

doi: 10.3788/gzxb20164505.0511001

基于去噪降维和蝙蝠优化的高光谱图像盲解混算法

贾志成¹, 薛允艳¹, 陈雷^{2,3}, 郭艳菊¹, 许浩达¹

(1 河北工业大学 电子信息工程学院, 天津 300401)

(2 天津大学 精密仪器与光电子工程学院, 天津 300072)

(3 天津商业大学 信息工程学院, 天津 300134)

摘要:为解决盲源分离技术难以直接用于高光谱图像解混这一问题,将丰度非负及和为 1 约束作为盲源分离的目标函数,改变传统的独立性假设;同时,针对目标函数中具有大量的局部极小,引入蝙蝠优化算法,解决传统梯度类优化算法易陷入局部极值的问题.在降维过程中,提出一种基于奇异值分解去噪的正交子空间投影的降维方法.仿真数据和真实遥感数据实验表明,所提出算法收敛速度和解混准确度高,具有较强的抗噪声干扰能力,适用于像元纯度很低的高光谱图像解混.

关键词:遥感;高光谱解混;盲源分离;目标函数;蝙蝠算法;正交子空间投影

中图分类号: TP751

文献标识码: A

文章编号: 1004-4213(2016)05-0511001-10

Blind Separation Algorithm for Hyperspectral Image Based on the Denoising Reduction and the Bat Optimization

JIA Zhi-cheng¹, XUE Yun-yan¹, CHEN Lei^{2,3}, GUO Yan-jun¹, XU Hao-da¹

(1 School of Electronic Information Engineering, Hebei University of Technology, Tianjin 300401, China)

(2 School of Information Engineering, Tianjin University of Commerce, Tianjin 300134, China)

(3 School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China)

Abstract: In order to solve the problem that the blind source separation is difficult to be directly applied to the hyperspectral unmixing, the linear spectral mixture model was introduced in the presence of Abundance Non-negative Constraint (ANC) and Abundance Sum-to-one Constraint (ASC) as the objective function of the blind source separation to change the traditional independence assumption. Then, the Bat Algorithm (BA) was introduced to optimize the objective function. This algorithm solves the problem that the traditional gradient optimization algorithm is easy to fall into the local extremum. A method was proposed for dimensionality reduction, which is based on Singular Value Decomposition Denoising-orthogonal Subspace Projection (SVDD-OSP). The experimental results on synthetic data and real remote sensing data indicate that the proposed algorithm has a high convergence rate and a high accuracy. In addition, it has the strong anti noise interference ability and can be applied to the data with a low purity.

Key words: Remote; Hyperspectral unmixing; Blind source separation; Objective function; Bat algorithm; Orthogonal subspace projection

OCIS Codes: 110.4234; 100.4145; 070.4790

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)和天津市应用基础与前沿技术研究计划(No. 15JCYBJC17100)资助

第一作者: 贾志成(1957-), 男, 教授, 主要研究方向为高光谱图像处理. Email: jiazc@hebut.edu.cn

通讯作者: 陈雷(1980-), 男, 副教授, 博士, 主要研究方向为高光谱图像处理和盲信号处理. Email: chenleitju@139.com

收稿日期: 2015-12-07; 录用日期: 2016-02-18

<http://www.photon.ac.cn>

0 引言

高光谱遥感数据最主要的特点是将图像维和光谱维信息融合在一起,在获取地表空间图像的同时,可以得到地物的连续光谱信息^[1].然而,由于有限的空间分辨率以及复杂的地形,使得所拍摄的高光谱图像中含有大量混合像元,进而严重影响地物的分类和识别准确度.因此,为了提高遥感应用的准确度,必须解决混合像元的分解问题^[2].

基于线性模型的高光谱解混算法多是基于几何学原理^[3],如顶点成分分析算法^[4](Vertex Component Analysis, VCA),最小体积单形体分析算法^[5](Minimum Volume Simplex Analysis, MVSA)等.但这些算法并不适用于没有纯像元的数据集,在真实场景中应用具有局限性.近几年,研究人员在几何学方法的基础上对上述算法进行了改进^[6-7],改进后的算法虽然降低了对像元纯度的要求,但其极易受到噪声的影响.

为解决传统的基于几何学方法存在的不足,研究人员对基于统计学^[8]的盲源分离^[9](Blind Source Separation, BSS)进行了研究.2005年,Nascimento^[10]把端元光谱矩阵作为混合矩阵进行盲源分离,并证明了其可行性.但是BSS的独立性假设与高光谱解混模型的丰度相关性相矛盾,使得算法的解混效果降低了.针对此问题,本文将丰度非负约束和丰度和为1约束作为BSS的目标函数,改变传统的独立性假设,提高算法的解混准确度.

高光谱图像解混算法中采用的传统优化方法多是梯度法^[4-7],其易受初始值影响而陷入局部极值.为解决这一问题,本文采用收敛性能更佳的群智能算法-蝙蝠算法^[11](Bat Algorithm, BA)优化目标函数.该优化算法能很好地解决了传统梯度算法存在的不足,提高了算法的稳定性.

有效地降维可以降低高光谱图像中的噪声,提高算法的抗噪声能力.主成分分析^[12](Principal Components Analysis, PCA)是目前广泛使用的降维算法,其不足是容易丢失一些无法用二阶统计特性表示的有用信息,抗噪声能力差.文献^[13]提到正交子空间投影是高光谱图像降维的一个有力工具.与PCA相比,OSP降低了计算复杂性,而且还可以有效保护二阶统计量在降维过程中易丢失的数据特征,最重要的是经过OSP后,图像的噪声得到了有效的投影压缩.但是OSP算法选择原始图像中范数最大的点作为初始端元,该点可能为原始图像中的噪声点,会导致之后的降维失败.为减小噪声对解混算法性能的影响,本文提出基于奇异值分解去噪的正交子空间投影^[14](Orthogonal Subspace Projection, OSP)降维方法.该

方法克服了传统主成分分析的缺点,可以在降维过程中有效提高算法的抗噪能力.

