

基于 WSVR 和 FCM 聚类的实时寿命预测方法

胡友涛¹ 胡昌华¹ 孔祥玉¹ 周志杰¹

摘要 针对产品的性能退化轨迹呈现为非线性特性,且个体的性能退化数据为小样本的情形,为了充分利用同类产品的性能退化数据进行特定个体的实时寿命预测,从研究退化轨迹相似性的角度出发,提出一类基于小波支持向量回归机(Wavelet support vector regression, WSVR)和模糊 C 均值(Fuzzy *c*-means, FCM)聚类的实时寿命预测方法.该方法分为离线和实时两个阶段:离线阶段先采用 WSVR 对同类产品的性能退化数据进行规范化处理,接着对规范化数据进行 FCM 聚类,然后,基于 WSVR 建立各聚类中心的退化轨迹模型;在实时阶段,针对特定个体的历史测量数据是否规范化,分别提出两种实时退化轨迹建模和寿命预测方法——隶属度加权法和误差加权法.最后,通过两个实例分析验证了所提方法的有效性.

关键词 性能退化,小波支持向量回归机,模糊 C 均值聚类,实时寿命预测

DOI 10.3724/SP.J.1004.2012.00331

Real-time Lifetime Prediction Method Based on Wavelet Support Vector Regression and Fuzzy *c*-means Clustering

HU You-Tao¹ HU Chang-Hua¹ KONG Xiang-Yu¹ ZHOU Zhi-Jie¹

Abstract For the case where the products have nonlinear performance degradation paths and there is little performance degradation data for each individual, in order to take full advantage of performance degradation data of the same kind of products in individual real-time lifetime prediction, as viewed from the comparability of degradation paths, a class of real-time lifetime prediction methods are proposed, on the basis of wavelet support vector regression (WSVR) and fuzzy *c*-means (FCM) clustering. The methods consist of two stages, called offline and real-time stages. In the offline stage, WSVR is employed to normalize performance degradation data, and FCM is used to classify the normalized data, then WSVR is adopted again to build the cluster centers' degradation path models. In the real-time stage, depending on whether the specific individual's historical data is normalized or not, two real-time model-building methods, named degree-of-membership-based weighted method and error-based weighted method, are proposed. And then, by combining with the specific individual's real-time measurement, its degradation path model is renewed, and its lifetime is predicted. Two example analyses are executed based on fatigue crack growth data and the CG36A transistor degradation data, and the experimental results validate the validity of the two proposed methods.

Key words Performance degradation, wavelet support vector regression (WSVR), fuzzy *c*-means (FCM) clustering, real-time lifetime prediction

随着科技的进步,航空航天、军事、电子工业等领域的部件和系统变得越来越复杂.这些部件和系统一旦发生事故,就有可能造成灾难性的后果.例如:“切尔诺贝利”核电站事故、“挑战者”号航天飞机的失事、“澳星”的发射失败和吉林石化公司双苯厂重大爆炸事故等都带来了巨大的经济损失和人员伤亡^[1].因此,在部件或系统未受到重大危害前即进行剩余寿命预测,能够为其延寿和最优维护决策提

供重要的依据.

现有的寿命预测方法中,基于失效时间分析的方法依赖于失效数据,而工程实践中高可靠、长寿命产品的失效数据一般极少,即使采用加速寿命试验也很难获取;基于性能退化分析的方法是目前的一个研究热点,根据部件或系统的性能退化数据建立退化轨迹模型,预测性能退化值并结合失效阈值预测失效时间^[2-4].退化轨迹建模方法可分为两类:1) 基于机理的建模方法^[5-9],根据部件或系统的物理特性或者失效机理建立模型,但大部分复杂部件或系统的失效机理很难准确获知;2) 基于数据驱动的建模方法,采用随机效应回归技术^[4, 10-18]、时间序列分析技术^[19-20]、系统辨识技术^[21]、神经网络^[3, 22-23]和支持向量机^[24-25]、Gamma 过程^[26]等方法对历史性能退化数据进行拟合,建立退化轨迹模型,该类方法不依赖于失效机理,具有灵活多样性.这两类模型都能够实现离线的寿命预测.近年来,实时寿命预测越来越受到重视,提出了不少实时

收稿日期 2011-01-25 录用日期 2011-11-09
Manuscript received January 25, 2011; accepted November 9, 2011

国家自然科学基金(60736026, 61074072, 61004069), 国家杰出青年基金(61025014)资助
Supported by National Natural Science Foundation of China (60736026, 61074072, 61004069) and National Funds for Distinguished Young Scientists of China (61025014)

本文责任编辑 姜斌
Recommended by Associate Editor JIANG Bin

1. 第二炮兵工程大学自动化系 西安 710025
1. Department of Automation, Xi'an Institute of Hi-Tech, Xi'an 710025

建模和寿命预测方法. 如: Gebraeel 等^[3] 用神经网络建立同类轴承的退化轨迹模型, 根据对轴承个体的实时估计误差确定权值, 结合同类轴承的指数模型进行实时寿命预测; Gebraeel 等^[23] 用文献 [3] 的方法计算轴承个体在历史测量时刻的寿命估计值并得到先验寿命分布, 然后, 结合新的寿命估计值更新寿命分布; Gebraeel 等^[12-14, 23] 还研究了含随机参数的线性和指数退化轨迹模型, 采用贝叶斯方法更新剩余寿命分布; Chinnam^[11] 基于一般多项式回归模型实时估计个体的可靠性; Xu 等^[18] 将文献 [12] 的方法推广到含随机参数的一般非线性退化轨迹模型; Lu 等^[19] 用状态空间模型对多元性能退化量进行实时建模和可靠性评估; Xu 等^[21] 针对带有隐含性能退化过程的非线性动态系统, 基于粒子滤波算法估计系统状态、隐性能变量和未知参数, 从而实现实时可靠性预测; 胡昌华等^[24] 针对小样本情形给出加权支持向量机回归模型; 李常有等^[26] 给出基于平稳 Gamma 过程退化模型及贝叶斯估计的实时可靠性评估方法; 赵焯等^[27] 给出基于退化量分布模型及贝叶斯估计的实时可靠性评估方法. 然而, 上述研究并没有充分利用同类产品性能退化数据包含的丰富信息, 特别是退化轨迹之间同时存在着几乎相同和差异较大这一情况. 通过研究特定个体与同类产品的退化轨迹相似性, 可以找到与特定个体最相似的退化轨迹, 如果基于相似性加权同类产品的退化轨迹, 并以此作为特定个体的退化轨迹进行寿命预测, 则可能获得更为可信的结果. 因此, 本文从退化轨迹相似性的角度开展个体实时寿命预测方法的研究.

