

基于光谱库优化学习的光谱超分与分类精度提升

韩晓琳, 张欢, 孙卫东

清华大学 电子工程系, 北京 100084

摘要: 光谱库优化学习是将光谱库中的光谱数据作为训练样本, 在严格理论推导下构建字典优化学习过程。基于光谱库优化学习, 本研究提出了一种光谱超分辨率重建方法, 该方法在稀疏表示框架下, 通过波段匹配, 将光谱库映射为与待重建高光谱图像波段相对应的特定光谱库; 并利用映射后的特定光谱库与高分多光谱图像, 从理论上推导、并构建基于 ADMM 算法的光谱字典与稀疏系数优化学习过程。多种数据集上的对比分析表明, 即使仅使用一幅高分多光谱图像, 本研究方法仍能恢复重建出高质量的高分高光谱图像, 同时光谱超分辨率重建后的高分高光谱图像可显著提升地物分类精度。结果表明, 本研究实现了仅由一幅高分多光谱图像到高分高光谱图像的高质量光谱超分辨率重建。

关键词: 光谱超分辨率, 光谱库, 稀疏表示, 优化学习, 地物分类

中图分类号: TP751

引用格式: 韩晓琳, 张欢, 孙卫东. 2023. 基于光谱库优化学习的光谱超分与分类精度提升. 遥感学报, 27(11): 2530-2540

Han X L, Zhang H and Sun W D. 2023. Spectral super-resolution using optimized dictionary learning via spectral library and its effects on classification. National Remote Sensing Bulletin, 27 (11) : 2530-2540 [DOI: 10.11834/jrs.20210591]

1 引言

高空间分辨率高光谱图像可同时提供丰富的空间与光谱信息, 已广泛应用于环境监测、精准农业、地物分类、目标检测等不同领域。但高光谱成像过程中光谱分辨率的提升, 使得光谱带宽变窄, 需要采用较大的瞬时视场才能积累足够的能量以维持较高的信噪比, 这导致其空间分辨率降低 (Akhtar 等, 2014; Li 等, 2021)。与高光谱图像相比, 多光谱图像具有更高的空间分辨率, 但光谱信息匮乏, 这制约了其在相关领域, 特别是在材质识别等光谱目标识别领域的可适用性 (Zhu 等, 2011)、地物分类 (Yokoya 等, 2017)。近年来, 以混合像元分解 (Lan 等, 2018)、地物分类等为代表的多光谱应用技术发展迅猛。由混合像元分解理论可知, 自然遥感图像中蕴含的光谱信息是稀疏的, 因此多光谱成像中丢失的光谱信息有望借助光谱库, 以后处理的形式加以

恢复重建。即, 利用光谱库提供的全类别光谱信息, 在稀疏表示框架下, 通过高分多光谱图像恢复重建高分高光谱图像。这不仅有助于提高对地表地物的检测与识别能力, 也可用于研发轻小型高分高光谱成像设备。

现有的高分高光谱图像超分辨率重建算法, 经历了从融合到恢复重建的发展过程, 主要分为基于全色锐化、基于空间字典和基于光谱字典的 3 大类别。基于全色锐化的融合重建是指在同一场景下, 将低分多光谱与高分全色图像加以融合 (Loncan 等, 2015)。以此为目的, Carper 等 (1990) 提出了用全色图像替代 HIS 空间中多光谱图像的亮度分量, 以获取高分多光谱图像的方法。Aiazzi 等 (2007) 提出了一种基于多元回归增强的成分替代方法, 进一步提升全色锐化效果。Wang 等 (2017) 利用全色图像构建的空间字典, 提高了多光谱图像的空间分辨率。Zhu 等 (2012) 利用多光谱与全色图像块的联合稀疏表示, 提出了 J-SparseFI 算

收稿日期: 2021-01-21; 预印本: 2021-06-03

基金项目: 国家自然科学基金(编号:41971294); 中国博士后科学基金(编号:2020M680560); 北京信息科学与技术国家研究中心跨媒体智能专项资助项目(编号:BNR2019TD01022)

第一作者简介: 韩晓琳, 研究方向为图像处理、模式识别、字典学习与深度学习。E-mail: hxl15@tsinghua.org.cn

通信作者简介: 孙卫东, 研究方向为空间信息处理与应用、图像处理、模式识别。E-mail: wdsun@tsinghua.edu.cn

法。Grohnfeldt等(2013)将该算法进一步拓展为利用高光谱与多光谱图像恢复重建高分高光谱图像的算法,但该算法中的全局字典学习过程易导致较高的计算成本。

为了进一步提升高分高光谱图像的重建质量,Wei等(2015)利用过完备空间字典恢复重建高分高光谱图像。Zhao等(2016)提出了一种基于协同表示的重建算法,该算法利用局部自适应空间字典对高光谱与多光谱图像进行稀疏表示。同时考虑到计算成本,该算法中的空间字典由图像块及其近邻图像块构成。Ghasrodashti等(2017)提出了一种基于光谱解混和贝叶斯稀疏的算法,该算法利用两个加权字典以提高待重建高光谱图像的空间分辨率。

鉴于上述基于空间字典的超分辨率重建算法的光谱保持能力有限,人们进而开始研究基于光谱字典学习的超分辨率重建算法。其中,基于线性混合模型(Keshava和Mustard,2002),Kawakami等(2011)在自然高光谱图像重建中,将同一场景的多光谱与高光谱图像对作为训练数据,利用学习获得的光谱字典作为光谱表达的基元。相似的方法也运用在高光谱遥感图像中(Huang等,2014),其中光谱字典改由纯净光谱构成。Yokoya等(2012)提出的耦合矩阵分解算法,将高光谱图像分解为端元与丰度矩阵,其端元矩阵可看作是一种特殊形式的光谱字典。该算法在丰度非负及归一化约束下进行求解,用来提升高光谱图像的空间分辨。Simões等(2015)提出了一种基于子空间变分约束的图像融合方法,其光谱字典由端元光谱构成。Veganzones等(2016)提出了一种基于图像块端元的全局光谱字典学习算法,较好解决了高光谱图像重建中的低秩病态问题。Akhtar等(2014)提出了一种非负约束下的空间—光谱稀疏表示算法,该算法在相似光谱具有相同丰度这一假设下求解光谱字典。Dong等(2016)提出了一种基于非负稀疏表示的融合算法,利用近邻光谱的相似性和稀疏先验联合求解光谱字典和稀疏系数。Chen等(2019)提出了一种基于光谱字典学习的超分辨率重建算法,该算法利用不同场景多光谱—高光谱图像对提供的光谱映射关系进行超分辨率重建,并利用辅助高光谱图像学习得到光谱字典。此外,为了同时利用光谱与空间信息,Zhang等(2016)利用两个字典分别用于表达

