

# 基于动态主成分子空间的人脸识别算法

邹建法<sup>1</sup> 龚 勋<sup>1,2</sup> 王国胤<sup>1,2</sup>

(重庆邮电大学计算机科学与技术研究所 重庆 400065)<sup>1</sup>

(西南交通大学信息科学与技术学院 成都 610031)<sup>2</sup>

**摘 要** 在基于子空间分析的人脸识别中,通常是按照特征值的大小来确认主成分的重要性,并以此为基础构造一个固定的特征子空间。通过人脸图像重建分析,发现固定的特征子空间会给人脸识别带来误差,于是采用多元线性回归分析理论,提出一个动态主成分子空间构造算法。在此基础上,得到了动态 PCA(主成分分析)算法和基于 Gabor 特征的动态 PCA 算法。由 ORL 和 Georgia Tech 人脸数据库上的实验结果表明,该算法不仅减少了主成分数目,而且提高了识别率。

**关键词** 人脸识别,特征选择,主成分分析,Gabor 特征,回归分析

## Face Recognition Based on Dynamic Principal Component Subspace

ZOU Jian-fa<sup>1</sup> GONG Xun<sup>1,2</sup> WANG Guo-yin<sup>1,2</sup>

(Institute of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)<sup>1</sup>

(School of Information Science and Technology, Southwest Jiaotong University, Chengdu 610031, China)<sup>2</sup>

**Abstract** The significance of principal component was determined by the corresponding eigenvalue in face recognition based on subspace analysis, then a static feature subspace was established. However, it could result in an inaccurate performance by analyzing the process of face reconstruction. A dynamic feature subspace algorithm was proposed according to multiple linear regression analysis. Furthermore, a dynamic principal component analysis (DPCA) and a Gabor feature based dynamic principal component analysis (GDPCA) were brought forward. Experiment results on ORL and Georgia Tech face databases show that the proposed algorithm not only decrease the number of principal components but also increase the correct rate of face recognition.

**Keywords** Face recognition, Feature selection, Principal component analysis, Gabor feature, Regression analysis

## 1 引言

人脸识别是模式识别领域中的一个经典而富有挑战性的研究课题。人脸图像特征的提取与选择作为人脸识别中关键的一步,直接决定了人脸识别的效果。人脸识别经过几十年的发展出现了许多的人脸图像特征提取算法,特别是从上世纪 80 年代后期开始, Kirby 和 Sirovich<sup>[1]</sup> 将 K-L 变换的思想引入到图像表示领域中,提出了一种最小均方差意义下描述人脸图像的最优技术。随后, Turk 和 Pentland<sup>[2]</sup> 利用重构权重向量作为识别的特征,开创性地提出了“特征脸”(也称 PCA) 识别技术,并在很大程度上促进了基于表观 (Appearance-based) 的子空间和基于统计人脸识别技术的发展,使其逐渐成为主流的人脸识别技术。其他比较有代表性的工作有 Fisher-Face 方法<sup>[3]</sup>、Bayesian 方法<sup>[4,5]</sup>、独立成分分析 (ICA)<sup>[6]</sup> 等。

传统的子空间构造方法都是按照一定的静态规则来进行特征向量选择的,比如选择最大的  $k$  个特征值对应的特征向量。这样,对不同的识别个体都是同样的特征子空间。但是,

我们通过对 PCA 算法的研究发现,由于个体的差异性,从训练样本静态选择的各个主成分对测试样本并非都有用。如果对于不同的测试样本我们选择同样子空间,会存在一些干扰识别的主成分。根据 PCA 工作原理,训练集的人脸图像可以由特征子空间完整地重构,但是特征子空间中的主成分是从所有训练样本数据中得到抽象集合,并非都与待识别人脸图像有关。因此,本文在前期工作的基础上<sup>[7]</sup>,基于统计学理论,提出了一种动态主成分子空间构造算法。在 ORL 和 Georgia Tech 人脸数据库进行了验证,取得了较好的识别效果。

本文第 2 部分从人脸图像重建的角度出发,对主成分的作用进行了分析,然后提出了动态主成分子空间构造算法,并用该算法对传统的 PCA 和基于 Gabor 特征的 PCA 算法 (Gabor feature based Principal Component Analysis algorithm, 简称 GPCA) 进行改进,提出了 DPCA 和 GDPCA 算法;第 3 部分对所采用的分类器进行介绍;第 4 部分分别在 ORL 和 Georgia Tech 人脸库做了实验并进行讨论;最后总结本文工作。

