

基于上下文多字典学习的高光谱波段选择

李 飞^{1,2}, 卢湖川^{*1}, 薄纯娟³

(1. 大连理工大学 电子信息与电气工程学部, 辽宁 大连 116024;

2. 沈阳航空航天大学 计算机学院, 辽宁 沈阳 110136;

3. 大连民族大学 机电工程学院, 辽宁 大连 116600)

摘要: 高光谱图像存在大量冗余信息, 波段选择是一种有效的减少冗余、降低光谱维数的方法. 提出一种基于上下文多字典学习的高光谱图像波段选择算法. 该算法使每个波段的图像都可以通过其他波段图像的线性组合来近似表示, 而且能够保证相邻波段图像具有相似的性质. 同时通过稀疏求解方法求出每个波段对应整个原始图像的权重, 便可按照权重来选择波段. 实验结果表明, 该算法相对其他波段选择算法具有良好的技术性能.

关键词: 高光谱图像; 波段选择; 稀疏表示

中图分类号: TP751

文献标识码: A

doi: 10.7511/dllgxb202101014

0 引言

高光谱图像具有很高的光谱分辨率, 包含数百个甚至上千个光谱波段. 丰富的光谱信息为精确的目标识别和分类应用提供了有利条件^[1]. 然而, 其庞大的数据也带来了数据传输与存储慢、冗余信息多等一系列问题, 而且光谱维数的增加使传统图像处理方法不能完全适用于高光谱图像数据. 一方面, 高光谱图像中存在大量的冗余信息; 另一方面, 高光谱图像的光谱维数太高, 很容易导致维度灾难问题^[2-3]. 因此, 对高光谱图像进行降维处理是很有必要的.

针对高光谱图像的降维方法有两种: 一种是特征提取, 利用基于某一准则的变换矩阵进行数据变换得到低维光谱数据; 另一种是波段选择(也称特征选择), 根据选择准则从原始波段挑选最佳波段子集, 以保证光谱物理信息不被破坏. 例如, 主成分分析(principal component analysis, PCA)、线性判别分析(linear discriminant analysis, LDA)、非参数加权特征提取(non-parametric weighted feature extraction,

NWFE)等, 这些特征提取方法的处理结果改变了原始波段的物理意义. 波段选择是高光谱图像在不进行特征变换的情况下降低波段维数的一种有效方法^[4]. 根据先验条件现有波段选择方法可以分为两类: 有监督波段选择和无监督波段选择. 有监督波段选择方法需要样本标签的先验信息, 因此受到应用目标的限制^[5]. 例如, Wei等提出了基于粒子群优化的有监督波段选择算法^[6]; Yang等根据各类别的谱特征, 提出了采用序贯前向选择搜索方法选择波段^[7]; Cao等将高光谱图像的局部空间信息集成到波段选择算法中^[8]. 与有监督波段选择方法不同, 无监督波段选择不需要样本标签的先验信息, 直接对无标签原始数据进行波段选择. 虽然在某些特定的应用中, 有监督波段选择方法获得的波段比无监督波段选择方法获得的波段更有效, 但是在很多情况下先验知识不容易获得, 因此无监督波段选择方法比有监督波段选择方法实用性更强, 适用范围更广. 例如, Bajcsy等对一些无监督波段选择方法进行了简要描述和实验, 包括信息熵、一阶和二阶谱导数、比值、相关性和基于主成分分析的排序算法^[5]. 袁博等将相

收稿日期: 2020-03-21; 修回日期: 2020-11-30.

基金项目: 国家自然科学基金联合基金资助项目(U1903215).

作者简介: 李 飞(1976-), 女, 博士生, E-mail: alinafeili@mail.dlut.edu.cn; 卢湖川*(1972-), 男, 教授, 博士生导师, E-mail: lhchuan@dlut.edu.cn.

对熵矩阵与互信息结合,定量描述高光谱影像信息分布,进行波段选择^[9]. Du 等提出了基于相似性的波段选择算法:线性预测(linear prediction, LP)和正交子空间投影(orthogonal subspace projection, OSP)^[10]. Yang 等又利用 GPU 将 LP 和 OSP 算法与并行算法相结合,提高了运算效率^[11]. Sui 等提出了一种无监督的波段选择算法,将总体精度和冗余度的约束结合到波段选择过程中,设计了一个平衡参数通过优化模型来权衡总体精度和冗余度^[12]. 曾梦等使用深度对抗子空间聚类实现了高光谱波段选择^[13].

