

文章编号: 0253-374X(2017)03-0420-07

DOI: 10.11908/j.issn.0253-374x.2017.03.017

基于功率传感器的刀具磨损量预测方法

谢楠¹, 段明雷², 高英强¹, 郑蓓蓉³

(1. 同济大学 中德工程学院, 上海 201804; 2. 同济大学 机械与能源工程学院, 上海 201804; 3. 温州大学 机电工程学院, 浙江 温州 325000)

摘要: 使用功率传感器监测机床加工功率, 和切削力、声发射等传感器相比, 功率传感器具有实用性强、对加工过程无影响等优点。针对采集到的功率信号, 在分析信号特征相关性的基础上, 提出了一个多目标优化 RP-SBL 的刀具磨损量预测方法。对信号特征进行后处理(Re-processing, RP)消除电网波动和切削中其他偶然因素的影响, 进一步提高特征对刀具磨损敏感性。基于处理后的特征, 运用稀疏贝叶斯学习(Sparse Bayesian Learning, SBL)方法建立刀具磨损量预测模型。此外, 使用非支配排序遗传算法(Non-dominated Sorting Genetic Algorithm II, NSGA-II)对 SBL 模型相关参数进行优化以提高预测精度。实验研究表明, 该方法能够实现刀具磨损量的准确预测。不同预测方法的对比表明, 通过特征后处理提高信号特征对刀具磨损的敏感性, 保证了刀具磨损量的准确预测, 对 SBL 模型参数进行优化可进一步提高预测精度, 减小预测误差的最大值。

关键词: 刀具磨损; 预测; 特征后处理; 稀疏贝叶斯学习; 非支配排序遗传算法

中图分类号: TH17

文献标志码: A

Sorting Genetic Algorithm II (NSGA-II) approach was proposed to achieve the tool wear prediction. First, the features re-processing was applied to eliminating impacts caused by power fluctuation and other casual factors, and the sensitivity of tool wears enhanced. Then, the tool wear was predicted by Sparse Bayesian Learning based on the re-processed features. Finally, the parameter of Sparse Bayesian Learning was also optimized by NSGA-II to improve the prediction accuracy. The experimental results on a milling machine tool show the effectiveness in predicting the tools wear by the proposed approach. A comparative study of different methods shows feature sensitivity enhancement of the tool wear by feature re-processing ensures its prediction accuracy; Prediction accuracy can be further improved and the maximum of the prediction error can be minimized through the optimization of SBL with NSGA-II.

Key words: tool wear; prediction; feature re-processing; Sparse Bayesian Learning; Non-dominated Sorting Genetic Algorithm II(NSGA-II)

Tool Wear Prediction Approach Based on Power Sensor

XIE Nan¹, DUAN Minglei², GAO Yingqiang¹, ZHENG Beirong³

(1. Sino-German College of Applied Sciences, Tongji University, Shanghai 201804, China; 2. School of Mechanical and Power Engineering, Tongji University, Shanghai 201804, China; 3. College of Mechanical and Electrical Engineering, Wenzhou University, Wenzhou 325000, China)

Abstract: The power sensor was used to monitor machine processing power which was more practical and of no influence on the cutting process in comparison with conventional sensors such as force and AE. For the collected power signal, based on the analysis of signal features, a Re-processing Sparse Bayesian Learning (RP-SBL) with Non-dominated

智能设备作为智慧工厂的核心之一, 对运行状态的自我识别、自我学习和自我维护能力是其重要特征^[1]。据统计, 加工过程中换刀和对刀约占设备运行时间的 20%^[2]。此外, 刀具的磨损和破损对加工质量、加工效率、机床寿命甚至操作人员的人身安全有重要影响。因此, 准确、高效的刀具运行状态自我识别和自动预警对提高机床的智能水平有重要意义, 可有效地节约成本、提高效率。

刀具状态监测方法主要分为两大类: 直接法和间接法。直接法利用光学或图像检测装置直接测量刀具磨损量, 但通常存在以下问题: 离线检测实时性较差, 降低了加工效率; 在线光学或图像检测装置易受切屑、冷却液等因素的影响, 实用性不强^[2-3]。间接法通过采集加工过程中的物理信号, 建立刀具磨损

收稿日期: 2016-03-22

基金项目: 国家自然科学基金(71471139); 国家国际科技合作专项资助(2012DFG72210); 浙江省自然科学基金(LY14E050020)

第一作者: 谢楠(1975—), 女, 副教授, 工学博士, 主要研究方向为故障诊断、制造系统建模。E-mail: xienan115@tongji.edu.cn

