

压缩感知光谱重构中的字典原子选取优化方法

汪 琪^{1,2} 马灵玲^{1*} 李传荣¹ 唐伶俐¹ 周勇胜¹

¹中国科学院光电研究院定量遥感信息重点实验室, 北京 100094

²中国科学院大学, 北京 100094

摘要 针对常用的迭代追踪类算法难以保证低采样下光谱重构的成功率与精度的问题,提出了一种在低采样下光谱重构中字典原子选取的优化方法。利用 AVIRIS 和 ROSIS 高光谱数据构建光谱稀疏字典并进行压缩感知光谱重构实验,分别从光谱重构精度、稀疏成分提取能力、光谱重构的成功率和光谱识别的准确率等不同角度进行了分析。实验结果表明,本文方法不仅优于传统的匹配追踪算法,同时也优于公认的精度较高的 FOCUSS、MSBL 等其他类型的算法。

关键词 光谱学; 光谱重构; 压缩感知; 稀疏表示; 稀疏字典; 匹配追踪

中图分类号 TP79 文献标识码 A

doi: 10.3788/AOS201636.0930002

Improved Method of Dictionary Atom Selection in Compressive Sensing Spectral Reconstruction

Wang Qi^{1,2} Ma Lingling¹ Li Chuanrong¹ Tang Lingli¹ Zhou Yongsheng¹

¹Key Laboratory of Quantitative Remote Sensing Information Technology, Academy of Opto-Electronics, Chinese Academy of Sciences, Beijing 100094, China

²University of Chinese Academy of Sciences, Beijing 100094, China

Abstract To solve the problem that common iterative pursuit algorithm has low success rate and precision of spectrum reconstruction in low sampling rate, an improve atom selection method of the spectrum reconstruction in low sampling rate is proposed. The spectrum dictionaries are constructed with AVIRIS and ROSIS hyperspectral data and the compressive sensing hyperspectral reconstruction experiment is conducted. The spectrum reconstruction precision, the sparse component extraction ability, and the success rate and accuracy rate in spectral reconstruction are analyzed in different views, respectively. Experimental results show that the proposed method is much better than conventional matching pursuit algorithms and also superior to the well know high precision method such as FOCUSS and MSBL algorithms.

Key words spectroscopy; spectrum reconstruction; compressive sensing; sparse representation; sparse dictionary; matching pursuit

OCIS codes 300.6170; 300.6550; 200.4560

1 引 言

压缩感知理论把压缩和采样过程合二为一,省去了在传统信号采集方案中先高速采样获取大批冗余数据再舍去大部分无用数据的过程,利用目标的稀疏特性,突破了奈奎斯特采样定理的限制,能从极少的测量值中重构出目标图像^[1]。在遥感成像应用中,采用压缩感知的成像系统既可以大大降低采集系统的规模,又可以省去传统成像先采样后压缩的过程,减少了在轨处理的压力,成为了一个极有潜力的研究方向^[2-3]。

收稿日期: 2016-04-21; 收到修改稿日期: 2016-05-11

基金项目: 国家 863 计划(2013AA12904); 中国科学院/国家外国专家局创新国际团队(2013AA1229)

作者简介: 汪 琪(1990—),男,博士研究生,主要从事压缩感知关联成像方面的研究。E-mail: wangqi@aoe.ac.cn

导师简介: 唐伶俐(1955—),女,硕士,研究员,博士生导师,主要从事遥感图像处理与应用方面的研究。

E-mail: lltang@aoe.ac.cn

* 通信联系人。E-mail: llma@aoe.ac.cn

高光谱遥感利用地物的诊断性光谱特征定量分析地球表层物理、化学属性,能够分辨通常手段不能区分的地物属性,近年来成为各国竞相发展的遥感技术^[4]。高光谱遥感图像可以形象地表征为描述目标二维空间信息和一维光谱信息的图像立方体。随着空间分辨率和光谱分辨率的提高,高光谱数据量迅速增长,不仅给传输和存储以及在轨压缩处理增加了难度,而且增大了成像系统的实现难度和成本。将压缩感知理论引入到高光谱成像领域,是解决上述问题的一种可行思路。Russell 等^[5]和吴建荣等^[6]等分别研制了不同的压缩感知光谱成像系统,从压缩采样数据中成功重构出目标的光谱图像。

