

一种基于签名分段和 HMM 的 离线中文签名验证方法

陈晓苏¹ 吴振华¹ 肖道举¹

摘要 离线中文签名的自动验证是一个极其复杂的问题,其困难主要在于难以建立能够容忍类内偏移同时对类间区别相对敏感的签名模型.借鉴离线中文识别系统中笔划提取的成功经验,同时结合签名验证自身的特点提出了一个计算更简单、鲁棒性更高的签名分段方法.对每个分段提取一个六维的特征矢量,按特征矢量的分量在物理意义上的区别将特征矢量分为两组分别进行矢量量化,以得到观测值序列.用每个签名个体的 12 个真实签名进行训练得到该签名个体的模型.实验中使用了 4576 个测试签名进行验证,得到了交叉错误率为 5.5% 的较好结果.

关键词 签名验证,分段,隐马尔柯夫模型,矢量量化
中图分类号 TP391

Off-Line Chinese Signature Verification Based on Segmentation and HMM

CHEN Xiao-Su¹ WU Zhen-Hua¹ Xiao Dao-Ju¹

Abstract Automatic off-line Chinese signature verification is a very complicated problem. The difficulty lies in the fact that it is hard to find a signature model that is insusceptible to inter-classes distance and at the same time is sensitive to inter-classes distance. In this paper, a simple robust segmentation method with low computation cost is proposed which can successfully extract strokes of handwritten Chinese characters and takes into account the characteristics of signature verification. After being segmented and feature extracted, each signature is represented by a series of six-dimensional vectors quantized using an improved vector quantization method to obtain a series of observation values. Twelve genuine samples were used to train the signature DHMM of a writer and 4576 signatures are used in the test. The cross error rate is only 5.5%.

Key words Signature verification, segmentation, HMM, vector quantization

1 引言

离线签名验证是利用相机、扫描仪等光学设备将人们书写在普通纸张上的签名录入为签名图像,用数字图像处理技术获取签名信息,并利用计算机和模式识别技术对签名真伪进行验证的技术^[1].其一般方法是,利用从真实签名图像中提取的一种或几种特征的组合(如:水平和垂直重心、总体倾斜等全局特征^[2]、栅格化后的局部特征^[2]、矩特征^[3]、伪动态特征^[4]和近年来提出的 Graphometirc 特征^[5])作为该签名的模板,验证的时候将待验证的签名的相应特征利用匹配方法与模板进行匹配计算,并利用阈值判断待验证签名的真伪.各种匹配方法,如弹性匹配方法、基于欧氏距离分类器、神经网络的方法^[6,7]、支持向

量机(Support vector machine, SVM)^[5]和隐马尔柯夫模型(Hidden Markov Model, HMM)^[8]都得到了应用.文献[1,9,10]对自 20 世纪 80 年代以来在自动签名验证方面的研究工作做了详细的总结.

由于文化上的差异,对中文签名验证的研究国外学者很少涉及,国内的研究大多只停留在利用像签名图像水平和垂直重心、长宽比、不变矩等基于形状的全局特征,使用基于欧氏距离的分类器的水平上,这种相对粗糙的方法很难较好的完成验证任务.其困难主要在于,难以建立能够较好容忍真实签名之间存在的类内偏移,同时又能充分彰显真伪签名之间区别的各签名个体不同的模型.

HMM 作为典型的统计学模式识别方法,因为完善的数学理论的支撑和在自动语音识别系统中的成功应用^[11],近十几年来越来越受到广泛关注,并且在更多的系统如手写体识别^[12]、人脸识别^[13]、在线签名验证^[14]等系统中得到应用.从理论上讲,HMM 所能代表的概率分布类型没有限制^[15].一个恰当构建的 HMM 对类内偏移具有较强的鲁棒性,同时对类间模式的区别有较强的敏感性.本文借鉴离线中文字符识别系统中笔划提取的成功经验,结合签名验证的特点,提出了一个简单的、具有高鲁棒性的签名分段方法.对签名的每个分段提取一个六维的特征矢量,将签名的所有分段的特征矢量按照物理意义上的不同区分为两组分别进行矢量量化(Vector quantization, VQ),以得到该签名的观测值序列.实验证明,这种分组量化的方法大大提高了签名验证的正确率.此外,本文还对在构建 HMM 时,各参数的选择做了初步的探讨.第 2 节对实验数据进行介绍,第 3 节描述签字图像预处理、分段方法和特征提取,第 4 节讨论 HMM 构建方法,第 5 节是实验及结果,第 6 节给出结论.

