

文章编号:1001-9081(2007)08-2044-03

雷达目标一维像识别中的自适应特征子空间法

周代英¹, 张琰²

(1. 电子科技大学 电子工程学院, 成都 610054; 2. 湖南信息职业技术学院, 长沙 410200)

(daiyingzhou@163.com)

摘要: 针对雷达目标一维距离像识别中常规特征子空间法的缺点, 提出了一种自适应特征子空间法。该子空间既能自适应子空间维数的变化, 又能自适应目标类别数的变化。同时, 与常规特征子空间相比, 建立自适应特征子空间的运算量大为减少。对三类和四类目标的仿真实验结果表明了该方法的有效性。

关键词: 雷达目标识别; 一维距离像; 自适应特征子空间

中图分类号: TP391 **文献标志码:**A

Recognition of radar target based on adaptive feature subspace using range profile

ZHOU Dai-ying¹, ZHANG Yan²

(1. School of Electronic Engineering, University of Electronic Science and Technology of China, Chengdu Sichuan 610054, China;
2. Hunan Vocational Information Technology College, Changsha Hunan 410200, China)

Abstract: Aiming at the shortcoming of general statistical feature subspace for range profile recognition in radar target, an adaptive feature subspace approach was proposed. When the number of subspace's dimension or the number of target classes was changed, the adaptive feature subspace could be easily obtained by iteration. Compared with general statistical feature subspace, less operation was needed in forming the adaptive feature subspace. The simulated experimental results of three targets and four targets demonstrate the efficiency of the proposed approach.

Key words: radar target recognition; range profile; adaptive feature subspace

0 引言

基于高分辨率雷达可获取目标的一维距离像。相对于低分辨率雷达而言, 一维距离像包含了更多有利于目标识别的信息, 因此, 利用一维距离像能够提高雷达对目标的识别性能。但是, 一维距离像敏感于目标姿态角的变化。因此, 恰当的特征提取和分类方法是基于一维距离像识别目标的关键^[1-4]。其中, 特征子空间法是一种比较有效的方法^[5], 当目标类别数和训练样本确定时, 通过建立一个特征子空间来提取目标分类特征, 既可以减少数据量, 又可以获得较高的正确识别率。但在实际应用中, 当一种新的目标出现时, 原来的目标模板库必须进行更新, 即所谓的动态建库技术, 而对于传统的统计特征子空间方法, 当库目标数变化时, 必须重新建立一个新的子空间, 以前的子空间得不到充分的利用。

本文提出一种自适应特征子空间法, 当目标类别数及子空间维数变化时, 不需要从头开始建立子空间, 而是在原来子空间的基础上, 经过较少的运算即可获得所要求的子空间。

1 自适应特征子空间

设 X_i (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 ($i = 1, 2, \dots, g$; $j = 1, 2, \dots, N$; $N = N_1 + N_2 + \dots + N_g$; 其中 g ($g \geq 2$) 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), 所有这些一维距离像构成训练样本集 $\{x(1), x(2), \dots, x(N)\}$, 其中 $x(m)$ ($m = 1, 2, \dots, N$) 表示训练样本集中第 m 个训练一维距离像减去训练样本集总

平均矢量后的矢量。由训练样本集建立协方差矩阵 C , 由以下神经网络结构模型可计算矩阵 C 中的特征矢量^[6]。

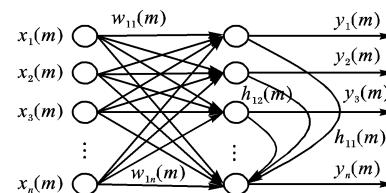


图 1 计算特征矢量的神经网络结构模型

图 1 中只有输入层和输出层, 没有隐含层, 输入数据为减去训练样本平均值的训练一维距离像, $x_i(m)$ ($i = 1, 2, \dots, n$) 为 $x(m)$ 中的第 i 个元素。由图 1 可得:

$$\begin{aligned} y(m) &= z(m) + H^T(m)y(m) \\ z(m) &= W^T(m)x(m) \end{aligned} \quad (1)$$

