

基于图像梯度和 2DPCA 的单样本人脸识别

吴 凡, 杨 丹

(重庆大学 计算机学院, 重庆 400044)

摘 要:提出了一种基于图像梯度的 2DPCA 的算法用于单样本人脸识别。采用图像梯度方法进行人脸识别具有光照不变性、能提取丰富的局部纹理信息等优点,但是这种方法只考虑了图像的局部信息,并没有充分利用全局信息。基于这种问题,文章考虑融合全局和局部信息进行单样本人脸识别。对于全局人脸信息的提取,采用 2DPCA 方法,相对与传统 PCA 方法,2DPCA 能够在不破坏图像二维结构的基础上进行全局信息提取。由于上述两种方法在图像匹配时所采用的匹配算法不一致,文章根据两种匹配方式的特点进行改进和融合,提出了一种新的匹配方案。实验证明,基于图像梯度和 2DPCA 的算法在单样本人脸识别问题上识别率优于传统方法。

关键词:图像梯度;2DPCA;单样本识别;人脸识别

中图分类号:

文献标志码:A

文章编号:1000-582X(2014)S2-254-05

随着人们对人脸识别技术研究的深入以及其应用领域的拓宽,人脸识别技术遇到了一个新的难题——单样本人脸识别。所谓的单样本人脸识别是指每人只存储一张已知身份的人脸图像作为训练样本用来识别具有姿态、光照等不可预测的人脸图像的身份^[1]。在实际生活的应用中,往往只拥有一张已知身份的人脸图像(如身份证、护照上的照片),因此解决单样本识别的问题具有非常重要的意义并吸引了众多研究者的广泛关注^[2-5]。单样本识别的研究最早可以追溯到 20 世纪 70 年代,Kanade^[6]设计的系统在一个具有 20 个人每人 2 张图像(一张用来训练一张用来测试)的数据库上取得了最高 75% 的识别率。

1 相关工作

解决单样本人脸识别问题具有重要的意义,近年来它已发展成为人脸识别研究中的一个重要研究方向,得到了国内外研究人员的广泛关注,提出了很多算法。目前文献中出现的主要针对单训练样本人脸识别的方法可以分为以下几类:基于几何特征的方法、样本扩张法、特征子空间扩展法和其他方法。基于几何特征的方法主要是检测出鼻子、眉毛、嘴巴、眼睛等部件在脸部的位置和大小,然后利用这些部件的总体几何分布以及相互之间的参数比例用来

识别人脸。基于几何特征的方法比较有代表性的有: Brunelli^[7]构建了一个人脸识别系统,它抽取人脸图像 35 个几何特征,形成 35 维的向量来表示人脸,并采用贝叶斯分类器来完成相似性匹配。Cox^[8]提出了一种混合距离的技术,人脸图像用手工抽取的 30 个距离来表示。样本扩张法的原理是利用原样本图像通过变化合成多个虚拟图像,扩张每类的训练样本数目,使单训练样本人脸识别问题变成一般的人脸识别问题。David^[9]提出了一种用线性物体类(Linear Object Classes)技术合成不同姿态的视图的方法,核心是认为一个物体可由若干个原型物体的加权和来表示,如果对该物体施加线性变换,变换结果同样可以由原型物体线性变换的加权和来表示,而且在这个过程中各个原型物体的权重不变。特征子空间扩展法比较有代表性的是 Chen 等人^[10]把每张人脸图像分割成大小相等的子图像,每张图像的所有子图像看作是一类的多幅图像,使用 LDA(Linear Discriminate Analysis)算法完成识别。对于单样本识别技术,算法所具有的训练样本就只有一个。因此识别技术的关键则是从一张训练样本中尽可能多地提取样本信息用于识别。因此对图像的局部纹理信息的提取则显得尤为重要,然而上述大部分算法都是基于灰度图像的操作,缺乏对图像纹理的应用。

收稿日期:2014-10-10

基金项目:国家自然科学基金(60975015)

作者简介:吴凡(1989-),男,硕士,主要从事图像处理及模式识别等领域研究,(E-mail)oimz1989@gmail.com.

