

一种面向信号分类的匹配追踪新方法

王磊* 周乐园 姬红兵 林琳
(西安电子科技大学电子工程学院 西安 710071)

摘要: 匹配追踪(MP)的主要策略是通过每次迭代时选择一个局部最优解,从而逐步逼近原始信号。然而传统的MP系列算法进行原子匹配时,各类原子集间存在交集,从而影响了原子的表示能力以及相应的分类效果。基于此,该文提出一种适用于信号监督分类的匹配追踪新算法。其原子挑选的准则为:同类信号采用相同的原子集匹配,获取相同的类内表示结构;异类信号选择不同的原子集匹配,从而增强信号的类间差异。示例分析表明,使原子集间相互独立,能够减少异类信号间的共性因素,强化信号间的区分度,从而有利于提升分类识别效果。通过在标准图像库和实测雷达辐射源信号集上的实验表明,较之传统的MP系列方法,所提算法对噪声和遮挡具有更强的鲁棒性。

关键词: 匹配追踪; 雷达辐射源识别; 稀疏表示; 特征提取; 监督分类

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2014)06-1299-08

DOI: 10.3724/SP.J.1146.2013.00942

A New Matching Pursuit Algorithm for Signal Classification

Wang Lei Zhou Le-nan Ji Hong-bing Lin Lin
(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

Abstract: The main idea of Matching Pursuit (MP) is to get a local optimal solution by iteration, so as to gradually approach the original signal. To cope with the intersection of different atom sets, which may affect the classification performance of conventional MP methods, a new matching pursuit algorithm is proposed, which is suitable for supervised classification. The criterion for atoms selection consists of two parts. On one hand, by using the same atom set within the class, the intra-class structure of the similar signals is obtained for class-representation; on the other hand, by selecting the atom sets independently for every class, the discrimination ability for different classes could be further strengthened. The analysis on a toy example indicates that this scheme reduces the common factors between different classes and highlights the discrimination between signals, which may boost the performance of signal classification. Finally, the experiments on benchmark image databases and the measured radar emitter signals verify that the proposed algorithm achieves better robustness against noise and occlusion, compared with the convention MP-related methods.

Key words: Matching Pursuit (MP); Radar emitter identification; Sparse representation; Feature extraction; Supervised classification

1 引言

稀疏表示又称为稀疏分解,其主要思想是用冗余函数库取代传统的基函数,构造过完备字典,根据信号的特点,从冗余字典中找到原子数目最少且重构效果最佳的线性组合。作为信号的稀疏表达^[1-4]。寻找信号的稀疏分解主要有两种途径,一类称为凸松弛算法,虽然能够获得全局最优解,但

是计算复杂度较高^[5];另一类称为贪婪算法,也叫匹配追踪类算法,其主要思想是通过每次迭代时选择一个局部最优解从而逐步逼近原始信号,由于其简单、高效,对该类方法的研究成为压缩感知领域的一个研究热点。对于这一分支的发展而言,经典的方法包括有:最原始的匹配追踪算法(Matching Pursuit, MP)^[6],正交匹配追踪算法(Orthogonal Matching Pursuit, OMP)^[7,8],正则化正交匹配追踪算法(Regularized OMP, ROMP)^[9],分段匹配追踪算法(Stagewise OMP, StOMP)^[10],压缩采样匹配追踪算法(Comprehensive Sampling Matching Pursuit, CoSaMP)以及子空间追踪算法(Subspace

2013-07-01 收到, 2014-01-08 改回

国家自然科学基金(61203137), 高等学校博士学科点专项科研基金(20120203120010)和中央高校基本科研业务费专项资金(K5051302011, K5051302039)资助课题

*通信作者: 王磊 leiwang@mail.xidian.edu.cn

Pursuit, SP)^[11,12]等。

沿该类算法的发展脉络进行分析, 作为最原始的贪婪算法, MP 算法经过一定次数的迭代, 信号可以由候选集合中的原子线性表示。但是由于信号在候选原子集合上的投影是非正交性的, 导致每次迭代逼近的结果可能是次优的, 因而算法为获得收敛需要较多次迭代; OMP 算法沿用了匹配追踪算法中原子挑选的准则, 并递进地对已选择原子集合进行正交化以保证逼近的最优性, 从而减少了迭代次数; 进一步, ROMP 算法在正则化过程中进行原子的二次筛选, 确保了挑选原子的能量远大于被剔除的原子; StOMP 算法每次可以选取多个原子, 因此运算速度较快, 适用于大规模信号重构问题; CoSaMP 算法和 SP 算法是两种相似的算法, 它们都采用了一种回退策略进行原子剔除, 在保证重构效果精确的同时, 可以提供比 OMP 算法和 ROMP 算法更优的理论保证。

