

引用格式:王亚堃,朱荣刚,刘波,等.最小体积约束的高光谱图像分辨率增强算法[J].电光与控制,2019,26(1):38-42. WANG Y K, ZHU R G, LIU B, et al. Hyperspectral image resolution enhancement algorithm with minimum volume constraint[J]. Electronics Optics & Control, 2019, 26(1): 38-42.

最小体积约束的高光谱图像分辨率增强算法

王亚堃^{1,2}, 朱荣刚^{1,2}, 刘波^{1,2}, 李剑茹³

(1. 中国航空工业集团公司洛阳光电设备研究所, 河南 洛阳 471000;

2. 光电控制技术重点实验室, 河南 洛阳 471000; 3. 中国人民解放军61858部队, 西安 710100)

摘要: 针对现有的高光谱多光谱图像融合算法解空间较大、未考虑高光谱数据的物理意义以及存在局部最优的问题,提出了一种基于单形体最小体积约束的耦合非负矩阵分解的高光谱与多光谱图像融合算法(MVC-CNMF)。该算法在混合像元解混的过程中,考虑图像的物理意义,加入了端元单形体最小体积约束。由仿真结果可以看出,该算法能有效地克服现有融合算法中的缺陷,实现了高光谱与多光谱图像的端元与丰度的精确匹配,获得高空间分辨率的融合图像,尤其适用于端元数目较多的高光谱图像。

关键词: 高光谱图像; 空间分辨率; 图像融合; 单形体最小体积约束

中图分类号: TP751 **文献标志码:** A **doi:**10.3969/j.issn.1671-637X.2019.01.009

Hyperspectral Image Resolution Enhancement Algorithm with Minimum Volume Constraint

WANG Ya-kun^{1,2}, ZHU Rong-gang^{1,2}, LIU Bo^{1,2}, LI Jian-ru³

(1. Luoyang Institute of Electro-Optic Equipment, AVIC, Luoyang 471000, China; 2. Science and Technology on Electro-Optic Control Laboratory, Luoyang 471000, China; 3. No. 61858 Unit of PLA, Xi'an 710100, China)

Abstract: The current hyperspectral and multi-spectral image fusion algorithms have such defects as having large solution space, not considering the physical meaning of hyperspectral data, and being prone to local optimal solutions. To solve these problems, a hyperspectral and multi-spectral image fusion algorithm is proposed based on Minimum Volume Constraint and Coupled Non-negative Matrix Factorization (MVC-CNMF). In the process of separating the mixed pixels, the algorithm takes the physical meaning of the image into consideration and adds the minimum volume constraint of the endmember single body. Simulation results show that the proposed algorithm can effectively overcome the defects in the existing fusion algorithms, accurately match the endmember with the abundance of hyperspectral and multi-spectral images, and obtain high-spatial-resolution fused images. This algorithm is especially suitable for the hyperspectral images with a large number of endmembers.

Key words: hyperspectral image; spatial resolution; image fusion; minimum volume constraint

0 引言

高光谱图像是指光谱分辨率较高的图像,可包含上百个精细的连续波段,为地表物质识别、分类与检测提供丰富的光谱信息^[1]。但是,相比于高的光谱分辨率,高光谱图像的空间分辨率较低,其单个像元中会存

在多种地物,导致图像中有混合像元的存在^[2]。因此,如何对高光谱图像进行解混,提高其空间分辨率,已经成为遥感图像研究的首要任务。高光谱图像光谱分辨率很高,包含丰富的光谱信息。相反,多光谱图像虽然光谱分辨率较低,但其空间分辨率较高。所以,可以利用图像融合的思想,将低空间分辨率的高光谱图像与高空间分辨率的多光谱图像相融合,从而获得既具备高图像的光谱特性,又具备较高空间分辨率的融合图像。当前,关于高光谱图像和多光谱图像的研究相对较少。YOKOYA等提出了用于高光谱多光谱图像融合的CNMF算法^[3],该方法单纯考虑图像的物理意义,