到稿日期:2008-03-20 本文受新世纪优秀人才支持计划(NCET),重庆市计算机网络与通信重点实验室开放基金“基于三维重建的人脸识别研究”,重庆市自然科学基金(No. CSTC2007BB2445)资助。

邹建法 硕士研究生,主要研究方向为计算机视觉、人脸识别,E-mail: zbzoujianfa@163.com;龚 勋 博士研究生,主要研究方向为计算机视觉、模式识别;王国胤 博士,教授,博士生导师,主要研究领域为模式识别、神经网络、粗糙集、粒计算。

## 2 动态主成分分子空间构造算法

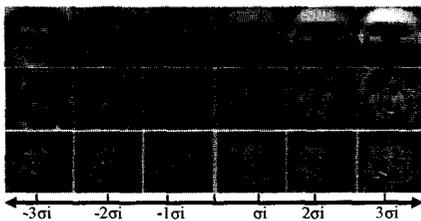
### 2.1 基于 PCA 的人脸重建分析

PCA 算法简单有效,目前仍然是人脸识别领域流行的算法之一<sup>[8,9]</sup>,同时也是对比测试时的基准识别算法。对于一幅大小为  $I_h \times I_w$  的人脸图像,依次将其每列相连,则构成一个大小为  $N=I_h \times I_w$  维的列向量,人脸图像就可以看作  $N$  维空间中的一个点。其实,人脸图像在这个高维空间中是存在一定规律的,即可以找到一个相对低维的“最优特征空间”的数据,来代替原始空间的高维数据,也可以说是找到某一个最有利于识别而且维数又大大降低的特征空间。如何找这个特征子空间  $W^T(\omega_1, \omega_2, \dots, \omega_k)^T$ ,就成了主成分分析算法的本质工作。该算法的基本思路就是找到一组最能反映训练样本分布特点的基向量,用这组基向量来表述“最优特征子空间”。把图像  $X(x_1, x_2, \dots, x_N)$  通过“最优特征子空间”投影得到特征数据  $Y(y_1, y_2, \dots, y_k)$ ,其数学形式可以按下式来表示:

$$Y=W^T X \quad (1)$$

其中  $X \in R^N, Y \in R^K, K \ll N, W^T$  代表基向量<sup>①</sup>。

PCA 处理后的主成分之间是正交的,如图 1 所示。从图 1 可以看到,不同的主成分从不同的方面反映了人脸的特征:第 1 主成分大致反映光照、姿态(人脸俯仰)等大轮廓的差异;第 10 主成分大致反映了头发和眼镜的变化;第 35 主成分比较明显地反映了人脸胡须的变化等局部变化。可以看出,从第 1 主成分到第  $k$  主成分是特征脸的一个由粗到细的变化过程。利用传统的人脸识别算法通常是选择最大的  $k$  个特征值对应的主成分作为特征子空间  $W^T$ 。特征值代表了其所对应的主成分在训练库中的信息含量,然而特征值大的主成分不一定与一个新的测试人脸相关,这是由训练库样本的限制引起的。也就是说,在训练库相对重要的成分而对一个新的人脸却可有可无,反之,在训练库中并不突出的特征可能对新的人脸影响较大。因此,如果完全按照特征值大小来选取特征矩阵,可能会引入干扰人脸分类的信息,为后续的分类带来误差。



三行分别是第 1,10,35 主成分对中性脸的作用结果。该图是在 ORL 人脸库中选取 40 张正面人脸图像训练得到的效果示例图。

图 1 单一主成分对中性人脸作用图

### 2.2 动态主成分分子空间构造算法

经过 PCA 处理后,可以用初选特征子空间重建出人脸图像  $\hat{X}$ ,人脸图像的重建其数学形式如式(2)所示。

$$\hat{X}=WY=y_1 \omega_1 + y_2 \omega_2 + \dots + y_k \omega_k \quad (2)$$

按照统计理论,把式(2)中的  $\hat{X}$  看作要预测的结果。选择

<sup>①</sup>也就是 PCA 算法初选的特征子空间。

自变量  $\omega_i (i=1, \dots, k)$  的基本指导思想是少而精,如果特征子空间中包含过多的无效成分,反而会降低特征子空间的预测精度。基于以上考虑,我们提出基于初选特征子空间的动态主成分分子空间构造算法,采用  $t$  检验对每个主成分进行线性相关性显著检验,筛选与当前特定人脸最相关的主成分构成特征子空间。令  $R = \|WY - X\|^2$  为人脸图像的重建误差平方和,其自由度为  $f_R = (N - K - 1)$ ,  $W$  的协方差矩阵为  $C_W = W^T \cdot W$ ,然后对第  $i$  成分( $\omega_i$ )我们假设:

