

中图法分类号: TP391.4 文献标志码: A 文章编号: 1006-8961(2012)01-0137-05
论文引用格式: 于红芸, 姜涛, 关键. SAR 图像的快速核主成分分析识别方法 [J]. 中国图象图形学报, 2012, 17(1): 137-141

SAR 图像的快速核主成分分析识别方法

于红芸^{1,2}, 姜涛³, 关键¹

1. 海军航空工程学院信息融合研究所, 烟台 264001; 2. 鲁东大学数学与信息学院, 烟台 264025;
3. 海军航空工程学院兵器科学与技术系, 烟台 264001

摘要: 提出一种基于张量代数的核主成分分析方法来进行特征提取。该方法可以有效避免维数过高导致计算消耗过大, 并合理利用已知训练样本的类别信息。算法先对每一类目标使用核主成分分析手段以形成其各自的特征空间; 再通过张量积将所有的特征映射到一高维线性空间; 随后直接在此空间上进行线性的主成分分析, 即可构造出了适宜的特征空间。其既能有效反映各类样本特征, 又能比直接使用核主成分的方法极大降低计算所需的消耗。目标识别实验表明, 该方法与直接使用核主成分方法构造特征空间的方法进行比较, 在保持识别效果的前提下, 可以明显降低计算的消耗与存储的需求。

关键词: 核主成分分析; 张量代数; 目标识别; 合成孔径雷达图像

SAR images recognition based on kernel principal component analysis

Yu Hongyun^{1,2}, Jiang Tao³, Guan Jian¹

1. Research Institute of Information Fusion, Naval Aeronautical Engineering Institute, Yantai 264001, China;
2. School of Mathematics and Information, Ludong University, Yantai 264025, China;
3. Department of Ordnance Science and Technology, Naval Aeronautical Engineering Institute, Yantai 264001, China

Abstract: A kernel principle component analysis method based on tensor algebra is proposed for feature extraction. It can reduce the huge computation cost due to increasing dimensions, while considering the information of known classes. First the kernel principle component analysis method is applied to each class of targets to build their corresponding feature spaces. Then the collection of feature spaces is unified into a higher dimensional space after introducing the operation of the tensor product. Hence a linear principle component analysis method can be directly applied on this feature space in order to construct the proper feature space to both reflect the characters of each class and lower the cost of computation. The recognition experiments showed that the cost of computation and memory can be decreased heavily compared to the approach that builds the feature space by using the kernel principle component analysis method directly.

Key words: kernel principle component analysis (KPCA); tensor algebra; automatic target recognition; SAR

0 引言

核主成分分析(KPCA)是在主成分分析(PCA)

基础上发展起来的。其基本思想是先将原始输入样本通过一个非线性变换映射到一个高维线性空间, 继而在高维空间中进行线性的主成分分析, 这样可以解决原始图像线性特征空间不易得到的情形。

收稿日期: 2011-01-04; 修回日期: 2011-04-28

基金项目: 国家自然科学基金项目(60672140); 全国优秀博士学位论文作者专项基金项目(200237); 教育部新世纪优秀人才支持计划资助项目(NCET-05-0912)

第一作者简介: 于红芸(1971—), 女, 讲师, 现为海军航空工程学院信息融合研究所信号与信号处理专业博士研究生, 主要研究方向为图像处理、目标检测和模式识别。E-mail: xiaofish_er@163.com

所以这类 KPCA 方法应用广泛,如不仅用于人脸识别和遥感分类等领域,近年还用于合成孔径雷达(SAR)图像的识别^[1-3]。

核函数参数的选取和计算是核方法的关键。由于核投影方法本身的性质无法知道样本在非显式映射后变成了什么分布模式。核函数中参数的选取没有相应选择标准,大多数只能采取经验参数选取;不适合训练样本很多的情况,原因是经过核映射后,样本的维数等于训练样本的个数,如果训练样本数目很大,核映射后的向量维数将会很高,并将遇到计算量上的难题。在以往的算法中都是将所有的样本放在一起进行非线性映射。这样在映射后的高维空间,无法确定其分布模式。为避免“维数灾难”,KPCA 用满足 Mercer 条件的核函数替换特征空间中样本的内积运算。通常的做法为预先给定一个核函数的集合,继而视问题的需要筛选出满意的某一核函数。这一筛选过程原则上采用基于训练样本的监督学习方法。在标准的核主成分计算过程中,需要储存所有数据形成的 Gram 矩阵,其空间复杂度为 $O(n^2)$,其中 n 表示样本数。另外,对 Gram 矩阵进行特征分解的时间复杂度为 $O(n^3)$ ^[4]。可以看出,核函数矩阵的维数受训练样本的数量制约:当训练样本数目过大时,核矩阵维数就会很大;如果训练样本数目过小,则很难保证特征提取的理想效果。针对大数据集的情形降低计算复杂度,研究者提出了几类改进方法:通过采样训练集而近似求解特征向量的“贪婪”的核主成分分析方法^[5];使用广义 Hebbian 算法对核空间迭代的求解进行扩展以避免储存问题^[6]。前种方法对算法空间复杂度(即存储要求)的降低仍不理想;后种方法的收敛性不能保证。

