

基于多特征融合词包模型的SAR目标鉴别算法

宋文青 王英华* 时荔蕙 刘宏伟 保铮
(西安电子科技大学雷达信号处理国家重点实验室 西安 710071)
(西安电子科技大学信息感知技术协同创新中心 西安 710071)

摘要: 针对复杂场景中的SAR目标鉴别问题,该文提出一种基于多特征融合词包(Bag-of-Words, BoW)模型的SAR目标鉴别算法。在BoW模型底层特征提取阶段,算法采用SAR-SIFT特征描述局部区域的形状信息;同时,采用该文基于传统鉴别特征提出的一组新的SAR图像局部特征描述局部区域的对比度信息和纹理信息。对于BoW模型中多个底层特征的融合,算法采用图像层的特征融合方式生成图像的全局鉴别特征,其中各单底层特征BoW模型特征的权系数通过L2范数约束的多核学习方法训练得到。在MiniSAR实测SAR图像数据上的目标鉴别实验表明,与基于传统鉴别特征以及单底层特征BoW模型特征的鉴别算法相比较,该文基于多特征融合BoW模型SAR目标鉴别算法具有更好的鉴别性能。

关键词: SAR; 目标鉴别; 词包模型; 底层特征; 多核学习

中图分类号: TN958

文献标识码: A

文章编号: 1009-5896(2017)11-2705-11

DOI: 10.11999/JEIT170086

SAR Target Discrimination Algorithm Based on Bag-of-words Model with Multi-feature Fusion

SONG Wenqing WANG Yinghua SHI Lihui LIU Hongwei BAO Zheng
(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

(Collaborative Innovation Center of Information Sensing and Understanding at Xidian University, Xi'an 710071, China)

Abstract: In order to solve the SAR target discrimination problem in the real complex scenes, a SAR target discrimination method is proposed based on Bag-of-Words (BoW) model with multiple low-level features fusion. In the low-level feature extraction stage of BoW model, the SAR-SIFT feature is utilized to describe the shape information of local regions of an image sample. And also, a set of new local descriptors is used to capture the contrast information and the texture information of the local regions, which is extracted based on the traditional target discrimination features. For the fusion of different low-level features in BoW model, the image-level feature fusion strategy is implemented to generate the image global feature, which is realized by the Multiple Kernel Learning (MKL) method with L2-norm regularization. Experimental results with the MiniSAR real SAR dataset show that the proposed SAR target discrimination algorithm based on BoW model with multi-feature fusion achieves better discrimination performance compared with methods based on the traditional discrimination features and the BoW model features using single low-level descriptor.

Key words: SAR; Target discrimination; Bag-of-Words (BoW) model; Low-level descriptor; Multiple Kernel Learning (MKL)

1 引言

随着SAR成像技术的不断发展,目前其已成为

对地观测不可或缺的遥感平台之一。SAR图像自动目标识别(Automatic Target Recognition, ATR),特别是车辆目标识别,是SAR图像的重要应用之一,越来越受到研究人员的关注。典型的SAR ATR系统包括目标检测、目标鉴别和目标分类3个阶段^[1]。在检测阶段,检测器快速地标记出图像场景中的疑似目标区域,其中疑似目标区域一般包括车辆目标、自然杂波和人造杂波。在鉴别阶段,鉴别器通过对疑似目标区域进行特征分析从而剔除其中的自然杂波和人造杂波。在分类阶段,分类器对通过

收稿日期: 2017-01-23; 改回日期: 2017-08-25; 网络出版: 2017-09-13

*通信作者: 王英华 yhwang@xidian.edu.cn

基金项目: 国家自然科学基金(61671354, 61701379), 国家杰出青年科学基金(61525105), 中央高校基本科研业务费专项资金, 陕西省自然科学基金基础研究计划(2016JQ6048)

Foundation Items: The National Natural Science Foundation of China (61671354, 61701379), The National Science Fund for Distinguished Young Scholars of China (61525105), The Fundamental Research Funds for the Central Universities, The Natural Science Basic Research Plan in Shaanxi Province of China (2016JQ6048)

鉴别器的感兴趣目标进行类别分类。在 SAR ATR 三级处理流程中,目标鉴别处于中间环节,具有承前启后的作用,是一个重要的处理步骤,因此对于目标鉴别算法的研究也是一个重要的研究方向。在 SAR 图像目标鉴别处理中,疑似目标切片图像的鉴别特征提取是其首要环节。在美国国防部先进研究项目局 (Defense Advanced Research Projects Agency, DARPA) 资助下,首批 SAR 目标鉴别特征由林肯实验室 (Lincoln Laboratory, LL) 和密西根环境研究所 (Environmental Research Institute of Michigan, ERIM) 等多家单位提出。这些特征大致可以分为 4 种类型:纹理特征、尺寸特征、对比度特征和极化特征^[1]。之后,林肯实验室的 Verbout 等人^[2]根据目标散射点在空间上的散布特性又提出一组空间边界属性特征。以上鉴别特征形成了 SAR 目标鉴别领域的传统特征集合。近来,新的鉴别特征不断被提出^[3-6],但是 LL 和 ERIM 提出的传统鉴别特征依然是目前应用较为广泛的鉴别特征^[7]。

传统鉴别特征一般假定提取的疑似目标切片区域为均匀场景中心分布着一个单一的感兴趣目标,然后在切片内的目标最小外接矩形内或者目标分割区域内提取各个属性特征。然而对于多目标和杂波边界等复杂背景下的目标切片区域,切片内单个目标的最小外接矩形和目标分割的估计精度很难达到特征提取的要求^[3],从而大大影响传统特征的鉴别性能,尤其是对尺寸类型特征的影响较为严重。空间边界属性特征不需要目标分割预处理^[2],但该特征是基于单目标场景提出的,并不能有效地描述多目标场景中目标散射点在空间上的散布特性。此外,传统鉴别特征对于区分车辆目标和人造建筑杂波的能力较差。

随着 SAR 图像分辨率的不断提高,目标的局部结构在图像上变的越来越清晰。考虑到目标和杂波的局部结构之间存在的差异特性,文献[8]提出采用 BoW (Bag-of-Words) 模型算法解决复杂场景中的 SAR 目标鉴别问题,并取得了良好的鉴别性能。BoW 模型最早出现在文本分类领域,于 2004 年由 Csurka 等人^[9]首次引入到计算机视觉领域。并由此开始,在光学图像场景分类和目标检测领域得到了广泛的研究^[10-13]。最近,BoW Bag-of-Word 模型算法开始逐渐应用到 SAR 图像处理领域^[8,14-17]。对于一个图像样本,BoW 模型利用图像中局部区域特征集合表征其包含的内容信息。典型的 BoW 模型图像分类算法可以分为 5 个部分^[18]:底层特征提取、视觉字典生成、底层特征编码、特征空间合并和分类器训练。在文献[8]中,针对 BoW 模型中的视觉

字典生成问题展开了研究,提出一种样本重加权类别特定与共享字典学习 (Sample-Reweighted Category-specific and Shared Dictionary Learning, SR-CSDL) 的视觉字典生成方法。本文将针对 BoW 模型算法中的底层特征提取问题进行展开讨论。

