

# 應用於慢跑運動之智慧型音樂播放系統

陳建逸

國立屏東科技大學  
資訊管理系  
碩士生

M9656036@mail.npust.edu.tw

謝顯孟

國立屏東科技大學  
資訊管理系  
碩士生

M9756014@mail.npust.edu.tw

劉寧漢\*

國立屏東科技大學  
資訊管理系  
助理教授

gregliu@mail.npust.edu.tw

## 摘要

在現代這個社會環境中，工作環境所產生的壓力、快速的生活步調，多種文明病和心理方面的疾病，已經隨著這種緊張又忙碌生活方式悄悄的蔓延到現代人的身上，大家也開始注意到健康的重要性。而擁有健康的身心，儼然成為國人一個基本追求的生活指標，並成為一種生活形態，不被工作和生活的壓力追著跑。

本研究將音樂與慢跑運動結合，讓使用者在進行慢跑運動的時候，能夠推薦給使用者喜愛的音樂，並符合使用者當時的運動節奏，讓音樂與人的律動能夠一致。

**關鍵詞：**慢跑、音樂推薦、C4.5 決策樹

## 1. 前言

隨著現在生活步調快速，工作環境所產生的壓力造成多種文明病與心理方面的疾病，緊張又忙碌生活方式悄悄蔓延至現代人的身上，由許多醫療案例中，社會大眾開始注意自我健康的重要性，因此擁有健康的身心，不被工作和生活的壓力追著跑，儼然已成為國人一個基本追求的生活指標，並成為一種新的生活形態。

而台灣已漸漸邁入高齡化的社會，龐大的醫療負擔，也正慢慢侵蝕國家的資本，老年化已經是台灣一個需要高度重視的問題。除了高齡化的問題產生之外，肥胖亦是成為國人生活中一個關於健康的隱憂。肥胖者常見的心臟病、\*高血壓、腎上腺、甲狀腺內分泌問題等疾病，若持續保持肥胖的狀態，則可能產生一些嚴重的症狀，像是心血管疾病、肝功能衰退、慢性糖尿病、膽固醇過高等問題。

而缺乏運動容易帶來身體上的疾病，近年

來有個較常出現的醫學名詞『代謝症候群』，慢慢的在各個醫療院所中出現，並漸漸的爬上國人的疾病排行榜，成為國人所要面臨的一個新的問題。代謝症候群所指的是一群代謝異常的組合，包括有高血壓、高血糖、血脂異常與肥胖。

而由許多運動項目評估過後，慢跑為最經濟、方便、有效率，且不受空間、時間、性別和年齡限制的一項運動，只要養成慢跑的習慣，使其成為一項終身運動，常常走出戶外去慢跑，對自己的身體健康將會有很大的幫助，也可進而降低國家的醫療負擔，對整個社會成本也可以大幅的降低，更提高自己的生活水準。

每個人都知道適度的運動能有效地幫助身心成長，但要讓慢跑成為一項有規律且持續性、計畫性的運動，卻不是一件很容易的事。大部分的人在慢跑的同時，常常感到無聊，並且不能持續地維持此習慣。據研究指出，一個健康的成年人的運動強度要達到最大心跳的55-90%，再加上每週運動3-5天，每次運動時間至少要達20分鐘，則可達到身體熱量上的消耗，由上推估，若要增加熱量的消耗，則需持續增加其運動時間並長時間維持此習慣，即可達到運動的目的，由許多報導指出，若慢跑運動要達有效性並且可見其成果，最少需持續三個禮拜維持此運動習慣即可達成。

而手機的發展也日新月異，特別為智慧型手機，近年來，一般的手機可以上網已經成為一種必要的趨勢，而在智慧型手機上更是紛紛的加入了許多功能，例如GPS、三軸加速規、3.5G、音樂播放、高畫素的相機等功能。對使用者而言，手機已經脫離了原本通話的特性，轉而成為另一種生活中很方便的工具。

由上述可發現運動對身體之重要影響性，但一般人卻常因許多外在因素，以致無法維持其習慣，因此本研究計畫將音樂與慢跑運動結合，再搭配智慧型手機上G-sensor感測器擷取

---

\* 為通訊作者

使用者當下的運動節奏，當使用者進行慢跑運動，能夠依照使用者的喜好推薦合適的音樂給予使用者，讓音樂的節奏與人的律動能夠一致，以達到使用者因其推薦之音樂，達到運動之持續性。

為了要達到推薦的音樂能更貼近使用者的運動情形，我們觀察到跑步的速度變化若能與系統所推薦播放的音樂時間長短相同或者接近，對於使用者在接受推薦的音樂上能有一個正向的提升，在跑步時也可以減少換歌的機會，讓運動情形更順暢，在此系統內利用隱藏式馬可夫演算法，對使用者的跑步速度變化進行預測。

## 2. 相關文獻

### 2.1 運動與音樂相關研究

音樂節奏律動是人類的共同語言，當本研究聽到節奏分明的音樂或是聲響時，都會忍不住的隨著節奏一起律動，不管是用手腳打著拍子或是肢體自然的跟隨著節奏擺動，都一一表現出大腦接收到音樂節奏而產生之情緒波動，而一段好的音樂可以讓人身心舒緩、調劑身心，並提高人在運動中的表現。

若把音樂對於運動員在運動的情境下，起源在於聽音樂時所得到的效益，其效益[6]如：(1)使正向積極的情緒增加，減少負面消極的情緒(2)可以提前熱身或放鬆的效果(3)脫離不愉快的感覺，像是疼痛或疲勞(4)在增氧運動訓練過程中，減少體力耗盡的程度(Ratings of Perceived Exertion, RPE)(5)在音樂跟運動同步的狀況下可擴展成果產出(6)當節奏或是聯想和相關的運動模式符合，可增加相關運動技能的獲得(7)增加運動員達到目標流暢狀態的可能性與(8)藉由上述的機制使成績增加。

