

# 基于状态持续时间的 HMM 语音识别模型<sup>①</sup>

孙玉莎, 王朝立, 白 洁, 鲁国辉

(上海理工大学 光电与计算机工程学院, 上海, 200093)

**摘 要:** 针对经典隐马尔可夫模型对状态持续时间的函数表达与实际语音的物理事实不相符合这一缺点, 在通常隐马尔可夫的基础上引入状态持续时间参数, 建立基于状态持续时间的 HMM 语音识别模型 (SDHMM), 并用其进行语音识别实验, 与经典隐马尔可夫模型相比, 识别率有所提高。

**关键词:** 隐马尔可夫模型; 状态持续时间; 语音识别;

## Speech Recognition Models Based on State Duration Hmm

SUN Yu-Sha, WANG Chao-Li, BAI Jie, LU Guo-Hui

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

**Abstract:** In order to solve the Function expression of state duration of Classic hidden Markov model doesn't match The physical facts of actual voice, this article proposed a state duration based HMM (SDHMM), bring the state duration parameters into the usual hidden Markov model. With its voice recognition experiments with the classical hidden Markov models, the recognition rate improved.

**Key words:** Hidden Markov model state duration; speech recognition

### 1 引言

HMM 模型是一个双重的随机过程, 即一个隐藏的 (不可观察的) 具有有限状态的马尔可夫链和一个与马尔可夫链相关联的随机函数集 (可观察的), 隐马尔可夫模型是一种应用非常广泛的统计模型, 能够很好的描述语音信号的非平稳性和可变性。语音等时变信号的功率谱可以唯一地由模型对应的状态的随机函数决定<sup>[1]</sup>, 而信号频谱时间的变化则由隐藏的马尔可夫链的转移概率决定, 因此非常适合建立语音信号的模型。但通常的隐马尔可夫模型的主要弱点是它对状态持续时间的建模不够理想<sup>[2]</sup>, 本文针对这一问题提出基于状态持续时间的 HMM 语言识别模型, 将状态持续时间这一参数引入到通常的 HMM 模型中, 利用其进行语音识别并与传统的 HMM 识别进行比较。

### 2 经典隐马尔可夫模型 (HMM)

一个经典的 HMM 由 3 个参数  $(\pi, A, B)$  确定,  $\lambda = (\pi, A, B)$ 。其中:

①  $\pi$ : 初始状态概率,  $\pi = (\pi_1, \dots, \pi_N)$ , 式中,  $1 \leq i \leq N$ 。

②  $A$ : 状态转移概率矩阵, 其中  $a_{ij} = P(q_{t+1} = s_j, q_t = s_i)$ ,  $1 \leq i, j \leq N$ 。

③  $B$ : 观察值概率矩阵, 其中

$b_{jk} = P(o_t = v_k | q_t = s_j)$ ,  $1 \leq j \leq N, 1 \leq i \leq M$ 。

④  $N$ : 模型的状态数。记  $N$  个状态为  $Z_1, Z_2, \dots, Z_N$ ,  $t$  时刻 Markov 链所处的状态记为  $Q_t$ 。

⑤  $M$ : 每个状态所对应的可能出现的观察值的数目。记  $M$  个观察值为  $V_1, V_2, \dots, V_m$ ,  $t$  时刻的观察值为  $O_t$ 。

我们以  $V_{(t)}$  作为我们的观察值序列。可以看出, 经典 HMM 可以分为两部分, 一个是 Markov 链, 用  $\pi, A$  描述; 另一个随机过程用  $B$  描述, 产生的输出为观察值序列,  $P$  为概率。

经典隐马尔可夫模型的三个问题及解决方法<sup>[3]</sup>:

① 评估问题: 给定一个模型参数  $\lambda = (\pi, A, B)$  和观察序列  $O = (O_1, O_2, \dots, O_t)$ , 如何有效地计算  $\lambda$  条件下产生观测序列  $O$  的最大概率  $P(O | \lambda)$ 。

① 收稿时间:2011-05-30;收到修改稿时间:2011-06-24

② 解码问题：对于给定模型参数 $(\pi, A, B)$ 和观察序列  $O=(o_1, o_2, \dots, o_T)$ ，选择最优的隐含状态序列  $Q=(q_1, q_2, \dots, q_T)$  来最佳地解释观察序列, 最大化  $P(O|\lambda)$ 。

