

论文

谱间和帧内协同稀疏的高光谱图像压缩感知模型

王相海^{①②}, 宋海鹰^①, 宋传鸣^{①*}, 陶兢喆^②

① 辽宁师范大学计算机与信息技术学院, 大连 116029

② 辽宁师范大学自然地理与空间信息科学辽宁重点实验室, 大连 116029

* 通信作者. E-mail: chmsong@lnnu.edu.cn

收稿日期: 2015-05-04; 接受日期: 2015-06-09; 网络出版日期: 2015-08-04

国家自然科学基金项目 (批准号: 41271422, 61402214)、高等学校博士学科点专项科研项目 (批准号: 20132136110002)、辽宁省博士科研启动基金项目 (批准号: 20121076) 和辽宁省教育厅科学研究一般项目 (批准号: L2013405, L2013406) 资助

摘要 本文基于压缩感知理论, 利用高光谱图像谱间存在极强的相关性, 提出一种基于谱间和帧内协同稀疏的高光谱图像压缩感知模型 (hyperspectral image collaborative sparsity measure, HICoSM). 模型包括对高光谱图像各波段帧内及其帧间 3 方面的稀疏性挖掘: 一是对各波段帧基于局部区域平滑性的稀疏性度量; 二是对各波段帧基于非局部区域纹理、边缘等细节信息的自相似性稀疏性度量; 三是相邻波段帧基于谱间相关性的预测稀疏性度量, 具体利用前一个波段帧, 通过最小二乘法线性预测形成当前波段帧的预测帧, 通过确定预测帧与当前波段帧的最佳预测差实现谱间的稀疏性度量. 进一步, 给出了所提出模型的数值计算过程. 仿真实验表明, 模型 HICoSM 在对各个波段帧的稀疏性进行度量的基础上, 通过挖掘和测量高光谱图像波段间的谱间稀疏性, 有效地提高了各波段帧在压缩感知恢复阶段的解码质量.

关键词 高光谱图像 压缩感知 协同稀疏 谱间相关性 优化求解 预测残差

1 引言

高光谱遥感技术将地物光谱与空间图像有机地结合在一起, 以数以百计的连续且细分的光谱波段对地物进行观测成像, 实现了“图谱合一”, 所获取的图像具有高空间分辨率和高光谱分辨率, 为进一步的地物探测提供了丰富的细节信息^[1]. 然而也正是这种高光谱和高空间分辨率的属性使高光谱图像的数据量急剧增加, 再加上空间通信的传输信道通常具有异构、时变、带宽有限、误码率高、资源和星载设备处理能力有限等特点, 这给高光谱图像的压缩和传输带来了巨大的困难. 传统的高光谱图像有损压缩总体上可分为基于预测、变换和矢量量化等压缩方法^[2], 比如英国萨里空间中心 (SSC) 和萨里卫星技术有限公司 (SSTL) 的研究人员对现阶段较为实用的遥感数据星上压缩算法进行了总结^[3], 指出目前工程化应用程度较高的星载数据压缩算法包括 JPEG 算法、JPEG2000 算法和 CCSDS-LDC 无损压缩算法, 主要以单波段图像空间相关性为基础. 这种传统的基于 Nyquist 采样定理的先高速采

引用格式: 王相海, 宋海鹰, 宋传鸣, 等. 谱间和帧内协同稀疏的高光谱图像压缩感知模型. 中国科学: 信息科学, 2016, 46: 361-375, doi: 10.1360/N112014-00402

样、再压缩的过程, 不仅浪费了大量的采用资源, 而且给低功耗、资源有限的星上应用带来巨大的压力 [4,5].

近年来, 压缩感知 (compressive sensing, CS) 理论的发展受到人们的关注 [6]. 其突破传统 Shannon 采样定理的限制, 提出了一种新的采样理论 [7,8], 即对于在某个变换域下可稀疏表示的信号 (称为可压缩的), 可以通过采用一个与变换基满足等容性原则 (RIP) 的观测矩阵, 将这些高维稀疏系数投影到一个低维空间上, 获得少量的投影观测值, 其数量将远远少于传统的 Nyquist 采样定理所要求的采用个数; 然后可利用这些少量的观测值通过求解一个最优化问题, 以高概率的可能性重构出原信号. 该理论突破了传统 Nyquist 采样定理的瓶颈, 为采集高分辨率信号奠定了理论基础; 同时它将采样和压缩同步进行, 避免了传统信号采集所采用的先进行包含大量冗余信息的高速采样, 然后再通过压缩过程滤掉这些多余信息的中间环节, 极大地降低了采样和存储成本, 为现代图像信息处理的进一步发展奠定了基础 [9~13].

基于 CS 的信源编码过程中其稀疏表示部分对应着传统编码架构的编码阶段, 而重构部分则对应着信源的解码阶段. 与传统信源编码方法不同的是该编码机制在编码端具有较低的计算复杂度, 而将更多的计算工作量转移到了解码端, 因而目前重构部分的工作主要集中在如何进一步通过非凸优化方法更精确地解决联合优化问题. 尽管重构端具有较高的计算复杂度, 这是压缩感知编码原理的一大弱点, 但对于编码端资源受限的诸如星载遥感的应用环境, 恰恰能很好地得以适应. 文献 [14] 基于高光谱图像噪声方差估计方法, 提出了一种有效的基于改进噪声方差估计的分块压缩感知算法, 解码端采用基于三维小波变换的迭代投影 Landweber 和软阈值双变量收缩图像去噪方法; 文献 [15] 提出一种以端元光谱为先验知识的基于投影梯度法的一阶变分模型, 有效地提升了重构图像中低丰度区域空间的保真度, 同时通过采用简化的投影梯度法和基于搜索方向共轭的场景线性混合假设, 大大减少了计算量, 提高了高光谱影像的恢复速度.

除了对计算复杂度的关注以外, 人们更加关注的是 CS 方案的编码效率和解码质量. 事实上, CS 方案重构端信源的解码质量受到编码端信号稀疏程度的直接影响, 信号越稀疏, 所恢复的效果越好 [16]. 因而寻找能够使信号足够稀疏的变换域成为 CS 编码方案具有挑战性的一个问题. 由于图像和遥感图像等自然信号属于非平稳信号, 很难用某一固定的基底使其变换域系数的每个部分都达到稀疏, 这也是目前大部分 CS 算法采用 DCT 或 Wavelet 域等对图像进行稀疏表示很难使恢复图像达到理想的率失真性等的一个主要原因. 针对这一问题, 人们进行了积极研究, 文献 [17] 将一个分段平稳自回归模型结合到重构过程中, 提出一种在恢复阶段可方便使用自适应基底的模型引导架构, 该架构可方便地将一些先验知识模型结合到其中来提高最后图像的恢复质量. 然而, 这种通过最初恢复图像进行评估的自回归模型不可能具有鲁棒性, 并且往往会产生“鬼影”的视觉假象 [18]. 文献 [19] 将基于块的随机采样结合到投影驱动的 CS 重构过程中, 以增强方向变换 (诸如 Contourlet 和复值双树小波等) 域下的稀疏性. 但算法对图像的所有块均采用了相同的采样率, 对一些信息量较少的块将造成一些观测值的浪费. 文献 [20] 基于分块压缩感知对高光谱图像进行压缩采样, 在解码端采用谱间预测和平滑投影联合算法进行重构, 尽管方案中利用了谱间相关性和空间的局部相似特性, 但缺少对高光谱图像非局部自相似性的考虑. 文献 [16] 基于图像的非平稳特性, 提出了一种描绘自然图像结构稀疏性的协同稀疏测量 (collaborative sparsity measure, CoSM) 模型, 模型兼顾了图像的局部平滑特性和非局部的自相似特性, 使自然图像在混合空间—频率域尽可能地达到最稀疏表示, 取得了较固定基函数更好的 CS 恢复效果.

