

doi: 10.7690/bgzd.2022.04.009

基于多特征核协同表示的 SAR 目标识别

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: 为利用合成孔径雷达 (synthetic aperture radar, SAR) 目标不同特征数据间的相关性与互补性, 提出一种基于多特征的 Tikhonov 正则化核函数协同表示 (multi-feature kernel collaborative representation-based classification with tikhonov regularization, MFKCRT) 算法。采用美国运动和静止目标获取与识别 (moving and stationary target acquisition and recognition, MSTAR) 计划公开发布的 SAR 图像数据库进行实验, 实现核函数变换空间上的多特征融合协同表示识别。实验结果表明: 该算法相较于基本的协同表示, 具有更优的可靠性与鲁棒性。

关键词: 合成孔径雷达; 自动目标识别; 多特征; 核函数; 协同表示

中图分类号: TN959 **文献标志码:** A

SAR Target Recognition Based on Multi-feature Kernel Cooperative Representation

Liu Miaomiao¹, Jiang Yufan², Xing Dingfan²

(1. Chongqing Optoelectronics Research Institute, Chongqing 400060, China;

2. Military Representative Bureau in Chongqing, Chongqing 400060, China)

Abstract: In order to exploit the correlation and complementarity between different feature data of synthetic aperture radar (SAR) target, a Tikhonov regularization kernel function collaborative representation algorithm based on multiple features is proposed. The SAR image database released by the moving and stationary target acquisition and recognition (MSTAR) program of the United States is used in the experiment. The multi-feature fusion collaborative representation and recognition on the kernel function transformation space is realized. Experimental results show that the proposed algorithm is more reliable and robust than the basic collaborative representation.

Keywords: SAR; automatic target recognition; multi-feature; kernel function; cooperative representation

0 引言

合成孔径雷达 (SAR) 是一种高分辨率成像雷达, 具有全天候、全天时、大测绘带的对地观测数据获取能力^[1]。随着 SAR 的高速发展, 其涉及的领域越来越全面, 包括海洋、地形、矿藏、农业以及军事等。如海洋中的海冰识别^[2]、农业观测中的水稻估产、地质灾害中的地震灾害识别^[3]等。

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, 然后甄别所检测到的目标类型。随着 SAR 应用的领域越来越广泛, 各研究人员对 SAR ATR 有关算法的研究与改进也是层出不穷。从基于 SAR 图像本身作为特征的 SAR 目标识别到采用特征提取方法对 SAR 图像进行特征提取再基于特征进行目标识别^[4]; 从基于模板匹配到基于模型的识别方法; 从支持向量机到稀疏表示 (sparse representation-based classification, SRC) 算法, 其目的都是想得到准确性更高、鲁棒性更强的

SAR ATR 方法。近年来, 基于 SRC 的 SAR ATR^[5-6]更是成为热门研究内容。然而, 在 SAR 目标识别系统中, SRC 虽然能够获得不错的识别效果, 却也存在运算复杂、识别过程比较耗时、难以求得全局最优解等不足。基于 SRC 在实际应用中遇到的这些问题, 一种替代算法应运而生, 这便是基于协同表示的分类 (collaborative representation-based classification, CRC) 算法^[7]。CRC 算法将 SRC 模型中正则化项的约束由 l_1 -范数约束放宽至 l_2 -范数, 这样不仅使 CRC 算法可以得到解析解, 而且在识别性能基本不会下降的前提下将识别速度提高很多。CRC 算法一经提出, 便受到许多研究学者的关注, 应用领域也越来越广泛^[8-9]。值得注意的是, CRC 方法虽然具有很多优点, 但在 SAR 目标识别中的识别性能还有待进一步提高, 这也是需要探索并改进的地方。基本的 CRC 虽然在 SAR 目标识别领域取得了不错的成果, 但是可靠性和鲁棒性还有一定的上升空间。

