

面向高光谱影像分类的改进局部切空间排列降维

孙伟伟^{1,2}, 刘 春^{1,3}, 施蓓琦¹, 李巍岳¹

(1. 同济大学 测绘与地理信息学院, 上海 200092; 2. 宁波大学 建筑工程与环境学院,
浙江 宁波 315211; 3. 现代工程测量国家测绘地理信息局重点实验室, 上海 200092)

摘要: 提出多策略提升的局部切空间排列算法来解决常规局部切空间排列降维在高光谱影像分类中计算复杂度高的问题. 通过引入随机映射来预先减少高光谱影像波段数, 降低后续 k -邻域和局部切空间构建的计算复杂度; 采用递归兰索斯切分算法快速构建近似 k -邻域, 降低常规 k -邻域构建的计算时间; 采用快速近似奇异值分解算法提高全局排列矩阵的本征分解计算速度. 利用两个不同的高光谱数据集, 设计 4 组实验来分析多策略速度提升的局部切空间排列算法的计算性能和分类效果. 实验证明, 相比常规局部切空间排列方法, 多策略提升的局部切空间排列方法损失约 1% 左右的总体分类精度却能够提高至少 3 倍的计算速度.

关键词: 多策略提升局部切空间排列; 局部切空间排列; 随机映射; 降维; 高光谱影像分类

中图分类号: TP75

文献标志码: A

Dimensionality Reduction with Improved Local Tangent Space Alignment for Hyperspectral Imagery Classification

SUN Weiwei^{1,2}, LIU Chun^{1,3}, SHI Beiqi¹, LI Weiye¹

(1. College of Surveying and Geo-informatics, Tongji University, Shanghai 200092, China; 2. College of Architectural Engineering, Civil Engineering and Environment, Ningbo 315211, China; 3. Key Laboratory of Advanced Engineering Survey of National Administration of Surveying, Mapping and Geoinformation, Shanghai 200092, China)

Abstract: The paper proposes a new version of local tangent space alignment (LTSA), named multi-strategies upgraded local tangent space alignment (MSU-LTSA), to solve the problem of computational complexity in dimensionality reduction of hyperspectral imagery (HSI) for classification. First, random projection is introduced into the new method to reduce the number of HSI bands. That decreases the computational complexity of k -nearest neighbors (KNNs) construction and local tangent space construction of each

pixel. Then, the recursive lanczos bisection algorithm is utilized to construct the fast approximate KNNs graph and it reduces the computational time of regular approach. Finally, when finishing constructing the global alignment matrix, the new method uses the fast approximate singular value decomposition to promote the computational speed of the regular eigenvalue decomposition of global alignment matrix. With two different HSI datasets, four groups of experiments are designed to completely analyze and testify the performance of computation and classification for MSU-LTSA. The results show that MSU-LTSA speeds up LTSA at least 3 times whereas only degrading about 1% in its overall classification accuracy (OCA).

Key words: multi-strategies upgraded local tangent space alignment; local tangent space alignment; random projection; dimensionality reduction; hyperspectral image classification

高光谱影像利用数十至数百个波段采集地面地物的光谱特征, 并通过分类来识别各地物间的细微差异. 其分类结果影响后期的实际应用, 如环境监测^[1]、植被覆盖制图^[2]、地质探测^[3]及精细农业^[4]等. 然而, 由于波段众多且相关性强, 高光谱影像存在“维数灾难”现象^[5]. 而且由于样本获取难度大, 分类存在“Hughes”现象. 因此, 通常对高光谱影像降维然后再进行分类.

近年来, 非线性流形学习被引入高光谱领域来降维并挖掘其潜在流形特征. 流形学习假设高光谱影像采集于一个低维流形上, 通过将原始数据映射到低维空间实现降维并发掘其潜在流形结构. 目前存在许多流形学习方法, 如等距映射^[6]、局部切空间排列(local tangent space alignment, LTSA)^[7]、局部线性嵌入^[8]、拉普拉斯特征映射^[9]及自组织映射^[10]等. 其中, LTSA 是流形学习局部方法的代表.

