

自适应阈值及加权局部二值模式的人脸识别

张洁玉* 赵鸿萍 陈曙

(中国药科大学理学院 南京 211198)

摘要: 针对局部二值模式(LBP)和中心对称局部二值模式(CS-LBP)方法描述图像纹理特征时, 阈值不能自动选取并且图像中不同子块的贡献也没有进行区分的问题, 该文提出一种自适应阈值及加权的局部二值模式方法。首先, 将图像进行分块, 采用设定的自适应阈值提取每个子块的 LBP 或 CS-LBP 纹理直方图; 然后, 将各子图像的信息熵作为直方图的加权依据, 对每个子块对应的直方图进行自适应加权, 并将所有子块的直方图连接成最终的纹理特征; 最后, 通过快速计算图像均值加快了算法的计算速度。在人脸数据库上进行的实验证明, 利用该文提出的方法提取纹理特征, 并结合最近邻分类法可以得到较高的正确识别率。

关键词: 人脸识别; 纹理特征; 局部二值模式; 自适应阈值; 自适应加权

中图分类号: TP391.41

文献标识码: A

文章编号: 1009-5896(2014)06-1327-07

DOI: 10.3724/SP.J.1146.2013.01218

Face Recognition Based on Weighted Local Binary Pattern with Adaptive Threshold

Zhang Jie-yu Zhao Hong-ping Chen Shu

(School of Science, China Pharmaceutical University, Nanjing 211198, China)

Abstract: A new method called weighted Local Binary Pattern (LBP) with adaptive threshold is proposed in this paper to address the shortcomings of LBP and Center Symmetric Local Binary Pattern (CS-LBP), using unflexible threshold and non-discriminating respective sub-patches based on different textures. Firstly, the image is divided into several sub-images and LBP or CS-LBP texture histograms are extracted respectively from each sub-image based on the adaptive threshold. Then, the proposed algorithm adaptively weighted the LBP or CS-LBP histograms of sub-patches with information entropy as their basis and connected all histograms serially to create a final texture descriptor. Finally, the improved efficiency of the proposed algorithm is achieved by speeding up the computation of the average of an image. The experimental results by face databases show that a higher recognition accuracy can be obtained by employing the proposed method with nearest neighbor classification.

Key words: Face recognition; Texture features; Local Binary Pattern (LBP); Adaptive threshold; Adaptively weighted

1 引言

图像特征提取是图像处理及计算机视觉等领域的一个重要研究内容, 图像配准、物体识别、目标跟踪以及基于内容的图像检索等问题都可以通过特征的提取与匹配来实现^[1]。常用的图像特征有颜色特征、形状特征及纹理特征, 其中由于纹理特征简单有效而倍受国内外学者的青睐。

目前纹理分析方法可以总结为 4 大类, 即: 统计法、结构法、模型法和空域/频域联合法, 其中结构分析法的研究内容为如何描述纹理基元之间的内

在相互关系和排列规则。在较早的结构分析法中, 具有代表性的是由文献[2]提出的通过描述中心像素和邻域像素灰度差来描述纹理的方法^[2]。文献[3]提出了局部二值模式(Local Binary Pattern, LBP)纹理描述法^[3]。该方法简单高效, 具有良好的旋转不变性和灰度不变性, 已经广泛应用于目标检测^[4]、人脸识别^[5,6]、纹理分类^[7,8]、图像匹配^[9]、背景建模^[10]、生物和医学图像分析等领域^[11]。但在实际应用中, LBP 方法难以适应不同粗糙度和尺度纹理的需要, 近年来许多学者在具体应用中对 LBP 进行了不少相应的改进, 其中较有代表性的是香港理工大学和清华大学共同针对 LBP 做了一系列深入的研究。例如, 提出了基于方向统计的自适应局部二值模式, 增加了图像的空间结构信息^[12]; 提出了局部二值模

2013-08-13 收到, 2013-12-18 改回

教育部直属高校特色项目基金(O2600005)和中国药科大学理学院青年教师科研资助课题

*通信作者: 张洁玉 zhjy_xx@126.com

式与方差相结合的纹理表示方法,将每个点的方差作为编码值的权重,提高了纹理分类性能^[13]。此外,文献[14]在 LBP 的基础上提出了局部三值模式(Local Ternary Patterns, LTP)^[14],LTP 通过 0, 1 和 -1 3 个值进行编码,在均匀区域比 LBP 具有更强的判别能力。LTP 特征已经在图像匹配^[15]、人脸识别^[16]领域得到了较好的应用效果。

