

## 基于二维随机投影特征典型相关分析融合的 SAR ATR 方法

李正伟<sup>1,2</sup>, 黄孝斌<sup>2\*</sup>, 胡 尧<sup>2\*</sup>

(1. 成都理工大学 地球科学学院, 四川 成都 610059;  
2. 成都理工大学 工程技术学院, 四川 乐山 614000)

**摘要:** 合成孔径雷达 (Synthetic aperture radar, SAR) 自动目标识别 (Automatic target recognition, ATR) 是现代战场情报侦察、精确打击的重要支撑技术。为提升 SAR ATR 整体性能, 提出基于二维投影特征多重集典型相关分析 (Multiset canonical correlations analysis, MCCA) 的方法。首先, 采用若干二维随机投影矩阵对 SAR 图像进行特征提取, 获得多层次特征描述。考虑到这些结果之间的相关性和可能存在的冗余及干扰, 进一步通过 MCCA 对它们进行融合处理, 获取单一特征矢量。基于稀疏表示分类器 (Sparse representation-based classification, SRC) 对融合特征矢量进行处理, 判决目标类别。实验基于 MSTAR 数据集开展, 对方法性能进行检验确认, 结果能够验证其有效性。

**关键词:** 合成孔径雷达; 自动目标识别; 二维随机投影; 多重集典型相关分析; 稀疏表示分类  
**中图分类号:** TN957 **文献标志码:** A **DOI:** 10.3788/IRLA20220029

## SAR ATR method based on canonical correlations analysis of features extracted by 2D random projection

Li Zhengwei<sup>1,2</sup>, Huang Xiaobin<sup>2\*</sup>, Hu Yao<sup>2\*</sup>

(1. School of Earth Science, Chengdu University of Technology, Chengdu 610059, China;  
2. The Engineering & Technical College of Chengdu University of Technology, Leshan 614000, China)

**Abstract:** Synthetic aperture radar (SAR) automatic target recognition (ATR) is an important support technology for modern battlefield intelligence reconnaissance and precision strikes. In order to improve the overall performance of SAR ATR, a method based on multiset canonical correlations analysis (MCCA) of two-dimensional (2D) projection features is proposed. First, a series of 2D random projection matrices are used to extract features from SAR images to obtain multi-level feature descriptions. Considering the correlation between these results and the possible redundancy and interference, they are further fused through MCCA to obtain a single feature vector. The sparse representation-based classification (SRC) is used to process the fusion feature vector to determine the target class. The experiment is carried out based on the MSTAR dataset to fully test the proposed methods. The experimental results verify its effectiveness.

**Key words:** synthetic aperture radar; automatic target recognition; 2D random projection; multiset canonical correlations analysis; sparse representation-based classification

收稿日期: 2022-02-12; 修订日期: 2022-03-25

基金项目: 四川旅游发展研究中心项目 (2021SCLV-06); 四川省乐山市科技局重点项目 (19GZD025)

