

# 基于多字典稀疏表示的遥感图像亚像元映射

黄慧娟, 禹 晶, 孙卫东

(清华大学电子工程系, 北京 100084)

**摘 要:** 本文提出了一种基于多字典稀疏表示的亚像元映射算法, 利用已知的同类型高空间分辨率地物分布图像, 构建能够更好反映不同类别地物空间分布模式的多个字典, 将待分类亚像元用每一类字典稀疏表示, 并依据重构误差最小化原则以及光谱失真程度约束条件来划分亚像元的地物类别. 模拟与真实数据上的实验结果表明, 本文算法能有效应对地物空间分布模式的多样性, 具有更高的亚像元映射精度和更好的算法鲁棒性.

**关键词:** 亚像元映射; 像元分解; 空间连续性; 多字典学习; 稀疏表示

**中图分类号:** TN91      **文献标识码:** A      **文章编号:** 0372-2112 (2015)06-1041-09

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2015.06.001

## Subpixel Land Cover Mapping Based on Multi-dictionary Sparse Representation for Remote Sensing Images

HUANG Hui-juan, YU Jing, SUN Wei-dong

(Dept. of Electronic Engineering, Tsinghua University, Beijing 100084, China)

**Abstract:** This paper proposes a subpixel land cover mapping method based on multi-dictionary sparse representation. In this method, some known high spatial resolution land cover maps are used to formulate different dictionaries that represent distribution modes of different land cover classes, the unclassified subpixels are represented by each dictionary, and they are also classified according to the principle of reconstruction-error minimization and spectral distortion constraint. Experimental results both on artificial and real images show that the method deals with the diversity between different distribution modes of different land cover classes effectively, and achieves higher subpixel mapping accuracy and robustness than the other related methods.

**Key words:** subpixel mapping; spectral unmixing; spatial dependence; multi-dictionary learning; sparse representation

### 1 引言

多光谱和高光谱遥感图像 (Multispectral and Hyperspectral remote Sensing Images, MHSI) 不仅能够在较大范围内提供地表地物的空间信息, 而且能够在较多或准连续的波段上提供地物的光谱信息, 利用这些信息能够辨识不同像元所属的地物类别, 进行地物分类<sup>[1]</sup>. 但是由于成像设备的限制, 得到的 MHSI 的空间分辨率较低 (Low spatial Resolution, LR), 从而导致图像中的单一像元往往是多种不同地物的混合体, 在空间与光谱上呈混合状态, 称之为混合像元<sup>[2]</sup>. 在对地物进行分类时, 混合像元不能被简单的划分为单一的一类地物. 像元分解通过建立像元光谱混合模型, 能够提取出纯净的地物, 同时估计各类地物在混合像元中所占的比例, 其中纯净地物

称为端元, 其所占比例称为丰度值, 各端元的丰度值组成相应类别地物的丰度图<sup>[2]</sup>. 然而, 像元分解无法估计各端元在混合像元内的分布结构, 因而无法提高地物分类的精度.

基于地物分布的空间连续性, Atkinson<sup>[3]</sup>首次提出了亚像元映射 (Sub-Pixel Mapping, SPM) 的概念, 又称亚像元定位或超分辨率制图<sup>[4]</sup>, 该方法能够获得具有更高空间分辨率 (High spatial Resolution, HR) 的地物分布图像, 提高地物分类精度. 图 1 以空间分辨率提升倍率  $S=2$  为例给出了亚像元映射的示意图. 图 1(a) 所示为“农作物”类别的丰度值, 可以看出, 中心像元含有 46% 的“农作物”和 64% 的“土壤”, 因此当将每个像元分割为  $2 \times 2$  个亚像元之后应选定其中的  $2(2 \times 2 \times 46\%)$  个亚像元划分为“农作物”类别, 其余的 2 个亚像元划分

为“土壤”类别.图 1(b)和图 1(c)分别给出了两种可能的亚像元映射结果,根据地物分布空间连续性的基本规律,一般认为图 1(c)所示地物分布图像要优于图 1(b).

现有的 SPM 算法可以分为两类:基于空间最优化的 SPM 方法与基于学习的 SPM 方法<sup>[5]</sup>.基于空间最优化的 SPM 方法使用目标函数对地物分布空间连续性进行建模,并通过最优化目标函数获取亚像元级地物分布图像<sup>[3,6~10]</sup>.这类方法仅利用所建立的单一地物分布空间连续性模型来划分亚像元的地物类别,然而在实际情况下地物空间分布模式非常复杂多样,单一模型远不能对其进行准确合理的描述.




图1 亚像元映射基本原理示意图

基于学习的 SPM 方法采用机器学习的方式预测混合像元内各类地物的分布结构,其关键在于如何有效的学习有关地物空间分布模式的先验知识. Boucher 等<sup>[11,12]</sup>从统计学的角度,在更高空间分辨率下构建了一种基于结构与纹理的地物空间分布模式先验模型. Mertens 等<sup>[13]</sup>提出了一种基于小波学习的 SPM 算法(Wavelet Learning based Sub-pixel Mapping, WLSM),通过神经网络学习小波系数与丰度值之间的关系,并利用小波系数重建亚像元级地物分布图像. Tatem 等<sup>[14]</sup>将像元内各类地物的分布结构表示为 Hopfield 神经网络的能量函数,但该算法所需计算时间较长. Nguyen 等<sup>[15]</sup>提出了一种基于 Hopfield 神经网络的 SPM 算法,但该算法需要一幅融合图像作为辅助数据. Gu 等<sup>[16]</sup>提出了一种基于 BP (Back Propagation) 网络的 SPM 算法(BP based Sub-pixel Mapping, BPSM),通过对各类别地物空间分布模式的无区分学习得到单一的 BP 神经网络. Foody<sup>[17]</sup>利用同一区域、同一时相的 HR 图像来提高丰度图的分辨率,继而得到 HR 地物分布图像,但实际情况下往往难以获取此类额外 HR 图像.

