

文章编号 1004-924X(2013)11-2922-09

基于稀疏鉴别嵌入的高光谱遥感影像分类

黄 鸿^{1,2*}, 杨 媚¹, 张满菊³

(1. 重庆大学 光电技术及系统教育部重点实验室, 重庆 400030;

2. 重庆川仪自动化股份有限公司技术中心, 重庆 401121;

3. 酒泉卫星发射中心, 甘肃 酒泉 735300)

摘要:稀疏保持投影(SPP)是一种基于 l_1 图的新型降维算法,它利用样本间的稀疏重构关系建图,但是 SPP 为非监督算法,分类效果受到限制。针对此问题,本文提出了一种新的稀疏流形学习算法—稀疏鉴别嵌入(SDE)。该算法在利用样本的稀疏重构关系建图时引入了样本的类别信息,并通过优化目标函数来得到投影矩阵,使得不同类的数据点在低维嵌入空间中尽可能地分散开。SDE 通过结合数据稀疏性及类间流形结构的优点,不仅保留样本间的稀疏重构关系,而且通过引入训练样本的类别信息实现稀疏鉴别特征提取,更有利于分类。在 Urban 和 Washington DC Mall 数据集上的实验结果表明:SDE 算法比其他算法的分类性能有明显的提升,在每类随机选取 16 个训练样本的情况下,SDE 算法的分类精度分别达到了 73.47%和 98.35%。

关键词:高光谱遥感影像;维数约简;稀疏表示;流形学习;稀疏鉴别嵌入

中图分类号:TP751.1 **文献标识码:**A **doi:**10.3788/OPE.20132111.2922

Hyperspectral remote sensing image classification based on SDE

HUANG Hong^{1,2*}, YANG Mei¹, ZHANG Man-ju³

(1. Key Laboratory of Opto-electronic Technology & Systems of the Ministry of Education, Chongqing University, Chongqing 400030, China;

2. The Technical Center of Chongqing Chuanyi Automation Co., Ltd., Chongqing 401121, China;

3. Jiuquan Satellite Launch Center, Jiuquan 735300, China)

* Corresponding author, E-mail: hhuang.cqu@gmail.com

Abstract: Sparsity Preserving Projection(SPP) is a new algorithm for reducing dimensions of dataset based on a weighted graph(l_1 -Graph), which reconstructs the weighted graph by the sparse relationship of train samples. However, SPP is an unsupervised learning method essentially, and it doesn't employ any prior knowledge of class to extract identification features. For this issue, a novel algorithm, Sparsity Discriminant Embedding (SDE) is proposed. Unlike SPP, the SDE adopts the class information of train samples when it constructs weighted graph of sparse reconstruction relationship. The projection matrix of the SDE is obtained via optimizing objective function and making different kinds of data points separate in the low-dimensional embedding space via a projection. By combining

收稿日期:2013-04-01;修订日期:2013-04-24.

基金项目:国家自然科学基金资助项目(No. 61101168);中国博士后科学基金资助项目(No. 2012M511906);重庆市博士后科研基金特别资助项目(No. XM2012001)

both interclass manifold structure and sparse property, the SDE keeps the sparse reconstructive relationships of dataset, and employs the class information of train samples to increase the classification rate. The experimental results obtained from operations on Urban and Washington DC Mall datasets show that the classification efficiency of the SDE has improved greatly as compared to those of other algorithms. The obtained classification accuracy has been 73.47% and 98.35%, respectively, when 16 samples of each class are randomly selected for training.

Key words: hyperspectral remote sensing image; dimensionality reduction; sparsity representation; manifold learning; sparsity discriminant embedding

1 引 言

自 20 世纪 80 年代以来,高光谱遥感技术发展迅速,由于其具有空间分辨率高、地物光谱曲线连续等特点,在科研和国民经济中得到广泛应用^[1-3]。然而,高光谱遥感影像往往为高维数据,若要直接对原始数据进行分析,则对存储空间和计算能力有较高要求,而且,可能导致维数灾难问题^[4]。降低数据维数是约简数据复杂度、提取鉴别特征的重要技术,可有效避免维数灾难,使分类任务更加稳定高效。

目前,应用较广泛的降维方法主要有主成分分析(Principal Component Analysis, PCA)^[5-6]、局部保持投影(Locality Preserving Projection, LPP)^[7]、近邻保持嵌入(Neighborhood Preserving Embedding, NPE)^[8]等。PCA 的主要思想是在最小均方意义下寻找最能够代表原始数据的投影方向,属于全局降维方法,但不一定是最优分类。LPP 和 NPE 通过近邻图以保留样本的局部近邻结构,在一定程度上保持了原始数据的非线性流形结构,但是并没有利用训练数据的类别信息,分类效果会受到限制。监督局部保持投影(Supervised LPP, SLPP)^[9]、监督近邻保持嵌入(Supervised NPE, SNPE)^[10-11]分别为 LPP、NPE 的监督改进形式,但分类效果都依赖于人工预定义的近邻图,要获得好的性能往往需要更多的训练样本,同时存在近邻参数选择困难(如近邻数 k 、核宽 σ)、噪声敏感等问题。

