

基于图像欧氏距离流形降维的端元提取算法

陈居现¹, 杨 磊¹, 唐晓燕^{1,2}

(1. 南阳理工学院 电子与电气工程学院, 河南 南阳 473004;

2. 北京理工大学 光电成像技术与系统教育部重点实验室, 北京 100081)

摘 要:由于多重反射和散射, 高光谱图像中的混合像元实际上是非线性光谱混合传统的端元提取算法是以线性光谱混合模型为基础, 因此提取精度不高针对高光谱图像的非线性结构, 本文提出了基于图像欧氏距离非线性降维的高光谱遥感图像端元提取方法该方法结合高光谱数据的物理特性, 将图像欧氏距离引入局部切空间排列进行非线性降维以更好的去除高光谱数据集中冗余的空间信息和光谱维度信息, 然后对降维后的数据利用寻找最大单形体体积的方法提取端元. 真实高光谱数据实验表明, 提出方法对高光谱图像端元提取具有良好的效果, 性能优于线性降维的主成分分析算法和原始的局部切空间排列算法.

关键词:高光谱图像; 非线性降维; 图像欧氏距离; 局部切空间排列; 端元提取

中图分类号:TP751

文献标志码:A

由于高光谱成像光谱仪空间分辨率的限制以及自然界地物的复杂多样性, 获得的遥感图像的某些像素中往往包含多种地物类型, 即混合像元^[1]. 如何有效地实现混合像元分解, 已经成为遥感研究的一个重要方向. 混合像元分解可以分为两个步骤, 端元提取和丰度估计. 端元提取是混合像元分解的前提, 已有的端元提取算法有: 基于凸面几何学的像元纯度索引, 顶点成分分析, N-FINDR^[2]; 可以同时完成端元提取和丰度估计的迭代误差分析^[3], 最小体积变换, 非负矩阵分解^[4-5]等算法. 这些算法均以线性光谱混合模型为基础, 但是由于地面散射的非线性、最小反射率波长明显的非线性变化、像素内水体变化的衰减作用、一个像素内的多种散射和亚像元成分的异质性等因素, 高光谱数据具有内在的非线性特征^[6-7].

处理高光谱图像非线性的一个策略是进行非线性降维, 流形学习算法可在降维的同时更好地挖掘数据的非线性特性, 已经被成功应用到高光谱图像的非线性特征提取^[8]、分类^[9]、异常检测^[10]、混合像元解混^[11]等方面. 文献[9]将经典流形学习算法等距映射(Isometric Mapping, Isomap)引入高光谱图像处理, 代替主成分分析(Principal Component Analysis, PCA)对高光谱数据进行非线性降维, 获得较好的分类效果. 文献[8]提出利用光谱夹角距离(Spectral Angle Distance, SAD)和光谱信息散度(Spectral Information Divergence, SID)代替欧氏距离与测地线距离相结合对高光谱图像进行特征提取, 获得较好效果. 文献[9]参考 ISOMAP 算法提出了基于测地线距离的最大单形体体积解混算法, 虽然该算法考虑了因为考虑了高光谱数据的非线性, 得到了较好的解混结果, 但算法仅考虑了高光谱图像的光谱特征, 忽略了其空间信息. 本文针对高光谱图像的非线性特征, 结合高光谱图像的空间信息, 采用基于图像欧氏距离的流形学习算法, 对高光谱图像进行非线性降维, 并参考 N-FINDR 算法对降维后的数据进行端元提取.

1 局部切空间排列算法

局部切空间排列算法(Local Tangent Space Alignment, LTSA)^[12]是张振跃等人提出的一种经典的流

收稿日期:2014-10-02;修回日期:2014-12-10.

基金项目:河南省重点科技攻关计划项目(122102210243);光电成像技术与系统教育部重点实验室开放基金(2014J0F0E01).

作者简介(通信作者):陈居现(1974-),男,河南南阳人,南阳理工学院讲师,主要从事数字图像处理研究, E-mail: chen-jx8062@sina.com.

形学习算法. 对于一个给定的数据集 $[x_1, x_2, \dots, x_N], x_i \in R^m, m$ 维, N 点, LTSA 算法可得到其嵌入的低维流形 $y_i \in R^d (d < m)$.

