

文章编号: 1001-0920(2011)12-1835-05

基于非参数化最大间隔准则的雷达目标识别

吴 杰, 周建江, 朱劼昊

(南京航空航天大学 信息科学与技术学院, 南京 210016)

摘 要: 针对线性判别分析(LDA)的“小样本”和要求数据须服从高斯分布的问题, 提出一种基于非参数化最大间隔准则(NMMC)的雷达目标识别方法. 首先, 利用自相关小波变换提取目标高分辨距离像(HRRP)的非平稳特征, 将其与HRRP原信号一起作为目标的分类特征, 利用NMMC实现特征提取; 然后, 通过支持向量机进行分类. NMMC在解决小样本问题的同时, 松弛了对数据分布的类高斯要求. 最后, 基于5种飞机高分辨距离像数据的仿真实验验证了所提出方法的有效性.

关键词: 自动目标识别; 雷达高分辨距离像; 非参数最大间隔准则; 自相关小波变换

中图分类号: TN911.7

文献标识码: A

Radar target recognition method based on nonparametric maximum margin criterion

WU Jie, ZHOU Jian-jiang, ZHU Jie-hao

(College of Information Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China. Correspondent: WU Jie, E-mail: bxwuhe@163.com)

Abstract: As an effective feature extraction method in radar target high-resolution range profile(HRRP) recognition community, linear discriminant analysis(LDA) faces two main shortcomings which are referred to as small sample size problem and Gaussian-like assumption respectively. Therefore, a radar target recognition method based on nonparametric maximum margin criterion(NMMC) is proposed. Firstly, the non-stationary characters of HRRP are extracted by the auto-correlation wavelet transform, which are used as the target classification characteristics together with HRRPs. Then the classification characteristics are extracted by using the NMMC algorithm, and support vector machine(SVM) classifier is used for target recognition. NMMC solves the small sample size problem and relaxes the requirement of Gaussian distribution assumption in LDA. Finally, simulation results based on a HRRP dataset of five aircraft models show the effectiveness of the proposed approach.

Key words: automatic target recognition; HRRP; NMMC; auto-correlation wavelet transform

1 引 言

雷达高分辨距离像(HRRP)提供了目标散射点的强度和位置信息, 相比雷达目标的二维像更容易获取. 因此, 利用高分辨一维距离像进行目标识别一直是宽带雷达目标识别技术领域研究的重要内容^[1-5]. 但是, HRRP对目标姿态变化非常敏感, 全面描述一个目标的特征需要在方位角和俯仰角域内分别以一定角度间隔建立全姿态的HRRP模版库, 而且HRRP的维数一般较高, 在利用HRRP进行目标识别时, 目标数据库的存储量和识别的运算量会很大. 因此, 在目标识别前对HRRP进行特征提取是非常必要的.

线性判别分析(LDA)是一种典型的将高维数据向低维空间投影的方法, 它充分利用训练样本的类别信息, 在最小均方意义下, 寻找一组最佳投影矢量, 使各类的类内离散度最小, 同时使类间的离散度达到最大. 但LDA算法需要假设待分类数据均服从具有相同协方差矩阵的高斯分布, 当样本维数大于或接近于样本个数时, 又容易导致类内散射矩阵 S_w 奇异, 即所谓的“小样本问题”. 在基于HRRP的雷达自动目标识别中, 随着雷达发射带宽的提高, 距离像的特征维数一般较高, 并且由于HRRP的方位敏感性, 训练样本通常不足. 文献[6]以最大化平均类间距作为

收稿日期: 2010-08-03; 修回日期: 2010-11-12.

基金项目: 装备预研重点基金项目(N0601-041); 中电集团第14研究所院士基金项目(2008041001).

作者简介: 吴杰(1977-), 女, 博士生, 从事雷达自动目标识别、信号处理等研究; 周建江(1962-), 男, 教授, 博士生导师, 从事雷达信号处理、目标识别等研究.