传统的 LBP 模式对单调的图像区域不具有鲁棒性,并且由于该模式会产生 256 个不同的二进制值,导致形成的统计直方图维数较高,因此出于简化 LBP 和减少运算的目的,文献[17]提出了中心对称局部二值模式(Center Symmetric LBP, CS-LBP)^[17]。该模式维数低,抗噪能力强,引起了广泛的关注^[18-20]。但 LBP 和 CS-LBP 模式本身存在共同的缺陷,例如在提取图像纹理特征时,阈值不能自动选取,鲁棒性较差。另外,一般情况下图像中不同子块包含的信息量也不尽相同,而 LBP 和 CS-LBP 模式并没有区分不同子块的贡献,一定程度上降低了正确识别率。针对以上问题,本文提出了一种自适应阈值选取及加权的局部二值模式方法(Weighted LBP with Adaptive Threshold, W-LBPAT)。该方法首先将图像分为不同子块,结合自适应阈值提取各个子块的 LBP 或 CS-LBP 特征,然后利用每个子块对应的信息熵构造加权系数,将生成的各 LBP 或 CS-LBP 特征乘以对应的系数之后连接成一个完整的纹理特征。该纹理特征在人脸数据库中进行了验证实验,结果表明改进的新算法有效地提高了正确识别率。

2 LBP 与 CS-LBP

2.1 LBP

在灰度图像中,任意一点记为 n_c ,在以该点为中心半径为 R ($R=1$ 或 $R=2$)的环形邻域上, P ($P=8$ 或 $P=16$)个像素点均匀分布。对于刚好不是处于某个像素上的点,可利用插值法得到其像素值。设以该邻域中心像素为基准的纹理为 T ,则 T 使用邻域中的 $P+1$ 个像素可定义为

$$T = t(s(g_0 - g_c), s(g_1 - g_c), \dots, s(g_{p-1} - g_c)) \quad (1)$$

其中, g_c 代表中心像素 n_c 的灰度值, g_0 到 g_{p-1} 代表环形邻域上的 P 个点的灰度值。 s 是权重系数,当周边像素灰度值大于中心像素时, s 为 1, 否则为 0。由此可以得到一个 P 位的二进制数,每一位乘以相应的权重系数求和累加得到 LBP 值,即

$$\text{LBP}_{P,R} = \sum_{i=0}^{P-1} s(g_i - g_c) 2^i \quad (2)$$

其中

$$s(u) = \begin{cases} 1, & u \geq T, \text{通常 } T = 0 \\ 0, & \text{其它} \end{cases} \quad (3)$$

对于图像中的每个像素点都可以计算得到一个 LBP 特征值,将这些特征值进行直方图统计,就能够得到图像模式特征的统计分布情况。利用 LBP 统计直方图可以进行纹理分类、人脸识别等应用,并且性能较好。但 LBP 直方图随着半径 R 的增大和邻域像素点 P 的增加,直方图维数会显著增高,计算量也会随之提高,导致后续识别工作的运算效率降低,由此文献[17]提出了 CS-LBP 模式来解决这个问题。

2.2 CS-LBP

CS-LBP 不同于 LBP 的地方在于,它不再依次比较邻域周边 P 个像素和中心像素的灰度值,而是比较基于中心像素对称的两个周边像素点的灰度值,即

$$\text{CS-LBP}_{P,R}(x,y) = \sum_{i=0}^{P/2-1} s(g_i - g_{i+P/2}) 2^i \quad (4)$$

其中 s 依然是权重系数,当中心对称的两个像素点的灰度差大于某个阈值 T 时, s 为 1, 否则为 0。

$$s(u) = \begin{cases} 1, & u \geq T \\ 0, & \text{其它} \end{cases} \quad (5)$$

CS-LBP 相比 LBP 统计直方图的维数更低,LBP 直方图维数为 2^P , 而 CS-LBP 直方图维数为 $2^{P/2}$, 计算复杂度显著降低,能够适应实时计算的需求。另外,当图像存在噪声干扰时,CS-LBP 比 LBP 的抗噪能力更强^[21]。

