

文章编号:1006-2467(2019)07-0838-06

DOI: 10.16183/j.cnki.jsjtu.2019.07.010

基于稀疏自编码神经网络的产品再设计模块识别方法

马斌彬¹, 马红占¹, 褚学宁¹, 李玉鹏²

(1. 上海交通大学 机械与动力工程学院, 上海 200240; 2. 中国矿业大学 矿业工程学院, 江苏 徐州 221116)

摘 要: 提出了基于性能时变数据分析的再设计模块识别方法. 利用产品在健康状态下的性能时变数据构建无监督学习的稀疏自编码神经网络(SAENN)模型, 以用于健康状态下产品性能数据的特征提取以及产品功能退化程度的评估; 将产品在健康状态下的性能数据用于训练 SAENN 模型, 使用运行期间的性能时变数据更新产品的状态特征, 以反映功能的退化过程; 通过对比功能间的退化差异来识别需要再设计模块; 同时, 以某制造企业水平定向钻产品再设计功能模块的识别为例验证了所提方法的可行性. 结果表明, 所提出的再设计模块识别方法具有较好的准确性, 能够识别需改进的功能模块, 识别结果可作为产品再设计的依据.

关键词: 产品再设计; 模块识别; 性能时变数据; 稀疏自编码神经网络; 功能退化

中图分类号: TB 472

文献标志码: A

Identification of Product Redesign Modules Based on Neural Network of Sparse Auto-Encoder

MA Binbin¹, MA Hongzhan¹, CHU Xuening¹, LI Yupeng²

(1. School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;

2. School of Mines, China University of Mining and Technology, Xuzhou 221116, Jiangsu, China)

Abstract: This paper presents a redesign-module identification method based on time-varying product usage data. The method is conducted in three steps: Building a model based on sparse auto-encoder (SAE) neural network using performance feature data from the product health state; Assessing functional performance degradation by using the data during the actual operation; Identifying the redesign module by comparing the difference in functional degradation. Then, a case study of horizontal directional drilling redesign module identification is presented to illustrate feasibility of the proposed method. The result shows the effectiveness of proposed method so that it can identify the weak function modules, while the identified result can provide support for redesign decision-making.

Key words: product redesign; module identification; time-varying performance feature data; sparse auto-encoder neural network (SAENN); function degradation

随着运行时间的增长, 产品功能模块的性能逐渐退化, 而产品的薄弱环节通常是退化严重、对产品

的安全性和可靠性产生重大不利影响的功能模块^[1], 因此, 设计人员往往采用再设计的方法对产品

收稿日期: 2017-11-01

基金项目: 国家自然科学基金项目(51875345, 51475290, 51075261, 51505480)

作者简介: 马斌彬(1993-), 男, 浙江省宁波市人, 硕士生, 研究方向为产品再设计, E-mail: mabinbin@sjtu.edu.cn.

通信作者: 褚学宁, 男, 教授, 博士生导师, E-mail: xnchu@sjtu.edu.cn.

的薄弱环节进行重新设计. 其中,再设计功能模块识别方法是通过找出产品的薄弱环节并对其重新展开设计,从而进一步提高产品的可靠性和服务水平. 目前,国内外学者基于产品的故障数据和运行数据对再设计功能模块识别方法进行了研究. 例如: Francesco 等^[2]提出了改进的产品失效模式、影响和危害性分析(FMECA)方法;全睿等^[3]通过建立模糊故障树来识别影响燃料电池发动机安全性的薄弱环节. 但是,由于船舶、起重机等复杂机械产品具有可靠性高、寿命长的特点,偶发的故障数据不能真实反映产品在一段时间内的连续状态变化情况,所以基于故障数据的产品再设计模块识别的结果不能很好地反映功能模块间退化水平的差异. 随着传感器和无线技术的发展,获取产品运行状态的实时数据变得可行^[4]. Shin 等^[5]基于产品性能时变数据,利用聚类方法分析了产品的失效情况,通过建立性能参数与设计参数之间的关联矩阵来对产品再设计进行改进,但利用聚类方法进行失效分析需要预先设定运行工况的个数,而产品的运行工况具有复杂性和多变性,因此,很难预先确定运行工况的个数;Ma 等^[6]以履带起重机的功能模块的性能参数为输入,通过建立混合高斯模型来拟合性能参数的取值区间,以用于产品再设计模块的识别. 但是,混合高斯模型需要在每个状态点更新退化模型,其计算过程复杂,不利于实时处理. 而神经网络模型可用于处理具有多状态(非线性)的性能特征参数,适用于描述运行工况复杂的产品退化状态^[7],因此,本文利用产品在健康状态下的性能时变数据构建稀疏自编码神经网络(SAENN)模型,以用于产品功能模块退化程度的评估,并通过对比模块功能间的退化差异来识别需要再设计的功能模块.