上述算法虽然可以通过迭代匹配得到较为精确的结果, 但是每次只能获得单个信号在匹配字典下的局部最优解, 也就是说 N 个信号需要运算 N 次, 不仅耗时, 而且匹配时由于只考虑信号自身而未从信号集的角度进行衡量, 造成挑选的原子集各异, 得到的总的原子数目过多, 因而信号的类内和类间信息不易区分, 不适合于分类任务。基于此, 本文提出了一种新颖的监督型匹配追踪算法, 其不仅借鉴了有监督的匹配追踪方法的思想, 而且发展了“原子独立性”的概念, 使得原子集间相互独立, 减少异类信号间的共性因素, 从而强化信号间的区分度, 有效地提升了信号分类的性能, 并体现了对于噪声和遮挡的鲁棒性。

本文其余内容安排如下, 第 2 节概述了经典的匹配追踪分类算法; 第 3 节提出了基于原子独立约束的新算法, 并给出了示例分析; 第 4 节通过标准图像库和雷达辐射源数据库上的分类实验验证了所提算法的有效性; 最后对所提算法进行了总结, 并展望下一步的研究工作。

2 匹配追踪分类算法

在相同字典下, 对多信号同步进行原子分解有利于从全局角度进行特征提取, 能部分改善前述问题。虽然从图像重建角度看, 相应的匹配结果并不精确, 但得到的稀疏系数却比较适合于特征表示与分类。

2.1 SSOMP 算法

2005 年, Tropp 等人^[13]在 OMP 算法的基础上, 提出了在共享原子集下同时分解多个信号的同步正

交匹配追踪算法 (Simultaneous Orthogonal Matching Pursuit, SOMP), 该算法在降低了挑选原子总数的同时, 也实现了同时对多个信号的稀疏分解, 提高了原子匹配的效率。稀疏表示不仅是信号重构的基础, 也是实现各类信号和图像分类的有效途径。如果将得到的稀疏系数看作信号在冗余字典下的变换特征, 设计相应的分类器, 即可完成对信号的分类识别任务。

给定信号集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_K]$ 在冗余字典 \mathbf{D} 下的稀疏表达为 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_K]$, 将 SOMP 算法视为分类算法时, 其目标函数的设定为

$$J_1(\mu, \mathbf{A}) = \min \left(\sum_{i=1}^K \|\mathbf{x}_i - \mathbf{D}\mathbf{a}_i\|_2^2 + \mu \sum_{i=1}^K \|\mathbf{a}_i\|_1 \right) \quad (1)$$

这里 μ 表示重构误差项与稀疏项之间的调节系数。

2.2 SSOMP 算法

对于信号的重构而言, 只需考虑重构误差项和稀疏项, 但对于分类任务来说, 这样的目标函数则有明显的局限性。若想通过优化目标函数得到的稀疏系数具有显著的分类效果, 就要保证投影系数稀疏的同时, 还要使非同类信号的系数间拥有足够大的类间距离和尽可能小的类内距离, 这就是在目标函数中加入 Fisher 鉴别项, 发展有监督的 SOMP 分类算法的原因。2007 年文献[14]提出的 SRSC (Sparse Representation for Signal Classification) 算法以及文献[15]提出的 SSOMP (Supervised Simultaneous Orthogonal Matching Pursuit) 算法就是引入 Fisher 鉴别项的较为相似的信号分类算法。它们的核心思想即是通过调节鉴别项在目标函数中所占的比重以获得最优的分类效果。如式(2)所示, 当 $\theta = 0$ 时, 式(2)便退化成式(1), 即有监督退化成无监督的情形。

$$J_2(\mu, \theta, \mathbf{A}) = \max \left(F(\mathbf{A}) \cdot \theta - \sum_{i=1}^K \|\mathbf{x}_i - \mathbf{D}\mathbf{a}_i\|_2^2 - \mu \sum_{i=1}^K \|\mathbf{a}_i\|_1 \right) \quad (2)$$

这里 θ 表示 Fisher 鉴别项在目标函数中所占的比重。 K 个样本分属 C 个类别, 第 C_j 类包含 K_j 个样本 ($1 \leq j \leq C$), 其均值和方差分别为 m_j 和 s_j^2 , 总的样本均值为 m 。式(2)中的 Fisher 鉴别项定义如下:

$$F(\mathbf{A}) = \frac{S_b}{S_w} = \frac{\left\| \sum_{j=1}^C K_j (m_j - m)(m_j - m)^T \right\|_2^2}{\sum_{j=1}^C s_j^2} \quad (3)$$

这里 $m_j = \frac{1}{K_j} \sum_{\mathbf{a} \in C_j} \mathbf{a}$, $s_j^2 = \frac{1}{K_j} \sum_{\mathbf{a} \in C_j} \|\mathbf{a} - m_j\|_2^2$, $m =$

$\frac{1}{K} \sum_{i=1}^K \mathbf{a}_i$, S_b 称为类间距离, S_w 称为类内距离, 式(3)

