

基于局部连续性与全局相似性的光谱保持型亚像元映射

黄慧娟¹ 禹晶¹ 肖创柏² 孙卫东¹

摘要 遥感图像的像元级分类精度受混合像元的影响. 亚像元映射以像元分解获得的丰度值为基础, 在地物分布规律的约束下, 细化估计各类地物的亚像元级分布模式. 本文同时考虑了地物分布的空间与光谱信息, 提出了一种基于局部连续性与全局相似性的光谱保持型亚像元映射算法. 针对地物的空间分布特性, 提出了利用类内离散度对局部连续性进行建模, 并通过相似分布像元表示误差引入全局相似性约束项. 针对地物的光谱特性, 采用最小化光谱误差约束了亚像元映射过程中的光谱无失真性. 模拟数据与真实数据上的实验结果表明, 本文算法比其他同类算法具有更高的估计精度, 且更适合于实际应用.

关键词 亚像元映射, 像元分解, 局部连续性, 全局相似性, 光谱保持

引用格式 黄慧娟, 禹晶, 肖创柏, 孙卫东. 基于局部连续性与全局相似性的光谱保持型亚像元映射. 自动化学报, 2014, 40(8): 1612–1622

DOI 10.3724/SP.J.1004.2014.01612

Spectrum preserving Sub-pixel Mapping Based on Local Connectivity and Nonlocal Similarity

HUANG Hui-Juan¹ YU Jing¹ XIAO Chuang-Bai² SUN Wei-Dong¹

Abstract In remote sensing images, the accuracy of land cover classification at pixel scale is affected by mixed pixels greatly. Sub-pixel mapping tries to predict land-cover map at sub-pixel scale according to spectral unmixing abundances and some constraints of land-cover distribution patterns. In this paper, using both spatial and spectral information of land-cover, we propose a new spectrum preserving sub-pixel mapping algorithm based on local connectivity and as a constraint similarity. Spatially, local dependence is re-modeled by the with-in class scatter, nonlocal similarity is introduced by minimizing the representation errors among similar pixels. Spectrally, spectrum preserving is realized by minimizing the spectra errors in sub-pixel mapping. Comparative experiments with artificial and real images show that the proposed algorithm achieves a higher accuracy than other related algorithms, thus it is more suitable for practical application.

Key words Sub-pixel mapping, spectral unmixing, local dependence, nonlocal similarity, spectrum preserving

Citation Huang Hui-Juan, Yu Jing, Xiao Chuang-Bai, Sun Wei-Dong. Spectrum preserving sub-pixel mapping based on local connectivity and nonlocal similarity. *Acta Automatica Sinica*, 2014, 40(8): 1612–1622

由于成像传感器空间分辨率以及地物多样性的共同作用, 遥感图像中的单一像元通常是多种不同地物的混合体, 在空间与光谱上呈混合状态, 称为混合像元. 混合像元现象的存在直接导致像元级分类精度的降低, 特别是不同类别地物间过渡性边界的判定为定量解译与应用参数反演带来了极大困

难. 传统的硬分类算法将遥感图像中的每个像元划归为在该像元中所占比例最大的那类地物, 这不可避免地造成了信息丢失与分类精度的下降. 像元分解^[1–3]通过对混合像元的空间与光谱组成进行分析, 提取出纯净的地物像元, 称为端元, 同时估计各端元在混合像元中所占的比例, 称为丰度值, 图像中各端元的丰度值组成相应地物类别的丰度图. 像元分解仅能够精确估计出各端元在混合像元中所占比例, 却无法估计各端元在混合像元内的分布模式, 因而无法有效提高地物分类的精度.

1997年, Atkinson^[4]首次提出了亚像元映射的概念, 即以像元分解获得的丰度值为基础, 在地物分布规律的约束下, 估计各类地物的亚像元级分布模式, 也称为超分辨率映射^[5]. 亚像元映射是像元分解的后处理过程, 能够获得具有更高空间分辨率的地物分布图像, 提高地物分类精度. 地物分布规律是自然界中各类地物的分布模式所具有的相同或不同的规律, 是实现亚像元级地物分布图像细化估计的主

收稿日期 2013-06-17 录用日期 2014-04-18
Manuscript received June 17, 2013; accepted April 18, 2014
国家自然科学基金 (61171117), 国家科技支撑计划项目 (2012BAH31B01), 北京市教育委员会科技计划重点项目 (kz201310028035) 资助
Supported by National Natural Science Foundation (61171117), National Science and Technology Pillar Program (2012BAH31B01), Key Project of the Science and Technology Development Program of China (kz201310028035)
本文责任编辑 田捷
Recommended by Associate Editor TIAN Jie
1. 清华大学电子工程系 北京 100084 2. 北京工业大学计算机学院 北京 100124
1. Department of Electronic Engineering, Tsinghua University, Beijing 100084 2. Department of Computer, Beijing University of Technology, Beijing 100124

要依据. 近年来, 人们提出了诸多亚像元映射算法, 这些算法主要分为两类: 基于学习方法与基于空间最优化方法^[6]. 基于学习方法采用机器学习的方式预测像元内的地物分布模式^[7]. 这类方法的前提是存在与待处理低分辨率遥感图像中地物类型及分布都相似的高分辨率遥感图像, 然而在实际情况下通常难以获取这种额外辅助数据, 通过学习所获得的先验模型的普适性也值得考虑, 更为重要的是这种分布式隐性表达方式不利于引入地物分布的内在特点.

基于空间最优化方法使用目标函数对地物分布规律进行建模, 并通过最优化目标函数获取亚像元级地物分布图像. Mertens 等^[8] 根据邻域的丰度值提出了一种基于直接相邻模型的亚像元映射算法 (Direct-neighboring based sub-pixel mapping, DNSM), 将亚像元划归为其邻域内含量最多的那类地物. Mertens 等^[9] 提出一种基于亚像元/像元吸引模型的亚像元映射算法 (Sub-pixel/pixel attraction based sub-pixel mapping, SASM), 该算法将每个亚像元划归为对其具有最大吸引力的那类地物. Verhoeve 等^[10] 提出一种表示亚像元与其邻域像元之间相关性的模型, 并将亚像元映射问题转换为线性优化问题; Mertens 等^[11] 则采用了遗传算法来优化与文献 [10] 相同的目标函数. Atkinson^[12] 针对两类地物的亚像元映射问题, 提出了一种简单的亚像元交换策略. Villa 等^[13] 认为属于同一类地物的亚像元所组成区域的周长应该最短, 提出一种基于周长最小化模型的亚像元映射算法 (Perimeter minimum based sub-pixel mapping, PMSM). 基于空间最优化方法的关键在于如何描述地物分布规律以及如何对此描述进行准确合理的建模.

现有的算法通常仅在局部范围内针对地物分布规律的某个侧面描述进行简单建模, 且大多数算法采用合成丰度图来验证算法的精度, 无法有效应对真实遥感图像的复杂性. 本文提出了一种基于局部连续性与全局相似性的光谱保持型亚像元映射算法 (Local-nonlocal-spectral based sub-pixel mapping, LNSSM), 从局部、全局和光谱三个侧面约束地物的亚像元级分布模式. 针对地物的空间分布特性, 局部连续性是指相对于不同类别的地物而言, 同类地物之间的分布更加紧凑; 全局相似性是指当像元本身及其邻域的丰度值相似时, 像元内部的地物分布模式也相似. 本文通过类内离散度对局部连续性进行建模, 并通过最小化相似分布像元间的表示误差引入全局相似性. 亚像元映射将像元划分为一系列的亚像元, 并将每个亚像元映射为某一类地物, 即将连续的丰度值离散化, 这势必造成亚像元映射后的像元级光谱出现一定程度的失真, 但现

有算法均没有考虑这种失真. 针对地物的光谱特性, 本文采用最小化光谱误差来保持像元光谱的一致性. 同时, 本文将约束条件以正则项的形式叠加到目标函数中, 将亚像元映射问题转换为最优化问题, 采用模拟退火优化算法^[14] 进行最优化求解.

