

基于光谱稀疏模型的高光谱压缩感知重构

汪琪^{1,2}, 马灵玲^{1*}, 唐伶俐¹, 李传荣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 100049)

摘要:提出了一种基于光谱稀疏化的压缩感知采样与重构模型, 通过从训练样本中构建光谱稀疏字典提升光谱稀疏化效果, 同时在重构时兼顾空间图像的全变分约束进一步提升重构精度. 对 200 波段 AVIRIS 高光谱场景进行压缩感知重构的实验表明, 利用构建的光谱稀疏字典与传统的 DCT 字典和 Haar 小波字典相比光谱稀疏化效果明显提升, 同时在 25% 采样下基于光谱稀疏字典几乎无差别重构出了高光谱图像, 同样条件下在空间和光谱的精度与现有常用方法相比有较大的提升.

关键词:压缩感知; 高光谱成像; 稀疏表示; 字典学习; 重构算法

中图分类号: TP751.1 **文献标识码:** A

Hyperspectral compressive sensing reconstruction based on spectral sparse model

WANG Qi^{1,2}, MA Ling-Ling^{1*}, TANG Ling-Li¹, LI Chuan-Rong¹, ZHOU Yong-Sheng¹

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

2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: A new compressive sensing (CS) sampling and reconstruction model based on spectral sparse representation is put forward in this paper. The spectral sparse dictionary is constructed from training samples to enhance the effect of sparse representation and the total variation restriction of spatial images is also considered to further enhance the precision during the reconstruction. The experiment to reconstruct 200 bands AVIRIS hyperspectral images show that the effect of spectral sparse representation enhances largely compared with traditional DCT dictionary and Haar wavelet dictionary, and the hyperspectral image is reconstructed nearly perfectly at 25% sampling rate and the spatial and spectral precision is higher than existing common methods in the same condition.

Key words: compressive sensing (CS), hyperspectral imaging, sparse representation, dictionary learning, reconstruction algorithm.

PACS: 42. 68. Wt

引言

压缩感知 (Compressive Sensing) 理论是近几年来信号与图像处理领域广受关注的新型理论. 应用压缩感知理论, 可以在目标的稀疏特性约束下, 从少

量非相关观测值中恢复出目标信号, 是突破奈奎斯特采样定理限制, 实现超分辨率成像的有力途径, 在医学成像、遥感成像等领域具有极大的应用前景^[1]. 对于遥感成像, 基于压缩感知理论的成像系统可以极大降低成像和采集系统的规模, 同时也显著减少

收稿日期: 2016-05-24, 修回日期: 2016-09-30

Received date: 2016-05-24, revised date: 2016-09-30

基金项目: 国家高技术研究发展计划 (863 计划) (2013AA12904), 中国科学院/国家外国专家局创新国际团队 (2013AA1229)

Foundation items: Supported by National High Technology Research and Development Program of China (2013AA12904), Chinese Academy of Sciences and State Administration of Foreign Experts Affairs Project of Innovation Team International Partner Program (2013AA1229)

作者简介 (Biography): 汪琪 (1990-), 男, 博士研究生, 主要研究方向为压缩感知关联成像. E-mail: wangqi@mails.aoe.ac.cn

* 通讯作者 (Corresponding author): E-mail: llma@aoe.ac.cn

了在轨处理和传输的压力. Marco F. Duarte 等研制的“单像素相机”系统^[2], 利用压缩感知理论成功实现了仅使用一个单点探测器的测量数据重建出目标的二维图像; Gang Huang 等人实现了无透镜压缩感知成像系统^[3], 颠覆了传统的成像系统结构.

高光谱遥感成像系统在获取成像场景二维空间信息的同时可以得到图像中每个空间位置的光谱反射率曲线, 构成图像数据立方体, 因此可以利用不同地物的独特光谱特征定量分析地物的物理和化学属性, 提取常规遥感手段通常难以区分的信息, 是近二三十年来各国争相发展的前沿遥感技术. 然而随着人们应用需求的提升, 对高光谱成像系统的海量数据获取和处理能力提出了更高的要求. 获取信息效率极高的压缩感知高光谱成像系统是解决上述问题的一种有效途径. Wagadarikar^[4]、Thomas A. Russell^[5]、吴建荣等^[6]分别采用不同的理论模型和物理器件成功实现了压缩感知光谱成像系统, 从少量压缩采样数据中恢复出目标的多光谱图像, 由于受到硬件系统和处理算法发展不成熟的限制, 其图像质量和光谱精度与现有成熟的光谱成像系统相比还有一定距离, 其中的一个关键问题在于对高光谱信号的稀疏化效果不够理想, 导致算法在光谱重构上精度受到影响.