收稿日期: 2021-12-30; 修回日期: 2022-01-28

作者简介: 刘苗苗 (1993—), 女, 安徽人, 硕士, 工程师, 从事 SAR 图像解译、协同表示、光通信等研究。

E-mail: liumiaomiao2113640@foxmail.com。

最近，机器学习中的核函数变换受到了研究者的广泛关注。其不仅使系统避免了维数过高无法计算的问题，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困境。此外，核函数的运用十分灵活，可与其他算法结合形成多种不同的基于核函数变换的新模型，且这 2 部分的设计能够单独进行，并可针对具体应用灵活选择组合方式。笔者将核函数变换与协同表示框架相结合，利用 SAR 目标不同特征数据间的相关性与互补性，提出一种基于多特征核协同表示算法用于 SAR 目标识别，进一步提高了协同表示对 SAR 目标的识别性能。

1 协同表示理论及其识别算法

稀疏表示近年来成功应用于图像恢复、图像识别等领域^[10-11]。稀疏表示的基本模型如下：

$$\hat{\alpha} = \arg \min_{\alpha} \{ \|y - X\alpha\|_2^2 + \lambda \|\alpha\|_1 \}. \quad (1)$$

但是，稀疏表示理论在有些情况下也显示出其机理上的不足。在稀疏表示理论中，假设对于第 i 类的样本集 X_i 都有足够的训练样本，则字典 X_i 是超完备的。但在很多实际情况中，单个类别的训练样本集是一个典型的小样本系统，所以通常 X_i 是不完备的。此时，若用 X_i 来表示测试样本 y ，则表示误差会很大（即使 y 是来源于 i 集时，即 y 与 X_i 来自于同一个集）。最终，不论是使用重构误差 e_i 还是稀疏表示系数 $\|\hat{\alpha}\|_p$ 来识别 y ，其识别结果都不稳定。这是稀疏表示理论固有的缺陷。

对于这种情况，一种解决方法就是用更多的 i 集中的样本去表示测试样本 y ，但在很多实际情况中，没有这么多的同类别训练样本。很多传感器获取的不同目标的图像也具有一定程度的相似性，可以用 j 类训练样本集中的一些样本来表示 i 类的测试样本 y 。这种解决方法就是在稀疏系数的 l_1 范数约束下，融合所有类别的训练样本形成字典 $X=[X_1, X_2, \dots, X_K]$ ，再用字典去编码 y 。

在稀疏表示中，识别是逐个样本集合对 y 进行分类实现的。若除去稀疏表示最优化公式中稀疏系数 α 的 l_1 范数限制，然后将其表示成最小均方问题：

$$\hat{\alpha} = \arg \min_{\alpha} \|y - X\alpha\|_2^2. \quad (2)$$

那么其线性表示 $\hat{y} = \sum_i X_i \hat{\alpha}_i$ 就是 y 在 X 的有限空间上的垂直投影。在稀疏表示中，每一个类训练数据集的重构误差 $e_i = \|y - X_i \hat{\alpha}_i\|_2^2$ 都可用于分类。很容易推导出：

$$e_i = \|y - X_i \hat{\alpha}_i\|_2^2 = \|y - \hat{y}\|_2^2 + \|\hat{y} - X_i \hat{\alpha}_i\|_2^2. \quad (3)$$

误差 $e_i^* = \|\hat{y} - X_i \hat{\alpha}_i\|_2^2$ 可用于进行分类（因为 $\|y - \hat{y}\|_2^2$ 对于所有类的训练样本集而言是一个常数）。若定义 $\chi_i = X_i \hat{\alpha}_i$ 和 $\bar{\chi}_i = \sum_{j \neq i} X_j \hat{\alpha}_j$ 因为 $\bar{\chi}_i$ 与 $\hat{y} - X_i \hat{\alpha}_i$ 平行，则可得出：

$$e_i^* = \sin^2(\hat{y}, \chi_i) \|\hat{y}\|_2^2 / \sin^2(\chi_i, \bar{\chi}_i). \quad (4)$$

