

基于模块化 2DPCA 和 CSKDA 的人脸验证

袁 宁¹, 吴小俊¹, 王士同¹, 杨静宇², Josef Kittler³

(1. 江南大学信息工程学院, 无锡 214122; 2. 南京理工大学计算机科学与技术学院, 南京 210094;

3. Dept. of Electrical Engineering, University of Surrey, GU2, 7XH, UK)

摘要: 针对客户相关的核判别分析(CSKDA)对图像列向量进行处理数据维数大、计算复杂,对图像整体处理没有考虑到局部特征等缺点,提出 M2DPCA 和 CSKDA 结合的方法。新方法对二维数据进行分块后采用 2DPCA 抽取局部特征,施行 CSKDA,不仅考虑了类内、类间的差异,而且可以较好地描述不同个人脸间的差异性。在 XM2VTS 和 ORL 人脸库上的实验结果表明,该方法在验证效果上优于 CSKDA 方法。

关键词: 客户相关的核判别分析; 模块化 2DPCA; 特征抽取; 人脸验证

Face Verification Based on Modular 2DPCA and CSKDA

YUAN Ning¹, WU Xiao-jun¹, WANG Shi-tong¹, YANG Jing-yu², Josef Kittler³

(1. School of Information Engineering, Jiangnan University, Wuxi 214122; 2. School of Computer Science and Technology,

Nanjing University of Science & Technology, Nanjing, 210094; 3. Dept. of Electrical Engineering, University of Surrey, GU2, 7XH, UK)

【Abstract】 An improved face verification algorithm is proposed based on the modular 2DPCA and Client Specific Kernel Discriminant Analysis (CSKDA) because of the disadvantage of CSKDA. CSKDA first transforms an image matrix to a vector which caused high dimensionality and computational complexity and not considered the local feature. While the method first extracts the local features with the original images which are divided into modular sub-images, CSKDA is utilized. The discriminant information obtained from the between-class and the within-class scatter matrix are developed. Moreover, client specific subspace can describe the diversity of different faces. Experimental results obtained on XM2VTS and ORL show the effectiveness of the method.

【Key words】 Client Specific Kernel Discriminant Analysis(CSKDA); modular 2DPCA; feature extraction; face verification

1 概述

人脸验证是判断图像中的人脸是否是指定的人,解决是不是某人的问题。

特征提取是人脸验证的一个关键问题^[1]。Turk 等首先把主成分分析(PCA)的子空间思想引入到识别中,主成分分析没有考虑到类内、类间的差异,不能获得很好的结果^[2]。LDA(Linear Discriminate Analysis)的提出弥补了这个缺点,使样本在所生成的子空间类间散度最大,类内散度最小。Belhumeur 等进一步发展了这种算法,称为 Fisher 脸方法。近来 Fisher 脸又有新的发展^[3],这对模式识别有十分重要的意义。Scholkopf 和 Mika 分别提出了基于核运算的核主成分分析和核线性判别分析,进行了非线性推广。为避免可能出现的小样本问题和类内散布矩阵奇异性导致最优鉴别矢量集计算困难,1993 年 Liu 等提出了直接利用图像矩阵构造散布矩阵的方法;2003 年 Yang 将 2D 的思想引入 PCA,提出了 2DPCA 方法,2005 年 Chen 等对 2DPCA 进行推广,提出了模块化 2DPCA 方法^[4],基本思想是对图像矩阵分块得到的子图像进行分析。

在人脸验证的应用中,为取得更好的效果,1999 年 Kittler 在 LDA 的基础上引进了客户相关子空间(Client Specific Subspace)方法^[5],不同类得到不同的特征投影向量,后来 Wu 和 Kittler 在此基础上引入等价的 Fisher 准则,提出了改进的方法^[6-8],提高了验证性能。对其进行非线性推广提出了客户相关的核判别分析(Client Specific Kernel Discriminant

Analysis, CSKDA)^[5]。

本文在这些研究的基础上,对 Wu 提出的 CSKDA 进行改进,对模块化 2DPCA 和 CSKDA 相结合。该方法的特点是对图像分块能有效地提取局部特征,使用客户相关子空间能更好地描述不同人脸的差异性,引入核函数解决非线性问题,因此,该方法更有利于分类;由于直接基于二维子图像矩阵,能方便地降低原始特征的维数;在 XM2VTS 和 ORL 库上的实验结果表明,新方法在验证效果上优于 CSKDA。

