

电子系统健康状态监测数据优化算法

杨森*, 孟晨, 王成

(军械工程学院 导弹工程系, 石家庄 050003)

(* 通信作者电子邮箱 yangsanmu@sogou.com)

摘要:为解决电子系统健康状态监测数据的冗余性和高维性问题,提出了一种将样本优化和特征优化相结合的监测数据优化算法。首先,采用特征空间样本选择算法对监测数据进行样本优化,找出最具代表性的样本;然后,采用核主成分分析—分布估计算法(KPCA-EDA)对样本优化后的监测数据进行特征优化,在保证特征信息充足的情况下,保留更多的识别信息;最后,以某滤波电路为例进行了验证,仿真结果表明,该算法同KPCA等优化算法相比,在训练时间和识别率上能达到更好的平衡。

关键词:电子系统;监测数据优化;特征空间样本选择;核主成分分析;分布估计算法

中图分类号: TP18; TP216 **文献标志码:** A

Optimization algorithm of electronic system condition monitoring data

YANG Sen*, MENG Chen, WANG Cheng

(Department of Missile Engineering, Ordnance Engineering College, Shijiazhuang Hebei 050003, China)

Abstract: To solve the redundancy and high-dimensional problem of the electronic system condition monitoring data, a monitoring data optimization algorithm that combined the sample optimization and features optimization was put forward. Firstly, monitoring data samples were optimized by feature space sample selection algorithm, and the most representative samples were found; then monitoring data characteristics were optimized by KPCA-EDA algorithm after the sample optimization. More recognition information was retained on guarantee that the feature information was enough. Finally, a filter circuit was taken as an example to simulate, and the result shows that this method is effective.

Key words: electronic system; monitoring data optimization; feature space sample selection; Kernel Principal Component Analysis (KPCA); Estimation of Distribution Algorithms (EDA)

0 引言

在我军装备跨越式发展过程中,电子系统在武器装备中的比重越来越大,在战争中的作用也越来越突出,一旦其健康状态发生退化,将会直接影响部队战斗力的发挥。因此,监测电子系统的健康状态对部队装备维护具有重要意义^[1]。但是,在对电子系统健康状态进行监测时,通常需要采集大量数据,这些数据大多具有冗余性和高维性的特点,将其直接送入监测模型中会极大降低监测效率,并导致不准确的状态评估结果。因此需对监测数据进行优化,这是监测评估电子系统健康状态的第一步。

文献[2]提出的主成分分析(Principal Component Analysis, PCA)算法是一种常用的将多个互相关变量转化为少量不相关变量的数据优化方法,该算法理论完善,计算方便,具有最优的线性重构误差,但是,该方法对主成分个数的确定没有明确的准则,而且不能用于处理非线性数据,因此限制了其应用范围;之后有学者对此方法进行了改进,提出了基于核空间的核主成分分析(Kernel Principal Component Analysis, KPCA)算法^[3-4],通过引入核函数,在特征空间内对数据进行PCA处理,对非线性数据具有较好的处理能力,但是,该算法的性能依赖于核的选择,并且核矩阵的大小是数据中样本数的平方,若样本数量很大时,核矩阵的计算量较大。另外,无论是PCA算法还是KPCA算法,在优化数据过程中

均将全部数据视为一个整体,寻求散度最大的方向,然而在很多情况下,散度最大方向与识别最有利的方向并不一致^[5],这大大限制了其在数据优化中的应用。

本文针对这两种算法的缺陷,提出了将样本优化和特征优化相结合的监测数据优化算法:首先,采用特征空间样本选择算法对样本进行优化,这不仅可以有效地消除相似样本,提高监测模型的泛化能力,还可以降低KPCA中核矩阵运算的计算复杂度^[6];然后,对优化后的样本集进行KPCA分析,并采用分布估计算法(Estimation of Distribution Algorithm, EDA)对主成分特征信息进行选择,在保证状态特征信息充足的前




