

DOI:10.13203/j.whugis20150052



文章编号:1671-8860(2017)04-0441-08

利用稀疏自表达实现高光谱影像波段选择

孙伟伟^{1,2,3} 蒋曼² 李巍岳⁴

1 航空遥感技术国家测绘地理信息局重点实验室,北京,100830

2 宁波大学建筑工程与环境学院,浙江 宁波,315211

3 武汉大学测绘遥感信息工程国家重点实验室,武汉,430079

4 上海师范大学城市发展研究院,上海,200234

摘要:提出一种稀疏自表达方法来研究高光谱影像分类中的波段选择问题。该方法利用字典矩阵等于测量矩阵的条件来改进多观测向量的稀疏表达模型,将波段子集看作高光谱影像波段集中的代表子集。稀疏自表达方法将波段选择转换为寻求多观测向量中稀疏系数矩阵的非零行向量问题,通过引入混合范数来限定非零元素行向量的个数,利用快速交替方向乘子方法求解稀疏系数矩阵,并聚类非零行向量,实现波段的有效选择。基于两个公开高光谱影像数据集并对比其他4种波段选取方法来验证稀疏自表达方法。实验结果证明,稀疏自表达方法能够在计算效率明显优于基于波段相关性的线性限制最小方差方法的同时,取得与该方法和非负稀疏矩阵分解方法相匹甚至略高的总体分类精度。

关键词:波段选择;稀疏自表达;多观测向量;高光谱影像;分类;快速交替方向乘子

中图法分类号:P237

文献标志码:A

高光谱影像利用成像光谱仪,收集可见光至近红外的几十至数百个波段的光谱响应信息,通过分类技术可以实现地物之间的细微差异区分。高光谱影像分类已广泛应用于植被覆盖制图、海洋环境监测、矿区制图和军事目标识别等领域。然而,由于高光谱影像的光谱波段众多且相关性导致高光谱影像处理的计算量较大,加之野外实际样本采集难度较大,导致高光谱影像存在严重的“维数灾难”现象^[1]。因此,通常先对高光谱影像进行波段选择的降维处理,降低高光谱影像的数据量和波段相关性,然后进行后续的高光谱影像分类^[2]。

近年来,稀疏表达理论的出现和兴起,为高光谱影像波段选择提供了新的研究思路和方法。稀疏表达理论认为一个正常信号投影至特定的变换空间(变化基)能够变为一个稀疏信号,其中的少数非零元素能够很好地继承原始信号的特性^[3]。稀疏表达理论与压缩感知技术关系密切,是压缩感知技术的重要理论基础,能够减少数据采集量并采用复杂的重构算法来恢复原始信号,目前广

泛应用于高光谱影像的混合像元分解、特征提取^[4]、异常探测^[5,6]等众多领域。理论证明,波段的稀疏系数向量能够凸显原始高光谱影像中的一些潜在结构信息,利用这些潜在信息可以实现波段的选取。如 Li 和 Qi 基于稀疏表达理论,分析稀疏系数矩阵的直方图分布来确定波段的重要性,选取最佳的波段组合^[7]。Li^[8]和施琦琦^[9]等分析稀疏系数矩阵的聚类结构特征,利用欧氏距离度和相对熵距离度约束将高光谱数据矩阵分解为低阶字典矩阵和稀疏系数矩阵,根据稀疏系数矩阵中对应的系数权重大小确定该波段的聚类,最终实现波段的有效选取。Du 等基于协同稀疏模型,利用稀疏回归系数来改善光谱影像的波段选取效果^[10]。Chepushtanova 等提出稀疏支持向量机模型,利用 L_1 范数正则化约束的二值分类器来获取稀疏系数向量,进而选取有效波段组合^[11]。近期,孙伟伟等提出采用稀疏子空间的思想,利用波段相关性和 L_2 范数约束来聚类并选取高光谱影像的有效波段^[12]的方法。

收稿日期:2015-01-30

项目资助:国家自然科学基金(41671342, 41401389);航空遥感技术国家测绘地理信息局重点实验室经费资助课题(2015B12);中国博士后科学基金(2016T90732, 2015M570668);浙江省科技厅公益项目(2016C33021)。

第一作者:孙伟伟,副教授,主要从事地理信息系统和遥感理论与方法及“3S”技术在海岸带资源管理与环境变化监测中的应用研究。

sunweiwei@nbu.edu.cn

通讯作者:李巍岳,博士。lwy_326@126.com

不同于当前研究,本文利用字典矩阵等于观测矩阵来改进多观测向量的稀疏表达理论,采用稀疏系数矩阵的 $L_{1,2}$ 混合范数来限定非零行向量的个数,提出稀疏自表达(sparse self-representation, SSR)的高光谱影像波段选择方法。

