



基于波段影像统计信息量加权K-means聚类的高光谱影像分类

李玉, 甄畅, 石雪, 朱磊

引用本文:

李玉, 甄畅, 石雪, 等. 基于波段影像统计信息量加权K-means聚类的高光谱影像分类[J]. 控制与决策, 2021, 36(5): 1119–1126.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1516>

您可能感兴趣的其他文章

Articles you may be interested in

基于相互邻近度的密度峰值聚类算法

Density peaks clustering based on mutual neighbor degree

控制与决策. 2021, 36(3): 543–552 <https://doi.org/10.13195/j.kzyjc.2019.0795>

基于搜索空间划分与Canopy K-means聚类的种群初始化方法

Population initialization based on search space partition and Canopy K-means clustering

控制与决策. 2020, 35(11): 2767–2772 <https://doi.org/10.13195/j.kzyjc.2019.0358>

考虑时间序列的动态大群体应急决策方法

Dynamic large group emergency decision-making method considering time series

控制与决策. 2020, 35(11): 2609–2618 <https://doi.org/10.13195/j.kzyjc.2019.0088>

基于社交网络的双知识表达分类方法

Double knowledge representations based classification method from perspective of social networks

控制与决策. 2020, 35(11): 2653–2664 <https://doi.org/10.13195/j.kzyjc.2019.0141>

双层多态加权\$ k/n \$系统可用性模型与冗余设计优化

Availability modeling and redundancy design optimization of dual hierarchical multi-state weighted bmk-out-of-bmn system

控制与决策. 2020, 35(11): 2752–2760 <https://doi.org/10.13195/j.kzyjc.2018.1752>

基于波段影像统计信息量加权 K -means 聚类的高光谱影像分类

李 玉^{1†}, 甄 畅¹, 石 雪¹, 朱 磊²

(1. 辽宁工程技术大学 测绘与地理科学学院, 辽宁 阜新 123000;
2. 葫芦岛宏跃集团有限公司, 辽宁 葫芦岛 125200)

摘要: 针对分类过程中如何合理利用高光谱影像波段问题, 提出一种基于波段影像统计量加权 K -means 聚类的高光谱影像分类算法。该算法的核心思想在于: 由波段含有的信息量及波段间的相关性确定各波段权重, 同时考虑各波段对各聚类的重要性。首先, 根据波段影像的熵、标准差及均值定义波段信息量函数, 根据相邻波段影像互信息定义相关性函数; 其次, 由上述波段信息量函数及波段间相关性函数定义波段权重函数; 然后, 结合波段权重和波段-类属权重定义规则化目标函数; 最后, 依据参数特性设计目标函数求解方案。对 Salinas 高光谱影像和 Pavia Centre 高光谱影像分别采用所提出的算法与传统 K -means 算法、PCA+ K -means 算法及子空间波段选择+ K -means 算法进行对比实验, 对于总精度及 Kappa 系数, 所提出的算法都高于其他 3 种对比算法, 结果验证了所提出算法的有效性。相对于其他 3 种算法而言, 所提出的算法可有效改善高光谱影像分类的性能。

关键词: 波段加权; 统计信息; 熵信息; K -means; 高光谱影像; 分类

中图分类号: TP751

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1516

开放科学(资源服务)标识码(OSID):

引用格式: 李玉, 甄畅, 石雪, 等. 基于波段影像统计信息量加权 K -means 聚类的高光谱影像分类[J]. 控制与决策, 2021, 36(5): 1119-1126.



Algorithm based on band statistical information weighted K -means for hyperspectral image classification

LI Yu^{1†}, ZHEN Chang¹, SHI Xue¹, ZHU Lei²

(1. School of Geomatics, Liaoning Technical University, Fuxin 123000, China; 2. Huludao Hongyue Group CO., Ltd., Huludao 125200, China)

Abstract: Aiming at the problem of how to use band information reasonably in the hyperspectral image classification, this paper proposes a hyperspectral image classification algorithm based on band statistical information weighted K -means clustering. The algorithm considers not only the quantity of information contained in each band and the correlation between bands but also the importance of each band to different clusters. The band weight is determined by the statistics of information and correlation functions. The statistics of information function is defined according to the entropy, standard deviation and mean value of the band image. The correlation function is defined according to the mutual information of adjacent band images. In order to express the importance of each band to different clusters, the band-category weight is introduced, and its entropy information measurement is defined. The above two types of weights are embedded into the K -means objective function. The final classification result can be obtained by minimizing the objective function. Classification experiments are conducted on Salinas and Pavia Centre hyperspectral images using the proposed algorithm, the traditional K -means algorithm, the PCA + K -means algorithm and the subspace band selection + K -means algorithm, respectively. The results demonstrate that the proposed algorithm is higher than the other three algorithms on overall accuracy and Kappa. It shows that the proposed algorithm can effectively improve the performance of hyperspectral image classification.

Keywords: feature weighting; statistical information; entropy information; K -means; hyperspectral image; classification

收稿日期: 2019-10-30; 修回日期: 2019-12-26。

基金项目: 国家自然科学基金青年科学基金项目(41301479); 辽宁省高校创新人才支持计划项目(LR2016061); 辽宁省教育厅科学技术研究一般项目(LJCL009)。

责任编辑: 薛建儒。

[†]通讯作者. E-mail: Intuliyu@163.com.