目前,LBP 模式中的阈值 T 一般选为 0, 很少有学者针对该阈值的选取进行研究。CS-LBP 模式中阈值 T 有两种选择:将 T 置为 0 或 0.01^[17]。但是对于不同的图像,无论 LBP 还是 CS-LBP,阈值 T 如果始终选为固定值,必然使得局部二值模式不能具备良好的鲁棒性。如果能够根据图像的自身情况,自适应选取合适的阈值,则局部二值模式才能够更加真实地反映图像中纹理细节的变化情况。另外,通常情况下一幅图像中不同子块所包含的信息量的大小是不同的,而 LBP 和 CS-LBP 模式都没有区别对待不同子块,使得提取的纹理信息独特性不高。针对以上问题,本文提出了 W-LBPAT 纹理特征,该改进方法同时适用于原 LBP 和原 CS-LBP 特征,分别称之为 W-LBPAT(LBP) 和 W-LBPAT(CS-LBP)。

3 W-LBPAT 特征的构造

3.1 图像分块

原始 LBP 和 CS-LBP 模式都是一次性提取了整

个图像的纹理特征, 没有区别对待图像中的不同子块。但事实上, 图像中不同子块包含的纹理细节是不同的。若有的子块纹理细节较为丰富, 应该将该子块赋予较大的权重, 而纹理细节较为稀少的子块应赋予较小的权重, 这样最终得到的 LBP 或 CS-LBP 纹理特征才能最大程度地真实反映图像纹理的变化情况。因此, 在本文提出的 W-LBPAT 纹理模式中, 首先将原始图像划分为若干小块, 然后求出每个子块对应的 LBP 或 CS-LBP 统计直方图特征, 最后将它们串联起来作为最终的纹理特征。

3.2 提取各子块纹理特征

将图像划分为若干子块之后, 提取每个子块的 LBP 或 CS-LBP 统计直方图。提取时, 涉及到两方面的改进, 即: 自适应选取阈值和计算加权系数。

3.2.1 选取自适应阈值 W-LBPAT 纹理模式中, 阈值 T 根据图像自身情况自适应选取。选取方法为计算中心像素邻域内所有像素点的均值, 将该均值的 $n\%$ 设为阈值 T , 本文通过一系列实验获得 n 的最终取值。

以半径 $R = 1, P = 8$ 为例, 即考虑以当前像素点为中心, 周围 8 邻域的点情况。则此时

$$\begin{aligned} \text{W-LBPAT} = & s(g_0 - g_4)2^0 + s(g_1 - g_5)2^1 \\ & + s(g_2 - g_6)2^2 + s(g_3 - g_7)2^3 \end{aligned} \quad (6)$$

其中

$$s(u) = \begin{cases} 1, & u \geq T, T = \frac{1}{P} \sum_{i=0}^{P-1} g_i \times n\% \\ 0, & \text{其它} \end{cases} \quad (7)$$

3.2.2 选取自适应加权系数 一般情况下, 一幅图像中不同子块包含的信息量是不同的。纹理丰富的区域包含的信息量大, 反之包含的信息量小。若不区分地对待不同的区域, 则会降低纹理特征的独特性, 影响识别率的提升。

Shannon 在 1948 年将熵的概念应用于信息理论中, 提出了信息熵理论。信息熵反映了图像中信息量的大小, 信息熵越大, 表明纹理细节越丰富; 反之, 纹理细节越稀少。因此, 在新算法中首先计算各个子块的信息熵。设图像分为 m 个子块, 则第 i 个子块的信息熵表示为

$$E_i = -\sum_{k=1}^n p_i^k \lg p_i^k \quad (8)$$

其中, n 表示像素级数, 取为 256。 p_i^k 表示第 k 级像素点出现的概率。子块的信息熵越大, 则赋予它越大的权重, 由此第 i 个子块的权重系数定义为

$$w_i = E_i / \left(\sum_{i=1}^m E_i \right) \quad (9)$$

3.3 生成 W-LBPAT 特征

设 $v_i, i = 1, 2, \dots, m$ 为各个子块对应的统计直方图向量, 则将各个子块的直方图向量进行加权连接后可以得到最终的 W-LBPAT 特征向量, 即

$$V = (w_1 v_1, w_2 v_2, \dots, w_m v_m) \quad (10)$$

图 1 为采用 W-LBPAT(CS-LBP)提取人脸图像特征的效果图, 由于该算法的原理是利用自适应阈值判断关于中心对称的像素点灰度值的对比情况来描述纹理, 因此可以得到非常清晰的图像局部纹理的反差效果。

