

噪声鲁棒的高光谱图像波段选择方法

路燕, 任月, 崔宾阁

山东科技大学 计算机科学与工程学院, 山东 青岛 266590

摘要: 目前大多数高光谱图像波段选择方法仅考虑波段信息冗余问题, 忽略了所选波段的噪声水平, 致使选取的代表性波段子集中可能含有噪声水平较高的波段。为解决这一问题, 本文提出一种噪声鲁棒的高光谱图像波段自适应分区与子空间搜索方法。首先, 基于皮尔逊相关系数构造高光谱图像波段相关性矩阵; 然后, 将高光谱图像光谱波段等分为若干子空间, 通过构造与皮尔逊相关系数相适应的子空间划分最优目标函数, 自适应地调整子空间的分割点; 最后, 综合考虑波段的信息熵和噪声水平, 在子空间波段选择时将噪声水平以惩罚项的形式反映在优化问题的目标函数中。在 Indian Pines、Washington DC 和 Salinas 这 3 个数据集上进行了实验, 采用波段平均相关性、分类精度两种指标对不同方法的波段选择结果进行评价, 并分析各种波段选择方法的噪声鲁棒性。实验结果表明, 本文方法能够挑选出信息量大且噪声水平低的代表性波段。与其它波段选择方法相比, 本文方法所选择的代表性波段平均相关性弱, 分类精度高, 在包含噪声波段的高光谱图像中效果尤为显著。

关键词: 高光谱, 波段选择, 噪声鲁棒, 子空间划分, 搜索准则

中图分类号: P2

引用格式: 路燕, 任月, 崔宾阁. 2022. 噪声鲁棒的高光谱图像波段选择方法. 遥感学报, 26(11): 2382-2398

Lu Y, Ren Y and Cui B G. 2022. Noise robust band selection method for hyperspectral images. National Remote Sensing Bulletin, 26(11): 2382-2398 [DOI: 10.11834/jrs.20211128]

1 引言

高光谱传感器以数十至数百个连续且细分的光谱波段对目标区域同时成像, 形成了包含数十至数百个波段的高光谱图像 (HSI Hyperspectral Image) (张良培和李家艺, 2016)。由于包含丰富的光谱和空间信息, 高光谱图像被广泛应用于各种任务, 如复杂环境下的地物精细分类 (Thenkabail 和 Lyon, 2011; 崔宾阁等, 2019)、目标检测 (Nasrabadi, 2014; Zhu 等, 2019) 和植被面积估计 (Lees, 2020) 等。高维度的光谱数据在为图像处理提供更多光谱信息的同时, 也带来了维数灾难、信息冗余、计算复杂度高和存储成本巨大等问题 (Fauvel 等, 2013)。因此, 维度约减已成为高光谱图像处理的一个重要环节 (Zhao 和 Du, 2016)。

高光谱图像降维方法通常可以分为两类: 特征提取和波段选择 (Cui 等, 2020)。特征提取是

根据某种准则将高维数据映射到一个特定的低维特征空间中, 并提取新的特征值来表示原始高维数据 (Sun 等, 2014; Dópidio 等, 2012)。典型的特征提取方法包括主成分分析 PCA (Principal Component Analysis) (Chang 等, 1999)、独立成分分析 ICA (Independent Component Algorithm) (Wang 和 Chang, 2006)、线性判别分析 LDA (Linear Discriminant Analysis) (Bandos 等, 2009; Zhai 等, 2019) 和局部线性嵌入 LLE (Locally Linear Embedding) (Li 等, 2012) 等。经过上述的空间变换, 原始高光谱图像波段的物理含义发生了变化, 并且丢失了一些关键信息 (Yang 等, 2012)。与特征提取方法不同, 波段选择是从高光谱图像中选择出信息量较大、相关性较弱、类别可分性较好的波段组合, 因而基本保留了地物的固有物理属性 (Wang 等, 2018)。常用的波段选择方法有基于排名、基于搜索、基于聚类、基于稀疏性、基于

收稿日期: 2021-03-13; 预印本: 2021-09-11

基金项目: 国家重点研发计划 (编号: 2017YFC1405600); 国家自然科学基金 (编号: 42276185, 62073387, 42076189); 山东省自然科学基金 (编号: ZR2020MD096, ZR2020MD099)

第一作者简介: 路燕, 研究方向为智能信息处理、遥感图像分类和目标检测研究。E-mail: luyan@sdust.edu.cn

通信作者简介: 崔宾阁, 研究方向为高光谱遥感、海洋和海岸带遥感监测技术研究。E-mail: cuibinge@sdust.edu.cn

嵌入学习和基于混合方案等 (Sun 和 Du, 2019)。

基于聚类的波段选择方法是高光谱图像降维的重要方法 (Sun 和 Du, 2019)。该方法首先通过聚类将原始波段分组, 然后从每组中选择一个代表性波段。最早的高光谱图像波段聚类方法是基于 Ward 链接的分层聚类 (Martínez-Usómartínez-Uso 等, 2007)。之后, 基于聚类的各种高光谱图像波段选择方法陆续被提出, 如 Rodriguez 和 Laio (2014) 提出基于密度峰值的快速聚类算法 FDPC (Fast Density-Peak-based Clustering), 该算法通过计算每个样本的局部密度和组内距离来识别聚类中心; Jia 等 (2016) 对 FDPC 算法进行了改进, 提出了增强的快速聚类算法 E-FDPC (Enhanced-FDPC), 该算法通过加权归一化的局部密度和组内距离来计算每个波段的排名得分; Yuan 等 (2016) 提出了一种基于上下文分析和双聚类的高光谱图像波段选择方法; Wang 等 (2018) 提出了一种用于高光谱波段选择的最佳聚类框架, 该框架通过动态编程将高光谱波段划分为多个组, 并在每个组中选择一个代表性波段; 赵亮等 (2019) 提出了一种基于平均相关性和最佳指数等指标的高光谱图像子空间波段选择方法; Wang 等 (2019) 提出了一种用于波段子空间划分的自适应分区框架, 通过最大化组间距离与组内距离之比将光谱空间中有序的高光谱数据划分为多个子空间, 可以有效避免选择具有高相关性的波段子集。

上述基于聚类的高光谱图像波段选择方法主要考虑了波段的信息量和相关性, 忽视了波段的噪声问题。然而受瑞利散射、水和二氧化碳吸收等大气噪声及传感器自身噪声的影响, 真实的高光谱图像通常在某些波段有严重的噪声。这些噪声会对波段信息量估计和波段间相似度计算产生不利影响, 甚至导致选择的波段子集中包含多个噪声波段的情况。现有的波段选择方法为避免这种情况, 通常会将特定传感器中的水吸收波段等受噪声影响严重的波段去除, 但在高光谱图像的成像过程中产生噪声波段的因素众多, 去除特定水吸收波段后的数据集中仍然存在其它的噪声波段 (刘雪松等, 2012), 因此在波段选择过程中考虑噪声问题是非常有必要的 (Wang 等, 2019)。本文提出一种噪声鲁棒的高光谱图像子空间划分与波段搜索方法, 即基于皮尔逊相关系数、信息熵和噪声水平 PIENL (Pearson correlation coefficient,

Information Entropy and Noise Level) 的波段选择方法。PIENL 方法首先采用抗噪声干扰能力较强的皮尔逊相关系数计算波段间相似度, 然后基于波段相似度自适应地将高光谱图像划分成有序的子空间, 最后综合考虑波段的信息熵和噪声水平, 在各个子空间中挑选出信息量大且噪声水平低的代表性波段。

2 方法

本文方法首先依据波段间皮尔逊相关系数对高光谱图像进行自适应子空间划分, 得到相关性较弱的多个波段子空间; 然后使用结合波段信息熵和噪声水平两个指标的信息量度量准则在各个子空间中进行搜索, 选择最具代表性的波段子集。

2.1 子空间划分

2.1.1 划分依据

高光谱遥感数据具有光谱划分精细的特点, 同一地物在相邻波段的光谱反射率相近 (赵亮等, 2019)。为了将相似波段划分到同一子空间, 需要衡量各个波段之间的光谱差异 (Wang 等, 2019)。目前波段间光谱差异的度量方法主要有距离度量 (Wang 等, 2019) 和相关性度量 (赵春晖等, 2017; 赵亮等, 2019)。图 1 展示了欧氏距离和皮尔逊相关系数在 Indian Pines 数据集与 Salinas 数据集上的可视化矩阵。

图 1 (a) 和图 1 (c) 分别展示了欧氏距离在 Indian Pines 数据集与 Salinas 数据集上的可视化矩阵。根据右侧图例, 越靠近深蓝色区域欧氏距离越小, 代表波段间的光谱差异越小; 越靠近深红色区域欧氏距离越大, 代表波段间的光谱差异越大; 可以看出, 噪声波段与其他正常波段间的欧氏距离较大, 但噪声波段间的欧氏距离较小, 例如 Indian Pines 数据集中 103—112 波段和 148—165 波段, Salinas 数据集中 108—112 波段和 154—167 波段。

皮尔逊相关系数可视化矩阵如图 1 (b) 与图 1 (d) 所示。皮尔逊相关系数的绝对值越大, 代表波段之间的相关性越强。根据右侧图例, 深蓝色区域代表波段间呈现负相关, 暗红色区域代表波段间呈现正强相关, 黄色区域代表波段间相关性较弱, 青色及浅蓝色区域代表波段间基本不相关; 可以看出, 相关性较强的区域主要集中在主对角线附近, 说明相邻波段间的相关性更强