不同于传统成像系统“所见即所得”, 压缩感知成像系统需要从较少的非相关或部分相关观测值中通过求解优化问题精确恢复原信号. 信号的稀疏性是应用压缩感知理论求解欠定问题的前提条件, 重构图像的质量与对目标的稀疏化约束的效果有很强的关联性. 目前二维空间图像的压缩感知成像主要基于二维离散梯度的稀疏性的最小全变分(TV)模型^[7], 可是应用于地物特征复杂多变的遥感图像, 效果往往难以令人满意, 特别是对压缩比要求更高的高光谱图像, 易产生过度平滑的问题, 影响空间分辨能力. 高光谱图像中相邻谱段的图像之间通常存在较高的相似度, 因此研究人员利用了谱段间相关性的特点提出了不同的约束模型进行高光谱压缩感知重构. Wang, L^[8]将传统空间图像的二维 TV 模型扩展到三维, 用于高光谱压缩感知的重构中. 冯燕^[9]和刘海英^[10]分别提出了基于谱间预测的算法, 采用已重构的部分波段图像和重构中的图像残差作为参考, 利用高光谱的谱间相关性在重构中增加对其他波段的约束. Golbabaee^[11]应用了高光谱数据所有谱段空间图像的低秩特性, 将矩阵核范数加入约束模型中进行联合优化. 贾应彪^[12]则在高光谱谱间

统计相关性的基础上提出了一种结构相关性模型并结合图像的空间梯度稀疏性用于高光谱压缩感知重构. 尽管上述基于不同模式的谱间相关模型在一定程度上提高了高光谱压缩感知的重构精度, 然而其约束模式单一, 仅对所有不同特征的地物光谱用简单的谱间相关模型约束不够准确, 同时在重构中易产生谱间过度相关的问题, 造成光谱分辨能力降低, 对于包含大量光谱信息的宽波段、多波段的高光谱场景问题更为明显.

大部分地物光谱具有分段光滑的特性, 在光谱域上存在大量的可压缩的多余信息, 仅利用相邻谱段的预测或整体的秩最小等手段不足以充分去除光谱的信息冗余. 另一方面, 信号的稀疏理论指出, 对于近似分段光滑的信号, 可以用某种字典中的极少量原子精确表示, 大大降低信息冗余, 已有研究人员将稀疏表示理论应用于光谱的提取与分类中并尝试用于简单地物光谱的压缩感知重构^[13-15]. 在此基础上, 本文将信号的稀疏理论引入高光谱压缩感知重构计算中, 通过对地物光谱稀疏特性的研究, 利用先验光谱数据构建冗余稀疏字典, 建立基于字典的光谱稀疏约束下的高光谱压缩感知模型, 同时结合空间全变分约束进行高光谱数据压缩感知重构. 实验表明, 本文提出的基于光谱冗余稀疏字典的高光谱压缩感知重构方法具有更高的光谱重构精度.

1 压缩感知高光谱采样模型

对于图像或光谱信号 $x^{N \times 1}$, 压缩感知测量过程通过非相关的线性观测矩阵 $\Phi^{M \times N}$ 进行采样得到测量向量 $y^{M \times 1}$, 其中 M 与 N 的比值称为采样率, 通常为保证系统获取信息的高效性, 采样率远低于 1. 采样过程可以用线性方程组表示为

$$y = \Phi x \quad (1)$$

由于式(1)中未知量的个数远大于方程数量, 因此是高度欠定的问题. Donoho 等人证明, 当测量矩阵 Φ 具有满足非相关的 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)式在稀疏约束下可以得到唯一精确解^[16]. 对于不同的信号在应用中可以采用不同的稀疏约束模式, 包括全变分(TV)约束, l_0 范数约束, l_1 范数约束等, 求解的数学模型和算法包括贪婪追踪法(OMP, GP)、基追踪法(BP)、软阈值迭代法(IST)、光滑范数法(SLO)等众多类别^[17-18].

