



基于 KL-ISOMAP 的高光谱图像彩色可视化

摘要

标志点等距映射(L-ISOMAP)作为一种降维方法,在高光谱图像可视化中极具潜力.针对L-ISOMAP算法标志点代表性不足以及计算代价较高的问题,提出了基于K-medoids聚类算法的改进型L-ISOMAP算法(KL-ISOMAP),进而形成可视化方法.该可视化方法由以下几部分组成:1)通过改进型K-medoids算法选择标志点;2)根据相似度剔除相似像元;3)实现剩余像元的非线性降维;4)完成降维结果的可视化.实验结果表明,KL-ISOMAP算法一方面有效地提高了标志点的内在结构代表性,进而取得了更好的可视化效果;另一方面可通过对相似阈值的设置,加快算法的运算速度.由此形成的可视化方法有着较好的视觉效果、距离保持特性以及像元可分性.

关键词

高光谱数据;彩色可视化;标志点选择;L-ISOMAP算法;NK-medoids算法

中图分类号 TP391.41

文献标志码 A

收稿日期 2017-10-26

资助项目 国家自然科学基金(61675051)

作者简介

王立国,男,教授,博士生导师,研究方向为遥感图像处理、模式识别与机器学习理论.
wangliguo@hrbeu.edu.cn

¹ 哈尔滨工程大学 信息与通信工程学院,哈尔滨,150001

0 引言

高光谱图像(Hyperspectral Imagery, HSI)不仅包含丰富的空间信息,而且包含丰富的光谱信息.面对HSI数百个波段的信息,仅凭人眼观察显然无法直接获取有用信息,因此彩色可视化技术在现实需求下应运而生.彩色可视化超越了以往基于灰度空间的显示方法,可将HSI的丰富信息以更符合人眼视觉系统感知的方法呈现出来.因此,近年来高光谱图像彩色可视化逐步引起国内外学者的重视.现行的彩色可视化的主流方法是各像元对应的高光谱向量降维至某一色彩空间的三数值向量进行显示.

Jacobson等^[1]提出了彩色可视化方法的一系列设计目标和度量标准,加快了HSI彩色可视化领域的发展步伐.目前,最简单的彩色显示方法当属彩色匹配函数法(Color Matching Functions, CMF)^[2],该方法虽然快速、直接,但显示效果较差.因此,通过降维实现HSI彩色可视化成为了主流方法.基于降维实现HSI可视化的方法主要分为特征选择和特征提取.特征选择通过数学变换的方法提取高光谱向量中最重要的光谱特征,而特征提取主要分为线性和非线性2种方法.基于线性特征提取方法有主成分分析(PCA)^[3]、独立成分分析(Independent Component Analysis, ICA)^[4]和投影寻踪(Projection Pursuit, PP)^[5].在很多情况下,由于各数据点在HSI立方体呈稀疏分布状态,因此利用PCA等方法输出的图像往往偏暗^[6].ICA的计算速度要远低于PCA,并且目前仍很难对各主成分的特征排序进行判断^[7],而真实HSI也并非ICA所假设的各成分之间相互独立^[7-8].线性降维方法需要的计算时间较短,但使用的前提是数据的各方面特性皆为线性,这并不完全适用于HSI的可视化^[6].非线性流形学习作为非线性特征提取方法中的一种,通过重构HSI数据内潜在的流形来提取特征,具有较高的计算复杂度^[9].因为非线性结构的存在使得流形学习更适合于HSI数据^[10],因此,本文将致力于通过流形学习实现对HSI数据的彩色可视化.

目前,有许多可行的流形学习方法,诸如等距映射(ISOMAP)^[9]、局部线性嵌入(LLE)^[11]、局部切线空间对齐(LTSA)^[12]、拉普拉斯特征映射(LE)^[13]和自组织映射(SOM)^[14].流形学习假设高维数据从一个流形中均匀采样,并且它试图通过将原始数据集映射到预定义的低维嵌入空间来找到潜在的流形^[9].在上述的方法中,ISOMAP是全

局方法的代表,因为它保留了原始数据的全局几何特征.在应用于 HSI 数据之前,ISOMAP 已被应用于人脸识别、手写数字图像分类和网页图像检索.

