

doi: 10.7690/bgzdh.2021.12.014

ELM 在机床切削刀具磨损快速检测中的应用

唐鑫¹, 巫茜², 邝茜², 王成睿²

(1. 鼎兆(重庆)包装科技有限公司, 重庆 400050; 2. 重庆理工大学计算机科学与工程学院, 重庆 400054)

摘要: 为检测加工过程中切削刀具的磨损和破损, 探讨一种基于声音识别的超限学习机(extreme learning machine, ELM)模型检测方法。论述切削声音信号的时频域特性, 讨论基于小波包分解的刀具工作状态敏感频谱能量统计特征量提取方法, 构建基于声音特征量识别的 ELM 快速检测模型。以某操作现场刀具切削磨损声音信号识别实验为例, 实测数据验证了采用该模型可获得更高的检测准确度且响应速度更快。实验仿真结果表明: 采用 ELM 模型借助声音识别检测切削刀具磨损的方法是有效的。

关键词: 切削刀具破损; 声音识别; 时频特性; 小波包分解; ELM 检测模型

中图分类号: TP273 **文献标志码:** A

Research on Application of Extreme Learning Machine in Rapid Detection of Cutting Tool Wear in Machine Tools

Tang Xin¹, Wu Qian², Kuang Xi², Wang Chengrui²

(1. Dingzhao (Chongqing) Packaging Technology Co., Ltd., Chongqing 400050, China;

2. College of Computer Science & Engineering, Chongqing University of Technology, Chongqing 400054, China)

Abstract: In order to detect the wear and breakage of cutting tools during machining, an extreme learning machine (ELM) model detection method based on sound recognition was proposed. The time-frequency domain characteristics of cutting sound signal were discussed, and the extraction method of cutting tool status-sensitive spectrum energy statistical feature quantity based on wavelet packet decomposition was discussed. A fast ELM detection model based on sound feature quantity recognition was constructed. An example was taken for the identification of cutting wear sound signal in an operation site. The measured data verify that the proposed model can obtain higher detection accuracy and faster response speed. The experimental simulation results show that the ELM model is effective in detecting cutting tool wear with sound recognition.

Keywords: cutting tool damage; voice recognition; time-frequency characteristics; wavelet packet decomposition; ELM model

0 引言

在高速机械精加工过程中, 由于刀具刀尖和外切削刃承受着巨大的机械冲击、振动和高温、高压等复合载荷, 极易引发刀具失效导致的突发崩刃等事故, 轻则造成工件报废, 重则可能导致机床损坏; 因此, 如何及时准确地辨识刀具运行状态已成为智能机械制造领域的研究热点。迄今为止, 无论是直接检测还是间接检测方法, 都存在某些不足或者弊端, 有的甚至需要生产线停机才能对刀具状态进行检测, 付出的代价较高, 因此其检测方法^[1-6]并不一定都是可取的。值得关注的现象是: 一个切削操作经验非常丰富的熟练操作工, 常凭借对来源于切削区域声音信号经耳朵的直觉判断, 就可分辨出切削刀具运行是否处于正常状态, 或者分辨出切削刀具的磨损与破损程度。这是因为熟练操作工经过长期

的训练与学习, 其由耳朵感知系统和大脑神经网络所组成的听觉系统对声音频谱能量非常敏感, 并且其听觉系统对声音频谱能量的些微变化还表现出很强的鲁棒性。受上述听觉系统启发, 笔者采用超限学习机(ELM)模型模仿熟练操作工识别切削刀具的声音能谱特性^[7-8], 借助人工智能的方法检测加工刀具可能产生的磨损状态。

1 刀具切削声音信号的特征提取

1.1 刀具状态声能谱特征分析

切削刀具声音为非语音信号, 表达的是一个非平稳的过程。人们关注的重点在于对信号进行时域、频域以及功率谱分析, 以便找出与刀具运行工作状态相关性极强的特征量, 并建立时域特性参数与刀具工作状态之间的映射关系, 从而确定表征刀具工

收稿日期: 2021-08-12; 修回日期: 2021-09-24

基金项目: 重庆市科技局重点项目(cstc2019jsx-fxydX0047); 重庆市科技局重点项目(cstc2019jsx-fxydX0090)

作者简介: 唐鑫(1980—), 男, 重庆人, 硕士, 工程师, 从事大数据、人工智能、产业互联网研究。E-mail: franckytang@kingzon.ltd.

