

人脸确认的动态支持向量数据描述方法

肖健华

(五邑大学智能技术与系统研究所, 广东江门 529020)

摘要 人脸的确认实质上是一个一类分类问题或野点检测问题,即只需要精确地描述某一类样本的分布,而将该类样本之外大范围内的样本点视为野点。为了能精确地描述某一类样本的分布,在对国内外现有统计学习理论和核方法进行研究的的基础上,针对“人脸确认”这一特定的应用对象,分析了已有的一类分类算法,即支持向量数据描述方法在处理动态样本中存在的不足,进而指出,随着训练样本数目的增加,该算法会因为过大的优化规模而无法实际操作,为此提出了用于人脸确认的动态支持向量数据描述算法。由于新算法在优化过程中,仅需要考虑待检测样本和原有支持向量集,从而可以大大降低优化过程中涉及的运算规模和内存需求,进而可保证人脸确认过程中的实时性与动态性要求。

关键词 数据描述 人脸确认 核方法 野点

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2006)01-0019-07

A Dynamic Support Vector Data Description Algorithm Applied to Face Verification

XIAO Jian-hua

(Institute of Intelligent Technology & Systems, Wuyi University, Jiangmen, Guangdong 529020)

Abstract Face verification is essentially a problem of one-class classification or outlier detection. Its goal is to accurately describe one class of objects opposing to a wide range of other objects considered as outliers. Based on the existing research work on statistical learning theory and kernel methods, this paper analyses the drawbacks of a existing one-class classification algorithm, namely support vector data description (SVDD), on dealing with dynamic samples of face verification. This paper points out that, with the increase of samples, the size of optimization will exceed the memory space of the computer. Consequently, the algorithm will be unable to carry out. For the purpose of reducing the size of optimization, the dynamic support vector data description algorithm (DSVDD) is proposed. The new algorithm only computes the new samples and support vectors in the process of optimization, so that the required operation size and memory space can be reduced in a great degree, which means the real-time and dynamic demands are met for face verification.

Keywords data description, face verification, kernel methods, outlier

1 引言

身份的自动确认指的是利用计算机验证用户是否为他所声明的身份。目前身份确认技术在罪犯身份认定、监控装置与门禁系统、驾驶执照与护照等的

核对等很多方面得到了越来越广泛的应用。现有的身份确认技术主要基于以下几种信息:(1)持有物,如各种证件;(2)所了解的信息,如口令或密码;(3)生物特征,如指纹、掌纹、声音、人脸等。

在已有的身份确认技术中,人脸确认最受关注,因为,作为生物特征识别技术的一种,人脸确认技术

基金项目:广东省自然科学基金项目(032353);国家自然科学基金资助项目(70471074)

收稿日期:2004-12-30;改回日期:2005-05-09

第一作者简介:肖健华(1970 ~),男,副教授。中国自动化学会智能自动化专业委员会委员,2002年于华中科技大学机械制造及其自动化专业获工学博士学位,目前主要从事智能信息处理的研究工作,发表论文40余篇。E-mail: jianhuaxiao@tom.com

不会像密码那样容易被忘记和破解,也不会像持有物那样容易被窃取或转移,所以基于生物特征的身份确认更加可靠^[1]。同时,与其他生物识别技术相比,通过人脸确定身份对用户最无侵害性,也是最自然和最直观的方式。

现有的人脸确认技术往往是建立在对人脸特征进行有效提取的基础上,利用模式识别手段,诸如 Fisher 判决、神经网络、支持向量机等来对人脸进行识别与判定。

实际上,从模式识别的角度考虑,人脸的确认可视为一种特殊的分类问题,即一类分类问题(one-class classification problem),也称为数据描述或野点检测。在这类分类问题中,分类的目的是如何精确地描述一类样本,即目标类或正类,而与之相反的大范围内的样本点则被视为野点^[2]。

目前野点检测方法已经有很多种,如统计学方法^[3]、基于距离的检测方法^[4]、神经网络方法^[5]、基于边界的方法,等等。统计学习理论^[6]出现后,基于边界的野点检测方法更受到重视,由 Tax 等人提出的支持向量数据描述(support vector data description, SVDD)方法为野点检测提供了全新的研究途径^[2],本文即是在此基础上展开的。

