lei. Robust bearing performance degradation assessment method based on improved wavelet packet-support vector data description[J]. Mechanical Systems and Signal Processing, 2009, 23: 669-681.
- [16] WANG Shijin, YU Jianbo, EDZEL L, et al. A modified support vector data description based novelty detection approach for machinery components[J]. Applied Soft Computing, 2013, 13: 1193-1205.
- [17] ZHU Xiaoran, ZHANG Youyun, ZHU Yongsheng. Bearing performance degradation assessment based on the rough support vector data description[J]. Mechanical Systems and Signal Processing, 2013, 34: 203-217.
- [18] 吴石, 林连冬, 肖飞, 等. 基于多类超球支持向量机的铣削颤振预测方法[J]. 仪器仪表学报, 2012, 33(11): 2414-2421.
- WU Shi, LIN Liandong, XIAO Fei, et al. Milling chatter prediction method based on multiclass hypersphere support vector machine[J]. Chinese Journal of Scientific Instrument, 2012, 33(11): 2414-2421.
- [19] CHOI Y S. Least squares one-class support vector machine[J]. Pattern Recognition Letters, 2009, 30: 1236-1240.
- [20] WANG Tian, CHEN Jie, ZHOU Yi. Online least squares one-class support vector machines-based abnormal visual event detection[J]. Sensors, 2013, 13: 17130-17155.
- [21] NOUMIR Z, HONEINE P, RICHARD C. Online one-class machines based on the coherence criterion[C]// Proceedings of the 20th European Signal Processing Conference, August 27-31, 2012, Bucharest, Romania, 2012: 664-668.
- [22] RICHARD C, BERMUDEZ J, HONEINE P. Online prediction of time series data with kernels[J]. IEEE Transactions on Signal Process, 2009, 57(3): 1058-1067.
- [23] MARKOU M, SINGH S. Novelty detection: A review(Part 1): Statistical approaches[J]. Signal Processing, 2003, 83(12): 2481-2497.
- [24] ZHANG Chunliang, YUE Xia, JIANG Yongtao. A hybrid approach of ANN and HMM for cutting chatter monitoring[J]. Advanced Materials Research, 2010, 97(101): 3225-3232.
- [25] METZ CE. Basic principles of ROC analysis[J]. Seminars in Nuclear Medicine, 1978, 8: 283-298.

作者简介: 钱士才, 男, 1990 年出生。主要研究方向为智能制造、支持向量机。

E-mail: qianshica@situ.edu.cn

熊振华(通信作者), 男, 1974 年出生, 博士, 研究员, 博士研究生导师。主要研究方向为智能制造、运动控制与先进电子制造。

E-mail: mexiong@situ.edu.cn