稀疏保持投影(Sparsity Preserving Projections, SPP)是最近提出的一种基于稀疏表示理论的降维方法。与传统方法的建图方式不同,SPP 算法利用样本间的稀疏重构关系建图,并可以归结为 l_1 -范数最小化问题^[12],因此,不需要人为地

选择近邻参数值。SPP 算法能有效利用稀疏表示的自然判别能力,在很大程度上缓解了近邻参数选择的困难。因此,SPP 算法在信号处理、模式识别等众多领域有着广泛的应用,但目前较少用于高光谱遥感影像分类,且 SPP 算法本质上是一种无监督的算法,它并不利用样本的类别信息来提取鉴别特征。

针对上述问题,本文在 SPP 算法的基础上,提出了一种新的稀疏鉴别嵌入算法(Sparsity Discriminant Embedding, SDE),并将它应用于高光谱遥感影像分类。该方法结合了类间流形结构及稀疏性的优点,不仅保留了样本间的稀疏重构关系,而且由于引入了训练样本的类别信息,从而提高了算法的分类精度。

2 稀疏保持投影

2.1 稀疏表示

稀疏表示^[12-13](Sparsity Representation, SR)最初用于信号的压缩和表示,现已成功应用于信号处理、统计学及模式识别等领域。其核心思想是将信号 $x_i \in \mathbf{R}^m$ 分解为一系列基信号 $\mathbf{X} = \{x_i \in \mathbf{R}^m\}_{i=1}^n$ 的线性组合 $x \approx \sum_{i=1}^n s_i x_i$,并希望尽可能多的 s_i 系数为零(即向量 $\mathbf{S} = [s_1, s_2, \dots, s_n]^T$ 尽可能稀疏)。具有非零系数的信号揭示了原信号的主要特征和内在结构。其严格的数学模型如下:

$$\min_{s_i} \|s_i\|_0 \quad s.t. \quad x_i = \mathbf{X} s_i, \quad (1)$$

式中: $\mathbf{X} = [x_1, x_2, \dots, x_n]$, $\mathbf{X} \in \mathbf{R}^{m \times n}$ 为基信号矩阵, $s_i \in \mathbf{R}^n$, \mathbf{S}_i 表示用除 x_i 以外的基信号进行稀疏表示的重建系数向量, $\|s_i\|_0$ 表示 s_i 的 l_0 范数,用于衡量 s_i 的稀疏性,等于 s_i 中非零元素的数目。

最小化 l_0 范数问题是一个 NP-hard 问题,求解困难。在系数足够稀疏的条件下, l_0 范数最小

化问题可以转化为 l_1 范数最小化问题:

$$\min \|s_i\|_1 \quad s. t. \quad x_i = Xs_i. \quad (2)$$

式中: $\|s_i\|_1$ 表示 s_i 的 l_1 范数。

2.2 稀疏保持投影(SPP)

目前,许多降维算法采用近邻图来描述数据集的几何结构^[14],但其近邻图的构建依赖于人为选择的近邻参数,通常很难选择出合适的近邻参数值。SPP^[15-16]通过稀疏表示获取样本间的稀疏重构关系,并以此建图。

设 $\{x_i, i=1, 2, \dots, n\}$ 为一组训练样本点,其中, $x_i \in \mathbf{R}^m$, 令 \mathbf{X} 为训练样本集矩阵, $\mathbf{X} = [x_1, x_2, \dots, x_n]$, $\mathbf{X} \in \mathbf{R}^{m \times n}$, 对于样本 $x_i \in \mathbf{X}$ 。SPP 的目标函数为:

$$J(\mathbf{V}) = \min \sum_{i=1}^n \| \mathbf{V}^T x_i - \mathbf{V}^T \tilde{X} s_i \|^2, \quad (3)$$

式中: \mathbf{V} 为投影矩阵 $\mathbf{V} \in \mathbf{R}^{m \times n}$ 。对目标函数进行简单的代数运算,可得到:

$$\begin{aligned} J(\mathbf{V}) &= \min \text{tr} \{ \mathbf{V}^T [\sum_{i=1}^n (x_i - \tilde{X} s_i)(x_i - \tilde{X} s_i)^T] \mathbf{V} \} = \\ &= \min \text{tr} \{ \mathbf{V}^T [\sum_{i=1}^n (\mathbf{X} e_i - \tilde{X} s_i)(\mathbf{X} e_i - \tilde{X} s_i)^T] \mathbf{V} \} = \\ &= \min \text{tr} \{ \mathbf{V}^T \mathbf{X} [\sum_{i=1}^n (e_i - \tilde{s}_i)(e_i - \tilde{s}_i)^T] \mathbf{X}^T \mathbf{V} \} = \\ &= \min \text{tr} \{ \mathbf{V}^T \mathbf{X} [\sum_{i=1}^n (e_i e_i^T - \tilde{s}_i e_i^T - e_i \tilde{s}_i^T - \tilde{s}_i \tilde{s}_i^T)] \mathbf{X}^T \mathbf{V} \} = \\ &= \min \text{tr} \{ \mathbf{V}^T \mathbf{X} (\mathbf{I} - \mathbf{S} - \mathbf{S}^T + \tilde{\mathbf{S}}^T \mathbf{S}) \mathbf{X}^T \mathbf{V} \}, \quad (4) \end{aligned}$$

