

引用格式:王源源.基于单演信号多重集典型相关分析的 SAR 目标识别方法[J].电光与控制,2019,26(10):7-11,29. 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.

## 基于单演信号多重集典型相关分析的 SAR 目标识别方法

王源源

(电子科技大学成都学院,成都 611731)

**摘要:**提出了一种基于多层次单演信号特征的合成孔径雷达(SAR)图像目标识别方法。为了充分利用多层次单演信号特征的鉴别力,采用多重集典型相关分析(MCCA)分别对各个层次上的局部幅度、局部相位以及局部方位进行融合。融合得到的特征矢量包含了不同层次之间各类特征的内在相关性。在分类阶段,采用联合稀疏表示(JSR)对3类特征融合得到的特征矢量进行联合决策,进一步发掘不同特征之间的内在相关性。最后,根据联合稀疏表示输出的重构误差判定目标类别。基于MSTAR数据集对提出方法进行了性能测试,结果证明了其有效性。

**关键词:**合成孔径雷达;目标识别;单演信号;多重集典型相关分析;联合稀疏表示

**中图分类号:** TP753 **文献标志码:** A **doi:**10.3969/j.issn.1671-637X.2019.10.002

## SAR Target Recognition Based on Monogenic Features via Multiset Canonical Correlation Analysis

WANG Yuan-yuan

(Chengdu College, University of Electronic Science and Technology of China, Chengdu 611731, China)

**Abstract:** A Synthetic Aperture Radar (SAR) target recognition method based on the multi-scale monogenic features is proposed. To fully exploit the discrimination capability of the multi-scale monogenic features, the Multiset Canonical Correlation Analysis (MCCA) is used to fuse the different types of monogenic features from different scales including local amplitude, local phase, and local orientation, which results in a feature vector containing the internal correlations of each kind of feature. In the classification stage, the Joint Sparse Representation (JSR) is employed to classify the feature vector fused by the three kinds of features, and to further exploit the internal correlations of different types of features. Finally, the target type is decided according to the reconstruction errors from JSR. Experiments are conducted on the Moving and Stationary Target Acquisition and Recognition (MSTAR) dataset to evaluate the performance of the proposed method, and the results prove the validity of the proposed method.

**Key words:** Synthetic Aperture Radar (SAR); target recognition; monogenic signal; Multiset Canonical Correlation Analysis (MCCA); Joint Sparse Representation (JSR)

### 0 引言

随着合成孔径雷达(SAR)传感器的不断进步以及成像技术的不断发展,海量 SAR 图像的解译显得尤为重要。作为战场情报获取的重要手段之一,SAR 图像自动目标识别(ATR)技术自 20 世纪 90 年代以来得到广泛研究<sup>[1-2]</sup>。具体的 SAR 目标识别方法主要涉及到

特征提取和分类器设计两个关键步骤。前者通过适当的图像处理、数学分析或信号处理的方式获取原始 SAR 图像的特性描述。常用于 SAR 目标识别的特征包括几何形状特征(如目标轮廓<sup>[3]</sup>、目标区域<sup>[4]</sup>),变换域特征(如主成分分析(PCA)、线性鉴别分析<sup>[5]</sup>(LDA))以及散射中心特征(如属性散射中心<sup>[6-7]</sup>)等。分类器则是为提取的特征设计合理的决策机制,通过匹配待识别样本的特征以及训练样本的特征估计其类别。大量的高性能分类器已在 SAR 目标识别中得到应用,如支持向量机<sup>[8]</sup>(SVM)、稀疏表示分类器<sup>[9]</sup>(SRC)、卷积神经网络<sup>[10-11]</sup>(CNN)等。

DONG 等将单演信号引入 SAR 图像特征提取及目

收稿日期:2018-10-31

修回日期:2019-07-12

基金项目:四川省高校计算机基础教育研究会“教育教学改革研究”(2015-09)

