基于自适应 RVM 的电子系统缓变故障预测方法

范 庚 马登武 张继军 吴明辉

(海军航空工程学院 兵器科学与技术系, 烟台 264001) (海军航空工程学院 科研部, 烟台 264001)

摘 要: 针对电子系统缓变故障的预测问题,提出一种自适应相关向量机(RVM, Relevance Vector Machine)方法. 首先,对反映电子系统性能的参数序列进行相空间重构,建立 RVM 的输入输出对应关系;然后,将嵌入维数和核函数参数作为人工鱼位置,取留一交叉验证(LOOCV, Leave-One-Out Cross-Validation)误差的相反数作为目标函数,利用人工鱼群算法(AFSA, Artificial Fish Swarm Algorithm)实现方法参数的自适应优化选择;最后,通过雷达发射机高压电源与多注速调管的故障预测实验验证了方法的性能. 实验结果表明:该方法在预测精度和预测可靠性方面优于现有方法.

关 键 词: 故障预测; 电子系统; 相关向量机; 自适应优化; 人工鱼群算法; 留一交叉验证

中图分类号: TP 206

文献标识码: A **文 章 编 号**: 1001-5965(2013)10-1319-06

Gradual fault prediction method for electronic system based on adaptive RVM

Fan Geng Ma Dengwu Zhang Jijun

(Department of Ordnance Science and Technology, Naval Aeronautical and Astronautical University, Yantai 264001, China)

Wu Minghui

(Department of Scientific Research, Naval Aeronautical and Astronautical University, Yantai 264001, China)

Abstract: Aiming at gradual fault prediction of electronic system, a method based on adaptive relevance vector machine (RVM) was proposed. Firstly, the phase space of electronic system performance parameter time series was reconstructed, and then the corresponding relationship between the input and the output of RVM was educed. Secondly, the artificial fish swarm algorithm (AFSA) was adopted to realize the adaptive optimization of method parameters, which took the embedding dimension and the RVM kernel parameter as the artificial fish position and took the opposite number of leave-one-out cross-validation (LOOCV) error as the objective function. Lastly, the performance of the proposed method was validated by radar transmitter fault prediction experiment. The experimental results show that the proposed method has better accuracy and reliability than the existed methods.

Key words: fault prediction; electronic system; relevance vector machine; adaptive optimization; artificial fish swarm algorithm; leave-one-out cross-validation

目前,武器装备中电子系统的维修保障问题日益凸显,例如在 F-15 飞机中,航空电子系统的故障数占到全机故障数的 40% 以上,维修工时占到全机维修工时的 1/3 左右. 这是因为[1]:首先,随着武器装备信息化程度的不断提高,部分传统的非电系统被电子系统所取代,电子系统所占比

收稿日期: 2012-07-02; **网络出版时间**: 2013-04-22 10:11

网络出版地址: www.cnki.net/kcms/detail/11.2625.V.20130422.1011.002.html

作者简介: 范 庚(1985-),男,山东临沂人,博士生,meteras@163.com.

例越来越高;其次,在现代战争中,通信、导航、雷达、火力控制、电子对抗等电子系统对武器装备作战性能的影响越来越大;另外,随着电子系统不断渗透到武器系统的核心任务系统,信息化、智能化程度越高的武器装备需要电子系统辅助完成的任务将会越多,因电子系统故障引起的损失也将大大增加.

电子系统在使用过程中因其组成部件性能的逐渐退化往往会导致缓变故障的发生. 这类故障相对于突发故障具有明显的规律性,可通过监测能反映系统性能的特征参数进行预测[1-4],进而实现对电子系统的视情维修. 文献[2-4]分别将灰色模型、最小二乘支持向量机和极端学习机应用于电子系统缓变故障的预测. 这些方法都属于点预测方法,即只给出确切的预测值,而无法给出预测结果可能的波动范围,忽略了预测风险问题. 相关向量机(RVM, Relevance Vector Machine)[5-7]是 M. E. Tipping 提出的一种基于贝叶斯框架的机器学习方法,通过引入概率模型处理预测中的不确定性问题,能够在给出预测值的同时给出其概率分布,在水文预测[8]、电力负荷预测[9]和故障预测[10]等工程领域的应用研究中取得了较好效果.

