

图像分块匹配的 SAR 目标识别方法

马丹丹

(佳木斯大学 信息电子技术学院, 黑龙江 佳木斯 154000)

摘要: 提出基于分块匹配的合成孔径雷达 (Synthetic Aperture Radar, SAR) 目标识别方法。对待识别 SAR 图像进行 4 分块处理, 每个分块描述目标的局部区域。对于每个分块, 基于单演信号构造特征矢量, 描述其时频分布以及局部细节信息。单演信号从幅度、相位以及局部方位 3 个层次对图像进行分解, 可有效描述图像的局部变化情况, 对于扩展操作条件下的目标变化分析具有重要的参考意义。对于构造得到的 4 个特征矢量, 分别采用稀疏表示分类 (Sparse Representation-based Classification, SRC) 分别进行分类, 获得相应的重构误差矢量。在此基础上, 按照线性加权融合的基本思想, 通过构造随机权值矩阵进行分析。对于不同权值矢量下获得的结果, 经统计分析构造有效的决策变量, 通过比较不同训练类别的结果, 判定测试样本的类别。所提方法在特征提取和分类决策过程中充分考虑 SAR 图像获取条件的不确定, 通过统计分析获得最优决策结果。实验在 MSTAR 数据集上设置和开展, 包含了 1 类标准操作条件和 3 类扩展操作条件。通过与现有几类方法对比, 有效证明了所提方法的有效性。

关键词: 合成孔径雷达; 目标识别; 图像分块; 单演信号; 随机权值

中图分类号: TN957 **文献标志码:** A **DOI:** 10.3788/IRLA20210120

SAR target recognition based on image blocking and matching

Ma Dandan

(College of Information Science & Electronic Technique, Jiamusi University, Jiamusi 154000, China)

Abstract: A synthetic aperture radar (SAR) target recognition method based on image blocking and matching was proposed. The tested SAR image was blocked into four patches, which described the local regions of the target, respectively. For each SAR image patch, the monogenic signal was employed to construct a feature vector, which described its time-frequency distribution and local details. The monogenic signal decomposed the input image from amplitude, phase, and local orientation. Therefore, it could reflect the local variations in the image so providing more reference information for the analysis of target changes under the extended operating conditions. For the 4 feature vectors, the sparse representation-based classification (SRC) was used for classification and produce the corresponding reconstruction error vectors. Accordingly, based on the linear weighting fusion, the random weight matrix was constructed for analysis. For the results from different weight vectors, an effective decision variable was defined based on statistical analysis. By comparison of the decision values of different classes, the target label of the test sample could be decided. The proposed method made sufficient analysis of the uncertainties about the operating conditions during SAR image measurement, an optimal decision was made based on statistical analysis. Experiments were set up and conducted on the MSTAR dataset including one

收稿日期: 2021-04-10; 修订日期: 2021-05-20

基金项目: 佳木斯大学科研项目 (L2012-084)

作者简介: 马丹丹, 女, 讲师, 博士, 主要从事计算机应用、图像处理等方面的研究。

standard operating condition and three extended operating conditions. Compared with several present methods, the results confirmed the validity of the proposed method.

Key words: synthetic aperture radar; target recognition; image blocking; monogenic signal; random weight

0 引言

高分辨合成孔径雷达 (Synthetic Aperture Radar, SAR) 图像为高效、准确的情报解译提供了有力支撑。MSTAR 数据集为 SAR 目标识别算法的研究提供了数据基础^[1]。该数据集中的 SAR 图像分辨率达到 0.3 m, 可有效用于坦克、装甲车、加农炮等 10 类典型车辆目标的分类识别。随着近 30 年的研究发展, 针对 MSTAR 数据集的 SAR 目标识别方法在性能上取得了长足进步。然而, 这些研究成果也暴露了当前识别方法对于扩展操作条件的不足。SAR 目标识别中的扩展操作条件可能由于目标、背景、传感器等因素的差异造成, 其直接结果结束待识别的测试样本与已建立的训练样本存在较大的差异。为此, 着力解决扩展操作下的难点问题是目前 SAR 目标识别方法的研究重点。

