

雷达目标一维距离像识别中的最优因式分析子空间法

周代英 杨万麟

(电子科技大学电子工程学院 成都 610054)

摘要: 该文提出一种基于因式分析子空间进行特征提取的雷达目标识别方法。通过对目标训练样本集进行因式分析,在最大似然估计准则和最小错误分类率准则下建立最优因式分析子空间,利用因式分析子空间能够增强同类目标特征之间的相关性,提高同类目标特征的聚集度,从而改善目标识别性能。对三类飞机目标的仿真实验结果表明了方法的有效性。

关键词: 雷达目标识别; 一维距离像; 最优因式分析子空间

中图分类号: TN957.52

文献标识码: A

文章编号: 1009-5896(2007)10-2341-05

Recognition of Radar Target Based on Optimal Factor Analysis Subspace Using Rangeprofile

Zhou Dai-ying yang Wan-lin

(School of Electronic Eng., the Univ. of Electronic Science and Technology of China, Chengdu 610054 China)

Abstract: A novel approach of radar target recognition is proposed in this paper. For each target class, according to maximum likelihood rule and minimum classification error rate rule, an optimal factor analysis subspace is constructed by factor analysis on the training sample sets of target rangeprofiles. The optimal factor analysis subspace can produce an enhancement of correlation existing in the features of same target class. Such an enhancement provides higher clustering degree of the same class features. Thus, the factor analysis subspace is used to extract the feature of target for improving the accuracy of classification. The experimental results of three kinds of airplane targets demonstrate the efficiency of the approach proposed in this paper.

Key words: Radar target recognition; Rangeprofile; Optimal factor analysis subspace

1 引言

由高距离分辨率雷达可获取目标一维距离像,一维距离像反映了目标散射中心在雷达视线上的分布情况,表明一维距离像是利用一维信息来描述目标的三维信息;另外,一维距离像对目标姿态角的变化比较敏感,这些给基于一维距离像的目标识别带来困难^[1-3]。因此,采用合适的特征提取方法是基于一维距离像正确识别目标的关键^[2-4]。子空间法是非常经典的识别方法,通过首先建立一个子空间(特征子空间^[5]、正则子空间^[6]等)来提取目标分类特征,既可以减少数据量,又能获得较高的正确识别率,在雷达目标一维距离像识别中获得了较好的识别效果。

因式分析方法利用较少的参数对高维数据的协方差矩阵建模且能增大同类目标特征之间的相关性,因此,在手写体数字识别、数据压缩中得到应用^[7,8]。本文基于因式分析方法提出一种最优因式分析子空间,并将其应用于雷达目标一维距离像识别中。

2 因式分析子空间

设 $\mathbf{x}_{i,j}$ (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 ($i=1,2,\dots,g; j=1,2,\dots,N_i; N = N_1 + \dots + N_g$; 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), \mathbf{u}_i 为第 i 类目标的样本均值, 矢量 $\mathbf{y}_{i,j}$ 为 $\mathbf{x}_{i,j}$ 减去 \mathbf{u}_i 后的一维距离像矢量, 则第 i 类目标的矢量 $\mathbf{y}_{i,j}$ 按列组成矩阵

$$\mathbf{Y}_i = \left[\begin{array}{ccc} \mathbf{y}_{i,1} & \mathbf{y}_{i,2} & \dots & \mathbf{y}_{i,N_i} \end{array} \right] \left\{ \begin{array}{l} \mathbf{y}_{i,j} = \mathbf{x}_{i,j} - \mathbf{u}_i \end{array} \right. \quad (1)$$

将 $\mathbf{y}_{i,j}$ 矢量按以下方式进行因式分解^[9]

$$\left. \begin{array}{l} \mathbf{y}_{i,j,k} = \lambda_{i,k,1}f_{i,j,1} + \lambda_{i,k,2}f_{i,j,2} + \dots + \lambda_{i,k,M}f_{i,j,M} + \varepsilon_{i,k} \\ i = 1, 2, \dots, g; j = 1, 2, \dots, N_i \\ k = 1, 2, \dots, n; M \leq n \end{array} \right\} \quad (2)$$

