

文章编号: 1001-0920(2013)08-1219-07

基于块非负稀疏重构嵌入的高光谱数据降维

高 阳, 王雪松, 程玉虎, 汪 婵

(中国矿业大学 信息与电气工程学院, 江苏 徐州 221116)

摘 要: 为了在充分利用高光谱信息的同时减少因数据冗余带来的分类精度降低, 提出一种块非负稀疏重构嵌入降维算法. 首先, 将传统超完备字典转化成超完备块字典; 然后, 通过计算每个超完备块字典对应样本的最小重构误差, 得到块非负稀疏重构权重矩阵; 最后, 在低维嵌入时, 通过同时最小化局部和最大化非局部高光谱数据的非负稀疏信息, 得到全局最优的低维子空间高光谱数据. 通过 3 组高光谱数据的实验结果验证了所提出方法的可行性和有效性.

关键词: 高光谱数据; 降维; 块非负稀疏表示; 全局最优

中图分类号: TP75

文献标志码: A

Dimensionality reduction of hyperspectral data based on block non-negative sparsity reconstruction embedding

GAO Yang, WANG Xue-song, CHENG Yu-hu, WANG Chan

(School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou 221116, China.
Correspondent: WANG Xue-song, E-mail: wangxuesongcumt@163.com)

Abstract: In order to take full advantage of high spectral information and to reduce the decline of classification accuracy resulted from data redundancy, a dimensionality reduction algorithm called block non-negative sparsity reconstruction embedding is proposed. Firstly, an ordinary over-complete dictionary is converted into an over-complete block dictionary. Then, a block non-negative sparsity reconstruction weight matrix is obtained through computing the minimum reconstruction error of the sample corresponding to each over-complete block dictionary. Finally, in the phase of low-dimensional embedding, the global optimum hyperspectral data in a low-dimensional subspace can be obtained by minimizing the local and maximizing the non-local non-negative sparse information of the hyperspectral data simultaneously. Experimental results of three groups of hyperspectral data validate the feasibility and effectiveness of the proposed algorithm.

Key words: hyperspectral data; dimensionality reduction; block non-negative sparsity representation; global optimum

0 引 言

随着高光谱传感器的发展, 能够获得大量密集且连续的光谱波段并广泛地应用于观察地球表面. 高光谱数据分类过程的复杂性通常取决于所获得数据的波段数, 而密集连续的光谱波段间的相关性较高, 同时会使波段冗余度提高并产生 Hughes 现象^[1]. 因此, 为了保留尽可能多的有用信息, 同时减少高光谱数据分类的复杂性, 通常利用波段选择或波段特征提取方法将高维数据转化到低维子空间, 从而使高光谱数据得到更高效的分类.

目前已有许多降维方法, 主成分分析 (PCA)^[2] 和线性判别分析 (LDA)^[3] 是两种最流行的子空间学习方

法. PCA 尝试寻找一个最优投影方向, 即寻求数据的最大协方差. PCA 在将高维数据降低维子空间时没有考虑数据的类别信息, 是一种无监督方法. 而 LDA 是一种监督方法, 通过最大化类间散度和最小化类内散度来寻找最优判别子空间. 最近, 大量基于图的降维方法被成功地应用于机器学习和模式识别领域. 如局部线性嵌入 (LLE)^[4], 局部切空间排列^[5], 拉普拉斯特征映射^[6], 局部保持投影 (LPP)^[7], 无监督判别投影 (UDP)^[8], 稀疏保持投影 (SPP)^[9], 基于稀疏约束的图优化降维 (GODRSC)^[10] 和非负稀疏保持嵌入算法 (NSPE)^[11] 等. 尽管这些基于图的嵌入降维方法获得了成功的应用, 但是它们仍然存在一些不足: 1)

收稿日期: 2012-04-20; 修回日期: 2012-09-12.

基金项目: 国家自然科学基金项目(61072094, 61273143); 教育部新世纪优秀人才支持计划项目(NCET-10-0765); 教育部博士点基金项目(20110095110016, 20120095110025).

作者简介: 高阳(1985-), 男, 博士生, 从事支持向量机、高光谱图像的研究; 王雪松(1974-), 女, 教授, 博士生导师, 从事机器学习、模式识别等研究.

文献[4-7, 9-11]提到的算法是基于局部特征的降维算法, 局部特征只适合单流形结构的数据, 因此, 在数据结构为多流形的情况下, 这些方法不能产生好的便于分类的投影特征. 2) UDP方法同时考虑局部和非局部结构, 能够得到全局最优, 但UDP和LPP均需要构建近邻图, 而近邻参数的选择迄今为止仍是一个开放问题. 虽然交叉验证是常用的参数选择技术, 但是它们在高维空间中既耗时代价又极高, 并且消耗大量的训练样本. 3) SPP、GODRSC和NSPE采用(非负)稀疏表示方法^[12], 充分利用了高光谱数据的稀疏结构, 同时避免了近邻参数的选择. 然而, 它们重构数据时采用传统基于超完备字典的(非负)稀疏表示, 其计算复杂, 没有考虑源高光谱数据的结构, 重构精度低, 包含的判别信息少.