(赵亮等, 2019), 但噪声波段间基本不相关或弱相关, 例如 Indian Pines 数据集中 103—112 波段和

148—165 波段, Salinas 数据集中 108—112 波段和 154—167 波段。

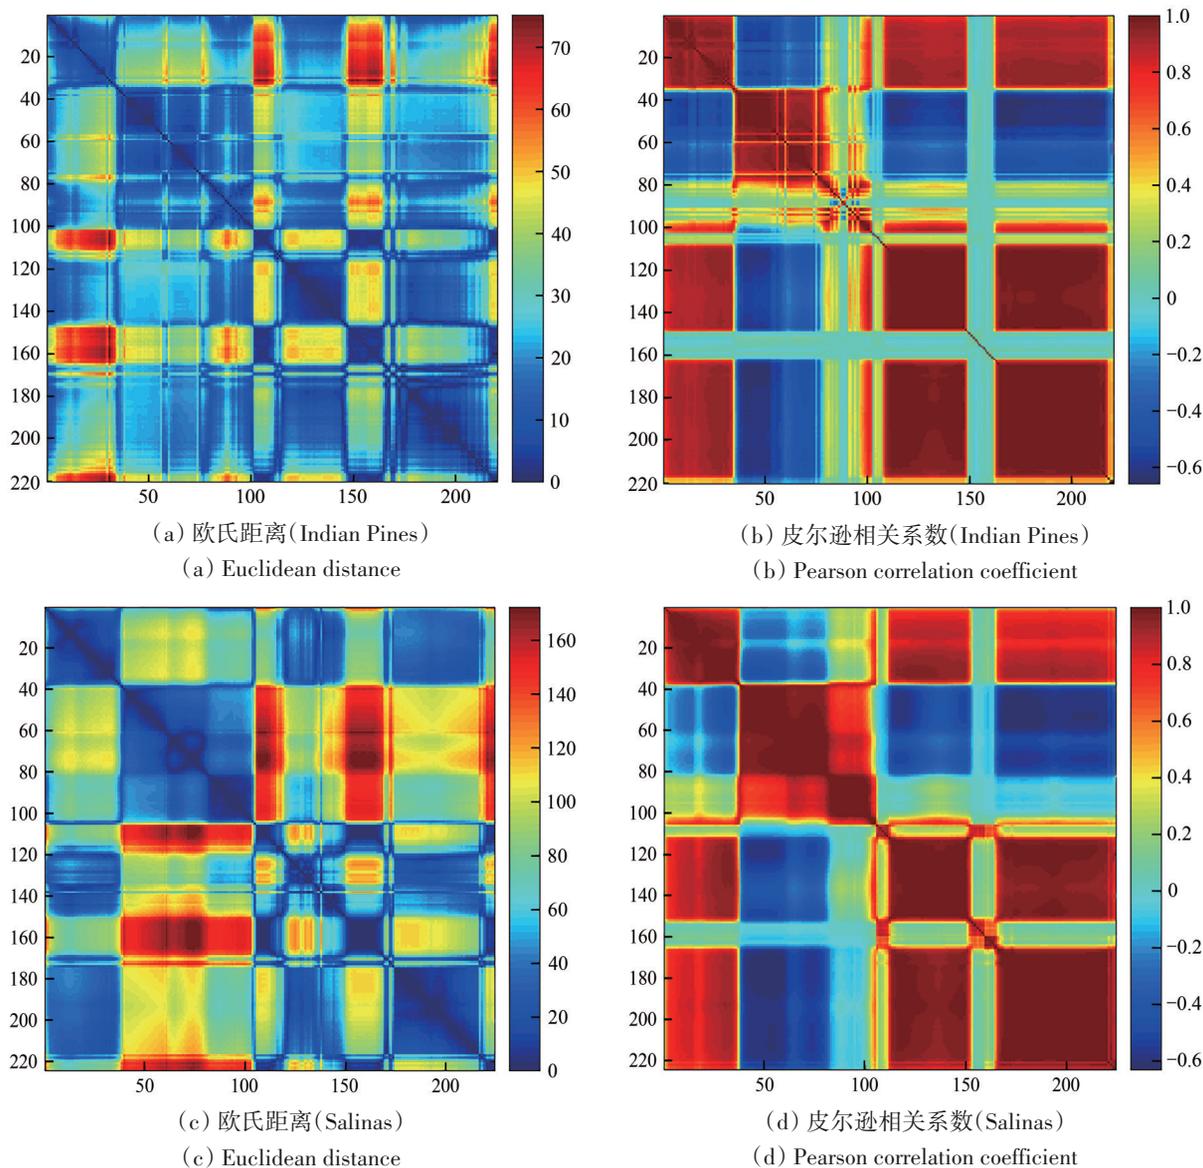


图1 欧氏距离与皮尔逊相关系数的可视化矩阵

Fig. 1 Visual matrix of Euclidean distance and Pearson correlation coefficient

依据欧氏距离度量波段间差异时, 噪声波段与非噪声波段间的距离较大, 但噪声波段之间的距离较小(例如 Indian Pines 数据集中 103—112 波段和 148—165 波段)。因此, 在采用欧氏距离划分子空间时, 可能出现同一子空间中所有波段都是噪声波段的情况, 致使下一阶段所选的最具代表性波段子集中必然存在噪声波段。图2展示了在未去除噪声波段的 Indian Pines 数据集上分别采用欧氏距离与皮尔逊相关系数的子空间划分情况, 其中噪声波段区域使用黑白纹理标注。可以看出, 采用欧氏距离的分区方法将噪声波

段 148—165、218—220 单独分成同一子空间。与欧氏距离不同, 皮尔逊相关系数基于波段间的协方差和波段标准差计算两个波段的相似度(Algina 和 Olejnik, 2003), 噪声波段间皮尔逊相关系数较小(例如 Salinas 数据集中 108—112 波段和 154—167 波段), 甚至接近于 0(例如 Indian Pines 数据集中 103—112 波段和 148—165 波段), 因此基于皮尔逊相关系数的子空间划分方法有助于避免将噪声波段单独分成同一子空间。据此本文选用皮尔逊相关系数作为高光谱图像子空间的划分依据。

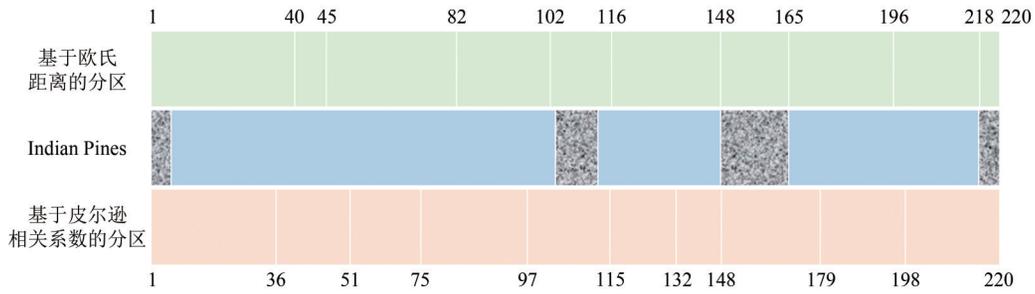


图2 在 Indian Pines 数据集上的分区情况

Fig. 2 Partition on the Indian Pines dataset

假设高光谱数据集 $X = [x_1, x_2, \dots, x_L]$, 其中 L 代表高光谱图像的波段数。波段间皮尔逊相关系数的计算如式 (1) 所示:

$$c_{i,j} = \frac{\text{cov}(x_i, x_j)}{\sigma_{x_i} \sigma_{x_j}} \quad (1)$$

式中, $\text{cov}(x_i, x_j)$ 是第 i 个波段 x_i 与第 j 个波段 x_j 的协方差, σ_{x_i} 和 σ_{x_j} 分别是 x_i 与 x_j 的标准差。 $c_{i,j}$ 表示第 i 个波段 x_i 与第 j 个波段 x_j 的皮尔逊相关系数。 $c_{i,j}$ 的绝对值越大, 代表 x_i 和 x_j 之间的相关性越强 (Zhang 等, 2018)。所有波段的皮尔逊相关系数矩阵 A 可以表示如下

$$A = \begin{bmatrix} c_{1,1} & c_{1,2} & \cdots & c_{1,L} \\ c_{2,1} & c_{2,2} & \cdots & c_{2,L} \\ \vdots & \vdots & \ddots & \vdots \\ c_{L,1} & c_{L,2} & \cdots & c_{L,L} \end{bmatrix} \quad (2)$$

2.1.2 基于皮尔逊相关系数的自适应子空间划分

受自适应子空间划分策略的启发 (Wang 等, 2019), 本文将高光谱图像视为有序数据, 提出了基于皮尔逊相关系数的自适应子空间划分方法。为避免所选代表性波段过于集中, 划分过程分为粗划分和细划分两个阶段: 粗划分是将整个高光谱图像立方体均分成 K 个子空间; 细划分是依据波段相关矩阵自适应调整相邻子空间的分割点。用 $\rho_s^{(k)}$ 表示第 k 个子空间内部波段的平均相关性, $\rho_d^{(k,k+1)}$ 表示第 k 和 $k+1$ 个子空间的波段平均相关性, 记 $C_s^{(k)} = \sum_{i=1}^{|B_k|-1} \sum_{j=i+1}^{|B_k|} |c_{i,j}|$, $C_d^{(k,k+1)} = \sum_{i=1}^{|B_k|} \sum_{j=1}^{|B_{k+1}|} |c_{i,j}|$, 则 $\rho_s^{(k)}$ 与 $\rho_d^{(k,k+1)}$ 的计算公式可以表示如下:

$$\rho_s^{(k)} = \frac{2C_s^{(k)}}{|B_k|(|B_k| - 1)} \quad (3)$$

$$\rho_d^{(k,k+1)} = \frac{C_d^{(k,k+1)}}{|B_k||B_{k+1}|} \quad (4)$$

式中, B_k 代表划分后的第 k 个子空间, $|B_k|$ 为第 k 个子空间的波段数。参照 Wang 等 (2019) 提出的子空间划分方法, 定义子空间划分的优化问题如下:

$$\begin{aligned} t_k^* &= \arg \min_{t_k} \frac{\rho_d^{(k,k+1)}}{\rho_s^{(k)} + \rho_s^{(k+1)}} \\ \text{s.t. } |B_k| &\geq 3, 1 \leq k \leq K-1 \end{aligned} \quad (5)$$

式中, t_k 为第 k 个子空间与第 $k+1$ 个子空间之间所有可能的分割点, t_k^* 为最佳分割点。考虑到子空间波段数量过少会造成波段的可选择性太低, 本文在式 (5) 中添加了子空间内波段数目大于或等于 3 的约束条件。

然而, 当高光谱图像中存在噪声波段时, 式 (5) 倾向于将连续噪声波段单独划分成一组。这是因为噪声波段组与其他波段组光谱相关性较弱, 如果选择分割点 t_k 使得所有噪声波段分为一组, 则式 (5) 中的分子项会取得最小值, 而分母项数值近似等于非噪声波段组相关性的大小, 因此这种划分方法容易导致代表性波段子集中出现噪声波段。

为解决式 (5) 倾向于将连续噪声波段单独划分成一组的问题, 本文提出使用乘积运算取代式 (5) 分子式中分母项的求和运算。这是因为噪声波段组内部相关性较小, 相比求和运算, 乘积运算会大幅降低分母项数值的大小, 从而避免在噪声波段组划分为一个子空间、非噪声波段组划分为一个子空间的情况下分子式取得最小值。改写后的优化问题目标函数可表达如下:

$$\begin{aligned} t_k^* &= \arg \min_{t_k} \frac{\rho_d^{(k,k+1)}}{\rho_s^{(k)} \rho_s^{(k+1)}} \\ \text{s.t. } |B_k| &\geq 3, 1 \leq k \leq K-1 \end{aligned} \quad (6)$$

