

依據慢跑者腦波狀態調節播放音樂類型之機制

楊登宇 江政祐 劉寧漢*
國立屏東科技大學資訊管理系 國立屏東科技大學資訊管理系 國立屏東科技大學資訊管理系
研究生 研究生 副教授
a0988239034@gmail.com djmb3567@gmail.com gregliu@mail.npust.edu.tw

摘要

本研究結合了音樂、腦波與慢跑運動，分析由正常運動狀態至和緩運動狀態的腦波變化，找出產生變化的波形及數據資料，並設計出具有激勵性效果的音樂推薦系統。以腦波數據資料分析為基礎，利用腦波感測器收集慢跑運動中產生的狀態數據，並使用支持向量機分類演算法將腦波數據狀態進行分類，藉以找出最容易觀測慢跑腦波變化的時間軸長度。本論文所提出的依據腦波變化自動切換音樂的推薦機制，判斷慢跑者產生和緩運動狀態的腦波變化時，調節正在播放的音樂，推薦對於慢跑者有幫助、激勵性較高的音樂。經由實驗驗證，我們所提出的腦波狀態辨識方法能有效的辨識出最容易觀測慢跑運動腦波的時間軸長度，而音樂推薦機制則是能夠提升慢跑者的運動時間。

關鍵詞：慢跑、腦波、支持向量機、音樂推薦、決策樹

Abstract

This thesis is about combining EEG and music and jogging. I analysis EEG signal from the normal to alleviate changes in the state, then design a mechanism of adaptive music which has the incentive effect. My thesis is based on EEG data analysis. I use EEG sensors to collect the data of jogger's state. Assort support vector machine classification algorithm to classify the EEG data state, and then identify the most easily observed time length in jogging EEG.

My thesis proposes a mechanism of adaptive music type selection based on EEG status. When judging jogger produced alleviative changes in EEG states, regulate the music being played, recommended helpful and incentive music for joggers. Proved by the experiments, the proposed EEG state identification method in this study can effectively identify the most easily observed EEG time length of jogging, and the mechanism of adaptive music type selection is able to enhance

exercise time for joggers.

Keywords: Jogging, EEG, Support Vector Machine, Music Recommend, Decision Tree

1. 前言

在各式運動中，慢跑(Jogging)為一種全球性的運動，尤其在科技越先進的國家，其國民對於個人的身心健康狀況更是高度重視，而慢跑運動更是許多歐、美洲國家重視及推廣的項目之一。慢跑運動者不分性別、年齡、族群，在場地方面更是不受拘束，只要地勢平整，不論在何處皆可以是慢跑運動的好場所。慢跑者經常使用隨身裝置(如 iPod、smart phone、MP3)聆聽音樂，除了使之能夠紓解長時間慢跑下所產生的沉悶情緒外，還能夠配合不同類型的音樂進行情緒與壓力的調適。現今也有許多專業的運動選手，會在比賽之前，聆聽與將要進行之運動節奏較相似的音樂；而在培訓時，也為了更準確的判斷運動員的生理狀況與提升之成效，讓運動員配戴了腦波偵測儀器(Electroencephalography Sensor)來偵測運動員在培訓時的生理狀態。

要如何從眾多類型的音樂中，挑選出適合的音樂，是一件讓使用者非常煩惱的事情。傳統的音樂推薦方式，大多都是以歌曲點播率、熱門程度等當作推薦的依據，但是在使用者的差異性與個人需求漸增的趨勢下，傳統的音樂推薦已經無法滿足每位使用者。近年來，已經有許多學者在個人化的音樂推薦領域上提出許多的方法，能夠增加個人化音樂推薦的正確率。因此，個人化音樂推薦，儼然已成為現在音樂推薦方式的趨勢。

本論文結合了音樂、腦波與慢跑運動，在慢跑運動中使用手持式行動裝置及腦波感測器(Electroencephalogram Sensor, EEG Sensor)收集慢跑者的腦波資訊，觀察慢跑者在運動中的腦波變化情況。