基于压缩感知理论可知,目标光谱在特定字典下的稀疏特性是从压缩观测数据中重构目标光谱的前提条件。稀疏特性是指目标光谱可以用事先构建的字典中少量原子精确表示,选择的原子越少,重构所需的测量数据量就越少,能更大限度发挥压缩感知的优势,因此如何从字典中选择合适的原子是压缩感知重构的重要环节^[7]。经典的原子选择方法是通过贪婪迭代的思想,逐个选择字典中的原子加入解集中,选择的标准主要是判断字典原子与信号当前分解后残差的匹配性。根据这一思想,相关的算法被广泛应用于稀疏分解和压缩感知中,比如匹配跟踪(MP)、正交匹配跟踪(OMP)、正则化正交匹配跟踪(ROMP)、分段正交匹配跟踪(StOMP)等^[8-11]。这类算法虽然适用性强、效率高,但直接应用于超低采样下的压缩感知光谱重构中效果并不理想。主要问题在于:1)以缩小残差为目标的匹配策略计算简便但收敛较慢,这是由于在匹配过程中每次选择的原子并不一定是全局最优的,其残差往往偏离最优解,故在此基础上的优化匹配易导致误差的放大,需要更多的原子进行校正;2)不同类型的地物光谱具有各自的分类特征,例如植物光谱由具有植物光谱特征的原子组合的可能性更高。举例来说,在光谱重构中用字典中的矿物光谱原子来表示植物目标光谱在当前一步是算法的最优选择,但其实与全局最优解相去甚远。以上问题在采样数相对较多时可能有机会在后续的原子的选择中弥补前期的错误,但在采样数不足时往往没有这样的机会,因此准确选取原子是在低采样下光谱压缩重构中的关键。

本文基于信号的稀疏编码理论,针对地物光谱在低采样下的压缩感知重构问题,提出了一种字典原子选取的优化方法。其相对于传统的匹配追踪算法主要有以下两点改进:1)直接对观测信号本身而非残差进行原子匹配;2)根据地物光谱的分类属性构建不同类别的联合字典,在重构中对不同类别的原子进行类别估计并根据结果设定不同的权值。将该算法用于压缩感知光谱重构实验,并与常用的四类算法:OMP,欠定系统局灶法(MFOCUSS)、光滑 L₀ 范数法(SL₀)、稀疏贝叶斯估计法(MSBL),在同样条件下进行对比实验,采用机载可见光/红外成像光谱仪(AVIRIS)和反射式光学系统成像光谱仪(ROSIS)光谱成像仪的数据分别从不同的角度验证了本文方法在超低采样下进行压缩感知光谱重构的优点。

2 相关理论与方法

2.1 稀疏表示与字典学习

设 \mathbf{x} 为长度 N 的信号, $\mathbf{D}=[d_1, d_2, \dots, d_K]$ 为 N 维空间中的 K 组基向量,也被称为字典。若 \mathbf{x} 可以被 K 组基向量中的 L 组线性表示(通常 L 远小于 K 和 N),则称 \mathbf{x} 可以被字典 \mathbf{D} 稀疏表示,稀疏度为 L ,即有

$$\mathbf{x} = \sum_{i=1}^L \alpha_i d_{\delta_i} + \boldsymbol{\varepsilon}, \quad \delta_i \in 1, 2, \dots, K, \quad (1)$$

式中 $\boldsymbol{\varepsilon}$ 为稀疏表示的残差。 \mathbf{x} 用矩阵形式表达为

$$\mathbf{x} = \mathbf{D}\mathbf{s} + \boldsymbol{\varepsilon}, \quad (2)$$

式中 \mathbf{s} 为只有 L 个非零值的坐标向量,称为 \mathbf{x} 在字典 \mathbf{D} 下的稀疏系数。对 \mathbf{s} 的求解可以表示为求解最优化问题,即从字典中选取 L 个原子使得用这些原子表示信号 \mathbf{x} 的残差最小,表达式为

$$\min_s \|\mathbf{D}\mathbf{s} - \mathbf{x}\|_2, \quad \text{s.t. } \|\mathbf{s}\|_0 = L, \quad (3)$$

