

利用运行状态信息的机床刀具可靠性预测方法

陈保家, 陈雪峰, 何正嘉, 李兵

(西安交通大学机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 针对数控机床类退化失效型设备,提出了一种基于设备运行状态信息的可靠性预测方法,主要包括状态特征指标选取、瞬时可靠度计算以及神经网络预测模型的建立和应用. 其中,瞬时可靠度计算是准确预测的关键,结合 Bayes 方法和 KM 估计器思想提出的基于状态特征指标比例关联关系的瞬时可靠度算法简单高效. 针对刀具加工过程中的磨损量时变数据,以可靠度为评价标准,正确预测出了刀具的失效时间,该过程表明设备状态信息用于可靠性预测的可行性和有效性,是未来可靠性发展的一个重要方向.

关键词: 运行状态;刀具;可靠性预测;瞬时可靠度

中图分类号: TP31;TG659 **文献标志码:** A **文章编号:** 0253-987X(2010)09-0074-04

Operating Condition Information-Based Reliability Prediction of Cutting Tool

CHEN Baojia, CHEN Xuefeng, HE Zhengjia, LI Bing

(State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: For the reliability prediction to equipment, such as machine tools, whose failure is mainly due to degradation, a forecasting method based on operating condition information is proposed, which includes extraction of condition characteristic index, computation of instantaneous reliability, construction and application of the neural network prediction model. The key issue of prediction accuracy is the computation of instantaneous reliability. A novel approach incorporating Bayes theorem and Kaplan-Meier (KM) estimator principle is employed to calculate the instantaneous reliability. According to the time-varying data of the tool wear, the trained network is available for forecasting the accurate failure time judged by the criterion of reliability. The results show the feasibility and effectiveness to predict reliability by operating condition information.

Keywords: operating condition; cutting tool; reliability prediction; instantaneous reliability

传统的基于样本寿命统计基础上的可靠性分析方法得到的是设备的整体可靠性估计,但对于正在运行的单台或小批量设备,这些统计数据的意义则不大,人们更关心的是当前所用设备的寿命裕度和可靠性. 设备运行过程的状态信息能够实时反映设备的运行性能、精度,准确判定设备的时间、动态特性,揭示产品失效与性能退化之间的关系^[1]. 国内外很多专家已经意识到设备运行状态信息在设备性能退化和可靠性评估中的重要性,并做了一些相关的

研究和应用^[2]. Nagi 等人^[3]选用轴承振动信号故障特征频率及谐波频率的幅值变化作为退化指标,来计算轴承的剩余寿命及其分布. Chinnam 等人^[4]将钻削加工过程中推力和扭矩变化作为退化信号,对钻头的磨损状况进行监测并对刀具的可靠性进行了在线预测. Cao 等人^[5]利用二代小波方法提取端铣刀加工过程中声发射信号特征频率处的幅值变化信息,运用马氏距离评估方法对其损伤程度进行了定量诊断.

本文以数控车床刀具系统为例,提出了一种利用设备运行状态信息的可靠性预测方法. 预测所采用的工具是 BP 神经网络,网络输入为设备的状态特征指标向量,这些指标能够反映设备性能的退化过程,具有明显的趋势性变化和明确的失效阈值定义. 网络输出为设备运行到某一时刻时不同指标值所对应的瞬时可靠度,其中瞬时可靠度的确定是预测结果正确与否的关键,常见的处理方法是先估计出状态特征指标在某一时刻的概率密度函数(PDF),然后由失效阈值和指标观测值所界定的区间积分来计算相应的瞬时可靠度^[6]. 但是,这种方法需要考虑失效 PDF 的选择是否合适,并对观测样本的数量有要求,特别是当设备接近失效时,如果样本数太少,所估计出来的模型参数误差就很大.

本文结合 Bayes 方法和 KM 评估器思想,以大于状态特征指标观测值的正常样本数目和所有样本数目比值的连乘积作为设备的瞬时可靠度,使算法简单高效,而且不需要对设备进行失效 PDF 估计,所以不会因样本数太少而引起大的估计误差. 通过对实际刀具可靠度的准确预测,验证了该方法的有效性.