0 引言

高光谱遥感技术^[1]自出现以来一直是遥感领域研究的重点。由于高光谱影像的波长范围跨越可见光及短波红外区域且是对光谱的连续密集采样,使其形成数十个或数百个窄波段影像,为地物的精细分类提供最优的数据源,现已广泛应用于农作物检测^[2]、矿石勘探^[3]和植被元素检测^[4]等各个领域。高光谱影像的主要特点是波段数目多,各波段含有信息量不同,因此如何充分、合理地利用波段信息实现影像的精细分类是目前存在的重点和难点问题。

根据不同的应用目的,高光谱影像波段信息使用方式大致分为两种:直接采用全部波段以及降维使用部分波段信息。对于第1种方式,文献[5]提出了基于多中心光谱角分类器(spectral angle mapping, SAM)和马尔可夫随机场(Markov random field, MRF)的光谱-空间高光谱分类方法。该方法以SAM为基础,将多中心模型和MRF引入概率决策框架,得到分类结果。虽然充分运用所有波段信息,提高了分类精度,但是直接运用各波段信息,忽略了波段间的冗余问题,导致算法实现时间长且在分类精度提高方面没有预想的多。对于第2种方式,学者们提出了多种方法^[6-9],包括降维及波段选择。如,文献[10]提出了一种改进的局部保持投影(locality preserving projection, LPP)高光谱图像分类方法。该方法克服了传统LPP只考虑局部邻近数据点信息的缺陷,自适应地为每个数据点选择不同数量的最近邻,并使最近邻点间的距离最大化,之后分别利用近邻分类器和支持向量机实现分类。该方法虽然保留了数据固有的几何结构,增加了具有不同光谱特征地物之间的可分性,但是只运用部分波段信息且改变了特征空间,导致特征相近的部分地物难以区分,使得该分类方法具有局限性。文献[11]提出了结合波段选择的差分进化高光谱图像分类方法。该方法首先利用遗传算法进行波段选择,其次运用差分进化算法选择样本,最后将所选样本与已知类别的样本集结合,运用最小二乘孪生支持向量机实现分类。虽然该方法在已知类别样本集少的情况下有优势,但是其波段选择只选用了较少波段并且同等看待选用的波段,没有充分运用波段信息,对所有地物的可分性不理想。因此,本文针对波段信息的利用问题引用特征加权的思想^[12],将波段看作特征,用权重表达波段的重要性。考虑波段含有信息量及波段间相关性等因素,定义波段权重。

在分类方法中,聚类算法是实现图像分类最基本的方式,其中文献[13]提出的K-means算法是最为经

典的聚类算法,它是通过循环迭代数据点与类中心间距离并使之达到最小化的聚类算法。但是K-means算法同等看待各波段特征,由于没有合理利用特征,使得分类精度差。

针对以上提出的问题,本文提出基于统计信息熵加权K-means聚类的高光谱影像分类方法。所提出的方法首先运用各波段的熵信息^[14-15]、标准差^[16]及均值^[17]3个统计量^[18]的函数作为信息量函数,将波段间的互信息^[19]作为相关性函数,以这两个函数确定波段权重;其次,在K-means算法中引入波段权重;然后,为了表达各波段对各聚类的重要程度,引入波段-类属权重,同时定义波段-类属权重的熵信息来表达其分布情况;最后,通过最小化目标函数得到分类结果。本文通过对Salinas高光谱数据和Pavia Centre高光谱数据进行实验,并与3种对比算法分类结果对比表明,该算法对光谱曲线有差异的地物能够实现很好的分类。

1 算法描述

1.1 基本方法

设原始高光谱影像 $\mathbf{y} = \{\mathbf{y}_n, n = 1, 2, \dots, N\} = \{\mathbf{y}_{(i)}, i = 1, 2, \dots, D_0\}$ 。其中: n 为像素索引; N 为像素数; i 为波段索引; D_0 为波段数; $\mathbf{y}_n = \{y_{ni}, i = 1, 2, \dots, D_0\}^T$ 为像素 n 的光谱测度矢量, T 为转置操作符, y_{ni} 为像素 n 在 i 波段的光谱测度; $\mathbf{y}_{(i)} = \{y_{ni}, n = 1, 2, \dots, N\}$ 为 i 波段对应的光谱影像。

在基于K-means算法对高光谱影像进行分类时,认为各波段含有信息量相同且波段间独立,其目标函数为

$$J_1(\mathbf{y}, \mathbf{x}, \mathbf{r}) = \sum_{n=1}^N \sum_{m=1}^M r_{nm} \sum_{i=1}^{D_0} (y_{ni} - x_{mi})^2. \quad (1)$$

其中: $\mathbf{x} = \{\mathbf{x}_m, m = 1, 2, \dots, M\}$ 为类中心矢量集, m 为类属索引, M 为类属数, $\mathbf{x}_m = (x_{mi}, i = 1, 2, \dots, D_0)^T$ 为类属 m 的中心矢量; $\mathbf{r} = \{\mathbf{r}_n, n = 1, 2, \dots, N\}$ 为类属矢量集, $\mathbf{r}_n = (r_{nm}, n = 1, 2, \dots, N)^T$, $r_{nm} \in \{0, 1\}$ 为像素 n 属于类属 m 的隶属度, $r_{nm} = 1$ 表示像素 n 隶属于类属 m , 并且满足如下约束条件:

$$\sum_{m=1}^M r_{nm} = 1.$$

由于K-means算法同等看待各波段,数据冗余及维数灾难现象使得影像分类精度低。通过聚类实现分类时,需要考虑各波段含有信息量及波段间的相关性等因素。为了避免“维数灾难”,采用波段加权的方式,运用波段权重表达波段对聚类的重要性。

1.2 分类模型

受传感器及大气等因素的影响,原始高光谱影像部分波段中包含很多噪声,导致该部分波段的信噪比极低,其对目标提取和影像分类有很大负面影响,所以需要将该部分波段删除.