上式是用协同表示的误差 e_i^* ，当 y 属于集合 i 时，协同表示误差则不只考虑 \hat{y} 与 X_i 间的夹角很小的情况，还需考虑 χ_i 与 $\bar{\chi}_i$ 间夹角很大（ $\sin(\chi_i, \bar{\chi}_i)$ 很大）的情况。这样能让识别更有效且稳定。

当所有训练集合数目太大时，直接协同表示下的最小均方优化问题 $\hat{\alpha} = \min_{\alpha} \|y - X\alpha\|_2^2$ 将会变得不稳定。

在稀疏表示中， l_1 范数稀疏约束条件促使 α 解能更稳定地识别。然而，用 l_1 范数来提高系统的稳定性并不是唯一的解决方法。在协同表示中，用 l_2 范数去规则化 α 的解决方法与 l_1 范数的分类效果接近，但复杂性减少很多，实际是协同表示（而不是 l_1 范数稀疏约束）实现了高识别率的效果。

很多前人的工作都强调识别中“稀疏”的重要性，但却没有类别样本之间“协同”的机理。为了对测试样本进行协同表示，并且避免计算量大，采用规则化最小均方的协同表示模型：

$$\hat{\beta} = \arg \min_{\beta} \{ \|y - X\beta\|_2^2 + \lambda \|\beta\|_2^2 \}. \quad (5)$$

其中 λ 为规则化参数。规则化项可以让最小均方解保持稳定，这对解 $\hat{\beta}$ 进行了一定程度上的稀疏约束，但这种稀疏约束远比 l_1 范数弱。

具有规则化最小均方的协同表示最优化问题的解，解析表达式如下：

$$\hat{\beta} = (X^T X + \lambda \cdot I)^{-1} X^T y. \quad (6)$$

若令 $Q = (X^T X + \lambda \cdot I)^{-1} X^T$ 。则 Q 和测试样本 y 无关，所以该矩阵可以事先根据训练样本集计算出来。一旦输入测试样本 y ，则可以将 y 投影到 Q 上，因此协同表示可以用很快的运算实现。

2 基于 Tikhonov 正则化的核协同表示模型

作为协同表示算法的改进算法，基于 Tikhonov 正则化的协同表示 (collaborative representation-based classification with tikhonov regularization,

CRT) 是将正则化项由原始协同表示模型中的 $\|\beta\|_2^2$ 乘以 Tikhonov 偏置矩阵, 变为 $\beta^* = \|\Gamma_{l,y}\beta\|_2^2$ 。将核函数变换与 CRT 算法相融合, 结合两者优点, 即为基于 Tikhonov 正则化的核协同表示 (kernel collaborative representation-based classification with Tikhonov regularization, KCRT) 算法。

对于单特征 KCRT 算法, 首先提取 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, 根据 SAR 图像样本数较大的特性, 这里选择高斯核函数。最后用所有可利用的训练样本线性表示出测试样本 y 。则新的权重系数向量 β' 可以表示成下列二范数的组合形式:

$$\beta' = \arg \min_{\beta'} \|\Phi(y) - \Phi\beta^*\|_2^2 + \xi \|\Gamma_{\Phi(y)}\beta^*\|_2^2. \quad (7)$$

式中的映射函数 Φ 为测试样本到核特征空间的映射: $y \rightarrow \Phi(y) \in \mathbb{R}^{M \times 1}$ ($M \gg m$ 为核函数特征空间的维数), $\Phi = [\Phi(d_1), \Phi(d_2), \dots, \Phi(d_n)] \in \mathbb{R}^{M \times n}$ 。则新的 Tikhonov 偏置矩阵 $\Gamma_{\Phi(y)}$ 如下:

$$\Gamma_{\Phi(y)} = \begin{bmatrix} \|\Phi(y) - \Phi(d_1)\|_2 & \dots & 0 \\ \vdots & & \vdots \\ 0 & \dots & \|\Phi(y) - \Phi(d_n)\|_2 \end{bmatrix}. \quad (8)$$

