



(12)发明专利申请

(10)申请公布号 CN 111300146 A

(43)申请公布日 2020.06.19

(21)申请号 201911199533.6

(22)申请日 2019.11.29

(71)申请人 上海交通大学

地址 200240 上海市闵行区东川路800号

(72)发明人 杜正春 陈沁心 冯晓冰 杨建国

(74)专利代理机构 上海交达专利事务所 31201

代理人 王毓理 王锡麟

(51)Int.Cl.

B23Q 17/09(2006.01)

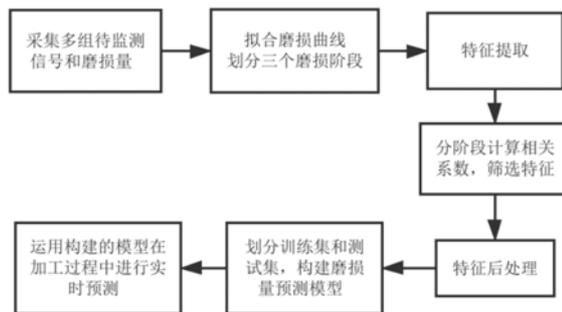
权利要求书3页 说明书5页 附图5页

(54)发明名称

基于主轴电流和振动信号的数控机床刀具磨损量在线预测方法

(57)摘要

一种基于主轴电流和振动信号的数控机床刀具磨损量在线预测方法,通过在设有传感器的数控机床主轴上利用多把同型号刀具在同一工况下重复进行试运行加工并测得原始加工磨损数据,根据刀具的初期快速磨损阶段、正常磨损阶段和急剧磨损阶段三个磨损阶段,分别从中提取出训练用的最优特征集并对支持向量回归机预测模型进行训练,最后采用训练后的模型进行实际加工过程中的在线实时预测刀具磨损量;本发明通过多把同型号刀具在同等条件下重复实验获得的数据,不仅可以充分挖掘原始信号中各磨损阶段与刀具磨损相关的特征参数,并通过后处理方式进一步增强和刀具磨损量的关联程度,使得构建的支持向量回归机预测模型可以取得较高的预测精度和很好的推广性。



1. 一种基于主轴电流和振动信号的数控机床刀具磨损量在线预测方法,其特征在于,通过在设有传感器的数控机床主轴上利用多把同型号刀具在同一工况下重复进行试运行加工并测得原始加工磨损数据,根据刀具的初期快速磨损阶段、正常磨损阶段和急剧磨损阶段三个磨损阶段,分别从中提取出训练用的最优特征集并对支持向量回归机预测模型进行训练,最后采用训练后的模型进行实际加工过程中的在线实时预测刀具磨损量;

所述的原始加工磨损数据,包括采用加速度传感器测得的主轴振动时域信号、采用电流传感器测得的主轴单相电流时域信号、采用显微镜测得的对应的刀具磨损量;

所述的提取,包括:根据刀具磨损量和对应的走刀次数拟合得到的磨损曲线、提取主轴单相电流时域信号的时域特征、提取主轴振动时域信号的时域特征、频域特征以及时频域特征。

2. 根据权利要求1所述的数控机床刀具磨损量在线预测方法,其特征是,所述的多把同型号刀具,具体为三把山特维克直径8mm的3刃平头立铣刀对45钢工件进行面铣方式加工,每次走刀长度为120mm,利用Kistler三轴加速度传感器采集主轴振动信号,用电流传感器采集主轴单相电流信号。

3. 根据权利要求1或2所述的数控机床刀具磨损量在线预测方法,其特征是,所述的最优特征集是指:相关系数大于阈值且在多组实验中重复出现的所有特征的集合,即根据所有特征与磨损曲线的相关系数,取得大于阈值的相关系数对应的特征作为有效特征,经高斯加权移动平均和归一化处理得到;

所述的相关系数,即皮尔逊相关系数  $r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$ , 其中:  $X_i$ 、 $Y_i$  分别表示特征参数和磨损量的第  $i$  个值,  $\bar{X}$ 、 $\bar{Y}$  分别表示该特征向量和磨损量的均值,  $r$  为皮尔逊相关系数,取值范围在  $[-1, 1]$  之间,越接近区间的极值代表其相关性越强,其中 1 代表完全正相关, -1 代表完全负相关, 0 代表不相关。

4. 根据权利要求1所述的数控机床刀具磨损量在线预测方法,其特征是,所述的时域特征包括:包括:均值、方差、标准差、均方根、最大值、峰峰值、整流平均值、波形因子、峰值因子、峭度因子、脉冲因子、均方幅值、裕度因子、偏斜度指标;