2008年北京奧運上，勇奪8面金牌的美國游泳名將麥可·弗雷德·菲爾普斯二世(Michael Fred Phelps II)，在比賽前有一個經典動作，他在比賽前總是戴著 i-Pod 的白色耳機聽著音樂，漫不經心的做著熱身運動，當脫了衣服進游泳池後，他即時的脫下耳機，此時大約距離比賽前兩分鐘，每場比賽皆是如此。一直到他得到了8面金牌，破了奧運史上同屆個人最多金牌的記錄，大家開始猜測音樂能否在運動中帶來的出色表現[1]。

德國萊比錫馬普(Max Planck)學院的人類認知和腦科學專家斯蒂芬·考爾思克博士經過

研究，推論菲爾普斯賽前所聽的音樂是他奪金的主要關鍵，並可以當作是一種無形的興奮劑，這個結論基於的事實是，某種節奏的音樂可以提高運動員的呼吸頻率以及血紅蛋白攜帶氧的數量。儘管運動循環的過程中產生額外氧氣所持續的時間沒有定論，但藉由有人專為菲爾普斯量身設定之音樂而能提高其比賽成績。

在慢跑運動中常會遇到一個人單獨跑步過於無趣，而兩人同時跑步又因每個人體能不同而導致慢跑速度難以配合，由統計調查[8]中發現，若聲音能夠透過手機或可攜式裝置，便能夠激勵慢跑運動者，使其更有效率地進行跑步運動，若是此激勵能夠有回應與互動，那在慢跑運動中便能夠幫助使用者在慢跑運動上有更好的表現。

現在也有越來越多MP3音樂播放器與慢跑運動結合，像是APPLE公司所生產的i-Pod與運動大廠NIKE公司合作，推出了在i-Pod上使用的慢跑運動套件—NIKE Plus[5]。當使用者進行慢跑運動的過程中，可將感測器放置在專為此系統設計的慢跑鞋當中，當使用者進行慢跑運動的同時，i-Pod將透過感測器回傳的資料，記錄使用者所跑的速度、距離、消耗的卡路里等資料，並透過語音回傳資料給使用者，當使用者在進行跑步運動時，若是覺得無力以繼，則可透過操控i-Pod來播放自行設定的PowerSong，以振奮精神和體力。在跑步結束後，可透過NikePlus.com的網站，上傳個人跑步資料，也可在網站上安排跑步訓練模式。

SONY也有推出與慢跑相關，並具有動態感測的MP3播放器—NW-S203F[9]，其可偵測使用者跑步的速度、距離、和所消耗的卡路里，並可在運動模式下編輯播放清單，當使用者在跑步的同時，在WALK和RUN的模式下進行不同的音樂播放，也可以透過設定目標，如距離或消耗的卡路里，當目標達到後即停止播放音樂。

### 2.2 C4.5 決策樹

#### 2.2.1 分類學習法(Classification Learning)

分類學習法(Classification Learning)是一種常被應用在機器學習領域的一種學習方法，資料探勘中決策樹(Decision Tree)已是常被用到的其中一種分類學習技術，一般在資料分析或預測方面，會透過每個節點中將資料集作測試，來達到分類分析的目的，所謂分類

(Classification)即是根據已知的類別屬性，對資料集來建立分類模型，並可利用它來預測新進資料或未知資料的類別，其中以Quinlan在1986年所提出ID3分類樹演算法較為常見，此演算法在分類樹的應用上已有相當不錯的表現，在1993年時更針對ID3無法處理連續性數值的缺點上作進一步地改進，提出C4.5分類學習演算法。

## 2.2.2 ID3 分類學習法

ID3分類學習法因能產生精簡的決策樹，其目的是選擇最佳的屬性來當作節點，使建構出的決策樹能呈現或接近最簡單狀態，且在計算空間成本均小的情況下，已被廣泛運用在許多領域[2]。但ID3只適用在處理屬性值項數較少的名目屬性(Nominal Attributes)，對於屬於連續數值的資料集，尤其當同時存在有連續性數值與多值的資料集應用，容易造成節點與分支過多，降低分類能力。

ID3的核心演算法，乃是以資訊理論為基礎，設法讓變數間比較的次數最小化，主要以資訊增益(Information Gain)作為選擇最佳屬性的分割變數 (splitting variable)，並在決策樹上的各級節點選擇屬性。其利用熵函數來量化資訊，對資料的不確定性進行測量，如果所有的資料屬於同一類別，不確定性將不存在，熵值則為0。

ID3演算法的基本步驟包含以下幾點[3]：

1. 由訓練樣本開始訓練模型，若樣本屬於同一類別，則節點成為樹葉並使用該類別的標籤。
2. 若然樣本不屬於同一類別，演算法則使用資訊增益來選擇將樣本最佳化分類的變數，該變數則為該節點的分割變數。對分割變數的每個已知值皆產生一個分支，並以此值進行分割樣本。
3. 在演算的過程中，每個分割的樣本決策樹逐次形成。假如一個變數出現在一個節點上，則接續的分割時便不考慮該變數。
4. 當所給的節點上所有樣本屬於同一類別，或者沒有剩餘變數可進一步用來分割樣本，此時便可停止分割，決策樹的建構便完成。

ID3分類演算法的優點如下：演算法的理論清晰且方法簡單，學習能力強；缺點：分類時會偏向選擇分出較多類別的屬性值，造成當分割後會有劃分較小的類別或只有一個類別

的情況，則其分割後的熵值(Entropy)為零，所獲得的資訊增益量值也最大。這會造成決策樹分支過大，且會有過度學習的問題發生。因此，Quinlan[7]又提出C4.5演算法。

## 2.2.3 C4.5 分類學習法

C4.5分類學習法改良自ID3而來。主要以資料為導向，當測試一個連續數值屬性時，是屬於「由上而下的決策樹歸納法」，在建構決策樹時，是採用監督式訓練學習。C4.5演算法是先建立一棵完整的決策樹，並由增益率(Gain Ratio)分岔準則來挑選最佳屬性，之後以二元分割方式建出決策樹根節點(Root Node)及內部節點(Internal nodes)，為避免資料中含有雜訊或有資料不完整情況，在建完C4.5決策樹後會對產生的樹進行分支修剪(Prune)，修剪時會藉由預估錯誤率的計算評斷每個子樹節點與葉節點的錯誤率。修剪後的樹，可得到最精簡且錯誤率又不會過高的決策模型。

