

融合局部结构和差异信息的监督特征提取算法

高全学¹ 谢德燕¹ 徐辉¹ 李远征¹ 高西全¹

摘要 针对监督局部保持投影 (Supervised locality preserving projection, SLPP) 存在过学习和不能较好地保持图像空间的差异信息等问题, 造成算法性能不够好, 提出了一种新的基于流形学习的监督特征提取方法 (Supervised local structure and diversity projection, S-LSDP). S-LSDP 从信息统计量角度引入差异信息, 并给出度量差异信息大小的准则 (差异离散度) 及明确的物理含义; 然后通过最小化局部离散度和最大化差异离散度准则提取投影方向. 投影后的特征既能有效地保持图像之间的局部结构属性, 又能较好地保持图像之间的差异信息, 而且避免了过学习问题. 在 UMIST, Yale, PIE 和 AR 数据库上的实验结果表明了该算法的有效性.

关键词 特征提取, 流形学习, 局部离散度, 差异离散度, 人脸识别

DOI 10.3724/SP.J.1004.2010.01107

Supervised Feature Extraction Based on Information Fusion of Local Structure and Diversity Information

GAO Quan-Xue¹ XIE De-Yan¹ XU Hui¹ LI Yuan-Zheng¹ GAO Xi-Quan¹

Abstract Supervised locality preserving projection (SLPP) seeks to find the projection which efficiently preserves the local structure of data points embedded in high-dimensional data space. However, it has the over-learning problem and does not preserve the diversity information of data which is also useful for data recognition. A novel feature extraction method based on manifold learning, namely supervised local structure and diversity projection (S-LSDP), is presented to address this problem. The S-LSDP introduces the diversity of data points from the perspective of statistic and then calculates diversity scatter via the diversity of data points to measure the diversity information of data. A concise feature extraction criterion is raised by minimizing the local scatter, which efficiently preserves the local structure and simultaneously maximize the diversity scatter. Different from the most existing manifold learn methods, the S-LSDP not only preserves both the local structure and diversity information of data, but also avoids the data over-fitting problem. Extensive experiments in UMIST, Yale, PIE, and AR face database show the efficiency of the proposed method.

Key words Feature extraction, manifold learning, locality scatter, diversity scatter, face recognition

特征提取一直是模式识别、计算机视觉、机器学习等领域中不可避免的问题. 而如何从原始数据中得到有效的低维描述是研究者所关心的主要研究方向之一, 对此研究者提出了许多方法, 其中最经典且部分得到成功应用的方法是子空间分析法 (Subspace analysis method, SAM)^[1-2]. SAM 的思想是根据某种准则寻找投影方向, 使得投影后的特征便于后续分析, 如分类. SAM 中最为经典的技术是主成分分析 (Principal component analysis, PCA) 和线判别分析 (Linear discriminant analysis, LDA), 其中, PCA 是描述模式的典型代表技术,

LDA 是分类模式的典型代表, 它们都被广泛地应用到特征提取的相关领域, 特别是生物特征识别^[1, 3-5].

PCA 是基于最小均方误差的无监督特征提取方法, 而 LDA 是通过最大化类间离散度, 同时最小化类内离散度寻找最优投影方向, 属于有监督的特征方法. 利用两种技术识别人脸, Turk 等^[4] 和 Belhumeur 等^[5] 分别提出了经典的 Eigenface 和 Fisherface 算法, 取得了较好的识别性能, 加速了子空间分析的研究和进展. 但是, 这两种技术仅保存了模式的全局欧氏距离结构, 即模式的全局结构属性, 适用于线性可分情况. 而研究表明^[6-9]: 1) 许多自然界获取的图像, 特别是人脸图像因光照、姿势、表情等变化, 使得图像线性不可分; 2) 人脸图像位于隐藏在图像高维空间的非线性流形结构上. 这些因素使得这两种技术不能较好地提取出模式的内在结构, 导致识别率比较低.

最近, 利用基于视觉的几何方法 (也叫流形学习) 进行模式分析已引起研究者的关注和重视, 典型的代表有 Isomap^[6], Local linear embedding^[8], 和

收稿日期 2009-04-01 录用日期 2009-11-04
Manuscript received April 1, 2009; accepted November 4, 2009
国家自然科学基金 (60802075, 60872141), 综合业务网理论及关键技术国家重点实验室自主研究课题 (ISN090403), 高等学校学科创新引智计划 (B08038) 资助

Supported by National Natural Science Foundation of China (60802075, 60872141) and the State Key Laboratory of Integrated Services Networks (ISN090403), and the 111 Project (B08038)

1. 西安电子科技大学通信工程学院 西安 710071
1. School of Communication Engineerings, Xidian University, Xi'an 710071