所述的频域特征包括:表征频谱位置重心的重心频率、表征频谱分布的离散程度的频率方差和表征频谱主频带的位置变化的均方频率,其中:当刀具的磨损量增大时,频谱结构也发生改变而使重心频率发生变化,重心频率  $FC = [\sum_{f=1}^{N/2} f w(f)] / \sum_{f=1}^{N/2} w(f)$ ; 频率方差  $VF = [\sum_{f=1}^{N/2} (f - FC)^2 w(f)] / \sum_{f=1}^{N/2} w(f)$ ; 均方频率  $MSF = [\sum_{f=1}^{N/2} f^2 w(f)] / \sum_{f=1}^{N/2} w(f)$ , 其中:  $f$  表示频率,  $w(f)$  为该频率对应幅值,  $N$  为采样频率;

所述的时频域特征,采用小波包分解和经验模态分解进行提取,具体为:首先用 db4 小波基对原始振动信号的每个分量进行 4 层小波包分解,然后对 16 个子频带分别提取能量值、各频带能量所占百分比以及各频带重构信号的时域特征。

5. 根据权利要求1所述的数控机床刀具磨损量在线预测方法,其特征是,所述的训练,以部分特征数据作为训练集,剩余部分作为测试集,选取模型磨损量预测的均方误差作为种群适应度,根据个体的适应度,进行选择、交叉、变异操作,产生新的种群并计算每个个体

当前适应度;选出最优个体中与记录的最优适应度进行比较,决定是否更新最优参数和最佳适应度,经迭代训练得到最优预测模型。

6. 根据权利要求1或5所述的数控机床刀具磨损量在线预测方法,其特征是,所述的支持向量回归机预测模型为基于遗传算法参数寻优的支持向量回归模型,其构建和训练过程具体步骤包括:

步骤1:选取模型磨损量预测的均方误差作为种群适应度,设置种群中个体数目为20,最大进化代数50以及两个参数的寻优区间;

步骤2:初始化种群,计算每个个体的适应度值,记录初始参数为最优参数、初始适应度值为最优适应度;

步骤3:根据个体的适应度,进行选择、交叉、变异操作,产生新的种群并计算每个个体当前适应度;选出最优个体中与记录的最优适应度进行比较,决定是否更新最优参数和最佳适应度;

步骤4:当达到最大迭代次数或满足终止条件时输出当前最优参数,否则回到步骤3;

步骤5:将获取的最优参数作为支持向量回归机模型的最终参数,构建最优预测模型。

7. 根据权利要求6所述的数控机床刀具磨损量在线预测方法,其特征是,所述的基于遗传算法参数寻优的支持向量回归模型的待寻优的参数为惩罚系数、容错间隔带,具体寻优步骤包括:

①给定训练样本 $\{(x_i, y_i), i=1, \dots, n | x_i \in \mathbb{R}^N, y \in \mathbb{R}\}$ 拟合函数 $f$ ,使 $f(x_i)$ 与 $y_i$ 的最大偏差为 $\varepsilon$ ,即当 $|f(x_i) - y_i| > \varepsilon$ 时,才计算误差,相当于以 $f(x)$ 为中心,构建一个宽度为 $2\varepsilon$ 的间隔带,当样本落入其中,则被认为预测没有偏差, $f(x) = \langle w, x \rangle + b$ ,其中 $w$ 、 $b$ 分别为权重和偏置项;

②通过引入惩罚参数 $C$ 和松弛变量 $\xi$ ,支持向量回归问题可转化为:

$$\begin{aligned} & \text{minimize } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \hat{\xi}_i) \\ & \text{subject to } \begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \hat{\xi}_i \\ \xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, \dots, n \end{cases} \end{aligned}$$

通过引入拉格朗日乘子,将该约束优化问题转换为无约束问题,拉格朗日函数:

$$\begin{aligned} L := & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \hat{\xi}_i) - \sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \hat{\mu}_i \hat{\xi}_i + \sum_{i=1}^n \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \\ & \sum_{i=1}^n \hat{\alpha}_i (y_i - f(x_i) - \varepsilon - \hat{\xi}_i); \end{aligned}$$

③根据约束问题最优解的必要条件,即KKT条件:

$$\partial_b L = \sum_{i=1}^n (\alpha_i - \hat{\alpha}_i) = 0$$

$$\partial_w L = w - \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i) x_i = 0$$

$$\partial_{\xi_i} L = C - \alpha_i - \mu_i = 0, \partial_{\hat{\xi}_i} L = C - \hat{\alpha}_i - \hat{\mu}_i = 0$$

