



# 高光谱图像光谱维结构相关性及稀疏重建模型

王相海<sup>1,2\*</sup>, 王顺<sup>2</sup>, 谢释铖<sup>2</sup>, 李业涛<sup>2</sup>, 陶兢喆<sup>1</sup>, 宋传鸣<sup>2\*</sup>

1. 辽宁师范大学地理科学学院, 大连 116029

2. 辽宁师范大学计算机与信息技术学院, 大连 116029

\* 通信作者. E-mail: xhwang@lnnu.edu.cn, chmsong@163.com

收稿日期: 2019–10–16; 修回日期: 2020–01–02; 接受日期: 2020–02–18; 网络出版日期: 2021–02–24

国家自然科学基金项目 (批准号: 41671439, 41971388) 和辽宁省高等学校创新团队支持计划 (批准号: LT2017013) 资助

**摘要** 高光谱图像 (HSI) 的高维度、高冗余等特性给其传输和处理带来了极大的挑战. 近年来基于压缩感知的 HSI 重建受到重视并成为一前沿问题, 在这一领域中有效挖掘 HSI 的稀疏先验成为提高其重建质量的一个关键. 本文首先定义了 HSI 波段组的“光谱维面”, 并以此为切入点对 HSI 光谱维的结构相关性进行研究, 获得了如下结论: 一是 HSI 光谱维面的纹理分布较空间域更为简单和均匀, 且其纹理的对比度低、平稳度高, 更容易被稀疏表达, 二是在 HSI 光谱维面, 与参考块相邻的搜索区域内存在着一定数量的与参考块具有较高相似度的光谱曲线块; 进一步确定了基于光谱维面的 HSI 光谱维结构相关性的涵义, 并提出了相应的稀疏测量模型; 在此基础上, 通过整合空间维非局部相关性与光谱维结构相关性的稀疏表示, 提出了稀疏模型 S-SCoSM, 并以其为稀疏约束先验构建了 HSI 的稀疏重构模型. 大量实验表明, 所提出的稀疏模型 S-SCoSM 从空间维和光谱维两个角度更深层次地挖掘了 HSI 的相关性, 获得了更为充分和有效的 HSI 稀疏约束先验, 使 HSI 的重构质量得到进一步提升, 在有效提高重构波段图像空间信息质量的同时, 很好地保持了波段组的光谱属性.

**关键词** 高光谱图像, 光谱维面, 光谱维结构相关性, 联合稀疏, 稀疏重建, 波段组

## 1 引言

高光谱 (hyperspectral, HS) 传感器在获取地物空间遥感图像的同时可通过不同电磁波段获取近似连续的地物光谱曲线, 大大提高了对地物的分类和识别能力, 因而自诞生以来便受到地质勘探、大气环境、环境检测、海洋遥感等多个领域的特别关注<sup>[1,2]</sup>. 然而高光谱图像 (hyperspectral image, HSI) 所具有的大数据量、强波段间相关性和多冗余信息等也给其传输、处理和存储等实际应用带来巨大挑战, 如何有效地对其信息进行组织、挖掘系数间的相关性并捕捉其内在特性对于提高 HSI 信息处理的质量便显得十分重要<sup>[3]</sup>. 压缩感知 (compressive sensing, CS) 理论<sup>[4~7]</sup> 的出现为解决上述问题提

**引用格式:** 王相海, 王顺, 谢释铖, 等. 高光谱图像光谱维结构相关性及稀疏重建模型. 中国科学: 信息科学, 2021, 51: 449–467, doi: 10.1360/SSI-2019-0229  
Wang X H, Wang S, Xie S C, et al. Spectral dimensional correlation and sparse reconstruction model of hyperspectral images (in Chinese). Sci Sin Inform, 2021, 51: 449–467, doi: 10.1360/SSI-2019-0229

供了思路, 即依据 HSI 在特定字典基下所表现的可压缩特性 [8], 通过将采样与压缩过程集成来获取少量的混合信息样本, 进而在先验稀疏特性约束下, 通过优化过程高概率地恢复出原始 HSI. 近年来基于 HSI 的稀疏表示和重建成为一重要的研究领域 [2,9], 人们结合 HSI 的自身特点对 HSI 的先验稀疏特性进行挖掘, 提出了许多有效的稀疏表示方法. 为了有效发掘 HSI 本身的特性, 文献 [10,11] 对 HSI 空 - 谱结构的非局部相似性和波段图像空间非局部相似性进行了研究, 获得了 HSI 图像具有较强的结构相似性特征, 能够更好地将噪声和非噪声信息进行分离; 但是这种方法依旧是停留在二维单波段图像的结构上, 没有很好地从 HSI 本身三维张量特性进行探究, 破坏了 HSI 的三维结构特性. 为了更好地发掘张量特性, 文献 [12] 采用基于张量块稀疏字典学习和类相关的块稀疏表示方法, 很好地保持了 HSI 的张量特性; 然而, HSI 对光谱信息的要求较高, 该方法对光谱信息的保持还需加强. 进一步, 为了提升对光谱信息先验约束的使用, 文献 [13] 利用 HSI 的光谱稀疏性和光谱非局部自相似性, 提出一种基于像素组非局部稀疏表示的 HSI 与同一场景多光谱图像 (multispectral image, MSI) 的融合方法, 用以增强 HSI 的空间分辨率. 可见在 HSI 各种特性的挖掘上, 前人做了大量的工作. 将前面各个特性应用于 HSI 的稀疏重建领域, 便衍生出各类 HSI 重构算法. 为了保持地物的重构效果, 文献 [14] 基于地物的先验光谱信息构建冗余稀疏字典, 利用该字典建立 HSI 压缩感知模型, 并结合空间全变分 (total variation, TV) 约束实现 HSI 重建, 在一定程度上提升了空间和光谱的重构精度, 但重建方案对成像区域光谱的先验信息具有一定的依赖性. 同样是为了保持结构特性, 与稀疏先验不同, 文献 [15] 对 HSI 矩阵表示的低秩特性进行挖掘, 将其与 HSI 的稀疏特性相结合提出一种稀疏和低秩联合约束的 HSI 重构算法, 有效地保持了重构 HSI 的结构相似性. 但是, 重建方法需要对图像进行奇异值分解 (singular value decomposition, SVD), 需要较大的计算量, 时间复杂度较高. 为了降低时间复杂度, 利用 HSI 图像的谱间相关性, 文献 [16] 提出一种基于预测的 HSI 稀疏重建算法, 该算法利用 k 均值聚类算法对 HSI 进行谱间分组, 通过优化选取各谱间组的关键波段, 并以此对组内的其他波段进行线性预测, 对关键波段和预测后的残差图像进行正交匹配追踪算法实现重建, 该重建算法对噪声具有一定的鲁棒性. 进一步, 从 HSI 整体数据组织形式上对空间和光谱特性进行发掘, 文献 [17] 分别采用基于张量的 Tucker 分解和基于加权的 3D 全变分, 对 HSI 的整体空 - 谱相关性和局部光滑结构进行刻画, 以此为约束构建了稀疏重建算法, 更加丰富了对 HSI 数据特性的表现. 此外我们在前期工作 [18] 中对文献 [19] 自然图像稀疏测量方法进行了推广, 在挖掘各波段图像空间结构信息相关性的基础上, 通过引入相邻波段图像间的预测误差正则项约束来提高对 HSI 谱间稀疏表示能力. 拓展这种相关性到整个波段上, 将波段图像空间非局部相似块推广到整个波段组, 文献 [20] 对 HSI 的多维度相关性进行了研究, 将 HSI 划分为若干“波段组”, 提出了一种“整体非局部相关”的相关性挖掘方案, 并将其作为稀疏先验应用于 HSI 的稀疏重建模型中, 使得 HSI 的重构效果得到了大大提升. 总体而言目前 HSI 稀疏重建研究领域还处于发展之中, HSI 稀疏表现能力还不是很强, 特别是关于光谱维稀疏挖掘方案还不是很多, 同时 HSI 稀疏重建的光谱信息保持还有待进一步提高.

