

文章编号:1001-9081(2008)05-1263-04

一种融合 KPCA 和 KDA 的人脸识别新方法

周晓彦^{1,2}, 郑文明³

(1. 南京信息工程大学 电子信息工程学院,南京 210044; 2. 东南大学 信息科学与工程学院,南京 210096;
3. 东南大学 学习科学研究中心,南京 210096)
(xiaoyan_zhou@seu.edu.cn)

摘要:核判别分析(KDA)和核主成分分析(KPCA)分别是线性判别分析(LDA)和主成分分析(PCA)在核空间中的非线性推广,提出了一种融合 KDA 和 KPCA 的特征提取方法并应用于人脸识别中,该方法综合利用 KDA 和 KPCA 的优点来提高人脸识别的性能。此外,还提出了一种广义最近特征线(GNFL)方法来构造有效的分类器。实验结果证明:提出的方法获得了更好的识别结果。

关键词:核判别分析;核主成分分析;广义最近特征线;人脸识别

中图分类号: TP391.41 文献标志码:A

Novel face recognition method based on KPCA plus KDA

ZHOU Xiao-yan^{1,2}, ZHENG Wen-ming³

(1. School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing Jiangsu 210044, China;
2. School of Information Science and Engineering, Southeast University, Nanjing Jiangsu 210096, China;
3. Research Center for Learning Science, Southeast University, Nanjing Jiangsu 210096, China)

Abstract: Kernel Discriminant Analysis (KDA) and Kernel Principal Component Analysis (KPCA) are the nonlinear extensions of Linear Discriminant Analysis (LDA) and Principal Component Analysis (PCA) respectively. In this paper, we presented a feature extraction algorithm by combining KDA and KPCA to extract reliable and robust features for recognition. Furthermore, a generalized nearest feature line (GNFL) method was also presented for constructing powerful classifier. The performance of the proposed method was demonstrated through real data.

Key words: Kernel Discriminant Analysis (KDA); Kernel Principal Component Analysis (KPCA); Generalized Nearest Feature Line (GNFL); face recognition

0 引言

人脸识别是统计模式识别领域中一个非常热门的研究课题,具有非常广泛的应用前景。近几年来,人脸识别技术得到了很大的发展,许多优秀的方法和算法^[1,2]相继被提出。其中,特征脸方法(Eigenfaces)方法^[3]和 Fisher 脸方法(Fisherfaces)^[4]是最为著名的两种。特征脸方法的基本思想是寻求一组特征脸,使得利用该特征脸进行人脸的重构具有最小的均方误差。简单说,特征脸方法就是通过主成分分析(Principal Component Analysis, PCA)来进行人脸识别,所提取的特征能较好地反映出人脸的分布信息。与特征脸方法类似,Fisher 脸方法也是通过求解一组特征矢量来进行人脸识别,所不同的是 Fisher 脸采用的是线性判别分析(Linear Discriminant Analysis, LDA)方法来求解该组特征矢量,所提取的特征主要体现人脸的判别信息。因此,PCA 方法和 LDA 方法在一定程度上是相互补充的。为了得到性能更稳定、鲁棒性更高的人脸识别方法,一种简单可行的方法就是充分利用 PCA 和 LDA 各自的优点来进行特征提取。另外,尽管 PCA 和 LDA 已经得到较为成功的应用,但二者在本质上仍是线性特征提取方法,因而也仅仅对线性模式具有较好的分类效果。在人脸识别中,由于人脸模式常常受光照、视角等因素影响而

体现出高度的非线性特性。因而为了解决线性 PCA 和 LDA 在处理非线性问题时的不足,文献[5]首次利用核函数方法把 PCA 推广到非线性领域,提出了核主成分分析方法(Kernel Principal Component Analysis, KPCA)。采用同样的思想,文献[6]提出了 LDA 的核化版本,即核判别分析方法(Kernel Discriminant Analysis, KDA),或叫广义判别分析方法(Generalized Discriminant Analysis, GDA)。文献[7]把 KPCA 方法和 KDA 方法分别应用于人脸识别中,提出了核特征脸和核 Fisher 脸方法,并得到比特征脸和 Fisher 脸更好的识别结果。

