

基于二叉树锚点的高光谱快速聚类算法

许裕雄¹, 杨晓君^{1*}, 蔡湧达¹, 杜晓颜², 张鑫¹

¹广东工业大学信息工程学院, 广东 广州 510006;

²中国人民解放军 96630 部队, 北京 102206

摘要 高光谱图像聚类问题一直是图像处理领域的研究热点。谱聚类算法是最流行的聚类算法之一,但其计算复杂度较大,难以处理大规模的高光谱图像数据。由于二叉树能够较快地选取锚点,因此基于二叉树锚点图,充分利用高光谱图像的光谱和空间特性,可保证聚类性能并降低计算复杂度。然而,该聚类算法一般采用有核的聚类方法,因此不可避免地引入了参数调节。在二叉树锚点选取的基础上,提出了一种基于二叉树锚点的高光谱快速聚类算法,该算法创新性地将二叉树锚点选取和无核聚类方法应用于高光谱图像中。首先,利用二叉树从高光谱数据中选取一些具有代表性的锚点;紧接着构造基于锚点的无核相似图,有效避免了通过人为调节热核参数来构造相似图;然后进行谱聚类分析获得聚类结果;最后,将该算法应用到高光谱图像聚类中。该算法不仅提高了聚类速度,还减少了原有热核参数调节。实验结果表明,与传统的聚类算法相比,所提算法能够在较短的时间内获得更佳的聚类精度。

关键词 图像处理; 高光谱图像; 谱聚类; 二叉树; 锚点

中图分类号 TP751

文献标志码 A

doi: 10.3788/LOP202158.0210021

Hyperspectral Fast Clustering Algorithm Based on Binary Tree Anchor Points

Xu Yuxiong¹, Yang Xiaojun^{1*}, Cai Yongda¹, Du Xiaoyan², Zhang Xin¹

¹College of Information Engineering, Guangdong University of Technology, Guangzhou, Guangdong 510006, China;

²Chinese People's Liberation Army 96630 Troops, Beijing 102206, China

Abstract Hyperspectral image clustering has always been a hot topic in the field of image processing. Spectral clustering algorithm, as one of the most popular clustering algorithms, is widely used in hyperspectral image clustering. However, due to the large computational complexity of the spectral clustering algorithm, it is difficult to process large-scale hyperspectral image data. Because the binary tree can select anchor points very fast, the spectral and spatial characteristics of a hyperspectral image are fully utilized to ensure the clustering performance and reduce the computational complexity based on the binary tree anchor graph. However, the clustering algorithm generally adopts the kernel clustering method, therefore it is inevitable to introduce parameter adjustment. Thus, based on the selection of anchor points in the binary tree, we proposes a hyperspectral fast clustering algorithm based on the binary tree anchor graph. This algorithm innovatively applies the method of binary tree anchor selection and coreless clustering to the hyperspectral images. First, the binary tree is used to select some representative anchor points from the hyperspectral data. Second, a coreless similarity map is constructed based on these anchor points, which effectively avoids the artificial adjustment of the thermonuclear parameters to construct the similarity map. Third, the spectral clustering analysis is performed to obtain the clustering results. Finally, this algorithm is used for

收稿日期: 2020-06-19; 修回日期: 2020-07-08; 录用日期: 2020-07-20

基金项目: 科技部重大专项(2018YFB1802100)

*E-mail: yxj029@163.com

hyperspectral image clustering. This algorithm not only improves the clustering speed, but also reduces the necessity of original thermonuclear parameter adjustment. The experimental results show that the proposed algorithm can obtain better clustering accuracy in a shorter time compared with the traditional clustering algorithm.

Key words image processing; hyperspectral image; spectral clustering; binary tree; anchor points

OCIS codes 100.4145; 100.3008; 110.4234

1 引言

高光谱图像(HSI)聚类可以提取许多有价值的聚类信息,被广泛应用于环境监测、精准农业和军事等领域^[1-2]。HSI 聚类目的是将输入的高光谱图像进行划分,使同一组的像素尽可能相似,而不同组的像素彼此相异^[3]。在数据量大和空间结构复杂的情况下,HSI 聚类方法显得十分重要。

近年来,HSI 聚类的研究越来越广泛^[4-5]。目前 HSI 聚类方法主要有 K-means 算法^[6-7]、模糊 c-means 算法(FCM)^[8]、FCM_S1 算法^[9]和谱聚类(SC)算法^[10]等。HSI 聚类能够对任意形状的数据样本进行最优划分,且能够获得较好的聚类精度。SC 算法由于能够获得不错的聚类结果而受到许多学者的关注。SC 算法首先构建亲和图,然后计算相应拉普拉斯矩阵的特征值。SC 算法的计算复杂度为 $O(n^2d + n^2c)$,其中 n 为 HSI 的数量, d 为 HSI 的维度, c 为 HSI 的类别数。随着 HSI 数据量的增长,SC 算法的计算复杂度增大,进而难以有效处理大规模的 HSI 数据^[11]。

