

基于协作表示Boosting的辐射源多传感器融合识别

周志文[†], 黄高明, 高 俊

(海军工程大学 电子工程学院, 武汉 430033)

摘 要: 由于单传感器辐射源识别的局限性,在低信噪比条件下仅提高单侦测平台的识别能力无法满足实际需求,为此提出基于协作表示 Boosting 的辐射源多传感器融合识别算法. 利用多传感器数据信息的冗余性和互补性,对多处理支路采用时频分析提取特征,并由协作表示分类器求得残差. 根据 Boosting 在训练阶段的权重组合得到最小分类残差,实现多传感器决策域的融合识别. 仿真实验结果验证了所提出方法有效性,并且在低信噪比情况下噪声鲁棒性更优异,易于实现.

关键词: 辐射源识别; 协作表示; 多传感器数据融合; 时频分析; Boosting

中图分类号: TP974

文献标志码: A

Emitter identification of multi-sensor fusion based on collaborative representation and Boosting

ZHOU Zhi-wen[†], HUANG Gao-ming, GAO Jun

(College of Electronic Engineering, Naval University of Engineering, Wuhan 430033, China)

Abstract: For the restrictions of emitter identification based on single sensor, simply improving the performance of single surveillance platform no longer meets the practical demands in low signal-to-noise ratio(SNR). Thus an algorithm of emitter identification of multisensory fusion based on collaborative representation and Boosting is proposed. By virtue of redundancy and complementarity of multisensory data information, feature extraction is implemented with time-frequency analysis, and multi-branch residuals are obtained through collaborative representation-based classifiers. The minimum classification residuals are acquired according to the weights in the Boosting training phase, in consequence the decision-level fusion identification is implemented. Simulation results show the effectiveness of the proposed algorithm, and show more robustness to noise when the signal-to-noise ratio is relatively low. Meanwhile, the proposed framework is easy to be conducted.

Keywords: emitter identification; collaborative representation; multisensor data fusion; time-frequency analysis; Boosting

0 引 言

在现代战争中,推断不同辐射源信号的类型是辐射源识别领域的一个研究热点,它可解决由特征参数引起的不确定性问题^[1],估计发射信号平台的特性、提供威胁估计和决策采取的军事行动^[2]. 然而,由于电磁环境的复杂性和信息技术的快速发展,传统的基于脉冲描述字的雷达辐射源识别方法已不能满足实际需求,新的特征提取和分类器设计技术亟需得到解决. 对于特征提取,扩散特征^[3]、循环谱零切片^[4]和时频能量分布特征^[5]均作为合适的特征输入识别有意调制. Boashash 等^[6]指出,利用时频分析工具可提取

辐射源信号的时变信息,可用于雷达探测、成像和分类. Zeng 等^[7]对雷达信号进行 ZAM 广义时频表示并提取四维特征,实现了低 SNR 条件下的识别. Li 等^[8]利用正交时频分析提取切片特征,验证了其在特定辐射源识别中的有效性. 而对于分类器设计,稀疏分类(SC)^[9]因其鲁棒效果受到了广泛关注. Ma 等^[10]将稀疏表示(SR)运用到雷达辐射源识别中,验证了算法的有效性较强的抗干扰性能. 王磊等^[11]利用 SR 实现了噪声条件下雷达信号鲁棒的个体识别. Jia 等^[12]进而指出协作表示(CR)在 SC 中起着关键作用,计算复杂度低但可获得相近的识别率.

收稿日期: 2016-06-27; 修回日期: 2016-10-09.

基金项目: 国家自然科学基金项目(61501484); 国家 863 计划项目(2014AA7014061).

作者简介: 周志文(1989—),男,博士生,从事辐射源识别、信息融合的研究; 黄高明(1972—),男,教授,博士生导师,从事盲信号处理、无源探测等研究.

[†]通讯作者. E-mail: mini_paper@sina.com

基于单侦收平台的辐射源识别系统也暴露出一些缺陷:1)信号的截获概率、测量精度等存在不确定性,造成了测量数据的偏差;2)挖掘新的特征或设计性能优良的分类器也无法弥补单传感器的局限性;3)单侦测设备往往在信噪比条件下无法满足实际作战需求.因此发挥多源数据的互补性、融合多传感器辐射源信息能有效提高单传感器识别系统的性能.在多源融合识别方面,马捷等^[13]实现了辐射源的信号级融合,比特特征级和决策级融合识别干扰性强,但要求高精度的测量和严格的时空对准.Chen等^[14]针对存在模糊和冲突信息的辐射源融合识别提出了改进型DSm理论的方法,在决策层实现弱和强冲突下的融合识别,但基本信度分配的计算十分庞大.鉴于协作表示中正则化因子影响着分类效果,而最优因子又依赖于实际应用场景^[15],本文提出一种基于协作表示Boosting的辐射源多传感器融合识别算法(MCR-Boosting).利用仿真数据验证了所提出的融合识别算法的有效性和噪声鲁棒性,且复杂度小,易于工程实现.

