

# 基于粒子群优化核独立分量的特征降维算法及其应用研究

孙 磊<sup>1</sup>, 贾云献<sup>1</sup>, 王卫国<sup>2</sup>, 张英波<sup>1</sup>, 赵劲松<sup>1,3</sup>

(1. 军械工程学院装备指挥与管理系, 河北石家庄 050003; 2. 军械工程学院科研部, 河北石家庄 050003; 3. 军事交通学院装备保障系, 天津 300161)

**摘 要:**大型复杂装备的工作过程均表现出较强的非线性,并且受非高斯噪声和各种不确定因素的影响,导致状态监测信息多是高维的非线性、非高斯数据,且计算量随信息维数呈指数增长,若直接用于预测模型则导致计算量异常庞大,不利于完成模型参数估计和实现实时维修。针对上述问题,对核独立分量分析算法中关于核函数参数选择的盲目性,提出了用粒子群优化算法改进核参数选择过程的核独立分量分析算法,实现了高维状态信息的降维。最后,通过对某自行火炮发动机油液监测数据进行特征降维实例分析,验证了所提方法的可行性与有效性。

**关键词:**粒子群算法;核独立分量分析;特征降维;油液光谱分析

中图分类号:TH17 文献标志码:A

## Feature dimension reduction of kernel independent component by particle swarm optimization and its application

SUN Lei<sup>1</sup>, JIA Yunxian<sup>1</sup>, WANG Weigu<sup>2</sup>, ZHANG Yingbo<sup>1</sup>, ZHAO Jinsong<sup>1,3</sup>

(1. Equipment Command and Management Department, Ordnance Engineering College, Shijiazhuang Hebei 050003, China; 2. Research Department, Ordnance Engineering College, Shijiazhuang Hebei 050003, China; 3. Equipment Support Department, Military Transportation Academy, Tianjin 300161, China)

**Abstract:** The operating process of complex equipment has strong non-linearity, and it is often affected by some unknown factors, bringing much non-linear and non-gaussian monitoring data, and the calculation time grows up like exponential form as calculated amount increases. If these data are used directly for equipment residual life prediction, it is hard to complete model parameters' estimation and realize equipment's online maintenance. Aiming at settling the above problems, especially for the blindness of kernel function parameters selection in kernel independent component analysis, the kernel function parameters are optimized by particle swarm optimization arithmetic to reduce feature dimension. Finally, the oil monitoring data of self-propelled gun engine is used for dimension reduction. Testing results show the feasibility and effects of the proposed method.

**Key words:** particle swarm optimization; kernel independent component analysis; feature dimension reducing; oil spectrum analysis

为了更好地掌握装备的运行状态,在对装备实施状态监测时往往采集多种状态信息<sup>[1]</sup>。例如:对于油液光谱分析采集的元素种类多达 20 几种,这些状态信息间存在一定的相关性,若把这些状态信息直接用于装

收稿日期:2012-11-02;修回日期:2012-12-03;责任编辑:李 穆

基金项目:总装备部重点预研基金资助项目(9140A27020308JB34)

作者简介:孙 磊(1985-),男,河北石家庄人,博士研究生,主要从事装备维修理论及其应用、故障诊断与预测等方面的研究。

E-mail:waterprison@163.com

备的剩余寿命预测将导致计算量急剧增大或难以计算,而且由于引入了与装备状态相关度较小的状态信息而导致结果存在偏差。因此,如何从大量状态信息中提取影响装备寿命的主要特征信息,使得这些特征信息间既充分反映原来的状态信息的作用又彼此相互无关,就显得十分重要,为下一步的故障诊断与预测提供有效特征值<sup>[2-3]</sup>。

独立分量分析(independent component analysis,ICA)是近年来在信号分析与处理中发展形成的一种数据处理方法<sup>[4]</sup>。ICA作为一种有效的盲源分离技术仍是信号处理领域的热点,但目前的算法在处理非线性变化的信号时还有一定的局限,而基于非线性函数空间的ICA方法——核独立分量分析(kernel independent component analysis,KICA)<sup>[5]</sup>则可以解决这一问题。KICA方法具有更好的灵活性和鲁棒性,不仅能够实现高维非线性数据的降维,更重要的是,基于信号的高阶研究信号间的独立关系使经过变换所得到的各个分量之间不仅正交,而且相互独立,避免了数据的非线性对预测模型的影响<sup>[6-7]</sup>。