本文针对高光谱图像谱间强相关性和各波段图像的非平稳特性, 提出一种基于高光谱图像的谱间和帧内协同稀疏模型, 模型在考虑各波段图像局部区域像元间的相似性以及非局部区域纹理、边缘等

细节信息的自相似性的基础上, 通过引入相邻两波段图像间的预测误差正则项约束, 来增强对高光谱图像谱间的稀疏表示.

2 压缩感知理论及协同稀疏模型

2.1 压缩感知的基本数学模型

设 \mathbb{R}^N 是 N 维离散实信号空间, $\{\Psi_i\}_{i=1}^N$ 为其一组正交基, 则对于任一 N 维实信号 $\mathbf{x} \in \mathbb{R}^N$, 可展开为 $\{\Psi_i\}_{i=1}^N$ 的一个线性表出:

$$\mathbf{x} = \sum_{i=1}^N \theta_i \Psi_i, \quad (1)$$

其中 $\theta_i = \langle \mathbf{x}, \Psi_i \rangle$, ($i = 1, \dots, N$). 其矩阵形式如下:

$$\mathbf{x} = \Psi \boldsymbol{\theta}, \quad (2)$$

其中, $\Psi = [\Psi_1, \Psi_2, \dots, \Psi_N]^T$, $\boldsymbol{\theta} = [\theta_1, \theta_2, \dots, \theta_N]^T$.

如果上述系数向量 $\boldsymbol{\theta}$ 中的元素大多数为零或者接近于零, 即若假设非零的个数为 K , 则满足 $K \ll N$, 此时称 $\boldsymbol{\theta}$ 为 K 稀疏的 [7], 则可通过另一个与 Ψ 不相关的测量矩阵 $\Phi_{M \times N}$ ($M \ll N$) 对 \mathbf{x} 进行如下观测投影:

$$\mathbf{y} = \Phi \mathbf{x} = \Phi \Psi \boldsymbol{\theta} = \mathbf{A} \boldsymbol{\theta}, \quad (3)$$

其中, $\mathbf{y} \in \mathbb{R}^M$, $\mathbf{A} = \Phi \Psi$. 这样便可获得一个远小于 N 的 M 个线性观测, 而这些少量的压缩测量则可以包含重构 \mathbf{x} 的足够信息.

然而, 由于 $\mathbf{y} = \Phi \mathbf{x}$ 为欠定方程, 不可能直接由 \mathbf{y} 来重构 \mathbf{x} . 尽管 $\mathbf{y} = \mathbf{A} \boldsymbol{\theta}$ 也为欠定方程, 但由于 $\boldsymbol{\theta}$ 较为稀疏, 这就为通过 \mathbf{y} 来获取 $\boldsymbol{\theta}$, 进而重构 \mathbf{x} 提供了可能.

事实上, 只要投影算子 \mathbf{A} 满足等距约束性 (restricted isometry property, RIP) [21], 则上述压缩感知问题在一定条件下可以转化为如下所述的约束最优化问题 [8].

(1) 假设 $\boldsymbol{\theta}$ 为 K 稀疏的, \mathbf{A} 的 $2K$ 阶等距约束常数 $\delta_{2K} < 1$, 则问题 (3) 可转换为如下的约束最优化问题:

$$\min_{\boldsymbol{\theta} \in \mathbb{R}^N} \|\boldsymbol{\theta}\|_0 \text{ s.t. } \mathbf{y} = \mathbf{A} \boldsymbol{\theta}, \quad (4)$$

式 (4) 的不足之处是 L_0 范数的非凸性将会导致其成为 NP-hard 问题, 难以实现其数值计算.

(2) 对于 \mathbb{R}^N 中的任意矢量 $\boldsymbol{\theta}$, 如果 \mathbf{A} 的 $2K$ 阶等距约束常数 $\delta_{2K} < \sqrt{2} - 1$, 则问题 (3) 可转换为如下的约束最优化问题:

$$\min_{\boldsymbol{\theta} \in \mathbb{R}^N} \|\boldsymbol{\theta}\|_1 \text{ s.t. } \mathbf{y} = \mathbf{A} \boldsymbol{\theta}, \quad (5)$$

从而将式 (4) 的优化问题转化为了凸优化问题, 进而通过线性规划求解.

在上述压缩感知模型的实际应用中, 对投影算子 \mathbf{A} 是否满足 RIP 条件的判断并不是很直观, 这也一定程度上影响了模型的使用. 目前已经被证明满足该条件的投影算子通常包括随机 Gauss 矩阵、随机 Bernonlli 矩阵和部分 Hadamard 矩阵等 [22,23]. 考虑到随机 Gauss 矩阵所具有的与大多数正交基不相关和精确重构所需要的测量数较少, 本文将其作为高光谱遥感影像压缩过程的投影算子. 有关压缩感知理论的进一步分析与发展情况请参见综述 [6,23,24].

压缩感知方法较之经典的 Nyquist 采样与重构能够有效节约存储空间, 适用的信号范围也相当广泛. 但是对于自然图像和遥感图像等存在明显相关性的一类信号, 若依旧采用与随机信号相同的重构

方式, 则难免会在一定程度上影响信号的重构效率. 基于该种考虑, 近年来出现了一种利用图像的数据相关性来约束重构过程、改善重构质量的压缩感知模型 — 协同稀疏测量模型 [16].

2.2 协同稀疏测量模型

研究表明, 图像中的像素往往与其相邻的像素具有相近的像素值, 同时一个像素块也会与位置不相邻的某些块具有相似的边缘、纹理或轮廓, 这一特性被分别称为“局部平滑性”和“非局部自相似性”. 文献 [16] 利用图像所具有的这种局部平滑性和非局部自相似性, 提出了一种构建自适应稀疏基的协同稀疏测量模型 (CoSM). 模型包含对基于图像局部平滑性的 2D 空间域稀疏性测量 Ψ_{L2D} 和基于图像非局部自相似性的 3D 变换域稀疏性度量 Ψ_{N3D} , 前者利用图像在某种滤波卷积下所具有的稀疏性来度量空间域的稀疏程度; 后者通过对图像中的相似块进行排队组合, 形成 3 维图像块组, 利用其 3D 正交变换系数所具有的稀疏性来度量非局部自相似块的稀疏程度, 具体测量模型如下:

$$f(\mathbf{x}) \triangleq \|\Psi_{L2D}\mathbf{x}\|_1 = \|D_h\mathbf{x}\|_1 + \|D_v\mathbf{x}\|_1, \quad (6)$$

$$g(\mathbf{x}) \triangleq \|\Psi_{N3D}\mathbf{x}\|_0 = \sum_{k=1}^n \|T^{3D}(Z_{x_k})\|_0, \quad (7)$$

其中, 式 (6) 中的 D_h 和 D_v 分别为图像水平和垂直方向的梯度算子; 式 (7) 中的 T^{3D} 为正交三维变换, Z_{x_k} 为与目标图像块 x_k 相似的图像块所组成的三维排列.

这样, 基于 CoSM 的 CS 重构公式为

$$\min_x \left(\|D_h\mathbf{x}\|_1 + \|D_v\mathbf{x}\|_1 + \sum_{k=1}^n \|T^{3D}(Z_{x_k})\|_0 \right) \text{ s.t. } \mathbf{y} = \mathbf{A}\mathbf{x}. \quad (8)$$

借助图像自身的正则性, 协同稀疏测量模型取得了优于传统压缩感知模型的重构效果, 这表明利用图像的统计特征是一种可行的重构优化思路. 虽然模型考虑了图像的局部平滑性和非局部的自相似性, 但对于高光谱遥感图像而言, 它还普遍存在另外一种数据相关 — 谱间相关. 文献 [25] 通过谱间预测来修正重构算法的初始值和收敛准则, 再利用基于谱间修正项的 GPSR 进行重构, 在一定程度上提高了信号的重建效率, 从而验证了谱间相关对于压缩感知重构的有效性. 然而该算法没有考虑图像的局部平滑性和非局部的自相似特性. 综合上述研究结果, 本文认为同时利用高光谱图像具有的空间局部和非局部相关性以及谱间相关性, 能够进一步改善压缩感知模型的效率. 基于此, 本文提出下列基于谱间和帧内相关性的高光谱图像协同稀疏模型.

