

利用稳健字典学习的雷达高分辨距离像目标识别算法

冯博 陈渤* 王鹏辉 刘宏伟 严俊坤
(西安电子科技大学雷达信号处理国家重点实验室 西安 710071)

摘要: 基于字典学习算法的信号稀疏表示被广泛应用于信号处理领域。由于字典原子间存在冗余性,求解信号的稀疏表示会受到观测信号中扰动分量的影响,从而带来表示的不确定性,不利于雷达高分辨距离像(HRRP)目标识别任务。针对这一问题,该文提出一种稳健字典学习(SDL)算法,通过边缘化信号丢失,构建稳健损失函数用于学习自适应字典。该算法利用距离像在散射点不发生越距离单元走动的方位帧内具有结构相似性,约束临近训练样本间稀疏表示的非零元素位置相同,并通过结构化稀疏约束选择最优子字典用于测试样本的分类。基于实测 HRRP 数据的实验结果验证了所提算法的有效性。

关键词: 雷达自动目标识别; 高分辨距离像; 稳健字典学习; 边缘化信号丢失; 稳健稀疏表示

中图分类号: TN959.1+7

文献标识码: A

文章编号: 1009-5896(2015)06-1457-06

DOI:10.11999/JEIT141227

Radar High Resolution Range Profile Target Recognition Algorithm via Stable Dictionary Learning

Feng Bo Chen Bo Wang Peng-hui Liu Hong-wei Yan Jun-kun
(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract: The sparse representation of signal via dictionary learning algorithms is widely used in signal processing field. Since there is redundancy in the new space defined by overcomplete dictionary atoms, the problem of finding sparse representations may bring the uncertainty and ambiguity in the presence of unknown amplitude perturbations, which is unfavorable to radar High Resolution Range Profile (HRRP) target recognition task. To deal with this issue, this paper proposes a novel algorithm called Stable Dictionary Learning (SDL), which constructs a robust loss function via marginalizing dropout to learn a stable adaptive dictionary. The algorithm considers the structure similarity among the adjacent HRRPs without scatterers' motion through range cells, and enforces the constraints that the sparse representations of adjacent HRRPs should have the same supports. Moreover, SDL utilizes the structured sparse regularization learned in the training phase to automatically select the optimal sub-dictionary basis vectors, which is used for the classification of the test sample. Experimental results on measured radar HRRP dataset validate the effectiveness of the proposed method.

Key words: Radar Automatic Target Recognition (RATR); High Resolution Range Profile (HRRP); Stable Dictionary Learning (SDL); Marginalizing dropout; Stable sparse representation

1 引言

雷达高分辨距离像(HRRP)是利用宽带雷达信号获取的目标散射点回波在雷达视线方向上投影的矢量和。它包含了目标尺寸,散射点分布等许多重要的结构信息,且易于获取、存储和处理,如今已成为了雷达自动目标识别(RATR)领域的一个重要的研究方向^[1-6]。

对于 RATR, 一个好的特征表示不仅可以有效消除回波中的噪声分量和冗余分量,而且能尽可能地保留样本中的类别信息,改善识别效率与精度^[3-5]。因此,不少学者对基于特征表示的 HRRP 目标识别算法进行了广泛的研究。文献[3]提出了基于实 HRRP 功率谱特征的识别算法,文献[4]进一步分析比较了 HRRP 频谱幅度,功率谱及高阶谱等频域特征在识别性能上的差异。这类算法将 HRRP 样本映射到特定的信号空间,物理意义明确且计算简单。文献[5]利用主成分分析(PCA)投影到子空间,构建最小重构误差准则实现 HRRP 目标识别。文献[6]提出因子分析(FA)模型,通过一个低维隐表示空间对

2014-09-19收到, 2014-12-10改回

国家自然科学基金(61372132, 61201292), 新世纪优秀人才支持计划(NCET-13-0945), 重点实验室基金和中央高校基本科研业务费专项资金资助课题