本文的主要内容安排如下: 第 1 节介绍亚像元映射的基本原理; 第 2 节详细阐述本文所提出的算法, 并给出了本文算法的整体算法流程; 第 3 节分别利用三组不同类型数据下的对比实验, 分析验证本文算法的有效性; 最后, 第 4 节给出本文的结论.

1 亚像元映射基本原理

基于多光谱或高光谱成像的对地观测技术可以同时获得地表地物的空间与光谱信息, 但由于现有光谱分光技术的限制以及地物多样性的共同作用, 导致遥感图像中的单一像元通常是多种地物的混合体, 在这种情况下, 不能简单地将其划归为任何一类地物. 像元分解通过一定的光谱混合模型估计各端元在混合像元中的丰度值, 常用的线性混合模型 (Linear mixing model, LMM) 可以表示为

$$\boldsymbol{\chi} = \sum_{c=1}^C \alpha_c \boldsymbol{s}_c + \boldsymbol{e} \quad (1)$$

其中, $\boldsymbol{\chi}$ 为混合像元光谱向量, \boldsymbol{s}_c 为第 c 类端元的光谱向量, α_c 为第 c 类端元的丰度值, C 为端元或地物类别总数, \boldsymbol{e} 为误差向量. 像元分解是通过最小化分解误差来获取端元光谱及丰度值^[2-3].

亚像元映射按照所给定的空间分辨率提升倍率将每个像元划分为一系列的亚像元, 并在每个亚像元均为纯净地物的假设前提下, 依据像元分解获得的丰度值及地物分布规律对每个亚像元的类别进行优化调整来获取合理的亚像元级地物分布图像, 从而达到细化地物分类尺度、提升地物分类精度的目的. 如图 1 所示, 图 1(a) 为像元分解所获得的“森林”类别的局部丰度图, 若给定空间分辨率提升倍率 $S = 2$, 则将每个像元划分为 2×2 个亚像元, 根据丰度值, 中心像元含有 50% 的“森林”和 50% 的“水体”, 因此应选定其中的 2 ($2 \times 2 \times 50\%$) 个亚像元划归为“森林”类别, 其余的 2 个亚像元划归为“水体”类别. 采用不同的数学模型会形成不同的空间分布模式, 根据地物分布规律, 一般认为图 1(c) 所示“森林”类别的亚像元级分布模式比图 1(b) 更为合理.

采用不同的地物分布规律描述方式可以建立不同的数学模型, 而模型的合理性决定了亚像元映射算法的精度和效率. DNSM 算法将待分类亚像元划归为其邻域中含量最多的地物类别, 能在较短时间内获得亚像元级地物分布图像, 但是由于该模型仅

对地物分布的局部连续性进行了简单建模,因此该算法的精度较低. SASM 算法在不同的尺度上将地物分布的局部连续性建模为像元与亚像元间的空间引力,距离较近且丰度值较大的像元对亚像元的空间引力更大,并将亚像元划归为对其具有最大引力的那类地物,该算法精度高于 DNSM 算法,但当多类地物对同一亚像元的引力相同时,其亚像元映射结果具有较大的不确定性. PMSM 算法认为地物分布的局部连续性意味着同类地物所组成区域的周长最小,据此建立了周长最小化的数学模型,该算法倾向于将地物收敛为圆形分布.目前的亚像元映射算法仅针对地物分布的局部连续性建立了相应的模型,但没有涉及亚像元映射造成的光谱失真问题.此外,大多数算法仅采用由已知的高分辨率地物分布图像合成丰度图来验证算法的精度,当将其应用于真实遥感图像时,由于大气效应、几何效应等成像环境会给像元分解等预处理过程带来影响,使得像元分解的精度下降,从而会导致亚像元映射精度严重下降^[15].

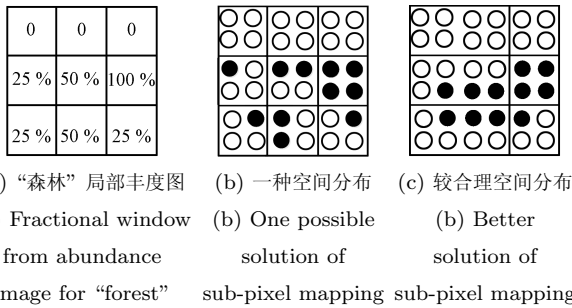


图 1 亚像元映射基本原理示意图
Fig. 1 Explanation of sub-pixel mapping

2 本文算法

本文提出的目标函数由局部、全局与光谱三方面的约束项构成,并采用了模拟退火算法对其进行最优化求解.

2.1 局部连续性模型

文献 [9–13] 针对局部范围内地物分布的连续性分别提出了不同的目标函数. 局部连续性是地物分布的重要特点,即在局部范围内相距较近像元相对于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^[9]. 从统计学的角度而言,类内离散度是衡量局部区域内地物分布紧凑性的重要测度之一,具有明确的物理含义,据此本文提出基于类内离散度来对局部连续性进行建模.

设 \mathbf{x} 为像元 q 内的地物分布模式, $\mathbf{p}_i^c, i = 1, 2, \dots, n_{\Omega}^c(\mathbf{x})$ 表示以该像元为中心的邻域 Ω 内属于第 c 类地物的亚像元坐标, $n_{\Omega}^c(\mathbf{x})$ 为该邻域内

属于第 c 类地物的亚像元数目, μ^c 表示 \mathbf{p}_i^c 的均值,基于类内离散度的局部连续性模型可表示为

$$\min_{\mathbf{x}} \sum_{c=1}^C \sum_{j=1}^{n_{\Omega}^c(\mathbf{x})} \|\mathbf{p}_j^c(\mathbf{x}) - \mu^c\|_2^2 \quad (2)$$

该模型意味着像元 q 内的最优地物分布模式应使得各类地物的类内离散度之和最小,即保证同类别的亚像元在空间上分布得更加紧凑.

更进一步,设 $\mathbf{p}_q^c(\mathbf{x})$ 和 $n_q^c(\mathbf{x})$ 分别表示像元 q 内属于第 c 类地物的亚像元坐标和数目, $\mathbf{p}_{\Omega \setminus q}^c$ 和 $n_{\Omega \setminus q}^c$ 分别表示该像元 8-邻域内属于第 c 类地物的亚像元坐标和数目, μ_q^c 和 $\mu_{\Omega \setminus q}^c$ 分别为 $\mathbf{p}_q^c(\mathbf{x})$ 和 $\mathbf{p}_{\Omega \setminus q}^c$ 的均值,其中, $\Omega \setminus q$ 表示以像元 q 为中心的邻域 Ω 内但不包含像元 q 的像元集合. 则式 (2) 可化简为

$$\min_{\mathbf{x}} \sum_{c=1}^C \left(\sum_{j=1}^{n_q^c(\mathbf{x})} \|\mathbf{p}_{q,j}^c(\mathbf{x}) - \mu_q^c\|_2^2 + \lambda \|\mu_q^c - \mu_{\Omega \setminus q}^c\|_2^2 \right) \quad (3)$$

式中, $\lambda = n_q^c(\mathbf{x})n_{\Omega \setminus q}^c / (n_q^c(\mathbf{x}) + n_{\Omega \setminus q}^c)$. 式 (3) 的物理含义为针对像元 q 的最优地物分布模式应满足该像元内各类地物的类内离散度之和最小,且同时满足与其 8-邻域 $\Omega \setminus q$ 内同类地物均值之间的距离值最小. 与式 (2) 相比,式 (3) 进一步降低了计算复杂度,减少了优化所需的时间.