特征提取标准, 提出最大间隔准则(MMC)算法, 通过将判决准则以差化商的方法解决了LDA算法的“小样本问题”。但MMC算法仍然建立在假设待分类数据须服从高斯分布的基础上, 并不适合数据服从非高斯分布的情况。而根据散射点模型理论, 雷达目标HRRP各距离单元幅值分布较复杂, 大致可分为3种情况^[1]: 1) 目标距离单元内分布着大量弱散射点, 没有主散射点, 其回波幅值服从瑞利分布; 2) 目标距离单元内存在一个主散射点和大量弱散射点, 其回波幅值服从莱斯分布; 3) 目标距离单元内包含多个(特别是2或3个主散射点)以及大量的弱散射点, 其回波幅值服从多峰分布。因此, 不能简单地用高斯分布模型来描述目标HRRP各距离单元幅值分布情况。

针对MMC算法要求假设待分类数据须服从高斯分布的问题, 借鉴文献[7]中提出的非参数特征分析(NFA)算法, 本文提出一种基于非参数化最大间隔准则(NMMC)的雷达目标识别方法。与MMC相比, NMMC中的类间散射矩阵和类内散射矩阵均采用非参数化的形式, 松弛了MMC对数据分布的类高斯要求, 更适合于目标HRRP特征提取; 在计算类内散射矩阵时, 利用权函数对每一个 K 近邻点加权, 更好地利用了有利于目标分类的类边界信息, 降低了非类边界样本的影响, 从而可获得更好的分类效果。同时, 为了获得更丰富的信号特征, 本文方法还利用具有时移不变性和紧支撑特征的dB4自相关小波对目标HRRP作自相关小波变换, 将一阶自相关小波变换的低频分量和原信号一起作为目标的分类特征。基于5类飞机的仿真实验表明, 本文提出的NMMC算法较LDA和MMC具有更好的分类性能。

2 最大间隔准则及其非参数化

2.1 最大间隔准则

假设待分类数据集有 C 类, 第 i 类目标的样本个数为 N_i ($i = 1, 2, \dots, C$), $N = \sum_{i=1}^C N_i$ 。用 M 维向量 x_{il} ($i = 1, 2, \dots, C, l = 1, 2, \dots, N_i$)表示第 i 类目标的第 l 个样本。则类内散射矩阵 S_w 和类间散射矩阵 S_b 分别为^[6]

$$S_w = \sum_{i=1}^C \sum_{l=1}^{N_i} (x_{il} - m_i)(x_{il} - m_i)^T, \quad (1)$$

$$S_b = \sum_{i=1}^C N_i (m_i - m)(m_i - m)^T. \quad (2)$$

其中: m_i 为第 i 类目标的均值向量, m 为目标的整体均值向量。

模式分类中特征提取的目的是在实现降维的同时尽可能多地保存待分类信号的分类信息, 因此一个

好的特征提取标准, 应该是最大化类间间隔的同时使类内间距最小化。典型的特征提取方法LDA是在最小均方意义下, 寻找最佳投影矢量 W 使Fisher判决准则 J_F 最大, 即

$$J_F(W) = \text{tr} \left(\frac{W^T S_b W}{W^T S_w W} \right). \quad (3)$$

然而当样本维数大于或接近于样本个数时, 容易导致类内散射矩阵 S_w 奇异, 无法求解最佳投影矢量 W 。与LDA算法不同, 最大间隔准则(MMC)的目的是最大化平均类间距, 第 i 类与第 j 类之间的类间距 $d(C_i, C_j)$ 的定义式如下^[6]:

$$d(C_i, C_j) = d(m_i, m_j) - S(C_i) - S(C_j). \quad (4)$$

其中: $d(m_i, m_j)$ 为 m_i 与 m_j 之间的欧氏距离, $S(C_i)$ 和 $S(C_j)$ 分别为第 i 类和第 j 类目标散射矩阵的迹。简化后, 平均类间距的判别准则为^[6]