LTSA 的具体算法如下. 1) 为每个点 x_i 构造邻域. 在原始高维输入空间, 通过欧氏距离寻找与每个点最近的 k 个近邻, 记点 x_i 的 k 近邻集合为 $X_i = \{x_{i1}, x_{i2}, \dots, x_{ik}\}$ (包括 x_i 本身). 2) 获取局部切空间坐标. 点 x_i 的局部切空间坐标 $\Theta_i = [\theta_1^{(i)}, \dots, \theta_k^{(i)}]$, 其计算公式为

$$\min \sum_{j=1}^k \|x_{ij} - (\bar{x} + Q\theta_j^{(i)})\|_F^2 = \min \sum_{j=1}^k \|X_i - (\bar{x}1_k^T + Q\Theta)\|_F^2, \quad (1)$$

其中 $\bar{x}_i = \frac{1}{k} \sum_{j=1}^k x_{ij}$, Q_i 为中心化矩阵 $X_i - \bar{x}_i 1_k^T = [x_{i1} - \bar{x}_i, \dots, x_{ik} - \bar{x}_i]$ 最大 d 个奇异值的左奇异向量所构成的矩阵, 公式的最优解为, $\Theta_i = Q_i^T (X_i - \bar{x}_i 1_k^T)$. 3) 获取全局低维嵌入坐标. 令 Y_i 为 X_i 中对应数据点的全局坐标. 首先采用对齐技术, 最小化公式所示的局部对齐误差来对齐局部切空间坐标和全局低维嵌入坐标.

$$E_i = \min_{L_i \in R^{d \times d}} \|Y_i \left(I - \frac{1}{k} 1_k 1_k^T \right) - L_i \Theta_i\|_F^2. \quad (2)$$

2 基于图像欧氏距离流形降维的端元提取算法

2.1 图像欧氏距离矩阵

原始的 LTSA 算法采用的是欧氏距离寻找与每个点最近的 k 个近邻, 被广泛地用于人脸、手写字体等高维数据的特征提取和识别. 但是对于高光谱图像数据, 地物在图像中的分布具有连续性, 每种端元的光谱与其周围的背景像元紧密相关. 根据图像的空间特性, 2005 年 Wang 等^[13] 提出了图像欧氏距离, 它的核心思想是将空间关系引入图像块距离计算中. 文献^[14] 对其改进后将其应用于高光谱图像块之间的距离计算. 对于水平宽度、垂直宽度和波段数分别为 W, H, L 的高光谱数据集 $X \in R^{W \times H \times L}$, 当使用 3×3 的图像块时, 数据点 $x_{l,r} \in R^{L \times 1}$ 和 $x_{p,q} \in R^{L \times 1}$ 之间的图像欧氏距离

$$d(x_{l,r}, x_{p,q}) = \sqrt{\sum_{m=1}^3 \sum_{n=1}^3 \left[\sum_{i=1}^3 \sum_{j=1}^3 g_{ij,mm} (x_{l-2+i, r-2+j} - x_{p-2+i, q-2+j})^T (x_{l-2+m, r-2+n} - x_{p-2+m, q-2+n}) \right]}, \quad (3)$$

其中, $g_{ij,mm}$ 为 9×9 的方阵 G , 如式(4)所示. 其中 t 是空间因子, 表征了空间关系的影响程度. 由于图像距离对 t 并不敏感, 一般可取 $3 \sim 6$.

$$g_{ij,mm} = \exp\left(-\frac{|i-m|^2 + |j-n|^2}{2t}\right). \quad (4)$$

从式(3)和(4)可看出, 图像欧氏距离很好地给出了高光谱图像中以观测像素为中心的 8 邻域之间的距离关系. 在实际应用中, 当地物分布较为集中或呈大片分布时, 此时图像块中的像素之间的空间关系较为显著, 因此空间因子 t 取较小值; 反之, 需选择较大的 t .

2.2 基于图像欧氏距离流形降维的端元提取算法

本文算法利用图像欧氏距离代替 LTSA 中的欧氏距离对高光谱数据进行非线性降维, 并参考 N-FINDR 端元提取算法^[15], 对非线性降维后数据随机选择 p 个像素光谱向量 A_1, A_2, \dots, A_p 构成单形体 $S(A_1, A_2, \dots, A_p)$, 计算单形体体积. 用每个像素依次替换每个当前选择的光谱端元, 如果某个替换能得到更大体积的单形体, 则这次替换被作为有效替换得以保留, 否则作为无效替换而被淘汰, 最终得到 p 个端元.