设 $P_{\mathbf{x}} = [P_{\mathbf{x}}^1, \dots, P_{\mathbf{x}}^C, \sqrt{\lambda}M_q]$, $M_q = [\mu_q^1, \dots, \mu_q^C]$, $P_{\mathbf{x}}^c = [\mathbf{p}_{q,1}^c(\mathbf{x}), \dots, \mathbf{p}_{q,n_q^c(\mathbf{x})}^c(\mathbf{x})]$, $c = 1, \dots, C$, $M = [M_q^1, \dots, M_q^C, \sqrt{\lambda}M_{\Omega \setminus q}]$, $M_q^c = \mu_q^c \cdot \mathbf{1}$, $M_{\Omega \setminus q}^c = [\mu_{\Omega \setminus q}^c, \dots, \mu_{\Omega \setminus q}^c]$, 将式 (3) 用如下的矩阵形式简化表示为

$$\min_{\mathbf{x}} \|P_{\mathbf{x}} - M\|_F^2 \quad (4)$$


其中, $\mathbf{1}$ 为 $n_q^c(\mathbf{x})$ 维的行向量, $\|\cdot\|_F$ 表示 Frobenious 范数.

2.2 全局相似性模型

自然图像中存在诸多重复区域,其中蕴含的冗余信息可用来提升超分辨率重建图像的质量^[16–17]. 本文认为在自然图像中地物分布模式也存在同样的重复性,也就是说,当某些像元及其邻域的丰度值相似时,这些像元内部的地物分布模式也相似,本文将地物分布的这种特性称为全局相似性.

图 2 直观描述了空间分辨率提升倍率 $S = 2$ 情况下全局相似性的物理含义. 图 2(a) 中实线方格表示像元,虚线方格表示给定倍率下的亚像元. 从图 2 中可以看出,在整幅图像范围内以像元 q^l 为中心的邻域内丰度值和以像元 q 为中心的邻域内丰度值相似,因此在亚像元级上, q^l 为 q 的相似像元,像元 q

内的地物分布模式可由像元 q^l 内的地物分布模式线性表示.



(a) 像元 q 及其所属邻域的重复区域 q^l
(a) Pixel q and its repetitive pixels q^l

30 %	50 %	60 %	32 %	50 %	59 %
0	25 %	45 %	0	25 %	45 %
0	0	29 %	0	0	30 %
q			q^l		

(b) 以两像元为中心的邻域的丰度值

(b) Abundances of neighborhood centered on the two pixels

图 2 全局相似性的直观描述

Fig. 2 Explanation of nonlocal similarity

对于像元 q , 在整幅图像中搜索与其相似的像元, 即如果存在像元 q^l 满足 $\epsilon_l = \|\alpha_{q^l} - \alpha_q\|_2^2 \leq T_h$, 则认为该像元 q^l 为像元 q 的相似像元. 其中, α_q 是由以像元 q 为中心的邻域内的丰度值组成的向量, T_h 为判断像元相似程度的阈值. 选择前 L 个满足上述不等式的像元, 则像元 q 内的地物分布模式 \mathbf{x} 可由像元 $q^l, l = 1, 2, \dots, L$ 内的分布模式 \mathbf{x}_{q^l} 线性表示, 即 $\sum_{l=1}^L \beta_l \mathbf{x}_{q^l}$, 其中 β_l 是 ϵ_l 的归一化倒数. 本文提出的全局相似性模型可表示为

$$\min_{\mathbf{x}} \left\| \mathbf{x} - \sum_{l=1}^L \beta_l \mathbf{x}_{q^l} \right\|_2^2 \quad (5)$$

式中, \mathbf{x} 和 \mathbf{x}_{q^l} 分别为像元 q 和像元 q^l 内的地物分布模式. 式 (5) 通过最小化相似像元之间的表示误差来进一步约束像元 q 内的地物分布模式. 可以看出, 阈值 T_h 以及前 L 个像元具体个数的选取对像元相似程度以及模型的准确性会产生较大影响. 虽然从算法理论上难以确定最佳阈值 T_h 以及前 L 个像元的具体个数, 但一般来讲较小的阈值 T_h 可以期待较高的像元相似程度、较大的像元个数 L 会带来算法复杂度的增加. 通过大量实验结果对比分析, 本文认为设定阈值 $T_h = 0.005$, 并选取前 $L = 3$ 个相似像元可以满足绝大部分实际应用需求, 因此在后续实验中将采用上述实验性参数设定结论.

2.3 光谱一致性模型

亚像元映射借助像元分解获得的丰度值来提高

地物分类的精度, 生成亚像元级的地物分布图像. 在像元分解过程中, 获取丰度值的基本原则是使得重构光谱的误差最小. 将像元分解结果应用于亚像元映射时, 主要存在两个方面的问题.

一方面, 根据光谱重构误差最小原则获得的丰度值并不完全适合于以地物分类为目的的亚像元映射, 例如像元分解将公路上含有少量泥土的像元分解为“公路”与“泥土”两类物质的混合体, 但是这种物理上的混合体在地物分类中应被视为单一的地物类别. 为了解决这一问题, 本文将丰度大于 95% 的像元视为纯净像元.

另一方面, 像元分解所获得的丰度值是连续量, 而亚像元映射中每个亚像元均为纯净地物的假设前提实际上是将丰度值离散化, 这势必造成亚像元映射后逆向合成出的像元级光谱出现一定程度的失真, 为了保持亚像元映射前后的光谱一致性、减小光谱失真, 本文通过最小化光谱误差来约束像元 q 内的地物分布模式 \mathbf{x} , 光谱一致性模型可表示为

$$\min_{\mathbf{x}} \left\| \sum_{c=1}^C \frac{n_q^c(\mathbf{x}) \mathbf{s}_c}{S^2} - \boldsymbol{\chi} \right\|_2^2 \quad (6)$$

其中, $\boldsymbol{\chi}$ 为原多光谱或高光谱图像中像元 q 的光谱向量, \mathbf{s}_c 为第 c 类端元的光谱向量, $n_q^c(\mathbf{x})$ 为像元 q 内属于第 c 类地物的亚像元数目, S 为空间分辨率提升倍率. 式 (6) 的物理含义为最优的地物分布模式, 应使得亚像元映射后像元级光谱失真最小.

2.4 本文算法整体流程

本文将上述局部、全局和光谱三方面的约束项合并为目标函数, 将亚像元映射问题转化为最优化问题. 本文提出的目标函数为

$$\min_{\mathbf{x}} \|P_{\mathbf{x}} - M\|_F^2 + \eta_1 \left\| \mathbf{x} - \sum_{l=1}^L \beta_l \mathbf{x}_{q^l} \right\|_2^2 + \eta_2 \left\| \sum_{c=1}^C \frac{n_q^c(\mathbf{x}) \mathbf{s}_c}{S^2} - \boldsymbol{\chi} \right\|_2^2 \quad (7)$$

其中, 前两项分别为局部连续性约束项与全局相似性约束项, 第三项为光谱一致性约束项, η_1 、 η_2 是常数, 用于控制正则项在目标函数中的权重, 它们的取值对算法的性能会产生重要的影响, 因此需要合理设定 η_1 与 η_2 的取值, 当 η_1 或 η_2 取值较小时, 它们所对应正则项对算法结果的影响将会很小, 而当 η_1 或 η_2 的取值较大时, 将会过惩罚它们所对应的正则项, 且确定两个正则化参数取值的复杂度要高于仅有一个正则化参数的情况, 本文将在第 3 节实验中进一步细化讨论参数设置的基本原则及其实际取值.