* 通訊作者

要根據 EEG 判斷運動者是否為正常運動狀態或和緩運動狀態，是與二元分類相關的問題。支持向量機(Support Vector Machine, SVM)是專門應用於二元分類的演算法，所以我們選擇 SVM 當作分類辨識的方法，依據不同的時間軸長度將腦波數據輸入 SVM 中，用於分析慢跑運動的腦波資料變化，找出慢跑運動中，觀察何種類型的腦波及時間軸長度的數據資料可以分辨出對於慢跑運動中，產生和緩運動腦波分類正確率。並且，透過音樂推薦機制(Music Recommendation)，依據音樂的特徵及使用人工智慧的方法進行音樂的推薦。此推薦機制主要是利用慢跑者的腦波資料進行判斷，根據慢跑者的腦波變化狀態，由音樂資料庫中挑選出慢跑者喜好的歌曲，並且對於運動狀態是有激勵性的音樂給予聆聽，分析所播放的音樂是否能有效增加慢跑者的運動時間，藉以達到提升慢跑者運動效益的目標。

2. 相關研究

2.1 腦波

腦波的詳細分類，是由臨床生理學會國際聯盟(International Federation of Societies for Electroencephalography and Clinical Neurophysiology) [13]所制定；腦波波型共分為五個波段，可依頻率範圍分為 α (alpha)波、 β (beta)波、 δ (delta)波、 θ (theta) 波及 γ (gamma)波。表 2-1 列舉常見的四種腦波特性與分類：

狀態	腦波	頻率	產生情況
清醒	α 波	8~13 Hz	安靜、休息、放鬆時
	β 波	14~30 Hz	清醒狀態、思考時
睡眠	θ 波	4~7 Hz	深度放鬆、恢復體力的睡眠狀況
	δ 波	0.5~3 Hz	熟睡、無意識、作夢
專注	γ 波	31~50 Hz	極度專注的狀態

表 2-1 腦波波型之頻率與特性分類

2.2 腦波、音樂與運動相關研究

學者 Li & Wang 指出，運動操作階段，專業運動員的左大腦顳葉的 α 波功率值增加、 β 波功率值減少[9]，比起一般人在運動時的 α 、 β 波腦波變化更加明顯，因此我們可以了解到在運動進行的狀態時，大腦會處於較為放鬆的狀態，不會邊運動邊進行思考，研究[2]則是指

出，運動後之 α 腦波活動明顯比運動前增加，且在中強度運動的完整運動流程中，在還未達到所要求的強度前，即可使大腦產生明顯之放鬆狀態；而持續較長時間的中強度運動有助於此放鬆狀態之維持。[6]則是利用腦波與心跳頻率觀測駕駛者的精神狀況，當發現精神狀態改變時則利用音樂喚醒駕駛者，並且設定一個門檻值，用於判斷駕駛者的腦波狀態，此門檻值的設定是應用於觀測駕駛者的精神狀態是否進入瞌睡狀態。

2.3 支持向量機

支持向量機(Support Vector Machine, SVM)通常用在機器學習上，是由[16]所提出，能夠解決二元分類的問題。目前已經有許多研究將 SVM 應用在腦波訊號的分類與處理，[5]就是使用 SVM 進行腦波的分類與處理，並藉此設計 BCI(Brain computer interface)分類系統，能夠辨識出簡易的數學運算及左、右手移動時的腦波。[17]則是使用 SVM 去辨識駕駛人的腦波，主要是為了區分駕駛人是否在駕駛車輛的時候產生瞌睡的狀況，並藉此發展一套預先提醒之睡意探測系統。

2.4 音樂推薦方式

推薦系統(Recommend System)是一種在大量的資訊中，有效的替使用者篩選出最感興趣資訊的服務工具。推薦系統根據演算法的不同，大致分成三大類，分為內容導向式(Content-Based Methods)、合作式過濾法(Collaborative-Filtering Methods)及混合式推薦法(Hybrid Recommendation Methods)。