将上式带入可求得对偶问题：

$$\begin{aligned} & \text{maximize} \sum_{i=1}^n y_i(\hat{\alpha}_i - \alpha_i) - \varepsilon(\hat{\alpha}_i + \alpha_i) - \frac{1}{2} \sum_{i,j=1}^n (\hat{\alpha}_i - \alpha_i)(\hat{\alpha}_j - \alpha_j) \Phi(x_i)\Phi(x_j) \\ & \text{subject to} \begin{cases} \sum_{i=1}^n (\alpha_i - \hat{\alpha}_i) = 0 \\ 0 \leq \alpha_i, \hat{\alpha}_i \leq C \end{cases} \end{aligned}$$

得到  $w = \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i)x_i$  ,  $b = y_i + \varepsilon - \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i)\langle x_i, x \rangle$  , 因此  $f(x) = \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i)\langle x_i, x \rangle + b$ 。

## 基于主轴电流和振动信号的数控机床刀具磨损量在线预测方法

### 技术领域

[0001] 本发明涉及的是一种机械加工领域的技术,具体是一种基于主轴电流和振动信号的高精度的数控机床刀具磨损量在线预测方法。

### 背景技术

[0002] 数控机床是现代先进制造技术重要的基础装备,而由刀具失效引起的机床停机时间大约占机床总停机时间的1/5-1/3。而对于配备有一套相对成熟的刀具监测系统的数控机床,其故障停机时间可以减少75%,加工效率可以提高10-60%。现有的刀具状态监测技术普遍对刀具磨损状态类别能达到较精准的预测,但对磨损量的预测精度不高,且实时性、推广性较差,难以大规模应用到工业生产中。

### 发明内容

[0003] 本发明针对现有刀具监测技术预测模型精度低且基于单把刀具实验数据建立的模型推广性差的缺陷,提出一种基于主轴电流和振动信号的数控机床刀具磨损量在线预测方法,通过多把同型号刀具在同等条件下重复实验获得的数据,不仅可以充分挖掘原始信号中各磨损阶段与刀具磨损相关的特征参数,并通过后处理方式进一步增强和刀具磨损量的关联程度,使得构建的支持向量回归机预测模型可以取得较高的预测精度和很好的推广性。

[0004] 本发明是通过以下技术方案实现的:

[0005] 本发明涉及一种基于主轴电流和振动信号的数控机床刀具磨损量在线预测方法,通过在设有传感器的数控机床主轴上利用多把同型号刀具在同一工况下重复进行试运行加工并测得原始加工磨损数据,根据刀具的初期快速磨损阶段、正常磨损阶段和急剧磨损阶段三个磨损阶段,分别从中提取出训练用的最优特征集并对支持向量回归机预测模型进行训练,最后采用训练后的模型进行实际加工过程中的在线实时预测刀具磨损量。

[0006] 所述的原始加工磨损数据,包括采用加速度传感器测得的主轴振动时域信号、采用电流传感器测得的主轴单相电流时域信号、采用显微镜测得的对应的刀具磨损量。

[0007] 所述的提取,包括:根据刀具磨损量和对应的走刀次数拟合得到的磨损曲线、提取主轴单相电流时域信号的时域特征、提取主轴振动时域信号的时域特征、频域特征以及时频域特征。

[0008] 所述的最优特征集是指:根据所有特征与磨损曲线的相关系数,取得在多次实验中均大于阈值的相关系数对应的特征作为有效特征;优选对有效特征进行高斯加权移动平均和归一化处理得到。

[0009] 所述的支持向量回归机预测模型,优选为基于遗传算法参数寻优的支持向量回归模型。

[0010] 所述的训练,以部分刀具的全部走刀数据作为训练集,剩余部分作为测试集,选取

模型磨损量预测的均方误差作为种群适应度,根据个体的适应度,进行选择、交叉、变异操作,产生新的种群并计算每个个体当前适应度;选出最优个体中与记录的最优适应度进行比较,决定是否更新最优参数和最佳适应度,经迭代训练得到最优预测模型。

#### 技术效果

[0011] 本发明整体所解决的技术问题是:避免使用价格高昂、工业应用性差但能最直接反映刀具磨损状况的切削力传感器,选择使用经济性好且工业应用性高的振动传感器和电流传感器进行刀具磨损预测。现有技术基于单把刀具数据建立的模型尽管预测准确度较高,但由于切削实验的复杂性和各种偶然因素的干扰,如果使用同型号的刀具在同等实验条件下重复试验,该模型的预测效果较差,即利用单把刀具建立的模型往往不适用于另一把刀,即使在完全相同的加工条件下。

[0012] 与现有技术相比,本发明提出使用同型号刀具重复实验的数据,根据三个磨损阶段分别提取出在多组实验中重复出现的相关特征作为该阶段的最优特征集。相比于单把刀具数据在整个磨损阶段选取特征的方法,本发明可在保持较高预测精度的基础上,大大提高模型的可推广性。由此产生的意料之外的技术效果包括:

