

以隱藏式馬可夫模型來計算中文簽名驗證系統之動態相似度值

A Method of Measuring Dynamic Similarities for Chinese Signature Verification System Using Hidden Markov Models

林啟芳^{*}@、洪睦偉[@]、張保忠^{**}

Chi-Fang Lin^{*}@, Mu-Wei Hung[@], and Pao-Chung Chang^{**}

[@]元智大學 電機暨資訊工程研究所

^{*}cscflin@saturn.yzu.edu.tw

^{**}中華電信研究所

摘要

在本論文中，我們提出方法，將簽名的速度資料經由 k-means 群聚演算法分類後，統計出個別簽名的最佳化初始值，來建構每個簽名的隱藏式馬可夫模型 (HMM)。再經由 Baum-Welch 演算法 [1] 執行學習及分類後，求出更精確的 HMM。所提方法除了可以大量減少學習時間，並且可以有效的提高簽名辨識率。
關鍵字：簽名驗證，靜態相似度，動態相似度，隱藏式馬可夫模型。

Abstract

In this paper, the Hidden Markov Model (HMM) is constructed for each signer using a set of learning signatures described by the quantized velocities. The Baum-Welch algorithm is utilized for finding the optimal parameters of the HMM. Experimental results are given to reveal the feasibility of the proposed method.
Keywords: Signature Verification, Dynamic Similarity Measure, Hidden Markov Models.

I. 前言

目前被使用來驗證個人身份的方法，包括下列四種方式：(1)核對個人所設定的密碼；(2)比對個人聲音或指紋；(3)比對個人印章；及(4)比對個人簽名 (signature) 資料。(1)法雖然簡便，但缺點是容易遺忘，且有被破解盜用的危險。至於(2)法的缺點則是辨識系統的設置費用高昂，且指紋與(3)法一樣有容易被仿冒盜用的缺點。因此在國外普遍仍採用簽名來代表個人身份特徵的資料。簽名是由一種不加思索的書寫動作所完成的筆跡。這種由長期經驗所累積而成的直覺動作不容易被模仿，因此簽名具有高度安全行性與

不需記憶的優點，且不像印章般有遺失與被偽刻的問題。因此使用簽名來核對個人身份的方法，在未來將會被大量應用在一般的生活上，如電傳手寫系統 (tele-writing system)、電傳銀行的金融交易、大樓門禁、秘密資料的查詢及電子郵件等。

個人的簽名隱含兩種資料能夠用來代表個人的特徵。其一是靜態特徵，如筆跡及筆韻等；另一則是動態特徵，如筆速及筆力等。我們可以根據這兩大類的特徵找出簽名間的相似度，進而判斷它的真偽。但同一個人在不同的時間、地點、環境、甚至心理因素，都會造成簽名特徵的改變。所以必須找出穩定性較佳且具代表性的簽名特徵來加以分類、訓練及比較，進而判斷出簽名的真偽。在實際應用上，簽名辨識系統必須儘量減少真實簽名被系統拒絕的錯誤，即類-I 錯誤(type-I error)，以及偽造簽名被系統接受的錯誤，即類-II 錯誤(type-II error)，以提高系統辨識的可靠度。本論文所要研究的主題，即是利用簽名的速度變化(屬於動態特徵)，提出方法來達成上述要求。

自動簽名辨識系統大致可分為兩類：離線系統與線上系統。在離線系統上所能擷取的簽名特徵較少，對於偽造簽名的辨識比較困難，所以大部分的應用系統都是採用線上系統。後者是利用數位板來書寫簽名資料，因此可以獲得簽名之筆跡、速度、加速度及壓力等變化，可提高辨識能力。以下就過去在線上自動簽名辨識系統上所提方法，做一瀏覽與比較。