一般地, SAR 目标识别方法通过寻找特征和分类器最佳的组合达到提高识别性能的目标。特征提取方面, 参考文献 [2-6] 以区域、轮廓等描述目标几何形状并设计目标识别方法。灰度分布特性可通过数学变换或信号处理等手段进行描述。典型的投影变换算法有主成分分析 (Principal Component Analysis, PCA)^[7-8], 非负矩阵分解 (Non-negative Matrix Factorization, NMF)^[9] 等, 实现高维 SAR 图像到低维特征矢量的变换。应用于 SAR 图像特征提取的信号处理算法包括小波分解^[10]、单演信号^[11] 以及经验模态分解^[12] 等。这些算法主要是将原始 SAR 图像分解为多个层次的表示, 从而获得目标更多的特性描述。电磁散射特征描述目标的后向散射特性, 主要代表是散射中心^[13-15]。参考文献 [13-14] 提出基于属性散射中心 (Attributed Scattering center, ASC) 匹配的 SAR 目标识别方法。分类阶段对测试样本提取特征的类别归属进行判定决策。对于形式规则、维度统一的投影变换特征, 一般可直接通过传统的分类器进行分类识别, 典型的包括 K 近邻 (K-nearest Neighbor, KNN)^[16], 支持向量机 (Support Vector Machine, SVM)^[17-18], 稀疏表示分类 (Sparse

Representation-based Classification, SRC)^[8, 18-21] 等。对于目标轮廓点、散射中心等排列不规则、数量不一致的特征, 则需要针对性设计分类策略, 如参考文献 [13-15] 设计的散射中心集的相似度等。此外, 深度学习模型也在 SAR 目标识别中得到广泛应用, 典型的是卷积神经网络 (Convolutional Neural Network, CNN)^[22-24]。深度学习模型直接基于原始图像进行训练和学习, 回避了传统的手动特征提取过程。研究成果验证了深度学习模型对于 SAR 目标识别的有效性, 但其对于训练样本的需求量很大。对于 SAR 目标识别中的扩展操作条件, 相关的训练样本十分有限, 这就导致了深度学习方法对于扩展操作条件的适应性较差。

文中提出一种 SAR 图像分块匹配的识别方法, 其核心思想是对目标区域进行分块考察, 通过对各个字块的对比分析更为可靠地判定目标类别。在扩展操作条件下, 目标 SAR 图像多发生局部变化。对于同类样本之间, 它们仍然存在较高的相似性。因此, 通过观察和评估 SAR 图像的局部差异以及一致性可更为有效地克服扩展操作条件。为此, 文中将待识别的 SAR 图像进行分块处理, 以其中中心为基础划分为 4 个面积相等的字块。每个子块可以体现目标在一个方向的局部分布特性。在各个子块上, 文中采用单演信号分别进行特征提取并构造相应的特征矢量。基于单演信号分解得到的谱成分可有效反映目标的频谱特性以及局部分布。对于各个字块构造得到的特征矢量, 通过 SRC 获得重构误差矢量。对于不通分块的结果, 采用随机权值它们进行线性加权融合, 进而统计多组权值下的统计特征。对于正确类别, 较低重构误差的子块占多数, 因此最终 4 个重构误差的均值较小、方差较小。反之, 对于错误类别, 其获得的 4 个重构误差均值相对较大并且可能出现较大的方差。文中据此设计决策变量, 作为最终的分类依据。基于 MSTAR 数据集构造典型测试条件和场景对方法进行测试, 结果表明其在标准操作条件和扩展操作

条件下均具有显著的性能优势。

1 SAR 图像分块

现有研究表明, SAR 图像中的扩展操作条件多与目标的局部变化相关联。例如, 在型号变化的情形下, 目标仅是局部结构发生改变, 体现在 SAR 图像中也是局部像素分布、几何结构等信息的变化。为此, 充分考察 SAR 图像中目标的局部变化具有重要意义。传统 SAR 目标识别方法基于原始整体 SAR 图像进行特征提取与分类, 往往会出现由于局部变化导致的全局特征变化, 导致最终的全局特征匹配出现较大误差。为此, 文中将原始 SAR 图像进行分块处理, 然后在各个子块上对目标特性进行分别考察, 最后基于各子块的结果综合分析得到更为可靠的分类结果。

