

基于回溯优化的非线性高光谱图像解混

陈 雷^{1,2}, 甘士忠³, 孙 茜¹

(1. 天津商业大学 信息工程学院, 天津 300134; 2. 天津大学 精密仪器与光电子工程学院, 天津 300072;
3. 天津工业大学 电子信息工程学院, 天津 300387)

摘 要: 为了进一步提升高光谱图像的解混精度, 提出一种基于回溯优化的高光谱图像后非线性解混算法。在后非线性混合模型的基础上, 以观测图像与重构图像之间的重构误差为目标函数, 使用回溯搜索算法在解空间搜索使目标函数取得极小值的最优解。在搜索过程中, 利用回溯搜索算法的边界控制机制有效保证了高光谱图像解混过程中的约束条件, 进而有效实现了对解混丰度值和非线性参数的精确估计。针对合成高光谱图像和真实高光谱遥感图像的解混实验表明, 文中算法具有优异的解混性能, 所达到的解混精度显著优于现有非线性高光谱图像解混算法。

关键词: 高光谱图像; 非线性解混; 后非线性模型; 仿生智能优化; 回溯搜索优化算法
中图分类号: TP751 **文献标志码:** A **DOI:** 10.3788/IRLA201746.0638001

Nonlinear unmixing using backtracking optimization for hyperspectral images

Chen Lei^{1,2}, Gan Shizhong³, Sun Qian¹

(1. School of Information Engineering, Tianjin University of Commerce, Tianjin 300134, China;
2. School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China;
3. School of Electronics and Information Engineering, Tianjin Polytechnic University, Tianjin 300387, China)

Abstract: A postnonlinear unmixing algorithm was presented for hyperspectral images based on backtracking optimization to improve the unmixing accuracy. On the basis of the postnonlinear mixing model, the reconstruction error between the observed images and the reconstructed images was used as the objective function, backtracking search optimization algorithm was used to search in the solution space to obtain the optimal solution which minimize the objective function. In the search process, the boundary control mechanism of the backtracking search optimization algorithm effectively ensured the constraint condition in the hyperspectral image unmixing, and then the abundance and nonlinear parameters can be estimated accurately. The experiments conducted for both synthetic images and real remote sensing images show that the algorithm proposed is provided with excellent unmixing performance. The unmixing accuracy achieved is significantly better than the state-of-the-art nonlinear hyperspectral images unmixing algorithms.

Key words: hyperspectral images; nonlinear unmixing; postnonlinear model;
bionic intelligence optimization; backtracking search optimization algorithm

收稿日期: 2016-10-10; 修订日期: 2016-11-20

基金项目: 国家自然科学基金(61401307); 中国博士后科学基金(2014M561184); 天津市应用基础与前沿技术研究计划项目(15JCYBJC17100)

作者简介: 陈雷(1980-), 男, 副教授, 博士后, 主要从事高光谱图像处理 and 仿生智能计算方面的研究。Email: chenleitjcu@139.com

0 引言

高光谱图像解混是遥感高光谱图像数据开发利用过程中的一项关键技术。目前,线性混合模型(Linear Mixing Model, LMM)被广泛应用于高光谱图像解混技术中,并已取得了一系列研究成果^[1-3]。基于线性混合模型的解混算法具有原理简单、计算量低的优点。但当拍摄场景中存在多种不同地物成分,光线会在地物之间形成多散射现象。此时,基于非线性混合模型(Nonlinear Mixing Model, NLMM)的解混算法将会实现更优的解混效果^[4]。

近些年,为了减小非线性解混算法的计算复杂度、提高算法的解混精度,一些性能优良的双线性类非线性混合模型被相继提出^[4],如 Fan 模型(Fan Model, FM)^[5]、广义双线性模型(Generalized Bilinear Model, GBM)^[6]等。最近,一类新颖的非线性混合模型—后非线性混合模型(Postnonlinear Mixing Model, PNMM)^[7]也被提出。研究表明:PNMM 能够对存在多种混合物的复杂场景表述得更为准确,其相应的解混算法性能也会更优^[7-8]。但基于该模型的已有解混算法使用传统最优化方法(基于梯度原理的最优化方法)求解丰度值和非线性参数,梯度优化过程的局部收敛性和迭代初值要求限制了解混算法性能的进一步提升。因此,有必要研究利用新型最优化方法在 PNMM 下进行高光谱图像解混的新算法。