在纹理提取方面,Gabor^[11]和局部二元模式(Local Binary Patterns, LBP)^[12]由于具有对光照影响不敏感的优点,近年来也吸引了大批研究者的参与并取得了较好的结果。但是,Gabor和LBP特征计算复杂且特征维数过高,给实际应用带来了一定的困难。相比之下,Zhang等人^[13]提出的梯度脸方法,计算较为简单,速度较快,具有一定的优势。其核心思想是认为一张人脸图片 $I(x,y)$ 可以用乘积的方式表示 $I(x,y)=R(x,y)L(x,y)$, $R(x,y)$ 是人脸图像在每一点的放射率,而 $L(x,y)$ 是人脸图像每一点的光照值。于是通过在梯度空间计算人脸图像的梯度值,便可以提取近似与 $R(x,y)$ 的特征。然而纹理信息主要是图像局部信息的体现,并不能很好地反映出图像的全局信息。对于全局信息的提取,Yang等人提出的2DPCA^[14](二维主成分分析)具有良好的效果。从这个角度出发,文章提出了基于图像梯度和2DPCA的G2DPCA单样本人脸识别算法。

2 算法简介

Zhang等人^[13]提出的梯度脸是一种提取鲁棒图像梯度方向的方法。该方法首先通过高斯低通滤波器对图像进行平滑,削弱光照突变的影响,然后通过光滑的高斯函数一阶导数与图像作卷积,求取图像 X 和 Y 方向的梯度分量,最后根据梯度方向的定义求取图像的光照变化不敏感特征——梯度脸。对于求出来的梯度脸使用2DPCA求取全局特征。与PCA相比,第一,由训练样本构成的协方差矩阵不需要特征值定理间接推导,能够直接计算其准确地特征值与特征向量;第二,整个算法特征抽取过程空间复杂度和计算复杂度都大大降低,需要训练样本数减少,更适合单样本人脸检测。

2.1 梯度脸方法

求取梯度脸的具体步骤如下。

步骤1:通过高斯滤波器平滑图像

$$F' = F \cdot G(x,y,\sigma) \quad (1)$$

$$G(x,y,\sigma) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2+y^2}{2\pi\sigma^2}\right) \quad (2)$$

其中 F 表示原始人脸图像, F' 表示图像 F 的平滑图像, \cdot 是卷积算子, σ 为高斯滤波器的标准差($\sigma \in [0.1, 0.6]$)。

步骤2:通过高斯函数的一阶导数与图像作卷积运算,求取图像 X 方向和 Y 方向的梯度分量。

$$F_x = F' \cdot G_x(x,y,\sigma) \quad (3)$$

$$F_y = F' \cdot G_y(x,y,\sigma) \quad (4)$$

其中, $G_x(x,y,\sigma)$ 和 $G_y(x,y,\sigma)$ 分别代表高斯

函数 X,Y 方向的一阶导数, F_x 和 F_y 分别表示图像 X 和 Y 方向的梯度分量。

步骤3:计算人脸图像的梯度

$$I = \arctan\left(\frac{F_y}{F_x}\right) \quad (5)$$

其中 I 代表最终求出的梯度脸。

2.2 二维主成分分析

在经典的主成分分析(PCA)方法中,必须先把所有训练样本图像的二维矩阵拉伸成一维的特征向量,图像矩阵被拉伸成一维特征向量后,会形成一个高维的向量空间,此向量空间的维数等于原人脸图像像素的行数与列数之积。与传统PCA不同的是,二维主成分分析是直接对二维图像做处理,不用提前把二维图像矩阵拉伸成很长的一维向量。

2DPCA的主要思想是将大小为 $m \times n$ 的人脸图像 A ,通过公式(6)所示的线性变换投影到单位向量 x 上,获得投影向量 y ,称为图像 A 的投影特征向量。

$$y = Ax \quad (6)$$

其中 x 需要最大化准则函数(7)。

$$J(x) = x^T G_i x \quad (7)$$

其中 G_i 为 A 的协方差矩阵。

$$G_i = E[(A - EA)^T (A - EA)] \quad (8)$$

x 要满足以下约束条件。

$$\begin{cases} x = (x_1, x_2, \dots, x_d) = \operatorname{argmax} J(x) \\ x_i^T x_j = 0, i \neq j, i, j = 1, 2, \dots, d \end{cases} \quad (9)$$

2.3 算法描述

人脸识别的性能常常受到光照、表情、姿态等因素的影响,而且在实际应用中图像经常含有噪声。单张样本识别则面临更大的困难,因此在只有一个训练样本的情况下,应尽量多地提取样本特征。梯度脸则具有不敏感于光照且能提取人脸图片局部纹理信息。仅仅基于人脸局部信息进行单张样本识别有一定的局限性,而2DPCA则能够在不破坏人脸图片结构的基础上提取人脸图片的全局信息。基于此,文章提出了基于图像梯度和2DPCA的单样本人脸识别算法。算法流程图如图1所示。

