

基于 Laplacian 正则化最小二乘的半监督 SAR 目标识别^{*}

张向荣^{1,2+}, 阳春^{1,2}, 焦李成^{1,2}

¹(西安电子科技大学 智能感知与图像理解教育部重点实验室, 陕西 西安 710071)

²(西安电子科技大学 智能信息处理研究所, 陕西 西安 710071)

Semi-Supervised SAR Target Recognition Based on Laplacian Regularized Least Squares Classification

ZHANG Xiang-Rong^{1,2+}, YANG Chun^{1,2}, JIAO Li-Cheng^{1,2}

¹(Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education of China, Xidian University, Xi'an 710071, China)

²(Institute of Intelligent Information Processing, Xidian University, Xi'an 710071, China)

+ Corresponding author: E-mail: xrzhang@ieee.org

Zhang XR, Yang C, Jiao LC. Semi-Supervised SAR target recognition based on Laplacian regularized least squares classification. *Journal of Software*, 2010,21(4):586-596. <http://www.jos.org.cn/1000-9825/3538.htm>

Abstract: A Synthetic Aperture Radar (SAR) target recognition approach based on KPCA (kernel principal component analysis) and Laplacian regularized least squares classification is proposed. KPCA feature extraction method can not only extract the main characteristics of target, but also reduce the input dimension effectively. Laplacian regularized least squares classification is a semi-supervised learning method. In the target recognition process, training set is treated as labeled samples and test set as unlabeled samples. Since the test samples are considered in the learning process, high recognition accuracy is obtained. Experimental results on MSTAR (moving and stationary target acquisition and recognition) SAR datasets show its good performance and robustness to azimuth interval. Compared with template matching, support vector machine and regularized least squares learning method, the proposed method gets more SAR target recognition accuracy. In addition, the effect of the number of labeled points on target identification performance is analyzed at different conditions.

Key words: KPCA (kernel principal component analysis); semi-supervised learning; Laplacian regularized least squares classification; SAR (synthetic aperture radar) target recognition

摘要: 提出了一种基于核主成分分析(kernel principal component analysis,简称 KPCA)和拉普拉斯正则化最小二乘(Laplacian regularized least squares,简称 LapRLS)的合成孔径雷达(synthetic aperture radar,简称 SAR)目标识别方

* Supported by the National Natural Science Foundation of China under Grant Nos.60803097, 60672126 (国家自然科学基金); the National High-Tech Research and Development Plan of China under Grant Nos.2008AA01Z125, 2007AA12Z223, 2006AA01Z107 (国家高技术研究发展计划(863)); the 11th 5-Year Pre-Research Project of China under Grant No.51307040103 (“十一五”预研项目); the Scientific and Technological Research Key Project of Ministry of Education of China under Grant No.108115 (国家教育部科学技术研究重点项目)

Received 2008-01-25; Revised 2008-08-07, 2008-10-06; Accepted 2008-11-28

法。KPCA 特征提取方法不仅能够提取目标主要特征,而且有效地降低了特征维数。Laplacian 正则化最小二乘分类是一种半监督学习方法,将训练集样本作为有标识样本,测试集样本作为无标识样本,在学习过程中将测试集样本包含进来以获得更高的识别率。在 MSTAR 实测 SAR 地面目标数据上进行实验,结果表明,该方法具有较高的识别率,并对目标角度间隔具有鲁棒性。与模板匹配法、支撑向量机以及正则化最小二乘监督学习方法相比,具有更高的 SAR 目标识别正确率。此外,还通过实验分析了不同情况下有标识样本数目对目标识别性能的影响。

关键词: 核主成分分析;半监督学习;拉普拉斯正则化最小二乘分类;SAR 目标识别

中图分类号: TP391 文献标识码: A

合成孔径雷达(synthetic aperture radar,简称 SAR)在对地面目标探测方面的独特优势及其在现代战场感知、对地打击等领域的良好应用前景,使得基于 SAR 图像的自动目标识别技术受到了越来越多的重视。SAR 图像不同于光学图像,它通常表现为稀疏的散射中心分布,并对成像的方位非常敏感,在不同视角上的目标呈现很大的差异。基于二维 SAR 图像的自动目标识别主要从两方面展开研究:特征提取方法和识别方法。前者如基于 Radon 变换、主成分分析(principle component analysis,简称 PCA)等,后者如模板匹配方法^[1,2]、基于 Bayes 网络的方法、基于隐 Markov 模型的识别方法^[3,4]、神经网络^[5]以及支撑向量机(support vector machine,简称 SVM)^[6,7]等。其中,模板匹配法是利用样本均值作为模板,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,方位间隔越小,形成的模板质量越高、匹配效果越好,但是需要对方位有较好的估计。文献[6]则利用全部像素值作为特征,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。该方法对目标图像没有进行特征提取,一方面,会因为噪声的存在降低识别率;另一方面,没有对样本进行适当降维,会给计算带来负担。文献[8]提出了采用核主成分分析(kernel PCA,简称 KPCA)对 SAR 目标进行特征提取,然后用 SVM 进行识别。与前两种方法相比,该方法的识别率有一定的提高,但当对包含 0°~360°方位角的所有数据同时进行识别时,由于方位角的变化范围较大,使得目标图像结构变化也较大,识别率不够理想。

上述 SAR 目标识别方法都是采用监督学习算法。近年来,半监督学习已成为机器学习领域的一个研究热点,在众多领域得到了广泛应用。传统的监督学习算法依赖于有标识的训练样本集,忽略了未标识样本的作用。实际应用中存在大量未标识数据资源,半监督学习算法就是利用这些未标识样本来提高学习算法的性能。本文主要研究基于半监督学习的 SAR 目标识别方法。