Lee, Berger, and Aviczer [1] 從簽名訊號中找出兩組參數，分別為一般參數共 42 個，及經過正規化處理後的參數共 49 個兩個特徵集，利用各個特徵之間的取樣平均值(sample mean)及取樣變異量(sample variance)，分別選出 10 個最具代表性的共同特徵組，由此共同特徵組來進行簽名辨識。Lin and Huang [2] 提出方法，事先將靜態手寫筆跡之相似度計算出來後，將較差的筆劃捨去，而留下相似度較高的筆劃繼續計算出速度曲線的動態相似度，並以動態及靜態相似度的乘積來決定此簽名的真偽。Lin and Chen [3]

利用簽名的下筆點、提筆點及轉折點，做為簽名特徵，使用 A*搜尋法及鬆弛法，找出參考簽名及待測簽名之最佳點配對關係，並利用此配對關係計算出最佳的轉換矩陣，來調整簽名時所產生的大小，旋轉和平移所產生之差異性。另外，Wang and Lin [4]進一步將簽名曲線轉至頻域(frequency domain)，使用傅利葉(Fourier)係數來計算待測簽名與參考簽名間的靜態筆跡曲線與動態速度曲線之相似度值。Yang, Widjaja, and Prasad [5]將每個簽名軌跡經正規化後，計算出其方向角函式，代入隱藏式馬可夫模式(Hidden Markov Model)求出簽名相似度，並使用Baum-Welch演算法來執行學習及分類的工作。所提方法並未使用動態特徵的差異，來決定簽名的真偽。

由於HMM已成功的使用在語音辨識方面的應用，而語音的連續性訊號和簽名動態訊號資料兩者非常類似，因此我們提出方法，依據簽名的速度變化，建構出每個簽名的HMM。經由Baum-Welch演算法執行學習及分類後，求出更精確的相似度值，並使用一臨界值參數來決定簽名的真偽。與前述方法[5]的比較，前者使用簽名的靜態特徵來建構HMM，而我們則是使用簽名動態特徵。簽名動態特徵有不容易被仿冒的優點，但在建構HMM上則困難度較高。

本論文之內容安排如下。第一節我們介紹中文簽名驗證的動機與背景，並對其它簽名驗證系統所使用的驗證的方法作回顧與比較。在第二節裏，我們對隱藏式馬可夫模型作一簡單的介紹，並說明如何將此模型應用在簽名驗證系統上。第三節是對我們所提方法做詳盡的說明。在第四節中以實驗結果來驗證所提方法的可行性。第五節則做一簡單的結論，並討論未來的研究工作及方向。

II. HMMs 觀念介紹及簽名辨識之應用

2.1 HMM 介紹

目前已成功的使用在語音識別技術的隱藏式馬可夫模型，是由統計學及推測學所發展出來的一種模型。利用此模型可同時推導並計算出某種變異量大的訊號資料特徵，並將它模型化。其基本觀念是將某個事件所發生或產生的觀察點(observations)，依照發生的順序集合起來。由觀察點的集合反求可能發生的狀態數，狀態出現的機率，以及觀察點從所對應的狀態下產生的機率等，並將這些參數模型化。以下就HMM的內部參數做詳細的介紹。

- (1) N ：在模型中的狀態數，其標示為 $\{1,2,3,\dots,N\}$ ， q_i 用來表示在時間 t 時，其狀態為 q_i 。
- (2) M ：每個狀態中所產生不同觀察點的數量，其標示為 $V = \{v_1, v_2, v_3, \dots, v_M\}$ ， V 為所有可能出現的觀察點集合。
- (3) A ：狀態和狀態之間的轉換機率，