作者简介:王源源(1984—),男,河南南阳人,硕士,讲师,研究方向为智能计算、嵌入式系统、图像识别与处理。

标识别中,并设计了多种分类机制验证其有效性<sup>[12-15]</sup>。单演信号特征直接基于 SAR 图像的复数据进行处理,全面分析了原始图像的幅度、相位以及局部纹理特征。同时,通过 Log-Gabor 滤波器的预处理可以得到多分辨率的谱特征,从而更为充分地描述原始目标。文献[12]中采用决策层融合的方法对各个层次单演信号特征的独立决策结果进行并行融合;为了考察各个层次之间的内在关联,文献[13]采用联合稀疏表示(JSR)对3个层次的单演信号特征进行联合决策;文献[14-15]通过流形学习的引入进一步增强了单演信号特征的鉴别力;后续的学者又进一步验证了单演信号特征对于 SAR 目标识别的性能<sup>[16-17]</sup>。这些研究结果均表明了单演信号特征对于 SAR 目标识别具有良好的鉴别力。

本文提出基于多重集典型相关分析<sup>[18-19]</sup>(MCCA)的单演信号特征融合的 SAR 目标识别方法。以往的方法在各个层次上对单演信号的3种特征进行融合,构造特征矢量,这种方法忽略了同一特征在不同层次之间的内在关联。本文方法中,首先采用多重集典型相关分析对各个层次上的局部幅度、局部相位以及局部方位分别进行相关分析,进而构造对应的特征矢量。因此,对于多个层次的单演信号特征,最终可以得到3个特征矢量,分别代表局部幅度、局部相位以及局部方位的特征。在分类阶段,采用联合稀疏表示<sup>[13,20]</sup>对3个融合后的特征进行决策,进一步挖掘不同类型特征之间的内在关联。为了验证本文方法的有效性,基于MSTAR数据集进行了 SAR 目标识别实验并与其他方法进行了对比。

## 1 特征构造

### 1.1 基于单演信号的 SAR 图像特征提取

单演信号是解析信号在高维空间的扩展。特别地,对于图像数据,可以采用二维单演信号进行特性分析<sup>[12]</sup>。二维单演信号是信号自身与其 Riesz 变换相结合的产物。记信号  $f(z)$  的 Riesz 变换为  $f_R(z)$ ,其中,  $z = (x, y)^T$  代表二维坐标。其对应的单演信号  $f_M(z)$  算式为

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

式中,  $i$  和  $j$  均为虚数单位。原始信号及其 Riesz 变换分别构成单演信号的实部和虚部。基于单演信号,可以采用式(2)构造3种特征分类,即局部幅度  $A(z)$ 、局部相位  $\varphi(z)$  和局部方位  $\theta(z)$ ,分别为

$$\begin{cases} A(z) = \sqrt{f(z)^2 + |f_R(z)|^2} \\ \varphi(z) = \arctan 2(|f_R(z)|, f(z)) \in (-\pi, \pi] \\ \theta(z) = \arctan 2(f_y(z)/f_x(z)) \in (-\frac{\pi}{2}, \frac{\pi}{2}] \end{cases} \quad (2)$$

式中,  $f_x(z)$  和  $f_y(z)$  分别对应单演信号的  $i$ -虚部和  $j$ -虚部。

3种单演信号特征从不同方面描述了原始 SAR 图像的特性。具体地,局部幅度  $A(z)$  反映了原始 SAR 图像的灰度分布;局部相位  $\varphi(z)$  和局部方位  $\theta(z)$  则体现了原始图像的几何结构信息。因此,联合3种特征可以实现对原始图像更为充分的描述。考虑到实际信号均具有无限的频谱(有限的长度),一般在进行单演信号分析之前先采用 Log-Gabor 滤波器对原始图像进行预处理。通过在不同层次进行滤波,最终可以得到多个层次的单演信号特征。本文参照文献[12]中的参数设置,获取3个层次的单演信号特征,如图1所示。