2 实验数据

国外研究人员通常将伪签名分为三类:随机伪签名、简单伪签名和熟练模仿伪签名.实践表明,将伪签名分为三类有助于区别对待不同类型的伪签名,所以本文也采用这种分类方法对三类伪签名进行研究.文中使用的签名来自 32 个书写者,在两个月的时间内陆续取得每个书写者 18 个共计 576 个真实签名.签名使用的纸张是 A5 幅面,每张纸上横竖各三排共九个大小相等的方框,签名者被要求将自己的签名书写在方框中.方框的面积足够大,以保证签名者可以书写大小偏差很大的签名.除了这 576 个真实签名外,每个书写者都有由其他书写者书写的 8 个简单伪签名.另外,每个书写者还有由其他书写者模仿真实签名样本而得的 5 个模仿伪签名.随机伪签名由除书写者本人外的另 31 个书写者的每人 4 个真实签名构成.这样对每一个书写者来说有 18 个真实签名、124 个随机伪签名、8 个简单伪签名和 5 个模仿伪签名.这些签名使用富士通 4120C 型扫描仪以 200×200 的分辨率扫描成灰度图像.

3 预处理和特征提取

3.1 签名图像预处理

按灰度扫描的图像在进行特征提取前要经过一系列的预处理过程.将含有 9 个签名的图像二值化(以 1 表示黑像素即前景笔划像素,0 表示白像素即背景像素)后应用经典的投影法进行签名分割和边缘切除.然后,使用文献[16]中介绍的方法对二值图像进行细化(细化后的签名图像下文都简称为细化图像).图 1 给出了两个细化结果的示例.

收稿日期 2005-11-7 收修改稿日期 2006-3-8
Received November 7, 2005; in revised form March 8, 2006
国家 863 计划(2003AA712022)资助
Supported by the National High-Tech Research and Development Plan of P. R. China (2003AA712022)
1. 华中科技大学计算机科学技术学院 武汉 430074
1. College of Computer Science and Technology, Huazhong University of Science and Technology, Wuhan 430074
DOI: 10.1360/aas-007-0205




图 1 签名图像的细化

Fig. 1 Thinning results of signature images

3.2 签名分段

在基于结构化方法的离线中文字符识别系统中,主要是依据构成字符的诸多笔划的相互位置在空间结构上的相似性来识别字符图像所代表的字符,所以提取到相对清晰和标准的笔划对识别正确率的提高起着重要的作用.为了尽量使提取到的笔划更为“恰当”,基于细划图像的笔划提取方法^[17~19]主要从两个方面着手来解决问题:1)特征点的定义和提取,2)确定被断开的笔划的连接原则.特征点是指具有多个分支的点,通常是由两个或两个以上笔划交叉或粘连产生,准确的提取到这些特征点是笔划提取的前提;多个分支在断开之后采用何种原则将之连接起来以组成完整的笔划是提取到相对清晰和标准的笔划的关键.文献^[17,18]通过提取到多于实际数目的分支点修正了采用 Rutoviz 的关于像素交叉数的定义^[18,19]不能找到所有的分支点的不足,文献^[19]则采用局部修正的方法提取到分支点.此外,文献^[19]中还提出了一个新的连接断开笔划的方法.所有这些方法都比较繁琐,除增大了计算量外,也使得有时无法完成对部分结构复杂的中文手写字的笔划提取.