$$A = \{a_{ij}\}, \text{ 而}$$

$$a_{ij} = P[q_{t+1} = j | q_t = i], 1 \leq i, j \leq N.$$

亦即表示已知在時間 t 為狀態 i 的情況下，在

時間 $t+1$ 為狀態 j 的機率。

- (4) B ：觀察點所產生的機率， $B = \{b_j(k)\}$ ，

而

$$b_j(k) = P[o_t = v_k | q_t = j], 1 \leq k \leq M,$$

$$j = 1, 2, \dots, N.$$

亦即表示觀察點 v_k 在狀態 j 被產生的機率， o_t 表示在時間 t 的觀察點， q_t 則表示在時間 t 的狀態。

- (5) p ：初始狀態的機率， $p = \{p_i\}$ ，而

$$\pi_i = P[q_1 = i], 1 \leq i \leq N.$$

亦即表示第一個狀態為狀態 i 的機率。

將上述的函數成員整合起來後，HMM 完整的表示如下：

$$\lambda = (A, B, p).$$

當HMM準備使用在實際的應用上時，必須要先解決下列兩個問題。

問題一：如果有一組觀察點 $O = (o_1 o_2 \dots o_r)$ 和模型 $\lambda = (A, B, p)$ ，要如何有效的計算出 O 是從 λ 產生的機率，即計算 $P(O|\lambda) = ?$

問題二：如何調整 $\lambda = (A, B, p)$ 的參數，來獲得最大的機率 $P(O|\lambda)$?當有一組觀察點被用來調整 HMM 的參數時，如何做好調整和訓練 HMM 模型參數的工作是困難且具關鍵性的問題。

解決問題一的方法必需靠向前程序與向後程序。而解決問題二的方法必需靠 HMM 參數的重新評估。HMM 的參數重新評估可使用一種反覆的運算程序來逼近最佳值，例如 Baum-Welch 演算法[7]。利用其最大相似度(maximum likelihood)模型參數可求出最佳的 HMM 參數。

在 HMM 內的參數 A ，是由一組馬可夫鏈(Markov chain)所組成的矩陣，而矩陣內的元素就是狀態之間的轉換機率 a_{ij} 。一般最常被採用的是由左至右模型，或稱為 Bakis 模型，如圖 1 所示。使用由左至右的狀態轉換模型在 HMM 裏，矩陣內的元素 a_{ij} 會有下列特性及限制：

$$a_{ij} = 0, \quad j < i \text{ or } j > i + \Delta i,$$

$$\pi_i = \begin{cases} 0, & i \neq 1, \\ 1, & i = 1, \end{cases}$$

$$a_{NN} = 1,$$

$$a_{Nj} = 1, \quad j < N,$$

其中 N 為狀態總數。為了求得更高的辨識率，必須使用同一類型且相互獨立的多組觀察點(例如同一個人的多次發聲或多次簽名)，執行前述所提出的重新評估 HMM 參數流程，找出適合同一類型的 HMM 參數。首先假設共有 K 組觀察點，且狀態的轉換是使用由左至右之狀態轉換模型：

$$O = [O^{(1)}, O^{(2)}, \dots, O^{(K)}].$$

第 k 組的觀察點順序(observation sequence)表示為

$$O^{(k)} = (o_1^{(k)}, o_2^{(k)}, o_3^{(k)}, \dots, o_{T_k}^{(k)}).$$

我們可利用[7]找出整體重新評估後的新參數。

2.2 將 HMM 應用於簽名辨識

本研究著重在動態特徵的分析。為了減低系統的複雜度，所以只使用簽名速度做為參考特徵，如圖 2 所示。因為每筆簽名長度可能不一樣，為了有效解決簽名長度縮放(scaling)的問題，所以必須把數位板傳回的取樣點，依簽名時間順序將其點數平均分配成若干個框架(frame)，並求出每個框架內之平均速度值，經二值劃分法(binary split algorithm)及 k-means 群聚法分類後，成為有限變化的速度分類指標，再把這些指標值按照順序將它集合起來就成為 HMM 模式中的觀察點順序。如圖 3 所示。

按照離散式 HMM 模型及由左至右狀態轉換模型的特性，建構初始狀態轉換機率矩陣，並且指定初始狀態為第一個狀態。根據矩陣內的狀態轉換機率，及利用 k-means 群聚法分類加以統計後，可求出每一個觀察點在某時間狀態下產生的機率。

收集同一個簽名者之若干次簽名，使用上述方法並個別的取出其分類速度指標值後，重新建立並且重覆的訓練，找出最佳化也是最具個人簽名速度特徵的 HMM 模式，並將它存入參考資料庫。當簽名者下次欲進入系統時，系統必須計算出目前的簽名資料與其相對應的 HMM 模式之間的相似度值，進而判斷該簽名者之真偽。