1 协作表示Boosting辐射源融合识别算法

为方便下文叙述,先对部分符号加以说明.定义 $\mathbf{A}_i = [\mathbf{a}_{i,1}, \mathbf{a}_{i,2}, \dots, \mathbf{a}_{i,n_i}] \in \mathbf{R}^{m \times n_i}$ 为第 i 类训练样本,其中列向量 $\mathbf{a}_{i,j} (j = 1, 2, \dots, n_i)$ 为 m 维特征向量.假设有 C 类样本, $\mathbf{A} = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_C] \in \mathbf{R}^{m \times n}$ 为样本字典,其中 $\sum_{i=1}^C n_i = n$.验证集 $\mathbf{V} = [\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_C] \in \mathbf{R}^{m \times L}$ 有 L 个样本,每类子集对应的样本数为 $l = [l_1, l_2, \dots, l_C]$,且 $\sum_{i=1}^C l_i = L$.测试样本信号 $\mathbf{s}_y \in \mathbf{R}^m$,假设来自同一类别的训练样本存在于某一子空间中,并且 $\mathbf{s}_y$ 可由同类训练样本的线性组合表示.

1.1 算法框架

针对同一辐射源多侦测平台识别的情况,提出图




图1 协作表示Boosting辐射源识别算法流程

1所示的MCR-Boosting算法识别框架流程.训练阶段为识别阶段提供了具有先验知识的数据库和更新不同支路的权值,识别阶段根据同一雷达辐射源不同平台进行综合决策,推断出辐射源类型.

1.2 单支路信号处理

为提取稳健可分的脉内特征,提取了不同辐射源脉内时频域特征,利用短时傅里叶变换将辐射源信号变换到二维时频域.然而,二维数据不利于后续信号处理,因此将时频图像向量化.利用随机投影对高维数据降维,在保留原始数据信息的同时,提取有效的特征向量,降维后的特征向量分别作为训练样本库 $\hat{\mathbf{A}}$ 和测试样本集 $\hat{\mathbf{V}}$.

对于单传感器的辐射源识别,假设接收端传感器的待测辐射源信号 $\mathbf{s}_y$ 属于第 $i (1 \leq i \leq C)$ 类,即 $\text{label}(\mathbf{s}_y) = i$,经预处理后得到高维测试样本为 $\mathbf{y}$.基于前述假设,降维后的测试样本可表示为

$$\hat{\mathbf{y}} = \sum_{i=1}^C \hat{\mathbf{A}}_i \alpha_i = \hat{\mathbf{A}} \alpha. \quad (1)$$

其中: $\mathbf{R} \mathbf{y} = \hat{\mathbf{y}} \in \mathbf{R}^d$, $\mathbf{R} \mathbf{A} = \hat{\mathbf{A}} \in \mathbf{R}^{d \times n}$, $\mathbf{R} \in \mathbf{R}^{d \times m}$ 且 $d \ll m$ 为随机压缩矩阵, $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_C]^T$ 为 $\hat{\mathbf{y}}$ 在完备字典下的表示系数.利用过完备字典 $\mathbf{A}$ 表示 $\mathbf{s}_y$ 以及第 j 类训练样本,有助于协作表示属于第 i 类的 $\mathbf{s}_y$.对式(1)的求解引入 ℓ_2 约束项

$$\hat{\alpha} = \arg \min_{\alpha} \|\hat{\mathbf{y}} - \hat{\mathbf{A}} \alpha\|_2 + \lambda \|\alpha\|_2^2, \quad (2)$$

则式(2)有如下近似最优解:

$$\hat{\alpha} = (\hat{\mathbf{A}}^T \hat{\mathbf{A}} + \lambda \mathbf{I})^{-1} \hat{\mathbf{A}}^T \hat{\mathbf{y}}. \quad (3)$$

无论是训练字典 $\mathbf{A}$ 还是高维样本 $\mathbf{y}$,经过降维, $\hat{\alpha}$ 的计算量大大降低.而由于 $\hat{\alpha}$ 包含着分类信息,利用此信息可推断出单接收平台的辐射源类型.