其中 $\mathbf{y}_{i,j,k}$ 为 $\mathbf{y}_{i,j}$ 中的第 k 个元素, $\lambda_{i,k,m}$ ($m = 1, 2, \dots, M$) 为负载系数, $\mathbf{f}_{i,j} = [f_{i,j,1}, f_{i,j,2}, \dots, f_{i,j,M}]^T$ 为第 i 类目标一维距离像数据(去掉均值)的共同因子矢量, ε_i (n 维)为第 i 类目标一维距离像数据(去掉均值)的独立因子矢量, $\varepsilon_{i,k}$ 为 ε_i 的第 k 个元素。设 ε_i 和 $\mathbf{f}_{i,j}$ 满足以下条件

$$\left. \begin{array}{l} \mathbf{E}(\mathbf{f}_{i,j}) = \mathbf{0}, \text{Var}(\mathbf{f}_{i,j}) = \mathbf{I} \\ \mathbf{E}(\varepsilon_i) = \mathbf{0}, \text{Cov}(\varepsilon_{i,k_1}, \varepsilon_{i,k_2}) = 0, k_1 \neq k_2 \\ \text{Var}(\varepsilon_i) = \text{diag}\{\Psi_{i,1}^2, \Psi_{i,2}^2, \dots, \Psi_{i,n}^2\} \\ \text{Cov}(\mathbf{f}_{i,j}, \varepsilon_i) = \mathbf{0} \end{array} \right\} \quad (3)$$

其中 $E(\cdot)$ 为数学期望, $\text{Var}(\cdot)$ 为方差, $\text{Cov}(\cdot, \cdot)$ 为协方差。将式(2)改写为矩阵形式

$$\mathbf{y}_{i,j} = \mathbf{A}_i \mathbf{f}_{i,j} + \boldsymbol{\varepsilon}_i \quad (4)$$

其中

$$\mathbf{A}_i = \begin{bmatrix} \lambda_{i,1,1} & \lambda_{i,1,2} & \cdots & \lambda_{i,1,M} \\ \lambda_{i,2,1} & \lambda_{i,2,2} & \cdots & \lambda_{i,2,M} \\ \vdots & \vdots & & \vdots \\ \lambda_{i,n,1} & \lambda_{i,n,2} & \cdots & \lambda_{i,n,M} \end{bmatrix} \quad (5)$$

计算式(1)中 \mathbf{Y}_i 的相关矩阵

$$\mathbf{R}_i = [r_{i,l,m}] = E[\mathbf{Y}_i \mathbf{Y}_i^T] = \mathbf{A}_i \mathbf{A}_i^T + \boldsymbol{\Psi}_i \quad (6)$$

其中 $r_{i,l,m}$ 为相关矩阵 \mathbf{R}_i 中的第 l 行第 m 列上的元素, $\boldsymbol{\Psi}_i = \text{diag}\{\boldsymbol{\Psi}_{i,1}^2, \boldsymbol{\Psi}_{i,2}^2, \dots, \boldsymbol{\Psi}_{i,n}^2\}$ 。取式(4)中共同因子部分

$$\mathbf{y}'_{i,j} = \mathbf{A}_i \mathbf{f}_{i,j} \quad (7)$$

将矢量 $\mathbf{y}'_{i,j}$ 按列组成矩阵

$$\mathbf{Y}'_i = [\mathbf{y}'_{i,1} \quad \mathbf{y}'_{i,2} \quad \cdots \quad \mathbf{y}'_{i,N_i}] \quad (8)$$

计算矩阵 \mathbf{Y}'_i 的相关矩阵

$$\mathbf{R}'_i = [r'_{i,l,m}] = E[(\mathbf{Y}'_i)(\mathbf{Y}'_i)^T] = \mathbf{A}_i \mathbf{A}_i^T \quad (9)$$

其中 $r'_{i,l,m}$ 为相关矩阵 \mathbf{R}'_i 中的元素。比较式(6)和式(9), 有

$$\left. \begin{aligned} r'_{i,l,m} &= r_{i,l,m}, & l \neq m \\ r'_{i,l,l} &= r_{i,l,l} - \boldsymbol{\Psi}_{i,l}^2, & l = m \end{aligned} \right\} \quad (10)$$

计算相关系数

$$\tilde{r}_{i,l,m} = \frac{r'_{i,l,m}}{\sqrt{r'_{i,l,l} r'_{i,m,m}}}, \tilde{r}'_{i,l,m} = \frac{r'_{i,l,m}}{\sqrt{r'_{i,l,l} r'_{i,m,m}}} \quad (11)$$

组合式(10)和式(11), 可得

$$\left. \begin{aligned} \tilde{r}'_{i,l,m} &> \tilde{r}_{i,l,m} \\ l &= m \end{aligned} \right\} \quad (12)$$