结合式 (3) 与式 (4), 式 (6) 可以写成:

$$t_k^* = \arg \min_{t_k} \frac{C_D^{(k,k+1)} \cdot (|B_k| - 1)(|B_{k+1}| - 1)}{C_S^{(k)} C_S^{(k+1)} \cdot 4} \quad (7)$$

s.t. $|B_k| \geq 3, 1 \leq k \leq K - 1$

在式(7)中,第2个分子式计算子空间 B_k 与 B_{k+1} 波段数量分别减1后的乘积,目标函数的优化过程将使得这两个子空间中的波段数量差别较大。这是因为当总波段数量一定时,两个子空间波段数相差越大,第2个分子式的值越小。假设总共有10个波段,当 $B_k = 2, B_{k+1} = 8$ 时,第2个分子式的值为1.75;当 $B_k = 5, B_{k+1} = 5$ 时,第2个分子式的值为4,显然最小化优化问题的目标函数将倾向于选择前一种划分策略。为了解决这一问题,依据Geoffrion(1974)和Guignard(2003)关于最小化问题的松弛定义,对式(7)中的优化问题进行了松弛处理,如式(8)所示:

$$t_k^* = \arg \min_{t_k} \frac{C_D^{(k,k+1)}}{C_S^{(k)} C_S^{(k+1)}} \quad (8)$$

s.t. $|B_k| \geq 3, 1 \leq k \leq K - 1$

式(8)是式(7)的松弛问题,证明如下:

(1) 式(8)和式(7)的约束条件完全相同,因此式(8)的可行解集必定包含式(7)的可行解集;

(2) 由于约束条件 $|B_k| \geq 3$ 成立,式(7)中的第二个因子项 $\frac{(|B_k| - 1)(|B_{k+1}| - 1)}{4}$ 大于等于1,因此式(8)中每个可行解对应的目标函数值均小于等于式(7)的目标函数值。

通过对优化问题(7)的松弛处理,可以有效缓解各子空间波段数目不均衡的问题。据此,本文通过求解式(8)的最优化问题,得到第 k 个子空间与第 $k+1$ 个子空间之间的最佳分割点。

2.2 波段搜索准则

波段搜索准则旨在从子空间中选出高光谱图像信息量大、类别可分性较好的波段组合。波段方差、信息熵和噪声水平等是常用的波段评价依据(谷延锋和张晔,2003;蒋金豹等,2016;Zhang等,2016;Wang等,2019)。当高光谱图像中包含噪声时,噪声波段会对图像质量产生较大影响,增加图像分类任务的不确定性。

为了选择子空间中信息量大、且噪声水平低的波段作为该子空间的代表性波段,本文提出的

波段搜索准则将通过组合信息熵和噪声水平两个指标来评估各个波段的信息量。选择子空间 B_k 中代表性波段 y_k 的优化任务可以定义如下:

$$y_k = \arg \max_{x_i \in B_k} [E(x_i) - \lambda N(x_i)] \quad (9)$$

式中, $E(x_i)$ 和 $N(x_i)$ 分别代表波段 x_i 的信息熵和噪声水平, $\lambda N(x_i)$ 为惩罚项, λ 为惩罚系数,可以通过实验选取使波段选择结果最优的 λ 值。波段的噪声水平计算采用Coakley和Bretherton(1982)给出的方法。依据式(9)计算划分到子空间 B_k 中所有波段的信息量,将具有最高信息量的波段选为该子空间的代表性波段。子空间划分与波段搜索方法(PIENL)的实现过程为

输入: 高光谱数据集 $X = [x_1, x_2, \dots, x_L]$, 代表性波段数 K 。

输出: 代表性波段子集 Y

过程:

1. 根据式(1)和(2),构造波段间皮尔逊相关系数矩阵 A ;
2. 初始化 $Y = \{ \}$,分割点 $t_0 = 0, t_{k+1} = t_k + L/K, 0 \leq k < K$;
3. for $k \leftarrow 1$ to $K - 1$ do
4. 根据相关系数矩阵 A 和式(8),计算第 k 个最佳分割点 t_k^* ;
5. end for
6. 根据得到的 $K - 1$ 个最佳分割点 t_k^* ,将高光谱数据集重新划分为 K 个连续子空间;
7. for $k \leftarrow 1$ to K do
8. 计算子空间 B_k 中波段的信息熵和噪声水平;
9. 根据式(9)搜索子空间 B_k 的代表性波段 y_k ;
10. $Y = Y \cup \{y_k\}$;
11. end for
12. 返回代表性波段子集 Y 。

3 实验与分析

3.1 实验数据

本文使用3个公开常用的高光谱数据集来验证所提出方法的有效性。

(1) Indian Pines 数据集: 通过AVIRIS传感器采集,由145像素 \times 145像素和220个波段组成,波长范围在0.4—2.5 μm 之间,空间分辨率为20 m,包含16种地物类型;其中,信噪比较低的波段有

1—3、103—112、148—165 和 217—220 等 35 个波段 (Zhang 等, 2018)。去掉水和二氧化碳吸收严重噪声波段 (104—108、150—163 和 220) 后的修

正数据集共 200 个波段, Indian Pines 数据集假彩色图像及其真值图如图 3 所示。



图3 Indian Pines 数据集
Fig. 3 Indian Pines dataset

(2) Washington DC 数据集: 通过 HYDICE 传感器拍摄, 由 280×307 像素和 191 个波段组成, 波长范围在 0.4—2.4 μm 之间, 空间分辨率为 1.5 m, 包含 6 种地物类型。由于航拍数据噪声水平较低, 本文人为地对波段 61—80 和 141—150 等 30 个波段

添加 10% 的高斯噪声以检验不同波段选择算法的抗噪能力, 将人为添加噪声后的图像作为未去除噪声波段的数据集; Washington DC 数据集假彩色图像及其真值图如图 4 所示。

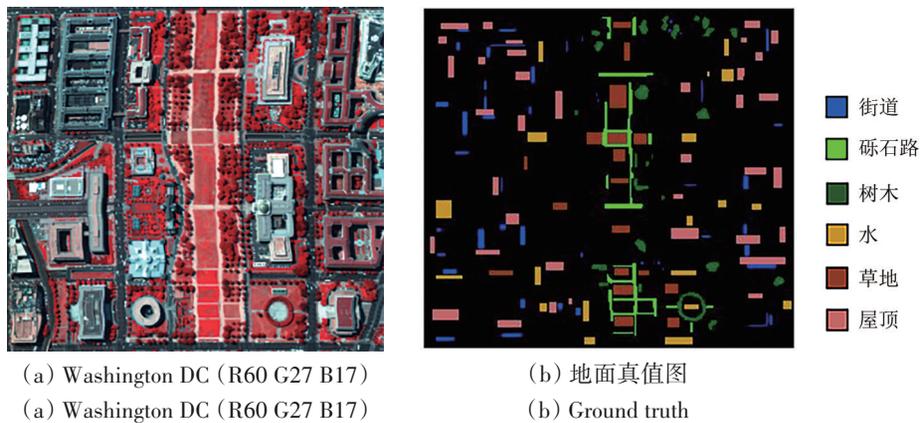


图4 Washington DC 数据集
Fig. 4 Washington DC dataset

(3) Salinas 数据集: 通过 AVIRIS 传感器采集, 由 512 像素×217 像素和 224 个波段组成, 空间分辨率为 3.7m, 包含 16 种地物类型。受大气影响较大和信噪比较低的波段有 108—112、154—167 和 224 等 20 个波段, 去除噪声严重波段后的修正数据集共 204 个波段; Salinas 数据集假彩色图像及其真值图如图 5 所示。

3.2 评价指标

本文通过波段平均相关性与分类精度两种指标来验证所提出方法的有效性, 并分析各种波段选择方法的噪声鲁棒性。

(1) 分类精度: 总体精度 (OA)、平均精度 (AA) 和 Kappa 系数用于量化分类效果。在实验中使用 SVM 分类器对高光谱图像进行分类, 并采用

径向基函数作为核函数。通过交叉验证方法估计最优方差参数和惩罚因子。每次实验随机选择10%的样本进行训练,其余样本用于测试。分类精度采用10次独立运行实验精度的平均值和标准差。

(2) 波段相关性: 本文使用波段平均相关系数(ACC)评估所选的代表性波段的相关性,ACC的绝对值越大,波段平均相关性越强,冗余度越高。

(3) 噪声鲁棒性: 以Indian Pines和Salinas数据集为例,对不同方法所选择的代表性波段进行分析和比较,评价各种波段选择方法对噪声的鲁棒性。

3.3 参数设置

在计算波段噪声水平时,需要事先将每个波段图像划分为 $M \times M$ 像素大小的小块(Coakley和Bretherton, 1982)。Wang等(2019)详细分析了块大小对不同数据集的影响。参考Wang等(2019)论文中的实验结果数据,本文在Indian Pines数据集上取 $M = 3$,在Washington DC数据集上取 $M = 5$,在Salinas数据集上取 $M = 10$ 。

在式(9)的目标函数中,参数 λ 的最优值通过实验确定。图6给出了在3个数据集上选取10个

代表性波段时,随着 λ 值逐步增加,分类精度的变化情况。本文在Indian Pines和Washington DC数据集上取 $\lambda = 100$,在Salinas数据集上取 $\lambda = 125$ 。

