

基于微分搜索的高光谱图像非线性解混算法

陈 雷^{1,2,3}, 郭艳菊⁴, 葛宝臻^{1,3}

(1. 天津大学精密仪器与光电子工程学院, 天津 300072; 2. 天津商业大学信息工程学院, 天津 300134;
3. 光电信息技术教育部重点实验室, 天津 300072; 4. 河北工业大学电子信息工程学院, 天津 300401)

摘 要: 针对线性混合模型在实际高光谱图像解混过程中的局限性, 提出一种新的基于微分搜索的非线性高光谱图像解混算法. 在广义双线性模型的基础上采用重构误差作为解混的目标函数, 将非线性解混问题转化为最优化问题. 将目标函数中的待求参数映射为微分搜索过程中的位置变量, 利用微分搜索算法对目标函数进行优化求解. 在求解过程中, 通过执行搜索范围控制等机制满足高光谱图像解混的约束要求, 进而求得丰度系数和非线性参数, 实现非线性高光谱图像解混. 仿真数据和真实遥感数据实验结果表明, 所提出的非线性解混算法可以有效克服线性模型下解混算法的局限性, 避免了由于使用梯度类优化方法而易陷入局部收敛的问题, 较之其它高光谱图像解混算法具有更好的解混精度.

关键词: 高光谱图像; 谱解混; 非线性模型; 群智能优化; 微分搜索算法

中图分类号: TP751

文献标识码: A

文章编号: 0372-2112 (2017)02-0337-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2017.02.011

Nonlinear Unmixing of Hyperspectral Images Based on Differential Search Algorithm

CHEN Lei^{1,2,3}, GUO Yan-ju⁴, GE Bao-zhen^{1,3}

(1. School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China;
2. School of Information Engineering, Tianjin University of Commerce, Tianjin 300134, China;
3. Key Laboratory of Opto-Electronic Information Technology, Ministry of Education, Tianjin 300072, China;
4. School of Electronic and Information Engineering, Hebei University of Technology, Tianjin 300401, China)

Abstract: A novel nonlinear hyperspectral image unmixing algorithm based on differential search is proposed for solving the limitations of linear mixing model. The reconstruction error is used as the objective function for unmixing based on generalized bilinear model and the nonlinear unmixing is transformed into the optimization problem. The parameters in objective function are mapped onto the location variables of the search process and the differential search algorithm is used to optimize the objective function. In the optimization process, the constraint conditions for hyperspectral image unmixing are fulfilled by implementing the search range controlling strategy. And then, the abundance and the nonlinear parameters for unmixing can be obtained. Experiments on synthetic data and real data validate that the proposed nonlinear unmixing algorithm can effectively overcome the limitations of linear unmixing algorithm, as well as the local convergence of gradient optimization method, and the performance of the proposed algorithm is better than other state-of-the-art hyperspectral image unmixing algorithms.

Key words: hyperspectral images; spectral unmixing; nonlinear model; swarm intelligence optimization; differential search algorithm

1 引言

高光谱图像解混是高光谱图像分析处理中的一项重要工作, 其目的是为了解决高光谱图像拍摄过程中

空间分辨率不足的问题, 已被广泛应用于遥感学、材料学和显微光谱学等多学科领域^[1]. 目前, 大部分解混算法认为混合像是端元光谱成分的线性混合^[2~4]. 然而, 当高光谱图像场景中存在泥土、植被和水等地物时,

收稿日期: 2015-10-13; 修回日期: 2016-05-26; 责任编辑: 蓝红杰

基金项目: 国家自然科学基金 (No. 61401307); 中国博士后科学基金 (No. 2014M561184); 天津市应用基础与前沿技术研究计划项目 (No. 15JCYBJC17100)

光线会在不同地物之间发生反射和相互作用,基于线性混合模型(Linear Mixing Model, LMM)的解混算法效果往往并不理想. 应该尝试在非线性混合模型(Nonlinear Mixing Model, NLMM)下研究解混算法.

目前,已有非线性混合模型主要基于辐射传输(Radiative Transfer, RT)理论^[5]. 该理论下的模型能够精确表述多种材料产生的光线散射现象,但针对该模型的解混算法复杂度很高,限制了高光谱图像解混技术的实际应用. 进一步,有学者提出 RT 模型的近似模型(如 Hapke 模型^[6]),但该类模型中仍然存在高度的非线性和复杂的积分计算.

为了避免高复杂度的数学计算,一些学者在保证实际物理意义的基础上提出了简化而有效的非线性混合模型,其中包括双线性模型(Bilinear Model, BM)^[7]、Fan 模型(Fan Model, FM)^[8]和广义双线性模型(Generalized Bilinear Model, GBM)^[9,10]等. 其中,新近提出的 GBM 是一个广义模型,它涵盖了 LMM、BM 和 FM. 因此,GBM 针对未知混合类型的实际场景解混具有更广泛的适应性和更佳的性能. 在该模型下进行解混,主要进行两部分工作:第一是端元提取,第二是丰度估计. 此时,线性混合模型下基于几何理论的端元提取方法仍然适用^[7](如 Vertex Component Analysis, VCA^[11]),解混的关键在于如何进行有效的丰度估计. 目前,针对该类模型的丰度估计方法主要有 Bayesian 估计和梯度法. 然而,Bayesian 估计方法存在参数复杂,计算量大等缺点^[12]. 而基于梯度法的解混方法存在易陷入局部收敛、解混精度低等问题^[13].

