

引用格式: Duan Jinliang, Zhang Rui, Li Kui, *et al.* A Kind of Extended Linear Spectral Unmixing Algorithm based on Noise Level Estimation[J]. Remote Sensing Technology and Application, 2021, 36(4): 820-826. [段金亮, 张瑞, 李奎, 等. 一种基于噪声水平估计的扩展线性光谱分解算法[J]. 遥感技术与应用, 2021, 36(4): 820-826.]
DOI: 10.11873/j.issn.1004-0323.2021.4.0820

一种基于噪声水平估计的扩展线性光谱分解算法

段金亮¹, 张 瑞^{1,2}, 李 奎¹, 庞家泰¹

(1. 西南交通大学 地球科学与环境工程学院测绘遥感信息系, 四川 成都 611756;
2. 西南交通大学 高速铁路运营安全空间信息技术国家地方联合工程实验室, 四川 成都 611756)

摘要: 针对传统的光谱分解算法忽略了影像在不同波段的不同噪声水平, 导致分解精度提高受限。为克服这个问题, 以高光谱影像为基础, 提出了一种基于噪声水平估计的扩展线性光谱分解算法(NELMM)。首先, 根据高光谱应用中的多元回归理论, 估计相邻波段的噪声; 其次, 从估计噪声中获得噪声权重矩阵; 最后, 将噪声权重矩阵引入到线性混合像元的框架中, 可以减轻不同波段噪声水平的影响。为验证算法精度, 利用全约束最小二乘法(FCLS)和协同稀疏分解算法(CLSUnSAL)来进行对比分析, 并通过此算法反演TM影像的植被覆盖度来验证其在多光谱影像上的实用性。结果表明: NELMM算法对高光谱影像分解的结果比FCLS和CLSUnSAL好, 其噪声权重矩阵很好地平衡了波段间的噪声, 使NELMM算法分解影像的精度显著提高; 同时, 此算法对多光谱影像分解呈现很好的适用性。

关键词: 高光谱影像; 植被覆盖度; 噪声权重矩阵; 多光谱影像; 扩展线性光谱分解

中图分类号: TP75 **文献标志码:** A **文章编号:** 1004-0323(2021)04-0820-07

1 引言

高光谱影像(HyperSpectral Image, HSI)是一种被广泛应用的影像, HSI中丰富的光谱信息为不同的应用开辟了新的视角, 如目标检测、光谱分解、对象分类和匹配^[1-3]。对象分类技术的基本假设是每个像元只包含一种物质, 由于成像传感器的空间分辨率不足以及地表的混合效应, 混合像元在HSI中普遍存在, 这使得几种不同的物质共同占据一个像元, 导致对HSI准确解译是困难^[4]。因此, 光谱分解是非常重要的, 因为它旨在计算混合像元中包含的光谱成分(端元)与相应比例(丰度)^[5-6]。

国内外研究者根据端元的先验知识, 将光谱分解大致分为3个主要类别, 即监督式、非监督式和半监督式^[7-10]。监督式的分解算法是估计已知端元的

丰度, 例如全约束最小二乘法(Fully Constrained Least Squares, FCLS)^[8]。非监督的分解方法旨在估计端元及其相应的丰度。一种方法是首先使用端元提取算法^[9]提取端元, 然后通过有监督的分解方法估计其相应的丰度。此外, 可以通过独立分量分析方法^[10]和非负矩阵分解方法^[11]同时估计端元及其对应的丰度。半监督式的分解方法假定可以预先知道混合像元的多种纯光谱特征的线性组合形式, 然后找出最优子集的特征去模拟影像中的混合像元^[12-15], 其中突出的是协同稀疏分解算法(Collaborative Sparse Unmixing by variable Splitting and Augmented Lagrangian, CLSUnSAL)^[16]。然而, 上述算法忽略了HSI在不同波段的噪声水平, 对于真实的影像, 不同波段的噪声水平是不同, 以同样的方式处理所有波段将是不准确, 高噪声水平的波段

