

基于流形学习与隐马尔可夫模型的 刀具磨损状况识别

张栋梁, 莫蓉, 孙惠斌, 李春磊

(西北工业大学 现代设计与集成制造技术教育部重点实验室, 陕西 西安 710072)

摘要:为了提高金属铣削过程中的刀具磨损状态识别的自动化程度与精度,提出了基于局部切空间排列(LTSA)方法与隐 Markov 模型(HMM)来识别刀具的不同磨损状态的方法。该方法首先利用小波分析技术对铣削过程中的切削进给方向力信号进行处理,构造了高维特征空间。然后使用基于流形学习方法实现了高维特征空间的维数约简。最终利用约简后的低维特征向量训练 HMM,从而实现刀具磨损状态的识别。实验结果说明该方法能够有效地识别铣削过程的刀具磨损状态。与未经特征维数约简的识别方法相比,新方法能够提高刀具磨损状态的识别效率与准确率。

关键词:维数约简;刀具磨损状态识别;流形学习;隐马尔可夫模型(HMM)

中图分类号: TG71, TH117 **文献标志码:** A **文章编号:** 1000-2758(2015)04-0651-07

在金属铣削过程中,刀具的磨损与产品的加工质量具有密切的联系。刀具的磨损量可以通过铣削过程中的动态信号表现出来,通过对铣削过程中的动态信号进行采集、处理与识别能够监测刀具的磨损状态,从而避免刀具磨损所造成的损失。识别刀具磨损状态一直是国内外学者研究的热点问题之一,他们提出了众多利用振动信号、力信号以及声发射信号识别刀具磨损状态的研究成果^[1-7]。目前的研究成果主要是基于支持向量机、模糊系统、神经网络等人工智能算法建立信号特征与刀具磨损状态的数学模型,通过多个训练样本的学习确定模型的参数^[8-9]。这些方法的可行性与有效性主要依赖于信号特征与判决阈值的选择。小波变换^[10]、希尔伯特-黄变换(HHT)^[11]、混沌时序分析^[12]等信号特征提取方法被不断地应用在刀具磨损的信号特征提取方面,但是由于刀具磨损信号特征常常被淹没在强大的噪声背景中,很多信号特征提取方法所提取的特征中含有冗余信息。在这种情况下,刀具磨损的信号特征的敏感度与关联度被大大地降低了,最终影响了刀具磨损状态的识别效果。所以,如何简化

包含冗余信息的多维信号特征,得到能够反映刀具磨损状态的低维特征具有非常重要的价值。

流形学习能够通过非线性降维的方式提取不同类型高维数据的内在特征,与传统的线性降维方法相比,流形学习在处理高维、复杂非线性的刀具磨损信号时能够更加有效地发现非线性数据的本质结构。本文通过流形学习中的局部切空间排列(LTSA)方法对刀具磨损信号的时域特征与频域特征构成的原始高维特征空间进行维数约简,消除原来信号特征中的冗余信息。然后使用隐马尔可夫模型作为分类器^[13],建立降维之后的特征矢量与故障类别之间的映射关系,最终实现刀具磨损状态的识别。

1 局部切空间排列算法(LTSA)的维数约简方法

局部切空间排列(local tangent space alignment, LTSA)方法是一种有效的流形学习算法,被广泛地

应用在信号数据集维数约简方面^[14]。本文使用 LTSA 方法用来约简铣削过程中的刀具切削力信号的原始特征维数。其主要思想是:将刀具磨损相关的力信号进行特征提取,将每一次不同刀具磨损量的实验信号转化为一个特征点,该特征点的维数就是刀具磨损特征提取后的维数,而所有特征点的存在形成了刀具磨损特征空间;利用刀具磨损特征点所在局部空间的切空间来表示点的邻域,并对每一个刀具磨损特征点都建立邻域切空间;最后利用刀具磨损特征点局部切空间排列来求出整体低维嵌入坐标,从而实现约简刀具磨损特征。使用 LTSA 方法将刀具磨损数据集 $\mathbf{X} = [x_1, x_2, \dots, x_N]$, $x_i \in \mathbf{R}^m$, 化简为 $d(m > d)$ 维的数据集的步骤总结如下:

1) 构造特征点的局部邻域。对于刀具磨损数据集 \mathbf{X} 中的任意特征点 x_i , $i = 1, 2, \dots, N$, 使用欧氏距离确定其 k_i 个邻近特征点组成的邻域 $\mathbf{X}_i = [x_{i_1}, x_{i_2}, \dots, x_{i_{k_i}}]$ 。