由于KICA算法精度受到核函数类型及其参数的影响,因此选择合适的核参数至关重要。目前核参数的选择方法仍是主要靠大量的试验人为确定或采用交叉检验的办法,不但费时费力效率低,而且这样确定的核函数参数不一定是最优的。因此,对KICA核函数参数的优化方法进行研究,对改善其特征降维结果具有重要的意义。粒子群优化算法(particle swarm optimization,PSO)是一种全局并行的寻优方法,近年来已在函数优化、自动控制、机器学习、人工生命等领域都得到了广泛的应用<sup>[8-9]</sup>。笔者针对KICA技术在核函数参数选择上的盲目性,首先利用Fisher判别函数的思想建立核函数的参数优化的适应度,进而基于PSO算法求出核函数参数优化模型的全局最优解,改善KICA的性能。最后通过案例验证了方法的可行性与有效性。

## 1 独立分量分析

假设 $S=[s_1, s_2, \dots, s_n]^T$ 为 $n$ 个相互独立的源信号, $X=[x_1, x_2, \dots, x_n]^T$ 为 $m$ 个观测信号,其满足以下关系<sup>[10]</sup>:

$$X=AS。$$

式中: $A$ 为 $m \times n$ 阶矩阵,该式表示了观察所得的状态变量是如何由独立分量构成的。目的是通过观测数据 $x$ 估计未知独立源 $s$ 和混合矩阵 $A$ ,即求解一个解混矩阵 $W$ ,使得

$$Y=WX=WAS=\hat{S}$$

的各分量相互独立,并把 $Y$ 作为 $S$ 的估计。独立分量分析中所有的出发点都是一个基本假定:即认为这些独立分量 $s_i$ 互相统计独立,且不服从高斯分布。若记 $Y=W^T X$ ,则可以通过最大化 $W^T X$ 的非高斯性来求 $W$ ,从而求得独立分量 $Y$ 。

## 2 核独立分量分析

### 2.1 Mercer 核

Mercer核条件是任意平方可积函数 $K(x, y)$ ,它是某个特征空间中内积函数的充分必要条件是对于任意 $\varphi(x) \neq 0$ 且 $\int \varphi^2(x) dx < \infty$ ,存在:

$$\iint K(x, y) \varphi(x) \varphi(y) dx dy > 0。$$

事实上任何一个函数只要满足Mercer条件,就可以用作Mercer核,同时可以分解成特征空间的点积形式。假设输入空间的样本 $x_k \in R^N, k=1, 2, \dots, l$ ,被某种非线性映射 $\varphi$ 映射到某一特征空间 $R$ ,得到 $\varphi(x_1), \varphi(x_2), \dots, \varphi(x_l)$ 。那么输入空间的内积运算,在特征空间就可以用Mercer核表示为 $K(x_i, x_j) = \varphi(x_i) \cdot \varphi(x_j)$ 。

### 2.2 KICA 算法步骤

输入:数据向量 $x_1, x_2, \dots, x_n$ 和核函数 $K(x, z)$ 。

1) 对输入数据向量 $x_1, x_2, \dots, x_n$ 进行预白化处理,使输入的向量之间相互正交。

2) 利用Cholesky分解求出原始独立数据 $z_1, z_2, \dots, z_n$ 的Gram矩阵 $K_1, K_2, \dots, K_m$ ,其中 $z_i = Wx_i, W$ 为独立分量分析中的解混矩阵。

3) 定义  $\lambda_H(K_1, K_2, \dots, K_m)$  为下式的最大特征值:

$$\begin{pmatrix} K_1 K_1 & K_1 K_2 & \cdots & K_1 K_m \\ K_2 K_1 & K_2 K_2 & \cdots & K_2 K_m \\ \vdots & \vdots & \ddots & \vdots \\ K_m K_1 & K_m K_2 & \cdots & K_m K_m \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_m \end{pmatrix} = \lambda \begin{pmatrix} K_1 K_1 & 0 & \cdots & 0 \\ 0 & K_2 K_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & K_m K_m \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_m \end{pmatrix}. \quad (1)$$

4) 对  $W$  求  $M_{\lambda_H} = -\frac{1}{2} \log \lambda_H(K_1, K_2, \dots, K_m)$  的最小化。

输出:  $W$  矩阵。上面的算法不断在步骤 2) 和 4) 之间重复运行, 直到满足了收敛性的条件便可以得到解混矩阵  $W$ ,  $W$  为  $m \times n$  阶 ( $m < n$ ) 解混矩阵。对于一组观察数据  $x_1, x_2, \dots, x_n$ , 根据  $z = Wx$ , 就可以分离出相互独立的信号, 并将维数从  $n$  降到  $m$ 。