由于在统计分布中,直方图可以有效表示影像各灰度值像元数量的分布情况,其灰度频率非0的个数越少,表示影像含有的信息越少,可用各波段的直方图中波段频率非0数确定其信息量.

设高光谱影像各波段的直方图为

$$\mathbf{H} = \{\mathbf{H}_i, i = 1, 2, \dots, D_0\}.$$

其中: $\mathbf{H}_i = \{o_{si}, s = 0, 1, \dots, 255\}$ 为第 i 波段的直方图, o_{si} 为 i 波段影像中灰度为 s 的像素数. 设 $\mathbf{y}_{(i)} = \{y_{ni}, n = 1, 2, \dots, N\}$ 为波段 i 对应的灰度影像, 则 $o_{si} = \#\{n, y_{ni} = s\}$. 各波段影像直方图中波段频率非0数的集合为 $\mathbf{h} = \{h_i, i = 1, 2, \dots, D_0\}$, 即 $h_i = \#\{o_{si} \neq 0, s \in \{0, 1, \dots, 255\}\}$. 对于给定阈值 T , 当 $h_i < T$ 时, 认为该波段信息量较少, 因此在分类过程中无需考虑该波段.

波段去除后, 将高光谱影像按照波段索引大小重新排序, 设重新排序后的高光谱影像为

$$\mathbf{z} = \{z_n, n = 1, 2, \dots, N\} = \{z_{(d)}, d = 1, 2, \dots, D\}.$$

其中: d 为波段索引, D 为波段数, $z_{(d)} = \{z_{nd}, n = 1, 2, \dots, N\}$ 为波段 d 对应的光谱影像, $z_n = \{z_{nd}, d = 1, 2, \dots, D\}^T$ 为像素 n 的光谱测度矢量, z_{nd} 为像素 n 在波段 d 的光谱测度.

为实现影像分类, 建立目标函数为

$$\begin{aligned} J(\mathbf{z}, \mathbf{v}, \mathbf{r}, \mathbf{w}, \mathbf{a}, \boldsymbol{\lambda}) = & \\ & \sum_{n=1}^N \sum_{m=1}^M r_{nm} \sum_{d=1}^D w_d a_{md} (z_{nd} - v_{md})^2 + \\ & \sum_{m=1}^M \lambda_m \sum_{d=1}^D a_{md} \ln a_{md}. \end{aligned} \quad (2)$$

其中: $\mathbf{v} = \{\mathbf{v}_m, m = 1, 2, \dots, M\}$ 为类中心矢量集, $\mathbf{v}_m = (v_{md}, d = 1, 2, \dots, D)^T$ 为类属 m 的中心矢量; $\mathbf{w} = (w_d, d = 1, 2, \dots, D)^T$ 为波段权重矢量, w_d 为 d 波段的波段权重; $\mathbf{a} = \{\mathbf{a}_m, m = 1, 2, \dots, M\}$ 为波段-类属权重矢量集, $\mathbf{a}_m = \{a_{md}, d = 1, 2, \dots, D\}$, a_{md} 为波段 d 对类属 m 的波段类属权重; $\boldsymbol{\lambda} = (\lambda_m, m = 1, 2, \dots, M)^T$ 为正则化项权重矢量, λ_m 为类属 m 的正则化权重.

由于各波段的信息量及波段间的相关性决定波段对分类的重要程度, 考虑各波段含有信息量及波段

间相关性影响, 引入 \mathbf{w} 表达其对聚类的重要性. 因此, \mathbf{w} 由波段含有信息量函数及波段间的相关性函数确定.

在统计分布中, 熵是影像信息不确定性程度的度量, 熵值越大, 影像信息的不确定性越大, 含有的信息量越大. 因此本文用熵值大小表示各波段影像在影像信息量的度量.

设高光谱影像各波段的熵值为

$$\mathbf{E} = (E_d, d = 1, 2, \dots, D),$$

E_d 为波段 d 的熵值, 即

$$E_d = - \sum_{g=0}^G p_g^{(d)} \ln p_g^{(d)}. \quad (3)$$

其中: $p_g^{(d)}$ 是灰度值为 g 且频率不为0的概率, 即

$$p_g^{(d)} = \frac{1}{N} \#\{n, z_{nd} = g\}. \quad (4)$$

在统计分布中, 标准差反映一组数据的离散程度. 影像的标准差越大, 表示影像灰度越离散, 含有的信息量越大. 均值反映一组数据的平均水平. 由于标准差是绝对量化指标, 为了消除影像平均水平的影响, 用标准差与均值的比值(即离散系数)表示影像在离散程度的信息量.

设高光谱影像各波段的标准差的集合为

$$\boldsymbol{\sigma} = \{\sigma_d, d = 1, 2, \dots, D\},$$

σ_d 为波段 d 的标准差, 即

$$\sigma_d = \sqrt{\frac{\sum_{n=1}^N (z_{nd} - \mu_d)^2}{N}}, \quad (5)$$

其中 μ_d 为波段 d 的均值. $\boldsymbol{\mu} = \{\mu_d, d = 1, 2, \dots, D\}$ 为波段均值的集合.

$$\mu_d = \frac{1}{N} \sum_{n=1}^N z_{nd}. \quad (6)$$

离散系数的集合为 $\mathbf{c} = \{c_d, d = 1, 2, \dots, D\}$, c_d 为波段 d 的离散系数, 即

$$c_d = \frac{\sigma_d}{\mu_d}. \quad (7)$$

设各波段信息量函数为 $\mathbf{I} = (I_d, d = 1, 2, \dots, D)$, I_d 为波段 d 的信息量, 由熵值及离散系数乘积确定, I_d 的具体表达式为

$$I_d = E_d \times c_d. \quad (8)$$

在统计分布中, 互信息表示两个变量之间所含信息的相关性, 因此用波段间的互信息表示波段间的相关性. 通过计算各波段间的互信息, 可以根据互信息的分布情况将总体波段进行分块, 对各块中的各波段

计算相关性.