3 基于谱间和帧内高光谱图像协同稀疏模型

3.1 观测向量初始化高光谱图像的分组

高光谱图像是对同一地物不同谱段反射光的成像, 因此相邻谱段图像的相同位置像素具有很强的谱间相关性. 该特性可通过如下的谱间相关系数 $r_k(t)$ 进行度量 [2]:

$$r_k(t) = \frac{\sum_{i=1}^N \sum_{j=1}^M (I(k, i, j) - I_k)(I(k+t, i, j) - I_{k+t})}{\sqrt{\sum_{i=1}^N \sum_{j=1}^M (I(k, i, j) - I_k)^2 \sum_{i=1}^N \sum_{j=1}^M (I(k+t, i, j) - I_{k+t})^2}}, \quad (9)$$




图 1 EO-1 卫星拍摄的高光谱图像谱间相关系数统计

Figure 1 The correlation coefficient statistics of hyperspectral image photoed by EO-1 satellite. (a) Hyperspectral remote sensing image of Dalian coastal zone; (b) hyperspectral remote sensing image of Jasper Ridge

其中, $I(k, i, j)$ 和 $I(k + t, i, j)$ 分别表示第 k 波段和第 $k + t$ 波段图像的 i 行、 j 列像素的灰度值; I_k 和 I_{k+t} 则分别表示第 k 和 $k + t$ 波段所有像素点灰度值的平均值. 图 1 给出了美国航天局地球观测-1 号 (EO-1) 卫星拍摄的两幅高光谱图像按式 (9) 统计的谱间相关性的统计结果. 可以看出, 高光谱图像谱间一般具有很强的相关性, 存在着很高的冗余信息, 有效的对其进行稀疏表示, 对于提高高光谱图像 CS 编码的效率和恢复质量具有重要意义.

基于上述高光谱图像间所具有的高相关特性, 本文方案在重构端首先对各波段帧的观测向量进行初始重构形成初始化波段帧, 并对其按照波段顺序进行基于谱间相关系数的分组, 使得分在同一组中的波段帧高度相关 (实验中选取波段系数阈值为 0.9, 即分在一组中的波段帧间的波段系数不小于 0.9).

3.2 模型的提出

根据高光谱图像所具有的高空间分辨率和高光谱分辨率所带来的谱间和谱内空间高相关性的特性, 提出如下用于高光谱图像 CS 恢复的协同稀疏测量 (hyperspectral image collaborative sparsity measure, HICoSM) 模型.

设重构端经各波段帧观测值初始化的第 k 组高光谱图像为 $\mathbf{X}^{(k)} = (\mathbf{x}_1^{(k)}, \mathbf{x}_2^{(k)}, \dots, \mathbf{x}_{N_k}^{(k)})$, 其中 $k \in [1, M]$ (M 为分组个数), N_k 为该组的波段数, $\mathbf{x}_i^{(k)}$ 为该组第 i 波段 ($i \in [1, N_k]$) 的初始化图像, 定义 HICoSM 模型如下:

$$\text{HICoSM}(\mathbf{X}^{(k)}) = \sum_{i=1}^{N_k} (\|\Psi_{L2D}\mathbf{x}_i^{(k)}\|_1 + \|\Psi_{N3D}\mathbf{x}_i^{(k)}\|_0) + \sum_{i=2}^{N_k} \|\Psi_{T3D}(\mathbf{x}_i^{(k)}, \mathbf{x}_{i-1}^{(k)})\|_1, \quad (10)$$

其中, $\|\Psi_{L2D}\mathbf{x}_i^{(k)}\|_1$ 和 $\|\Psi_{N3D}\mathbf{x}_i^{(k)}\|_0$ ($i \in [1, N_k]$) 分别表示第 i 波段初始化图像 $\mathbf{x}_i^{(k)}$ 基于局部平滑性的稀疏性度量和基于非局部自相似性的 3D 变换域稀疏性度量, 其表达式参见式 (6) 和 (7); $\|\Psi_{T3D}(\mathbf{x}_i^{(k)}, \mathbf{x}_{i-1}^{(k)})\|_1$ ($i \in [2, N_k]$) 为基于谱间相关性的预测稀疏性度量, 具体过程如下:

(1) 利用前一个波段帧 $\mathbf{x}_{i-1}^{(k)}$, 通过最小二乘法线性预测形成 $\mathbf{x}_i^{(k)}$ 的预测帧 $\mathbf{x}_i^{(k)-pre}$, 如下:

$$\mathbf{x}_i^{(k)-pre} = \theta(\mathbf{x}_{i-1}^{(k)} - \mathbf{A}_{\mathbf{x}_{i-1}^{(k)}}) + \mathbf{A}_{\mathbf{x}_i^{(k)}}, \quad (11)$$

其中 $\mathbf{A}_{x_{i-1}^{(k)}}$ 和 $\mathbf{A}_{x_i^{(k)}}$ 分别为由 $\mathbf{x}_{i-1}^{(k)}$ 和 $\mathbf{x}_i^{(k)}$ 的平均灰度值所形成的与其大小相同的矩阵, θ 为通过最小二乘法所获得的预测系数, 具体形式为

$$\theta = \frac{\sum_{m,n} (\mathbf{x}_i^{(k)}(m,n) - \mathbf{A}_{x_i^{(k)}}(m,n)) \times (\mathbf{x}_{i-1}^{(k)}(m,n) - \mathbf{A}_{x_{i-1}^{(k)}}(m,n))}{\sum_{m,n} (\mathbf{x}_{i-1}^{(k)}(m,n) - \mathbf{A}_{x_{i-1}^{(k)}}(m,n))^2}.$$

(2) 通过 $\mathbf{x}_i^{(k)-pre}$ 与 $\mathbf{x}_i^{(k)}$ 的预测差实现谱间的稀疏性度量, 即有

$$\|\Psi_{T3D}(\mathbf{x}_i^{(k)}, \mathbf{x}_{i-1}^{(k)})\|_1 = \|\mathbf{x}_i^{(k)-pre} - \mathbf{x}_i^{(k)}\|_1 + \mathbf{x}_i^{(k)-pre}. \quad (12)$$

这样, 基于所提出 HICoSM 模型的第 k 组波段帧 CS 重构公式为

$$\min_{\mathbf{x}_i^{(k)}} (\|\Psi_{L2D}\mathbf{x}_i^{(k)}\|_1 + \|\Psi_{N3D}\mathbf{x}_i^{(k)}\|_0 + \|\Psi_{T3D}(\mathbf{x}_i^{(k)}, \mathbf{x}_{i-1}^{(k)})\|_1) \text{ s.t. } \mathbf{y} = \mathbf{A}\mathbf{x}_i^{(k)}, i \in [2, N_k]. \quad (13)$$

3.3 模型的数值计算

上述基于 HICoSM 模型的第 k 组波段帧 CS 重构 (13) 式等同于求解如下优化问题:

$$\min_{\mathbf{x}_i^{(k)}} \left(\frac{1}{2} \|\mathbf{y} - \mathbf{A}\mathbf{x}_i^{(k)}\|_2^2 + \lambda (\|\Psi_{L2D}\mathbf{x}_i^{(k)}\|_1 + \|\Psi_{N3D}\mathbf{x}_i^{(k)}\|_0 + \|\Psi_{T3D}(\mathbf{x}_i^{(k)}, \mathbf{x}_{i-1}^{(k)})\|_1) \right), \quad (14)$$

其中 λ 为一非负参数, 本文实验中选取其为 10.