算法首先对人脸图像进行预处理,如归一化等,然后分别计算图像梯度脸和2DPCA特征,最后融合全局与局部信息进行图像匹配并返回识别结果。

1) 梯度脸计算

核心思想是认为一张人脸图片 $I(x,y)$ 可以用乘积的方式表示 $I(x,y)=R(x,y)L(x,y)$, $R(x,y)$ 是人脸图像在每一点的放射率,而 $L(x,y)$ 是人脸图像每一点的光照值。根据通用假设,在人脸图像中 R 的值




图 1 算法流程图

比 L 的值改变小很多于是通过在梯度空间计算人脸图像的梯度值,便可以提取近似与 $R(x, y)$ 的特征。图 2 中展示了不同光照条件下计算出来的梯度脸。



图 2 同一个人不同光照条件下的梯度脸

令 I 代表原图像, I_g 代表图像梯度脸, 则梯度脸计算公式为:

$$I_g = \arctan\left(\frac{I_{y\text{-gradient}}}{I_{x\text{-gradient}}}\right), I_g \in [0, 2\pi) \quad (10)$$

其中 $I_{x\text{-gradient}}, I_{y\text{-gradient}}$ 代表图像在 x 和 y 方向上的梯度。

2) 2DPCA 计算

2DPCA 为传统 PCA 的改进, 它在保留了二维图像结构的基础上进行主成分分析。相对应 PCA, 2DPCA 更容易计算出训练样本的协方差矩阵, 并且计算特征向量所用的时间远少于 PCA 方法。

令 I 代表原图像, A 代表训练样本集, I_{2d} 代表图像 2DPCA 特征。

$$\begin{cases} I_{2d} = I^T x \\ x = \operatorname{argmax}_x x^T E[(A - EA)^T (A - EA)] x \\ x_i^T x_j = 0, i \neq j, i, j = 1, 2, \dots, d \end{cases} \quad (11)$$

3) 匹配

对于计算出来的梯度脸, 两张图像 G_1 和 G_2 直接的相似性定义为:

$$D_{\text{gradient}}(G_1, G_2) = \sum_{i=1}^n \min(|g_{1i} - g_{2i}|, 2\pi - |g_{1i} - g_{2i}|) \quad (12)$$

其中 $G_1 = (g_{11}, g_{12}, \dots, g_{1n}), G_2 = (g_{21}, g_{22}, \dots,$

$g_{2n})$ 指的是梯度脸向量, n 代表的是向量维度。毫无疑问, 当 $D_{\text{gradient}}(G_1, G_2)$ 的值越小时, 相似度越高。

对于计算出来的 2DPCA, 通常使用下述公式计算任意两个人脸图像 $P_1 = (p_{11}, p_{12}, \dots, p_{1d})$ 和 $P_2 = (p_{21}, p_{22}, \dots, p_{2d})$ 相似度距离。

$$D_{2\text{DPCA}}(P_1, P_2) = \sum_{i=1}^d \|p_{1k} - p_{2k}\|_2 \quad (13)$$

其中 $\|p_{1k} - p_{2k}\|_2$ 代表主成分 p_{1k}, p_{2k} 之间的欧氏距离。

虽然对于上述两种方法都有着自己的相似性度量标准, 然而它们并不统一, 在此我们将其进行归一化并融合, 提出新的匹配方案如下:

$$D_{\text{new}}(I_1, I_2) = \alpha \times \exp^{-D_{\text{gradient}}(I_1, I_2)} + (1 - \alpha) \times \exp^{-D_{2\text{DPCA}}(I_1, I_2)} \quad (14)$$

可以看到, 新的匹配算法将上述两种匹配算法都归一化到 $[0, 1]$ 的范围, 并可以通过权重因子来控制全局信息和局部信息在匹配中的比例。

3 实验结果

实验在公开的标准数据库上进行的: Yale 数据库、ORL 数据库以及 FERET 数据库。主要进行了两组实验: 第一组是测试不同权重因子对算法带来的影响。第二组是在确定权重因子下, 与传统单样本人脸识别算法的对比。

3.1 不同权重因子 α 对算法的影响

文章将上述 3 种数据库中的每一个人的一张人脸图像用来进行训练, 然后将此人所有剩下的人脸图像用来测试。 α 的取值范围 $[0.1, 0.9]$, 步长为 0.1。