为了更好的实现高光谱图像解混,近几年已有学者开始尝试采用性能更加优异的全局优化方法—群智能优化(Swarm Intelligence Optimization, SIO)方法解决该问题,并取得了优于传统方法的性能^[14,15]. 但这些方法目前主要还是解决高光谱图像的线性解混问题,进一步应当将群智能优化方法引入非线性解混领域,从而获得更好的解混效果.

因此,为了更有效的解决高光谱图像的非线性解混问题、提高解混精度,本文提出一种新的基于微分搜索的高光谱图像非线性解混算法. 首先,针对非线性混合模型设计解混的目标函数. 进而利用微分搜索算法对目标函数进行优化求解,并利用搜索范围控制策略满足高光谱图像解混的约束条件. 与已有其它解混算法相比,本文算法充分利用了群智能优化算法优异的全局优化能力,提升了解混精度.

2 高光谱图像非线性混合模型

2.1 线性混合模型

线性混合模型假设光谱在进入传感器之前没有发生交互影响,每个入射到高光谱成像仪传感器的光

子是一种地物成分的体现. 此时,得到具有个波段,像素数为 $I \times J$ 的高光谱图像为一个图像立方体,每个像素点的观测值 $\mathbf{y} = [y_1, y_2, \dots, y_L]^T$ 可以表示为

$$\mathbf{y} = \sum_{k=1}^R a_k \mathbf{m}_k + \mathbf{n} = \mathbf{M}\mathbf{a} + \mathbf{n} \quad (1)$$

式中, R 为端元数目; $\mathbf{M}$ 为 $L \times R$ 维的端元光谱矩阵,其每一列 $\mathbf{m}_k = [m_{1,k}, m_{2,k}, \dots, m_{L,k}]^T$ ($k = 1, 2, \dots, R$) 代表一种端元光谱; $\mathbf{a} = [a_1, a_2, \dots, a_R]^T$ 为该像素点的丰度矢量; $\mathbf{n} = [n_1, n_2, \dots, n_L]^T$ 为附加的高斯白噪声. 其中,由于丰度矢量 $\mathbf{a}$ 代表像素点中各端元所占比例,其必须满足“丰度非负约束”(Abundance Nonnegative Constraint, ANC)和“丰度和为一约束”(Abundance Sum-to-one Constraint, ASC),即

$$a_k \geq 0, \sum_{k=1}^R a_k = 1, k = 1, 2, \dots, R \quad (2)$$

图1所示为简化的不考虑噪声的高光谱图像线性混合模型.




图1 高光谱图像线性混合模型

2.2 非线性混合模型

当上述线性混合模型的假设不能完全满足,多光子在进入传感器之前发生相互作用时,非线性效应就会显现出来,如图2所示. 针对目前受到广泛关注的 BM,它体现出端元之间的二阶相关性,该模型的公式表示为:

$$\mathbf{y} = \mathbf{M}\mathbf{a} + \sum_{i=1}^{R-1} \sum_{j=i+1}^R \beta_{i,j} \mathbf{m}_i \odot \mathbf{m}_j + \mathbf{n} \quad (3)$$

式中, $\odot$ 为 Hadamard 乘积,具体运算规则为:

$$\mathbf{m}_i \odot \mathbf{m}_j = \begin{pmatrix} m_{1,i} \\ \vdots \\ m_{L,i} \end{pmatrix} \odot \begin{pmatrix} m_{1,j} \\ \vdots \\ m_{L,j} \end{pmatrix} = \begin{pmatrix} m_{1,i} m_{1,j} \\ \vdots \\ m_{L,i} m_{L,j} \end{pmatrix} \quad (4)$$




图2 线性混合与非线性混合场景图

为了体现高光谱图像混合的实际物理意义,在 BM 的基础之上,对丰度添加额外的如式(5)约束,就构成了新的非线性混合模型—FM:

$$\sum_{k=1}^R a_k = 1, \beta_{i,j} = a_i a_j \quad (5)$$

而最近提出的更具代表性的模型—GBM 则定义为:

$$\mathbf{y} = \mathbf{M}\mathbf{a} + \sum_{i=1}^{R-1} \sum_{j=i+1}^R \gamma_{i,j} a_i a_j \mathbf{m}_i \odot \mathbf{m}_j + \mathbf{n} \quad (6)$$

式中,要求满足式(2)的约束条件; $\gamma_{i,j}$ 是控制端元间相互作用程度的非线性参数,要求 $0 \leq \gamma_{i,j} \leq 1$. GBM 体现出的物理意义为:高光谱传感器接收到经多种物质依次反向散射的混合光谱信号. 例如,“树木($\mathbf{m}_1$)”和“泥土($\mathbf{m}_2$)”普遍存在于拍摄得到的高光谱图像场景中. 当信号首先被树木散射,然后又被泥土散射,传感器接收到的信号将会是 $\gamma_{1,2} a_1 a_2 \mathbf{m}_1 \mathbf{m}_2$. 并且,由于信号经过了两次反射,传输路径要长于只有单一物质的一次反射路径, $\gamma_{1,2}$ 的值必须小于 1. 尽管多次反射而形成的更高阶的相互作用项也存在,但这些信号已经非常微弱,在实际应用中可以忽略不计^[16].

