

线性混合光谱模型高光谱压缩感知

王忠良¹, 何密², 叶珍³, 粘永健²

1. 铜陵学院 电气工程学院, 铜陵 244061;

2. 陆军军医大学(第三军医大学) 生物医学工程与影像医学系, 重庆 400038;

3. 长安大学 电子与控制工程学院, 西安 710064

摘要: 高光谱压缩感知(HCS)对于解决机载或星载高光谱数据的存储与实时传输具有重要意义。目前,线性混合模型(LMM)已被成功应用于HCS;然而,由于光照条件、地形变化以及大气作用等的影响,所获取的地物光谱会发生扰动,从而限制了HCS重建质量的提高。在LMM基础上,通过引入光谱修正项来修正光谱扰动,提出了光谱扰动修正的LMM(SPC_LMM);在此基础上,进一步提出了基于SPC_LMM的HCS(HCS_SPC_LMM)方法。该方法在采样端仅对原始高光谱图像进行光谱维压缩采样,基于压缩采样数据,将SPC_LMM应用HCS的重建,利用交替方向乘法(ADMM)分别估计SPC_LMM中各分量的最优值,以获得最优的高光谱图像重建质量。实验结果表明,HCS_SPC_LMM能够获得优于其他典型HCS方法的重建质量。

关键词: 遥感,高光谱遥感,压缩感知,线性混合模型,光谱扰动

引用格式: 王忠良,何密,叶珍,粘永健.2020.线性混合光谱模型高光谱压缩感知.遥感学报,24(3):277-289

Wang Z L, He M, Ye Z and Nian Y J. 2020. For hyperspectral compressed sensing method on linear mixed spectrum model. *Journal of Remote Sensing(Chinese)*, 24(3): 277-289[DOI:10.11834/jrs.20209211]

1 引言

高光谱图像HSI(Hyper Spectral Imagery)可以提供丰富的地物光谱信息,在矿物勘探、农业生产、环境与灾害监测等领域得到广泛应用(Bioucas-Dias等,2012;童庆禧等,2016)。然而,随着分辨率的不断提高,成像光谱仪获取的数据量呈指数级增长。海量的高光谱数据给机载或者星载成像系统的功耗、计算能力以及数据的实时传输均带来了巨大压力。传统的压缩技术首先通过光学系统采集高分辨率的高光谱数据,然后对其进行压缩,这种“先成像后压缩”的模式显著增加了成像平台的功耗与硬件复杂度。压缩感知CS(Compressed Sensing)技术能以较低的采样率(远低于奈奎斯特采样率)采集数据,将数据采集与压缩融为一体,在成像的同时完成数据压缩,适合解决机载或者星载

高光谱成像平台数据采集与压缩难题。目前,高光谱压缩感知HCS(Hyperspectral Compressed Sensing)已经成为当今高光谱遥感领域研究的热点。

基于高光谱采样数据的重建是HCS研究中的关键问题之一。近年来针对高光谱图像的结构特点已经提出了一系列HCS重建方法,经典的HCS重建技术是在充分分析高光谱数据特征的基础上,结合各种稀疏先验约束,通过凸优化的方法进行重建。Mun和Fowler(2009)将基于块的随机采样与投影驱动的CS重建相结合,增强了方向变换域的稀疏性。3维压缩感知3D CS(Three-dimensional Compressive Sampling)结合了HSI的3维稀疏、平滑与低秩先验,取得了一定的重建性能(Shu和Ahuja,2011)。孙玉宝等(2014)将HSI分解为低秩与稀疏成分,结合光谱维低秩先验与空间维稀疏先验进行重建。Jia等(2015)将HSI的结构相

收稿日期:2019-06-26;预印本:2019-10-18

基金项目:国家自然科学基金(编号:41601344);重庆市基础科学与前沿技术一般项目(编号:cstc2016jcyjA0539);安徽高校自然科学研究重点项目(编号:KJ2019A0709);安徽省质量工程项目(编号:2016zy126);安徽省高校优秀青年骨干人才国内外访学研修项目(编号:gxgwf2019056);后勤科研重点项目(编号:BLJ18J005)

第一作者简介:王忠良,1980年生,男,副教授,研究方向为遥感图像处理。E-mail:asdwzl@hotmail.com

通信作者简介:粘永健,1982年生,男,副教授,研究方向为遥感图像处理。E-mail:yjnian@126.com

似性先验应用于重建方法中, 进一步提高了重建性能。Wang等(2017)应用张量分析的方法建模隐含在HSI中的空谱相关性和局部平滑性, 采用张量Tucker分解来描述所有波段间的全局空谱相关性。Zhang等(2016)提出了加权拉普拉斯先验的HCS方法, 通过挖掘图像中的结构稀疏性来提高HCS的重建性能。结合先验信息的凸优化重建方法虽然获得了一定的重建性能, 但此类方法通常具有较高的计算复杂度, 先验信息的设计也对重建性能的影响较大。主成分分析压缩投影CPPCA (Compressive-Projection Principal Component Analysis) (Fowler, 2009)及其改进方法(Chen等, 2014; Ly等, 2013)采用光谱维压缩采样的方式获取采样数据, 重建端首先估计特征向量, 然后利用主成分分析PCA (Principal Component Analysis)来重建原始数据, 通常可以获得优于凸优化方法的重建性能。

线性混合模型LMM (Linear Mixing Model)作为HSI简单而有效的假设已被广泛应用于光谱解混(蓝金辉等, 2018; 袁博等, 2018)。LMM认为高光谱图像可以表示为端元矩阵与丰度矩阵的乘积。近年来, 在LMM的假设下, 基于光谱解混的重建方法逐渐应用于高光谱CS重建, 不但提高了重建速度, 而且较大程度地提高了重建质量。Martin等(2015)在假设端元已知的情况下, 将HCS重建问题转化为丰度矩阵的估计问题。Wang等(2015), 冯燕等(2015), Wang等(2018)构造了一种双CS矩阵, 可以同时实现高光谱图像的空间压缩采样与光谱维压缩采样, 利用采样数据能够分别提取端元与丰度信息。Martín和Bioucas-Dias(2016)提出了一种谱压缩采样SpeCA (Spectral Compressive Acquisition)方法, 编码端采用双测量矩阵分别对高光谱数据进行压缩采样, 重建时应用顶点成分分析VCA (Vertex Component Analysis) (Nascimento和Dias, 2005)预先提取出端元, 然后结合最小二乘法估计出丰度, 从而实现高光谱图像的重建。

现有的基于光谱解混的重建方法均是建立在传统LMM的基础上; 然而, 由于光照条件、地形变化以及大气等因素的影响, 所获取的成像光谱会发生扰动, 从而偏离了地物的真实光谱, 降低了LMM的适用性(宋江涛等, 2019)。Thouvenin等(2016)为了减小光谱扰动带来的影响, 为每一端元均增加了一个扰动项来表征光谱的变化。Drumetz等(2016)提出了扩展的LMM, 即ELMM

(Extended LMM), 通过标量因子来缩放端元光谱, 以模拟光谱扰动的变化, 其不足是仅用标量因子难以精确表达光谱的扰动。Hong等(2019)将ELMM与PLMM两种模型结合起来, 通过引入谱变异字典SVD (Spectral Variability Dictionary)来纠正光谱扰动。然而, 光谱中每个点的扰动幅度通常是不均匀的, 上述模型难以进行自适应地修正; 此外, 上述模型仅仅应用于混合像元的分解, 其在HCS重建领域的应用未见报道。针对以上不足, 本文将ELMM中用于缩放端元光谱的标量因子推广到修正矩阵, 提出了光谱扰动修正的线性混合模型SPC_LMM (Spectral Perturbed Correction-Linear Mixing Model)。与传统的LMM相比, SPC_LMM能够自适应地修正光谱扰动幅度, 进而提高表征高光谱图像的能力, 从而提高HCS的重建质量。在此基础上, 本文提出了基于SPC_LMM的HCS (HCS_SPC_LMM)方法, 在假设端元光谱已知的情况下, 采样端首先对原始高光谱数据进行光谱维压缩采样, 重建端基于SPC_LMM来重建原始高光谱图像, 结合交替方向乘子法ADMM (Alternating Direction Method of Multipliers)优化求解模型的各变量, 最后利用高光谱实测数据对所提方法进行了性能测试。

2 线性混合模型(LMM)与光谱扰动修正的线性混合模型(SPC_LMM)

若采用矩阵 $\mathbf{X} \in \mathbb{R}^{L \times N}$ 表示原始高光谱数据, 其中 L 为波段数, N 为每个波段的像素总数, LMM可表示为

$$\mathbf{X} = \mathbf{E}\mathbf{S} + \mathbf{R} \quad (1)$$

式中, $\mathbf{E} \in \mathbb{R}^{L \times p}$ 为端元矩阵, p 为端元数量, $\mathbf{S} \in \mathbb{R}^{p \times N}$ 为丰度矩阵, \mathbf{R} 为误差项。在LMM假设条件下, 现有的基于光谱解混的HCS均是基于端元与丰度的乘积来重建原始高光谱图像。然而, LMM毕竟是一种理想模型, 当存在光谱扰动时, LMM将难以准确描述HSI。图1给出具体的光谱扰动实例, 其中曲线1为光谱库中明矾石(Alunite)的标准光谱曲线, 曲线2为通过VCA方法从Cuprite数据中提取的Alunite光谱曲线, 显然两者之间差异较大, 说明实测数据中的光谱发生了扰动。ELMM利用尺度缩放来修正该光谱扰动, 如曲线3所示, 虽然在一定程度上接近了标准光谱曲线, 但仍有较大差距, 曲线5显示了曲线1与曲线3之间的光谱差异。

