

基于动态 Bayesian 网络的叶片加工质量监控与溯源

王佩, 张定华*, 陈冰, 李山, 王明微

西北工业大学 现代设计与集成制造技术教育部重点实验室, 陕西 西安 710072

摘要: 针对叶片加工过程中质量精度不高的问题, 提出了基于动态 Bayesian 网络的叶片加工质量监控与溯源方法。利用动态 Bayesian 网络建立起叶片加工工序间的相互联系, 实现对整个加工过程的控制。基于 Bayesian 网络对影响加工工序的因素集建立因果联系, 采用多元统计过程控制中的 T^2 控制图完成对各工序影响因素集的监控。进行误差溯源时, 根据 Bayesian 网络建立的因果关系对失控样本的 T^2 统计量依据原因变量进行误差分解, 并构建各分解变量的控制限, 将其作为误差源判定的条件。通过对某叶片加工过程的仿真, 验证了所提方法的有效性。

关键词: 航空发动机; 叶片加工; 质量监控; 误差溯源; 动态 Bayesian 网络; 误差分解

中图分类号: V232.4; V263.1 **文献标识码:** A

叶片是航空发动机产品制造过程中最容易发生质量问题的零件之一, 为了提高叶片的生产制造水平, 需要从加工过程入手, 对过程波动现象进行监控, 对引起过程异常的因素进行溯源, 在还没有发生质量问题之前对叶片加工过程的波动进行预报警和诊断分析, 以减少加工过程中的不合格品、降低返修率和生产成本来提高加工效率。

叶片加工过程是一个多输入/多输出的复杂过程, 过程的波动现象往往是多种影响因素共同作用的结果, 而一个影响因素又有可能造成多种过程波动。对叶片加工过程波动进行监控和溯源就是一个发现波动和诊断的过程。有很多学者在过程监控和异常诊断方面进行了研究。目前有 3 种方法被用于过程波动的监控^[1-2]: 基于知识的方法、基于模型的方法和数据驱动的方法。基于知识的方法包括: 有向图法^[3]、故障树法^[2]和推理的方法^[4]。基于模型的方法是基于物理模型来模拟

系统的, 为了有效地监控, 这种技术可以对过程模型进行过程的预测, 能够提高预测精度^[5-8]。数据驱动的方法是基于过程样本数据的一系列不同的监控技术^[9-12], 包括控制图、主成分分析法等。基于知识的方法模型精度低、知识规则提取困难, 且较为复杂的生产过程很难用简单的知识模型加以描述。基于模型的方法需要很精确的数学模型, 才能够有效地进行波动的监控, 但是数学模型很难获得, 并且费时费力, 在变量多的时候更难处理。与上述方法相比较, 数据驱动的方法不需要提取知识和建立数学模型, 且在多元过程中进行监控和溯源是可靠和有效的^[13]。当过程中发生波动时, 需要对过程异常进行诊断溯源, 为后续的调整提供依据。在过程诊断的研究中, 包括基于判别式分析的方法^[14]、以单元 t 统计量作为标准诊断的方法^[15]、多元回归调整的方法^[16-17]、MYT (Mason, Young and Tracy) 方法^[18] 以及人工智

收稿日期: 2011-05-06; 退修日期: 2010-08-22; 录用日期: 2011-10-24; 网络出版时间: 2011-11-07 10:19

网络出版地址: www.cnki.net/kcms/detail/11.1929.V20111107.1019.001.html

DOI: CNKI:11-1929/V.20111107.1019.001

基金项目: 国家自然科学基金 (70931004)

* 通讯作者. Tel.: 029-88493009 E-mail: dhzhang@nwpu.edu.cn

引用格式: Wang P, Zhang D H, Chen B, et al. Machining quality monitoring of blades and source tracing based on dynamic Bayesian network. Acta Aeronautica et Astronautica Sinica, 2012, 33(1): 170-181. 王佩, 张定华, 陈冰, 等. 基于动态 Bayesian 网络的叶片加工质量监控与溯源. 航空学报, 2012, 33(1): 170-181.

能的方法^[19-22]等。这些方法为失控过程的诊断问题提供了有效的解决方案,但是应用在本文所要解决的问题方面,有的方法没有考虑变量之间的相互关系,有的方法计算量大,并且随着变量个数的增多会导致诊断效率下降。

针对叶片加工的多元过程,本文采用数据驱动的方法进行过程监控和误差溯源。采用数据驱动进行过程监控与溯源时,应先对过程的波动及时进行监控,当过程失控时进行报警,然后诊断其发生的根本原因。在进行过程监控时,本文采用多元统计过程控制(Multivariate Statistical Process Control, MSPC)方法进行波动监控。在进行误差溯源时,本文考虑影响生产过程的变量之间存在的多重因果关系,将影响叶片加工的因素集和质量特性集进行搜集,根据因素集元素之间和因素集与质量特性集之间的因果关系,建立起一个因果模型,依据因果模型对波动进行分解,找出引起过程异常的根本原因,从源头上进行控制。通过对叶片加工过程中波动情况监控和失控情况的误差溯源将对叶片加工质量的持续改善有重大意义。

1 叶片加工中质量监控与诊断过程分析

叶片加工误差与误差原因间存在不确定的映

射关系,但又具有统计规律性,技术人员的经验可以理解为此统计规律的一种知识表达。叶片零件某个工序完成后,可能存在一种或多种加工缺陷。这些加工缺陷是多方面因素共同影响的结果,某一种原因可能造成多种加工缺陷,且缺陷原因间存在层次因果关系。叶片经过多道工序加工后可能会造成的质量问题有叶片尺寸超差、叶身发生弯曲、扭转、翘曲、收缩等变形以及由于薄壁引起的让刀变形等。这些质量问题可能是基准、装夹等原因共同造成的,并且基准和装夹也存在相互影响的关系。通过以上分析可知,缺陷原因和加工缺陷间的影响关系复杂,在实际叶片加工质量溯源中,通常由技术人员对加工过程进行调查询问,基于经验对搜集的缺陷证据进行分析,找出缺陷原因。为了克服这种主观的现象,本文通过对叶片加工过程中的影响因素进行分析,采用动态 Bayesian 网络建立起各工序间的关系,在此基础上考虑工序之间的误差传递,基于 Bayesian 网络对每道工序的影响因素建立起因果关系,并通过采用 MSPC 中的 T^2 控制图进行过程的监控,对过程的异常进行报警,然后进行报警原因的分析,对失控的过程依据因果模型实施分解,进行误差溯源找到影响最大的几个因素。具体流程如图 1 所示。

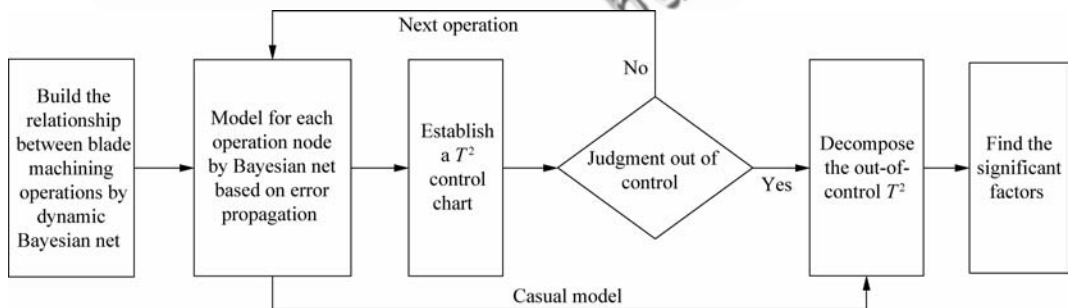


图 1 基于动态 Bayesian 网络的过程监控与溯源

Fig. 1 Process monitoring and source tracing based on dynamic Bayesian network

2 基于动态 Bayesian 网络的叶片加工过程模型的建立

动态 Bayesian 网络模型可以用一个二元组 $B = \{G(t), D(t)\}$ 来表示, t 表示时间片段。该模型由两部分组成: $\{G(t)\}$ 表示有向无环图, $G(t) = \{V(t), A(t)\}$, 用来描述节点之间的依赖和独立关系; $D(t)$ 表示与每个节点相关的系数,

