

一种基于 E-HMM 的选择性集成人脸识别算法

李金秀 高新波 杨越 肖冰
(西安电子科技大学电子工程学院 西安 710071)

摘要: 基于嵌入式隐马尔可夫模型(Embedded Hidden Markov Model, E-HMM)的人脸识别方法的识别性能依赖于模型参数的合理选择。提出了一种基于E-HMM的多模型选择性集成人脸识别算法,选择出个体精度高且互补性强的模型来进行集成的人脸识别。实验结果表明,与传统的基于E-HMM的人脸识别方法相比,新算法不仅可以获得更好、更稳定的识别效果,而且具有更强的泛化能力。

关键词: 人脸识别; 嵌入式隐马尔可夫模型; 模型选择; 选择性集成; 泛化能力

中图分类号: TP391.41

文献标识码: A

文章编号: 1009-5896(2009)02-0288-05

A Face Recognition Algorithm Based on Selective Ensemble of E-HMMs

Li Jin-xiu Gao Xin-bo Yang Yue Xiao Bing
(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

Abstract: The performance of Embedded Hidden Markov Model (E-HMM) based face recognition algorithm heavily depends on the selection of model parameters. A selective ensemble of multi E-HMMs based face recognition algorithm is proposed, selecting many accurate and diverse models for ensemble face recognition. Comparing with the traditional E-HMM based face recognition algorithm, the experimental results illustrate that the proposed method can not only obtain better and more stable recognition effect, but also achieve higher generalization ability.

Key words: Face recognition; E-HMM; Model selection; Selective ensemble; Generalization ability

1 引言

HMM 是表示人脸的有效模型,适于用来进行人脸及其表情的识别^[1-4]。20 世纪 60 年代末, Baum 等人建立了 HMM 的基本理论^[5,6]。80 年代以后, HMM 被成功地应用在语音识别和印刷体识别中。1994 年, Samaria 最早建立了基于人脸灰度的一维 HMM^[7]。Nefian 在 Samaria 的基础上提出了基于 DCT 系数来代替灰度值作为观察值序列^[8],既解决了算法对光照、旋转等敏感的问题,又大大降低了数据量。后来,为了准确地描述人脸图像的二维空间关系,人们提出了基于二维 HMM 的人脸模型^[9],但因计算复杂度太大而限制了其实际的应用。为此,人们又引入一种嵌入式 HMM (Embedded HMM, E-HMM)来表示人脸^[10]。该模型在计算复杂度适中的情况下,不仅能提取人脸的主要二维特征,而且对姿态和环境的变化具有较好的鲁棒性。

不过,在基于 E-HMM 进行人脸识别时,不同的模型参数所描述的人脸信息有所不同,从而导致了识别性能的差异。这样,模型参数的选择成为现有基于 E-HMM 的人脸识别算法中一个亟待解决的问题。但是,即便是针对个别样本

集表现最优的模型,在应用到其他的样本集上时,也不一定是最优的;而仅仅简单地集成若干个表现最优的模型来进行识别,所得到的性能不一定是最优的,因为它们可能同时侧重表达了同样的具有明显鉴别意义的特征,不具有互补性。鉴于此,本文提出了一种基于 E-HMM 的多模型选择性集成的人脸识别方法,选择多个精度高且互补性强的 E-HMM 模型进行集成来实现识别人脸的任务,以降低识别性能对 E-HMM 模型参数的敏感性,提高人脸识别算法的泛化能力。

2 人脸图像的 E-HMM

E-HMM是由一系列竖向的超状态和横向的嵌入状态构成,一般记为 $\lambda = (\Pi, \mathbf{A}, \Lambda)$,其中, Π 为超状态初始概率分布, $\Pi = \{\Pi_i, 1 \leq i \leq N_s\}$, N_s 为垂直方向的超状态数; \mathbf{A} 为超状态转移概率矩阵; Λ 为嵌入的马尔可夫模型, $\Lambda = \{A_i, 1 \leq i \leq N_s\}$;其中第 i 个超状态可表示为 $A_i = \{\Pi_i, \mathbf{A}_i, \mathbf{B}_i\}$, Π_i 为嵌入状态的初始概率分布, $\Pi_i = \{\pi_{ik}, i \leq k \leq N^i\}$, N^i 为嵌入的子状态数; \mathbf{A}_i 为嵌入状态的转移概率矩阵; \mathbf{B}_i 为第 i 个超状态中嵌入的子状态的观察值概率密度函数, $\mathbf{B}_i = \{b_k^i(\mathbf{O}_{x,y})\}$, $\mathbf{O}_{x,y}$ 表示第 x 行、第 y 列的观测向量($1 \leq x \leq X; 1 \leq y \leq Y$)。 \mathbf{B}_i 通常用混合高斯模型来近似表示:

$$b_k^i(\mathbf{O}_{x,y}) = \sum_{j=1}^K C_{kj}^i N(\mathbf{O}_{x,y}, \boldsymbol{\mu}_{kj}^i, \boldsymbol{\Sigma}_{kj}^i), \quad 1 \leq k \leq N^i \quad (1)$$