Laplacian eigenmap^[9], 在实验数据上取得了令人瞩目的结果, 但是所提取的映射关系仅建立在训练数据上, 对如何估计测试数据的映射不清楚, 导致在计算机视觉和模式识别领域应用的比较少. 对此问题, He 等^[10] 将 Laplacian eigenmap 近似线性化, 提出了局部保持投影 (Locality preserving projection, LPP). 该算法有效地保持了图像之间的局部结构, 在模式识别、文档分析等方面取得了较好的结果, 引起了研究者的关注^[11-14]. 然而该方法并没有利用图像类别信息, 导致在光照、姿态、表情变化较大时识别性能不是足够的好. 对此问题, 人们提出了有监督的 LPP 算法^[10, 15-17], 取得了不错的效果, 典型的代表有 Supervised LPP (SLPP)^[10] 和 Locally discriminating projection (LDP)^[17]. 但是这类方法在保持图像之间的局部结构时, 忽略了图像之间的非局部属性^[13] 和图像之间的总体信息, 导致识别性能不够好. 另外一个缺点是, 该类方法通过惩罚因子最小化局部离散度时, 使得邻域内的样本投影后比较接近, 当邻域内的样本过于接近时, 容易造成邻域内样本之间的差异信息丢失, 即过学习问题.

针对上述问题, 提出一种基于流形学习的特征提取算法——有监督的局部结构和差异信息投影 (Supervised local structure and diversity information projection, S-LSDP). 该算法从信息统计角度引入差异信息, 并给出度量差异离散度的准则及物理含义, 然后通过最大化差异离散度和最小化局部离散度准则寻找投影方向, 使得投影后的特征既能很好地保持图像之间的局部结构属性, 又能较好地保持图像之间的差异信息, 也有效地避免了过学习问题. 在 PIE, AR, UMIST 和 Yale 数据库上的实验结果表明了所提算法的有效性和正确性.

1 SLPP

给定 N 个训练图像集 $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, 其中, $\mathbf{x}_i \in \mathbf{R}^m$ 代表第 $i = 1, \dots, N$ 个训练图像向量. SLPP 的目的是寻找一个投影方向 \mathbf{w} 使得下式最小

$$J(\mathbf{w}) = \frac{\mathbf{w}^T X L X^T \mathbf{w}}{\mathbf{w}^T X D X^T \mathbf{w}} \quad (1)$$

其中, 分子 $\mathbf{w}^T X L X^T \mathbf{w}$ 代表样本的局部离散度, $L = D - S$ 是拉普拉斯矩阵, 度量了图像之间局部结构属性, S 是一个实对称矩阵, 度量了不同图像之间的相似性, 定义如下:

$$S_{ij} = \begin{cases} \exp\left(\frac{-\|\mathbf{x}_i - \mathbf{x}_j\|^2}{t}\right), & \mathbf{x}_i \in \tau_i, \mathbf{x}_j \in \tau_j, \\ & \tau_i = \tau_j, \mathbf{x}_i \in \Omega_{\mathbf{x}_j}^k \text{ 或 } \mathbf{x}_j \in \Omega_{\mathbf{x}_i}^k \\ 0, & \text{其他} \end{cases} \quad (2)$$

其中, S_{ij} 代表 S 的第 i 行第 j 列的元素. $\Omega_{\mathbf{x}_i}^k$ 代表 \mathbf{x}_i 的 k 邻域. D 是一个对角矩阵, 第 i 行第 i 列的元素 $D_{ii} = \sum_j S_{ij}$.

SLPP 通过最小化 (1) 来保持图像之间的局部结构属性, 即相似性. 但在式 (1) 中, 分母的物理意义并不清楚. 为了分析方便, 分母展开可写成

$$\mathbf{w}^T X D X^T \mathbf{w} = \mathbf{w}^T \left[\sum_i D_{ii} \mathbf{x}_i \mathbf{x}_i^T \right] \mathbf{w} \quad (3)$$

式 (3) 表明, 式 (1) 的分母是训练图像的加权离散度, D_{ii} 是相应图像的加权系数, 表征该图像的贡献大小; 当训练图像的均值为 0 时, 分母则是训练图像加权总体离散度.

由式 (2) 知, 当 \mathbf{x}_i 和 \mathbf{x}_j 在图像空间相距很近时, S_{ij} 就越大; 如果 \mathbf{x}_i 与其 k 邻域内的所有图像在图像空间分布都比较近 (分布紧凑), 则由式 (2) 和式 (3) 知, D_{ii} 的值就越大. 它意味着图像 \mathbf{x}_i 的贡献就越大, 反之, 贡献就越小. 然而, 从信息统计角度看, 如果任意两个图像在图像空间分布比紧凑, 即欧氏距离比较小, 则两个图像所提供的差异信息就减少, 因此一个图像相对于另外一个图像提供的差异信息就减少, 相应的贡献就小. 同样, 如果一个图像与库中的几个图像在图像空间分布都比较紧凑, 则它对图像库总体的贡献就比较小, 加权系数也就比较小. 显然, 这与 D_{ii} 和 S_{ij} 的定义正好相反, 因此 SLPP 不能有效地保持图像空间的差异信息, 导致分类性能不是足够的好.