为解决上述问题, 本文提出一种块非负稀疏重构嵌入(BNSRE)降维算法, 并将其应用于高光谱数据降维问题. BNSRE的主要贡献是: 1) 采用块非负稀疏表示重构高光谱数据, 不仅能够提高重构精度, 而且可以提高计算效率; 2) 构建的块非负稀疏权重矩阵能够较好地反映数据的内在几何结构, 获得较多的判别信息; 3) 嵌入低维时, 同时考虑了高光谱数据的非负稀疏信息局部最小化和非局部最大化, 从而能够得到全局最优的低维高光谱数据. 这一特性比仅考虑(非负)稀疏信息局部最小化的算法更直观、更有效.

1 块非负稀疏重构嵌入

块非负稀疏重构嵌入主要包含2个部分: 块非负稀疏表示和低维嵌入. 块非负稀疏表示部分, 将传统超完备字典转化成超完备块字典, 通过计算每个超完备块字典对应样本的最小重构误差, 得到每个子块样本的块非负稀疏重构权重矩阵, 并计算整体非负稀疏重构权重矩阵. 低维嵌入部分, 通过最小化局部非负稀疏重构嵌入和最大化非局部非负稀疏重构嵌入, 获得最优的非负稀疏重构嵌入.

给定一个来自某未知分布的高维高光谱数据集 $O_m = [x_1, x_2, \dots, x_n]$. 其中: $x_i \in R^m$, $i = 1, 2, \dots$, n, m 为原始高光谱数据的高维维数, 类别个数为 c . 目标是找到一个低维子空间表示高维数据, 即

$$z = W^T x \in R^d. \quad (1)$$

其中: z 为高维高光谱数据 x 的低维表示, $d \ll m$, 投影矩阵 $W = (w_1, w_2, \dots, w_d) \in R^{m \times d}$.

1.1 非负稀疏表示

给定一高光谱数据点 x_i , 超完备字典 $X = [x_1, x_2, \dots, x_n] \in R^{m \times n}$, 且 $m < n$, x_i 是超完备字典 X 中的原子, 非负稀疏表示的目的是用尽可能少的超完备字典 X 中的列元素表示 x_i , 即

$$\begin{aligned} \min_{h_i} \|h_i\|_0; \\ \text{s.t. } x_i = Xh_i, h_i \geq 0. \end{aligned} \quad (2)$$

其中: $\|h_i\|_0$ 表示 h_i 的 l_0 范数, 其值为 h_i 中非零元素的个数, $h_i = [h_{i,1}, \dots, h_{i,i-1}, 0, h_{i,i+1}, \dots, h_{i,n}]^T \in R^n$, h_{ij} 表示第 j 个样本 x_j 对重构样本 x_i 所做出的贡献. 因为将 x_i 从 X 中去除, 所以 h_i 中第 i 个元素为 0, 即 $x_i = h_{i,1}x_1 + \dots + h_{i,i-1}x_{i-1} + h_{i,i+1}x_{i+1} + \dots + h_{i,n}x_n$.

1.2 块非负稀疏表示

传统非负稀疏表示方法计算复杂, 重构精度低. 为解决这些问题, 受文献[13]启发, 本文提出一种新的块非负稀疏表示方法. 主要是将超完备字典 X 分成 v 块, 即

$$X = \underbrace{[x_1^1, \dots, x_b^1, \dots, x_B^1]}_{X^1}, \dots, \underbrace{[x_1^v, \dots, x_b^v, \dots, x_B^v]}_{X^v}, \dots, \underbrace{[x_1^V, \dots, x_b^V, \dots, x_B^V]}_{X^V}. \quad (3)$$

其中: $n = VB$, $x_b^v = x_{(v-1)B+b}$, X^v 为一个超完备块字典. 则第 v 子块中高光谱数据点 x_b^v 可用超完备块字典 X^v 表示为

$$\begin{aligned} \min_{h_b^v} \|h_b^v\|_0; \\ \text{s.t. } x_b^v = X^v h_b^v, h_b^v \geq 0. \end{aligned} \quad (4)$$

其中 $h_b^v \in R^B$. 式(4)是一个NP难的非凸组合优化问题, 但在解足够稀疏的条件下, 可以采用求解局部最优的贪婪的迭代算法(如块正交匹配追踪算法^[14]), 即用求解 l_1 范数的方法来近似取代求解 l_0 范数的方法, 以降低计算复杂度, 则有

$$\begin{aligned} \min_{h_b^v} \|h_b^v\|_1; \\ \text{s.t. } x_b^v = X^v h_b^v, \mathbf{1} = \mathbf{1}^T \cdot h_b^v, h_b^v \geq 0. \end{aligned} \quad (5)$$

其中 $\mathbf{1} \in R^B$ 是全1向量. 利用非负最小二乘法求解式(5), 得重构误差^[15]为

$$\begin{aligned} \min_{h_b^v} E(H^v) = \min_{h_b^v} \|X^v - X^v H^v\|_2^2 + \gamma \|h_b^v\|_1; \\ \text{s.t. } h_b^v \geq 0, \mathbf{1} = \mathbf{1}^T h_b^v. \end{aligned} \quad (6)$$

其中 γ 是平衡稀疏和重构误差的非负系数.

