

融合简单线性迭代聚类的高光谱混合像元分解策略

张飞飞^{1,2}, 孙旭^{2*}, 薛良勇³, 高连如², 刘长星¹

(1.西安科技大学测绘科学与技术学院, 西安 710054; 2.中国科学院遥感与数字地球研究所, 北京 100094;
3.中国矿业大学计算机科学与技术学院, 徐州 221116)

摘要: 高光谱图像中的混合像元问题广泛存在, 混合像元的分解效率一直是遥感应用研究的难点和热点。目前成熟的端元提取算法有纯像元指数(pure pixel index, PPI)、内部最大体积法(N-FINDR)、顶点成分分析(vertex component analysis, VCA)、顺序最大角凸锥(sequential maximum angle convex cone, SMACC)、交替最大体积法(alternating volume maximization, AVMAX)、最小体积封闭单形体(minimum volume enclosing simplex, MVES)等, 这些算法从图像所有像元中提取纯光谱, 具有提取速度慢、精度不高的缺点。为此, 该文引入了一种融合简单线性迭代聚类(simple linear iterative clustering, SLIC)超像元分割的高光谱混合像元分解算法。超像元分割技术能够将具有相似特征的相邻像元组成图像块, 并保留进一步进行图像处理的有效信息, 从而大幅减少参与端元提取的像元数量, 为解决上述问题提供了有效的途径。通过试验对比了降维方式(主成分分析和最大噪声分数)、RGB对应关系(6种)、色彩空间RGB(red, green, blue)和LAB(lightness-A-B)、数据格式(JPG, BIN)和算法参数K对高光谱图像超像元分割结果的影响, 并进一步分析了SLIC超像元分割结果对2种典型端元提取算法(AVMAX、MVES)产生的不同效果。试验结果表明, 随着K值的增大, 混合像元分解的时间逐渐增加, 均方根误差(root mean square error, RMSE)持平或减少, 而JPG(有损压缩)数据格式的时间始终比BIN(无损压缩)数据格式的要短。SLIC+MVES的RMSE略高于MVES的RMSE, 低于AVMAX的RMSE, 但时间远小于MVES。当K足够大的时候, SLIC+MVES的效果就近似MVES的效果了。在大部分情况下, 最大噪声分数的降维效果优于主成分分析。以最大噪声分数作为降维方法、以JPG作为数据格式、以LAB作为色彩空间对混合像元分解结果较为有利。另外, SLIC的参数K的取值在5~10之间较为合适。该研究中的SLIC超像元分割算法简单易行, 并且提高了混合像元分解的效率, 具备很好的实用价值。

关键词: 像元; 光谱分析; 算法; 简单线性迭代聚类; 超像元

doi: 10.11975/j.issn.1002-6819.2015.17.026

中图分类号: S127; TP79

文献标志码: A

文章编号: 1002-6819(2015)-17-0199-08

张飞飞, 孙旭, 薛良勇, 高连如, 刘长星. 融合简单线性迭代聚类的高光谱混合像元分解策略[J]. 农业工程学报, 2015, 31(17): 199—206. doi: 10.11975/j.issn.1002-6819.2015.17.026 <http://www.tcsae.org>

Zhang Feifei, Sun Xu, Xue Liangyong, Gao Lianru, Liu Changxing. Hyperspectral mixed pixel decomposition policy merging simple linear iterative clustering[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2015, 31(17): 199—206. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2015.17.026 <http://www.tcsae.org>

0 引言

图像中每个像元往往包含不同的地物类型, 若一个像元仅包含一种地物, 则该像元称为纯像元; 若一个像元包含不止一种地物, 则该像元称为混合像元。由于地物具有不同的辐射特性, 纯像元易于识别, 而混合像元无论归属到哪一种地物都是错误的, 因为它至少不完全属于这种地物^[1]。混合像元的存在是传统的像元级遥感分类和面积量测精度难以达到使用要求的主要原因, 而成像光谱仪的数据获取方式使得混合像元在高光谱遥感图像中更加普遍^[2]。混合像元问题不仅是遥感技术量化深

入发展的重要障碍, 还严重影响计算机处理的效果和在计算机技术在遥感领域中的应用^[3]。提高遥感影像应用的精度, 必须解决混合像元问题。

端元提取和丰度估计是混合像元分解的两个重要的过程。端元提取是指在混合图像中提取出各种成分。具有代表性的算法有: 纯像元指数(pure pixel index, PPI)、内部最大体积法(N-FINDR)、顶点成分分析(vertex component analysis, VCA)、顺序最大角凸锥(sequential maximum angle convex cone, SMACC)、交替最大体积法(alternating volume maximization, AVMAX)、最小体积封闭单形体(minimum volume enclosing simplex, MVES)。它们均采用了几何学端元提取的基本思想, 但具体方法不同, 也有各自的优缺点。PPI是利用几何学分析的方法提取图像端元的雏形^[4]。N-FINDR是利用高光谱数据在特征空间中的凸面单形体的特殊结构, 通过寻找具有最大体积的单形体从而自动获取图像中的所有端元^[5]。VCA是从高光谱数据中非监督提取端元的算法^[6]。

收稿日期: 2015-04-20 修订日期: 2015-07-21

基金项目: 国家自然科学基金青年基金项目(41201356)

作者简介: 张飞飞, 女, 主要从事超像元分割方面的研究。西安 西安科技大学测绘科学与技术学院, 710054。Email: 843110467@qq.com

※通信作者: 孙旭, 男, 研究员, 主要从事高光谱图像信息提取方面的研究。北京 中国科学院遥感与数字地球研究所, 100094。

Email: sunxu@radi.ac.cn

SMACC 可以在提取端元的同时得到丰度反演的结果^[7]。最小体积封闭单形体法将体积最小化问题转化成了若干个线性规划问题,使得端元提取问题能够利用已有的线性规划问题的算法求解,因此速度比较慢^[8]。交替最大体积法绕开了线性规划问题来提取端元,因此速度比较快^[9]。丰度估计是指对每种估计出来的端元物质的比例加以估计,该算法最常用的有:无约束最小二乘法、“和为 1”约束最小二乘法、“非负”约束最小二乘法和全约束最小二乘法^[10]。在遥感图像处理中一般采用线性混合模型进行混合像元分解。在线性光谱混合模型的基础上,目前采用 PPI、N-FINDR、VCA、SMACC、AVMAX、MVES 等端元提取算法。这些算法从图像所有像元中提取纯光谱,具有 2 个缺点:1) 端元提取的速度慢。所有像元的光谱都参与运算,因此运算量较大,导致端元提取的速度减慢。2) 端元提取的精度低。单个像元光谱存在着系统引入的随机噪声和测量误差等,直接影响端元的提取精度^[11]。