需要注意的是:在采用 KDA 方法进行人脸识别时,核空间的维数通常远大于训练样本的数目,即所谓的“小样本问题”^[8,9]。由于“小样本问题”的存在,使得采用 KDA 方法后样本的类内散射信息丢失,此时所有的最佳判别矢量都位于类内散射矩阵的零空间中^[10]。这种情况下导致了所谓的“过学习”现象。为了弥补 KDA 所存在的不足同时提高系统的识别性能,本文在文献[10]的研究工作的基础上,提出了一种融合 KDA 和 KPCA 优点的学习算法。该方法分为三个步骤:1)求解 KDA 的最佳判别矢量;2)基于 KPCA 准则函数求得另一组投影矢量;3)将两组投影矢量融合成另一组复特征矢量以用于特征提取。此外,本文还提出了一种广义最近特征线

收稿日期:2007-11-29;修回日期:2008-01-12。

基金项目:国家自然科学基金资助项目(60503023);南京信息工程大学校内科研基金资助项目(Y603)。

作者简介:周晓彦(1980-),女,江苏淮安人,讲师,博士研究生,主要研究方向:模式识别、机器学习; 郑文明(1974-),男,福建南安人,教授,博士生导师,主要研究方向:模式识别、计算机视觉、机器学习。

分类器,它是最近特征线^[11]方法在复空间中的推广。最近特征线通过扩展人脸图像的表示范围来提高最近邻分类器的性能。本文先将最近特征线方法从实特征空间扩充到复特征空间,再利用该分类器进行人脸的分类。

1 相关工作回顾

假设 $X = \{\mathbf{x}_i^j | i = 1, 2, \dots, c; j = 1, 2, \dots, N_i\}$ 是 n 维空间中的样本集,其中 c 表示样本的类别数, \mathbf{x}_i^j 表示第 i 类样本集中的第 j 个样本, N_i 是第 i 类样本的个数。令 X_i 表示第 i 类样本集,则可得到 $X = \bigcup_{i=1}^c X_i$, $N = \sum_{i=1}^c N_i$ 。设 Φ 是从样本空间到某一特征空间 F 的一个非线性映射,即如式(1):

$$\Phi: X \rightarrow F, \mathbf{x} \rightarrow \Phi(\mathbf{x}) \quad (1)$$

则在 F 中样本的类间散射矩阵 S_B^Φ ,类内散射矩阵 S_W^Φ 和总体散射矩阵 S_T^Φ 可表示为:

$$S_B^\Phi = \sum_{i=1}^c N_i (\mathbf{u}_i^\Phi - \mathbf{u}^\Phi)(\mathbf{u}_i^\Phi - \mathbf{u}^\Phi)^T \quad (2)$$

$$S_W^\Phi = \sum_{i=1}^c \sum_{j=1}^{N_i} (\Phi(\mathbf{x}_i^j) - \mathbf{u}_i^\Phi)(\Phi(\mathbf{x}_i^j) - \mathbf{u}_i^\Phi)^T \quad (3)$$

$$S_T^\Phi = \sum_{i=1}^c \sum_{j=1}^{N_i} (\Phi(\mathbf{x}_i^j) - \mathbf{u}^\Phi)(\Phi(\mathbf{x}_i^j) - \mathbf{u}^\Phi)^T \quad (4)$$

其中 \mathbf{x}^T 表示 \mathbf{x} 的转置, \mathbf{u}_i^Φ 表示 F 中第 i 类样本的均值, \mathbf{u}^Φ 表示所有样本的均值, 定义如式(5):

$$\mathbf{u}_i^\Phi = \frac{1}{N_i} \sum_{j=1}^{N_i} \Phi(\mathbf{x}_i^j), \mathbf{u}^\Phi = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^{N_i} \Phi(\mathbf{x}_i^j) \quad (5)$$

