

DOI: 10.11992/tis.201703023

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20170702.1547.030.html>

基于最大最小距离的高光谱遥感图像波段选择

王立国, 赵亮, 石瑶

(哈尔滨工程大学信息与通信工程学院, 黑龙江 哈尔滨 150001)

摘 要: 为减少高光谱遥感图像光谱空间冗余, 降低后续处理的计算复杂度, 提出一种基于最大最小距离的高光谱图像波段选择算法。首先计算波段标准差, 选定标准差最大的波段作为初始中心; 然后使用最大最小距离算法得到相对距离较远的聚类中心, 对波段进行聚类; 最后使用 K 中心点算法更新聚类中心。实验仿真结果表明: 通过基于最大最小距离算法选择的波段, 能够选出同时满足信息量大、相关性小的要求的波段子集, 并将获得的波段组合用于高光谱图像分类时, 可以得到较好的分类精度。

关键词: 高光谱遥感; 波段选择; 波段聚类; 无监督; 最大最小距离算法; K-medoids 聚类; 最大似然法; 分类

中图分类号: TN911.73, TP391 **文献标志码:** A **文章编号:** 1673-4785(2018)01-0131-07

中文引用格式: 王立国, 赵亮, 石瑶. 基于最大最小距离的高光谱遥感图像波段选择[J]. 智能系统学报, 2018, 13(1): 131-137.

英文引用格式: WANG Ligu, ZHAO Liang, SHI Yao. Maximin distance algorithm-based band selection for hyperspectral imagery[J]. CAAI transactions on intelligent systems, 2018, 13(1): 131-137.

Maximin distance algorithm-based band selection for hyperspectral imagery

WANG Ligu, ZHAO Liang, SHI Yao

(College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract: In this paper, we propose a hyperspectral-image band-selection algorithm based on the maximin distance to reduce the spectral redundancy of hyperspectral remote sensing images as well as the associated computational complexity. First, the algorithm computes the standard deviation of all bands and selects the one with the maximum standard deviation as the initial center. Then, to cluster the bands, we use the maximin distance algorithm to obtain centers that are relatively farther away. Finally, we use the k-medoids algorithm to update the clustering center. The experimental results show that the bands selected by the maximin distance algorithm can satisfy the demands associated with a large amount of information and relatively low correlation. At the same time, when the obtained bands are combined for hyperspectral image classification, higher classification accuracy can be achieved.

Keywords: hyperspectral images; band selection; band clustering; unsupervised; maximin distance; K-medoids clustering; maximum likelihood method; classification

随着遥感技术的快速发展, 高光谱图像分析也有了重大进展。高光谱数据因其波段众多可以提供地物更精确详尽的信息, 但与此同时也带来了信息冗余, 因而在对数据分析时会产生较高的计算复杂度以及 Hughes 现象, 所以在高光谱图像处理过程

中, 降维是其重要环节。遥感数据降维有两种方法: 特征提取和波段选择。特征提取是用映射的方法将原始数据变换为较少的新特征, 常用的方法有主成分分析、独立成分分析、局部线性嵌入等^[1-3]。与特征提取不同, 波段选择依据高光谱遥感数据的特点从原始数据集中选择合适的波段子集, 在不改变原始数据的物理意义及光谱特性的同时降低数据维度, 是一种有效的高光谱图像降维技术。

按照先验信息的有无, 高光谱图像波段选择方

收稿日期: 2017-03-17 **网络出版日期:** 2017-07-02.

基金项目: 国家自然科学基金项目 (61675051); 国家教育部博士点基金项目 (20132304110007); 黑龙江省自然科学基金项目 (F201409).

通信作者: 王立国. E-mail: wangliguo@hrbeu.edu.cn.

