

引用格式: Su Yuanchao, Sun Xu, Gao Lianru, *et al.* The Analysis and Comparison of Hyperspectral Endmember Extraction Algorithms[J]. Remote Sensing Technology and Application, 2015, 30(6): 1195-1205. [苏远超, 孙旭, 高连如, 等, 高光谱影像端元提取算法的进展分析与比较[J]. 遥感技术与应用, 2015, 30(6): 1195-1205.] doi:10.11873/j.issn.1004-0323.2015.6.1195

# 高光谱影像端元提取算法的进展分析与比较

苏远超<sup>1</sup>, 孙旭<sup>2</sup>, 高连如<sup>2</sup>, 陈晓宁<sup>1</sup>

(1. 西安科技大学测绘科学与技术学院, 陕西 西安 710054;

2. 中国科学院遥感与数字地球研究所, 北京 100094)

**摘要:** 对当前国际经典和前沿的6种代表性的端元提取算法进行比较研究, 包括SPP-N-FINDR、VCA、SPICE、PCOMMEND、MVSA和MVC-NMF, 通过理论和实验两种方式对这些算法进行综合性对比和分析, 总结其优势和存在的问题。通过模拟和真实数据实验得出: SPP-N-FINDR算法的抗噪声能力不如其他5种算法; VCA和MVSA的稳定性较好; MVC-NMF和SPICE无需知道端元数目, 且能直接得出丰度矩阵, 自动化程度较高; PCOMMEND在真实高光谱图像中提取端元的结果最好, 能直接得出丰度矩阵, 但若端元数量为素数时精度会下降。研究成果将为今后围绕这些算法的相关研究提供必要的理论支持和参考。

**关键词:** 高光谱; 混合像元分解; 端元提取

**中图分类号:** TP 751 **文献标志码:** A **文章编号:** 1004-0323(2015)06-1195-12

## 1 引言

高光谱遥感数据具有较高的光谱分辨率, 在可见光到短波红外范围内甚至达到纳米级, 使得一幅影像既有能反映其几何特征的空间信息, 又有能反映地物光谱特征的光谱信息, 实现了图谱合一<sup>[1]</sup>。但在高光谱图像中, 混合像元的存在是一个普遍且难以避免的问题, 而且处理该问题的主要方法为混合像元分解。混合像元分解通常分为端元提取和丰度反演两个过程。本文选择的这6种端元提取算法均基于线性混合模型, 因为线性混合模型只考虑电磁波被地物吸收和反射, 而不考虑其相互作用。相对于非线性混合模型而言, 线性混合模型更适应于面积大且空间分辨率较低的高光谱图像, 并且计算方便, 概括性强, 便于用数学公式表述。按照线性混合模型理论, 端元光谱位于凸集体(单形体)的顶点。在高光谱影像中, 将代表组成地物类别的纯净光谱

信号称为端元。在高光谱影像的混合像元中, 丰度表示某种端元在这个像元中所占的比例。线性光谱混合模型如下:

$$x_i = \sum_{k=1}^M p_{ik} e_k + \epsilon_i \quad i = 1, \dots, N \quad (1)$$

其中:  $x_i$  表示像元,  $e_k$  表示端元,  $N$  表示图像中像元的数量,  $M$  表示图像中端元的数量,  $\epsilon_i$  表示误差。 $p_{ik}$  表示端元在像元中所占的比例。上述模型的限制条件为:

$$\begin{cases} p_{ik} \geq 0 & \forall k = 1, \dots, M \\ \sum_{k=1}^M p_{ik} = 1 \end{cases} \quad (2)$$

本文重点对内部最大体积算法(N-FINDR)<sup>[2]</sup>、顶点成分分析算法(Vertex Component Analysis, VCA)<sup>[3]</sup>、基于稀疏策略的迭代约束算法(Sparsity Promoting Iterated Constrained Endmember, SPICE)<sup>[4]</sup>、多凸集模型算法(Piecewise Convex

收稿日期: 2014-11-08; 修订日期: 2015-02-04

基金项目: 国家自然科学基金青年基金项目(41201356)。

作者简介: 苏远超(1988—), 男, 陕西西安人, 硕士研究生, 主要从事高光谱图像混合像元分解方面的研究。E-mail: knightsuyuanchao@126.com。

通讯作者: 高连如(1979—), 男, 北京人, 博士, 副研究员, 主要从事高光谱图像信息提取方面的研究。E-mail: gaolr@radi.ac.cn。

Multiple Model Endmember, PCOMMEND)<sup>[5]</sup>、最小体积单形体分析算法(Minimum Volume Simplex Analysis, MVSA)<sup>[6]</sup>、最小体积约束的非负矩阵分解法(Minimum Volume Constrained Nonnegative Matrix Factorization, MVC-NMF)<sup>[7]</sup> 6 种端元提取算法进行综述及实验。这 6 种算法中既有近年发展的新算法,亦有经典的算法,且均基于线性混合模型理论,其数学模型涵盖了纯像元假设、最小体积变换、稀疏策略、多凸集模型和非负矩阵分解等当前主流方向,因而有必要进行综合性的定量比较与分析

来得出各算法的优劣。

2 算法综述

本文选择的 6 种端元提取算法为:SPP-N-FINDR、VCA、SPICE、PCOMMEND、MVSA 和 MVC-NMF。其中 N-FINDR 和 VCA 两种算法均基于纯像元假设,SPICE 算法基于稀疏策略,PCOMMEND 算法基于多凸集模型,MVC-NMF 和 MVSA 两种算法皆基于最小体积变换。为了直观地展示,现将 6 种算法按性能进行详细划分,如表 1 所示。

表 1 算法性能比较  
Table 1 The comparing for properties algorithms

算法	是否需要降维	利用纯像元假设	利用光谱库	端元是否同时提取	利用空间信息	需要已知端元数量
VCA	否	是	否	否	否	是
SPP-N-FNIDR	是	是	否	是	是	是
MVC-NMF	否	否	是	是	否	是
MVSA	是	否	否	是	否	是
SPICE	否	否	否	是	否	否
PCOMMEND	否	否	否	是	否	是

2.1 SPP-N-FINDR 算法

SPP-N-FINDR 是给 N-FINDR 算法加入空间预处理(Spatial Preprocessing, SPP)<sup>[8]</sup>,通过以往的实验发现 N-FINDR 受到噪声影响较大,而目前多数端元提取算法仅依赖于高光谱数据的光谱信息,却没有利用到图像的空间信息,若在其处理前加入 SPP 算法进行预处理可提高其鲁棒性。

N-FINDR 算法是一种基于线性混合模型的高光谱图像端元提取算法,利用特征空间内单形体几何结构的特点,通过寻找特征空间中最大体积的单形体,最大体积单形体的各个顶点即为高光谱图像的端元。单形体的体积定义适合于任意有限维空间,设空间  $R^{M-1}$  内有  $M$  个不同点构成的矩阵  $E$ 。

$$E = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ e_1 & e_2 & \cdots & e_M \end{bmatrix}$$

(3)

$$V(E) = \frac{1}{(M-1)!} \text{abs}(\det(E))$$

(4)

其中: $V(E)$  表示特征空间中单形体的体积, $M$  为端元数目, $e_k$  表示第  $k$  个端元对应的光谱向量  $k = 1, 2, \cdots, M$ 。由于  $E$  是方阵,所以  $e_k$  是一个  $(M-1)$  维的向量。根据线性混合模型的定义,由  $M$  个端元构成的单形体的体积必定是特征空间内  $M$  个像元构成单形体的最大体积。

SPP 算法是在基于光谱信息的端元提取算法上

加入空间信息。对于每个像元,根据其与其邻域像元的光谱相似程度提出了一个比例因子,这个比例因子作为该像元在空间上下文中光谱信息重要程度的权重。

假设在图像空间内存在一个以像元为  $x(i, j)$  中心的大小为  $w_s \times w_s$  的正方形邻域窗口, $i$  表示行号, $j$  表示列号, $w_s$  是一个奇数,该窗口的半径为  $d = (w_s - 1)/2$   $d = (w_s - 1)/2$  个像元。定义比例权重如下:

$$\alpha(i, j) = \sum_{r=i-d}^{r=i+d} \sum_{s=j-d}^{s=j+d} \beta(r-i, s-j) \cdot \gamma(r-i, s-j)$$