现有的半监督算法有生成模型方法、自训练方法、互训练方法、基于图的方法等。基于生成模型的半监督学习可以为未标识数据如何在学习算法中起到作用而提供最直观的 Bayesian 解释。在半监督学习中,未标识数据对辨识模型的先验分布 $p(x)$ 起作用,而标识数据对辨识模型的条件分布 $p(y|x)$ 起作用,通过综合两方面的信息来获得更好的模型联合分布 $p(x,y)$ 的估计。EM 算法可以用来学习分类问题中的混合正态分布模型,若生成混合模型假设正确,则未标识样本可以改善识别精度^[9];但是如果模型假设不正确,则未标识样本反而会损害识别精度^[10]。自训练半监督学习方法就是自己给自己提供训练,相当于自学。在半监督算法中,这一思想体现为学习机首先采用已标识样本进行训练,然后对未标识样本进行检验,从检验样本获取高置信(具有较高置信概率输出的样本)样本,再对学习机进行训练。如此训练下去,直到算法稳定。互训练半监督学习方法是指多个学习机互相提供训练,即互相学习。以两类学习问题为例,其思想体现为:首先将特征集分成两个尽可能相对平衡的特征集,然后对每个学习机采用已标识样本进行训练,采用另一学习机为本学习机对未标识样本集中具有较高置信的样本标识,然后进行再训练。如此循环,直至算法稳定^[11]。基于图的半监督学习方法由于受到谱图聚类和图结构化核迅速发展的促进,成为目前半监督学习方法中发展最为迅速且获得成果最多的领域,学者们已提出了众多的基于图的半监督学习算法。该方法总体上都是基于这样一个思想:在要求对已标识样本的识别应尽可能与目标标识一致的条件下,使得对整个图的标识尽可能地光滑,即避免出现标识的琐碎变化。这样,基于图的半监督学习方法就可以由正则框架来描述,即对已标识样本的损失函数加上光滑正则项。一般对于已标识样本的损失函数采用二次损失,而光滑正则项有多种选择,不同的选择形成了不同的基于图的半监督学习方法。基于 Laplacian

算子谱的图核方法采用再生核希尔伯特空间(reproducing kernel Hilbert space,简称 RKHS)中的范数 $\|f\|_K^2$ 作为正则项,其中,核 K 可以根据图得到,文献[12,13]都证明了 Laplacian 算子的谱变换可以得到适合半监督学习的核.文献[14]采用谱变换后的 Laplacian 算子生成正则项,提出了谱图转导学习机.

本文研究基于图的半监督学习算法的 SAR 目标识别,在训练学习过程中引入测试样本,将训练集作为有标识样本,测试集作为无标识样本,共同构造判决函数,使用该含有测试样本信息的判决函数实现对测试样本的识别.正则化最小二乘分类(regularized least squares classification,简称 RLSC)实现简单,仅要求解一个线性方程的系统,而在性能上与 SVMs 相当^[15,16].在其基础上引入一个关于图的 Laplacian 的正则化项,称为 Laplacian 正则化最小二乘分类(简称 LapRLSC),形成半监督学习框架.此框架下的半监督方法,可以通过所谓的“转导推理”^[14]将无标识样本以较高的精度赋予标识.本文首先基于 KPCA 对 SAR 目标图像进行非线性特征提取,在学习过程中纳入测试集样本,通过“转导推理”使测试样本获得标识.实验中,采用美国国防部高级研究计划局和空间实验室提供的实测 MSTAR SAR 地面目标数据对该方法进行验证,与原有的 SAR 目标识别方法相比, Laplacian 正则化最小二乘分类具有较高的识别率,并且对方位具有较好的鲁棒性.

1 SAR 图像特征提取——KPCA

PCA 是一种常用的特征提取方法,它能够较好地克服由于图像尺寸、方向、部分场景内容变化以及噪声干扰等的影响.但是,PCA 只考虑了图像数据中的二阶统计信息,未能利用数据中的高阶统计信息,忽略了多个像素间的非线性相关性.有研究表明,一幅图像的高阶统计往往包含了图像边缘或曲线多个像素间的非线性关系.KPCA 基于数据的高阶统计,描述了多个像素间的相关性,对噪声具有鲁棒性.所以,本文采用 KPCA 对 SAR 图像进行特征提取.

KPCA^[17]是一种非线性特征提取方法,它通过映射函数 Φ 把原始向量映射到高维特征空间 \mathcal{F} .在 \mathcal{F} 上进行 PCA 分析.其基本原理是:假设 x 是原始空间中的样本,通过映射函数 $x \rightarrow \Phi(x) \in \mathcal{F}$.假设训练集中有 m 个样本点,原始空间中的两个样本点 x_i, x_j 在 \mathcal{F} 空间的距离用它们的内积 $(\Phi(x_i) \cdot \Phi(x_j))$ 表示,定义核函数 $K(x_i, x_j) = (\Phi(x_i) \cdot \Phi(x_j))$.在特征空间 \mathcal{F} 上映射数据的协方差矩阵为

$$C \equiv \frac{1}{m} \sum_{i=1}^m (\Phi_i - u)(\Phi_i - u)^T \quad (1)$$

其中, $\Phi_i = \Phi(x_i)$, $u = \frac{1}{m} \sum_i \Phi_i$.

对于矩阵 C 的特征向量 v 和对应的特征值 λ , $Cv = \lambda v$, 因为 v 是在 $\{\Phi_i - u\}$ 生成的空间中,所以 v 可表示成

$$v = \sum_{i=1}^m \alpha_i (\Phi_i - u) \quad (2)$$

公式(2)两边都是在 $\{\Phi_i - u\}$ 生成的空间中,所以上式可以用 m 个方程表示为

$$\{\Phi_i - u\} \cdot Cv = \lambda ((\Phi_i - u) \cdot v) \quad (3)$$

令核矩阵为 K , $K_{ij} = (\Phi_i \cdot \Phi_j)$, $i, j = 1, 2, \dots, m$, 则在 \mathcal{F} 空间中的点积可以用 $(\Phi_i \cdot \Phi_j) = K(x_i, x_j)$ 给定的核函数来计算.