法可分为监督波段选择和无监督波段选择^[4]。监督波段选择一般用一个准则函数来衡量已选波段与带标签数据之间的相似度,然后通过一些优化策略来搜索最优波段子集^[5]。无监督波段选择则只需要地物的原始高光谱图像信息,而无需带标签样本,因而更具有普适性,因此本文主要研究无监督的波段选择。

无监督的波段选择方法一般可分为如下几类:一类是按照信息量以及波段间相关程度排序的方法,一类是基于聚类的方法,此外由于端元选择与波段选择问题在模型上具有共性,一些端元选择方法也用于波段选择中^[6]。最大方差主成分分析方法(maximum-variance principle component analysis, MVPCA)是一种经典的基于信息量的方法,它利用PCA变换获取各波段的方差,将方差作为信息量的考量标准,然后按照方差的大小进行排序,以确定波段的优先级^[7]。基于信息散度(information divergence, ID)的波段选择方法是用信息散度对全波段计算概率密度分布与其所对应的高斯分布的偏离度,按照偏离度从大到小的顺序对波段进行排序,得到所需数目的波段子集^[8]。但鉴于高光谱数据的相邻波段具有较大相关性,按照信息量排序所选定的某波段,其相邻的波段也极有可能具有相近的信息量,因此也会被选入波段子集,造成冗余。于是,一些同时考虑信息量与相关系数的无监督波段选择方法被提出来,如最佳指数因子(optimal index factor, OIF)法计算波段的方差与相关系数的比值,再用这个数值来衡量波段的优先次序。但是OIF方法需要多次计算波段间的OIF,因此计算量庞大。自适应波段选择方法(adaptive band selection, ABS)与OIF方法类似,采用标准差与相关系数的比值作为考量标准,但较之OIF,ABS只计算相邻波段的相关系数,虽然计算复杂度较低,却忽视了所选波段子集的整体相关性^[9]。近些年,一些学者用聚类的方法进行波段选择,即将波段按照某衡量准则分成多个子集,用聚类中心代表子集内的其他波段,聚类数目根据所需的波段数确定。具有代表性的方法如基于K均值(K-means)算法的波段选择,基于谱聚类(spectral clustering, SC)的波段选择,使用仿射传播(affinity propagation, AP)的波段选择等^[10-12]。K均值算法简单易行,但是容易受初值影响,并且所选择的聚类中心是算术平均的位置,需要进一步处理。基于K-medoids的聚类直接选取候选波段作为波段的聚类中心,具有很好的鲁棒性,但该方法同样易受初始值影响,随着初值的不同而导致最后的聚类中心不同。基于SC的波段选择方法采用类内波段算术均值而非现实中存在的

波段,对噪声敏感,且每类中随机选取的波段不一定能够最好地代表所在的类。基于AP算法的波段选择方法将每个样本点都视为候选类代表点,不受初始点选择的困扰,但相似矩阵的计算复杂度较高。而最大最小距离算法是一种基于试探的聚类算法,它以某种距离作为衡量标准,采用相距尽量远的样本作为聚类中心点,可以避免随机选取的初始聚类中心相距太近的情况^[13]。针对现有波段选择方法的不足,本文提出了一种基于最大最小距离的波段选择方法,该方法通过迭代计算得到一组初始的距离较远的波段子集,然后以这些波段为基础进行聚类更新,获取具有代表性的波段子集。

1 波段聚类的基础

高光谱数据的特点是具有极高的光谱分辨率,其相邻波段间具有较强的相关性,这里的谱间相关性就是指,对空间上某一相同位置,相邻波段的波段图像具有相似性。具有这种相似的原因主要是:同一地物在相邻波段的光反射率是非常相近的,因此产生了一定的相关性。这种相关性可以用相关系数矩阵来描述^[14],以AVIRIS采集的印第安农林数据为例,计算其相关系数矩阵和相关系数向量,并将得到的矩阵和向量进行可视化,如图1。




图1 Indian数据谱间相关性的可视化

Fig. 1 Visualization of spectral correlation of Indian Pines

图1中,(a)是以灰度图像的形式呈现,由灰度图像的取值特点可知,越明亮的区域其相关系数越大,而明亮区域主要集中于主对角线,因此可以说相邻波段间的相关性更强,而从图1(b)可以直观看到相关性较强的各个波段范围。鉴于高光谱图像波段间具有的这种聚集特性,可以将其看作波段聚类问题,即将波段划分为具有相似特性的波段组成的集合,选择这些波段集合中具有代表性的聚类中心,就可以得到数据的一个波段子集,从而完成波段选择过程。

2 基于最大最小距离的波段选择

最大最小距离法是模式识别中一种基于试探的

聚类算法, 它以欧氏距离为基础, 取尽可能远的对象作为聚类中心。因此它可以避免 K-means 算法初值选取时可能出现的聚类种子过于临近的情况, 它不仅能智能确定初始聚类种子的个数, 而且提高了划分初始数据集的效率。所以, 本文尝试利用最大最小距离法进行高光谱图像的波段选择, 以方差最大的波段作为第一个聚类中心, 不断迭代计算最大最小距离获取所需数目的聚类中心集合, 进而对集合外的剩余波段聚类, 最后以 K-medoids 方法对聚类中心进行更新, 获取最终波段子集, 具体描述如下。

