

# 基于关联子区域映射的多姿态人脸识别

陈华杰 韦巍

(浙江大学电气工程学院, 杭州 310027)

**摘要** 针对人脸识别中的姿态变化问题,提出了子区域关联映射的方法识别多姿态的人脸图像。人脸被分割为若干子区域,姿态变化对图像的影响被分解为关联子区域的形状映射与纹理映射。提出了2维耦合成分分析的方法构造关联子区域的映射关系。2维耦合成分分析采用2维矩阵方式直接表达人脸图像,在此基础上获取不同观测空间上的低维耦合空间,根据局部几何关系不变性的原理学习耦合空间上投影特征矩阵之间的非线性映射。在应用贝叶斯框架评估子区域可分性的基础上,综合全体子区域的信息给出最终的判别结果。比较实验结果表明,关联子区域映射方法能有效补偿姿态变化带来的影响;对应的多姿态识别方法判别率高,对姿态变化敏感度低。

**关键词** 多姿态人脸识别 关联子区域映射 2维耦合成分分析 姿态补偿

**中图分类号**: TP181 **文献标识码**: A **文章编号**: 1006-8961(2007)07-1254-07

## Multi-pose Face Recognition Based on Correlative Sub-region Mapping

CHEN Hua-jie, WEI Wei

(College of Electrical Engineering, Zhejiang University, Hangzhou 310027)

**Abstract** As for the pose variation in face recognition, a correlative sub-region mapping method was proposed to recognize the multi-pose face images. The face was divided into several sub-regions, and the influence to image caused by the pose variation was decomposed into shape mapping and texture mapping between correlative sub-regions. A new technique coined two-dimensional coupled component analysis(2D CCA) was developed to construct these mapping functions. Based on 2D image matrices rather than 1D vectors, 2D CCA obtained the low-dimensional coupled spaces embedded in two observation spaces, and learned the nonlinear mapping relation between the projected feature matrices according to the principle of local geometry preserving. The discriminative power of each sub-region was estimated using Bayesian framework, and thereafter the final recognition result was obtained by combining the measures in all sub-regions. The results of comparing experiment show that, correlative sub-region mapping method compensates the pose variation effectively, and the corresponding multi-pose recognition method is of high recognition rate and low sensitivity to pose variation.

**Keywords** multi-pose face recognition, correlative sub-region mapping, two-dimensional coupled component analysis, pose compensation

## 1 引言

人脸识别所需要处理的各种变化因素,其中重要的一个就是姿态。头部在3维垂直坐标系中绕3个轴的旋转造成面部变化,其中在垂直于图像平面的两个方向上的深度旋转使得面部信息的部分缺失。在影响人脸图像的所有变化因素中,姿态或是

最难以建模的一个,并对识别率起到最显著的影响。

针对多姿态人脸识别问题,已经提出了很多算法。第1种类型的算法是学习并记忆多种姿态下的特征,但是该类算法只适用于多姿态人脸数据可以容易获取的场合下;第2种类型的算法是估计头部的3维几何模型,提取姿态无关特征来识别人脸<sup>[1,2]</sup>,复杂的模型有利于提高识别精度,但代价是增大模型匹配的难度,即使是采用简单的椭球模型,

收稿日期:2006-03-03;改回日期:2006-05-26

第一作者简介:陈华杰(1978~)男。2001年于浙江大学获工业自动化专业学士学位,现为浙江大学控制理论与控制工程博士研究生。主要从事模式识别、计算机视觉等研究。E-mail: binwhite@163.com

也要采用不断反馈调整的方法来选择合适的参数<sup>[1]</sup>;第3种类型的算法是将同一姿态下的所有人脸图像看作是 高维空间上的一个数据集,通过建立正面与非正面人脸图像所对应的数据集之间的映射函数,来学习得到它们之间的关系<sup>[3,4]</sup>,对任意姿态的测试样本,或是将其转换到正面视角<sup>[3]</sup>,或是将训练样本转换到与测试样本相同的视角<sup>[4]</sup>,问题在于,用简单的函数,例如线性转换函数<sup>[3,4]</sup>,来近似拟合不同姿态图像间的差异,不能保证保留足够多的识别所需的信息。