高光谱数据通常表示为矩阵形式 $X^{n_1 \times n_2 \times B}$, 其中 $n_1 \times n_2 = N$ 为每个谱段的像元数, B 为谱段数. 对

高光谱场景的稀疏采样目前基本是在空间域进行。 $x_i^{N \times 1}$ 表示第 i 谱段空间图像按列堆叠形成的一维向量, y_i 表示对应的采样值, 对所有谱段进行采样, 即

$$[y_1, y_2, \dots, y_B] = \Phi[x_1, x_2, \dots, x_B], \quad (2)$$

对式(2)的通常解法是利用空间全变分约束分别求解每个谱段的空间图像 x_i 并根据 x_1, x_2, \dots, x_B 的谱间相关性进行修正. 前文已指出, 在此采样模型下, 含有大量冗余信息的光谱稀疏特性并未得到充分发掘, 重构效果尚有提高的空间. 因此, 区别于空间压缩采样, 本文提出在光谱域上进行稀疏采样, 有

$$[y_1, y_2, \dots, y_N] = \Phi[\lambda_1, \lambda_2, \dots, \lambda_N], \quad (3)$$

其中 $\lambda_i^{B \times 1}$ 为第 i 个空间像元的光谱数据向量. 本文将基于式(3)的采样模型进行求解.

2 基于光谱稀疏的重构模型

2.1 光谱稀疏与冗余字典

设 x 为长度 N 的信号, $D = [d_1, d_2, \dots, d_k]$ 为 N 维空间中的 K 组基向量, 也被称为字典. 当 $K \geq N$ 时目标信号 x 可以分解为字典 D 中的基向量的组合, 即有

$$x = \sum_{i=1}^K \alpha_i d_i, \quad (4)$$

若 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 x 可以被字典 D 稀疏表示, 稀疏度为 L , 即有

$$x = \sum_{i=1}^L \alpha_i d_{\delta_i} + \varepsilon, \delta_i \in 1, 2, \dots, K, \quad (5)$$

ε 为稀疏表示的误差. 用矩阵形式表达有

$$x = Ds + \varepsilon, \quad (6)$$

其中 s 为只有 L 个非零值的坐标向量, 称为 x 在字典 D 下的稀疏系数. 对 s 的求解过程称为稀疏编码, 常用的稀疏编码算法有 OMP、IRLS、MFOCUSS 等^[19-21].

在压缩感知重构中, 常用的稀疏字典有 DCT 基、小波基、Gabor 基等形式, 这些按特定数学模型构建的稀疏基具有较好的普适性, 但难以针对信号的稀疏特征进行自适应调整, 对信号稀疏性的发掘不足. 近年来在图像去噪和识别领域基于特征样本的自适应字典训练方法被越来越多地应用, 采用样本训练手段构建的稀疏字典对目标信号稀疏性的发掘能力更强. 光谱稀疏字典训练模型可以表示为

$$\min_{D, X} \|W - DS\|_2 \quad \text{s. t.} \quad \forall i \|s_i\|_0 \leq L, \quad (7)$$

其中 W 为待训练的光谱样本列向量排成的矩阵, D 和 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, $\|\cdot\|_0$ 为表示向量非零元素个数的 l_0 范数.

对式(7)的求解包含稀疏编码和字典更新过程, 稀疏编码是在确定 D 后求解稀疏系数 S , 字典更新是根据更新后的 S 对 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 KSVD、MOD、RLS 等多种字典训练算法^[22-24].