矩阵中的元素为: $\|\Phi(y) - \Phi(d_i)\|_2 = [k(y, y) + k(d_i, d_i) - 2k(y, d_i)]^{1/2}$, $i = 1, 2, \dots, n$ 将权重系数向量 β' 展开, 用最小二乘法令其偏导为 0, 则可得到解:

$$\beta' = \left(K + \xi^2 \Gamma_{\Phi(y)}^T \Gamma_{\Phi(y)} \right)^{-1} k(\bullet, y). \quad (9)$$

式中 $k(\bullet, y) = [k(d_1, y), k(d_2, y), \dots, k(d_n, y)]^T \in \mathbb{R}^{n \times 1}$, 而 $K = \Phi^T \Phi \in \mathbb{R}^{n \times n}$ 是元素为 $K_{i,j} = k(d_i, d_j)$ 的 Gram 矩阵。权重向量 β' 由分段的 $\beta'_i = \{\beta'_i | \forall i \text{ s.t. } w_i = l\} \in \mathbb{R}^{n \times 1}$ 组成, w_i 为第 i 类样本的类标签, β'_i 为第 l 类权重子向量。测试样本的类标签:

$$\text{class}(y) = \arg \min_{l=1, \dots, C} \|\Phi_l \beta'_l - \Phi(y)\|_2. \quad (10)$$

式中 $\Phi_l = [\Phi(d_{l,1}), \Phi(d_{l,2}), \dots, \Phi(d_{l,n_l})]$ 为第 l 类的核函数字典, 将上述判决式进一步展开可得:

$$\|\Phi_l \beta'_l - \Phi(y)\|_2 = \sqrt{(\Phi(y) - \Phi_l \beta'_l)^T (\Phi(y) - \Phi_l \beta'_l)} = \sqrt{k(y, y) + (\beta'_l)^T K_l \beta'_l - 2(\beta'_l)^T k_l(\bullet, y)}. \quad (11)$$

式中 K_l 为第 l 类样本的 Gram 矩阵, 而 $k_l(\bullet, y) = [k(d_{l,1}, y), k(d_{l,2}, y), \dots, k(d_{l,n_l}, y)]^T \in \mathbb{R}^{n_l \times 1}$ 。

3 多特征核协同表示模型及算法流程

3.1 多特征核协同表示模型

基于前述核函数协同表示模型, 笔者提出一种融合了多特征的基于 Tikhonov 正则化的核协同表示 (MFKCRT) 算法。

首先, 分别提取 SAR 目标训练样本集的 PCA^[12]、小波变换^[13]以及 2DSZMs 特征^[14]。分别得到这 3 种特征下的字典 $\{D^t\}_{t=1,2,3}$, 其中 t 为特征类型索引。同理, 对于某一个测试样本, 也要提取其 3 类特征, 表示为 $\{y^t\}_{t=1,2,3}$ 。根据表示学习原理, 特征提取后的测试样本 $\{y^t\}_{t=1,2,3}$ 可以被训练样本集的特征字典 $\{D^t\}_{t=1,2,3}$ 线性表示: $\{y^t\}_{t=1,2,3} = \sum_l^C D_l^t \beta_l^t + \varepsilon^t$, $l = 1, \dots, C$ 。其中: t 为特征索引; C 为总类别数; β_l^t 为系数向量; ε 为表示误差。

根据核函数协同表示原理, 可得核函数协同表示模型:

$$\{\beta_l^t\}_{t=1,2,3} = \arg \min_{\beta_l^t} \left\{ \|y^t - D_l^t \beta_l^t\|_2^2 + \rho \|\Gamma_{l,y}^t \beta_l^t\|_2^2 \right\}. \quad (12)$$

其中 ρ 为 MFKCRT 模型的正则化参数。将上式展开求解, 即可得到核函数协同表示系数的解析解:

$$\{\beta_l^t\}_{t=1,2,3} = \left(K^t + \rho^2 (\Gamma^t)_{\Phi(y)}^T \Gamma^t_{\Phi(y)} \right)^{-1} k^t(\bullet, y). \quad (13)$$

