

基于大数据分析技术的刀具寿命预测研究

朱凌锋,曹槩,邹付军,康安辉,雷达尊
(天地(常州)自动化股份有限公司,江苏常州 213000)

摘要:为了提高刀具寿命预测精度,提出基于大数据分析技术的刀具寿命预测方法。构建刀具磨损预测模型,更新网络结构参数,训练并处理测试数据,利用大数据分析获取刀具磨损时窗中的历史序列信息,评估历史不同序列的异常数据值,确定异常数据,更新健康指标,分析刀磨工艺,划分磨耗阶段,制定刀具健康指数评价标准,实现刀具寿命预测。实验结果表明:所提方法的预测刀具寿命与实际刀具寿命一致,具有精准的预测效果。

关键词:大数据分析技术;刀具寿命;刀具磨损;健康指标;走刀

中图分类号:TG711 **文献标志码:**B **文章编号:**1671-5276(2022)04-0148-04

Research on Tool Life Prediction Based on Big Data Analysis Technology

ZHU Lingfeng, CAO Shuo, ZOU Fujun, KANG Anhui, LEI Dazun
(Tiandi (Changzhou) Automation Co., Ltd., Changzhou 213000, China)

Abstract: In order to improve the accuracy of tool life prediction, a tool life prediction method based on big data analysis technology is proposed. The tool wear prediction model is built. The network structure parameters are updated, and the test data is trained and tested. The big data analysis method is used to obtain the historical sequence information in the tool wear time window. The abnormal data values of different historical sequences are evaluated, and the abnormal data is determined. The health indicators are updated, the tool wear process is analyzed, the wear stages are divided, and the evaluation criteria of tool health index is formulated. Thus tool life prediction is realized. The experimental results show that the predicted tool life of the proposed method is consistent with the actual tool life, and has accurate prediction effect.

Keywords: big data analysis technology; tool life; tool wear; health indicators; feeding

0 引言

刀具是机械加工的重要工具,关系着产品的加工质量与速度。高效、合理地使用刀具,能够缩短加工时间,提高工作效率。由于在加工过程中所使用的刀具磨损较大,所以加工成本较高。刀具磨损会影响加工效率和人员安全,在极端情况下,刀具检查、维修和更换所耗费的时间甚至是整个工作时间的一半。因此,最大限度地提高刀具寿命和预测刀具寿命至关重要。黄志平等^[1]提出基于数据驱动的铣削刀具寿命预测研究方法,通过构建轨迹相似度和支持向量回归机的综合预测模型,结合时域和小波处理方式,确定刀具磨损与信号特征量的关系,输出刀具寿命预测结果;陈小康等^[2]提出基于 Bagging 集成高斯过程回归模型的刀具寿命预测方法,该方法结合 Bagging 集成高斯过程回归模型,预测刀具寿命,结合时域和频域分析方法,提取信号的频域特性。整合 Bagging 算法和距离相关系数,输出调整结果,得到刀具寿命预测结果。虽然以上两种方法都可以迅速预测刀具寿命,但由于刀具受刀面纹理的影响,刀具磨损信息难以直接获取,很难作出精确的寿命预测。为了解决上述方法中存在的问题,本文提出一种大数据分析技术的刀具寿命预测研究方法。

1 大数据分析技术的刀具磨损预测模型构建

运用大数据分析技术,获取全样本变工况因子数据,使其具有增量学习能力,不断融合新的工况条件,得到更准确的预测模型。在此基础上,提出了一种新的刀具状态特征向量的增量学习方法,通过不断地融合学习环境,得到更准确的预测模型,为进一步分析影响刀具磨损的相关因素提供了依据^[3]。

基于大数据分析技术与现有数据驱动、Bagging 集成高斯过程回归模型相比,能够在复杂工作条件下,提高变工况下刀具磨损状态预测的准确性。

在输入新工况向量的基础上,判断工况是否是已知刀具磨损状态,如果是已知刀具磨损状态,则通过下式进行增量学习:

$$J(\mathbf{x}, \theta + \Delta\theta) = \frac{1}{2} \Delta y_n^T \Delta y_n \quad (1)$$