GBM 的优势在于它是一个广义通用模型:当 $0 < \gamma_{i,j} < 1$ 时,GBM 可以很好诠释实际场景的非线性效应;当 $\gamma_{i,j} = 1$ 时,GBM 就转化成了 FM;当 $\gamma_{i,j} = 0$ 时,GBM 就退化成 LMM. 并且,GBM 对高光谱图像混合特性是逐点描述的,可应用于实际场景中既存在非线性混合,又存在线性混合的复杂情况,对图像场景具有更好的适应性.

3 基于微分搜索的非线性解混算法

GBM 具有较强的通用性,可以很好的描述光谱混合的非线性物理特性. 本文将在 GBM 下,从最优化理论出发,利用群智能优化方法优异的全局优化求解能力,克服传统梯度类优化方法易陷入局部收敛的缺点,提出基于微分搜索的高光谱图像非线性解混新算法.

从最优化理论出发研究高光谱图像非线性解混,重点要解决两个问题:(1)目标函数的构造;(2)利用优化算法对目标函数进行优化求解,得到实现非线性解混的丰度值和非线性参数.

3.1 目标函数与约束条件

本文算法采用重构误差作为评价参数估计效果的测度. 在 GBM 下,高光谱成像仪观测得到的图像中单像素点观测值为 $\mathbf{y}$,采用基于几何的端元估计方法得到的端元光谱矩阵为 $\hat{\mathbf{M}}$. 设本文算法估计出的丰度为 $\hat{\mathbf{a}} = [\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R]^T$,估计出的表征端元间相互作用程度的非线性参数为 $\hat{\gamma}_{i,j}$. 则重构出的该像素点高光谱图像矢量为

$$\hat{\mathbf{y}}_{\text{GBM}} = \hat{\mathbf{M}}\hat{\mathbf{a}} + \sum_{i=1}^{R-1} \sum_{j=i+1}^R \hat{\gamma}_{i,j} \hat{a}_i \hat{a}_j \hat{\mathbf{m}}_i \odot \hat{\mathbf{m}}_j \quad (7)$$

如果丰度和非线性参数估计正确,则观测值 $\mathbf{y}$ 和重构值 $\hat{\mathbf{y}}_{\text{GBM}}$ 将非常接近,据此构造目标函数

$$J(\hat{\mathbf{a}}, \hat{\gamma}) = \|\mathbf{y} - \hat{\mathbf{y}}_{\text{GBM}}\|^2 \quad (8)$$

式中, $\|\cdot\|$ 为 2-范数, $\hat{\gamma} = [\hat{\gamma}_{1,2}, \hat{\gamma}_{1,3}, \dots, \hat{\gamma}_{1,R}, \hat{\gamma}_{2,3}, \hat{\gamma}_{2,4}, \dots, \hat{\gamma}_{2,R}, \dots, \hat{\gamma}_{R-1,R}]^T$. 则高光谱图像非线性解混问题转化为式(9)的最优化问题. 本文算法的解混过程即为求解使目标函数 $J(\hat{\mathbf{a}}, \hat{\gamma})$ 达到最小值的丰度矢量 $\hat{\mathbf{a}}$ 和非线性参数矢量 $\hat{\gamma}$ 的过程.

$$\min J(\hat{\mathbf{a}}, \hat{\gamma}) = \|\mathbf{y} - \hat{\mathbf{y}}_{\text{GBM}}\|^2 \quad (9)$$

式中,丰度 $\hat{\mathbf{a}}$ 为每个像素中各端元成分所占比例值,求解过程必须保证 $\hat{\mathbf{a}}$ 中各元素的非负特性约束(ANC)以及和为 1 约束(ASC). 同时,非线性参数矢量 $\hat{\gamma}$ 还要满足 $0 \leq \gamma_{i,j} \leq 1$ 的要求. 由于本文算法利用群智能优化算法进行目标函数的求解,所以将在优化求解过程中,通过在差分搜索算法进化过程执行搜索范围控制等机制保证算法满足约束要求.

传统对目标函数进行优化求解的方法主要是梯度类优化方法,需要对目标函数进行求导计算,从而推导出算法的迭代公式. 而本文采用群智能优化算法对构造的目标函数进行优化求解,无须进行复杂的公式推导,直接对目标函数进行优化求解即可,求解过程体现出的物理意义更加明确. 并且其更主要的优势体现在:新兴的群智能优化算法具有更加优异的全局优化能力,可以有效克服传统梯度类优化方法易收敛于局部极值而影响解混效果的缺点,得到的解混算法具有更好的鲁棒性和更高的解混精度.

3.2 微分搜索算法

微分搜索(Differential Search, DS)算法^[17]是新近提出的一种性能优异的群智能优化算法,该算法的寻优思想源于生物迁徙运动中的随机漫步行为. 由于自然界中的食物分布情况在一年中会受季节变化而相应改变,大量生物个体在迁徙的过程中会自发形成群体,该群体会利用集体智慧(即群智能)向食物更充足的地区运动.

