

一种非参数核函数鉴别分析法及其在人脸识别中的应用

薛寺中¹ 戴 飞^{1,2} 陈秀宏¹

(江南大学数字媒体学院 无锡 214122)¹ (江南大学物联网工程学院 无锡 214122)²

摘要 核判别分析(KDA)算法仅考虑 $c-1$ 个判别特征,且计算类间离散度矩阵时需使用所有的训练样本,而一些有利于分类的边界结构未能被提取。为此,提出了一种非参数非线性(核)鉴别分析方法,其在计算特征空间中的类间散布矩阵时引入一个权值函数,从而能提取有利于分类的边界结构。仿真试验表明,新方法在识别性能上优于已有的一些方法,且避免了使用繁琐的矩阵奇异值分解理论,有一定的实用价值。

关键词 核判别分析,非参数非线性,人脸识别,特征提取

中图分类号 TP391 文献标识码 A

Non-parameter Kernel Function Discriminant Analysis Method and its Application in Face Recognition

XUE Si-zhong¹ DAI Fei^{1,2} CHEN Xiu-hong¹

(School of Digital Media, Jiangnan University, Wuxi 214122, China)¹ (School of Internet of Things, Jiangnan University, Wuxi 214122, China)²

Abstract Because of kernel discriminant analysis(KDA) algorithm only considers $c-1$ discriminated features, and neglects to capture the boundary structure while computing between-class scatter matrix. So an improved algorithm of non-parametric and nonlinear(kernel) was proposed. It added a weight function during computing the between-class scatter matrix which can overcome the above two disadvantages of KDA. Simulation results show that the recognition performance of the new method is superior to those of the existed methods, and it can avoid using the singular value decomposition theory of the matrixes, so it has some practical value.

Keywords Kernel discriminant analysis, Non-parameter and nonlinear, Face recognition, Feature extraction

1 引言

自 20 世纪六、七十年代提出人脸识别研究课题开始,人们对人脸识别的研究至今已近 40 年的历史。在此期间提出了很多著名的经典方法以及针对经典方法进行的改进方法,推动了人脸研究课题较大和长足的进展。基于线性判别分析^[1](Linear Discriminant Analysis, LDA)与核判别分析^[2](Kernel Discriminant Analysis, KDA)是比较有代表性的两种方法。

LDA 方法应用非常广泛,多年来许多学者在 LDA 方法上逐步改进完善, Li 等人^[3]于 2009 年提出的 NDA(Non-parametric Discriminant Analysis, NDA)方法,其主要思想是在 LDA 方法的类间散布矩阵中加入一个权值函数,这样可有效地提取图像的局部特征,识别率在 LDA 方法的基础上有了较大的提高。但实际应用中,许多问题往往是非线性的,此时线性方法的识别效果不是很理想。为此, Mika 等人^[2]提出了 KDA 等非线性方法,从而能有效地进行特征表示和分类^[4]。KDA 算法通过非线性映射将低维空间的原始数据样本投影到高维特征空间中,然后在该空间中实施 LDA 特征提取^[4]。但是, KDA 也有如下的缺点:首先, KDA 最多有 $c-1$ 个判别特征,但在一些高维空间中这些特征对于判别来说往往是不够

的;其次 KDA 方法需使用所有训练样本来构造类间离散度矩阵,很多有利于分类的边界结构未能被有效地提取出来,这些边界结构已经被证实后续的分类中是非常有用的^[4-8]。

为克服 KDA 方法中的缺点,本文提出了一种非参数非线性 KDA 方法并将其应用于人脸识别。其主要思想是:在计算特征空间中的类间离散度时引入一个权值函数^[3],然后对核 Fisher 鉴别函数进行分析以确定求最佳鉴别向量的方法^[1]。通过实验说明本文方法的识别率优于 KDA 方法;同时也指出当人脸表情姿态及光照条件有明显变化时,本文方法能有效提取图像的局部特征。

