

DOI: 10.13382/j.jemi.B2003082

基于 DE-QPSO 算法的 MKRVM 对电容式 RF-MEMS 开关的寿命预测方法*

何怡刚 白月皎 鲁力

(合肥工业大学 电气与自动化工程学院 合肥 230009)

摘要:为进一步研究电容式 RF-MEMS 开关在实际应用中存在的可靠性问题,提出一种基于差分进化的量子粒子群算法(DE-QPSO)的多核相关向量机(MKRVM)方法对开关寿命进行预测。首先采用了限制带宽经验模态分解(BREMD)来对实验过程中获得的寿命数据进行去噪处理,提高数据的可靠性;其次采用 DE-QPSO 获取 MKRVM 的最优稀疏权重,并利用 MKRVM 算法对此类开关进行寿命预测;最后利用实验获取的实际数据对所用方法的准确性进行测试。实验结果表明,MKRVM 能在 0.21 s 的时间内得到预测结果,所得数据的均方根为 3.1043×10^6 s,最接近原始数据的 3.0657×10^6 s;DE-QPSO 能在 0.45 s 内得到优化结果,方差为 7×10^{-5} 。同时得到弹性系数在 4~16 N/m 的范围内取值时开关寿命最长的结论。

关键词: 电容式 RF-MEMS 开关;BREMD;MKRVM;DE-QPSO;寿命预测

中图分类号: TN406;TP211 **文献标识码:** A **国家标准学科分类代码:** 510.8040

MKRVM prediction of capacitive RF-MEMS switching life based on DE-QPSO algorithm

He Yigang Bai Yuejiao Lu Li

(School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

Abstract: To further study the reliability problems of capacitive RF-MEMS switches in practical applications, a multi-core relevance vector machine (MKRVM) method based on differential evolution quantum particle swarm optimization (DE-QPSO) is proposed to predict the switch lifetime. First of all, bandwidth restricted empirical mode decomposition (BREMD) is used to denoise the life data obtained during the experiment to improve the data reliability; secondly, DE-QPSO is used to obtain the optimal sparse weight of MKRVM, and the MKRVM algorithm is used to predict the life of such switches; finally, the actual data obtained by experiment is used to test the accuracy of the methods. The experimental results show that MKRVM can obtain the prediction results within 0.21 s. The root mean square of the data is 3.1043×10^6 s, which is the closest to the original data of 3.0657×10^6 s; DE-QPSO can be optimized within 0.45 s, the variance is 7×10^{-5} . At the same time, it is concluded that the switch life is the longest when the elastic coefficient is in the range of 4~16 N/m.

Keywords: capacitive RF-MEMS switch; BREMD; MKRVM; DE-QPSO; life prediction

0 引言

随着 5G 时代的到来,无线通讯技术正处于高速发展的阶段,对于新型器件的设计,除在保留原有器件功能的同时,更要求器件消耗最小的资源并高效率的完成所承担的任务。随着射频微机电系统(RF-MEMS)技术的出

现,很好的帮助人们达到这些要求。

RF-MEMS 是微机电系统(MEMS)技术的重要的实际应用领域之一,并可以用于微波电路中无线电波的信号处理,对当代的无线通讯等产生重大的影响。虽然 RF-MEMS 技术已经应用于多个领域,但总的来说我国在 RF-MEMS 的研究起步要晚于西方国家,而 5G 技术的普遍化给我国 RF-MEMS 的创新研究带来巨大的挑战,一

收稿日期: 2010-04-19 Received Date: 2010-04-19

* 基金项目:国家自然科学基金(51577046)、国家自然科学基金重点项目(51637004)、国家重点研发计划“重大科学仪器设备开发”项目(2016YFF0102200)、装备预先研究重点项目(41402040301)资助

方面,因为 5G 技术刚刚开始普及,RF-MEMS 在 5G 方面应用的研究相对较少;但另一方面对 RF-MEMS 的研究存在一定的难度,其中 RF-MEMS 器件的可靠性就是制约其发展的主要因素之一。RF-MEMS 器件的可靠性关系到产品本身的开发效率、开发成本以及它的实际使用性,在工业应用领域,器件的失效可能会带来巨大的经济损失甚至会威胁到相关工作人员的生命安全。

因此,对于 RF-MEMS 器件的可靠性研究一直是 MEMS 器件研究的热点之一。RF-MEMS 开关作为 RF-MEMS 技术的最初研究对象,理论研究基础已经比较成熟。RF-MEMS 开关主要有接触式和电容式两种,实验发现,电容式 RF-MEMS 开关相对于接触式开关有高频性能好,本身结构有利于获得较小的损耗的特点,使其有着更好的应用前景,所以对它的研究更加成熟一些。文献[1]研究了电容式 RF-MEMS 开关的相关参数对可靠性的影响,利用 MATLAB 仿真开关的性能参数,得到了相关结构参数(极板距离、温度以及频率等)对开关寿命的影响;文献[2]在研究 MEMS 开关的失效机理的基础上,构建了一种开关测试平台对开关进行寿命测试,主要分析了开关的制作工艺以及温度对开关可靠性的影响;文献[3]在理论上计算了 RF-MEMS 开关的桥膜弹性系数,以降低开关启动电压提高开关性能;文献[4]分别研究了影响接触式 RF-MEMS 开关和电容式 RF-MEMS 开关可靠性的因素,利用 Intllisuite 软件分析接触式开关的驱动电压、回复力以及接触力对其可靠性的影响,得到降低驱动电压来提高开关可靠性,同时并设计了一种弯曲型电容式开关,实现低电压驱动,提高开关寿命;文献[5]利用仿真技术研究了介电层电荷积累引起开关的可靠性问题,分析了引起此现象的主要来源是界面极化和介质层陷阱俘获自由电荷,并提出了可行的解决方案;文献[6]通过对电容式开关主要的失效机理的研究得到改善开关可靠性的途径主要是减小介电层充电。

由此可见,对于 RF-MEMS 开关的可靠性研究多在于其失效机理的理论分析及仿真,但对于开关的寿命预测的研究较少。本文针对电容式 RF-MEMS 开关的特点^[7],在前人对 RF-MEMS 开关可靠性研究的理论基础上,选取电容式 RF-MEMS 开关特性参数之一——弹性系数 K 作为研究对象^[8-9],提出一种对开关寿命预测的方法。由于开关产生的相关信号是非线性、非平稳的^[10-11],并且存在一系列噪声的干扰,然而传统的经验模态分解(ensemble empirical mode decomposition, EMD)方法存在模态混叠与信号分量相互影响的现象,因而在 EMD 的基础上采用限制带宽经验模态分解(bandwidth restricted empirical mode decomposition, BREMD)方法^[12],抑制模态混叠,提高信号分辨率^[13-15];在寿命预测方面,支持向量机(support vector machine, SVM)和相关向量机