2.4.1 內容導向式

是利用音樂的特徵值當作推薦的基礎，對使用者進行推薦[8]，例如演唱者、類型、歌詞等，或利用歌曲所擷取出的內容特徵來進行分析與比對，內容特徵可以用於描述歌曲聲音的特性，例如音色、音高及節奏等。在一般的音樂推薦系統中，通常會先替使用者建立特性輪廓(User Profile)，[14]主要是記錄使用者相關資訊及關鍵字，如聆聽過的歌曲、曲風、歌手等，經由推薦系統的過濾機制過濾出與使用者特性輪廓相符合的音樂。

2.4.2 合作式過濾法

又稱之為社會過濾(Social Filtering)法，主

要是根據使用者歷史資料與喜好，利用分群演算法將相似的使用者聚集於同一群集。再於同一群集內尋找相似度較高的使用者，並由尋找出的使用者的歷史資料中，透過推薦機制，挑選出適合的項目進行推薦[15]。

2.4.3 混合式

內容導向式及合作式過濾法各有缺點，因此有學者將兩種方式混合，提出了混合式過濾法[7]，期望解決它們的缺點。[12][4]皆將使用者的輪廓當作基礎，將使用者過去的喜好資料配合音樂特徵進行分類，找出與使用者喜好相近的歌曲後，推薦使用者喜歡的類型，並計算輪廓的相似度，產生相同群組使用者的推薦清單。

3. 研究方法

3.1 系統概念與架構

透過頭戴式腦波偵測儀配合偵測系統進行數據資料收集，藉此擷取慢跑至產生和緩運動狀態變化的腦波數據資料，收集到的腦波數據資料，先以人工進行資料的篩選及標記出產生和緩運動腦波變化的區間，運用 SVM 進行分類與計算，找出最適合觀測慢跑運動腦波之時間軸長度，並搭配激勵性音樂推薦模組，當使用者產生和緩運動腦波變化時，推薦使用者具有激勵性的音樂，以下將逐一說明各步驟的流程及運作方式。圖 3-1 為系統架構圖：




圖 3-1 系統架構圖

3.2 腦波偵測儀

我們使用可攜式腦波感測器，對於所量測到之微弱腦波訊號進行量化處理，並且可以去除及過濾來自周圍的微弱電力、肌肉運動及環境雜訊等所產生出的微弱電波。由於人的精神、專注狀態與情緒主要是受到大腦前額葉區域的控制，因此我們偵測 FP1 與 FP2 兩處所產生的電位用以進行慢跑者的運動狀態分析。如圖 3-2 所示：




圖 3-2 國際 10-20 電擊配置圖與腦波收集位置

人的大腦各部位均會產生腦電波，而傳統的腦波收集方式是在大腦的 37 處貼上電極，並依據國際 10-20 腦波電極配置圖進行腦波的收集，此種方式雖然能夠收集到完整的腦波變化，但是對於慢跑者來說，不可能使用此種腦波收集方式；因此我們使用方便運動者攜帶的可攜式無線腦波偵測裝置，搭配行動裝置臂套，進行腦波偵測與收集。

3.3 腦波數據辨識與運算

3.3.1 特徵擷取

EEG 有五種不同類型的腦波波行，分別為 α 波、 β 波、 δ 波、 θ 波、 γ 波，但根據研究 [9] 之中所提到與運動較為關的腦波為 α 波、 β 波， δ 波與 θ 波為淺層與深層睡眠時較容易產生，所以將會以 α 波及 β 波兩種腦波視為主要觀測的腦波數據資料。接下來依據腦波的波段分佈將能量值加總，產生 2 個特徵值。特徵值定義如下：

$$\alpha = \sum_{freq=8}^{13} P_{freq} \quad (3-1)$$

$$\beta = \sum_{freq=14}^{30} P_{freq} \quad (3-2)$$

在運動狀態下，產生疲倦感導致和緩運動是一種短暫性狀況，所以除了觀察時間軸序列 n 等於 1(秒)時的腦波資料外，還需將時間軸長度遞增後分析不同長度的腦波變化；因此，腦波數據會以每 n 筆加總平均後視為一個單位，用以觀察一段時間的腦波狀況，如圖 3-3 所示：