式中: \mathbf{x} 为新输入的工况向量; θ 为网络参数; T 为切削温度; n 为可控系数; Δy 为实际输出与网络输出的差值。由增量学习获取的误差函数,其计算公式为

$$J(X, \theta + \Delta\theta) = \frac{1}{2} \Delta y_n^2 = \frac{1}{2} (f(x, \theta + \Delta\theta) - y)^2 \quad (2)$$

式中: X 表示刀具磨损参数; $f(x, \theta)$ 为当参数为 θ 时, x 经过非线性映射 f 得到的实际输出。求解式(2)的一阶近似式为

$$\frac{1}{2} (f(x, \theta + \Delta\theta) - f(x, \theta) + f(x, \theta) - y)^2 \cong \frac{1}{2} \left(\frac{\partial f(x, \theta)}{\partial \theta} \Delta\theta + \Delta y \right)^2 \quad (3)$$

式中 $\Delta\theta$ 的求导公式表达为

$$\Delta\theta = -u \left(\frac{\partial f(x, \theta)}{\partial \theta} \right)^{-1} \Delta y \quad (4)$$

式中 u 为学习效率。这样以参数 $\theta + \Delta\theta$ 的更新代替原有参数 θ 。

切削加工刀具磨损以多种磨损机制为主, 切削温度低于 600°C 时对磨损机理有重要影响^[4]; 切削温度超过 600°C 时, 刀具磨损模式为扩散磨损, 降低了刀具磨损程度, 模型中可以不考虑磨粒磨损。经研究发现, 刀具磨损过程中, 温度一般都超过 600°C , 此时扩散磨损起到了关键作用, 加剧了刀具的磨损程度^[5-7]。基于此, 在综合考虑热工失稳对刀具磨损的影响后, 设定以 600°C 为阈值的判断条件, 并充分考虑扩散磨损机理, 构建数学模型, 其计算公式为

$$\begin{cases} \frac{dw}{dt} = \frac{dw_1}{dt} + \frac{dw_2}{dt} & T < 600^\circ\text{C} \\ \frac{dw}{dt} = \frac{dw_2}{dt} + \frac{dw_3}{dt} & T \geq 600^\circ\text{C} \end{cases} \quad (5)$$

式中: $\frac{dw}{dt}$ 为刀具在某段时间内的磨损率; dw_1 为磨损程度; dw_2 为黏结磨损程度; dw_3 为扩散磨损程度^[8]。对于这三种程度下的变化率情况进行详细分析:

1) 磨粒磨损率

在刀具磨削过程中, 前面刀直接与硬颗粒接触。在受到压力的情况下, 刀具磨削产生的硬颗粒直接嵌入到刀具里, 刀具受到硬颗粒影响会形成凹槽, 这就造成了刀具表面出现一定的磨损^[9]。在标准滑动距离内, 硬颗粒在刀具表面留下磨痕, 消磨的体积就是磨粒磨损量。因此, 需先假设磨粒是尖锐的, 其产生的摩擦温度不会对刀具磨损产生影响, 由此可计算出刀具磨损率^[10]。

2) 黏结磨损率

将接触表面上的扩散层结构和元素浓度看作恒定的常数, 结合切屑上硬质颗粒的高度和两相邻硬质颗粒的平均间距, 可计算出黏结磨损率^[11]。

3) 扩散磨损率

刀具在工作环境下与硬颗粒摩擦出现高温, 是由其切屑流动中的 Co 元素所引起, 为此, 可以将扩散磨损率表示为温度与刀具间的滑动速度函数。

2 大数据分析技术的刀具寿命预测流程设计

结合上述分析的刀具磨损、黏结、扩散程度, 构建刀具磨损预测模型, 设计刀具寿命预测流程如下所示:

步骤一: 更新参数

在不属于已知刀具磨损状态的情况下, 采用网络更新的方法研究这种添加工况。结果表明, 每增加一个神经元, 增加一行和一列加权矩阵, 这会使偏置向量分量增大^[12]。通过加入神经元, 将矩阵赋权, 增加偏置向量, 更新网络结构参数。