收稿日期: 2020-05-10; 修订日期: 2021-06-10

基金项目: 高分辨率对地观测重大专项航空观测系统(30-H30C01-9004-19/21), 四川省科技计划(2018JY0564)。

作者简介: 段金亮(1994—), 男, 四川达州人, 硕士研究生, 主要从事数字图像处理、定量遥感和光谱分解等研究。

E-mail: jinliangduan@my.swjtu.edu.cn

通讯作者: 张 瑞(1982—), 男, 河南新乡人, 博士, 副教授, 主要从事SAR图像处理和定量遥感等研究。E-mail: zhangrui@swjtu.edu.cn

将主宰损失函数 $\| (EA - Y) \|_F^2$, (其中 Y 是影像上的混合像元, E 是端元光谱库, A 是丰度矩阵, $\| \cdot \|$ 是矩阵 Frobenius 范数), 导致整个丰度矩阵的估算将受到严重影响, 这将使得它偏离真值。

因此, 实验提出了一种基于噪声水平估计的扩展线性光谱分解算法 (Noise Estimation Linear Mixing Model, NELMM)。首先, 用 Bioucas 和 Nascimento 提出的基于多元回归理论的噪声估算方法^[17]估算影像的每个波段中的噪声。其次, 所提出的 NELMM 为考虑每个波段的噪声水平构建噪声权重矩阵分别处理每个波段的权重, 即噪声等级越高, 波段的权重越小。噪声权重矩阵可以使 HSI 在不同波段的不同噪声水平之间取得平衡, 从而减小不同波段的噪声水平对分解精度的影响^[7]。最后, 将得到的噪声权重矩阵集成到线性混合模型框架中, 可以使不同波段不同噪声水平下的 NELMM 具有鲁棒性, 同时保证 NELMM 的时间效率。为验证 NELMM 算法对 HSI 的分解精度, 对 Hyperion 影像进行光谱分解, 并利用 FCLS 和 CLSUnSAL 来进行对比分析。同时, 为进一步挖掘 NELMM 算法的适用性, 对 TM 影像进行植被覆盖度反演^[18]来探索该噪声权重矩阵能否对多光谱波段间的噪声进行平衡, 从而能提高其反演精度。

2 试验方法

2.1 全约束最小二乘法

全约束最小二乘法是遥感影像光谱分解时常用的线性光谱分解模型^[8,19], 它认为混合像元中各个端元的丰度就是该像元对应地面上各种地物所占的面积与总面积的比值, 其线性光谱分解模型定义为:

$$y = Ea + n \quad (1)$$

$$\sum_{i=1}^M a_i = 1, a_i \geq 0, \forall i = 1, \dots, M \quad (2)$$

公式(1)中 y 是一个 $D \times 1$ 的像元向量, D 是波段的数目, $E = [e_1, \dots, e_M] \in R^{D \times M}$ 表示端元, M 是端元的数目, $a \in R^{M \times 1}$ 表示丰度向量, n 表示噪声项, 此外丰度应满足两个物理约束(公式(2))。

通常影像中的每个像元被假定为由端元组 E 中的端元构成, 因此公式(1)改写成如下:

$$Y = EA + N \quad (3)$$

其中: $A \in R^{M \times P}$ 表示丰度矩阵, $Y \in R^{D \times P}$ 表示影像矩阵, $N \in R^{D \times P}$ 表示噪声矩阵, P 表示像元总数。

2.2 噪声权重矩阵

以前 HSI 的噪声估计相关的研究^[17,20]已经证明, HSI 的噪声与波长是有一定的相关性, 因此不同波段的噪声水平是存在差异的。然而, 常规的线性光谱分解算法以相同的方式处理所有波段, 忽略不同波段的噪声水平的差异, 这种差异可能导致算法的分解精度降低。这些具有高噪声水平的波段将主宰损失函数 $\| Y - EA \|_F^2$, 并且整个丰度矩阵的估计将受到严重影响, 这使得它偏离了真值, 因此, 以相同的方式对待所有波段是不合适的。为克服上述问题, 采取由 Bioucas 和 Nascimento 提出的一种基于多元回归理论的噪声估算方法^[17], 简单有效地估算影像各个波段的噪声。