针对 SC 算法的计算复杂度问题,一些研究提出了基于锚点的谱聚类方法。首先从 HSI 数据中选取部分具有代表性的数据点,将选出的数据点称为锚点,然后构造基于锚点的相似图并进行谱聚类分析^[12]。文献[13]通过从 HSI 数据中选取随机少量的锚点,有效解决了大规模 HSI 聚类的计算复杂度问题,其计算复杂度为 $O(1)$ 。但随机选取锚点的聚类精度往往较差。文献[14]针对半监督学习数据量较大的问题,提出了利用 K-means 算法选取具有代表性且性能优异的锚点,使锚点能够充分表征整个数据集。但 K-means 算法选取锚点的计算复杂度为 $O(ndmt)$ (其中 t 为迭代次数, m 为锚点数),难于应用在大规模高光谱数据中^[15]。

目前,针对二叉树算法在图像处理方面的应用,许多学者进行了广泛的研究。文献[16]针对大数据库中图像索引维度灾难问题,提出了一种基于云的大规模图像检索技术。该方法利用主成分分析法对帧特征进行降维处理,并使用二叉树表征降维后的特征以实现图像检索。文献[17]针对图像中的椒盐

噪声抑制,提出了一种新的滤波算法。该算法借助 K-means 聚类将当前像素所在邻域的灰度进行有效划分,然后构建噪声污染像素的识别规则,借助多层二叉树决策,实现不同类型噪声污染像素的检测。文献[18]提出了一种快速谱聚类方法。该方法首先采用基于分层 K-means 的平衡 K-means 算法构造基于锚点的相似图,有效处理了大规模的数据集,最后进行聚类分析。上述二叉树算法的应用都取得了良好的效果,但在大规模高光谱图像中的应用研究鲜有报道。

针对上述问题,本文提出了一种基于二叉树锚点的高光谱快速聚类(FHC-BTA)算法。该算法创新性地将二叉树锚点选取和无核聚类的方法应用于高光谱图像中。FHC-BTA 算法提高了聚类速度,其计算复杂度为 $O(ndm)$,大大降低了 SC 算法的计算复杂度,并且减少了热核参数调节。通过 Indian Pines 数据集和 Salinas 数据集的仿真,验证了 FHC-BTA 算法能够有效处理大规模高光谱图像。

2 基本原理

2.1 基于二叉树选取锚点

假设从 HSI 数据中选取 m 个锚点,基于二叉树选取锚点的目标函数^[18]为

$$\min_{G \in \text{Ind}, \mathbf{1}^T G = [\kappa, \iota]} \|\mathbf{X} - \mathbf{G}\mathbf{C}^T\|_F^2, \quad (1)$$

式中: \mathbf{X} 为 HSI 数据, $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_n]^T \in \mathbb{R}^{n \times d}$,其中 \mathbf{x}_i 为矩阵 \mathbf{X} 的第 i 个行向量; \mathbf{C} 为聚类中心矩阵, $\mathbf{C} \in \mathbb{R}^{n \times 2}$; \mathbf{G} 为由 0 和 1 所组成的指示矩阵, $\mathbf{G} \in \mathbb{R}^{n \times 2}$,当矩阵元素 $g_{i1} = 1$ 时,第 i 个 HSI 数据点被划分到第一个簇,当矩阵元素 $g_{i2} = 1$ 时,第 i 个 HSI 数据点被划分到第二个簇; \mathbf{I} 为单位矩阵; κ, ι 为逐次选取生成的簇样本数,其中 $\kappa + \iota = n$,为了使生成簇中的 HSI 数据量相等,当 n 为偶数时, $\kappa = \lfloor \frac{n}{2} \rfloor$,当 n 为单数时, $\kappa = \lfloor \frac{n-1}{2} \rfloor$; $\mathbf{1}$ 为元素均为 1 的矩阵; $\|\cdot\|_F$ 为 F 范数。为了方便求解,(1)式可以转化为

$$\min_{G \in \text{Ind}, \mathbf{1}^T G = [\kappa, \iota]} \sum_{i=1}^n \sum_{r=1}^2 \|\mathbf{x}_i - \mathbf{c}_r\|_2^2 g_{ir}, \quad (2)$$