1 高光谱图像线性混合模型

在高光谱遥感图像线性光谱混合模型(Linear Spectral Mixture Model, LSMM)中,像素的观察值等同于各端元的光谱特征按照它们的丰度(物质在像素中所占比例)进行线性组合.用 $\mathbf{x} \in \mathbf{x}^{L \times N}$ 表示图像中的光谱矩阵,其中, L 代表光谱维,即高光谱图像的波段数; N 表示每个波段有 N 个像素.假设它是由 P 个端元线性组合而成,则线性混合模型可表示为

$$\mathbf{x} = \mathbf{M}\mathbf{s} + \mathbf{n} \quad (1)$$

式中, $\mathbf{M} = [m_1, m_2, \dots, m_P]^T \in \mathbf{x}^{L \times P}$ 是光谱信号矩阵, m_i 代表第 i 个端元的光谱向量; $\mathbf{s} = [s_1, s_2, \dots, s_P]^T \in \mathbf{x}^{P \times N}$ 是丰度矩阵,其中 s_i 代表第 i 个端元在高光谱数据中所占的比例; \mathbf{n} 为误差项.实际环境中,丰度矩阵受到非负及和为1两个约束的限制,即

$$s_i \geq 0, \sum_{i=1}^P s_i = 1, (i = 1, 2, \dots, P) \quad (2)$$

线性光谱混合模型与BSS的数学模型很相似,因此将BSS应用到高光谱图像解混,将丰度向量 \mathbf{s} 视为源信号,端元光谱 \mathbf{M} 视为混合信号,高光谱图像 \mathbf{x} 视为观测信号,在没有任何先验知识的情况下,仅使用观测得到的混合信号 \mathbf{x} ,求出一个分离矩阵为

$$\mathbf{W} = [\omega_1, \omega_2, \dots, \omega_P] \quad (3)$$

使得每个像元光谱中各端元的丰度估计为

$$\mathbf{Y} = \mathbf{W}\mathbf{x} \quad (4)$$

式中, $\mathbf{Y} = [y_1, y_2, \dots, y_P]^T$ 尽可能地接近丰度矩阵 \mathbf{s} .

2 算法描述

2.1 基于去噪原理的降维方法

本文对OSP算法进行改进,在降维前先去噪,提出基于奇异值分解去噪的正交子空间投影(Singular Value Decomposition Denoising-Orthogonal Subspace Projection, SVDD-OSP)的降维方法.首先借鉴VCA算法对数据降维处理以消除噪声影响的思路,利用SVD(Singular Value Decomposition)投影技术将原始数据投影到低维空间,然后利用投影变换的逆变换将降维后的数据恢复,实现去噪,即得到去噪后的高光谱图像;再通过OSP方法降维至 P 个端元,从而使得高光谱图像的噪声有效的去除而且还可以有效保护二阶统计量在降维过程中易丢失的数据特征,抗噪声能力明显提高.

基于奇异值分解去噪的正交子空间投影降维算法的步骤为

- 1)将 L 维的原始数据 \mathbf{Y} 去均值得到新的数据 \mathbf{Y}_1 ;
- 2)选择利用SVD投影技术,将 \mathbf{Y}_1 降维至 $P-1$ 维

数据;

3)利用投影变换的逆变换将降维后的数据 \mathbf{Y}_1 恢复为 L 维数据 \mathbf{Y}_2 , 实现去噪;

4)将 \mathbf{Y}_2 加上均值恢复原始数据 \mathbf{Y} ;

5)利用正交基投影,取具有最大投影值的像元为新端元,再通过伪逆矩阵变换运算重新确定一个正交投影方向;

6)将所有像元向该方向投影,实现高光谱图像的降维;

7)将降维后的数据再经过白化处理,达到去相关的目的,得到最终的预处理结果。

经过这种降维方法得到的数据有效提高了算法的抗噪声性能。经过降维后,将盲源分离应用于高光谱图像解混,丰度非负及和为 1 约束作为其目标函数,利用蝙蝠算法^[11]来优化目标函数,从而实现图像解混。

2.2 基于丰度约束的目标函数

高光谱遥感图像中,端元丰度存在非负及和为 1 约束,破坏了传统盲源分离要求各成分独立的前提,使得盲源分离算法难以直接用于高光谱图像解混。为解决该问题,Wang^[15]等将丰度非负及和为 1 约束加入到目标函数中,尽管可以使解混结果在满足约束条件的同时尽可能减小它们的互信息,但在实际中概率密度函数难以获取且算法的计算量大。针对该问题本文进行了改进,只将丰度非负约束 (Abundance Non-negative Constraint, ANC) 及丰度和为 1 约束 (Abundance Sum-to-one Constraint, ASC) 作为盲源分离的目标函数,提高算法的解混速度。

2.2.1 丰度非负约束 (Abundance Non-negative Constraint, ANC)

在目标函数中引入非负约束项使得结果满足 ANC,设计原则为,当结果满足约束时, $J_ANC(\mathbf{Y}) = 0$; 否则, $J_ANC(\mathbf{Y}) < 0$ 。构造 ANC 目标函数为^[16]

$$J_ANC(\mathbf{Y}) = - \sum_{j=1}^N \sum_{i=1}^P [f(y_{ij}) + |f(y_{ij})|] / 2 \quad (5)$$

式中,函数 $f(y_{ij})$ 满足以下条件

$$f(y_{ij}) \begin{cases} < 0, & y_{ij} \in [0, 1] \\ > 0, & y_{ij} \notin [0, 1] \end{cases} \quad (6)$$

式中,取 $f(y_{ij}) = [(y_{ij} - 0.5)^2 - 0.25] / 2$, 这时,当矩阵 \mathbf{Y} 中负分量的绝对值越大时, $J_ANC(\mathbf{Y})$ 的绝对值也越大,这一特性有助于加快算法的收敛速度。

2.2.2 丰度和为 1 约束 (Abundance Sum-to-one Constraint, ASC)

构造 ASC 目标函数为^[16]

$$J_ASC(\mathbf{Y}) = - \sum_{j=1}^N \left(\sum_{i=1}^P y_{ij} - 1 \right)^2 / 2 \quad (7)$$

当结果满足约束时,约束项为 0; 否则,小于 0。

基于两个约束,本文算法的目标函数总结为

$$\min J(\mathbf{Y}) = \eta_1 J_ANC(\mathbf{Y}) + \eta_2 J_ASC(\mathbf{Y}) \quad (8)$$

式中, $\mathbf{Y} = \mathbf{W}\mathbf{x}$, 参量 η_1, η_2 用于控制约束条件的权重。 $J(\mathbf{Y})$ 就是本文算法总的目标函数。