设高光谱影像的互信息矩阵为 \mathbf{R} , 设高光谱影像中的两波段为 d_1 和 d_2 , 其互信息 R_{d_1, d_2} 为

$$R_{d_1, d_2} = E_{d_1} + E_{d_2} - E_{d_1, d_2}, \quad (9)$$

其中 E_{d_1, d_2} 为 d_1 和 d_2 波段的联合熵.

设各波段相关性函数集合为

$$\mathbf{M} = (M_d, d = 1, 2, \dots, D),$$

其中 M_d 为波段 d 的相关性, 即

$$M_d = (R_{d, d-1} + R_{d, d+1})/2, \quad (10)$$

这里 $R_{d, d-1}$ 和 $R_{d, d+1}$ 分别为波段 d 与波段 $d-1$ 以及波段 $d+1$ 的互信息.

综上, 定义波段的权重 w_d 为

$$w_d = \frac{I_d^B}{A \times M_d} = \frac{\left(E_d \frac{\sigma_d}{\mu_d}\right)^B}{A(R_{d, d-1} + R_{d, d+1})/2}, \quad (11)$$

其中 A 和 B 为调节参数. 为了保证 $\mathbf{w} = (w_d, d = 1, 2, \dots, D)$ 与 \mathbf{I} 及 \mathbf{M} 呈正相关, 取 $A > 0, B > 0$. 参数 A 选取的越大, 波段的 \mathbf{I} 对 \mathbf{w} 的变化范围影响越大, 但对分类起主要作用的波段越少. 例如, 当 $A = 7$ 时, 虽然 \mathbf{w} 的变化范围很大, 但仅有极少数波段的 \mathbf{w} 值很大, 即在分类时只有极少数波段起作用, 导致分类结果精度不高. 为了使 \mathbf{w} 的变化范围大且对分类起作用波段多, 可选取参数 $A \in (0, 7]$. 参数 B 的取值越小, 波段间的 \mathbf{M} 对 \mathbf{w} 的整体影响程度越大. 例如, 当 $B = 4$ 时, \mathbf{w} 的变化范围小, 导致 \mathbf{w} 对分类的影响不大, 分类精度不高. 为了使 \mathbf{w} 的整体差异变大, 可选取参数 $B \in (0, 4]$.

由于在聚类时, 每个波段对各个聚类的重要性不尽相同, 本文定义 $\mathbf{a} = \{\mathbf{a}_m, m = 1, 2, \dots, M\}$ 表达其对各聚类的重要性, 其中 $\mathbf{a}_m = \{a_{md}, d = 1, 2, \dots, D\}$, 且满足条件 $\sum_{d=1}^D a_{md} = 1$. 同时, 为了表达各个聚类中 a_{md} 的不确定程度, 对 a_{md} 引入信息熵作为规则化项. 为了使每个聚类中各波段-类属权重值的差异较大, 即使得 a_{md} 的变化范围较大, λ_m 的取值规定为

$$\lambda_m = \frac{1}{8} \max_{d \in \{1, 2, \dots, D\}} Q_{md}, \quad (12)$$

其中

$$Q_{md} = \sum_{n=1}^N r_{nm} w_d (z_{nd} - v_{md})^2. \quad (13)$$

得到 a_{md} 的取值范围为 $a_{md} \in [0.0003, 1]$.

1.3 模型求解

为了得到最优的分类结果, 通过局部优化 \mathbf{r}, \mathbf{v} 和 \mathbf{a} , 求解目标函数 J 的最小值, 使得

$$(\mathbf{z}, \hat{\mathbf{v}}, \hat{\mathbf{r}}, \mathbf{w}, \hat{\mathbf{a}}, \hat{\boldsymbol{\lambda}}) = \arg \min J\{\mathbf{z}, \mathbf{v}, \mathbf{r}, \mathbf{w}, \mathbf{a}, \boldsymbol{\lambda}\}. \quad (14)$$

模型求解过程描述如下.

1) 求解 \mathbf{r} . 已知 $\mathbf{z}, \mathbf{v}, \mathbf{w}, \mathbf{a}$ 和 $\boldsymbol{\lambda}$, 计算像素到各聚类的加权类内非相似性测度, 找到非相似测度最小的一类, 则该像素到该聚类的隶属度为 1, 其他为 0, 即

$$r_{nm} =$$

$$\begin{cases} 1, & m = \arg \min_{m \in \{1, 2, \dots, M\}} \mathbf{w} \times \mathbf{a}_m \times \|\mathbf{z}_n - \mathbf{v}_m\|^2; \\ 0, & \text{otherwise.} \end{cases} \quad (15)$$

2) 求解 \mathbf{v} . 由于目标函数关于 v_{md} 是一次函数, 通过令偏导数为 0 进行求解. 已知 $\mathbf{z}, \mathbf{r}, \mathbf{w}, \mathbf{a}$ 和 $\boldsymbol{\lambda}$, 对目标函数 J 中 v_{md} 求偏导, 并令该导数为 0, 求得目标函数最小时的 \mathbf{v} , 其过程为

$$\frac{\partial J}{\partial v_{md}} = 2 \sum_{n=1}^N r_{nm} w_d (z_{nd} - v_{md}) = 0, \quad (16)$$