$$J(W) = \text{tr}(W^T (S_b - S_w) W). \quad (5)$$

分析可知, MMC算法中判决准则采用差化商的方法, 消除了由于类内散射矩阵 S_w 奇异而无法求解最佳投影矢量 W 的情况, 解决了LDA算法的小样本问题; 当类内散射矩阵 S_w 非奇异时, 理论上MMC等同于LDA, 但由于MMC算法舍弃了矩阵 $S_b - S_w$ 负的特征值对应的特征向量, 其可分性优于LDA算法^[6]; 在满足 $\text{rank}(S_t) = \text{rank}(S_w) + \text{rank}(S_b)$ 的条件下(这里 $S_t = S_w + S_b$ 为总散射矩阵), MMC和LDA+PCA的分类性能相当^[8], 但MMC算法依然有如下缺点: 1) 该算法仍然建立在假设待分类数据服从具有相同协方差矩阵的高斯分布的基础上; 2) 在计算散射矩阵时并没有充分利用在模式分类中有着重要作用的类边界样本。

2.2 非参数化最大间隔准则

针对MMC算法的不足, 借鉴文献[7]中提出的非参数特征分析算法, 将MMC中的类间散射矩阵 S_b 和类内散射矩阵 S_w 采用非参数化的形式, 称为非参数化最大间隔准则。非参数化的类内散射矩阵 S_w^N 和类间散射矩阵 S_b^N 分别为^[7]

$$S_w^N = \sum_{i=1}^C \sum_{p=1}^{k_1} \sum_{l=1}^{N_i} (x_{il} - NN_p(x_{il}, i))(x_{il} - NN_p(x_{il}, i))^T, \quad (6)$$

$$S_b^N = \sum_{i=1}^C \sum_{j=1, j \neq i}^C \sum_{p=1}^{k_2} \sum_{l=1}^{N_i} \omega(i, j, p, l) (x_{il} - NN_p(x_{il}, j))(x_{il} - NN_p(x_{il}, j))^T. \quad (7)$$

其中: $NN_p(x_{il}, j)$ 表示 k 近邻法中第 j 类目标里第 p 个离样本 x_{il} 最近的样本矢量, k_1 和 k_2 分别表示类内和类间近邻个数, 权函数^[7]

$$\omega(i, j, p, l) = \frac{\min[d^\alpha(x_{il}, NN_p(x_{il}, i)), d^\alpha(x_{il}, NN_p(x_{il}, j))]}{d^\alpha(x_{il}, NN_p(x_{il}, i)) + d^\alpha(x_{il}, NN_p(x_{il}, j))}. \quad (8)$$

其中: $d(v_1, v_2)$ 为矢量 v_1 与 v_2 之间的欧式距离; 参数 α 用于控制权函数 ω 的变化速度, 取值范围为 $0 \sim +\infty$. 从式 (8) 可知, 对于类边界附近的样本, 权函数 ω 的值接近 0.5, 样本离类边界越远权函数 ω 的值越小, 当样本远离类边界时, 权函数 ω 的值逐渐减小至零. 因此, 通过加权可以增强训练数据中类边界样本在分类中的作用. 非参数化最大间隔准则的判别准则为

$$J(W) = \text{tr}(W^T(S_b^N - S_w^N)W). \quad (9)$$

其中: 变换矩阵 $W \in R^{M \times d}$, M 和 d 分别为投影变换前后信号维数. 记 $W = [w_1, w_2, \dots, w_h, \dots, w_d]$, w_h 为单位列向量, 通过求解下面的约束方程得到:

$$\begin{aligned} \max \left\{ \sum_{h=1}^d w_h^T (S_b^N - S_w^N) w_h \right\}; \\ \text{s.t. } w_h^T w_h - 1 = 0, h = 1, 2, \dots, d. \end{aligned} \quad (10)$$

利用拉格朗日乘数法可得

$$(S_b^N - S_w^N)w_h = \lambda_h w_h, \quad h = 1, 2, \dots, d. \quad (11)$$

其中: λ_h 为矩阵 $(S_b^N - S_w^N)$ 的特征值, w_h 为其对应的特征向量.

