

分块 MMC 及其在人脸识别中的应用

刘辉¹ 万鸣华^{1,2} 王巧丽¹

(南昌航空大学无损检测技术教育部重点实验室 南昌 330063)¹

(南京理工大学高维信息智能感知与系统教育部重点实验室 南京 210094)²

摘要 用最大间距准则(Maximum Margin Criterion, MMC)算法进行特征提取时,提取的是全局的特征,对局部的特征不能有效地抽取。因此,对 MMC 算法进行改进,提出一种基于分块 MMC(Modular Maximum Margin Criterion, MMMC)的人脸识别方法。首先对图像矩阵进行分块,然后对分块后的矩阵进行 MMC 特征抽取,对每一子块抽取的特征进行整体融合,最后采用最近邻判决准则进行分类识别。在 ORL、Yale 人脸图像库进行的实验结果表明,新算法相比于 MMC 算法有更好的识别性能。

关键词 最大间距准则,分块最大间距准则,人脸识别,特征提取

中图分类号 TP391.41 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.8.017

Modular MMC and its Application in Face Recognition

LIU Hui¹ WAN Ming-hua^{1,2} WANG Qiao-li¹

(Key Laboratory of Nondestructive Testing, Ministry of Education, Nanchang Hangkong University, Nanchang 330063, China)¹

(Key Laboratory of Intelligent Perception and Systems for High-dimensional Information of Ministry of Education, Nanjing University of Science and Technology, Nanjing 210094, China)²

Abstract Maximum margin criterion(MMC) algorithm for feature extraction only extracts global features while local features can not be effectively extracted. So, an improved version of maximum margin criterion(MMC) named modular maximum margin criterion(MMMC) was proposed in this paper. First, in proposed approach, the original images are divided into modular images, which are also called sub-images. Then, MMC method is directly used to extract the features of the sub-images from the previous step. Features of sub-images are combined into global features. At last, the recognition results are obtained by nearest neighbor(NN) classifier. The results of test on ORL, Yale and AR face database show that the proposed algorithm with respect to the MMC algorithm has better recognition performance.

Keywords Maximum margin criterion, Modular maximum margin criterion, Face recognition, Feature extraction

1 引言

人脸识别涉及图像处理、模式识别、计算机视觉等多个研究领域,是目前一个非常活跃的研究方向,具有十分广泛的应用前景^[1]。特征提取是人脸识别非常重要的一个环节,人脸识别的特征抽取和描述方式大致可归纳为基于几何特征和基于统计特征两大类。早期提出的基于几何特征的提取方法对光照、表情、姿态等变化非常敏感,所以稳定性不高,识别率较低。近年来提出的方法大多是基于统计特征的方法。在众多基于统计特征的方法中,具有代表性的是主成分分析(principle component analysis, PCA)^[2]和线性鉴别分析(linear discriminant analysis, LDA)^[3]。PCA 和 LDA 已经被广泛地应用于人脸识别中进行特征降维,并取得了很好的结果。然而,PCA 和 LDA 用于人脸识别时,会碰到小样本问题^[4-6]。众多

科研工作者们提出了很多方法来解决它^[7-11],其中 Li 等^[11,12]提出了一种基于最大间距准则的特征提取方法。然而,MMC 是全局的方法,不能有效地抽取人脸图像的局部特征,对人脸表情和光照条件变化较大的图像表现尤为突出。

因此,本文继承最大间距准则的思想,提出了基于图像分块的 MMC 改进算法,即分块最大间距准则(MMMC)方法。MMMC 方法先对图像矩阵进行分块,对分块得到的子图像矩阵直接进行鉴别分析,其突出的优点是提高了特征提取的速度,在特征提取时可以完全避免使用矩阵的奇异值分解,方法简便。与 MMC 相比,在图像局部差异存在的情况下,通过分块能抽取到更能体现图像间的差异性的局部特征,有利于分类,可以实现使用低维的鉴别特征而保持较高的正确识别率的目的。最后,在 ORL、Yale 标准人脸库上的实验结果验证了该算法的有效性。