3.4 快速算法

计算 W-LBPAT 特征时, 自适应阈值选为中心像素点邻域内所有像素点平均值的 $n\%$ 。每考察一个像素点, 就要计算一次邻域均值, 直到遍历完一整幅图像为止。如图 2 所示, 图中显示了以某两个相邻像素点为中心(半径 $R = 1, P = 8$ 为例)的周围 8 个像素组成的邻域。左斜线填充区域代表以像素点 (i, j) 为中心的 8 像素邻域 M , 右斜线填充区域代表以点 $(i, j + 1)$ 为中心的 8 像素邻域 N , 算法需要求得这些区域中像素的均值作为阈值。从图中可以看出, 前后两个区域存在大量的重叠部分, 如果每次单独计算这些区域的均值, 会造成很多重复性劳动, 使得算法很耗时。因此, 有必要寻找一种简单快速的方法计算每个邻域的均值, 提高算法的运算效率。

本文提出的算法中, 在提取 W-LBPAT 特征前, 事先遍历图像中的每个像素点, 计算出以每个像素点为中心的邻域内所有像素的均值。而相邻像素对应的邻域之间包含大量的重叠部分(如图 2 所示), 为了加快运算速度可以采取如下措施简化计算过程。

求邻域均值前先求邻域内所有像素和, 设图 2 中邻域 M 内的 9 个像素和为 SUM_M 。计算邻域 N 内的 9 个像素和时, M 和 N 重叠部分的 6 个像素和不再重复计算, 则邻域 N 的像素和 SUM_N 可通过下式得到

$$\begin{aligned} \text{SUM}_N = & \text{SUM}_M - \text{SUM}(i-1:i+1, j-1) \\ & + \text{SUM}(i-1:i+1, j+2) \end{aligned} \quad (11)$$

其中, $\text{SUM}(i-1:i+1, j-1)$ 表示第 $j-1$ 列的 $i-1, i$ 和 $i+1$ 行的 3 个像素和; $\text{SUM}(i-1:i+1, j+2)$ 代表第 $j+2$ 列的 $i-1, i$ 和 $i+1$ 行的 3 个像素和。按照此法, 计算所有水平方向相邻的两个邻域的均值时, 后一个邻域的均值都可用前一个邻域的均值快速计算得到。同理, 所有竖直方向相邻的两个邻域, 后一个邻域的均值可用同样的方法快速计算得到, 如图 3 所示。设以像素点 (i, j) 和 $(i+1, j)$ 为中心的邻域



图1 W-LBPAT算法提取特征效果

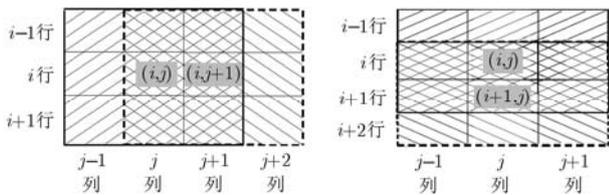


图2 水平相邻像素邻域示意图 图3 竖直相邻像素邻域示意图

分别为 U 和 V , 邻域 U 的像素和为 SUM_U , 则邻域 V 的像素和 SUM_V 为式(12)所示。

$$SUM_V = SUM_U - SUM(i-1, j-1: j+1) + SUM(i+2, j-1: j+1) \quad (12)$$

其中, $SUM(i-1, j-1: j+1)$ 和 $SUM(i+2, j-1: j+1)$ 分别表示第 $i-1$ 行及第 $i+2$ 行的 $j-1, j$ 和 $j+1$ 列的3个像素和。

按照上述方法, 遍历整幅图像中的所有像素点, 可以快速求出所有像素点邻域的均值, 为后续提取 W-LBPAT 纹理特征做好准备。本文使用不加速 W-LBPAT(CS-LBP)及加速 W-LBPAT(CS-LBP)算法针对 ORL 人脸库、YALE 人脸库和 FERET 人脸库

中大小分别为 112×92 (400幅)、 100×100 (165幅)和 80×80 (350幅)的人脸图像进行了特征提取的时间测试, 结果如表1所示。

表1 两种算法提取人脸图像特征的时间(s)

识别算法	人脸库		
	ORL	YALE	FERET
不加速W-LBPAT	0.0829	0.0780	0.0500
加速W-LBPAT	0.0393	0.0439	0.0279