空间和光谱域中图像潜在结构,Nezhad等(2016)也提出了一种基于光谱解混的算法,同时使用空间和光谱字典提升高光谱图像的空间分辨率。

基于单幅图像的空间超分辨率重建是指利用先验知识或样本学习获取额外的附加信息,进而由低分高光谱图像重建高分高光谱图像。目前,基于深度学习的算法在单幅图像的高光谱图像重建中获得了较好的效果。其中,Yuan等(2017)利用迁移学习和卷积神经网络(CNN)(Dong,2014)实现了由低分高光谱图像重建高分高光谱图像。Hu等(2017)提出了一种光谱差异学习算法,利用CNN进行高分高光谱图像重建。Mei等(2017)在利用CNN提升高光谱图像的空间分辨率时,引进了3D卷积神经元。Ertürk等(2014)提出了二元粒子群优化算法(BPSO),该算法在不使用任何额外高空间分辨率图像的情况下,提升了高光谱图像的空间分辨率。Villa等(2010)提出了一种基于模拟退火的算法来提升高光谱图像的空间分辨率。Pan等(2014)利用光谱和结构相似性,提出了单幅高光谱图像恢复重建算法。为了进一步利用高光谱图像的内在几何结构和字典基元之间的不相关性,Lu等提出了一种稀疏编码算法(2014),以获得更好的超分辨率重建性能。需要指出的是,上述恢复重建算法旨在提高低分高光谱图像的空间分辨率,而非光谱分辨率。

自20世纪70年代以来,不同机构逐渐建立了众多光谱库,如美国地质调查局(USGS)、喷气推进实验室(JPL)和约翰霍普金斯大学(JHU)等。这些光谱库已被广泛应用于高光谱图像分类、光谱解混以及ENVI等商业软件。其中,Iordache等(2014)提出了一种利用光谱库进行端元矩阵估计的算法。Xu等(2016)提出了一种光谱库与像素的混合结构,用以改善端元提取性能。Ertürk等(2016)提出了类似的算法,并用于高光谱图像的变化检测。

利用低分高光谱图像进行光谱字典学习是一种有效的高分高光谱图像恢复重建方法,其中,光谱字典的每一列代表一条纯净的光谱端元。然而,在实际应用中,光谱端元的数量难以确定,尤其是在含有弱小光谱目标的情况下。且在光谱解混中,先验信息通常用于保证分解的唯一性,但先验信息的设计和评价是十分困难的。此外,高光谱图像融合或重建过程中对同一场景或不同场景

多光谱与高光谱图像的依赖也制约了其普适性。针对上述问题,基于光谱空间的高度稀疏性, Han等(2019)提出了一种基于光谱库的高分高光谱图像重建方法,该方法利用光谱库提供的光谱信息与高分多光谱图像提供的空间信息,实现了单帧高分多光谱图像的光谱超分辨率。其核心是基于光谱库的光谱字典学习与基于高分多光谱图像的稀疏系数求取,一般来讲,光谱信息与空间信息的协同利用、以及光谱字典与稀疏系数求取精度的进一步提升有助于改善光谱超分辨率重建质量。因此,本研究提出了一种基于光谱库优化学习的光谱超分辨率重建方法 SODL (Spectral super-resolution using Optimized Dictionary Learning via spectral library)。SODL与 Han等提出的方法相比,同样利用单帧高分多光谱图像进行光谱超分辨率重建,但本研究在更为严格的理论推导下,构建了光谱字典与稀疏系数的优化学习过程,同时利用了光谱库提供的光谱信息与高分多光谱图像提供的空间信息,实现了更高精度更为稳健的、由单帧高分多光谱图像到高分高光谱图像的光谱超分辨率重建。

2 光谱超分辨率重建模型

设高分高光谱图像由 $X \in \mathbb{R}^{\lambda_x \times N}$ 表示,高分多光谱图像由 $Y \in \mathbb{R}^{\lambda_y \times N}$ 表示,光谱库由 $Z \in \mathbb{R}^{\lambda_z \times M}$ 表示。其中, N 和 M (一般应用场景下通常 $N \gg M$) 分别表示 X 和 Z 各波段中的像素数, λ_x 、 λ_y 和 λ_z ($\lambda_z \geq \lambda_x \gg \lambda_y$) 分别表示 X 、 Y 和 Z 的光谱波段数。则,观测图像 Y 可以表示为 X 的光谱退化:

$$Y = LX + N_y \quad (1)$$

式中, $L \in \mathbb{R}^{\lambda_y \times \lambda_x}$ 为光谱响应函数, N_y 表示观测模型中的零均值高斯噪声。通过式(1)对 X 的估计是一个病态逆问题,可以通过引入稀疏表达来求解。因此,高分高光谱图像 X 与光谱库 Z 可分别表示为光谱字典 $D_x \in \mathbb{R}^{\lambda_x \times K}$ 和 $D_z \in \mathbb{R}^{\lambda_z \times K}$ 的线性组合:

$$X = D_x A_x \quad (2)$$

$$Z = D_z A_z \quad (3)$$

式中, $A_x \in \mathbb{R}^{K \times N}$ 和 $A_z \in \mathbb{R}^{K \times M}$ 分别为 X 和 Z 的稀疏系数矩阵, K 为光谱字典列数。此时,光谱字典 D_x 和 D_z 中的每个原子都可以被视为没有物理意义、更广义的光谱特征,即它们不再是纯净光谱端元。

为了利用光谱库 Z 提供的光谱信息重建 X , 需

要在空间和光谱上建立 X 与 Z 的关系。在光谱上,其光谱分辨率(包括波长和波段数)可能有所不同,因此需要利用矩阵 $P \in \mathbb{R}^{\lambda_x \times \lambda_z}$ 对 Z 进行波段匹配,即匹配后的光谱库可表示为 PZ ;在空间上,如果光谱库 Z 涵盖了 X 中的所有地物种类, X 与 Z 的关系可视为从属关系,由于 D_x 和 D_z 可以分别表示 X 与 PZ , 本文假设从属关系也存在于 D_x 和 D_z 中,可以利用空间变换矩阵 $Q \in \mathbb{R}^{K \times K}$ 表示,即 $D_x = PD_z Q$ 。此时,式(2)可以表达为

$$X = PD_z Q A_x = D_p A_q \quad (4)$$

式中, $A_q = Q A_x$ 为等价稀疏系数矩阵, $D_p = PD_z$ 为匹配后的光谱字典。以上处理过程的主要目的是通过光谱字典,将普通光谱库 Z 映射为与待重建高光谱图像 X 波段对应的特定光谱库。此时,可通过式(4)估计匹配后的光谱字典 D_p 与等价稀疏系数矩阵 A_q , 从而超分重建出高分高光谱图像 X 。