稀疏表示是对原始信号的分解过程,在这个过程中,将输入信号表示为字典的线性近似.在图像处理领域,稀疏表示已成功应用于图像去噪、图像复原、图像识别等领域.于伟等利用稀疏表示理论将上下文字典学习用于提高图像超分辨率技术^[14].同样,在高光谱图像处理方面,稀疏表示方法也取得了巨大的成功^[15].本文在多字典稀疏表示(multi-dictionary sparse representation, MDSR)波段选择算法^[16]基础上,提出基于上下文多字典稀疏表示(context multi-dictionary sparse representation, CMDSR)波段选择算法. CMDSR 波段选择算法将图像的每个波段看作字典原子,用该字典对相邻多个波段进行联合稀疏表示求解,可以得到代表输入样本原子和相关权重的稀疏向量.向量中的非零元素可以看成是这些波段在整个图像中所占权重,最后利用累计权重求出每个波段图像对于整个高光谱图像的贡献度,优先选择贡献度大的波段.为了评价该算法的性能,将该算法同几种无监督波段选择算法进行比较.采用一组藻类水体的高光谱曲线数据和一幅公开高光谱图像数据集做实验.

1 算 法

1.1 波段选择算法 MDSR

波段选择的主要目的是找到一个最优或次优的波段子集,来代替原始高光谱图像信息.换句话说,这个波段子集在某些度量标准下能够近似表示原始数据.因此,应该找出每个波段对整个图像的贡献,根据贡献大小选择合适波段.稀疏表示可以用来计算波段对整个图像的贡献.当一个波段

图像由其他波段图像组成的字典来近似线性组合时,所求出的稀疏系数可以表示每个字典原子对目标波段图像的贡献.如果系数绝对值较大,则该波段原子对目标波段的贡献较大;如果系数绝对值较小,则该波段原子对目标波段的贡献较小.通过相应的字典计算每个波段的稀疏表示,得到一系列权重.通过统计权重可以得到各波段对整个图像的贡献.因此,权重较大的波段就是最后选定的波段.

描述高光谱图像的波段选择问题时,要处理的对象是每个波段的图像,而不是像素点.假设用 $\bar{Y} \in \mathbf{R}^{W \times H \times B}$ 表示原始高光谱图像, W 和 H 分别为图像行和列的像素个数, B 为波段数量.将每个波段的图像从一个二维矩阵拉伸成一个实向量,从而得到一个矩阵 $\mathbf{Y} = (\mathbf{y}_1 \quad \mathbf{y}_2 \quad \cdots \quad \mathbf{y}_B)$, 这里 \mathbf{y}_i 代表第 i 个波段图像拉伸后的列向量.假设每个波段都可以用其他波段组合来近似表示,可以用下面的公式来表示这个关系:

$$\mathbf{y}_i \approx \mathbf{D}_i \boldsymbol{\alpha}_i \quad (1)$$

这里字典矩阵 \mathbf{D}_i 包含除 \mathbf{y}_i 以外的其他波段, $\boldsymbol{\alpha}_i$ 是线性组合的系数.这个公式也可以转换成如下形式:

$$\mathbf{y}_i = \mathbf{D}_i \boldsymbol{\alpha}_i + \boldsymbol{\beta}_i \quad (2)$$

其中 $\boldsymbol{\beta}_i$ 是误差项.如果 $\boldsymbol{\alpha}_i$ 是稀疏的,那么可以计算出 $\boldsymbol{\alpha}_i$ 的值.可以将其看成是 \mathbf{D}_i 中每个原子对波段 \mathbf{y}_i 的贡献情况,系数越大,该原子对这个波段的贡献越大,反之亦然.稀疏系数 $\boldsymbol{\alpha}_i$ 可以通过求解下面的约束优化问题得到:

$$\begin{aligned} \hat{\boldsymbol{\alpha}} &= \arg \min \|\boldsymbol{\alpha}\|_0 \\ \text{s. t. } \quad & \mathbf{y}_i = \mathbf{D}_i \boldsymbol{\alpha}_i + \boldsymbol{\beta}_i \end{aligned} \quad (3)$$