图1 监测数据优化策略

数据优化过程如图1所示。

1 基于特征空间样本选择的样本优化算法

针对监测模型大多在特征空间进行模式识别而以往样本选择在原始空间进行的矛盾,提出了基于核方法的特征空间样本选择技术,即利用核技巧将样本选择方法拓展到特征空间,在特征空间中选择最具代表性的样本来表征整个样本集,提高

收稿日期:2012-04-28;修回日期:2012-06-02。 基金项目:总装备部科研项目;总装备部预研项目。

作者简介:杨森(1984-),男,河北石家庄人,博士研究生,主要研究方向:复杂电子装备状态监测与自动测试;孟晨(1963-),男,河南郑州人,教授,博士生导师,主要研究方向:军械装备通用自动测试系统检测与诊断;王成(1980-),男,湖北人,讲师,博士,主要研究方向:自动测试系统。

监测效率。基于特征空间样本选择的样本优化算法如下:

设第 i 类样本集 X_i 包含 n_i 个样本,已选样本子集为 X_i' , $l(l < n_i)$ 为已选样本数,拟选择的样本总数设为 $s(0 < s < n_i)$,逼近距离下界为 $\varepsilon(\varepsilon \geq 0)$ 。定义核函数 $k(\mathbf{x}, \mathbf{y}) = \varphi(\mathbf{x}) \cdot \varphi(\mathbf{y})$, 其中 $\varphi(\cdot)$ 表示原始空间 \mathbf{R}^n 到特征空间 F 的映射函数, $\varphi(X_i)$ 和 $\varphi(X_i')$ 分别表示 X_i 和 X_i' 在特征空间中的映射集合。

步骤1 确定候选样本集。对于 $\forall \mathbf{x}_j \in X_i$, 在特征空间中样本 $\varphi(\mathbf{x}_j)$ 与第 i 类样本集中所有训练样本 $\mathbf{x}_k(k = 1, 2, \dots, n_i)$ 之间的欧氏距离平方之和为:

$$\sum_{k=1}^{n_i} d^2(\mathbf{x}_j, \mathbf{x}_k) = \sum_{k=1}^{n_i} \varphi(\mathbf{x}_j)^T \varphi(\mathbf{x}_j) - 2\varphi(\mathbf{x}_j)^T \varphi(\mathbf{x}_k) + \varphi(\mathbf{x}_k)^T \varphi(\mathbf{x}_k) \quad (1)$$

由于式(1)只涉及特征空间中样本内积运算,因此可以利用核方法,用核函数 $k(\mathbf{x}, \mathbf{y})$ 代替特征空间中的样本内积 $(\varphi(\mathbf{x}) \cdot \varphi(\mathbf{y}))$, 因此式(1)可改写为:

$$\sum_{k=1}^{n_i} d(\mathbf{x}_j, \mathbf{x}_k) = \sum_{k=1}^{n_i} k(\mathbf{x}_j, \mathbf{x}_j) - 2k(\mathbf{x}_j, \mathbf{x}_k) + k(\mathbf{x}_k, \mathbf{x}_k) \quad (2)$$

依据式(2)计算出第 i 类样本集中每一个样本 $\varphi(\mathbf{x}_j)$ 与所有训练样本之间的欧氏距离平方之和,选出其中值较小的 $n(n < n_i)$ 个样本作为候选样本集。

步骤2 确定初始样本集。取步骤1得到的候选样本集中距离平方和最小的样本作为样本选择集 X_i' 的初始样本 $\mathbf{z}_i(l = 1)$ 。

步骤3 若样本选择集 X_i' 中的样本个数 $l < s$,则在特征空间中计算候选样本集的其余样本与样本选择集 X_i' 之间的不相似程度,将不相似度最大的样本加入到样本选择集 X_i' 中,作为新的样本 \mathbf{z}_{l+1} ;否则,退出。