上式表明, 一维距离像中共同因子矢量部分的相关性比原有一维距离像矢量的相关性要强, 即可以提高目标一维距离像数据集的聚集度, 从而减少异类目标特征区域之间的交叠。求解式(6)中的参数 \mathbf{A}_i 和 $\boldsymbol{\Psi}_i$ 的过程, 称为因式分析。通过对目标训练数据集的因式分析, 得到矩阵 \mathbf{A}_i 和 $\boldsymbol{\Psi}_i$, 代入式(7), 有

$$\left. \begin{aligned} \mathbf{f}_{i,j} &= \mathbf{A}_i^{-1} \mathbf{y}'_{i,j} = \mathbf{A}_i^T \mathbf{y}'_{i,j} \\ \mathbf{A}_i &= (\mathbf{A}_i^{-1})^T \end{aligned} \right\} \quad (13)$$

上式可见, M 维共同因子矢量 $\mathbf{f}_{i,j}$ 是矢量 $\mathbf{y}'_{i,j}$ 向矩阵 \mathbf{A}_i 的投影, 则称矩阵 \mathbf{A}_i 为因式分析子空间。但矢量 $\mathbf{y}'_{i,j}$ 不易获取, 实际中, 直接将矢量 $\mathbf{y}_{i,j}$ 向矩阵 \mathbf{A}_i 投影

$$\mathbf{z}_{i,j} = \mathbf{A}_i^T \mathbf{y}_{i,j} = \mathbf{A}_i^T (\mathbf{x}_{i,j} - \mathbf{u}_i) \quad (14)$$

其中 $\mathbf{z}_{i,j}$ 为投影矢量, 也称因式分析子像。比较式(13)和式(14)可知, $\mathbf{z}_{i,j}$ 比 $\mathbf{f}_{i,j}$ 多了一个分量, 该分量为独立因子矢量在子空间 \mathbf{A}_i 中的投影矢量, 由于因式分析子空间表征的是共同因子矢量的主投影方向, 而不是独立因子矢量的主投影方向, 所以, 共同因子矢量投影后, 其投影分量较大; 而独立因子矢量向子空间 \mathbf{A}_i 中投影后, 其投影分量变小, 即 $\mathbf{z}_{i,j}$ 中的主要分量仍然是 $\mathbf{f}_{i,j}$ 。因此, 以 $\mathbf{z}_{i,j}$ 代替 $\mathbf{f}_{i,j}$ 作为目标特征对识

别结果不会产生太大的影响。若矩阵 \mathbf{A}_i 是在特定准则下获得的, 则称为最优因式分析子空间。

3 基于最大似然估计的最优因式分析子空间

设矢量 $\mathbf{f}_{i,j}$ 和 $\boldsymbol{\varepsilon}_i$ 是均值和方差矩阵满足式(3)的高斯分布的随机矢量, 则 $\mathbf{f}_{i,j}$ 的概率密度函数为

$$p(\mathbf{f}_{i,j}) = (2\pi)^{-M/2} \exp\left\{-\frac{1}{2} \mathbf{f}_{i,j}^T \mathbf{f}_{i,j}\right\} \quad (15)$$

很显然, 由式(4)可得 $\mathbf{x}_{i,j}$ 对 $\mathbf{f}_{i,j}$ 的条件概率密度函数 $p(\mathbf{x}_{i,j} / \mathbf{f}_{i,j})$, 随后可计算 $\mathbf{x}_{i,j}$ 的概率密度函数 $p(\mathbf{x}_{i,j})$ 。设不同一维距离像的测量样本值 $\mathbf{x}_{i,j}$ 之间是统计独立的, 则第 i 类目标的所有一维距离像样本的联合概率密度函数的自然对数为

$$\ln p(\mathbf{x}_{i,1}, \mathbf{x}_{i,2}, \dots, \mathbf{x}_{i,N_i}) = \sum_{j=1}^{N_i} \ln p(\mathbf{x}_{i,j}) \quad (16)$$

最大似然估计就是使式(16)达到最大时估计参数 \mathbf{u}_i , \mathbf{A}_i 和 $\boldsymbol{\Psi}_i$ 。直接通过式(16)估计参数不是很容易, 而通过最大似然估计(17)中的 $Q(\tilde{\mathbf{u}}_i, \tilde{\mathbf{A}}_i, \tilde{\boldsymbol{\Psi}}_i; \mathbf{u}_i, \mathbf{A}_i, \boldsymbol{\Psi}_i)$ 函数使问题求解简单化而同样可以得到最大似然估计的结果^[10]。

$$Q(\tilde{\mathbf{u}}_i, \tilde{\mathbf{A}}_i, \tilde{\boldsymbol{\Psi}}_i; \mathbf{u}_i, \mathbf{A}_i, \boldsymbol{\Psi}_i) = \sum_{j=1}^{N_i} \int [d\mathbf{f}_{i,j} p(\mathbf{f}_{i,j} / \mathbf{x}_{i,j}, \mathbf{u}_i, \mathbf{A}_i, \boldsymbol{\Psi}_i) \cdot \ln p(\mathbf{f}_{i,j}, \mathbf{x}_{i,j} / \tilde{\mathbf{u}}_i, \tilde{\mathbf{A}}_i, \tilde{\boldsymbol{\Psi}}_i)] \quad (17)$$

