

高连如¹ 孙旭¹ 罗文斐² 唐茂峰¹ 张兵^{1,3}

高光谱遥感图像混合像元分解的群智能算法

摘要

近年来,通过群智能算法求解组合优化或连续优化问题以实现高光谱图像混合像元分解方面取得了重要进展和显著成果.本文首先回顾了高光谱图像混合像元分解的研究背景和群智能算法的特点,然后梳理了光谱混合模型及对应的最优化模型,进而介绍了基于群智能算法的端元提取和丰度反演方法,最后通过2组实验比较了群智能算法和其他传统算法在端元提取和丰度反演方面的精度,对基于群智能算法的混合像元分解效果进行了评价.另外,本文也对群智能算法在高光谱图像信息提取中应用的优势和存在的问题进行了总结.

关键词

高光谱图像;混合像元分解;群智能;端元提取;丰度反演

中图分类号 TP18;TP751

文献标志码 A

收稿日期 2017-11-10

资助项目 国家自然科学基金(41571349,91638201)

作者简介

高连如,男,博士,研究员,主要研究高光谱图像处理与信息提取.gaolr@radi.ac.cn

1 中国科学院遥感与数字地球研究所,北京,100094

2 华南师范大学 地理科学学院,广州,510631

3 中国科学院大学,北京,100049

0 引言

高光谱遥感技术能够同时获取目标区域的2维几何空间信息与1维光谱信息,具有“图谱合一”的特点和优势(图1).高光谱图像中的每个像元记录着瞬时视场角内几十甚至上百个连续波段的光谱信息,反映出能够区分不同物质的诊断性光谱特征,使得在宽波段多光谱遥感图像中不可探测的地物在高光谱遥感中能够被探测^[1].但是由于成像光谱仪空间分辨率的限制,混合像元问题在高光谱遥感图像中广泛存在,是影响高光谱图像信息提取精度的重要因素,阻碍了高光谱遥感图像在资源环境、国防军事、工农业生产等领域中的应用.因此,混合像元分解方法的研究一直是高光谱图像处理的重要内容之一^[2].

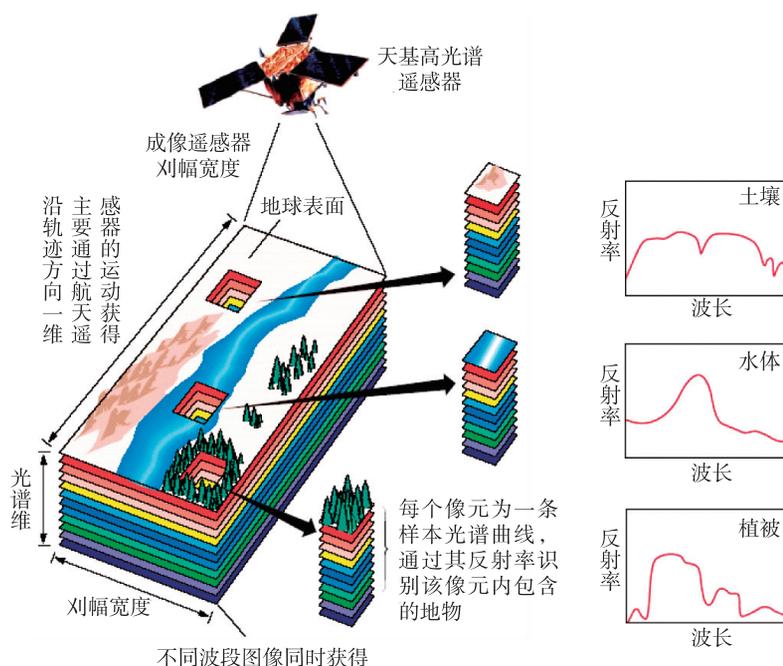


图1 高光谱遥感图像与光谱曲线^[3]

Fig.1 Hyperspectral remote sensing image and spectral curves

混合像元指的是在一个像元中包含多种不同的物质,混合像元分解(也称为光谱解混)的主要目的就是分析出混合像元中包含哪些物质(称为端元)以及它们所占的比例(称为丰度).为了实现混合像

元分解,通常需要建立光谱混合物理过程的数学模型,进而设计混合像元分解算法并评价混合像元分解精度.典型的光谱混合模型可以分为线性光谱混合模型、非线性光谱混合模型和正态组分模型^[4].其中,线性光谱混合模型在混合像元问题中广泛使用,这是因为其在一定条件下能够符合光谱混合过程的物理原理,同时形式简单且易于设计算法和分析比较.以线性光谱混合模型为基础的端元提取算法又可以根据设计思路具体分为几何学方法、统计学方法、稀疏表示方法和融合空间信息方法等类型^[5].其中,几何学方法又可根据端元单形体与数据点云在高维空间中的位置关系分为内部最大体积法和外部最小体积法,其中有部分算法需要应用纯像元假设.非线性光谱混合模型是线性模型的推广,用来描述光谱混合过程中的多重散射效应,相对于线性光谱解混,非线性光谱解混对于处理高分辨率和复杂场景中的混合像元现象更具优势^[6].比较典型的非线性光谱混合模型有 NM 模型^[7]、FM 模型^[8]和 GBM 模型^[9]等.正态组分模型是线性光谱混合模型的一种扩展,用概率来描述光谱的不确定性,将端元视为一个呈给定概率分布的随机变量,利用特定参数来表示端元光谱变异性^[10].

群智能算法是人工智能的一个重要分支,指的是一类模拟自然界低智能个体通过分工协作完成复杂任务的优化算法.“群智能”中的“群”指的是“一组相互之间可以进行直接通信或者间接通信的主体,这组主体能够合作进行分布式的问题求解”,而“智能”指的是“无智能的主体通过合作表现出智能行为的特性”^[11].群智能算法的产生得益于生物学对社会性动物的自组织行为的观察和研究.在近 20 年中,群智能算法得到了快速的发展,在求解一些复杂的最优化问题方面体现出显著的优势和巨大的潜力.典型的群智能算法包括蚁群算法 (ACO)、粒子群算法 (PSO)、萤火虫算法 (FA) 和蜂群算法 (ABC) 等.

混合像元分解问题可以基于不同的假设条件转化为具有不同目标函数和约束条件的最优化问题,这些最优化问题往往是非线性的、非凸的,因此非常适合利用群智能算法等启发式算法搜索最优解.2011 年, Zhang 等^[12-13]分别利用蚁群优化算法和离散粒子群算法,通过求解组合优化形式的线性光谱混合模型的方法进行端元提取;2013 年, Zhang 等^[14]采用精英蚂蚁策略又对蚁群优化的端元提取

算法做了进一步改进;然后,2014 年, Gao 等^[15]比较了不同预处理方式对离散粒子群端元提取结果的影响,同时又提出了基于蚁群优化的多算法融合端元提取策略;2015 年, Sun 等^[16]利用人工蜂群算法完成了不依赖纯像元假设情况下的端元提取;2016 年, Su 等^[17]改进了蚁群优化和离散粒子群优化端元提取的目标函数,同时提出了离散人工蜂群优化的端元提取算法;2016 年, Luo 等^[18]利用双种群粒子群优化算法解决了基于双线性光谱混合模型的光谱解混问题.

本文首先回顾了常用的光谱混合模型并梳理了高光谱图像混合像元分解的基本流程;然后分别介绍了典型的基于群智能算法的端元提取算法和丰度反演算法,包括算法的基本原理和处理过程;最后通过真实高光谱图像实验对比了群智能算法和传统算法的混合像元分解效果.另外,本文也对群智能算法在高光谱图像处理方面的问题与挑战进行了归纳总结.