收稿日期: 2012-12-02

基金项目: 国家“九七三”重点基础研究发展规划(2012CB957702); 教育部留学回国人员科研启动基金

第一作者: 孙伟伟(1985—), 男, 工学博士, 主要研究方向为 T-GIS 理论及工程应用、高光谱影像非线性降维、压缩感知和遥感影像处理理论与方法等. E-mail: sw8525@gmail.com

LTSA 利用样本邻域点表示局部切空间的几何结构,并通过全局排列局部的切空间来构造全局流形坐标.目前,学者已经对高光谱影像 LTSA 降维做出一些研究. Fong 通过实验分析 LTSA 降维及后续分类结果^[11]. Ma 等引入 LTSA 方法来研究高光谱影像的异常探测问题^[12]. 在此基础上,她提出广义监督局部切空间排列方法^[13]. 随后,她又提出监督局部流形学习-k-最近邻分类器方法,并证明该方法比非监督 LTSA-k 近邻法的分类效果好^[14]. 后来, Yang 等基于 LTSA 方法提出统一流形排列框架^[15]. Crawford 等研究了 LTSA 用于分类的性能并对比等距映射、局部线性嵌入及其他降维方法^[16]. Luo 等通过实验分析 LTSA 及其他流形学习方法用于高光谱影像降维时的优势和不足^[17]. Khodr 等从低维空间中异常向量的保持角度出发,利用实验分析对比了 LTSA 等诸多流形学习降维方法的性能差异^[18]. 以上研究对 LTSA 在高光谱影像的分类应用起到很大推动作用. 然而,高光谱影像的 LTSA 降维仍存在计算效率低下问题. 高光谱影像 LTSA 降维的计算时间随像素个数 N 的增加而指数增长呈 $O(N^3)$. 而且, LTSA 的计算效率与邻域大小及低维嵌入的维数也密切相关. 这极大影响了高光谱影像 LTSA 降维在实际分类中的应用. 因此研究高光谱影像 LTSA 降维的提升策略对于其后续分类应用至关重要.

本文集成三种数学计算方法,提出多策略提升局部切空间排列方法 (multi-strategies upgraded local tangent space alignment, MSU-LTSA) 来解决 LTSA 降维用于高光谱影像分类的计算问题.

1 高光谱影像的 LTSA 降维

LTSA 试图构建位于每个像素点的局部几何结构,并通过排列彼此重叠的局部切空间来得到全局流形坐标^[7]. 假设高光谱影像为向量集 $\mathbf{X}=[x_1, \dots, x_N]^T \in \mathbf{R}^D$, 其中 N 和 D 分别为像素点个数和波段数; 假设低维流形坐标向量集 $\mathbf{Y}=[y_1, \dots, y_N]^T \in \mathbf{R}^d$, 其中 d 为低维流形坐标的维数; 假设每个像素点在光谱空间的邻域为 $C_i=[x_{i_1}, \dots, x_{i_k}]$, 其中 k 为邻域大小. 首先, LTSA 通过任意像素点 x_i 和 x_j 间的欧氏距离来构建邻域 C_i . 其次, LTSA 计算一个 d 维的仿射子空间来逼近 C_i 中的点, 即

$$\min_{\mathbf{x}, \mathbf{\Theta}, \mathbf{Q}} \sum_{j=1}^k \|x_{ij} - (\mathbf{\Theta}_i + \mathbf{Q}_i \mathbf{\Theta}_j)\|^2 =$$

$$\min_{\mathbf{x}, \mathbf{\Theta}, \mathbf{Q}} \|\mathbf{X}_i - (\mathbf{\Theta}_i \mathbf{e}_k^T + \mathbf{Q}_i \mathbf{\Theta}_i)\|^2 \quad (1)$$

式中: $\mathbf{\Theta}_i=[\theta_{i_1}, \dots, \theta_{i_k}]$ 为 C_i 中的局部流形坐标; $\mathbf{\Theta}_i$ 为邻域中心点的局部流形坐标; \mathbf{Q}_i 为局部仿射变换矩阵且 \mathbf{Q}_i 的列数为 d . 经式(1)最小化后得到邻域 C_i 中每个像素的局部流形坐标为 $\mathbf{\Theta}_i = \mathbf{Q}_i^T (C_i - \bar{x}_i \mathbf{e}_k^T)$, 其中 \mathbf{Q}_i 为中心化邻域矩阵 $C_i - \bar{x}_i \mathbf{e}_k^T = [x_{i_1} - \bar{x}_i, \dots, x_{i_k} - \bar{x}_i]$ 的最大 d 个右奇异值向量 $\sigma_{i_1}, \dots, \sigma_{i_d}$ 所对应的矩阵, $\bar{x}_i = C_i \mathbf{e}^T$ 为邻域矩阵 C_i 的中心像素点, \mathbf{e}_k 为长度为 k 的单位列向量. 将所有重叠的局部坐标系 $\mathbf{\Theta}_i=[\theta_{i_1}, \dots, \theta_{i_k}]$ 排列起来得到全局坐标系 $\mathbf{Y}=[y_1, \dots, y_N]^T$. LTSA 认为全局坐标 y_i 能反映局部坐标 θ_i 所决定的局部几何结构, 即满足

$$\mathbf{Y}_i = \mathbf{Y}_i \mathbf{e}^T / k + \mathbf{L}_i \mathbf{\Theta}_i + \mathbf{E}_i \quad (2)$$