ISOMAP 已经以多种方式应用于 HSI 数据. Bachmann 等使用 ISOMAP 来实现 HSI 海洋数据的彩色可视化^[10,15-16]. Chen 等^[17-18]和 Crawford 等^[19]使用 ISOMAP 来提取流形特征,以获得更准确的地物分类结果. Uto 等^[20]研究了一组叶片的光谱分布中的非线性等距流形,并估计了 HSI 数据在叶片数量上的 lambert 参数.上述人员的研究大大提高了 ISOMAP 对 HSI 数据的应用.然而,ISOMAP 方法的计算代价较大,其以 $O(N^3)$ 的速率增加^[9],其中 N 为像元数.因此,即使是处理一个较小的 HSI 数据依旧要耗费较长的运算时间.例如,在 Pentium IV 3.06 GHz 处理器的计算机上,ISOMAP 处理一个大小为 100 像素×100 像素,波段数为 114 的 PROBE2 数据集的 CPU 运行时间达到 920 s^[10].

为了降低 ISOMAP 的计算复杂性, Silva^[21]提出了标志点等距映射(L-ISOMAP).该算法从整个 HSI 数据中随机选择一些像元作为标志点,并在每个像元和标志点之间建立最短路径图,而不是在所有像元之间建立最短路径图.与 ISOMAP 相比,L-ISOMAP 在最短路径图构造和多维标度法(CMDS)的特征值分解中一定程度地降低了算法的复杂度.然而,L-ISOMAP 方法在标志点选择和运算速度方面仍然存在较大的不足.

传统的 L-ISOMAP 在标志点选择上假设光谱空间中的像素均匀分布,因此从 HSI 数据中随机地选择标志点,这与 HSI 数据的实际情况不符.实验表明,光谱空间中的像素是分散的且局部密度变化较大的类簇^[15].在这种情况下,随机选取的标志点主要位于光谱空间内的高密度区域.因此,随机选取的标志点不能代表 HSI 数据的真实几何结构^[22],L-ISOMAP 嵌入会丢失一部分原始数据中的重要信息,从而导致进一步的降维结果受损.因此,根据 HSI 在欧氏空间中的分布情况选择合理标志点对 HSI 的可视化效果将是至关重要的.

针对这一问题,学者们已经提出了一些应对的策略. Bachmann 等提出了 ENH-ISOMAP(增强型等距映射)算法,该算法基于 L-ISOMAP 以增强对较大 HSI 数据的彩色可视化效果^[15]. ENH-ISOMAP 方法的创新主要通过骨架化方法的选择标志点,然而,骨架化方案不能保证所选择的标志点完全覆盖嵌入空

间.此外,该方案不能准确保留高光谱数据的内在几何结构,对流形产生扭曲,这在某种意义上违背了 L-ISOMAP 的初衷.另外, ENH-ISOMAP 使用的策略对于实际应用来说过于复杂.

鉴于上述不足,本文提出了 KL-ISOMAP 的方法.考虑到光谱空间中的像元分散且局部密度变化较大^[15],KL-ISOMAP 使用基于 Num-近邻方差优化的 K-medoids 聚类(NK-medoids)算法^[23]对 HSI 进行聚类,获取的聚类中心将作为标志点进行等距映射,而且可根据各类簇内像元与聚类中心的相似性选取相似像元以加快算法运行速度. NK-medoids 算法根据 HSI 各像元在欧氏空间所处位置的局部分布情况,求取数据的局部方差,然后将像元的局部标准差作为邻域半径,选取局部方差最小且位于不同类簇的像元作为初始中心,然后再利用 K-medoids 完成聚类.初始中心的选取充分利用了方差所提供的 HSI 数据的局部分布信息,以提高聚类精度.实验结果表明,本文提出的 KL-ISOMAP 算法在视觉效果、距离保持特性及像元可分性上优于常用的 L-ISOMAP、PCA 以及 CMF 算法的可视化结果.

1 L-ISOMAP 算法

Silva 和 Tenenbaum 于 2000 年提出 L-ISOMAP 算法^[21]. L-ISOMAP 的目的在于减少运算量同时保持标志点与各像元之间的测地距离. L-ISOMAP 算法从 HSI 数据中随机选取 n 个像元作为标志点,通过 Dijkstra 算法计算标志点与各像元之间的最短路径,进而得到一个大小为 $n \times N$ 的测地距离矩阵.