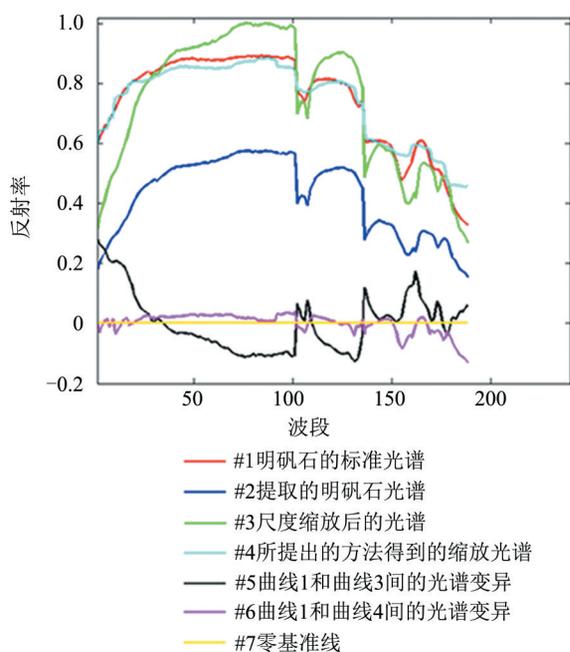


图1 光谱扰动示例

Fig. 1 An example of spectral variability

实际上, 曲线1与曲线3之间光谱差异较大的原因是由于采用了单一的尺度缩放因子, 这使得光谱曲线上每个点均按照同样的比例进行缩放, 难以符合光谱扰动的实际情况。针对该问题, 通过在LMM基础上引入修正项, 提出了光谱扰动修正的线性混合模型 (SPC_LMM), 如式 (2) 所示

$$X = ES + BEH + R \quad (2)$$

式中, BEH 为修正项, $B \in \mathbb{R}^{L \times L}$ 表示端元光谱的修正矩阵, $H \in \mathbb{R}^{v \times N}$ 表示修正后的端元光谱所对应的丰度矩阵。修正矩阵 B 能够根据光谱上每个点的扰动情况自适应地进行修正, 从而提升模型的表达精度, 有利于实现更高质量的HCS重建。图1中曲线4为基于SPC_LMM的HCS重建结果。可以看出, SPC_LMM仍能够获得更接近于曲线1的结果。曲线6给出了曲线4和曲线1之间的光谱差异, 可以看出, 曲线6明显比曲线5更接近于零基准线, 充分表明了SPC_LMM比ELMM更能准确反映光谱的扰动情形, 并实现更有效的修正。

3 基于修正线性混合模型的高光谱压缩感知

3.1 光谱维压缩采样

目前, 世界上多个学术机构建立起了一系列光谱库, 例如美国地质勘探局 USGS (United States Geological Survey) 数字光谱库、喷气推进实验室 JPL (Jet Propulsion Laboratory) 光谱库以

及加利福尼亚技术研究所的先进星载热发射和反射辐射仪 ASTER (Advanced Spaceborne Thermal Emission and Reflection radiometer) 光谱库等, 这使得端元 E 已知成为可能。此时, 需要选取合理的高光谱压缩采样方式, 才能够在SPC_LMM基础上获得良好的重建质量。高光谱图像压缩采样通常包括空间采样与光谱维采样。由于空间采样会严重破坏高光谱图像的丰度信息, 因此, 本文选用高光谱图像光谱维压缩采样, 这是一种简单高效的CS数据采集方式, 无论对于推扫式还是摆扫式高光谱成像系统, 硬件上都比较容易实现 (王忠良等, 2014)。结合式 (1) 与式 (2), 对高光谱图像进行光谱维压缩采样可表示为

$$Y = AX = AES + ABEH + AR \quad (3)$$

式中, $Y \in \mathbb{R}^{v \times N}$ 表示光谱维压缩采样后的 v 个波段的观测数据 ($v \ll L$); $A \in \mathbb{R}^{v \times L}$ 为高斯随机观测矩阵, 光谱维压缩采样的采样率SR (Sampling Rate) 为 v/L 。需要指出的是, 本文将高斯随机矩阵 A 归一化为0—1矩阵, 这种处理方式便于数字显微镜设备DMD (Digital Micromirror Device) 等光学器件的硬件实现, 更符合实际应用的需求。

3.2 基于SPC_LMM的HCS重建

HCS重建的目标是在已知端元矩阵 E 、观测数据 Y 与观测矩阵 A 的情况下, 尽可能完全重建原始的高光谱数据 X 。从式 (3) 可以看出, 在端元 E 已知的前提下, 实现这一目标可以通过估计丰度矩阵 S 、修正矩阵 B 与丰度矩阵 H 来完成。然而, 直接求解这3个变量是一个非凸优化问题, 本文采用ADMM (Boyd等, 2010) 对各个变量进行交替迭代估计。

首先固定 S 和 H , 针对修正矩阵 B 的估计是一个欠定方程的优化求解问题, 需要引入合理的先验假设。文献 (Wang等, 2019) 引入 B 和 E 的正交先验来求解该问题, 其结果不尽如意。因此本文在估计过程中引入全变分TV (Total Variation) 约束项; 同时, 考虑到修正矩阵 B 本身具有的稀疏特性, 引入标准正交基下的稀疏约束。因此, 重建过程的目标函数可表示为

$$\min_{S, H, B} \frac{1}{2} \|Y - AES - ABEH\|_F^2 + \lambda \|WB\|_{1,1} + \lambda_{TV} TV(B) \quad (4)$$

式中, $\|C\|_F \equiv \sqrt{\text{trace}\{CC^T\}}$ 称为 C 的 Frobenius 范数, 上标T表示矩阵的转置; $\|C\|_{1,1} \equiv \sum_{i=1}^L \|C_i\|_1$, C_i 为 C 的第 i 列向量; W 为标准正交基, 文中选用

正交小波基; $TV(C) \triangleq \|FC\|_{1,1} = \|F_h C\|_{1,1} + \|F_v C\|_{1,1}$ 定义为空间各向异性TV范数, F_h 与 F_v 分别表示水平和垂直方向的离散梯度算子; λ 与 λ_{TV} 为大于零的正则项系数, 在后续的实验结果与分析中将会具体讨论两者的合理取值范围。其次, 固定 B 和 H , 由于 $p \ll N$, 针对丰度 S 的估计为超定方程的求解问题。虽然增加先验信息, 如丰度的稀疏、和为一以及非负约束 (Iordache 等, 2012) 有利于获得最优解, 但相对于欠定问题的求解, 约束项的增加对超定问题的求解影响较小。增加丰度的约束项不但无助于提高重建质量, 而且会增加求解的复杂度。因此, 本文仅采用最小二乘法估计 S 。同理, H 的估计也采用类似的方法进行求解。

此外, 在交替优化 S 、 H 与 B 之前, 首先引入变量 $R_1 = AB$, $R_2 = WB$, $R_3 = B$ 与 $R_4 = FR_3$, 式 (4) 的无约束优化问题可以转化为如下的约束优化问题

$$\min_{S,H,B,R_1,R_2,R_3,R_4} \frac{1}{2} \|Y - AES - R_1 EH\|_F^2 + \lambda \|R_2\|_{1,1} + \lambda_{TV} \|R_4\|_{1,1} \quad (5)$$

s.t. $AB - R_1 = 0, WB - R_2 = 0, B - R_3 = 0, FR_3 - R_4 = 0$

式 (5) 关于 S 、 H 、 B 、 R_1 、 R_2 、 R_3 与 R_4 的扩展拉格朗日函数为

$$\mathcal{L}(S,H,B,R_1,R_2,R_3,R_4) = \frac{1}{2} \|Y - AES - R_1 EH\|_F^2 + \lambda \|R_2\|_{1,1} + \lambda_{TV} \|R_4\|_{1,1} + \frac{\mu}{2} \|AB - R_1 - T_1\|_F^2 + \frac{\mu}{2} \|WB - R_2 - T_2\|_F^2 + \frac{\mu}{2} \|B - R_3 - T_3\|_F^2 + \frac{\mu}{2} \|FR_3 - R_4 - T_4\|_F^2 \quad (6)$$

式中, μ 为一正惩罚常数, 用于控制迭代收敛速度, 实验中其大小选取为 0.05; T_1 、 T_2 、 T_3 与 T_4 为拉格朗日乘子。式 (6) 的扩展拉格朗日函数同时对所有变量的最小化是一非凸优化问题, 但当固定其他变量, 仅对单一变量的最小化就成为凸优化问题。因此, 计算过程中首先固定其他变量, 分别对 S^k 、 H^k 、 B^k 、 R_1^k 、 R_2^k 、 R_3^k 与 R_4^k 中的一个变量进行最小化, 然后再更新拉格朗日乘子 T_1^k 、 T_2^k 、 T_3^k 与 T_4^k , 其中上标 k 表示第 k 次迭代。