C4.5分類學習法與ID3最大不同在於它能夠處理資料集中帶有連續性數值屬性，其演算法對於連續數值屬性處理的流程如圖所示，我們將透過以下步驟分述決策樹建置過程。




圖 1 c4.5 對連續數值屬性之處理流程

C4.5在決策樹的每個節點上使用資訊增益量(Information Gain)來選擇測試屬性，選擇具有最高資訊增益量(或最大entropy壓縮)的屬性作為當前節點的測試屬性。假設 $S$ 是 $s$ 個資料樣本的集合，類別標籤屬性具有 $m$ 個不同值，定義 $m$ 個不同類 $C_i(i=1, \dots, m)$ ，設 $s_i$ 是 $Z_i$ 的樣本數。對一個給定的樣本分類所需的期望資訊由下式計算出[6]：

$$I(S_1, S_2, \dots, S_m) = - \sum_{i=1}^m p_i \log_2(p_i) \quad (1)$$

其中 $p_i$ 是任意樣本屬於 $Z_i$ 的機率，利用 $s_i/s$ 來估計。

假定屬性 $A$ 具有 $n$ 個不同的值 $s_i\{a_1, a_2, \dots, a_n\}$ ，則屬性 $A$ 可將 $S$ 劃分為 $n$ 個子集合 $\{S_1, S_2, \dots, S_n\}$ ， $S_{ij}$ 為 $Z_i$ 在子集合中 $S_j$ 的樣本數，則可計算該組資料的熵值(Entropy)：

$$E(A) = -\sum_{j=1}^n \frac{S_{1j} + S_{2j} + \dots + S_{mj}}{S} \times I(S_{1j}, \dots, S_{mj}) \quad (2)$$

其資訊增益量是將訓練資料的集合 $S$ ，在分割前的分類函數所求的值，減去每個屬性的特性所求得的熵分類函數，熵值越小，子集合所劃分的純度越高，其資訊增益量 (Information Gain) 為：

$$Gain(S, A) = I(S_1, S_2, \dots, S_m) - E(A) \quad (3)$$

利用演算法計算每個屬性的資訊增益量，將具有最高資訊增益量的屬性選作給集合 $S$ 的測試屬性，再建立一個節點，並以此屬性標記之。對屬性的每個值建立分枝，並根據此來劃分樣本。

### 2.3 隱藏式馬可夫模型 (Markov Hidden Model)

隱藏式馬可夫模型[4]是一種雙重的隨機模型，而其中有一組隨機過程的模型是隱藏的，故稱為隱藏式。HMM在60年代後期被提出，早期因訓練模型需要耗費大量的計算，因此較少被拿來應用，直到後期因有較佳的訓練方式，此方法才漸漸受到重視。隱藏式馬可夫模型的特性在應用時能用到時序上的資訊，在時間有先後關係的資料辨識上有著顯著的優勢。目前在語音辨識上已經有相當多的研究，也有傑出的表現，近年來因多媒體的需求日益加增，也有大量的研究和應用在影片、影像的辨識上。

隱藏式馬可夫模型是由馬可夫鏈所延伸出來，在一個馬可夫鏈中能經由統計 $t$ 個時間觀測序列 (Observation Sequence) 的觀測值，能預測當時時間點在 $t+1$ 的時候，該序列的狀態為何。在馬可夫鏈的中，所觀測的對象其狀態是已知、能直接量測到。但是在現實狀態中，觀測序列的狀態有時是無法從觀測或直接量測所得到，例如跑步中身體的自身反應狀態是亢奮或是疲憊，無法由單從跑步中量測，我們只能量測到跑步的速度變化情形，若要用馬可夫鏈便無法進行預測。

在隱藏式馬可夫模型中便可針對此類型的狀況所延伸出來的模型，而一個隱藏式馬可夫模型的特性的描述可用下列的參數來定義：

#### 隱藏狀態集合 (Hidden State) $H$

$$H = \{h_1, h_2, \dots, h_s\} \quad (4)$$

$s$  為隱藏狀態的個數，無法直接被觀測到狀態的個數，在本研究中為使用者跑步自身的

狀態變化。

#### 隱藏狀態移轉機率 $A$

$$A = \{a_{ij}\}, i \geq 1, j \geq S \quad (5)$$

隱藏狀態的轉移機率主要是因我們無法直接觀測到在時間軸上的轉移機率 $a_{ij}$ ， $a_{ij}$ 主要在表示時間點 $t$ 時的隱藏狀態為 $h_i$ 時，在時間點 $t+1$ 為 $h_j$ 時的機率，可表示如下：

$$a_{ij} = P[q_{t+1} = h_j | q_t = h_i], \quad (6)$$

其中  $a_{ij} \geq 0$  且  $\sum_{j=1}^S a_{ij} = 1$

#### 觀測值種類 $V$

$$V = \{v_1, v_2, \dots, v_M\} \quad (7)$$

指的是當在隱藏狀態下在量測的樣本裡所定義的情況，在本論文中我們將 $V$ 值定義為跑步速度的變化。

#### 量測樣本值機率分佈 $B$

$$B = \{b_j(k)\}, 1 \leq j \leq S, 1 \leq k \leq M \quad (8)$$

樣本值的機率分佈 $b_j(k)$ 指示的在時間點 $t$ 上，隱藏狀態 $S_j$ ，所產生出 $v_k$ 的機率。

初始狀態機率分佈 $\pi$ 要可由上述多個參數定義而成

初始機率分佈定義為當開始量測時處於某隱藏狀態的機率。

$$\pi = \{\pi_i\}, 1 \leq i \leq S \quad \text{且} \quad (9)$$

$$\pi_i = P[q_i = h_i], 0 \leq \pi_i, \sum_{i=1}^S \pi_i = 1$$

隱藏式馬可夫模型主要是由上述多個參數定義而成，主要可由 $A$ 、 $B$ 、 $\pi$ 來決定HMM的特性，可以用下列來表示：

$$\lambda = (A, B, \pi) \quad (10)$$

### 2.3.1 正向 (Forward procedure) 與逆向 (Backward procedure) 程序

瞭解HMM主要的組成後，可用最原始的方法將序列可能產生的路徑機率加以計算，再將所有的機率加總，以求得最佳解。但若時間越長，序列的長度也越長，計算量也會相對的增加。因此需要使用方法來統計所量測樣本序列的機率值，一般再預測會有正向程序 (Forward procedure) 與逆向程序 (Backward procedure) 來計算所量測序列在模型上可能路徑的機率總和，對於一個觀測序列