2 NDA 方法

假设有一训练样本集 $\{x_1, x_2, x_3, \dots, x_N\}$, 它们分别属于 C 个不同的类 $\{C_1, C_2, C_3, \dots, C_C\}$, 每个样本都是 d 维的列向量, $x_i^{(l)}$ 表示第 i 类中的第 l 个样本, 而第 i 类 C_i 有 N_i 个样本, $N = \sum_{i=1}^C N_i$ 。全体样本的均值向量 μ 及类 C_i 的样本均值向量 μ_i 分别为

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i, \mu_i = \frac{1}{N_i} \sum_{l=1}^{N_i} x_i^{(l)}$$

在非参数鉴别分析(NDA)中,训练样本的类内散布矩阵取线性判别分析法(LDA)的类间散布矩阵 S_w , 为

本文受中央高校基本科研业务费专项资金(JUSRP211A70)资助。

薛寺中(1964-),男,讲师,主要研究方向为图像处理、计算机视觉;戴飞(1987-),女,硕士生,主要研究方向为模式识别与人工智能, E-mail: hidaifei@163.com;陈秀宏(1964-),男,博士,教授,主要研究方向为图像处理、模式识别等。

$$S_w = \frac{1}{N} \sum_{i=1}^C \sum_{l=1}^{N_i} (x_i^{(l)} - \mu)(x_i^{(l)} - \mu)^T - m_i(\phi(x_j^{(i)}))^T \quad (1)$$

而训练样本的类间散布矩阵 S_b^N 则定义为

$$S_b^N = \sum_{i=1}^C \sum_{j=1}^C \sum_{l=1}^{N_i} w(i, j, l) (x_i^{(l)} - m_j(x_i^{(l)}))(x_i^{(l)} - m_j(x_i^{(l)}))^T \quad (2)$$

其中, 权值函数 $w(i, j, l)$ 定义为

$$w(i, j, l) = \frac{\min\{d^\alpha(x_i^{(l)}, NN_k(x_i^{(l)}, i)), d^\alpha(x_i^{(l)}, NN_k(x_i^{(l)}, j))\}}{d^\alpha(x_i^{(l)}, NN_k(x_i^{(l)}, i)) + d^\alpha(x_i^{(l)}, NN_k(x_i^{(l)}, j))} \quad (3)$$

式中, α 是一个小到零、大至无穷的变化的参数, 它的作用是控制权值方面距离比变化速度; $d(v_1, v_2)$ 是矢量 v_1 和 v_2 的欧氏距离; $NN_p(x_i^{(l)}, j)$ 表示 $x_i^{(l)}$ 在类 j 中的第 p 个近邻; $m_j(x_i^{(l)})$ 为 k 最近邻均值, 即

$$m_j(x_i^{(l)}) = \frac{1}{k} \sum_{p=1}^k NN_p(x_i^{(l)}, j) \quad (4)$$

综合式(1)~式(4)中的各个参数的选取, 可得到如下 3 个结论: 首先, 若所有 $w(i, j, l)$ 函数的值被设置为整数 1 且 $k = N_i$ 即 k 等于第 i 类样本数目时, 则 k 最近邻均值变成 μ_j 即第 j 类的样本均值, 也就是说 NSA 方法是 LDA 方法的一个推广和深化。其次, 相较于 LDA 方法最多只能提取 $c-1$ 个判别特征向量, NSA 的类间散布矩阵由类中心构造而成, 而非所有训练样本。正因如此, NSA 的分类性能将优于 LDA。此外, 由 k 最近邻均值 $m_j(x_i^{(l)})$ 的定义可得知, NSA 方法能更好地利用各种不同类别的边界信息。

由式(1)和式(2)得如下最佳判别准则函数, 即

$$J(w) = \frac{|w^T S_b^N w|}{|w^T S_w w|} \quad (5)$$

式中, w 表示为最优鉴别矢量。当 S_w 非奇异时, 极大化 $J(w)$ 即为求以下广义特征值问题, 即

$$S_b^N u = \lambda S_w u \quad (6)$$

其前 d 个最大特征值对应的特征向量则可作为最优鉴别向量。

3 非参数核方法(NPKDA)