的引入可以使得信号的稀疏表达系数具有最大的类间距离和最小的类内距离, 从而最大化 Fisher 鉴别信息。

2.3 CSSOMP 算法

虽然引入了监督思想, 但是 SRSC 和 SSOMP 算法往往适用于提取一类信号的相同内在结构。随着信号类别的增加, 这种相同的内在结构逐渐减少直至消失, 取而代之的则是信号的类间差异逐步增大, 此时, 用上述算法同时匹配多类信号所需的原子数目将远多于单一处理某一类信号的情况, 从而造成匹配原子的冗余性; 另一方面, 稀疏表示获取了更多的类内信息而非类间信息, 从而降低了分类效果。

基于上述考虑, 2008 年文献[16]提出了类依赖的 SSOMP(Class SSOMP, CSSOMP)算法, 目的在于获得信号相同类内结构的同时, 使得类间具有很好的全局区分度, 其目标函数为

$$J_3(\mu, \theta, \mathbf{A}) = \max \left(F(\mathbf{A}) \cdot \theta - \sum_{j=1}^C \sum_{i=1}^{K_j} \|\mathbf{x}_i^j - \mathbf{D}\mathbf{a}_i^j\|_2^2 - \mu \sum_{j=1}^C \sum_{i=1}^{K_j} \|\mathbf{a}_i^j\|_1 \right) \quad (4)$$

CSSOMP 算法的最大进步在于: 对于待分类的信号不再采取单一的原子集, 而是根据信号的类别进行区分。也就是说, 同类信号选取相同的原子集, 减小类内的重构误差, 获取信号间相同的类内结构; 而非同类信号寻找各自最匹配的原子集, 使信号间的区分性得以体现, 从而在一定程度上解决了上述分析的第 1 个问题, 即匹配原子的冗余性。

3 基于 MP 的监督分类新算法

针对在原子匹配时各类原子集存在交集从而影响分类性能的问题, 本文引入了原子独立性的思想, 使得获取的信号类间结构具有最大的相异度。将该策略融入 CSSOMP 算法, 本文将所提新分类方法称为改进的 CSSOMP(Modified CSSOMP, MCSSOMP)算法。

3.1 MCSSOMP 算法

MCSSOMP 算法的原子匹配准则为: 同类信号匹配时挑选相同的原子集, 并使之线性独立, 最大化地提取出同类信号内的相同结构; 异类信号匹配时挑选不同的原子集, 即保证原子集间相互独立无交集, 以期最大化地提取出异类信号间的特征差异。事实上, 当各类的信号投影到相互独立的原子集上时, 同类信号的非零参数将出现在相同的原子集上,

而异类信号的稀疏投影在相同的原子上则无交集。可见这种挑选原子的思路在获取相同类内结构的同时, 能够弱化信号类间的共性信息, 强化所属不同类信号之间的差异, 从而提升分类性能。

体现在目标函数上, MCSSOMP 算法继承了 CSSOMP 算法的优点: 重构误差项按类计算, 而鉴别项则从全局角度考虑。这种局部误差加全局判别的策略, 能够使稀疏表示系数既包含重构信息(信号表征能力), 又具备分类特性。尽管所提算法的目标函数式(5)与 CSSOMP 算法类似, 但其增加了新的独立性约束以指导最优原子的挑选, 因而避免了 CSSOMP 算法所挑选的类内原子集合可能线性相关、不同类原子集合存在交集的缺陷, 增加了原子的利用率, 最大化地提取出同类样本的相同特征和不同类间相互区别的鉴别信息。

$$J_4(\mu, \theta, \mathbf{A}) = \max \left(F(\mathbf{A}) \cdot \theta - \sum_{j=1}^C \sum_{i=1}^{K_j} \|\mathbf{x}_i^j - \mathbf{D}\mathbf{a}_i^j\|_2^2 - \mu \sum_{j=1}^C \sum_{i=1}^{K_j} \|\mathbf{a}_i^j\|_1 \right) \quad (5)$$

MCSSOMP 算法中, 为快速而准确地获取最优解, 最优原子的获取采用的是原子迭代匹配的贪婪方法, 算法由以下核心步骤构成:

首先, 按信号的类别进行算法的初始化, 对于第 q 类样本, 初始化其残差和候选原子支撑集, 迭代次数 $t=1$ 。

其次, 通过优化如下的式(6), 循环迭代挑选出匹配原子 λ :

$$\lambda_1 = \arg \max_{p=1,2,\dots,N} \left\{ \sum_{i=1}^{K_q} \langle \mathbf{r}_i^{q,(t-1)}, \mathbf{d}_p \rangle + \theta \cdot F(\mathbf{A}) \right\} \quad (6)$$

