

## 基于核函数的雷达一维距离像目标识别

孟继成 杨万麟

(电子科技大学电子工程学院 成都 610054)

**摘要:** 该文分析了基于核函数的三大模式识别方法(支持向量机、非线性主分量分析、非线性判别分析)的分类机理,并将其应用于雷达一维距离像目标识别中。用 3 种飞机实测雷达距离像数据样本进行识别研究,结果表明对于雷达目标距离像识别,支持向量机方法较其它两种方法更为有效,并对实验结果给出了合理的解释。

**关键词:** 雷达目标识别, 基于核函数的方法, 支持向量机, 非线性主分量分析, 非线性判别分析

**中图分类号:** TN957.7      **文献标识码:** A      **文章编号:** 1009-5896(2005)03-0462-05

## Range Profile Recogniton of Radar Target Based on the Kernel-Based Methods

Meng Ji-cheng Yang Wan-lin

(College of Electronic Engineering, UEST of China, Chengdu 610054, China)

**Abstract** The classification mechanism of the kernel-based methods in pattern recognition, i.e. SVMs, nonPCA, and nonLDA, are analyzed in detail in this paper. The range profiles of radar target are recognized by the kernel-based methods. The results of the simulation on three radar target show that SVMs is more effective than nonPCA and nonLDA, and a sound explanation for the results is given too.

**Key words** Radar target recognition, Kernel-based methods, Support vector machines, Nonlinear principal component analysis, Nonlinear discriminant analysis

### 1 引言

目前,非线性问题是许多科技领域的学者关注的焦点。而基于核函数的方法是处理模式识别中非线性问题的有效手段。该方法是通过引入满足 Mercer 条件<sup>[1]</sup>的核函数  $K$ ,把线性算法转换为非线性算法。采用一非线性映射函数  $\phi$  将样本数据从原始空间映射到一高维空间,如在此高维空间利用映射函数直接求解,计算量将非常大。幸运的是,只要高维空间的内积可以用原始空间中的数据直接计算得到,就不需定义映射函数,而直接定义满足 Mercer 条件的核函数  $K$ 。由于核函数的引入,则在高维空间求解的计算量不会太大<sup>[1,2]</sup>。

子空间法<sup>[3]</sup>已成为雷达目标距离像识别中的经典方法。其基本思想是根据最小均方近似的原则建立子空间,并且采用 Fisher 准则函数,使异类目标之间的距离加大而同类目标之间的距离减小。由于雷达目标及其所处环境的复杂性,导致目标之间的关系往往是非线性的,使得经典子空间法的实际应用范围受到限制。本文探讨基于核函数的模式识别方法的分类机理,并将其应用于雷达一维目标距离像识别。

### 2 基于核函数的模式识别方法

基于核函数的思想最早于 20 世纪 90 年代初由 Vapnik 等应用到支持向量机(SVMs)的构造之中<sup>[4]</sup>;1998 年, Schölkopf 等介绍了将这一思想应用到非线性 PCA(nonPCA)中的成果<sup>[5]</sup>;1999 年, Mika 等又将其应用于非线性 Fisher 判别分析(nonlinear Discriminant Analysis, nonDA)中<sup>[6]</sup>(nonPCA、nonDA 亦称 KPCA, KDA, K 即 Kernel)。至此形成了机器学习领域中基于核函数的三大主要学习方法(基于核的感知机,影响不大,本文不予介绍,详细请见文献[7])。

#### 2.1 支持向量机

2.1.1 统计学习理论 统计学习理论是支持向量机的理论基石,它所采用的原则是 SRM(Structure Risk Minimization),即结构风险最小化。这是它与传统的统计理论(采用经验风险最小化)的本质不同之处。在这一原则下,对于统计学习理论所研究的函数集中的所有函数,实际风险  $R(w)$  和经验风险  $R_{emp}(w)$  之间至少以  $1-\eta$  的概率满足如下关系:

$$\begin{aligned} R(w) &\leq R_{emp}(w) + \sqrt{\frac{h(\ln(2n/h) + 1) - \ln(\eta/4)}{n}} \\ &= R_{emp}(w) + \phi(h/n) \end{aligned} \quad (1)$$

其中  $w$  为函数的广义参数,  $\phi(h/n)$  为置信范围,  $h$  为函数的 VC(Vapnik & Chervonenkis) 维,  $n$  为样本数。传统的模式识别方法只考虑经验风险最小, 而 SRM 不仅考虑了经验风险, 还考虑了置信范围, 构造出两者之和为最小的、更科学的学习机器用于模式识别。SVMs 就是一种较好实现 SRM 原则的技术。