③ 学习问题：给定一个观察序列  $O=(o_1, o_2, \dots, o_T)$  和一个模型参数  $\lambda=(\pi, A, B)$ ，如何调整参数值使  $P(O|\lambda)$  最大。

解决办法如下：观察输出概率的  $P(O|\lambda)$  计算。

对于给定的观察序列  $O=(o_1, o_2, \dots, o_T)$  和模型  $\lambda=(\pi, A, B)$ ，模型  $\lambda$  产生  $O$  的概率可采用前向概率、后向概率，可以使其计算量降低到  $N^2T$  次运算。

定义 1：前向概率用  $T$  时刻以前出现的观察序列来推算到当前时刻  $t$  时出现某个观察值的概率，即用出现  $o_1, o_2, \dots, o_{t-1}$  的概率来推算出现  $o_1, o_2, \dots, o_{t-1}, o_t$  的概率，用  $\alpha_t(i)$  表示。

前向概率计算算法。

① 初始化： $\alpha_1(i) = \pi_i b_i(o_1)$ ， $1 \leq i \leq N$

② 递归：

$$\alpha_{t+1}(j) = \left\{ \sum_i^N \alpha_t(i) a_{ij} \right\} b_j(o_{t+1}) \quad 1 \leq t \leq T-1, 1 \leq j \leq N$$

③ 结束： $P(O|\lambda) = \sum_{i=1}^N \alpha_T(i)$

定义 2：后向概率用  $o_{t+2}, o_{t+3}, \dots, o_N$  去推算  $o_{t+1}, o_{t+2}, \dots, o_N$  的概率，用  $\beta_t(i)$  表示。

后向概率算法如下：

① 初始化： $\beta_T(i) = 1$ ， $1 \leq i \leq N$

② 递归：

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j) \quad t=T-1, T-2, \dots, 1, 1 \leq i \leq N$$

③ 结束： $P(O|\lambda) = \sum_{i=1}^N \beta_T(i)$

在定义了前向概率、后向概率和它们的算法后，观察输出概率  $P(O|\lambda)$  便很容易得到：

$$P(O|\lambda) = \sum_{i=1}^N \alpha_T(i) \beta_T(i)$$

最佳状态序列的寻找：

对于 HMM 系统，外界观察到的某个序列  $O$  在系统内部对应的状态序列  $Q$  不是唯一的，但是不同的  $Q$  产生  $O$  的可能性不一样。最佳状态序列寻找的任务就是根据系统输出  $O$  寻找最有可能的状态序列  $Q$ ，使得该状态序列产生  $O$  的可能性达到最大。其常用的算法是 Viterbi 算法。Viterbi 算法是动态规划算法的一种变形，它可用如下递推算算法求得：

① 初始化：

$$\delta_1(i) = \pi_i b_i(o_1), \quad 1 \leq i \leq N$$

$$\phi_1(i) = 0, \quad 1 \leq i \leq N$$

② 递归：

$$\delta_t(i) = \max_{1 \leq j \leq N} [\delta_{t-1}(j) a_{ji}] b_i(o_t) \quad 2 \leq t \leq T, 1 \leq i \leq N$$

$$\phi_t(j) = \arg \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] \quad 2 \leq t \leq T, 1 \leq j \leq N$$

③ 结束：

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)], \quad q_T^* = \arg \max_{1 \leq i \leq N} [\delta_T(i)]$$

④ 状态序列求取：

$$q_t^* = \phi_{t+1}(q_{t+1}^*), t = T-1, T-2, \dots, 1$$

由此便可求得  $P(O|\lambda)$  的最佳状态序列：

$q_1^*, q_2^*, \dots, q_T^*$ 。

模型参数的估计：

模型参数的估计是 HMM 模型的训练问题，即如何根据系统所给的若干输出来确定模型  $\lambda=(\pi, A, B)$ ，使  $P(O|\lambda)$  最大。研究者一般采用 Baum-Welch 重估算法来进行 HMM 模型的训练。

Baum-Welch 算法可描述如下：

令

$$\xi_t(i, j) = P(q_t = S_i, q_{t+1} = S_j | o, \lambda)$$

$$\gamma_t(i) = P(q_t = S_i | o, \lambda)$$

则

$$\xi_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{P(O|\lambda)}, \quad \gamma_t(i) = \sum_{j=1}^N \xi_t(i, j)$$