假设有一 C 类样本集, $x_j^{(i)}$ 表示第 i 类中的第 j 个样本, N_i 为第 i 类的样本数, $N = \sum_{i=1}^C N_i$ 为样本总数。通过一个指定的映射 $\phi: x \rightarrow \phi(x) R^n \rightarrow H$ 将空间 R^n 中人脸图像样本映射到高维空间 H 中, 利用核函数 $k(x, y) = \phi^T(x)\phi(y)$ 可将 H 中点 $\phi(x)$ 和 $\phi(x_j^{(i)})$ 之间的距离表示为

$$\begin{aligned} d(\phi(x), \phi(x_j^{(i)})) &= \|\phi(x) - \phi(x_j^{(i)})\| \\ &= ((\phi(x) - \phi(x_j^{(i)}))^T (\phi(x) - \phi(x_j^{(i)})))^{1/2} \\ &= (\phi^T(x)\phi(x) - 2\phi^T(x_j^{(i)})\phi(x) + \phi^T(x_j^{(i)})\phi(x_j^{(i)}))^{1/2} \\ &= (k(x, x) - 2k(x_j^{(i)}, x) + k(x_j^{(i)}, x_j^{(i)}))^{1/2} \end{aligned} \quad (7)$$

H 中的类间散布矩阵为

$$S_b^N = \sum_{i=1}^C \sum_{j=1}^C \sum_{l=1}^{N_i} w(i, j, l) (\phi(x_j^{(i)}) - m_i(\phi(x_j^{(i)}))) (\phi(x_j^{(i)}) - m_i(\phi(x_j^{(i)})))^T$$

$$- m_i(\phi(x_j^{(i)}))^T \quad (8)$$

其中, $w(i, j, l) =$

$$\frac{\min\{d^\beta(\phi(x_j^{(i)}), NN_k(\phi(x_j^{(i)}), i)), d^\beta(\phi(x_j^{(i)}), NN_k(\phi(x_j^{(i)}), l))\}}{d^\beta(\phi(x_j^{(i)}), NN_k(\phi(x_j^{(i)}), i)) + d^\beta(\phi(x_j^{(i)}), NN_k(\phi(x_j^{(i)}), l))}$$

正参数 β 控制关于距离比的权值变化速度; $m_i(\phi(x_j^{(i)})) = \frac{1}{k} \sum_{p=1}^k NN_p(\phi(x_j^{(i)}), l)$; $d(\phi(x_j^{(i)}), NN_p(\phi(x_j^{(i)}), i))$ 是 $\phi(x_j^{(i)})$ 到 $NN_k(\phi(x_j^{(i)}), i)$ 的距离, 而 $NN_k(\phi(x_j^{(i)}), i)$ 表示点 $\phi(x_j^{(i)})$ 在类 i 中的第 p 个近邻。

H 中的类内散布矩阵为

$$S_w^N = \sum_{i=1}^C \sum_{j=1}^{N_i} (\phi(x_j^{(i)}) - \mu^i) (\phi(x_j^{(i)}) - \mu^i)^T \quad (9)$$

式中, μ^i 为在特征空间 H 中所有样本的均值, μ^i 为在特征空间 H 中第 i 类样本的均值, 即 $\mu^i = \frac{1}{N_i} \sum_{j=1}^{N_i} \phi(x_j^{(i)})$ 。

于是, Fisher 判别准则为

$$J(w) = \frac{w^T S_b^N w}{w^T S_w^N w} \quad (10)$$

极大化该准则函数即可得特征空间 H 中的最佳投影向量。

由再生核理论可知, Fisher 式的任一解 $w \in H$ 可表示为 H 中全体训练样本的线性组合^[5], 即

$$w = \sum_{i=1}^C \sum_{j=1}^{N_i} \alpha_j^i \phi(x_j^{(i)}) \quad (11)$$

于是, 有

$$\begin{aligned} w^T \phi(x_j^{(i)}) - w^T \mu^i &= \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r \phi(x_s^{(r)})^T \phi(x_j^{(i)}) - \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r \phi(x_s^{(r)})^T \cdot \frac{1}{N_i} \sum_{p=1}^{N_i} \phi(x_p^{(i)}) \\ &= \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r [k(x_s^{(r)}, x_j^{(i)}) - \frac{1}{N_i} \sum_{p=1}^{N_i} k(x_s^{(r)}, x_p^{(i)})] \\ &= \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r (KK_{ij})_s^{(r)} = \alpha^T KK_{ij} \end{aligned} \quad (12)$$