1 光谱混合模型

高光谱图像混合像元分解是为了确定混合像元中的基本组成地物及其所占比例.具体而言,解决这个问题可以分为 2 个步骤^[19]:

- 1) 端元提取 (endmember extraction), 确定混合像元的基本组成地物;
- 2) 丰度反演 (abundance inversion), 量化组成地物的比例.

为了实现光谱解混,需要构建数学模型来描述光谱混合的物理过程,且根据抽象程度的不同,光谱混合模型可以被分为线性光谱混合模型 (Linear Spectral Mixing Model, LSMM) 和非线性光谱混合模型 (Nonlinear Spectral Mixing Model, NLSMM).地物的混合模式、物理分布的空间尺度大小与结构决定了非线性的程度,大尺度、空间上均匀的光谱混合通常被认为是一种线性混合,而小尺度、复杂空间结构上的物质混合则是非线性的.

1.1 线性光谱混合模型

线性光谱混合模型假设太阳入射辐射是平行的,且在被传感器接收前,每束信号只与一种地物表面发生作用,每个光子仅能“看到”一种物质并将其信号叠加到像元光谱中.线性光谱混合模型在混合像元问题中广泛使用,这是因为其在一定条件下能够符合光谱混合过程的物理原理,同时形式简单,易

于设计算法和分析比较.假设像元 r_i 由 m 个端元 $\{e_j\}_{j=1}^m$ 组成,则线性光谱混合模型可表示为

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

式中, ε_i 为误差项, α_{ij} 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:

$$\alpha_{ij} \geq 0, \quad \forall i, j, \quad (2)$$

$$\sum_{j=1}^m \alpha_{ij} = 1, \quad i = 1, 2, \dots, n, \quad (3)$$

其中,式(2)称为“非负”约束,式(3)称为“和为1”约束.

目前,以线性光谱混合模型为基础的端元提取算法已经取得了长足的发展,根据设计思路分为几何学方法、统计学方法和稀疏回归方法等类型^[5].几何学方法的核心思想是寻找能包含像元点的单形体顶点,由于丰度的“非负”约束与“和为1”约束,所有线性混合像元都处在以端元为顶点的单形体之中,如图2所示.几何学方法又可根据端元单形体与像元点云构成的凸包之间的关系分为内部最大体积法和外部最小体积法.由于体积的计算公式的限制,应用此类方法提取端元之前需要先对原图像 $\{r_i\}_{i=1}^N$ 进行降维,得到 $\{\bar{r}_i\}_{i=1}^N$,其中 $\bar{r}_i \in \mathbf{R}^{M-1}$. $\{\bar{r}_i\}_{i=1}^N$ 对应的低维端元记为 $\{\bar{e}_j\}_{j=1}^M$,其体积定义为

$$V(\{\bar{e}_j\}_{j=1}^M) = \frac{1}{(M-1)!} \cdot \left| \det \begin{pmatrix} 1 & 1 & \dots & 1 \\ \bar{e}_1 & \bar{e}_2 & \dots & \bar{e}_M \end{pmatrix} \right|, \quad (4)$$

则内部最大体积法的最优化模型为

$$\begin{aligned} \max \quad & V(\{\bar{e}_j\}_{j=1}^M), \\ \text{s.t.} \quad & S(\{\bar{e}_j\}_{j=1}^M) \subseteq \text{cov}(\{\bar{r}_i\}_{i=1}^N), \end{aligned} \quad (5)$$

外部最小体积法的最优化模型为

$$\begin{aligned} \min \quad & V(\{\bar{e}_j\}_{j=1}^M), \\ \text{s.t.} \quad & \text{cov}(\{\bar{r}_i\}_{i=1}^N) \subseteq S(\{\bar{e}_j\}_{j=1}^M), \end{aligned} \quad (6)$$

其中, $S(\{\bar{e}_j\}_{j=1}^M)$ 表示以 $\{\bar{e}_j\}_{j=1}^M$ 为顶点的单形体, $\text{cov}(\{\bar{r}_i\}_{i=1}^N)$ 表示包含 $\{\bar{r}_i\}_{i=1}^N$ 的最小凸集,即 $\{\bar{r}_i\}_{i=1}^N$ 的凸包.

典型的几何学方法中, PPI^[20]、NFINDR^[21]、VCA^[22]、SGA^[23]、SMACC^[24]、AVAMX^[25]、SVMAX^[25] 等属于内部最大体积法; MVSA^[26]、MVES^[27]、RMVES^[28] 和 MVC-NMF^[29] 等属于外部最小体积法.

统计学方法将光谱解混视为一个统计推理问题,主要包括独立成分分析^[30]、依赖成分分析^[31]和

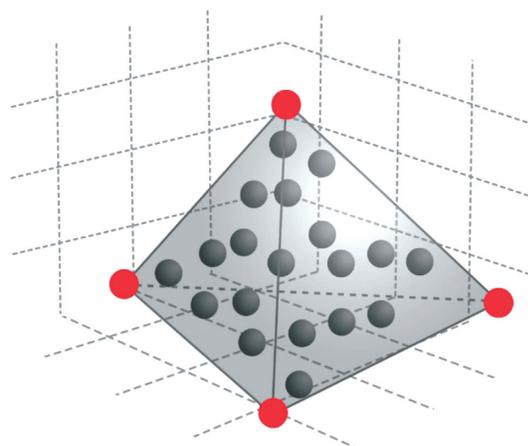


图2 端元单形体示意(红色为端元,灰色为混合像元)
Fig. 2 The endmember simplex, with red as endmembers and gray as mixing image pixels

贝叶斯分析^[32]等.稀疏回归方法是一类基于半监督学习的光谱解混方法,它需要一个完备光谱库作为先验知识并在求解中对端元添加稀疏约束以求得一个可靠的有效端元集,主要包括 SPICE^[33]、SUN-SAL^[34]、SUnSAL/TV^[35] 和 L1/2-NMF^[36] 等.

另外,根据纯像元是否存在,LSMM 模型求解算法可分为纯像元算法和非纯像元算法.纯像元算法中假设每个纯地物都对应图像中的至少一个像元,而后者则假设至少一个纯地物在图像中找不到对应的像元.

1.2 非线性光谱混合模型

相对于线性模型,非线性光谱混合模型考虑了光子与物质接触时的能量传递过程和光子在不同物质之间的多重散射.依据辐射传输理论,很多针对特定的地物类型的非线性光谱混合模型被提出,但这一类模型结构复杂、模型假设多,在实际的使用中需要观测许多受环境影响的参量,从而导致其推广受到限制^[6].