分子 $\mathbf{w}^T X L X^T \mathbf{w}$ 代表了图像空间的局部离散度, 通过最小化局部离散度, 使得邻域内的任意两个图像 $\mathbf{x}_j \in \Omega_{\mathbf{x}_i}^k$ 和 $\mathbf{x}_i \in \Omega_{\mathbf{x}_j}^k$, 投影后的相应特征 y_i 和 y_j 也比较接近. 当投影后的特征过于接近, 甚至重合到一个点时, 容易造成邻域内图像之间的差异信息丢失, 不利于分类, 造成所谓的过学习问题. 针对此问题, 本文第 2 节给出了一种新的有监督特征提取算法.

2 S-LSDP

2.1 思想

如上所述, SLPP 在保持图像之间的局部结构时, 不能有效地保持图像之间的差异信息以及存在

过学习问题, 使得分类性能不够好. 对此问题, 从信息统计角度出发, 引入度量图像差异的权值, 并给出度量差异离散度的模型和物理含义, 然后借助局部离散度的定义, 建立了一个简单、物理意义明确的特征提取准则. 该准则通过最大化差异离散度, 同时最小化局部离散度提取投影方向, 使得投影后的特征既有效地保持了图像之间的局部结构属性, 又能较好地保持图像之间的差异信息. 由于图像受光照、表情、姿势等变化, 使得同类图像之间的距离大于不同类图像之间的距离, 导致离散度所保存的局部结构不能有效地区分开不同类之间的图像, 因此在度量局部离散度时, 需要考虑图像类别信息, 即监督的局部离散度.

2.2 局部离散度

给定 N 个训练图像集 $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, 其中, $\mathbf{x}_i \in \mathbf{R}^m$ 代表第 $i = 1, \dots, N$ 个训练图像向量. 假定 \mathbf{x}_i 和 \mathbf{x}_j 在原始图像空间相距很近, 如果投影后的特征 y_i 和 y_j 也相距很近, 即距离很小, 则图像空间的局部结构属性得到了很好地保持. 图像空间的局部结构属性可通过局部离散度 S_L 度量^[10].

$$S_L = \sum_{i,j=1}^N (y_i - y_j)^2 S_{ij} \quad (4)$$

其中, $y_i = \mathbf{w}^T \mathbf{x}_i$, \mathbf{w} 代表投影方向. S_{ij} 刻画了样本 \mathbf{x}_i 和 \mathbf{x}_j 的空间相似性, 定义如下

$$S_{ij} = \begin{cases} \exp\left(\frac{-\|\mathbf{x}_i - \mathbf{x}_j\|^2}{t}\right), & \mathbf{x}_i \in \tau_i, \mathbf{x}_j \in \tau_j, \\ & \tau_i = \tau_j, \\ & \|\mathbf{x}_i - \mathbf{x}_j\|^2 < \varepsilon \\ 0, & \text{其他} \end{cases} \quad (5)$$

ε 是一个足够小的正数, 刻画了图像空间的局部结构属性, t 是一个常数. 如果投影后的特征相距较远 (分布稀疏), 则破坏了嵌入在图像空间的局部结构属性. 为了很好地保持局部结构属性, 需要通过较大的惩罚因子 (权值) S_{ij} 使得 y_i 和 y_j 之间的距离尽可能的小. 即最小化图像空间的局部离散度

$$\min \sum_{i,j=1}^N (y_i - y_j)^2 S_{ij} \quad (6)$$

这就是式 (5) 和 (6) 的物理含义.

把 $y_i = \mathbf{w}^T \mathbf{x}_i$ 代入式 (6), 展开可写成

$$\sum_{i,j=1}^N (y_i - y_j)^2 S_{ij} =$$

$$\begin{aligned} & \sum_{i,j=1}^N (\mathbf{w}^T \mathbf{x}_i - \mathbf{w}^T \mathbf{x}_j)^2 S_{ij} = \\ & 2 \left[\sum_{i,j=1}^N \mathbf{w}^T \mathbf{x}_i S_{ij} \mathbf{x}_i^T \mathbf{w} - \sum_{i,j=1}^N \mathbf{w}^T \mathbf{x}_i S_{ij} \mathbf{x}_j^T \mathbf{w} \right] = \\ & 2 [\mathbf{w}^T X D X^T \mathbf{w} - \mathbf{w}^T X S X^T \mathbf{w}] = \\ & 2 [\mathbf{w}^T X (D - S) X^T \mathbf{w}] = \\ & 2 \mathbf{w}^T X L X^T \mathbf{w} \end{aligned} \quad (7)$$

其中, D 是一个对角矩阵, $D_{ii} = \sum_i S_{ij}$ 或 $\sum_j S_{ij}$ 令 $G_L = X L X^T$, 则 G_L 称为模式的局部离散矩阵. 实际应用中, ε 参数很难选取, 为了方便应用, S_{ij} 可按式 (2) 定义.

把式 (7) 代入式 (6), 则最小化局部离散度可写成

$$J_{LP} = \min \mathbf{w}^T X L X^T \mathbf{w} \quad (8)$$

式 (8) 有效地保持了图像空间的局部结构属性, 但是, 从信息统计角度分析, 当投影后的特征相距很近时, 式 (8) 提取的特征很相似, 即共性特性. 显然其忽略了样本之间的差异属性, 不利于分类, 造成过学习问题. 对此问题, 第 2.3 节引入度量样本差异信息的差异离散度.