RVM 用于时间序列预测时,嵌入维数和核参数的选择是影响其预测性能的主要因素. 目前研究中,嵌入维数和核参数的选择主要由研究人员凭主观经验人为地进行选取,缺乏合理依据,不具备推广性. 本文提出一种自适应 RVM 时间序列预测方法,并将其应用于电子系统缓变故障的预测. 首先,对反映电子系统性能的参数序列进行相空间重构,建立 RVM 的输入输出对应关系;然后,将嵌入维数和 RVM 核参数作为人工鱼位置,取留一交叉验证(LOOCV, Leaveone-Out Cross-Validation)误差的相反数作为目标函数,利用人工鱼群算法(AFSA, Artificial Fish Swarm Algorithm)实现方法参数的自适应优化选择;最后,通过雷达发射机高压电源与多注速调管的故障预测实验对方法的性能加以验证.

1 相空间重构

相空间重构的目的是找到 RVM 输入输出之间的对应关系. 对于时间序列$\{x_1,x_2,\cdots,x_l\}$,假设预测目标值x_n与先前的d个目标值$x_{n-1},x_{n-2},\cdots,x_{n-d}$之间存在非线性映射关系:

$$\begin{aligned} x_n &= \zeta(x_{n-1},x_{n-2},\cdots,x_{n-d}) \\ n &= d+1,d+2,\cdots,l \end{aligned} \tag{1}$$

式中,d为嵌入维数;$\zeta(\cdot)$为非线性映射函数. 可以得到 RVM 的训练样本集:

$$\boldsymbol{X}=\begin{bmatrix}\boldsymbol{x}_1\\ \boldsymbol{x}_2\\ \vdots\\ \boldsymbol{x}_N\end{bmatrix}=\begin{bmatrix}x_1 & x_2 & \cdots & x_d\\ x_2 & x_3 & \cdots & x_{d+1}\\ \vdots & \vdots & \ddots & \vdots\\ x_N & x_{N+1} & \cdots & x_{d+N-1}\end{bmatrix}$$

$$\boldsymbol{t}=\begin{bmatrix}t_1\\ t_2\\ \vdots\\ t_N\end{bmatrix}=\begin{bmatrix}x_{d+1}\\ x_{d+2}\\ \vdots\\ x_{d+N}\end{bmatrix}$$

式中,$\boldsymbol{X}$为输入样本;$\boldsymbol{t}$为输出样本;$N=l-d$为训练样本数目. 利用该训练样本集训练 RVM,则可以使训练后的 RVM 逼近$\zeta(\cdot)$,进而实现对$\{x_1,x_2,\cdots,x_l\}$后续数据的预测.

2 RVM 回归原理

假定目标值是独立的,且来自带噪声的模型:

$$t_i = y(\boldsymbol{x}_i,\boldsymbol{\omega}) + \varepsilon_i \tag{2}$$

式中,样本噪声ε_i服从均值为 0、方差为σ^2的高斯分布,则$p(t_i|\boldsymbol{x}_i)=N(t_i|y(\boldsymbol{x}_i,\boldsymbol{\omega}),\sigma^2)$. RVM 模型输出可以表示为

$$y(\boldsymbol{x},\boldsymbol{\omega}) = \sum_{i=1}^{N}\omega_i k(\boldsymbol{x},\boldsymbol{x}_i) + \omega_0 \tag{3}$$

式中,$k(\cdot,\cdot)$为核函数,本文选择高斯核函数作为 RVM 核函数,其表达式为

$$k(x,y) = \exp\left(-\frac{\|x-y\|^2}{\gamma^2}\right) \tag{4}$$

γ为高斯核宽度;$\boldsymbol{\omega}=[\omega_0,\omega_1,\cdots,\omega_N]^{\mathrm{T}}$为模型的权值向量;引入超参数$\beta=\frac{1}{\sigma^2}$,则相应的训练样本集的似然函数为

$$p(\boldsymbol{t}\mid\boldsymbol{\omega},\beta) = \left(\frac{\beta}{2\pi}\right)^{-N/2}\exp\left\{-\frac{\beta}{2}\|\boldsymbol{t}-\boldsymbol{\Phi}\boldsymbol{\omega}\|^2\right\} \tag{5}$$

式中,$\boldsymbol{\Phi}=[\boldsymbol{\phi}(\boldsymbol{x}_1),\boldsymbol{\phi}(\boldsymbol{x}_2),\cdots,\boldsymbol{\phi}(\boldsymbol{x}_N)]^{\mathrm{T}}$,$\boldsymbol{\phi}(\boldsymbol{x}_i)=[1,k(\boldsymbol{x}_i,\boldsymbol{x}_1),\cdots,k(\boldsymbol{x}_i,\boldsymbol{x}_N)]^{\mathrm{T}}$.