与此同时,许多不针对特定地物类型、通用性更强的非线性光谱混合模型也被提出了.这一类模型避免了引入复杂的物理过程从而简化了参数反演过程.1979年, Singer 等^[37] 首先提出了两端元双线性模型,并应用于火星表面物质的分析;1998年, Zhang 等^[38] 提出了土壤和植被之间光谱相互作用的两端元双线性模型;2010年, Raksuntorn 等^[7] 提出了一种多端元双线性的 NM 模型:

$$r = E\alpha + \sum_{i=1}^{m-1} \sum_{j=i+1}^m \beta_{i,j} e_i \odot e_j + \varepsilon, \quad (7)$$

其中 $\sum_{k=1}^m \alpha_k + \sum_{i=1}^{m-1} \sum_{j=i+1}^m \beta_{i,j} = 1, \alpha_k \geq 0, \beta_{i,j} \geq 0$. 式中 \odot

表示 Hadamard 积,这一项的意义是考虑了端元间的二次反射,将其称为双线性项.相对于线性模型,双线性项可以被视为额外的端元.通过一个一般非线性混合方程的有限泰勒展开,Fan 等^[8]也提出了一种双线性的 FM 模型,它与式(2)形式相同,但约束条件为

$$\begin{cases} \sum_{k=1}^m \alpha_k = 1, & \alpha_k \geq 0, \\ \beta_{i,j} = \alpha_i \alpha_j. \end{cases} \quad (8)$$

在此基础上,Halimi 等^[9]提出了广义双线性模型(GBM).与 FM 不同的是,该模型在双线性项中增加相互作用系数 γ_{ij} ,即:

$$\mathbf{r} = \mathbf{E}\boldsymbol{\alpha} + \sum_{i=1}^{m-1} \sum_{j=i+1}^m \gamma_{ij} \alpha_i \alpha_j \mathbf{e}_i \odot \mathbf{e}_j + \boldsymbol{\varepsilon}. \quad (9)$$

它需要满足的约束如下:

$$\begin{cases} \alpha_k \geq 0, & k = 1, \dots, m, \\ \sum_{k=1}^m \alpha_k = 1, \\ \gamma_{ij} \in [0, 1], & i = 1, \dots, m; j = i + 1, \dots, m, \end{cases} \quad (10)$$

式中, $\gamma_{ij} \in [0, 1]$ 是因为 2 次反射的路径相对于只经过一个地物的独立路径更加长,使得信号的强度变小.显然,当 $\gamma_{ij} = 0$ 时,广义双线性模型即为 LSMM; 当 $\gamma_{ij} = 1$ 时,广义双线性模型即为 FM.

2 端元提取的群智能算法

2.1 蚁群优化端元提取

蚁群优化算法的端元提取方法(Ant Colony Optimization for Endmember Extraction, ACO-EE)是以蚁群算法为基础的^[12].蚁群算法是通过模拟自然界中的蚂蚁的行动方式和交流方式解决问题的群智能启发式算法.自然界中的蚂蚁通过“信息素”进行交流,大量的蚂蚁组成的群体去寻找巢穴和食物源之间的最短路径.如果将寻找最短路径视为一个最优化问题,那么起点(巢穴)到终点(食物源)之间的每一条路径都可以视为这个最优化问题的可行解,相应的,最优化问题的目标函数是路径的长度,最优化问题就是将目标函数最小化,最短路径就是最优化问题的解.因此,只要一个问题能够转化成上述最优化问题,就可以用蚁群算法来求解.

根据 LSMM 和纯像元假设,并将原始高光谱图像与反混图像的均方根误差(Root Mean Square Error, RMSE)作为目标函数,端元提取问题可转换为如下最优化问题:

$$\begin{aligned} \min \quad & E_{\text{RMS}}(\{\mathbf{r}_i\}_{i=1}^n, \{\mathbf{e}_j\}_{j=1}^m), \\ \text{s.t.} \quad & \{\mathbf{e}_j\}_{j=1}^m \in C(\{\mathbf{r}_i\}_{i=1}^n, m), \end{aligned} \quad (11)$$

其中, $C(\{\mathbf{r}_i\}_{i=1}^n, m)$ 表示包含 $\{\mathbf{r}_i\}_{i=1}^n$ 中 m 个元素的集合构成的集合.

设 $G = \{V, E, H\}$ 为一个有向有权图,其中 $V = \{v_i\}_{i=0}^n$ 为顶点集合,每个顶点 v_i 对应一个像元 x_i , v_0 作为算法的起始顶点,不对应任何像元; $E = \{\langle v_i, v_j \rangle \mid \forall i, \forall j \neq 0\}$ 为有向边集, $\langle v_i, v_j \rangle$ 表示从 v_i (起点) 指向 v_j (终点) 的一条有向边; $H = \{\eta_{ij}\}$ 为有向边权值集, η_{ij} 为有向边 $\langle v_i, v_j \rangle$ 上的权值.这样, G 就构造了一个包括所有像元和像元关系的有向有权图.在这个图中,式(11)中的一个可行解就转化成了 G 中的一条包含 m 个顶点(不包括起始顶点)的路径.人工蚂蚁从起始顶点出发,延有向边依次移动到 m 个顶点并构造一条路径即完成了一次端元选取,每条有向边的终点对应的像元即为端元.

对于单个人工蚂蚁,第 k 次迭代中,人工蚂蚁在第 $t-1$ 次移动后到达顶点 v_i ,那么第 t 次移动时,由 v_i 向其他各顶点的转移概率为

$$p_{ij}^k(t) = \frac{\tau_{ij}^{k\alpha} \eta_{ij}^\beta}{\sum_{j \in \text{allowed}_i} \tau_{ij}^{k\alpha} \eta_{ij}^\beta}, \quad \forall j \in \text{allowed}_i, \quad (12)$$

其中, $\tau_{ij}^{k\alpha}$ 表示第 k 次迭代过程中,有向边 $\langle v_i, v_j \rangle$ 上的信息素含量,指数 α 和 β 反映了信息素和能见度在路径选择中的相对重要程度.

对于人工蚂蚁群体,信息素是其中个体相互交流信息的唯一手段,也是蚁群算法能够完成复杂任务的根本原因.在初始状态下,各条边上的信息素含量相等,随着迭代的进行,信息素不断更新并通过式(12)影响人工蚂蚁选择顶点的概率,最终使得算法收敛到全局最优解.信息素更新公式为

$$\tau_{ij}^{k+1} = \rho \tau_{ij}^k + \Delta \tau_{ij}^k, \quad (13)$$

其中, ρ 为信息素耗散系数, $\Delta \tau_{ij}^k$ 为信息素增量.如果第 k 次迭代中的最优目标函数值为 f_k , 其对应的路径为 $p_{\text{ath},k}$, 则 $\Delta \tau_{ij}^k$ 为

$$\Delta \tau_{ij}^k = \begin{cases} Q/f_k, & v_i, v_j \in p_{\text{ath}}, \\ 0, & v_i, v_j \notin p_{\text{ath}}, \end{cases} \quad (14)$$

其中, Q 为一常数,控制信息素调整幅度,使得 $\Delta \tau_{ij}^k$ 与 τ_{ij}^k 相比不至于过大(陷入局部最优解)或过小(收敛很慢).

2.2 离散粒子群优化端元提取

基于离散粒子群算法的端元提取方法(Discrete Particle Swarm Optimization for Endmember

Extraction, DPSO-EE)是以粒子群算法为基础的^[13].粒子群算法是通过模仿自然界中鸟群的寻找食物源这种行为,以此达到寻找最优化问题的全局最优解的过程.在自然界中,鸟群在某区域内飞行并寻找食物源时,鸟群中的个体可以对自身所处的环境进行评估,以此来判断当前位置适合寻找食物源的程度.组成鸟群的每只鸟之间可以通过鸣叫等方式,在一定空间范围内可以彼此交流信息.每一只鸟会根据其他鸟传递的信息以及自身的经验来改变飞行速度和飞行方向,从而继续寻找食物源.通过这种方式,鸟群最终可以聚集在某区域食物源最丰富的地方.