*通信作者: 陈渤 bchen@mail.xidian.edu.cn

HRRP 的频谱幅度进行描述。这类基于特定数学模型的算法, 能够获得信号的低维表示, 具有更优的识别性能, 推广性较好。然而, 所有这些算法都隐含一个相同的假设: 特征表示的维度不超过观测信号的维度。近年来, 大量研究^[7-11]表明, 通过字典学习算法获得信号的超完备稀疏表示可以更好地改善模型性能。

基于字典学习的信号稀疏表示通过选取超完备字典中少数原子来线性稀疏地表示信号, 有利于发现数据中的内在结构信息。通过构建简单的稀疏模型可以有效避免过学习现象, 且选取的原子通常具有生物或物理意义, 这是模型解释所感兴趣的^[8]。但是, 由于超完备字典原子间的冗余性, 当观测信号中存在噪声扰动时, 求解信号的稀疏表示常常会带来不确定性, 即稀疏表示对噪声扰动并不稳健^[9]。特别是对于目标识别, HRRP 的方位敏感性, 幅度起伏特性以及少量奇异样本的存在都会影响 HRRP 样本稀疏表示的稳健求解, 导致同类样本在表示空间出现失配现象, 进而引起识别性能下降。

针对这一问题, 本文提出一种稳健字典学习 (SDL) 算法。区别于传统字典学习算法, 该算法通过边缘化信号丢失 (Marginalizing dropout), 构建稳健损失函数用于学习自适应字典, 减少了原子间的互适应性 (co-adaptation), 避免了参数的过学习现象。在算法训练阶段, 考虑到距离像在散射点不发生越距离单元走动 (MTRC) 的方位帧内具有相似的物理特性, 通过约束临近训练样本间稀疏表示的非零元素位置相同, 使得 HRRP 帧内结构信息在特征表示空间得到保持; 测试阶段, 基于学习得到的结构化稀疏约束, 自动选择最优子字典用于测试样本的分类。实测 HRRP 数据的实验结果验证了本文算法的有效性。

2 字典学习理论

传统字典学习理论的目的在于寻求一个自适应字典, 使得在该字典下, 信号不仅能以小误差重构, 且重构系数尽可能是稀疏的。字典学习的数学模型可表示为

$$\min_{D, \mathbf{A}} \|\mathbf{X} - \mathbf{D}\mathbf{A}\|_F^2, \quad \text{s.t.} \quad \forall i, \|\mathbf{a}_i\|_0 \leq T \quad (1)$$

其中 $\mathbf{D} \in \mathbb{R}^{P \times K}$ 是超完备字典 ($P < K$, P 为观测信号维度, K 为字典原子个数), $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbb{R}^{P \times N}$, $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N] \in \mathbb{R}^{K \times N}$ 分别表示观测信号和稀疏表示矩阵。这里 $\|\mathbf{a}\|_0$ 表示 l_0 范数, 用于计算

向量 \mathbf{a} 中非零元素的个数, T 为稀疏度。为了求解式 (1), 通常采用稀疏编码和字典更新两部分交替迭代优化求解^[7-11]。

(1) 稀疏编码 给定超完备字典 $\mathbf{D} \in \mathbb{R}^{P \times K}$, 观测样本 $\mathbf{x} \in \mathbb{R}^{P \times 1}$ 的稀疏表示 $\mathbf{a} \in \mathbb{R}^{K \times 1}$ 可以计算为

$$\min_{\mathbf{a}} \|\mathbf{x} - \mathbf{D}\mathbf{a}\|_2^2, \quad \text{s.t.} \quad \|\mathbf{a}\|_0 \leq T \quad (2)$$

事实上, 精确求解式 (2) 需要遍历所有非零项的组合, 这是一个 NP 难问题, 一般松弛 l_0 范数为 l_1 范数, 将原问题转化为一个凸二次规划问题^[8], 或采用贪婪算法如正交匹配追踪算法 (OMP)^[10] 求解。文献^[7,8,10]表明, 相比于凸松弛求解, 贪婪算法求解的信号稀疏表示通常更为稀疏且计算更加高效。

