

基于拉普拉斯方向的差值线性判别分析

李照奎^{1,2} 丁立新¹ 王岩² 何进荣¹ 周凌云¹

(武汉大学软件工程国家重点实验室 武汉大学计算机学院 武汉 430072)¹

(沈阳航空航天大学计算机学院 沈阳 110136)²

摘要 标准的LDA方法通常有3个问题:1)为了确保类内散度矩阵的非奇异性,必须首先通过PCA进行维数约简,这限制了对更多维数空间的使用;2)当每人只有单个训练样本时,类内散度矩阵必然奇异,此时LDA无法工作;3)缺乏对像素间的局部相关性的考虑。为了解决这些问题,提出一种基于拉普拉斯方向的差值线性判别分析方法。该方法通过拉普拉斯方向实现更鲁棒的图像相异性测度,通过引入差值散度矩阵来避免类内散度矩阵的奇异性。实验结果显示,该算法对表情变化、光照改变及不同遮挡情况获得了更高的识别率,尤其针对光照变化,效果更加显著。

关键词 拉普拉斯方向,维数约简,线性判别分析,鲁棒的相异性度量

中图分类号 TP391 **文献标识码** A

Different Linear Discriminant Analysis Based on Laplacian Orientations

LI Zhao-kui^{1,2} DING Li-xin¹ WANG Yan² HE Jin-rong¹ ZHOU Ling-yun¹

(State Key Laboratory of Software Engineering, School of Computer, Wuhan University, Wuhan 430072, China)¹

(School of Computer, Shenyang Aerospace University, Shenyang 110136, China)²

Abstract For the traditional linear discriminant analysis method, there are usually three questions: 1) In order to ensure that the within-class scatter matrix is nonsingular, the principal component analysis must firstly be performed, which limits the effect of multidimensional space. 2) If the number of training samples per person is single, the within-class scatter matrix is generally singular, and the method does not work. 3) Without considering the partial correlation between pixels. To address these problems, this paper proposed a different linear discriminant analysis based on Laplacian orientations. The usage of the Laplacian orientations results in a more robust dissimilarity measures between images. The introduction of the difference scatter matrix avoids the singularity of the within-class scatter matrix. Experiments show that the proposed method has better robustness for facial expressions, illumination changes and different occlusions, and achieves a higher recognition rate. Especially for illumination changes, the effect is better.

Keywords Laplacian orientations, Dimensionality reduction, Linear discriminant analysis, Robust dissimilarity measures

1 引言

维数约简方法的主要目标是寻找一个低维特征空间去表示人脸,迄今为止,研究人员已经提出了基于无监督、有监督和半监督的多种降维方法。无监督方法典型的包括主成份分析(Principal Component Analysis, PCA)^[1]、局部保持投影(Locality Preserving Projection, LPP)^[2]、邻域保持嵌入(Neighborhood Preserving Embedding, NPE)^[3]等。有监督方法典型的包括线性判别分析(Linear Discriminant Analysis, 简称LDA)^[4]、间隔Fisher分析(Marginal Fisher Analysis, 简称MFA)^[5]、局部敏感判别分析(Locality Sensitive Discriminant Analysis, 简称LSDA)^[6]等。半监督方法典型的包括半监督维数约简(Semi-supervised Dimensionality Reduction, 简称SSDR)^[7]、半监督判别分析(Semi-supervised Discriminant

Analysis, 简称SDA)^[8]等。在人脸识别中,维数约简方法的性能严重受每人训练样本数量的影响。

在该科学领域主要围绕两个方向进行研究。一个方向是流形学习,流形学习算法假定输入观测数据位于或近似位于一个嵌入在高维欧氏空间中内在的低维流形上,算法的主要目标是发现高维观测数据集的内在低维流形结构和嵌入映射关系。典型的例子包括等度规映射(Isomap)^[9]、局部线性嵌入(Locally Linear Embedding, 简称LLE)^[10]和拉普拉斯特征映射(Laplacian eigenmaps, 简称LE)^[11]。另外LPP^[2]是LE的线性化版本,NPE^[3]是LLE的线性化版本。

另一个方向是基于核的方法把线性降维方法(如PCA和LDA)扩展到任意的希尔伯特空间进行^[12-16]。这些方法的主要思想是通过一个隐式的非线性映射,把输入数据映射到高维的希尔伯特空间,然后在特征空间上执行线性降维方法,所

到稿日期:2013-07-24 返修日期:2013-11-02 本文受国家自然科学基金(60975050, 60902053),广东省省部产学研结合专项(2011B090400477),珠海市产学研合作专项(2011A050101005, 2012D0501990016),珠海市重点实验室科技攻关项目(2012D0501990026)资助。
李照奎(1976-),男,博士生,副教授,主要研究方向为模式识别、智能计算、图像处理, E-mail: lzk@whu.edu.cn; 丁立新(1967-),男,教授,博士生导师,主要研究方向为智能计算、智能信息处理、机器学习、云计算。

有的计算都通过特征空间的内积进行(即所谓的核技巧)。一般的线性降维算法都有其相对应的核算法(PCA 和 KPCA, LDA 和 KDA, LPP 和 KLPP, NPE 和 KNPE),在文献[15]中则提出了一种新的核判别分析算法,即谱回归核判别分析(Spectral Regression Kernel Discriminant Analysis, 简称 SRKDA)算法。