其中 T 表示转置; $y(m)$ (l 维列矢量, $l < n$) 表示图中的输出矢量, 即 $y(m) = [y_1(m), y_2(m), \dots, y_l(m)]^T$; $W(m)$ ($n \times l$ 维) 为所有前馈权系数组成的矩阵, 其中每一列对应于一个输出节点的前馈权系数矢量, 即 $W(m) = [w_1(m) \ w_2(m) \ \dots \ w_l(m)]$; $H(m)$ ($l \times l$ 维) 为所有反馈系数组成的矩阵, 其中每一列对应相应输出节点的反馈权系数矢量, 即 $H(m) = [0 \ h_2(m) \ \dots \ h_l(m)]$, 由图可见, H 为上三角形方阵; 为书写简单, 在后面的推导中, 将 m 省略。由式(1) 可得, 对第 k 个输出节点的值平方并取期望值:

$$E(y_k^2) = E[(w_k^T x)^2] + E[(h_k^T y)^2] + 2E[(w_k^T x)(h_k^T y)] \quad (2)$$

收稿日期: 2007-02-05; 修回日期: 2007-04-12。

作者简介: 周代英(1966-), 男, 湖南涟源人, 副教授, 博士, 主要研究方向: 目标识别、雷达信号处理; 张琰(1964-), 男, 湖南洞口人, 工程师, 硕士, 主要研究方向: 通信信号处理。

式(2)右边第一项为输入矢量变换后的矢量的能量,第二项为横向变换矢量的能量,第三项为输入变换矢量与横向变换矢量的互相关值。根据特征分解理论可知:1)在满足 $\mathbf{w}_k^T \mathbf{w}_k = 1$ 的条件下,第一项的值应最大;2)在满足 $\mathbf{h}_k^T \mathbf{h}_k = 0$ 的条件下,第二项的值应为零^[8]。据此可以得到两个目标函数:

$$J(\mathbf{W}, \mathbf{H}) = \sum_{k=1}^l E[y_k^2] + \sum_{k=1}^l (1 - \mathbf{w}_k^T \mathbf{w}_k) u_k \quad (3)$$

$$B(\mathbf{W}, \mathbf{H}) = \rho \sum_{k=1}^l E[y_k^2] + \sum_{k=1}^l (\mathbf{h}_k^T \mathbf{h}_k) E[v_k] \quad (4)$$

其中 $u_k, E[v_k]$ 为 Lagrange 乘数, ρ 为一常数。从以上的讨论可知,对 $J(\mathbf{W}, \mathbf{H})$,只需调整 \mathbf{W} 使 $J(\mathbf{W}, \mathbf{H})$ 最大,而对 $B(\mathbf{W}, \mathbf{H})$,只需调整 \mathbf{H} 使 $B(\mathbf{W}, \mathbf{H})$ 最小。由式(3)两边对 \mathbf{w}_k 求导:

$$\begin{aligned} \frac{\partial J(\mathbf{W}, \mathbf{H})}{\partial \mathbf{w}_k} &= E[2(\mathbf{w}_k^T \mathbf{x}) \mathbf{x} + 2(\mathbf{h}_k^T \mathbf{y}) \mathbf{x}] - 2u_k \mathbf{w}_k \\ &\quad - 2E[y_k \mathbf{x}] - 2u_k \mathbf{w}_k \end{aligned} \quad (5)$$

令式(5)为零,然后两边乘 \mathbf{w}_k^T ,并利用条件 $\mathbf{w}_k^T \mathbf{w}_k = 1$,化简可得:

$$\begin{aligned} u_k &= E[y_k z_k] \\ z_k &= \mathbf{w}_k^T \mathbf{x} \end{aligned} \quad (6)$$

将式(6)代入式(5):

$$\frac{\partial J(\mathbf{W}, \mathbf{H})}{\partial \mathbf{w}_k} = 2E[y_k \mathbf{x}] - 2E[y_k z_k] \mathbf{w}_k \quad (7)$$

根据统计梯度最速上升方法,将式(7)中的偏导值作为矩阵 \mathbf{W} 的调整量,去掉数学期望运算符,则 \mathbf{W} 中列矢量(即前馈权系数矢量)的更新方程为:

$$\mathbf{w}_k(m+1) = \mathbf{w}_k(m) + \eta [y_k(m) \mathbf{x}(m) - y_k z_k(m) \mathbf{w}_k(m)] \quad (8)$$