(relevance vector machine, RVM)是近年来广泛应用预测的方法,相对于 SVM 方法,RVM 方法更多的被用^[16],但是该方法多依靠经验来做回归预测分析,为了提高方法的准确性,在传统 RVM 的基础上,采用多核学习方法,利用多核相关向量机(multi-core relevance vector machine, MKRVM)进行回归预测分析^[17];MKRVM 方法的关键在于核函数的选取,近年来量子粒子群算法(quantum particle swarm optimization, QPSO),差分进化算法(differential evolution, DE)等多用于最优解的获取。QPSO 算法具有搜索速度快,迭代次数少的优点,但在运算后期极易陷入局部最优解,DE 算法虽然可以避免陷入局部最优解,却存在速度低,迭代次数多的缺点^[18-19],因此本文将两种优化算法结合,保留各自优点得到基于差分进化的量子群算法(differential evolution quantum particle swarm optimization, DE-QPSO)来计算 MKRVM 核函数的最优解。

综上所述,本文采用 BREMD 对获取的含有噪声的开关寿命数据进行去噪处理,并利用 MKRVM 进行开关的寿命预测,从而对电容式 RF-MEMS 开关进行剩余寿命预测(RUL),同时采用基于差分进化的量子群粒子群算法(DE-QPSO)对 MKRVM 中核函数中的稀疏权重进行优化,并通过实验检测本文所提方法的准确性和可靠性。

1 电容式 RF MEMS 开关

1.1 电容式 RE MEMS 开关原理

以静电驱动 RF-MEMS 开关为例,此类开关主要由电极,电介质层,锚点,共面波导(CPW)传输线四部分组成^[1]。其典型的弯曲型 RF-MEMS 开关的三维立体模型如图 1 所示。



图 1 弯曲型悬臂梁 RF-MEMS 开关

Fig. 1 RF-MEMS switch for curved cantilever beam

此类开关中,射频信号的输入与输出都是依靠共面波导的传输线以及可移动的金属电极和锚点所在区域的支撑立柱,这样的设计可以使这些部件中留出间隙起到保护内部电路的作用;为避免开关内部造成短路故障,所以氮化硅绝缘介质层被设计到共面波导传输线上方;为了避免元器件焊接过程中产生的不利影响,因而金属与电极线之间的黏着力也相应的减小。

外加的偏置电压驱动电极来改变耦合电容的大小从

而达到控制信号的目的。当无偏置电压的情况下,射频信号可以几乎无变化的从一端传送到另一端,这时的开关处于开启状态,开关电容如式(1)所示。

$$C_{\text{up}} = \frac{\varepsilon_0 A}{g_0 + t_d / \varepsilon_r} \quad (1)$$

式中: ε_0 表示空气介电常数; A 表示传输线和薄膜的面积; g_0 表示金属板和绝缘层之间的初始距离; t_d 表示介质层厚度; ε_r 表示相对介电常数。

当偏置电压不再为 0, 存在加载在导体和地板间的直流电压时, 在静电力的作用下, 薄膜向下移动, 导致极板间间距变小, 所以电容会增大, 当位于上方的极板与介质层接触时, 信号则会从地线输出, 这时的开关处于关闭状态^[6]。

1.2 影响电容式 RF-MEMS 开关寿命因素

由上述开关的工作原理可知, 电容式 RF-MEMS 开关的寿命与两端的偏置电压和电介质充电效应有关。偏置电压不仅会影响可动薄膜的冲击速度还会对介质层的内部电场产生影响, 从而对开关的寿命造成一定的影响。本文主要介绍电介质的充电效应对开关寿命的影响, 通过对其失效机理的分析研究影响开关剩余寿命的因素, 并利用 MATLAB 软件进行相关的分析。

通过其他相关文献的研究可知, MEMS 开关的失效主要是由充电失效引起的^[7-9], 原理如图 2 所示。

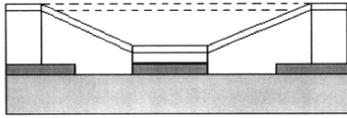


图 2 电介质充电引起的粘连失效

Fig. 2 Adhesion failure caused by dielectric charging

当薄膜下拉时产生的电场在临界击穿值附近, 因而会发生极化和介质层漏电流现象, 当漏电流的电荷被介质层内的陷阱捕获后产生的捕获电压 $> V_{\text{pull-out}}$ 就会产生粘连失效。而界面产生极化现象时的极化电荷和捕获的漏电流电荷造成了累积电荷的存在。因而当开关失效时的电荷分布如图 3 所示。

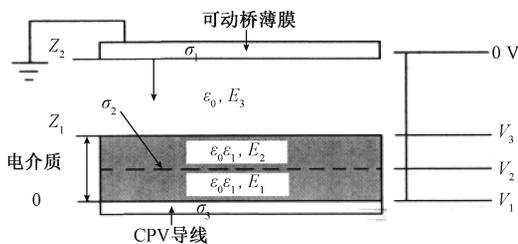


图 3 开关电荷分布

Fig. 3 Switching charge distribution

本文用 σ_1 来表示可动桥膜中的电荷密度, σ_2 表示

电介质中的电荷密度, σ_3 为 CPW 导线中的电荷密度, ε_1 为电介质的相对介电常数, $V_1 - V_3$ 为偏置电压, $E_1 - E_3$ 是电场分布^[10], t 为开关的工作时间, ζ 为驱动信号的占空比, η 为电介质电荷捕获系数, ε_r 代表相对介电常数, U 为外加电压和射频电压之和, S 则为极板正对面积。

由于可动桥薄膜的弹性恢复力如下:

$$F = Kx = K(g_0 - t) \quad (2)$$

电场分布如下:

$$E = \varepsilon_r \times \frac{U}{2t} \quad (3)$$

电荷量如下:

$$q = CV = \frac{\varepsilon_0 \varepsilon_r S}{t} \times U \quad (4)$$

弗伦克尔-普尔传导电流密度如下:

$$J_{FP} = \rho_{FP} E_d \exp \left[\frac{-(E_t - e\beta \sqrt{E_d})}{kT} \right] \quad (5)$$

Ohmic 传导电流密度如下:

$$J_{\Omega} = \rho_{\Omega} \exp \left[\frac{-E_{\Omega}}{KT} \right] \times E_d \quad (6)$$

总电流密度如下:

$$J = J_{\Omega} + J_{FP} = \rho_{\Omega} \exp \left[\frac{-E_{\Omega}}{KT} \right] \times E_d + \rho_{FP} E_d \exp \left[\frac{-(E_t - e\beta \sqrt{E_d})}{KT} \right] \quad (7)$$