圖 3-3 腦波特徵值時間軸長度範例

當時間軸長度 n 為 2 時，將第一筆與第二筆腦波數據資料加總平均後的資料當作起始點，計算方法如下面公式(3-3)(3-4)定義：

$$\alpha_{avg,T} = \frac{1}{n} \sum_{i=T-n+1}^T \alpha_i \quad (3-3)$$

$$\beta_{avg,T} = \frac{1}{n} \sum_{i=T-n+1}^T \beta_i \quad (3-4)$$

上述兩公式為計算不同時間軸長度之平均值， n 為特徵值所取之時間軸長度，而時間軸總長度為 T ，且 $T \geq n$ 。

另外，研究[9]與[3]中有明確的指出，運動的操作進行階段 α 波功率值增加，此種腦波的變化很明顯的表達出，在運動進行階段，人的大腦實際上是處於放鬆的狀態。為了觀察受測者的連續性的精神狀態變化，所以我們延伸出一項特徵值 R ，是利用 α 、 β 兩種腦波平均值作簡易的公式(3-5)除法運算。如下所示：

$$R = \alpha_{avg} / \beta_{avg} \quad (3-5)$$

此特徵值是為了能夠更輕易的觀察慢跑者運動變化的情形，判斷運動者在運動中的狀態為何。研究[6]中將 R 值的門檻值定為 1，用於判斷駕駛者的腦波狀態且分析精神狀況是否進入瞌睡狀態，但此數值並不一定適合應用於判斷慢跑運動的腦波狀態，因此將會分析出較符合本論文慢跑運動的門檻值，並於後續的實驗部分與其他特徵值進行比較。

3.3.2 運動狀態之識別

本研究所收集的腦波資料，是慢跑者在運動進行時，隨著疲勞累積到一定的程度，決定停止跑步改為走路之和緩運動時的腦波變化，所以將運動狀態分為兩種，如表 3-1 所示：

表 3-1 運動狀態分類

狀態	說明	特徵 R
正常運動	剛開始慢跑，且能持續一定時間，短時間內沒有停止跡象。	> 1
和緩運動	運動一段時間，跑者主觀認定無法繼續進行運動，運動狀況從跑步變成走路。	≤ 1

3.3.3 人工紀錄/辨識切換點

為了能更準確地辨識出腦波由正常運動轉變為和緩運動的時間點，所以我們將每次進行實驗時的狀況使用數位相機對運動狀況進行錄影，並將所收集到的影像與腦波數據資料進行對照，以便正確的分辨出進行跑步運動時，由正常運動狀態轉變為走路的和緩運動狀態時間點及進行和緩運動前的腦波變化情況。

3.3.4 SVM 的腦波數據計算與分類

我們使用 SVM 的主要目的是將腦波資料

藉由一個超平面(hyperplane)，將數據資料分割為正常與和緩兩種狀態，所以希望找出劃分此兩種狀態的直線，並且找出分割此兩種狀態的最大邊界。圖 3-4 為 SVM 分類示意圖：




圖 3-4 SVM 分類圖

研究[1]中指出，SVM 分類多項式核心 (polynomial) 函數在辨識資料複雜度較低(即資料分佈散亂程度低)的分類準確率較高；而研究[3]中指出，腦波數據資料經由正規化步驟後，可能會使某些數據失去其代表的分類意義，因此 Polynomial K 識別的分類正確率都比 Normalized Polynomial 來得好一些。本研究主要是分析慢跑運動的腦波，屬於複雜度較低的數據資料，因此將選擇 Polynomial 函數當作依據進行計算與分類，並使用 k -fold 交叉驗證法 (k -fold Cross-validation) 進行正確率的驗證。

3.4 音樂推薦機制

除了收集與分析慢跑者在運動時，由正常運動狀態改變為和緩運動狀態的腦波變化，以及將腦波資料輸入 SVM 並分析何種時間軸長度最容易觀測慢跑運動的腦波變化外，設計了一套能根據腦波變化自動切換音樂的推薦機制。當慢跑者主觀認定無法繼續運動，產生想停止跑步進行和緩運動的腦波變化時，我們將透過以下的機制去做音樂的推薦。