BoW 模型算法中,底层特征提取是算法的核心部分之一。经典的局部描述子尺度不变特征变换 (Scale Invariant Feature Transform, SIFT) 特征^[19]能够描述局部区域的边缘方向信息,具有特征描述独特性,同时对旋转、尺度、平移及光照变化具有一定的不变性。因此,SIFT 特征常被用于光学图像 BoW 模型中的底层特征提取阶段^[10,13]。在 SAR 图像处理领域,文献[8]中 BoW 模型的底层特征采用了一种 SAR-SIFT 特征^[20],其中 SAR-SIFT 特征是基于比值梯度 (Gradient by Ratio, GR)^[20]方法的改进 SIFT 特征。相比于原始 SIFT 特征,SAR-SIFT 特征能够更好地抑制 SAR 图像中相干斑噪声,对 SAR 图像局部区域的特征表征能力更为稳健。然而,与 SIFT 特征相同,SAR-SIFT 特征主要描述了局部区域的形状信息^[21],而对于其他鉴别性信息描述能力不足,如局部区域的对比度信息和纹理信息等。因此,针对 BoW 模型中的底层特征提取问题,本文基于传统 SAR 目标鉴别特征提出一组新的 SAR 图像局部描述子,旨在局部区域中提取更为丰富的鉴别性信息,以应用于 BoW 模型底层特征提取阶段。在 BoW 模型中,多底层特征的融合一般具有两种方式:区域层的特征融合和图像层的特征融合^[21,22]。区域层的特征融合为直接对不同底层特征进行拼接组成融合后的局部区域描述特征;图像层的特征融合为对不同底层特征生成的 BoW 模型特征进行融合形成最终的图像全局描述特征。对于区域层的特征融合方式,各个特征的权值系数很难获取,特别是当底层特征中融合了区分性能较差的特征时,就会严重影响算法的鉴别性能^[21]。图像层的特征与分类器直接相连,其各个底层特征对应的 BoW 模型特征的权值可以与分类器共同训练得到^[21]。而且,当 BoW 模型分类器采用直方图交叉核 SVM 时^[23],图像层的特征融合问题可以通过多核学习 (Multiple Kernel Learning, MKL) 方法^[24]解决。

综上所述,针对复杂场景中的 SAR 目标鉴别问题,本文提出一种基于多特征融合 BoW 模型 SAR 目标鉴别算法。在底层特征提取阶段,采用 SAR-SIFT 特征和本文基于传统鉴别特征提出的一组新的局部特征用于 SAR 图像局部区域特征描述。对于不同底层特征的融合,算法采用图像层的特征融合方式,特征的权值系数利用 MKL 方法学习获得。

通过实测 SAR 图像数据的目标鉴别实验表明, 本文基于多特征融合 BoW 模型 SAR 目标鉴别算法具有良好的鉴别性能。

2 BoW 模型

在本节中, 首先依据文献[18]对 BoW 模型图像分类算法进行简要介绍。BoW 模型利用图像中局部区域特征集合来表征其包含的内容信息。其处理流程主要由以下 5 个步骤组成。

(1)底层特征提取: 图像底层特征提取包括特征点采样和特征点周围局部区域特征提取两个步骤。特征点采样有随机采样、关键点采样和均匀密集采样 3 种方式^[18,25]。相比于随机采样方式和关键点采样方式, 均匀密集采样方式能够保留图像中更为丰富的内容信息, 常用于图像分类任务^[18,25]。密集采样方式是指在图像中按照固定尺度和固定步长滑动截取图像中的局部区域块, 其中每个局部区域的中心对应密集采样特征点。本文实验中, 图像局部区域大小设为 24×24 , 步长设为 4。局部区域提取之后, 接下来就是对局部区域进行特征描述。通过底层特征提取后, 每个图像样本可以表示成一组底层特征集合。

(2)视觉字典生成: 视觉字典由视觉单词组成, 通过训练集中底层特征集合学习得到。常用的视觉字典生成方法有 K-means 聚类方法^[9]和稀疏编码方法^[10]等, 其中 K-means 聚类中每个类中心和稀疏编码中每个字典元素对应一个视觉单词。

(3)底层特征编码: 底层特征编码为根据步骤(2)中生成的视觉字典对图像中每个底层特征进行矢量量化的过程。特征编码有硬矢量量化方法和软矢量量化方法^[18]。在硬矢量量化方法中, 每个底层特征仅用字典中与其最近的一个视觉单词来表示。而在软矢量量化方法中, 每个底层特征由若干个视觉单词的线性组合来表示, 以解决特征表示中存在的模糊性问题^[13]。为了方便本文对底层特征提取问题的分析, 本文 BoW 模型统一采用了 K-means 算法生成视觉字典, 同时采用硬矢量量化方法对底层特征进行编码。

(4)特征空间合并: 特征空间合并是指由编码后图像的底层特征集合生成图像全局特征的过程, 有平均合并和最大合并两种方法^[10]。鉴于步骤(3)中选择的特征编码方式, 本文算法采用平均合并方法生成图像 BoW 模型直方图特征, 特征的每一维对应视觉单词在图像中出现的频率。

(5)分类器训练: 在算法的最后, 根据训练集中的 BoW 模型特征集合训练一个有效的图像分类器。

BoW 模型直方图特征通常采用直方图交叉核支持向量机(Support Vector Machine, SVM)分类器^[23], 其中直方图交叉核函数可以表示为

$$K(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^D \min(x_i, y_i) \quad (1)$$


式中, 向量 \mathbf{x} 和 \mathbf{y} 分别表示两个图像样本的 D 维 BoW 模型特征, $\mathbf{x} = [x_1, x_2, \dots, x_D]^T \in R^D$, $\mathbf{y} = [y_1, y_2, \dots, y_D]^T \in R^D$, D 对应视觉字典中视觉单词个数。

3 SAR 图像局部区域描述子


对于第 2 节中介绍的 BoW 模型算法, 图像底层特征提取是算法的核心部分之一, 局部区域的信息表征直接关系到图像整体信息的表达。同时, 底层特征提取也是将 BoW 模型应用到 SAR 目标鉴别领域的首要问题。本文算法首先采用 SAR-SIFT 描述子用于描述局部区域形状特征, 并在 3.1 节中对原始 SIFT 特征及 SAR-SIFT 特征提取过程进行简单介绍。同时, 在 SAR-SIFT 特征提取框架基础上, 通过改进传统 SAR 目标鉴别特征, 在 3.2 节中提出一组新的 SAR 图像局部区域描述子用于描述局部区域对比度特征和纹理特征, 以提高局部区域的特征描述能力。

3.1 SIFT 及 SAR-SIFT 特征

SIFT 特征^[19]描述了局部区域内像素梯度方向的统计直方图信息。其特征提取的过程为: 首先按照一定规则将局部区域在空间上划分成若干个单元格(笛卡尔坐标系下的单元格划分和对数极坐标系下的单元格划分^[26], 如图 1 所示); 然后在各个单元格内统计像素梯度幅度加权的梯度方向直方图特征; 最后将各个单元格的直方图特征串接起来组成最终的局部区域 SIFT 特征。SIFT 特征可以看成是在局部区域内关于像素空间位置和梯度方向的 3 维统计直方图特征^[19,26], 其中包括空间 2 维和角度 1 维。为了抑制由空间和角度的区间量化引起的边界效应对特征的影响, 一般需要对 3 维直方图特征进行三线性插值^[19]处理, 即将每个像素对直方图的贡献分配到若干个直方图区间内。SIFT 特征的计算可以表示为