图1 基于单演信号的 SAR 图像特征提取示意  
Fig. 1 Illustration of SAR image feature extraction based on monogenic signal

由图1可知,不同层次的单演信号特征对于描述原始图像具有良好的互补性,对它们进行综合利用有望提高后续的分类性能。

### 1.2 基于多重集典型相关分析的特征融合

多重典型相关分析<sup>[18-19]</sup>是典型相关分析(CCA)在多个随机变量上的应用,可以同时分析多个随机变量的内在相关性。对于  $n$  个随机变量  $X_1, X_2, \dots, X_n$ , 它们的维数分别为  $m_i (i=1, 2, \dots, n)$ 。设定  $m_1$  最小且每个随机变量对应的样本均经过去均值中心化,多重集典型相关分析的准则函数为

$$J_{\text{MCCA}}(\alpha_1, \alpha_2, \dots, \alpha_n) = \frac{\sum_{i=1}^n \sum_{j=1}^n \alpha_i^T S_{ij} \alpha_j}{\sqrt{\sum_{i=1}^n \alpha_i^T S_{ii} \alpha_i}} \quad (3)$$

式中,  $S_{ij} = E(X_i X_j^T)$  代表随机变量  $X_i$  与  $X_j$  之间的互协方差矩阵。式(3)的最大化问题等效于

$$\begin{aligned} & \max_{\alpha_1, \alpha_2, \dots, \alpha_n} \sum_{i=1}^n \sum_{j=1}^n \alpha_i^T S_{ij} \alpha_j \\ & \text{s. t. } \sum_{i=1}^n \alpha_i^T S_{ii} \alpha_i = 1. \end{aligned} \quad (4)$$

采用 Lagrange 乘子法对式(4)中的优化问题求解得

$$\begin{pmatrix} S_{11} & \cdots & S_{1n} \\ \vdots & & \vdots \\ S_{n1} & \cdots & S_{nn} \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} = \begin{pmatrix} \lambda_1 S_{11} & \cdots & 0 \\ \vdots & & \vdots \\ 0 & \cdots & \lambda_n S_{nn} \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} \quad (5)$$

根据式(5)的求解结果得到变换矩阵  $A = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ , 其中:

$$\begin{cases} \alpha_1 = [\alpha_{11}, \alpha_{12}, \dots, \alpha_{1m_1}]_{m_1 \times m_1} \\ \alpha_2 = [\alpha_{21}, \alpha_{22}, \dots, \alpha_{2m_2}]_{m_2 \times m_2} \\ \vdots \\ \alpha_n = [\alpha_{n1}, \alpha_{n2}, \dots, \alpha_{nm_n}]_{m_n \times m_n} \end{cases} \quad (6)$$

由此得到各个随机变量  $X_i$  对应的投影方向。本文采用

$$Z = \alpha_1^T X_1 + \alpha_2^T X_2 + \dots + \alpha_n^T X_n \quad (7)$$

的叠加形式获得各个随机变量融合后的结果, 该结果能够保持各个随机变量之间的内在相关性。

本文通过多重典型相关分析对各个层次上的单演信号特征进行融合。具体而言, 对于每个层次上的某一特征, 首先, 采用矢量化以及降采样的方式获得对应的特征矢量; 然后, 基于所有训练样本在 3 个不同层次上的特征矢量进行多重典型相关分析并得到融合后的特征矢量; 最终获得 3 个特征矢量, 分别对应于原始图像的局部幅度、局部相位以及局部方位。