本文基于张量代数的基础上提出一种快速计算核矩阵的方法,简称 TAKPCA 方法。其主要思想是:假设共有 n 类物体,首先将每一类样本通过非线性变换分别映射到 n 个高维线性空间,记为 H_n ,核矩阵记为 K_n ,再将这 n 个线性空间进行 n 重的线性映射到高维的线性空间记为 H ,核矩阵记为 K 。 H 空间进行线性主成分分析主要就是对核矩阵 K 进行 SVD 分解。通过多重线性代数的性质,有 $H = H_1 \otimes H_2 \otimes \dots \otimes H_n$,由再生核理论有 $K = K_1 \otimes K_2 \otimes \dots \otimes K_n$,此时对核矩阵的奇异值分解就转化成分别对 H_1 到 H_n 空间的核矩阵 K_1 到 K_n 的分解了。由于 H_n 是由每类样本所组成的空间,很显然

K_n 的计算量要明显低于所有样本组成的空间。实验中将每一类的样本进行单独映射,映射后尽量使得类内散布矩阵较小,也就是使得映射后的样本在新的子空间中尽量集中在一起。这样也就相对解决了核函数中参数的选择问题。本文利用美国实测 MSTAR(运动和静止目标获取与识别)切片数据^[7]对方法进行仿真实验,实验结果表明,该方法是切实可行的。

1 基于张量代数的核主成分分析

1.1 矩阵的张量计算

定理 1 针对矩阵的张量计算列出基本性质^[8]

如果 A 和 B 分别是 $m \times n$ 和 $p \times q$ 的矩阵,则

$$1) (A \otimes B)^T = A^T \otimes B^T.$$

$$2) (\lambda A) \otimes B = \lambda(A) \otimes B = A \otimes (\lambda B).$$

3) 如果 A 和 B 是非奇异的,则

$$(A \otimes B)^{-1} = A^{-1} \otimes B^{-1}.$$

$$4) \text{tr}(A \otimes B) = \text{tr}(A) \otimes \text{tr}(B).$$

5) 如果 A 和 B 都是正交矩阵,则 $A \otimes B$ 也是正交矩阵。

6) $(A \otimes B)(C \otimes D) = (AC) \otimes (BD)$,对 $\forall A \in C^{m \times n}, \forall B \in C^{p \times q}, \forall C \in C^{n \times k}, \forall D \in C^{q \times r}$ 。

定理 2 特征值、特征向量的张量合成关系

假设 $\sigma(B)$, $\sigma(C)$ 和 $\sigma(B \otimes C)$ 分别是 B , C 和 $B \otimes C$ 的特征值。如果 $\lambda \in \sigma(B)$ 并且 b 是与之对应的特征向量;如果 $\mu \in \sigma(C)$ 并且 c 是与之对应的特征向量,那么一定有

$\lambda\mu \in \sigma(B \otimes C)$ 并且 $b \otimes c$ 是与之对应的特征向量。另外,如果

$$\sigma(B) = \{\lambda_1, \lambda_2, \dots, \lambda_{n_1}\}$$

且 $\sigma(C) = \{\mu_1, \mu_2, \dots, \mu_{n_2}\}$

则 $\sigma(B \otimes C) = \{\lambda_i \mu_j; i=1, \dots, n_1; j=1, \dots, n_2\}$ 。