**2.1.2 支持向量机分类机制** 设给定训练样本集为  $\{(x_i, y_i)\}$  ( $y_i \in \{+1, -1\}$ ,  $i = 1, \dots, n$ ), 分类面为  $(wx_i) + b = 0$ , 且记  $g(x_i) = wx_i + b$  为判别函数。最优分类面定义为训练集所有向量均能被正确划分, 且使距分类面最近的异类向量之间距离最大的分类面, 即为将两类分开最大间隙的分类面。我们将这种距分类面最近的向量称为支持向量。对判别函数进行适当处理, 不失一般性可得  $|g(x)| \geq 1$ 。由于支持向量满足  $(wx_i) + b = 1$ , 其与最优分类面距离为  $1/\|w\|$ , 要它最大, 即最小化  $\|w\|$ ; 在分类面对样本分类时, 如下不等式成立:

$$y_i[(wx_i) + b] - 1 + \xi_i \geq 0 \quad (2)$$

对线性可分问题  $\xi_i = 0$ , 求解相对简单, 本文只给出在线性不可分情况下, 问题的求解过程。当划分出现错误时,  $\xi_i > 0$ 。因此  $\sum_{i=1}^n \xi_i$  是训练样本集中划分错误的向量数的一种量度。

事实上, 对一个规范分类面子集来说, 在  $\|w\| \leq C$  的约束下, 其 VC 维  $h$  满足下面不等式  $h \leq \min\{(R^2 C, d) + 1\}$ , 其中  $d$  为向量空间维数,  $R$  为覆盖所有向量的超球体半径。由此可知, 最小化期望风险, 即等同为最小化式(3)问题。

$$\phi(w, \xi) = 1/2(w \cdot w) + C \sum_{i=1}^n \xi_i \quad (3)$$

其中  $C$  为可调参数, 起着控制对错分样本惩罚程度的作用。在条件式(2)的约束下, 求函数式(3)的极小值, 就可得线性不可分情况下的最优分类面, 称为广义最优分类面。

利用 Lagrange 乘子法可把解广义最优分类面问题转化为一个较简单的对偶问题, 即在式(5), 式(6)约束下最大化式(4)。

$$Q(\lambda) = \sum_{i=1}^n \lambda_i - (1/2) \sum_{i,j=1}^n \lambda_i \lambda_j y_i y_j (x_i \cdot x_j) \quad (4)$$

$$\sum_{i=1}^n \lambda_i y_i = 0 \quad (5)$$

$$0 \leq \lambda_i \leq C \quad (6)$$

由 KKT(Karush-Kuhn-Tucher) 条件<sup>[4]</sup>可知, 最优解满足:

$$\lambda_i \{y_i[(wx_i) + b] - 1 + \xi_i\} = 0 \quad (7)$$

$$\mu_i \xi_i = 0 \quad (8)$$

由此知, 当  $0 < \lambda_i < C$  时,  $\xi_i = 0$ 。所以广义最优分类面的权系数  $w$  是支持向量的线性组合。  $b$  值可由支持向量  $x_i$ , 及  $w$  代入式(7)求得。

非线性 SVMs 是采用核函数, 将输入向量  $x$  通过映射  $\phi: R^n \rightarrow H$  映射到 Hilbert 空间, 在此空间求解广义最优分类面。在最优分类面中采用引入适当的核函数  $K$  就可以实现非线性变换后的线性分类。事实上, 在取核函数为点积形式  $(x_i \cdot x_j)$  时, 就可得到上述求解的线性 SVMs。对不同核函数对应不同的 SVMs, 常用的有以下几种 (本文采用高斯核函数):

$$(1) \text{ 线性 SVMs: } K(x_i, x_j) = (x_i \cdot x_j);$$

$$(2) \text{ 多项式 SVMs: } K(x_i, x_j) = [(x_i \cdot x_j) + 1]^d;$$

$$(3) \text{ 高斯核函数 SVMs: } K(x_i, x_j) = e^{-|x_i - x_j|^2 / 2\sigma^2}.$$

SVMs 是面向两类问题的, 对于多类问题可以通过建立多个 SVMs 的方式加以解决。本文所谓的“一对一”方法<sup>[2]</sup>。即如果有  $g$  个类别, 为每两类都建立一个 SVMs, 则共有  $g(g-1)/2$  个, 再采用投票的方式进行分类。

