光电技术及应用

DOI：10.16818/j.issn1001－5868.2021070105

自适应核协同表示在SAR目标识别中的应用

刘苗苗[1*]，蒋宇帆[2]，邢钉凡[2]

（1. 重庆光电技术研究所，重庆 400060；2. 驻重庆地区军代局，重庆 400060）

摘　要： 针对合成孔径雷达(Synthetic Aperture Radar，SAR)目标识别中方位角差距大的训练样本之间存在干扰的问题，对传统协同表示字典进行了改进，得到更适应于当前测试样本且能够降低弱相关原子对系统影响的自适应字典，基于此提出了一种自适应原子选择的核函数变换协同表示算法，并在美国DARPA中的运动和静止目标获取与识别计划公开发布的SAR图像数据库上进行了验证实验。实验结果表明，相较于基于全部训练样本字典的核协同表示模型，基于自适应原子选择的核协同表示方法降低了干扰原子的不良影响，提高了对SAR目标识别的可靠性和鲁棒性。

关键词： 合成孔径雷达；自动目标识别；自适应原子选择；多特征；核协同表示

中图分类号： TN959　**文章编号：** 1001－5868(2021)06－0891－06

Application of Kernel Function Transformation Collaborative Representation in SAR Target Recognition

LIU Miaomiao[1]，JIANG Yufan[2]，XING Dingfan[2]

（1. Chongqing Optoelectronics Research Institute，Chongqing 400060，CHN；
2. Military Representative Bureau in Chongqing，Chongqing 400060，CHN）

Abstract： Aiming at the disturbance of training samples with large aspect gap in SAR target recognition，a kernel function transformation collaborative algorithm based on adaptive atom selection is proposed. This method improves the representation dictionary in the traditional collaborative representation，and gets the adaptive dictionary which is more adaptable to the current test samples and can reduce the influence of the unrelated atoms to the system. The experiments of SAR target recognition based on MSTAR datasets were carried out. The experimental results show that the kernel collaborative representation based on adaptive atom selection is more effective than the kernel collaborative representation model based on all training sample dictionary，which reduces the harmful effect of the interference atoms and further improves the reliability and robustness of the system.

Key words： synthetic aperture radar；automatic target recognition；adaptive atom selection；multi-feature；kernel collaborative representation

0　引言

合成孔径雷达(Synthetic Aperture Radar，SAR)是一种高分辨率成像雷达，其具有全天候、全天时、大测绘带的对地观测数据获取能力[1]。SAR图像是通过合成孔径雷达对感兴趣目标区域进行观测所得，而SAR自动目标识别(SAR Automatic Target Recognition，SAR ATR)就是在SAR捕捉到的场景图像中寻找可能的目标，然后甄别检测到的目标类型[2]。SAR ATR是SAR图像解译的核心与关键，已成为各国竞相研究的重点领域。

收稿日期：2021－07－01.

* **通信作者：**刘苗苗

在各种 SAR ATR 算法中，协同表示(Collaborative Representation，CR)算法一经提出，便受到许多研究者的关注[3-4]。基本的协同表示虽然在 SAR 目标识别领域取得了不错的成果，但是其识别性能仍需提高。最近，机器学习中的核函数变换成为研究热点[5-6]，其不仅使系统避免了因维数过高导致无法计算的问题，而且利用简单的内积运算就解决了低维空间中线性不可分的难题。此外，核函数十分灵活，可以针对具体应用与其他算法相结合，形成多种不同的基于核函数变换的新模型。基于此，将核函数变换与协同表示框架相结合，进一步提高协同表示对 SAR 目标的识别性能，成为一种新的研究思路与方向。

另外，目前协同表示方法均直接采用特征提取后的训练样本作为字典[7-8]，但实际上，训练样本集中的很多样本与当前测试样本都是弱相关的，即这部分弱相关训练样本不仅不能对系统的识别能力做出“贡献”，反而会干扰到识别结果。因此，一个合适有效的字典对于协同表示分类器非常重要。针对上述问题，本文提出一种基于自适应原子选择的多特征核协同表示算法，进一步提高了协同表示对 SAR 目标识别系统的识别性能。