复杂产品的退化轨迹通常为非线性, 而高可靠、长寿命产品由于价格昂贵和测量损伤等原因导致每个产品往往是小样本性能退化数据. 如何在小样本、非线性情形下建立每个产品的性能退化轨迹模型是本文要解决的一个基础性问题. 基于统计学习理论的支持向量机实现了结构风险最小化准则, 具有结构简单、泛化能力强、小样本学习能力等优点, 它通过引入核函数将线性不可分转化为特征空间线性可分, 最后, 化为一个线性约束的凸二次规划求解问题^[28]; Morlet 小波核函数已被证明是具有平移不变性的可容许支持向量机核函数, 不仅具有非线性映射特征, 而且还继承了子波分析对非平稳信号的逐级精细描述的特征^[29]. 因此, 本文采用小波支持向量回归机 (Wavelet support vector regression, WSVR) 进行退化轨迹建模. 为提高 WSVR 的精度, 采用遗传算法 (Genetic algorithm, GA) 优化模型的参数.

对于退化轨迹相似性的确定, 本文提出以规范化测量时刻为基准, 将对应的退化测量值向量作为特征向量, 则特征向量间的 Euclid 距离能反映相似性. 考虑到某些同类产品的退化轨迹可能几乎相同,

当该类情形较为突出时, 在离线阶段合并相似的退化轨迹, 有利于减少实时寿命预测阶段的加权计算量. 模糊 C 均值 (Fuzzy c-means, FCM) 聚类算法是一种基于目标函数的聚类方法, 它通过反复修改聚类中心集和隶属度矩阵来实现动态的迭代聚类, 使得被划分到同一簇的对象之间相似度最大, 而不同簇之间的相似度最小^[30]. 因此, 无论同类产品退化轨迹的结构相同与否, 对其特征向量进行 FCM 聚类分析均可实现有效的合并和分类. 最终, 本文提出一类基于 WSVR 和 FCM 聚类的实时寿命预测方法.

为了清楚地解释算法, 定义如下符号标记: 小写斜体字符如 $t, y, t_{ij}, y_{ij}, \dots$ 表示标量; 小写粗斜体字符如 $\mathbf{v}_k, \mathbf{x}_i, \mathbf{y}_i, \dots$ 表示列向量; 大写字母如 C, D, T, \dots 表示特殊标量或数据集; 大写粗斜体字符如 $\mathbf{U}, \mathbf{V}, \mathbf{Y}, \dots$ 表示矩阵, 矩阵 $\mathbf{Y} \in \mathbf{R}^{m \times n}$ 由样本 $\mathbf{y}_i, i = 1, 2, \dots, n$ 作为列而构成.

1 问题描述和预备知识

1.1 问题描述

设产品在恒定应力水平下工作, 其某项性能参数 y 会随着运行时间 t (或者行程距离、应力周期次数等) 呈单调递增或递减的趋势变化, 定义当 y 达到失效阈值 η 时产品发生失效.

定义 1. 设 $[t_1; t_2; \dots; t_m]$ 为规范化测量时刻, 共 n 个同类产品, t_{ij} 为第 i 个产品的第 j 次测量时刻, y_{ij} 为退化测量值, m_i 为第 i 个产品的总测量次数, $D_i = \{(t_{ij}, y_{ij}), j = 1, 2, \dots, m_i\}$ 为第 i 个产品的性能退化数据, $D_Z = \{(t_{Zj}, y_{Zj}), j = 1, 2, \dots, m_Z\}$ 为特定个体的历史测量数据. 若 $\prod_{j=1}^{m_i} P(t_{ij} = t_j) = 1$ 成立, 则称 D_i 为规范化性能退化数据. 若 $\prod_{j=1}^{m_Z} P(t_{Zj} = t_j) = 1$ 成立, 则称 D_Z 为规范化历史测量数据.

本文所要解决的问题是:

1) 基于 $D_i (i = 1, 2, \dots, n)$ 和 D_Z 建立特定个体的退化轨迹模型, 即 y 与 t 之间的函数关系模型 $y = f_Z(t)$; 并结合 η 预测失效时间 T , 即求解 $\eta = f_Z(T)$, 从而得到剩余寿命预测值 $(T - t)$.

2) 根据特定个体的实时测量数据 (t, y_Z) 更新模型 $y = f_Z(t)$, 从而实现实时寿命预测.

1.2 预备知识

1.2.1 WSVR 原理

给定 l 个训练数据 $\{(\mathbf{x}_i, y_i), \mathbf{x}_i \in \mathbf{R}^h, y_i \in \mathbf{R}, i = 1, 2, \dots, l\}$, 根据结构风险最小化准则, 标准支持向量回归机模型的优化目标和约束条件为^[28]

$$\begin{aligned} \min_{\omega, \xi^{(*)}, b} & \frac{1}{2}(\omega \cdot \omega) + \frac{C}{l} \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t.} & ((\omega \cdot \varphi(\mathbf{x}_i)) + b) - y_i \leq \varepsilon + \xi_i \\ & y_i - ((\omega \cdot \varphi(\mathbf{x}_i)) + b) \leq \varepsilon + \xi_i^* \\ & \xi_i^{(*)} \geq 0, \quad \forall i = 1, 2, \dots, l \end{aligned} \quad (1)$$

式中, ω 为特征空间中的权值向量; ε ($\varepsilon > 0$) 为不敏感参数; C ($C > 0$) 为惩罚参数, 控制对超出 ε 的样本的惩罚程度; $\xi_i^{(*)}$ 为松弛因子, 是对 ξ_i 和 ξ_i^* 的统一表述; $\varphi(\cdot)$ 为从输入空间到特征空间的映射, 由其构成核函数. 本文选择的 Morlet 小波核函数形式为^[29]

$$\begin{aligned} K(\mathbf{x}_i, \mathbf{x}_j) &= \prod_{k=1}^h \varphi\left(\frac{x_{ik} - x_{jk}}{a_k}\right) = \\ & \prod_{k=1}^h \left[\cos\left(1.75 \frac{x_{ik} - x_{jk}}{a_k}\right) \exp\left(-\frac{\|x_{ik} - x_{jk}\|^2}{2a_k^2}\right) \right] \end{aligned} \quad (2)$$

式中, h 为输入向量 \mathbf{x}_i 的维数; a_k 为伸缩因子.

利用对偶原理, 同时引入 Lagrange 乘子和核函数, 求解原始问题 (1) 的对偶问题得到 WSVR 的决策函数:

$$f(\mathbf{x}) = \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(\mathbf{x}_i, \mathbf{x}) + b \quad (3)$$

式中, α_i 和 α_i^* 为 Lagrange 乘子; b 为偏置.