为了解决上述混合像元分解问题,本文引入简单线性迭代聚类(simple linear iterative clustering, SLIC)算法。Ren 等^[12]最早提出了超像元这一概念,被 Greg^[13]应用于身体模型估计和骨架化。所谓的超像元,是指具有相似颜色、纹理、光谱等特征的相邻像元组成的图像块。超像元提供了一种便捷的方式来处理图像,它利用像元之间特征的相似程度将像元分组,可以获取图像的冗余信息,在很大程度上降低了后续图像处理任务的复杂度。因此,超像元分割是解决大尺度高光谱遥感图像端元提取效率问题的有效途径。David R. Thompson 等将超像元分割中的 Graph-based 与端元提取中的 SMACC 相结合,在超像元端元提取方面做出了重要的探索^[14]。超像元生成算法大致可分为两大类:基于图论的方法和基于梯度上升的方法。基于图论的方法有:Graph-based 方法、Normalized cuts 方法、Superpixel lattice 方法等。基于梯度上升的方法有:分水岭(Watersheds)方法、MeanShift 方法、Quick-shift 方法、Turbopixels 和 SLIC 方法等。其中 Graph-based 使用最小生成树的思想来分割图像^[15]。Normalized cuts 利用轮廓特征和纹理特征来全局最小化代价函数^[16]。Superpixel lattice 是保持了图像的拓扑结构信息,但性能严重依赖于预先提取的图像边界^[17]。Watersheds 是基于拓扑理论的数学形态学分割方法^[18]。MeanShift 是一个迭代的过程,能产生形状规则的超像元^[19]。Quick-shift 也是个迭代的过程,但它比 MeanShift 的速度快。Turbopixels 是基于几何流的水平集方法^[20]。SLIC 是基于距离和颜色的相似性进行超像元的分割,该方法思想简单,可以产生大小均匀、形状规则的超像元^[21]。

本文使用 SLIC 超像元分割,是因为 SLIC 算法能够减少后续计算的复杂度,从而提高混合像元分解的效率。本文首先介绍 SLIC 超像元分割原理、线性混合像元分解模型和 2 种端元提取算法(AVMAX、MVES),然后使用 2 组不同的高光谱影像进行试验,最后比较和

分析基于 SLIC 超像元和基于像元的混合像元分解结果。

1 研究方法

1.1 SLIC 超像元分割

SLIC 采用的是局部像元聚类,计算像元之间的相似性,进而进行超像元分割。该像元是 5 维特征向量,分别是颜色空间 L , a , b 的数值以及像元的坐标值 (x, y) 。其中 L 表示亮度, a 是表示从红色至绿色的范围, b 表示从蓝色至黄色的范围, (x, y) 是指像元的位置。输入一个与超像元数目相关的参数 K 和一个平衡参数 M , 假设一张图像有 N 个像元点, 每个超像元的大小约为 N/K 个像元, 那么每 2 个相邻的超像元之间的距离 $s = \sqrt{N/K}$ 。对于图像中的每一个像元, 在计算像元之间的相似性时, 首先计算距离最近的若干像元之间的相似性, 由近到远依次计算每个像元之间的相似性, 给相似性最高的像元标签。然后对图像像元进行局部聚类, 只有当像元出现在搜索的范围内, 才能计算出像元之间的相似程度。此时, 限定像元的搜索空间是以标签像元为中心的 $2s \times 2s$ 区域, 而不是在整张图像中寻找。限定搜索范围是提高算法运算速度的关键所在。

当每一个像元被赋予与其最为相似的像元标签后, 更新每个聚类的中心, 同一个聚类内的所有像元的 C_j 平均值 ($C_j = [L_i, a_i, b_i, x_i, y_i]$) 作为新的聚类中心。对于上述过程不断地更新聚类, 至到收敛为止。相似度的衡量关系如式 (1) 所示:

$$\begin{aligned} d_{lab} &= \sqrt{(l_{i_0} - l_{j_0})^2 + (a_{i_0} - a_{j_0})^2 + (b_{i_0} - b_{j_0})^2} \\ d_{xy} &= \sqrt{(x_{i_0} - x_{j_0})^2 + (y_{i_0} - y_{j_0})^2} \\ D_s &= d_{lab} + \frac{M}{s} \cdot d_{xy} \end{aligned} \quad (1)$$

式中: d_{lab} 为像元点间的颜色差异; d_{xy} 为像元点间的空间距离; D_s 为 2 个像元的相似度; i_0 表示有标签的像元; j_0 表示没有标签的像元; s 为 2 个相邻超像元之间的距离; M 为平衡参数, 用来衡量颜色值与空间信息在相似度衡量中的比例。

1.2 混合像元分解

线性混合模型比较简单, 并且在多数情况下是有效的, 因此在遥感图像处理中一般采用线性混合模型进行光谱解混合。本文采用的端元提取算法是交替最大体积法和最小体积单形体法, 而后用全约束最小二乘法进行丰度反演。

1.2.1 线性光谱混合模型

假设包含 n 个像元的 L 波段高光谱图像 $\{r_i\}_{i=1}^n$ 中包含 m 个端元 $\{e_j\}_{j=1}^m$, 并认为每个像元和端元均为 L 维 (列) 向量, 则线性光谱混合模型如式 (2) 所示:

$$r_i = \sum_{j=1}^m \alpha_{ij} e_j + \varepsilon_i \quad (2)$$

式中： α_{ij} 表示第 j 个端元在第 i 个像元中的丰度； ε_i 为误差项。

由于 α_{ij} 的物理意义是第 j 个端元在第 i 个像元中所占的面积比例，因此 α_{ij} 要服从如下约束条件：

$$\alpha_{ij} \geq 0, \forall i, j \quad (3)$$

$$\sum_{j=1}^m \alpha_{ij} = 1, i = 1, 2, \dots, n \quad (4)$$

式中：式 (3) 称为“非负”约束，式 (4) 称为“和为 1”约束。

1.2.2 交替最大体积法

交替最大体积算法是寻找包含所有像元点的体积最大的单形体来获得端元。通过对最大体积模型(5)进行改造，然后绕开线性规划问题来完成端元提取。

$$\begin{aligned} \max_{\tilde{\mathbf{v}}_J, J=1, \dots, m} \quad & V(\{\tilde{\mathbf{v}}_J\}_{J=1}^m) \\ \text{s.t.} \quad & \tilde{\mathbf{v}}_J \in \text{conv}\{\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n\} \end{aligned} \quad (5)$$

$$\begin{aligned} \max_{\tilde{\mathbf{v}}_p} \quad & |\mathbf{b}_p^T \tilde{\mathbf{v}}_p + (-1)^{m+p} \det(\mathbf{V}_{mp})| \\ \text{s.t.} \quad & \tilde{\mathbf{v}}_p \in \text{conv}\{\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n\} \end{aligned} \quad (6)$$