### 3 基于粒子群优化算法的核独立分量分析技术

#### 3.1 基本 PSO 算法

PSO 算法将每个优化问题的潜在解看作是搜索空间的粒子, 每个粒子都有一个被优化函数决定的适应值和一个决定其运动方向和距离的速度向量, 然后粒子群就追随当前的最优粒子在解空间进行搜索<sup>[11]</sup>。PSO 初始化为一群随机粒子, 通过不断迭代搜索最优解。在每一次迭代中, 粒子通过跟踪 2 个极值来更新自己, 一个就是粒子本身到当前时刻为止找到的最优解, 称为个体最优值; 另一个就是整个种群到当前时刻找到的最优解, 称为全局最优值, 粒子位置更新过程如图 1 所示。

图中:  $x_{id}(t)$  为第  $i$  个粒子的当前位置;  $v_{id}(t)$  为第  $i$  个粒子的当前速度,  $v_{id} \in [-V_{\max}, V_{\max}]$ ,  $V_{\max}$  是最大限制速度, 非负;  $p_{id}(t)$  为第  $i$  个粒子迄今为止搜索到的最优位置;  $p_{gd}(t)$  为整个粒子群搜索到的最优位置。

假设在一个  $D$  维的目标搜索空间中, 有  $m$  个粒子组成一个群体, 其中第  $i$  个粒子的位置表示为向量  $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ ,  $i = 1, 2, \dots, m$ , 其速度也是一个  $D$  维的向量, 记为  $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 。第  $i$  个粒子迄今为止搜索到的最优位置为  $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ , 整个粒子群搜索到的最优位置为  $p_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ , 粒子更新公式如下<sup>[12]</sup>:

$$v_{id}(t+1) = v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t)); \quad (2)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1). \quad (3)$$

将式(2)称为基本粒子群优化算法。其中, 当  $v_{id} > V_{\max}$  时, 取  $v_{id} = V_{\max}$ ; 当  $v_{id} < -V_{\max}$  时, 取  $v_{id} = -V_{\max}$ ;  $i = 1, 2, \dots, m$ ;  $d = 1, 2, \dots, D$ ; 加速常数  $c_1$  和  $c_2$  为非负常数;  $r_1$  和  $r_2$  服从  $[0, 1]$  上的均匀分布随机数。

#### 3.2 基于 PSO 的核函数参数优化方法

大量数值实验表明, 核参数的取值对基于核函数的特征降维算法性能具有很大的影响。例如: 高斯径向基核函数  $\sigma$  过大, 样本“势力范围”也会过大, 以致一些毫无关系的训练样本会干扰对新测试样本作出正确判断;  $\sigma$  过小, 则会导致核学习只有记忆功能而无法对新样本进行判断<sup>[13]</sup>。所以选择合适的函数宽度需要在两者之间进行权衡。

根据前面的分析, KICA 的主要思想是使得各分量的数据点散布于最大统计相关方向, 强调的是分解出来的各分量之间的相互独立性。而 Fisher 线性判别分析 (fisher linear discriminant analysis, FDA 或 LDA) 的基本思想是选择使得 Fisher 准则函数达到极值的向量作为最优投影方向, 把原始数据沿该方向进行投影得




图 1 粒子位置更新示意图

Fig. 1 Scheme of particle position updating

到一条直线,使投影后不同类别的数据尽可能分开,相同类别的数据则尽可能的聚集,即投影后模式样本的类间散布最大而类内散布最小。因此,基于 KICA 和 FDA 基本思想之间的相通性,可以借鉴 FDA 的思想来探索 KICA 中核参数优化方法。

### 1) 建立核参数优化适应度函数

设  $X_1, X_2, \dots, X_D$  是特征空间  $D$  个样本类,特征样本  $X$  为  $n$  维实向量,即  $X \in R^n$ ,经过非线性映射  $\Phi$  后对应样本向量为  $\Phi(X) \in H$ 。则样本类  $X_i$  在特征空间的均值向量为

$$m_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \Phi(x_{ij}), i = 1, 2, \dots, D, j = 1, 2, \dots, n_i. \quad (4)$$