式中 $\|\cdot\|_0$ 为表示向量非零元素个数的 l_0 范数。

如果采用全局搜索的方式遍历所有的组合将面临巨大的计算量,例如在 400 个原子的字典中寻找 5 个原子的组合需要尝试 832 亿次。为了解决这个问题,通常采用贪婪迭代的思想寻找局部最优解,代表算法为 OMP 算法。此类算法基本思想为:从字典中选择与当前残差最匹配的原子(匹配度可用内积、Dice 系数等指标衡量)加入解集中,再用扩张的解集更新稀疏系数和残差用于下一次迭代,直到选择的原子数达到要求。

在稀疏表示中另一个关键是构造先验稀疏字典 \mathbf{D} 。早期常用的稀疏字典有离散余弦变换(DCT)基、小波基、Gabor 基等形式,近年来基于特征样本的自适应字典训练方法被越来越多地用于稀疏字典的构造中,被广泛应用于光谱重构、光谱解混等领域^[12-13]。在本文中,光谱稀疏字典训练模型可以表示为

$$\min_{\mathbf{D}, \mathbf{S}} \|\mathbf{W} - \mathbf{D}\mathbf{S}\|_2, \quad \text{s.t.} \quad \forall i \|s_i\|_0 \leq L, \quad (4)$$

式中 \mathbf{W} 为待训练的光谱样本列向量排成的矩阵, \mathbf{D} 和 \mathbf{S} 分别为所求的稀疏字典和稀疏系数, L 为稀疏度约束参数。

对(4)式的求解分为稀疏编码和字典更新两个关键步骤,稀疏编码步骤是在确定 \mathbf{D} 后求解 \mathbf{S} ,字典更新步骤是根据更新后的 \mathbf{S} 对 \mathbf{D} 进行调整,两个步骤交替循环进行直到收敛。根据字典更新算法的不同,研究人员提出了基于 K 均值聚类的奇异值分解法(KSVD)、最优方向法(MOD)、回归最小二乘法(RLS)等多种字典训练算法^[14-16]。

2.2 压缩感知光谱重构

对于 N 波段的地物光谱信号 $\mathbf{x}^{N \times 1}$,通过随机测量矩阵 $\Phi^{M \times N}$ 进行线性观测采样得到测量向量 $\mathbf{y}^{M \times 1}$,其中采样个数 M 远小于信号个数 N 。采样过程可以表示为

$$\mathbf{y} = \Phi \mathbf{x}. \quad (5)$$

求解(5)式中未知光谱信号 x 的过程为压缩感知重构。由于(5)式的未知数远大于条件数,是一个高度欠定问题。Donoho 等^[17]证明了当测量矩阵 Φ 具有有限等距(RIP)性质时(随机高斯矩阵、随机伯努利矩阵等具有较好的 RIP 性质),(1)式在稀疏约束下具有唯一精确解。所谓稀疏约束,即目标光谱 x 可以分解为稀疏形式,即有

$$\mathbf{y} = \Phi \mathbf{D} \mathbf{s} + \epsilon. \quad (6)$$

通过求解(3)式得到稀疏系数 s ,进而重构出目标信号 \mathbf{x} ,这样可以将压缩感知问题的求解转化为对求解字典原子选取方式的稀疏表示问题,只不过这里的字典是观测矩阵 Φ 与先验稀疏字典 \mathbf{D} 的乘积。

需要指出的是,上述策略并非是求解压缩感知问题的唯一思路。研究人员提出了多种模型求解(6)式,具有代表性的包括基于加权最小二乘的 FOCUSS 模型、采用光滑的函数逼近 l_0 范数的 Smooth- l_0 模型、采用最大后验概率估计法的贝叶斯模型等,其中代表性的算法有 MFOCUSS、GSL0、MSBL 等^[18-20]。通常认为在压缩感知重构中上述算法比贪婪类算法的重构精度更高。

2.3 字典原子选择优化方法

传统的匹配追踪类算法在字典原子选择上采用与稀疏表示后残差的匹配度作为度量标准,容易导致误差放大,另外字典中所有原子具有同等的选择权重,容易忽略字典原子与信号间的内在特征关联。针对低采样下光谱压缩感知重构问题,提出了字典原子选择的优化方法,主要改进点有:1)通过直接对观测信号本身而非残差进行原子匹配;2)根据地物光谱的分类属性构建不同类别的联合字典,在重构中对不同类别的原子设定不同的权值。具体步骤为:

1) 分类字典构建:不同类型的地物光谱具有各自的特征,这一特征也会反映在稀疏表示中,例如植物光谱由具有植物光谱特征的原子组合的可能性更高。为利用光谱的这种特性,首先进行分类光谱样本和字典的构建。设 $\mathbf{W} = [\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_K]$ 为 K 类光谱样本集合,其中 \mathbf{W}_i 为第 i 类光谱样本集合。对每个集合 \mathbf{W}_i ,采用(4)式的模型进行光谱稀疏字典训练,得到字典 $\mathbf{D}^0 = [\mathbf{D}_1^0, \mathbf{D}_2^0, \dots, \mathbf{D}_K^0]$,其中 \mathbf{D}_i^0 为从样本集 \mathbf{W}_i 中训练得到的字典并计算压缩感知中与观测矩阵结合后的新字典 $\mathbf{D} = [\Phi \mathbf{D}_1^0, \Phi \mathbf{D}_2^0, \dots, \Phi \mathbf{D}_K^0]$ 。

2) 设定分类权重函数:在字典原子选择过程中,应当提高与当前估计的目标光谱类型相同的字典中的原子被选择的概率,降低类型不同的原子被选择的概率。设 i 为当前估计的光谱目标类别, d 为候选的原子,则分类权重函数定义为

$$t = \begin{cases} t_1, & \text{if } d \in D_i \\ t_2, & \text{if } d \notin D_i \end{cases}, \quad (7)$$

式中 t_1, t_2 的相对大小表示在原子原则中对原子类型匹配度的约束大小, t_1 可以固定为 1,当 t_2 值越小时,对原子类型的限制越大,更适用于采样数和选择总原子数少的情况,而当 t_2 值越大,对原子类型的限制越小,更适用采样数和选择总原子数多的情况。本文选取 $t_1 = 1, t_2 = 0.7$ 。值得注意的是,如何选择更优的权

重值尚待进一步研究,例如可以考虑在迭代中先设置较小的 t_2 值缩小选择范围保证前期选择原子时类型不出现偏差,而后逐步增大 t_2 值使算法可以在更大的空间内搜索原子,并对稀疏表示进行更好地修正。

3) 确定初始原子和类别:对字典 D 的每个列向量 d 计算最小二乘解 $\hat{s} = (d^T d)^{-1} d^T y$,并计算其估计的误差 $\|y - d\hat{s}\|_2^2$,选出误差最小的 \hat{d} 作为第一步迭代选择的原子,初始解集 $\hat{D} = \hat{d}$,将原子 \hat{d} 所在的字典类别作为对目标光谱估计的类别。

4) 更新解集:从字典 D 剩余的原子中依次选取每个列向量 d 加入解集中,即 $\hat{D} = \hat{D} \cup d$,计算最小二乘解 $\hat{s} = (\hat{D}^T \hat{D})^{-1} \hat{D}^T y$ 及对应的带权重误差 $t \|y - \hat{D}\hat{s}\|_2^2$,选出误差最小的 \hat{d} 作为新选择的原子。

5) 更新类别:计算不同类别在 \hat{s} 中对应的稀疏系数绝对值之和,将绝对值之和最大的分类更新为当前对目标的类别估计。

6) 循环迭代:重复步骤 4)和 5)直到迭代次数达到设定的阈值要求。

7) 计算重构光谱:

$$\hat{x} = D^0 \hat{s}。 \quad (8)$$

3 实验结果及分析

3.1 光谱稀疏字典构建

分别采用 AVIRIS 高光谱遥感成像仪获取的 $0.4 \sim 2.5 \mu\text{m}$ 波长范围的印第安松林场景以及 ROSIS 高光谱遥感成像仪获取的 $0.45 \sim 0.85 \mu\text{m}$ 波长范围的帕维亚大学场景中的光谱数据作为字典训练样本,训练两组光谱稀疏字典用于压缩感知光谱的重构。对于高光谱数据,由于部分谱段受大气水汽吸收影响较大,去除了受影响较大的若干谱段,最终采用 200 个谱段的 AVIRIS 数据和 102 谱段的 ROSIS 数据。选取的光谱样本类别和样本数量如表 1 和表 2 所示。为减少不同场景图像 DN 值的差异性,对所有光谱数据进行了归一化处理。对样本库中各类型的光谱样本进行稀疏字典训练,训练过程中的稀疏编码算法采用效率较高的快速 OMP 算法,字典更新算法采用适应性强的 SVD 分解算法,稀疏度阈值 L 设定为 5,迭代次数为 30 次,每种类型字典包含的原子数量为 100,即 AVIRIS 字典共计 400 个原子,ROSIIS 字典共计 600 个原子。原子数量设定为 100 是在能保证重构效果时取的较小的值以使算法的计算时间更少,当原子数量更少时可能影响重构精度,而原子数量更多则会使计算时间增长。大字典中不同类型地物训练的小字典按表 1 中的顺序排列。需要注意的是,上述参数的选取是从多次实验中兼顾计算效率和算法精度得到的经验值,不一定是最优选择。光谱稀疏字典中的部分原子如图 1 所示。