自然图像或特定对象图像中广泛存在相似区域,其中蕴含的附加信息可经过稀疏表示学习到字典中去,并用于图像表达或图像建模等<sup>[18~21]</sup>. 本文认为地物分布图像中也同样广泛存在相似结构,比如“河流”类别一般表现为线状分布、且同一流域的河流存在明显的相似性,“建筑物”类别一般表现为多边形分布、且同一风格的建筑物存在很强的相似性. 根据这种分布结构相似性,本文提出了一种基于多字典稀疏表示的

SPM 算法(Multi-dictionaries Sparse Representation based Sub-pixel Mapping, MSRSM),构建能够充分反映地物分布空间连续性的特征向量,采用稀疏表示对 HR 训练图像中每类地物的空间分布模式进行样本学习得到相应的字典,并将待分类亚像元分别用每一类字典稀疏表示,依据重构误差最小化原则以及光谱失真程度约束条件来划分该待分类亚像元的地物类别. 采用上述思路的主要原因,一是因为现有的基于学习的 SPM 算法在获取地物空间分布模式时普遍存在过学习问题,且学习过程和 SPM 过程都易受噪声的影响. 而基于稀疏表示的字典学习能够有效获取样本的本质特征、且具有更好的抗噪性,这一特性在 Wright 等基于稀疏表示的人脸识别算法研究中得到了证实<sup>[21]</sup>. 另一方面,现有的 SPM 算法大多不考虑不同类别地物在空间分布模式上的差异性,对所有类别地物的样本进行整体学习,然而在实际情况下,不同类别地物的空间分布模式往往差别很大,同一类别地物的空间分布模式则具有很强的相似性,因此单一地物空间分布模式既不能充分刻画某一特定类别地物空间分布模式的特殊性,也不能有效反映所有类别地物的共同空间分布模式. 本文算法提出的多字典学习策略,采用稀疏表示分别对每一类地物的空间分布模式进行样本学习,通过多个字典实现对不同类别地物空间分布模式的有区分表示.

## 2 稀疏表示

自然图像往往可以由某组基稀疏表示,这种稀疏性被广泛用于图像表达和图像建模等领域,如图像复原<sup>[20]</sup>、图像去噪<sup>[19]</sup>、人脸识别<sup>[21]</sup>、手写数字识别<sup>[18]</sup>等.

对于信号  $\mathbf{x} \in \mathbb{R}^n$ , 设其在一组基  $\{\phi_i\}_{i=1}^d$  上能够被

稀疏表示,即  $\mathbf{x} = \sum_{i=1}^d \alpha_i \phi_i$ ,  $\phi_i \in \mathbb{R}^n$ . 令  $\mathbf{a} = [\alpha_1, \dots, \alpha_d]^T \in \mathbb{R}^d$ ,  $\Psi = [\phi_1, \dots, \phi_d] \in \mathbb{R}^{n \times d}$ , 则有:

$$\mathbf{x} = \Psi \mathbf{a} \quad (1)$$

其中,  $\Psi$  称为字典,  $\phi_i$  称为字典的元素. 信号  $\mathbf{x}$  可由字典  $\Psi$  稀疏表示意味着  $\mathbf{a}$  中非零元素的个数  $\|\mathbf{a}\|_0 = m \ll d$ , 因此称  $\mathbf{a}$  为稀疏表示系数. 字典  $\Psi$  是通过样本学习而得到的,而不是预先定义的,即在  $\Psi$  与  $\mathbf{a}$  均未知的情况下求解下式:

$$\min_{\Psi, \mathbf{A}} \{ \|\mathbf{X} - \Psi \mathbf{A}\|_F^2 \} \quad \text{s.t.} \quad \forall i, \|\mathbf{a}_i\|_0 \leq T \quad (2)$$

其中,  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_i]$  为训练样本矩阵,每一列为一个输入样本,  $\mathbf{A} = [\mathbf{a}_1, \dots, \mathbf{a}_i]$  为稀疏表示矩阵,每一列为相应样本的稀疏表示系数,即  $\mathbf{x}_i = \Psi \mathbf{a}_i$ .  $\|\cdot\|_F$  表示矩阵的 Frobenius 范数,  $T$  为控制  $\mathbf{a}_i$  稀疏程度的参数. 本文采用 K-SVD 算法<sup>[22]</sup>和 OMP 算法<sup>[23]</sup>对式(3)进行求解,由于当训练样本  $\mathbf{x}_i$  的维数  $n = \|\mathbf{a}_i\|_0^2$  时,OMP 算法的

效率最高,因此控制 $\alpha_i$ 稀疏程度的参数 $T \leq \sqrt{n}$ .