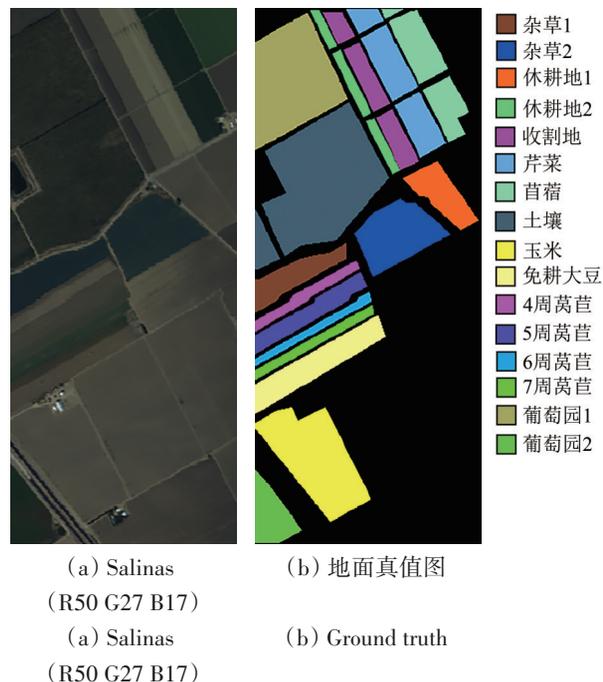


图5 Salinas数据集

Fig. 5 Salinas dataset

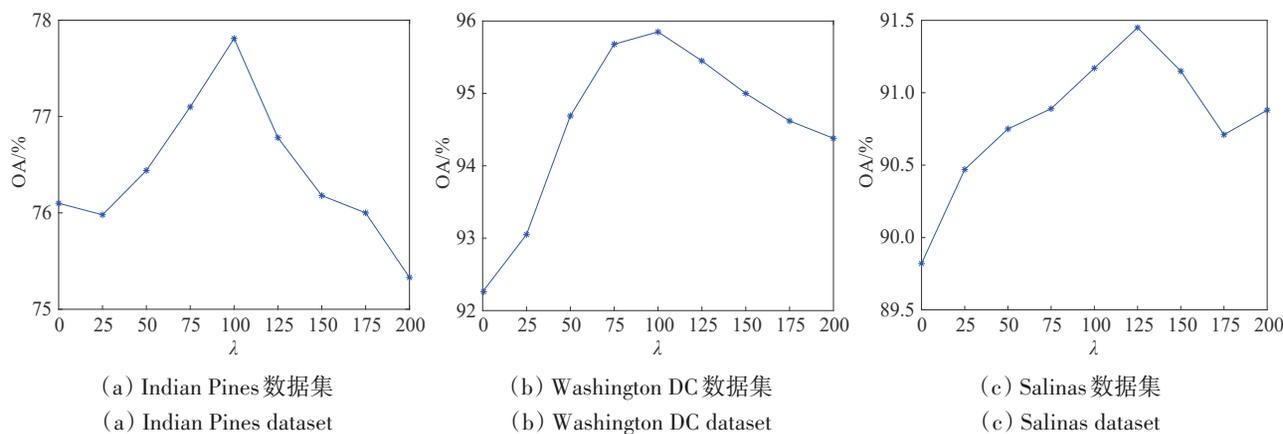


图6 在3个数据集上选取10个代表性波段的分类精度随 λ 值的变化曲线

Fig. 6 Classification accuracy of 10 representative bands selected from three datasets varies with the value of λ

3.4 实验结果与分析

实验环境为Intel Core i7-6700四核处理器,主频3.40 GHz,有效内存32 GB,开发环境为Matlab R2017b。本文将PIENL方法与Chang等(1999)提出的最大方差主成分分析方法MVPCA(Maximum-Variance PCA),Chang和Wang(2006)提出的基于线性约束最小方差的波段相关最小化方法

LCMVBCM(Linearly Constrained Minimum Variance based Band Correlation Minimization),Martínez-Usómartínez-Usó等(2007)提出的沃德发散联动策略(WaluDI),Rodríguez和Laio(2014)提出的基于快速密度峰的聚类算法(FDPC)和Wang等(2019)提出的自适应子空间噪声最小化方法(ASPS_MN)等波段选择方法进行了对比实验。其

中，ASPS_MN方法在波段搜索阶段同样考虑了噪声的影响，该方法将Coakley和Bretherton(1982)提出的噪声水平计算方法作为波段搜索准则。为了充分验证本文提出方法的优越性，在去除噪声严重波段的修正数据集与未去除噪声波段的数据集上均进行了对比实验。

3.4.1 基于皮尔逊相关系数的自适应子空间划分有效性验证

(1) 子空间划分的目标函数有效性验证。以Indian Pines高光谱图像的148—197波段(共50个连续波段，其中148—165为噪声波段，166—197为非噪声波段)为实验数据集，验证式(8)中目

标函数的有效性，实验结果如图7所示。由图7可以看出，在所有可能划分情况下，式(5)中的目标函数在将连续噪声波段148—165划分为一个子空间、非噪声波段166—197划分为另一个子空间时取得最小值；式(6)和(7)中的目标函数在分割点为194时取得最小值，避免了将连续噪声波段148—165划分为一个子空间的情况，然而两个子空间中的波段数量分别为47和3，相差极大；式(8)中的目标函数在分割点为179时取得最小值，既避免了相邻子空间 B_k 与 B_{k+1} 中波段数量不均衡的问题，也避免了将连续噪声波段单独划分为一个子空间的情况。因此，选用式(8)作为自适应子空间划分优化问题的目标函数是有效的。

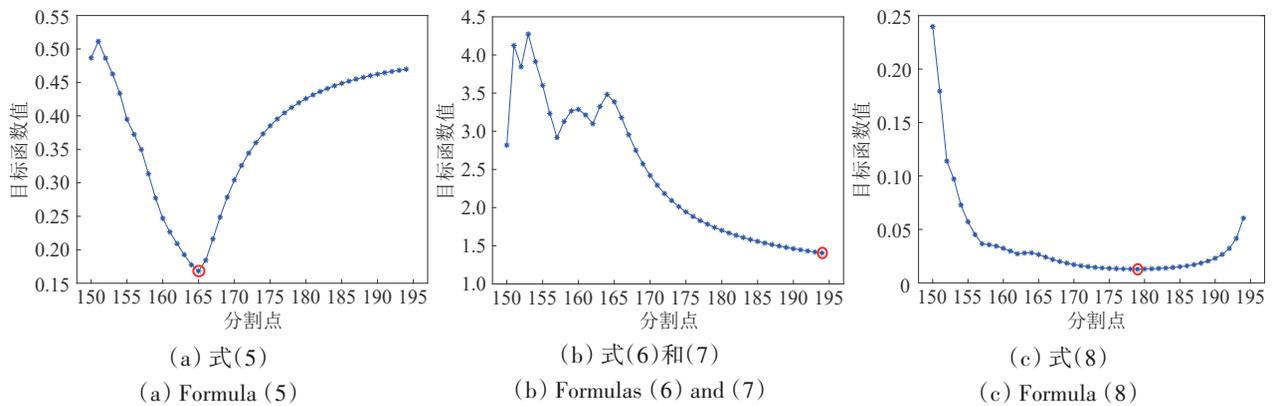


图7 不同目标函数对最佳分割点选择的影响(红圈代表最佳分割点)

Fig. 7 Adjacent subspace partition points of different objective functions (the red circle represents the best partition point)

(2) 与其他子空间划分方法的对比实验。为了验证本文提出的基于皮尔逊相关系数的子空间划分方法的有效性，本文将PIENL方法与其他子空间划分方法及波段均分方法进行了对比。其中，增强的快速聚类算法E-FDPC(Jia等,2016)和波段均分方法(根据所选代表性波段的数量将高光谱数据集平均划分)为非自适应划分方法，ASPS_MN和PIENL为自适应子空间划分方法。表1展示了在3个数据集上选取20个代表性波段时的分类精度。为了消除子空间波段搜索方法差异的影响，对比方法在波段搜索过程中均使用本文提出的子空间波段搜索方法，在表1中使用*标注。从表2中可以看出，PIENL方法在去除噪声严重波段的修正数据集上总体精度比ASPS_MN方法提高了大约1%，比E-FDPC方法及波段均分方法提高了大约1%—2%，Kappa系数在3个修正数据集上提高了1%—5%左右。PIENL方法在未去除噪声波

段数据集上总体精度比ASPS_MN方法提高了大约1%—3%，比E-FDPC方法及波段均分方法提高了大约1%—2%，Kappa系数提高了大约1%—5%。在几种对比方法中，PIENL的分类精度最高，证实了本文提出的基于皮尔逊相关系数的子空间划分方法的有效性。

3.4.2 提出的波段信息量度量方法有效性验证

为了验证本文提出的波段信息量度量方法的有效性，本文在3个未去除噪声波段的数据集上采用相同的子空间划分方法验证不同度量方法选取代表性波段的类别可分性。图8展示了在3个未去除噪声波段数据集上，使用不同度量方法选取不同数量代表性波段时的OA曲线。从图8中可以看出，采用本文提出的信息量度量方法选取的代表性波段的OA明显高于使用方差、信息熵和噪声水平作为波段搜索准则的方法，这也证实了采用本

文在波段搜索阶段改进的信息熵与噪声水平相结合的信息量度量方法可以选出子空间中信息量大且噪声水平低的代表性波段，具有较好的类别可分性。

表1 在3个数据集上分别选取20个代表性波段用于验证子空间划分方法的有效性

Table 1 Select 20 bands to verify the effectiveness of the subspace partition method on three hyperspectral datasets

数据集	分类度量	去除噪声严重波段的修正数据集				未去除噪声波段数据集			
		E-FDPC*	波段均分*	ASPS_MN*	PIENL	E-FDPC*	波段均分*	ASPS_MN*	PIENL
Indian Pines	OA	79.83±0.11	79.46±0.08	80.78±0.12	81.89±0.13	74.45±0.14	75.13±0.14	73.76±0.10	76.59±0.12
	AA	76.56±0.12	76.96±0.09	76.35±0.13	81.65±0.09	72.05±0.12	72.68±0.15	71.64±0.09	75.55±0.10
	Kappa	76.94±0.12	76.43±0.08	78.31±0.11	81.42±0.10	70.89±0.12	71.71±0.12	70.02±0.11	75.43±0.11
Washington DC	OA	95.41±0.09	95.06±0.05	95.56±0.05	96.30±0.04	94.91±0.09	94.53±0.08	95.36±0.09	95.90±0.06
	AA	95.23±0.08	95.11±0.04	95.52±0.07	95.94±0.06	94.62±0.08	94.27±0.06	95.45±0.09	95.75±0.05
	Kappa	94.17±0.09	94.06±0.04	94.30±0.07	95.53±0.05	93.54±0.08	93.26±0.06	93.96±0.08	94.31±0.05
Salinas	OA	90.93±0.07	90.23±0.13	91.06±0.08	91.39±0.05	90.42±0.08	89.23±0.12	90.96±0.08	91.50±0.03
	AA	94.84±0.06	93.79±0.14	94.98±0.07	95.28±0.04	94.98±0.07	93.01±0.11	95.00±0.09	95.96±0.03
	Kappa	90.33±0.06	89.56±0.12	90.21±0.07	91.01±0.04	90.21±0.07	88.24±0.12	90.32±0.08	91.32±0.02