3.4.1 音樂特徵值

音樂包含了許多不同的特徵，如節奏、音高、音長等。在音樂特徵值的處理上，我們將使用 MIDI 檔案；在 MIDI 檔中，音樂是以單音的方式呈現，利用音樂特徵值工具可以很容易擷取出相關節拍、音高及音長，並將所擷取出的資訊記錄成 (v, s, e)， v 代表音高， s 是起始時間， e 則是結束時間，我們可以由主歌的 MIDI 檔案得到下列的相關特徵值[11]：

- (1) 音樂速度(Tempo)
由慢到快為 0 至 208BPM。
- (2) 平均音高(Average Pitch, AP)
表示音樂的音域高低，計算方法如下：

$$AP = \frac{\sum_{i=1}^n v_i}{n} \quad (3-6)$$

v_i 代表第 i 個音符的音高， n 代表音符的序列長度。

(3) 音高亂度(Pitch Entropy, PE)

表示音高間的變化程度，計算方法如下：

$$PE = -\sum_{i=1}^{np} P_i \log P_i \quad (3-7)$$

np 代表不同的音高在音樂中出現的次數，而公式中 P_i 的定義為下：

$$P_i = \frac{N_i}{T} \quad (3-8)$$

N_i 代表具有相同音高的音符數目， T 是音符的總數。

(4) 音高密度(Pitch Density, PD)

用來表示一首或一個片段音樂的音高變化程度，計算方法如下：

$$PD = \frac{np}{128} \quad (3-9)$$

128 是標準音樂 MIDI 格式中不同音高的總數。

(5) 平均音長(Average Duration, AD)

用於描述音樂節奏的快或慢，方法如下：

$$AD = \frac{\sum_{i=1}^n D_i}{n} \quad (3-10)$$

D_i 代表的是音符的音長，而第 i 個音符的音長則是 $e_i - s_i$ 。

(6) 音長亂度(Duration Entropy, DE)

用於表示一首音樂節奏的變異程度，計算方法如下：

$$DE = -\sum_{i=1}^{nd} P_i \log P_i \quad (3-11)$$

公式中的 nd 代表不同的音長在音樂中出現的次數，而 P_i 的定義如下：

$$P_i = \frac{D_i}{T} \quad (3-12)$$

D_i 代表具有相同音長的音符總數， T 是音符的總數。

(7) 音高差亂度(Pitch Interval Entropy, PIE)

是在表示音樂與音調無關的狀態下，音高差的變化程度，計算方法如下：

$$PIE = -\sum_{i=1}^{ni} P_i \log P_i \quad (3-13)$$

ni 表示不同音高差在音高差字串出現的次數， P_i 的定義如下：

$$P_i = \frac{I_i}{T} \quad (3-14)$$

I_i 代表具有相同數值的音高差的數目， T 是音符的總數。

我們在之後要進行音樂的分類時，是依據 MIDI 檔案所辨別出的特徵值進行分類，但是

在音樂資料庫中音樂是包含了 MIDI 與 Wave 檔案，而實際在運動進行的階段所撥放的音樂是 Wave 檔案。

3.4.2 音樂分類

我們將音樂以使用者喜好進行初步分類。運動過程中，慢跑者運動主觀認定無法繼續時，推薦的音樂如果是使用者所不喜歡的歌曲，就算是判別對運動成效有幫助，也會不想繼續運動，甚至直接進行和緩運動並停止聆聽音樂。因此透過使用者平時聆聽音樂的記錄，記錄內容包含歌曲的特徵、類型及對於歌曲的評價資料(喜好程度分數以 1~10 進行記錄，1 分為極度不喜歡，10 分為非常喜歡)等，使用者記錄資料如下表 3-2 所示：

表 3-2 使用者聆聽音樂記錄範例資料

編號	喜好程度	演唱人	性別	音樂速度	節拍	年代
1	8	單人	男	113bpm	弱	90
3	9	團體	男	144bpm	強	90
5	3	單人	女	98bpm	弱	80