其中 $\|\cdot\|_0$ 是 0 范数,计算向量中非零元素的个数.由于在经验数据中,逼近误差通常被限制在可控区间,上面的公式可以放宽到下面的不等式形式:

$$\begin{aligned} \hat{\boldsymbol{\alpha}} &= \arg \min \|\boldsymbol{\alpha}\|_0 \\ \text{s. t. } \quad & \|\mathbf{D}_i \boldsymbol{\alpha}_i - \mathbf{y}_i\|_2 \leq \sigma \end{aligned} \quad (4)$$

其中 $\|\cdot\|_2$ 是 L_2 范数, σ 是误差容限.上述优化问题可以进一步解释为在一定的稀疏水平上最小化近似误差:

$$\begin{aligned} \hat{\boldsymbol{\alpha}} &= \arg \min \|\mathbf{D}_i \boldsymbol{\alpha}_i - \mathbf{y}_i\|_2 \\ \text{s. t. } \quad & \|\sigma\|_2 \leq K_0 \end{aligned} \quad (5)$$

其中 K_0 是给定稀疏度的上界.可以用贪婪追踪

算法近似求解,例如,匹配追踪(matching pursuit, MP)算法、正交匹配追踪(orthogonal matching pursuit, OMP)算法、子空间追踪(subspace pursuit, SP)算法. 这里采用 OMP 算法求解^[17]. MP 算法的基本思想是:通过从字典矩阵中选择与信号匹配的原子来构造稀疏近似. 通过推导信号的残差,选择与残差匹配最佳的原子. 重复上述过程,直到残差可以忽略或达到预先定义的迭代次数. OMP 算法在 MP 算法基础上做了改进,要求在分解每一步选择的所有原子都是正交的. 在相同的准确度条件下,OMP 算法的收敛速度比 MP 算法快.

每个波段图像由相应的字典表示之后,得到一个稀疏系数矩阵. 在该矩阵中,大多数系数都为零. 系数的绝对值越大,对应的字典原子对原始高光谱图像贡献越大. 对整个系数矩阵,按行计算不为零的系数个数,得到一个横坐标为波段标号的直方图. 如果用 h_i 表示直方图,那么计算公式如下:

$$h_i = \sum_{j=1}^B g(\alpha_{ij})/B \quad (6)$$

当 $x=0$ 时, $g(x)=0$, 其他情况下 $g(x)=1$. 在直方图中,对系列进行排序,最后选系列值较大的波段. 下面给出具体的算法步骤.

步骤 1 将高光谱图像拉伸成二维矩阵.

步骤 2 随机选取 N 个像元,形成新的样本集: $\hat{Y} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_N\}$, $\hat{y}_i \in \mathbf{R}^N$.

步骤 3 建立一组过完备字典,每个字典矩阵形式为 $\mathbf{D}_i = (\hat{y}_1 \ \hat{y}_2 \ \dots \ \hat{y}_{i-1} \ \mathbf{0} \ \hat{y}_{i+1} \ \dots \ \hat{y}_N)$.

步骤 4 用 OMP 算法求解式(5),得到由 α 构成的稀疏系数矩阵 $\tilde{\mathbf{X}} \in \mathbf{R}^{B \times H}$.

步骤 5 用式(6)统计非零元素系数个数.

步骤 6 对每个波段非零元素系数个数按降序排列,选取前 \tilde{B} 个波段为最后结果.

1.2 波段选择算法 CMDSR

高光谱图像中,相邻元素的光谱具有很高的相似性^[18],同理,相邻波段通常也具有相似的空间信息,因此在上文提出的稀疏表示模型中,应该考虑上下文波段信息,整体流程如图 1 所示. 对于给定的字典,小范围内邻域波段的稀疏性相似,是相同公共原子的稀疏线性组合,只是对应的稀疏系数不同. 例如 \mathbf{y}_i 和 \mathbf{y}_j 是两个相邻的波段图像,那么 \mathbf{y}_i 对字典的稀疏表示为

$$\mathbf{y}_i = \mathbf{D}\boldsymbol{\alpha}_i = \alpha_{i,\lambda_1} \mathbf{d}_{\lambda_1} + \alpha_{i,\lambda_2} \mathbf{d}_{\lambda_2} + \dots + \alpha_{i,\lambda_k} \mathbf{d}_{\lambda_k} \quad (7)$$