式中: $\mathbf{Y}_i=[y_{i_1}, \dots, y_{i_k}]$ 为邻域 C_i 中每个像素点的全局坐标; $\mathbf{E}_i=[\epsilon_{i_1}, \dots, \epsilon_{i_k}]$ 为对应的每个像素点的局部重构误差; \mathbf{L}_i 为待定的局部仿射变换矩阵. 最后, 通过最小化局部重构误差来计算全局流形坐标. 式(2)中的 \mathbf{L}_i 可通过最小化特定 \mathbf{Y}_i 的局部重构误差 $\|\mathbf{E}_i\|$ 得到式(3)求得:

$$\mathbf{L}_i = \mathbf{Y}_i (\mathbf{I} - \mathbf{e} \mathbf{e}^T / k) \mathbf{\Theta}_i^+ \quad (3)$$

式中, \mathbf{I} 为单位矩阵. 为了得到唯一解, 给 \mathbf{Y} 加上中心化和标准化约束. 因此, 最小化局部重构误差可转换为

$$E(\mathbf{Y}) = \sum_{i=1}^N \|\mathbf{Y}_i (\mathbf{I} - \mathbf{e} \mathbf{e}^T / k) (\mathbf{I} - \mathbf{L}_i \mathbf{\Theta}_i^+ \mathbf{\Theta}_i)\|^2 = \text{trace}(\mathbf{Y} \mathbf{\Phi} \mathbf{Y}^T) \quad (4)$$

式中: $\mathbf{\Phi} = \sum_{i=1}^N \mathbf{S}_i \mathbf{W}_i \mathbf{W}_i^T \mathbf{S}_i^T$ 为局部坐标排列矩阵; $\mathbf{S}_i \in \mathbf{R}^{N \times k}$ 为选择矩阵. $\mathbf{W}_i = \mathbf{I} - [1_k / \sqrt{k}, \mathbf{V}_i] [1_k / \sqrt{k}, \mathbf{V}_i]^T$, 其中 \mathbf{V}_i 为中心化邻域矩阵 $C_i - \bar{x}_i \mathbf{e}^T$ 的最大 d 个左奇异值向量 $(\sigma_{i_1}, \dots, \sigma_{i_d})$ 所对应的矩阵. 全局流形坐标 \mathbf{Y} 为全局排列矩阵 $\mathbf{\Phi}$ 的第 2 到第 $d+1$ 的特征值所对应的特征向量.

2 基于 MSU-LTSA 的高光谱影像降维

假设高光谱影像为向量集 $\mathbf{X}=[x_1, \dots, x_N]^T \in \mathbf{R}^D$, MSU-LTSA 降维的目的是获取低维流形坐标向量集 $\mathbf{Y}=[y_1, \dots, y_N]^T \in \mathbf{R}^d$, 其中 N 和 D 分别为像素点个数和波段数, d 为低维流形坐标的维数. MSU-LTSA 方法通过三种策略来综合提高 LTSA 降维的运算效率.

2.1 随机映射减少高光谱波段数

本文引入随机映射^[19]来预先减少高光谱影像的

波段数,降低 LTSA 的计算复杂度. 随机映射理论认为,如果利用随机矩阵 Ψ 将含有潜在流形的高维数据集 $\mathbf{X}^T \in \mathbf{R}^D$ 投影到一个适当的低维空间 \mathbf{R}^P ,各数据点间的测地距离将保持不变^[20]. 随机映射将 \mathbf{X}^T 映射到 P 维空间,如下:

$$\mathbf{X}' = \Psi \mathbf{X}^T \quad (5)$$

$P \times N \quad P \times D \quad N \times D$

式中: Ψ 为随机矩阵; \mathbf{X}' 为映射后的高光谱数据, $P \ll D$. 随机映射的计算复杂度为 $O(DPN)$. 随机矩阵 Ψ 通常由均值为 0 方差为 $1/P$ 的独立同分布的随机元素构成. 随机映射将快速近似 k -邻域构建(见第 2.2 节)的复杂度从 $O(DN^2)$ 将至 $O(PN^2)$,并将局部邻域构建的复杂度从 $O(DNk^3)$ 降至 $O(PNk^3)$.

2.2 基于递归兰索斯算法的快速近似 k -邻域构建

常规 k -邻域利用欧氏距离搜索每个像素周围最近的 k 个像素点而得到,其计算复杂度为 $O(DN^2)$,其中 D 和 N 分别为高光谱数据的波段数和像素点个数. 因此本文引入递归兰索斯切分 (recursive Lanczos bisection, RLB)^[21] 来快速构建近似 k -邻域,降低邻域构建的计算复杂度.