2007-07-24 收到, 2007-12-28 改回

国家自然科学基金(60202004), 教育部长江学者和创新团队支持计划和新世纪优秀人才支持计划(NCET-04-0948)资助课题

其中 K 为组成 $b_k^i(\mathbf{O}_{x,y})$ 的混合高斯概率密度函数的个数; C_{kj}^i 是第 i 个超状态中第 k 个嵌入状态的第 j 个混合量的权重系数; $N(\mathbf{O}_{x,y}, \boldsymbol{\mu}_{kj}^i, \mathbf{U}_{kj}^i)$ 为多维高斯概率密度函数, 其中, $\boldsymbol{\mu}_{kj}^i$ 表示第 i 个超状态中嵌入的第 k 个状态的第 j 个组合量的均值向量; $\boldsymbol{\Sigma}_{kj}^i$ 表示第 i 个超状态中嵌入的第 k 个状态的第 j 个混合量的协方差矩阵。

将 E-HMM 用于人脸识别时, 不同的 N_s , N^i , K 所建立的模型 $\lambda = (\Pi, \mathbf{A}, \Lambda)$ 也是有差异的。这样, 也可以将该模型记为 $\lambda = (\Pi, \mathbf{A}, \Lambda | N_s, N^i, K)$ 。运用 E-HMM 对人脸图像进行建模时, N_s , N^i 与 K 这 3 个参数需要事先给定。观察向量的提取一般是通过构造一个采样窗口对图像进行扫描遍历, 然后对每个图像块进行 DCT 变换实现的^[7]。具体方法如图 1 所示: 在人脸图像平面上用一个像素点数为 $P \times L$ 采样窗, 从左到右、从上到下滑动, 相邻窗口在垂直方向和水平方向的采样间隔分别有 Δ_x 行、 Δ_y 列。对每个观察图像块应用 2D-DCT 变换, 取每一个块 2D-DCT 左上角的低频系数组成观察向量。由此可得, 观察向量是由 $P \times L$, $\Delta_x \times \Delta_y, N_{2D-DCT}$ 这三组参数决定的, 因此, 我们可以将其记为 $\mathbf{O} = (o_1, o_2, \dots, o_T | P \times L, \Delta_x \times \Delta_y, N_{2D-DCT})$ 。

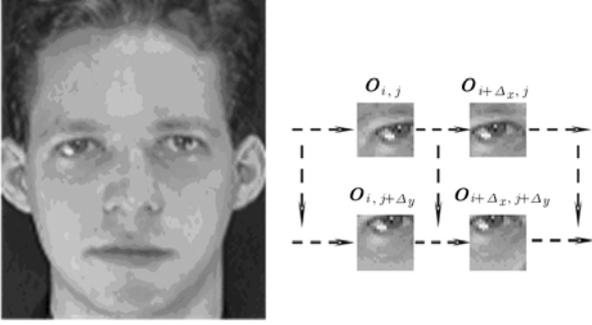


图 1 人脸模型中观察向量的提取

3 基于 E-HMM 的选择性集成人脸识别算法

集成学习被认为是近年来机器学习领域的四大研究方向之一^[12], 具有比单个学习器更强的泛化能力。但是集成的学习器并不是越多越好, 大量的研究^[13]证明, 选择部分性能高、差异大的学习器来构建的集成要优于使用全部的个体学习器所构建的集成。为此, 本文提出一种基于 E-HMM 选择性集成的人脸识别算法, 该算法分为两部分: 第 1 部分为 E-HMM 模型的训练选择模块, 从 n 个模型中选择出 m 个个体精度高且差异大的模型; 第 2 部分是集成的人脸识别模块, 利用集成训练所得到的 m 个模型进行人脸识别。其流程如图 2 所示。