由此得出了 Baum-Welch 算法中著名的重估公式：

$$\bar{\pi}_i = \gamma_1(i), \bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)}, \bar{b}_{ij} = \frac{\sum_{t=1, o_t=j}^T \gamma_t(i)}{\sum_{t=1}^T \gamma_t(i)}$$

$\bar{\lambda} = \{\bar{\pi}, \bar{A}, \bar{B}\}$  即是重估后的模型参数，且  $P(o|\bar{\lambda}) \geq P(O|\lambda)$ 。

### 3 基于状态持续时间的隐马尔可夫模型(简称SDHMM——State Duration Hmm)

虽然经典的隐马尔可夫模型由  $(\pi, A, B)$  来表征

语音信号并在识别领域中得到了一些应用，但是若基于经典的隐马尔可夫模型可以得出在状态  $i$  上相继产生  $d$  个观察值的概率为：

$$p_i(d) = (a_{ii})^{d-1}(1 - a_{ii}) \quad (1)$$

这个概率值  $p_i(d)$  描述了状态  $i$  的逗留时间 (State duration) 显然这是一个指数分布，且其最大值出现在  $d=1$  处，随  $d$  增大概率按指数逐渐减小，这与语音的物理事实不相符合<sup>[4]</sup>。因为在 HMM 应用于语音处理中，状态一般总与一定的语音单位相对应，而这些语音单位都具有相对稳定的分布，实际分布是  $d$  较小或较大时出现概率较小，处于某些中间值时出现概率较大。显然，不能孤立的通过状态转移概率矩阵  $A$  估计每个状态持续时间，但是各状态的持续时间是一个明显有用的参数，有必要加入到系统中与原有的参数共同估计，因此本文考虑可以增加这一参数来表达一个 HMM 系统，从而使它更确切地表示语音信号，提高识别率。

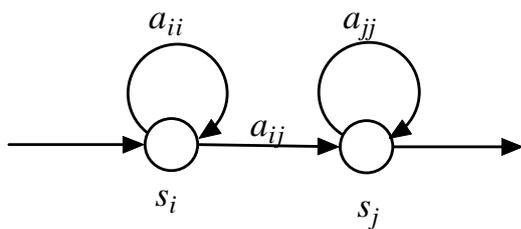


图 1 经典 HMM 系统

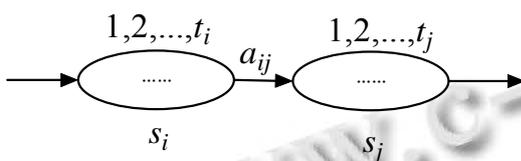


图 2 SDHMM 系统

增加了状态持续时间参数的系统如图 2 所示，与其对应的标准 HMM 系统如图 1<sup>[5]</sup>，这种 HMM 系统参数除了标准系统中具有参数组  $(\pi, A, B)$ ，并且规定  $a_{ii}=0$ ，即各状态无自转移弧，此外增加状态逗留时间概率分布  $p_i(d)$ ，式中  $d=1, \dots, D$ ， $D$  为所有状态可能停留的最长时间，当  $d>D$  时， $p_i(d)=0$ 。在这种模型中，只有在一个状态已经产生出一定数量的观测(由状态持续时间密度确定)之后才转移到另一个状态。

根据图(b)的简单模型，可变持续时间隐马尔可夫模型的输出序列将按以下步骤来产生：

① 按初始状态分布选择一个初始状态， $q_1 = S_i$ 。

② 按状态持续时间密度函数  $p_{q_1}(d_1)$  选择持续时间  $d_1$ ，为了方便和便于实现常将持续时间密度函数  $p_q(d)$  在最大持续时间值  $D$  处截断。

按联合观测密度选择观测序列  $\{o_1, o_2, \dots, o_{d_1}\}$ ，所以有：

$$b_{q_1}(o_1, o_2, \dots, o_{d_1}) = \prod_{t=1}^{d_1} b_{q_1}(o_t)$$

③ 按状态转移概率  $a_{q_1 q_2}$  选择下一个状态  $q_2 = S_j$ ；约束条件是  $a_{q_1 q_1} = 0$ ，重复这个过程，直到产生整个观测值序列  $O = (O_1, O_2, \dots, O_t)$ 。