1 基于 SAENN 的产品功能退化建模

1.1 稀疏自编码神经网络

在产品运行过程中,传感器采集到的各种性能特征参数在一定程度上反映了产品功能退化的程度,这些状态信息对产品再设计具有重要的价值. 然而,产品的退化过程复杂,其功能退化的规律与性能特征参数之间存在着复杂的非线性时变关系,难以利用确定的解析模型来评估,而神经网络模型可以表征产品性能参数之间的非线性关系,因此,它可用于评估产品功能的退化程度,进而比较不同功能模块间的退化差异.

自编码神经网络(AENN)模型是一种无监督的神经网络模型,包括输入层、隐含层和输出层,其主

要通过编码-重构过程来表征输入样本的数据特性^[8]. 通过建立 AENN 模型、训练产品在健康状态下各功能模块的性能特征数据,能够提取在健康状态下产品性能参数之间的抽象特征. 当产品功能发生退化时,这些性能参数的特征与健康状态下的具有明显差异,通过分析其差异即可评估各功能模块的退化程度. 而 SAENN 模型是在 AENN 模型的基础上在隐含层神经元引入了稀疏性限制条件,从而增强了模型的泛化能力(模型对于健康状态下性能特征的识别能力). 稀疏性限制条件能够使 AENN 模型的隐含层通过特征选择来找出高维数据中重要的若干维,从而学习相对稀疏、简明的数据特征,以更好地表达输入数据,它克服了 AENN 模型泛化能力较差、不能提取数据内在特征的缺点.

1.2 产品功能退化评估模型的建立

以下为建立产品功能退化评估模型的步骤.

(1) 构建产品功能退化评估模型. 首先,划分功能模块. 对于机械产品来说,功能模块可以按照实现功能的不同划分为机、电、液等系统,每个系统均采用对应的性能特征参数来表征其功能模块的退化程度. 假设产品由 N 个功能组成,第 n 个功能表示为 F_n ($n=1,2,\dots,N$),功能 F_n 有 M 个性能特征,则功能 F_n 的性能时变特征可用矩阵形式表示为

$$\mathbf{P}_{M \times t} = [\mathbf{p}_1 \quad \mathbf{p}_2 \quad \cdots \quad \mathbf{p}_t] \quad (1)$$

式中: $\mathbf{p}_i \in \mathbf{R}^{M \times 1}$, $i=1,2,\dots,t$,为第 i 时刻功能 F_n 的性能特征向量,且 $\mathbf{p}_i = [p_{1i}^{(n)} \quad p_{2i}^{(n)} \quad \cdots \quad p_{Mi}^{(n)}]^T$. 评估模型为全连接神经网络,如图 1 所示. 模型输入参数为功能 F_n 的性能特征,每个输入神经元定义为 F_n 的一个性能特征;模型输出参数为 F_n 重构后的性能特征,其神经元与输入神经元的个数相同;隐含层表示对性能特征参数进行特征提取后的特征神经元. 利用分布在产品上的传感器获得功能 F_n 在健康状态下的性能特征矩阵 $\mathbf{P}_{M \times t}$ 并作为模型的输入矩阵,取矩阵中第 i 时刻的性能特征向量 \mathbf{p}_i 作为输入,从输入层到隐含层进行特征提取,由下式所得低维向量为