2.3 蝙蝠优化算法

蝙蝠算法^[11]是 Yang Xin-she 在 2010 年提出的一种群智能优化算法。它是基于回声定位的声学理论,每个蝙蝠对自己发出超声波的回声进行分析,从而准确的搜索猎物。蝙蝠算法中,每个优化问题的解都是搜索空间中的一个蝙蝠,所有蝙蝠通过调整频率 f_i 、响度 A_i 、脉冲发射率 r_i , 追随当前的最优蝙蝠在解空间中搜索。这里的 f_i, A_i 和 r_i 分别指蝙蝠在搜索过程中发出的超声波脉冲的频率、超声波脉冲的强度和超声波脉冲的频度。

2.3.1 速度和位置的更新

蝙蝠算法首先需要确定速度和位置更新公式。在一个多维搜索空间中,第 i 只蝙蝠的新位置 \mathbf{x}_i 和新速度 \mathbf{v}_i 在时刻 t 时的更新公式为^[11]

$$f_i = f_{\min} + (f_{\max} - f_{\min})\beta, \beta \in [0, 1] \quad (9)$$

$$\mathbf{v}_i = \mathbf{v}_i + (\mathbf{x}_i - \mathbf{x})f_i \quad (10)$$

$$\mathbf{x}_i = \mathbf{x}_i + \mathbf{v}_i \quad (11)$$

式中, $\beta \in [0, 1]$ 是一个服从均匀分布的随机向量^[11], \mathbf{x}_i 是当前全局最佳位置。在实际求解过程中,我们可以根据问题的领域大小确定频率 f_i 的取值。在算法开始时,随机地分配一个频率作为当前蝙蝠发出的频率,而且随机分配的频率 $f_i \in [f_{\min}, f_{\max}]$ 。

2.3.2 局部搜索

蝙蝠算法在搜索过程中要先经过一次全局搜索,得到当前的全局最优解。然后,通过对当前全局最优解进行扰动而实施蝙蝠的局部搜索。全局搜索和局部搜索之间的平衡是通过改变响度 A_i 和脉冲发射率 r_i 来实现的。局部搜索时,每只蝙蝠的更新公式为^[11]

$$\mathbf{x}_{\text{new}} = \mathbf{x}_{\text{old}} + \epsilon \mathbf{A}, \epsilon \in [-1, 1] \quad (12)$$

式中, \mathbf{x}_{new} 代表局部搜索后蝙蝠的新位置, \mathbf{x}_{old} 则是蝙蝠的原位置, ϵ 是一个任意数字^[11], 且 $\epsilon \in [-1, 1]$, 由算法事先随机得到。在蝙蝠进行捕食的过程中,当蝙蝠接近猎物时,脉冲发射率提高,而响度会不断地减小,直到最后响度为 0。脉冲发射的响度 A_i 和脉冲发射率 r_i 的更新公式为^[11]

$$A_i = \alpha A_i, \alpha \in [0, 1] \quad (13)$$

$$r_i = r_i [1 - e^{-\gamma}], \gamma \geq 0 \quad (14)$$

式中, α 和 γ 均为常量,为算法开始时,预先指定好的参量,其中算法规定 $\alpha \in [0, 1], \gamma \geq 0$ 。从式中明显可以看出当 $t \rightarrow \infty$ 时, $A_i \rightarrow 0, r_i$ 不变,表现为当蝙蝠现猎物后,蝙蝠就不再会发出声音。

近年来,研究人员将蝙蝠算法与粒子群算法^[17] (Particle Swarm Optimization, PSO) 及和声搜索^[18] (Harmony Search, HS) 等群智能优化算法进行了客观实验比较。实验证明,蝙蝠算法比其它群智能优化算法

更具发展潜力,最主要的原因是蝙蝠算法完美结合这些算法的主要优点,在计算准确度和速度方面明显优于其他算法.因此,本文将采用蝙蝠算法优化高光谱解混的目标函数.

综合目标函数和蝙蝠算法,将本文算法统称为蝙蝠算法优化基于丰度约束的盲源分离(Bat Algorithm-Abundance Constrained Blind Source Separation, BA-CBSS)算法. BA-CBSS引入蝙蝠算法优化目标函数,在可行解空间内寻找最小的适应度值,适应度值越小,说明各分量的相关性越小,从而将不同地物分离开来.由于算法中的蝙蝠群体在每次进化迭代过程不需要再利用所有混合信号样本点重新计算互信息值,即无需知道概率密度函数,因而使得算法的计算量减小,加快了解混速度.

2.4 BA-CBSS 算法的基本流程

针对传统的盲源分离应用于高光谱解混的局限性,根据式(5)~(8)将丰度非负和丰度和为一约束作为盲源分离的目标函数,将高光谱解混转化为最优化问题,引入蝙蝠算法(BA)对式(8)进行优化求解,得到解混矩阵 \mathbf{W} . 利用矩阵 QR 分解理论^[19],对解混矩阵 \mathbf{W}

的搜索等价于对一系列 Gives 矩阵的辨识,将解混矩阵 \mathbf{W} 转化为 Gives 矩阵乘积的形式为^[19]

$$\mathbf{W} = \mathbf{T}_{p-1} \cdots \mathbf{T}_2 \mathbf{T}_1 = \begin{bmatrix} q_{11} & q_{12} & \cdots & q_{1p} \\ q_{21} & q_{22} & \cdots & q_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ q_{p1} & q_{p2} & \cdots & q_{pp} \end{bmatrix} \quad (15)$$

$$\mathbf{T}_1 = \mathbf{T}_{1p} \mathbf{T}_{1,p-1} \cdots \mathbf{T}_{12}; \mathbf{T}_2 = \mathbf{T}_{2p} \mathbf{T}_{2,p-1} \cdots \mathbf{T}_{23}, \cdots; \mathbf{T}_{p-1} = \mathbf{T}_{p-1,p} \quad (16)$$

$$q_{ij}(\theta_1, \theta_2, \cdots, \theta_i, \cdots, \theta_{e_i}) = w_{ij} \quad i = 1, 2, \cdots, P; j = 1, 2, \cdots, P \quad (17)$$

式中, \mathbf{T}_{iq} 是 P 阶旋转矩阵,旋转角度 $\theta \in [0, 2\pi]$,对于 P 个端元的解混问题, \mathbf{W} 为 C_p^2 个 Gives 矩阵的乘积,每个 Gives 矩阵只有一个未知元素 θ ,这个 θ 即本中蝙蝠算法最终搜索的最优位置,因此对解混矩阵 \mathbf{W} 的优化求解问题则转化为对角度向量 θ 的优化求解问题,得到 \mathbf{W} 后根据式(4)得到丰度的估计值,再用混合矩阵除以丰度矩阵的逆从而获取端元矩阵,实现高光谱图像的解混.