$$H_{0,i}: y_i = 0, 1 \leq i \leq K \quad (3)$$

根据  $t$ -检验,  $H_{0,i}$  的拒绝域为

$$A = \{t_i > t_{\alpha/2}(f_R)\} \quad (4)$$

$$t_i = \frac{(|y_i| \cdot \sqrt{f_R})}{(R \cdot c_{i,i})} \quad (5)$$

其中,  $\alpha$  是显著性水平,  $c_{i,i}$  是矩阵  $(C_W)^{-1}$  主对角线上第  $i$  个元素。

关于  $H_{0,i}$  的假设如果被接受,则表明第  $i$  个成分与当前人脸图像线性相关关系不显著,应该从特征子空间中将其剔除,然后重新计算新的  $Y$  值。如果检验结果是同时有多个成分与当前人脸图像线性相关性不显著,则选取  $t_i$  值最小的成分加以剔除,然后更新  $Y$  值,继续检验,直到余下的成分全部显著为止。给定初选特征向量  $W^T$ ,动态主成分分子空间构造算法的过程如下:

(a) 根据待测试样本  $X$  来计算初选特征子空间  $W^T$  上的特征数据  $Y$ ;

(b) 根据式(5)为  $Y$  的每一分量  $y_i$  计算相应的  $t_i$ ,如果  $\forall t_i > t_{\alpha/2}(f_R), 1 \leq i \leq K$ ,转步骤(d);否则,转步骤(c);

(c) 从特征子空间  $W^T$  中删除最小  $t_i$  所对应的主成分,得到新特征子空间  $W^{T*}$ ,同时删除  $Y$  对应的分量  $y_i$ ,得到新特征数据  $Y^*$ ,转步骤(b);

(d) 用最终的特征子空间  $W^{T*}$  计算训练样本的特征数据  $Y^*$ 。

从上面的算法过程可以看出,如果有多个成分与当前形状线性相关性不显著,单个的逐步检验会带来很高的时间复杂度,所以我们在实际的试验中采用了一次性剔除多个成分的做法。

在传统的 PCA 算法基础上,用本文提出的动态主成分分子空间构造算法对传统的 PCA 算法初步选定特征子空间进一步筛选,选取对当前测试人脸有用的主成分。改进后的新算法称为 DPCA,其算法流程如图 2 所示。

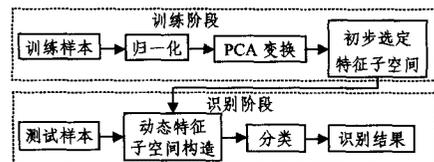


图 2 DPCA 算法流程

### 2.3 GDFPCA 算法

二维 Gabor 小波可以提取图像不同的频率尺度和纹理方向上的特征信息。Jones 和 Palmer<sup>[10]</sup>用电生理试验测量了视觉皮层 VI 区简单细胞空间及空间频谱的相应特性。在统计

意义下,这些响应特性可以用二维 Gabor 函数相当好地拟合。Gabor 小波可以提取图像特定区域内的多尺度、多方向空间频率特征,就像显微镜一样放大灰度的变化,这样人脸图像中的眼睛、鼻子和嘴以及其他的一些局部特征被放大。因此,利用 Gabor 特征来处理人脸图像,可以增强一些关键的局部特征,以区分不同人脸图像,Gabor 小波也因此图像特征提取领域内得到广泛的应用<sup>[11,12]</sup>。本文也引入 Gabor 滤波器来分解输入的人脸图像。所采用的 Gabor 滤波器数学表示形式如式(6)所示。

$$\psi_j(\vec{x}) = \frac{||\vec{K}_j||^2}{\sigma^2} \exp\left(-\frac{||\vec{K}_j||^2 ||\vec{x}||^2}{2\sigma^2}\right) \left[ \exp(i\vec{K}_j \cdot \vec{x}) - \exp\left(-\frac{\sigma^2}{2}\right) \right] \quad (6)$$