1) 在 Yale 数据库上的实验效果

Yale 人脸库是由耶鲁大学创建, 包含 15 位志愿者在不同光照、表情和姿态变化下的 165 张图片。在 Yale 人脸库中包含 15 个人 165 幅图像, 每人 11 幅图像。根据取值的不同, 可以得到本文提出算法在 Yale 数据库上的单样本人脸识别率如图 3 所示。

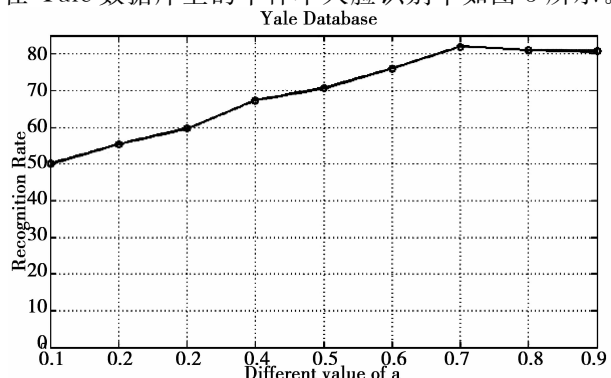


图 3 α 取不同值时 Yale 数据下的识别率

从上图可以得知, α 取 0.6 时, 本文算法在 Yale 数据库上的效果最好, 接近 82%。

2) 在 FERET 数据库上的实验效果

FERET 数据库由美国国防部发起建立的 FERET 项目所建立。原数据库包含 1 万多张人脸图像, 本实验所用的是其一个子集, 为 72 个人在不同光照及表情下的 432 幅图像。根据取值的不同, 可以得到本文提出算法在 FERET 数据库上的单样本人脸识别率如图 4 所示。

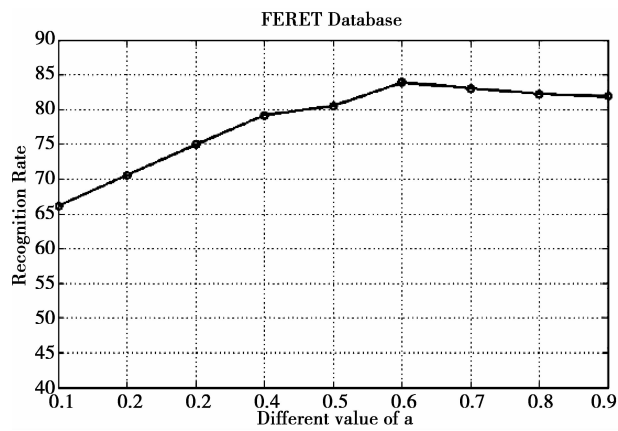


图 4 α 取不同值时 FERET 数据下的识别率

从上图可以得知, α 取 0.6 时, 本文算法在 FERET 数据库上的效果最好, 接近 85%。

3) 在 ORL 数据库上的实验效果

ORL 数据库由剑桥大学创建, 包含 40 人包括姿态、表情和面部饰物变化的共 400 张人脸图像。根据 α 取值的不同, 可以得到本文提出算法在 ORL 数据库上的单样本人脸识别率如图 5 所示。

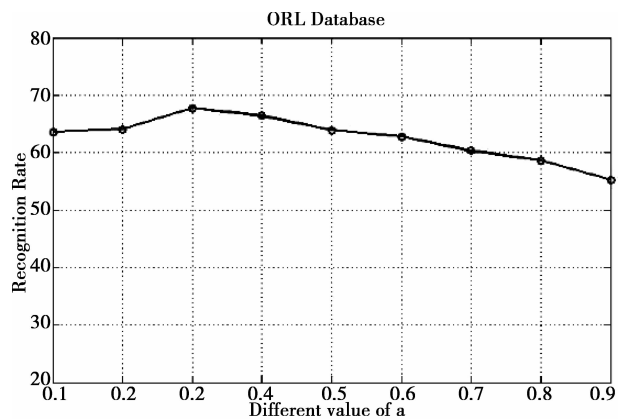


图 5 α 取不同值时 ORL 数据下的识别率

从上图可以得知, α 取 0.3 时, 本文算法在 FERET 数据库上的效果最好, 接近 70%。

3.2 不同权重因子 α 对算法的影响

表 1 不同算法在不同数据库下识别率

	PCA	2DPCA	(2D) ² PCA	LBP	G2DPCA
Yale	44	48	50	75	82($\alpha=0.6$)
FERET	47	60	65	70	85($\alpha=0.6$)
ORL	64	66	68	57	68($\alpha=0.3$)