$O=o_1, o_2, \dots, o_t$ ,  $o_t \in V$ , 可將機率值  $P(O|\lambda)$  定義為

$$P(O|\lambda) = \sum_{i=1}^S \alpha_i(i) \beta_i(i) \quad \forall t$$

**正向程序(Forward procedure) :**

當在計算在對已知觀測序列  $O$  的狀況下，在時間點之前所有的隱藏狀態機率，且在  $t$  時間點上的隱藏狀態  $h_i$ ，稱為正向程序，可以表示如下：

$$\alpha_i(i) = P(o_1, o_2, \dots, o_t, q_t = h_i | \lambda)$$

$\alpha_i$  的值可用二個部分來表示

初式

$$\alpha_1(t) = \pi_1 b_1(o_i), \quad 1 \leq i \leq N \quad (11)$$

通式

$$\alpha_{t+1}(j) = \left( \sum_{i=1}^S \alpha_t(i) a_{ij} b_j(o_{t+1}) \right), \quad (12)$$

$$1 \leq j \leq N, \quad 1 \leq t \leq T-1$$

**逆向程序(Backward procedure)**

$$\beta_i(i) = P(o_{t+1}, o_{t+2}, \dots, o_T, q_t = h_i, \lambda)$$

初式

$$\beta_i(i) = 1, \quad 1 \leq i \leq S \quad (13)$$

通式

$$\beta_t(i) = \sum_{j=1}^S a_{ij} b_j(o_{t+1}) \beta_{t+1}(j), \quad (14)$$

$$1 \leq i \leq S, \quad 1 \leq t \leq T-1$$

### 2.3.2 Baum-Welch 演算法

當在HMM的參數訓練上，主要是訓練以求得一個  $\lambda=(A, B, \pi)$ ，能使得  $P(O|\lambda)$  的機率值為最大，在本研究中將利用Baum-Welch演算法來進行。Baum-Welch為EM演算法的一個特例，因可同時應用前進與後退兩變數，進行模式參數的調整，也可稱之為前進-後退演算法。

以下將定義在Baum-Welch的參數部分：

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (15)$$

$$\bar{b}_j(k) = \frac{\sum_{t=1, o_t=v_k}^{T-1} \gamma_t(j)}{\sum_{t=1}^{T-1} \gamma_t(j)} \quad (16)$$

$$\bar{\pi}_i = \gamma_1(i) \quad (17)$$

$$\xi_t(i, j) = P(q_t = h_i, q_{t+1} = h_j | O, \lambda) = \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{P(O|\lambda)} \quad (18)$$

$$\gamma_t(i) = P(q_t = h_i | O, \lambda) = \sum_{j=1}^N \xi_t(i, j) \quad (19)$$

## 3. 系統架構

本研究將開發在使用者進行慢跑運動的時候，可利用手機內部的感測裝置，偵測使用者的跑步情形，並可經由網路傳輸資料至伺服器內，並由伺服器內部的音樂推薦模組，推薦使用者所喜歡的音樂。其系統架構圖如下：

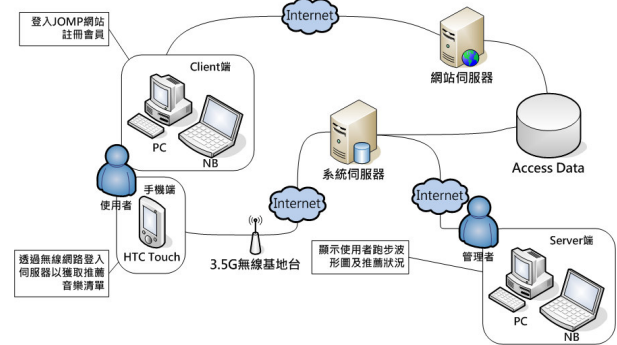


圖 2 系統架構圖

本研究主要將重點分為兩個部分，第一部份為手機裝置端(Mobile Device)，使用者功能與智慧型裝置感測人體手臂擺動部分，進行的開發與實作步驟；第二部分則是在音樂推薦伺服器端(Music recommendation service)，如何推薦合適使用者的跑步節奏且是使用者所喜好的音樂，本研究利用HMM來預測跑步速度變換的時間預測，以便從音樂資料庫中挑選合適時間的歌曲並符合使用者跑步的速度，並產生音樂播放清單以進行推薦，則是本部分的重點。

### 3.1 智慧型手機端

在本研究中，我們將智慧型手機放置於使



用者的手臂上，如圖：



圖 3 智慧型手機放置處

利用了三軸加速規來偵測使用者跑步的手臂擺動，如圖：



圖 4 跑步時的手臂擺動

在此藉由三軸加速規的X軸及Y軸所偵測的加速度，來判定使用者的手臂擺動情形，但我們發現在使用者靜止不動的狀態下，三軸加速規仍然會有變動情形，如圖，為防止系統產生誤判情形，我們將藉由設立門檻值來判定跑步動作的產生。