其中  $\vec{K}_j = K_v \cdot \exp(i\varphi_\mu)$ ,  $K_v = 2^{-\frac{v+2}{2}} \pi$ ,  $\varphi_\mu = \mu \frac{\pi}{8}$ 。

人脸图像的 Gabor 特征由人脸图像和 Gabor 滤波器的卷积得到。令  $I(x, y)$  表示人脸图像的灰度分布,那么  $I(x, y)$  和 Gabor 滤波器的卷积可以定义为

$$G(x, y, v, u) = I(x, y) * \psi_j(\vec{x}) \quad (7)$$

其中, \* 表示卷积运算。通常情况下,我们采用 5 个中频率和 8 个方向组成的 40 个 Gabor 滤波器  $\vec{K}_j$ ,  $v=0, \dots, 4, \mu=0, \dots, 7, j=\mu+8v$ 。这样我们就可以得到人脸图像的多层 Gabor 滤波器的分解表示。

考虑到如前所述的 Gabor 滤波器的诸多优良特性,我们把 Gabor 特征引入进来,用本文提出的动态主成分子空间构造算法对 GPCA 选定的特征子空间做进一步筛选,选取对当前测试人脸有用的主成分。改进后的算法称为 GDPCA,其算法流程如图 3 所示。

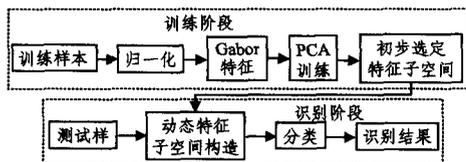


图 3 GDPCA 算法流程

### 3 分类器

本文工作重点在于分析人脸图像特征。本文采用最近邻欧氏距离分类器,对提取的特征进行分类。任意两个向量  $B_i(b_1^{(i)}, b_2^{(i)}, \dots, b_k^{(i)})$  和  $B_j(b_1^{(j)}, b_2^{(j)}, \dots, b_k^{(j)})$ , 它们之间的距离定义为:

$$d(B_i, B_j) = \sum_{l=1}^k (b_l^{(i)} - b_l^{(j)})^2 \quad (8)$$

假设由训练样本集得到的特征向量为  $B_1, B_2, \dots, B_M$ ,  $M$  为训练样本的个数,  $B$  为待测试样本, 如果  $d(B, B_i) = \min_{j=1, \dots, M} d(B, B_j)$ , 我们就认为  $B$  和  $B_i$  是同一个类别。

### 4 仿真实验

#### 4.1 实验平台简介

实验采用了 ORL(AT&T) 和 Georgia Tech 人脸数据库。ORL 人脸数据库共有 400 张图像,共 40 个人,每个人有 10 种不同姿态与表情的正面人脸图像,人脸面部表情及面部修

饰都是变化的。这些图像分别是不同的角度来拍摄的,分辨率为  $112 \times 92$ ,灰度级为 256,部分代表图片如图 4 所示。

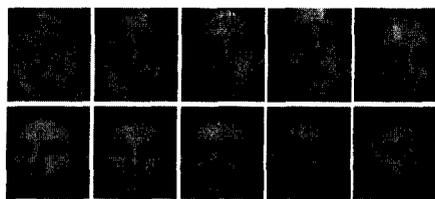


图 4 ORL 人脸示例图

Georgia Tech<sup>®</sup> 人脸数据库共有 750 张图像,共 50 个人,每个人有 15 种正面图像,包含了各种表情、小幅度俯仰姿态、深度旋转、不同距离和光照。手工切割出人脸区域的图像,并把人脸图像归一化为分辨率为  $80 \times 64$ ,灰度级为 256,部分代表图片如图 5 所示。

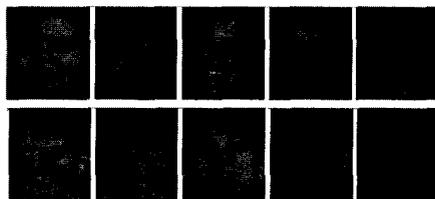


图 5 Georgia Tech 人脸示例图

实验环境条件为 Pentium 4, CPU 为 2.67GHZ, 内存为 512M, Matlab 7.1 软件环境。

#### 4.2 实验结果及分析

首先, ORL 人脸库中每个人的 10 幅图像被分成两份,一份(我们选取 1, 3, 6, 7, 10)用来训练,一份(剩余的 2, 4, 5, 8, 9)用来识别。PCA 和 DPCA 直接用分辨率为  $112 \times 92$ 、灰度级为 256 的图片进行识别;而 GPCA 和 GDPCA 先利用双线内插法把图像缩小为  $64 \times 64$  的图片进行 Gabor 变换,然后把每一个 Gabor 特征图片利用双线内插法把图像缩小为  $16 \times 16$ , 并把它变换为一列,这样就得到  $256 \times 40$  的 Gabor 特征图片,在此基础上进行识别。这样,在 ORL 库上的识别率比较如图 6 所示,而对应的主元数筛选情况如图 7 所示。