具体而言, 文中使用的分块算法可分为两个主要步骤。首先, 对原始图像进行中心化操作, 即使得目标质心处于图像的中心位置, 从而为所有的训练和测试样本构建参考基准。在此基础上, 以图像中心为焦点, 沿方位向和距离向进行分割, 从而将原始图像四等分, 获得 4 个子块图像。图 1 所示为 MSTAR SAR 图像的分块结果。具体使用中, 各个子块独立处理, 因此互不影响。因此, 当某一子块出现局部变化时, 其分类结果对于其他子块的影响很小。

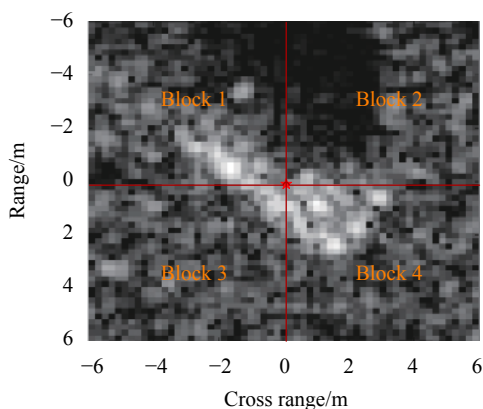


图 1 SAR 图像分块结果示意图

Fig.1 Schematic diagram of SAR image segmentation results

2 特征提取

根据参考文献 [11], 单演信号可用于 SAR 图像分解和特征提取。对于待分解的 SAR 图像 $f(z)$, 其中 $z = (x, y)^T$ 为坐标位置, 其单演信号 $f_M(z)$ 为:

$$f_M(z) = f(z) - (i, j)f_R(z) \quad (1)$$

式中: $f_R(z)$ 为输入图像的 Riesz 变换; i 和 j 均为虚数单位。根据上式, 分别定义三类单演信号特征:

$$A(z) = \sqrt{f(z)^2 + |f_R(z)|^2}$$

$$\varphi(z) = a \tan 2(|f_R(z)|, f(z)) \in (-\pi, \pi]$$

$$\theta(z) = a \tan 2(f_y(z)/f_x(z)) \in \left(-\frac{\pi}{2}, \frac{\pi}{2}\right) \quad (2)$$

式中: $f_x(z)$ 和 $f_y(z)$ 分别为两个轴上单演信号的分量; $A(z)$ 为幅度信息; $\varphi(z)$ 和 $\theta(z)$ 分别为相位成分和方位信息。

三类单演信号特征能够有效反映图像的多层次特征, 包括局部幅度、相位以及方向特性。通过结合这三类特征可为图像分析提供更为充分的信息。为此, 文中采用单演信号描述各个子块的图像特征, 具体按照参考文献 [11] 的思路对分解得到的三类特征进行矢量化串接以及降采样获得低维度特征矢量。最终, 基于单演信号特征对各个子块进行分类。

3 方法描述

3.1 稀疏表示分类

稀疏表示分类根据不同类别对未知样本进行线性拟合, 通过拟合误差大小实施判决。现阶段, 稀疏表示分类已经在 SAR 目标识别方法中得到广泛运用并得到验证 [8, 18-21]。对于测试样本 y , 其稀疏表示为:

$$\begin{aligned} \hat{\alpha} &= \arg \min_x \|\alpha\|_0 \\ \text{s.t. } &\|y - D\alpha\|_2^2 \leq \varepsilon \end{aligned} \quad (3)$$

式中: $D = [D^1, D^2, \dots, D^C] \in \mathbb{R}^{d \times N}$ 表示 C 个训练类别构成的全局字典; α 为稀疏表示系数。在 ℓ_0 范数的约束下, α 呈现稀疏特性。