1 字典学习理论概述

字典学习理论来源于压缩感知，之后被广泛应用于图像处理的各个领域，如去噪、聚类、分类等[9]。字典学习算法包含两个阶段：字典构建阶段和利用字典表示样本阶段，大致流程如图 1 所示。

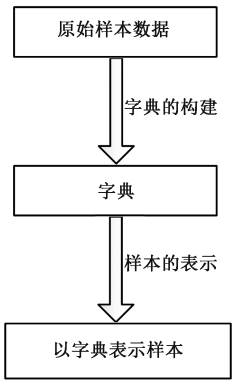


图 1 字典学习的基本过程

对于给定的测试样本集(记作 $\boldsymbol{Y}=\{\boldsymbol{y}_l\}_{l=1}^{C}$)，$\boldsymbol{Y}$ 的每一列表示一个样本。从矩阵分解角度来看，字典学习的过程就是把 $\boldsymbol{Y}$ 矩阵分解成 $\boldsymbol{D}$ 和 $\boldsymbol{B}$ 矩阵：

$$\boldsymbol{Y}\approx\boldsymbol{DB} \tag{1}$$

同时满足约束条件：$\boldsymbol{B}$ 尽可能稀疏，且 $\boldsymbol{D}$ 的每一列是一个归一化向量。则 $\boldsymbol{D}$ 被称之为字典，$\boldsymbol{D}$ 的每一列就是原子，$\boldsymbol{B}$ 被称为系数矩阵。

字典学习已被广泛应用于 SAR 目标识别。齐会娇等[10]结合鉴别字典学习及联合动态稀疏表示模型，提出了一种基于多信息字典学习及稀疏表示的 SAR 目标分类算法。王保云等[11]针对 SAR 目标识别，提出了一种动态字典学习算法，其能够自动调整字典表示性能和尺寸。

然而传统的协同表示中所用字典往往都只是对原始训练样本做简单特征提取而得到。实际上，对当前未分类测试样本进行识别时，训练样本集中的大部分样本都是与其弱相关的，这部分弱相关原子必定会对最终的识别结果造成不良影响。不难看出，合适有效的字典对于协同表示分类器非常重要。

2 基于 Tikhonov 正则化的单特征核函数协同表示模型

核函数变换方法可以通过简单的内积运算解决低维空间中线性不可分的难题，在模式识别中具有独特优势[12]。基于 Tikhonov 正则化的协同表示(Collaborative Representation-based Classification with Tikhonov Regularization，CRT)方法则是将正则化项由基本协同表示模型中的 $\|\boldsymbol{\beta}_l^*\|_2^2$ 乘以 Tikhonov 偏置矩阵，变为 $\|\boldsymbol{\Gamma}_{l,y}\boldsymbol{\beta}_l^*\|_2^2$。将核函数变换与 CRT 算法相融合，结合两者优点，即为基于 Tikhonov 正则化的单特征核函数协同表示(Kernel Collaborative Representation-based Classification with Tikhonov Regularization，KCRT)算法，Li 等指出此算法可以达到很好的模式识别效果[13]。

对于单特征 KCRT 算法，即：首先分别提取出 SAR 图像目标训练样本和测试样本的某种特征数据。其次，选择合适样本的核函数，这里，根据 SAR 图像样本数较大的特性选择高斯核函数。这样就可以用所有可利用的训练样本线性表示出测试样本 $\boldsymbol{y}$，新的权重系数向量 $\boldsymbol{\beta}'$ 就可以表示成下列二范数的组合形式：

$$\boldsymbol{\beta}'=\underset{\boldsymbol{\beta}^*}{\operatorname{argmin}}\|\Phi(\boldsymbol{y})-\boldsymbol{\Phi}\boldsymbol{\beta}^*\|_2^2+\xi\|\boldsymbol{\Gamma}_{\Phi(\boldsymbol{y})}\boldsymbol{\beta}^*\|_2^2 \tag{2}$$