其中 $\eta (> 0)$ 为学习率。

由式(4)两边对 \mathbf{h}_k 求导:

$$\frac{\partial B(\mathbf{W}, \mathbf{H})}{\partial \mathbf{h}_k} = 2\rho E[y_k y_{k-1}] + 2E[v_k] \mathbf{h}_k \quad (9)$$

$$\mathbf{y}_{k-1} = [y_1 \ y_2 \ \cdots \ y_{k-1}]^T$$

其中 \mathbf{y}_k 为第 k 个输出节点之前的所有输出节点值组成的列矢量。同理,由梯度最速下降方法,将式(9)中的导数作为矩阵 \mathbf{H} 的调整量,则 \mathbf{H} 中列矢量(即反馈权系数矢量)的更新方程为:

$$\begin{aligned} \mathbf{h}_k(m+1) &= \mathbf{h}_k(m) - \eta [\rho y_k(m) \mathbf{y}_{k-1}(m) + \\ &\quad v_k(m) \mathbf{h}_k(m)] \end{aligned} \quad (10)$$

其中 η 为学习率,可以取为正常数,也可以按式(11)自适应变化^[6]:

$$\eta_k(m+1) = \frac{\eta_k(m)}{\gamma + y_k^2(m) \eta_k(m)} \quad (11)$$

其中 γ 为小于但接近于 1 的常数,如 $\gamma = 0.99$, η_k 为 \mathbf{w}_k 和 \mathbf{h}_k 对应的学习率。

文献[8]已证明,当取 $\rho < 3/2$ 及 $v_k > y_k z_k$ 时,式(8)和式(10)中的迭代方程是收敛的,当收敛到稳态值时,有:

$$\begin{aligned} \mathbf{w}_k(\infty) &= \mathbf{e}_k \\ \mathbf{h}_k(\infty) &= 0 \end{aligned} \quad (12)$$

其中 \mathbf{e}_k 表示协方差矩阵 \mathbf{C} 的特征值按从大到小的顺序排列时的第 k 个特征值所对应的特征矢量。

由以上的讨论可知,每输入一个一维距离像,迭代一次,经过所有训练一维距离像输入迭代后,前馈权值矢量 \mathbf{w}_k 即接近于协方差矩阵 \mathbf{C} 的第 k 个特征值所对应的特征矢量。选取前 $l(l \leq n)$ 个输出节点对应的权值矢量组成矩阵:

$$\mathbf{A} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \cdots \ \mathbf{w}_l] \quad (13)$$

则 \mathbf{A} 称为自适应特征子空间。其主要特点表现在:

1)当子空间的维数增大时,只要在图 1 中增加输出节点,且原来子空间的坐标轴完全不用改变,由式(8)和式(10)迭代即可求得增加的坐标轴。这表明了它具有子空间维数的自适应。

2)当目标类别数增大时,训练样本集也增多,只需在原有子空间的基础上对增加部分的训练一维距离像进行迭代即可得到新的子空间。这表明它具有目标类别数的自适应。

3)与常规特征子空间相比,建立自适应特征子空间的运算量大为减少。因为,建立常规特征子空间时,必须计算训练样本集的协方差矩阵,然后进行奇异值分解求取特征值及对应的特征矢量,而建立自适应特征子空间只需通过简单的迭代即可。

一维距离像 \mathbf{x}_{ij} 向子空间 \mathbf{A} 投影:

$$\mathbf{s}_{ij} = \mathbf{A}^T (\mathbf{x}_{ij} - \bar{\mathbf{x}}) \quad (14)$$

其中 $\bar{\mathbf{x}}$ 为训练样本集的总平均矢量; \mathbf{s}_{ij} 为一维距离像的投影矢量。

2 基于自适应特征子空间的目标识别

现有 $g(g \geq 2)$ 目标,按以上方法,由训练样本集建立自适应特征子空间 \mathbf{A} ,然后,按式(14)计算各目标训练一维距离像在 \mathbf{A} 中的投影矢量,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:

$$\{\bar{\mathbf{s}}_1 \ \bar{\mathbf{s}}_2 \ \cdots \ \bar{\mathbf{s}}_g\} \quad (15)$$