S^k 最小化: 扩展拉格朗日函数仅对 S^k 最小化是如下的最小二乘问题

$$\min_{S^k} \frac{1}{2} \|Y - AES^k - R_1^k EH^k\|_F^2 \quad (7)$$

其解析解为

$$S^{k+1} \leftarrow ((AE)^T(AE))^{-1} (AE)^T(Y - R_1^k EH^k) \quad (8)$$

式中, C^{-1} 为矩阵 C 的逆矩阵。

H^k 最小化: 与 S^k 一样, H^k 的最小化仍是小二乘问题, 其解析解为

$$H^{k+1} \leftarrow ((R_1^k E)^T R_1^k E)^{-1} (R_1^k E)^T(Y - AES^{k+1}) \quad (9)$$

B^k 最小化: B^k 最小化的子问题表示如下

$$\min_{B^k} \frac{\mu}{2} \|AB^k - R_1^k - T_1^k\|_F^2 + \frac{\mu}{2} \|WB^k - R_2^k - T_2^k\|_F^2 + \frac{\mu}{2} \|B^k - R_3^k - T_3^k\|_F^2 \quad (10)$$

式中, W 为正交基, $W^T W$ 为单位矩阵。式 (10) 中 B^k 的最优解为

$$B^{k+1} \leftarrow (A^T A + 2I_L)^{-1} (A^T (R_1^k + T_1^k) + W^T (R_2^k + T_2^k) + (R_3^k + T_3^k)) \quad (11)$$

式中, I_L 表示 $L \times L$ 的单位矩阵。

R_1^k 最小化: R_1^k 最小化的子问题如下

$$\min_{R_1^k} \frac{1}{2} \|Y - AES^{k+1} - R_1^k EH^{k+1}\|_F^2 + \frac{\mu}{2} \|AB^{k+1} - R_1^k - T_1^k\|_F^2 \quad (12)$$

其解可以利用式 (13) 进行更新

$$R_1^{k+1} \leftarrow ((Y - AES^{k+1})(EH^{k+1})^T + \mu(AB^{k+1} - T_1^k)) ((EH^{k+1})(EH^{k+1})^T + \mu I_L)^{-1} \quad (13)$$

R_2^k 最小化: R_2^k 最小化可以转换成如下优化子问题

$$\min_{R_2^k} \lambda \|R_2^k\|_{1,1} + \frac{\mu}{2} \|WB^{k+1} - R_2^k - T_2^k\|_F^2 \quad (14)$$

该问题可以通过典型的 soft-threshold 方法求解, 即

$$R_2^{k+1} \leftarrow \text{soft}\left(WB^{k+1} - T_2^k, \frac{\lambda}{\mu}\right) \quad (15)$$

式中, $\text{soft}(\ast)$ 表示 soft-threshold 函数。

R_3^k 最小化: R_3^k 可以通过求解如下的无约束优化问题获得

$$\min_{R_3^k} \frac{1}{2} \|B^{k+1} - R_3^k - T_3^k\|_F^2 + \|FR_3^k - R_4^k - T_4^k\|_F^2 \quad (16)$$

其解可以利用式 (17) 进行更新

$$R_3^{k+1} \leftarrow (FF^T + I_L)^{-1} ((B^{k+1} - T_3^k) + F^T(R_4^k + T_4^k)) \quad (17)$$

R_4^k 最小化: 扩展拉格朗日函数对 R_4^k 的最小化可以得到式 (18) 的优化子问题

$$\min_{R_4^k} \lambda_{TV} \|R_4^k\|_{1,1} + \|FR_3^{k+1} - R_4^k - T_4^k\|_F^2 \quad (18)$$

R_4^k 的更新也可以用 soft-threshold 函数实现, 如式 (19) 所示

$$R_4^{k+1} \leftarrow \text{soft} \left(FR_3^{k+1} - T_4^k, \frac{\lambda_{TV}}{\mu} \right) \quad (19)$$

应用梯度下降法更新拉格朗日乘子 T_1^k, T_2^k, T_3^k 与 T_4^k

$$\begin{aligned} T_1^{k+1} &\leftarrow T_1^k - (AB^{k+1} - R_1^{k+1}) \\ T_2^{k+1} &\leftarrow T_2^k - (WB^{k+1} - R_2^{k+1}) \\ T_3^{k+1} &\leftarrow T_3^k - (B^{k+1} - R_3^{k+1}) \\ T_4^{k+1} &\leftarrow T_4^k - (FR_3^{k+1} - R_4^{k+1}) \end{aligned} \quad (20)$$

经过 k 次迭代后, 在满足收敛条件下, 即可利用式 (21) 得到原始高光谱图像的估计值

$$\hat{X} = ES^{k+1} + B^{k+1}EH^{k+1} \quad (21)$$

综上所述, HCS_SPC_LMM 的计算过程如下:

HCS_SPC_LMM 方法

输入数据: 观测数据 Y 、测量矩阵 A 与端元矩阵 E

参数设置: $\lambda, \lambda_{TV}, \mu$ 与 maxiters

Step 1 初始化:

$$\begin{aligned} H^0 &= \mathbf{0}, B^0 = I_L, R_1^0 = AB^0, R_2^0 = WB^0, R_3^0 = B^0, R_4^0 = FR_3^0, \\ T_1^0 &= \mathbf{0}, T_2^0 = \mathbf{0}, T_3^0 = \mathbf{0}, T_4^0 = \mathbf{0}, k = 1, thr = 10^{-5}, res = \infty \end{aligned}$$

Step 2 While $k < \text{maxiters}$ and $res > thr$

Step 3 根据式(8)计算 S^{k+1}

$$S^{k+1} \leftarrow \left((AE)^T (AE) \right)^{-1} (AE)^T (Y - R_1^k E H^k)$$

Step 4 根据式(9)计算 H^{k+1}

$$H^{k+1} \leftarrow \left((R_1^k E)^T R_1^k E \right)^{-1} (R_1^k E)^T (Y - AES^{k+1})$$

Step 5 根据式(11)计算 B^{k+1}

$$B^{k+1} \leftarrow \left(A^T A + 2I_L \right)^{-1} \left(A^T (R_1^k + T_1^k) + W^T (R_2^k + T_2^k) + (R_3^k + T_3^k) \right)$$

Step 6 根据式(13)计算 R_1^{k+1}

$$\begin{aligned} R_1^{k+1} &\leftarrow \left((Y - AES^{k+1})(EH^{k+1})^T + \mu (AB^{k+1} - T_1^k) \right) \\ &\quad \left((EH^{k+1})(EH^{k+1})^T + \mu I_L \right)^{-1} \end{aligned}$$

Step 7 根据式(15)计算 R_2^{k+1}

$$R_2^{k+1} \leftarrow \text{soft} \left(WB^{k+1} - T_2^k, \frac{\lambda}{\mu} \right)$$

Step 8 根据式(17)计算 R_3^{k+1}

$$R_3^{k+1} \leftarrow \left(FF^T + I_L \right)^{-1} \left((B^{k+1} - T_3^k) + F^T (R_4^k + T_4^k) \right)$$

Step 9 根据式(19)计算 R_4^{k+1}

$$R_4^{k+1} \leftarrow \text{soft} \left(FR_3^{k+1} - T_4^k, \frac{\lambda_{TV}}{\mu} \right)$$

Step 10 根据式(20)更新 $T_1^k, T_2^k, T_3^k, T_4^k$

Step 11 收敛条件计算 $res = \|Y - AES - R_1 E H\|_F / \|Y\|_F$

End While

Step 12 根据式(21)获得估计的高光谱数据 \hat{X}

$$\hat{X} = ES^{k+1} + B^{k+1}EH^{k+1}$$

输出: 重建的高光谱数据 \hat{X}

4 实验结果与分析

为了验证方法的有效性, 针对机载可见光/红外成像光谱仪 AVIRIS (Airborne Visible Infrared Imaging Spectrometer) 获取的高光谱图像 Yellowstone0、Yellowstone3、Yellowstone10 与 Maine10 进行了性能测试 (<http://aviris.jpl.nasa.gov/html/aviris.freedata.html> [2007-05-28])。上述数据集均是未经任何处理的原始机载高光谱数据, 其中每个数据的空间大小均截取为 256×256 , 波段数为 224, 每个像素为 2 个比特。图 2 给出了各数据的第 80 波段图像, 其对应的中心波长为 $0.75 \mu\text{m}$, 其中前 3 个数据成像地区是美国的 Yellowstone, 最后一个数据成像地区是美国的 Maine。