算法具体步骤如下. 1) 指定端元数目 p , 用上节所述的图像欧氏距离代替 LTSA 算法中的欧氏距离对数据进行降维, 使其维数降至 $p-1$ 维. 2) 在降维后的高光谱数据中, 随机选择 p 个像元 $[x_1, x_2, \dots, x_p]$ 作为候选端元, 并计算端元形成的单体体积 V_1 , 体积计算公式为: $V_1(EB) = \text{abs}(|E|)/(p-1)!$, 其中 $E =$

$$\begin{bmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_p \end{bmatrix}.$$

3) 在降维后高光谱数据其他像元中选择一个像元 P_1 , 取代一个候选端元, 形成新的凸面单体, 计算体积 V_2 , 如 $V_2 > V_1$, 则该像点取代候选端元形成新的候选点. 4) 所有其他像元循环执行步骤(3), 最终形成体积最大的单体, 其顶点对应的降维前的高光谱图像中的像元为所提取的端元.

3 实验结果

本节中,采用实际的高光谱数据测试算法的性能,本文提出的算法与以下两种降维算法进行比较:PCA, LTSA. 降维后的数据,结合 N-FINDR 端元提取算法,通过端元提取精度来评价这 3 种算法的性能. 本文采用 SAD 和平均 SAD, SID, 平均 SID 作为端元提取结果的评价标准,这些参数越小说明端元的估计值与真实值越相似. 所有的算法均运行 10 次,取其均值. 本文中涉及的所有算法均利用 Matlab 2010a,在同一台计算机上实现(Win7 系统、Intel Pentium 处理器 3.0 GHz, 4 GB 内存).

3.1 AVIRIS Cuprite 数据

AVIRIS Cuprite 数据为 1995 年 7 月获取的 Nevada 州 Cuprite 采矿区的数据. 该高光谱图像数据大小为 250×191 , 224 个波段 ($0.4 \sim 2.5 \mu\text{m}$), 空间分辨率和光谱分辨率分别为 20 m 和 10 nm. 本实验从中截取 50×50 大小的子图. 除去存在水气吸收和信噪比较低的波段,实验中使用了 188 个波段. 实验数据的伪彩色图像(R:波段 40, G:波段 28, B:波段 10)如图 1 所示.

用虚拟维度方法^[16]在虚警概率 $P_F = 10^{-6}$ 或者更小时,求出端元个数为 4. 与实地勘测地物分布图相比较,图 1 中主要包含的 4 种矿物成分分别为钙铁榴石、蓝线石、白云母、榍石. 对比美国地质勘探局(USGS)光谱实验室所提供的实地探测分布^[17]及文献^[18]对该地区包含矿物类型的描述,图 1 中主要包含的 4 种矿物成分如表 1 所示. 利用 SAD 和平均 SAD,将 3 种降维算法提取得到的端元光谱与 USGS 光谱库中的对应光谱进行比较,用于确定端元提取结果与光谱库中相应地物光谱的近似程度. 本文算法在端元个数确定后,还包括空间因子 t 和 LTSA 的邻域 k 两个参数,其中 t 为空间因子,根据 3.1 节所述,当地物分布较为集中或呈大片分布时, t 取较大值, AVIRIS Cuprite 数据地物分布较为分散,因此取 $t=3$. 本文对 $k=3 \sim 30$ 之间的值进行实验发现, $k < 10$ 时结果不稳定,但当 k 取 $10 \sim 30$ 时,结果差别不大,因此取 $k=15$. 表 1 为 3 种算法提取的端元结果与 USGS 光谱库中对应光谱的 SAD 和 SID. 从表 1 中看出, LTSA 和本文提出算法由于考虑了高光谱图像的非线性结构,提取结果优于线性降维算法 PCA. 而本文算法在进行非线性降维的同时结合了图像的空间信息,因此得到了最小的平均 SAD 和平均 SID,即与真实光谱曲线最接近. 从表 2 可看出, 3 种算法中 PCA 效率最高, 本文提出算法效率最低. 由于 LTSA 算法本身比较复杂,效率比线性降维的 PCA 算法低,而本文算法在 LTSA 的基础上,将欧式距离改为较为复杂的图像欧氏距离,因此效率低于 LTSA 算法.