式中, $(KK_{ij})_s^{(r)} = k(x_s^{(r)}, x_j^{(i)}) - \frac{1}{N_i} \sum_{p=1}^{N_i} k(x_s^{(r)}, x_p^{(i)})$, 而 α 和 KK_{ij} 分别为两个 N 维列向量 $\alpha = (\alpha_1^{(1)}, \alpha_2^{(1)}, \dots, \alpha_{N_1}^{(1)}, \alpha_1^{(2)}, \alpha_2^{(2)}, \dots, \alpha_{N_2}^{(2)}, \dots, \alpha_1^{(C)}, \alpha_2^{(C)}, \dots, \alpha_{N_C}^{(C)})^T$, $KK_{ij} = ((KK_{ij})_1^{(1)}, (KK_{ij})_2^{(1)}, \dots, (KK_{ij})_{N_1}^{(1)}, (KK_{ij})_1^{(2)}, (KK_{ij})_2^{(2)}, \dots, (KK_{ij})_{N_2}^{(2)}, \dots, (KK_{ij})_1^{(C)}, (KK_{ij})_2^{(C)}, \dots, (KK_{ij})_{N_C}^{(C)})^T$ 。从而有

$$\begin{aligned} w^T S_b^N w &= \sum_{i=1}^C \sum_{j=1}^{N_i} w^T (\phi(x_j^{(i)}) - \mu^i) (\phi(x_j^{(i)}) - \mu^i)^T w \\ &= \sum_{i=1}^C \sum_{j=1}^{N_i} \alpha^T (KK_{ij}) (KK_{ij})^T \alpha \end{aligned} \quad (13)$$

令 $V = \sum_{i=1}^C \sum_{j=1}^{N_i} (KK_{ij})(KK_{ij})^T$, 则 $w^T S_b^N w$ 可表示为 $w^T S_b^N w = \alpha^T V \alpha$ 。

另一方面, 假设点 $\phi(x_j^{(i)})$ 在类 l 中的 k 个近邻分别为 $\phi(x_{l_1}^{(i)}), \phi(x_{l_2}^{(i)}), \dots, \phi(x_{l_k}^{(i)})$, 则 $m_l(\phi(x_j^{(i)}))$ 可表示为

$$m_l(\phi(x_j^{(i)})) = \frac{1}{k} \sum_{i=1}^k NN_r(\phi(x_j^{(i)}), l) = \frac{1}{k} \sum_{i=1}^k \phi(x_{l_i}^{(i)}) \quad (14)$$

从而有

$$\begin{aligned} w^T (\phi(x_j^{(i)}) - m_l(\phi(x_j^{(i)}))) \\ = w^T \phi(x_j^{(i)}) - w^T m_l(\phi(x_j^{(i)})) \end{aligned}$$

$$\begin{aligned}
&= \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r \phi^T(x_s^{(r)}) \phi(x_j^{(j)}) - \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r \phi^T(x_s^{(r)}) \cdot \frac{1}{k} \sum_{i=1}^k \phi(x_i^{(D)}) \\
&= \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r [\phi^T(x_s^{(r)}) \phi(x_j^{(j)}) - \frac{1}{k} \sum_{i=1}^k \phi^T(x_s^{(r)}) \phi(x_i^{(D)})] \\
&= \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r [k(x_s^{(r)}, x_j^{(j)}) - \frac{1}{k} \sum_{i=1}^k k(x_s^{(r)}, x_i^{(D)})] \\
&= \sum_{r=1}^C \sum_{s=1}^{N_r} \alpha_s^r (KK_{ij})_s^{(r)} = \alpha^T KK_{ij} \quad (15)
\end{aligned}$$