式中: e_i 为 n 维向量(e_i 中第 i 个元素为 1, 其余为 0)。

为了避免退化解的出现,增加约束 $\text{tr}(\mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V}) = 1$ 。从而,目标函数表示为以下最优化问题:

$$J(\mathbf{V}) = \min_{\mathbf{V}} \frac{\text{tr}[\mathbf{V}^T \mathbf{X} (\mathbf{I} - \mathbf{S} - \mathbf{S}^T + \tilde{\mathbf{S}}^T \mathbf{S}) \mathbf{X}^T \mathbf{V}]}{\text{tr}(\mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V})}. \quad (5)$$

为了能得到更加稳定的数值解,把上述最小化问题转化为如下最大化问题:

$$\begin{aligned} J(\mathbf{V}) &= \max_{\mathbf{V}} \frac{\text{tr}[\mathbf{V}^T \mathbf{X} (\mathbf{S} + \mathbf{S}^T - \tilde{\mathbf{S}}^T \mathbf{S}) \mathbf{X}^T \mathbf{V}]}{\text{tr}(\mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V})} = \\ &= \max_{\mathbf{V}} \frac{\text{tr}[\mathbf{V}^T \mathbf{X} \mathbf{S}_\beta \mathbf{X}^T \mathbf{V}]}{\text{tr}(\mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V})}, \quad (6) \end{aligned}$$

式中: $\mathbf{S}_\beta = \mathbf{S} + \mathbf{S}^T - \tilde{\mathbf{S}}^T \mathbf{S}$, 通过求解广义特征值问题 $\mathbf{X} \mathbf{S}_\beta \mathbf{X}^T \mathbf{V} = \lambda \mathbf{X} \mathbf{X}^T \mathbf{V}$, 获得最优投影矩阵 $\mathbf{V} = [v_1, v_2, \dots, v_d]$, 其中, $v_i (i=1, \dots, d)$ 为前 d 个最大特征值对应的特征向量。

3 稀疏鉴别嵌入(SDE)

SPP 本质上是一种非监督算法^[17-18], 本文对 SPP 进行了扩展, 提出一种新的稀疏鉴别嵌入算法(SDE), 下面对其进行介绍。

3.1 SDE 算法原理

通常来自同一类别的样本间的线性相关程度要高于不同类别样本间的, 因此使用与当前样本具有相同类别的训练样本进行稀疏表示, 可以得到更好的稀疏表示效果。本文对 SPP 中的稀疏表示做如下改进:

$$\min_{s_i} \|s_i\|_1 \quad s. t. \quad \|x_i - \mathbf{X}_j s_i\| \leq \epsilon \quad \mathbf{1} = \mathbf{1}^T s_i, \quad (7)$$

式中: \mathbf{X}_j 表示与 x_i 同类的训练样本集, ϵ 为算法的容许误差。与 SPP 算法不同的是, SDE 仅用与当前样本具有相同类型的训练样本进行稀疏重构, 而 SPP 则是用全部的训练样本进行稀疏重构。同时, 为了度量数据间的相异性, SDE 还构建了类间图 \mathbf{G}_b 。具体定义为: 设 $l(x_i)$ 和 $l(x_j)$ 分别表示数据点 x_i 和 x_j 的类别, 若 $l(x_i) \neq l(x_j)$, 则在 \mathbf{G}_b 中用一条边连接 x_i 和 x_j 两点, 否则, x_i 和 x_j 不相连。然后计算 \mathbf{G}_b 的权重矩阵 ω_b , 如下:

$$\omega_{b,ij} = \begin{cases} 1 & l(x_i) \neq l(x_j) \\ 0 & \text{otherwise} \end{cases}. \quad (8)$$

对于分类而言, 不仅希望在低维嵌入空间能够保持数据的局部特性, 而且还要求不同类的样本数据要具有很好的可分性, 即它们尽可能地分散, 这样, 有利于分类。因此, SDE 目标函数可定义为:

$$J(\mathbf{V}) = \max \sum_{ij} \| \mathbf{V}^T x_i - \mathbf{V}^T \tilde{X} s_j \|^2 \omega_{ij}. \quad (9)$$

经过代数运算, 式(9)可化简为:

$$\begin{aligned} & \sum_{ij} \| \mathbf{V}^T x_i - \mathbf{V}^T \tilde{X} s_j \|^2 \omega_{ij} = \\ & \sum_{ij} (\mathbf{V}^T x_i - \mathbf{V}^T \tilde{X} s_j)(\mathbf{V}^T x_i - \mathbf{V}^T \tilde{X} s_j)^T \omega_{ij} = \\ & \mathbf{V}^T \left(\sum (x_i - \tilde{X} s_j) \omega_{ij} (x_i - \tilde{X} s_j)^T \right) \mathbf{V} = \\ & \mathbf{V}^T (\mathbf{X} \mathbf{D}_s \mathbf{X}^T - \mathbf{X} \mathbf{W}_s (\tilde{\mathbf{X}} \tilde{\mathbf{S}})^T - \tilde{\mathbf{X}} \tilde{\mathbf{S}} \mathbf{W}_s \mathbf{X}^T + \\ & \quad \tilde{\mathbf{X}} \tilde{\mathbf{S}} \mathbf{D}_s \tilde{\mathbf{S}}^T \mathbf{X}^T) \mathbf{V} = \\ & \mathbf{V}^T \mathbf{X} (\mathbf{D}_s - \mathbf{W}_s \tilde{\mathbf{S}}^T - \tilde{\mathbf{S}} \mathbf{W}_s + \tilde{\mathbf{S}} \mathbf{D}_s \tilde{\mathbf{S}}^T) \mathbf{X}^T \mathbf{V} = \\ & \mathbf{V}^T \mathbf{X} \mathbf{S}_\gamma \mathbf{X}^T \mathbf{V}, \quad (10) \end{aligned}$$

式中, $\mathbf{S}_\gamma = \mathbf{D}_s - \mathbf{W}_s \tilde{\mathbf{S}}^T - \tilde{\mathbf{S}} \mathbf{W}_s + \tilde{\mathbf{S}} \mathbf{D}_s \tilde{\mathbf{S}}^T$, \mathbf{D}_s 为对角阵,

其对角线元素为 $D_{s,i} = \sum_j \omega_{ij}$, $\tilde{S} = [\tilde{s}_1, \tilde{s}_2, \dots, \tilde{s}_n]$ 。

然后,添加约束条件 $\text{tr}(\mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V}) = 1$, 目标函数可表达为:

$$J(\mathbf{V}) = \text{argmax} \mathbf{V}^T \mathbf{X} \mathbf{S}_\gamma \mathbf{X}^T \mathbf{V} \quad s. t. \quad \mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V} = \mathbf{I}. \quad (11)$$

对式(11)运用拉格朗日乘数法求解,即令 $J(\mathbf{V})$ 对 \mathbf{V} 的偏导数为零:

$$\frac{\partial}{\partial \mathbf{V}} (\mathbf{V}^T \mathbf{X} \mathbf{S}_\gamma \mathbf{X}^T \mathbf{V} - \lambda (\mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V} - \mathbf{I})) = 0. \quad (12)$$

则可表示为以下的广义特征值求解问题:

$$\mathbf{X} \mathbf{S}_\gamma \mathbf{X}^T \mathbf{V} = \lambda \mathbf{X} \mathbf{X}^T \mathbf{V}. \quad (13)$$

得到最优投影矩阵 $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_d]$, 其中, $\mathbf{v}_i (i = 1, \dots, d)$ 为前 d 个最大特征值对应的特征向量。

3.2 SDE 算法步骤

本文所提出的 SDE 算法的步骤具体如下:

表 1 SDE 算法步骤

Tab. 1 SDE algorithm steps

输入: N 个训练样本的数据 $\mathbf{X} = \{(x_1, l_1), (x_2, l_2), \dots, (x_n, l_n)\}$, $x_i \in \mathbf{R}^m$, 嵌入特征维数 d
输出: 投影矩阵 \mathbf{V} , 嵌入特征 \mathbf{Y}
Step1: 根据式(7)构造稀疏系数矩阵 \tilde{S}
Step2: 构造类间图 G_b , 根据式(8)计算权重矩阵 \mathbf{W}
Step3: 计算 $\mathbf{S}_\gamma = \mathbf{D}_s - \mathbf{W}_s \tilde{S}^T - \mathbf{S} \mathbf{W}_s + \tilde{S} \mathbf{D}_s \tilde{S}^T$
Step4: 通过广义特征值问题 $\mathbf{X} \mathbf{S}_\gamma \mathbf{X}^T \mathbf{V} = \lambda \mathbf{X} \mathbf{X}^T \mathbf{V}$ 计算特征向量, 获得投影矩阵 \mathbf{V} 。

4 实验与分析

为了验证 SDE 算法的有效性, 本文在高光谱

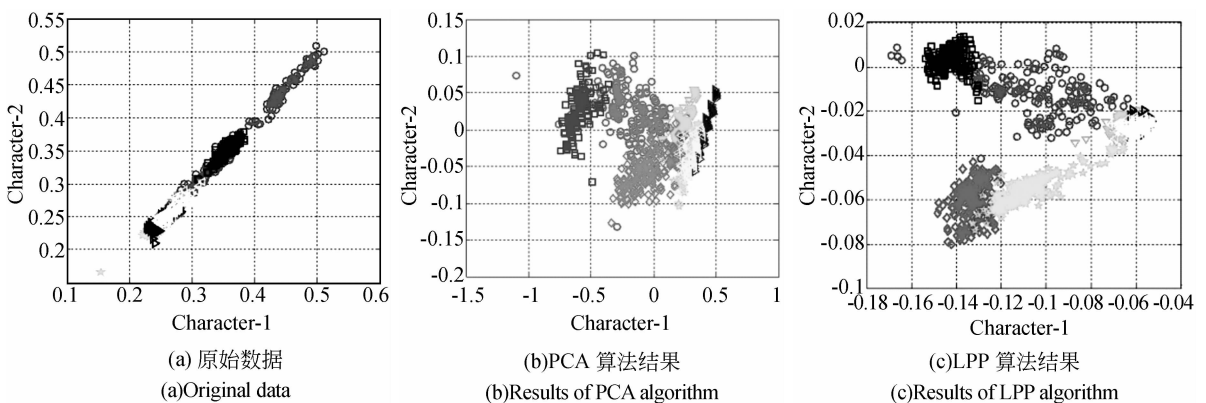
遥感数据集 Urban 和 Washington DC Mall^[19] 上进行实验, 并与 PCA、LPP、SLPP、NPE、SNPE 及 SPP 等算法进行比较。实验中, 调整各个算法的参数, 使其达到最佳效果。具体参数设置如下: PCA 的能量保持为 90%, 维数降到 20 维; LPP、SLPP、NPE、SNPE 的近邻数 $k = 5$ 。