(2) 字典更新 相比于预先设定的字典, 基于数据学习得到的自适应字典通常可以更好地描述数据的本质特征, 有利于模型性能的改善。在给定稀疏表示矩阵 \mathbf{A} 的情况下, 字典更新的过程可表示为

$$\min_{\mathbf{D}} \|\mathbf{X} - \mathbf{D}\mathbf{A}\|_F^2, \quad \text{s.t.} \quad \forall k, \|\mathbf{d}_k\|_2 = 1 \quad (3)$$

式 (3) 为一有约束优化问题, 可通过 MOD^[8], K-SVD^[10] 或者交替投影梯度下降法等算法有效地求解。

3 基于稳健字典学习的 HRRP 目标识别算法

基于稀疏表示理论, 为了获得数据中所有内在的固有模式, 通常将 $\mathbf{D} \in \mathbb{R}^{P \times K}$ 设计为超完备字典 ($P < K$)。然而, 超完备字典的冗余性使得求解信号的稀疏表示会受到观测信号中扰动分量的影响, 带来表示的不确定性, 不利于分类识别任务^[9,11]。本节首先分析 HRRP 样本的目标特性, 然后针对临近样本间的幅度扰动特性, 设计了一种稳健的字典学习算法。

3.1 HRRP 特性分析

对于 HRRP 目标识别任务, 由于方位敏感性的存在, 当目标姿态相对雷达发生变化时, 即使在散射中心结构保持不变的方位帧内, 各距离单元内的散射点到雷达的距离会有不同程度的变化, 从而导致 HRRP 幅度发生起伏。此外, 宽带检测识别中的噪声分量、闪烁效应、奇异样本也会引起 HRRP 幅度的变化。这些因素都将影响稀疏表示的稳健求解。

图 1 给出了在散射点不发生越距离单元走动的方位角内 (定义为一个方位帧) 的一组 HRRP 样本。结果显示, 同一方位帧内的临近 HRRP 样本间具有强的结构相似性, 但同时也存在一定的幅度扰动 (图 1 中阴影部分)。下一小节将针对临近 HRRP 样本间




图1 一个方位帧内的 HRRP 样本

的幅度扰动现象，提出一种稳健字典学习(SDL)算法。

3.2 基于 SDL 的 HRRP 目标识别

对于 HRRP 目标识别而言，能否获得信号的稳健稀疏表示很大程度上取决于如何有效消除字典原子间冗余性的影响。为此，本节提出了一种稳健字典学习(SDL)算法。SDL 主要通过以下 3 种方式实现信号的稳健稀疏表示：首先，采用结构化的稀疏约束，限定临近训练样本间稀疏表示的非零元素位置相同，减少冗余原子的出现，避免了同类样本在表示空间可能出现的失配问题，保持了帧内样本间的结构相似性；其次，通过边缘化信号丢失，构建稳健损失函数，减少了原子间的互适应性，实现去冗余化；最后，通过学习得到的结构化稀疏约束，自适应地选择最优子字典用于测试样本的分类，避免了采用全局超完备字典所带来的冗余性。这样的模型构架不仅具有稳健的稀疏描述能力，而且一定程度上使 HRRP 的帧内结构特性得到保持。算法训练、测试阶段的具体描述如下。

3.2.1 SDL 训练阶段 给定第 c 类目标的训练样本集 $\mathbf{X}_c \in \mathbb{R}^{P \times N_c}$ ，其中 $c = 1, 2, \dots, C$ ， C 为目标类别总数。基于前文描述，将 \mathbf{X}_c 等间隔划分为 L_c 帧，即 $\mathbf{X}_c = [\mathbf{X}_{c,1}, \mathbf{X}_{c,2}, \dots, \mathbf{X}_{c,L_c}] \in \mathbb{R}^{P \times N_c}$ ， $\mathbf{X}_{c,l}$ 中训练样本数为 $N_{c,l}$ 。SDL 算法训练阶段的具体实现如下。