2.2 基于光谱稀疏模型的压缩感知高光谱重构

在上文中的光谱稀疏模型下, 式(3)中的光谱信号可以分解为稀疏字典与稀疏系数的乘积, 即有

$$\lambda_i = Ds_i, i = 1, 2, \dots, N \quad (8)$$

定义矩阵 $A = \Phi D$, 将式(8)代入式(3)有

$$y_i = \Phi Ds_i = As_i \quad (9)$$

通过求解如下最优化问题得到稀疏系数 s_i

$$\min \|s_i\|_0, \quad \text{s. t.} \quad y_i = As_i \quad (10)$$

由于稀疏表示存在误差, 式(10)可以表达为带正则项的无约束优化问题:

$$\min_{s_i} \frac{1}{2} \|y_i - As_i\|_2^2 + \beta_0 \|s_i\|_0, \quad (11)$$

其中参数 β_0 表示对光谱稀疏约束的程度. 由于 l_0 范数的优化是一个 NP 难问题, 这里采用光滑高斯函数逼近 l_0 范数, 转化为凸优化问题采用梯度下降搜索算法进行求解, 具体步骤参考文献[18].

对每个空间区域的光谱求解式(11)得到稀疏系数, 代入式(8)求得重构光谱, 按空间位置排列成三维矩阵即得到初步重构的高光谱数据立方体 $X^{n_1 \times n_2 \times B}$. 仅在光谱稀疏约束下重构高光谱图像的空间信息准确度难以保证, 因此在空间全变分约束下对初步重构结果进行修正, 求解如下最优化问题:

$$\min_{x'_j} \frac{1}{2} \|x_j - x'_j\|_2^2 + \beta_1 \|x'_j\|_{TV}, \quad (12)$$

其中参数 β_1 表示空间图像平滑度约束的程度, x_j 为高光谱数据 X_0 第 j 谱段的空间图像, x'_j 为修正后的第 j 谱段的空间图像, 对所有谱段采用文献[25]中的算法依次求解式(12), 将各谱段空间图像组合成三维高光谱数据 X' , 通过求解下式对 X' 进行光谱修正:

$$\min_{s_i} \frac{1}{2} \|y_i - As_i\|_2^2 + \frac{\beta_2}{2} \|s_i - s'_i\|_2^2 + \beta_3 \|s_i\|_0, \quad (13)$$

其中参数 β_2 与 β_3 分别表示在光谱修正中对光谱更新的改变量和进一步稀疏约束的程度, s'_i 为 X' 中第 i 个空间位置的光谱, 将修正后的 s_i 组合为三维高光谱数据 X , 代入式(12)再次修正. 循环交替求解

(12)和(13)依次进行空间和光谱的修正,直到满足下式的收敛条件:

$$\frac{\|X - X'\|_2^2}{\|X\|_2^2} \leq 0.001 \quad (14)$$

2.3 高光谱重构图像评价指标

为定量评价计算得到的压缩感知高光谱图像质量,需要选用合适的图像质量评价指标.对于高光谱数据的评价,又可以分为空间评价和光谱评价,两种方法分别从空间和光谱两个方面反映了图像的质量,本文将同时采用空间评价和光谱评价的手段.假定 $X^{n_1 \times n_2 \times B}$ 和 $X'^{n_1 \times n_2 \times B}$ 分别为重构前后的高光谱图像,定义平均均方根误差用于空间质量评价:分别计算各谱段空间图像的均方根误差(RMSE),再对所有谱段求平均:

$$\text{MRMSE} = \frac{1}{B} \sum_{k=1}^B \sqrt{\left(\sum_{j=1}^{n_2} \sum_{i=1}^{n_1} X(i,j,k) - X'(i,j,k) \right) / (n_1 n_2)} \quad (15)$$

定义平均谱向角误差(MSA)用于光谱质量评价:分别计算各空间区域对应光谱谱线的误差角度,再对所有空间点求平均:

$$\text{MSA} = \frac{1}{n_1 n_2} \sum_{j=1}^{n_2} \sum_{i=1}^{n_1} \cos^{-1} \left[\frac{\sum_{k=1}^B X(i,j,k) X'(i,j,k)}{\sqrt{\sum_{k=1}^B X(i,j,k)^2} \sqrt{\sum_{k=1}^B X'(i,j,k)^2}} \right] \quad (16)$$

3 实验结果与分析

3.1 光谱冗余稀疏字典构建

采用 AVIRIS 高光谱遥感成像仪获取的 0.4 ~ 2.5 波长范围遥感影像中的光谱数据作为字典训练样本.随机选取场景 Indian pines、Salinas、Cuprite 和 Kennedy Space Center 中共计 38 类地物的 5 000 条光谱作为训练样本集.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 24 个谱段,最终采用 200 个谱段数据.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.部分类型的训练样本光谱如图 1 所示.对光谱样本库中的样本进行冗余字典训练,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,稀疏度阈值设定为 5,迭代次数为 30 次,字典包含的原子数量为 400.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,不同参数变化对光谱稀疏字典

影响的定量分析及最佳参数的选择尚待进一步研究.