(5)

其中: $\gamma$  是中心像元  $x(i, j)$  和邻域像元  $x(r, s)$  的相似性度量, $\beta$  是相似性度量值的权重,根据  $w_s \times w_s$  大小的窗口内的不同位置来调节权重。故使得本文对距离中心像元较近的邻域像元的重要性赋予较大权重,而距离远权重较小。每个像元在端元提取中的空间权重因子为  $p(i, j)$ ,若约束  $\beta$  和  $\gamma$  的值,则  $p(i, j) \geq 1$ ,要求  $\beta$  和  $\gamma$  的值为非负。利用空间权重因子按比例缩小原始图像的像元光谱值:

$$\begin{cases} x(i, j)' = \frac{1}{\rho(i, j)} (x(i, j) - \bar{I}) + \bar{I} \\ \rho(i, j) = (1 + \sqrt{\alpha(i, j)})^2 \end{cases}$$

(6)

其中: $x(i, j)'$  表示利用空间信息在  $x(i, j)$  上加权后得到的光谱特征值, $\bar{I}$  是原始图像所有像元的光谱

均值。

将每个像元光谱数据点的均值点移动(即朝着图 1 中的点  $O'$  移动),每个光谱移动的程度与前面的空间光谱相似度量值成比例。与邻域像元光谱差异性较大的像元(如图 1 中标号为“2”和“3”的像元)位移程度较大,与邻域像元光谱差异性较小的像元移动程度较小(如图 1 中标号为“1”的像元)。通过此操作,利用空间信息和光谱信息修正了高光谱数据形成的单形体。修正后的单形体顶点为空间均质区域纯像元的可能性更高。




图 1 SPP 算法的几何意义

Fig. 1 The geometric meaning of SPP

## 2.2 VCA 算法

VCA 算法是通过重复搜寻正交向量并计算像元在正交向量上的投影距离来逐一提取端元。由于单形体若干个顶点可以张成一个子空间,而单形体在某个与这个子空间正交的向量上的投影距离的最大值点是单形体的顶点。故可以先设法找到一个纯像元作为初始端元,每次循环都先找到一个与之前找到端元同时正交的单位向量,然后将所有像元投影到这个单位向量上,并将投影到这一单位上结果最大的那个像元记为新端元。依次循环,直到找到  $M$  个端元为止。

若前  $k$  次提取的端元组成的矩阵为  $E_k$ ,则其子空间为  $\langle E_k \rangle$ ,在其空间内的正交补空间  $\langle E_k \rangle^\perp$  的基矩阵为:

$$W = I_L - E_k (E_k^T E_k)^{-1} E_k^T \quad (7)$$

其中:  $I_L$  是  $L$  阶单位矩阵,  $W$  中的列向量并非线性无

关,其列向量的极大线性无关组是  $\langle E_k \rangle^\perp$  的基底。 $W$  中的任意一列均是  $\langle E_k \rangle^\perp$  的正交向量,可从  $W$  中任意取出一列作为正交方向向量  $w$ ,像元的光谱向量  $x_i$  在  $w$  上的投影为  $w^T x_i$ ,其投影长度最长的像元为第  $k+1$  个端元。

VCA 算法理论上不需要降维,原始文献[3]采用降维处理,主要目的是为了提高运算效率。在本文试验中采用的是原始文献中 VCA 算法的处理思路,在用 VCA 算法提取端元之前用 PCA 算法进行了降维处理。

## 2.3 SPICE 算法

SPICE 是基于稀疏策略的迭代约束端元提取算法,其原理是在迭代约束算法(Iterated Constrained Endmember, ICE)[9]的基础上加入了稀疏策略。在端元数目未知情况下,对原始 ICE 算法使用远大于真实值的端元数目,得到的丰度矩阵必然是个稀疏矩阵,根据这个稀疏矩阵的先验知识,在 ICE 的目标函数中加入稀疏项可防止估计出的丰度矩阵过大[4]。ICE 通过最小二乘方法使模型描述中的像元残差平方和最小化。像元残差平方和(Residual Sum of Squares, RSS)表示模型提取出的光谱与真实端元光谱的误差。

$$RSS = \sum_{i=1}^N (x_i - \sum_{k=1}^M p_{ik} e_k)^T (x_i - \sum_{k=1}^M p_{ik} e_k) \quad (8)$$

像元的距离平方和(Sum of Squared Distances Term, SSD)与端元构成单形体面积大小成正比,在目标函数中增加 SSD,目的是便于找到更合理的端元。由文献[9]可知 ICE 算法的目标函数为:

$$RSS_{reg} = (1 - \mu) \frac{RSS}{N} + \mu V \quad (9)$$

其中:  $V$  是估计端元的方差之和,  $M$  是端元个数。 $\mu$  是用于平衡 RSS 和 SSD 的正则化参数。通过迭代计算实现目标函数最小化。在图像中随机选择像元作为初始端元,已知端元数量的情况下,用最小二乘法可估计丰度矩阵。再利用新的丰度矩阵来更新端元,如此往复直到  $RSS_{reg}$  小于一定的阈值。加入稀疏项后的 ICE 目标函数(SPICE 的目标函数)表示为:

$$RSS_{reg}^* = (1 - \mu) \frac{RSS}{N} + \mu V + \sum_{k=1}^M \frac{\Gamma}{\sum_{i=1}^N p_{ik}} \sum_{i=1}^N p_{ik} \quad (10)$$

其中:  $\Gamma$  是一个描述促使丰度值趋向零的程度的常数,当给定端元数量时,目标函数第一项最小化的丰度值需要用二次规划的方法求解。

## 2.4 PCOMMEND 算法

PCOMMEND 算法是多凸集端元提取算法

(Piece-wise Convex Endmember, PCE)<sup>[10]</sup>的延伸。PC(Piece-wise Convex)表示多个凸集体的意思,多凸集模型来描述高光谱图像便于较好地解决光谱变异性问题。在以往基于凸集几何模型的高光谱端元提取算法中,普遍将高光谱数据看成是一个线性组合的凸集体(或单形体)。但是当图像中纯像元较少或者没有纯像元时,基于一个单形体的假设模型得到的结果往往不理想。PCOMMEND 算法先初步给定各个小凸集体的数量。该算法并非直接估算出某一个端元的单一光谱,而是利用端元分布(Endmember Distributions, ED)<sup>[10]</sup>探测法去估算出每个端元在小凸集体内的分布情况。

端元比例值是指每一个凸集体内每个像元所占比例,在此需注意与以往“丰度”概念的区分。利用贝叶斯机器学习方法对数据进行初始化来在特征空间中划分不同的类别,然后利用模糊聚类的方法来确定端元的归属(隶属度),采用交替优化进行迭代来估计出真实的端元,根据设定的条件阈值来决定何时停止迭代。

PCOMMEND 通过最小化目标函数来估计端元集和比例值,其目标函数为:

$$J(E, P, U) = \sum_{i=1}^C \left( \sum_{j=1}^N u_{ij}^m (x_j - E_i p_{ij})^T (x_j - E_i p_{ij}) + \alpha \sum_{k=1}^{M-1} \sum_{j=k+1}^M (e_{ik} - e_{ij})^T (e_{ik} - e_{ij}) \right) \quad (11)$$

约束条件为:

$$\begin{cases} p_{ijk} \geq 0 \quad \forall k = 1, \dots, M \\ \sum_{k=1}^M p_{ijk} = 1 \\ u_{ij} \geq 0 \quad \forall k = 1, \dots, M \\ \sum_{i=1}^C u_{ij} = 1 \end{cases} \quad (12)$$