### 3 本文算法

在地物分布图像中相同类别地物的空间分布模式往往具有很强的相似性,而不同类别地物的空间分布模式往往差别很大.如图2所示,图2(a)和图2(b)中的河流都呈现出线状分布的基本特点,居民区都呈现出多边形分布的基本特点,因此本文认为某一类地物的空间分布模式可由某种特定字典稀疏表示,本文通过对现有 HR 地物分布图像中的地物空间分布模式进行样本学习来得到此种字典.本文提出的 MSRS 算法将构建能够充分体现地物分布空间连续性的特征向量,在稀疏表示框架下对已知的 HR 地物分布图像中各类地物的空间分布模式进行多字典学习,并利用学习得到的字典对待分类亚像元进行重构,将重构误差最小化原则以及光谱失真程度约束作为划分亚像元地物类别的依据.图3给出了本文算法的整体框架,以下将对本文所提算法的核心细节加以详细阐述.

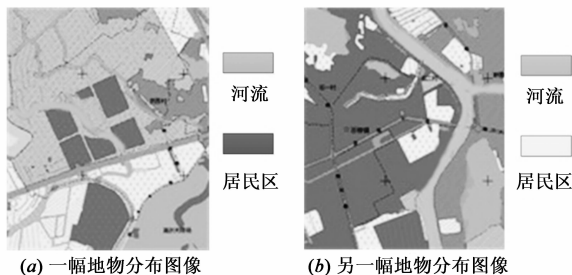


图2 地物空间分布模式相似性示意图

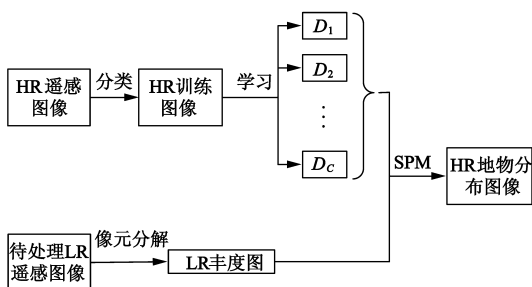


图3 本文算法整体框架

#### 3.1 地物分布空间连续性与特征向量

亚像元映射的理论依据是地物分布的空间连续性,即相距较近像元相对于相距较远像元更倾向于具有相同的性质,也更倾向于属于同一类地物<sup>[3]</sup>,因此,用于描述地物空间分布模式的特征向量应能充分体现这种空间连续性.如上所述,WLSM 和 BPSM 算法均以每幅丰度图中 $3 \times 3$ 邻域内的丰度值作为特征向量,无法有效体现地物分布的空间连续性,就此本文提出了一种能够更加有效表示地物分布空间连续性的特征向量.

设空间分辨率提升倍率为 $S$ ,位于坐标 $(i, j)$ 处的像元为 $P_{i,j}$ ,在 SPM 过程中,每个像元被分割为 $S \times S$ 个亚像元 $p_{a,b}^k$ ,其中, $(a, b)$ 表示该亚像元坐标, $k$ 表示其地物类别,图4(a)直观给出了各符号的意义.本文提出的针对像元 $P_{i,j}$ 内第 $k$ 类亚像元 $p_{a,b}^k$ 的特征向量为 $\mathbf{f}_k = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_C]^T$ ,其中:

$$\mathbf{v}_c = \left[ \frac{P_{i-1,j-1}^c}{d(p_{a,b}^k, P_{i-1,j-1})}, \dots, \frac{P_{i+1,j+1}^c}{d(p_{a,b}^k, P_{i+1,j+1})} \right]^T \quad (3)$$

$d(p_{a,b}^k, P_{i-1,j-1})$ 表示亚像元 $p_{a,b}^k$ 和像元 $P_{i-1,j-1}$ 之间的距离; $P_{i-1,j-1}^c, c = 1, \dots, C$ 表示像元 $P_{i-1,j-1}$ 内第 $c$ 类地物的丰度值.即,特征向量 $\mathbf{f}_k$ 是由以第 $k$ 类亚像元所在像元为中心的 $3 \times 3$ 邻域内所有类别地物的加权丰度值组成.图4(b)给出了加权系数 $d(\cdot, \cdot)$ 的计算方法示意图,可以看出距离亚像元 $p_{a,b}^k$ 越近、丰度值越大的邻域像元在特征向量中占有的比重越大,对亚像元的地物类别影响也就越大,换言之,地物分布的空间连续性也就越强.




图4 特征向量示意图

#### 3.2 基于稀疏表示的多字典学习

本文在稀疏表示框架下,利用已知的同类型 HR 训练图像所提供的、针对各类地物的样本特征集合进行学习,通过式(4)求取代表每类地物空间分布模式的字典 $\mathbf{D}_k, k = 1, \dots, C$ .

$$\arg \min_{\mathbf{D}_k, \mathbf{A}_k} \{ \|\mathbf{F}_k - \mathbf{D}_k \mathbf{A}_k\|_2^2 \} \text{ s.t. } \|\alpha_i^k\|_0 \leq T \quad (4)$$

其中, $\mathbf{F}_k = \bigcup_{i=1}^{n_k} \mathbf{f}_i^k$ 为第 $k$ 类地物的 $n_k$ 个特征向量集合, $\mathbf{A}_k = [\alpha_1^k, \dots, \alpha_{n_k}^k]$ 为稀疏表示系数矩阵.本文采用交替求解 $\mathbf{D}_k$ 和 $\mathbf{A}_k$ 来获得最终解,即固定 $\mathbf{A}_k$ 时采用 K-SVD 算法<sup>[22]</sup>学习 $\mathbf{D}_k$ ,固定 $\mathbf{D}_k$ 时采用 OMP 算法<sup>[23]</sup>获得稀疏表示矩阵 $\mathbf{A}_k$ .此外,由 2.1 小节可知,特征向量 $\mathbf{f}_k$ 的维数 $n_k = 3 \times 3 \times C$ ,而 OMP 算法在 $n_k = \|\alpha_i^k\|_0^2$ 时性能最好,因此本文选择控制稀疏程度的参数 $T \leq \sqrt{9C}$ .