这里的映射函数 Φ 表示测试样本到核特征空间的映射：$\boldsymbol{y}\rightarrow\Phi(\boldsymbol{y})\in\mathbb{R}^{M\times 1}$($M\gg m$ 为核函数特征空间的维数)，$\boldsymbol{\Phi}=[\Phi(\boldsymbol{d}_1),\Phi(\boldsymbol{d}_2),\cdots,\Phi(\boldsymbol{d}_n)]\in\mathbb{R}^{M\times n}$。那么，新的 Tikhonov 偏置矩阵 $\boldsymbol{\Gamma}_{\Phi(\boldsymbol{y})}$ 就有

如下形式：

$$\boldsymbol{\Gamma}_{\Phi(\boldsymbol{y})}=\begin{bmatrix}\|\Phi(\boldsymbol{y})-\Phi(\boldsymbol{d}_1)\|_2 & & 0\\ & \ddots & \\ 0 & & \|\Phi(\boldsymbol{y})-\Phi(\boldsymbol{d}_n)\|_2\end{bmatrix} \tag{3}$$

其中，$\|\Phi(\boldsymbol{y})-\Phi(\boldsymbol{d}_i)\|_2=[k(\boldsymbol{y},\boldsymbol{y})+k(\boldsymbol{d}_i,\boldsymbol{d}_i)-2k(\boldsymbol{y},\boldsymbol{d}_i)]^{1/2}$，$i=1,2,\cdots,n$。将权重系数向量 $\boldsymbol{\beta}'$ 展开，用最小二乘法令其偏导为 0，则可得到解：

$$\boldsymbol{\beta}'=(\boldsymbol{K}+\xi^2\boldsymbol{\Gamma}^{\mathrm{T}}_{\Phi(\boldsymbol{y})}\boldsymbol{\Gamma}_{\Phi(\boldsymbol{y})})^{-1}k(\cdot,\boldsymbol{y}) \tag{4}$$

其中，$k(\cdot,\boldsymbol{y})=[k(\boldsymbol{d}_1,\boldsymbol{y}),k(\boldsymbol{d}_2,\boldsymbol{y}),\cdots,k(\boldsymbol{d}_n,\boldsymbol{y})]^{\mathrm{T}}\in\mathbb{R}^{n\times 1}$，而 $\boldsymbol{K}=\boldsymbol{\Phi}^{\mathrm{T}}\boldsymbol{\Phi}\in\mathbb{R}^{n\times n}$ 是元素为 $\boldsymbol{K}_{i,j}=k(\boldsymbol{d}_i,\boldsymbol{d}_j)$ 的 Gram 矩阵。权重向量 $\boldsymbol{\beta}'$ 由分段的 $\boldsymbol{\beta}'_l=\{\boldsymbol{\beta}'_i\mid\forall i\,\mathrm{s.t}\,w_i=l\}\in\mathbb{R}^{n_l\times 1}$ 组成，这里的 w_i 表示第 i 类样本的类标签，$\boldsymbol{\beta}'_l$ 为第 l 类权重子向量。最终，测试样本的类标签由下式判断出：

$$\mathrm{class}(\boldsymbol{y})=\arg\min_{l=1,\cdots,C}\|\boldsymbol{\Phi}_l\boldsymbol{\beta}'_l-\Phi(\boldsymbol{y})\|_2 \tag{5}$$

式中，$\boldsymbol{\Phi}_l=[\Phi(d_{l,1}),\Phi(d_{l,2}),\cdots,\Phi(d_{l,n_l})]$ 表示第 l 类核函数子字典，将上述判决式进一步展开可得：

$$\|\boldsymbol{\Phi}_l\boldsymbol{\beta}'_l-\Phi(\boldsymbol{y})\|_2=\sqrt{k(\boldsymbol{y},\boldsymbol{y})+(\boldsymbol{\beta}'_l)^{\mathrm{T}}\boldsymbol{K}_l\boldsymbol{\beta}'_l-2(\boldsymbol{\beta}'_l)^{\mathrm{T}}k_l(\cdot,\boldsymbol{y})} \tag{6}$$