$$\mathbf{q}_i = \mathbf{s}_i(\mathbf{W}\mathbf{p}_i + \mathbf{b}_1) \quad (2)$$

式中: \mathbf{s}_i 为从输入层到隐含层的激活函数,也就是 Sigmoid 函数 $f(x) = 1/(1 + e^{-x})$; $\mathbf{W} \in \mathbf{R}^{d \times M}$,为隐含层的权重矩阵; $\mathbf{b}_1 \in \mathbf{R}^{d \times 1}$,为隐含层的偏置向量. 从隐含层到输出层进行特征重构,将 \mathbf{q}_i 经过计算后所得与 \mathbf{p}_i 具有相同维度的性能特征向量为

$$\mathbf{p}'_i = \mathbf{s}_g(\tilde{\mathbf{W}}\mathbf{q}_i + \mathbf{b}_2) \quad (3)$$

式中: \mathbf{s}_g 为从隐含层到输出层的激活函数(Sigmoid 函数); $\tilde{\mathbf{W}} \in \mathbf{R}^{M \times d}$,为输出层的权重矩阵; $\mathbf{b}_2 \in \mathbf{R}^{M \times 1}$,

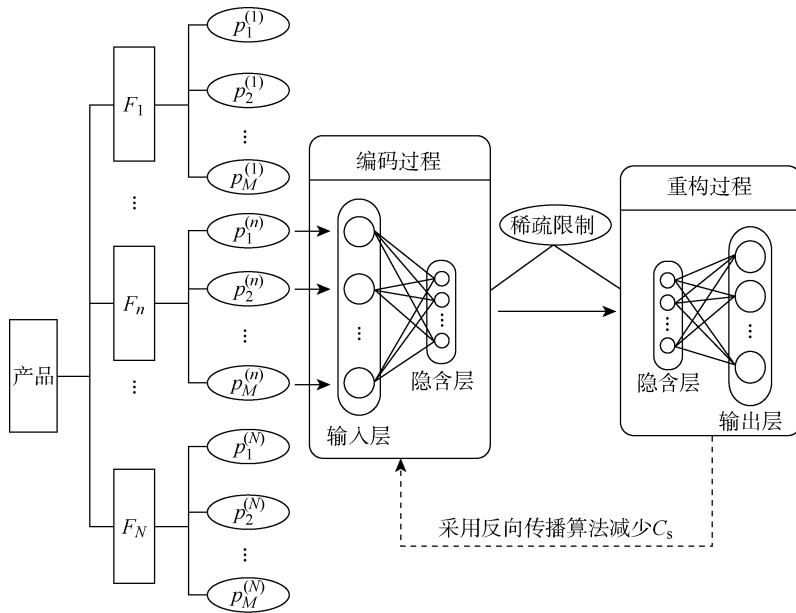


图 1 功能退化的评估模型
Fig. 1 Assessment model of function degradation

为输出层的偏置向量. 用重构误差 C 表示输入产品性能特征向量与其重构后的差异, 即

$$C = \sum_{i=1}^t \|s_g[\tilde{W}s_f(Wp_i + b_1) + b_2] - p_i\| \quad (4)$$

(2) 增加稀疏性限制条件. 在重构误差 C 的基础上增加稀疏性限制条件. 对于 $P_{M \times t}$ 中 M 个输入性能特征向量, 假设隐含层中第 k ($k = 1, 2, \dots, d$) 个神经元的平均活跃度为

$$\hat{\rho} = \frac{1}{t} \sum_{i=1}^t \|s_i(Wp_i + b_1)\| \quad (5)$$

稀疏性限制条件可以表示为

$$\hat{\rho} = \rho \quad (6)$$

式中: ρ 为设定的稀疏性参数, 通常是一个接近于 0 的常数. 若隐含层神经元的输出接近于 1, 则认为 ρ 被激活; 若隐含层神经元的输出接近于 0, 则认为 ρ 被抑制. 可见, 利用稀疏性限制条件可使得神经元在大部分时间处于被抑制状态. 为了在退化模型训练中实现稀疏性限制, 在重构 C 时加入惩罚因子, 以区分 $\hat{\rho}$ 与 ρ 不同的情况, 从而使得隐含层神经元的平均活跃度保持在较低水平. 本文使用 Kullback-Leibler 散度作为惩罚因子^[9], 其表达式为

$$\sum_{k=1}^d \text{KL}(\rho \parallel \hat{\rho}_k) = \sum_{k=1}^d \left(\rho \log \frac{\rho}{\hat{\rho}_k} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_k} \right) \quad (7)$$

式中: $\text{KL}(\rho \parallel \hat{\rho}_k)$ 为稀疏性惩罚因子, 表示分别以 ρ 和 $\hat{\rho}_k$ 为均值的两个变量之间的相对熵.