注：*代表使用原始方法的子空间划分策略和本文提出的波段搜索方法，粗体表示精度最高。

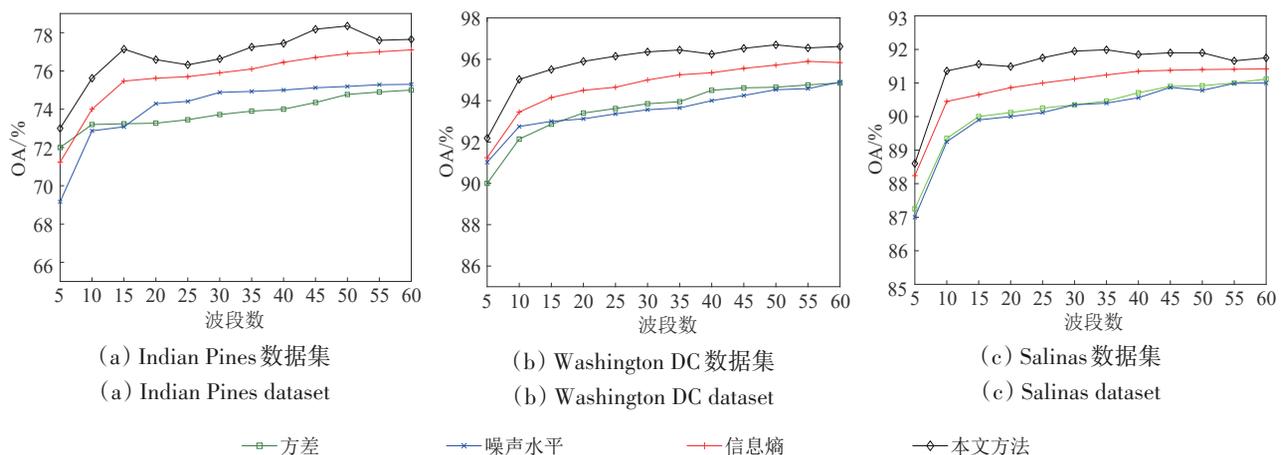


图8 在3个数据集上使用不同信息量度量方法选取波段的OA曲线

Fig. 8 OA for using different information measurement methods to select bands on three datasets

3.4.3 修正数据集上的结果与分析

(1) 类别可分性。图9展示了几种波段选择方法在3个去除噪声严重波段的修正数据集上选取不同数量代表性波段的OA变化曲线。从总体变化趋势上看，大部分方法的分类精度随所选代表性波段数量的增加而增加。当所选波段达到30个以上时，各种方法的精度基本趋于稳定。图9中水平虚线为使用全波段分类的结果。PIENL方法在3个修正数据集上选择20—30个代表性波段时，精度达到或超过使用全波段分类的结果。从图9(a)可以看出，当PIENL方法在Indian Pines数据集上选

择代表性波段的数量超过15个时，其分类精度明显高于其他方法。各种波段选择方法在Washington DC和Salinas数据集上的分类精度变化曲线分别由图9(b)和图9(c)给出。与Indian Pines数据集相比，PIENL方法在Washington DC和Salinas数据集上的优势并不明显，这是由于Indian Pines数据集是由星载传感器拍摄，受大气噪声影响较为严重，波段的噪声水平较高，而Washington DC和Salinas数据集是由机载传感器拍摄，空间分辨率较高，波段的噪声水平较低。

表2给出了在3个修正数据集上分别选取10个

代表性波段的总体精度 (OA)、平均精度 (AA) 和 Kappa 系数。当选取 10 个代表性波段时, PIENL 方法与 ASPS_MN 方法在去除噪声严重波段的 Indian Pines 数据集上明显优于其它方法, 可以说明在去除噪声严重波段后的数据集上考虑噪声影响也是十分必要的。从表 2 中可以看出, 本文提出的 PIENL 方法在各个数据集上都取得了较好的结

果。PIENL 方法在的 Indian Pines 数据集上总体精度相比其它方法提高了 3%—13%, 分类精度已经非常接近使用所有波段分类的结果, 在 Washington DC 数据集上总体精度相比其它方法提高了 1.5%—6.0%, 在 Salinas 数据集上总体精度相比其它方法提高了 1%—6%。

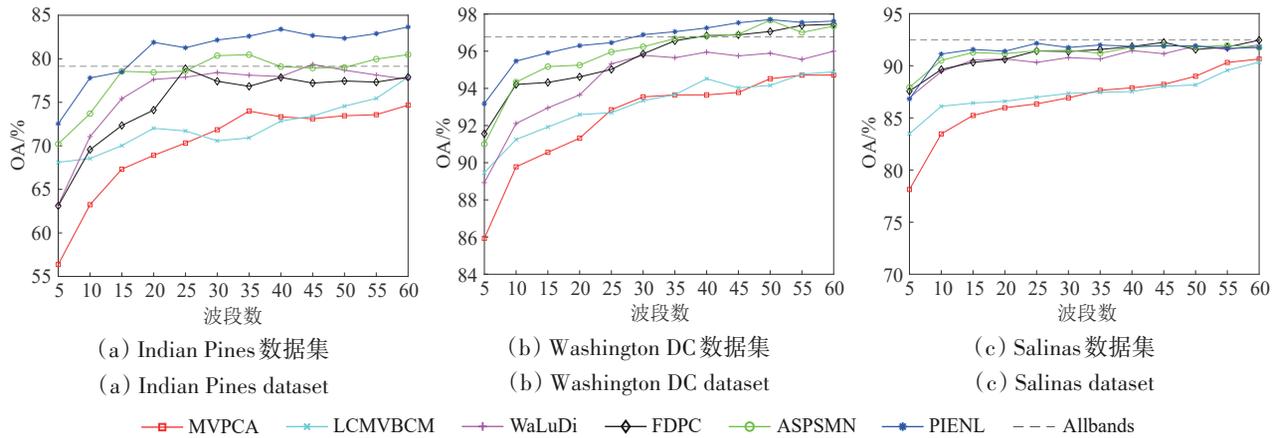


图 9 在去除噪声严重波段的修正数据集上选取不同数量波段的 OA 曲线

Fig. 9 OA for selecting different numbers of bands on the dataset with high-noise bands removed

表 2 在 3 种修正数据集上选取 10 个代表性波段的分类精度

Table 2 Classification accuracy of 10 representative bands selected on three datasets with high-noise bands removed

数据集	分类度量	All bands	MVPCA	LCMVBCM	WaluDI	FDPC	ASPS_MN	PIENL
Indian Pines	OA	79.13±0.02	64.18±0.08	68.53±0.23	69.34±0.18	69.56±0.16	74.72±0.29	77.81±0.14
	AA	78.00±0.02	63.99±0.06	68.01±0.25	68.78±0.15	69.89±0.14	72.18±0.15	75.44±0.12
	Kappa	76.52±0.03	63.83±0.09	67.74±0.19	68.03±0.20	69.72±0.19	71.33±0.36	74.71±0.17
Washington DC	OA	96.78±0.04	89.78±0.03	91.25±0.11	92.11±0.07	94.21±0.05	94.34±0.02	95.82±0.04
	AA	96.97±0.04	89.63±0.02	90.55±0.12	92.24±0.09	93.06±0.03	94.82±0.05	95.90±0.05
	Kappa	96.00±0.03	88.02±0.03	89.41±0.10	91.55±0.10	92.42±0.06	92.97±0.03	94.81±0.07
Salinas	OA	92.46±0.05	83.46±0.07	86.11±0.29	89.64±0.01	89.44±0.10	90.52±0.13	91.45±0.05
	AA	96.10±0.05	83.17±0.06	86.21±0.25	88.79±0.02	91.45±0.08	94.04±0.09	95.44±0.04
	Kappa	90.41±0.03	83.05±0.08	85.79±0.31	87.12±0.01	90.33±0.11	89.35±0.15	90.15±0.05

注: 粗体表示精度最高。

PIENL 方法在去除噪声严重波段后的修正数据集上效果仍然优异的原因如下: 一是提出的基于皮尔逊相关系数的子空间划分方法能够降低代表性波段间的相关性, 从而减少所选波段之间的冗余信息; 二是修正数据集中仍包含部分信噪比较低的波段, 噪声增加了高光谱图像分类任务的不确定性, 在波段搜索过程中提出改进的波段信息度量方法能够同时兼顾信息熵和噪声水平, 选

出子空间中信息量大且噪声水平低的波段。在 3 个数据集上选取 10 个代表性波段的分类图由图 10、图 11 和图 12 给出。

(2) 相关性分析。表 4 展示了在 3 个数据集上分别选取 10 个代表性波段的平均相关系数。对于高光谱数据, 代表性波段的平均相关性越小, 波段子集冗余度越低。平均相关系数 ACC 的取值范围为 $[-1, 1]$: $|ACC| < 0.2$ 为极弱相关或不相关;

$0.2 \leq |\text{ACCI}| < 0.4$ 为弱相关； $0.4 \leq |\text{ACCI}| < 0.6$ 为中等程度相关； $0.6 \leq |\text{ACCI}| < 0.8$ 为强相关； $0.8 \leq |\text{ACCI}| \leq 1$ 为极强相关 (Acito 等, 2011)。在 Indian Pines 数据集上, PIENL 及 ASPS_MN 方法选取波段子集的 ACC 相比其它方法是较低的, 其值都小于 0.4, 即它们选择的代表性波段之间为弱相关, 而其他方

法选择的代表性波段之间为中等程度相关甚至强相关。在 Washington DC 和 Salinas 数据集上, PIENL 方法较其他方法的 ACC 是最低的。在 Salinas 数据集上, PIENL 方法所选波段子集的 ACC 只有 0.2 左右, 说明代表性波段的冗余度非常低。