2.1 初始化聚类中心

2.1.1 第一个聚类中心的选取

在数据处理上, 高光谱图像用集合 $B = \{b_1, b_2, \dots, b_n\}$ 表示, 其中, n 为波段个数, $b_i (i = 1, 2, \dots, m)$ 为 m 行的列向量, 代表第 i 个波段, m 为波段图像包含的像素个数, 则波段 i 的标准差值为

$$s_i = \left((1/m) \sum_{l=1}^m (b_{il} - \mu_i)^2 \right)^{1/2} \quad (1)$$

式中 μ_i 为波段 i 的均值, 即

$$\mu_i = (1/m) \sum_{l=1}^m b_{il} \quad (2)$$

波段均值 μ_i 可以用于表征波段 i 各地物的平均强度; 波段标准差 s_i 可以反应波段 i 中像素强度与均值的偏离程度, 一定程度上反映各波段图像的信息量, 图像标准差越大, 其所包含的信息越丰富, 因此可以采用标准差值定量表示波段包含的信息量, 并用标准差最大的波段作为最大最小距离算法第 1 个聚类中心 B_1 。

2.1.2 其他聚类中心的迭代选取

设最大最小距离算法最后得到的聚类中心为集合 $B_s = \{B_1, B_2, \dots, B_k\}$, 其中 k 为聚类中心个数, 即所选波段个数。根据 2.1.1 节的结果可知, 第 1 个初始聚类中心 B_1 可表示为

$$B_1 = \arg \max s_i \quad (3)$$

则 $B_s = \{B_1\}$ 。然后计算 B 中其他波段与 B_1 的距离, 选择距离最大的波段作为第 2 个类的聚类中心 B_2 , 可表示为

$$B_2 = \arg \max d(b_i, B_1) \quad (4)$$

这里 $d(\cdot)$ 表示某种距离测度, 则 B_s 更新为 $\{B_1, B_2\}$ 。

当 k 大于 2 时, 则第 k 个聚类中心 B_k 为 B 中剩余波段中 b_i 与 B_s 中的波段的最大最小距离, 表示为

$$B_k = \arg \max d(b_i, \text{MIN}_{k-1}) \quad (5)$$

式中 $\text{MIN}_{k-1} = \min\{d(b_i, B_1), d(b_i, B_2), \dots, d(b_i, B_{k-1})\}$, 此时 B_s 更新为 $\{B_1, B_2, \dots, B_k\}$ 。

2.2 更新聚类中心

通过最大最小距离方法得到了相互距离较远的

一组波段, 在原本的最大最小距离算法中会将这组波段作为聚类中心, 然后计算其他波段与这些中心的距离, 以距离最小为原则划分类别。虽然这些波段间的区分度较高, 但会导致聚类中心与簇内相距较远波段的相关性较低, 而对于波段选择来说, 其最终得到的应该具有代表性的波段, 也就是说, 该波段到簇内其他波段间的代价函数应该最小。因此将这些“激进”但区分度又高的波段组合作为一个初始的聚类中心, 然后采用对噪声较不敏感的 K-medoids 算法更新聚类中心, 得到最终的波段组合。具体的步骤如下:

1) 选择 B_s 作为初始中心点;

2) 计算 B 中剩余波段与 B_s 中各波段的距离, 以距离最小为准则进行分配;

3) 在每一个类内, 选择代价函数最小的波段作为新的聚类中心;

4) 重复 2)、3) 直至各类的中心点稳定, 此时算法结束。

算法的整体流程如下。

算法 基于最大最小距离的波段选择方法

输入 给定所需的波段数目 k 。

1) 根据式 (1)、(2) 计算每个波段的标准差 s_i , 取标准差最大的波段作为 1 个聚类中心 B_1 ;

2) 计算剩余波段与 B_1 间距离, 取距离最小的波段作为第 2 个聚类中心 B_2 ;

3) 当 $k > 2$ 时, 按照式 (5) 迭代选择剩余的聚类中心, B_s 更新为 $\{B_1, B_2, \dots, B_k\}$;