式中，$\boldsymbol{K}_l$ 是第 l 类样本的 Gram 矩阵，而 $k_l(\cdot,\boldsymbol{y})=[k(d_{l,1},\boldsymbol{y}),k(d_{l,2},\boldsymbol{y}),\cdots,k(d_{l,n_l},\boldsymbol{y})]^{\mathrm{T}}\in\mathbb{R}^{n_l\times 1}$。

3　基于自适应原子选择的核协同表示模型

针对协同表示框架中所用到的字典存在大量冗余干扰信息这一问题，本文对传统的以训练样本为字典的 KCRT 算法做出改进，提出了一种新的自适应原子选择方法，即基于自适应原子选择的核协同表示（Adaptive Atom Selection-based KCRT，AASKCRT）算法，如图 2 所示。

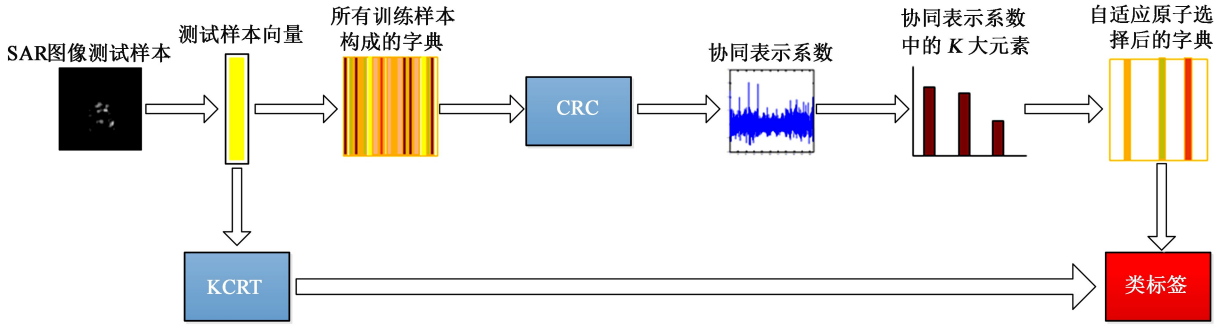


图 2　AASKCRT 算法框图

假设第 i 类训练样本的字典为 $\boldsymbol{D}_i$，测试样本为 $\boldsymbol{y}$，传统的协同表示问题就是在表示系数 $\boldsymbol{\beta}$ 的 l_2-范数约束下，用融合了所有类别训练样本的字典 $\boldsymbol{D}=[\boldsymbol{D}_1,\boldsymbol{D}_2,\cdots,\boldsymbol{D}_N]$ 来编码 $\boldsymbol{y}$，其中 N 表示样本总类别数。协同表示的一般模型如下：

$$\boldsymbol{\beta}=\arg\min_{\boldsymbol{\beta}}\{\|\boldsymbol{y}-\boldsymbol{D}\boldsymbol{\beta}\|_2^2+\vartheta\|\boldsymbol{\beta}\|_2\} \tag{7}$$

其中，ϑ 是规则化参数，规则化项可以让最小均方解保持稳定，根据协同表示模型解的解析表达式，得：

$$\boldsymbol{\beta}=(\boldsymbol{D}^{\mathrm{T}}\boldsymbol{D}+\vartheta\cdot\boldsymbol{I})^{-1}\boldsymbol{D}^{\mathrm{T}}\boldsymbol{y} \tag{8}$$

对于系数向量 $\boldsymbol{\beta}$，很显然，其各元素的大小就对应于相应训练样本的权重。也就是说，$\boldsymbol{\beta}$ 即为训练样本的权重向量。令 $\boldsymbol{\beta}=[\beta_1,\beta_2,\cdots,\beta_n]$，这里的 n_i 表示第 i 类训练样本的个数。显然，系数向量 $\boldsymbol{\beta}$ 中各元素的大小就代表着此元素所对应的训练样本与当前测试样本相关性的强弱。$\boldsymbol{\beta}$ 中某位置元素的值越大，其对应的训练样本与当前测试样本的相关性就越强。为了降低训练样本中那些与测试样本弱相关的原子对系统识别的影响，可以将这些与当前测试样本弱相关的训练样本原子设置为 0，只保留相关性强的那些原子用于构成当前测试样本的新字典。这样，对于每个测试样本，都可以得到一个与之关系最紧密，冗余与噪声最少的新字典。很显然，这种字典是动态的，也就是说，每一个测试样本所对应的字典都不同。假设当前测试样本的协同表示向量为 $\boldsymbol{\beta}=[\beta_1,\beta_2,\cdots,\beta_{n_i}]$，将向量 $\boldsymbol{\beta}$ 中的各个元素按照从大到小的顺序重新排列，可以得到新的向量：