对于标准的 LDA 方法,通常有 3 个问题:1)为了确保类内散度矩阵 S_w 的非奇异性,通常必须首先通过 PCA 进行维数约简,这限制了对更多维数空间的使用,而更多的维数空间可能更有利于分类效果。2)当每人只有单个训练样本时,类内散度矩阵必然奇异,此时 LDA 无法工作。3)传统 LDA 方法主要基于像素强度进行处理,通常只是简单地把二维图像转换成一维向量。在图像转换过程中,仅图像像素的强度值被保留,而像素之间的相关性并没有被考虑。像素之间的相关性常常反映了结构信息和轮廓信息,毫无疑问更有利于最终的分类型效果。

为了解决这些问题,本文提出了一种基于拉普拉斯方向的差值线性判别分析方法(different linear discriminant analysis based on Laplacian orientations, LO-DLDA)。拉普拉斯方向的使用带来了更鲁棒的图像相异度测量。此外,我们通过最大化一个新的差值散度矩阵 $S_{b_w} = S_b - S_w$ 来获得最优判别子空间。由于 S_{b_w} 的引入,我们不必担心奇异值问题,并确保每人只有单个训练样本时,我们的方法依然正常工作。实验显示 LO-DLDA 对人脸表情变化、光照变化和遮挡变化具有较好的鲁棒性,并且获得了更好的识别率。

本文第 2 节介绍基于拉普拉斯方向的图像变换;第 3 节提出了 LO-DLDA 算法;第 4 节介绍了实验结果与分析展示;最后对论文进行总结。

2 基于拉普拉斯方向的图像变换

图像锐化是直接对图像中的局部空间像素进行操作的过。空间域处理可以定义如下:

$$g(x, y) = T[f(x, y)] \quad (1)$$

其中, $f(x, y)$ 是 $M \times N$ 的输入图像, $g(x, y)$ 是 $M \times N$ 的输出图像。

图像锐化处理的目的是增强图像的轮廓,突出图像中的细节。微分运算经常用来进行锐化处理,微分运算主要求信号的变化率,以加强高频分量的作用,从而使图像轮廓更加清晰。拉普拉斯算子(Laplacian)是一种常用的微分算子。

对于数字图像 $f(x, y)$, 其拉普拉斯算子为:

$$\nabla^2 f = \Delta_x^2 f(x, y) + \Delta_y^2 f(x, y) \quad (2)$$

其中

$$\Delta_x^2 f(x, y) = f(x+1, y) + f(x-1, y) - 2f(x, y) \quad (3)$$

同理可求得

$$\Delta_y^2 f(x, y) = f(x, y+1) + f(x, y-1) - 2f(x, y) \quad (4)$$

则式(2)中的二维拉普拉斯算子实现可由两个分量相加得到:

$$\nabla^2 f = [f(x+1, y) + f(x-1, y) + f(x, y+1) + f(x, y-1)] - 4f(x, y) \quad (5)$$

图 1 是常用的拉普拉斯图像掩模。式(5)可以用图 1(a)所示的掩模来实现。通常对角线方向也可以加入到拉普拉斯变换的定义中,相对应的变形图像掩模如图 1(b)所示。

0	1	0
1	-4	1
0	1	0

1	1	1
1	-8	1
1	1	1

(a) 标准 3×3 掩模

(b) 变形 3×3 掩模

图 1 图像掩模

拉普拉斯是一种微分算子,它强调图像中灰度的突变以及降低灰度慢变化的区域。这将产生一幅把图像中的浅灰色边线和突变点叠加到暗背景中的图像。将原始图像和拉普拉斯图像叠加在一起的简单方法可以保护拉普拉斯锐化处理的效果,同时又能复原背景信息。用 γ 表示拉普拉斯掩模中心系数,如果 $\gamma > 0$ 则 $sign(\gamma) = -1$, 否则 $sign(\gamma) = 1$ 。使用拉普拉斯变换对图像增强的基本方法可表示为:

$$g(x, y) = f(x, y) + sign(\gamma) \times \nabla^2 f(x, y) \quad (6)$$

在本文,我们并不打算使用此方法增强图像,而更关心拉普拉斯算子对图像的变换结果。我们可以把图 1 所示的图像掩模扩展到 $n \times n$ (n 为奇数)掩模,图 2 给出了一个 5×5 掩模的例子。 $n \times n$ 掩模共有 n^2 个元素, $f(x, y)$ 在 $n \times n$ 掩模中共有 $n^2 - 1$ 个邻居,设 Ω 为 $f(x, y)$ 的邻域, $\Omega = \{\omega_1, \omega_1, \dots, \omega_{n^2-1}\}$, 则 $n \times n$ 掩模的拉普拉斯算子为:

$$\nabla^2 f = \sum_{i=1}^{n^2-1} \omega_i - (n^2 - 1)f(x, y) \quad (7)$$

1	1	1	1	1
1	1	1	1	1
1	1	-24	1	1
1	1	1	1	1
1	1	1	1	1

图 2 5×5 图像掩模

下面对拉普拉斯算子进行均值化处理,以平衡不同掩模对变换结果的影响。具体方法如下:

$$\overline{\nabla^2 f} = \nabla^2 f / l, l = \#(\Omega) \quad (8)$$

如果均值化的结果的绝对值过高,基于图像中相邻像素具有相似性的假设,说明掩模中心像素相对于其邻域像素表现异常,因此要对该均值化结果进行平滑,以弱化可能出现的异常像素值。为了得到更好的平滑结果,我们选取合适的门限值 σ , 以及合适的微调参数 τ 。当 $|\overline{\nabla^2 f}|$ 大于门限值 σ 时进行平滑,否则 $|\overline{\nabla^2 f}|$ 保持不变。具体平滑方法如下:

$$\overline{\nabla^2 f} = sign(\overline{\nabla^2 f}) \times \exp(-|\overline{\nabla^2 f}| - \tau), |\overline{\nabla^2 f}| > \sigma \quad (9)$$

在这里,如果 $\overline{\nabla^2 f} \geq 0$ 则 $sign(|\overline{\nabla^2 f}|) = 1$, 否则 $sign(|\overline{\nabla^2 f}|) = -1$ 。

下面我们引入均值化拉普拉斯算子的方向,令 $\alpha(x, y)$ 表示 $\overline{\nabla^2 f}$ 在 (x, y) 处的方向角,则有:

$$\alpha(x, y) = \arctan(\overline{\nabla^2 f}) \quad (10)$$

对于输入图像 $f(x, y)$, 我们最终得到的输出图像 $g(x, y)$ 定义如下:

$$g(x, y) = \alpha(x, y) = \arctan(\overline{\nabla^2 f}) \quad (11)$$

$f(x, y)$ 中的像素值取值范围为 $[0, 255]$, 经变换后的 $g(x, y)$ 中每个元素的取值范围被限制到 $(-\frac{\pi}{2}, \frac{\pi}{2})$ 。通过拉普拉斯方向的计算,使得与邻域像素值近似的像素点,方向角

趋向于0,而相对于邻域像素值变化过于剧烈的像素点,方向角的计算起到了弱化的作用,实质上是对异常像素影响的一种抑制。因此,拉普拉斯方向的计算,一方面增强了图像的轮廓,突出了图像中的细节,另一方面也抑制了噪声的影响。另外我们考虑同一幅图像在不同光照情况下,图像中的某些区域的像素值可能被同时增高或同时降低,但拉普拉斯方向将保留一定的不变性,这在某种程度上减少了光照对图像的影响。

图3展示了Yale B人脸数据库中的在不同光照下的两张原始图像以及对原始图像做拉普拉斯方向变换后的结果。从图2可以看出,通过拉普拉斯方向算子处理后的图像,图像轮廓更清晰,并且明显抵消了光照作用的影响。



图3 (a)和(c)是原始图像;(b)和(d)是相应的拉普拉斯方向图像

下面将通过不同的距离度量方式(欧式距离度量、相关距离度量和余弦距离度量)来比较变换前后图像之间的相异性。用 a 表示图像 $f(x,y)$ 的 $p(=M \times N)$ 维列向量,用 b 表示图像 $g(x,y)$ 的 $p(=M \times N)$ 维列向量。图4展示了从AR人脸库中选取的多幅图像。针对图4中的图像,表1展示了在不同度量方式下中性表情图像和其他图像之间的相异性比较。从表1可以看出一个非常有趣的结果,即对于原始图像,在不同度量方式下,不同人的脸之间的相异性更小,同一人之间的中性表情图像与遮挡图像(包括墨镜遮挡和面罩遮挡)之间的相异性更大,而采用拉普拉斯方向算子变换后的图像,在所有情况下,不同人的脸之间的相异性都是最大的,这其实更符合实际情况,也充分说明了拉普拉斯方向算子对遮挡情况的鲁棒性。



图4 每行从左到右依次是中性表情图像,微笑表情图像,墨镜遮挡图像,面罩遮挡图像和另一个人的中性表情图像。

表1 在不同度量方式下中性表情图像和其他图像之间的相异性比较

测度	测试图像	强度值	拉普拉斯方向
欧式测度	微笑	1200.2	70.5266
	墨镜遮挡	3880.1	74.8603
	围巾遮挡	4787.6	74.4744
	不同的人	2830.8	79.7498
相关测度	微笑	0.0931	0.7126
	墨镜遮挡	0.5165	0.8547
	围巾遮挡	0.8221	0.8379
	不同的人	0.3917	0.928
余弦测度	微笑	0.0097	0.7014
	墨镜遮挡	0.0727	0.8424
	围巾遮挡	0.1345	0.8208
	不同的人	0.0536	0.9045

3 基于拉普拉斯方向的差值线性判别分析

在基于外观的识别方法中,一个2维人脸图像通常被当

作一个列向量来处理。一系列人脸图像样本 $\{a_i\}$ 被表示成一个 $p \times n$ 矩阵 $A = [a_1, a_2, \dots, a_n] \in \mathbb{R}^{p \times n}$, $a_i \in \mathbb{R}^{p \times 1}$, 在这里 p 是一张图像的像素数, n 是样本数。每张人脸图像 a_i 属于 C 个人脸类 $\{A_1, A_2, \dots, A_C\}$ 中的一个, $c(a_i)$ 是 a_i 的类标记。对于一个测试人脸图像 T ,人脸识别的任务是在数据库中寻找它的类标记。