若把“寻找食物源”看作是一个最优化问题,那么鸟群的搜索区域就可以等于是这个问题的可行解空间.该区域中的每一个位置便是一个可行解,每只鸟对其位置适合寻找食物源程度的评价就是最优化问题的目标函数.原始的粒子群算法将鸟群中的这些鸟抽象为具有“速度”和“位置”2种属性的粒子,因此可以进行位置更新、速度更新.在每个时刻,每只鸟会计算其所在位置的适应度,从而得到这个位置的适应度.然后,鸟群中的鸟会互相交换适应度信息,同时会回顾自身在运动过程中获得“社会经验”和“自身经验”的2种经验值.以这2种经验为根据,每只鸟会更新自身的速度,同时利用当前速度进行位置移动,然后会到达新的位置.最终,若鸟群中所有的鸟均停止在适应度值最高的位置时,则可以认为鸟群已经找到了最优化问题的全局最优解.

定义集合: $X_{n,m} = \{(x_1, x_2, \dots, x_n) \mid x_i \in \{0, 1\}, \sum_{i=1}^n x_i = m\}$, 即 $\mathbf{x} \in X_{n,m}$ 表示一个由0和1组成的 n 位数字串, 其中有 m ($\leq n$) 个位置为1, 其余为0. 若 $\{\mathbf{r}_i\}_{i=1}^n$ 中的某个像元 \mathbf{r}_i 被选为端元(进入集合 E), 则 \mathbf{x} 对应位置上的 x_i 就取1, 否则就取0. 于是对于给定的图像 $\{\mathbf{r}_i\}_{i=1}^n$ 和端元数量 m , 可用 $X_{n,m}$ 表示式(11)的可行解空间, 作为粒子的搜索空间.

第 k 个粒子在 t 时刻的位置 $\mathbf{x}_k(t) \in X_{n,m}$. 显然, 第 k 个粒子在前 t 时刻的最优位置 $\mathbf{x}_{k,best}(t) \in X_{n,m}$, 所有粒子在前 t 时刻的最优位置 $\mathbf{x}_{gbest}(t) \in X_{n,m}$. 若定义集合 $V_{n,q} = \{(v_1, v_2, \dots, v_n) \mid v_i \in \{-1, 0, 1\}, \sum_{i=1}^n v_i = 0, \sum_{i=1}^n |v_i| = 2q\}$, 那么 $\mathbf{v} \in V_{n,q}$ 表示一个由0、1、-1组成的 n 位数字串(或者说 n 维向量), 且其中1的数量和-1的数量均为 q 个. 若 $E_1, E_2 \in$

$C(\{\mathbf{r}_i\}_{i=1}^n, m)$ 对应的 $\mathbf{x}_1, \mathbf{x}_2 \in X_{n,m}$, 那么从 \mathbf{x}_2 到 \mathbf{x}_1 的速度定义为 $\mathbf{v} = \mathbf{x}_1 - \mathbf{x}_2 = (v_1, v_2, \dots, v_n) \in V_{n,q}$, 且满足:

$$v_i = \begin{cases} 1, & r_i \in E_1, r_i \notin E_2, \\ -1, & r_i \notin E_1, r_i \in E_2, \\ 0, & \text{other.} \end{cases} \quad (15)$$

事实上, \mathbf{v} 反映了 E_1 与 E_2 的不同, 而 q 反映了这种“不同”的程度, 因此 q 称为“速度的大小”.

根据位置和速度的定义, 显然 $\mathbf{x}_{k,best}(t) - \mathbf{x}_k(t) \in V_{n,q_1}, \mathbf{x}_{gbest}(t) - \mathbf{x}_k(t) \in V_{n,q_2}$. 在 $X_{n,m}$ 中, 速度更新方程为

$$\mathbf{v}_k(t+1) = \begin{cases} T((\mathbf{x}_{k,best}(t) - \mathbf{x}_k(t)) + \\ (\mathbf{x}_{gbest}(t) - \mathbf{x}_k(t))), \\ R(\mathbf{x}_k(t)), \end{cases} \quad (16)$$

其中, T 和 R 均表示随机选择函数. $T(\mathbf{x})$ 表示从 \mathbf{x} 的正分量对应的位置中随机选择一个赋值为1, 负分量对应的位置中随机选择一个赋值为-1, 其余位置赋值为0, $\mathbf{x}_k(t) \in X_{n,m}$; $R(\mathbf{x})$ 表示从 \mathbf{x} 的正分量对应的位置中随机选择一个赋值为-1, 负分量对应的位置中随机选择一个赋值为1, 其余位置赋值为0. $T(\mathbf{x})$ 表示根据自我经验和社会经验得到的速度, 称为“定向移动”; $R(\mathbf{x})$ 表示放弃经验, 随机选择一个速度, 称为“随机移动”. 每次迭代时, 粒子会随机选择进行定向移动或随机移动, 即预制一个随机选择概率 $p \in (0, 1)$, 粒子以 p 的概率选择定向移动, 以 $1-p$ 的概率选择随机移动. 另外, 如果粒子所在位置恰好是全局历史最优位置, 那么 $(\mathbf{x}_{k,best}(t) - \mathbf{x}_k(t)) + (\mathbf{x}_{gbest}(t) - \mathbf{x}_k(t)) = 0$, 无法进行定向移动, 只能进行随机移动. 位置更新方程为

$$\mathbf{x}_k(t+1) = \mathbf{x}_k(t) + \mathbf{v}_k(t+1). \quad (17)$$

2.3 蜂群优化端元提取

人工蜂群算法通过模拟自然界中蜂群的觅食行为实现最优化问题的求解^[16]. 对于待求解最优化问题, 可行解空间对应蜂群的搜索空间, 一个可行解称为一个食物源(food source). 食物源中包含花蜜的数量称为适应度(fitness), 与该食物源对应的可行解所产生的目标函数值有关, 较好的可行解会产生较高的适应度, 也就会吸引更多的蜜蜂来此食物源采蜜. 全部蜜蜂被分为3类: 采蜜蜂(employed bee)、跟随蜂(onlooker bee)和侦察蜂(scout bee). 3类蜜蜂分别按照各自的策略进行搜索、判断和类型转换.

每个采蜜蜂对应一个食物源(及其适应度). 采蜜蜂可以在该食物源的邻域内进行局部搜索并发现

新的食物源,若新的食物源的适应度优于原食物源,则将其对应关系更新为新的食物源(及其适应度),否则放弃新食物源并继续在原食物源的邻域内搜索.若 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{i, m \times L})^T \in \mathbf{R}_+^{M \times (M-1)}$ 表示第 i 个食物源,也就是第 i 个采蜜蜂的位置,则邻域局部搜索可表示为

$$x'_{ij} = x_{ij} + \varphi(x_{ij} - x_{kj}), \quad (18)$$

其中, k 是随机选择的不同于 i 的另一个食物源, j 是从 $\{1, 2, \dots, M \times (M-1)\}$ 中随机选择的一个整数.