定义 $Z_{\sigma_i} = [z_1, \dots, z_{i-1}, z_{i+1}, \dots, z_D]$, $Z = Y^T$ 和 $z_i = [Z]_{:,i}$, 其中 $[Z]_{:,i}$ 表示第 i 列的 Z , 即 z_i 表示 HSI 的第 i 波段的所有像元, 在中假定 z_i 是其余 $D-1$ 波段的线性组合^[17], 表示如下:

$$z_i = Z_{\sigma_i} \beta_i + \zeta_i, i = 1, \dots, D \quad (4)$$

其中: β_i 是回归向量, ζ_i 是建模误差向量。对于每个波段都能够用最小二乘回归法来估算 β_i :

$$\beta_i = \left(Z_{\sigma_i}^T Z_{\sigma_i} \right)^{-1} Z_{\sigma_i}^T z_i, i = 1, \dots, D \quad (5)$$

HSI 每个波段被估计的噪声如下:

$$\zeta_i = z_i - Z_{\sigma_i} \beta_i, i = 1, \dots, D \quad (6)$$

因此估算每个波段的噪声水平如下:

$$\delta_i = \sqrt{\frac{1}{P} \sum_{j=1}^P \zeta_i^2(j)}, i = 1, \dots, D \quad (7)$$

其中: $\zeta_i(j)$ 为影像上的第 i 波段的第 j 个像元的噪声。

在获得每个波段的噪声水平后, 这里使用一种简单有效的权重方案, 即噪声水平越高波段所占权重越大, 噪声水平越低波段所占权重越小, 从而使不同波段的噪声水平达到平衡, 进而减轻不同波段噪声水平的影响, 故构建权重矩阵的对角线元素如下:

$$w_{i,i} = 1/\delta_i, i = 1, \dots, D \quad (8)$$

而非对角线上的元素都为零, 故构建权重矩阵如下:

$$W = \begin{bmatrix} w_{1,1} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & w_{D,D} \end{bmatrix} \quad (9)$$

2.3 基于噪声水平估计的扩展线性混合模型

使用最小二乘算法求解公式(3), 即全约束最

小二乘算法框架^[8],变换公式(3)如下:

$$\min \| (Y - EA) \|_F^2, A \geq 0 \quad (10)$$

在获得噪声权重矩阵后,将噪声权重矩阵引入线性混合模型框架公式(10)中,用来减弱不同波段噪声水平的影响,因此公式(10)改写成如下:

$$\min \| W(Y - EA) \|_F^2, A \geq 0 \quad (11)$$

其中: $\| \cdot \|$ 表示矩阵Frobenius范数,这里使用交替方向乘子法(Alternating Direction Multiplier Method)迭代求解上式的解。

3 试验与分析

3.1 研究区概况

选择新疆玛纳斯河流域和新疆维吾尔自治区天山中段焉耆盆地。焉耆盆地作为新疆农牧业生产的主要基地之一,地处 $85^{\circ}50' \sim 87^{\circ}50' E$, $41^{\circ}40' \sim 42^{\circ}20' N$,海拔1 050~1 200 m,其水土资源丰富,是一个典型的绿洲—荒漠交错地域^[21]。焉耆盆地多年平均气温 $8.4^{\circ}C$,年降水量50~80 mm,年蒸发量2 000.5~2 449.7 mm,光热条件充分,其气候属于南北疆过渡的大陆荒漠性气候^[22]。研究区范围为 $86^{\circ}1' \sim 86^{\circ}5'E$, $42^{\circ}2' \sim 42^{\circ}6' N$,其地块规整,破碎化程度低,高程变化小^[21]。玛纳斯河流域地处新疆准噶尔盆地西南部,位于天山北坡中部、准噶尔盆地南边,该流域年平均气温 $4.7 \sim 5.7^{\circ}C$,年降雨量115~200 mm,年蒸发量1 500~2 100 mm,其光热条件充足,属于温带大陆性干旱气候特征^[23]。研究区范围为 $86^{\circ}2' \sim 86^{\circ}14'E$, $41^{\circ}18' \sim 44^{\circ}26' N$,其植被类型复杂,地块破碎化程度高。