权重向量 β' 由分段的 $\beta'_i = \{\beta'_i | \forall i \text{ s.t. } w_i = l\} \in \mathbb{R}^{n \times 1}$ 组成。测试样本的类标签:

$$\text{class}(y^t) = \arg \min_{l=1, \dots, C} \|\Phi_l^t \beta_l^t - \Phi^t(y^t)\|_2, \quad t = 1, 2, 3. \quad (14)$$

对于同一个测试样本, 可以得到不同特征下的 3 个核函数协同表示标签 $[\delta^1, \delta^2, \delta^3]$, 再根据投票准则, 对这 3 个标签再进行投票融合, 即可得到测试样本 y 的最终类标签 $\bar{\delta}$, 也就是 MFKCRT 算法的最终识别结果。

3.2 多特征核协同表示算法流程

将 MFKCRT 分类器的算法流程总结如下:

1) 输入所有类的训练样本 $X^{m \times n}$, 所有类的测试样本 $Y^{m \times q}$, MFKCRT 模型的正则化参数 ρ 。

2) 分别提取 $X^{m \times n}$ 的 PCA, 小波变换和 2DSZMs 特征, 得到 3 个特征字典: $D^1=D_{\text{PCA}}, D^2=D_{\text{wavelet}}$ 以及 $D^3=D_{2\text{DSZMs}}^{\text{selet}}$ 。

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

4) 选择核函数以及其对应的参数(这里选择的是 RBF 核函数), 计算出各种特征下的 K^i 和 $k^i(\bullet, y)$ 。

5) 计算每种特征下的 Tikhonov 偏置矩阵 $\Gamma'_{\phi(y)}$ 以及权重系数向量 β^i 。

6) 计算余差 $\|\Phi'_i \beta^i - \Phi'(y^i)\|_2$, 根据最小化重构误差准则, 得到 3 种特征下的测试样本 y 的临时标签向量 $[\delta^1, \delta^2, \delta^3]$ 。

7) 根据多特征投票决策, 得到当前测试样本 y 的最终类标签 $\bar{\delta}$ 。

8) 转向下一个未分类测试样本, 重复步骤 3)

—8), 直至得到所有测试样本的类标签。

9) 输出 $Y^{m \times q}$ 识别结果。

4 SAR 目标识别实验及分析

4.1 实验数据集

笔者采用美国 DARPA 运动和静止目标获取与识别 (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 3 类目标: 装甲运兵车 BMP2、装甲运兵车 BTR70 以及主战坦克 T72。图 1 给出了 3 个目标的光学图像, 图 2 给出了近方位 3 个目标的微波图像。BMP2 有 3 种不同的配置: bmp2-9563、bmp2-9566 和 bmp2-c21。BTR70 有 1 个类型: btr70-c71。T72 有 3 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 , 每个目标 SAR 图像的方位角均在 $0^\circ \sim 360^\circ$ 之间。



(a) BMP2




(b) BTR70




(c) T72


图 1 3 个目标的光学图像



(a) BMP2



(b) BTR70



(c) T72

图 2 近方位 3 个目标的 SAR 图像

表 1 训练样本和测试样本的型号及数量

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

4.2 3 类目标识别结果与分析

为说明 MFKCRT 方法的有效性, 将 MFKCRT

算法与基于 PCA 特征的 KCRT 算法 (PCKCRT)、基于小波特征的 KCRT 算法 (WKCRT)、基于

2DSZMs 特征的 KCRT 算法 (2DSZMKCRT) 以及 PCA 特征 CRC 算法 (PCACRC)、小波变换特征 CRC 算法 (WCRC)、2DSZMs 特征 CRC 算法 (2DSZMCR)、多特征协同表示 (MFCRC) 算法在相同条件下进行实验比较。为了令实验结果更让人信服, 本实验中的 3 种特征的维数均取 600 维, 所有模型中的正则化项参数均取 0.001。