这里下标集 $\Lambda_k = \{\lambda_1, \lambda_2, \dots, \lambda_k\}$ 对应字典原子的下标. \mathbf{y}_j 与 \mathbf{y}_i 相邻,那么支撑 \mathbf{y}_j 的原子集与支撑 \mathbf{y}_i 的原子集相同,可用 $\{\mathbf{d}_v\}_{v \in \Lambda_k}$ 表示,但是对应的系数集 $\{\alpha_{j,v}\}_{v \in \Lambda_k}$ 不同,即:

$$\mathbf{y}_j = \mathbf{D}\boldsymbol{\alpha}_j = \alpha_{j,\lambda_1} \mathbf{d}_{\lambda_1} + \alpha_{j,\lambda_2} \mathbf{d}_{\lambda_2} + \dots + \alpha_{j,\lambda_k} \mathbf{d}_{\lambda_k} \quad (8)$$

由此可以扩展到一个包含多个相邻波段的邻域情况,例如, $\mathbf{Y} = (\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_N)$ 表示一个 $B \times N$ 的矩阵,列向量 $\{\mathbf{y}_n\}_{n=1,2,\dots,N}$ 是其中的一个波段,可以用联合稀疏表示:

$$\begin{aligned} \mathbf{Y} &= (\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_N) = \\ &(\mathbf{D}\boldsymbol{\alpha}_1 \ \mathbf{D}\boldsymbol{\alpha}_2 \ \dots \ \mathbf{D}\boldsymbol{\alpha}_N) = \\ &\mathbf{D}(\boldsymbol{\alpha}_1 \ \boldsymbol{\alpha}_2 \ \dots \ \boldsymbol{\alpha}_N) = \mathbf{D}\mathbf{S} \end{aligned} \quad (9)$$

这里 $\mathbf{S} = (\boldsymbol{\alpha}_1 \ \boldsymbol{\alpha}_2 \ \dots \ \boldsymbol{\alpha}_N)$, 它是一个行稀疏矩阵,在给定字典 \mathbf{D} 的情况下,可以通过解决下面的联合稀疏问题求解:

$$\begin{aligned} \min \quad & \|\mathbf{S}\|_{\text{row},0} \\ \text{s. t.} \quad & \mathbf{Y} = \mathbf{D}\mathbf{S} \end{aligned} \quad (10)$$

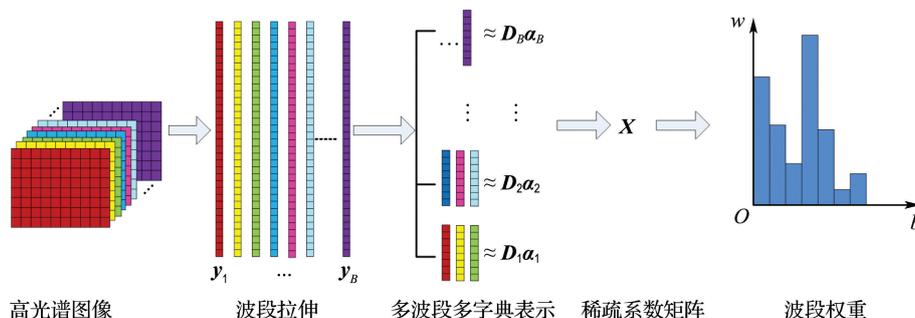


图 1 本文提出的波段选择算法总体流程图

Fig. 1 The flow chart of the proposed band selection algorithm

上面的公式也可以改写成

$$\begin{aligned} \hat{S} &= \arg \min \|DS - Y\|_F \\ \text{s. t. } \|S\|_{\text{row},0} &\leq K_0 \end{aligned} \quad (11)$$

其中 $\|\cdot\|_F$ 表示 F 范数. 该稀疏求解可以采用同步正交匹配追踪 (simultaneous orthogonal matching pursuit, SOMP) 算法^[19]. 在 SOMP 算法中, 求得结果是按顺序更新的, 每次迭代时, 选择同时对所有残差向量都是最佳结果的原子. 在残差足够小, 或达到期望的稀疏度, 或达到预设的迭代次数时, 算法结束. 基于 SOMP 的上下文波段选择算法描述如下:

步骤 1 将高光谱图像拉伸成二维矩阵.

步骤 2 随机选取 N 个像元, 形成新的样本集: $\hat{Y} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_B\}, \hat{y}_i \in \mathbb{R}^N$.