对于式 (7) 中的目标函数, 本文采用模拟退火算法进行优化求解. 模拟退火优化算法是一种通用概率算法, 起源于对热力学中退火过程的模拟, 即在某一给定初始温度下, 通过缓慢下降温度参数, 使算法能够在多项式时间内, 收敛至一个近似最优解^[14]. 给定模拟退火算法迭代过程的初值, 在每次迭代过程中对像元内的地物分布模式进行一次小的调整, 如果该调整使得目标函数值下降, 那么接受这样的调整; 否则, 将按一定的概率拒绝调整. 重复迭代过程直至目标函数值不再下降或达到预先设置的迭代次数.

关于模拟退火算法初值的选取, 在本文算法中, 对待处理的低分辨率多光谱或高光谱图像进行像元分解, 提取端元光谱以及估计各端元的丰度值, 按照给定的空间分辨率提升倍率 S 将每个像元划分为相应数目的亚像元, 并根据丰度值随机生成一幅亚像元级地物分布图像, 将该图像作为模拟退火算法迭代过程的初始值. 模拟退火优化算法能够避免陷入局部极值点, 得到较为合理的准全局最优解.

3 实验结果与分析

为了验证本文算法的有效性, 实验中分别采用了模拟图像、AVIRIS (Airborne visible infrared imaging spectrometer) 合成丰度图和 TM (Thematic mapper) 多光谱图像 3 组不同类型的数据, 将本文的 LNSSM 算法与 DNSM 算法、SASM 算法、PMSM 算法进行比较与分析, 并对 3 组实验的结果进行了定性定量评价. 其中, DNSM 算法和 SASM 算法经过单次运算就能得到亚像元映射结果, PMSM 算法和本文 LNSSM 算法需采用模拟退火优化算法迭代获取亚像元映射结果. 实验中为了公平起见, SASM 算法采用了文献 [9] 中具有最高精度的象限型邻域和归一化吸引力, PMSM 算法和本文所提 LNSSM 算法的迭代次数均设定为 5 次. 本文 LNSSM 算法的目标函数式 (7) 中包含两个正则化参数 η_1 和 η_2 , 其中, η_1 所对应的全局相似性约束项是利用图像的全局信息来进一步优化地物分布模式, 是局部相关性约束项的补充, 因此 η_1 取值不宜过大; 而 η_2 所对应的光谱一致性约束项直接反映了亚像元映射算法的光谱保持能力, 也即亚像元映射结果与实际地物组成的统一性, 因此 η_2 取值应当充分. 根据上述参数选取基本原则以及大量实际实验结果, 实验中本文设置 $\eta_1 = 0.2$, $\eta_2 = 1$.

基于混淆矩阵的正确分类率 (Percent correctly classified, PCC)^[18]、Kappa 系数 κ ^[19]、生产者精度 (Producer's accuracy, PA)、用户精度 (User's accuracy, UA) 是定量评价亚像元映射性能的常用指标. PCC 为正确分类的亚像元数目与全部亚像元

数目的比值, 即 $PCC = \sum_{c=1}^C p_{cc}/p$, p_{cc} 为混淆矩阵中的对角线取值, p 为全部亚像元的数目. κ 为评价交互可靠性的统计度量, 其具体计算方法为 $\kappa = \left(p \sum_{c=1}^C p_{cc} - \sum_{c=1}^C p_{c+} p_{+c} \right) / \left(p^2 - \sum_{c=1}^C p_{c+} p_{+c} \right)$, p_{c+} 为混淆矩阵中第 c 行的所有亚像元数目, p_{+c} 为混淆矩阵中第 c 列的所有亚像元数目^[19], 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, 即 $PA = p_{cc}/p_{+c}$. 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, 即 $UA = p_{cc}/p_{c+}$. 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, 无法真实反映亚像元映射算法的有效性, 因此本文仅采用混合像元来得到修正混淆矩阵, 并采用基于该修正混淆矩阵的修正正确分类率 PCC* (Adjusted PCC)、修正 Kappa 系数 κ^* (Adjusted Kappa) 以及修正平均生产者精度 APA* (Adjusted average of producer's accuracy) 和修正平均用户精度 AUA* (Adjusted average of user's accuracy) 这 4 种评价指标来评价亚像元映射算法的精度. 同时, 为了验证本文算法的实际可用性, 在实验中对 4 种算法的运行时间 (Time) 进行了对比分析.

3.1 模拟图像下的对比实验

为了评价理想状态下亚像元映射算法自身的精度, 避免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^[9]. 合成策略包含三个步骤: 1) 对已知的高分辨率遥感图像进行像元级分类, 获得原始硬分类图像; 2) 对该分类图像进行下采样处理, 生成包含纯净与混合像元的低分辨率图像; 3) 依据原始硬分类图像, 对低分辨率图像中的每一像元计算各类端元的丰度值, 并将该丰度值作为像元分解的结果. 在采用合成策略中, 由于每一像元内属于每类地物的亚像元数目 $n_q^c(\mathbf{x})$ 能够被准确确定, 即不存在像元级光谱失真, 因此在采用合成策略的相关实验中略去了式 (7) 所示目标函数中的光谱一致性约束项. 合成策略不仅可以为亚像元映射提供所需要的丰度图, 还可以提供高分辨率参考图像, 为亚像元映射结果的定量评价提供依据.

第 1 组实验中的高分辨率参考图像包含目标与背景两类地物, 如图 3 所示, 采用了 3 种几何形状代表简单的地物分布模式, 以便对亚像元映射结果进行更为直观的主观评价. 图 3(a) 为亚像元映射的高分辨率参考图像, 其中黑色像元为目标地

物 (C1)、白色像元为背景地物 (C2). 图 3(b) 所示为对图 3(a) 进行 3 倍下采样而生成的合成丰度图. 图 3(c)~(f) 分别为提升倍率为 3 情况下的 DNSM、SASM、PMSM 以及本文 LNSSM 算法的亚像元映射结果. 为了便于从视觉上对这 4 种算法的亚像元映射结果进行比较, 图 3(g) 对各图像中的部分区域 (图 3(a) 所示长方形区域) 进行了细节放大显示. 由图 3 可以看出, 本文 LNSSM 算法的结果优于 DNSM、SASM 和 PMSM 算法的结果. 表 1 给出了 4 种评价指标下的定量比较结果, 其中, 黑体标出数值为各评价指标下的最优值. 由表 1 可以看出, LNSSM 算法的 PCC^* 、 κ^* 、 APA^* 和 AUA^* 值明显高于其他三种算法. 通过定性与定量评价可以看出, DNSM 算法精度最低, SASM 算法的精度略高于 DNSM 算法, 但其单一吸引力的作用使得类边界处出现了诸多毛刺, LNSSM 算法在两类边界的

