

文章编号:1007-2780(2017)03-0219-08

基于压缩感知的高光谱遥感影像重构方法研究

王 晗,王阿川*,苍 圣

(东北林业大学 信息与计算机工程学院,黑龙江 哈尔滨 150040)

摘要:高光谱遥感影像包含丰富的空间、辐射以及光谱信息,同时海量的数据也引发了高光谱成像技术在传输和存储方面的诸多问题。针对这一问题,根据高光谱遥感影像谱间相关性强的特性,提出了一种结合谱间多向预测的基于压缩感知的高光谱遥感影像重构方法。首先,根据高光谱遥感影像的谱间相关性对高光谱遥感影像的波段进行分组,每组确定一个参考波段,使用平滑 l_0 范数算法重构每组的参考波段。其次,根据重构恢复的相邻组内的参考波段,建立了一个非参考波段预测模型,用来计算非参考波段的预测测量值;然后,计算实际测量值与预测测量值的差值,使用 SL0 算法重构该差值得到差值向量;最后,利用得到的差值向量迭代更新预测测量值,直到恢复该波段原始图像。仿真实验结果表明,该方法提高了高光谱遥感影像的重构效果。

关 键 词:高光谱遥感影像;压缩感知;预测模型;图像重构

中图分类号:TP751.1 **文献标识码:**A **doi:**10.3788/YJYXS20173203.0219

Hyperspectral remote sensing image reconstruction method based on compressive sensing

WANG Han, WANG A-chuan*, CANG sheng

(College of Information and Computer Engineering,
Northeast Forestry University, Harbin 150040, China)

Abstract: Hyperspectral remote sensing image contains rich space, radiation and spectral information. Meanwhile, massive data also lead to many problems in the transmission and storage of hyperspectral imaging technology. To solve this problem, a new method of hyperspectral remote sensing image reconstruction based on compressive sensing is proposed, which combines the spectral correlation and multi direction prediction. Firstly, according to the spectral correlation of hyperspectral remote sensing image, the bands of hyperspectral remote sensing image are grouped into each group, each group is defined as a reference band, and the I_0 norm algorithm is used to reconstruct the reference band. Secondly, according to the reference band adjacent reconstructed within the group, a non reference band prediction model is set up, which is used to calculate the predicted measurement non reference band value. Then, we calculate the difference between the actual measured value and the predic-

收稿日期:2016-10-26;修订日期:2016-11-28.

基金项目:黑龙江省自然科学基金资助项目(No.C201414);哈尔滨市优秀学科带头人基金项目(No.2014RFXXJ040)

Supported by Natural Science Foundation of Heilongjiang province (No.C201414); Harbin Good Foundation for Leaders of Disciplines(No.2014RFXXJ040)

* 通信联系人, E-mail: wangcal1964@126.com

ted measured values, and reconstruct the difference vector difference using SLO algorithm. Finally, by using difference vector iteration, we update the prediction measurements until the band recovers the original image. The simulation results show that the proposed method improves the reconstruction effect of hyperspectral remote sensing image.

Key words: hyperspectral remote sensing image; compressive sense; prediction model; image reconstruction

1 引言

高光谱图像(Hyperspectral Image, HSI)是指光谱分辨率在 $10^{-2}\lambda$ (其中 λ 为波长)数量级范围内的一组光谱图像,通常包含数百个光谱波段,通过高光谱传感器,用从紫外到中红外区域内的、波长连续且间隔相等的电磁波对目标区域进行成像,获取地面目标的空间信息及相应丰富的光谱信息^[1],同时高光谱图像也带来了海量的数据,这也导致了高光谱图像的光谱范围和空间分辨率由于传感器的设计、海量数据的存储、传输和处理的局限性而受到限制^[2],因此有效地压缩高光谱数据以及快速传输数据成为目前高光谱技术中亟需解决的问题。压缩感知(compressed sensing, CS)理论指出,如果一个信号是稀疏或者可压缩的,则只需要以此信号在某一个投影域上的少量投影值即可近似地重构原信号。把压缩感知理论应用到高光谱图像的采集与成像上,可以大大降低高光谱图像所带来的海量数据的同时,还可以比较精确的重构恢复原图像。