该过程的思路为:若候选样本 $\varphi(\mathbf{x}_i)$ 可由样本选择集 $\varphi(X_i')$ 中的样本线性组合近似表示,则认为该候选样本为冗余样本,可以被剔除。记:

$$u(X_i') = \sum_{j=1}^l a_j \varphi(\mathbf{z}_j) \quad (3)$$

其中: $\mathbf{a} = [a_1, a_2, \dots, a_l]^T$ 为线性组合系数,满足 $\sum_{j=1}^l a_j = 1$, $a_j \geq 0$ 。可以通过计算候选样本 $\varphi(\mathbf{x}_i)$ 与 $u(X_i')$ 之间的相似程度来进行样本选择,将不相似度最大的样本保留,达到样本选择的目的。

采用欧氏距离度量 $\varphi(\mathbf{x}_i)$ 与 $u(X_i')$ 之间的相似程度,将距离平方最大的样本点加入到样本选择集 X_i' 中,作为新样本 \mathbf{z}_{l+1} 。每一个候选样本 $\varphi(\mathbf{x}_i)$ 与 $u(X_i')$ 之间的欧氏距离平方可由下面的优化方程得出:

$$\begin{aligned} d_i^2(\mathbf{a}) = \min \left\| \varphi(\mathbf{x}_i) - \sum_{j=1}^l a_j \varphi(\mathbf{z}_j) \right\|^2 = \\ \min \left[\varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_i) - 2 \sum_{j=1}^l a_j \varphi(\mathbf{z}_j) \cdot \varphi(\mathbf{x}_i) + \right. \\ \left. \sum_{i=1}^l \sum_{j=1}^l a_i a_j \varphi(\mathbf{z}_i) \cdot \varphi(\mathbf{z}_j) \right] \end{aligned} \quad (4)$$

用核函数 $k(\mathbf{x}, \mathbf{y})$ 代替特征空间中的样本内积 $(\varphi(\mathbf{x}) \cdot \varphi(\mathbf{y}))$, 式(4)可改写为:

$$\begin{aligned} \min d_i^2(\mathbf{a}) = [k(\mathbf{x}_i, \mathbf{x}_i) - 2 \sum_{j=1}^l a_j k(\mathbf{z}_j, \mathbf{x}_i) + \\ \sum_{i=1}^l \sum_{j=1}^l a_i a_j k(\mathbf{z}_i, \mathbf{z}_j)] \\ \text{st. } \sum_{j=1}^l a_j = 1, a_j \geq 0 \end{aligned} \quad (5)$$

可以看出,式(5)为关于 \mathbf{a} 的凸二次规划问题,采用 Matlab 中的 quadprog 函数求解可以得到线性组合系数 $a_j(j = 1, 2, \dots, l)$ 。将其代入式(5)即可求得候选样本点 $\varphi(\mathbf{x}_i)$ 到 $u(X_i')$ 的距离平方 d_i^2 。

依据上述求解过程计算每一个候选样本与已选样本集 $\varphi(X_i')$ 线性组合 $u(X_i')$ 之间的欧氏距离平方 $d_i^2(i = 1, 2, \dots, n - l)$, 并记 $d_{\max}^2 = \max\{d_i^2 | i = 1, 2, \dots, n - l\}$ 。

步骤4 若 $d_{\max}^2 > \varepsilon$,则将 d_{\max}^2 对应的样本点加入到样本选择集 X_i' 中,作为新的样本 \mathbf{z}_{l+1} ;否则,退出。

步骤5 $l = l + 1$, 返回步骤3。

2 基于 KPCA-EDA 的特征优化算法

2.1 EDA 算法原理

EDA 是最近兴起的一类新型智能优化方法,它作为一种群体搜索算法是在遗传算法基础上发展起来的^[7]。EDA 算法基本原理为:首先从当前种群中优选出一部分个体,根据这些优选个体产生统计信息,估计概率分布;然后利用这个概率分布产生下一代个体,重复此过程直到满足算法结束条件。EDA 算法与遗传算法的对比如图2^[8]所示。