其中 $p(\mathbf{f}_{i,j} / \mathbf{x}_{i,j}, \mathbf{u}_i, \mathbf{A}_i, \boldsymbol{\Psi}_i)$ 为后验概率密度函数, $p(\mathbf{f}_{i,j}, \mathbf{x}_{i,j} / \tilde{\mathbf{u}}_i, \tilde{\mathbf{A}}_i, \tilde{\boldsymbol{\Psi}}_i)$ 为联合条件概率密度函数, $\tilde{\mathbf{u}}_i, \tilde{\mathbf{A}}_i, \tilde{\boldsymbol{\Psi}}_i$ 分别为 $\mathbf{u}_i, \mathbf{A}_i, \boldsymbol{\Psi}_i$ 的估计。求 Q 对 $\tilde{\mathbf{u}}_i$, $\tilde{\mathbf{A}}_i$ 及 $\tilde{\boldsymbol{\Psi}}_i$ 的偏导数且令其等于零, 并将以上所求的概率密度函数代入, 化简可得最大似然估计参数的迭代方程

$$\tilde{\mathbf{A}}_i = \left\{ \sum_{j=1}^{N_i} (\Delta \mathbf{x}_{i,j})(\Delta \mathbf{f}_{i,j})^T \cdot \left[\sum_{j=1}^{N_i} [E[\boldsymbol{\delta} \mathbf{f}_{i,j} \boldsymbol{\delta} \mathbf{f}_{i,j}^T / \mathbf{x}_{i,j}] + (\Delta \mathbf{f}_{i,j})(\Delta \mathbf{f}_{i,j})^T] \right]^{-1} \right\} \quad (18)$$

$$\tilde{\mathbf{u}}_i = \frac{1}{N_i} \sum_{j=1}^{N_i} (\mathbf{x}_{i,j} - \tilde{\mathbf{A}}_i E[\mathbf{f}_{i,j} / \mathbf{x}_{i,j}]) \quad (19)$$

$$\tilde{\boldsymbol{\Psi}}_{i,k} = \frac{1}{N_i} \sum_{j=1}^{N_i} [(\Delta \mathbf{x}_{i,j} - \tilde{\mathbf{A}}_i \Delta \mathbf{f}_{i,j})_k^2 + (\tilde{\mathbf{A}}_i E[\boldsymbol{\delta} \mathbf{f}_{i,j} \boldsymbol{\delta} \mathbf{f}_{i,j}^T / \mathbf{x}_{i,j}] \tilde{\mathbf{A}}_i^T)_{k,k}], \quad k = 1, 2, \dots, n \quad (20)$$

其中 $(\cdot)_{k,k}$ 为矩阵中第 k 行第 k 列上的元素, $(\cdot)_k$ 为矢量中第 k 个元素

$$\Delta \mathbf{x}_{i,j} = \mathbf{x}_{i,j} - \frac{1}{N_i} \sum_{j=1}^{N_i} \mathbf{x}_{i,j} \quad (21)$$

$$\Delta \mathbf{f}_{i,j} = E[\mathbf{f}_{i,j} / \mathbf{x}_{i,j}] - \frac{1}{N_i} \sum_{j=1}^{N_i} E[\mathbf{f}_{i,j} / \mathbf{x}_{i,j}] \quad (22)$$

$$E[\mathbf{f}_{i,j} / \mathbf{x}_{i,j}] = [\mathbf{I} + \tilde{\mathbf{A}}_i^T \tilde{\boldsymbol{\Psi}}_i^{-1} \tilde{\mathbf{A}}_i]^{-1} \tilde{\mathbf{A}}_i^T \tilde{\boldsymbol{\Psi}}_i^{-1} (\mathbf{x}_{i,j} - \tilde{\mathbf{u}}_i) \quad (23)$$

$$E[\boldsymbol{\delta} \mathbf{f}_{i,j} \boldsymbol{\delta} \mathbf{f}_{i,j}^T / \mathbf{x}_{i,j}] = [\mathbf{I} + \tilde{\mathbf{A}}_i^T \tilde{\boldsymbol{\Psi}}_i^{-1} \tilde{\mathbf{A}}_i]^{-1} \quad (24)$$

