

文章编号:1004-9037(2012)01-0105-06

一种基于双子空间的人脸美感分析方法

段红帅 朱振峰 赵 耀

(北京交通大学信息科学研究所,北京,100044; 现代信息科学与网络技术北京市重点实验室,北京,100044)

摘要:子空间技术是一种有效的人脸美感本征描述方法。为了克服单一子空间在人脸图像美感描述方面的不足,提出了一种基于主成分分析(PCA)与广义矩阵低秩逼近(Generalized low rank approximation matrix, GLRAM)双子空间的自动人脸美感分析方法。通过组合PCA和GLRAM子空间获取人脸美感特性的全局及局部本征描述,并利用高斯场模型(Gaussian field model, GF)构造组合子空间的内在几何结构关系。实验选用了光照、背景、表情、年龄和种族等变化比较显著的数据库,结果表明,提出的基于双子空间算法优于基于单一子空间的人脸美感分析方法。

关键词:人脸美感分析;子空间分析;广义矩阵低秩逼近;主成分分析;高斯场模型

中图分类号:TP391

文献标识码:A

Dual Subspace Algorithm for Facial Attractiveness Analysis

Duan Hongshuai, Zhu Zhenfeng, Zhao Yao

(Institute of Information Science, Beijing Jiaotong University, Beijing, 100044, China;

Beijing Key Laboratory of Advanced Information Science and Network Technology, Beijing, 100044, China)

Abstract: Subspace technique is an efficient method for automatic facial attractiveness analysis. To enhance the intrinsic description for facial attractiveness, a dual subspace method on the subspaces of principal component analysis (PCA) and generalized low rank approximation matrix (GLRAM) is proposed. Thus, their individual characteristics in characterizing the global and local intrinsic description of facial attractiveness can be collaboratively boosted. Besides, the Gaussian field (GF) model is applied to reflect the geometric structure in sample space. The experiment is performed on a challenging database. It takes on significant variations in the aspects of illumination, background, facial expression, age, race, and so on. Experimental results show the advantages of the proposed dual subspace method for facial attractiveness analysis over the individual subspace one.

Key words: facial attractiveness analysis; subspace analysis; generalized low rank approximation matrix; principal component analysis; Gaussian field model

引 言

自古以来,人们对美的追求就从未停止过。哲学家、心理学家、美学家等也一直在试图寻找美的本质。美国整容手术学会发表报告称,美国整容市场10年来增长4.57倍,2007年行业产值达约130亿美元。进化心理学家从女性美与繁殖的关系中引

入“繁殖价值”概念,从进化的角度解释了男性对女性的审美观。面对互联网上的海量信息,从美感角度进行个性化的信息检索也越来越成为各个社交网站的主流方法。鉴于人脸美感分析技术在整容手术、化妆、社交网站、娱乐软件、科学研究等领域带来的巨大的经济效益和社会效益,以及在相关领域潜在的应用前景,人们开始思考美的本质,组成美的元素是什么,能否对其进行量化。

基金项目:国家自然科学基金(61025013)资助项目;北京交通大学基本科研业务费重点专项资金(2009JBZ006)资助项目;北京市自然科学基金(4112043)资助项目。

收稿日期:2011-01-14; **修订日期:**2011-06-15

伏尔泰曾说,“美是相对的”,即对美的判断会根据观察者的性别、年龄、种族、教育程度、文化、环境等差异而有所不同。然而,Langlois 等人^[1]研究发现,给 2~3 月和 6~8 月的婴儿呈现按照成人标准打分的女性图片,婴儿注视美女图片的时间明显长于非美女;同时,进化心理学的一项研究发现,亚洲人、西班牙人、黑人和白人在对女性照片打分时,有着高达 0.93 的正相关。即全世界的人们都在使用一套类似的美感判断准则。

近年来,随着计算机技术的飞速发展,人们开始从数据挖掘的角度,利用机器学习和模式识别的方法来分析研究人脸美感。目前人脸美感分析技术主要包括:(1)基于几何特征的方法;(2)基于子空间的方法。

基于几何特征的研究方法符合人类大脑的认知原理、易于理解、存储量小、光照变化不敏感等。Eisenthal 等人^[2]从一组专业摄制的 92 幅人脸图片中,选取了 37 个反映人脸美感的几何距离,其回归模型预测值与基准的相关系数高达 0.6。Chang 等人^[3]人工选取了 46 个描述人脸美感的几何特征,通过计算与“有吸引力的平均面孔”和“没有吸引力的平均面孔”两个原型的距离学习出 15 个能有效描述女性人脸美感的特征。