#### 3.3 基于多字典的亚像元映射

SPM 将像元分割为 $S \times S$ 个亚像元,并根据学习得到的有关地物空间分布模式的多字典先验知识,以 LR 丰度值为基础,将每个亚像元划分为合适的地物类别,从而达到提升地物分布图像空间分辨率的目的.

本文所提算法的具体步骤为,对于待处理的 LR 丰

度图,首先,针对每个待分类亚像元构建其特征向量  $\mathbf{g} = [\mathbf{v}_1, \mathbf{v}_2, \cdots, \mathbf{v}_C]^T$ ,其中  $\mathbf{v}_c, c = 1, \cdots, C$ ,如式(4)所示;然后,将此特征向量  $\mathbf{g}$  分别用每类地物空间分布模式的字典  $\mathbf{D}_k$  稀疏表示,得到相应的稀疏表示系数  $\beta_k$ ,即  $\arg \min_{\beta_k} \{ \|\mathbf{g} - \mathbf{D}_k \beta_k\|_2^2 \}$  s.t.  $\|\beta_k\|_0 \leq T$ ;其次,计算每一类字典  $\mathbf{D}_k$  上  $\mathbf{g}$  的重构误差,即  $e_k = \|\mathbf{g} - \mathbf{D}_k \beta_k\|_2^2$ ;最后,依据重构误差来划分该亚像元所属的地物类别。

重构误差最小分类原则是一种最为简单的亚像元划分方法,现有 SPM 算法大都在此基本分类原则上加入了基于丰度值的亚像元划分个数限制条件,即将亚像元划分为某一类地物时应保证当前像元内已划分为该类地物的亚像元总数小于该像元内丰度值所规定的属于该类地物的亚像元总数,如若原像元内含有两类地物,且二者的丰度值均为 50%,那么 SPM 处理后应该分别各有一半的亚像元分属于这两类地物. 现有 SPM 算法中,像元内属于第  $k$  类地物的亚像元数目  $N_k = \text{round}(P^k S^2)$ ,其中  $P^k$  为该像元内第  $k$  类地物的丰度值,  $S$  为空间分辨率提升倍率,  $\text{round}(\cdot)$  为四舍五入操作。

由于现有 SPM 算法假设每一个亚像元均为纯净地物,其实质是将连续的丰度值离散化,因而这势必造成像元级光谱失真,针对这一问题,本文采用通过光谱失真程度来约束  $N_k$  的取值,即:

$$\min_{N_k} \left\| \sum_{k=1}^C N_k \mathbf{s}_k / S^2 - \boldsymbol{\chi} \right\|_2^2 \quad (5)$$

其中,  $\mathbf{s}_k$  为第  $k$  类地物所对应端元的光谱向量,  $\boldsymbol{\chi}$  为当前像元的光谱向量。

当某一像元内所有的亚像元在第  $k$  类地物空间分布模式字典  $\mathbf{D}_k$  上都具有相对较大的重构误差,而该像元内属于该类地物的亚像元数目  $N_k$  不为零时,为了避免忽略本应属于该第  $k$  类地物的亚像元,本文将重构误差  $e_1, e_2, \cdots, e_C$  进行归一化处理,即  $\overline{e}_k = e_k / \sum_{c=1}^C e_c$ .

表 1 以提升倍率  $S = 2$  为例对此种情况进行了说明. 对于某一给定的像元,若其针对第 1、2 类地物的丰度值分别为 0.25、0.75,该像元内属于第 1、2 类地物的亚像元数目  $N_1, N_2$  分别为 1、3,而分割为 4 个亚像元后,各亚像元在字典  $\mathbf{D}_1, \mathbf{D}_2$  上的原始重构误差  $e_1, e_2$  分别如表 1 所示,则不难看出,由于在字典  $\mathbf{D}_2$  上亚像元 1、2、3 的重构误差小于在字典  $\mathbf{D}_1$  上的重构误差,因此这三个亚像元将被划分为第 2 类地物;而根据  $N_1$  与  $N_2$  的取值,当属于第 2 类地物的亚像元数目达到  $N_2$  的取值 3 时,亚像元 4 就会被划分为第 1 类地物. 但从表 1 还可以看出,在字典  $\mathbf{D}_1$  上亚像元 4 的重构误差要远大于亚像元 1 的重构误差,即将亚像元 4 划分为第 1 类地物不合理. 按照本文方法进行归一化处理,根据  $\overline{e}_1$  与  $\overline{e}_2$  的取