$$\boldsymbol{\beta}''=[\beta_a,\beta_b,\beta_c,\cdots] \tag{9}$$

式中，$a,b,c,\cdots$ 为列标号，也就是训练样本的索引号。对于 $\boldsymbol{\beta}''$，只保留其最大的 K 个值，以及记录这 K 个值所对应的位置 $a,b,c,\cdots$。然后，对原始的训练样本构成的字典 $\boldsymbol{D}=[\boldsymbol{D}_1,\boldsymbol{D}_2,\cdots,\boldsymbol{D}_N]$ 进行改进。将 $\boldsymbol{\beta}$ 中前 K 大值对应位置的训练样本数据保留，其他设置为 0。这里，如果令 $K=2$，当前测试样本的表示字典则变为

$$\boldsymbol{D}''=\begin{bmatrix}0&\cdots&0&d_{1,a}&0&\cdots&0&d_{1,b}&0&\cdots&0\\0&\cdots&0&d_{2,a}&0&\cdots&0&d_{2,b}&0&\cdots&0\\\vdots&\ddots&\vdots&\vdots&\vdots&\ddots&\vdots&\vdots&\vdots&\ddots&\vdots\\0&\cdots&0&d_{m-1,a}&0&\cdots&0&d_{m-1,b}&0&\cdots&0\\0&\cdots&0&d_{m,a}&0&\cdots&0&d_{m,b}&0&\cdots&0\end{bmatrix} \tag{10}$$

这里，$d_{i,j}$ 表示原始字典 $\boldsymbol{D}$ 中第 i 行，第 j 列的元素。而 $\boldsymbol{D}''$便是当前测试样本的协同表示自适应原子选择后的字典。从上述步骤可以发现，基于协同表示的自适应原子选择方法，有效结合了协同表示中表示系数与训练样本的关联性，利用协同表示的特点，减少了非相关原子对当前测试样本的干扰。较传统的协同表示中简单运用训练样本作为字典的方法而言，其字典的构成更加灵活，更加适合于当前测试样本，从而提高了系统的可靠性和鲁棒性。对于新的自适应原子选择后的字典 $\boldsymbol{D}''$，将其和当前测试样本 $\boldsymbol{y}$ 一起输入核函数协同表示框架 $\boldsymbol{\beta}_l=\underset{\boldsymbol{\beta}_l^*}{\operatorname{argmin}}\|\boldsymbol{y}-\boldsymbol{D}''_l\boldsymbol{\beta}_l^*\|_2^2+\lambda\|\boldsymbol{\Gamma}_{l,y}\boldsymbol{\beta}_l^*\|_2^2$。这里，输入核函数协同表示模型中的字典均由基于协同表示的自适应原子选择方法得到，不再由原始的训练样本简单堆砌而成。上述方法即是 AASKCRT 算法。

4 基于多特征自适应原子选择的核协同表示算法流程

由于同一 SAR 图像的不同特征之间存在关联性和互补性，本文结合 SAR 图像的 PCA、小波变换、2DSZMs 特征，进一步提出了一种基于多特征的 AASKCRT(Multi-Feature AASKCRT，MFAASKCRT)算法。

MFAASKCRT 分类器的算法流程如下：

(1)输入所有类的训练样本 $\boldsymbol{X}^{m\times n}$，所有类的测试样本 $\boldsymbol{Y}^{m\times q}$，协同表示模型正则化参数 ϑ，KCRT 模型正则化参数 ξ。