令向量 $\mathbf{X} = [x_1, x_2, \dots, x_N]^T \in \mathbf{R}^D$, $\mathbf{Y} = [y_1, y_2, \dots, y_N] \in \mathbf{R}^d$, \mathbf{X}, \mathbf{Y} 分别表示 HSI 数据和低维嵌入, N 为像元数目, D 和 d 分别为 HSI 数据波段数和低维空间的维度,其中 $d = 3$. 令标志点集 $\mathbf{X}_L = \{x'_i\}_{i=1}^n \in \mathbf{X}$, $n \leq N$, 标志点和非标志点的低维空间坐标分别记为 \mathbf{Y}_L 和 $\mathbf{Y}_C = \mathbf{Y}/\mathbf{Y}_L$. HSI 基于 L-ISOMAP 算法的可视化主要分为 4 个步骤. 首先,计算各像元之间的欧氏距离,保留像元与最近邻的 K 个像元之间的欧氏距离,与其他点的距离值置为 ∞ ,构建出各像元的邻域图. 然后基于邻域图,利用 Dijkstra 算法^[9]计算随机选取的标志点集 \mathbf{X}_L 与各像元点之间的测地距离矩阵 $\mathbf{D}_{n \times N}$. 再由 CMDS 计算标志点距离矩阵 \mathbf{D}_C 得到标志点的低维嵌入坐标 \mathbf{Y}_L . 最后,利用式(1)求得 \mathbf{Y}_C . 其中 \mathbf{Y}_L^+ 为 \mathbf{Y}_L 的伪逆, $\bar{\mathbf{D}}$ 是测地距离矩阵 $\mathbf{D}_{n \times N}$ 的列均值.

$$Y_C = \frac{1}{2} Y_L^+ (\bar{D} - D_{n \times N}). \quad (1)$$

2 KL-ISOMAP 算法的构建及在可视化中的应用

实验表明,光谱空间中的像元分散且局部密度变化较大^[15].L-ISOMAP 算法随机选取的标志点主要位于高密度区域,无疑会因为像元在光谱空间中局部密度变化较大而使得标志点无法代表 HSI 数据流形的真实几何结构^[22],L-ISOMAP 嵌入会丢失一部分原始数据中的重要信息,从而导致进一步的可视化结果精度的降低和视觉效果的损失.L-ISOMAP 算法相较于 ISOMAP 虽然将最短路径图构造和 CMDS 的计算复杂度从 $O(N^3)$ 和 $O(N^3)$ 分别降至 $O(nN \log N)$ 和 $O(n^2N)$ (n 为标志点数),但用于大型 HSI 数据时的运算量仍然居高不下.鉴于上述不足,本文基于 NK-medoids 聚类算法对 L-ISOMAP 进行改进,提出了 KL-ISOMAP 算法.KL-ISOMAP 算法主要从精度以及运算速度 2 个方面对 L-ISOMAP 进行改进.利用 NK-medoids 算法对高光谱数据聚类,以聚类中心作为标志点,可提高标志点对数据内在结构的代表性,进而提升可视化结果的精度.若依据光谱角距离从各类簇中选择相似像元并予以剔除,则可加快运算速度,而这一优势是 L-ISOMAP 无法达到的.

2.1 NK-medoids 算法

统计理论利用方差来反映数据点分布情况,当数据较为分散时,方差较大,当数据较为集中时,方差较小.文献[24]结果表明,使用每个数据点在局部区域的方差有助于聚类算法区分簇内和簇外的点.因此,利用 Num-近邻方差度量每个像元所处局部区域的像元分布密度的这一测量方式将在数据中选取较接近实际聚类中心的像元作为经典 K-medoids 算法的初始聚类中心.K-medoids 算法的目标函数为最小化各个划分的像元与聚类中心之间的距离,可将无监督数据较好地划分至 K 个类簇中.由于局部方差在聚类中具有的优势,Num-近邻方差将有效提高 K-medoids 算法的聚类效果.

2.1.1 Num-近邻方差的定义

对于像元 x_i ,其局部方差及邻域半径分别如式(2)和式(3)所示,式(4)表示 x_i 的近邻点.

$$F(x_i) = \frac{\sum_{j=1}^{N_{um}} \left[d(x_i, x_j) - \frac{\sum_{j=1}^{N_{um}} d(x_i, x_j)}{N_{um}} \right]^2}{N_{um} - 1}, \quad (2)$$

$$L_i = \sqrt{F(x_i)}, \quad (3)$$

$$n_{\text{neighbor}}(x_i) = \{x_j \mid d(x_i, x_j) \leq L_i\}. \quad (4)$$

2.1.2 基于 NK-medoids 聚类算法的标志点选取

输入 HSI 数据集 X 、距离矩阵、近邻参数 N_{um} 以及类簇数 K ,最终将输出 K 个聚类中心和 K 个类簇.