与离线中文字符识别不同,离线签名验证正是要利用不同签名个体书写同一个名字时存在的不同的个体特征来验证签名的真伪.因此,相对清晰、准确的笔划的提取在这里不是必需的,如果笔划的提取会修正签名原始像素的分布,这种笔划提取甚至会不利于真伪签名的区分.考虑到这种情况,我们提出了一种更为简单和鲁棒性更高的方法对签名进行分段.设 S 是细化图像, P 是细化图像中的一个点(像素).则黑像素点可以形式化描述为

$$S(P) = \begin{cases} 1, & \text{如果 } P \text{ 是黑像素点} \\ 0, & \text{否则} \end{cases} \quad (1)$$

以 S_b 表示细化图像中所有的黑像素点的集合.对图 2 所示的像素点 P 和点 P 的 8 邻域的像素点集合,采用如下的特征点定义:1)如果 $N_b(P) = 1$, P 是端点;2)如果 $N_b(P) = 2$, P 是连接点;3)如果 $N_b(P) = 3$, P 是交叉点.其中, $N_b(P)$ 是点 P 的 8 邻域像素点集合中黑像素点的总数,即 $N_b(P) = \sum_{i=1}^8 S(x_i)$.细化图像中所有的交叉点的集合可以形式化表述为: $S_f = \{P | N_b(P) > 2, P \in S_b\}$.分段的主要步骤如下:

步骤 1. 从细化图像中提取所有的交叉点并加入到集合 S_f 中;

步骤 2. 将 S_f 中的所有点的值更改为 0,即从细化图像中清除所有的交叉点;

步骤 3. 提取清除交叉点后的细化图像中所有的 8-邻接(邻接的像素集合为 $\{1, 2\}$)的连通分量,每个连通分量为一个分段;

步骤 4. 将黑像素点的总数小于某一较小阈值的分段从分段集合中删除,实验中这个较小的阈值设为 5.

最后所得的分段集合即为分段结果.前面已经分析过在

签名验证中不需要提取相对准确的笔划,所以不再对被分为几个分段的笔划进行连接.这种处理使得分段算法更为简单和鲁棒性更高,并且减少了同化真伪签名的可能.经过分段以后,每个签名就由若干个分段表示.图 3 给出了使用这种分段方法对图 1 中的一个签名进行分段的结果示例.

$$\begin{matrix} x_4 & x_3 & x_2 \\ x_5 & p & x_1 \\ x_6 & x_7 & x_8 \end{matrix}$$

图 2 像素点 P 及点 P 的 8 邻域

Fig. 2 Pixel and its neighbours

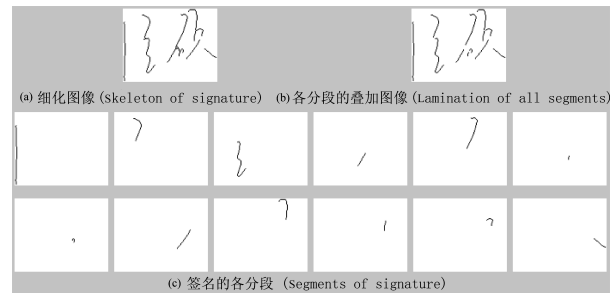


图 3 签名分段结果示例

Fig. 3 Sample result of segmentation

3.3 特征提取

签名图像分段以后,对每一个分段图像提取两组共六个特征.设 $f_i(x, y)$ 为第 i 个分段, M 和 N 分别为签名图像的水平与垂直像素总数,这两组特征的定义如下:

- 第一组,分段的水平和垂直重心.

$$\begin{aligned} C_x^i &= \frac{\sum_{y=1}^N \sum_{x=1}^M x \cdot f_i(x, y)}{\sum_{x=1}^M \sum_{y=1}^N f_i(x, y)} / M \\ C_y^i &= \frac{\sum_{x=1}^M \sum_{y=1}^N y \cdot f_i(x, y)}{\sum_{x=1}^M \sum_{y=1}^N f_i(x, y)} / N \end{aligned} \quad (2)$$

- 第二组,分段的轨迹特征,包含四个分量.

$$R_k^i = P_k^i / \sum P_k^i, k \in \{h, v, o, e\} \quad (3)$$

其中, $\sum P_k^i = P_h^i + P_v^i + P_o^i + P_e^i$. P_h^i 、 P_v^i 、 P_o^i 和 P_e^i 分别是分段的黑像素具有水平直接邻居、垂直直接邻居、正对角线直接邻居和反对角线直接邻居的像素的总数.这四种直接邻居如图 4 所示.