根据稀疏表示系数的求解结果 $\hat{\alpha}$, 分别计算不同类别的重构误差:

$$r(i) = \|y - D_i \hat{\alpha}_i\|_2^2 (i = 1, 2, \dots, C) \quad (4)$$

式中: $\hat{\alpha}_i$ 表示第 i 类的稀疏矢量; $r(i)$ 则为第 i 类的重构误差。

传统分类策略即根据最小误差的类别进行决策。对于与测试样本一致的训练类别, 其对应的重构误差显著小于其他类别, 因此可以据此进行类别判定。

3.2 随机权值矩阵

文中采用 SRC 对原始 SAR 图像的 4 个子块分别

进行分析处理, 据此获得它们相应的重构误差矢量。对不同子块的结果, 以线性加权为基本手段进行融合。但考虑到单一固定权值矢量的局限性, 文中采用多组随机权值矢量进行处理, 设计的权值矩阵如下:

$$W = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1N} \\ w_{21} & w_{22} & \cdots & w_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_{K1} & w_{K2} & \cdots & w_{KN} \end{bmatrix} \quad (5)$$

其中, 每一列对应一组随机权值矢量, 满足约束:

$$\sum_{k=1}^K w_{ki} = 1 \text{ 且 } w_{ki} \geq 0 \quad (6)$$

在公式 (6) 的约束下, 每一组权值矢量随机确定, 共计得到 N 组随机权值矢量。每一组权值矢量的可能对于不同的子块赋予不同的权值, 其最终的结果可以更为有效的获得融合结果, 有效规避了传统确定权值可能带来的不稳定性。

记第 i 类对第 $k(k = 1, 2, \dots, 4)$ 个子块的重构误差为 r_k^i , 随机加权融合描述为:

$$R_n^i = [r_1^i \ r_2^i \ \cdots \ r_K^i] \begin{bmatrix} w_{n1} \\ w_{n2} \\ \vdots \\ w_{nK} \end{bmatrix} \quad (7)$$

以公式 (7) 为基础, 采用公式 (5) 中的所有权值矢

量重复操作, 第 i 类则有 N 个结果 $R = [R_1^i \ R_2^i \ \cdots \ R_N^i]$, 记为融合误差矢量。

若第 i 类为实际类别, 则各个子块相应的重构误差都较小。此时, 在随机权值矢量下, 融合误差矢量中各个元素的数值较小且变化较为平缓。反之, 若当前测试样本并非来自第 i 类, 则各个子块的重构误差相对较大, 最终在随机权值下的融合误差矢量均值和反差都相对较大。因此, 根据以上统计特征, 定义决策变量为:

$$J = m + \lambda\sigma \quad (8)$$

式中: m 和 σ 对应任一类别融合误差矢量的均值及方差; λ 为大于零的调节参数。按照公式 (8) 可分别计算各个类别对应的决策变量 J_1, J_2, \dots, J_C , 具有最小值的类别即被判断为测试样本真实目标类别。

图 2 显示了提出方法的基本实施流程。采用图像分块算法对所有训练样本进行处理, 并对每个子块进行单演特征矢量提取。在此基础上, 形成各个子块的字典。对于测试样本, 相应进行分块操作并获得相应的单演特征矢量。基于 SRC 计算重构误差并进行随机加权融合处理, 最终根据不同类别的决策变量获得目标所属类别。