4) 以最近邻原则将 B 中剩余波段划分给 B_s 中的各个聚类中心;

5) 用 K-medoids 算法更新聚类中心 B_s , 输出最终的波段组合。

3 实验与分析

为验证本文算法的有效性, 采用真实高光谱数据进行了仿真实验, 同时与基于 K-medoids, 基于 AP, 以及基于 ABS 的典型波段选择算法进行比较。第 1 种和第 2 种是基于聚类方法的波段选择, 第 3 种是同时考量了信息量与相关性的波段选择方法。实验环境为 AMD 双核处理器, 主频 2.47 Hz, 有效内存 3 GB, 开发环境为 MATLAB R2008a。

实验数据为去除噪声波段的 200 波段的 AVIRIS 印第安农林数据和 103 波段的 ROSIS 帕维亚大学数据:

1) 印第安农林数据的波长范围为 $0.4 \sim 2.5 \mu\text{m}$, 空间分辨率为 17 m, 共有 144×144 个像素点。数据中剔除背景共包含 16 类地物, 主要农作物是生长

期的玉米和大豆,结合地面实际测量数据,其中7种地物样本量过少,对于该数据不具有代表性,因此选取另9种样本数目较多的主要类型地物用于实验。

2) 帕维亚大学数据波长范围为 $0.43 \sim 0.86 \mu\text{m}$, 空间分辨率为 1.3 m , 共有 610×340 个像素点, 共包含9类地物, 实验中9种地物均用于实验。两组数据所对应的地物真实情况如图2、图3所示, 9种地物类型及数目如表1所示。




图2 Indian 数据

Fig. 2 Land covers at Indian pines

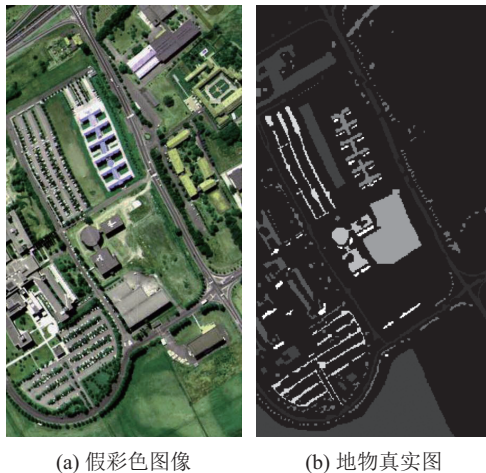


图3 PaviaU 数据

Fig. 3 Land covers at university of Pavia

表1 印第安农林数据和帕维亚大学数据地物类别

Table 1 Land covers at Indian pines and university of pavia

印第安农林数据 地物类别(数目)	帕维亚大学数据 地物类别(数目)
Corn-notill (1 434)	Asphalt (6 641)
Corn-min (834)	Meadows (18 649)
Grass/Pasture (497)	Gravel (2 099)
Soybeans-notill (968)	Trees (3 064)
Soybeans-clean (614)	Metal Sheets (1 345)
Grass/Trees (747)	Soil (5 029)
Hay-windrowed (489)	Bitumen (1 330)
Soybeans-min (2 468)	Bricks (3 682)
Woods (1 294)	Shadows (947)

3.1 评价标准

对于高光谱遥感图像,一般评价所选波段组合的优劣主要是面向应用的角度,其中地物的分类是一个重要的应用方法,因此本文以总体分类精度 (overall accuracy, OA) 为主评价波段选择方法的质量,同时辅助地考虑波段子集的平均相关性、信息贡献率、最佳指数 (optimum index factor, OIF), 计算公式为

$$\bar{R} = \frac{1}{C^2} \sum_{i=1}^{m-1} \sum_{j=i+1}^m R_{ij} \quad (6)$$

式中: C 为样本总数, R_{ij} 为波段 i 和波段 j 的相关系数, 计算公式为

$$R_{ij} = \frac{\sum_{k=1}^n (x_{ik} - \bar{x}_i)(x_{jk} - \bar{x}_j)}{\sqrt{\sum_{k=1}^n (x_{ik} - \bar{x}_i)^2 \sum_{k=1}^n (x_{jk} - \bar{x}_j)^2}} \quad (7)$$