图1 AVIRIS Cuprite地区的伪彩色图像

表 1 AVIRIS Cuprite 地区抽取端元光谱与 USGS 光谱库中相应矿物

USGS 矿物	SAD			SID		
	PCA	LTSA	本文算法	PCA	LTSA	本文算法
钙铁榴石	0.147	0.097	0.085	0.0237	0.0095	0.0073
蓝线石	0.139	0.076	0.098	0.0198	0.0094	0.0091
白云母	0.098	0.157	0.101	0.0167	0.0277	0.0136
榍石	0.131	0.138	0.146	0.0184	0.0219	0.0312
平均值	0.130	0.121	0.110	0.0190	0.0220	0.0180

3.2 AVIRIS Indian Pine 数据

AVIRIS Indian Pine 数据的图像光谱范围为 $0.4 \sim 2.5 \mu\text{m}$, 光谱分辨率为 10 nm, 共有 220 个谱段, 空间分辨率为 17 m, 图像大小为 145×145 ^[19]. 去除水吸收谱段, 剩下 202 个谱段被用于进一步处理. 为了减少计算的时间复杂度, 从原始图像左下角截取大小为 70×70 的子图, 其假彩色图像如图 2(a) 所示, 地面的真实值如图 2(b) 所示. 为了定量评价算法的性能, 各端元的参考光谱为根据地物真实分布情况人工从图像中提取得到. 由图 2(b) 可看出, 除了背景外, 共有 6 种端元, 分别对应 Corn-Notill(3)、Grass/pasture(5)、Grass/trees(6)、Soy-Notill(10)、Soy-Mintill(11)、Wheat(13). 在每一类像元的中心处分别抽取 4 个点, 并将其

均值作为该端元的参考光谱。

表2 AVIRIS Cuprite地区的端元提取算法的运行时间

图像大小	程序运行时间/s		
	PCA	LTSA	本文算法
50×50	0.127	1.314	1.715

该实验数据地物分布比较集中,根据3.1所述空间因子选取 $t=3$,对 $k=3\sim 30$ 之间的值进行实验发现 $k<10$ 时结果不稳定,但当 k 取 $10\sim 30$ 时,结果差别不大,因此取 $k=15$ 。比较3种算法得到的端元估计光谱与真实光谱之间的SAD, SID(表3)。本文算法得到的平均SAD

和平均SID均最小,即算法精度最高。从表4可看出,3种算法的中文本算法需要时间最长,PCA算法运行时间最短。本文算法虽然提高了精度,但是由于算法复杂度较高,所以效率较低。

表3 AVIRIS Indian Pine地区抽取端元光谱与真实光谱

端元	SAD			SID		
	PCA	LTSA	本文算法	PCA	LTSA	本文算法
Corn-Notill(3)	0.027	0.057	0.072	0.0041	0.0067	0.0077
Grass/pasture(5)	0.125	0.061	0.146	0.0149	0.0070	0.0159
Grass/trees(6)	0.374	0.209	0.132	0.0414	0.0247	0.0151
Soy-Notill(10)	0.224	0.059	0.172	0.0223	0.0065	0.0183
Soy-Mintill(11)	0.060	0.253	0.065	0.0074	0.0291	0.0072
Wheat(13)	0.056	0.035	0.121	0.0065	0.0049	0.0223
平均值	0.188	0.141	0.124	0.0206	0.0164	0.0154

表4 高光谱图像的端元提取算法的运行时间


图像大小	程序运行时间/s		
	PCA	LTSA	本文算法
70×70	0.16	23.714	26.678

4 结 语

针对高光谱数据的非线性特征,提出了基于图像欧氏距离非线性降维的高光谱遥感图像端元提取方法。该方法结合高光谱数据的物理特性,将图像欧氏距离引入局部切空间排列非线性降维算法中以更好的去除高光谱数据集中冗余的空间信息和光谱维度信息。此算法充分考虑了高光谱图像的非线性结构和图像的空间信息,提高了端元提取的精度。真实高光谱数据实验表明,提出方法对高光谱图像端元提取具有良好的效果,性能优于线性降维PCA和原始的LTSA算法。然而由于采用了图像欧氏距离,使得算法的复杂度增大,如何提高算法效率,有待进一步的研究。