3.2 数据来源及处理

使用的高光谱影像来源于美国USGS网站上获得的L1R格式的Hyperion影像,且使用的TM影像也来源于此网站,同时从网站上分别获得同一时间段的ALI影像,具体信息如表1所示。

表1 研究区影像的信息

Table 1 Information of image in region

影像类型	时间	云量	空间分辨率/m
Hyperion影像	2006.07.18	0~9%	30
ALI影像	2006.07.18	0~9%	10/30
TM影像	2001.08.29	0.07	30
ALI影像	2001.08.27	10%~19%	10/30

采用高空间分辨率的ALI影像作为光谱分解结果的参考真值。首先对ALI影像进行辐射定标将原始灰度值转换为辐射值,其中Gain与Bias系数

参见文献^[24]。然后将ALI影像的30 m分辨率的波段和10 m全色波段进行Gram-Schmit Spectral Sharpening融合,使其具有更高的分辨率(10 m)^[18]。最后,使用研究区的矢量文件裁剪整景ALI影像,获得研究区的ALI影像,如图1(b)和图2所示(波长对应于2.223、0.840、0.485 μm)。

获得研究区的ALI影像后,首先,结合Google Earth对两个研究区ALI影像进行目视判读,获得两个研究区的土地利用类型总体分为未利用地、植被、建筑用地、水体及阴影等4大类。然后,分别选择分类需要的分类样本及验证样本,其中分类样本占研究区域的10%,验证样本占研究区域的5%。再使用ENVI软件中支持向量机算法(Support Vector Machine Algorithm, SVM)对其进行分类和精度验证。最后,通过目视解译的方法来改正SVM分类错误的像元,并且为了使分类后的ALI影像(10 m)与Hyperion影像和TM影像的空间分辨率保持一致,对其使用 3×3 的模板进行像元聚类,使其分辨率重采样为30 m。最终得到焉耆盆地的真实覆盖度影像,如图3所示,并从采样后的玛纳斯地区的分类影像中提取出真实植被覆盖度,如图1(a)所示。

处理完ALI影像获得研究区的参考真值后,再分别对Hyperion影像和TM影像进行预处理,其中Hyperion影像的预处理参考文章^[21]进行波段剔除、坏线修复、条纹去除、辐射定标和大气校正等操作, TM影像的预处理参考文章^[23]进行辐射定标和大气校正等操作。最后,使用研究区的矢量文件分别裁剪预处理完Hyperion和TM,获得研究区域的Hyperion影像和TM影像,如图1(a)、图2(a)所示(波长对应于2.223 μm 、0.840 μm 、0.485 μm)。




图1 焉耆盆地的Hyperion影像和ALI影像

Fig.1 Hyperion Image and ALI Image of Yanqi Basin

对Hyperion影像进行光谱分解前,需要构建端元光谱库,这里使用自动端元束算法从Hyperion影像上获取未利用地、植被、建筑用地、水体及阴影等类别的端元,对异常端元剔除后,最终获取每个类




图2 玛纳斯的TM影像和ALI影像

Fig.2 The TM Image and ALI Image of Manas

别各10个端元,建立如图3所示的端元光谱库。同时,NELMM算法反演植被覆盖度前,也需要构建端元光谱库,使用空间分块自动端元提取算法^[25],从TM影像上提取未利用地、植被、建筑用地、水体及阴影等类别的端元,对异常端元剔除后,最终获取每个类别各10个端元,主要是用来反演植被覆盖度,故其余端元光谱不在此展示,建立如图4所示的植被端元光谱库,其中veg1~veg10表示10种不同的植被。