目前已有一些学者提出了基于群智能的全局优化算法,并在很多领域得以有效应用^[18,19]. 新近提出的 DS 算法同时利用多个个体,优化求解过程并非一味朝着群体中的最优解移动,因此对于复杂的多模态问题具有更好的优化性能. DS 算法仅有两个控制参数,更加简单、易用,其性能已被证明优于 SADE^[20]、ABC 算法^[21]和 GSA 算法^[22]等多种优秀的群智能优化算法. 因此,本文选用 DS 算法作为优化算法解决非线性高光谱图像解混问题. 下面对 DS 算法的优化机理进行简要介绍:

(1) 搜索群体初始位置的产生

设 DS 算法的种群规模为 N , 在维数为 D 的问题空间进行最优解搜索, 搜索个体所处位置为 $X_i (i = \{1, 2, 3, \dots, N\})$, $x_{ij} (j = \{1, 2, 3, \dots, D\})$ 为第 i 个搜索个体在第 j 维的值. 在群体搜索之前对搜索个体所处位置在 up_j 和 low_j 的范围内按照式 (10) 进行随机初始化, 设置最大进化代数 G . 然后按照 DS 算法的搜索策略通过逐代进化寻找最优解.

$$x_{ij} = \text{rand}(up_j - low_j) + low_j \quad (10)$$

在群体进化过程中, 如果搜索个体在某一维度上的值超出 up_j 和 low_j 的上下限范围, 也将按照式 (10) 在范围内随机产生该维度上的新值, 以保证搜索群体在有效范围内进行高效搜索.

(2) DS 算法的搜索策略

群智能优化算法的每一代进化都是一次解空间位置更新的过程, DS 算法是按照式 (11) 的仿生变异原理进行新的 *StopoverSite* _{i} (经停位置) 的产生.

$$\text{StopoverSite}_i = X_i + R_g (\text{donor} - X_i) \quad (11)$$

式中, $\text{donor} = [X_{\text{random_shuffling}(i)}]$ 为从当前 N 个搜索个体中随机选出的一个个体所处的位置, 进而利用 $(\text{donor} - X_i)$ 的交叉变异操作产生新的搜索方向. R_g 为随机数, 由 Gamma 随机数产生器和均匀分布随机数产生器共同运算得到. $R_g = \text{randg}[2 \cdot \text{rand}_1] \cdot (\text{rand}_2 - \text{rand}_3)$, 其作用是保证各搜索个体向着新产生的方向 $(\text{donor} - X_i)$ 以随机的跨度探索. 如果 StopoverSite_i 的适应度值优于 X_i , 则由 StopoverSite_i 代替 X_i 作为该搜索个体的当前位置, 否则仍然保留搜索个体的原位置 X_i . 当种群进化代数达到最大进化代数 G , 将当前搜索群体中适应度值最优的个体位置作为输出.

DS 算法原理简单、控制参数少. 在进化过程中, 不以每代进化的群体最优作为方向引导, 在对最优解的搜索过程中有效平衡了种群多样性与方向性集中搜索, 在搜索群体向全局最优位置高效运动的同时, 有效避免陷入局部极值, 从而能够快速、准确的搜索到问题的全局最优解. 因此, 本文算法利用 DS 算法作为最优优化方法进行高光谱图像的非线性解混.

3.3 优化求解过程与算法流程

在本文算法中, 将高光谱图像的非线性解混问题归结为针对式 (9) 的最优化问题. 本文利用 DS 算法对目标函数进行优化求解, 从而得到单像素点的丰度矢量 $\hat{a} = [\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R]^T$ 和非线性参数矢量 $\hat{\gamma} = [\hat{\gamma}_{1,2}, \hat{\gamma}_{1,3}, \dots, \hat{\gamma}_{1,R}, \hat{\gamma}_{2,3}, \hat{\gamma}_{2,4}, \dots, \hat{\gamma}_{2,R}, \dots, \hat{\gamma}_{R-1,R}]^T$. 通过对高光谱图像所有像素点重复进行基于 DS 算法的优化求解过程, 最终实现整幅图像的非线性解混工作.

针对某一像素点进行优化求解, 首先要解决解混过程中待求变量与 DS 算法中位置变量的对应映射问

题, 即进行 DS 算法中搜索个体的位置编码. 本文算法中的待求变量是式 (9) 中丰度矢量 $\hat{a}$ 的各丰度值和非线性参数矢量 $\hat{\gamma}$ 的各参数值. 则针对存在 R 种端元成分的高光谱图像解混问题, 搜索个体的位置编码为: $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R, \hat{\gamma}_{1,2}, \hat{\gamma}_{1,3}, \dots, \hat{\gamma}_{1,R}, \hat{\gamma}_{2,3}, \hat{\gamma}_{2,4}, \dots, \hat{\gamma}_{2,R}, \dots, \hat{\gamma}_{R-1,R})$. 如当 $R=3$ 时, 搜索个体的位置编码为: $(\hat{a}_1, \hat{a}_2, \hat{a}_3, \hat{\gamma}_{1,2}, \hat{\gamma}_{1,3}, \hat{\gamma}_{2,3})$, 搜索个体将在 6 维空间按照 DS 算法的搜索策略进行最优解的搜索.