其中:  $x_j$  是一个  $d \times 1$  的列向量,代表第  $j$  个像元。 $C$  是估计的端元集的数目,是比例值向量,比例值表示像元  $j$  在第  $i$  端元集所占的比例。 $E_i$  是一个大小为  $d \times M$  的矩阵,  $E_i$  的每一列向量为  $e_{ik}$ ,  $e_{ik}$  是一个  $d \times 1$  维向量,代表在第  $i$  个端元集中第  $k$  个端元。权重  $u_{ij}$  表示像元  $j$  在第  $i$  个端元集的隶属度值。 $\alpha$  表示一个固定参数,其作用是平衡目标函数前后两项。 $m$  也是一个固定参数,这个参数控制着端元集之间的相似度。

## 2.5 MVSA 算法

MVSA 算法的原理是通过由内向外扩张来寻找包含所有像元点的体积最小的单形体来获得端元,其原理源于最小体积变换算法(Minimum

Volume Transforms, MVT)<sup>[11]</sup>。对于波段数目为  $L$  的图像, MVSA 只能找到  $L$  个端元,因此使用 MVSA 算法之前需根据端元数量  $M$  对图像进行降维,使得  $L = M$ 。拟合最小体积的单形体是一个非凸的优化问题,存在大量的局部最优解,无法找到全局最优解的, MVSA 算法其实是寻找足够好的次优解的过程。

当  $L = M$  时,降维后的图像矩阵为  $X$ ,端元矩阵  $E$  为方阵且各个端元之间线性无关,设  $Q = E^{-1}$ ,寻找最小体积单形体的最优化问题为:

$$\begin{cases} E^* = \arg \min \{ |\det(E)| \} \\ QX \geq 0 \quad 1_L^T QX = 1_N^T \end{cases} \quad (13)$$

其中:  $\det(E)$  为  $E$  的行列式(即单形体体积)。 $\det(E) = 1/\det(Q)$ ,则可将上述最优化问题转换为:

$$\begin{cases} Q^* = \arg \max \{ \log |\det(Q)| \} \\ QX \geq 0 \quad 1_L^T QX = 1_N^T \end{cases} \quad (14)$$

提取端元的问题转换为求解  $Q$  的问题。每一个像元  $x_i$  都在  $E$  的子空间中,  $X$  的大小为  $M \times N$ ,则  $X$  中必然存在  $M$  个线性无关列向量  $\{x_k\}_{k=1}^M$  构成的方阵  $X_M = \{x_{i1}, x_{i2}, \dots, x_{i3}\}$ 。 $x_i = X_M \beta$  其中,  $1^T \beta = 1$ 。可以通过逐次二次规划法(Sequential Quadratic Programming, SQP)求解得到:

$$Q = \text{SQP}[f, Q_0, X, 0, 1_L^T, 1_M^T (X_M)^{-1}, g, H] \quad (15)$$

其中:  $f$  是目标函数,  $g$  是  $f$  的梯度,  $H$  为  $f$  的 Hessian 矩阵,  $Q_0$  为迭代的初始值。

## 2.6 MVC-NMF 算法

MVC-NMF 算法是将体积限制加入到非负矩阵分解算法(Non-negative Matrix Factorization, NMF)<sup>[12]</sup>中来实现最小二乘法分析和凸面几何的结合。该算法强调两个重要的因素:①矩阵分解后得到的端元矩阵和丰度矩阵是非负的;②由端元所构成的单形体必须是特征空间中所可能构成的单形体中体积最小的。MVC-NMF 算法提出的代价函数包括两部分,一部分用来估计观测数据与端元和丰度重建数据之间的近似误差,另一部分由最小体积限制组成。通过最小化近似误差使得估计结果向点云外部移动。通过最小化单形体体积使得在相反方向上的端元尽可能地相互靠近。构建目标函数为:

$$\begin{cases} \min f(E, S) = \frac{1}{2} \|X - ES\|_F^2 + \lambda J(E) \\ E \geq 0, S \geq 0, 1_M^T S = 1_N^T \end{cases} \quad (16)$$

其中:  $X$  为原始图像,大小为  $L \times N$ ;  $E$  为端元矩阵,  $S$  为丰度矩阵,  $L$  为波段数,  $N$  为原始图像向量个数,



$M$  为端元数量。式中  $1_M$  和  $1_N$  分别为元素全为 1 的  $M$  维和  $N$  维列向量;  $J(E)$  为惩罚项,即每次迭代过程中估计的端元集合所构成的单形体的体积; $\lambda$  为正则化参数。

从数据中随机选择若干个像素光谱作为初始端元集合,构成  $E$  的初始值;再运用全约束最小二乘法(Fully Constrained Least Squares,FCLS)获取丰度矩阵初始值。设定迭代次数和迭代误差,根据加入投影梯度学习的交互的非负最小二乘算法<sup>[13]</sup> 计算能够最小化目标函数的矩阵  $E$  和  $S$ 。

3 实验与分析

3.1 高光谱模拟数据实验及分析

3.1.1 高光谱数据模拟

本文的模拟数据由 5 个来自 ENVI5.0 软件的

veg\_1dry. s 光谱库中的端元光谱和对应的丰度经过反混得到。5 个端元分别记为  $r_1$ 、 $r_2$ 、 $r_3$ 、 $r_4$ 、 $r_5$ , 光谱曲线如图 2(b) 所示。它们分别位于图像的 4 个角和中心,各端元的丰度从纯像元所在位置向周围逐渐减小。模拟图像大小为  $100 \times 100 \times 826$ ,波段范围为  $0.4 \sim 2.5 \mu\text{m}$ 。为了进行噪声影响测评,在模拟数据加入了不同水平的高斯白噪声,产生了信噪比(Signal to Noise Ratio, SNR) 为 10 : 1、20 : 1、40 : 1、60 : 1、80 : 1 和 100 : 1 的 6 幅模拟图像。此外,由于模拟数据本身存在纯像元,为减少纯像元对实验结果的影响,客观评价在有无纯像元条件下各算法的性能,因而剔除信噪比 100 : 1 和 20 : 1 的模拟图像中丰度值大于 85% 的像元,生成一幅无纯像元的高光谱模拟图像。因此,本实验共用到 8 幅高光谱模拟图像。

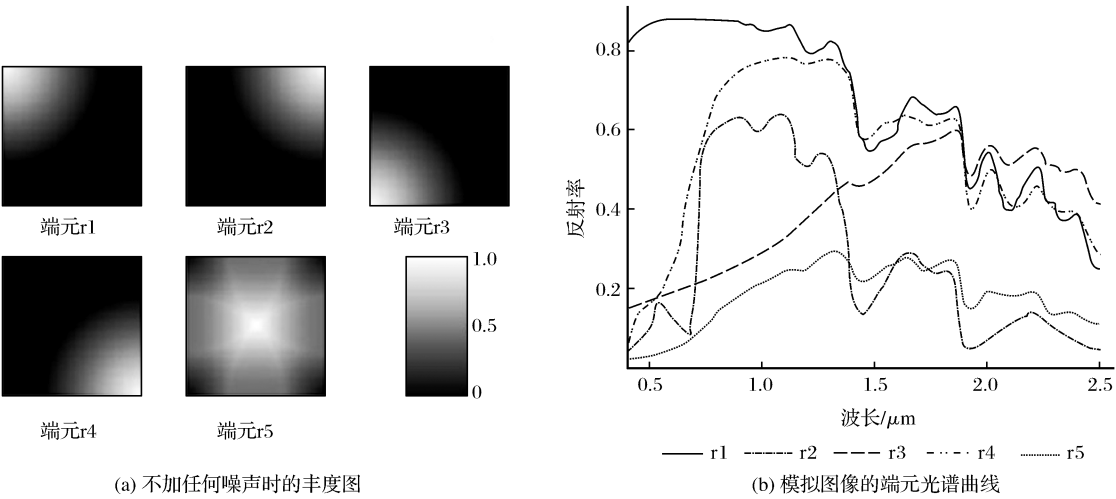


图 2 不添加任何噪声时的丰度图和模拟图像的端元光谱曲线

Fig. 2 The abundance maps without any noise and the spectrums of respective endmembers in simulated image