4 实验与分析

4.1 自适应阈值 T 的选取

在改进算法中, 自适应阈值的选取方法(见3.2.1节)为

$$T = Ave \times n\% \quad (13)$$

其中, Ave 为中心像素邻域内所有像素点的均值。 n 值的选取要通过一系列实验后经过比较得到。文中的人脸识别实验都是在 ORL 人脸库、YALE 人脸库

和 FERET 人脸库上进行的。

ORL 人脸库包含 40 个人, 每个人有 10 幅人脸图像, 共 400 幅, 其中包括姿态、表情和面部饰物(如眼镜)等变化。每幅图像均为 112×92 的灰度图像, 图 4 即为 ORL 人脸库部分图像。YALE 人脸库包括了 15 个人共 165 幅图像, 每个人有 11 幅图像, 其中的姿态和光照变化都是在严格控制条件下采集的, 每幅图像均为 100×100 , 图 5 为 YALE 人脸库的部分图像。

FERET 不仅包含通用的人脸库还包含了通用的测试标准。该图像库包括 ba, bj, be 和 bf 等若干子库, 如图 6 所示。它们都含有同样的 200 个人的人脸图像, 其中 ba 含有每人 1 张正面人脸图像, bj 包含与 ba 中表情不同的每人 1 张图像, be 包含 ba 中每个人脸左转 15° 的图像, 而 bf 中包含 ba 中每个人脸右转 15° 的图像。

本文结合最近邻分类器进行人脸识别实验, 在 ORL 人脸库中, 对于每个人的 10 幅图像随机取 5 张作为训练样本, 剩下的 5 张为测试样本, 则训练样本数和测试样本数各为 200。YALE 人脸库中, 随机取每个人的 5 幅图像作为训练样本, 剩下的 6 幅图像作为测试样本, 训练样本数和测试样本数分别为 75 和 90。而在 FERET 人脸库中, 采用通用

测试标准测试, 即: 利用子库 ba 中的 200 张图像作为训练样本, bj, be 和 bf 3 个子库作为测试样本。

为了能够合适地取到阈值 T 中的 n , 本文利用 W-LBPAT 特征进行了一系列的对比实验, 即考察将 n 取为 $0.01 \sim 0.10$ (步长为 0.01) 中的每个值时, 算法对应的正确识别率的变化情况。

随着 n 值的变化, 由图 7 可以看出: 在 ORL 和 YALE 两个人脸库中, 改进的 W-LBPAT(LBP) 特征和 W-LBPAT(CS-LBP) 特征对应的人脸识别率波动的幅度均较小。在 FERET 的 3 个子库中, 两种特征对应的识别率波动的幅度均相对稍大一些。由图 7 的 10 条曲线可以得知, 当 n 为 0.05 时, 基本可以使得各条曲线接近或达到峰值。因而, 自适应阈值 T 选择为

$$T = Ave \times 5\% \quad (14)$$

4.2 人脸识别实验

为了检验 W-LBPAT 特征的有效性, 本文将 LBP, CS-LBP, LTP 及 W-LBPAT 特征分别在 ORL 人脸库、YALE 人脸库和 FERET 人脸库上进行人脸识别实验。其中, 对于 ORL 人脸库和 YALE 人脸库通过随机更换训练样本和测试样本而各自分别进行 3 次识别实验, 最后取 3 次识别率的均值。而