经多次迭代后, 将 $\tilde{\mathbf{A}}_i$ 结果代入式(13), 即可得到基于最大似

然估计的最优因式分析子空间, 简称为最大似然因式分析子空间。

4 基于最小错误分类率的最优因式分析子空间

令 ω_s 表示第 s 类目标的集合, $p(\mathbf{x}_{i,j}/\omega_s)$ 表示一维距离像 $\mathbf{x}_{i,j}$ 属于第 s 类目标的概率密度函数。设各类目标的先验概率相同, 则最大后验概率分类准则可简化为

$$\omega_l = \arg \max_{\{\omega_s\}} [\ln p(\mathbf{x}_{i,j}/\omega_s)] \quad (25)$$

则判为第 l 类。计算对所有训练样本集的错误分类率

$$J = \frac{1}{N} \sum_{i=1}^g \sum_{j=1}^{N_i} \Theta \left(\max_{\omega_s \neq \omega_i} \ln \left[\frac{p(\mathbf{x}_{i,j}/\omega_s)}{p(\mathbf{x}_{i,j}/\omega_i)} \right] \right) \quad (26)$$

其中 $\Theta(\cdot)$ 为门限函数

$$\Theta(v) = \begin{cases} 1, & v > 0 \\ 0, & v \leq 0 \end{cases} \quad (27)$$

很显然, J 不是一个可导函数。为此, 将式(26)做一些改造, 使之平滑化。令

$$d(\mathbf{x}_{i,j}) = \ln \sum_{\substack{s=1 \\ s \neq i}}^g p(\mathbf{x}_{i,j}/\omega_s) - \ln p(\mathbf{x}_{i,j}/\omega_i) \quad (28)$$

采用以下的门限函数

$$\Theta(v) = \frac{1}{1 + \exp(-v)} \quad (29)$$

并利用公式 $\max_{\{k\}} h_k \approx \ln \sum_k e^{h_k}$, 再组合式(26), 式(28)及式(29), 可得

$$J = \frac{1}{N} \sum_{i=1}^g \sum_{j=1}^{N_i} \frac{1}{1 + \exp(-d(\mathbf{x}_{i,j}))} \quad (30)$$

最小错误分类率准则参数估计原理就是估计参数 \mathbf{u}_i , \mathbf{A}_i 及 Ψ_i 使 J 达到最小, 采用最速下降算法可得到各估计参数的迭代方程^[11]

$$\tilde{u}_{i,k}(\tau+1) = \tilde{u}_{i,k}(\tau) - \eta_{\tilde{u}_{i,k}} \frac{\partial J}{\partial \tilde{u}_{i,k}} \quad (31)$$

$$\tilde{A}_{i,k,m}(\tau+1) = \tilde{A}_{i,k,m}(\tau) - \eta_{\tilde{A}_{i,k,m}} \frac{\partial J}{\partial \tilde{A}_{i,k,m}} \quad (32)$$

$$\tilde{\Psi}_{i,k}(\tau+1) = \tilde{\Psi}_{i,k}(\tau) - \eta_{\tilde{\Psi}_{i,k}} \frac{\partial J}{\partial \tilde{\Psi}_{i,k}} \quad (33)$$

其中 $\tilde{u}_{i,k}$ 为矢量 $\tilde{\mathbf{u}}_i$ 中的第 k 个元素, $\tilde{A}_{i,k,m}$ 为矩阵 $\tilde{\mathbf{A}}_i$ 中第 k 行第 m 列上的元素, $\tilde{\Psi}_{i,k}$ 为矩阵 $\tilde{\Psi}_i$ 中对角线上的第 k 个元素; $\eta_{\tilde{u}_{i,k}}$, $\eta_{\tilde{A}_{i,k,m}}$ 和 $\eta_{\tilde{\Psi}_{i,k}}$ 为正的学习率, 由实验确定。

$$\frac{\partial J}{\partial \tilde{u}_{i,k}} = \sum_{t=1}^g \sum_{j=1}^{N_t} \frac{\partial J}{\partial \ln p(\mathbf{x}_{t,j}/\omega_i)} \frac{\partial \ln p(\mathbf{x}_{t,j}/\omega_i)}{\partial \tilde{u}_{i,k}} \quad (34)$$