2 模块化 2DPCA 与 CSKDA 方法

设类别 c 个: $\omega_1, \omega_2, \dots, \omega_c$, 第 i 类有 n_i 个样本。 A_1, A_2, \dots, A_M ($M = \sum_{i=1}^c n_i$) 为所有训练样本,均为 $m \times n$ 矩阵。模块 2DPCA 的思想是将 $m \times n$ 矩阵 A 分成 $p \times q$ 个模块矩阵,即

$$A = \begin{pmatrix} A_{11} & A_{12} & \dots & A_{1q} \\ A_{21} & A_{22} & \dots & A_{2q} \\ \vdots & \vdots & \dots & \vdots \\ A_{p1} & A_{p2} & \dots & A_{pq} \end{pmatrix} \quad (1)$$

基金项目: 国家自然科学基金资助项目(60472060, 60572034); 2006 年教育部新世纪优秀人才计划基金资助项目; 江苏省自然科学基金资助项目(BK2006081); 江南大学创新团队建设基金资助项目(JNIRT0702)

作者简介: 袁 宁(1983—),女,硕士研究生,主研方向:模式识别; 吴小俊、王士同、杨静宇,教授、博士、博士生导师; Josef Kittler,教授、博士

收稿日期: 2008-09-14 **E-mail:** yuanningliok@163.com

其中，每个子图像矩阵是 $m_1 \times m_2$ 的矩阵， $p \times m_1 = m$ ， $q \times m_2 = n$ ，然后对所有子图像矩阵施行 2DPCA 方法^[4]。

对于 CSKDA，引入非线性映射，将输入空间投影到高维的空间中。将第 i 类看作当前客户，其他类均为冒充者， μ_i 为第 i 类的均值。

定义准则函数

$$J(v) = \frac{v^T M_i v}{v^T \Sigma_i v} \quad (2)$$

其中， M_i 表示客户和冒充者这 2 类的类间散布矩阵； Σ_i 表示第 i 类客户的类内散布矩阵。容易得出最大化该准则函数的解为 $v = \Sigma_i^{-1} \mu_i$ ，即第 i 类的 Fisher 脸子空间^[5]。随后将测试样本投影到每个人的训练样本的 Fisher 脸子空间上，作为分类的依据。

3 模块 2DPCA + CSKDA 方法

3.1 模块化 2DPCA

将训练样本 $z_i (i=1,2,\dots,M)$ 分成 $p \times q$ 个模块，则训练样本的总体散布矩阵为

$$S_i = \frac{1}{N} \sum_{k=1}^p \sum_{l=1}^q (z_{ikl} - \mu[(z_i)_{kl}] - \mu)^T \quad (3)$$

其中， $N = Mpq$ ，表示训练样本子图像矩阵总数； μ 是所有训练样本子矩阵的均值矩阵。

定义准则函数

$$J(w) = w^T S_i w \quad (4)$$

训练样本 z_i 投影到式(4)的最优解上记为 Y_i ，为进行以下步骤，将矩阵 Y_i 按列排成一个列向量 y_i ，即矩阵的向量化。

3.2 CSKDA 中的降维

经过以上步骤后，训练样本为 $y_i, i=1,2,\dots,M$ ，经过非线性映射 ϕ 投影到高维空间 $\phi(y_i)$ ，所有训练样本均值为 $\bar{\phi}$ ，第 i 类的均值为 $\bar{\phi}_i$ ，类间散布矩阵为

$$S_b = \sum_{i=1}^c \left(\sqrt{\frac{n_i}{M}} (\bar{\phi}_i - \bar{\phi}) \right) \left(\sqrt{\frac{n_i}{M}} (\bar{\phi}_i - \bar{\phi}) \right)^T = \sum_{i=1}^c \tilde{\phi}_i \tilde{\phi}_i^T = P_b P_b^T \quad (5)$$

引入核函数，得到所有训练样本的核矩阵 K ，经推导得

$$P_b^T P_b = \frac{1}{M} B (A_{Mc}^T \cdot K \cdot A_{Mc} - \frac{1}{M} (A_{Mc}^T \cdot K \cdot I_{Mc}) - \frac{1}{M} (I_{Mc} \cdot K \cdot A_{Mc}) + \frac{1}{M^2} (I_{Mc} \cdot K \cdot I_{Mc})) \cdot B \quad (6)$$