作者简介: 李正伟, 讲师, 博士, 主要从事资源与环境遥感、微波遥感、3S 技术、遥感图像处理方面的研究。

通讯作者: 黄孝斌, 副教授, 硕士, 主要从事 3S 技术、大地测量、遥感图像处理方面的研究。

胡尧, 讲师, 硕士, 主要从事遥感图像处理、地理信息、大地测量、3S 技术方面的研究。

## 0 引言

合成孔径雷达 (Synthetic aperture radar, SAR) 具有很强的数据测量和成像能力,因而在不同领域发挥着重要作用。以 SAR 自动目标识别 (Automatic target recognition, ATR) 为代表的关键技术成为情报侦察、情报解译以及导弹制导等军事应用的重要支撑<sup>[1]</sup>。伴随高分辨 SAR 成像技术的发展和成熟,基于 SAR 图像的战术目标识别方法应运而生。这些方法主要采用“特征提取+分类器”的两阶段思路。特征提取从原始 SAR 图像出发,秉承去粗存精的思维抽取有价值的目标特征,如几何形状、灰度分布以及散射特性等。参考文献 [2-3] 通过目标区域等几何特性进行分析和匹配识别,体现了目标物理外观信息。然而,受 SAR 图像中的噪声、杂波等影响以及可能出现的人为干扰,几何形状等信息的抽取和分析难度较大。参考文献 [4-10] 以主成分分析 (Principal component analysis, PCA)、单演信号、模态分解等数学投影或信号分解算法为基本手段获取 SAR 图像矢量化特征。这些特征具有良好的一致性,并且提取效率很高。不足的是,它们往往不能反映目标的物理层信息。描述 SAR 目标散射特性的特征包括极化信息<sup>[11]</sup>、局部散射中心<sup>[12-13]</sup>等。其中,散射中心特征应用更为普遍,可通过属性参数 (位置、长度、结构等) 的匹配进行类别决策。然而,由于散射中心模型一般较为复杂,散射中心参数估计难度较大,在一定程度影响了识别精度。SAR 目标识别中使用的分类器大多继承于传统模式识别领域,或是根据 SAR 图像的特点进行了优化改进,如参考文献 [14] 采用的 K 近邻,参考文献 [15-16] 使用的支持向量机 (Support vector machine, SVM), 参考文献 [17-19] 采用的稀疏表示分类 (Sparse representation-based classification, SRC) 以及近年来常见的卷积神经网络 (Convolutional neural network, CNN)<sup>[20-22]</sup> 等。

根据上述介绍,设计或选取有效的特征是影响 SAR 目标识别性能的关键因素之一。文中提出基于二维随机投影特征多重集典型相关分析 (Multiset canonical correlations analysis, MCCA)<sup>[23-24]</sup> 融合的识别方法。参考文献 [25] 根据压缩感知的原理提出了基于随机投影的特征提取算法,并在 SAR 目标识别中进行了应用。其结果表明随机投影作为一种非参

数化的降维算法,具有很高的效率并且可以保持特征的鉴别力。考虑到一维随机投影对于 SAR 图像二维结构信息的潜在破坏性,参考文献 [26-27] 对其进行了扩展,提出二维随机投影算法。经验证,二维随机投影针对 SAR 目标识别问题具有性能优势。为此,文中以二维随机投影作为特征提取的基础算法,通过若干个不同的投影矩阵获取 SAR 图像的多层次特征描述。不同的投影结果之间具有良好的互补性,同时也存在一定的冗余或干扰。为此,文中进一步采用 MCCA 对不同投影矩阵下获得的特征进行融合分析。融合的特征矢量既可以保持不同层次特征之间的关联性,又可以有效去除冗余和干扰成分,从而为后续分类提供高鉴别力的特征输入。在分类阶段,选用稳健性较强的 SRC 作为基础分类器,通过融合特征矢量的训练和处理获取最终分类结果。

## 1 二维随机投影特征提取

根据压缩感知原理,稀疏信号可基于少量的观测进行重构。因此,存在冗余的信号可按此原理进行有效降维。参考文献 [25] 根据这一理论设计了随机投影算法并在特征提取和目标识别中进行了应用。为进一步处理图像等二维数据,参考文献 [26-27] 将一维的投影矩阵延伸到二维。以图像分析为例,输入图像  $X \in R^{m_1 \times m_2}$  经过两个随机投影矩阵  $A \in R^{m_1 \times n_1}$  和  $B \in R^{m_2 \times n_2}$ , 按照  $Y = AXB^T$  的方式变换得到特征矩阵  $Y \in R^{m_1 \times m_2}$ , 其中  $m_1$  远小于  $n_1$ ,  $m_2$  远小于  $n_2$ , 实现高效降维。

根据参考文献 [26] 相关论述,为了使得二维投影后的特征矩阵能够有效保持图像特性,要求通过低维度的投影矩阵  $Y$  能够对原始图像进行高精度重构。此时,需要对两个投影矩阵进行如下约束:

$$\|X\|_0 < \text{spark}(A)\text{spark}(B)/4$$

$$(\ell_0 \text{ norm of each column of } X) < \text{spark}(A)/2$$

$$(\ell_0 \text{ norm of each row of } X) < \text{spark}(B)/2 \quad (1)$$

式中:  $\|X\|_0$  计算  $X$  的  $\ell_0$  范数,即为矩阵中非零元素的个数;函数  $\text{spark}$  获取当前矩阵中相互独立的列数。对于矩阵  $A \in R^{m_1 \times n_1}$  和  $B \in R^{m_2 \times n_2}$ , 满足  $\text{spark}(A) = m_1 + 1$ ,  $\text{spark}(B) = m_2 + 1$ 。