本文对 HSI 的光谱维相关性进行研究, 提出一种基于“光谱维面”的结构相关性稀疏度量方案, 在此基础上设计一种基于 HSI 空间维非局部相关性和光谱维结构相关性的 HSI 稀疏重建模型. 主要工作包括: (1) 探讨了 HSI 波段组空间维局部相关性在光谱维上的表现形态, 表明波段图像空间维同一列 (或行) 上的相邻像元在光谱维上具有相似的光谱曲线, 为了捕捉光谱维的这种结构相关性, 本文定义了 HSI 波段组的“光谱维面”, 统计研究表明, 与空间维的波段图像相比, 光谱维面具有简单、规则和均匀的纹理分布, 从而为有效挖掘 HSI 的结构相关性奠定了基础; (2) 对基于 HSI 光谱维面的结构相关性进行了研究, 提出了一种基于 3D 相似“光谱曲线块”组的相关性稀疏度量方案; (3) 提出一种协同光谱维结构相关性和空间维非局部相关性为稀疏先验的 HSI 稀疏重建模型, 该模型提高了




图 1 (网络版彩图) HSI 谱域光谱维面示意图

Figure 1 (Color online) Schematic diagrams of HSI spectral dimension plan

波段组 HSI 的重构质量, 且能够更好地保持各地物光谱曲线的恢复效果。

## 2 HSI 光谱维结构相关性研究

从空间域上看, HSI 在每一个波段的图像都是当前波段下地物的光谱反射率, 每一个像素在相邻列和行像元之间也存在着一定的相关性, 通常称之为空间维的局部相关性<sup>[18, 19]</sup>。这种空间维的局部相关性理论上表现为相邻的像元在光谱维上具有相似的光谱曲线, 本文对由这些相似的光谱曲线所形成的光谱维结构相关性进行研究。为此定义了如下 HSI 波段组的“光谱维面”, 这里的“波段组”是指对 HSI 按波段的自然先后顺序划分的组, 使得分在同一波段组中的波段图像间具有较高的“光谱相关系数”<sup>[1]</sup>。

对于三维 HSI 波段组, 将各波段图像空间维相同列组成的面称为该列所对应的“光谱维面 (spectral dimension plan)” (参见图 1)。

### 2.1 HSI 空间维局部相关像元的光谱维面表现

本文利用光谱角评价指标来度量分析 HSI 空间维同一列局部相关像元对应光谱曲线的相关性情况。光谱角的计算公式如下所示:

$$\theta_{a,b} = \cos^{-1} \left( \frac{\sum_{i=1}^S t_{a,i} \times t_{b,i}}{\sqrt{\sum_{i=1}^S t_{a,i}^2 \times \sum_{i=1}^S t_{b,i}^2}} \right) \times \frac{180}{\pi}, \quad (1)$$

其中  $S$  为 HSI 波段组的波段数,  $\mathbf{t}_a = (t_{a,1}, t_{a,2}, \dots, t_{a,S})$  和  $\mathbf{t}_b = (t_{b,1}, t_{b,2}, \dots, t_{b,S})$  分别为同一光谱维面对应的  $a, b$  行光谱向量 (参见图 1),  $\theta_{a,b}$  为  $\mathbf{t}_a, \mathbf{t}_b$  的光谱角 (单位为度), 光谱角越大,  $\mathbf{t}_a, \mathbf{t}_b$  相关性越弱, 反之亦然。

图 2 为 AVIRIS 拍摄的高光谱 Cuprite 波段组 (共 224 个波段) 中第 9, 61, 113 和 165 列所对应的“光谱维面”, 表 1 给出了每一光谱维面中若干光谱向量 (称为“参考光谱向量”) 与其上、下相邻光谱向量 (称为“测试光谱向量”) 的光谱角统计结果, 这里光谱向量选择 15 波段长进行构建。




图 2 Cuprite HSI 部分列对应的光谱维面

Figure 2 The partial column corresponding spectral dimension plan of the Cuprite HSI. (a) The 9th column; (b) the 61st column; (c) the 113rd column; (d) the 165th column

表 1 光谱维面中光谱曲线与其相邻光谱曲线的光谱角统计

Table 1 Spectral angle statistics of spectral curve and its adjacent spectral curve in spectral dimension plan

Spectral dimension plan number	Reference spectral vector number $k$	Spectral angle between reference spectral vector $t_k$ and adjacent spectral vector $t_{k\pm i}$ ( $i = 1, 2, 3, 4$ )								
		$t_{k-4}$	$t_{k-3}$	$t_{k-2}$	$t_{k-1}$	$t_k$	$t_{k+1}$	$t_{k+2}$	$t_{k+3}$	$t_{k+4}$
9	50	0.73	0.55	0.94	0.37	0	0.44	0.68	0.67	0.59
	100	1.61	0.75	1.48	0.87	0	0.31	1.81	1.01	1.56
	150	0.4	1.49	1.8	0.44	0	0.45	0.65	0.92	0.71
	200	0.57	1.08	0.55	0.54	0	1.14	0.58	0.53	0.78
61	50	0.9	0.76	0.77	0.6	0	0.77	1.12	1.18	1.44
	100	0.94	1.32	1.07	0.89	0	0.85	0.73	0.96	1.28
	150	1.11	0.78	0.63	0.71	0	0.58	0.36	0.43	0.62
	200	1.96	1.49	1.12	1.34	0	0.68	1.73	1.26	1.1
113	50	1.53	2.33	1.81	0.99	0	0.66	1	1.14	1.52
	100	2.53	0.62	1	0.67	0	0.76	0.54	0.57	1.61
	150	0.86	1.56	0.66	0.94	0	0.63	1.05	1.41	1.39
	200	2.24	1.48	1.02	1.44	0	2.81	2.6	3.81	3.71
165	50	1.45	1.58	0.65	1.32	0	1.45	0.95	2.57	1.78
	100	1.37	1.24	0.98	1.23	0	2.23	0.89	0.7	1.12
	150	1.52	0.89	1.27	0.8	0	0.89	1.6	0.95	1.19
	200	0.97	0.66	0.9	0.81	0	1.82	1.47	1.42	0.78

从表 1 可以看出, 在光谱维面中各行对应的光谱向量与其上、下相邻光谱向量具有较小的光谱角, 反应在光谱曲线的形状上为光谱维面中相邻光谱曲线的形状具有相似特性 (参见图 3). 图 3 中可以明显得看出相邻光谱曲线走势相似, 这种相似性使得整体的光谱维面纹理结构都为沿光谱维度纹理方向, 纹理分布形式比较简单, 尤其使得在局部的相邻光谱曲线所组成的光谱曲线块结构相关性较高, 具体分析参见 2.2 小节.

## 2.2 光谱维面纹理特征分析

为了对光谱维面的纹理结构进行定量分析并与空间维波段图像进行对比, 我们选取了如图 4 所示




图 3 (网络版彩图) 第 9 列光谱维面部分相邻光谱曲线段

Figure 3 (Color online) Part of the adjacent spectral curve segment in the 9th column spectral dimension




图 4 波段图像以及光谱维面

Figure 4 The band image and the spectral dimension plan. (a) The 90th band image (Pavia); (b) the 90th column spectral dimension plan (Pavia); (c) the 95th band image (Chikusei); (d) the 95th column spectral dimension plan (Chikusei)

的高光谱 Pavia 波段组的空间维第 90 波段图像和第 90 列光谱维面, 以及 Chikusei 波段组的空间维第 95 波段和第 95 列光谱维面. 随机从各自的空间以及光谱维图像中选取 500 块大小为  $8 \times 8$  的图像块, 计算沿着光谱维度方向的灰度共生矩阵; 进一步计算统计了二图像的对比度、相关性、灰度共生矩阵的熵值、平稳度和二阶矩, 统计结果参见图 5 和 6.

图 5(a) 和 (b) 分别给出了 Pavia 波段组光谱维面和波段图像的对比度和相关性的比较, 可以看出光谱维面中大部分图像块具有较低的对比度和较高的相关性; 图像块具有较浅的“沟纹”, 纹理分布较为均匀, 且方向都为沿着光谱维度方向, 图像块内的信息相关性更强. 图 5(c) 为光谱维面和波段图像熵值的比较, 可以看出光谱维面中的图像块总体表现出具有较高的熵值, 即这些图像块包含更多的信息量. 图 5(d) 和 (e) 为光谱维面和波段图像灰度共生矩阵平稳度以及二阶矩指标的对比, 同样光谱维面具有较高的数值表现, 表明光谱维面的共生矩阵具有更为紧凑集中的系数分布.

图 6 分别给出了 Chikusei 波段组光谱维面和波段图像的相关评价指标的比较, 整体表现的趋势与 Pavia 波段组相似, 在此不再赘述. 综合上面的统计指标分析, 可以看出在 HSI 普遍存在光谱维面的局部图像块具有简单、均匀和规则的纹理分布, 其信息紧凑、对比度低、平稳度高. 光谱维面的这些特征为有效挖掘 HSI 的相关性奠定了很好的基础.