## 2.2 非线性主分量分析

对于训练样本集为  $X = \{x_1, x_2, \dots, x_n\}$ , 不失一般性可假设  $E(x) = 0$  (如均值不为零, 可用  $x = x - E(x)$ ), 则特征子空间的基就是协方差矩阵:

$$C = \frac{1}{n} \sum_{i=1}^n x_i x_i^T \quad (9)$$

的特征向量。对  $x_i$  作非线性变换  $\phi(x_i)$ , 得到集合  $F = \{\phi(x_1), \phi(x_2), \dots, \phi(x_n)\}$  和

$$\bar{C} = \frac{1}{n} \sum_{i=1}^n \phi(x_i) \phi(x_i)^T \quad (10)$$

$\bar{C}$  的特征向量  $v$  就是原训练样本集的非线性特征子空间的基向量, 即满足式:

$$\bar{C}v = \lambda v \quad (11)$$

且特征向量  $v$  可表示为

$$v = \sum_{i=1}^n \alpha_i \phi(x_i) \quad (12)$$

引入 Mercer 核函数, 它满足

$$K(x_i, x_j) = \phi(x_i) \phi(x_j) \quad (13)$$

定义矩阵  $K = \{(\phi(x_i)^T \cdot \phi(x_j))\} = \{K(x_i, x_j)\}$ , 将式(11)两边同时左乘  $\phi(x_i)$  得式:

$$\phi(x_i) \bar{C}v = \lambda \phi(x_i) v \quad (14)$$

将式(12)代入式(14), 整理可得式:

$$K\alpha = n\lambda\alpha, \quad \alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^T \quad (15)$$

由式(15)可求出  $\alpha$ , 即可得由  $\bar{C}$  的特征向量组成的矩阵  $V = (v_1, v_2, \dots, v_n)$ , 即为非线性特征子空间。在目标识别过程中, 实际上我们感兴趣的不是非线性特征子空间本身, 而是训练样本在其中的投影, 即  $x_i$  在非线性特征子空间的子像,

记为  $y_i$  则:

$$y_i = V^T \varphi(x_i) = \begin{pmatrix} \sum_{j=1}^n (\alpha_{1j} \varphi(x_j)^T \cdot \varphi(x_i)) \\ \sum_{j=1}^n (\alpha_{2j} \varphi(x_j)^T \cdot \varphi(x_i)) \\ \vdots \\ \sum_{j=1}^n (\alpha_{nj} \varphi(x_j)^T \cdot \varphi(x_i)) \end{pmatrix} = \begin{pmatrix} \sum_{j=1}^n \alpha_{1j} K(x_j, x_i) \\ \sum_{j=1}^n \alpha_{2j} K(x_j, x_i) \\ \vdots \\ \sum_{j=1}^n \alpha_{nj} K(x_j, x_i) \end{pmatrix} \quad (16)$$

### 2.3 非线性判别分析

设  $x_{ij}$  ( $n$  维列矢量) 表示第  $i$  类目标的第  $j$  个训练姿态角的一维距离像, 定义函数  $\phi: R^N \rightarrow F$ 。  $\phi$  将原始数据样本非线性映射到特征空间  $F$  中。在  $F$  中定义准则函数为

$$J(w) = \frac{w^T S_B^\phi w}{w^T S_W^\phi w} \quad (17)$$

其中

$$w \in F, \quad S_B^\phi = \sum_{i=1}^g (\overline{\phi(x_i)} - \overline{\phi(x)}) (\overline{\phi(x_i)} - \overline{\phi(x)})^T \quad (18)$$

$$S_W^\phi = \sum_{i=1}^g \sum_{j=1}^{N_i} (\phi(x_{ij}) - \overline{\phi(x_i)}) (\phi(x_{ij}) - \overline{\phi(x_i)})^T \quad (19)$$

$$\overline{\phi(x_i)} = \frac{1}{N_i} \sum_{j=1}^{N_i} \phi(x_{ij}) \quad (20)$$

$$\overline{\phi(x)} = \frac{1}{N} \sum_{i=1}^g \sum_{j=1}^{N_i} \phi(x_{ij}) \quad (21)$$