本文提出的关联子区域映射的多姿态人脸识别方法,属于第3种类型。从形状与纹理这两个方面来分析姿态变化引起的人脸图像的变化。考虑到姿态变化时,人脸的不同局部区域变化的方式不同,故将正面人脸图像划分为若干子区域,搜索在非正面图像上对应的耦合度最高的关联区域;采用2维耦合成分分析算法,对关联区域上的纹理数据间的映射关系建模;在此基础上,采用概率模型估计子区域上同类与非同类样本本征距离的分布,并综合各个子区域的信息给出判定结果。

## 2 关联子区域

由于面部是一个复杂的3维形体,面部各个部分随姿态变化的方式是不一致的。用一个简单的模型,例如椭球,整体上补偿姿态变化存在着比较大的误差。可以将人脸区域分成若干个子区域,不同子区域采用不同的补偿方式。

假设人脸的某一子区域,在某一姿态下的观测数据为  $B((x, y), I)$ , 其中  $(x, y)$  表示子区域的位置,  $I$  表示了图像纹理数据。两种不同姿态下的子区域图像  $B_1((x_1, y_1), I_1), B_2((x_2, y_2), I_2)$ , 若对应于相同的人脸子区域,则有理由认为它们之间存在着某种关联。为了简化问题,将此种关联分解为形状关联与纹理关联,分别用形状映射函数与纹理映射函数来表述:

$$F_p: (x_1, y_1) \rightarrow (x_2, y_2)$$

$$F_t: I_1 \rightarrow I_2$$

其中,  $F_p$  是关联区域位置的映射函数,  $F_t$  是关联区域纹理数据的映射函数。类似地,姿态2向姿态1的映射则为  $F_p^{-1}$  与  $F_t^{-1}$ 。

从严格意义上来说,由于每个人头部的3维形体间存在的差异,形状映射函数是特定于个人的。

但是在无法获取头部形体的确切信息下,忽略此种个体上的差异,也是一种合理的选择。

## 3 2维耦合成分分析

假设有一组对象空间上的观测对象,记为  $a_1, a_2, \dots, a_n$ ,  $n$  是对象的个数。在某一观测条件下,在观测空间  $X$  上对应的观测数据为  $x_1, x_2, \dots, x_n$ , 在另外一个观测空间  $Y$  上对应的采样数据为  $y_1, y_2, \dots, y_n$ 。因为这两个观测空间都与同一个对象空间相关联,因此可以把每个观测空间分解为两个子空间,其中一个子空间只包含此观测空间特有成分,另外一个子空间则包含了与其他观测空间相耦合的成分。现有的一些算法用于把高维的观测数据投影到低维耦合空间,在降维的同时保留并提取此种耦合关系<sup>[5,6]</sup>。但是这些算法都是先把2维的图像转换为1维的向量形式再加以处理,得到的图像向量往往位于高维空间。而一般的人脸识别任务中,样本的个数往往是很有限制的,因此易引起小样本问题。同时,将2维图像转化为1维向量形式时,邻近像素之间的空间关联信息有一定程度的丢失。

2维耦合成分分析直接采用2维图像矩阵的形式来表征人脸图像,通过统计学习获取两个观测空间的低维耦合空间。相比于1维向量表达形式,邻近像素之间的空间关联信息能够得到更完整的保留;此外,协方差矩阵的维度大大降低,方便了协方差矩阵与特征值的计算<sup>[7]</sup>。但带来的一个问题是:采用2维矩阵表达形式投影所得特征矩阵的维度,比同等条件下1维向量表达形式对应的特征矩阵的维度要高得多<sup>[7]</sup>。常规的线性变换矩阵方法处理少量高维数据时不稳定,且不能反映数据之间的非线性关系,为此根据局部几何关系不变性原则,提出了构建耦合空间上特征矩阵之间非线性映射的方法。