1.2.2 FCM 聚类原理

n 个样本的特征向量 \mathbf{y}_i 构成矩阵 $\mathbf{Y} \in \mathbf{R}^{m \times n}$, 将其分为 c ($2 \leq c < n$) 类. 设 $\mathbf{V} \in \mathbf{R}^{m \times c}$ 为聚类中心集, \mathbf{v}_k 为第 k 个聚类中心, d_{ki} 为 \mathbf{y}_i 与 \mathbf{v}_k 的 Euclid 距离, $\mathbf{U} \in \mathbf{R}^{c \times n}$ 为隶属度矩阵, u_{ki} 为 \mathbf{y}_i 对 \mathbf{v}_k 的隶属度. 建立一个基于可能性分布的聚类有效性函数 $F(\mathbf{U}; c)$ ^[30]:

$$F(\mathbf{U}; c) = \frac{1}{n} \sum_{k=1}^c \sum_{i=1}^n u_{ki}^2 - \frac{1}{c} \sum_{k=1}^c \left[\left(\sum_{i=1}^n u_{ki} \right)^{-1} \sum_{i=1}^n u_{ki}^2 \right] \quad (4)$$

选择使得 $F(\mathbf{U}; c)$ 取值最小的 c 值为最优聚类数, 记为 \bar{c} . \bar{c} 值下求得的最优聚类中心集和隶属度矩阵分别记为 $\hat{\mathbf{V}}$ 和 $\hat{\mathbf{U}}$. 最优 FCM 聚类算法基本步骤如下:

步骤 1. 设定加权指数 q 和迭代停止阈值 δ , 令 $c = 2$.

步骤 2. 令迭代次数 $p = 0$, 初始化 $\mathbf{V}(p) = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_c]$.

步骤 3. 根据式 (5) 计算隶属度矩阵 \mathbf{U} , 根据 $\hat{\mathbf{U}}_k = (\sum_{i=1}^n u_{ki}^q)^{-1} (\sum_{i=1}^n u_{ki}^q \mathbf{y}_i)$ 计算新的聚类中心集 $\hat{\mathbf{V}}(p)$.

$$u_{ki} = \begin{cases} 0, & \text{若 } d_{kj} = 0, \text{ 且 } j \neq i \\ \left[\sum_{j=1}^c (d_{ki} d_{kj}^{-1})^{\frac{2}{q-1}} \right]^{-1}, & \text{若 } d_{ki} \neq 0, d_{kj} \neq 0 \\ 1, & \text{否则} \end{cases} \quad (5)$$

步骤 4. 如果 $\|\hat{\mathbf{V}}(p) - \hat{\mathbf{V}}(p-1)\| > \delta$, 令 $p = p + 1$ 并转步骤 3; 否则根据式 (4) 计算聚类有效性函数值, 令 $c = c + 1$ 并转步骤 5.

步骤 5. 如果 $c < n$, 转步骤 2; 否则选择使得 $F(\mathbf{U}; c)$ 取值最小的 c 值为 \bar{c} , 并获得对应的 $\hat{\mathbf{V}}$ 和 $\hat{\mathbf{U}}$.

2 基于 WSVR 和 FCM 的实时寿命预测方法

本文所提方法的完整流程图如图 1 所示, 整个方法分为离线和实时两个阶段:

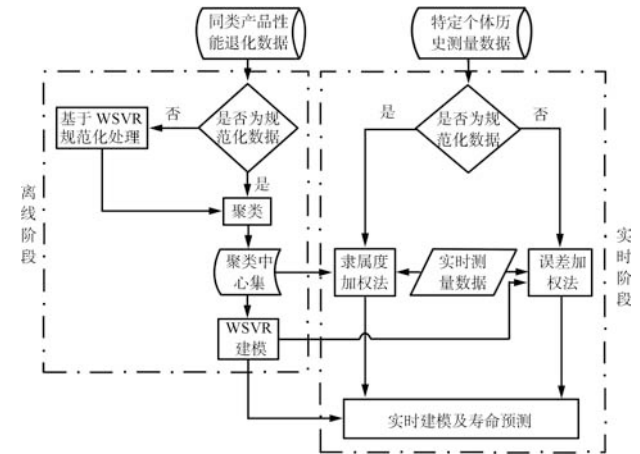


图 1 基于 WSVR 和 FCM 聚类的实时寿命预测方法流程图

Fig.1 The flow chart of real-time lifetime prediction method based on WSVR and FCM clustering

1) 离线阶段. 首先, 判断同类产品的性能退化数据是否为规范化性能退化数据, 是则直接进行最优 FCM 聚类, 否则基于 WSVR 进行规范化处理后再进行最优 FCM 聚类; 最后, 基于 WSVR 建立各聚类中心的退化轨迹模型.

2) 实时阶段. 首先, 判断特定个体的历史测量数据是否为规范化历史测量数据, 是则采用隶属度加权法, 否则采用误差加权法, 得到特定个体的退化

轨迹模型;再结合特定个体的实时测量数据进行模型更新和寿命预测。

2.1 离线阶段

根据 n 个产品的测量时刻和测量次数确定合适的规范化测量时刻,确定原则为:1)力求测量次数尽量多,测量时刻尽量等间距;2)力求需规范化处理的产品个数尽量少。工程实践中,由于各用户对同类产品进行测量的时刻和次数可能不一致,导致收集的数据不一定是规范化性能退化数据。因此,对同类产品的退化轨迹进行最优 FCM 聚类之前,需要先作规范化判断,如果为非规范化数据,则基于 WSVR 进行退化轨迹建模和规范化处理。

2.1.1 基于 WSVR 建模的规范化处理

假设 D_k 需要进行规范化处理,基本思想是:首先,基于 WSVR 原理建立 D_k 的退化轨迹模型 $f_k(t)$,然后,用 $f_k(t)$ 估计 D_k 相对规范化测量时刻缺少时刻处的性能退化值。WSVR 模型参数 (ε, C, a) 的确定是影响预测精度的重要因素,鉴于 GA 具有优秀的全局搜索能力,本文采用 GA 优化参数,以检验集的平均相对估计误差为适应度函数:

$$e(\mathbf{g}, \hat{\mathbf{g}}_p) = \frac{1}{h} \sum_{j=1}^h \left| \frac{g_j - \hat{g}_{pj}}{g_j} \right| \times 100\% \quad (6)$$

式中, \mathbf{g} 为检验集的真实输出; $\hat{\mathbf{g}}_p$ 为第 p 次迭代后对检验集的预测; h 为检验集样本个数。

基于 GA 优化的 WSVR 退化轨迹建模算法流程如下:

步骤 1. 确定训练集和检验集:选取 D_k 的前 r_k 组数据作为训练集,后 $m_k - r_k$ 组数据作为检验集。

步骤 2. 令代数变量 $p = 0$, 设置迭代代数最大值 p_{\max} 和适应度最大值 e_{\max} , 确定交叉概率值、变异概率值和各优化参数的变化范围;随机产生优化参数的 M 组初始值(初始种群),分别在初始种群各个体下基于 WSVR 原理建立式(3)所示的退化轨迹模型,对检验集进行预测并根据式(6)计算各个体的适应度值。

步骤 3. $p = p + 1$; 根据适应度值选择较优的个体,按照交叉概率均匀交叉产生新个体,按变异概率对个体进行变异操作,形成新的种群,分别在新种群各个体下基于 WSVR 原理建立退化轨迹模型,对检验集进行预测并计算各个体的适应度值。

步骤 4. 如果同时满足 $p < p_{\max}$ 和 $\max e(\mathbf{g}, \hat{\mathbf{g}}_p) > e_{\max}$, 则转步骤 3; 否则选择适应度最小值对应的个体为最优参数 $(\bar{\varepsilon}, \bar{C}, \bar{a})$ 。

步骤 5. 以 D_k 为训练数据,在 $(\bar{\varepsilon}, \bar{C}, \bar{a})$ 下基于

WSVR 原理建立最终的退化轨迹模型:

$$y_k = f_k(t) = \sum_{i=1}^{m_k} (\alpha_i^* - \alpha_i) K(t_{ki}, t) + \bar{b} \quad (7)$$

D_k 的规范化处理:以规范化测量时刻为基准,将 D_k 对应缺少的时刻 t_j 依次代入式(7)估计性能退化值 $\tilde{y}_{kj} = f_k(t_j)$,记规范化处理后的 D_k 为 $\tilde{D}_k = \{(t_j, y_{kj}), j = 1, 2, \dots, m\}$ 。

2.1.2 规范化数据的最优 FCM 聚类

记 \tilde{D}_i 的特征向量为 $\tilde{\mathbf{y}}_i = [\tilde{y}_{i1}; \tilde{y}_{i2}; \dots; \tilde{y}_{im}]$, 记 n 个同类产品的特征向量集为 $\tilde{\mathbf{Y}} = [\tilde{\mathbf{y}}_1, \tilde{\mathbf{y}}_2, \dots, \tilde{\mathbf{y}}_n]$ 。按照第 1.2.2 节的最优 FCM 聚类算法步骤对 $\tilde{\mathbf{Y}}$ 进行聚类分析,得到 \bar{c} 和 $\tilde{\mathbf{V}} = [\tilde{\mathbf{v}}_1, \tilde{\mathbf{v}}_2, \dots, \tilde{\mathbf{v}}_{\bar{c}}]$ 。

值得指出的是:当同类产品的数量不大、退化轨迹几乎相同的情形不突出或者绝大多数同类产品都要进行规范化处理时,采用 FCM 聚类不能很好地归纳信息或者减少实时阶段的计算量,因此,这些情况下不必进行 FCM 聚类,直接把各同类产品的 WSVR 模型和规范化数据用于实时阶段的计算。

2.1.3 最优聚类中心的退化建模

以规范化测量时刻 $[t_1; t_2; \dots; t_n]$ 为输入,聚类中心 $\tilde{\mathbf{v}}_i (i = 1, 2, \dots, \bar{c})$ 为输出,按照第 2.1.1 节基于 GA 优化的 WSVR 退化轨迹建模算法步骤,依次建立 \bar{c} 个聚类中心的退化轨迹模型 $\{\tilde{f}_1(t), \tilde{f}_2(t), \dots, \tilde{f}_{\bar{c}}(t)\}$ 。

2.2 实时阶段

同类产品包含了丰富的退化轨迹曲线,特定个体的退化轨迹极有可能与某个同类产品非常相似甚至相同,或者介于几个同类产品之间。因此,只要能确定特定个体对同类产品退化轨迹的相似程度,即可根据相似程度加权同类产品的模型建立其退化轨迹模型,再结合特定个体的实时测量数据更新相似程度的计算,即可实现特定个体的实时建模。其中,准确的同类产品退化轨迹模型是前提,离线阶段基于 GA 优化的 WSVR 退化轨迹建模算法能够保证模型的精度。相似程度的量化是关键,当 D_Z 为规范化历史测量数据时,其与同类产品截短的特征向量间的 Euclid 距离能够反映退化轨迹的相似程度;但如果 D_Z 不是规范化数据,由于其测量次数较少,不适宜对 D_Z 进行规范化处理,考虑到两条退化轨迹越相似,其在任意相同时刻处的性能退化值越接近,于是,特定个体与同类产品在其最近一次测量时刻处的性能退化值的差异大小可以反映特定个体对同类产品退化轨迹的相似程度。因此,针对 D_Z 是否为规范化历史测量数据的情形,本文提出两种实时退化轨迹建模和寿命预测方法——隶属度加权法和误差加权法。

2.2.1 隶属度加权法算法

隶属度加权法 (Degree-of-membership-based weighted method, DWM) 适用于 D_Z 为规范化历史测量数据的情形. DWM 的基本思想是: 计算特定个体的历史性能退化值向量与各聚类中心前 m_Z 个元素组成向量的 Euclid 距离, 以此确定特定个体对各聚类中心的隶属度值, 从而加权各聚类中心的退化轨迹模型得到特定个体的退化轨迹模型, 最后, 结合特定个体的实时测量数据依次更新 Euclid 距离、隶属度值及其退化轨迹模型, 将失效阈值代入模型求解失效时间, 实现实时寿命预测. 其步骤如下:

步骤 1. 令 $p = m_Z, t_0 = t_p, \mathbf{y}_Z = [y_{Z1}; y_{Z2}; \dots; y_{Zp}]$;

步骤 2. 取 $\tilde{\mathbf{V}}$ 的前 p 行记为矩阵 $\tilde{\mathbf{V}}_Z$, 计算 \mathbf{y}_Z 与 $\tilde{\mathbf{V}}_Z$ 各列向量的 Euclid 距离, 将距离值代入式 (5), 计算出特定个体对聚类中心的隶属度向量 $\mathbf{w} = [w_1; w_2; \dots; w_c]$;

步骤 3. 建立特定个体的退化轨迹模型 $f_Z(t) = \sum_{i=1}^c w_i f_i(t)$;

步骤 4. 求解 $\eta = f_Z(T)$ 得失效时间预测值 T , 计算剩余寿命 $(T - t_0)$;

步骤 5. 获取实时测量数据 (t, y_Z) , 令 $t_0 = t, p = p + 1, \mathbf{y}_Z = [y_Z; y_Z]$, 转步骤 2.