评价 HCS 重建性能所用的指标包括采样率 (SR)、平均信噪比 SNR (Signal-to-Noise Ratio) 和平均光谱角距离 SAD (Spectral Angle Distance)。实验中主要通过分析平均 SNR 和平均 SAD 随 SR 的变化情况来评估重建性能, 其中平均 SNR 和平均 SAD 的计算方法如下

$$\text{SNR} = \frac{1}{L} \sum_{i=1}^L 10 \lg \frac{\|x_i\|_2^2}{\|x_i - \hat{x}_i\|_2^2} \quad (22)$$

$$\text{SAD} = \frac{1}{N} \sum_{j=1}^N \arccos \frac{r_j^T \cdot \hat{r}_j}{\|r_j\|_2 \cdot \|\hat{r}_j\|_2} \quad (23)$$

式中, x_i 和 \hat{x}_i 分别对应原始与重建的高光谱图像第 i 个波段的向量, r_j 和 \hat{r}_j 分别对应原始与重建高光谱图像空间第 j 个像素的光谱向量, 其中 SNR 越大或者 SAD 越小, 表明重建质量越高, 反之越低。

4.1 正则化参数的选取

首先考察正则化参数 λ 与 λ_{TV} 对于重建质量的影响。图 3 给出了 Yellowstone0 与 Yellowstone3 在 $\text{SR} = 0.5$ 时以及 Yellowstone10 与 Maine10 在 $\text{SR} = 0.2$ 时参数 λ 与 λ_{TV} 对重建质量的影响。可以看出, 4 个数据集的测试结果比较类似, 随着 λ 和 λ_{TV} 的增加, 重建质量首先得到迅速提升, 然后稳定在一个较高水平, 其中 Yellowstone0 在 λ 和 λ_{TV} 都取 10^{-5} 时重建质量达到最大值, Yellowstone3 在 λ 和 λ_{TV} 都取 10^{-3} 时重建质量达到最大值, Yellowstone10 在 λ 和 λ_{TV} 分别取 10^{-5} 和 10^{-3} 时重建质量达到最大值, Maine10 在 λ 和 λ_{TV} 分别取 10^{-3} 和 10^{-5} 时重建质量达到最大

值。总的来看, λ 和 λ_{TV} 的取值在 $10^{-3} - 10^{-6}$ 范围内均能获得较为满意的重建质量, 所对应的 SNR 仅有

0.1 dB 的波动。根据以上结果, HCS_SPC_LMM 中 λ 和 λ_{TV} 均设置为 10^{-5} 。

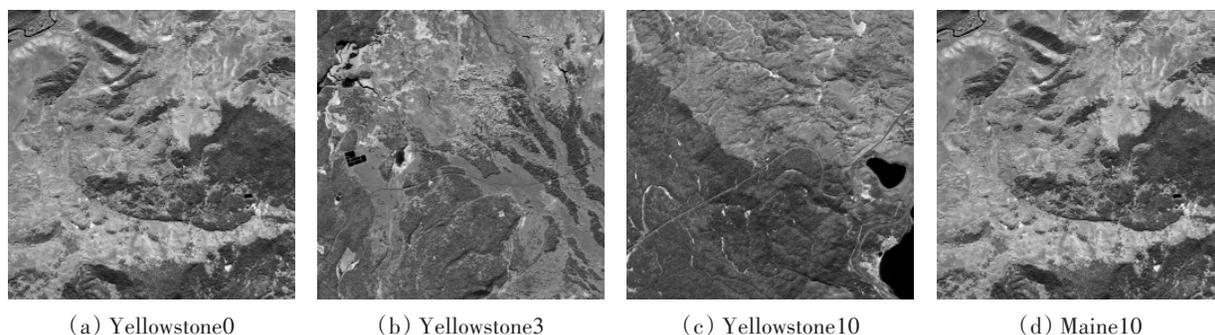


图2 高光谱测试图像的第80波段

Fig. 2 The 80th band of hyperspectral tested images

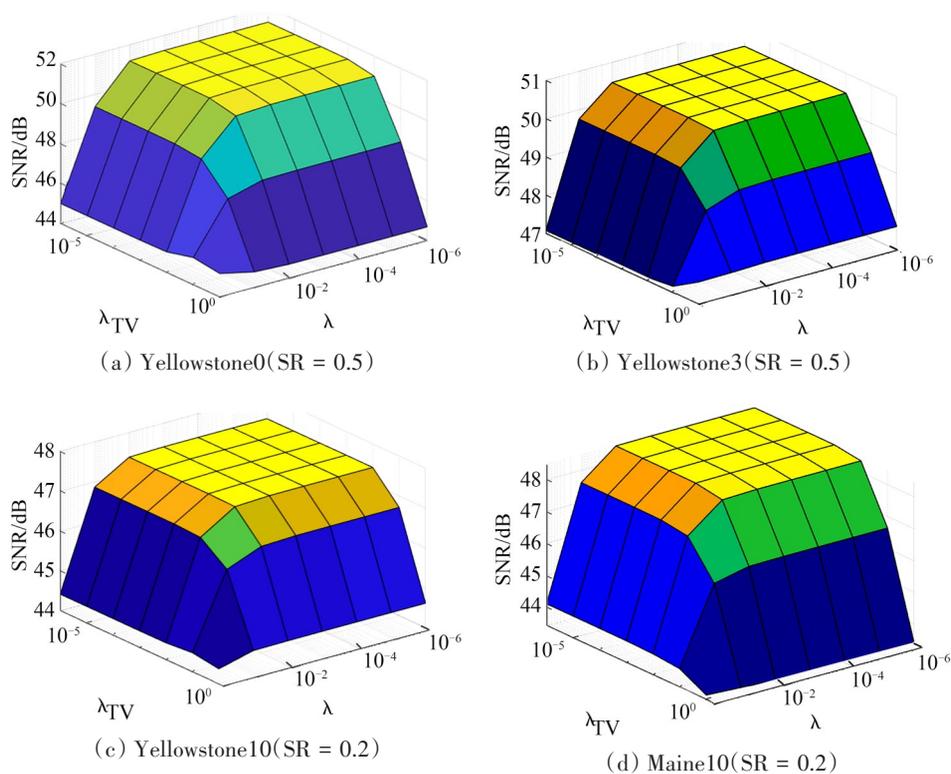


图3 参数 λ 与 λ_{TV} 对重建质量的影响

Fig. 3 The influence on reconstruction quality by parameters λ and λ_{TV}

4.2 利用 SNR 比较重建质量

为了验证 HCS_SPC_LMM 的有效性, 将其与结合平滑投影 Landweber 的块压缩感知 BCS_SPL (Block Compressed Sensing-Smooth Projected Landweber)、CPPCA、SpeCA 以及基于 LMM 的 HCS 重建的 HCS_LMM 性能进行比较, 其中 SpeCA、HCS_LMM 以及 HCS_SPC_LMM 均采用光谱解混的方

式重建原始高光谱图像。为了保证比较的公平性, SpeCA、HCS_LMM 和 HCS_SPC_LMM 均预先使用 HySime (Bioucas-Dias 和 Nascimento, 2008) 方法从原始数据中估计出端元数量。BCS_SPL 的块大小设置为 50×50 , 并选取小波稀疏进行 HCS 重建。由于本文假设端元已知, 通常利用 VCA 预先从原始高光谱数据中提取出相应端元作为已知端元,

这也是此类方法的通行做法 (Zhang 等, 2016)。HCS_LMM 与 HCS_SPC_LMM 的主要区别在于基于不同的模型进行 HCS 重建, 其中 HCS_LMM 为基于 LMM 进行 CS 重建, 而 HCS_SPC_LMM 为基于 SPC_LMM 进行 CS 重建。

图 4 给出了不同方法重建的 SNR 随 SR 的变化情况, SR 的选取范围为 0.2—0.5, 步长为 0.05。从图 4 可以看出, BCS_SPL 的重建质量最差, 这是由于该方法仅仅使用了空间压缩采样。与 BCS_SPL 相比, CPPCA 在 SR = 0.2 时的重建性能没有明显改善, 随着采样率的不断提高, 其重建性能显著提升并显著优于 BCS_SPL。所有方法的重建质量随着 SR 的增加均有所提高, 其中 CPPCA 上升速度较快, 而其他方法相对缓慢。基于光谱解混的 CS

重建方法能够获得显著优于 CPPCA 与 BCS_SPL 的重建质量, 其中 HCS_SPC_LMM 的重建质量均显著优于其他方法。与 HCS_LMM 相比, 随着 SR 的不断提高, 重建质量的提高程度也逐渐增大, 这是由于在低 SR 条件下, 观测数据量的大幅减少会显著降低修正矩阵 B 的估计准确度; 在高 SR 条件下, 信息量的增加可以较为准确地估计 B , 从而较大程度地改善重建质量, 这也充分表明了 SPC_LMM 的有效性。对于高光谱图像压缩而言, 在传输带宽允许的条件下, 为了保证重建图像的高质量, 多数情况下考虑对原始高光谱图像进行高 SR 的压缩采样, 此时 HCS_SPC_LMM 在重建质量上更具优势。

