

## 空间光谱联合稀疏表示的高光谱图像超分辨率方法

许蒙恩<sup>1</sup>, 谢宝陵<sup>1</sup>, 徐国明<sup>1,2\*</sup><sup>1</sup>中国人民解放军陆军炮兵防空兵学院, 安徽 合肥 230031;<sup>2</sup>安徽新华学院信息工程学院, 安徽 合肥 230088

**摘要** 针对获取的高光谱图像空间分辨率较低的问题,设计了一种空间光谱联合稀疏表示的超分辨率方法:提取图像中不同的反射光谱,通过压缩感知字典学习算法得到强稀疏性、弱相干性的光谱字典;利用高光谱图像信号的稀疏性、非负性以及空间结构相似性,通过同步正交匹配追踪算法,从相同场景的高空间分辨率的低光谱图像求解得到稀疏编码矩阵;联合光谱字典和稀疏编码矩阵得到目标图像。由于联合使用高光谱图像的空间与光谱信息,仿真实验数据和真实实验数据结果表明,相比于传统方法和矩阵分解方法本文方法,能够有效重建图像细节信息与纹理结构,有效提高波段平均峰值信噪比、波段平均结构相似度以及光谱角映射,并且更好地保持光谱信息。

**关键词** 图像处理;超分辨率重建;高光谱图像;联合稀疏表示;同步正交匹配追踪;信号非负性;空间结构相似性  
中图分类号 TP391; TN911.73 文献标识码 A doi: 10.3788/LOP55.071014

## Hyperspectral Image Super-Resolution Method Based on Spatial Spectral Joint Sparse Representation

Xu Meng'en<sup>1</sup>, Xie Baoling<sup>1</sup>, Xu Guoming<sup>1,2</sup><sup>1</sup>Army Artillery and Air Defense Forces Academy of PLA, Hefei, Anhui 230031, China;<sup>2</sup>Information Engineering College, Anhui Xinhua University, Hefei, Anhui 230088, China

**Abstract** In order to solve the problem of low spatial resolution of hyperspectral image, a method based on spatial spectral joint sparse representation is designed. Firstly, we extract the different reflectance spectra of scenes and obtain a spectral dictionary with strong sparsity and weak coherence by exploiting compressed sensing dictionary learning algorithm. Then using sparsity, non-negativity and spatial structure similarity of hyperspectral image signals, we obtain the sparse coding matrix from the high-spatial resolution low-spectral image of the same scene by the simultaneous orthogonal matching pursuit algorithm. Finally, we combine the spectral dictionary with sparse coding matrix to get the target image. As a result of the combined spatial and spectral information, the simulated data and real data experimental results show that this method can effectively reconstruct image detail information and texture structure compared with bicubic interpolation method and matrix decomposition method, and effectively improve the value of average peak signal-to-noise ratio, average structural similarity, and spectral angle mapper, and maintain the spectral information better.

**Key words** image processing; super-resolution reconstruction; hyperspectral image; joint sparse representation; simultaneous orthogonal matching pursuit; signal non-negative; spatial structure similarity

**OCIS codes** 100.6640; 110.3010; 110.4234

收稿日期: 2018-01-17; 收到修改稿日期: 2018-01-31

基金项目: 安徽高校科学研究自然科学重点项目(KJ2018A0587)、中国博士后科学基金(2016M592961)、安徽省自然科学基金(1608085MF140)

作者简介: 许蒙恩(1994—),男,硕士研究生,主要从事计算机视觉、图像超分辨率重建与目标检测等方面的研究。

E-mail: 2695315332@qq.com

导师简介: 谢宝陵(1960—),男,硕士,教授,硕士生导师,主要从事计算机视觉、图像处理与网络空间安全等方面的研究。

E-mail: xiao8288@qq.com

\* 通信联系人。E-mail: xgm121@163.com

# 1 引言

高光谱成像技术是 20 世纪 80 年代以来综合对地观测技术的重要组成部分。高光谱成像技术将成像技术与光谱技术结合在一起,包含丰富的空间信息、辐射信息和光谱信息,具有光谱连续、图谱合一等特性<sup>[1]</sup>。由于其良好的光谱特性,高光谱图像已经广泛应用于地质勘查、海洋监测、战场侦察等领域<sup>[2]</sup>。另外,在医学成像中,通过高光谱成像技术获得的超分辨率光谱成像可提供关于组织生理学、形态学和组成的诊断信息<sup>[3]</sup>。遥感图像的空间分辨率是衡量高光谱遥感影像质量的一个重要指标,反映了图像上能看到的表面最小目标尺寸,决定了实际应用中地面目标的检测识别能力<sup>[4]</sup>。受成像条件和成像环境的影响,高光谱成像技术获取的图像空间分辨率较低,并产生大量混合像素,大大降低后续的检测和识别性能,进而影响其在军事和民用领域的应用。因此,提高高光谱图像的空间分辨率具有重要意义。为解决该问题,有研究者提出使用高分辨率传感器的方案,但是该方案会降低到达传感器光子的密度,使其在许多应用场合不可行<sup>[5]</sup>。由于硬件设备的限制,采用基于软方法的图像超分辨率(SR)技术是提升图像空间分辨率的有效手段<sup>[6]</sup>。由于 SR 问题的性质不足,已经有多种正则化方法被用来解决该问题,包括基于插值的方法、基于多帧图像的方法和基于样本学习的单帧图像超分辨率方法<sup>[7]</sup>。这些方法在灰度图像或彩色图像上取得较好的重建效果,但是直接应用于高光谱图像重建的效果并不理想。