其中， $B = \text{diag}[\sqrt{n_1}, \sqrt{n_2}, \dots, \sqrt{n_c}]$ ， I_{Mc} 是一个元素全为 1 的 $M \times c$ 的矩阵； A_{Mc} 是一个 $M \times c$ 的块对角矩阵，即 $A_{Mc} = \text{diag}[a_{M_1}, a_{M_2}, \dots, a_{M_c}]$ ； a_{M_i} 是一个元素全部为 $n_i/1$ 的 $n_i \times 1$ 的列向量。

令 λ_i 和 e_i 是 $P_b^T P_b$ 的第 i 个特征值及其对应的特征向量，且这些特征值降序排列，易得到 $t_i = P_b e_i$ 是 S_b 的特征向量。用于降维的向量组取前 m_b 个最大特征值所对应的特征向量。

令 $D_b = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_{m_b}]$ ，从而令 $U = T D_b^{-\frac{1}{2}}$ ，这样将 T 进行归一化处理。此时将样本投影到该子空间上，

$$x_i = U^T \phi(y_i) = (E_m D_b^{-\frac{1}{2}})^T P_b^T \phi(y_i) \quad (7)$$

所有训练样本的均值可以表示为

$$m_\phi = U^T \bar{\phi} = (E_m D_b^{-\frac{1}{2}})^T \cdot \frac{1}{M} \sum_{j=1}^M P_b^T \phi(y_j) \quad (8)$$

令 $\tilde{x}_i = x_i - m_\phi$ ，那在空间 U 上全局散布矩阵为

$$\Phi = \frac{1}{M} \sum_{i=1}^M \tilde{x}_i \tilde{x}_i^T \quad (9)$$

将所有训练样本分为 2 类：第 i 类以及区别于第 i 类的其他所有类，即客户和冒充者。第 i 类的均值矩阵表示如下：

$$\mu_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \tilde{x}_j = (E_m D_b^{-\frac{1}{2}})^T \cdot \frac{1}{n_i} \sum_{j=1}^{n_i} \left(P_b^T \phi(y_j) - \frac{1}{M} \sum_{k=1}^M P_b^T \phi(y_k) \right) \quad (10)$$

容易得到区别于第 i 类的冒充者均值 μ_Ω 。

传统的 Fisher 准则对于不同的类别需要计算各自的类内散布矩阵的逆矩阵 Σ_i^{-1} ，计算量较大，当 Σ_i 可逆时，它等价于以下准则：

$$J(v) = \frac{v^T M_i v}{v^T \Phi v} \quad (11)$$

该式的最优解为

$$\tilde{v}_i = \Phi^{-1} \mu_i \quad (12)$$

从而获得第 i 类的特征为

$$a_i = \tilde{v}_i \quad (13)$$

3.3 分类

待测数据 H 为 $m \times n$ 的矩阵，首先将其投影到 M2DPCA 提取的子空间 V 上，进行向量化后记为 h 。

由以上叙述可知，训练样本经过 M2DPCA 投影向量化处理后，每类的均值记为 u_i 。待测样本 h 投影到该算法提取的空间上记为 $\tilde{h} = (E_m D_b^{-\frac{1}{2}} a_i)^T (P_b^T \phi(h))$ ，经推导

$$P_b^T \phi(h) = \frac{1}{\sqrt{M}} \cdot B \cdot \left(A_{Mc}^T \cdot r(\phi(h)) - \frac{1}{M} I_{Mc}^T \cdot r(\phi(h)) \right) \quad (14)$$

$$r(\phi(h)) = [\phi_1^T \phi(h), \phi_2^T \phi(h), \dots, \phi_{Mc}^T \phi(h)]^T$$

第 i 类的中心 u_i 投影到该算法提取的空间记为 \tilde{u}_i ，第 i 类的伪类的中心 u_Ω 投影到该算法提取的空间后记为 \tilde{u}_Ω 。

基于客户的分类，待测样本和第 i 类中心之间的距离记为 $d_i = |\tilde{h} - \tilde{u}_i|$ ，若该距离超过阈值 t_c ，则认为待测样本属于第 i 类。

基于冒充者的分类，待测样本和第 i 类的伪类的中心之间的距离记为 $d_i = |\tilde{h} - \tilde{u}_\Omega|$ ，若该距离超过阈值 t_i ，认为待测样本属于第 i 类的伪类，即不属于第 i 类。

4 实验结果与分析

4.1 实验 1

本实验在 XM2VTS 库上进行，包括 295 人 4 次录制的人脸和语音数据^[6]。从每个时期提取 2 幅图像构成这个人脸验证的数据库。图 1 是该库的 10 幅图像。