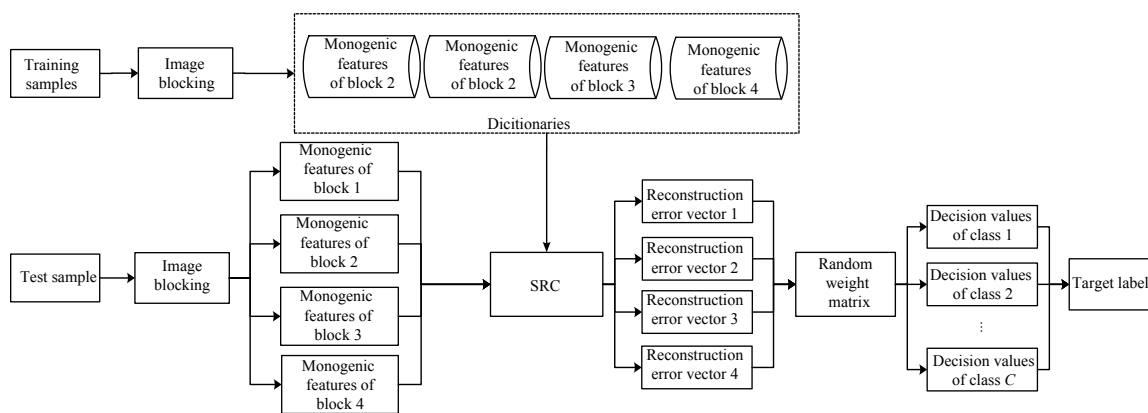


图 2 提出方法实施流程

Fig.2 Procedure of implementation of the proposed method

4 实验结果与分析

4.1 实验设置

MSTAR 数据集由美国 DARPA 和 AFRL 发布, 包括图 3 中的 10 类目标, 图像分辨率 0.3 m, 可据此

设置场景对方法进行分析。共设置 5 类对比方法, 包括参考文献 [2] 基于 Zernike 矩的方法; 参考文献 [11] 中采用单演信号的方法 (记为 Mono); 参考文献 [13] 中基于属性散射中心匹配的方法 (记为 ASC Matching); 参考文献 [22] 中的全卷积神经网络 (A-ConvNet, 记为



图 3 MSTAR 目标图示

Fig.3 Illustration of MSTAR targets

CNN1) 方法以及参考文献 [24] 中设计的平移、旋转不变网络 (记为 CNN2)。前三类对比方法侧重于特征提取, 通过不同类型的特征提高 SAR 目标识别性能; 后两种对比方法则是档期最为流行的深度学习方

识别样本数占总样本数的比例, 统计 10 类目标的 $P_{av}=99.32\%$, 充分显示了提出方法的有效性。表 2 对比各类方法在标准操作条件下的识别性能。各类方

4.2 结果与讨论

4.2.1 测试条件 1

测试条件 1 为标准操作条件, 整体难度相对较小。表 1 为测试条件 1 的相关设置, 包括了图 3 所有目标。训练和测试样本分别为 17° 和 15° 下的 SAR 图像集。测试样本和训练样本来自相同的目标及型号。图 4 显示了文中方法在标准操作条件下的分类混淆矩阵。10 类目标对应的正确识别率对应于对角线元素, 均高于 98.5%。定义平均识别率 P_{av} 为正确




图 4 测试条件 1 下所提方法结果

Fig.4 Results of the proposed method under test condition 1

表 1 测试条件 1 相关设置

Tab.1 Relevant setup for test condition 1

Type	Training		Test	
	Depression	Scale	Depression	Scale
BMP2		232		193
BTR70		232		194
T72		231		194
T62		297		271
BRDM2	17°	296	15°	272
BTR60		255		193
ZSU23/4		297		272
D7		297		273
ZIL131		297		272
2S1		297		271

表 2 测试条件 1 下的结果

Tab.2 Results under test condition 1

Method	P_{av}
Proposed	99.32%
Zernike	98.12%
Mono	98.64%
ASC Matching	98.32%
CNN1	99.08%
CNN2	99.12%

法在标准操作条件下的平均识别率均高于 98%，也反映了标准操作条件下的识别问题相对简单。所提方法在当前条件下可以取得最高的识别率，显示了方法的优势。

4.2.2 扩展操作条件

由于实际场景的复杂性，目标自身、背景环境以及传感器等要素都可能发生变化，因此扩展操作条件更为常见。后续设置 3 类典型扩展操作条件进行测试。

(1) 测试条件 2

测试条件 2 为型号差异，表 3 为相关试验数据和

设置。其中，BMP2 和 T72 采用不同型号的样本分别用于训练和分类。表 4 列出了不同方法在此时的识别率。对比测试条件 1，各方法受到型号差异影响，性能出现下降。对于基于深度洗的 CNN1 和 CNN2 方法，由于存在的型号差异，最终平均识别率下降最为显著。文中方法对测试 SAR 图像进行分块处理，并且分区进行局部分析，因此有利于充分考察由于型号差异带来的局部图像变化。从识别结果上可以看出，文中方法的识别率更高，表明其对于型号差异的稳健性。