2 SVDD 方法

2.1 基于边界的野点检测方法

基于边界的野点检测方法的目标是寻找包含全体正类样本(positive sample)的最小球体,球体外即为野点区域。对于正类样本集

$$\Omega = \{x_1, x_2, \dots, x_N\} \quad (1)$$

$x_i \in \mathbf{R}^d, i = 1, 2, \dots, N, \mathbf{R}^d$ 表示 d 维实数空间。设完全包围 Ω 中的全体样本的最小球体半径为 R , 球心为 a , 则满足优化方程

$$\min L(R) = R^2 \quad (2)$$

$$\text{s.t. } R^2 - (x_i - a)(x_i - a)^T \geq 0 \quad (3)$$

由式(2)和式(3)可定义如下的 Lagrange 函数

$$L(R, a, \Lambda) = R^2 - \sum_{i=1}^N \alpha_i \{R^2 - (x_i - a)(x_i - a)^T\} \quad (4)$$

式中, $\Lambda = \{\alpha_i\}, \alpha_i$ 为 Lagrange 系数, $\alpha_i \geq 0 (i = 1, \dots, N)$ 。将式(4)对半径 R 和球心 a 求偏微分,并令它们等于 0, 可得

$$\sum_{i=1}^N \alpha_i = 1 \quad (5)$$

$$a = \sum_{i=1}^N \alpha_i x_i \quad (6)$$

将式(5)和式(6)代入式(4), 稍作变换, 即有优化方程

$$\max L = \sum_{i=1}^N \alpha_i (x_i \cdot x_i) - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j (x_i \cdot x_j) \quad (7)$$

$$\text{s.t. } \sum_{i=1}^N \alpha_i = 1 \quad \alpha_i \geq 0 \quad (8)$$

实际上, 根据 KT(Kuhn-Tucker) 条件, Λ 中大部分元素为 0, 只有一小部分 $\alpha_i > 0$, 而与这些 α_i 对应的样本点就决定了边界的构成, 这些数据称为支持向量。

若已知 Λ , 则由式(6)即可求出球心 a , 而任选一支持向量 x_s , 则由式(9)就可求出 R

$$R^2 - (x_s - a)(x_s - a)^T = 0 \quad (9)$$

对于待测试数据 z , 令

$$\begin{aligned} f(z) &= (z - a)(z - a)^T \\ &= (z \cdot z) - 2 \sum_{i=1}^N \alpha_i (z \cdot x_i) + \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j (x_i \cdot x_j) \end{aligned} \quad (10)$$

则依据下式可判断 z 是否为野点

$$\begin{cases} f(z)/R^2 \leq 1 & z \text{ 不为野点} \\ f(z)/R^2 > 1 & z \text{ 为野点} \end{cases} \quad (11)$$

2.2 SVDD 方法

考虑图 1 所示正类样本点分布, 利用基于边界的野点检测方法所求得的边界列于图 1(a)中, 图中用小圆圈圈起的点为支持向量, 从图 1(a)中可见, 由于采用球形边界形状单一, 且边界区域显得过大, 不够紧密, 因此所形成的区域容易进入野点范围。

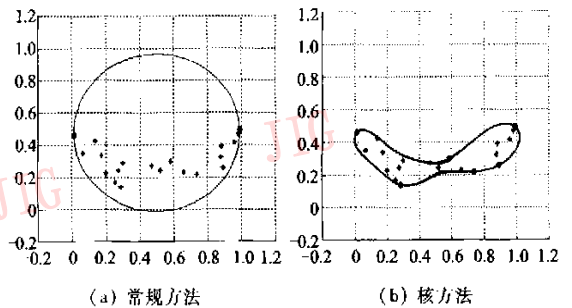


图 1 正类域边界的形成方法

Fig. 1 Borderline of the positive region

为此, 若在式(7)中引入核变换 $(x \cdot y) \rightarrow K(x, y)$, 则在属性空间中的优化方程为

$$\max L = \sum_{i=1}^N \alpha_i K(x_i, x_i) - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(x_i \cdot x_j) \quad (12)$$

且约束条件不变。通过对上式的求解即可获得 α_i ($i=1, 2, \dots, N$) 以及相应的支持向量。

进一步, 根据 KT 条件, 对应于 $0 < \alpha_i < C$ (C 为折中系数^[2]) 的样本必然满足

$$R^2 - (K(x_i, x_i) - 2 \sum_{j=1}^N \alpha_j K(x_j, x_i) + (a \cdot a)) = 0 \quad (13)$$

其中, $a = \sum_{i=1}^N \alpha_i \varphi(x_i)$ 。此时判别函数式(式(10))变为

$$f(z) = K(z, z) - 2 \sum_{i=1}^N \alpha_i K(z, x_i) + \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(x_i, x_j) \quad (14)$$