基于上述准则构造的二维随机投影矩阵可有效获取 SAR 图像的鉴别力特征,并已成功应用于目标

识别。然而,这种特征提取方法由于投影矩阵的不唯一性而具有一定的随机性,导致识别结果存在不稳定的问题。为此,文中采用若干个二维随机投影矩阵对原始图像进行处理。不同投影矩阵下的结果具有互补性,可有效弥补单一投影矩阵存在的不稳定。因此,联合不同投影矩阵下的结果有利于提供最终的识别性能。

## 2 多重集典型相关分析

传统典型相关分析 (Canonical correlations analysis, CCA) 主要用于比较两组随机变量,分析它们之间的关联性和差异。MCCA 则是对传统 CCA 进行延伸扩展,主要用于分析多组不同随机变量之间的关联性和差异<sup>[23-24]</sup>。记一组随机变量为 $X_1, X_2, \dots, X_n$ , 它们的维度分别为 $m_1, m_2, \dots, m_n$ ( $m_1$ 为最小值)。MCCA 算法首先对各个随机变量进行去均值和中心化。然后,设计如公式 (2) 所示的准则函数:

$$J_{MCCA}(\alpha_1, \alpha_2, \dots, \alpha_n) = \frac{\sum_{i=1}^n \sum_{j=1}^n \alpha_i^T S_{ij} \alpha_j}{\sqrt{\sum_{i=1}^n \alpha_i^T S_{ii} \alpha_i}} \quad (2)$$

式中:  $S_{ij} = E(X_i X_j^T)$  计算  $X_i$  与  $X_j$  两个随机变量的互协方差矩阵。为了对这一准则函数进行最大化,开展以下优化过程:

$$\begin{aligned} \max_{\alpha_1, \alpha_2, \dots, \alpha_n} & \sum_{i=1}^n \sum_{j=1}^n \alpha_i^T S_{ij} \alpha_j \\ \text{s.t.} & \sum_{i=1}^n \alpha_i^T S_{ii} \alpha_i = 1 \end{aligned} \quad (3)$$

对于公式 (3) 的优化过程,可利用 Lagrange 乘子法进行求解:

$$\begin{pmatrix} S_{11} & \dots & S_{1n} \\ \vdots & \ddots & \vdots \\ S_{n1} & \dots & S_{nn} \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} = \begin{pmatrix} \lambda_1 S_{11} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_n S_{nn} \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} \quad (4)$$

根据对公式 (4) 的求解结果进一步获取变换矩阵  $A = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ , 其中:

$$\begin{aligned} \alpha_1 &= [\alpha_{11}, \alpha_{12}, \dots, \alpha_{1m_1}]_{m_1 \times m_1} \\ \alpha_2 &= [\alpha_{21}, \alpha_{22}, \dots, \alpha_{2m_1}]_{m_2 \times m_1} \\ &\vdots \\ \alpha_n &= [\alpha_{n1}, \alpha_{n2}, \dots, \alpha_{nm_1}]_{m_n \times m_1} \end{aligned} \quad (5)$$

对应地,从公式 (5) 中可以得到不同变量  $X_i$  对应的投影方向,采用公式 (6) 对不同随机变量加权融合,得到结果如下:

$$Z = \alpha_1^T X_1 + \alpha_2^T X_2 + \dots + \alpha_n^T X_n \quad (6)$$

文中采用 MCCA 对同一幅 SAR 图像的多个不同特征进行融合。最终获取的特征矢量不仅能保持不同投影矩阵的独立性,也可以去除可能存在的冗余或干扰成分。因此,融合后的特征矢量具有更强的鉴别力和简洁性,有利于提高识别算法的整体性能。

## 3 识别方法描述

### 3.1 稀疏表示分类

自稀疏表示理论提出和应用以来,其衍生工具在信号、图像处理等领域得到十分广泛的运用。SRC 就是一个典型代表,主要用于模式识别中监督分类问题<sup>[17-19]</sup>。对于多类别的训练样本,可根据它们建立全局字典  $A = [A_1, A_2, \dots, A_C] \in R^{d \times N}$ , 其中  $A_i$  对应来自第  $i$  类中  $N_i$  个训练样本。测试样本  $y$  在全局字典上进行线性表示,求解线性表示系数:

$$\begin{aligned} \hat{x} &= \arg \min_x \|x\|_0 \\ \text{s.t.} & \|y - Ax\|_2^2 \leq \varepsilon \end{aligned} \quad (7)$$