1.1 核判别分析(KDA)

KDA 是 LDA 在核空间中的非线性推广,其最佳判别矢量定义如下:第一个判别矢量 ω_1 是在空间 F 中使得 Fisher 准则 $J_F(\omega)$ 最大的单位矢量,其中 Fisher 判别准则定义如式(6):

$$J_F(\omega) = \frac{\omega^T S_B^\Phi \omega}{\omega^T S_T^\Phi \omega} \quad (6)$$

根据判别分析理论^[9], ω_1 是以下特征方程对应于最大特征值的特征矢量:

$$S_B^\Phi \omega = \lambda S_T^\Phi \omega \quad (7)$$

假设前 $i-1$ 个判别矢量已经得到,则第 i ($i > 1$) 个判别矢量 ω_i 是在满足以下约束条件下对应于特征方程(7)的最大特征值的特征矢量:

$$\omega_i^T S_T^\Phi \omega_j = 0; j = 1, 2, \dots, i-1 \quad (8)$$

1.2 核主成分分析(KPCA)

KPCA 是 PCA 在核空间中的非线性推广,其各主成分矢量生成方式如下:第一个主成分矢量 $\tilde{\omega}_1$ 是使得 $J_P(\omega)$ 最大的单位矢量,其中 $J_P(\omega)$ 定义为式(9):

$$J_P(\omega) = \frac{\omega^T S_T^\Phi \omega}{\omega^T I^\Phi \omega} \quad (9)$$

其中 I^Φ 是特征空间 F 中的单位阵。由判别分析理论知: $\tilde{\omega}_1$ 是对应于特征方程 $\lambda \omega = S_T^\Phi \omega$ 最大特征值的特征矢量。假设前 $i-1$ 个判别矢量已经得到,则第 i ($i > 1$) 个判别矢量 $\tilde{\omega}_i$ 为满足约束条件 $\tilde{\omega}_i^T S_T^\Phi \tilde{\omega}_j = 0 (j = 1, 2, \dots, i-1)$ 下对应于特征方程 $\lambda \omega = S_T^\Phi \omega$ 最大特征值的特征矢量。

1.3 最近特征线分类器

最近特征线(Nearest Feature Line, NFL) 分类器是对最近邻(Nearest Neighbor, NN) 分类器方法的扩展,其基本思想是通过对两样本点进行线性内插值和线性外插值来扩充样本

的容量,从而提高最近邻分类器的性能。具体方法为:假设 \mathbf{x} 是某一测试样本,对于第 i 类样本 $\mathbf{x}_i^j (j = 1, 2, \dots, N_i)$ 中的任意两点 \mathbf{x}_i^m 和 \mathbf{x}_i^n ,令 $\overline{\mathbf{x}_i^m \mathbf{x}_i^n}$ 表示通过它们的一条特征线,则 \mathbf{x} 和特征线 $\overline{\mathbf{x}_i^m \mathbf{x}_i^n}$ 之间的距离由式(10)给出:

$$d(\mathbf{x}, \overline{\mathbf{x}_i^m \mathbf{x}_i^n}) = \|\mathbf{x} - \mathbf{p}_{mn}^i\| \quad (10)$$

其中 $\|\cdot\|$ 表示欧氏距离, \mathbf{p}_{mn}^i 是 \mathbf{x} 到特征线 $\overline{\mathbf{x}_i^m \mathbf{x}_i^n}$ 上的投影(如图 1 所示)。