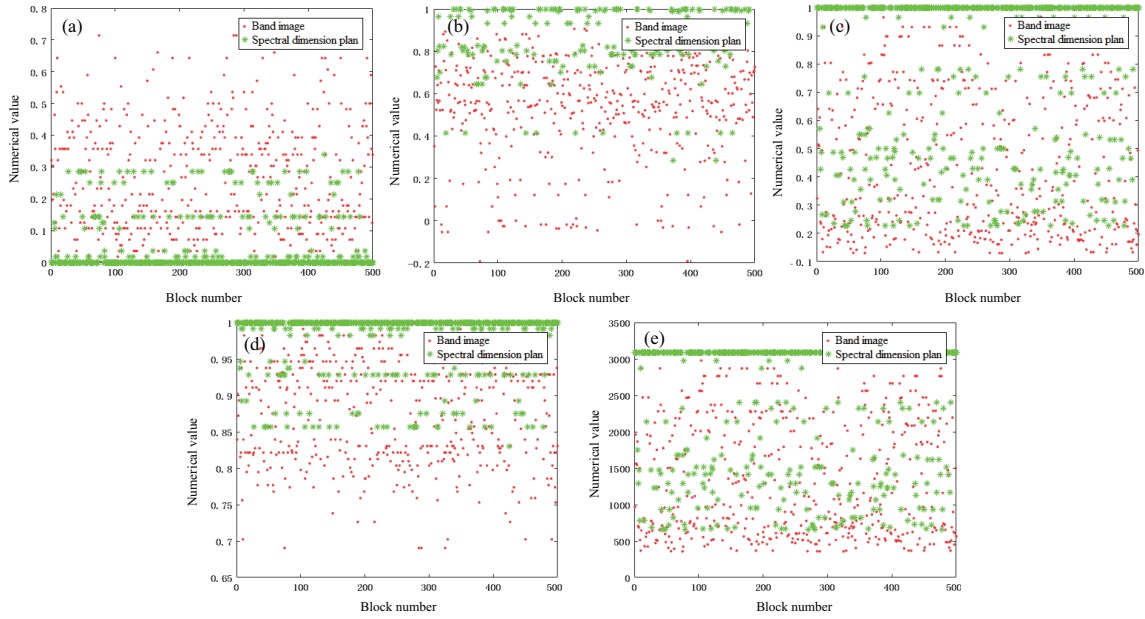


图 5 (网络版彩图) Pavia 波段图像与光谱维面纹理特征比较

Figure 5 (Color online) Comparison of texture features about the Pavia band image and the spectral dimension plan. (a) Contrast; (b) inverse different moment; (c) entropy; (d) homogeneity; (e) angular second moment

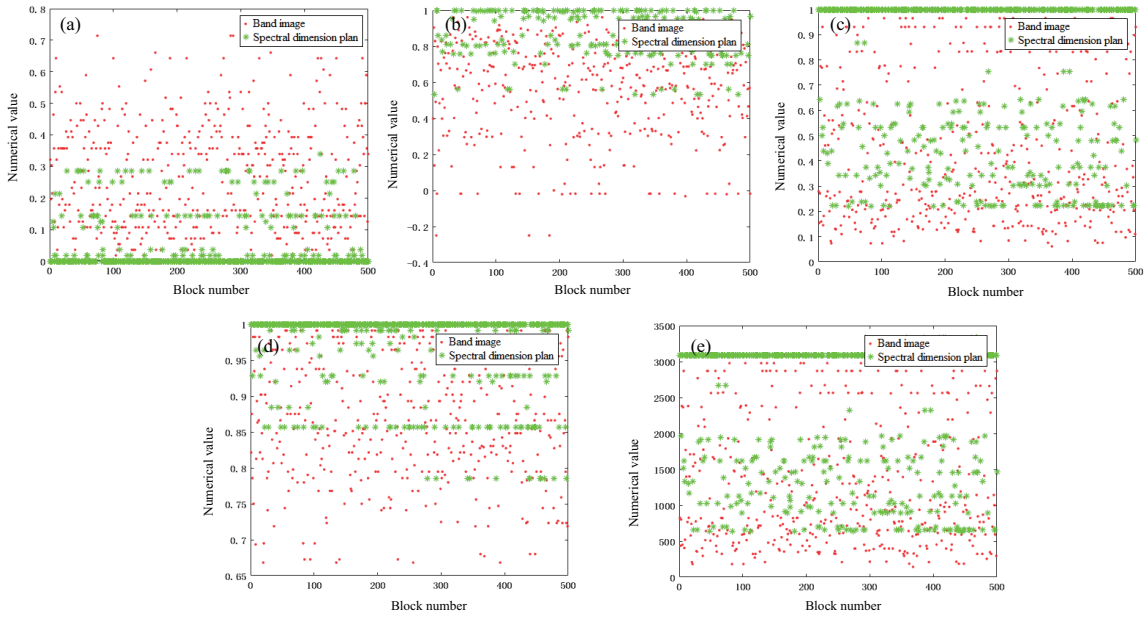


图 6 (网络版彩图) Chikusei 波段图像与光谱维面纹理特征比较

Figure 6 (Color online) Comparison of texture features about the Chikusei band image and the spectral dimension plan. (a) Contrast; (b) inverse different moment; (c) entropy; (d) homogeneity; (e) angular second moment

### 2.3 光谱维面结构相关性

首先定义“光谱曲线块”: 对于光谱维面上任意一点  $(m, n)$ , 选取以其为中心, 上、下各相邻  $H$  行

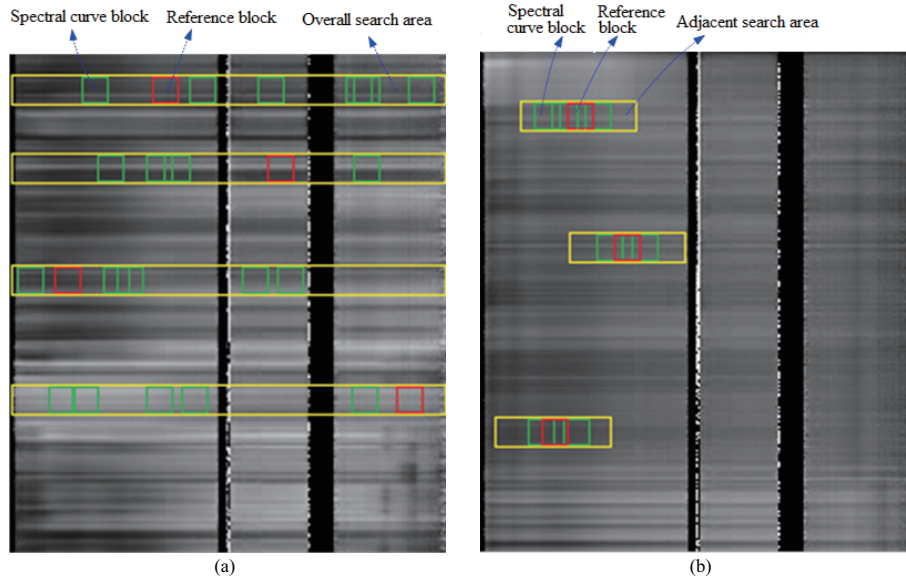


图 7 (网络版彩图) 光谱维面中搜索范围、光谱曲线块和参考块示意图

**Figure 7** (Color online) Search range, spectral curve block and reference block schematic in the spectral dimension plan. (a) Overall search area; (b) adjacent search area

光谱曲线段所形成的长、宽分别为  $S$  和  $2H + 1$  的矩形区域  $S \times (2H + 1)$  (称为“整体搜索区域”, 其中  $S$  为 HSI 波段组的波段数), 定义以  $(m, j)$  为中心, 长、宽分别为  $2K + 1$  和  $2H + 1$  的矩形块  $(2K + 1) \times (2H + 1)$  为“光谱曲线块”, 记为  $\mathbf{B}_{m,j}$ , 其中  $j \in \{K + 1, K + 2, \dots, S - K\}$ ; 以  $(m, n)$  为中心的光谱曲线块  $\mathbf{B}_{m,n}$  被称为“参考块”. 具体参见图 7(a). 本文实验中选取  $H = 4, K = 4$ .

由于相邻光谱曲线具有较高的相关性, 这样由其组成的“光谱曲线块”结构简单且相关性高, 本文采用了沿光谱维度、由相邻光谱曲线所构成的“整体搜索区域”(参见图 7) 进行光谱曲线块的搜索, 一方面可以保证获得高相关性的光谱曲线块, 另一方面也符合高光谱图像成像的物理含义.

进一步, 为了探究光谱维面上的结构相关性, 本文对整体搜索区域内类似于参考块  $\mathbf{B}_{m,n}$  的光谱曲线块  $\mathbf{B}_{m,j}$  情况进行了统计, 其中相似度采用如式 (2) 所示的块间平均欧式距离获得.

$$d(\mathbf{B}_{m,n}, \mathbf{B}_{m,j}) = \frac{\sqrt{\sum_{h=-H}^H \sum_{k=-K}^K (\mathbf{B}_{m,n}(m+h, n+k) - \mathbf{B}_{m,j}(m+h, j+k))^2}}{(2H+1) \times (2K+1)}. \quad (2)$$

一般而言  $d(\mathbf{B}_{m,n}, \mathbf{B}_{m,j})$  越小, 表示  $\mathbf{B}_{m,n}$  与  $\mathbf{B}_{m,j}$  的相似程度越高 [21, 22]. 表 2 对 EO-1 卫星、Hyperion 光谱仪拍摄的大连地区海岸带 HSI 第 103 列对应的光谱维面上的结构相关性的存在情况进行了统计, 给出了与参考块相关性程度按由高到低排列的前 5 个光谱曲线块的相关信息 (参考块自身除外), 其中整体搜索区域共包含 155 个波段 (即  $S$  为 155), 参考块与相似光谱维曲线块之间的距离为两块中心点之间的位置距离. 从统计结果可以看出, 每一个参考块在搜索区域内均存在着一定数量相关程度较高的光谱曲线块, 表现出了很好的结构相关特性.