### 3.1 统计学习低维耦合空间

采用2维矩阵的方式直接表达观测得到的图像数据。有两组观测数据  $\{x_i | i = 1, 2, \dots, n\}$  与  $\{y_i | i = 1, 2, \dots, n\}$ , 其中  $x_i, y_i \in \mathbf{R}^{r \times c}$ 。两个观测图像间相互耦合的成分,构成了高维观测空间上的嵌入低维耦合空间。将观测图像向各自的低维耦合空间做投影,则有:

$$u = xP_x$$

$$v = yP_y$$

其中,  $P_x$  与  $P_y$  为  $c \times k$  矩阵。如此, 得到了  $r \times k$  的投影矩阵  $u$  与  $v$ , 称之为图像  $x$  与  $y$  向耦合空间的投影特征矩阵。

采用统计相关来表征这两组投影特征矩阵之间的耦合关系。两个投影特征矩阵之间的协方差为

$$\text{Cov}(u, v) = \text{tr}(u \times v^T)$$

注意到在非线性相关情况下, 是协方差的幅值而非符号表征了相关的强度, 故采用了其平方来表征相互耦合强度:

$$CI(u, v) = [\text{tr}(u \times v^T)]^2$$

则对应的两组观测数据在给定耦合空间上的耦合强度为

$$CI(P_x, P_y) = \sum_{i=1}^n CI(u_i, v_i)$$

2 维耦合成分分析寻找最优的低维耦合空间, 使得耦合强度最大:

$$(P_x, P_y) = \arg \max_{P_x, P_y} CI(P_x, P_y)$$

采用轮流优化的方法求解该目标函数: 固定变换矩阵  $P_x$ , 求得另一变换矩阵  $P_y$  对应的最优解; 再固定此最优解, 求得对应的最优的  $P_x$ 。当  $P_x$  或  $P_y$  固定时, 目标函数为凸函数, 因此该迭代优化的方法可以保证收敛性<sup>[5]</sup>。根据此原理, 下面给出了 2 维图像矩阵表示方式所对应的优化方法, 其中耦合空间维数  $k$  的选择需考虑以下因素:  $k$  增大, 则图像的重构误差减小; 但对应的投影特征矩阵的维度增加, 后续的特征矩阵映射学习的计算量增大且泛化能力下降。

2 维图像耦合空间学习算法如下:

给定两组观测数据  $\{x_i | i = 1, 2, \dots, n\}$  与  $\{y_i | i = 1, 2, \dots, n\}$ ,  $x_i, y_i \in \mathbf{R}^{c \times c}$ 。

(1) 初始化  $P_x^{(0)}$  与  $P_y^{(0)}$  为单位矩阵,  $P_x^{(0)}, P_y^{(0)} \in \mathbf{R}^{c \times c}$

(2) 重复下列步骤, 在第  $t$  次迭代过程中:

$$S_x^{(t)} = \sum_i [(x_i - Ex)^T (y_i - Ey) P_y^{(t-1)} \dots$$

$$(P_y^{(t-1)})^T (y_i - Ey)^T (x_i - Ex)]$$

$$P_x^{(t)} = \arg \max_{P_x} P_x^T S_x^{(t)} P_x$$

$$S_y^{(t)} = \sum_i [(y_i - Ey)^T (x_i - Ex) P_x^{(t)} \dots$$

$$(P_x^{(t)})^T (x_i - Ex)^T (y_i - Ey)]$$

$$P_y^{(t)} = \arg \max_{P_y} P_y^T S_y^{(t)} P_y$$

(3) 计算  $CI^{(t)}$ , 当  $CI^{(t)} - CI^{(t-1)} < \varepsilon$  时, 退出。

(4) 分别取  $P_x^{(t)}, P_y^{(t)}$  的前  $k$  个列向量构成  $P_x, P_y$ 。

### 3.2 局部几何关系不变原则下的特征矩阵映射

常规的线性变换矩阵方法求取映射函数时, 需要大量的数据才能保证估计得到的变换矩阵没有大的偏差, 并且简单的线性处理方式也无法表达特征矩阵之间存在的非线性关系。受 LLE<sup>[8]</sup> 启发, 采用局部几何关系不变的原则来学习两个特征矩阵数据集间的非线性映射关系。