表 1 AVIRIS 训练样本中各类型地物的数量

Table 1 Number of various types of ground objects in AVIRIS training sample

Type	Woods	Corn	Wheat	Soybean
Sample number	730	237	205	593

表 2 ROSIS 训练样本中各类型地物的数量

Table 2 Number of various types of ground objects in ROSIS training sample

Type	Trees	Asphalt	Bricks	Tiles	Meadows	Bare soil
Sample number	820	816	808	593	824	820

3.2 AVIRIS 光谱压缩感知重构

把 AVIRIS 传感器获取的高光谱场景印第安松林中的玉米光谱作为目标光谱进行压缩感知采样和重构实验,注意重构目标所在区域与字典训练中样本所在区域是分离的。通过(5)式进行压缩感知采样,采样数量为 5,观测矩阵为具有良好随机性的高斯随机矩阵(即矩阵中每个元素独立符合标准高斯分布),并在测量值上添加了 40 dB 的随机高斯噪声。对仅有 5 个数据的观测值按 2.3 节中提出的方法进行压缩感知重构,同时分别采用同类型的经典贪婪类算法 OMP 以及不同的压缩感知重构模型下使用较多的 MFOCUSS、




图 1 光谱稀疏字典中的部分原子。(a) AVIRIS; (b) ROSIS

Fig. 1 Part of the atoms in the spectral sparse dictionary. (a) AVIRIS; (b) ROSIS

GSL0 和 MSBL 算法进行对比实验。MFOCUSS、GSL0 和 MSBL 算法不是通过相同思路来实现稀疏编码的,而是用不同的思路(MFOCUSS 求解加权最小二乘问题,GSL0 采用光滑函数逼近 L0 优化问题,MSBL 用贝叶斯模型求解)同步获得每个原子的稀疏表示系数,因而不适用本字典原子优化选择的方法。重构的光谱如图 2 所示。图 2(a)为本文算法在均方根误差为 0.31%,时间为 1.26s 的重构结果;图 2(b)为 OMP 算法在均方根误差为 1.92%,时间为 0.12 s 的重构结果;图 2(c)为 MFOCUSS 算法在均方根误差为 1.03%,时间为 0.27 s 的重构结果;图 2(d)为 GSL0 算法在均方根误差为 1.09%,时间为 0.45 s 的重构结果。




图 2 不同算法下玉米光谱的重构结果。(a)本文算法;(b)OMP 算法;(c)MFOCUSS 算法;(d)GSL0 算法;(e)MSBL 算法
Fig. 2 Reconstruction results of corn spectrum with different algorithms. (a) Proposed algorithm; (b) OMP algorithm; (c) MFOCUSS algorithm; (d) GSL0 algorithm; (e) MSBL algorithm

由图 2 可知,所提出的采用字典原子选择优化后的重构算法相当准确地重构了目标光谱,而未经改进的经典 OMP 算法重构结果十分不理想,其他模型下的重构算法相比 OMP 算法有很大进步,但效果仍然不及本文算法的重构结果。由于本文算法在迭代过程中采用了更复杂的字典原子选择方式,其计算时间明显长于其他算法。

观察不同重构算法下光谱稀疏字典中原子的选择情况,图 3 表示重构过程中的稀疏系数的分布,即(8)式中的 \hat{s} ,每个位置的稀疏系数对应该位置字典中原子的选择情况。由图 3 可知,不同算法下对原子的选择互不相同,本文算法、OMP 算法以及 MFOCUSS 算法只选取了字典中的 5 个原子,其余位置原子的系数为