[0013] 通过在三个磨损阶段分别提取信号时域、频域、时频域的大量特征参数,能充分挖掘信号中潜在的和不同阶段磨损量高度相关的特征,通过计算相关系数筛选出与磨损量高度相关的特征作为最优特征集,然后进行高斯加权移动平均的后处理,可进一步提高特征和磨损量的关联程度,并提高最后预测模型的精度。

#### 附图说明

[0014] 图1为本发明流程示意图;

[0015] 图2为实施例刀具磨损量在线预测方法的流程图;

[0016] 图3为实施例拟合的刀具磨损量和走刀次数的磨损曲线示意图;

[0017] 图4为实施例刀具磨损量预测模型构建的流程图;

[0018] 图5为实施例遗传算法参数寻优种群适应度变化示意图;

[0019] 图6为实施例刀具磨损量分段预测模型整体的误差示意图。

#### 具体实施方式

[0020] 如图1和图2所示,为本实施例涉及一种刀具磨损量预测方法的具体流程,包括如下步骤:

[0021] 步骤1、设置切削参数为:主轴转速2000RPM,进给速度300mm/min,切深1mm,切宽4.5mm,在该参数设置下用三把山特维克直径8mm的3刃平头立铣刀对45钢工件进行面铣方式加工,每次走刀长度为120mm,利用Kistler三轴加速度传感器采集主轴振动信号,用电流传感器采集主轴单相电流信号。

[0022] 所述的振动信号的采样频率为20kHz,电流信号的采样频率为5kHz。

[0023] 优选地,每加工一段时间后停机卸刀一次,用显微镜测量刀具后刀面磨损量并记录对应的走刀次数,三把刀分别切削290刀、280刀和320刀以后铣刀达到磨钝标准停止采集。

[0024] 步骤2、如图3所示,为根据测量的磨损量和对应的走刀次数拟合得到磨损曲线之

一,根据磨损量变化趋势划分为三个磨损阶段:初期快速磨损阶段、正常磨损阶段和急剧磨损阶段。

[0025] 步骤3、分别提取电流信号的时域特征、振动信号的时域特征、频域特征和时频域特征。

[0026] 所述的时域特征包括:均值、方差、标准差、均方根、最大值、峰峰值、整流平均值、波形因子、峰值因子、峭度因子、脉冲因子、均方幅值、裕度因子、偏斜度指标。

[0027] 所述的频域特征,优选在提取前先通过离散傅里叶变换得到频谱图。

[0028] 所述的频域特征包括:表征频谱位置重心的重心频率、表征频谱分布的离散程度的频率方差和表征频谱主频带的位置变化的均方频率,其中:当刀具的磨损量增大时,频谱结构也发生改变而使重心频率发生变化,重心频率 $FC = \left[ \sum_{f=1}^{N/2} fw(f) \right] / \sum_{f=1}^{N/2} w(f)$ ;频率方差

$VF = \left[ \sum_{f=1}^{N/2} (f - FC)^2 w(f) \right] / \sum_{f=1}^{N/2} w(f)$ ;均方频率 $MSF = \left[ \sum_{f=1}^{N/2} f^2 w(f) \right] / \sum_{f=1}^{N/2} w(f)$ ,其中:f表示频率,w(f)为该频率对应幅值,N为采样频率。

[0029] 所述的时频域特征,采用小波包分解和经验模态分解进行提取,具体为:首先用db4小波基对原始振动信号的每个分量进行4层小波包分解,然后对16个子频带分别提取能量值、各频带能量所占百分比以及各频带重构信号的时域特征。

[0030] 所述的能量值 $E_i = \sum_{j=1}^n x_{ij}^2$ ,其中: $E_i$ 为第i个子频带的能量值, $x_{ij}$ 为小波包分解后第i个子频带中j个分解系数;各频带能量所占百分比 $\psi_i = E_i / \sum_{k=1}^n E_k$ 。

[0031] 本实施例中的经验模态分解,获取前8个信号分量,以每个分量的总能量作为特征参数。

[0032] 步骤4、对三个磨损阶段分别计算步骤3得到的每个特征与步骤1中参数设置下走刀对应磨损量的相关系数,从而筛选出每个磨损阶段各自的最优特征集。

[0033] 所述的最优特征集是指:相关系数大于阈值且在上述三组实验中重复出现的所有特征的集合。

[0034] 所述的相关系数,即皮尔逊相关系数 $r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$ ,其中: $X_i$ 、 $Y_i$ 分别表示特征参数和磨损量的第i个值, $\bar{X}$ 、 $\bar{Y}$ 分别表示该特征向量和磨损量的均值,r为皮尔逊相关系数,取值范围在[-1,1]之间,越接近区间的极值代表其相关性越强,其中1代表完全正相关,-1代表完全负相关,0代表不相关。