步骤二: 数据训练

从某个时间节点将健康指标分成两段, 第一段为训练数据, 是模型训练的结果。对训练数据进行分段重组, 形成多个重叠序列, 序列长度 n 是利用历史健康指数, 预测下一阶段健康指标的值; 根据经验设定初始值, 利用贪心策略进行优化; 第二段为测试数据, 这两种数据的处理结果如图 1 所示。

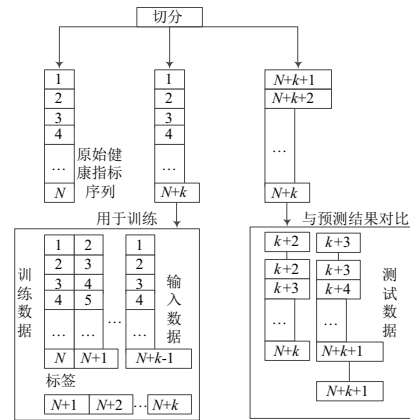


图 1 训练数据与测试数据处理

由图 1 可知, 模型训练之后, 健康指标下一时刻的值从训练数据的最后时刻开始预测。将预测结果添加到序列的尾部作为已知数据, 舍弃原始序列头的值, 不断循环以得到健康指标的未来趋势。

步骤三: 优化神经网络

在新的条件下, 通过增加隐含神经元的结构更新会降低神经网络的学习性能, 即出现冗余网络连接。此时, 神经网络权重矩阵 W 执行 SVD 分解, 其计算公式为

$$W = U \Sigma V^T \quad (6)$$

式中: W 表示网络权重矩阵; Σ 表示对角矩阵; U 和 V 表示分解矩阵。在对角矩阵中, 其权重 = 0 或接近 0 意味着网络中有冗余。删除冗余数据, 可缩短优化时间。

步骤四: 数据分析处理

1) 在数据时间分量中添加时窗, 由于在刀具磨损过程中存在大量的时间序列数据, 所以每一步时窗都需要结合时间分量和生成的子序列来获取不同时间段内的观察数据;

2) 利用大数据分析技术分析刀具磨损不同时窗中子序列的内在结构, 获取每块矩阵中的时窗种类;

3) 利用每块矩阵, 在不同的时间窗口赋予种类异常值, 从而建立刀具磨损连续窗之间的关系;

4) 在刀具磨损的不同时窗内对子序列进行聚类处理, 揭示刀具磨损数据在不同时间段的结构特征;

5) 利用数据分析方法获取刀具磨损时窗中的历史序列信息, 对不同序列的异常数据值进行评估, 综合这些评

估结果,在每个时窗中确定异常数据。

步骤五:刀具磨损量变化情况分析

分析刀具磨损量与走刀数之间的关系结果如图2所示。




图2 刀具磨损量变化曲线

由图2可知,磨削初期刀具磨损较快,原因是新刀具刚开始切削时刀刃非常锋利,后刀面逐渐与工作目标接触面积减小,从而加快刀具磨损速度。在磨削中期,刀具磨损逐渐增加,达到稳定磨损阶段,此时接触面的承受压力慢慢降低。由于磨削时间长,刀具磨损突然增加,切削力、切削温度明显提高,磨削过程中如继续使用刀具,会严重影响工件和机床的加工,必须更换刀具。

步骤六:刀具磨损阶段划分

刀损分级是把刀具的磨损状态分为初期磨损状态、稳定磨损状态和急剧磨损状态3种类型。结构件实际加工时,工件表面加工质量和精度标准较高,刀具磨损量大,同时对工件的质量也有很大的影响。因此,在实际生产加工中,刀具远未达到 $V_b = 0.3 \text{ mm}$ 的磨钝标准,就必须采取换刀操作。