值,亚像元 1 将取代亚像元 4 被划分为第 1 类地物,这是一种更加合理的划分方法。

表 1 采用非归一化误差和归一化重构误差的 SPM 结果示例

亚像元标号	1	2	3	4
非归一化误差 $e_1$	0.25	0.72	0.66	0.61
非归一化误差 $e_2$	0.08	0.09	0.07	0.06
归一化误差 $\overline{e}_1$	0.09	0.32	0.29	0.27
归一化误差 $\overline{e}_2$	0.27	0.30	0.23	0.20
采用 $e_1$ 与 $e_2$ 划分类别	2	2	2	1
采用 $\overline{e}_1$ 与 $\overline{e}_2$ 划分类别	1	2	2	2

4 实验结果与分析

为了验证本文所提 MSRSM 算法的有效性,实验中分别采用了模拟图像、AVIRIS 合成丰度图和真实 TM 多光谱图像 3 组不同类型的数据,将本文 MSRSM 算法与目前得到普遍认可的 WLSM 算法、BPSM 算法进行了比较与分析,并对 3 组实验的结果进行了定性定量评价. 同时,为了保证对比分析的公平性,本文利用了 WLSM 算法<sup>[13]</sup>中的实验参数设置,设空间分辨率提升倍率  $S = 2$ .

基于混淆矩阵的正确分类率 PCC (Percent Correctly Classified)<sup>[24]</sup>、Kappa 系数  $\kappa$ <sup>[25]</sup>、生产者精度 (Producer's Accuracy, PA)、用户精度 (User's Accuracy, UA) 是定量评价 SPM 精度的常用指标. PCC 为正确分类的亚像元数目与全部亚像元数目的比值.  $\kappa$  为评价交互可靠性的统计度量,由于该系数考虑了数据的偶然一致性,通常认为它比 PCC 更为可靠. 生产者精度又称为制图精度,表示地面实际类别的任意一个样本与分类图像上同一地点的分类结果相一致的条件概率. 用户精度表示从分类图像上任取一个随机样本,其分类结果与地面实际类别相同的条件概率. 然而需要指出的是,由于纯净像元内各亚像元的地物类别是确定的,若把纯净像元也作为定量评价对象,则只会起到单纯增大评价指标的作用,无法真实反映 SPM 算法的有效性,因此本文采用了仅以混合像元为评价对象的修正型正确分类率 PCC\* (adjusted PCC)、修正型 Kappa 系数  $\kappa^*$  (adjusted Kappa),以及修正型平均生产者精度 APA\* (adjusted Average of Producer's Accuracy) 和修正型平均用户精度 AUA\* (adjusted Average of User's Accuracy) 这 4 种评价指标. 并且,为了评价亚像元映射算法的实用性,实验中对三种算法的所需时间 time 进行了对比。

4.1 AVIRIS 合成丰度图下的对比实验

为了评价理想状态下 SPM 算法自身的理论精度,剥离像元分解或其他预处理过程所带来的误差,本文

在前两组实验中采用了合成策略来生成丰度值<sup>[6]</sup>.合成策略包含三个步骤,(1)对给定的 HR 遥感图像进行像元级分类,获得 HR 分类图像;(2)对该 HR 分类图像进行下采样处理,生成包含纯净与混合像元的 LR 图像;(3)依据 HR 分类图像与 LR 图像间的多对一映射关系,针对各类地物所对应的端元,合成 LR 图像中每一像元的丰度值,并将该丰度值作为像元分解的结果.合成策略不仅可以为 SPM 算法提供所需要的丰度图,还可以提供作为分类真值的 HR 参考图像,为 SPM 结果的定量评价提供依据.

为了更接近真实的地物空间分布模式,本组实验采用了地物类别数量及空间分布模式更加复杂的真实遥感图像.实验中,首先对相同类别地物空间分布模式相似的两幅 AVIRIS 高光谱遥感图像进行分类,形成 HR

分类图像,将其中一幅作为 HR 训练图像,另外一幅作为 HR 参考图像,然后依据合成策略生成合成丰度图.合成策略除了可为定量评价提供真值外,还能够避免大气、几何效应等成像环境因素对像元分解过程可能产生的影响,更好体现 SPM 算法本身的处理精度.

两幅 AVIRIS 图像分别为 2000 年和 2001 年针对长江流域的高光谱遥感图像,空间分辨率为 20m、光谱分辨率为 10nm.采用无监督分类和形态学滤波所获得的 HR 训练图像和 HR 参考图像分别如图 5(a)和图 5(b)所示.图 5(c)为采用合成策略对图 5(b)进行 2 倍下采样生成的 4 类地物丰度图.图 5(d)~(f)分别为提升倍率为 2 情况下的 WLSM、BPSM 和 MSRSM 三种算法的 SPM 处理结果,图 5(g)对各图像的局部区域(图 5(b)所示长方形区域)进行了细节放大显示.




图5 AVIRIS合成丰度图下的亚像元映射结果对比

如图 5(d)所示,WLSM 算法虽然能够保持各类地物的大致空间分布结构,但在各类地物边界处的表现较差,其 SPM 处理结果与 HR 参考图像在细节结构上的差异较大.BPSM 算法处理结果如图 5(e)所示,虽然相对于 WLSM 算法有所改进,但各类地物的边界处仍存在诸多毛刺.从图 5(f)可以看出,本文 MSRSM 算法的处理结果与 HR 参考图像最为接近,能够保持绝大多数的地物分布结构,尤其在较小结构以及类边界的处理

上效果显著.表 2 给出了 4 种评价指标下的定量比较结果,从表中可以看出,本文 MSRSM 算法的  $PCC^*$ 、 $\kappa^*$ 、 $APA^*$  与  $AUA^*$  评价指标均达到最高值.从表 2 中的时间对比可以看出,本文提出的算法所需要的时间与其它两种算法相差无几.主观与客观评价结果均表明本文 MSRSM 算法能够通过多字典学习获取不同地物类别的有针对性地物空间分布模式,能够获得更为合理的亚像元级地物分布图像.