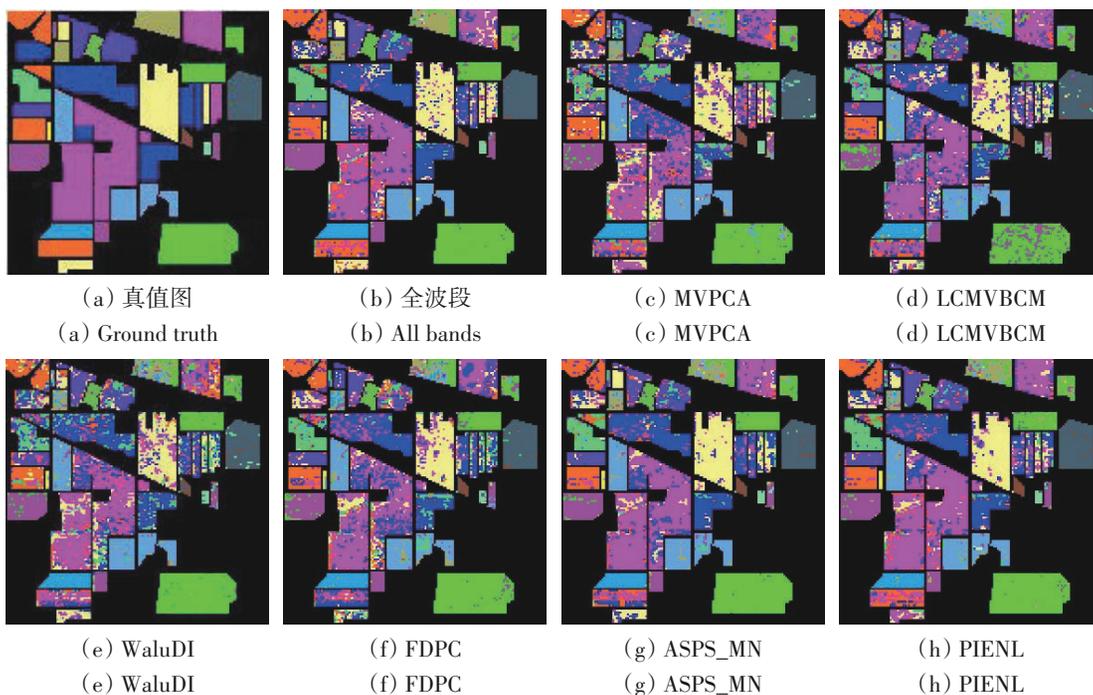


图 10 不同方法的 Indian Pines 图像分类结果

Fig. 10 Indian Pines image classification results obtained by different methods

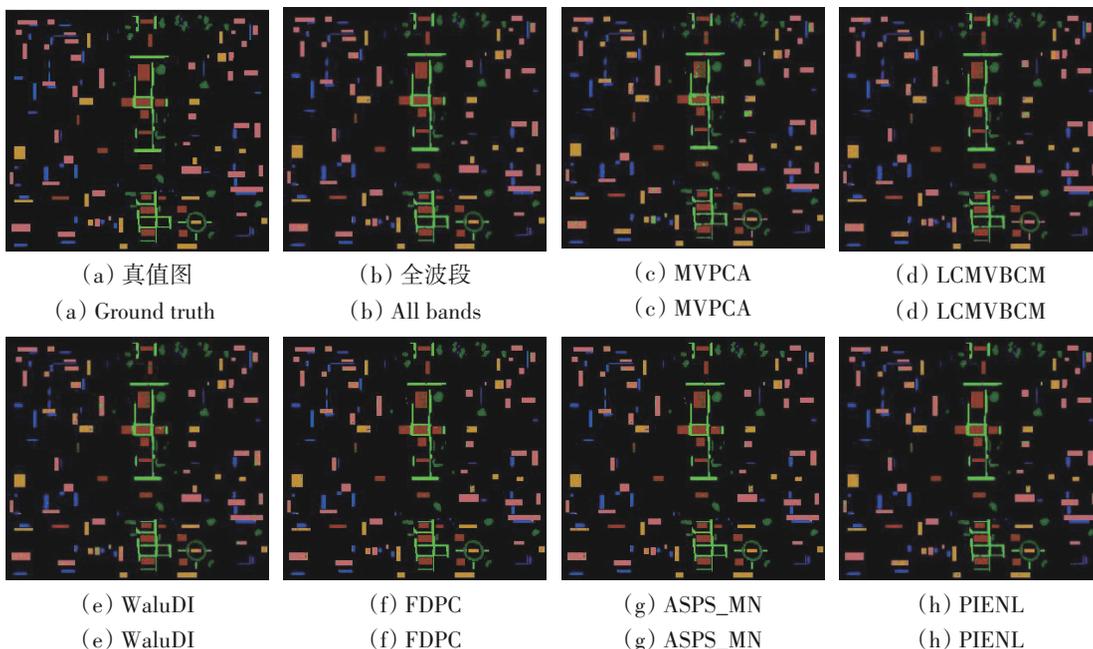


图 11 不同方法的 Washington DC 图像分类结果

Fig. 11 Washington DC image classification results obtained by different methods

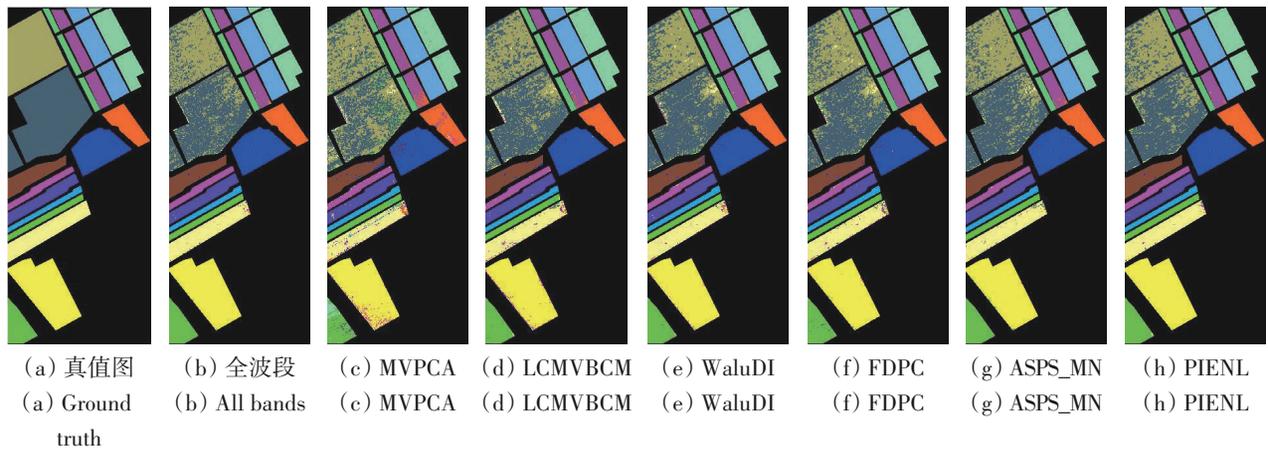


图12 不同方法的Salinas图像分类结果

Fig. 12 Salinas image classification results obtained by different methods

表4 3个数据集上选取10个代表性波段的平均相关系数

Table 4 Average correlation coefficient of 10 representative bands selected on three datasets

方法	Indian Pines (ACC)	Washington DC (ACC)	Salinas (ACC)
MVPCA	0.5950	0.7971	0.8050
LCMVBCM	0.8482	0.8076	0.7906
WaluDI	0.5766	0.5854	0.5872
FDPC	0.4794	0.5111	0.4625
ASPS_MN	0.3212	0.4740	0.2652
PIENL	0.3525	0.4651	0.2334

注：粗体表示波段间相关性最弱。

3.4.4 未去除噪声波段数据集上的结果与分析

(1) 类别可分性。图13展示了几种波段选择方法在3个未去除噪声波段的高光谱数据集上的OA变化曲线。从总体变化趋势上看，大部分方法的分类精度随所选代表性波段数量的增加而增加。图13中水平虚线代表使用全波段分类的结果，与图9中水平虚线相比，使用未去除噪声波段的全波段进行分类时，分类精度明显降低。从图13中可以看出，当仅选择10个代表性波段时，PIENL方法的精度便达到或高于使用全波段进行分类的精度。ASPS_MN等波段选择方法受噪声影响较大，而PIENL方法在3个未去除噪声波段的数据集上均有良好表现，证实了PIENL方法对噪声具有较强的鲁棒性。

表5给出了在3个未去除噪声波段的数据集上分别选取10个代表性波段的总体精度(OA)、平均精度(AA)和Kappa系数，从中可以看出，本

文提出的PIENL方法在各个数据集上都取得了较好的结果。在未去除噪声波段的Indian Pines和Washington DC数据集上选取10个波段的分类结果高于使用所有波段及其它方法的分类精度。从表5中可以看出，PIENL方法在3个未去除噪声波段的数据集上的分类精度高于其它所有方法，在未去除噪声波段的Indian Pines数据集上相比其它方法总体精度提高了6%—11%，在Washington DC数据集上总体精度提高了2%—8%，在Salinas数据集上总体精度提高了3%—7%，证实了PIENL方法在未去除噪声波段的数据集上表现更加优异。

(2) 噪声鲁棒性分析。表6和表7展示了不同波段选择方法在未去除噪声波段的Indian Pines和Salinas数据集上所选的10个代表性波段的序号，并对其中的噪声波段进行了颜色加深标记。在未经噪声波段去除的Indian Pines数据集上，LCMVBCM和WaluDI方法所选的10个代表性波段中包含3个噪声波段，FDPC和ASPS_MN方法包含了2个噪声波段。在未去除噪声波段的Salinas数据集上，LCMVBCM和ASPS_MN方法选择了2个噪声波段，FDPC和WaluDI方法选择了1个噪声波段。MVPCA和PIENL方法在两个数据集上都没有选择噪声波段作为代表性波段。然而从表6和表7中可以看出，MVPCA方法选择的大多数代表性波段序号都是相邻的，波段子集的信息冗余度非常高，多样性无法保证，因而相比其他方法，该方法的分类精度是最低的。PIENL方法能有效避开噪声波段，且其选择的代表性波段之间相关性较弱，因而分类精度是所有方法中最高的，这表明PIENL方法具有噪声鲁棒性。

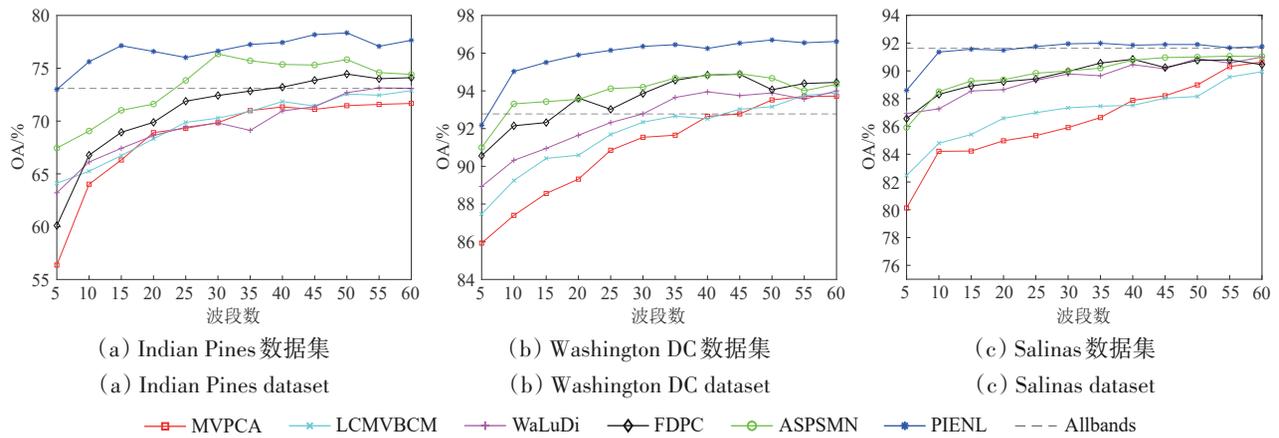


图 13 在未去除噪声波段的数据集上选取不同数量波段的 OA 曲线

Fig. 13 OA for selecting different numbers of bands on datasets containing noise bands

表 5 在未去除噪声波段的数据集上选取 10 个代表性波段的分类精度

Table 5 Classification accuracy of 10 representative bands selected on datasets containing noise bands

