

基于 KPCA 准则的 SAR 目标特征提取与识别¹

韩 萍^{***} 吴仁彪^{**} 王兆华^{*} 王蕴红^{***}

^{*}(天津大学电信学院 天津 300072)

^{**}(中国民航学院通信与信息处理研究所 天津 300300)

^{***}(中国科学院自动化研究所模式识别国家重点实验室 北京 100080)

摘 要 该文给出了一种基于 KPCA (Kernel Principal Component Analysis) 和 SVM(Support Vector Machine) 的合成孔径雷达 (Synthetic Aperture Radar, SAR) 目标特征提取与识别方法。该方法在非线性空间内利用线性 PCA (Principal Component Analysis) 准则提取目标特征并由 SVM 分类器完成目标识别。基于美国国防高级研究计划署 (Defense Advanced Research Project Agency, DARPA) 和空军研究室 (Air Force Research Laboratory, AFRL) 提供的实测 SAR 地面目标数据的实验结果表明, 该文方法不但能够提高识别率, 具有良好的推广能力, 同时还降低了对方位估计精度的要求, 是一种有效的 SAR 目标特征提取与识别方法。

关键词 合成孔径雷达, 自动目标识别, KPCA 准则, 特征提取, SVM 分类器

中图分类号 TN951, TP751

1 引 言

合成孔径雷达自动目标识别 (Automatic Target Recognition, ATR) 因其在现代战场感知中的重要性已成为目前国内外模式识别领域的重点研究课题之一。其主要环节之一就是目标的特征提取, 它直接影响识别结果。SAR 图像不同于一般的光学图像能够比较完整地描述目标的整体形状, 而是表现为稀疏的散射中心分布, 并对成像的方位非常敏感。因此, 如何有效地提取目标特征就显得更为重要。

本文给出了一种基于 KPCA 准则^[1] 及 SVM^[2] 的 SAR 目标图像的特征提取与识别方法, 该方法利用 KPCA 准则进行非线性特征提取, 然后送入 SVM 分类器分类。用 DARPA/AFRL 提供的实测 MSTAR(Moving and Stationary Target Acquisition and Recognition)SAR 地面目标数据对该方法进行验证, 并与其它方法相比较, 结果表明本文方法具有良好的识别率及推广能力。

2 KPCA 方法^[1]

设训练样本集为 $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M\}$, 其中 $\mathbf{x}_k \in \mathbf{R}^N$ 是一个列矢量, M 为训练样本总数。设 Φ 是一个非线性映射, 对应的空间记为 F , F 中的样本记为 $\Phi(\mathbf{x}_k)$, 且满足 $\sum_{k=1}^M \Phi(\mathbf{x}_k) = 0$, 则 F 空间中样本的协方差矩阵为

$$C = \frac{1}{M} \sum_{j=1}^M \Phi(\mathbf{x}_j) \Phi(\mathbf{x}_j)^T \quad (1)$$

对 C 做特征分解得:

$$\lambda \mathbf{v} = C \mathbf{v} \quad (2)$$

¹ 2002-07-09 收到, 2003-01-08 改回

国家自然科学基金项目 (69902009, 60272049); 中国科学院自动化研究所模式识别国家重点实验室开放课题; 民航总局教育研究基金项目

其中 \mathbf{v} 是 F 空间中对应于 λ 的特征矢量, \mathbf{C} 的特征值均为非负, 不失一般性, 设 $0 \leq \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_M$, 对应的特征向量分别记为 $\mathbf{v}^1, \mathbf{v}^2, \dots, \mathbf{v}^M$, 它们可由 F 空间中的样本 $\Phi(\mathbf{x}_i)$ 张成, 记

$$\mathbf{v}^r = \sum_{i=1}^M \alpha_i^r \Phi(\mathbf{x}_i) \quad (3)$$

考虑等式:

$$\lambda_r(\Phi(\mathbf{x}_k) \cdot \mathbf{v}^r) = \Phi(\mathbf{x}_k) \cdot \mathbf{C}\mathbf{v}^r \quad (4)$$

式中 (\cdot) 表示点积运算。

将 (1), (3) 式代入 (4) 式并令 $K_{ij} = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)), i, j = 1, 2, \dots, M$; 得

$$M\lambda_r \alpha^r = \mathbf{K}\alpha^r \quad (5)$$

式中 $M\lambda_r$ 是 \mathbf{K} 的特征值, $\alpha^r = [\alpha_1^r, \alpha_2^r, \dots, \alpha_M^r]^T$ 是相应的特征向量。假设对应于特征值大于零的特征向量分别为 $\alpha^p, \alpha^{p+1}, \dots, \alpha^M$, 将 \mathbf{v}^r 归一化 ($r = p, p+1, \dots, M$), 可得 $M\lambda_r(\alpha^r \cdot \alpha^r) = 1$, 此时样本 $\Phi(\mathbf{x})$ 在 \mathbf{v}^r 上的投影:

$$g_r(\mathbf{x}) = (\mathbf{v}^r \cdot \Phi(\mathbf{x})) = \sum_{i=1}^M \alpha_i^r (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x})), \quad r = p, p+1, \dots, M \quad (6)$$