(2)分别提取 $\boldsymbol{X}^{m\times n}$ 的 PCA、小波变换和 2DSZMs 特征，得到三个特征字典：$\boldsymbol{D}^1=\boldsymbol{D}_{\mathrm{PCA}}$，$\boldsymbol{D}^2=\boldsymbol{D}_{\mathrm{wavelet}}$ 以及 $\boldsymbol{D}^3=\boldsymbol{D}_{\mathrm{2DSZMs}}$。

(3)对于一个未分类测试样本 $\boldsymbol{y}\in\boldsymbol{Y}^{m\times q}$，分别提取 $\boldsymbol{y}$ 的 PCA，小波变换和 2DSZMs 特征，得到：$\boldsymbol{y}^1=\boldsymbol{y}_{\mathrm{PCA}}$，$\boldsymbol{y}^2=\boldsymbol{y}_{\mathrm{wavelet}}$ 以及 $\boldsymbol{y}^3=\boldsymbol{y}_{\mathrm{2DSZMs}}$。

(4)将 $\boldsymbol{D}^1$ 和 $\boldsymbol{y}^1$ 输入 CR 分类器，得到协同表示系数向量 $\boldsymbol{\beta}^1$。

(5)将向量 $\boldsymbol{\beta}^1$ 中的元素从大到小排列，取出其中的 K 大值，并且记住该 K 大值的位置。

(6)保留 $\boldsymbol{D}^1$ 中对应步骤(5)中 K 大值位置的训练样本，其余元素均设置为 0，即得到自适应原子选择后的字典 $\boldsymbol{D}^{1''}$。

(7)将自适应原子选择后的字典 $\boldsymbol{D}^{1''}$ 与测试样本 $\boldsymbol{y}^1$ 输入 KCRT 分类器，得到临时标签 l^1。

(8)换下一种 SAR 图像特征数据分别重新进行(4)～(7)步骤，得到小波变换特征对应的 AASKCRT 算法临时标签 l^2，以及 2DSZM 特征对应的 AASKCRT 算法临时标签 l^3。

(9)根据多特征投票决策，得到当前测试样本 $\boldsymbol{y}$ 的 MFAASKCRT 算法最终类标签 l。

(10)转向下一个未分类测试样本，重复步骤(3)～(10)，直至得到所有测试样本类标签。

(11)输出 $\boldsymbol{Y}^{m\times q}$ 的识别结果。

5 SAR 目标识别实验及分析

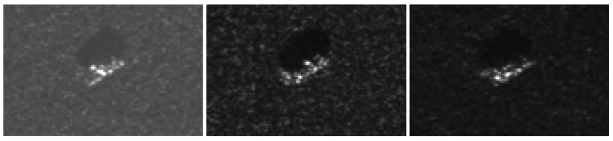
5.1 实验数据集

本文采用美国 DARPA 中的运动和静止目标获取与识别(Moving and Stationary Target Acquisition and Recognition，MSTAR)研究计划公开发布的数据库开展实验。实验的训练数据以及测试数据均包含三类目标：装甲运兵车 BMP2、装甲运兵车 BTR70 以及主战坦克 T72。图 3 给出了三个目标的光学图像。图 4 给出了近方位三个目标的微波图像。这里，BMP2 有三种不同的配置：bmp2-9563，bmp2-9566 和 bmp2-c21。BTR70 有一个类型：btr70-c71。T72 也有三种不同的配置：t72-132，t72-812 和 t72-s7。表 1 列出了训练样本和测试样本的数量。其中，17°俯仰角的合成孔径雷达图像数据作为训练样本集，15°的合成孔径雷达图像数据作为测试样本集。所有图像的像素均为 128×128，每



(a) BMP2 (b) BTR70 (c) T72

图 3 三个目标的光学图像



(a) BMP2　(b) BTR70　(c) T72

图 4　近方位三个目标的 SAR 图像

个目标 SAR 图像的方位角均在 0°～360°。

表 1　训练样本和测试样本的型号及数量

目标型号	训练集(17°俯视角)		测试集(15°俯视角)	
	序列编号	目标数目	序列编号	目标数目
BMP2	sn-9563	233	sn-9563	195
	sn-9566	232	sn-9566	196
	sn-c21	233	sn-c21	196
BTR70	sn-c71	233	sn-c71	196
T72	sn-132	232	sn-132	196
	sn-812	231	sn-812	195
	sn-s7	228	sn-s7	191