仿生智能优化算法(Bionic Intelligence Optimization Algorithm)^[9]是近些年兴起的新型智能优化方法。该类方法较之传统的最优化方法具有全局收敛性好、优化求解精度高等优点,已在三维成像、图像处理、生物医学和工业调度等多领域表现出明显优势^[10-13]。并且,基于仿生智能优化的信息处理方法具有物理意义清晰、不需要复杂的数学推导等优势,更加有利于在工程实际应用中推广。

最近,已有学者尝试将仿生智能优化算法应用于高光谱图像处理领域,如高光谱图像亚像元定位^[14]、高光谱图像端元提取^[15-16]等。这些高光谱图像处理新算法的性能已显著优于传统方法,但对于如何利用仿生智能优化方法在非线形混合模型下实现高光谱图像解混,还有必要进一步深入研究。

为此,文中提出一种新的基于回溯优化的高光

谱图像非线性解混算法。算法中对整幅高光谱图像进行逐点解混,针对像素点构造基于重构误差的目标函数,利用回溯搜索算法优异的全局优化能力求解目标函数,有效解决了梯度法优化求解过程的局部收敛和引入约束条件困难等问题,能够得到精确实现解混的丰度值和非线性参数。较之现有的高光谱图像解混算法,所提出算法的解混性能更加优异。

1 高光谱图像后非线性混合模型

目前,线性混合模型已在高光谱遥感图像解混中得以广泛应用。然而,当光线在进入高光谱成像仪之前发生了多散射现象时,采用非线性混合模型诠释地物成分的混合机理将更为精确。PNMM 是 Altmann 等^[7]新近提出的一类非线性高光谱图像混合模型。该模型能够很好地诠释实际高光谱遥感图像中的非线性场景。PNMM 可以表示为:

$$y = g \sum_{r=1}^R (a_r m_r) + n = g(Ma) + n \quad (1)$$

式中: R 为端元数目; M 为 $L \times R$ 维的端元光谱矩阵; $a = [a_1, a_2, \dots, a_R]^T$ 为高光谱图像中像素点的丰度矢量; $y = [y_1, y_2, \dots, y_L]^T$ 为拍摄到的高光谱图像中的像素点矢量; $n = [n_1, n_2, \dots, n_L]^T$ 为加性高斯噪声; g 表示非线性变换。依据高光谱图像的实际物理意义,丰度矢量的取值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)。

不同的非线性变换 g 能够表征不同的非线性混合场景,通常多采用多项式拟合非线性变换。此时,由于高阶项在实际拍摄环境下已淹没于噪声之中,所以参考文献[7]在考虑了二阶多项式非线性的情况下,提出更为简化且便于实际应用的 PPNMM (Polynomial PNMM):

$$y = g_b(Ma) + n = Ma + b(Ma) \odot (Ma) + n \quad (2)$$

PPNMM 可以有效表征实际环境下的光散射特性,且模型中仅需使用一个非线性参数 b ,与现有的非线性模型相比,该模型更加简单有效,具有更低的计算量。在 PPNMM 下,高光谱图像的解混可以归结为一个最优化过程。传统最优化过程一般采用最小二乘(Least Square, LS)方法对目标函数进行优化求解,但由于高光谱图像解混过程需要考虑 ANC 和

ASC 两个约束条件,使得基于 LS 的优化求解过程变得更为困难。为此,参考文献 [7] 中采用 Subgradient Optimization(SO)方法进行目标函数的求解,从一定程度上解决了引入约束困难的问题。然而,Altmann 同时也指出:SO 方法本质上还是梯度类优化方法,当端元数目增多时,解混算法会存在陷入局部收敛的现象。针对上述问题,文中将仿生智能优化算法—回溯搜索算法引入高光谱图像的非线性解混过程中,利用回溯搜索算法替代梯度类优化方法搜索得到解混丰度值和非线性参数,从而获得更加优异的解混效果。