3 光谱超分辨率重建方法

3.1 波段匹配

通过光谱上的波段匹配矩阵 P , 即可实现 X 与 Z 之间的波段匹配过程, P 的求解可描述为以下最小距离问题:

$$\arg \min_{p_i, 1 \leq i \leq \lambda_x} \|P_i W_z - W_{xi}\|_2 \quad (5)$$

式中, $W_z \in \mathbb{R}^{\lambda_z}$ 和 $W_x \in \mathbb{R}^{\lambda_x}$ 分别表示 Z 与 X 的波段信息, W_z 是由光谱库 Z 的各波段中心频率组成的列向量, W_x 是由拟获取高光谱图像 X 的各波段中心频率组成的列向量,需要根据光谱超分辨率需求预先确定;由上式求解波段匹配矩阵 P 的第 i 行 $P_i = [p_{i1}, p_{i2}, \dots, p_{i\lambda_z}] \in \mathbb{R}^{1 \times \lambda_z}$ 过程中,依据 2 范数从 W_z 中寻找与 W_{xi} 最接近的波段中心频率 W_{z_j} , 此时,令 $p_{ij} = 1$ 、 P_i 中其他元素皆为“0”,由此求得 P_i , 逐行重复上述求解过程即可获得波段匹配矩阵 $P = [P_1; P_2; \dots; P_{\lambda_x}] \in \mathbb{R}^{\lambda_x \times \lambda_z}$ 。该波段匹配过程从光谱库中选择特定波段,实现了与待重建高分高光谱图像波段之间的一一对应。

3.2 光谱字典优化学习

获得波段匹配矩阵 P 后,根据波段匹配与空间从属关系,式(1)可进一步表示为

$$Y = LPD_z Q A_x + N_y = LD_p A_q + N_y \quad (6)$$

同时,考虑到光谱信息多存在于匹配后的光谱库 PZ 中,即 $PZ = PD_z A_z = D_p A_z$, 匹配后的光谱

字典 D_p 与等价稀疏系数矩阵 A_q 可以通过求解以下凸松弛后的优化函数获得:

$$\arg \min_{D_p, A_q, A_z} \left\| PZ - D_p A_z \right\|_F^2 + \lambda_1 \| A_z \|_1 + \eta \left\| Y - LD_p A_q \right\|_F^2 + \lambda_2 \| A_q \|_1 \quad (7)$$

式中, η 用于平衡空间误差与光谱误差, 正则化参数 λ_1 与 λ_2 用于平衡表示误差和稀疏性。利用收敛性迭代策略, 通过分别优化以下 3 个子问题, 可以获得上述凸优化问题的解:

$$A_z^{k+1} = \arg \min_{A_z} \mathcal{J}(A_q^k, A_z, D_p^k) \quad (8)$$

$$D_p^{k+1} = \arg \min_{D_p} \mathcal{J}(A_q^k, A_z^{k+1}, D_p) \quad (9)$$

$$A_q^{k+1} = \arg \min_{A_q} \mathcal{J}(A_q, A_z^{k+1}, D_p^{k+1}) \quad (10)$$

式中, $\mathcal{J}(A_q, A_z, D_p)$ 表示式 (7) 中的目标函数, k 为迭代次数。

在固定稀疏系数后, 光谱字典 D_p 可根据式 (9) 优化求解。式 (9) 可细化表示为

$$\arg \min_{D_p} \left\| PZ - D_p A_z \right\|_F^2 + \eta \left\| Y - LD_p A_q \right\|_F^2 \quad (11)$$

由于最小化式 (11) 中两项之和比分别最小化每一项更具挑战性, 本文采用分裂策略利用 ADMM 算法 (Boyd 等, 2011) 求解上述凸问题。此时, 式 (11) 的拉格朗日函数可以描述为

$$L(D_p, S, V_1) = \left\| PZ - D_p A_z \right\|_F^2 + \eta \left\| Y - LS \right\|_F^2 + \mu_1 \left\| S - D_p A_q + V_1/2\mu_1 \right\|_F^2 \quad (12)$$

式中, V_1 为拉格朗日乘子, $S = D_p A_q$ 表示分裂变量。以上最小化问题可以进一步描述为对 D_p 和 S 最小化的子问题:

$$\arg \min_{D_p} \left\| PZ - D_p A_z \right\|_F^2 + \mu_1 \left\| S - D_p A_q + V_1/2\mu_1 \right\|_F^2$$

$$\arg \min_S \eta \left\| Y - LS \right\|_F^2 + \mu_1 \left\| S - D_p A_q + V_1/2\mu_1 \right\|_F^2 \quad (13)$$

式中, 拉格朗日乘子的更新可以表示为

$$V_1^{k+1} = V_1^k + \mu_1 (S^{k+1} - A_q^{k+1}). \quad (14)$$

式 (13) 中的所有子问题的闭式解可以表示为

$$D_p = [PZA_z^T + \mu_1 (S + V_1/2\mu_1) A_q^T] (A_z A_z^T + \mu_1 A_q A_q^T)^{-1}$$

$$S = (\eta L^T L + \mu_1 I)^{-1} [\eta L^T Y + \mu_1 D_p A_q - V_1/2] \quad (15)$$

3.3 稀疏系数优化学习

采用与式 (9) 相似的分裂优化策略, 利用 ADMM 算法优化求解式 (8) 与式 (10), 从而获得稀疏系数 A_z 与等价稀疏系数矩阵 A_q 的闭式解:

$$A_z = \text{soft}(B + V_2/2\mu_2, \lambda_1/2\mu_2)$$

$$B = (D_p^T D_p + \mu_2 I)^{-1} [D_p^T PZ + \mu_2 A_z - V_2/2] \quad (16)$$

$$A_q = \text{soft}(C + V_3/2\mu_3, \lambda_2/2\mu_3)$$

$$C = (\eta D_l^T D_l + \mu_3 I)^{-1} [\eta D_l^T Y + \mu_3 A_q - V_3/2] \quad (17)$$

式中, $D_l = LD_p$ 表示低光谱分辨率字典, $B = A_z$ 与 $C = A_q$ 表示分裂变量, V_2 与 V_3 为拉格朗日乘子。

综上所述, 本研究将光谱库中的光谱信息作为先验, 通过综合利用光谱库提供的光谱信息与高分多光谱提供的空间信息, 进行光谱字典及其稀疏系数优化学习, 实现了仅由一幅高分多光谱图像光谱超分辨率重建高分高光谱图像的目的。本研究建立的 SODL 方法的总体算法框架见图 1。基本算法流程如下。

步骤 1 输入光谱库 Z 、多光谱图像 Y 、波段信息 W_x 、光谱响应函数 L , 设置参数 η 、 λ_1 、 λ_2 、 μ_1 、 μ_2 、 μ_3 , 光谱字典列数 K , 迭代次数 T_1 、 T_2 。

步骤 2 通过式 (5) 求解波段匹配矩阵 P ;

步骤 3 通过式 (15) 求解光谱字典 D_p , 迭代 T_1 次后终止;

步骤 4 通过式 (16) 与式 (17) 求解稀疏系数 A_z 与等价稀疏系数矩阵 A_q , 迭代 T_2 次后终止;

步骤 5 通过式 (8) 至式 (10) 迭代更新步骤 3 至步骤 4;