高光谱图像 SR 问题在于不仅要提高空间域信息,而且还需要保持光谱信息。Akgun 等<sup>[8]</sup>提出一种基于凸集投影的高光谱图像 SR 方法,融合多个光谱带的信息以提高空间分辨率,并将观测场景的频谱重建为少量频谱基函数的组合。为了估计运动参数,Zhang 等<sup>[9]</sup>提出一种基于最大后验的多帧图像 SR 方法,利用主成分分析减少计算负荷,并重建高分辨率图像。然而,上述基于多帧图像的 SR 方法需要精确的配准过程。为了克服这个困难,近年来基于压缩感知的方法得到足够重视,可以从高分辨率的训练图像中学习,重建后得到高分辨率图像的高频细节<sup>[10]</sup>。针对高光谱图像各波段噪声强度不同,空间域和光谱域均存在噪声污染的问题,徐平等<sup>[11]</sup>提出一种基于分组三维离散余弦变换字典的稀疏表示方法。为了增强高光谱图像的空间分辨

率,Huang 等<sup>[12]</sup>利用稀疏矩阵分解的方法将高光谱图像与全色图像融合;Nezhad 等<sup>[13]</sup>提出一种光谱解混合与稀疏编码方法,用于高光谱图像与 RGB 图像融合;Zhou 等<sup>[14]</sup>利用耦合光谱解混合的方法融合多光谱和高光谱遥感图像,提高高光谱图像的空间分辨率。上述图像融合的方法在一定程度上提高了图像的空间分辨率,但是没有采用行之有效的方法引入光谱域信息来提高重建效果,所得图像存在光谱信息失真的问题。

与高光谱成像系统相比,低光谱分辨率成像系统场景辐射的总体量化虽然消除了大部分的光谱信息,但是能够较好地保留场景图像的空间结构信息,利用该成像系统获取的高分辨率图像有助于提高高光谱图像的空间分辨率。为此,本文联合利用高分辨率的低光谱图像以及高光谱图像信息,提出一种空间光谱联合稀疏表示的高光谱图像超分辨率方法。提取图像中不同的反射光谱,通过压缩感知字典学习方法得到光谱字典;利用高光谱图像信号的稀疏性、非负性以及空间结构相似性,从相同场景的高空间分辨率的低光谱图像中,通过同步正交匹配追踪算法求解得到稀疏编码矩阵;联合光谱字典和稀疏编码矩阵得到目标图像。

## 2 高光谱图像 SR 框架

高光谱图像 SR 的目标是从已经获得的低分辨率(LR)高光谱图像  $\mathbf{Y}_h$  和相应的高分辨率图像  $\mathbf{Y}$  中恢复得到高分辨率的高光谱图像  $\mathbf{S}$ ,其中  $\mathbf{Y}_h \in \mathbf{R}^{m \times n \times L}$ ,  $\mathbf{Y} \in \mathbf{R}^{M \times N \times l}$ ,  $\mathbf{S} \in \mathbf{R}^{M \times N \times L}$ ,  $M$ 、 $m$ 、 $N$  和  $n$  为空间维尺寸, $L$  和  $l$  为光谱维数。由于  $M \gg m$ ,  $N \gg n$ ,  $L \gg l$ ,使得该问题不适定,现考虑将  $\mathbf{Y}_h$  和  $\mathbf{Y}$  分别作为目标图像  $\mathbf{S}$  的线性映射,即:

$$\begin{cases} \mathbf{Y}_h = \phi_h(\mathbf{S}) \\ \mathbf{Y} = \phi(\mathbf{S}) \end{cases}, \quad (1)$$

式中  $\phi_h$  表示  $\mathbf{R}^{M \times N \times L} \rightarrow \mathbf{R}^{m \times n \times L}$ ,  $\phi$  表示  $\mathbf{R}^{M \times N \times L} \rightarrow \mathbf{R}^{M \times N \times l}$ 。

由高光谱图像的稀疏性先验信息可知,高光谱图像中通常只包含少数不同的材料,并且与整个图像相比,每个像素中通常只包含非常少量的不同光谱。因此  $\mathbf{Y}_h$  中的像素  $\mathbf{y}_h$  可以通过线性组合光谱字典  $\Phi$  的原子来表示,则  $\mathbf{y}_h \in \mathbf{R}^L$ ,可表示为

$$\mathbf{y}_h \approx \Phi \boldsymbol{\alpha}, \quad (2)$$

式中:  $\Phi \in \mathbf{R}^{L \times d}$ , 为图像中不同材料的反射向量;  $\boldsymbol{\alpha} \in \mathbf{R}^d$ , 为系数向量。当像素  $\mathbf{y}_h$  表示的场景也包括  $\mathbf{Y}$  的像素  $\mathbf{y}$  对应区域时,则  $\mathbf{y} \in \mathbf{R}^l$ ,可以近似表示为

$$\mathbf{y} \approx (\mathbf{T}\Phi)\boldsymbol{\beta}, \quad (3)$$

式中:  $\mathbf{T} \in \mathbf{R}^{l \times L}$ , 是一个变换矩阵;  $\boldsymbol{\beta} \in \mathbf{R}^d$ , 为系数向量。  $\mathbf{T}$  是将高光谱成像系统的光谱量化与高分辨率的低光谱成像系统相关联的矩阵, 使用矩阵之间的联系性可得:

$$\mathbf{y} \approx (\mathbf{T}\Phi)\boldsymbol{\beta} \approx \mathbf{T}\mathbf{s}, \quad (4)$$

式中  $\mathbf{s} \in \mathbf{R}^L$ , 表示高分辨率目标图像  $\mathbf{S}$  中的像素。(4)式表明, 如果字典  $\Phi$  已知, 则可以通过适当的稀疏编码矩阵联合估计高分辨率的高光谱图像  $\mathbf{S}$ 。

本文将  $\Phi$  称为字典,  $\mathbf{T} \in \mathbf{R}^{l \times L}$  为变换矩阵,  $\tilde{\Phi}$  为变换后的字典。字典  $\Phi$  的每一列被称为字典原子, 系数矩阵(例如  $\mathbf{B}$ )被称为稀疏编码矩阵。接下来将通过学习字典  $\Phi$  以及相应的稀疏编码矩阵  $\mathbf{B}$ , 进而得到目标图像  $\mathbf{S}$ 。