2.2.2 误差加权法算法

误差加权法^[3, 24] (Error-based weighted method, EWM) 对 D_Z 没有限制, 适用于任何情形. EWM 的基本思想是: 把特定个体的最近一次测量时刻代入各聚类中心退化轨迹模型, 估计性能退化值, 根据各估计误差的平方确定权值, 从而加权各聚类中心的退化轨迹模型得到特定个体的退化轨迹模型, 最后, 结合特定个体的实测数据依次更新性能退化估计值、权值及其退化轨迹模型, 将失效阈值代入模型求解失效时间, 实现实时寿命预测. 其步骤如下:

步骤 1. 令 $t_0 = t_{Zm_Z}, y_0 = y_{Zm_Z}$;

步骤 2. 把 t_0 代入 $\{\bar{f}_1(t), \bar{f}_2(t), \dots, \bar{f}_c(t)\}$ 得到 $\{\bar{f}_1(t_0), \bar{f}_2(t_0), \dots, \bar{f}_c(t_0)\}$, 计算估计误差的平方 $e_i = (\bar{f}_i(t_0) - y_0)^2$, 根据式 (8) 计算权值

$$w'_i = \begin{cases} 0, & \text{若 } e_i = 0, \text{ 且 } j \neq i \\ \left(\sum_{j=1}^c \frac{e_i}{e_j} \right)^{-1}, & \text{若 } e_i \neq 0, e_j \neq 0 \\ 1, & \text{否则} \end{cases} \quad (8)$$

步骤 3. 建立特定个体的退化轨迹模型 $f'_Z(t) = \sum_{i=1}^c w'_i f_i(t)$;

步骤 4. 求解 $\eta = f'_Z(T)$ 得失效时间预测值 T , 计算剩余寿命 $(T - t_0)$;

步骤 5. 获取实时测量数据 (t, y_Z) , 令 $t_0 = t,$

$y_0 = y_Z$, 转步骤 2.

3 实例分析

3.1 在疲劳裂纹增长数据中的应用

疲劳裂纹增长数据^[4](如图 2 所示) 已被很多学者作为性能退化数据进行研究分析^[4, 11, 15, 18, 24]. 该数据的特点是: 共有 21 条裂纹的增长数据, 初始裂纹长度均为 0.90 英寸 (inch), η 为 1.60 英寸; 每 0.01 万次循环 (million cycles) 测量一次, 试验截止时间为 0.12 百万次循环; 如果某次测量时发现某条裂纹的长度 $y \geq \eta$, 则该条裂纹随即退出试验. 选取 5#、10# 和 15# 作为需要进行寿命预测的特定个体, 其余 18 条裂纹作为同类产品性能退化数据使用.




图 2 疲劳裂纹增长数据

Fig. 2 Fatigue crack growth data

3.1.1 离线阶段

文献 [24] 采用径向基核函数的支持向量回归机对裂纹进行退化轨迹建模, 本文采用 Morlet 小波核函数进行建模. 对 21 条裂纹, 均将最后 3 次测试数据作为检验集, 分别用径向基核和小波核进行训练和检验. 表 1 给出 2 种核函数模型对检验集的相对估计误差范围 $[e_l, e_h]$ 和相对估计误差绝对值的平均值 e_m . L-2、L-1 和 L 依次表示检验集的 3 个测量时刻. 从表 1 中看出小波核的建模精度略高于径向基核, 因此, 下文的仿真都是基于小波核函数, 以便获得较高的实时预测精度.

表 1 径向基核和小波核 SVR 的预测精度 (%)

Table 1 Prediction precisions of two kernel functions (%)

相对估计误差	径向基核			小波核		
	L-2	L-1	L	L-2	L-1	L
e_l	-1.96	-0.62	-3.57	-1.01	-0.27	0.43
e_h	3.80	2.80	2.91	1.65	2.71	3.41
e_m	1.64	1.13	1.34	0.62	1.09	1.31

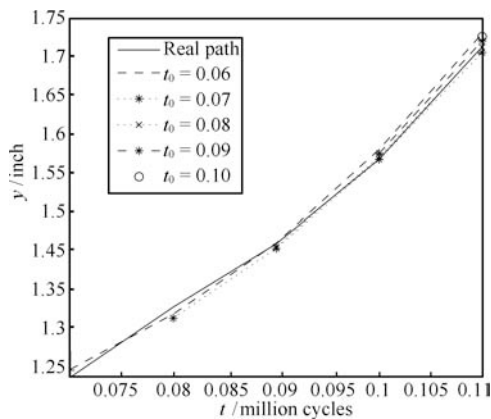
确定规范化测量时刻为前 12 次测量时刻 (即 $m = 12, t_m = 0.11$ 百万次循环), 只有 1# 和 2# 需要进行规范化处理 (进行增补). 基于 GA 优化的 WSVR 退化轨迹建模算法中定义优化参数 (ε, C, a) 的初始范围为 $\{[10^{-4}, 0.05], [10, 100], [0.01, 10]\}$, 确定 1# 和 2# 的最优参数 $(\bar{\varepsilon}, \bar{C}, \bar{a})$ 分别为 $(9.375 \times 10^{-4}, 62.063, 0.045)$ 和 $(3.441 \times 10^{-4}, 99.75, 0.091)$. FCM 算法中取加权指数 $q = 2$, 迭代停止阈值 $\delta = 10^{-5}$, 确定 18 条裂纹的最优聚类数为 12, 聚类将使实时阶段的加权计算量减少 1/3. 然后, 用基于 GA 优化的 WSVR 退化轨迹建模算法对 12 个聚类中心进行退化轨迹建模.

3.1.2 实时阶段

首先, 取 $t_0 = 0.06$, 即用特定个体前 7 次测量的数据进行建模, 第 7 次以后测量的数据用于检验模型的精度; 然后, 逐次增加 1 次测量数据以实现实

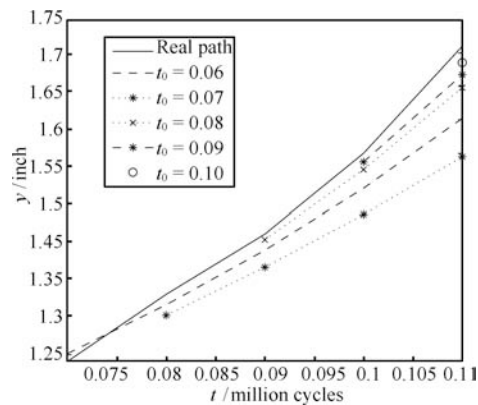
时建模, 其后的测量数据用于检验模型的精度. 分别用 DWM 和 EWM 进行建模实验, 图 3(a) 和 3(c) 分别给出两种方法对 5# 进行 5 次实时建模的预测结果. 为了对比预测效果, 用同样的数据, 以文献 [4, 15, 18] 中使用的 Paris law 模型 (下文称 PL) 进行实时建模, 图 3(b) 给出对 5# 进行 5 次实时建模的预测结果. 表 2 给出 3 种方法对 3 个特定个体的退化量预测误差; 表 3 给出 3 种方法 6 次预测得到的失效时间及均值和标准差. PL 模型的形式为 $y = 0.9(1 - 0.9^{\theta_2} \theta_1 \theta_2 t)^{-\frac{1}{\theta_2}}$.