1 多观测向量的高光谱影像稀疏表达模型

单观测向量的稀疏表达模型认为,一组 L 维的高光谱向量(光谱向量或波段向量) $\mathbf{y} \in \mathbf{R}^{L \times 1}$ 在某组特定变换基 $\{\mathbf{a}_i\}_{i=1}^M$ (\mathbf{a}_i 为 M 维列向量)下展开,即式(1):

$$\mathbf{y} = \sum_{i=1}^M \theta_i \mathbf{a}_i = \mathbf{A}\mathbf{x} + \mathbf{e} \quad (1)$$

式中, $\mathbf{A} = [\mathbf{a}_1 \ \mathbf{a}_2 \ \cdots \ \mathbf{a}_L] \in \mathbf{R}^{L \times M}$ 为字典矩阵(满足 $\mathbf{A}\mathbf{A}^T = \mathbf{A}^T\mathbf{A} = \mathbf{I}$), \mathbf{R} 为实数符号;系数向量 $\mathbf{x} = [\theta_1 \ \theta_2 \ \cdots \ \theta_M]^T$ 为 k -稀疏的,即非零系数的个数 k 远小于 M , θ_i 为系数向量中任一元素; \mathbf{e} 为高光谱影像采集过程中存在的随机噪声。假设高光谱数据集 $\mathbf{Y} = [\mathbf{y}_1 \ \mathbf{y}_2 \ \cdots \ \mathbf{y}_N]$ 包含 N 远大于 L 个向量元素,将每一维向量 \mathbf{y}_i 按列方向排列,式(1)转换为多观测向量的稀疏表达模型^[13]:

$$\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{E} \quad (2)$$

式中, $\mathbf{X} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \cdots \ \mathbf{x}_N]$ 是稀疏向量矩阵,其中任一高光谱向量 $\mathbf{y}_j = \mathbf{Y}\mathbf{x}_j + \mathbf{e}_j$; $\mathbf{E} = [\mathbf{e}_1 \ \mathbf{e}_2 \ \cdots \ \mathbf{e}_N]$ 为误差项矩阵。式(2)的求解可以转换为目标优化问题:

$$\begin{aligned} \hat{\mathbf{X}} &= \arg \min_{\mathbf{X}} \|\mathbf{Y} - \mathbf{A}\mathbf{X}\|_F^2 \\ \text{s.t. } &\|\mathbf{x}_i\|_0 \leq k, \mathbf{X} \geq 0 \end{aligned} \quad (3)$$

式中, $\|\mathbf{x}_i\|_0$ 表示稀疏系数列向量 \mathbf{x}_i 中非零元素的个数。考虑到其中每一列的稀疏性导致系数矩阵 \mathbf{X} 的整体稀疏性,式(3)的目标函数优化问题可以近似转换为求解 \mathbf{X} 的 L_0 范数问题:

$$\begin{aligned} \arg \min \|\mathbf{X}\|_0 &= \min \left\| \left(\sum_{j=1}^L x_{ij} \right)_{i \in \Omega} \right\|_0, \\ \Omega &= \{1, 2, \dots, M\} \\ \text{s.t. } &\|\mathbf{Y} - \mathbf{A}\mathbf{X}\|_F^2 \leq \sigma \text{ 且 } \mathbf{X} \geq 0 \end{aligned} \quad (4)$$

式中, $\left\| \left(\sum_{j=1}^L x_{ij} \right)_{i \in \Omega} \right\|_0$ 为稀疏矩阵 \mathbf{X} 的 L_0 范数; σ 为设定的逼近误差。式(4)的最优解为找寻 \mathbf{X} 中非零元素的个数 $|S| := \text{supp}(\mathbf{X}) := \{1 \leq i \leq m; \mathbf{x}_i \neq \mathbf{0}\}$ 。考虑到 L_0 范数问题的非凸性和较高的计算复杂度,通常将式(4)的 L_0 范数优化问题,松弛为 L_1 和 L_2 范数的求解问题来进行求解,如利用 $L_{1,2}$ 范数约束的 SPG 算法^[14],

基于 L_2 范数约束的普化子空间追踪算法^[15]。

2 基于稀疏自表达模型的高光谱影像波段选择

2.1 高光谱波段向量的稀疏自表达模型

多观测向量稀疏表达模型认为,高光谱影像数据集 $\mathbf{Y} = [\mathbf{y}_1 \ \mathbf{y}_2 \ \cdots \ \mathbf{y}_N] \in \mathbf{R}^{L \times N}$ 可以在字典矩阵 $\mathbf{A} = [\mathbf{a}_1 \ \mathbf{a}_2 \ \cdots \ \mathbf{a}_M] \in \mathbf{R}^{L \times M}$ 构成的特征空间中近似展开为稀疏系数矩阵 $\mathbf{X} = [\mathbf{x}_1 \ \cdots \ \mathbf{x}_j \ \cdots \ \mathbf{x}_N] \in \mathbf{R}^{M \times N}$,其中 L 为高光谱影像的像素个数, N 为波段数, M 为字典矩阵中变换基的个数。波段选择中,波段子集可认为是高光谱影像中的代表波段的集合,因此任一波段可以由波段子集对应的波段向量来线性组合表示。进一步,任一波段可以在高光谱影像数据中所有波段向量构建的特征空间内进行稀疏展开,得到的稀疏系数向量中非零元素的位置指向波段子集,即波段子集中的各波段对应的重构系数非0,非波段子集对应的重构系数为0。因此,式(2)的稀疏表达模型中,字典矩阵 \mathbf{A} 可转换为 $\mathbf{A} = \mathbf{Y}$,得到高光谱影像的稀疏自表达模型^[16]:

$$\begin{aligned} \mathbf{Y} &= \mathbf{Y}\mathbf{X} + \mathbf{E} \\ &\quad \begin{matrix} L \times N & L \times N & N \times N & L \times N \end{matrix} \\ \text{s.t. } &\mathbf{X} \geq 0, \text{diag}(\mathbf{X}) = 0 \end{aligned} \quad (5)$$

式中,每一列为高光谱的波段向量 $\mathbf{y}_j = \mathbf{Y}\mathbf{x}_j + \mathbf{e}_j$, $\mathbf{x}_{jj} = 0$, $\|\mathbf{x}_j\|_0 \leq p$; \mathbf{E} 为随机噪声矩阵; $\mathbf{X} \geq 0$ 是为了满足高光谱影像的光谱响应的非负特性; $\text{diag}(\mathbf{X}) = 0$ 是指稀疏系数矩阵 \mathbf{X} 的对角元素都为0,为了避免任意波段 \mathbf{y}_i 只被自身的波段向量所表示。 $\mathbf{y}_j = \mathbf{Y}\mathbf{x}_j + \mathbf{e}_j$ 的物理意义为每一个波段向量 \mathbf{y}_j 可以在所有波段向量构成的特征空间中稀疏展开,其对应的稀疏向量 \mathbf{x}_j 中非零元素代表波段子集对该波段重构的贡献大小。式(5)的求解可以转换为类似于式(4)的最小化重构误差的范数求解问题:

$$\begin{aligned} \hat{\mathbf{X}} &= \arg \min_{\mathbf{X}} \|\mathbf{Y} - \mathbf{Y}\mathbf{X}\|_F^2 \\ \text{s.t. } &\|\mathbf{x}_j\|_0 \leq p, \mathbf{X} \geq \mathbf{0}, \text{diag}(\mathbf{X}) = 0 \end{aligned} \quad (6)$$

式中, $\|\mathbf{x}_j\|_0 \leq p$ 是指每一列的系数向量为 p -稀疏。式(6)中系数矩阵 \mathbf{X} 的稀疏特性限制可以近似转换为其行方向的稀疏限制条件,即:

$$\begin{aligned} \hat{\mathbf{X}} &= \arg \min_{\mathbf{X}} \|\mathbf{Y} - \mathbf{Y}\mathbf{X}\|_F^2 \\ \text{s.t. } &\|\mathbf{X}\|_{0,2} \leq p, \mathbf{X} \geq \mathbf{0}, \text{diag}(\mathbf{X}) = 0 \end{aligned} \quad (7)$$

式中, $\|\mathbf{X}\|_{0,2} = \sum_{i=1}^N I(\|\mathbf{x}^i\|_2 > 0)$, 其中 \mathbf{x}^i 是系数矩阵 \mathbf{X} 中第 i 行的系数向量, $I(\cdot)$ 是指示函

数。即 $\| \mathbf{X} \|_{0,2} \leq p$ 限制系数矩阵向量 \mathbf{X} 中非零行向量的个数。进一步,考虑到稀疏矩阵的全局不变性和 $L_{0,q}$ 范数的计算复杂性,式(7)可以通过 L_1 范数松弛,转换为以下优化问题:

$$\hat{\mathbf{X}} = \arg \min_{\mathbf{X}} \| \mathbf{Y} - \mathbf{YX} \|_F^2$$

$$\text{s.t. } \| \mathbf{X} \|_{1,2} \leq t, \mathbf{X} \geq 0, \mathbf{1}^T \mathbf{X} = \mathbf{1}^T, \text{diag}(\mathbf{X}) = 0 \quad (8)$$

式中, $\| \mathbf{X} \|_{1,2} = \sum_{i=1}^N \| \mathbf{x}^i \|_2$ 是 \mathbf{X} 中每一行向量 \mathbf{x}^i 的 L_2 范数之和; t 为设定范数限制大小。

2.2 稀疏系数矩阵的求解

利用拉格朗日乘法原理,式(8)的目标优化问题可以转换为:

$$\hat{\mathbf{X}} = \arg \min_{\mathbf{X}} \frac{1}{2} \| \mathbf{Y} - \mathbf{YX} \|_F^2 + \lambda \| \mathbf{X} \|_{1,2}$$

$$\text{s.t. } \mathbf{X} \geq 0, \mathbf{1}^T \mathbf{X} = \mathbf{1}^T, \text{diag}(\mathbf{X}) = 0 \quad (9)$$