在搜索群体的搜索过程中, 为保证算法得到的解满足 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R)$ 的 ANC 要求和 $(\hat{\gamma}_{1,2}, \hat{\gamma}_{1,3}, \dots, \hat{\gamma}_{1,R}, \hat{\gamma}_{2,3}, \hat{\gamma}_{2,4}, \dots, \hat{\gamma}_{2,R}, \dots, \hat{\gamma}_{R-1,R})$ 的 $0 \leq \gamma_{i,j} \leq 1$ 要求, 本文算法将进行搜索范围控制, 即将 DS 算法中搜索个体的 up_j 和 low_j 设置为: $up_j = 1$ 和 $low_j = 0$. 为保证 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R)$ 的 ASC 要求, 在搜索群体每代进化结束后对求得的解中的 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R)$ 进行归一化处理.

基于 DS 算法的高光谱图像非线性解混算法的具体流程如下:

步骤 1 利用 VCA 对实际高光谱图像进行端元提取.

步骤 2 根据高光谱图像中的端元数目确定搜索个体的维数和位置编码.

步骤 3 按照 DS 算法的初始化原理在搜索空间产生一定数量的搜索个体, 设定 $up_j = 1$ 和 $low_j = 0$.

步骤 4 按照式 (9) 中的目标函数计算各搜索个体的适应度值.

步骤 5 按照式 (11) 计算新的经停位置 *StopoverSite* _{i} , 同时对 *StopoverSite* _{i} 进行边界控制.

步骤 6 比较每个搜索个体的当前位置 X_i 和其经停位置 *StopoverSite* _{i} 的适应度值, 如果 *StopoverSite* _{i} 的适应度值小于 X_i , 则由 *StopoverSite* _{i} 代替 X_i 作为该搜索个体的当前位置, 否则仍然保留搜索个体的当前位置 X_i .

步骤 7 对 X_i 中的 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R)$ 部分进行归一化.

步骤 8 如果已经达到最大进化代数, 则输出当前搜索群体中最优搜索个体的位置: $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R, \hat{\gamma}_{1,2}, \hat{\gamma}_{1,3}, \dots, \hat{\gamma}_{1,R}, \hat{\gamma}_{2,3}, \hat{\gamma}_{2,4}, \dots, \hat{\gamma}_{2,R}, \dots, \hat{\gamma}_{R-1,R})$, 从而得到丰度矢量 $\hat{a} = [\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R]^T$ 和非线性参数矢量 $\hat{\gamma} = [\hat{\gamma}_{1,2}, \hat{\gamma}_{1,3}, \dots, \hat{\gamma}_{1,R}, \hat{\gamma}_{2,3}, \hat{\gamma}_{2,4}, \dots, \hat{\gamma}_{2,R}, \dots, \hat{\gamma}_{R-1,R}]^T$. 否则, 转到步骤 4 进行下一代的进化搜索过程.

步骤 9 如果已经对高光谱图像中的所有像素进行了解混, 则停止计算; 否则, 返回步骤 3, 针对下一个像素执行解混工作.

4 实验分析

为评价本文提出的基于 DS 算法的非线性高光谱

图像解混算法性能,分别进行仿真数据和真实遥感数据的解混实验.解混性能评价选用以下三种指标:重构误差(Reconstruction Error, RE)^[23]、光谱角分布(Spectral Angle Mapper, SAM)^[23]和均方根误差(Root Mean Square Error, RMSE)^[24].其中,RE和SAM是从算法重构出的高光谱图像数据与实际观测数据间误差的角度评价算法性能,而RMSE则用于评价算法估计出的丰度与真实丰度之间的相似程度.

三种性能评价指标分别定义如下:

(1) RE

$$RE = \sqrt{\frac{1}{(I \times J)L} \sum_{p=1}^{I \times J} \|y(p) - \hat{y}(p)\|^2} \quad (12)$$

式中, L 为波段数目, $I \times J$ 为高光谱图像像素数. $y(p)$ 和 $\hat{y}(p)$ 分别为高光谱图像第 p 个像素点的真实观测数据和本文算法重构出的数据.

(2) SAM

$$SAM = \frac{1}{I \times J} \sum_{p=1}^{I \times J} \theta[y(p), \hat{y}(p)] \quad (13)$$

式中, $\theta[y(p), \hat{y}(p)] = \arccos\left(\frac{\langle y(p), \hat{y}(p) \rangle}{\|y(p)\| \|\hat{y}(p)\|}\right)$.

(3) RMSE

$$RMSE = \sqrt{\frac{1}{(I \times J)R} \sum_{p=1}^{I \times J} \|a(p) - \hat{a}(p)\|^2} \quad (14)$$

式中, $a(p)$ 和 $\hat{a}(p)$ 分别为高光谱图像第 p 个像素点的真实丰度和本文算法估计出的丰度.

4.1 仿真数据实验

仿真数据实验中的数据选自美国地质勘测局(United States Geological Survey, USGS)提供的矿物光谱库(<http://speclab.cr.usgs.gov/spectral-lib.html>),库中的光谱曲线数据为224个波段,从库中选择3种成分的光谱作为端元光谱(Alunite, Andradite, Buddingtonite),光谱曲线如图3所示.