图2 EDA 算法与遗传算法比较

按照概率模型的不同,可以将 EDA 算法分为不同的类别^[9]:按变量的相关性划分,EDA 可以分为变量不相关、变量相关和多变量相关三类;按照编码方式的不同划分,可将其分为二进制编码和实数编码两类。代表性的变量不相关二进制编码分布估计算法主要有基于群体的递增学习算法 (Population Based Incremental Learning, PBIL), 单变量边缘分布算法 (Univariate Marginal Distribution Algorithm, UDMA) 和紧致遗传算法 (Compact Genetic Algorithm, CGA) 等。由于 KPCA 是一种去相关的技术,即提取出的特征向量之间是统计不相关的,并且特征向量的选择是一个离散的过程,因此应采用变量不相关二进制编码的 EDA 算法进行优化。

2.2 基于 KPCA-EDA 的特征优化算法

由于 KPCA 的特征向量选择是一个离散的过程,很难用一般的分析手段进行求解,而分布估计算法则可以通过采用离散型编码形式来解决这种离散的优化过程且避免了传统遗传算法易陷入局部最优解的问题^[10],因此,本文提出了基于 EDA 算法的 KPCA 特征向量选择算法,即 KPCA-EDA 算法。算法步骤如下:

步骤1 产生初始种群 $D_l(l = 0)$ 。采用 KPCA 算法在特征空间对监测数据进行主成分分析,得到 N 个特征向量 \mathbf{a}^r 及相应的特征值 λ^r , 其中 $r = 1, 2, \dots, N(N$ 为监测数据样本数)。将特征值按降序排列,选择较大的 $n(n \leq N)$ 个特征值对应的特征向量作为候选主成分,记 $KP = (\mathbf{a}^1, \dots, \mathbf{a}^n)$ 以及 $\Lambda_{KP} = \text{diag}(\lambda^1, \dots, \lambda^n)$ 。以特征向量 $\mathbf{a}(r = 1, 2, \dots, n)$ 为随机变量,产生种群数为 M 的初始样本 D_0 ,采用二进制编码方式对 n 个特征向量 \mathbf{a}^r 进行编码,编码中的每一位代表对应的特征向量是否被选中,为1表示选中该特征向量,为0表示未选中,编码长度为 n 。初始样本产生过程中,变量为0和1的概率相同。

步骤2 计算适应度值,选择优秀个体 D_l^{se} 。适应度函数

的设计与计算是 KPCA-EDA 算法的关键,通过比较种群中每个个体的适应度值来选择优秀个体进行个体信息统计,为产生新样本奠定统计基础。在 KPCA-EDA 算法中,既要保证选择的主成分包含充足的信息量又要考虑其识别能力,因此设计适应度函数如下:

$$fitness_i = J(KP_i) \times F(KP_i) \quad (6)$$

其中: $J(KP_i)$ 表征所选特征向量的识别能力; $F(KP_i)$ 为约束函数,以使得所选特征向量满足某种约束。下面分别对其含义进行描述。

对任意样本 x_i^j ,经 KPCA 特征降维后 $\tilde{x}_i^j = a^T k(x_i^j, x_i^j) = (KP)^T k(x_i^j, x_i^j)$,第 j 类样本中心 m_j 变为 $\tilde{m}_j = (KP)^T k(x_i^j, m_j)$,全体样本中心 m 变为 $\tilde{m} = (KP)^T k(x_i^j, m)$ 。由于状态监测与评估过程本质上是基于分类思想的,因此在进行主成分选择时,可采用分类概念之中的距离可分性判据进行选择。本文将设计 $J(KP_i)$ 为基于类内—类间距离的可分性判据,分别以类内散度矩阵 S_w 的迹和类间散度矩阵 S_b 的迹来度量类内距离与类间距离,若异类样本之间的距离越大,同类样本之间的距离越小,则识别效果越好。基于类内—类间距离的可分性判据表达式为^[11]:

$$J(KP_i) = \text{tr}(S_b) / \text{tr}(S_w) \quad (7)$$

其中:

$$S_b = \frac{1}{N} \sum_{j=1}^c N_j (\tilde{m}_j - \tilde{m})(\tilde{m}_j - \tilde{m})^T \quad (8)$$

$$S_w = \frac{1}{N} \sum_{j=1}^c \sum_{i=1}^{N_j} (\tilde{x}_i^j - \tilde{m}_j)(\tilde{x}_i^j - \tilde{m}_j)^T \quad (9)$$