其中 \mathbf{d}_p 表示冗余字典 \mathbf{D} 中的第 p 个原子, K_q 表示第 q 类样本的数目, $\mathbf{r}_i^{q,(t-1)}$ 表示 $t-1$ 时刻第 q 类残差。式(6)中第 1 项实现按类进行原子匹配, 第 2 项则是全局 Fisher 鉴别项。为获取相互独立的原子, 本文主要采用如下操作: 若 $\lambda_1 \in \Gamma_q$ 或 $\lambda_1 \in \Lambda_q^t$, 剔除该原子, 求取满足条件的次优解 λ_2 , 以此类推, 直至获得满足条件的 $\lambda_{ii} \notin \Gamma_q$ 且 $\lambda_{ii} \notin \Lambda_q^t (ii=1,2,\dots)$, 令 $\lambda_i^q = \lambda_{ii}$, 这样得到的原子集间相互独立。这里, λ_i^q 表示第 q 类样本通过单步迭代求得的第 t 个原子的标号 ($1 \leq q \leq C, 1 \leq t \leq L$), Γ_q 表示对前 q 类信号所挑选的原子支撑总集, 而 Λ_q^t 和 Φ_q^t 则分别表示经过 t 次迭代后, 对第 q 类信号所选定的支撑集和原子集。

然后, 根据更新的原子支撑集和重构残差项, 计算出新的稀疏系数。将新挑选的原子加入第 q 类的支撑集 $\Lambda_q^t = \Lambda_{q,t-1}^t \cup \{\lambda_i^q\}$, 计算此时的残差 $\mathbf{r}_i^{q,(t)} = \mathbf{x}_i^j - \hat{\mathbf{x}}_i^{j,(t)}$, 并得到这一步的稀疏系数为 $\mathbf{a}_i^{j,(t)} = (\Phi_i^{q,T} \Phi_i^q)^{-1} \Phi_i^{q,T} \mathbf{x}_i^j$ 。

最后, 保存该类计算的结果, 即当迭代次数满足 $t = L$ 时, 保存第 q 类的重构项 $\hat{\mathbf{x}}_i^{q(L)}$ 和最终得到的稀疏系数 $\hat{\mathbf{a}}_i^{q(L)}$, 并更新总的原子支撑集 $\Gamma_q = \Gamma_{q-1} \cup \Lambda_L^q$ 。

这里将 MCSSOMP 算法的伪码总结如表 1 所示。

表 1 MCSSOMP 的伪码

输入:	信号 $\mathbf{X} \in \mathbb{R}^{M \times K}$, 字典 $\mathbf{D} \in \mathbb{R}^{M \times N}$, 稀疏度 L , Fisher 系数 θ
输出:	挑选的原子支撑总集 Γ_q , 重构信号 $\hat{\mathbf{X}} \in \mathbb{R}^{M \times K}$, 稀疏系数矩阵 $\mathbf{A} \in \mathbb{R}^{N \times K}$
步骤 1	初始化: 类计数器 $q=1$, 原子支撑集 $\Gamma_0 = \emptyset$;
步骤 2	迭代循环选出第 q 类的 L 个匹配原子:
	(a) 第 q 类的残差初始化 $\mathbf{r}_i^{j(0)} = \mathbf{X}^q$, 原子支撑集初始化 $\Lambda_0^q = \emptyset$, 迭代次数 $t=1$;
	(b) 根据式(6)获取独立原子的类标 λ_i^q 。其挑选的策略为: 若 $\lambda_1 \in \Gamma_q$ 或 $\lambda_1 \in \Lambda_t^q$, 剔除该原子, 求取满足条件的次优解 λ_2 , 以此类推, 直至 $\lambda_{ii} \notin \Gamma_q$ 且 $\lambda_{ii} \notin \Lambda_t^q$, 令 $\lambda_i^q = \lambda_{ii}$;
	(c) 更新类内支撑集 $\Lambda_t^q = \Lambda_{t-1}^q \cup \{\lambda_i^q\}$, 更新选定的原子集 $\Phi_t^q = [\Phi_{t-1}^q, \mathbf{d}_{\lambda_i^q}]$;
	(d) 计算新的稀疏系数 $\mathbf{a}_i^{j(t)}$ 和残差 $\mathbf{r}_i^{j(t)}$;
	(e) $t=t+1$, 如果 $t \leq L$, 返回步骤(b);
	(f) 重构的第 q 类信号为 $\hat{\mathbf{x}}_i^{q(L)}$, 稀疏表示系数为 $\hat{\mathbf{a}}_i^{q(L)}$;
步骤 3	保存 $\hat{\mathbf{x}}_i^{q(L)}$ 和 $\hat{\mathbf{a}}_i^{q(L)}$, 更新总的原子支撑集 $\Gamma_q = \Gamma_{q-1} \cup \Lambda_L^q$, $q=q+1$, 若 $q \leq C$, 返回步骤 2;
步骤 4	迭代结束, 带参数返回。

3.2 示例分析

图 1 给出了训练样本类数为 2 的情况下(稀疏度 $L=15$), 4 种分类算法对简单数字图像所挑选的匹配原子示意图。可见监督分类算法挑选的 Haar 字典集中的原子数目明显多于无监督的 SOMP 算法。由于 Haar 字典集中的原子主要用来描述图像的细节信息, 当重构误差项按类计算时, 样本“0”和“1”在 CSSOMP 算法下所挑选的原子, 相比 SSOMP 算法出现了较为明显的区别, 但原子集间仍存在一定交集, 因而影响到信号分类的可区分性。而当引入原子集间相互独立的约束后, 所提 MCSSOMP 算法将信号投影到相应的原子集上时, 得到的稀疏系数在类间有着更好的区分度, 有利于后续分类任务。