步骤 6 输出高分高光谱图像 $\hat{X} \leftarrow D_p A_q$ 。

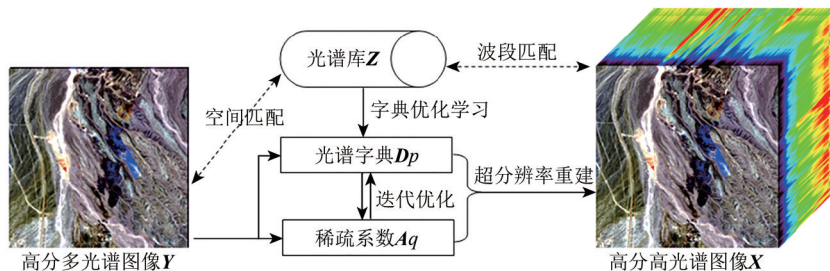


图 1 本研究建立的 SODL 方法的总体算法框架

Fig. 1 Overall framework of the proposed SODL method

4 结果与分析

通过3组实验分别从定性评价、定量分析、以及分类性能提升效果3个方面验证本文方法的有效性与实用性。实验采用均方误差 MSE (Mean Square Error)、峰值信噪比 PSNR (Peak-signal-to-noise ratio)、光谱角 SAM (Spectral Angle Mapper)、通用图像质量指数 UIQI (Universal Image Quality Index) 以及平均结构相似性 ASSIM (Averaged Structural Similarity) 进行评价。其中 ASSIM = $1/\lambda x \sum_{i=1}^{\lambda x} SSIM_i$, $SSIM_i$ 为各波段结构相似性 (Wang 等, 2004) 指标。除了将 SODL 方法与仅利用一幅高分多光谱图像进行光谱超分辨率重建的 HIRSL 算法进行对比外, 还与 G-SOMP+、SASFM、LACRF、NSSR 等同时利用同一场景高分多光谱与低分高光谱图像的重建算法进行了比较。

4.1 模拟数据对比

为了排除成像环境、成像噪声等对超分辨率重建过程有可能产生的不利影响, 在理想环境下对本文所提算法的理论性能加以评价, 模拟数据对比实验选用了 USGS 光谱库中 480 条典型矿物光谱, 其光谱覆盖范围为 400—2500 nm。选择了其中 400 个 97 波段的、可均匀覆盖上述光谱范围的不同光谱数据, 模拟构建 20×20×97 像素的理想高光谱图像, 以排除实际高光谱成像中的噪声影响。为了模拟光谱混合过程, 本实验采用尺寸为 8×8 的高斯模糊核对该理想高光谱图像进行了空间模糊, 从而得到本组实验的高分高光谱参考图像。再利用覆盖可见光与近红外波段的 IKONOS-like 光谱响应函数对参考图像进行光谱退化, 获得尺寸为 20×20×4 像素的模拟高分多光谱图像。同时, 对参考图像进行 $\sigma = 3, 5 \times 5$ 的高斯模糊以及因子为 2 的降采样, 获得尺寸为 10×10×97 像素的同一场景低分高光谱图像, 以满足对比算法对高分多光谱与低分高光谱图像同时获取的要求。受限于低分高光谱图像的尺寸, 对比方法中的光谱字典列数设置为 100。在仅利用一幅高分多光谱图像的 SODL 方法中, 匹配光谱字典列数设为 480, 以更多地保留光谱库中的光谱信息。迭代次数 T_1 、 T_2 分别设置为 30 与 1, 拉格朗日函数中的参数分别设置为

$$\lambda_1 = \lambda_2 = 10^{-4}, \mu_1 = \mu_2 = \mu_3 = 10^{-2}。$$

表 1 比较了在平均 MSE、PSNR、UIQI、SAM 和 ASSIM 指标下不同算法的重建效果, 其中粗体字标示的数值为最优。结果表明, SODL 方法不仅在 ASSIM 指标上优于 SASFM 和 G-SOMP+ 算法, 而且在 MSE、PSNR 和 UIQI 评价指标上优于 G-SOMP+ 算法。具体分析如下: 与 SASFM、G-SOMP+ 算法相比, SODL 方法将 ASSIM 指标由 0.9882、0.9915 提高到了 0.9947; 与 G-SOMP+ 算法相比, SODL 方法中, PSNR 由 48.4157 dB 提高到了 48.8755 dB, 说明重建图像质量至少改善了 0.45 dB。上述结果表明: 即使 G-SOMP+ 等算法同时利用了多光谱与高光谱图像, SODL 方法仍在空间结构上恢复重建出了更多的细节, 获得了较好的重建高分高光谱图像质量; 与利用同一场景低分高光谱图像作为附加信息重建算法不同, SODL 方法的输入仅为一幅高分多光谱图像, 因此其 SAM 指标稍差, 为 1.1911°, 但与 G-SOMP+ 算法的 1.2322°、SASFM 算法的 0.9072°、以及 NSSR 算法的 1.1130° 相比, 相差不大; 与未进行光谱字典与稀疏系数优化学习的 HIRSL 算法相比, SODL 方法的 PSNR 至少提高了 0.32 dB, SAM 指标至少改善了 0.02°, 说明该方法在光谱超分重建上具有更高的准确性。

表 1 模拟数据下不同算法间定量评价指标对比结果

Table 1 Comparison results between different methods on the simulated data

评价 指标	同时利用同一场景多光谱 与高光谱图像方法			仅利用一幅多光谱 图像方法	
	G-SOMP+ 2014	SASFM 2014	NSSR 2016	HIRSL 2019	SODL
MSE	0.9365	0.7096	0.6809	0.9069	0.8424
PSNR	48.4157	49.6206	49.7998	48.5550	48.8755
UIQI	0.9935	0.9944	0.9945	0.9940	0.9941
SAM	1.2322	0.9072	1.1130	1.2152	1.1911
ASSIM	0.9915	0.9882	0.9948	0.9947	0.9947

注: 粗体字标示的数值为最优。

图 2 比较了不同算法下重建图像的光谱曲线。与其他超分辨率重建算法相比, SODL 方法在仅利用一幅高分多光谱图像的情况下, 较好的保持了光谱向量的趋势。从图 2 中重建光谱向量可以看出, 在第 50 和第 85 波段附近, SODL 方法的光谱重建准确性甚至优于 G-SOMP+ 算法。