为了考察上述参考块与光谱曲线块相关性的稳定性, 图 8 分别给出了以 (72, 80) 和 (203, 76) 为中心的参考块在整体搜索范围内与光谱曲线块的相关性统计曲线, 可以看出, 参考块与光谱曲线块所具有的这种强相关性在一定区域范围内是平稳的, 尽管不排除在距离参考曲线块较远的位置上存在一些相关性较高的光谱曲线块, 但大多数高相关的光谱曲线块位于参考曲线块的相邻区域内, 为了提升

表 2 大连地区海岸带 HSI 光谱维面中参考块与光谱曲线块的相似情况统计

Table 2 Statistics on reference blocks and similar spectral curve blocks in the HSI spectral dimension of the coastal zone in Dalian

		Reference block location						
		(72, 80)	(120, 87)	(37, 48)	(106, 34)	(142, 73)	(203, 76)	
Similar block information in the overall search area	1	Location	(72, 75)	(120, 77)	(37, 37)	(106, 40)	(142, 81)	(203, 80)
		Similarity	0.0231	0.0327	0.0578	0.0222	0.0166	0.0235
		Distance from reference block	5	10	11	6	8	4
	2	Location	(72, 74)	(120, 65)	(37, 57)	(106, 39)	(142, 80)	(203, 81)
		Similarity	0.0259	0.0331	0.0579	0.0236	0.0193	0.0238
		Distance from reference block	6	22	9	5	7	5
	3	Location	(72, 76)	(120, 82)	(37, 79)	(106, 41)	(142, 82)	(203, 86)
		Similarity	0.0277	0.0347	0.0591	0.0244	0.02	0.0252
		Distance from reference block	4	5	31	7	9	10
	4	Location	(72, 73)	(120, 81)	(37, 54)	(106, 38)	(142, 85)	(203, 82)
		Similarity	0.0289	0.0349	0.0594	0.0255	0.021	0.0262
		Distance from reference block	7	6	6	4	9	6
	5	Location	(72, 72)	(120, 80)	(37, 58)	(106, 42)	(142, 84)	(203, 84)
		Similarity	0.031	0.035	0.0597	0.0276	0.0212	0.0264
		Distance from reference block	8	7	10	8	11	8

计算效率, 本文仅在与参考块“相邻搜索区域”内对光谱曲线块进行考察 (参见图 7(b)), 实验中选取的相邻搜索区域的长度为 15.

### 3 联合光谱维结构相关性和空间维非局部相关性的 HSI 重构模型

#### 3.1 分块 HSI 压缩感知分析

设 HSI 波段组为  $\mathbf{X}_{p \times q \times s} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_s)$  (其中  $p \times q$  为波段图像大小,  $s$  为波段数), 将波段  $\mathbf{x}_i$  ( $i \in \{1, 2, \dots, s\}$ ) 按照步长  $L$  分成大小为  $W \times W$  的图像块. 对于当前波段中的第  $j$  个图像块  $\mathbf{x}_j$ ,  $j$  表示图像块的序数 ( $j = 1, 2, \dots, (p - W + L) \times (q - W + L) / (L \times L)$ ), 将其按列为  $W^2 \times 1$  的一维向量进行堆叠. 令  $m = W^2$ , 该一维向量可由含有  $n$  个原子的字典  $\mathbf{D} \in \mathbb{R}^{m \times n}$  表示为  $\mathbf{x}_j = \mathbf{D}\boldsymbol{\alpha}_j$  ( $\boldsymbol{\alpha}_j \in \mathbb{R}^n$ ). 为了描述一个可表示为  $\mathbf{D}$  中原子稀疏线性组合的信号,  $\mathbf{D}$  须为一个过完备字典, 满足  $m < n$ , 此时可将一个  $K$  稀疏信号表示为

$$\mathbf{x}_j = \mathbf{D}\boldsymbol{\alpha}_j, \quad \|\boldsymbol{\alpha}_j\|_0 \ll K, \quad (3)$$

$\boldsymbol{\alpha}_j$  被称为  $\mathbf{x}_j$  的稀疏系数或稀疏编码,  $\|\boldsymbol{\alpha}_j\|_0$  称为稀疏度.

通过求解下列  $l_0$  最小化问题, 对稀疏系数集  $\boldsymbol{\alpha}_j$  进行刻画:

$$\min_{\boldsymbol{\alpha}} \|\boldsymbol{\alpha}_j\|_0 \quad \text{s.t.} \quad \mathbf{x}_j = \mathbf{D}\boldsymbol{\alpha}_j. \quad (4)$$

为了获得问题的唯一精确解, 通常用  $l_1$  范数替代  $l_0$  范数来获得原问题的一种凸松弛, 此时上述






图 8 (网络版彩图) 光谱曲线块与参考块的相关性统计曲线图

Figure 8 (Color online) Statistical graph of correlation between spectral curve blocks and reference blocks. Reference block centered on (a) (72, 80), (b) (203, 76)

问题转化为下列求解  $l_1$  范数最小化的问题:

$$\min_{\alpha} \|\alpha_j\|_1 \quad \text{s.t. } \mathbf{x}_j = \mathbf{D}\alpha_j. \quad (5)$$

考虑到 HSI 在形成过程中会受到多种噪声源的干扰, 这样在实际应用中  $\mathbf{x}_j = \mathbf{D}\alpha_j$  的约束也被松弛, 进而将稀疏表示问题整合为如下  $l_1$  范数正则化的最小化问题:

$$\min_{\alpha} \|\mathbf{x}_j - \mathbf{D}\alpha_j\|_2 + \lambda \|\alpha_j\|_1, \quad (6)$$

其中参数  $\lambda > 0$  用以协调保真项和稀疏正则项.

式 (6) 可拓展为式 (7) 的一般形式:

$$\min_{\alpha, \mathbf{D}} F_1(\mathbf{x}_j, \alpha_j, \mathbf{D}) + \lambda F_2(\alpha_j), \quad (7)$$

其中损失函数  $F_1$  用以衡量  $\mathbf{X}_j$  的重构误差, 损失函数  $F_2$  用以约束稀疏系数  $\alpha_j$  的稀疏度. 当  $\mathbf{D}$  为已知时, 上式仅对  $\alpha_j$  进行优化求解, 此时为稀疏系数的求解问题; 而当  $\mathbf{D}$  为未知时, 则上式转换为字典的学习问题.

由式 (7) 可以看出, 在 HSI 的稀疏表示模型中, 依据其自身特性挖掘并利用其相关性获得更加有效的稀疏先验约束, 对于提高模型的表现能力和重构图像质量特别重要.

### 3.2 HSI 空间维非局部相关及其稀疏测量

本文采用的 HSI 空间维非局部相关稀疏是指由 HSI 波段组中第 1 波段的非局部相似块, 以及其对应的其余各波段相同位置的所有块汇集在一起所构成的“整体非局部相似块”所形成的稀疏<sup>[20]</sup> (参见图 9). 具体形成途径和测量模型如下:

设对于  $\mathbf{x}_1$  中当前“基准块”大小为  $u \times v$  (本文实验中选取  $u = v = 8$ ), 按式 (2) 所示的两块间相似性度量公式, 在以其为中心的一定区域范围内按相似度由大到小搜索并选取前  $N$  个相似块  $\mathbf{E}_{c,1}$  ( $c \in [1, N]$  本文实验中选取  $N$  为 5); 进一步, 按  $\mathbf{E}_{c,1}$  相同位置、相同大小分别提取  $\mathbf{x}_r$  ( $r \in [2, S]$ ) 波段中的相似块  $\mathbf{E}_{c,r}$ , 并将其按照图 9 所示的顺序排列, 形成 3D 相似图像块组  $\mathbf{E}_z^{3D}$ , 其中  $z$  对应所选取的“基准块”序号; 对图像块组  $\mathbf{E}_z^{3D}$  进行“2Dwavelet+1Ddct”正交变换 (记为  $T_{3D}$ ), 即对空间维的

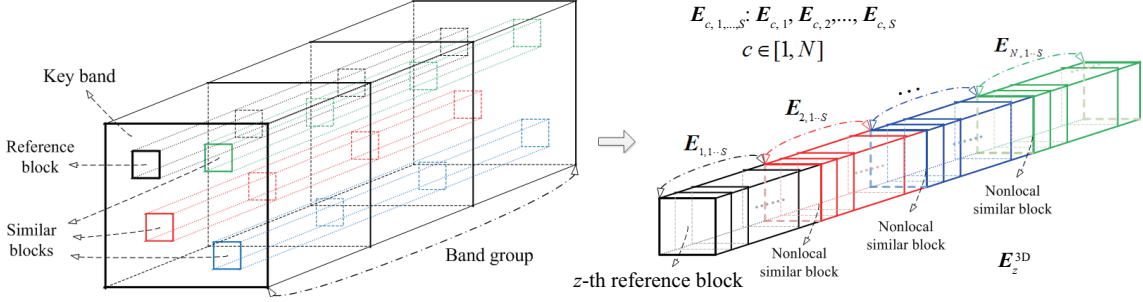


图 9 (网络版彩图) 高光谱图像整体非局部相关性示意图

Figure 9 (Color online) Global nonlocal correlation diagram of HSI

每一个 2D 图像块进行 2D 小波变换、对图像块间采用 1D 离散余弦变换, 并通过计算变换系数的稀疏度获得波段组整体非局部相关块的稀疏先验, 测量模型如下:

$$f_1(\mathbf{X}_{p \times q \times S}) \triangleq \|\Psi_{\text{NLoc-Spa-Bloc}}(\mathbf{X}_{p \times q \times S})\|_0 = \frac{\sum_{z=1}^{(p-u) \times (q-v)/N} (\|T_{3D}(\mathbf{E}_z^{3D})\|_0)}{(p-u) \times (q-v) \times u \times v \times S}, \quad (8)$$

其中  $(p-u) \times (q-v) \times u \times v \times S$  为归一化因子. 有关 HSI 空域非局部相关性稀疏的详细讨论请参见文献 [20].