根据式(6), 计算第 v 子块中每一个高光谱数据点 x_b^v 最优的非负稀疏重构权重向量 $\tilde{h}_b^v \in R^B$, 则第 v 子块的块非负稀疏重构权重矩阵 $H^v = [\tilde{h}_b^v]_{B \times B}$. 高光谱数据的整体非负稀疏重构权重矩阵 H 表示为

$$H = \text{diag}(H^1, \dots, H^v, \dots, H^V) = [\tilde{h}_i]_{n \times n}. \quad (7)$$

1.3 低维嵌入

局部的非负稀疏重构权重矩阵 H , 并不能保证嵌入到低维子空间后可以得到很好的分类精度. 为解决

这个问题, 引入非局部的非负稀疏重构权重矩阵 H' . 通过最大化非局部的非负稀疏重构权重矩阵, 使相似度低的高光谱数据在输出低维子空间远离, 通过最小化局部的非负稀疏重构权重矩阵, 使相似度高的高光谱数据在输出低维子空间接近, 从而达到全局最优, 并可提高降维后的分类精度.

根据局部的非负稀疏重构权重矩阵 H 定义局部非负稀疏重构嵌入, 即每个高光谱数据可以由局部域内的高光谱数据进行线性重构, 有

$$J_L = \sum_{i=1}^n \left\| z_i - \sum_{j=1}^n \tilde{h}_j z_j \right\|^2, \quad (8)$$

其中 $z_i = W^T x_i$, 则式(8)可转换为

$$J_L(W) = \sum_{i=1}^n \|W^T x_i - W^T X \tilde{h}_i\|^2 = W^T \left[\sum_{i=1}^n (x_i - X \tilde{h}_i)(x_i - X \tilde{h}_i)^T \right] W = W^T S_L W, \quad (9)$$

其中 S_L 是局部散度矩阵, 即

$$S_L = \sum_{i=1}^n (x_i - X \tilde{h}_i)(x_i - X \tilde{h}_i)^T = X(I - H - H^T + H^T H)X^T = X(I - H_\beta)X^T, \quad (10)$$

这里 $H_\beta = H + H^T - H^T H$.

令非局部的非负稀疏重构权重矩阵 $H' = I - H$, 并定义其非负稀疏重构嵌入, 即每个高光谱数据可以由非局部域内的高光谱数据进行线性重构, 类似于式(9)和(10), 有

$$J_N(W) = \sum_{i=1}^n \|W^T x_i - W^T X \tilde{h}'_i\|^2 = W^T S_N W, \quad (11)$$

其中 S_N 是非局部散度矩阵, 即

$$S_N = X(I - H'_\beta)X. \quad (12)$$

这里: $H'_\beta = H' + H'^T - H'^T H$, I 为单位矩阵.

为了提高降维后的分类精度, 试图在输出的低维子空间中使相似的高光谱数据接近, 而不相似的高光谱数据远离. 为此, 定义一个理想的保持嵌入, 即最小化局部非负稀疏重构嵌入 $J_L(W)$, 同时最大化非局部非负稀疏重构嵌入 $J_N(W)$, 有

$$\begin{aligned} \min_W \quad & \text{tr}(W^T S_L W), \\ \max_W \quad & \text{tr}(W^T S_N W). \end{aligned} \quad (13)$$

显然, 局部散度矩阵 S_L 和非局部散度矩阵 S_N 是对称和半正定的. 类似于 NSPE, 为了消除因式在投影时任意缩放, 应加强约束 $W^T X X^T W = I$. 为此, 式(13)中两个目标函数转化为

$$\begin{aligned} \arg \max_W \quad & \alpha \text{tr}(W^T S'_L W) + (1 - \alpha) \text{tr}(W^T S_N W), \\ \text{s.t.} \quad & W^T X X^T W = I. \end{aligned} \quad (14)$$

其中: $\alpha \in [0, 1]$ 是平衡两个目标函数的常数, $S'_L = X H_\beta X^T$. 这个转换的好处是, 在某些情况下最大化公式可以得到更多的数值稳定解^[16]. 设 $S = \alpha S'_L + (1 - \alpha) S_N$, $S_G = X X^T$ 是全局散度矩阵, 则目标函数转化为

$$\begin{aligned} \arg \max_W \quad & \text{tr}(W^T S W), \\ \text{s.t.} \quad & W^T S_G W = I. \end{aligned} \quad (15)$$

式(15)通过拉格朗日乘子方法求解, 可得

$$S W = \lambda S_G W. \quad (16)$$

设 $\lambda_1, \lambda_2, \dots, \lambda_d$ 为式(16)中前 d 个最大特征值, 其对应的特征向量为 w_1, w_2, \dots, w_d , 则 BNSRE 中降维的最优投影矩阵为 $W = (w_1, w_2, \dots, w_d)$. 从而, 高维高光谱数据 x 投影到低维子空间的高光谱数据为 $z = W^T x$.