收稿日期:2018-07-16 修回日期:2018-12-19

基金项目:航空科学基金(2017ZC13002)

作者简介:王亚堃(1992—),男,山西朔州人,硕士生,研究方向为系统工程。

解空间比较大;SCLSU 算法^[4]的丰度矩阵不满足物理意义的非负性;SFIM 算法^[5]没有考虑丰度矩阵的不相关性,故混合像元分解效果不够精确。

为提高高光谱图像的空间分辨率,且满足融合图像的物理意义,本文在传统 CNMF 算法的基础上,提出了一种基于单形体体积最小约束的高光谱多光谱图像融合算法(MVC-CNMF)。该方法在混合像元耦合解混的过程中,加入单形体最小体积约束,将分别从高光谱图像与多光谱图像提取出的端元矩阵和丰度矩阵进行迭代匹配,获得兼具二者优点的融合图像。

1 高光谱多光谱图像光谱解混与融合

1.1 非负矩阵分解

1999年,LEE和SEUNG在Nature杂志上提出一种基于乘法迭代的非负矩阵分解法(NMF)^[6]。只要初值非负,通过乘法迭代,就可将一个非负矩阵分解为两个非负矩阵之积。

假定有一个非负矩阵 $W \in \mathbf{R}^{m \times n}$,则 NMF 算法就是找到两个矩阵 $H \in \mathbf{R}^{m \times r}$ 和 $U \in \mathbf{R}^{r \times n}$,使得

$$W \approx HU \quad (1)$$

$$\text{s. t. } H \geq 0, U \geq 0$$

其目标函数为 W 与 HU 之间的欧氏距离,当 $W = HU$ 时,达到该目标函数的下界0。目标函数可表示为

$$\min F(H, U) = \frac{1}{2} \|X - HU\|_F^2 \quad (2)$$

$$\text{s. t. } H \geq 0, U \geq 0$$

式中, $\|\Delta\|_F$ 表示 Frobenius 范数,通过梯度下降法可求解迭代公式并优化,即

$$H \leftarrow H \cdot (WU^T) ./ (HUU^T) \quad (3)$$

$$U \leftarrow U \cdot (H^T W) ./ (H^T H U) \quad (4)$$

1.2 基于耦合非负矩阵分解的高光谱多光谱融合算法(CNMF)

多光谱图像的空间分辨率较高,空间分辨率信息主要体现在丰度矩阵上。2012年,YOKOYA等设计了耦合非负矩阵分解算法(CNMF),利用多光谱图像的丰度信息来改善高光谱图像的空间分辨率^[3]。

高空间分辨率高光谱图像 $Y (Y \in \mathbf{R}^{\lambda_h \times L_h})$ 经空间退化与光谱退化可分别得到低空间分辨率的高光谱图像 $Y_H (Y_H \in \mathbf{R}^{\lambda_h \times L_h})$ 与高空间分辨率的多光谱图像 $Y_M (Y_M \in \mathbf{R}^{\lambda_h \times L_h})$,三者之间的关系为

$$Y_H = YS + N_H \quad (5)$$

$$Y_M = RY + N_M \quad (6)$$

式中; $S \in \mathbf{R}^{L_h \times L_h}$ 与 $R \in \mathbf{R}^{\lambda_h \times \lambda_h}$ 分别为空间退化矩阵与光谱退化矩阵; N_H 和 N_M 分别为高光谱图像与多光谱图像的噪声。在本文中, S 和 R 已知。对两种图像进

行混合像元分解,有

$$\begin{cases} Y_H \approx HU_H \\ Y_M \approx H_M U \end{cases} \quad (7)$$

经矩阵退化可得

$$\begin{cases} U_H \approx US \\ H_M \approx RH \end{cases} \quad (8)$$

式中, U_H, H_M 分别为高光谱图像的端元矩阵与多光谱图像的丰度矩阵。

由

$$Y = HU \quad (9)$$

可计算获得融合图像。CNMF 算法迭代公式为^[3]

$$\begin{cases} H \leftarrow H \cdot (Y_H U_H^T) ./ (H U_H U_H^T) \\ U_H \leftarrow U_H \cdot (H^T Y_H) ./ (H^T H U_H) \\ H_M \leftarrow H \cdot (Y_M U^T) ./ (H_M U U^T) \\ U \leftarrow U \cdot (H_M^T Y_M) ./ (H_M^T H_M U) \end{cases} \quad (10)$$