式中: $\mathbf{x}_i = [x_{i1} x_{i2} \cdots x_{in}]^T$ 为第 i ($i = 1, 2, \cdots, m$) 个波段, \bar{x}_i 是第 i 个波段的均值。选择的 m 个波段的信息量贡献为

$$o_{R_{var}}(m) = \frac{\sum_{g=1}^m \lambda_g}{\sum_{k=1}^n \lambda_k} \times 100\% \quad (8)$$

式中: n 为波段总数, m 为所选波段的个数, 通常 $m \leq n$, λ_g ($g = 1, 2, \cdots, m$) 是所选波段经主成分变换后的特征值; λ_k ($k = 1, 2, \cdots, n$) 是全波段主成分变换得到的特征值。

$$O_{OIF} = \frac{\sum_{i=1}^n S_i}{\sum_{i=1}^n \sum_{j=1}^n |R_{ij}|} \quad (9)$$

式中: S_i 是第 i 波段的标准差。

$$O_{OA} = \frac{\sum_{i=1}^c m_{ii}}{C} \quad (10)$$

式中: m_{ii} 为第 i 类测试样本被正确分类的样本数, c 为样本类别数^[15]。

3.2 结果分析

为定量比较几种波段选择方法随所选波段数目的变化趋势, 所以选择连续变化的波段数目。分类采用最大似然分类法, 训练样本数目与测试样本数目各占总样本数目的一半。同时, 也将只进行最大最小距离选择而未更新聚类中心的结果进行比较, 在效果评价图中用 MMD 表示, 本文算法记作 MM-DK。各波段选择算法在两组数据上所选波段子集的总体分类精度、最佳指数、信息贡献率、平均相关性和总体分类精度的结果分别绘制于图4、5中。下面分别对两组数据的实验结果进行分析。

3.2.1 Indian 数据集

Indian 数据集所选的波段数目为 5~15, 从两方面分析各算法在该数据集上所选波段的性能。




图4 不同波段选择方法在 Indian 数据的效果评价

Fig. 4 Evaluation of effects of different wavelength selection methods for Indian data

1) 分类结果分析

从图4(a)中可以看到, AP、ABS、MMD 和本文所提算法所得波段的总体分类精度随波段数目的增加而稳定上升, 但无论所选的波段数目是多少, 本文所提算法获取的波段组合总能够得到最高的分类精度。而 MMD 虽然选择了光谱维度上“距离”较远的波段, 但分类效果并不理想, 这也说明“激进”的波段并不能代表其所在的聚类, 需要进一步更新聚类中心。K-medoids 算法所选的波段组合随波段数目

的增加具有波动性, 再一次证明初始聚类中心对于保证波段选择效果的重要性。




图5 不同波段选择方法在 PaviaU 数据的效果评价

Fig. 5 Evaluation of effects of different wavelength selection methods for PaviaU data

2) 信息量与相关性结果分析

对于信息量与相关性的考量则需要结合图4(b)、(c)、(d)一起分析。从图4中可以看出, ABS 算法在信息量及综合考虑二者的 OIF 上均表现得很优秀, 这是由于 ABS 是基于 OIF 而进行的改进, 采用标准差与相关系数的比值作为考量标准, 但 ABS 相较 OIF 是只计算相邻波段的相关系数, 忽视了所选波段子集的整体相关性, 因此其平均相关性较低。K-medoids 算法受随机初始化的影响, 所选的波段

组合依然不稳定。本文所提算法在平均相关性与信息量上结果居中,与 MMDK 相比平均相关性稍高,信息量也较小,但却说明一个问题:具有高信息量与低相关性的波段组合不一定是最能体现各波段聚类的,并且应用到实际问题中时的表现也不一定最优。这是因为,若以信息量大小排序来选择波段,当某波段入选,则相邻波段由于具有与其近似的波段图像,因此相邻波段也具有较高入选优先性。虽然 OIF 考虑了相关性,但直接用方差与相关系数的比值来全面衡量二者,其结果较为生硬。