则 v_{ma} 的具体表达式为

$$v_{md} = \frac{\sum_{n=1}^N r_{nm} z_{nd}}{\sum_{n=1}^N r_{nm}}. \quad (17)$$

3) 求解 \mathbf{a} . 由于 a_{md} 有约束条件, 是约束解, 通过拉格朗日极值法进行求解. 已知 $\mathbf{z}, \mathbf{v}, \mathbf{r}, \mathbf{w}$ 和 $\boldsymbol{\lambda}$, 在目标函数 J 中引入拉格朗日因子 u_m , 构建拉格朗日方程

$$\begin{aligned} L = & \sum_{n=1}^N \sum_{m=1}^M r_{nm} \sum_{d=1}^D w_d a_{md} (z_{nd} - v_{md})^2 + \\ & \sum_{m=1}^M \lambda_m \sum_{d=1}^D a_{md} \ln a_{md} + \\ & \sum_{m=1}^M u_m \left(\sum_{d=1}^D a_{md} - 1 \right). \end{aligned} \quad (18)$$

对式(18)中的 a_{md} 求偏导, 并令该导数为 0, 同时结合 a_{md} 的约束项式, 最终得到权重 a_{md} 的具体表达式为

$$a_{md} = \frac{\exp \left(-\frac{Q_{md}}{\lambda_d} \right)}{\sum_{l=1}^M \exp \left(-\frac{Q_{ld}}{\lambda_d} \right)}. \quad (19)$$

综上所述, 算法的伪码如下.

Input: $\mathbf{y}, N, D_0, M, T, \mathbf{v}^{(0)}, \mathbf{a}^{(0)}, \varepsilon_1, \varepsilon_2, L, A, B$;
Output: $\mathbf{r}, \mathbf{v}, \mathbf{a}, \mathbf{w}$.

```

for i = 1 to  $D_0$ 
     $d \leftarrow 1$ 
    accept  $H_i$  and  $h_i$ 
    if  $h_i > T$ 
        then  $\mathbf{z}_d \leftarrow \mathbf{y}_i, d \leftarrow d + 1$ 
    end if
end for
 $D \leftarrow d - 1$ 
for d = 1 to D
    calculate  $E_d, \mu_d, \sigma_d$  and  $M_d$  from (3), (5), (6) and (10), respectively
    accept  $w_d$  from (11)
end for
 $t \leftarrow 0, b \leftarrow 1$ 
while  $b == 1$ 
     $\mathbf{v}^{(t)} \leftarrow \mathbf{v}^{(t+1)}, \mathbf{a}^{(t)} \leftarrow \mathbf{a}^{(t+1)}$ 
    for n = 1 to N
        for m = 1 to M
            accept  $r_{nm}$  from (15)
        end for
    end for
    for m = 1 to M
        for d = 1 to D
            accept  $v_{md}$  from (17)
        end for
    end for
    for m = 1 to M
        for d = 1 to D
            calculate  $\lambda_m$  and  $Q_{md}$  from (12) and (13), respectively
            accept  $a_{md}$  from (19)
        end for
    end for
    end for
    if  $|v_{md}^{(t+1)} - v_{md}^{(t)}| < \varepsilon_1$  and  $|a_{md}^{(t+1)} - a_{md}^{(t)}| < \varepsilon_2$  or  $t \leq L$ 
        then  $b \leftarrow 0, t \leftarrow t + 1$ 
    end if
end while
 $\mathbf{v} \leftarrow \mathbf{v}^{(t)}, \mathbf{a} \leftarrow \mathbf{a}^{(t)}$ 

```

2 实验结果和讨论

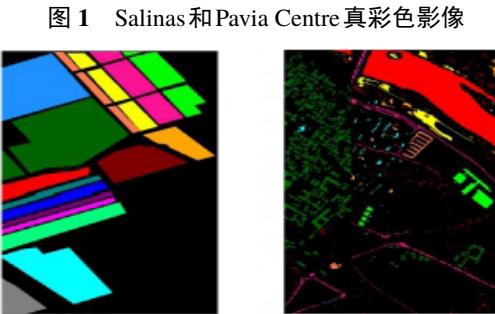
为了验证本文算法的可行性和有效性, 使用 Matlab R2014b 对高光谱影像进行分类实验。实验选用了美国加利福尼亚州 Salinas 地区的 AVIRIS 数据和意大利北部 Pavia Centre 地区的 ROSIS 数据, 图1为真彩色影像, 图2为两个数据的标准分类图。Salinas 高光谱影像的光谱测量范围为 400~2 500 nm, 空间分辨率为 3.7 m, 共 224 个波段, 去除 20 个水吸收波段, 共有 204 个波段参与实验, 原始影像大小为 512×217 像素, Pavia Centre 高光谱影像的光谱测量范围为 430~860 nm, 空间分辨率为 1.3 m, 共 102 个波段, 原始影像为 1 096×1 096 像素, 由于有一部分没有信息, 用于分类的影像大小为 1 096×715 像素。

在本文算法中, 随着迭代次数的增加, 运行时间呈线性增长, 算法复杂度为线性复杂度 $O(n)$, 因此对影像大小不作要求。由于高光谱影像数据在成像过

程中受各种因素影响, 导致影像变形, 需要对采集数据进行几何校正; 同时在成像过程中有些波段成为水吸收波段, 对分类产生不利影响, 因此在分类之前需要将水吸收波段删除。