用来刻画节点对其父节点的依赖强度。则叶片加工过程的 Bayesian 网络模型可以表示为: $G(t) = \{V(t), A(t)\}$ 。其中: $t = 1, 2, \dots, n$ 表示第几道工序; $V(t)$ 表示叶片加工过程第 t 道工序的节点; $A(t)$ 表示叶片加工过程第 t 道工序各节点间有向图边的集合, 每个边代表 $V(t)$ 中两个节点之间存在的因果关系, $V(t)$ 中任意节点至少存在一条有向边。叶片加工过程动态 Bayesian 网络模型如

图 2 所示,可以看出当其中某个变量的均值出现偏移时,该偏移将会在因果关系链中传递,叶片加工过程出现波动可以看成是加工过程由平稳状态产生故障变成波动状态。

叶片形状结构复杂,尺寸精度、位置精度和形状精度等要求高,依据叶片的形状,需要加工榫头、叶盆、叶背、进、排气边等多个部位,需经过多道工序的加工才能完成。这些工序之间相互影响,如叶身定位基准榫头的加工质量影响着叶身的加工,榫头加工超差会传递到叶身加工的工序,影响叶身加工的质量,因此工序间存在误差传递关系。传统的叶片加工误差分析理论仅是在加工前采用有限元分析的方法,考虑比较理想的情况进行变形的预测和补偿,并没有结合实际的生产过程考虑多种加工要素对叶片质量的影响和工序间的误差传递,这不满足对叶片加工过程中误差的监控和诊断要求,因此需要结合实际的生产过程从制造系统误差输入的角度来研究各误差源与误差之间的关系,以实现叶片加工误差进行分

析、监控和诊断。影响叶片加工过程的制造系统误差主要包括:装夹引起的误差、刀具引起的误差、加工轨迹引起的误差以及让刀变形引起的误差,除了制造系统这种局部误差,还包括基准误差,它可以看做是上一道工序传递给下一道工序的误差,是全局误差^[23]。各个误差因素之间的相互影响关系具体如图 3 所示。图中有因果关系的变量用箭头连接,箭头的方向与因果关系的方向相同,通过对每道工序的监控,就可以完成对叶片加工过程的监控。 X_{hi} 表示第 h 道工序的第 i 个因素变量 ($i=1, 2, \dots, 6$), 其结果变量的集合记为 $R(X_{hi})$, 工序质量 X_{h6} 表示的是该工序的质量集, 可以是一个质量变量, 也可以是多个质量变量。这样建立起叶片的质量特性集与误差源之间的因果关系, 为了考虑方便, 本文假定每次采样是相互独立的。第 h 道工序的第 i 个原因变量的集合记为 $PA(X_{hi}) = \{PA_1(X_{hi}), PA_2(X_{hi}), \dots, PA_{s_i}(X_{hi})\}$, s_i 为 X_{hi} 的原因变量的个数, $PA(X_{hi})$ 表示第 h 道工序的变量 X_i 的父节点集合。

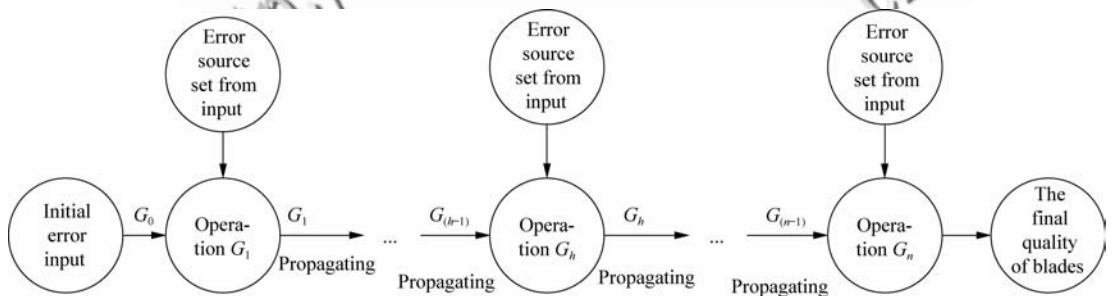


图 2 叶片加工过程的动态 Bayesian 网络模型

Fig. 2 Dynamic Bayesian network model of blade machining process

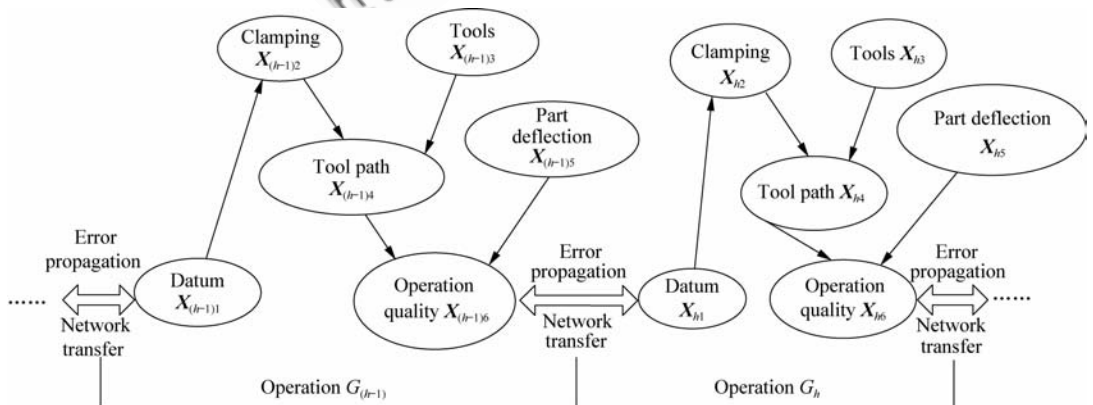


图 3 工序节点的 Bayesian 网络模型

Fig. 3 Bayesian network model of operation nodes

3 基于多元统计过程的叶片加工过程监控

从第 2 节的分析中可知,叶片的加工过程由多道工序组成,每道工序的质量受到基准、装夹、刀具和加工轨迹等因素的影响,即这些因素共同影响叶片的质量状态,通过对这些因素的监控,就可以判断叶片的质量情况。因为叶片的加工质量受多个因素的影响,因此选用 MSPC 的方法对叶片加工过程进行监控,为了方便后续的诊断,本文采用 T^2 控制图。