式中: $\|\cdot\|_2$ 为二范数; \mathbf{c}_r 为矩阵 \mathbf{C} 的第 r 列; g_{ir} 为

矩阵 \mathbf{G} 的第 i 行第 r 列的元素。为了简化计算,假设矩阵 $\mathbf{E} \in \mathbb{R}^{n \times 2}$, 则矩阵 \mathbf{E} 的第 i 行第 r 列元素表示为 $e_{ir} = \| \mathbf{x}_i - \mathbf{c}_r \|_2^2$, 那么(2)式的矩阵表达式为

$$\min_{\mathbf{G} \in \text{Ind}, \mathbf{1}^T \mathbf{G} = [\kappa, \kappa]} \text{Tr}(\mathbf{E}^T \mathbf{G}), \quad (3)$$

式中: $\text{Tr}(\cdot)$ 表示求矩阵的迹。 \mathbf{g}_r 为矩阵 \mathbf{G} 的第 r 列, 因为矩阵 \mathbf{G} 由 0 和 1 所组成, 因此矩阵 \mathbf{G} 的另一列为 $(1 - \mathbf{g}_r)$, 则(3)式化简为

$$\min_{\mathbf{1}^T \mathbf{g}_r = \kappa} \mathbf{g}_r^T \mathbf{e}_1 + (\mathbf{1} - \mathbf{g}_r)^T \mathbf{e}_2, \quad (4)$$

式中: $\mathbf{e}_1, \mathbf{e}_2$ 分别为矩阵 \mathbf{E} 的第一列和第二列。(4)式合并为

$$\text{argmin}_{\mathbf{1}^T \mathbf{g}_r = \kappa} (\mathbf{e}_1 - \mathbf{e}_2)^T \mathbf{g}_r. \quad (5)$$

对含行标签的 $(\mathbf{e}_1 - \mathbf{e}_2)$ 的元素按从小到大进行排序, 取前 κ 个元素所对应的行标签。因为 $(\mathbf{e}_1 - \mathbf{e}_2)$ 与 \mathbf{g}_r 均为 n 行且一一对应, 所以(5)式的解是 \mathbf{g}_r 中与 κ 个行标签所对应的元素为 1。因此, 矩阵 $\mathbf{G} = [\mathbf{g}_r, 1 - \mathbf{g}_r]$, 接着对矩阵 \mathbf{C} 的列向量进行模糊 K-means 聚类以获得两个子聚类的中心, 子聚类的中心点即为锚点, 获得的锚点表征着各自簇的特性。通过(5)式最终选取了 m 个锚点, 锚点矩阵为 $\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_j, \dots, \mathbf{u}_m]^T \in \mathbb{R}^{m \times d}$, 其中 \mathbf{u}_j 为矩阵 \mathbf{U} 的第 j 个行向量。基于二叉树选取锚点的计算复杂度为 $O[nd(\log_m t)]$, 其中 $m \ll n$ 。图 1 所示为二叉树选取锚点示意图。




图 1 二叉树选取锚点示意图
Fig. 1 Schematic of selecting anchor points for binary tree

2.2 基于锚点的无核相似图

通常采用基于核的邻近分配方法构造相似图。在基于核的邻近分配方法中, 高斯核函数为 $K(\mathbf{x}_i, \mathbf{u}_j) = \exp(-\| \mathbf{x}_i - \mathbf{u}_j \|_2^2 / 2\sigma^2)$, 其中 σ 为热核参数^[19]。基于核的邻近分配方法引入了热核参数, 需要人为调参。为了避免这个问题, 本文采用一种有效的无核邻近分配方法来构造基于锚点的无核相似图。假设 HSI 数据与锚点的邻接矩阵 $\mathbf{Z} \in \mathbb{R}^{n \times m}$, z_{ij} 为矩阵 \mathbf{Z} 的第 i 行第 j 列的元素, 表示第 i 个数据点与第 j 个锚点的相邻关系^[20]。 z_{ij} 的定义为

$$\min_{\mathbf{z}_i^T \mathbf{1} = 1, z_{ij} \geq 0} \sum_{j=1}^m \| \mathbf{x}_i - \mathbf{u}_j \|_2^2 z_{ij} + \gamma z_{ij}^2, \quad (6)$$

式中: \mathbf{z}_i^T 为矩阵 \mathbf{Z} 的第 i 行向量; γ 为正则化参数。文献[21]证明了(6)式为无核邻近分配方法。 \mathbf{x}_i 与 \mathbf{u}_j 的欧氏距离的平方为 $d(\mathbf{x}_i, \mathbf{u}_j) = \| \mathbf{x}_i - \mathbf{u}_j \|_2^2$, 正则化参数为 $\gamma = \frac{k}{2} d(i, k+1) - \frac{1}{2} \sum_{j=1}^k d(i, j)$, (6)式的解为

$$z_{ij} = \frac{d(i, k+1) - d(i, j)}{kd(i, k+1) - \sum_{j=1}^k d(i, j)}, \quad (7)$$