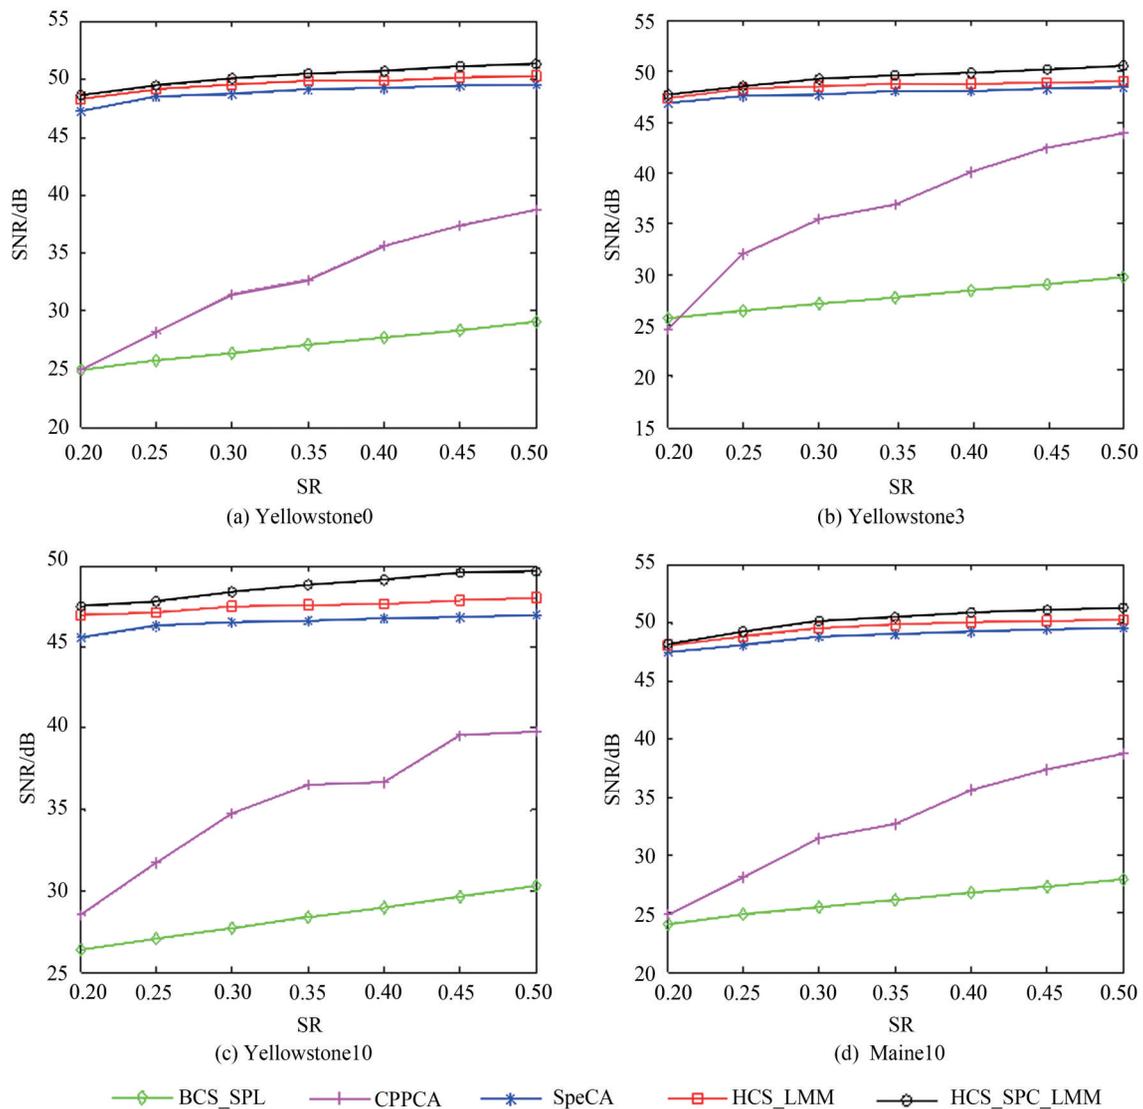


图 4 各种方法的重建性能比较

Fig. 4 Comparison of reconstructed performance achieved by various methods

4.3 重建质量的主观评价

图5给出了在SR = 0.5时Yellowstone10第67波段的重建图像。可以看出,即使在较高SR条件下,BCS_SPL的重建质量仍然较差,而其他方法均能得到相对较好的重建质量,其中CPPCA在这一波段的重建质量略高于SpeCA。除了BCS_SPL

之外,其他方法的重建图像在视觉效果上无明显区分度,但它们所对应的SNR存在显著差异。HCS_LMM与HCS_SPC_LMM的重建SNR均高于CPPCA与SpeCA,而HCS_SPC_LMM相比HCS_LMM提高了超过4 dB,充分表明了SPC_LMM相对于LMM的优越性。

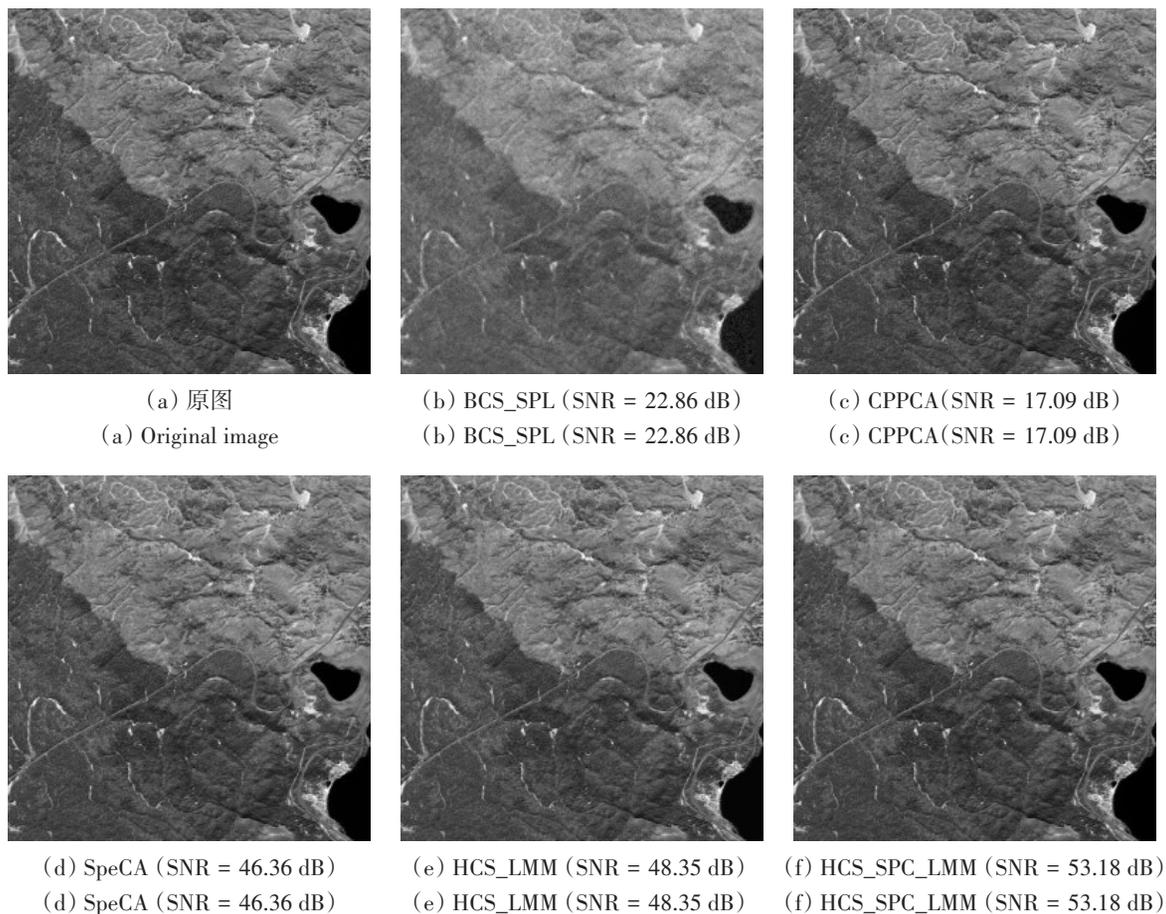


图5 SR=0.5时Yellowstone10第67波段的原始图像以及不同方法的重建图像比较

Fig. 5 Original and reconstructed images of the 67th band of Yellowstone10 with 0.5 sampling rate

图6给出了在SR = 0.2时Yellowstone10第69波段的重建图像。由于SR较低,BCS_SPL与CPPCA的重建图像视觉效果均不理想,丢失了大量纹理与细节信息。SpeCA、HCS_LMM以及HCS_SPC_LMM能够取得较好的视觉效果,与SpeCA相比,HCS_LMM的重建SNR提高了将近2 dB,而HCS_SPC_LMM在HCS_LMM基础上提高了将近2 dB。因此,与其他方法相比,即使在低SR条件下,HCS_SPC_LMM仍能够更好地恢复图像的细节与纹理,从而有利于后续的分类与识别等应用。

4.4 利用SAD比较重建质量

表1—表4分别给出了测试数据集在不同SR条件下对应的SAD比较,可以看出,SpeCA、HCS_LMM与HCS_SPC_LMM明显优于CPPCA和BCS_SPL。在较高SR时,HCS_LMM的SAD稍低于SpeCA的SAD;而在较低SR时,前者比后者有了显著的降低,而HCS_SPC_LMM能够在HCS_LMM的基础上进一步降低SAD,充分说明了HCS_SPC_LMM在提高CS重建质量方面的有效性。