通讯作者: 郑蓓蓉(1961—), 女, 研究员, 主要研究方向为故障诊断与预测维护。E-mail: zhengbeirong@163.com

状态和信号特征的映射关系,采用智能算法自我识别刀具磨损状态,分析当前磨损值,为刀具的自我维护提供依据,从而实现刀具状态的智能监测。

刀具状态的变化直接影响切削力的变化,因而通过切削力进行刀具状态监控是最常用的方法^[4]. Jemielniak^[5]等通过实验发现铣削中进给力和径向分力相对于切向分力对刀具磨损更加敏感. Wang^[6]等基于力传感器建立了一个刀具状态监测系统,利用分布式高斯神经网络实现了刀具磨损状态的分类. Wang^[7]等基于力传感器,采用自联想神经网络建立了刀具磨损量预测模型. 高宏力^[8]等利用切削力信号,提出了基于动态树理论的刀具磨损监测方法. 声发射信号具有灵敏度高、可避免低频噪声干扰等优点,在刀具状态监测的研究中也有较为广泛的应用. Iwata^[9]等最先研究刀具磨损和声发射信号间的关系,发现350 kHz以上的声发射信号功率谱随刀具磨损的增加而增大. Zhou^[10]等使用声发射传感器实现了刀具磨损量的预测. 电流、功率等传感器具有安装和测量方便,不影响加工等特点,可有效地实现刀具状态监测. Lee^[11]等使用进给电流实现刀具破损识别. Li^[12]等使用进给电流实现刀具磨损速率的识别,进而通过磨损速率确定刀具磨损阶段. Shao^[13]等结合功率传感器建立了考虑磨损量时的切削功率模型,通过该模型可确定需要换刀时的切削功率阈值. 此外,也有学者将振动信号、声音信号等用于刀具状态监测,但由于这些信号易受噪声干扰等问题,常仅作为切削力信号或声发射信号的补充以提高预测精度^[14-15].

功率信号具有安装测量方便,不影响正常加工等优点,但由于电网波动、切削过程中的各种偶然变化(如材料内部缺陷、外部冲击引起工件与刀具之间的异常颤振)等,减低了信号特征对刀具磨损的敏感度,因而限制了功率信号在刀具磨损量预测上的应用.

刀具状态监测的另一核心问题是在分析信号特征的基础上,构建有效的算法进行刀具磨损量的预测. 常用算法包括人工神经网络和支持向量机等. 人工神经网络的预测算法,模型过于复杂、需要大量的实验样本,且计算收敛困难. 支持向量机可以实现在小样本下刀具磨损量的预测^[16-17],但易出现过学习现象,模型的稀疏性有限,且无法提供预测结果的概率信息.

本文提出基于功率的刀具磨损量预测方法,运用功率传感器采集机床功率信号,提取和刀具磨损

量相关性强的信号特征,对特征进行后处理(Re-Processing, RP)以提高特征对刀具磨损的敏感性,建立基于稀疏贝叶斯学习方法(Sparse Bayesian Learning, SBL)的刀具磨损量预测模型,采用多目标优化算法NSGA-II,提高模型的预测精度.

1 基于功率的多目标优化RP-SBL刀具磨损量预测方法

提出的多目标优化RP-SBL刀具磨损量预测方法如图1所示,包括数据采集、特征提取、特征后处理和预测模型的优化.

(1)数据采集:使用功率传感器采集机床加工功率信号,同时在每次加工完毕后使用显微镜进行刀具磨损的拍照与测量.

(2)特征提取:针对上述原始功率数据,对数据进行特征提取,分析各特征与刀具磨损量的相关性并选取相关性强的特征.

(3)特征后处理:为了增强数据特征对刀具磨损量的敏感度,将上述得到的数据特征进行后处理,包括保序回归和指数平滑,使得处理后的特征能更好地适应刀具磨损量预测模型.