图 1 XM2VTS 人脸库中的部分图像

该实验遵循 Lausanne 协议将图像数据分为 200 个客户和 95 个冒充者。实验用错误拒绝率(False Rejection Rate, FRR)和错误接受率(False Acceptance Rate, FAR)来评价算法性能。错误拒绝就是错误地把客户当作冒充者拒绝，错误接受即错误地把冒充者当成客户接受。

本文使用最小距离分类器，用欧式距离表征测试样本和训练样本间的距离。采用的阈值不同，得到的 FAR 和 FRR 也不同。一般 FAR 随阈值的增大而增大，FRR 随阈值的增大而减小。因此，在评价阶段通过使 FAR 和 FRR 相等来调整阈值，使得错误决定最小化，得到最可靠的验证率。并将该

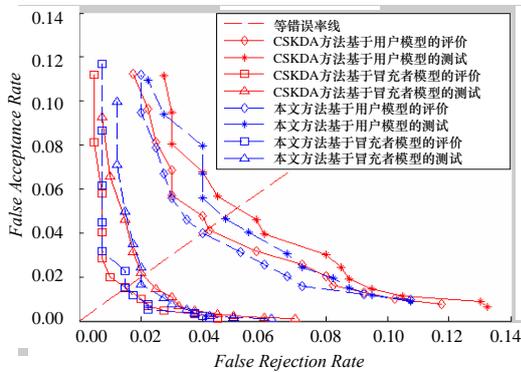
阈值用于测试, 判别算法的验证性能。

本实验使用 XM2VTS 的协议 II 进行评价和测试。表 1 给出了对原始图像进行 11×3, 5×3, 1×3, 5×17, 1×17 和 11×17 这 6 种分块的结果。这 2 种方法分别进行了基于用户(On Client model)和基于冒充者(On Imposter model)的分类, 以下简称 On C, On I, 表 1 中 TER=FAR+FRR, 表示总的错误率。

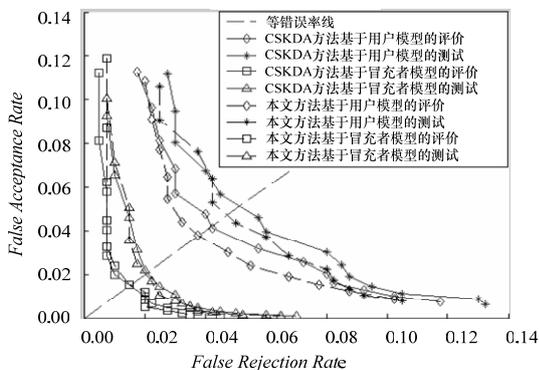
表 1 在 XM2VTS 上 CSKDA 和本文方法的结果对比

方法	评估	Testing				
		FAR	FRR	FAR	FRR	TER
CS LDA	On C	4.75	4.75	4.64	6.50	11.14
	On I	1.51	1.50	1.06	3.00	4.06
CS KDA	On C	4.25	4.25	4.12	6.00	10.12
	On I	1.54	1.50	1.10	3.00	4.10
新方法(11×3)r=3	On C	4.00	4.00	4.03	5.50	9.53
	On I	1.50	1.50	1.04	2.75	3.79
新方法(5×3)r=6	On C	3.79	3.75	3.71	6.00	9.71
	On I	1.54	1.50	1.06	2.50	3.56
新方法(1×3)r=19	On C	3.50	3.50	3.39	5.50	8.89
	On I	1.91	2.00	1.32	2.00	3.32
新方法(5×17)r=7	On C	3.74	3.75	3.67	5.75	9.42
	On I	1.50	1.50	1.05	2.50	3.55
新方法(1×17)r=19	On C	3.50	3.50	3.41	5.50	8.91
	On I	1.89	2.00	1.29	2.25	3.54
新方法(11×17)r=3	On C	3.99	4.00	4.03	5.50	9.53
	On I	1.50	1.50	1.04	2.75	3.79

实验结果均表明了新方法优于原有方法, 但为了更明确地表现新方法的性能, 本文使用 ROC 曲线(Receiver Operating Characteristics curve)描述实验结果。曲线上每个点表明不同阈值对应的 FAR 和 FRR 的值, 曲线和等错误率线重合的点表示 FAR 和 FRR 相等的值, 即 EER。图 2(a)描述了 CSKDA 和本文方法(分块为 11×17)在 XM2VTS 数据库基于用户和基于冒充者的 ROC 曲线。图 2(b)描述了 CSKDA 和本文方法(分块为 5×3)在 XM2VTS 数据库基于用户和基于冒充者模型的 ROC 曲线。