首先简要回顾LDA子空间方法。LDA的基本思想是将高维的模式样本投影到最佳鉴别矢量空间,以达到抽取分类信息和压缩特征空间维数的效果,投影后保证模式样本在新的子空间有最大的类间距离和最小的类内距离,即模式在该空间中有最佳的可分离性。因此,它是一种有效的特征抽取方法。使用这种方法能够使投影后模式样本的类间散布矩阵 S_b 最大,同时类内散布矩阵 S_w 最小。因此它能够保证投影后模式样本在新的空间中有最小的类内距离和最大的类间距离,即模式在该空间中有最佳的可分离性。

S_b 和 S_w 分别定义如下:

$$S_b = \sum_{i=1}^C n_i (m_i - m)(m_i - m)^T \quad (12)$$

$$S_w = \sum_{i=1}^C \sum_{a_k \in A_i} (a_k - m_i)(a_k - m_i)^T \quad (13)$$

在这里 m_i 是 A_i 类中所有样本的均值, n_i 是 A_i 类中的样本个数。 m 是所有类中样本的均值。

LDA的子空间通过一系列列向量 Q 扩张而成,这里 Q 满足如下式子:

$$Q = \arg \max | \frac{Q^T S_b Q}{Q^T S_w Q} | \quad (14)$$

因此 Q 能够通过求解 $S_w^{-1} S_b$ 的特征向量来获得, Q 映射原始的 p 维空间到一个 d 维的特征空间,其中 $p \ll d$ 。我们注意到:1)至多有 $C-1$ 个非0广义特征向量,因此 d 的上界是 $C-1$ 。2)需要至少 $p+C$ 个样本来保证 S_w 的非奇异性(这在任何现实应用中都是不可能的)。

为了解决这些问题,文献[4]提出了过渡特征空间的使用。在上面提到的两种情况下,过渡特征空间通过PCA来获得。因此原始的 p 维空间,首先用PCA投影到一个过渡的 q 维特征空间,然后再用LDA投影到最终的 d 维特征空间。

经典的LDA方法显然有两个问题:1)为了保证 S_w 是非奇异的,我们必须首先通过PCA执行维数约简,这限制了对更多维数的使用,而这些更多的维中会有更适合分类的维存在。2)当每一类只有一个样本存在时, S_w 变成全0矩阵, S_w 必然奇异,因此LDA方法失效。

下面结合前面提到的拉普拉斯方向,提出我们的子空间学习方法。我们的方法并不直接处理像素强度值,而是先通过拉普拉斯方向算子变化图像,然后针对变化后的图像进行子空间学习。为了解决经典LDA方法的两个问题,我们通过最大化一个新的差值散布矩阵 S_{b-w} 来寻找具有最佳可分性的子空间。 S_{b-w} 被定义如下:

$$S_{b-w} = S_b - S_w \quad (15)$$

对于差值散度矩阵 S_{b-w} ,我们要解决如下的优化问题:

$$J(Q) = Q^T (S_b - S_w) Q \quad (16)$$

这里就是要选取使得 $J(Q)$ 达到最大值的投影基矩阵 Q ,其物理意义是要保证投影后的样本具有最大类间散度和最小类内散度。

对于投影方向向量(标准正交向量) q_j ,有 $q_j^T (m_i - m)$ 是 $m_i - m$ 在 q_j 上的投影分量, $q_j^T (a_k - m_i)$ 是 $a_k - m_i$ 在 q_j 上的投影分量。则有:

$$\begin{aligned}
J(q) &= \sum_{i=1}^C n_i [q_j^T (m_i - m)] [q_j^T (m_i - m)]^T - \sum_{i=1}^C \sum_{a_k \in A_i} [q_j^T (a_k - m_i)] [q_j^T (a_k - m_i)]^T \\
&= \sum_{i=1}^C q_j^T n_i (m_i - m) (m_i - m)^T q_j - \sum_{i=1}^C \sum_{a_k \in A_i} q_j^T (a_k - m_i) (a_k - m_i)^T q_j \\
&= q_j^T \left\{ \sum_{i=1}^C n_i (m_i - m) (m_i - m)^T \right\} q_j - q_j^T \left\{ \sum_{i=1}^C \sum_{a_k \in A_i} (a_k - m_i) (a_k - m_i)^T \right\} q_j \\
&= q_j^T S_b q_j - q_j^T S_w q_j \\
&= q_j^T (S_b - S_w) q_j \quad (17)
\end{aligned}$$

因此,最终的最优判别投影基 $Q=[q_1 q_2 \dots q_d]$ 和特征值 Λ 可通过解决如下的特征分解问题获得。

$$(S_b - S_w)Q = Q\Lambda \quad (18)$$

引入 S_{b-w} 后,由于不要求类内散度矩阵的逆矩阵,因此我们不用再担心奇异值问题,自然不需要过渡特征空间的计算,从而可以利用更多的维数空间;同时也能保证当每类只有一个样本时,我们的方法依然能够正常运行。

由于在该方法中引入了拉普拉斯方向算子和差值散布矩阵,因此我们称此算法为 LO-DLAD 算法。

完整的算法如下:

算法 1 计算最优判别投影基

输入: n 个训练图像集合 $I_j^{\text{train}} \in \mathbb{R}^{M \times N}$, $j=1, 2, 3, \dots, n$ 。 d 个主成分。

输出: 最优判别投影基 Q , 低维坐标 Z 。

① 用式(12)对图像 $I_j^{\text{train}} \in \mathbb{R}^{M \times N}$ 变换得到图像 $g_j^{\text{train}} \in \mathbb{R}^{M \times N}$, 对 g_j^{train} 进行列变换生成列向量 $b_j \in \mathbb{R}^{p \times 1}$, $p=M \times N$, 组成矩阵

$$B_{\text{train}} = [b_1, b_2, \dots, b_n] \in \mathbb{R}^{p \times n}, \text{并标准化到} [-1, 1].$$

② 用式(12)、式(13)和式(15)分别计算 S_b , S_w 和 S_{b-w} 。

③ 根据式(18)获得最优判别投影基 Q 。

④ 获得低维坐标 $Z=Q^T B$, $Z \in \mathbb{R}^{d \times n}$ ($d \ll p$)。

同理可由 Q 得到测试样本的低维坐标。

LO-DLAD 的计算成本分析如下:拉普拉斯方向变换的时间复杂度是 $O(n^2)$, 特征分解的时间复杂度是 $O(n^2 p)$, LO-DLAD 算法的整个时间复杂度是 $O(n^2 + n^2 p)$ 。 LO-DLAD 算法的空间复杂度为 $O(p)$ 。

4 实验结果

该部分将执行一系列人脸识别实验来评估我们提出的 LO-DLAD 算法。在实验中,将其分别和多个降维算法进行比较,为了保证公正性,采用简单的 KNN 分类器进行分类。3 个广泛使用的人脸库 AR^[17]、Yale^[4] 和 Extended Yale B^[18] 被应用在我们的实验中。实验主要针对各种非理想情况进行评价,具体包括人脸表情变化(Yale, AR),光照变化(Yale B, Yale, AR)以及部分遮挡情况(AR)。图 5 展示了实验中用到的一些人脸图像。



(a) 在 AR 数据库中第一个人的所有 26 张图像



(b) 在 Yale 数据库中第一个人的 11 张图像



(c) 在 Extended Yale B 数据库中第一个人的部分图像

图 5

4.1 参数选择

在这里 PCA 算法中的能量比通常取 1。LPP 的最近邻居数取 2,邻接权计算直接采用余弦距离度量,NPE 的最近邻居数取 3。最近邻居的选择策略是从 $\{1, 2, 3, \dots, n_i - 1\}$ 中搜索最佳的识别效果,这里 n_i 是每类训练样本的数量。所有的核方法(KPCA, KDA, KLPP, SRKDA)的核函数都采用简单的线性核函数,其中 KLPP 采用有监督模式。为达到最佳的识别效果,针对 LO-DLAD 采用 5×5 掩模矩阵进行图像变换。对于门限值 σ 和微调参数 τ , AR 分别取 12 和 10, Yale 分别取 10 和 10, Extended Yale B 分别取 30 和 10。所有实验中图像的分辨率被设置为 60×60 。

4.2 AR 人脸数据库

AR 人脸库包含 126 个人(70 个男性,56 个女性)的 4000 多张正面人脸图像。每个人有 26 张图像,被分作两部分,第一部分每个人共有 13 张图像,从 1 到 13 进行编号,其中包括不同的人脸表情(1-4)、光照变化(5-7)以及在不同光照条件下的不同遮挡(8-13)。第二部分和第一部分类似。实验中选择 AR 的一个子集,包括 100 个人(50 个男性,50 个女性),同样也被分为两部分,每部分每个人各 13 张图像。对于 AR 人脸数据库,主要针对人脸表情变化、光照变化、墨镜遮挡(含光照)变化以及围巾遮挡(含光照)变化,来评估提出方法的鲁棒性。

表 2 提供了每个实验的详细信息。最佳识别率被分别展示在表 3-表 5 中,其中小括号内是获得最佳识别率时对应的维数。

表 2 AR 人脸库中所有实验的详细信息

Exp.	Training Set (session 1)	Test Set (session 2)
Exp. 1	1-4	1-4 expressions(neural, smile, anger and scream)
Exp. 2	1-4	5-7 illumination variations
Exp. 3	1-4	8-10 sunglasses-illumination
Exp. 4	1-4	11-13 scarves-illumination
Exp. 5	8-13	1-4 expressions(neural, smile, anger and scream)
Exp. 6	8-13	5-7 illumination variations
Exp. 7	8-13	8-10 sunglasses-illumination
Exp. 8	8-13	11-13 scarves-illumination
Exp. 9	1	1-4 expressions(neural, smile, anger and scream)
Exp. 10	1	5-7 illumination variations
Exp. 11	1	8-10 sunglasses-illumination
Exp. 12	1	11-13 scarves-illumination

表 3 在 AR 人脸库中不同降维方法的最佳识别率对比(Exp. 1-Exp. 4)