在获取端元光谱库过后,使用 Matlab 编写




图3 Hyperion 影像的端元光谱库

Fig.3 Endmember Spectral Library of Hyperion Image

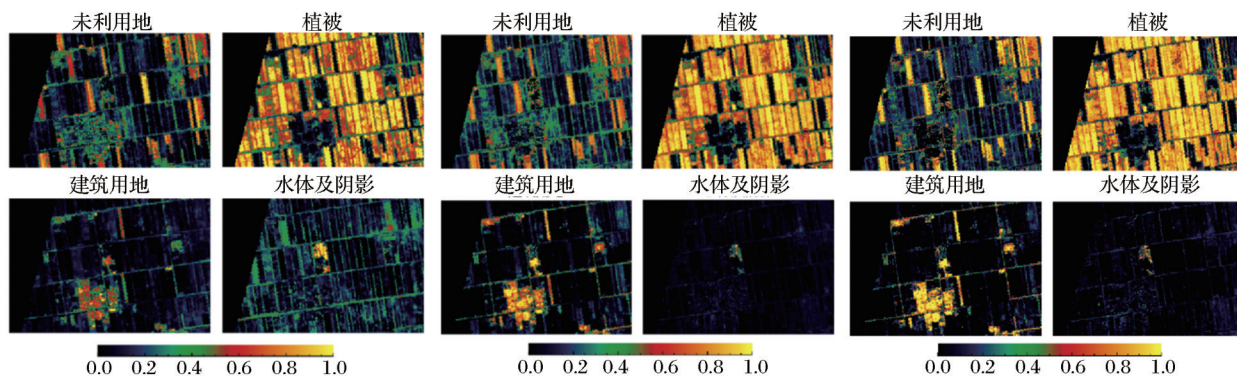


图5 FCLS、CLSUnSAL 和 NELMM 的分解 Hyperion 影像的结果

Fig.5 The Results of Unmixing Hyperion Images of FCLS, CLSUnSAL and NELMM




图4 TM 影像的植被端元光谱库

Fig.4 Vegetation Endmember Spectral Library of TM Image

FCLS、CLSUnSAL 和 NELMM 算法的光谱分解代码对 Hyperion 影像进行光谱分解,获得丰度影像。

3.3 结果与分析

为验证 FCLS、CLSUnSAL 和 NELMM 分解 Hyperion 影像精度,使用经过像元聚合后的 ALI 分类影像作为真值,同时利用均方根误差(RMSE)、相关系数(R)指标来进行精度衡量。针对 FCLS、CLSUnSAL 和 NELMM 分解的结果,按照类别对分解结果进行求和与归一化^[26],其结果分别为图5(a)~5(c)所示,同时其结果的精度指标对比如表2所示。首先,对比图6、图5(a)和5(b),并结合表2指标可知:CLSUnSAL 模型对未利用地、植被、建筑用地的分解效果均优于 FCLS,但是在衡量分解精度的指标数值上差异不大,其值均在 0~0.01 之间波动。其次,对比图3、图6(b)和6(c)可知:NELMM 模型对未利用地、植被、建筑用地的分解效果均优于 CLSUnSAL,同时结合表2分析,NELMM 对未利用地、植被、建筑用地的分解精度明显高于 CLSUnSAL。




图 6 焉耆盆地的地表真实覆盖度
Fig.6 The Real Surface Coverage of Yanqi Basin

最后,对比图 6、图 5 可得,FCLS、CLSUnSAL 和 NELMM 对未利用地、植被、建筑用地分解效果较好,但是对水体及阴影分解结果较差。综上,可以得出 NELMM 对分解 Hyperion 影像精度都要比 FCLS 和 CLSUnSAL 好,且与真实值存在很高的相互一致性,证明了其噪声权重的引入平衡了不同波段间的噪声,提高了分解精度。