式中, $\lambda > 0$ 为平衡参数,用来控制 $\| \mathbf{X} \|_{1,2}$ 对整个目标函数的影响。式(9)可以采用类似于多观测向量模型求解的方法来进行求解,如 SPGL1 方法、交替方向乘子法和正交匹配追踪方法等。相比其他方法,交替方向乘子法充分利用目标优化函数的可分离性,利用拉格朗日方程将式(9)的目标优化问题分解为若干个更容易得到全局解的交替的极小化子问题进行分析,通过各子问题的全局优化来得到原始问题(9)的最优解^[17]。考虑到交替方向乘子法的收敛效率较低,本文采用快速交替方向乘子法^[18]来求解式(9)的问题,得到满足最优的稀疏系数矩阵 $\hat{\mathbf{X}}$ 。

可以看出, $\hat{\mathbf{X}}$ 中非零行向量中系数的数量和大小代表着其对应的 \mathbf{Y} 中的波段向量用来重构原始的高光谱波段数据集中其他波段向量的权重大小。即 $\hat{\mathbf{X}}$ 中非零行向量的范数大小代表其对原始高光谱波段数据集的贡献大小。因此,理论上可以通过选择稀疏系数矩阵 $\hat{\mathbf{X}}$ 对应的非零行向量对应的波段序号来确定波段子集。然而,由于高光谱影像中相邻波段相关性太强,可能导致相邻两个或数个波段在稀疏系数矩阵 $\hat{\mathbf{X}}$ 中具有相近的非零行向量。因此,本文采用 K -均值聚类方法,聚类稀疏系数矩阵 $\hat{\mathbf{X}}$ 中非零行向量至 k 个类别中,通过选取距离其类中心最近的非零行向量对应的波段作为代表波段来构成最终波段子集。

2.3 基于稀疏自表达模型的波段选择流程

稀疏自表达模型 SSR 用于高光谱影像波段选择的流程如下。

1) 将三维的高光谱影像立方体转换为二维

波段向量数据集 \mathbf{Y} ,以二维矩阵形式表示,其中波段数为 \mathbf{Y} 对应的矩阵的列数,高光谱影像中像素个数为 \mathbf{Y} 的行数;

2) 利用式(5)构建高光谱影像波段数据集的稀疏自表达模型;

3) 将式(5)的稀疏自表达模型求解问题转换为式(8)的目标方程优化问题,利用拉格朗日方程展开为式(9)并采用快速交替方向乘子法来求解,得到满足条件的稀疏系数矩阵 $\hat{\mathbf{X}}$;

4) 利用 K -均值方法来聚类稀疏系数矩阵中的非零行向量,选取距离各类中心最近的非零行向量对应的波段构成最终的波段子集。

3 实验和分析

3.1 实验数据

Urban 数据为从美国陆军地理空间中心获取的 HYDICE 高光谱影像数据。数据采集于 1995 年 10 月,空间分辨率为 2 m,光谱分辨率为 10 nm。影像大小为 307 像素 \times 307 像素,覆盖美国德克萨斯州科帕拉斯区域(靠近胡德堡),如图 1(a)所示。对原始的 210 波段数据进行预处理,移除低噪比波段,剩余 162 波段,包含 22 种主要地物,各地物样本的真实空间分布和训练及测试样本信息如图 1(b)和表 1 所示。表 1 中训练样本总数为 446,测试样本总数为 1 708。PaviaU 数据来自西班牙巴斯克大学计算智能课题组,影像覆盖帕维亚大学区域,共 103 波段,空间分辨率为 1.3 m,如图 1(c)所示。影像为较大数据集集中的一部分,包含 350 像素

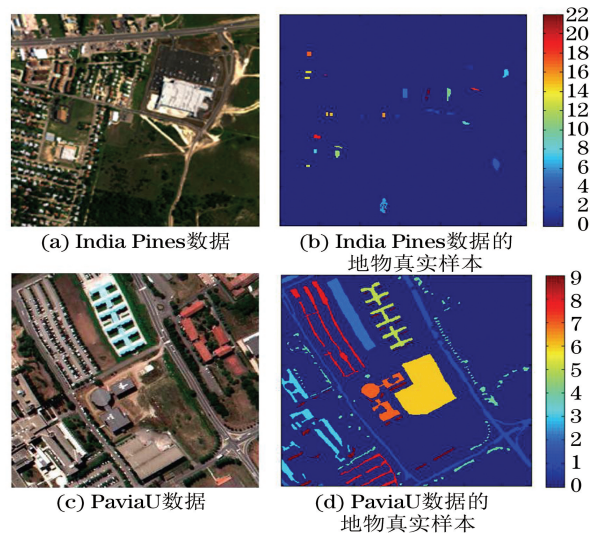


图 1 高光谱影像数据和地物真实样本分布

Fig.1 Two Hyperspectral Datasets and Their Ground Truth Information

×340 像素,波段数为 103,包含 9 类地物(包括阴影)。数据中各地物样本的真实空间分布和训练及测试样本的信息如图 1(d)和表 2 所示。表 2 中训练样本总数为 4 202,测试样本总数为 16 087。