3.1 多元统计过程控制图第 I 阶段

假设叶片由 n 道工序加工完成,工序之间误差的传递只考虑基准引起的,对于非基准引起的传递误差,如叶身粗加工产生的误差到了精加工之后是可以消除的,一般不会由于其质量超差而影响后面加工的质量,各种误差的关系具体如图 3 所示。假设第 h 道工序由 p 个相关的质量因素 $\mathbf{X}_{h1}, \mathbf{X}_{h2}, \dots, \mathbf{X}_{hp}$ 组成,这 p 个因素组成了叶片的质量状态集,包括前文所述的误差源(数量为 5)产生的影响,也包括该工序对应的叶片的质量特性集(数量为 $p-5$),可以是叶片的弦长、叶片的厚度、位置误差、轮廓误差及榫头的几何误差等,这些对象必须是可控、可测量的,通过对第 h 道工序的这些数据进行采集、分析,建立 MSPC 监控过程,本文主要应用 T^2 控制图样本容量为单值样本的情况,对于多值样本的情况可参考文献[24]。建立控制图对质量状态集进行监控,监控完一道工序,进入下一道工序,重新进行过程分析,建立相应工序的控制图进行监控,依工序进行监控直到所有工序加工完成就可以完成对叶片整个加工过程的波动的监控。假设这 p 个指标服从 p 维正态分布 $N_p[\boldsymbol{\mu}, \boldsymbol{\Sigma}]$,均值向量 $\boldsymbol{\mu}$ 和协方差矩阵 $\boldsymbol{\Sigma}$ 均未知,采集的第 h 道工序的数据矩阵为

$$\mathbf{X}_h = \begin{bmatrix} \mathbf{X}_{h1}^T \\ \mathbf{X}_{h2}^T \\ \vdots \\ \mathbf{X}_{hm}^T \end{bmatrix} = \begin{bmatrix} \mathbf{X}_{h11} & \mathbf{X}_{h21} & \cdots & \mathbf{X}_{hp1} \\ \mathbf{X}_{h12} & \mathbf{X}_{h22} & \cdots & \mathbf{X}_{hp2} \\ \vdots & \vdots & & \vdots \\ \mathbf{X}_{h1m} & \mathbf{X}_{h2m} & \cdots & \mathbf{X}_{hpm} \end{bmatrix} \quad (1)$$

式中: $\mathbf{X}_{hi} = [\mathbf{X}_{hi1} \ \mathbf{X}_{hi2} \ \cdots \ \mathbf{X}_{hip}]^T$,共有 m 个样本; \mathbf{X}_{hip} 为第 h 道工序中变量 \mathbf{X}_p 的第 i 次采样值,

$h=1, 2, \dots, n; i=1, 2, \dots, m$ 。根据每道工序的数据矩阵可以得到该道工序的样本均值向量和样本协方差矩阵分别为

$$\bar{\mathbf{X}}_h = [\bar{\mathbf{X}}_{h1} \ \bar{\mathbf{X}}_{h2} \ \cdots \ \bar{\mathbf{X}}_{hp}]^T \quad (2)$$

$$\mathbf{S}_h = \frac{1}{m} \sum_{i=1}^m (\mathbf{X}_{hi} - \bar{\mathbf{X}}_h)(\mathbf{X}_{hi} - \bar{\mathbf{X}}_h)^T \quad (3)$$

式中: $\bar{\mathbf{X}}_{hj} = \frac{1}{m} \sum_{i=1}^m \mathbf{X}_{hji}$ 表示第 h 道工序中第 j 个因素的样本均值, $j=1, 2, \dots, p$; \mathbf{X}_{hi} 表示第 i 次采样得到的一组样本值,则第 h 道工序的第 I 阶段的 T_{h1}^2 统计量为

$$T_{h1}^2 = (\mathbf{X}_{hi} - \bar{\mathbf{X}}_h)^T \mathbf{S}_h^{-1} (\mathbf{X}_{hi} - \bar{\mathbf{X}}_h) \sim \frac{p(m+1)(m-1)}{m(m-p)} F_{p, m-p} \quad (4)$$

取第 1 类错误概率为 α ,则多元 T_h^2 控制图的控制限为

$$UCL_h = \frac{p(m+1)(m-1)}{m(m-p)} F_{p, m-p}(\alpha) \quad (5)$$

如果这 m 个样本中有 v 个超出了控制限,说明加工过程不稳定,不能用其来建立控制图。此时,需要分析 v 个样本点出界的原因。如果是由于工艺过程导致的,则需要分析工艺过程,通过调整工艺过程参数,使过程趋于稳定,然后再进行采样,判断过程是否稳定,如仍不稳定,需要进行上述的迭代过程,直至过程稳定,计算控制图的控制限,进行过程监控;如果是由于误读造成的,则需要将这 v 个样本点去除,重新计算统计量和控制限,来判断 $m-v$ 个采样点是否受控,如果受控,则所建立的控制图是合格的,可以被应用。本文假定的是后一种情况,则此时对应的第 h 道工序的数据矩阵为

$$\mathbf{X}'_h = \begin{bmatrix} (\mathbf{X}'_{h1})^T \\ (\mathbf{X}'_{h2})^T \\ \vdots \\ (\mathbf{X}'_{h(m-v)})^T \end{bmatrix} = \begin{bmatrix} \mathbf{X}'_{h11} & \mathbf{X}'_{h21} & \cdots & \mathbf{X}'_{hp1} \\ \mathbf{X}'_{h12} & \mathbf{X}'_{h22} & \cdots & \mathbf{X}'_{hp2} \\ \vdots & \vdots & & \vdots \\ \mathbf{X}'_{h1(m-v)} & \mathbf{X}'_{h2(m-v)} & \cdots & \mathbf{X}'_{hp(m-v)} \end{bmatrix} \quad (6)$$

式中: $\mathbf{X}'_{hs} = [\mathbf{X}'_{hs1} \ \mathbf{X}'_{hs2} \ \cdots \ \mathbf{X}'_{hps}]^T$,共有 $m-v$ 个样本,此时对应的第 h 道工序的样本均值向量

和样本协方差矩阵分别为

$$\bar{\mathbf{X}}'_h = [\bar{\mathbf{X}}'_{h1} \quad \bar{\mathbf{X}}'_{h2} \quad \cdots \quad \bar{\mathbf{X}}'_{hp}] \quad (7)$$

$$\mathbf{S}'_h = \frac{1}{m-v-1} \sum_{i=1}^{m-v} (\mathbf{X}'_{hi} - \bar{\mathbf{X}}'_h)(\mathbf{X}'_{hi} - \bar{\mathbf{X}}'_h)^T \quad (8)$$

式中: $\bar{\mathbf{X}}'_{hj}$ 为第 h 道工序中第 j 个因素的样本均值, $j=1, 2, \dots, p$ 。则第 h 道的 T_{h1}^2 统计量为

$$T_{h1}^2 = (\mathbf{X}'_{h1} - \bar{\mathbf{X}}'_h)^T (\mathbf{S}'_h)^{-1} (\mathbf{X}'_{h1} - \bar{\mathbf{X}}'_h) \sim \frac{p(m-v+1)(m-v-1)}{(m-v)(m-v-p)} F_{p, m-v-p} \quad (9)$$

取第 1 类错误概率为 α , 则多元 T_h^2 控制图的控制限为

$$UCL'_h = \frac{p(m-v+1)(m-v-1)}{(m-v)(m-v-p)} F_{p, m-v-p}(\alpha) \quad (10)$$

假设此时的统计量都在控制限范围内, 那么过程稳定, 则所建立的控制图合理, 可以将其应用于该道工序后续加工的监控过程, 判断该工序是否依然受控。

3.2 多元统计过程控制图第 II 阶段

设 \mathbf{X}_{hk} 为叶片加工过程中第 h 道工序新采样的第 k 次采样值 ($k=1, 2, \dots, l$), l 表示采样次数, 将第 I 阶段的样本均值和协方差应用到第 II 阶段, 则第 II 阶段第 h 道工序的 T_h^2 统计量的分布为

$$T_{h1}^2 = (\mathbf{X}_{hk} - \bar{\mathbf{X}}'_h)^T (\mathbf{S}'_h)^{-1} (\mathbf{X}_{hk} - \bar{\mathbf{X}}'_h) \sim \frac{p(l+1)(l-1)}{l(l-p)} F_{p, l-p} \quad (11)$$