式中:  $x$  为需要求解的系数矢量;  $\varepsilon$  为误差门限。

根据现有文献,上述非凸优化问题可通过  $\ell_1$  范数替代  $\ell_0$  范数进行转换,从而简化优化问题,获取近似解。此外,也可采用正交匹配追踪等贪婪算法进行寻优。根据系数求解结果,可以按照公式 (8) 分别阶段单个类别的重构误差大小:

$$r(i) = \|y - A_i x_i\|_2^2 \quad (i = 1, 2, \dots, C) \quad (8)$$

式中:  $x_i$  为第  $i$  类上的系数矢量;  $r(i)$  即为  $i$  类别的最终误差。最后,可以根据误差判定测试样本与哪一类训练样本最为相似,从而获得类别决策结果。

### 3.2 目标识别流程

根据前文思想,文中设计如图 1 所示的目标识别流程,实线部分代表训练流程,虚线部分代表测试流程,中间部分为相同流程,具体实施描述如下。首先,按照二维随机投影的构造原则获取若干对随机投影矩阵,用于对 SAR 图像的特征提取。对于训练样本,分别采用不同的投影矩阵进行特征提取,进一步采用

MCCA 对它们进行融合,获得单一的特征矢量,存入全局字典。据此可构建与训练样本规模一致的全局字典。对于测试样本,按照上述步骤经随机投影特征

提取和 MCCA 特征融合获得对应的特征矢量。最终,采用 SRC 对测试样本的特征矢量进行分类,判决目标所属类别。




图 1 基于二维随机投影特征 MCCA 融合的自动目标识别流程

Fig.1 Procedure of ATR based on MCCA of 2D random projection features

二维随机投影矩阵在无需先验知识的情况下,保持了 SAR 图像的二维结构信息。同时,结合多个不同二维随机投影矩阵的结果,能够实现对目标特性互补的描述,进一步增强特征层的鉴别力。基于 MCCA 的特征融合有效继承了多层次二维随机投影特征的优势,同时去除了存在的冗余分量。SRC 中的稀疏重构分类机制具有较强的噪声、遮挡稳健性,采用其进行最终决策有利于提高识别结果的稳健性。因此,文中方法通过结合特征提取和分类决策的优势提升整体识别性能。

数据集。MSTAR 计划中,研究人员在多种场景和操作条件下采集了图 2 所示的 10 类目标的 SAR 图像,分辨率达到 0.3 m。据此,可分别构建训练和测试样本,验证目标识别算法的有效性。根据现有文献报道,在 MSTAR 数据集的样本基础上可设置诸如标准操作条件、目标型号差异、俯仰角差异等测试条件。此外,通过对原始 MSTAR 样本进行简单处理,可进一步构建噪声干扰、部分遮挡等测试条件。文中在上述条件中重点对标准操作条件、俯仰角差异以及噪声干扰三种场景进行针对性实验,检验提出方法的有效性和稳健性。

## 4 实验结果与讨论

### 4.1 数据集描述

在 SAR 目标识别领域, MSTAR 数据集具有很强的代表性,是当前绝大多数相关方法开展验证的基础

实验中还设置了一些对比方法,它们包括参考文献 [25] 基于随机投影的方法 (Random projection), 该方法采用一维随机投影算法进行 SAR 图像降维; 参考文献 [26] 中二维随机投影的方法 (记为 2D random



图 2 MSTAR 数据集包含的车辆目标图像

Fig.2 Images of the vehicle targets in the MSTAR dataset

projection), 该方法将一维投影扩展到二维, 从而更好地保持图像结构信息; 参考文献 [8] 采用单演信号特征的方法 (记为 Monogenic), 结合不同成分特征进行决策; 参考文献 [20] 中基于 CNN 的方法 (记为 CNN), 该方法针对 SAR 目标识别设计了特定结构的 CNN。