$J(KP_i)$ 值越大,表明异类样本之间的距离越大,同类样本之间的距离越小,则该特征组合的识别效果越好。

当 $J(KP_1)$ 和 $J(KP_2)$ 值差不多时(即识别能力相近),应选择对应大特征值较多的个体(即选择包含信息量较多的特征向量),因此设计约束函数 $F(KP_i)$ 如下:

$$F(KP_i) = e^{a(\eta-b)}; a \geq 0, 0 \leq b \leq 1 \quad (10)$$

其中: $\eta = (\sum_{k=1}^m \lambda_{ik}) / (\sum_{j=1}^n \lambda_j)$, m 表示选中的特征向量个数, n 为编码长度,即候选的特征向量个数; b 为 η 的阈值,可根据需要来确定; a 是约束函数的调节系数,它用来调节约束函数在整个适应度函数中的权重,当 a 过小时,EDA 算法寻优过程可能需要的时间更长,并导致约束函数作用减弱;当 a 过大时,EDA 算法会过早收敛以至得不到最优解,因此应根据实际情况选择 a 的大小。

适应度函数设计完成后,便可根据初始种群计算每个个体的适应度值,选择适应度值较大的 Se ($Se \leq M$) 个个体作为优秀个体进行下一步的个体信息统计。

步骤 3 根据优选个体,建立概率模型 $p_i(x)$ 。由于经 KPCA 提取后得到的特征向量之间是统计不相关的,因此选择变量不相关的 UMDA 算法作为 EDA 的概率模型,每个单变量边缘分布由优选个体集中每一位取 1 的频率进行统计,其概率分布表述为:

$$p_i(x) = p(x | D_i^{Se}) = \prod_{i=1}^n p_i(x_i) = \prod_{i=1}^n \frac{\sum_{j=1}^{Se} \delta_j(X_i = x_i | D_i^{Se})}{Se} \quad (11)$$

其中:

$$\sum_{j=1}^{Se} \delta_j(X_i = x_i | D_i^{Se}) = \begin{cases} 1, & X_i = x_i \\ 0, & \text{其他} \end{cases} \quad (12)$$

步骤 4 随机采样。从概率向量 $p_i(x)$ 中采样 M 次,得到

新一代群体 D_{l+1} ,并计算每一个新个体的适应度值。

步骤 5 终止条件判断。若满足终止条件,则进行下一步;否则 $l = l + 1$,返回步骤 2。

步骤 6 输出结果。种群 D_{l+1} 为所求解。

算法流程如图 3 所示。

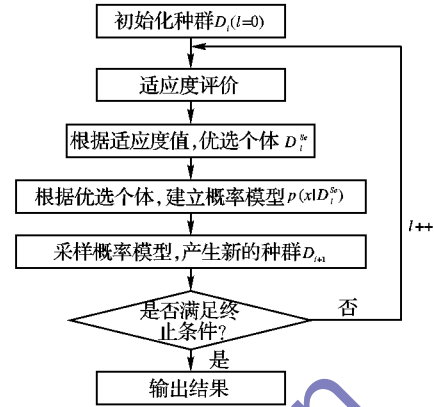


图 3 算法流程

3 某滤波电路仿真验证

以某滤波电路为例验证该监测数据优化算法的有效性,电路如图 4 所示。提取电路幅频响应曲线的各频点幅度为待选特征,在 $[1\text{kHz}, 1\text{MHz}]$ 的区间进行采样,每十倍频采样 10 个点,共采样 31 个特征点^[12]。在正常状态下输出的幅频曲线如图 4 所示。