综上所述, 给出 NMMC 算法变换矩阵 W 的计算方法如下:

Step 1: 针对每一个训练样本搜索其 k_1 个类内近邻, 分别搜索该样本与其他每类样本间的 k_2 个类间近邻;

Step 2: 由式 (8) 计算权函数 ω , 其中 $\alpha = 2$;

Step 3: 根据式 (6) 和 (7) 分别计算 C 类子目标对应的非参数化最大间隔准则的类内散布矩阵 S_w^N 和类间散射矩阵 S_b^N ;

Step 4: 求矩阵 $S_b^N - S_w^N$ 前 d 个最大特征值 $\{\lambda_1, \lambda_2, \dots, \lambda_d\}$ 对应的特征向量 $W = \{w_1, w_2, \dots, w_d\}$.

通过分析可知: 1) 非参数化的最大间隔准则中的类内和类间散射矩阵均采用非参数形式, 松弛了 MCC 算法对数据分布的类高斯要求; 2) 在计算类间散射矩阵时, NMMC 分别计算了每一个 K 近邻点的权值并对其加权, 更好地利用了训练数据的类边界信息, 有利于目标识别.

3 非参数化最大间隔准则下的 HRRP 目标识别

3.1 基于自相关小波目标 HRRP 特征提取

小波变换是时间和频域的局域变换, 它通过伸缩平移运算对信号进行多尺度细化, 在时频平面不同位置上获得不同的分辨率, 因而利用小波变换可有效地从信号中提取时频信息. 但是, 大部分小波变换并不

满足时移不变性, Saito 等人^[9]使用紧支撑小波自相关函数对信号进行多尺度分解, 指出其具有时移不变性.

3.1.1 自相关小波

尺度函数 $\phi(x)$ 和小波母函数 $\psi(x)$ 的双尺度方程为^[10]

$$\phi(x) = \sqrt{2} \sum_{k \in Z} h_k \phi(2x - k), \quad (12)$$

$$\psi(x) = \sqrt{2} \sum_{k \in Z} g_k \phi(2x - k). \quad (13)$$

其中: $H = \{h_k\}_{k \in Z}$ 为低通滤波器系数, $G = \{g_k\}_{k \in Z}$ 为高通滤波器系数.

尺度函数和小波母函数自相关函数的离散表达式为^[9]

$$\begin{aligned} \Phi(x) = \Phi(2x) + \frac{1}{2} \sum_{l=1}^{L/2} [b_{2l-1}(\Phi(2x - 2l + 1) + \\ \Phi(2x + 2l + 1))], \end{aligned} \quad (14)$$

$$\begin{aligned} \Psi(x) = \Phi(2x) - \frac{1}{2} \sum_{l=1}^{L/2} [b_{2l-1}(\Phi(2x - 2l + 1) + \\ \Phi(2x + 2l + 1))]. \end{aligned} \quad (15)$$

其中: b_k 为低通滤波器系数 $H = \{h_0, h_1, \dots, h_{L-1}\}$ 的自相关函数, 即

$$b_k = 2 \sum_{l=0}^{L-k-1} h_l h_{l+k}, \quad k = 1, 2, \dots, L-1;$$

$$b_{2k} = 0, \quad k = 1, 2, \dots, L/2 - 1.$$

若 ψ 为紧支撑小波, 则 $\Phi(x)$ 和 $\Psi(x)$ 同样满足紧支撑特性, 其支撑域是 $[-L+1, L-1]$.

3.1.2 自相关小波函数的选取

根据小波变换理论^[10], 消失矩参数一定时, 在所有的正交小波中, Daubechies (dB) 小波具有最短的支撑, 并且 dB 小波能很好地表征信号的突变和细节特征, 应用较为广泛. 但是, dB4 的小波母函数不具有时移不变性, 根据 3.1.1 节可构造其自相关小波. Su27 飞机某方位角下 HRRP 序列的 dB4 小波变换和 dB4 自相关小波变换如图 1 所示.