1.2 基于张量代数的核主成分分析算法

前述指出, KPCA 之核矩阵计算的消耗与训练样本的个数有关。假设训练样本个数是 n 个,则产生的核函数矩阵 K 的维数为 $n \times n$,对于 K 矩阵进行特征值分解或者求逆,其计算的时间复杂度为 $O(n^3)$,内存使用对应的空间复杂度是 $O(n^2)$ 。然而,通过多重线性代数中的张量积运算,能够将核函数矩阵 K 变成两个核函数矩阵 K_1, K_2 ,其中, K_1 的维数为 $n_1 \times n_1$, K_2 的维数为 $n_2 \times n_2$, $n = n_1 + n_2$,计算的时间复杂度遂变为 $O(n_1^3) + O(n_2^3)$ 。另外,

空间复杂度是 $O(n_1^2) + O(n_2^2)$ 。当 n 较大时, 会有效地降低计算的时间复杂程度。下面, 以样本空间中存在两类不同的训练数据 T_1 和 T_2 的情形, 说明算法的思想。

1) 对每类训练集进行核主成分分析

设根据 T_1 中的训练样本数据得到的特征空间 H_1 对应的变换为 φ_1 。则对与 T_1 中任意样本 $x_i, i = 1, \dots, n_1$, 其变换后的结果为 $\varphi_1(x_i)$ 。同样, 设由 T_2 的训练样本数据得到的特征空间 H_2 对应的变换为 φ_2 , 则将 T_2 中任意样本 $y_j, j = 1, \dots, n_2$, 被变换为 $\varphi_2(y_j)$ 。并假设它们在各自特征空间中已被中心化, 即满足

$$\sum_{i=1}^{n_1} \varphi_1(x_i) = 0 \quad \sum_{j=1}^{n_2} \varphi_2(y_j) = 0 \quad (1)$$

2) 通过张量积合成每个特征空间

对 H_1 和 H_2 两个空间进行张量积运算, 即从 $H_1 \times H_2 \rightarrow H$ 的双线性映射, 可得到一个新的空间 H 。将该空间作为使用所有训练数据后形成的高维样本空间。

3) 在该空间进行主成分分析

利用张量积的性质, 给出通过每个特征空间的特征向量, 求取 H 的主成分分析所需的协方差矩阵 C 的特征向量集合 $\{v\}$ 的方法。

对于 H 空间, 训练样本的协方差矩阵为

$$C = \frac{1}{n_1 n_2} \times \sum_{j=1}^{n_2} \sum_{i=1}^{n_1} (\varphi_1(x_i) \otimes \varphi_2(y_j)) (\varphi_1(x_i) \otimes \varphi_2(y_j))^T \quad (2)$$

由定理 1 的性质 1) —5) 可得

$$C = \frac{1}{n_1 n_2} \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} (\varphi_1(x_i) \varphi_1(x_i)^T) \otimes (\varphi_2(y_j) \varphi_2(y_j)^T) \quad (3)$$

对应有 C 的特征方程为

$$\lambda v = Cv \quad (4)$$

根据定理 2 表示的再生核关系, 特征向量 v 一定位于由 $\varphi_1(x_i) \otimes \varphi_2(y_j)$ 张成的空间内, 即 v 可以由 $\varphi_1(x_i) \otimes \varphi_2(y_j)$ 的线性组合表示为

$$v = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \alpha_i \beta_j (\varphi_1(x_i) \otimes \varphi_2(y_j)) \quad (5)$$

式中 α_i, β_j 为常数。

设 H_1 对应的核矩阵为 $K_1, n_1 \times n_1$ 维; H_2 对应的核矩阵为 $K_2, n_2 \times n_2$ 维的矩阵。

$$K_1 = \varphi_1(x_i)^T \varphi_1(x_i), \quad K_2 = \varphi_2(y_j)^T \varphi_2(y_j) \quad (6)$$

类似的, 可假定 H 空间对应初始的样本空间, 存在一个 $(n_1 \times n_1) \times (n_2 \times n_2)$ 维的“核矩阵” K , 由张量积性质可知满足如下关系:

$$K = (\varphi_1(x_i)^T \varphi_1(x_i)) \otimes (\varphi_2(y_j)^T \varphi_2(y_j)) = K_1 \otimes K_2 \quad (7)$$

将式 (3) (5) (7) 代入式 (4) 得

$$Kv = n_1 n_2 \lambda v \quad (8)$$

这样, 求解式 (4) 特征向量的问题就转化为如何求解特征方程 (8) 的特征向量。

(1) 由式 (7) 可知, K_1, K_2 都是对称的半正定方阵, 它的特征值将是非负的。可知, 核矩阵 $K = K_1 \otimes K_2$ 也是正定的。