式中, $(KK_{ij})_s^{(r)} = k(x_s^{(r)}, x_j^{(j)}) - \frac{1}{k} \sum_{i=1}^k k(x_s^{(r)}, x_i^{(D)})$ 。于是, $\omega^T S_i^k \omega$ 可转化为

$$\omega^T S_i^k \omega = \sum_{i=1}^C \sum_{j=1}^{N_i} \sum_{l=1}^C w(i, j, l) \alpha^T (KK_{ij}) (KK_{ij})^T \alpha = \alpha^T U \alpha \quad (16)$$

式中, $U = \sum_{i=1}^C \sum_{j=1}^{N_i} \sum_{l=1}^C w(i, j, l) (KK_{ij}) (KK_{ij})^T$ 。这样, 准则式(10)可变为

$$J(\omega) = \frac{\alpha^T U \alpha}{\alpha^T V \alpha} \quad (17)$$

求出 $U^{-1}V$ 的 m 个最大特征值所对应的特征向量 $\alpha_1, \alpha_2, \dots, \alpha_m$, 再由式(11)即可得 m 个最佳投影向量 $\omega_1, \omega_2, \dots, \omega_m$ 。

4 实验与分析

4.1 ORL 库中的实验

由英国剑桥大学 AT&T 实验室创建的 ORL 人脸数据库可从网站上免费下载得到, 此为人脸识别领域应用最广泛的人脸数据库之一。库中采集了 40 名志愿者每人 10 张灰度级为 256 的面部图像, 共计 400 张, 分辨率为 92×112 。每张图像在姿态、神情、头部饰物、视角和旋转方向等各不相同。图 1 是一组取自 ORL 库的图像。




图 1 ORL 库中某人的 10 张图像

因为人脸图像必须是独立的才能进行本次实验, 所以现将人脸库一分为二: 每组的前 5 张用来作为训练样本, 而后 5 张作为测试样本。投影轴数目取值分别为 39, 40, 41, 42, 43, 44 和 45。实验的数据如表 1 所列(本实验选用多项式核函数 $k(x, y) = (x \cdot y + 1)^2$ 和径向基内积核函数 $k(x, y) = \exp(-\frac{\|x-y\|^2}{20})$, 实验中使用最小距离分类器)。

表 1 核函数 $k(x, y) = (x \cdot y + 1)^2$ 下 ORL 的识别率比较

投影轴数目	39	40	41	42	43	44	45
本文方法	91%	91%	92.5%	92.5%	93%	92%	91.5%
KDA 法	91%	91.5%	92%	93%	92%	91.5%	91.5%

表 1 中的数据显投影轴数目为 41, 43 和 44 时, 新方法要比原方法分别高出 0.5%, 1% 和 0.5%; 但原方法在投影轴

数目为 40 和 42 时, 识别率比新方法均高 0.5%; 当投影轴数目为 39 和 45 时, 两种方法的识别率相同。表 2 中的数据显投影轴数目为 43, 44 和 45 时, 新方法要比原方法分别高出 1%, 0.5% 和 0.5%; 但原方法在投影轴数目为 39, 41 和 42 时, 识别率比新方法分别高 0.5%, 1.5% 和 0.5%; 当投影轴数目为 40 时, 两种方法的识别率相同。表 3 中的数据为各类方法进行 10 次以上取得的平均值。由表 3 可以看出, 对于 ORL 数据库, 使用核函数为多项式内积的核方法和线性方法取得的识别率相差无几, 但是采用核函数为径向内积的核方法比线性方法识别率最多相差 2.40%。

表 2 核函数 $k(x, y) = \exp(-\frac{\|x-y\|^2}{20})$ 下 ORL 的识别率比较

投影轴数目	39	40	41	42	43	44	45
本法识别率	89%	89.5%	89%	89%	90.5%	90%	89.5%
KDA 识别率	89.5%	89.5%	90.5%	90%	89.50%	89.5%	89%