表 2 合成图像下的定量对比分析结果

评价指标	WLSM	BPSM	MSRSM
PCC *	0.5388	0.5612	0.8153
$\kappa$ *	0.3699	0.4042	0.7471
APA *	0.5375	0.5700	0.8109
AUA *	0.5375	0.5627	0.8158
time(s)	76.31	48.56	89.85

4.2 SPOT 合成丰度图下的对比实验


本组实验采用了 2005 年安徽省南部的 SPOT 图像, HR 训练图像的大小为  $592 \times 730$ , 用于测试 SPM 算法精度的 HR 参考图像大小为  $588 \times 726$ , 分别如图 6(a) 和图 6(b) 所示. 图 6(c) 为对 HR 参考图像进行 2 倍下采样得到的 4 类地物的丰度图. 图 6(d) ~ (f) 所示为空间分辨率提升倍率为 2 的情况下 WLSM、BPSM 和 MSRSM 算法的 SPM 结果, 由于这些图像空间维数较大, 所以通过比较这三幅图像不易看出区别. 图 6(g) 给出了图 6(b) 中黑色矩形区域 S1 和 S2 的细节图像.

通过比较可以看出, 本文所提出的 MSRSM 算法所

得到的结果与 HR 参考图像最为接近. WLSM 算法和 BPSM 算法不能够很好的处理类边界处的地物分布, 所得结果出现诸多的奇异点和不平滑边界. 表 3 给出的 4 种评价指标结果与主观评价结果一致. 通过对比 3 种算法所需时间 time 可以看出, 由于本组实验的图像较大、地物分布结构较为复杂, 各种算法所需的时间都有所提升, 其中本文提出的算法所耗费的时间要少于 WLSM 算法. 该组实验结果再一次证明本文提出的算法能够在一定时间内获得更合理的亚像元级地物分布图像, 具有实际的应用意义.

表 3 SPOT 图像下的定量对比分析结果

评价指标	WLSM	BPSM	MSRSM
PCC *	0.5608	0.6276	0.8245
$\kappa$ *	0.3235	0.3880	0.7240
APA *	0.5422	0.5494	0.8013
AUA *	0.5422	0.6343	0.8312
time(s)	520.70	199.09	421.74



4.3 真实 TM 多光谱图像下的对比实验

前两组实验中的合成策略能够在避免其他误差源干扰的情况下,对 SPM 算法本身的处理精度进行有参考的定量评价.第三组实验的目的在于验证真实 LR 遥感图像下 SPM 算法的实际有效性.本组实验对象为 2004 年获取的 30m 空间分辨率的北京密云地区 Landsat-TM 多光谱图像,并选用相同类别地物空间分布模式与其相似的 2007 年获取的 Spot-4 多光谱图像作为训练数据,其空间分辨率为 20m,如图 7(a)所示.同时,为了能够对 SPM 处理结果进行定量评价,本组实验采用了 2004 年获取的与 TM 多光谱图像同一区域的 Spot-4 多光谱图像作为 HR 参考图像.对于仅包含“水域”、“土壤”、“植被”三种自然地物类别的研究区域,可以认为 Spot-4 图像中的相应像元为相对“纯净”像元,同地域与

同时相特性也确保了 TM 与 Spot-4 图像之间的可比性.在预处理过程中,本文采用 SIFT 特征对 TM 图像与 Spot-4 图像进行了精确配准,图 7(e)所示即为与图 7(c)相对应的配准后 Spot-4 图像.采用无监督分类算法分别对图 7(a)和图 7(e)进行像元级分类,所获得的 HR 训练图像和 HR 参考图像分别如图 7(b)和图 7(f)所示.实验中,为了确保 TM 与 Spot-4 图像在空间分辨率上的整数倍率关系,将 TM 图像降采样至 40m 空间分辨率,降采样后的 TM 图像如图 7(c)所示.采用文献 [26]算法对 TM 图像进行像元分解,“水域(C1)”、“土壤(C2)”、“植被(C3)”三类地物的丰度图如图 7(d)所示.然后再分别采用 WLSM、BPSM 以及本文 MSRSM 算法进行提升倍率为 2 的 SPM 处理,并对所得结果进行定量评价.