1 神经网络可靠性预测模型

BP 网络是一种前向多层网络,利用误差反向传播算法对网络进行训练,结构简单,步骤明确. 通过自学习,BP 网络可从数据中自动总结规律,把具有复杂因果关系的物理量在经过适当数量的训练之后比较准确地反映出来,并可用总结出的规律来预测未知的信息^[7]. 本文所采用的预测模型为 1 个 3 层 BP 神经网络,其结构如图 1 所示,输入神经元个数为 $d+1$,输出神经元个数为 h . 网络输入为设备状态的特征向量

$\mathbf{X} = [x(t), x(t - \Delta t), \dots, x(t - d\Delta t)]^T$
它由当前测量值和其前 d 个测量值组成. 网络输出为预测的未来 h 个时间间隔的可靠度向量

$\hat{\mathbf{R}} = [\hat{R}(t + \Delta t), \hat{R}(t + 2\Delta t), \dots, \hat{R}(t + h\Delta t)]^T$

为了实现网络的预测功能,必须确定网络的输入和输出,即确定在不同特征向量下的瞬时可靠度,

$$R_i(t + k\Delta t) = \prod_{j=1}^k \frac{P(x_i(t + j\Delta t) \leq \mathbf{X}(t + j\Delta t) < X_{th} \mid P(x_i(t + (j-1)\Delta t) \leq \mathbf{X}(t + (j-1)\Delta t) < X_{th}))}{P(x_i(t + j\Delta t) \leq \mathbf{X}(t + j\Delta t) \mid P(x_i(t + (j-1)\Delta t) \leq \mathbf{X}(t + (j-1)\Delta t))} = \prod_{j=1}^k \frac{\int_{x_{i,t+j\Delta t}}^{X_{th}} f(x \mid t + j\Delta t) dx}{\int_{x_{i,t+j\Delta t}}^{\infty} f(x \mid t + j\Delta t) dx} \tag{3}$$

然后设定网络参数,对其进行训练,将网络模型所需知识记忆在网络的权值中. 最后,利用训练好的网络模型进行实际设备的可靠性预测.




图 1 神经网络可靠性预测模型的结构

2 时间和状态特征指标瞬时可靠度算法

在传统可靠性理论中,可靠度定义为产品在规定的时间内和条件下完成规定功能的概率

$$R(t) = P(T > t) = \int_t^{+\infty} f(u) du \tag{1}$$

式中: T 为产品寿命; t 为规定时间; f 为寿命分布函数; P 为规定功能的概率; u 表示积分的时间变量.

传统的可靠度评估方法对于机床类设备,特别是少失效或零失效产品是不适宜的,有文献提出从产品性能退化的角度进行可靠性评估^[8],由拟合的性能退化轨迹曲线和失效阈值外推出各样本的伪失效寿命,并求出 $f(t)$,代入式(1)求取设备可靠度. 但是,这种方法求取的依然是设备的整体可靠度,而且需要对退化轨迹(退化规律)进行合适的假设. 在此基础上,有研究者提出先估计出状态特征指标在不同时刻的 PDF,然后由失效阈值和指标观测值所界定的区间积分来计算相应的瞬时可靠度. 假设

$$\mathbf{X}(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$$

为时刻 t 所测得的 m 个产品的状态特征指标值, x 呈单调上升趋势,其 PDF 为 $f(x \mid t)$,失效阈值为 X_{th} ,此时的整体可靠度可表示为

$$R(t) = P(T > t) = P(\mathbf{X}(t) < X_{th}) = \int_0^{X_{th}} f(x \mid t) dx \tag{2}$$

如果产品 i 在时刻 $t + k\Delta t$ 的状态特征参量为 $x_i(t + k\Delta t)$,其瞬时可靠度可表示为

式(3)中比值的连乘积体现了 Bayes 条件概率思想,表示设备在 $t+j\Delta t$ 时刻可靠的前提条件是在 $t+(j-1)\Delta t$ 时刻必须是可靠的. 由式(3)可知,这种算法需要对 x 的 PDF 进行估计,并选择 PDF 的分布形式. 当设备接近失效时,如果样本数太少,所估计出来的模型参数误差就很大,会影响预测的准确性. KM 评估器是一种非参数估计方法^[9],它的最大优点是不依赖于失效 PDF 的分布假设,且不受采样间隔影响,只要知道失效样本和正常工作样本的数目就可以估计出产品的可靠度. 结合 KM 思想,可将式(3)改写为

$$R_i(t+k\Delta t) = \prod_{j=1}^k \frac{\int_{x_{i,t+j\Delta t}}^{X_{th}} f(x | t+j\Delta t) dx}{\int_{x_{i,t+j\Delta t}}^{\infty} f(x | t+j\Delta t) dx} = \prod_{j=1}^k \frac{d_{i,t+j\Delta t}}{n_{i,t+j\Delta t}} \quad (4)$$

