

## 基于均匀 $k$ 均值和高维局部二值模式的人脸识别算法

邓燕妮<sup>†</sup>, 褚四勇, 涂林丽, 赵东明, 刘小珠

(武汉理工大学 控制科学与工程系, 武汉 430000)

**摘 要:** 针对传统局部二值模式 (LBP) 及其一些改进方法会将具有不同灰度特征的邻域赋予相同的特征值和特征维数倍增的问题, 提出一种基于均匀  $k$  均值和高维局部二值模式的算法. 该算法首先对原图进行切割得到子图; 然后提取子图的高维局部二值模式特征, 利用均匀  $k$  均值对高维特征进行降维处理; 最后级联所有的子图特征进行分析. 为了验证该算法的性能, 在 ORL 人脸库和 YALE 人脸库以及 FERET 人脸库上进行对比实验, 结果表明该算法在保证特征维数不递增的前提下, 能够明显提高 LBP 算法的识别率.

**关键词:** 均匀  $k$  均值; 高维局部二值模式; 特征提取; 人脸识别

中图分类号: TP391.41

文献标志码: A

## Face recognition algorithm based on homogeneous $k$ -means and high-dimensional local binary pattern

DENG Yan-ni<sup>†</sup>, CHU Si-yong, TU Lin-li, ZHAO Dong-ming, LIU Xiao-zhu

(Department of Control Science and Engineering, Wuhan University of Technology, Wuhan 430000, China)

**Abstract:** In view of the problem that the traditional local binary pattern(LBP) and its extensions give the same eigenvalues and multiplication of feature dimension to the neighborhoods with different gray features, an algorithm based on the homogeneous  $k$ -means and high-dimensional local binary pattern is proposed. Firstly, the algorithm gets the sub-graph by cutting the original image, then extracts the high-dimensional local binary pattern characteristics of sub-graph and uses the homogeneous  $k$ -means to process the high-dimensional features by dimension reduction. Finally, the features of all the sub-graphs are cascaded to be analyzed. To verify the performance of the algorithm, the comparative experiments on the ORL face database, YALE face database and FERET face database are conducted, and the results show that the algorithm obviously improve the recognition rate of the LBP algorithm on the premise of ensuring that the feature dimension doesn't increase.

**Keywords:** homogeneous  $k$ -means; high-dimensional local binary pattern; feature extraction; face recognition

### 0 引 言

随着人们生活需求的日益增加, 人脸识别作为一种安全、高效的生物识别技术已成为当下研究的热门. 局部二值模式<sup>[1-3]</sup>因其优秀的图像纹理描述能力而在人脸识别领域中频频出现. 鉴于其简明有效的描述特性, 众多学者对局部二值模式进行研究并提出了许多改进和优化的方法.

为了提取到局部邻域中更多的信息, 赵玉丹等<sup>[4]</sup>提出了一种 float-LBP 算法, 通过提取邻域点之间的灰度变化信息增加提取的信息量; 袁宝华等<sup>[5-6]</sup>提出了一种完整局部二值模式 (CLBP) 算法, CLBP 算子包含差分、符号和数值 3 个部分, 使得所提取的信息

更加丰富; 王成等<sup>[7]</sup>提出了一种多尺度加权的 LBP 算法, 通过加权多个尺度上的局部信息来增强算子的描述能力; 为了增加局部二值算法对光照的鲁棒性, Girish 等<sup>[8-9]</sup>提出了 MB-LBP 算法, 该算法中进行比较的不是某一个像素点而是某一个区域内像素点的灰度均值, 大大地增加了算法对光照的抑制性; 李伟生等<sup>[10]</sup>提出了一种自适应阈值的 LTP 算法, 通过设定阈值来减少算法对中心点的依赖、增加对噪声的抑制能力.

上述对局部二值模式的改进方法主要集中在如何从局部提取鲁棒性更强的信息, 忽略了邻域和全局之间关系以及特征向量的维数. 本文从这两个缺陷

收稿日期: 2016-04-12; 修回日期: 2016-06-18.

基金项目: 国家 863 计划项目 (2015AA015904).

作者简介: 邓燕妮 (1962—), 女, 教授, 从事计算机控制与应用、过程智能控制与优化等研究; 褚四勇 (1991—), 男, 硕士生, 从事模式识别、图像处理的研究.