Method	Exp. 1	Exp. 2	Exp. 3	Exp. 4
PCA	70.3%(280)	34.3%(210)	20.7%(345)	8.3%(332)
LPP	67.3%(223)	37%(149)	22.3%(380)	28.7%(191)
NPE	75.8%(222)	40.3%(278)	21.3%(179)	29.7%(278)
LDA	85.5%(99)	48.3%(99)	16%(62)	33.7%(98)
LSDA	88.3%(97)	55.7%(321)	17.7%(381)	36%(334)
KPCA	70.3%(280)	34.3%(210)	20.7%(345)	8.3%(332)
KLPP	67.5%(29)	24.7%(23)	16.3%(28)	9%(26)
KDA	74.5%(92)	32%(93)	19.3%(70)	13.3%(91)
SRKDA	92.5%(87)	48%(99)	17.7%(96)	30.3%(86)
LO-DLDA	96%(383)	91%(395)	81%(390)	69%(372)

从实验 1 到实验 4,我们使用第一部分中的不同的人脸表情(1-4)为训练集,所有方法的最佳识别率被展示在表 3 中。实验结果显示 LO-DLDA 获得了比其他方法更高的识别率。实验 1 中以第二部分的人脸表情(1-4)作为测试集, LO-DLDA 获得 96% 的识别率;实验 2 中以第二部分的光照

变化(5-7)作为测试集, LO-DLDA 获得 91% 的识别率; 对于实验 3 和实验 4, 显然是 AR 数据库中更有挑战性的实验, 以第二部分的遮挡图像作为测试集(8, 9, 11-13), 结果显示 LO-DLDA 分别获得了 81% 和 69% 的识别率。在实验 4 中 LO-DLDA 的实验效果并不是特别好, 但我们的方法仍然优于其它方法。

表 4 在 AR 人脸库中不同降维方法的最佳识别率对比(Exp. 5-Exp. 8)

Method	Exp. 5	Exp. 6	Exp. 7	Exp. 8
PCA	27.5%(268)	17.3%(571)	60.3%(209)	35.3%(429)
LPP	7.8%(132)	6.3%(105)	33.7%(516)	15.3%(428)
NPE	28%(599)	22.7%(599)	55.7%(598)	38.7%(597)
LDA	53.5%(98)	69.3%(99)	74%(98)	60.7%(99)
LSDA	56%(124)	75.3%(123)	77.7%(98)	63%(91)
KPCA	27.5%(268)	17.3%(571)	60.3%(209)	35.3%(429)
KLPP	36.3%(28)	45.7%(24)	69.3%(30)	45.3%(30)
KDA	48.3%(58)	53.3%(59)	73.7%(54)	52%(89)
SRKDA	67.8%(88)	82.3%(96)	88.3%(95)	76.3%(95)
LO-DLDA	75.25%(244)	90%(381)	93.33%(534)	73.67%(374)

表 5 在 AR 人脸库中不同降维方法的最佳识别率对比(Exp. 9-Exp. 12)

Method	Exp. 9	Exp. 10	Exp. 11	Exp. 12
PCA	58.75%(89)	35%(91)	23.33%(95)	6.67%(91)
LPP	51%(99)	34%(99)	21.33%(99)	14%(99)
NPE	60%(97)	48%(97)	23%(95)	13.33%(99)
LSDA	66.5%(98)	48%(95)	18%(89)	20.33%(90)
KPCA	58.75%(89)	35%(91)	23.33%(95)	6.67%(91)
KLPP	52.25%(27)	27.33%(29)	18.67%(24)	5.67%(28)
KDA	58.75%(89)	35%(91)	23.33%(95)	6.67%(91)
SRKDA	71.25%(89)	47.33%(83)	22.67%(98)	15.67%(86)
LO-DLDA	75%(99)	87.35%(96)	78.33%(534)	57.67%(374)

从实验 5 到实验 8, 我们使用第一部分中的不同的遮挡图像(8-13)为训练集, 这些实验在 AR 数据库中也是比较有挑战性的, 所有方法的最佳识别率被展示在表 4 中。实验结果显示 LO-DLDA 也获得了不错的识别率。针对表情变化(实验 5), LO-DLDA 获得了 75.25% 的识别率; 针对光照变化(实验 6), LO-DLDA 获得了 90% 的识别率; 由于使用遮挡图像作为训练集, 针对墨镜遮挡(实验 7), LO-DLDA 获得高达 93.33% 的识别率; 针对围巾遮挡(实验 8), LO-DLDA 也获得 73.67% 的识别率(低于 SRKDA 的 76.3%)。

从实验 9 到实验 12, 我们将进行 AR 中最难的实验, 我们仅使用第一部分中的第一张表情图像(1)为训练集, 来测试 LO-DLDA 的识别率, 所有方法的最佳识别率被展示在表 5 中。由于单训练样本时, LDA 不能正常工作, 因此表 5 中并没有列出 LDA 的实验结果。实验结果显示 LO-DLDA 在大多数情况下获得了比其他方法更高的识别率。针对表情变化情况(实验 9), LO-DLDA 获得了 75% 的识别率; 针对光照变化(实验 10), LO-DLDA 获得了 87.35% 的识别率; 对于实验 11 和实验 12, 以第二部分的遮挡图像作为测试集(8, 9, 11-13), 结果显示 LO-DLDA 分别获得了 78.33% 和 57.67% 的识别率。