2 回溯搜索算法

回溯搜索算法(Backtracking Search Optimization Algorithm, BSA)^[17]是 Civicioglu 于 2013 年提出的仿生智能优化算法,该算法具有原理简单、控制参数少、全局优化能力强和搜索精度高等诸多优点,其优化搜索能力优于 ABC、JDE、CLPSO 和 CMAES 等多种主流的仿生智能优化算法,是求解多模态、复杂非线性问题的一种优秀的最优化方法。BSA 的基本原理简述如下:

BSA 的优化求解过程包含 5 部分操作:初始化、选择-1、变异、交叉和选择-2。

(1) 初始化

BSA 在求解最优化问题之前,首先要根据待优化问题的实际可行解空间,在搜索上下限 up_j 和 low_j 之间进行搜索种群 P 的初始化:

$$P_{i,j} \sim U(low_j, up_j) \quad (3)$$

式中: $i=1, 2, \dots, NP$ 为种群规模; $j=1, 2, \dots, D$ 为待优化问题的维数; U 为随机均匀分布函数。

(2) 选择-1

BSA 会在该阶段生成另外的一个历史种群 $oldP$,用以计算判断新的搜索方向。历史种群的初始产生方法与搜索种群相同,即:

$$oldP_{i,j} \sim U(low_j, up_j) \quad (4)$$

在每代进化过程中,随机生成[0,1]的均匀分布随机数 a 和 b 。如果 $a < b$,令 $oldP_{i,j} = P_{i,j}$,从而体现出 BSA 群体的记忆能力。进而还要将种群中各搜索个体的顺序进行重新随机排列,为下一步的变异过程做准备。

(3) 变异

BSA 通过原始种群 P 和历史种群 $oldP$ 之间的变异过程产生下一步的进化搜索方向,如下所示:

$$Mutant = P + F \cdot (oldP - P) \quad (5)$$

式中: F 用来控制产生的新搜索方向的前进幅度,其产生方法为 $F = 3 \cdot rand$, $rand$ 为 [0,1] 均匀分布随机数。

(4) 交叉

BSA 的交叉策略与 DE 算法等其他算法不同,BSA 的交叉策略用于产生试验种群 T (试验种群的初始值采用变异结果)。BSA 算法利用混合比例参数控制参与交叉的搜索个体数目。通过计算得到一个二元整数矩阵 map 来完成试验种群 T 的生成。

$$T_{i,j} = \begin{cases} Mutant_{i,j}, map_{i,j} = 1 \\ P_{i,j}, map_{i,j} = 0 \end{cases} \quad (6)$$

矩阵 map 的产生方式为:

$$\begin{cases} map_{i,u(1:(mixrate \cdot rand \cdot D))}, a < b \\ map_{i,rand(D)}, a \geq b \end{cases} \quad (7)$$

式中: $mixrate$ 为混合比例参数, $rand, a, b$ 均为[0,1]均匀分布随机数。混合比例参数 $mixrate$ 有效控制了参与变异个体的元素数量。种群交叉后产生的新种群个体有可能超出搜索的边界范围,算法中将通过边界控制机制(放弃该个体,按照公式(3)重新产生一个新的个体)予以处理。

(5) 选择-2

在 BSA 的选择-2 流程中,利用贪婪选择原理将新种群中更优的搜索个体替换原有种群中的个体,同时更新当前种群的全局最优解 P_{best} ,从而完成一代进化过程。通过重复进行多次上述搜索进化过程,最终得到全局最优解。

3 基于回溯优化的非线性解混算法

在文中算法中,采用 BSA 替代 Subgradient Optimization 方法进行高光谱图像的解混。算法在解空间进行高效的全局搜索,并通过 BSA 自身的边界控制机制和端元变换操作解决了 ANC 和 ASC 两个约束问题,从而实现了对高光谱图像的有效解混。