1.3 MCR-Boosting训练阶段

由于同一接收信号多传感器融合系统的多支路信息十分相关,采用相同参数的分类器不利于挖掘相关性和差异性,且无法改善融合识别性能.另外,单侦收平台的最优 λ 需要根据实际应用场景确定,当样本改变时又需重新调整 λ ,增加了识别的复杂度且不利于后续应用扩展.本节提出随机选择正则化因子,以去除择优的针对性.

假设接收端有 P 个传感器,考虑到接收通道和传输路径的差异,被截获信号 $\mathbf{s}_y$ 在传感器端形成独立且相关的信号集 $\{\mathbf{s}_y^{(p)}, p = 1, 2, \dots, P\}$,随机生成参数集 $\{\lambda^{(p)}, p = 1, 2, \dots, P\}$ 且满足 $0 < \lambda^{(p)} < 1$,训练字典集为 $\mathbf{A}$.在第1.2节下获得协作表示系数 $\hat{\alpha}^{(p)}$,希望找到一个决策分类器,试图对多个侦收平台的残

差进行加权,从而实现决策级融合识别,即有

$$\mathbf{H}\{s_y^{(1)}, \dots, s_y^{(P)}\} = \arg \min_{i \in \{1, \dots, C\}} r_i^{(p)}, \quad (4)$$

其中

$$r_i^{(p)} = \sum_{p=1}^P \beta^{(p)} \|\hat{\mathbf{y}}^{(p)} - \hat{\mathbf{A}}_i \hat{\alpha}_i^{(p)}\|_2^2. \quad (5)$$

$\beta = [\beta^{(1)}, \beta^{(2)}, \dots, \beta^{(P)}]$ 为 P 个处理支路的权重系数,不失一般性,假设 $\sum \beta^{(p)} = 1$. 考虑到 Adaboost 出发点是对多个弱分类器集成学习,而本文是针对多传感器不同的接收数据进行融合识别,但源数据为不同接收通道的同一信号,关联性强且信号间存在着共同分量,因而可采用 Boosting 训练多支路分类器,从而为多个协作表示分类器分配权重. 本文提出的 MCR-Boosting 算法总结如下.

输入: 训练字典 $\mathbf{A}$ 和验证集 $\mathbf{V}$, 随机选择正则化参数 $\lambda = [\lambda^{(1)}, \dots, \lambda^{(P)}]$ 且 $\lambda^{(p)} > 0$;

输出: $\{\beta^{(p)}\}_{p=1}^P$.

Step 1: $\mathbf{A}$ 和 $\mathbf{V}$ 降维, 有 $\hat{\mathbf{A}} = \mathbf{R}\mathbf{A}$ 和 $\mathbf{R}\mathbf{V} = \hat{\mathbf{V}} \in \mathbf{R}^{d \times L}$.

Step 2: 初始化分布 $D_k^{(1)} = 1/L$, $k = 1, 2, \dots, L$.

Step 3: 迭代, For $p = 1 \rightarrow P$.

Step 3.1: 对每个验证集样本寻找分布 $D_k^{(p)}$ 上最大化验证权重误差 $|\varepsilon_p|$ 的表示, 其中

$$\varepsilon_p = \sum_p D^{(p)} |g_{k,p}|,$$

$$g_{k,p} = \|\hat{\mathbf{v}}_k - \hat{\mathbf{A}}_k \hat{\alpha}_k^{(p)}\|_2^2 - \min_{i \neq k} \|\hat{\mathbf{v}}_k - \hat{\mathbf{A}}_i \hat{\alpha}_i^{(p)}\|_2^2;$$

Step 3.2: 选择

$$\beta^{(p)} = \max\{0.5 \log(1 - \varepsilon_p) / \varepsilon_p, 0\};$$

Step 3.3: 更新

$$D_k^{(p+1)} = D_k^{(p)} \exp(\beta^{(p)} g_{k,p}) / Z_p,$$

其中 Z_p 为归一化因子, 满足 $\sum_{k=1}^K D_k^{(p+1)} = 1$.

结束 For 循环.