到稿日期:2014-05-23 返修日期:2014-07-15 本文受高维信息智能感知与系统教育部重点实验室(南京理工大学)基金(30920140122006),中国博士后基金(2013M530223),江苏省博士后基金(1301095C),国家自然科学基金(61203243),江西省自然科学基金(201222BAB211025),南昌航空大学研究生创新专项基金(YC2013-013)资助。

刘辉(1988-),男,硕士生,主要研究方向为图像处理, E-mail: 772507808@qq.com; 万鸣华(1978-),男,博士后,副教授,硕士生导师,主要研究方向为模式识别、机器学习等; 王巧丽(1990-),女,硕士生,主要研究方向为图像处理。

2 最大间距准则

设在高维欧氏空间中有样本集 $X = \{x_1, x_2, \dots, x_n\}$, $x_i \in \mathcal{R}^D$, 寻求一个投影矩阵 V , 希望将这些样本映射到一个相对低维的特征空间 \mathcal{R}^d , $d \leq D$. 这样, 样本在新特征空间中的表述为 $Y = \{y_1, y_2, \dots, y_n\}$, $y_i = V^T x_i$. 设矩阵 $V = \{v_1, v_2, \dots, v_d\}$ 为最佳鉴别矢量 v_i 所构成的投影矩阵.

MMC 准则的目的是能够将数据从原始的高维空间压缩到低维空间, 并使得在低维空间中保持较高的可分性, 即寻找一组最优鉴别矢量集, 使得样本数据投影到这些方向后, 特征空间的样本类间散度矩阵与类内散度矩阵之差最大. 可将最大间距准则 (MMC) 目标函数定义为:

$$\max \text{tr}(V^T (S_b - S_w) V) \quad (1)$$

$$\text{s. t. } V^T V = I \quad (2)$$

其中, S_b 为样本类间散度矩阵, S_w 为样本类内散度矩阵, 即

$$S_b = \sum_{i=1}^C n_i (m_i - m)(m_i - m)^T \quad (3)$$

$$S_w = \sum_{i=1}^C \sum_{j=1}^{n_i} (x_j^{(i)} - m_i)(x_j^{(i)} - m_i)^T \quad (4)$$

其中, C 为类别数, n_i 为第 i 类样本数, $x_j^{(i)}$ 表示第 i 类的第 j 个样本, 设第 i 类均值和总体均值分别为 m_i 和 m .

$$m_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_j^{(i)} \quad (5)$$

$$m = \frac{1}{N} \sum_{i=1}^C n_i m_i \quad (6)$$

其中, N 为样本数.

通过解广义特征方程求 MMC 算法的最优投影矩阵 V , 即

$$(S_b - S_w) v_i = \lambda_i v_i \quad (7)$$

其中, λ_i 为类间散度矩阵与类内散度矩阵之差 $(S_b - S_w)$ 的特征值, v_i 为 λ_i 所对应的特征向量. 选取 $(S_b - S_w)$ 的前 d 个最大的特征值所对应的特征矢量 $\omega_1, \omega_2, \dots, \omega_d$ 作为投影方向, 可得最优投影矩阵为:

$$V = [v_1, v_2, \dots, v_d] \quad (8)$$

由于最大间距准则方法无需求类内散度矩阵的逆矩阵, S_w 是否可逆对求最终判别矢量没有任何影响, 因此不存在奇异问题.

3 分块最大间距准则

3.1 基本思想

设 $A_i (i=1, 2, \dots, N)$ 为 $m \times n$ 的人脸训练样本图像, 每一幅人脸训练样本图像可用一个矩阵来表示. 先将一个 $m \times n$ 的图像矩阵分成 $p \times q$ 分块图像矩阵:

$$A_i = \begin{bmatrix} I_{11} & I_{12} & \dots & I_{1q} \\ I_{21} & I_{22} & \dots & \dots \\ \dots & \dots & \dots & \dots \\ I_{p1} & I_{p2} & \dots & I_{pq} \end{bmatrix} \quad (9)$$