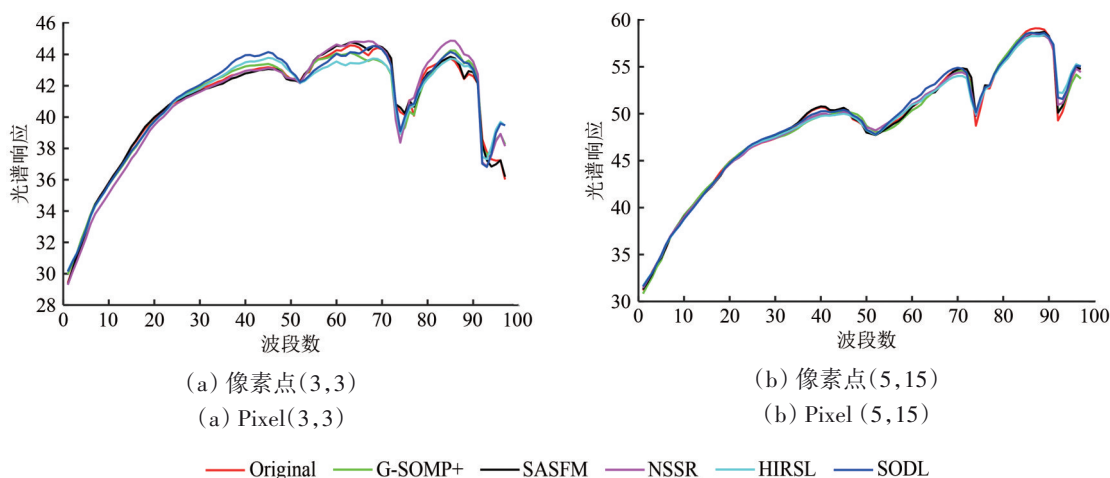


图2 模拟数据下不同算法间重建光谱比较

Fig. 2 Comparison results in the spectral domain between different methods on the simulated data

4.2 真实数据对比

为了在实际成像环境下评价SODL方法的可靠性和有效性,进行了真实数据对比实验。该实验采用AVIRIS机载成像系统于1997年6月19日获得的高光谱图像作为参考图像,尺寸为300×300×97像素、光谱覆盖范围为683—1978 nm。如图3(a)所示,去除了水汽吸收影响较大的第1—2、105—115、150—170和223—224波段,并利用IKONOS-like光谱响应函数对参考图像进行了光谱退化,得到尺寸为300×300×4像素的高分多光谱图像。光谱库则同样采用了USGS光谱库中480条典型矿物光谱。同时,为满足对比算法对高分多光谱与低分高光谱图像的同时获取要求,对参考图像采用 $\sigma = 3$ 、7×7模糊核进行了高斯模糊以及因子为6的降采样,从而获得了尺寸为50×50×97像素的同一场景低分高光谱图像。为了具有可比性,所有算法中的光谱字典列数设置为480,其余参数与上节实验保持相同的设置。

表2为AVIRIS数据下不同算法的平均MSE、PSNR、UIQI、SAM和ASSIM指标对比分析结果,粗体标示的数值为最优。其中,由于NSSR算法中光谱字典列数超出了其最优重建效果范围,该算法的重建效果较差。可见:与同时利用高分多光谱与低分高光谱两幅图像的G-SOMP+、SASFM、LACRF以及NSSR算法相比,SODL方法在仅利用一幅高分多光谱图像的情况下,重建效果仍具有

很好的可比性;与未进行光谱字典与稀疏系数优化学习的HIRSL算法相比,重建出的高分高光谱图像具有更高准确度。值得注意的是,SODL方法在ASSIM指标下具有最优重建效果,这表明其在空间结构中保留了最多的细节信息。此外,SODL方法在SAM、MSE和PSNR指标下优于NSSR与HIRSL算法,在UIQI指标下比同时利用附加图像的LACRF和G-SOMP+算法的重建效果更好。图4为不同算法下重建图像的光谱曲线的比较。可见与其他超分辨率重建方法相比,SODL方法的重建光谱较好保持了原光谱的变化趋势。

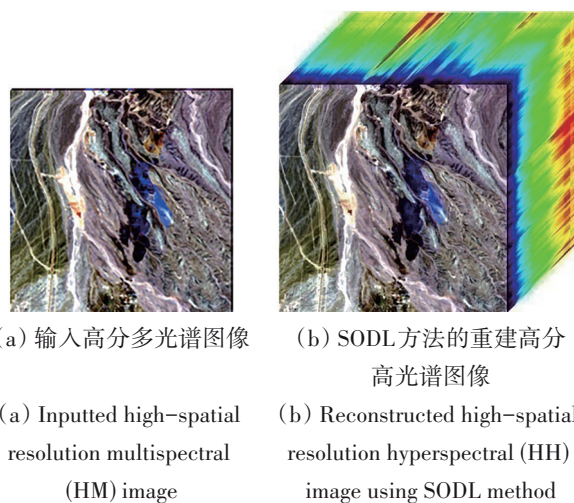


图3 重建前后的假彩色图像示意图

Fig. 3 False color images before and after reconstruction

表2 AVIRIS数据下不同算法间定量评价指标对比结果
Table 2 Comparison results between different methods on AVIRIS data

评价指标	同时利用同一场景多光谱与高光谱图像方法				仅利用一幅多光谱图像方法	
	G-SOMP+2014年	SASFM 2014年	LACRF2016年	NSSR 2016年	HIRSL2019年	SODL
MSE	0.7384	0.4896	0.7792	3.5912	1.6687	1.5802
PSNR	49.4479	51.2322	49.2145	42.5784	45.9071	46.1437
UIQI	0.9979	0.9985	0.9975	0.9920	0.9982	0.9982
SAM	0.3652	0.3198	0.3796	0.7582	0.6119	0.5940
ASSIM	0.9964	0.9965	0.9949	0.9820	0.9970	0.9971

注：粗体字标示的数值为最优。




图4 AVIRIS数据下不同算法间重建光谱比较

Fig. 4 Comparison results in the spectral domain between different methods on the AVIRIS data

4.3 超分辨率重建图像分类精度提升效果分析

采用USGS光谱库中480条典型矿物光谱与18条典型植被光谱数据，每条光谱含有420个波段，同时将地物分类精度测试用、公开高光谱图像Indian Pines和University of Pavia数据集作为实验数据，再利用涵盖可见光和近红外波段的IKONOS-like光谱响应函数对Indian Pines数据进行光谱退化，生成尺寸为145×145×4像素的高分多光谱图像，SODL方法超分辨率重建后的高分高光谱图像尺寸为145×145×200像素。采用相似的光谱退化，由University of Pavia数据获得的高分多光谱图像尺寸为610×340×4像素，SODL方法超分辨率重建后的高分高光谱图像尺寸为610×340×103像素。实验同时采用了Ni和Ma (2015)提出的NC-SVM方法、以及Xu等(2018)提出的RPNNet方法，分别对高分多光谱图像、以及超分辨率重建后的高分高光谱图像进行了地物分类。在有监督分类过程中，Indian Pines数据5%的标注样本、以及University of Pavia数据1%的标注样本将作为有监督分类的训练数据，并对各分类结果采用总体正确率OA (Overall Accuracy) 进行评价。

图5—8分别为NC-SVM方法及RPNNet方法在Indian Pines及University of Pavia数据上的分类结果。可见：与高分多光谱图像相比，利用SODL方法进行超分辨率重建后的高分高光谱图像具有更高的地物分类准确度。即对于NC-SVM方法，在两个数据集上的OA指标分别提升了11.0%与0.94%；RPNNet方法在两个数据集上的OA指标分别提升了0.33%与1.24%。由此可见，采用不同类别的高光谱地物分类方法，光谱超分辨率重建后高分高光谱图像的地物分类精度均有一定幅度的提升，说明SODL方法具有普适性及其实际应用价值。