每个跟随蜂会根据采蜜蜂获得的所有食物源的适应度,按照一定概率挑选一个食物源(等同于采蜜蜂)并在该食物源的邻域内进行局部搜索,如果发现的新食物源的适应度优于原食物源,则将采蜜蜂(而不是跟随蜂)对应的食物源更新为新的食物源,否则放弃新食物源.跟随蜂挑选第 j 个食物源的“跟随概率”

$$p_j = \frac{f_j}{\sum_{i=1}^{N_e} f_i}, \quad (19)$$

其中, f_i 表示第 i 个食物源的适应度, N_e 表示食物源的总数量,也就是采蜜蜂的总数量.若最优化问题的目标函数非负,则食物源 \mathbf{x}_i 的适应度

$$f_i = \frac{1}{f(\mathbf{x}_i)}, \quad (20)$$

其中, $f(\mathbf{x})$ 为最优化问题的目标函数.综合考虑式(6)和式(11)2个最优化模型,基于ABC的端元提取问题可描述为如下最优化模型:

$$\begin{aligned} \min \quad & f(\mathbf{E}) = V(\{\tilde{\mathbf{e}}_j\}_{j=1}^M) + \\ & \mu_R E_{\text{RMS}}(\{\tilde{\mathbf{r}}_i\}_{i=1}^N, \{\tilde{\mathbf{e}}_j\}_{j=1}^M), \\ \text{s.t.} \quad & \mathbf{E} \in \mathbf{R}_+^{M \times (M-1)}, \forall j, \end{aligned} \quad (21)$$

其中, μ_R 为惩罚系数,用来调节 $E_{\text{RMS}}(\{\tilde{\mathbf{r}}_i\}_{i=1}^N, \{\tilde{\mathbf{e}}_j\}_{j=1}^M)$ 对整体目标函数的影响.

2.4 离散蜂群优化端元提取

改进的离散蜂群优化端元提取算法与2.3节人工蜂群优化端元提取的原理相同,也是利用采蜜蜂、跟随蜂和侦查蜂搜索、评价、交流和分身转化的策略实现最优化问题的求解.但人工蜂群优化算法是在连续空间中搜索可行解,而离散蜂群优化算法是在离散空间中搜索,因此其可行解空间与2.2节中DPSO的可行解空间一致,可行解的邻域搜索策略也与DPSO的速度、位置更新原理一致.

IDABC的改进体现在端元提取的目标函数^[17]. ACOEE和DPSOEE提取端元时,会出现同一种端元

被重复识别的现象,这是因为提取相同或相近的端元能够有效减小反演误差,与目标函数(11)的含义一致.为了避免端元被重复识别的问题, IDABC法在目标函数(11)中加入距离项 $g(\mathbf{d})$, 其中 \mathbf{d} 为图像中端元与端元之间的欧氏距离,即:

$$f(\{\mathbf{e}_j\}_{j=1}^m) = E_{\text{RMS}}(\{\mathbf{r}_i\}_{i=1}^N, \{\mathbf{e}_j\}_{j=1}^m) + u \times g(\mathbf{d}), \quad (22)$$

$$g(\mathbf{d}) = \frac{1}{\mathbf{d}}, \quad (23)$$

$$\mathbf{d} = \min \| \mathbf{e}_i - \mathbf{e}_j \|_2, \quad \forall i \neq j, \quad (24)$$

u 表示惩罚系数,对 E_{RMS} 和 g 调节平衡. $g(\mathbf{d})$ 是 \mathbf{d} 的递减函数, \mathbf{d} 值越大则 $g(\mathbf{d})$ 越小.利用ABC算法对目标函数(22)进行最优化,获得的最优解既符合ABC算法找到最优解的目的,又能避免相邻纯净像元被同时识别.

如果将ACO和DPSO的目标函数更改为(22),并利用各自的优化策略进行搜索,则可得到IACO和IDPSO.

3 丰度反演的群智能算法

基于LSMM的光谱解混,在提取端元后,可以利用最小二乘法求解线性方程组进行丰度反演;而基于NLSMM的光谱解混因为对应的是非线性方程组,无法通过最小二乘法求解,只能将丰度反演转化为最优化问题.群智能算法在求解最优化问题方面具有独特的优势,因此也被应用于非线性光谱解混.

根据FM模型(7)和(8),混合像元分解的优化问题为

$$\begin{aligned} \min \quad & V(\mathbf{E}), \\ \text{s.t.} \quad & \sum_{i=1}^N \| \mathbf{r}_i - \mathbf{E}\boldsymbol{\alpha}_i - nl(\mathbf{E}, \boldsymbol{\alpha}_i) \|_2^2 \leq \varepsilon, \end{aligned} \quad (25)$$

其中

$$nl(\mathbf{E}, \boldsymbol{\alpha}_i) = \sum_{i=1}^{m-1} \sum_{j=i+1}^m \beta_{i,j} \mathbf{e}_i \odot \mathbf{e}_j, \quad (26)$$

$V(\mathbf{E})$ 表示端元单形体的体积.体积的引入用于保证解的唯一性.

设第 i 个粒子的当前位置为 \mathbf{X}_i , 速度为 \mathbf{v}_i , 个体历史最优位置为 \mathbf{p}_i , 全局历史最优位置为 \mathbf{g} , 粒子个数为 s . 那么其在第 j 步中的速度为

$$\begin{aligned} \mathbf{v}_i^{(j+1)} = & w\mathbf{v}_i^{(j)} + c_1 r_1^{(j)} (\mathbf{p}_i^{(j)} - \mathbf{x}_i^{(j)}) + \\ & c_2 r_2^{(j)} (\mathbf{g}^{(j)} - \mathbf{x}_i^{(j)}), \end{aligned} \quad (27)$$

其中, w 为惯性系数, c_1, c_2 称为加速因子, $r_1, r_2 \sim U(0, 1)$ 为随机数.

其在第 j 步后的位置为

$$\mathbf{x}_i^{(j+1)} = \mathbf{x}_i^{(j)} + \mathbf{v}_i^{(j+1)}, \quad (28)$$

第 j 步后,第 i 个粒子的个体历史最优位置为

$$p_i^{(j+1)} \begin{cases} p_i^{(j)}, & f(\mathbf{x}_i^{(j+1)}) \geq f(p_i^{(j)}), \\ \mathbf{x}_i^{(j+1)}, & f(\mathbf{x}_i^{(j+1)}) < f(p_i^{(j)}), \end{cases} \quad (29)$$

第 j 步后,全局历史最优位置为

$$\mathbf{g}^{(j+1)} = \operatorname{argmin}_{p_i^{(j+1)}} \{f(p_i^{(j+1)}), \text{for all } i \in 1, \dots, s\}. \quad (30)$$

PSO 算法不断更新全局历史最优位置,直到满足算法终止条件.此时,全局历史最优位置即为最终解.

双种群粒子群优化(BiPSO)^[18]考虑问题(25),需要同时估计 \mathbf{E} 和 \mathbf{A} , $\mathbf{A} = \{\alpha_i\}_{i=1}^N$,因此需要在算法框架中定义 2 个种群来分别估计 \mathbf{E} 和 \mathbf{A} ,记 SE 种群用于估计 \mathbf{E} ,SA 种群估计 \mathbf{A} .在第 t 次迭代中,首先固定 SA 种群,把 SA 种群的当前最优解代入(25)作为常量,然后更新 SE 种群中的粒子速度和位置,从而获得历史最优位置以及当前最优粒子;然后固定 SE 种群,把当前最优粒子代入式(25)作为常量,用类似的方法来更新 SA 种群的粒子;2 个种群相互交换各自的最优解,如此交替迭代,最后同时得到最终解.