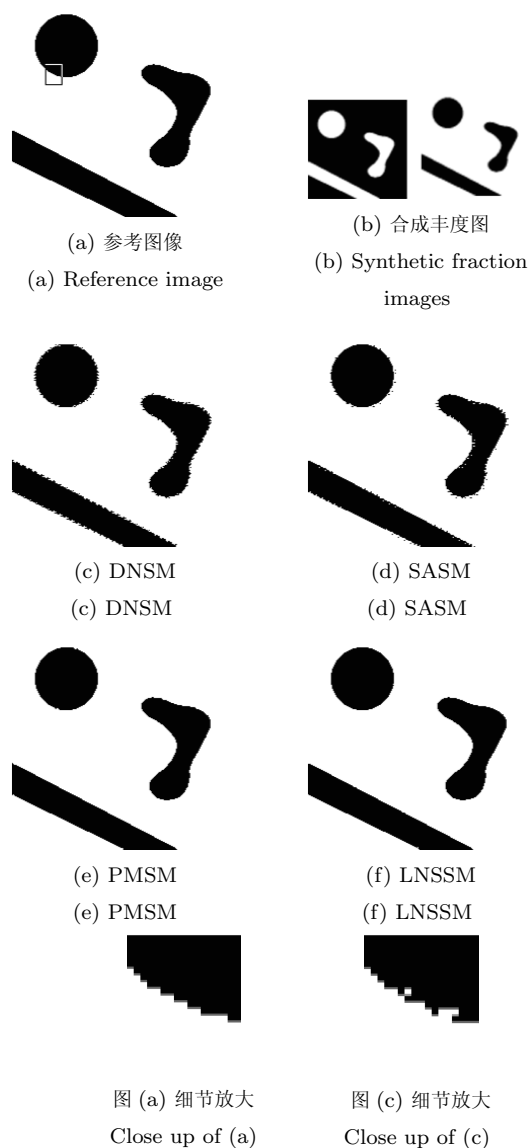


图 (d) 细节放大 图 (e) 细节放大 图 (f) 细节放大
Close up of (d) Close up of (e) Close up of (f)

(g) 图 (a)、(c)~(f) 的局部细节放大图
(g) Close up of (a)、(c)~(f)

图 3 模拟图像下的亚像元映射结果对比

Fig. 3 Sub-pixel mapping results with the artificial image

映射结果, PMSM 算法在每一次迭代中都需要计算局部范围内每类地物的周长, 所需运行时间最长, 而本文算法通过式 (3) 大大降低了式 (2) 的计算复杂度, 因此本文算法虽然也采用了模拟退火算法, 但仍能在较短时间内获得亚像元映射的结果, 具有实际可用性.

表 1 各模拟图像下的定量对比分析结果

Table 1 Quantitative evaluation of sub-pixel mapping results with the artificial image

评价指标	DNSM	SASM	PMSM	LNSSM
PCC^*	0.8023	0.8841	0.9885	0.9943
κ^*	0.6472	0.7682	0.9770	0.9885
APA^*	0.8024	0.8841	0.9885	0.9942
AUA^*	0.8024	0.8841	0.9885	0.9942
Time (s)	40.19	45.91	2791.94	67.09

3.2 AVIRIS 合成丰度图下的对比实验

为了更接近真实的地物分布模式, 本组实验采用了地物类别数量及分布模式更加复杂的遥感图像. 实验中, 首先, 对两幅真实 AVIRIS 高光谱遥感图像进行分类, 形成高分辨率地物分布图像; 然后, 依据合成策略生成合成丰度图. 采用合成策略除了可为定量评价提供参考依据外, 还能够避免真实遥感成像时, 大气或几何效应对像元分解过程所可能产生的影响, 更好体现算法本身的评价精度^[15].

第一幅 AVIRIS 图像为 Blackhawk 岛的高光谱遥感图像, 图像尺寸为 210×210 , 空间分辨率为 20 m, 光谱分辨率为 10 nm. AVIRIS 图像共有 224 个光谱波段, 其中某一波段如图 4(a) 所示. 本实验选取了受噪声影响小的 100 个连续波段, 并采用 ISODATA (Iterative self-organizing data analysis technique algorithm) 无监督分类算法对其进行分类, 继而进行形态学滤波处理, 所得高分辨率地物分布图像如图 4(b) 所示. 图 4(c) 为采用合成策略对图 4(b) 进行 3 倍下采样生成的 4 类地物丰度图. 图 4(d)~(g) 分别为提升倍率为 3 情况下的 DNSM、SASM、PMSM 和 LNSSM 四种算法的亚

像元映射结果, 图 4(h) 对各图像的局部区域 (S1 和 S2) 进行了细节放大显示.

根据合成策略, 本文将图 4(b) 所示图像作为参考图像来定量评价亚像元映射算法的精度. 如图 4(d) 所示, DNSM 算法不能很好保持较小的地物结构, 尤其在各类地物边界处的表现较差, 其亚像元映射结果与参考图像的差异较大. SASM 算法所得亚像元级地物分布图像如图 4(e) 所示, 各类地物的边界处存在诸多毛刺, 与实际不符. 从图 4(h) 可以看到, PMSM 算法倾向于将地物分布收敛为圆形, 这在类边界处尤为明显 (S1 区域), 且对于较复杂的地物分布模式 (S2 区域), PMSM 算法不能很好地保持地物分布的结构, 而本文 LNSSM 算法的结果与参考图像最为接近, 能够保持大多数的地物结构, 尤其在保持较细的线状结构以及类边界处理上效果显著. 表 2 给出了 4 种评价指标下的定量比较结果, 从表 2 中可以看出, LNSSM 算法的 PCC^* 、 κ^* 与 APA^* 评价指标均达到最高值. 而 LNSSM 算法的 AUA^* 指标略低于 PMSM 算法的具体原因如下, 在参考图像中属于 C1、C2、C3 和 C4 类地物的亚像元数目分别为 619、3 333、3 913 和 2 224, 可以看出, C1 类地物的含量远少于其他三类地物, 即可视为小样本. 一般来讲, 当样本数量足够多时, 用户精度更具统计意义, 并且更为稳定、可靠; 但当样本数量较少时, 用户精度失去其原有的统计意义, 此时正确分类数目作为一种辅助评价指标可以进一步起到对算法性能进行细化分析的作用. 对于样本数量较多的 C2、C3、C4 类地物, LNSSM 算法的用户精度分别为 0.8782、0.8554 和 0.8880, 均优于 PMSM 算法相应的结果 0.8534、0.8314 和 0.8862. 对于样本数量较少的 C1 类地物, 虽然 LNSSM 算法的用户精度 0.8013 略低于 PMSM 算法的用户精度 0.8569,