图 2 中 \mathbf{M} 表示基于不同参数的 E-HMM 所构建的人脸模型, 记为: $\mathbf{M} = (\mathbf{O}; \lambda)$, 其中 $\mathbf{O} = (o_1, o_2, \dots, o_T | P \times L, \Delta_x \times \Delta_y, N_{2D-DCT})$ 为模型的特征信息; $\lambda = (\Pi, \mathbf{A}, \Lambda | N_s, N^i, K)$ 为模型的结构信息。因此, 模型 M 就由上述 6 组参数所确定。

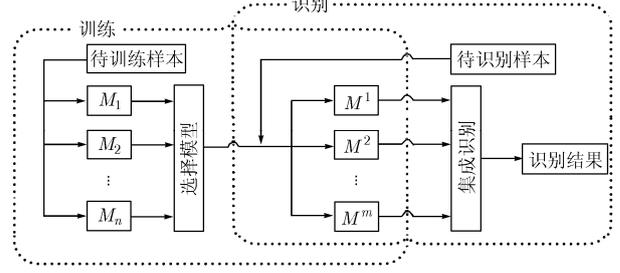


图 2 基于 E-HMM 的选择性集成人脸识别算法流程图

3.1 E-HMM 模型的选择算法

本节给出一种 E-HMM 模型的自动选择算法。给定 L 个人脸样本库, 每人 l 幅图像, 其中 l_1 幅作为 gallery 图像, l_2 幅作为 probe 图像。具体算法步骤如下:

步骤 1 以 gallery 图像为训练集建立 n 个 E-HMM 模型 $\{M_1, M_2, \dots, M_n\}$, 利用这 n 个模型识别所有的 probe 图像, 得到相应的识别率 r_i ($i = 1, 2, \dots, n$);

步骤 2 根据相应识别率 r_i 由高到低将所建立的 n 个 E-HMM 模型排序, 记作 $\{M'_1, M'_2, \dots, M'_n\}$, 令 $S = \{M'_1\}$, $Z = \{M'_2, \dots, M'_n\}$, 进行如下操作:

(1) 令 $t = 1$, 设 S 中误识的图像数目为 ε_t ;

(2) 对于每一个 $M^i \in Z$, 计算它可以识别正确, 但是 S 中至少有一个模型识别错误的 probe 图像数目, 记为 c_i , 代表纠识图像的数目。常用的方法^[14]是将纠识图像数目最多的模型添加到 S 中, 但实际应用中存在纠识图像数目相同的模型, 为了将其中识别率较高的模型添加到 S 中, 可根据以下准则进行模型选择:

$$M^k, \text{ with } k = \arg \left\{ \max_{M^i \in Z} \left\{ w_1 r_i + w_2 \frac{c_i}{\varepsilon_t} \right\} \right\} \quad (2)$$

其中 $w_2 + w_1 = 1$, 且 w_1 为识别率所占的权重, 取值较小, 范围为 $(0, 0.1]$, 起辅助作用; w_2 为纠错率所占权重, 取值较大, 范围为 $[0.9, 1)$, 起主要作用;

(3) $S \leftarrow S \cup M^k, Z \leftarrow Z - M^k$;

(4) 若 $t < m$, 则 $t = t + 1$, 转(2); 否则停止, 输出选择出来的 m 个 E-HMM 模型, 记为 $\{M^1, M^2, \dots, M^m\}$ 。

3.2 基于 E-HMM 集成的人脸识别算法

利用所得到的 m 个模型, 即可采用如下的方法进行人脸识别。假设人脸库中有 H 个人脸图像, 当待识别图像输入系统进行识别时, 应用上节所得到的 m 个 E-HMM 模型, 求其在各个模型下与人脸库中每个人图像的似然值矩阵:

$$\mathbf{P} = \begin{bmatrix} P(O^1 | \lambda_1^1) & P(O^1 | \lambda_2^1) & \cdots & P(O^1 | \lambda_H^1) \\ P(O^2 | \lambda_1^2) & P(O^2 | \lambda_2^2) & \cdots & P(O^2 | \lambda_H^2) \\ \vdots & \vdots & \vdots & \vdots \\ P(O^m | \lambda_1^m) & P(O^m | \lambda_2^m) & \cdots & P(O^m | \lambda_H^m) \end{bmatrix}_{m \times H} \quad (3)$$

其中 O^i ($i = 1, 2, \dots, m$) 和 λ_j^i ($i = 1, 2, \dots, m; j = 1, 2, \dots, H$) 分别为待识别图像在第 i 个模型 M^i 中所对应的观察向量序列与