3.1 目标函数与约束条件

文中算法基于 PPNMM 对整幅高光谱图像进行逐点解混,解混过程需要求解每个像素点的丰度矢

量 $\hat{\mathbf{a}}$ 和非线性参数 $\hat{\mathbf{b}}$ 。据此对每一个像素点构造基于重构误差的目标函数:

$$J(\hat{\mathbf{a}}, \hat{\mathbf{b}}) = \left\| \mathbf{y} - \hat{\mathbf{y}}_{\text{PPNMM}} \right\|^2 \quad (8)$$

式中: \mathbf{y} 为实际观测得到的高光谱图像像素点矢量; $\hat{\mathbf{a}}=[\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R]$ 和 $\hat{\mathbf{b}}$ 分别为算法解混得到的丰度矢量和非线性参数; $\hat{\mathbf{y}}_{\text{PPNMM}}$ 为由 $\hat{\mathbf{a}}$ 和 $\hat{\mathbf{b}}$ 混合得到的像素点矢量。如果丰度矢量和非线性参数估计准确,目标函数 $J(\hat{\mathbf{a}}, \hat{\mathbf{b}})$ 将取得极小值。文中采用 BSA 在解空间搜索实现最小化目标函数的 $\hat{\mathbf{a}}$ 和 $\hat{\mathbf{b}}$ 。由于像素点矢量

$$\hat{\mathbf{y}}_{\text{PPNMM}} = \hat{\mathbf{M}}\hat{\mathbf{a}} + \hat{\mathbf{b}}(\hat{\mathbf{M}}\hat{\mathbf{a}}) \odot (\hat{\mathbf{M}}\hat{\mathbf{a}}) \quad (9)$$

解混算法中需要事先求得估计的端元光谱矩阵 $\hat{\mathbf{M}}$ 。尽管文中算法是针对非线性混合模型进行的解混,但仍然可以使用线性混合模型下的端元提取方法估计 $\hat{\mathbf{M}}$ ^[4],故文中算法将采用基于几何学的 VCA 算法^[10]对实际拍摄得到的高光谱图像进行 $\hat{\mathbf{M}}$ 的提取。

针对梯度优化过程中存在的引入约束条件困难问题,在使用 BSA 优化求解公式(8)的目标函数过程中,为保证满足 ANC 约束,将 BSA 中的搜索上限 up_j 设为 1、搜索下限 low_j 设为 0。为保证满足 ASC 约束,在针对存在 R 个端元的图像解混时,将第 R 个端元的丰度值表示为:

$$\hat{a}_R = 1 - \sum_{i=1}^{R-1} \hat{a}_i \quad (10)$$

算法中的该变换过程在保证满足约束条件的同时,减少了目标函数中需要求解参数的个数,降低了求解难度,即在 BSA 优化求解过程中需要求解的丰度值由 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R)$ 变为 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_{R-1})$ 。

3.2 位置参数编码与解混过程

文中算法在采用 BSA 优化求解公式(8)的目标函数过程中,首先要进行 BSA 中种群个体位置与目标函数中待求变量的映射编码。即确定种群个体在搜索空间中各维度上的位置变量值与丰度值 $[\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R]$ 和非线性参数 $\hat{\mathbf{b}}$ 的对应关系。

由于解混过程中为满足 ASC 约束,进行了如公式(10)的变换,则映射结果为 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_{R-1}, \hat{\mathbf{b}})$ 。如:当高光谱图像中存在 $R=5$ 种端元时,BSA 的位置参数

编码应为 $(\hat{a}_1, \hat{a}_2, \hat{a}_3, \hat{a}_4, \hat{\mathbf{b}})$ 。BSA 中的生物群体将在 5 维空间中,搜索使目标函数 $J(\hat{\mathbf{a}}, \hat{\mathbf{b}})$ 取得极小值的空间位置,最终得到最优端元丰度值 $(\hat{a}_1, \hat{a}_2, \hat{a}_3, \hat{a}_4, 1 - \sum_{i=1}^4 \hat{a}_i)$ 和非线性参数 $\hat{\mathbf{b}}$ 。文中算法在完成一个像素点的解混后,继续对图像中的下一个像素点进行解混,通过逐点分别解混最终完成对整幅高光谱图像的解混工作。