在 HMM 三个基本问题的解决中，可以让参数  $p_i(d)$  与 HMM 的参数一起估计，此时前向变量定义为：

$$\alpha_t(i) = P(o_1, o_2, \dots, o_t; t \text{ 时结束于状态 } S_i | \lambda) \quad (2)$$

此外，假定在  $t$  个观测期间一共访问了  $r$  个状态，这些状态用  $q_1, q_2, \dots, q_r$  表示，每个状态的持续时间分别用  $d_1, d_2, \dots, d_r$  表示，那么式(2)应受到下列约束：

$$q_r = S_i \quad (3)$$

$$\sum_{n=1}^r d_n = t \quad (4)$$

于是，式(2)可写成：

$$\begin{aligned} \alpha_t(i) = & \sum_q \sum_d \pi_{q_1} p_{q_1}(d_1) P(o_1, o_2, \dots, o_{d_1} | q_1) \\ & \cdot a_{q_1 q_2} p_{q_2}(d_2) P(o_{d_1+1}, \dots, o_{d_1+d_2} | q_2) \dots \\ & \cdot a_{q_{r-1} q_r} p_{q_r}(d_r) P(o_{d_1+d_2+\dots+d_{r-1}+1}, \dots, o_t | q_r) \dots \end{aligned} \quad (5)$$

这里，求和是对所有状态  $q$  和所有可能的状态持续时间  $d$  进行的。用归纳法可得到  $\alpha_t(j)$  的迭代计算公式：

$$\alpha_t(j) = \sum_{i=1}^N \sum_{d=1}^D \alpha_{t-d}(i) a_{ij} p_j(d) \prod_{s=r-d+1}^t b_j(o_s) \quad (6)$$

上式中  $D$  是任何状态中的最大持续时间。这里从状态  $i$  到  $j$  的转移不仅与转移概率有关，而且与  $j$  的持续时间有关。为了使  $\alpha_t(j)$  的计算初始化，使用以下各式：

$$\alpha_1(i) = \pi_i p_i(1) b_i(o_1) \quad (7)$$

$$\alpha_2(i) = \pi_i p_i(2) \prod_{s=1}^2 b_i(o_s) + \prod_{\substack{j=1 \\ j \neq i}}^N \alpha_1(j) a_{ij} p_j(1) b_i(o_2) \tag{8}$$

$$\alpha_3(i) = \pi_i p_i(3) \prod_{s=1}^3 b_i(o_s) + \sum_{d=1}^2 \sum_{\substack{j=1 \\ j \neq i}}^N \alpha_{3-d}(j) a_{ji} p_j(d) \prod_{s=4-d}^3 b_i(o_s) \tag{9}$$

等等，直到计算出  $\alpha_T(i)$ 。显然，待求的  $P(o|\lambda)$  (即已知  $\lambda$  条件下  $O$  的概率) 可以用  $\alpha_T(i)$  的值表示为：

$$P(o|\lambda) = \sum_{i=1}^N \alpha_T(i) \tag{10}$$

该式与通常的隐马尔可夫模型的计算公式一样。

同样，在 Viterbi 算法中，也考虑进去状态持续时间参数，不单从  $(\pi, A, B)$  三个基本的模型参数推出最佳状态序列，而是结合状态持续时间  $p_i(d)$  这个参数在总体上估计最可能出现的序列。

① 初始化：

$$\delta_1(i) = \pi_i b_i(o_1), \quad 1 \leq i \leq N$$

$$\varphi_1(i) = 0, \quad 1 \leq i \leq N$$

② 递归：加入参数  $p_i(d)$ ，得出  $\delta_t(j)$  和  $\varphi_t(j)$  的迭代计算公式：

$$\delta_t(j) = \max_{1 \leq i \leq N} \sum_{d=1}^D \delta_{t-d}(i) a_{ij} p_j(d) \prod_{s=t-d+1}^t b_j(o_s) \quad 2 \leq t \leq T, 1 \leq j \leq N \tag{11}$$

$$\varphi_t(j) = \arg \max_{1 \leq i \leq N} \left[ \sum_{d=1}^D \delta_{t-d}(i) a_{ij} p_j(d) \right] \quad 2 \leq t \leq T, 1 \leq j \leq N \tag{12}$$