LLE 是一种流形学习算法, 常用于非线性降维与图像分析。LLE 基于一个简单的原则: 在流形的局部区域, 相互邻近的数据点之间的几何关系, 在映射前后近似保持不变。针对关联子区域映射问题, 可以假设: 在某一姿态下相似的若干图像块, 在另一个姿态下对应的图像块也相似。这里图像间的相似性采用对应特征矩阵之间的距离测度来表征。

假设训练样本数据为两组特征矩阵集合:  $\{u_i | i = 1, 2, \dots, n\}$  与  $\{v_i | i = 1, 2, \dots, n\}$ 。对于一个新的特征矩阵  $\hat{u}$ , 首先是在训练样本集中  $\{u_i | i = 1, 2, \dots, n\}$  找到若干个最靠近的样本, 计算对应的权重; 对应特征矩阵  $\hat{v}$  由  $\{v_i | i = 1, 2, \dots, n\}$  中对应的样本采用相同的权重系数重构而成。简要的处理流程如下:

特征矩阵映射算法:

(1) 针对新特征矩阵  $\hat{u}$ , 搜索得到  $K$  个与其最靠近的训练样本

$$\hat{u}_l \in \{u_i | i = 1, 2, \dots, n\}, l = 1, 2, \dots, K.$$

(2) 计算每个近邻样本的权重  $w_l, l = 1, 2, \dots, K$ , 使得  $\hat{u}$  的重构误差最小。

(3) 基于局部关系不变原则, 使用与  $\hat{u}_l$  相对的训练样本  $\hat{v}_l$ , 在相同权重系数下, 估计对应的特征矩阵  $\hat{v}$ 。

在步骤 1 中, 采用 Frobenius 范数计算特征矩阵之间的距离:

$$d(\hat{u}, u_i) = \|\hat{u} - u_i\|_F (\text{tr}[(\hat{u} - u_i)^T (\hat{u} - u_i)])^{1/2}$$

步骤 2 中基于重构误差最小的原则求取每个近邻样本的权重系数, 其重构误差表示为

$$\varepsilon(w) = \left\| \hat{u} - \sum_{l=1}^K w_l \hat{u}_l \right\|_F, \sum_{l=1}^K w_l = 1$$

这是一个带约束的最小二乘问题。定义一个  $K \times K$  的矩阵  $Q$ :

$$Q(i, j) = \text{tr}[(\hat{u} - \hat{u}_i)^T (\hat{u} - \hat{u}_j)]$$

以及  $R = Q^{-1}$ , 则上述问题有一个固定解析解<sup>[9]</sup>:

$$w_l = \frac{\sum_{m=1}^K R(l, m)}{\sum_{i=1}^K \sum_{j=1}^K R(i, j)}, l = 1, 2, \dots, K$$

得到了权重系数之后,采用下式估计步骤 3 中对应的特征矩阵:

$$\hat{v} = \sum_{i=1}^K w_i \hat{v}_i$$

近邻点个数  $K$  是此映射算法唯一需要确定的参数。

### 4 多姿态人脸识别算法

#### 4.1 使用 2 维耦合成分分析求取关联子区域映射

在本文的多姿态人脸识别算法中,采用 2 维耦合成分分析的方法,获取非正面姿态下的人脸子区域图像向正面姿态下图像的映射函数。正面人脸被分割为若干个子区域,对应的图像数据为  $\{B_n^f((x, y), I) | n=1, 2, \dots, N\}$ 。空间上的映射关系表现为正面与非正面姿态下子区域图像位置上的映射关系:

$$(x_n^f, y_n^f) \rightarrow (x_n^p, y_n^p), n = 1, 2, \dots, N$$

其中,  $(x_n^f, y_n^f)$ 、 $(x_n^p, y_n^p)$  分别为正面与非正面子区域图像的位置。

在给定正面姿态下子区域位置情况下,满足下式的为非正面姿态下对应的子区域位置:

$$\arg \max_{(x_n^p, y_n^p)} CI[(x_n^f, y_n^f), (x_n^p, y_n^p)]$$

其中,  $CI[(x_n^f, y_n^f), (x_n^p, y_n^p)]$  是对应位置上的图像数据的耦合强度。

对于子区域图像块上的数据施加规一化预处理,使得其均值为 0, 方差为 1。针对给定的正面子区域,在非正面图像上完全搜索得到对应的关联区域。为了减少计算量,采用从粗到细的搜索方法:先采用比较大的位置步进值搜索,得到关联区域的粗略定位;再在此粗略定位的局部区域采用比较小的位置步进值搜索,得到较精细的定位;如此迭代直至位置步进值为一个像素。