(a)CSKDA 和本文方法(分块为 11×17)的结果对比



(b)CSKDA 和本文方法(分块为 5×3)的结果对比

图 2 CSKDA 和本文方法的结果对比

从表 1 和图 2 的实验数据可以看出, FAR 和 FRR 之间存在

在如下关系: 当一方逐渐变大时, 另一方逐渐减小。新方法的验证效果优于 CSKDA, 错误率更低, 基于客户的性能提高更明显; 从 2 种方法的 ROC 图对比可以看出, 基于冒充者的结果普遍比基于用户的效果好。CSLDA 只对一维数据进行处理, 而本文的方法使用模块化 2DPCA 对二维数据进行特征提取, 考虑了图像的局部特征, 而且图像维数降低, 减少了计算量。在此基础上转化为一维数据使用 CSKDA, 考虑了类内类间的差异性, 可以更好地描述个人脸的特性, 所以, 改进的方法具有更好的验证效果。

4.2 实验 2

实验 2 在 ORL 库上进行, 该库包括 40 人, 每人 10 幅图像, 有些图像拍摄于不同时期, 脸部表情与细节有变化; 人脸姿态有变化, 深度旋转与平面旋转可达 20°, 人脸尺度也有最多 10% 的变化。将库中图像分为 3 类: (1)采用每人的前 2 幅作为训练集, 提取子空间; (2)采用每人的前 4 幅作为评价集, 确定 FAR=FRR 的阈值; (3)采用每人的后 6 幅作为测试集, 测试算法性能的优劣。

表 2 给出了对原始图像进行 2×2, 4×4, 1×4, 7×4, 8×4 等分块得到的结果。

表 2 在 ORL 上 CSKDA 和本文方法的结果对比

方法	评估	测试				
		FAR	FRR	FAR	FRR	TER
CS LDA	On C	2.756 4	2.500 0	5.096 2	8.750 0	13.846 0
	On I	2.500 0	2.500 0	4.914 5	7.916 7	12.831 0
CS KDA	On C	3.380 0	3.130 0	5.500 0	8.750 0	14.250 0
	On I	2.500 0	2.500 0	4.640 0	7.500 0	12.140 0
新方法(2×2)r=28	On C	3.390 0	3.120 0	5.450 0	8.750 0	14.200 0
	On I	2.500 0	2.500 0	4.640 0	7.500 0	12.140 0
新方法(4×4) r=11	On C	3.680 0	3.750 0	5.850 0	8.330 0	14.180 0
	On I	2.500 0	2.500 0	4.610 0	7.500 0	12.110 0
新方法(1×4) r=56	On C	3.360 0	3.120 0	5.440 0	8.750 0	14.190 0
	On I	2.500 0	2.500 0	4.660 0	7.500 0	12.160 0
新方法(7×4)r=9	On C	3.260 0	3.120 0	5.320 0	8.750 0	14.070 0
	On I	2.500 0	2.500 0	4.640 0	7.500 0	12.140 0
新方法(8×4)r=8	On C	3.260 0	3.120 0	5.350 0	8.750 0	14.100 0
	On I	2.500 0	2.500 0	4.620 0	7.500 0	12.120 0

ORL 人脸库是作为人脸识别的人脸库, 现将其用于人脸验证。从表中数据可以看出, 新方法比原方法在效果上有了提高, 至少不低于原方法的验证率。此外, 基于 Imposter 的效果要优于基于 Client 的验证效果。

综上 2 个实验, 可以看出本文的新方法在验证效果上优于原有方法。

5 结束语

本文在 CSKDA 的基础上将 M2DPCA 和 CSKDA 相结合, 提出了一种新的人脸验证算法。该算法一方面吸取了 CSLDA 使用客户相关子空间, 可以更好地描述每个人脸的特征区别于其他个体; 另一方面, 吸取了 M2DPCA 的分块和对原始数据进行处理, 可以较好地提取局部特征, 降低维数, 简化计算。还引入了核运算, 进行了非线性的推广。实验结果表明, 该算法具有较高的验证效果。此外, 实验发现不同的分块得到的结果也不相同, 因此, 如何分块得到最高的识别率有待于进一步研究。

参考文献

- [1] 边肇祺, 张学工. 模式识别[M]. 北京: 清华大学出版社, 1999: 176-197.
- [2] Turk M, Pentland A. Eigenfaces for Recognition[J]. Cognitive Neuroscience, 1991, 3(1): 71-86.

(下转第 205 页)