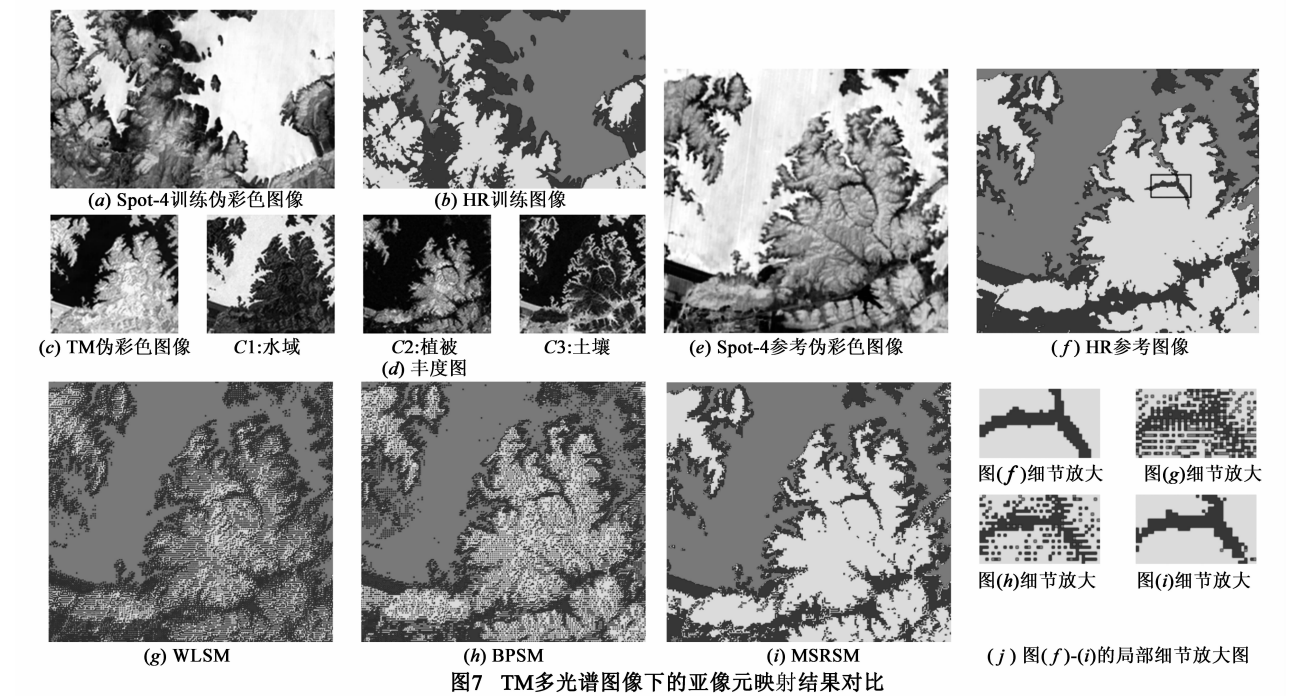


图7 TM多光谱图像下的亚像素映射结果对比

图 7(g)~(i)所示为 3 种 SPM 算法所获得的 2 倍率地物分布图像.图 7(j)为各图像长方形区域的细节放大图.从图 7 可以看出,MSRSM 算法所得地物分布图像与图 7(f)所示 HR 参考图像最为接近,其他 2 种算法将一些纯净像元映射为了包含多种地物的混合像元,导致其处理结果与 HR 参考图像相差较大.由图 7(j)所示细节放大图可以清楚看出,WLSM 算法不能有效保持地物分布的连续性结构,原本连通的区域被分裂成了细小的点状区域.BPSM 算法所得结果略优于 WLSM 算法,但其类边界不平滑,且相对于前两组实验,这两种算法在实际遥感图像下的地物分布结构保持能力明显下降.

表 4 给出了 3 种 SPM 算法的定量评价结果,从表中可以看出,相对于其他两种算法,本文 MSRSM 算法在 4

种评价指标下均取得了最大值,其中,在  $\kappa^*$  指标上 MSRSM 算法相对于 WLSM、BPSM 算法分别提高了 37.34%、24.41%,这表明在实际遥感图像下本文算法在性能指标上远优于其他三种算法,具有更高的处理精度与算法鲁棒性.而且,本文算法的计算时间要少于 WLSM 算法所需的时间.

表 4 TM 图像下的定量对比分析结果

评价指标	WLSM	BPSM	MSRSM
PCC *	0.5848	0.6959	0.8535
$\kappa^*$	0.3786	0.5079	0.7520
APA *	0.6358	0.6905	0.8424
AUA *	0.5899	0.6890	0.8522
time(s)	716.14	207.07	316.57



由于像元光谱能够体现光谱层次上的像元组成,因此为了进一步验证本文 MSRSM 算法处理结果与实际地物组成的一致性,本文对 SPM 处理结果进行了逆向合成,即在 TM 图像空间分辨率下逆向计算图 7(g)~(i)中各像元的光谱,将其与原 TM 图像相应像元的光谱进行比较,并通过二者间的欧氏距离评价光谱误差。




图8 光谱误差直方图

## 5 结论

本文提出了一种基于多字典稀疏表示的 SPM 算法,该算法给出了一种能够有效表达地物分布空间连续性的特征向量,在稀疏表示框架下对 HR 训练图像进行样本学习,获得能够更好反映各类地物不同空间分布模式的多个字典,形成有针对性的多字典学习策略,将待分类亚像元分别用各类字典加以表示,并依据重构误差最小化原则与光谱失真程度约束条件来划分亚像元的地物类别。本文分别采用了模拟与真实数据验证了本文算法的有效性,三组不同类型的对比实验结果表明,与其他同类算法相比,本文算法具有更高的亚像元映射精度和算法鲁棒性。