步骤 1 稳健稀疏编码：训练阶段，编码算法的目的在于计算训练样本 \mathbf{X}_c 在字典 \mathbf{D}_c 下的稳健稀疏表示。当给定字典 \mathbf{D}_c 时，不同帧稀疏表示 $\mathbf{A}_{c,l}$ 的计算相互独立，稳健稀疏编码可表示为

$$\left. \begin{aligned} \min_{\mathbf{A}_{c,l}} \|\mathbf{X}_{c,l} - \mathbf{D}_c \mathbf{A}_{c,l}\|_F^2 \\ \text{s.t. } \|\mathbf{a}_{c,l}^i\|_0 \leq T, \text{ supp}(\mathbf{a}_{c,l}^i) = \text{supp}(\mathbf{a}_{c,l}^j) \\ \forall i, j = 1, 2, \dots, N_{c,l} \end{aligned} \right\} \quad (4)$$

其中 $\mathbf{a}_{c,l}^i$ 为第 c 类目标第 l 帧中第 i 个训练样本的稀疏表示， $\text{supp}(\mathbf{a})$ 用于计算向量 \mathbf{a} 中非零元素出现的位置。为避免生成退化的稀疏解， $\mathbf{D}_c = [\mathbf{d}_1, \mathbf{d}_2,$

$\dots, \mathbf{d}_K] \in \mathbb{R}^{P \times K}$ 中每一原子均采用 l_2 范数归一。求解式(4)的详细算法流程如表 1 所示。

表1 SDL稳健稀疏编码算法

(1)算法输入：训练样本集 $\mathbf{X}_{c,l} = \{\mathbf{x}_{c,l}^i\}_{i=1}^{N_{c,l}}$ ，稀疏度 T ，初始化类字典 \mathbf{D}_c (\mathbf{D}_c 中各原子 l_2 范数归一)；
(2)参数设定：索引集 $\Lambda = \emptyset$ ， $\mathbf{D}_\Lambda = \emptyset$ ，信号余量 $\mathbf{r}_{c,l}^i = \mathbf{x}_{c,l}^i$ ， $n = 0$ ；
(3)寻找最优匹配原子的索引位置：
$\beta = \arg \max_{k=1,2,\dots,K} \sum_{i=1}^{N_{c,l}} (\mathbf{d}_k^T \mathbf{r}_{c,l}^i)^2 \quad (5)$
(4)更新索引集及对应的字典子集：
$\Lambda := \Lambda \cup \beta, \mathbf{D}_\Lambda := [\mathbf{D}_\Lambda, \mathbf{d}_\beta] \quad (6)$
(5)更新稀疏表示，重构信号以及信号余量：
$\mathbf{a}_{c,l}^i = \arg \min_{\mathbf{a}} \ \mathbf{x}_{c,l}^i - \mathbf{D}_\Lambda \mathbf{a}\ _2^2 = (\mathbf{D}_\Lambda^T \mathbf{D}_\Lambda)^{-1} \mathbf{D}_\Lambda^T \mathbf{x}_{c,l}^i \quad (7)$
$\hat{\mathbf{x}}_{c,l}^i = \mathbf{D}_\Lambda \mathbf{a}_{c,l}^i \quad (8)$
$\mathbf{r}_{c,l}^i = \mathbf{x}_{c,l}^i - \mathbf{D}_\Lambda \mathbf{a}_{c,l}^i \quad (9)$
(6)令 $n := n + 1$ 。若 $n < T$ ，跳转至步骤(3)；
(7)输出稀疏表示矩阵 $\mathbf{A}_{c,l}$ 。

步骤 2 边缘化信号丢失下的字典更新：

$$\left. \begin{aligned} \min_{\mathbf{D}_c} E_{\mathbf{r} \sim \text{Bernoulli}(p)} \left[\sum_{l=1}^{L_c} \sum_{i=1}^{N_{c,l}} \|\mathbf{x}_{c,l}^i - \mathbf{D}_c (\mathbf{a}_{c,l}^i \cdot \mathbf{r})\|_2^2 \right] \\ \text{s.t. } \|\mathbf{d}_c^k\|_2 = 1, \forall k = 1, 2, \dots, K \end{aligned} \right\} \quad (10)$$