本文 BA-CBSS 算法的具体实现流程为

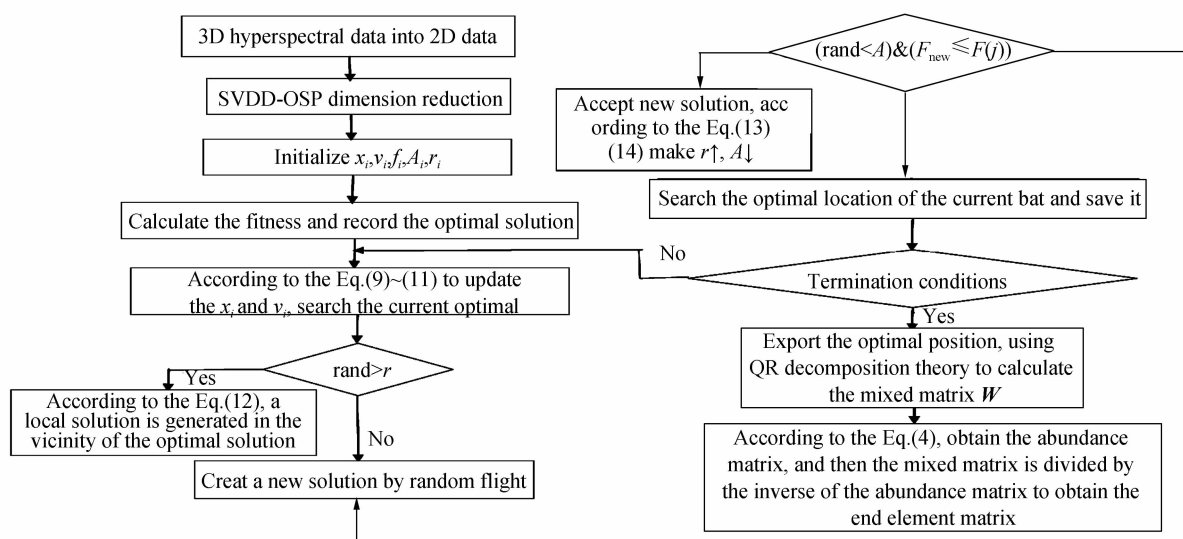


图1 BA-CBSS 算法的流程

Fig. 1 Procedure of BA-CBSS algorithm

3 实验结果与讨论

分别用仿真数据实验及真实遥感数据实验测试算法的性能.实验中,蝙蝠算法的参量设置为:最小频率 $f_{\min} = 0$,最大频率 $f_{\max} = 1$,响度 $A = 0.5$,脉冲频率 $r = 0.5$, $\delta = 0.6$, $\gamma = 0.9$,最小惯性权重 $\omega_{\min} = 0.4$,最大惯性权重 $\omega_{\max} = 0.9$. BA-CBSS 算法的参量统一设置为: $\eta_1 = 50/N$, $\eta_2 = 10/N$.

3.1 仿真数据实验

从美国地质调查局光谱库^[23]中任意选择 5 种地物的光谱作为仿真数据的端元,该光谱库中地物光谱的

波长范围是 395.1 nm~2 650 nm,光谱分辨率为 10 nm,共有 224 个波段.丰度矩阵服从 Dirichlet 分布^[20].图 2 为实验中所用的 5 个端元的光谱及其丰度.

光谱角距离(Spectral Angle Distance, SAD)和均方根误差(Root Mean Square Error, RMSE)两个指标是用来衡量所有算法的结果和真实参考值之间的差异.光谱角距离来表征估计光谱与真实值之间的相似性.对于第 i 个端元,其光谱信号矩阵 $\mathbf{m}_i = [m_{1i}, m_{2i}, \cdots, m_{Li}]^T$,对应的估计参考光谱曲线是 $\hat{\mathbf{m}}_i$, SAD 定义为

$$SAD_i = \arccos \frac{\mathbf{m}_i^T \cdot \hat{\mathbf{m}}_i}{|\mathbf{m}_i^T| |\hat{\mathbf{m}}_i|} \quad (18)$$

均方根误差用于度量丰度解混结果与真实参考值的差


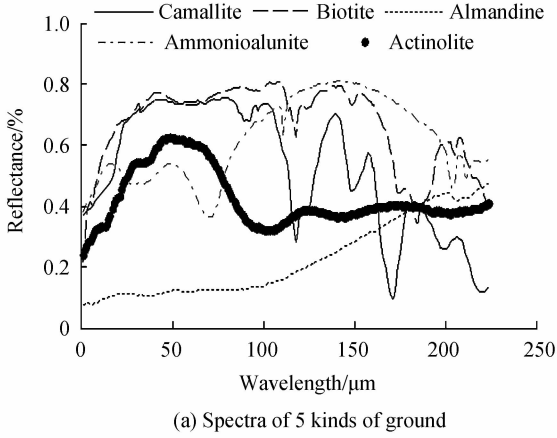


图 2 仿真数据

Fig. 2 Simulation data

异. 对于第 i 个端元, 其丰度矩阵 $\mathbf{s}_i = [s_{i1}, s_{i2}, \dots, s_{iN}]^T$, 对应丰度的估计为 $\mathbf{y}_i = [y_{i1}, y_{i2}, \dots, y_{iN}]^T$, RMSE 定义为

$$RMSE_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (y_{ij} - s_{ij})^2} \quad (19)$$

为了使实验结果更具说服力, 对每次实验进行 20 次仿真并取 SAD 和 RMSE 的平均值来评测算法性能.

仿真数据实验包含三个部分: 1) 分析降维方法对解混结果的影响; 2) 将 BA-CBSS 算法与 VCA^[4]、MVSA^[5] 和 Constrained Non-negative Matrix Factorization (CNMF)^[21] 三种算法进行对比; 3) 将 BA-CBSS 算法与传统的 PSO-CBSS 算法进行性能比较.

3.1.1 降维方法对解混结果的影响

降维方法分别使用传统的 PCA 降维和本文所提的 SVDD-DSP 降维方法. 在此实验中我们改变信噪比的大小, 来比较这两种降维方法的抗噪声性能. 实验数据的信噪比从 ∞ (无噪声)、40 dB 降至 20 dB, 每 5 dB 为一档.