3.2.2 PaviaU 数据集

PaviaU 数据集所选的波段数目为 3~13,同样从两方面分析各算法在该数据集上所选波段的性能。

1) 分类性能分析

因为 PaviaU 数据集的空间分辨率较高,混合像素较少,并且地物种类与 Indian 数据相比,类别差异性更大,相对而言更容易区分,分类精度也更高。图 5(a) 中 MMDK 算法始终保持着较高的分类精度,而 ABS 算法在波段数目为 3 时分类精度较低,这是由于 ABS 算法虽以信息量与相关性为选择波段的标准,但其为计算便捷,会忽略波段组合整体相关性,因此容易选出相关性较高的波段子集,当所选波段数据较少时,这种差异性较其他方法会更明显。随机选择初始聚类中心的 K-medoids 算法整体依然存在波动性。AP 算法在波段数目 3~6 区间时,具有较好的分类精度,但当大于 6 时相较 MMDK 分类精度低,这与 AP 算法中参考度 p 有关, p 代表着相似度值,其值越大则簇越多,所以需要较多的簇时, p 就需要取较大的相似度值,使得其各簇中心相似度较高,而对于波段选择来说,这是不利的。MMD 算法整体分类精度与 MMDK 相仿,这主要是由于该数据相似波段之间距离较小,波段聚集密度较高,所以二者具有水平相当分类能力。

2) 信息量与相关性结果分析

结合图 5(b)、(c)、(d) 来分析各算法在 PaviaU 数据集所选波段子集包含的信息量与平均相关性可以看到,ABS 算法在 OIF 值上依然整体占优,其他几种算法有着接近的 OIF 值。在信息量贡献率上 ABS 同样较其他算法得到较高的贡献率,但其平均相关性也更高,这依然由 ABS 算法优先将近似的但拥有较大信息量的波段选择到子集中,忽略波段子集的整体相关性导致。其他几种聚类算法除 K-medoids 具有波动性外,在各评价函数上均相差不大,这是由于 PaviaU 数据各波段簇较紧密所致。

通过两组数据的实验可以看出,MMDK 算法所选的波段子集在两种数据集上均获得较高的分类精

度,且其各性能随波段数目的增加均呈现平稳趋势,证明了算法的有效性与稳定性。而基于聚类的波段选择与基于信息属性的波段选择方法也有不同,基于聚类的波段选择更倾向于选择最具代表性的,而不是波段本身差异性大的,因此波段子集的信息量较基于信息属性所选择的波段子集低。而 MMDK 在信息量与相关性的评价中,虽始终居中,但这符合波段聚类中心需要更有代表性,而不是差异性大的选择标准。综上,可以得出结论,MMDK 算法是一种行之有效的波段选择方法。

4 结束语

本文针对高光谱图像波段冗余问题,提出了基于最大最小距离的波段选择算法,该算法只需要输入待选波段的数目,不需要进行其他参数的设置,通过迭代计算已选波段与待选波段间的最大最小距离获取初始的聚类中心,然后用 K-medoids 更新此聚类中心,最终输出波段子集。此方法物理意义明确,便于实现。与基于 K-medoids 算法、基于 AP 算法、基于 ABS 算法的波段选择方法所进行的对比实验表明,基于 MMDK 算法的波段选择方法较其他 3 种典型波段选择算法在分类精度方面更理想,生成的波段组合也更稳定,更加能够满足实际需求。

未来的研究工作可从如下两方面展开:1) 本文在计算距离时,采用的是欧氏距离,而衡量波段间区分性的还有光谱角距离、Bhattacharyya 距离、JM 距离等,不同的距离计算方式对聚类结果的影响如何,有待讨论;2) 文中是通过给定波段子集大小的方式确定聚类中心的个数,而若给定的数目太小则不足以描述数据,给定的数目过多又会造成冗余,同样影响后续应用的效果,因此如何自动地确定不同数据集所需的波段数目也是一个值得研究的问题。

参考文献:

- [1] AGARWAL A, EL-GHAZAWI T, EL-ASKARY H, et al. Efficient hierarchical-PCA dimension reduction for hyperspectral imagery[C]//Proceedings of 2007 IEEE International Symposium on Signal Processing and Information Technology. Giza, Egypt, 2007: 353–356.
- [2] WANG Jing, CHANG C I. Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis[J]. IEEE transactions on geoscience and remote sensing, 2006, 44(6): 1586–1600.
- [3] LI Wei, PRASAD S, FOWLER J E, et al. Locality-preserving dimensionality reduction and classification for hyperspectral image analysis[J]. IEEE transactions on geoscience and remote sensing, 2012, 50(4): 1185–1198.