2.3 差异离散度

如上所述, 最小化局部离散度不能有效地保持样本之间的差异信息, 导致分类性能不是很好. 对此, 从信息统计角度出发, 引入局部差异离散度 G_{Np}

$$G_{Np} = \sum_{i,j=1}^N (y_i - y_j)^2 B_{ij} \quad (9)$$

其中, B_{ij} 刻画了图像空间中 \mathbf{x}_i 相对于 \mathbf{x}_j 对统计信息贡献的大小, 定义如下:

$$B_{ij} = \begin{cases} \exp\left(\frac{-b}{\|\mathbf{x}_i - \mathbf{x}_j\|^2}\right), & \mathbf{x}_i \in \Omega_{\mathbf{x}_j}^{k_1} \text{ 或} \\ & \mathbf{x}_j \in \Omega_{\mathbf{x}_i}^{k_1} \\ 0, & \text{其他} \end{cases} \quad (10)$$

b 是一个正数. 此外, 也可以根据 ε 确定邻域. B_{ij} 的取值, 根据以下事实:

1) 从信息统计角度出发, 如果两个样本 \mathbf{x}_i 和 \mathbf{x}_j 在空间分布相距很近, 即 \mathbf{x}_i 和 \mathbf{x}_j 之间的几何距离很小, 则它们两个所提供的差异信息就很少, 即 \mathbf{x}_i 相对于 \mathbf{x}_j 的贡献就越小, 因此权值 B_{ij} 比较小.

2) 实际中要求训练样本尽可能地反映模式的不同状态, 如姿势、光照、表情以及装饰物等, 这样的样本称为好样本, 对模式的统计属性具有较大的贡

献, 权值 B_{ij} 应该比较大. 但此时, 样本空间分布比较稀疏, 即 \mathbf{x}_i 和 \mathbf{x}_j 之间的距离比较大.

3) 自然图像大都位于隐藏在图像空间的非线性流形结构上, 因此, 图像与在其 $k-1$ 邻域外任意一个图像之间的欧氏距离, 不能够反映图像空间的本质结构, 故在邻域外取 0.

如果相距比较远的两个样本 \mathbf{x}_i 和 \mathbf{x}_j , 投影后的特征 y_i 和 y_j 相距很近, 则图像空间中的差异信息损失就比较大. 为了很好地保持图像空间的差异信息, 提高分类性能, 则需要通过加大权值 (惩罚因子) B_{ij} 来最大化差异离散度, 即

$$\max \sum_{i,j=1}^N (y_i - y_j)^2 B_{ij} \quad (11)$$

式 (11) 的物理含义就是使投影后的特征能最大限度地保持样本间的差异信息.

把 $y_i = \mathbf{w}^T \mathbf{x}_i$ 代入式 (11), 并展开可写成

$$\begin{aligned} \sum_{i,j=1}^N (y_i - y_j)^2 B_{ij} &= \\ \sum_{i,j=1}^N (\mathbf{w}^T \mathbf{x}_i - \mathbf{w}^T \mathbf{x}_j)^2 B_{ij} &= \\ 2 \left[\sum_{i,j=1}^N \mathbf{w}^T \mathbf{x}_i B_{ij} \mathbf{x}_j^T \mathbf{w} - \sum_{i,j=1}^N \mathbf{w}^T \mathbf{x}_i B_{ij} \mathbf{x}_j^T \mathbf{w} \right] &= \\ 2 [\mathbf{w}^T X \bar{D} X^T \mathbf{w} - \mathbf{w}^T X B X^T \mathbf{w}] &= \\ 2 [\mathbf{w}^T X (\bar{D} - B) X^T \mathbf{w}] &= \\ 2 \mathbf{w}^T X \bar{L} X^T \mathbf{w} \end{aligned} \quad (12)$$

其中, \bar{D} 是对角矩阵, $\bar{D}_{ii} = \sum_i B_{ij}$ 或 $\sum_j B_{ij}$. B 是一个实对称方阵, B_{ij} 代表方阵 B 第 i 行第 j 列的元素. $G_N = X \bar{L} X^T$ 称为样本的局部差异离散矩阵.

2.4 特征提取准则及分类

S-LSDP 的思想是寻找一个投影方向 \mathbf{w} , 使得投影后的特征不仅有效地保持了图像空间的局部结构属性, 而且最大限度地保持了样本的信息 (差异信息). 结合第 2.2 节和第 2.3 节知, S-LSDP 的特征提取准则如下.

$$J(\mathbf{w}) = \arg \min_{\mathbf{w}^T \mathbf{w}=1} \frac{\mathbf{w}^T G_L \mathbf{w}}{\mathbf{w}^T G_N \mathbf{w}} \quad (13)$$

分子和分母的含义分别如第 2.2 节和第 2.3 节所述. 式 (13) 是一个典型的瑞利商, 由于在计算时, 考虑了样本的类别信息. 因此, 所提算法属于有监督的特征提取方法.