4 实验结果和分析

为验证本文算法的性能, 这里比较上述 4 种算法在 USPS 手写体数据库, Extended Yale B 人脸库和雷达辐射源数据下的识别效果。为公平比较, 各实验匹配字典事先给定, 分类阶段均采用最近邻分类器。




图 1 各算法的原子挑选示意图

4.1 USPS 数据库上的实验

实验描述: 从 USPS 手写体数据库^[17]中选取“0”~“9”共 10 类样本(每类 100 个), 每类随机抽取 80 个, 组成 800 个样本的训练集, 其余构成测试集, 选用 DCT 和 Haar 基组成的字典(包含 362 个原子), 用 SOMP, SSOMP, CSSOMP(稀疏度 $L=15$), MCSSOMP($L=10$)算法先进行如下实验: (1)训练图像不加噪, 测试集添加不同信噪比的高斯白噪声; (2)训练图像不遮挡, 测试集受到不同程度遮挡。重复实验 10 次, 求取两种情况下的平均识别率及误差, 结果分别如表 2 和表 3 所示。

综合表 2 和表 3 可见, 4 类算法在无噪声干扰的情况下均能达到 88% 以上的识别率。其中, 有监督的 SSOMP 算法要优于无监督的 SOMP 算法, 但次于按类进行原子挑选的 CSSOMP 算法。随着噪声的增加或遮挡物的增大, 所对比的 3 种算法的识别率都呈显著下降趋势。令人惊喜的是, 本文提出的引入类间原子独立性思想的 MCSSOMP 算法在鲁棒性方面要明显优于其它 3 种算法, 在测试数据受到不同程度噪声干扰或不同程度遮挡的情况下, 都有良好的表现。例如, 本文方法仅在遮挡物边长为 6 时识别率低于 90%, 而此时 SOMP 和 SSOMP 均已低于 40%。

众所周知, 对于贪婪类算法, 匹配原子数目的选择即稀疏度 L 的确定, 在很大程度上影响着稀疏逼近的结果, 因此图 2 给出了稀疏度 L 取值分别为 5, 10, 15, 20, 25 时的各方法识别效果对比图。此时训练样本不加噪声或遮挡, 其它参数的设定与前相同。

通过图 2 可以看到, 随着稀疏度即匹配原子数目的增加(当 $L > 5$ 时), 由于信号更多的细节信息被有效挖掘, SOMP, SSOMP 和 CSSOMP 算法的识别率不断提升, 直至达到较为理想的匹配效果($L=15$)转而平缓, 但随着稀疏度继续增大($L > 15$), 由于共性信息有限而用于匹配的原子数目过多, 出现了过匹配现象, 3 种算法的识别率都有所下降或

表 2 USPS 数据的测试集添加不同信噪比噪声时各算法的识别率(%)

算法	信噪比(dB)				
	无噪声	20	15	10	5
SOMP	88.0±1.9	80.2±3.4	50.6±3.8	16.4±2.8	11.2±0.7
SSOMP	89.5±2.1	80.6±4.5	49.4±3.0	16.3±2.4	11.8±0.8
CSSOMP	98.4±1.7	95.3±3.4	74.0±2.3	33.2±2.3	24.6±1.1
MCSSOMP	99.5±0.3	100±0.5	97.6±0.2	97.5±0.5	95.0±0.2

表 3 USPS 数据的测试集受到不同程度遮挡时各算法的识别率(%)

算法	边长				
	2	3	4	5	6
SOMP	83.2±1.8	71.3±2.5	59.0±3.7	48.1±3.1	37.3±2.2
SSOMP	85.4±1.9	74.3±2.8	62.9±3.5	51.2±3.4	38.9±2.7
CSSOMP	96.9±0.9	94.6±1.9	90.7±1.6	86.8±3.2	76.5±3.1
MCSSOMP	99.7±0.2	99.0±0.7	97.7±0.9	94.3±1.1	85.5±2.9

遇到瓶颈。其中，由于采取了分类匹配原子的思想，CSSOMP 算法的整体性能要优于 SOMP 和 SSOMP 算法。与这 3 种方法不同，本文提出的 MCSSOMP 算法由于强调了原子挑选的独立性，在稀疏度合适的条件下($5 \leq L \leq 20$)，测试信号能够投影到相互独立的原子集上，减少了异类信号间的交集，因此在分类方面具有明显的优势，但随着稀疏度继续增大($L > 20$)，剩余原子已无法更好地表示迭代中产生的残差，故识别率会略有下降。