在不同的训练集下, 实验 1、实验 5 和实验 9 主要针对表情变化进行测试。实验 2、实验 6 和实验 10 主要针对光照变化进行测试。实验 3、实验 7 和实验 11 主要针对墨镜遮挡进行测试。实验 4, 实验 8 和实验 12 主要针对围巾遮挡进行测试。从实验结果可以看出, 针对光照变化测试(91%、90% 和 87.35%) 和墨镜遮挡测试(81%、93.33% 和 78.33%), LO-DLDA 表现得比较稳定。针对表情变化测试(96%、75.25%

和 75%) 和围巾遮挡测试(69%、73.67% 和 57.67%), LO-DLDA 表现得不够稳定。特别值得注意的是针对围巾遮挡测试, LO-DLDA 获得的识别率相对较低(69%、73.67% 和 57.67%), 说明该方法对围巾遮挡比较敏感, 这也是我们下一步研究工作的重点。

4.3 Yale 人脸数据库

Yale 人脸库包含 15 个人的 165 张人脸图像, 每个人有大约 11 张图像, 这些图像是在不同表情和光照条件下采集的。

每个人随机选择一定数量的图像作为训练集, 剩下的图像作为测试集。在实验中, 我们分别为每人选择的训练样本为 1、2、3、5。所有方法的最佳识别率被展示在表 6 中。从表 6 可以看出, 相比于其它方法, LO-DLAD 获得了更高的识别率, 在每人训练样本为 5 时, LO-DLAD 和 LSDA 的识别率相同。针对每个单个训练样本时, LO-DLAD 获得了优于其它方法的识别率。

表 6 在 Yale 人脸库中不同降维方法的最佳识别率对比

Method	1	2	3	5
PCA	51.33% (13)	60.74% (25)	74.17% (21)	78.89% (12)
LPP	55.33% (12)	56.30% (29)	73.33% (42)	81.11% (72)
NPE	54.67% (13)	67.41% (28)	77.50% (38)	86.67% (73)
LDA	-	82.22% (11)	93.33% (14)	96.67% (10)
LSDA	54.00% (14)	91.11% (18)	95.83% (14)	98.89% (13)
KPCA	51.33% (13)	60.74% (25)	71.47% (21)	78.89% (12)
KLPP	51.33% (13)	74.81% (13)	8500% (6)	93.33% (8)
KDA	52.67% (13)	88.15% (14)	94.17% (13)	96.67% (14)
SRKDA	61.33% (13)	90.37% (14)	95.83% (13)	96.67% (13)
LO-DLDA	70.67% (12)	93.33% (14)	95.91% (18)	98.89% (62)

4.4 Extended Yale B 人脸数据库

Extended Yale B 人脸库包含 38 个人的 2414 张正面人脸图像, 每个人有大约 64 张图像, 这些图像是在不同光照条件下采集的。

每个人随机选择一定数量的图像作为训练集, 剩下的图像作为测试集。在实验中, 我们分别为每人选择的训练样本为 1、10、15、20。所有方法的最佳识别率被展示在表 7 中。从表 7 可以看出, 相比于其它方法, LO-DLAD 获得了更高的识别率, 在每人训练样本为 10、15、20 时, LO-DLAD 都获得了高于 99% 的识别率, 其中当每人训练样本到达 20 时, LO-DLAD 获得了 100% 的识别率。针对每个单个训练样本时, LO-DLAD 也获得了优于其它方法的识别率。

表 7 在 Extended Yale B 人脸库中不同降维方法的最佳识别率对比

Method	1	10	15	20
PCA	12.16% (37)	53.83% (327)	61.98% (519)	70.31% (449)
LPP	22.64% (36)	81.56% (378)	85.25% (521)	87.00% (741)
NPE	24.28% (37)	85.00% (372)	85.58% (491)	88.57% (687)
LDA	-	90.61% (37)	94.03% (37)	95.95% (37)
LSDA	28.62% (37)	92.28% (313)	94.36% (335)	96.07% (51)
KPCA	12.17% (37)	53.83% (327)	61.98% (519)	70.31% (449)
KLPP	10.60% (29)	88.20% (27)	93.44% (29)	95.22% (30)
KDA	28.91% (36)	89.97% (37)	93.98% (37)	95.53% (37)
SRKDA	30.51% (37)	90.66% (37)	94.96% (36)	97.10% (36)
LO-DLDA	57.11% (37)	99.75% (278)	99.89% (537)	100% (291)

结束语 在本文, 我们提出了一种基于拉普拉斯方向的差值 LDA。实验结果显示, 该方法对表情变化、光照变化和遮挡情况具有较好的鲁棒性, 尤其对光照变化, LO-DLDA 表现更为突出。LO-DLDA 也有一定的不足, 即对遮挡情况, 实

(下转第 203 页)