式中,  $n_i$  为第  $i$  个样本类的样本数。

定义样本的类间散度  $S_b$  为

$$S_b = \sum_{i=1}^D \|m_i - m_0\|^2 = \sum_{i=1}^D \left( \frac{1}{n_i^2} \sum_{k=1}^{n_i} \sum_{l=1}^{n_i} k(x_{ik}, x_{il}) - \frac{2}{n_i n} \sum_{k=1}^{n_i} \sum_{j=1}^D \sum_{l=1}^{n_j} k(x_{ik}, x_{jl}) + \frac{1}{n^2} \sum_{j=1}^D \sum_{k=1}^D \sum_{l=1}^{n_j} \sum_{m=1}^{n_k} k(x_{jl}, x_{km}) \right). \quad (5)$$

式中:  $m_0 = \frac{1}{n} \sum_{j=1}^D \sum_{l=1}^{n_j} \Phi(x_{jl}), n = \sum_{i=1}^D n_i$ 。

定义样本的类内散度  $S_w$  为

$$S_w = \sum_{i=1}^D \sum_{j=1}^{n_i} \|\Phi(x_{ij}) - m_i\|^2 = \sum_{i=1}^D \left( \sum_{j=1}^{n_i} k(x_{ij}, x_{ij}) - \frac{1}{n_i} \sum_{j=1}^{n_i} \sum_{k=1}^{n_i} k(x_{ij}, x_{ik}) \right). \quad (6)$$

式中,  $\Phi(x_{ij})$  表示特征空间  $H$  中第  $i$  类第  $j$  个样本。对于高斯径向基核函数,由于  $k(x_{ij}, x_{ij})$  的值等于 1,所以对高斯径向基函数式(6)可以简化为

$$S_w = \sum_{i=1}^D \left( n_i - \frac{1}{n_i} \sum_{j=1}^{n_i} \sum_{k=1}^{n_i} k(x_{ij}, x_{ik}) \right). \quad (7)$$

那么,根据 Fisher 极小鉴别准则,在此建立适应度函数为

$$F(\omega) = \frac{S_w}{S_b}. \quad (8)$$

实验表明,对于完全非线性可分问题,Fisher 鉴别函数  $F(\omega)$  的极小值点  $\omega^*$  存在<sup>[14]</sup>。对于高斯径向基核函数把  $\omega^*$  作为参数  $\sigma$  的值可以取得较好的效果;而对于多项式核函数则把  $\omega^*$  作为多项式的阶次  $d$  的取值。对于线性可分或几乎线性可分问题,随着  $\omega$  由小变大,  $F(\omega)$  值急剧下降,然后趋于平稳,此时可以取  $F(\omega)$  开始趋于平稳时的  $\omega$  作为  $\omega^*$ 。

### 2) KICA 算法中核参数的粒子群优化过程

在实现核参数优化过程中,对于适应度函数式(8),需要求 Fisher 鉴别函数  $F(\omega)$  的极值点。 $F(\omega)$  有可能是多峰值函数,存在多个极值点。为了得到全局最优值,在此结合 PSO 算法对参数  $\omega$  进行优化,建立 PSO-KICA 算法流程,如图 2 所示。具体步骤如下。

输入:数据样本  $x_1, x_2, \dots, x_n$ ,选择核函数  $K(x, z)$ 。

1) 计算样本的类间散度  $S_b$  和类内散度  $S_w$ ;

2) 构建 Fisher 鉴别函数  $F(\omega)$  作为粒子群优化的适应度函数;

3) 给定核参数  $\omega$  的取值范围  $(\omega_{\min}, \omega_{\max})$ 、种群规模  $m$ 、加速常数  $c_1$  和  $c_2$ 、最大进化代数  $T_{\max}$ 、最大限制速度  $V_{\max}$ 、惯性权重  $\omega$  和计算精度  $\epsilon$ 。

4) 随机产生初始群体,计算个体适应度值  $F_p$  和种群整体适应度值  $F_g$ ;

5) 对粒子的位置和速度进行更新;

6) 判断迭代次数  $t$  是否达到最大进化代数  $T_{\max}$  或评价值小于给定精度  $\epsilon$ 。如果达到最大进化代数  $T_{\max}$  或评价值小于给定精度  $\epsilon$ ,得到最优核参数  $\omega$ ;