4.4 计算复杂度分析

SODL方法复杂度主要由波段匹配、光谱字典优化学习与稀疏系数优化学习3部分构成。其中，波段匹配的复杂度为 $O(\lambda_x \lambda_x)$ 。根据式(15)，光谱字典优化学习中更新 D_p 和 S 的计算复杂度分别为 $O(T_1(\lambda_x KN + K^3 + NK^2))$ 与 $O(T_1(\lambda_y \lambda_x^2 + \lambda_x^3 + \lambda_x KN))$ ；与Han等(2019)所提方法的分析类似，根据式(16)与(17)，稀疏系数优化学习中更新 A_2 、 B 、 A_q 与 C 的计算复杂度分别为 $O(M)$ 、

$O(T_2(\lambda_x K^2 + K^3 + \lambda_x KM))$ 、 $O(N)$ 与 $O(T_2(\lambda_y K^2 + K^3 + \lambda_y KN))$ 。因此, 在 $\lambda_y \ll \lambda_x \ll K \ll N$ 的一般应

用场景下, 本文所提方法的总计算复杂度为 $O(T_1 NK^2 + T_2(\lambda_x KM + \lambda_y KN + K^3))$ 。

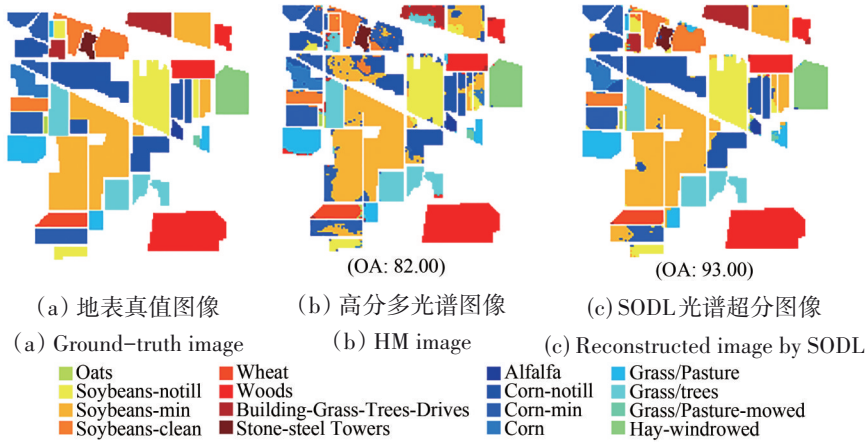


图5 Indian Pines 数据集下 NC-SVM 方法分类结果

Fig. 5 Classification results on the Indian Pines dataset by NC-SVM method

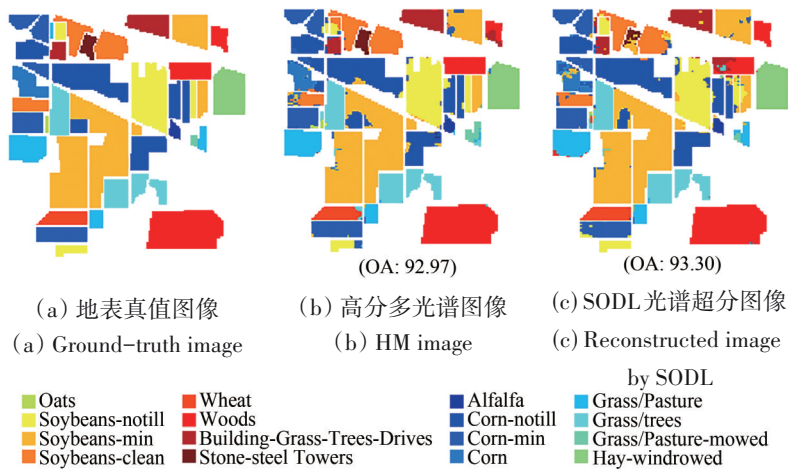


图6 Indian Pines 数据集下 RPNNet 方法分类结果

Fig. 6 Classification results on the Indian Pines dataset by RPNNet method

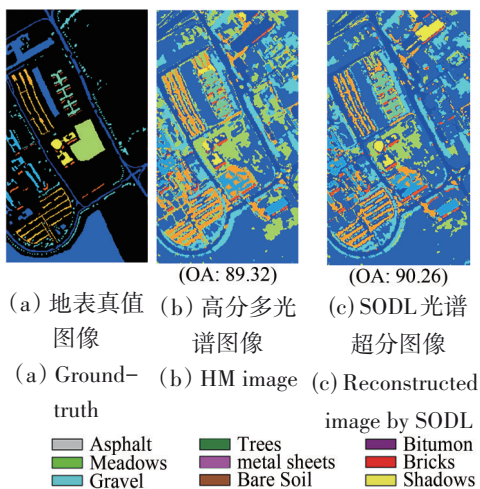


图7 University of Pavia 数据集下 NC-SVM 方法分类结果
Fig. 7 Classification results on the University of Pavia dataset by NC-SVM method

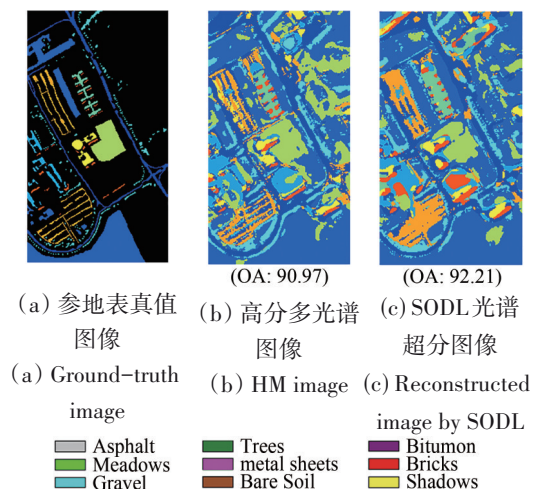


图8 University of Pavia 数据集下 RPNNet 方法分类结果
Fig. 8 Classification results on the University of Pavia dataset by RPNNet method

5 结 论

本文提出了一种基于光谱库优化学习的光谱超分辨率重建方法, 简称SODL方法。该方法利用波段匹配, 将光谱库映射为与待重建高分高光谱图像波段对应的特定光谱库; 综合利用特定光谱库提供的光谱信息与高分多光谱提供的空间信息, 进行光谱字典优化学习与稀疏系数矩阵估计, 进而实现了仅由一幅高分多光谱图像到高分高光谱图像的超分辨率重建。模拟与真实数据集、以及多种图像质量评价指标下的光谱超分辨率重建对比结果表明, 虽然SODL方法仅使用了一幅高分多光谱图像, 但与同时使用高分多光谱图像与低分高光谱图像的其他超分辨率重建算法相比, 其在重建效果上具有很好的可比性, 部分指标甚至更优; 与未进行光谱字典与稀疏系数优化学习的相关算法相比, SODL方法重建的高分高光谱图像具有更高准确度; 同时, 光谱超分辨率重建后的高分高光谱图像可显著提升地物分类精度。SODL方法可为促进轻小型高分高光谱成像设备的研发, 为小卫星及无人机平台提供更为可行的高光谱成像手段。

