

doi: 10.7690/bgzdh.2018.10.013

# ABC 算法优化 SVR 的磨损故障预测模型

邓建球<sup>1</sup>, 赵建忠<sup>1</sup>, 陈洪<sup>2</sup>, 丛林虎<sup>1</sup>

(1. 海军航空大学兵器科学与技术系, 山东 烟台 264001;

2. 中国船舶重工集团公司第七一三研究所第九研究室, 郑州 450015)

**摘要:** 为了提高故障预测的精度, 针对支持向量回归(support vector machine for regression, SVR)参数选择困难的问题, 提出一种采用人工蜂群(artificial bee colony, ABC)算法优化(SVR)的故障预测模型(ABC-SVR)。该模型先对样本数据进行重构, 然后将故障预测误差(适应度)作为优化目标, 通过 ABC 算法寻优找到最优的 SVR 参数, 建立故障预测模型。最后通过实例仿真验证了模型的优越性。仿真结果表明: ABC-SVR 模型有效解决了 SVR 参数选择难题, 能够更加准确地表现故障变化规律, 提高了故障预测精度。

**关键词:** 磨损故障; 人工蜂群优化算法; 支持向量回归; 预测模型

**中图分类号:** TP18 **文献标志码:** A

## Wear Faults Prediction Model Based on SVR Optimized by ABC

Deng Jianqiu<sup>1</sup>, Zhao Jianzhong<sup>1</sup>, Chen Hong<sup>2</sup>, Cong Linhu<sup>1</sup>

(1. Department of Ordnance Science &amp; Technology, Navy Aeronautical University, Yantai 264001, China;

2. The Ninth Research Laboratory, No. 713 Research Institute, China Shipbuilding Industry Corporation, Zhengzhou 450015, China)

**Abstract:** In order to improve the prediction accuracy of wear faults, we propose a wear faults prediction model(ABC-SVR), which is based on support vector machine for regression (SVR) optimized by artificial bee colony(ABC) algorithm and aims at the parameter optimization issue in regard to support vector machine for regression. The model reconstructs the time series of wear faults according to chaos theory, and then takes the wear faults prediction accuracy as the optimization objective; it finds the optimal SVR parameters by ABC algorithm, and builds prediction model of wear faults. Finally, we use simulative contrasting experiment to test the performance of the model. Simulation results show that compared with other models in the experiment, ABC-SVR solves SVR parameter optimization problem, and can describe the complicated change rules of wear faults, as well as improves the accuracy of wear faults prediction.

**Keywords:** wear faults; artificial bee colony; support vector machine for regression; prediction model

## 0 引言

SVR 是在统计学习理论的基础上发展起来的一种新的通用学习方法, 通过在高维空间中构造线性决策函数来实现线性回归, 用核函数代替线性方程中的线性项来实现非线性回归, 适用于对有限样本数据的回归分析, 已被广泛用于数据分类、预测等领域。但在使用 SVR 进行预测的过程中, 它的不敏感损失函数参数、惩罚系数、核函数及其参数等的选择对预测结果有很大的影响<sup>[1]</sup>。目前常用遗传算法、粒子群优化算法等对 SVR 预测模型的参数进行优化, 但这些优化算法在寻优过程中常常不同程度地陷入局部最优, 难以达到理想的预测效果<sup>[2-3]</sup>。人工蜂群算法(artificial bee colony, ABC)是由 Karaboga 于 2005 年提出的一种新的基于群智能的全局优化算法。其直观背景来源于蜂群的采蜜行为,

蜜蜂根据各自的分工进行不同的活动, 并实现蜂群信息的共享和交流, 解决了扩展新解域与已知解域之间进行精细搜索的矛盾, 在很大程度上避免了陷入局部最优解问题, 从而找到问题的最优解<sup>[4-5]</sup>。因此, 笔者提出一种基于支持向量机回归和人工蜂群优化算法的故障预测方法, 以提高故障预测的准确性。

## 1 人工蜂群算法描述

人工蜂群算法的原理是模拟实际蜜蜂的采蜜机制。它将人工蜂群分为观察蜂、采蜜蜂和侦察蜂 3 类, 整个蜂群的目标是寻找花蜜量最大的蜜源。采蜜蜂利用先前的蜜源信息寻找新的蜜源并与观察蜂分享蜜源信息; 观察蜂在蜂房中等待并依据采蜜蜂分享的信息寻找新的蜜源; 侦察蜂的任务是在蜂房附近随机寻找一个新的有价值的蜜源。在 ABC 算法中, 食物源(蜜源)的位置用解空间中的点来替代,