假设$\omega_j(j=0,1,\cdots,N)$服从均值为 0,方差为α_j^{-1}的高斯分布,则$\boldsymbol{\omega}$的先验条件概率分布为

$$p(\boldsymbol{\omega}\mid\boldsymbol{\alpha}) = \prod_{i=0}^{N}N(\omega_i\mid 0,\alpha_i^{-1}) \tag{6}$$

式中,$\boldsymbol{\alpha}=[\alpha_0,\alpha_1,\cdots,\alpha_N]^{\mathrm{T}}$. 根据贝叶斯公式,利用样本似然函数式(5)和$\boldsymbol{\omega}$先验分布式(6)可以得到$\boldsymbol{\omega}$的后验分布计算公式:

$$p(\boldsymbol{\omega}\mid\boldsymbol{t},\boldsymbol{\alpha},\beta) = \frac{p(\boldsymbol{t}\mid\boldsymbol{\omega},\beta)p(\boldsymbol{\omega}\mid\boldsymbol{\alpha})}{p(\boldsymbol{t}\mid\boldsymbol{\alpha},\beta)} \tag{7}$$

由于$p(\boldsymbol{t}|\boldsymbol{\omega},\beta)$和$p(\boldsymbol{\omega}|\boldsymbol{\alpha})$均为高斯分布,而

$p(\boldsymbol{t}|\boldsymbol{\alpha},\beta)$中不含 $\boldsymbol{\omega}$,可看作归一化系数. 则 $\boldsymbol{\omega}$ 的后验分布可进一步表示为

$$p(\boldsymbol{t}\mid\boldsymbol{\alpha},\beta)=N(\boldsymbol{\omega}\mid\boldsymbol{\mu},\boldsymbol{\Sigma}) \tag{8}$$

后验协方差矩阵和均值分别为

$$\left.\begin{aligned}\boldsymbol{\Sigma}&=(\beta\boldsymbol{\Phi}^{\mathrm{T}}\boldsymbol{\Phi}+\boldsymbol{A})^{-1}\\ \boldsymbol{\mu}&=\beta\boldsymbol{\Sigma}\boldsymbol{\Phi}^{\mathrm{T}}\boldsymbol{t}\end{aligned}\right\} \tag{9}$$

式中,$\boldsymbol{A}=\mathrm{diag}(\alpha_0,\alpha_1,\cdots,\alpha_N)$. 超参数 $\boldsymbol{\alpha}$ 和 β 直接影响 $\boldsymbol{\omega}$ 的后验分布,需对其优化以得到 $\boldsymbol{\omega}$ 的最大后验分布. 通过最大化边缘似然函数 $p(\boldsymbol{t}|\boldsymbol{\alpha},\beta)$ 实现超参数的优化. 将 $p(\boldsymbol{t}|\boldsymbol{\alpha},\beta)$ 取负对数得到目标函数,将目标函数对超参数 $\alpha_j(j=0,1,\cdots,N)$ 和 β 求偏导并令导数式为 0,得到以下迭代公式:

$$\left.\begin{aligned}\alpha_j&=\frac{\gamma_j}{\mu_j^2}\\ \beta&=\frac{N-\sum_j\gamma_j}{\|\boldsymbol{t}-\boldsymbol{\Phi}\boldsymbol{\mu}\|^2}\\ j&=0,1,\cdots,N\end{aligned}\right\} \tag{10}$$

式中,μ_j 为权值后验均值向量 $\boldsymbol{\mu}$ 的第 j 个元素;$\gamma_j\equiv1-\alpha_j\Sigma_{jj}$,$\Sigma_{jj}$为后验权协方差矩阵 $\boldsymbol{\Sigma}$ 的第 j 个对角元素. 式(9)、式(10)依次进行迭代计算,直到所有参数都收敛或达到最大训练次数时为止.