在 MCR-Boosting 每次迭代中, $\beta^{(p)}$ 的权重不断学习更新. 其中 $g_{k,p}$ 衡量着正确分类的残差与第 k 个样本剩余类别的最小残差的关系, 若第 p 个处理支路分类正确, 则有 $g_{k,p} < 0$, 否则 $g_{k,p} > 0$. MCR-Boosting 通过判断, 若不是正确分类, 则将更大的权重置于第 p 个支路, 从而更新分布 $D_k^{(p+1)}$. 通过迭代逐步更新 P 个接收支路的权重 $\{\beta^{(p)}\}_{p=1}^P$, 而 $\{\beta^{(p)}\}_{p=1}^P$ 衡量着不同 $\lambda^{(p)}$ 协作表示分类器在测试集上的分类错误概率, 当 $\beta^{(p)} = 0$ 时跳出循环, 避免了支路权值为负的情况, 因为负值是无意义的.

1.4 MCR-Boosting 识别阶段

在线识别时, 各传感器支路利用残差向量 $\{\mathbf{r}^{(p)}\}_{p=1}^P$ 和训练阶段得到的权重 $\{\beta^{(p)}\}_{p=1}^P$, 得到融合识别决策域上的加权分类残差, 从而实现最优识别, 即

$$\text{label}(s_y) =$$

$$\text{label}\{s_y^{(p)}, p = 1, 2, \dots, P\} = \arg \min_{i \in \{1, 2, \dots, C\}} r_i^{(p)}. \quad (6)$$

其中: $r_i^{(p)}$ 的定义与式 (5) 相同, 表示每个处理支路分类的残差. 由式 (6) 可知, 对于截获到的同一辐射源信号, 可在决策层推断出多传感器融合识别结果.

2 仿真实验

通过实验测试所提出算法的有效性和识别性能. 实验中样本为 6 类辐射源信号, 包括常规脉冲 (CP)、线性调频 (LFM)、非线性余弦 (NCFM)、二频率编码 (BFSK)、四频率编码 (QFSK) 和二相编码 (BPSK) 信号. 在 [20, 30] dB 信噪比范围内随机产生 480 个前述不同调制类型的样本, 抽取 180 个作为训练样本, 剩余 300 个作为验证样本, 且保证 $n_1 = n_2 = \dots = n_C$ 和 $l_1 = l_2 = \dots = l_C$. 在实验中, 随机投影矩阵选择常见的高斯矩阵.

2.1 两个传感器 MCR-Boosting 融合性能

随机选择正则化因子 $\{\lambda^{(1)} = 0.2, \lambda^{(2)} = 0.4\}$, 则训练得到权重系数 $\{\beta^{(1)} = 0.421, \beta^{(2)} = 0.579\}$. 下面对比单传感器和融合后的识别性能, 测试样本实时产生, 且参数设置与训练数据相同. 为测试所提出算法的噪声鲁棒性, 每个信噪比条件下产生 1200 个测试样本, 其中 $n_i = 200$. 噪声为加性高斯白噪声, 随机投影后的压缩维度为 $d = 90$, 由于 d 的选择与计算复杂度、样本信号的冗余度相关, 在此暂不讨论, 只取为合适的值. 识别性能用正确识别率衡量, 仿真结果如图 2 所示.




图2 单传感器与融合后的识别率

由图 2 可见, 随着 SNR 的提高, 无论是单传感器还是融合后的识别率均有所提高, 且正则化因子造成

两个支路识别性能有差异. 当 $\text{SNR} \geq 8 \text{ dB}$ 时, 两者性能改善得不再明显, 并且融合后的识别率与传感器1支路相同, 说明在低信噪比条件下利用传感器间的冗余信息提高了正确识别率, 增强了正确决策能力. 但继续增大 SNR 时并没能提升融合识别效果, 说明此时制约因素不再单纯是信噪比. 下面探讨可能影响的因素: 传感器数目 P 和字典大小 n .

2.2 传感器数目对融合识别性能的影响

改变 $P \in [2, 7]$, 随机选择不同支路的正则化因子, 其他实验参数设置保持不变. 进行1 200次Monte Carlo实验, 求得平均识别率, 记录运行时间, 包括训练时间 n_1 和识别时间 n_2 . 当 $P = 7$ 时, 正则因子为 $\{0.2, 0.4, 0.03, 0.3, 0.08, 0.6, 0.5\}$, 训练权值为 $\{0.151, 0.209, 0.079, 0.139, 0.073, 0.192, 0.157\}$, 可以看出权重与正则因子并不是单纯的线性关系, 因此MCR-Boosting遍历 $[0, 1]$ 范围的正则因子有利于选择最佳 λ . 实验采用的电脑配置为i3-2100 CPU 3.10 GHz, 3.49 GB内存, Matlab版本为R2011a. 不同传感器数目融合识别的仿真实验结果如表1所示.