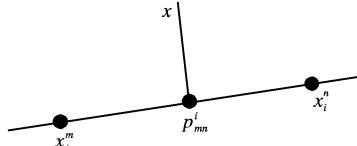


图 1 特征线和点到特征线的距离

2 融合 KDA 和 KPCA 的特征提取算法

在本节中,提出一种融合 KDA 和 KPCA 的特征提取方法,该方法包括三个步骤:1) 求解 KDA 的一组最佳判别矢量 $\omega_i (i = 1, 2, \dots, c-1)$;2) 求解基于准则函数 $J_P(\omega)$ 的另一组特征矢量,要求所求解得到的特征矢量与 KDA 的最佳判别矢量是统计不相关的;3) 将两种矢量融合成一组复判别矢量进行特征提取。设 $\omega_i (i = 1, 2, \dots, c-1)$ 是采用 KDA 算法^[9]求得的 $c-1$ 个最佳判别矢量,则第 j 个特征矢量 $\omega_j (j = c, c+1, \dots, 2c-2)$ 定义为满足统计不相关约束 $\omega_j^T S_T^\Phi \omega_i = 0 (i = 1, 2, \dots, j-1)$ 下使得 $J_P(\omega)$ 最大的单位矢量。为了求解判别矢量 $\omega_j (j = c, c+1, \dots, 2c-2)$,先引入定理 1,其详细证明过程可参考文献[8,9]:

定理 1 设 B 和 R 是半正定矩阵, V 是一个正定阵。定义判别准则函数为: $F(\varphi) = \frac{\varphi^T B \varphi}{\varphi^T V \varphi}$

令 φ_1 是使 $F(\varphi)$ 最大化的判别特征矢量, φ_{r+1} 是满足约束条件 $\varphi_{r+1}^T R \varphi_i = 0 (i = 1, 2, \dots, r)$ 下使 $F(\varphi)$ 最大的第 $r+1 (r \geq 1)$ 个判别矢量。则 φ_{r+1} 是特征方程 $P B \varphi = \lambda V \varphi$ 对应于最大特征值的特征向量,其中 $P = I - RD^T(DRV^{-1}RD^T)^{-1}DRV^{-1}$, $D = [\varphi_1 \varphi_2 \dots \varphi_r]^T$ 。

2.1 判别矢量求解

令 $\Phi(X) = [\Phi(\mathbf{x}_1^1) \dots \Phi(\mathbf{x}_1^{N_1}) \dots \Phi(\mathbf{x}_c^1) \dots \Phi(\mathbf{x}_c^{N_c})]$, 则由式(2)~(5), 可得:

$$S_B^\Phi = \Phi(X)(W - M)(W - M)^T(\Phi(X))^T \quad (11)$$

$$S_W^\Phi = \Phi(X)(I - W)(I - W)^T(\Phi(X))^T \quad (12)$$

$$S_T^\Phi = \Phi(X)(I - M)(I - M)^T(\Phi(X))^T \quad (13)$$

其中, $W = (W_l)_{l=1, 2, \dots, c}$ 是一个 $N \times N$ 的分块对角阵, W_l 是一个所有元素都等于 $1/N_l$ 的 $N_l \times N_l$ 矩阵, I 是一个 $N \times N$ 的单位阵, $M = (m_{ij})_{i=1, 2, \dots, N; j=1, 2, \dots, N}$ 是一个所有元素都等于 $1/N$ 的 $N \times N$ 矩阵。

设 $k(x_i, x_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle = (\Phi(\mathbf{x}_i))^T \Phi(\mathbf{x}_j)$ 是 F 空间中的核函数,其中 $\langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$ 表示 $\Phi(\mathbf{x}_i)$ 和 $\Phi(\mathbf{x}_j)$ 的点积。对于任意的 p 和 q , 可用式(14)表示这个核函数:

$$(k_{pq})_{pq} = \langle \Phi(\mathbf{x}_p^i), \Phi(\mathbf{x}_q^j) \rangle = (\Phi(\mathbf{x}_p^i))^T \Phi(\mathbf{x}_q^j) \quad (14)$$