图 4 ORL 人脸库部分图像



图 5 YALE 人脸库部分图像



图 6 FERET 人脸库部分图像

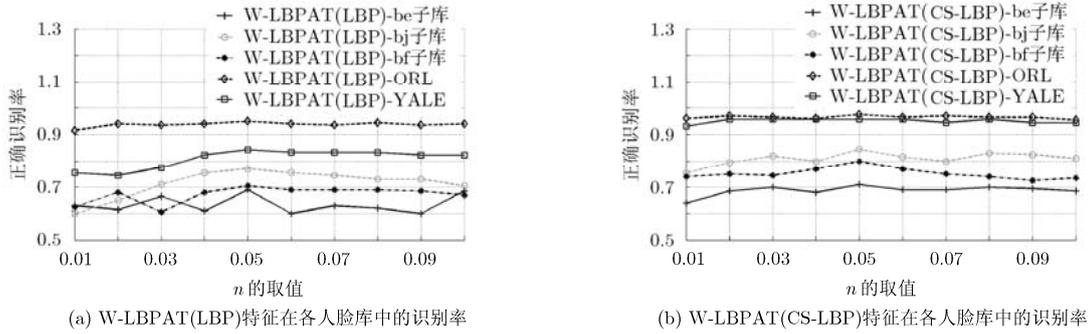


图 7 改进算法对应的识别率随 n 值变化的曲线图

对于 FERET 人脸库采用通用测试标准进行识别测试。

各类算法均采用了分块做法，即：先将图像分成若干小块，然后提取各子块的 LBP, CS-LBP 或 LTP 特征，之后再将各个子特征进行串联生成最终的纹理特征。在本文实验中，首先将图像分成了 $4 \times 4 = 16$ 个子块后再利用各算法进行人脸识别。每种算法对应的正确识别率见表 2。

从表 2 可以得出以下结论：

(1)在各人脸库中，识别率由低到高的顺序基本可以归纳为：LBP, CS-LBP 和 LTP 分块一类算法，LBP, CS-LBP 和 LTP 分块并自适应加权一类算法，本文的 W-LBPAT(CS-LBP), W-LBPAT(LBP) 算法。通过各自比较每种特征相应的分块算法、分块并自适应加权算法以及本文算法，可以看出自适应加权策略对识别率的提升有一定的帮助。本文算法除了分块并自适应加权外，还在提取特征时采用了自适应阈值的策略，致使识别率得到了进一步地提升。

(2)W-LBPAT(LBP)和 W-LBPAT(CS-LBP)得到了最高的识别率，这是因为：(a)W-LBPAT 算法是将图像进行分块后，计算了每个子块的信息熵，

并以此作为各个子块的加权系数，然后提取每个子块的特征后对各子块进行加权串联，形成了最终的 W-LBPAT 特征。(b)在提取每个子块的 CS-LBP 或 LBP 纹理特征时，根据每个子块的像素平均值自适应设定阈值，利用该阈值能够依据图像自身的情况提取真实的纹理特征，因此 W-LBPAT 得到了最高的正确识别率。

(3)在各种 CS-LBP, LTP 和 LBP 算法中，识别率由低到高的顺序基本可以总结为：LBP 一类算法、LTP 一类算法和 CS-LBP 一类算法。这是因为：CS-LBP 一类算法比以 LBP 为基础的一类算法在梯度方向上能够获取更好的信息，而 LTP 一类算法是以 LBP 为基础利用相同的提取原理得到了种类更多的纹理模式，因此使得 LTP 一类算法比 LBP 算法识别率更高，但是大多数情况其识别率要低于 CS-LBP 一类算法。

5 结束语

本文在 LBP 和 CS-LBP 算法的基础上，提出了自适应阈值及加权的局部二值模式纹理特征提取算法。本文的工作主要包含 3 个方面：(1)不再提取整幅图像的特征，而是将图像分块，提取每个子块的

表 2 各种算法识别率比较

识别算法	人脸库				
	ORL(3 次均值)	YALE(3 次均值)	FERET(be 子库)	FERET(bj 子库)	FERET(bf 子库)
分块 LBP	0.8583	0.7353	0.615	0.635	0.610
分块 CS-LBP	0.9467	0.7418	0.635	0.740	0.740
分块 LTP	0.9183	0.8009	0.615	0.650	0.620
分块+自适应加权 LBP	0.8750	0.7941	0.635	0.650	0.615
分块+自适应加权 CS-LBP	0.9433	0.7843	0.665	0.770	0.770
分块+自适应加权 LTP	0.9167	0.8102	0.615	0.670	0.625
W-LBPAT(LBP)	0.9500	0.8333	0.690	0.780	0.705
W-LBPAT(CS-LBP)	0.9650	0.9491	0.710	0.845	0.800

特征后利用各个子块的信息熵进行加权,再串联成最终的特征;(2)提取每个子块的 LBP 或 CS-LBP 特征时,根据子块图像自身的情况设定阈值,利用该阈值提取纹理特征;(3)采用快速计算图像均值的方法,加快了本文提出算法的计算速度。在人脸数据库上进行的实验证明,本文提出的算法具有更高的正确识别率。