参考文献(References)

- Aiazzi B, Baronti S and Selva M. 2007. Improving component substitution pansharpening through multivariate regression of MS + Pan data. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10): 3230-3239 [DOI: 10.1109/TGRS.2007.901007]
- Akhtar N, Shafait F and Mian A. 2014. Sparse spatio-spectral representation for hyperspectral image super-resolution//13th European Conference on Computer Vision. Cham: Springer: 63-78 [DOI: 10.1007/978-3-319-10584-0_5]
- Boyd S, Parikh N, Chu E, Peleato B and Eckstein J. 2011. 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]
- Carper W J, Lillesand T M and Kiefer P W. 1990. The use of intensity-hue-saturation transformations for merging SPOT panchromatic and multispectral image data. *Photogrammetric Engineering and Remote Sensing*, 56(4): 457-467.
- Dong C, Loy C C, He K M and Tang X O. 2014. Learning a deep convolutional network for image super-resolution//13th European Conference on Computer Vision. Zurich: Springer: 184-199 [DOI: 10.1007/978-3-319-10593-2_13]
- Dong W S, Fu F Z, Shi G M, Cao X, Wu J J, Li G Y and Li X. 2016. Hyperspectral image super-resolution via non-negative structured sparse representation. *IEEE Transactions on Image Processing*, 25(5): 2337-2352 [DOI: 10.1109/TIP.2016.2542360]
- Ertürk A, Güllü M K, Çeşmeci D, Gerçek D and Ertürk S. 2014. Spatial resolution enhancement of hyperspectral images using unmixing and binary particle swarm optimization. *IEEE Geoscience and Remote Sensing Letters*, 11(12): 2100-2104 [DOI: 10.1109/LGRS.2014.2320135]
- Ertürk A, Iordache M D and Plaza A. 2016. Sparse unmixing-based change detection for multitemporal hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(2): 708-719 [DOI: 10.1109/JSTARS.2015.2477431]
- Ghasrodashti E K, Karami A, Heylen R and Scheunders P. 2017. Spatial resolution enhancement of hyperspectral images using spectral unmixing and bayesian sparse representation. *Remote Sensing*, 9(6): 541 [DOI: 10.3390/rs9060541]
- Grohnfeldt C, Zhu X X and Bamler R. 2013. Jointly sparse fusion of hyperspectral and multispectral imagery//2013 IEEE International Geoscience and Remote Sensing Symposium. Melbourne: IEEE: 4090-4093 [DOI: 10.1109/IGARSS.2013.6723732]
- Han X L, Yu J, Luo J Q and Sun W D. 2019. Reconstruction from multispectral to hyperspectral image using spectral library-based dictionary learning. *IEEE Transactions on Geoscience and Remote Sensing*, 57(3): 1325-1335 [DOI: 10.1109/TGRS.2018.2866054]
- Hu J, Li Y S and Xie W Y. 2017. Hyperspectral image super-resolution by spectral difference learning and spatial error correction. *IEEE Geoscience and Remote Sensing Letters*, 14(10): 1825-1829 [DOI: 10.1109/LGRS.2017.2737637]
- Huang B, Song H H, Cui H B, Peng J G and Xu Z B. 2014. Spatial and spectral image fusion using sparse matrix factorization. *IEEE Transactions on Geoscience and Remote Sensing*, 52(3): 1693-1704 [DOI: 10.1109/TGRS.2013.2253612]
- Iordache M D, Bioucas-Dias J M and Plaza A. 2014. Collaborative sparse regression for hyperspectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*, 52(1): 341-354 [DOI: 10.1109/TGRS.2013.2240001]
- Kawakami R, Matsushita Y, Wright J, Ben-Ezra M, Tai Y W and Ikeuchi K. 2011. High-resolution hyperspectral imaging via matrix factorization//CVPR 2011. Colorado Springs: IEEE: 2329-2336 [DOI: 10.1109/CVPR.2011.5995457]
- Keshava N and Mustard J F. 2002. Spectral unmixing. *IEEE Signal Processing Magazine*, 19(1): 44-57 [DOI: 10.1109/79.974727]
- 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]