式中： $\{\tilde{\mathbf{r}}_i\}_{i=1}^n$ 表示 L 波段高光谱图像 $\{\mathbf{r}_i\}_{i=1}^n$ 通过数据降维后得到的 \tilde{L} 维向量集； $\tilde{\mathbf{v}}_J$ 表示第 J 个单形体的体积。

$$\mathbf{b}_J = [(-1)^{1+p} \det(\mathbf{V}_{1p}), (-1)^{2+p} \det(\mathbf{V}_{2p}), \dots, (-1)^{m+1+p} \det(\mathbf{V}_{(m-1)p})] \in \mathbf{R}^{m-1}$$

对最大体积模型 (5) 进行改造得到式 (6)，其中 $\det(\mathbf{V}_{mp})$ 为 $\det(\Delta(\{\tilde{\mathbf{v}}_J\}_{J=1}^m))$ 中第 m 行、第 p 列元素的余子式。 $(-1)^{m+p} \det(\mathbf{V}_{mp})$ 对于优化变量 $\tilde{\mathbf{v}}_p$ 是个常数，不失一般性，可以将其从目标函数中消去，得到：

$$\begin{aligned} \max_{\tilde{\mathbf{v}}_p} \quad & |\mathbf{b}_p^T \tilde{\mathbf{v}}_p| \\ \text{s.t.} \quad & \tilde{\mathbf{v}}_p \in \text{conv}\{\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n\} \end{aligned} \quad (7)$$

进而，可以去掉式 (7) 中的绝对值，得到：

$$\begin{aligned} \max_{\tilde{\mathbf{v}}_p} \quad & \mathbf{b}_p^T \tilde{\mathbf{v}}_p \\ \text{s.t.} \quad & \tilde{\mathbf{v}}_p \in \text{conv}\{\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n\} \end{aligned} \quad (8)$$

不难发现，式 (8) 的最优解一定是式 (7) 的最优解。这是因为，若存在 $\tilde{\mathbf{v}}_p^* \in \text{conv}\{\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n\}$ 是式 (7) 的最优解，则对于任意 $\tilde{\mathbf{v}}_p \in \text{conv}\{\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n\}$ ，都有 $\mathbf{b}_p^T \tilde{\mathbf{v}}_p^* \geq |\mathbf{b}_p^T \tilde{\mathbf{v}}_p| \geq \mathbf{b}_p^T \tilde{\mathbf{v}}_p$ 。而 $\mathbf{b}_p^T \tilde{\mathbf{v}}_p^* = \mathbf{b}_p^T \tilde{\mathbf{v}}_p^*$ 或 $-\mathbf{b}_p^T \tilde{\mathbf{v}}_p^*$ ，并且显然 $\pm \tilde{\mathbf{v}}_p^* \in \text{conv}\{\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n\}$ ，所以 $\tilde{\mathbf{v}}_p^*$ 或 $-\tilde{\mathbf{v}}_p^*$ 为式 (8) 的最优解。

由于 $\tilde{\mathbf{v}}_p = \tilde{\mathbf{R}}\boldsymbol{\theta}_p$ ，则式 (8) 的目标函数：

$$\mathbf{b}_p^T \tilde{\mathbf{v}}_p = \mathbf{b}_p^T \tilde{\mathbf{R}}\boldsymbol{\theta}_p = \sum_{i=1}^n \theta_{ip} \mathbf{b}_p^T \tilde{\mathbf{r}}_i \leq \max\{\mathbf{b}_p^T \tilde{\mathbf{r}}_i\} \quad (9)$$

若记 $q = \arg \max_i \{\mathbf{b}_p^T \tilde{\mathbf{r}}_i\}$ ，则当 $\tilde{\mathbf{v}}_p = \tilde{\mathbf{r}}_p \in \text{conv}\{\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n\}$ 时等号成立，因此式(8)可简化为：

$$\max_{i=1,2,\dots,n} \mathbf{b}_p^T \tilde{\mathbf{r}}_i \quad (10)$$

式中： $\mathbf{R} = [\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \dots, \tilde{\mathbf{r}}_n]$ 为降维后的图像矩阵； $\boldsymbol{\theta}_p \in \mathbf{R}$ 。

由于 AVMAX 是迭代算法，因此需要一组初始 $\{\tilde{\mathbf{v}}_J\}_{J=1}^m$ 和一个能够使算法停止的收敛判定准则。初始 $\{\tilde{\mathbf{v}}_J\}_{J=1}^m$ 可以从 $\{\tilde{\mathbf{r}}_i\}_{i=1}^n$ 中随机选择 m 个得到， m 表示端元个数。每求解一次，就是对 $\{\tilde{\mathbf{v}}_J\}_{J=1}^m$ 中的一个元素进行了优化，但对 $\{\tilde{\mathbf{v}}_J\}_{J=1}^m$ 中的每一个一次优化后，可得到一组新的 $\{\tilde{\mathbf{v}}_J\}_{J=1}^m$ 。但新的 $\det(\Delta(\{\tilde{\mathbf{v}}_J\}_{J=1}^m))$ 相对于上一次迭代，改进非常少时，可以认为算法收敛。

1.2.3 最小体积封闭单形体

最小体积封闭单形体算法是通过寻找包含所有像元点的体积最小的单形体来获得端元。通过对最小体积模型 (11) 进行改造，把一个端元提取问题分解为若干个线性规划问题，利用现有的求解线性规划问题的方法完成端元提取。

$$\begin{aligned} \min_{\tilde{\mathbf{v}}_J, J=1, \dots, m} \quad & V(\{\tilde{\mathbf{v}}_J\}_{J=1}^m) \\ \text{s.t.} \quad & \tilde{\mathbf{r}}_i \in \text{conv}\{\tilde{\mathbf{v}}_1, \tilde{\mathbf{v}}_2, \dots, \tilde{\mathbf{v}}_m\} \end{aligned} \quad (11)$$

由 $\Delta(\{\tilde{\mathbf{v}}_J\}_{J=1}^m) = [\tilde{\mathbf{v}}_1 - \tilde{\mathbf{v}}_m, \tilde{\mathbf{v}}_2 - \tilde{\mathbf{v}}_m, \dots, \tilde{\mathbf{v}}_{m-1} - \tilde{\mathbf{v}}_m]$ ，可令 $\mathbf{B} = [\tilde{\mathbf{v}}_1 - \tilde{\mathbf{v}}_m, \tilde{\mathbf{v}}_2 - \tilde{\mathbf{v}}_m, \dots, \tilde{\mathbf{v}}_{m-1} - \tilde{\mathbf{v}}_m]$ 得

$$\tilde{\mathbf{r}}_i = \sum_{J=1}^m \alpha_{iJ} \mathbf{v}_J = \mathbf{v}_m + \mathbf{B}\boldsymbol{\alpha}_i' \quad (12)$$