在 SE 种群中,为了处理约束问题,引入了多目标优化机制,定义如下目标函数:

$$f_1(\mathbf{X}) = \sum_{n=1}^N \|\mathbf{y}[n] - \mathbf{X}\mathbf{a}[n] - nl(\mathbf{X}, \mathbf{a}[n])\|_2^2, \quad (31)$$

$$f_2(\mathbf{X}) = V(\mathbf{X}), \quad (32)$$

则称粒子 \mathbf{X}_i Pareto 支配 \mathbf{X}_j , 当且仅当

$$\begin{aligned} \forall k \in \{1, 2\}, & f_k(\mathbf{X}_i^{(j+1)}) \leq f_k(\mathbf{X}_j^{(j+1)}), \\ \exists k \in \{1, 2\}, & f_k(\mathbf{X}_i^{(j+1)}) < f_k(\mathbf{X}_j^{(j+1)}), \end{aligned} \quad (33)$$

记

$$p_d(\mathbf{X}_i) = c_{\text{ard}} \{ \mathbf{X}_j \mid \forall \mathbf{X}_j \in SE \text{ and } \mathbf{X}_i \text{ Pareto dominates } \mathbf{X}_j \}, \quad (34)$$

其中 $c_{\text{ard}} \{ \cdot \}$ 为集合的势.最终可定义指标函数

$$u(\mathbf{X}_i) = \begin{cases} o_{\text{rder}}(\mathbf{X}_i, p_d, S, 'D'), & \mathbf{X}_i \in S, \\ n_s + o_{\text{rder}}(\mathbf{X}_i, p_d, \bar{S}, 'D'), & \mathbf{X}_i \in \bar{S}, \end{cases} \quad (35)$$

其中, S 为可行粒子集合, \bar{S} 为不可行粒子集合, n_s 为 S 的势, $o_{\text{rder}}(\mathbf{X}_i, p_d, S, 'D')$ 表示 \mathbf{X}_i 根据 p_d 值在集合中的降序序号.该函数表示了 2 个准则:具有更高的 p_d 值的粒子排在低 p_d 值的粒子前面;可行粒子排在不可行粒子的前面.

4 实验与分析

按照群智能算法在混合像元分解不同阶段中的应用,实验分为端元提取实验和丰度反演实验,利用不同的数据对比群智能算法和其他基于相同假设的

算法之间的精度.

4.1 端元提取实验

端元提取实验使用的真实高光谱数据为 1994 年 Airborne Visible Infrared Imaging Spectrometer (AVIRIS) 遥感器在美国内达华州 Cuprite 地区采集的数据,如图 3 所示.图像共 50 个波段,波长范围为 $1.99 \sim 2.48 \mu\text{m}$,空间大小为 400×350 ,假彩色合成波段为 R: $2.10 \mu\text{m}$, G: $2.20 \mu\text{m}$, B: $2.34 \mu\text{m}$. Cuprite 数据在高光谱混合像元分解实验验证中被广泛应用,主要包括明矾石、高岭石、方解石等多种矿物^[39].



图 3 AVIRIS 传感器 Cuprite 地区高光谱图像假彩色合成
Fig. 3 False color composition of AVIRIS hyperspectral image at Cuprite, Nevada

端元提取结果的可信程度评价方法是比较提取的端元光谱与实验室光谱库中的光谱(或其他一些已知地物的光谱)的相似程度.光谱角距离(Spectral Angle Divergence, SAD) 是进行相似性度量的常用指标.若所得到的光谱角距离越小,说明提取的结果越接近真实图像.性能优越的端元提取方法,在提取端元的同时,也能最大限度地保存图像的原始信息.通过计算 RMSE 值可以来检验混合像元分解产生的信息量损失,均方根误差越小,则说明信息量损失越少.

4.1.1 纯像元假设的端元提取算法实验

基于纯像元假设的群智能端元提取算法主要包括 ACOEE、DPSOEE、IACOEE、IDPSOEE 和 IDABC,另外,加入经典的 N-FINDR 和 VCA 作为对比,评价群智能端元提取算法的精度.为减少计算时间,先用 PPI 算法从图像中提取 80 个像元作为候选端元集,所有算法均从候选端元集中提取端元.

端元提取结果如表 1 所示.可以看出,当端元数目确定时, N-FINDR、VCA 和 DPSOEE 可识别出 6 种端元, ACOEE 和 IACOEE 可识别出 5 种端元, IDPSO

可识别出 7 种端元, IDABC 可识别出 8 种端元, IACOOE、IDPSO 比原先的 ACOEE 和 DPSOEE 识别出的端元种类要多, 提取的精度也更高. 另外, IACOOE、IDPSO 和 IDABC 的提取端元的精度明显高于 N-FINDR 和 VCA; IDABC 的 RMSE 结果最好, 且提取出的矿物 Desert varnish、Alunite 和 Chalcodony 与标准光谱库中提供的光谱之间的 SAD 值最优.

4.1.2 非纯像元假设的端元提取算法实验

ABCEE 是不基于纯像元假设的端元提取算法, 可以在连续空间中搜索最优端元. 与 ABCEE 目标函数相似的算法包括 MVC-NMF、MVSA、MVES 和 SISAL 等, 实验结果如表 2 所示. 可以看出, MVC-NMF 提取的端元 SAD 结果最好, 即最接近真实地物光谱, 但是 RMSE 结果最差. ABCEE 提取的端元 RMSE 结果最好, 而对于 Alunite、Calcite 和 Muscovite 其 SAD 结果仅次于 MVC-NMF; SISAL 的结果与 ABCEE 近似. 二者都很好地平衡了光谱真实性与反演误差之间的关系, 与目标函数的意义一致.

4.2 丰度反演实验

丰度反演实验使用的是 2 幅高光谱影像. 一幅为 1997 年由 AVIRIS 在 Moffett Field (美国洛杉矶) 地区所获取的高光谱图像, 选取了其中 50×50 像元的子图像进行评价, 去除了 1~7、108~113、152~169

和 221~224 水汽吸收以及低信噪比波段后, 剩余 189 个波段, 端元数量设置为 3. 另一幅影像为 AVIRIS 在 1992 年 Indian Pines 地区获得高光谱影像, 该影像有真实验证样本, 选取了 Stone-Steel-Towers、Soybean-notill、Soybean-clean 以及 Vegetation 4 类地物进行评价, 端元数量设置为 4.

参与对比的算法包括基于 GBM 模型的梯度下降算法(记为 GBA)^[40]、基于 FAN 模型的非负矩阵分解算法(记为 Fan-NMF)^[41]、约束非线性最小二乘算法(记为 CNLS)^[42]以及基于核混合模型的解混算法(记为 SK-Hype)^[43]. 所有的算法均以 VCA 算法^[22]所提取的端元结果作为初始状态, GBA 和 CNLS 为监督算法, 因此以 VCA 结果为端元集合, 并以全约束丰度反演算法^[44]的丰度反演结果作为丰度估计的初始状态. 设置算法最大迭代次数为 500, 收敛阈值为 10^{-6} , 算法运行 10 遍取均值作为结果进行评价(表 3).