虽然基于几何特征的方法得到了一些较好的结果,但也存在不足的地方:首先,对强烈的表情变化和姿势变化的鲁棒性较差;其次,一般的几何特征只描述了人脸的基本形状和结构关系,忽略了局部细微特征,如纹理特征,造成部分信息丢失;此外,还需人工标定几何关系,工作量大,实验过程需人工介入,不能实现全自动。而基于子空间的方法,从人脸表象信息出发,不需要人为地对图像标定,直接输入图像数据,即可实现全自动的人脸美感分析。

主成分分析(Principal component analysis, PCA),是一个非常经典的子空间分析方法,Kirby^[4]和 Turk^[5]等人首次把主成分分析的子空间思想引入到人脸识别中,并获得了较大成功。Eisenthal 等人^[2]首次引入 PCA 子空间用于人脸美感分值回归预测,预测值与基准的相关系数达 0.45。Gray 等人^[6]采用分层反馈模型方法,并利用语义梯度下降法实现美感预测。Davis 等人^[7]采用局部欧式子空间的流形核回归方法,由给定分值回归相应等级人脸,得到不同等级下脸型的美丑变化趋势。

PCA 子空间方法将人脸图像矩阵预先转换成

行或列向量,然后以向量矩阵作为输入得到子空间特征描述,从宏观(全局)角度描述了人脸图像的本征特性。但转换后的向量,由于忽略了原始图像矩阵相邻像素之间局部位置信息,因而失去了原始的二维结构关系。Yie 等人^[8]提出的广义矩阵低秩逼近(Generalized low rank approximation matrix, GLRAM)直接将图像矩阵作为输入,从微观(局部)角度描述了人脸图像的本征特性。为了克服单一子空间在人脸图像美感描述方面的不足,提高美感本征描述的性能,本文提出了一种基于 PCA 与 GLRAM 双子空间的自动人脸美感分析方法,以此强化人脸美感图像全局信息和局部信息的本征特性描述。

1 子空间分析

人脸图像的维数通常较高,同类的人脸图像在这样高维空间中的分布很不紧凑,因而不利于分类,且计算复杂度高。子空间分析把原始的高维空间中的人脸图像数据投影压缩到一个低维子空间,使数据在子空间中的分布更加紧凑,更有利于分类,同时也大大降低了计算的复杂度。目前得到成功应用的子空间分析方法有很多,本文考虑通过组合 PCA 与 GLRAM 子空间的特征描述来增强人脸图像美感本征描述的判别能力。下面分别介绍 PCA 和 GLRAM 技术。

1.1 主成分分析

主成分分析的基本思想是找到一个投影映射 P ,使得样本从高维空间 R^d 映射到低维 R^m 子空间。设 $X = [x_1, x_2, \dots, x_n]$ 是 $R^{d \times n}$ 空间上的训练样本的向量集合, n 为样本个数。通过训练样本矩阵的协方差矩阵的特征值分解可以获得投影映射

$$\text{cov}(X)v_i = \lambda_i v_i \quad i = 1, \dots, d \quad (1)$$

其中, $\text{cov}(X)$ 为二阶统计协方差矩阵, λ_i 为协方差矩阵 $\text{cov}(X)$ 的特征值, v_i 为对应的特征向量。选取前 m 个最大特征值对应的特征向量组成投影映射 $P = [v_1, v_2, \dots, v_m]$, $m \leq d$, 由此得到 PCA 子空间特征描述 X^{PCA} 为

$$X^{\text{PCA}} = X^T \times P \quad (2)$$

1.2 广义矩阵低秩逼近

正如前所述, GLRAM 方法直接将图像矩阵作为输入得到的子空间特征描述,弥补了 PCA 子空间特征描述由于以行或列向量作为输入失去的

相邻像素之间的局部位置信息的本征特性。令 $X_i \in \mathbf{R}^{r \times c}$, $i=1, \dots, n$ 为样本图像的矩阵集合, n 为样本个数。GLRAM 方法就是要计算左右投影矩阵 $L_{r \times p}$ 和 $R_{c \times q}$, 其中 $p < c, q < r$, 使得 $LD_i R^T$ ($i=1, \dots, n$) 是 X_i 的一个逼近, 其中二维子空间 D_i 大小为 $p \times q$ (本文取 $p=q$)。具体来说, GLRAM 可归结为如下最小化问题^[8]

$$\begin{aligned} \min \quad & \sum_{i=1}^n \|X_i - LD_i R^T\|_F^2 \\ \text{s. t.} \quad & L^T L = I^p, L \in \mathbf{R}^{r \times p}, \\ & R^T R = I^q, R \in \mathbf{R}^{c \times q}, \\ & D_i \in \mathbf{R}^{p \times q}, i=1, \dots, n \end{aligned} \quad (3)$$

