

文章编号:1001-9081(2009)07-1927-03

## 基于 2DLDA 与 SVM 的人脸识别算法

甘俊英, 何思斌

(五邑大学 信息学院, 广东 江门 529020)

(hesibin123@163.com)

**摘要:**二维线性鉴别分析(2DLDA)算法能有效解决线性鉴别分析(LDA)算法的“小样本”效应,支持向量机(SVM)具有结构风险最小化的特点,将两者结合起来用于人脸识别。首先,利用小波变换获取人脸图像的低频分量,忽略高频分量;然后,用 2DLDA 算法提取人脸图像低频分量的线性鉴别特征,用“一对多”的 SVM 多类分类算法完成人脸识别。基于 ORL 人脸数据库和 Yale 人脸数据库的实验结果验证了 2DLDA + SVM 算法应用于人脸识别的有效性。

**关键词:**小波变换;二维线性鉴别分析;支持向量机;人脸识别

**中图分类号:** TP391 **文献标志码:** A

## Face recognition based on 2DLDA and SVM

GAN Jun-ying, HE Si-bin

(School of Information, Wuyi University, Jiangmen Guangdong 529020, China)

**Abstract:** "Small sample size" problem of LDA algorithm can be overcome by two-dimensional LDA (2DLDA), and Support Vector Machine (SVM) has the characteristic of structural risk minimization. In this paper, two methods were combined and used for face recognition. Firstly, the original images were decomposed into high-frequency and low-frequency components by Wavelet Transform (WT). The high-frequency components were ignored, while the low-frequency components can be obtained. Then, the linear discriminant features were extracted by 2DLDA, and "one vs rest", strategy of SVMs for multiclass classification was chosen to perform face recognition. Experimental results based on ORL (Olivetti Research Laboratory) face database and Yale face database show the validity of 2DLDA + SVM algorithm for face recognition.

**Key words:** wavelet transform; Two-Dimensional Linear Discriminant Analysis (2DLDA); Support Vector Machine (SVM); face recognition

### 0 引言

人脸识别技术在 20 世纪初就受到了研究者的关注,现已广泛应用于安全领域。人脸与虹膜、指纹等生物特征一样,具有唯一性和相对稳定性,且人脸图像的获取具有非接触性、易获取性、无伤害性、操作简单等特点。因此,人脸识别的研究与发展对提高社会安全识别系统、增加识别的准确性与高效性有重要意义。

人脸识别要取得较好的识别率,有两个关键的步骤。第一,提取稳定、有效的鉴别特征。稳定的特征可以有效地去除光照、表情和姿态变化等产生的影响。第二,分类器的选择。一个优秀、合理的分类器将会直接提高人脸识别的识别率。2DLDA(two-dimensional LDA)算法<sup>[1]</sup>源于 LDA 算法<sup>[2-3]</sup>,能有效地解决 LDA 算法的“小样本问题”<sup>[4]</sup>,它直接将人脸图像灰度矩阵作为样本,提取出最具判别能力的人脸特征,这些特征满足样本类间离散度和类内离散度的比值最大。支持向量机(Support Vector Machine, SVM)<sup>[5-6]</sup>是近年来研究的热点,并已应用于人脸识别<sup>[7-9]</sup>。基本思想是通过核映射,将输入样本空间非线性变换到另一个高维空间,然后在这个新的空间中求取样本的最优分类超平面。最优分类超平面满足结构风险最小化,得到的解为全局最优解。本文运用 2DLDA 提取人脸特征,然后结合“一对多”的 SVM 多类分类算法完成

人脸识别,实验结果与 PCA + LDA<sup>[10-11]</sup>和 2DLDA 算法相比较,表明 2DLDA + SVM 算法应用于人脸识别的有效性。

### 1 算法模型

本文的人脸识别模型如图 1 所示。首先,用小波变换<sup>[12]</sup>提取人脸图像的低频分量;然后,由 2DLDA 算法提取人脸图像低频分量的鉴别特征;最后,用 SVM 算法完成人脸识别。文献[13]研究了人脸表情和光照的变化与其频谱的关系,他们发现微小的表情变化与少许的光照变化只会影响局部光强度流,如果用频率来表达只会影响高频部分。因此,去除人脸图像小波分解后的高频分量,只用低频分量来表达人脸图像将会取得较好的效果。下面重点探讨 2DLDA 算法与 SVM 分类器。