2) 特征点的局部邻域中线性拟合。在刀具磨损特征点 x_i 的邻域内选择一组正交基 O_i 构成 x_i 的 d 维切空间;计算邻域中每一个点 x_{ij} ($j = 1, 2, \dots, k_i$) 到切空间上的正交投影 $\theta_j^i = O_i^T(x_{ij} - \bar{x}_i)$ 。其中 $\bar{x}_i = \frac{\sum_{j=1}^{k_i} x_{ij}}{k_i}$, O_i 为矩阵 $\mathbf{X}_i \left(\mathbf{I} - \frac{\mathbf{e}\mathbf{e}^T}{T} \right)$ 的前 d 个最大的左奇异矢量。特征点 x_i 的在其邻域中的局部坐标为 $\Theta_i = [\theta_1^i, \theta_2^i, \dots, \theta_{k_i}^i]$ 。

3) 获取特征的全局坐标 T_i 。将每一个特征点的局部坐标转化为刀具磨损特征空间的全局坐标需要满足 2 个条件:(1) 全局坐标应该尽量保留每个特征点邻域的几何结构信息;(2) 全局重构误差 $\sum_{i=1}^N \|E_i\|_2^2 = \sum_{i=1}^N \left\| T_i \left(\mathbf{I} - \frac{\mathbf{e}\mathbf{e}^T}{k_i} \right) - L_i \Theta_i \right\|_2^2$ 为最小值。其中,特征点 x_i 的局部坐标 Θ_i 经过转化后得到全局坐标 $T_i = [t_{i_1}, t_{i_2}, \dots, t_{i_{k_i}}]$, 其中 L_i 为转化矩阵,将全局重构误差最小化得到全局坐标 T_i 。

2 基于隐马尔可夫模型的刀具磨损识别问题描述与相关算法简述

2.1 基于隐马尔可夫模型的刀具磨损识别问题

隐马尔可夫模型(HMM)是一种概率论模型,具有学习能力与自适应能力,拥有严谨的数据结构和

完善的数学理论基础,能够通过训练获取知识,从而有效地对待识别目标进行分类。近年来,HMM 在切削过程监测中得到了广泛应用^[15-17]。考虑使用测力传感器记录刀具磨损过程中的工件受力情况,其力信号的变化与刀具磨损状态具有密切的关系,定义力信号特征,并将其划分为 n 个级别。记录刀具的磨损量,按磨损量的范围划分 3 种磨损状态,分别为:初始、正常与剧烈。当刀具处于某一磨损状态时,其力信号特征处于第 i 个级别的概率为 p_i 。在这种情况下,本文研究的问题可以描述为:已知观测的力信号特征序列,如何判断是由哪种刀具磨损状态序列产生的观测信号特征序列。

针对刀具磨损识别问题,定义隐马尔可夫模型(HMM): $\lambda = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B})$ 。根据刀具磨损有限状态集 S , 定义取值于 S 的马尔可夫链为 $\{q_t: t \geq 1\}$, 其中 $\{q_t: t \geq 1\}$ 的初始分布 q_1 为 $\boldsymbol{\pi}$, 状态转移矩阵为 \mathbf{A} 。事实上,刀具磨损状态链 q_t 的值、初始概率分布 $\boldsymbol{\pi}$ 与状态转移矩阵 \mathbf{A} 都不能直接得到。对于刀具磨损识别问题而言,能够直接通过观测获取的是取值于有限观测集 Ω 的变量序列 $\{o_t: t \geq 1\}$, 将其称之为观测链。通过直接观测得到的观测链与未知状态链一起构成了隐马尔可夫模型(HMM), 并定义观测链与状态链的关系矩阵 \mathbf{B} , 将其称为观测值概率矩阵。由以上可以看到参数矩阵 \mathbf{A} 与 \mathbf{B} , 以及参数向量 $\boldsymbol{\pi}$ 都是未知的, 使用 $\lambda = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B})$ 来表示隐马尔可夫模型。

2.2 面向刀具磨损状态识别 HMM 的基本算法

在建立 HMM 时, HMM 中初始概率分布向量 $\boldsymbol{\pi}$ 、状态转移概率矩阵 \mathbf{A} 与观测值概率矩阵 \mathbf{B} 都是未知的。在本文中,通过流形学习方法 LTSA 进行特征约简之后的 d 维特征向量是用于训练的观测序列 $\{o_t: t \geq 1\}$ 。