(a)笛卡尔坐标系单元格划分



(b)对数极坐标单元格划分

图 1 局部区域空间单元划分示例

$$\begin{aligned}
 F_{\text{SIFT}}(m, n, p) &= \sum_{(x, y) \in R} W(x, y, m, n, p) G^R(x, y) \\
 &= \sum_{(x, y) \in R} W_{s1}(x, y, m) W_{s2}(x, y, n) \\
 &\quad \cdot W_{\theta}(x, y, p) G^R(x, y) \quad (2)
 \end{aligned}$$

式中, $m \in [1, M], n \in [1, N], p \in [1, P], M, N$ 和 P 分别对应 3 维直方图中的空间‘垂直’维、空间‘水平’维¹⁾和梯度角度维的区间量化数目, R 为局部区域范围, $G^R(x, y)$ 为 R 内像素 (x, y) 的梯度幅度, $W(x, y, m, n, p)$ 为像素 (x, y) 对应的三线性插值因子, 表示像素 (x, y) 在 3 维直方图 F_{SIFT} 的区间 (m, n, p) 内的单位梯度幅度贡献系数。 $W(x, y, m, n, p)$ 由 $W_{\theta}(x, y, p)$, $W_{s1}(x, y, m)$ 和 $W_{s2}(x, y, n)$ 3 部分组成²⁾。其中, $W_{\theta}(x, y, p)$ 为梯度角度维插值系数分量, 与像素 (x, y) 的梯度方向角 $\theta^R(x, y)$ 到直方图角度区间 p 的中心角度 θ_p 的角度距离相关; $W_{s1}(x, y, m)$ 和 $W_{s2}(x, y, n)$ 分别为空间垂直维和水平维的插值系数分量, 分别与像素 (x, y) 到直方图的空间区间 (m, n) 中心的水平方向和垂直方向距离相关。在本文实验中, 图像局部区域单元格划分采用图 1(b)所示对数极坐标单元格划分形式^[20,26], 每个局部区域划分成 5 个单元格, 其中半径量化为 2 个区间, 极坐标角度量化为 4 个区间, 且在中心单元内不再进行角度划分。在原始 SIFT 特征提取中, 为了保证特征具有一定的旋转不变特性, 在计算式(2)之前, 首先对局部区域 R 内像素的空间坐标和梯度角度进行主方向对齐处理^[19,20]。同时, 为了保证特征具有一定的光照不变特性, 最后对特征进行归一化处理^[19]。

SAR-SIFT 特征与 SIFT 特征具有相同的特征提取过程^[20]。区别于 SIFT 特征, SAR-SIFT 特征基于 GR 方法计算像素的梯度幅度和梯度方向, 其水平梯度和垂直梯度采用指数加权均值比(Ratio Of Exponential Weighted Averages, ROEWA)算子^[27]计算, 从而能够抑制相干斑乘性噪声对特征的影响^[20]。文献[20]中给出了其梯度幅度和梯度方向的具体计算公式。本文 BoW 模型底层特征中首先采用了 SAR-SIFT 特征, 用于描述 SAR 图像局部区域的形状特征。在本文具体应用中, 与文献[20]有两点不同:

(1)由于本文 BoW 模型中采用了均匀密集采样方式提取图像中的局部区域, 局部区域具有相同的

尺度大小, 因此在 SAR-SIFT 特征提取过程中不再对特征点进行尺度估计。

(2)对于 SAR-SIFT 特征, 由比值梯度算子计算得到像素梯度幅度响应具有一定的鉴别信息, 因此, 最后不再对 SAR-SIFT 特征进行归一化处理。

3.2 新的 SAR 图像局部描述子

SAR-SIFT 特征能够描述局部区域的边缘方向分布特征, 而对于对比度特征和纹理特征等鉴别信息描述能力不足。考虑到对比特征和纹理特征是传统目标鉴别特征中常用的属性特征, 因此在本节中基于部分传统的鉴别特征提出一组新的 SAR 图像局部区域描述子, 用于对比度特征和纹理特征描述。这组部分传统鉴别特征包括恒虚警率(Constant False Alarm Rate, CFAR)响应特征^[1]、标准差(Standard Deviation, SD)特征^[1]、加权排列能量比(Weighted Rank Fill Ratio, WRFR)特征^[1]和可变指数(Variability Index, VI)特征^[28]。

新的 SAR 图像局部特征和 SAR-SIFT 特征具有相同的提取过程: 首先将局部区域在空间上划分成若干个单元格; 然后在各空间单元内统计描述特征; 最后将各个单元的描述特征拼接起来形成最终的局部区域描述子。同样, 为了使新的局部特征具有旋转不变性, 在计算各个局部特征之前, 需要对局部区域内像素坐标进行主方向对齐处理, 其中主方向对齐处理与 SAR-SIFT 特征计算相同。因此, 新的 SAR 图像局部特征同样具有特征描述的独特性以及一定的空间旋转、平移不变性。

在给出各新特征的具体计算方式之前, 我们首先对式(2)SIFT 特征的计算过程进行重新分析, 式(2)可以整合成以下形式:

$$\begin{aligned}
 F_{\text{SIFT}}(m, n, p) &= \sum_{(x, y) \in R} \left\{ [W_s(x, y, m, n)] \right. \\
 &\quad \left. \cdot [W_{\theta}(x, y, p) G^R(x, y)] \right\} \quad (3)
 \end{aligned}$$

其中, $W_s(x, y, m, n) = W_{s1}(x, y, m) W_{s2}(x, y, n)$ 。由式(3)可以看出, SIFT 特征计算过程可以分成局部区域内像素特征提取($W_{\theta}(\cdot, \cdot, p) G^R(\cdot, \cdot)$)和像素特征空间加权($W_s(\cdot, \cdot, m, n)$)合并($\sum \{\cdot\}$)两个步骤。新的 SAR 图像局部特征的计算过程同样采用像素特征提取和特征空间合并两个步骤。同时, 在空间加权合并步骤中, 各个局部特征采用与 SIFT 特征相同的空间加权因子 $W_s(\cdot, \cdot, m, n)$, 即采用相同的空间单元格划分形式。这样以来, 各个局部特征提取的唯一不同就是像素特征生成过程。

SAR 图像局部描述子可以分成两种类型, 局部对比度特征和局部纹理特征:

(1)SAR 图像局部对比度特征: 在传统鉴别特

¹⁾“垂直”维和“水平”维泛指笛卡尔坐标系或者对数极坐标系中的垂直维和水平维。

²⁾考虑到三线性插值可以一定程度上抑制区域边缘处像素对特征的影响, $W(x, y, m, n, p)$ 中忽略了原始 SIFT 特征计算中的空间高斯加权项。

征中, CFAR 特征常用于描述图像中散射点与背景的对比度信息, 是 SAR ATR 领域重要的区分性特征^[1,3]。基于图像的 CFAR 响应特征图, 本文提出 3 个 SAR 图像局部区域对比度特征, 包括局部区域 CFAR 响应直方图特征 (Histogram of CFAR feature)、局部区域最大 CFAR 响应特征 (Maximum CFAR feature) 和局部区域平均 CFAR 响应特征 (Mean CFAR feature), 分别记为 LHistCFAR 特征、LMaxCFAR 特征和 LMeanCFAR 特征。

在计算各个局部对比度特征之前, 首先需要得到图像的 CFAR 响应特征图。与传统的 CFAR 特征计算不同^[29], 此处的 CFAR 特征图可以看作是 SAR 图像的一种正则化图像, 以消除绝对幅度对局部特征的影响。考虑到多目标和杂波边界等图像样本的存在, 首先采用有序统计量 CFAR (Order Statistics CFAR, OS-CFAR) 算法^[29] 求出图像初步的 CFAR 特征图; 同时, 为了增强图像 CFAR 响应的幅值一致性, 接着对初步的 CFAR 特征图进行 Sigmoid 函数压缩变换, 从而得到图像 I 最终的 CFAR 响应特征图。其计算过程可以表示为

$$I_{\text{CFAR}} = \sigma(I/I_{\text{opt}}, a) \quad (4)$$

其中, $\sigma(x, x_0) = 1/(1 + e^{-(x-x_0)})$ 为 Sigmoid 函数, I_{opt} 为 OS-CFAR 算法中的分位数, a 是与虚警概率有关的常数因子。本文实验中, I_{opt} 设为图像中值, a 设为 3。

SAR 局部区域对比度特征在式(4)CFAR 响应特征图上计算得到, 其中, LHistCFAR 特征为局部区域内像素 CFAR 响应的统计直方图, 其直方图各灰度中心由训练样本中像素的最大、最小 CFAR 响应和直方图区间个数确定; LMaxCFAR 特征和 LMeanCFAR 特征分别为局部区域内像素最大和平均 CFAR 响应特征。根据 SAR-SIFT 特征计算公式(3), 其各个局部对比度特征的计算可以表示为

$$\left. \begin{aligned} F_{\text{LHistCFAR}}(m, n, q) &= \sum_{(x,y) \in R} W_s(x, y, m, n) W_{\text{CFAR}}^R(x, y, q) \\ F_{\text{LMaxCFAR}}(m, n) &= \max_{(x,y) \in R} (W_s(x, y, m, n) I_{\text{CFAR}}^R(x, y)) \\ F_{\text{LMeanCFAR}}(m, n) &= \sum_{(x,y) \in R} W_s(x, y, m, n) I_{\text{CFAR}}^R(x, y) \end{aligned} \right\} \quad (5)$$

式中, $q \in [1, Q]$, Q 表示单元格内 CFAR 响应直方图区间个数(实验中, Q 设为 4); I_{CFAR}^R 表示 I_{CFAR} 的局部区域 R 对应的特征图; $W_{\text{CFAR}}^R(x, y, q)$ 为局部区域 R 内像素 (x, y) 在 CFAR 直方图区间 q 上的贡献大小, 与 (x, y) 的 CFAR 响应和直方图区间 q 的中心

值有关。由式(5)也可以看出, 与 LHistCFAR 特征和 LMeanCFAR 特征计算不同, LMaxCFAR 特征的特征空间加权合并采用了最大合并策略。

(2)SAR 图像局部纹理特征: SAR 图像局部纹理特征基于传统鉴别特征中的纹理特征提出, 包括局部区域 SD 特征、局部区域 WRFR 特征和局部区域 VI 特征, 分别记为 LSD 特征、LWRFR 特征和 LVI 特征。LSD 特征和 LVI 特征分别是 SAR 图像局部区域在对数域和幅度域的纹理统计特征, 描述局部区域内像素幅值的波动情况; LWRFR 特征是局部区域内强散射点能量之和与总能量间的比值特征。依照文献[1]中 SD 特征和 WRFR 特征的定义、文献[28]VI 特征的定义及式(3), LSD 特征、LWRFR 特征和 LVI 特征的计算公式分别可以表示成式(6)³⁾、式(7)和式(8)形式。

$$F_{\text{LSD}}(m, n) = \left\{ \sum_{(x,y) \in R} W_s(x, y, m, n) I_{\log}^R(x, y)^2 - \left(\sum_{(x,y) \in R} W_s(x, y, m, n) I_{\log}^R(x, y) \right)^2 \right\}^{1/2} \quad (6)$$

$$F_{\text{LWRFR}}(m, n) = \left(\sum_{(x,y) \in R'} W_s(x, y, m, n) I^R(x, y) \right) / \left(\sum_{(x,y) \in R} W_s(x, y, m, n) I^R(x, y) \right) \quad (7)$$

$$F_{\text{LVI}}(m, n) = \sqrt{\sum_{(x,y) \in R} W_s(x, y, m, n) I^R(x, y)^2} / \left(\sum_{(x,y) \in R} W_s(x, y, m, n) I^R(x, y) \right) \quad (8)$$

其中, 式(6)中 I_{\log}^R 为图像 I 的局部区域 R 对应的对数特征图; 式(7)和式(8)中 I^R 表示图像 I 的局部区域 R 对应的图像; 式(7) R' 为 R 的子集, 对应经 $W_s(\cdot, \cdot, m, n)$ 空间加权后的 I^R 的前 20% 非零强像素点。与 SAR 图像局部对比度特征计算不同, 局部纹理特征可以看成两个局部特征的非线性组合特征, 以消除图像绝对幅度对局部特征的影响。

4 特征融合

如引言中分析, 对于 BoW 模型中的多底层特征融合问题, 特征融合常采用图像层的特征融合方式^[21]。当 BoW 模型采用 M 个底层特征时, 每个图像可以生成 M 个 BoW 模型直方图特征 $\{h_1, h_2, \dots,$

³⁾在式(6)中, $W_s(x, y, m, n)$ 进行了 L1 范数归一化处理, $F_{\text{LSD}}(m, n)$ 特征可以看作是局部区域 R 的 (m, n) 单元格内像素的在对数域的加权统计方差。

$\mathbf{h}_M\}$ 。假设各 BoW 模型特征的权系数为 $\{d_1, d_2, \dots, d_M\}$, 则多特征融合 BoW 模型特征可以表示为 $\mathbf{H} = [d_1\mathbf{h}_1; d_2\mathbf{h}_2; \dots; d_M\mathbf{h}_M]$ 。根据式(1)中给出的 SVM 分类器的核函数形式, 两个图像样本特征 \mathbf{H}_1 和 \mathbf{H}_2 在核空间的内积形式可以表示为

$$\mathbf{K}(\mathbf{H}_1, \mathbf{H}_2) = \sum_{m=1}^M d_m K_m(\mathbf{h}_{m,1}, \mathbf{h}_{m,2}) \quad (9)$$