3.1.2 实验结果及分析

当前国际普遍采用光谱角(Spectral Angle Divergence,SAD)和光谱离散度(Spectral Information Divergence,SID)来进行相似性度量。光谱角和信息离散度越小说明提取的结果越接近真实图像。

$$\text{SAD}[e_k, \hat{e}_k] = \arccos\left(\frac{[e_k, \hat{e}_k]}{\|e_k\|_2 \cdot \|\hat{e}_k\|_2}\right) \tag{17}$$

$$\text{SID}[e_k, \hat{e}_k] = \sum_{j=1}^L p_j \log\left(\frac{p_j}{q_j}\right) + \sum_{j=1}^L q_j \log\left(\frac{q_j}{p_j}\right) \tag{18}$$

其中: $e_k = \{e_j\}_{j=1}^L$  表示光谱库中的真实端元,  $\hat{e}_k = \{\hat{e}_j\}_{j=1}^L$  表示提取出的端元,  $p_i = e_i / \sum_{j=1}^L e_j$ ,  $q_i = \hat{e}_i / \sum_{j=1}^L \hat{e}_j$ ,  $L$  表示波段。

在模拟实验中,SPICE 的初始端元数设为 10,

其他 5 种算法的端元数目均设置为 5。文中的算法最大迭代次数均设为 500,其余参数值均与对应文献提供的原始代码参数保持一致。

通过表 2 和表 3 可以看出,在理想的纯像元条件下,模拟图像是由不同的已知端元光谱经过绝对线性混合而得来的,且图像端元的分布完全符合均匀分布,因而模拟图像的各个端元在特征空间中一定位于单形体的各个顶点,这种特殊性的数据对 VCA 算法最为合适,故 VCA 算法的结果最好。该结论与文献[3]中的实验结论相一致。因而,仅凭理想纯像元模拟数据的实验不能充分说明 VCA 算法优于其他 5 种算法。通过表 2 和表 3 无纯像元条件下的实验结果表明,当图像中没有纯像元时,基于非

表 2 不同信噪比条件下,端元提取结果的光谱角(弧度)(其中无法提取端元的结果用“—”表示)

Table 2 Showing spectral angle scales of extracted endmembers (in radian) on the condition of different values of signal to noise ratio(Using “—”to represent the falling results of endmembers extraction)

光谱角(SAD)						
r1						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$8.19 \times 10^{-7}$	$7.17 \times 10^{-3}$	$1.27 \times 10^{-3}$	<b><math>1.90 \times 10^{-5}</math></b>	$6.65 \times 10^{-3}$	$3.98 \times 10^{-3}$
80 : 1	$1.10 \times 10^{-5}$	$7.39 \times 10^{-3}$	$1.27 \times 10^{-3}$	<b><math>1.46 \times 10^{-4}</math></b>	$5.50 \times 10^{-3}$	$4.42 \times 10^{-3}$
60 : 1	$1.10 \times 10^{-4}$	0.01	<b><math>1.27 \times 10^{-3}</math></b>	$1.46 \times 10^{-3}$	$2.55 \times 10^{-3}$	$3.9 \times 10^{-3}$
40 : 1	$1.11 \times 10^{-3}$	0.03	<b><math>1.29 \times 10^{-3}</math></b>	0.01	$6.42 \times 10^{-3}$	$5.5 \times 10^{-3}$
20 : 1	0.15	—	<b><math>5.88 \times 10^{-3}</math></b>	0.09	$7.7 \times 10^{-3}$	0.07
10 : 1	0.03	—	—	0.15	<b>0.08</b>	0.13
无纯像元	0.03	0.05	0.04	$4.1 \times 10^{-3}$	0.01	<b><math>1.7 \times 10^{-3}</math></b>
无纯 20 : 1	0.13	—	0.11	0.05	<b>0.03</b>	0.09
r2						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$3.09 \times 10^{-6}$	0.16	0.10	<b><math>1.76 \times 10^{-5}</math></b>	0.07	0.20
80 : 1	$3.05 \times 10^{-5}$	0.16	0.10	<b><math>2.35 \times 10^{-4}</math></b>	0.11	0.27
60 : 1	$3.04 \times 10^{-4}$	0.16	0.10	<b><math>2.35 \times 10^{-3}</math></b>	0.11	0.19
40 : 1	$3.03 \times 10^{-3}$	0.23	0.10	<b>0.02</b>	0.12	0.25
20 : 1	0.03	—	<b>0.10</b>	0.23	0.11	0.36
10 : 1	0.62	—	—	0.56	<b>0.34</b>	0.54
无纯像元	0.24	0.31	<b>0.10</b>	0.13	0.18	0.14
无纯 20 : 1	0.47	—	0.14	<b>0.13</b>	0.30	0.48
r3						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$1.70 \times 10^{-6}$	0.14	0.09	<b><math>1.39 \times 10^{-5}</math></b>	0.12	0.02
80 : 1	$1.84 \times 10^{-5}$	0.14	0.09	<b><math>1.47 \times 10^{-4}</math></b>	0.09	0.13
60 : 1	$1.84 \times 10^{-4}$	0.14	0.09	<b><math>1.46 \times 10^{-3}</math></b>	0.11	0.02
40 : 1	$1.85 \times 10^{-3}$	0.21	0.09	<b>0.15</b>	0.08	0.05
20 : 1	0.04	—	<b>0.08</b>	0.14	0.12	0.23
10 : 1	0.85	—	—	0.39	<b>0.19</b>	0.42
无纯像元	0.22	0.29	0.17	0.12	0.17	<b>0.11</b>
无纯 20 : 1	0.31	—	—	<b>0.20</b>	0.27	0.42
r4						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$1.47 \times 10^{-6}$	0.05	0.07	<b><math>2.29 \times 10^{-6}</math></b>	0.04	0.01
80 : 1	$1.38 \times 10^{-5}$	0.05	0.07	<b><math>3.98 \times 10^{-5}</math></b>	0.05	0.14
60 : 1	$1.38 \times 10^{-4}$	0.06	0.07	<b><math>3.98 \times 10^{-4}</math></b>	0.05	0.05
40 : 1	$1.38 \times 10^{-3}$	0.09	0.07	<b><math>3.95 \times 10^{-3}</math></b>	0.04	0.03
20 : 1	0.01	—	<b>0.07</b>	0.03	0.03	0.14
10 : 1	0.10	—	—	0.17	<b>0.08</b>	0.27
无纯像元	0.14	0.17	0.09	0.39	0.09	<b>0.07</b>
无纯 20 : 1	0.10	—	0.19	<b>0.03</b>	0.12	0.28
r5						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$4.17 \times 10^{-6}$	0.31	0.14	<b><math>1.73 \times 10^{-5}</math></b>	0.24	0.06
80 : 1	$4.65 \times 10^{-5}$	0.31	0.14	<b><math>2.64 \times 10^{-4}</math></b>	0.21	0.42
60 : 1	$4.65 \times 10^{-4}$	0.32	0.14	<b><math>2.64 \times 10^{-3}</math></b>	0.21	0.07
40 : 1	$4.66 \times 10^{-3}$	0.39	0.14	<b>0.03</b>	0.22	0.13
20 : 1	0.17	—	<b>0.15</b>	0.53	0.22	0.45
10 : 1	0.50	—	—	2.00	0.68	<b>0.52</b>
无纯像元	0.39	0.45	—	—	0.41	<b>0.25</b>
无纯 20 : 1	—	—	—	—	—	<b>0.56</b>

表 3 不同信噪比条件下,端元提取结果的信息离散度(无法提取端元的结果用“—”表示)

Table 3 Showing values of Spectral Information Divergence for extracted endmembers on the condition of different values of signal to noise ratio(Using “—”to represent the falling results of endmembers extraction)