0; MSBL 和 GSL0 算法则会采用字典中几乎所有的原子进行信号的稀疏分解, 尽管大部分原子的系数较小但不为 0。通过观察字典中被选择原子的分布, 本文算法选择的字典原子序号集中在 100~200 之间, 这一区域正是由玉米光谱样本训练得到的稀疏字典, 结果与重构目标的类型相符, 而在其他算法中并未观察到这一现象, 进而验证了本文算法可以选出与重构目标类型相匹配的字典原子, 同时也是本文算法可以更准确地重构目标光谱的重要原因。

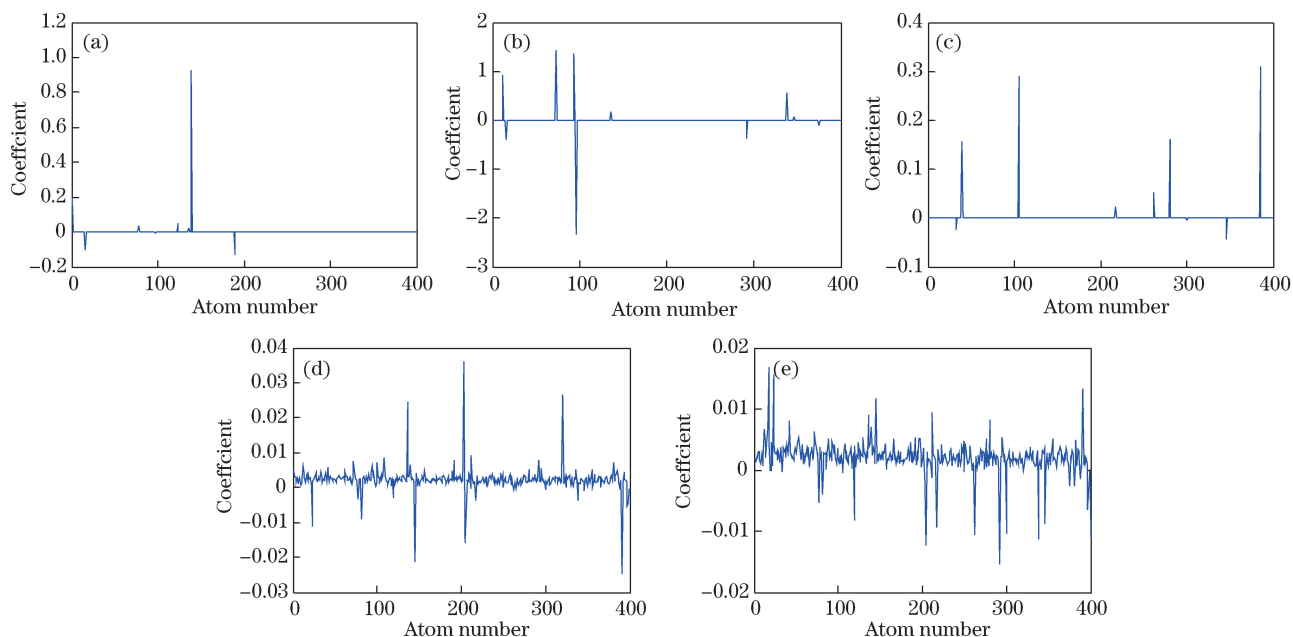


图 3 不同算法下重构的稀疏系数。(a)本文算法;(b)OMP 算法;(c)MFOCUSS 算法;(d)GSL0 算法;(e)MSBL 算法
Fig. 3 Reconstructed sparse coefficients with different algorithms. (a) Proposed algorithm; (b) OMP algorithm; (c) MFOCUSS algorithm; (d) GSL0 algorithm; (e) MSBL algorithm

3.3 ROSIS 光谱压缩感知重构

将 ROSIS 传感器获取的高光谱场景帕维亚大学中的砖块作为光谱目标来进行压缩感知采样和重构实验, 设定从 1 到 10 不同的采样数, 其余实验条件与 AVIRIS 光谱压缩感知重构实验相同, 在不同算法下进行 1000 次独立实验, 每次实验随机生成不同的 5 测量矩阵。定义重构光谱与原始光谱之间的均方根误差误差值在 1% 以内即为重构成功, 统计不同算法在不同采样数下 1000 次重构中成功的比例, 结果如图 4 所示。从图 4 可以看出, 经典的 OMP 算法重构成功率非常低, GSL0、MFOCUSS 和 MSBL 三种算法相差不大, GSL0 略有优势, 本文算法重构成功率明显高于其他算法, 在采样数为 5 时重构的成功率超过 80%, 而其他算法成功率不超过 50%。