<sup>†</sup>通讯作者. E-mail: 719145031@qq.com

为起点进行研究, 提出基于均匀k均值和高维局部二值模式的方法. 实验结果表明, 该方法在保证特征维数不增加的前提下, 能够明显提高传统局部二值模式的识别能力.

### 1 高维局部二值模式

在局部二值模式及其一些改进方法中, 重点关注邻域内的灰度特性, 而忽略了全局的灰度特性, 导致图像特征信息提取不完整. 如图1所示, 两个具有不同灰度特征的8-邻域经过LBP计算后得出相同的特征值.

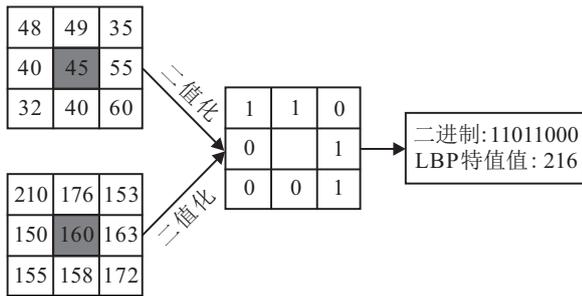


图1 LBP特征缺陷示意图

为解决这一问题, 本文提出一种高维局部二值模式(HDLBP)方法, 通过将中心特征作为高维分量加入二进制序列的办法进行区分. 分析图1, 两个灰度值相差较大的8-邻域经过二值化以后的二进制序列完全相同, 导致计算出的LBP特征值相同, 但其中心像素点的灰度值较好地体现了二者的区别. 考虑到全局特征引入的目的, 对具有相同LBP特征值的邻域内中心像素点灰度值和整幅图像的灰度均值之间的内在关系进行研究, 发现以整幅图像的灰度均值为阈值对邻域内中心像素点的灰度值进行区分, 可以很好地解决上述问题. 首先, 对邻域内边缘像素点采用经典LBP二值化的算法进行二值化, 提取边缘特征, 即局部特征; 其次, 以整幅图像的灰度均值为阈值对邻域内中心像素点进行二值化, 提取中心特征, 即全局特征; 最后, 整合边缘二值化与中心二值化的结果.

在转化二进制序列为特征值的过程中, 如何合理融合边缘二值化与中心二值化的结果又成为研究的重点. 在不打破边缘二进制序列的前提下, 将中心特征融入边缘特征中只有两种情况, 即中心特征作为最高维分量或最低维分量加入边缘二进制序列中, 如图2所示.



图2 LBP特征融合图

分析图2, 在边缘特征值相同的条件下, 中心特征作为最低维分量时, 无论中心特征是否相同, 计算出的特征值在数值上的差异度都较低, 不大于1, 中心特征作为最高维时, 由于中心特征的不同, 计算出的特征值在数值上具有指数级变化的差异度, 其差异度非常大. 解决图1中问题的关键是融入中心特征, 通过中心特征的不同进行区分, 即融合后由于中心特征的不同而引起特征值的不同越明显越好, 因此本文选择将中心特征作为最高维分量加入边缘二进制序列的方法. 算法的具体过程如图3所示.

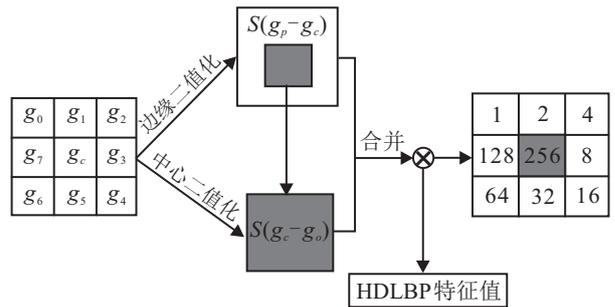


图3 HDLBP特征的计算过程

对于每一个邻域, 特征值提取的方法不再是单独的边缘特征提取, 而是边缘特征和中心特征同时提取, 然后将中心特征作为最高维融入边缘二进制序列, 得到完整的特征二进制序列. 边缘特征的提取过程沿用的是经典的LBP二值化过程, 中心特征的提取过程类似于边缘特征的提取过程, 将中心像素灰度值以整幅图像的灰度均值为阈值进行二值化. 将特征提取的过程转化成计算公式, 即