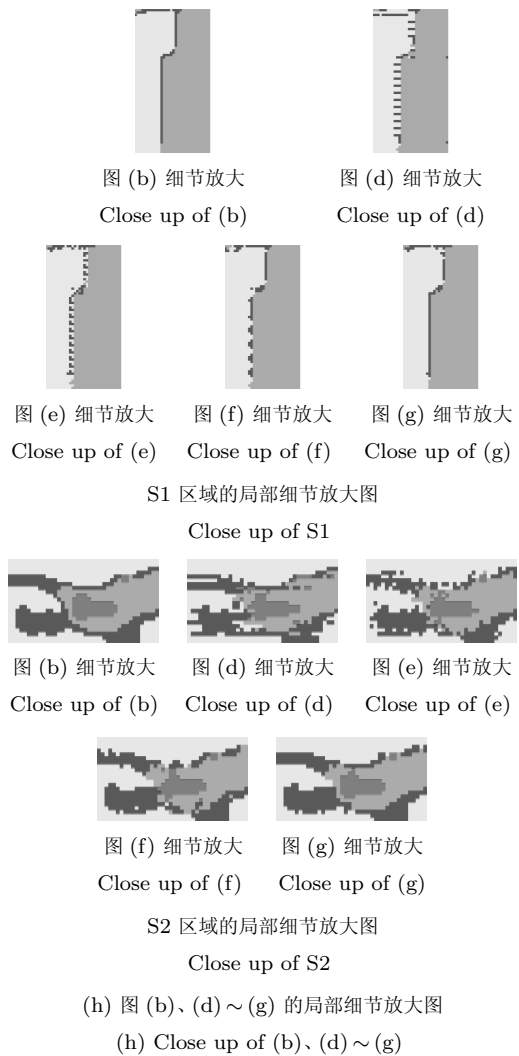
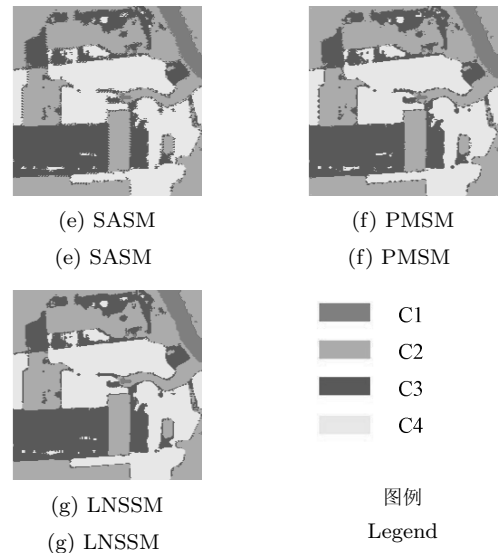
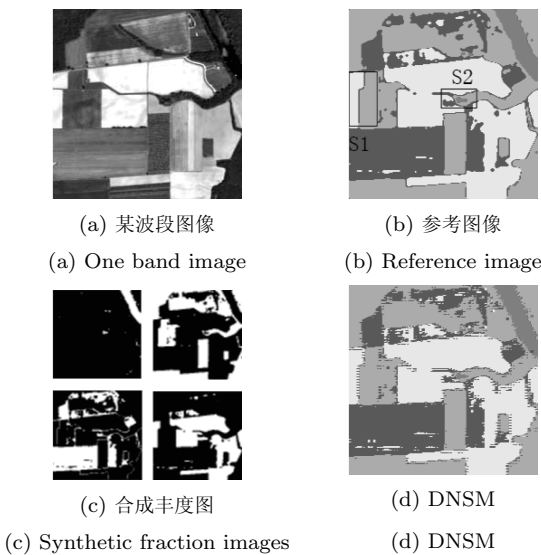


图 4 AVIRIS 合成丰度图下的亚像元映射结果对比
Fig. 4 Sub-pixel mapping results with the AVIRIS synthetic fraction images

但 LNSSM 算法正确划归为 C1 类地物的亚像元个数 496 要高于 PMSM 算法下的相应个数 443, 因此在此情形下仍可以认为 LNSSM 算法性能优于 PMSM 算法. 主观与客观的评价结果均表明本文对地物分布规律的描述与实际情况相符, 能够获得更为合理的亚像元级地物分布图像. 此外, 从表 2 中运算时间对比可以明显看出, 对于地物类别数量及分布模式更加复杂的遥感图像, DNSM、SASM 和本文 LNSSM 算法的运算时间较短, 而 PMSM 算法的运算时间急剧增加, 因此相比于其他三种算法而言, 本文算法不仅精度高而且适合于实际应用.

表 2 AVIRIS 合成丰度图下的定量对比分析结果

Table 2 Quantitative evaluation of sub-pixel mapping results with the AVIRIS synthetic fraction images

评价指标	DNSM	SASM	PMSM	LNSSM
PCC*	0.7006	0.7408	0.8511	0.8668
κ^*	0.5657	0.6244	0.7822	0.8064
APA*	0.6897	0.7416	0.8230	0.8557
AUA*	0.6784	0.7306	0.8570	0.8557
Time (s)	60.33	67.38	28 732.37	443.70

图 5(a) 为第二幅 AVIRIS 图像中的某一波段, 图 5(c) 为对图 5(b) 所示高分辨率地物分布图像进行 3 倍下采样生成的合成丰度图. 图 5(d)~(g) 分别为提升倍率为 3 情况下的 DNSM、SASM、PMSM 和 LNSSM 四种算法的亚像元映射结果. 图 5(h) 对各图像的区域 (S1 和 S2) 进行了细节放大显示. 如图 5(d) 所示, DNSM 算法的结果最差, 不能保持大多数的地物结构. PMSM 算法的结果优于 SASM 算法, 但其类边界仍然不够平滑. 从视觉效果来看, 本文 LNSSM 算法的结果与参考图像最为接近. 表 3 为 4 种精度评价指标和运算时间下的定量比较结果, 可以看出, LNSSM 算法的 PCC*、 κ^* 、APA* 和 AUA* 评价指标均达到最高值, 与定性评价结果一致, 而且本文算法的运算时间与 DNSM 算法和 SASM 算法具有一定的可比性, 远优于 PMSM 算法, 该实验进一步验证了本文所提算法的有效性.

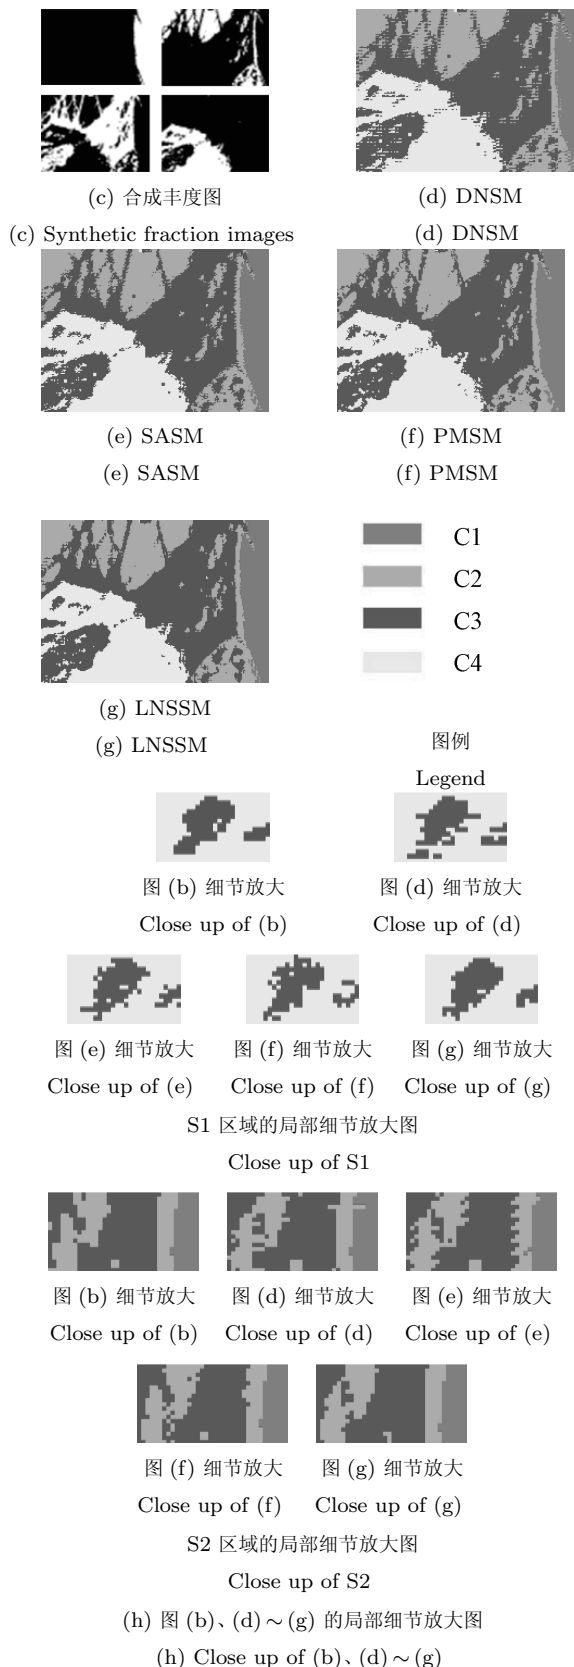



图 5 AVIRIS 合成丰度图下的亚像元映射结果对比
Fig. 5 Sub-pixel mapping results with the AVIRIS synthetic fraction images