1) 从 X 数据集中选取初始聚类中心

① 计算每个像元与其他像元之间的欧氏距离,构建距离矩阵 D ,令初始聚类中心点集 $M = \emptyset$.

② 根据式(2)、式(3)以及距离矩阵计算每一像元的局部方差及标准差.

③ 按照局部方差的大小对数据集 X 排序,得到矩阵 X' .

④ 选择当前局部方差最小的像元 x_i 作为初始聚类中心.令 $M = M \cup \{x_i\}$, $X' = X' - \{x_i\}$,即在 X' 中将 x_i 删除.

⑤ 根据式(2)从 X' 中选取与 x_i 的距离小于 L_i 的像元,即获取 x_i 的邻域,再令 $X' = X' - n_{\text{neighbor}}(x_i)$,删除 x_i 的邻域点.

⑥ 转到④,直至 M 中包含 K 个初始聚类中心.

2) 类簇划分

① 逐个比较每一像元与各聚类中心的距离,各像元将划分给相距最近的聚类中心,得到类簇划分.

② 计算类簇划分的聚类误差平方和.

3) 更新聚类中心

在每一类簇中寻找与其他同类簇点距离之和最小的像元,并将其作为新的聚类中心.如果聚类误差平方和不再发生变化,则算法结束,输出最终的聚类中心,否则转至步骤 2)更新类簇划分.

2.2 相似像元的选取

光谱角作为像元之间相似度的衡量指标,光谱角越小,表明像元的相似度越高^[25].光谱角与矢量的模无关,即不受向量本身长度的影响.光谱角对乘性干扰具有良好的抗干扰性且不受光照度条件变化的影响.两光谱之间的夹角越小,说明光谱之间的相似性越大.光谱角可以通过式(5)确定像元 P 和像元 Q 之间的相似性,式中, n 是像元的波段数.在 NK-medoids 算法最终确定各类簇划分中选取光谱角高于相似阈值的像元作为相似像元.相似阈值的设定将在实验部分具体给出.

$$\cos \alpha = \frac{\sum_{i=1}^n P_i Q_i}{\left(\sum_{i=1}^n P_i^2 \right)^{\frac{1}{2}} \left(\sum_{i=1}^n Q_i^2 \right)^{\frac{1}{2}}}. \quad (5)$$

2.3 彩色可视化

首先,构建剔除相似像元后的像元的邻域图,然后基于邻域图和随机选取的标志点集 X_l ,利用 Dijkstra 算法计算标志点与各像元之间的最短路径,通过 CMDS 计算得到低维嵌入坐标 Y ,再将 Y 的 3 个分量分别对应红绿蓝三基色的分量值,最后,将各类簇内被剔除的像元赋予与标志点相同的色彩,最终合成彩色图像,实现对 HSI 的彩色可视化。

3 实验

为了测试本文提出的可视化方法有效性,分别对高光谱数据处理常用的 Pavia University、Moffett、Indiana 和 Salinas 这 4 个数据集进行实验,并将提出的 KL-ISOMAP 算法与传统的 L-ISOMAP 算法、PCA 算法以及 CMF 算法进行比较.实验环境是 AMD core E450 1.65 GHz CPU,2 GB 内存,500 GB 硬盘,Win7 操作系统, MATLAB2014a 应用软件。

3.1 评价标准

3.1.1 距离保持特性

距离保持特性指的是高光谱数据的各高光谱向量间的距离与经过彩色可视化处理后的像元之间的距离尽可能地相关,这一特性由处理前后各像元的距离矩阵的相关系数 ρ 进行度量,其表达式如式(6)所示.相关系数 ρ 的值越趋近于 1,则表示处理结果的距离保持特性越好.当数据较大时,可对数据进行降采样以加快运算速度^[6].

$$\rho = \frac{(X^T Y) / |X| - \bar{X}\bar{Y}}{\text{std}(X) \cdot \text{std}(Y)}, \quad (6)$$

式中, X 为高光谱数据中各个光谱向量间的欧氏距离或光谱角距离构成的距离矩阵, Y 为处理结果在 CIELab 彩色空间下各像元之间的距离矩阵, $|X|$ 为像元数目, \bar{X} 和 \bar{Y} 分别为 X 和 Y 的均值。