### 3 空间光谱联合稀疏表示的 SR 方法

#### 3.1 基于压缩感知的字典学习方法

如前所述, 基于压缩感知的 SR 方法可以从高分辨率的训练图像中学习, 重建后得到高分辨率图像的高频细节<sup>[10]</sup>。现假设低分辨率的高光谱图像  $\mathbf{Y}_h$  和高分辨率的高光谱图像  $\mathbf{X}_h, h = \{1, 2, \dots, L\}$ , 式中  $L$  为图像中光谱带的数量。根据压缩感知理论,  $\mathbf{Y}_h$  和  $\mathbf{X}_h$  之间的关系为

$$\mathbf{Y}_h = \mathbf{F}\mathbf{H}\mathbf{X}_h + \mathbf{v}, \quad (5)$$

式中  $\mathbf{F}$  为下采样算子,  $\mathbf{H}$  为模糊滤波器,  $\mathbf{v}$  为加性噪声。其中  $\mathbf{W} = \mathbf{F}\mathbf{H}$ ,  $\mathbf{W}$  为线性观测矩阵。将线性观测矩阵  $\mathbf{W}$  表示为压缩感知理论的感知矩阵。为了从  $\mathbf{Y}_h$  正确地恢复  $\mathbf{X}_h$ , 根据压缩感知理论可知, 必须满足以下两个条件。

1) 稀疏性。假设高分辨率图像块的列向量  $\mathbf{x}_i$  可以由完备的字典稀疏表示, 其中  $\mathbf{x}_i \in \mathbf{R}^L, \mathbf{x}_i = \mathbf{R}_i\mathbf{X}_h, \mathbf{R}_i$  表示  $\mathbf{X}_h$  的提取算子, 则有

$$\mathbf{x}_i = \Phi\alpha_i, \quad (6)$$

式中  $\alpha_i$  为稀疏表示系数, 并且  $\alpha_i$  中大多数元素为零, 可以得到以下  $l_0$  范数优化问题, 即:

$$\min \|\mathbf{x}_i - \Phi\alpha_i\|_2 \text{ s.t. } \|\alpha_i\|_0 \leq V_0, \quad (7)$$

式中  $V_0$  为稀疏约束参数。

2) 不相干性。感知矩阵  $\mathbf{W} \in \mathbf{R}^{m \times L}$  与字典  $\Phi \in \mathbf{R}^{L \times d}$  之间的相干性为

$$V(\mathbf{W}, \Phi) =$$

$$\sqrt{L} \max_{1 \leq p \leq m, 1 \leq q \leq d} |\langle \mathbf{W}_p, \Phi_q \rangle|, \quad (8)$$

式中  $\mathbf{W}_p$  为  $\mathbf{W}$  的第  $p$  行,  $\Phi_q$  为  $\Phi$  的第  $q$  列,  $V(\mathbf{W}, \Phi) \in [1, \sqrt{L}]$ 。压缩感知理论证明, 相干性  $V$  越小, 重建结果越好。

字典的选择在稀疏表示领域起着非常重要的作用。基于上述压缩感知理论的稀疏性和不相干性, 将通过压缩感知的字典学习方法得到一个强稀疏性、弱相干性的光谱字典。该字典学习方法从获取的 LR 图像本身学习字典, 因为在局部或者非局部区域内, 不同波段的 LR 图像中存在大量相似的图像块; 并且 Pan 等<sup>[16]</sup>的研究结果表明, 使用预处理后的 LR 图像作为训练样本, 学习的字典比使用高分辨率图像训练得到的字典效果更好。

基于压缩感知的字典学习方法, 首先通过线性插值方法处理 LR 高光谱图像  $\mathbf{Y}_h$ , 然后利用预处理后的图像块训练得到字典。另外, 为了生成高分辨率训练集  $\mathbf{X}_h^{\text{HR}}$ , 将训练图像块的所有列向量连接成矩阵  $\mathbf{X}_h^{\text{HR}}, \mathbf{X}_h^{\text{HR}} = \{\mathbf{x}_1, \dots, \mathbf{x}_i, \dots, \mathbf{x}_{mn}\}$ , 式中  $\mathbf{x}_i$  为预处理后的图像块形成的列向量,  $mn$  为训练图像块的数量。为了同时满足压缩感知理论的两个约束条件, 该字典学习任务可表示为

$$\min \{\Phi, \mathbf{A}\} \|\mathbf{X}_h^{\text{HR}} - \Phi\mathbf{A}\|_F^2 \text{ s.t. } \|\alpha_i\|_0 \leq V_0, \quad V(\mathbf{W}, \Phi) \leq V_1, \quad (9)$$

式中  $\mathbf{A} \in \mathbf{R}^{d \times mn}$  为所有稀疏表示系数  $\alpha_i$  的矩阵,  $V_0$  为稀疏约束参数,  $V_1$  为相干性阈值。基于压缩感知的字典学习方法充分利用压缩感知理论的强稀疏性和弱相干性, 使学习字典和感知矩阵之间的一致性变小; 另外, 本方法学习的字典并不是含有固定数量的字典原子, 可以根据相干阈值来降低字典的维度, 加快稀疏分解的速度。综上所述, 基于压缩感知的字典学习算法描述如下。

算法 1: 基于压缩感知的字典学习算法

输入: 获取的 LR 高光谱图像  $\mathbf{Y}_h$ , 训练集  $\{\mathbf{X}_i^{\text{HR}}\}_{i=1}^m$  和线性观测矩阵  $\mathbf{W}$ ;

1) 随机初始字典  $\Phi^0 \in \mathbf{R}^{L \times d}$ ;

2) 重复以下步骤, 并将  $r$  每次增加 1:

- ① 固定字典  $\Phi$ , 使用 OMP 算法来获得(9)式中的稀疏系数  $\alpha^r$ ;
- ② 使用 K-SVD 方法的字典更新阶段来更新字典中的每一列, 获得字典  $\Phi^r$ ;
- ③ 通过(8)式计算相干矩阵  $\mathbf{V}$ , 然后找到矩阵  $\mathbf{V}$  中每一列的最大值, 得到向量  $\{\tau_u\}_{u=1}^d$ ;

④ 如果存在  $\tau_u > V_1$ , 则删除字典  $\Phi^r$  中相应列的原子, 获得新字典  $\Phi^{r+1}$ ,  $\Phi^{r+1} \in \mathbf{R}^{L \times d^*}$ ,  $L \leq d^* \leq d$ , 否则  $\Phi^{r+1} = \Phi^r$ ;

直到  $\| \mathbf{X}_h^{\text{HR}} - \Phi^{r+1} \mathbf{A}^r \|_F^2$  的变化足够小, 结束;  
输出: 学习的字典  $\Phi^{r+1}$ 。

### 3.2 稀疏编码矩阵求解

通过上述基于压缩感知的字典学习方法, 求解(9)式得到字典  $\Phi$ 。为了得到目标图像  $\mathbf{S}$ , 根据(4)式需要求解得到合适的稀疏编码矩阵  $\mathbf{B}$ 。本文通过学习得到的字典  $\Phi$  和高分辨率图像  $\mathbf{Y}$  以及两个重要的先验信息来求解稀疏编码矩阵  $\mathbf{B}$ : 1) 在高分辨率图像中, 附近的像素可能在图像中表示相同的材料, 可以被一组相同的字典原子很好地表示; 2) 稀疏编码矩阵  $\mathbf{B}$  中的元素为非负, 表示场景中光谱信号源的比例系数。为此, 通过小的不相交的空间图像块处理图像  $\mathbf{Y}$ , 计算稀疏编码矩阵  $\mathbf{B}$ 。用  $\mathbf{P} \in \mathbf{R}^{M_P \times N_P \times l}$  表示高分辨率图像的每个图像块, 并通过求解以下问题, 得到相应的稀疏编码矩阵  $\mathbf{B}_p \in \mathbf{R}^{d \times M_P N_P}$ , 即

$$\min \| \mathbf{B}_p \|_0 \text{ s.t. } \| \bar{\mathbf{P}} - \Phi \mathbf{B}_p \|_F \leq \varepsilon, \\ \| \beta_{p_i} \| \geq 0, \forall i \in \{1, \dots, M_P N_P\}, \quad (10)$$

式中:  $\bar{\mathbf{P}} \in \mathbf{R}^{l \times M_P N_P}$ , 通过连接  $\mathbf{P}$  中的像素形成的二维矩阵形式;  $\mathbf{T} \in \mathbf{R}^{l \times l}$  是变换矩阵;  $\bar{\Phi} = \mathbf{T}\Phi$ ;  $\beta_{p_i}$  表示矩阵  $\mathbf{B}_p$  的第  $i$  列。当输入的信号为单一系列原子时, 可以采用标准的正交匹配追踪算法求解, 但是(10)式中的  $\bar{\mathbf{P}} \in \mathbf{R}^{l \times M_P N_P}$  包含了  $M_P N_P$  个信号列原子,

并且具有非负性约束, 因此(10)式是一个约束的同步稀疏近似问题<sup>[17]</sup>。为了求解(10)式, 该算法在正交匹配追踪算法的基础上进行拓展, 每次迭代会同时选择字典  $\Phi$  中的多个列原子, 并且将解空间约束为非负矩阵, 因此将该算法作为同步正交匹配追踪算法。该算法通过选择索引集合  $\partial$  所对应的  $\bar{\Phi}$  的字典原子  $\varphi_{\varepsilon}$ , 寻求输入信号  $\bar{\mathbf{P}}$  的近似值。初始索引集  $\partial^0$  设置为空, 图像块本身作为初始残差  $\mathbf{R}^0$ 。在第  $i$  次迭代中, 首先计算每个字典原子与图像块当前近似残差的累积相关性; 然后识别其中具有最大累积相关性的  $D$  个字典原子, 将这些原子添加到集合  $\partial^i$  索引的子空间中; 而后将上述子空间用于图像块的非负最小二乘近似, 并且更新残差  $\mathbf{R}^i$ 。如果更新后的残差大于上一次迭代残差的  $\sigma$  倍, 则算法停止。本算法使用非负最小二乘法近似每次迭代中的图像块, 而不是标准的最小二乘近似, 可以对稀疏编码矩阵施加非负约束。通过求解(10)式得到稀疏编码矩阵  $\mathbf{B}$ , 与字典  $\Phi$  一起得到目标图像  $\mathbf{S}$ 。

### 3.3 超分辨率方法

综上所述, 本文的空间光谱联合稀疏表示高光谱图像超分辨率算法描述如下。

#### 算法 2: 超分辨率算法

输入: 算法 1 字典学习得到的  $\Phi$ , 经过变换得到字典  $\bar{\Phi}$ ;

1) 初始化:

①  $i = 0$ ;

② 初始解:  $\mathbf{B}^0 = 0$ ;

③ 初始残差:  $\mathbf{R}^0 = \bar{\mathbf{P}} - \bar{\Phi} \mathbf{B}^0 = \bar{\mathbf{P}}$ ;

④ 初始索引集:  $\partial^0 = \emptyset = \text{row-supp}\{\mathbf{B}^0\}$ ,  $\text{row-supp}\{\mathbf{B}\} = \{1 \leq t \leq d, \beta^t \neq 0\}$ , 表示矩阵  $\mathbf{B}$  中非 0 行的基数,  $\beta^t$  是矩阵  $\mathbf{B}$  的第  $t$  行;