已知存处于刀具磨损状态 s_i 的训练观测序列 $\{o_t: t \geq 1\}$ 以及 HMM 的初始模型 λ_0 。使用 Baum-Welch 算法^[15], 训练得到第 i 个磨损状态的马尔可夫模型 λ_i , $i = 1, 2, \dots, N$, N 为刀具磨损状态数目,本文中磨损状态数 N 为 3。

使用 Viterbi 算法计算未知磨损状态的观察序列 $\{o_t: t \geq 1\}$ 的在各个状态 HMM λ_i 下的概率 $P\left(\frac{\{o_t\}}{\lambda_i}\right)$, 选取最大的 $P\left(\frac{\{o_t\}}{\lambda_i}\right)$ 所对应的磨损状态为观察序列 $\{O_u\}$ 的磨损估计状态,进而完成未知刀具磨损状态的识别^[16];

除了 Baum-Welch 算法与 Viterbi 算法之外, Baum 等人提出了前向算法与后向算法用于解决 HMM 中的概率计算问题,即在给定观测序列 $\{o_t; t \geq 1\}$ 与模型 λ 的情况下,有效地计算观测序列在模型 λ 下中出现的概率 $P\left(\frac{\{o_t\}}{\lambda}\right)$ 。Baum-Welch 算法与 Viterbi 算法的详细步骤参见文献[15-16]。

3 基于流形学习方法 LTSA 与 HMM 的刀具磨损状态识别模型

3.1 基于流形学习方法 LTSA 刀具磨损信号特征提取

为了实现最终的刀具磨损状态的分类,需要提取与刀具磨损状态相关的信号特征,由于刀具在进给方向的切削力信号与刀具切削状态具有密切的联系,很多研究将进给方向的切削力作为信号特征提取的对象。本文使用流形学习方法(LTSA 算法)对进给方向的切削力信号的时域特征与频域特征进行特征约简。由于 LTSA 算法从原始的特征空间中提取出的低维子流形拥有能够代表原始数据结构的能力,所以使用 LTSA 算法进行特征约简后,不但能够有效降低信号特征维数与计算复杂度,而且能够得到与刀具磨损状态密切相关的新信号特征,在本文的实验中证明了 LTSA 算法的有效性。本文进行信号特征约简的实现过程如下所述:

1) 原始特征空间的构成。构造原始特征空间的信号特征为时域特征与频域特征。其中时域特征分别为均值、均方根值、波形指标、波峰指标、脉冲指标、裕度指标以及峭度指标等 7 个时域特征,频域特征为使用 db4 小波包函数进行 3 层正交小波分解得到的 8 个子频带信号的功率谱能量。

2) 特征压缩的目标维数 d 与局部邻域中特征点的个数 k 选择。LTSA 方法中目标维数的选择会影响特征的敏感性,而局部邻域中特征点的个数会影响低维流形的提取效果。本文将降维后特征空间中不同磨损状态下的分类质量作为测度函数,使用网格搜索算法来选取 LTSA 方法的最优参数。

3) 获取低维特征。对于选定的目标维数 d 与局部邻域中特征点的个数 k ,计算每个特征点的邻域,计算中心化矩阵中心化矩阵 $X_i \left(I - \frac{ee^T}{T} \right)$ 的 d 个