在主成分分析中,需要中心化的核矩阵 K^C , $K_{ij}^C = ((\Phi_i - u) \cdot (\Phi_j - u))$, 则公式(3)可写为

$$K^C K^C \alpha = \bar{\lambda} K^C \alpha \quad (4)$$

其中, $\bar{\lambda} = m\lambda$, $\alpha \in R^m$.

$$K^C \alpha = \bar{\lambda} \alpha \quad (5)$$

为了满足 $v \cdot v = 1 = \bar{\lambda} \alpha \cdot \alpha$, 取 α 的模为 $\sqrt{\bar{\lambda}}$. 对于训练向量 x_k 的主成分是 $(\Phi(x_k) - u) \cdot v = \bar{\lambda} \alpha_k$; 对于测试向量的主成分 $(\Phi(x) - u) \cdot v = \sum_i \alpha_i K(x, x_i) - \frac{1}{m} \sum_{ij} \alpha_i K(x, x_j) - \frac{1}{m} \sum_{ij} \alpha_j K(x_i, x_j) + \frac{1}{m^2} \sum_{i,j,n} \alpha_i K(x_j, x_n)$. 得到的主成分就是 \mathcal{F} 空间中的一个坐标值,把主成分向量作为新点的向量来表示.

KPCA 得到的主成分能够表示样本数据的最大方差,用主成分进行样本数据重构,其均方误差最小,比 PCA

提取出更多的样本信息,将许多在原样本空间用线性方法难以解决的问题转换为在高维空间可以用线性方法来解决的问题,而且它只涉及矩阵的特征值分解计算,不需要解决非线性优化问题.

2 基于 Laplacian 正则化最小二乘的 SAR 自动目标识别

SAR 自动目标识别应用在军事领域,获得高识别率无疑是至关重要的.由于正则化最小二乘分类只需要求解一个线性方程系统,实现简单,而且对其扩展的半监督方法——Laplacian 正则化最小二乘分类可以通过所谓的“转导推理”^[14]将无标识样本以较高的精度赋予标识,所以本文采用半监督学习算法的 Laplacian 正则化最小二乘分类进行 SAR 目标识别.

2.1 正则化最小二乘分类

正则化最小二乘分类(RLSC)是由 Rifkin 和 Poggio 提出的一种基于二次损失函数的正则化网络^[18].RLSC 和 SVMs 都建立在核函数基础上,在实现上,SVMs 通常要求解凸的二次规划问题,而 RLSC 则直接在由核定义的 RKHS 上最小化一个线性正则化函数,因而 RLSC 计算简捷;在性能上,RLSC 完全可以与 SVMs 相媲美^[15,16].下面给出 RLSC 的基本原理.

对于给定的训练集 $D = (x_i; y_i)_{i=1}^l$,其中 $x_i \in X$,表示第 i 个样本,用一个向量表示, $y_i \in Y$ 是该样本所属的类别标号, X 是 R^n 的闭子集, $Y \subset R$,RLSC 算法选择 RKHS 作为假设空间 \mathcal{H}_K ,最小化正则化风险泛函:

$$f^* = \arg \min_{f \in \mathcal{H}_K} \frac{1}{l} \sum_{i=1}^l (y_i - f(x_i))^2 + \gamma \|f\|_K^2 \quad (6)$$

其中, $\|f\|_K^2$ 是正定核 K 诱导的 \mathcal{H}_K 中函数 f 的范数, γ 是一个固定的参数.在分类情况下,取 $y_i \in \{1, -1\}$;对于多类情况,本文采用一对多的策略.基于 RKHS 的两个重要结论简化了式(6).

第一,该最小化问题的解存在且唯一^[15],并由表示理论^[19]给出解的表达形式:

$$f^*(x) = \sum_{i=1}^l \alpha_i^* K(x_i, x) \quad (7)$$

第二, $\|f\|_K^2$ 可以表示成下面的式子:

$$\|f\|_K^2 = \alpha^T K \alpha \quad (8)$$

其中, α 是待优化的列向量, K 是一个 $l \times l$ 的 Gram 矩阵, $K_{ij} = K(x_i, x_j)$.

将公式(7)、公式(8)代入公式(6),可得:

$$\alpha^* = \arg \min_{\alpha} \frac{1}{l} (Y - K\alpha)^T (Y - K\alpha) + \gamma \alpha^T K \alpha \quad (9)$$

通过解公式(9)得到 $\alpha^* = (K + \gamma I)^{-1} Y$,其中, Y 是一个标识向量, $Y = [y_1, \dots, y_l]^T$.

2.2 基于图的半监督学习

将 RLSC 扩展到 LapRLSC 涉及到基于图的半监督学习.根据半监督学习中数据的一致性先验假设^[20]:

- 局部一致性:指的是在空间位置上相邻的数据点具有较高的相似性;
- 全局一致性:指的是位于同一流形上的数据点具有较高的相似性.

流形即局部具有欧氏空间性质的空间.由以上两个假设可知:如果两点 $x_1, x_2 \in X$ 在 $p(x)$ 的内在几何中是靠近的,那么条件分布 $p(y|x)$ 在 $p(x)$ 的内在几何中沿着测地线的距离变化很小.

由于图和流形有很多相似的性质,最重要的一点就是都可以嵌入到欧氏空间,所以很多研究人员都使用图的方法逼近流形,并利用图的理论求解低维嵌入.对于流形来说,一个与之对应的图就是一个拓扑对象,其拓扑性质通过边的权值来表现.如果数据集足够大、噪声较小,合理定义图中边的权值可以充分逼近嵌入流形^[21].那么对于样本数据集 X ,将数据点看作一个无向加权图 $G=(V, E)$ 的顶点 V ,并定义成对数据点的相似度为图中的边,这样就根据数据点建立了一个与之对应的图.在图上定义一个近似函数,要求它尽可能地光滑,恰好可以满足一致性先验假设.