2 基于最小体积约束的 CNMF 高光谱多光谱图像融合算法(MVC-CNMF)

CNMF 算法通过乘性迭代至收敛,可以保证结果的非负性。但是,由于该目标函数为非凸性函数,导致对模型的求解会存在大量局部最优解,因此考虑对 CNMF 加入适当的约束条件。以图像的端元为顶点,包含该图像所有像元的凸面几何体被称为“单形体”^[7]。为使估计端元向单形体中的像元靠近,可以对端元构成的单形体体积进行最小化约束,使得求解空间缩小,结果更符合实际。该算法的终止条件是预先设定的残差临近值,当计算结果残差足够小的时候终止算法。

假设一幅高光谱图像中有 N 个像元, P 种地物,波段数为 L 。目标函数及约束条件可表示为^[7]

$$\min F(H, U) = \frac{1}{2} \|Y_H - HU\|_F^2 + \beta C(H) \quad (11)$$

$$\text{s. t. } H \geq 0, U \geq 0$$

式中; $Y \in \mathbf{R}^{L \times N}$ 是已知的观测数据,在高光谱数据中表示图像的矩阵; $H = (h_1, h_2, \dots, h_n) \in \mathbf{R}^{L \times P}$ 和 $U \in \mathbf{R}^{P \times N}$ 分别为估计的端元矩阵和丰度矩阵; β 为单形体最小体积约束的权值; $C(H)$ 为体积约束项。本文中,通过设置等间隔离散化的参数区间,利用试探法选取较优权值。运算符号 $\|\cdot\|$ 表示 Frobenius 范数,即

$$\|Y - HU\|_F^2 = \sum_{i=1}^L \sum_{j=1}^N (Y_{ij} - (HU)_{ij})^2 \quad (12)$$

式中, $Y_{ij}, (HU)_{ij}$ 表示高光谱图像 Y 中,第 i 个波段里的第 j 个像元的像素信息, Y_{ij} 为其观测值, $(HU)_{ij}$ 为其计算值。

2.1 体积最小化约束

在体积约束项 $C(H)$ 中, 体积的定义用所有端元到单形体中心的欧氏距离表示, 即^[8]

$$C(H) = \sum_{k=1}^m \sum_{j=1}^l (h_{kj} - \frac{1}{m} \sum_{i=1}^m h_i)^2 \quad (13)$$

式中: $\frac{1}{m} \sum_{i=1}^m h_i$ 为单形体的中心; $h_{kj} = (h_{1j}, h_{2j}, \dots, h_{lj})^T$ 为第 j 个端元向量。加入体积约束项后, 对 CNMF 分解混合像元的效果进行比较, 如图 1 所示, 其中, 灰色的点代表图像中的所有像元, 所有估计端元包含在凸面几何体。




图1 加入体积约束前后的 CNMF 混合像元分解效果图
Fig.1 CNMF mixed pixel decomposition effect diagram before and after adding volume constraint

从图 1 可看出, 由于 CNMF 目标函数中最小化近似误差的作用使估计结果向点外部移动, 导致原始 CNMF 估计出的部分端元处于几何体外, 且距离真实端元较远。加入体积约束后, 端元尽可能向像元靠近, 缩小了解空间。本文考虑这种凸面几何体体积约束, 使得混合像元解混效果更准确, 更符合实际高光谱图像的特征。

2.2 MVC-CNMF 融合算法

本文采用最小体积约束的 CNMF 算法对高光谱多光谱图像进行耦合解混, 通过对解混后提取的端元矩阵与丰度矩阵匹配迭代, 从而提高高光谱图像的空间分辨率。算法结构如图 2 所示。