式中: k 为近邻数据点的数量。

相似度矩阵 \mathbf{A} ^[22] 为

$$\mathbf{A} = \mathbf{Z} \mathbf{A}^{-1} \mathbf{Z}^T, \quad (8)$$

式中: \mathbf{A} 为对角矩阵, 其第 j 项可以表示为 $\Lambda_{jj} = \sum_{i=1}^n z_{ij}$; \mathbf{A}^{-1} 为矩阵 \mathbf{A} 的逆。由(8)式可获得基于锚点的无核相似图, 基于矩阵 \mathbf{Z} 构造相似图的计算复杂度为 $O(ndm)$ 。

2.3 谱聚类分析

高光谱聚类的目标函数^[23] 为

$$\min_{\mathbf{F}^T \mathbf{F} = \mathbf{I}} \text{Tr}(\mathbf{F}^T \mathbf{L} \mathbf{F}), \quad (9)$$

式中: \mathbf{F} 为类指引矩阵, $\mathbf{F} \in \mathbb{R}^{n \times c}$, 其中 c 为聚类的类别数; \mathbf{L} 为拉普拉斯矩阵, $\mathbf{L} \in \mathbb{R}^{n \times n}$ 。(9)式中的最优解为拉普拉斯矩阵 \mathbf{L} 的 c 个最小特征值的特征向量。矩阵 \mathbf{L} 可以表示为

$$\mathbf{L} = \mathbf{D} - \mathbf{A}, \quad (10)$$

式中: \mathbf{D} 为对角矩阵, $\mathbf{D} \in \mathbb{R}^{n \times n}$, 其第 i 项为 $d_{ii} =$

$\sum_{j=1}^n a_{ij}$, 其中 a_{ij} 为相似度矩阵 \mathbf{A} 第 i 行第 j 列元素。利用(10)式求解获得矩阵 \mathbf{F} , 对矩阵 \mathbf{F} 进行 K-

means 离散化以获得聚类结果。本文提出的 FHC-BTA 算法的流程如图 2 所示。

algorithm 1 FHC-BTA algorithm

input: HSI data matrix $\mathbf{X} \in \mathbb{R}^{n \times d}$, number of anchor points m , number of neighbors k , number of neighbors c .

1) obtain matrix \mathbf{G} by Eq. (5) and obtain anchor set \mathbf{U} by fuzzy K-means clustering for matrix \mathbf{C} .

2) obtain matrix \mathbf{Z} by Eq. (6).

3) obtain relaxed continuous solution \mathbf{F} by Eq. (10).

4) perform K-means on relaxed continuous solution \mathbf{F} for final clustering results.

output: c classes

图 2 FHC-BTA 算法流程

Fig. 2 Flow chart of FHC-BTA algorithm

2.4 时间复杂度分析

给定 HSI 数据矩阵 \mathbf{X} , 锚点数 m , 类别数 c , 簇类数 k 。FHC-BTA 算法的计算复杂度可以分为:

1) 基于二叉树选取锚点的计算复杂度为 $O[nd(\log_m t)]$, t 为执行二叉树的迭代次数;

2) 构建基于锚点的无核相似图的计算复杂度为 $O(ndm)$;

3) 获得松弛的连续解矩阵 \mathbf{F} 的计算复杂度为 $O(m^3 + m^2n)$;

4) 针对矩阵 \mathbf{F} 执行 K-means 离散化以获得最终的聚类结果, 其计算复杂度为 $O(nmr)$, r 为迭代次数。

其中, $m \ll n$ 且 t 通常比较小, 因此 FHC-BTA 算法总的计算复杂度为 $O(ndm)$, 与谱聚类的计算复杂度相比, FHC-BTA 算法可以大大降低了 SC 算法的计算复杂度。

3 实验结果与分析

3.1 实验数据集

为了验证 FHC-BTA 算法的有效性, 在 Indian Pines 数据集和 Salinas 数据集上开展了相关实验。

Indian Pines 数据集是由 AVIRIS 传感器在 1992 年拍摄获取的高光谱图像, 图像的像素尺寸为 $145 \text{ pixel} \times 145 \text{ pixel}$, 含有 16 类地物信息和 220 个光谱带。为了实验研究, 去除了 20 个含有吸水带和噪音带的光谱(104-108, 150-163), 所以用于实验研究的光谱带为 200 个, 总样本数为 21025 个。

