嵌入式隐 Markov 模型的分段训练方法

薛斌党 薛文芳

(北京航空航天大学 宇航学院, 北京 100083) (中科院自动化研究所, 北京 100080)

姜志国

(北京航空航天大学 宇航学院, 北京 100083)

摘 要: 针对嵌入式隐 Markov 模型再学习问题,提出了分段训练方法用于人脸识别:把当前的训练样本看作整体训练样本的一部分,训练结束后存储训练后的模型参数和中间变量;增加新样本后,以当前模型参数作为初始模型参数,用新增样本训练模型,得到新的中间变量,最后将已存储的中间变量和用新样本计算得到的中间变量合成,得到最终的模型. 人脸识别实验结果表明了该方法的可行性.

关 键 词: 隐马尔可夫模型; 分段训练; 人脸识别; 随机建模

中图分类号: TP 391.41

文献标识码: A **文 章 编 号**: 1001-5965(2006)06-0695-05

Segmental training scheme for embedded hidden markov model

Xue Bindang

(School of Astronautics, Beijing University of Aeronautics and Astronautics, Beijing 100083, China)

Xue Wenfang

(Institute of Automation, Chinese Academy of Science, Beijing 100080, China)

Jiang Zhiguo

(School of Astronautics, Beijing University of Aeronautics and Astronautics, Beijing 100083, China)

Abstract: A segmental scheme to retrain E-HMM(embedded hidden Markov models) for face recognition was presented. The current samples were assumed to be a subset of the whole training samples, after the training process, the E-HMM parameters and the necessary temporary parameters in the parameter re-estimating process were saved for the use of next step. When new training samples were added, the trained E-HMM parameters were chosen as the initial parameters, the E-HMM was retrained based on the new samples and the new temporary parameters were obtained. These temporary parameters were combined with the saved temporary parameters to form the final E-HMM parameters so that one person face was presented. Experiments on face database showed that the segmental training method was effective.

Key words: hidden markov model; segmental training; face recognition; stochastic modeling

嵌入式隐 Markov 模型 E-HMM(Embedded Hidden Markov Model)是在 HMM(Hidden Markov Model)[1]基础上演变的具有伪二维结构的模型,因其能够更好地描述具有二维结构的信息,所以在字符识别[2]和人脸识别[3-5]中得到了较成功的应用. 基于 E-HMM 的人脸识别方法,是将一个具体人脸作为一个系统对象看待,人脸的不同照片是同一个系统的不同光照表现,通过分析和综合其若干个光照表现建立具体对象的内在的人脸统计模型来进行识别. 统计建模一般需要大样本,而

收稿日期: 2005-07-07

作者简介: 薛斌党(1971-), 男, 河南新野人, 讲师, xuebd@buaa.edu.cn.

人脸识别中用于训练的脸像通常是小样本,对训练好的模型,在新的环境下为了提高模型的适应能力,需要增加新的训练样本,使得模型能够保留旧样本知识并补充学习新样本知识,这就是模型的再训练问题. 经典的 Baum-Welch[1] 算法只能组合所有样本重新训练模型参数,无法有效利用过去的训练工作,而且还需要保存过去的训练样本以便用于后续可能的再训练,使得模型与训练样本不能分离.

本文针对 E-HMM 的再训练问题,提出了一种分段训练方法,并应用于人脸识别.

1 E-HMM 及其训练

E-HMM 由垂直方向的主 HMM 和水平方向嵌入的多组子 HMM 组成,主 HMM 中每个状态由一个子 HMM 构成,主 HMM 的状态称为超状态,子 HMM 的状态称为子状态. 一个 E-HMM 可以由下述参数表示:

1) 超状态参数.

N:垂直方向主 HMM 状态数,称为超状态数;

$\prod$:超状态初始概率分布 $\prod=\{\prod_i\}$, $1\leqslant i\leqslant N$;

$\boldsymbol{A}$:超状态转移概率矩阵 $\boldsymbol{A}=(a_{ij})$, $1\leqslant i,j\leqslant N$;

Λ:超状态内嵌入的水平方向的子 HMM 序列 $\Lambda=\{\Lambda^i\}$, $1\leqslant i\leqslant N$.

2) 子状态参数.