RLB 算法的思想是将高光谱数据集递归地分为两个重叠的子集,计算每个子集的近似 k -邻域,然后拼接成最终 k -邻域图. 首先,RLB 利用谱分割的方法将高光谱数据集递归地分为重叠的数据子集,其重叠部分的大小通过重叠系数 α 来控制. 谱分割方法根据中心化的高光谱数据的最大奇异三重线构成的超平面来实现分割. 其次,当分割的数据子集的大小小于一定的阈值时,采用常规方法来计算其 k -邻域. 最后,将每个子集的 k -邻域拼接在一起,形成最终的全局 k -邻域. 如果一个像素点属于两个或以上不同的子集,其邻域信息从每个子集中选取. 快速近似 k -邻域构建同随机映射结合,能够将 k -邻域图构建的计算复杂度降低至 $O(PN^2)$,其中 P 为随机映射的维数, $\alpha = 1/(1 - \log_2(1 + \alpha))$, α 为重叠系数且 $0 < \alpha < 1$.

2.3 全局排列矩阵的快速近似奇异值分解

本文引入快速近似奇异值分解降低其复杂度至 $O(dN^2)$ ^[22],其中 d 为低维嵌入的维数. 假设全局排列矩阵为 Φ ,快速近似奇异值分解算法通过找到 d 阶分解来逼近 Φ ,如式(6):

$$\Phi \approx \hat{\mathbf{U}} \hat{\mathbf{\Sigma}} \hat{\mathbf{V}}^T \quad (6)$$

$N \times N \quad N \times d \quad d \times N \quad N \times d$

式中: $\hat{\mathbf{\Sigma}}$ 是对角线为前 d 个递减本征值的对角阵; $\hat{\mathbf{U}}$ 为 d 个本征值对应的本征向量; $\hat{\mathbf{V}}$ 为 d 阶矩阵. 由于 LTSA 的流形坐标需要 Φ 的 2 至 $d+1$ 个本征值对

应的本征向量,因此通过逼近 $\mathbf{A} = \lambda_1 \mathbf{I} - \Phi$ 来得到对应的本征向量,其中 λ_1 为 Φ 的最大的本征值. 假设 $m = d+1$, $l = m+2$ 且 $l < N-m$,首先构建均值为 0 且方差为 1 的随机矩阵 $\mathbf{G}_{l \times N}$,并得到矩阵 $\mathbf{R} = \mathbf{G}(\mathbf{A}\mathbf{A}^T)\mathbf{A}$. 其次,通过对 \mathbf{R}^T 进行奇异值分解得到其左 m 列本征向量构成的矩阵 $\mathbf{B}_{N \times m}$,以及对应的积矩阵 $\mathbf{T}_{N \times m} = \mathbf{A}\mathbf{B}$. 接下来,通过对 $\mathbf{T} = \mathbf{U}\mathbf{\Sigma}\mathbf{W}^T$ 的奇异值分解得到矩阵 \mathbf{U} 和 \mathbf{W} ,以及积矩阵 $\mathbf{V}_{N \times m} = \mathbf{B}\mathbf{W}$. 最后,所求的 MSU-LTSA 的流形坐标为矩阵 \mathbf{V} 的左 2 至 m 列构成的向量集.

2.4 MSU-LTSA 的算法流程

高光谱影像 MSU-LTSA 降维的流程(图 1)如下:① 采用式(5)中的随机映射来降低高光谱影像的波段数 D ;② 采用快速近似 k -邻域构建来得到每个像素点的 k -邻域 \mathbf{C} ;③ 最小化(1)获得每个像素点的局部流形坐标 θ ,并通过最小化得到全局排列矩阵 Φ ;④ 采用公式(6)中的快速近似奇异值分解得到 MSU-LTSA 的全局流形坐标 \mathbf{Y} .

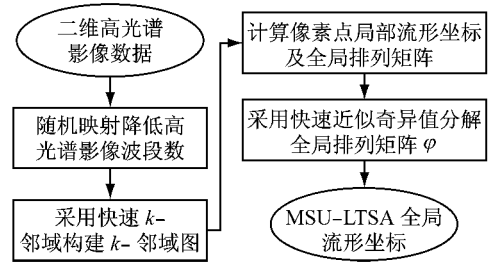


图 1 MSU-LTSA 方法流程

Fig.1 The method of MSU-LTSA

表 1 对比了 MSU-LTSA 与 LTSA 的计算复杂度,其中 D 和 N 为高光谱数据的波段数和像素个数; P 为随机映射的维数; d 为低维嵌入的维数; k 为邻域大小; $\alpha = 1/(1 - \log_2(1 + \alpha))$, α 为重叠系数,且 $0 < \alpha < 1$. 可以看出,MSU-LTSA 比 LTSA 的计算复杂度明显降低.