Salinas 数据集是由 AVIRIS 传感器拍摄的美国加利福尼亚州北部的萨林河谷的高光谱图像, 图像的像素尺寸为 $512 \text{ pixel} \times 217 \text{ pixel}$, 含有 16 类地物信息和 224 个光谱带。为了实验研究, 去除了 20 个含有吸水带和噪音带的光谱(108-112, 154-167,

224), 所以用于实验研究的光谱带为 204 个, 总样本数为 111104 个。

3.2 聚类实验

为了验证 FHC-BTA 算法的有效性, 聚类实验将 FHC-BTA 算法与目前主流的 HSI 聚类算法进行对比, HSI 聚类算法主要有 K-means、FCM、FCM_S1 和 SC。针对目前已有的选取锚点算法, 利用 K-means 选取锚点(FHC-BTA_K)和随机选取锚点(FHC-BTA_R), 在 HSI 数据集下进行对比实验。本文采用总准确度(OA)、平均准确度(AA)、Kappa 系数、运行时间和聚类图作为实验评估指标。

3.2.1 Indian Pines 数据集实验

在基于 Indian Pines 数据集的实验中, 锚点数和簇类数分别为 $m = 128$ 和 $k = 15$ 。表 1 为各算法在 Indian Pines 数据集下的实验结果对比, 其中对最佳的结果进行了加粗标记。从表 1 可见, 在选取锚点的实验数据中, FHC-BTA_R 算法的运行时间最短, 但 AA、OA 和 Kappa 系数都是最差的, 验证了随机选取锚点速度快但聚类精度较差; 与 FHC-BTA_K 算法相比, FHC-BTA 算法在 AA 上优于 FHC-BTA_K 算法, 虽然 FHC-BTA 算法在 OA 和 Kappa 系数上与 FHC-BTA_K 算法相差 1% 左右, 但 FHC-BTA_K 算法的运行时间是 FHC-BTA 算法的 3 倍, 所以在运行时间较短的情况下, FHC-BTA 算法选取的锚点能够较好地表征整个数据集。在 HSI 聚类算法实验结果中, 与 SC 算法相比, FHC-BTA 算法在 AA、OA 和 Kappa 系数上均提升了 2%~7%, 更重要的是运行速度比 SC 算法快 7.1 倍, 说明 FHC-BTA 算法有效地提升了谱聚类算法在高光谱图像处理中的聚类精度。因为 Indian Pines 数据集有 21025 个样本数, 不属于大规模 HSI 数据集, 所以 SC 算法能够运行

并获得聚类结果。与 K-means、FCM 和 FCM_S1 算法相比,FHC-BTA 算法在 AA、OA 和 Kappa 系数上都是最优的,且运行时间也是最短的。图 3 为各算法在 Indian Pines 数据集下的聚类图,可

以看出,相比于其他 HSI 聚类算法,FHC-BTA 方法能够获得更多的同质区域和更好的聚类图,充分说明了 FHC-BTA 算法能够有效地处理高光谱图像。

表 1 各算法在 Indian Pines 数据集下的比较

Table 1 Comparison of all algorithms on Indian Pines dataset

Parameter	K-means	FCM	FCM_S1	SC	FHC-BTA_K	FHC-BTA_R	FHC-BTA
AA/%	36.36	36.79	34.34	32.81	38.41	35.46	39.14
OA/%	34.89	35.54	36.17	34.10	38.82	35.70	37.31
Kappa	0.2767	0.288	0.2914	0.2824	0.3117	0.2868	0.3039
Time/s	3.87	2.35	4.00	7.86	3.30	0.61	1.10




图 3 各算法在 Indian Pines 数据集下的聚类图。(a)地物图;(b) K-means;(c) FCM;(d) FCM_S1;(e) SC;(f) FHC-BTA_K;(g) FHC-BTA_R;(h) FHC-BTA

Fig. 3 Clustering map of each algorithm on Indian Pines dataset. (a) Ground map; (b) K-means; (c) FCM; (d) FCM_S1; (e) SC; (f) FHC-BTA_K; (g) FHC-BTA_R; (h) FHC-BTA

3.2.2 Indian Pines 数据集实验

在基于 Salinas 数据集的实验中,锚点数和类簇数分别为 $m = 1024$ 和 $k = 15$ 。表 2 为各算法在 Salinas 数据集下的实验结果对比,其中对最佳的结果进行了加粗标记。从表 2 可见,在选取锚点的实验数据中,FHC-BTA 算法相比于 FHC-BTA_R 算法在 OA 和 Kappa 系数上都提升了 2%~3%,同时运行速度快了 5.4 倍;虽然 FHC-BTA_K 算法的运行时间仅为 7.51 s,但 AA、OA 和 Kappa 系数都较差。这些数据有效验证了在运行时间相对合理的情况下,FHC-BTA 算法能够获得更具代表性的锚