数据集	分类度量	All bands	MVPCA	LCMVBCM	WaluDI	FDPC	ASPS_MN	PIENL
Indian Pines	OA	73.08±0.11	64.02±0.20	65.25±0.28	66.13±0.15	68.77±0.27	69.06±0.32	75.62±0.15
	AA	72.67±0.12	63.70±0.21	65.09±0.24	65.62±0.16	66.28±0.25	66.10±0.30	74.71±0.13
	Kappa	69.29±0.09	63.23±0.18	64.14±0.27	65.11±0.15	65.32±0.25	65.22±0.36	72.24±0.15
Washington DC	OA	92.78±0.06	87.40±0.14	89.25±0.12	90.32±0.09	92.15±0.15	93.31±0.10	95.03±0.07
	AA	93.95±0.07	87.26±0.15	88.53±0.15	90.24±0.10	92.06±0.18	93.64±0.09	95.56±0.06
	Kappa	91.00±0.05	86.00±0.15	87.41±0.14	88.05±0.12	90.42±0.16	91.59±0.12	93.81±0.04
Salinas	OA	91.65±0.13	84.21±0.09	84.79±0.15	87.27±0.07	88.31±0.13	88.51±0.20	91.36±0.03
	AA	95.55±0.15	83.42±0.07	85.21±0.20	88.33±0.09	90.12±0.15	92.95±0.18	95.79±0.04
	Kappa	90.62±0.13	84.11±0.09	84.39±0.15	87.06±0.07	89.60±0.15	87.11±0.23	90.29±0.03

注：粗体表示精度最高。

表 6 不同方法在 Indian Pines 数据集上选取的 10 个波段时噪声波段包含情况

Table 6 Noise bands in 10 bands selected by different methods on the Indian Pines dataset

方法	10 个代表波段									
MVPCA	20	21	22	23	24	25	26	27	29	39
LCMVBCM	119	123	130	153	159	160	171	174	185	196
WaluDI	3	21	46	54	82	105	141	162	174	200
FDPC	8	50	67	77	108	123	133	136	147	219
ASPS_MN	28	45	58	92	114	117	159	169	199	219
PIENL	29	49	75	90	114	125	134	178	184	203

注：粗体为噪声波段。

3.4.5 计算时间分析

表 8 展示了在 Indian Pines 数据集上使用不同波段选择方法分别选取 10、20、30、40、50 和 60 个代表性波段 (k) 的计算时间。可以看出, PIENL 方法的计算时间仅次于 MVPCA 方法, 优于

ASPS_MN 等其他波段选择方法。但 MVPCA 方法所选的代表性波段分类精度较低 (图 9、表 3、图 13 和表 5), 而 PIENL 方法所选的代表性波段在各种波段选择方法中分类精度最高。

表7 不同方法在Salinas数据集上选取的10个波段时噪声波段包含情况
Table 7 Noise bands in 10 bands selected by different methods on the Salinas dataset

方法	10个代表波段									
MVPCA	23	24	25	26	27	28	29	30	32	42
LCMVBCM	106	110	128	129	145	159	172	176	197	202
WaluDI	8	15	25	32	45	58	93	124	165	183
FDPC	7	11	20	31	32	55	109	126	136	184
ASPS_MN	13	44	67	106	109	151	156	197	200	222
PIENL	30	52	60	73	113	124	153	179	192	204

注：粗体为噪声波段。

表8 在Indian Pines数据集上使用不同波段选择方法的计算时间

Table 8 Computing times of different band selection methods used on the Indian Pines dataset

所选波段数量	计算时间/s				
	MVPCA	LCMVBCM	FDPC	ASPS_MN	PIENL
$k = 10$	0.091	2.914	2.672	0.741	0.688
$k = 20$	0.091	2.920	2.679	0.805	0.723
$k = 30$	0.095	2.926	2.702	0.864	0.695
$k = 40$	0.096	2.935	2.703	0.946	0.705
$k = 50$	0.097	2.937	2.711	0.963	0.703
$k = 60$	0.102	2.939	2.714	0.813	0.697

3.4.6 消融实验

PIENL方法在Wang等(2019)提出的ASPS_MN方法的基础上做了两点改进：一是提出基于皮尔逊相关系数的自适应子空间划分方法；二是提出基于信息熵与噪声水平的波段搜索准则。表9在3个数据集上分别展示了本文提出的自适应子空间

划分方法及波段搜索准则的有效性。从表9中的可以看出，ASPS_MN方法在去除噪声严重波段的修正Indian Pines数据集上，采用本文提出的子空间划分方法的总体精度提高了2%左右，在未去除噪声的波段Indian Pines数据集上提高了3%左右，这是由于本文提出的子空间划分方法能够避免将连续的噪声波段单独划分成一个子空间，在Salinas和Washington DC数据集上也取得了不同程度的提升，证实了本文提出的子空间划分方法的有效性和必要性。ASPS_MN方法在未去除噪声波段的3个数据集上使用本文提出的波段搜索准则，其总体精度提高了2%左右，证实了本文提出的使用信息熵与噪声水平相结合的波段搜索准则优于单独使用噪声水平的波段搜索准则。将基于皮尔逊相关系数的子空间划分方法及波段搜索准则相结合时，PIENL方法在未去除噪声波段的Indian Pines数据集上总体精度提高了6%以上。在Salinas和Washington DC数据集上的实验也可以得到类似结论。

表9 在3个高光谱数据集上选取10个波段的消融实验

Table 9 Ablation experiments with 10 bands selected on three hyperspectral datasets

数据集	分类度量	去除噪声严重波段的修正数据集				未去除噪声波段数据集			
		ASPS_MN	ASPS_MN ¹	ASPS_MN ²	PIENL	ASPS_MN	ASPS_MN ¹	ASPS_MN ²	PIENL
Indian Pines	OA	74.72±0.29	76.76±0.17	75.61±0.09	77.81±0.14	69.06±0.32	72.15±0.27	71.60±0.18	75.62±0.15
	AA	72.18±0.15	73.69±0.16	73.01±0.10	75.44±0.12	66.10±0.30	68.78±0.23	69.17±0.20	74.71±0.13
	Kappa	71.33±0.36	73.51±0.14	72.34±0.10	74.71±0.17	65.22±0.36	68.37±0.25	67.64±0.19	72.24±0.15
Washington DC	OA	94.34±0.02	94.93±0.05	95.03±0.06	95.82±0.04	93.31±0.10	94.28±0.11	95.02±0.09	95.03±0.07
	AA	94.82±0.05	95.56±0.05	95.48±0.07	95.90±0.05	93.64±0.09	94.79±0.08	95.31±0.10	95.56±0.06
	Kappa	92.97±0.03	93.68±0.04	93.81±0.06	94.81±0.07	91.59±0.12	92.88±0.10	93.80±0.09	93.81±0.04
Salinas	OA	90.52±0.13	90.67±0.12	90.95±0.09	91.45±0.05	88.51±0.20	89.45±0.15	90.34±0.11	91.36±0.03
	AA	94.04±0.09	94.25±0.10	94.45±0.07	95.44±0.04	92.95±0.18	93.81±0.17	94.59±0.09	95.79±0.04
	Kappa	89.35±0.15	89.40±0.13	89.46±0.09	90.15±0.05	87.11±0.23	88.15±0.15	89.15±0.09	90.29±0.03

注：ASPS_MN为方法本身，ASPS_MN¹表示将ASPS_MN中的分区方法替换为本文提出的分区方法，ASPS_MN²表示将ASPS_MN中的波段搜索准则替换为本文提出的波段搜索准则。

4 结 论

本文针对高光谱图像波段选择结果受噪声影响较大的问题,提出了一种噪声鲁棒的高光谱图像自适应子空间划分与波段搜索方法PIENL,该方法在子空间划分和波段搜索过程中都考虑了噪声对波段选择的影响。在子空间划分阶段,使用皮尔逊相关系数度量含有噪声的高光谱图像波段间的相关性;在波段搜索阶段,提出了引入噪声水平作为惩罚项,即挑选出信息量大且噪声水平低的波段作为代表性波段。在Indian Pines、Washington DC和Salinas这3个高光谱公共数据集上的实验结果表明:

(1) 采用欧氏距离划分子空间时可能出现同一子空间中所有波段都是噪声波段的情况,导致下一阶段所选的最具代表性波段子集中必然存在噪声波段;而基于皮尔逊相关系数的子空间划分方法则有助于避免将噪声波段单独分成同一子空间,因此,皮尔逊相关系数更适合于度量含有噪声的高光谱图像波段之间的光谱差异;

(2) 综合考虑信息熵和噪声水平两个指标度量波段信息量,有助于选出高光谱图像中信息量大且噪声水平低的代表性波段;

(3) PIENL方法选择的代表性波段具有更好的类别可分性。相比ASPS_MN等先进的波段选择方法,PIENL方法在3个修正数据集上的总体精度分别提高了3%—13%、1.5%—6.0%和1%—6%;在3个未去除噪声波段的数据集上总体精度分别提高了6%—11%、2%—8%和3%—7%。这也表明PIENL方法在未去除噪声波段的数据集上表现更加优异。

下一步工作主要考虑PIENL方法在子空间划分过程中自适应确定子空间的数量,避免代表性波段数量选择不当造成高光谱图像重要光谱特征缺失或波段信息冗余等问题。

参考文献(References)

Acito N, Diani M and Corsini G. 2011. Subspace-based striping noise reduction in hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 49(4): 1325-1342 [DOI: 10.1109/TGRS.2010.2081370]

Algina J and Olejnik S. 2003. Sample size tables for correlation analysis with applications in partial correlation and multiple regression

analysis. *Multivariate Behavioral Research*, 38(3): 309-323 [DOI: 10.1207/S15327906MBR3803_02]

Bandos T V, Bruzzone L and Camps-Valls G. 2009. Classification of hyperspectral images with regularized linear discriminant analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3): 862-873 [DOI: 10.1109/TGRS.2008.2005729]

Chang C I, Du Q, Sun T L and Althouse M L G. 1999. A joint band prioritization and band-decorrelation approach to band selection for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 37(6): 2631-2641 [DOI: 10.1109/36.803411]

Chang C I and Wang S. 2006. Constrained band selection for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 44(6): 1575-1585 [DOI: 10.1109/TGRS.2006.864389]

Coakley J A and Bretherton F P. 1982. Cloud cover from high-resolution scanner data: detecting and allowing for partially filled fields of view. *Journal of Geophysical Research: Oceans*, 87(C7): 4917-4932 [DOI: 10.1029/JC087iC07p04917]

Cui B G, Cui J D, Lu Y, Guo N N and Gong M G. 2020. A sparse representation-based sample pseudo-labeling method for hyperspectral image classification. *Remote Sensing*, 12(4): 664 [DOI: 10.3390/rs12040664]