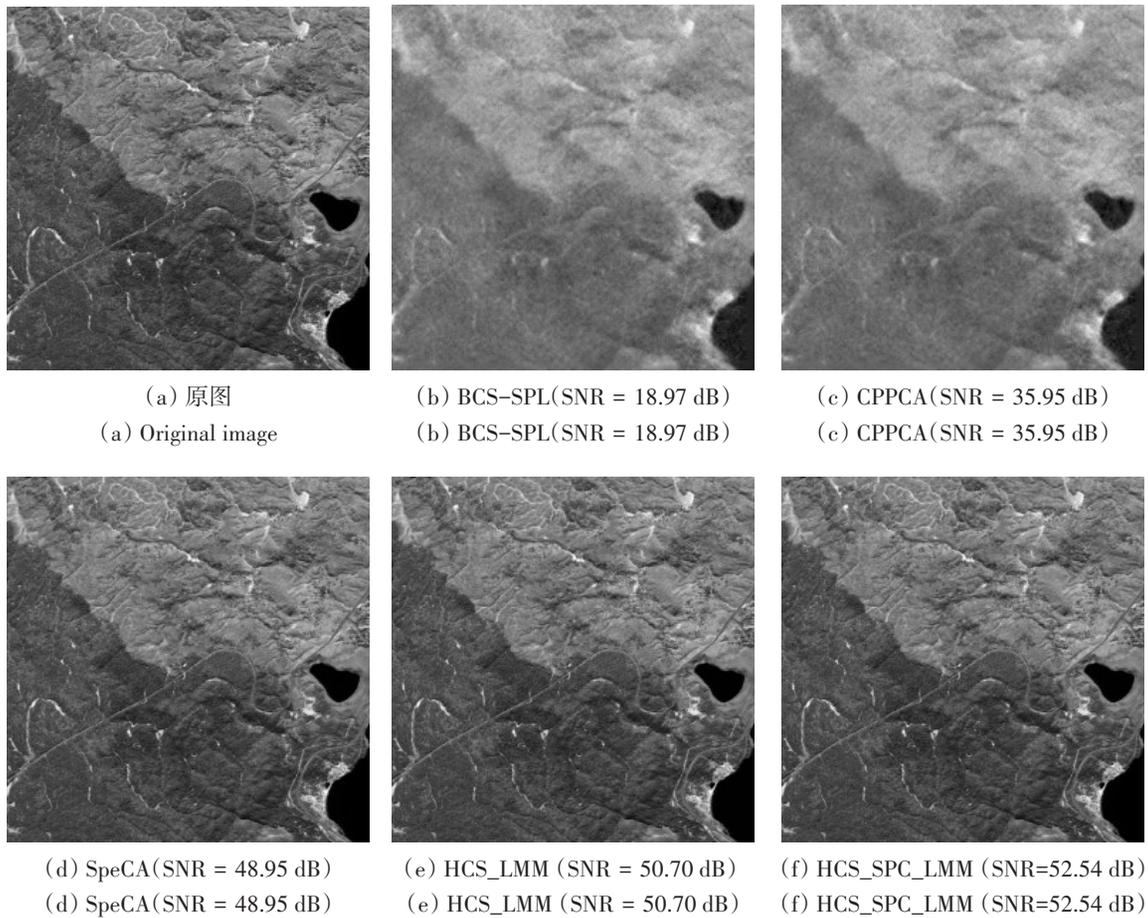


图6 SR = 0.2时 Yellowstone10第69波段的原始图像以及不同方法的重建图像比较
Fig. 6 Original and reconstructed images of the 69th band of Yellowstone10 with 0.2 sampling rate

表1 不同方法对应的SAD比较(Yellowstone0)

Table 1 Comparison of SAD achieved by various methods (Yellowstone0)

SR	0.2	0.3	0.4	0.5
BCS_SPL	0.0645	0.0567	0.0500	0.0437
CPPCA	0.0486	0.0222	0.0138	0.0097
SpeCA	0.0038	0.0032	0.0030	0.0029
HCS_LMM	0.0035	0.0030	0.0029	0.0028
HCS_SPC_LMM	0.0033	0.0028	0.0026	0.0024

表2 不同方法对应的SAD比较(Yellowstone3)

Table 2 Comparison of SAD achieved by various methods (Yellowstone3)

SR	0.2	0.3	0.4	0.5
BCS_SPL	0.0631	0.0556	0.0491	0.0431
CPPCA	0.0487	0.0142	0.0082	0.0055
SpeCA	0.0040	0.0036	0.0034	0.0033
HCS_LMM	0.0039	0.0034	0.0032	0.0031
HCS_SPC_LMM	0.0037	0.0031	0.0029	0.0026

表3 不同方法对应的SAD比较(Yellowstone10)

Table 3 Comparison of SAD achieved by various methods (Yellowstone10)

SR	0.2	0.3	0.4	0.5
BCS_SPL	0.0565	0.0500	0.0442	0.0388
CPPCA	0.0302	0.0148	0.0119	0.0084
SpeCA	0.0043	0.0040	0.0038	0.0037
HCS_LMM	0.0040	0.0038	0.0037	0.0036
HCS_SPC_LMM	0.0038	0.0034	0.0031	0.0029

表4 不同方法对应的SAD比较(Maine10)

Table 4 Comparison of SAD achieved by various methods (Maine10)

SR	0.2	0.3	0.4	0.5
BCS_SPL	0.0729	0.0655	0.0585	0.0523
CPPCA	0.0486	0.0222	0.0138	0.0097
SpeCA	0.0037	0.0032	0.0030	0.0029
HCS_LMM	0.0035	0.0030	0.0028	0.0027
HCS_SPC_LMM	0.0034	0.0028	0.0025	0.0024

图7给出了Yellowstone3在空间位置为(50, 50)处的原始光谱曲线与重建光谱曲线比较(SR = 0.3), 其中红色实线为原始光谱曲线, 蓝色虚线为各方法重建图像的光谱曲线。为了更为清晰地展示光谱差异, 在每个子图的右上角分别给出了1.875—1.969 μm 这个区间光谱曲线的放大图。可以看出, BCS_SPL与CPPCA的重建光谱曲

线与原始光谱曲线差异较大, 而SpeCA、HCS_LMM与HCS_SPC_LMM的重建光谱曲线质量显著优于前两种方法。此外, 与SpeCA、HCS_LMM相比, HCS_SPC_LMM重建光谱曲线更接近于原始光谱曲线, 充分说明了HCS_SPC_LMM在保持光谱特征方面的有效性。