图 1 2DLDA + SVM 算法的人脸识别模型

#### 1.1 2DLDA 算法

2DLDA 与 LDA 算法在表征人脸图像时,LDA 算法用一个向量,而 2DLDA 算法用一个矩阵。假设  $C$  个模式类别表示为  $A^1, A^2, A^3, \dots, A^C$ , 每类样本有  $n$  个,总数为  $N$ ;  $A_j^i$  为  $m \times l$  维矩阵,表示第  $i(i = 1, 2, 3, \dots, C)$  类的第  $j(j = 1, 2, 3, \dots, n)$

收稿日期:2009-01-13;修回日期:2009-03-12。

基金项目:广东省自然科学基金资助项目(07010869,032356);广东省江门市科技攻关项目(江财企[2006]59号)。

作者简介:甘俊英(1964-),女,江西樟树人,教授,博士,主要研究方向:生物特征融合与识别;何思斌(1986-),男,江西萍乡人,硕士研究生,主要研究方向:生物特征信息处理与识别。

个样本。则  $C$  类样本各自的类内均值  $\bar{A}^i = \frac{1}{n} \sum_{j=1}^n A_j^i$ ;  $C$  类样本总均值  $\bar{A} = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^n A_j^i$ 。因此,  $C$  类样本总的类内离散度矩阵  $S_w$  为:

$$S_w = \sum_{i=1}^c \sum_{j=1}^n (A_j^i - \bar{A}^i)^T (A_j^i - \bar{A}^i) \quad (1)$$

$C$  类样本总的类间离散度矩阵  $S_b$  为:

$$S_b = \sum_{i=1}^c (\bar{A}^i - \bar{A})^T (\bar{A}^i - \bar{A}) \quad (2)$$

2DLDA 准则函数  $J(w)$  定义为:

$$J(w) = \frac{w^T S_b w}{w^T S_w w} \quad (3)$$

为使投影后的线性鉴别特征具有最优的分类能力,最优投影向量  $w_{opt}$  应使得准则函数  $J(w)$  最大。求取 2DLDA 算法的最优鉴别矢量  $w_{opt}$  可通过求取广义线性方程特征矢量与特征值的问题,即:

$$S_b S_w^{-1} w_{opt} = \lambda w_{opt} \quad (4)$$

其中,  $\lambda$  为  $S_b S_w^{-1}$  的最大特征值,  $w_{opt}$  即为  $\lambda_i$  对应的特征矢量。通常选取一个鉴别矢量作为投影方向是不够的,所以选  $S_b S_w^{-1}$  的  $d$  个较大特征值对应的特征矢量  $w_1, w_2, w_3, \dots, w_d$  作为投影方向,则可得最优投影矩阵  $W_{opt} = [w_1, w_2, w_3, \dots, w_d]$ 。

## 1.2 SVM 算法

假设两类不可分训练样本集  $\{(x_i, y_i), i = 1, 2, 3, \dots, n\}$ 。其中  $x_i \in \mathbf{R}^m$  为第  $i$  个训练样本,  $y_i \in \{-1, 1\}$  为样本类别标签。将样本通过非线性映射  $\Phi: x_i \rightarrow \Phi(x_i)$  映射到高维线性可分空间  $H$  中,则训练样本集又可表示为  $\{(\Phi(x_i), y_i); i = 1, 2, 3, \dots, n\}$ 。

求解最优分类超平面可表示为约束优化问题<sup>[8]</sup>

$$\min \frac{1}{2} \|w\|^2 \quad (5)$$

约束条件为  $\forall i, y_i(w \cdot \Phi(x_i) + b) - 1 \geq 0$ 。

这是一个凸优化问题<sup>[6]</sup>。其中,  $w$  是最优分类超平面的法线向量,  $b$  为一常量,  $\| \cdot \|$  表示欧式距离。引入拉格朗日乘子  $a = a_i (i = 1, 2, 3, \dots)$ , 令  $a_i [y_i(w \cdot \Phi(x_i) + b) - 1] = 0$ , 则可得拉格朗日方程:

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n a_i y_i (w \cdot \Phi(x_i) + b) + \sum_{i=1}^n a_i \quad (6)$$

于是,可得:

$$\frac{\partial}{\partial w} L(w, b, a) = 0 \Rightarrow w = \sum_{i=1}^n a_i y_i \Phi(x_i)^T$$

$$\frac{\partial}{\partial b} L(w, b, a) = 0 \Rightarrow \sum_{i=1}^n a_i y_i = 0; a_i > 0, \forall i$$

因此,式(6)的 Wolfe 对偶表达式可写为:

$$L(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j (\Phi(x_i)^T \cdot \Phi(x_j)) \quad (7)$$