其中 $\boldsymbol{\alpha}_i' = [\alpha_{i1}, \alpha_{i2}, \dots, \alpha_{i,m-1}]^T$ ；相应的， $\alpha_{im} = 1 - \mathbf{I}_{m-1}^T \boldsymbol{\alpha}_i'$ 。于是，可以改写为

$$\begin{aligned} \min_{\mathbf{B}, \mathbf{v}_m, \boldsymbol{\alpha}_i', i=1, \dots, m} \quad & |\det(\mathbf{B})| \\ \boldsymbol{\alpha}_i' \in \mathbf{R}_+^{m-1} \\ \text{s.t.} \quad & 1 - \mathbf{I}_{m-1}^T \boldsymbol{\alpha}_i' \geq 0 \\ & \tilde{\mathbf{r}}_i = \tilde{\mathbf{v}}_m + \mathbf{B}\boldsymbol{\alpha}_i' \end{aligned} \quad (13)$$

由于式 (13) 中的目标函数中有绝对值运算，仍然不是线性函数，因此将式 (13) 拆分为如下 2 个最优化问题

$$\begin{aligned} \bar{\omega} = \max_{h_p^T, g_p} \quad & \sum_{q=1}^{m-1} (-1)^{p+q} h_{pq} \det(\mathbf{H}_{pq}) \\ \text{s.t.} \quad & 0 \leq \mathbf{h}_p^T \tilde{\mathbf{r}}_i - g_p \leq 1 - \sum_{p \neq q} (\mathbf{h}_p^T \tilde{\mathbf{r}}_i - g_p), \forall i \\ \underline{\omega} = \min_{h_p^T, g_p} \quad & \sum_{q=1}^{m-1} (-1)^{p+q} h_{pq} \det(\mathbf{H}_{pq}) \\ \text{s.t.} \quad & 0 \leq \mathbf{h}_p^T \tilde{\mathbf{r}}_i - g_p \leq 1 - \sum_{p \neq q} (\mathbf{h}_p^T \tilde{\mathbf{r}}_i - g_p), \forall i \end{aligned} \quad (14)$$

式中： h_{pq} 为 \mathbf{H} 中的第 p 行、第 q 列； $\det(\mathbf{H}_{pq})$ 为 h_{pq} 的余子式， $\det(\mathbf{H}) = \sum_{q=1}^{m-1} (-1)^{p+q} h_{pq} \det(\mathbf{H}_{pq})$ ； \mathbf{h}_p^T 表示 \mathbf{H} 中的第 p 行； g_p 表示 \mathbf{g} 中第 p 个分量。

此时，这两个最优化问题均为线性规划，可用现有的线性规划算法求解。通过比较式 (14) 的 2 个解的绝对值 $|\bar{\omega}|, |\underline{\omega}|$ ，可以获得 (13) 的最优解。

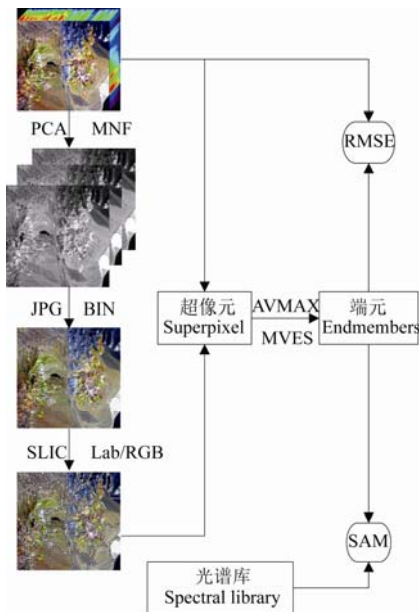
2 试验

本文采用上述 SLIC 超像元分割算法和基于线性混合模型的 2 种端元提取算法 (AVMAX 和 MVES) 进行试验。

2.1 试验步骤

根据伯克利标准数据库 (Berkeley benchmark dataset) [22] 中的试验得出, $M=10$ 既能在感官经验上满足颜色距离最大化, 又能很好的在颜色和空间相似度上平衡。SLIC 算法唯一需要设置参数 K , K 不能为 1, 因此在本试验中 $K=2,3,\dots,12$ 。

对模拟数据和试验数据进行以下处理: 该研究没有选择任何特定波段作为 RGB, 而是对高光谱图像分别进行 PCA 和 MNF 降维处理, 后取前 3 个波段 Red、Green、Blue, 因为这 3 个波段保留了高光谱图像的多波段信息, 此方法的合理性是本研究的重点目的之一。计算机的显示设备只能用 RGB 的不同数值合成各种颜色。然后对他们进行排列组合形成 6 个不同的图像为 123、132、213、231、312、321 (1 代表 R, 2 代表 G, 3 代表 B), 每个图像都是 3 个波段, 分别以 JPG (有损压缩) 和 BIN (无损压缩) 格式的图像保存; 而 SLIC 算法需要将图像从 RGB 色彩空间转换到 CIELAB 色彩空间, 但事实上, 高光谱图像经过降维后 3 个波段的数值并不是原始意义的 Red、Green 和 Blue, 因此进行色彩空间转换的必要性也值得考虑。不同降维方式 (主成分分析和最大噪声分数)、不同 RGB 对应关系 (6 种)、不同数据保存格式 (BIN 和 JPG)、不同色彩空间 (RGB 和 Lab)、不同 K 值 (11 种) 和不同端元提取算法 (AVMAX 和 MVES), 共进行 1056 组试验。并用混合像元分解模型进行试验, 试验流程图如图 1 所示。



注: PCA 为主成分分析; MNF 为最大噪声分数; JPG 为有损压缩; BIN 为无损压缩; SLIC 为简单线性迭代聚类; Lab 为 lightness-A-B; RGB 为 red、green、blue; RMSE 为均方根误差; SAM 为光谱角。
Note: PCA is principal components analysis; MNF is minimum noise fraction; JPG is loss compression; BIN is lossless compression; SLIC is simple linear iterative clustering; Lab is lightness-A-B; RGB is red, green, blue; RMSE is root-mean-square error; SAM is spectral angle mapper.