假定 G_N 是可逆的, 则最佳投影方向就是广义特征方程 $G_L \mathbf{w} = \lambda G_N \mathbf{w}$ 最小非零特征值对应的特征向量 \mathbf{w} . 在实际应用中, 一般要选择多个投影方向. 假定 $W \in \mathbf{R}^{m \times n}$ 代表投影矩阵, $d \leq m$ (一般远远小于 m). 则 W 是由前 d 个最小非零特征值对应的特征向量组成, 且满足

$$\mathbf{w}_i^T \mathbf{w}_j = \begin{cases} 0, & i \neq j \\ 1, & i = j \end{cases} \quad (14)$$

当 G_N 不可逆时, 求解方法很多, 经典方法如文献 [5], 不再阐述.

给定任意一个训练图像向量 \mathbf{x}_i , S-LSDP 算法提取的特征为 $y_i = W^T \mathbf{x}_i$. 类似地, 给定任意一个测试图像向量 \mathbf{x}^* , 向 W 投影后的特征为 $y^* = W^T \mathbf{x}^*$.

测试图像的分类可通过度量测试样本投影后的特征与训练图像投影后的特征的相似性来实现. 一般使用比较多的相似性度量准则有欧氏距离, 夹角余弦, 马氏距离, L-1 范数等. 这里以欧氏距离为例说明如何实现分类. 假定 y^* 和 y_i 的欧氏距离为

$$d(\mathbf{x}_i, \mathbf{x}^*) = \|y^* - y_i\|_2 \quad (15)$$

如果

$$d(\mathbf{x}_k, \mathbf{x}^*) = \min_i (d(\mathbf{x}_i, \mathbf{x}^*)) \quad (16)$$

则认为 \mathbf{x}_k 和 \mathbf{x}^* 属于同一类.

2.5 算法总结

应用 S-LSDP 识别模式的步骤总结如下:

步骤 1. 获取训练样本集 $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, N 代表训练样本的个数, $\mathbf{x}_i \in \mathbf{R}^m$ 代表第 i ($i = 1, \dots, N$) 个图像向量.

步骤 2. 计算局部离散矩阵 G_L . 利用式 (5) 和 (7) 计算训练样本的局部离散矩阵, 度量了图像之间的局部结构属性, 即相似性.

步骤 3. 计算差异离散矩阵 G_N . 利用式 (10) 度量样本间的差异信息, 然后利用式 (12) 计算样本的差异离散矩阵 G_N , 有效地度量了样本之间的差异信息.

步骤 4. 提取投影矩阵 W . 利用式 (13) 和 (14) 提取 S-LSDP 的投影矩阵 W .

步骤 5. 特征提取及分类. 将样本和测试图像向 W 张成的空间投影, 即可获得对应的特征, 然后根据式 (15) 度量特征之间的相似度, 最后利用式 (16) 进行分类, 实现测试图像的分类.

3 实验及结果

实验以人脸识别来评价所提算法 S-LSDP 的性能. 实验分别选用 Yale, UMIST, PIE 及 AR 人脸数

数据库进行分析, 并和经典的特征提取方法如 PCA^[5], LPP^[10], UDP^[13], SLPP^[10] 和 LDP^[17] 相比较. 实验中, 用欧氏距离度量相似度, 选用最近邻分类器进行分类.

3.1 Yale 库上的实验结果

Yale 数据库 (<http://cvc.yale.edu/projects/yalefaces/yalefaces.html>) 是由耶鲁大学计算机视觉与控制中心创建. 该数据库由 15 人组成, 共 165 幅灰度图像. 每个人含有不同光照、表情、姿态等共 11 张图像. 实验中, 每张图片通过手动裁剪扣取面部图像, 并归一化成 32 像素 × 32 像素^[10].

实验分别选取每个人的前 6、9 张图像用于训练, 相应的剩余图像构成测试图库. 即两个训练图库分别包含 90 和 135 个图像, 对应的两个测试图库分别包含 75 和 30 个图像. 分别选用 PCA, LPP, UDP, LDP, SLPP 和 S-LSDP 提取特征, 利用欧氏距离度量相似度和最近邻准则分类. 需要说明的是, 在 LPP, UDP, LDP, SLPP 和 S-LSDP 中, 都涉及参数选择问题, 由于至今为止还无法从理论上给出最优选择, 因此参数选择是公认的难题, 为了更好地评价几种算法的性能, 实验通过在区间 $[0, +\infty]$ 上多次改变参数, 选择出各自算法对应的最佳识别率. 后续实验中, 参数选择方法一样, 除非另有说明. 表 1 给出了几种算法的最高识别率, 括号内为对应的特征个数. 图 1 给出了训练样本数/测试样本数为 90/75 时, 几种算法的识别率随特征个数变化的曲线.