按照线性混合模型(LMM)和非线性混合模型(GBM和Hybrid Model, HM)分别产生3幅 10×10 像素的合成图像Image1, Image2和Image3.其中,丰度值 $a_k(p)$ 在保证和为1的前提下,在 $0 \sim 0.8$ 之间随机产生,以保证图像中不包含纯像元.非线性参数 $\gamma_{i,j}$ 在 $0 \sim 1$ 之间选取. Hybrid Model的图像中,一半为LMM混合图像,一半为GBM混合图像.针对该图像的实验是为验证GBM作为广义模型对非线性混合和线性混合场景的广义适应性.

在利用本文算法对高光谱图像进行解混之前,需要事先确定端元光谱.为评估端元提取方法对解混算法性能的影响,在两种实验条件下进行解混:

实验1采用光谱库中的真实端元光谱作为端元.实验2采用端元提取算法提取出的端元(选用VCA算




图3 USGS光谱库中选择的3种光谱曲线

法).

在进行两种实验时,本文算法的参数设置均为:DS算法种群规模 $N = 30$,维数 $D = 6$,进化代数 $G = 80$, $up_j = 1$, $low_j = 0$.所有合成高光谱图像均加入方差 $\sigma = 2.8 \times 10^{-3}$ 的高斯白噪声作为干扰成分.实验结果数据均为本文算法和对比算法各自独立运行20次的统计平均值.

实验1 采用光谱库中的真实端元光谱进行解混

表1所示为将光谱库中的真实光谱作为端元时,本文算法与Bayes算法^[25]、FCLS算法^[26]、SUnSAL算法^[27]和GBM-GDA算法^[9,10]四种算法的解混性能进行比较.其中,Bayes算法、FCLS算法和SUnSAL算法为三种性能优良的高光谱图像线性解混算法,GBM-GDA算法为新近提出的基于GBM模型和梯度优化的非线性解混算法.由表1中数据可知,对于Image1(LMM)、Image2(GBM)和Image3(HM)三种混合图像,本文算法获得了总体最优的解混效果,且针对非线性混合图像的解混具有明显优势.

由于GBM模型既能很好的描述高光谱图像混合的非线性特性,又能涵盖线性混合模型.因此,Bayes算法、FCLS算法、SUnSAL算法、GBM-GDA算法和本文算法五种算法均能够较好的实现Image1的解混.本文算法由于采用了DS算法进行目标函数的优化求解,获得了非常优异的解混精度.

对于Image2和Image3,由于两幅图像中均存在非线性混合效应,Bayes算法、FCLS算法和SUnSAL算法三种线性解混算法的解混性能不佳,GBM-GDA算法和本文算法的性能明显优于这三种线性解混算法,获得了较好的解混效果.同时,由于本文算法使用了DS算法完成解混工作,较之采用梯度优化方法具有更好的全局收敛性和更高的优化精度.因此,本文算法获得

了比 GBM-GDA 算法更高的解混精度.

表 1 算法解混性能(真实端元)

		Bayes	FCLS	SUn SAL	GBM- GDA	本文 算法
RE ($\times 10^{-2}$)	Image1	7.96	5.26	5.25	5.26	5.25
	Image2	8.83	6.73	6.47	5.96	5.25
	Image3	10.33	5.80	5.63	5.56	5.29
SAM ($\times 10^{-2}$)	Image1	7.56	7.79	7.80	7.49	7.47
	Image2	8.82	7.02	7.04	6.97	6.79
	Image3	7.75	7.52	7.56	7.19	7.13
RMSE ($\times 10^{-2}$)	Image1	2.52	2.62	2.51	2.65	2.52
	Image2	25.57	16.42	18.35	7.23	3.90
	Image3	18.79	9.74	8.57	4.52	3.52

实验 2 采用 VCA 算法提取出的端元光谱进行解混

在实际端元未知的情况下,需要先用端元提取算法提取端元,本文采用 VCA 算法进行端元的提取.尽管 VCA 算法是一种线性模型下的端元提取算法,但对于非线性模型下的高光谱数据,仍然可以利用 VCA 这类基于几何原理的端元提取算法进行端元提取^[7].

由表 2 数据可知,当端元为从高光谱图像中提取时,包括本文算法在内的五种解混算法的部分性能指标会略有下降,但整体变化不大.这说明在进行非线性解混时,采用 VCA 等基于几何理论的端元提取算法提取端元是可行的.同样,本文算法仍然获得了总体最优的解混效果.

表 2 算法解混性能(估计端元)

		Bayes	FCLS	SUn SAL	GBM- GDA	本文 算法
RE ($\times 10^{-2}$)	Image1	7.33	5.24	5.26	5.25	5.24
	Image2	10.54	7.26	7.11	5.38	5.28
	Image3	8.10	6.43	6.85	5.95	5.29
SAM ($\times 10^{-2}$)	Image1	8.33	7.92	8.06	7.22	7.21
	Image2	7.29	7.19	7.66	6.71	6.61
	Image3	7.85	7.57	7.72	7.66	7.36
RMSE ($\times 10^{-2}$)	Image1	4.77	4.56	4.35	4.33	4.31
	Image2	20.44	27.21	21.46	6.17	4.59
	Image3	19.61	14.46	11.17	7.27	5.71

4.2 真实数据实验

进一步将本文算法应用于真实场景高光谱图像数据的解混,真实场景数据选用 Moffett Field 数据和 Japser Ridge 数据两种高光谱图像数据.