于是对 RLSC 进行扩展,给定一个有 l 个具有标识样本的集合 $\{(x_i, y_i)\}_{i=1}^l$ 和一个具有 u 个无标识本的集合 $\{x_j\}_{j=l+1}^{l+u}$, 无标识样本通过一个正则项加入进来,其作用是惩罚在一个聚类中变化太大的函数,从而得到下面的优化问题:

$$f^* = \arg \min_{f \in \mathcal{H}_K} \frac{1}{l} \sum_{i=1}^l (y_i - f(x_i))^2 + \gamma_A \|f\|_K^2 + \frac{\gamma_I}{(l+u)^2} \sum_{i,j=1}^{l+u} (f(x_i) - f(x_j))^2 W_{ij} \quad (10)$$

W_{ij} 是根据两点距离确定的权值.可以证明:

$$\sum_{i,j} (f_i - f_j)^2 W_{ij} = \sum_{i,j} (f_i^2 + f_j^2 - 2f_i f_j) W_{ij} = \sum_i f_i^2 D_{ii} + \sum_j f_j^2 D_{jj} - 2 \sum_{i,j} f_i f_j W_{ij} = 2f^T L f \quad (11)$$

其中: $D_{ii} = \sum_{j=1}^{l+u} W_{ij}$; $L = D - W$, L 是一个正定矩阵,可以看成定义在图上的算子.那么根据谱图理论:如果数据均匀取自高维空间中的低维流形,流形上的 Laplacian-Beltrami 算子可以由图的 Laplacian 逼近,则可得:其最前面的几个特征向量就是流形上的 Laplacian-Beltrami 算子特征函数的离散逼近^[22], L 就相当于流形学习中的 Laplacian-Beltrami 算子.

2.3 Laplacian正则化最小二乘分类

LapRLSC 是在 RLSC 基础上引入另外一个正则化项而形成的半监督学习框架,结合公式(11),则 LapRLSC 需要解决下式所表达的问题:

$$\min_{f \in \mathcal{H}_K} \frac{1}{l} \sum_{i=1}^l (y_i - f(x_i))^2 + \gamma_A \|f\|_K^2 + \frac{\gamma_I}{(l+u)^2} f^T L f = \min_{f \in \mathcal{H}_K} \frac{1}{l} \sum_{i=1}^l (y_i - f(x_i))^2 + \gamma_A \|f\|_K^2 + \gamma_I \|f\|_L^2 \quad (12)$$

其中: $f = [f(x_1), \dots, f(x_{l+u})]^T$. 对于第 2 个正则项,核 K 是约束在流形 \mathcal{M} 上的,记为 $K_{\mathcal{M}}$; RKHS 也是在流形 \mathcal{M} 上的,即 $\mathcal{H}_{\mathcal{M}}$, 这表明 $\|f\|_K = \|f\|_{\mathcal{H}_{\mathcal{M}}}$. 文献[23]已证明关于得到最优化问题的最优 f^* , 有 $\|f^*\|_L = \|f^*\|_K$; 并证明对于求解式(12)的最优化问题与求解式(6)所表达的正则化问题是相同的,尽管它们的正则化参数 γ 不同.根据表示理论^[19]:

$$f^*(x) = \sum_{i=1}^{l+u} \alpha_i^* K(x_i, x) \quad (13)$$

将公式(8)和公式(13)代入公式(12),可得

$$\alpha^* = \arg \min_{\alpha \in \mathbb{R}^{l+u}} \frac{1}{l} (Y - JK\alpha)^T (Y - JK\alpha) + \gamma_A \alpha^T K \alpha + \frac{\gamma_I}{(l+u)^2} \alpha^T K L K \alpha \quad (14)$$

对上式求关于 α 的偏导数,令该偏导数等于 0,则得到解 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_{l+u}^*)$ 的表达式:

$$\alpha^* = \left(JK + \gamma_A I I + \frac{\gamma_I l}{(l+u)^2} L K \right)^{-1} Y \quad (15)$$

K 是 $(l+u) \times (l+u)$ 的 Gram 矩阵, Y 是关于有标识和无标识样本点的 $(l+u)$ 维标识向量 $Y = [y_1, \dots, y_l, 0, \dots, 0]$, J 是一个 $(l+u) \times (l+u)$ 的对角矩阵 $J = \text{diag}(1, \dots, 1, 0, \dots, 0)$, L 是对图求 Laplacian 得到的 $(l+u) \times (l+u)$ 的矩阵.针对多类情况,本文采用一对多的策略.当 $\gamma_I = 0$ 时,就成为标准的 RLSC. LapRLSC 算法流程如下:

LapRLSC 算法.

输入: l 个有标识样本 $\{(x_i, y_i)\}_{i=1}^l$, u 个无标识样本 $\{x_j\}_{j=l+1}^{l+u}$;

Step 1. 用 $l+u$ 个结点建立一个数据邻接图,如果结点 i 在结点 j 的 n 近邻中或者 j 在 i 的 n 近邻中,那么将连接 i 和 j 的边的权值赋为 1,即 $W_{ij} = 1$; 否则, $W_{ij} = 0$.

Step 2. 计算图的 Laplacian 矩阵 $L = D - W$, D 是一个对角矩阵 $D_{ii} = \sum_{j=1}^{l+u} W_{ij}$.

Step 3. 计算 Gram 矩阵 $K_{ij} = K(x_i, x_j)$, 其中,核函数 $K(x_i, x_j) = \exp\left\{-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right\}$.

Step 4. 选择正则化参数 γ_A 和 γ_I .

Step 5. 用公式(15)计算 α^* .