3 实验分析与结果

3.1 实验数据

PaviaU 数据来自西班牙巴斯克大学计算智能课题组. 影像由 ROSIS 传感器采集得到,覆盖帕维亚大学区域,共 103 波段,空间分辨率为 1.3 m,如图 2 所示. 影像为较大数据集中的一部分,包含 350×340 像素,波段数为 103,包含 9 类地物(包括阴影),各地物的训练和测试样本信息见表 2.

Indian 数据来自美国普渡大学遥感应用实验

表 1 MSU-LTSA 与 LTSA 的计算复杂度对比

Tab.1 The contrast of the computational complexity between MSU-LTSA and LTSA

步骤	复杂度	
	MSU-LTSA	LTSA
(1) 随机映射降低高光谱波段数	$O(DPN)$	
(2) k -邻域搜索	$O(PN^a)$ ($1 < a < 2$, $P \ll D$)	$O(DN^2)$
(3) 局部切空间和全局排列矩阵构建	$O(PNk^3) + O(k^2d)$	$O(DNk^3) + O(k^2d)$
(4) 排列矩阵的奇异值分解	$O(dN^2)$	$O(N^3)$
总体复杂度	$O(DPN) + O(PN^a) + O(PNk^3) + O(k^2d) + O(dN^2)$	$O(DN^2) + O(DNk^3) + O(k^2d) + O(N^3)$

室. 数据由美国 JPL 成像光谱仪于 1992 年 6 月 12 日采集得到, 波段数为 200, 空间分辨率为 20 m, 光谱分辨率为 10 nm, 光谱区间为 200~2 400 nm. 图 3 为覆盖西拉法叶地区西部 6 英里的一小块区域, 包含 145×145 像素. 图中共含 16 类地物, 各地物的训练和测试样本信息见表 3.

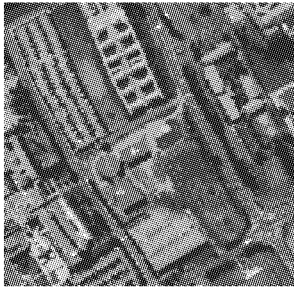


图 2 PaviaU 数据

Fig.2 The PaviaU dataset



图 3 Indian 数据

Fig.3 The Indian dataset

3.2 实验结果

采用以上数据集来全面分析和测试 MSU-LTSA 方法的计算速度和分类性能. MSU-LTSA 方法中, 递归兰索斯算法分割数据集的阈值设定为统一值 500. 实验采用 k -近邻 (k -nearest neighbors, KNN) 和支持向量机 (support vector machine, SVM)

表 2 PaviaU 数据中训练和测试样本信息

Tab.2 The information of training and testing samples in PaviaU dataset

类号	类名	解释	训练	测试	类号	类名	解释	训练	测试
1	Asphalt	柏油	839	3 356	6	Bare Soil	裸土	1 006	4 023
2	Meadows	牧场	437	1 748	7	Bitumen	沥青	266	1 064
3	Gravel	碎石	420	1 679	8	Self-Blocking Bricks	自封闭砖	469	1 878
4	Trees	树木	310	1 240	9	Shadows	阴影	186	743
5	Painted metal sheets	喷漆金属薄板	269	1 076	总数			4 202	16 087

表 3 Indian 数据中训练和测试样本信息

Tab.3 The information of training and testing samples in Indian dataset

类号	类名	解释	训练	测试	类号	类名	解释	训练	测试
1	Alfalfa	苜蓿	9	37	9	Oats	燕麦	4	16
2	Corn-notill	未耕犁的玉米地	286	1 142	10	Soybeans-notill	未耕犁的大豆地	194	778
3	Corn-min	嫩玉米	166	664	11	Soybeans-min	嫩大豆	491	1 964
4	Corn	玉米地	47	190	12	Soybeans-clean	收割后的大豆地	119	474
5	Grass/Pasture	草地	97	386	13	Wheat	小麦	41	164
6	Grass/Trees	草树混合	146	584	14	Woods	树林	253	1 012
7	Grass/pasture-mowed	犁过的草地	7	21	15	Bldg-Grass-Tree Drives	建筑-草地-树木混合	77	309
8	Hay-windowed	干草	96	382	16	Stone-Steel towers	石钢塔	19	74
总数								2 052	8 197

两种分类器,并结合总体分类精度(overall classification accuracy, OCA)来定量评价分类结果.其中,KNN 中采用欧氏距离进行度量;SVM 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.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.