N^i:第 i 个超状态中嵌入的子 HMM 状态数,称为子状态数 $S^i=\{s_k^i\}$, $1\leqslant k\leqslant N^i$;

$\prod^i$:第 i 个超状态中嵌入的子 HMM 状态的初始概率分布 $\prod^i=\{\prod_k^i\}$, $1\leqslant k\leqslant N^i$;

$\boldsymbol{A}^i$:第 i 个超状态中嵌入的子 HMM 状态的转移概率矩阵, $\boldsymbol{A}^i=(a_{kl}^i)$, $1\leqslant k,l\leqslant N^i$;

B^i:第 i 个超状态中嵌入的子 HMM 状态的观察值概率密度函数 $B^i=b_k^i(\boldsymbol{o}_{xy})$,其中,$\boldsymbol{o}_{xy}$ 表示 x 行,y 列的观察向量($x=1,\cdots,X$; $y=1,\cdots,Y$). 通常用多维高斯概率密度函数来近似表示 B^i:

$$B^i=b_k^i(\boldsymbol{o}_{xy})=\sum_{f=1}^{F}C_{kf}^iN(\boldsymbol{o}_{xy},\boldsymbol{\mu}_{kf}^i,\boldsymbol{U}_{kf}^i)$$
$$1\leqslant k\leqslant N^i$$

式中,F 为组成 $b_k^i(\boldsymbol{o}_{xy})$ 的混合概率密度函数个数;C_{kf}^i 为超状态 i 中嵌入状态 k 的第 f 个组合量的权值;$N(\boldsymbol{o}_{xy},\boldsymbol{\mu}_{kf}^i,\boldsymbol{U}_{kf}^i)$ 为观察值概率密度函数中第 f 个多维高斯概率密度函数. 第 i 个超状态可表示为 $\Lambda^i=\{\prod^i,A^i,B^i\}$,因此 E-HMM 可记为 $\lambda=\{\prod,A,\Lambda\}$.

经典的 Baum-Welch 算法能够使用多个观察向量序列来训练 E-HMM 参数:设有 R 个训练样本形成观察向量 $\boldsymbol{O}^1,\cdots,\boldsymbol{O}^r,\cdots,\boldsymbol{O}^R$, $\boldsymbol{O}^r=(\boldsymbol{O}_y^r)$, $1\leqslant y\leqslant Y$, $\boldsymbol{O}_y^r=(\boldsymbol{o}_{xy}^r)$, $1\leqslant x\leqslant X$,状态序列 $\boldsymbol{Q}=(\boldsymbol{Q}_y)$, $1\leqslant y\leqslant Y$, $\boldsymbol{Q}_y=(q_{xy})$, $1\leqslant x\leqslant X$,在 $P(\boldsymbol{O}|\lambda)$ 局部极大时估计出模型参数.

为了叙述方便,定义以下几个变量:

$\gamma_y^r(i)=P(\boldsymbol{Q}_y=\Lambda^i|\boldsymbol{O}^r,\lambda)$:在第 y 行观察向量 $\boldsymbol{O}_y$ 时主 HMM 的超状态为 Λ^i 的概率;

$\gamma_{xy}^{ri}(k)=P(q_{xy}=s_k^i|\boldsymbol{O}_y^r,\Lambda^i,\lambda)$:在第 y 行观察向量 $\boldsymbol{O}_y$ 中 $\boldsymbol{o}_{xy}$ 位置,超状态 Λ^i 的子状态为 s_k^i 的概率;

$\xi_y^r(i,j)=P(\boldsymbol{Q}_y=\Lambda^i,\boldsymbol{Q}_{y+1}=\Lambda^j|\boldsymbol{O}^r,\lambda)$:在第 y 行观察向量 $\boldsymbol{O}_y$ 时主 HMM 的超状态为 Λ^i,在第 $y+1$ 行观察向量 $\boldsymbol{O}_{y+1}$ 时主 HMM 的超状态为 Λ^j 的概率;

$\xi_{xy}^{ri}(k,l)=P(q_{xy}=s_k^i,q_{x+1\,y}=s_l^i|\boldsymbol{O}_y^r,\Lambda^i,\lambda)$:在第 y 行观察向量 $\boldsymbol{O}_y$ 中 $\boldsymbol{o}_{xy}$ 位置超状态 Λ^i 的子状态为 s_k^i,$\boldsymbol{o}_{x+1\,y}$ 位置超状态 Λ^i 的子状态为 s_l^i 的概率;