电介质层中的电荷累积密度如下:

$$\sigma_p = \zeta \times \eta \times J \times t = \zeta \times \eta \times E_d \left\{ \rho_{\Omega} \exp \left[\frac{-E_{\Omega}}{KT} \right] + \rho_{FP} \exp \left[\frac{-(E_t - e\beta \sqrt{E_d})}{KT} \right] \right\} \quad (8)$$

据此推导开关寿命的相关公式当静电力和弹性回复力处于平衡状态时, 有:

$$K(g_0 - t) = \varepsilon_r \times \frac{U}{2t} \times \frac{\varepsilon_0 \varepsilon_r S}{t} \times U \quad (9)$$

进一步进行推导可得锁住电压:

$$V_{\text{pull-out}} = \sqrt{\frac{2K_{\text{bridge}} g g_0^2}{\varepsilon_0 \varepsilon_r^2 A} - V_{RF}^2} \quad (10)$$

由电压与电容的关系可知:

$$V_{\text{pull-out}} = V_{\text{Charge}} = \frac{I \Delta t}{C} = \frac{(J_{FP} + J_{\Omega}) A \zeta \eta}{C} \Delta t \quad (11)$$

可得开关的寿命公式为:

$$t_{\text{fail}} = \frac{2 \sqrt{\frac{2K_{\text{bridge}} g \varepsilon_0}{A} - V_{RF}^2 \left(\frac{\varepsilon_0 \varepsilon_r}{g_0} \right)^2}}{\varepsilon \eta E_d \left(\rho_{FP} \exp \left[\frac{-(E_t - e\beta \sqrt{E_d})}{KT} \right] + \rho_{\Omega} \exp \left[\frac{-E_{\Omega}}{KT} \right] \right)} \quad (12)$$

因此,不难看出影响电容式 RF-MEMS 开关寿命的因素包括弹性系数 K , 介质层厚度 t , 上下极板间距离 g_0 , 介电常数 ε 等。

其中薄膜力学性能对于 MEMS 器件设计是必不可少的,而器件的性能表现与所用材料的杨氏模量、泊松比等弹性性能直接相关,而可动桥膜的弹性系数和开关的驱动电压有着密切的联系,驱动电压又是开关的重要参数之一,因而本文主要讨论弹性系数 K 对寿命的影响,并利用 MATLAB 软件进行寿命仿真^[1]。

2 BREMD 去噪

由于射频信号在输入输出过程中可能会和各种噪声混合,包括环境噪声和电磁干扰,这样会造成获取的数据存在偏差,增加了之后预测开关寿命过程的不准确性。因此,为了增加数据的可靠性,对于获取的数据采取去噪的方法。通常去除噪声干扰一般会采用经验模态分解 EMD 的方法,EMD 算法是一种处理非平稳信号的方法^[11],它不仅可以处理非平稳、非线性信号,也适用于线性、平稳信号,但在实际应用中会出现模态混叠的现象,一旦此种现象出现特征模态函数也就失去了意义,因而本文在 EMD 的基础上采用 BREMD 的方法来对信号进行去噪处理。

BREMD 去噪包括两个过程,1) 筛选过程;2) 相关组件选择^[12]。首先,通过筛选将原始信号分解为一系列的本征模态函数 IMF 和余量^[13]。假设原始信号为 $x(t)$, 然后原始信号就可以被分解成为:

$$x(t) = \sum_{i=1}^n C_i(t) + r_n(t) \quad (13)$$

式中: $C_i(t)$ 为第 i 个 IMF; $r_n(t)$ 为余量。

原始信号主要的信息由几个相关的 IMF 函数和余量组成。因此,相似系数 s_i 被应用于确定相关 IMF。 s_i 的定义如下^[9]:

$$s_i = \frac{\sum_{t=1}^n x(t)c_i(t)}{\sqrt{\sum_{t=1}^n x^2(t) \sum_{t=1}^n c_i^2(t)}} \quad (14)$$

其中, s_k 是大于相似系数阈值 R 的第 1 个值(本文 $R=0.3$), $k \in [1, n]$ 。其他的 IMF 被称作应该被去噪的噪声占主导的 IMF (NDIMF)。由于阈值去噪方较容易实现,所以此方法常常用来噪声抑制。这种方法的核心是阈值的确定,其中 SUREShrink 阈值^[14] 和 VisuShrink 阈值^[15] 是两种应用较为广泛的决定阈值的方法。然而, VisuShrink 方法可能会有“过度切割”的现象,这种现象将会丢掉一些重要的信号特征。SUREShrink 阈值方法则是通过均方误差的无偏估计确定阈值 (MSE), 此方法可以保存信号的详细信息,但是这种方法可以导致“过度存储”的现象,也就是意味着噪声的抑制性差。因此,在

本文中提出一种模糊阈值方法来解决上述两种方法可能遇到的问题。这种模糊阈值方法采用一种隶属函数和一个模糊区域来代替常规的固定阈值。从 VisuShrink 方法中获得的阈值(记作 V) 作为模糊区域的上界,而从 SUREShrink 阈值方法中得到的阈值(记作 S) 作为模糊区域的下界。因此,去噪 NDIMF 公式如下:

$$c'_i(t) = c_i(t) \cdot \mu_i(c_i(t)) \quad (15)$$

式中: $c'_i(t)$ 为去噪 NDIMF; $c_i(t)$ 为原始 NDIMF; $\mu_i(c_i(t))$ 为相应的隶属函数。

由此可知,NDIMF 中振幅接近 V 的应该要进行小幅度抑制,甚至要完全保留;另一方面,NDIMF 中振幅接近 S 的要被大幅度抑制或者剔除,所以隶属度函数如下:

$$\mu_i(c_i(t)) = \begin{cases} 1, & |c_{i(t)}| \geq V \\ \left(\frac{|c_{i(t)}| - S}{V - S} \right)^2, & S \leq |c_{i(t)}| \leq V \\ 0, & |c_{i(t)}| \leq S \end{cases} \quad (16)$$

因此,去噪信号可以由如下方式计算:

$$x'(t) = \sum_{i=1}^{k-1} c'_i(t) + \sum_{i=k}^n c_i(t) + r_n(t) \quad (17)$$

因而之前所提出去噪方法的具体步骤如下。

- 1) 在原始信号中应用 BREMD 并获取全部的 IMF。
- 2) 根据相似系数的式(14)获得相关的 IMF。
- 3) 根据去噪 NDIMF 和隶属度函数的式(15)、(16)计算去噪 $c_1(t)$ 到 $c_{k-1}(t)$ 。