鉴于 EWM 的广泛适用性, 用 WSVR 模型对 5# 的历史测量数据进行仿真插值, 然后, 用 EWM 在插值时刻处进行实时建模. 图 3(d) 给出 EWM 对 5# 进行 6 次实时建模的预测结果, 增加的非规范化测量时刻为 $[0.055, 0.065, 0.075, 0.085, 0.095, 0.105]$, 对应的退化量插值为 $[1.1554, 1.2117, 1.2918, 1.3793, 1.4870, 1.6249]$.



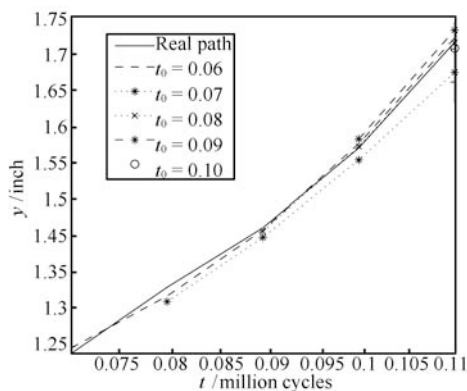
(a) DWM 的退化轨迹预测

(a) Degradation path predicted by DWM




(b) PL 的退化轨迹预测

(b) Degradation path predicted by PL



(c) EWM 在规范化时刻处的退化轨迹预测

(c) Degradation path predicted at normalized time by EWM



(d) EWM 在非规范化时刻处的退化轨迹预测

(d) Degradation path predicted at non-normalized time by EWM

图 3 DWM, PL 和 EWM 对 5# 的退化轨迹预测

Fig. 3 Degradation paths of 5# predicted by DWM, PL, and EWM

比较图 3(a)~3(c) 发现: 5# 为规范化历史测量数据时, DWM, EWM 和 PL 的建模精度依次降低. 比较图 3(b) 和图 3(d) 发现: 5# 为非规范化历史测量数据时, EWM 的建模精度高于 PL. 可见, DWM 和 EWM 考虑了同类产品退化轨迹的相似性, 基于相似性加权同类产品的退化轨迹模型, 使建模精度得到提高.

从表 2 中看出: 1) DWM 对 3 个特定个体的预测精度都是最高; 2) EWM 对 10# 的预测精度最差, 对 5# 和 15# 的预测精度都较高; 3) PL 对 10# 的预测精度较高, 对 5# 和 15# 的预测精度最差. 从表 2 可见, DWM 的精度高于 EWM, 由于 DWM 是根据规范化历史数据确定权值, 考虑了特定个体的全部历史数据, 而 EWM 是基于特定个体当前的实时数据确定权值, 可能是部分当前时刻的测量数据精度较低所致, 也说明了 DWM 更为鲁棒.

表 2 DWM, EWM 和 PL 的预测精度 (%)
Table 2 Prediction precisions of DWM, EWM, and PL (%)

裂纹	算法	相对估计误差		
		e_l	e_h	e_m
5#	DWM	-1.778	1.407	0.953
	EWM	-2.859	1.580	1.113
	PL	-9.658	0.924	3.019
10#	DWM	-2.209	0.864	1.080
	EWM	-3.071	1.025	1.466
	PL	-0.754	2.859	1.157
15#	DWM	-0.990	1.436	0.895
	EWM	-2.848	0.504	1.174
	PL	-3.888	2.841	1.682

从表 3 中看出: 1) DWM 和 EWM 多次预测结果的最大标准差分别为 0.0028 和 0.0051, 而 PL 的最大标准差为 0.0081, 表明 DWM 方法的鲁棒性最好, EWM 方法次之, PL 的鲁棒性最差; 2) 结合图 3, 由于退化轨迹的低估导致失效时间的高估, 所以 PL 预测的 5# 失效时间高于真实值, 而 DWM 和 EWM 预测的 5# 失效时间较为可信.

3.2 在 CG36A 晶体管退化数据中的应用

对 CG36A 晶体管的 100 个样品进行退化寿命试验, 每个样品均测量 9 次, 测量时刻为 [0, 1, 3, 10, 30, 100, 250, 500, 1000] 小时, 试验数据显示性能参数 z 随着时间递增^[17]. 规定当 z 相对于初始值 z_0 增长变化达到 30% 时产品失效, 于是定义退化量为 $y = (z - z_0)/z_0$, 则 η 为 0.3, 退化量数据如图

4 所示. Chen 等^[15] 用 $y = \theta_1 t^{\theta_2}$ (下文称 Ch&Zh) 对退化轨迹进行拟合, 考虑到模型的符号恒定性, 他们剔除掉 11 个包含负增长变化阶段的样品, 在个体寿命预测时发现 1 个样品的寿命值过大, 也予以剔除, 最终用 88 个样品进行总体寿命分布估计. 文献 [15] 特别指出: 剔除 12 个样品可能是不适当的, 应该验证数据的有效性并找出导致个体差异的原因, 对这些个体应该特别对待. 鉴于本文基于 GA 优化的 WSVR 退化轨迹建模方法能够较好地拟合各种非线性曲线, FCM 聚类算法能够将特殊个体单独划分为一类, 因此, 本文所提方法无需剔除样品.




图 4 CG36A 晶体管退化数据

Fig. 4 CG36A transistor degradation data

将 9 个测量时刻定义为规范化测量时刻, 则 100 个样品都是规范化性能退化数据. 挑选 3 个样品作为特定个体, 分别编号为 1#、2# 和 3#. 对其余 97 个样品进行最优 FCM 聚类, 确定最优聚类数为 29, 聚类将使实时阶段的加权计算量减少 70%. 在基于 GA 优化的 WSVR 退化轨迹建模过程中, 为了减小不等时间间隔所造成的影响, 这里去除零时刻及其对应的零初始退化量, 并对其余测量时刻取以 10 为底的对数, 即以 $\lg t$ 作为输入. 首先, 将特定个体的前 5 次测量数据 (即起始点为 $t_0 = 100, \lg t_0 = 2$) 用于建模, 后面的 3 次测量数据用于检验模型的精度; 然后, 逐次增加 1 次测量数据以实现实时建模, 其后的测量数据用于检验模型的精度. 表 4 给出 3 种方法对 3 个特定个体的退化量预测误差; 表 5 给出 3 种方法 4 次预测的失效时间及均值和标准差. 从表 4 中看出: DWM、EWM 和 Ch&Zh 的建模精度依次降低. 从表 5 中看出: DWM 和 EWM 多次预测结果的最大标准差分别为 3.447 和 15.430, 而 PL 的最大标准差为 39.451, 表明 DWM 方法的鲁棒性最好, EWM 方法次之, PL 的鲁棒性最差.