此外，Fisher 系数 θ 的调节，决定着 Fisher 鉴别项和重构误差项在目标函数中各自所占的比例，也最终影响着分类原子的挑选。图 3 给出了 USPS 数据库下对该参数的实验结果，其中 $\theta \in [0, 3.0]$ ，训练样本不加噪声或遮挡，其它参数的设定与前相同。注意 SOMP 无系数 θ ，这里仅作为基准进行对比。

通过图 3 可以发现，采用相同原子集进行匹配的 SSOMP 算法，与按信号类别采用不同原子集进行匹配的方法(CSSOMP 算法和 MCSSOMP 算法)的识别率随调节参数 θ 的变化呈现出两种不同的趋势。当引入 Fisher 鉴别项后，随着 θ 逐渐增大，SSOMP 算法识别率有了一定提升，当 $\theta \in [1.0, 1.5]$ 时得到其最好的效果，但此后 θ 继续增大，由于极大地削弱了重构误差项所占的比例，目标函数过于依赖鉴别项，导致识别效果逐渐变差。相比之下，当采用不同原子集按类匹配信号策略时，参数 θ 在小范围内($\theta \in [0, 3.0]$)的变化不会对识别效果有较为明显的影响。也就是说，在一定范围内，CSSOMP 算法和 MCSSOMP 算法对于参数 θ 的选取不太敏感。因此后续实验中，与文献[16]类似，参数 θ 取默认值 1。

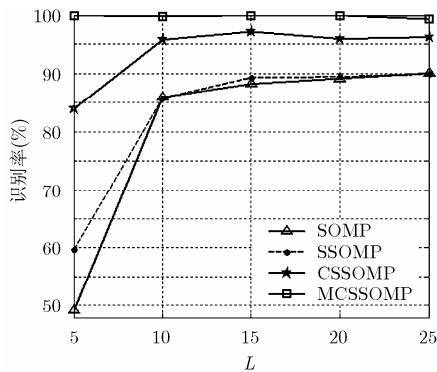


图 2 USPS 数据集上各算法识别率随稀疏度 L 的变化

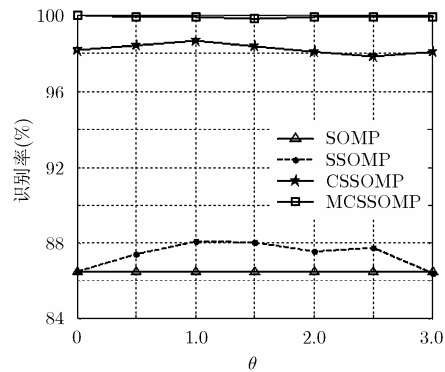


图 3 USPS 数据集上各算法识别率随系数 θ 的变化

4.2 Extended Yale B 数据库上的实验

实验描述: 从 Extended Yale B 人脸数据库^[18]中抽取 5 组人脸图像(每组 64 张), 将每张图像裁剪成 16×16 大小, 每组随机抽取 50 张, 组成 250 个样本的训练集, 其余组成测试集, 字典选择 DCT 基(包含 256 个原子), 对 SOMP, SSOMP, CSSOMP ($L=15$), MCSSOMP($L=8$)算法进行实验: (1)测试集添加不同信噪比的高斯白噪声; (2)测试集受到不同程度遮挡。实验重复 10 次, 求取两种情况下的平均识别率及误差, 结果如表 4 和表 5 所示。

这里, 图 4 和图 5 分别为测试集在受到严重的高斯白噪声污染($SNR=5$ dB)和被严重遮挡(正方形遮挡物边长 $Size=6$)情况下的示例图。从图中可以看




图 4 SNR = 5 dB 时 Extended Yale B 的测试图像



图 5 Size = 6 时 Extended Yale B 的测试图像

到, 此时图像受到干扰的情况较为严重, 已经无法用肉眼辨识出图像原本所属的类别。

结合表 4 和表 5 的实验结果, 可以得到以下几点结论: 首先, 随着噪声的增加和遮挡范围的变大, 4 种分类算法的识别效果都呈下降趋势, 相较而言, 监督型算法对噪声的影响会更加敏感; 其次, 按类挑选匹配原子的策略有利于信号的分类识别, $SNR \geq 15$ dB 时, MCSSOMP 算法和 CSSOMP 算法的识别效果和抗噪能力要明显优于 SSOMP 算法和 SOMP 算法, 但当信噪比低于 15 dB 时, CSSOMP 算法下降明显; 最后, 原子集间相互独立的策略有利于将非同类图像的特征投影到不同的原子集上, 减少异类信号间的共性因素, 强化信号间的区分度, 从而有利于提升分类识别效果。特别地, 即便在图像受到严重的噪声污染(图 4)或遮挡(图 5)的情况下, 本文的 MCSSOMP 算法性能也显著优于另外 3 种方法。