点,从而获得更佳的聚类结果。在 HSI 聚类算法实验结果对比中,Salinas 数据集有 111104 个样本数,属于大规模 HSI 数据集,SC 算法的计算复杂度高,导致计算机无法运行,说明 SC 算法难以有效处理大规模高光谱图像;与其他 HSI 聚类算法相比,FHC-BTA 算法在 AA、OA 和 Kappa 系数上都获得了最佳的聚类精度,运行时间也是最短的。图 4 为各算法在 Salinas 数据集下的聚类图,可以看出,在 FHC-BTA 算法得到的聚类图中,错分点更少,地物分布更加平滑,充分说明 FHC-BTA 算法的计算复杂度小,能够有效地处理大规模高光谱图像。

表 2 各算法在 Salinas 数据集下的比较

Table 2 Comparison of all algorithms on Salinas dataset

Parameter	K-means	FCM	FCM_S1	FHC-BTA_K	FHC-BTA_R	FHC-BTA
AA/%	65.53	65.90	66.37	66.10	64.22	66.47
OA/%	66.66	63.90	67.05	66.60	67.62	68.60
Kappa	0.6284	0.6006	0.6326	0.6273	0.6405	0.6511
Time/s	23.71	12.44	20.96	61.62	7.51	11.33




图 4 各算法在 Salinas 数据集下的聚类图。(a) 地物图; (b) K-means; (c) FCM; (d) FCM_S1; (e) FHC-BTA_K; (f) FHC-BTA_R; (g) FHC-BTA

Fig. 4 Clustering map of each algorithm on Salinas dataset. (a) Ground map; (b) K-means; (c) FCM; (d) FCM_S1; (e) FHC-BTA_K; (f) FHC-BTA_R; (g) FHC-BTA

3.3 参数实验

本文提出的 FHC-BTA 算法需要输入两个参数,分别为锚点数 m 和近邻数据点数 k 。为了获得更好的聚类性能,测试不同锚点数 m 和近邻数

据点数 k 数值下的 OA、AA 和 Kappa 值, m 的取值范围为 $64 \sim 4096$, k 的取值范围为 $6 \sim 30$ 。图 5 所示为 Indian Pines 数据集下的测试结果。随着 m 的增加,参数曲线呈现出先上升后下降再上升的

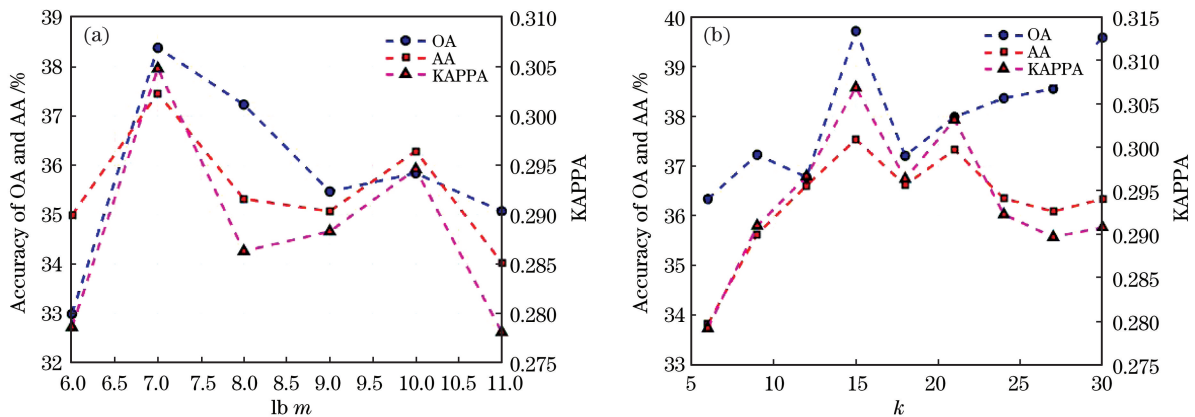


图 5 Indian Pines 数据集下的测试结果。(a) 不同锚点数; (b) 不同近邻点数

Fig. 5 Test results under Indian Pines dataset. (a) Different numbers of anchor points; (b) different numbers of nearest neighbors