对于波段帧的局部和非局部自相似特性, 模型中局部平滑稀疏性和非局部平滑稀疏性可分别通过式 (6) 和 (7) 来描述, 而针对谱间的强相关性, $\|\Psi_{T3D}(\mathbf{x}_i^{(k)}, \mathbf{x}_{i-1}^{(k)})\|_1$ 为求使误差项最小的正则项, 此时可将其转化为基于 L_1 范数的下述问题来求解:

$$\arg \min_{\mathbf{x}} \frac{1}{2} \|\mathbf{x} - (\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre})\|_2^2 + \tau \|\mathbf{x}\|_1, \quad (15)$$

问题 (15) 可以用软阈值方法^[16] 进行求解, 上述求解问题等价于

$$\hat{\mathbf{x}} = \text{soft}(\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}, \tau) = \text{sgn}(\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}) \cdot \max(|\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}| - \tau, \mathbf{0}), \quad (16)$$

这里 $\hat{\mathbf{x}}$ 是谱间最小误差项, τ 是一正常数 (实验中选择其为 6), $\text{sgn}(\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre})$ 为与 $\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}$ 所对应的符号矩阵, 即 $\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}$ 矩阵中负数、零和正数元素分别对应 -1 、 0 和 $+1$ 所形成的矩阵; $|\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}| - \tau$ 则表示 $\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}$ 矩阵中的每个元素取绝对值并与 τ 作差所形成的矩阵.

这样, 单纯考虑谱间相关性所确定的当前波段帧的重构图像为

$$z(\mathbf{x}_i^{(k)}) \triangleq \|\Psi_{T3D}(\mathbf{x}_i^{(k)}, \mathbf{x}_{i-1}^{(k)})\|_1 = \hat{\mathbf{x}} + \mathbf{x}_i^{(k)-pre} = \text{sgn}(\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}) \cdot \max(|\mathbf{x}_i^{(k)} - \mathbf{x}_i^{(k)-pre}| - \tau, \mathbf{0}) + \mathbf{x}_i^{(k)-pre}. \quad (17)$$

进一步引入一个中间变量 $\mathbf{u}_i^{(k)}$, 并令 $\mathbf{x}_i^{(k)} = \mathbf{u}_i^{(k)}$, 则式 (14) 可以表示为

$$\min_{\mathbf{x}_i^{(k)}, \mathbf{u}_i^{(k)}} \left(\frac{1}{2} \|\mathbf{y} - \mathbf{A}\mathbf{x}_i^{(k)}\|_2^2 + \lambda (\|\Psi_{L2D}\mathbf{u}_i^{(k)}\|_1 + \|\Psi_{N3D}\mathbf{u}_i^{(k)}\|_0 + \|\Psi_{T3D}(\mathbf{u}_i^{(k)}, \mathbf{u}_{i-1}^{(k)})\|_1) \right) \text{ s.t. } \mathbf{x}_i^{(k)} = \mathbf{u}_i^{(k)}. \quad (18)$$

对式 (18) 的求解可依据 SBI (split Bregman iteration) 算法^[26~28] 表示为以下 3 步迭代子问题:

$$(\mathbf{x}_i^{(k)})^{(t+1)} = \arg \min_x \frac{1}{2} \left\| \mathbf{y} - \mathbf{A} \mathbf{x}_i^{(k)} \right\|_2^2 + \frac{\mu}{2} \left\| \mathbf{x}^{(k)} - \mathbf{u}_i^{(k)} - \mathbf{b}^{(t)} \right\|_2^2, \quad (19)$$

$$\begin{aligned} (\mathbf{u}_i^{(k)})^{(t+1)} = \arg \min_u \frac{m}{2} & \left\| (\mathbf{x}_i^{(k)})^{(t+1)} - \mathbf{u}_i^{(k)} - \mathbf{b}^{(t)} \right\|_2^2 + \lambda (\| \Psi_{L2D} \mathbf{u}_i^{(k)} \|_1 \\ & + \| \Psi_{N3D} \mathbf{u}_i^{(k)} \|_0 + \| \Psi_{T3D} (\mathbf{u}_i^{(k)}, \mathbf{u}_{i-1}^{(k)}) \|_1), \end{aligned} \quad (20)$$

$$\mathbf{b}^{(t+1)} = \mathbf{b}^{(t)} - ((\mathbf{x}_i^{(k)})^{(t+1)} - (\mathbf{u}_i^{(k)})^{(t+1)}), \quad (21)$$

其中 μ 和 m 为正值参数, 实验中选取 m 为 0.0025.

对于式 (19), 采用最速梯度下降法求解, 得到

$$(\mathbf{x}_i^{(k)})^{(t+1)} = (\mathbf{x}_i^{(k)})^{(t)} - h(\mathbf{A}^T(\mathbf{A}(\mathbf{x}_i^{(k)})^{(t)} - \mathbf{y}) + m((\mathbf{x}_i^{(k)})^{(t)} - (\mathbf{u}_i^{(k)})^{(t)} - \mathbf{b}^{(t)})), \quad (22)$$

其中, h 是最优下降步长.

为方便描述, 引用记号 $\text{prox}_a(F)(\mathbf{x})$ 如下:

$$\text{prox}_a(F)(\mathbf{x}) = \arg \min_u \left\{ \frac{1}{2} \left\| \mathbf{u} - \mathbf{x} \right\|_2^2 + a \cdot F(\mathbf{u}) \right\}, \quad (23)$$

其中 F 为一个函数, a 为一正常数.

令 $\mathbf{r}_i^{(t+1)} = (\mathbf{x}_i^{(k)})^{(t+1)} - \mathbf{b}^{(t)}$, 则式 (20) 可以表示为

$$(\mathbf{u}_i^{(k)})^{(t+1)} = \text{prox}_{\lambda/m}(f + g + z)(\mathbf{r}_i^{(t+1)}), \quad (24)$$

其中函数 f , g 和 z 分别对应上述式 (6), (7) 和 (17). 进一步按照分离求解的思想^[29] 可将式 (24) 表示为

$$(\mathbf{u}_i^{(k)})^{(t+1)} = w_i^{(f)} \times \text{prox}_{\lambda/m}(f)(\mathbf{r}_i^{(t+1)}) + w_i^{(g)} \times \text{prox}_{\lambda/m}(g)(\mathbf{r}_i^{(t+1)}) + w_i^{(z)} \times \text{prox}_{\lambda/m}(z)(\mathbf{r}_i^{(t+1)}), \quad (25)$$

其中 $w_i^{(f)}$, $w_i^{(g)}$ 和 $w_i^{(z)}$ 为权重系数.

3.4 权重系数的自适应计算方法

同一地物对不同谱段反射光的成像结果往往不同, 对于纹理较强的光谱帧, 其局部相关性和谱间相关性较强; 而对于平滑的或轮廓边较强的光谱帧, 其非局部相关性也会较强. 这样, 式 (25) 中的权重系数 $w_i^{(f)}$, $w_i^{(g)}$ 和 $w_i^{(z)}$ 若采用统一的固定值, 则不利于充分发挥各种相关性以及协同稀疏模型的作用. 因此, 本文提出一种基于前一波段重构帧的权重系数自适应计算方案, 即根据前一帧重构过程中各预测分量对重构帧的预测误差来度量其权重, 即根据前一帧局部相似性、非局部相似性和谱间相似性分别计算的重构分量, 分别与前一帧重构出的最终图像进行预测误差计算, 预测误差越大, 表明根据该相似性计算的重构分量对该帧的贡献越小, 反之则越大. 实验结果表明基于前一帧预测的权重系数较基于固定值的权重系数具有更好的重构效果. 据此本文提出下述自适应的权重系数计算过程.