1.4 算法步骤

输入: 高维高光谱数据 $O_m = [x_1, x_2, \dots, x_n]$, 低维子空间维数 d , 常数 α 和 γ .

输出: 低维高光谱数据 $O_d = [z_1, z_2, \dots, z_n]$.

Step 1: 根据式(3)划分超完备字典 X ;

Step 2: 求解式(6), 得到最优的块非负稀疏重构权重矩阵 H^v ;

Step 3: 根据式(7)求得整体非负稀疏重构权重矩阵 H , 令 $H' = I - H$, 并求解 H_β 和 H'_β ;

Step 4: 求解 $S'_L = X H_\beta X^T$, $S_N = X(I - H'_\beta)X$ 和 $S_G = X X^T$;

Step 5: 求解 $S = \alpha S'_L + (1 - \alpha) S_N$, 并通过拉格朗日乘子方法求解式(16), 得到最优投影矩阵 W ;

Step 6: 求高维高光谱数据 x 的低维表示 $z = W^T x$.

2 实验与分析

本节通过高光谱数据 (AVIRIS 92AV3C、ROSIS 和 AVIRIS KSC) 降维实验来评估 BNSRE 的性能, 对比算法有 NSPE、SPP、LPP、LDA 和 UDP. 为比较的公平性, 统一采用支持向量机进行监督分类, 选用高斯核函数且核函数宽度为 0.01, 惩罚因子 $C = 10$, LPP 和 UDP 的近邻数设为 5, BNSRE 中 $\alpha = 0.5$, BNSRE、NSPE 和 SPP 中 $\gamma = 1$. 仿真中, 每个实验均做 20 次, 取平均值.

2.1 高光谱实验数据

AVIRIS 92AV3C 高光谱数据来源于美国的普渡大学, 1992 年拍摄于印第安纳州西北部农业区, 观察

区域覆盖 145 行、145 列, 包括 220 个波段. 该图主要由森林、大豆和玉米等不同的农作物组成. 图 1(a) 为 AVIRIS 92AV3C 高光谱数据的假彩色合成图及真实标记图. 地物类别包含 16 类, 其中 7 类地物样本过少, 未用于实验. 剩下 9 类地物包含 9 167 个像素, 分别为 C1: Corn-min (751 像素), C2: Corn-notill (1 428 像素), C3: Grass/Pasture (483 像素), C4: Grass/Trees (736 像素), C5: Hay-windrowed (479 像素), C6: Soybeans-notill (977 像素), C7: Soybeans-min (2 455 像素), C8: Soybeans-clean (593 像素), C9: Woods (1 265 像素). 数据中有 2 种 Corn、2 种 Grass 和 3 种 Soybeans, 其中 C1、C2、C6 和 C7 地物分别含有不同量的上季度作物残留物, 部分还是裸地, 因此这几种地物光谱曲线相近, 类间光谱重叠较大, 谱间相似度较小, 使得该高光谱数据分类难度较大.

ROSIS 高光谱数据是 2003 年由意大利 Pavia 大学 Reflective optics system imaging spectrometer 传感器

获取的数据, 光谱范围 $0.43 \sim 0.86 \mu\text{m}$, 大小为 610×340 像素, 103 个波段, 1.3 m 空间分辨率. 图 1(b) 为 ROSIS 高光谱数据的假彩色合成图及真实标记图. 包含 9 类地物, 分别为 L1: 沥青路面 (6 592 像素), L2: 树 (3 064 像素), L3: 砖块 (3 682 像素), L4: 阴影 (942 像素), L5: 柏油房顶 (1 330 像素), L6: 裸地 (5 029 像素), L7: 金属板 (1 345 像素), L8: 沙砾 (2 099 像素), L9: 草地 (18 675 像素).

AVIRIS KSC 高光谱数据来源于肯尼迪空间中心 (KSC) 遥感研究组, 1996 年拍摄于佛罗里达州 KSC 附近. 观测区域覆盖 512 行、614 列, 包括 176 个波段, 地面分辨率为 18 m . 图 1(c) 为 AVIRIS KSC 高光谱数据的假彩色合成图及真实标记图. 地物类别包含 13 类, 分别为 S1: Scrub (761 像素), S2: Willow (243 像素), S3: CP Hammock (256 像素), S4: CP Oak (252 像素), S5: Shsh Pine (161 像素), S6: Oak Broadleaf (229 像素), S7: Hardwood Swanp (105 像素), S8: Graminoid Marsh (431 像素), S9: Spartina Marsh (520 像素), S10: Cattail Marsh (404 像素), S11: Salt Marsh (419 像素), S12: Mud Flats (503 像素), S13: Water (927 像素).