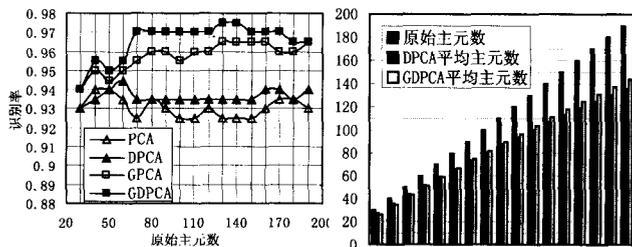


图 6 ORL 库上的识别率比较 图 7 ORL 库上的主元数比较图,其中原始主元数对应于图 6 中的原始主元数

其次,在 Georgia Tech 人脸库中每个人 15 幅图像的前 10 幅用来训练,后 5 幅用来识别。PCA 和 DPCA 直接用分辨率为  $80 \times 64$ 、灰度级为 256 的图片进行识别。GPCA 和 GDPCA 先利用双线内插法把图像缩小为  $64 \times 64$  的图片进行 Gabor 变换,然后把每一个 Gabor 特征图片利用双线内插法

©[http://www.anefian.com/face\\_reco.htm](http://www.anefian.com/face_reco.htm).

把图像缩小为  $16 \times 16$ , 并把它变换为一列, 这样就得到  $256 \times 40$  的 Gabor 特征图片, 在此基础上进行识别。这样在 Georgia Tech 库上的识别率比较如图 8 所示, 而对应的主元数筛选情况如图 9 所示。

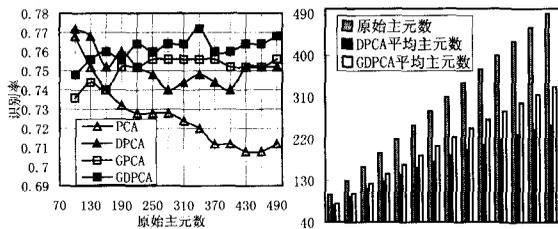


图 8 Georgia Tech 库上的识别率比较图

图 9 Georgia Tech 库上的主元数比较图, 其中原始主元数对应于图中的原始主元数

从实验结果可以看出, 利用本文提出的 DPCA 和 GDPCA 算法, 与相应文献[2]中用的 PCA 算法和文献[11]中用的 GPCA 算法相比, 在主元有一定数量减少的情况下, 识别率却有所提高。从图 6 和表 1 可以看出, 在 ORL 人脸库上 DPCA 和 GDPCA 算法最高识别率分别为 94.5% 和 97.5%, 平均识别率也均比 PCA 和 GPCA 算法高。从图 8 和表 1 可以看出, 在 Georgia Tech 人脸库上由于样本自身姿态的变化比较大, 所以最高识别率不高, 但我们的 DPCA 和 GDPCA 算法仍然比相应 PCA 和 GPCA 的算法在平均识别率还是在最高识别率上均有相应的提高。从图 7 和图 9 可以看出, 在两个人脸库上, 在识别率提高的情况下, 本文提出的算法所用的主元数均少于传统的算法。这说明本文提出的动态主成分空间构造算法, 在选择和优化特征空间, 去除干扰特征方面具有很好的效果。

表 1 平均识别率对照表

算法	R1 (%)	R2 (%)
PCA <sup>[2]</sup>	93.06	72.66
DPCA	93.65	75.17
GPCA <sup>[11]</sup>	95.76	75.11
GDPCA	96.53	76.14

注: R1 代表 ORL 库上的平均识别率, R2 代表 Georgia Tech 库上的平均识别率。

**结束语** 本文根据待测试人脸图像的个体差异性, 利用多元线性回归分析的数理统计理论, 对 PCA 算法初步选定的特征空间进一步筛选, 提出了一种自主式动态的特征选择方法。为了验证效果, 我们首先把该算法用到传统的 PCA 算法中, 提出了 DPCA 算法, 在 ORL(AT&T) 和 Georgia Tech 人