通过最大似然方法得到超参数 $\boldsymbol{\alpha}_{\mathrm{MP}}$和噪声方差 σ^2_{MP}. 若给定输入值 $\boldsymbol{x}_*$,则相应输出的概率分布为

$$p(t_*\mid\boldsymbol{t},\boldsymbol{\alpha}_{\mathrm{MP}},\sigma^2_{\mathrm{MP}})=\int p(t_*\mid\boldsymbol{\omega},\sigma^2_{\mathrm{MP}})p(\boldsymbol{\omega}\mid\boldsymbol{t},\boldsymbol{\alpha}_{\mathrm{MP}},\sigma^2_{\mathrm{MP}})\mathrm{d}\boldsymbol{\omega} \tag{11}$$

式(11)服从高斯分布,即

$$p(t_*\mid\boldsymbol{t},\boldsymbol{\alpha}_{\mathrm{MP}},\sigma^2_{\mathrm{MP}})=N(t_*\mid y_*,\sigma^2_*) \tag{12}$$

其中,预测均值和方差分别为

$$\left.\begin{aligned}y_*&=\boldsymbol{\mu}^{\mathrm{T}}\boldsymbol{\phi}(\boldsymbol{x}_*)\\ \sigma^2_*&=\sigma^2_{\mathrm{MP}}+\boldsymbol{\phi}(\boldsymbol{x}_*)^{\mathrm{T}}\boldsymbol{\Sigma}\boldsymbol{\phi}(\boldsymbol{x}_*)\end{aligned}\right\} \tag{13}$$

由式(13)可以看出,RVM 回归预测的方差由两部分组成:一是数据噪声引起的预测方差;二是模型权值估计的不确定性引起的预测方差. 因此,RVM 回归预测结果反映了预测过程中的不确定性. 根据预测均值和方差可以计算预测值的概率密度和分布[11]:

$$f(t_*)=\frac{1}{\sqrt{2\pi}\sigma_*}\exp\left[-\frac{(t_*-y_*)^2}{2\sigma^2_*}\right] \tag{14}$$

$$F(t_*)=\frac{1}{\sqrt{2\pi}\sigma_*}\int_{-\infty}^{t_*}-\frac{(q-y_*)^2}{2\sigma^2_*}\mathrm{d}q \tag{15}$$

3　基于 AFSA 的参数自适应优化

LOOCV 的基本原理[12]为:假设训练样本集的样本数目为 N,每次选取不同的 1 个样本作为测试集,其余 $N-1$ 个样本作为训练集训练模型并进行测试,得到测试误差;取所有测试误差的平均值作为最终估计误差. 可以看出,LOOCV 误差能够直接反映 RVM 泛化能力的优劣,本文将 LOOCV 误差最小作为参数优化的目标.

遗传算法(GA, Genetic Algorithm)和粒子群优化(PSO, Particle Swarm Optimization)算法是目前模型参数优化中较为常用的两种智能优化算法. GA 有结构复杂、计算量较大、收敛速度较慢的缺点;PSO 算法虽结构简单,运算量小,但由于粒子的记忆性及对全局最优位置的收敛性,导致局部搜索能力较差,容易陷入早熟收敛,算法精度低. AFSA[13]是模拟鱼群行为而提出的一种智能优化方法,主要利用鱼的觅食、聚群和追尾行为,通过各人工鱼个体的局部寻优最终实现全局寻优的目的. 该算法具有良好的克服局部极值、获得全局极值的能力,而且该算法具有 GA 和 PSO 算法不具备的特点,如使用灵活、收敛速度快等[14]. 因此,以 LOOCV 误差最小作为优化目标,利用 AFSA 自适应优化选择嵌入维数和 RVM 核参数,可在提高 RVM 泛化能力的基础上,有效简化模型参数的优化选择过程. AFSA 的计算流程见图 1.

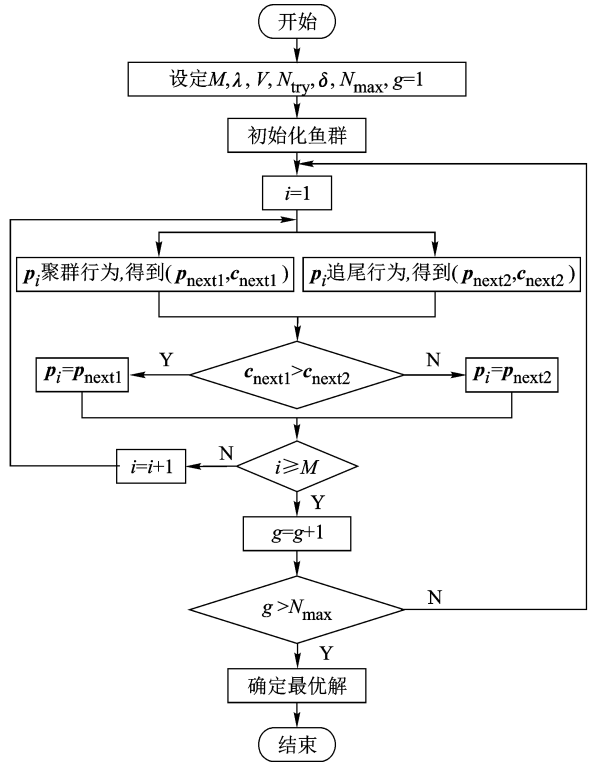

图 1　AFSA 流程图

AFSA 的具体实现过程如下:

1) 鱼群初始化. 设置当前迭代次数 $g=1$,鱼群大小 M,在嵌入维数 d 和高斯核宽度 γ 的取值

范围内随机初始化每条人工鱼的位置 $\boldsymbol{p}_i=[d_i\ \gamma_i]$，$i=1,2,\cdots,M$，人工鱼移动的最大步长 λ，人工鱼的感知距离 V，觅食行为尝试的最大次数 N_{try}，拥挤度因子 δ，最大迭代次数 $N_{\max}$.

2）觅食行为. 以 LOOCV 误差的相反数作为目标函数，即食物浓度函数. 设人工鱼的当前位置为 $\boldsymbol{p}_i$，该位置食物浓度为 c_i，在其感知范围内随机选择一个状态 $\boldsymbol{p}_j$，计算该位置的食物浓度为 c_j，如果 $c_i<c_j$，则向该方向前进一步；反之则重新选取状态 $\boldsymbol{p}_j$，判断是否满足移动条件，不能满足则继续重复该过程，直至达到尝试的最大次数 N_{try}. 若人工鱼的尝试次数达到 N_{try} 仍不能满足移动条件，则在感知范围内随机移动一步，即执行随机操作.

3）聚群行为. 设人工鱼的当前位置为 $\boldsymbol{p}_i$，该位置食物浓度为 c_i. 探索其感知距离内的鱼的数目 n_f，计算其中心位置 $\boldsymbol{p}_c$ 及食物浓度 c_c. 如果 $c_c/n_f>\delta c_i$，即表明中心位置有较多的食物并且不太拥挤，则朝中心位置 $\boldsymbol{p}_c$ 方向前进一步；否则执行觅食行为.

4）追尾行为. 设人工鱼的当前位置为 $\boldsymbol{p}_i$，该位置食物浓度为 c_i. 探索其感知距离内食物浓度最大的人工鱼位置为 $\boldsymbol{p}_{\max}$，其食物浓度为 $c_{\max}$. 以 $\boldsymbol{p}_{\max}$ 为中心探索 $\boldsymbol{p}_{\max}$ 感知距离内的人工鱼的数目记为 n_f. 如果 $c_{\max}/n_f>\delta c_i$，表明 $\boldsymbol{p}_{\max}$ 处有较多的食物且不太拥挤，则向 $\boldsymbol{p}_{\max}$ 方向前进一步；否则执行觅食行为.

4 故障预测实验

4.1 实验说明

高压电源与多注速调管作为雷达发射机的核心部件，其状态直接关系到雷达发射机的可靠性. 本文实验数据来源于文献[2]中雷达发射机高压电源与多注速调管在等时间间隔采样条件下采集的40个纹波电压数据与阴极电流数据(见表1和表2).

对于电子系统的缓变故障预测问题，由于采样数据间隔较大，因此主要研究其短期预测[2]. 已有文献中主要以一步预测为主[3,15-17]，因此，本文以数据中的前30个数据作为建模数据，最后10个数据作为测试数据，进行一步预测实验. 参数优化时，参数设置如下：人工鱼数目设为20，人工鱼移动的最大步长设为0.01，人工鱼的感知距离设为1，觅食行为尝试的最大次数设为50，拥挤度因子设为0.618，最大迭代次数设为50，嵌入维数和核参数的取值区间分别为[1,10]和[0.001,1 000].