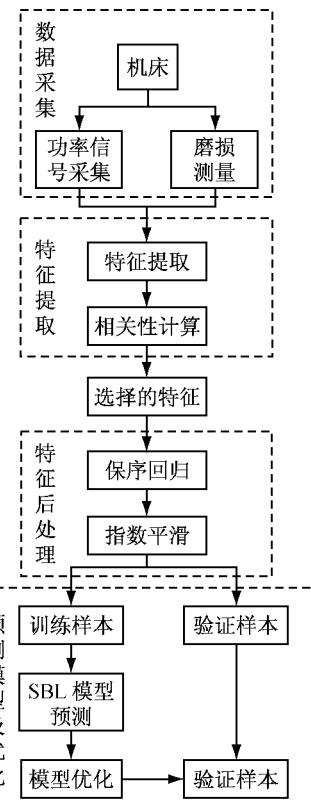


图1 基于功率的刀具磨损量预测方法

Fig. 1 Tool wear prediction approach based on power sensor

(4) 预测模型及优化: 经过后处理的数据特征和显微镜测量刀具磨损量数据形成样本组, 采用基于SBL的识别方法对数据进行建模, 采用多目标优化方法NSGA-II对SBL模型核函数的宽度参数进行优化, 实现刀具磨损量的准确预测.

1.1 特征提取

对采集到的功率信号进行时域特征提取, 利用式(1)计算各特征与刀具磨损量之间的相关系数. $|\rho|$ 越接近 1, 表示该特征与刀具磨损量的相关性越强.

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(V_{ai} - \bar{V}_a)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (V_{ai} - \bar{V}_a)^2}} \quad (1)$$

式中: x_i 为特征值; \bar{x} 为特征均值; V_{ai} 为刀具磨损值; \bar{V}_a 为刀具磨损均值; ρ 为相关系数.

1.2 特征后处理(Re-processing)

正常的刀具磨损是渐变且单调增的过程, 功率信号的相关特征变化情况应能较好地反映这一现象. 如图2所示是铣削加工时在恒定切削参数下每

次走刀材料的切削功率有效值均值(AVG-RMS)变化曲线, 可以看到随着磨损的增大, 有效值均值整体呈增加的趋势, 但由于电网波动等因素的影响, 仍有一些异常变化情况, 具体数据如表1所示. 后处理的过程主要包括保序回归和指数平滑. 保序回归可以使得特征值保持单调不减的趋势; 指数平滑使得特征值变化光滑.

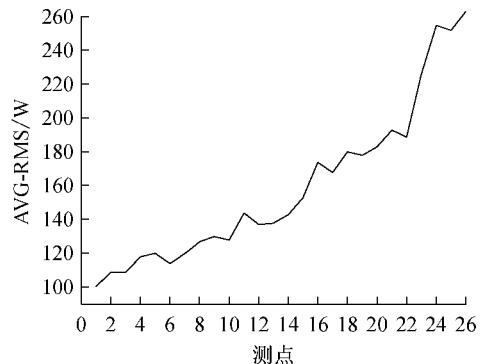


图2 恒定切削参数下材料切削功率有效值均值变化曲线

Fig.2 AVG-RMS curves under the constant cutting parameters

表1 图2曲线各点磨损量和功率值的原始数据

Tab.1 The original data of tool wear and power of AVG-RMS curve in Fig.2

测点	1	2	3	4	5	6	7	8	9	10	11	12	13
刀具磨损量/m	0.0248	0.0264	0.0280	0.0295	0.0344	0.0392	0.0440	0.0542	0.0644	0.0746	0.0895	0.1043	0.1192
原始切削功率有效值均值/W	100.53	109	109	118	120	114	120	127	130	128	144	137	138
测点	14	15	16	17	18	19	20	21	22	23	24	25	26
刀具磨损量/m	0.1305	0.1418	0.1518	0.1617	0.1769	0.1921	0.1987	0.2052	0.2086	0.2231	0.2324	0.2459	0.2938
原始切削功率有效值均值/W	143	153	174	168	180	178	183	193	189	226	255	252	263

(1) 保序回归

设相互独立的变量序列 x_1, x_2, \dots, x_n 满足关系 $x_1 \leq x_2 \leq \dots \leq x_n$. 定义 $g(x_i)$ 为 x_i 的函数, 则 $g(x_i)$ 的保序回归 $g(x_i)^*$ 满足关系: $g(x_1)^* \leq g(x_2)^* \leq \dots \leq g(x_n)^*$. 其中, $g(x_i)^*$ 通过式(2)计算^[18], 得

$$g(x_i)^* = \min_{i \leq n, 1 \leq s \leq i} \max_{s \leq t \leq n} A_v(s, t) \quad (2)$$

式中, $A_v(s, t) = \frac{\sum_{j=s}^t w(x_j)g(x_j)}{\sum_{j=s}^t w(x_j)}$, $0 \leq w(x_j) \leq 1$

(2) 指数平滑

给定时间序列 $x_t, x_{t-1}, \dots, x_2, x_1$, 则经一次指数平滑后的序列如下^[19]:

$$y_i = \alpha x_i + (1-\alpha)y_{i-1} \quad (2 \leq i \leq t) \\ y_1 = \frac{(x_1 + x_2 + x_3)}{3} \quad (3)$$

式中: $0 < \alpha < 1$ 为平滑系数(文中取 0.3); y_i 为时刻 i

的平滑值; y_{i-1} 为时刻 $i-1$ 的平滑值; y_1 为初始平滑值, 在此通过前三个时刻值的平均确定 y_1 .