Step 6. 输出函数 $f^*(x) = \sum_{i=1}^{l+u} \alpha_i^* K(x_i, x)$.

输出:通过 $f^*(x) = \sum_{i=1}^{l+u} \alpha_i^* K(x_i, x)$ 判断无标识样本 $\{x_j\}_{j=l+1}^{l+u}$ 的类别.

上述算法通过对训练集的有标识和无标识样本的学习得到判决函数,依此对测试集样本进行判决.同时,通过所谓的“转导推理”^[14]将训练集中无标识样本以最高的精度赋予标识.也就是说,在上述算法的 Step 1~Step 3 中,未标识数据训练集参与图的建立、图的 Laplacian 矩阵的求解以及 Gram 矩阵的计算,在得到判决函数后,分别对未标识数据及测试样本进行分类.未标识样本的作用是与有标识样本一起建立图,进而用图来逼近流形.由于流形假设高维的数据位于低维的流形上,利用流形可以帮助我们挖掘数据的内在结构,那么数据越充分,对于流形的逼近越有利.所以,本文将测试集样本引入学习训练中作为无标识样本,训练集作为有标识样本,两者共同参与图的建立、图的 Laplacian 矩阵的求解以及 Gram 矩阵的计算,使判决函数更加精确,最终通过决策函数对测试集样本进行决策.我们通过实验分析了有标识样本个数对于算法性能的影响.

3 SAR 图像识别实验

3.1 实验测试数据——MSTAR数据

本实验所用的 MSTAR 数据集由聚束式 SAR 采集而成,分辨率为 0.3m,包括 3 类目标:BMP2,BTR70 和 T72,每类样本的方位覆盖范围是 $0^\circ \sim 360^\circ$.在 SAR 图像中,目标是散射中心电磁散射的合成结果,对于同一目标,当它与雷达的相对位置发生变化时,其散射中心也会发生变化,导致不同方位角下的目标有明显的区别.实验中,先从原始 128×128 的图像中心截取 60×60 的区域,该区域包含了整个目标,而去除了多余的背景区域.在此基础上,利用 KPCA 提取各自目标图像 35 维特征,并归一化到 $[-1,1]$.表 1 列出了训练集和测试集样本的个数.

Table 1 Training and test set of SAR
表 1 SAR 目标识别训练集和测试集数据

Training set	Number of training data	Test set	Number of test data
BMP2 (Sn-c9563)	233	BMP2 (Sn-c9563)	195
		BMP2 (Sn-c9566)	196
		BMP2 (Sn-c21)	196
BTR70 (Sn-c71)	233	BTR70 (Sn-c71)	196
T72 (Sn-132)	232	T72 (Sn-132)	196
		T72 (Sn-812)	195
		T72 (Sn-s7)	191

3.2 参数设置

用于 SAR 目标识别的 Laplacian 正则化最小二乘方法有 4 个需要设定的参数:邻接图的近邻个数 n 、高斯核函数 $K(x_i, x_j) = \exp\left\{-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right\}$ 的宽度 σ^2 、控制周围空间中函数复杂性的参数 γ_A 以及控制分布的内在几何结构函数复杂性的参数 $\frac{\gamma_l}{(l+u)^2}$.其中,邻接图的近邻个数 n 在这一算法中不敏感,因此设为经验值 6.实验中主要考虑核函数的宽度 σ^2 以及 γ_A 和 $\frac{\gamma_l}{(l+u)^2}$ 对识别结果的影响.

(1) 核参数的确定

实验采用高斯核函数,其宽度 σ^2 过大或过小都会使识别率下降.如果能够建立起目标与核函数之间匹配程度的一种度量,则可为确定最优核参数提供依据.文献[24]提出了一种将核参数与超参数分开优化的方法,最大化核-目标配准来选择最优核参数.首先为每一个 σ^2 计算 Gram 矩阵 K ,然后根据 $\hat{A}(K', yy^T) = \frac{\langle K', yy^T \rangle}{\sqrt{\langle K', K' \rangle \langle yy^T, yy^T \rangle}}$

计算 $\hat{A}(K', yy^T)$, 使 \hat{A} 最大的 σ^2 即为最优的核参数. 这里的 K' 是关于有标识样本的 Gram 矩阵, y 是有标识样本的标签列向量. 实验中, σ^2 在 $\ln\sigma^2 = \{-10:1:10\}$ 上搜索, 得到在 10° 和 30° 的方位间隔分组实验中的 σ^2 为 e^2 , 在 $90^\circ, 180^\circ$ 和 360° 的方位间隔分组实验中的 σ^2 为 1.

(2) γ_A 和 $\frac{\gamma_l}{(l+u)^2}$ 的确定

γ_A 和 $\frac{\gamma_l}{(l+u)^2}$ 分别控制周围空间中函数的复杂性和控制分布的内在几何结构函数的复杂性. 对于不同比例的有标识样本和无标识样本, 其设置随之有所不同, 本文采用简单的网格搜索找到识别率最高的参数格点为最优的参数对, 其取值在下面的实验中给出.

3.3 实验结果与分析

实验 1. 本文方法与其他文献方法的比较.

为了评价本文提出的基于 Laplacian 正则化最小二乘 SAR 目标识别方法的性能, 我们将该方法与模板匹配法^[2], SVM^[6], PCA+SVM, KPCA+SVM 和 KPCA+RLSC 进行了比较. 分别对不同方位角度间隔的 SAR 目标数据进行了对比实验, 将每类训练样本和测试样本在 $0^\circ \sim 360^\circ$ 方位范围内, 按等方位间隔分为 P 组 (比如方位间隔为 10° , 则分为 36 组), 在每一组中将训练集全部作为有标识样本、测试集作为无标识样本进行测试, 最后将 P 组的结果求平均记录在表 2 中.