式(3)最优解可通过以下迭代得到, 即给定

$D_R = \sum_{j=1}^n X_j^T L_{i-1} L_{i-1}^T X_j$ 通过计算矩阵 D_R 的前 p 个最大特征值对应的特征向量组成 R ; 再由所得 R 通

过计算矩阵 $D_L = \sum_{j=1}^n X_j R_i R_i^T X_j^T$ 的前 p 个最大特征值对应的特征向量更新 L ; 重复上述过程直到满足

收敛条件 $\frac{|RE(i) - RE(i-1)|}{RE(i-1)} < \eta$, 从而得到最优解 L^* 和 R^* , 其中, $RE(i)$ 和 $RE(i-1)$ 分别是两次迭代的人脸图像重建误差, 并有: $RE(i) =$

$\sqrt{\frac{1}{n} \sum_{i=1}^n \|X_i - LD_i R^T\|_F^2}$, η 是一个阈值常量 (本文取 10^{-4})。进一步, 对于第 i 个样本可以得到其二维 GLRAM 子空间描述 $D_i = (L^*)^T X_i R^*$, $i=1, \dots, n$ 。为便于阐述, 令 $X^{\text{GLRAM}} = [X_1^{\text{GLRAM}}, X_2^{\text{GLRAM}}, \dots, X_n^{\text{GLRAM}}]^T \in \mathbf{R}^{n \times p^2}$ 表示 GLRAM 子空间特征描述, 其中 $X_i^{\text{GLRAM}} = \text{Vect}(D_i) \in \mathbf{R}^{p^2}$, Vect 表示把二维矩阵 D_i 转换为列向量的操作算子。

2 特征选择

PCA 子空间基于矩阵的二阶统计特性, 从全局角度提取出不具相关性的主要成分; GLRAM 子空间直接把图像矩阵作为输入提取特征, 保留了图像更多的局部本征特性。为了避免单一子空间在人脸图像美感描述方面的不足, 充分利用图像的全局和局部信息, 本文提出将 PCA 和 GLRAM 子空间组合的方法。首先将人脸图像分别通过 PCA 和 GLRAM 子空间技术得到 X^{PCA} 和 X^{GLRAM} , 然后得到组合子空间的特征描述 $X^{\text{PCA+GLRAM}}$ 。但是组合子空间特征维数依然较高, 且有的特征维并不具有较好的美感描述特性, 为了去除冗余, 降低计算复杂度, 通过引入标签信息^[2]与组合子空间的相关性进行

特征选择, 提高本征判别性能。

相关系数是一种用以衡量两个变量之间关系的度量, 其中皮尔森相关系数是最常用的相关性度量准则。将来自于 PCA 子空间的 $n \times m$ 大小特征矩阵 X^{PCA} 和来自于 GLRAM 子空间的 $n \times p^2$ 大小特征矩阵 X^{GLRAM} 直接组合, 得到 $n \times (m + p^2)$ 组合子空间特征描述 $X_{n \times (m+p^2)}^{\text{PCA+GLRAM}} = [X_{n \times m}^{\text{PCA}}, X_{n \times p^2}^{\text{GLRAM}}]$, 令 $S = [S_1, S_2, \dots, S_n]^T$ 为 n 个样本的基准分值, 即由多人对人脸美感的实际打分平均值, $X_{i \cdot}^{\text{PCA+GLRAM}} = [X_{1i}^{\text{PCA+GLRAM}}, X_{2i}^{\text{PCA+GLRAM}}, \dots, X_{ni}^{\text{PCA+GLRAM}}]^T$, $i=1, \dots, m + p^2$ 表示在组合子空间第 i 维上 n 个样本点的描述, 由此得皮尔森相关系数:

$$\rho_i(X_{i \cdot}^{\text{PCA+GLRAM}}, S) = \frac{\sum_{j=1}^n (X_{ji}^{\text{PCA+GLRAM}} - \mu_{X_{i \cdot}^{\text{PCA+GLRAM}}})(S_j - \mu_S)}{(n-1)\sigma_{X_{i \cdot}^{\text{PCA+GLRAM}}}\sigma_S} \quad (4)$$