最大左奇异向量构成 d 维切空间。计算特征点在邻域切空间的投影。将特征点的局部投影进行整合,通过最小化全局重构误差,获取经过约简后的刀具磨损特征的全局坐标。

3.2 基于 HMM 的刀具磨损状态识别方法与步骤

本文提出的基于 HMM 的刀具磨损状态识别流程主要包含生成任务、训练任务以及识别任务,如图 1 所示。

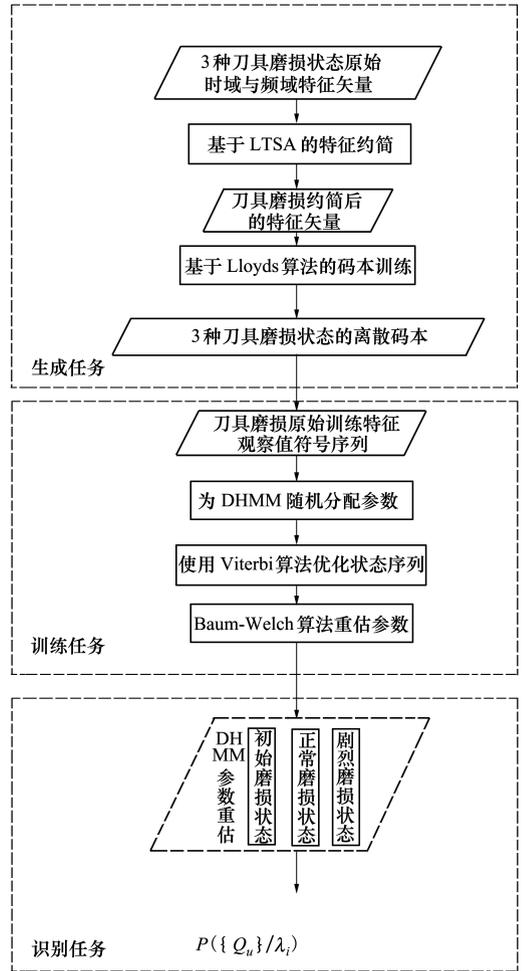


图 1 基于 HMM 的刀具磨损状态识别流程

生成任务将训练集中经过 LTSA 方法特征约简的刀具磨损特征矢量转化为观察值符号序列。首先基于 LTSA 方法对原始的刀具磨损切削力信号的时域与频域的特征进行维数约简,形成新的特征矢量;然后使用 K-means 算法对训练集中不同刀具磨损状态的特征矢量训练出离散码本^[17];再利用离散码本将训练集中的各个特征矢量量化为观察值符号序列。

训练任务使用 Baum-Welch 算法对不同刀具磨

损状态的观察值符号序列进行训练,得到每一种磨损状态的 HMM^[15]。

识别任务中首先遍历训练样本中的每一个样本,分别使用样本的码本将待识别刀具磨损原始序列特征转化为观察值符号序列,并使用对应样本的 HMM 计算待识别观察值符号序列的 Viterb 评分 $P\left(\frac{\{O_i\}}{\lambda_i}\right)$,将具有最高 Viterb 评分的 HMM 所对应的刀具磨损状态作为识别的结果^[16]。其中按照铣刀主切削刃后刀面的磨损量(V_B),将刀具磨损过程划分为的 3 个不同状态:状态 1 - 初期磨损状态: $V_B < 0.1 \text{ mm}$;状态 2——正常磨损状态: $0.1 \text{ mm} \leq V_B < 0.35 \text{ mm}$;状态 3——剧烈磨损状态: $V_B \geq 0.35 \text{ mm}$ 。

4 刀具磨损状态识别实例

4.1 实验对象与数据采集

从切削原理可知,进给方向的切削力信号包含了刀具磨损运行状态的丰富信息。本文使用 KISTLER 公司生产的测力仪来采集株洲钻石 PM-4E-D6.0-G 整体螺旋立铣刀的切削力,采样频率为 200 kHz,采样长度为 0.5 s。实验详细信息如表 1 所示。本文采集的进给方向的切削力信号的实验平台如图 2 所示。

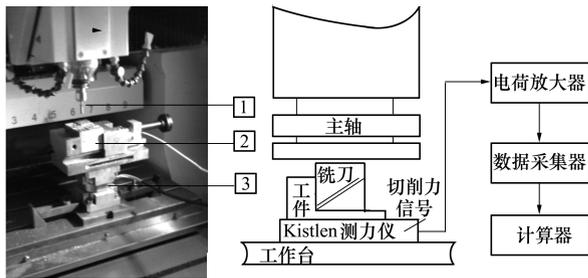


图 2 实验平台示意图

为了保证所采集的进给方向的切削力信号处于对应的磨损状态中,本文根据实验经验选定了一定的时间间隔,使用 Alicano 公司的 Infinite focus 测力仪对后刀面的磨损量进行测量。在本文所设定的切削加工参数下,对每一把刀具均在一定的时间间隔下进行 6 次后刀面的测量,前 2 次测量的间隔时间为进行铣削加工 30 s,第 3 次与第 4 次测量的间隔时间为进行铣削加工 20 s,第 5 次与第 6 次测量的