$\psi_{xy}^{ri}(k,f)=P(\boldsymbol{Q}_y=\Lambda^i,q_{xy}=s_k^i,g_{xy}=f|\boldsymbol{O}^r,\lambda)$:在第 y 行观察向量 $\boldsymbol{O}_y$ 中,$\boldsymbol{o}_{xy}$ 位置超状态 Λ^i 的子状态 s_k^i 的观察值概率密度函数中出现第 f 个分量的概率,其中 g_{xy} 表示子状态观察值概率密度函数中的组合量.

另外,定义如下期望值变量:

$S^s(i)$:在 $y=1$ 时,处于超状态 i 的次数期望值;

$S^c(i,k)$:在每一行观察向量中 $x=1$ 时,处于超状态 i 中嵌入的子状态 k 的次数的期望值;

$S^s(i,j)$:超状态 i 转移到超状态 j 次数期望值;

$S^c(i,k,l)$:超状态 i 中从嵌入的子状态 k 转移到嵌入的子状态 l 的次数的期望值;

$S^s(i)$:从超状态 i 转移出去次数期望值;

$S^c(i,k)$:超状态 i 中从嵌入子状态 k 转移出去次数的期望值;

$C(i,k,f)$:超状态 i 中嵌入子状态 k 的观察值概率密度函数中出现第 f 个组合量次数期望值. 这些期望值变量计算如下:

$$S^s(i)=\sum_{r=1}^{R}\gamma_1^r(i) \tag{1}$$

$$S^c(i,k)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\gamma_{1\,y}^{ri}(k) \tag{2}$$

$$S^s(i,j)=\sum_{r=1}^{R}\sum_{y=1}^{Y-1}\xi_y^r(i,j) \tag{3}$$

$$S^{c}(i,k,l)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X-1}\xi_{kl}^{ri}(k,l) \quad (4)$$

$$S^{s}(i)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\gamma_{y}^{r}(i) \quad (5)$$

$$S^{c}(i,k)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}\gamma_{xy}^{ri}(k) \quad (6)$$

$$C(i,k,f)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f) \quad (7)$$

基于这些期望值变量, E-HMM 参数重估公式可以表示为[3]

$$\overline{\Pi}_{i}=\frac{S^{s}(i)}{\sum_{j=1}^{N}S^{s}(j)} \quad (8)$$

$$\overline{a}_{ij}=\frac{S^{s}(i,j)}{S^{s}(i)} \quad (9)$$

$$\overline{\Pi}_{k}^{i}=\frac{S^{c}(i,k)}{\sum_{k=1}^{N^{i}}S^{c}(i,k)} \quad (10)$$

$$\overline{a}_{kl}^{i}=\frac{S^{c}(i,k,l)}{S^{c}(i,k)} \quad (11)$$

$$\overline{C}_{kf}^{i}=\frac{C(i,k,f)}{\sum_{f=1}^{F}C(i,k,f)} \quad (12)$$

$$\overline{\mu}_{kf}^{i}=\frac{\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)\boldsymbol{o}_{xy}^{r}}{\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)} \quad (13)$$

$$\overline{U}_{kf}^{i}=\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)\cdot(\boldsymbol{o}_{xy}^{r}-\boldsymbol{\mu}_{kf}^{i})(\boldsymbol{o}_{xy}^{r}-\boldsymbol{\mu}_{kf}^{i})^{\mathrm{T}}\Big/\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f) \quad (14)$$