$S_B^\phi$  和  $S_W^\phi$  分别表示原始样本经非线性变换后在  $F$  中的类间散度矩阵和类内散度矩阵,  $i=1, 2, \dots, g$ ;  $j=1, 2, \dots, N_i$ ;  $N = N_1 + N_2 + \dots + N_g$ ; 其中  $g$  为目标类别数,  $N_i$  为第  $i$  类目标的训练样本数,  $N$  为训练样本总数。显然  $J(w)$  越大, 表明类间差异相对于类内差异越大, 越有利于目标分类。引入 Mercer 核函数。它满足  $K(x_i, x_j) = \phi(x_i) \phi(x_j)$ 。  $w$  可以写成下式:

$$w = \sum_{i=1}^N \alpha_i \phi(x_i) \quad (22)$$

则由式(22)可得

$$w^T \overline{\phi(x_i)} = \frac{1}{N_i} \sum_{j=1}^N \sum_{k=1}^{N_i} \alpha_j K(x_j, x_{ik}) = \alpha^T P_i \quad (23)$$

$$w^T \overline{\phi(x)} = \frac{1}{NN_i} \sum_{i=1}^g \sum_{j=1}^N \sum_{k=1}^{N_i} \alpha_j K(x_j, x_{ik}) = \alpha^T Q \quad (24)$$

$$w^T \phi(x_{ij}) = \sum_{k=1}^N \alpha_k K(x_k, x_{ij}) = \alpha^T (K_k)_{ij} \quad (25)$$

而  $\alpha^T = (\alpha_1, \alpha_2, \dots, \alpha_N)$ ,  $(P_i)_j = \frac{1}{N_i} \sum_{k=1}^{N_i} K(x_j, x_{ik})$ ,  $Q_j = \frac{1}{NN_i}$

$\sum_{i=1}^g \sum_{k=1}^{N_i} K(x_j, x_{ik})$ , 所以

$$w^T S_B^\phi w = \alpha^T R_B \alpha, \quad R_B = \sum_{i=1}^g (P_i - Q)(P_i - Q)^T \quad (26)$$

$$w^T S_W^\phi w = \alpha^T R_W \alpha, \quad R_W = \sum_{i=1}^g \sum_{j=1}^{N_i} ((K_k)_{ij} - P_i)((K_k)_{ij} - P_i)^T \quad (27)$$

这样, 最大化原准则函数  $J(w) = \frac{w^T S_B^\phi w}{w^T S_W^\phi w}$  可等价于最大化

$$J(\alpha) = \frac{\alpha^T R_B \alpha}{\alpha^T R_W \alpha}.$$

可求得矩阵  $R_W^{-1} R_B$  的一组基  $\alpha$ , 由此可得  $w$ , 构成非线性变换矩阵  $V$ , 即为非线性判别子空间。在目标识别过程中, 我们感兴趣的不是非线性判别子空间本身, 而是训练样本在其中的投影, 即  $x_i$  在非线性判别子空间的子像, 记为  $y_i$ , 则

$$y_i = V^T \phi(x_i) = \begin{pmatrix} \sum_{j=1}^n (\alpha_{1j} \phi(x_j)^T \cdot \phi(x_i)) \\ \sum_{j=1}^n (\alpha_{2j} \phi(x_j)^T \cdot \phi(x_i)) \\ \vdots \\ \sum_{j=1}^n (\alpha_{nj} \phi(x_j)^T \cdot \phi(x_i)) \end{pmatrix} = \begin{pmatrix} \sum_{j=1}^n \alpha_{1j} K(x_j, x_i) \\ \sum_{j=1}^n \alpha_{2j} K(x_j, x_i) \\ \vdots \\ \sum_{j=1}^n \alpha_{nj} K(x_j, x_i) \end{pmatrix} \quad (28)$$

由上文可以看出, 采用非线性主分量分析和非线性判别分析, 不论是求解  $\alpha_i$ , 还是求解子像  $y_i$ , 只需在原始训练样本空间中计算用作内积的核函数  $K$ , 而无需知道  $\phi(x)$  的具体表达式。在本文中我们采用核函数:

$$K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / 2\sigma^2)$$

### 2.4 最近中心距离分类器

对于非线性 SVMs 来说其本身就是一个非线性分类器, 可直接做为分类识别目标的机器。而在本文中, 非线性主分量分析、非线性判别分析只是进行非线性变换和提取特征(生成子像), 本文将其与最近中心距离分类器相结合以达到识别目标的目的。