3.3 算法具体步骤

(1) 使用基于几何学的端元提取方法得到高光谱图像中的端元光谱曲线。

(2) 依据高光谱图像中的端元数目,确定搜索空间维数,在约束范围内随机产生 BSA 的搜索种群。

(3) 按照公式(8)中的目标函数计算各搜索个体的适应度值。

(4) 按照搜索种群的产生方式生成历史种群 *oldP*,通过原始种群 *P* 和历史种群 *oldP* 之间的变异和交叉策略产生新的种群个体,并通过边界控制机制保证种群个体位置满足高光谱图像解混的约束条件。

(5) 使用贪婪选择原理将新种群中更优的搜索个体替换原有种群中的个体,同时更新当前种群的全局最优解 \mathbf{P}_{best} 。

(6) 如果已经达到最大进化代数,则输出当前种群中的全局最优解 $\mathbf{P}_{\text{best}}: (\hat{a}_1, \hat{a}_2, \dots, \hat{a}_{R-1}, \hat{\mathbf{b}})$,结合公式(10)得到丰度矢量 $\hat{\mathbf{a}}=[\hat{a}_1, \hat{a}_2, \dots, \hat{a}_R]^T$ 和非线性参数 $\hat{\mathbf{b}}$ 。否则,跳转至步骤(3)。

(7) 如果已经完成了整幅图像的解混工作,则输出估计出的丰度值和非线性参数;否则,返回步骤(2),继续进行图像中其他像素点的解混。

4 解混实验分析

为了验证文中算法的有效性,针对合成图像和真实遥感图像进行高光谱图像解混实验。构成合成图像的端元光谱从 U. S. Geological Survey(USGS)光谱库中提取。实际拍摄的真实图像数据选用 Samson 和 Jasper Ridge 两组高光谱遥感图像,这两个场景的高光谱遥感图像已被广泛应用于高光谱图

像解混性能测试中。用于评估算法解混质量的性能指标为光谱角分布 (SAM)^[19]、图像均方根误差 (RMSE(X))^[15]和丰度均方根误差(RMSE(S))^[15]。