- tracking based on first order divided difference filter[C]//25th Chinese Control and Decision Conference, 2013;351-356
- [9] Leong P H, Arulampalam S, Lamahewa T A, et al. A Gaussian-sum based cubature Kalman filter for bearings-only tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2013, 49(2);1161-1176
- [10] Cappe O, Godsill S J, Moulines E. An overview of existing methods and recent advances in sequential Monte Carlo[J]. Proceedings of the IEEE, 2007, 95(5);899-924
- [11] Gustafsson F. Particle filter theory and practice with positioning applications[J]. IEEE Aerospace and Electronic Systems Magazine, 2010, 25(7);53-82
- [12] Karlsson R. Particle filter for positioning and tracking applications[D]. Linköping; Linköping University, 2005
- [13] Qi C, Bondon P. An efficient two-stage sampling method in particle filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(3);2666-2672
- [14] Fu X Y, Jia Y M. An improvement on re-sampling algorithm of particle filters[J]. IEEE Transactions on Signal Processing, 2010, 58(10);5414-5420
- [15] Li H W, Wang J, Su H T. Improved particle filter based on differential evolution[J]. Electronics Letters, 2011, 47(19);1078-1079
- [16] Zhong J, Fung Y F. Case study and proofs of ant colony optimization improved particle filter algorithm[J]. IET Control Theory & Applications, 2012, 6(5);689-697
- [17] Schon T, Gustafsson F, Nordlund P J. Marginalized particle filters for mixed linear/nonlinear state-space models[J]. IEEE Transactions on Signal Processing, 2005, 50(7);2279-2289
- [18] Karlsson R, Schon T, Gustafsson F. Complexity analysis of the marginalized particle filter[J]. IEEE Transactions on Signal Processing, 2005, 53(11);4408-4411
- [19] Djuric P M, Bugallo M F. Cost-reference particle filtering for dynamic systems with nonlinear and conditionally linear states[C]//IEEE Nonlinear Statistical Signal Processing Workshop, 2006;183-188
- [20] Jaechan L, Hong D. Cost Reference Particle Filtering Approach to High-Bandwidth Tilt Estimation[J]. IEEE Transactions on Industrial Electronics, 2010, 57(11);3830-3839
- [21] Li C H, Yang S X, Nguyen T T. A self-learning particle swarm optimizer for global optimization problems[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2012, 42(3);627-646
- [22] Hu Z T, Liu X X, Jin Y. Cost Reference Particle Filter Based on Adaptive Particle Swarm Optimization in Observation Uncertainty [C]// Proceedings of the 30th Chinese Control Conference, 2011;769-800

(上接第 165 页)

验显示 LO-DLDA 对围巾遮挡要劣于墨镜遮挡, 主要原因可能是围巾遮挡破坏了脸部轮廓。如何解决 LO-DLDA 对围巾遮挡比较敏感的问题, 将是我们下一步研究工作的重点。

参 考 文 献

- [1] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1);71-86
- [2] He X F, Yan S C, Hu Y X, et al. Face recognition using Laplacianfaces[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2005, 27(3);328-340
- [3] He X F, Cai D, Yan S C, et al. Neighborhood preserving embedding[C]//Proc. of the IEEE Int'l Conf. on Computer Vision (ICCV). Beijing, 2005;1208-1213
- [4] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces; Recognition using class specific linear projection [J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 1997, 19(7);711-720
- [5] Xu D, Yan S, Tao D, et al. Marginal Fisher analysis and its variants for human gait recognition and content-based image retrieval[J]. IEEE Trans. Image Process, 2007, 16(11);2811-2821
- [6] Cai Deng, He Xiao-fei, Zhou Kun, et al. Locality Sensitive Discriminant Analysis[C]//Proceedings of the 20th International Joint Conference on Artificial Intelligence(IJCAI). Hyderabad, 2007;708-713
- [7] Chen Xiao-hong, Chen Song-can, Xue Hui. A unified dimensionality reduction framework for semi-paired and semi-supervised multi-view data[J]. Pattern Recognition, 2012, 4(5);2005-2018
- [8] Cai D, He X, Han J. Semi-supervised discriminant analysis[C]//Proceedings of IEEE 11th International Conference on Computer Vision (ICCV). Riode Janeiro, 2007;1-7
- [9] Balasubramanian M, Schwartz E L, Tenenbaum J B, et al. The Isomap Algorithm and Topological Stability[J]. Science, 2002, 295(5552);7
- [10] Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500);2323-2326
- [11] Belkin M, Niyogi P. Laplacian Eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6);1373-1396
- [12] Schölkopf B, Smola A, Müller K R. Nonlinear Component Analysis as a Kernel Eigenvalue Problem[J]. Neural Computation, 1998, 10(5);1299-1319
- [13] Baudat G, Anouar F. Generalized Discriminant Analysis Using a Kernel Approach[J]. Neural Computation, 2000, 12(10);2385-2404
- [14] Di You, Hamsici O C, Martinez A M. Kernel Optimization in Discriminant Analysis[J]. IEEE Trans. Pattern Analysis and Machine Intelligence, 2011, 33(3);631-638
- [15] Yang J, Frangi A F, Yang J Y, et al. KPCA plus LDA: A complete kernel fisher discriminant framework for feature extraction and recognition[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2005, 27(2);230-244
- [16] Cai Deng, He Xiao-fei, Han Jia-wei. Speed up kernel discriminant analysis[J]. The VLDB Journal, 2011, 20(1);21-33
- [17] Martinez A M, Kak A C. PCA versus LDA[J]. IEEE Trans. Pattern Analysis and Machine Intelligence, 2001, 23(2);228-233
- [18] Lee K, Ho J, Kriegman D. Acquiring linear subspaces for face recognition under variable lighting[J]. IEEE Trans. Pattern Analysis and Machine Intelligence, 2005, 27(5);684-698