經由表格所收集到的音樂特徵資料，可以透過分類學習法找出慢跑者喜好的音樂特性。因此，我們將使用 C4.5 分類學習法作為我們建構喜好模型的基礎[10]。

Step 1：搜尋候選分割點

在初始搜尋的過程中，我們將依照特徵值 F_n 由大到小先進行排序 $F = \{ M_1, M_2, \dots, M_n \}$ ，並且建立一個候選分割點 C_p ，候選分割點是由相鄰的歌曲號碼取平均值取得，如下：

$$C_p = (M_i, M_{i+1})/2 \quad (3-15)$$

M_i 表示時間間隔內的連續數值、 M_{i+1} 是相鄰的號碼。

Step 2：搜尋實際分割點

透過所搜尋出的候選分割點的位置，計算所得到的最大資訊貢獻量(Maximum Information Gain)當作實際分割點的位置，計算方式如下：

$$Gain(S) = Entropy_{before}(S) - Entropy_{after}(S) \quad (3-16)$$

如果要計算出特徵值 R 的資訊貢獻量，必須使用經過分割後的熵值來進行運算，如公式(3-15)，當資料集合 S 中具有 n 個不同的結果時， C_p 對應於 S 集合中每種結果可能產生的機率。集合 S 的熵值計算方式如下公式：

$$Entropy_{after}(S) = \sum_{k=1}^n -C_p \log_2 C_p \quad (3-17)$$

這是用來計算分割點與貢獻量之間的比較，找

出 k 當作真正的分割點，並將所找出的實際分割點使用二元分割法劃分為兩個區間，分別是 $\leq k$ 與 $> k$ 。

Step 3：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 F 及比較 $GainRatio$ 的值，選擇最大者優先當作二元樹的根節點，計算公式如下：

$$GainRatio(F) = \frac{Entropy_{non}(S) - Entropy_{after}(S)}{Entropy_{after}(S)} \quad (3-18)$$

之後再以遞迴的方式重覆 Step1~Step3 的步驟，即可再次決定樹的下一層測試節點與分支，直到每個子集都屬於同一種類別或是再無資料可再供分類時，則二元樹就會停止分類的動作，最後所產生出來的葉節點(leaf node)就是符合我們決策條件的歌曲類型。

我們將使用者聆聽音樂的記錄資料建立為使用者喜好決策樹，用於分類出使用者喜好的音樂。使用者喜好決策樹如下圖 3-5 所示：

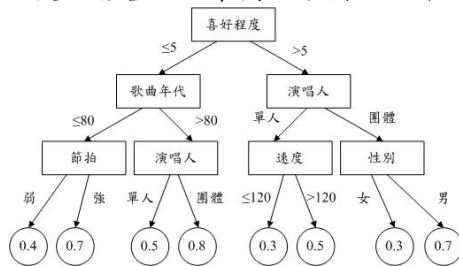


圖 3-5 使用者喜好決策樹

透過使用者喜好決策樹對音樂資料庫中的歌曲進行篩選，初步篩選出使用者喜歡的歌曲後，將篩選出的喜好歌曲輸入激勵性決策樹。慢跑者運動至產生和緩運動腦波變化時，我們利用腦波判斷撥放的歌曲對於使用者是否有激勵的效果，如果撥放該首音樂後，能讓和緩運動狀態腦波減弱，就假定該首音樂對於使用者是具有激勵性的效果。我們記錄慢跑者使用一段時間的系統後，能夠得到音樂對於慢跑者的相關紀錄表格，如下表 3-3 所示：

表 3-3 慢跑者聆聽音樂之特徵與激勵性範例

編號	F_1	F_2	F_3	F_4	F_5	F_6	F_7	激勵性
1	108	66	0.2	0.2	0.7	0.3	0.4	無
4	94	64	0.3	0.4	0.4	0.2	0.3	無
8	137	75	0.6	0.2	1.2	0.4	0.5	有
11	158	94	0.8	0.6	1.9	0.3	0.3	有