## 4.2 识别结果与对比分析

### 4.2.1 标准操作条件

标准操作条件是 SAR 目标识别问题中一项基础且具有代表性意义的实验场景。根据 MSTAR 数据集包含的目标类别和不同条件下的 SAR 图像数据, 设置表 1 所示的测试条件, 且每个目标只有一种型号。测试集为各类目标 15°俯仰角下的样本, 其中 BMP2 和 T72 两类目标各包含 3 个型号。对比训练和测试集, 两种样本虽然存在一定差异但整体相似度较

高, 可认为是标准操作条件。对于 10 类目标的识别结果, 采用平均识别率进行定量评价, 即正确识别样本数所占的比例。据此, 表 2 对比了不同方法的识别性能。文中方法以 99.08% 的平均识别率优于四类对比方法。CNN 方法性能排名第二, 显示了深度学习网络优越性能。二维随机投影方法的性能优于传统的一维随机投影方法, 体现了二维特征提取的必要性。相比单演信号方法, 二维随机投影方法略有劣势, 主要是特征鉴别力的差距。然而, 单演信号特征分解的复杂度要远远高于二维随机投影。文中方法在多层次二维随机投影特征的基础上进行融合处理, 经过 MCCA 过后的特征矢量显著提升了识别性能, 反映了方法设计思路的科学性。

表 1 标准操作条件的样本设置

Tab.1 Sample settings for SOC

| Target label | Training set (Depression: 17°) |         | Test set (Depression: 15°) |         |
|--------------|--------------------------------|---------|----------------------------|---------|
|              | Configuration                  | Samples | Configuration              | Samples |
| BMP2         | 9 563                          | 218     | 9 563                      | 180     |
|              |                                |         | 9 566                      | 181     |
|              |                                |         | e21                        | 181     |
| BTR70        | -                              | 218     | -                          | 181     |
|              |                                |         | 132                        | 181     |
| T72          | 132                            | 217     | 812                        | 180     |
|              |                                |         | s7                         | 176     |
| T62          | -                              | 284     | -                          | 258     |
| BRDM2        | -                              | 283     | -                          | 259     |
| BTR60        | -                              | 241     | -                          | 180     |
| ZSU23/4      | -                              | 284     | -                          | 259     |
| D7           | -                              | 284     | -                          | 259     |
| ZIL131       | -                              | 284     | -                          | 259     |
| 2 S1         | -                              | 284     | -                          | 180     |

表 2 标准操作条件下的对比结果

Tab.2 Comparison results under SOC

| Method                   | Proposed | Random projection | 2D random projection | Monogenic | CNN    |
|--------------------------|----------|-------------------|----------------------|-----------|--------|
| Average recognition rate | 99.08%   | 97.18%            | 98.23%               | 98.64%    | 98.82% |

### 4.2.2 俯仰角差异

在上述标准操作条件中, 一个重要的因素是测试样本与训练样本的俯仰角差异很小。实际上, 测试样

本很可能来自于测试样本差距较大俯仰角, 此时两者的图像差异也会较为明显。根据 MSTAR 数据集中的 SAR 图像数据, 设置如表 3 所示的训练和测试

集。训练集包含了 2S1、BRDM2 以及 ZSU23/4 共 3 类目标在 17°俯仰角下的 SAR 图像。测试样本来自差异较大的俯仰角,可进一步区分为两个子集,分别对应 30°俯仰角和 45°俯仰角。两个测试子集反映了不同程度的俯仰角差异,能够更为全面地反映方法在不同俯仰角差异程度条件下的识别性能。基于上述设置,获取不同方法的识别性能,统计如表 4 所示。从两个测试子集的角度来看,30°俯仰角下的整体性能要明显优于 45°,反映了大俯仰角差异带来的识别

难度急剧增加。根据上述结果,文中方法对于不同程度俯仰角差异的适应性和稳健性更强,能够在俯仰角差异的情形下保持良好性能。相比标准操作条件,CNN 方法在此条件下的性能下降最为剧烈,表明在训练样本不足或与测试样本差异较大时,深度学习算法也存在很大的局限性。文中方法通过 MCCA 对多层次的二维随机投影特征进行融合,可获取稳健的识别性能,确保了在此场景下的性能。