图 3(a) 和图 3(b) 分别给出了采用两种不同降维

方法的 SAD 和 RMSE 指标的变化情况. 随着信噪比的降低, 两种算法的性能在整体上都有所下降. 当 SNR = ∞ , 即无噪声时, 两种降维方法的性能相差不大. 但随着噪声的增加, PCA 降维方法的性能急剧下降, 而 SVDD-DSP 降维方法则表现出良好的抗噪声性能. 下面实验的降维方法均采用 SVDD-DSP 降维.




图 3 不同噪声强度下两种不同降维方法性能的比较
Fig. 3 Comparison of two different dimension reduction method with different noise intensity performance

3.1.2 与其它算法的性能比较

本文算法 (BA-CBSS 算法) 与 VCA^[4]、MVSA^[5]、CNMF^[21] 三种算法进行对比. 其中 VCA 只能提取端元, 因此我们需要在得到端元光谱后, 在此基础上用全约束最小二乘法^[22] (Fully Constrained Least Squares, FCLS) 来求出丰度矩阵, 将这种方法记为 VCA-FCLS 算法. 同样采用 SAD 和 RMSE 两个指标来衡量所有算法的结果与真实参考值之间的差异. 在进行实验测试时, 取所有端元的平均 SAD 和 RMSE 作为评价标准. 通过两个实验评估这几种算法的性能.

1) 测试算法的抗噪声干扰性能. 一般, 在真实遥感图像中并非所有的地物都存在纯像元, 为了让仿真数据接近真实情况, 设定端元的最大纯度为 0.8. 在像元最大纯度相同的条件下 (固定为 0.8), 通过式 (1) 把高斯白噪声加入到仿真数据中, 通过改变所加噪声的强

度,来比较各算法的抗噪声性能.信噪比从 ∞ (无噪声)、40 dB降至 20 dB,步长为 5 dB,以形成不同信噪比的仿真数据.

图 4(a)和图 4(b)分别给出了几种算法在不同信噪比下 RMSE 和 SAD 的变化情况.随着信噪比的下降,所有算法的整体效果都在逐渐变差.从图可以看出,噪声对 CNMF、MVSA 算法的影响很大,而 BA-CBSS 和 VCA-FCLS 抗噪声性能表现良好,BA-CBSS 的解混效果始终是最好的,VCA-FCLS 次之,CNMF 最差.

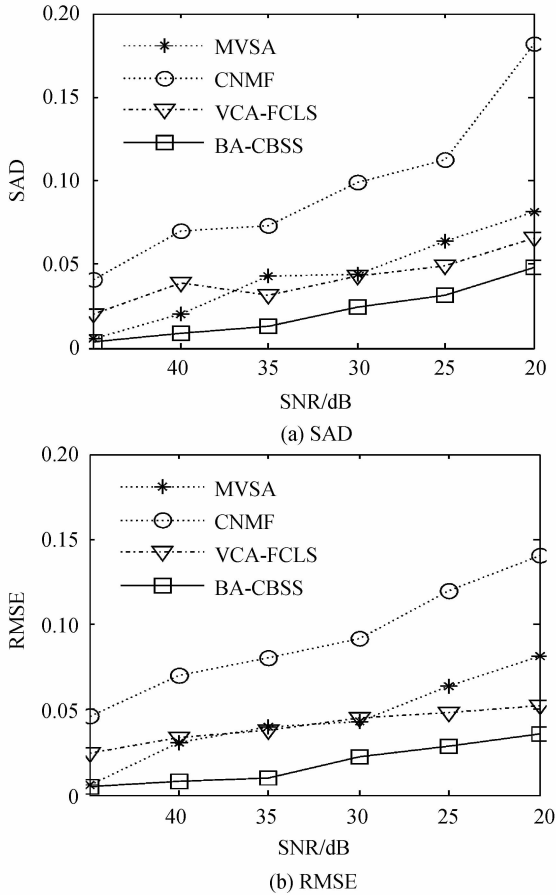


图 4 不同信噪比下不同算法的性能比较
Fig. 4 Comparison of different algorithms with different SNR

2)测试算法对无纯像元存在情况的适应性.在这个实验中,信噪比固定为 35 dB,通过改变像元的纯度,来比较各算法对无纯像元存在的情况下的适应性.让纯度由 1(1 代表数据中存在纯像元)改变到 0.5,每隔 0.1 为一档,以形成不同像元纯度的仿真数据.

图 5(a)和图 5(b)分别给出了几种算法在不同纯像元缺失程度下 SAD 和 RMSE 的变化情况.由图可见,VCA-FCLS 受像元纯度影响最大,主要原因是图像中不存在纯像元时,VCA 只能找到“最纯的像元”来作为端元估计,这降低了算法的有效性.MVSA、CNMF 受像元纯度影响较小,但是它们的解混效果并不理想.

而 BA-CBSS 几乎不受像元纯度的影响,对像元纯度具有良好的鲁棒性,对像元纯度很低的情况也适用.一般,在真实高光谱遥感图像中,像元的纯度并不高,因此 BA-CBSS 对真实高光谱遥感图像的解混具有很好的适应性.这一优点是其他算法所不具备的.

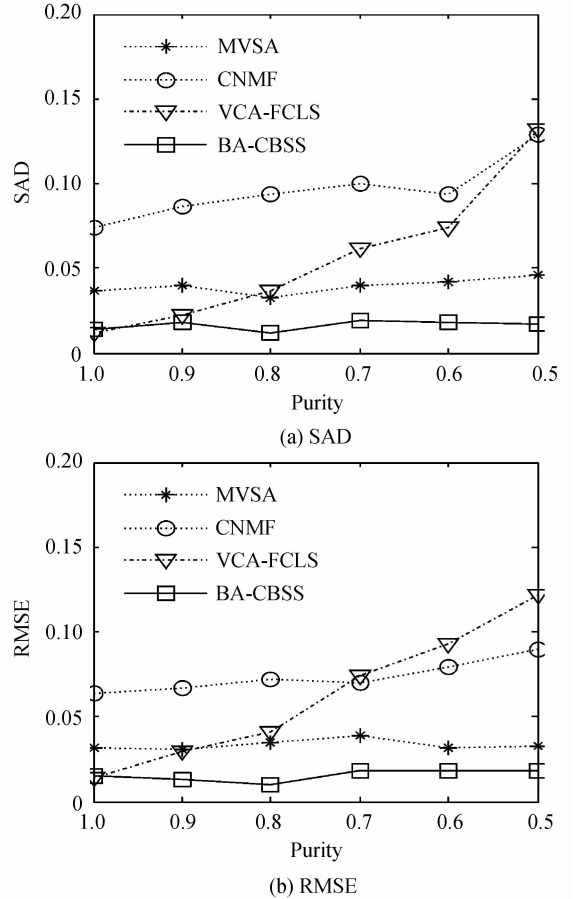


图 5 不同混合度下不同算法性能的比较
Fig. 5 Comparison of different algorithms with different purity

以上实验说明在高光谱图像解混上本文算法优于传统的梯度优化算法.下面实验说明对于同类群智能算法,蝙蝠算法优化目标函数在解混准确度和收敛速度上也明显的优于粒子群优化算法.