其中 \cdot 为点乘运算。随机变量 \mathbf{r} 服从均值 p (保留概率 $p \in [0, 1]$) 的伯努利分布， E 表示期望算子。传统蒙特卡罗信号丢失(Monte-Carlo dropout)技术通过 \mathbf{r} 随机采样全局网络中的子网络进行学习，有效地避免了小训练样本集大规模参数情况下可能出现的过学习现象，减少了原子间的互适应性，被广泛应用于深层网络理论^[12-15]。为了将信号丢失与字典学习理论有效结合，SDL 通过边缘化随机变量 \mathbf{r} (求解期望)获得了解析的目标函数，避免了传统蒙特卡罗信号丢失繁冗的迭代过程，更利于优化问题的求解。式(10)的解析表达为

$$\left. \begin{aligned} \min_{D_c} & \|X_c - pD_c A_c\|_F^2 + p(1-p)\|D_c \Gamma\|_F^2 \\ \text{s.t.} & \quad \|\mathbf{a}_c^k\|_2 = 1, \forall k = 1, 2, \dots, K \end{aligned} \right\} \quad (11)$$

其中 $\Gamma = (\text{diag}(A_c A_c^T))^{1/2}$, $\text{diag}(\cdot)$ 为对角化操作。基于学习得到的稀疏表示矩阵 A_c , 式(11)的解为

$$D_c^* = \text{norm}\left(X_c A_c^T [p A_c A_c^T + (1-p)\Gamma \Gamma^T]^{-1}\right) \quad (12)$$

其中 $\text{norm}(\cdot)$ 为矩阵列 l_2 范数归一化算子。

步骤3 重复迭代步骤1~步骤2, 直至达到终止条件。

3.2.2 SDL 测试阶段 如前文所述, 传统的稀疏编码方法(式(2))对扰动噪声较为敏感。针对这一问题, 这里构建一种新的损失函数, 用于计算测试样本 \mathbf{y} 在类别字典 $D_{c,l}^*$ 下的稀疏表示 $\beta_{c,l}^*$ 。

$$\beta_{c,l}^* = \arg \min_{\beta_{c,l}} \|\mathbf{y} - D_{c,l}^* \beta_{c,l}\|_2, \text{ s.t. } \|\beta_{c,l}\|_0 \leq T \quad (13)$$

令 $D_{c,l}^* = \{\mathbf{a}_c^k \mid \|\mathbf{a}_c^k\|_2 > 0\}$, \mathbf{a}_c^k 为训练样本稀疏表示矩阵 $A_{c,l}$ 的第 k 行, 类别子字典 $D_{c,l}^* \in \mathbb{R}^{P \times |D_{c,l}^*|}$ 由所有 $\mathbf{a}_c^k \in D_{c,l}^*$ 构成。式(13)利用结构化稀疏约束, 通过最优优化算法自适应地选择最优类别子字典, 避免了采用全局超完备字典带来的冗余性。具体算法实现如表2所示。

表2 SDL测试阶段的算法实现

- (1) 基于训练样本的稀疏表示矩阵 $A_{c,l}$, 计算类别子字典 $D_{c,l}^*$;
- (2) 依式(13), 计算测试样本 \mathbf{y} 的在子字典 $D_{c,l}^*$ 下的稀疏表示 $\beta_{c,l}^*$;
- (3) 依信号丢失理论^[12-15], 计算测试样本在全局类别字典 D_c^* 下对应的最优帧号:

$$\tilde{l}_c = \arg \min_{l=1,2,\dots,L_c} \|\mathbf{y} - p D_{c,l}^* \beta_{c,l}^*\|_2 \quad (14)$$