- 4) 由去噪信号式(17)获得去噪信号。

3 MKRVM 及其生成方法

RVM 是一种基于稀疏贝叶斯理论的机器学习算法^[16]。与 SVM 算法作比较,RVM 更加稀疏,所用时间更短。但由于单核 RVM 应用在回归预测时多依赖于经验,因而获取最优选择就存在不小的困难,所以本文采用多核学习的方法,即 MKRVM 进行预测,已达到短时间内得到最优选择的目的,提高预测的准确性。

将一组训练数据假设为 $\{x_i, t_i\}_{i=1}^N$, 其中 x_i 为输入向量, t_i 为相应目标向量。目标向量 t_i 可以定义为:

$$t_i = y(x_i; \omega) + \delta_i, \delta_i \sim N(0, \sigma^2) \quad (18)$$

式中: $\omega = (\omega_0, \omega_1, \dots, \omega_N)^T$ 是权重向量; δ_i 为噪声。

假设 t_i 是独立存在的,那么全部数据可以被定义为:

$$p(t | \omega, \sigma^2) = (2\pi\sigma^2)^{-N/2} \exp\left\{-\frac{1}{2\sigma^2} \|t - \mu\omega\|^2\right\} \quad (19)$$

式中: $t = (t_1, t_2, \dots, t_N)^T$, $\mu = (\mu(x_1), \mu(x_2), \dots, \mu(x_N))$, $\mu(x_i) = [1, K(x_i, x_1), K(x_i, x_2), \dots, K(x_i, x_N)]^T$, $K(x_i, x)$ 为核函数。 ω 和 σ^2 的最大似然估计可能会导致过拟合现象,因此,采用零均值高斯先验概率分布来约束这两个

参数:

$$p(\boldsymbol{\omega} | \boldsymbol{\lambda}) = \prod_{i=0}^N N(\omega_i | 0, \lambda_i^{-1}) \quad (20)$$

式中: $\boldsymbol{\lambda}$ 是 $N+1$ 维超参数向量。

所有未知参数的后验概率可根据贝叶斯规则获得:

$$\frac{p(\boldsymbol{\omega}, \boldsymbol{\lambda}, \sigma^2 | \mathbf{t})}{\int p(\mathbf{t} | \boldsymbol{\omega}, \boldsymbol{\lambda}, \sigma^2) p(\boldsymbol{\omega}, \boldsymbol{\lambda}, \sigma^2) d\boldsymbol{\omega} d\boldsymbol{\lambda} d\sigma^2} \quad (21)$$

其中 $p(\boldsymbol{\omega}, \boldsymbol{\lambda}, \sigma^2 | \mathbf{t})$ 可以进行如下分解:

$$p(\boldsymbol{\omega}, \boldsymbol{\lambda}, \sigma^2 | \mathbf{t}) = p(\boldsymbol{\omega} | \mathbf{t}, \boldsymbol{\lambda}, \sigma^2) p(\boldsymbol{\lambda}, \sigma^2 | \mathbf{t}) \quad (22)$$

$$p(\boldsymbol{\omega} | \mathbf{t}, \boldsymbol{\lambda}, \sigma^2) = \frac{p(\mathbf{t} | \boldsymbol{\omega}, \sigma^2) p(\boldsymbol{\omega} | \boldsymbol{\lambda})}{p(\mathbf{t} | \boldsymbol{\lambda}, \sigma^2)} =$$

$$(2\pi)^{-(N+1)/2} |\boldsymbol{\Sigma}|^{-1/2} \exp\left\{-\frac{0.5(\boldsymbol{\omega} - \boldsymbol{\varphi})^T}{\boldsymbol{\Sigma}^{-1}(\boldsymbol{\omega} - \boldsymbol{\varphi})}\right\} \quad (23)$$

式中: $\boldsymbol{\varphi} = \sigma^{-2} \boldsymbol{\Sigma} \boldsymbol{\mu}^T \mathbf{t}$, $\boldsymbol{\Sigma} = (\sigma^{-2} \boldsymbol{\mu}^T \boldsymbol{\mu} + \mathbf{A})^{-1}$, $\mathbf{A} = (\lambda_0, \lambda_1, \dots, \lambda_N)$ 。

$p(\mathbf{t} | \boldsymbol{\lambda}, \sigma^2)$ 可以被定义为如式(24), 表示的统一超参数。

$$p(\mathbf{t} | \boldsymbol{\lambda}, \sigma^2) = \int p(\mathbf{t} | \boldsymbol{\omega}, \sigma^2) p(\boldsymbol{\omega} | \boldsymbol{\lambda}) d\boldsymbol{\omega} =$$

$$(2\pi)^{-N/2} |\sigma^2 \mathbf{I} + \boldsymbol{\mu} \mathbf{A}^{-1} \boldsymbol{\mu}^T|^{-\frac{1}{2}} \cdot \exp\{-0.5^T(\sigma^2 \mathbf{I} + \boldsymbol{\mu} \mathbf{A}^{-1} \boldsymbol{\mu}^T)^{-1} \mathbf{t}\} \quad (24)$$

而对于一个新的输入向量 \mathbf{x}_* , 输出向量的预测分布可以从式(25)获得。

$$p(\mathbf{t}_* | \mathbf{t}, \lambda_{MPE}, \sigma_{MPE}^2) = \int p(\mathbf{t}_* | \boldsymbol{\omega}, \sigma_{MPE}^2) p(\boldsymbol{\omega} | \mathbf{t}, \lambda_{MPE}, \sigma_{MPE}^2) d\boldsymbol{\omega} \quad (25)$$

高斯核函数由于自身出色的非线性数据处理性能而被广泛应用^[17], 此函数通常如下所示:

$$K_c(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}\|^2}{2\theta^2}\right) \quad (26)$$

式中: θ 为内核宽度。

多项式内核函数被证实对于高斯内核函数是一种有效的补充^[13], 此多项式函数可以表示为式(27)。

$$x_i(t+1) = \begin{cases} v_i(t+1) + \left\{0.5 + 0.5 \times \frac{T-t}{T}\right\} \times |m_i - x_i(t)| \times \ln u, & u > 0.5 \\ v_i(t+1) - \left\{0.5 + 0.5 \times \frac{T-t}{T}\right\} \times |m_i - x_i(t)| \times \ln u, & u \leq 0.5 \end{cases} \quad (32)$$

式中: p_i 为种群数量, c_1, c_2 为学习因子, 一般取常数, 本文中令 $c_1 = c_2 = 2$; r_1, r_2 为 $[0, 1]$ 的随机数; $p_i(t)$ 为个体最优解; $p_g(t)$ 为全局最优解; $v_i \in [-v_{\min}, v_{\max}]$; t 为当前迭代次数; T 为最大迭代次数。