图 1 试验流程图

Fig.1 Experiment flow chart

2.2 评价结果

本文中的试验结果采用均方根误差 (RMSE, root-mean-square error) 和光谱角 (SAM, spectral angle

mapper) 评价。

2.2.1 均方根误差

对端元完备程度及丰度反演结果的评价就是判断提取的端元是否足以包含图像的绝大部分信息, 通常是利用提取的端元和反演的丰度重新混合成反混图像, 然后比较反混图像与原图像的差异程度 [23]。差异程度用 2 个图像的均方根误差表示:

$$\text{RMSE}(\{r_i\}_{i=1}^n, \{e_j\}_{j=1}^m) = \frac{1}{n} \sum_{i=1}^n \sqrt{\frac{1}{L} \|r_i - \hat{r}_i\|_2^2} \quad (15)$$

式中: $\{r_i\}_{i=1}^n$ 为反混图像, 即

$$\hat{r}_i = \sum_{j=1}^m \hat{\alpha}_{ij} e_j \quad (16)$$

RMSE 的值越小, 说明 2 个图像差异越小, 进而说明端元提取和丰度反演的信息量损失越少, 即端元的完备程度及丰度反演结果越好。

2.2.2 光谱角

光谱角是测试光谱与参考光谱 (通过实验室测量或野外测量获得) 之间的夹角, 利用它表示测试光谱与参考光谱之间的相似性 [24]。光谱夹角越小, 说明两者的相似性越大, 计算公式如下:

$$\text{SAM}(L_1^*, L_2^*) = \arccos \left(\frac{L_1^* L_2^*}{\|L_1^*\|^2 \times \|L_2^*\|^2} \right) \quad (17)$$

式中: L_1^* 和 L_2^* 分别为参考光谱和测试光谱的波谱曲线。

2.3 试验数据

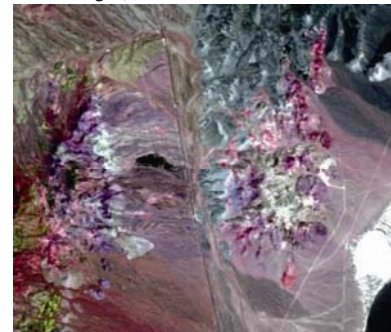
2.3.1 模拟数据

本文所采用的模拟图像是由 USGS 的 veg_1dry.s 光谱库中的 9 个端元光谱和对应的丰度经过混合而成的图像, 从 400~2 500 nm 221 波段 100×100 像元的数据, 可见光和近红外的分辨率分别为 4 和 10 nm, 其中丰度是人为规定的, 并按照 100:1 的信噪比加入高斯白噪声, 得到的模拟数据 [25]。模拟图像如图 2a 所示。



a. 模拟图像

a. Simulation image (R:band45, G:band65, B:band101)



b. 实际图像

b. Actual image (R:band183, G:band193, B:band207)

图 2 模拟图像和实际图像的真彩色合成

Fig.2 True color synthesis for simulation and experiment image

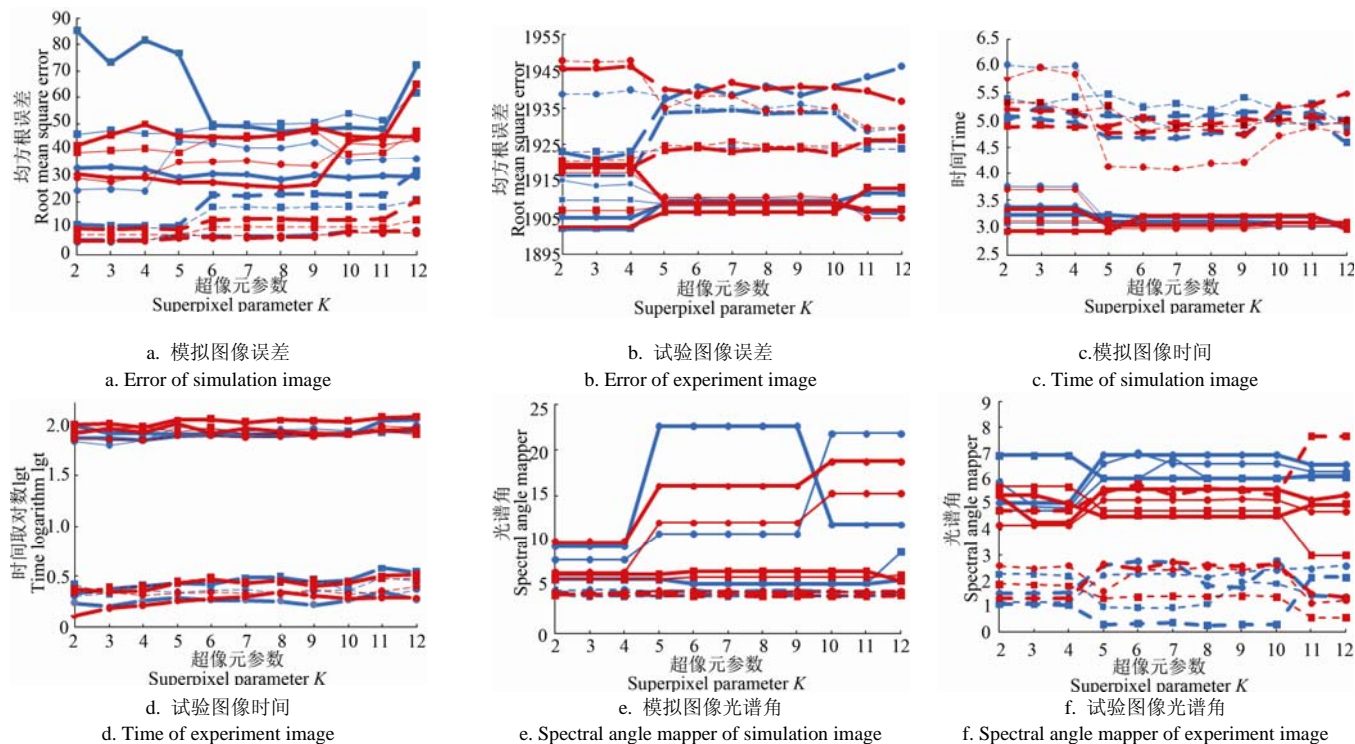
2.3.2 实际数据

本文所采用的实际数据是美国内华达州 Cuprite 地区 1995 年成像的从 $1.9908 \sim 2.4790 \mu\text{m}$ 50 波段 400×350 像元 AVIRIS (airborne visible infrared imaging spectrometer) 数据, 这组数据在高光谱图像端元提取方法的研究中广泛应用, 具有很好的代表性。实际图像如图 2b 所示。

3 结果与分析

3.1 试验结果

按照图 1 的流程图进行试验。其中模拟数据提取的端元数目是 9 个端元, 而试验数据提取的端元数目是 8 个端元。对得到的 6 个时间和误差取平均数, 得到图 3 和表 1 中的结果, 而时间只表示从超像元分割到端元提取这段的时间。



注: 蓝色表示 PCA 压缩方式, 红色表示 MNF 压缩方式; 圆点表示压缩后的图像以 JPG 格式保存, 而方块表示压缩后的图像以 BIN 格式保存; 粗线表示采用 RGB 形式的超像元分割, 细线表示采用 Lab 形式的超像元分割; 虚线表示用 AVMAX 算法进行端元提取, 实线表示用 MVES 算法进行端元提取。

Note: Blue said PCA compression method, red said MNF compression method; dot indicates the compressed image was saved in JPG format, and squares denote the compressed image was saved in BIN format; thick line indicates the RGB form super pixel segmentation and thin lines indicate in the Lab in the form of super pixel segmentation; dotted line represents the AVMAX algorithm used for endmember extraction, solid lines represent with MVES algorithm for endmember extraction.