## 2 联合单演信号特征的目标识别方法

### 2.1 联合稀疏表示

联合稀疏表示<sup>[13,20]</sup>是稀疏表示算法在多任务学习领域的应用。本文将用于 3 种单演信号特征的联合分类从而挖掘它们之间的内在相关性。记测试样本经过多重集典型相关分析融合后得到的特征  $m_i (i = 1, 2, \dots, n)$  为  $\mathbf{y} = [\mathbf{y}^{(1)} \quad \mathbf{y}^{(2)} \quad \mathbf{y}^{(3)}]$ , 其中  $\mathbf{y}^{(1)}$ ,  $\mathbf{y}^{(2)}$  和  $\mathbf{y}^{(3)}$  分别对应局部幅度、局部相位和局部方位。联合稀疏表示为

$$\mathbf{y}^{(k)} = \mathbf{D}^{(k)} \boldsymbol{\alpha}^{(k)} + \boldsymbol{\varepsilon}^{(k)} \quad k = 1, 2, 3 \quad (8)$$

式中,  $\mathbf{y}^{(k)}$ ,  $\mathbf{D}^{(k)}$ ,  $\boldsymbol{\alpha}^{(k)}$  分别为对应第  $k$  个任务的特征矢量、字典和稀疏表示系数矢量。为了求解式(8)中各个任务的稀疏表示系数矢量, 构造优化过程

$$\min_{\boldsymbol{\beta}} \{g(\boldsymbol{\beta}) = \sum_{k=1}^3 \|\mathbf{y}^{(k)} - \mathbf{D}^{(k)} \boldsymbol{\alpha}^{(k)}\|\} \quad (9)$$

式中,  $\boldsymbol{\beta} = [\boldsymbol{\alpha}^{(1)} \quad \boldsymbol{\alpha}^{(2)} \quad \boldsymbol{\alpha}^{(3)}]$  代表稀疏系数矩阵。

式(9)在认为各个任务独立的条件下最小化 3 种特征的重构误差之和。而实际上, 不同特征之间往往存在一定的关联。为了体现这种关联性, 在目标函数中对稀疏系数矩阵进行  $\ell_1/\ell_2$  范数约束, 即

$$\min_{\boldsymbol{\beta}} g(\boldsymbol{\beta}) + \lambda \|\boldsymbol{\beta}\|_{2,1} \quad (10)$$

式中,  $\|\cdot\|_{2,1}$  代表  $\ell_1/\ell_2$  范数。本文利用文献[13]中的

求解算法获得稀疏系数矩阵并计算不同类别下 3 类特征的总体重构误差, 进而判定目标类别为

$$\text{identity}(\mathbf{y}) = \min_i \sum_{k=1}^3 \|\mathbf{y}^{(k)} - \mathbf{D}_i^{(k)} \boldsymbol{\alpha}_i^{(k)}\| \quad (11)$$

### 2.2 目标识别流程

本文采用多重集典型相关对 3 个层次上的单演信号特征进行融合并采用联合稀疏表示对融合得到的 3 类特征进行分类。识别方法的具体流程如图 2 所示, 可总结为以下 5 个步骤:

- 1) 提取所有训练样本 3 个层次上的单演信号特征;
- 2) 采用多重集典型相关分别处理 3 个特征分量, 计算各自的投影矩阵;
- 3) 基于训练样本融合得到的 3 类特征构造对应的全局字典;
- 4) 提取测试样本的 3 个层次上的单演信号特征并根据投影矩阵获得相应的特征矢量;
- 5) 采用联合稀疏表示对测试样本的 3 类特征矢量进行联合决策, 判定测试样本的目标类别。

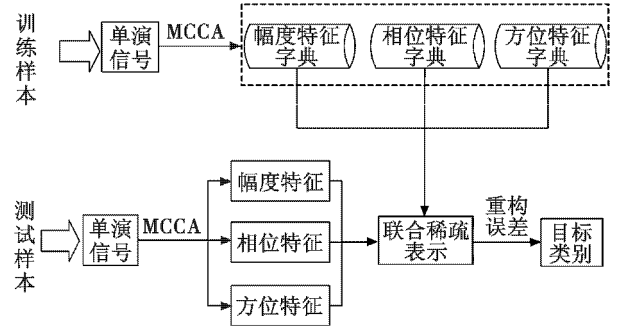


图 2 本文识别方法的基本流程

Fig. 2 Basic procedure of the proposed recognition method

## 3 实验与分析

### 3.1 MSTAR 数据集

采用 MSTAR 数据集对提出的 SAR 目标识别方法进行性能测试。该数据集利用 X 波段机载平台获取了 10 类地面静止军事目标的 SAR 图像。各类目标的名称以及对应的光学图像如图 3 所示。原始 SAR 图像的分辨率为 0.3 m。该数据集包含了多种操作条件, 如标准操作条件、型号变化以及俯仰角变化等扩展操作条件。因此, 利用该数据集可以对 SAR 目标识别方法的性能进行全面测试。