在实际生产现场,由于所收集的刀具磨损值通常刚刚超过 0.1 mm ,为此,采用上述磨损分级方法比较符合现场生产的实际情况。

磨损阶段的划分和分类标签见表1。

表1 磨损阶段的划分和分类标签 单位:mm

磨损阶段	刀具磨损程度
初期磨损	0~0.03
稳定磨损	0.03~0.10
急剧磨损	>0.10

步骤七:结合刀具健康指数预测

在实际应用中,设备退化过程是不可逆的,刀具也是如此。从理论上讲,刀具健康指标应该是单调性增加或减少,该过程的公式为

$$M = \left| \frac{N_{o_i} - N_{o_j}}{L-1} \right| \quad (7)$$

式中: N_{o_i} 表示目标差值序列中 >0 的数量; N_{o_j} 表示目标差值序列中 <0 的数量; L 表示健康指标序列的长度。

随着作业时间的延长,机械设备的退化程度越来越严重。因此,健康指标应该与工作时间有关,这是一种趋势。潮流度衡量的是健康指标与时间的线性相关,其计算公式为

$$T_{\text{red}} = \frac{\left[\sum_{k=1}^{k=1} (h_k - \bar{H})(t_k - \bar{T}) \right]}{\sqrt{\sum_{k=1}^{k=1} (h_k - \bar{H})^2 \sum_{k=1}^{k=1} (t_k - \bar{T})^2}} \quad (8)$$

式中: h_k 表示健康指标序列的第 k 个值; \bar{H} 表示健康指标序列的均值; t_k 表示第 k 点位置上的累积时间,即时间序列的均值。

在刀具数据采样频率不变的情况下,数据序号序列等价于时间序列。上述两个指标都是无因次指标,且健康指标越大,评价值也越高。因此,两者平均值可作为刀具健康指标的综合评价指标。结合上述得到的刀具健康指标,预测刀具的寿命,其计算过程如下:

$$\delta = \frac{T_{\text{red}} h_k \times t_k D_0^q}{v_0 \times a^p \cdot (f^y \times Z^p)} \quad (9)$$

式中: D_0^q 表示刀具直径; v_0 表示刀切速度; a^p 表示加工深度; f^y 表示每齿进给量; Z^p 表示铣刀齿数。运用以上步骤即可完成对刀具寿命的有效预测。

3 实验

为了验证大数据分析技术在刀具寿命预测中的有效性,进行一次仿真实验分析。

3.1 实验装置

实验是 UC Berkeley 与 NASA 联合在松浦加工中心上进行的磨损实验。本实验采用的采样间隔是 $2 \sim 3 \text{ min}$ 。由于设备原因,在取样过程中出现了刀具磨损量采空情况,即没有成功地获得刀具磨损数据,这需要在研究中予以删除。

3.2 实验数据

在工况单一的情况下,根据现有的数据为刀具构建一个虚拟健康指数。以健康指数为特征,将剩余寿命占比(RULR)作为训练标签,把预测问题转化为一个回归问题。关于 RULR,它是一个 $0 \sim 1$ 的值,表示的是当前剩余寿命占总寿命的比值。因为刀具本身质量的不同,即使在完全相同的工况下,最终寿命也不一样,而 RULR 比时间更能反映刀具的内在健康状态。为此将 RULR 作为训练的预测目标。

对一组数据训练时,根据实验采样信号的频率,将每个信号分为 100 组。训练结束后,随机选取一组刀具的健康指数,并进行归一化后作为训练输入值;对大数据分析技术的刀具寿命预测效果进行了验证,在整个刀具使用周期,刀具性能指标的实际使用情况如图3所示。




图3 训练组刀具健康指数整体情况

由图3可知,当走刀数为108时,刀具健康指数达到标准值0.8。在0~108走刀数范围内,刀具健康指数逐渐逼近0.8标准值,超过108走刀数后,刀具健康指数基本保持不变。