式中: $d_{i,t+j\Delta t}$ 表示在 $t+j\Delta t$ 时刻 $\mathbf{X}(t)$ 中大于等于 $x_i(t+k\Delta t)$ 且小于失效阈值的样本总数; $n_{i,t+j\Delta t}$ 表示在 $t+j\Delta t$ 时刻 $\mathbf{X}(t)$ 中大于等于 $x_i(t+k\Delta t)$ 的样本总数,但在 $t+j\Delta t$ 时刻以前已经失效的样本不记入 $n_{i,t+j\Delta t}$ 中,以避免对可靠度的估计过于保守.

3 数控机床刀具可靠性预测实例

3.1 实验数据的获取

对于数控机床加工刀具,国际标准 ISO3685-1977 中规定以 1/2 背吃刀量处测得的后刀面磨损量 V_B 作为刀具的磨钝测量基准,因此本文将 V_B 值作为可靠性预测的状态特征指标. 对照国标中对外圆车刀加工碳钢的精车磨钝标准的规定,本文实验将刀具的失效阈值定为 0.6 mm. 目前,刀具磨损监测主要分为直接式和间接式^[10]方法,直接式方法直接测量磨损区域的实际参数值的大小(如磨损区的面积、周长等),间接式方法主要测量与刀具磨损相关的其他参数(如切削力和振动).

实验以友嘉精机 FTC-20 数控车床为实验平台,针对 CNMG120408-HM 刀具,利用 MZDH0670 系列视频显微系统测量刀具磨损图像信息,利用自带测微尺读取刀具的 V_B 值,最高分辨率为 0.01 mm,测量时采用可调节 LED 环形光源,加工工件材料为 45 号钢. 同时为了研究的需要,还采集了车刀加工过程中的振动信号、声发射信号、电机电流信号和工件表面粗糙度数据,图 2 为实验测试系统框图,图 3 为实际测试所用的视频显微系统,以及声发射传感器、振动传感器的布置位置照片.




图 2 刀具切削实验的系统框图




图 3 传感器布置图

3.2 刀具的可靠性预测

刀具磨损是一个缓慢的过程,且从开始到中间很长一段时间磨损较慢,对加工工件质量影响也较小. 在刀具磨损后期,磨损速度明显加快,对加工工件质量影响较大,因此实验所采集的刀具磨损量数据主要集中于 0.25 ~0.7 mm 之间. 实验共采集了 12 把刀具磨损量的时变数据,如图 4 所示. 将图 4 中的刀具磨损量数据代入式(4)可以计算出刀具在不同时刻、不同磨损量所对应的瞬时可靠度,如图 5 所示.




图 4 刀具磨损量的时变曲线

在确定了状态特征指标和瞬时可靠度后,就可以对网络进行训练以实现预测功能. 将采集的前 11 把刀具的磨损时间变化数据建立训练样本,以刀具当前磨损量及其前 6 个时间间隔的磨损量作为神经网络的输入,刀具未来 5 个时间间隔的可靠度作为输出,即输入神经元个数为 7,输出神经元个数为 5,




图 5 刀具的瞬时可靠度

共得到 131 个训练样本.

为了比较不同算法、不同隐含层神经元个数对 BP 网络的影响,在训练步数同为 1 000 时,对各自的均方差进行了比较,如表 1 所示.表中 N 表示隐含层神经元个数,可以看出,当 $N=12$ 时,采用 Levenberg-Marquardt 算法时所取得的均方差最小,因此将其选为网络的训练参数.

为了检验网络的预测能力,将第 12 把刀的磨损量作为待检样本,利用训练好的网络对其进行可靠性预测,结果如表 2 所示.由表 2 可见,刀具的实际

失效时间为 99 min,对应的磨损量为 0.61 mm,超出了刀具的失效阈值.如果以 $R(t)=0.5$ 作为刀具的失效阈值,当刀具运行到第 89 min 时,网络首次预测失效发生于未来的第 5 步,即第 99 min,与实际失效时间一致.随着刀具运行时间 t 的变化,当刀具运行到第 91、93、95、97 min 时,都可正确地预测出刀具的实际失效时间.