7) 利用优化的核函数实现 KICA 算法。

输出:根据  $z = Wx$  分离出相互独立的信号。

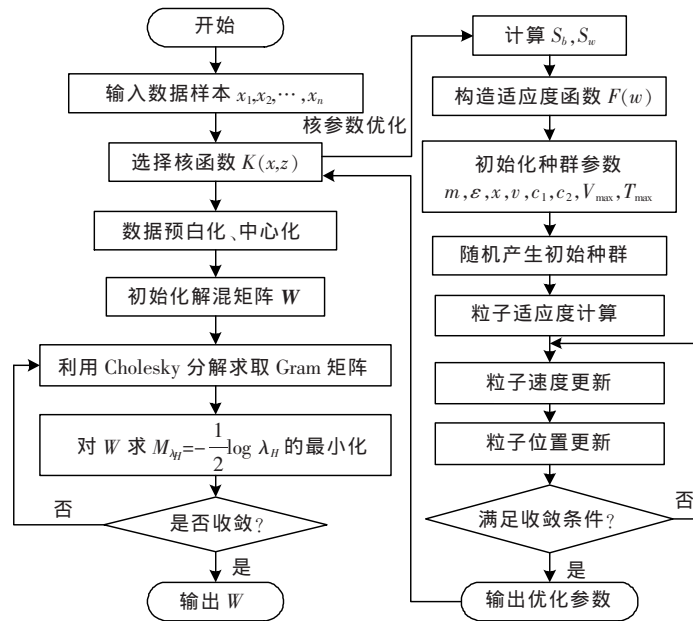


图 2 PSO-KICA 算法流程

Fig. 2 Flow chart of PSO-KICA

#### 4 案例分析

由于自行火炮发动机工作条件复杂多变、工作环境相对恶劣,对其进行状态监测往往采用油液分析方法提取润滑油中金属元素的成分和浓度。然而,油液数据大多具有高维、非线性特点,不利于进一步的分析处理,人们往往采用降维的手段对其进行分析处理。

为验证上述所建立的基于粒子群优化算法的核独立分量分析技术的可行性和有效性,采用油液光谱分析的监测方式采集某型发动机润滑油中各元素的浓度为状态信息<sup>[15]</sup>。笔者重点收集了该发动机润滑油中铁、铝、铅、硼、钡、铬、镁、硅等 8 种元素浓度值。图 3 是原始的油液光谱分析数据散点图(由于篇幅所限仅给出 Fe 元素和 Al 元素的浓度散点图)。




图 3 Fe 元素和 Al 元素浓度散点图

Fig. 3 Graphical of iron and aluminum oil concentration records

基于油液浓度数据,采用 PSO 算法对 KICA 中的高斯径向基核函数参数进行优化,确定 KICA 分析的最优核函数,参数收敛过程如图 4 所示。可见,当核函数参数进化到 50 代时,适应度函数已收敛到规定的精度要求并逐渐趋于稳定,且核函数宽度也逐渐收敛于 1。即当高斯径向基核函数  $\sigma = 1.07$  时,适应度函数  $F(w)$  取得最优值为 3.428 6。




图 4 基于 PSO 的高斯径向基核函数参数优化

Fig. 4 Parameter optimization of gaussian kernel function based on PSO

得到最优核函数之后,根据前述降维算法对发动机油液浓度数据进行降维分析与处理,得到了 3 个独立主成分,如图 5 所示。图 6a)是油液浓度数据进行 PSO-KICA 算法降维后,前 3 个独立成分在空间的投影图,可见各个分量之间具有较好的独立性。而未经 KICA 分析处理的原始数据则存在较大的相关性,如图 6b)所示。利用 PSO-KICA 算法对油液浓度数据进行处理的过程表明,该算法不仅避免了核函数参数选择过程的盲目性,而且实现了高维非线性数据的降维,得到了相互独立的特征分量。




图 5 油液浓度数据特征降维结果

Fig. 5 Feature dimension reducing result of oil concentration data




图 6 原始油液梯度数据投影和梯度数据 KICA 投影

Fig. 6 Projective and KICA projective chart of oil concentration data

### 5 结 语

针对 KICA 特征降维算法在核函数参数的选择上存在的问题,利用 PSO 算法实现了核函数参数的优化,建立了基于 PSO-KICA 的特征降维算法。通过对某自行火炮发动机油液浓度数据进行降维处理,达到了基于 PSO-KICA 降低特征向量的维数的目的,验证了该方法用于特征降维的可行性和有效性。