其中, $\mathbf{h}_{m,1}$ 和 $\mathbf{h}_{m,2}$ 分别对应两个图像样本由第 m 个底层特征生成的 BoW 模型特征; $\mathbf{K}(\cdot, \cdot)$ 和 $K_m(\cdot, \cdot)$ 分别为特征 \mathbf{H} 和特征 \mathbf{h}_m 对应的核函数, 其都具有式(1)形式。可以看出, 两个样本的融合特征在核空间的内积可以表示为单底层特征 BoW 模型特征在核空间的内积的线性组合。因此, 特征的权系数 $\{d_1, d_2, \dots, d_M\}$ 和 SVM 分类器共同学习的问题可以看作是一个多核学习问题^[21]。常用的多核学习方法有 SimpleMKL 算法和 GMKL 算法等^[24], 其中 SimpleMKL 算法和 GMKL 算法都是基于 SVM 分类器的多核学习方法。文献[24]指出, 当融合特征数量较少时, 由权系数 ℓ_2 范数约束的多核学习方法求得的图像融合特征具有更优的分类性能。因此, 本文采用约束更为灵活的 GMKL 算法解决多特征融合问题, 其中权系数采用 ℓ_2 范数约束。

5 实验结果和分析

为了验证本文算法的目标鉴别性能, 本文选取了 miniSAR 数据库^[30]中 4 幅包含有车辆目标的地面场景高分辨 SAR 图像, 图像分辨率为 $0.1 \text{ m} \times 0.1 \text{ m}$, 如图 2 所示。图 2 SAR 图像提供了本文验证实验采用的目标样本和杂波样本数据集, 其切片样本提取过程可以分为以下 3 个步骤^[8]: 首先利用双参数 CFAR 检测算法对图 2 所示的 4 幅 SAR 图像进行目标检测, 同时利用文献[31]中的超像素分割

方法对图像进行超像素分割; 当超像素内包含疑似目标像素时, 则该超像素被标记疑似目标超像素。然后从图像中以每个疑似目标超像素为中心提取疑似目标切片; 最后根据人工标记图对疑似目标切片进行类别标注。其中, 目标切片大小根据实测 SAR 图像的分辨率以及待鉴别车辆目标的尺寸设定的, 一般要求提取的切片图像中包含整个中心目标车辆结构和部分背景区域。本文实验采用的 miniSAR 高分辨 SAR 图像分辨率为 $0.1 \text{ m} \times 0.1 \text{ m}$, 车辆目标长度约为 $4 \sim 5 \text{ m}$ 左右, 因此我们将切片半窗窗长设为 45, 此时切片大小为 $(2 \times 45 + 1) \times (2 \times 45 + 1) = 91 \times 91$ 。表 1 中列出了从 4 幅图像中分别提取的目标切片样本个数和杂波切片样本个数。图 3 展示了数据集中不同类型的部分切片样本。

分析图 2 不同场景中车辆目标情况可以看出, 图像中存在大量多目标区域, 而仅有少量单目标区域。因此提取的目标样本集中包含大量的多目标切片样本, 而包含少量的单目标切片样本。分析图 2 不同场景中的杂波情况可以看出, SAR 图像 1 和图像 2 中存在大量的人造杂波, 而自然杂波较少; SAR 图像 3、图像 4 中自然杂波占主要部分, 而人造杂波较少。因此, 由 SAR 图像 1 和 SAR 图像 2 提取的杂波样本集中包含大量的人造杂波切片样本, 而由图像 3 和图像 4 提取的杂波样本集中自然杂波切片样本占主要部分。由此可以看出, 由图 2 复杂场景 SAR 图像中提取的数据集对于验证本文算法在不同场景中的目标鉴别性能是一个有效的数据集。

本文分别进行了两组对比实验验证本文基于多特征融合 BoW 模型目标鉴别算法的性能, 其中实验 1 为单底层特征 BoW 模型特征和多特征融合 BoW 模型特征的鉴别性能对比实验, 实验 2 为 BoW 模型特征和传统特征的鉴别性能对比实验。实验中,




图 2 4 幅包含有车辆目标的高分辨 SAR 图像

表 1 4 幅 SAR 图像中分别提取的目标切片和杂波切片样本个数

	SAR 图像 1	SAR 图像 2	SAR 图像 3	SAR 图像 4
目标样本个数	79	159	115	140
杂波样本个数	510	627	305	599




图 3 数据集中的切片样本示例

单底层特征 BoW 模型特征采用直方图交叉核 SVM 分类器；多特征融合 BoW 模型特征采用基于直方图交叉核 SVM 分类器的多核学习 GMKL 分类器；对比的传统鉴别特征采用高斯核 SVM 分类器。SVM 分类器中各个参数在训练阶段通过 5 折交叉验证获得。程序中，SVM 分类器使用 LIBSVM 工具箱⁴⁾；GMKL 分类器使用 SPG-GMKL 工具箱⁵⁾，其中 SPG-GMKL 工具箱中梯度求解和 SVM 分类环节选择 LIBSVM 工具箱求解。对于 BoW 模型特征，不同底层特征对应的视觉字典大小统一设为 128。

实验中为了保证训练样本和测试样本间的独立性，每组对比实验分别进行 4 次试验，其中每次试验选用图 2 中 1 幅图像提取的样本集作为测试集，另外 3 幅图像提取的样本集作为训练集。分析表 1 中各类型样本数量可以看出，目标样本和杂波样本间存在严重的数据非平衡性问题^[32]，例如，当 SAR 图像 2、图像 3 和图像 4 的样本作为训练集时，训练集中目标样本数量为 $159 + 115 + 140 = 414$ ，而杂波样本数量为 $627 + 305 + 599 = 1531$ 。本文实验中通过调整 SVM 分类器中两类样本错分惩罚因子间的比例来解决样本间的非平衡问题。假设目标类和杂波类样本错判惩罚因子分别为 C_t 和 C_c ，则其可以

表示为

$$\left. \begin{aligned} C_t &= N/2N_t \cdot C \\ C_c &= N/2N_c \cdot C \end{aligned} \right\} \quad (10)$$

其中， N_t 为训练集中目标样本个数， N_c 为杂波样本个数， N 为总样本个数， C 为惩罚因子系数。

实验最后采用 SAR 目标检测/鉴别领域中常用受试者工作特征 (Receiver Operating Characteristics, ROC) 曲线来评价算法的鉴别性能^[1-3,8]，其中 ROC 曲线的横坐标对应杂波虚警概率 p_f ，纵坐标对应目标检测概率 p_d 。同时，为了定量分析 ROC 性能曲线，实验中给出了不同特征对应的 ROC 曲线下面积 (Area Under the ROC Curve, AUC) 性能指标以及 ROC 曲线在检测率 $p_d = 0.9$ 时对应的虚警概率 p_f 性能指标。目标检测概率 p_d 和杂波虚警概率 p_f 计算如下：

$$p_d = N_{dt}/N_t, \quad p_f = N_{dc}/N_c \quad (11)$$

其中， N_{dt} 和 N_{dc} 分别为被判决为目标类的目标类样本个数和杂波类样本个数， N_t 和 N_c 分别为测试集中目标类样本个数和杂波类样本个数。