3.1.3 同类群智能算法的性能比较

为了更加客观的评价本文算法的解混效果和性能,将本文算法与 PSO-CBSS 算法进行比较.在这个实验中我们改变算法的停止条件,来测试各个算法的收敛性能.粒子群算法^[17]的参量设置为:最大速度 $v_{max} = 3$,最大加权因子 $step_{max} = 0.8$,最小惯性权重 $w_{min} = 0.3$,最大惯性权重 $w_{max} = 0.8$, $c_1 = 2$, $c_2 = 2$. PSO-CBSS 算法的参量设置与 BA-CBSS 算法的相同.通过观察两种算法所得到的 SAD 和 RMSE 值以及算法的收敛图,分析两者的解混准确度和收敛速度以说明本文算法的优势.

1)个体数对算法性能的影响.算法停止的条件固

定为进化代数达到 500 代,通过改变个体数来比较两种算法的性能.个体数从 10 个增至 50 个,每隔 10 个为一档.

图 6(a) 和 (b) 分别给出了两种算法的 SAD 和 RMSE 的变化情况.由图可以看出,在相同的迭代次数下,本文的 BA-CBSS 算法需要较少的个体数就可以达到很高的解混准确度.而 PSO-CBSS 算法解混结果不稳定,即便很大的个体数,其解混准确度也不高.

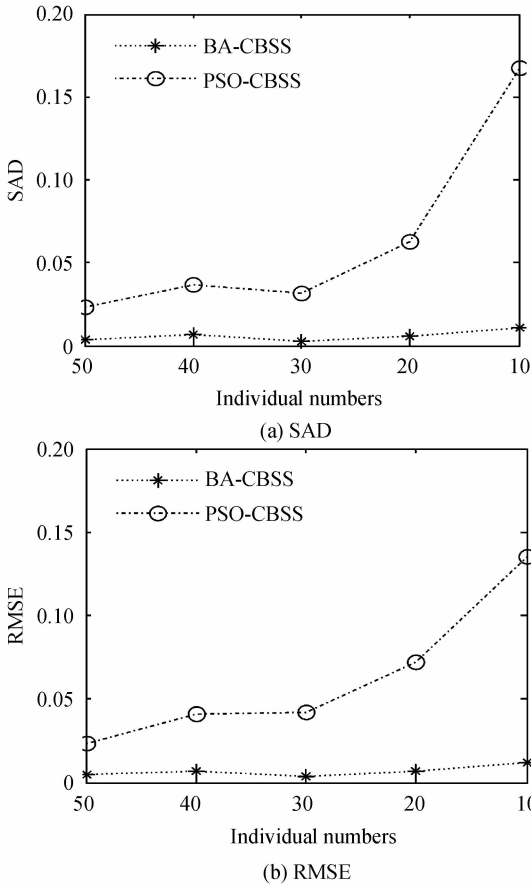


图 6 不同个体数下两种算法性能的比较

Fig. 6 Comparison of two different algorithms with different individual numbers

2) 迭代次数对解混结果的影响.个体数均设置为 30 个,通过改变迭代次数来比较两种算法的性能.迭代数从 500 代降至 100 代,每隔 100 代为一档.

图 7(a) 和 (b) 分别给出了两种算法的 SAD 和 RMSE 的变化情况.由图可以看出,在相同的个体数下,本文的 BA-CBSS 算法需要较少的迭代次数就可以达到很高的解混准确度.而 PSO-CBSS 算法解混结果不稳定,即便很高的迭代次数解混准确度也不高.

3) 算法收敛性分析.计算机仿真实验平台配置为: Intel Core i3 处理器,主频 2.8 GHz; 4GB 内存; Windows 7 旗舰版 6 位 SP1 操作系统, MATLAB R2010b 版本.本文进一步通过比较两种不同算法在相同计算机硬件平台下的收敛图 and 不同迭代次数下的运

行时间,来更加客观地评价算法的收敛速度.

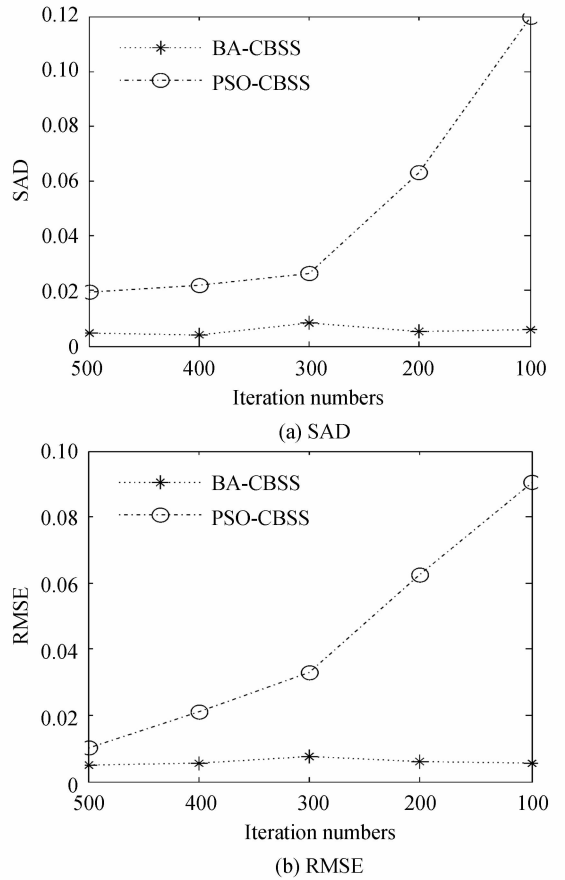


图 7 不同迭代次数下两种算法性能的比较

Fig. 7 Comparison of two different algorithms with different iteration numbers

对比图 8,在相同的条件下,两种算法均采用 30 个个体,本文算法只需迭代 10 次左右,即可达到收敛,实现高光谱的解混,此时的算法只需要 0.940 7 s.而 PSO-CBSS 算法则需要迭代 900 次左右才勉强达到收敛,所需的时间为 22.603 8 s.由此可以看出,新提出的算法具有更高的收敛速度.