### 3.3 HSI 光谱域结构相关性涵义及其稀疏测量

对于当前待处理的 HSI 波段组  $\mathbf{X}_{p \times q \times S} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_S)$ , 按照图 1 所示方式将其转换为对应的“光谱维面”表示形式:  $\mathbf{Y}_{p \times S \times q} = (y_1, y_2, \dots, y_q)$ , 其中  $y_j$  为对应  $\mathbf{X}_{p \times q \times S}$  表示中第  $j$  列 ( $j \in [1, q]$ ) 光谱维面 (称为“第  $j$  个光谱维面”), 其大小为  $p \times S$ . 由本文第 2 节的分析可知, 每一个光谱维面在相邻搜索区域内存在着参考块与光谱曲线块的结构相关性, 本文对该类相关性的稀疏表示进行挖掘, 进而形成 HSI 光谱维的结构相关性稀疏先验约束, 进一步提高 HSI 的重建质量. 具体过程如下 (相关符号的含义与 2.3 小节相同):

(1) 对于当前光谱维面  $y_j$  ( $j \in [1, q]$ ) 的以  $(m, n)$  为中心、大小为  $(2H+1) \times (2K+1)$  的参考块 ( $m \in \{H+1, H+2, \dots, p-H\}$ ;  $n \in \{K+1, K+2, \dots, S-K\}$ ), 确定其相邻搜索区域 (参见图 7(b)), 并在该区域按式 (2) 搜索与参考块相似程度由高到低的前  $R$  个“光谱曲线块” (本文实验中选取  $R=3$ ), 将参考块及所选取的  $R$  个相关光谱曲线块按其中心自左向右顺序进行堆叠形成“3D 光谱曲线块”  $\mathbf{G}_{m,g}^{3D}$  (参见图 10), 其中  $g$  ( $g \in \{1, 2, \dots, (S-2K)/R\}$ ) 为所选取的参考块序号, 参考块的选择原则为之前被选中的参考块, 后续不再选择.

(2) 对  $\mathbf{G}_{m,g}^{3D}$  ( $g \in \{1, 2, \dots, (S-2K)/R\}$ ) 进行  $T_{3D}$  正交变换, 并通过式 (9) 所示的测量模型获得 HSI 光谱维结构相关性稀疏先验:

$$f_2(\mathbf{Y}_{p \times S \times q}) \triangleq \|\Psi_{\text{Strc-spe-Blo}}(\mathbf{Y}_{p \times S \times q})\|_0 = \frac{\sum_{j=1}^q \sum_{m=H+1}^{p-H} \sum_{g=1}^{(S-2K)/R} (\|T_{3D}(\mathbf{G}_{m,g}^{3D})\|_0)}{(p-2H) \times (S-2K) \times (2H+1) \times (2K+1) \times q}, \quad (9)$$

其中分母  $(p-2H) \times (S-2K) \times (2H+1) \times (2K+1) \times q$  为归一化因子.

### 3.4 空间维非局部相关性与光谱维结构相关性稀疏表示的整合

假设经观测值初始化的 HSI 依据谱间相关性被分成了  $M$  个波段组  $\mathbf{X}_{p \times q \times S}^{(k)}$  ( $k \in \{1, 2, \dots, M\}$ , 不同波段组中的波段数  $S$  可能不同), 进一步  $\mathbf{X}_{p \times q \times S}^{(k)}$  所对应的“光谱维面”表示形式为  $\mathbf{Y}_{p \times S \times q}^{(k)}$ . 基于

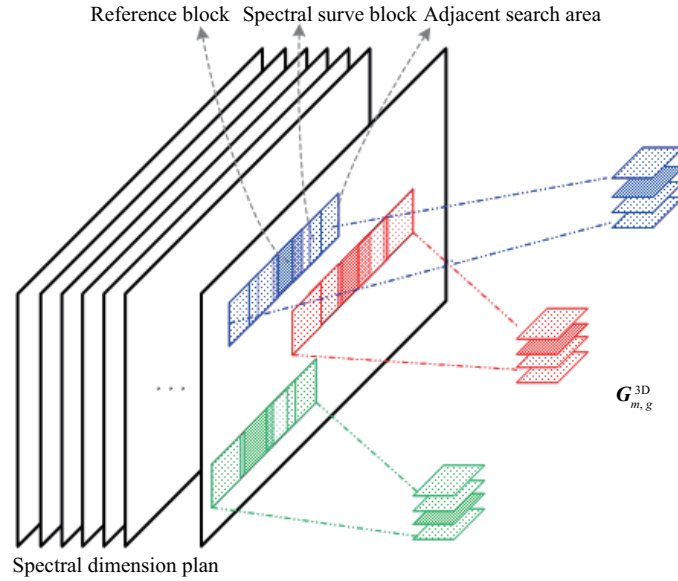


图 10 (网络版彩图) 光谱维面结构相关性稀疏挖掘示意图

Figure 10 (Color online) Mining sparse representations in spectral dimension structure correlation

式 (8) 和 (9), 提出如下联合空间维非局部相关性与光谱维结构相关性稀疏表示模型 (S-SCoSM):

$$\begin{cases} \text{S-SCoSM}(\mathbf{X}_{p \times q \times S}^{(k)}) = \alpha^{(k)} f_1(\mathbf{X}_{p \times q \times S}^{(k)}) + \beta^{(k)} f_2(\mathbf{Y}_{p \times S \times q}^{(k)}), \\ f_1(\mathbf{X}_{p \times q \times S}) \triangleq \|\Psi_{\text{NLoc-Spa-Bloc}}(\mathbf{X}_{p \times q \times S})\|_0 = \frac{\sum_{z=1}^{(p-u) \times (q-v)/N} (\|T_{3D}(\mathbf{E}_z^{3D})\|_0)}{(p-u) \times (q-v) \times u \times v \times S}, \\ f_2(\mathbf{Y}_{p \times S \times q}) \triangleq \|\Psi_{\text{Strc-spe-Blo}}(\mathbf{Y}_{p \times S \times q})\|_0 = \frac{\sum_{j=1}^q \sum_{m=H+1}^{p-H} \sum_{g=1}^{(S-2K)/R} (\|T_{3D}(\mathbf{G}_{m,g}^{3D})\|_0)}{(p-2H) \times (S-2K) \times (2H+1) \times (2K+1) \times q}, \end{cases} \quad (10)$$

其中  $\alpha^{(k)}$  和  $\beta^{(k)}$  为非负参数, 分别表示当前波段组中空间维整体非局部相关性和光谱维结构相关性的权重, 满足  $\alpha^{(k)} + \beta^{(k)} = 1$ .

考虑到 HSI 中上述两类相关性强度的差异, 以及相邻波段组相关特性的延续性, 本文采用利用前一重构波段组来预测当前波段组权重系数, 具体方案如下:

当  $k=1$  时, 通过对两类相关性的总体稀疏效果进行实验统计, 选取  $(\alpha^{(1)}, \beta^{(1)}) = (0.80, 0.20)$ ; 对于  $k \geq 2$ , 按照式 (11) 确定当前波段组的权重系数  $\alpha^{(k)}$  和  $\beta^{(k)}$ :

$$\alpha^{(k)} = \frac{f_1(\mathbf{X}_{p \times q \times S}^{(k-1)})}{f_1(\mathbf{X}_{p \times q \times S}^{(k-1)}) + f_2(\mathbf{Y}_{p \times S \times q}^{(k-1)}), \quad \beta^{(k)} = \frac{f_2(\mathbf{Y}_{p \times S \times q}^{(k-1)})}{f_1(\mathbf{X}_{p \times q \times S}^{(k-1)}) + f_2(\mathbf{Y}_{p \times S \times q}^{(k-1)})}. \quad (11)$$

### 3.5 基于 S-SCoSM 的 HSI 重构模型

(1) 模型的表现形式. 基于所提出的联合空间维非局部相关性与光谱维结构相关性的稀疏表示模型 (S-SCoSM), 构建如下 HSI 稀疏重建模型:

$$\begin{cases} \min_{\mathbf{X}_{p \times q \times S}^{(k)}} \left( \alpha^{(k)} f_1(\mathbf{X}_{p \times q \times S}^{(k)}) + \beta^{(k)} f_2(\mathbf{Y}_{p \times S \times q}^{(k)}) \right) \\ \text{s.t. } \mathbf{A} = \Phi \hat{\mathbf{X}}^{(k)}, \end{cases} \quad (12)$$

其中  $\hat{\mathbf{X}}^{(k)}$  为与三维立方体数据  $\mathbf{X}_{p \times q \times S}^{(k)}$  对应的二维矩阵, 具体对应关系如下: 依次选取  $\mathbf{X}_{p \times q \times S}^{(k)}$  的每一波段图像, 按自顶向下、从左到右的顺序将其作为  $\hat{\mathbf{X}}^{(k)}$  的对应列向量, 从而形成  $(p \times q) \times S$  的二维矩阵  $\hat{\mathbf{X}}^{(k)}$ ;  $\Phi$  为采样矩阵,  $\mathbf{A}$  为采样数据, 其每一列对应相应波段图像的测量值.