1.3 刀具磨损量预测模型及优化

稀疏贝叶斯学习是 Tipping^[20] 在支持向量机的基础上提出的用于回归和分类的机器学习法. SBL 采用了贝叶斯推理方法, 模型有着良好的稀疏性, 可避免过学习现象, 同时具有概率预测能力.

1.3.1 SBL 预测模型

给定的模型输入 $Y_{nk} = [y_1, y_2, \dots, y_k]$, 其中的 y_1, y_2, \dots, y_k 分别为经过后处理的 k 个特征. 对应 Y 的每一行 $y_i = [y_{i1}, y_{i2}, \dots, y_{ik}]$ ($i=1, \dots, n$), 其相应的输出为显微镜测量的刀具磨损量 t_i . 假定 t_i 是未知函数和测量误差 ϵ_i 的组合, 即

$$t_i = F(y_i; W) + \epsilon_i \quad (4)$$

式中: ϵ_i 是独立的误差项, 服从高斯分布 $N(0, \sigma^2)$, 则 t_i 服从期望为 $F(y_i; W)$ 方差为 σ^2 的高斯分布. 基于 t_i 独立性的假设, 所有输入的似然函数可表示为

$$p(t|W, \sigma^2) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \|t - \Phi W\|^2\right\} \quad (5)$$

式中: $t = (t_1, t_2, \dots, t_n)^T$ 是输出向量即刀具磨损量, $W = (w_0, w_1 \dots w_n)$ 是权值向量; $\Phi = [\Phi(y_1), \Phi(y_2), \dots, \Phi(y_n)]^T$ 是基函数矩阵,其中 $\Phi(y_i) = [1, K(y_i, y_1), K(y_i, y_2), \dots, K(y_i, y_n)]^T$, W 服从高斯先验分布

$$p(W|\alpha) = \prod_{i=0}^n N(w_i | 0, \alpha_i^{-1}) \quad (6)$$

式中: $\alpha = (\alpha_0, \alpha_1, \dots, \alpha_n)$ 是超参数向量, α_i 是为 w_i 指定的超参数。根据文献[20],最终 W 的后验分布表示为

$$P(W|t, \alpha, \sigma^2) = \frac{P(t|W, \sigma^2)P(W|\alpha)}{P(t|\alpha, \sigma^2)} \quad (7)$$

该分布也是一个高斯分布,方差 Σ 和期望 μ 为 $\Sigma = (\sigma^{-2} \Phi^T \Phi + A)^{-1}$, $\mu = \sigma^{-2} \Sigma \Phi^T t$ 其中, $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_n)$ 。

由于基函数权值向量 W 的期望向量 μ 具有很多零元素,因此模型具有很强的稀疏性。

通过训练样本获得模型的相关参数后,对于新的输入样本 y^* ,预测对应的刀具磨损值 t^* 的分为

$$p(t^* | t, \alpha_{MP}, \sigma_{MP}^2) = \int p(t^* | W, \sigma_{MP}^2) p(W | t, \alpha_{MP}, \sigma_{MP}^2) dW = N(t^* | F^*, \sigma_*^2) \quad (8)$$

其中

$$\begin{aligned} F^* &= \mu^T \Phi(y^*) \\ \sigma_*^2 &= \sigma_{MP}^2 + \Phi(y^*)^T \Sigma \Phi(y^*) \end{aligned} \quad (9)$$

即预测的期望值是 F^* ,方差是 σ_*^2 。

1.3.2 预测模型优化

建立刀具磨损量的SBL模型时,需要选择合适类型的核函数 $K(y_i, y_j)$ 。在高维非线性模型中,高斯核函数

$$K(y_i, y_j) = \exp\left(-\frac{\|y_i - y_j\|^2}{2\eta^2}\right) \quad (10)$$

是最常用的核函数并且有着很好的预测效果,其宽度参数 η 对模型稀疏性和预测精度有重要影响:

(1)若 η 远小于训练样本间的平均距离,则所有的训练样本点都能够被准确预测,但会出现过学习现象,对新的样本无法进行准确预测;