其中:

$$I_{ij} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n_1} \\ a_{21} & a_{22} & \dots & a_{2n_1} \\ \dots & \dots & \dots & \dots \\ a_{m_1 1} & a_{m_1 2} & \dots & a_{m_1 n_1} \end{bmatrix} \quad (10)$$

每个子图像矩阵 $I_{ij} (i=1, 2, \dots, p; j=1, 2, \dots, q)$ 是 $m_1 \times n_1$ 矩阵, 其中 $p \times m_1 = m, q \times n_1 = n$, 所有的训练图像样本的子图像矩阵可以看作训练样本图像向量, 然后用 MMC 算法进行特征提取.

如上所述, 单幅训练样本图像可以分成 $p \times q$ 块, N 个训练样本图像总共有 $p \times q \times N$ 个子块. 用 $I_i^k (i=1, 2, \dots, N; k=1, 2, \dots, pq)$ 表示第 i 个训练样本的第 k 个子块.

对所有训练样本子块用 MMC 方法进行特征提取.

首先求取所有训练样本子块的平均值矩阵:

$$\bar{I} = \frac{1}{p \times q \times N} \sum_{i=1}^N \sum_{k=1}^{p \times q} I_i^k \quad (11)$$

再求取所有训练样本子块的总体散布矩阵 S :

$$S = \frac{1}{p \times q \times N} \sum_{i=1}^N \sum_{k=1}^{p \times q} (I_i^k - \bar{I})(I_i^k - \bar{I})^T \quad (12)$$

计算总体散布矩阵 S 的特征值与特征矩阵, 选取前 w 个最大的特征值对应的特征向量组成最佳投影空间 W . 将所有的训练样本子块向最佳投影空间 W 投影, 得到投影矩阵 $U_i (i=1, 2, \dots, pqN)$, 这样一共可以得到 pqN 个投影向量 (为列向量).

对测试样本进行同样的分块, 设测试样本的子块为 $J_i^k (i=1, 2, \dots, M; k=1, 2, \dots, pq)$, 将所有的测试样本子块向最佳投影空间 W 投影得到投影矩阵 $V_i (i=1, 2, \dots, pqN)$, 一共可以得到 pqN 个投影向量 (为列向量).

上面得到的 $U_i (i=1, 2, \dots, pqN)$ 和 $V_i (i=1, 2, \dots, pqN)$ 便是运用 MMC 算法提取出来的特征向量, 下一步将利用这些提取出来的特征值矩阵进行分类.

3.2 分类

通过上述特征提取过程, 每一幅原始图像都对应一个特征矩阵, 利用最近邻分类器实现对图像的分类.

(1) 将训练样本子块的投影向量 $U_i (i=1, 2, \dots, pqN)$ 按照分块时子块在原图像矩阵中对应的位置再合为一个矩阵, 设合成的矩阵为 $C_j (j=1, 2, \dots, N)$:

$$C_j = \begin{bmatrix} U_1 & U_2 & \dots & U_q \\ U_{q+1} & U_{q+2} & \dots & U_{2q} \\ \dots & \dots & \dots & \dots \\ U_{q(p-1)+1} & U_{q(p-1)+2} & \dots & U_{pq} \end{bmatrix}, j=1, 2, \dots, N \quad (13)$$

(2) 同样将测试样本子块的投影向量 $V_i (i=1, 2, \dots, pqN)$ 按照分块时子块在原图像矩阵中对应的位置再合为一个矩阵, 设合成的矩阵为 $D_i (i=1, 2, \dots, N)$:

$$D_i = \begin{bmatrix} V_1 & V_2 & \dots & V_q \\ V_{q+1} & V_{q+2} & \dots & V_{2q} \\ \dots & \dots & \dots & \dots \\ V_{q(p-1)+1} & V_{q(p-1)+2} & \dots & V_{pq} \end{bmatrix}, i=1, 2, \dots, M \quad (14)$$