令 $\mathbf{K}_{pq} = (k_{pq})_{pq} (i = 1, 2, \dots, N_p; j = 1, 2, \dots, N_q)$ 是 $N_p \times N_q$ 矩阵, $\mathbf{K} = (\mathbf{K}_{pq})_{p=1, 2, \dots, c; q=1, 2, \dots, c}$ 是 $N \times N$ 矩阵, 则可得到 $\mathbf{K} = (\Phi(X))^T \Phi(X)$ 。从文献[8~10]中可知, KDA 或 KPCA 的解 ω 可写成:

$$\boldsymbol{\omega} = \Phi(\mathbf{X})(\mathbf{I} - \mathbf{M})\boldsymbol{\alpha} \quad (15)$$

其中 $\boldsymbol{\alpha}$ 是 $N \times 1$ 矢量。因此, KDA 的判别矢量可以表示为: $\boldsymbol{\omega}_i = \Phi(\mathbf{X})(\mathbf{I} - \mathbf{M})\boldsymbol{\alpha}_i$ ($i = 1, 2, \dots, c-1$), 而第 j ($j > c-1$) 个判别矢量 $\boldsymbol{\omega}_j = \Phi(\mathbf{X})(\mathbf{I} - \mathbf{M})\boldsymbol{\alpha}_j$ 是在满足约束条件 $\boldsymbol{\omega}_j^T S_T^\Phi \boldsymbol{\omega}_i = \boldsymbol{\alpha}_j^T T \boldsymbol{\alpha}_i = 0$ ($i = 1, 2, \dots, j-1$) 下使得式(16) 最大的单位矢量:

$$J_p(\boldsymbol{\omega}) = \bar{J}_p(\boldsymbol{\alpha}) = \frac{\boldsymbol{\alpha}^T T \boldsymbol{\alpha}}{\boldsymbol{\alpha}^T \tilde{\mathbf{K}} \boldsymbol{\alpha}} \quad (16)$$

其中, $T = (\mathbf{I} - \mathbf{M})^T \mathbf{K} (\mathbf{I} - \mathbf{M}) (\mathbf{I} - \mathbf{M})^T \mathbf{K} (\mathbf{I} - \mathbf{M})$, $\tilde{\mathbf{K}} = (\mathbf{I} - \mathbf{M})^T \mathbf{K} (\mathbf{I} - \mathbf{M})$ 。由定理 1 可知, $\boldsymbol{\alpha}_j$ 是对应于下面特征方程最大特征值的特征向量:

$$P \boldsymbol{\alpha} = \lambda \tilde{\mathbf{K}} \boldsymbol{\alpha} \quad (17)$$

其中 $P = \mathbf{I} - TD^T(DT\tilde{\mathbf{K}}^{-1}TD^T)^{-1}DT\tilde{\mathbf{K}}^{-1}$, $D = [\boldsymbol{\alpha}_1 \ \boldsymbol{\alpha}_2 \ \dots \ \boldsymbol{\alpha}_{j-1}]^T$ 。将 $\boldsymbol{\alpha}_j$ 除以 $\sqrt{\boldsymbol{\alpha}_j^T R \boldsymbol{\alpha}_j}$ 可使得对应的判别矢量 $\boldsymbol{\omega}_j$ 被归一化, 即 $\boldsymbol{\omega}_j^T \boldsymbol{\omega}_j = 1$ 。

2.2 特征提取

记 $E_1 = [\boldsymbol{\omega}_1 \ \boldsymbol{\omega}_2 \ \dots \ \boldsymbol{\omega}_{c-1}]$ 和 $E_2 = [\boldsymbol{\omega}_c \ \boldsymbol{\omega}_{c+1} \ \dots \ \boldsymbol{\omega}_{c-2}]$, 则 E_1 和 E_2 分别代表依 KDA 和 KPCA 准则求解得到的特征矢量矩阵。令 $E = E_1 + iE_2$, 其中 i 是虚数单位。则测试样本 t 到判别变换矩阵 E 上的投影可通过式(18) 算得:

$$z = E^H(\Phi(t) - u^\Phi) = Q^H(\mathbf{I} - \mathbf{M})^T(\Phi(\mathbf{X}))^T(\Phi(t) - \Phi(\mathbf{X})\mathbf{1}_N) = Q^T(\mathbf{I} - \mathbf{M})^T \kappa - Q^T(\mathbf{I} - \mathbf{M})^T \mathbf{K} \mathbf{1}_N \quad (18)$$