根据第 I 阶段的控制限 UCL'_h 建立监控用控制图, 当控制图上出现超出 UCL'_h 的异常点时, 控制图发出警报信号, 表示过程发生异常, 但是并不能判断是由哪个变量引起的, 需要对这个失控的状态进行误差溯源, 对过程波动情况进行进一步的分解, 以确定引起失控信号产生的原因。

4 基于 Bayesian 网络的误差溯源

通过 MSPC 对叶片加工过程的质量状态集进行监控, 可以判断叶片的加工过程是否已经产生波动, 但是不能给出失控状态的诊断信息, 因此当出现波动时, 就要对加工过程进行溯源。

图 3 的 Bayesian 网络模型采用有向图的方

式描述了一道工序的各影响因素之间的因果关系, 是该道工序的因果模型, 用来绘制控制图的 T_h 统计量就是通过这个模型中的元素计算出来的, 进行误差溯源就是要将失控的 T_h^2 值依据因果模型进行分解, 计算出组成项对它的贡献值, 由此确定哪几个变量是误差源。

为了进行 T_h^2 值的分解, 将 T_h^2 值直接与组成项建立起关系, 传统的方法采用 MYT 分解法^[25], 将 T_h^2 值分解为两类相互独立的分解项, 即独立项和条件项。由于 MYT 仅考虑 $\mathbf{X}_{h1}, \mathbf{X}_{h2}, \dots, \mathbf{X}_{hp}$ 各个变量之间的相关关系, 因此 T_h^2 值的分解存在 $p!$ 种方式, 可以产生 $2^{p-1} \cdot p!$ 个分解项, 计算量很大, 其中的一种分解方式为

$$T_h^2 = T_{h1}^2 \cdot \text{PA}(\mathbf{X}_{h1}) + T_{h2}^2 \cdot \text{PA}(\mathbf{X}_{h2}) + \cdots + T_{hp}^2 \cdot \text{PA}(\mathbf{X}_{hp}) = \sum_{i=1}^p T_{hi}^2 \cdot \text{PA}(\mathbf{X}_{hi}) = T_{h1}^2 + \sum_{j=2}^p T_{hj}^2 \cdot \text{PA}(\mathbf{X}_{hj}) \quad (12)$$

式中: T_{h1}^2 为独立项; $T_{hj}^2 \cdot \text{PA}(\mathbf{X}_{hj})$ ($j=2, 3, \dots, p$) 为条件项, 文献^[26]证明在所有的分解中它具有很高的诊断精度, 子项的计算公式为

$$\begin{cases} T_{h1}^2 = \frac{(\mathbf{X}_{h1} - \bar{\mathbf{X}}_{h1})^2}{\mathbf{S}_{h1}^2} \sim \frac{m+1}{m} F_{\alpha, 1, m-1} \\ T_{hj}^2 \cdot \text{PA}(\mathbf{X}_{hj}) = \frac{(\mathbf{X}_{hj} - \bar{\mathbf{X}}_{hj, \text{PA}(\mathbf{X}_{hj})})^2}{\mathbf{S}_{hj, \text{PA}(\mathbf{X}_{hj})}^2} \sim \frac{(m+1)(m-1)}{m(m-d-1)} F_{\alpha, 1, m-k-1} \end{cases} \quad (13)$$

式中: $\bar{\mathbf{X}}_{h1}$ 和 \mathbf{S}_{h1}^2 分别为 \mathbf{X}_{h1} 的样本均值和样本方差; $\bar{\mathbf{X}}_{hj, \text{PA}(\mathbf{X}_{hj})}$ 和 $\mathbf{S}_{hj, \text{PA}(\mathbf{X}_{hj})}^2$ 分别代表以 $\text{PA}(\mathbf{X}_{hj}) = \{\mathbf{X}_{h1}, \mathbf{X}_{h2}, \dots, \mathbf{X}_{h(j-1)}\}$ 为条件变量的 \mathbf{X}_{hj} 的条件均值和条件方差估计值; d 为条件因子的数量, 当没有条件项时值为 0。

根据上文分析可知 MYT 的计算量很大, 为此, 利用图 3 的 Bayesian 网络模型给出的变量之间的因果关系, 实现减少分解项。将有因果关系的留下, 没有因果关系的置为 0, 直接对 Bayesian 网络模型的各个 $T_{i, \text{PA}(\mathbf{x}_i)}^2$ 进行监控。如图 4 所示, 当对应的独立项和条件项失控时可以诊断为误差源, 这样可以提高诊断效率, 因此式(12)变为

$$T_h^2 = T_{h1}^2 \cdot \text{PA}(\mathbf{X}_{h1}) + T_{h2}^2 \cdot \text{PA}(\mathbf{X}_{h2}) + \cdots + T_{hp}^2 \cdot \text{PA}(\mathbf{X}_{hp}) = T_{h1}^2 + T_{h2, h1}^2 + T_{h3}^2 + T_{h4, h2, h3}^2 + T_{h5}^2 + T_{h6, h5, h4}^2 \quad (14)$$

对于一个出界的 T_h^2 值, 由式(9)对其进行分解, 通过确定分解项的判定界限, 建立诊断失控信

号的标准。 T_h^2 统计量的独立项 T_{h1}^2 和条件项 $T_{hi \cdot PA(X_{hi})}^2 (i = 2, 3, \dots, q)$ 的计算公式分别为

$$\begin{cases} T_{h1}^2 = (\mathbf{X}_{h1} - \bar{\mathbf{X}}_{h1})^2 / \mathbf{S}_{h1}^2 \\ T_{h2, h1}^2 = T^2(\mathbf{X}_{h1}, \mathbf{X}_{h2}) - T_{h1}^2 \\ \vdots \\ T_{h(p-1) \cdot h1, h2, \dots, h(p-2)}^2 = T^2(\mathbf{X}_{h1}, \mathbf{X}_{h2}, \dots, \mathbf{X}_{h(p-1)}) - \\ T^2(\mathbf{X}_{h1}, \mathbf{X}_{h2}, \dots, \mathbf{X}_{h(p-2)}) \\ T_{h(p-1) \cdot h1, h2, \dots, h(p-1)}^2 = T^2(\mathbf{X}_{h1}, \mathbf{X}_{h2}, \dots, \mathbf{X}_{h(p)}) - \\ T^2(\mathbf{X}_{h1}, \mathbf{X}_{h2}, \dots, \mathbf{X}_{h(p-1)}) \end{cases} \quad (15)$$

T_{h1}^2 和 $T_{hi \cdot PA(X_{hi})}^2$ 的服从分别为

$$\begin{cases} T_{h1}^2 \sim \frac{m+1}{m} F_{1, m-1} \\ T_{hj \cdot PA(X_{hj})}^2 \sim \frac{(m+1)(m-1)}{m(m-s_{hi}-1)} F_{1, n-s_{hi}-1} \end{cases} \quad (16)$$

取第 1 类错误概率为 α , 可确定 T_1^2 和 $T_{i \cdot PA(X_i)}^2$ 的判定界限分别为

$$\begin{cases} UCL_{T_{h1}^2} \sim \frac{m+1}{m} F_{1, m-1}(\alpha) \\ UCL_{T_{hi \cdot PA(X_{hi})}^2} \sim \frac{(m+1)(m-1)}{m(m-s_{hi})} F_{1, n-s_{hi}-1}(\alpha) \end{cases} \quad (17)$$