圖 5 靜止狀態下的三軸加速規狀態

### 3.2 音樂推薦模組設計

在音樂推薦模組中，我們利用了C4.5決策樹分類學習法來對使用者進行音樂推薦，因為它自有分岔的條件方法，可以對離散型或連續型數值中的一個數值加以分類，並有明顯優勢在於處理複雜問題上產生的決策規則，對於人來說是容易理解的結構。且在學習過程中能夠進行調整，及快速建立等優勢，這使得決策樹分類學習法能夠更適用於明確決策模型的相關領域。

當模型在建置時，我們將利用使用者的步伐偵測資料和音樂特徵及使用者對音樂的喜好來進行分類，建立決策樹。在決策樹建置過程中，需要分析資料集的類別分佈，才能選擇出最適當的分割點與分類屬性，分類時需考慮到資料量可能十分龐大，且真實資料集中可能有資料稀疏或雜訊等問題，若拿一般ID3決策樹作分割點搜尋時，資料在分割後可能都只有單一筆數值，然而計算資訊貢獻量又偏向取值大的，造成分類出的規則必定產生過度適配(Over-fitting)的問題，且在擷取有意義的知識上也會大大降低。所以又提出C4.5分類學習法，延伸解決上述ID3所會出現的問題。

故在本研究中利用C4.5分類學習法作為我們建構喜好模型的基礎係由資料庫中的記錄，取得各項屬性，如「SPM(Step Per Minute)」與「音樂內容特徵」等不同資料，另以「評分喜好」作為決策樹目標分類的依據。

而我們將由下表說明建置步驟：

表 1 分類資料集表

歌曲編號	平均音高	平均音長	節奏	類別
10	100	70	175	5
5	120	60	63	3
15	70	80	72	2
21	80	70	45	4
50	60	70	88	3
11	70	80	131	2
18	80	60	56	3
20	100	70	80	5
22	130	90	172	1
33	120	80	112	3
27	150	60	69	5

範例中顯示使用者對音樂的喜好和節奏對應到的區間，表頭中「平均音高」、「平均音長」、「節奏」代表音樂內容特徵屬性，「對應區間」為節奏所對應到的速度區間，另外，「類別」為使用者回饋的分數記錄，我們由C4.5演算過程為此使用者建置個人行為模型，其步驟如下。

Step1：搜尋可能候選分割點。

其初始搜尋先將屬性值作排序，依排序後的結果，取可能出現的兩筆數值間作為候選分割點，此候選點位置由兩屬性值取平均數得之。

Step2：搜尋實際分割點位置。

由搜尋出的候選分割點位置，計算得到資訊貢獻量(Information Gain)，以屬性中得到的

Information Gain最大者為實際分割點位置。

Step3：選擇最佳特徵屬性節點

由搜尋出的實際分割點位置，計算不同維度的特徵屬性並比較Gain Ratio的值，選擇最大者優先當作二元樹的根(Root)節點。

之後我們以遞迴方式重覆Step1~Step3的演算步驟，即可再搜尋最佳分割點與挑選最佳屬性的過程中，決定樹的下一個測試節點(Nodes)與分支(Breaches)，直到分割後每個子集中都屬於同一種類別或是子集中無資料可再供分類時，則二元樹就會停止分類的動作。

在模型產生後，C4.5將會進一步做適當樹的修剪，會採用事後修剪(Post-Pruning)的方式，以避免在產生樹的過程有過度適配的情形。作法是由葉節點往上測試所隸屬的子樹節點，並採用預估錯誤率(Predicted Error Rate)為評斷修剪的條件。

### 3.3 預測模型設計

在系統設計上，我們將測試k-means的k值，主要是考慮若將使用者的跑步速率的群數分成過多，則系統在換歌的時候會產生能推薦的歌曲過少，對推薦上難以有較好的表現。對使用者在聆聽音樂上，也容易因跑步的速度有些許的改變而產生換歌的動作。

#### 3.3.1 使用者資料分群

系統將先把使用者的原始資料做平滑化處理。

$$\bar{D}_s = \sum_{n+2}^n d_s \quad (20)$$

再將平滑化的資料利用k-means將k值假設為4，在求出求出中心點後，將各資料進行做分群。

以下是我們針對使用者跑步的SPM所做分群圖，如圖：

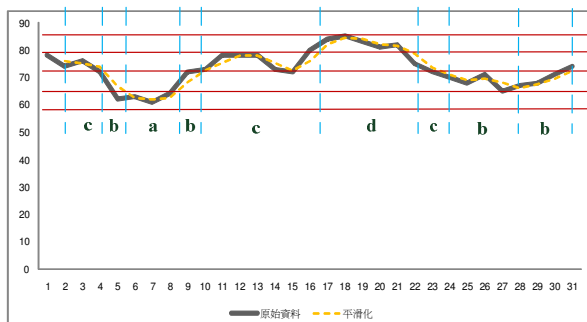


圖 6 SPM 分群圖

在上圖中粗線條為使用者的原始跑步資

料，採樣的時間點為10秒鐘一次。虛線為平滑化後的曲線變化情形。利用k-means分群後，我們將使用者跑步的速度分為四區間，分別為a、b、c、d四種情形，可以看出使用者在跑步變化，我們整理成下表：

表 2 使用者跑步變化

時間(sec)	10	20	30	40	50	60	70	80	90	100
區間	c	c	c	b	b	a	a	a	a	b
時間(sec)	110	120	130	140	150	160	170	180	190	200
區間	c	c	c	c	c	c	c	d	d	d
時間(sec)	210	220	230	240	250	260	270	280	290	300
區間	d	d	c	c	b	b	b	b	b	b

#### 3.3.2 隱藏式馬可夫模型設計

隱藏式馬可夫模型是一種機率的統計模型，包括具有隱藏狀態的馬可夫鏈、狀態轉移機率矩陣、初始狀態機率分佈和可觀測的隨機過程。而此過程中的隱藏狀態是不確定或不可見的，只有透過觀測序列的隨機過程才能表現出來，在這裡我們設計了一個隱藏式馬可夫模型來對應使用者跑步的狀態轉移，在隱藏層部分我們預設使用者的跑步狀態分為啓始狀態、活躍狀態、平穩狀態、疲乏狀態，這四種狀態除了啓始狀態外，其餘皆無法由實際行為上觀察到的。如圖：