趋势,OA、AA 和 Kappa 值的下降比较明显,下降之后上升的幅度不大。当 $m=128$ 时,OA、AA 和 Kappa 值均达到最大。随着 k 的增加,参数曲线呈现出先上升后下降的趋势,当 $k=15$ 时,OA、AA 和 Kappa 值均达到最大。所以在 Indian Pines 数据集实验中选取 $m=128$ 和 $k=15$ 。图 6 所示为 Salinas 数据集下的测试结果。随着 m 的增加,

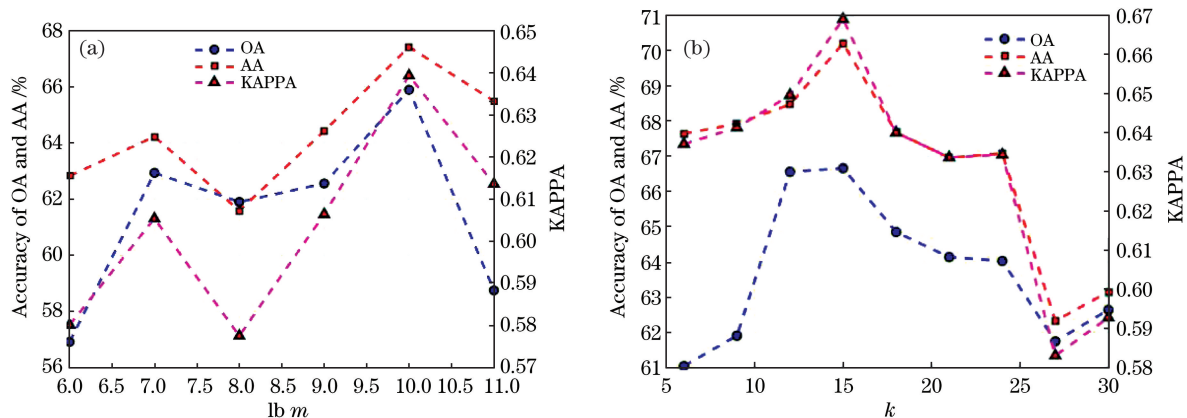


图 6 Salinas 数据集下的测试结果。(a)不同锚点数;(b)不同近邻点数

Fig. 6 Test results under Salinas dataset. (a) Different numbers of anchor points; (b) different numbers of nearest neighbors


4 结 论

针对基于锚点的谱聚类算法存在的问题,提出了一种基于二叉树锚点的快速高光谱图像聚类方法,创新性地将二叉树锚点选取和无核聚类的方法应用于高光谱图像中。该算法既减少了 HSI 数据量,又充分利用了 HSI 的光谱和空间特性,因此获得了较好的结果。Indian Pines 和 Salinas 高光谱数据集下的实验结果表明,与 K-means 算法和随机选取锚点方法相比,二叉树选取锚点方法在运行时间可接受的范围内能够获得更好的聚类性能。与其他 HSI 聚类算法相比,FHC-BTA 算法的聚类精度是最佳的,且时间更短。FHC-BTA 算法的计算复杂度小,有效减少了错分的现象,且分类后的图像更加平滑,充分说明 FHC-BTA 算法能够有效处理大规模高光谱图像。

参 考 文 献

[1] Zeng C P, Ju L J, Zhang J C. Hyperspectral image classification based on clustering dimensionality reduction and visual attention mechanism[J]. Laser & Optoelectronics Progress, 2019, 56(21): 212802
曾朝平, 琚丽君, 张建辰. 基于聚类降维和视觉注意力机制的高光谱影像分类[J]. 激光与光电子学进展, 2019, 56(21): 212802

参数曲线呈现出先上升后下降再上升的趋势,其中 m 为 256~1024 时曲线上上升幅度比较大,当 $m=1024$ 时,OA、AA 和 Kappa 值均达到最大。随着 k 的增加,曲线呈现出先上升后下降的趋势,当 $k=15$ 时,OA、AA 和 Kappa 值均达到最大。所以在 Salinas 数据集实验中选取 $m=1024$ 和 $k=15$ 。



- [2] Huang D M, Zhang X T, Zhang M H, et al. Feature extraction of hyperspectral images based on semi-supervised locality preserving projection with spatial-correlation[J]. Laser & Optoelectronics Progress, 2019, 56(2): 021003.
黄冬梅, 张晓桐, 张明华, 等. 考虑空间相关性的半监督局部保持投影的高光谱图像特征提取[J]. 激光与光电子学进展, 2019, 56(2): 021003.
- [3] Ji L, Zhang X, Zhang L M, et al. Hyperspectral image classification algorithm based on spatial spectrum weighted nearest neighbors[J]. Laser & Optoelectronics Progress, 2020, 57(6): 061013.
纪磊, 张欣, 张丽梅, 文章. 基于空谱加权近邻的高光谱图像分类算法[J]. 激光与光电子学进展, 2020, 57(6): 061013.
- [4] Xue Z H, Du P J, Li J, et al. Sparse graph regularization for hyperspectral remote sensing image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(4): 2351-2366.
- [5] Chang X J, Yang Y. Semisupervised feature analysis by mining correlations among multiple tasks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2294-2305.
- [6] Hartigan J A, Wong M A. Algorithm AS 136: a K-means clustering algorithm[J]. Applied Statistics, 1979, 28(1): 100-108.
- [7] Li Y, Zhen C, Shi X, et al. Hyperspectral image