其野点判别方法同式(11), 上述过程即为 SVDD 方法^[2]。

仍用图 1(a) 中数据, 现采用核方法求其正类域范围。由图 1(b) 可看出, 先通过选择适当的核函数及相应的参数, 然后采用核方法求出的正类区域非常紧致, 由此可见, 核方法具有更为优秀的野点识别能力。此外, 在一定范围内, 采用核方法确定正类域边界还能排除干扰样本的影响^[7]。

3 动态支持向量数据描述方法

3.1 人脸确认过程中的动态性

由于多方面的原因, 使得人脸图像具有动态性^[8], 即①人脸随年龄的增长而变化; ②人脸表情丰富; ③人脸所成图像受光照、成像角度及距离等影响。正因为人脸图像的动态性, 使得人脸确认和人脸识别成为模式识别领域中的一个极富挑战性的课题, 也就是说, 人脸图像的动态性对人脸确认技术提出了相应的要求。基于野点检测的人脸确认技术如图 2 所示。

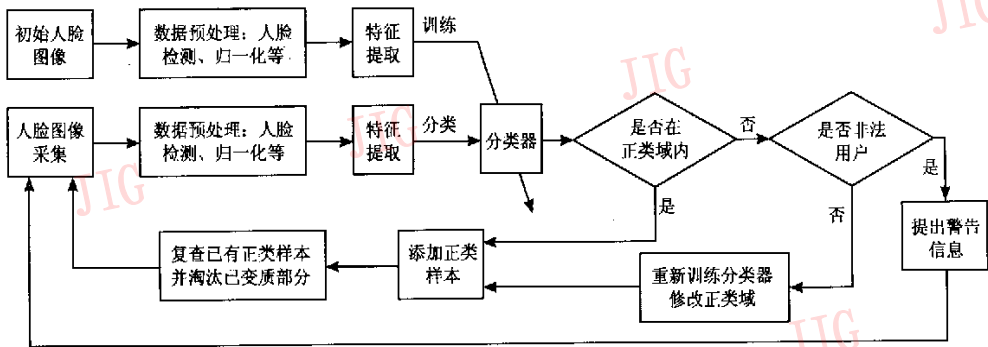


图 2 基于野点检测的人脸确认技术示意图

Fig. 2 Flow chart of face verification based on novelty detection

从图 2 不难发现, 随着时间的推移, 正类样本在数量上有两种变化趋势, 即, 一是新的人脸图像不断添加进来; 二是随着时间的推移, 由于人脸图像可能会产生较大的变化, 使原有的一些正类图像不能继续使用, 因此这部分图像有必要从正类样本中淘汰出去。在使用时间不是很长的情况下, 样本数量增加的趋势占了绝对的主导地位, 这样对分类器的训练所涉及的优化规模也就不断扩大, 最终, 必然导致该算法难以实现。

3.2 动态支持向量数据描述方法

在确定正类域范围时, 最理想的情况是希望增加一个样本后的正类域仅与该样本和前一次的支持向量相关, 即对式(1)所示的样本集 Ω , 设其在某种核函数的作用下, 求得的支持向量集用 U 表示, 则

形成的新边界为 $\hat{\zeta}$ 。若将新的正类样本 x_{N+1} 加入到样本集 Ω 中, 则形成新的正类样本集 $\hat{\Omega}$

$$\hat{\Omega} = \{x_1, x_2, \dots, x_N, x_{N+1}\} \quad (15)$$

在同样的核函数作用下, 设求得的支持向量集用 \hat{U} 表示, 则形成的新边界为 $\hat{\zeta}$ 。理想情况下可表示为

$$\hat{U} \subseteq U \cup \{x_{N+1}\} \quad (16)$$

此时, 边界 $\hat{\zeta}$ 或完全包含边界 ζ , 或与边界 ζ 完全相同。本文称这种边界为理想边界。

实际上, 这种理想情况在大多数情况下是不成立的, 如图 3(a) 所示, 加入正类样本 x_{N+1} 前后的两个边界显然不存在包含或相同关系, 同时存在数据样本由非支持向量转为支持向量的情况, 如图中带圆圈的实心点所示。