Table 2 Recognition accuracy of six methods

表 2 6 种方法的识别率 (%)

Azimuth interval	Template matching ^[2]	SVM ^[6]	PCA+SVM ^[8]	KPCA+SVM ^[8]	KPCA+RLSC	KPCA+LapRLSC
10°	88.88	87.58	93.63	93.85	90.94	94.81
30°	70.55	90.70	94.73	95.16	94.91	97.53
90°	-	-	95.02	95.46	94.43	98.48
180°	-	-	88.79	92.38	95.85	98.45
360°	-	-	84.54	91.50	95.38	98.63

实验中, 参数 γ_A 和 $\frac{\gamma_l}{(l+u)^2}$ 的选择采用在参数范围 $\ln\gamma_A = \{-10:1:10\}$ 和 $\ln\frac{\gamma_l}{(l+u)^2} = \{-10:1:10\}$ 的网格中搜索得到, 表 3 为各个方位间隔分组实验中的最优参数. 以 180° 为例: $-9 \sim -4$ 表示 $\ln\gamma_A$ 可以取到 $[-9, -8, -7, -6, -5, -4]$ 中的任意一个值. 同样, $-2 \sim -1$ 表示 $\ln\frac{\gamma_l}{(l+u)^2}$ 可以取到 $[-2, -1]$ 中的任意一个值. 两者自由组合.

Table 3 Parameters setting

表 3 参数设置

Azimuth interval	Parameter			
	Number of neighbors n	Kernel parameter σ^2	$\ln\gamma_A$	$\ln\frac{\gamma_l}{(l+u)^2}$
10°	6	e^2	-4	-4
30°	6	e^2	-9~-7	-4
90°	6	1	-9~-3	-2~-1
180°	6	1	-9~-4	-2~-1
360°	6	1	-9~-3	1~2

文献[2]采用模板匹配法, 在图像域内分别将样本按 10° 和 30° 方位间隔分组, 在每一方位组内利用样本均值作为模板, 用最小距离分类法加以识别. 文献[6]没有作任何特征提取, 将样本分别按 10° 和 30° 方位间隔分组, 在每一个方位单元内利用 SVM 进行识别. KPCA+RLSC 是对应于公式(6)的监督学习方法, 对训练样本集进行学习、对测试集的样本进行识别. 由于不要求公式(10)的第 3 项, 其参数与 KPCA+LapRLSC 相比少了 $\frac{\gamma_l}{(l+u)^2}$ 和

近邻个数 n ; σ 的设置与 KPCA+LapRLSC 相同;对于 γ_A ,在 $\ln \gamma_A = \{-10:1:10\}$ 范围内进行实验,记录最好的结果及其所对应的参数,对应于 $10^\circ, 30^\circ, 90^\circ, 180^\circ$ 和 360° 方位间隔的分组实验中该参数分别为 $e^{-3}, e^{-6}, 1, e^{-3}$ 和 e^{-3} 。

从表 2 列出的识别结果可以看出,在各个方位间隔分组实验中,LapRLSC 的识别率比文献中的方法都要高。尽管在 10° 方位间隔分组时每组样本数过少,每类目标在每个方位单元内只有 6、7 个样本,但该方法此时识别率仍然较高,说明了该方法在小样本情况下的有效性。在按 $30^\circ, 90^\circ, 180^\circ$ 和 360° 等方位间隔分组时也都取得了较好的结果,说明尽管方位角的变化范围较大,目标图像的结构变化也较大,相似性变差,本文的方法仍然能够获得较高的识别率,进而说明该方法对方位具有较好的鲁棒性,降低了对目标方位信息估计的精度要求。同时,从表 2 中可以看到,在各方位间隔下,KPCA+LapRLSC 的识别率均高于 KPCA+RLSC 的识别率,从而验证了将测试集样本加入到训练集中作为无标识样本的 LapRLSC 方法能够有效提高目标识别率。

实验 2. 测试样本不作为无标识样本、有标识样本的数量对识别率的影响。

本实验分析在测试样本不参与训练的情况下,有标识样本的数目对识别率的影响。在 360° 方位范围内,从训练集的每类中随机取出相同数目的有标识样本,依次为 20~100 个,训练过程只包含训练集中的有标识和无标识样本,测试集不参与训练,做 10 次实验取平均。为方便理解,图 1 给出了数据处理的示意图(测试集样本不作为无标识样本)。

本实验的参数 n 和 σ^2 的设置与实验 1 相同,由于 γ_A 和 $\frac{\gamma_l}{(l+u)^2}$ 的选取与有标识和无标识样本的比例有关,为简单起见, γ_A 和 $\frac{\gamma_l}{(l+u)^2}$ 分别取经验值 0.005 和 0.045。实验结果如图 2 所示(测试集样本不作为无标识样本),其中, LapRLSC-U(transductive)表示训练集中无标识样本的识别错误率,LapRLSC-T(out-of-sample)表示测试集样本的识别错误率。随着训练集有标识样本数目的增加,识别错误率有所下降,说明增加有标识样本的个数会有利于提高识别率;但是,下降到一定程度时曲线有所浮动。原因是随着无标识样本和有标识样本的比例不同,正则化参数的组合也要有细微的调整。本实验中的 γ_A 和 $\frac{\gamma_l}{(l+u)^2}$ 取了固定值,这也说明正则化参数的选取与有标识和无标识样本的比例有关系。还可以看到,对无标识样本的错误率要低于对测试集的错误率,说明参与训练的无标识样本的识别率比不参与训练的测试集样本的识别率要高。需要指出的是,LapRLSC 对测试集样本的识别率能够达到 96%,表明它具有对新样本良好的判决性能,这得益于正则项 $\|f\|_k$ 和约束在流形上的 $\|f\|_l$ 具有不同的平滑测度,而其他基于图的半监督算法如文献[25],则必须用所有的样本(训练集和测试集)来建立图,然后用类似 Dijkstra 算法寻找邻接图上两点的最短距离等操作来判断测试集样本类别,不具备对新样本的判决能力,这也是半监督学习中 LapRLSC 方法的一个优势。