- (4) 分别计算测试样本 \mathbf{y} 对不同类别字典的重构误差:

$$r_c(\mathbf{y}) = \min_{l=1,2,\dots,L_c} \|\mathbf{y} - p D_{c,\tilde{l}_c}^* \beta_{c,\tilde{l}_c}^*\|_2 \quad (15)$$

- (5) 判决测试样本 \mathbf{y} 的目标类别:

$$I(\mathbf{y}) = \arg \min_{c=1,2,\dots,C} r_c(\mathbf{y}) \quad (16)$$

4 实验结果与分析

4.1 实验数据介绍

本文采用国内某所逆合成孔径雷达(ISAR)测量的飞机数据。实验飞机有3种, 其中“雅克-42”为中型喷气飞机, “奖状”为小型喷气飞机, “安-26”为中小型螺旋桨飞机。飞机航迹投影如图2所示。与文献[1-7]相同, 本文选择“雅克-42”的第2, 5段, “奖状”的第6, 7段, “安-26”的第5, 6段数据作为训练样本, 用于学习稳健字典参数; 其余段数据作为测试样本用来验证算法性能。

由于HRRP存在幅度, 平移敏感性问题, 所以需要考虑相应的敏感性预处理。HRRP的幅度敏感性问题是指目标的HRRP幅度会受雷达发射功率、天线增益和目标距离等测量条件的影响。本文对HRRP进行 l_2 范数归一化, 以消除样本的幅度敏感性。HRRP的平移敏感性是由于目标运动导致HRRP在距离波门中发生平移。本文依文献[3,4]采用具有平移不变性的功率谱特征作为输入信号用来消除平移敏感性问题, 相应的信号维度 $P = 128$ 。

4.2 实验结果分析

实验1 识别性能对比分析 图3实验分别比较了8种模型的识别性能, 其中MCC^[4], FA^[6], AGC^[7]是常规的统计识别算法, PCA^[5]及3种字典学习算法K-SVD^[7], MOD^[8], SDL则基于最小重构误差准则实现分类识别, CDA^[3]为有监督的特征学习方法, 其分类器采用最近邻分类器(NN)。从特征维度的角度看, CDA, PCA和FA将原始观测投影到某一低维(隐)表示空间, MCC和AGC维度不变, K-SVD, MOD和SDL则能获得信号的超完备稀疏表示。实验1中训练样本数为2800, 测试样本数为1200。

图3结果显示, CDA在所有基于低维表示的识别算法中具有最优的识别性能(89.81%), 其识别精度略高于MOD, 低于SDL大约3%。由此可见, 获得信号的超完备稀疏表示有利于挖掘数据的内在结构信息, 从而改善识别性能。3种字典学习方法中, SDL有效抑制了临近样本间的扰动现象带来的




图2 雅克-42、奖状和安-26飞机的航迹图




图 3 不同算法的识别性能比较

稀疏表示不确定性，因此获得了最优的识别性能，达到 92.30%，而传统字典学习算法 K-SVD, MOD 的识别精度甚至低于或是仅与 CDA 的识别精度相当。这表明，传统的基于信号超完备稀疏表示的字典学习算法容易受到信号间扰动分量的影响，导致无法获得稳健的稀疏表示，限制了其识别性能，而 SDL 可以有效解决这一问题。

实验 2 SDL 稳健性能分析 表 3 给出了 SDL 中稳健约束对识别性能的影响。若不考虑临近样本间的结构化稀疏约束，且设置保留概率 $p = 1$ ，则 SDL 退化为 MOD；若考虑临近样本间的结构化稀疏约束且令 $p = 1$ ，则 SDL 中不包含边缘化信号丢失部分；若设置 SDL 中 $p < 1$ ，模型既带有结构化稀疏约束且包含边缘化信号丢失。

表 3 结果显示，通过引入结构化稀疏约束可以有效改善算法的识别性能，而且结合边缘化信号丢失技术的算法识别性能更优。这进一步说明 SDL 算法能够保持 HRRP 的帧内结构特性，减少幅度扰动、噪声闪烁和奇异样本^[4]对识别算法的影响，有利于获得稳健的稀疏特征表示。