图1 部分类型的训练样本光谱
Fig.1 Some types of spectra in the training set

为验证构建的高光谱冗余稀疏字典对未知成像目标光谱具备有效的稀疏表达能力,选取 Indian pines 场景中的两条光谱作为验证目标(验证目标光谱不在字典训练样本中),在冗余稀疏字典下采用 OMP 算法进行稀疏编码,计算选择字典中不同数量的原子进行稀疏表达的后残差的长度,其值越小表明稀疏表达越精确.作为对比,选择信号稀疏领域常




图2 目标光谱在不同字典下稀疏表达的残差大小
Fig.2 The sparse representation residual of the object spectra under different dictionary

用的冗余 DCT 字典和冗余 haar 小波字典进行同样的实验,为具有可比性,上述两种字典大小均设置为 400,与光谱稀疏字典大小相同. 目标光谱在不同字典下稀疏表达的残差大小如图 2 所示. 从图中可见, 本文采用样本训练方法构建的光谱冗余稀疏字典对目标光谱稀疏表达的精度明显高于 DCT 字典和 Haar 小波字典,在高光谱压缩感知成像的图像重构中具有应用价值.

3.2 高光谱压缩感知重构

采用 Indian Pines 场景中大小为 128×128 的子区域作为实验目标(目标区域不在字典训练范围内). 采用 1.1 的模型对目标进行压缩感知采样,采样矩阵为具有良好 RIP 性质且易于硬件实现的随机伯努利矩阵,采样率设定为 0.25,同时在采样值上添加随机高斯噪声使其信噪比为 40dB(噪声强度约为信号值的 1%). 通过压缩感知采样,将原来 200 波段的高光谱数据降低到 40 波段. 采样前后目标光谱和空间图像如图 3 所示,采样后的数据完全无规律,需要通过最优化求解恢复出目标场景.

采用 3.1 中构建的光谱冗余稀疏字典和 2.2 中







图 3 压缩感知采样前后的高光谱数据
Fig. 3 The hyperspectral data before and after compressive sensing sampling




(a) 玉米光谱曲线



(b) 苜蓿光谱曲线



(c) 第50波段原始图像和重构图像



(d) 第100波段原始图像和重构图像

图 4 重构前后的光谱曲线和空间图像
Fig. 4 The spectral curves and spatial images before and after reconstruction

提出的算法对压缩采样值进行重构. 重构中参数 $\beta_0 = 300, \beta_1 = 100, \beta_2 = 200, \beta_3 = 200$. 重构前后的光谱曲线和空间图像如图 4 所示. 从展示的光谱曲线可以看出,光谱整体符合性较好,局部存在差异. 这是由于本文的稀疏字典从全谱段的样本中整体训练得到,同时重构算法优化的也是整体误差,因此可能存在局部光谱误差偏大的问题,如何在整体优化的同时兼顾局部光谱特征的字典训练和高光谱重构方法是进一步研究的方向. 另外,从空间图像可以看出,重构图像目视效果良好,很好地保留了场景的空间

结构和细节变化特征,仅有少量噪声,这是由于本文算法中采用光谱稀疏字典对光谱信息进行较强的约束,以尽可能地恢复光谱的细节信息,然而在有限的稀疏字典下对光谱的稀疏表示不可避免地存在误差,使得重构的光谱出现波动误差,反映在重构的空间图像上就形成了随机噪声.

3.3 算法对比

为进一步验证本文算法的优越性,将其与目前高光谱压缩感知重构中普遍采用的算法进行对比,共对比三种算法,分别为:TV 约束算法^[7],TV 约束与谱间预测算法(TVSS)^[9],TV 约束与核范数算法(TVNU)^[11].如图5所示是在3.2中同样条件下采用四种算法重构出的高光谱场景第100谱段图像,可以看出,本文算法重构的图像精度较之对比的三种方法有明显提升,特别是有效地改善了TV类算法易造成的过度平滑导致图像细节模糊的问题.