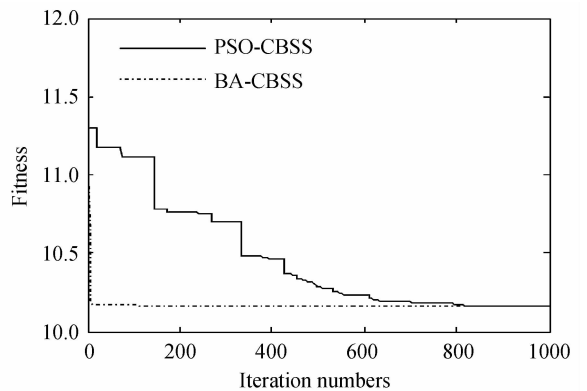


图 8 两种不同算法采用 30 个个体迭代 1000 次时的收敛图比较

Fig. 8 Convergence comparison of two different algorithms with 30 individuals and 1000 iterations

综合 3 个实验,解混性能的提高与新提出的蝙蝠优化算法密切相关.与粒子群算法相比,蝙蝠算法在优化高光谱图像解混时,具有更高的寻优准确度.由实验 3 可知,BA-CBSS 算法所耗的运行时间仅为 PSO-CBSS 算法的 1/24,可见,BA-CBSS 算法在保证了更高的解混准确度的同时,具有更快的收敛速度.与此同时,BA-CBSS 算法解混的稳定性也比 PSO-CBSS 算法有了很大地提高.

3.2 真实遥感数据实验

实验采用了由机载可见光及红外成像光谱仪 (Airborne Visible /Infrared Imaging Spectrometer, AVIRIS) 拍摄于美国印第安纳州 Pine 测试点的 Indiana 数据^[24].它成像于 1992 年 6 月,成像区域为美国印第安那州的派恩遥感测试点,该数据有 220 个波段,波长范围从 0.4~2.5 μm ,光谱分辨率为 10 nm,空间分辨率为 17 nm.实验所用的图像大小为 145 \times 145 像素.在第 70、86、136 波段获取的该数据集的灰色图像如图 9.



图 9 Indiana 数据的灰色图

Fig. 9 Grey figure of Indiana data

数据已被广泛地用于遥感图像的分类研究,覆盖该区域的典型地物包括玉米、大豆、干草堆、树林、草地、公路、石塔和一些房屋.在进行处理之前,该数据的第一~4,103~113 以及 148~166 波段由于信噪比太低或为水吸收波段而被移除,剩下 188 个波段被用于

进一步处理.为定量衡量算法的性能,根据地物真实报告所提供的分布情况对端元进行手动提取,总共提取了 6 个端元光谱,分别对应玉米、树林、大豆、人工建筑、干草堆和草地.

手动提取的端元参考光谱与 BA-CBSS 算法解出的端元光谱比较以及 BA-CBSS 的丰度解混结果如图 11 和图 10.在图 10 中,图像中像元的亮度与相应地物的含量成正比,较亮的像元处含较多的相应地物,例如,component1 中较亮部分含较多的玉米,而其它地物含量较少或没有.从图 11 可以看出,提取的 6 个端

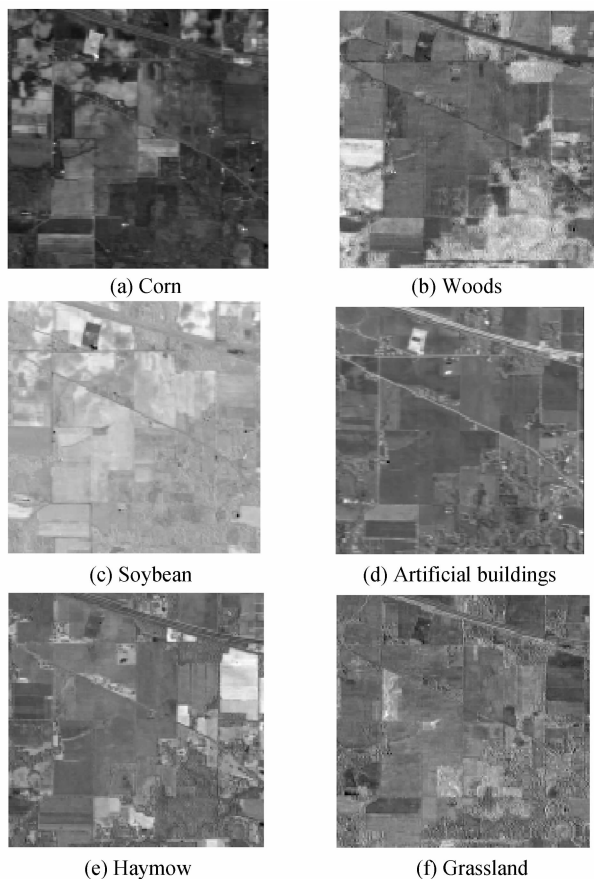



图 10 Indiana 数据的丰度分解结果

Fig. 10 Unmixing results for the Indiana data



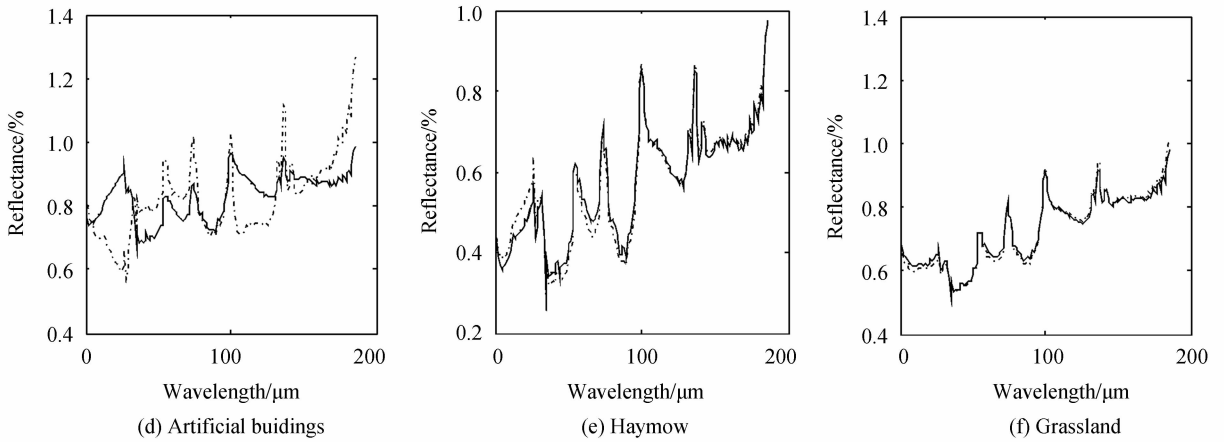


图 11 端元参考光谱与 BA-CBSS 算法解出的光谱比较

Fig. 11 Comparison between the reference spectra and the unmixing spectra with BA-CBSS algorithm