4.2 DE 算法

DE 算法可分为变异、交叉以及选择, 以此来找寻最优解, 计算过程如下。

$$K_p(\mathbf{x}, \mathbf{x}_i) = [\mathbf{x}_i^T \cdot \mathbf{x} + 1]^m \quad (27)$$

式中: m 为度数。本文采用的 MKRVM 算法的内核函数主要有上述的两个基本的内核函数组成, 并用来对电容式 RF-MEMS 开关进行寿命预测。多项内核可以被定义为:

$$K(\mathbf{x}, \mathbf{x}_i) = \sum_{j=1}^L v_j K_c(\mathbf{x}, \mathbf{x}_i) + \sum_{r=1}^U v_r K_p(\mathbf{x}, \mathbf{x}_i) \quad (28)$$

式中: v_j 和 v_r 分别表示第 j 个高斯内核函数和第 r 个多项式核函数的权重, $\sum_{j=1}^L v_j + \sum_{r=1}^U v_r = 1$, 本文令 $L=5, U=3$ 。

然而, 内核函数的权重容易影响预测的速度和准确度, 因而我们要采用优化算法来找到内核函数的稀疏权重, 利用优化算法可以减少得到最优解的时间, 可以更快更准确的得到权重最优解, 如果没有采用优化算法, 得到权重最优解的时间会大大增加, 带来不必要的损耗。因此, 本文采用 DE-QPSO 算法去寻找 MKRVM 中核函数的最佳权重。

本文采用均方根作为健康指标 (HI), 定义如下:

$$HI = \sqrt{\frac{1}{k} \sum_{i=1}^k v_i^2} \quad (29)$$

式中: v_i 是第 i 个寿命特征数据^[12]。

4 DE-QPSO 算法

4.1 QPSO 算法

QPSO 为引入量子行为的粒子群算法^[18], 由于粒子群算法在寻优过程中容易陷入局部最优解, 所以 Sun 等在传统粒子群算法的基础上做出改进, 并提出了量子粒子群优化算法^[19], 在这种算法中, 粒子最终收敛在以局部吸引点为中心的 δ 势阱中, 并进行迭代次数的更新, 这样提高了算法的全局搜索能力, 其计算公式^[20-21]如下:

$$m_i = \sum p_i(t) / p_s \quad (30)$$

$$v_{i+1} = [c_1 r_1 p_i(t) + c_2 r_2 p_g(t)] / (c_1 r_1 + c_2 r_2) \quad (31)$$

1) 种群初始化, 随机产生初始种群^[22-23]:

$$x_{i,j}(0) = \mathbf{x}_j^L + rand \times (\mathbf{x}_j^U - \mathbf{x}_j^L) \quad i = 1, 2, \dots, N; j = 1, 2, \dots, P \quad (33)$$

式中: $x_{i,j}$ 为第 i 个个体的第 j 个分量; \mathbf{x}_j^U 表示父本向量; N 为种群大小; P 为个体决策变量个数; $rand$ 为均匀分布的随机数。

2) 变异, 在初始的随机种群中抽取不同的两个个体向量, 之后与等待变异操作的两个不同个体向量运算后

产生新的变异种群,其计算公式^[22-23]为:

$$V_i(t+1) = X_{r_1}(t) + S \times (X_{r_1}(t) - X_{r_3}(t)) \quad (34)$$

其中, r_1, r_3 为 $[0, n]$ 的随机整数; S 为 $[0.5, 1]$ 的缩放因子; t 为进化代数; $X_i(t)$ 为第 t 代种群的第 i 个个体。

3) 交叉, 为了增加种群的多样性, 要进行交叉的操作, 将 t 代与新的变异种群 $V_i(t+1)$ 进行交叉, 具体操作如下所示^[22-23]:

$$U_i(t+1) = (u_{i,1}(t+1), u_{i,2}(t+1), \dots, u_{i,j}(t+1)) \quad (35)$$

$$u_{i,j}(t+1) = \begin{cases} v_{i,j}(t+1), & \text{rand}(0,1) \leq CR \text{ 或 } j = j_{\text{rand}} \\ x_{i,j}(t), & \text{其他} \end{cases} \quad (36)$$

式中: CR 为交叉概率; j_{rand} 为随机数。

4) 选择, 用贪婪选择的方法选择进入下一代的最优个体^[22-23]。

$$X_i(t+1) = \begin{cases} U_i(t+1), & f(U_i(t+1)) \leq f(X_i(t)) \\ X_i(t), & \text{其他} \end{cases} \quad (37)$$

4.3 基于 DE-QPSO 算法

QPSO 算法搜索速度快, 迭代次数少, 但在收敛后期种群的多样性逐渐减少, 会使算法陷入局部最优解, 而 DE 算法正好可以弥补这个缺陷, 增加种群的多样性, 但 DE 算法的迭代次数多致使速度降低, 因而本文选择两种算法结合的一种优化算法——DE-QPSO, 这样两种方法可以互相弥补各自缺陷, 增加算法的准确性, 此优化算法分为以下几步进行^[19], 算法流程如图 4 所示。

- 1) 随机产生初始种群, 并设置初始化种群粒子的位置和速度以及当前迭代次数 t 和最大迭代次数 T ;
 - 2) 若 $t > T$, 则输出 $p_g(t)$, 否则进行下一步;
 - 3) 更新粒子的位置和速度;
 - 4) 对粒子的位置进行 DE 算法的操作;
 - 5) 选择最优个体进入下一代, 同时更新 $p_g(t)$ 的值;
 - 6) 令 $t = t + 1$ 之后继续步骤 2)。
- 最后得出的最优解便是 MKRVM 的内核权重。

5 实验测试与分析

根据电容式 RF-MEMS 开关的寿命式(12)可知, 影响其开关寿命的因素有弹性系数 K , 温度 T , 介电常数 ϵ 等有关, 本文选取弹性系数 K 作为研究对象, 通过测试不同弹性系数下电容式 RF-MEMS 开关的寿命, 得到开关的寿命与弹性系数的关系, 并根据这些数据利用 MKRVM 对开关进行寿命预测, 由此来选择合适的弹性系数达到增加开关在使用过程中的可靠性的目的。整个实验过程如图 5 所示。