[0035] 所述的三个磨损阶段的阈值优选为0.9、0.6和0.8。

[0036] 步骤5、对最优特征集中的每个特征依次进行高斯加权移动平均和归一化处理得到规整特征集。

[0037] 本实施例中三个磨损阶段的移动平均的数据滑动窗口大小选择分别为25、60、65。

[0038] 所述的归一化处理是指:最大最小归一化法,通过线性变换将原始数据转换到[0,1]区间内,公式为: $y = \frac{x - x_{min}}{x_{max} - x_{min}}$ ,其中:x为输入值,y为归一化后的值, $x_{min}$ 、 $x_{max}$ 分别表示该序列最小和最大值。

[0039] 步骤6、以规整特征集作为输入、刀具磨损量作为输出、步骤1所得数据作为测试集

和训练集数据分三个磨损阶段分别构建并训练基于遗传算法参数寻优的支持向量回归机模型,并将训练后的模型用于实际加工过程中的在线实时预测刀具磨损量。

[0040] 所述的测试集和训练集是指:在步骤1采集到的三把刀的890个样本中,选取两把刀的全部样本作为训练集数据,剩余一把刀的样本作为测试集数据。

[0041] 所述的支持向量回归机模型中需要寻优的参数为惩罚系数、容错间隔带,具体步骤包括:

[0042] ①给定训练样本  $\{(x_i, y_i), i=1, \dots, n | x_i \in \mathbb{R}^N, y_i \in \mathbb{R}\}$ , 希望拟合一个函数  $f$ , 使  $f(x_i)$  与  $y_i$  的差值尽可能的小, 在支持向量回归机模型中设置最大偏差为  $\varepsilon$ , 则只有当  $|f(x_i) - y_i| > \varepsilon$  时, 才计算误差。这就相当于以  $f(x)$  为中心, 构建一个宽度为  $2\varepsilon$  的间隔带, 当样本落入其中, 则被认为预测没有偏差,  $f(x) = \langle w, x \rangle + b$ , 其中  $w, b$  分别为权重和偏置项。

[0043] ②通过引入惩罚参数  $C$  和松弛变量  $\xi$ , 支持向量回归问题可转化为:

$$[0044] \quad \text{minimize} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \hat{\xi}_i)$$

$$[0045] \quad \text{subject to} \quad \begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \hat{\xi}_i \\ \xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, \dots, n \end{cases}$$

[0046] 通过引入拉格朗日乘子, 将该约束优化问题转换为无约束问题, 拉格朗日函数:

$$L := \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \hat{\xi}_i) - \sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \hat{\mu}_i \hat{\xi}_i + \sum_{i=1}^n \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \sum_{i=1}^n \hat{\alpha}_i (y_i - f(x_i) - \varepsilon - \hat{\xi}_i)$$

[0047] ③根据约束问题最优解的必要条件, 即KKT条件:

$$[0048] \quad \partial_b L = \sum_{i=1}^n (\alpha_i - \hat{\alpha}_i) = 0$$

$$[0049] \quad \partial_w L = w - \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i) x_i = 0$$

$$[0050] \quad \partial_{\xi_i} L = C - \alpha_i - \mu_i = 0, \partial_{\hat{\xi}_i} L = C - \hat{\alpha}_i - \hat{\mu}_i = 0$$

[0051] 将上式带入可求得对偶问题:

$$[0052] \quad \text{maximize} \quad \sum_{i=1}^n y_i (\hat{\alpha}_i - \alpha_i) - \varepsilon (\hat{\alpha}_i + \alpha_i) - \frac{1}{2} \sum_{i,j=1}^n (\hat{\alpha}_i - \alpha_i) (\hat{\alpha}_j - \alpha_j) \Phi(x_i) \Phi(x_j)$$

$$[0053] \quad \text{subject to} \quad \begin{cases} \sum_{i=1}^n (\alpha_i - \hat{\alpha}_i) = 0 \\ 0 \leq \alpha_i, \hat{\alpha}_i \leq C \end{cases}$$

$$[0054] \quad \text{得到} \quad w = \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i) x_i, \quad b = y_i + \varepsilon - \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i) \langle x_i, x \rangle$$

[0055] 因此,  $f(x) = \sum_{i=1}^n (\hat{\alpha}_i - \alpha_i) \langle x_i, x \rangle + b$ , 本实施例中寻优区间设置为  $C \in [0, 35]$ ,  $\varepsilon \in [0.005, 1]$ 。

[0056] 如图4所示, 为刀具磨损量预测模型构建的流程图, 本实施例中构建和训练过程具体步骤包括:

[0057] 步骤6.1: 选取模型磨损量预测的均方误差作为种群适应度, 设置种群中个体数目为20, 最大进化代数为50以及两个参数的寻优区间;

[0058] 步骤6.2: 初始化种群, 计算每个个体的适应度值, 记录初始参数为最优参数、初始适应度值为最优适应度;

[0059] 步骤6.3: 根据个体的适应度, 进行选择、交叉、变异操作, 产生新的种群并计算每

个个体当前适应度;选出最优个体中与记录的最优适应度进行比较,决定是否更新最优参数和最佳适应度;

[0060] 步骤6.4:当达到最大迭代次数或满足终止条件时输出当前最优参数,否则回到步骤6.3;

[0061] 步骤6.5:将获取的最优参数作为支持向量回归机模型的最终参数,构建最优预测模型。

[0062] 所述的在线实时预测是指:按照步骤1、3、4、5中特征采集、提取、筛选后后处理方法获取特征集作为所述支持向量回归机模型的输入,实时获取其输出即为当前状态下刀具磨损量的预测值。

[0063] 如图4所示,为本实施例中遗传算法参数寻优过程中正常磨损阶段种群最佳适应度和平均适应度随代数的变化情况,如图5所示,为本实施例中刀具磨损量分段最优预测模型在整个测试集上的误差图。

[0064] 如下表所示,为本实施例中在测试集上的预测精度:

评价指标	值
均方误差	175.2592 $\mu\text{m}^2$
平均相对误差	14.56%
平均绝对误差	9.3552 $\mu\text{m}$
最大绝对误差	57.4960 $\mu\text{m}$

[0065] 可以看到,采用本方法构建的模型仍具有较高的预测精度,在整个测试集上的平均相对误差为14.56%,平均绝对误差为9.3552 $\mu\text{m}$ 。虽然最大绝对误差高达57.4960 $\mu\text{m}$ ,但除了最开始和接近磨钝阶段误差较大,中间部分的绝对误差均在12 $\mu\text{m}$ 以下。

[0066] 本发明利用主轴振动和电流这两种易于采集的加工信号,相比大多数以单把刀具全寿命实验数据划分训练集和测试集,并以在测试集上的预测精度作为评价指标的方法,本发明更侧重模型的可推广性,故采用多把刀的实验数据作为训练集,并将建立的模型在另一把刀上进行预测验证模型的准确度,实施例中预测结果证明了本发明建模方法的可推广性;相比多数方法中以刀具从新刀到磨钝的整个过程作为整体进行特征提取,本发明根据三个磨损阶段分别进行特征提取,在保证较高预测精度的情况下,能较好地排除加工环境和偶然因素的干扰,对于同型号刀具同一工况的实验条件下的刀具磨损预测有很好的适应性和推广性。

[0067] 上述具体实施可由本领域技术人员在不背离本发明原理和宗旨的前提下以不同的方式对其进行局部调整,本发明的保护范围以权利要求书为准且不由上述具体实施所限,在其范围内的各个实现方案均受本发明之约束。