3.1.2 像元可分性

可分性指的是结果图像的各像元之间具有较高的对比度,这一特性可由像元之间色彩差异的平均值 δ 表征. δ 的值越大,则说明处理结果的各像元之间的差异越明显,可分性更好,如式(7)所示:

$$\delta = |Y|_1 / |Y|, \quad (7)$$

式中, Y 为处理结果在 CIELab 彩色空间下各像元之间的距离矩阵, $|Y|_1$ 和 $|Y|$ 分别为 Y 的 1 范数和像元数目。

3.2 实验数据描述

Moffett 和 Indiana Pines 数据由美国航天局喷气

推进实验室(NASA 和 JPL)使用 AVIRIS 传感器分别于 1987 年 1992 年采集,空间分辨率为 20 m,光谱分辨率为 10 nm,覆盖从 200~2 400 nm 的光谱范围.本文根据这 2 个数据的噪声从原始的 220 个波段中剔除了 20 个噪声较大的波段进行实验,使用的数据大小分别为 150×150 和 144×144 个像元, Moffett 第 90 波段的灰度图像如图 1a 所示, Indiana Pines 数据的第 30 波段的灰度图像如图 1b 所示。

Pavia University 数据拍摄的是帕维亚大学的高光谱图像,光谱覆盖范围从 430~860 nm,拥有 115 个波段和 1.3 m 的空间分辨率.本文在使用之前去除了 12 个噪声最大的波段,使用剩余的 103 波段进行实验,使用的数据集大小为 150×150 个像元,其第 90 波段的灰度图像如图 1c 所示。

Salinas 数据光谱覆盖范围为 400~2 500 nm,空间分辨率为 3.7 m,包含 204 个有效波段,使用的数据集大小为 86×86 个像元,其第 80 波段的灰度图像如图 1d 所示。

3.3 聚类方法验证

为了更为直观地呈现 NK-medoids 算法在选取标志点上的优势,本文使用一个人工合成的高斯分布二维数据进行了实验.实验结果如图 2 所示,图 2a、2b 分别表示使用随机选取和 NK-medoids 算法选择 30% 的数据点作为标志点的分布情况,可以看出,随机选取的标志点主要位于中部高密度区域,较少位于低密度区域,丢失了数据的部分信息(如蓝色椭圆内的数据点);NK-medoids 算法选取的标志点更加全面,更能代表数据的内在结构,显然比随机选取更加合理。

图 3 和图 4 分别为 Indiana Pines 数据集和 Salinas 数据集地物实际分布的灰度图以及使用 NK-medoids 和 K-medoids 聚类后的结果,表 1 和表 2 分别为聚类结果对应聚类度量指标的数值.从聚类效果以及度量指标的对比上可以看出,NK-medoids 明显优于 K-medoids,应用于 HSI 中的 NK-medoids 与 K-medoids 相比能更好地识别同类地物,因此其聚类中心可以更为有效地表示数据集的整体分布和代表 HSI 数据流形结构。

3.4 HSI 彩色可视化结果对比

对 Pavia University 和 Moffett 数据分别采用 CMF、PCA、L-ISOMAP 以及 KL-ISOMAP 这 4 种方法进行彩色可视化处理,其中 KL-ISOMAP 使用时的相似阈值设定为 1(即未剔除相似像元).其结果如图 5




图1 高光谱数据灰度显示

Fig. 1 Gray scale display of hyperspectral scenes

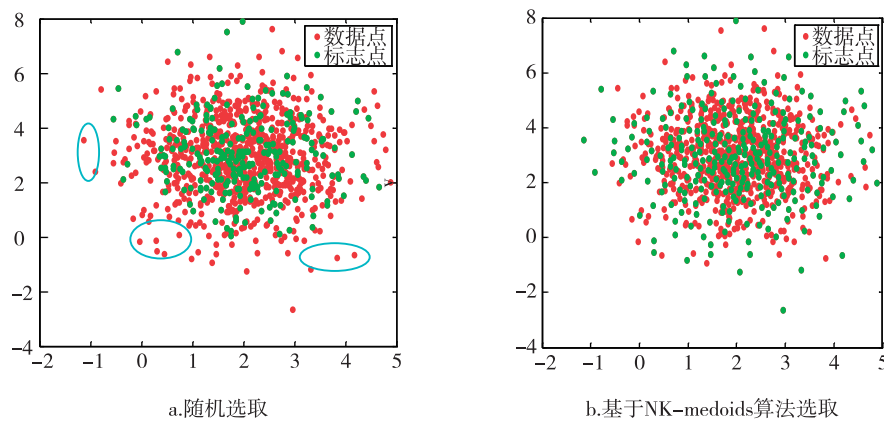


图2 不同方法选取的标志点的分布情况

Fig. 2 Distribution of the landmarks selected by different methods,
(a) random selection, and (b) selection based on NK-medoids algorithm