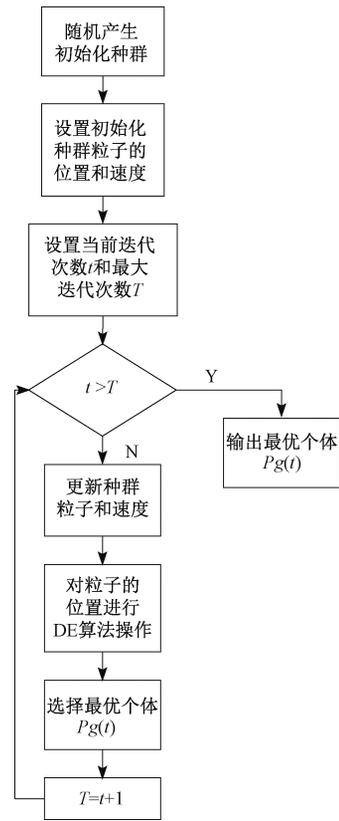


图 4 DE-QPSO 算法流程

Fig. 4 DE-QPSO flow chart of the algorithm

本次实验在满足低阈值电压驱动的要求下进行开关寿命测试, 选取开关的梁材为金属铝, 梁长为 $200 \mu\text{m}$, 梁宽为 $30 \mu\text{m}$, 梁厚为 $1 \mu\text{m}$, 极板间距离为 $2 \mu\text{m}$, 传输线宽度为 $150 \mu\text{m}$, 电介质材料为氮化铝, 外加偏置电压选择脉冲波形偏置电压^[1]。在不同弹性系数下对开关进行寿命加速测试实验, 最后获取了 581 组数据继续相关的数据处理以及预测。

5.1 BREMD 去噪过程

基于本文第二部分详细阐述的 BREMD 去噪过程, 对于获取的原始寿命数据进行去噪处理, 重新构建开关寿命的纯数据, 以达到提高获取信数据的准确性的目的, 避免在实验过程中遇到的噪声干扰问题, 结果如图 6 所示。

去噪结果如图 6 所示, 为方便观察结果, 特截取部分弹性系数在 $4 \sim 5 \text{ N/m}$ 的图像表示在图 6 放大图, 可以看出 BREMD 去噪方法在原始数据的基础上进行重构, 比起原始数据形成的曲线, 经过 BREMD 去噪处理之后的曲线更加光滑, 排除了一些不确定的干扰噪声的影响, 可以帮助提高 MKRVM 预测结果的准确性。

5.2 基于 DE-QPSO 优化算法

对于 MKRVM 算法中内核函数的稀疏权重最优解的

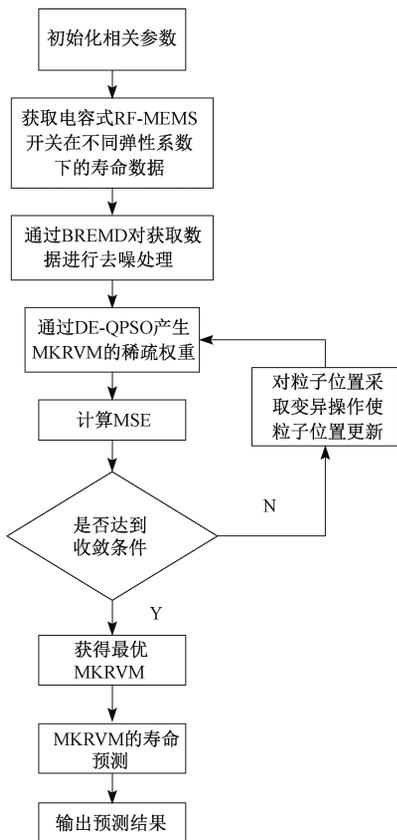


图 5 MKRVM 寿命预测流程

Fig. 5 MKRVM flow chart for life prediction

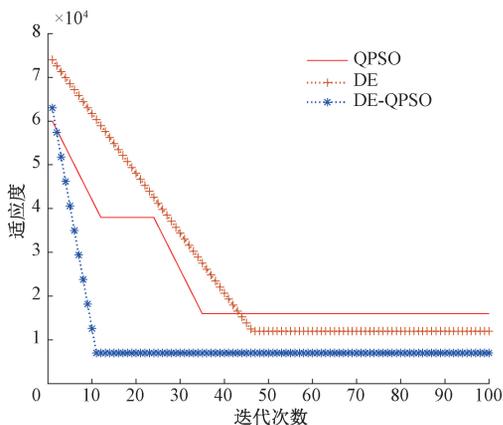


图 7 不同优化算法的稀疏权重对比

Fig. 7 Comparison of sparse weight in different optimization algorithms

表 1 不同算法的优化结果

Table 1 Optimization results of different algorithms

算法	方差	平均时间/s
DE-QPSO	7×10^{-5}	0.453 21
QPSO	1.8×10^{-4}	1.789 35
DE	1.2×10^{-4}	2.873 64

从图 7 可以明显的看出 QPSO 算法在运行过程中会陷入局部最优解而 DE 算法迭代次数最多;从 3 种方法的运行结果即表 1 可以看出,DE 算法运行时间最长达到 2.873 64 s,而 DE-QPSO 的时间最短,只有 0.453 21 s, QPSO 运行时间为 1.789 35 s;从适应度方差可以看出,DE-QPSO 的方差最小为 7×10^{-5} ,所以其优化效果最好,准确度最高, QPSO 的方差最大,达到 1.8×10^{-4} ,因此 QPSO 算法的优化效果最差,准确率最低,DE 的方差为 1.2×10^{-4} 处于两者中间。综上所述,相对于 DE 和 QPSO 两种算法,DE-QPSO 算法的准确性、优化效果以及运行时间明显更具有优势。表 2 为利用 DE-QPSO 优化算法得到 MKRVM 的稀疏权重的最优结果。

表 2 优化稀疏权重

Table 2 Optimized sparse weights

权重	1	2	3	4	5	6	7	8
值	0	0.012	0	0.143 5	0.183 7	0.273 6	0	0.122 3

5.3 MKRVM 进行寿命预测

在本次实验中,采用了两种寿命预测的方法对开关寿命进行预测,分别为 RVM 和 MKRVM,设置多项式核函数阶次为 1、2、3,高斯核函数的宽度因子分别为 0.1、0.2、0.3、0.4、0.5,预测结果如图 8 所示。

图 8 放大图是截取了弹性系数 7~10 N/m 的图像,可以比较明显的看出利用 MKRVM 得到的预测数据更接近原始数据。为了较为明显地分辨出两种预测方法的优劣,本文利用两种方法得到寿命预测的结果与实际数据