为验证 NELMM 算法反演多光谱影像的植被覆盖度的效率,故在电脑配置 Intel(R) Core(TM) i7-9750 CPU@ 2.60 GHz、运行内存 16 GB、显卡 GTX1660ti 和 64 位 windows10 的操作系统下对 TM

影像(500×500×6)进行植被覆盖度反演运算,反演的植被覆盖度如图 7(b)。最终,整个反演运算的时间为 12 s,由此可知 NELMM 算法的时间成本低且效率高。

同时,为验证 NELMM 算法反演的植被覆盖度的精度,利用采样后的 ALI 分类影像作为真实参考值,同时使用 R 和 RMSE 指标来进行精度衡量,通过计算得到 R 和 RMSE 分别为 0.823 6 和 0.220 5。通过对比图 7(a) 和图 7(b),并结合评价指标,NELMM 反演的植被覆盖度的效果与真实的植被覆盖度影像相比,相互一致性很高,其反演的精度高,说明此算法应用在多光谱影像上反演植被覆盖度有明显的优势。




图 7 玛纳斯地区的植被覆盖度
Fig.7 Vegetation Coverage in Manas Region

表 2 FCLS、CLSUNAL 和 NELMM 分解 Hyperion 影像指标对比

Table 2 Comparison of Hyperion Image Indexes of FCLS, CLSUNAL and NELMM Unmixing

指标	R				RMSE			
类别	1	2	3	4	1	2	3	4
FCLS	0.7742	0.7401	0.7527	0.5455	0.2692	0.2337	0.2357	0.1701
CLSUnSAL	0.7832	0.7476	0.7589	0.5466	0.2605	0.2276	0.2282	0.1637
NELMM	0.8139	0.8193	0.8218	0.5674	0.2157	0.2068	0.1817	0.1420

注:类别中的 1 为未利用地、2 为植被、3 为建筑用地、4 为水体及阴影

4 讨 论

NELMM 算法对高光谱影像分解有很好的效果,尤其对大面积地类的分解精度高,而对小面积地类的分解精度相对较低,引入噪声权重矩阵对于平衡高光谱影像中不同波段的噪声是起到正向作用。正是 NELMM 算法考虑了不同波段噪声水平干扰的问题,相当于对光谱分解过程中存在误差项进行分解并控制,这样降低了不可控的总体误差,从而提高了模型的分解精度。同时从对 TM 影像反演植被覆盖度的结果中可以得出噪声权重矩阵对于平衡多光谱影像中不同波段的噪声同样有用,且

多光谱算法在反演植被覆盖度上面有很好的应用市场,其算法精度高且效率快。

5 结 论

研究针对高光谱影像提出一种基于噪声水平估计的扩展线性光谱分解算法,引入噪声权重矩阵来平衡不同波段的不同噪声,从而减轻噪声对分解结果的干扰,通过对 HSI(Hyperion)分解来验证算法精度,同时通过对多光谱影像(TM)进行定量反演来验证该噪声权重矩阵对于提高多波段影像分解精度是否有作用。试验结果表明基于噪声水平估计(NELMM)的稀疏分解算法对 HSI 分解有很高

的精度,同时此算法展现出对基于多光谱影像反演植被覆盖度方面精度高且效率高的优势,并得出如下结论:

(1)NELMM算法对HSI分解的结果比FCLS和CLSunSAL好,且与真值十分接近,其噪声权重矩阵很好地平衡了HSI波段间的噪声,使NELMM算法分解精度显著提高。