在确定形状映射关系之后,采用 2 维耦合成分分析,得到各自的低维耦合子空间,获取投影特征矩阵之间的映射关系。由此利用训练样本获取关联子区域的形状映射与纹理映射。

#### 4.2 采用子区域关联映射实现姿态补偿

对于一个非正面姿态的待识别人脸图像,识别之前先进行姿态补偿处理,如图 1 所示。采用文献[9]




图 1 子区域关联映射的多姿态人脸识别算法流程  
Fig. 1 Sub-region correlative mapping based multi-pose face recognition algorithm

的算法估计原始测试样本的姿态  $\hat{\rho}$ , 根据对应姿态下的形状映射, 将图像分割为若干子区域, 然后再采用纹理映射函数, 得到正面姿态下的子区域映射数据。

#### 4.3 基于贝叶斯框架的子区域集成分类算法

非正面人脸图像经过姿态补偿后, 得到正面姿态下若干子区域上的特征矩阵。不同子区域上对分类判别有用的信息量是不一致的, 为此, 采用贝叶斯框架来处理此种区域间的差异。

非正面图像块映射后的特征矩阵与对应正面图像块的特征矩阵之间的距离, 由于消除了姿态变化的影响, 称为本征距离。若图像块对应于同一对象, 则称为同类样本本征距离; 若对应不同对象, 则为异类样本本征距离。距离的计算采用了 Frobenius 范数。

假设同类样本本征距离与非同类样本本征距离均为高斯分布, 则具体的分布为

$$p(d_i | \text{same}, \rho) = \frac{1}{\sqrt{2\pi}\sigma_i^{\text{same}}} \exp\left[-\frac{1}{2}\left(\frac{d_i - u_i^{\text{same}}}{\sigma_i^{\text{same}}}\right)^2\right]$$

$$p(d_i | \text{diff}, \rho) = \frac{1}{\sqrt{2\pi}\sigma_i^{\text{diff}}} \exp\left[-\frac{1}{2}\left(\frac{d_i - u_i^{\text{diff}}}{\sigma_i^{\text{diff}}}\right)^2\right]$$

其中,  $\rho$  为姿态值, 在第  $i$  个子区域上,  $(u_i^{\text{same}}, \sigma_i^{\text{same}})$  为同类样本本征距离的均值与标准差,  $(u_i^{\text{diff}}, \sigma_i^{\text{diff}})$  为异类样本本征距离的均值与标准差。在训练样本集上计算同类样本本征距离时, 获取当前训练样本与其他训练样本的几何关系以及对应的权重, 再重构出对应的特征矩阵。

根据学习得到的本征距离分布模型来判定某一 Probe 样本与 Gallery 样本是否归属同类。采用贝叶斯公式估计判别所需的后验概率:

$$P(\text{same} | d_i, \rho) = \frac{p(d_i | \text{same}, \rho)P(\text{same})}{p(d_i | \text{same}, \rho)P(\text{same}) + p(d_i | \text{diff}, \rho)P(\text{diff})}$$

其中,  $P(\text{same})$  为 Probe 样本与 Gallery 样本归属同一类别的先验概率,  $P(\text{diff})$  为非同类的先验概率。

若共有  $L$  个对象,则可以设置  $P(\text{same}) = \frac{1}{L}$  与  $P(\text{diff}) = \frac{L-1}{L}$ 。

最终的判别结果需综合全体子区域上的后验概率,此处采用累加的方法求取后验概率的平均值,然后选择平均后验概率最大的一个对象作为判别结果。整体的识别流程如图 1 所示。

### 5 实验

在 PICS<sup>[10]</sup> 与 HPID<sup>[11]</sup> 人脸图像库上,将本文算法与现有的若干种算法进行了比较实验,由此来测试本文算法的有效性。