(1) 计算速度实验

实验通过改变不同的嵌入维数和邻域大小来综合比较 MSU-LTSA 和 LTSA 的计算速度. PaviaU 数据中低维嵌入维数 d 的范围为 20~50,步长为 10, k 的大小设置为 $k=d+5$; Indian 数据中低维嵌入维数 d 的范围为 25~55,步长为 10,邻域 k 的大小为 $k=d+10$. 两个数据集中设置 $k=d+5$ 和 $k=d+10$ 能够保证足够多的邻域点来构建局部切空间,

同时满足两种方法的对比要求. 经过交叉验证, PaviaU 数据中随机投影维数 P 为 60,重叠系数 α 为 0.15; Indian 数据中随机投影维数 P 为 100,重叠系数 α 为 0.10. 实验环境是戴尔 Xeon E5400 2.83 GHz 处理器、32 GB 内存和 Windows 7 操作系统,代码编译环境为 Matlab 2011b. 两种方法的计算速度对比见表 4. 可以看出, PaviaU 中, $k=25$ 和 $d=20$ 时, MSU-LTSA 提高 LTSA 的计算速率 3.87 倍;随着 k 和 d 的增加, MSU-LTSA 的计算优势更加明显;在 $k=55$ 和 $d=50$ 时,能够提高约 4.69 倍的 LTSA 计算速度. Indian 数据的实验结果也同样阐释这一现象. 当 $k=35$ 和 $d=25$ 时, MSU-LTSA 的计算时间是 LTSA 的 1/3.30;随着 k 和 d 的增加,在 $k=65$ 和 $d=55$ 时,计算优势达到 4.58 倍. 因此, MSU-LTSA 能够提高 LTSA 的计算效率至少 3 倍.

表 4 MSU-LTSA 与 LTSA 的计算速度对比

Tab.4 The contrast in computational speed between MSU-LTSA and LTSA

PaviaU 数据				Indian 数据			
参数设置	计算时间/ 10^4 s		比率	参数设置	计算时间/ 10^4 s		比率
	MSU-LTSA	LTSA			MSU-LTSA	LTSA	
($k=25, d=20$)	3.712	14.37	3.87	($k=35, d=25$)	0.522 7	1.727	3.30
($k=35, d=30$)	6.702	26.41	3.94	($k=45, d=35$)	1.037	3.479	3.35
($k=45, d=40$)	9.508	40.76	4.28	($k=55, d=45$)	1.427	6.033	4.23
($k=55, d=50$)	14.43	67.71	4.69	($k=65, d=55$)	2.219	10.18	4.58

(2) 分类实验

实验通过分类来研究 MSU-LTSA 的流形坐标的分类效果. 由于三种速度提升策略仅提高 LTSA 的计算速度,并未关系 LTSA 算法的核心思想. 因此,通过选择适当维数来对比分析两种方法的分类结果. 经过交叉验证, PaviaU 数据中随机投影维数 P 为 60,重叠系数 α 为 0.10,嵌入维数 d 为 45,邻域 k 的大小为 50; Indian 数据中 P 为 100, α 为 0.15, d 为 50, k 为 60. 表 4 可以看出, PaviaU 中, MSU-LTSA 的总体分类精度 OCA 相比 LTSA 平均下降约 1.26%; Indian 中, MSU-LTSA 的 OCA 相比 LTSA 平均下降约 1.08%. 因此, MSU-LTSA 在提高 LTSA 计算速度的同时,仅仅降低了 1%左右的总体分类精度. 同时, LLTSA (linear local tangent space alignment)^[23] 作为 LTSA 的线性改进方法,表 5 对比了 MSU-LTSA 与 LLTSA 总体分类精度. 可以发现,尽管 MSU-LTSA 的 OCA 结果略低于 LTSA,但仍明显高于 LLTSA 的分类结果.

(3) 随机投影维数 P 对分类影响实验

实验通过改变随机投影维数 P 研究其对 MSU-LTSA 分类结果的影响. PaviaU 数据的 P 的选择区

表 5 MSU-LTSA 与 LTSA 的分类结果对比

Tab.5 The contrast in classification results between MSU-LTSA and LTSA

数据集	分类器	OCA/%		
		MSU-LTSA	LTSA	LLTSA
PaviaU 数据	KNN	74.41	75.46	71.33
	SVM	83.12	84.58	80.15
Indian 数据	KNN	81.67	82.58	77.48
	SVM	86.69	87.94	84.72

间为 50~100,步长为 10; Indian 数据的 P 的选择区间为 80~180,步长为 20. 经过交叉验证, PaviaU 数据的 d 选为 40, k 为 45, α 为 0.10; Indian 数据的 d 为 55, k 为 70, α 为 0.12. P 与分类精度 OCA 的关系如图 4 所示. 可以看出,随着 P 的增加,各数据的 OCA 有小幅震荡且增长非常缓慢. 因此,投影维数 P 对分类精度的影响并不大. 然而,考虑到实际分类精度的需求且随机投影的计算复杂度低,因此建议选用稍大的 P 来保证分类结果的高精度.