(3) 计算第 i 个测试样本的合成矩阵 $D_i (i=1, 2, \dots, N)$ 与第 j 个训练样本的合成矩阵 $C_j (j=1, 2, \dots, N)$ 之间的欧氏距离 d_{ij} . 那么就可以计算出第 i 个测试样本的合成矩阵 $D_i (i=1, 2, \dots, N)$ 与所有的训练样本的合成矩阵 $C_j (j=1, 2, \dots, N)$ 之间的欧氏距离, 并设此距离为 $d_{ij} (i=1, 2, \dots, M; j=$

1, 2, ..., N), 这样一共可以计算出 N 个距离。

(4) 采用最近邻分类器进行分类。即在上一步中计算出来的 N 个距离中取最小距离, 如果这个最小距离是第 i 个测试样本的合成矩阵 D_i ($i=1, 2, \dots, N$) 与第 r 个训练样本的合成矩阵 C_j ($j=1, 2, \dots, N$) 之间的距离, 且第 r 个训练样本属于 M 类, 则判定第 i 个测试样本同属于第 M 类。

本文提出的基于图像分块的 MMC 人脸识别算法涉及到图像分块、特征提取和判决准则 3 个部分, 其算法模型如图 1 所示。基于分块的 MMC 从表示一个块的一维向量中而不是从表示整幅图像的一维向量中提取特征。表示一幅图像的一维向量的大小很明显大于表示一个块的一维向量的大小。因此与 MMC 相比, MMMC 有 2 个优点: 1) 求解特征向量需要的时间更少; 2) MMMC 能够有效地将图像的局部差异限制在某些块的特征上而不是整幅图像的特征上。

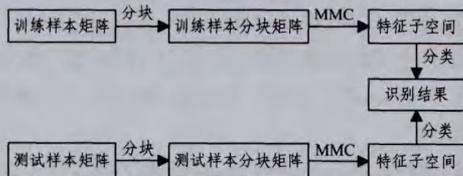


图 1 人脸识别算法模型

4 实验结果分析

为了验证本文提出的方法的有效性, 在 2 个经典的人脸数据库上 (ORL、Yale) 分别使用 MMC、MMMC 对人脸图像提取特征, 并比较几种方法的特征提取性能。ORL 人脸库用来衡量本文提出的方法在姿态和一些人脸细节变化的情况下的特征提取性能。Yale 数据库中的人脸图像是在光照和表情变化的情况下拍摄的。所有的算法均采用欧氏距离和最近邻分类器。在实验中, 为了快速得到结果, 每种算法都用 PCA 做预处理。此时, 本文保持约 95% 的图像能量。实验环境: Dell PC, CPU: Inter Athlon (tm) 64 Processor, 内存: 1024M, Matlab 7. 01。

4.1 ORL 人脸库上的实验

ORL 标准人脸图像库^[13]由 40 人、每人 10 幅图像组成, 其中有些图像是拍摄于不同时期的; 人的脸部表情和脸部细节有着不同程度的变化, 比如笑或不笑、眼睛或睁或闭、戴或不戴眼镜; 人脸姿态也有相当程度的变化, 深度旋转和平面旋转可达 20° ; 人脸的尺度也有多达 10% 的变化。图 2 是 ORL 人脸图像库中某一个人的 10 幅图像。对每一个人, 分别选取前 4、5、6 幅图像用作训练样本, 剩下的图像用作测试样本。实验中, 对原始图像矩阵进行 2×2 、 2×4 及 4×4 这 3 种分块方案, 图 3 是 ORL 人脸数据库中的一张图片分别采用 3 种不同分块方案的示意图。为便于比较, 表 1 给出了在 ORL 人脸库上不同分块方式以及不同算法的最大识别率及其对应的特征维数。同时, 当训练样本数为 5 时, 识别结果如图 4 所示。