最近中心距离分类器描述如下: 将表示每种目标训练样本的  $n$  维特征向量平均后作为对应库目标模板向量,  $g$  种目标模板向量库为:  $\{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_g\}$ 。设待识别目标的  $n$  维特征向量  $x_x$ , 则使欧氏距离  $d_k = \|x_x - \bar{x}_k\|$ ,  $k=1, 2, \dots, g$  最小的  $k$ , 就判为输入目标所属的类。

### 3 实验结果

本文实验采用的实测数据是 ISAR 雷达对空中的 3 种飞机( $a, b, c$ )所成的距离像。ISAR 交替发射窄带(脉冲时宽为  $1\mu s$ )和宽带两种波形, 窄带系统主要用于跟踪目标和产生宽带本振定时信号。宽带信号的带宽  $400MHz$ (理论距离分辨率

为 0.375m), 采样点数为 256(经过 FFT 后所得一维距离像的像点数也为 256)。每种飞机记录了 7 段数据, 每段数据含 26000 个宽、窄带信号(相邻间隔 2.5ms)。宽带信号为全去斜后的正交双通道信号(其 FFT 即一维距离像), 每段数据含 260 个宽带正交双通道信号。实验数据为 3 种飞机各取一段的 120 幅距离像(总数为 360 幅), 其中分别任取每一段的 80 幅作为训练样本, 另外 40 幅为测试样本。

在对基于核函数的 3 种模式识别方法进行训练前, 作如下两步预处理:

(1) 归一化: 将每一幅像用其总能量归一;

(2) 距离对准: 利用 Fourier 变换的平移不变性, 将一维距离像作 Fourier 变换即可对齐。同时, 据实数 Fourier 变换的共轭对称性, 可取一维距离像 Fourier 变换的一半(128 维)作为识别输入矢量进行实验。

对数据样本, 分别采用支持向量机、非线性主分量分析(结合最近中心距离分类器)、线性判别分析(结合最近中心距离分类器)进行识别, 表 1、表 2 分别给出了在每种飞机训练样本数为 40、80(总训练样本数为 120、240), 测试样本数为 40(总测试样本数为 120)时的识别结果。

表 1 120 个训练样本时的识别结果

目 标	核函数方法		
	支持向量机	非线性主量分析	非线性判别分析
	正确识别率(%)		
a	92.5	85	87.5
b	95.0	95.0	92.5
c	92.5	85.0	90.0
平均识别率(%)	93.3	88.3	90.0

表 2 240 个训练样本时的识别结果

目 标	核函数方法		
	支持向量机	非线性主分量分析	非线性判别分析
	正确识别率(%)		
a	92.5	60	62.5
b	97.5	97.5	95.0
c	95.0	82.5	80.0
平均识别率(%)	95.0	80.0	79.2

从识别结果可得到如下结论: (1) 采用支持向量机的平均识别率要明显高于其它两种方法的平均识别率, 而采用非线性主分量分析与非线性判别分析的平均识别率相差不大。这正体现了支持向量机在小样本情况下较非线性主分量分析与非线性判别分析更为优秀。(2) 在训练样本数增多时, 支持向量机的识别率有所提高, 而其它两种方法的平均识别率却大幅下降。对此我们的解释是: 一般来说, 在模式识别

领域, 固定测试样本, 则随着训练样本的增加, 分类的识别率会随之上升, 对支持向量机来讲, 对训练样本的多少不敏感, 所以其识别率随着训练样本的增加, 有所提高但并不太大; 在雷达一维距离像目标识别中, 距离像敏感于目标姿态角变化, 增加训练样本往往会使目标姿态角增大, 所以在训练样本并不太多时(如本文), 采用非线性主分量分析或非线性判别分析的识别率反而大幅下降。正是因为距离像敏感于雷达目标姿态角变化, 所以在基于雷达一维距离像目标识别中, 往往采用较少的训练样本数(一般来讲, 较少的训练样本意味着姿态角变化不大)<sup>[3]</sup>。

因为雷达一维距离像目标识别主要用于军事领域, 实时性要求较高, 故本文在表 3 中给出 3 种方法的训练及测试时间(240 个训练样本, 120 个测试样本)。

表 3 核函数方法的实时性能

任 务	核函数方法		
	支持向量机	非线性主分量分析	非线性判别分析
	所耗时间(s)		
训练	0.4020	3.5350	8.5820
测试	0.6060	3.9960	8.6820
单个样本测试	0.0050	0.0333	0.0723