因此, 加入稀疏性限制条件后的重构误差可以表示为

$$C_s = \sum_{i=1}^t \|s_g[\tilde{W}s_f(Wp_i + b_1) + b_2] - p_i\| + \beta \sum_{k=1}^d \text{KL}(\rho \parallel \hat{\rho}_k) \quad (8)$$

式中: β 为稀疏性惩罚因子的权重, 决定了对稀疏性限制条件的重视程度.

(3) 计算退化评估模型参数. 设置目标重构误差, 当 C_s 小于目标重构误差时结束训练. 随机初始化权重矩阵和偏移量, 通过反向传播算法使 C_s 值最小化来不断更新权重矩阵和偏置向量, 得到最优的 F_n 的功能退化评估模型参数 W, \hat{W}, b_1, b_2 .

2 产品再设计功能模块识别

2.1 功能退化程度的评估

假设产品在实际运行过程中 F_n 的性能时变特征矩阵为 $P'_{M \times t}$, p_i 是 $P'_{M \times t}$ 中第 i 个时刻的性能特征向量, 将 p_i 作为退化模型的输入, 经过计算得到输出向量 p'_i , 定义劣化指数 DI 并作为功能退化程度的评估指标, 其表达式为

$$\text{DI} = \sqrt{(p_i - p'_i)^T (p_i - p'_i)} \quad (9)$$

将评估矩阵中的性能时变特征向量逐次作为模型输入, 计算每一时刻的劣化指数 DI, 从而得到 F_n 的退化趋势.

2.2 性能特征重要度的分配

性能特征重要度是性能参数对功能退化的影响

程度.对于功能 F_n 的 M 个性能特征,其数值与正常的性能特征范围的偏差对 F_n 层次的功能退化的影响程度有所不同.例如,液压系统失压比油温偏高对功能造成的影响更严重,因此,在计算 DI 时,需给油压分配更大的权重,以便于合理描述功能退化的程度.在实际应用中,对于性能特征重要度的分配,主要依靠工程人员的知识和经验确定.假设性能特征重要度的权重向量为 \mathbf{V} ,第 j 个性能特征的权重为 v_j ,则

$$\sum_{j=1}^M v_j = 1$$

(10)

考虑到性能特征重要度权重的影响,修正后的劣化指数为

$$DI = \sqrt{[\mathbf{V} \cdot (\mathbf{p}_i - \mathbf{p}_i')]^T [\mathbf{V} \cdot (\mathbf{p}_i - \mathbf{p}_i')]} \quad (11)$$

2.3 再设计功能模块的识别

首先,对产品的 N 个功能模块分别建立功能退化评估模型,以分析功能退化趋势与性能时变特征的关系;然后,采用修正后的劣化指数 DI 表征其退

化程度.在对产品的薄弱功能模块进行识别时,应比较相同时间内不同功能模块的 DI 的变化趋势,DI 值越大,说明退化越严重,该模块再设计的必要性越高,在再设计过程中需要格外关注.

3 案例分析

本文以国内某大型工程机械制造企业的水平定向钻产品为例进行案例分析.该企业的水平定向钻产品包括小型机系列、中型机系列以及重型机系列,主要型号有 SDD100 型、SDD330 型、SDD3000 型等,本文的研究对象为重型机产品.

3.1 产品功能模块的划分

根据前期的调研,本文将该企业在水平定向钻设计过程中的功能模块划分为液压系统 F_1 、机械系统 F_2 、发动机系统 F_3 以及泥浆系统 F_4 ,每个功能均采用对应的性能特征参数 p (例如 $p_2^{(1)}$ 表示功能 F_1 的第 2 个参数)表征功能退化程度,并采用专家打分法确定各性能特征重要度的权重 v ,其结果见表 1.