$$\frac{\partial J}{\partial \tilde{A}_{i,k,m}} = \sum_{t=1}^g \sum_{j=1}^{N_t} \frac{\partial J}{\partial \ln p(\mathbf{x}_{t,j}/\omega_i)} \frac{\partial \ln p(\mathbf{x}_{t,j}/\omega_i)}{\partial \tilde{A}_{i,k,m}} \quad (35)$$

$$\frac{\partial J}{\partial \tilde{\Psi}_{i,k}} = \sum_{t=1}^g \sum_{j=1}^{N_t} \frac{\partial J}{\partial \ln p(\mathbf{x}_{t,j}/\omega_i)} \frac{\partial \ln p(\mathbf{x}_{t,j}/\omega_i)}{\partial \tilde{\Psi}_{i,k}} \quad (36)$$

$$\frac{\partial \ln p(\mathbf{x}_{i,j}/\omega_i)}{\partial \tilde{u}_{i,k}} = -[\mathbf{O}_i^{-1}(\mathbf{x}_{i,j} - \tilde{\mathbf{u}}_i)]_k \quad (37)$$

$$\frac{\partial \ln p(\mathbf{x}_{i,j}/\omega_i)}{\partial \tilde{A}_{i,k,m}} = -[\mathbf{O}_i^{-1} \tilde{\mathbf{A}}_i]_{k,m} - [\mathbf{O}_i^{-1}(\mathbf{x}_{i,j} - \tilde{\mathbf{u}}_i)]_k \cdot [(\mathbf{x}_{i,j} - \tilde{\mathbf{u}}_i)^T \mathbf{O}_i^{-1} \tilde{\mathbf{A}}_i]_m \quad (38)$$

$$\frac{\partial \ln p(\mathbf{x}_{i,j}/\omega_i)}{\partial \tilde{\Psi}_{i,k}} = -\frac{1}{2} \{ \mathbf{O}_{i,k,k}^{-1} - [\mathbf{O}_i^{-1}(\mathbf{x}_{i,j} - \tilde{\mathbf{u}}_i)]_k^2 \} \quad (39)$$

$$\mathbf{O}_i = \tilde{\Psi}_i + \tilde{\mathbf{A}}_i \tilde{\mathbf{A}}_i^T \quad (40)$$

其中 $\mathbf{O}_{i,k,k}$ 为矩阵 \mathbf{O}_i 第 k 行第 k 列上的元素, $[\cdot]_{k,m}$ 为矩阵中第 k 行第 m 列上的元素, $[\cdot]_k$ 为矢量中第 k 个元素。按以上方程经多次迭代后, 将求取的 $\tilde{\mathbf{A}}_i$ 代入式(13), 即可获得基于最小错误分类率的最优因式分析子空间, 简称为最小错误分类率因式分析子空间。

5 基于最优因式分析子空间的目标识别

现有 g ($g \geq 2$) 目标, 按以上方法, 由每一类目标的训练样本集建立各自的最优因式分析子空间 \mathbf{A}_i ($i=1,2,\dots,g$), 然后, 按式(14)计算每一类目标的各训练一维距离像在相应子空间中的投影矢量(子像)。每类目标的训练投影矢量平均作为该类目标的库模板矢量, 则总的库模板矢量为

$$\{\bar{\mathbf{z}}_1, \bar{\mathbf{z}}_2, \dots, \bar{\mathbf{z}}_g\} \quad (41)$$

其中 $\bar{\mathbf{z}}_i$ 为第 i 类目标的训练平均投影矢量。

对输入目标的一维距离像 \mathbf{x}_i , 在子空间 \mathbf{A}_i 中的投影矢量为 \mathbf{z}_i , 计算以下欧氏距离

$$d_i = \|\mathbf{z}_i - \bar{\mathbf{z}}_i\|, \quad i=1,2,\dots,g \quad (42)$$

则判输入目标为第 l 类

$$l = \arg \min_{\{i\}} \{d_i\} \quad (43)$$

6 仿真实验

6.1 数据描述

本实验中用于分类的数据是对飞行中的 3 种飞机(大型、中型、小型)所成的一维距离像。信号的带宽为 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)。每一飞机录取 7 段数据。对飞机目标数据进行识别之前作如下预处理:

(1)归一化: 将每幅一维距离像的模归一化为 1。

(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 变换的一半作为识别输入矢量进行实验。

6.2 实验结果

实验数据为 3 种飞机各取一段的 160 幅距离像数据(总数为 480 幅), 其中, 每一目标从一段数据中取 100 幅彼此之间相关性最小的距离像作为训练数据, 在剩余的距离像数据中选 60 幅距离像作为测试数据。对所选训练数据, 采用以上两种方法分别建立基于最大似然估计因式分析子空间和基