表1 纹波电压数据 V

序号	1	2	3	4	5
数值	19.46	19.88	20.35	20.75	21.25
序号	6	7	8	9	10
数值	21.75	22.26	22.81	23.37	23.95
序号	11	12	13	14	15
数值	24.58	25.23	25.94	26.65	27.38
序号	16	17	18	19	20
数值	28.17	29.00	29.92	30.85	31.82
序号	21	22	23	24	25
数值	32.94	34.08	35.31	36.63	38.04
序号	26	27	28	29	30
数值	39.63	41.00	43.10	44.98	47.07
序号	31	32	33	34	35
数值	49.48	52.36	54.95	58.10	61.37
序号	36	37	38	39	40
数值	66.00	70.25	76.00	82.80	89.87

表2 阴极电流数据 mA

序号	1	2	3	4	5
数值	493.1	502.6	513.9	523.5	530.1
序号	6	7	8	9	10
数值	538.9	550.7	563.1	575.0	584.1
序号	11	12	13	14	15
数值	590.2	596.7	605.5	615.0	622.9
序号	16	17	18	19	20
数值	630.1	638.4	648.5	658.9	668.4
序号	21	22	23	24	25
数值	676.9	684.0	689.3	693.9	699.2
序号	26	27	28	29	30
数值	704.7	709.9	715.7	722.7	730.5
序号	31	32	33	34	35
数值	738.6	745.5	750.4	755.5	760.4
序号	36	37	38	39	40
数值	764.1	768.2	772.3	776.5	782.3

4.2 参数优化结果

本文方法的参数自适应优化迭代过程如图2所示. 从图中可以看出：纹波电压预测时，只需8次迭代就能得到相对最优的嵌入维数和核参数；阴极电流预测时，只需6次迭代就能得到相对最优的嵌入维数和核参数. 这说明该方法具有良好的收敛性能. 参数优化结果为：纹波电压预测时，嵌入维数 $d=7$，高斯核宽度 $\gamma=54.52$；阴极电流预测时，嵌入维数 $d=6$，高斯核宽度 $\gamma=47.97$.

4.3 确定性预测结果

将本文方法与文献[2]和文献[3]的方法进

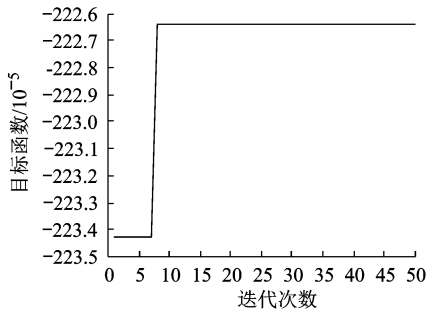

a　纹波电压预测时的参数优化

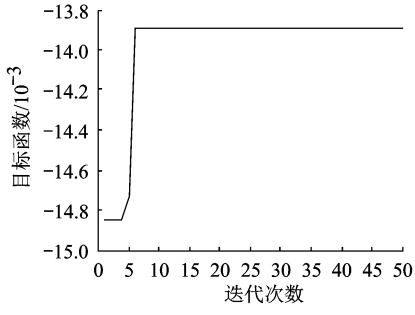

b　阴极电流预测时的参数优化

图 2　参数自适应优化迭代过程

行对比,各方法预测结果如表 3 所示. 纹波电压预测时,本文方法的平均相对预测误差比文献[2]降低了 6.3%,比文献[3]中的两种方法分别降低了 2.6% 和 1.6%;阴极电流预测时,本文方法的预测精度与文献[3]的方法相当,优于文献[2]的方法,平均相对预测误差降低了 1.4%.

表 3　预测结果

预测方法	纹波电压平均预测误差		阴极电流平均预测误差	
	绝对值/V	相对值/%	绝对值/mA	相对值/%
PSOAGM[2]	5.1896	6.7796	13.9544	1.8094
CVLSSVM[3]	2.4203	3.1221	1.8346	0.2425
BLSSVM[3]	1.5911	2.0937	3.6099	0.4725
AFSARVM	0.3568	0.4879	3.0278	0.4017

4.4　预测值的概率分布

以对 31 号阴极电流值预测为例,根据式(14)、式(15)分别计算预测值的概率密度和概率分布,如图 3 所示. 从图中可以看出,预测均值为 733.43 mA,小于实际值 738.60 mA. 因此,如果仅根据确切的预测值即预测均值判断预测对象未来的健康状况,有可能出现预测均值小于故障阈值,而实际值已经超出故障阈值的情况,不利于维修决策.

计算各预测值置信度 90%,95% 和 97% 的置信上界,结果如图 4 所示. 可以看出,阴极电流的实际值均包含在置信度 97% 的置信区间内. 因此,结合预测值的置信区间对电子系统缓变故障进行预测得出的结果更加可靠. 虽然该方法相对保守,但对于可靠性要求较高的武器装备而言,这种相对保守的预测具有重要的工程应用价值.