表 3 测试条件 2 相关设置

Tab.3 Relevant setup for test condition 2

Type	Training			Test		
	Depression/(°)	Configuration	Scale	Depression/(°)	Configuration	Scale
BMP2	17	9 563	233	15	9 566 c21	196
BTR70	17	c71	233	15	c71	196
T72	17	132	232	15	812 s7	195 191

表 4 测试条件 2 下的结果

Tab.4 Results under test condition 2

Method	Pav
Proposed	98.46%
Zernike	96.82%
Mono	97.82%
ASC Matching	98.02%
CNN1	96.54%
CNN2	97.02%

(2) 测试条件 3

测试条件 3 为俯仰角差异，表 5 给出了相应的训练和测试集。采用 17°俯仰角样本对算法进行训练，分别采用 30°和 45°俯仰角作为测试样本，考察不同俯仰角差异条件下的影响。表 6 显示不同方法的结果。在 30°时，俯仰角差异造成的影响相对不大，各方法仍能保持 94% 以上的识别率。但在 45°时，俯仰角差异带来的影响十分显著，各方法平均识别率大幅度降低，说明此时俯仰角差异带来了较大的 SAR 图像差异。与型号差异的情形类似，CNN1 和 CNN2 方法

表 5 测试条件 3 相关设置

Tab.5 Relevant setup for test condition 3

Type	Training		Test	
	Depression	Scale	Depression/(°)	Scale
2S1		288	30 45	285 302
BDRM2	17°	289	30 45	284 302
ZSU23/4		289	30 45	287 302

表 6 测试条件 3 下的结果

Tab.6 Results under test condition 3

Method	Pav	
	30°	45°
Proposed	97.12%	73.63%
Zernike	94.82%	68.24%
Mono	96.35%	70.92%
ASC Matching	96.72%	71.36%
CNN1	95.82%	66.74%
CNN2	96.24%	67.56%

的性能下降最为显著。文中方法通过图像分块匹配以及多权值的融合以及统计分析,可以更好地分析目标的局部变化,进而通过统计分析获得可靠的决策结果。

4.2.3 测试条件 4

测试条件 4 为噪声干扰。当测试样本处于较低的信噪比 (SNR) 时,其与高信噪比的测试样本会出现较大的差异,导致识别问题难度显著增加。原始 MSTAR 测试样本于训练样本来自相近的信噪比,不能直接用于测试 SAR 目标识别方法的噪声稳健性。为此,文中首先通过噪声生成的方式获得含噪测试集,验证方法的噪声为减小。图 5 显示不同方法的结果,所提方法随着噪声加权可以保持更为稳定的性能。随着测试样本的信噪比降低,基于深度学习的 CNN1 和 CNN2 方法性能下降较为显著。散射中心匹配方法在噪声干扰条件下性能相对稳健,主要是属性散射中心提取过程中有效剔除了噪声的印象。图 5 所示结果充分验证了文中方法在噪声干扰下的性能优势。

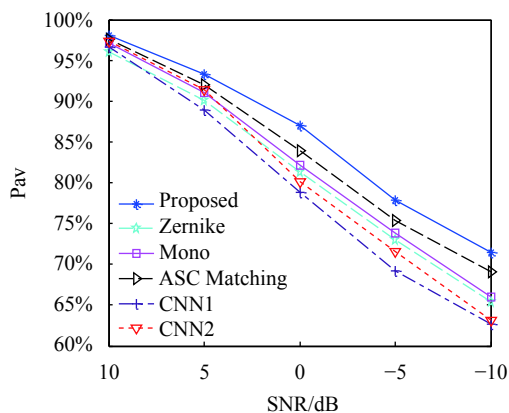


图 5 测试条件 4 下的结果

Fig.5 Results under test condition 4

5 结 论

论文提出基于分块匹配的 SAR 图像目标识别方法。对原始 SAR 图像进行 4 分块处理,各个子块体现不同方向的局部特性。采用单演信号描述各个子块的频谱特性以及局部特征并构造特征矢量。对 4 个子块的单演特征矢量分别采用 SRC 进行分类进而获得重构误差矢量。基于随机权值矩阵对 4 个子