图 3 模拟图像和试验图像的误差、时间、光谱角

Fig.3 Error, time, spectral angle mapper of simulation and experiment image

3.2 试验结果分析

从图 3a 和图 3b 中的曲线可以看出, 随着 K 值的增加, RMSE 逐渐减小或持平, 并且 MVES 的 RMSE 总是比 AVMAX 的 RMSE 小。这是因为随着 K 值的增大, 超像元的数量不断的增多, 超像元的尺寸不断减小并接近一个正常像元。SLIC+MVES 的 RMSE 略高于 MVES 的 RMSE, 低于 AVMAX 的 RMSE, 但时间远小于 MVES。也就是说, SLIC+MVES 相对于 MVES, 在牺牲少量精度的代价下, 极大提高了运算速度。AVMAX 本身运算时间少, 因为其不需要反复求解线性规划问题, 因此加入超像元分割后, 对 AVMAX 的时间缩短并不显著, 反而增加了 SLIC 的计算时间。当 K 足够大的时候, SLIC+MVES 的效果就近似 MVES 的效果了。RGB (粗线) 色彩空间和 Lab (细线) 色彩空间的差异并不明显。SLIC 算法采用 Lab 色彩空间是因为它除了不依赖于设备的优点外, 还具有自身的优势: 色域宽阔。它不仅包含了 RGB, CMY 的所有色域, 还能表现它们不能表现

的色彩。人的肉眼能感知的色彩, 都能通过 Lab 模型表现出来。另外, Lab 色彩模型弥补了 RGB 色彩模型色彩分布不均的不足, 因为 RGB 模型在蓝色到绿色之间的过渡色彩过多, 而在绿色到红色之间又缺少黄色和其他色彩。

表 1 端元提取结果

Table1 Endmember extraction results				
项目 Item	数据类型 Data types	算法 Algorithm	均方根误差 RMSE	时间 Time/s
无超像元分割 No superpixel division	模拟数据 Simulated data	AVMAX	1909.10	0.29
		MVES	1891.20	410.30
	试验数据 Experimental data	AVMAX	3.30	0.29
		MVES	2.60	2614.60
超像元分割 Superpixel division	模拟数据 Simulated data	AVMAX	1896.80	1.29
		MVES	1901.90	60.74
	试验数据 Experimental data	AVMAX	2.92	1.60
		MVES	2.98	47.30

图 3c 中的纵轴时间表示以 10 为底的对数值, 从图 3c 和图 3d 中的曲线可以看出, 随着 K 值的增加, 混合像元分解的时间逐渐增加, 并且可以看出 AVMAX 算法的时间总是比 MVES 算法的时间短。大量的红线在蓝线的下方, 即大量的 JPG 格式图像比 BIN 格式图像的时间要短。有损压缩是可以减少图像在内存和磁盘中占用的空间, 但在屏幕上观看图像时, 不会发现它对图像的外观产生太大的不利影响。因为人的眼睛对光线比较敏感, 光线对景物的作用比颜色的作用更为重要, 这就是有损压缩技术的基本依据。无损压缩的基本原理是相同的颜色信息只需保存一次。从本质上看, 无损压缩的方法可以删除一些重复数据, 大大减少要在磁盘上保存的图像尺寸。但是, 无损压缩的方法并不能减少图像的内存占用量, 这是因为, 当从磁盘上读取图像时, 软件又会把丢失的像素用适当的颜色信息填充进来。如果要减少图像占用内存的容量, 就必须使用有损压缩。

试验使用 SAM 指标检测结果的准确性。光谱角是通过比较待识别地物向量与参考地物向量在光谱空间上所形成的夹角来确定每类地物的归属。高光谱影像波段信息多、光谱分辨率高的特点, 使得该方法精度较高。图 3e 是模拟数据中 9 个端元光谱角的平均, 图 3f 实际数据中 8 个端元光谱角的平均值。从图 3e 和图 3f 中的曲线可

以看出 AVMAX 算法的结果始终是在 MVES 算法的下面, 表明 AVMAX 算法得到的结果比较好。

根据以上曲线图和表格可以看出: 采用 AVMAX 算法经过超像元分割的速度减慢了, 但是精度有所提高; 而 MVES 算法经过超像元分割的速度是提高了, 但精度有所下降。当 K 的取值很小时, 超像元分割得到的图像块较大, 虽然速度是提高了, 但是 RMSE 较大; 当 K 的取值较大时, 得到的图像块较小, RMSE 也很小, 但速度却很慢。根据大量的试验结果得出 SLIC 算法的参数 K 在 5~10 之间取值, 得到的超像元分割结果对端元提取结果的影响较好。

各算法光谱曲线提取结果如图 4 所示。图中的横坐标是波段号, 没有纵坐标^[26]。中间的光谱曲线分别是采用 AVMAX 和 MVES 算法, 进行无超像元分割得到的端元。其中, 超像元分割后的光谱是选择了 MNF 降维方式、BIN 的数据格式、RGB 的色彩空间、MVES 端元提取算法的情况。由图 4 中的光谱曲线图可以看出, 超像元分割提取的端元比无超像元分割提取的端元要好。超像元分割提取的 Nontronite、Alunite、Kaolinite CM9 这 3 种矿物的端元比无超像元分割提取的好。模拟图像结果为, 超像元分割提取的 Alunite、Buddingtonite、Kaolinite、Calcite、Dickite、Nontronite 这 6 种矿物的端元比无超像元分割提取的端元要好。