称 $g_r(\mathbf{x})$ 为对应于 Φ 的第 r 个非线性主元分量。将所有投影值形成一个矢量 $\mathbf{g}(\mathbf{x}) = [g_p(\mathbf{x}), g_{p+1}(\mathbf{x}), \dots, g_M(\mathbf{x})]^T$ 作为样本的特征。

计算 $g_r(\mathbf{x})$ 时, 涉及到求解非线性映射的点积运算问题, 若 F 空间中的维数很高甚至是无限维时, 直接计算点积将很困难, 为解决这一问题, 同时也为避免寻找映射 Φ , 根据 Mercer^[2] 定理, 用核函数 $K_1(\mathbf{x}_i, \mathbf{x}) = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}))$ 代替 F 空间的点积运算, (6) 式可写为

$$g_r(\mathbf{x}) = (\mathbf{v}^r \cdot \Phi(\mathbf{x})) = \sum_{i=1}^M \alpha_i^r K_1(\mathbf{x}_i, \mathbf{x}), \quad r = p, p+1, \dots, M \quad (7)$$

这里需要说明的是, 我们在本节开始做了一个假设, 即 $\sum_{k=1}^M \Phi(\mathbf{x}_k) = 0$, 若样本数据不满足这一条件, F 空间中的样本可由下式代替:

$$\tilde{\Phi}(\mathbf{x}_i) = \Phi(\mathbf{x}_i) - \frac{1}{M} \sum_{i=1}^M \Phi(\mathbf{x}_i) \quad (8)$$

其它与上述计算方法相似。此时, (5) 式中的 \mathbf{K} 用下式来代替

$$\tilde{\mathbf{K}} = \mathbf{K} - \mathbf{1}_M \mathbf{K} - \mathbf{K} \mathbf{1}_M + \mathbf{1}_M \mathbf{K} \mathbf{1}_M \quad (9)$$

式中 $\mathbf{1}_M$ 是系数为 $\frac{1}{M}$ 的 $M \times M$ 阶单位阵。

KPCA 方法在 F 空间内具有与线性 PCA 相同的数学和统计特性, 如各主元分量互不相关; 主元分量能够表示样本数据的最大方差; 用主元分量进行样本数据重构其均方误差最小; 样本的表示熵减小等等。除此之外, 还能比线性 PCA 提取出更多的样本信息。有实验证明, 在达到同样分类性能的前提下, KPCA 所需的主元个数要少于线性 PCA^[1]。与其它非线性特征提取方法相比, 它不需要解决非线性优化问题而只涉及矩阵的特征值分解计算。

3 分类器设计

由于 SAR 自身的特点, 其在 360° 方位范围内对目标的成像数目有限, 因此, 训练样本集

比较小, 为了得到更高的识别率和更好的推广性, 我们选用 SVM 分类器^[2]。SVM 分类器是对统计学习理论中结构风险最小化原则的一个实现, 它既可以解决线性可分问题又可解决非线性可分问题。同时, 它能很好地控制小样本、高维模式情况下学习机的推广性能并给出唯一最优解。分类准则是使两类样本距分类面最近的样本点到分类面的距离最大。如图 1 所示, 图中最优分类面为 H。

最优分类判决函数为^[2]

$$f(x) = \text{sgn} \left(\sum_{i=1}^{N_{sv}} y_i \gamma_i^* K_2(x, x^*) + b \right) \quad (10)$$

式中 $\text{sgn}(\cdot)$ 表示符号函数; $y_i \in \pm 1$ 表示样本类别标号; γ_i^* 表示支持矢量对应的拉格朗日因子; x 为输入样本矢量, x^* 表示支持矢量, 如图 1 中落在 H_1 和 H_2 上的点; $K_2(x, x^*)$ 表示核函数; b 表示分类面的阈值; N_{sv} 表示支持矢量的个数。

在 SVM 分类器和 KPCA 中都用到了核函数, 二者可以相同也可以不同, 若将按 (7) 式求解出的样本特征送入 SVM 分类器中训练, 得到的支持矢量记为 $g(x_i)^*$, $i = 1, 2, \dots, N_{sv}$ 。此时 (10) 式可写为

$$f(x) = \text{sgn} \left(\sum_{i=1}^{N_{sv}} y_i \gamma_i^* K_2 [g(x), g(x_i)^*] + b \right) \quad (11)$$