从这六个特征的定义可以看到,每个特征的取值都归一化到 $[0, 1]$ 范围内,这样处理有助于 HMM 的构建.经过特征提取后,每个分段都由两组共六个特征代表,而每一个签名则由一系列的六维特征矢量代表.各个分段提取的时候是从上到下、从左到右的顺序扫描每个连通分量的最左端的端

0	0	0	0	1	0	1	0	0	0	0	1
1	+	1	0	+	0	0	+	0	0	+	0
0	0	0	0	1	0	0	0	1	1	0	0
(a)	水平		(b)	垂直		(c)	正对角		(d)	反对角	

图 4 四种直接邻居的定义
Fig. 4 Four kinds of neighbour

点, 这样使得分段的顺序由各分段的左端点在细化图像中的分布决定, 随机性太大, 不利于签名个体的签名模型的建立. 因此, 对代表签名的六维特征矢量序列进行重新排序, 排序的原则为: 首先按照水平重心的值从小到大排列各特征矢量, 对于水平重心相同的特征矢量再按照垂直重心的值从小到大排列. 对排序后的特征矢量序列进行矢量量化后就得到了该签名的离散观测值序列.

4 签名分段的 HMM 模型

按照观测序列的取值及描述其分布的方法的不同, 通常将 HMM 分为三类: 离散隐马尔柯夫模型 (DHMM)、连续隐马尔柯夫模型 (CHMM) 和半连续隐马尔柯夫模型 (SCHMM). DHMM 中的观测值是离散的观测值序列, 并采用离散的概率模型描述其分布, 它具有运算量小, 计算简单的优点. 作为对应用 HMM 进行离线中文签名验证的一个初步探讨, 本文采用了 DHMM 的方法.

4.1 矢量量化的改进

使用 DHMM, 首先要将连续值的观测矢量序列进行矢量量化以得到离散的观测值序列. 矢量量化过程大大压缩了数据量, 从而较大的减少了运算量, 但量化的同时也损失了较多的有用信息. 一个可能的解决办法是大大增加码本的大小. 但这样一来, 一则计算量会显著增大得不偿失; 再则会极大的增加训练数据的需求量. 一般来说, 训练数据至少应该是码本大小的 3~5 倍^[8], 一个太大的码本需要的训练数据在实际应用中很难得到满足. 我们采用将特征矢量分组量化的方法较好的解决了这个问题.

在特征矢量量化过程中, 一个通常的做法是将特征矢量作为一个整体进行量化, 这在特征矢量的各分量的物理意义相同或相关 (即各分量互不独立) 的情况下时是不得不为之的. 在本文中, 特征矢量从物理意义上就分为了两组, 一组反映分段的位置, 一组反映分段的轨迹, 对它们采用两个不同的码本进行量化不仅更好的反映了特征在物理意义上的区别, 而且也直接增大了码本承载的信息量. 设两个码本的大小分别为 M 和 N , 这等同于一个大小为 $M \times N$ 的码本所能承载的信息量, 但是训练数据却并不需要增加, 当然采用这种方法, 必须以特征在物理意义上可分为不同组 (即各组特征相互间是独立的) 为基础, 因为只有相互间独立的特征才可能有多种不同的组合.

这种方法可以形式化的描述为: 设有一个维度为 d 的观测矢量序列, 其在 t 时刻的观测矢量为 \mathbf{x}_t , 将这个观测矢量按照其在物理意义上的区别分为 R 个维度分别为 $d_r (r \in [1, R])$ 且 $\sum_{r=1}^R d_r = d$ 的子矢量即 $\mathbf{x}_t = \{\mathbf{x}_t^1, \mathbf{x}_t^2, \dots, \mathbf{x}_t^r, \dots, \mathbf{x}_t^R\}$, 并对这 R 个子矢量使用 R 个码本 $V^1 = \{v_1^1, v_2^1, \dots, v_{M_1}^1\}$ 、 $V^2 = \{v_1^2, v_2^2, \dots, v_{M_2}^2\}$ 、 \dots 、 $V^R = \{v_1^R, v_2^R, \dots, v_{M_R}^R\}$ (其中, M_1, M_2, \dots, M_R 分别为对应码本的大小, 即码字的个数) 分别进行矢量量化. 除了采用上面这种方法, 还使用

用了多个码字的权重平均表征一个观测值的方法, 在后文的叙述中为了方便, 将码字的个数用“混合度”来表示. 我们使用经典的 LBG 算法为每个签名个体利用其训练数据产生了各自的两个码本.