3.3 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干扰的情况下,对亚像元映射算法本身的评价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遥感图像下亚像元映射算法的实际有效性.本组实验对北京密云地区的 Landsat-TM 多光谱图像进行亚像元映射,该图像的空间分辨率为 30 m.同时,为了能够对亚像元映射结果进行定量评价,本组实验采用了同一区域、同一时相的 Spot-4 多光谱图像作为高分辨率参考图像,其空间分辨率为 20 m.对于仅包含“水域”、“土壤”、“植被”三种自然物类别的研究区域,可以认为 Spot-4 图像中相应区域的像元为纯净像元,相同地域与相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 图像进行了配准,并采用 ISODATA 无监督分类算法对图 6(c) 所示的配准后 Spot-4 图像进行了像元级分类,所获得的分类图像如图 6(d) 所示,将其用作参考图像来评价亚像元映射算法的精度.实验中,为了确保 TM 与 Spot-4 图像空间分辨率间的 2 倍关系,将 TM 图像降采样至 40 m 分辨率,降采样后的 TM 图像如图 6(a) 所示.采用文献 [1] 算法对 TM 图像进行像元分解,相应的“水域(C1)”、“土壤(C2)”、“植被(C3)”三类地物的丰度图如图 6(b) 所示.分别采用 DNSM、SASM、PMSM 以及 LNSSM 算法进行提升倍率为 2 的亚像元映射,并对所得结果进行定量评价.

表 3 AVIRIS 合成丰度图下的定量对比分析结果

Table 3 Quantitative evaluation of sub-pixel mapping results with the AVIRIS synthetic fraction images

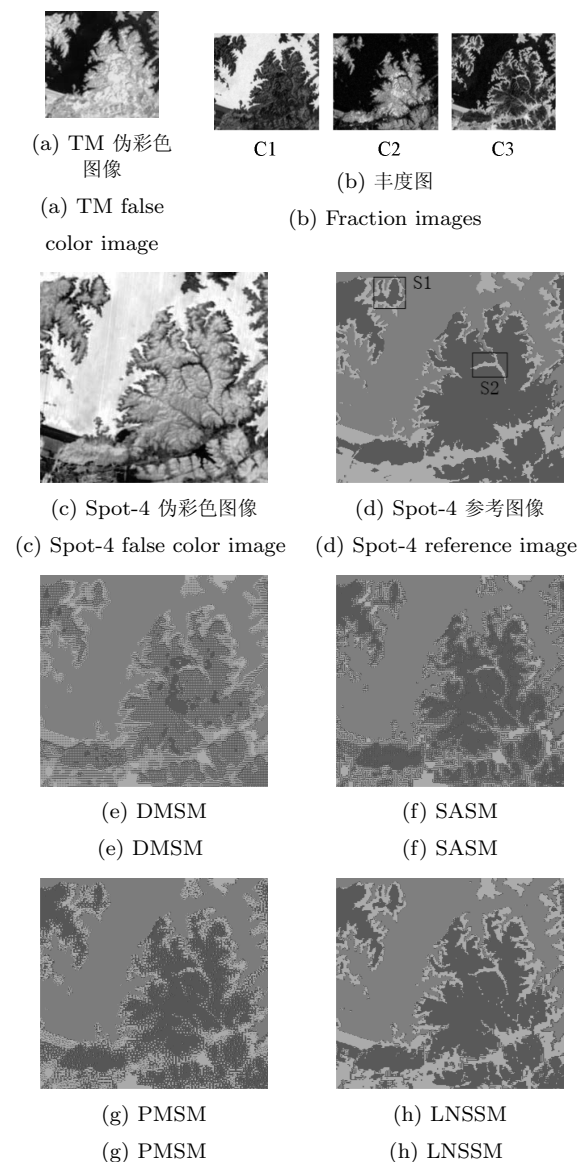
评价指标	DNSM	SASM	PMSM	LNSSM
PCC*	0.6871	0.7612	0.7867	0.8355
κ^*	0.5111	0.6269	0.6665	0.7427
APA*	0.6928	0.7699	0.8050	0.8422
AUA*	0.6916	0.7686	0.8050	0.8422
Time (s)	43.97	47.68	17289	181.46

图 6(e)~(h) 所示为这 4 种算法所获得的 2 倍率地物分布图像.图 6(i) 为各图像 S1 和 S2 区域的细节放大图.从图 6 可以看出, LNSSM 算法所得地物分布图像与图 6(d) 所示参考图像最为接近,其他三种算法将一些纯净像元映射为包含多种地物的混合像元,导致它们的结果与参考图像相差较大.由图 6(i) 所示细节放大图可以清楚地看出, DNSM 算法不能有效保持地物分布的结构,原本连通的区域被分裂为细小的带状区域. SASM 与 PMSM 算法所得图像的类边界不平滑,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,所得结果与实际地物分布模式差异较大.

表 4 给出了 4 种亚像元映射算法的定量评价结果和运算时间对比结果,从表 4 中可以看出,本文的 LNSSM 算法在 4 种评价指标下均取得了最大值,其中,在 κ^* 指标上 LNSSM 算法相对于 DNSM、SASM、PMSM 算法分别提高了 43.87%、31.46%、25.02%,而且运算时间远少于 PMSM 算法,这表明在真实遥感图像下,本文算法在性能指标上远优于其他三种算法.

为了进一步验证 LNSSM 算法的光谱保持能力,本文对亚像元映射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 6(e)~(h) 中各像元的光谱值,并将其与原 TM 图像相应像元的光谱值进行比较,二者的欧氏距离为光谱误差.图 7 所示为 1000 个随机选取像元的光谱误差.对于 DNSM、SASM、PMSM 和 LNSSM 算法,光谱误



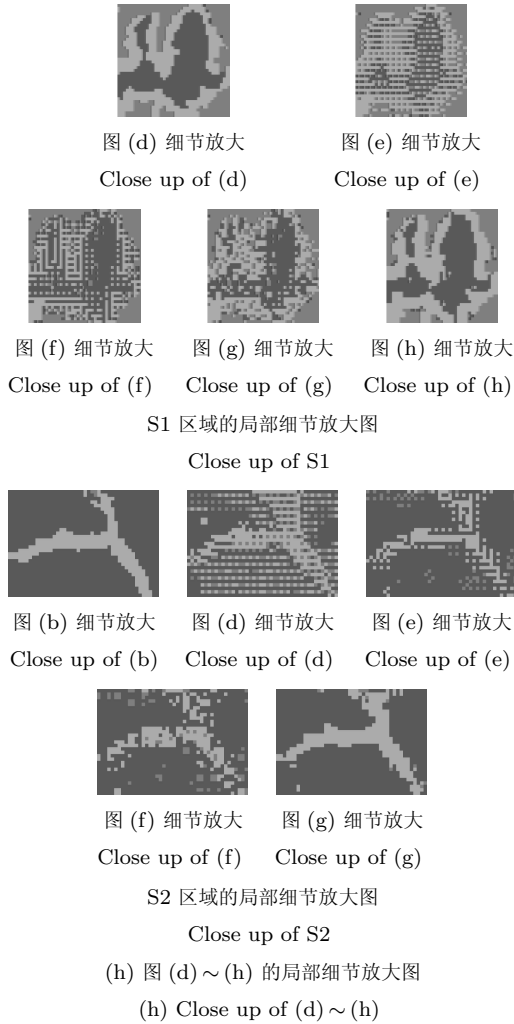


图 6 TM 多光谱图像下的亚像元映射结果对比
Fig. 6 Sub-pixel mapping results with the TM multispectral image