2.2 BNSRE 中字典块个数及稀疏权重矩阵分析

首先, 在 AVIRIS 92AV3C 高光谱数据中, 随机从各类地物中选取 30% 高光谱数据作为训练样本进行特征提取, 并根据得到的 d 个特征向量将剩下的 70% 高光谱数据投影到低维子空间. BNSRE 算法中固定低维子空间维数 $d = 20$ 不变, 分析超完备字典的个数对分类整体精度、Kappa 系数、降维时间和总时间的影响, 表 1 给出了相应的实验结果. 由表 1 可以看出, 当超完备字典个数为 9 时, 即超完备字典个数与类别数相同时, 分类整体精度和 Kappa 系数最高, 降维时间和总时间比最快时间慢了不到 1 s, 是可以接受的. 因此, 在接下来的实验中, 对于各高光谱数据, BNSRE 中的超完备字典个数 V 等于类别数的个数 c .

表 1 分类整体精度、Kappa 系数、降维时间和总时间与字典块个数的关系

字典块个数	1	2	3	4	5	6
分类整体精度/%	70.73	83.33	85.43	86.86	87.86	87.74
Kappa 系数	0.643 3	0.800 6	0.826 3	0.843 9	0.856 1	0.854 4
降维时间/s	69.02	29.71	20.92	17.24	15.11	14.44
总时间/s	71.96	32.04	23.11	19.33	17.71	16.47
字典块个数	7	8	9	10	11	12
分类整体精度/%	88.04	88.11	88.16	88.14	88.11	87.96
Kappa 系数	0.858 1	0.859 0	0.859 6	0.859 3	0.858 9	0.857 3
降维时间/s	13.77	13.39	12.48	12.24	11.98	11.76
总时间/s	16.12	15.39	14.52	14.23	13.98	13.80

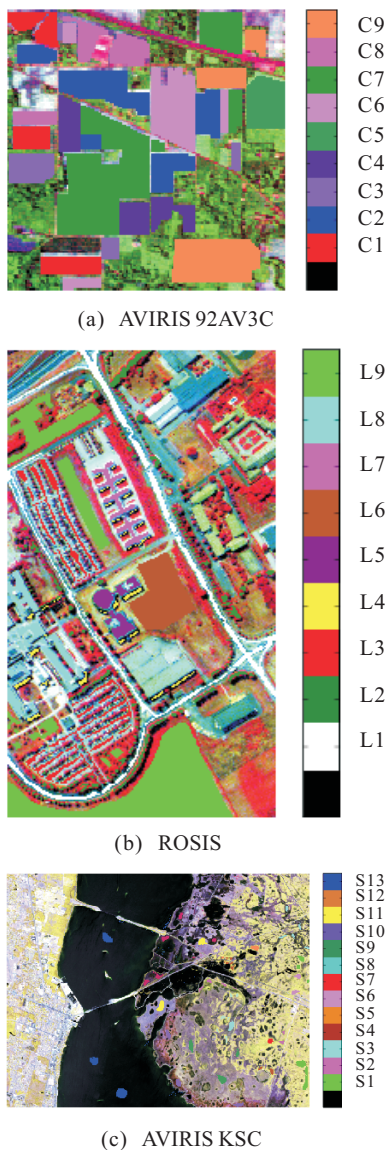


图 1 高光谱数据的假彩色合成图及真实标记图

然后, 从 AVIRIS 92AV3C 高光谱数据的各类地物中随机选取 5 个样本, 分析稀疏权重矩阵是否能

在一定程度上反映高光谱数据的内在几何结构以及是否含有判别信息. 图 2 给出了稀疏权重矩阵的非 0 分布系数情况. 图 2(a) 中的点表示非 0 的数据, 位于 (i', j') 的点表示第 j' 个样本 $x_{j'}$ 是样本 x_i 的 k 最近邻之一, LPP 和 UDP 具有相同的近邻结构. 图 2(b)~图 2(e) 中的点表示绝对值大于一个非常接近 0 值的数据, 位于 (i', j') 的点表示第 j' 个样本 $x_{j'}$ 是样本 x_i 的稀疏重构样本. 在图 2(f) 中, 位于 (i', j') 的点表示样本 $x_{j'}$ 和 x_i 具有相同标签. 由于 LDA 是监督降维, 只有同类点的权重才大于 0, 其稀疏权重矩阵是严格块对角矩阵.