作状态的参数特征向量。傅立叶变换与小波分析方法相比^[9-10]，后者可在时域和频域 2 方面同时对信号的低频频率特性细分和高频时间特性细分，更有利于提取出反映表征刀具工作状态的特征向量；特别是其中的小波包分析，无论在信号低频区域还是在高频区域都可进行多分辨率分析，是一种从高低频区都能更好地分析时频局部特征的分析方法^[11-14]。假设刀具切削声音原始信号的频率区间为 $[0, f_{\max}]$ ，经过一层小波分解之后，声音信号可分别在近似部分即频率段 $[0, f_{\max}/2]$ 和细节部分即频率段 $[f_{\max}/2, f_{\max}]$ 上对信号图像做充分的表达。以此类推，信号在经过 n 层小波包分解之后，在声音信号

的近似部分可获得在频率段 $[0, f_{\max}/2^n]$ 上的信号表达，细节部分可获得在频率段 $[f_{\max}/2^n, f_{\max}/2^{n-1}]$ 上的信号表达。例如，一个 5 层小波包分解如图 1 所示，图中 S、L 和 H 分别代表切削声音信号、信号分解后的低频和高频特性表达，其末尾的序号表示所在的分解层数，图 1 所示为高低频分解、L1 和 H1 的近似和细节特性部分的小波包分解。图 2 为近似部分 L1 的小波包分解，图 3 为细节部分（高频部分）H1 的小波包分解。

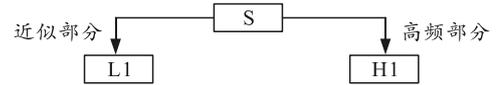


图 1 小波包低频高频分解

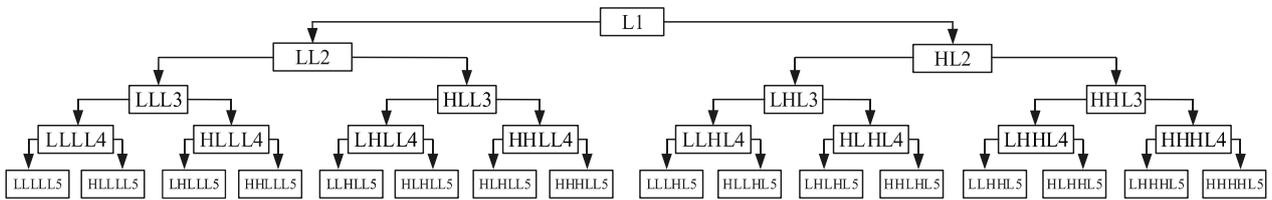


图 2 近似部分 L1 的小波包分解

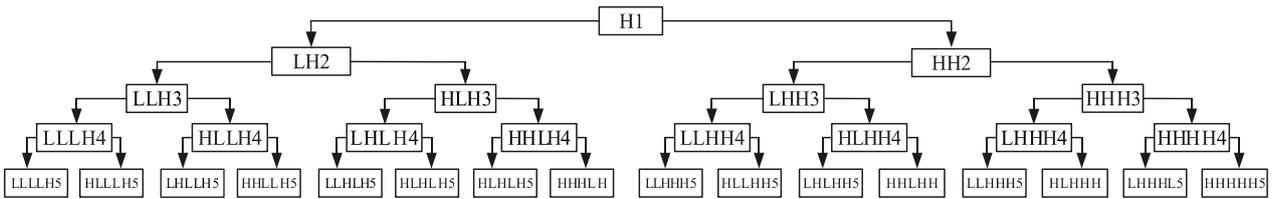


图 3 细节部分 H1 的小波包分解

每次分解所获得的细节和近似特性 2 部分的长度相加就是上一层信号的长度，在对信号进行多层分解后，最后一层各个部分的信号长度之和就是总的原始信号的长度。采用小波包分解方法的优势为：该方法可做到让切削声音信号在各个微小频率段进行信号表述的同时不会丢失原始信号的任何信息；因此，其精确度极高。