4.3 雷达辐射源数据上的实验

实验描述: 雷达辐射源个体识别是一项具有挑战性的课题^[19], 其目的在于区分具有相同型号和参数的雷达个体, 实测的雷达辐射源数据包含雷达的“指纹”信息和一定程度的噪声干扰。选用 10 组实测雷达辐射源信号组成的数据集, 抽取信号的模糊函数特征^[20]作为特征集, 每组随机抽取 15, 20, 25, 30 个组成训练集, 其余组成测试集, 初始字典选择 DCT 基(包含 450 个原子), 选用 SOMP, SSOMP, CSSOMP ($L=20$), MCSSOMP ($L=10$)算法, 重复 10 次实验求取平均识别率及误差, 结果如表 6 所示。

表 4 Extended Yale B 数据的测试集添加不同信噪比噪声时各算法的识别率(%)

算法	信噪比(dB)				
	无噪	20	15	10	5
SOMP	72.8±7.5	64.4±6.5	45.7±6.2	32.7±3.7	23.8±3.4
SSOMP	76.3±4.4	66.0±6.3	47.9±6.2	31.9±3.8	22.4±3.5
CSSOMP	92.0±5.5	86.9±6.6	61.3±6.2	33.0±3.8	23.3±5.5
MCSSOMP	99.6±0.7	96.0±2.4	88.0±4.6	77.6±4.9	74.1±5.1

表 5 Extended Yale B 数据的测试集受到不同程度遮挡时各算法的识别率(%)

算法	边长				
	2	3	4	5	6
SOMP	65.6±6.9	56.6±5.6	45.3±5.8	43.6±6.3	40.7±4.4
SSOMP	67.1±6.2	57.3±5.1	50.4±6.7	45.6±6.6	39.8±4.6
CSSOMP	87.6±6.1	74.7±4.9	67.8±6.7	63.8±5.0	54.0±5.1
MCSSOMP	98.4±1.4	99.0±1.8	98.3±2.2	98.1±1.3	97.1±1.8

表 6 雷达辐射源数据集中抽取不同数目训练样本时各算法的识别率(%)

算法	训练样本数目			
	15	20	25	30
SOMP	55.13±1.91	60.69±1.82	65.06±2.57	70.68±3.88
SSOMP	54.33±2.10	60.84±1.65	64.77±2.26	70.77±3.65
CSSOMP	68.97±2.09	73.59±1.65	79.11±2.11	84.11±3.20
MCSSOMP	86.99±2.98	92.13±2.91	92.96±2.03	93.01±1.42

可以看到,随着训练样本数目的不断增加,各算法的识别率均有提升,当训练样本数目达到每组 30 个时,4 种算法的平均识别率达到 70%以上。然而对比可见,尽管引入了 Fisher 判别项和按类匹配原子的思想,在训练样本数目相同的情况下,SSOMP 算法的识别率却与 SOMP 十分接近,且分类效果不够理想,相比前两组图像数据库下的实验也有一定的差距。这是因为本组实验采用的是实测雷达辐射源数据集,信号特征的构造与前两组数据集有很大的不同,异类信号间的结构差异十分微小,将其投影在相同的原子集上,微小的结构差异可能被丢失,不利于分类识别。我们认为,SOMP 和 SSOMP 算法应更适合图像信号的分类,对于实测的 1 维信号,它们原子选择的策略具有一定的局限性。

相较而言,本文提出的 MCSSOMP 算法保证了类间原子集匹配时具有很强的独立性,能将异类信号投影到不同的原子集上,类间的差异信息得以保留,因此最大限度地挖掘了雷达信号间的指纹差异,有效地实现了辐射源个体识别任务。而 CSSOMP 算法的性能虽然较之 SOMP 和 SSOMP 算法提升很多(>10%),却也远不及本文所提 MCSSOMP 算法。

5 结束语

本文提出了一种面向信号分类的匹配追踪新方法。MCSSOMP 算法不仅继承了 CSSOMP 算法在类内获取相同结构和在全局把握类间区分性的优点,而且受益于所设计的异类间挑选原子时约束其相互独立的策略,从而最大程度地获取了信号间的差异信息,有效地提升了信号分类的性能。通过在各种图像库和实测雷达信号集上的实验表明,当数据受到噪声干扰或遮挡时,本文算法仍具有较高的鲁棒性。值得注意的是,实验中的冗余字典都是事先给定的,而在实际中,图像或信号的种类是多种多样的,且与每一种信号所对应的字典也不尽相同。如何更好地设计初始字典,亦或者是通过有效的字典学习方法^[21]得到更加合