## 参考文献


- [1] Shaw G, Manolakis D. Signal processing for hyperspectral image exploitation[J]. IEEE Transactions on Signal Processing Magazine, 2002, 19(1): 12–16.
- [2] Keshava N, Mustard J F. Spectral unmixing[J]. IEEE Signal Processing Magazine, 2002, 19(1): 44–57.
- [3] Atkinson P M. Mapping Sub-pixel Boundaries from Remote Sensed Images[M]. Innovations in GIS 4, London: Taylor & Francis, 1997. 166–180.
- [4] 凌峰, 吴胜军, 肖飞, 等. 遥感影像亚像元定位研究综述[J]. 中国图象图形学报, 2011, (08): 1335–1345.  
Ling Feng, Wu Sheng-jun, Xiao Fei, et al. Sub-pixel mapping of remotely sensed imagery: a review[J]. Journal of Image and Graphics, 2011, (08): 1335–1345. (in Chinese)
- [5] Atkinson P M. Issues of uncertainty in super-resolution mapping and their implications for the design of an inter-comparison study[J]. International Journal of Remote Sensing, 2009, 30(20): 5293–5308.
- [6] Mertens K C, de Baets B, Verbeke L P C, et al. A sub-pixel mapping algorithm based on sub-pixel/pixel spatial attraction models[J]. International Journal of Remote Sensing, 2006, 27(15): 3293–3310.
- [7] Zhong Y, Zhang L. Remote sensing image subpixel mapping based on adaptive differential evolution[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2012, 42(5): 1306–1329.
- [8] Villa A, Chanussot J, Benediktsson J A, et al. Spectral unmixing for the classification of hyperspectral images at a finer spatial resolution[J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(3): 521–533.
- [9] Atkinson P M. Sub-pixel target mapping from soft-classified, remotely sensed imagery[J]. Photogrammetric Engineering and Remote Sensing, 2005, 71(7): 839–846.
- [10] Xu X, Zhong Y, Zhang L. Adaptive subpixel mapping based on a multiagent system for remote-sensing imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(2): 787–804.
- [11] Boucher A, Kyriakidis P C, Cronkite-Ratcliff C. Geostatistical solutions for super-resolution land cover mapping[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(1): 272–283.
- [12] Boucher A, Kyriakidis P C. Super-resolution land cover mapping with indicator geostatistics[J]. Remote Sensing of Environment, 2006, 104(3): 264–282.
- [13] Mertens K C, Verbeke L P C, Westra T, et al. Sub-pixel mapping and sub-pixel sharpening using neural network predicted wavelet coefficients[J]. Remote Sensing of Environment, 2004, 91(2): 225–236.
- [14] Tatem A J, Lewis H G, Atkinson P M, et al. Super-resolution land cover pattern prediction using a Hopfield neural network[J]. Remote Sensing of Environment, 2002, 79(1): 1–14.



- [15] Nguyen M Q, Atkinson P M, Lewis H G. Superresolution mapping using a Hopfield neural network with fused images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(3): 736 – 749.
- [16] Yanfeng G, Ye Z, Junping Z. Integration of spatial-spectral information for resolution enhancement in hyperspectral images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(5): 1347 – 1358.
- [17] Foody G M. Sharpening fuzzy classification output to refine the representation of sub-pixel land cover distribution[J]. International Journal of Remote Sensing, 1998, 19(13): 2593 – 2599.
- [18] Meng Y, Zhang D, Xiangchu F, et al. Fisher discrimination dictionary learning for sparse representation[A]. IEEE International Conference on Computer Vision (ICCV)[C]. Washington, D C: IEEE Computer Society, 2011. 543 – 550.
- [19] Elad M, Aharon M. Image denoising via sparse and redundant representations over learned dictionaries [J]. IEEE Transactions on Image Processing, 2006, 15(12): 3736 – 3745.
- [20] Mairal J, Sapiro G, Elad M. Learning multiscale sparse representations for image and video restoration[J]. Multiscale Modeling & Simulation, 2008, 7(1): 214 – 241.
- [21] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210 – 227.
- [22] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311 – 4322.
- [23] Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655 – 4666.
- [24] Congalton R G K G. Assessing the Accuracy of Remote Sensed Data: Principles and Practices[M]. New York: Lewis Publishers, 1999.


- [25] Cohen J. A coefficient of agreement for nominal scales[J]. Educational and Psychological Measurement, 1960, 20(1): 37 – 46.
- [26] Yu Y, Sun W. Target spectra guided spectral unmixing for hyperspectral images [J]. Chinese High Technology Letters, 2012, 22(3): 240 – 248.

#### 作者简介



**黄慧娟** 女, 1988 年 11 月出生于山东菏泽. 现为清华大学电子工程系博士研究生. 主要研究方向为图像处理与模式识别. 在国内外发表学术论文 6 篇、发明专利 2 项.

E-mail: hhj09@mails.tsinghua.edu.cn



**禹晶** 女, 1981 年 12 月出生于北京. 2011 年毕业于清华大学电子工程系、博士. 现为清华大学电子工程系博士后. 主要研究方向为图像处理与模式识别. 在国内外发表学术论文 50 余篇、发明专利 10 项.

E-mail: yujing@tsinghua.edu.cn



**孙卫东(通信作者)** 男, 1960 年 4 月出生于山东单县. 1988 年毕业于日本东京大学信息工程系、博士. 现为清华大学电子工程系教授、博士生导师. 主要研究方向为图像处理、模式识别、空间信息处理与应用. 在国内外发表学术论文 160 余篇、发明专利 12 项.

E-mail: wdsun@tsinghua.edu.cn