和图6所示,对应处理结果的距离保持特性和像元可分性分别如表3和表4所示.在L-ISOMAP和KL-ISOMAP应用于Pavia University和Moffett数据时邻域参数 K 分别设置为25和30,标志点数设定为600. NK-medoids算法的Num值设定为200.

使用CMF生成的图5a、图6a可以观察到图像中的光谱相近的类别之间的可分性较差,光谱空间中各类别间的距离未能得到较好的保持.由L-

ISOMAP得到的图5c,从左下方地物的对称分布可知,红色矩形框内原属同类的地物被分配成2种颜色,未能满足距离保持特性;图6c中的道路与右下方的水域被分配为同一颜色,草地的颜色也与原有的颜色相差较大.由KL-ISOMAP得到的图5d相比于由其他方法处理的结果,图像更为清晰明亮,植被之间的差异以及植被内的细节描绘得更加细致,建筑物及由于阳光照射产生的阴影可以直接观察到,

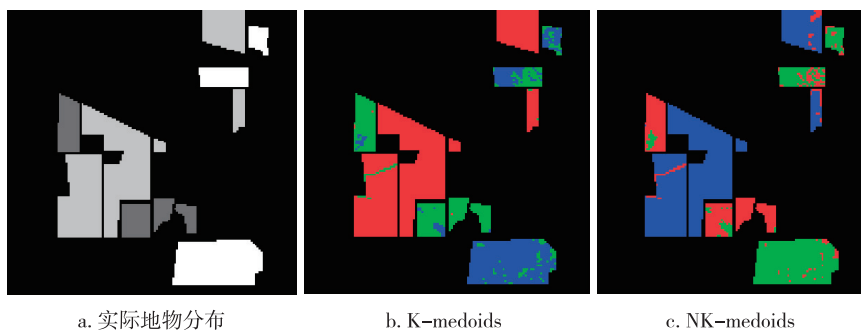


图3 Indiana Pines 数据的聚类效果

Fig. 3 Clustering map of Indiana Pines, (a) distribution of the actual surface features, (b) K-medoids, and (c) NK-medoids




图4 Salinas 数据的聚类效果

Fig. 4 Clustering map of Salinas, (a) distribution of the actual surface features, (b) K-medoids, and (c) NK-medoids

表1 Indiana Pines 数据的聚类度量指标对比

Table 1 Comparison of clustering metrics of Indiana Pines

算法	聚类误差平方和	Jacard Coefficient	Rand Index
K-medoids	$1.968\ 0 \times 10^6$	0.584 3	0.890 4
NK-medoids	$1.536\ 5 \times 10^6$	0.613 5	0.896 1

表2 Salinas 数据的聚类度量指标对比

Table 2 Comparison of clustering metrics of Salinas

算法	聚类误差平方和	Jacard Coefficient	Rand Index
K-medoids	$1.127\ 7 \times 10^6$	0.763 8	0.875 3
NK-medoids	$1.017\ 7 \times 10^6$	0.854 7	0.937 1

表3 各数据距离保持特性结果对比

Table 3 Results contrast in distance preservation of each data

数据	CMF	PCA	L-ISOMAP	KL-ISOMAP
Pavia University	0.697 3	0.805 1	0.810 2	0.874 9
Moffett	0.719 6	0.633 4	0.798 5	0.825 4

表4 各数据像元可分性结果对比

Table 4 Results contrast in feature separability of each data

数据	CMF	PCA	L-ISOMAP	KL-ISOMAP
Pavia University	13.930 7	18.761 1	21.175 3	18.864 7
Moffett	14.165 0	18.870 4	19.925 2	20.594 1

各类地物之间可分性较好,无疑显示效果更优;图6d相比于其他方法处理得到的结果,成功地将对道路与水域之间的差异显示出来,而其他3种方法都将道路与水域混为一体,同时,图6d对建筑和植被的刻画效果也较好。