4.1 合成图像解混实验

从 USGS 库中选择端元光谱进行合成图像解混

实验,分别对端元数目 $R=3$ 和 $R=9$ 两种情况进行解混实验,实验中使用的 9 种光谱曲线如图 1 所示。

用于解混实验的合成图像由 3 种方式产生。其中,图像 I1 由随机产生的满足 ANC 和 ASC 两项约束的丰度值线性合成;图像 I2 按照 PPNMM 非线性

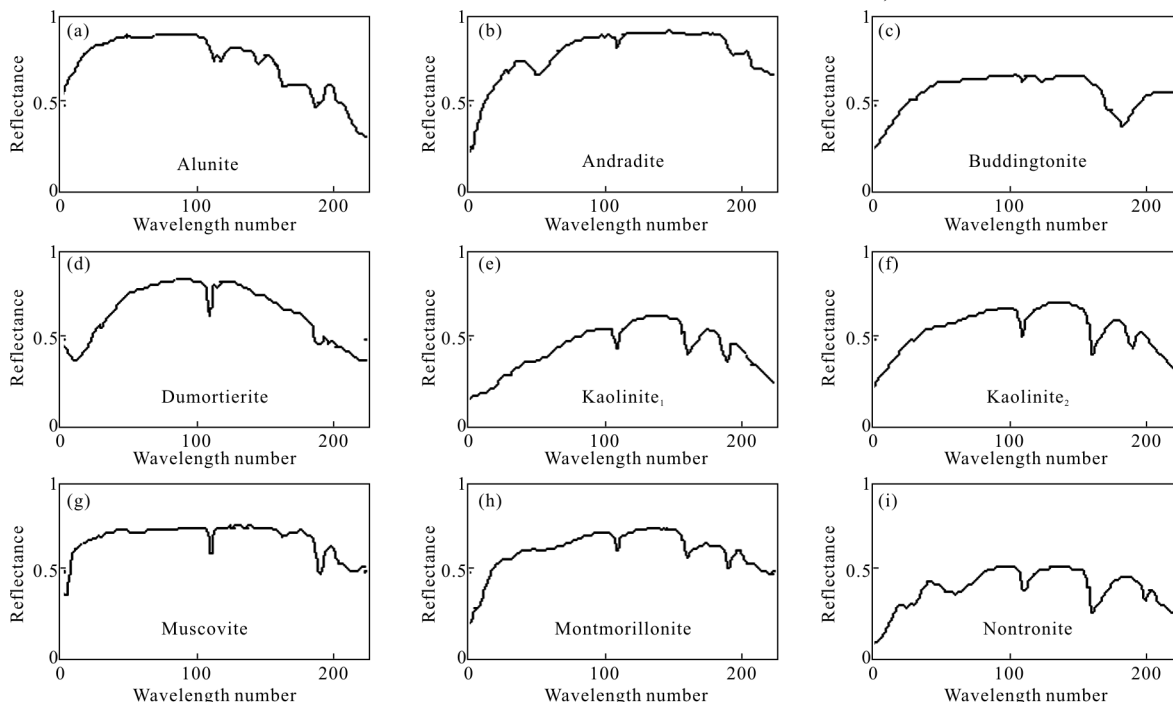


图 1 USGS 光谱库中的 9 种光谱曲线

Fig.1 Nine spectral curves selected from the USGS spectral library

合成得到,其非线性参数 b 在 $(-1,1)$ 范围内随机选取;图像 I3 为综合混合图像,其线性混合的像素点和 PPNMM 非线性混合的像素点各占总像素点的 50%,产生该测试图像的目的是为了模拟真实场景中线性混合像素点和非线性混合像素点同时存在的实际情况。合成的图像尺寸均为 10×10 像素。图 2 和图 3 分别示出了端元数目 $R=3$ 和 $R=9$ 两种情况下,混合高光谱图像 I1、图像 I2 和图像 I3 的第 1 个波段图像。在进行解混实验时,文中算法的参数设置为:BSA 种群规模 $N=30$,搜索空间维数 $D=R$,种群进化代数 $G=5\ 000$, $up_j=1$, $low_j=0$ 。种群在约束范围内随机初始化。




图 2 混合高光谱图像示意图($R=3$)

Fig.2 Mixing hyperspectral images($R=3$)




图 3 混合高光谱图像示意图($R=9$)

Fig.3 Mixing hyperspectral images($R=9$)

解混过程使用 USGS 光谱库中的对应真实端元光谱进行,表 1 中的性能指标数据为文中算法、Bayes 算法^[20]和 PPNMM 算法^[7]3 种算法的解混结果。其中,Bayes 算法是线性混合模型下的高光谱图像解混算法,PPNMM 算法为参考文献[7]中提出的基于 PPNMM 模型和 Subgradient Optimization 的非线性解混算法,该算法中需要使用 FCLS 算法^[21]获得后续解混过程的初值。表 1 统计了 30 次 Monte Carlo 实验的平均结果数据。

综合分析表中数据可知,对于线性混合图像 I1,

Bayes 算法、PPNMM 算法和文中算法均获得了较好的解混效果,这说明线性解混算法——Bayes 算法和 PPNMM 算法、文中算法两种非线性解混算法均能较好地解混线性场景的高光谱图像。而对于 I2 和 I3 两幅存在非线性混合情况的图像, Bayes 算法的解

混效果会显著下降,此时 PPNMM 算法和文中算法的解混效果具有明显优势。并且,文中算法由于采用全局搜索能力更强、搜索精度更高的 BSA 进行丰度值和非线性参数的搜索,解混性能更加稳定,所得的解混结果明显优于 PPNMM 算法。

表 1 算法解混性能比较(合成图像)

Tab.1 Comparison of unmixing performances (synthetic images)