(2)NELMM算法对植被覆盖度反演的结果十分接近真实值,证明其噪声权重矩阵对于平衡多光谱影像波段间的噪声是显著的,且此算法精度效率高。

NELMM算法对高光谱影像分解有很好的结果,同时在多光谱影像分解上也展现了很好的适用性,所消耗的时间成本极低。但是NELMM算法仅考虑了不同波段的噪声水平,但是未考虑影像的空间领域信息,在后期的研究中,争取将权重噪声矩阵引入考虑空间领域信息的线性模型框架中来提高影像的分解精度^[27]。

参考文献 (references):

- [1] Williams M D, Parody R J, Fafard A J, *et al.* Validation of abundance map reference data for spectral unmixing [J]. Remote Sensing, 2017, 9:473.DOI: 10.3390/rs9050473.
- [2] Fan H, Chen Y, Guo Y, *et al.* Hyperspectral image restoration using low-rank tensor recovery [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10:4589-4604.
- [3] Li Y, Huang X, Liu H. Unsupervised deep-feature learning for urban village detection from high-resolution remote sensing images [J]. Photogrammetric Engineering and Remote Sensing, 2017, 83: 567-579.
- [4] 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, 5:354-379.
- [5] Liu R, Du B, Zhang L. Hyperspectral unmixing via double abundance characteristics constraints based NMF [J]. Remote Sensing, 2016, 8: 464.DOI: 10.3390/rs8060464.
- [6] Li C, Ma Y, Huang J, *et al.* GBM-Based Unmixing of hyperspectral data using bound projected optimal gradient method [J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 13:952-956.
- [7] Li Chang. Research on key technologies of hyperspectral remote sensing imagery [D]. Wuhan: Huazhong University of Science and Technology, 2018.[李畅. 高光谱遥感影像处理中的若干关键技术研究[D]. 武汉: 华中科技大学, 2018.]
- [8] 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, 39:529-545.
- [9] Nascimento J M, Dias J M. Vertex component analysis: a fast algorithm to unmix Hyperspectral data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43:898-910.
- [10] Nascimento J M, Dias J M. Does Independent component analysis play a role in unmixing Hyperspectral data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43: 175-187.
- [11] Pauca V P, Piper J, Plemmons R J. Nonnegative matrix factorization for spectral data analysis [J]. Linear Algebra and Its Applications, 2006, 416: 29-47.
- [12] Ma J, Jiang J, Liu C, *et al.* Feature guided Gaussian mixture model with semi-supervised EM and local geometric constraint for retinal image registration [J]. Information Sciences, 2017, 417:128-142.
- [13] Akhtar N, Shafait F, Mian A. Futuristic greedy approach to sparse unmixing of hyperspectral data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53: 2157-2174.
- [14] Zhang G, Xu Y, Fang F. Framelet-based sparse unmixing of Hyperspectral images [J]. IEEE Transactions on Image Processing, 2016, 25:1516-1529.
- [15] Iordache M D, Bioucas-Dias J M, Plaza A. Total variation spatial regularization for sparse Hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50: 4484-4502.
- [16] Iordache M D, Bioucas-Dias J M, Plaza A. Collaborative sparse regression for Hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52: 341-354.
- [17] Bioucas-Dias J M, Nascimento J M. Hyperspectral subspace identification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46:2435-2445.
- [18] Zhang Yunxia, Li Xiaobing, Chen Yunhao. Overview of field and multiscale remote sensing measurement approaches to grassland vegetation coverage [J]. Advance In Earth Sciences, 2003, 18(1):85-93.[张云霞, 李晓兵, 陈云浩. 草地植被覆盖度的多尺度遥感与实地测量方法综述 [J]. 地球科学进展, 2003, 18(1):85-93.]
- [19] Xiao Hao, Wang Jie. Comparison between two spectral mixture analysis methods based on IDL and MATLAB [J]. Remote Sensing Technology and Application, 2017, 32(5): 858-865.[肖昊, 王杰. 基于 IDL 和 MATLAB 混合编程的两种光谱混合分析方法比较 [J]. 遥感技术与应用, 2017, 32(5): 858-865.]
- [20] Uss M L, Vozel B, Lukin V V, *et al.* Local signal-dependent noise variance estimation from hyperspectral textural images [J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5:469-486.
- [21] Duan Jinliang, Wang Jie, Wen Xingyue. Comparison analysis between two spectral mixture analysis methods of incorporating