图 1(a) 自上而下分别为原 HRRP 序列, 自相关小波变换的一阶低频分量, 二阶低频分量和三阶低频分量; 图 1(b) 自上而下分别为原 HRRP 序列, 小波变换的一阶低频分量, 二阶低频分量和三阶低频分量. 从图 1 中可以看出, 与小波变换相比, dB4 自相关小波变换可更好地刻画信号的边缘、尖峰、断点等非平稳特征.

为了获得更加丰富的信号特征, 这里利用具有时移不变性和紧支撑特征的 dB4 自相关小波对目标 HRRP 作自相关小波变换, 将一阶自相关小波变换的低频分量和原信号一起作为目标的分类特征.




图1 dB4小波变换和自相关小波变换对比

3.2 基于NMMC的雷达目标HRRP识别

假设目标模板库中共有 J 类目标 $\{X_1, X_2, \dots, X_J\}$, 对于平移对准的HRRP, 为了解决其方位敏感性, 在训练阶段, 将目标姿态角划分为多个角域, 每个角域称为一帧, 对于每一帧HRRP提取其分类特征用于表达该帧所有HRRP的特性. 根据散射点模型理论^[1], 在散射点不发生越距离单元走动(MTRC)的方位角范围内, 目标的散射点模型基本不变. 用 ΔR 表示距离分辨率, L 表示目标相对雷达的横向尺寸, 散射点不发生越距离单元走动(MTRC)的方位角范围为^[1]

$$\delta_\phi \leq (\delta_\phi)_{\text{MTRC}} = \Delta R/L. \quad (16)$$

对每一个目标的HRRP数据采用基于 $(\delta_\phi)_{\text{MTRC}}$ 等方位间隔的数据划分方法得到 K 帧信号, 每帧看作一个子目标, 则整个目标模板库被划分为 $C = JK$ 个子目标. 第 i 个子目标的距离像记作 $\{x_{il} | l = 1, 2, \dots, N_i\}$, 包含 N_i 个距离像, 每幅距离像包含 M 个距离单元. 基于NMMC的雷达目标HRRP识别方法如下:

Step 1: 利用dB4自相关小波对目标模板库中的每一个训练样本作无抽取的一阶自相关小波变换, 记第 i 个子目标第 l 个距离像 x_{il} 的一阶自相关小波变换的低频分量 $CA_{il} = \{ca_{il}(1), ca_{il}(2), \dots, ca_{il}(M)\}$, 构造第 i 个子目标第 l 个分类特征, 记作

$$y_{il} = \{x_{il}(1), \dots, x_{il}(M), ca_{il}(1), \dots, ca_{il}(M)\};$$

Step 2: 根据第2.2节所述方法, 计算NMMC算法的变换矩阵 W ;

Step 3: 通过变换 $z_{il} = W^T y_{il}$ 将 $2M$ 维的原始数据空间中第 i 个子目标的第 l 个分类特征 y_{il} 映射到NMMC子空间得到 d 维特征向量 z_{il} ;

Step 4: 用dB4自相关小波对待测试样本 $\tilde{x} =$

$\{\tilde{x}(1), \tilde{x}(2), \dots, \tilde{x}(M)\}$ 作无抽取的一阶自相关小波变换, 得到其低频分量 $\tilde{CA} = \{\tilde{ca}(1), \tilde{ca}(2), \dots, \tilde{ca}(M)\}$, 则待测试样本 \tilde{x} 的分类特征

$$\tilde{y} = \{\tilde{x}(1), \dots, \tilde{x}(M), \tilde{ca}(1), \dots, \tilde{ca}(M)\};$$

Step 5: 通过变换 $\tilde{z} = W^T \tilde{y}$ 将 \tilde{y} 映射到NMMC子空间;

Step 6: 利用SVM分类器判断待测试样本的类别.