	SAM($\times 10^{-2}$)			RMSE(X)($\times 10^{-2}$)			RMSE(S)($\times 10^{-2}$)			
	Bayes	PPNMM	Proposed algorithm	Bayes	PPNMM	Proposed algorithm	Bayes	PPNMM	Proposed algorithm	
I1	3	7.40	7.42	7.36	5.28	5.25	5.20	2.92	3.53	3.12
	9	8.67	8.45	8.44	5.37	5.21	5.19	8.21	8.84	8.24
I2	3	8.31	6.44	5.46	33.41	5.22	5.21	18.87	3.30	2.46
	9	8.38	7.42	6.29	16.23	5.22	5.16	7.71	8.27	7.31
I3	3	8.05	6.48	6.47	23.31	5.25	5.24	14.80	2.99	2.55
	9	8.36	7.42	7.34	16.43	5.22	5.15	7.86	7.84	7.77

4.2 真实遥感图像实验

(1) Samson 数据

Samson 数据是由美国 Florida Environmental Research Institute 利用 Samson sensor 拍摄的高光谱图像数据,该数据记录了 401~889 nm 之间的 156 个波段数据,其光谱分辨率为 3.13 nm。原图像包含 952×952 个像素点,为了节省计算耗时,通常选取如图 4 所示的 95×95 子区图像进行解混实验。图像中包含 Soil、Tree 和 Water 3 种地物成分。




图 4 Samson 场景图

Fig.4 Samson scene

(2) Jasper Ridge 数据

Jasper Ridge 数据是拍摄于美国 California 地区 Jasper Ridge 自然保护区的高光谱图像数据,该数据记录了 380~2 500 nm 之间的 198 个波段数据,其光谱分辨率为 9.46 nm。原图像包含 512×614 个像素点,通常

选取如图 5 所示的 100×100 的子区图像进行解混实验。图像中包含 Tree、Water、Soil 和 Road 4 种地物成分。




图 5 Jasper Ridge 场景图

Fig.5 Jasper Ridge scene

在进行真实遥感图像数据的解混过程中,由于端元未知,需要先进行端元光谱的提取。此处采用基于几何学的 VCA 算法进行端元提取,然后使用文中算法求解丰度值和非线性参数,完成对真实高光谱图像的解混。文中算法解混得到的丰度图如图 6 和




图 6 文中算法解混得到的丰度图(Samson)

Fig.6 Abundance maps estimated by the proposed algorithm (Samson)

图 7 所示,由丰度图可以看出,文中算法清晰地还原了各种地物的实际分布情况。




图 7 文中算法解混得到的丰度图(Jasper Ridge)

Fig.7 Abundance maps estimated by the proposed algorithm (Jasper Ridge)

为了进一步客观分析文中算法对实际高光谱遥感图像的解混效果,将文中算法与 Bayes 算法、PPNMM 算法、PPNMM-NonFCLS 算法进行解混性能指标对比。其中,PPNMM-NonFCLS 为随机给定解混初值情况下的 PPNMM 算法。由于真实遥感图像的实际丰度值是未知的,所以该实验选用 SAM 和 RMSE(X)两个性能指标进行对比分析。

表 2 中的数据为多种算法对于真实遥感图像的解混结果,与线性解混算法——Bayes 算法、非线性解混算法——PPNMM 算法和 PPNMM-NonFCLS 算法相比,文中算法具有明显的性能优势。尤其对比分析 PPNMM 算法和 PPNMM-NonFCLS 算法的解混效果可知,在 PPNMM 算法不使用 FCLS 算法进行

表 2 算法解混性能比较(真实遥感图像)

Tab.2 Comparison of unmixing performances (real remote sensing images)

	Samson		Jasper Ridge	
	SAM($\times 10^{-2}$)	RMSE(X)($\times 10^{-2}$)	SAM($\times 10^{-2}$)	RMSE(X)($\times 10^{-2}$)
Bayes	7.53	4.40	18.19	8.13
PPNMM	10.03	1.15	15.61	1.93
PPNMM-NonFCLS	10.08	14.28	23.72	31.35
Proposed algorithm	6.47	1.12	7.22	1.58