总而言之,KL-ISOMAP的视觉效果优于CMF、PCA以及L-ISOMAP。在距离保持特性度量上,L-ISOMAP明显优于CMF和PCA,但差于本文提出的KL-ISOMAP方法。在像元可分性方面,KL-ISOMAP略逊于L-ISOMAP,但优于PCA和CMF。

L-ISOMAP对Pavia University和Moffett数据的运算时间分别为1 764 s和1 975 s。本文通过对相似阈值 α 的不同设定来降低KL-ISOMAP实现可视化的运算量。本文对Pavia University和Moffett数据做了11组实验,相似阈值的步进设置为0.01,所得结果如图7所示。从图7的中可以看出,当 α 的取值为0.96时,对Pavia University数据运算时间从1 837 s下降至1 581 s,此时的处理结果的距离保持特性和像元可分性2个指标分别为0.859 4和17.054 5,距离保持特性仍优于L-ISOMAP,且在运算时间上比L-ISOMAP降低了183 s;当 α 的取值小于0.96时,运




图5 不同可视化方法对 Pavia University 数据处理的结果
Fig.5 Results of Pavia University by different visualization methods




图6 不同可视化方法对 Moffett 数据处理的结果
Fig.6 Results of Moffett by different visualization methods

算时间虽有减少,但距离保持特性和像元可分性 2 个指标的值下降严重;当 α 的取值为 0.97 时,对




图7 运算时间及精度随相似阈值的变化

Fig. 7 Change of operating time (a), accuracy (b), and feature separability (c) with similarity thresholds

Moffett 数据运算时间从 2 032 s 下降至 1 817 s, 距离保持特性和像元可分性 2 个指标的值分别为 0.793 1 和 19.462 7, 与 L-ISOMAP 结果的指标值相近且运算时间减少了 158 s; 当 α 小于 0.97 时, 运算时间急剧下降, 运算结果的精度有一定程度的降低. 因此, 相比于 L-ISOMAP, KL-ISOMAP 在衡量指标数值与之相近时, 可有效减少运算时间; 当相似阈值为 1 时 (即无像元被剔除), KL-ISOMAP 整体效果优于 L-ISOMAP.

4 结论

CMF 方法可以快速显示高光谱数据, 但在处理过程中信息损失较多, 处理结果所能提供的信息较为有限. 如今在可视化领域中, PCA 使用广泛但存在较多问题, 例如像元可分性较低及图像亮度较暗等, 虽然在基于欧氏距离时效果较好, 但在使用其他距离标准时效果不佳^[6,26].

本文提出的 KL-ISOMAP 方法弥补了 L-ISOMAP 在标志点选择上的不足, 同时提出了提高运算速度的方法, 相比于其他 3 种方法在像元可分性和距离保持特性上表现出了较好的特性, 其结果图像清晰, 对细节的显示也更为合理. 相比于 CMF 和 PCA 这 2 种线性降维可视化方法, 基于 L-ISOMAP 的非线性降维可视化方法的运算时间较长, 仍需进一步改进.

参考文献

References

- [1] Jacobson N P, Gupta M R. Design goals and solutions for display of hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43 (11): 2684-2692
- [2] Polder G, van der Heijden G W A M. Visualization of spectral images[C] // Proceedings of SPIE the International Society of Optical Engineering, 2001:132-137
- [3] Tyo J S, Konsolakis A, Diersen D I, et al. Principal-components-based display strategy for spectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(3): 708-718
- [4] Du H T, Qi H R, Wang X L, et al. Band selection using independent component analysis for hyperspectral image processing[C] // IEEE Applied Imagery Pattern Recognition Workshop, 2003:93-98
- [5] Jimenez-Rodriguez L O, Arzuaga-Cruz E, Vélaz-Reyes M. Unsupervised linear feature-extraction methods and their effects in the classification of high-dimensional data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(2): 469-483
- [6] Cui M, Razdan A, Hu J X, et al. Interactive hyperspectral image visualization using convex optimization[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(6): 1673-1684
- [7] Cai S S, Du Q, Moorhead R J. Hyperspectral imagery visualization using double layers[J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45 (10): 3028-3036
- [8] Cai S S, Du Q, Moorhead R J. Feature-driven multilayer visualization for remotely sensed hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(9): 3471-3481
- [9] Tenenbaum J B, De Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(5500): 2319-2323
- [10] 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
- [11] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326
- [12] Zhang Z Y, Zha H Y. Nonlinear dimension reduction via local tangent space alignment[C] // International Conference on Intelligent Data Engineering and Automated Learning, 2003:477-481
- [13] Belkin M, Niyogi P. Laplacian Eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6): 1373-1396
- [14] Tamayo P, Slonim D, Mesirov J, et al. Interpreting patterns