## 参考文献/References:

- [1] JARDINE A K S, LIN D, BANJEVIC D. A review on machinery diagnostics and prognostics implanting condition-based maintenance[J]. Mechanical System and Signal Processing, 2006, 20(1): 1 483-1 510.
- [2] ABRAHAM B, MEROLA G. Dimensionality reduction approach to multivariate prediction[J]. Computational Statistics and Data Analysis, 2005, 48(1): 5 016.
- [3] 欧阳晓黎, 张延生, 杨 军. 复杂电子装备智能故障诊断方法[J]. 河北科技大学学报, 2004, 25(2): 42-49.  
OUYANG Xiaoli, ZHANG Yansheng, YANG Jun. The intelligent fault diagnosis methods for complex electronic equipments[J]. Journal of Hebei University of Science and Technology, 2004, 25(2): 42-49.
- [4] COMON P. Independent component analysis-a new concept[J]. Signal Processing, 1994(36): 287-314.
- [5] 胥永刚, 李 强, 王正英, 等. 基于独立分量分析的机械故障信息提取[J]. 天津大学学报, 2006, 39(9): 1 066-1 071.  
XU Yonggang, LI Qiang, WANG Zhengying, et al. Fault information extraction of mechanical equipment based on independent component analysis[J]. Journal of Tianjin University, 2006, 39(9): 1 066-1 071.
- [6] FAUVEL M, CHANUSSOT J, BENEDIKTSSON J A. Kernel principal component analysis for feature reduction in hyperspectral images analysis[A]. Proceedings of the 7th Nordic[C]. [S. l.]: Signal Processing Symposium, 2006. 238-241.
- [7] XU Anbang, JIN Xin, GUO Ping. KICA feature extraction in application to FNN based image registration[A]. 2006 International Joint Conference on Neural Networks[C]. [S. l.]: [s. n.], 2006. 3 602-3 608.
- [8] 高 峰, 武 睿, 刘南平. 基于自适应蚁群算法的无线传感器网络能量优化[J]. 河北工业大学学报, 2010, 39(16): 4-7.  
GAO Feng, WU Rui, LIU Nanping. An approach to WSN energy optimization based on self-adaptive ant colony algorithm[J]. Journal of Hebei University of Technology, 2010, 39(6): 4-7.
- [9] 李正涛, 赵环宇, 马献果. 应用粒子群算法从已知数据中确定置信测度和似然测度[J]. 河北科技大学学报, 2011, 32(2): 128-132.  
LI Zhengtao, ZHAO Huanyu, MA Xianguo. Using particle swarm algorithm to identify belief and plausible measures from known data [J]. Journal of Hebei University of Science and Technology, 2011, 32(2): 128-132.
- [10] BACH F R, JORDAN M I. Kernel independent component analysis[J]. Machine Learning Research, 2002(3): 1-48.
- [11] 何学文. 基于支持向量机的故障智能诊断理论与方法研究[D]. 长沙: 中南大学, 2004.  
HE Xuewen. Research on Fault Intelligent Theory Based on SVM [D]. Changsha: Central South University, 2004.
- [12] KENNEDY J, EBERHART R. Particle swarm optimization[A]. Proc IEEE Intl Conf on Neural Networks, IV. Piscataway[C]. NJ: IEEE Service Center, 1995. 1 942-1 948.
- [13] 魏秀业. 基于粒子群优化的齿轮箱智能故障诊断研究[D]. 太原: 中北大学, 2009.  
WEI Xiuye. Study on Intelligent Fault Diagnosis of Gearbox Based on Particle Swarm Optimization [D]. Taiyuan: North University of China, 2009.
- [14] 褚蕾蕾, 陈绥阳, 周 梦, 等. 计算智能的数学基础[M]. 北京: 科学出版社, 2002.  
CHU Leilei, CHEN Suiyang, ZHOU Meng, et al. Mathematics Foundation of Computation Intelligent[M]. Beijing: Science Press, 2002.
- [15] 陈 丽. 基于状态的维修模型及应用研究[D]. 石家庄: 军械工程学院, 2009.  
CHEN Li. Condition Based Maintenance Model and Application[D]. Shijiazhuang: Ordnance Engineering College, 2009.

## 向本期载文的审稿专家致谢

本期《河北科技大学学报》共发表论文 17 篇。这些论文的发表是与有关专家的认真审读、细查资料、推敲分析、中肯评价分不开的。对此,本编辑部特向这些专家表示敬意,对他们的辛勤劳动表示感谢。本期载文的审稿专家名单如下(按姓名的汉语拼音顺序排列):

陈冠华 程庆彦 丛日敏 崔明辉 董 浙 范妍芹 李江林 李巧奎  
李 晓波 李永梅 鲁世平 任小强 邵新慧 史兰香 魏世泽 杨卯生  
张炳烛 张 广 张红霞

(本刊编辑部)