对于 $i = 2$, 选择 $(w_2^{(f)}, w_2^{(g)}, w_2^{(z)}) = (0.8, 0.05, 0.15)$; 对于 $i \geq 3$, $(w_i^{(f)}, w_i^{(g)}, w_i^{(z)})$ 按 (26) 式计算:

$$\begin{cases} w_i^{(f)} = \frac{\beta\gamma}{\alpha\beta + \beta\gamma + \alpha\gamma}, \\ w_i^{(g)} = \frac{\alpha\gamma}{\alpha\beta + \beta\gamma + \alpha\gamma}, \\ w_i^{(z)} = 1 - w_i^{(f)} - w_i^{(g)}, \end{cases} \quad (26)$$

其中, α_{i-1} , β_{i-1} 和 γ_{i-1} 分别为 $f(\mathbf{x}_{i-1}^{(k)})$, $g(\mathbf{x}_{i-1}^{(k)})$ 和 $z(\mathbf{x}_{i-1}^{(k)})$ 与 $(\mathbf{u}_{i-1}^{(k)})^{(t+1)}$ 的均方误差值.

本文模型有效利用了单波段图像自身的局部相似性和非局部的自相似性, 在此基础上进一步结合高光谱图像波段间存在的谱间相关性; 同时采用均方误差度量每个相关性分量对图像重构的作用, 并通过线性模型自适应地调整每个相关性分量的权值. 较之现有方法, 该模型更加有利于充分、灵活地发掘图像中广泛存在的正则性来改善重构质量.

4 基于 HICoSM 模型的高光谱影像压缩感知算法实现

在 HICoSM 模型的基础上, 本节提出一种高光谱影像的压缩感知编码算法, 其中编码过程与典型压缩感知编码相同, 即对每一帧高光谱图像 $\mathbf{x}_i^{(k)}$ 进行压缩、采样, 获得测量值 $\mathbf{y}_i^{(k)}$, 这里不再赘述. 下面给出解码的具体过程:

Step 1 初始化, $k=1, i=1$ ($k \in [1, M]$, M 为分组个数; $i \in [1, N_k]$, N_k 为第 k 组的波段数).

Step 2 如果 $k > M$, 则输出 $\bar{\mathbf{x}}_i^{(k)}$ ($k \in [1, M], i \in [1, N_k]$), 解码过程结束; 否则转入 Step 3.

Step 3 如果 $i > N_k$, 则 $k++$, $i=1$, 并转入 Step 2; 否则转入 Step 4.

Step 4 输入第 k 组的第 i 波段帧的测量值 $\mathbf{y}_i^{(k)}$.

Step 5 如果 $i=1$, 即待解码图像为第一波段帧, 则对测量值 $\mathbf{y}_1^{(k)}$ 通过模型 RCoS 恢复 $\bar{\mathbf{x}}_1^{(k)}$; 否则对 $\mathbf{y}_i^{(k)}$ ($i \in [2, N_k]$) 进行基于 HICoSM 模型的迭代优化恢复, 即分别利用式 (22), (25) 和 (21) 对 $(\mathbf{x}_i^{(k)})^{(t+1)}$, $(\mathbf{u}_i^{(k)})^{(t+1)}$ 和 $\mathbf{b}^{(t+1)}$ 进行更新, 然后根据自定义的最大迭代次数恢复波段帧 $\bar{\mathbf{x}}_i^{(k)}$. 在迭代过程中, 通过式 (26) 计算局部相似性、非局部相似性和谱间相关性对当前波段重构图像的影响因子, 即权值系数 $w_i^{(f)}$, $w_i^{(g)}$ 和 $w_i^{(z)}$, 以此作为下一波段帧的权值系数.

Step 6 $i++$, 转入 Step 3.

5 实验与分析

为验证和评估所提出模型的有效性, 选取了 EO-1 卫星搭载的 Hyperion 成像光谱仪对大连地区拍摄的已定标的高光谱遥感图像 EO1H1200332003092110PZ.L1R (该图像共有 242 个波段, 光谱范围为 400~2500 nm, 光谱分辨率达到 10 nm) 和美国圣马丁湾地区的高光谱遥感图像 ($614 \times 512 \times 224 \times 8$), 并截取其 256×256 像素的图像区域进行了仿真实验. 实验在 Intel(R) Xeon(R) CPU E5-26090, 2.4 GHz, 8 G 内存机器上的 Matlab 环境下进行. 此外, 实验在对所提出模型和算法进行验证的同时, 还与 GPSR 算法^[30]、改进的 GPSR 算法^[31] 和 RCoS 算法^[16] 进行了对比. 具体实验结果如下所述.

(1) EO-1 卫星 Hyperion 图像

对 EO-1 所拍摄的大连区域高光谱图像, 选取 15~30 的 16 个波段进行仿真实验. 其中图 S1(a) 为部分帧的原始图像, 图 S1(b) 给出了不同算法对图 S1(a) 图像不同码率下的重构帧 (图 S1 请参见电子附件); 表 1 给出了 16 个波段帧重构图像的 PSNR.

从图 S1 和表 1 可以看出, 由于 GPSR 算法针对的是所有信号, 并没有考虑到图像的特性, 其重构图像的 PSNR 较低; 而改进的 GPSR 考虑了谱间相关性, 加入了线性滤波, 其 PSNR 较 GPSR 提高了 6 dB 左右, 但其并没有考虑图像自身的相关性; RCoS 算法充分考虑了图像邻域的局部平滑性, PSNR 又进一步提高了 13 dB 左右. 本文算法对大连区域高光谱图像的重构效果较 RCoS 算法重构的图像质量略有改善, 较 GPSR 算法及其改进的 GPSR 算法有很大提升; 从 PSNR 上可以看出相同码率下较 GPSR 算法、改进的 GPSR 算法和 RCoS 算法分别提升 12 db, 7 db, 1 db 左右.

表 1 不同算法对 EO-1 所拍摄高光谱图像重构各帧的 PSNR 对比

Table 1 The contrast of PSNR of EO-1 hyperspectral data's reconstructed image under the different algorithms