2　改进的 E-HMM 分段训练方法

基于训练样本集 R_1(其样本个数为 r_1)训练好的模型,在新的环境下为了提高模型的适应能力,需要增加新的训练样本,要求重新估计 E-HMM 参数. 设新增的样本集为 R_2(其样本个数为 r_2),分段训练方法是将式(8)~式(14)改写为

$$\overline{\Pi}_{i}=\frac{S_{R_1}^{s}(i)+S_{R_2}^{s}(i)}{\sum_{j=1}^{N}S_{R_1}^{s}(j)+\sum_{j=1}^{N}S_{R_2}^{s}(j)} \quad (15)$$

$$\overline{a}_{ij}=\frac{S_{R_1}^{s}(i,j)+S_{R_2}^{s}(i,j)}{S_{R_1}^{s}(i)+S_{R_2}^{s}(i)} \quad (16)$$

$$\overline{\Pi}_{k}^{i}=\frac{S_{R_1}^{c}(i,k)+S_{R_2}^{c}(i,k)}{\sum_{k=1}^{N^{i}}S_{R_1}^{c}(i,k)+\sum_{k=1}^{N^{i}}S_{R_2}^{c}(i,k)} \quad (17)$$

$$\overline{a}_{kl}^{i}=\frac{S_{R_1}^{c}(i,k,l)+S_{R_2}^{c}(i,k,l)}{S_{R_1}^{c}(i,k)+S_{R_2}^{c}(i,k)} \quad (18)$$

$$\overline{C}_{kf}^{i}=\frac{C_{R_1}(i,k,f)+C_{R_2}(i,k,f)}{\sum_{f=1}^{F}C_{R_1}(i,k,f)+\sum_{f=1}^{F}C_{R_2}(i,k,f)} \quad (19)$$

$$\overline{\mu}_{kf}^{i}=\Big[\sum_{r=1}^{r_1}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)\boldsymbol{o}_{xy}^{r}+\sum_{r=1}^{r_2}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)\boldsymbol{o}_{xy}^{r}\Big]\Big/\Big[\sum_{r=1}^{r_1}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)+\sum_{r=1}^{r_2}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)\Big] \quad (20)$$

$$\overline{U}_{kf}^{i}=[\zeta^{r_1}(i,k,f)+\zeta^{r_2}(i,k,f)]\Big/\Big[\sum_{r=1}^{r_1}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)+\sum_{r=1}^{r_2}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(k,f)\Big] \quad (21)$$

其中

$$\zeta^{R}(i,k,f)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}\psi_{xy}^{ri}(\boldsymbol{o}_{xy}^{r}-\boldsymbol{\mu}_{kf}^{i})(\boldsymbol{o}_{xy}^{r}-\boldsymbol{\mu}_{kf}^{i})^{\mathrm{T}}$$

式中,$S_{R_1}^{s}(i)$等表示用训练样本集 R_1 估计的中间参数;$S_{R_2}^{s}(i)$等表示用训练样本集 R_2 估计的中间参数. 分段训练方法分别用 2 个或更多训练样本估计模型参数的中间参数,最后集成得到模型参数. 训练结束后,存储模型参数的同时,需要存储中间参数如 $S_{R_1}^{s}(i)$等,便于后续的再训练.

为了进一步提高模型参数估计的效率,下面提出基于双重嵌套的 Viterbi 算法的分段训练方法:对给定观察向量 $\boldsymbol{O}$ 和初始模型 λ^{*},用双重嵌套的 Viterbi 算法寻找一个最优状态序列 $\boldsymbol{Q}$,在此过程中不断调整模型参数,使得 $P(\boldsymbol{Q},\boldsymbol{O}\mid\lambda)$取最大值, 而 $\max_{\boldsymbol{Q}}P(\boldsymbol{Q},\boldsymbol{O}\mid\lambda)$ 是 $P(\boldsymbol{O}\mid\lambda)=\sum_{\boldsymbol{Q}}\boldsymbol{P}(\boldsymbol{Q},\boldsymbol{O}\mid\lambda)$ 中最主要分量. 双重嵌套的 Viterbi 算法由垂直方向的 Viterbi 算法和水平方向的 Viterbi 算法分别寻找最优的超状态序列和超状态内嵌入的子状态序列组成[2]. 基于该算法的训练算法中,观察向量与状态序列的隶属关系是用 1 或 0 来表示. 而 Baum-Welch 参数重估算法中,观察向量与状态序列的隶属关系是用概率值来表示,这是 2 种训练算法的主要差别.

便于叙述,定义下面变量记录训练模型的中间结果:

$I_{y}^{r}(i)$替代 $\gamma_{y}^{r}(i)$:在第 y 行观察向量为 $\boldsymbol{O}_{y}$,主 HMM 的超状态 $\boldsymbol{Q}_{y}=\Lambda^{i}$ 时,$I_{y}^{r}(i)=1$;否则,$I_{y}^{r}(i)=0$.