表 1 功能模块的性能特征及重要度

Tab. 1 Performance feature and importance rate of the function module

功能	性能特征参数	v	参数描述	功能	性能特征参数	v	参数描述
F_1	$p_1^{(1)}$	0.20	液压系统油箱总压力	F_1	$p_2^{(1)}$	0.15	进给液压位移误差
	$p_3^{(1)}$	0.50	进给液压分系统油压		$p_4^{(1)}$	0.15	进给液压分系统油温
F_2	$p_1^{(2)}$	0.30	主轴振动时域信号	F_2	$p_2^{(2)}$	0.40	主轴油液温度
	$p_3^{(2)}$	0.15	主轴电流		$p_4^{(2)}$	0.15	进给油液温度
F_3	$p_1^{(3)}$	0.30	左右气缸压力差	F_3	$p_2^{(3)}$	0.30	排烟总管温度
	$p_3^{(3)}$	0.20	冷却液温度		$p_4^{(3)}$	0.20	发动机转速
F_4	$p_1^{(4)}$	0.20	泥浆泵缸表面温度	F_4	$p_2^{(4)}$	0.15	泥浆泵入口流量
	$p_3^{(4)}$	0.15	泥浆泵出口流量		$p_4^{(4)}$	0.50	泥浆泵容积效率

3.2 功能退化评估与再设计的必要性

首先,定义水平定向钻在未出厂时的调试过程采集的性能时变数据为健康状态下的产品性能特征,用该时段的数据训练退化评估模型;然后,对水平定向钻出厂后投入运行 3 a 内各功能退化的程度进行评估.每隔 30 min 采集一次各功能模块的性能特征.其中,主轴时域信号采用振动信号的方均根(RMS)作为特征参数.对于每个功能模块,将采集的 1 620 组健康状态下的性能特征数据作为训练集数据,随机抽取其中 1 296 组数据用于模型训练,324 组数据用于模型验证;将产品运行过程中的 6 000 组性能时变数据作为测试集数据,以评估功能模块的退化程度.评估过程分为 3 个步骤:

(1) 数据预处理.由于产品功能模块的性能时变数据的量纲和数值区间不同,直接进行训练会导

致数值区间大的性能特征过支配数值区间小的性能特征,所以需要采用数据标准化的方法将其统一变换为无单位数据.本文采用 0-1 标准化方法^[10]对训练集数据进行缩放,并将缩放比例应用于测试集数据.

(2) 训练功能退化评估模型.分别建立 4 个功能模块的退化评估模型.以 F_1 为例,利用 Python 语言的 Keras 模块建立 SAENN 模型,设置 SAENN 模型为全连接结构.模型输入参数分别为 $p_1^{(1)}$ 、 $p_2^{(1)}$ 、 $p_3^{(1)}$ 和 $p_4^{(1)}$,节点个数为 4;隐含层节点个数为 8;输出层参数用于表征重构的性能特征,输出层节点个数为 4.隐含层和输出层的激活函数采用 Sigmoid 函数, $\rho=0.01$, $\beta=1$,优化器采用 Adam 算法^[11],重构误差函数采用式(8),目标重构误差为 0.06,其余参数为默认值.采用 1 296 组训练数据进

行模型训练,迭代 250 次后的重构误差小于 0.06,满足精度要求,将该模型作为 F_1 的退化评估模型.

(3) 评估功能退化程度. 获取不同性能特征重要度的权重(见表 1). 采用步骤(2)中训练好的退化模型评估测试集数据,计算得到修正后的劣化指数 DI. 所得 3 a 内不同功能模块的劣化指数的变化趋势如图 2 所示. 由图 2 可见,随着运行时间增加,各功能劣化指数均逐渐增大. 而劣化指数越大,说明功能退化越严重.