4 实验仿真

4.1 实验数据及其预处理

实验选用南京航空航天大学目标特性研究中心提供的J8II, F16, M2000, Su27和J6五种战斗机全方位角转台仿真数据, 雷达发射带宽约为500MHz. 所选实验数据中, 目标的方位角范围为 $0^\circ \sim 90^\circ$, 每度包含两个训练数据, 一个测试数据, 大致等间隔分布, 每幅HRRP包含128个距离单元. 针对雷达目标HRRP的幅值敏感性和时移敏感性问题, 需对HRRP数据进行类内对准和幅值归一化预处理. 由于实验采用转台数据, 不存在距离像时移敏感性问题, 并且所有距离像均已实现2-范数归一化处理.

4.2 雷达目标HRRP识别结果及分析

针对雷达目标HRRP的方位敏感性问题, 训练数据方位角域采用平均划分的方法, 方位角间隔由式(16)确定, 对于飞机类目标, 可适当放宽角度范围. 由于所选5种飞机几何外形结构数据相似, 综合考虑计算复杂度和特征提取算法对方位角的敏感程度, 在特征提取阶段统一设定 $(\delta_\phi)_{\text{MTRC}} = 18^\circ$. 每个子目标包含36个训练样本, 每个训练样本的特征维数为256, 特征维数远大于样本个数, 属于“小样本问题”. 由于支持向量机(SVM)基于结构风险最小化原理, 针对训练样本量较少、非线性以及高维模式识别问题表现出许多特有优势. 这里选择SVM分类器, 利用“一对一”算法, 采取多数胜出的原则对输入样本进行分类.

图2给出了F16, M2000和Su27三类飞机在MMC和NMMC两种算法下的二维HRRP特征投影. 其中: 图2(a)为MMC算法下的二维特征投影, 图2(b)为数据相同时NMMC算法下的二维特征投影. 从投影结果可以看出, 由于MMC算法要求假设待分类数据须服从高斯分布, 不适合雷达目标HRRP各距离单元幅值分布较为复杂的情况, 数据投影后的线性可分性不强. 而NMMC算法松弛了对数据分布的类高斯要求, 其降维特征的内聚度和类间可分性均优于MMC算法, 因此更加适合于目标HRRP特征提取.

LDA, MMC以及NMMC在所选HRRP实验数据下针对SVM分类器的识别结果如表1所示.

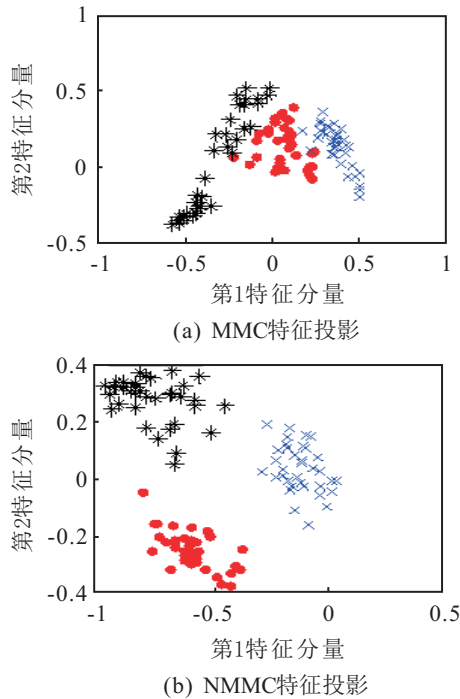


图 2 MMC 和 NMMC 算法下 3 类飞机二维 HRRP 特征提取

表 1 几种方法的识别结果比较 %

	LDA	MMC	NMMC
J8II	78.89	80.00	77.78
F16	82.22	81.11	84.44
M2000	82.22	85.56	90.00
Su27	84.44	88.89	95.56
J6	78.89	91.11	92.22
平均识别率	81.33	85.33	88.00