$$g_o = \frac{1}{m \times n} \sum_{i=0}^m \sum_{j=0}^n g(i, j), \tag{1}$$

$$HL = \sum_{p=0}^{n-1} 2^p s(g_p - g_c) + 2^n s(g_c - g_o). \tag{2}$$

其中:  $g(i, j)$  为像素点的灰度值,  $g_o$  为图像灰度均值,  $g_c$  为邻域内中心像素点的灰度值,  $g_p$  为邻域内边缘像素点灰度值,  $n$  为选取邻域内像素点个数,  $HL$  为邻域的特征值,  $s$  为阶跃函数.

对图1中出现的问题, 利用高维局部二值模式方法即可解决. 中心特征作为高维分量的加入, 使得具有相同边缘特征的邻域在中心特征的作用下提取到差异度很大的特征值, 并且灰度值较大的邻域提取出的特征值较大, 灰度值较小的邻域提取出的特征值较小. 从邻域这一角度分析, 高维分量的加入, 使得边缘特征向高一维伸展, 扩大了提取特征值的范围, 特征值的表现能力更强; 从整幅图像这一角度分析, 由于提取的特征值范围变大, 导致特征图像体现的纹理信

息更丰富,视觉效果更好,如图4所示.



(a) LBP 特征图 (b) 原图 (c) HDLBP 特征图

图4 特征图像对比图

## 2 均匀 $k$ 均值降维

经过特征提取得到的特征向量,最理想的情况是包含最多信息量的同时维数也达到最低.但是,包含的信息量越多相应的维数也越高,维数较低时包含的信息量也必然有限,难以达到区分的目的.因此,对信息量比较大的特征向量进行降维处理是比较合理的方法,可以达到二者兼顾的目的.特征降维的原理是将高维的数据通过线性或非线性的变换映射到低维空间,从而获得一个关于原始数据集紧密的低维表示.高维到低维映射的核心是抓住主要特征,忽略或是兼并非主要特征,使相同类型的特征向量之间的差异度更低,不同类型之间的差异度更高.

直方图是对整幅图像进行数据统计的一种方法,统计的是图像中每一灰度值出现的频率,频率越高,具有该灰度值的像素点个数越多.特征图像的直方图表示每一种特征值出现的频率,特征值的范围越大,直方图的维数越高,进行模式识别的难度越大.因此,对特征向量进行降维处理的核心是在不降低直方图之间差异度的条件下,降低特征值的范围.

分析传统的降维处理方法,如PCA、LDA和LPP等<sup>[9,11-12]</sup>有一个共同的特点,需要将所有的特征向量集合在一起才能进行计算,然后按照某种规则进行处理来达到降维的目的.一个明显的缺陷是将所有的特征向量集合在一起进行处理时会大大增加计算的难度.而利用 $k$ 均值<sup>[13]</sup>进行降维时,只需要对每一列特征向量单独进行聚类处理,大大减少了计算的复杂度. $k$ 均值算法是一种快速的聚类算法,目标是将 $n$ 个对象划分为 $k$ 类,使每个类内差异度渐小,类间的差异度渐大,从而得到一个理想的聚类.但是 $k$ 均值算法的不足之处是对初始聚类中心点非常敏感,为了改善这一不足,本文根据人脸图像特征向量的数值分布特性,提出一种均匀 $k$ 均值算法,核心思想是选取均匀分布的初始数据点作为聚类的初始聚类中心点,如图5所示.