在 Yale 数据库下, 可以看到 G2DPCA 在 α 取 0.6 时的单样本识别率明显高于传统算法, 以及基于全局特征的提取算法 (PCA, 2DPCA, (2D)²PCA) 在 Yale 上的单样本识别率均较低。而基于局部特征提取的 LBP 算法相对较高, 识别率达到 75%, 融合了局部和全局特征的 G2DPCA 算法最高, 达到 82%。

在 FERET 数据库下, 可以看到 G2DPCA 在 α 取 0.6 时的单样本识别率明显高于传统算法, 以及基于全局特征的提取算法 (PCA, 2DPCA, (2D)²PCA) 在 FERET 上的单样本识别率均优于在 Yale 数据库上的识别率, 但还是较低。而基于局部特征提取的 LBP 算法相对较高, 识别率达到 70%, 融合了局部和全局特征的 G2DPCA 算法最高, 达到 85%。

在 ORL 数据库下, 可以看到 G2DPCA 在 α 取 0.3 时的单样本识别率明显高于传统算法, 以及基于全局特征的提取算法 (PCA, 2DPCA, (2D)²PCA) 在 Yale 上的单样本识别率相对基于局部特征提取的 LBP 算法识别率相对较高, 达到 65% 左右, 其中, (2D)²PCA 达到了 68%。融合了局部和全局特征的 G2DPCA 算法与 (2D)²PCA 持平, 也是 68%。

4 结论

提出了基于 2DPCA 和图像梯度的单样本识别方法。考虑了通过 2DPCA 提取图像全局特征信息, 然后使用图像梯度提取图像局部纹理特征信息, 将两种方法相融合, 通过权重因子控制全局特征或者局部特征在识别中所占比例, 实验表明本文算法较传统算法有了一定的提升。

参考文献:

[1] Tan X, Chen S, Zhou Z H, et al. Face recognition from a single image per person: A survey[J]. Pattern Recognition, 2006, 39(9): 1725-1745.
 [2] Lu J, Tan Y P, Wang G. Discriminative multimanifold

analysis for face recognition from a single training sample per person[J]. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 2013, 35(1): 39-51.

[3] Liu N, Lai J H, Zheng W S. A facial sparse descriptor for single image based face recognition [J]. *Neurocomputing*, 2012, 93: 77-87.

[4] Zeng X, Huang H. Super-resolution method for multiview face recognition from a single image per person using nonlinear mappings on coherent features [J]. *IEEE Signal Processing Letters*, 2012, 19(4): 195-198.

[5] Kuo C H, Lee J D. Face recognition based on a two-view projective transformation using one sample per subject[J]. *Computer Vision, IET*, 2012, 6(5): 489-498.

[6] Kanade T. *Picture Processing by Computer Complex and Recognition of Human Faces* [M]. Kyoto: Department of Information Science, Kyoto University, 1973, 48-62P.

[7] Brunelli R, Poggio T. Face Recognition: Features versus Templates [M]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1993 15(10): 1042-1052P.

[8] Cox J, Ghosn J, Yianilos P N. Feature-based Face Recognition Using Mixture-distance [M]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, an Francisco, CA, USA, 1996: 209-216P.

[9] David B, Poggio T. Face Recognition from One Example View[M]. *IEEE International Conference on Computer Vision*, Cambridge, MA, USA, 1995: 500-507P.

[10] Chen S, Liu J, Zhou Z. Making FLDA applicable to Face Recognition with One Sample per Person[M]. *Pattern Recognition*, 2004, 37(7): 1553-1555P.

[11] Liu C J, Wechsler H. A gabor feature classifier for face recognition [C]//*Proceedings of Eighth IEEE International Conference on Computer Vision*, July 7-14, 2001, Vancouver, Canada. Piscataway: IEEE Press, 2001, 2: 270-275.

[12] Ojala T, Pietikainen M, Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns [J]. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 2002, 24(7): 971-987.

[13] Zhang T, Tang Y Y, Fang B, et al. Face recognition under varying illumination using gradientfaces [J]. *Image Processing, IEEE Transactions on*, 2009, 18(11): 2599-2606.

[14] Yang J, Zhang D, Frangi A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition [J]. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 2004, 26(1): 131-137.

(编辑 欧阳雪梅)