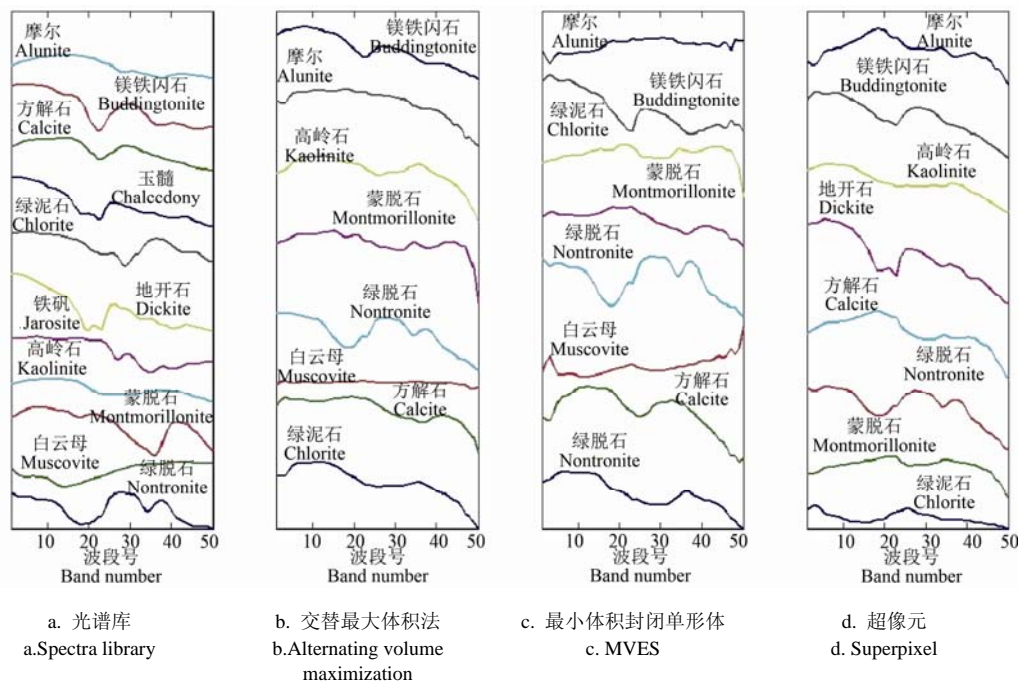


图 4 试验数据的光谱库光谱曲线及不同算法提取的光谱曲线比较

Fig.4 Comparison between spectra curve based on three algorithms and spectral library for experimental data

4 结论

随着 K 值的增大, 经过超像元分割后进行混合像元分解所需的时间逐渐增加, RMSE 减少或持平。这是因为随着 K 值的增大, 超像元的数量不断的增多, 超像元的尺寸不断减小并接近一个正常像元。随着 K 值的增大, JPG 数据格式的时间始终比 BIN 数据格式的要短, 并且

JPG 数据格式的 RMSE 结果也优于 BIN。这是因为有损压缩可以减少图像在内存和磁盘中占用的空间。

1) SLIC+MVES 的 RMSE 略高于 MVES 的 RMSE, 低于 AVMAX 的 RMSE, 但时间远小于 MVES。也就是说, SLIC+MVES 相对于 MVES, 在牺牲少量精度的代价下, 极大提高了运算速度。AVMAX 本身运算时间少,

因为其不需要反复求解线性规划问题, 因此加入超像元分割后, 对 AVMAX 的时间缩短并不显著, 反而增加了 SLIC 的计算时间。当 K 足够大的时候, SLIC+MVES 的效果就近似 MVES 的效果了。

2) RGB 色彩空间和 Lab 色彩空间的差异并不明显。SLIC 算法采用 Lab 色彩空间是因为它除了不依赖设备的优点外, 还具有他自身的优势: 色域宽阔。

3) 在大部分情况下, MNF 降维的效果优于 PCA 降维。以 MNF 作为降维方法、以 JPG 作为数据格式、以 LAB 作为色彩空间对混合像元分解结果较为有利。另外, 通过实验对比可以发现, 当 K 的取值很小时, 超像元分割得到的图像块较大, 虽然速度是提高了, 但是 RMSE 较大; 当 K 的取值较大时, 得到的图像块较小, RMSE 也很小, 但速度却很慢。根据大量的试验结果得出 SLIC 算法的参数 K 在 5~10 之间取值, 得到的超像元分割结果对端元提取结果的影响较好。

SLIC 超像元分割克服了混合像元分解冗余量大的问题, 并提高了混合像元分解的精度。但本文所述方法对其他端元提取算法的效率和精度的影响以及对不同信噪比图像的适用性仍有待进一步的试验分析。

[参 考 文 献]

- [1] 李霞, 王飞, 徐德斌, 等. 基于混合像元分解提取大豆种植面积的应用探讨[J]. 农业工程学报, 2008, 24(1): 213—217.
Li Xia, Wang Fei, Xu Debin, et al. Application research on the method for extracting soybean covered areas based on the pixel unmixing[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2008, 24(1): 213—217. (in Chinese with English abstract)
- [2] 郝虑远, 孙睿, 谢东辉, 等. 基于改进 N-FINDR 算法的华北平原冬小麦面积提取[J]. 农业工程学报, 2013, 29(15): 153—161.
Hao Lüyuan, Sun Rui, Xie Donghui, et al. Planting area extraction of winter wheat in North China Plain based on optimized N-FINDR algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering (Transaction of the CSAE), 2013, 29(15): 153—161. (in Chinese with English abstract)
- [3] 李素, 李文正, 周建军, 等. 遥感影像混合像元分解中的端元选择方法综述[J]. 地理与地理信息科学, 2007, 23(5): 35—42.
Li Su, Li Wenzheng, Zhou Jianjun, et al. Mixed pixel decomposition of remote sensing images endmember selection review[J]. Geography and Geo-Information Science, 2007, 23(5): 35—42. (in Chinese with English abstract)
- [4] Boardman J W, Kruse F A, Green R O. Mapping target signatures via partial unmixing of aviris data[C]. Summaries of the Fifth Annual JPL Airborne Earth Science Workshop, California: JPL Publication, 1995: 23—26.
- [5] Winter M E. N-FINDR: An algorithm for fast autonomous spectral end-member determination in hyperspectral data[J]. Proceedings of SPIE, 1999, 3753(10): 266—275.
- [6] Nascimento J M P, Dias J M B. Vertex component analysis: A fast algorithm to unmix hyperspectral data[J]. IEEE Transactions on , 2005, 43(4): 898—910.
- [7] John H, Gruninger, Anthony J Ratkowski, et al. The sequential maximum angle convex cone (SMACC) endmember model[J]. SPIE, 2004, 5425(1): 1—14.
- [8] Chan T H, Chi C Y, Huang Y M, et al. A convex analysis-based minimum-volume enclosing simplex algorithm for hyperspectral unmixing[J]. IEEE, 2009, 57(11): 4418—4432.
- [9] Wang Fayu, Chi Chongyung, Wang Xue. Nonnegative least-correlated component analysis for separation of dependent sources by volume maximization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(5): 875—888.
- [10] 孙旭. 基于群智能算法的高光谱遥感图像端元提取方法研究[D]. 北京: 中科院对地观测与数字地球科学中心, 2011.
Sun Xu. Research on Endmember Extraction Algorithm of Hyperspectral Remote Sensing Images Based on Swarm Intelligence[D]. Beijing: Center for Earth Observation and Digital Earth Chinese Academy of Sciences, 2011. (in Chinese with English abstract)
- [11] 高晓惠, 相里斌, 魏儒义. 基于光谱分类的端元提取算法研究[J]. 光谱学与光谱分析, 2011, 31(7): 1995—1998.
Gao Xiaohui, Xing Libin, Wei Ruyi. Based spectral classification of endmember extraction algorithm [J]. Spectroscopy and Spectral Analysis, 2011, 31(7): 1995—1998. (in Chinese with English abstract)
- [12] Ren X, Malik J. Learning a classification model for segmentation[J]. ICCV, 2003, 1(10): 10—17.
- [13] Greg M. Guiding model search using segmentation[J]. IEEE International Conference on Computer Vision , Canada, 2005, 2(2): 1417—1423.
- [14] David R Thompson, Lukas Mandrake, Martha S Gilmore, et al. Superpixel endmember detection[J]. IEEE Transactions on Geosciences and Remote Sensing, 2010, 48(11): 4023—4033.
- [15] Felzenszwalb P, Huttenlocher D. Efficient graph-based image segmentation[J]. International Journal of Computer Vision, 2004, 59(2): 167—181.
- [16] Shi J, Malik J. Normalized cuts and image segmentation[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888—905.
- [17] Moore A, Prince S, Warrell J, et al. Superpixel lattices[C]. Proc of IEEE Conference on Computer Vision and Pattern Recognition, London: IEEE Conference Publications, 2008: 1—8.
- [18] Vincent L, Soille P. Watersheds in digital spaces: An efficient algorithm based on immersion simulations[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1991, 13(6): 583—598.
- [19] Comaniciu D, Meer P. Mean shift: A robust approach toward feature space analysis[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603—619.
- [20] Vedaldi A, Soatto S. Quick Shift and Kernel Methods for Mode Seeking[M/OL]. Berlin: Springer-Verlag, 2008: 705—718.