表1 传感器数目与识别率、运行时间关系

数目 p	识别率 η						运行时间 / s	
	-8 dB	-4 dB	0 dB	4 dB	8 dB	12 dB	t_1	t_2
2	0.786	0.845	0.859	0.863	0.865	0.865	5.7	711.8
3	0.793	0.845	0.862	0.864	0.866	0.866	8.7	1 246.2
4	0.816	0.854	0.860	0.864	0.866	0.866	11.3	1 751.3
5	0.824	0.854	0.862	0.863	0.865	0.866	14.3	2 195.1
6	0.827	0.855	0.862	0.863	0.866	0.866	16.2	2 609.1
7	0.827	0.855	0.863	0.864	0.866	0.866	19.6	3 041.5

由表1可知: 1) 当接收端信号信噪比增大时可提高融合识别精度, 且本实验中 $\text{SNR} \geq 8 \text{ dB}$ 时再提升信噪比对改善性能意义不大. 2) 当 $\text{SNR} \leq 0 \text{ dB}$ 时增加传感器数目可一定程度提高识别率, 有效信息的增加有利于作出最佳判决, 但也会增加计算成本. 可以看到, 当 $\text{SNR} = 0 \text{ dB}$ 且 $P = 4$ 时识别率反而下降, 这是由于样本噪声的差异性使得识别结果存在一定的偏差, 但在可信度范围以内. 考虑到计算复杂度和实际成本问题, 需根据实际应用场景考虑最优的传感器数目. 3) 由运行时间可知, 随着传感器数目的增加, 训练和识别时间几乎成线性增长. 从定量上分析, 若 $O(s_y^{(1)})$ 、 $O(s_y^{(2)})$ 分别为两个支路的处理时间, 则 $O(s_y^{(1)}) = O(s_y^{(2)})$, 而在训练阶段第3步(其他步计算成本可忽略)可表示为 $O(P)$, 因此线性增加 P 使得计算成本同样线性增大.

2.3 字典大小对融合识别性能的影响

当字典 $\mathbf{A}$ 过定时, 即字典样本数目大于特征维度, 式(1)的解可由最小均方解满足; 当字典 $\mathbf{A}$ 为欠定时, 利用式(3)可求最优解. 在保证仿真条件与2.1节一致的前提下, 本节改变每类样本数目 n_i 进行仿真. 其中 $n_i \in [5, 10, 20, 30, 50]$, 传感器数目 $P = 2$. 仿真结果如图3所示, 图中注明了不同训练样本下 $\text{SNR} = 12 \text{ dB}$ 时的识别率. 逐渐增大每类样本数目时, 不同信噪比条件下的识别率均显著提高. 对比 $n_i = 5$, 字典在充分完备的情况下($n_i = 50$)可获得大于90%的正确识别率. 对比 n_i 取不同的值可发现, 随着 n_i 的增加, 不同信噪比之间的识别率改善得不再明显. 当 $n_i = 50$ 且 $\text{SNR} \geq 0 \text{ dB}$ 时, 融合识别率几乎相同. 因此, 对于提出的MCR-Boosting算法框架, 获取更充分的先验知识库和增加侦收平台数目将有利于提高辐射源融合识别的正确率和鲁棒性.




图3 单传感器与融合后的识别率

2.4 不同融合识别算法性能对比

本文的MCR-Boosting隶属于决策级融合识别, 将文献[13]中信号级SRSF算法、D-S证据理论决策级融合算法(在此用MCR-DS表示此法)与本文算法进行对比. 其中, SRSF中稀疏求解采用OMP方法, 融合规则为最大活跃度准则; 而MCR-DS根据残差信息建立基本可信度赋值函数, 从而进行DS证据推理. 接收传感器数目设定为2, 其他实验参数保持不变, 将两个单传感器识别率的平均值作为识别结果, 并表示为CR-Sensor1.