其中 H 表示复矩阵的转置, $\mathbf{1}_N$ 是一个所有元素都等于 $1/N$ 的 $N \times 1$ 矢量, 并且 $\kappa = [\kappa_1 \ \kappa_2 \ \dots \ \kappa_N]^T$, 其中 $\kappa_1 = k(x_1^1, t)$, $\kappa_2 = k(x_1^2, t)$, \dots , $\kappa_N = k(x_c^{N_c}, t)$ 。

3 基于 GNFL 的模式分类

在本节中, 将考虑 NFL 方法在复空间中的推广, 并提出广义最近特征线(Generalized Nearest Feature Line, GNFL)方法。现假设 z_i^j 是 $\Phi(x_i^j) - u^\Phi$ 到复变换矩阵 E 上的投影, 即

$$z_i^j = E^H(\Phi(x_i^j) - u^\Phi) \quad (19)$$

则通过复空间中两点 z_i^m 和 z_i^n 的广义特征线 $\overline{z_i^m z_i^n}$ 可定义如式(20):

$$\overline{z_i^m z_i^n} = \{z \mid z = z_i^m + \mu(z_i^n - z_i^m), \mu \in R\} \quad (20)$$

设 z 是复空间中的某一测试样本, 则 z 到 $\overline{z_i^m z_i^n}$ 之间距离的定义如式(21):

$$d(z, \overline{z_i^m z_i^n}) = \|z - p_{mn}^i\| = \|z - z_i^m - \mu(z_i^n - z_i^m)\| \quad (21)$$

其中 $p_{mn}^i = z_i^m + \mu(z_i^n - z_i^m)$ 是 z 到 $\overline{z_i^m z_i^n}$ 上的投影, $d(z, \overline{z_i^m z_i^n})$ 可按如下方式求解得到: 设 A_R 和 A_I 分别代表 $z - z_i^m$ 的实部和虚部, 且 B_R 和 B_I 分别代表 $z_i^n - z_i^m$ 的实部和虚部, 即:

$$z - z_i^m = A_R + iA_I, z_i^n - z_i^m = B_R + iB_I \quad (22)$$

由式(21)和式(22)可得:

$$\begin{aligned} \|z - p_{mn}^i\|^2 &= \| (A_R - \mu B_R) + i(A_I - \mu B_I) \|^2 = \\ &= (A_R - \mu B_R)^T (A_R - \mu B_R) + (A_I - \mu B_I)^T (A_I - \mu B_I) \end{aligned} \quad (23)$$

相应的拉格朗日方程为: $L(\mu) = (A_R - \mu B_R)^T (A_R - \mu B_R) + (A_I - \mu B_I)^T (A_I - \mu B_I)$, 求 L 对 μ 的偏导, 并设其等于零, 可得:

$$\frac{\partial L(\mu)}{\partial \mu} = -2(A_R - \mu B_R)^T B_R - 2(A_I - \mu B_I)^T B_I = 0 \quad (24)$$

由式(24)可得 $\mu = (A_R^T B_R + A_I^T B_I) / (B_R^T B_R + B_I^T B_I)$ 。于 z 到广义最近特征线 $\overline{z_{c^*}^m z_{c^*}^n}$ 的距离可定义为:

$$d(z, \overline{z_{c^*}^m z_{c^*}^n}) = \min_{1 \leq i \leq c} \min_{1 \leq i' < i \leq N_i} d(z, \overline{z_i^m z_i^n}) \quad (25)$$