通过如图 3 所示柱状图的直观比较, 表明 KCRT、MFKCRT 分类器优越的性能。表 2 给出了 8 种分类器的具体识别结果。显然, 基于单特征的 KCRT 算法相对于单特征 CRC 算法的识别能力要提高很多。值得注意的是, 对于传统的 CRC 算法, 普遍存在一种现象: 对于第 2 类样本也就是 BTR70 类识别的正确率明显低于其他 2 类。造成这种结果的原因是实验使用的数据集中, 第 2 类中的数据最少, 大致只有第 1 类或第 3 类数据数量的 1/3。而传统的 CRC 算法主要利用数据之间的协同性, 会导致数据被分到数据量较少类的可能性较低。KCRT 分类器解决了此问题, 3 类数据识别正确率分布比

较均匀。MFKCRT 作为单特征 KCRT 算法的一种投票融合, 利用不同特征之间的互补信息。虽然 MFKCRT 较 PCAKCRT 识别准确率略有下降 (从 99.41% 稍降为 99.37%), 但对于 WKCRT 以及 2DSZMKCRT 而言, MFKCRT 的识别准确率还是提高很多。另外, 由于 MFKCRT 分类器综合了 3 种特征的不同图像信息, 所以其识别性能对图像的变化更加稳定, 普遍适用性更广。




图 3 基于各种特征的 CRC 分类器与 KCRT 分类器的性能比较

表 2 CRC 与 KCRT 以及 MFKCRT 分类器的识别性能比较

分类器	类标签				均值
	BMP2	BTR70	T72		
PCACRC	89.10	55.10	96.05		80.02
PCAKCRT	99.83	98.98	99.14		99.41
WCRC	91.99	43.37	98.97		78.03
WKCRT	96.76	100.00	99.48		98.39
2DSZMCR	89.78	77.55	96.74		87.99
2DSZMKCRT	83.82	93.37	95.02		89.96
MFCRC	95.23	59.86	99.31		84.75
MFKCRT	98.81	100.00	99.48		99.37

4.3 抗噪声实验

评价一个识别系统的性能高低还有一项重要标准: 对噪声的鲁棒性。系统性能对噪声的改变越不敏感, 系统的抗噪声性能就越好, 实际应用的价值也就越大。本实验将不同程度的高斯噪声 (信噪比分别为 -10, 0, 10, 20, 30, 40 和 50 dB) 加入到原始的测试样本当中, 降低图像质量, 分析 MFKCRT 对低质量图像的识别效果。为了统一起见, 本实验中所用到的 3 种特征 (PCA、小波变换、2DSZMs) 维数均取 600 维, 5 种分类器 (PCAKCRT、WKCRT、2DSZMKCRT、CRC、MFKCRT) 的正则化参数取 0.001, 其中 CRC 分类器即直接对原始 SAR 数据进行协同表示分类。