(2)若 η 远大于训练样本间的平均距离,则对于所有的样本都不能进行准确预测。

通常能根据样本初步判断 η 的取值区间,利用算法寻优则可以确定较为合理的取值,使得模型有着良好的预测精度和稀疏性。

定义1 每个样本的相对误差 γ_i 如式(11)所示

$$\gamma_i = \frac{|v_{ai} - v_{pi}|}{v_{ai}} \times 100\% \quad (i = 1, 2, \dots, n) \quad (11)$$

式中: v_{ai} 表示第*i*个样本的实测磨损值; v_{pi} 表示相应的预测值。针对模型训练过程,定义如下目标函数

$$\min \text{obj1} = \frac{1}{n} \sum_{i=1}^n \gamma_i \quad (12)$$

$$\min \text{obj2} = \sum_{i=0}^n a_i \quad (13)$$

式(13)中,若 $w_i = 0$,则 $a_i = 0$;若 $w_i \neq 0$,则 $a_i = 1$ 。

$$\min \text{obj3} = \frac{1}{n} \sum_{i=1}^n (\gamma_i - \text{obj1})^2 \quad (14)$$

上述三个目标无法同时达到最优,因此需要采用优化算法进行多目标寻优。利用基于Pareto寻优的非支配排序遗传算法(Non-dominated Sorting Genetic Algorithm II, NSGA-II)^[21]求解该问题。基于NSGA-II的寻优过程如图3所示。

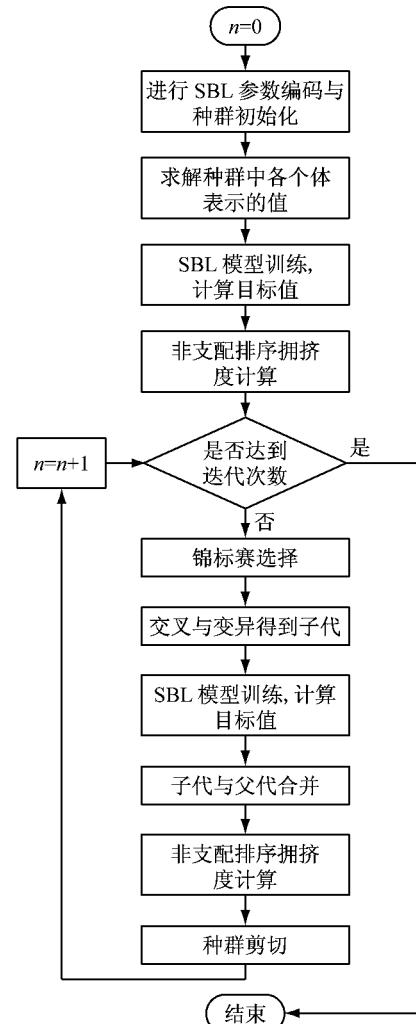


图3 基于NSGA-II的寻优过程

Fig.3 The optimization process based on NSGA-II

2 实验研究

实验加工设备 CFV-550 铣削加工中心,工件材料 45#钢,尺寸 $50 \times 80 \times 100$ mm,刀具型号: $\phi 12$ YG-1 立铣刀,加工参数如表 2 所示。

表 2 加工参数

Tab. 2 The cutting parameters

进给方向	切削长度/mm	$n/(r \cdot min^{-1})$	$f/(mm \cdot min^{-1})$	a_p/mm	a_e/mm
Y	80	1 800	240	3	2.5

使用 HIOKI PW3360 功率仪采集机床的功率信号,该功率仪采样频率为 10.24 kHz,同时自动计算并输出每秒功率有效值。每一次走刀后,减去机床空载功率即可得到如图 4 所示的材料切削功率有效值。图 5 是在每一次走刀结束后,使用显微镜测量刀具后刀面磨损量。