收稿日期: 2018-06-22; 修回日期: 2018-07-05

作者简介: 邓建球(1974—), 男, 湖南人, 博士, 副教授, 从事军械装备保障和信息研究。

蜜蜂采蜜(寻找食物源)的过程也就是搜寻最优解的过程。每个蜜源的位置代表问题的一个可行解,蜜源的花蜜量对应于相应的解的适应度,寻找并采集蜜源的速度对应问题求解的速度<sup>[6-8]</sup>。

假设 ABC 算法包含  $S$  个初始解,其中  $S$  为食物源数目。每个解  $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{id})$  为一个  $d$  维的向量 ( $i=1, 2, \dots, S$ ,  $d$  为优化参数的个数)。然后,观察蜂、采蜜蜂和侦察蜂开始进行循环搜索,循环次数为 MCN。先由观察蜂对相应的食物源(可行解)进行一次邻域搜索,当观察蜂寻找到的食物源(可行解)的花蜜数量(解的适应度)优于之前时,就用新的食物源位置(可行解)替代原来的食物源位置,否则食物源位置保持不变。当所有的观察蜂完成搜索之后,观察蜂跳摆尾舞与采蜜蜂共享蜜源信息。采蜜蜂依据得到的蜜源信息在一定的概率条件下选择食物源。花蜜量越大(适应度越优)的食物源(可行解),被选择的概率越大。当采蜜蜂选中食物源后,也要进行一次邻域搜索,然后把它搜索的结果与观察蜂进行比较,当采蜜蜂的搜索解优于观察蜂的解时,更新可行解,即替换原观察蜂的解,完成角色互换;反之,保留有观察蜂的解。ABC 算法求解的过程,就是通过反复搜索可行解来最终找到最优解的过程。

观察蜂和采蜜蜂按照式(1)进行邻域搜索来完成蜜源(食物源)位置的更新<sup>[9]</sup>:

$$v_{ij} = x_{ij} + r_{ij}(x_{ij} - x_{kj}) \quad (1)$$

式中:  $j \in \{1, 2, \dots, d\}$ ,  $k \in \{1, 2, \dots, S\}$ ,  $k$  为随机数,且  $k \neq i$ ;  $r_{ij}$  为  $[-1, 1]$  之间的随机数,决定着  $\mathbf{x}_i$  领域的大小。随着搜索次数的增加,邻域的范围会逐渐减小,即搜索的范围不断缩小。这样有助于减少获得最优解的计算时间和提高算法精度。

采蜜蜂按照概率  $p_i$  对第  $i$  个食物源进行选择,当对函数最大值寻优时,  $p_i$  依据式(2)进行确定:

$$p_i = \frac{fit_i}{\sum_{k=1}^S fit_k} \quad (2)$$

式中  $fit_i$  为第  $i$  个解的适应度(函数值),代表第  $i$  个食物源的花蜜数量。显然,当适应度越大时,相对应的食物源被选择的概率越大。当对函数最小值寻优时,则  $p_i$  依据下式进行确定:

$$p_i = 1 - \frac{fit_i}{\sum_{k=1}^S fit_k} \quad (3)$$

此外, ABC 算法中的控制参数 limit, 表示某个

可行解被更新的次数<sup>[10]</sup>。在寻优过程中,如果某个可行解连续经过 limit 次循环之后仍然没有被更新,此时这个解陷入了局部最优,与这个解相对应的观察蜂也转变为侦察蜂,这个食物源位置(可行解)就要被放弃。假设被放弃的解是  $\mathbf{x}_i$ , 则由侦察蜂通过下式随机产生一个新的解来代替  $\mathbf{x}_i$ 。

$$x_{ij} = \min_j x_{ij} + \text{rand}(0, 1) \left( \max_j x_{ij} - \min_j x_{ij} \right) \quad (4)$$

式中  $j \in \{1, 2, \dots, d\}$ ,  $x_{ij}$  为向量  $\mathbf{x}_i$  的第  $j$  个元素。

## 2 ABC 算法优化的 SVR 故障预测模型

根据支持向量机(support vector machine, SVM)的构造原理<sup>[11-13]</sup>可知:

支持向量回归模型是对目标函数求极值,可通过下式表示:

$$Q(\omega) = \frac{1}{2} \|\omega\|^2 + CR_{\text{emp}}(f) \quad (5)$$

式中  $R_{\text{emp}}(f)$  为损失函数。笔者引入  $\varepsilon$ -不敏感损失函数,有利于保持对偶变量的稀疏性,同时确保可靠泛化界的优化和全局最小解的存在。此时,式(5)可表示为:

$$\min \frac{1}{2} \|\omega\|^2$$

s. t.

$$y_i - (\mathbf{w} \cdot \mathbf{X}_i) - b \leq \varepsilon, (\mathbf{w} \cdot \mathbf{X}_i) - y_i + b \leq \varepsilon \quad (6)$$

由于上述条件很难完全达到,笔者再引入松弛因子和  $\xi \geq 0$  和  $\xi^* \geq 0$ , 用来表示允许拟合误差的大小。式(6)的优化问题则可表示为:

$$\begin{aligned} \min \quad & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*), \\ \text{s. t.} \quad & y_i - (\mathbf{w} \cdot \mathbf{X}_i) - b \leq \varepsilon + \xi_i \\ & (\mathbf{w} \cdot \mathbf{X}_i) - y_i + b \leq \varepsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0, \quad i = 1, 2, \dots, n \end{aligned} \quad (7)$$

式中常数  $C > 0$ , 为惩罚系数。

引入 Lagrange 函数

$$\begin{aligned} L(\mathbf{w}, \xi_i, \xi_i^*) = & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - \\ & y_i + (\mathbf{w} \cdot \mathbf{X}_i) + b) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + y_i - \\ & (\mathbf{w} \cdot \mathbf{X}_i) - b) - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*) \end{aligned} \quad (8)$$

式中,  $\alpha_i^*$  和  $\alpha_i$  为 Lagrange 因子。式(7)的优化问题可用其对偶形式来表示:

$$\begin{aligned} \min_{\alpha^{(i)} \in R^{2n}} & \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) (X_i \cdot X_j) + \\ & \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) - \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*), \\ \text{s.t} & \\ \sum_{i=1}^n (\alpha_i - \alpha_i^*) &= 0 \quad 0 \leq \alpha_i, \alpha_i^* \leq C \quad i=1,2,\dots,n. \end{aligned} \quad (9)$$

对参数  $\alpha_i, \alpha_i^*$  进行求解后, 再利用式(10)就可求得

$$b = -\frac{1}{2} \sum_{i=1}^n (\alpha_i - \alpha_i^*) [(X_i, X_i) + (X_i, X_s)]. \quad (10)$$

式中,  $X_i X_i$  为任意 2 个非支持向量。在此基础上, 就可得到回归函数

$$f(\alpha, \alpha^*, X) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) (X_i, X_j) + b. \quad (11)$$

为了将低维空间的非线性问题转化为高维空间的线性问题, 内积运算用核函数  $K(X_i, X_j)$  来替代, 从而实现由低维空间到高维空间的映射<sup>[14]</sup>。此时, 优化目标函数就可通过核函数来表示, 式(9)就转化为如下形式:

$$\begin{aligned} \min_{\alpha^{(i)} \in R^{2n}} & \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(X_i \cdot X_j) + \\ & \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) - \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*). \\ \text{s.t} & \\ \sum_{i=1}^n (\alpha_i - \alpha_i^*) &= 0 \quad 0 \leq \alpha_i, \alpha_i^* \leq C \quad i=1,2,\dots,n. \end{aligned} \quad (12)$$

与之对应, 回归函数也做相应变化, 式(11)可表示为:

$$f(\alpha, \alpha^*, X) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(X_i, X_j) + b. \quad (13)$$