- [21] Levinshtein A, Stere A, Kutulakos K, et al. Turbopixels: Fast superpixels using geometric flows[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2290—2297.
- [22] Achanta R, Shaji A, Smith K. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274—2282.
- [23] 刘洁, 李小昱, 李培武, 等. 基于近红外光谱的板栗水分检测方法[J]. 农业工程学报, 2010, 26(2): 338—341.
Liu Jie, Li Xiaoyu, Li Peiwu, et al. Determination of moisture in chestnuts using near infrared spectroscopy[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2010, 26(2): 338—341. (in Chinese with English abstract)
- [24] 何中海, 何彬彬. 基于权重光谱角制图的高光谱矿物填图方法[J]. 光谱学与光谱分析, 2011, 31(8): 2200—2204.
He Zhonghai, He Binbin. Weight-based spectral angle mapping hyperspectral mineral mapping method[J]. Spectroscopy and Spectral Analysis, 2011, 31(8): 2200—2204. (in Chinese with English abstract)
- [25] Martin G, Plaza A. Spatial-spectral preprocessing prior to endmember identification and unmixing of remotely sensed hyperspectral data [J]. IEEE Journals, 2012, 5(2): 380—395
- [26] Tsung-Han Chan, Wing-Kin Ma, Ambikapathi. A simplex volume maximization framework for hyperspectral endmember extraction [J]. IEEE Transactions on Geosciences and Remote Sensing, 2011, 49(11): 4177—4193.

Hyperspectral mixed pixel decomposition policy merging simple linear iterative clustering

Zhang Feifei^{1,2}, Sun Xu^{2*}, Xue Liangyong³, Gao Lianru², Liu Changxing¹

(1. *Surveying Science and Technology, Xi'an University of Science and Technology, Xi'an 710054, China;*
2. *Institute of Remote Sensing and Digital Earth, Computer Science and Technology, Chinese Academy of Sciences, Beijing 100094, China;* 3. *Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China*)

Abstract: The decomposition efficiency of mixed pixels is an important subject in the research of remote sensing application. Current mature extraction algorithms of the endmember are pure pixel index (PPI), N-FINDR, vertex component analysis (VCA), sequential maximum angle convex cone (SMACC), alternating volume maximization (AVMAX), minimum volume enclosing simplex (MVES), etc. Extracting pure spectra from all pixels of an image by those algorithms has relatively slow processing and low accuracy. Therefore, in this paper, we introduced an integration of simple linear iterative clustering (SLIC) super pixel segmentation of hyperspectral mixed pixel decomposition algorithm. The number of pixels in a hyperspectral image was one of the main reasons that affected pixel unmixing (especially endmember extraction). Super pixel segmentation techniques can compose adjacent pixels with similar characteristics into image blocks, and retain useful information for further image processing, thus significantly reducing the number of pixels involved in endmember extraction and solving the problems of low processing and low accuracy in an effective way. In this paper, endmember extraction method was modified. We used Simple Linear Iterative Clustering (SLIC) algorithm to segment hyperspectral image pixels into super pixel sets, and conducted experimental comparisons on impact of different dimension reduction methods such as principal components analysis (PCA), minimum noise fraction (MNF), correspondence between different RGB (six kinds), different color spaces (RGB, LAB), different data formats (JPG, BIN) and different algorithms' parameters K on hyperspectral image super pixel segmentation results. Furthermore, the impact of SLIC super pixel segmentation results on two typical endmember extraction algorithms was analyzed. The results showed that, with the increase of K value, the decomposition of mixed pixels gradually increased. The reason for such change was that as the K value increased, the number of pixels increased, and the size of the image was reduced and was close to a normal pixel. The JPG (lossy compression) data format of time was shorter than BIN (lossless compression) data format because a lossy compression can reduce the image size occupied in memory or disk space. The root-mean-square error (RMSE) of SLIC+MVES was slightly higher than that of MVES, and lower than that of AVMAX, with the time much less than actual MVES. In other words, relative to MVES, SLIC+MVES greatly increased processing speed, at the expense of a small amount of sacrifice in accuracy. AVMAX consumed little time itself because it did not need to solve linear programming problems repeatedly. So after adding super pixel segmentation, the time shortened for AVMAX was not significant, but the time for SLIC computing had increased. When increasing K, the computation time increased gradually, and the RMSE was flat or deceasing. When K was large enough, the results of SLIC+MVES was approximate to that of MVES. The difference in the RGB color space and Lab color space was not obvious. SLIC algorithm used Lab color space because it did not rely on the advantages of the device, but also had its own advantages, i.e., a wide color gamut. In most cases, dimensionality reduction by MNF was better than that of PCA. As to the MNF dimensionality reduction method, the data in JPG format, with Lab color space were more favorable for unmixing results. In addition, the value of SLIC parameters from 5 to 10 was more appropriate. The SLIC super pixel segmentation algorithm was simple and improved the efficiency of unmixing, with a great practical value.

Key words: pixels; spectrum analysis; algorithms; simple linear iterative clustering (SLIC); super pixel