具体的处理方法为:首先确定特征值中的最大值和最小值,然后根据 $k$ 值将处于两个最值之间的范围均匀地分成 $k-1$ 段区域,间隔区域的 $k$ 个点即为所

选取的初始聚类中心点.特征向量一般是一维向量,

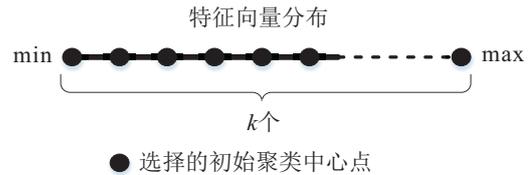


图5 初始点的选择方法示意图

因此只考虑一维条件下的计算公式,即

$$P_n = \frac{\max(D) - \min(D)}{k-1} (n-1). \quad (3)$$

其中: $D$ 为数据集, $k$ 为初始聚类中心点的个数, $p_n$ 为第 $n$ 个初始聚类中心点.通过式(3)计算初始聚类中心点必须首先确定 $k$ 的值,在实际应用中 $k$ 值的确定一般是根据经验得到,理论上得出的 $k$ 的范围是 $2 \leq k \leq N$ , $N$ 为数据集 $D$ 的大小.为了明确地计算出 $k$ 的取值,研究 $k$ 值在取不同值的情况下,聚类的结果有什么不同.对 $0 \sim 255$ 之间的灰度值构成的集合在不同 $k$ 值条件下利用均匀 $k$ 均值算法进行聚类处理,记录下每次聚类后的总体误差,得到图6.

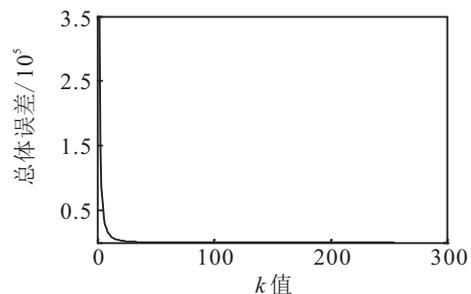


图6 误差变化示意图

由图6可知:随着 $k$ 值的增大,总体误差由急剧下降变换到平缓下降. $k$ 值越大,聚类的效果越好; $k$ 值越小,聚类的效果越差.结合本文的降维要求,在降维的同时必须保持特征向量之间的差异度,以保证识别率不受太大影响.对应到聚类的处理要求,即 $k$ 值越小越好,总体误差越小越好.根据以上分析建立一个评价函数

$$\mu = \alpha \frac{e}{\max(e)} + (1-\alpha) \frac{k}{\max(k)}. \quad (4)$$

其中: $e$ 为总体误差, $\alpha$ 为权重系数.对于不同的 $k$ 值,利用式(4)都可计算出相应的 $\mu$ 值,选择最小的 $\mu$ 值对应的 $k$ 值即为最佳的取值.经过分析确定 $k$ 值和初始聚类中心后,利用均匀 $k$ 均值算法对特征向量进行聚类处理建立映射表,然后根据映射表对特征向量进行降维映射,即可得到降维后的特征向量.对映射结果的分析可知,直方图统计的不再是单一的特征值出现的频率,而是经过聚类后属于同一类的特征值出现的频率,保证在不丢失大量信息的条件下,有效地实现

了维数的降低.

### 3 实验与分析

实验所用到的人脸识别数据库是 ORL 数据库(样本个数:测试个数 = 5 : 5,共 400张)和 YALE 数据库(样本个数:测试个数 = 6 : 5,共 165张)以及 FERET 数据库(样本个数:测试个数 4 : 3 =,共 1400张). 进行特征向量识别时统一使用最邻近算法以示对比. 实验主要分为两个部分:降维前和降维后算法识别率及特征向量维数的对比实验.

#### 3.1 降维前对比实验

分块数的多少直接影响算法的性能,因此选取合适的分块数非常重要. 选取分块数为  $1 \times 1, 2 \times 2, 3 \times 3, 4 \times 4, 5 \times 5$  的 LBP 算法和 HDLBP 算法进行实验,得到图 7 和图 8.