表 3 俯仰角差异的样本设置

Tab.3 Sample settings for depression angle variance

| Target label | Training set   |         | Test set       |         |
|--------------|----------------|---------|----------------|---------|
|              | Depression/(°) | Samples | Depression/(°) | Samples |
| 2 S1         | 17             | 284     | 30             | 283     |
|              |                |         | 45             | 288     |
| BRDM2        | 17             | 283     | 30             | 272     |
|              |                |         | 45             | 288     |
| ZSU23/4      | 17             | 284     | 30             | 273     |
|              |                |         | 45             | 288     |

表 4 俯仰角差异下的结果对比

Tab.4 Comparison results under depression angle variances

| Method               | Average recognition rate |        |
|----------------------|--------------------------|--------|
|                      | 30°                      | 45°    |
| Proposed             | 96.87%                   | 72.19% |
| Random projection    | 94.72%                   | 68.52% |
| 2D random projection | 95.14%                   | 69.52% |
| Monogenic            | 95.73%                   | 70.42% |
| CNN                  | 95.32%                   | 68.34% |

4.2.3 噪声干扰

图像噪声水平直接影响图像质量,低信噪比(Signal-to-noise ratio, SNR)的图像会给识别问题带来很大难度。原始 MSTAR 数据集的 SAR 图像整体信噪比较高,据此建立的训练和测试集具有相接近的噪声水平,因此难以评价方法在测试样本不同信噪比条件下的识别性能。为此,文中按照参考文献 [12] 的思路和方法对表 1 中的测试样本进行噪声条件,以原始图像为参照分别构建多个不同信噪比(含 -10 dB、-5 dB、0 dB、5 dB 和 10 dB)的样本测试集。

然后,就不同信噪比下的测试样本对各类方法进行测试,获得如图 3 所示的平均识别率曲线。伴随信噪比的降低,各类方法的平均识别率均出现了较为明显的下降,充分反映了噪声干扰的影响。对比几类方法,文中方法可在不同噪声水平保持最佳性能,具有最强的噪声稳健性。与俯仰角差异的情况类似,CNN 方法由于样本不足,导致性能下降十分剧烈。与二维随机投影方法相比,文中通过多个随机投影矩阵的联合使用和有效的特征融合显著提升了对于噪声干扰的稳健性。




图 3 噪声干扰下的结果对比

Fig.3 Comparison results under noise corruption

## 5 结 论

论文针对 SAR 图像目标识别问题提出结合二维随机投影和 MCCA 的特征提取方法,进而采用 SRC 进行分类决策。利用多个不同的二维随机投影矩阵获取原始 SAR 图像多层次的特征描述。进一步,采用 MCCA 对多层次的二维随机投影特征进行融合处理,获取一致性更强、维度更低、鉴别力更优的特征矢量。最后,通过 SRC 对融合的特征矢量进行分类,获取识别结果。在 MSTAR 数据集上开展了 3 类典型实验,覆盖了标准操作条件和代表性扩展操作条件。经实验对比分析,提出方法对于 SAR ATR 可以取得良好性能。

### 参考文献:

[1] EL-Darymli K, Gill E W, Mcguire P, et al. Automatic target recognition in synthetic aperture radar imagery: a state-of-the-art review [J]. *IEEE Access*, 2016, 4: 6014-6058.

[2] Anagnostopoulos G C. SVM-based target recognition from synthetic aperture radar images using target region outline descriptors [J]. *Nonlinear Analysis*, 2009, 71(2): 2934-2939.

[3] Papson S, Narayanan R M. Classification via the shadow region in SAR Imagery [J]. *IEEE Transactions on Aerospace and Electronic System*, 2012, 40(8): 969-980.

[4] Mishra A K, Motaung T. Application of linear and nonlinear PCA to SAR ATR[C]// *Radioelektronika*, 2015: 1-6.

[5] LI W H, Wang J G. SAR images target recognition based on bilateral two-dimensional principal component analysis and

probabilistic neural network ensemble [J]. *Journal of CAEIT*, 2014, 9(4): 401-407. (in Chinese)

[6] Cui Z Y, Cao Z J, Yang J Y, et al. Target recognition in synthetic aperture radar via non-negative matrix factorization [J]. *IET Radar, Sonar and Navigation*, 2015, 9(9): 1376-1385.

[7] Dong G G, Kuang G Y, Wang N, et al. SAR target recognition via joint sparse representation of monogenic signal [J]. *IEEE Journal of Selected Topics Applied Earth Observation and Remote Sensing*, 2015, 8(7): 3316-3328.