适的字典集,并自适应地与不同类型信号的分类问题相结合,将是下一步的研究重点。

参考文献

- [1] Elad M. Sparse and redundant representation modeling-what next?[J]. *IEEE Signal Processing Letters*, 2012, 19(12): 922-928.
- [2] 王海涛, 王俊. 基于压缩感知的无源雷达超分辨 DOA 估计[J]. *电子与信息学报*, 2013, 35(4): 877-881.
Wang Hai-tao and Wang Jun. Super-resolution DOA estimation in passive radar based on compressed sensing[J]. *Journal of Electronics & Information Technology*, 2013, 35(4): 877-881.
- [3] 何艳敏, 甘涛, 陈武凡. 基于稀疏表示的两级图像去噪[J]. *电子与信息学报*, 2012, 34(9): 2268-2272.
He Yan-min, Gan Tao, and Chen Wu-fan. Two-stage image denoising based on sparse representations[J]. *Journal of Electronics & Information Technology*, 2012, 34(9): 2268-2272.
- [4] 解志斌, 薛同思, 田雨波, 等. 一种稀疏增强的压缩感知 MIMO-OFDM 信道估计算法[J]. *电子与信息学报*, 2013, 35(3): 665-670.
Xie Zhi-bin, Xue Tong-si, Tian Yu-bo, et al. A sparsity enhanced channel estimation algorithm based on compressed sensing in MIMO-OFDM systems[J]. *Journal of Electronics & Information Technology*, 2013, 35(3): 665-670.
- [5] Candes E J, Eldar Y C, Needell D, et al. Compressed sensing with coherent and redundant dictionaries[J]. *Applied and Computational Harmonic Analysis*, 2011, 31(1): 59-73.
- [6] Mallat S G and Zhang Z. Matching pursuits with time-frequency dictionaries[J]. *IEEE Transactions on Signal Processing*, 1993, 41(12): 3397-3415.
- [7] Pati Y C, Rezaifar R, and Krishnaprasad P S. Orthogonal matching pursuit: recursive function approximation with applications to wavelet decomposition[C]. The IEEE Twenty-Seventh Asilomar Conference on Signals, Systems and Computers, Pacific Grove, USA, 1993: 40-44.
- [8] Tropp J A and Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. *IEEE Transactions on Information Theory*, 2007, 53(12):

- 4655–4666.
- [9] Needell D and Vershynin R. Uniform uncertainty principle and signal recovery via regularized orthogonal matching pursuit[J]. *Foundations of Computational Mathematics*, 2009, 9(3): 317–334.
- [10] Donoho D L, Tsaig Y, Drori I, *et al.* Sparse solution of underdetermined systems of linear equations by stagewise orthogonal matching pursuit[J]. *IEEE Transactions on Information Theory*, 2012, 58(2): 1094–1121.
- [11] Needell D and Tropp J A. CoSaMP: iterative signal recovery from incomplete and inaccurate samples[J]. *Applied and Computational Harmonic Analysis*, 2009, 26(3): 301–321.
- [12] Dai W and Milenkovic O. Subspace pursuit for compressive sensing signal reconstruction[J]. *IEEE Transactions on Information Theory*, 2009, 55(5): 2230–2249.
- [13] Tropp J A, Gilbert A C, and Strauss M J. Algorithms for simultaneous sparse approximation. Part I: greedy pursuit[J]. *Signal Processing*, 2006, 86(3): 572–588.
- [14] Huang K and Aviyente S. Sparse representation for signal classification[J]. *Advances in Neural Information Processing Systems*, 2007, 19(1): 609–616.
- [15] Kokiopoulou E and Frossard P. Semantic coding by supervised dimensionality reduction[J]. *IEEE Transactions on Multimedia*, 2008, 10(5): 806–818.
- [16] Rodriguez F and Sapiro G. Sparse representations for image classification: learning discriminative and reconstructive non-parametric dictionaries[R]. IMA Preprint 2213, University of Minnesota Publisher, Minneapolis, USA, June 2008: 1–16.
- [17] Hull J J. A database for handwritten text recognition research[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1994, 16(5): 550–554.
- [18] Georghiadis A S, Belhumeur P N, and Kriegman D J. From few to many: illumination cone models for face recognition under variable lighting and pose[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(6): 643–660.
- [19] 王磊, 史亚, 姬红兵. 基于多集典型相关分析的雷达辐射源指纹识别[J]. 西安电子科技大学学报, 2013, 40(2): 164–171.
Wang Lei, Shi Ya, and Ji Hong-bing. Specific radar emitter identification using multiset canonical correlation analysis[J]. *Journal of Xidian University*, 2013, 40(2): 164–171.
- [20] 王磊, 姬红兵, 史亚. 基于模糊函数特征优化的雷达辐射源个体识别[J]. 红外与毫米波学报, 2011, 30(1): 74–79.
Wang Lei, Ji Hong-bing, and Shi Ya. Feature optimization of ambiguity function for radar emitter recognition[J]. *Journal of Infrared and Millimeter Waves*, 2011, 30(1): 74–79.
- [21] Zhou Y and Barner K E. Locality constrained dictionary learning for nonlinear dimensionality reduction[J]. *IEEE Signal Processing Letters*, 2013, 20(4): 335–338.
- 王磊: 男, 1979年生, 副教授, 研究方向为雷达信号处理、模式识别、机器学习.
- 周乐囡: 女, 1989年生, 硕士生, 研究方向为压缩感知、信号分析.
- 姬红兵: 男, 1963年生, 教授, 研究方向为智能信息处理、被动多传感器探测与目标跟踪.
- 林琳: 女, 1987年生, 硕士生, 研究方向为压缩感知、雷达辐射源识别.