(2) 模型的计算. 对模型 (12) 的优化求解转化为如下线性回归模型目标函数的最优化问题:

$$\min_{\mathbf{X}_{p \times q \times S}^{(k)}} \left( \frac{1}{2} \|\mathbf{A} - \Phi \hat{\mathbf{X}}^{(k)}\|_2^2 + \lambda \left( \alpha^{(k)} f_1(\mathbf{X}_{p \times q \times S}^{(k)}) + \beta^{(k)} f_2(\mathbf{Y}_{p \times S \times q}^{(k)}) \right) \right), \quad (13)$$

其中  $\lambda$  为一非负参数,  $\mathbf{Y}_{p \times S \times q}^{(k)}$  是  $\mathbf{X}_{p \times q \times S}^{(k)}$  的“光谱维面”表示形式. 式 (13) 的求解涉及多个正则项的优化, 本文采用在对原式变量分裂的基础上再进行基于分离 Bregman 迭代方法的交替求解方法. 为此, 引入中间变量  $\mathbf{U}_1^{(k)}$ , 令  $\mathbf{U}_1^{(k)} = \mathbf{X}_{p \times q \times S}^{(k)}$ , 同时将与  $\mathbf{X}_{p \times q \times S}^{(k)}$  对应的  $\mathbf{Y}_{p \times S \times q}^{(k)}$  记为  $\mathbf{U}_2^{(k)}$ , 将  $\mathbf{X}_{p \times q \times S}^{(k)}$  的二维矩阵转换形式记为  $\hat{\mathbf{U}}^{(k)}$ , 这样可将式 (13) 转换为下式:

$$\begin{cases} \min_{\hat{\mathbf{X}}^{(k)}, \mathbf{U}_1^{(k)}} \left( \frac{1}{2} \|\mathbf{A} - \Phi \hat{\mathbf{X}}^{(k)}\|_2^2 + \lambda \left( \alpha^{(k)} f_1(\mathbf{U}_1^{(k)}) + \beta^{(k)} f_2(\mathbf{U}_2^{(k)}) \right) \right) \\ \text{s.t. } \hat{\mathbf{X}}^{(k)} = \hat{\mathbf{U}}^{(k)}. \end{cases} \quad (14)$$

进一步, 通过 SBI (split Bregman iteration) 算法 [23] 可上述问题转换为下列 3 步迭代子问题:

$$\begin{cases} (\hat{\mathbf{X}}^{(k)})^{(t+1)} = \arg \min_{\hat{\mathbf{X}}^{(k)}} \left( \frac{1}{2} \|\mathbf{A} - \Phi \hat{\mathbf{X}}^{(k)}\|_2^2 + \frac{\mu}{2} \|\hat{\mathbf{X}}^{(k)} - \hat{\mathbf{U}}^{(k)} - \hat{\mathbf{B}}^{(t)}\|_2^2 \right), \\ (\hat{\mathbf{U}}^{(k)})^{(t+1)} = \arg \min_{\hat{\mathbf{U}}^{(k)}} \left( \frac{\zeta}{2} \|(\hat{\mathbf{X}}^{(k)})^{(t+1)} - \hat{\mathbf{U}}^{(k)} - \hat{\mathbf{B}}^{(t)}\|_2^2 + \lambda \left( \alpha^{(k)} f_1(\mathbf{U}_1^{(k)}) + \beta^{(k)} f_2(\mathbf{U}_2^{(k)}) \right) \right), \\ \hat{\mathbf{B}}^{(t+1)} = \hat{\mathbf{B}}^{(t)} - \left( (\hat{\mathbf{X}}^{(k)})^{(t+1)} - (\hat{\mathbf{U}}^{(k)})^{(t+1)} \right), \end{cases} \quad (15)$$

其中  $\mu$  和  $\zeta$  为正值参数, 本文实验中分别选取其为 0.025 和 0.05. 式 (15) 的计算过程可参见文献 [18, 24].

## 4 实验与分析

为了验证本文重构模型的有效性, 选取了 4 类 HSI 波段组进行验证和评估. 第 1 类为 EO-1 卫星上 Hyperion 光谱仪拍摄的大连地区海岸 HSI ( $660 \times 256 \times 220$ , 光谱范围为 400~2500 nm, 共有 220 个波段), 选择了其中的 15~24 个波段, 并截取其  $256 \times 256$  的图像区域作为波段组; 第 2 类是 AVIRIS 光谱仪拍摄的 Cuprite HSI ( $420 \times 360 \times 224$ , 光谱范围为 400~2500 nm, 共有 224 个波段), 实验中选取其 180~189 个波段, 并截取其  $256 \times 256$  的图像区域作为波段组; 第 3 类是 Hyperspec 光谱仪拍摄的 Chikusei HSI ( $540 \times 420 \times 128$ , 光谱范围为 360~1020 nm, 共有 128 个波段), 实验中选取其 80~89 个波段, 并截取其  $256 \times 256$  的图像区域作为波段组; 第 4 类是 Rosis-3 光谱仪拍摄的 Pavia HSI ( $560 \times 320 \times 103$ , 光谱范围为 430~840 nm, 共有 103 个波段), 实验中选取其 90~99 个波段, 并截取其  $256 \times 256$  的图像区域作为波段组. 实验环境为: Intel Core CPU i7-4790, 3.60 GHz, 16 G 内存和 Matlab 2017. 4 类 HS 波段组的部分原始波段图像参见图 11.

为了衡量重构 HSI 的质量, 需要从空间域和光谱域两个角度对重构图像的质量进行评价, 本文采用峰值信噪比 (PSNR) 和结构特征相似度 (FSIM) [25] 来对重构 HSI 空间恢复效果进行度量, 同时采用光谱角 (SAM) 来度量光谱的保持效果; 进一步与近年来的一些典型算法: GPSR [26] 算法、改进的 GPSR 算法 [27]、全变分 (TV) 算法 [28] 和 HiCoSM 算法 [18] 进行对比.




图 11 实验用 HSI 波段组部分波段图像

Figure 11 Partial band images of HSI band group in experiment

#### 4.1 Hyperion 大连海岸带区域高光谱图像

附录 A 图 A1 和图 12 分别给出了对 Hyperion 大连海岸带区域 HSI 波段组在 0.2 采样率下本文算法与比较算法的重构波段图像, 以及在 0.2, 0.3 和 0.4 采样率下各重构波段图像的 PSNR 对比曲线图. 可以看出, 本文算法的重构波段图像的质量无论从主观可视化质量还是客观 PSNR 值均较 GPSR 算法、改进的 GPSR 算法 (SLF\_GPSR)、全变分 (TV) 算法和 HiCoSM 算法有一定幅度的提升. 分析其主要原因在于: 改进的 GPSR 算法是在 GPSR 算法<sup>[26]</sup>基础上将谱间线性滤波用于 HSI 的稀疏重建中, 但其缺少对 HSI 的空间结构或光谱曲线结构等相关性的考量; 全变分 (TV) 算法考虑了图像的平滑性, 但是对于图像纹理的约束并没有很好的保持; HiCoSM 算法在 RCoS 算法<sup>[19]</sup>基础上增加了相邻波段间的相关性先验, 但其对 HSI 的光谱维相关性的挖掘有限; 本文算法 (S-SCoSM) 从空间维和光谱维两个角度更深层的对 HSI 的相关性进行了挖掘, 获得了更为充分的 HSI 稀疏先验. 具体从重构波段图像的客观 PSNR 度量数值上看, 本文算法在 0.2 采样率下较 GPSR 算法、改进的 GPSR 算法、全变分 (TV) 算法和 HiCoSM 算法分别平均提升了 21.61, 16.47, 12.05 和 9.27 dB; 在 0.3 采样率下较上述算法分别平均提升了 21.97, 14.44, 11.55 和 9.61 dB; 在 0.4 采样率下较 GPSR 算法、改进的 GPSR 算法、全变分 (TV) 算法和 HiCoSM 算法分别平均提升了 16.99, 12.47, 11.39 和 9.03 dB.