5.2　AASKCRT 的识别性能

为了说明 MFAASKCRT 方法的有效性，这里将 MFAASKCRT 与基于 PCA 特征的 AASKCRT(PCAAASKCRT)、基于小波变换特征的 AASKCRT(WAASKCRT)、基于 2DSZMs 特征的 AASKCRT(2DSZMAASKCRT)算法以及 PCA 特征 KCRT(PCAKCRT)、小波变换特征 KCRT(WKCRT)、2DSZMs 特征 KCRT(2DSZMKCRT)、多特征核协同表示(MFKCRT)算法在相同条件下进行实验比较，目的就是分析自适应原子选择对 KCRT 分类器性能的影响。为了令实验结果更具说服力，本实验中的三种特征的维数均取 600 维，所有模型中的正则化参数均取 0.001，AASKCRT 以及 MFAASKCRT 模型中的参数 $K=5$。表 2 给出了这 8 种方法的具体识别结果，图 5 则用更直观的图形形式将它们的平均识别效果做了对比。

表 2　AASKCRT 与 KCRT 分类器的识别准确率(%)

分类器	类标签			
	BMP2	BTR70	T72	均值
PCAKCRT	99.83	98.98	99.14	99.41
PCAAASKCRT	99.66	100.00	99.83	99.78
WKCRT	96.76	100.00	99.48	98.39
WAASKCRT	99.66	100.00	99.83	99.78
2DSZMKCRT	83.82	93.37	95.02	89.96
2DSZMAASKCRT	97.96	98.47	97.77	97.95
MFKCRT	98.81	100.00	99.48	99.37
MFAASKCRT	99.66	100.00	99.83	99.80

实验结果表明，无论对于 SAR 图像的何种特征，基于自适应原子选择的 KCRT 分类器总能获得比 KCRT 分类器更好的识别结果。而多特征 AASKCRT 分类器利用各特征之间的互补性，进一步提高了识别性能，其平均识别率高达 99.80%。根据图 5，可以明显观察出 AASKCRT 分类器相较于 KCRT 分类器的优势，这也说明，合适的表示字典对协同表示模型非常重要。

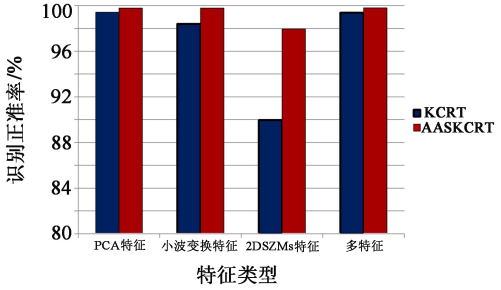


图 5　KCRT 分类器与 AASKCRT 分类器的性能比较

5.3　抗噪声试验

本实验研究了 MFAASKCRT 分类器在 SAR 低图像质量时的性能，这里，不同信噪比的高斯随机噪声被添加在原始 SAR 图像数据中。

表 3 展示了 MFAASKCRT 算法在不同质量 SAR 图像下的识别准确率，图 6 则直观地示出了 MFAASKCRT 分类器在不同噪声图像下识别性能的变化趋势。当加入图像的噪声信噪比大于 20 dB 时，系统的识别正确率可以达到 97%以上，说明 MFAASKCRT 分类器在低图像质量下的识别性能优异。

表 3　不同噪声下 MFAASKCRT 识别准确率(%)

SNR/dB	类标签			
	BMP2	BTR70	T72	均值
−10	43.25	41.84	46.42	44.76
0	48.60	45.33	50.45	47.89
10	60.31	55.72	61.34	59.15
20	97.27	92.86	98.97	97.36