1.2 基于小波包分解的声音信号特征提取

基于对切削声音信号的 n 层小波包分解，可直接求出信号在第 n 层各个频率段部分的小波包系数。该系数决定了原始信号各个频率段的频率能量值大小，再借助图 1 就可读取信号在第 n 层分解部分各个频率段的节点信息，从而完成对声音信号能谱特征的提取。值得注意的是：其节点顺序代表的是时域信息，即各个微小频率段频率变化的顺序。在获取声音信号从低频到高频的小波包系数之后，计算出各频率段所占有的能量：

$$E_{i,j} = \int |S_{i,j}(t)| dt = \sum_{k=1}^n |d_{j,k}|^2 \quad (1)$$

式中： $E_{i,j}$ 为第 i 层第 j 个节点的能量， i, j 均为整数； $d_{j,k} (k=1, 2, \dots, n)$ 为 $S_{i,j}$ 的小波系数。

求出各频率段区间能量后，可获得各频段能量占原始信号总能量的百分比：

$$L_{i,j} = E_{i,j} / E ; E = \sum_{j=1}^{n+1} E_{i,j} \quad (2)$$

2 基于 ELM 的刀具状态识别模型

2.1 机器学习模型

在如图 4 所示的机器学习模型中， x, y 分别为实际系统输入、输出的采样样本，学习样本集合为 $\{x, y\}$ 。所谓机器学习是指在最小期望风险条件下，寻找出实际系统的预测输出。

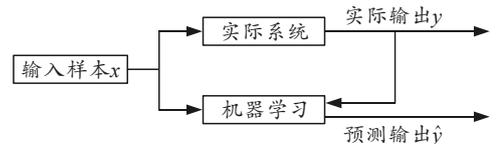


图 4 机器学习

文献[15]指出：极限学习机 ELM 是一种新型神经网络，是一种简易有效的单隐层前馈神经网络学

习算法。只需设置网络的隐层权重个数, 无需调整网络的输入权重 W 及隐层神经元的偏置。ELM 具有参数选择容易、学习速度快且泛化性能好的优点, 具有学习能力强, 能逼近任意复杂连续函数。该网络中的基本信息处理单元为神经元。如图 5 所示的第 k 个神经元就是一个多输入-单输出的非线性系统。

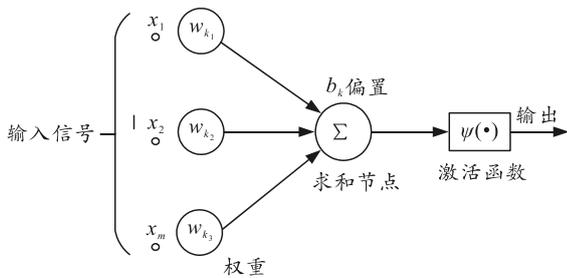


图 5 神经元模型

图中: 输入信号为 x_1, x_2, \dots, x_m , 其与第 k 个神经元对应的权重分别为 $w_{k_1}, w_{k_2}, \dots, w_{k_m}$; $\psi(\cdot)$ 为激活函数; b_k 为求和节点设置的偏置; u_k 为输入信号的线性组合; y_k 为神经元的输出; $u_k = \sum_{j=1}^m w_{kj} x_j$, $y_k = \psi(u_k + b_k)$ 。

$\psi(v)$ 的作用在于限制神经元的输出幅度, 通常选择为 Sigmoid 函数。

2.2 ELM 算法模型

ELM 在机器学习和人工智能领域获得了广泛的关注, 现已逐渐扩展到了人类行为识别、故障诊断等多个领域的应用。一个包含 M 个隐含层节点的 ELM 结构如图 6 所示。

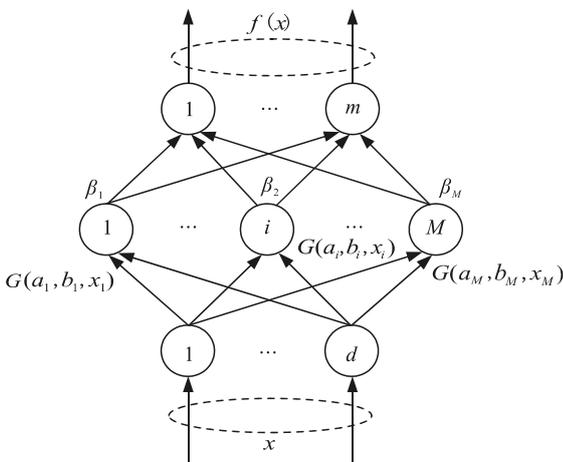


图 6 ELM 结构

图中: 激活函数 $G(a_j, b_j, x)$ 选为 Sigmoid 函数, a_j, b_j 分别为输入和隐含层之间的连接权重和偏置

值; $\beta_{L \times M}$ 为隐含层与输出层之间的权重矩阵。输入层与隐含层之间的权重随机产生, 输入层与隐含层以及隐含层与输出层之间均为全连接, N 为采样样本数; x_i 为采样数据; t_j 为分类标签号; 相互之间关系满足:

$$\{(x_i, t_j)\}_{j=1}^N \subset R^n \times R^m. \quad (3)$$

ELM 计算分为 2 个步骤:

1) 针对实验采集的所有训练样本, 计算出隐含层节点的输出矩阵:

$$H = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_1) \\ \vdots & & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}. \quad (4)$$

2) 借助最小二乘法, 计算出隐含层节点的最优输出权重矩阵:

$$\|H\hat{\beta} - Y\| = \min_{\beta} \|H\beta - Y\|. \quad (5)$$

当样本数 N 大于或等于隐含层节点数 L , 计算最优输出权重矩阵:

$$\hat{\beta} = (1/C + H^T H)^{-1} H^T Y. \quad (6)$$

否则, 计算最优输出权重矩阵:

$$\hat{\beta} = H^T (1/C + H H^T)^{-1} Y. \quad (7)$$

式中 $Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_N^T \end{bmatrix}_{N \times M}$ 。

以下对计算过程作一些必要的解释^[16-17]。

1) 理论已证明: 只要单隐层节点的数目 L 足够, 激活函数 $G(a_j, b_j, x)$ 在任意区间内都能实现无限可微, 在此前提下网络参数无需做任何调整。

2) 最优输出权重矩阵具有下列特征。

① 采用最小二乘法计算出的输出权重矩阵 β 估计值, 可使 ELM 算法获得最小的训练误差。

② β 的估计值是最小范式, 由此可知 ELM 网络具有最佳的泛化能力。

③ β 估计值具有唯一性, 因此 ELM 输出是全局最优解而非局部最优解。

ELM 模型算法的优势: 在应用中, 只需设置隐含层节点数和选择激活函数, 不存在人为干扰; 因此, 学习速度快, 泛化能力好, 所获得的计算结果是全局最优解。基于上述独特优势, 笔者尝试采用该 ELM 算法识别刀具切削声音信号的能谱特性以检测运行切削刀具的工作状态。

3 实验仿真及其结果分析

3.1 实验仿真准备

测试现场某卧式钻床环境和声音传感器的安装如图 7 所示, 当其刀具在空转、初期正常、严重磨损和刀具崩刃的 4 种状态下某时刻的钻削加工时域特性如图 8—11 所示。