③ 结束：

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)]$$

$$q_T^* = \arg \max_{1 \leq i \leq N} [\delta_T(i)]$$

④ 状态序列求取

$$q_t^* = \varphi_{t+1}(q_{t+1}^*), t = T-1, T-2, \dots, 1$$

由此便可求得  $P(O|\lambda)$  的最佳状态序列：

$$q_1^*, q_2^*, \dots, q_T^*$$

最后，为了得到可变持续时间隐马尔可夫模型的所有变量的重估公式，还需要定义三个前向后向变量，即

$$\alpha_t^*(i) = P(o_1, o_2, \dots, o_t; \text{状态 } S_i \text{ 始于 } t+1 | \lambda) \tag{13}$$

$$\beta_t(i) = P(o_{t+1}, \dots, o_T | S_i \text{ 止于 } t, \lambda) \tag{14}$$

$$\beta_t^*(i) = P(o_{t+1}, \dots, o_T | S_i \text{ 始于 } t+1, \lambda) \tag{15}$$

$\alpha$  和  $\alpha^*$ ,  $\beta$  和  $\beta^*$  之间有如下关系：

$$\alpha_t^*(j) = \sum_{i=1}^N \alpha_t(i) a_{ij} \tag{16}$$

$$\alpha_t(i) = \sum_{d=1}^D \alpha_{t-d}^*(i) p_i(d) \prod_{s=t-d+1}^t b_i(o_s) \tag{17}$$

$$\beta_t(i) = \sum_{j=1}^N a_{ij} \beta_t^*(j) \tag{18}$$

$$\beta_t^*(i) = \sum_{d=1}^D \beta_{t+d}(i) p_i(d) \prod_{s=t+1}^{t+d} b_i(o_s) \tag{19}$$

根据以上定义式和关系式，可以得到可变持续时间隐马尔可夫模型的重估公式如下：

$$\bar{\pi}_i = \frac{\pi_i \beta_o^*(i)}{P(o|\lambda)} \tag{20}$$

$$\bar{a}_{ij} = \frac{\sum_{t=1}^T \alpha_t(i) a_{ij} \beta_t^*(j)}{\sum_{j=1}^N \sum_{t=1}^T \alpha_t(i) a_{ij} \beta_t^*(j)} \tag{21}$$

$$\bar{b}_j(k) = \frac{\sum_{t=1, o_t=v_k}^T \left[ \sum_{\tau < t} \alpha_\tau^*(i) \beta_\tau^*(i) - \sum_{\tau < t} \alpha_\tau(i) \beta_\tau(i) \right]}{\sum_{k=1}^M \sum_{\tau=1}^T \left[ \sum_{\tau < t} \alpha_\tau^*(i) \beta_\tau^*(i) - \sum_{\tau < t} \alpha_\tau(i) \beta_\tau(i) \right]} \tag{22}$$

$$\bar{p}_i(d) = \frac{\sum_{t=1}^T \alpha_t^*(i) p_i(d) \beta_{t+d}(i) \prod_{s=t+1}^{t+d} b_i(o_s)}{\sum_{d=1}^D \sum_{t=1}^T \alpha_t^*(i) p_i(d) \beta_{t+d}(i) \prod_{s=t+1}^{t+d} b_i(o_s)} \tag{23}$$

以上重估公式解释如下：

$\bar{\pi}_i$  是在给定  $O$  的条件下，状态  $i$  成为第一个状态的概率； $\bar{a}_{ij}$  几乎与通常的隐马尔可夫模型相同，只是现在要利用这样的条件，即  $\alpha$  因子中状态在  $t$  结束，而因子中新状态在  $t+1$  开始； $\bar{b}_j(k)$  (假设是离散密度) 是状态  $i$  中产生观测的次数的期望值  $O_t = v_k$  (用状态  $i$  中产生任意观测的次数的期望值来归一化)； $\bar{p}_i(d)$  是以持续时间  $d$  产生状态  $i$  的次数的期望值与以任意持续时间产生状态  $i$  的次数的期望值之比。