[8] Wang Y Y. SAR target recognition based on monogenic features via multiset canonical correlation analysis [J]. *Electronics Optics & Control*, 2019, 26(10): 7-11,29. (in Chinese)

[9] Liu X W, Lei J J, Wu Y P. Synthetic aperture radara target recognition based on bidimensional empirical mode decomposition [J]. *Laser and Optoelectronics Progress*, 2020, 57(5): 051004. (in Chinese)

[10] Zhou G Y, Liu B Q, Zhang D. Target recognition in SAR images based on variational mode decomposition [J]. *Remote Sensing for Land and Resources*, 2020, 32(2): 33-39. (in Chinese)

[11] Zhang R, Hong J, Ming F. Full polarimetry SAR ATR algorithm based on polarimetry similarity [J]. *Foreign Electronic Measurement Technology*, 2010, 29(5): 24-27. (in Chinese)

[12] Ding B Y, Wen G J, Yu L S, et al. Matching of attributed scattering center and its application to synthetic aperture radar automatic target recognition [J]. *Journal of Radar*, 2017, 6(2): 157-166. (in Chinese)

[13] Ding B Y, Wen G J, Zhong J R, et al. A robust similarity measure for attributed scattering center sets with application to SAR ATR [J]. *Neurocomputing*, 2017, 219: 130-143.

[14] Hao Y, Ai Y P, Zhang Y F. Synthetic aperture radar target recognition based on KNN [J]. *Fire Control & Command Control*, 2018, 43(9): 113-115, 120. (in Chinese)

[15] Liu C Q, Chen B, Pan Z H, et al. Research on Target Recognition Technique via Simulation SAR and SVM classifier [J]. *Journal of CAEIT*, 2016, 11(3): 257-262. (in Chinese)

[16] Liu H C, Li S T. Decision fusion of sparse representation and support vector machine for SAR image target recognition [J]. *Neurocomputing*, 2013, 113: 97-104.

[17] Thiagaraianm J, Ramamurthy K, Knee P P, et al. Sparse representations for automatic target classification in SAR images [C]//4th Communications, Control and Signal Processing, 2010: 1-4.

[18] Tang J S, Qin S H. SAR target recognition based on sparse coefficients optimal local reconstruction [J]. *Journal of*

- Detection & Control*, 2013, 43(2): 69-75. (in Chinese)
- [19] Zhang H, Zuo X L, Huang Y. Feature selection based on the correlation of sparse coefficient vectors with application to SAR target recognition [J]. *Laser and Optoelectronics Progress*, 2020, 57(14): 141029. (in Chinese)
- [20] Chen S Z, Wang H P, Xu F, et al. Target classification using the deep convolutional networks for SAR images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4806-4817.
- [21] Zhang P P, Luo H B, Ju M R, et al. An improved capsule and its application in target recognition of SAR images [J]. *Infrared and Laser Engineering*, 2020, 49(5): 20201010. (in Chinese)
- [22] Xu Y, Gu Y, Peng D L, et al. SAR ATR based on disentangled representation learning generative adversarial networks and support vector machine [J]. *Optics and Precision Engineering*, 2020, 28(3): 727-735. (in Chinese)
- [23] Peng J L, Li Q, El-latif A A, et al. Linear discriminant multi-set canonical correlations analysis (LDMCCA): an efficient approach for feature fusion of finger biometrics [J]. *Multimedia Tools and Applications*, 2015, 74(13): 4469-4486.
- [24] Qiu A K, Zhu J G. Multi-set canonical correlations analysis based on ensemble learning [J]. *Computer Engineering and Applications*, 2017, 53(6): 162-169. (in Chinese)
- [25] Zhang H C, Nasrabadi N M, Zhang Y, et al. Multi-view automatic target recognition using joint sparse representation [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(3): 2481-2497.
- [26] Ding B Y, Wen G J, Ye F, et al. Feature extraction based on 2 D compressive sensing for SAR automatic target recognition [C]//EUCAP, 2017: 1219-1223.
- [27] Wu J B, Lu Z W, Guang Y R, et al. SAR target recognition using feature fusion by 2D compressive sensing with multiple random projection matrices [J]. *Infrared and Laser Engineering*, 2021, 50(6): 20200531. (in Chinese)