E-HMM 模型, $P(O^i | \lambda_j^i)$ ($i = 1, 2, \dots, m; j = 1, 2, \dots, H$) 表示待识别图像在第 i 个模型 M^i 下与第 j 个人的似然值。

对于每个人的 m 个模型, 其对应的权值为 w^i ($i = 1, 2, \dots, m$), $\sum_i w^i = 1$ 。 w^i 有多种选择方式, 比如可选择等权平均, 即 $w^i = 1/m$; 或根据识别率设置不同权值, 即

$$w^i = \frac{r_i}{\sum_{j=1}^m r_j} \quad (4)$$

其中 r_i 为在进行模型选择时第 i 个模型所对应的识别率。

在对待识别图像进行判决时, 首先对似然矩阵 \mathbf{P} 进行二值化处理生成决策矩阵 \mathbf{P}_d :

$$P_d(O^i | \lambda_j^i) = \begin{cases} 1, & P(O^i | \lambda_j^i) = \max_k \{P(O^i | \lambda_k^i)\} \\ 0, & \text{其他} \end{cases} \quad (5)$$

然后, 对每个人的 m 个模型进行集成, 得到最终的识别判决输出:

$$D = \arg \left\{ \max_j \left[\sum_{i=1}^m w^i \cdot P_d(O^i | \lambda_j^i) \right] \right\} \quad (6)$$

4 实验结果及分析

实验在 ORL(Olivetti Research Ltd)数据库^[17]上进行。该数据库中共有 40 人, 每人 10 幅大小为 92×112 的人脸灰度图像。图像在光照均匀条件下获取, 人脸姿态在深度和平面旋转可达 20° , 人脸尺寸也有最多 10% 的变化。对每人的 10 幅图像随机挑选 5 张作为 gallery 图像, 剩下的 5 张为

probe 图像, 得到样本集 A 。然后, 将样本集 A 中的 probe 图像与 gallery 图像互换, 得到样本集 B , 二者分别作为建模和选择性集成的训练样本集。在进行测试时, 所选用的样本集为 C , D 和 E , 它们都是在该人脸库中每人随机挑选出 5 张作为 gallery 图像, 剩下的 5 张为 probe 图像所得到的, 且相异于 A 和 B 。

实验参数取值如下: 样本集中的人数 $L = 40$, 每人图像数 $l = 10$, gallery 图像个数 $l_1 = 5$, probe 图像个数 $l_2 = 5$ 。E-HMM 模型集 $\Omega = \{M_1, M_2, \dots, M_{2000}\}$, 其中各个模型所对应采样窗口的参数取值范围为 $2 \times 2 \leq P \times L \leq 31 \times 31$, 采样步长取值范围为 $1 \times 1 \leq \Delta_x \times \Delta_y \leq 26 \times 26$, 2D-DCT 系数个数取值范围为 $4 \leq N_{2D-DCT} \leq 24$, 高斯概率密度函数个数取值范围为 $2 \leq K \leq 8$, 超状态个数取值范围为 $2 \leq N_s \leq 7$, 子状态个数取值范围为 $1 \leq N^i \leq 9$ 。由于 $w_1 \in (0, 0.1]$, 故模型选择时识别率所占的权值为 $w_1 = (1 + 0)/2 = 0.05$, 纠错率所占的权值为 $w_2 = 1 - w_1 = 0.95$ 。

4.1 基于单个 E-HMM 的人脸识别测试实验

在进行测试实验中, 利用集合 Ω 中的 N 个模型分别对样本集 C , D , E 进行识别, 所得到识别性能最优的模型分别记为 M_C , M_D , M_E 。为了进行对比测试实验, 本文随意选择了一个模型 M_W 和文献[7]中常选用的模型 M_T 作为参考模型。上述模型的参数如表 1 所示。

表 1 E-HMM 模型及相应的模型参数

E-HMM 模型	$P \times L$	$\Delta_x \times \Delta_y$	N_{2D-DCT}	N_s	$N^i (i = 1, 2, \dots, N_s)$	K
M_C	8×8	3×3	12	7	(3, 3, 3, 3, 3, 3)	6
M_D	18×18	4×4	10	4	(9, 9, 9, 9)	6
M_E	12×12	2×2	6	7	(2, 2, 2, 2, 2, 2)	3
M_W	31×31	24×24	6	2	(3, 3)	2
M_T	10×8	2×2	24	5	(3, 6, 6, 6, 3)	3