- [4] 刘雪松, 葛亮, 王斌, 等. 基于最大信息量的高光谱遥感图像无监督波段选择方法[J]. 红外与毫米波学报, 2012, 31(2): 166–170, 176.
LIU Xuesong, GE Liang, WANG Bin, et al. An unsupervised band selection algorithm for hyperspectral imagery based on maximal information[J]. Journal of infrared and millimeter waves, 2012, 31(2): 166–170, 176.
- [5] FENG Jie, JIAO L C, ZHANG Xiangrong, et al. Hyperspectral band selection based on trivariate mutual information and clonal selection[J]. IEEE transactions on geoscience and remote sensing, 2014, 52(7): 4092–4105.
- [6] 王立国, 邓禄群, 张晶. 改进的 SGA 端元选择的快速方法[J]. 应用科技, 2010, 37(4): 1–22.
WANG Ligu, DENG Luqun, ZHANG Jing. A fast end-member selection method based on simplex growing algorithm[J]. Applied science and technology, 2010, 37(4): 1–22.
- [7] CHANG C I, DU Qian, SUN T L, et al. A joint band prioritization and band-decorrelation approach to band selection for hyperspectral image classification[J]. IEEE transactions on geoscience and remote sensing, 1999, 37(6): 2631–2641.
- [8] CHANG C I, WANG Su. Constrained band selection for hyperspectral imagery[J]. IEEE transactions on geoscience and remote sensing, 2006, 44(6): 1575–1585.
- [9] 刘春红, 赵春晖, 张凌雁. 一种新的高光谱遥感图像降维方法[J]. 中国图象图形学报, 2015, 10(2): 218–222.
LIU Chunhong, ZHAO Chunhui, ZHANG Lingyan. A new method of hyperspectral remote sensing image dimensional reduction[J]. Journal of image and graphics, 2015, 10(2): 218–222.
- [10] AHMAD M, HAQ I U, MUSHTAQ Q, et al. A new statistical approach for band clustering and band selection using K-means clustering[J]. IACSIT international journal of engineering and technology, 2011, 3(6): 606–614.
- [11] 秦方普, 张爱武, 王书民, 等. 基于谱聚类与类间可分性因子的高光谱波段选择[J]. 光谱学与光谱分析, 2015, 35(5): 1357–1364.
QIN Fangpu, ZHANG Aiwu, WANG Shumin, et al. Hyperspectral band selection based on spectral clustering and inter-class separability factor[J]. Spectroscopy and spectral analysis, 2015, 35(5): 1357–1364.
- [12] DUECK D. Affinity propagation: clustering data by passing messages[D]. Toronto, Canada: University of Toronto, 2009.
- [13] 成卫青, 卢艳虹. 一种基于最大最小距离和 SSE 的自适应聚类算法[J]. 南京邮电大学学报: 自然科学版, 2015, 35(2): 102–107.
CHENG Weiqing, LU Yanhong. Adaptive clustering algorithm based on maximum and minimum distances, and SSE[J]. Journal of Nanjing university of posts and telecommunications: natural science edition, 2015, 35(2): 102–107.
- [14] 刘颖, 谷延锋, 张晔, 等. 一种高光谱图像波段选择的快速混合搜索算法[J]. 光学技术, 2007, 33(2): 258–261, 265.
LIU Ying, GU Yanfeng, ZHANG Ye, et al. A fast hybrid search algorithm for band selection in hyperspectral images[J]. Optical technique, 2007, 33(2): 258–261, 265.
- [15] 王立国, 肖倩. 结合 Gabor 滤波和同质性判定的高光谱图像分类[J]. 应用科技, 2013, 40(4): 21–26.
WANG Ligu, XIAO Qian. Hyperspectral imagery classification combined with Gabor filtering and homogeneity discrimination[J]. Applied science and technology, 2013, 40(4): 21–26.

作者简介:



王立国, 男, 1974 年生, 教授, 博士生导师, 主要研究方向为遥感图像处理与机器学习。主持国家自然科学基金 3 项, 发表学术论文 150 余篇, 其中被 SCI 检索 40 余篇, EI 检索 100 余篇, 授权国家专利 20 余项, 出版专著 2 部。



赵亮, 女, 1987 年生, 博士研究生, 主要研究方向为高光谱遥感图像波段选择与分类, 发表学术论文 8 篇。



石瑶, 女, 1988 年生, 博士研究生, 主要研究方向为高光谱遥感图像亚像元定位。