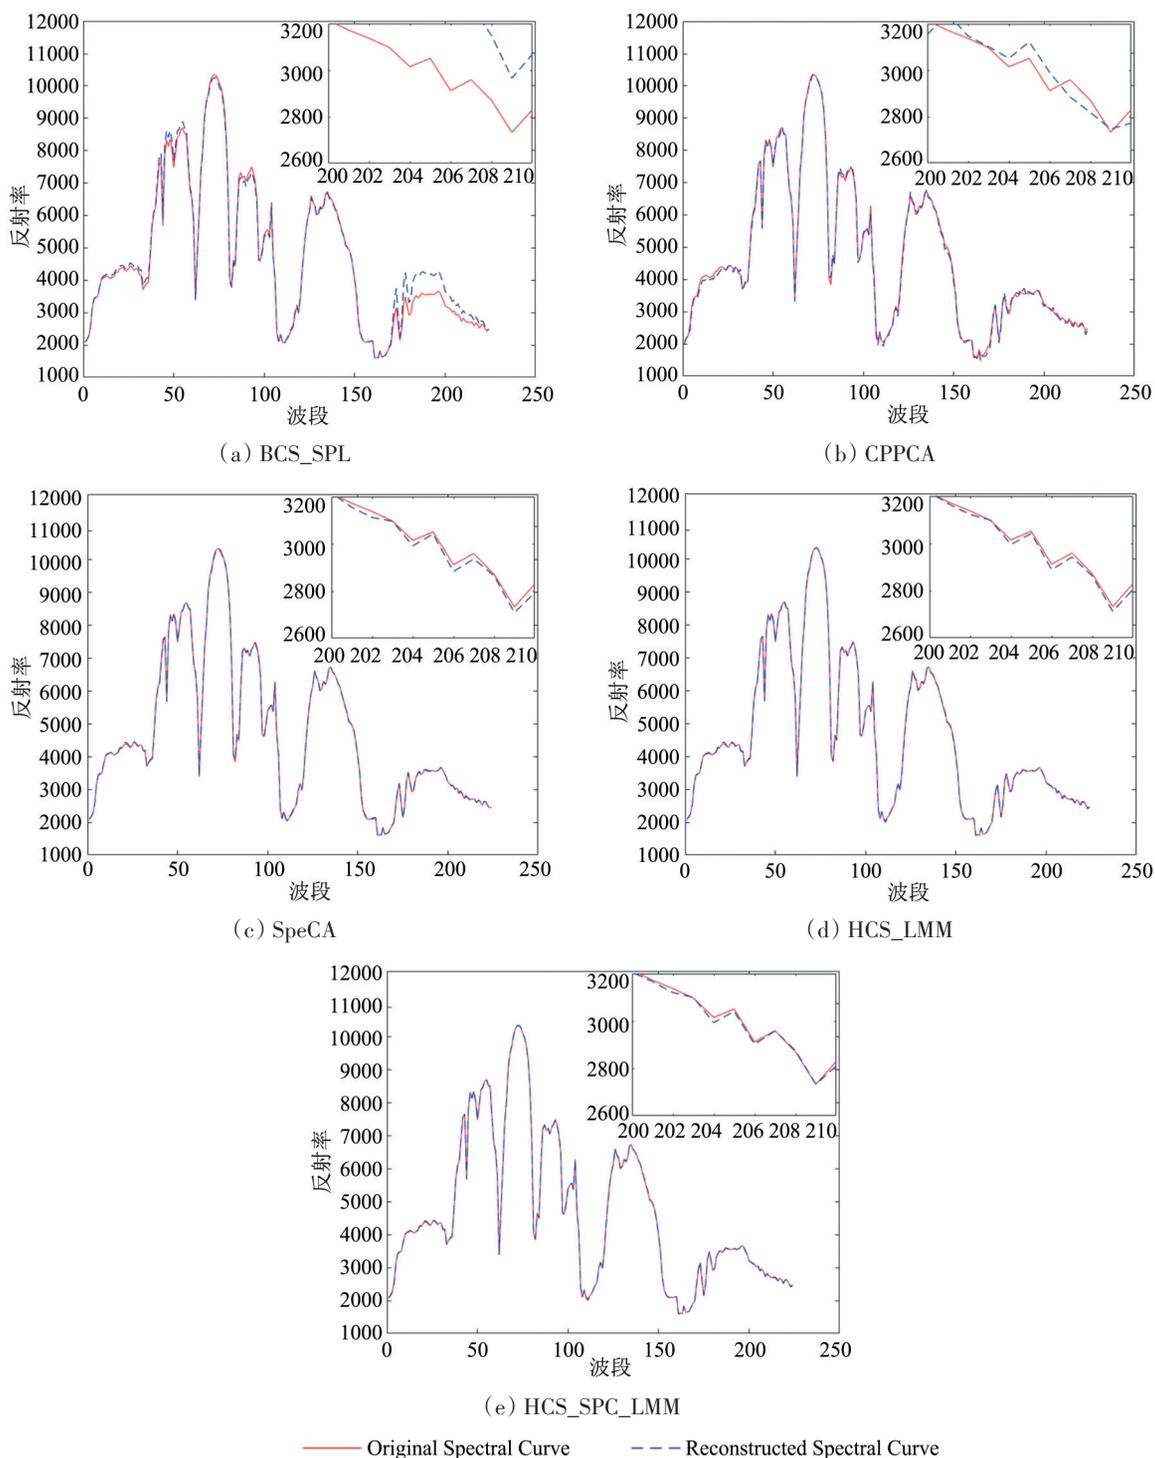


图7 各种方法的重建光谱曲线与原始光谱曲线的比较

Fig. 7 Original and reconstructed spectral curve achieved by various methods

4.5 复杂度比较

在 HCS_SPC_LMM 的整个求解过程中, 方法复杂度较高的步骤分别是: step 4、step 5、step 6 以及 step 9, 其时间复杂度分别为 $O(pvN)$ 、 $O(L^3)$ 、 $O(NL^2)$ 以及 $O(L^2 \log L)$ 。通常情况下, 由于 N 远大于 L , 因此, HCS_SPC_LMM 方法的复杂度为 $O(NL^2)$ 。SpeCA 的复杂度为 $O(p^3L^3)$ (Martín 和 Bioucas-Dias, 2016)。HCS_SPC_LMM 与 SpeCA 的复杂度高低取决于 N 与 p^3L 的大小关系。对于本文的测试数据而言, 显然有 $N < p^3L$, 此时, SpeCA 的复杂度显著高于 HCS_SPC_LMM。此外, 本文利用平均运行时间进一步评估了各方法的计算复杂度, 所用的软硬件环境如下: Windows7 操作系统 (64 位), 计算软件为 Matlab 2014a, CPU 为 Intel i7-6700HQ 以及内存为 32 GB。表 5 给出了各方法在不同 SR 时的运行时间比较。从表 5 可以看出, BCS_SPL 的运算时间最长, 其重建质量也是最差的。SpeCA 的运算时间低于 BCS_SPL, 重建质量却显著优于 BCS_SPL。HCS_LMM 所需的运行时间最少, 并且其重建质量均优于 BCS_SPL 与 SpeCA。CPPCA 的运行时间稍高于 HCS_LMM, 但其重建质量远低于后者。与 HCS_LMM 相比, HCS_SPC_LMM 利用交替迭代的方法计算变量的最优值, 在提高重建质量的同时, 必然会增加计算复杂度。总的来讲, HCS_SPC_LMM 具有较为适中的计算复杂度, 其运行时间高于 CPPCA 与 HCS_LMM, 但显著低于 SpeCA 与 BCS_SPL。由于 HCS 重建通常是在地面进行的, 而地面的计算资源比较充裕, 完全能够应对上述水平的计算复杂度。

表 5 不同方法的运行时间比较

SR	0.2	0.3	0.4	0.5
BCS_SPL	1028.84	765.34	612.62	496.78
CPPCA	0.81	1.28	2.81	3.88
SpeCA	294.80	294.78	294.42	295.10
HCS_LMM	0.20	0.18	0.16	0.16
HCS_SPC_LMM	93.94	103.47	113.96	123.48

5 结论

本文在传统 LMM 的基础上, 提出了一种改进的 SPC_LMM, 该模型可以有效修正光谱扰动, 从而更为准确地表征高光谱图像。在此基础上, 提

出了基于 SPC_LMM 的 HCS, 该方法利用二值化的高斯随机矩阵对原始高光谱图像进行光谱维压缩采样; 在 SPC_LMM 基础上, 重建端结合 ADMM 获得最优的重建质量。针对 AVIRIS 获取的高光谱图像进行测试, 在相同 SR 条件下, 无论在主观评价还是客观评价方面, 所提出的方法在重建性能上均优于其他典型的 HCS 方法, 同时具有适中的计算复杂度, 充分表明了 SPC_LMM 的有效性。后续需考虑非线性光谱混合因素对于 LMM 模型表达的影响, 从而进一步提高 HCS 的重建质量。

参考文献 (References)

- Bioucas-Dias J M and Nascimento J M P. 2008. Hyperspectral subspace identification. *IEEE Transactions on Geoscience and Remote Sensing*, 46(8): 2435-2445 [DOI: 10.1109/TGRS.2008.918089]
- Bioucas-Dias J M, Plaza A, Dobigeon N, Parente M, Du Q, Gader P and Chanussot J. 2012. Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2): 354-379 [DOI: 10.1109/JSTARS.2012.2194696]
- Boyd S, Parikh N, Chu E, Peleato B and Eckstein J. 2010. Distributed optimization and statistical learning via the alternating direction method of multipliers. *Foundations and Trends® in Machine Learning*, 3(1): 1-122 [DOI: 10.1561/22000000016]
- Chen C, Li W, Tramel E W and Fowler J E. 2014. Reconstruction of hyperspectral imagery from random projections using multihypothesis prediction. *IEEE Transactions on Geoscience and Remote Sensing*, 52(1): 365-374 [DOI: 10.1109/TGRS.2013.2240307]
- Drumetz L, Veganzones M A, Henrot S, Phlypo R, Chanussot J and Jutten C. 2016. Blind hyperspectral unmixing using an extended linear mixing model to address spectral variability. *IEEE Transactions on Image Processing*, 25(8): 3890-3905 [DOI: 10.1109/TIP.2016.2579259]
- Feng Y, Wang Z L and Wang L. 2015. A double compressed sensing model of hyperspectral imagery. *Acta Aeronautica et Astronautica Sinica*, 36(9): 3041-3049 (冯燕, 王忠良, 王丽. 2015. 一种高光谱图像的双压缩感知模型. *航空学报*, 36(9): 3041-3049) [DOI: 10.7527/S1000-6893.2014.0350]
- Fowler J E. 2009. Compressive-projection principal component analysis. *IEEE Transactions on Image Processing*, 18(10): 2230-2242 [DOI: 10.1109/TIP.2009.2025089]
- Hong D F, Yokoya N, Chanussot J and Zhu X X. 2019. An augmented linear mixing model to address spectral variability for hyperspectral unmixing. *IEEE Transactions on Image Processing*, 28(4): 1923-1938 [DOI: 10.1109/TIP.2018.2878958]
- Iordache M D, Bioucas-Dias J M and Plaza A. 2012. Total variation spatial regularization for sparse hyperspectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11): 4484-4502 [DOI: 10.1109/TGRS.2012.2191590]
- Jia Y B, Feng Y and Wang Z L. 2015. Reconstructing hyperspectral images from compressive sensors via exploiting multiple priors.