对于给定的 ORL 数据库, 上述给定的 5 个 E-HMM 模型在 3 组测试样本集上所得到的识别率如表 2 所示。实验结果表明:

(1)不同的模型所表现出来的识别性能有可能相差甚远, 例如在对样本集 D 进行识别时, 模型 M_D 和模型 M_W 之间的识别率竟然相差了 54%。这是因为不同的模型所表达以及擅长表达的人脸信息是不一样的, 当然所表现出来的识别性能以及擅长于识别准确的图像也是不一样的;

(2)单个模型(如 M_C 、 M_D 、 M_E)针对个别的样本集虽然能够达到最优的识别性能, 但应用到别的样本集上时识别性能并不能保持, 说明单个模型的泛化能力不够强。

表 2 5 个 E-HMM 模型在 3 组测试样本集上的识别结果(识别率%)

E-HMM 模型	样本集 C	样本集 D	样本集 E
M_C	98.5	96.5	96.0
M_D	98.0	99.5	97.0
M_E	95.5	98.0	98.5
M_T	95.5	98.5	94.0
M_W	55.5	45.5	62.0

4.2 两种 E-HMM 选择性集成方式的测试实验

为了更加完善地表达人脸信息从而达到更高的识别性

能, 对于样本集 A 和 B , 本文分别从 Ω 的 n 个模型中按照 3.1 节中的算法选择出的模型, 组成了模型集 M_A 和 M_B 。利用 M_A 和 M_B 分别对样本集 C, D 和 E 进行等权平均和加权平均的识别, 结果如表 3 所示。

表 3 模型集 M_A 和 M_B 进行集成后在 3 个样本集上的识别结果(识别率%)

模型(集)	样本集 C	样本集 D	样本集 E
M_A (等权平均)	95.0	98.5	97.5
M_A (加权平均)	98.5	100	99.0
M_B (等权平均)	95.5	97.5	94.5
M_B (加权平均)	98.0	99.0	98.0

由表 3 中的实验结果可知:

(1)在模型集 M_A 与 M_B 中, 利用等权平均方式来进行识别时并没有达到单个最优识别性能模型(分别为 M_C, M_D 和 M_E)那么优秀的识别性能, 这就说明简单的利用等权平均的方式来对模型进行集成, 并不能达到所期望的识别效果;

(2)无论是在模型集 M_A 还是在模型集 M_B 中, 加权平均所得到的识别效果明显的优于等权平均的识别结果, 这说明加权平均较之等权平均更加有效。

4.3 多种人脸识别方法的对比测试实验

采用 3.2 节所提出的 E-HMM 选择性集成的人脸识别算法, 分别基于模型集 M_A 和 M_B 对样本集 C, D, E 进行识别, 这里选择加权平均的集成方法。将多 E-HMM 选择性集成方法和单一 E-HMM 方法进行对比实验, 结果如表 4 所示。

表 4 多种人脸识别方法的在 3 个样本集上的识别效果对比(识别率%)

模型(集)	样本集 C	样本集 D	样本集 E	均值	方差	复杂度
M_A	98.5	100	99.0	99.17	0.39	$\sum_{i=1}^m O(M_A^i)$
M_B	98.0	99.0	98.0	98.33	0.22	$\sum_{i=1}^m O(M_B^i)$
M_C	98.5	96.5	96.0	97.00	1.17	$O(M_C)$
M_D	98.0	99.5	97.0	98.17	1.06	$O(M_D)$
M_E	95.5	98.0	98.5	97.33	1.72	$O(M_E)$
M_T	95.5	98.5	94.0	96.0	3.50	$O(M_T)$

分析表 4 中的实验结果, 可以得到以下 3 个结论:

(1)在这 3 个样本集中, 基于选择性集成的 E-HMM 人脸识别算法所取得的识别效果优于常用的 E-HMM 模型, 可见常用的 E-HMM 参数并不是普适的;

(2)在这些样本集中, 使用本文方法所得到的模型集总能取得比单个最优识别性能模型更好或者接近的效果(两者差距不超过 0.5%), 而实际应用 E-HMM 模型进行识别时, 并不能预见哪个模型的泛化性好, 而本文方法则无需考虑模型

选择问题;

(3)本文方法所得到的模型集, 选择性集成的方法使得算法的复杂度提升为单个模型的 m 倍, 但是其识别率均值都高于单个最优识别率模型, 而方差都低于单个最优识别率模型, 这进一步说明了本文提出的方法不仅识别性能高而且稳定性好, 即能够比其它的单个模型更好地处理新数据, 有更好的识别性能和泛化能力。