图 3(b) 为采用折线按一定方式形成边界的情




图 3 增加一个样本对正类域边界和支持向量的影响

Fig. 3 The influence on the borderline and SVs by adding a sample

况,图中细折线和粗折线分别表示加入正类样本 x_{N+1} 前后的两个边界,从图中不难看出,不论是边界

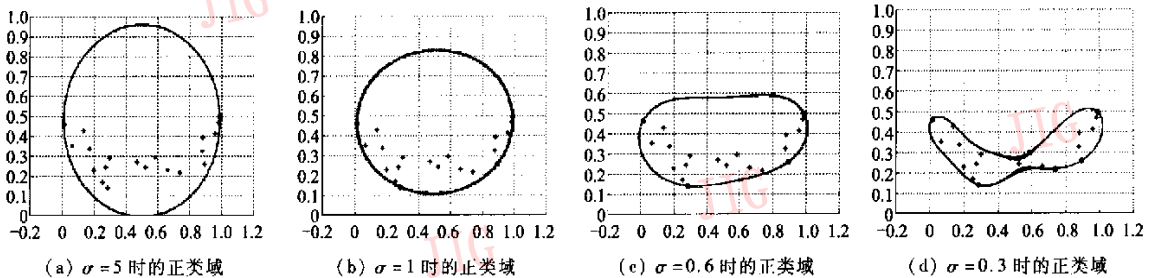


图 4 参数 σ 对正类域边界和支持向量的影响

Fig. 4 The influence on the borderline and SVs with the parameter σ

有了上面关于理想边界构成近似方法的讨论,便可得到动态支持向量描述方法(dynamic support vector data description algorithm, DSVDD),该方法就是首先对初始样本进行优化,形成初始支持向量集和正类域边界;然后对测试样本依式(11)判断该样本是否为野点,若测试点为野点,则进一步判断是否为正类样本,若是,则将新增测试样本与当前支持向量集一起,形成训练样本集,并对训练样本集依式(12)进行优化,以获取新的支持向量集和正类域边界。DSVDD算法的具体步骤为

(1) 初始化正类区域

① 输入初始样本数据集 $\Omega = \{x_1, x_2, \dots, x_N\}$;

② 采用 SVDD 方法,由式(12)和式(13)构造初始正类区域,并获得支持向量集 U 。

(2) 是否退出野点检测? 若是,退出;否则,执行步骤(3)。

(3) 输入新样本点 z ,由式(14)计算 $f(z)$ 。

(4) 判断 $f(z) \leq R^2$ 是否成立

的包含关系还是支持向量的组成情况,都符合理想情况的要求。考虑到,目前虽还没有有效的优化算法用来形成由折线(平面)构成的封闭区域,但可以使用其他函数来逼近,使得支持向量之间近似以折线(平面)方式连接。

重新使用图 1 所示的数据,通过调整高斯径向基核函数中参数 σ 值的大小来比较所取得的效果(如图 4 所示)。图 4(a)~图 4(d)表明,随着参数 σ 的减小,正类域范围不断缩小,支持向量数目则不断增加。考察图 4(d)不难发现,它具有近似图 3(b)的性能。当然,参数 σ 也并不是越小越好,过小的 σ 则会造成正类域分成很多个互不相通的小区域,甚至会出现一个支持向量成为一个正类域的极端情况^[7]。

① 若成立,则 z 不是野点,转步骤(2);

② 若不成立,则 z 为野点,转步骤(5)。

(5) 判断样本点 z 是否为正类样本

① 若是,即 $\Omega = U \cup \{z\}$,则采用 SVDD 方法,由式(12)和式(13)来构造新的正类区域,并获得新的支持向量集 U ,转步骤(2);

② 若不是,则发出警告信息,转步骤(2)。

需要指出的是,其中第 5 步正类样本的判断,通常要通过人机交互的方式进行。

从上面的讨论不难发现,DSVDD 算法可以仅对较少的样本进行优化操作,并可获取相对紧凑的正类域范围,最终即可实时实现对野点的动态检测。

4 DSVDD 在人脸确认中的应用

4.1 一个仿真算例

仿真时,首先依图 5 所示的封闭曲线形成 300 个正类样本,并使封闭曲线内样本点出现的概率相

等,这条封闭曲线本身也是以下各种情况下的期望正类域范围;然后采用以下两种方法来求取不同样本数目下的正类域边界:一是在式(12)中对当前为止所采集的所有样本进行优化操作;二是采用DSVDD方法,即仅对当前样本和上一次优化获得的支持向量进行优化操作。