约束条件为  $\forall i, a_i > 0, \sum_{i=1}^n a_i y_i = 0$ 。

对于任意一个测试样本  $x$ , 判决函数为:

$$f(x) = \text{sign}(w \cdot \Phi(x) + b) = \text{sign}\left(\sum_{i=1}^n a_i y_i \Phi(x_i) \cdot \Phi(x) + b\right) \quad (8)$$

式(8)中只涉及  $\Phi(\cdot)$  的点积运算,于是定义核函数

$K(x_i, x_j) = \Phi(x_i)^T \cdot \Phi(x_j)$  来避免复杂的非线性映射  $\Phi: x_i \rightarrow \Phi(x_i)$ 。常用的核函数有径向基核函数:  $K(x_i, x_j) = \exp(-\sigma \|x_i - x_j\|^2)$ ; 多项式核函数:  $K(x_i, x_j) = (\sigma + \gamma(x_i \cdot x_j))^\delta$ ; 双曲正切核函数:  $K(x_i, x_j) = \tanh(\sigma(x_i \cdot x_j) - \delta)$ 。因此,判决函数又可写为:

$$f(x) = \text{sign}\left(\sum_{i=1}^n a_i y_i K(x_i, x) + b\right) \quad (9)$$

人脸识别是一个多类分类问题。在多类情况下, SVM 有两种基本策略:

1) 1 对 1 判别策略 (One Versus One, 1-V-1)。在此策略中,对于  $C$  类样本,需要训练  $\frac{C(C-1)}{2}$  个 SVM 分类器<sup>[8]</sup>。

2) 1 对多判别策略 (One Versus Rest, 1-V-R)。在此策略中,对于  $C$  类样本,需要训练  $C$  个 SVM 分类器<sup>[9]</sup>。

## 2 应用于人脸识别

首先,通过 Harr 小波变换获取人脸图像的低频分量,然后分别计算人脸图像低频分量的类间和类内离散度矩阵,由(4)式求取人脸图像的最优投影矩阵  $W_{opt}$ ,则人脸低频分量向  $W_{opt}$  投影,得到人脸图像的 2DLDA 特征。将人脸图像的 2DLDA 特征转换成一行向量,选取二次多项式核函数  $K(x_i, x_j) = ((x_i \cdot x_j) + 1)^2$ ,采用“一对多”的 SVM 多类分类策略<sup>[9]</sup>完成人脸识别。

### 2.1 实验对象

本文的实验对象取自 ORL 人脸数据库和 Yale 人脸数据库。ORL 人脸数据库是基于表情和姿态变化的人脸数据库,该数据库有 40 个人,每人 10 张不同姿态和表情的人脸图像,总共 400 张;这些图像是从不同角度拍摄的,分辨率为  $112 \times 92$ ,灰度级为 256。每张人脸图像通过一次小波变换获取的低频分量分辨率为  $63 \times 53$ 。

Yale 人脸数据库共有 15 人,每人 11 张不同表情、姿态和受光照影响的图像,分辨率为  $243 \times 320$ ,灰度级为 256,实验时每张人脸图像先通过两次小波变换,获取的低频分量分辨率为  $72 \times 91$ 。

### 2.2 实验结果及分析

#### 2.2.1 PCA + LDA 与 2DLDA 的性能分析

为比较 PCA + LDA 与 2DLDA 算法的性能,在 ORL 人脸数据库上选取每人前 5 幅人脸图像作为训练样本,识别结果如图 2 所示。




图 2 基于 ORL 人脸数据库 PCA + LDA 与 2DLDA 的正确识别率

Yale 人脸数据库上选取每人前 7 幅人脸图像作为训练样

本分别实验,识别结果分别如图3所示。实验中PCA+LDA与2DLDA算法采用欧式距离分类器。




图3 基于Yale人脸数据库PCA+LDA与2DLDA的正确识别率

由图2可知,当选取ORL人脸数据库每人前5幅图像为训练样本时,随着选取的特征维数的增加,2DLDA的识别率在达到极值后,有下降的趋势;2DLDA识别率的极值比PCA+LDA高出1.5%。由图3可知,在Yale人脸数据库选取每人前7幅图像为训练样本时,PCA+LDA的正确识别率极值不到90%,而2DLDA的识别率极值高于96%。

#### 2.2.2 2DLDA+SVM算法的性能分析

在ORL人脸数据库上,分别选取每人前5张和前7张人脸图像作为训练样本,剩余的作为测试样本,一次小波变换后选取每人前20个2DLDA特征完成实验,实验结果如表1所示。Yale人脸数据库上,分别选取每人前7张和前9张作为训练样本,剩余的作为测试样本完成实验,两次小波变换后选取每人前20个2DLDA特征完成实验,实验结果如表2所示。