其中, $\mu_{X_{i \cdot}^{\text{PCA+GLRAM}}}$, $\sigma_{X_{i \cdot}^{\text{PCA+GLRAM}}}$, μ_S , σ_S 分别为训练样本第 i 维描述 $X_{i \cdot}^{\text{PCA+GLRAM}}$ 的均值、标准差及相应基准分值的均值、标准差。 ρ 的取值范围为 $(-1, +1)$, 当 ρ 小于 0 时, 称为负相关; 大于 0 时, 称为正相关; 等于 0 时, 称为零相关。基于子空间与标签相关性的子空间特征选择过程如表 1 所示。

表 1 基于皮尔森相关的组合子空间特征选择

- (1) 图像预处理;
- (2) 由式(2)得 $n \times m$ 大小经 PCA 子空间投影后的子空间描述 $X_{n \times m}^{\text{PCA}}$;
- (3) 由式(3)得 $n \times p^2$ 大小经 GLRAM 子空间后的二维逼近子空间描述 $X_{n \times p^2}^{\text{GLRAM}}$;
- (4) 由(2,3)得 $n \times (m + p^2)$ 大小组合子空间特征描述 $X_{n \times (m+p^2)}^{\text{PCA+GLRAM}} = [X_{n \times m}^{\text{PCA}}, X_{n \times p^2}^{\text{GLRAM}}]$, 由式(4)计算与基准向量的皮尔森相关系数 $\rho_i(X_{i \cdot}^{\text{PCA+GLRAM}}, S)$;
- (5) 按 ρ_i 大小降序排列, 取最大的前 \tilde{d} 个 ρ_i ① 值对应的组合子空间的特征描述作为新的人脸美感本征描述 $\tilde{X}_{n \times \tilde{d}}^{\text{PCA+GLRAM}}$, $\tilde{d} \ll m + p^2$ 。

3 高斯场模型

高斯场模型^[9](Gaussian field model, GF)是一种基于图的标签传递算法。该方法利用样本空间的几何结构关系建立关系图模型 $G(V, E)$, $V = \{v_i\}_{i=1, \dots, n}$ 表示由样本点构成的图结点集合, $E = \{e_{ij}\}_{i, j=1, \dots, n}$ 表示由结点 v_i, v_j 所构成的边集合, 相应的边强度 w_{ij} (也称为边权值) 反映了两个结点间的近似性程度。已知数据集 $X = [(x_1, y_1), \dots, (x_l, y_l), (x_{l+1}, \dots, x_n)]$, 前 l 个表示具有类标签样本, 并有

① 本文还尝试了比例选择法, 具体分析详见第三部分。

$y_i \in \{1, 2, \dots, c\}, i = 1, \dots, l, c$ 表示样本类别数。Zhu 等人^[9]提出的 GF 模型是通过图模型约束实现由已标记结点的类标签预测未标记结点的类标签信息,目标函数可写为

$$\min_{F_i \in \mathcal{R}^c} \frac{1}{2} \sum_{i,j=1}^n w_{ij} \|F_i - F_j\|_F^2$$

$$\text{s. t. } F_i = Y_i, \quad i = 1, \dots, l \quad (5)$$

其中, $Y_i \in \mathcal{R}^c$, 且 $Y_{i,j} = \begin{cases} 1 & y_i = j \\ 0 & \text{其他} \end{cases}$ 表示与类标签有关的初始状态量(也可看作是一种类信息编码方式), $F_i \in \mathcal{R}^c, i = 1, \dots, l$ 为与类标签有关的某种最终收敛状态量(对于已标记样本有 $F_i = Y_i, i = 1, \dots, l$), 而

$$w_{ij} = \begin{cases} \exp\left(-\frac{d^2(x_i, x_j)}{2\sigma^2}\right) & x_i \in N_k(x_j) \text{ 或者 } x_j \in N_k(x_i) \\ 0 & \text{其他} \end{cases} \quad (6)$$