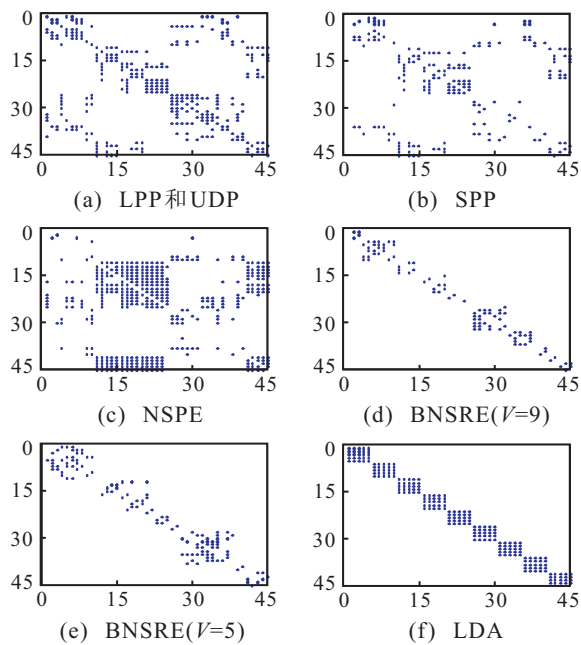


图 2 稀疏权重矩阵的非 0 系数分布

图 2 中 5 种无监督算法的稀疏权重矩阵在一定程度上反映了数据的内在几何结构和包含了一定的判别信息. 图 2(d)~图 2(e) 的稀疏权重矩阵比图 2(a)~图 2(c) 更接近于图 2(f), 说明块非负稀疏重构权重含有更多潜在的判别信息, 能够很好地划分出不同类别样本. 由图 2(d) 和图 2(e) 可以看出, 对于 BNSRE 而言, $V = 9$ 情况下的稀疏权重矩阵比 $V = 5$ 情况下的稀疏权重矩阵更加接近于图 2(f), 这进一步说明了当超完备块字典个数 V 等于类别个数 c 时, 能获得最佳的具有判别信息的稀疏权重矩阵. 总之, BNSRE 获得的判别信息高于 LPP、UDP、SPP 和 NSPE.

2.3 降维性能分析

首先, 从各类地物中随机选取 30% 高光谱数据作为训练样本进行特征提取, 并根据得到的 d 个特征向量将剩下的 70% 高光谱数据投影到低维子空间. 分别采用 BNSRE、NSPE、SPP、LPP、LDA 和 UDP 将 AVIRIS 92AV3C、RODIS 和 AVIRIS KSC 高光谱数据

中的各类地物进行降维, 再利用 SVM 进行分类. 图 3 和图 4 给出了各高光谱实验数据上的分类整体精度和 Kappa 系数与低维子空间维数间的关系图.

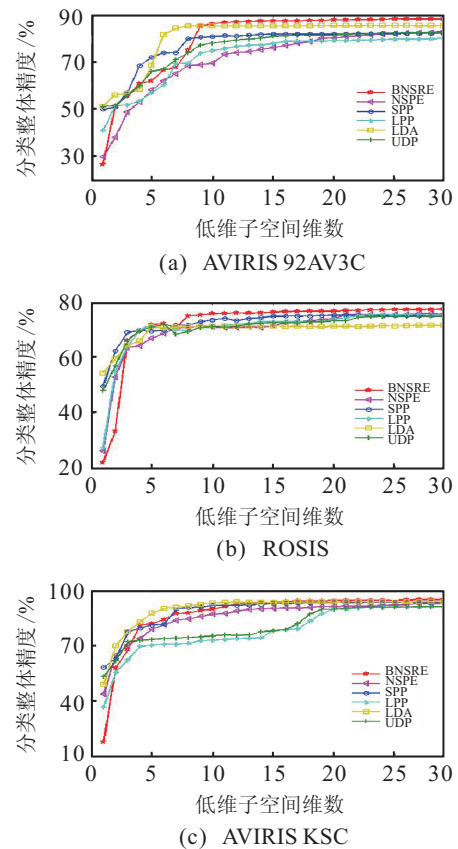


图 3 分类整体精度与低维子空间维数关系

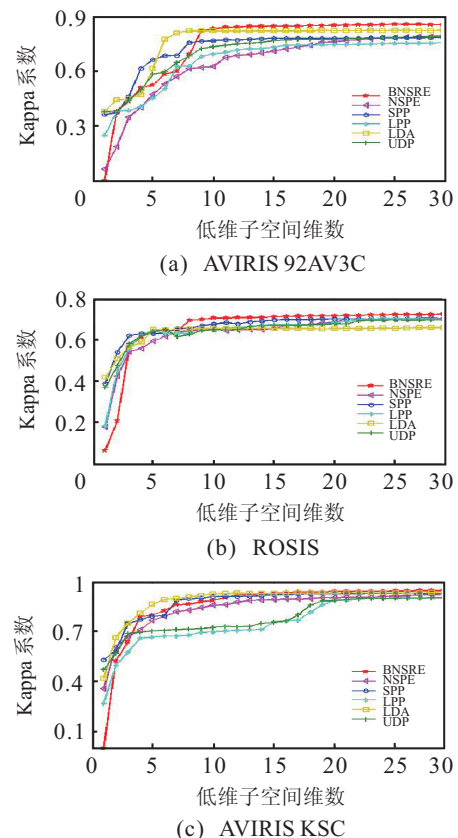


图 4 Kappa 系数与低维子空间维数关系

然后,考查各降维算法在不同训练样本量情况下的降维性能.分别从各类地物中随机选取 10%、20% 和 40% 高光谱数据作为训练样本进行特征提取,并利用得到的 d 个特征向量将剩下的 90%、80% 和 60% 高光谱数据投影到低维子空间.评价各种降维算法将高光谱数据统一降维到 30 维时的各项降维性能指标,如表 2 所示.