上表中的 F_1, F_2, \dots, F_7 是對應前一章節之音樂特徵值。

依據表 3-3 所收集到的特徵值 F_n ，將值再透過分類學習法找出具有激勵性的音樂特

徵，並建立激勵性的決策樹。激勵性決策樹範例如下圖 3-6 所示：

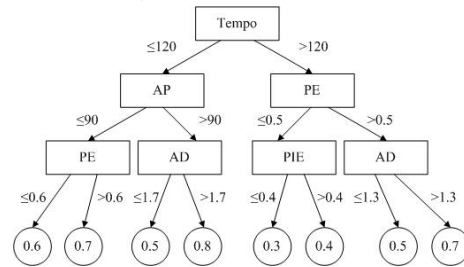


圖 3-8 激勵性決策樹範例

決策樹在學習的過程中可能會遭遇到過度配適(over-fitting)的問題，因此預先限制決策樹的高度，在決策樹產生後進行適當的修剪。

3.4.3 音樂排程機制

當激勵性決策樹模型建立後，系統就可以透過音樂資料庫中篩選出激勵性高的歌曲，並且由此類型的歌曲中隨機挑選一首歌曲進行播放，而使用隨機撥放的原因是為了避免每次所挑選出的歌曲都是同一首音樂(eg. 激勵性最高)。經過我們初步的實驗與觀察發現，如果一直聆聽同樣的歌曲對於慢跑者來說，會使得慢跑者感覺到厭煩甚至立即停止運動，也導致激勵的效用降低。

4. 實驗

4.1 實驗環境

本論文所要記錄的腦波數據資料，是要找出正常運動至產生和緩運動狀態時的腦波變化。實驗皆是在戶外運動場進行腦波資料的收集，資料收集的時間點大部分是在下午趨近於黃昏時段及天氣晴朗且溫度差異性低的狀況下進行實驗。

盡量要求受測者於體力所能承受之範圍進行慢跑，且沒有設定跑步圈數上限，只要尚有辦法不間斷的跑步，即可持續運動至主觀認定無法繼續運動，由正常運動變更為和緩運動為止。為了能夠確實的分析與紀錄出受測者的腦波和運動狀態變化的時間點，過程中除了紀錄腦波數據外，還會錄下受測者進行實驗時影像，以便於分析資料時能做出更為準確的判斷。

4.2 受測資訊

我們的實驗總受測人數共 12 位 (7 男 5 女)，平均年齡為 24 歲(介於 23~27 歲)。受測

者皆未經過腦波相關訓練，並且體力、精神狀態及健康狀況皆正常。有研究指出男性與女性的腦波特性和不相同，但本研究希望能夠觀察男性與女性在產生和緩運動狀態時腦波變化的共同特性，所以將兩性的資料共同處理，並訓練分類器可以判斷任一受測者的腦波狀態。

實驗開始前，會替受測者調整腦波偵測儀器之位置，並調整其運動頭帶及確認儀器位置是否有不適或者鬆動之影響，避免因為運動進行時因不適或設備鬆脫，影響腦波數據之收集，盡可能讓外在干擾因素降到最低的狀況下進行實驗。實驗流程如下圖 4-2 所示：

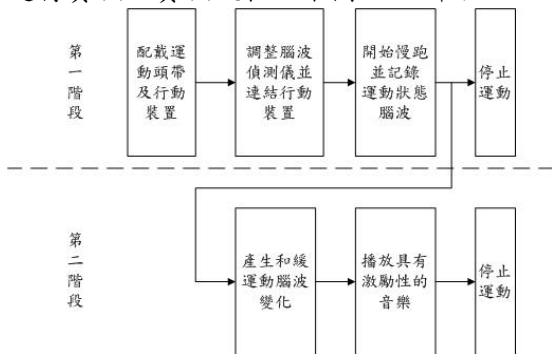


圖 4-2 實驗流程

由於在實驗進行的過程中，我們皆有使用數位相機記錄受測者進行實驗的過程，能夠於資料收集完畢後，觀看錄影畫面區分受測者的運動狀態，藉此標記出受測者正常運動狀態與和緩運動狀態的腦波資料區間。

經由人工標記兩種狀態後，發現正常運動轉換為和緩運動狀態時，腦波所產生的變化只有極短的一瞬間，所以在所收集到的資料數量上較低。因此我們避免腦波數據資料的訓練樣本數量輸入 SVM 分類器的時候，會因為資料數量的比例不同導致影響分類器所產出的正確率，所以將正常運動與和緩運動兩種樣本的數據資料各取每位受測者 200 筆（正常運動狀態與和緩運動狀態各半）腦波數據資料進行計算。