(2) 由定理 2.2 可知核矩阵 K 的特征值和特征向量可以分别由矩阵 K_1, K_2 的特征值和特征向量表示出。

那么假设 $\sigma(K_1), \sigma(K_2)$ 和 $\sigma(K)$ 分别是 K_1, K_2 和 K 的特征值。

对不同情形有:

(1) 对某一特征向量, 若 $\lambda \in \sigma(K_1)$ 且 α 是与之对应的特征向量, 并且若 $\mu \in \sigma(K_2)$ 且 β 是与之对应的特征向量, 那么有 $\lambda\mu \in \sigma(K)$ 且 $\alpha \otimes \beta$ 是与之对应的特征向量。

(2) 同样若 $\sigma(K_1) = \{\lambda_1, \lambda_2, \dots, \lambda_{n_1}\}$ 且 $\sigma(K_2) = \{\mu_1, \mu_2, \dots, \mu_{n_2}\}$ 通过解特征方程式 (8), 可得到一组非零特征值 $\sigma(K) = \{\lambda_i \mu_j \mid i = 1, \dots, n_1; j = 1, \dots, n_2\}$ 以及对应的满足归一化条件的特征向量集合。

4) 对非训练样本在 H 上进行特征表示

由式 (5) 可知, H 特征空间上的投影主分量为 $v_k (k = 1, \dots, n_1 \cdot n_2)$ 。

设 x 是检验样本, 则其在 v_k 上的投影为

$$(v_k)^T (\varphi_1(x) \otimes \varphi_2(x)) = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \alpha_i \beta_j (\varphi_1(x_i) \otimes \varphi_2(y_j))^T (\varphi_1(x) \otimes \varphi_2(x)) = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \alpha_i \beta_j (\varphi_1(x_i)^T \varphi_1(x)) \otimes (\varphi_2(y_j)^T \varphi_2(x)) = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \alpha_i \beta_j K_1(x_i, x) \otimes K_2(y_j, x) \quad (9)$$

这样在每个特征向量上投影后, 就可得出原始图像的投影特征向量, 即图像 x 的特征值。从式 (9) 可以看出, 上述计算中既不需知 $\varphi_1(x)$ 和 $\varphi_2(y)$ 的确切表达式, 亦不需知核函数 K 的表达式, 仅需知核函数 K_1 和 K_2 的表达式即可。显然, 若核函数 K_1 和 K_2 所

对应的样本数分别为 n_1 和 n_2 这种使用张量积合成两个 KPCA 空间的 KPCA 方法,其计算的时间复杂度是 $O(n_1^3) + O(n_2^3)$ KPCA 而非直接进行 KPCA 方法所需的 $O((n_1 + n_2)^3)$ 。这样,计算量会显著降低。同样,计算的空间复杂度为 $O(n_1^2) + O(n_2^2)$,而非 $O(n^2)$,空间存储量也相应显著降低了。

2 SAR 图像目标识别

与光学图像不同,SAR 图像中包含大量的相干斑噪声且幅度数据服从瑞利分布。由于模板匹配法对高斯分布且具有相同方差的样本呈最优分类性能,因此在设计基于模板的分类器时,对 SAR 幅度数据进行幂变换,将服从瑞利分布的 SAR 幅度数据换为类正态分布^[9],其公式为

$$Y = X^\lambda, \quad 0 < \lambda < 1 \quad (10)$$

式中, X 表示 SAR 幅度数据, λ 为幂转换因子。根据文献[10]得出的结论,当 X 服从瑞利分布时, λ 选取 0.35 或 0.85, Y 可以近似转化为正态分布,实验中 $\lambda = 0.85$ 。

本文实验在 KPCA 处理前将服从瑞利分布的 SAR 幅度数据通过幂变换转化为高斯分布,因此这里选取高斯核函数。根据高斯核函数参数的选取原则,当 $\sigma \rightarrow \infty$ 时,高斯核函数支撑向量机的判别函数为一常数,即把所有的样本点判为同一类。但是 σ 过大,其对新数据的分类能力较差,所以在实验的过程中,选择 $\sigma \gg \max\{\|x_i - x_j\|\}$,也就达到了 $\sigma \rightarrow \infty$ 的效果^[11]。