表 3 各类方法(线性/核方法)在 ORL 库上的识别率比较

比较项目	LDA	NDA	多项式内积函数		径向内积函数	
			KDA	本文方法	KDA	本文方法
识别率	91.50%	92.00%	91.79%	91.93%	89.64%	89.60%

4.2 XM2VTS 库中的实验

XM2VTS 人脸库中共有 295 人, 每个人 8 张照片, 分辨率为 55×51 , 图像有抬头、低头、表情平和、表情愤怒、蒙面、不蒙面、闭眼、睁眼等各种差异。每组的前 4 张是训练集, 后 4 张为测试集。图 2 是一组取自 XM2VTS 库的图像。




图 2 XM2VTS 人脸库中某人的 8 张图像

实验的数据如表 4 所列(本实验选用多项式核函数 $k(x, y) = (x \cdot y + 1)^2$ 和径向基内积核函数 $k(x, y) = \exp(-\frac{\|x-y\|^2}{20})$, 实验中使用最小距离分类器)。

表 4 各类方法(线性/核方法)在 XM2VTS 库上的识别率比较

比较项目	LDA	NDA	多项式内积函数		径向内积函数	
			KDA	本文方法	KDA	本文方法
识别率	92.57%	94.41%	83.11%	83.15%	74.29%	74.24%

图 3 中的数据显投影轴数目为 42, 43, 44 和 45 时, 新方法要比原方法性能略好; 但原方法在投影轴数目为 39, 40 和 41 时, 识别率比新方法略好。图 4 中的数据显投影轴数目为 42, 44 和 45 时, 新方法要比原方法性能略好; 但原方法在投影轴数目为 39, 40, 41 和 43 时, 识别率比新方法略好。表 4 中的数据为各类方法进行 10 次以上取得的平均值。由表 4 知, 对于 XM2VTS 数据库, 使用核函数为多项式内积和径向内积的核方法与线性方法取得的识别率相差很大, 尤其是径向内积核函数与线性方法的识别率差异最大达 20.17%。综上分析, 在 XM2VTS 数据库中, 采用线性方法能取得较好的识别率。

(下转第 518 页)

配结果,如表 1 所列。

表 1 近似取整和修正算法对题量为 20,30,60 的难度分配结果

总题数	平均难度	难度								
		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
20	0.65	0	0	1	2	3	5	4	3	2
	0.7	0	0	1	1	3	4	4	4	3
	0.75	0	0	0	1	2	4	4	5	4
	0.8	0	0	0	1	2	3	5	4	5
30	0.65	0	1	1	3	5	6	6	5	3
	0.7	0	0	1	2	4	6	7	6	4
	0.75	0	0	1	2	3	5	7	7	5
	0.8	0	0	0	1	3	5	7	7	7
60	0.65	0	1	3	6	10	12	12	10	6
	0.7	0	1	2	4	8	12	13	12	8
	0.75	0	0	1	3	7	11	14	13	11
	0.8	0	0	1	2	5	9	14	15	14

结束语 利用正态分布来确定各种难度的题量是自动组卷问题中的关键技术,应该引起教育工作者的重视和研究。学生的成绩呈正态分布,可以通过控制平均难度来控制学生的平均成绩。在各种难度的题量控制研究中,主要有 3 个方面的研究内容:(1)难度不可能为任意实数,如何进行离散化,并以数学理论为指导计算各种难度的概率;(2)离散化后出现的误差如何补偿;(3)正态分布的标准化参数如何确定。以难度作为自变量的正态分布,离散化后,可以采用向前积分、向后积分和对称积分来求取各种难度的概率,其中对称积分所

产生的误差更小。可以采用平均补偿和比例补偿方法来减少误差,其中比例补偿的效果更好一些。通过多次实验,我们发现在自动组卷问题中,标准差 σ 取 0.2 会使计算结果更接近理论值。