实验 1 单底层特征 VS 多特征融合

图 4 给出了各个单底层特征 BoW 模型特征及多特征融合 BoW 模型特征在不同测试集上的鉴别性能 ROC 曲线。其中，图 4(a)~4(d) 分别对应 SAR 图像 1~图像 4 提取的样本作为测试集时的实验结果；各个 ROC 曲线名称对应 BoW 模型所采用的底层特征，MultiF 对应多特征融合 BoW 模型特征。从图 4 实验结果可以看出，不同单底层特征 BoW 模型特征在各个测试集上具有不同的鉴别性能，而多特征融合 BoW 模型特征的鉴别性能 ROC 曲线都要优于各个单底层特征 BoW 模型特征。表 2 给出了图 4 中各个 ROC 曲线的 AUC 参数及在 $p_d = 0.90$ 时对应的杂波虚警概率 p_f 。从表 2 结果可以看出，与各单底层特征 BoW 模型特征相比较，多特征融合 BoW 模型特征在不同测试集上的鉴别性能 ROC 曲线都具有最大的 AUC 面积和最低的杂波虚警概率 p_f 。不同单底层特征 BoW 模型特征可以看作不同属性局部结构在图像中的分布信息，通过融合图像不同底层特征的 BoW 模型特征能够保留图像中更为完整、丰富的内容信息，进而可以提高特征鉴别性能。

实验 2 传统鉴别特征 VS BoW 模型特征

接下来本文将 BoW 模型特征与传统的目标鉴别特征进行对比。在对比特征中选取了目前应用较为广泛的传统目标鉴别特征，包括 LL 提出的纹理特征 (标准差特征、分形维数特征和加权排列填充比

⁴⁾ <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>

⁵⁾ <http://www.cs.cornell.edu/~ashesh/pubs/code/SPG-GMKL/download.html>

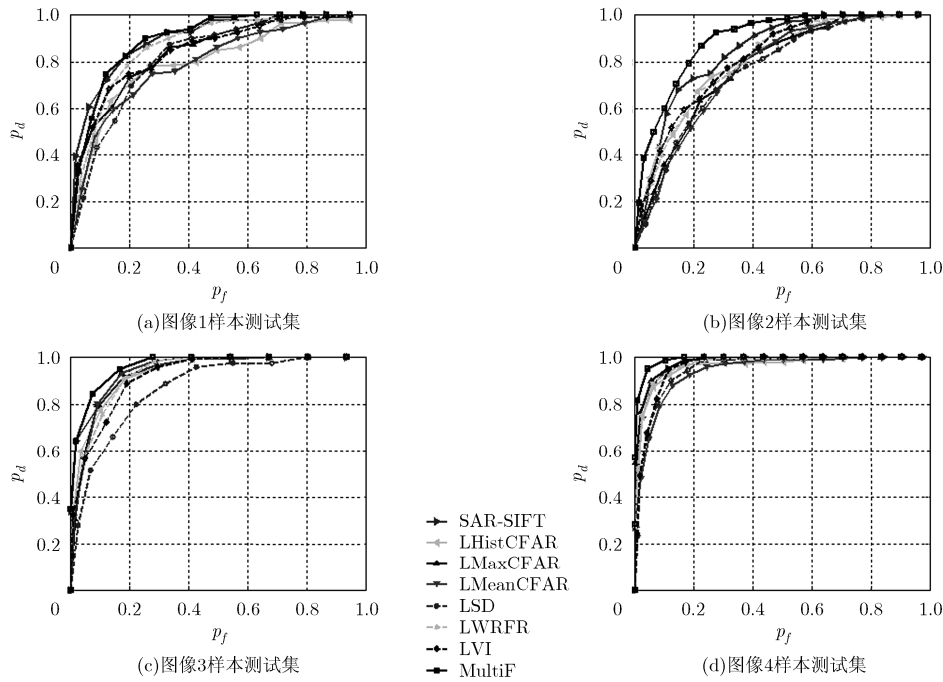


图 4 单底层特征及多特征融合 BoW 模型特征在不同测试集上的鉴别性能 ROC 曲线

表 2 图 4 实验中各个 ROC 曲线的 AUC 指标及在 $p_d = 0.90$ 时对应的 p_f

底层特征	SAR 图像 1		SAR 图像 2		SAR 图像 3		SAR 图像 4	
	AUC	p_f	AUC	p_f	AUC	p_f	AUC	p_f
SAR-SIFT	0.898	0.280	0.847	0.381	0.948	0.148	0.973	0.075
LHistCFAR	0.800	0.622	0.805	0.509	0.933	0.177	0.963	0.070
LMaxCFAR	0.848	0.433	0.779	0.528	0.941	0.144	0.977	0.043
LMeanCFAR	0.799	0.543	0.770	0.482	0.941	0.154	0.939	0.155
LSD	0.823	0.388	0.765	0.539	0.873	0.321	0.955	0.117
LWRFR	0.870	0.324	0.808	0.455	0.933	0.174	0.971	0.060
LVI	0.853	0.471	0.816	0.450	0.924	0.213	0.961	0.092
MultiF	0.901	0.241	0.893	0.258	0.966	0.102	0.993	0.022

特征), ERIM 提出的对比度特征(平均 CFAR 响应特征、最大 CFAR 响应特征和强点 CFAR 百分比特征)和文献[3]中使用的鉴别特征(目标空间边界属性特征和在边界属性特征基础上提出的对比度特征)。实验中将以上传统鉴别特征组合成了两个对比特征组:传统特征 F1 和传统特征 F2, 其中 F1 中包含了以上全部的传统鉴别特征, 而 F2 中不包含文献[3]中的鉴别特征。对比的 BoW 模型特征包括 BoW-subMultiF 和 BoW-MultiF, 其中 BoW-subMultiF 中融合的底层特征为本文基于部分传统特征 F2 内的特征的提出的局部特征(包括 LSD 特征、LWRFR 特征、LMaxCFAR 特征和 LMeanCFAR 特征), BoW-MultiF 中融合的底层特征为本文第 3 节全部 SAR 图像局部特征(和实验 1 的中

MultiF 相同)。图 5 中给出了两个传统鉴别组合特征和两个多特征融合 BoW 模型特征在四组测试集上的鉴别性能 ROC 曲线。表 3 给出了图 5 中各个 ROC 性能曲线的 AUC 指标及在 $p_d = 0.90$ 时对应的杂波虚警概率 p_f 。

从图 5 和表 3 的实验结果可以看出, 基于 BoW 模型提取的特征的鉴别性能要明显优于传统鉴别特征。不同于传统鉴别特征, BoW 模型特征提取算法利用图像中局部结构的分布信息来描述图像所包含的内容, 而且局部结构的特征提取受背景杂波影响较小, 从而能够大大提升复杂场景中的 SAR 目标鉴别性能。如引言中分析, 空间边界属性特征是基于单目标均匀背景提出的, 并不适合于多目标场景的特征表征。从实验结果也可以看出, 包含有空间边