参考文献

- [1] Keshava N, Mustard J F. Spectral unmixing[J]. IEEE Signal Processing Magazine, 2002, 19(1): 44-57.
- [2] Plaza A, Martínez R, Pérez R, et al. A quantitative and comparative analysis of endmember extraction algorithms from hyperspectral data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(3): 650-663.
- [3] Neville R A, Staenz K, Szeredi T, et al. Automatic endmember extraction from hyperspectral data for mineral exploration[C]. Proc 21st Canadian Symposium Remote Sensing, Ottawa, 1999.
- [4] Jia S, Qian Y. Constrained nonnegative matrix factorization for hyperspectral unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(1): 161-173.
- [5] 孙旭光,蔡敬菊,徐铅勇,等.基于非负矩阵分解的高光谱图像混合像元分解[J].光电工程, 2013, 39(12): 97-102.



(a) 伪彩色图像

(b) 地面真实数据

图2 AVIRIS Indian Pine 70×70子图

- [6] 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.
- [7] Bachmann C M, Ainsworth T L, Fusina R A. Exploiting manifold geometry in hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 441-454.
- [8] 杜培军, 王小美, 谭 琨, 等. 利用流形学习进行高光谱遥感影像的降维与特征提取[J]. *武汉大学学报: 信息科学版*, 2011, 36(2): 148-152.
- [9] Chen Y, Crawford M M, Ghosh J. Improved nonlinear manifold learning for land cover classification via intelligent landmark selection[C]. *IEEE Geoscience and Remote Sensing Symposium*, Denver, 2006.
- [10] Ma L, Crawford M M, Tian J. Anomaly detection for hyperspectral images based on robust locally linear embedding[J]. *Journal of Infrared, Millimeter, and Terahertz Waves*, 2010, 31(6): 753-762.
- [11] Heylen R, Burazerovic D, Scheunders P. Non-linear spectral unmixing by geodesic simplex volume maximization[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2011, 5(3): 534-542.
- [12] Zhang Z, Zha H. Principal manifolds and nonlinear dimension reduction via local tangent space alignment [J]. *Journal of Shanghai University (English Edition)*, 2004, 8(4): 406-424.
- [13] Wang L, Zhang Y, Feng J. On the Euclidean distance of images[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(8): 1334-1339.
- [14] 陈宏达, 普哈啉, 王 斌, 等. 基于图像欧氏距离的高光谱图像流形降维算法[J]. *红外与毫米波学报*, 2013, 32(5): 450-455.
- [15] Winter M E. N-FINDR: an algorithm for fast autonomous spectral endmember determination in hyperspectral data[C]. *SPIE's International Symposium on Optical Science, Engineering, and Instrumentation. International Society for Optics and Photonics*, Denver, 1999.
- [16] Chang C I, Du Q. Estimation of number of spectrally distinct signal sources in hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(3): 608-619.
- [17] Swayze G, Clark R, Kruse F, et al. Ground-Truthing Aviris Mapping at Cuprite, Nevada[J]. *United States*, 1992, 47.
- [18] Zortea M, Plaza A. Spatial Preprocessing for Endmember Extraction[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(8): 2679-2693.
- [19] Landgrebe D, Biehl L. Hyperspectral Images[EB/OL]. [2014-09-15]. <https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>.

Image Euclidean Distance-based Manifold Dimensionality Reduction for Endmember Extraction

CHEN Juxian¹, YANG Lei¹, TANG Xiaoyan^{1,2}

(1. School of Electronics and Electrical Engineering, Nanyang Institute of Technology, Nanyang 473004, China;

2. Key Laboratory of Photoelectronic Imaging Technology and System, Ministry of Education of China, Beijing Institute of Technology, Beijing 100081, China)

Abstract: Mixed pixel in hyperspectral image is actually nonlinear mixing of endmembers, which is caused by multiple reflectance and scattering. Since traditional endmember extraction algorithms are based on linear spectral mixture model, they perform poorly in finding the correct endmembers. Considering the physical characters of hyperspectral imagery, a new method is proposed to introduce image Euclidean distance into local tangent space alignment for nonlinear dimension reduction. The proposed methods can discard efficiently the redundant information from both the spectral and spatial dimensions. Endmembers are extracted by looking for the largest simplex volume from low-dimensional space. The experimental results of real image scenes demonstrated that the method outperformed the PCA and LTSA algorithm.

Keywords: hyperspectral imagery; nonlinear dimensional reduction; image Euclidean distance; local tangent space alignment; endmember extraction