- ing endmember variability [J]. Resource Development and Market, 2017, 33(6):651-655.[段金亮,王杰,文星跃.基于端元变化的两种混合像元分解算法比较研究[J].资源开发与市场,2017,33(6):651-655.]
- [22] Shi Ruihua, Li Xia, Dong Xinguang, *et al.* Research on the relationship between natural vegetation growth and groundwater in Yanqi basin[J]. Journal of Natural Resources, 2009, 24(12):2096-2103.[石瑞花,李霞,董新光等.焉耆盆地天然植被与地下水关系研究[J].自然资源学报,2009,24(12):2096-2103.]
- [23] Duan Jinliang, Wang Jie, Zhang Ting. A kind of vegetation cover fraction retrieval algorithm based on spectral normalization frame[J]. Remote Sensing Technology and Application, 2018, 33(2):252-258.[段金亮,王杰,张婷.一种基于光谱归一化下的植被覆盖度反演算法[J].遥感技术与应用,2018,33(2):252-258.]
- [24] Chander G, Markham B L, Helder D L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors[J]. Remote Sensing of Environment, 2009, 113(5):893-903.
- [25] Wang Jie, Yang Liao, Shen Jinxiang, *et al.* Two endmember extraction algorithms with combined spatial and spectral domain TM image [J], Spectroscopy and Spectral Analysis, 2011, 31(5):1286-1290.[王杰,杨辽,沈金祥,等.两种基于空间与光谱相结合的TM影像端元提取算法[J].光谱学与光谱分析,2011,31(5):1286-1290.]
- [26] Veganzones M A, Drumetz L, Tochon G, *et al.* A new extended linear mixing model to address spectral variability [C]// Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2014, 6(6):1-5
- [27] Xinyu W, Yanfei Z, Liangpei Z, *et al.* Spatial group sparsity regularized nonnegative matrix factorization for Hyperspectral unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55:6287-6304.

A Kind of Extended Linear Spectral Unmixing Algorithm based on Noise Level Estimation

Duan Jinliang¹, Zhang Rui^{1,2}, Li Kui¹, Pang Jiatai¹

(1.Faculty of Geosciences and Environmental Engineering, Southwest Jiaotong University, Chengdu 611756, China;

2.State-Province Joint Engineering Laboratory of Spatial Information Technology of High-Speed Rail Safety, Chengdu 611756, China)

Abstract: The traditional spectral unmixing algorithm ignores the different noise levels of the image in different bands, which leads to the limited accuracy of unmixing. To overcome this problem, based on the hyperspectral imagery, an Extended linear spectral unmixing algorithm based on noise level estimation (NELMM) is proposed. First, according to the multivariate regression theory in hyperspectral applications, the noise in adjacent bands is estimated. Second, the noise weight matrix is obtained from the estimated noise. Finally, the noise weighting matrix is integrated into the linear spectral unmixing framework, which can alleviate the impact of different noise levels at different bands. In order to verify the accuracy of the algorithm, the Fully Constrained Least Squares (FCLS) and Collaborative Sparse Unmixing by variable Splitting and Augmented Lagrangian (CLSUnSAL) are used for comparative analysis, and the vegetation coverage of the TM image is inverted by this algorithm to verify its practicality on multispectral images. The final test results show that the NELMM algorithm is better than the FCLS and CLSUnSAL for the unmixing of hyperspectral images. The noise weight matrix balances the noise between the bands, and the accuracy of the NELMM algorithm for unmixing images is significantly improved. At the same time, this algorithm shows good applicability to multi-spectral image unmixing.

Key words: Hyperspectral image; Vegetation coverage; Noise Weight Matrix; ALI image; Extended Linear Spectral Unmixing