于最小错误分类率因式分析子空间, 利用这些子空间对测试数据集进行如下识别实验。实验中, 对每类目标的训练样本集计算协方差矩阵, 以协方差矩阵的对角元素作为 $\tilde{\Psi}_i$ 的初值, 对协方差矩阵进行本征分解, 以特征矢量组成的矩阵与特征值的均方根值组成的对角矩阵的积作为 $\tilde{\Lambda}_i$ 的初值, 以各目标训练样本均值作为 \tilde{u}_i 的初值。

(1)子空间维数 M 对最大似然因式分析子空间, 取不同的维数, 且 3 类目标的子空间维数取相同的值, 迭代次数均为 20, 然后进行识别实验, 实验结果如图 1 所示。图中示意了平均正确识别率与子空间维数的关系曲线。




图 1 平均正确识别率与子空间维数的关系曲线

由图 1 可见, 最大似然因式分析子空间法的识别率随子空间维数的增大而有上升的趋势, 但维数为 16 以后, 平均正确识别率几乎没有多大变化, 因此, 在实验中, 取子空间的维数为 16。对基于最小错误分类率的因式分析子空间进行实验, 可得到同样的结论, 不过这时子空间的维数取 14 较为合适。

(2)基于两个最优准则的因式分析子空间的分类结果 利用训练数据集和测试数据集, 基于两个因式分析子空间法(最大似然因式分析子空间的维数为 16 维及最小错误分类率因式分析子空间的维数为 14)和直接利用距离像方法(不分展区, 距离像维数取 128)进行分类实验; 在建立因式分析子空间时, 所有目标类对应的各迭代参数完成一次迭代后, 然后对训练数据集进行识别, 计算平均错误分类率, 当平均错误分类率小于给定的门限值或迭代次数大于 200 时停止迭代。本实验中, 对最大似然因式分析子空间法, 该门限值取 10%, 其迭代次数为 20 时终止, 对最小错误分类率因式分析子空间法, 该门限值取 7%, 其迭代次数为 35 时终止; 最小错误分类率因式分析子空间, $\tilde{\Lambda}_i$, $\tilde{\Psi}_i$ 和 \tilde{u}_i 的学习率分别取为 0.03, 0.2 及 0.05, 即同类参数中的元素的学习率选为一样。结果列于表 1 中。

由表 1 可见, 两因式分析子空间的平均识别率比直接利用一维距离像的识别率高 4% 以上, 这主要是因为: (1)特征提取时已减去一维距离像均值矢量, 但纵向上散射点之间相对分布状态并没有改变, 即分类信息仍然保留下来。(2)利用最优因式分析子空间提取的特征比原始一维距离像数据的聚集度有所增大, 从而减少了不同目标类特征之间的交

迭。另外, 从表中还可看到, 最小错误分类率因式分析子空间法的平均识别率又比最大似然因式分析子空间法高 3% 左

表 1 3 方法对 3 种飞机目标的识别率(%)

	直接利用一维距离像方法 (128 维)	基于最大似然估计的因式分析子空间法(16 维)	最小错误分类率因式分析子空间法(14 维)
大型飞机	91	95	96
中型飞机	91	91	93
小型飞机	77	85	89
平均识别率	86	90	93

右, 因式分析子空间法对识别输入矢量的维数由原来的 128 维降低至 16 维和 14 维。因此, 因式分析子空间能降低维数和提高正确识别率, 且基于最小错误分类率而建立的因式分析子空间对识别率有进一步的改善, 这些结果与理论分析一致。

(3)两因式分析子空间法的收敛速度 图 2 列出了两因式分析子空间的平均正确识别率与迭代次数的关系曲线, 最大似然因式分析子空间的维数为 16, 最小错误分类率因式分析子空间的维数取 14, 学习率与以上取法相同。由图 2 可见, 最大似然因式分析子空间法经过 20 次迭代后, 平均正确识别率达到 90% 左右; 而最小错误分类率因式分析子空间法需要经过 35 次迭代后, 平均正确识别率才达到 93% 左右。结果表明, 两因式分析子空间的收敛速度均较快, 相对而言, 最大似然因式分析子空间法的收敛速度比最小错误分类率因式分析子空间法更快一些。