3.3 实验分析

为了分析刀具健康指数预测结果是否精准,需将数据驱动、Bagging集成高斯过程回归模型的预测方法与基于大数据分析技术的预测结果进行对比,如图4所示。




图4 3种方法预测结果对比分析

由图4可知,使用数据驱动预测方法,当走刀数为118时,刀具健康指数达到标准值0.8。在0~118走刀数范围内,刀具健康指数逐渐逼近0.8标准值,超过118走刀数后,刀具健康指数始终保持在标准值0.8以上;使用Bagging集成高斯过程回归模型,当走刀数为52时,刀具健康指数达到标准值0.8。在52~54走刀数范围内,刀具健康指数在标准值0.8以上,其余均低于0.8;使用大数据分析技术,当走刀数为108时,刀具健康指数达到标准值0.8,在0~108走刀数范围内,刀具健康指数逐渐逼近0.8标准值,超过108走刀数后,刀具健康指数与实际情况基本保持不变。通过上述分析结果可知,该技术预测精度较高。

在上述基础上,对不同方法进行了刀具寿命预测精度的对比测试,得到对比精度如图5所示。




图5 3种方法预测精度对比

分析图5得知,基于大数据分析技术与数据驱动、Bagging集成高斯过程回归模型预测方法的预测精度对比实验表明:随着迭代次数的增加,使用数据驱动预测方法的预测精度都在80%以下;使用Bagging集成高斯过程回归模型预测方法的预测精度则不到60%;而使用大数据分析技术预测方法的预测精度都在90%以上,从而进一步证明本文方法的预测精度较高。

4 结语

本文研究了以加工过程的刀具健康指数为依据,检验刀具健康指数的方法。采用该方法能很好地反映刀具寿命的变化。利用3种不同的预测方法对预测精度进行了验证,通过对实际数据的分析,证明了该方法的有效性和准确性。

刀具预测过程涉及许多方面的研究,研究工作以数据处理和建模为核心,但也存在一些不足:在研究刀具状态分类时,因受实验数据的限制,只能粗略地将磨损状态分为3类。为此,在后续研究过程中,还应着重分析磨损状态,以延长刀具的使用寿命。

参考文献:

- [1] 黄志平,黄新宇,李亮,等. 基于数据驱动的铣削刀具寿命预测研究[J]. 制造技术与机床,2020(1):153-161.
- [2] 陈小康,涂焯,许维东,等. 基于Bagging集成高斯过程回归模型的刀具寿命预测[J]. 制造技术与机床,2020(12):110-115,121.
- [3] 王海宇,谢峰,李楠,等. 基于功率谱特征分析的立铣刀磨损实时监测方法[J]. 工具技术,2019,53(3):123-126.
- [4] 刘胜辉,张人敬,张淑丽,等. 基于深度神经网络的切削刀具剩余寿命预测[J]. 哈尔滨理工大学学报,2019,24(3):1-8.
- [5] 卢志远,马鹏飞,肖江林,等. 基于机床信息的加工过程刀具磨损状态在线监测[J]. 中国机械工程,2019,30(2):220-225.
- [6] 彭锐涛,降皓鉴,徐莹,等. 刀具磨损的机器视觉监测研究[J]. 机械科学与技术,2019,38(8):1257-1263.
- [7] 杨德义,王平岗,吴东林. 收割机刀具磨损状态监测系统的设计——基于图像处理技术[J]. 农机化研究,2019,41(4):228-232.
- [8] 桂宇飞,官威,陈标,等. 基于HHT算法与主轴功率信号的刀具磨损状态在线监测[J]. 机械设计与研究,2019,35(5):63-69.
- [9] 陶正瑞,陈杰,安庆龙,等. CFRP及叠层结构螺旋铣孔专用刀具切削性能评价[J]. 工具技术,2020,54(1):22-27.
- [10] 马廉洁,左宇辰,周云光,等. 氧化铝陶瓷车削刀具几何参数的多目标优化[J]. 东北大学学报(自然科学版),2020,41(8):1129-1134.
- [11] 曹大理,孙惠斌,张纪铎,等. 基于卷积神经网络的刀具磨损在线监测[J]. 计算机集成制造系统,2020,26(1):74-80.
- [12] 何彦,凌俊杰,王禹林,等. 基于长短期记忆卷积神经网络的刀具磨损在线监测模型[J]. 中国机械工程,2020,31(16):1959-1967.

收稿日期:2021-10-08