由表 1 和图 1 可知, 有以下几点结论: 1) 在欧氏距离度量下, 基于流形学习的特征提取方法的最高识别率比经典的特征提取方法 PCA 要好, 这主要是因为人脸图像受光照、表情等变化, 导致人脸图像是非线性不可分, 使得 PCA 所保存的全局欧氏距离不能有效地反映出图像空间的内在结构; 而基于流形学习的特征提取方法通过局部 k 邻域有效地保存

了隐藏在图像空间的局部结构, 很好地反映了图像空间分布的内在属性. 2) 在最优参数选择下, 有监督的特征提取方法 (SLPP、LDP、S-LSDP) 总体上比无监督方法 (PCA、LPP、UDP) 要好, 主要是因为图像受外在变化的影响, 如表情、光照等, 导致不同类图像之间的距离比同类图像之间的距离小, 使得无监督特征提取方法所保存的局部属性不能有效地区分开不同类的图像; 相反, 监督特征提取方法由于考虑了图像的类别信息, 因此有效地避免了这个缺点. 3) 所提算法 S-LSDP 的识别率明显好于其他几种有监督的流形学习算法, 在训练个数为 135 时, 提高了将近 4%. 这主要是因为, 流形学习利用类别信息和 k 邻域保存隐藏在图像空间的局部内在结构属性 (即相似性) 时, 丢失了有利于分类的差异信息; 而所提算法 S-LSDP 不仅保持了流形学习的优点, 即局部结构属性, 而且利用另外一个局部 k_1 邻域, 对图像空间进行了压缩, 有效地保存了隐藏在图像空间的差异信息 (总体信息), 同时避免了已有监督特征提取算法存在的过学习问题.




图 1 6 种算法在 Yale 数据库上的识别曲线
Fig. 1 The curves of recognition accuracy of six methods in Yale database

表 1 6 种算法在 Yale 数据库上的最高识别率 (%) (括号中为相应的特征维数)

Table 1 The top recognition accuracies of six methods in Yale database (%) (The values in parentheses are the corresponding numbers of features.)

训练/测试个数	PCA	LPP	UDP	LDP	SLPP	S-LSDP
90/75	66.67 (13)	69.33 (15)	70.67 (24)	69.33 (17)	81.33 (8)	82.67 (15)
135/30	86.67 (46)	96.67 (24)	86.67 (35)	93.33 (8)	96.67 (13)	100.00 (14)

表 2 6 种算法在 UMIST 数据库上的最高识别率 (%) (括号中为相应的特征维数)

Table 2 The top recognition accuracies of six methods in UMIST database (%) (The values in parentheses are the corresponding numbers of features.)

训练/测试个数	PCA	LPP	UDP	LDP	SLPP	S-LSDP
120/260	58.85 (46)	82.69 (10)	76.15 (52)	82.69 (13)	85.77 (9)	87.31 (11)
180/200	65.00 (48)	88.00 (10)	79.50 (62)	88.00 (8)	90.00 (8)	91.50 (16)

3.2 UMIST 库上的实验结果

UMIST 人脸库 (<http://images.ee.umist.ac.uk/danny/database.html>) 是由英国曼彻斯特大学创建的. 该数据库包括 20 人的 564 张人脸灰度图片, 每人 19~48 幅不等. 实验选用 UMIST 的子库进行分析. 该子库由 20 人组成, 每个人含有 19 张不同姿势的照片, 共 380 张, 分辨率为 112 像素 × 92 像素.

实验分别选取每人前 6、9 张图片构成训练库, 即两个训练库分别包含 120、180 个图像, 对应的余下图像构成测试图库 (两个测试图库分别包含 260 和 200 个图像). 表 2 给出了 6 种算法的最佳识别率, 括号内的数字为对应的特征个数. 选择每个人前 6 张图片用于训练, 剩余图像用于测试时, 图 2 给出了 6 种算法的识别率与特征个数的变化曲线. 从表 2 和图 2 可知以下结论: 1) 基于流形学习的特征提取方法明显比经典特征提取方法 PCA 要好, 尤其在训练样本比较少的情况下; 相比 Yale 数据库的实验结果, 流形学习算法的识别率提高很明显. 对比两个数据发现, 在 UMIST 数据库上, 测试图库和训练图库差别比较大, 因此基于流形学习的特征算法具有高识别率的原因可能是, 姿势变化导致人脸图像的非线性分布比较明显, 使得 PCA 保存的全局欧氏距离结构不能有效地体现出图像分布的内在属性, 而基于流形学习的特征提取方法通过局部离散度有效地避免了这个问题. 2) 有监督的特征提取方法比无监督的特征方法好, 原因是姿势变化导致同类图像之间的距离变化比较大, 而非同类图像之间的距离相对比较小, 使得无监督的特征提取方法所保存的局部结构不能较好地分离不同类之间的图像. 3) S-LSDP 的最高识别率明显好于其他有监督的特征提取方法, 在训练样本个数比较少的情况下尤其明显. 除了在 Yale 数据上所提到的原因外, 另外一个原因可能是人脸图像的非线性分布比较明显, 导致已有基于监督的流形学习算法丢失了较多图像之间的差异信息; 而 S-LSDP 算法所保存的差异信息对分类则起到相对重要的作用. 这也说明, S-LSDP 算法对外在变化具有较好的鲁棒性.