在已有的高光谱重构方法中,文献[3]提出了一种基于变采样率的高光谱图像压缩感知重构方法,提供了参考波段与非参考波段使用不同采样率的新思路;文献[4]提出了一种基于空谱联合的多假设预测压缩感知重构算法,对于非参考波段的重构,根据和它相邻的非参考波段图像以及参考波段重构的图像来预测非参考波段的图像块;文献[5]提出了一种基于过完备原子库上分解图像的稀疏分解快速算法,利用贪心聚类算法去除了图像的谱间冗余,加强了每类谱带的相关性;文献[6]提出了一种参考波段对普通波段的预测方法,增加了相邻组中参考波段对于普通波段的预测。这些方法对本文的研究也起到了指导和帮助作用,但是,这些方法都未能充分利用高光谱图像各波段之间的谱间相关性信息对提高重构质量的作用。

因此,针对上述重构算法中存在的不足,本文提出了一个高光谱压缩感知采样和谱间多向预测的重构方法。首先,按照谱间相关性对高光谱图像的波段分组,每组确定一个参考波段,对参考波段采用较高的采样率;其次,使用平滑 l_0 范数算法重构每组的参考图像;然后,建立了一个预测模型,通过预测模型得到非参考图像的预测测量值,并计算实际测量值与预测测量值的差值;最后,重构该差值得到差值向量,从而更新预测测量值,直到恢复该波段原图像。本文算法更加充分的利用了高光谱图像谱间相关性强的特点,实验表明,该方法能有效提高高光谱遥感影像的重构效果。

2 高光谱图像的特性

高光谱图像是三维数据,在空间上反映的是被拍摄场景的外形信息,在谱向上反映场景中不同位置的光谱信息。高光谱图像通常存在两类数据冗余:空间冗余和谱间冗余^[7]。高光谱图像在空间上是物体在某个波长辐射出的能量大小而形成的灰度图像,这一点和普通的自然图像很相近,但它的空间相关性却比普通的自然图像弱。在谱方向上,高光谱图像上每一个像素点都是一条光滑的曲线,这条曲线是由一种或几种物质的光谱反射曲线的线性叠加得到的^[8]。高光谱图像的这些特性为后续图像的重构起到了至关重要的作用。

2.1 高光谱图像的空间相关性

高光谱图像相关性反映的是图像在空间位置上相邻像素点之间的相关程度,本文选取了一幅高光谱遥感影像,并将其局部放大 16 倍,如图 1 所示。从主观上看该局部相邻像素点之间的灰度值变化不大。从客观上看,画出该局部的灰度分布直方图,如图 2 所示。其中横坐标为图像的灰度值,纵坐标为灰度出现的频率。从直方图中可以清晰地看出在该局部相邻像素点之间的灰度值几乎全部聚集在 80~120,非常稳定没有发生较

大的跃变,即说明了该高光谱遥感图像在空间方向上具有一定的相关性。




图1 高光谱遥感图像的空间相关性图

Fig.1 Spatial correlation of hyperspectral remote sensing images




图2 灰度分布直方图

Fig.2 Histogram of gray level distribution

2.2 高光谱图像的谱间相关性

高光谱图像的不同光谱波段之间存在着的图像相关性称为谱间相关性^[9]。通过计算图像的互相关函数^[10]:

$$R_{x_i, x_j} = X(x_i, x_j) \times [X(x_i, x_i)X(x_j, x_j)]^{-1/2}, \quad (1)$$

可以得到谱间相关性,其中: $X(x_i, x_j)$ 表示协方差; x_i 和 x_j 均为列向量,分别表示为第 i 和第 j 波段的图像。本文选取一幅高光谱遥感影像,如图3所示,其中(a)为第75波段灰度图像,(b)为第77波段灰度图像。经过计算第75波段灰度图像和第77波段灰度图像的相关系数为0.997 304。由此可见高光谱遥感图像的谱间相关性比较高,这些特点为后续的高光谱图像的重构起到了非常重要的作用。




图3 高光谱影像

Fig.3 Hyperspectral image

3 压缩感知理论

压缩感知理论是一种新颖的信号采样理论,2004年首先由Donoho和Candes提出。该理论指出,当信号具有稀疏性或者可压缩性时,我们能够从与传统的Nyquist采样定理相比少得多的信号投影值,就能够准确或者近似重构出原始信号。