图 5 样本数据采样区间
Fig. 5 The sampling space

持向量集;以 $\text{card}(X)$ 表示任一集合 X 中元素的个数,则

$$O_{t+1}^{(1)} = \{x_1, x_2, \dots, x_t, x_{t+1}\} \quad (17)$$

$$O_{t+1}^{(2)} = \{S_t, x_{t+1}\} \quad (18)$$

由于存在一个较大时刻 t_0 , 当 $t > t_0$, 必然有

$$\text{card}(S_t) \ll \text{card}(O_t^{(1)}) = t \quad (19)$$

因此

$$\text{card}(O_{t+1}^{(2)}) \ll \text{card}(O_{t+1}^{(1)}) = t + 1 \quad (20)$$


由此可见,DSVDD方法大大减少了运算规模。更为重要的是, $\text{card}(O_t^{(2)})$ 不是单调递增,而是在一个区域中振荡,但其总体增加速度越来越缓慢。

图 6(a)、图 6(c)和图 6(e)对应第 1 种方法,即对全体样本进行优化的情况下,样本数目分别为 20, 100, 300 个样本时的正类域区间,优化中采用


$$K(x, y) = \exp(-\|x, y\|^2/0.09) \quad (21)$$

作为核函数;图 6(b)、图 6(d)和图 6(f)对应 DSVDD 算法,即只对前次支持向量和当前采样数据进行优化。


以 $O_t^{(1)}$ 和 $O_t^{(2)}$ 分别表示 t 时刻两种不同方式下边界形成中待优化的样本集; S_t 表示 t 时刻的支




(a) 数目为 20 全体样本优化形成的边界




(b) 数目为 20 DSVDD 方法形成的边界




(c) 数目为 100 全体样本优化形成的边界



(d) 数目为 100 DSVDD 方法形成的边界



(e) 数目为 300 全体样本优化形成的边界



(f) 数目为 300 DSVDD 方法形成的边界

图 6 两种边界构成方式比较

Fig. 6 A comparison of the two methods used to form borderlines

从图 6 中看出,在样本点数目较少时,两种方法形成的边界可能存在较大的差异,但是随着样本数目的增加,两者之间的差异逐渐消失,另外,DSVDD 方法每次需要进行优化的样本数目随样本总体数目的增加变化不大,如总体样本数目为 20 个时,需优

化的数目为 7 个,总体样本数目为 100 个时,需优化的数目为 14 个,总体数目为 300 个时,需优化的数目为 13 个,即 DSVDD 方法中需优化的样本数目对样本总体数目不敏感,而是与样本空间维数关系更大些,这一特性就保证了实时监测的可操作性。

4.2 DSVDD 在人脸确认中的应用

下面以目前广泛应用的 ORL 人脸图像数据库为例来说明 DSVDD 在人脸确认中的应用。ORL 图像库中图像的分辨率为 112×92 , 可将其一行接一行地展开为 10304 维列向量^[9]。

由于本文讨论的是人脸的确认问题, 因此, 这里只选用第 1 个人的 10 个样本和第 2 个人的 2 个样本进行实验。整个实验过程如下:

(1) 以第 1 个人的前 8 幅图像作为初始人脸图像, 实验采用高斯径向基函数

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2/5000) \quad (22)$$

作为核函数, 同时利用核主成分分析 (kernel principle component analysis, KPCA) 来提取主成分^[10], 并依贡献率大小选出 4 个主成分, 即可进行非线性特征提取。

(2) 以高斯径向基函数

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2/0.001) \quad (23)$$

作为核函数, 同时依式 (12) 进行优化来求出对应的

半径 R 值和 Lagrange 参数 $\alpha_i (i = 1, 2, \dots, 8)$ 的值, 并确定相应的支持向量。

(3) 对剩下的 4 个样本, 每次输入一个样本, 再依次完成如下操作

① 采用 KPCA 方法来提取新输入测试样本 \mathbf{z} 的 4 个主成分;

② 依式 (14), 以式 (23) 为核函数来计算测试样本的 $f(\mathbf{z})$ 值;

③ 根据式 (11), 判断测试样本 \mathbf{z} 是否为野点, 若不是, 则返回步骤 3, 否则进行下一步操作;

④ 判断测试样本是否为非法用户, 若是, 返回步骤 3, 否则进行下一步操作;

⑤ 将以主成分表示的测试样本与前次的支持向量一起形成训练样本集, 同时以式 (23) 作为核函数, 并依式 (12) 进行优化来求出对应的半径 R 值和 Lagrange 参数 $\alpha_i, i = 1, 2, \dots, 8$ 值, 并确定相应的支持向量, 返回步骤 (3)。