- Li S T, Li C Y and Kang X D. 2021. Development status and future prospects of multi-source remote sensing image fusion. *National Remote Sensing Bulletin*, 25(1): 148-166 (李树涛, 李聪好, 康旭东. 2021. 多源遥感图像融合发展现状与未来展望. *遥感学报*, 25(1): 148-166) [DOI: 10.11834/jrs.20210259]
- Loncan L, De Almeida L B, Bioucas-Dias J M, Briottet X, Chanussot J, Dobigeon N, Fabre S, Liao W Z, Licciardi G A, Simoes M, Tourneret J Y, Veganzones M A, Vivone G, Wei Q and Yokoya N. 2015. Hyperspectral pansharpening: a review. *IEEE Geoscience and Remote Sensing Magazine*, 3(3): 27-46 [DOI: 10.1109/MGRS.2015.2440094]
- Lu X Q, Yuan Y and Yan P K. 2014. Alternatively constrained dictionary learning for image superresolution. *IEEE Transactions on Cybernetics*, 44(3): 366-377 [DOI: 10.1109/TCYB.2013.2256347]
- Mei S H, Yuan X, Ji J Y, Wan S, Hou J H and Du Q. 2017. Hyperspectral image super-resolution via convolutional neural network//2017 IEEE International Conference on Image Processing (ICIP). Beijing: IEEE: 4297-4301 [DOI: 10.1109/ICIP.2017.8297093]
- Nezhad Z H, Karami A, Heylen R and Scheunders P. 2016. Fusion of hyperspectral and multispectral images using spectral unmixing and sparse coding. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(6): 2377-2389 [DOI: 10.1109/JSTARS.2016.2528339]
- Ni D and Ma H B. 2015. Spectral-spatial classification of hyperspectral images based on neighborhood collaboration. *Acta Automatica Sinica*, 41(2): 273-284 (倪鼎, 马洪兵. 基于近邻协同的高光谱图像谱-空联合分类. *自动化学报*, 2015, 41(2): 273-284) [DOI: 10.16383/j.aas.2015.c140043]
- Pan Z X, Yu J, Xiao C B and Sun W D. 2014. Spectral similarity-based super resolution for hyperspectral images. *Acta Automatica Sinica*, 40(12): 2797-2807 (潘宗序, 禹晶, 肖创柏, 孙卫东. 基于光谱相似性的高光谱图像超分辨率算法. *自动化学报*, 40(12): 2797-2807) [DOI: 10.3724/SP.J.1004.2014.02797]
- Simões M, Bioucas-Dias J, Almeida L B and Chanussot J. 2015. A convex formulation for hyperspectral image superresolution via subspace-based regularization. *IEEE Transactions on Geoscience and Remote Sensing*, 53(6): 3373-3388 [DOI: 10.1109/TGRS.2014.2375320]
- Veganzones M A, Simoes M, Licciardi G, Yokoya N, Bioucas-Dias J M and Chanussot J. 2016. Hyperspectral super-resolution of locally low rank images from complementary multisource data. *IEEE Transactions on Image Processing*, 25(1): 274-288 [DOI: 10.1109/TIP.2015.2496263]
- Villa A, Chanussot J, Benediktsson J A, Ulfarsson M and Jutten C. 2010. Super-resolution: an efficient method to improve spatial resolution of hyperspectral images//2010 IEEE International Geoscience and Remote Sensing Symposium. Honolulu: IEEE, 2003-2006 [DOI: 10.1109/IGARSS.2010.5654208]
- Wang J, Peng J Y, Jiang X Y, Feng X and Zhou J H. 2017. Remote-sensing image fusion using sparse representation with sub-dictionaries. *International Journal of Remote Sensing*, 38(12): 3564-3585 [DOI: 10.1080/01431161.2017.1302106]
- Wang Z, Bovik A C, Sheikh H R and Simoncelli E P. 2004. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4): 600-612 [DOI: 10.1109/TIP.2003.819861]
- Wei Q, Bioucas-Dias J, Dobigeon N and Tourneret J Y. 2015. Hyperspectral and multispectral image fusion based on a sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7): 3658-3668 [DOI: 10.1109/TGRS.2014.2381272]
- Xu N, Xiao X Y, Geng X R, You H J and Cao Y G. 2016. Spectral-spatial constrained sparse unmixing of hyperspectral imagery using a hybrid spectral library. *Remote Sensing Letters*, 7(7): 641-650 [DOI: 10.1080/2150704X.2016.1177240]
- Xu Y H, Du B, Zhang F and Zhang L P. 2018. Hyperspectral image classification via a random patches network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 142: 344-357 [DOI: 10.1016/j.isprsjprs.2018.05.014]
- Yokoya N, Grohnfeldt C and Chanussot J. 2017. Hyperspectral and multispectral data fusion: a comparative review of the recent literature. *IEEE Geoscience and Remote Sensing Magazine*, 5(2): 29-56 [DOI: 10.1109/MGRS.2016.2637824]
- Yokoya N, Yairi T and Iwasaki A. 2012. Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 50(2): 528-537 [DOI: 10.1109/TGRS.2011.2161320]
- Yuan Y, Zheng X T and Lu X Q. 2017. Hyperspectral image superresolution by transfer learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(5): 1963-1974 [DOI: 10.1109/JSTARS.2017.2655112]
- Zhang K, Wang M, Yang S Y, Xing Y H and Qu R. 2016. Fusion of panchromatic and multispectral images via coupled sparse nonnegative matrix factorization. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(12): 5740-5747 [DOI: 10.1109/JSTARS.2015.2475754]
- Zhao T, Zhang Y F, Xue X Q and He M Y. 2016. Hyperspectral and multispectral image fusion using collaborative representation with local adaptive dictionary pair//2016 IEEE International Geoscience and Remote Sensing Symposium. Beijing: IEEE: 7212-7215 [DOI: 10.1109/IGARSS.2016.7730881]
- Zhu J, Zhou L F and Zhang D R. 2011. Identification for building surface material based on hyperspectral remote sensing//2011 19th International Conference on Geoinformatics. Shanghai: IEEE: 1-5 [DOI: 10.1109/GeoInformatics.2011.5980687]
- Zhu X X, Spiridonova S and Bamler R. 2012. A pan-sharpening algorithm based on joint sparsity//2012 Tyrrhenian Workshop on Advances in Radar and Remote Sensing (TyWRRS). Naples: IEEE: 177-184 [DOI: 10.1109/TyWRRS.2012.6381125]

Spectral super-resolution using optimized dictionary learning via spectral library and its effects on classification

HAN Xiaolin, ZHANG Huan, SUN Weidong

Department of Electronic Engineering, Tsinghua University, Beijing 100084, China

Abstract: The spectral library can contain the spectral information on the whole types of ground surface objects in the observation area of hyperspectral images. Thus, the optimized dictionary learning via spectral library refers to the process of constructing optimized spectral dictionary under strict theoretical derivation, in which the spectra in the spectral library are used as training samples. The abovementioned process enables the spectra in the hyperspectral image to be sparsely represented under the learned spectral dictionary. To this end, a new spectral super-resolution method using optimized dictionary learning via spectral library is proposed in this study. This method uses only one high spatial multispectral image to reconstruct high spatial hyperspectral image. The aforementioned problem is formulated in the framework of sparse representation, as an estimation of the band matching matrix, the optimized spectral dictionary, and the corresponding sparse coefficients. Specifically, a band matching method is proposed to map the common spectral library to a specific spectral library corresponding to the reconstructed high spatial hyperspectral image. Then, an optimization of spectral dictionary and its corresponding sparse coefficients is derived theoretically using the alternating direction method of multipliers (ADMM) algorithm and by utilizing the abovementioned specific spectral library and the high spatial multispectral image. Comparison results with the relative methods demonstrate that our method not only can achieve a high-quality reconstruction of the high spatial hyperspectral image but also can significantly improve the classification accuracy of multispectral images by even only using one high spatial multispectral image.

We aim to reconstruct high spatial hyperspectral image only from one high spatial multispectral image with high quality.

Three steps of our proposed method are discussed in detail. First, the band matching matrix is estimated using the band wavelength information. Second, the matched spectral dictionary is optimized using the matched spectral library and the high spatial multispectral image. Third, the equivalent sparse coefficient matrix with respect to the matched spectral dictionary is derived theoretically and estimated iteratively.

Extensive experiments and comparative analyses of the proposed method are conducted on various datasets to demonstrate the performance and practical application value of our proposed method. The improvement in classification accuracy on the reconstructed high spatial hyperspectral images is also evaluated using some typical classification methods.

A spectral super-resolution method is proposed, and it uses only one high spatial multispectral image to reconstruct high spatial hyperspectral image. A band matching matrix, which is used to map the common spectral library to a specific spectral library, is obtained by solving the minimum distance problem. A spectral dictionary and its corresponding sparse coefficient matrix are optimized from the matched spectral library and the high spatial hyperspectral image by minimizing augmented Lagrangian function using ADMM iteratively. Experiments on simulated and real datasets demonstrate that our proposed method can produce comparable results for the spectral super-resolution to the other relative state-of-the-art reconstruction or fusion-based methods using additional low spatial hyperspectral image. It can also provide higher reconstruction quality than the HIRSL method without optimization. Our proposed SODL method that uses only one multispectral image may help develop new light and small high spatial hyperspectral imaging equipment.

Key words: spectral super-resolution, spectral library, sparse representation, optimized dictionary learning, landcover classification

Supported by National Natural Science Foundation (No. 41971294); Project funded by China Postdoctoral Science Foundation (No. 2020M680560); Cross-Media Intelligent Technology Project of BNRist (No. BNR2019TD01022)