选取重构前后高光谱图像中的玉米和苜蓿光谱曲线进行对比,不同算法下重构的光谱如图6和图7所示,可以看出,相比于本文的方法,TV算法重构谱线一些谱段出现严重偏差,在有光谱约束下的TVSS和TVNU算法尽管一定程度上保持了重构光谱的连续性,但仍然存在不能忽视的误差,并且在30-50波段等谱线变化幅度较大处未能较好地重构出光谱细节,显然本文方法的光谱重构精度优于其他方法.

采用2.3中的质量评价参数进行高光谱压缩感




图5 不同算法下高光谱场景第100谱段重构图像
Fig.5 The 100th band reconstructed images of the hyperspectral scene via different algorithms




图6 不同算法重构前后的玉米谱线
Fig.6 The corn spectra before and after reconstruction via different algorithms

知重构图像的定量评价,同时改变采样率,在不同采样率下分别用四种算法对上文的高光谱场景进行压缩感知采样和重构.不同采样率下表征空间质量的MRMSE参数和表征光谱质量的MSA参数如图8所示.在20%采样率下本文方法重构的高光谱场景MRMSE误差不超过0.3%,MSA误差不超过0.05.可以看出,无论是重构图像的空间还是光谱性能本文算法均优于其他算法.




图 7 不同算法重构前后的苜蓿谱线
 Fig. 7 The alfalfa spectra before and after reconstruction via different algorithms

4 结论

针对高光谱压缩感知遥感成像在图像重构中对




图 8 不同采样率下重构高光谱图像质量参数
 Fig. 8 The quality parameter of the reconstructed hyperspectral image at different sampling rate

光谱信息的稀疏性未能得到充分利用的问题,提出了一套基于光谱稀疏的采样与重构方法,通过构建光谱冗余稀疏字典对光谱域进行稀疏约束,并结合空间图像的全变分约束进行修正.实验表明,构建的光谱冗余稀疏字典对地物光谱目标具有显著的稀疏化效果,在高光谱图像的压缩感知重构中使用 25% 的压缩采用数据得到了高质量的重构图像,为提升现有高光谱系统的采样效率提供了新思路,同时与目前常用的其他压缩感知重构方法相比,在同样实验条件下,本文算法在空间和光谱重构精度上均有较明显的提升,具有极大应用前景.

需要指出的是,尽管本文方法在重构精度上具有较大优势,然而在实际应用中还有如下问题需要解决:一是在光谱稀疏字典构建中需要目标区域的先验信息,实验中发现选用与成像区域获取传感器或地物类型相差较大的样本用于构建稀疏字典则光谱稀疏化效果会受较大影响,进而影响图像重构精度.二是本文的光谱稀疏采样模式相对于目前较为成熟的空域稀疏采样模式在硬件实现上难度更大,对于光谱随机编码的工程实现要求较高,在工程化上还有很大的研究空间.三是与传统系统相比,尽管