通过式(13)可建立支持向量机的回归模型。

假设一个时间序列为  $\{x_1, x_2, \dots, x_n\}$ , 前  $\tau$  个时刻的值已知时, 任务是来预测当前时刻  $t$  的值。这里, 输出用预测的目标值  $x_t$  表示, 输入用前  $\tau$  个目标值  $\{x_{t-1}, x_{t-2}, \dots, x_{t-\tau}\}$  表示, 则需要将输入与输出之间建立一一映射关系  $f: \mathfrak{R}^\tau \rightarrow \mathfrak{R}$ ,  $\tau$  称为嵌入维数<sup>[15]</sup>。则用于支持向量机学习的训练样本集可表示为:

$$X = \begin{bmatrix} x_1 & x_2 & \dots & x_{n-\tau} \\ x_2 & x_3 & \dots & x_{n-\tau+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_\tau & x_{\tau+1} & \dots & x_{n-1} \end{bmatrix}; \quad (14)$$

$$Y = [y_{\tau+1} \ y_{\tau+2} \ \dots \ y_n] = [x_{\tau+1} \ x_{\tau+2} \ \dots \ x_n]. \quad (15)$$

根据式(8), 可建立 SVR 回归预测模型

$$y_t = \sum_{i=1}^{n-\tau} (\alpha_i - \alpha_i^*) K(x_{t-1}, x_i) + b. \quad (16)$$

式中  $t = \tau + 1, \dots, n$ 。

SVR 回归预测模型是在时间序列预测非常重要的一个步骤, 是对其参数的优化选择, 即嵌入维数  $\tau$ 、损失函数参数  $\varepsilon$ 、惩罚系数  $C$  以及核函数参数  $\sigma$  的优化选取。这 4 个参数的确定对 SVR 的预测精度影响很大。目前, 在 SVR 参数确定时常用遗传算法、粒子群优化算法等进行优化, 但在寻优过程中常常会陷入局部最优。ABC 算法是同时对局部最优解和全局最优解进行搜索, 能够最大限度地避免陷入局部最优。因此笔者提出采用 ABC 算法对 SVR 预测模型参数进行优化选取, 以提高预测的精度和效率。

在 ABC 算法中, 蜂群采蜜行为对应着预测问题, 如表 1 所示。食物源(蜜源)的位置对应预测问题的一个可行解, 即预测模型中需要优化选择的参数; 食物源的花蜜量大小对应预测模型的预测误差大小; 搜寻食物源和采蜜的速度对应参数优化问题的求解速度; 当得到最大花蜜量时表示取得了最佳的预测效果, 即此时预测误差达到最小。

表 1 蜂群采蜜行为与预测问题对应关系

蜂群采蜜行为	预测问题
食物源位置	预测模型中需优化的参数
食物源蜜量大小	预测误差大小(适应度)
寻找及采蜜的速度	求解速度
最大花蜜量	最佳预测效果(预测误差达到最小)

ABC 算法中, 进行参数优化的依据是适应度, 其过程是根据适应度的大小来评判食物源位置(可行解)的优劣<sup>[16-17]</sup>。进行参数优化的目的是使预测模型的预测总误差达到最小, 因此, 适应度通常通过预测总误差  $e$  来表示:

$$f = e = \frac{\sum_{i=1}^N [y(i) - \hat{y}(i)]^2}{\sum_{i=1}^N [y(i) - \bar{y}(i)]^2}. \quad (17)$$

式中:  $y(i)$  为第  $i$  个数据的实测值;  $\hat{y}(i)$  为第  $i$  个数据的预测值;  $\bar{y}(i)$  为实测数据平均值;  $N$  为测试数据个数。  $f$  越小表明预测误差越小。

笔者提出的基于人工蜂群优化算法和 SVR 的预测方法的使用过程可分为以下步骤<sup>[18-19]</sup>:

1) 对变量进行初始化, 假设食物源个数、引领蜂的个数、跟随蜂的个数的初始值一样, 并随机为食物源的位置赋一个初始值。然后根据每个食物源的位置向量, 对  $\varepsilon$ 、 $\sigma$ 、 $C$  及  $\tau$  4 个参数进行求取, 建立 SVR 预测模型, 再根据式(14)来计算每个食物源的适应度  $f$ 。

2) 观察蜂依据式(1)进行领域搜索, 当搜索到的食物源的适应度比前面的更优时, 则对食物源位置进行更新, 否, 则保持食物源位置不变。

3) 求取所有食物源的适应度, 并按照式(3)计算发生概率, 采蜜蜂依据概率大小选择食物源(可行解), 并进行领域搜索, 根据食物源的适应度对食物源的位置进行更新, 完成与观察蜂的角色互换。

4) 在经过  $limit$  次循环之后, 判断是否存在局部最优解。若存在局部最优解, 则侦察蜂根据式(4)对食物源位置进行更新。

5) 重复第 2)–4) 的运算, 直到满足最大迭代次数或最小收敛误差为止。最后, 将对应最优适应度的食物源的位置, 即参数  $\varepsilon$ 、 $\sigma$ 、 $C$  及  $\tau$  的最优解进行输出。