表 1 Urban 数据的训练和测试样本信息

Tab.1 Training and Testing Samples of Urban Dataset

类别		样本	
类号	类名	训练	测试
1	AsphaltDrk	17	68
2	AsphaltLgt	12	45
3	Concrete01	25	99
4	VegPasture	47	189
5	VegGrass	25	102
6	VegTrees01	53	210
7	Soil01	23	90
8	Soil02	11	42
9	Soil03Drk	12	47
10	Roof01Wal	24	94
11	Roof02A	18	73
12	Roof02BGvl	8	31
13	Roof03LgtGray	7	28
14	Roof04DrkBrn	17	67
15	Roof05AChurch	18	67
16	Roof06School	13	51
17	Roof07Bright	15	59
18	Roof08BlueGrn	9	36
19	TennisCrt	19	77
20	ShadedVeg	8	32
21	ShadedPav	13	51
22	VegTrees01	52	210

表 2 PaviaU 数据的训练和测试样本信息

Tab.2 Training and Testing Samples of PaviaU Dataset

类别		样本	
类号	类名	训练	测试
1	Asphalt	839	3 356
2	Meadows	437	1 748
3	Gravel	420	1 679
4	Trees	310	1 240
5	Painted metal sheets	269	1 076
6	Bare Soil	1 006	4 023
7	Bitumen	266	1 064
8	Self-Blocking Bricks	469	1 878
9	Shadows	186	743

3.2 实验分析

本节利用提出的 SSR 波段选择模型来实现 Urban 和 PaviaU 数据的分类,验证提出的 SSR 模型的有效性。采用的对比波段选择方法有基于波段相关性的线性限制最小方差方法(linear constrained minimum variance-based band correlation constraint, LCMV-BCC)^[19],最大方差主成分分析法(maximum-variance principal component analysis, MVPCA)^[20],基于稀疏的波段选择法(sparse based band selection, SpaBS)^[7]

和稀疏矩阵分解的波段选择法(SNMF)^[8]。对比实验中采用支持向量机法(support vector machine, SVM)作为分类器,采用总体分类精度(overall classification accuracy, OCA)作为分类精度评价指标。其中 SVM 分类器中采用径向基核函数,其方差和惩罚因子通过交叉验证获得。从每个数据集的训练和测试样本中随机抽取 10 次进行实验,以下实验结果是 10 次独立实验的平均结果。

3.2.1 分类结果对比

实验对比分析不同波段数下的 SSR 方法和 LCMV-BCC、MVPCA、SpaBS 及 SNMF 方法的 SVM 分类结果。Urban 和 PaviaU 数据集中波段数的选择区间都为 2~50;SpaBS 方法的迭代次数都设置为 5 次。利用交叉验证方法,Urban 和 PaviaU 数据集中,SSR 方法的平衡参数 λ 分别设置为 80 和 95;Urban 数据集中,SNMF 方法中正则化因子 α 和 β 分别设定为 3.5 和 0.01;PaviaU 数据集中,SNMF 方法的正则化因子 α 和 β 分别设定为 4.0 和 0.001。

图 2 列出 SSR 和其他 4 种波段选择方法利用 Urban 和 PaviaU 数据集上得到的不同波段数目条件下的总体分类精度 OCA 结果。从图 2(a)可以看出,当波段数 k 取 2 时,5 种方法得到的分





图 2 Urban 和 PaviaU 数据中不同波段选择方法得到的总体分类精度

Fig.2 The Curves of OCA from all Five Band Selection Methods on Urban and PaviaU Dataset

类精度都较低;随着波段数 k 的增加,5 种方法对应的 OCA 曲线都逐步上升,在 $k=10$ 附近达到一个较高值;随着波段数 k 的持续增加,OCA 曲线都增长缓慢并呈现波动状态。同时,可以看出,在波段数 $k \geq 10$ (地物类别个数=9) 时,SpaBS 的总体分类精度 OCA 整体最低;MVPCA 曲线的 OCA 结果总体高于 SpaBS;SSR 的总体分类精度 OCA 结果和 LCMV-BCC 和 SNMF 方法较为接近,甚至一定程度上稍优于 LCMV-BCC 和 SNMF。同样地,从图 2(b)可以看出,随着波段数 k 的增加,SSR 和其他 4 种方法的 OCA 曲线逐步上升;在 $k > 22$ (地物类别个数=22) 时,5 种方法的 OCA 曲线增长都开始趋于缓慢,个别曲线的增幅伴随着一定波动来实现。同时,SSR 的总体分类精度 OCA 曲线与 SNMF 和 LCMV-BCC 方法的曲线较为接近,而且 OCA 结果稍微优于这两种方法;SpaBS 方法和 MVPCA 方法的 OCA 结果低于 SSR、SNMF 和 LCMV-BCC 方法,尤其 SpaBS 方法的 OCA 曲线整体结果最差。因此,SSR 波段选择方法的总体分类结果优于 SpaBS 和 MVPCA 方法,而且在波段数目大于地物类别个数时,能够得到相匹甚至稍优于 SNMF 和 LCMV-BCC 的总体分类精度。