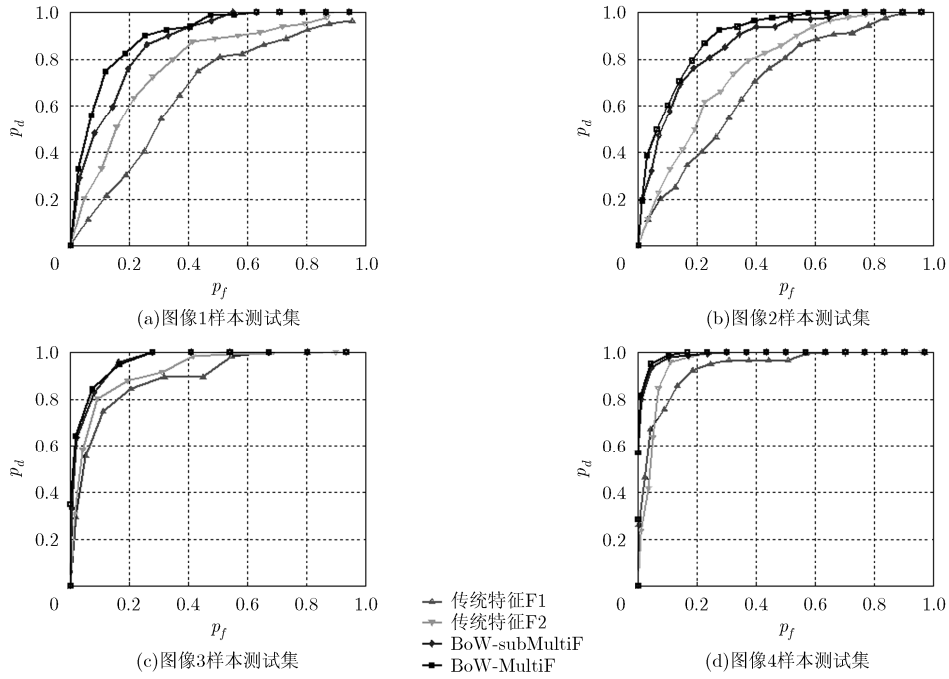


图 5 两个传统鉴别组合特征和两个多特征融合 BoW 模型特征的鉴别性能 ROC 曲线

表 3 图 5 实验中各个 ROC 曲线的 AUC 指标及在 $p_d = 0.90$ 时对应的 p_f

鉴别特征	SAR 图像 1		SAR 图像 2		SAR 图像 3		SAR 图像 4	
	AUC	p_f	AUC	p_f	AUC	p_f	AUC	p_f
传统特征 F1	0.663	0.753	0.693	0.628	0.896	0.239	0.935	0.145
传统特征 F2	0.773	0.547	0.763	0.537	0.924	0.200	0.956	0.078
BoW-subMultiF	0.867	0.290	0.866	0.352	0.960	0.115	0.988	0.030
BoW-MultiF	0.901	0.241	0.893	0.258	0.966	0.102	0.993	0.022

界属性特征的传统特征 F1 的鉴别性能明显低于不包含该特征的传统特征 F2。对于两个 BoW 模型特征，BoW-subMultiF 特征要略微差于 BoW-MultiF 特征。该实验结果可以从一定程度上说明本文基于传统鉴别特征提出的 SAR 图像局部描述子的有效性，同时也进一步说明了融合多种底层特征能够保留更多图像的鉴别信息，从而提升 BoW 模型特征的鉴别能力。

结合实验 1 和实验 2 的实验结果可以看出，相对于单底层特征 BoW 模型特征和传统鉴别特征，多特征融合 BoW 模型特征的鉴别性能在不同测试集上都有所提升，特别是在人造杂波样本占主要部分的 SAR 图像 2 样本集上目标鉴别性能提升更为明显，如图 4(b)和图 5(b)所示。而对于人造杂波居多的图像 1 测试集的实验结果图 4(a)，多特征融合 BoW 模型特征相对于单底层特征 BoW 模型特征性能提升不够明显，其可能原因是 SAR 图像 1 中的人造杂波在形状、纹理和对比度方面与车辆目标较为

相似。尽管如此，多特征融合 BoW 模型特征依然具有更优的鉴别性能。

表 4 中比较了在 Intel Core i7 4790 CPU @3.60 GHz 和 32G RAM 配置环境下本文实验中不同鉴别算法对单个样本的测试时间，包括特征提取时间和鉴别器鉴别时间。表 4 中，第 1 行为以传统特征 F1 为鉴别特征的传统鉴别算法，第 2 行为以 SAR-SIFT 特征为底层特征的 BoW 模型鉴别算法，最后一行为本文多特征融合的 BoW 模型鉴别算法。

从表 4 可以看出，相对于传统的鉴别算法，基于 BoW 模型的鉴别算法运算时间具有明显的提升。

表 4 不同鉴别算法的单个样本测试时间(s)

鉴别算法	运行时间
传统特征 F1	0.03
BoW-SARSIFT	0.44
BoW-MultiF	0.61

传统的 SAR 目标鉴别算法虽然计算简单、运算时间短,然而由实验 2 结果可以看出,随着 SAR 图像场景中的杂波越来越复杂,其鉴别性能越来越差,不再能够满足 SAR 目标鉴别要求。而相对于传统鉴别算法,基于 BoW 模型的 SAR 目标鉴别算法能够剔除更多类型的杂波虚警,从而能够大大减少 SAR ATR 流程中的目标识别环节处理时间。基于 SIFT 特征的 BoW 模型算法在光学场景图像分类中得到了广泛的应用。相对于 BoW-SARSIFT 鉴别算法,本文多特征融合 BoW 模型鉴别算法计算时间仅提升了 0.4 倍左右,因此同样具有一定的应用价值。

6 结束语

针对复杂场景中的 SAR 目标鉴别问题,本文提出一种基于多特征融合 BoW 模型的 SAR 目标鉴别算法。实验结果表明基于 BoW 模型提取的鉴别特征的鉴别性能要明显优于传统鉴别特征;同时,相比于单个底层特征的 BoW 模型特征,多特征融合 BoW 模型特征能够保留图像中更为丰富的可分性信息,从而能够提升特征的鉴别性能。本文中 BoW 模型算法可以看成是一个浅层网络模型^[18],设计基于深度卷积神经网络^[33]的 SAR 目标鉴别算法将是我们接下来的研究内容。