在获取已知目标样本特征和待测目标样本特征后,由于本文算法要与经典的 KPCA 算法进行比较,所以本文采用了欧氏距离分类器实现目标的识别。令已知目标样本的特征值为 O_{x_r} ,待测目标的特征值为 U_{y_i} 。待测目标与目标样本特征之间的距离为

$$d_{ir} = \|U_{y_i} - O_{x_r}\|^\mu, \quad r = 1, 2, \dots, N \quad (11)$$

又设 $\forall i, \exists r$,使得 d_{ir} 最小,即

$$r^* = \arg \min d_{ir} \quad (12)$$

图 1 给出基于张量代数的 KPCA SAR 图像识别方法的流程框图。

3 仿真实验及结果分析

利用美国 MSTAR 项目提供的实测 SAR 地面静

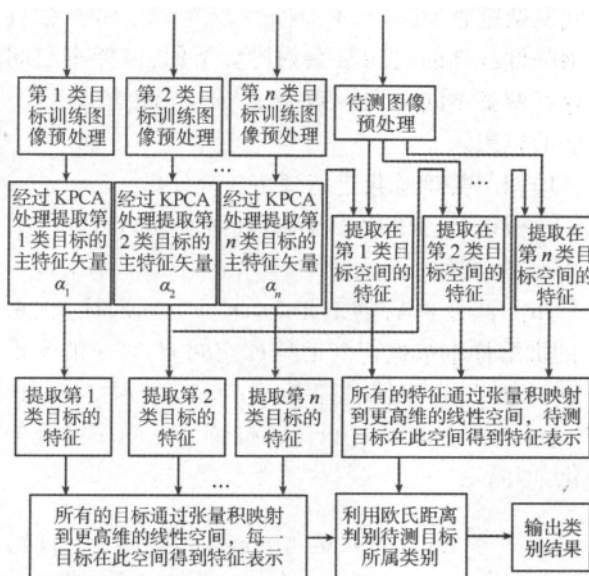


图 1 基于张量代数的 KPCA SAR 图像识别方法流程
Fig. 1 Recognition method based on TAKPCA

止军用目标数据进行仿真实验。仿真验证时本文采用两组数据进行测试,一组为项目组推荐使用的俯仰角为 15° 、 17° 时的地面目标数据,包括 3 类: T72 (主战坦克)、BMP2 (装甲车) 和 BTR70 (装甲车 APCs); 另一组为俯仰角 15° 、 17° 时的混合目标数据。

3.1 两类目标

仿真环境: 以俯仰角 17° 下 BMP_sn9563、T72_sn132 作为训练集,以俯仰角 15° 下的 BMP_sn9563、T72_sn132 作为测试集。训练集和测试集目标图像大小均为 128×128 。

表 1 和表 2 给出本文提出的方法与标准 KPCA 方法的目标识别结果以及不同算法下某一类测试集核函数的运行时间。不同的算法都是利用 MATLAB 进行编程仿真,并且在同一计算机配置下完成(计算机配置为 AMDsempro3000 + 1.61GHz 512MB RAM)。

表 1 TAKPCA 两类目标识别结果与核函数运行时间
Table 1 Results and elapsed time with TAKPCA

15°训练集 (个数)	17°测试集(个数)		识别率 /%	时间/s
	BMP2 (233)	T72 (232)		
BMP2_sn9563(195)	193	2	98.97	6.11
T72_sn132(197)	2	195	98.98	

表 2 KPCA 两类目标识别结果与核函数运行时间

Table 2 Results and elapsed time with KPCA

15°训练集 (个数)	17°测试集(个数)		识别率 /%	时间/s
	BMP2 (233)	T72 (232)		
BMP2_sn9563(195)	193	2	98.97	15.52
T72_sn132(197)	2	195	98.98	

3.2 3 类目标

仿真环境: 以俯仰角 17°下 BMP_sn9563、T72_sn132 和 BTR70_snc71 作为训练集, 以俯仰角 15°下的 BMP_sn9563、T72_sn132、BTR70_snc71 作为测试集。训练集和测试集目标图像大小均为 128 × 128。表 3 和表 4 给出本文方法与 KPCA 方法的目标识别结果以及不同算法下某一类测试集的核函数运行时间。

表 3 TAKPCA 3 类目标识别结果与核函数运行时间

Table 3 Results and elapsed time with TAKPCA

15°训练集 (个数)	17°测试集(个数)			识别率 /%	时间 /s
	BMP2 (233)	T72 (232)	BTR70 (233)		
BMP2_sn9563(195)	192	1	2	98.46	9.03
T72_sn132(197)	1	195	1	98.98	
BTR70_snc71(196)	3	8	185	94.39	