(4)含有噪声样本数据的识别 一维距离像在一维距离像样本中加入高斯噪声, 信噪比分别为 5dB、10dB、15dB 及 20dB。由于是实测数据, 其中已含有一些噪声, 为了较真实地反映信噪比的情况, 在加入噪声前, 必须先估计其中的信噪比: 先确定目标所在区域, 则剩下的区域为噪声, 即可计算信噪比。实验参数同上。每一信噪比下, 进行 200 次重复实验, 然后计算 3 类目标的平均正确识别率, 利用两因式分析子空间方法和一维距离像方法进行了识别实验, 结果如图 3 所示。




图 2 两因式分析子空间法的平均正确识别率与迭代次数的关系曲线

图 3 3 方法的平均正确识别率与信噪比的关系曲线

由图 3 可见, 在高信噪比 20dB 时, 两因式分析子空间方法的平均正确识别率与样本中没有加入噪声时的识别率相差不大; 在低信噪比 5dB 时, 两方法的平均识别率仍然在为 77.3% 以上, 而直接利用一维距离像方法只有 64% 左右, 表明, 最优因式分析子空间法具有一定的抗噪性能。这主要因为: 噪声的分布特性与独立因子矢量的分布相似, 在建立因式分析子空间时, 噪声当作是独立因子矢量中的分量而被去掉; 而且, 因式分析子空间不是独立因子矢量和噪声的主投影方向, 则噪声向因式分析子空间投影后, 其投影分量减小, 即噪声分量降低了。

7 结束语

本文提出基于最优因式分析子空间的雷达目标一维距离像识别方法。文中给出了两种建立最优因式分析子空间的迭代方程, 最后利用因式分析子空间法对 3 类飞机目标的实测距离像数据进行了分类实验, 从实验结果可得出如下结论: (1) 因式分析子空间能降低识别输入矢量的维数。(2) 因式分析子空间法能改善正确识别率。(3) 最小错误分类率因式分析子空间法的正确识别率高于最大似然因式分析子空间法。(4) 最大似然因式分析子空间法的收敛速度较最小错误分类率因式分析子空间法要快。(5) 最优因式分析子空间方法具有一定的抗噪性能。

参考文献

- [1] Rihaczek A W and Hershkowitz S J. Theory and Practice of Radar Target Identification[M]. Norwood, MA: Artech House, 2000: 168-181.
- [2] Hudson S and Psaltis D. Correlation filters for aircraft identification from radar range profiles[J]. *IEEE Trans. on Aerospace and Electronic Systems.*, 1993, 29(3):741-748.
- [3] Nelson D E, Starzyk J A, and Ensley D D. Iterated wavelet transformation and discrimination for HRR radar target recognition[J]. *IEEE Trans. on System Man and Cybernetics-part: system and humans*, 2002, 33(1): 52-57 .
- [4] Jacobs S P and Sullivan J A. Automatic target recognition using sequences of high range resolution radar range profiles[J]. *IEEE Trans. on Aerospace and Electronic Systems.*, 2000, 36(2): 364-381.
- [5] Novak L M and Owirka G J. Radar target recognition using an eigen-image approach[C]. IEEE International Radar Conference, America, 1994: 129-131.
- [6] Liu B Y and Yang W L. Radar target recognition using canonical transformation to extract features[J]. *Proc. SPIE*, 1998, 3545: 368-371.
- [7] Hinton G, Dayan P, and Revow M. Modeling the manifolds of images of handwritten digits[J]. *IEEE Trans. on Neural Networks*, 1997, 8(1): 65-74.
- [8] Kambhatla N and Leen T K. Fast nonlinear dimension reduction. In Advances in Neural Information Processing Systems[C]. Cowan J, Tesauro G, and Alspector J, Eds. San Mateo. CA: Morgan Kaufman, 1994, 6: 152-159.
- [9] Itagaki A, Takashima M and Ashino Y, *et al.* Fuzzy inference systems by genetic algorithm and factor analysis modeling for multivariate complex systems[C]. IEEE Symposium on Emerging Technologies & Factory Automation, Europe, 1994: 199-205.
- [10] Ghahramani Z and Hinton G. The EM algorithm for mixtures of factor analyzers[R]. Uni. Toronto, Toronto, Ont., Canada, Tech. Rep. CRG-TR-96-1, 1996.
- [11] Saul L K and Rahim M G. Maximum likelihood and Minimum classification error factor analysis for automatic speech recognition[J]. *IEEE Trans. on Speech and Audio Processing*, 2000, 8(2): 115-125.

周代英: 男, 1966 年生, 副教授, 研究方向为目标识别、雷达信号处理及高速信号处理等。

杨万麟: 男, 1945 年生, 教授, 博士生导师, 研究方向为大阵列雷达成像、目标识别及雷达信号处理等。