#### 5.1 PICS 上的实验

PICS 包括了一系列的人脸图像库,实验中采用的 Stirling\_faces 是其中的一个子库,共包含了 36 个对象的图像,每个对象包括了从正面到的侧面 9 张图像。从中选择了正面与右侧面这两个姿态下的图像,构成实验所需样本。其中训练样本包含了 22 个对象,测试样本包含了 12 个对象。图像经剪裁缩放,统一大小为 80(高)×60(宽)。图 2 给出了一些部分样本。正面人脸的被分割为若干子区域,子区域的大小 13×10。采用 2 维耦合成分分析获取子区域关联映射,耦合子空间的维数  $k$  设置为 3,学习纹理映射函数时近邻点个数  $K$  设置为 5。得到的形状映射如图 3 所示,可以看到不同姿态下的子区域大体上对应了人脸上的同一区域。

侧面样本根据映射函数得到正面的投影特征矩阵,计算同类样本与非同类样本的本征距离,并由此



图 2 PICS 部分样本实例  
Fig.2 Some examples from PICS




图 3 关联子区域映射  
Fig.3 Correlative sub-region mapping

提取本征距离分布的概率模型。图 4 给出了位于第 3 行第 3 列的子区域上的本征距离图。可以看到 2 维图上的对角元素偏黑,表示同类样本本征距离值相对较小。分别统计对角元素与非对角元素的数值分布得到本征距离分布的高斯模型。进一步计算后验概率,并由此得到最终的判定结果。




图 4 本征距离 2 维图  
Fig.4 2D figure of eigen-distance

将本文算法与其他算法进行比较实验。第 1 个算法是经典的特征脸法,投影后的维度根据最好的实验结果确定。第 2 个算法是 Fisher 脸法。这两个算法均采用最近邻方法获得判别结果。此两种方法均无姿态补偿处理。第 3 个算法是文献[12]中提出的处理方法,手工标定人眼与嘴巴位置,将图像划分为若干子区域,然后对应的图像矩阵直接相减,求其差值平方和(sum of squared difference, SSD)来计算图像间的距离。为了阐述上的方便,第 3 种方法简称为直接 SSD 法。4 种算法的识别率在图 5 中给出。可以看到在此非正面姿态下,采用了姿态补偿处理的直接 SSD 法与本文算法优于其他两种算法;而本文算法的识别率又高于直接 SSD 方法,最重要的原因在于纹理映射的处理。

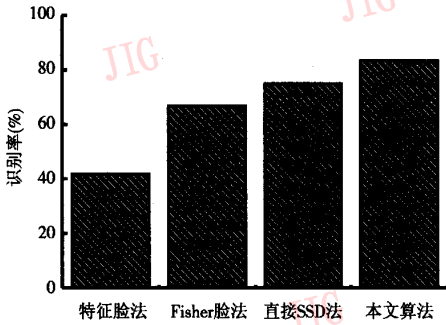


图 5 PICS 上识别率比较

Fig. 5 Detection rate comparison on PICS

在 Pentium 1.6 GHz 计算机上,采用 matlab 实现本文算法。训练时关联子区域搜索耗时约 10s,识别每个测试样本的平均耗时为 100ms。

### 5.2 HPID 上的实验

为了对算法进行更全面的比较验证,在 HPID 库上进行了另外一次实验。该数据库包括了 15 组图像,每组图像中又包含了同一对象在不同姿态下的 2 个系列共 186 张图像。前一个系列为训练样本,后一系列为测试样本。从中选出了有代表性的 9 种典型姿态,如图 6 所示。为了保证有充足的训练样本,针对每个典型姿态,每个对象选择了 4 张图像,这些图像对应的姿态位于典型姿态的附近。其中 1 系列的图像用来训练学习子区域关联映射函数以及距离分布概率模型,另外一个系列的图像用来进行识别实验。每张图像都经过剪裁缩小灰度化处