图 2 ORL 人脸图像库中一个人的 10 张图



图 3 ORL 库人脸图像分块示意图

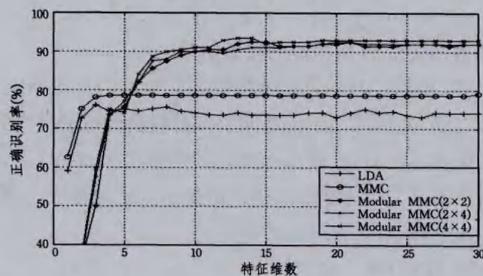


图 4 ORL 人脸库中训练样本数为 5 时, 不同算法的识别率随特征维度的变化情况

表 1 在 ORL 人脸库上不同算法的最大识别率及对应的特征维数

		LDA	MMC	MMMC		
				2x2	2x4	4x4
4	正确识别率	75.00	76.00	84.58	85.00	87.50
	鉴别特征维数	3	29	30	24	17
5	正确识别率	76.00	79.00	92.50	92.50	93.50
	鉴别特征维数	3	30	14	20	13
6	正确识别率	81.87	90.00	94.38	95.00	96.88
	鉴别特征维数	16	30	17	16	22

4.2 Yale 人脸库上的实验

Yale 人脸图像库^[14]中包括了 15 个人的 165 幅灰度人脸图像。每个人由 11 张照片构成, 这些照片在不同的表情和光照等条件下拍摄。图 5 是 Yale 人脸图像库中某一个人的 11 幅图像。分别选取每个人的 11 幅图像中的 4、5、6 幅图像用作训练样本, 剩余的用作测试样本。对于 Yale 人脸库上的实验同样考虑同 ORL 库一样的分块方案, 即 2×2 、 2×4 及 4×4 这 3 种分块方案。图 6 是 Yale 人脸数据库中的一张图片分别采用 3 种不同分块方案的示意图。为便于比较, 表 2 给出了在 Yale 人脸库上不同分块方式以及不同算法的最大识别率及其对应的特征维数。同时, 当训练样本数为 5 时, 识别结果如图 7 所示。



图 5 Yale 人脸图像库中一个人的 11 张图



图 6 Yale 库人脸图像分块示意图

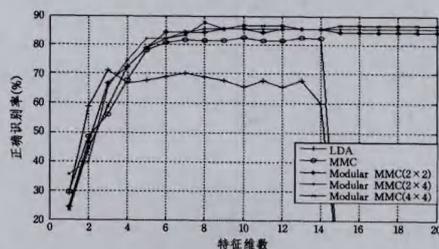


图 7 Yale 人脸库中训练样本数为 5 时, 不同算法的识别率随特征维度的变化情况

表2 在Yale人脸库上不同算法的最大识别率及对应的特征维数

	LDA	MMC	MMMM			
			2×2	2×4	4×4	
4	正确识别率	68.09	74.76	85.71	85.71	87.62
	鉴别特征维数	7	9	14	9	11
5	正确识别率	71.11	82.53	85.56	85.56	87.78
	鉴别特征维数	3	10	9	8	8
6	正确识别率	77.33	82.67	88.50	88.00	89.67
	鉴别特征维数	13	2	8	9	12

4.3 实验结果分析

(1)表1、表2中的数据均表明无论采用哪种分块方式,实验结果都比原来方法的人脸识别率要高。随着训练样本数目的不同,正确识别率也有所不同。

(2)从图4及图7中可以看出,对于3种不同的分块方式,本文方法的结果均明显优于LDA及MMC方法。

(3)Modular MMC方法是MMC方法的推广,通过对图像进行分块,再对每一子块抽取得到与直接将MMC方法用于原始图像抽取的全局特征相比更具有鉴别性的局部特征,这些局部特征更能表现图像的差异性,从而取得了较好的识别效果。

结束语 本文提出了一种基于图像分块的最大间距准则(MMMC)的人脸识别方法,该方法是对MMC方法的改进和推广。与MMC方法相比,它的突出优点是在人脸图像局部差异(姿态、表情、光照、细节)存在的情况下,通过分块能抽取到图像的局部特征,这些局部特征更好地体现了图像间的差异性,有利于分类,降低了MMC方法提取特征矩阵的维数,有利于加快特征提取速度。实验结果表明,MMMM方法能得到比全局方法MMC更好的特征提取性能。然而在实验中发现,子图像的划分不同,得出的识别性能有所不同,如何找到最佳分块来获得最佳的识别性能还需要进一步的研究。未来将扩展MMMM算法到流形学习上,提出多流形分块算法。