将 T_{h1}^2 和 $T_{hi \cdot PA(X_{hi})}^2$ 的统计量值分别与其判定界限 $UCL_{T_{h1}^2}$ 和 $UCL_{T_{hi \cdot PA(X_{hi})}^2}$ 进行比较, 若 $T_{h1}^2 > UCL_{T_{h1}^2}$ 则表明变量 \mathbf{X}_{h1} 是引起失控信号产生的根本原因; 若 $T_{hi \cdot PA(X_{hi})}^2 > UCL_{T_{hi \cdot PA(X_{hi})}^2}$, 则表明变量 \mathbf{X}_{hi} 是引起失控信号产生的根本原因; 若 T_1^2 和 $T_{i \cdot PA(X_i)}^2$ 均大于判定界限, 则表明变量 \mathbf{X}_{h1} 和 \mathbf{X}_{hi} 都为根本原因。具体流程图如图 5 所示。

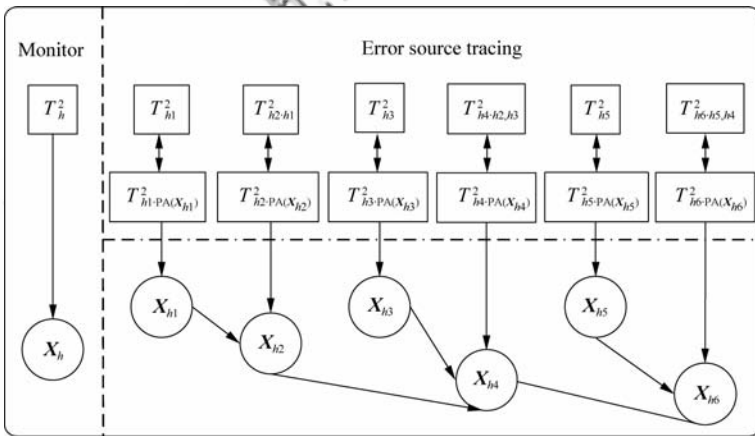


图 4 基于 Bayesian 网络的加工过程误差溯源方法

Fig. 4 Error source tracing method based on Bayesian network

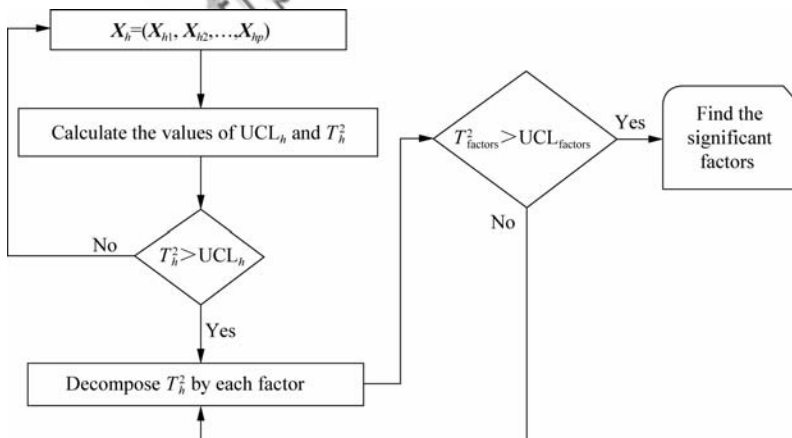


图 5 误差溯源流程

Fig. 5 Flowchart of error source tracing

5 仿真验证

下面通过模拟叶片加工过程的失控情况,采用本文方法对其进行波动监控和误差溯源,来说明所提方法的有效性。

以某压气机叶片的生产过程为例,进行叶片变形的监控和诊断。依据叶片的主要组成部分确定叶片的主要加工过程为:榫头加工—粗铣叶身—半粗铣叶身—精铣叶身……。为了描述多工序之间误差的传递,对中间工序粗铣叶身这道工序进行监控。由于榫头是粗铣叶身的基准,榫头加工这道工序产生的误差将会作为基准误差传递到粗铣叶身这道工序,因此本文将作为影响叶片质量的一个因素来进行监控,传递过程如图6所示。假定榫头已经加工完成,由基准引起的误差是可知的,因此直接对粗铣叶身的工序进行分析。如图6的 Operation 2 所示,叶身由多条截面线组成,需要对多条截面线的监控来完成对叶身加工质量的监控,如果有一条截面线出现异常,则叶片的加工质量不稳定。为了简化描述,对每个叶片都选取图中的箭头所指截面线进行本文方法的描述,其他截面线的监控方法类似。由于叶片薄,刚度差,易发生变形,本文主要考虑加工过程中的弯扭变形,即主要考虑叶片的弯扭质量特性。叶片弯扭变形模型截面线分析如图7所示,可知弯扭变形的质量特性个数为3个,分别为在X方向的偏移 ΔX ,在Y方向的偏移 ΔY ,绕Z轴的扭转偏移 $\Delta\theta$ 。结合上文对误差源的分析,对应的质量状态数据向量为: $\mathbf{X}_i = (\mathbf{X}_{i1}, \mathbf{X}_{i2}, \mathbf{X}_{i3}, \mathbf{X}_{i4}, \mathbf{X}_{i5}, \mathbf{X}_{i6},$

$\mathbf{X}_{i7}, \mathbf{X}_{i8})$,其中: i 表示第 i 次采样, $i=1, 2, \dots, m$; \mathbf{X}_{ij} 表示第 i 次采样的第 j 个变量的值, $j=1, 2, \dots, 8$ 依次表示为由基准产生的误差,由装夹产生的误差,由刀具缺陷产生的误差,由刀具路径产生的误差,由让刀变形产生的误差,后面3个则表示叶身弯扭变形量,这个状态向量涵盖了粗铣叶身这道工序的主要的质量信息。设每次采样采一组值,即样本容量为1。




图6 误差传递过程

Fig. 6 Error propagation process




图7 叶片弯扭变形监控变量

Fig. 7 Monitoring variables of blade bend and twist deformation

假设箭头所指截面线的质量状态数据在第I阶段服从 $N(\mathbf{0}, \Sigma)$ 的多元正态分布,这里假定弯扭变形的各个变量之间是相互独立的,即 \mathbf{X}_{i6} 、 \mathbf{X}_{i7} 、 \mathbf{X}_{i8} 是相互独立的,依据前文中所述的各个变量之间的关系和工程经验确定协方差为

$$\Sigma = \begin{bmatrix} 1.0000 & 0.5662 & 0.0000 & 0.1523 & 0.0000 & 0.1165 & 0.1165 & 0.1165 \\ 0.5662 & 2.0000 & 0.0000 & 0.2689 & 0.0000 & 0.2085 & 0.2085 & 0.2085 \\ 0.0000 & 0.0000 & 4.0000 & 0.8695 & 0.0000 & 0.6654 & 0.6654 & 0.6654 \\ 0.1523 & 0.2689 & 0.8695 & 5.0000 & 0.0000 & 0.7653 & 0.7653 & 0.7653 \\ 0.0000 & 0.0000 & 0.0000 & 0.0000 & 1.0000 & 0.9685 & 0.9685 & 0.9685 \\ 0.1165 & 0.2085 & 0.6654 & 0.7653 & 0.9685 & 8.0000 & 0.0000 & 0.0000 \\ 0.1165 & 0.2085 & 0.6654 & 0.7653 & 0.9685 & 0.0000 & 5.0000 & 0.0000 \\ 0.1165 & 0.2085 & 0.6654 & 0.7653 & 0.9685 & 0.0000 & 0.0000 & 6.0000 \end{bmatrix}$$