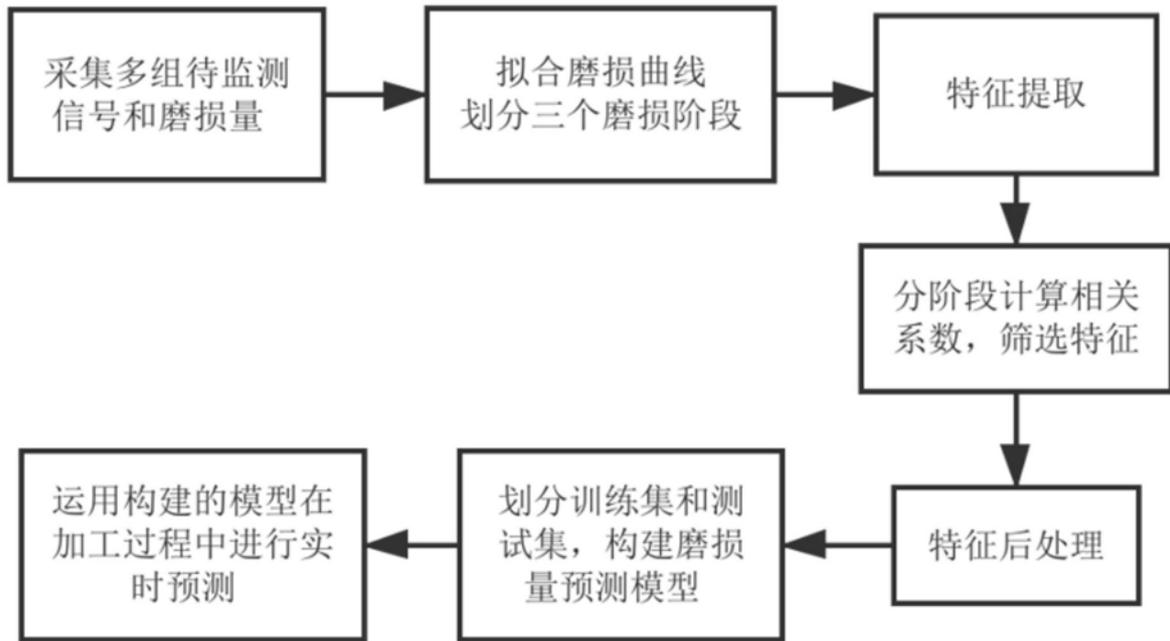


图1

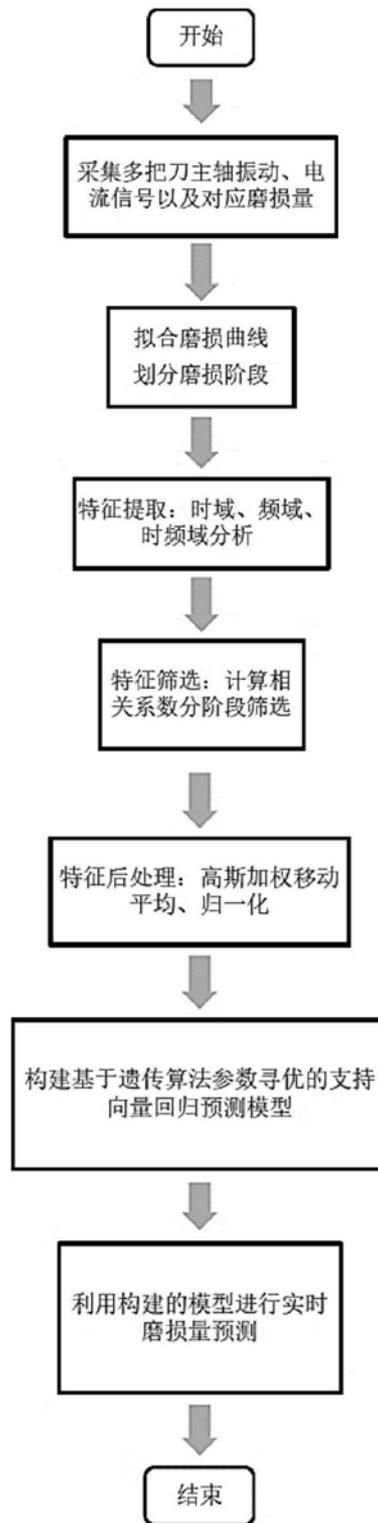


图2

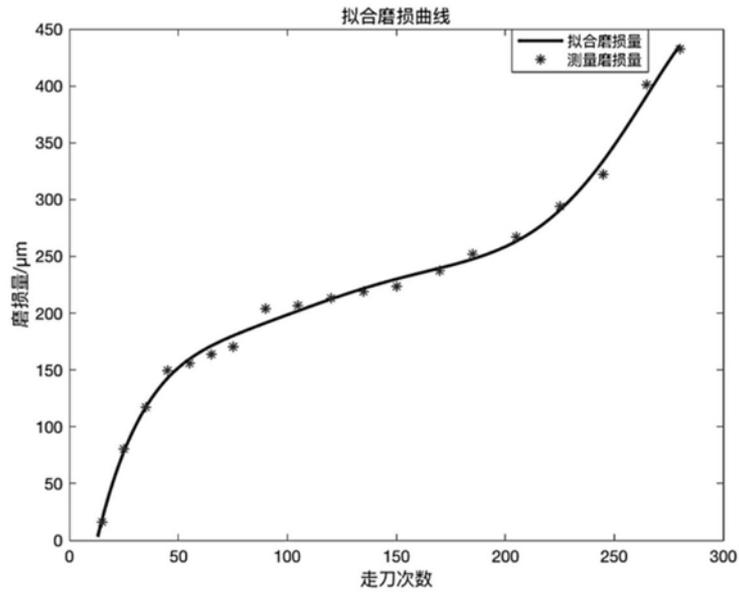


图3