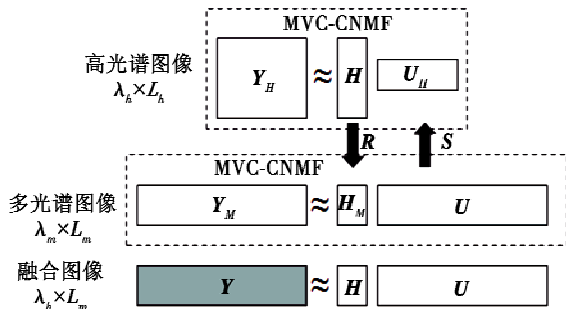


图2 MVC-CNMF 融合算法流程结构图

Fig.2 Flow chart of MVC-CNMF fusion algorithm

根据式(12)推导 MVC-CNMF 算法的乘法迭代式为

$$H \leftarrow H * (Y_H U_H^T) ./ (H H U_H U_H^T + 2\beta (H - \frac{1}{m} \sum_{j=1}^m h_j)) \quad (14)$$

$$U_H \leftarrow U_H * (H^T Y_H) ./ (H^T H U_H) \quad (15)$$

经过偏导, 可计算出该方法的迭代式为

$$H_M \leftarrow H * (Y_M U^T) ./ (H_M U U^T + 2\beta (H_M - \frac{1}{m} \sum_{j=1}^m h_j)) \quad (16)$$

$$U \leftarrow U * (H_M^T Y_M) ./ (H_M^T H_M U) \quad (17)$$

其具体流程如下所述。

1) 高光谱图像解混: 用 VCA 算法提取端元矩阵 H , 通过式(7)初始化丰度矩阵 U_H 。根据式(16)、式(17)迭代分解, 得到端元矩阵 H 和丰度矩阵 U_H ;

2) 对高光谱图像的端元矩阵 H 进行光谱退化, 通过 $H_M \approx RH$ 初始化多光谱图像端元矩阵;

3) 多光谱图像解混: 由式(8)初始化丰度矩阵, 根据式(16)、式(17)迭代分解得到端元矩阵 H_M 和丰度矩阵 U ;

4) 对多光谱图像的丰度矩阵 U 进行空间退化, 通过 $U_H \approx US$ 初始化高光谱图像丰度矩阵;

5) 高光谱图像匹配解混: 根据式(7)初始化端元矩阵 H , 根据式(16)、式(17)迭代分解得到端元矩阵 H 和丰度矩阵 U_H ;

6) 重复步骤 2), 3), 4), 5) 进行高光谱与多光谱图像端元矩阵与丰度矩阵间的匹配, 直至满足初始设置条件;

7) 由 $Y = HU$ 得到具有高空间分辨率和高光谱分辨率的融合图像 Y 。

3 仿真实验与结果分析

3.1 仿真实验数据

仿真实验数据选取美国 AVIRIS 提供的基准高光谱图像数据 92AV3C。该数据采集自美国某地的一块印度松树测试地, 图像像素大小为 145×145 (共 21 025), 有 220 个光谱波段^[9], 图像的空间分辨率约为 20 m。对其进行空间域下高斯下采样并加噪, 可得到符合实际情况的低空间分辨率的高光谱图像 Y_H , 多光谱图像数据 Y_M 也随之确定。本文中, 关键控制参数 β 的数值为 0.0017。

3.2 性能评价指标

为验证融合算法 (MVC-CNMF) 的有效性, 并与现有的相关算法进行对比分析, 本文使用相关系数 (Cross Correlation, CC) 光谱角匹配指数 (Spectral Angle Mapper, SAM) 以及 ERGAS 指数来衡量图像融合效果^[10]。

1) 相关系数 C_c 。相关系数用来衡量融合图像与原始参考图像的相关性。融合图像 Y 与原始参考图像 \hat{Y} 的相关系数定义为

$$C_c(\hat{Y}, Y) = \frac{1}{\lambda_h} \sum_{i=1}^{\lambda_h} C_{CS}(\hat{Y}^i, Y^i) \quad (18)$$