信息离散度(SID)						
r1						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$8.78 \times 10^{-13}$	$5.64 \times 10^{-5}$	$2.03 \times 10^{-5}$	<b><math>4.09 \times 10^{-10}</math></b>	$4.41 \times 10^{-5}$	$2.52 \times 10^{-5}$
80 : 1	$1.96 \times 10^{-10}$	$6.00 \times 10^{-5}$	$2.03 \times 10^{-5}$	<b><math>2.38 \times 10^{-8}</math></b>	$3.50 \times 10^{-5}$	$2.29 \times 10^{-5}$
60 : 1	$1.96 \times 10^{-8}$	$1.17 \times 10^{-4}$	$2.04 \times 10^{-5}$	<b><math>2.37 \times 10^{-6}</math></b>	$7.20 \times 10^{-6}$	$2.07 \times 10^{-5}$
40 : 1	$1.33 \times 10^{-6}$	$8.71 \times 10^{-4}$	$2.08 \times 10^{-5}$	<b><math>2.37 \times 10^{-6}</math></b>	$4.90 \times 10^{-5}$	$1.50 \times 10^{-4}$
20 : 1	0.02	—	<b><math>3.83 \times 10^{-5}</math></b>	$8.86 \times 10^{-3}$	$7.48 \times 10^{-5}$	$8.53 \times 10^{-3}$
10 : 1	$1.47 \times 10^{-3}$	—	—	0.02	<b><math>7.40 \times 10^{-3}</math></b>	0.03
无纯像元	$1.26 \times 10^{-3}$	$2.27 \times 10^{-3}$	$1.66 \times 10^{-3}$	$2.08 \times 10^{-5}$	$1.07 \times 10^{-4}$	<b><math>3.06 \times 10^{-6}</math></b>
无纯 20 : 1	0.01	—	0.02	<b><math>3.13 \times 10^{-3}</math></b>	$8.89 \times 10^{-4}$	0.02
r2						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$3.64 \times 10^{-11}$	0.07	0.03	<b><math>1.09 \times 10^{-9}</math></b>	0.02	0.10
80 : 1	$4.78 \times 10^{-9}$	0.07	0.03	<b><math>1.98 \times 10^{-7}</math></b>	0.04	$7.13 \times 10^{-4}$
60 : 1	$4.78 \times 10^{-7}$	0.07	0.03	<b><math>1.99 \times 10^{-5}</math></b>	0.04	0.01
40 : 1	$4.75 \times 10^{-5}$	0.13	0.03	<b><math>1.99 \times 10^{-5}</math></b>	0.04	$9.12 \times 10^{-3}$
20 : 1	0.0039	—	<b>0.03</b>	0.22	0.04	0.25
10 : 1	0.0681	—	—	1.13	<b>0.30</b>	0.47
无纯像元	0.13	0.19	0.10	<b>0.05</b>	0.08	0.05
无纯 20 : 1	0.36	—	0.18	<b>0.16</b>	0.20	0.39
r3						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$4.79 \times 10^{-12}$	0.02	0.01	<b><math>2.59 \times 10^{-10}</math></b>	0.02	$3.86 \times 10^{-4}$
80 : 1	$5.08 \times 10^{-10}$	0.02	0.01	<b><math>2.79 \times 10^{-8}</math></b>	0.01	0.04
60 : 1	$5.08 \times 10^{-8}$	0.02	0.01	<b><math>2.78 \times 10^{-6}</math></b>	0.02	$5.29 \times 10^{-4}$
40 : 1	$5.13 \times 10^{-6}$	0.05	0.01	<b><math>2.78 \times 10^{-6}</math></b>	0.01	$4.16 \times 10^{-3}$
20 : 1	$2.90 \times 10^{-3}$	—	<b><math>9.43 \times 10^{-3}</math></b>	0.03	0.02	0.07
10 : 1	0.35	—	—	0.44	<b>0.05</b>	0.15
无纯像元	0.06	0.10	0.07	0.02	0.04	<b>0.02</b>
无纯 20 : 1	0.13	—	—	0.09	<b>0.07</b>	0.10
r4						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$3.22 \times 10^{-12}$	$8.11 \times 10^{-3}$	0.01	<b><math>8.69 \times 10^{-12}</math></b>	$3.82 \times 10^{-3}$	$2.75 \times 10^{-4}$
80 : 1	$2.91 \times 10^{-10}$	$8.11 \times 10^{-3}$	0.01	<b><math>2.67 \times 10^{-9}</math></b>	$4.71 \times 10^{-3}$	0.10
60 : 1	$2.91 \times 10^{-8}$	$8.58 \times 10^{-3}$	0.01	<b><math>2.66 \times 10^{-7}</math></b>	$7.25 \times 10^{-3}$	0.01
40 : 1	$2.91 \times 10^{-6}$	0.02	0.01	<b><math>2.66 \times 10^{-7}</math></b>	$4.16 \times 10^{-3}$	$7.56 \times 10^{-3}$
20 : 1	$3.02 \times 10^{-4}$	—	0.01	<b><math>9.98 \times 10^{-4}</math></b>	$2.82 \times 10^{-3}$	0.04
10 : 1	0.01	—	—	0.04	<b>0.01</b>	0.13
无纯像元	0.04	0.06	0.05	0.18	0.02	<b>0.01</b>
无纯 20 : 1	0.11	—	<b>0.06</b>	0.07	0.09	0.14
r5						
SNR	VCA	SPP-N-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
100 : 1	$5.83 \times 10^{-11}$	0.22	0.06	<b><math>6.77 \times 10^{-10}</math></b>	0.16	0.01
80 : 1	$1.09 \times 10^{-8}$	0.22	0.06	<b><math>2.00 \times 10^{-9}</math></b>	0.12	0.37
60 : 1	$1.09 \times 10^{-6}$	0.22	0.06	<b><math>2.03 \times 10^{-5}</math></b>	0.12	0.02
40 : 1	$1.13 \times 10^{-4}$	0.31	0.06	<b><math>2.03 \times 10^{-5}</math></b>	0.12	0.06
20 : 1	0.08	—	<b>0.07</b>	0.50	0.14	0.39
10 : 1	0.47	—	—	1.72	0.64	<b>0.52</b>
无纯像元	0.32	0.39	—	—	0.31	<b>0.17</b>
无纯 20 : 1	—	—	—	—	—	<b>0.64</b>

纯像元假设的端元提取算法提取的结果(如 MV-SA、SPICE 和 PCOMMEDN)多数情况下在精度上高于纯像元假设的算法(如 VCA)。

此外,对于存在纯像元的情况下,表 2 和表 3 中被加粗的数值为各信噪比条件下的模拟数据实验结果的最优解(不包含 VCA)。通过表 2 和表 3 还可以看出当信噪比大于 40 : 1 时,MVSA 算法的提取结果优于除 VCA 外的其他 4 种算法,SPP-N-FIN-DR 算法在信噪比小于 20 : 1 后无法提取端元,MVC-NMF 在信噪比小于 10 : 1 后无法提取端元。

PCOMMEND 与 SPICE 提取结果较为近似,这是因为 PCOMMEND 算法在提取端元数目为素数时,实质上 and SPICE 算法相似。其原因是由于 PCOMMEND 算法的初始化是先确定若干小凸集区域的数量,然后将端元平均划分入不同的小凸集区域,如果端元的数量为素数,则无法完成前一步。若要用 PCOMMEND 算法提取的端元数量为素数的端元集时,则只能设置一个小凸集体,其实质类似于 SPICE 算法。例如,当端元数目为 8 时,可以设置小凸集体的数量为 2,每个小凸集体包含 4 个端元。当端元数目为 5 时,无法平均分配端元数目,只能设计一个凸集体,5 个端元全在这个凸集体中。

### 3.2 真实高光谱数据及实验分析

#### 3.2.1 真实高光谱数据

本文使用的真实高光谱数据来自 AVIRIS 遥感器在美国内达华州 Cuprite 地区采集的数据,如图 3 所示。采集时间是 1994 年 4 月 25 日。图像共 50 个波段,波长范围为 1.99~2.48 μm,空间大小为 400×350,假彩色合成波段为 R: 2.10 μm, G: 2.20 μm, B: 2.34 μm。Cuprite 数据在高光谱混合像元分解实验验证中被广泛应用,通过地质调查已经证明该区域存在着明矾石、高岭石和方解石等多种矿物<sup>[12-13]</sup>。