脸数据库的实验表明: 本文的动态主成分空间构造算法, 在主元数目减少的情况下, 而识别率却有进一步的提高; 其次, 为了验证算法的普适性, 把该算法应用到基于 GPCA 中, 提出了 GDPCA 算法, 在 ORL(AT&T) 和 Georgia Tech 人脸数据库的实验中同样取得了很好的效果。这些实验结果充分说明了本算法对特征选择和优化的有效性。

## 参考文献

- [1] Kirby M, Sirovich L. Application of the Karhunen-Loève procedure for the characterization of human faces. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 1990, 12(1): 103-108
- [2] Turk M, Pentland A. Eigenfaces for Recognition. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71-86
- [3] Belhumeur P N, Hespanda J, Kriegeman D. Eigenfaces vs. Fisherfaces: Recognition Using Class Special Linear Projection. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 1997, 19(7): 711-720
- [4] Moghaddam B, Jebara T, Pentland A. Bayesian face recognition. *Pattern Recognition*, 2000, 13(11): 1771-1782
- [5] Wang Xiaogang, Tang Xiaoou. A unified framework for subspace face recognition. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2004, 26(9): 1222-1228
- [6] Bartlett M S, Movellan J R, Sejnowski T J. Face Recognition by Independent Component Analysis. *IEEE Trans. on Neural Networks*, 2002, 13(6): 1450-1464
- [7] Gong Xun, Wang Guoyin. A Dynamic Component Deforming Model for Face Shape Reconstruction. // *Proceeding of the International Symposium on Visual Computing 2007*, L-NCS 4841. US, 2007: 488-497
- [8] Chen Songcan, Zhang Daoqiang, Zhou Zhihua. Face recognition with one training image per person. *Pattern Recognition Letters*, 2002, 23(14): 1711-1719
- [9] 王蕴红, 范伟, 谭铁牛. 融合局部与全局特征子空间人脸识别. *计算机学报*, 2005, 28(10): 1657-1663
- [10] Jones J P, Palmer L A. An evaluation of the two-dimensional Gabor filter model of simple receptive fields in cat striate cortex. *Journal of Neurophysiology*, 1987, 58(6): 1233-1258
- [11] Liu Chengjun, Wechsler H. Gabor feature based classification using the enhanced fisher linear discriminant model for face recognition. *IEEE Trans. on Image Processing*, 2002, 11(4): 467-476
- [12] Zhang Baochang, Shan Shiguang, Chen Xilin, et al. Histogram of Gabor Phase Patterns (HGPP): A Novel Object Representation Approach for Face Recognition. *IEEE Trans. on Image Processing*, 2007, 16(1): 57-68

(上接第 209 页)

- [3] 张春阳, 蔡庆生, 等. 抽样在数据挖掘中的应用研究. *计算机科学*, 2004, 31(2)
- [4] Olken F, Rotem D, Xu Ping. Random sampling from hash files. // *Proceedings of the 1990 ACM SIGMOD International Conference on Management of Data*. ACM Press, 1990: 375-386
- [5] Guha S, Rastogi R, Shim K. CURE: An Efficient Clustering Algorithm for Large Databases. // *Proc. ACM SIGMOD Conf.*. June 1998: 73-84
- [6] Knorr E, Ng R. A unified notion of outliers: Properties and computation. // *Proc. 1997 Int. Conf. Knowledge Discovery and Data Mining (KDD'97)*. Newport Beach, CA. Aug. 1997: 219-222

- [7] Motwani R, Raghavan P. *Randomized Algorithms*. Cambridge University Press, 1995
- [8] Poosala V, Ioannidis Y. Selectivity Estimation Without the Attribute Value Independence Assumption. // *Proc. Very Large Data Bases Conf.*. Aug. 1997: 486-495
- [9] Blohsfeld B, Korus D, Seeger B. A Comparison of Selectivity Estimators for Range Queries on Metric Attributes. // *Proc. ACM SIGMOD Int'l Conf. Management of Data*. 1999
- [10] Scott D. *Multivariate Density Estimation: Theory, Practice and Visualization*. Wiley & Sons, 1992
- [11] 李存华, 孙志挥. 核密度估算及其在聚类算法构造中的应用. *计算机研究与发展*, 2004, 41(10): 1713-1719