式中, C_{CS} 为单波段图像的相关系数。相关系数越大, 表示融合图像与原始图像相关性越强, 融合效果越好。理想情况下, 相关系数的值为 1。

2) 光谱角匹配指数 S_{AM} 。用来衡量融合图像与原

始参考图像的光谱匹配程度。两幅图像的 S_{AM} 定义为

$$S_{AM}(\hat{Y}, Y) = \frac{1}{n} \sum_{j=1}^n S_{AM}(\hat{y}_j, y_j) \quad (19)$$

式中,

$$S_{AM}(\hat{y}_j, y_j) = \arccos\left(\frac{\langle \hat{y}_j, y_j \rangle}{\|\hat{y}_j\| \|y_j\|}\right) \quad (20)$$

S_{AM} 越小,表示融合图像光谱失真越小,与原始参考图像匹配度越高。理想情况下, S_{AM} 的值为 0。

3) E_{RGAS} 指数。用来评价融合后图像的光谱质量,其定义为

$$E_{RGAS}(\hat{Y}, Y) = 100d \sqrt{\frac{1}{\lambda_h} \sum_{k=1}^{\lambda_h} \left(\frac{R_{MSE_k}}{\mu_k}\right)^2} \quad (21)$$

表 1 不同端元数目情况下各算法性能指标

Table 1 Performance of each algorithm with different endmember number

端元数目	SFIM 算法			SCLSU 算法			CNMF 算法			MVC-CNMF 算法		
	CC	SAM 指数	ERGAS 指数	CC	SAM 指数	ERGAS 指数	CC	SAM 指数	ERGAS 指数	CC	SAM 指数	ERGAS 指数
6	0.9185	4.3653	3.5167	0.9117	4.5805	3.4325	0.8677	5.0123	3.8573	0.8584	5.7426	4.3761
10	0.9274	4.2843	3.4324	0.9438	4.3366	3.3213	0.9042	4.8763	3.5814	0.8745	5.1030	3.8743
20	0.9580	4.2814	3.2666	0.9541	4.2436	3.3022	0.9639	4.1984	2.9635	0.9624	4.1421	2.8429
30	0.9502	4.2765	3.1597	0.9526	4.2283	2.9316	0.9642	4.1207	2.7143	0.9671	4.0935	2.6375
40	0.9535	4.2743	3.1435	0.9557	4.2323	2.8777	0.9646	4.0983	2.6537	0.9672	3.9578	2.5231
50	0.9538	4.2718	3.1472	0.9559	4.2096	2.8241	0.9650	4.0524	2.6341	0.9676	3.9422	2.4415
60	0.9539	4.2700	3.1463	0.9565	4.2017	2.7999	0.9650	3.9745	2.5728	0.9677	3.9327	2.4336
70	0.9541	4.2643	3.0987	0.9601	4.1781	2.7423	0.9650	3.8713	2.5616	0.9678	3.8261	2.4281

增加端元的密度,可以得出各算法的性能指标随端元变化的趋势图,如图 3、图 4、图 5 所示。




图 3 相关系数(CC)

Fig. 3 Cross correlation(CC)




图 4 光谱角匹配指数(SAM)

Fig. 4 Spectral angle mapper (SAM)

式中: d 为常数,是多光谱图像空间分辨率与高光谱图像空间分辨率比值; R_{MSE_k} 为两幅图像第 k 个像素点的均方根误差。 E_{RGAS} 指数越小,表明在光谱范围内,融合图像的光谱质量越好,误差越小。理想情况下 E_{RGAS} 的值为 0。

3.3 实验结果与分析

本文设计了 MVC-CNMF 算法,在混合像元分解时,加入端元单形体体积最小约束,使得融合性能更佳。依次选取端元数目为 10, 20, 30, 40, 50, 60, 70, 将 MVC-CNMF 算法与现有的 CNMF 算法、SFIM 算法以及 SCLSU 算法作性能对比。各算法的性能指标结果如表 1 所示,其中,黑体部分表示在对应条件下各指标的最优值。