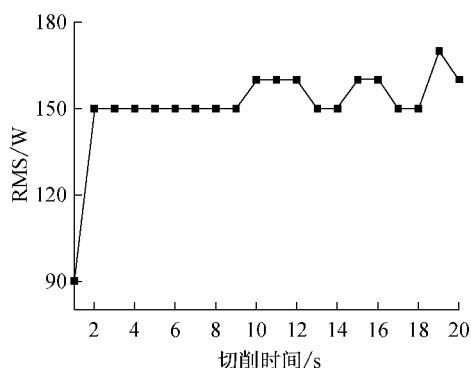


图 4 某次走刀时的材料切削功率有效值
Fig. 4 The RMS value of one single pass

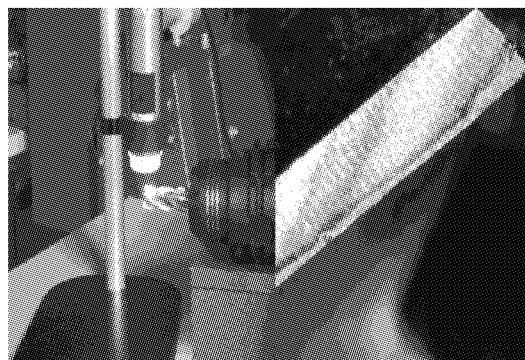


图 5 后刀面磨损测量

Fig. 5 The wear-measurement of flank surface of cutting tools

2.1 样本数据的特征提取与后处理

对图 2 中的数据进行保序回归的处理,其结果如图 6 所示,保序回归对样本点 11~15 和点 21~23 等位置的特征值进行了修正,使得数据满足单调非

减的趋势,体现了刀具磨损的单调非减性。

在图 6 的基础上,对数据进行指数平滑处理,其结果如图 7 所示。

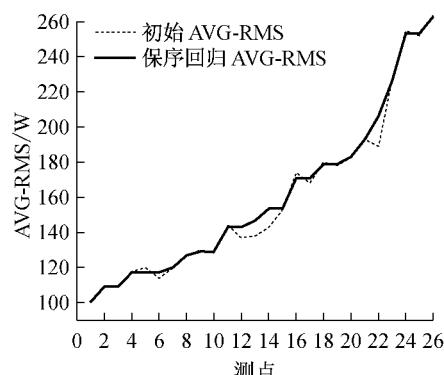


图 6 保序回归处理后的特征
Fig. 6 The features after the isotonic regression

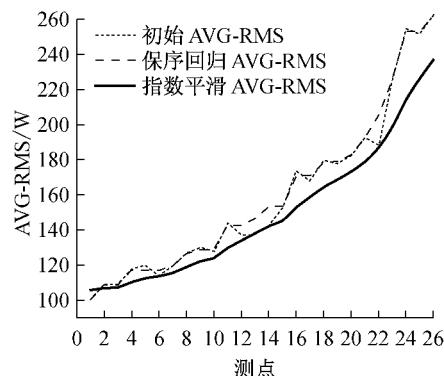


图 7 指数平滑后的特征
Fig. 7 The features after the exponential smoothing

由图 7 可见,指数平滑法在特征值单调非减的基础上保证了其变化的平滑性,反映出刀具磨损的渐变性,可更好地描述刀具磨损的趋势,同时由于保序回归后特征值保持单调不减,因此经指数平滑后的值基本小于或等于初始值。

2.2 刀具磨损量预测结果分析

经后处理的数据分成 2 组,其中 65% 为训练组,其余为测试组。如图 3 所示的 NSGA-II 寻优算法的过程和参数如下:

- (1)参数编码和初始化:针对高斯核函数宽度参数 η ,采用二进制编码,产生规模为 100 染色体长度为 10 的初始种群;
 - (2)对种群中的个体计算相应的目标函数值;
 - (3)进行非支配排序和拥挤度计算;
 - (4)锦标赛选择;
 - (5)交叉变异:交叉率 0.7,变异率 0.1。
- 种群个体目标值均值的进化过程如图 8 所示。图 9 和图 10 是优化后预测模型的训练输出和

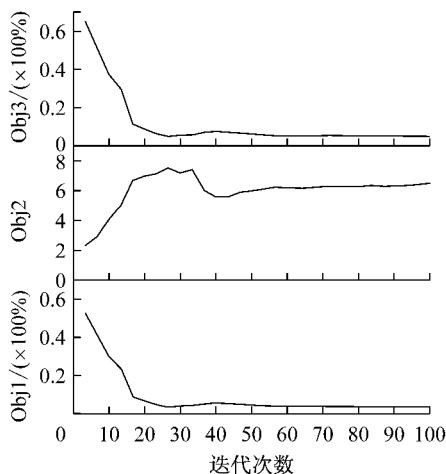


图 8 种群个体目标值均值进化曲线

Fig.8 Target population mean curve evolution

预测输出以及和实际值的比较,训练样本集的相对误差和预测样本集的相对误差如图 11 和图 12 所示。采用样本集平均相对误差(Mean Relative Error, MRE)与最大相对误差(Max Relative Error, Max RE)衡量模型训练和预测精度。训练样本集 MRE 为 4.68%,Max RE 为 13.52%;预测样本集 MRE 为 2.34%,Max RE 为 5.94%。