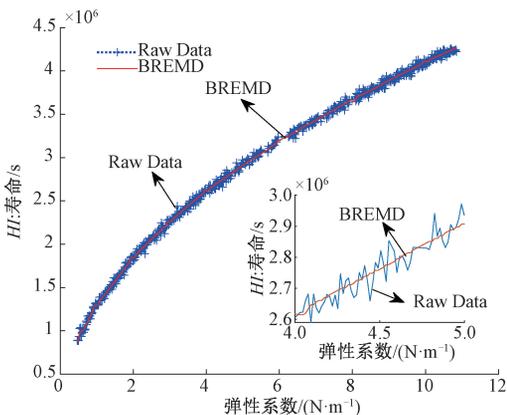


图 6 BREMD 去噪

Fig. 6 BREMD denoise

确定,本文采用了 3 种优化算法,并进行对比,分别是 DE 算法, QPSO 算法, DE-QPSO 算法,本次实验设置的最大迭代次数 $T=100$,种群数量为 581,粒子数为 500,缩放因子为 0.6,交叉概率为 0.80,变异概率为 0.05,三种算法在运算过程得到的适应度(本次实验选算法的适应度方差来反应种群中粒子的收敛程度,方差越小则算法的优化效果越好)随着迭代次数的变化如图 7 所示。

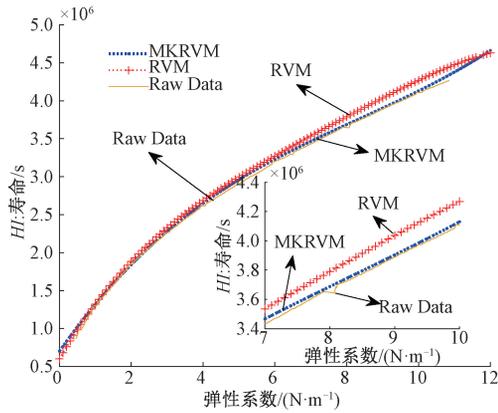


图 8 不同的寿命预测方法对比

Fig. 8 Comparison of different life prediction methods

的绝对误差 error 做出对比, error 定义如式(38)所示。

$$error = \left| \frac{D_{real} - D_{pre}}{D_{real}} \right| \quad (38)$$

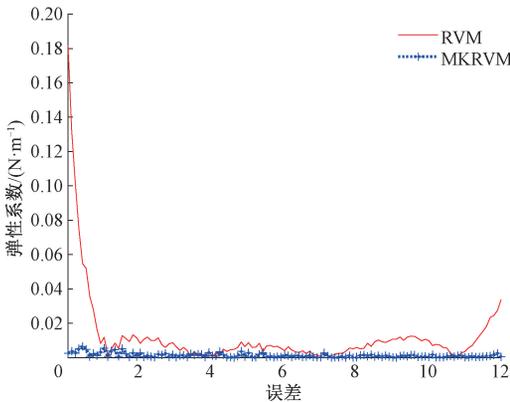


图 9 两种预测算法误差

Fig. 9 Error of two prediction algorithms

从图 8 和 9 可以得到以下结论, MKRVM 算法所预测的开关寿命的绝对误差较小, 比 RVM 算法预测得到的寿命数据更接近于实验所得出的真实数据(图中的原始数据表示去噪之后的数据), 因而采用多核学习的方法得到的预测结果比单核的学习方法得到的结果准确度更高。

一方面从两种方法的预测时间做出对比, 如表 3 所示, MKRVM 算法所用时间为 0.21 s, RVM 算法所用时间为 0.63 s, MKRVM 算法的速度要快于 RVM 算法; 另一方面利用式(29)得到各个方法预测的寿命数据计算健康指标, 结果如表 4 所示, 从表 4 可以看出 MKRVM 预测结果的健康指标为 3.1043×10^6 s, 更接近于原始寿命数据的健康指标 3.0657×10^6 s, RVM 为 3.1961×10^6 s; 综上所述, 通过预测结果的准确度、运行时间以及健康指标三方面的对比, MKRVM 都优于 RVM 算法, 因而本文选择 MKRVM 来对电容式 RF-MEMS 开关进行寿命预测。

表 3 不同预测方法的预测时间

Table 3 Prediction time for different prediction methods

方法	MKRVM	RVM
预测时间/s	0.21	0.63

表 4 HI 数据计算

Table 4 HI data calculations

方法	原始数据	MKRVM	RVM
HI/s	3.0657×10^6	3.1043×10^6	3.1961×10^6

为了进一步表示电容式 RF-MEMS 开关的可靠性, 可以在预测结果的基础上对开关进行剩余使用寿命 RUL (remaining useful life) 的预测, 若能准确地预测出开关的 RUL, 会大幅度减少因为器件损坏而导致系统无法继续正常运行的概率, 减少不必要的经济损失, 增加系统的可靠性。将 MKRVM 预测的某确定弹性系数的开关寿命设为 t_p , 而开关实际已经运行的时间为 t_r , 所以开关的 RUL 可以由式(39)计算。

$$RUL = t_p - t_r \quad (39)$$

通过对电容式 RF-MEMS 开关剩余寿命的预测可以得出当开关的弹性系数在 4~16 N/m 时, 开关的寿命较长, 当选择弹性系数为 10 的开关时, 此时的寿命可以达到 1388 h 左右, 假设当前开关已经运行了 88 h, 那得到开关的 RUL 为 1300 h, 约 54 d, 在继续运行 50 d 以后, 就要及时对开关进行更换来维持系统继续正常运行, 保障系统的可靠性。

6 结论

本文应用 BREMD 方法对实验中获取的电容式 RF-MEMS 开关寿命数据进行去噪处理, 之后采用 DE-QPSO 优化算法生成 MKRVM 的稀疏权重, 并利用 MKRVM 进行开关的寿命预测得到 RUL。通过 MKRVM 与 RVM 算法对比得到 MKRVM 具有更优的学习性能; 在选择优化算法时本文所选用的 DE-QPSO 算法比 DE 算法和 QPSO 算法具有更高的准确性和运算速度, 这些方法也可以应用在其他回归预测的研究中。本文仅仅讨论了弹性系数 K 对电容式 RF-MEMS 开关寿命的影响, 在今后的研究中还会继续研究其他因素对其寿命的影响, 进一步加深对 MEMS 器件可靠性的研究, 使研究更加全面。

参考文献

[1] 郑国旭. 电容式 RF MEMS 开关设计与失效研究[D]. 哈尔滨: 哈尔滨理工大学, 2013.
ZHENG G X. Study on design and failure of capacitive RF MEMS switch [D]. Harbin: Harbin University of Technology, 2013.

[2] 刘若林. MEMS 开关失效机理及 MEMS 开关在微波电路应用中的研究[D]. 成都: 电子科技大学, 2017.