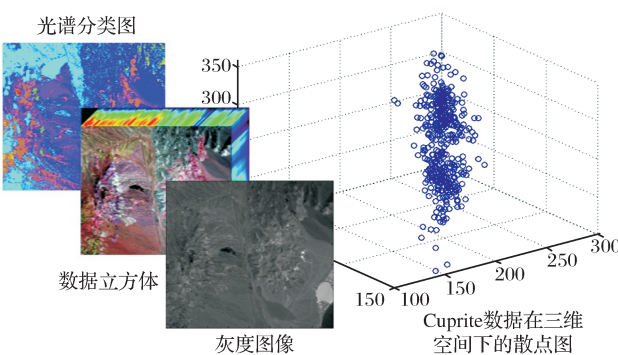


图 3 美国内达华州 Cuprite 地区 AVIRIS 高光谱数据

Fig. 3 AVIRIS hyperspectral dataset over the Cuprite district in Nevada

#### 3.2.2 实验结果及分析

真实的高光谱数据对应的地物类型分布复杂且无法确定端元数量,因此通过 Hysime<sup>[14]</sup> 算法对图像端元数目进行估计,得出端元数目  $M=8$ 。评价提取的端元包含原始图像信息量的多少时,当前国际普遍认可的方法是对比反混图像与原始图像的均方根误差(Root Mean Square Error, RMSE),均方根误差越小说明差异程度越低,得到的结果越好。反混图像是指利用提取出的端元和反演出的丰度矩阵相乘而重新合成的高光谱图像。

在此实验中,SPICE 的初始端元数设为 15,其他 5 种算法的端元数目均设置为 8。本文中 6 种算法最大迭代次数均设为 1 000。其余参数值均与对应文献提供的原始代码参数值保持一致。

此实验用反混图像与原始图像的均方根误差,以及提取出的端元与 USGS 光谱库提供的端元之间光谱角来衡量提取结果精度的优劣。原始图像与反混图像均方根误差为:

$$RMSE(mixed,remixed)=\frac{1}{N}\sum\sqrt{\frac{1}{L}\|x_i-\hat{x}_i\|_2^2}\quad(19)$$

其中:mixed 表示原始高光谱图像,remixed 表示反混图像。 $x_i$  为原图像的像元, $\hat{x}_i$  为反混图像的像元。

根据表 4 和图 5 可看出,PCOMMEND 的 RMSE 结果最好。这是因为通过 Hysime 算法估计出的端元数量  $M=8$ ,由于 8 是合数,避免了 PCOMMEND 算法应对端元数量为素数时的缺陷,因而该算法的优势得以发挥,得到的 RMSE 结果也最好。SPICE 和 MVSA 的 RMSE 结果次之,大致相同。在所有算法实验结果中,SPP-N-FINDR、MVC-NMF 得出的 RMSE 实验结果最差。

RMSE 值虽能较好地反映提取出的端元包含原图像的信息量,但却不能反映提取出的端元向量与真实的端元向量之间的差异,若要比其向量差异,得出更为准确的评价结果,还须用进行光谱角比较。

由图 4 可以看出,本文的 6 种算法总共可以提

表 4 原始图像与反混图像均方根误差比较	
Table 4 Values of Root Mean Square Error (RMSE) between original image and back mixed image	
算法	RMSE
VCA	3.66
SPP-N-FINDR	4.24
MVC-NMF	4.52
MVSA	2.59
SPICE	2.67
PCOMMEND	0.56

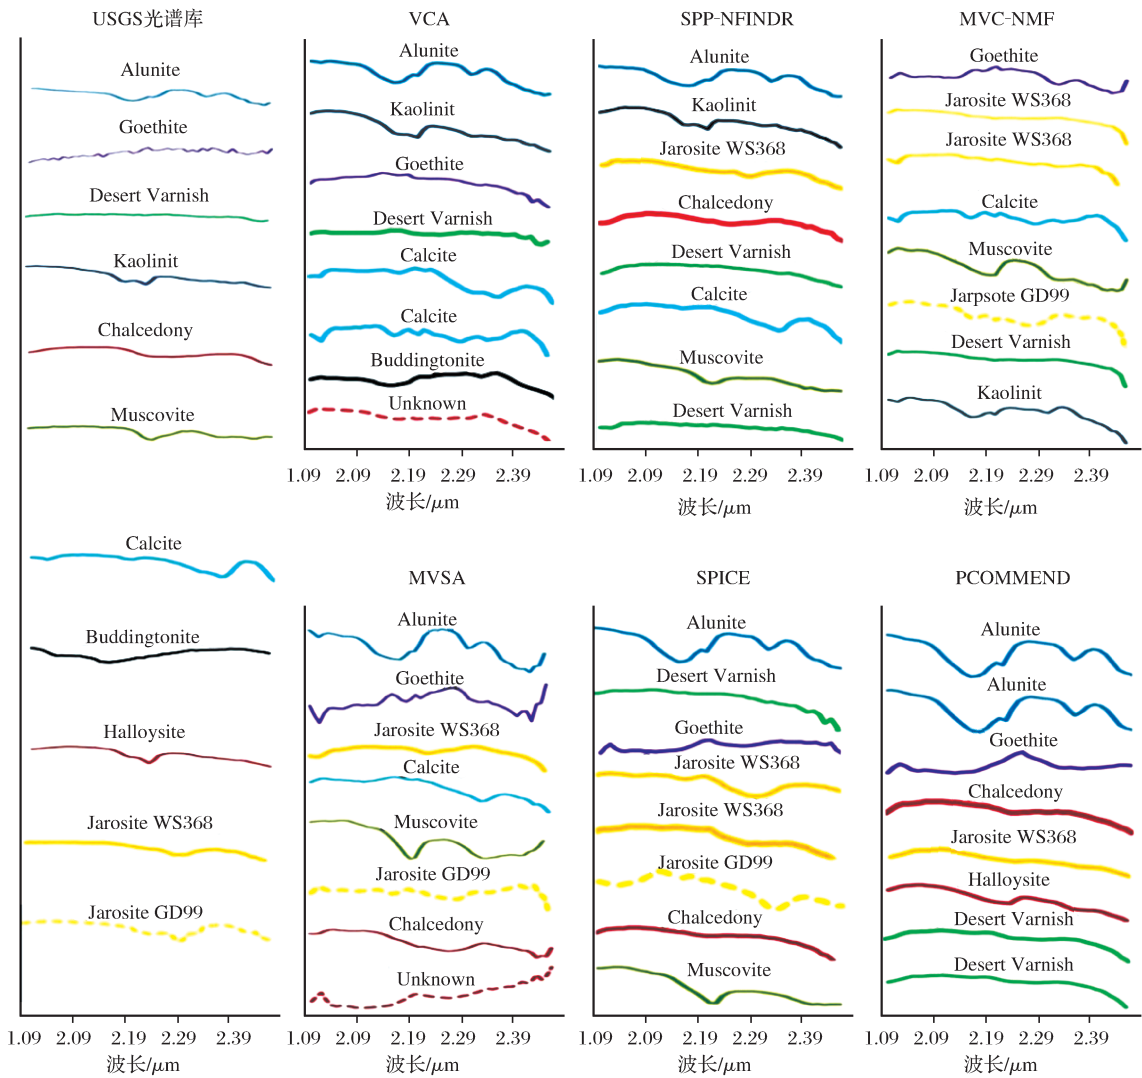


图 4 USGS 光谱库提供的端元光谱及文中 6 种算法提取的端元光谱

Fig. 4 Showing spectrums provided by USGS library and spectrums extracted by each algorithm