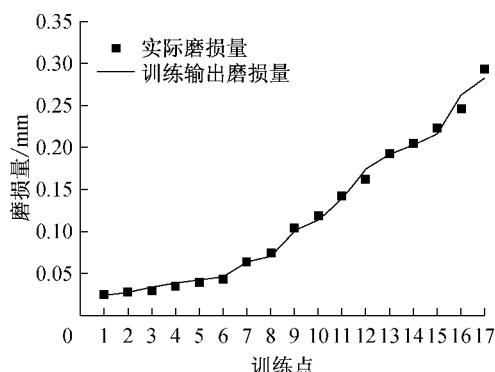


图 9 多目标优化 RP-SBL 模型的训练输出

Fig.9 The training output of the multi-objective optimization model

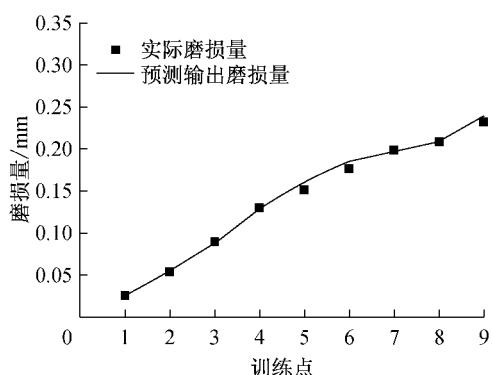


图 10 多目标优化 RP-SBL 模型的预测输出

Fig.10 The predicting output of the multi-objective optimization model

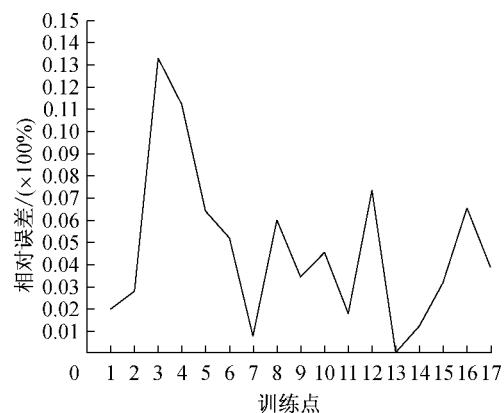


图 11 多目标优化 RP-SBL 模型的训练精度

Fig.11 The training precision of the multi-objective optimization model

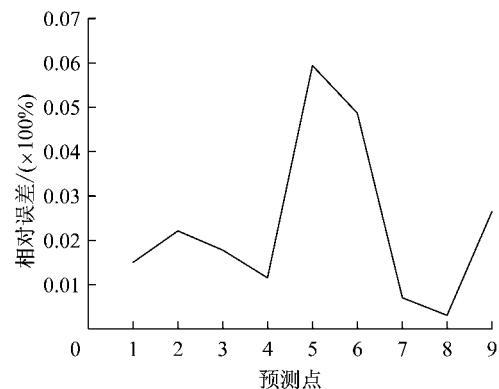


图 12 多目标优化 RP-SBL 的预测精度

Fig.12 The predicting precision of the multi-objective optimization model

2.3 不同预测模型的对比

对如下不同模型进行预测精度分析:①经过特征后处理与优化的预测模型结合 NSGA-II 的 RP-SBL;②经过后处理但未进行参数优化的预测模型 RP-SBL;③未经过后处理与参数优化的预测模型 SBL。三种不同预测模型的分析结果如表 3 所示,对比 RP-SBL 模型与 SBL 模型可以看到特征后处理较大幅度地提高了刀具磨损量的预测精度,将 MRE 值从 11.26% 减小到了 5.26%,Max RE 由 25.52% 减小到 11.96%,模型通过多目标优化后则可以进一步提高预测精度,使 MRE 降低到 2.34%,Max RE 减

表 3 三种预测方法结果分析

Tab.3 The analysis results of 3 prediction approaches

预测方法	平均相对误差/%	最大误差/mm	最大相对误差/%
结合 NSGA-II 的 RP-SBL	2.34	0.009	5.94
RP-SBL	5.26	0.027	11.96
SBL	13.1	0.027	25.52