图 4 是 Moffett Field 丰度反演结果, 除 SK-Hype 结果异常外, 其他算法均能较好地反演水、植被和土壤等 3 种地物的丰度; 图 5 是 Indian Pines 子图像的丰度反演结果, 可以看出 4 种算法清楚地显示了第 1 类的大部分区域, 但 SK-Hype 包含了其他类别的信息; 对于第 2 类地物, 所有算法均与真实地物存在较大差异, 这主要是因为其左边区域的地物光谱与该

表 1 纯像元假设的端元提取算法实验结果

Table 1 Results of endmember extraction algorithms with pure pixel assumption

端元提取	Desert varnish	Alunite	Budding tonite	Goethite	Kaolinite	Jarsite GD99	Halloy site	Chalcodony	RMSE
N-FINDR		0.145 8	0.125 4	0.203 8	0.095 1	0.126 1		0.131 1	5.721 5
VCA	0.035 6	0.145 4		0.137 6		0.126 5	0.057 2		3.855 9
ACOEE	0.044 8	0.108 7		0.205 5	0.114 5			0.057 19	3.824 5
DPSOEE	0.045 3	0.110 4		0.097 9	0.114 5	0.100 2	0.070 4		3.741 5
IACOOE	0.032 9	0.108 7		0.175 5	0.084 5			0.070 3	3.774 7
IDPSO	0.030 1	0.090 4	0.057 4	0.117 8	0.093 7	0.114 2	0.109 9		3.552 6
IDABC	0.027 5	0.083 7	0.064 0	0.114 6	0.118 6	0.114 2	0.098 7	0.055 6	3.522 7

表 2 非纯像元假设的端元提取算法实验结果

Table 2 Results of endmember extraction algorithms without pure pixel assumption

端元提取	Alunite GDS84	Calcite WS272	Kaolinite KGa-1	Muscovite GDS107	Mean	RMSE
MVC-NMF	6.450	6.104	5.295	4.755	5.651	2.951
MVSA	10.937	6.887	7.709	8.518	8.513	2.592
SISAL	11.403	4.844	7.662	8.377	8.071	2.591
MVES	12.260	7.346	7.539	7.832	8.744	2.594
ABCEE	10.904	7.641	6.991	7.673	8.302	2.586

类别地物的光谱极为相似;第3类样本,所有算法在中间区域与第2类样本混淆,原因见第2类样本的分析,除此之外,其他区域 BiPSO 算法的结果比其他算法更为清晰;最后一类各算法均能准确提取.表3为重构误差,从结果可以看出,丰度结果各算法差异不大,而 BiPSO 的重构误差小于其他算法.

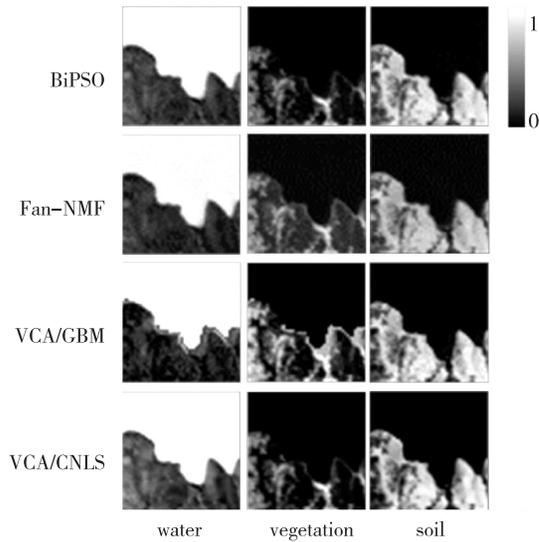


图4 Moffett Field 丰度反演结果

Fig. 4 Abundance inversion results of Moffett Field

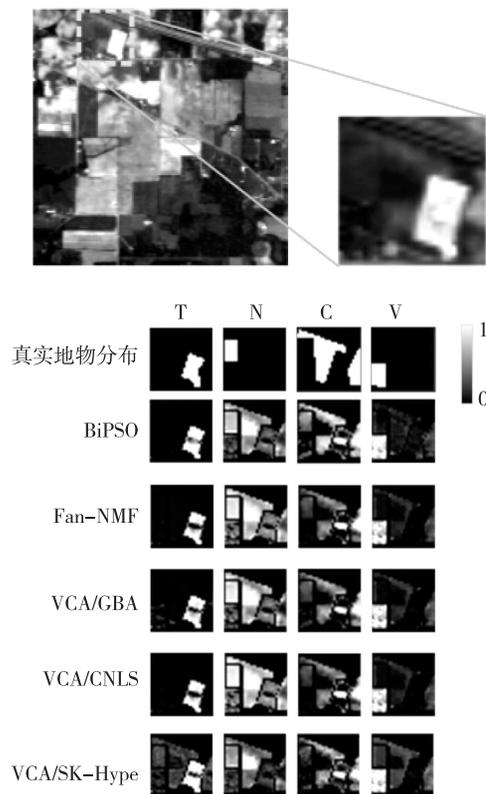


图5 Indian Pines 子图像及丰度反演结果

Fig. 5 Subimage and abundance inversion results of Indian Pines

表3 非线性丰度反演 RMSE

Table 3 RMSE of nonlinear abundance inversion

图像	BiPSO	Fan-NMF	GBM	CNLS	SK-Hype
Moffett Field	0.006 3	0.013 0	0.150 2	0.073 0	10.002 *
Indian Pine	0.011 5	0.013 1	0.038 6	0.024 7	0.071 8 *

注:SK-Hype 的 RMSE 由 FAN 模型进行估计.

5 存在问题与发展方向

群智能算法在求解一些比较困难的最优化问题方面体现出独特的优势,在高光谱图像混合像元分解方面的应用也取得了一些值得关注的成果,但是群智能算法在具体问题的应用中仍存在一些不可忽略的困难.阻碍群智能算法广泛应用的一个显而易见的问题就是搜索空间、种群规模与计算效率之间的矛盾:如果希望搜索到尽可能好的解,则应使用较大的搜索空间和种群规模,但这同时意味着更长的搜索时间和更多的无效搜索.

应用新型的计算技术是解决这一问题的重要方向.例如目前已经在科学计算领域广泛使用的大型计算机集群并行计算技术、基于互联网的云计算技术和多智能体技术等,另外,GPU、FPGA 和非精确计算芯片等硬件的快速发展也为群智能算法的改进、扩展和应用提供了更多的选择.

参考文献

References

- [1] 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,2006
TONG Qingxi, ZHANG Bing, ZHENG Lanfen. Hyperspectral remote sensing: Principle, technology, and applications[M]. Beijing: Higher Education Press, 2006
- [2] 张兵,孙旭.高光谱图像混合像元分解[M].北京:科学出版社,2015
ZHANG Bing, SUN Xu. Hyperspectral image unmixing[M]. Beijing: Science Press, 2015
- [3] Shaw G A, Burke H K. Spectral imaging for remote sensing[J]. Lincoln Laboratory Journal, 2003, 14(1): 3-28
- [4] 张兵.高光谱图像处理与信息提取前沿[J].遥感学报,2016,20(5):1062-1090
ZHANG Bing. Advancements of hyperspectral image processing and information extraction[J]. Journal of Remote Sensing, 2016, 20(5): 1062-1090
- [5] Bioucas-Dias J M, Plaza A, Dobigeon N, et al. Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(2): 354-379