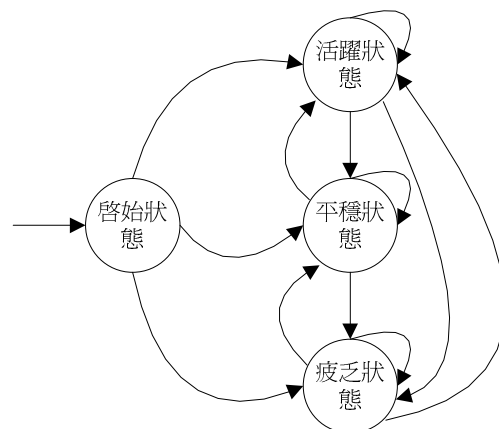


圖 7 隱藏式馬可夫的跑步狀態

在各狀態的轉移機率部分，我們預設使用者使用後，由啓始狀態開始，一開始皆有可能

會出現三種狀態，各狀態間也有可能會有狀態互換之情形，但是其餘三種狀態皆不會逆行至啟始狀態。

隱藏式馬可夫模型主要是由多個參數定義而成，主要可由 $A$ 、 $B$ 、 $\pi$ 來決定HMM的特性，可以用下列來表示：

$$\lambda = (A, B, \pi) \quad (21)$$

在模型的狀態數我們設定了4個隱藏狀態的個數，則狀態集合 $H$ 為：

$$H = \{h_1, h_2, h_3, h_4\} \quad (22)$$

定義模型的狀態在時間 $t$ ， $1 \leq t \leq T$ ， $T$ 則為觀測序列的長度。

隱藏狀態移轉機率以 $A$ 來表示，

$$A = \begin{Bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{Bmatrix}, i \geq 1, j \leq 4 \quad (23)$$

在這部分我們將先由隨機機率代替一開始的初始機率。

隱藏狀態的轉移機率主要是因我們無法直接觀測到在時間軸上的轉移機率 $a_{ij}$ ， $a_{ij}$ 主要在表示時間點 $t$ 時的隱藏狀態為 $h_i$ 時，在時間點 $t+1$ 為 $h_j$ 時的機率，可表示如下：

$$a_{ij} = P[q_{t+1} = h_j | q_t = h_i], \quad (24)$$

$$\text{其中 } a_{ij} \geq 0 \text{ 且 } \sum_{j=1}^S a_{ij} = 1$$

在量測樣本值的機率分佈，我們以 $B$ 來表示，

$$B = \{b_j(k)\}, 1 \leq j \leq S, 1 \leq k \leq M \quad (25)$$

樣本值的機率分佈 $b_j(k)$ 指示的在時間點 $t$ 上，隱藏狀態 $S_j$ ，所產生出 $v_k$ 的機率。

在初始狀態機率的分佈，我們以 $\pi$ 來表示。

初始機率分佈定義為當開始量測時處於某隱藏狀態的機率。

$$\pi = \{\pi_i\}, 1 \leq i \leq S \text{ 且 } \pi_i = P[q_1 = h_i], 0 \leq \pi_i, \sum_{i=1}^S \pi_i = 1 \quad (26)$$

### 3.3.3 波氏演算法(Baum-Welch Algorithm)

從 HMM 模型裡  $\lambda$  將產生觀測序列  $O=(o_1, o_2, \dots, o_T)$ ，而我們將從觀測序列推算出模型  $\lambda$  的參數，且在調整估算參數過程中，須讓  $P(O; \lambda)$  為最大。對HMM的應用來說乃是最重要的工作。而當觀測序列被用來調整HMM

之參數時，則該觀測序列被稱為訓練序列(Training sequence)，為了要使 $P(O; \lambda)$ 為最大值，須調整HMM之參數，目前並沒有數學算式等解析方法可直接求出最佳參數，因此我們利用波氏演算法(Baum-Welch Algorithm)，其原理就是使用反覆運算來改進參數來得到局部最佳解，也就是利用最大概似法的特性，選出一組隨機機率組合和觀測序列最一致的HMM參數。

我們將利用以下步驟進行：

1. 我們將定義兩個參數分別為  $\zeta_t(i, j)$  與  $\gamma_t(i)$ ：

$\zeta_t(i, j)$  為在模型  $\lambda$  中，在第  $t$  個時間上由狀態  $i$  轉移到狀態  $j$  的機率。

$$\begin{aligned} \zeta_t(i, j) &= P(q_t = i, q_{t+1} = j | O; \lambda), \\ t &= 1, 2, \dots, T-1, i, j = 1, 2, \dots, N \\ &= \frac{P(q_t = i, q_{t+1} = j, O; \lambda)}{P(O; \lambda)} \\ &= \frac{\alpha_t \cdot a_{ij} \cdot b_j(o_{t+1}) \cdot \beta_{t+1}(j)}{P(O; \lambda)} \end{aligned} \quad (27)$$

$\gamma_t(i)$  則為在模型  $\lambda$  中，，在第  $t$  個時間上狀態  $i$  的所停留機率。

$$\begin{aligned} \gamma_t(i) &= P(q_t = i | O; \lambda), \\ t &= 1, 2, \dots, T-1, i = 1, 2, \dots, N \\ &= \sum_{j=1}^N \zeta_t(i, j) \\ &= \frac{\sum_{j=1}^N \alpha_t \cdot a_{ij} \cdot b_j(o_{t+1}) \cdot \beta_{t+1}(j)}{P(O; \lambda)} \\ &= \frac{\alpha_t(i) \cdot \beta_t(i)}{P(O; \lambda)} \end{aligned} \quad (28)$$

由以上參數便可知在1到 $T$ 個時間點內，利用模型  $\lambda$  和觀測序列  $O$  的條件，便可得到：

在狀態  $i$  之機率和為：

$$\sum_{t=1}^T P(q_t = i | O; \lambda) = \sum_{t=1}^T \gamma_t(i) \quad (29)$$

在狀態  $i$  且我們所定義的跑步分群符號的機率和為：

$$\sum_{t=1}^T P(o_t = k, q_t = i | O; \lambda) = \sum_{t=1}^T \gamma_t(i) \quad (30)$$