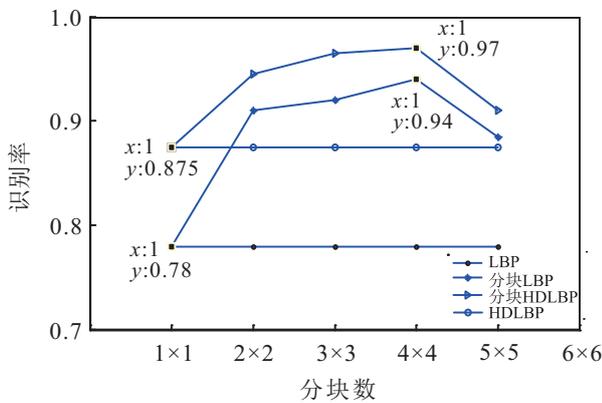


图 7 识别率对比图

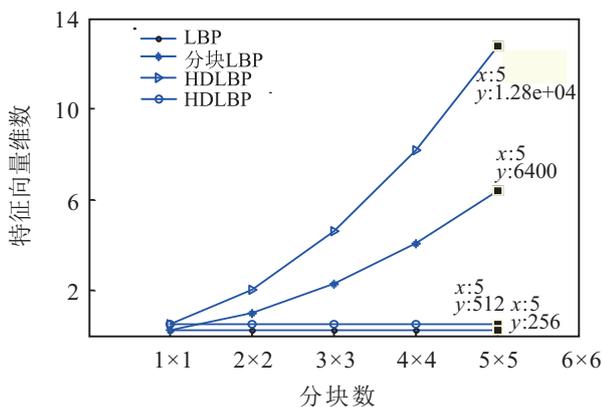


图 8 特征向量维数对比图

由图 7 和图 8 可知:

- 1) 在分块数为  $1 \times 1$  时,高维局部二值模式算法的识别率高于传统的局部二值模式算法,提升大约 9%;
- 2) 高维局部二值模式算法的识别率高于传统局部二值模式算法,并且不受分块数的影响;
- 3) 随着分快数的增加,两种算法的识别率都是先增加后减少,在分块数为  $4 \times 4$  时算法的识别率达到最高;
- 4) 高维局部二值模式提取特征向量的维数是传统局部二值模式的两倍,并且不受分块数影响;
- 5) 随着分块数的增加,两种算法提取的特征向量的维数越来越大;
- 6) 高维局部二值模式算法同样存在错误识别的情况,其主要原因是改进后的算法解决了传统局部二值模式算法不能提取全局特征的问题,但是对于局部特征信息提取不完全的缺陷却没有弥补,如:邻域点之间的灰度变化信息完全丢失,所以依然存在错误分类和识别率较低的情况.

#### 3.2 降维后对比实验

利用均匀  $k$  均值算法分别对 LBP 和 DHLBP 提取的特征向量进行降维处理,分块数统一选择为  $4 \times 4$ ,权重系数  $\alpha$  取 0.9,得到表 1.

分析表 1 可知:

- 1) 经过降维处理后,高维局部二值模式算法的识别率高于传统局部二值模式算法的识别率;
- 2) 经过降维处理后,两种算法的识别率都没有出现明显的波动,基本保持不变,但是特征向量的维数大大降低,单个样本的识别时间也大大降低;
- 3) 随着数据库样本个数的增加,降维处理后的算法在时间上的优势越来越显著;
- 4) 基于均匀  $k$  均值和高维局部二值模式的算法相比于传统的局部二值模式算法,大幅提高了算法识别率,同时保证特征向量维数不递增;
- 5) 在 FERET 数据库上运行时所有算法的识别率都不高,其原因是相比于 YALE 和 ORL 数据库,FERET 数据库里统计的人脸图像较多、较复杂.

表 1 降维前后实验结果对比

算法	YALE			ORL			FERET		
	识别率/%	维数	时间/s	识别率/%	维数	时间/s	识别率/%	维数	时间/s
LBP	76	256	0.0953	78	256	0.1413	31.17	256	0.2854
分块+LBP	96	4096	0.4092	94	4096	1.0201	72.83	4096	5.1975
HDLBP	81.33	512	0.1631	87.5	512	0.2555	49	512	0.5759
分块HDLBP	98.67	8192	0.8129	97	8192	2.0397	78.17	8192	8.9611
均匀 $k$ 均值+分块+LBP	94.67	416	0.3526	96	416	0.4723	64.17	416	1.0141
均匀 $k$ 均值+分块+HDLBP	98.67	512	0.8381	96.5	512	1.0943	70.17	512	1.5820

## 4 结 论

对比传统的局部二值模式算法,本文提出的高维局部二值模式算法在识别率上有较大提升,但是特征向量的维数倍增;区别于传统的降维处理,均匀 $k$ 均值算法降维处理更加简单,速度更快,对人脸识别率的影响更小.实验表明,二者相结合以后的算法,达到了优势互补,在提高算法识别率的同时能够保证特征向量基本保持不变.但也有不足之处,高维局部二值模式算子对全部变量的引入不够充分,对局部特征信息的提取不够详细, $k$ 值的选择受样本大小的影响较大,仍需继续研究.