步骤 3 建立一组过完备字典, 每个字典矩阵形式为 $D_i = (\hat{y}_1 \ \hat{y}_2 \ \dots \ \hat{y}_{i-1} \ \mathbf{0} \ \hat{y}_{i+1} \ \dots \ \hat{y}_B)$.

步骤 4 用 SOMP 算法求解式(11), 得到由 α 构成的稀疏系数矩阵 $\tilde{X} \in \mathbb{R}^{B \times H}$.

步骤 5 用式(6)统计非零元素系数个数.

步骤 6 对每个波段非零元素系数个数按降序排列, 选取前 \tilde{B} 个波段为最后结果.

2 实验结果与分析

在实验中, 将本文算法与 4 种波段选择算法做比较, 分别是 MDSR 算法、LP 算法、OSP 算法和 Cluster(基于聚类的波段选择)算法.

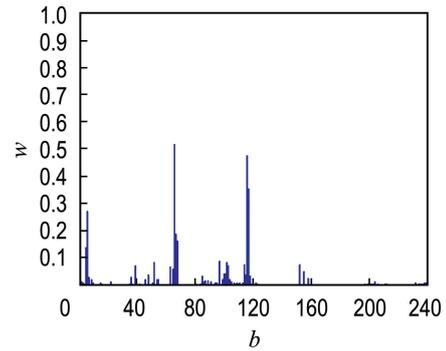
2.1 数据描述

本实验采用两组数据集, 第 1 组是藻类水体高光谱数据, 来自中国海洋监控中心遥感实验室. 它是 4 类藻种水体在不同叶绿素浓度下的光谱反射率曲线, 包括甲藻、叉角藻、夜光藻和异弯藻. 光谱值包含 240 个波段, 波长覆盖范围为 400 ~ 1 000 nm. 第 2 组数据 ROSIS 高光谱图像 PaviaU 采集自意大利北部的帕维亚大学校园, 共有 103 个波段, 610 × 340 个像元, 包含 9 类地物.

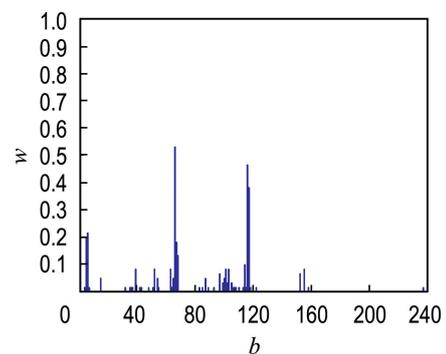
2.2 波段选择结果

MDSR 和 CMDSR 两个算法中, 创建的字典要保证过完备性, 但是高光谱图像拉伸成二维矩阵后, 维数过大, 因此要减少字典的原子维数. 在文献[16]和本文中均采用随机选取 N 个像元的方法, 文献[16]验证了 N 值的变化不会影响波段

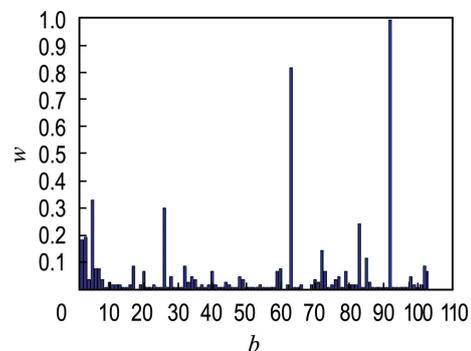
选择的结果和性能. 图 2 展示 MDSR 和 CMDSR



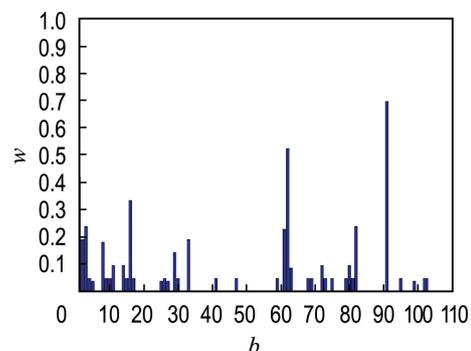
(a) 藻类水体高光谱数据 MDSR 结果



(b) 藻类水体高光谱数据 CMDSR 结果



(c) PaviaU 图像 MDSR 结果



(d) PaviaU 图像 CMDSR 结果

图 2 两组数据集的波段权重

Fig. 2 Band weights of two data sets

算法对两组数据集的波段选择结果. 横坐标为波段序号, 纵坐标是波段权重. 权重值越大, 说明该波段对整个数据的贡献越多. CMDSR 算法的处理结果与 MDSR 算法的处理结果基本一致, 但是在时间效率上考虑, CMDSR 算法效果更好.