(a) Salinas 真彩色影像 (b) Pavia Centre 真彩色影像



(a) Salinas 标准分类 (b) Pavia Centre 标准分类

图 1 Salinas 和 Pavia Centre 真彩色影像

本文运用的对比算法为传统 K-means 算法、PCA+K-means 算法和子空间波段选择+K-means 算法^[20]。在后文中分别叫作对比算法1、对比算法2以及对比算法3。传统 K-means 算法同等看待各个波段。PCA 是经典的降维方法, 通过改变特征空间, 选择前一个或几个主成分作为新的特征, 用于后续分类。本文中选择第一及第二主成分作为特征。子空间波段选择方法首先根据各波段影像的相关系数矩阵将波段划分为几个子空间; 然后在各子空间中找到方差最大的波段作为初始波段; 之后设定目标函数, 逐子空间替换波段使得目标函数达到最优。本文选择的目标函数为最佳指数。

Salinas 高光谱影像中包括 16 类地物目标, 分别为杂草——西兰花 1、杂草——西兰花 2、休耕地、休耕犁、光滑休耕地、农作物残茬、芹菜、未训练葡萄园 1、生长葡萄园、枯萎期玉米、4 星期莴苣、5 星期莴苣、6 星期莴苣、7 星期莴苣、未训练葡萄园 2、垂直篱壁式葡萄园, 分别记为 $C_1 \sim C_{16}$ 类。由于 Salinas 影像中类别为 16 类, 若 $h_i < 16$ ($i = 1, 2, \dots, D_0$), 则表示 i 波段对分类没有有利的影响, 认定为噪声波段, 需要删除, 因此选择阈值 T 为 16, 由于满足 $h_i < T$ ($i = 1, 2, \dots, D_0$) 条件的波段有 39 个, 则剩余波段为 165 个, 即在 Salinas 影像分类中, $D = 165$ 。

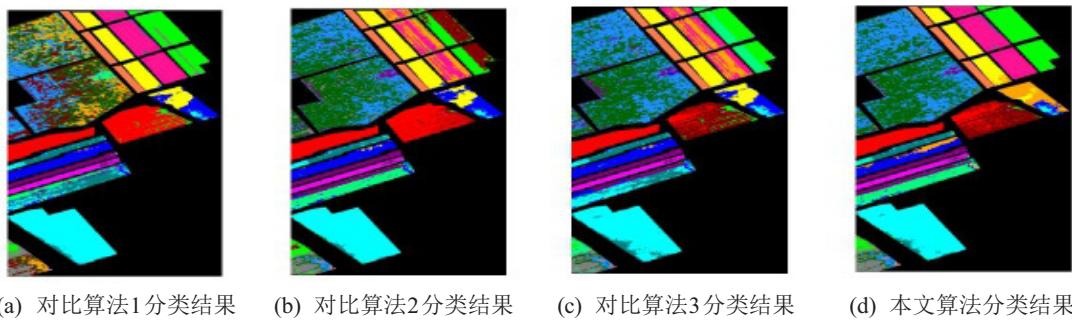


图3 Salinas分类结果

图3为Salinas高光谱影像的分类结果,其中,图3(a)~图3(d)分别为对比算法1分类结果、对比算法2分类结果、对比算法3分类结果和本文算法分类结果。

就视觉而言:对于 C_8 和 C_{15} 类的分类结果,本文算法明显好于对比算法1,与对比算法2和对比算法3的结果相似;对于 C_1 和 C_2 类的分类结果,本文算法明显好于对比算法1和对比算法2,较好于对比算法3;对于 C_6 和 C_7 类的分类结果,本文算法明显好于对比算法2和对比算法3,略好于对比算法1;对于 C_{10} 类,对比算法1和对比算法3产生了错分类;对于 C_3

类,只有本文算法得出了分类结果,3种对比算法都产生了错分类。

为了定量描述Salinas高光谱影像的分类结果,对图3的4个分类结果分别生成混淆矩阵并根据混淆矩阵计算用户精度、产品精度、总体精度以及Kappa系数(见表1)。

可以看出:在总精度方面,本文算法比其他3种对比算法都高,本文算法达到76.08%,比对比算法1高出20%多,比对比算法2高出14%多,比对比算法3高出11%多;在Kappa系数方面,本文算法比其他3种对比算法都大。

表1 Salinas影像分类结果用户精度、产品精度、总精度和Kappa系数

算法	精度/%	C_1	C_2	C_3	C_4	C_5	C_6	C_7	C_8	C_9	C_{10}	C_{11}	C_{12}	C_{13}	C_{14}	C_{15}	C_{16}
用户精度	37.38	0.09	0	95.24	73.46	99.97	86.34	59.05	84.97	47.47	28.82	59.38	68.45	92.95	42.72	67.41	
对比算法1 产品精度	99.95	0.11	0	99.00	97.68	96.01	91.14	29.25	94.49	16.90	75.09	98.60	98.03	87.48	29.55	41.56	
总精度/% = 55.83																	
用户精度	38.99	21.25	0	95.04	77.16	100	78.58	65.42	91.98	93.45	55.78	54.72	35.75	92.47	53.22	40.18	
对比算法2 产品精度	99.90	14.73	0	99.00	97.24	47.13	44.17	62.37	94.36	58.33	69.10	96.57	98.69	88.32	47.04	41.45	
总精度/% = 61.70																	
用户精度	73.10	98.95	0	95.64	73.59	99.80	84.57	71.30	76.35	0.05	31.15	56.66	34.68	94.35	54.33	77.41	
对比算法3 产品精度	98.61	71.15	0	99.07	97.91	50.90	56.52	61.14	89.21	0.03	76.22	97.35	98.58	88.97	60.54	44.38	
总精度/% = 64.38																	
用户精度	65.13	99.46	66.81	95.29	92.48	100	90.74	69.82	93.78	90.98	52.54	74.12	42.65	91.65	52.13	73.44	
本文算法 产品精度	99.40	69.22	68.57	98.78	92.79	96.26	98.24	60.17	92.31	59.67	74.63	77.89	98.47	89.25	62.91	48.20	
总精度/% = 76.08																	
Kappa系数 = 0.73																	