表 2 不同训练样本量情况下的降维性能比较

训练样本量及降维性能	BNSRE	NSPE	SPP	LPP	LDA	UDP
10%						
分类整体精度/%	72.68	60.84	57.51	61.21	68.25	64.39
Kappa 系数	0.6659	0.5117	0.4657	0.5139	0.6063	0.5581
降维时间/s	3.10	4.51	5.72	0.42	0.31	0.44
总时间/s	4.18	5.66	6.90	1.49	1.40	1.50
20%						
分类整体精度/%	86.03	81.71	70.16	74.14	83.60	74.94
Kappa 系数	0.8339	0.7827	0.6350	0.6864	0.8000	0.6963
降维时间/s	6.42	14.31	23.92	0.83	0.32	0.95
总时间/s	8.16	16.02	26.16	2.90	2.32	3.02
40%						
分类整体精度/%	89.63	83.39	87.85	86.01	86.64	86.46
Kappa 系数	0.8774	0.8033	0.8562	0.8338	0.8412	0.8391
降维时间/s	20.03	55.06	101.23	2.33	0.47	2.68
总时间/s	23.13	58.42	104.31	5.92	4.08	6.23

2.4 讨 论

比较 AVIRIS 92AV3C、RODIS 和 AVIRIS KSC 高光谱数据上的实验结果,从图 3 和图 4 可以得到如下结论:

1) 在 AVIRIS 92AV3C、RODIS 和 AVIRIS KSC 高光谱数据中, BNSRE 的最高分类整体精度和 Kappa 系数比 NSPE、SPP、LPP、LDA 和 UDP 都高.这主要是由于 BNSRE 在采用块非负稀疏重构高光谱数据时,能够较好地反映数据的内在几何结构和包含更多的潜在判别信息,从而使降维后的高光谱数据包含更多有价值的特征波段.

2) 在 AVIRIS 92AV3C、RODIS 和 AVIRIS KSC 高光谱数据中,基于局部近邻算法中,同时考虑近邻信息局部最小和非局部最大的 UDP 分类整体精度和 Kappa 系数,高于只考虑近邻信息局部最小的 LPP 分类整体精度和 Kappa 系数.基于稀疏表示算法中,考虑非负稀疏信息非局部最大的 BNSRE 分类整体精度和 Kappa 系数优于 NSPE 和 SPP 的分类整体精度和 Kappa 系数.这是因为同时考虑非负稀疏信息局部最小化和非局部最大化,能够找到高光谱数据降维的全局最优解,从而使分类器具有更好的分类整体精度和 Kappa 系数.

3) 监督的 LDA 在 AVIRIS 92AV3C 和 AVIRIS KSC 高光谱数据中,其获得的分类整体精度和 Kappa 系数高于无监督的 NSPE、SPP、LPP 和 UDP,但是在

RODIS 高光谱数据中的分类整体精度和 Kappa 系数要低于它们.这说明在有标签的高光谱数据中,存在影响分类整体精度和 Kappa 系数的冗余样本.而采用块非负稀疏表示的 BNSRE 高于其他方法,这是因为 BNSRE 在获得较好判别信息的同时,保持了非负稀疏结构,可以有效地降低冗余样本的影响,获得较高的分类整体精度和 Kappa 系数.

4) 在 AVIRIS KSC 高光谱数据中,几种算法的最高分类整体精度和 Kappa 系数差别不大,这主要是因为选取高光谱数据时,选取的样本较少,各类之间的差异较大,光谱波段之间相似性小,所以在进行特征提取时,得到的特征很相近.

在 AVIRIS 92AV3C 高光谱数据上比较不同训练样本量的降维性能实验中(见表 2),可得以下结论:

1) 不同训练样本量情况下, BNSRE 都能获得比其他算法高的分类整体精度和 Kappa 系数. SPP 在训练样本量较小时得到的分类整体精度和 Kappa 系数低于其他算法,稀疏表示的 SPP 算法只有在训练样本量较大时才能较好地反映分类判别信息. NSPE 在训练样本量较小时得到的分类整体精度和 Kappa 系数高于 SPP,但当训练样本量较大时却低于 SPP,这是因为 NSPE 在降到 30 维时的分类整体精度和 Kappa 系数还没有达到稳定(由图 3 和图 4 同样可以得出此结论). BNSRE 采用块非负稀疏表示,并同时考虑局部最小化和非局部最大化以达到全局最优,使得其受训练样本量的影响较小,且能够获得更多的分类判别信息.

2) 在稀疏类降维中,随着训练样本量的增加, BNSRE 的降维时间和总时间比 NSPE 和 SPP 的降维时间和总时间减少的越来越多.这说明 BNSRE 采用块非负稀疏表示的计算机耗时比 NSPE 的非负稀疏表示和 SPP 的稀疏表示的计算机耗时要少,且训练样本量越大,减少的时间越多.这说明 BNSRE 的块非负稀疏表示的时间复杂度较低.

3) 与传统的 LPP、LDA 和 UDP 相比,因 BNSRE 需要对训练样本进行块非负稀疏表示,故需要花费较多的时间进行高光谱数据降维.即 BNSRE 能够在牺牲计算机耗时的情况下,使得分类整体精度和 Kappa 系数都有较大程度的提高,而且,表 2 中 BNSRE 的降维时间和总时间是可以接受的.