2.3 性能分析

为了分析波段选择算法的性能, 从分类精度、波段相关性和算法运行时间 3 个方面与其他波段选择算法进行比较和分析.

(1) 分类精度

采用 KNN 方法对波段选择后的藻类水体数据和 PaviaU 数据进行分类. 在藻类水体高光谱分类实验中, 每类选 3 个样本; 在 PaviaU 高光谱图像分类实验中, 每类选 20 个样本. 波段数量从 1 到 50. 在 MDSR 和 CMDSR 方法的实现过程中, 稀疏度设置为 6. 在 KNN 方法实现过程中, 最近邻值分别设置为 4 和 6. 为了减少随机性, 每个结果都经过 10 次运行后求得平均值. 图 3 表示了两组数据的整体分类精度. 横坐标为波段数量 B ,

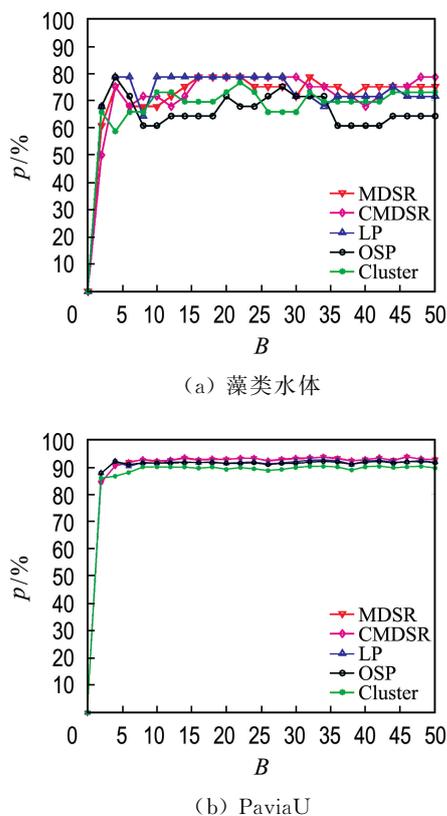


图 3 不同波段选择算法的分类结果比较
Fig. 3 Comparison of classification results of different band selection algorithms

纵坐标为总体分类精度 p . 由于藻类水体数据每类样本数量较少, 精度变化差异较大, 在波段数量超过 30 之后, MDSR 和 CMDSR 表现了较好的效果. 在 PaviaU 数据上, 各个算法所得分类精度相差不多, 都比较平稳, 但整体来说 MDSR 和 CMDSR 算法优于其他算法, 而基于聚类的算法稍显落后.

(2) 相关系数

为了衡量所选波段的可分性, 计算了不同算法所选波段的相关系数. 一般来说, 所选波段之间的相关性越低越好. 图 4 显示了波段之间的相关性随波段数目的变化情况. 横坐标为波段数量, 纵坐标为波段间相关系数 c . 除了 OSP 算法外, 其他几种算法的波段选择结果都显示了比较低的相关性, 尤其在波段数量比较少时, CMDSR 算法体现了很好的性能.

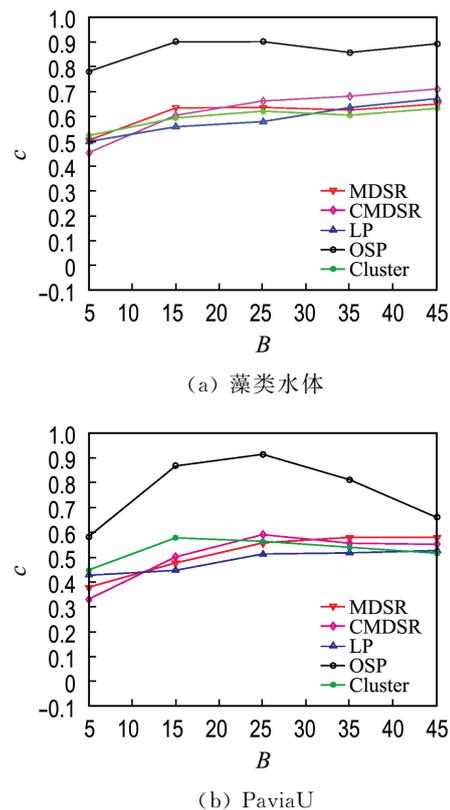
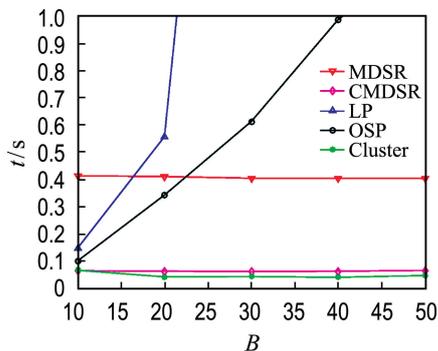