表 3 失效时间预测结果 (百万次循环)
Table 3 Estimation of failure time (million cycles)

裂纹	算法	t_0						μ	σ
		0.06	0.07	0.08	0.09	0.10	0.11		
5#	DWM	0.1024	0.1035	0.1032	0.1028	0.1025	0.1030	0.1029	0.0004
	EWM	0.1028	0.1052	0.1032	0.1023	0.1035	0.1036	0.1034	0.0010
	PL	0.1098	0.1160	0.1063	0.1051	0.1041	0.1032	0.1074	0.0048
10#	DWM	0.1211	0.1202	0.1179	0.1167	0.1178	0.1161	0.1183	0.0020
	EWM	0.1233	0.1217	0.1200	0.1186	0.1184	0.1173	0.1199	0.0023
	PL	0.1151	0.1134	0.1122	0.1125	0.1150	0.1162	0.1141	0.0016
15#	DWM	0.1334	0.1354	0.1380	0.1407	0.1398	0.1361	0.1372	0.0028
	EWM	0.1397	0.1514	0.1509	0.1454	0.1448	0.1400	0.1454	0.0051
	PL	0.1464	0.1243	0.1255	0.1268	0.1298	0.1315	0.1307	0.0081

表 5 失效时间预测结果 (小时)
Table 5 Estimation of failure time (h)

晶体管	算法	t_0				μ	σ
		100	250	500	1000		
1#	DWM	55.463	53.211	52.845	53.333	53.713	1.185
	EWM	22.233	52.845	52.966	53.456	45.375	15.430
	Ch&Zh	42.073	51.151	58.108	63.649	53.745	9.311
2#	DWM	170.216	176.198	177.828	172.584	174.207	3.447
	EWM	174.985	203.704	186.209	177.419	185.579	13.009
	Ch&Zh	126.613	150.915	186.029	216.535	170.023	39.451
3#	DWM	27.670	27.353	27.040	27.227	27.323	0.265
	EWM	28.576	26.792	27.102	29.235	27.926	1.169
	Ch&Zh	33.498	38.477	42.472	46.020	40.117	5.382

表 4 DWM, EWM 和 Ch & Zh 的预测精度 (%)
Table 4 Prediction precisions of DWM, EWM, and Ch & Zh (%)

晶体管	算法	相对估计误差		
		e_l	e_h	e_m
1#	DWM	-6.710	-2.262	4.317
	EWM	-15.840	1.464	6.394
	Ch & Zh	22.266	60.169	35.725
2#	DWM	1.162	6.652	4.762
	EWM	-0.760	33.548	11.210
	Ch & Zh	11.269	34.639	21.811
3#	DWM	-3.525	1.131	1.398
	EWM	-6.777	1.890	2.973
	Ch & Zh	12.928	31.311	18.976

4 结论

本文针对现有实时寿命预测方法没有充分利用同类产品性能退化数据信息的问题, 从研究退化轨迹相似性的角度出发, 提出了一类基于 WSVR 和 FCM 聚类的实时退化轨迹建模和寿命预测方法. 鉴于 WSVR 的小样本学习、非线性映射能力和 FCM 的信息归纳能力, 采用 WSVR 对同类产品进行退化轨迹建模和性能退化数据规范化处理, 运用 FCM 聚类对规范化性能退化数据进行信息归纳. 针对特定个体的历史测量时刻特点, 分别提出两种基于加权思想的实时退化轨迹建模方法: 1) 隶属度加权法, 适用于历史测量时刻为规范化测量时刻的特定个体, 根据特定个体退化轨迹与聚类中心轨迹间的 Euclid 距离确定隶属度权值; 2) 误差加权法, 对历史测量时

刻没有限制, 具有普适性, 根据聚类中心退化轨迹模型对特定个体最近一次测量时刻处的预测误差确定权值. 通过两个实例分析验证了所提方法的有效性, 结果表明: DWM 的预测精度高于 EWM 和现有模型的精度, DWM 的鲁棒性也最好. 总之, 本文所提方法对实时寿命预测具有一定的参考价值.