$I_{xy}^{ri}(k)$替代 $\gamma_{xy}^{ri}(k)$:在第 y 行观察向量 $\boldsymbol{O}_{y}$ 中 $\boldsymbol{o}_{xy}$位置,超状态 Λ^{i} 的子状态为 $q_{xy}=s_{k}^{i}$ 时,$I_{xy}^{ri}(k)=1$;否则,$I_{xy}^{ri}(k)=0$.

$I_{xy}^{ri}(k,f)$替代 $\psi_{xy}^{ri}(k,f)$,表示在第 y 行观察向量 $\boldsymbol{O}_{y}$ 中 $\boldsymbol{o}_{xy}$位置超状态 Λ^{i} 的子状态 s_{k}^{i} 的观察值概率密度函数中出现第 f 个分量时,$I_{xy}^{ri}(k,f)=1$,

否则,$I_{xy}^{r,i}(k,f)=0$.

因此,式(3)~式(7)可以改写为

$$S^{s}(i,j)=\sum_{r=1}^{R}\sum_{y=1}^{Y-1}I_{y}^{r}(i)I_{y+1}^{r}(j) \quad (22)$$

$$S^{c}(i,k,l)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X-1}I_{xy}^{ri}(k)I_{x+1\,y}^{ri}(l) \quad (23)$$

$$S^{s}(i)=\sum_{r=1}^{R}\sum_{y=1}^{Y}I_{y}^{r}(i) \quad (24)$$

$$S^{c}(i,k)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}I_{xy}^{ri}(k) \quad (25)$$

$$C(i,k,f)=\sum_{r=1}^{R}\sum_{y=1}^{Y}\sum_{x=1}^{X}I_{xy}^{ri}(k,f) \quad (26)$$

把上述变量代入式(15)~式(21)中替换原来的中间变量,即为双重嵌套 Viterbi 分段训练算法公式.

3 人脸识别实验

人脸识别是当前信息学科研究热点之一[6]. 基于 E-HMM 的人脸识别方法用采集的脸像构造观察向量,用 E-HMM 的超状态序列描述人脸的前额、眼睛、鼻子、嘴巴和下巴 5 个最主要的特征区域,用超状态内嵌入的子状态序列描述每个宏观特征区域内自左至右不同的局部子区域,而观察向量与子状态之间的关系则由观察值概率密度函数决定. 每个对象的人脸用一个 E-HMM 来表示,人脸的差异就是通过模型参数的不同表现出来的.

E-HMM 观察向量序列应采用遍历方法. 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,从上向下滑动,相邻窗口在垂直方向和水平方向分别有 M 行、Q 列重叠,获取观察图像块 $\boldsymbol{o}_{xy}$,如图 1 所示.

然后,取观察图像块的二维 DCT(Discrete Cosine Transform)低频系数组成观察向量.

设人脸库中有 P 个对象,人脸识别时,提取待识别人脸图像 t 的观察向量后,根据训练后的 E-HMM 参数,计算所有训练过的模型与观察向量匹配的似然度,通过比较匹配似然值来确定待识别的人脸,即

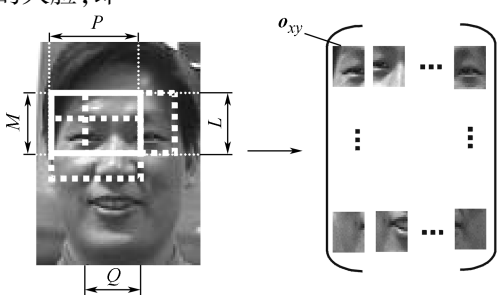

图 1 观察向量序列形成示意图

$$P(\boldsymbol{O}^{t}\mid\lambda_{k})=\max(P(\boldsymbol{O}^{t}\mid\lambda_{p}))$$
$$1\leqslant k,p\leqslant P$$

识别结果为人脸图像 t 是人脸库中第 k 个对象.