3.2.2 计算效率分析

在对比 5 种波段选择方法的分类性能的基础上,表 3 列出 SSR 和其他 4 种波段选择方法对 Urban 和 PaviaU 数据集进行波段选择的计算时间。5 种波段选择算法都通过 MATLAB 2014a 编程实现,运算环境为联想 i5-4570 四核处理器,8 GB 内存和 Windows7 操作系统。Urban 数据和 PaviaU 数据的 5 种波段选取方法的参数设置同实验 1) 保持一致。

从表 3 可以看出,随着波段数 k 的增大,SSR

和其他 4 种波段选择方法的计算时间持续增长。4 种波段选择方法中,MVPCA 方法的计算效率最高,所消耗的计算时间最短;SNMF 方法的计算时间稍高于 MVPCA 方法,但计算效率明显高于 SSR、LCMV-BCC 和 SpaBS 方法。LCMV-BCC 和 SpaBS 的计算效率最低,明显低于 SSR 和其他两种方法;尤其是 SpaBS 方法的计算效率在 5 种方法中最低,所需要的计算时间最长。实验中,MVPCA 计算效率最高是因为该方法依赖的主成分分析算法具有较低的计算复杂度^[20];SpaBS 的高计算时间是因为其利用计算复杂度较高的奇异值分解算法来求解字典矩阵^[7]。因此,5 种波段选取的计算效率从高至低依次为 MVPCA、SNMF、SSR、LCMV-BCC 和 SpaBS。

3.2.3 平衡参数 λ 对 SSR 波段子集的分类影响

从式(8)中可看出,平衡参数 λ 和拉格朗日方程优化问题的目标解的关系显著,其取值大小能够改变稀疏系数矩阵 \hat{X} 的非零行的个数来影响 SSR 的波段选择结果。因此,对比分析不同 λ 对 Urban 数据和 PaviaU 数据的 SSR 波段子集的 SVM 分类结果的影响。我们认为,用于分类的波段数应至少大于地物实际类别的个数,因此 Urban 和 PaviaU 数据集中波段数分别选择为 23 和 10。Urban 数据集中,SSR 方法的 λ 的选择区间分别为 20~150,步长为 5;PaviaU 数据集中 SSR 方法的平衡参数 λ 的选择区间分别为 5~150,步长为 5。Urban 和 PaviaU 数据中其他未提及的 SSR 的参数设置与 § 3.2.1 及 § 3.2.2 保持一致。

图 3 列出 Urban 和 PaviaU 数据中不同取值对 SSR 的总体分类精度 OCA 的影响。从图 3(a) 的 Urban 数据中可以看出,当 λ 具有较小值时,SSR 得到的 OCA 分类精度较低;随着 λ 的持续增加,OCA 曲线逐步上升,在一个明显“拐点”处达到一个较高值;随着 λ 的持续增加,OCA 曲线增长

表 3 Urban 和 PaviaU 数据中 5 种波段选取方法的计算时间对比

Tab.3 Contrast in Computational Times Among all Five Band Selection Methods on Urban and PaviaUDatasets

数据集	波段数 k	不同方法的计算时间/min				
		SSR	LCMV-BCC	MVPCA	SpaBS	SNMF
Urban 数据	$k=10$	75.158	1 123.124	18.241	1 512.036	21.743
	$k=20$	123.928	1 574.263	23.256	1 727.641	30.471
	$k=30$	171.568	1 607.272	31.382	1 906.576	48.262
	$k=40$	202.489	1 772.241	45.582	2 035.429	52.803
	$k=50$	223.472	1 807.454	58.483	2 106.553	74.425
PaviaU 数据	$k=10$	104.689	1 515.092	27.526	1 728.659	32.592
	$k=20$	193.446	2 076.524	43.137	2 237.461	51.677
	$k=30$	233.156	2 917.889	59.205	3 141.394	70.224
	$k=40$	276.946	4 052.803	81.732	4 277.556	89.539
	$k=50$	300.457	5 044.261	102.422	5 429.083	121.773




图3 Urban和PaviaU数据中平衡参数 λ 对SSR波段子集的总体分类精度OCA的影响

Fig.3 Effect from the Balance Parameter λ on OCA Results of the SSR Band Subset for Urban and PaviaU Datasets