压缩感知理论的一个应用前提就是信号必须具有稀疏性或者可压缩性,设一个长度为 N 的离散信号: $x(n), n \in [1, 2, 3, \dots, N]$,根据信号理论可知该信号 $x(n)$ 能够被一组基 $\Psi = [\Psi_1, \Psi_2, \Psi_3, \dots, \Psi_N]$ 的线性组合表示:

$$x = \sum_{k=1}^N \Psi_k \alpha_k = \Psi \alpha, \quad (2)$$

其中: $x, \alpha \in R^{N \times 1}, \Psi \in R^{N \times N}$ 。当信号 $x(n)$ 在基 Ψ 上仅有 $K \ll N$ 个非零系数 α_k 时,则称 Ψ 为信号 $x(n)$ 的稀疏基,此时认为该信号具有稀疏性或者可压缩性。常用的稀疏基有:正弦基、余弦基、curvelet基等。

压缩感知的编码测量模型中,得到的观测值并非是对信号本身的采样,而是信号从高维到低维的投影值,信号的随机投影过程是压缩感知理论中非常关键的步骤,这一过程大大降低了信号的采样率。每个观测值都是原始信号的组合函数。假设,将信号 x 投影到一组观测向量 $\Phi = [\phi_1, \phi_2, \phi_3, \dots, \phi_M]^T$ 上得到观测值 $y_m = \langle x, \phi_m^T \rangle$,即:

$$y = \Phi x, \quad (3)$$

其中: $x \in R^{N \times 1}, y \in R^{M \times 1}, \Phi \in R^{M \times N}$ 。将式(2)代入式(3),有:

$$y = \Phi x = \Phi \Psi \alpha = \Theta \alpha, \quad (4)$$

其中, $\Theta = \Phi \Psi \in R^{M \times N}$ 。由于观测值维数远小于信号维数,因而要求出 x ,需要先求解式(4)中的 α ,然后代入式(2)求解 x 。压缩感知理论指出,如果要精确的重构出原始信号,测量矩阵 Φ 必须要满足不相干性^[11](Incoherence)和限制等容性^[12](Restricted Isometry Property, RIP)的原则。

4 图像重构算法

4.1 高光谱影像谱间相关性分析及波段分组

高光谱图像在空间上的性质和普通自然图像很相近,每个波段的光谱图像都可以看作是一幅普通的灰度图像,但这些灰度图像之间有比较强的相关性。本文利用高光谱图像这种较强的谱间相关性,结合灰度图像的重构方法,提出了一种基于谱间相关性的高光谱图像压缩感知重构方法。

(1) 计算高光谱图像的谱间相关性

设 $X \in R^{N \times N \times J}$ 为实验高光谱图像, $x_{i,j,k}$ 表示第 k 个波段像素位置 (i,j) 点的像素值, $\bar{x}_k$ 表示第 k 个波段所有像素点的像素值的平均值,计算公式:

$$\bar{x}_k = \frac{1}{N \times N} \sum_{i=1}^N \sum_{j=1}^N x_{i,j,k}. \quad (5)$$

令 $\tilde{x}_{i,j,k} = x_{i,j,k} - \bar{x}_k$, 则第 k 波段和 $k+1$ 波段的相关性计算公式如式(6)所示,其中 $c \in [0,1]$ 。

$$c_{k,k+1} = \frac{\sum_{i=1}^N \sum_{j=1}^N \tilde{x}_{i,j,k} \tilde{x}_{i,j,k+1}}{\sqrt{\sum_{i=1}^N \sum_{j=1}^N \tilde{x}_{i,j,k}^2 \sum_{i=1}^N \sum_{j=1}^N \tilde{x}_{i,j,k+1}^2}}, \quad (6)$$

(2) 按照谱间相关性将高光谱图像的波段进行分组

首先根据高光谱图像的总波段数确定总组数 n , 设组内大小为 p , 每个组内有 1 个参考波段和 $(p-1)$ 个非参考波段, 即总共确定 n 个参考波段, 经研究表明一组取 7 个波段最为合适, 分组时每个待分组波段都与这 n 个参考波段进行相关性计算, 找到相关性最高的那个参考波段;

然后把待分组的波段分到该参考波段所在的组内, 若一个组内的波段数 p 应为 7 时, 该组的参考波段则不再参与运算, 这样保证每个小组的波段数不会超过 7 个, 依次进行循环直到最后一个波段分组完毕。