3.3 PIE 库上的实验结果

PIE 人脸库^[18] 为美国卡耐基梅隆大学于 2000 年 11 月建立, 由 68 个人的 40000 幅图像组成, 其中包括了 13 种姿态条件、43 种光照条件和 4 种表情下的照片. 实验选择 Pose29 子图库进行分析. 该库包含 68 个人, 每个人由不同光照、表情下的 24 幅图像组成, 且每幅图像均由手动裁减扣取面部图像, 大小为 64 像素 × 64 像素. 实验选择每个人的前 12 幅图像作为训练库, 其余 12 幅图像进行测试.

表 3 给出了 6 种算法的最佳识别率和对应的特征个数, 图 3 给出了 6 种算法的识别率随特征个数变化的曲线.




图 2 6 种算法在 UMIST 数据库上的识别曲线
Fig. 2 The curves of recognition accuracies of six methods in UMIST database




图 3 6 种算法在 PIE 数据库上的识别曲线
Fig. 3 The curves of recognition accuracies of six methods in PIE database

由表 3 和图 3 可知, 流形学习算法明显比 PCA 要好, 提高了至少 36%, 虽然该图库和 Yale 数据一样, 主要是由光照引起的变化, 但是该图库光照变化比 Yale 数据库明显, 导致人脸图像的非线性分布相对比较明显, 因此在该数据上, 基于流形学习的特征提取算法的识别率明显很高, 这说明流形学习对光照变化具有好的鲁棒性. 有监督的特征提取算法 LDP 和 SLPP 没有无监督的 LPP 和 UDP 好, 这可能是因为 LDP 和 SLPP 在监督下, 造成图像之间的差异信息丢失很大; UDP 比有监督的 SLPP 和 LDP 的识别率高, 主要原因可能是 UDP 所考虑的非局部离散度起到了较好的作用. 在所有算法中, S-

表 3 6 种算法在 PIE 数据库上的最高识别率 (%) 及对应的特征个数

Table 3 The top recognition accuracies of six methods and corresponding numbers of features in PIE database (%)

算法	PCA	LPP	UDP	LDP	SLPP	S-LSDP
识别率	53.43	91.67	94.24	91.18	85.91	95.59
特征个数	89	97	136	135	79	100

表 4 6 种算法在 AR 数据库上的最高识别率 (%) 及对应的特征个数

Table 4 The top recognition accuracies of six methods and corresponding numbers of features in AR database (%)

算法	PCA	LPP	UDP	LDP	SLPP	S-LSDP
识别率	66.55	66.90	67.26	66.55	69.64	69.76
特征个数	168	84	152	55	119	118

LSDP 的识别率最高, 主要是因为所提算法很好地保持了有利于分类的差异信息, 和上述实验结果一致; 和 UDP 相比, S-LSDP 的识别率要高, 主要是因为 UDP 同样不能有效地保持图像之间的差异信息.

3.4 AR 库上的实验结果

AR 人脸数据库 (<http://rv11.ecn.purdue.edu/~aleix/aleix-face-DB.html>) 库包括 120 个人, 每个人由不同光照、表情、遮挡的 26 张人脸图像组成, 共 3120 张. 其中, 每个人的前 13 张是由第一时期采集的, 后 13 张由第二时期采集, 时间间隔 1 个月, 且照片排列相互对应. 实验中, 每张图片通过手动裁剪扣取面部图像, 并归一化成大小为 50 像素 \times 40 像素. 选取每个人的前 7 张图像作为训练样本, 第二时期对应的 7 张人脸图像作为测试样本. 图 4 给出了几种算法的识别率与特征个数的变化曲线. 表 4 给出了几种算法的最高识别率与对应的特征个数. 由图 4 和表 4 可知, 基于流形学习的特征提取算法比 PCA 好; 有监督的特征提取算法总体上比无监督的要好; 在 6 种算法中, S-LSDP 的识别率最高. 和有监督的流形学习算法 LDP 相比, S-LSDP 提高了 3%, 缺点是特征个数比较多; 和 SLPP 相比, S-LSDP 提高了 0.12%, 特征个数略少, 与上述实验结论总体上一致. 由图 4 知, 当特征个数大于 100 时, 所提算法的性能比较好.

4 结论

通过引入局部差异离散度, 并借助流形学习的思想, 提出了一种有监督的特征提取算法 — S-LSDP. 该算法通过最小化局部离散度和最大化差异离散度准则提取投影方向. 和经典的基于流形学习的算法相比, S-LSDP 不仅有效地保持了隐藏在图像空间的非线性流结构上的局部结构属性, 而且有

效地保持了局部图像之间的差异信息, 同时避免了过学习问题. 在 Yale, UMIST, PIE 及 AR 人脸库上的实验结果表明了 S-LSDP 算法的有效性.

如前所述, 上述提到的流形学习算法是通过局部线性近似实现特征提取, 而如何从理论上定义局部性仍然是一个难题, 即如何选择参数, 使得算法具有稳定的性能, 以及如何有效地利用局部结构属性 (即相似性) 和差异性, 是我们今后需要重点研究的问题.