| Ratio | Frame | PSNR (dB) | | | |
|-------|---------|-----------|---------------|---------|----------------|
| | | GPSR | Improved GPSR | RCoS | Our algorithms |
| 0.2 | 15 | 10.7315 | 10.7315 | 23.1587 | 23.1587 |
| | 16 | 10.7809 | 16.4377 | 22.6449 | 23.4891 |
| | 17 | 10.8750 | 17.7049 | 22.6749 | 23.3015 |
| | 18 | 10.9223 | 18.0879 | 22.7084 | 23.3321 |
| | 19 | 11.0121 | 17.7893 | 22.6697 | 23.2928 |
| | 20 | 11.0965 | 17.6508 | 22.4663 | 23.1095 |
| | 21 | 11.0553 | 17.8316 | 22.4111 | 23.0234 |
| | 22 | 11.2138 | 17.7403 | 22.3806 | 23.0007 |
| | 23 | 11.4002 | 18.3068 | 21.9806 | 22.5512 |
| | 24 | 11.3887 | 18.2042 | 21.8042 | 22.3556 |
| | 25 | 11.6164 | 18.1019 | 21.4676 | 22.0439 |
| | 26 | 11.6756 | 18.2269 | 21.3071 | 21.8455 |
| | 27 | 11.4775 | 18.0245 | 21.8082 | 22.3871 |
| | 28 | 10.2487 | 18.0995 | 23.8788 | 24.6605 |
| 0.3 | 29 | 9.2403 | 18.2537 | 27.6159 | 28.4254 |
| | 30 | 9.5331 | 18.2286 | 27.7348 | 28.5895 |
| | 15 | 12.5478 | 12.5478 | 24.8872 | 24.8872 |
| | 16 | 12.5335 | 18.0741 | 24.4014 | 25.4545 |
| | 17 | 12.5976 | 19.7815 | 24.2905 | 25.3481 |
| | 18 | 12.7072 | 20.4062 | 24.5048 | 25.0423 |
| | 19 | 12.8364 | 20.8637 | 24.5328 | 25.4652 |
| | 20 | 12.9056 | 20.5505 | 24.1952 | 25.1775 |
| | 21 | 12.8518 | 20.6755 | 24.1823 | 25.1822 |
| | 22 | 13.0124 | 20.5696 | 24.1757 | 25.1237 |
| | 23 | 13.1802 | 20.9499 | 23.9054 | 24.8201 |
| | 24 | 13.1729 | 20.6960 | 23.7188 | 24.6036 |
| | 25 | 13.3162 | 20.8095 | 23.3876 | 24.2812 |
| | 26 | 13.3399 | 20.5496 | 23.2053 | 23.8501 |
| 27 | 13.1216 | 20.8278 | 23.7062 | 24.2952 | |
| 28 | 12.0096 | 21.3003 | 25.6031 | 26.7836 | |
| 29 | 18.8578 | 21.7220 | 29.5112 | 29.3490 | |
| 30 | 19.4763 | 23.0618 | 29.7944 | 30.7192 | |
| | 15 | 20.1087 | 20.1087 | 26.7609 | 26.7609 |
| | 16 | 19.8473 | 22.6252 | 26.1217 | 27.2462 |
| | 17 | 19.9811 | 23.5409 | 25.9881 | 27.0694 |
| | 18 | 19.7882 | 23.5162 | 26.1305 | 27.1679 |
| | 19 | 19.7319 | 23.6129 | 26.0791 | 27.1818 |
| | 20 | 19.4516 | 23.0752 | 25.9319 | 26.9213 |

| Ratio | Frame | PSNR (dB) | | | |
|-------|-------|-----------|---------------|---------|----------------|
| | | GPSR | Improved GPSR | RCoS | Our algorithms |
| 0.4 | 21 | 19.5155 | 23.6395 | 25.9848 | 26.9695 |
| | 22 | 19.4622 | 23.2745 | 25.6984 | 26.7666 |
| | 23 | 17.8308 | 23.5502 | 25.5051 | 26.4961 |
| | 24 | 17.2026 | 23.5127 | 25.3063 | 26.2840 |
| | 25 | 17.0869 | 23.3151 | 24.9373 | 25.8781 |
| | 26 | 17.0132 | 23.2326 | 24.9593 | 25.8362 |
| | 27 | 16.9625 | 23.4384 | 25.4485 | 26.3709 |
| | 28 | 20.7465 | 23.9444 | 27.5876 | 28.6389 |
| | 29 | 22.8082 | 25.4482 | 31.2074 | 32.3162 |
| | 30 | 22.4730 | 26.4098 | 31.4922 | 32.5586 |

(2) 美国圣马丁湾地区高光谱图像

选取美国圣马丁湾地区的 9~19 共 11 个波段进行仿真实验. 其中图 S2(a) 为部分帧的原始图像, 图 S2(b) 给出了不同算法对图 S2(a) 图像不同码率下的重构帧 (图 S2 请参见电子附件); 表 2 给出了 11 个波段帧重构图像的 PSNR.

从图 S2 和表 2 可以看出, 本文算法对高光谱图像重构的质量和 PSNR 方面较其他算法有所提升. 相比 GPSR 算法、改进的 GPSR 算法和 RCoS 算法, 本文算法在码率为 0.2 时, PSNR 提高约 11 db, 5 db, 1 db 左右; 在码率为 0.3 时, PSNR 提高约 10 db, 6db, 1.5 db 左右; 在码率为 0.4 时, PSNR 提高约 7 db, 4 db, 1 db 左右.

(3) AVIRIS 高光谱图像

选取 AVIRIS 高光谱图像 Jasper Ridge 60~75 共 16 个波段进行仿真实验. 其中图 S3(a) 为部分帧的原始影像, 图 S3(b) 给出了不同算法对图 S3(a) 影像不同码率下的重构帧 (图 S3 请参见电子附件); 表 3 给出了 16 个波段帧重构影像的 PSNR.

从图 S3 和表 3 可以看出, 相比 GPSR 算法、改进的 GPSR 算法、RCoS 算法, 本文算法无论从图像质量还有 PSNR 上都有所提高. 其在码率为 0.2 时, PSNR 提高约 13 db, 5 db, 0.3 db 左右; 在码率为 0.3 时, PSNR 提高约 10 db, 5 db, 0.3 db 左右; 在码率为 0.4 时, PSNR 提高约 9 db, 5 db, 0.5 db 左右.

6 结束语

针对高光谱图像相邻波段间所具有的高谱间相关性, 提出一种用于高光谱图像 CS 恢复的协同稀疏测量 (HICoSM), 该模型在考虑各光谱帧局部相似性、非局部纹理区域的自相似性的基础上, 重点考察了各高光谱相邻图像间的谱间相关性, 通过最小二乘法线性预测获得预测帧, 进而利用预测帧与当前帧的稀疏帧差谱间稀疏性的度量, 在此基础上给出了模型 HICoSM 的数值计算方法. 大量的仿真实验表明, 模型 HICoSM 在对各个波段帧的稀疏性进行有效度量的基础上, 能够充分挖掘和测量高光谱波段间的谱间稀疏性, 从而有效地提高了各高光谱帧在 CS 恢复阶段的解码质量. 此外该模型也为基于高光谱图像谱间相关性的进一步应用提供了一种思路.

表 2 不同算法对美国圣马丁湾地区高光谱图像重构各帧的 PSNR 对比

Table 2 The contrast of PSNR of American St Martin area's reconstructed image under the different algorithms

| Ratio | Frame | PSNR (dB) | | | |
|-------|---------|-----------|---------------|---------|----------------|
| | | GPSR | Improved GPSR | RCoS | Our algorithms |
| 0.2 | 9 | 10.5792 | 10.5792 | 20.2744 | 20.2744 |
| | 10 | 11.3946 | 17.8909 | 21.9711 | 22.7162 |
| | 11 | 12.3369 | 18.9276 | 22.7393 | 23.5746 |
| | 12 | 12.4533 | 20.0758 | 24.2051 | 25.0962 |
| | 13 | 12.5937 | 19.9921 | 24.2954 | 25.4063 |
| | 14 | 13.1362 | 19.4639 | 24.1382 | 25.2341 |
| | 15 | 13.1089 | 19.5678 | 24.5718 | 25.6459 |
| | 16 | 13.1615 | 19.5590 | 24.6481 | 25.7441 |
| | 17 | 12.3492 | 20.5984 | 25.0925 | 26.2573 |
| | 18 | 12.0842 | 20.8409 | 25.6174 | 26.7217 |
| 0.3 | 9 | 14.0048 | 14.0048 | 21.5632 | 21.5632 |
| | 10 | 13.1593 | 19.6212 | 23.6051 | 24.1962 |
| | 11 | 14.0391 | 20.9642 | 24.4955 | 25.3214 |
| | 12 | 17.1044 | 22.4576 | 26.0612 | 27.0652 |
| | 13 | 17.2326 | 22.8446 | 26.4092 | 27.5761 |
| | 14 | 17.0879 | 22.0820 | 26.3232 | 27.5153 |
| | 15 | 17.2246 | 22.2281 | 26.6706 | 27.9075 |
| | 16 | 17.2696 | 22.1639 | 26.7546 | 28.0281 |
| | 17 | 14.0306 | 23.2891 | 26.9720 | 28.5501 |
| | 18 | 14.4857 | 23.3186 | 27.6331 | 29.0106 |
| 0.4 | 9 | 14.3812 | 14.3812 | 22.4791 | 22.4791 |
| | 10 | 18.1639 | 20.7247 | 24.5519 | 25.2682 |
| | 11 | 20.3103 | 22.6071 | 25.6889 | 26.6104 |
| | 12 | 21.3856 | 24.3626 | 27.3989 | 28.2333 |
| | 13 | 21.5703 | 24.8236 | 28.0087 | 29.2441 |
| | 14 | 21.0283 | 24.6479 | 27.9771 | 29.3356 |
| | 15 | 20.9893 | 24.6008 | 28.3979 | 29.8028 |
| | 16 | 21.1306 | 24.4506 | 28.4956 | 30.0012 |
| | 17 | 20.4947 | 25.6056 | 28.9789 | 30.5707 |
| | 18 | 18.7574 | 26.0016 | 29.4295 | 31.0472 |
| 19 | 18.5235 | 25.6627 | 29.4861 | 31.0588 | |