参考文献

- [1] 张晓博. 基于 SOA 试题库自动组卷系统的设计与开发[D]. 武汉: 武汉理工大学, 2011
- [2] 武仁杰. 蚁群算法在自动组卷建模中的应用研究[J]. 计算机仿真, 2011(8): 380-384
- [3] 刘毅. 人工智能在自动组卷建模中应用研究[J]. 计算机仿真, 2011(8): 385-388
- [4] 刘敏钰, 李萍, 杨丽军, 等. 成绩分布正态性检验的研究与实现[J]. 新西部(下半月), 2007(4): 242-243
- [5] 王琴竹, 孟朝霞. 通过试题难度控制试卷难度方法的探讨[J]. 电脑知识与技术, 2009, 5(3): 761-763
- [6] 毛秉毅. 一种计算试卷中试题难度分布的有效方法[J]. 计算机工程, 2002, 28(6): 280-281
- [7] 张殿龙. 正态分布函数在试题难度分配算法中的研究[J]. 哈尔滨理工大学学报, 2009, 4(13): 13-15
- [8] 徐玮, 康重庆, 夏清, 等. 序列运算离散化过程中的误差成因及补偿[J]. 清华大学学报: 自然科学版, 2009, 49(1): 17-20
- [9] 宣仲良. 各级难度试题分值比例的确定[J]. 淮阴师范学院学报: 自然科学版, 2004(3): 24-25

(上接第 509 页)




图 3 核函数 $k(x, y) = (x \cdot y + 1)^2$ 下在 XM2VTS 上的识别率




图 4 核函数 $k(x, y) = \exp(-\frac{\|x-y\|^2}{20})$ 下在 XM2VTS 上的识别率

结束语 本文提出一种非参数核函数的判别分析方法(NPKDA),它通过在类间离散度矩阵中加入一个权值函数,使得类间离散度矩阵由类中心构造而成而非所有训练样本,其目的是为了地分析多个像素间的非线性相关性,从而有效地提取图像的局部特征并合理地利用各种不同类别的边界信息。该方法的实验结果表明,其识别率较原方法虽未有大的提高,但算法的稳定性有所加强,且可避免使用繁琐的矩阵奇异值分解理论,一定程度上简化了分类器的设计。但由于 KDA 仍然使用的是 Fisher 判别准则,因此在分类率方面,其并不是一种最优的方法。而判定一种核方法的优劣,关键因素在于所选取的核函数,因此核函数的选取是解决此类问题的关键。核选取对 KDA 的性能有较大影响。如何选择有关核函数,还需进一步的研究。

参考文献

- [1] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720
- [2] Mika S, Rätsch G, Weston R J, et al. Fisher discriminant analysis with kernels[C]//IEEE Neural Networks for Signal Processing Workshop. Wisconsin, USA, 1999
- [3] Li Zhi-feng, Tang Xiao-ou, et al. Nonparametric discriminant analysis for face recognition[J]. IEEE Transactions on Pattern Analysis Machine Intelligence, 2009, 31(4): 755-761
- [4] 郑宇杰, 杨静宇, 吴小俊, 等. 一种新的核线性鉴别分析算法及其在人脸识别上的应用[J]. 计算机科学, 2006, 33(7): 223-226
- [5] 田捷, 杨鑫, 等. 生物特征识别理论与应用[M]. 北京: 清华大学出版社, 2009
- [6] 徐东, 刘政凯. 数据降维算法的研究及其应用[D]. 合肥: 中国科学技术大学, 2005
- [7] 王伟, 张佑生, 方芳. 人脸检测与识别技术综述[J]. 合肥工业大学学报: 自然科学版, 2006, 2(29): 158-162
- [8] Turk M, Pentland A. Face recognition using eigenfaces[C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition(CVPR'91). Washington, 1991: 586-591
- [9] Tefas A, Kotropoulos C, Pitas I. Using support vector machines to enhance the performance of elastic matching for frontal face authentication[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(7): 735-745
- [10] Hua Yu, Jie Yang. A direct LDA algorithm for high-dimensional data with application to face recognition[J]. Pattern Recognition, 2001, 34(10): 2067-2070
- [11] Scholkopf B, Smola A, Muller K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998, 10(5): 1299-1319