图 4 不同波段选择算法的平均相关系数比较
Fig. 4 Comparison of average correlation coefficient of different band selection algorithms

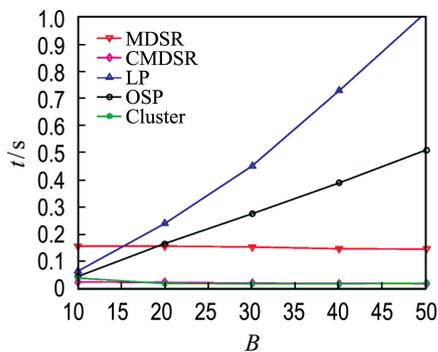
(3) 运行时间

为了评估该算法的效率, 计算了每种算法的运行时间. 所有比较的算法都在 Matlab 2016 中

实现,并在 8 GB 内存, Intel Core i5-2400 CPU 的运行环境下进行测试. 图 5 显示了不同波段选择算法在波段数目不同时的运行时间. 横坐标为波段数量, 纵坐标为算法运行时间. 结果表明, 基于聚类的算法耗时最少. 虽然本文算法不是最快的, 但是它与大多数算法比较, 效率比较高, 更重要的是, 本文提出的算法几乎不受波段数量的影响, 而 LP 和 OSP 算法随着波段数量的增加运行耗时越来越长. 由于 CMDSR 算法计算的迭代次数明显比 MDSR 算法少, 因此在运行时间上更有优势.



(a) 藻类水体



(b) PaviaU

图 5 运行时间比较

Fig. 5 Comparison of computational time

3 结 语

本文提出的高光谱图像波段选择算法,很好地保留了原始图像某些波段的物理信息. 与目前流行的几种波段选择算法比较,在分类精度上可以达到或超过其他同类算法,在相关性和运行时间上表现出更大的优势. 本文不但在公开数据集上,而且在一组藻类水体高光谱数据集上验证了所提算法的可行性.

参考文献:

- [1] 童庆禧, 张兵, 郑兰芬. 高光谱遥感——原理、技术与应用 [M]. 北京: 高等教育出版社, 2006.
TONG Qingxi, ZHANG Bing, ZHENG Lanfen. **Hyperspectral Remote Sensing — Principle, Technology and Application** [M]. Beijing: Higher Education Press, 2006. (in Chinese)
- [2] HUGHES G. On the mean accuracy of statistical pattern recognizers [J]. **IEEE Transactions on Information Theory**, 1968, **14**(1): 55-63.
- [3] CHANG C I. **Hyperspectral Imaging: Techniques for Spectral Detection and Classification** [M]. New York: Plenum Publishing Co., 2003.
- [4] JIA Xiuping, KUO B C, CRAWFORD M M. Feature mining for hyperspectral image classification [J]. **Proceedings of the IEEE**, 2013, **101**(3): 676-697.
- [5] BAJCSY P, GROVES P. Methodology for hyperspectral band selection [J]. **Photogrammetric Engineering and Remote Sensing**, 2004, **70**(7): 793-802.
- [6] WEI Wei, DU Qian, YOUNAN N H, *et al.* Fast supervised hyperspectral band selection using graphics processing unit [J]. **Journal of Applied Remote Sensing**, 2012, **6**(1): 885-886.
- [7] YANG He, DU Qian, SU Hongjun, *et al.* An efficient method for supervised hyperspectral band selection [J]. **IEEE Geoscience and Remote Sensing Letters**, 2011, **8**(1): 138-142.
- [8] CAO Xianghai, XIONG Tao, JIAO Licheng. Supervised band selection using local spatial information for hyperspectral image [J]. **IEEE Geoscience and Remote Sensing Letters**, 2016, **13**(3): 329-333.
- [9] 袁博, 胡冰. 相对熵结合互信息的高光谱波段选择方法 [J]. 遥感信息, 2019, **34**(6): 33-38.
YUAN Bo, HU Bing. Band selection algorithm for hyperspectral remote sensing with relative entropy and mutual information [J]. **Remote Sensing Information**, 2019, **34**(6): 33-38. (in Chinese)
- [10] DU Qian, YANG He. Similarity-based unsupervised band selection for hyperspectral image analysis [J]. **IEEE Geoscience and Remote Sensing Letters**, 2008, **5**(4): 564-568.