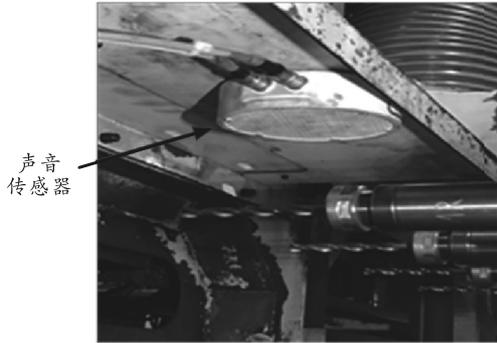


图 7 测试现场

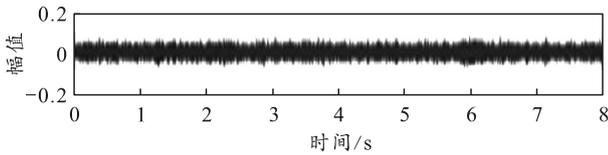


图 8 刀具空转声音时域

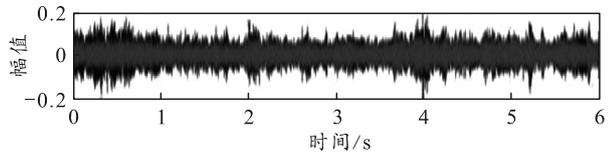


图 9 刀具钻削声音时域

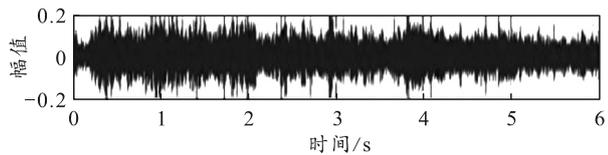


图 10 严重磨损刀具钻削声音时域

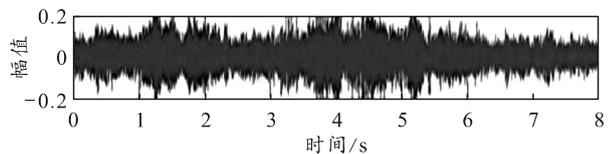


图 11 刀具崩刃钻削声音时域

由 Matlab 频谱分析可知: 刀具空转时, 噪声频谱分布在 300 Hz~1.6 kHz 范围; 正常工作时, 声音频谱在 150~1 000 Hz 范围; 严重磨损时, 声音频谱分布在 300 Hz~1.4 kHz 和 1.8 Hz~3 kHz 2 个频率段。当刀具分别处于正常、严重磨损和破损(崩刃)状态时, 不同切削声音信号各频带能量在总能量中的占比是不同的。图 12 记录了在 5 层小波包分解下, 各频带能量在总能量中的占比数值。

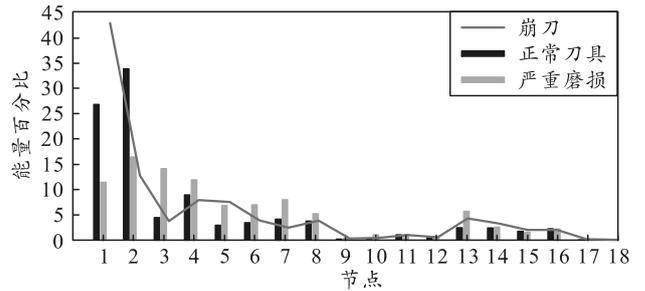


图 12 各频带能量值占比

从上图可知: 节点 17 以后的各个节点能量占比均小于 0.01%, 可忽略不计, 基于此可确定 ELM 的输入层节点。特征输入向量为 16, ELM 模型的输入层节点数选择为 16, 其特征输入向量按节点顺序排成一个数组, 以能谱特征向量形式表征了切削刀具所处的工作状态。

隐藏层节点数的确定。显然, 节点数过少, 会出现欠拟合导致识别精度降低; 反之, 会出现过拟合, 造成学习时间长而难以识别新增样本等问题。基于经验公式、试验与计算相结合, 反复实验表明: 当隐含层节点为 118 时, 模型识别精度最高, 其样本训练时长也最短; 因此隐含层节点数确定为 118。

输出层节点数的确定。为简化讨论, 将刀具工作状态类型分为正常、严重磨损和破损(崩刃)3 种状态, 输出节点选择为 3, 即每种状态对应于一个输出节点, 并在实验中分别用标签号 1、2 和 3 表示。

按 5 层小波包分解的各个节点频带能量占比值符合刀具切削声音信号能谱特征, 样本数据基于 Matlab 平台采集。在大量采集的实验数据样本中, 随机抽取正常刀具标签号 1、崩刃标签号 2 和严重磨损标签号 3 的 3 种状态各 200 组数据, 共计 600 组实验数据作为样本, 在不同状态下的特征值样本能谱实验数据记录如表 1 所示。

表 1 能谱特征值样本记录

序号	节点 1	节点 2	节点 3	...	节点 16	刀具状态	输出标签
1	26.617 1	33.074 0	4.582 7	...	2.014 5	正常	1
2	27.069 7	32.599 0	4.436 7	...	2.058 7	正常	1
3	26.243 1	33.094 9	4.742 9	...	2.127 6	正常	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
200	30.246 8	38.311 5	5.362 3	...	1.034 2	正常	1
201	36.143 9	27.006 4	3.886 1	...	1.792 5	破损	2
202	32.603 9	31.646 6	3.774 4	...	1.690 3	破损	2
203	35.691 8	29.460 7	3.590 7	...	1.656 0	破损	2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
400	41.741 8	16.763 6	4.251 4	...	1.810 8	破损	2
401	11.201 9	14.619 1	15.285 6	...	2.807 6	严重磨损	3
402	10.684 6	13.027 4	15.859 9	...	3.539 3	严重磨损	3
403	12.404 0	18.221 4	16.838 8	...	1.999 2	严重磨损	3
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
600	9.930 5	14.915 7	16.693 8	...	2.173 1	严重磨损	3