Cui B G, Wu Y N, Zhong Y, Zhong L W and Lu Y. 2019. Hyperspectral image rolling guidance recursive filtering and classification. *Journal of Remote Sensing*, 23(3): 431-442 (崔宾阁, 吴亚男, 钟勇, 钟利伟, 路燕. 2019. 高光谱图像滚动引导递归滤波与地物分类. *遥感学报*, 23(3): 431-442) [DOI: 10.11834/jrs.20197510]

Dópido I, Villa A, Plaza A and Gamba P. 2012. A quantitative and comparative assessment of unmixing-based feature extraction techniques for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2): 421-435 [DOI: 10.1109/JSTARS.2011.2176721]

Fauvel M, Tarabalka Y, Benediktsson J A, Chanussot J and Tilton J C. 2013. Advances in spectral-spatial classification of hyperspectral images. *Proceedings of the IEEE*, 101(3): 652-675 [DOI: 10.1109/JPROC.2012.2197589]

Geoffrion A M. 1974. Lagrangean relaxation for integer programming// *Approaches to Integer Programming*. Berlin, Heidelberg: Springer: 82-114 [DOI: 10.1007/BFb0120690]

Gu Y F and Zhang Y. 2003. Feature extraction based on automatic subspace partition for hyperspectral images. *Remote Sensing Technology and Application*, 18(6): 384-387 (谷延锋, 张晔. 2003. 基于自动子空间划分的高光谱数据特征提取. *遥感技术与应用*, 18(6): 384-387) [DOI: 10.3969/j.issn.1004-0323.2003.06.006]

Guignard M. 2003. Lagrangean relaxation. *Top*, 11(2): 151-200 [DOI: 10.1007/BF02579036]

Jia S, Tang G H, Zhu J S and Li Q Q. 2016. A novel ranking-based clustering approach for hyperspectral band selection. *IEEE Transactions on Geoscience and Remote Sensing*, 54(1): 88-102 [DOI: 10.1109/TGRS.2015.2450759]

- Jiang J B, Qiao X J, He R Y and Tian F M. 2016. Use of near-infrared hyperspectral images to differentiate architectural coatings with different qualities. *Spectroscopy and Spectral Analysis*, 36(2): 379-383 [蒋金豹, 乔小军, 何汝艳, 田奋民. 2016. 用近红外高光谱图像区分不同品质的建筑涂料. *光谱学与光谱分析*, 36(2): 379-383] [DOI: 10.3964/j.issn.1000-0593(2016)02-0379-05]
- Lees K J, Artz R R E, Khomik M, Clark J M, Ritson J, Hancock M H, Cowie N R and Quaife T. 2020. Using spectral indices to estimate water content and GPP in *Sphagnum* moss and other peatland vegetation. *IEEE Transactions on Geoscience and Remote Sensing*, 58(7): 4547-4557 [DOI: 10.1109/TGRS.2019.2961479]
- Li W, Prasad S, Fowler J E and Bruce L M. 2012. Locality-preserving dimensionality reduction and classification for hyperspectral image analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 50(4): 1185-1198 [DOI: 10.1109/TGRS.2011.2165957]
- Liu X S, Ge L, Wang B and Zhang L M. 2012. An unsupervised band selection algorithm for hyperspectral imagery based on maximal information. *Journal of Infrared and Millimeter Waves*, 31(2): 166-171 (刘雪松, 葛亮, 王斌, 张立明. 2012. 基于最大信息量的高光谱遥感图像无监督波段选择方法. *红外与毫米波学报*, 31(2): 166-171) [DOI: 10.3724/SP.J.1010.2012.00166]
- Martínez-Usó Martínez-Uso A, Pla F, Sotoca J M and García-Sevilla P. 2007. Clustering-based hyperspectral band selection using information measures. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12): 4158-4171 [DOI: 10.1109/TGRS.2007.904951]
- Nasrabadi N M. 2014. Hyperspectral target detection: an overview of current and future challenges. *IEEE Signal Processing Magazine*, 31(1): 34-44 [DOI: 10.1109/MSP.2013.2278992]
- Rodriguez A and Laio A. 2014. Clustering by fast search and find of density peaks. *Science*, 344(6191): 1492-1496 [DOI: 10.1126/science.1242072]
- Sun W W and Du Q. 2019. Hyperspectral band selection: a review. *IEEE Geoscience and Remote Sensing Magazine*, 7(2): 118-139 [DOI: 10.1109/MGRS.2019.2911100]
- Sun W W, Halevy A, Benedetto J J, Czaja W, Liu C, Wu H B, Shi B Q and Li W Y. 2014. UL-Isomap based nonlinear dimensionality reduction for hyperspectral imagery classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 89: 25-36 [DOI: 10.1016/j.isprsjprs.2013.12.003]
- Thenkabail P S and Lyon J G. 2011. Spectral and spatial methods of hyperspectral image analysis for estimation of biophysical and biochemical properties of agricultural crops//*Hyperspectral Remote Sensing of Vegetation*. Boca Raton, FL: CRC Press: 289-308 [DOI: 10.1201/b11222-19]
- Wang J and Chang C I. 2006. Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 44(6): 1586-1600 [DOI: 10.1109/TGRS.2005.863297]
- Wang Q, Li Q and Li X L. 2019. Hyperspectral band selection via adaptive subspace partition strategy. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12): 4940-4950 [DOI: 10.1109/JSTARS.2019.2941454]
- Wang Q, Zhang F H and Li X L. 2018. Optimal clustering framework for hyperspectral band selection. *IEEE Transactions on Geoscience and Remote Sensing*, 56(10): 5910-5922 [DOI: 10.1109/TGRS.2018.2828161]
- Yang H, Du Q and Chen G S. 2012. Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2): 544-554 [DOI: 10.1109/JSTARS.2012.2185822]
- Yuan Y, Lin J Z and Wang Q. 2016. Dual-clustering-based hyperspectral band selection by contextual analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3): 1431-1445 [DOI: 10.1109/TGRS.2015.2480866]
- Zhai H, Zhang H Y, Zhang L P and Li P X. 2019. Total variation regularized collaborative representation clustering with a locally adaptive dictionary for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1): 166-180 [DOI: 10.1109/TGRS.2018.2852708]
- Zhang L P and Li J Y. 2016. Development and prospect of sparse representation-based hyperspectral image processing and analysis. *Journal of Remote Sensing*, 20(5): 1091-1101 (张良培, 李家艺. 2016. 高光谱图像稀疏信息处理综述与展望. *遥感学报*, 20(5): 1091-1101) [DOI: 10.11834/jrs.20166050]
- Zhang W Q, Li X R and Zhao L Y. 2016. An advanced hyperspectral band selection approach based on mutual information//2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Beijing: IEEE: 2703-2706 [DOI: 10.1109/IGARSS.2016.7729698]
- Zhang W Q, Li X R and Zhao L Y. 2018. A fast hyperspectral feature selection method based on band correlation analysis. *IEEE Geoscience and Remote Sensing Letters*, 15(11): 1750-1754 [DOI: 10.1109/LGRS.2018.2853805]
- Zhao C H, Tian M H and Li J W. 2017. Research progress on spectral similarity measurement metrics. *Journal of Harbin Engineering University*, 38(8): 1179-1189 (赵春晖, 田明华, 李佳伟. 2017. 光谱相似性度量方法研究进展. *哈尔滨工程大学学报*, 38(8): 1179-1189) [DOI: 10.11990/jheu.201612063]
- Zhao L, Wang L G and Liu D F. 2019. A subspace band selection method for hyperspectral imagery. *Journal of Remote Sensing*, 23(5): 904-910 (赵亮, 王立国, 刘丹凤. 2019. 高光谱图像子空间的波段选择. *遥感学报*, 23(5): 904-910) [DOI: 10.11834/jrs.20197508]
- Zhao W Z and Du S H. 2016. Spectral-spatial feature extraction for hyperspectral image classification: a dimension reduction and deep learning approach. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8): 4544-4554 [DOI: 10.1109/TGRS.2016.2543748]
- Zhu D H, Du B and Zhang L P. 2019. Binary-class collaborative representation for target detection in hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 16(7): 1100-1104 [DOI: 10.1109/LGRS.2019.2893395]

Noise robust band selection method for hyperspectral images

LU Yan, REN Yue, CUI Bing

College of Computer Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China

Abstract: Most proposed hyperspectral image band selection methods only consider the problem of band information redundancy and ignore the noise level of the selected bands. Accordingly, the representative band subset may contain high-noise bands, which is not conducive to subsequent semantic segmentation, image classification, and other applications. In response to this problem, this work proposes a noise-robust band selection method based on Pearson correlation coefficient, Information Entropy and Noise Level, referred to as PIENL.

In the proposed PIENL method, the Pearson correlation coefficient is first used to calculate the correlation between the bands, and the band correlation matrix is constructed. Then, the spectral bands of the hyperspectral image are divided into several subspaces of the same size, and an optimal subspace division objective function adapted to the Pearson correlation coefficient is constructed to adjust the division points of the subspace. Finally, a new band information measurement criterion is proposed, which observes the band information entropy and noise level at the same time and uses the noise level as a penalty item in the objective function of the optimization problem. According to this criterion, the spectral band with high information entropy and low noise level in each subspace is selected as the representative band.

Experiments were conducted on three public hyperspectral datasets of Indian Pines, Salinas, and Washington DC. Different band selection methods are evaluated using the average correlation degree of bands, classification accuracy, and the noise robustness. The experimental results show that this proposed PIENL method demonstrated outstanding band selection performance in terms of class separability, average correlation of representative bands, and noise robustness compared with the other advanced band selection methods.

The PIENL method has strong robustness to noise and has achieved significant results on hyperspectral datasets containing noise bands. We can conclude that: (1) The similarity measurement method based on the Pearson correlation coefficient is more suitable for measuring the spectral difference between the noisy hyperspectral image bands compared with Euclidean distance; (2) Considering both information entropy and noise level to measure band information is helpful to select representative bands of hyperspectral image; (3) The representative bands selected by PIENL have better class separability. Compared with other advanced band selection methods, the overall accuracy of PIENL method is improved by 3%—13%, 1.5%—6.0% and 1%—6% respectively on the three datasets with high-noise bands removed. The overall accuracy is improved by 6%—11%, 2%—8% and 3%—7% respectively on the three datasets containing high-noise bands. This also shows that PIENL has better performance on hyperspectral images that contain high-noise bands.

Key words: hyperspectral, band selection, noise robustness, subspace partition, search criteria

Supported by National Key Research and Development Program of China (No. 2017YFC1405600); National Natural Science Foundation of China (No. 42276185, 62073387, 42076189); Natural Science Foundation of Shandong Province (No. ZR2020MD096, ZR2020MD099)