3 结 论

光谱遥感技术已成为人们获取地球表面信息的一种非常重要的手段.然而,由于高光谱数据具有信息量大、信息相关性强、信息冗余度高和 Hughes 现象等特性,使得目前遥感信息的提取和利用水平大大滞后于遥感技术的发展.为提高高光谱数据的分类

性能, 本文提出了一种块非负稀疏重构嵌入降维算法 BNSRE. 算法的主要思想是: 采用块非负稀疏表示重构高光谱数据, 一方面能够较好地反映数据的内在几何结构和包含更多的潜在判别信息, 使降维后的高光谱数据包含更多有价值的特征波段; 另一方面通过将传统超完备字典转化成超完备块字典, 以减少超完备字典中的原子数量, 进而提高计算效率. 同时最小化局部和最大化非局部高光谱数据的非负稀疏信息, 能够使得相似度高的数据在输出低维子空间接近、相似度低的数据在输出低维子空间远离, 从而得到全局最优的低维高光谱数据. 但是, 该算法仍有进一步改进的空间, 例如尽管 BNSRE 的耗时低于 NSPE 和 SPP, 但高于 LPP、UDP 和 LDA 等传统降维算法, 因此, 如何进一步提高 BNSRE 的计算效率有待于进一步探讨.

参考文献(References)

- [1] Fauvel M, Chanussot J, Benediktsson J A. Kernel principal component analysis for the classification of hyperspectral remote-sensing data over urban areas[J]. *Eurasip J on Advances in Signal Processing*, 2009(1): 1-14.
- [2] 陈才扣, 杨静宇, 杨健. 一种融合 PCA 和 KFDA 的人脸识别方法[J]. *控制与决策*, 2004, 19(10): 1147-1154.
(Chen C K, Yang J Y, Yang J. Fusion of PCA and KFDA for face recognition[J]. *Control and Decision*, 2004, 19(10): 1147-1154.)
- [3] Du Q, Nekovei R. Implementation of real-time constrained linear discriminant analysis to remote sensing image classification[J]. *Pattern Recognition*, 2005, 38(4): 459-471.
- [4] 黄远灿. 改进 Lagrange 乘子法及收敛性分析[J]. *控制与决策*, 2008, 23(4): 409-414.
(Huang Y C. Modified Lagrange multiplier method and its convergence analysis[J]. *Control and Decision*, 2008, 23(4): 409-414.)
- [5] 闫德勤, 刘胜蓝, 李燕燕. 一种基于稀疏嵌入分析的降维方法[J]. *自动化学报*, 2011, 37(11): 1306-1312.
(Yan D Q, Liu S L, Li Y Y. An embedding dimension reduction algorithm based on sparse analysis[J]. *Acta Automatica Sinica*, 2011, 37(11): 1306-1312.)
- [6] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. *Neural Computation*, 2003, 15(6): 1373-1397.
- [7] Chen Y W, Han X H. Classification of high-resolution satellite images using supervised locality preserving projections[J]. *Lecture Notes in Computer Science*, 2008, 5178(1): 149-156.
- [8] Yang J, Zhang D, Yang J Y, et al. Globally maximizing, locally minimizing: Unsupervised discriminant projection with applications to face and palm biometrics[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2007, 29(4): 650-664.
- [9] Qiao L S, Chen S C, Tan X Y. Sparsity preserving projections with applications to face recognition[J]. *Pattern Recognition*, 2009, 43(1): 331-341.
- [10] Zhang L M, Chen S C, Qiao L H. Graph optimization for dimensionality reduction with sparsity constraints[J]. *Pattern Recognition*, 2012, 45(3): 1205-1210.
- [11] Wong W K. Discover latent discriminant information for dimensionality reduction: Non-negative sparseness preserving embedding[J]. *Pattern Recognition*, 2012, 45(4): 1511-1523.
- [12] 李映, 张艳宁, 许星. 基于信号稀疏表示的形态成分分析进展和展望[J]. *电子学报*, 2009, 37(1): 146-152.
(Li Y, Zhang Y N, Xu X. Advances and perspective on morphological component analysis based on sparse representation[J]. *Acta Electronica Sinica*, 2009, 37(1): 146-152.)
- [13] Baraniuk R G, Volkan C, Marco F D, et al. Model-based compressive sensing[J]. *IEEE Trans on Information Theory*, 2010, 56(4): 1982-2001.
- [14] Yonina C E, Patrick K, Helmut B. Block-sparse signals: Uncertainty relations and efficient recovery[J]. *IEEE Trans on Signal Processing*, 2010, 58(6): 3042-3054.
- [15] He R, Hu B G, Zheng W S, et al. Two-stage sparse representation for robust recognition on large-scale database[C]. *Proc of the 24th AAAI Conf on Artificial Intelligence*. Atlanta, 2010: 475-480.
- [16] Cai D, He X F, Han J W. Spectral regression for dimensionality reduction[R]. Urbana: Computer Science Department, University of Illinois at Urbana-Champaign, 2007.