- Spectroscopy Letters, 48(1): 22-26 [DOI: 10.1080/00387010.2013.850727]
- Lan J H, Zou J L, Hao Y S, Zeng Y L, Zhang Y Z and Dong M W. 2018. Research progress on unmixing of hyperspectral remote sensing imagery. *Journal of Remote Sensing*, 22(1):13-27 (蓝金辉, 邹金霖, 郝彦爽, 曾溢良, 张玉珍, 董铭巍. 2018. 高光谱遥感影像混合像元分解研究进展. *遥感学报*, 22(1):13-27) [DOI: 10.11834/jrs.20186502]
- Ly N H, Du Q and Fowler J E. 2013. Reconstruction from random projections of hyperspectral imagery with spectral and spatial partitioning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2): 466-472 [DOI: 10.1109/JSTARS.2012.2217942]
- Martín G and Bioucas-Dias J M. 2016. Hyperspectral blind reconstruction from random spectral projections. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(6): 2390-2399 [DOI: 10.1109/JSTARS.2016.2541541]
- Martín G, Bioucas-Dias J M and Plaza A. 2015. HYCA: a new technique for hyperspectral compressive sensing. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5): 2819-2831 [DOI: 10.1109/TGRS.2014.2365534]
- Mun S and Fowler J E. 2009. Block compressed sensing of images using directional transforms//*Proceedings of the 2009 16th IEEE International Conference on Image Processing*. Cairo, Egypt: IEEE: 3021-3024 [DOI: 10.1109/ICIP.2009.5414429]
- Nascimento J M P and Dias J M B. 2005. Vertex component analysis: a fast algorithm to unmix hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 43(4): 898-910 [DOI: 10.1109/TGRS.2005.844293]
- Shu X B and Ahuja N. 2011. Imaging via three-dimensional compressive sampling (3DCS)//*Proceedings of 2011 International Conference on Computer Vision*. Barcelona, Spain: IEEE: 439-446 [DOI: 10.1109/ICCV.2011.6126273]
- Song J T, Pan J, Xing L X, Jiang L J, Sun Y H, Zhang X F, Zhong W J and Fan B W. 2019. Applicable observational scale analysis of Linear Spectral Mixture Model. *Journal of Remote Sensing*, 23(2): 262-279 (宋江涛, 潘军, 邢立新, 蒋立军, 孙也涵, 张雪峰, 仲伟敬, 范博文. 2019. 线性光谱混合模型的适用观测尺度分析. *遥感学报*, 23(2):262-279) [DOI:10.11834/jrs.20198244]
- Sun Y B, Wu Z B, Wu M and Liu Q S. 2014. Compressed sensing reconstruction of hyperspectral imagery jointly using low rank and sparse prior. *Acta Electronica Sinica*, 42(11): 2219-2224 (孙玉宝, 吴泽彬, 吴敏, 刘青山. 2014. 联合低秩与稀疏先验的高光谱图像压缩感知重建. *电子学报*, 42(11): 2219-2224) [DOI: 10.3969/j.issn.0372-2112.2014.11.014]
- Thouvenin P A, Dobigeon N and Tourneret J Y. 2016. Hyperspectral unmixing with spectral variability using a perturbed linear mixing model. *IEEE Transactions on Signal Processing*, 64(2): 525-538 [DOI: 10.1109/TSP.2015.2486746]
- Tong Q X, Zhang B and Zhang L F. 2016. Current progress of hyperspectral remote sensing in China. *Journal of Remote Sensing*, 20(5):689-707 (童庆禧, 张兵, 张立福. 2016. 中国高光谱遥感的前沿进展. *遥感学报*, 20(5):689-707) [DOI:10.11834/jrs.20186502]
- Wang L, Feng Y, Gao Y L, Wang Z L and He M Y. 2018. Compressed sensing reconstruction of hyperspectral images based on spectral unmixing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(4): 1266-1284 [DOI: 10.1109/JSTARS.2017.2787483]
- Wang Y, Lin L, Zhao Q, Yue T W, Meng D Y and Leung Y. 2017. Compressive sensing of hyperspectral images via joint tensor tucker decomposition and weighted total variation regularization. *IEEE Geoscience and Remote Sensing Letters*, 14(12): 2457-2461 [DOI: 10.1109/LGRS.2017.2771212]
- Wang Z L, Feng Y and Jia Y B. 2015. Spatio-spectral hybrid compressive sensing of hyperspectral imagery. *Remote Sensing Letters*, 6(3): 199-208 [DOI: 10.1080/2150704X.2015.1024892]
- Wang Z L, Feng Y and Wang L. 2014. Compressive sensing imaging and reconstruction of pushbroom hyperspectra. *Optics and Precision Engineering*, 22(11): 3129-3135 (王忠良, 冯燕, 王丽. 2014. 推扫式高光谱谱间压缩感知成像与重构. *光学精密工程*, 22(11): 3129-3135) [DOI: 10.3788/OPE.20142211.3129]
- Wang Z and Xiao H. 2019. Hyperspectral Compressive Sensing Using Improved Linear Mixing Model//*Proceedings of 2019 3rd International Conference on Imaging, Signal Processing and Communication*. Singapore, Singapore: IEEE: 52-56 [10.1109/ICISPC.2019.8935773]
- Yuan B. 2018. NMF hyperspectral unmixing algorithm combined with spatial and spectral. *Journal of Remote Sensing*, 22(2): 265-276 (袁博. 2018. 空间与谱间相关性分析的NMF高光谱解混. *遥感学报*, 22(2):265-276) [DOI: 10.11834/jrs.20186445]
- Zhang L, Wei W, Tian C N, Li F and Zhang Y N. 2016. Exploring structured sparsity by a reweighted laplace prior for hyperspectral compressive sensing. *IEEE Transactions on Image Processing*, 25(10): 4974-4988 [DOI: 10.1109/TIP.2016.2598652]

For hyperspectral compressed sensing method on linear mixed spectrum model

WANG Zhongliang¹, HE Mi², YE Zhen³, NIAN Yongjian²

1. Department of Electric Engineering, Tongling University, Tongling 244061, China;

2. College of Biomedical Engineering and Imaging Medicine, Army Medical University (Third Military Medical University), Chongqing 400038, China;

3. School of Electronics and Control Engineering, Chang'an University, Xi'an 710064, China

Abstract: Hyperspectral Compressed Sensing (HCS) is crucial for data storage and the real-time transmission of airborne- or spaceborne-based imaging platforms. The Linear Mixing Model (LMM) has been successfully applied to HCS reconstruction. However, the obtained

spectrum may be disturbed, thereby limiting the improvement of reconstruction quality due to the influence of illumination conditions, topographic changes, and atmospheric effects. Spectral disturbance is corrected on the basis of LMM by introducing the spectral correction term, and a linear mixing model for spectral perturbation correction is proposed. Moreover, an improved HCS method based on modified LMM is proposed. This proposed model only performs spectral compressed sampling on the original hyperspectral images at the sampling end. The proposed method uses the proposed spectral perturbation correction model to reconstruct the original hyperspectral images based on the compressed sampling data. The alternating direction multiplier method is used to estimate the optimal values of each component in the modified LMM to obtain the optimal reconstruction quality. Experimental results show that the proposed method can achieve better reconstructed performance compared with other classical HCS methods.

Key words: remote sensing, hyperspectral remote sensing, compressed sensing, linear mixing model, spectral perturbed

Supported by National Natural Science Foundation of China (No. 41601344)

附录:

表 A1 缩略词
Table A1 Acronym

缩写	全拼	中文含义
HSI	HyperSpectral Imagery	高光谱图像
CS	Compressed Sensing	压缩感知
HCS	Hyperspectral Compressed Sensing	高光谱压缩感知
LMM	Linear Mixed Model	线性混合模型
SPC_LMM	Spectral Perturbed Correction-Linear Mixing Model	光谱扰动修正的线性混合模型
HCS_SPC_LMM	Hyperspectral Compressed Sensing_ Spectral Perturbed Correction-Linear Mixing Model	基于光谱扰动修正的线性混合模型的高光谱压缩感知
ADMM	Alternating Direction Method of Multipliers	交替方向乘法
PCA	Principal Component Analysis	主成分分析
CPPCA	Compressive-Projection Principal Component Analysis	主成分分析压缩投影
BCS-SPL	Block Compressed Sensing-Smooth Projected Landweber	结合平滑投影 Landweber 的块压缩感知
3D CS	Three-dimensional Compressive Sampling	三维压缩感知
SpeCA	Spectral Compressive Acquisition	谱压缩采样
VCA	Vertex Component Analysis	顶点成分分析
ELMM	Extended Linear Mixed Model	扩展的线性混合模型
SVD	Spectral Variability Dictionary	谱变异字典
USGS	United States Geological Survey	美国地质勘探局
JPL	Jet Propulsion Laboratory	喷气推进实验室
ASTER	Advanced Spaceborne Thermal Emission and Reflection radiometer	先进星载热发射和反射辐射仪
SR	Sampling Rate	采样率
DMD	Digital Micromirror Device	数字微镜设备
TV	Total Variation	全变分
AVIRIS	Airborne Visible Infrared Imaging Spectrometer	机载可见光/红外成像光谱仪
SNR	Signal-to-Noise Ratio	信噪比
SAD	Spectral Angle Distance	光谱角距离