其中 $\bar{\mathbf{s}}_i$ 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}_t ,在 \mathbf{A} 中的投影矢量为 \mathbf{s}_t ,计算以下欧氏距离:

$$d_i = \|\mathbf{s}_t - \bar{\mathbf{s}}_i\|; i = 1, 2, \dots, g \quad (16)$$

则判输入目标为第 k 类:

$$k = \arg \min_{|i|} \{d_i\} \quad (17)$$

当目标类别数增多时,在原有子空间的基础上,对新增加目标的训练一维距离像数据按以上方法进行迭代,即可获得目标数增加后的子空间。

3 仿真实验

设计四种点目标:“|”字型、“V”字型、“干”字型和“小”字型。雷达发射脉冲的带宽为 150 MHz(距离分辨率为 1 m,雷达径向取样间隔为 0.5 m),目标设置为均匀散射点目标,“|”目标的散射点为 5,其余三目标的散射点数均为 9。在目标姿态角为(0~60°)范围内每隔 1°的一维距离像中,取目标姿态角为 0°、2°、4°、6°、…、60°的一维距离像进行训练,组成训练样本集,其余姿态角的一维距离像作为测试数据,组成测试样本集,则每类目标有 30 个测试样本。对训练样本集先按以上方法求取自适应特征子空间的第一根坐标轴,在此基础上,经过简单迭代可求取第二根坐标轴,以此类推即可求取所需要的坐标轴。由此可见,对子空间维数的自适应已经包含在建立过程中。所以没有单独用仿真实验来验证对子空间维数的自适应性。经过实验,子空间的维数取 10 较合适。

实验 1 学习率(η)对识别性能的影响

从以上的推导中可知,前馈权值矢量与反馈权值矢量的收敛速度与学习率有关。学习率不同,那么建立的特征子空间的坐标轴也不同,最终影响对目标的正确识别率。选取不同的常数学习率,对三类目标(“|”、“V”和“干”)进行了识别实验,结果如表 1 所示。表 2 也列出了采用自适应变化学习

率的识别结果。表 1 可见,当学习率从 0.0001 到 0.08 时,对三类目标的平均识别率逐渐增大,过后又有一些降低,对这三类目标的最佳学习率应该为 0.08 左右。表 2 是采用自适应学习率的识别结果,与表 1 比较,其平均识别率超出了表 1 中最好的情况,这与所期望的一致。因此,在以后的识别实验中均采用自适应学习率。取不同的学习率,对“|”目标的都能全部正确识别,这可能是因为该目标与其他两目标差异较大所造成的。表 1、2 中, $\rho = 3$, $v_k = y_k z_k$, 子空间维数为 10。

表 1 取不同的学习率 η , 对三类目标的识别率(%)

η	“ ”目标	“V”目标	“干”目标	平均识别率
0.0001	100	57	50	69
0.001	100	70	63	77
0.005	100	47	73	73
0.01	100	67	70	79
0.05	100	83	73	85
0.08	100	83	80	88
0.1	100	80	77	85
0.15	100	80	80	86

表 2 采用自适应学习率的识别结果

目标类别	识别率/%
“ ”目标	100
“V”目标	87
“干”目标	83
平均识别率	90

实验 2 乘子对识别性能的影响

在式(10)中,没有明确给出 v_k 乘子的具体的显式表达式,不同的取法,同样会影响前馈权值矢量与反馈权值矢量的收敛速度,影响最后的特征子空间。实验中, v_k 取三种形式:(a) $y_k z_k + 0.01 \times y_k^2$, (b) $y_k z_k + 0.01 \times |y_k|$ 及(c) $y_k z_k$ 。实验结果列于表 3。表 3 可见, v_k 乘子取为(a) 时,平均识别率最好; v_k 乘子取为(b)、(c) 时,平均识别率有所降低;从总体看,三种形式的平均识别率相差不是太大,并且取为(c) 时计算最为简单,因此,在后面的识别实验中 v_k 乘子取为(c)。