差均值分别为 0.2383、0.2167、0.2167 和 0.1872, 方差分别为 0.0032、0.0034、0.0034 和 0.0024。可以看出, LNSSM 算法的光谱误差最小, 与原图像最为接近, 这表明本文算法具有最优的光谱保持能力。

表 4 TM 多光谱图像下的定量对比分析结果

Table 4 Quantitative evaluation of sub-pixel mapping results with the TM multispectral image

评价指标	DNSM	SASM	PMSM	LNSSM
PCC*	0.5193	0.6737	0.6907	0.8436
κ^*	0.2698	0.3939	0.4583	0.7085
APA*	0.5602	0.6012	0.6473	0.7935
AUA*	0.5099	0.5775	0.5944	0.8240
Time (s)	94.56	109.25	8121	291.10

4 结论

本文提出了一种基于局部连续性与全局相似性

的光谱保持型亚像元映射算法。该算法利用类内离散度对局部连续性进行建模, 通过最小化相似分布像元间的表示误差引入全局相似性约束项, 采用最小化光谱误差约束了光谱不失真性。本文提出的目标函数由局部、全局与光谱三方面的约束项构成, 将亚像元映射问题转换为最优化问题, 并采用模拟退火优化算法进行最优化求解, 通过迭代获取亚像元级地物分布图像。模拟与真实数据下的三组不同类型对比实验表明, 与其他同类算法相比本文算法具有更高的精度, 尤其在应用于真实遥感图像时, 本文算法能够获得更符合实际的亚像元级地物分布图像。





图 7 亚像元映射算法的光谱保持能力对比分析
Fig. 7 Spectral errors of 1000 randomly selected pixels

References

- 1 Yu Yue, Sun Wei-Dong. Target spectra guided spectral unmixing for hyperspectral images. *Chinese High Technology Letters*, 2012, **22**(3): 240–248
(于钺, 孙卫东. 目标光谱指导下的高光谱图像混合像元分解方法. 高技术通讯, 2012, **22**(3): 240–248)
- 2 Bioucas-Dias J M, Plaza A, Dobigeon N, Parente M, Du Q, Gader P, Chanussot J. Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, **5**(2): 354–379
- 3 Zhu F Y, Wang Y, Xiang S M, Fan B, Pan C H. Structured sparse method for hyperspectral unmixing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, **88**: 101–118
- 4 Atkinson P M. Mapping sub-pixel boundaries from remote sensed images. In: *Proceedings of the Innovations in GIS 4*. London, UK: Taylor & Francis, 1997. 166–180
- 5 Muad A M, Foody G M. Super-resolution mapping of lakes from imagery with a coarse spatial and fine temporal resolution. *International Journal of Applied Earth Observation and Geoinformation*, 2012, **15**: 79–91
- 6 Atkinson P M. Issues of uncertainty in super-resolution mapping and their implications for the design of an inter-comparison study. *International Journal of Remote Sensing*, 2009, **30**(20): 5293–5308

- 7 Boucher A, Kyriakidis P C, Cronkite-Ratcliff C. Geostatistical solutions for super-resolution land cover mapping. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(1): 272–283
- 8 Mertens K C, De Baets B, Verbeke L P C, De Wulf R R. Direct sub-pixel mapping exploiting spatial dependence. In: Proceedings of IEEE International Symposium on Geoscience and Remote Sensing. New York, USA: IEEE, 2004, **5**: 3046–3049
- 9 Mertens K C, de Baets B, Verbeke L P C, de Wulf R R. A sub-pixel mapping algorithm based on sub-pixel/pixel spatial attraction models. *International Journal of Remote Sensing*, 2006, **27**(15): 3293–3310
- 10 Verhoeve J, De Wulf R. Land cover mapping at sub-pixel scales using linear optimization techniques. *Remote Sensing of Environment*, 2002, **79**(1): 96–104
- 11 Mertens K C, Verbeke L P C, Ducheyne E I, De Wulf R R. Using genetic algorithms in sub-pixel mapping. *International Journal of Remote Sensing*, 2003, **24**(21): 4241–4247
- 12 Atkinson P M. Sub-pixel target mapping from soft-classified, remotely sensed imagery. *Photogrammetric Engineering and Remote Sensing*, 2005, **71**(7): 839–846
- 13 Villa A, Chanussot J, Benediktsson J A, Jutten C. Spectral unmixing for the classification of hyperspectral images at a finer spatial resolution. *IEEE Journal of Selected Topics in Signal Processing*, 2011, **5**(3): 521–533
- 14 Metropolis N, Rosenbluth A W, Rosenbluth M N, Teller A H, Teller E. Equation of state calculations by fast computing machines. *Journal of Physics*, 1958, **21**: 1087–1092
- 15 Zhong Y F, Zhang L P. Remote sensing image subpixel mapping based on adaptive differential evolution. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2012, **42**(5): 1306–1329
- 16 Dong W S, Zhang D, Shi G M, Wu X L. Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization. *IEEE Transactions on Image Processing*, 2011, **20**(7): 1838–1857
- 17 Pan Z X, Yu J, Huang H J, Hu S X, Zhang A W, Ma H B, Sun W D. Super-resolution based on compressive sensing and structural self-similarity for remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **51**(9): 4864–4876
- 18 Congalton R G, Green K. *Assessing the Accuracy of Remote Sensed Data: Principles and Practices*. New York: Lewis Publishers, 1999
- 19 Cohen J. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 1960, **20**: 37–46



黄慧娟 清华大学电子工程系博士研究生. 2009 年获得山东大学信息科学与工程学院学士学位. 主要研究方向为图像处理与模式识别. 本文通信作者.

E-mail: hhj09@mails.tsinghua.edu.cn
(**HUANG Hui-Juan** Ph.D. candidate in the Department of Electronic Engineering, Tsinghua University. She received her bachelor degree from Institute of Information Science and Engineering, Shandong University in 2009. Her research interest covers image processing and pattern recognition. Corresponding author of this paper.)



禹晶 清华大学电子工程系博士后. 2011 年获清华大学电子工程系博士学位. 主要研究方向为图像处理与模式识别. E-mail: yujing@tsinghua.edu.cn

(**YU Jing** Postdoctor in the Department of Electronic Engineering, Tsinghua University. She received her Ph. D. degree from Department of Electronic Engineering, Tsinghua University. Her research interest covers image processing and pattern recognition.)



肖创柏 北京工业大学计算机学院教授. 1995 年获得清华大学博士学位. 主要研究方向为数字信号处理, 音视频信号处理, 网络通信.

E-mail: cbxiao@bjut.edu.cn
(**XIAO Chuang-Bai** Professor at the College of Computer Science and Technology, Beijing University of Technology. He received his Ph. D. degree in pattern recognition and intelligent control from Tsinghua University in 1995. His research interest covers digital signal processing, audio and video signal processing, and network communication.)



孙卫东 清华大学电子工程系教授. 主要研究方向为图像处理, 模式识别, 空间信息处理与应用.

E-mail: wdsun@tsinghua.edu.cn
(**SUN Wei-Dong** Professor in the Department of Electronic Engineering, Tsinghua University. His research interest covers image processing, pattern recognition, spatial information processing and application.)