3.2 实验结果及其分析

实验中选择 Sigmoid 函数作为 ELM 模型的激活函数,并在实验仿真前对表 1 中能谱特征值样本记录的所有能谱特征值样本数据进行归一化处理。首先,在经归一化处理后对应于能谱特征值样本记录的正常、严重磨损和破损(崩刃)3 种状态下各选取前 100 组数据作为 ELM 模型的学习训练样本,并以此为准完成对 ELM 模型的参数训练;然后,各选取 3 种状态下的后 100 组数据作为测试样本再进行测试,并将其作为实验仿真的最终测试结果,刀具工作状态的最终识别结果如表 2 所示。

表 2 刀具工作状态识别结果

状态	状态分类号	测试样本数	正确识别个数
正常	1	100	93
崩刃	2	100	89
严重磨损	3	100	95

由上表可见:3 种状态的正确识别率分别为 93%、89%和 95%。由于切削刀具磨损实际运行时,ELM 模型是在“在线状态”下运行的;因此,在实际工程应用中,其实时性是相当高的。

4 结论

初步研究结果表明:基于 ELM 模型对切削刀具磨损状态采用声音识别方法进行检测是有效的。加工过程中,切削刀具磨损故障的判断很复杂。受到机加工现场、刀具类型数据采集等实验条件的限制,加上故障分类也不够细致,笔者只完成了原理性验证,要真正将探讨的方法投入实际生产应用,还有许多问题有待解决。

参考文献:

- [1] 李勇,王细洋,王学超. 基于 AR 模型的铣刀磨损诊断[J]. 失效分析与预防, 2009, 4(1): 24-29.
- [2] 王利强,李绍朋,吕志杰. 刀具失效状态监测研究综述[J]. 机电技术, 2019(4): 110-114.
- [3] 张学忱,刘红岩,史尧臣,等. 基于声发射信号的振动

- 钻削刀具磨损状态监测试验研究[J]. 机床与液压, 2020, 48(13): 189-192.
- [4] 艾长胜,何光伟,董全成,等. 基于切削声 LPCC 的刀具磨损监测[J]. 中国机械工程, 2009, 20(17): 2045-2048.
- [5] 艾长胜,董全成,灵向博,等. 基于声信号小波分析的刀具破损监测[J]. 组合机床与自动化加工技术, 2007(10): 54-56.
- [6] 朱国奎,张敏良,朱鹤. 基于铣削声音信号的刀具状态实验研究[J]. 轻工机械, 2017, 35(1): 54-58.
- [7] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1): 489-501.
- [8] BOGGESS A, NARCOWICH F J. 小波与傅里叶分析基础[M]. 2 版. 北京: 电子工业出版社, 2010, 175-183.
- [9] 刘鑫. 基于小波分析的强噪声环境下弱信号提取研究[D]. 南京: 南京大学, 2012.
- [10] 高延峰,王齐胜,黄林然,等. 基于人耳听觉模型的 MIG 焊接滴过渡状态识别[J]. 机械工程学报, 2019, 55(17): 68-76.
- [11] MANNAN M A, SHRAF A, KASSIM A, et al. Application of image and sound analysis techniques to monitor the condition of cutting tools[J]. Pattern Recognition Letters, 2000(21): 969-979.
- [12] 郝碧君,陈妮,李亮,等. 基于小波包分析和 LS-SVM 的钻削刀具状态识别研究[J]. 工具技术, 2019, 53(12): 3-9.
- [13] 李涛,黄新宇,罗明. 基于小波包分解的刀具磨损特征分析[J]. 组合机床与自动化加工技术, 2020(7): 10-15.
- [14] 锁小红. 刀具磨损破损监控技术[J]. 现代制造技术与装备, 2016(10): 115-117.
- [15] 宋巧君. 基于 ELM 神经网络的研究与应用[D]. 南京: 南京信息工程大学, 2016.
- [16] 关山,聂鹏. 在线金属切削刀具磨损状态监测研究的回顾与展望 III: 模式识别方法[J]. 机床与液压, 2012, 40(3): 148-153.
- [17] 罗丹. 基于极限学习机的过程监控方法研究[D]. 广州: 华南理工大学, 2018.