4.2 模型的逻辑结构、训练及验证

HMM 具有多种不同的逻辑结构, 在手写体识别领域得到较多应用的主要是网状和链状结构. 文中采用“左右型”链状结构, 并且对状态间的转移做了较为严格的限制: 由左至右无跳转. 这种结构与人们书写签名的时候通常都是由左至右的移动顺序相一致, 能够较好的适应签名的动态过程. 确定了模型的状态转移的逻辑结构以后, 还有一个重要的参数就是状态数的确定. 作为初步的探讨, 对不同的签名个体使用了固定的状态数, 在实验中对不同状态数对性能的影响做了比较.

每个签名个体的 HMM 使用 Baum-Welch 算法进行训练, 为了应用上面提到的两个量化改进方法, 一是将一个观测矢量按照特征的物理意义分为了两个子矢量, 并分别用两个不同的码本进行量化, 另外一个是在量化的时候对每个矢量用同一个码本中的多个码字的权重平均表征, 这需要对 Baum-Welch 算法中的观测值概率矩阵的重估公式进行一个细微的调整.

设一个 DHMM 表示为: $\lambda = (\boldsymbol{\pi}, A, B)$, 其中, $\boldsymbol{\pi} = (\pi_1, \pi_2, \dots, \pi_N)$ 是初始概率矢量, N 为状态数; $A = (a_{ij})_{N \times N}$ 是状态概率转移矩阵; $B = (b_j(v_k))_{N \times M}$ 是观测值概率矩阵. 当观测矢量作为一个整体进行量化时, Baum-Welch 算法中对 B 的重估公式为

$$\bar{b}_j(v_k) = \frac{\sum_{t=1}^T \gamma_t(j)}{\sum_{t=1}^T \gamma_t(j)} \quad (4)$$

其中, $\gamma_t(j)$ 为 Markov 链在时刻 t 处于状态 j 的概率.

- 1) t 时刻的观测矢量 \mathbf{x}_t 分为 R 个子矢量 \mathbf{x}_t^r 并用 R 个码本分别进行量化时, 其观测值概率为

$$\bar{b}_j(O_t) = \prod_{r=1}^R \bar{b}_j(O_t^r) \quad (5)$$

$$\text{其中, } \bar{b}_j(O_t^r) = \bar{b}_j(v_k^r), \bar{b}_j(v_k^r) = \frac{\sum_{t=1}^T \gamma_t(j)}{\sum_{t=1}^T \gamma_t(j)}$$

- 2) 每个观测值用 $c (c \leq M)$ 个码字的权重平均表征时, 其观测值概率计算式为

$$b_j(O_t) = \sum_{k \in C} \omega_k b_j(v_k) \quad (6)$$

其中, $\omega_k = \frac{1/d(\mathbf{x}_t, \mathbf{v}_k)}{\sum_{k \in C} 1/d(\mathbf{x}_t, \mathbf{v}_k)}$, $d(\mathbf{x}_t, \mathbf{v}_k)$ 是 \mathbf{x}_t 与 \mathbf{v}_k 的距离, C 是离 \mathbf{x}_t 最近的 c 个码矢量对应的码字的集合. 重

估公式为

$$\bar{b}_j(v_k) = \frac{\sum_{\substack{t=1 \\ \text{且 } k \in C}}^T \gamma_t(j) \cdot \omega_k}{\sum_{t=1}^T \gamma_t(j)} \quad (7)$$

由 (5)~(7) 式得到最后的观测值概率为

$$b_j(O_t) = \prod_{r=1}^R \sum_{k \in C} \omega_k^r b_j(v_k^r) \quad (8)$$

重估公式为

$$\bar{b}_j(v_k^r) = \frac{\sum_{\substack{t=1 \\ \text{且 } k \in C}}^T \gamma_t(j) \cdot \omega_k^r}{\sum_{t=1}^T \gamma_t(j)} \quad (9)$$