2) 通过同步正交匹配追踪算法解决(10)式, 迭代项  $i = i + 1$

① 计算  $b_j = \sum_{\tau=1}^{M_P N_P} \frac{\bar{\Phi}_j^T \mathbf{R}_{\tau}^{i-1}}{\| \mathbf{R}_{\tau}^{i-1} \|_2}, \forall j \in \{1, \dots, d\}$ ,  $b_j$  表示每一个字典原子与当前图像块近似残差的累积相关性;

②  $\mathbf{N} = \{\text{对应于最大 } b_j \text{ 的 } D \text{ 个 } \bar{\Phi} \text{ 列原子相应的索引集合}\}$ ;

③  $\partial^i = \partial^{i-1} \cup \mathbf{N}$ ;

④  $\mathbf{B}^i = \min \| \bar{\Phi} \mathbf{B} - \bar{\mathbf{P}} \|_F^2 \text{ s.t. } \text{row-supp}\{\mathbf{B}\} = \partial^i, \beta^t \geq 0, 1 \leq t \leq d$ ;

⑤ 更新残差:  $\mathbf{R}^i = \bar{\mathbf{P}} - \bar{\Phi} \mathbf{B}^i$ ;

⑥ 如果  $\|R^i\|_F > \sigma \|R^{i-1}\|_F$  则停止, 否则继续下一次迭代。

输出:  $S, S = \Phi B$

## 4 实验结果与分析

### 4.1 实验说明

为了检验本文方法的有效性, 所采用的测试图像包括公共数据集中的图像以及采集的实验图像, 并将重建结果与经典的双三次插值方法、矩阵分解(MF)方法进行比较。为了评估本文方法的重建效果, 实验结果从主观和客观两个方面进行比较分析。对于单波段的重建图像, 主观上主要从视觉效果比较重建结果的去模糊以及纹理细节等信息的重建情况; 客观上从峰值信噪比(PSNR)、结构相似度(SSIM)进行图像重建质量比较。另外, 采用波段平均峰值信噪比(APSNR)、波段平均结构相似度(ASSIM)以及光谱角映射(SAM)对重建图像的质量进行定量分析。

采集实验图像所用的设备是分孔径同时式偏振高光谱成像仪, 处理图像进行实验的运行环境为: Lenovo ideapad700, Intel Core i5-6300HQ, CPU @ 2.30 GHz, 8 GB RAM, MATLAB R2014a。

### 4.2 实验结果

实验采用公共数据集(AVIRIS Dataset)的“大学校园”高光谱图像以及实际采集的缩比模型“卡车”高光谱图像。其中“大学校园”图像的光谱波段

范围为 400~1200 nm, 光谱分辨率为 20 nm; 所采集的“卡车”实验图像光谱波段范围为 400~700 nm, 光谱分辨率为 10 nm。实验中将高分辨率参考图像分别进行高斯模糊以及降采样处理, 得到待处理的 LR 图像。高斯模糊核的尺寸为 8 pixel×8 pixel, 行和列的降采样因子均为 3。字典学习训练阶段, 取  $N=10000$  个训练图像块, 图像块尺寸为 4 pixel×4 pixel,  $V_1$  取值为 1.6, 初始化字典  $\Phi^0$  的原子数为  $d=100$ ; 同步正交匹配追踪算法中, 每次迭代同时选取  $D=25$  个字典原子, 残差参数  $\sigma=0.9$ 。分别采用双三次插值方法、MF 方法以及本文方法对低分辨率图像进行超分辨率重建, 并对不同方法的重建效果进行比较。

图 1 为“大学校园”图像在不同超分辨率算法的 600 nm 波段的重建图像。图 1(a)为高分辨率参考图像; 图 1(b)为双三次插值方法的重建图像, 整体比较模糊; 图 1(c)为 MF 方法的重建图像, 与双三次插值相比, MF 方法恢复了很多细节, 提高了图像的边缘锐度以及整体清晰度; 图 1(d)为本文方法的重建图像, 与 MF 方法相比, 其能更好地提高边缘的锐度, 并且恢复更多的图像细节信息, 例如图像上方道路的边缘信息。

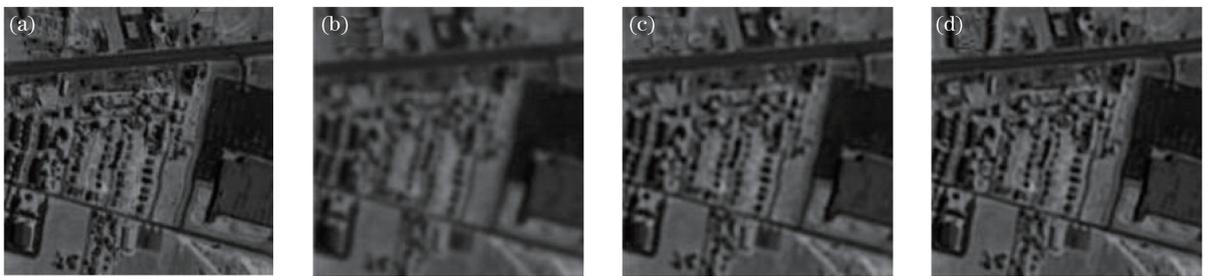


图 1 “大学校园”图像的不同 SR 方法重建效果。(a)高分辨率参考图;(b)双三次插值法;(c) MF 方法;(d)本文方法

Fig. 1 Reconstruction effect of different SR methods of university image.