图 6 典型姿态

Fig. 6 Typical poses

理,同一大小为 80(高)×60(宽)。其他的处理方法以及对应的算法参数设置均与 PICS 上实验一致。

4 个算法的识别率如图 7 所示。可以看到随着姿态向侧面方向变化,各个算法的识别率均有下降。采用直接 SSD 法与本文算法在侧面姿态时的识别率高于特征脸、Fisher 脸法,最重要的原因在于采用了姿态补偿处理。本文算法较之直接 SSD 法,识别率较高,特别是在大的姿态变化角度下。原因在于:姿态变化给图像带来的影响,除了形状方面,还有纹理方面,随着姿态角度的增大,纹理的变化也逐渐增大,则图像直接相减的方法带来的误差也就增大,而本文所提出的纹理映射处理算法更合理一点。




图 7 HPID 上多姿态识别率比较

Fig. 7 Detection rate comparison under multi-pose on HPID

同样在 Pentium 1.6 GHz 计算机上,采用 matlab 实现本文算法。训练耗时约 235s;识别每个测试样本的平均耗时为 347ms,其中,姿态估计耗时 260ms,姿态补偿与分类耗时 87ms。

## 6 结论

针对人脸识别中的姿态变化问题,将姿态变化对图像的影响分解为形状与纹理这两个方面,提出了基于关联子区域映射的多姿态人脸识别方法。采用 2 维耦合成分分析方法,计算对应图像块的耦合度以匹配关联区域,并学习对应的低维耦合空间上投影特征矩阵之间映射关系。建立了子区域上本征距离分布的概率模型,由此综合全体子区域上的信息给出最终的判别结果。在 PICS 与 HPID 人脸库上进行了比较实验,与其他算法相比,本文算法的识别率更好,检测性能受姿态变化的影响更小。

当前采用了全搜索的方法获取关联子区域,如何利用相邻子区域的空间分布约束条件加快搜索的速度并使搜索结果更合理,是后续工作的一个内容。此外,求取不同姿态下人脸子区域的形状映射时,隐含了对所有对象的形状变化采用统一的模型变换的方法。如何进一步处理对象间差异以获得更精确的形状映射以及对应的纹理映射,是后续工作的另一个内容。

### 参考文献 (References)

- 1 Liu X, Chen T. Pose-robust face recognition using geometry assisted probabilistic modeling [A]. In: IEEE Computer Society Conference on Computer Vision and Pattern Recognition [C], San Diego, CA, USA, 2005: 502 ~ 509.
- 2 Blanz V, Vetter T. Face recognition based on fitting a 3D morphable model [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(9): 1063 ~ 1074.
- 3 Lee H, Kim D. Pose invariant face recognition using linear pose transformation in feature space [A]. In: ECCV 2004 Workshop on Computer Vision in Human-Computer Interaction [C], Prague, Czech Republic, 2004: 211 ~ 220.
- 4 Okada K, Malsburg C. Pose-invariant face recognition with parametric linear subspaces [A]. In: The 5th International Conference on Automatic Face and Gesture Recognition [C], Washington DC, USA, 2002: 64 ~ 69.
- 5 Lin D, Tang X. Coupled Space learning for image style transformation [A]. In: The 10th IEEE International Conference on Computer Vision [C], Beijing, China, 2005, 2: 1699 ~ 1706.
- 6 Torre F, Black M J. Dynamic coupled component analysis [A]. In: IEEE Computer Society Conference on Computer Vision and Pattern Recognition 2001 [C], Kauai Marriott, Hawaii, 2001: 643 ~ 650.
- 7 Yang J, Zhang D, Frangi A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131 ~ 137.
- 8 Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5500): 2323 ~ 2326.
- 9 Raychev B, Yoda I, Sakaue K. Head pose estimation by nonlinear manifold learning [A]. In: The 17th International Conference on Pattern Recognition [C], Cambridge, UK, 2004, 4: 462 ~ 466.
- 10 Hancock P. Psychological Image Collection at Stirling [EB/OL]. <http://pics.psych.stir.ac.uk/>, 2005-8-26.
- 11 Gourier N. Head Pose Image Database [EB/OL]. <http://www-prima.inrialpes.fr/Pointing04/data-face.html>, 2005-9-5.
- 12 Kanade T, Yamada A. Multi-subregion based probabilistic approach toward pose-invariant face recognition [A]. In: IEEE International Symposium on Computational Intelligence in Robotics Automation [C], Kobe, Japan, 2003, 2: 954 ~ 959.