块的重构误差矢量进行加权融合。通过对多组权值矢量下的融合结果进行统计分析设计决策变量,获得样本类别。实验在 MSTAR 数据集设置 4 种测试条件,包括标准操作条件和扩展操作条件。实验结果表明文中方法相比现有方法具有较为显著的性能优势。

参考文献:

- [1] Wu Wenda, Zhang Bao, Hong Yongfeng, et al. Design of co-aperture antenna for airborne infrared and synthetic aperture radar [J]. *Chinese Optics*, 2020, 13(3): 595-604. (in Chinese)
- [2] Amoon M, Rez-radai G A. Automatic target recognition of synthetic aperture radar (SAR) images based on optimal selection of Zernike moment features [J]. *IET Computer Vision*, 2014, 8(2): 77-85.
- [3] Fu Fancheng. SAR target recognition based on target region matching [J]. *Electronics Optics & Control*, 2018, 25(4): 37-40. (in Chinese)
- [4] Xie Qing, Zhang Hong. Multi-level SAR image enhancement based on regularization with application to target recognition [J]. *Journal of Electronic Measurement and Instrumentation*, 2018, 32(9): 157-162. (in Chinese)
- [5] 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.
- [6] 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.
- [7] Mishra A K, Motaung T. Application of linear and nonlinear PCA to SAR ATR[C]//Radioelektronika, 2015: 1-6.
- [8] Han Ping, Wang Huan. Research on the synthetic aperture radar target recognition based on KPCA and sparse representation [J]. *Journal of Signal Processing*, 2013, 29(13): 1696-1701. (in Chinese)
- [9] 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): 1376-1385.
- [10] Li Shuai, Xu Yuelei, Ma Shiping, et al. SAR target recognition using wavelet transform and deep sparse autoencoders [J]. *Video Engineering*, 2014, 38(13): 31-35. (in Chinese)
- [11] 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.
- [12] Chang M, You X, Cao Z. Bidimensional empirical mode

- decomposition for SAR image feature extraction with application to target recognition [J]. *IEEE Access*, 2019, 6: 7, 135720-135731.
- [13] Ding Baiyuan, Wen Gongjian, Yu Liansheng, 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)
- [14] 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.
- [15] Liu Yang. Target recognition of SAR images based on multi-level matching of attributed scattering centers [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(11): 192-198. (in Chinese)
- [16] Hao Yan, Bai Yanping, Zhang Xiaofei. Synthetic aperture radar target recognition based on KNN [J]. *Fire Control & Command Control*, 2018, 43(9): 113-115, 120. (in Chinese)
- [17] Liu Changqing, Chen Bo, Pan Zhouhao, et al. Research on target recognition technique via simulation SAR and SVM classifier [J]. *Journal of CAEIT*, 2016, 11(3): 257-262. (in Chinese)
- [18] 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.
- [19] Xing X W, Ji K F, Zou H X, et al. Sparse representation based SAR vehicle recognition along with aspect angle [J]. *The Scientific World Journal*, 2014, 834140: 1-10.
- [20] Zhang L, Tao Z W, Wang B J. SAR image target recognition using kernel sparse representation based on reconstruction coefficient energy maximization rule[C]//IEEE ICASSP, 2016: 2369-2373.
- [21] Tan Cuimei, Xu Tingfa, Ma Xu, et al. Graph-spectral hyperspectral video restoration based on compressive sensing [J]. *Chinese Optics*, 2018, 11(6): 949-957. (in Chinese)
- [22] 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.
- [23] Zhang Panpan, Luo Haibo, Ju Moran, 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)
- [24] Xu Ying, Gu Yu, Peng Dongliang, 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)