间隔时间为 10 s。本文在实际加工过程中为了避免工件的结构形式以及刀具的加工路径对切削过程的进给方向切削力信号的特征影响,实验所有的铝合金工件都是预先处理为 15 cm×10 cm×10 cm 尺寸。为了保证实验过程的一致性,本文在实验过程中选择相同的刀具以及工件,按照本实验所设定轴向切深、径向切深进行直线走刀,每次直线走刀的长度为 10 cm。

表 1 本文实验参数

参数	数值
进给速度/(mm·min ⁻¹)	100
主轴转速/(r·min ⁻¹)	3 000
轴向切削深度/mm	5
径向切削深度/mm	0.3

在本文中,根据 3.2 节中所述,在刀具磨损的不同状态采集了 3 类切削力信号,每类磨损信号包含 30 组数据,一共 90 组数据。

4.2 基于网格计算的 LTSA 的参数寻优

按照 3.1 节所描述的步骤实现基于 LTSA 的刀具磨损信号特征提取。首先构造原始特征空间,本文所建立的原始特征空间中包含了:均值、波形指标、峰值指标、脉冲指标、裕度指标、峭度指标、子频带 1 的能量、子频带 2 的能量、子频带 3 的能量、子频带 4 的能量、子频带 5 的能量、子频带 6 的能量、子频带 7 的能量、子频带 8 的能量。

使用网格搜索算法来选取 LTSA 方法的最优目标维数 m_best 与最优局部邻域点数 k_best ,将降维后特征空间中 3 种磨损状态下的特征点最小包含球的平均半径作为测度函数。其中, $1 \leq m \leq 15, 1 \leq k \leq 20$,设定搜索步长为 1。使用网格搜索算法进行 LTSA 方法参数寻优结果,当测度函数在降维目标维数 m 为 7(原始信号特征维数为 15),局部邻域点数 k 为 11 的时候取得最高的测度函数值 21.987。

对实验样本数据使用 LTSA 方法进行维数约简,经过维数约简之后得到维数为 7 的数据。原始磨损特征空间中冗余特征已经被约简,基于 LTSA 方法得到新的数据结构更加紧凑,有效改善了同一磨损状态的数据特征的内聚度。而且经过特征约简之后的信号样本特征主要分布在 3 个不同的数量级,能够提高原始特征矢量量化的速度与准确率。

4.3 磨损状态识别实验

在完成基于 LTSA 方法的特征约简之后,按照

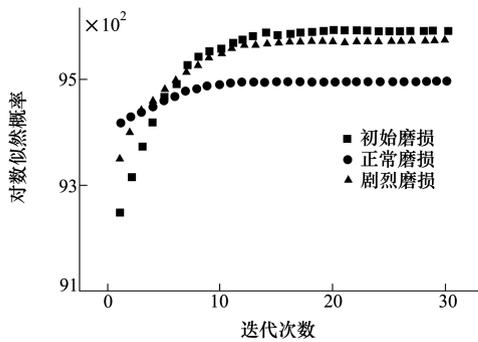


图 3 3 种磨损状态的 HMM 训练迭代曲线

如 3.2 节所示的方法,对本文实验所采集的 3 种刀具磨损状态的信号求解码本,并利用码本将信号的特征矢量量化为观察值符号序列。经过 LTSA 方法进行特征约简后的 3 种刀具磨损状态的 HMM 模型训练结果如图 3 所示。从图 3 中可以看到,3 种刀具磨损状态的 HMM 对数似然估计在 30 步迭代之后就可以达到收敛误差范围,并且 3 种刀具磨损状态具有不同的收敛值。

在完成 3 种刀具磨损状态的 HMM 建立之后,根据 3.2 节中所陈述的基于 HMM 的分类方法进行刀具磨损状态的识别。对于 3 种刀具磨损状态的实验条件下分别选取 5 次观测样本进行分类测试,其分类结果如表 4 所示。