为反映图结点近似性程度的边权值, $d(x_i, x_j)$ 为某种距离度量, σ 为高斯核径(本文由任意两个相邻图像点之间的平均距离得到, 即 $\sigma = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n d(x_i, x_j)$), $x_i \in N_k(x_j)$ 表示 x_i 属于 x_j 的 k 个最近邻。经过求导, 式(5)的最优解可由式(7)给出

$$\begin{bmatrix} M_{LL} & 0 \\ 0 & M_{UU} \end{bmatrix} \begin{bmatrix} F_L \\ F_U \end{bmatrix} = \begin{bmatrix} W_{LL} & W_{LU} \\ W_{UL} & W_{UU} \end{bmatrix} \begin{bmatrix} F_L \\ F_U \end{bmatrix}$$

$$F_L = Y_L \quad (7)$$

其中, 对角阵 $M = \text{diag}(\sum_j W_{ij})$, $L = \{1, \dots, l\}$ 与 $U = \{l+1, \dots, n\}$ 分别表示标记与非标记样本索引集合。经简单几何变换, 式(7)可简化为

$$F_U = (M_{UU} - W_{UU})^{-1} W_{UL} Y_L \quad (8)$$

为提高最终分类性能的稳定性, 可对 F_U 进一步归一化^[9]: $(\bar{F}_U)_{i,j} = (F_U)_{i,j} \cdot \frac{\sum_i (Y_L)_{ij}}{\sum_i (F_U)_{ij}}$, 由此对于未标记样本 $y_i, i \in U$, 可得其类标签预测值

$$y_U = \text{argmax}_{j \leq c} (\bar{F}_U)_{ij} \quad (9)$$

4 实验结果与分析

实验中用到的数据库来自于 www.hotornot.com 网站^[10], Hotornot 网站是一个允许人们对自愿上传的图片进行打分的社交网站。本文选用了 1 230 张女性图片组成的子数据库, 且每张图片均附有超过 50 人打分的等级平均值, 即基准分值, 等级分为 1 到 10 级。实验只考虑两类情况, “没有吸引

力的”和“有吸引力的”, 其中基准值小于 8 的, 共 601 张图片划分为第一类, 即“没有吸引力的”, 剩余基准值大于 8 的, 共 629 张划分为第二类, 即“有吸引力的”。

由于上述图片来自于网站上的个人上传, 图片光照、亮度、颜色等变化比较显著, 对人脸美感分析具有很大挑战性。部分不同种族和表情, 不同年龄和光照的图片分别如图 1 和图 2 所示, 其中有由专业的摄影师拍摄的高像素图片, 也有由分辨率不高的手持设备, 如手机等拍摄得到。此外, 实验中图片大小调整为 86×86 。

为了尽量减小光照对美感分析的影响, 先对图像进行灰度化及归一化预处理。图 3(a, b) 分别是处理前原始图像和灰度图像, 图 3(c) 是经归一化处理后的去光照图像。本文采用留一交叉验证法, 即每次只抽取一张图片作为测试样本, 剩下的均为训练样本。



图 1 不同种族和表情

图 2 不同年龄和光照



图 3 处理前后图像对比

4.1 不同 GLRAM 维数性能分析(实验 1)

为了观察不同维数对 GLRAM 子空间的影响, 采用单一 GLRAM 子空间技术提取不同特征维数, 并分别用 GF 和 K-NN(本文取 $K=25$) 进行分类。由图 4 实验结果可知, 当 $p=30$ 时 GF 性能最优, 识别率最高可达 59.70%, K-NN 最高识别率达 57.89%。以下涉及 GLRAM 子空间实验均先降到 $p=30$ 。

4.2 组合子空间性能分析(实验 2)