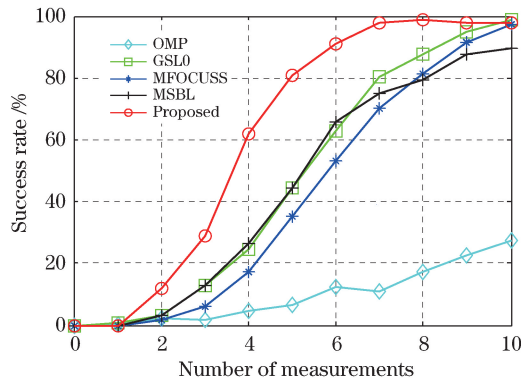


图 4 不同算法下光谱重构的成功率

Fig. 4 Success rate of the reconstructed spectrum with different algorithms

当采样数为 5 时,利用压缩感知光谱重构中的稀疏系数进行目标光谱的分类识别实验。识别的目标光谱为帕维亚大学场景中与稀疏字典训练样本类型相同的 6 种类别地物样本,每种类别样本数量为 1000,识别策略为 2.3 节中的步骤 4)所描述:对重构的稀疏系数绝对值按字典的类别分类求和,求和最大的类别作为分类识别的结果。这种基于稀疏表示的目标识别策略被应用于文献[21]、[22]中,具有理论依据和可行性。采用上述方法来对比不同压缩感知重构算法的效果。每种光谱目标在不同重构算法下识别的准确率如表 3 所示。可以看出,本文算法对重构光谱分类识别的平均正确率为 79.1%,而其他算法中正确率最高的 MSBL 算法为 64.7%,本文算法正确率高出近 15%,具有显著的优势。另外,本文算法对树木和草地的识别正确率高于其他类型地物,说明植被类光谱在稀疏字典下的特征更为显著,这种现象值得进一步研究。

表 3 不同算法下重构光谱分类识别正确率

Table 3 Accuracy rate of reconstructed spectral classification with different algorithms

Method	Trees	Asphalt	Bricks	Tiles	Meadows	Bare soil	Average
Proposed	82	75	76	74	91	77	79.1
MSBL	62	58	63	58	74	73	64.7
GSL0	66	37	67	44	74	73	60.2
MFOCUSS	38	41	39	66	73	62	53.2
OMP	32	24	26	27	33	37	29.8

4 结 论

提出了一种基于光谱分类训练字典的字典原子选择优化方法。在对 AVIRIS 传感器获取的玉米光谱重构中,该算法在仅有 5 个采样数下准确地重构了目标光谱,重构效果不仅大大优于改进前的经典 OMP 算法,同时也优于在压缩感知重构中广泛使用的其他类型算法。另外在对 ROSIS 传感器获取的砖块光谱的重构中,该算法在采样率不超过 5%时,精确地重构出了地物光谱,其重构成功率明显高于其他类型算法,同时对不同类别光谱在重构中的识别准确率也有较大优势。实验验证了该算法在压缩感知光谱重构的精度、稀疏成分提取能力、重构成功率、类型识别准确率等方面的优越性,可以作为低采样下压缩感知光谱重构的有效手段。

本文算法的局限性在于:1)算法在迭代中采用对目标本身而非稀疏表示残差进行匹配,一定程度上提高了字典原子选择的正确率但计算代价较高,计算时间大约为经典 OMP 算法的 10 倍;2)算法需要有分类光谱稀疏字典的支持,当目标光谱类别不在稀疏字典训练的范围时会影响重构效果,不过通过对训练样本进行多尺度的特征提取扩充训练集,以及采用多尺度特征的 Gabor 基等弥补训练样本的不足可以一定程度上改进该问题,还需要进一步深入研究;3)算法关注于利用极少量的字典原子表示目标光谱,可能是一种拔苗助长的策略,实验中发现选取的原子数量较多时算法的性能提升缓慢,重构精度不如其他算法。如何解决上述局限性,在压缩感知光谱重构中发挥更大的作用将是下一步研究工作的重点。