实验中选用了几类对比方法, 包括文献[8]中基于 SVM 的方法、文献[9]中基于 SRC 的方法以及文献[10]中基于 CNN 的方法。同时, 将本文方法与 DONG 等提出的基于单演信号特征的方法进行对比, 包括文献[12]的并行决策融合方法(记为 Mono1)以及文献[13]中基于联合稀疏表示的方法(记为 Mono2)。




图 3 十类目标的光学图像

Fig. 3 The optical images of ten kinds of targets

### 3.2 实验结果与分析

#### 3.2.1 标准操作条件

首先在标准操作条件下对本文方法的识别性能进行测试。本文实验中的 10 类目标的训练和测试样本如表 1 所列。其中,训练样本来自于 17°俯仰角,测试样本来自于 15°俯仰角,且两者具有完全相同的型号。图 4 显示了所提方法对这 10 类目标的混淆矩阵。各类方法的识别率均达到 98% 以上,最终得到的平均识别率达到 99.24%,这一结果充分说明了本文方法在标准操作条件下的高效性。

表 1 标准操作条件下的训练和测试样本

Table 1 Training and test samples under the standard operating condition

类别	训练样本(17°俯仰角)	测试样本(15°俯仰角)
BMP2	233 (Sn_9563)	195 (Sn_9563)
BTR70	233 (Sn_c71)	196 (Sn_c71)
T72	232 (Sn_132)	196 (Sn_132)
T62	299	273
BRDM2	298	274
BTR60	256	195
ZSU23/4	299	274
D7	299	274
ZIL131	299	274
2S1	299	274




图 4 本文方法在标准操作条件下对 10 类目标的混淆矩阵

Fig. 4 Confusion matrix of the proposed method on the 10 targets under standard operating condition

表 2 对比了各类方法在标准操作条件下的识别性能。

表 2 标准操作条件下各类方法的识别性能

Table 2 Recognition performance of different methods under standard operating condition

方法类型	平均识别率/%	时间消耗/ms
本文方法	99.24	63.7
SVM	97.88	54.3
SRC	97.36	58.8
CNN	99.08	61.5
Mono1	98.26	86.5
Mono2	98.47	68.8

经过对比,本文方法的平均识别率最高,验证了其优越性。CNN 方法的识别率略低于所提方法而优于其他方法,说明了卷积神经网络的优势。相比 SVM 和 SRC 两类方法,基于单演信号特征的 Mono1 和 Mono2 方法识别性能更高,体现了单演信号特征对于 SAR 目标识别的鉴别力。对比 3 类基于单演信号特征的方法,本文方法的优势较为明显,说明了进行多重集典型相关分析有利于充分利用多层次的单演信号特征提高目标识别性能。

表 2 同时给出了各类方法的识别效率,即识别单幅 MSTAR 图像所需要的时间消耗。由于涉及到单演信号的特征构造,本文方法的效率略低于 SVM, SRC 和 CNN。但与同样采用单演信号特征的 Mono1 和 Mono2 方法相比,本文方法的效率更高。综合考虑分类精度以及效率,本文方法在标准操作条件下仍然具有一定的优势。