为了验证本文所提算法的优越性, 图 5 是分别基于单一子空间和组合子空间的结果对比图。由图可知, 单一的 GLRAM 子空间人脸美感分析性能要优

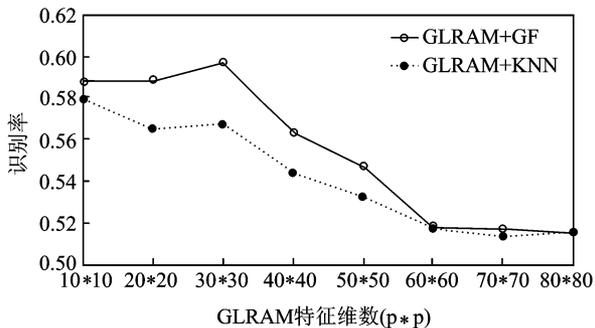


图 4 GLRAM 提取不同特征维数分类结果

于 PCA 子空间;本文所提出的基于 PCA 和 GLRAM 的双子空间方法结果要优于采用 PCA 或 GLRAM 的单一子空间方法;此外,由于 GF 考虑了更多内在的几何结构关系,分类性能要优于 K-NN。当组合后维数选取 $\tilde{d}=50$ 时,识别率最高可达 65.77%。以向量作为原始输入的 PCA 子空间特征描述所包含的美感判别信息较多地保留了图像的全局信息,丢失了二维结构关系,以矩阵作为原始输入的 GLRAM 子空间特征描述则较多地保留了图像的局部本征特征,而基于 PCA 和 GLRAM 的双子空间技术进一步强化了对人脸美感特性的本征描述,获得较好的识别性能。

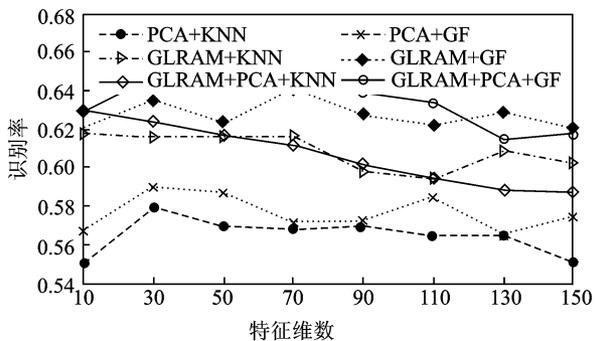


图 5 提取不同特征维数分类结果

4.3 组合子空间相似性近邻个数 k 值选择 (实验 3)

实验 1 和实验 2 在计算 GF 的相似性邻接矩阵

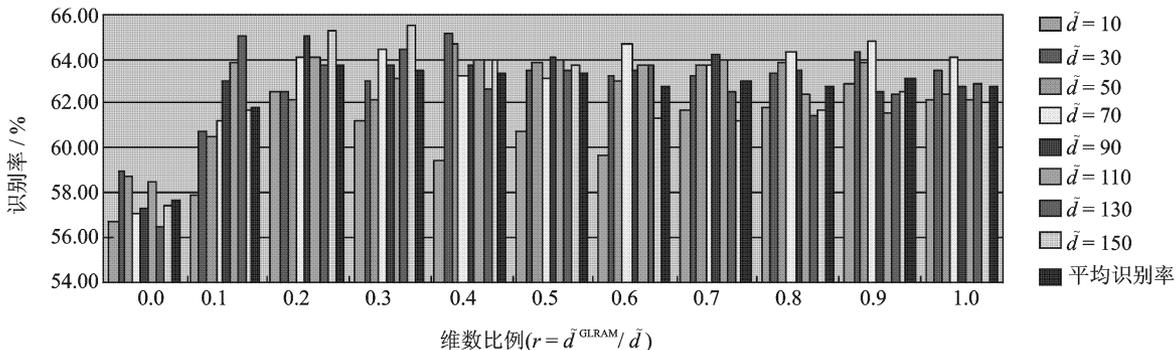


图 7 GLRAM 特征维数不同比例下分类结果

W 时,相似性邻接个数 k 值是个重要的参数,图 6 给出了不同 k 值的最终识别率变化曲线,可以看出相似性邻接个数 $k=45, \tilde{d}=50$ 时,性能最优。

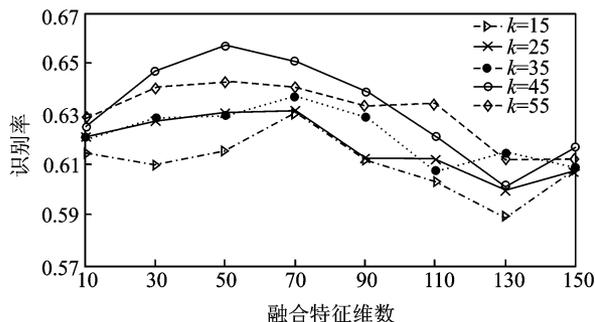


图 6 组合子空间不同 k 值分类结果

4.4 基于比例选取法的组合子空间特征选择 (实验 4)