Urban 数据集和 Washington DC Mall 数据集^[20-21] 均是 HYDICE 传感器获取的高光谱影像^[19]。其中, Urban 数据集影像大小为 307 pixel \times 307 pixel, 覆盖了某城郊住区; 空间分辨率为 3m, 波谱范围为 400~2 500 nm; 已知地物类别包括“道路”、“建筑”、“树木”和“草地”4 类。Washington DC Mall 数据集获取时间为 1995 年 8 月 23 日, 空间分辨率为 4m, 覆盖了华盛顿特区国家广场的局部; 该影像大小为 1 280 pixel \times 307 pixel; 共 191 个波段; 波谱范围为 400~2 400 nm; 已知的地物类别包括“建筑”、“道路”、“小路(广场砾石小径)”、“草地”、“树木”、“水体”和“阴影”7 类。

4.1 SDE 算法对数据可分性增强效果

为了直观地分析 SDE 算法对数据集可分性增强的效果, 本文对 Washington DC Mall 数据集通过 SDE 算法的二维嵌入结果进行可视化显示, 并与其他算法的效果进行对比。图 1(a) 是 Washington DC Mall 数据集投影前的二维可视化显示, 图 1(b)~1(h) 分别是 Washington DC Mall 数据集经过 PCA、LPP、SLPP、NPE、SNPE、SPP、SDE 算法投影到二维嵌入空间的可视化结果。

从图 1(a) 可看出, 样本数据集在投影前, 不同类别之间存在混叠现象, 样本可分性较差。经过上述各种算法投影后, 样本的混叠现象得到不同程度的改善。从图 1(h) 可知, 本文所提出的 SDE 算法使得数据集的可分性显著增强, 有利于分类。