表 3 不同算法对 Jasper Ridge 高光谱影像重构各帧的 PSNR 对比
Table 3 The contrast of PSNR of Jasper Ridge's reconstructed image under the different algorithms

| Ratio | Frame | PSNR (dB) | | | |
|-------|---------|-----------|---------------|---------|----------------|
| | | GPSR | Improved GPSR | RCoS | Our algorithms |
| 0.2 | 60 | 7.0793 | 7.0793 | 20.4843 | 20.4843 |
| | 61 | 7.1109 | 15.2143 | 20.5580 | 20.7999 |
| | 62 | 7.1394 | 15.9120 | 20.5864 | 20.7922 |
| | 63 | 7.1610 | 15.9163 | 20.6155 | 20.8159 |
| | 64 | 7.5079 | 15.8553 | 20.6240 | 20.8377 |
| | 65 | 7.4855 | 15.8908 | 20.6841 | 20.9039 |
| | 66 | 7.4747 | 15.9087 | 20.7371 | 20.9578 |
| | 67 | 7.4593 | 15.9566 | 20.7762 | 21.0011 |
| | 68 | 7.4418 | 16.0051 | 20.8114 | 21.0337 |
| | 69 | 7.4213 | 16.0549 | 20.8263 | 21.0465 |
| | 70 | 7.4080 | 16.1224 | 20.8674 | 21.0935 |
| | 71 | 7.3906 | 16.1839 | 20.8762 | 21.0982 |
| | 72 | 7.3815 | 16.2284 | 20.4843 | 20.4843 |
| | 73 | 7.3659 | 16.2737 | 20.5580 | 20.7999 |
| | 74 | 7.3619 | 16.3223 | 20.5864 | 20.7922 |
| 75 | 7.3587 | 16.3488 | 20.6155 | 20.8159 | |
| 0.3 | 60 | 11.3748 | 11.3748 | 22.1737 | 22.1737 |
| | 61 | 11.3787 | 16.8566 | 22.2314 | 22.5485 |
| | 62 | 11.4232 | 17.4889 | 22.2734 | 22.5551 |
| | 63 | 11.4638 | 17.4992 | 22.3121 | 22.5788 |
| | 64 | 11.5366 | 17.4368 | 22.3099 | 22.5818 |
| | 65 | 11.5709 | 17.4699 | 22.4016 | 22.6963 |
| | 66 | 11.6123 | 17.4943 | 22.4572 | 22.7555 |
| | 67 | 11.6367 | 17.5446 | 22.5159 | 22.8131 |
| | 68 | 11.6127 | 17.5831 | 22.5424 | 22.8326 |
| | 69 | 11.6077 | 17.6246 | 22.5527 | 22.8484 |
| | 70 | 11.6053 | 17.6805 | 22.5946 | 22.8884 |
| | 71 | 11.5902 | 17.7312 | 22.6045 | 22.9085 |
| | 72 | 11.5765 | 17.7652 | 22.6143 | 22.9191 |
| | 73 | 11.5653 | 17.8001 | 22.6336 | 22.9308 |
| | 74 | 11.5661 | 17.8369 | 22.6508 | 22.9465 |
| 75 | 11.5713 | 17.8536 | 22.6496 | 22.9483 | |
| | 60 | 14.4388 | 14.4389 | 23.5483 | 23.5483 |
| | 61 | 14.4202 | 18.6715 | 23.467 | 24.0956 |
| | 62 | 14.5356 | 18.8573 | 23.6351 | 24.1228 |
| | 63 | 14.5459 | 18.8492 | 23.7858 | 24.1909 |
| | 64 | 14.8294 | 18.7892 | 23.6896 | 24.1648 |
| | 65 | 15.0327 | 18.8262 | 23.7857 | 24.2946 |

续表 3

| Ratio | Frame | PSNR (dB) | | | |
|-------|-------|-----------|---------------|---------|----------------|
| | | GPSR | Improved GPSR | RCoS | Our algorithms |
| 0.4 | 66 | 15.2115 | 18.8567 | 23.8569 | 24.3678 |
| | 67 | 15.2954 | 18.9193 | 23.9176 | 24.4281 |
| | 68 | 15.2801 | 18.9714 | 23.9398 | 24.4404 |
| | 69 | 15.2179 | 19.0205 | 23.9601 | 24.4724 |
| | 70 | 15.2017 | 19.0919 | 23.9904 | 24.5001 |
| | 71 | 15.1675 | 19.1489 | 24.0213 | 24.5359 |
| | 72 | 15.1085 | 19.1883 | 24.0156 | 24.5342 |
| | 73 | 15.0388 | 19.2257 | 24.0398 | 24.5538 |
| | 74 | 15.0020 | 19.2670 | 24.0524 | 24.5563 |
| | 75 | 15.0149 | 19.2833 | 24.0516 | 24.5579 |

补充材料 图 S2-S4. 本文的补充材料见网络版 info.scichina.com. 补充材料为作者提供的原始数据, 作者对其学术质量和内容负责.