可以看到这是一个基于多层核的 SVM 分类器。




图 1 最优分类面 H 及非最优分类面 H'

4 实验结果及分析

4.1 实验数据

本实验所用数据是由美国 DARPA/AFRL MSTAR 工作组提供的实测 SAR 地面静止目标数据。数据由聚束式 SAR 采集而成, 分辨率为 $0.3 \times 0.3\text{m}$ 。该数据集中所有目标图像大小为 128×128 。我们选用了工作组推荐的训练和测试数据。其中, 训练样本是 SAR 在俯仰角为 17° 时对地面目标的成像数据, 包括 3 类, 即 T72sn-132(主战坦克 MBTs, Main Battle Tanks), BMP2sn-c21(装甲车 APCs, Armored Personal Carriers) 和 BTR70sn-c71(装甲车 APCs)。其样本数分别为 232, 233 和 233 个, 它们的光学像如图 2 所示。测试样本是 SAR 在俯仰角为 15° 时对地面目标的成像数据, 有 3 大类 7 个型号, 各个型号对应的样本数分别为 T72sn-132(196 个), T72sn-812(195 个), T72sn-S7(191 个), BMP2sn-c21(196 个), BMP2sn-9563(195 个), BMP2sn-9566(195 个) 和 BTR70sn-c71(196 个)。每类样本的方位覆盖范围是 $0^\circ \sim 360^\circ$, 间隔为 1° , 即每隔 1° 就给出一幅像, 图 3 给出了 T72sn-132 在不同方位角下的 SAR 像。同类不同型号的目标在配备上有些差异, 可参见文献 [3]。



图 2 三种训练样本光学像




图 3 T72sn-132 在 $2^\circ, 87^\circ, 235^\circ$ 方位角下的 SAR 像

4.2 SAR 像预处理

为保证目标在图像中的平移不变性,同时为减小 SAR 目标图像的动态范围并抑制乘性噪声,首先对目标像做对数变换,然后再做傅里叶变换,并取其幅频特性,以保证目标的平移不变性。因傅里叶变换幅频特性具有对称性,所以只用一半信息,这样既压缩了样本的维数,又提高了运算速度。

4.3 特征提取

图像经过预处理后,利用 KPCA 准则求解样本的主元分量,核函数选为多项式函数, $K_1(u, v) = (u \cdot v + 1)^d$, $d = 2$ 。由于 SAR 像对目标方位的敏感性较强,不同方位下,同一目标对应的 SAR 像有很大区别,见图 3。为了更有效地提取目标特征,将每一类训练样本在 $0^\circ \sim 360^\circ$ 方位范围内,按等方位间隔分为 P 组,对 3 类训练样本在相同的方位组内分别进行特征提取。我们选用了 5 种分组方式,分别按 $10^\circ, 30^\circ, 90^\circ, 180^\circ, 360^\circ$ 间隔分组,以便分析方位角的变化对目标特征的影响。用 KPCA 提取主元分量时,主元个数与样本数有关,最多与样本数相等。本实验中,无论怎样分组,所提取的主元个数远远小于输入样本的维数 ($128 \times 128/2 = 8192$)。以不分组情况为例 (360°),训练样本共有 698 个,其主元分量个数最多也只有 698 个,所以在提取主元分量时,只要提取出核矩阵中对应于特征值大于零的特征矢量即可。

4.4 基于 SVM 的 SAR 目标识别

实验中,在每个方位单元内,每两类样本之间需建立一个 SVM 分类器,即 T72-BMP, T72-BTR 及 BMP-BTR。分类器的核函数选用径向基核函数 $K(u, v) = \exp(-\gamma\|u - v\|)$, $\gamma = 0.5$ 。识别时,利用待识别样本的方位信息(可通过目标跟踪或方位估计近似得到^[4]),选出相应方位单元的分类器两两分类,利用投票选举法得出最后分类结果。

我们将不同分组情况下得到的实验结果分别列于表 1 和表 2,并与文献 [5]、文献 [6] 及线性 PCA 方法相比较。其中文献 [5] 是由 Timothy Ross 等人提出的一种基于模板匹配的 SAR ATR 方法,并以此结果作为标准,向该领域征集更优的 ATR 方法。该方法是在图像域内,将样本按 10° 方位间隔分组,在每一方位组内利用样本均值作为模板,用最小距离分类法进行分类。文献 [6] 是没有做任何特征提取,将样本按 30° 方位分组,在每一个方位单元内建立 SVM 分类器,识别时利用目标的方位信息选出相应方位单元的分类器进行分类。