参 考 文 献

[1] 马汝成. 基于子空间线性投影的人脸识别方法研究[D]. 南昌: 华东交通大学, 2008
Ma Ru-cheng. Study of Face Recognition based on Subspace Linear Projection[D]. Nanchang, East China Jiaotong University, 2008

[2] Turk M, Pentland A. Eigenfaces for Recognition [J]. Journal of

Cognitive Neuroscience, 1991, 3(1):71-86

[3] 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

[4] Raudys S J, Jain A K. Small sample size effects in statistical pattern recognition: recommendations for practitioners [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, 13(3):252-264

[5] Swets Daniel L, Weng J. Using discriminant eigenfeatures for image retrieval [J]. IEEE Trans. Pattern Anal. Machine Intell (S0162-8828), 1996, 18(8):831-836

[6] Belhumeur Peter N, Hespanha Joao P, Kriegm David J. Eigenfaces vs. Fisherfaces; Recognition using class specific linear projection [J]. IEEE Trans. Pattern Anal. Machine Intell (S0162-8828), 1997, 19(7):711-720

[7] Chen L, Liao H, Ko M, et al. A new LDA-based face recognition system which can solve the small sample size problem [J]. Pattern Recognition, 2000, 33(10):1713-1726

[8] Yu H, Yang J. A direct LDA algorithm for high-dimensional data-with application to face recognition [J]. Pattern Recognition, 2001, 34(11):2067-2070

[9] Yang J, Yang J-Y. Why can LDA be performed in PCA transformed space? [J]. Pattern Recognition, 2003(36):563-566

[10] Dai D Q, Yuen P C. Regularized discriminant analysis and its application on face recognition [J]. Pattern Recognition, 2003, 36(1):845-847

[11] Li H, Jiang T, Zhang K. Efficient and robust feature extraction by maximum margin criterion [C] // Proc. Adv. Neural Inf. Process. Syst. . 2003:97-104

[12] Li H, Jiang T, Zhang K. Efficient and robust feature extraction by maximum margin criterion [J]. IEEE Transactions on Neural Networks, 2006, 17(1):1157-1165

[13] Olivetti & Oracle Research Laboratory. The Olivetti & Oracle Research Laboratory Face Database of Faces [OL]. <http://www.cam-orl.co.uk/facedatabase.html>, 1994

[14] Yale University Face Database [OL]. <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>, 2002

(上接第47页)

[10] Rizvandi N B, Taheri J, Zomaya A Y. On using pattern matching algorithms in MapReduce applications [C] // The 9th IEEE International Symposium on Parallel and Distributed Processing with Applications (ISPA). 2011:75-80

[11] Sun Y J, Todorvic S, Goodison S. Local Learning Based Feature Selection for High Dimensional Data Analysis [J]. On Pattern Analysis and Machine Intelligence, 2010, 32(9):1610-1626

[12] Li Y, Lu B L. Feature selection based on loss margin of nearest neighbor classification [J]. Pattern Recognition, 2009, 42:1914-1921

[13] Han Y, Yu L. A variance reduction framework for stable feature

selection [C] // Proc. Int'l Conf. on Data Mining. 2010:206-215

[14] Zinkevich M, Weimer M, Smola A, et al. Parallelized stochastic gradient descent [J]. Advances in Neural Information Processing Systems, 2010:1-37

[15] Ranger C, Raghuraman R, Penmetsa A, et al. Evaluating MapReduce for Multicore and Multiprocessor Systems [C] // Proceedings of 2007 IEEE 13th International Symposium on High Performance Computer Architecture. 2007:13-24

[16] Lichman M. UCI Machine Learning Repository [OL]. <http://archive.ics.uci.edu/ml/>

[17] <http://www.nipsfsc.ecs.soton.ac.uk/datasets/>