解混初值初始化的情况下,解混性能会明显下降。这是由于 PPNMM 算法所使用的最优化方法是梯度类优化算法(Subgradient Optimization),当解混初始值设置不理想时,算法容易陷入局部收敛而导致解混性能降低。而文中算法由于采用仿生智能优化算法—BSA 进行图像解混过程的最优解搜索,算法中无需进行特定的初始值设定,即可完成对高光谱图像的有效解混。

5 结论

为了更好地解决高光谱图像非线性解混问题,文中以仿生智能优化算法为最优化方法,在 PPNMM 的基础上提出了一种新的非线性解混算法。算法使用 BSA 替代 Subgradient Optimization 方法对目标函数进行求解,利用生物种群的信息交流与合作共享机制,搜索得到正确的解混参数,从而在对合成光谱图像和真实遥感图像的解混过程中表现出优异的性能。与已有基于 PPNMM 和梯度优化的非线性解混算法相比,文中算法无需额外利用 FCLS 等其他线性解混算法初始化解混初值,具有更高的解混精度。并且,文中算法的解混思想具有较强的通用性,今后可继续结合新的混合模型和搜索能力更强的仿生智能优化算法,提出性能更优的高光谱图像非线性解混算法。

参考文献:

- [1] Guerra R, Santos L, Lopez S, et al. A new fast algorithm for linearly unmixing hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(12): 6752–6765.
- [2] Li J, Bioucas-Dias J M, Plaza A, et al. Robust collaborative nonnegative matrix factorization for hyperspectral unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10): 6076–6090.
- [3] He W, Zhang H, Zhang L. Sparsity-regularized robust non-negative matrix factorization for hyperspectral unmixing [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 13(5): 686–690.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] Altmann Y, Halimi A, Dobigeon N, et al. Supervised nonlinear spectral unmixing using a postnonlinear mixing model for hyperspectral imagery [J]. *IEEE Transactions on Image Processing*, 2012, 21(6): 3017–3025.
- [8] Dobigeon N, Tits L, Somers B, et al. A comparison of nonlinear mixing models for vegetated areas using simulated and real hyperspectral data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 1869–1878.
- [9] Yang X S, Cui Z H, Xiao R B, et al. Swarm Intelligence and Bio-Inspired Computation: Theory and Applications [M]. USA: Elsevier Inc, 2013.
- [10] Bermejo E, Cordón O, Damas S, et al. A comparative study on the application of advanced bacterial foraging models to image registration [J]. *Information Sciences*, 2015, 295: 160–181.
- [11] Mao Haicen, Liu Aidong, Wang Liang. Star recognition method based on hybrid particle swarm optimization algorithm [J]. *Infrared and Laser Engineering*, 2014, 43(11): 3762–3766. (in Chinese)
毛海岑, 刘爱东, 王亮. 采用混合粒子群算法的星图识别方法 [J]. *红外与激光工程*, 2014, 43(11): 3762–3766.
- [12] Ahirwal M K, Kumar A, Singh G K. Adaptive filtering of EEG/ERP through bounded range artificial bee colony (BR-ABC) algorithm [J]. *Digital Signal Processing*, 2014, 25(1): 164–172.
- [13] Wang S Y, Wang L. An estimation of distribution algorithm-based memetic algorithm for the distributed assembly permutation flow-shop scheduling problem [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, 46(1): 139–149.
- [14] Zhong Y, Zhang L. Remote sensing image subpixel mapping based on adaptive differential evolution [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2012, 42(5): 1306–1329.
- [15] Zhong Y, Zhao L, Zhang L. 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] Gao L, Gao J, Li J, et al. Multiple algorithm integration based on ant colony optimization for endmember extraction from hyperspectral imagery [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2569–2582.
- [17] Civicioglu P. Backtracking search optimization algorithm for numerical optimization problems [J]. *Applied Mathematics and Computation*, 2013, 219(15): 8121–8144.
- [18] 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.
- [19] Keshava N, Mustard J F. Spectral unmixing [J]. *IEEE Signal Processing Magazine*, 2002, 19(1): 44–57.
- [20] Dobigeon N, Tournier 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.
- [21] 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.