小为 5.94%，同时使 Max Error 减小为 0.009 mm。

3 结论

(1) 基于经过后处理的功率信号特征,采用稀疏贝叶斯学习方法建立了刀具磨损量预测模型,实现了小样本条件下刀具磨损量的准确预测。

(2) 对功率信号特征进行后处理,提高了特征对刀具磨损的敏感性,保证了刀具磨损量的准确预测。

(3) 使用非支配排序遗传算法对 SBL 预测模型的核函数宽度参数进行优化,进一步提高了模型预测精度,减小预测误差最大值。

参考文献:

- [1] Hessman T. The dawn of the smart factory [J]. Industry Week, 2013, 262(2):14.
- [2] Karuda S, Bradley C. A review of machine vision sensors for tool condition monitoring[J]. Computers in Industry, 1997, 34(1):55.
- [3] Zhang C, Zhang J. On-line tool wear measurement for ball-end milling cutter based on machine vision [J]. Computers in Industry, 2013, 64(6):708.
- [4] Datta R K, Paul S, Chattopadhwaj A B. Fuzzy controlled backpropagation neural network for tool condition monitoring in face milling[J]. International Journal of Production Research, 2000, 38(13):2989.
- [5] Jemielniak K, Arrazola P J. Application of AE and cutting force signals in tool condition monitoring in micro-milling[J]. CIRP Journal of Engineering Manufacture, 2000, 214(7):535.
- [6] G Wang, Z Guo, Y Yang. Force sensor based online tool wear monitoring using distributed Gaussian ARTMAP network[J]. Sensors and Actuators A:Physical, 2013, 192:111.
- [7] Wang G, Cui Y. Online tool wear monitoring based on auto associative neural network [J]. Journal of Intelligent Manufacturing, 2013, 24(6):1085.
- [8] 高宏力,许明恒,傅攀,等.基于动态树理论的刀具磨损监测技术[J].机械工程学报,2006,42(7):227.
GAO Hongli, XU Mingheng, FU Pan, et al. Tool wear monitoring based on dynamic tree [J]. Chinese Journal of Mechanical Engineering, 2006, 42(7):227.
- [9] Iwata K, Moriwaki T. Assessment of machining features for tool condition monitoring in face milling using an artificial neural network [J]. Journal of Engineering Manufacture, 2000, 214(7):535.
- [10] Zhou J H, Pang C K, Zhong Z W, et al. Tool wear monitoring using acoustic emissions by dominant-feature identification[J]. IEEE Transactions on Instrumentation and Measurement, 2011, 60(2):547.
- [11] J M Lee, D K Choi, J Kim, et al. Real-time tool breakage monitoring for NC milling process [J]. CIRP Annals Manufacturing Technology, 1995, 44(1):59.
- [12] Li X, Djordjevich A, Venuvinod P K. Current-sensor-based feed cutting force intelligent estimation and tool wear condition monitoring[J]. IEEE Transactions on Industrial Electronics, 2000, 47(3):697.
- [13] Shao H, Wang H L, Zhao X M. A cutting power model for tool wear monitoring in milling [J]. International Journal of Machine Tools & Manufacture, 2004, 44:1503.
- [14] Dilma Sr D E. Sensor signals for tool wear monitoring in metal cutting operations-review of methods[J]. International Journal of Machine Tools & Manufacture, 2000, 40(8):1073.
- [15] Salgado D R, Cambero I. A tool wear monitoring system for steel and aluminium alloys based on the same sensor signals and decision strategy[J]. Materials Science Forum, 2014, 797:17.
- [16] 刘路,王太勇,蒋永翔,等.基于超球面支持向量机的刀具磨损状态识别[J].农业机械学报,2011,42(1):218.
Liu L, Wang T, Jiang Y, et al. Tool wear state recognition based on hyper-sphere support vector machine [J]. Transactions of the Chinese Society for Agricultural Machinery, 2011, 42(1):218.
- [17] 申中杰,陈雪峰,何正嘉,等.基于相对特征和多变量支持向量机的滚动轴承剩余寿命预测[J].机械工程学报,2013,49(2):183.
SHEN Zhongjie, CHEN Xuefeng, HE Zhengjia, et al. Remaining life predictions of rolling bearing based on relative features and multivariable support vector machine[J]. Chinese Journal of Mechanical Engineering, 2013, 49(2):183.
- [18] Barlow R E, Bartholomew D J, Bremner J M, et al. Statistical inference under order restriction[M]. New York: Wiley, 1972.
- [19] Taylor J W. Smooth transition exponential smoothing [J]. Journal of Forecasting, 2004, 23(6):385.
- [20] Tipping M E. Sparse Bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research, 2001, 1(3):211.
- [21] Deb K. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Transaction on Evolutionary Computation, 2002, 6(2):180.