4.2 参考波段的稀疏表示及随机投影

先对参考波段进行处理。随机投影矩阵选择压缩感知理论中常用的高斯测量矩阵。研究[13]表明, 高斯矩阵满足限制等容性且与几乎任何稀疏或可压缩的信号都是不相干的, 完全符合对随机投影矩阵的要求。设高斯测量矩阵 $\Phi \in$

$R^{M \times N}$, 则它服从均值为 0, 方差为 $1/\sqrt{M}$ 的正态分布。 $x_{1,1}, x_{2,1}, \dots, x_{n,1}$ 为 n 个参考波段, 它们均以较大的采样率采样。本文选择双正交小波基 Ψ 对高光谱图像进行稀疏表示, 如式(7)所示:

$$\{y_i\} = \Phi \Psi \alpha_{i,1}, \quad i=1,2,\dots,n, \quad (7)$$

其中: $\{y_i\}$ ($i=1,2,3,\dots,n$) 是测量值, 为简化式子, 令 $Y = \{y_i\}_{i=1,2,3,\dots,n}$, 则式(7)简化为式(8), 如下:

$$Y = \Phi \Psi \alpha_{i,1}, \quad i=1,2,\dots,n. \quad (8)$$

在对高光谱图像进行随机投影时, 每个组内的每个波段使用的测量矩阵和测量方法都相同, 因此图像域具有很强谱间相关性的高光谱图像, 在其测量域同样具有很强的相关性^[14]。

4.3 参考图像重构算法

在重构端, 已知测量值 Y , 测量矩阵 Φ , 采样率 r_h 以及稀疏基 Ψ 。先重构参考图像。参考图像的测量值为 $Y = \Phi x_1 = \Phi \Psi \alpha_{i,1}$, 本文使用平滑 l_0 范数算法^[15-16] (Smooth l_0 , SL0) 算法对参考图像进行重构。SL0 算法通过代价方程(9)最小, 来求解稀疏系数 α ,

$$\alpha = \max F_\sigma(\alpha) \text{ s.t. } y = \Phi x = \Phi \Psi \alpha = \Theta \alpha, \quad (9)$$

其中: $F_\sigma(\alpha) = \sum_{i=1}^k f_\sigma(s_i)$, $f_\sigma(\alpha) = \exp(-\alpha^2/2\sigma^2)$, 则当 σ 趋向于 0 时有:

$$\lim_{\sigma \rightarrow 0} f_\sigma(\alpha) = \begin{cases} 1, & \alpha = 0 \\ 0, & \alpha \neq 0 \end{cases}, \quad (10)$$

所以 α 的 l_0 范数就可以等价于 $\|\alpha\|_0 \approx k - F_\sigma(\alpha)$ 。SL0 对式 $x = \Psi \alpha$ 的求解步骤:

(1) 初始化, 选定 α 的初始解 $\alpha = A^+ x$ (A^+ 是 A 的伪逆矩阵); 选择下降因子 $[\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_K]$ 和下降步长 μ 。

(2) 令 $\sigma = \sigma_k, \alpha = v_{k-1}, k=1,2,\dots,K$ 开始进行迭代, 对于 $l=1,2,\dots,L$ 进行内部迭代:

① 求 $F_\sigma(\alpha)$ 的导数得到 $\Delta \alpha$;

② 更新稀疏系数值 $\alpha = \alpha - \mu \Delta \alpha$;

③ 向约束平面进行反向投影 $\alpha \leftarrow \alpha - A^+ (A\alpha - x)$;

④ $v_k = \alpha$, 返回①继续迭代, 直到最大迭代次数时停止。

4.4 谱间多向预测模型的建立

谱间多向预测是用来预测波段组中的非参考波段的, 预测的数据源是该组的参考波段 $x_{i,1},$

上一组的参考波段 $x_{i+1,1}$ 以及下一组的参考波段 $x_{i+1,1}$, 本文由重构恢复所得的 3 个参考波段 $\hat{x}_{i,1}$ 、 $\hat{x}_{i+1,1}$ 和 $\hat{x}_{i+1,1}$ 来预测第 i 组的非参考波段 $x_{i,j}$, 因此, 建立预测模型如下:

$$x'_{i,j} = \alpha \hat{x}_{i,1} + \beta \hat{x}_{i+1,1} + \gamma \hat{x}_{i+1,1}, \quad (11)$$