验证时完成的任务就是对于给定的观测值序列 O 和隐马尔柯夫模型 λ , 计算由 λ 产生 O 的概率, 文中采用前向-后向算法. 计算时要用到的观测值概率矩阵用式 (8) 计算. 为了避免数值太过密集采用通常的做法: 对计算的概率取自然对数. 因为每个签名的分段数不同, 最后计算的结果都用该签名的分段数进行归一化, 其数学表达式为

$$P_v = \lg(P(O|\lambda))/L \quad (10)$$

5 实验及其结果

在签名验证领域, 一般用错误拒绝率 (FRR)、错误接受率 (FAR) 和交叉错误率 (FRR 和 FAR 相等时的错误率) 这三个参数对系统的性能进行评估. 错误拒绝率是将真实签名误判为伪签名的错误发生率, 错误接受率是将伪签名误判为真实签名的错误发生率. 判断的依据是, 当验证的结果值 P_v 大于一个门限值 (RT) 的时候认为待验证的签名是真实签名, 反之为伪签名. FRR 和 FAR 的取值可以通过调整门限值得到平衡.

我们用 matlab 和 VC 混合编程实现了系统的原型, 并用第 2 节介绍的实验数据进行实验. 用每个签名个体的 12 个真实签名进行训练得到该签名个体的签名模型, 剩下的 6 个真实签名和 137 个伪签名作为该签名个体的测试数据. 第一个实验中, 考察了将特征矢量按物理意义分组进行量化的方法对验证结果的影响, 码本的大小均为 32, 状态数均为 10, 混合度均为 6. 实验结果如表 1 所示. 从表 1 可以看到, 在码本大小相同的情况下, 分组量化等同于增大了码本的大小, 其验证结果要大大优于将特征矢量作为一个整体进行量化的方法.

第二个实验, 对采用不同的交叉点定义进行分段的方法进行了比较. 对同一个签名细化后, 三种不同的交叉点定义 (即 Liu 等人^[18] 采用的定义、Tang 等人^[19] 采用的定义和本文采用的定义) 得到交叉点数有很大的不同, 表 2 给出了图 1 中的两个签名采用三种不同的交叉点定义得到的交叉点数, 一般来说 Tang 等人采用的定义得到的交叉点数最少, 而本文采用的定义得到的交叉点数最多. 分别采用这三种定义进行分段、验证, 码本大小、状态数以及混合度与第一个实验相同. 实验结果如图 5 所示. 可以看到, 文中采用的定义较大

表 1 两种不同的量化方法的比较

Table 1 Compare of two kinds of quantization methods

	RT ¹	FRR(%)			
		真实签名	模仿	简单	随机
作为一个整体	-2.68	21.35	21.42	13.28	0.43
量化	-2.7	18.23	24.34	14.84	0.53
按物	-2.72	13.54	24.91	16.41	0.71
理意	-2.74	9.38	31.39	22.27	0.88
义分	-2.76	7.81	33.68	25.39	1.18
组量	-5.42	7.29	11.63	5.47	0.13
化	-5.44	6.25	12.04	5.86	0.13
	-5.46	4.69	13.03	6.25	0.13
	-5.48	4.17	13.26	6.64	0.15
	-5.5	3.65	13.61	7.03	0.18

1. RT 为门限值

表 2 不同交叉点定义所得到的交叉点数示例

Table 2 Samples of number of fork point when using different fork point definition

Definition	The first ¹	The second ²
Def. of Liu	8	51
Def. of Tang	8	45
Def. of us	18	84