(a) High-resolution reference image; (b) bicubic interpolation method; (c) MF method; (d) proposed method

图 2 为“卡车”缩比模型图像采用不同超分辨率方法的 540 nm 波段的重建图像。图 2(a)为高分辨率参考图像; 图 2(b)为双三次插值方法的重建图像, 比较模糊, 很多细节信息无法分辨; 图 2(c)为 MF 方法的重建图像, 与双三次插值方法相比, MF 方法恢复了很多图像细节, 比如“卡车”周围情况的清晰度增强; 图 2(d)为本文方法的重建图像, 与 MF 方法相比, 其能更好地重建“卡车”的轮廓边缘及细节信息, 提高图像边缘锐度

以及“卡车”图像周围的细节。

为进一步客观评价超分辨率重建方法, 对不同超分辨率方法的重建效果利用 PSNR 和 SSIM 比较分析。在 3 倍重建倍率下, 评价结果如表 1 所示。实验结果表明, 本文方法的客观评价指标均优于另外两种方法, PSNR 和 SSIM 的平均值比双三次插值方法分别提高 2.50 dB 和 0.1499, 比 MF 方法分别提高 1.35 dB 和 0.0663。

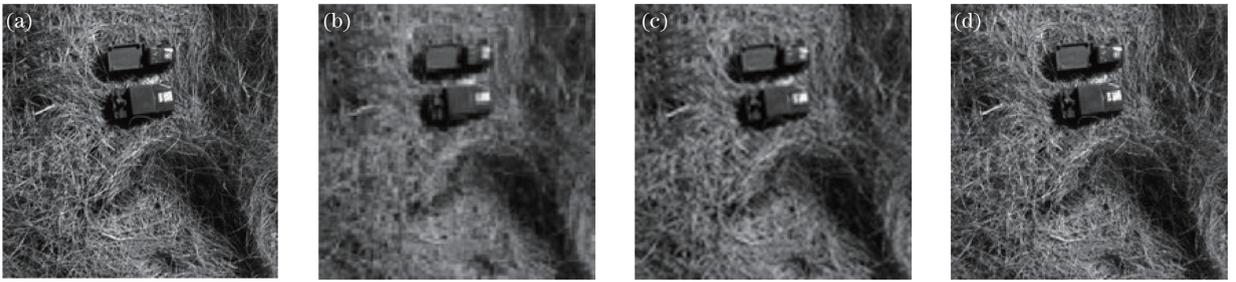


图 2 “卡车”缩比模型的不同超分辨率方法重建效果。(a)高分辨率参考图;(b)双三次插值法;(c) MF 方法;(d)本文方法

Fig. 2 Reconstruction effect of different SR methods of truck contraction model.

(a) High-resolution reference image; (b) bicubic interpolation method; (c) MF method; (d) proposed method

表 1 不同方法的 PSNR 和 SSIM 评价指标比较

Table 1 Comparison of PSNR and SSIM evaluation indexes of different methods

Method	PSNR /dB			SSIM evaluation index		
	Fig. 1	Fig. 2	Average	Fig. 1	Fig. 2	Average
Bicubic method	27.14	25.07	26.10	0.6913	0.6602	0.6757
MF method	28.33	26.18	27.25	0.7762	0.7424	0.7593
Proposed method	<b>29.64</b>	<b>27.56</b>	<b>28.60</b>	<b>0.8631</b>	<b>0.7881</b>	<b>0.8256</b>

另外,采用 APSNR、ASSIM 和 SAM 对图像的重建质量进行定量分析评价<sup>[18]</sup>。设  $\mathbf{Y}$  表示高光谱参考图像,可以用三维矩阵来表示,  $\mathbf{Y} = (y_{i,j,l}) \in \mathbf{R}^{M \times N \times L}$ ,  $M$  和  $N$  分别为图像  $\mathbf{Y}$  水平和垂直方向的尺寸,  $L$  为光谱波段的个数,  $\mathbf{Y}$  的第  $l$  波段形成的图像  $\mathbf{Y}_l$ , 其中  $l = \{1, 2, \dots, L\}$ ;  $\bar{\mathbf{Y}}$  表示重建后的高光谱图像,  $\bar{\mathbf{Y}}_l$  表示  $\bar{\mathbf{Y}}$  的第  $l$  波段图像。APSNR、ASSIM 和 SAM 分别定义如下:

$$\begin{cases} X_{\text{APSNR}} = 10 \lg \left( \frac{1}{L} \sum_{l=1}^L \frac{T_l^2}{m} \right) \\ X_{\text{ASSIM}} = \frac{1}{L} \sum_{l=1}^L t_l \\ X_{\text{SAM}} = \arccos \left\{ \frac{[y(i,j), \bar{y}(i,j)]}{\|y(i,j)\|_2 \cdot \|\bar{y}(i,j)\|_2} \right\} \end{cases}, \quad (11)$$

式中:  $T_l$  为  $\mathbf{Y}_l$  的峰值;  $m$  为  $\bar{\mathbf{Y}}$  的均方误差;  $t_l$  为  $\bar{\mathbf{Y}}$  的第  $l$  波段 SSIM 值;  $y(i,j)$  和  $\bar{y}(i,j)$  分别表示原始图像的像素和图像重建后的像素。

APSNR 和 ASSIM 的值越大,表明高光谱重建图像的质量越高。SAM 通过原始图像和重建图像的每个像素所构成的两个光谱向量之间的绝对角度反映光谱失真,并且对整个图像进行平均计算测量 SAM。对于理想的重建图像, SAM 的值应该为 0。表 2 和表 3 分别比较了“大学校园”图像和“卡车”缩比模型图像在不同超分辨率算法下重建图像的 APSNR、ASSIM 和 SAM 值,粗体标记的数值表示

相应评价指标下具有最优效果。结果表明,本文方法具有更好的超分辨率重建效果。

表 2 “大学校园”图像不同算法的 APSNR、ASSIM、SAM 评价指标对比结果

Table 2 Comparison of APSNR、ASSIM、SAM evaluation indexes of different algorithms of university image

Evaluation index	Bicubic method	MF method	Proposed method
APSNR /dB	24.33	25.84	<b>27.28</b>
ASSIM	0.6824	0.7652	<b>0.8227</b>
SAM	0.1021	0.0981	<b>0.0847</b>