- classification based on entropy-weighted K-means global information clustering[J]. *Chinese Journal of Image and Graphics*, 2019, 24(4): 630-638.
- 李玉,甄畅,石雪,赵泉华. 基于熵加权 K-means 全局信息聚类的高光谱图像分类[J]. *中国图象图形学报*, 2019, 24(4): 630-638.
- [8] Bezdek J C. Modified objective function algorithms [M]//*Pattern recognition with fuzzy objective function algorithms*. Boston: Springer, 1981: 155-201.
- [9] Chen S, Zhang D. Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure[J]. *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, 2004, 34(4): 1907-1916.
- [10] Ng A Y, Jordan M I, Weiss Y. On spectral clustering: analysis and an algorithm [C] // *14th International Conference on Neural Information Processing Systems: Natural and Synthetic*, December 3-8, 2001, Vancouver, Canada. New York: Curran Associates, 2001:849-856.
- [11] Yang X J, Yu W Z, Wang R, et al. Fast spectral clustering learning with hierarchical bipartite graph for large-scale data[J]. *Pattern Recognition Letters*, 2020, 130: 345-352.
- [12] Jebara T, Wang J, Chang S F. Graph construction and b-matching for semi-supervised learning [C] // *Proceedings of the 26th Annual International Conference on Machine Learning: ICML '09*, June 14-18, 2009, Montreal, Quebec, Canada. New York: ACM Press, 2009: 441-448.
- [13] Wang R, Nie F P, Yu W Z. Fast spectral clustering with anchor graph for large hyperspectral images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(11): 2003-2007.
- [14] Li Y, Nie F, Huang H, et al. Large-scale multi-view spectral clustering via bipartite graph [C] // *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence*, January 25-30, 2015, Austin, Texas, USA. [S.l.: s. n.], 2015: 2750-2756.
- [15] Cai D, Chen X L. Large scale spectral clustering via landmark-based sparse representation [J]. *IEEE Transactions on Cybernetics*, 2015, 45(8): 1669-1680.
- [16] Zhou X M, Pan D. Research on large scale image indexing technology based on PCA-binary tree [J]. *Journal of Southwest China Normal University (Natural Science Edition)*, 2019, 44(7): 57-62.
- 周雪梅,潘多. 基于 PCA-二叉树的大规模图像索引技术研究[J]. *西南师范大学学报(自然科学版)*, 2019, 44(7): 57-62.
- [17] Liu Y X, Zhang Z H, Zhang Y M. Image denoising based on K-means clustering and binary tree decision [J]. *Computer Engineering & Science*, 2013, 35(5): 118-123.
- 刘永霞,张朝晖,张艳敏. 基于 K-均值聚类及二叉树决策的图像去噪[J]. *计算机工程与科学*, 2013, 35(5): 118-123.
- [18] Zhu W, Nie F P, Li X L. Fast spectral clustering with efficient large graph construction [C] // *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, March 5-9, 2017, New Orleans, LA, USA. New York: IEEE, 2017: 2492-2496.
- [19] Zhou Y C, Peng J T, Chen C L P. Dimension reduction using spatial and spectral regularized local discriminant embedding for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(2): 1082-1095.
- [20] Nie F, Zhu W, Li X. Unsupervised large graph embedding [C] // *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, February 4-9, 2017, San Francisco, California, USA. [S.l.: s. n.], 2017: 2422-2428.
- [21] Nie F P, Wang X Q, Jordan M I, et al. The constrained Laplacian rank algorithm for graph-based clustering[C] // *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence*, February 12-17, 2016, Phoenix, Arizona, USA. [S.l.: s. n.], 2016: 1969-1976.
- [22] Wei Y W, Niu C, Wang Y T, et al. The fast spectral clustering based on spatial information for large scale hyperspectral image [J]. *IEEE Access*, 2019, 7: 141045-141054.
- [23] Wang R, Nie F P, Hong R C, et al. Fast and orthogonal locality preserving projections for dimensionality reduction[J]. *IEEE Transactions on Image Processing*, 2017, 26(10): 5019-5030.