实验 3 不同训练样本数下识别性能分析 实际应用中，HRRP 的训练样本数量是有限的。在这种情况下训练得到的模型往往容易出现过学习现象，影响算法的推广性能^[6,7]。实验 3 比较分析了不同训练样本数条件下不同算法的识别性能变化曲线，检验了算法在小训练样本情况下的泛化能力。

图 4 中，统计模型 AGC, FA 需对各帧数据单独建模，具有较高的模型自由度，因此参数估计精度会随训练样本数的减少而显著下降，导致识别性能的恶化。CDA, PCA 为全局识别算法，但其构建的

低维表示仅具有有限的数据描述能力，影响了识别精度。MCC 虽然稳健性能较好，但其过于简单的模型构造限制了其识别性能。而字典学习算法如：SDL, K-SVD 及 MOD，通过在不同帧间共享类别信息，构建了全局的超完备字典，减少了对各帧样本数的需求，因此其识别性能较好，且未随训练样本数的减少发生明显变化。3 类字典学习算法中，SDL 在小样本情况下同样具有最优的识别性能，表明其具有良好的泛化能力。

实验 4 噪声稳健性能分析 在实际战场中，受目标距离雷达远近、目标特定方位反射特性和大气状况等条件的影响，目标回波中总是不可避免地含有噪声，导致测试与训练样本间信噪比失配，识别性能恶化。因此，噪声稳健性是衡量 HRRP 目标识别算法实用与否的重要指标。具体的信噪比 SNR 定义为

$$SNR = 10 \times \lg \left(\frac{\bar{P}_s}{P_n} \right) = 10 \times \lg \left(\frac{\sum_{i=1}^I P_{s_i}}{I \times P_n} \right) \quad (17)$$

其中 \bar{P}_s 表示原始 HRRP 的平均功率， P_{s_i} 为每个距离单元的信号功率， I 为距离单元数， P_n 为噪声功率。本节实验将分析比较不同信噪比条件下各种算法的识别性能变化情况。

图 5 给出了各类算法识别率随信噪比的变化曲线。可以看到，随着信噪比的降低，所有方法的识别性能均出现了不同程度的下降。这是因为噪声分量的存在使得各类目标的回波差异变小。当 SNR > 20 dB 时，SDL 具有最高的识别精度。当 SNR ≤ 20 dB 时，SDL 的识别性能相近或略优于 K-SVD 和 CDA 算法，但仍然明显优于其他算法。实验结果表明 SDL 对噪声具有一定的稳健性。

5 结论

传统字典学习算法由于原子间存在冗余性，在求解信号稀疏表示时会受到观测信号中扰动分量的影响，不利于分类识别。为此，该文提出了一种稳健字典学习(SDL)算法用于雷达 HRRP 目标识别。该算法通过边缘化信号丢失，构建稳健损失函数来学习自适应字典，减少了原子间的相互依赖性，避

表 3 SDL 中稳健约束对识别性能的影响 (%)

识别算法	MOD			SDL($p = 1$)			SDL($p = 0.9$)		
	雅克-42	奖状	安-26	雅克-42	奖状	安-26	雅克-42	奖状	安-26
雅克-42	96.67	0.33	3.00	96.67	0.33	3.00	97.33	0.00	2.67
奖状	2.44	82.00	15.56	0.44	90.44	9.11	0.44	91.56	8.00
安-26	7.11	6.44	86.44	3.56	7.56	88.89	3.78	8.22	88.00
平均识别率	88.37			92.00			92.30		




图4 不同训练样本数下的识别性能比较




图5 噪声稳健性性能分析比较

免了参数的过学习现象。结合距离像在散射点不发生 MTRC 的方位帧内具有相似的物理特性,通过约束临近训练样本间稀疏表示的非零元素位置相同,使得 HRRP 帧内结构信息在表示空间得到保持,并利用学习得到的结构化稀疏约束,自动地选择最优子字典用于测试样本的分类。基于实测 HRRP 数据的实验结果表明,SDL 算法提高了识别性能,而且具有较好的稳健性和泛化能力。