开始缓慢并呈现波动状态。而且,可以看出,Urban数据的OCA曲线的拐点在 $\lambda=45$ 左右,即拐点 λ 稍大于Urban数据中地物类别个数的2倍。同样地,由图3(b)的PaviaU数据可以看出,SSR的OCA结果随着 λ 的增加而持续增加,在 $\lambda=20$ (即稍大于地物类别个数的2倍)左右达到一个较高值;然后随着 λ 的继续增加,OCA曲线开始波动并缓慢上升。因此,较小的平衡参数 λ 对SSR的波段子集用于分类的精度结果影响显著,在平衡参数 λ 大于地物类别个数2倍取值时,能够实现SSR的波段选择结果,得到较高的总体分类精度。

4 结 语

本文提出SSR波段选择方法用于研究高光谱影像分类过程中的波段选择问题。SSR方法基于字典矩阵等于测量向量的多观测向量的稀疏表达理论,将波段选择转换为多观测向量模型中稀疏系数矩阵的求解问题,引入稀疏系数矩阵的 $L_{1,2}$ 混合范数来限定非零元素行的个数,利用凸优化方法求解稀疏系数矩阵的非零行向量来帮助实现波段的有效选择。利用Urban和PaviaU两

个高光谱影像数据并对比4种典型的波段选取方法(LCMV-BCC、MVPCA、SpaBS和SNMF)来证明SSR波段选取方法的有效性。实验结果表明,SSR方法的总体分类结果优于SpaBS和MVPCA方法,而且在波段数目大于地物类别个数时,能够类似于或稍优于SNMF和LCMV-BCC的总体分类精度。SSR方法的计算效率在5种波段选择方法中处于中等级位,计算速度明显优于MVPCA和SpaBS方法,却低于MVPCA和SNMF。同时,研究发现,SSR中平衡参数 λ 对波段子集用于分类的精度结果影响较为明显,在实际中应选择大于地物类别个数2倍的 λ 值来保证SSR得到较高的分类结果。

本文的研究结果需要下一步的工作来进一步完善。首先,本文没有考虑最佳波段个数的参数选择问题,只是对比不同方法在一定波段数量区间范围内的分类性能。其次,本文采用K-均值聚类方法来消除相邻波段的强相关性,会导致SSR模型选取相邻几个近似波段作为波段子集的元素。而波段相关性能够利用波段的相关系数矩阵或各波段构成的相似性矩阵来度量,并可以作为先验信息纳入到SSR模型中,进而实现波段的有效和自适应选取。

参 考 文 献

- [1] Hsu Paihui. Feature Extraction of Hyperspectral Images Using Wavelet and Matching Pursuit[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2007, 62(2): 78-92
- [2] Sun Weiwei, Halevy A, Benedetto J J, et al. UL-Isomap Based Nonlinear Dimensionality Reduction for Hyperspectral Imagery Classification[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 89: 25-36
- [3] Divekar A. Theory and Applications of Compressive Sensing[D]. Indiana, USA: Purdue University, 2010
- [4] Liu Shuai, Zhu Yajie, Xue Lei. Remote Sensing Image Super-resolution Method Using Sparse Representation and Classified Texture Patches[J]. *Geomatics and Information of Wuhan University*, 2015, 40(5): 578-582 (刘帅, 朱亚杰, 薛磊. 一种结合稀疏表示和纹理分块的遥感影像超分辨率方法[J]. 武汉大学学报·信息科学版, 2015, 40(5): 578-582)
- [5] Huang Yuancheng, Zhong Yanfei, Zhao Yehe, et al. Joint Blind Unmixing and Sparse Representation for Anomaly Detection in Hyperspectral Image[J].