式中: α 、 β 和 γ 是预测系数, $\alpha = \frac{p-j+1}{p}$, $\beta = \frac{j-1}{2p}$, $\gamma = \frac{j-1}{2p}$ 。其中, p 为组内的波段数, j 为波段在组内的位置。根据上文所述的分组策略, 非参考波段在组内位置越靠前, 则它与该组内参考波段的相关性越大, 在预测模型中, 对于位置靠前的非参考波段, 同一组的参考波段所占的权重较大; 位置靠后的非参考波段则上一组和下一组的参考波段所占的权重较大。需要特别说明的是, 当第一组和最后一组波段进行预测时 $\beta=0$ 或是 $\gamma=0$ 即可。

4.5 非参考图像重构算法

多向谱间预测重构算法的过程为: 通过多向谱间预测模型得到的非参考波段的预测值, 与实际测量值进行求差、重构测量差值, 最后更新修正预测值, 然后迭代上述操作不断逼近非参考波段数据的原始值。

首先, 进行测量求差, 根据式(13)预测模型求出的预测值 $x'_{i,j}$, 使用和参考图像相同的测量矩阵 Φ , 可以得到预测值的测量值 $y'_{i,j} = \Phi x'_{i,j}$, 非参考波段 $x_{i,j}$ 通过随机投影得到的实际测量值为 $y_{i,j} = \Phi x_{i,j}$, 则两个测量值的差为:

$$y = y_{i,j} - y'_{i,j} = \Phi(x_{i,j} - x'_{i,j}) = \Phi \Delta x, \quad (12)$$

式中: Δx 为当前波段原始值 $x_{i,j}$ 与多向预测值 $x'_{i,j}$ 之间的差, 对应的测量差值 Δy , 相当于对差值向量 Δx 随机投影得到的。

然后, 使用 SLO 算法由测量差值 Δy 重构恢复差值向量 Δx 。高光谱图像谱间相关性极强, 所以多向谱间预测后, 预测值 $x'_{i,j}$ 已经很接近原始值 $x_{i,j}$, 因而得到的测量差值 x 比原始值 $x_{i,j}$ 还要稀疏, 所以重构差值 Δy 恢复差值向量 Δx 比重构 $y_{i,j}$ 恢复 $x_{i,j}$ 效果更好。

最后, 由重构恢复的 $\hat{x}$ 来修正预测值 $x'_{i,j}$, 从而得到更新后的预测值 $x'_{i,j} = x'_{i,j} + \Delta \hat{x}$, 显然更新后的预测值更加接近原始值。迭代上述的测量求差、重构差值以及修正预测值的步骤, 可以




图4 非参考波段重构算法

Fig. 4 Reconstruction algorithm of non reference band reconstruction algorithm

使预测值不断的逼近原始值, 当重构的差值向量 Δx 小于 σ 时, 即预测值的几乎不再更新时, 停止迭代, 此时的预测值可以认为是真实值。非参考图像的重构算法如图4所示。

5 实验及结果分析

实验数据选用 2008 年 9 月发射的 HJ-1A 星 HIS 数据, 本文以黑龙江省大兴安岭塔河地区的 HIS 2 级产品高光谱遥感数据作为数据源, 波段数为 115。本文选择编号为 1019906 的高光谱图像进行实验。展示 1019906 号图像的第 67 和 70 波段, 其中, 第 67 波段是其中一个组的参考波段, 70 波段为该组的非参考波段。实验的测量矩阵选用高斯测量矩阵, 参考波段的采样率 $r_h = 0.35$, 非参考波段的 $r_l = 0.05$, 稀疏基 Ψ 选择双正交小波基。本文选择了目前重构效果较好的 MT-Bayes 算法以及 GPSR 算法作为对比试验, 同样使用分组参考波段和非参考波段的方法进行

重构。本文给出第 67 和 70 波段原始图像的重构效果,第 67 波段的重构效果如图 5 所示,其中(a)为原始图像,(b)为 MT-Bayes 算法重构效果,(c)为 GPSR 算法重构效果,(d)为本文算法重构效果。第 67 波段的重构效果如图 6 所示,其中(a)为原始图像,(b)为 MT-Bayes 算法重构效果,(c)

为 GPSR 算法重构效果,(d)为本文算法重构效果。从图(5)中可以看出由于参考图像的采样率较高,三种方法对参考图像的重构效果差异不大,从图(6)可以看出,在对非参考图像的重构上,本文所采用的谱间多向预测的重构效果要远远好于前两种算法。