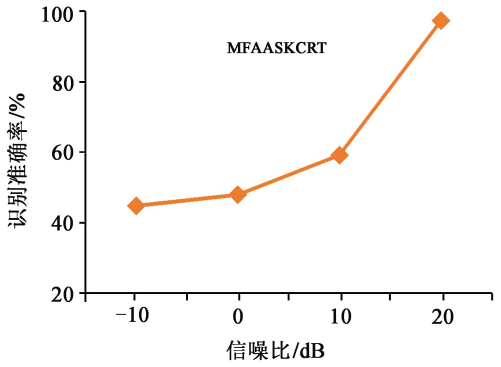


图 6　MFAASKCRT 分类器的抗噪声性能

6 总结

针对目前协同表示方法所用字典存在大量信息冗余和干扰的问题，本文提出了一种基于协同表示的自适应原子选择方法，并将其与核函数协同表示框架相结合用于SAR目标识别。最后，将提出的基于自适应原子选择的核协同表示算法在MSTAR数据集上进行实验验证。实验结果表明，与基本的协同表示相比，所提算法具有更高的可靠性和鲁棒性。

参考文献：

[1] Fennell M T, Wishner R P. Battlefield awareness via synergistic SAR and MTI exploitation[J]. IEEE Aerospace and Electronic Systems Magazine, 1998, 13(2): 39-45.

[2] 韩 萍. SAR自动目标识别及相关技术研究[D]. 天津：天津大学, 2004.
Han Ping. Research on SAR automatic target recognition and related technologies[D]. Tianjin: Tianjin University, 2004.

[3] Zhang L, Yang M, Feng X. Sparse representation or collaborative representation: Which helps face recognition [C]// Proc. of 2011 IEEE Inter. Conf. on Computer Vision, 2011: 12490911.

[4] Su H, Zhao B, Du Q, et al. Multifeature dictionary learning for collaborative representation classification of hyperspectral imagery[J]. IEEE Trans. on Geoscience and Remote Sensing, 2018, 56(4): 2467-2484.

[5] Maji S, Berg A C, Malik J. Classification using intersection kernel support vector machines is efficient[C]// Proc. of IEEE Conf. on Computer Vision and Pattern Recognition, 2008.

[6] Chen X, Peng X, Duan R, et al. Deep kernel learning method for SAR image target recognition[J]. Review of Scientific Instruments, 2017, 88(10): 104706.

[7] Chen X, Li S, Peng J. Hyperspectral imagery classification with multiple regularized collaborative representation[J]. IEEE Geoscience and Remote Sensing Lett., 2017, 14(7): 1121-1125.

[8] Geng J, Wang H, Fan J, et al. Wishart distance-based joint collaborative representation for polarimetric SAR image classification[J]. IET Radar, 2017, 11(7): 1620-1628.

[9] 练秋生，石保顺，陈书贞. 字典学习模型、算法及其应用研究进展[J]. 自动化学报, 2015, 41(2): 240-260.
Lian Qiusheng, Shi Baoshun, Chen Shuzhen. The research progress of dictionary learning model, algorithm and its application[J]. J. of Automatica Sinica, 2015, 41(2): 240-260.

[10] 齐会娇，王英华，丁 军，等. 基于多信息字典学习及稀疏表示的SAR目标识别[J]. 系统工程与电子技术, 2015, 37(6): 1280-1287.
Qi Huijiao, Wang Yinghua, Ding Jun, et al. SAR target recognition based on multi information dictionary learning and sparse representation[J]. J. of Systems Englneering and Electron., 2015, 37(6): 1280-1287.

[11] 王保云，张逸为，张 荣，等. 一种基于动态字典学习的SAR图像目标识别算法[J]. 光电工程, 2013, 40(6): 17-25.
Wang Baoyun, Zhang Yiwei, Zhang Rong, et al. An algorithm of SAR image target recognition based on dynamicdictionary learning[J]. J. of Optoelectronic Engineering, 2013, 40(6): 17-25.

[12] Chen X, Peng X, Duan R, et al. Deep kernel learning method for SAR image target recognition[J]. Review of Scientific Instruments, 2017, 88(10): 104706.

[13] Li W, Du Q, Xiong M M. Kernel collaborative hyperspesentation with Tikhonov regularization for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Lett., 2015, 12(1): 48-52.

作者简介：

刘苗苗(1993—)，女，安徽省人，硕士，工程师，2018年毕业于重庆大学信息与通信工程专业，主要研究方向为SAR图像解译、光通信等。