表 3 “卡车”图像不同算法的 APSNR、ASSIM、SAM 评价指标对比结果

Table 3 Comparison of APSNR、ASSIM、SAM evaluation indexes of different algorithms of truck image

Evaluation index	Bicubic method	MF method	Proposed method
APSNR /dB	23.34	24.57	<b>25.64</b>
ASSIM	0.6523	0.7425	<b>0.7886</b>
SAM	0.1096	0.0975	<b>0.0836</b>

图 3 为使用不同超分辨率方法重建图像的光谱比较,其中图 3(a)为“大学校园”图像中特定像元的光谱曲线,共 41 个光谱波段;图 3(b)为“卡车”缩比模型图像中特定像元的光谱曲线,共 31 个光谱波段。从图 3 的光谱曲线比较可见,本文方法重建的图像与参考图像之间的光谱差异最小,表明本文方法具有更好的光谱保真性。

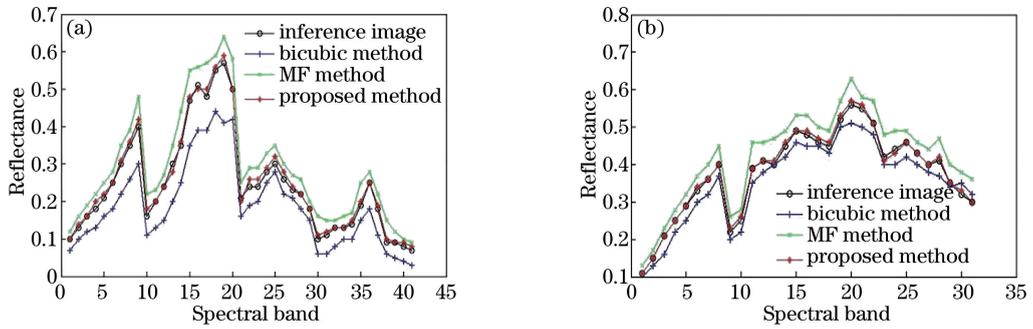


图 3 不同超分辨率方法重建图像的光谱比较。(a)“大学校园”图像;(b)“卡车”缩比模型图像  
Fig. 3 Comparison of the spectra of the reconstructed images with different super resolution methods.

(a) University image; (b) truck contraction model image

4.3 实验分析

为了细化分析参数与本文方法重建效果的关系,采用“卡车”缩比模型图像进行实验,定量化分析重建图像质量与图像块尺寸、分辨率提升倍率等参

数间的关系。图 4(a)~(c)分别为 APSNR、ASSIM、SAM 与图像块尺寸之间的关系,从图 4 可以看出,选择 4 pixel×4 pixel 的图像块重建效果更好。

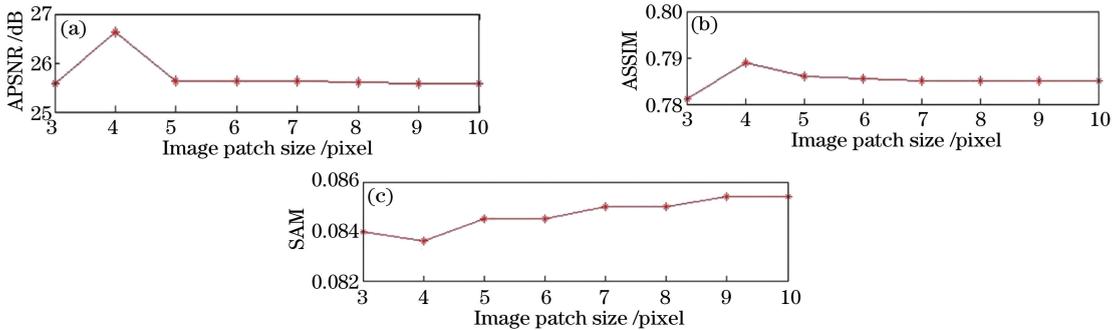


图 4 APSNR、ASSIM 和 SAM 与图像块尺寸之间的关系

Fig. 4 Relationship between APSNR, ASSIM, SAM and the image patches size

图 5(a)~(c)分别为 3 种算法重建图像的 APSNR、ASSIM 和 SAM 指标与分辨率提升倍率

间的关系。从图 5 可以看出,随着分辨率提升倍率的增加,三种算法重建图像的质量逐渐下降。与其

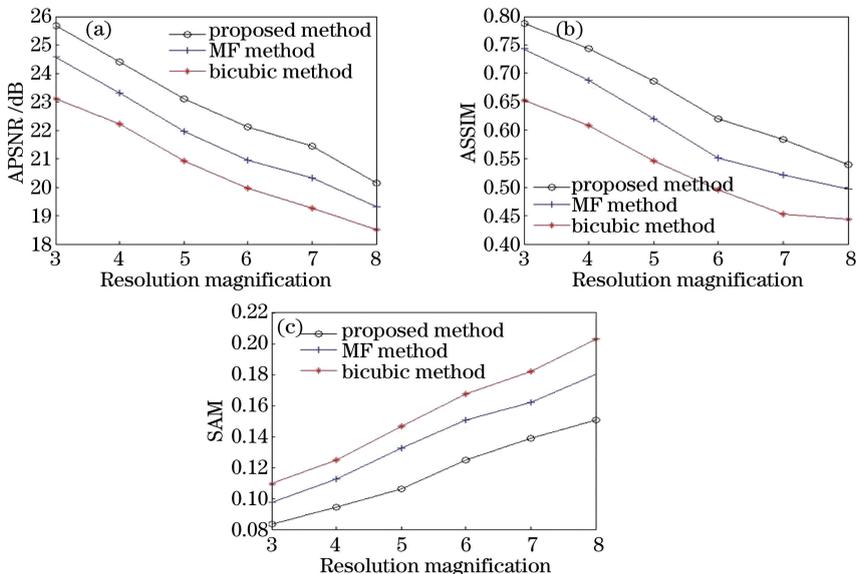


图 5 不同方法在不同分辨率提升倍率下重建图像的 APSNR、ASSIM 和 SAM 指标

Fig. 5 APSNR, ASSIM and SAM of reconstructed images using different methods with various upscaling factors