下面首先利用 ORL(Olivetti Research Ltd)人脸库[7]进行人脸识别实验. ORL 人脸库共有 40 个不同年龄、不同性别和不同种族的对象,每人有 10 幅分辨率为 92 像素×112 像素的不同姿态、不同表情和外表的图像,图像在光照均匀条件下获取,背景为黑色. 每人用 6 幅脸像组成训练样本,用另外 4 幅组成测试样本. 实验时,把 6 幅脸像分成 $r_1=3$ 和 $r_2=3$ 两部分,然后采用本文改进的分段训练方法训练模型,训练后的合成的 E-HMM 识别正确率达到 99.5%. 表 1 为经典的识别方法利用 ORL 人脸库的识别正确率比较.

表 1 人脸识别结果比较

识别方法	识别正确率/%
文献[3]	98.0
文献[8]	90.0
文献[9]	92.5
文献[10]	96.2
本文的方法	99.5

为了进一步测试算法,在实验室内,光照适度变化条件下,建立 60 个对象人脸测试库. 其中,每个对象的人脸图像是在不同时间、不同光照条件下获取,人脸库中部分人脸图像如图 2 所示. 把这 60 个对象和 ORL 人脸库加在一起,组成新的 100 个对象共 1 000 幅图像的人脸库,每个对象取 10 幅图像,用 6 幅组成训练样本,另外 4 幅组成测试样本. 仍然把 6 幅脸像分成 $r_1=3$ 和 $r_2=3$ 两部分,然后采用本文改进的分段训练方法训练模型,训练后进行人脸识别实验,正确率为 92.6%.

4 结束语

本文提出了 E-HMM 的分段训练方法,使得 E-HMM 参数估计过程具有较好的适应性,即补充新的训练样本后,不用过去的训练样本,只需要过去模型参数估计过程中样本的期望值变量,实现模型再训练. 该方法加快了训练速度,最后合成的



图 2 人脸库中部分对象

模型既保留了已经训练过的信息又能反映新增样本的信息.

采用分段训练方法,由于保存了样本的期望值变量,就不必保存用过的训练样本以便后续的再训练,因此模型和训练模型的样本可以分离开,增加了模型训练过程的灵活性.

另外,分段训练方法为初始模型选取提供了一种解决方案:分段训练方法用 R_1 得到的初始模型参数,已经初步得到了样本的统计特征,与随机选择模型初始参数相比,使最后计算的局部极大与全局极大接近,能够更好地描述样本图像的局部和整体特征. 因此,提高了人脸识别正确率.

参考文献 (**References**)

[1] Rabiner L. A tutorial on HMM and selected applications in speech recognition[J]. Proc of IEEE, 1989,77(2):257-286

[2] Kuo S, Agazzi O. Keyword spotting in poorly printed documents using pseudo 2-D hidden Markov models[J]. IEEE Trans on PAMI, 1994, 16(8):842-848

[3] Nefian A V, Hayes III H. Maximum likelihood training of the embedded HMM for face detection and recognition [C]// Proc of the International Conference on Image Processing. Vancouver, BC, Canada:[s. n.],2000:33-36

[4] Wallhoff F, Eickeler S, Gigoll G. A comparison of discrete and continuous output modeling techniques for a pseudo-2D hidden Markov model face recognition system[C]// Proc of International Conference on Image Processing. Thessaloniki. Greece:[s. n.],2001:685-688

[5] Liu Xiaoming, Chen Tsuhan. Video-based face recognition using adaptive hidden Markov models[C]// Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Madison, Wisconsin, USA:[s. n.],2003:340-345

[6] Zhao W. Face recognition: a literature survey[R]. CS-TR-4167R, 2002

[7] AT&T Laboratories Cambridge. ORL Face database[DB/OL]. http://www.uk.research.att.com/facedatabase.html,1994-04-01

[8] Turk M, Pentland A. Eigenceface for recognition[J]. Journal of Cognitive Neuoscience,1991,3(3):71-86

[9] Ben-Arie J, Nandy D. A volumetric/iconic frequency domain representation for object with application for pose invariant face recognition[J]. IEEE Trans on PAMI, 1998,20(3):449-457

[10] Lawrence L, Giles S C, Tsoi A C, et al. Face recognition: a convolutional neural network approach[J]. IEEE Trans on NN, 1997, 8(1): 98-113

(责任编辑:陈　琛)