图 4 给出了不同信噪比 (SNR) 下 5 种算法的识别性能曲线。

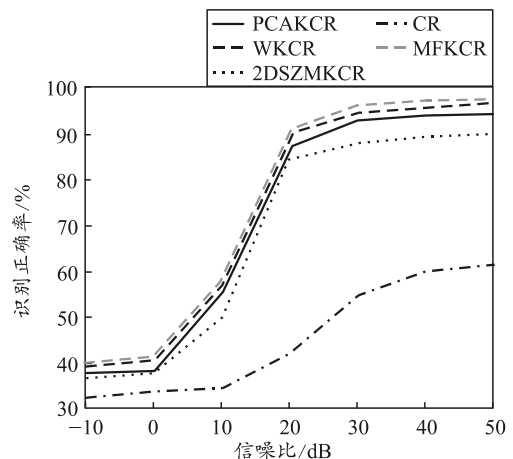


图 4 5 种分类器在低图像质量时的识别性能

上图表明: 当加入噪声的信噪比越小, 也就是 SAR 图像质量越低时, 系统的识别正确率也就越低, 这和理论分析一致。通过分析可发现, 无论基

于何种特征的 KCRT 分类器的抗噪声性能，相较于原始 CRC 分类器都有很大的提高。MFKCRT 分类器凭借其能够利用不同特征的互补信息的优势，其识别性能相较于任何特征的 KCRT 分类器都有着一定的提升。特别是对于 PCAKCRT 分类器，虽然在无噪声的情况下，PCAKCRT 的识别正确率稍高于 MFKCRT，但是从抗噪声性能曲线可以看出，其在

低图像质量下的识别能力还是弱于 MFKCRT，证明了 MFKCRT 算法的稳定性。

另外，不同信噪比噪声下 MFKCRT 识别正确率的详细数值如表 3 所示，当输入的噪声信噪比大于 30 dB 时，MFKCRT 的分类正确率达到了 95%，证明了 MFKCRT 分类器在低质量图像情况下识别性能的优越性。

表 3 MFKCRT 分类器在低图像质量时的识别性能

%

SNR/dB	类标签				均值
	BMP2	BTR70	T72		
-10	45.02	34.32	40.29		39.12
0	46.70	35.27	40.71		40.59
10	58.94	54.59	55.67		56.92
20	88.76	93.88	90.38		90.18
30	94.72	100.00	95.02		95.60
40	95.40	100.00	97.08		96.78
50	95.91	100.00	98.28		97.51

5 结束语

笔者提出了基于多特征核函数协同表示的 SAR 目标识别算法，并在 MSTAR 数据集上进行实验。实验结果证明，该算法具有优越的识别性能及抗噪声性能。

参考文献：

- [1] FENNEL 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] 陈少华. 面向海冰识别的 SAR 应用效能优化方法研究[D]. 北京: 中国科学院大学, 2013.
- [3] 刘云华, 屈春燕, 单新建, 等. SAR 遥感图像在汶川地震灾害识别中的应用[J]. 地震学报, 2010, 32(2): 214-223.
- [4] 贺志国, 陆军, 匡纲要. SAR 图像特征提取与选择研究[J]. 信号处理, 2008, 24(5): 813-823.
- [5] KNEE P, THIAGARAJAN J J, RAMAMURTHY K N, et al. SAR target classification using sparse representations and spatial pyramids[C]//IEEE Radar Conference. 2011: 12139489.
- [6] ZHANG H C, NASRABADI N M, HUANG T S, et al. Joint sparse representation based automatic target recognition in SAR images[J]. Proceedings of SPIE, 2011, 8051(5): 361-372.
- [7] ZHANG L, YANG M, FENG X. Sparse representation or collaborative representation: Which helps face recognition[C]//2011 IEEE International Conference on Computer Vision. 2011: 12490911.
- [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] SU H, ZHAO B, DU Q, et al. Multifeature dictionary learning for collaborative representation classification of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018(99): 1-18.
- [10] ELAD M, FIGUERIREDO M A T, MA Y. On the role of sparse and redundant representation in image processing[J]. Proceeding of the IEEE, 2010, 98(6): 972-982.
- [11] WRIGHT J, MA Y, MARIAL J, et al. Sparse representation for computer vision and pattern recognition[J]. Proceeding of the IEEE, 2010, 98(6): 1031-1044.
- [12] 王世晔, 贺志国. 基于 PCA 特征的快速 SAR 图像目标识别方法[J]. 国防科技大学学报, 2008, 30(3): 136-140.
- [13] SANDIRASEGARAM N M. Spot SAR ATR Using Wavelet Features and Neural Network Classifier[J]. Technical Memorandum, 2005.
- [14] ZHANG X Z, LIU Z Y, LIU S J, et al. Sparse coding of 2D-slice Zernike moments for SAR ATR[J]. International Journal of Remote Sensing, 2016, 38(2): 412-431.