图4的仿真结果表明: 1) 以文献[13]为代表的信号级算法在对比算法中性能最差, 甚至劣于单传感器, 尽管在低信噪比情况下融合原始数据提供了更多有意调制特征细节的信息, 但由于容错能力差, 部分错误或数据丢失叠加导致了信号失真, 从而影响并限制了信号级的融合识别能力; 2) 以CR为分类器的融合算法明显优于其他算法, 说明在低信噪比条件

下CR鲁棒性更强,更适用于恶劣环境下的多侦测平台融合识别;3)以D-S证据为代表的决策级融合较优于单传感器性能,但劣于所提出的MCR-Boosting算法,一方面是因为基本可信度赋值函数需要根据实际设计,另一方面没有考虑到不同支路传感器特性;而MCR-Boosting充分利用了训练阶段的先验知识,提高了正确决策能力。




图4 不同融合级别算法识别性能

3 结 论

针对单传感器辐射源识别的局限性,本文提出了一种新颖的多传感器融合识别算法,实现了多侦测信号数据融合识别。在算法框架中,多侦收平台将时域信号变换到时频域,利用Boosting训练得到支路权重,根据协作分类器在决策域的权重残差推断出识别结果。仿真实验结果表明,所提出的算法较单传感器识别率更高,且在低信噪比条件下比信号级、特征级的融合方法鲁棒性更强,计算复杂度低,提高了信息置信度。

参考文献(References)

- [1] Liu H J, Liu Z, Jiang W L, et al. Incremental learning approach based on vector neural network for emitter identification[J]. IET Signal Processing, 2010, 4(1): 45-54.
- [2] Tait P. Introduction to radar target recognition[M]. London: Institution of Engineering and Technology, 2005: 353-363.
- [3] 韩韬, 周一宇. 雷达信号的扩散特征及其在特定辐射源识别中的应用[J]. 电子学报, 2013, 41(3): 502-507. (Han T, Zhou Y Y. Diffusion features in radar specific emitter identification[J]. Acta Electronica Sinica, 2013, 41(3): 502-507.)
- [4] 史亚, 姬红兵, 朱明哲, 等. 多核融合框架下的雷达辐射源个体识别[J]. 电子与信息学报, 2014, 36(10): 2484-2490. (Shi Y, Ji H B, Zhu M Z, et al. Specific radar emitter identification in multiple kernel fusion framework[J]. J of Electronics and Information Technology, 2014, 36(10):

- 2484-2490.)
- [5] Yuan Y J, Huang Z T, Wu H, et al. Specific emitter identification based on hibert-huang transform-based time-frequency-energy distribution features[J]. IET Communications, 2014, 8(13): 2404-2412.
- [6] Boashash B, Cohen L, Chen V, et al. Time-frequency approach to radar detection, imaging, and classification[J]. IET Signal Processing, 2010, 4(4): 325-328.
- [7] Zeng D, Zeng X, Lu G, et al. Automatic modulation classification of radar signals using the generalized time-frequency representation of ahaio, atlas and marks[J]. IET Radar, Sonar and Navigation, 2010, 5(4): 507-516.
- [8] Li L, Ji H B, Jiang L. Quadratic time-frequency analysis and sequential recognition for specific emitter identification[J]. IET Signal Processing, 2011, 5(6): 568-574.
- [9] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
- [10] Ma J, Huang G M, Zuo W, et al. Robust radar waveform recognition algorithm based on random projections and sparse classification[J]. IET Radar, Sonar and Navigation, 2014, 8(4): 290-296.
- [11] 王磊, 周乐因, 姬红兵, 等. 一种面向信号分类的匹配追踪新方法[J]. 电子与信息学报, 2014, 36(6): 1299-1306. (Wang L, Zhou L N, Ji H B, et al. A new matching pursuit algorithm for signal classification[J]. J of Electronics and Information Technology, 2014, 36(6): 1299-1306.)
- [12] Jia S, Shen L L, Li Q Q. Gabor feature-based collaborative representation for hyperspectral imagery classification[J]. IEEE Trans on Geoscience and Remote Sensing, 2015, 53(2): 1118-1129.
- [13] 马捷, 黄高明, 吉嘉, 等. 基于稀疏表示的雷达辐射源信号级融合识别算法[J]. 控制与决策, 2014, 29(10): 1798-1802. (Ma J, Huang G M, Ji J, et al. Signal-level fusion algorithm for radar emitter identification based on spare representation[J]. Control and Decision, 2014, 29(10): 1798-1802.)
- [14] Chen C X, He M H, Li H F. An improved radar emitter recognition method based on dezert-smarandache theory[J]. Chinese J of Electronics, 2015, 24(3): 611-615.
- [15] Chi Y J, Porikli F. Classification and boosting with multiple collaborative representations[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2014, 36(8): 1519-1531.

(责任编辑: 孙艺红)