参 考 文 献

- 1 Donoho D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- 2 Busuiocanu M. Analysis of compressive sensing for hyperspectral remote sensing applications[M]. Rochester: Rochester Institute of Technology, 2013.
- 3 Han Shensheng. Intensity correlation imaging technology for remote sensing [J]. Spacecraft Recovery and Remote Sensing, 2011, 32(5): 44-51.
韩申生. 强度关联遥感成像技术[J]. 航天返回与遥感, 2011, 32(5): 44-51.
- 4 Li Chuanrong, Jia Yuanyuan, Ma lingling. Development and application of interference hyperspectral remote sensing technology[J]. Remote Sensing Technology and Application, 2010, 25(4): 451-457.
李传荣, 贾媛媛, 马灵玲. 干涉成像光谱遥感技术发展与应用[J]. 遥感技术与应用, 2010, 25(4): 451-457.
- 5 Russell T A, McMackin L, Bridge B, et al. Compressive hyperspectral sensor for LWIR gas detection[C]. Proceedings of SPIE, 2012, 8365: 83650C.

- 6 Wu Jianrong, Shen Xia, Yu Hong, *et al.* Snapshot compressive imaging by phase modulation[J]. *Acta Optica Sinica*, 2014, 34(10): 1011005.
吴建荣, 沈 夏, 喻 虹, 等. 基于相位调制的单次曝光压缩感知成像[J]. *光学学报*, 2014, 34(10): 1011005.
- 7 Kulkarni N, Nagesh P, Gowda R, *et al.* Understanding compressive sensing and sparse representation-based super-resolution[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2012, 22(5): 778-789.
- 8 Mallat S G, Zhang Z. Matching pursuits with time-frequency dictionaries[J]. *IEEE Transactions on Signal Processing*, 1993, 41(12): 3397-3415.
- 9 Needell D, Vershynin R. Signal recovery from incomplete and inaccurate measurements via regularized orthogonal matching pursuit[J]. *IEEE Journal on Selected Topics in Signal Processing*, 2010, 4(2): 310-316.
- 10 Liu Y X. Regularized adaptive matching pursuit algorithm for signal reconstruction based on compressive sensing[J]. *Journal of Electronics & Information Technology*, 2010, 32(11): 2713-2717.
- 11 Do T T, Gan L, Nguyen N, *et al.* Sparsity adaptive matching pursuit algorithm for practical compressed sensing[R]. *Conference on Circuits Systems & Computers*, 2008: 581-587.
- 12 Wang Qi, Li Chuanrong, Ma Lingling, *et al.* Compressive sensing spectral sparsification method based on training dictionary[J]. *Remote Sensing Technology and Application*, 2013, 28(6): 1013-1019.
汪 琪, 李传荣, 马灵玲, 等. 基于训练字典的压缩感知光谱稀疏化方法[J]. *遥感技术与应用*, 2013, 28(6): 1013-1019.
- 13 Liu J, Zhang J. Spectral unmixing via compressive sensing[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2014, 52(11): 7099-7110.
- 14 Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation[J]. *Signal Processing, IEEE Transactions on*, 2006, 54(11): 4311-4322.
- 15 Mairal J, Bach F, Ponce J, *et al.* Online dictionary learning for sparse coding [C]. *Proceedings of the 26th Annual International Conference on Machine Learning. ACM*, 2009: 689-696.
- 16 Skretting K, Engan K. Recursive least squares dictionary learning algorithm[J]. *IEEE Transactions on Signal Processing*, 2010, 58(4): 2121-2130.
- 17 Candes E J, Romberg J, Tao T. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information[J]. *IEEE Transactions on Information Theory*, 2006, 52(2): 489-509.
- 18 Cotter S F, Rao B D, Engan K, *et al.* Sparse solutions to linear inverse problems with multiple measurement vectors[J]. *IEEE Transactions on Signal Processing*, 2005, 53(7): 2477-2488.
- 19 Mohimani G H, Babaie-Zadeh M, Jutten C. Fast sparse representation based on smoothed ℓ_0 norm [C]. *International Conference on Independent Component Analysis and Signal Separation*, 2007: 389-396.
- 20 Wipf D P, Rao B D. An empirical Bayesian strategy for solving the simultaneous sparse approximation problem[J]. *IEEE Transactions on Signal Processing*, 2007, 55(7): 3704-3716.
- 21 Wright J, Ma Y, Mairal J, *et al.* Sparse representation for computer vision and pattern recognition[J]. *Proceedings of the IEEE*, 2010, 98(6): 1031-1044.
- 22 Chen Y, Nasrabadi N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2011, 49(10): 3973-3985.