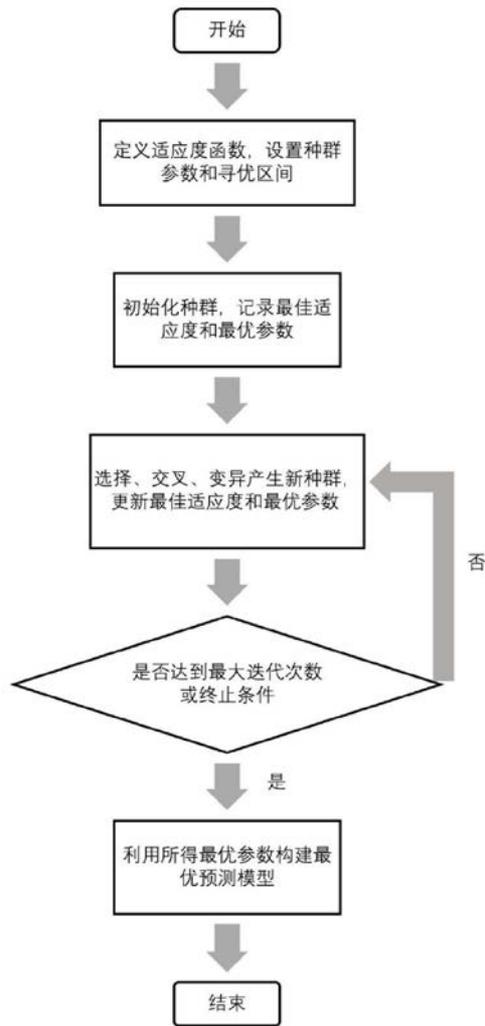


图4

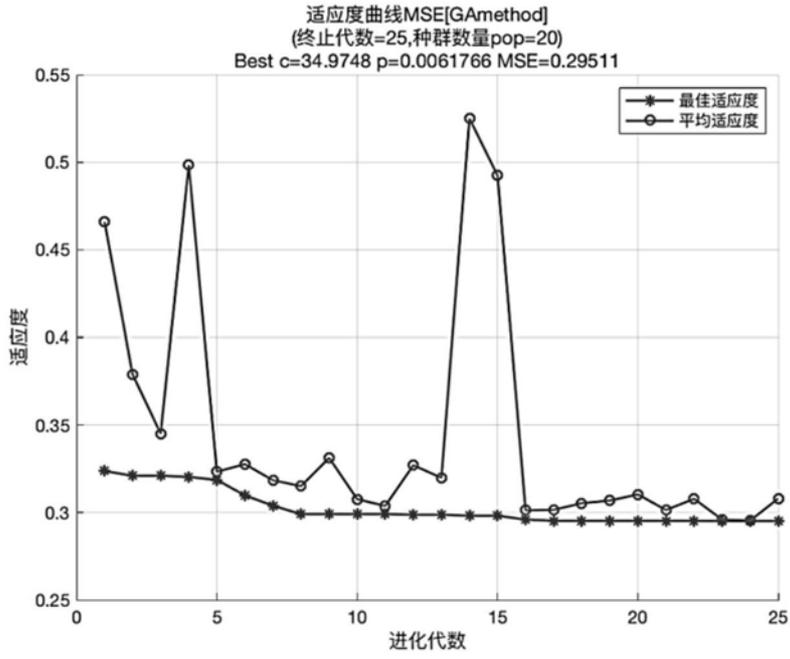


图5

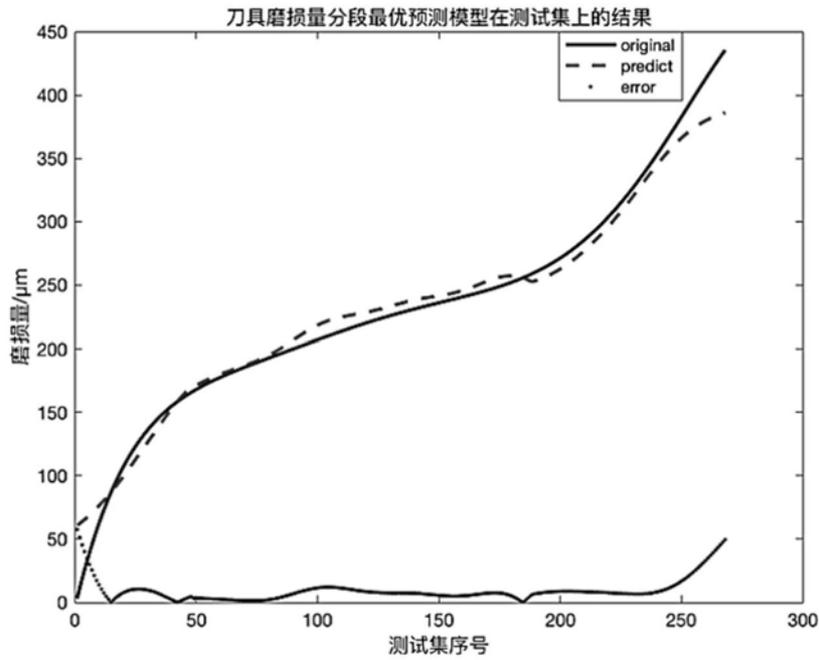


图6