参考文献

- Zhou H C, Luo J C. High Resolution Satellite Remote Sensing Image Geo Computation. Beijing: Science Press, 2009 [周虎成, 骆剑承. 高分辨率卫星遥感影像地学计算. 北京: 科学出版社, 2009]
- Luo J S, Zhou M, Sun L. Hyperspectral Remote Sensing Image Data Compression. Beijing: National Defence Industry Press, 2011 [罗建树, 周敏, 孙蕾. 高光谱遥感图像数据压缩. 北京: 国防工业出版社, 2011]
- Yu G, Vladimirova T, Sweeting M N. Image compression systems on board satellites. Acta Astronautica, 2009, 64: 988–1005
- Wu Q, Wang Z Y, Zhan Q. Discussion on the onboard compression methods of multi-spectral image. Remote Sens Appl, 2010, 25: 89–95 [吴强, 王智勇, 冉琼. 多光谱影像星上压缩方法探讨. 遥感应用, 2010, 25: 89–95]
- Liu H Y, Wu C K, Lv P, et al. Compressed hyperspectral image sensing reconstruction based on interband prediction and joint optimization. J Eletro Inform Technol, 2011, 33: 2248–2252 [刘海英, 吴成柯, 吕沛, 等. 基于谱间预测和联合优化的高光谱压缩感知图像重构. 电子与信息学报, 2011, 33: 2248–2252]
- Shao W Z, Wei Z H. Advances and perspectives on compressed sensing theory. J Image Graph, 2012, 17: 1–12 [邵文泽, 韦志辉. 压缩感知基本理论: 回顾与展望. 中国图象图形学报, 2012, 17: 1–12]
- Donoho D L. Compressive sensing. IEEE Trans Inform Theory, 2006, 52: 1289–1306
- Candès E J, Wakin M B. An introduction to compressive sampling. IEEE Signal Process Mag, 2008, 25: 14–20
- Salam A, Fawzy A, Shaker, N. High performance compressed sensing MRI image reconstruction. In: Proceeding of International Conference on Radio Science. Cairo: Radio Science Conference (NRSC), 2012. 627–631
- Yang S Y, Jin H H, Wang M, et al. Data-driven compressive sampling and learning sparse coding for hyperspectral image classification. IEEE Geosci Remote Sens Lett, 2014, 11: 479–483
- Yang S Y, Cheng K, Wang M, et al. High resolution range-reflectivity estimation multiple radar targets via compressive sampling and memetic algorithm. Inform Sci, 2013, 252: 144–156
- Yang S Y, Jin H H, Yang L X, et al. Compressive sensing-inspired dual-sparse SLFNN for hyperspectral imagery classification. IEEE Geosci Remote Sens Lett, 2014, 11: 220–224
- Yang S Y, Sun Y X, Chen Y G, et al. Structural similarity regularized and sparse coding based super-resolution for medical images. Biomed Signal Process Control, 2012, 7: 579–590
- Hou Y, Zhang Y N. Effective hyperspectral image block compressed sensing using thress-dimensional wavelet transform. In: Proc IEEE Int Conf Geosci Remote Sens Symposium, 2014. 2973–2976

- 15 Eason D, Andrews M. Compressed hyperspectral image recovery via total variation regularization assuming linear mixing. In: Proceedings of IEEE International Conference on Image Process, Paris, 2014. 620–624
- 16 Zhang J, Zhao D, Zhao C, et al. Image compressive sensing recovery via collaborative sparsity. IEEE J Emerg Select Top Circuits Syst. 2012, 2: 380–391
- 17 Wu X, Zhang X, Wang J. Model-guided adaptive recovery of compressive sensing. In: Proceedings of IEEE Data Compress Conference, Snowbird. USA: IEEE, 2009. 123–132
- 18 Dong W S, Zhang L, Shi G M, et al. Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization. IEEE Trans Image Process, 2011, 20: 1838–1856
- 19 Mun S, Fowler J E. Block compressed sensing of images using directional transforms. In: Proceedings of IEEE Int Conf Image Process, Cairo, 2009: 3021–3024
- 20 Jia Y B, Feng Y, Yuan X L, et al. Block compressed sensing sampling and reconstruction using spectral prediction for hyper spectral images. J Appl Sci, 2014, 32: 281–284 [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. 应用科学学报, 2014, 32: 281–284]
- 21 Candès E J. The restricted isometry property and its implications for compressed sensing. CR Math Acad Sci, Paris, 2008, 346: 589–592
- 22 Wu B. Research on measurement matrix for compressive sensing. Degree Thesis. Xi'an: Xidian University, 2012 [吴赟. 压缩感知测量矩阵的研究. 学位论文. 西安: 西安电子科技大学, 2012]
- 23 Shi G M, Liu D H, Gao D H, et al. Advances in theory and application of compressed sensing. Acta Electronica Sinica, 2009, 37: 1070–1081 [石光明, 刘丹华, 高大化, 等. 压缩感知理论及其研究进展. 电子学报, 2009, 37: 1070–1081]
- 24 Jiao L C, Yang S Y, Liu F, et al. Development and prospect of compressive sensing. Acta Electronica Sinica, 2011, 39: 1651–1662 [焦李成, 杨淑媛, 刘芳, 等. 压缩感知回顾与展望. 电子学报, 2011, 39: 1651–1662]
- 25 Liu H Y, Li Y S, et al. Compressed hyperspectral image sensing based on interband prediction. J Xidian University, 2011, 38: 37–43 [刘海英, 李云松, 等. 一种高重构质量低复杂度的高光谱图像压缩感知. 西安电子科技大学学报, 2011, 38: 37–43]
- 26 Goldstein T, Osher S. The split Bregman algorithm for L1 regularized problems. SIAM J Imag Sci, 2009, 2: 323–343
- 27 Cai J, Osher S, Shen Z. Split Bregman methods and frame based image restoration. Multiscale Model Simulation, 2009, 8: 337–369
- 28 Zhang J, Zhao D B. Split Bregman iteration based collaborative sparsity for image compressive sensing recovery. Intell Comput Appl, 2014, 4: 60–64 [张健, 赵德斌. 基于分离 Bregman 迭代协同稀疏性的图像压缩感知恢复算法. 智能计算机与应用, 2014, 4: 60–64]
- 29 Huang J, Zhang S, Li H. Composite splitting algorithms for convex optimization. Comput Vision Image Understand, 2011, 115: 1610–1622
- 30 Figureiredo M A T, Nowak R D, Wright S J. Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems. IEEE J Select Top Signal Process, 2007, 4: 586–597
- 31 Ji Z X, Kong F Q. Hyperspectral image compressed sensing based on linear filter between bands. Acta Photonica Sinica, 2012, 41: 82–86 [计振兴, 孔繁镝. 基于谱间线性滤波的高光谱图像压缩感知. 光子学报, 2012, 41: 82–86]

Hyperspectral image compressed sensing model based on the collaborative sparsity of the intra-frame and inter-band

Xianghai WANG^{1,2}, Haiying SONG¹, Chuanming SONG^{1*} & Jingzhe TAO²

1 College of Computer and Information Technology, Liaoning Normal University, Dalian 116029, China;

2 Liaoning Key Laboratory of Physical Geography and Geomatics, Liaoning Normal University, Dalian 116029, China

*E-mail: chmsong@lnnu.edu.cn

Abstract This paper proposes a new hyperspectral image compressed sensing model (hyperspectral image col-

laborative sparsity measure, HICoSM) based on the collaborative sparsity of the intra-frame and inter-band, which utilizes the strong correlation of the inter-band. The sparsity mining of the proposed model includes three aspects: the local smoothness of the intra-frame; the nonlocal self-similarity of the inter-band that measures the detail information of the texture and the edge; and the correlation prediction of the inter-band, which specifically utilizes the prior band via the least squares linear prediction method to predict the current band, and then calculates the best predicting residual to realize the inter-band sparsity measurement. Further, we describe the numerical procedure of the proposed model. A large number of simulation experiments show that the HICoSM can make an effective sparsity measurement for all the intra-frames. Simultaneously, it can sufficiently mine and measure the sparsity of the inter-band of a hyperspectral image and effectively improve the decoding quality of each band in the CS recovery stage.


Keywords hyperspectral images, compressed sensing, collaborative sparse, spectral correlation, optimal solution, predicting residual



Xianghai WANG was born in 1965. He received a Ph.D. degree from JiLin University, JiLin, in 1999. Currently, he is a professor with the College of Computer and Information Technology at Liaoning Normal University, Dalian. His research interests include computer graphics and multimedia information processing.



Haiying SONG was born in 1988. She received the M.E. degree in Computer Science and Technology from Liaoning Normal University, Dalian. She is studying for a B.S. degree from Liaoning Normal University, Dalian. Her research interest includes image coding.



Chuanming SONG was born in 1980. He received a Ph.D. degree in Computer Science and Technology from Nanjing University, Nanjing. He is an associate professor with the College of Computer and Information Technology at Liaoning Normal University, Dalian. His research interests include image and video coding, and digital watermarking of multimedia.



Jingzhe TAO was born in 1987. He is studying for a Ph.D. degree at the College of Urban and Environmental Science, Dalian. His research interests include hyperspectral image fusion and super-resolution.