表1 ORL人脸数据库上的实验结果

算法	训练样本数/类别数	测试样本数/类别数	识别率/%
PCA+LDA	5/40	5/40	93.50
2DLDA	5/40	5/40	95.00
2DLDA+SVM	5/40	5/40	96.50
PCA+LDA	7/40	3/40	96.67
2DLDA	7/40	3/40	98.33
2DLDA+SVM	7/40	3/40	98.33

表2 Yale人脸数据库上的实验结果

算法	训练样本数/类别数	测试样本数/类别数	识别率/%
PCA+LDA	7/15	4/15	88.33
2DLDA	7/15	4/15	96.67
2DLDA+SVM	7/15	4/15	96.67
PCA+LDA	9/15	2/15	96.67
2DLDA	9/15	2/15	96.67
2DLDA+SVM	9/15	2/15	100.00

由表1可知,在ORL人脸数据库上,当训练样本为5时,2DLDA+SVM的识别率为96.50%,比PCA+LDA和2DLDA分别提高了3.0%和1.5%;当训练样本为7时,2DLDA+SVM的识别率为98.33%,与2DLDA识别率相等,而PCA+LDA只有96.67%。由表2可知,在Yale人脸数据库上,选取训练样本数分别为7和9时,2DLDA+SVM的识别率分别为96.67%和100%。当每人的训练样本数为7时,PCA+LDA

和2DLDA的识别率分别只有88.33%与96.67%;训练样本数为9时,2DLDA+SVM的识别率分别比PCA+LDA和2DLDA高出3.33%。

### 3 结语

本文利用小波变换获得人脸图像的低频分量,去除了人脸图像高频分量的影响;2DLDA算法提取人脸最具鉴别能力的特征,解决了LDA算法的“小样本”效应;基于结构风险最小化的SVM分类算法完成人脸识别,识别率比PCA+LDA和2DLDA算法有提高。然而,SVM选择不同的核函数对识别率的影响,以及在复杂的背景下,如何提高识别率和识别效率仍有待深入研究。

#### 参考文献:

- [1] INOUE K, URAHAMA K. Non-iterative two-dimensional linear discriminant analysis for face recognition[R]. IPSJSIG, 2006: 351-354.
- [2] XU YONG, YANG JING-YU, JIN ZHONG. A novel method for Fisher discriminant analysis[J]. Pattern Recognition, 2004, 37(2): 381-384.
- [3] LU J, PLATANOTIS K N, VENETSANOPULAOS A N. Face recognition using lda-based algorithms[J]. IEEE Transactions on Neural Networks, 2003, 14(1): 195-200.
- [4] SANQUANASAT P, ASDORNWISED W, JITAPUNKUL S, et al. Two-dimensional linear discriminant analysis of principal component vectors for face recognition[C]// IEEE International Conference on Acoustics, Speech and Signal Processing. New York: IEEE, 2006: 2164-2170.
- [5] CRISTIANINI N, TAYLOR J S. An introduction to support vector machines[M]. Cambridge: Cambridge University Press, 2000.
- [6] CATANZARO B, SUNDARAM N, KEUTZER K. Fast support vector machine training and classification on graphics processors[C]// Proceedings of the 25th International Conference on Machine Learning. New York: ACM, 2008: 104-111.
- [7] LI ZHIFENG, TANG XIAOOU. Using support vector machines to enhance the performance of Bayesian face recognition[J]. IEEE Transactions on Information Forensics and Security, 2007, 2(2): 174-180.
- [8] GUO G, LI S Z, CHAN K. Face recognition by support vector machines[C]// IEEE International Conference on Automatic Face and Gesture Recognition. New York: IEEE, 2000: 196-201.
- [9] HEISELE B, HO P, POGGIO T. Face recognition with support vector machines: Global versus component-based approach[C]// Proceedings of the 8th IEEE International Conference on Computer Vision. New York: IEEE, 2001: 688-694.
- [10] MARCIALIS G L, ROLI F. Fusion of LDA and PCA for face recognition[EB/OL]. [2008-11-20]. <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.11.5717>.
- [11] ZHAO W, KRISHANASWAMY A, CHELLAPPA R, et al. Discriminant analysis of principal components for face recognition[C]// 3rd IEEE International Conference on Automatic Face and Gesture Recognition. Washington, DC: IEEE Computer Society, 1998: 336-341.
- [12] SUJARITHA M, ANNADURAI S. Face recognition using wavelet transform and locally discriminating projection[C]// International Conference on Computational Intelligence and Multimedia Applications. Washington, DC: IEEE Computer Society, 2007: 436-440.
- [13] NASTAR C, AYACHE N. Frequency-based nonrigid motion analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996, 18(11): 1067-1079.