- of gene expression with self-organizing maps: Methods and application to hematopoietic differentiation[J]. Proceedings of the National Academy of Sciences, 1999, 96(6):2907-2912
- [15] Bachmann C M, Ainsworth T L, Fusina R A. Improved manifold coordinate representations of large-scale hyperspectral scenes[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(10):2786-2803
- [16] Bachmann C M, Ainsworth T L, Fusina R A, et al. Bathymetric retrieval from hyperspectral imagery using manifold coordinate representations [J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(3):884-897
- [17] Chen Y C, Crawford M M, Ghosh J. Applying nonlinear manifold learning to hyperspectral data for land cover classification [C] // IEEE International Geoscience and Remote Sensing Symposium, 2005, 6:4311-4314
- [18] Chen Y C, Crawford M, Ghosh J. Improved nonlinear manifold learning for land cover classification via intelligent landmark selection [C] // IEEE International Geoscience and Remote Sensing Symposium, 2006:545-548
- [19] Crawford M M, Ma L, Kim W. Exploring nonlinear manifold learning for classification of hyperspectral data [M] // Prasad S, Bruce L M, Chanussot J. Optical Remote Sensing: Advances in Signal Processing and Exploitation Techniques. Berlin: Springer, 2011:207-234
- [20] Uto K, Kosugi Y. Estimation of Lambert parameter based on leaf-scale hyperspectral images using dichromatic model-based PCA [J]. International Journal of Remote Sensing, 2013, 34(4):1386-1412
- [21] Silva V D, Tenenbaum J B. Global versus local methods in nonlinear dimensionality reduction [C] // Proceedings of the 15th International Conference on Neural Information Processing Systems, 2002:721-728
- [22] Sun W W, Halevy A, Benedetto J J, et al. UL-Isomap based nonlinear dimensionality reduction for hyperspectral imagery classification [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 89(2):25-36
- [23] 谢娟英, 高瑞. Num-近邻方差优化的 K-medoids 聚类算法 [J]. 计算机应用研究, 2015, 32(1):30-34
XIE Juanying, GAO Rui. Optimized K-medoids clustering algorithm by variance of Num-near neighbor [J]. Application Research of Computers, 2015, 32(1):30-34
- [24] Ibrahim R, Elbagoury A, Kamel M S, et al. LVC: Local variance-based clustering [C] // IEEE International Joint Conference on Neural Networks, 2016:2992-2999
- [25] 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
DU Peijun, WANG Xiaomei, TAN Kun, et al. Dimensionality reduction and feature extraction from hyperspectral remote sensing imagery based on manifold learning [J]. Geomatics and Information Science of Wuhan University, 2011, 36(2):148-152
- [26] 王立国, 刘丹凤, 赵亮. 具有距离保持特性的高光谱彩色可视化模型 [J]. 应用科学学报, 2013, 31(1):72-78
WANG Ligu, LIU Danfeng, ZHAO Liang. Distance-preserving color visualization model for hyperspectral imagery [J]. Journal of Applied Science, 2013, 31(1):72-78

KL-ISOMAP-based color visualization for hyperspectral imagery

WANG Ligu¹ WU Fei¹

¹ College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001

Abstract Landmark-Isometric mapping (L-ISOMAP), as a dimensionality reduction method, has great potential in hyperspectral imagery visualization. There are two problems in L-ISOMAP algorithm, i.e., the computational cost is high and the landmarks lack of representation for hyperspectral imagery. In this case, an improved L-ISOMAP algorithm, named KL-ISOMAP, is proposed based on K-medoids clustering algorithm. The KL-ISOMAP algorithm consists of the following steps: 1) Selecting the landmarks by the improved K-medoids algorithm; 2) Removing the similar pixels according to the similarity; 3) Implementing the non-linear dimensionality reduction of the rest pixels; 4) Implementing visualization on the reduced dataset. Experimental results show that KL-ISOMAP algorithm can improve the intrinsic structure representation of the landmarks and therefore improve the visualization performance. Furthermore, the algorithm can be speeded up by setting the similarity threshold. The visualization method is reasonable, feasible and of good visual effect, and has good performance in terms of feature distance and class separability preserving for hyperspectral imagery.

Key words hyperspectral dataset; color visualization; landmark selection; L-ISOMAP; K-medoids