(1) Moffett Field 数据

该数据源自 1997 年采集的美国加州 San Francisco Bay 南端的 Moffett Field 高光谱图像.该图像具有 189 个波段,波长范围为 400nm-2500nm,光谱分辨率为 10nm.实验选取 50×50 的子图像进行算法解混性能评估,该场景主要由 Vegetation、Water 和 Soil 三种端元成分组成.




图4 Moffett Field伪彩色图

(2) Japser Ridge 数据

该数据源自 1994 年采集的加州地区的 Japser Ridge 自然保护区的高光谱图像.该图像具有 224 个波段,波长范围为 380nm-2500nm,光谱分辨率为 9.46nm.在去除了 1-3、108-112、154-166 和 220-224 共 26 个波段的数据后(为去除水汽和大气影响),剩余 198 个有效波段数据.实验选取 100×100 的子图像进行算法解混性能的评估,该场景主要由 Tree、Water、Soil 和 Road 四种端元成分组成.




图5 Japser Ridge伪彩色图

为了实现全自动解混,端元提取方法仍然选用 VCA 算法.图 6 和图 7 所示为利用 VCA 算法分别从两种场景高光谱图像数据中提取出的端元光谱曲线.图 8 和图 9 为采用本文算法解混得到的丰度图.通过对比分析可知,解混出的丰度与真实地物成分的分布是一致的.

为了定量评价本文算法对真实高光谱遥感数据的解混性能,采用 RE 和 SAM 两个指标对上述五种算法进行比较.五种算法的解混性能如表 3 所示.与仿真数据实验得到的结果一致,本文算法的性能优于 Bayes 算法、FCLS 算法和 SUnSAL 算法三种线性解混算法,并且还优于基于梯度优化的非线性解混算法 GBM-GDA,具有最小的 RE 和 SAM 值.




图6 VCA提取出的端元光谱曲线 (Moffett Field)




图7 VCA提取出的端元光谱曲线 (Japser Ridge)

表 3 真实数据算法解混性能

	Moffett Field		Japser Ridge	
	RE ($\times 10^{-2}$)	SAM ($\times 10^{-1}$)	RE ($\times 10^{-2}$)	SAM ($\times 10^{-2}$)
Bayes	2.67	2.559	6.02	10.92
FCLS	2.62	2.557	5.97	10.79
SUnSAL	2.82	2.637	6.11	13.57
GBM-GDA	2.34	2.558	5.96	10.49
本文算法	2.27	2.551	5.05	9.68

上述实验中,基于梯度优化的 GBM-GDA 算法要求利用 FCLS 等线性解混算法对高光谱图像数据进行预解混以获得初始值,然后在此初值的基础上执行 GBM-GDA 算法. 如果不进行预解混,而直接在丰度值和非线性参数值的约束范围内随机初始化初值,GBM-GDA 算法的性能将会急剧下降(如表 4 所示). 这是由于梯度类优化方法存在对初始值要求高的局限性,如果初始值选择不理想,很容易陷入局部收敛而导致解混精度降低.

而本文算法只要在约束范围内随机初始化搜索个体的位置,即可获得前述优于其它算法的解混性能. 其原因在于:本文采用基于群智能的优化方法完成解混工作,有效解决了梯度类优化方法的局部收敛问题,所提出的非线性解混算法具有更好的鲁棒性和更高的解混精度.




图8 本文算法解混得到的丰度图 (Moffett Field)

表 4 真实数据算法解混性能 (随机初始化)

	Moffett Field		Japser Ridge	
	RE ($\times 10^{-2}$)	SAM ($\times 10^{-1}$)	RE ($\times 10^{-2}$)	SAM ($\times 10^{-2}$)
GBM-GDA	16.85	13.563	13.48	27.40
本文算法	2.27	2.551	5.05	9.68




图9 本文算法解混得到的丰度图 (Jasper Ridge)

5 结论

本文提出了一种新的基于微分搜索的高光谱图像非线性解混算法. 算法在 GBM 的基础上采用重构误差作为解混的目标函数, 将非线性解混问题转化为最优化问题. 为了克服传统梯度类优化算法对初始值要求高、易陷入局部收敛的局限性, 采用性能更加优异的群智能优化算法—微分搜索算法完成优化求解过程. 实验结果表明, 所提出算法较之线性解混算法和基于梯度优化的非线性解混算法具有更高的解混精度. 且本文所提出的基于群智能优化的解混算法框架还具有物理意义明确、无须复杂的公式推导等优点, 可以针对不同的混合模型进行推广而得到新的解混算法.