(4) 重叠参数 α 对分类影响实验

实验通过改变快速近似 k -邻域构建中的重叠参数 α 的大小研究其对 MSU-LTSA 降维后分类结果的影响. 试验中, PaviaU 和 Indian 数据的重叠参数 α 的选择区间都为 0.05~0.4,步长为 0.05. 经过交叉

验证, PaviaU 数据的低维嵌入维数 d 选为 40, 邻域 k 大小为 45, 随机投影维数 P 为 80; Indian 数据的低维嵌入维数 d 选为 55, 邻域 k 的大小为 70, 随机投影维数 P 为 100. 重叠参数 α 与分类精度 OCA 的关系图如图 5 所示. 可以看出, 随着重叠参数 α 的增加, 分类精度逐渐提高但有小幅震荡. 因此, 较大的

重叠参数 α 将会提高快速近似 k -邻域逼近真实 k -邻域的结果, 进而改善最终的分类结果. 然而, 考虑到较大的重叠参数 α 会带来 k -邻域构建的计算复杂量的大幅度提高, 因此建议折衷选择较小的重叠参数 α 同样能够保证 MSU-LTSA 的实际分类精度要求.

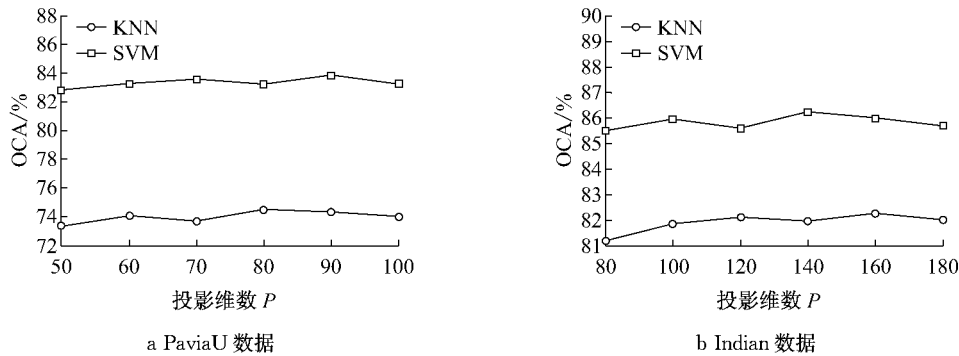


图 4 PaviaU 数据和 Indian 数据中投影维数 P 与总体分类精度(OCA)的关系

Fig. 4 The relationship between projected dimension P and OCA on the PaviaU and Indian datasets

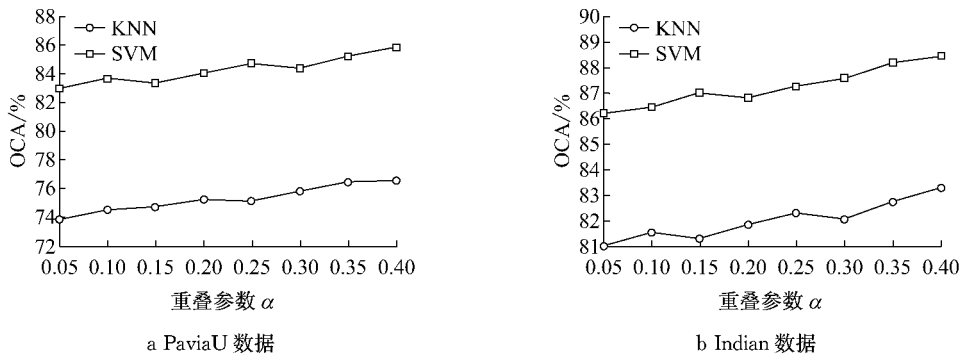


图 5 PaviaU 数据和 Indian 数据中重叠参数 α 与 OCA 的关系

Fig. 5 The relationship between overlapping parameter α and OCA on the PaviaU and Indian datasets

4 结论和展望

本文提出 MSU-LTSA 来综合提高 LTSA 的计算速度. 文中利用 PaviaU 和 Indian 数据集, 通过 4 组实验来分析 MSU-LTSA 的计算和分类性能. 实验结果显示, 随着嵌入维数 d 和邻域 k 的增加, MSU-LTSA 的计算优势越来越明显, 节约至少 3 倍的 LTSA 的计算时间. 另一方面, 分类结果证明, MSU-LTSA 能够得到低于 LTSA 约 1% 左右的总体分类精度. 这说明, MSU-LTSA 仅仅损失非常少的分类精度却提高至少 3 倍的 LTSA 的计算速度. 此外, 稍大的投影维数 P 和较小的重叠参数 α 能够保证 MSU-LTSA 获得较高的分类精度. 在接下来的工作中, 作者将全面分析递归兰索斯算法中分割阈值对后续分类结果的影响来进一步完善本文提出

的方法.