综上实验(1,2,3),基于皮尔森相关的 PCA 和 GLRAM 组合子空间特征选择中,当邻接个数 $k=45$,选择后组合特征维数 $\tilde{d}=50$ 时,人脸美感识别率最高达 65.77%,其中 $\tilde{d}^{GLRAM}=43$ 个特征来自 GLRAM, $\tilde{d}^{PCA}=7$ 个特征来自 PCA,即维数比例 $r=\tilde{d}^{GLRAM}/\tilde{d}=0.86$,其中 $\tilde{d}=\tilde{d}^{PCA}+\tilde{d}^{GLRAM}$ 。为了观察 $\tilde{X}^{PCA+GLRAM}$ 组合空间中 PCA 与 GLRAM 特征维数组合变化对最终识别率的影响,按 ρ_i 值大小分别选取 \tilde{d}^{PCA} 个 PCA 特征描述和 \tilde{d}^{GLRAM} 个 GLRAM 特征描述,图 7 为 \tilde{d}^{GLRAM} 与 \tilde{d} 不同比例下的识别率。对于基于比例的组合子空间特征选取方法,当 $\tilde{d}=150$,即 $r=0.3$ 时,识别率最高达 65.53%。可以看出,以上直接选取 \tilde{d} 个特征描述和按比例选取 \tilde{d} 个特征描述方法,识别性能最优时,维数比例分别为 $r=0.86$ 和 $r=0.3$, r 值差别较大。可推断出,基于独立特征选择的方法在描述人脸美感方面存在一定的不足,其特征组合并不随维数的增加而产生更有效的本征描述特性,在以后工作中可考虑增量的递归选择方式,即在组合子空间中进行最优组合特征选择,提高判别性能。

5 结束语

在研究 PCA 和 GLRAM 子空间的基础上,为了避免单一子空间对人脸图像美感描述不充分,本文提出基于 PCA 与 GLRAM 双子空间的人脸美感分析方法。组合子空间特征描述结合了 PCA 特征描述的全局信息和 GLRAM 特征描述的局部信息,强化了对人脸美感分析的本征特性描述。此外,为了进一步提高人脸美感本征描述的判别性能,引入了基于标签信息相关性的组合子空间特征选择。实验结果表明,基于 PCA 和 GLRAM 双子空间的算法性能优于单独使用 PCA 和 GLRAM 子空间。

参考文献:

- [1] Langlois J H, Roggman L A. Infant preferences for attractive faces; rudiments of a stereotype[J]. *Developmental Psychology*, 1987,23(3):363-369.
- [2] Eisenthal Y, Dror G, Ruppin E. Facial attractiveness; beauty and the machine[J]. *Neural Computation*, 2006,18(1):119-142.
- [3] Chang Fu, Chou Chienhsing. A bi-prototype theory of facial attractiveness [J]. *Neural Computation*, 2009,21(3):890-910.
- [4] Kirby M, Sirovich L. Application of the KL procedure for the characterization of human faces [J]. *IEEE Trans on PAMI*, 1990,12(1):103-108.
- [5] Turk M, Pentland A. Eigenfaces for recognition[J]. *Cognitive Neuroscience*, 1991,3(1):71-86.
- [6] Gray D, Yu Kai, Xu Wei, et al. Predicting facial beauty without landmarks [C]//11th European Conference on Computer Vision. Heraklion: Springer, 2010:434-447.
- [7] Davis B C, Lazebnik S. Analysis of human attractiveness using manifold kernel regression [C]//15th International Conference on Image Processing. San Diego: [s. n.], 2008:109-112.
- [8] Yie Jieping. Generalized low rank approximations of matrices[J]. *Machine Learning*, 2005,61:167-191.
- [9] Zhu Xiaojin, Ghahramani Z, Lafferty J. Semi-supervised learning using Gaussian Fields and harmonic functions[C]//20th International Conference on Machine Learning. Washington DC: [s. n.], 2003.
- [10] White R, Eden A. Automatic prediction of human attractiveness [R]. UC Berkely, USA;2004.

作者简介:段红帅(1987-),女,硕士研究生,研究方向:图像处理、机器学习,E-mail:09120478@bjtu.edu.cn;朱振峰(1974-),男,副教授,研究方向:图像与视频理解、计算机视觉、机器学习等;赵耀(1967-),男,教授,博士生导师,研究方向:图像与视频编码、数字水印与信息隐藏、基于内容的信息检索。