Salinas高光谱影像分类中,参数A和B根据总体精度的高低进行选取,通过控制变量法变换参数A和B,当总体精度达到最大值时,得到参数A和B的取值,参数A取2,B取2.5。

Pavia Centre高光谱影像中包括9种地物目标,分别为水、树木、柏油、砖、沥青、瓷砖、阴影、草地、裸土,分别记为 C_1 ~ C_9 类。由于Pavia Centre影像中类别为9类,选择阈值T为9,由于没有满足 $h_i < T$ ($i = 1, 2, \dots, D_0$)条件的波段,则不需要删除波段,

即在Pavia Centre影像分类中, $D = 102$ 。

图4为Pavia Centre高光谱影像的分类结果,其中,图4(a)~图4(d)分别为对比算法1分类结果、对比算法2分类结果、对比算法3分类结果和本文算法分类结果。

就视觉而言:对于 C_1 和 C_6 类的分类结果,本文算法好于其他3种对比算法;对于 C_7 类的分类结果,本文算法好于对比算法2,与对比算法1和对比算法3的结果相似;对于 C_3 类的分类结果,对比算法1和对

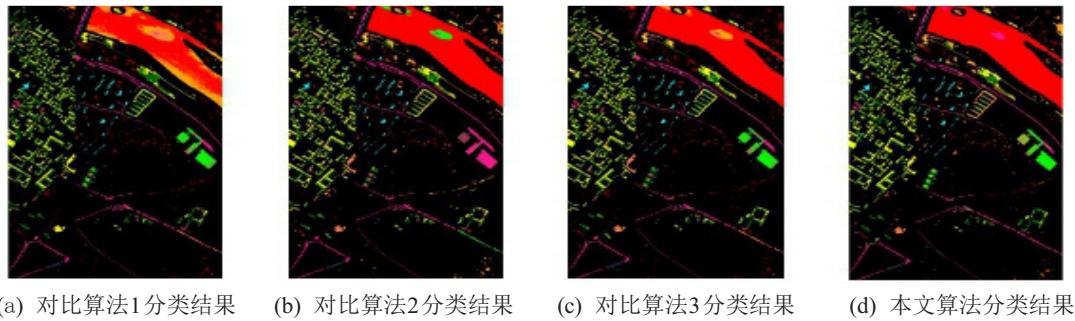


图4 Pavia Centre 分类结果

比算法3产生了错分类,对比算法2得到部分正确分类,本文算法大部分都是正确分类。

为了定量描述Pavia Centre高光谱影像的分类结

果,对图4的4个分类结果分别生成混淆矩阵并根据混淆矩阵计算用户精度、产品精度、总体精度以及Kappa系数(见表2)。

表2 Pavia Centre 影像分类结果用户精度、产品精度、总精度和Kappa系数

算法	精度/%	C_1	C_2	C_3	C_4	C_5	C_6	C_7	C_8	C_9
对比算法1	用户精度	100	70.77	0	0	16.85	63.78	87.61	86.49	99.72
	产品精度	69.38	96.92	0	0	55.53	90.59	72.51	55.66	99.90
	总精度/% = 65.57									
对比算法2	用户精度	99.97	77.17	36.77	13.35	12.27	50.11	0.91	82.16	99.55
	产品精度	95.99	58.16	59.26	20.93	42.19	91.40	0.41	46.50	99.41
	总精度/% = 70.30									
对比算法3	用户精度	100	71.10	0	12.11	13.56	67.77	90.17	84.83	100
	产品精度	95.75	92.68	0	19.85	47.68	91.72	68.73	46.60	100
	总精度/% = 74.38									
本文算法	用户精度	100	98.54	63.87	36.17	9.87	70.02	82.64	90.98	99.90
	产品精度	98.29	78.80	92.39	72.40	33.72	90.22	72.64	50.38	99.97
	总精度/% = 78.25									
Kappa系数 = 0.71										

可以看出:在总精度方面,本文算法比其他3种对比算法都高,本文算法达到78.25%,比对比算法1高出12%多,比对比算法2高出近8%,比对比算法3高出近4%;在Kappa系数方面,本文算法比其他3种对比算法都大。

Pavia Centre高光谱影像分类中,参数A和B同样通过控制变量法确定,参数A取2,B取4。

3 结论

本文提出了一种波段影像统计量加权K-means聚类的高光谱影像分类算法,在经典K-means算法的基础上考虑波段本身含有的信息量及波段间的相关性及各波段对各聚类的重要性,既拥有传统K-means算法不需采集样本的优势,又能充分合理地利用波段信息以达到分类的目的,在一定程度上还进行了波段选择。通过实验可知,该波段加权方式优于直接利用所有波段方式和经典的降维方式以及传统波段选择方式。当然,本文方法也存在不足之处,参数A和B通

过实验人为确定,有一定的局限性,在后期工作中,会考虑运用自适应性方式进行确定;该算法中没有考虑高光谱影像的空间信息,导致同物异谱及异物同谱的地物不能够实现很好的分类,接下来的工作中,将对同物异谱及异物同谱的地物分类问题进行更深入的研究。

参考文献(References)

- [1] Guo X, Huang X, Zhang L E, et al. Support tensor machines for classification of hyperspectral remote sensing imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(6): 3248-3264.
- [2] Qiu C, Liao G, Tang H, et al. Derivative parameters of hyperspectral NDVI and its application in the inversion of rapeseed leaf area index[J]. Applied Sciences, 2018, 8(8): 1300.
- [3] Mathieu M, Roy R, Launeau P, et al. Alteration mapping on drill cores using a HySpex SWIR-320m hyperspectral camera: Application to the exploration of