从表 1 可见,两种方式分组情况下,用本文方法得到的识别率均高于其它 3 种方法。由于模板匹配法是利用样本的均值作为模板,其与样本图像的几何形状有直接关系,同时 SAR 目标图像对方位比较敏感,所以方位间隔越小,形成的模板质量越高,匹配效果越好,识别率更高,但模板数量增加,所需存储空间增大。在用 SVM 分类时,虽然 SVM 适合解决小样本高维模式分类问题,但由于按 10° 方位间隔分组时,样本数过少,每类目标在每个方位单元内只有 6, 7 个训练样本,训练性能较差,因此在按 30° 分组时,识别结果更好一些。

表 2 中,在 90° 时,本文方法得到的识别率最高,即 95.46%,此时虽然线性 PCA 方法也达到了 95%,但分组间隔增大时,其识别率迅速下降,在 360° 时已下降到 84.54%。若不利用目标图像的方位信息,利用本文方法识别率虽然有所下降(这主要是由于方位角的变化范围大使得目标图像结构变化也较大,相似性变差的缘故。),但仍可达到 91% 以上,优于线性 PCA 方法,对方位具有较好的鲁棒特性,降低了对目标方位信息估计的精度要求。

表 1 4 种分类方法的比较

	文献 [5] 模板匹配法	文献 [6] SVM	线性 PCA+SVM	KPCA+SVM(本文)
10°	88.88%	87.58%	93.63%	93.85%
30°	70.55%	90.70%	94.73%	95.16%

表 2 线性 PCA, KPCA 按不同方位间隔分组情况下的分类结果

	90°	180°	360°
线性 PCA+SVM	95.02%	88.79%	84.54%
KPCA+SVM	95.46%	92.38%	91.5%

5 结 论

本文将 KPCA 方法用于 SAR 目标特征提取, 根据实验数据样本少、维数高的特点, 选用 SVM 分类器进行识别, 通过与其它 3 种方法的比较, 证明本文方法不但能有效地提高识别率, 而且还具有很好的推广能力。特别是在不利用目标方位信息的情况下, 识别率仍然能够达到 91% 以上, 降低了对目标方位信息估计精度的要求。因此是一种有效的 SAR 目标特征提取与识别方法。

参 考 文 献

- [1] B. Schölkopf, A. Smola, K. R. Müller, Nonlinear component analysis as a kernel eigenvalue problem, *Neural Computation*, 1998, 10(5), 1299–1319.
- [2] V. N. Vapnik, *Statistical learning theory*, AT&T Research, London University, 1998.
- [3] E. R. Keydel, S. W. Lee, J. T. Moore, MSTAR extended operating conditions, A Tutorial, *SPIE*, 1996, 2757(3), 228–242.
- [4] Qun Zhao, DongXin Xu, J. C. Principe, Pose estimation of SAR automatic target recognition, *Proceedings of Image Understanding Workshop*, Monterey, CA., 1998, 11, 827–832.
- [5] T. Ross, S. Worrell, V. Velten, J. Mossing, M. Bryant, Standard SAR ATR evaluation experiment using the MSTAR public release data set, *SPIE*, 1998, 3370(4), 566–573.
- [6] Qun Zhao, J. C. Principe, Support vector machine for SAR automatic target recognition, *IEEE Trans. on Aerospace and Electronic Systems*, 2001, 37(2), 643–654.

SAR AUTOMATIC TARGET RECOGNITION BASED ON KPCA CRITERION

Han Ping* ** Wu Renbiao** Wang Zhaohua* Wang Yunhong***

**(Institute of Electronic Information Eng., Tianjin University, Tianjin 300072, China)*

*** (Inst. of Comm. and Signal Proc., Civil Aviation Univ. of China, Tianjin 300300, China)*

**** (Nat. Key Lab of Pattern Recognition, Inst. of Automation, CAS, Beijing 100080, China)*

Abstract In this paper, SAR ATR (Synthetic Aperture Radar Automatic Target Recognition) approach based on KPCA (Kernel Principal Component Analysis) is proposed. KPCA first maps the input data into some feature space using kernel functions and then performs linear PCA on the mapped data. It takes the principal components in nonlinear space as sample features, then SVM classifier is used to classify targets. Experimental results with MSTAR SAR data sets provided by the US DARPA/AFRL (Defense Advanced Research Projects Agency/Air Force Research Laboratory) show a better performance of classification and generalization.

Key words SAR, ATR, KPCA criterion, Feature extraction, SVM classifier

韩 萍: 女, 1966 年生, 副教授, 在职博士生, 研究方向: 数字信号处理, 模式识别。

吴仁彪: 男, 1966 年生, 天津市特聘教授, 博士生导师, 研究方向: 阵列信号处理, 高分辨率雷达成像。

王兆华: 男, 1937 年生, 教授, 博士生导师, 研究方向: 数字图像处理。

王蕴红: 女, 1967 年生, 副研究员, 博士, 研究方向: 模式识别、神经网络、现代信号处理。