#### 3.2.2 型号变化

同一目标的不同型号往往存在一定的结构差异,这导致它们的 SAR 图像存在一定的变化。为了测试本文方法在型号变化条件下的识别性能,本文实验设置如表 3 所示的训练和测试样本。其中,BMP2 和 T72 两类目标的测试型号并不包含在对应的训练集中。表 4 对比了各类方法在型号变化条件下的识别性能。本文方法取得了最高的平均识别率,验证了其对于型号变化的有效性。同时,基于单演信号特征的方法的平均识别率高于其他方法,说明了多层次的单演信号特征在型号变化条件下可以保持更强的稳健性。

表 3 型号变化条件下的训练和测试样本

Table 3 Training and test samples under configuration variance

类别	训练样本	测试样本
BMP2	233 (Sn_9563)	196 (Sn_9566) 196 (Sn_c21)
BTR70	233 (Sn_c71)	196 (Sn_c71)
T72	232 (Sn_132)	195 (Sn_812) 191 (Sn_s7)



表 4 型号变化条件下各类方法的识别性能

**Table 4 Recognition performance of different methods under configuration variance** %

方法类型	平均识别率	方法类型	平均识别率
本文方法	95.42	CNN	93.96
SVM	92.58	Mono1	94.27
SRC	92.14	Mono2	95.03

3.2.3 俯仰角变化

不同俯仰角下采集的 SAR 图像具有一定的差异。因此,当测试样本的俯仰角与训练样本存在较大的差异时,正确识别的难度较大。为了验证本文方法对于俯仰角变化的稳健性,设置如表 5 所示的训练和测试样本。其中,训练样本来自于 17°俯仰角,测试样本分别来自于 30°和 45°俯仰角。各类方法在不同俯仰角下的平均识别率如表 6 所列。在 30°俯仰角时,各类方法均保持了较高的识别率,说明此时测试样本与训练样本的相关性仍然较高;在 45°俯仰角时,各类方法的识别性能均出现了剧烈下降,说明此时测试样本与训练样本存在较大的差异。对比而言,本文方法在 2 个俯仰角下均保持了最高的平均识别率,证明其对于俯仰角变化的稳健性。

表 5 俯仰角变化条件下训练与测试样本

**Table 5 Training and test samples under pitch angle variance**

	俯仰角/(°)	2S1	BRDM2	ZSU23/4
训练样本	17	299	298	299
测试样本	30	288	287	288
	45	303	303	303

表 6 俯仰角变化条件下各类方法的平均识别率

**Table 6 Average recognition rate of different methods under pitch angle variance** %

方法类型	俯仰角		方法类型	俯仰角	
	30°	45°		30°	45°
本文方法	98.43	72.12	CNN	98.17	63.48
SVM	96.72	63.46	Mono1	97.69	68.52
SRC	96.08	64.14	Mono2	98.04	70.17

4 结束语

本文提出基于多重集典型相关分析的多层次单演信号融合及 SAR 目标识别方法。通过多重集典型相关分析获得不同层次上 3 类单演信号特征的相关表示,从而更为充分地发掘它们的内在鉴别力。采用联合稀疏表示对 3 类单演信号的融合特征进行决策判定目标类别。基于 MSTAR 数据集分别在标准操作条件、型号变化以及俯仰角变化条件下对本文方法进行了全面测试,实验结果证明了本文方法对于 SAR 目标识别的有效性。

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] 文贡坚,朱国强,殷红成,等.基于三维电磁散射参数化模型的 SAR 目标识别方法[J].雷达学报,2017,6(2):115-135.

[3] ANAGNOSTOPOULOS G C. SVM-based target recognition from synthetic aperture radar images using target region outline descriptors [J]. Nonlinear Analysis, 2009, 71(12): 2934-2939.

[4] AMOON M, REZAI-RAD 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.

[5] MISHRA A K. Validation of PCA and LDA for SAR ATR [C]//IEEE TENCON, 2008:1-6.

[6] 丁柏圆,文贡坚,余连生,等.属性散射中心匹配及其在 SAR 目标识别中的应用[J].雷达学报,2017,6(2): 157-166.

[7] 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.