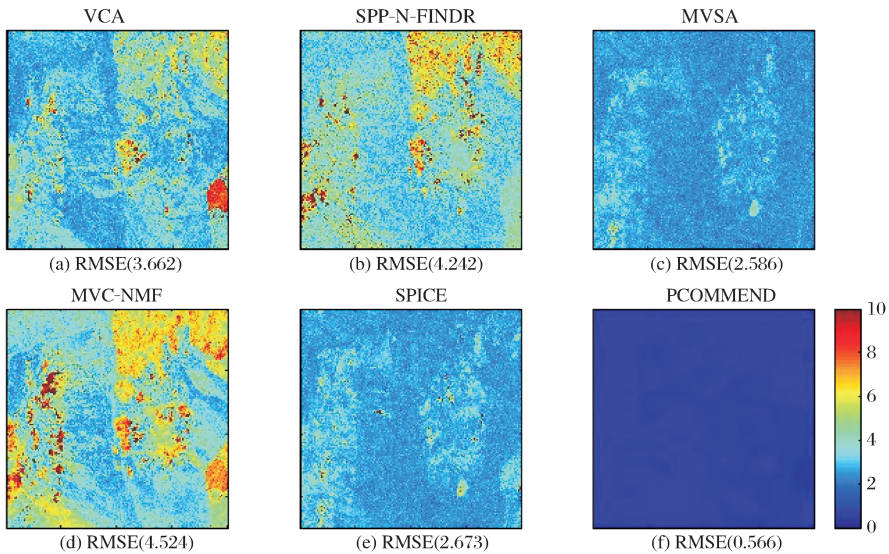


图 5 各种算法反演丰度的误差图 (RMSE)

Fig. 5 Maps of Root Mean Square Error by various algorithms

表 5 通过各算法提取的 8 种矿物端元光谱与 USGS Library 提供的矿物端元光谱之间的  
光谱角(弧度)(无法提取端元的结果用“—”表示)

Table 5 Spectral angle scales (in radian) between extracted 8 endmember spectrums and USGS  
mineral spectrums(Using “—”to represent the falling results of endmembers extraction)

端元	算法					
	VCA	SPP-FINDR	MVC-NMF	MVSA	SPICE	PCOMMEND
Alunite	0.15	0.11	—	0.18	<b>0.10</b>	0.23
Calcite	<b>0.07</b>	0.08	0.13	0.09	—	—
Desert Varnish	<b>0.04</b>	0.06	0.10	—	0.19	0.06
Goethite	0.20	—	0.21	0.23	<b>0.05</b>	0.12
Jarosite WS368	—	0.10	0.06	0.07	<b>0.05</b>	0.19
Kaolinite	<b>0.10</b>	0.13	0.16	—	—	—
Chalcedony	—	<b>0.06</b>	—	0.16	0.06	0.07
Muscovite	—	0.11	<b>0.21</b>	0.22	0.25	—

取 11 种矿物端元, SPP-N-FINDR、MVC-NMF、MVSA 和 SPICE 可提取 7 种端元,VCA 和 PCOMMEND 可提取 6 种端元。从 11 种端元中选出具有代表性的 8 种端元进行光谱角比较,如表 5 所示。通过表 5 可以看出,VCA 和 SPICE 提取的端元结果中有 3 次达到最小值,就整体情况而言,它们的光谱角比较结果在精度上高于其他 4 种。

综上,Curpite 数据的实验中,SPICE 算法的提取结果最优,VCA 算法次之。在真实数据应用中,根据有无纯像元存在的实际情况,这两个算法是可以考虑的优先选择。

4 结 语

高光谱图像在遥感领域逐渐发挥着越来越重要的作用,在地物识别、矿物检测和灾害监测等方面也有着越来越广泛的应用。混合像元的存在是高光谱图像普遍面临的问题,因此混合像元分解对于高光谱遥感的应用与发展有极其重要的作用,而端元提取是混合像元分解的一项关键技术。本文通过两个实验对 SPP-N-FINDR、VCA、MVSA、MVC-NMF、SPICE 和 PCOMMEND 6 种算法进行测评,对这 6 种算法进行比较和分析后得出以下 5 点结论。

(1)N-FINDR、VCA 是基于凸集几何模型端元提取的经典算法,这两种算法皆基于纯像元假设(即图像中有纯像元存在),如果图像中不存在纯像元或纯像元较少时得到结果精度会有所下降。N-FINDR 加入了 SPP(空间预处理)后,抗噪声能力有所增强<sup>[8]</sup>,但是依然不如其他 5 种算法。通过模拟实验与真实数据实验表明,VCA 作为经典算法,虽然提出时间相对较早,但目前在稳定性和精度上取得

结果依然最为理想。  
(2)根据模拟数据实验和真实数据实验发现 MVSA 算法的稳定性较好,相似度测评结果也相对较好,对最小体积变换思想的广泛应用有非同寻常的意义。但是该算法在使用前需要已知端元数目,自动化程度不如 MVC-NMF 和 SPICE。  
(3)MVC-NMF 算法在提取端元的同时能反演出其丰度,其自动化程度较高。在模拟数据实验中的结果呈现出一定的随机性(即并非信噪比越低结果越差),在真实数据实验中得到的均方根误差结果和光谱角比较结果相对其他 5 种算法较差,这可能与它最小化近似误差来改变单形体大小有关,也是今后需进一步研究的问题。

(4)SPICE 基于稀疏策略的端元提取算法,它无需已知端元数目,自动化程度较高。通过模拟与真实数据的两个实验的评价结果来看,SPICE 算法的评价精度相对较好。但是,SPICE 算法提取出端元的数量有一定随机性,即使用同一幅高光谱图像,在不同实验中提取的端元数量也不一定相同。

(5)PCOMMEND 算法的思想打破了传统的凸集(单形体)理念,将模糊分类理论引入了端元提取技术中,将凸集几何与模式识别理论巧妙结合。在真实数据实验中,PCOMMEND 的均方根误差实验结果最好,能较好地保存原始图像的信息量,且能直接得到端元比例值矩阵。对于端元数量为素数时精度下降的问题,目前还未能解决。同时,PCOMMEND 算法在使用前也必须已知端元数量,这些问题都应进一步研究。

参考文献(References):