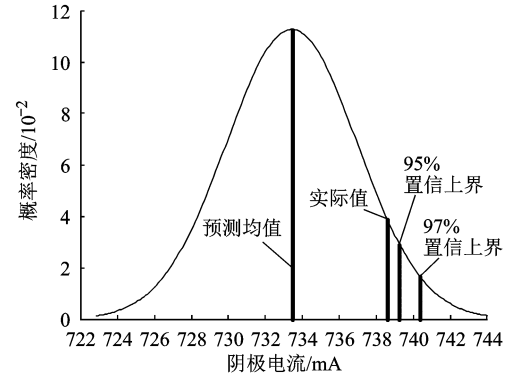

a　概率密度

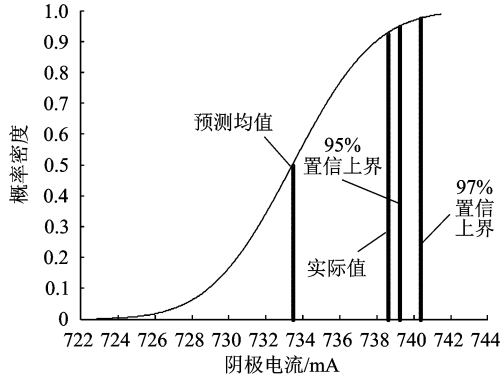

b　概率分布

图 3　31 号阴极电流预测值的概率密度与概率分布

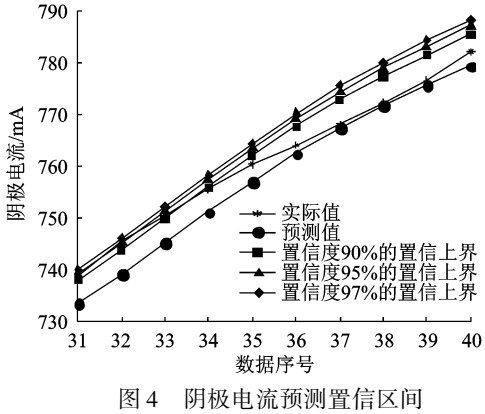

图 4　阴极电流预测置信区间

5　结　论

在信息化技术的推动下,电子系统在武器装备中的作用和影响日益突出,其维修保障问题也日益凸显. 通过对电子系统的缓变故障进行预测,进而实施视情维修,能够在有效降低装备故障风险的同时节约维修保障资源、降低维修保障费用. 本文提出一种基于自适应 RVM 的电子系统缓变故障预测方法,该方法的优势体现在:

1) 通过 LOOCV 和 AFSA 相结合的方法实现了参数的自适应优化选择,克服了人为凭工程经验选取嵌入维数和核参数的不可推广性,避免了随机设置的盲目性以及因此引起的过大预测误

差. 实验结果表明,相比已有方法,本文方法具有较高的预测精度.

2) 利用 RVM 概率式输出的优势,在给出预测值的同时给出其置信区间. 结合预测值的置信区间对电子系统未来健康状况进行判断能够有效避免仅根据预测值进行判断导致的不可靠性.

本文方法的不足在于:由于 LOOCV 的计算复杂度较高,而 AFSA 计算过程中需多次调用 LOOCV 过程,因此该方法对于实时性要求较低的电子系统缓变故障的预测适用性较好,对于实时性要求较高的在线预测问题则有待进一步研究.

参考文献 (References)

[1] 景博,黄以锋,张建业. 航空电子系统故障预测与健康管理技术现状与发展[J]. 空军工程大学学报:自然科学版,2010,11(6):1-6
Jing Bo,Huang Yifeng,Zhang Jianye. Status and perspectives of prognostics and health management technology of avionics system [J]. Journal of Air Force Engineering University:Natural Science Edition,2010,11(6):1-6(in Chinese)

[2] 许丽佳. 电子系统的故障预测与健康管理技术研究[D]. 成都:电子科技大学自动化学院,2005
Xu Lijia. Study on fault prognostic and health management for electronic system [D]. Chengdu:Automation Engineering Institute,University of Electronic Science and Technology of China,2005(in Chinese)

[3] 张弦,王宏力,张金生,等. 状态时间序列预测的贝叶斯最小二乘支持向量机方法[J]. 西安交通大学学报,2010,44(10):42-46
Zhang Xian,Wang Hongli,Zhang Jinsheng,et al. A least squares support vector machine for condition time series prediction based on Bayesian evidence framework [J]. Journal of Xi'an Jiaotong University,2010,44(10):42-46(in Chinese)