III. 所提方法

HMM 模型最重要的特性就是可同時解決分類問題(classification problem)和訓練問題(training problem)。這也是本研究採用 HMM 的原因之一。以下各節中，我們將詳細說明如何利用 HMM 來辨識出簽名真偽的方法。

3.1 擷取觀察點

完整的簽名辨識系統至少必須含有下列兩個步驟：學習階段(learning stage)及驗證階段(verification stage)。首先在學習階段中，收集若干名簽名者的簽名。依照簽名者姓名順序存入個人簽名資料庫中，所存放的資料是簽名者在簽名時，從數位板傳回的座標值 $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ 及傳回座標值時的系統時間 $\{t_1, t_2, \dots, t_N\}$ ， N 為某簽名者的簽名總點數。經由下式的計算後可求得整個簽名的速度曲線 $\{v_1, v_2, \dots, v_N\}$ ：

$$\begin{cases} v_n = \frac{\sqrt{(x_n - x_{n-1})^2 + (y_n - y_{n-1})^2}}{t_n - t_{n-1}}, & 2 \leq n \leq N, \\ v_n = 0, & n = 1. \end{cases}$$

因為每個簽名的長度(由數位板傳回的總點數)不一樣，為了避免產生縮放(scaling)的問題，必須將每個簽名的總點數平均等份為 T 個框架(frame)，如圖 3(c) 中的縱向格線，而 T 就是 HMM 所定義的觀察點長度(observation length)。假設第 i 個框架內有 f 個取樣點，則該框架內的平均速度為 $V_i = (V_{n+1} + V_{n+2} + \dots + V_{n+f})/f$ 。執行上述程序後，每

個簽名檔就被量化成 T 個速度值 V_1, V_2, \dots, V_T ，如圖 3(c) 中的橫向短線。但是量化後的單點速度值會有無限多變化，必須將簽名料執行上述量化的程序後，再使用二值劃分法及 k-means 群聚演算法把所有的量化速度值分為 M 類，如圖 3(c) 中有灰階漸層的區域。也就是每個量化速度值會相對應到一個類別指標值 I ， $I = 1, 2, \dots, M$ 。因此每筆簽名資料最後即被轉換成 T 個類別指標序列 (I_1, I_2, \dots, I_T) 。

3.2 建立 HMM 參數

根據離散式 HMM 的特性，初始狀態轉換機率矩陣 A 內的狀態轉換機率 a_{ij} ，觀察點在特定狀態發生的機率 $b_j(k)$ ，及狀態數 N 並沒有一種固定的數學公式或規則可循，必須靠經驗來自行設定。因為簽名是一種習慣性的固定行為，為了使得我們所建立的 HMM 更能代表個人的簽名行為，所以使用由左至右模型，因此是從第一個狀態開始執行，也就是 $\pi_1 = 1$ ，其他狀態出現的初始機率則為 0。而 a_{ij} 的初始值我們則是利用平均值的方法求出，也就是每個非零的(有效的)元素值等於該列非零元素值數目的倒數。

除了 π 和 A 參數外，HMM 中最為重要的則是 B 參數。根據實際的實驗顯示，使用離散式 HMM 時， $b_j(k)$ 如果能找到適當的初始值，可以更有效率的建構出正確的 HMM，不僅大量減少重覆學習的次數，亦可以得到更精確的辨識率，所以如何找出 $b_j(k)$ 的最佳值是本研究之重點之一。