- 1. 图 1 中第一个签名
- 2. 图 1 中第二个签名

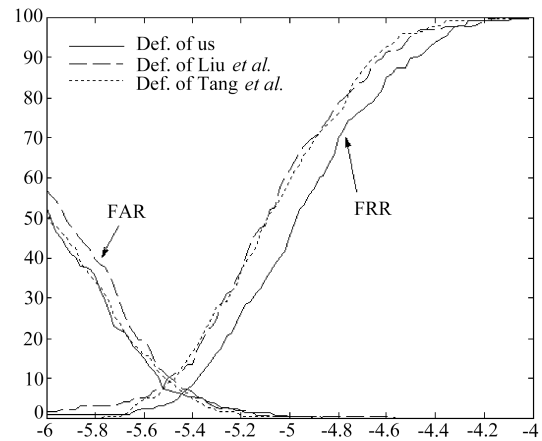


图 5 采用三种不同交叉点定义的验证结果比较
Fig. 5 Compare of verification results when using three different fork point definitions

地降低了误拒率, 这主要是因为本文所采用的定义对于交叉处的细节保留得较少, 从而有利于降低误拒率.

最后一个实验, 对状态数和混合度的不同取值作了比较, 实验中码本的大小均为 32, 表 3 给出了实验结果. 表中第二行为混合度的取值, 第二列为状态数的取值. 其它数值为取相应混合度和状态数的时候验证的错误拒绝率和三个错误接受率的平均值的差的绝对值取最小值时四个错误率的平均值 (即交叉错误率的近似值). 从混合度方面来看, 取多个码字表征矢量时的验证结果要大大优于只用一个码字表征矢量时的验证结果, 但混合度也不是越大越好, 混合度为 6 的时候得

表 3 状态数和混合度的不同取值的验证结果比较

Table 3 Compare of verification results when using different number of state and mix degree

	混合度 ¹							
	1	2	3	4	5	6	7	8
3	14.06	7.88	8.27	11.20	10.29	8.33	9.11	10.48
4	13.61	9.77	8.72	7.88	8.07	9.38	8.46	10.94
5	12.96	6.90	5.79	7.81	9.18	8.27	6.97	8.98
6	12.96	8.46	6.64	8.20	7.36	7.81	8.46	8.72
状	7	14.06	6.71	6.71	8.27	7.16	5.79	9.38
	8	13.61	6.25	6.71	6.71	8.27	8.27	7.16
态	9	14.97	6.90	5.53	5.34	8.07	7.10	8.01
	10	16.54	8.27	7.36	7.16	6.51	5.79	5.34
数	11	14.52	9.83	6.90	6.71	6.90	7.16	6.25
	12	13.61	6.05	7.36	6.05	6.71	5.60	8.07
	13	12.04	7.62	8.92	7.88	5.79	5.14	6.25
	14	11.85	8.27	5.60	6.71	6.25	7.16	5.14
	15	11.85	7.55	7.81	7.36	6.25	6.25	6.71

1. 量化中表征一个原始矢量所使用的码字的个数

到最好的结果。从状态数方面来看,没有一个确定的状态数使得验证结果相对最好,这是由于每个签名个体最适合的状态数并不一样所致。

6 结论

本文使用签名分段和 DHMM 的方法进行离线中文签名验证,得到交叉错误率为 5.5% 左右的较好结果。文中提出的简单的分段方法不仅降低了计算复杂度、提高了分段算法的鲁棒性,而且相对于另外两种交叉点定义,文中使用的定义较大程度地降低了交叉错误率。此外,采用将特征矢量按物理意义分组进行量化的方法也较大程度地提高了验证的正确率。

HMM 是一个较为复杂的模型,涉及的参数很多,要将其恰当地应用到离线签名验证系统中还有许多的问题需要进一步探讨。如何为每个签名个体确定最适合的状态数是下一阶段的主要工作。