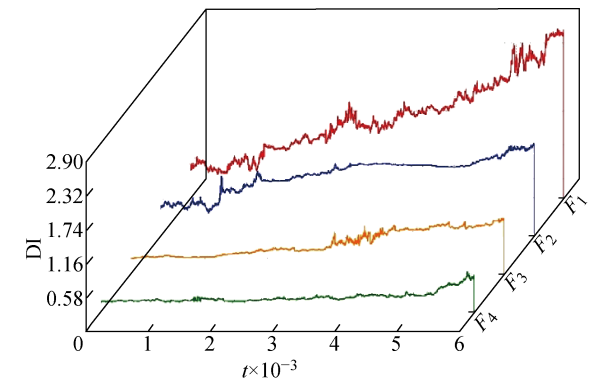


图 2 不同功能模块劣化指数的变化趋势
Fig. 2 Degradation tendency of each function module

由图 2 还可以看出,液压系统 F_1 的功能劣化指数随时间变化而迅速增长,其变化幅度远超过其他功能;而机械系统 F_2 相比初始时刻也有较明显的增长趋势. 通过比较各功能模块的劣化指数的最大值和变化趋势发现,液压系统的功能退化最严重.

另外,由企业调研中与产品设计师和相关技术人员的访谈可知,液压系统中子系统众多,但由于缺乏足够的设计和工艺操作经验的积累,所以液压系统的性能指标和可靠性与国外同行业的先进水平还存在差距,提升该功能模块的可靠性对于提升产品整体服务水平有着重要作用,因此,从实际工程的角度也说明液压系统功能模块再设计的必要性最高.

3.3 结果分析

为了验证 SAENN 模型的精度,采用 3.2 节中 F_1 的 1 620 组训练集数据及 AENN 和 SAENN 模型对于产品在健康状态下的性能特征提取效果进行对比,其结果见表 2. 由表 2 可以看出:SAENN 模型训练数据的平均重构误差略大于 AENN 模型,这是由于增加稀疏性限制条件的正则项的缘故,但其对模型精度的影响很小,且验证数据的平均重构误差小于 AENN 模型,说明 SAENN 模型的泛化能力更强. 因此,在训练数据重构误差差距不大的情况下,增加稀疏性限制条件能够提高模型的泛化能力,减少训练过程中的过拟合现象.

表 2 不同模型的重构误差		
Tab. 2 Reconstruction error of each model		
模型	平均重构误差	
	训练数据	验证数据
AENN	0.049	0.084
SAENN	0.055	0.063

为进一步验证 SAENN 模型的应用效果,本文采用改进 FMECA 方法^[2]、聚类方法^[5]和混合高斯模型(GMM)方法^[6]识别薄弱功能模块(液压系统),所得功能模块的再设计必要性见表 3. 其中,根据方法的不同,模块之间再设计必要性的高低有所区别. 改进 FMECA 方法是通过分析不同功能模块发生的故障模式及其可能造成的影响,按照故障的严重性、难检度和发生频次进行归纳,对各功能模块的再设计必要性进行排序;聚类方法是通过预先设定健康状态类别数,根据时变性能特征向量与聚类中心的距离计算功能模块的退化程度,进而比较功能模块间的退化差异;GMM 方法是通过建立混合高斯模型,将健康衰退指数作为功能模块退化程度的评估指标,以确定各功能模块再设计的必要性. 由表 3 可见,利用产品故障数据进行识别时,无法确定功能模块 F_2 和 F_3 的再设计必要性,其原因是产品故障数据来源于水平定向钻的返厂维修记录和用户反馈信息,而水平定向钻出厂投入运行 3 a 后只有 2 次返厂维修记录,分别为液压系统故障(表现为液压管颤抖)以及液压泵声音异常和泥浆系统故障(表现为管路堵塞). 因此,仅靠维修记录无法评估 F_2 和 F_3 的再设计必要性. 考虑性能时变数据后,采用聚类方法所得结果与 GMM、SAENN 方法的结果不同,其原因是聚类方法需预先确定工况个数,产品运行环境的多变性影响了产品退化趋势的评估;采用 GMM 模型与 SAENN 模型的结果一致,但 GMM 模型训练和评估的耗时较多,因此,采用 SAENN 模型进行再设计功能模块识别的整体性能最优.