参考文献

- [1] Bioucas-Dias J M, Plaza A, Camps-Valls G, et al. Hyperspectral remote sensing data analysis and future challenges [J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(2): 6–36.
- [2] Honeine P, Richard C. Geometric unmixing of large hyperspectral images: A barycentric coordinate approach [J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(6): 2185–2195.
- [3] 刘建军, 吴泽彬, 韦志辉等. 基于约束非负矩阵分解的高光谱图像解混快速算法[J]. 电子学报, 2013, 41(3): 432–437. Liu Jian-jun, Wu Ze-bin, Wei Zhi-hui, et al. A fast algorithm for hyperspectral unmixing based on constrained non-negative matrix factorization [J]. Acta Electronica Sinica, 2013, 41(3): 432–437. (in Chinese)
- [4] Rajabi R, Ghassemian H. Spectral unmixing of hyperspectral imagery using multilayer NMF [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(1): 38–42.
- [5] Hapke B. Bidirectional reflectance spectroscopy: I. theory [J]. Journal of Geophysical Research: Solid Earth, 1981, 86(B4): 3039–3054.
- [6] Hapke B. Theory of Reflectance and Emittance Spectroscopy [M]. Cambridge University Press, 1993.
- [7] Dobigeon N, Tournier J-Y, Richard C, et al. Nonlinear unmixing of hyperspectral images: models and algorithms [J]. IEEE Signal Processing Magazine, 2014, 31(1): 82–94.
- [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] Halimi A, Altmann Y, Dobigeon N, et al. Unmixing hyperspectral images using the generalized bilinear model [A]. IEEE International Geoscience and Remote Sensing Symposium [C]. Vancouver: IEEE, 2011, 1886–1889.
- [11] Nascimento J M, 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.
- [12] Altmann Y, Halimi A, Dobigeon N, et al. Supervised nonlinear spectral unmixing using a post-nonlinear mixing model for hyperspectral imagery [J]. IEEE Transactions on Image Processing, 2012, 21(6): 3017–3025.
- [13] Jia S, Qian Y T. Spectral and spatial complexity-based hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(12): 3867–3879.
- [14] Rezaei Y, Mobasheri M R, Zoj M J V, et al. Endmember extraction using a combination of orthogonal projection and genetic algorithm [J]. IEEE Geoscience and Remote Sensing Letters, 2012, 9(2): 161–165.
- [15] Zhong Y F, Zhao L, Zhang L P. An adaptive differential evolution endmember extraction algorithm for hyperspectral remote sensing imagery [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(6): 1061–1065.
- [16] Somers B, Cools K, Delalieux S, et al. Nonlinear hyperspectral mixture analysis for tree cover estimates in orchards [J]. Remote Sensing of Environment, 2009, 113(6): 1183–1193.
- [17] Civicioglu P. Transforming geocentric cartesian coordinates to geodetic coordinates by using differential search algo-

- rithm[J]. Computers and Geosciences, 2012, 46: 229 – 247.
- [18] Yang X S, Cui Z H, Xiao R B, et al. Swarm Intelligence and Bio-inspired Computation-Theory and Applications [M]. Elsevier Inc, 2013.
- [19] 邓广宏, 曹万华, 张 剑等. DTN 网络环境下基于蚁群算法的数据编码分发[J]. 电子学报, 2014, 42(8): 1636 – 1641.
Deng Guang-hong, Cao Wan-hua, Zhang Jian, et al. Data dissemination mechanism with network coding based on ant colony algorithm in DTN environment[J]. Acta Electronica Sinica, 2014, 42(8): 1636 – 1641. (in Chinese)
- [20] Wang Y, Cai Z X, Zhang Q F. Differential evolution with composite trial vector generation strategies and control parameters[J]. IEEE Transactions on Evolutionary Computation, 2011, 15(1): 55 – 66.
- [21] Karaboga D, Basturk B. On the performance of Artificial Bee Colony (ABC) algorithm[J]. Applied Soft Computing, 2008, 8(1): 687 – 697.
- [22] Rashedi E, Nezamabadi-pour H, Saryazdi S. GSA: a gravitational search algorithm [J]. Information Science, 2009, 179(13): 2232 – 2248.
- [23] Keshava N, Mustard J F. Spectral unmixing [J]. IEEE Signal Processing Magazine, 2002, 19(1): 44 – 57.
- [24] Plaza J, Plaza A, Perez R, et al. Joint linear/nonlinear spectral unmixing of hyperspectral image data [A]. 2007 IEEE International Geoscience and Remote Sensing Symposium [C]. Barcelona: IEEE, 2007. 4037 – 4040.
- [25] Dobigeon N, Tourneret J-Y, Chang C-I. Semi-supervised linear spectral unmixing using a hierarchical bayesian model for hyperspectral imagery [J]. IEEE Transactions on Signal Processing, 2008, 56(7): 2684 – 2695.
- [26] 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.
- [27] Bioucas-Dias J M, Figueiredo M A T. Alternating direction algorithms for constrained sparse regression: application to hyperspectral unmixing [A]. Proceedings of IEEE GRSS Workshop on Hyperspectral Image and Signal Processing [C]. Raykjavik: IEEE, 2010. 1 – 4.

作者简介



陈 雷 男, 1980 年 2 月生于河北唐山. 现为天津大学精密仪器与光电子工程学院博士后, 天津商业大学信息工程学院副教授. 主要研究方向为高光谱图像处理、仿生智能计算、盲信号处理等.

E-mail: chenleitjcu@139.com



郭艳菊 女, 1980 年 8 月生于河北邢台. 博士, 讲师, 研究方向为高光谱图像处理、仿生智能计算等.

葛宝臻 男, 1964 年 10 月生于内蒙古卓资, 教授, 博士生导师, 主要研究方向为光电成像技术, 激光粒子测量.