依照正常的簽名方式，每一筆劃的出現是有一定順序性的，所以我們假設每 R 筆筆劃的發生就是一個狀態，而一筆劃的內容就是前述 3.1 節內所提到的，先求出一個框架內所有取樣點的平均速度，再轉換成速度類別指標值 I ， $I = 1, 2, \dots, M$ 。假設每筆簽名速度資料被分配為 T 個框架，也就是 T 個觀察點，每個觀察點有 M 種變化，每個狀態則包含有 R 個觀察點。挑選出一個簽名者所簽下的 Q 組學習用簽名資料，則可利用下列式子預先統計出 $b_j(k)$ 如下：

$$O^{(q)} = [I_1^{(q)}, I_2^{(q)}, I_3^{(q)}, \dots, I_t^{(q)}, \dots, I_T^{(q)}] \quad (1)$$

$$\begin{cases} W(I_t^{(q)}) = 1, & \text{if } I_t^{(q)} = k \\ W(I_t^{(q)}) = 0, & \text{otherwise} \end{cases} \quad (2)$$

$$b_j(k) = \frac{\left[\sum_{q=1}^Q \sum_{r=0}^{R-1} W(I_{t+r}^{(q)}) \right]}{Q * R}, \quad (3)$$

其中 $q = 1, 2, \dots, Q$, $t = 1, 2, \dots, T$, $k = 1, 2, \dots, M$ ，及 $j = T/R$ 。

(1)式的 $O^{(q)}$ 表示第 q 組學習簽名之所有速度類別指標值集合， $I_t^{(q)}$ 表示第 t 個觀察點的類別指標值。(2)式中的 $W(I_t^{(q)})$ 則表示出每個觀察點的類別指標加權值。因為我們已經假設每 R 個的觀察點的發生相當於一個狀態，為了要計算出第 k 類的類別指標值在該狀態發生的機率，必須先計算出屬於該狀態中第 k 類

的指標值個數，所以使用 $W(I_i^{(q)})$ 來表示 $I_i^{(q)}$ 是否等於第 k 類的指標值。如果相等則標記為 1，否則標記為 0，表示 $I_i^{(q)}$ 不屬於第 k 類的指標值。(3)式則實際計算出第 k 類指標值在第 j 個狀態發生的機率。分母部份表示先計算出第 q 組簽名中，屬於第 j 個狀態的所有觀察點的加權值總和，然後再累加所有簽名的加權值總和，就可以求出屬於該狀態中第 k 類的指標值個數。分子部份則是計算出所有屬於第 j 個狀態的所有觀察點數。經由(3)式的計算後即可非常精確的預測出 $b_j(k)$ 值。

如果我們假設一筆筆劃(無論是落筆或是提筆軌跡)的發生就是一個狀態，相當於一個狀態對應到一個觀察點，(3)式則可以簡化為：

$$b_j(k) = \frac{\left[\sum_{q=1}^Q W(I_i^{(q)}) \right]}{Q} \quad (4)$$

由上述方法即可建立初始的 HMM 模型 λ ，利用 Baum-Welch 演算法重新找出新的 $\bar{\lambda}$ ，並由下列判斷式來決定是否要繼續重覆做評估的工作。如果計算出屬於個人全部簽名的整體相似度偏低，則代表我們所評估的 HMM 不適合此人的簽名模式。必須再重覆執行 Baum-Welch 演算法，重新做整體簽名評估的工作，直到找出更適合的 HMM 參數，並完成該簽名者的參考簽名資料庫。判斷式如下：

$$\begin{cases} \text{繼續評估且 } P(O|\lambda) = P(O|\bar{\lambda}), & \text{if } P(O|\bar{\lambda}) - P(O|\lambda) \geq \varepsilon. \\ \text{停止評估}, & \text{otherwise.} \end{cases} \quad \text{上式}$$

中 ε 代表一個臨界值，也就是當 $P(O|\bar{\lambda}) - P(O|\lambda) < \varepsilon$ 時，表示 $\bar{\lambda}$ 已經近似最佳的 HMM，不需再做多餘的運算，減少執行評估的時間。