表 3 不同方法识别的再设计功能模块的必要性		
Tab. 3 Different identified functions using different methods		
方法	数据类型	再设计必要性
改进 FMECA	产品故障	$F_1 > F_4$, F_2 与 F_3 无法比较
聚类	性能时变	$F_2 > F_1 > F_4 > F_3$
GMM	性能时变	$F_1 > F_2 > F_3 > F_4$
SAENN	性能时变	$F_1 > F_2 > F_3 > F_4$

4 结语

本文将产品在健康状态下的性能时变数据应用

于产品功能退化评估,提出了利用性能时变数据来指导产品再设计的思路,并将 SAENN 模型用于产品功能退化程度的评估,提高了再设计功能模块识别方法的准确性和客观性. 具体方法:将产品在健康状态下的性能数据作为训练数据,通过训练神经网络来学习性能参数深层次的特征,并引入稀疏性限制条件,以增强模型的泛化能力;利用产品运行阶段的性能时变数据评估产品功能退化的趋势;对比各功能模块间性能退化的差异,以识别需要改进的功能模块. 所得识别结果可作为产品再设计的依据,对提高产品可靠性具有重要意义.

然而,文中采用专家打分法对性能特征重要度进行评估,其主观性较强,下一步将考虑依据性能特征对产品健康状态下的敏感性和产品性能的退化程度来确定性能特征重要度.

参考文献:

[1] 周鹏辉,马红占,陈东萍,等. 基于模糊随机故障模式与影响分析的产品再设计模块识别[J]. *上海交通大学学报*, 2017, 51(10): 1189-1195.
ZHOU Penghui, MA Hongzhan, CHEN Dongping, *et al.* Identification of product redesign modules based on fuzzy random failure mode and effects analysis [J]. *Journal of Shanghai Jiao Tong University*, 2017, 51(10): 1189-1195.

[2] FRANCESCO Z, ROBERTO G. ANP/RPN: A multi criteria evaluation of the risk priority number [J]. *Quality and Reliability Engineering International*, 2012, 28(1): 85-104.

[3] 全睿,全书海,黄亮,等. 基于模糊故障树的燃料电池发动机氢安全[J]. *上海交通大学学报*, 2010, 44(7): 951-956.
QUAN Rui, QUAN Shuhai, HUANG Liang, *et al.* Study on hydrogen safety of fuel cell engine based on fuzzy fault tree [J]. *Journal of Shanghai Jiao Tong University*, 2010, 44(7): 951-956.

[4] DELANEY K D, PHELAN P. Design improvement using process capability data[J]. *Journal of Materials*

Processing Technology, 2009, 209(1): 619-624.

[5] SHIN J H, KIRITSIS D, XIROUCHAKIS P. Design modification supporting method based on product usage data in closed-loop PLM[J]. *International Journal of Computer Integrated Manufacturing*, 2015, 28(6): 551-568.

[6] MA H Z, CHU X N, LYU G L, *et al.* An integrated approach for design improvement based on analysis of time-dependent product usage data[J]. *Journal of Mechanical Design*, 2017, 139(11): 111401-1-13.

[7] 杜勉,易俊,郭剑波,等. 神经网络技术在风电机组 SCADA 数据分析中的应用研究[J]. *电网技术*, 2018, 42(7): 2200-2205.
DU Mian, YI Jun, GUO Jianbo, *et al.* Research on the application of neural networks on wind turbine SCADA data analysis[J]. *Power System Technology*, 2018, 42(7): 2200-2205.

[8] 王鲁昆,唐功夫,张健,等. 连续时变自编码器在人体行为识别中的应用[J]. *上海交通大学学报*, 2016, 50(7): 1065-1070.
WANG Lukun, TANG Gongfu, ZHANG Jian, *et al.* Human behavior recognition using continuous time-varying autoencoder [J]. *Journal of Shanghai Jiao Tong University*, 2016, 50(7): 1065-1070.

[9] DENG J, ZHANG Z X, MARCHI E, *et al.* Sparse autoencoder-based feature transfer learning for speech emotion recognition [C] // *Proceedings of Humaine Association Conference on Affective Computing and Intelligent Interaction*. New York, USA: ACM Press, 2013: 511-516.

[10] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, *et al.* Scikit-learn: Machine learning in python [J]. *Journal of Machine Learning Research*, 2012, 12: 2825-2830.

[11] KINGMA D, BA J. Adam: A method for stochastic optimization [EB/OL]. [2017-11-09]. <http://www.oalib.com/paper/4068193.XG5Cw6FJhtA>.

(本文编辑:何雪)