表 1 常用 BP 网络训练结果对比表

算法类型	函数	均方差		
		$N=9$	$N=12$	$N=15$
标准梯度下降法	traingd	0.045 6	0.095 1	0.034 9
BFGs 拟牛顿法	trainbfg	0.009 3	0.007 5	0.006 2
Fletcher-Powell	traincgf	0.007 2	0.006 5	0.007 3
共轭梯度法				
弹性 BP 算法	trainrp	0.009 1	0.009 6	0.009 3
Levenberg-Marquardt 算法	trainlm	0.033 1	0.002 5	0.003 7

表 2 刀具磨损量的可靠度预测结果

t/min	87	89	91	93	95	97	99	101
V_B/mm	0.49	0.51	0.53	0.55	0.56	0.58	0.61	0.63
$\hat{R}(t+\Delta t)$	0.768	0.695	0.635	0.608	0.542	0.351	0.208	0.0254
$\hat{R}(t+2\Delta t)$	0.703	0.613	0.677	0.593	0.348	0.220	0.066	0.001
$\hat{R}(t+3\Delta t)$	0.615	0.556	0.696	0.474	0.186	0.074	0.009	0
$\hat{R}(t+4\Delta t)$	0.622	0.539	0.429	0.267	0.061	0.016	0.001	0
$\hat{R}(t+5\Delta t)$	0.575	0.368	0.264	0.106	0.009	0.001	0	0

4 结 论

(1)本文针对数控机床类的退化失效型设备,提出了一种基于设备状态信息的神经网络可靠性预测方法.该方法充分利用了设备退化过程中的状态信息,能够动态地反映设备的运行性能、精度,准确判断设备的失效时间.

(2)结合 Bayes 方法和 KM 估计器思想提出的基于状态特征指标的瞬时可靠度算法无需对设备失效 PDF 进行估计,也不会因样本太少而引起大的估计误差,因此简单高效.

(3)以实际加工过程中所测得的刀具磨损量时变数据为例,以可靠度为评价标准,通过所建立的神经网络模型,正确预测出了刀具的失效时间.该过程

表明,设备状态信息用于设备可靠性预测是可行和有效的,也是未来可靠性发展的重要方向.

参考文献:

[1] WU S J, TSAI T R. Estimation of time-to-failure distribution derived from a degradation model using fuzzy clustering [J]. Quality and Reliability Engineering International, 2000,16(4):261-267.

[2] ZIO E. Reliability engineering: old problems and new challenges [J]. Reliability Engineering and System Safety, 2009,94(2):125-141.

[3] NAGI Z G, MARK A L. A neural network degradation model for computing and updating residual life distributions [J]. IEEE Transactions on Automation Science and Engineering, 2008,5(1):154-163.

- [4] CHINNAM R B, RAI B. Intelligence in reliability engineering [M]. Berlin, Germany: Springer, 2007: 223-260.
- [5] CAO H, CHEN X, ZI Y, et al. End milling tool breakage detection using lifting scheme and Mahalanobis distance [J]. International Journal of Machine Tools and Manufacture, 2008, 48(2): 141-151.
- [6] HENG A, TAN A, MATHEW J, et al. Intelligent condition-based prediction of machinery reliability [J]. Mechanical Systems and Signal Processing, 2009, 23(5): 1600-1614.
- [7] YI J, WANG Q, ZHAO D, et al. BP neural network prediction-based variable-period sampling approach for networked control systems [J]. Applied Mathematics and Computation, 2007, 185(2): 976-988.
- [8] LU J C, MEEKER W Q. Using degradation measures to estimation a time-to-failure distribution [J]. Technometrics, 1997, 39(4): 391-400.
- [9] KAPLAN E L, MEIER P. Nonparametric estimation from incomplete observations [J]. Journal of the American Statistical Association, 1958, 53(2): 457-481.
- [10] SICK B. On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research [J]. Mechanical Systems and Signal Processing, 2002, 16(4): 487-546.
- (编辑 管咏梅)