[8] ZHAO Q, PRINCIPE J C. Support vector machines for SAR automatic target recognition [J]. IEEE Transactions on Aerospace and Electronic Systems, 2001, 37(2): 643-654.

[9] THIAGARAJAN J J, RAMAMURTHY K N, KNEE P, et al. Sparse representations for automatic target classification in SAR images[C]//The 4th International Symposium on Communications, Control and Signal Processing (ISCCSP), 2010:1-4.

[10] 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.

[11] DING J, CHEN B, LIU H W, et al. Convolutional neural network with data augmentation for SAR target recognition [J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(3):364-368.

(下转第 29 页)

## 参 考 文 献

- [1] 徐诚,黄大庆. 无人机光电侦测平台目标定位误差分析[J]. 仪器仪表学报,2013,34(10):2265-2270.
- [2] 谭安胜,朱青松,王新为,等. 舰载无人机双机无源定位有效区域分析模型[J]. 电光与控制,2015,22(9):1-6.
- [3] 刘志阳,江涛. 无人机多目标侦察航迹规划方法[J]. 电光与控制,2018,25(8):49-53.
- [4] 孙辉,李志强,张建华,等. 机载光电平台目标交会定位[J]. 中国光学,2015,8(6):988-995.
- [5] 姚新. 无人机提高目标定位精度方法研究[J]. 舰船电子工程,2011,31(10):56-59.
- [6] 徐诚,黄大庆. 一种小型无人机无源目标定位方法及精度分析[J]. 仪器仪表学报,2015,36(5):1115-1122.
- [7] 张岩,李建增,李德良,等. 基于景象匹配的无人机侦察视频快速配准方法[J]. 电光与控制,2017,24(5):30-35.
- [8] 贺若飞,田雪涛,刘宏娟,等. 基于蒙特卡罗卡尔曼滤波的无人机目标定位方法[J]. 西北工业大学学报,2017,35(3):435-441.
- [9] 施丽娟,熊智,柏青青,等. 无人机多点测距目标定位算法及其误差研究[J]. 航空计算技术,2015,45(4):57-60.
- [10] 宋卫红,楼琳,李少敏,等. 基于总体最小二乘的多测距融合定位模型[C]//第九届中国卫星导航学术年会,2018:102-106.
- [11] 李涛,屈也频,梅风华. 基于总体最小二乘的多基地声呐系统定位算法[J]. 探测与控制学报,2015,37(3):82-85.
- [12] 吴晓平,顾治华,舒红波,等. 一种线性最小二乘法的声源目标精确定位方法[J]. 声学学报,2016,41(1):87-93.
- (上接第 11 页)
- [12] DONG G G, KUANG G Y. Classification on the monogenic scale space; application to target recognition in SAR images[J]. IEEE Transactions on Image Processing, 2015, 24(8):2527-2539.
- [13] 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 in Applied Earth Observations and Remote Sensing, 2015, 8(7):3316-3328.
- [14] DONG G G, KUANG G Y. Target recognition in SAR images via classification on Riemannian manifolds[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(1):199-203.
- [15] DONG G G, KUANG G. SAR target recognition via sparse representation of monogenic signal on Grassmann manifold[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(3):1-12.
- [16] NING C, LIU W B, ZHANG G, et al. Enhanced synthetic aperture radar automatic target recognition method based on novel features[J]. Applied Optics, 2016, 55(31):8893-8904.
- [17] ZHOU Z, WANG M, CAO Z J, et al. SAR image recognition with monogenic scale selection-based weighted multi-task joint sparse representation[J]. Remote Sensing, 2018, 10(4):504.
- [18] PENG J, 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.
- [19] 邱爱昆,朱嘉钢. 基于集成学习的多重集典型相关分析方法[J]. 计算机工程与应用,2017,53(6):162-169.
- [20] JI S H, DUNSON D, CARIN L. Multitask compressive sensing[J]. IEEE Transactions on Signal Processing, 2009, 57(1):92-106.