参考文献

- [1] Chen B, Liu H W, Chai J, *et al.* Large margin feature weighting method via linear programming[J]. *IEEE Transactions on Knowledge Data Engineering*, 2009, 21(10): 1475-1488.
- [2] 潘勉,王鹏辉,杜兰,等.基于TSB-HMM模型的雷达高分辨距离像目标识别算法[J].*电子与信息学报*, 2013, 35(7): 1547-1554.
Pan Mian, Wang Peng-hui, Du Lan, *et al.* Radar HRRP target recognition based on truncated stick-breaking hidden Markov model[J]. *Journal of Electronics & Information Technology*, 2013, 35(7): 1547-1554.
- [3] Chai J, Liu H W, and Bao Z. Combinatorial discriminant analysis: supervised feature extraction that integrates global and local criteria[J]. *Electronics Letters*, 2009, 45(18): 934-935.
- [4] Du L, Liu H W, Bao Z, *et al.* Radar HRRP target recognition based on higher-order spectra[J]. *IEEE Transactions on Signal Processing*, 2005, 53(7): 2359-2368.
- [5] Du L, Liu H W, Bao Z, *et al.* Radar automatic target recognition using complex high-resolution range profiles[J]. *IET Radar, Sonar, Navigation*, 2007, 1(1): 18-26.
- [6] Du L, Liu H W, Wang P H, *et al.* Noise robust radar HRRP target recognition based on multitask factor analysis with small training data size[J]. *IEEE Transactions on Signal Processing*, 2012, 60(7): 3546-3559.
- [7] 冯博,杜兰,张学峰,等.基于字典学习的雷达高分辨距离像目标识别[J].*电波科学学报*, 2012, 27(5): 897-905.
Feng Bo, Du Lan, Zhang Xue-feng, *et al.* Radar HRRP target recognition based on dictionary learning[J]. *Chinese Journal of Radio Science*, 2012, 27(5): 897-905.
- [8] Tošić I and Frossard P. Dictionary learning[J]. *IEEE Signal Processing Magazine*, 2011, 28(2): 27-38.
- [9] Donoho D L, Elad M, and Temlyakov V. Stable recovery of sparse overcomplete representations in the presence of noise[J]. *IEEE Transactions on Information Theory*, 2006, 52(1): 6-18.
- [10] Aharon M, Elad M, and Bruckstein A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
- [11] Wang H, Nie F P, and Huang H. Robust and discriminative self-taught learning[C]. International Conference on Machine Learning (ICML-13), Atlanta, Georgia, USA, 2013: 298-306.
- [12] Hinton G E, Srivastava N, Krizhevsky A, *et al.* Improving neural networks by preventing co-adaptation of feature detectors[OL]. <http://arxiv.org/abs/1207.0580>, 2012.
- [13] Bengio Y. Neural Networks: Tricks of the Trade[M]. Berlin Heidelberg: Springer, 2012: 437-478.
- [14] Wan L, Zeiler M, Zhang S X, *et al.* Regularization of neural networks using DropConnect[J]. *JMLR W&CP*, 2013, 28(3): 1058-1066.
- [15] Srivastava N. Improving neural networks with dropout[D]. [Ph.D. dissertation], University of Toronto, 2013.

冯博: 男, 1988年生, 博士生, 研究方向为雷达自动目标识别。

陈渤: 男, 1979年生, 博士, 教授, 博士生导师, 研究方向为雷达目标识别、统计信号处理、统计机器学习、深度学习网等。

王鹏辉: 男, 1984年生, 博士, 讲师, 研究方向为雷达自动目标识别以及统计机器学习理论等。

刘宏伟: 男, 1971年生, 博士, 教授, 博士生导师, 研究方向为雷达信号处理、雷达自动目标识别、认知雷达、协同探测等。

严俊坤: 男, 1987年生, 博士生, 研究方向为统计信号处理、认知雷达、协同探测等。