表 2 观测样本在 3 种刀具磨损状态 HMM 下的输出对数似然概率与识别结果

采样磨损状态	样本编号	3 种磨损状态 HMM 输出的对数似然概率			识别结果
		初始磨损	正常磨损	剧烈磨损	
初始磨损	1	95.894 5	94.845 2	94.360 5	初始磨损
	2	95.935 6	94.889 1	94.404 4	初始磨损
	3	95.964 2	94.937 8	94.453 1	初始磨损
	4	95.921 0	94.923 0	94.438 3	初始磨损
	5	95.959 9	94.923 0	94.438 3	初始磨损
正常磨损	1	95.058 9	95.937 9	94.583 5	正常磨损
	2	93.819 1	94.814 9	93.343 7	正常磨损
	3	94.836 1	95.668 4	94.360 7	正常磨损
	4	95.194 5	95.958 0	94.719 1	正常磨损
	5	94.771 7	95.596 5	94.296 3	正常磨损
剧烈磨损	1	94.301 3	93.310 6	94.983 6	剧烈磨损
	2	94.660 4	94.669 7	95.280 9	剧烈磨损
	3	94.463 9	94.473 2	95.043 5	剧烈磨损
	4	94.548 4	94.557 7	95.116 1	剧烈磨损
	5	94.504 6	94.513 9	95.117 7	剧烈磨损

为了评价本文所提出的刀具磨损识别方法的效果,在本节中针对 3 类刀具磨损信号使用 LTSA 方法进行特征约简后的识别结果与未特征约简后的识别方法进行对比。其中 LTSA 方法的邻域参数 k 为 11,目标维数为 7。表 5 为基于 LTSA 方法约简与未

经约简的特征向量进行隐马尔可夫模型识别的结果。从表 5 中可以看出 LTSA 方法能够有效区分 3 类刀具磨损状态,与未经约简的识别方法相比,前者具有更加优秀的识别效率与精度。

表 5 2 种特征约简方法的 3 种磨损状态的 HMM 识别结果

方法	初始磨损	正常磨损	剧烈磨损	平均识别精度	平均识别时间/s
	/%	/%	/%		
基于 LTSA 的 HMM 识别	96.67	93.33	93.33	94.44	7.5
未经特征约简的 HMM 识别	73.33	76.67	70	73.33	11.3

5 结 论

本文提出了基于 LTSA 方法和隐马尔可夫模型的刀具磨损状态识别方法。本文将金属铣削过程中进给方向的铣削力信号的时域特征与频域特征构建样本点的特征空间。由于 LTSA 方法能够在保持数据局部几何结构的同时降低数据的维数,将其用于分类问题能够获得较好的分类结果。本文在使用 LTSA 方法进行维数约简之后,通过 Lloyds 算法将特征矢量转化为观察值符号序列,并将其代入 HMM 中进行分类识别。HMM 通过 Viterbi 算法对观察序

列进行了优化,并使用 Baum-Welch 算法重新估计了 HMM 参数,通过比较样本的对数似然概率值的大小实现了状态识别。本文用 3 种刀具磨损状态的识别实例验证了经过 LTSA 方法进行特征约简的进给方向力信号识别不同磨损状态的可行性与有效性。

本文提出的方法利用了 LTSA 方法在特征约简与信息化简的优势,对进给方向的切削力信号的时域特征与以小波包函数子频的信号功率谱能量为主的频域特征组成的特征空间进行维数约简,并应用 HMM 实现了不同磨损状态的识别。本文的方法按照“特征提取”、“特征化简”、“模式识别”的流程,实现了刀具磨损状态识别自动化与高精度的统一。

参考文献:

- [1] Wang G F, Yang Y W, Zhang Y C, et al. Vibration Sensor Based Tool Condition Monitoring Using v Support Vector Machine and Locality Preserving Projection[J]. Sensors and Actuators A: Physical, 2014, 209: 24-32
- [2] Wang Guofeng, Guo Zhiwei, Yang Yinwei. Force Sensor Based Online Tool Wear Monitoring Using Distributed Gaussian ART-MAP Network[J]. Sensors and Actuators A: Physical, 2013, 192: 111-118
- [3] Ravindra H C, Srinivasa Y G, Krishnamurthy R. Acoustic Emission for Tool Condition Monitoring in Metal Cutting[J]. Wear, 1997, 212(1), 78-84
- [4] Zhou J M, Andersson M, Stahl J E. The Monitoring of Flank Wear on the CBN Tool in the Hard Turning Process[J]. Int J Adv Manuf Technol, 2003, 22: 697-702
- [5] Ai C S, Sun Y J, He G W, et al. The Milling Tool Wear Monitoring Using the Acoustic Spectrum[J]. Int J Adv Manuf Technol, 2012, 61: 457-463
- [6] Susanto V, Chen J C. Fuzzy Logic Based In-Process Tool-Wear Monitoring System in Face Milling Operations[J]. Int J Adv Manuf Technol, 2003, 3: 186-192
- [7] 张翔, 富宏亚, 孙雅洲, 等. 基于隐 Markov 模型的微径铣刀磨损监测[J]. 计算机集成制造系统, 2012, 18(01): 141-148
Zhang Xiang, Fu Hongya, Sun Yazhou, et al. Hidden Markov Model Based Micro-Milling Tool Wear Monitoring[J]. Computer Integrated Manufacturing Systems, 2012, 18(1): 141-148 (in Chinese)
- [8] Kuo R J, Cohen P H. Intelligent Tool Wear Estimation System through Artificial Neural Networks and Fuzzy Modeling[J]. Artificial Intelligence in Engineering, 1998, 12(3): 229-242
- [9] Silva R G, Reuben R L, Baker K J, et al. Tool Wear Monitoring of Turning Operations by Neural Network and Expert System Classification of a Feature Set Generated from Multiple Sensors[J]. Mechanical Systems and Signal Processing, 1998, 12(2): 319-332
- [10] Li Xiaoli, Yuan Zhejun. Tool Wear Monitoring with Wavelet Packet Transform-Fuzzy Clustering Method[J]. Wear, 1998, 219(2): 145-154
- [11] Tomas Kalvoda, Hwang Yeanren. A Cutter Tool Monitoring in Machining Process Using Hilbert-Huang Transform[J]. International Journal of Machine Tools & Manufacture, 2010, 50(5): 495-501
- [12] 徐创文, 陈花玲, 程仲文, 等. 基于时序分析与模糊聚类的铣削刀具磨损状态识别[J]. 机械强度, 2007, 29(4): 525-531
Xu Chuangwen, Chen Hualing, Cheng Zhongwen, et al. Recognition of Milling Tool Wear Based on Time Series Analysis and Fuzzy Cluster[J]. Journal of Mechanical Strength, 2007, 29(4): 525-531 (in Chinese)

- [13] Leonard E B, Ted P. Statistical Inference for Probabilistic Functions of Finite State Markov Chains[J]. The Annals of Mathematical Statistics, 1966, 37(6): 1554-1563
- [14] Zhang Zhenyue, Zha Hongyuan. Principal Manifolds and Nonlinear Dimensionality Reduction via Tangent Space Alignment[J]. SIAM Journal on Scientific Computing, 2004, 26(1): 313-338
- [15] Leonard E B, Ted Petrie, Norman Weiss. A Maximization Technique Occurring in the Statistical Analysis of Probabilistic Functions of Markov Chains[J]. The Annals of Mathematical Statistics, 1970, 41(1), 164-171
- [16] Andrew J V. Error Bounds for Convolutional Codes and an Asymptotically Optimum Decoding Algorithm[J]. IEEE Trans on Information Theory, 1967, 13(2): 260-269
- [17] MacQueen J. Some Methods for Classification and Analysis of Multivariate Observations[C]//Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, 1967, 1(14): 281-297

Tool Wear Condition Monitoring Based on Manifold Learning and Hidden Markov Model

Zhang Dongliang, Mo Rong, Sun Huibin, Li Chunlei

(Key Laboratory of Contemporary Design and Integrated Manufacturing Technology,
Northwestern Polytechnic University, Xi'an 710072, China)

Abstract: In order to improve the automation and the precision of tool wear condition recognition in the process of metal milling, we proposed the method based on the manifold learning—the local tangent space alignment (LTSA) method—and the hidden Markov model (HMM) to identify tool wear conditions. First, this method used the time domain and the wavelet analysis technique for signal processing of the milling cutting axial force to construct the high dimensional feature space. Then, the local tangent space alignment (LTSA) method was used to achieve the dimensionality reduction. At last, the low dimensional feature vector was used to train the HMM in order to recognize tool wear conditions. Additional tests were conducted to check the feasibility of the method. Comparison of the performance of the proposed method with that of the method of identification without the feature dimension reduction shows that the proposed method can improve the efficiency and the accuracy of tool wear condition recognition.

Key words: condition monitoring, conformal mapping, design of experiments, efficiency, eigenvalues and eigenfunctions, errors, experiments, feature extraction, flowcharting, hidden Markov models, matrix algebra, milling (machining), monitoring, probability, signal processing, time domain analysis, wavelet analysis, wear of materials; dimension reduction, local tangent space alignment (LTSA), the manifold learning, tool wear conditions recognition