其中 c^* 表示测试特征所属类别的标签。

4 实验

实验中采用 ORL 人脸数据库^[11] 和 Yale 人脸数据库^[4] 来测试本文所提出方法(KDA + KPCA + GNFL)的有效性。在每个实验中, 将整个数据库分为大小比例为 3:2 的两部分, 其中前面部分作为测试样本而后面部分则作为训练样本。为了便于进行实验对比, 分别采用 PCA、LDA、KPCA、KDA 等常用人脸识别方法进行了对比实验。实验中采用最近邻分类器来进行分类。核函数采用定义为: $k(x, y) = \exp(-\|x - y\|^2 / \sigma^2)$ 的高斯核函数, 其中 σ 是高斯核的参数。

4.1 ORL 人脸数据库上的实验

ORL 人脸数据库中共有 40 个人, 其中每个人包含了在不同时间, 光照稍微变化下的 10 幅不同的人脸图像。原始图像是灰度级为 256、尺寸大小为 112×92 的灰度图像, 为了减小计算量, 实验中对每幅图像下采样为 28×23 尺寸。表 1 显示了采用各种方法得到的实验结果, 图 2 则显示投影矢量个数与识别率的关系曲线。由表 1 和图 2 可得, KDA + KPCA + GNFL 方法取得了比 KDA 和 KPCA 更好的识别结果。

表 1 采用各种方法在 ORL 人脸数据库上的实验结果比较

方法	判别矢量个数	识别率/%	标准差/%
PCA	40	95.80	1.94
KPCA	40	95.80	1.87
LDA	39	96.45	1.90
KDA	39	96.40	1.98
LDA + PCA + GNFL	39	96.10	1.81
KDA + KPCA + GNFL	39	96.75	1.90

注: 表 1 中采用的核函数为高斯核, σ 的取值为 3×10^6 。

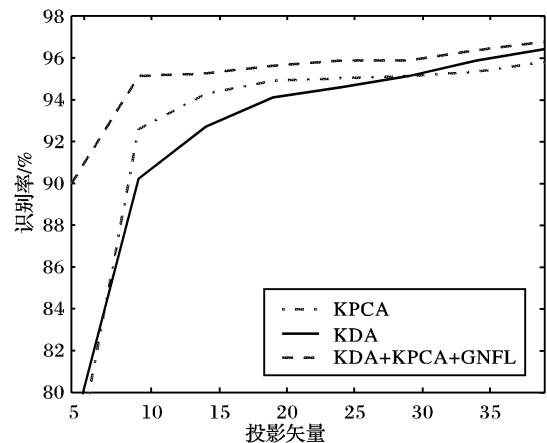


图 2 投影矢量和识别率的关系

4.2 Yale 人脸数据库上的实验

Yale 人脸数据库包含了 11 个人的 165 幅人脸图像, 每幅图像是灰度级为 256、尺寸为 243×320 的灰度图像。与第一个实验相似, 每幅图像被下采样为 23×28 尺寸, 然后再进行实验。表 2 显示了本次实验的结果, 从中可以看出, KDA + KPCA + GNFL 仍得到最高的识别率。另外, 为了进一步比较各种方法在高斯核参数下识别性能的变化情况, 对参数的不同取值进行了同样的实验。由图 3 可知, 各种识别方法的识

别率会受到不同参数值的影响,但是 KDA + KPCA + GNFL 仍取得了最好的识别结果。

表 2 采用各种方法在 Yale 人脸数据库上的实验结果比较

方法	特征空间	识别率/%	标准差/%
PCA	40	75.26	2.77
KPCA	40	75.20	2.84
LDA	14	83.33	2.50
KDA	14	83.51	2.41
LDA + PCA + GNFL	14	88.73	1.82
KDA + KPCA + GNFL	14	87.33	1.52