#### 4 语音识别具体过程

根据前面对隐马尔可夫模型的介绍，我们可知它是一个双重的随机过程，在语音识别中，这两个随机

过程共同描述了语音信号,其中语音信号某一段的特征由对应状态观测符号的随机过程描述(可观测的),而信号随时间的变化由隐马尔可夫的转移概率描述(不可观测的)。

模型中的状态与语音中的音素或音节等语音单位对应起来,而把语音单位的语音信号特征作为对应语音单元的观测量。

在识别过程中,待识别语音经过话筒变化成语音信号,进行预处理,语音的预处理包括对语音的采样,A/D 转换,预加重,分帧,加窗和端点检测等步骤<sup>[6]</sup>。端点检测就是要将语音信号与背景噪音分开。

接下来是特征参数提取,这里的特征参数应该是相互独立的并且可以有效反应语音本质特征的声学参数,常用的参数有线性预测倒谱参数(LPCC)和 Mel 倒谱参数(MFCC)。

然后是模板的训练,首先要将语音的特征参数矢量量化(VQ),以得到离散的标号。将每个词的特征矢量先用 VQ 技术表示成码本中码字(码矢标号)构成的时间序列。也就是我们在 HMM 中提到的观察序列。而后使用 HMM 第三个问题的解决方法 Baum-Welch 算法对单词的模型进行调整,每次迭代均使  $P(o|\lambda) \geq P(o|\lambda)$ ,直至收敛,训练完毕,存储模型待识别。

最后就是语音的识别,也就是采用上面介绍的 HMM 的第二个问题中的 Viterbi 算法,根据待识别语音的观测矢量序列找出对应的最佳状态序列。

综上所述,语音识别的过程可以概括为

- ① 前向后向算法计算  $P(O|\lambda)$
- ② B-E 算法求出最优解  $\lambda^* = \arg \max \{P(o|\lambda)\}$
- ③ Viterbi 算法解出最佳状态转移序列
- ④ 根据最佳状态转移序列对应的  $\lambda$  给出候选音节或因素
- ⑤ 通过语言模型形成词或者句子

复杂的语音识别问题就是这样通过隐含马尔可夫模型简单地被表述和解决的,让我们不得不感叹数学模型的妙处,隐马尔可夫模型识别系统之所以优于其它系统而被普遍应用,是在于隐马尔可夫模型识别系统中保留了更多训练数据的统计信息,并解决了训练和分类上的困难。

## 5 实验结果与讨论

为了验证 SDHMM 语音识别模型的性能,我们在 Matlab 环境下仿真完成了非特定人孤立字语音识别试验<sup>[7]</sup>。语音信号采样率为 16kHz,16 位采样,语音的帧长是 20ms,帧移为 10ms,状态数为  $N=4$ ,每帧语音参数为 24 维特征向量。

实验采用无噪音环境下 30 个志愿者,其中 15 名男性,15 名女性,每人说 10 组数据,其中 28 人的声音作为训练,2 个人的声音用于测试。

试验分两部分,先用经典的 HMM 进行训练和识别,再用 SDHMM 模型进行训练识别,结果如下表:

实验模型	男声 识别率%	女声 识别率%	平均 识别率%
经典 HMM	90.41	90.95	90.68
SDHMM	91.80	91.85	91.83

结论得出用改进的 SDHMM 模型在数据量较小的情况下识别效果比经典 HMM 有所提高,但是增加了计算量和存储空间,训练识别速度有所下降,且要估计出可靠的参数需要较多的训练数据量才可以做到,模型性能有待完善和优化。

## 参考文献

- 1 韩纪庆,张磊.语音信号处理.清华大学出版社,2004.
- 2 王作英,肖熙.基于段长分布的 HMM 语音模型.电子学报,2004,32(1):46-49.
- 3 姚天任.数字语音处理.武汉:华中科技大学出版社,1992.
- 4 王炳锡,屈丹.实用语音识别基础.国防工业出版社,2005.
- 5 赵力.语音信号处理.北京:机械工业出版社,2008.
- 6 徐惠红,栾方军.基于改进的 HMM 算法的说话人识别研究.微计算机信息,2010,26(8-1):174-175.
- 7 何强,何英.MATLAB 扩展编程.北京:清华大学出版一思想社,2002.
- 8 Ramesh P, Wilpon JG. Modeling state durations in hidden Markov models for automatic speech recognition. Proc. of IEEE I2 CASSP. San Francisco, CA, USA, ICASSP292, 1992,1:381-384.