由狀態  $i$  轉移到狀態  $j$  的機率和為：



$$\sum_{t=1}^{T-1} P(q_t = i, q_{t+1} = j, O; \lambda) \quad (31)$$

$$= \sum_{t=1}^{T-1} \zeta_t(i, j)$$

因此可以估算出新的模型參數

$$\bar{\lambda} = (\bar{A}, \bar{B}, \bar{\pi}) \quad (32)$$

其中

$$a_{ij} = \frac{\sum_{t=1}^{T-1} P(q_t = i, q_{t+1} = j, O; \lambda)}{\sum_{t=1}^{T-1} P(q_t = i | O; \lambda)} \quad (33)$$

$$= \frac{\sum_{t=1}^{T-1} \zeta_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)}$$

$$\bar{b}_j(k) = \frac{\sum_{t=1}^T P(o_t = k, q_t = j | O; \lambda)}{\sum_{t=1}^T P(q_t = j | O; \lambda)} \quad (34)$$

$$= \frac{\sum_{t=1}^T \gamma_t(i)}{\sum_{t=1}^T \gamma_t(j)}$$

$$\bar{\pi}_i = P(q_1 = i | O; \lambda) = \gamma_1(i) \quad (35)$$

利用上式便可完成一次參數值的估算，並可算出最新的機率值  $P(O; \bar{\lambda})$ ，皆下來便反覆遞迴，直到機率值的狀態達到穩定，以求得我們所需的模型預測。

### 3.3.4 模型預測

利用隱藏式馬可夫模型建立一個統計模型後，接下來我們便針對使用者跑步的變化建立預測模型。我們觀察了使用者跑步的速度，發現在跑步的速度變化在經過上節利用 k-means 分群法後，會在某個區間內維持一個固定的時間，例如下表為跑步速度的變化情形。

表 3 區間速度變化情形

區間變化	ccc bb aaaa b cccc dddddd cc bbb .....
------	--

因此我們針對使用者在跑步時所在的區間變化情形進行預測，利用建立的隱藏式馬可夫的機率模型，預測使用者在未來跑步的區間

速度變化情形，讓系統在推薦歌曲時，推薦出的歌曲能符合使用者接下來速度跟時間的變化。而接下來我們預測的步驟如下：

1. 建立使用者的隱藏式馬可夫模型：  
 $\lambda = (A, B, \pi)$
2. 先將使用者的跑步資料分為訓練組及觀測組，再利用 Baum-Welch 演算法將資料訓練成隱藏式馬可夫模型。
3. 跑步速率的變動會維持一段時間，雖然經由實際資料上速度會有改變，但經由分群過後，將歸屬於某一區間中，而且使用者在跑步的同時，對自身速度變化並不會有很大的感受，通常在慢跑運動中，速度並不會有非常劇烈性的變化，除非是刻意加速或是停止。在此我們便可針對跑步的速度所維持的時間進行預測。我們會先將各種可能的產生的速度變化投入模型中，再經由系統推算出較有可能的區間變化。如下圖所示：

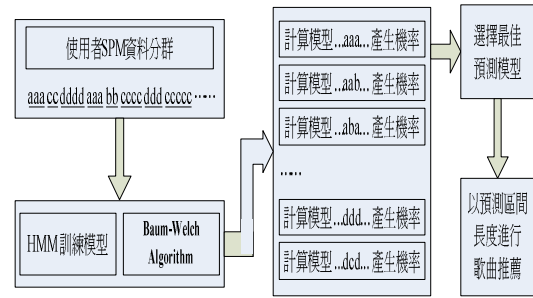


圖 8 模型預測流程圖

我們將以下例進行說明：

假設系統將使用者的跑步資料分為 a、b 兩群資料，則系統將產生 a 序列與 b 序列其機率產生大於 50% 的變化模型：

$$A_{sei} = (aaa \ aab \ aba \ baa)$$

$$B_{sei} = (bbb \ bba \ bab \ abb)$$

再將此資料序列經由 HMM 下去進行預測，求得各變化模型的機率產生值，將最大機率的變化模型做為推薦歌曲的模型。

$$P(A_{sei}) = \sum p(a_i), \quad a_i \in A_{sei}$$

$$P(B_{sei}) = \sum p(b_i), \quad b_i \in A_{sei}$$

## 4. 系統介面與實驗

我們在系統設計完成後，實際建置了系統網站、智慧型手機上介面開發及伺服器端的介面開發，將分述如下：

## 4.1 開發環境

在本研究中，我們所使用的系統端的開發平台和設備如下表：

表 4 系統端環境

名稱	內容
中央處理器	Intel® Core™ 2 Quad Q6600 @ 2.4GHz
記憶體	2048MB
作業系統	Windows XP Professional
程式語言	Microsoft Visual Studio C# 2008
網站架設	Microsoft Asp.Net
資料庫	Microsoft Access 2003

在智慧型手持裝置端，我們則是利用了HTC的PDA手機，如圖：



圖 9 智慧型手持裝置

而在手持式裝置的開發環境如下表：

表 5 手持式裝置的開發環境

名稱	內容
型號	HTC Diamond P3702
處理器	Qualcomm® MSM7201A™ @ 528 MHz
記憶體	ROM：256MB RAM：192MB DDR SDRAM 內建記憶體：4 GB
作業系統	Windows Mobile® 6.1 Professional
程式語言	Microsoft Visual Studio C# 2008 Windows Mobile 5.0 Pocket PC SDK
三軸感應器	內建三軸加速度感測器
GPS 配備	GPS 及 A-GPS
網路傳輸	Wi-Fi®：IEEE 802.11 b/g