5 结束语

本文基于选择性集成的思想提出一种多 E-HMM 的人脸识别算法, 在一定程度上解决了模型选择问题。实验结果表明, 新方法取得了优于常用的单 E-HMM 的识别性能, 对于给定的样本集取得了优于(或者接近)最优模型的识别性能和更好的泛化能力, 也就是说, 新算法具有更强的处理新数据的能力。尽管集成了多个模型进行识别使得算法时间复杂度有所提高, 但是由于所提出的算法本质上是并行的, 所以可以利用并行技术提高算法的效率, 这与识别率和误识率所权值的自动化确定都将是下一步的研究方向。

参考文献

- [1] 王晖, 卢健, 孙小芳. 人脸识别中嵌入式隐 Markov 模型结构的优化算法研究. 武汉大学学报, 2006, 31(7): 573-575.
Wang H, Lu J, and Sun X F. An improved algorithm based on embedded hidden markov model structure for face recognition. *Geomatics and Information Science of Wunan University*, 2006, 31(7): 573-575.
- [2] Aleksic P S and Katsaggelos A K. Automatic facial expression recognition using facial animation parameters and multistream HMMs. *IEEE Trans. on Information Forensics and Security*, 2006, 1(1): 3-11.
- [3] Santosh Kumar S A, Deepti D R, and Prabhakar B. Face recognition using pseudo-2D ergodic HMM. Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing, Toulouse, France, 2007: II-369-II-372.
- [4] Chien J T and Liao C P. Maximum confidence hidden Markov modeling for face recognition. *IEEE Trans. on Pattern Analysis and Machine Intelligence*. Accept for future publication.
- [5] Baum L E and Petrie T. Statistical inference for probabilistic functions of finite state Markov chains. *Annual Mathematics Statistics*, 1966, 37: 1554-1563.
- [6] Baum L E and Eagon J A. An inequality with applications to statistical estimation for probabilistic functions of Markov LLT processes and to a model for ecology. *Bulletin of the American Mathematical Society*, 1967, 73: 360-363.
- [7] Samaria F. Face recognition using hidden Markov models. [Ph.D. dissertation]. University of Cambridge, 1994.
- [8] Ara V N and Monson H H. Hidden Markov models for face

- recognition. Proceedings of IEEE International Conference on Image Processing, Michigan Avenue Chicago, Illinois, USA, 1998: 141-145.
- [9] Othman H and Aboulnasr T. A separable low complexity 2D HMM with application to face recognition. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2003, 25(10): 1229-1238.
- [10] Ara V N and Monson H H. Face recognition using an embedded HMM. Proceedings of IEEE International Conference on Audio Video Biometric based Person Authentication, Washington, DC, USA, 1999: 19-24.
- [11] Ara V N. A hidden Markov model-based approach for face detection and recognition. [Ph.D. dissertation]. Georgia Institute of Technology, 1999.
- [12] Dietterich T G. Machine learning research: Four current directions. *AI Magazine*, 1997, 18(4): 97-136.
- [13] Zhou Z H, Wu J, and Tang W. Ensemble neural networks: Many could be better than all. *Artificial Intelligence*, 2002, 137(1-2): 239-263.
- [14] 王珏, 周志华, 周傲英. 机器学习及其应用. 北京: 清华大学出版社, 2006: 170-188.
- Wang J, Zhou Z H, and Zhou AO Y. Machine Learning and Its Application. Beijing: Tsinghua University Press, 2006: 170-188.
- [15] Geng X and Zhou Z H. Image region selection and ensemble for face recognition. *Journal of Computer Science & Technology*, 2006, 21(1): 116-125.
- [16] Zhong J J, Gao X B, and Tian C N. Face sketch synthesis using E-HMM and selective ensemble. Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing, Honolulu, Hawaii, USA. 2007: I-485-I-488.
- [17] ORL face database. <http://www.cam-orl.co.uk/facedatabase.html>. 2006.
- 李金秀: 女, 1983 年生, 硕士生, 研究方向为人脸检测与识别.
- 高新波: 男, 1972 年生, 教授, 主要研究方向为图像处理、模式识别和人工智能.
- 杨 越: 女, 1983 年生, 硕士生, 研究方向为模式识别.
- 肖 冰: 女, 1981 年生, 博士生, 研究方向为人脸识别、图像配准等.