我们知道, 一个算法所耗时间, 不但与算法本身的复杂度相关, 而且与所在的软硬件平台密切相关。表 3 实验结果, 所采用的软硬件平台是: Windows XP, Matlab 6.5; P4, 2.2GHz, 内存 256M。从表 3 容易看出, 训练时间及测试时间达到秒级, 而我们所关心的只是单个测试样本的实时性, 训练时间稍长些是可以接受的。对单个测试样本来讲, 耗时最少的 SVMs 仅为 5ms, 耗时最多的非线性判别分析方法也才为 72.3ms, 可以满足雷达一维距离像目标识别的实时性要求的(实时性是个相对的概念, 在雷达一维距离像目标识别领域还没有统一标准)。对这一结果可作如下解释: 一方面对于一般的非线性问题, 确实计算量会明显增大, 但对本文采用的非线性方法, 由于满足 Mercer 条件的核函数  $K$  的引入, 所以计算量并不会太大, 这在引言中已提及; 另一方面, 雷达一维距离像维数并不高(本文 128 维), 总的训练样本也不多(本文 240 个), 与人脸识别等<sup>[8,9]</sup>相比数据量不大, 便于处理。而且, 对于一个实用的系统来讲, 往往可以利用并行处理技术或采用更高性能的专用处理机来进一步提高算法的实时性。所以, 我们认为所采用的非线性核函数的方法可以满足雷达一维距离像目标识别领域的实时性要求。

#### 4 结论

基于核函数的模式识别方法主要应用于人脸识别<sup>[8,9]</sup>、文本识别<sup>[10]</sup>、DNA 识别<sup>[11]</sup>等, 非线性 PCA 也可以完成图像的

去噪、压缩等功能。本文将基于核函数的模式识别方法用于雷达一维距离像目标识别,分别采用支持向量机、非线性主分量分析与非线性判别分析<sup>[12,13]</sup>进行识别研究,结果验证了支持向量机不敏感于训练样本数,对小样本情况下较其它两种方法更为适合雷达一维距离像目标识别,并具有较强的实时性能。

### 参 考 文 献

- [1] 边肇祺,张学工,等. 模式识别(第二版). 北京:清华大学出版社,2000,第十三章.
- [2] 田盛丰. 基于核函数的学习算法. 北方交通大学学报,2003,27(2):1-8.
- [3] 周代英. 雷达目标一维距离像识别研究, [博士论文], 成都:电子科技大学,2001,第一,二章.
- [4] Vapnik N. The Nature of Statistical Learning Theory. New York: Springer Verlag, 1995: 1-188.
- [5] Schölkopf B, Smola A, Müller K R. Nolinear component analysis as a kernel eigenvalue problem. *Neural Computation*, 1998,10(5): 1299-1319.
- [6] Sebastian Mika, Gunnar Rätsch, Jason Weston, Schölkopf B, Müller K R. Fisher discriminant analysis with kernels. *Neural Networks for Signal Processing IX*. New York: IEEE Press, 1999: 41-48.
- [7] Xu J H, Zhang X G, Ci Y D. Kernel neuron and its training algorithm. In: Proc. of 8<sup>th</sup> ICNIP2001, Shanghai, P.R.China, 2001, 2: 861-866.
- [8] Osuna E, Freund R, Girosi F. Training support vector machines, an application to face detection. In: Proc. of CVPR'97, Puerto Rico, 1997: 130-136.
- [9] Sakano H, Mukawa N. Kernel mutual subspace method for robust facial image recognition. In: Proc. of 4<sup>th</sup> KES, Brighton, UK, 2000, vol.1: 245-248.
- [10] Joachims T. Text categorization with support vector machines: learning with many relevant features. In: Proc. of the European Conf. on Machine Learning. Berlin, 1998: 137-142.
- [11] Zien A, Rätsch G, Mika S, *et al.*. Engineering support vector machine kernels that recognize translation initiation sites in DNA. *Bioinformatics*, 2000, 16(9): 799-807.
- [12] 张莉,周伟达,焦李成. 用于一维图像识别的支撑向量机方法. *红外与毫米波学报*, 2002, 21(2): 119-123.
- [13] 李映,焦李成. 基于核Fisher判别分析的目标识别. *西安电子科技大学学报(自然科学版)*, 2003, 30(2): 179-182.
- 孟继成: 男,1974年生,博士生,从事模式识别、雷达目标识别等方面的研究工作.
- 杨万麟: 男,1945年生,教授,博士生导师,从事微波成像、雷达目标识别等方面的研究工作.