- Geomatics and Information Science of Wuhan University*, 2015, 40(9): 1 144-1 150 (黄远程, 钟燕飞, 赵野鹤, 等. 联合盲分解与稀疏表达的高光谱图像异常目标检测[J]. 武汉大学学报·信息科学版, 2015, 40(9): 1 144-1 150)
- [6] Sun Weiwei, Liu Chun, Li Jialin, et al. Low-rank and Sparse Matrix Decomposition-based Anomaly Detection for Hyperspectral Imagery[J]. *Journal of Applied Remote Sensing*, 2014, 8(1): 083 641
- [7] Li Shuangjiang, Qi Hairong. Sparse Representation Based Band Selection for Hyperspectral Images[C]. 18th IEEE International Conference on Image Processing (ICIP), Brussels, Belgium, 2011
- [8] Li Jiming, Qian Yuntao. Clustering-based Hyperspectral Band Selection Using Sparse Nonnegative Matrix Factorization[J]. *Journal of Zhejiang University Science C*, 2011, 12(7): 542-549
- [9] Shi Beiqi, Liu Chun, Sun Weiwei, et al. Sparse Nonnegative Matrix Factorization for Hyperspectral Optimal Band Selection [J]. *Acta Geodaetica et Cartographica Sinica*, 2013, 42(3): 351-357 (施蓓琦, 刘春, 孙伟伟, 等. 应用稀疏非负矩阵分解聚类实现高光谱影像波段的优化选择[J]. 测绘学报, 2014, 42(3): 351-357)
- [10] Du Qian, Bioucas-Dias J M, Plaza A. Hyperspectral Band Selection Using a Collaborative Sparse Model[C]. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Munich, Germany, 2012
- [11] Chepushtanova S, Gittins C, Kirby M. Band Selection in Hyperspectral Imagery Using Sparse Support Vector Machines[C]. SPIE Defense+ Security Conference, Baltimore, Maryland, USA, 2014
- [12] Sun Weiwei, Zhang Liangpei, Li Weiyue, et al. Band Selection Using Improved Sparse Subspace Clustering for Hyperspectral Imagery Classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2 784-2 797
- [13] Chen Jie, Huo Xiaoming. Sparse Representations for Multiple Measurement Vectors (MMV) in an Over-Complete Dictionary[C]. IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP'05), Philadelphia, Pennsylvania, USA, 2005
- [14] Van Den B E, Friedlander M P. Theoretical and Empirical Results for Recovery from Multiple Measurements[J]. *IEEE Transactions on Information Theory*, 2010, 56(5): 2 516-2 527
- [15] Feng J M, Lee C H. Generalized Subspace Pursuit for Signal Recovery from Multiple -Measurement Vectors[C]. IEEE Wireless Communications and Networking Conference (WCNC), Shanghai, China, 2013
- [16] Elhamifar E, Sapiro G, Vidal R. See all by Looking at a few: Sparse Modeling for Finding Representative Objects[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Providence, Rhode Island, USA, 2012
- [17] Boyd S, Parikh N, Chu E, et al. Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers[J]. *Foundations and Trends® in Machine Learning*, 2011, 3(1): 1-122
- [18] Yang J, Zhang Y, Yin W. A Fast Alternating Direction Method for TVL1-L2 Signal Reconstruction from Partial Fourier Data[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2010, 4(2): 288-297
- [19] Chang C I, Wang S. Constrained Band Selection for Hyperspectral Imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(6): 1 575-1 585
- [20] Chang C I, Du Q, 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): 2 631-2 641

Band Selection Using Sparse Self-representation for Hyperspectral Imagery

SUN Weiwei^{1,2,3} JIANG Man² LI Weiyue⁴

1 Key Laboratory for Aerial Remote Sensing Technology of National Administration of Surveying, Mapping and Geoinformation (NASMG), Beijing 100830, China

2 Faculty of Architectural Engineering, Civil Engineering and Environment, Ningbo University, Ningbo 315211, China

3 State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079, China

4 Institute of Urban Studies, Shanghai Normal University, Shanghai 200234, China

Abstract: Hyperspectral imaging could collect spectrum information of ground objects on the earth surface using hundreds of bands and are widely used in recognizing subtle differences among difference ground objects. Unfortunately, numerous bands with strong intra-band correlations cause unbearable computational burdens in hyperspectral processing, and especially that seriously hinders the classification of Hyperspectral imagery (HSI) in many realistic applications. Therefore, a sparse self-representation (SSR) method was proposed to select proper bands and make dimensionality reduction on HSI data to benefit its further classification procedure. The SSR improves the sparse representation model of multiple measurement vectors (MMV) using the idea that the dictionary matrix is equal to the measurement matrix, and it regards the aimed band subset as the representative from all bands of the HSI dataset. The method formulates the band selection into finding nonzero row vectors of sparse coefficient matrix in MMV, and adopts the mixed norm to constrain the number of nonzero row vectors. The sparse coefficient matrix is solved by using fast alternating direction method of multipliers and nonzero row vectors are clustered to make proper selection from all bands. Two open HSI datasets including Urban and Pavia University are implemented to testify our SSR method and the results are compared with the other four alternative band selection methods. Experimental results show that the SSR achieves comparable even better overall classification accuracies than the linear constrained minimum variance-based band correlation constraint (LCMV-BCC) algorithm and the sparse nonnegative matrix factorization (SNMF) algorithm, whereas the computational speed of SSR significantly outperforms that of LCMV-BCC. The proposed SSR could accordingly be a good alternative to help choose proper bands from hyperspectral images.

Key words: band selection; sparse self-representation; multiple measurement vectors; hyperspectral imagery; classification; fast alternative direction method of multipliers

First author: SUN weiwei, PhD, associate professor, specializes in the theory and techniques of GIS and remote sensing, and “3S” applications in Coastal resources management and monitoring. E-mail: sunweiwei@nbu.edu.cn

Corresponding author: LI Weiyue, PhD. E-mail: lwy_326@126.com

Foundation support: The National Natural Science Foundation of China, Nos. 41671342, 41401389; the Key Laboratory for Aerial Remote Sensing Technology of National Administration of Surveying, Mapping and Geoinformation (NASMG), No. 2015B12; the Chinese Postdoctoral Science Foundation, Nos. 2016T90732, 2015M570668; Public Projects of Zhejiang Province, No. 2016C33021.