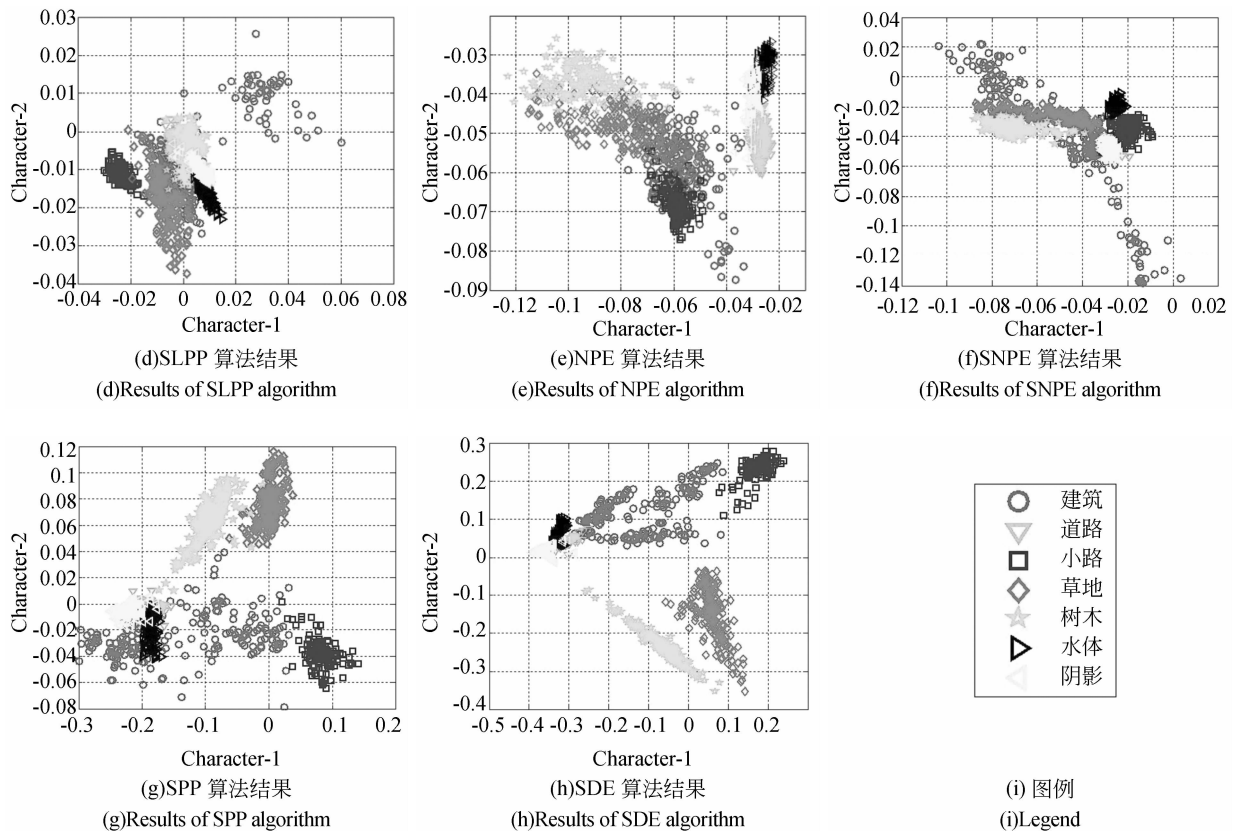


图 1 Washington DC Mall 数据集的二维空间分布及其通过不同降维方法的二维嵌入结果

Fig. 1 2-D spatial distribution of Washington DC Mall data set and its 2-D embedding results by different dimension reduction methods

4.2 Urban 数据集分类实验

实验设置如下: 分别对每类样本随机选取 4、8、12 和 16 个样本作为训练样本, 记为 4-train、8-train、12-train 和 16-train。剩下的样本均作为测试样本。分别用 PCA、LPP、SLPP、NPE、SNPE、

SPP 及 SDE 算法对每组样本进行降维。最后, 用最简单的最近邻分类器(1-NN)进行分类, 计算各算法的识别率, 重复做 10 次实验取 10 次的平均值, 分析各算法的识别效果。图 2 给出了采用各种降维方法在不同训练样本数目下的分类精度。

表 2 不同方法在 Urban 数据集上的最高精度

Tab. 2 Comparison of the highest precision of different methods on Urban dataset(mean±std)

算法	分类精度/(%)			
	4-train	8-train	12-train	16-train
PCA+1NN	61.37±3.1	66.52±3.8	67.83±3.6	68.08±2.4
LPP+1NN	64.22±3.0	66.39±2.6	67.34±3.0	68.17±2.2
SLPP+1NN	65.07±3.6	66.52±3.3	67.47±3.4	67.58±3.1
NPE+1NN	64.45±2.2	64.56±3.5	67.11±2.3	67.90±3.4
SNPE+1NN	65.97±3.1	68.87±3.2	69.95±3.1	70.08±2.1
SPP+1NN	68.22±2.7	68.37±2.9	71.25±2.0	71.83±2.0
SDE+1NN	63.97±2.1	69.12±2.5	72.05±1.8	73.47±1.8





图 2 不同方法在 Urban 数据集上的分类精度

Fig. 2 Classification accuracy of different methods on Urban dataset



(a)Urban 数据集高光谱图像
(a)Hyperspectral image of Urban dataset



(b)基于 SDE 的分类结果
(b)Classification results of SDE

图 3 Urban 数据集的地物图像和基于 SDE 的分类结果

Fig. 3 Hyperspectral image and classification results of Urban dataset

4.3 Washington DC Mall 数据集实验

对每类样本分别随机选取 4、8、12 和 16 个样本作为训练样本,剩下的样本均作为测试样本。分别用 PCA、LPP、NPE、SLPP、SNPE、SPP 及 SDE 算法对每组样本进行降维,然后,用最简单的最近邻分类器(1-NN)进行分类。计算各算法的识别率,重复实验 10 次,取其平均值。图 4 给出了采用各种降维方法在不同训练样本数目下的分类精度。

由图 4 和表 3 可知,随训练样本数目的增加,所有算法分类精度总体呈上升趋势。其中,SDE 算法的分类效果优于其他算法。图 5 给出了运用 SDE 算法在 Washington DC Mall 数据集上的实验结果。由图 5(b)可知,本文提出的 SDE 算法使数据的可分性增强,分类结果较好。

由图 2 和表 2 可知,所有算法随训练样本数目的增加,分类精度总体都呈上升趋势。其中,SLPP 和 SNPE 算法较 PCA、LPP 及 NPE 算法的分类效果更优。这是因为 SLPP 和 SNPE 是监督算法,它们引入了训练样本的类别信息,从而,提高了分类精度。较传统降维算法,SPP 的识别率有明显的提升,这体现了利用稀疏表示自然判别能力的优势。SDE 较 SPP 的分类效果更好,这是因为 SDE 在利用训练样本的稀疏重构关系建图的同时,引入了训练样本的类别信息,因此识别率得到了明显的提升。

图 3 给出了 Urban 数据集经过 SDE 算法降维,再用最近邻分类器(1-NN)分类的实验结果,由图 3(b)可知,SDE 算法提取的鉴别特征有利于后续分类,分类效果较理想。