### 3 实例分析

在进行发动机磨损故障预测时, 通常采用监测发动机润滑油中金属元素含量的方式来实现。现对某型航空发动机润滑油中金属元素 Mg 浓度进行分析, 采用光谱分析方法来实现。依据采样时间的先后顺序, 将获得的 Mg 浓度数据进行排列, 形成一个 Mg 浓度时间序列(94 个数据点), 如图 1 所示。从图中可以看出: 在第 94 次取样时, Mg 的浓度值发生了大幅度升高, 据此可以判断该发动机内部发生了异常磨损。现采用基于 ABC 算法优化的 SVR 预测模型对该时间序列进行分析, 前 60 个数据作为训练样本, 后 34 个数据作为测试样本, 其预测结果如图 2 所示。其中, 图 2(b)为预测残差结果, 预测残差表示实测值减去预测值之后的数值。从图中可以看出, 在 60~90 之间取样时, 预测误差相对较小, 基于 ABC 算法优化的 SVR 预测模型能够很好地跟踪正常状态下系统的变化过程。在第 92 次取样时, 预测残差发生了陡然增大, 这说明从第 92 次取样之后发动机内部就进入了磨损异常状态。因此采用 ABC 算法优化的 SVR 故障预测模型进行时间序列预测, 能够较好地跟踪发动机润滑油金属元素浓度的变化过程, 并且提前 2 个取样时间预测异常情况的出现(故障的发生)。






图 1 Mg 元素浓度的时间序列



(a) 实测值及预测值



(b) 预测残差

图 2 测试数据的预测结果

### 4 结束语

笔者利用支持向量回归和人工蜂群算法的优点, 提出了 ABC-SVR 的故障预测模型。结果表明: 该方法利用人工蜂群算法能够克服局部最优解, 解决了 SVR 参数选择的难题, 能够较好地预测故障的发生, 具有广泛的应用前景。

### 参考文献:

- [1] FERREIRA J P, CRISOSTOMO M M, COIMBRA A P. SVR versus neural-fuzzy network controllers for the sagittal balance of a biped robot[J]. IEEE Transactions on Neural Networks, 2009, 20(12): 1885-1897.
- [2] MAO Y, ZHOU X, PI D, et al. Parameters selection in gene selection using Gaussian kernel support vector machines by genetic algorithm[J]. Journal of Zhejiang University SCI-ENCE, 2005, 68(10): 961-973.
- [3] MING G, XIA H, SHENG C. A combined SMOTE and

PSO based RBF classifier for two-class imbalanced problems[J]. Neurocomputing, 2011, 74(17): 3456-3466.

[4] ZHU G, KWONG S. Gbest-guided artificial bee colony algorithm for numerical function optimization[J]. Applied Mathematics and Computation, 2010, 217(7): 3166-3173.

[5] OMAKAR S N, SENTHILNATH J, KHANDELWAL R, et al. Artificial bee colony(ABC) for multi-objective design optimization of composite structure[J]. Applied Soft Computing, 2011, 11(1): 489-499.

[6] KARABOGA D, BASTURK B. On the performance of artificial bee colony(ABC)algorithm[J]. Applied Soft Computing, 2008, 8(1): 687-697.

[7] KARABOGA D, AKAY B. A comparative study of artificial bee colony algorithm[J]. Applied Mathematics and Computation, 2009, 214(1): 108-132.

[8] PAN Q K, TASGETIREN M F, SUGANTHAN P N. A discrete artificial bee colony algorithm for the lot-streaming flow shop scheduling problem[J]. Information Sciences, 2011, 181(12): 2455-2468.

[9] SINGH A. An artificial bee colony algorithm for the leaf constrained minimum spanning tree problem[J]. Applied Soft Computing, 2008, 9(2): 625-631.

[10] KARABOGA D, BASTURK B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony(ABC)algorithm[J]. Journal of Global Optimization, 2007, 39(3): 459-471.

[11] KARABOGA D, BASTURK B. A comparative study of artificial bee colony algorithm[J]. Applied Mathematics

and Computation, 2009, 214(1): 108-132.