- [6] Dobigeon N, Tourneret J Y, Richard C, et al. Nonlinear unmixing of hyperspectral images: Models and algorithms [J]. *IEEE Signal Processing Magazine*, 2014, 31 (1) : 82-94
- [7] Raksuntorn N, Du Q A. Nonlinear spectral mixture analysis for hyperspectral imagery in an unknown environment[J]. *IEEE Geoscience and Remote Sensing Letters*, 2010, 7(4) : 836-840
- [8] Fan W Y, Hu B X, Miller J, et al. Comparative study between a new nonlinear model and common linear model for analysing laboratory simulated-forest hyperspectral data[J]. *International Journal of Remote Sensing*, 2009, 30(11) : 2951-2962
- [9] Halimi A, Altmann Y, Dobigeon N, et al. Nonlinear unmixing of hyperspectral images using a generalized bilinear model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11) : 4153-4162
- [10] Echès O, Dobigeon N, Tourneret J Y. Estimating the number of endmembers in hyperspectral images using the normal compositional model and a hierarchical Bayesian algorithm[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2010, 4(3) : 582-591
- [11] Blum C, Merkle D. *Swarm intelligence introduction and applications* [M]. Berlin: Springer, 2008: 43-85
- [12] Zhang B, Sun X, Gao L R, et al. Endmember extraction of hyperspectral remote sensing images based on the Ant Colony Optimization (ACO) algorithm [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(7) : 2635-2646
- [13] Zhang B, Sun X, Gao L R, et al. Endmember extraction of hyperspectral remote sensing images based on the discrete particle swarm optimization algorithm [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11) : 4173-4176
- [14] Zhang B, Gao J W, Gao L R, et al. Improvements in the ant colony optimization algorithm for endmember extraction from hyperspectral images [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(2) : 522-530
- [15] Gao L R, Zhuang L N, Wu Y F, et al. A quantitative and comparative analysis of different preprocessing implementations of DPSO: A robust endmember extraction algorithm [J]. *Soft Computing*, 2014, 20(12) : 1-15
- [16] Sun X, Yang L N, Zhang B, et al. An endmember extraction method based on artificial bee colony algorithms for hyperspectral remote sensing images [J]. *Remote Sensing*, 2015, 7(12) : 16363-16383
- [17] Su Y C, Sun X, Gao L R, et al. Improved discrete swarm intelligence algorithms for endmember extraction from hyperspectral remote sensing images [J]. *Journal of Applied Remote Sensing*, 2016, 10(4) : 45018
- [18] Luo W F, Gao L R, Plaza A, et al. A new algorithm for bilinear spectral unmixing of hyperspectral images using particle swarm optimization [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(12) : 5776-5790
- [19] Keshava N, Mustard J F. Spectral unmixing [J]. *IEEE Signal Processing Magazine*, 2002, 19(1) : 44-57
- [20] 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*, 1995: 3-6
- [21] Winter M E. N-FINDR: An algorithm for fast autonomous spectral end-member determination in hyperspectral data [J]. *Proceedings of SPIE*, 1999, 3753: 266-275
- [22] Nascimento J M P, Dias J M B. Vertex component analysis: A fast algorithm to unmix hyperspectral data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(4) : 898-910
- [23] Chang C I, Wu C C, Liu W, et al. A new growing method for simplex-based endmember extraction algorithm [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(10) : 2804-2819
- [24] Gruninger J H, Ratkowski A J, Hoke M L. The sequential maximum angle convex cone (SMACC) endmember model [J]. *Proceedings of SPIE*, 2004, 5425: 1-14
- [25] Chan T H, Ma W K, Ambikapathi A M, et al. A simplex volume maximization framework for hyperspectral endmember extraction [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11) : 4177-4193
- [26] Li J, Bioucas-Dias J M. Minimum volume simplex analysis: A fast algorithm to unmix hyperspectral data [C] // *IEEE International Geoscience and Remote Sensing Symposium*, 2008, 3: III-250-III-253
- [27] 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 Transactions on Signal Processing*, 2009, 57(11) : 4418-4432
- [28] Ambikapathi A M, Chan T H, Ma W K, et al. Chance-constrained robust minimum-volume enclosing simplex algorithm for hyperspectral unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11) : 4194-4209
- [29] Miao L D, Qi H R. Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(3) : 765-777
- [30] 罗文斐, 钟亮, 张兵, 等. 高光谱遥感图像光谱解混的独立成分分析技术 [J]. *光谱学与光谱分析*, 2010, 30(6) : 1628-1633
- LUO Wenfei, ZHONG Liang, ZHANG Bing, et al. Independent component analysis for spectral unmixing in hyperspectral remote sensing image [J]. *Spectroscopy and Spectral Analysis*, 2010, 30(6) : 1628-1633
- [31] Nascimento J M P, Bioucas-Dias J M. Hyperspectral unmixing based on mixtures of dirichlet components [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3) : 863-878
- [32] Moussaoui S, Carteret C, Brie D, et al. Bayesian analysis of spectral mixture data using Markov chain Monte Carlo methods [J]. *Chemometrics and Intelligent Laboratory Systems*, 2006, 81(2) : 137-148
- [33] 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
- [34] Bioucas-Dias J M, Figueiredo M A T. Alternating direction algorithms for constrained sparse regression: Application to hyperspectral unmixing[C]//IEEE Workshop on Hyperspectral Image & Signal Processing: Evolution in Remote Sensing, 2012;1-4
- [35] Iordache M, Bioucas-Dias J E M, Plaza A. Total variation spatial regularization for sparse hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(11):4484-4502
- [36] Qian Y T, Jia S, Zhou J, et al. Hyperspectral unmixing via L1/2 sparsity-constrained nonnegative matrix factorization [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(11):4282-4297
- [37] Singer R B, McCord T B. Mars-large scale mixing of bright and dark surface materials and implications for analysis of spectral reflectance[C]//Lunar & Planetary Science Conference, 1979;1835-1848
- [38] Zhang L, Li D, Tong Q, et al. Study of the spectral mixture model of soil and vegetation in Poyang Lake area, China [J]. International Journal of Remote Sensing, 1998, 19(11):2077-2084
- [39] Swayze G, Clark R N, Kruse F, et al. Ground-truthing AVIRIS mineral mapping at Cuprite, Nevada[C]//Summaries of the Third Annual JPL Airborne Geoscience Workshop, 1992:47-49
- [40] Halimi A, Altmann Y, Dobigeon N, et al. Nonlinear unmixing of hyperspectral images using a generalized bilinear model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(11):4153-4162
- [41] Eches O, Guillaume M. A bilinear-bilinear nonnegative matrix factorization method for hyperspectral unmixing [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(4):778-782
- [42] Pu H Y, Chen Z, Wang B, et al. Constrained least squares algorithms for nonlinear unmixing of hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3):1287-1303
- [43] Chen J, Richard C, Honeine P. Nonlinear unmixing of hyperspectral data based on a linear-mixture/nonlinear-fluctuation model[J]. IEEE Transactions on Signal Processing, 2013, 61(2):480-492
- [44] Heinz D C, Chang C I. Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(3):529-545

Swarm intelligence algorithms for spectral unmixing in hyperspectral image

GAO Lianru¹ SUN Xu¹ LUO Wenfei² TANG Maofeng¹ ZHANG Bing^{1,3}

1 Institute of Remote sensing and Digital Earth, Chinese Academy of Sciences, Beijing 100094

2 School of Geographical Sciences, South China Normal University, Guangzhou 510631

3 University of Chinese Academy of Sciences, Beijing 100049

Abstract In recent years, swarm intelligence algorithms have made important progress and remarkable achievements in spectral unmixing of hyperspectral image by solving combinatorial optimization or continuous optimization problems. In this paper, the background of the research of spectral unmixing in hyperspectral image and the characteristics of swarm intelligence algorithm were reviewed firstly, and then the optimization model and the spectral mixture model were teased out correspondingly. Then the endmember extraction and abundance inversion method based on swarm intelligent algorithms were introduced. Finally the accuracy of spectral unmixing achieved by swarm intelligence algorithms and other traditional algorithms was evaluated through two experiments. In addition, the advantages and problems of swarm intelligence algorithm in hyperspectral image information extraction were also summarized in this paper.

Key words hyperspectral image; spectral unmixing; swarm intelligence; endmember extraction; abundance inversion