从各种飞机的目标识别结果可以看出: MMC 解决了 LDA 算法中的小样本问题, 对 5 种飞机目标的平均识别率较 LDA 提高了 4%, 识别效果明显优于 LDA; NMMC 在 MMC 算法的基础上, 将类间散射矩阵和类内散射矩阵非参数化, 松弛了对数据分布的类高斯要求, 更加符合目标 HRRP 数据的实际情况, 该算法还充分利用了类边界信息, 因此它对 5 种飞机目标的平均识别效果明显优于其他两种方法. 就计算量而言, 雷达目标识别分为训练和识别两个阶段, 假设待分类数据包含 C 个目标, 共 N 个训练样本, 并且每类目标包含的样本量相同, HRRP 序列长度为 M . 在训练阶段, 与 LDA 算法相比, MMC 算法的判决准则以差化商减少了 $4M^3/3$ 次乘法, 增加了 M^2 次加法; NMMC 算法将 MMC 算法中的类间散射矩阵和类内散射矩阵表示为非参数化的形式, 增加的计算量主要来自求解类内和类间近邻的 $M(N-1)!$ 次乘法和求解权函数 ω 的 $4kNM$ 次乘法与 $4kN$ 次开方 (参数 $\alpha = 2, k$ 为近邻个数). 因此, 训练阶段 3 种特征提取算法的计算量从小到大依次为 MMC, LDA 和 NMMC. 在识别阶段, LDA, MMC 和 NMMC 3 种特征提取算法的运算量相同, 实现一帧 HRRP 数据

的特征提取需要 $M(C-1)$ 次乘法和 $(M-1)(C-1)$ 次加法. 现阶段的雷达目标识别一般采取离线训练, 因此非参数化后并不影响雷达目标识别的实时性.

5 结 论

雷达目标 HRRP 的维数较高, 各距离单元幅值的分布具有复杂性. 非参数化最大间隔准则有效结合了最大间隔准则方法和非参数化方法的优点, 它通过利用最大间隔准则, 并非参数化类内和类间散射矩阵, 有效解决了 LDA 算法的“小样本问题”和需要假设待分类数据服从具有相同协方差矩阵的高斯分布的问题, 更加适用于雷达目标 HRRP 的特征提取. 为了获得更好的分类性能, 本文方法还利用具有时移不变性和紧支撑特征的 dB4 自相关小波对目标 HRRP 作自相关小波变换, 将一阶自相关小波变换的低频分量和原信号一起作为目标的分类特征. 基于 5 种飞机目标 HRRP 的仿真实验表明, 非参数化最大间隔准则下的雷达目标识别方法相比 LDA 方法和 MMC 方法具有更好的分类性能.

参考文献(References)

- [1] Xing Meng-dao, Bao Zheng, Pei Bing-nan. Properties of high-resolution range profiles[J]. Optical Engineering, 2002, 41(2): 493-504.
- [2] 夏宇垠, 冯大政, 李涛. 一种基于高分辨距离像数据的稳健检测算法[J]. 电子学报, 2010, 38(3): 672-677. (Xia Y Y, Feng D Z, Li T. A robust detection method for HRRP data[J]. Acta Electronica Sinica, 2010, 38(3): 672-677.)
- [3] 朱玉鹏, 王宏强, 黎湘, 等. 基于一维距离像序列的空间弹道目标微动特征提取[J]. 宇航学报, 2009, 30(3): 1133-1140. (Zhu Y P, Wang H Q, Li X, et al. Micro-motion feature extraction of spatial ballistic target based on HRRP dynamic sequence[J]. J of Astronautics, 2009, 30(3): 1133-1140.)
- [4] 陈凤, 侯庆禹, 刘宏伟, 等. 一种雷达 HRRP 在线自适应目标识别方法[J]. 自然科学进展, 2009, 19(12): 1410-1417. (Chen F, Hou Q Y, Liu H W, et al. An adaptive radar target recognition online method based on HRRP[J]. Process in Nature Science, 2009, 19(12): 1410-1417.)
- [5] 刘敬, 张军英, 赵峰. 基于 direct LDA 的幅度谱子空间雷达目标识别[J]. 系统工程与电子技术, 2008, 30(10): 1815-1818. (Liu J, Zhang J Y, Zhao F. Radar HRRP target recognition in amplitude spectrum subspace based on direct LDA[J]. Systems Engineering and Electronics, 2008, 30(10): 1815-1818.)