图 4 6 种算法在 AR 数据库上的识别曲线
Fig. 4 The curves of recognition accuracies of six methods in AR database


References

- 1 Yan S C, Xu D, Zhang B, Zhang H, Yang Q, Lin S. Graph embedding and extensions: a general framework for dimensionality reduction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, **29**(1): 40–51
- 2 Liu Qing-Shan, Lu Han-Qing, Ma Song-De. A survey: subspace analysis for face recognition. *Acta Automatica Sinica*, 2003, **29**(6): 900–911
(刘青山, 卢汉清, 马颂德. 综述人脸识别中的子空间方法. *自动化学报*, 2003, **29**(6): 900–911)


- 3 Murase H, Nayar S K. Visual learning and recognition of 3-D objects from appearance. *International Journal of Computer Vision*, 1995, **14**(1): 5–24
- 4 Turk M A, Pentland A P. Face recognition using eigenfaces. In: *Proceedings of the Conference on Computer Vision and Pattern Recognition*. Hawaii, USA: IEEE, 1991. 586–591
- 5 Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs fisherfaces: recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, **19**(7): 711–720
- 6 Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction. *Science*, 2000, **290**(5500): 2319–2323
- 7 Seung H S, Lee D D. The manifold ways of perception. *Science*, 2000, **290**(5500): 2268–2269
- 8 Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 2000, **290**(5500): 2323–2326
- 9 Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation. *Neural Computation*, 2003, **15**(6): 1373–1396
- 10 He X F, Yan S C, Hu Y, Niyogi P, Zhang H. Face recognition using Laplacianfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, **27**(3): 328–240
- 11 Cai D, He X F, Han J W. Document clustering using locality preserving indexing. *IEEE Transactions on Knowledge and Data Engineering*, 2005, **17**(12): 1624–1637
- 12 Hu D W, Feng G Y, Zhou Z. Two-dimensional locality preserving projections (2DLPP) with its application to palmprint recognition. *Pattern Recognition*, 2007, **40**(1): 339–342
- 13 Yang J, Zhang D, Yang J, Niu B. Globally maximizing, locally minimizing: unsupervised discriminant projection with applications to face and palm biometrics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, **29**(4): 650–664
- 14 Deng W, Hu J, Guo J, Zhang H, Zhang C. Comments on “globally maximizing, locally minimizing: unsupervised discriminant projection with application to face and palm biometrics”. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008, **30**(8): 1503–1504
- 15 Jin Y, Ruan Q Q. An image matrix compression based supervised locality preserving projections for face recognition. In: *Proceedings of the International Symposium on Intelligent Signal Processing and Communication Systems*. Xiamen, China: IEEE, 2007. 738–741
- 16 Zhang Zhi-Wei, Yang Fan, Xia Ke-Wen, Yang Rui-Xia. A supervised LPP algorithm and its application to face recognition. *Journal of Electronics and Information Technology*, 2008, **30**(3): 539–541
(张志伟, 杨帆, 夏克文, 杨瑞霞. 一种有监督的 LPP 算法及其在人脸识别中的应用. *电子与信息学报*, 2008, **30**(3): 539–541)
- 17 Zhang H, Sun S, Jing Z, Yang J Y. Local structure based supervised feature extraction. *Pattern Recognition*, 2006, **39**(8): 1546–1550
- 18 Sim T, Baker S, Bsat M. The CMU pose, illumination, and expression (PIE) database. In: *Proceedings of the 5th International Conference on Automatic Face and Gesture Recognition*. Washington D. C., USA: IEEE, 2002. 53–57



高全学 西安电子科技大学副教授。2005 年获得西北工业大学自动化学院博士学位。主要研究方向为统计模式识别, 机器学习, 人脸识别。本文通信作者。
E-mail: qxgao@xidian.edu.cn
(GAO Quan-Xue Associate professor at the School of Communication Engineering, Xidian University. He received his Ph.D. degree at the College of Automation, the Northwestern Polytechnical University in 2005. His research interest covers statistical pattern recognition, machine learning, and face recognition. Corresponding author of this paper.)



谢德燕 西安电子科技大学硕士研究生。2007 年获得鲁东大学学士学位。主要研究方向为通信信号处理, 数字信号处理, 人脸识别。E-mail: xdy0306@163.com
(XIE De-Yan Master student at Xidian University. She received her bachelor degree from Ludong University in 2007. Her research interest covers communication signal processing, digital signal processing, and face recognition.)



徐辉 西安电子科技大学硕士研究生。2007 年获得合肥学院学士学位。主要研究方向为数字信号处理, 人脸识别。
E-mail: haxhuiily@yahoo.cn
(XU Hui Master student at Xidian University. He received his bachelor degree from Hefei University in 2007. His research interest covers digital signal processing and face recognition.)



李远征 西安电子科技大学博士研究生。主要研究方向为视觉目标跟踪, 智能视频监控, 模式识别。
E-mail: liyuanzheng@tom.com
(LI Yuan-Zheng Ph. D. candidate at Xidian University. Her research interest covers visual object tracking, intelligent video surveillance, and pattern recognition.)



高西全 西安电子科技大学教授。主要研究方向为通信信号处理, 数字信号与数字图像处理。
E-mail: xqgao@mail.xidian.edu.cn
(GAO Xi-Quan Professor at Xidian University. His research interest covers communication signal processing, digital signal processing, and digital image processing.)