- an unconformity-related uranium deposit (Saskatchewan, Canada)[J]. Journal of Geochemical Exploration, 2017, 172: 71-88.
- [4] 徐庆, 马驿, 蒋琦, 等. 水稻叶片含水量的高光谱遥感估算[J]. 遥感信息, 2018, 33(5): 1-8.
(Xu Q, Ma Y, Jiang Q, et al. Estimation of rice leaf water content based on hyperspectral remote sensing[J]. Remote Sensing Information, 2018, 33(5): 1-8.)
- [5] Tang B, Liu Z, Xiao X Y, et al. Spectral-spatial hyperspectral classification based on multi-center SAM and MRF[J]. Optical Review, 2015, 22(6): 911-918.
- [6] Liao W Z, Goossens B, Aelterman J, et al. Hyperspectral image deblurring with PCA and total variation[C]. 2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Piscataway: IEEE, 2013: 1-4.
- [7] Fang Y, Li H, Ma Y, et al. Dimensionality reduction of hyperspectral images based on robust spatial information using locally linear embedding[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(10): 1712-1716.
- [8] Ziemann A K, Messinger D W, Wenger P S. An adaptive k-nearest neighbor graph building technique with applications to hyperspectral imagery[C]. 2014 IEEE Western New York Image and Signal Processing Workshop (WNYISPW). Rochester: IEEE, 2014: 32-36.
- [9] 杨刚, 孙伟伟, 张殿发. 利用可分离非负矩阵分解实现高光谱波段选择[J]. 武汉大学学报: 信息科学版, 2019, 44(5): 737-744.
(Yang G, Sun W W, Zhang D F. Separable nonnegative matrix factorization based band selection for hyperspectral imagery[J]. Geomatics and Information Science of Wuhan University, 2019, 44(5): 737-744.)
- [10] Zhai Y G, Zhang L F, Wang N, et al. A modified locality-preserving projection approach for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(8): 1059-1063.
- [11] 田洪晨, 王立国, 赵亮, 等. 结合波段选择的差分进化高光谱图像分类[J]. 应用科技, 2019, 46(5): 45-50.
(Tian H C, Wang L G, Zhao L, et al. Differential evolution hyperspectral image classification combined with band selection[J]. Applied Science and Technology, 2019, 46(5): 45-50.)
- [12] 贾隆嘉. 文本分类中特征加权算法和文本表示策略研究[D]. 长春: 东北师范大学, 2016.
(Jia L J. Research on the term weighting scheme and text representation strategy for text categorization[D]. Changchun: Northeast Normal University, 2016.)
- [13] Selim S Z, Ismail M A. *K*-means-type algorithms: A generalized convergence theorem and characterization of local optimality[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1984, 6(1): 81-87.
- [14] Coifman R R, Wickerhauser M V. Entropy-based algorithms for best basis selection[J]. IEEE Transactions on Information Theory, 1992, 38(2): 713-718.
- [15] 周荣喜, 刘善存, 邱莞华. 熵在决策分析中的应用综述[J]. 控制与决策, 2008, 23(4): 361-366.
(Zhou R X, Liu S C, Qiu W H. Survey of applications of entropy in decision analysis[J]. Control and Decision, 2008, 23(4): 361-366.)
- [16] 王志衡, 吴福朝. 均值-标准差描述子与直线匹配[J]. 模式识别与人工智能, 2009, 22(1): 32-39.
(Wang Z H, Wu F C. Mean-standard deviation descriptor and line matching[J]. Pattern Recognition and Artificial Intelligence, 2009, 22(1): 32-39.)
- [17] 曾勇, 杨煜普, 赵亮. 基于局部均值与类均值的近邻分类[J]. 控制与决策, 2009, 24(4): 547-550.
(Zeng Y, Yang Y P, Zhao L. Nearest neighbour classification based on local mean and class mean[J]. Control and Decision, 2009, 24(4): 547-550.)
- [18] 茅诗松, 王静龙, 潘晓龙. 高等数理统计 [M]. 2 版. 北京: 高等教育出版社, 2006: 18-24.
(Mao S S, Wang J L, Pu X L. Advanced Mathematical Statistics[M]. The 2nd edition. Beijing: Higher Education Press, 2006: 18-24.)
- [19] 范雪莉, 冯海泓, 原猛. 基于互信息的主成分分析特征选择算法[J]. 控制与决策, 2013, 28(6): 915-919.
(Fan X L, Feng H H, Yuan M. PCA based on mutual information for feature selection[J]. Control and Decision, 2013, 28(6): 915-919.)
- [20] 赵亮, 王立国, 刘丹凤. 高光谱图像子空间的波段选择[J]. 遥感学报, 2019, 23(5): 904-910.
(Zhao L, Wang L G, Liu D F. A subspace band selection method for hyperspectral imagery[J]. Journal of Remote Sensing, 2019, 23(5): 904-910.)

作者简介

- 李玉(1963-), 男, 教授, 博士生导师, 从事遥感影像处理等研究, E-mail: Intuliyu@163.com;
- 甄畅(1994-), 女, 硕士生, 从事遥感影像处理的研究, E-mail: zhenchang1126@163.com;
- 石雪(1992-), 女, 博士生, 从事遥感影像处理的研究, E-mail: 18841842890@163.com;
- 朱磊(1989-), 男, 本科, 从事摄影测量与遥感的研究, Email: 873257999@qq.com.

(责任编辑: 闫妍)