Fig.1 Illustration of data set in Experiment 2

图 1 实验 2 样本集示意图

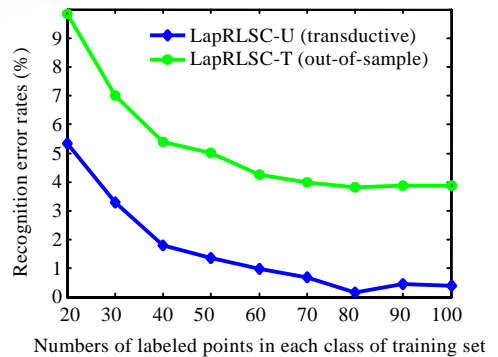


Fig.2 Error rates with different numbers of labeled points in Experiment 2

图 2 实验 2 中,随训练集中有标识样本数目变化的错误率

实验 3. 测试样本作为无标识样本、有标识样本的数量对识别率的影响。

本实验分析在测试集样本作为无标识样本参与训练的情况下,不同数量的有标识样本对识别率的影响.在 360°方位范围内,从训练集的每类中随机取出个数相同的样本,依次为 20~100 个,训练集剩余无标识样本和测试集样本全部作为无标识样本,做 10 次实验取平均.该实验中数据处理示意图如图 3 所示(测试集样本作为无标识数据).

实验中参数设置与实验 2 相同,实验结果如图 4 所示(测试集样本作为无标识数据).其中,LapRLSC-U(transductive)表示训练集中无标识样本的错误率,LapRLSC-T(transductive)表示将测试集样本作为无标识样本后得到的测试样本识别错误率.从图 4 中的结果可以看到,随着有标识样本数目的增加,LapRLSC-U(transductive)和 LapRLSC-T(transductive)的识别错误率都会有所下降,虽然下降到一定程度后趋于平稳,但可以说明,只要找到合适的正则化参数组合,较多的有标识样本得到的结果比使用较少的有标识样本的结果要好.此外,我们看到,图 4 中 LapRLSC-T(transductive)比图 2 中 LapRLSC-T(out-of-sample)的识别错误率要低,从而证实了将测试样本作为无标识样本参与训练可以获得更高的识别率.同时,图 4 中 LapRLSC-U(transductive)比图 2 中 LapRLSC-U(transductive)的识别错误率要低,这是因为实验 3 中测试样本参与了建立图和求图的 Laplacian,训练样本多,而实验 2 在这一过程中不包含测试集样本.




Fig.3 Illustration of data set in Experiment 3

图 3 实验 3 样本集示意图




Fig.4 Error rates with different numbers of labeled points in Experiment 3

图 4 实验 3 中,训练集中有标识样本数目变化的误差率

综合上述 3 个实验,在 KPCA 提取特征的基础上,用 LapRLSC 算法将全部训练集作为有标识样本、测试集作为无标识样本,具有识别率高的优势,并且对目标方位间隔具有较好的鲁棒性.由于在这个过程中需要对训练集和测试集样本建立图以及求图的 Laplacian,而 RLSC 不要求解这一步,所以时间复杂度比 RLSC 要高.但是在本文的实际应用中,由于目标成像数目有限,所以识别效率并不明显降低.

4 结 论

本文提出了一种基于 KPCA 和拉普拉斯正则化最小二乘的 SAR 图像半监督目标识别方法.基于 KPCA 特征提取方法不仅能够提取目标主要特征,而且有效地降低了特征维数.在此特征向量基础上,采用拉普拉斯正则化最小二乘进行 SAR 图像目标识别,将训练集样本全部作为有标识样本、将测试集样本作为无标识样本参与到学习过程中以获得更高的识别率.实验结果验证了该方法较模板匹配法、SVMs 以及正则化最小二乘监督学习方法具有更高的 SAR 图像目标识别正确率,并对目标角度间隔具有鲁棒性.此外,我们还对不同情况下有标识样本的个数对识别率的影响进行了实验分析.

References:

- [1] Zhang C, Li SD, Zou T, Wang ZZ. An automatic target recognition method in SAR imagery using peak feature matching. *Journal of Image and Graphics*, 2002,7(A):729–734 (in Chinese with English abstract).
- [2] Ross T, Worrell S, Velten V, Mossing J, Bryant M. Standard SAR ATR evaluation experiment using the MSTAR public release data set. In: Zelnio EG, ed. *Proc. of the Int'l Society for Optical Engineering (SPIE)*, Vol.3370. 1998. 556–573.
- [3] Kottke DP, Fiore PD, Brown KL, Fwu JK. A design for HMM-based SAR ATR. In: Zelnio EG, ed. *Proc. of the Int'l Society for Optical Engineering (SPIE)*, Vol.3370. 1998. 541–551.
- [4] Nilubol C, Pham QH, Mersereau RM, Smith MJT, Clements MA. Translational and rotational invariant hidden Markov model for automatic target recognition. In: *Proc. of the Int'l Society for Optical Engineering (SPIE)*, Vol.3374. 1998. 179–185. <http://spiedl.aip.org/getabs/servlet/GetabsServlet?prog=normal&id=PSISIDG003374000001000179000001&idtype=cvips&gifs=yes&ref=no>
- [5] Perlovsky LI, Schoendorf WH, Burdick BJ, Tye DM. Model-Based neural network for target detection in SAR images. *IEEE Trans. on Image Processing*, 1997,6(1):203–216. [doi: 10.1109/83.552107]
- [6] Zhao Q, Principe JC. Support vector machines for SAR automatic target recognition. *IEEE Trans. on Aerospace and Electronic Systems*, 2001,37(2):643–654. [doi: 10.1109/7.937475]
- [7] Zhao Q, Principe JC, Brennan V, Xu DX, Wang Z. Synthetic aperture radar automatic target recognition with three strategies of learning and representation. *Optical Engineering*, 2000,39(5):1230–1244. [doi: 10.1117/1.602495]
- [8] Han P, Wu RB, Wang ZH, Wang YH. SAR automatic target recognition based on KPCA criterion. *Journal of Electronics and Information Technology*, 2003,25(10):1297–1301 (in Chinese with English abstract).
- [9] Castelli V, Cover TM. The relative value of labeled and unlabeled samples in pattern recognition with an unknown mixing parameter. *IEEE Trans. on Information Theory*, 1996,42(6):2102–2117. [doi: 10.1109/18.556600]
- [10] Cozman FG, Cohen I, Cirelo MC. Semi-Supervised learning of mixture models. In: Fawcett T, Mishra N, eds. *Proc. of the 20th Int'l Conf. on Machine Learning (ICML)*. AAAI Press, 2003. 99–106.
- [11] Blum A, Mitchell T. Combining labeled and unlabeled data with co-training. In: *Proc. of the Conf. on Computational Learning Theory*. New York: ACM Press, 1998. 92–100. <http://portal.acm.org/citation.cfm?id=279962>
- [12] Chapelle O, Weston J, Schölkopf B. Cluster kernels for semi-supervised learning. *Advances in Neural Information Processing Systems*, 2003,15:585–592.
- [13] Smola A, Kondor R. Kernels and regularization on graphs. In: Schölkopf B, Warmuth MK, eds. *Proc. of the Conf. on Learning Theory and the 7th Kernel Workshop. LNCS 2777*, Springer-Verlag, 2003. 144–158.
- [14] Joachims T. Transductive learning via spectral graph partitioning. In: Fawcett T, Mishra N, eds. *Proc. of the Int'l Conf. on Machine Learning (ICML)*. AAAI Press, 2003. 290–297.
- [15] Poggio T, Smale S. The mathematics of learning: Dealing with data. *Notices of the American Mathematical Society*, 2003, 50(5):537–544.
- [16] Zhang P, Peng J. SVM vs. regularized least squares classification. In: Kittler J, Petrou M, Nixon MS, eds. *Proc. of the 17th Int'l Conf. on Pattern Recognition*, Vol.1. IEEE Computer Society Press, 2004. 176–179. <http://www.computer.org/portal/web/csdl/abs/proceedings/icpr/2004/2128/01/212810176abs.htm>
- [17] Schölkopf B, Smola A, Müller KR. Kernel principal component analysis. In: Schölkopf B, Burges CJC, Smola AJ, eds. *Advances in Kernel Methods: Support Vector Learning*. Cambridge: MIT Press, 1999. 327–352.
- [18] Rifkin RM, Yeo G, Poggio T. Regularized least squares classification. In: Suykens JAK, Horvath G, Basu S, Micchelli C, Vandewalle J, eds. *Advances in Learning Theory: Methods, Model and Applications*. NATO Science Series III: Computer and Systems Sciences. Amsterdam: DS Press, 2003. 131–153.
- [19] Schölkopf B, Herbrich R, Smola AJ. A generalized representer theorem. In: Helmbold DP, Williamson B, eds. *Proc. of the Conf. on Computational Learning Theory*. LNCS 2111, Springer-Verlag, 2001. 416–426.
- [20] Zhou D, Bousquet O, Lal TN, Weston J, Schölkopf B. Learning with local and global consistency. In: Thrun S, Saul L, Schölkopf B, eds. *Advances in Neural Information Processing Systems*. Cambridge: MIT Press, 2004. 321–328.
- [21] Luo SW, Zhao LW. Manifold learning algorithms based on spectral graph theory. *Journal of Computer Research and Development*, 2006,43(7):1173–1179 (in Chinese with English abstract).

- [22] Belkin M, Niyogi P. Toward a theoretical foundation for Laplacian-based manifold methods. In: Auer P, Meir R, eds. Proc. of the Computational Learning Theory. LNCS 3559, Springer-Verlag, 2005. 486–500.
- [23] Belkin M, Niyogi P, Sindhvani V. Manifold regularization: A geometric framework for learning from labeled and unlabeled examples. Journal of Machine Learning Research, 2006,7:2399–2434.
- [24] Yang HH, Wang XY, Wang Y, Gao HH. AlignLoo model selection approach for regularized least-squares classification. Control and Decision, 2006,21(1):7–12 (in Chinese with English abstract).
- [25] Chapelle O, Zien A. Semi-Supervised classification by low density separation. In: Proc. of the 10th Int'l Workshop on Artificial Intelligence and Statistics. 2005. 57–64. <http://eprints.pascal-network.org/archive/00000388/01/pdf2899.pdf>

附中文参考文献:


- [1] 张翠, 酆苏丹, 邹涛, 王正志. 一种应用峰值特征匹配的 SAR 图像自动目标识别方法. 中国图形图像学报, 2002, 7(A): 729–734.
- [8] 韩萍, 吴仁彪, 王兆华, 王蕴红. 基于 KPCA 准则的 SAR 目标特征提取与识别. 电子与信息学报, 2003, 25(10): 1297–1301.
- [21] 罗四维, 赵连伟. 基于谱图理论的流形学习算法. 计算机研究与发展, 2006, 43(7): 1173–1179.
- [24] 杨辉华, 王行愚, 王勇, 高海华. 正则化最小二乘分类的 AlignLoo 模型选择方法. 控制与决策, 2006, 21(1): 7–12.



张向荣(1978—), 女, 陕西宝鸡人, 博士, 副教授, CCF 高级会员, 主要研究领域为 SAR 图像处理与理解, 机器学习, 模式识别.



焦李成(1959—), 男, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为图像处理与理解, 机器学习, 智能计算.



阳春(1983—), 女, 硕士, 主要研究领域为 SAR 图像目标识别, 半监督学习.