3.3 利用 HMM 執行簽名驗證

當使用者欲進入本系統前，必須先表明身份，例如輸入自己的姓名或 ID 值，系統就會根據所輸入的姓名或 ID 值從資料庫中找出其相對應於這個名字的 HMM，準備執行驗証的工作。當使用者簽完名後，系統就將其簽名檔經由 3.1 節所提出的方法求出待測觀察點集合順序 O_{test} ，代入屬於此人的 HMM 模型 λ_{ref} 後算出 $P(O_{test}|\lambda_{ref})$ ，也就是求出待測簽名與參考簽名之間的相似度 P 。當待測簽名的 P 值高於我們所定訂的臨界值時，則代表待測簽名與參考簽名之間的相似度有著較高的相似度。如果同一個人的簽名所算出的 P 值低於一個臨界值而被系統拒絕，就會產生類-I 錯誤。非同一個人簽名所算出的 P 值卻高於臨界值則會產生所謂的類-II 錯誤。

IV. 實驗結果

我們共收集了 10 名女性及 40 名男性，每個人各簽下 30 筆自己的名字(即總共簽下 1500 筆個人簽名)，其中 10 筆用來學習並且建立屬於個人的 HMM 模型，另外的 20 筆則是用來測試及訂定臨界值。我

們另外收集模仿上述 50 個本人簽名者的 1000 個模仿簽名，也就是每個測試者的簽名資料庫中除了存有 30 筆本人簽名資料外，還有 20 筆偽造簽名。偽造簽名的模仿方式是限定在靜態熟練性(statically skilled)的偽造簽名[1]。也就是偽簽者除了知道被偽簽者的姓名外，亦持有被偽簽者的簽名筆跡。然後依照此筆跡在紙上及數位板上練習過後，再將偽造簽名輸入系統內進行比對。

為了提高本系統的辨識率，必須找出 HMM 中所有參數的最佳值。其中影響最大的是 HMM 初始值設定的方法。如果 HMM 的初始值是以亂數設定，在重覆學習的過程中收斂情形很差，疊代次數會相對的大量增加，浪費學習時間。如果使用前述 3.2 節所提的方法(分類統計法)，則可以在極短的時間內找出最佳的 HMM，大量減少疊代次數。使用分類統計法設定 HMM 的初始值除了可以減少學習時間外，更可以明顯的提高辨識率。由實驗結果得知，在固定類-I 錯誤的條件下，類-II 錯誤率最高可以減少 20%。由此證明我們利用前述 3.2 節提出的方法，可找出 HMM 中較佳的初始值。

如前所述，我們將簽名資料分為含提筆軌跡及不含提筆軌跡兩種，以便觀察這兩種簽名資料對於辨識率的影響。結果顯示當簽名含有提筆軌跡資訊時，更能代表個人的簽名特徵。亦即更加提高真實簽名與偽造簽名之間的差異，進而降低類-I 與類-II 錯誤發生的機會。另外，我們也觀察到當觀察點的數量(frame number)增加時，含提筆軌跡資料與不含提筆軌跡資料的辨識率差異程度會逐漸的降低，也就是提筆軌跡資料的重要性會相對的減低。但是觀察點數量愈多，學習時間就會急遽增加，因此觀察點的數量必需加以限制。

為了找出中文簽名筆劃，觀察點數量及狀態數三者之間對於整體辨識率的影響，我們假設每個狀態只包含一個觀察點(但實際上每個狀態可以包含若干個觀察點)。根據上述假設，將每筆簽名資料分別平均分成 10~80 個觀察點後(即 10~80 個筆劃數)，分別求出每組簽名(本人之測試簽名及偽造簽名資料)的最佳臨界值後，再計算出所有簽名資料的辨識率。也就是各別求出本人簽名被系統接受的機率及偽造簽名被系統拒絕的機率。所得結論是當觀察點數為 60 的時候，所獲得的結果最佳。另外實驗結果顯示，無論觀察點的多寡，只要是狀態數近似於觀察點數時，即可在固定類-I 錯誤的條件下，大量的減少類-II 錯誤。

因為我們所採用 HMM 是由左至右的結構，所以由目前狀態至下一個狀態的跳躍數，必須要考慮其對整體辨識率的影響。由實驗得知，當狀態跳躍數大於 1 時，類-II 錯誤就會偏高，特別是當觀察點數較少時，此現象會更為明顯。原因是當一筆簽名資料被分成較少的框架數時，在狀態數幾乎等於觀察點數的條件下，狀態數也會相對的減少。由於簽名是屬於一種順序性極高的動作，如果設定一個較為穩固的狀態轉移條件，也就是狀態跳躍數愈少時，愈能代表該筆簽名資料的特徵。但是如果狀態數增加時，可能必須視