表 3 乘子取三种形式的识别率(%)

v_k	“ ”目标	“V”目标	“干”目标	平均识别率	“干”目标
$y_k z_k + 0.01 \times y_k^2$	100	90	83	91	83
$y_k z_k + 0.01 \times y_k $	100	87	83	90	83
$y_k z_k$	100	87	83	90	83

注: $\rho = 3$, 自适应学习率, 子空间维数为 10

实验 3 基于本文方法和直接利用一维距离像方法对三类目标的识别

对以上三类仿真目标(“|”目标,“V”目标及“干”目标),在姿态角 0~60°范围内,划分训练样本集和测试样本集。利用两种方法进行了对比识别实验:直接利用一维距离像方法和基于自适应特征子空间方法。结果如表 4。

表 4 两种方法对三种目标在姿态角 0~60°范围内的正确识别率(%)

	直接利用一维距离像	基于自适应特征子空间法
“ ”目标	95	100
“V”目标	80	87
“干”目标	80	83
平均识别率	85	90

从中可以看到:对目标“|”,直接利用一维距离像方法的识别率为 95%,而本文方法的识别率为 100%;对目标“V”,直接利用一维距离像方法的识别率为 80%,而本文方法的识别率为 87%;对目标“干”,直接利用一维距离像方法的识别率为 80%,而本文方法的识别率为 83%。平均而言,本文方法的识别率高于直接利用一维距离像方法的识别率。

实验 4 四类目标的识别

在三类目标的基础上再增加一类目标即“小”字型目标,在三类目标自适应特征子空间的基础上,对“小”字型目标的训练—维距离像数据按以上方法进行迭代,即可获得四类目标的自适应特征子空间。不需要从头开始建立,从而减少运算时间。同样也采用直接利用一维距离像方法的对四类目标的识别结果。结果如表 5。由表可见,对四类目标,本文方法仍然能获得较高的识别率。

表 5 两方法对四种目标在姿态角 0~60°范围内的正确识别率/%

	直接利用一维距离像	基于自适应特征子空间法
“ ”目标	85	94
“V”目标	78	85
“干”目标	74	81
“小”目标	76	86
平均识别率	78	86

4 结语

提出一种自适应特征子空间雷达目标一维距离像识别方法。该子空间一方面能自适应子空间维数的变化,又能自适应目标类别数的变化,同时,与常规特征子空间法相比,建立子空间的运算量大为减少,并且仍然具有较好的识别性能。仿真实验结果表明了方法的有效性。

参考文献:

- [1] HE S H, ZHANG W, GUO G R. Target discrimination and recognition using high resolution range features[C]// Proceedings of the IEEE 1992 National Aerospace and Electronics Conference. [S. l.]: IEEE Press, 1992, 1: 280~283.
- [2] LI H J, YANG S H. Using range profiles as feature vectors to identify aerospace objects[J]. IEEE Transactions on Antennas and Propagation, 1993, 41(3): 261~268.
- [3] HUDSON S, PSALTIS D. Correlation filters for aircraft identification from radar range profiles[J]. IEEE Transactions on Aerospace and Electronics System, 1993, 29(3): 741~748.
- [4] EOM K B, CHELLAPPA R. Noncooperative target classification using hierarchical modeling of high-range resolution radar signatures[J]. IEEE Transactions on Signal Processing, 1997, 45(9): 2318~2326.
- [5] NOVAK L M, OWIRKA G J. Radar target identification using an eigen-image approach[C]// IEEE International Radar Conference. [S. l.]: IEEE Press, 1994: 129~131.
- [6] KUNG S, DIAMANTARAS K. Adaptive principal component extraction (APEX) and application[J]. IEEE Transactions on Signal Processing, 1994, 42(5): 1202~1217.
- [7] OJA E. A simplified neuron model as a principal component analyzer[J]. Journal of Math Biology, 1982, 15(3): 267~273.
- [8] FIORI S, PIAZZA F. A general class of Ψ -APEX PCA neural algorithms[J]. IEEE Transactions on Circuits and System, 2000, 47(9): 1394~1397.