## 4.2 系統介面

本研究在伺服器端上建立一個系統介面，可以見到目前使用者的資料、音樂推薦情形、即時及歷史的SPM資料及連線狀況，如下圖：



圖 10 系統介面圖

在系統介面端可分為四大區塊進行設計。

第一區塊使用者的個人資料和音樂喜好的類型。

第二區塊為當使用者在跑步的時候，播放清單上所推薦的歌曲。

第三區塊為當手持式裝置與系統連線後，可以即時的在介面上顯示出連線狀況。

第四區塊能觀看由手持式裝置端即時回傳的SPM資料和查詢系統所記錄使用者的SPM資料。

在手持式裝置端上的介面，則為使用者在跑步時所會使用到的播放器介面和登入畫面，如下圖：



圖 11 登入及播放器介面

上圖為使用者登入畫面，此功能與網站功能有相連結，需先至網站上註冊使用者個人資料，方能登入。在登入後便能見到播放介面，在播放介面上我們分為三個區塊進行設計。

第一區塊內可見到手持式裝置端在GPS衛星的連線數和播放的歌曲資訊。

第二區塊則為方便使用者在跑步時所若

要進行換歌，可以快速的找到換歌按鈕，不用停下來操作介面，因而會改變跑步速度和手臂擺動次數，影響系統偵測使用者的跑步情形。

第三區塊則為一般的播放器介面供使用者操作。

在網站部分，則可讓使用者在網站配合 Google Map 瀏覽跑步所行經的路徑。

### 4.3 三軸加速規門檻實驗

在跑步判定X軸及Y軸門檻值的部分，由10位受測者進行模擬跑步時手臂的擺動時取得，而感測器的所放置的位置則以圖3為例，皆放置於左手臂外側與手臂平行的位置。而X軸與Y軸的門檻部分則分開計算。

在經由100次的模擬跑步後，測得的資料統計如下表：

表 6 X 軸與 Y 軸樣本區間統計

樣本資料	X軸	Y軸
樣本值	100	100
最大值	156	184
最小值	-184	-144
平均	53.2	80
變異數	40.3	62
標準差	63.5	89
95%信賴區間	0.05	0.05
上限	65.7	97.5
下限	-40.8	-62.4

由上表可得知，X軸的有效門檻值為65.7到-40.8之間，Y軸的有效樣本值為97.5到-62.4之間。

### 4.4 預測區間長度實驗

在預測區間長度部分，在我們的音樂資料庫中，包含了整首歌以及副歌的部分，在副歌的部分，最短的歌曲長度約為30秒，以系統每10秒計算一次SPM，在預測區間長度部分，最小部分將以三階預測開始。我們對測試資料中以不同的模型下去進行測試，該模型會有一預測值的出現機率大於50%，並以預測模型中的 $\lambda$ 參數求得最大的機率值，設訂資料分群為四群。以下為對HMM架構做30次的實驗。

表 7 階層預測表

準確率(%)	最大值	最小值	平均	變異數
3 階	81.2	76.1	79.28	1.486933
4 階	80.8	75.3	78.29	2.343289

5 階	79.1	73.8	76.46	2.815556
6 階	78.6	71.1	74.84	4.772622
7 階	71.3	61.6	65.52	7.764933
8 階	62.5	54.9	57.48	4.049822




圖 12 階層預測分佈圖

由上圖及上表可分析實驗結果在階層數6階以下時，準確率皆能有70%以上，在7階以下則準確率大幅降低至55%。

## 5. 結論與未來研究方向

現代人工作忙碌，但也應同時也必須兼顧身體之健康，在休閒運動與品質上更該有相對的提升，而音樂這個元素若能增加進運動中，相信會提升運動休閒品質，因此開發此系統希望能夠滿足現代人在時間短少的情況下，能同時兼顧運動及休閒，並帶起一波運動音樂之潮流。

也由於科技的日漸進步，在智慧型手機這塊領域上也漸漸的多元化了起來，現在智慧型手機上已經有了多樣化的作業平台，因此我們期望在未來能將此系統擴展到其它的服務平台上，以讓其它的服務平台能夠利用我們的系統。

以目前智慧型手機的系統效能，若要同時負擔即時的偵測跑步步伐、推薦歌曲和播放歌曲等功能，對手機的負擔會非常大，因此需要靠無線網路來傳送資料至伺服器端進行運算，在目前無線網路的服務沒有非常普遍，且會因地而異的影響網路品質，而系統執行的環境必須要有無線網路連結，希望在未來也能在無網路的狀態下使用。

## Acknowledgement

This work was partially supported by the NSC in Taiwan under the contract numbers NSC

### 參考文獻

- [1] A. Koudinov, “Scientific evidence invalidates Beijing 2008 Olympic Swimming medals by Phelps,others” ,*The Doping Journal vol.5*,(<http://dopingjournal.org/content/5/2>), 2008.
- [2] Y. Fu., “Data mining: tasks, techniques, and applications” ,*IEEE Potentials*, Vol.16, No.4, pp.18-20, 1997.
- [3] J. Han, M. Kamber, “Data Mining : Concept and Techniques”, *Morgan Kaufmann Publisher.*, 2001.
- [4] L. E. Baum and T. Petrie, “Statistical inference for probabilistic function of finite state markov”, *Chains Annals of Math. Statistics*, vol.37, no. 1, pp. 554-1563, 1966.
- [5] Nike+iPod Sport Kit  
<http://www.apple.com/ipod/nike/>
- [6] P. C. Terry, C. I. Karageorghis, ” Psychophysical Effects of Music in Sport and Exercise:An Update on Theory, Research and Application”, *Psychology bridging the Tasman: Science, culture and practice – Proceedings of the 2006 Joint Conference of the Australian Psychological Society and the New Zealand Psychological Society*, pp. 415-419, 2006.
- [7] J. R. Quinlan “C4.5: Programs for Machine Learning”, *Morgan-Kaufmann, Morgan Kaufmann Series in Machine Learning*, pp.302, 1993.
- [8] S. O’Brien, F. F. Mueller, “Jogging the Distance”, *Computer/Human Interaction 2007 Conference*, April 28–May 3, 2007.
- [9] SONY NW-S203F  
<http://www.walkman.sony.co.jp/>.