参考文献

- [1] 张洁玉. 图像局部不变特征提取与匹配及应用研究[D]. [博士学位论文], 南京理工大学, 2010.
 - [2] He D C and Wang L. Texture unit, texture spectrum, and texture analysis[J]. *IEEE Transactions on Remote Sensing*, 1990, 28(4): 509-512.
 - [3] Ojala T, Pietikainen M, and Harwood D. A comparative study of texture measures with classification based on feature distributions[J]. *Pattern Recognition*, 1996, 29(1): 51-59.
 - [4] 潘泓, 金立左, 夏思宇, 等. 基于多层次互补特征的通用目标检测模型[J]. *电子与信息学报*, 2012, 34(7): 1531-1537.
 - [5] 黄非非. 基于 LBP 的人脸识别研究[D]. [硕士学位论文], 重庆大学, 2009.
 - [6] 徐杜功, 丁召, 刘桥. 基于稀疏表达和改进的 LBP 算子的人脸表情识别[J]. *计算机应用与软件*, 2013, 30(4): 246-248.
 - [7] 韩延彬, 尹键芹, 李金屏. 基于图元旋转不变性和相位统计信息的 LBP 算法在纹理分类中的研究[J]. *计算机学报*, 2011, 34(3): 583-592.
 - [8] Ojala T, Pietikainen M, and Maenpaa T. Multi-resolution grayscale and rotation invariant texture classification with local binary patterns[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(7): 971-987.
 - [9] 郑永斌, 黄新生, 丰松江. SIFT 和旋转不变 LBP 相结合的图像匹配算法[J]. *计算机辅助设计与图形学学报*, 2010, 22(2): 286-292.
 - [10] 祖仲林, 李勃, 陈启美. 基于 CUDA 的快速 LBP 纹理背景建模算法[J]. *武汉理工大学学报(交通科学与工程版)*, 2011, 35(1): 91-94.
 - [11] 陈廷寅, 张东, 杨艳, 等. 超声图像的 LBP 纹理特征提取[J]. *武汉大学学报(理学版)*, 2012, 58(5): 401-405.
 - [12] Guo Z H, Zhang L, Zhang D, et al. Rotation invariant texture classification using adaptive LBP with directional statistical features[C]. *Proceedings of the 17th IEEE International Conference on Image Processing, Hong Kong, China, 2010: 285-288.*
 - [13] Guo Z H, Zhang L, and Zhang D. Rotation invariant texture classification using LBP variance (LBPV) with global matching[J]. *Pattern Recognition*, 2010, 43(3): 706-719.
 - [14] Tan X and Triggs B. Enhanced Local Texture Feature Sets for Face Recognition under Difficult Lighting Conditions[M]. Berlin Heidelberg Springer, 2007: 168-182.
 - [15] 赵灵芝, 李伟生. 一种基于 LTP 特征的图像匹配方法[J]. *计算机应用研究*, 2009, 26(10): 3983-3985.
 - [16] 袁宝华, 王欢, 任明武. 融合 LTP 与 Fisherfaces 的分块人脸识别[J]. *计算机工程*, 2012, 38(10): 154-156.
 - [17] Heikkila M, Pietikainen M, and Schmid C. Description of interest regions with local binary patterns[J]. *Pattern Recognition*, 2009, 42(3): 425-436.
 - [18] 卢建云, 何中市, 余磊. 基于多级 CS-LBP 特征融合的人脸识别方法[J]. *计算机工程与科学*, 2010, 32(6): 48-51.
 - [19] 刘丹, 胡永健, 刘琪贝. 联合 SIFT 特征点和 CS-LBP 特征描述子的复制粘贴篡改检测[J]. *合肥工业大学学报(自然科学版)*, 2012, 35(3): 325-330.
 - [20] 刘毅, 黄兵, 孙怀江, 等. 结合 CS-LBP 纹理特征的快速图割算法[J]. *计算机科学*, 2013, 40(5): 300-302.
 - [21] 李勃, 郁健, 江登表, 等. 基于 ST-CSLBP 的混合时空背景建模算法[J]. *仪器仪表学报*, 2011, 32(12): 2781-2786.
- 张洁玉: 女, 1980 年生, 讲师, 研究方向为图像处理及其在药学领域的应用研究.
- 赵鸿萍: 女, 1971 年生, 副教授, 研究方向为药学信息的获取与数据挖掘.
- 陈 曙: 男, 1965 年生, 教授, 研究方向为信息技术和药学信息学研究.