他两种算法相比,本文方法重建图像质量在不同分辨率提升倍率时具有更好的重建质量,其中 APSNR 和 ASSIM 指标比其他两种方法更大,SAM 指标更小。

## 5 结 论

针对所获取的高光谱图像空间分辨率较低的问题,设计了一种空间光谱联合稀疏表示的超分辨率方法。该方法在高光谱图像超分辨率框架下,联合利用高光谱图像的空间信息与光谱信息,通过设计基于压缩感知的光谱字典学习方法,以及同步正交匹配追踪算法进行稀疏编码矩阵求解,完成了高光谱图像的超分辨率重建。该方法利用图像空间结构相似性的附加信息重建图像,有效提高重建图像的空间分辨率;利用高光谱图像中存在的相似光谱像元信息,更好地保持重建图像的光谱信息。实验验证从主观视觉效果和客观评价指标进行比较分析,结果表明,无论是主观视觉效果还是客观评价指标,本文方法均优于传统方法和矩阵分解方法,具有更好的空间分辨率提升能力以及光谱保真性。

## 参 考 文 献

- [1] Yi C. Research on spatial-spectral resolution enhancement of hyperspectral image [D]. Xi'an: Northwestern Polytechnical University, 2016: 1-5.  
益琛. 高光谱图像空间-光谱分辨率增强方法研究 [D]. 西安: 西北工业大学, 2016: 1-5.
- [2] Wu L D, Yao Z H, Ren Z W. Techniques on processing of hyperspectral images in perception of battlefield environment [J]. Journal of Equipment Academy, 2017, 28(3): 1-7.  
吴玲达, 姚中华, 任智伟. 面向战场环境感知的高光谱图像处理技术综述[J]. 装备学院学报, 2017, 28(3): 1-7.
- [3] Liu L X, Li M Z, Zhao Z G, *et al.* Recent advances of hyperspectral imaging application in biomedicine [J]. Chinese Journal of Lasers, 2017, 45(2): 0207017.  
刘立新, 李梦珠, 赵志刚, 等. 高光谱成像技术在生物医学中的应用进展[J]. 中国激光, 2017, 45(2): 0207017.
- [4] Zhang L P, Li J Y. Review and prospect of hyperspectral image sparse information processing [J]. Journal of Remote Sensing, 2016, 20(5): 1091-1101.  
张良培, 李家艺. 高光谱图像稀疏信息处理综述与展

望[J]. 遥感学报, 2016, 20(5): 1091-1101.

- [5] Lanaras C, Baltasavias E, Schindler K. Hyperspectral super-resolution by coupled spectral unmixing [C]. IEEE International Conference on Computer Vision, 2015: 3586-3594.
- [6] Bioucas-Dias J M, Plaza A, Camps-Valls G, *et al.* Hyperspectral remote sensing data analysis and future challenges[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 1(2): 6-36.
- [7] Su H, Zhou J, Zhang Z H. Review of image super resolution reconstruction methods [J]. Journal of Automation, 2013, 39(8): 1202-1213.  
苏衡, 周杰, 张志浩. 超分辨率图像重建方法综述 [J]. 自动化学报, 2013, 39(8): 1202-1213.
- [8] Akgun T, Altunbasak Y, Mersereau R. Super-resolution reconstruction of hyperspectral images[J]. IEEE Transactions on Image Processing, 2005, 14(11): 1860-1875.
- [9] Zhang H Y, Zhang L P, Shen H F. A super-resolution reconstruction algorithm for hyperspectral images[J]. Signal Processing, 2012, 92(9): 2082-2096.
- [10] Huang W, Xiao L, Liu H, *et al.* Hyperspectral imagery super-resolution by compressive sensing inspired dictionary learning and spatial-spectral regularization[J]. Sensors, 2015, 15(1): 2041-2053.
- [11] Xu P, Xiao C, Zhang J C, *et al.* Denoising method for plant hyperspectral data based on grouped 3D discrete cosine transform dictionary[J]. Acta Optica Sinica, 2017, 37(6): 0630003.  
徐平, 肖冲, 张竞成, 等. 基于分组三维离散余弦变换字典的植物高光谱数据去噪方法[J]. 光学学报, 2017, 37(6): 0630003.
- [12] Huang B, Song H, Cui H, *et al.* Spatial and spectral image fusion using sparse matrix factorization[J]. IEEE Transactions on Geoscience & Remote Sensing, 2014, 52(3): 1693-1704.
- [13] Nezhad Z H, Karami A, Heylen R, *et al.* Fusion of hyperspectral and multispectral images using spectral unmixing and sparse coding [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(6): 2377-2389.
- [14] Zhou Y, Feng L, Hou C, *et al.* Hyperspectral and multispectral image fusion based on local low rank and coupled spectral unmixing [J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55(10): 5997-6009.
- [15] Akhtar N, Shafait F and Mian A. Sparse spatio-

- spectral representation for hyperspectral image super resolution [C]. European Conference on Computer Vision, 2014, 8695: 63-78.
- [16] Pan Z, Yu J, Huang H, *et al.* Super-resolution based on compressive sensing and structural self-similarity for remote sensing images [J]. IEEE Transactions on Geoscience & Remote Sensing, 2013, 51(9): 4864-4876.
- [17] Belmerhnia L, Djerroune E H, Brie D. Greedy methods for simultaneous sparse approximation [C]. Signal Processing Conference, 2014: 1851-1855.
- [18] Akgun T, Altunbasak Y, Mersereau R M. Super-resolution reconstruction of hyperspectral images [J]. IEEE Transactions on Image Processing, 2005, 14 (11): 1860-1875.