表 4 KPCA 3 类目标识别结果与核运行时间

Table 4 Results and elapsed time with KPCA

15°训练集 (个数)	17°测试集(个数)			识别率 /%	时间 /s
	BMP2 (233)	T72 (232)	BTR70 (233)		
BMP2_sn9563(195)	192	1	2	98.46	41.9
T72_sn132(197)	1	195	1	98.98	
BTR70_snc71(196)	3	8	185	94.39	

可以得出以下结论, 本文方法在识别率相同的情况下, 包含两类目标时, TAKPCA 分解核函数所耗费的时间是 KPCA 的 0.394; 包含 3 类目标时, TAKPCA 分解核函数所耗费的时间是 KPCA 的 0.215。TAKPCA 分解核函数所耗费的时间远远低于标准的 KPCA 方法。

4 结 论

提出的基于张量代数的核主成分分析方法通过分别建立多类目标的不同特征空间, 使得属于该类目标的图像能够由此空间的特征线性地表示, 继而通过张量积将所有的类别合成到一个

可以比较的线性空间, 比之直接进行 KPCA 计算的消耗大大降低; 同时由于通过张量积可将不同类的目标样本映射到同一个空间, 可方便对目标的有效识别。分析实验结果得出, 本文提出的方法在直接进行的 KPCA 核矩阵的维数非常大时会更加有效。但当类别数目增加后, 各个 KPCA 的核参数的调整过程会变得比较繁琐, 所以在实际应用中采用欧氏距离分类器的方法, 目标的类别数目不应过多。也可以考虑其他的识别算法, 这也是以后研究的重点。

参考文献 (References)

- [1] Han P, Wu R B, Wang Z H, et al. SAR automatic target recognition based on KPCA criterion [J]. Journal of Electronics and Information Technology, 2003, 25(10): 1297-1301. [韩萍, 吴仁彪, 王兆华, 等. 基于 KPCA 准则的 SAR 目标特征提取与识别[J]. 电子与信息学报, 2003, 25(10): 1297-1301.]
- [2] Liu D Z, Huang S Q, Su J. A novel target detection approach for SAR images [J]. Journal of Astronautics, 2007, 28(5): 1266-1272. [刘代志, 黄世奇, 苏娟. 一种新的 SAR 图像目标检测方法[J]. 宇航学报, 2007, 28(5): 1266-1272.]
- [3] Zhao Q, Principe J C. Support vector machines for automatic electronic target recognition [J]. IEEE Trans. on Aerospace and Electronic Systems, 2001, 37(2): 643-654.
- [4] Scholkopf B, Smola A, Muller K. Nonlinear component analysis as a kernel eigenvalue problem [J]. Neural Computation, 1998, 10(5): 1299-1319.
- [5] Shi W Y, Guo Y F, Xue X Y. Efficient kernel principal component analysis algorithm for large-scale data set [J]. Journal of Software, 2009, 20(8): 2153-2159. [史卫亚, 郭跃飞, 薛向阳. 一种解决大规模数据集问题的核主成分分析算法[J]. 软件学报, 2009, 20(8): 2153-2159.]
- [6] Kim K I, Franz M O, Scholkopf B. Iterative kernel component analysis for image modeling [J]. IEEE Trans. Pattern Analysis Machine Intelligent, 2005, 27(9): 1351-1366.
- [7] Air Force Research Laboratory. Model Based Vision Laboratory. Sensor Data Management System [EB/OL]. (1999-08-08) [2009-10-07]. <http://www.mbvlab.wpafb.af.mil/public/sdms/datasets/mstar>.
- [8] Chern S S, Chen W H, Lam K S. Lectures on Differential Geometry [M]. Singapore: World Scientific Publishing Company, 2006.
- [9] Kukunage K. Introduction to Statistical Pattern Recognition [M]. Boston: Academic Press, 1990.
- [10] Xin N, Zhang J, Wang G H. Research on normality of power transform in radar target recognition [J]. Modern Radar, 2007, 29(7): 48-51. [辛宁, 张静, 王宏. 雷达目标识别中幂变换的正态性研究[J]. 现代雷达, 2007, 29(7): 48-51.]
- [11] Bishop C M. Neural Networks for Pattern Recognition [M]. Oxford: Clarendon Press, 1995.