- [11] YANG He, DU Qian, CHEN Genshe. Unsupervised hyperspectral band selection using graphics processing units [J]. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 2011, **4**(3): 660-668.
- [12] SUI Chenhong, TIAN Yan, XU Yiping, *et al.* Unsupervised band selection by integrating the overall accuracy and redundancy [J]. **IEEE Geoscience and Remote Sensing Letters**, 2015, **12**(1): 185-189.
- [13] 曾梦, 宁彬, 蔡之华, 等. 使用深度对抗子空间聚类实现高光谱波段选择 [J]. 计算机应用, 2020, **40**(2): 381-385.
- ZENG Meng, NING Bin, CAI Zhihua, *et al.* Hyperspectral band selection based on deep adversarial subspace clustering [J]. **Journal of Computer Applications**, 2020, **40**(2): 381-385. (in Chinese)
- [14] 于伟, 姚鸿勋, 孙晓帅, 等. 面向图像超分辨率的上下文字典学习 [J]. 计算机科学, 2014, **41**(10): 87-90.
- YU Wei, YAO Hongxun, SUN Xiaoshuai, *et al.* Contextual dictionary learning for super resolution [J]. **Computer Science**, 2014, **41**(10): 87-90. (in Chinese)
- [15] 任越美, 李垒, 张艳宁, 等. 一种基于多粒子群协同进化的高光谱图像波段选择与分类方法 [J]. 计算机科学, 2014, **41**(12): 283-287.
- REN Yuemei, LI Lei, ZHANG Yanning, *et al.* Band selection and classification for hyperspectral image based on multiple particle swarm cooperative optimization [J]. **Computer Science**, 2014, **41**(12): 283-287. (in Chinese)
- [16] LI Fei, ZHANG Pingping, LU Huchuan. Unsupervised band selection of hyperspectral images via multi-dictionary sparse representation [J]. **IEEE Access**, 2018, **6**: 71632-71643.
- [17] TROPP J A, GILBERT A C. Signal recovery from random measurements via orthogonal matching pursuit [J]. **IEEE Transactions on Information Theory**, 2007, **53**(12): 4655-4666.
- [18] CHEN Yi, NASRABADI N M, TRAN T D. Hyperspectral image classification using dictionary-based sparse representation [J]. **IEEE Transactions on Geoscience and Remote Sensing**, 2011, **49**(10): 3973-3985.
- [19] DETERME J F, LOUVEAUX J, JACQUES L, *et al.* On the noise robustness of simultaneous orthogonal matching pursuit [J]. **IEEE Transactions on Signal Processing**, 2017, **65**(4): 864-875.

Hyperspectral band selection based on context multi-dictionary learning

LI Fei^{1,2}, LU Huchuan^{*1}, BO Chunjuan³

(1. Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116024, China;
2. College of Computer Science, Shenyang Aerospace University, Shenyang 110136, China;
3. School of Electromechanical Engineering, Dalian Minzu University, Dalian 116600, China)

Abstract: There are a lot of redundant information in hyperspectral images. Band selection is an effective method to reduce redundancy and reduce spectral dimension. A new band selection algorithm for hyperspectral image based on context multi-dictionary learning is proposed. Under this new algorithm, each band image can be approximately represented by a linear combination of other band images, and adjacent band images have similar properties. Using the sparse solution method, the weight of each band corresponding to the whole original image is obtained, and bands can be selected by their weights. Experimental results show that the proposed algorithm has better performance than other band selection algorithms.

Key words: hyperspectral images; band selection; sparse representation