實際的應用，設定一個較寬鬆的狀態跳躍轉移條件。例如，當觀察點數增加為 60，而類-I 錯誤設定在 10% 以上時，並且狀態跳躍數等於 1 的條件下，類-II 錯誤最小。當類-I 錯誤設定為小於 10%，狀態跳躍數等於 2 時，可得到最小的類-II 錯誤。

另外會影響到系統整體辨識率的重要參數是 3.1 節中所提到的量化速度值的分類數。也就是在每個狀態中，可能產生觀察點的種類數。由實驗結果得知，當觀察點數量減少時，則需要增加可能發生的觀察點種類數量，以彌補觀察點數的不足，如此才有可能減少錯誤的辨識率。

根據以上的實驗結果，我們訂定出 HMM 的最佳化相關參數及設定條件如下：

- (1) 以分類統計法設定 HMM 之初始值；
- (2) 學習時必須包含提筆軌跡資料；
- (3) 觀察點數(frame number) = 60；
- (4) 狀態數(state number) = 59；
- (5) 量化速度值分類數(symbols per state) = 16；及
- (6) 狀態跳躍數(state steps) = 1。

利用上述所定出的相關參數及設定方式，在找出整體最佳化的參數及條件後，所得到的類-I 與類-II 錯誤，與[1]所提出使用 10 個最具代表性的共同特徵所求得的結果，比較起來前者有較佳的表現，如圖 4 所示。

V. 結論

在建立一個簽名驗證系統時，最主要也最難解決的問題就是簽名者本身的不穩定性，特別是要取得最能代表個人簽名的動態特徵。隱藏式馬可夫模型(HMM)正好可以解決這方面的問題，因為它可以將每個簽名者的動態簽名特徵加以模型化，並且經由重覆訓練後求得更精確的模型參數，藉以判別待測簽名的真偽。在本篇論文當中，只使用簽名速度做為特徵值，並且找出簽名筆劃、觀察點數及狀態數三者之間的對應關係。經由分類統計的方法直接設定最佳的 HMM 初始值，取代以亂數設定的方式。除了大量減少系統學習時間外，並且可以同時減少類-I 及類-II 錯誤。在建立 HMM 時，並且考慮到提筆軌跡對於整體辨識率的影響。實驗結果顯示我們所提的方法確實提高了簽名驗証系統的正確性。

參考文獻

- [1] L. L. Lee, T. Berger, and E. Aviczer, "Reliable on-line human signature verification systems," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 18, No. 6, 1996, pp. 643-647.
- [2] C. F. Lin, and C. C. Huang, "On-line Chinese signature verification system," *Proc. of National Computer Symposium 1993*, Chiayi, Taiwan, pp. 866-874.
- [3] C. F. Lin; and C. W. Chen, "A new approach to the verification of Chinese signatures with

different orientations and scales using relaxation and A* algorithm," *1994 IPPR Conference on Computer Vision, Graphics and Image Processing*, Shan-Lin Sea, Taiwan, R. O. C., pp. 153-161.

- [4] Z. Wang, and C. F. Lin, "An accurate method of measuring static and dynamic similarities for Chinese signature verification system using Fourier descriptors," *Master Thesis*, Yuan-Ze Institute of Technology, Taiwan, R.O.C., 1996.
- [5] L. Yang, B. K. Widjaja, and R. Prasad, "Application of hidden Markov models for signature verification," *Pattern Recognition*, Vol. 28, No. 2, 1995, pp. 161-170.
- [6] P. C. Wen, and L. L. Wang, "Identification of technical journals based on hidden Markov models," *CVGIP*, Taiwan, R.O.C., 1996. pp. 400-407.
- [7] L. Rabiner, and B. H. Juang, "Foundamentals of speech recognition," *Prentice Hall*, 1993.