进一步, 表 3 给出了上述对比算法与本文算法在采样率 0.2, 0.3 和 0.4 下重构波段图像的平均 FSIM 和光谱角 (SAM) 的对比统计. 可以看出, 与相关对比算法相比本文算法无论是 FSIM 还是 SAM 指标均取得了更优的效果, 本文算法的重构波段图像在保持原波段图像结构信息的同时, 更好地保持






图 12 (网络版彩图) 不同算法对 Hyperion 大连海岸带高光波段组在不同采样率下重构图像的 PSNR 比较  
 Figure 12 (Color online) Comparison of the reconstructed images PSNR in Dalian coastal zone of Hyperion between different algorithms at different sampling rates. Sampling rate of (a) 0.2, (b) 0.3, and (c) 0.4

表 3 对 Hyperion 大连海岸带高光波段组在不同采样率下重构图像的 FSIM 和 SAM 比较

Table 3 Comparison of the reconstructed images FSIM and SAM in Dalian coastal zone of Hyperion at different sampling rates

Algorithm	Sampling rate					
	0.2		0.3		0.4	
	FSIM	SAM (°)	FSIM	SAM (°)	FSIM	SAM (°)
GPSR	0.58	24.344	0.62	20.4333	0.77	11.786
SLF_GPSR	0.66	13.6745	0.78	7.7091	0.87	6.2841
TV	0.77	6.0196	0.84	4.9002	0.87	4.7052
HiCoSM	0.86	4.5998	0.9	4.3294	0.93	3.5475
S-SCoSM	0.97	4.2413	0.98	3.5904	0.98	2.9543

了 HSI 的光谱属性.

#### 4.2 AVIRIS Cuprite 高光谱遥感图像

图 A2 和 13 分别给出了对 AVIRIS Cuprite HSI 波段组在 0.2 采样率下本文算法与比较算法的重构波段图像, 以及在采样率分别为 0.2, 0.3 和 0.4 下重构波段图像的 PSNR 对比曲线图; 表 4 则给出了 GPSR 算法、改进的 GPSR 算法、全变分 (TV) 算法和 HiCoSM 算法与本文算法对在采样率为 0.2, 0.3 和 0.4 下重构波段图像 FSIM 和 SAM 的对比统计. 可以看出, 本文算法对该测试波段组的重构质量从主观可视化和客观 PSNR 值均有一定幅度的提升. 相比 GPSR 算法、改进的 GPSR 算法、全变分 (TV) 算法和 HiCoSM 算法, 本文算法在采样率为 0.2 时, 重构波段图像的 PSNR 值分别平均提高约 32.63, 16.70, 17.10 和 11.66 dB; 对采样率 0.3 时, PSNR 平均提高约 19.93, 15.79, 15.45 和 11.96 dB 左右; 对采样率 0.4 时, PSNR 平均提高约 17.76, 16.01, 14.65 和 11.64 dB 左右; 同时重构波段图像的 FSIM 和 SAM 指标较部分的对比算法有所提升, 整体效果提升效果明显.

#### 4.3 Hyperspec Chikusei 高光谱图像

图 A3 和 14 分别给出了 Hyperspec Chikusei HSI 波段组在 0.2 采样率下不同算法的重构波段图像, 以及分别在采样率 0.2, 0.3 和 0.4 下重构波段图像的 PSNR 对比曲线图. 表 5 为 GPSR 算法、改进的 GPSR 算法、全变分 (TV) 算法和 HiCoSM 算法与本文算法在采样率 0.2, 0.3 和 0.4 下重构波段图像的 FSIM 和 SAM 的对比统计. 可以看出, 与对比算法相比较, 本文算法在采样率为 0.2 时重构




图 13 (网络版彩图) 不同算法对 AVIRIS Cuprite 高光谱遥感波段组在不同采样率下重构图像的 PSNR 比较  
 Figure 13 (Color online) Comparison of the reconstructed images PSNR in Cuprite of AVIRIS between different algorithms at different sampling rates. Sampling rate of (a) 0.2, (b) 0.3, and (c) 0.4

表 4 对 AVIRIS Cuprite 高光谱波段组在不同采样率下重构图像的 FSIM 和 SAM 比较  
 Table 4 Comparison of the reconstructed images FSIM and SAM in Cuprite of AVIRIS at different sampling rates

Algorithm	Sampling rate					
	0.2		0.3		0.4	
	FSIM	SAM (°)	FSIM	SAM (°)	FSIM	SAM (°)
GPSR	0.56	3.5810	0.80	0.8509	0.83	0.6925
SLF_GPSR	0.79	1.5163	0.84	1.0139	0.87	0.9597
TV	0.82	0.9421	0.85	0.5742	0.88	0.5555
HiCoSM	0.88	0.9616	0.92	0.9105	0.95	0.7801
S-SCoSM	0.99	0.7379	0.99	0.6720	0.99	0.6083




图 14 (网络版彩图) 不同算法对 Hyperspec Chikusei 高光谱遥感波段组在不同采样率下重构图像的 PSNR 比较

Figure 14 (Color online) Comparison of the reconstructed images PSNR in Chikusei of Hyperspec between different algorithms at different sampling rates. Sampling rate of (a) 0.2, (b) 0.3, and (c) 0.4

波段图像的 PSNR 平均值分别提高约 35.41, 26.19, 22.92, 17.91 dB; 在采样率为 0.3 时, PSNR 平均值分别提高约 34.17, 24.35, 23.27, 18.21 dB 左右; 在采样率为 0.4 时, PSNR 提高约 27.32, 24.64, 23.97, 18.48 dB 左右; 所提出算法的重构图像在结构保持以及光谱保持的指标表现较好, 对比算法提升明显。

表 5 对 Hyperspec Chikusei 高光谱波段组在不同采样率下重构图像的 FSIM 和 SAM 比较

Table 5 Comparison of the reconstructed images FSIM and SAM in Chikusei of Hyperspec at different sampling rates

Algorithm	Sampling rate					
	0.2		0.3		0.4	
	FSIM	SAM (°)	FSIM	SAM (°)	FSIM	SAM (°)
GPSR	0.61	2.3092	0.68	1.0652	0.83	0.5601
SLF_GPSR	0.71	6.0992	0.84	1.3545	0.88	1.0283
TV	0.79	0.7649	0.84	0.3667	0.87	0.3451
HiCoSM	0.90	1.2493	0.95	0.8275	0.96	0.9042
S-SCoSM	0.99	0.6703	0.99	0.5683	0.99	0.4791




图 15 (网络版彩图) 不同算法对 Rosis-3 Pavia 高光谱遥感波段组在不同采样率下重构图像的 PSNR 比较

Figure 15 (Color online) Comparison of the reconstructed images PSNR in Pavia of Rosis-3 between different algorithms at different sampling rates. Sampling rate of (a) 0.2, (b) 0.3, and (c) 0.4

表 6 对 Rosis-3 Pavia 高光谱波段组在不同采样率下 Rosis-3 重构图像的 FSIM 和 SAM 比较

Table 6 Comparison of the reconstructed images FSIM and SAM in Pavia of Rosis-3 at different sampling rates

Algorithm	Sampling rate					
	0.2		0.3		0.4	
	FSIM	SAM (°)	FSIM	SAM (°)	FSIM	SAM (°)
GPSR	0.65	10.5909	0.69	4.5353	0.79	2.8592
SLF_GPSR	0.71	8.8390	0.80	3.3184	0.85	2.1311
TV	0.80	1.7677	0.84	1.1624	0.87	1.0814
HiCoSM	0.90	1.3796	0.94	1.2262	0.96	1.1571
S-SCoSM	0.99	1.2487	0.99	1.0745	0.99	0.9352

#### 4.4 Rosis-3 Pavia 高光谱图像

图 A4 和 15 分别给出了 Rosis-3 Pavia HSI 波段组在 0.2 采样率下不同算法的重构波段图像, 以及分别在采样率 0.2, 0.3 和 0.4 下重构波段图像的 PSNR 对比曲线图. 表 6 为 GPSR 算法、改进的 GPSR 算法、全变分 (TV) 算法和 HiCoSM 算法与本文算法在采样率 0.2, 0.3 和 0.4 下重构波段图像的 FSIM 和 SAM 的对比统计. 可以看出, 相比对比算法, 本文算法在采样率为 0.2 时重构波段图像的 PSNR 平均值分别提高约 29.67, 21.93, 18.40, 13.97 dB; 在采样率为 0.3 时, PSNR 平均值分别提高约 29.50, 21.19, 18.68, 14.14 dB 左右; 在采样率为 0.4 时, PSNR 提高约 25.26, 21.64, 19.26, 14.05 dB 左

右;同时所提出算法的重构图像具有较有关对比算法更高的结构相似度和更低的光谱角.

## 5 结束语

本文首先对 HSI 波段组光谱维结构相关性进行了研究,从 HSI 的“光谱维面”出发对 HSI 光谱维的结构相关性进行了分析,获得了如下两个结论:一是 HSI 光谱维面的纹理分布较空间域更为简单且容易被稀疏表达,二是在 HSI 光谱维面与参考块相邻的搜索区域内,存在着一定数量的与参考块具有较高相似度的光谱曲线块;进一步确定了 HSI 光谱维相关性稀疏的涵义,提出了基于 HSI 光谱维面结构相关性的稀疏测量模型.在此基础上,通过整合空间维非局部相关性与光谱维结构相关性的稀疏表示提出了稀疏表示模型 S-SCoSM,并给出了以 S-SCoSM 为约束先验的 HSI 稀疏重构模型. S-SCoSM 充分挖掘了 HSI 的稀疏性,使重建模型的约束先验更加有效和更具针对性,重构 HSI 的质量得到进一步提升.该稀疏模型进一步可应用于 HSI 的诸如解混、分类和变化检测等应用领域.