[12] LORENZI L, MERCIER G, MELGANI F. Support vector regression with kernel combination for missing data reconstruction[J]. IEEE Transactions on Geosciences and Remote Sensing Letters, 2012, 10(2): 367-371.

[13] CAMPS V G, BRUZZONE L, ROIO A J L, et al. Robust support vector regression for biophysical variable estimation from remotely sensed images[J]. IEEE Geosci Remote Sens Lett, 2009, 3(3): 339-343.

[14] ELATTAR E E, GOULERMAS J, WU Q H. Electric load forecasting based on locally weighted support vector regression[J]. IEEE Transactions on Systems, Man, and Cybernetics, 2010, 40(1): 438-447.

[15] 王坤, 员晓阳, 王力. 基于改进模糊支持向量回归模型的机场能源需求预测[J]. 计算机应用, 2016, 36(5): 1458-1463.

[16] 朱志洁, 张宏伟, 王春明. 基于人工蜂群算法优化支持向量机的采场底板破坏深度预测[J]. 重庆大学学报, 2015, 38(6): 37-43.

[17] 陈健飞, 蒋刚, 杨剑锋. 改进 ABC-SVM 的参数优化及应用[J]. 机械设计与制造, 2016, 22(1): 24-28.

[18] 施俊, 高正夏, 徐钦崙. 基于 ABC-SVM 的软基沉降预测研究[J]. 河南科学, 2016, 34(5): 741-745.

[19] 高相铭, 杨世凤, 潘三博. 基于 EMD 和 ABC-SVM 的光伏并网系统输出功率预测研究[J]. 电力系统保护与控制, 2015, 43(11): 86-92.

\*\*\*\*\*

(上接第 59 页)

八炮作战方式对单门火炮系数

$$k_{53} = T_3 / T_5^L = 628.8 / 55.7 = 11.3。$$

则单炮工作时间

$$t_3 = 126.5 + 4.3 \times 425.4 + 11.3 \times 16 = 2136.5。$$

统计至 2 088.5 h 为止。

试验中阵地基线测量仪未出现故障, 连射击指挥分系统出现一个故障, 单门火炮未出现故障, 满足故障数  $r \leq 2$  的要求, 因此系统可靠性满足战术技术指标要求。

### 3 结论

笔者针对某型牵引高炮系统设计定型试验与可靠性试验相结合时存在的问题, 采用了一种加权的可靠性时间统计方法, 将分系统工作时间统计为系统整体工作时间, 给出了成建制高炮系统可靠性试验时间累计方法。定型试验的应用结果表明, 该方法可以用于成建制武器的可靠性评定。

### 参考文献:

[1] 中国人民解放军总装备部. GJB 450A-2004 装备可靠

性工作通用要求[S]. 北京: 总装备部军标出版社, 2004.

[2] 中国人民解放军总装备部. GJB 899A-2009 可靠性鉴定和验收试验[S]. 北京: 总装备部军标出版社, 2009.

[3] 国防科学技术工业委员会. GJB 1829-1993 自行小高炮故障判别准则[S]. 北京: 国防科工委军标出版发行部, 1993.

[4] 邱有成, 谷师泉, 徐宏林. 可靠性试验技术[M]. 北京: 国防工业出版社, 2003: 174-183.

[5] 张志杰, 王静滨, 张树杰, 等. 某高炮电气控制系统使用可靠性评估方法研究[J]. 电子产品可靠性与环境试验, 2013, 31(1): 19-23.

[6] 宋方伟, 梅勇. 分布式高炮复合数据同步采集系统[J]. 兵工自动化, 2016, 35(5): 15-17.

[7] 孙志学, 杨红. 双 35mm 牵引高炮系统任务可靠性评估与分析[J]. 四川兵工学报, 2003: 24(1): 13-15.

[8] 金鑫, 欧阳春明, 郝利勇. 基于权函数的防空武器系统可靠性分配[J]. 兵工自动化, 2007, 26(6): 13-14.

[9] 张振禹, 雷玲, 程俊. 自动火炮武器火控系统可靠性分配方法[J]. 兵工自动化, 2011, 30(6): 6-8.

[10] 商兴华, 韩维, 李成, 等. 一种新的飞机系统可靠性分配方法[J]. 兵工自动化, 2010, 29(12): 16-19.

[11] 杨为民. 可靠性维修保障性总论[M]. 北京: 国防工业出版社, 1995: 52-62.