元中,有 5 个端元解混后的光谱曲线与标准光谱基本吻合,还有一个端元的光谱有较大的区别(如图(d)).图(d)是人工建筑,因为人工建筑极易受含水量、阴影等因素的影响,再加上地物和大气散射、地表的粗糙度、坡度等对其的影响,导致了它的端元光谱发生变化,所以用 BA-CBSS 算法解混的结果并不理想.但总体来看,解混的结果与真实分布是较吻合的.为了进一步衡量算法的性能,将手动提取的参考光谱与所有算法解出的光谱进行比较,求出它们的光谱角.

表 1 给出了 BA-CBSS、VCA、MVSA 和 CNMF 四种不同算法解混所得的光谱角,黑色的粗体表示不同算法相比较取得的最好结果.由此可见,BA-CBSS 算法解混的结果明显的优于其他算法.

表 1 Indiana 数据的光谱角比较

Table 1 The comparison of SAD values for Indianan date

	BA-CBSS	VCA	MVSA	CNMF
Corn	0.0339	0.0645	0.2380	0.2952
Woods	0.0228	0.1378	0.4153	0.4052
Soybean	0.0377	0.0751	0.1067	0.3662
Buildings	0.1351	0.1381	0.7508	0.8425
Haymow	0.0125	0.2156	0.3115	0.3262
Grassland	0.0140	0.2156	0.3243	0.2496
Mean	0.0427	0.1145	0.3243	0.4142

4 结论

本文提出的蝙蝠优化基于丰度约束的盲源分离(BA-CBSS)算法,即克服了传统盲源分离算法要求各成分相互独立这个前提的局限性,又解决了传统梯度算法易陷入局部极值的问题.同时,本文提出的基于奇异值分解去噪的正交子空间投影的降维方法能有效的抑制数据的噪声干扰,提高算法的抗噪声能力.仿真实验表明,所提出的算法与现有其他算法相比,解混准确度有了明显提高,而且对噪声干扰和像元纯度低的数据都表现出良好的鲁棒性.对于真实遥感数据实验,也

得到了理想的结果,进一步证实了算法的有效性和对于各种不同数据的适用性.BA 是一种随机搜索算法,牺牲了计算时间换取解混准确度,因此如何改进算法,调整参量以减少计算时间是后续研究的重要方向.

参考文献

- [1] TONG Q, XUE Y, ZHANG L. Progress in hyperspectral remote sensing science and technology in China over the past three decades [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(1): 70-91.
- [2] MA W K, BIOUCAS-D J M, CHAN T H, et al. A signal processing perspective on hyperspectral unmixing: Insights from remote sensing[J]. *IEEE Signal Processing Magazine*, 2014, 31(1): 67-81.
- [3] 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.
- [4] 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.
- [5] LI J, BIOUCAS-DIAS J M. Minimum volume simplex analysis: A fast algorithm to unmix hyperspectral data[J]. *IEEE Geoscience and Remote Sensing Symposium*, 2008, 3(3): 250-253.
- [6] CALLICO G M, LOPEZ S, AGUILAR B, et al. Parallel implementation of the modified vertex component analysis algorithm for hyper-spectral unmixing using openCL [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(8): 3650-3659.
- [7] LI J, AGATHOS A, ZAHARIE D, et al. Minimum volume simplex analysis: a fast algorithm for linear hyperspectral unmixing[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(9): 5067-5082.
- [8] 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.
- [9] COMON P, JUTTEN C. Handbook of blind source separation: independent component analysis and applications [M]. Academic press, 2010, 4(2): 179-420.

- [10] NASCIMENTO J M P, DIAS J M B. Does independent component analysis play a role in unmixing hyperspectral data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(1): 175-187.
- [11] YANG X S. A new metaheuristic bat-inspired algorithm[M]. Nature inspired cooperative strategies for optimization. Springer Berlin Heidelberg, 2010: 65-74.
- [12] JOLLIFFE I. Principal component analysis[M]. John Wiley & Sons, Ltd, 2002.
- [13] ACITO N, DIANI M, CORSINI G. Hyperspectral signal subspace identification in the presence of rare vectors and signal-dependent noise[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **51**(1): 283-299.
- [14] SONG M, CHANG C I. A theory of recursive orthogonal subspace projection for hyperspectral imaging [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(6): 3055-3072.
- [15] WANG N, DU B, ZHANG L, *et al.* An abundance characteristic based independent component analysis for hyperspectral unmixing[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(1): 416-428.
- [16] XIA W, LIU X, WANG B, *et al.* Independent component analysis for blind unmixing of hyperspectral imagery with additional constraints[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **49**(6): 2165-2179.
- [17] EBERHART R C, KENNEDY J. A new optimizer using particle swarm theory [C]. Proceedings of the sixth international symposium on micro machine and human science. 1995, 1: 39-43.
- [18] YANG X S. Harmony search as a metaheuristic algorithm [M]. Music-inspired harmony search algorithm. Springer Berlin Heidelberg, 2009: 1-14.
- [19] TAN He-ren, XIE Sheng-li. Blind separation algorithm based on QR decomposition and penalty function [J]. *Computer Engineering*, 2003, **29**(17): 55-57.
覃和仁, 谢胜利. 基于 QR 分解与罚函数方法的盲分离算法 [J]. 计算机工程, 2003, **29**(17): 55-57.
- [20] 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.
- [21] MIAO L, QI H. Endmember extraction from highly mixed data using minimum volume constrained non negative matrix factorization [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, **45**(3): 765-777.
- [22] 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.
- [23] <http://speclab.cr.usgs.gov/spectral-lib.html>.
- [24] <http://cobweb.ecn.purdue.edu/biehl/Multi-Spec>.