[1] Tong Qingxi, Zhang Bing, Zheng Lanfen. Hyperspectral Re-

- remote Sensing[M]. Beijing: High Education Press, 2007. [童庆禧, 张兵, 郑兰芬. 高光谱遥感原理、技术与应用[M]. 北京, 高等教育出版社, 2007.]
- [2] Winter E M. N-FINDR: An Algorithm for Fast Autonomous Spectral Endmember Determination in Hyperspectral Data [C]//SPIE Conference on Image Spectrometry, 1999: 266-275.
- [3] Nascimento J M P, Bioucas-Dias J M. Vertex Component Analysis: A Fast Algorithm to Unmix Hyperspectral Data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(4): 898-910.
- [4] Zare A, Gader P. Sparsity Promoting Iterated Constrained Endmember Detection in Hyperspectral Imagery [J]. IEEE Geoscience and Remote Sensing Letters, 2007, 4(3): 446-450.
- [5] Zare A, Gader P. Piece-wise Convex Multiple-model Endmember Detection and Spectral Unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(5): 2853-2861.
- [6] Li J, Bioucas-Dias J M. Minimum Volume Simplex Analysis: A Fast Algorithm to Unmix Hyperspectral Data [C]//IEEE International Geoscience and Remote Sensing, 2008: 250-253.
- [7] Miao L, Qi H. Endmember Extraction From Highly Mixed Data Using Minimum Volume Constrained[J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(3): 765-777.
- [8] Zortea M, Plaza A. Spatial Preprocessing for Endmember Extraction[J]. IEEE International Geoscience and Remote Sensing, 2009, 47(8): 2679-2693.
- [9] Berman M, Kiiveri H, Lagerstrom R, *et al.* ICE: A Statistical Approach to Identifying Endmembers in Hyperspectral Images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(10): 2085-2095.
- [10] Zare A, Gader P. PCE: Piece-wise Convex Endmember Detection and Spectral Unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(5): 1-14.
- [11] Maurice D C. Minimum-volume Transforms for Remotely Sensed Data[J]. IEEE Transactions on Geoscience and Remote Sensing, 1994, 32(3): 542-552.
- [12] Abrams M J, Ashley R P, Rowan L C, *et al.* Mapping of Hydrothermal Alteration in the Cuprite Mining District, Nevada, Using Aircraft Scanner Image for the Spectral Region 0.46 to 2.36  $\mu\text{m}$  [J]. Geology, 1977, 5(12): 713-718.
- [13] Resmini R, Kappus M, Aldrich W, *et al.* Mineral Mapping with Hyperspectral Digital Imagery Collection Experiment (HYDICE) Sensor Data at Cuprite Nevada, USA[J]. International Journal of Remote Sensing, 1997, 18(7): 1553-1570.
- [14] Lee D D, Seung H S. Algorithms and Applications for Approximate Nonnegative Matrix Factorization [J]. Elsevier Computation Statistics & Data Analysis, 2007, 52(2007): 155-173.
- [15] Zhang X, Tong X, Liu M. An Improved N-FINDR Algorithm for Endmember Extraction in Hyperspectral Imagery [C]//IEEE Urban Remote Sensing Joint. Event, 2009: 978-983.
- [16] Bioucas-Dias J M, Nascimento J M. Hyperspectral Subspace Identification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(8): 2435-2445.
- [17] Bioucas-Dias J M, Plaze A, Dobigon N, *et al.* Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-based Approaches[J]. IEEE Journal of Selected Topics in Earth Observation and Remote Sensing, 2012, 5(2): 354-379.
- [18] Charles E A. Mixtures of Dirichlet Processes with Applications to Bayesian Nonparametric Problems[J]. JSTOR The Annual of Statistics, 1974, 2(6): 1152-1174.
- [19] Geng X, Zhao Y, Wang F, *et al.* A New Volume Formula for A Simplex and Its Application to Endmember Extraction for Hyperspectral Image Analysis [C]//IEEE International Journal of Remote Sensing, 2010: 1027-1035.
- [20] Victor F H, Yosio E S. Spectral Linear Mixing Model in Low Spatial Resolution Image Data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(11): 2555-2562.
- [21] Lopez S, Horstrand P, Callico G M, *et al.* A Low-Computational-Complexity Algorithm for Hyperspectral Endmember Extraction: Modified Vertex Component Analysis [J]. IEEE Geoscience and Remote Sensing Letter, 2012, 9(3): 502-506.
- [22] Plaza A, Martinez P, Plaza Javier, *et al.* A Quantitative and Comparative Analysis of Endmember Extraction Algorithms from Hyperspectral Data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(3): 650-663.
- [23] Zare A, Gader P, George Casella. Sampling Piecewise Convex Unmixing and Endmember Extraction[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(3): 1655-1665.
- [24] Gao Jianwei. Research on Hyperspectral Images Information Extraction Algorithms based on Ant Colony Optimization [D]. Beijing: University of Chinese Academy of Sciences, 2005. [高建威. 基于蚁群优化算法的高光谱图像信息提取方法研究[D]. 北京: 中国科学院大学, 2014.]
- [25] Xue Qi, Kuang Gangyao, Li Zhiyong. Endmember Extraction Algorithms from Hyperspectral Image based on The Linear Mixing Model: An Overview[J]. Remote Sensing Technology and Application, 2004, 19(31): 197-201. [薛茜, 匡纲要, 李智勇. 基于线性混合模型的高光谱图像端元提取[J]. 遥感技术与应用, 2004, 19(31): 197-201.]
- [26] Peng Qingqing, Yang Liao, Wang Jie, *et al.* Endmember Extraction based on Anomaly Detection [J]. Remote Sensing Technology and Application, 2011, 26(4): 457-461. [彭青青, 杨辽, 王杰, 等. 基于异常探测的高光谱端元提取方法研究[J]. 遥感技术与应用, 2011, 26(4): 457-461.]
- [27] 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. [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: 中国科学院对地观测与数字地球科学中心, 2011.]



引用格式: Li Xiaojun, Lü Heng, Li Yunmei, *et al.* Modification of Cellular Automata (CA) Used in Sub-pixel Mapping[J]. Remote Sensing Technology and Application, 2015, 30(6): 1206-1214. [李晓俊, 吕恒, 李云梅, 等. 遥感图像亚像元定位元胞自动机算法改进研究[J]. 遥感技术与应用, 2015, 30(6): 1206-1214.]  
doi: 10.11873/j.issn.1004-0323.2015.6.1206

# 遥感图像亚像元定位元胞自动机算法改进研究

李晓俊, 吕 恒, 李云梅, 王 瑜, 张 杰, 潘洪洲

(南京师范大学虚拟地理环境教育部重点实验室, 江苏 南京 210023)

**摘要:** 元胞自动机模型(CA)常用于图像亚像元定位, 它将混合像元剖分为亚像元, 再利用端元组分的丰度及像元空间分布的特点, 将亚像元赋予不同端元组分得到各端元组分的空间分布情况。但其存在迭代次数过多、进化过程“不充分”以及结束迭代的条件不明确等缺点。针对上述问题, 对亚像元定位 CA 算法进行了 3 方面的改进。结果表明: 最终的亚像元定位结果调整后 Kappa 系数虽然平均只提高了 4.1% 与 3.7%, 但迭代次数大幅减少, 均在 5 次以内得到最优结果; 运行时间大幅下降, 仅占原方法的 25.8%, 使得 CA 的运行效率得到了显著提高。此外明确了 CA 的终止条件, 使得面向亚像元定位的 CA 算法更具实际应用价值。

**关键词:** 遥感; 亚像元定位; 元胞自动机; 尺度

**中图分类号:** TP 751.1      **文献标志码:** A      **文章编号:** 1004-0323(2015)06-1206-09

## 1 引 言

众所周知, 在遥感影像应用中的一个常见问题就是存在大量的混合像元<sup>[1]</sup>。在传统的土地利用分类中, 通常都是将混合像元归属到某一特定的地物类型中, 显然这种方法是不合理的, 因为它并不完全属于某个地物类型。鉴于此, 很多学者采用模糊分类的方法, 以获取像元内每种地物类型所占的比例<sup>[2]</sup>。然而模糊分类只能获取某种地物类型所占的面积比例, 并不能获取其在混合像元内的空间位置分布, 在许多遥感应用中, 其空间分布又是非常重要的信息, 因此有必要对混合像元内地物的空间位置进行求解, 亚像元定位技术正是以解决该问题为基本任务和目标<sup>[3]</sup>。

亚像元定位最早出现在制图应用上面, 1997 年 Atkinson<sup>[4]</sup>提出了亚像元定位的像元空间分布相关性理论。此后, 更多学者开始关注亚像元尺度上的遥感影像土地覆盖制图问题, 并提出了一些实际的模型, 亚像元定位算法总体上可以分为直接求解算法和

迭代方法两种。直接求解包括线性规划<sup>[5]</sup>、吸引力排序<sup>[6]</sup>以及 Ge 等<sup>[7]</sup>提出的根据端元组分比进行直接定位的方法; 迭代算法主要包括遗传算法<sup>[2]</sup>、opfield 神经网络<sup>[8-10]</sup>、正则 MAP 模型<sup>[11]</sup>、像元交换<sup>[12]</sup>、模拟退火<sup>[13]</sup>以及进化 Agent 模型<sup>[14]</sup>等。近期研究中, Ling 等<sup>[15]</sup>综合使用像元间与像元内地物相关性提出一种亚像元定位方法, Xu 等<sup>[16]</sup>使用多转移影像辅助的方法构建吸引力模型, 得到了较好的结果。

直接求解不需要迭代计算, 算法效率高, 运行速度快; 迭代方法则通常是计算亚像元尺度上的空间相关性, 能更好地反映地物的空间相关性<sup>[17]</sup>, 但是由于需要迭代运行, 因此运行速度偏慢。元胞自动机模型(CA)是一种简单有效的解决亚像元定位问题的迭代方法<sup>[18]</sup>。

但是利用元胞自动机迭代会耗费大量的计算时间并受周围邻域的范围大小影响, 这种情况在亚像元的尺度因子较大的情况下尤为突出; 其次, 元胞自动机运行的次数没有一个明确的终止条件; 再者, 在一

收稿日期: 2014-06-05; 修订日期: 2015-09-23

基金项目: 国家自然科学基金项目“微囊藻生物光学特性及其遥感定量识别研究”(41171269)。

作者简介: 李晓俊(1990—), 男, 江苏靖江人, 硕士研究生, 主要从事水环境遥感、亚像元定位、地理信息系统等方面的研究。

E-mail: leewith126@126.com。

通讯作者: 吕 恒(1977—), 男, 安徽滁州人, 教授, 主要从事水环境遥感方面的研究。E-mail: Henlu@njnu.edu.cn。