**致谢** 非常感谢匿名评审专家所提出的中肯而有建设性的修改意见.

**补充材料** 附录 A. 本文的补充材料见网络版 [infocn.scichina.com](http://infocn.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

- 1 Liu D Z, Huang S Q, Wang Y T, et al. Hyperspectral remote sensing image processing and application. Beijing: Science Press. 2018 [刘代志, 黄世奇, 王艺婷, 等. 高光谱遥感图像处理与应用. 北京: 科学出版社. 2018]
- 2 Zhang L P, Li J Y. Development and prospect of sparse representation-based hyperspectral image processing and analysis. *J Remote Sens*, 2016, 20: 1091–1101 [张良培, 李家艺. 高光谱图像稀疏信息处理综述与展望. *遥感学报*, 2016, 20: 1091–1101]
- 3 Bioucas-Dias J M, Plaza A, Camps-Valls G, et al. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geosci Remote Sens Mag*, 2013, 1: 6–36
- 4 Donoho D L. Compressed sensing. *IEEE Trans Inform Theory*, 2006, 52: 1289–1306
- 5 Candes E J, Wakin M B. An introduction to compressive sampling. *IEEE Signal Process Mag*, 2008, 25: 21–30
- 6 Jiao L C, Yang S Y, Liu F, et al. Development and prospect of compressive sensing. *Acta Electron Sin*, 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]
- 7 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]
- 8 Yin J H, Sun J Y, Jia X P. Sparse analysis based on generalized Gaussian model for spectrum recovery with compressed sensing theory. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2015, 8: 2752–2759
- 9 Ghamisi P, Yokoya N, Li J, et al. Advances in hyperspectral image and signal processing: a comprehensive overview of the state of the art. *IEEE Geosci Remote Sens Mag*, 2017, 5: 37–78
- 10 Qian Y T, Ye M C. Hyperspectral imagery restoration using nonlocal spectral-spatial structured sparse representation with noise estimation. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2013, 6: 499–515
- 11 Xue J Z, Zhao Y Q, Liao W Z, et al. Joint spatial and spectral low-rank regularization for hyperspectral image denoising. *IEEE Trans Geosci Remote Sens*, 2018, 56: 1940–1958
- 12 He Z, Li J, Liu L. Tensor block-sparsity based representation for spectral-spatial hyperspectral image classification. *Remote Sens*, 2016, 8: 636–656
- 13 Yang J, Li Y, Chan J, et al. Image fusion for spatial enhancement of hyperspectral image via pixel group based non-local sparse representation. *Remote Sens*, 2017, 9: 53–71
- 14 Wang Q, Ma L L, Tang L L, et al. Hyperspectral compressive sensing reconstruction based on spectral sparse model.

- J Infrared Millim Wave, 2016, 35: 723–730 [汪琪, 马灵玲, 唐伶俐, 等. 基于光谱稀疏模型的高光谱压缩感知重构. 红外与毫米波学报, 2016, 35: 723–730]
- 15 Gelvez T, Rueda H, Arguello H. Joint sparse and low rank recovery algorithm for compressive hyperspectral imaging. *Appl Opt*, 2017, 56: 6785–6795
  - 16 Xu P, Chen B Q, Xue L Y, et al. A prediction-based spatial-spectral adaptive hyperspectral compressive sensing algorithm. *Sensors*, 2018, 18: 3289
  - 17 Wang Y, Lin L, Zhao Q, et al. Compressive sensing of hyperspectral images via joint tensor tucker decomposition and weighted total variation regularization. *IEEE Geosci Remote Sens Lett*, 2017, 14: 2457–2461
  - 18 Wang X H, Song H Y, Song C M, et al. Hyperspectral image compressed sensing model based on the collaborative sparsity of the intra-frame and inter-band. *Sci Sin Inform*, 2016, 46: 361–375 [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]
  - 19 Zhang J, Zhao D, Zhao C, et al. Image compressive sensing recovery via collaborative sparsity. *IEEE J Emerg Sel Top Circ Syst*, 2012, 2: 380–391
  - 20 Li Y T. Research on hyperspectral image compression perception model based on multidimensional correlation. Dissertation for Master Degree. Dalian: Liaoning Normal University, 2018 [李业涛. 基于多维度相关性的高光谱图像压缩感知模型研究. 硕士学位论文, 大连: 辽宁师范大学, 2018]
  - 21 Wang L W, Zhang Y, Feng J F. On the Euclidean distance of images. *IEEE Trans Pattern Anal Machine Intell*, 2005, 27: 1334–1339
  - 22 Chen H D, Pu H Y, Wang B, et al. Image Euclidean distance-based manifold dimensionality reduction algorithm for hyperspectral imagery. *J Infrared Millim Waves*, 2013, 32: 450–454 [陈宏达, 普哈晔, 王斌, 等. 基于图像欧氏距离的高光谱图像流形降维算法. 红外与毫米波学报, 2013, 32: 450–454]
  - 23 Goldstein T, Osher S. The split Bregman method for L1-regularized problems. *SIAM J Imag Sci*, 2009, 2: 323–343
  - 24 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]
  - 25 Zhang L, Zhang L, Mou X Q, et al. FSIM: a feature similarity index for image quality assessment. *IEEE Trans Image Process*, 2011, 20: 2378–2386
  - 26 Figueiredo M A T, Nowak R D, Wright S J. Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems. *IEEE J Sel Top Signal Process*, 2007, 1: 586–597
  - 27 Ji Z X, Kong F Q. Hyperspectral image compressed sensing based on linear filter between bands. *Acta Photonica Sin*, 2012, 41: 82–86 [计振兴, 孔繁锵. 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]
  - 28 Li C, Yin W, Zhang Y. TVAL3: TV minimization by augmented Lagrangian and alternating direction algorithms. 2013. <http://www.caam.rice.edu/optimization/L1/TVAL3/>



# Spectral dimensional correlation and sparse reconstruction model of hyperspectral images

Xianghai WANG<sup>1,2\*</sup>, Shun WANG<sup>2</sup>, Shicheng XIE<sup>2</sup>, Yetao LI<sup>2</sup>, Jingzhe TAO<sup>1</sup> & Chuanming SONG<sup>2\*</sup>

1. School of Geography, Liaoning Normal University, Dalian 116029, China;

2. School of Computer and Information Technology, Liaoning Normal University, Dalian 116029, China

\* Corresponding author. E-mail: xhwang@lnnu.edu.cn, chmsong@163.com

**Abstract** The high dimensionality and redundancy properties of hyperspectral image (HSI) constitute great challenges for transmission and process. Recently, HSI reconstruction based on compressed sensing has received increasing attention and has become a frontier problem. Effectively exploiting the sparse prior of HSI is crucial to improve the reconstruction quality. In this paper, the spectral dimension plane of the HSI band group is defined, and the structural correlation of HSI spectral dimension is studied. The following conclusions can be obtained. First, the texture distribution of the HSI spectral dimension is simpler and more uniform than that of the HIS spatial domain, and its texture exhibits low contrast and high properties, thus simplifying the sparse representation process. Second, in the HSI spectral dimension plane, the search area adjacent to the reference block has a certain number of spectral curve blocks that are highly similar to the reference block. Based on this observation, the structure correlation of the HIS spectral dimension is defined, and a sparse measurement model is proposed. Finally, the sparse model S-SCoSM is proposed by integrating the sparse representation of spatial dimension nonlocal correlation and the spectral dimension structure correlation. The sparse reconstruction model of HSI is constructed using this sparse constrain prior. Experimental results show that by further exploring the correlation of HSI from the viewpoint of spatial and spectral domains, the proposed sparse model S-SCoSM obtains a more adequate and effective HSI sparse constraint prior; hence, the reconstruction quality of HSI is improved. Consequently, the spatial information quality of the reconstructed band image can be effectively improved as well as the spectral attributes of band groups can be well maintained.

**Keywords** hyperspectral image, spectral dimension, spectral dimensional correlation, joint sparse, sparse reconstruction, band group



**Xianghai WANG** was born in 1965. He received his Ph.D. degree in 1999 from Jilin University, Changchun. He is currently a professor at the School of Geography and School of Computer and Information Technology, Liaoning Normal University, Dalian. He is a senior member of the China Computer Federation (CCF). His research interests include computer graphics, multimedia information processing, and hyperspectral image processing.



**Shun WANG** was born in 1994. He is pursuing his M.S. degree at the School of Computer and Information Technology, Liaoning Normal University, Dalian. His research interest includes remote sensing image processing.



**Shicheng XIE** was born in 1995. He is pursuing his M.S. degree at the School of Computer and Information Technology, Liaoning Normal University, Dalian. His research interests include remote sensing image processing, and mathematical modeling.



**Chuanming SONG** was born in 1980. He received his Ph.D. degree in 2010 from Computer Science and Technology College, Nanjing University, Nanjing. He is currently a professor at the School of Computer and Information Technology, Liaoning Normal University, Dalian. He is a member of the China Computer Federation (CCF). His research interests include image and video coding and multimedia digital watermarking.