注:表 2 中采用的核函数为高斯核, σ 的取值为 4×10^7 。

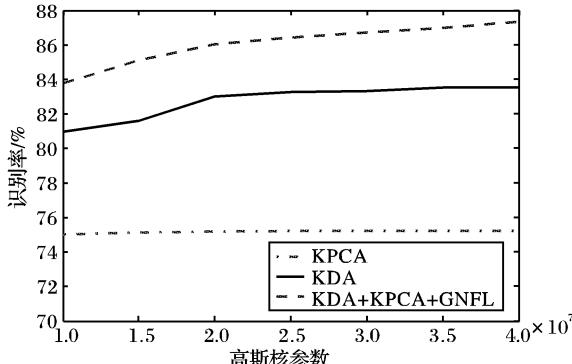


图 3 不同参数值和识别率的关系

5 结语

本文提出了一种新的基于核函数的学习算法,该算法融合了 KDA 和 KPCA 优点同时避免了它们各自的缺点。此外,本文还提出了 GNFL 分类器,并应用于人脸识别中。通过在国际著名人脸数据库上的实验,表明本文所提出的 KDA + KPCA + GNFL 方法可得到更好的识别效果。

参考文献:

- [1] SAMAL A, IYENGAR P. Automatic recognition and analysis of hu-

(上接第 1262 页)

别率不高是受到样本数较小、所用的直接奇异值识别方法识别率较低的限制。但是 DNA 计算应用在图像识别上,大量快速缩小识别范围是很成功的,达到了预期目的。

另外,这种方法在有新样本加入时不需要重新训练,新样本在统计范围外时直接扩展 DNA 存储链就可以了。

6 结语

本文提出的 DNA 计算结合奇异值的方法应用在人脸识别上,理论上较为成功,它的缺陷是在缩小识别范围后,识别率不高。这是受到奇异值特征提取的限制,而这种特征提取是考虑到一般算法能力提出的,无法彻底发挥出 DNA 巨大并行计算的优势。在理想的算法下,DNA 计算可轻易从上亿人的人脸库中快速有效地找到目标,这种便捷将使得建立庞大的个人图像数据库更有意义,任何对个人信息的查找、对比将变得非常快捷,安全机构可迅速由摄像头拍到的图像锁定犯罪嫌疑人,海关等人流众多的地方将能够快速确认通关者的身份,基于 DNA 计算的人脸识别会大量减少用于个人信息确认的资源。由于 DNA 计算有巨大并行性优势,对其以后的理论应用研究,不会只是放在结合现有的一般计算方法,而会专门针对 DNA 计算的优势发展出新的计算方法。由于目前科学技术限制,DNA 计算应用的具体实现还不太可能,但是一旦突破科技的瓶颈,人类计算将会得到完全的革新,如何充分

发挥 DNA 计算的优势将是 DNA 理论应用研究的一个重点。

- 参考文献:
- [1] ADLEMAN L M. Molecular computation of solutions to combinatorial problems[J]. Science, 1994, 266(11): 1021–1024.
 - [2] TSUBOI Y, ONO O. Applicability of DNA computing algorithm solving image recognition in intelligent visual mechanics[C]// Proceedings of the 29th Annual Conference of Industrial Electronics Society, 2003 (IECON'03). Virginia: IEEE Press, 2003: 2800–2803.
 - [3] ZHU YING, DING YONG-SHENG, LI WANG-GEN, et al. DNA algorithm of image recognition and its application[C]// Proceedings of 2006 IEEE International Conference on Information Reuse and Integration. Hawaii: IEEE Press, 2006: 375–379.
 - [4] ROWEIS S, WINFREE E, BOURGOYNE R, et al. A sticker-based model for DNA computation[J]. Computational Biology, 1998, 5(4): 615–629.
 - [5] HONG ZI-QUAN. Algebraic feature extraction of image for recognition[J]. Pattern Recognition, 1991, 24(3): 211–219.
 - [6] 孙继广. 矩阵扰动分析[M]. 北京: 科学出版社, 1987.
 - [7] MARINOVIC N, EICHMANN G. An expansion of wigner distribution and its applications[C]// Processing of IEEE International Conference on Acoustics, Speech, and Signal (ICASSP'85). Florida: IEEE Press, 1985: 1021–1024.
 - [8] 洪子泉, 杨静宇. 统计模式识别中的特征抽取[J]. 数据采集与处理, 1991, 6(2): 38–44.