[4] 张弦,王宏力. 局域极端学习机及其在状态在线监测中的应用[J]. 上海交通大学学报,2011,45(2):236-240
Zhang Xian,Wang Hongli. Local extreme learning machine and its application to condition online monitoring [J]. Journal of Shanghai Jiaotong University,2011,45(2):236-240(in Chinese)

[5] Tipping M E. The relevance vector machine [C]//Advances in Neural Information Processing Systems 12. Cambridge: MIT Press,2000:652-658

[6] Tipping M E. Sparse Bayesian learning and the relevance vector machine [J]. Journal of Machine Learning Research,2001,1(3):211-244

[7] Tipping M E,Faul A C. Fast marginal likelihood maximisation for sparse Bayesian models [C]//Proc of the Ninth International Workshop on Artificial Intelligence and Statistics. Key West,Florida,USA:[s. n.],2003:1-13

[8] 仕玉治,彭勇,周惠成. 基于相关向量机的中长期径流预报模型研究[J]. 大连理工大学学报,2012,52(1):79-84
Shi Yuzhi,Peng Yong,Zhou Huicheng. Research on mid-and long-term runoff forecast model with relevance vector machine [J]. Journal of Dalian University of Technology,2012,52(1):79-84(in Chinese)

[9] 黄帅栋,卫志农,高宗和,等. 基于非负矩阵分解的相关向量机短期负荷预测模型[J]. 电力系统自动化,2012,36(11):62-66
Huang Shuaidong,Wei Zhinong,Gao Zonghe,et al. A short-term load forecasting model based on relevance vector machine with nonnegative matrix factorization [J]. Automation of Electric Power Systems,2012,36(11):62-66(in Chinese)

[10] Goebel K,Saha B,Saxena A. A comparison of three data-driven techniques for prognostics [C]// Proc of the 62 nd Meeting of the Society For Machinery Failure Prevention Technology (MFPT). Virginia Beach,Virginia,USA:[s. n.],2008:119-131

[11] 盛骤,谢式千,潘承毅. 概率论与数理统计[M]. 北京:高等教育出版社,1989:53-55
Sheng Zhou,Xie Shiqian,Pan Chengyi. Probability and mathematical statistics [M]. Beijing:Higher Education Press,1989:53-55(in Chinese)

[12] Refaeilzadeh P,Tang L,Liu H. Encyclopedia of database systems:cross-validation [M]. Ozsu M T,Liu L. US:Springer,2009:532-538

[13] 李晓磊,邵之江,钱积新. 一种基于动物自治体的寻优模式:鱼群算法[J]. 系统工程理论与实践,2002(11):32-38
Li Xiaolei,Shao Zhijiang,Qian Jixin. An optimizing method based on autonomous animats:fish-swarm algorithm [J]. Systems Engineering—Theory & Practice,2002(11):32-38(in Chinese)

[14] 俞洋,殷志锋,田亚菲. 基于自适应人工鱼群算法的多用户检测器[J]. 电子与信息学报,2007,29(1):121-124
Yu Yang,Yin Zhifeng,Tian Yafei. Multiuser detector based on adaptive artificial fish school algorithm [J]. Journal of Electronics & Information Technology,2007,29(1):121-124(in Chinese)

[15] 何英,周东华,俞容. 一种基于性能退化数据的电子设备缓变故障预报方法[J]. 仪器仪表学报,2008,29(7):1526-1529
He Ying,Zhou Donghua,Yu Rong. Gradual failure prediction of electronic equipment based on performance degradation data [J]. Chinese Journal of Scientific Instrument,2008,29(7):1526-1529(in Chinese)

[16] 姜媛媛,王友仁,崔江,等. 基于 LS-SVM 的电力电子电路故障预测方法[J]. 电机与控制学报,2011,15(8):64-68
Jiang Yuanyuan,Wang Youren,Cui Jiang,et al. Research on fault prediction method of power electronic circuits based on least squares support vector machine [J]. Electric Machines and Control,2011,15(8):64-68(in Chinese)

[17] 薛辉辉,肖明清,段军峰. 基于杂合支持向量回归机的电子装备故障预测[J]. 计算机工程,2012,38(8):283-286
Xue Huihui,Xiao Mingqing,Duan Junfeng. Fault prediction for electronic equipment based on hybrid support vector regression [J]. Computer Engineering,2012,38(8):283-286(in Chinese)

(编 辑:娄 嘉)