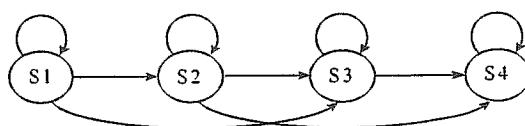
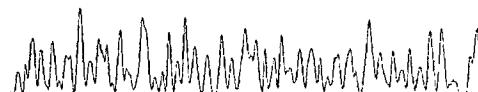


圖 1、Bakis 模型(含有 4 個狀態)。

(a) 靜態簽名筆跡。



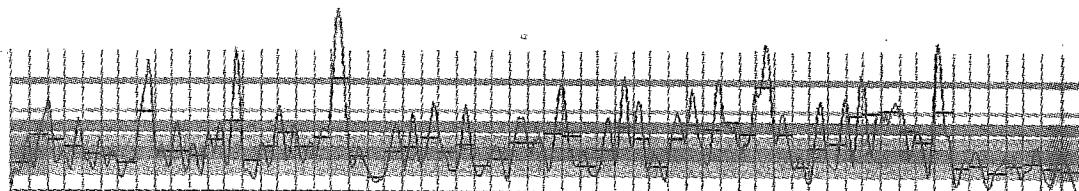
(b) 對應(a)之速度曲線。

圖 2、簽名速度曲線。

(a) 全部的靜態簽名軌跡(顏色較淡的為提筆軌跡)。

(b) 提筆軌跡。

圖 3、將簽名資料轉換為 HMM 所使用的觀察點集合順序。



(c) 對應於(a)之量化後的速度曲線及類別指標值分類情形。

圖 3 (續)、將簽名資料轉換為 HMM 所使用的觀察點集合順序。

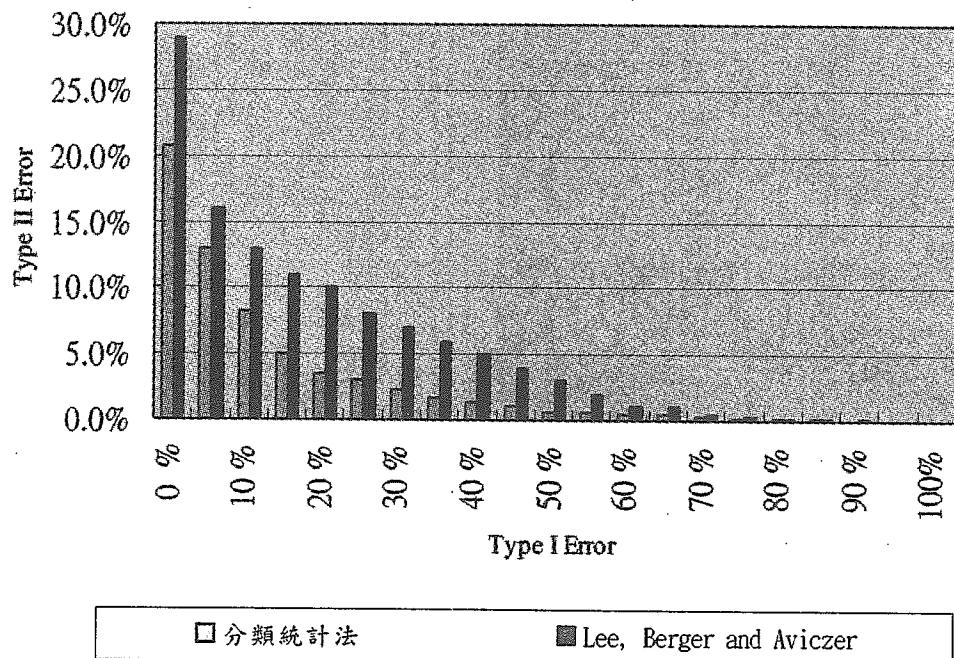


圖 4、分類統計法(我們的方法)與 Lee[1]等所提方法之類-I 及類-II 錯誤率比較圖。