压缩感知系统采样效率较高,但在重构计算时需要花费较长的时间,时效性尚待提高。

References

- [1] Donoho, D L. Compressed sensing [J]. *IEEE Transactions on Information Theory*, 2006. **52**(4):1289 - 1306.
- [2] Duarte, M F, Davenport M A, Takhar D, et al. Single-pixel imaging via compressive sampling [J]. *IEEE Signal Processing Magazine*, 2008, **25**(2):83.
- [3] Huang G, Jiang H, Matthews K, et al. Lensless imaging by compressive sensing [J]. *arXiv preprint*, 2013, arXiv:1305.7181.
- [4] Wagadarikar A, John R, Willett R, et al. Single disperser design for coded aperture snapshot spectral imaging [J]. *Applied optics*, 2008. **47**(10):B44 - B51.
- [5] Russell T A, McMackin L, Bridge B, et al. Compressive hyperspectral sensor for LWIR gas detection [J]. *Proceedings of SPIE - The International Society for Optical Engineering*, 2012. **8365**:83650C-83650C-13.
- [6] WU Jian-Rong, SHEN Xia, YU Hong, et al. Snapshot compressive imaging by phase modulation [J]. *Acta Optica Sinica* (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. *光学学报*), 2014, **34**(10):113 - 120.
- [7] Combettes P L, Pesquet J-C. Image restoration subject to a total variation constraint [J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2004. **13**(9):1213 - 22.
- [8] Wang L, Feng Y. Hyperspectral imaging via three-dimensional compressed sampling [C]. *Proceedings of the International Conference on Advanced Computer & Electronics Information*, 2013. **41**(1):355 - 359.
- [9] FENG Yan, JIA Ying-Biao, CAO Yu-Ming, et al. Compressed sensing projection and compound regularizer reconstruction for hyperspectral images [J]. *Acta Aeronautica et Astronautica Sinica* (冯燕,贾应彪,曹宇明,等,高光谱图像压缩感知投影与复合正则重构. *航空学报*), 2012, **33**(8):1466 - 1473.
- [10] LIU Hai-Ying, WU Cheng-Ke, LV Pei, et al. Compressed hyperspectral image sensing reconstruction based on inter-band prediction and joint optimization [J]. *Journal of Electronics & Information Technology* (刘海英,吴成柯,吕沛,等,基于谱间预测和联合优化的高光谱压缩感知图像重构. *电子与信息学报*), 2011, **33**(9):2248 - 2252.
- [11] Golbabaee M, Vandergheynst P. Compressed sensing of simultaneous low-rank and joint-sparse matrices [J]. *IEEE Transactions on Information Theory*, 2012.
- [12] JIA Ying-Biao, FENG Yan, WANG Zhong-Liang, et al. Hyperspectral compressive sensing recovery via spectrum structure similarity [J]. *Journal of Electronics and Information Technology* (贾应彪,冯燕,王忠良,等,基于谱间结构相似先验的高光谱压缩感知重构. *电子与信息学报*), 2014, **36**(6):1406 - 1412.
- [13] Charles A S, Olshausen B A, Rozell C J. Learning sparse codes for hyperspectral imagery [J]. *Selected Topics in Signal Processing IEEE Journal*, 2011, **5**(5):963 - 978.
- [14] WANG Qi, LI Chuan-Rong, MA Ling-Ling, et al. Compressive sensing spectral sparsification method based on training dictionary [J]. *Remote Sensing Technology And Application* (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. *遥感技术与应用*). 2013, **28**(6):1013 - 1019.
- [15] Zare A, Gader P, Gurumoorthy K S. Directly measuring material proportions using hyperspectral compressive sensing [J]. *IEEE Geoscience & Remote Sensing Letters*, 2012, **9**(3):323 - 327.
- [16] Candes E, 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.
- [17] LI Shen, MA Cai-Wen, LI Yan, et al. Survey on reconstruction algorithm based on compressive sensing [J]. *Infrared and Laser Engineering* (李坤,马彩文,李艳,等,压缩感知重构算法综述. *红外与激光工程*), 2013, **42**(S01):225 - 232.
- [18] Mohimani G H, Babaie-Zadeh M, Jutten C. Fast sparse representation based on smoothed l0 norm [J]. *Independent Component Analysis and Signal Separation*. Springer, 2007:389 - 396.
- [19] Needell D, Tropp J A. CoSaMP: Iterative signal recovery from incomplete and inaccurate samples [J]. *Applied and Computational Harmonic Analysis*, 2009. **26**(3):301 - 321.
- [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] 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.
- [22] Aharon M, Elad M, Bruckstein A. K-SVD: An Algorithm for designing overcomplete dictionaries for sparse representation [J]. *IEEE Transactions on Signal Processing*, 2006. **54**(11):4311 - 4322.
- [23] Mairal J, et al. Online dictionary learning for sparse coding [C]. *Proceedings of the 26th Annual International Conference on Machine Learning*. 2009.
- [24] Skretting K, Engan K. Recursive least squares dictionary learning algorithm [J]. *IEEE Transactions on Signal Processing*, 2010. **58**(4):2121 - 2130.
- [25] Chambolle A. An algorithm for total variation minimization and applications [J]. *Journal of Mathematical Imaging & Vision*, 2004. **20**(1-2):89 - 97.