整个实验结果如表 1 所示。

表 1 实验步骤与相应的结果

Tab. 1 Test procedures and corresponding results

步骤	$f(\mathbf{z})/R^2$ 是否大于 1	支持向量个数	是否野点	是否非法用户	下一步操作
1	否	6	否	否	返回第 3 步, 输入下一个样本
2	是	6	是	否	执行 3-⑤步, 重新优化, 然后输入下一个样本
3	是	7	是	是	返回第 3 步, 输入下一个样本
4	是	7	是	是	返回第 3 步, 输入下一个样本

在 3-④步中, 有以下两种方法可以用于确定一个野点是否为非法用户: 一是通过人工干预的方法; 二是设置一定的阈值, 如

$$\begin{cases} f(\mathbf{z})/R^2 \leq m & \mathbf{z} \text{ 不为非法用户} \\ f(\mathbf{z})/R^2 > m & \mathbf{z} \text{ 为非法用户} \end{cases} \quad (24)$$

式中, m 为一大于 1 的值, 如 $m = 2$ 。

5 结 论

本文以人脸确认为应用对象, 针对 SVDD 方法在处理动态、实时野点检测问题中存在的不足, 提出了 DSVDD 方法。这种 DSVDD 方法可大大地降低野点检测过程中对运行时间和内存的需求。

由于 DSVDD 算法的核心思想是为某一正类样本形成动态的正类域, 因此, 若对式 (12) 改进, 使之

形成多个正类区域, 则可以将之应用到人脸识别中, 此即所谓的多类分类问题。

当然, 由于受到核方法体系研究进展的限制, 因此 DSVDD 方法还有待于进一步的发展与完善, 其主要是优化方程中核函数的选择及相关参数的确定, 到目前为止, 还主要依赖于应用者的经验和不断地试凑。

参考文献 (References)

- SUN Dong-mei, QIU Zheng-ding. A Survey of the Emerging Biometric Technology [J]. Acta Electronica Sinica (A), 2001, 29 (12): 1744 ~ 1748. [孙冬梅, 裴正定. 生物特征识别技术综述 [J]. 电子学报 (A), 2001, 29 (12): 1744 ~ 1748.]
- Tax D J, Ypma A, Duin R W. Support vector data description applied to machine vibration [A]. In: Proceedings 5th Annual Conference of the Advanced School for Computing and Imaging [C],

- Heijen, NL, USA, 1999:398 ~ 405.
- 3 Fox A J. Outliers in time series[J]. *Journal of the Royal Statistical Society, Series B*, 1972, **34**(3): 350 ~ 363.
 - 4 Knorr E M, Ng R T. Algorithms for finding distance-based outliers in large datasets[A]. In: *Proceedings of 24th International Conference of Very Large Data Bases [C]*, New York, NY, USA: Morgan Kaufmann Publishers, 1998:392 ~ 403.
 - 5 Albrecht S, Busch J, Kloppenburg M, *et al.* Generalized radial basis function networks for classification and novelty detection: self-organisation of optimal Bayesian decision [J]. *Neural Networks*, 2000, **13**(10):1075 ~ 1093.
 - 6 Vapnik V N. *Statistical Learning Theory*[M]. New York: Wiley, 1998.
 - 7 XIAO Jian-hua. Research on intelligent approach to feature extraction and pattern classification for device running state [D]. Ph. D. dissertation. Wuhan: Huazhong University of Science and Technology, 2002. [肖健华. 机械设备运行状态特征提取与模式分类中的智能方法研究[D]. 博士学位论文. 武汉:华中科技大学, 2002.]
 - 8 ZHANG Cui-ping, SU Guang-da. Human face recognition: A survey [J]. *Journal of Image and Graphics*, 2000, **5**(11):886 ~ 894. [张翠平, 苏光大. 人脸识别技术综述[J]. *中国图象图形学报*, 2000, **5**(11):886 ~ 894.]
 - 9 SUN De-shan. The research on support vector machine classification and regression methods[D]. Ph. D. dissertation. Changsha: Central South University, 2004. [孙德山. 支持向量机分类与回归方法研究[D]. 博士学位论文. 长沙:中南大学, 2004.]
 - 10 Mika S, Schölkopf B, Smola A, *et al.* Kernel PCA and De-noising in feature spaces [A]. In: *Advances in Neural Processing Systems* (11), 1999:536 ~ 542. [EB/OL]. <http://citeseer.ist.psu.edu/mika99kernel.html>