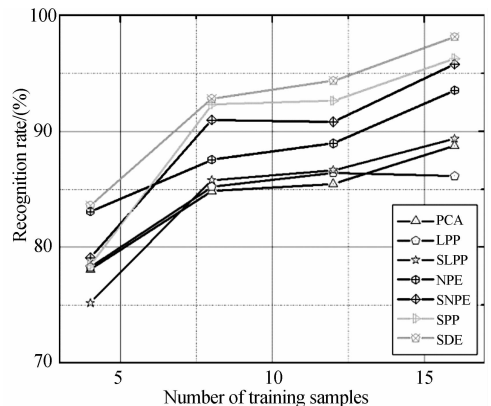



图 4 不同方法在 Washington DC Mall 数据集上的分类精度

Fig. 4 Classification accuracy of different methods on Washington DC Mall dataset


表 3 不同方法在 Washington DC Mall 数据集上的最高精度

Tab. 3 Comparison of the highest precision of different methods on Washington DC Mall dataset (mean±std)

算法	分类精度/(%)			
	4-train	8-train	12-train	16-train
PCA+1NN	78.07±3.4	84.84±2.1	85.47±3.1	88.77±1.5
LPP+1NN	78.29±3.0	85.23±3.3	86.41±2.5	86.14±2.9
SLPP+1NN	75.19±3.9	85.81±3.0	86.65±3.3	89.36±2.4
NPE+1NN	83.08±2.5	87.55±3.6	88.96±3.0	93.55±2.1
SNPE+1NN	79.11±3.3	90.99±3.6	90.82±2.9	95.81±1.9
SPP+1NN	78.47±1.8	92.32±2.7	92.64±2.7	96.31±0.9
SDE+1NN	83.86±2.2	93.72±1.6	95.30±2.0	98.35±0.7



(a) Washington DC Mall 数据集高光谱图像
(a) Hyperspectral image of Washington DC Mall dataset



(b) 基于 SDE 的分类结果
(b) Classification results of SDE

图 5 Washington 数据集的地物图像和基于 SDE 的分类结果

Fig. 5 Hyperspectral image and classification results of Washington dataset

5 结 论

SPP 是最近提出的一种基于 l_1 -图的新型降维

算法。它利用样本间的稀疏重构关系建图,但是 SPP 为非监督算法,分类效果受到限制。

本文针对该问题对 SPP 进行了扩展,提出了一种新的稀疏鉴别嵌入算法。该算法在利用样本的稀疏重构关系建图的同时引入了样本的类别信息,并通过优化目标函数来得到投影矩阵,使得投影后不同类数据点尽可能地分散开。然后提取稀疏鉴别特征,从而更有利于分类。在 Urban 和 Washington DC Mall 数据集上进行了实验,结果显示,SDE 算法的分类精度分别达到了 73.47% 和 98.35%,表明 SDE 算法比其他算法的分类性能有明显的提升。

本文提出的稀疏鉴别嵌入算法属于监督学习分类方法,要求所有的训练样本均事先标记样本类别,而在实际高光谱遥感影像分类的应用中,往往有类别标记的样本较少或标记的代价较高^[22-23]。因此,如何将 SDE 向半监督学习进行拓展,从标记数据和未标记数据中挖掘出有用信息来改善学习性能是下一步研究的主要内容。

参考文献:

- [1] 童庆禧,张兵,郑芬兰. 高光谱原理技术与应用[M]. 北京:高等教育出版社,2008.
TONG Q X, ZHANG B, ZHENG F L. *Principles and Application of Hyperspectral Remote Sensing* [M]. Beijing: Higher Education Press, 2008. (in

Chinese)

- [2] 陈进. 高光谱图像分类方法研究[D]. 长沙:国防科技大学, 2010.
CHEN J. *Hyperspectral image classification method* [D]. Changsha: National University of Defense Technology, 2010. (in Chinese)
[3] 黄鸿,秦高峰,冯海亮. 半监督流形学习及其在遥感影像分类中的应用[J]. 光学精密工程, 2011, 19