参 考 文 献

- [1] KREITHEN D E, HALVERSEN S D, and OWIRKA G J. Discriminating targets from clutter[J]. *The Lincoln Laboratory Journal*, 1993, 6(1): 25-52.
- [2] VERBOUT S M, WEAVER A L, and NOVAK L M. New image features for discriminating targets from clutter[C]. Defense Sensing and Controls. International Society for Optics and Photonics, Aerospace, 1998: 120-137. doi: 10.1117/12.319439.
- [3] GAO Gui. An improved scheme for target discrimination in high-resolution SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(1): 277-294. doi: 10.1109/TGRS.2010.2052623.
- [4] WANG Yinghua and LIU Hongwei. A hierarchical ship detection scheme for high-resolution SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(10): 4173-4184. doi: 10.1109/TGRS.2012.2189011.
- [5] 张小强, 熊博莅, 匡纲要. 一种基于变化检测技术的 SAR 图像舰船目标鉴别方法[J]. *电子与信息学报*, 2015, 37(1): 63-70. doi: 10.11999/JEIT140143.
ZHANG Xiaoqiang, XIONG Boli, and KUANG Gangyao. A ship target discrimination method based on change detection in SAR imagery[J]. *Journal of Electronics & Information Technology*, 2015, 37(1): 63-70. doi: 10.11999/JEIT140143.
- [6] PARK J I, PARK S H, and KIM K T. New discrimination features for SAR automatic target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, 10(3): 476-480. doi: 10.1109/LGRS.2012.2210385.
- [7] 高贵. SAR 图像目标鉴别研究综述[J]. *信号处理*, 2009(9): 1421-1432. doi: 10.3969/j.issn.1003-0530.2009.09.018.
GAO Gui. Study on target discrimination in SAR images: A survey[J]. *Signal Processing*, 2009, 25(9): 1421-1432. doi: 10.3969/j.issn.1003-0530.2009.09.018.
- [8] WANG Yinghua and LIU Hongwei. SAR target discrimination based on BOW model with sample-reweighted category-specific and shared dictionary learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017 in revision.
- [9] CSURKA G, DANCE C R, FAN L, et al. Visual categorization with bags of keypoints[C]. European Conference on Computer Vision, Prague, 2004: 1-22.
- [10] YANG Jianchao, YU Kai, GONG Yihong, et al. Linear spatial pyramid matching using sparse coding for image classification[C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Miami, Florida, 2009: 1794-1801. doi: 10.1109/CVPR.2009.5206757.
- [11] 王瑞霞, 彭国华. N-words 模型下 Hesse 稀疏表示的图像检索算法[J]. *电子与信息学报*, 2016, 38(5): 1115-1122. doi: 10.11999/JEIT150617.
WANG Ruixia and PENG Guohua. Hesse sparse representation under n-word model for image retrieval[J]. *Journal of Electronics & Information Technology*, 2016, 38(5): 1115-1122. doi: 10.11999/JEIT150617.
- [12] FAROOQ J. Object detection and identification using SURF and BoW model[C]. International Conference on Computing, Electronic and Electrical Engineering, Quetta, Pakistan, 2016: 318-323.
- [13] GEMERT J C, GEUSEBROEK J M, VEENMAN C J, et al. Kernel codebooks for scene categorization[C]. European Conference on Computer Vision, Marseille, France, 2008: 696-709. doi: 10.1007/978-3-540-88690-7_52.
- [14] BAHMANYAR R, CUI S, and DATCU M. A comparative study of Bag-of-Words and Bag-of-Topics models of EO image patches[J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(6): 1357-1361. doi: 10.1109/LGRS.2015.2402391.
- [15] YAO W, LOFFELD O, and DATCU M. Application and evaluation of a hierarchical patch clustering method for remote sensing images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(6): 2279-2289. doi: 10.1109/JSTARS.2016.2536143.
- [16] GLEICH D and SIPOS D. Categorization based on sparse coding for SAR patch categorization[C]. European Conference on Synthetic Aperture Radar, Hamburg, 2016:

- 1-4.
- [17] CUI S, SCHWARZ G, and DATCU M. Remote sensing image classification: no features, no clustering[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(11): 5158-5170. doi: 10.1109/JSTARS.2015.2495267.
- [18] 黄凯奇, 任伟强, 谭铁牛. 图像物体分类与检测算法综述[J]. *计算机学报*, 2014, 37(6): 1225-1240. doi: 10.3724/SP.J.1016.2014.01225.
HUANG Kaiqi, REN Weiqiang, and TAN Tieniu. A review on image classification and detection[J]. *Chinese Journal of Computers*, 2014, 37(6): 1225-1240. doi: 10.3724/SP.J.1016.2014.01225.
- [19] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110. doi: 10.1023/B:VISI.0000029664.99615.94.
- [20] DELLINGER F, DELON J, GOUSSEAU Y, *et al.* SAR-SIFT: A SIFT-like algorithm for SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(1): 453-466. doi: 10.1109/TGRS.2014.2323552.
- [21] Fernando B, MUSELET D, FROMONT E, *et al.* Discriminative feature fusion for image classification[C]. *IEEE Conference on Computer Vision and Pattern Recognition*, Providence, Rhode Island, 2012: 3434-3441. doi: 10.1109/CVPR.2012.6248084.
- [22] LUO Wei, YANG Jian, XU Wei, *et al.* Higher-level feature combination via multiple kernel learning for image classification[J]. *Neurocomputing*, 2015, 167(C): 209-217. doi: 10.1016/j.neucom.2015.04.075.
- [23] LAZEBNIK S, SCHMID C, and PONCE J. Beyond bags of features: spatial pyramid matching for recognizing natural scene categories[C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, New York, USA, 2006: 2169-2178. doi: 10.1109/CVPR.2006.68.
- [24] BUCAK S S, JIN R, and JAIN A K. Multiple kernel learning for visual object recognition: a review[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(7): 1354-1369. doi: 10.1109/TPAMI.2013.212.
- [25] LI F F and PERONA P. A bayesian hierarchical model for learning natural scene categories[C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Diego, USA, 2005(2): 524-531. doi: 10.1109/CVPR.2005.16.
- [26] MIKOLAJCZYK K and SCHMID C. A performance evaluation of local descriptors[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(10): 1615-1630. doi: 10.1109/TPAMI.2005.188.
- [27] FJORTOFT R, LOPES A, and MARTHON P. An optimal multiedge detector for SAR image segmentation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1998, 36(3): 793-802. doi: 10.1109/36.673672.
- [28] SMITH M E and VARSHNEY P K. Intelligent CFAR processor based on data variability[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2000, 36(3): 837-847. doi: 10.1109/7.869503.
- [29] ELDARYMLI K, MCGUIRE P, POWER D, *et al.* Target detection in synthetic aperture radar imagery: A state-of-the-art survey[J]. *Journal of Applied Remote Sensing*, 2013, 7(1): 1-35. doi: 10.1117/1.JRS.7.071598.
- [30] Sandia National Laboratories. Available online at: <http://www.sandia.gov/radar/minisar.html/SAND2005-3706P-miniSAR-flight-SAR-images.pdf>, 2005.
- [31] YU Wenyi, WANG Yinghua, and LIU Hongwei. Superpixel-based CFAR target detection for high-resolution SAR images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(5): 730-734. doi: 10.1109/LGRS.2016.2540809.
- [32] HE H and GARCIA E A. Learning from imbalanced data[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 21(9): 1263-1284. doi: 10.1109/TKDE.2008.239.
- [33] DING Jun, LIU Hongwei, CHEN Bo, *et al.* Convolutional neural network with data augmentation for SAR Target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 1-5. doi: 10.1109/LGRS.2015.2513754.
- 宋文青: 男, 1988 年生, 博士生, 研究方向为雷达目标识别、统计信号处理、统计机器学习。
- 王英华: 女, 1982 年生, 副教授, 博士, 主要研究方向为 SAR 目标检测与识别、极化 SAR 图像分析与解译等。
- 刘宏伟: 男, 1971 年生, 教授, 博士生导师, 主要研究方向为雷达自动目标识别、宽带雷达信号处理、网络化雷达技术、自适应和阵列信号处理等。