参考文献:

- [1] Chabrillat S, Goetz A F H, Krosley L, et al. Use of hyperspectral images in the identification and mapping of expansive clay soils and the role of spatial resolution [J]. Remote Sensing of Environment, 2002, 82:431.
- [2] Adam E, Mutanga O, Rugege D. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review [J]. Wetlands Ecology and Management, 2010, 18:281.
- [3] Chen X, Warner T A, Campagna D J. Integrating visible, near-infrared and short-wave infrared hyperspectral and multispectral thermal imagery for geological mapping at Cuprite, Nevada [J]. Remote sensing of Environment, 2007, 110:344.
- [4] Prabhakar M, Prasad Y, Thirupathi M, et al. Use of ground based hyperspectral remote sensing for detection of stress in

- cotton caused by leafhopper (Hemiptera: Cicadellidae) [J]. Computers and Electronics in Agriculture, 2011, 79:189.
- [5] Plaza A, Martínez P, Plaza J, et al. Dimensionality reduction and classification of hyperspectral image data using sequences of extended morphological transformations [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43: 466.
- [6] Tenenbaum J B, Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290:2319.
- [7] Zhang Z, Zha H. Nonlinear dimension reduction via local tangent space alignment[J]. Intelligent Data Engineering and Automated Learning, 2003, 2690:477.
- [8] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290:2323.
- [9] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15:1273.
- [10] Tamayo P, Slonim D, Mesirov J, et al. Interpreting patterns of gene expression with self-organizing maps: methods and application to hematopoietic differentiation[C]//Proceedings of the National Academy of Sciences. Washington D C: [s. n.], 1999: 2907-2912.
- [11] Fong M. Dimension reduction on hyperspectral images[R]. Los Angeles: Department of Mathematics of University of California, 2007.
- [12] Ma L, Crawford M M, Tian J. Anomaly detection for hyperspectral images using local tangent space alignment[C]//Proceedings of 2010 IEEE International Conference on Geoscience and Remote Sensing Symposium (IGARSS). Honolulu: IGARSS, 2010: 824-827.
- [13] Ma L, Crawford M, Tian J. Generalised supervised local tangent space alignment for hyperspectral image classification [J]. Electronics Letters, 2010, 46:497.
- [14] Ma L, Crawford M M, Tian J. Local manifold learning-based k -nearest-neighbor for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48:4099.
- [15] Yang H L, Crawford M M. Manifold alignment for multitemporal hyperspectral image classification [C]//Proceedings of 2011 IEEE International Conference on Geoscience and Remote Sensing Symposium (IGARSS). Vancouver: IGARSS, 2011: 4332-4335.
- [16] Crawford M M, Ma L, Kim W. Exploring nonlinear manifold learning for classification of hyperspectral data[J]. Optical Remote Sensing, 2011, 3:207.
- [17] Luo X and Jiang M F. A new dimensionality analysis algorithm for hyperspectral imagery [C]//Proceedings of 2011 International Conference on in Computer Science and Service System (CSSS). Nanjing: CSSS, China, 2011: 1952-1956.
- [18] Khodr J, Younes R. Dimensionality reduction on hyperspectral images: a comparative review based on artificial datas[C]//Proceedings of 2011 4th International Congress on Image and Signal Processing (CISP). Shanghai: CISP, 2011: 1875-1883.
- [19] Bingham E, Mannila H. Random projection in dimensionality reduction: applications to image and text data [C]//Proceedings of the Seventh ACM SIGKDD International Conference on Knowledge Discovery and Data mining. Boston: [s. n.], 2001: 245-250.
- [20] Baraniuk R G, Wakin M B. Random projections of smooth manifolds[J]. Foundations of Computational Mathematics, 2009, 9:51.
- [21] Chen J, Fang H, Saad Y. Fast approximate knn graph construction for high dimensional data via recursive lanczos bisection [J]. The Journal of Machine Learning Research, 2009, 10:1989.
- [22] Rokhlin V, Szlam A, Tygert M. A Randomized Algorithm for Principal Component Analysis[J]. SIAM Journal on Matrix Analysis and Applications, 2010, 31:1100.
- [23] Zhang T, Yang J, Zhao D, et al. Linear local tangent space alignment and application to face recognition [J]. Neurocomputing, 2007, 70:1547.