### 参考文献(References)

- [1] Ojala T, Harwood I. A comparative study of texture measures with classification based on feature distributions[J]. *Pattern Recognition*, 1996, 29(1): 51-59.
- [2] Ojala T, Pietikäinen M, Mäenpää T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. *IEEE Trans on Pattern Analysis & Machine Intelligence*, 2002, 24(7): 971-987.
- [3] 宋克臣, 颜云辉, 陈文辉, 等. 局部二值模式方法研究与展望[J]. *自动化学报*, 2013, 39(6): 730-744.  
(Song K C, Yan Y H, Chen W H, et al. Research and perspective on local binary pattern[J]. *Acta Automatica Sinica*, 2013, 39(6): 730-744.)
- [4] 赵玉丹, 王倩, 范九伦. 基于Float-LBP算法的纹理图像检索[J]. *计算机应用*, 2014, 34(12): 3545-3548.  
(Zhao Y D, Wang Q, Fan J L. Texture images retrieval based on Float-LBP[J]. *J of Computer Applications*, 2014, 34(12): 3545-3548.)
- [5] 袁宝华, 王欢, 任明武. 基于完整LBP特征的人脸识别[J]. *计算机应用研究*, 2012, 29(4): 1557-1559.  
(Yuan B H, Wang H, Ren M W. Face recognition based on completed local binary pattern[J]. *Application Research of Computers*, 2012, 29(4): 1557-1559.)
- [6] 王宪, 张彦, 慕鑫, 等. 基于改进的LBP人脸识别算法[J]. *光电工程*, 2012, 39(7): 109-114.  
(Wang X, Zhang Y, Mu X, et al. The face recognition algorithm based on improved LBP[J]. *Opto-Electronic Engineering*, 2012, 39(7): 109-114.)
- [7] 王成, 郭飞, 赖雄鸣, 等. 多尺度加权LBP的人脸识别[J]. *光电工程*, 2014, 41(4): 82-88.  
(Wang C, Guo F, Lai X M, et al. Face recognition based on multiple weight local binary pattern[J]. *Opto-Electronic Engineering*, 2014, 41(4): 82-88.)
- [8] Girish G N, Shrinivasa Naika C L, Das P K. Face recognition using MB-LBP and PCA: A comparative study[C]. *Int Conf on Computer Communication and Informatics*. IEEE, 2014: 1-6.
- [9] 杨海燕, 刘国栋. 基于MB-LBP算子和Multilinear PCA算法的人脸识别[J]. *计算机应用研究*, 2012, 29(12): 4733-4735.  
(Yang H Y, Liu G D. Face recognition based on MB-LBP operator and multi-linear PCA algorithm[J]. *Application Research of Computers*, 2012, 29(12): 4733-4735.)
- [10] 李伟生, 王立逗, 周丽芳. 一种基于LTP自适应阈值的人脸识别方法[J]. *小型微型计算机系统*, 2014, 35(9): 2099-2103.  
(Li W S, Wang L D, Zhou L F. Research on the local adaptive threshold ternary pattern for face recognition[J]. *J of Chinese Computer Systems*, 2014, 35(9): 2099-2103.)
- [11] Wu J, Trivedi M M. A two-stage head pose estimation framework and evaluation[J]. *Pattern Recognition*, 2008, 41(3): 1138-1158.
- [12] 曹洁, 吴迪, 李伟. 基于鉴别能力分析和LDA\_LPP算法的人脸识别[J]. *吉林大学学报: 工学版*, 2012, 42(6): 1527-1531.  
(Cao J, Wu D, Li W. Face recognition based on discrimination power analysis and LDA-LPP algorithm[J]. *J of Jilin University: Engineering and Technology Edition*, 2012, 42(6): 1527-1531.)
- [13] 薛红, 李晗, 王瑜. 基于局部二值模式与 $K$ -均值的人脸识别[J]. *计算机工程与设计*, 2014, 35(11): 3879-3882.  
(Xue H, Li H, Wang Y. Face recognition based on LBP and  $K$ -means[J]. *Computer Engineering and Design*, 2014, 35(11): 3879-3882.)

(责任编辑: 孙艺红)