采用蒙特卡洛模拟的方法产生30组样本数据。由第I阶段建立的控制图可以计算出控制限,依据模拟的样本数据,采用式(2)和式(3)进行

均值和方差的估计,得到均值估计量为 $(-0.0140, 0.2967, -0.0795, -0.2556, 0.0190, 0.2946, 0.1393, 0.0670)$,方差估计量为

$$S = \begin{bmatrix} 0.8584 & 0.6020 & -0.2052 & -0.0336 & 0.0566 & 0.2213 & -0.3813 & -0.1386 \\ 0.6020 & 1.5980 & 0.2028 & -0.5084 & 0.1273 & -0.1585 & -0.2761 & 0.9138 \\ -0.2052 & 0.2028 & 5.5886 & 2.1503 & 0.3690 & 4.6190 & 0.1193 & 1.4662 \\ -0.0336 & -0.5084 & 2.1503 & 5.3470 & -0.2127 & 1.7454 & 0.4778 & -0.1744 \\ 0.0566 & 0.1273 & 0.3690 & -0.2127 & 0.7443 & 0.9841 & 0.1326 & 0.9043 \\ 0.2213 & -0.1585 & 4.6190 & 1.7454 & 0.9841 & 9.2200 & -0.1031 & 1.9602 \\ -0.3813 & -0.2761 & 0.1193 & 0.4778 & 0.1326 & -0.1031 & 1.9703 & 1.3111 \\ -0.1386 & 0.9138 & 1.4662 & -0.1744 & 0.9043 & 1.9602 & 1.3111 & 5.3417 \end{bmatrix}$$

采用式(4)对所有 T^2 统计量进行计算,并计算其判定界限 UCL,取第 1 类错误概率为 $\alpha = 0.05$,采用式(5)计算对应的 UCL:

$$UCL = \frac{8 \times (30 + 1) \times (30 - 1)}{30 \times (30 - 8)}$$

$$F_{1,30-1}(0.05) = 26.1528$$

根据上述分析建立控制图,如图 8 所示,可以看到所有样本的统计量都在控制限范围之内,过程受控,则第 I 阶段所建立的控制图合理,可以应用本工序本截面线后续加工的监控过程,即监控第 II 阶段的加工过程是否依然受控。

为了进行异常的诊断,本文在第 II 阶段考虑了两种不同的异常情况,来进行波动监控和误差溯源。第 1 种是考虑上道工序的影响而带来的全局误差源和本道工序的局部误差源同时存在的情况;第 2 种是仅考虑本道工序所产生的局部误差源的情况。

1) 假定榫头加工误差生成偏差,引起第 2 道工序的基准产生偏差,即考虑多工序误差传递的影响,则给基准 X_{i1} 引入一个均值偏移 $\Delta \bar{x}_{i1} = 3$,同时给局部误差源装夹 X_{i2} 引入 $\Delta \bar{x}_{i2} = 0.11$,扭转 X_{i8} 引入 $\Delta \bar{x}_{i8} = 0.685$,其他的均值保持不变。这表示上道工序产生的基准存在质量波动,并伴有装夹误差,使得叶身的扭转量产生波动,导致过程

不稳定,这样继续生产下去,不进行误差源的分析 and 过程调整可能会由于生产过程的继续致使误差累积会在后续加工中产生质量问题。在均值发生上述变化,方差保持不变的情况下采用蒙特卡洛方法模拟 22 个样本,采用式(11)计算第 II 阶段的 T^2 统计量,并与第 I 阶段所计算的控制限进行比较,所建立的监控控制图如图 9 所示。

由图 9 可以看出有 4 个样本点超出控制线,过程失控,要确定失控原因,需要依据式(14)对失控的 T^2 统计量进行分解,选取第 3 个失控的样本点(5.48894, -0.98680, 0.95561, 0.69715, -0.18461, 0.90815, 1.79677, 5.03821)进行诊断,其对应的 T^2 统计量为 52.6556,由式(17)的第 1 个公式计算独立项的控制限为

$$UCL_d = \frac{30 + 1}{30} F_{1,30-1}(0.05) = 4.3193$$

由式(17)的第 2 个公式计算 1 个条件项和 2 个条件项的控制限分别为

$$UCL_1 = \frac{(30 + 1) \times (30 - 1)}{30 \times (30 - 1 - 1)}$$

$$F_{1,30-1-1}(0.05) = 4.4950$$

$$UCL_2 = \frac{(30 + 1) \times (30 - 1)}{30 \times (30 - 2 - 1)}$$

$$F_{1,30-2-1}(0.05) = 4.8337$$




图 8 第 I 阶段 T^2 控制图的建立

Fig. 8 Establishment of the phase one T^2 control chart

由式(15)可计算得到各个 T^2 统计量的值, 将 T^2 的计算值与上面计算的不同条件下的控制限建立表格进行比较, 可得到第 3 个失控样本具体的失控原因, 如表 1 所示。由表 1 可知诊断出了基准产生波动、装夹产生波动和扭转产生波动, 可见诊断出了全部设定的误差源。

选取第 2 个失控的样本点进行操作, 其他样本点类似。此时异常样本点对应的值为 (4.808 27, -0.283 27, 2.401 45, -2.950 70, 0.036 32, 3.603 12, -0.407 10, -0.541 15), 对应的 T^2 统计量为 47.140 0, 采用上述方法计算的结果如表 2 所示。由表 2 可知诊断出了基准产生波动和装夹产生波动, 但未诊断出扭转产生波动, 只诊断出部分误差源。可以得出每个样本所能给出的诊断信息不一样, 需要对每个失控的样本进行诊断, 以确定失控原因, 如何获取包含诊断信息比较全面的样本, 减小诊断次数, 提高诊断效

率需要进一步研究。

2) 假定过程中由于存在装夹波动 \mathbf{X}_{i2} 、刀具缺陷 \mathbf{X}_{i3} 和刀具路径波动 \mathbf{X}_{i4} 几个局部误差源, 而引发本道工序产生了波动, 使得叶身的弯曲 (\mathbf{X}_{i6} 和 \mathbf{X}_{i7}) 产生了波动。给 \mathbf{X}_{i2} 、 \mathbf{X}_{i3} 和 \mathbf{X}_{i4} 分别引入均值偏移 $\Delta\bar{x}_{i2} = 3.015\ 3$ 、 $\Delta\bar{x}_{i3} = 3.431\ 59$ 和 $\Delta\bar{x}_{i4} = 3.644\ 95$ 。叶身的加工是以榫头为定位基准的, 因此还存在由于榫头加工误差而产生的基准误差, 这里假设基准没有产生均值波动, 即基准产生的误差不足以使叶身制造过程发生波动。这些存在的误差源使得叶片发生了弯曲变形, 即 \mathbf{X}_{i6} 和 \mathbf{X}_{i7} 产生了均值波动分别为 $\Delta\bar{x}_{i6} = 2.660\ 47$ 和 $\Delta\bar{x}_{i7} = 1.784\ 97$, 方差保持不变, 采用蒙特卡洛方法模拟 22 个样本, 采用式(11)计算第 II 阶段的 T^2 控制量, 并与第 I 阶段所计算的控制限进行比较, 所建立的监控控制图如图 10 所示。