图 4 正常输出

假设电路发生了单软故障,包括电路无故障, R_1, R_2, C_1, C_2 正负偏 50%, R_3 正偏 50% 共 10 种状态类型。各单软故障类如表 1 所示。




图 5 滤波电路

表 1 单软故障类

故障号	故障类	故障号	故障类
F1	NF	F2	$C_1 = 25\text{nF}$
F3	$C_1 = 75\text{nF}$	F4	$C_2 = 25\text{nF}$
F5	$C_2 = 75\text{nF}$	F6	$R_1 = 150\Omega$
F7	$R_1 = 50\Omega$	F8	$R_2 = 150\Omega$
F9	$R_2 = 50\Omega$	F10	$R_3 = 7.5\Omega$

在正常状态下对电路进行 300 次 Monte-Carlo 仿真,进行小波特征提取后获得 300 个正常状态样本;对于每种故障状态分别进行 10 次 Monte-Carlo 仿真,9 种故障状态下共 90 个样本,进行小波特征提取后可获得 90 个故障状态样本。采用支持向量描述(Support Vector Data Description, SVDD)模型进行状态识别^[13-14],利用 2/3 的正常状态样本作为训练样本集,其余的 1/3 正常状态样本与其他 90 个故障状态样本作为测试样本集。数据优化过程如下:

首先,采用特征空间样本选择算法对训练样本集的 200 个正常状态样本进行样本选择,取逼近距离下界 $\varepsilon = 0.1$ 。优化后的训练样本数量以及优化率如表 2 所示。

表 2 基于特征空间样本选择结果

训练样本	样本个数	选择后样本数	优化率/%
正常类样本	200	97	51.50

然后,对样本优化后的训练样本以及所有测试样本共 287 个样本进行特征优化,每个样本的特征维数为 31。

步骤 1 选择径向基函数作为样本数据的核函数 $k(x_i, x_j)$,计算核矩阵 K 并对其进行中心化处理,得到 \bar{K} 。其中,核参数 $\gamma = 0.5$ 。

步骤 2 计算 \bar{K} 的特征值和相应的特征向量。取累计贡献率达到 98% 时的特征向量作为候选特征向量(共 16 个)。

步骤 3 以候选特征向量为随机变量,产生初始种群数为 150 的初始样本 D_0 。采用二进制编码方式对其进行编码,编码长度为 16。

步骤 4 采用 EDA 算法进行特征向量的优选。其中,适应度函数中 $F(KP_i) = e^{15(\eta-0.98)}$,即 $a = 15, b = 0.98$ 。迭代次数与每一代平均适应度之间的关系如图 6 所示。




图 6 平均适应度随迭代次数变化曲线

从图中可以看出,大约经过 40 次迭代达到了全局最优解,此时适应度值为 32.128。选出的最优个体为 0111101001001010,即第 2、3、4、5、7、10、13、15 个特征向量被选中,特征向量个数为 8。

步骤 5 将样本数据投影到选中的特征向量上,得到优化后的特征提取结果。每个样本特征优化的表达式如式 (13)^[15]所示:

$$y = \frac{1}{\sqrt{\lambda_l}} \sum_{k=1}^N a_k^l k(x_k, x); l \leq N \quad (13)$$

其中: a_k^l 为选中的特征向量, λ_l 为相应特征值。

采用优化后的训练样本集 (97×8 的特征矩阵) 训练 SVDD,然后将优化后的测试样本集 (190×8 的特征矩阵,其中正常状态样本为 100 个,故障状态样本为 90 个) 送入 SVDD 中进行识别,分别记录不同状态下样本的正常识别率、故障识别率以及总识别率,并与不进行优化、KPCA 优化、KPCA-EDA 优化等进行识别率和 SVDD 训练时间的比较,比较结果如表 3 所示。