图 5 ERGAS 指数

Fig. 5 ERGAS index

由表 1 以及图 3、图 4、图 5 可以看出,在端元数目较少(低于 16)时,现有的 SFIM 算法与 SCLSU 算法在性能指标方面要优于 CNMF 算法与 MVC-CNMF 算法。但是,随着端元数目的增加,CNMF 算法与 MVC-CNMF 算法的相关系数逐渐增大,光谱角匹配指数(SAM)与 ERGAS 指数逐渐变小,在性能指标值方面逐渐占优,均超过 SFIM 算法与 SCLSU 算法,且在本文中提出的 MVC-CNMF 算法效果更好。为了直观地观察与比较分析本文提出的 MVC-CNMF 图像融合算法与现有的融合算法的融合效果,选取提取端元数目为 45,在 1943 nm 波段,将原始参考图像(理解为具有高光谱高空间分辨率的图像)、低空间分辨率的图像以及经过不同算

法融合后的融合图像进行对比分析,如图 6 所示。




图 6 1943 nm 波段原始图像与各算法融合图像

Fig.6 Image in the 1943 nm band region, the original image and fusion image by different algorithms

由图 6 可看出,相比于原始参考图像,未经改善的高光谱图像比较模糊,空间分辨率较低。经各融合算法改进融合后,其空间分辨率得到明显改善,融合图像较好地恢复了原始参考图像的大量信息。而且,可以直观地看出,在各融合图像中,使用本文提出的 MVC-CNMF 算法融合后的图像与原始参考图像最为接近。

4 结论

由于在现有的高光谱多光谱图像融合算法中,存在解空间较大、容易陷入局部最小值以及未考虑高光谱数据的物理特性等问题,使得融合图像的精度比较低。本文结合高光谱图像的物理意义,在 CNMF 的目标函数中加入端元构成的凸面单形体体积最小化约束,提出了一种新的高光谱多光谱图像融合算法(MVC-CNMF)。通过多组真实高光谱数据的对比实验可以看出,与现有的 CNMF, SFIM, SCLSU 等融合算法相比较,随着端元数目的增加,本文算法在混合像元解混方面更为精确,客观性能较优,可获得与原始参考图像更为相似的融合图像。

参考文献

- [1] 浦瑞良,宫鹏. 高光谱遥感及其应用[M]. 北京:高等教育出版社,2000.
- [2] 王楠,张良培,杜博. 最小光谱相关约束 NMF 的高光谱遥感图像混合像元分解[J]. 武汉大学学报:信息科学版,2014,39(1):22-25.
- [3] YOKOYA N, YAIRI T, IWASAKI A. Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(2):528-537.
- [4] ZHANG Y F. Spatial resolution enhancement of hyperspectral image based on the combination of spectral mixing model and observation model[C]//Proceedings of SPIE-the International Society for Optical Engineering, 2014:201-204.
- [5] LIU D, BOUFONOS P T. Dictionary learning based pansharpening[C]//IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2012:2397-2400.
- [6] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization [J]. Nature, 1999, 401(6755):788-791.
- [7] 魏一苇,黄世奇,王艺婷,等. 基于体积和稀疏约束的高光谱混合像元分解算法[J]. 红外与激光工程, 2014,43(4):1247-1254.
- [8] HOYER P O. Non-negative matrix factorization with sparseness constraints [J]. Journal of Machine Learning Research, 2004, 5(9):1457-1469.
- [9] 郭连坤. 基于多核 Boosting 多特征组合高光谱分类技术研究[D]. 西安:西安科技大学,2015.
- [10] WEI Q, BIOUCAS-DIA J M, DOBICEON N, et al. Fusion of multispectral and hyperspectral images based on sparse representation[C]//The 22nd European Signal Processing Conference(EUSIPCO), 2014:1-5.