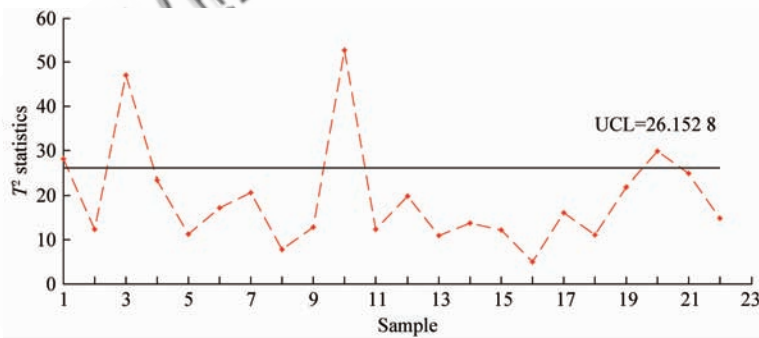


图 9 第 1 种误差情况下 T^2 控制图监控结果

Fig. 9 Monitoring results of T^2 control chart in the first error case

表 1 第 1 种误差情况下第 3 个失控样本的诊断信息

Table 1 Diagnostic information of the third sample out of control in the first error case

T^2 name	T_1^2	T_3^2	T_5^2	$T_{2,1}^2$	$T_{4,2,3}^2$	$T_{6,5,4}^2$	$T_{7,5,4}^2$	$T_{8,5,4}^2$
T^2 value	35.277 7	0.191 7	0.036 8	8.541 7	0.820 4	0.0408	1.360 9	6.385 6
Their UCL	4.319 3	4.319 3	4.319 3	4.4950	4.833 7	4.8337	4.833 7	4.833 7
Error source	✓			✓				✓

表 2 第 1 种误差情况下第 2 个失控样本的诊断信息

Table 2 Diagnostic information of the second sample out of control in the first error case

T^2 name	T_1^2	T_3^2	T_5^2	$T_{2,1}^2$	$T_{4,2,3}^2$	$T_{6,5,4}^2$	$T_{7,5,4}^2$	$T_{8,5,4}^2$
T^2 value	27.090 3	1.101 4	0.000 4	13.349 3	3.268 6	2.166 5	0.078 0	0.085 5
Their UCL	4.319 3	4.319 3	4.319 3	4.495 0	4.833 7	4.833 7	4.833 7	4.833 7
Error source	✓			✓				

由图 10 可以看出有 2 个样本出现失控,取第 2 个失控的样本进行诊断,对应的样本值为(0.547 797, 3.575 60,5.608 90,1.076 87,-1.134 60,6.049 89, 5.218 65,-0.959 818),对应的 T^2 统计量为 42.213 7,依据式(14)对其进行分解,采用式(15)计算独立项和条件项的 T^2 统计量值,采用式(17)计算独立项和条件项的控制限值,并将独立项和条件项的统计量分别与各自的控制限进行比较,具体结果如表 3 所示。可以看出第 2 个变量、第 5 个变量和第 8 个变量超出控制限,因此诊断存在装夹误差和让刀变形,因此在存在装夹误差和让刀变形的情况下,叶身的扭转量也超出了控制限,

与前面模拟假定的结果一致。

取第 3 个失控的样本进行诊断,样本值为(-0.513 10,3.180 82,8.470 04,4.561 32,0.762 98, 2.327 98,1.396 69,0.981 80),对应的 T^2 统计量为 29.585 2,采用如上方法可以计算得到如表 4 所示的结果,可以看出只能诊断出刀具和装夹两个误差源,诊断的信息不全面。

综上,可知本文所提的方法可以对过程中的异常进行有效的监控,并且可以对异常产生的原因进行有效的识别。如何在异常点中寻找出包含诊断信息比较全面的样本点,提高诊断效率,是本文需要进一步研究的内容。

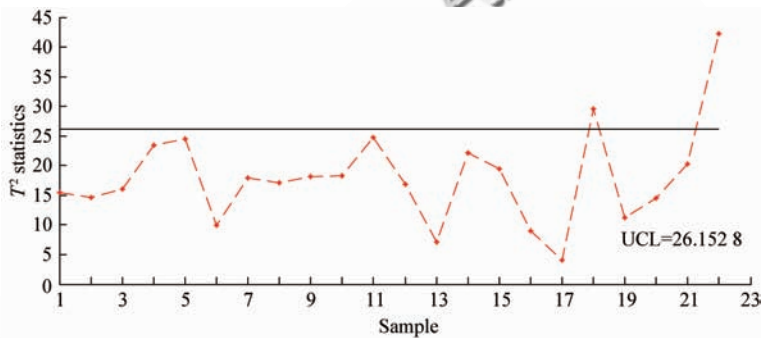


图 10 第 2 种误差情况下 T^2 控制图监控结果

Fig. 10 Monitoring result of T^2 control chart in the second error case

表 3 第 2 种误差情况下第 2 个失控样本的诊断信息

Table 3 Diagnostic information of the second sample out of control in the second error case

T^2 name	T_1^2	T_3^2	T_5^2	$T_{2,1}^2$	$T_{4,2,3}^2$	$T_{6,5,4}^2$	$T_{7,5,4}^2$	$T_{8,5,4}^2$
T^2 value	0.367 7	5.790 0	1.788 0	7.078 2	6.312 8	6.658 8	14.187 8	0.030 4
Their UCL	4.319 3	4.319 3	4.319 3	4.495 0	4.833 7	4.833 7	4.833 7	4.833 7
Error source		✓		✓	✓	✓	✓	

表 4 第 2 种误差情况下第 3 个失控样本的诊断信息

Table 4 Diagnostic information of the third sample out of control in the second error case

T^2 name	T_1^2	T_3^2	T_5^2	$T_{2,1}^2$	$T_{4,2,3}^2$	$T_{6,5,4}^2$	$T_{7,5,4}^2$	$T_{8,5,4}^2$
T^2 value	0.290 2	13.079 2	0.743 7	8.895 7	1.248 7	4.477 6	0.849 8	0.000 3
Their UCL	4.319 3	4.319 3	4.319 3	4.495 0	4.833 7	4.833 7	4.833 7	4.833 7
Error source		✓		✓				