从表 3 中可以看出:1) 经样本优化后 SVDD 模型的训练

时间大大减少,但对于测试样本的识别率并没有明显的损失,特别是在采用 KPCA-EDA 算法进行特征优化时,样本优化后的正常识别率反而较优化前有所提升;2) 经 KPCA-EDA 优化后无论是正常识别率还是故障识别率均较 KPCA 有所提高,尤其是故障识别率得到了大幅提升,而模型训练时间只是略有增加。因此,综合考虑训练时间与识别率两个因素,本文提出的优化算法(样本优化 + KPCA-EDA)是最有效的。

表 3 不同算法结果比较

不同算法	正常识别率	故障识别率	总识别率	SVDD 训练时间/s
不进行优化	0.8000	0.6667	0.7368	4.204
KPCA	0.9200	0.8444	0.8842	3.043
样本优化 + KPCA	0.9100	0.8333	0.8737	1.033
KPCA-EDA	0.9300	0.9778	0.9526	3.062
样本优化 + KPCA-EDA	0.9400	0.9778	0.9579	1.041

4 结语

本文以 KPCA 算法为基础,研究了监测数据的优化算法。针对 KPCA 的缺点,从两个方面对监测数据进行了优化:通过特征空间样本选择算法对数据样本进行了优化,有效地消除了相似样本,提高了监测模型的泛化能力;通过 KPCA-EDA 算法对样本优化后的监测数据进行了特征优化,有效降低了特征维数,并保留了更多的识别信息,为下一步健康状态监测奠定了基础。在某滤波电路的仿真实验中利用该算法对监测数据进行了优化并与 KPCA 等算法进行了比较,仿真结果表明该算法更有效。

参考文献:

- [1] 孙智信,李自力. 世界电子信息装备[M]. 北京: 国防科技出版社, 2001: 15-28.
- [2] JOLLIFFE I T. Principal component analysis[M]. 2nd ed. Berlin: Springer Series in Statistics, 2002.
- [3] JOHNSON R A, WICHERN D W. Applied multivariate statistical analysis[M]. New York: Prentice Hall, 2001: 55-74.
- [4] 李伟红,龚卫国,陈伟民,等. 基于小波分析与 KPCA 的人脸识别方法[J]. 计算机应用, 2005, 25(10): 2339-2341.
- [5] 肖健华. 智能模式识别方法[M]. 广州: 华南理工大学出版社, 2005: 61-64.
- [6] 姜文瀚. 模式识别中的样本选择研究及其应用[D]. 南京: 南京理工大学, 2007, 26-31.
- [7] 周树德,孙增圻. 分布估计算法综述[J]. 自动化学报, 2007, 33(2): 113-124.
- [8] LARRANAGA P, LOZANO J A. Estimation of distribution algorithms[C]// A New Tool for Evolutionary Computation. Boston: Kluwer Academic Publishers, 2002: 21-25.
- [9] SHAPIRO J L. Drift and scaling in estimation of distribution algorithms[J]. Evolutionary Computation, 2005, 13(1): 100-131.
- [10] 缪志敏,胡谷雨,丁力,等. 分布估计的粒子群算法的研究与应用[D]. 广州: 中山大学, 2008: 24-28.
- [11] VAPNIK V N. The nature of statistical learning theory[M]. New York: Springer-Verlag, 1995: 24-46.
- [12] 潘志松,陈斌,缪志敏. One-Class 分类器研究[J]. 电子学报, 2009, 37(11): 2496-2503.
- [13] 李瑜,郑敏娟,程国建. 基于支持向量数据描述的分类方法研究[J]. 计算机工程, 2009, 35(1): 235-237.
- [14] BAUDAT G, ANOUAR F. Generalized discriminant analysis using a kernel function[J]. Neural Computing, 2000, 12(10): 2385-2404.
- [15] VAPNIK V N. Statistical learning theory[M]. New York: Addison Wiley, 1998: 32-57.