- LIU R L. Failure mechanism of MEMS switch and application of MEMS switch in microwave circuit research in China [D]. Chengdu: University of Electronic Science and Technology, 2017.
- [3] 邵雯雯,惠春,徐爱兰. RF MEMS 开关的桥膜弹性系数计算[J]. 电子元件与材料,2005,24(3):47-51.
SHAO W W, HUI CH, XU AI L. Calculation of bridge membrane elastic coefficient of RF MEMS switch [J]. Electronic Components and Materials, 2005, 24 (3): 47-51.
- [4] 周光亚. RF MEMS 开关可靠性研究[D]. 洛阳:河南科技大学,2013.
ZHOU G Y. Reliability research of RF MEMS switch[D]. Luoyang: Henan University of Science and Technology,2013.
- [5] 吴银锋,万江文,于宁. 介质层充电对电容式 RF MEMS 开关的影响[J]. 传感技术学报,2006(5):1955-1958,1962.
WU Y F, WAN J W, YU N. Influence of dielectric charging on capacitive RF MEMS switch [J]. Journal of Sensing Technology,2006(5):1955-1958,1962.
- [6] 张永华,曹如平,赖宗声. 静电式 RF MEMS 开关的可靠性[J]. 微纳电子技术,2010,47(11):701-707.
ZHANG Y H, CAO R P, LAI Z SH. Reliability of electrostatic RF MEMS switch[J]. Micronanoelectronic Technology, 2010, 47(11):701-707.
- [7] 袁晓林,黄庆安. 电容式 RF 开关介电电荷及相关可靠性模型及模拟[J]. 传感技术学报,2006,19(1):87-92.
YUAN X L, HUANG Q AN. Model of dielectric charge and related reliability of capacitive RF switch [J]. Journal of Sensing Technology,2006,19(1):87-92.
- [8] HUANG J W, WANG Z G. RF MEMS switches based on thermal actuator [J]. Journal of Southeast University (English Edition),2007,23(4):520-523.
- [9] 李全宝,景玉鹏,刘茂哲,等. 电磁驱动 RFMEMS 开关的研究状况[J]. 电子工业专用设备,2007(1):18-20,30.
LI Q B, JING Y P, LIU M ZH, et al. Research status of electromagnetic driving RFMEMS switch [J]. Specialized Equipment for the Electronic Industry, 2007(1):18-20,30.
- [10] CHEN CH W, ZENG T. RF MEMS capacitive switch with Leaky nanodiamond dielectric film [J]. Diamond and Related Materials,2018,20(4):546-550.
- [11] 张朝龙,何怡刚,袁莉芬. 基于 EEMD 和 MKRVM 的锂电池剩余寿命预测方法[J]. 电力系统及其自动化学报,2018,30(7):38-44.
ZHANG CH L, HE Y G, YUAN L F. Prediction method of lithium battery residual life based on EEMD and MKRVM [J]. Power system Journal of Automation, 2018,30(7):38-44.
- [12] WANG T, HE Y G, SHI T C, et al. Transformer health management based on self-powered RFID sensor and multiple kernel RVM [J]. IEEE Transactions on Instrumentation and Measurement, 2018,28(51):40-45.
- [13] HONG K, HUANG H, ZHOU J, et al. A method of real time fault diagnosis for power transformers based on vibration analysis [J]. Measurement Science and Technology, 2015,26(11):50-61
- [14] SHARK L K, SHARK C K. Denoising by optimal fuzzy thresholding in wavelet domain [J]. Electronics Letters, 2000,36(6):581-582.
- [15] DONHON D L, JOHNSTONE I, KERKY G, et al. Wavelet shrinkage: Asymptopia [J]. Journal of the Royal Statistical Society Series B,1995,57(2):301-369.
- [16] CHANG M H, KANG M, PECHT M. Prognostics-based LED qualification using similarity-based statistical measure with RVM regression model [J]. IEEE Transactions on Industrial Electronics, 2017, 64 (7): 5667-5677.
- [17] XU F, MA L, WANG J. A fault diagnosis method based on optimized RVM and information entropy for quadruped robot [C]. China Control Conference, 2016, 62 (6): 6617-6622.
- [18] SU Y, CHI R. Multi-objective particle swarm-differential evolution algorithm [J]. Neural Computing & Applications, 2017,28(2):407-418.
- [19] 吴金文,王宇鹏,周海波. 采用量子粒子群算法耦合差分进化算法优化 BP 神经网络的铣床热误差预测研究[J]. 设计与研究,2018,20(6):105-109.
WU J W, WANG Y P, ZHOU H B. Optimization of BP neural network milling by quantum particle swarm algorithm coupled with differential evolutionary algorithm prediction of bed heat error [J]. Design and Research, 2018,20(6):105-109.
- [20] REHMAN O U, YANG S Y, SHAFI U K. A modified quantum-based particle swarm optimization for engineering inverse problem [J]. International Journal for Computation and Mathematics in Electrical and Electronic Engineering,2017,36(1):170-186.
- [21] 张兰. 量子粒子群算法及其应用[D]. 西安:西北大学,2010.
ZHANG L. Quantum Particle Swarm Algorithm and Its Application [D]. Xi'an: Northwestern University,2010.
- [22] DAS R J, SINGHN K J, TAPAN K G. Estimation of

dimensions for a trapezoidal-shaped steel fin using hybrid differential evolution algorithm [J]. *Neural Computing and Applications*, 2017, 28(7): 1683-1693.

- [23] SU Y, CHI R. Multi-objective particle swarm-differential evolution algorithm [J]. *Neural Computing & Applications*, 2017, 28(2): 407-418.

作者简介



何怡刚, 1992 年于湖南大学获得硕士学位, 1996 年于西安交通大学获得博士学位, 现任合肥工业大学电气与自动化工程学院院长, 主要研究方向为电路理论及其应用, 模拟与混合信号电路测试与故障诊断, 电信号检测, 智能电网, 卫星通信监测和智

能信号处理。

E-mail: 18655136887@163.com

He Yigang received his M. Sc. degree from Hunan University in 1992 and Ph. D. degree from Xi'an Jiaotong

University in 1996. He currently works as the Head of School of Electrical Engineering and Automation, Hefei University of Technology. His main research interests include power electronic circuit theory and its applications, testing and fault diagnosis of analog and mixed-signal circuits, electrical signal detection, smart grid, satellite communication monitoring, and intelligent signal processing.



白月皎, 2017 年于山东交通学院获得学士学位, 现为合肥工业大学硕士研究生, 主要研究方向为 IGBT 或电子元器件的可靠性。

E-mail: 857429407@qq.com

Bai Yuejiao received her B. Sc. degree from Shandong Jiaotong Institute in 2017. Now she is a M. Sc. candidate at Hefei University of Technology. Her main research interests include reliability of IGBT or electronic components.