6 结论

1) 针对叶片加工过程,从制造系统层面分析了影响叶片加工质量的多种因素,并分析了它们之间的相互关系。

2) 采用动态 Bayesian 网络对不同工序的各

种影响因素建立了因果关系,并采用 MSPC 的方法对叶片加工的各个工序进行了监控,对失控状态进行报警。

3) 对失控状态进行误差溯源时,以 T^2 控制图和 Bayesian 网络为基础得到了统一的 T^2 分解方式,并确立各分解式的判定界限,实现了叶片加

工过程的误差溯源。

4) 运用该方法对某叶片的加工过程采用仿真分析的方式进行监控和误差溯源, 仿真结果验证了本文所提出的质量监控与误差溯源方法的有效性。

5) 如何快速寻找出包含全部诊断信息的异常样本点, 减少诊断次数、提高诊断效率, 是需要进一步研究的内容。

参 考 文 献

- [1] Chiang L H, Russell E L, Braatz R D. Fault detection and diagnosis in industrial systems. New York: Springer-Verlag, 2001.
- [2] Venkatasubramanian V, Rengaswamy R, Yin K, et al. A review of process fault detection and diagnosis part I: quantitative model-based methods. *Computers and Chemical Engineering*, 2003, 27(3): 293-311.
- [3] Chen W D, Miao R, Zhao Y Z, et al. Multivariate statistical process diagnosis based on path diagram. *Journal of Shanghai Jiaotong University*, 2010, 44(12): 1758-1762. (in Chinese)
陈文多, 苗瑞, 赵言正, 等. 基于路径图的多元统计过程诊断. *上海交通大学学报*, 2010, 44(12): 1758-1762.
- [4] Chan F T. Application of a hybrid case-based reasoning approach in electroplating industry. *Expert Systems with Applications*, 2005, 29(1): 121-130.
- [5] Patton R J, Frank P M, Clark R N. Issues of fault diagnosis for dynamic systems. New York: Springer, 2000.
- [6] Du S C, Xi L F, Pan E S. Modeling & controlling of product quality in serial-parallel hybrid multi-stage manufacturing systems. *Computer Integrated Manufacturing Systems*, 2006, 12(7): 1068-1073. (in Chinese)
杜世昌, 奚立峰, 潘尔顺. 串并联混合式多阶段制造系统产品质量建模与控制. *计算机集成制造系统*, 2006, 12(7): 1068-1073.
- [7] Liu D Y, Jiang P Y. Fluctuation analysis of process flow based on error propagation network. *Chinese Journal of Mechanical Engineering*, 2010, 46(2): 14-21. (in Chinese)
刘道玉, 江平宇. 基于误差传递网络的工序流波动分析. *机械工程学报*, 2010, 46(2): 14-21.
- [8] Jin M, Tsung F. A chart allocation strategy for multistage processes. *IIE Transactions*, 2008, 41(9): 790-803.
- [9] Li Y, Tsung F. False discovery rate-adjusted charting schemes for multistage process fault diagnosis and isolation. *Technometrics*, 2008, 51(2): 186-205.
- [10] Du F Z, Tang X Q, Sun J. ARL computation and parameters optimization for MEWMA control chart based on the Markov chain. *Journal of Beijing University of Aeronautics and Astronautics*, 2006, 32(8): 974-978. (in Chinese)
杜福洲, 唐晓青, 孙静. MEWMA 控制图 ARL 计算及参数优化. *北京航空航天大学学报*, 2006, 32(8): 974-978.
- [11] Du F Z, Sun J, Tang X Q. Run length analysis for multivariate cumulative sum control chart based on Markov chains. *Journal of Tsinghua University: Science and Technology*, 2007, 47(2): 169-172. (in Chinese)
杜福洲, 孙静, 唐晓青. 基于 Markov 链的 MCUSUM 控制图链长分析. *清华大学学报: 自然科学版*, 2007, 47(2): 169-172.
- [12] Xiang L, Tsung F. Statistical monitoring of multistage processes based on engineering models. *IIE Transactions*, 2008, 40(10): 957-970.
- [13] Zantek P F, Li S, Chen Y. Detecting multiple special causes from multivariate data with applications to fault detection in manufacturing. *IIE Transactions*, 2007, 39(8): 771-782.
- [14] Kamal H, Meisam P, Hosein M. Fault diagnosis and classification based on wavelet transform and neural network. *Progress in Nuclear Energy*, 2011, 53(1): 41-47.
- [15] Doganaksoy N, Faltin F W, Tucker W T. Identification of out of control multivariate characteristic in a multivariable manufacturing environment. *Communications in Statistics*, 1991, 20(9): 2775-2790.
- [16] Cui X, Guo W, Lin L, et al. Covariate-adjusted nonlinear regression. *Annals of Statistics*, 2009, 37(4): 1839-1870.
- [17] Senturk D. Covariate-adjusted varying coefficient models. *Biostatistics*, 2006, 7(2): 235-251.
- [18] Marvelakis P E, Bersimis S, Panaretos J, et al. Identifying the out of control variable in a multivariate control chart. *Journal of Quality Technology*, 2002, 31(12): 2391-2408.
- [19] Aparisi F, Avendano G, Sanz J. Techniques to interpret T^2 control chart signals. *IIE Transactions*, 2006, 38(8): 647-657.
- [20] Sun H C, Yan Z Y, Xie L Y. Recognition based on wavelet neural network for sucker rod's defects. *Journal of Northeastern University: Natural Science*, 2008, 29(2): 258-261. (in Chinese)
孙红春, 阎志颖, 谢里阳. 基于小波神经网络的抽油杆缺陷识别. *东北大学学报: 自然科学版*, 2008, 29(2): 258-261.
- [21] Nie S C, Tang X Q. Research on quality fault diagnosis in mechanical machining process based on genetic algorithm. *Acta Aeronautica et Astronautica Sinica*, 2001, 22(6): 521-524. (in Chinese)
聂胜才, 唐晓青. 基于基因算法的加工质量故障诊断研究
© 航空学报编辑部 <http://hkxb.buaa.edu.cn>

与实现. 航空学报, 2001, 22(6): 521-524.

- [22] Niaki S T A, Abbasi B. Fault diagnosis in multivariate control chart using artificial neural networks. *Quality Reliability Engineering International*, 2005, 21(8): 825-840.
- [23] Zeng L, Zhou S. Variability monitoring of multistage manufacturing processes using regression adjustment methods. *IIE Transactions*, 2008, 40(2): 109-121.
- [24] Bersimis S, Psarakis S, Panaretos J. Multivariate statistical process control charts: an overview. *Quality Reliability Engineering International*, 2007, 23(5): 517-543.
- [25] Mason R L, Tracy N D, Young J C. Decomposition of T^2 for multivariate control chart interpretation. *Journal of Quality Technology*, 1995, 27(2): 109-119.

- [26] Li J, Jin J, Shi J. Causation-based T^2 decomposition for multivariate process monitoring and diagnosis. *Journal of Quality Technology*, 2008, 40(1): 46-58.

作者简介:

王佩 女, 博士研究生。主要研究方向: CAD/CAM 技术, 集成制造技术, 质量工程, 制造业信息化技术。

Tel: 029-88493232-415

E-mail: abinghoney@163.com

张定华 男, 博士, 教授, 博士生导师。主要研究方向: CAD/CAM 技术, 集成制造技术, 计算机图形图像。

Tel: 029-88493009

E-mail: dhzhang@nwpu.edu.cn

Machining Quality Monitoring of Blades and Source Tracing Based on Dynamic Bayesian Network

WANG Pei, ZHANG Dinghua^{*}, CHEN Bing, LI Shan, WANG Mingwei

Key Laboratory of Contemporary Design and Integrated Manufacturing Technology, Ministry of Education, Northwestern Polytechnical University, Xi'an 710072, China

Abstract: A methodology of monitoring the machining quality of blades and tracing the error source based on dynamic Bayesian network is proposed for solving the low accuracy of blade machining quality. Dynamic Bayesian network is used to establish the relationship between blade machining operations to realize the control of the whole machining process. The causal relation between the elements in the main process factor set that affects blade machining operations is built by Bayesian network. The control chart T^2 is used to monitor the factor set of each operation to judge whether the operation is out of control or not. While tracing error sources, the T^2 statistics of the samples out of control are decomposed according to causal variables described by aforementioned causal relation, and the decomposed variable control limits are built as error source judgment conditions are built. A simulation study on a blade machining process is carried out, which demonstrates that the proposed method is reasonable.

Key words: aeroengine; blade machining; quality monitoring; error source tracing; dynamic Bayesian network; error decomposition

Received: 2011-05-06; Revised: 2011-08-22; Accepted: 2011-10-24; Published online: 2011-11-07 10:19

URL: www.cnki.net/kcms/detail/11.1929.V20111107.1019.001.html

DOI: CNKI:11-1929/V.20111107.1019.001

Foundation item: National Natural Science Foundation of China (70931004)

* Corresponding author. Tel.: 029-88493009 E-mail: dhzhang@nwpu.edu.cn