图 5 参考波段 67 的重构效果对比

Fig.5 Comparison of the reconstruction effect of sixty-seventh reference band




图 6 非参考波段 70 的重构效果对比

Fig.6 Comparison of the reconstruction effect of Seventieth reference band

重构效果通常使用峰值信噪比(Peak Signal Noise Ratio,PSNR)来衡量,计算公式:

$$PNSR=20\log_{10}\frac{1}{\sqrt{MSE}},\quad (13)$$

其中:MSE 是均方误差(Mean Square Error),计算公式:

$$MSE=\frac{1}{mn}\sum_{i=1}^m\sum_{j=1}^n|x_{i,j}-\hat{x}_{i,j}|^2,\quad (14)$$

其中, $m、n$ 为光谱图像单个波段的宽和高, $x_{i,j}$ 是原始图像在 (i,j) 点的像素值, $\hat{x}_{i,j}$ 是重构后的图像在 (i,j) 的像素值。

本文选取了一个波段组计算 PSNR 值,其中 67 波段为参考图像,MT-Bayes 算法、GPSR 算法以及本文提出算法比较重构图像的 PSNR 结果如表 1 所示。

表 1 PSNR 效果比较
Tab.1 Comparison of PSNR effect

算法	图像波段						
	67	68	69	70	71	72	73
MT-Bayes	32.56	26.34	25.67	25.42	26.79	25.49	26.32
GPSR	32.89	28.17	27.56	28.06	27.84	27.69	28.21
本文算法	34.32	32.87	32.45	32.19	33.15	32.18	32.74

由表1可以看出,由于参考波段的采样率比较高,三种方法对于第67波段的重构效果都比较好,差异很小。从本组其他的非参考波段的PSNR可以看出,在采样率较低的情况下,本文提出的谱间多向预测模型使得非参考图像的重构效果得到了明显的提高。

参考波段和非参考波段采样率的选取对重

构算法的性能也有着比较大的影响。定义平均采样率 $R = \frac{1}{N} \times r_h + \frac{N-1}{N} \times r_l$, 其中 N 为波段组的大小, r_h 为参考波段的采样率, r_l 为非参考波段的采样率。本文选择不同的平均采样率对3种重构算法的平均PSNR进行比较如表2所示。

表2 不同平均采样率的平均PSNR对比

Tab.2 Average PSNR comparison of different average sampling rates

算法	平均采样率					
	0.10	0.15	0.20	0.25	0.30	0.35
MT-Bayes	27.83	29.35	31.15	32.88	34.76	36.69
GPSR	28.36	30.25	31.94	33.34	35.19	36.89
本文算法	32.87	34.69	36.09	37.32	39.37	41.15

由表2可以看出,与GPSR算法和MT-Bayes算法相比,本文提出的对波段的分组方法以及对参考图像的预测方法在不同的平均采样率下的平均PSNR提高了4-5dB,可见本文提出的算法在不同采样率下的重构效果都有了明显的提升。

6 结 论

针对高光谱图像数据量大,导致存储和传输存在的诸多问题,分析了现有的灰度图像的重构算法,提出了一种结合谱间多向预测的基于压缩感知的高光谱图像重构方法。首先,根据高光谱图像的谱间相关性,对高光谱图像的波段进行分

组,每组确定一个参考波段并选用较大的采样率进行采样,其他非参考波段采用较小的采样率采样。使用SL0算法重构参考波段;其次,建立了谱间多向预测模型,通过三个组中的参考波段来预测组内的所有非参考波段;然后,计算实际测量值与预测测量值的差值,并重构测量差值不断的更新修正预测值;最后,当预测值几乎不再更新时,得到的预测值最为接近真实值。与传统的重构方法相比,本文提出的重构算法更加充分的利用了高光谱图像谱间相关性强的特点。本文建立的预测模型有效地提高了非参考波段的重构精度。实验结果也表明,本文提出的方法显著提高了高光谱图像的重构效果。为后续高光谱遥感影像重构方法的研究提供了参考方向。

参 考 文 献:

- [1] KERKES J P, SCHOTT J R. *Hyperspectral Imaging Systems* [M]//CHANG C I. Hyperspectral Data Exploitation: Theory and Applications. Hoboken, HJ: Wiley-Interscience, 2007: 19-45.
- [2] WANG J, CHANG C I. Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(6): 1586-1600.
- [3] 赵阳.基于字典学习及压缩感知的高光谱图像重构算法研究[D].秦皇岛:燕山大学,2013.
ZHAO Y. Study on reconstruction of hyperspectral images based on dictionary learning and compressed sensing [D]. Qinhuangdao: Yanshan University, 2013. (in Chinese)
- [4] 王丽,冯燕.基于空谱联合的多假设预测高光谱图像压缩感知重构算法[J].电子与信息学报,2015,37(12): 3000-3008.
WANG L, FENG Y. Compressed sensing reconstruction of hyperspectral images based on spatial-spectral multihy-

- pothesis prediction [J]. *Journal of Electronics & Information Technology*, 2015, 37(12): 3000-3008. (in Chinese)
- [5] 马馨宏, 郭树旭. 高光谱遥感图像的稀疏分解与压缩感知[J]. 吉林大学学报: 理学版, 2015, 53(4): 767-772.
MA X H, GUO S X. Compressed sensing and sparse decomposition of hyperspectral remote sensing images [J]. *Journal of Jilin University: Science Edition*, 2015, 53(4): 767-772. (in Chinese)
- [6] 贾应彪, 冯燕, 袁晓玲, 等. 高光谱图像分块压缩感知采样及谱间预测重构[J]. 应用科学学报, 2014, 32(3): 281-286.
JIA Y B, FENG Y, YUAN X L, *et al.* Block compressed sensing sampling and reconstruction using spectral prediction for hyperspectral images [J]. *Journal of Applied Sciences*, 2014, 32(3): 281-286. (in Chinese)
- [7] CHAKRABARTI A, ZICKLER T. Statistics of real-world hyperspectral images [C]//*Proceedings of 2011 IEEE Conference on Computer Vision and Pattern Recognition*, Providence, RI: IEEE, 2011: 193-200.
- [8] CHAKRABARTI A, ZICKLER T. Statistics of real-world hyperspectral images [C]//*Proceedings of 2011 IEEE Conference on Computer Vision and Pattern Recognition*, Providence, RI: IEEE, 2011: 193-200.
- [9] LI W, PRASAD S, FOWLER J E, *et al.* Locality-preserving dimensionality reduction and classification for hyperspectral image analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(4): 1185-1198.
- [10] 张静. 高光谱图像无损及渐进有损压缩编码技术研究[D]. 西安: 西安交通大学, 2009.
ZHANG J. Research on hyperspectral imagery lossless and progressive lossy compression technology [D]. Xi'an: Xi'an Jiaotong University, 2009. (in Chinese)
- [11] CANDES E J, WAKIN M B. An introduction to compressive sampling [J]. *IEEE Signal Processing Magazine*, 2008, 25(2): 21-30.
- [12] CANDES E, TAO T. Decoding by linear programming [J]. *IEEE Transactions on Information Theory*, 2005, 51(12): 4203-4215.
- [13] CANDÈS E, ROMBERG J K, TAO T. Stable signal recovery from incomplete and inaccurate measurements [J]. *Communications on Pure and Applied Mathematics*, 2006, 59(8): 1207-1223.
- [14] HUO C F, ZHANG R, YIN D. Compression technique for compressed sensing hyperspectral images [J]. *International Journal of Remote Sensing*, 2012, 33(5): 1586-1604.
- [15] MOHIMANI G H, BABAIE-ZADEH M, JUTTEN C. Fast sparse representation based on smoothed ℓ^0 norm [C]//*Proceedings of the 7th International Conference on Independent Component Analysis and Signal Separation*, Berlin Heidelberg: Springer, 2007: 389-396.
- [16] MOHIMANI H, BABAIE-ZADEH M, JUTTEN C. A fast approach for overcomplete sparse decomposition based on smoothed ℓ^0 norm [J]. *IEEE Transactions on Signal Processing*, 2009, 57(1): 289-301.

作者简介: 王晗(1992—), 男, 吉林长春人, 硕士研究生, 主要从事高光谱遥感影像处理等方面的研究。E-mail: lwanghan@sina.cn

王阿川(1964—), 男, 黑龙江哈尔滨人。教授, 博士生导师, 主要研究方向: 模式识别、计算机视觉、3S 技术等。E-mail: wangcal1964@126.com