- (12):3025-3033.
- HUANG H, QIN G F, FENG H L. Semi-supervised manifold learning and its application to remote sensing image classification [J]. *Opt. Precision Eng.*, 2011, 19(12):3025-3033. (in Chinese)
- [4] 乔立山. 基于图的降维技术研究及应用[D]. 南京: 南京航空航天大学, 2009.
- QIAO L SH. *Research on graph-based dimensionality reduction and its applications* [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2009. (in Chinese)
- [5] 姚明海, 瞿心昱. 基于自适应子空间在线 PCA 的手势识别[J]. 模式识别与人工智能, 2011, 24(2): 299-304.
- YAO M H, QU X Y. Hand gesture recognition based on online PCA with adaptive subspace [J]. *Pattern Recognition and Artificial Intelligence*, 2011, 24(2): 299-304. (in Chinese)
- [6] 沈凌云, 郎百和, 朱明. 一种基于人工神经网络的人脸识别方法[J]. 液晶与显示, 2011, 26(6): 836-840.
- SHEN L Y, LANG B H, ZHU M. Face recognition method based on artificial neural network [J]. *Chinese Journal of Liquid Crystals and Displays*, 2011, 26(6): 836-840. (in Chinese)
- [7] 林玉娥, 李敬兆, 梁兴柱, 等. 直接正交鉴别保局投影算法[J]. 光电子·激光, 2012, 23(3): 561-565.
- LIN Y E, LI J ZH, LIANG X ZH, *et al.*. Direct orthogonal discriminant locality preserving projections method [J]. *Journal of Optoelectronics · Laser*, 2012, 23(3): 561-565. (in Chinese)
- [8] 张大明, 符茂胜, 罗斌, 等. 基于二维近邻保持嵌入的图像识别[J]. 模式识别与人工智能, 2011, 24(6): 810-815.
- ZHANG D M, FU M SH, LUO B, *et al.*. Image recognition with two-dimensional neighbourhood preserving embedding [J]. *Pattern Recognition and Artificial Intelligence*, 2011, 24(6): 810-815. (in Chinese)
- [9] 杜海顺, 柴秀丽, 汪凤泉, 等. 一种邻域保持判别嵌入人脸识别方法[J]. 仪器仪表学报, 2010, 31(3): 625-629.
- DU H SH, CHAI X L, WANG F Q, *et al.*. Face recognition method using neighborhood preserving discriminant embedding [J]. *Chinese Journal of Scientific Instrument*, 2010, 31(3): 625-629. (in Chinese)
- [10] ANDREW B J, PANG Y H. Analysis on supervised neighborhood preserving embedding [J]. *IEICE Electronics Express.*, 2009, 6(23): 1631-1637.
- [11] HAN X H, CHEN Y W. A supervised nonlinear neighborhood embedding of color histogram for image indexing [C]. *IEEE International Conference on Image Processing (ICIP)*, San Diego, United States, 2008, 949-952.
- [12] 彭澄宇. 图像稀疏建模理论与应用研究[D]. 重庆: 重庆大学, 2012.
- PENG CH Y. *Image the sparse modeling theory and applied research* [D]. Chongqing: Chongqing University, 2012. (in Chinese)
- [13] INABA F K, SALLES E O T. Face recognition based on sparse representation and joint sparsity model with matrix completion [J]. *IEEE Latin America Transactions*, 2012, 10(1): 1344-1351.
- [14] YAN S C, XU D, ZHANG B Y, *et al.*. Graph embedding and extensions: a general framework for dimensionality reduction [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(1): 40-51.
- [15] QIAO L S. Sparsity preserving projections with applications to face recognition [J]. *Pattern Recognition*, 2010, 43(1): 331-341.
- [16] LU G F, JIN Z, ZOU J. Face recognition using discriminant sparsity neighborhood preserving embedding [J]. *Knowledge-Based Systems*, 2012, 31: 119-127.
- [17] REN G B, ZHANG J, MA Y. Generative model based semi-supervised learning method of remote sensing image classification [J]. *Journal of Remote Sensing*, 2010, 14(6): 1090-1104.
- [18] FAN M Y, QIAO H, ZHANG B. Discriminative sparsity preserving projections for semisupervised dimensionality reduction [J]. *IEEE Signal Processing Letters*, 2012, 19(7): 391-394.
- [19] 王立志, 黄鸿, 冯海亮. 基于 SSMFA 与 kNNS 算法的高光谱遥感影像分类[J]. 电子学报, 2012, 40(4): 780-787.
- WANG L ZH, HUANG H, FENG H L. Hyperspectral remote sensing image classification based on SSMFA and kNNS [J]. *Acta Electronica Sinica*, 2012, 40(4): 780-787. (in Chinese)
- [20] LANDGREBE D A. *Signal Theory Methods in Multispectral Remote Sensing* [M]. Hoboken, NJ: Wiley, 2003.

- [21] 于长淞,方超.基于小波变换的 ESPI 图像去噪及边缘提取[J].液晶与显示,2011,26(6):818-822.
YU CH S,FANG CH.ESPI image denoising and edge extraction based on wavelet transform[J].*Chinese Journal of Liquid Crystals and Displays*, 2011,26(6):818-822. (in Chinese)
- [22] 郑玉权.温室气体遥感探测仪器发展现状[J].中国光学,2011,4(6):546-561.

- ZHENG Y Q. Development status of remote sensing instruments for greenhouse gases [J]. *Chinese Optics*, 2011,4(6):449-560. (in Chinese)
- [23] 刘倩倩,郑玉权.超高分辨率光谱定标技术发展概况[J].中国光学,2012,5(6):566-577.
LIU Q Q,ZHENG Y Q. Development of spectral calibration technologies with ultra-high resolutions [J]. *Chinese Optics*, 2012,5(6):566-577. (in Chinese)

作者简介:



黄 鸿(1980—),男,湖南新宁人,博士,副教授,硕士生导师,2003年、2005年、2008年于重庆大学分别获得学士、硕士、博士学位,主要从事流形学习、模式识别、遥感影像智能化处理等方面的研究。E-mail: hhuang. cq@gmail.com



张满菊(1980—),女,江苏徐州人,学士,工程师,2003年于吉林大学获得学士学位,主要从事遥感影像图像智能化处理方向的研究。E-mail: 51682523@qq.com



杨 媚(1986—),女,广西岑溪人,硕士研究生,2009年于重庆大学获得学士学位,主要从事图像处理、模式识别、遥感影像分类等方面的研究。E-mail: yangmei0604@163.com

(版权所有 未经许可 不得转载)