References

- Hu Chang-Hua, Xu Hua-Long. *Design and Analysis of Fault-Tolerant Control and Fault Diagnosis for Control System*. Beijing: National Defense Industry Press, 2000
(胡昌华, 许化龙. 控制系统故障诊断与容错控制的分析和设计. 北京: 国防工业出版社, 2000)
- Si X S, Wang W, Hu C H, Zhou D H. Remaining useful life estimation — a review on the statistical data driven approaches. *European Journal of Operational Research*, 2011, **213**(1): 1–14
- Gebraeel N Z, Lawley M A, Liu R, Parmeshwaran V. Residual life predictions from vibration-based degradation signals: a neural network approach. *IEEE Transactions on Industrial Electronics*, 2004, **51**(3): 694–700
- Lu J C, Meeker W Q. Using degradation measures to estimate a time-to-failure distribution. *Technometrics*, 1993, **35**(2): 161–174
- Chan V. *Degradation-Based Reliability in Outdoor Environments* [Ph.D. dissertation], Iowa State University, USA, 2001
- Lim K E, Baek J S, Lee E Y. A random shock model for a continuously deteriorating system. *Journal of Quality in Maintenance Engineering*, 2005, **11**(3): 206–215
- Ramakrishnan A, Pecht M. A life consumption monitoring methodology for electronic systems. *IEEE Transactions on Components and Packaging Technologies*, 2003, **26**(3): 625–634
- Son K I, Soma M. Dynamic life-estimation of CMOS ICs in real operating environment: precise electrical method and MLE. *IEEE Transactions on Reliability*, 1997, **46**(1): 31–37
- Lv Ke-Hong, Qiu Jing, Liu Guan-Jun. Research on life prognosis method for electronics based on dynamic damage and optimization AR model. *Acta Armamentarii*, 2009, **30**(1): 91–95
(吕克洪, 邱静, 刘冠军. 基于动态损伤及优化 AR 模型的电子器件寿命预测方法研究. 兵工学报, 2009, **30**(1): 91–95)
- Wu S J, Tsai T R. Estimation of time-to-failure distribution derived from a degradation model using fuzzy clustering. *Quality and Reliability Engineering International*, 2000, **16**(4): 261–267
- Chinnam R B. On-line reliability estimation for individual components using statistical degradation signal models. *Quality and Reliability Engineering International*, 2002, **18**(1): 53–73
- Gebraeel N Z, Lawley M A, Li R, Ryan J K. Residual-life distributions from component degradation signals: a Bayesian approach. *IIE Transactions*, 2005, **37**(6): 543–557
- Gebraeel N Z. Sensory-updated residual life distributions for components with exponential degradation patterns. *IEEE Transactions on Automation Science and Engineering*, 2006, **3**(4): 382–393
- Gebraeel N Z, Elwany A, Pan J. Residual life predictions in the absence of prior degradation knowledge. *IEEE Transactions on Reliability*, 2009, **58**(1): 106–117
- Chen Z H, Zheng S R. Lifetime distribution based degradation analysis. *IEEE Transactions on Reliability*, 2005, **54**(1): 3–10
- Deng Ai-Min, Chen Xun, Zhang Chun-Hua, Wang Ya-Shun. Reliability assessment based on performance degradation data. *Journal of Astronautics*, 2006, **27**(3): 546–552
(邓爱民, 陈循, 张春华, 汪亚顺. 基于性能退化数据的可靠性评估. 宇航学报, 2006, **27**(3): 546–552)
- Zhuang Dong-Chen. *Degradation Failure Model and Statistical Analysis* [Ph.D. dissertation], East China Normal University, China, 1994
(庄东辰. 退化失效模型及其统计分析 [博士学位论文], 华东师范大学, 中国, 1994)
- Xu Z G, Zhou D H. A degradation measurements based real-time reliability prediction method. In: *Proceedings of the 6th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*. Beijing, China: IFAC, 2006. 950–955
- Lu S, Lu H, Kolarik W J. Multivariate performance reliability prediction in real-time. *Reliability Engineering and System Safety*, 2001, **72**(1): 39–45
- You Qi, Zhao Yu, Ma Xiao-Bing. Performance reliability assessment for products based on time series analysis. *Journal of Beijing University of Aeronautics and Astronautics*, 2009, **35**(5): 644–648
(尤琦, 赵宇, 马小兵. 产品性能可靠性评估的时序分析方法. 北京航空航天大学学报, 2009, **35**(5): 644–648)
- Xu Z G, Ji Y D, Zhou D H. Real-time reliability prediction for a dynamic system based on the hidden degradation process identification. *IEEE Transactions on Reliability*, 2008, **57**(2): 230–242
- Huang R Q, Xi L F, Li X L, Liu C R, Qiu H, Lee J. Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods. *Mechanical Systems and Signal Processing*, 2007, **21**(1): 193–207
- Gebraeel N Z, Lawley M A. A neural network degradation model for computing and updating residual life distributions. *IEEE Transactions on Automation Science and Engineering*, 2008, **5**(1): 154–163

- 24 Hu Chang-Hua, Hu Jin-Tao, Zhang Wei, Ping Zhen-Hai. Reliability assessment of performance degradation using support vector machines. *Systems Engineering and Electronics*, 2009, **31**(5): 1246–1249

(胡昌华, 胡锦涛, 张伟, 平振海. 支持向量机用于性能退化的可靠性评估. 系统工程与电子技术, 2009, **31**(5): 1246–1249)

- 25 Wu J, Deng C, Shao X Y, Xie S Q. A reliability assessment method based on support vector machines for CNC equipment. *Science in China Series E: Technological Sciences*, 2009, **52**(7): 1849–1857

- 26 Li Chang-You, Xu Min-Qiang, Guo Song, Wang Ri-Xin, Gao Jing-Bo. Real-time reliability assessment based on gamma process and Bayesian estimation. *Journal of Astronautics*, 2009, **30**(4): 1715–1719

(李常有, 徐敏强, 郭耸, 王日新, 高晶波. 基于 Gamma 过程及贝叶斯估计的实时可靠性评估. 宇航学报, 2009, **30**(4): 1715–1719)

- 27 Zhao Zhao, Dong Dou-Dou, Zhou Jing-Lun, Feng Jing. Real-time reliability evaluation for degradation failure product based on Bayes method. *Journal of National University of Defense Technology*, 2007, **29**(6): 116–120

(赵焯, 董豆豆, 周经伦, 冯静. 基于贝叶斯方法的退化失效型产品实时可靠性评估. 国防科技大学学报, 2007, **29**(6): 116–120)

- 28 Deng Nai-Yang, Tian Ying-Jie. *A New Method of Data Mining: Support Vector Machine*. Beijing: Science Press, 2004

(邓乃扬, 田英杰. 数据挖掘中的新方法: 支持向量机. 北京: 科学出版社, 2004)

- 29 Zhang Li, Zhou Wei-Da, Jiao Li-Cheng. Wavelet kernel function network. *Journal of Infrared Millimeter Waves*, 2001, **20**(3): 223–227

(张莉, 周伟达, 焦李成. 子波核函数网络. 红外与毫米波学报, 2001, **20**(3): 223–227)

- 30 Gao Xin-Bo. *Fuzzy Cluster Analysis and Its Applications*. Xi'an: Xi'an University of Electronic Science and Technology Press, 2004

(高新波. 模糊聚类分析及其应用. 西安: 西安电子科技大学出版社, 2004)



胡友涛 第二炮兵工程大学自动化系博士研究生. 主要研究方向为寿命预测和可靠性评估. 本文通信作者.

E-mail: hujintao307@163.com

(HU You-Tao Ph. D. candidate in the Department of Automation, Xi'an Institute of Hi-Tech. His research interest covers lifetime prediction and reliability assessment. Corresponding author of this paper.)



胡昌华 博士, 第二炮兵工程大学教授. 主要研究方向为控制理论与应用, 故障预报、诊断与可靠性工程.

E-mail: hch6603@263.net

(HU Chang-Hua Ph. D., professor at Xi'an Institute of Hi-Tech. His research interest covers control theory and applications, fault prediction, fault diagnosis, and reliability engineering.)



孔祥玉 博士, 第二炮兵工程大学讲师. 主要研究方向为自适应信号处理, 非线性系统建模及应用, 故障诊断.

E-mail: xiangyukong01@163.com

(KONG Xiang-Yu Ph. D., lecturer at Xi'an Institute of Hi-Tech. His research interest covers adaptive signal processing, nonlinear system modeling and its application, and fault diagnosis.)



周志杰 博士, 第二炮兵工程大学讲师. 主要研究方向为系统辨识, 故障预报与最优维护. E-mail:

zhouzj04@mails.tsinghua.edu.cn

(ZHOU Zhi-Jie Ph. D., lecturer at Xi'an Institute of Hi-Tech. His research interest covers system identification, fault prediction, and optimal maintenance.)