References

- Plamondon R, Lorette G. Automatic signature verification and writer identification: The state of the art. *Pattern Recognition*, 1989, **22**(2): 107~131
- Qi Y Y, Hunt B R. Signature verification using global and grid features. *Pattern Recognition*, 1994, **22**(12): 1621~1629
- Hai Lin, Hai Zhou-Li. Chinese signature verification with moment invariants. In: Proceedings of IEEE International Conference on Systems, Man, and Cybernetics. IEEE, 1996. 2963~2966
- Ammar M. Progress in verification of skillfully simulated handwritten signatures. *International Journal of Pattern Recognition and Artificial Intelligence*, 1991, **5**(1-2): 337~351
- Justino E J R, Bortolozzi F, Sabourin R. An off-line signature verification method based on SVM classifier and graphometric features. In: Proceedings of the 5th International Conference on Advances in Pattern Recognition. Calcutta, India, New Delhi INDIA: Allied Publishers Pvt. Ltd., 2003. 134~141
- Bajaj R, Chaudhury S. Signature verification using multiple neural classifiers. *Pattern Recognition*, 1997, **30**(1): 1~7
- Baltzakis H, Papamarkos N. A new signature verification technique based on a two-stage neural network classifier. *Engineering Applications of Artificial Intelligence*, 2001, **14**(1): 95~103
- Justino E J R, El Yacoubi A, Bortolozzi F, Sabourin R. An off-line signature verification system using hidden Markov model and cross-validation. In: Proceedings of XIII Brazilian Symposium on Computer Graphics and Image Processing. IEEE, 2000. 105~112
- Leclerc F, Plamondon R. Automatic signature verification: The state of the art 1989-1993. *International Journal of Pattern Recognition and Artificial Intelligence*, 1994, **8**(3): 643~660
- Dimauro G, Impedovo S, Lucchese M G, Modugno R, Pirlo G. Recent advancements in automatic signature verification. In: Proceedings of the Ninth International Workshop on Frontiers in Handwriting Recognition. IEEE, 2004. 179~184
- Rabiner L R. A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 1989, **77**(2): 257~286
- Senior A W, Robinson A J. An off-line cursive handwriting recognition system. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, **20**(3): 309~321
- Liu Xiao-Jun, Wang Dong-Feng, Zhang Li-Fei, Shi Yong-Gang, Zou Mou-Yan. An approach for face recognition based on singular value decomposition and hidden Markov model. *Chinese Journal of Computers*, 2003, **26**(3): 340~344 (刘小军, 王东峰, 张丽飞, 时永刚, 邹谋炎. 一种基于奇异值分解和隐马尔可夫模型的人脸识别方法. *计算机学报*, 2003, **26**(3): 340~344)
- Kashi R S, Hu J, Nelson W L, Turin W. On-line handwritten signature verification using hidden Markov model features. In: Proceedings of the Fourth International Conference on Document Analysis and Recognition. IEEE, 1997. 253~257
- Jeff B. What HMMs Can Do: UWEE Technical Report [Online], available: <http://www.ee.washington.edu/techsite/papers/refer/UWEE-TR-2002-0003.html>, June 12, 2005
- Lam L, Lee S W, Suen C Y. Thinning methodologies—A comprehensive survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1992, **14**(9): 869~885
- Abuhaiba I S I, Holt M J J, Datta S. Processing of binary images of handwritten text documents. *Pattern Recognition*, 1996, **29**(7): 1161~1177

- 18 Liu K, Huang Y S, Suen C Y. Robust stroke segmentation method for handwritten Chinese character recognition. In: Proceedings of the Fourth International Conference on Document Analysis and Recognition. IEEE, 1997. **1**: 211~215
- 19 Lin F, Tang X. Offline handwritten Chinese character stroke extraction. In: Proceedings of 16th International Conference on Pattern Recognition. IEEE, 2002. **3**: 249~252

陈晓苏 华中科技大学教授, 博士生导师. 目前主要研究方向为: 现代计算机网络技术及其应用, 数字图像处理和模式识别. E-mail: x.s.chen@mail.hust.edu.cn

(**CHEN Xiao-Su** Professor in the College of Computer Science and Technology at Huazhong University of Science & Technology. His research interests include computer network, image processing, and pattern recognition.)

吴振华 博士研究生. 目前主要研究方向为: 模式识别, 机器学习. 本文通信作者. E-mail: wu.zhua@163.com

(**WU Zhen-Hua** Ph. D. candidate. His research interests include pattern recognition and machine learning. Corresponding author of this paper.)

肖道举 华中科技大学副教授. 目前主要研究方向为: 图像处理, 模式识别. E-mail: d.j.xiao@mail.hust.edu.cn

(**XIAO Dao-Ju** Associate professor in the College of Computer Science and Technology at Huazhong University of Science & Technology. His research interests include image processing and pattern recognition.)