4.3 各項腦波特徵於不同時間軸長度分析

我們使用的分類運算方法為 SVM，利用多項式 (polynomial) 核心函數公式 (4-1) 與不同的腦波特徵值排列組合進行實驗，比較各種組合下辨識率好壞。

$$K(x_i, x_j) = (x_i^T \cdot x_j + 1)^d \quad (4-1)$$

跑步所觀測的腦波是一種持續性的狀況，所以除了各項特徵值的比較，還會以不同時間軸長度進行分類正確率的比較，並以公式 (3-3) 及 (3-4) 調整不同時間軸長度下的數據資料。

表 4-1 各項特徵值之分類正確率 (n=1)

	α	β	R	$\alpha + \beta$	$\alpha + R$	$\beta + R$	$\alpha + \beta + R$
平均 Training	50.18	50.26	50.19	60.98	56.78	62.02	66.15
平均 k-fold	49.79	50.04	49.78	60.65	56.64	61.12	65.87
最高 Training	50.64	50.77	50.64	61.65	57.25	62.73	66.83
最高 k-fold	50.04	50.64	50.27	61.35	57.16	61.88	66.34

在表 4-1 中，我們看到輸入各種排列組合所得到的結果；兩種特徵組合中， β 波是一項略優於影響分類正確率的特徵；而輸入三項特徵值時，所得到的分類正確率是為最佳值。

我們將七項特徵值的時間軸逐步增加，分析何種時間軸長度會有較佳的分類正確率產生。此部分實驗的時間長度將從 2 開始，直到輸入 n 所產生的分類正確率小於 n-1 的分類正確率，且往後觀察 n+3 分類正確率的波動幅度皆為平緩時停止。

表 4-2 時間軸長度為 2 之分類正確率

	α	β	R	$\alpha + \beta$	$\alpha + R$	$\beta + R$	$\alpha + \beta + R$
平均 Training	50.79	50.91	50.79	61.65	57.34	62.74	66.86
平均 k-fold	50.62	50.84	50.43	61.17	56.94	62.23	66.54
最高 Training	51.14	51.56	51.15	62.09	57.87	63.33	67.43
最高 k-fold	50.99	51.19	51.03	61.98	57.61	62.82	67.25

表 4-2 中，與時間軸長度 n=1 相比，發現將時間軸長度增加為兩秒時，對於資料的辨識並沒有較為明顯的差異，因此我們將繼續觀察往上遞增的時間軸長度在分類正確率上是否會有更佳表現。

表 4-3 時間軸長度為 3 之分類正確率

	α	β	R	$\alpha + \beta$	$\alpha + R$	$\beta + R$	$\alpha + \beta + R$
平均 Training	51.54	51.88	51.66	62.36	58.11	63.69	68.28
平均 k-fold	51.41	51.69	51.45	61.98	57.88	63.17	68.06
最高 Training	52.03	52.67	52.05	62.84	58.48	64.12	68.94
最高 k-fold	51.71	52.08	51.98	62.47	58.25	63.89	68.68

在表 4-3 我們可以發現到與 n=2 時相比，所有的特徵值皆有微幅的成長，但是與 n=1、n=2 的分類正確率差異性不大。而在七項特徵值當中，輸入 $\alpha + \beta + R$ 此項特徵值的分類正確率為最高，因為尚未達到所設定的停止條件，因此我們繼續將值往上遞增為 n=4 進行分析。

表 4-4 時間軸長度為 4 之分類正確率

	α	β	R	$\alpha + \beta$	$\alpha + R$	$\beta + R$	$\alpha + \beta + R$
平均 Training	53.11	53.79	53.23	64.15	60.22	65.31	70.91
平均 k-fold	52.98	53.31	53.01	63.88	59.77	64.27	70.59
最高 Training	53.54	54.27	53.83	64.58	60.87	65.98	71.72
最高 k-fold	53.21	53.86	53.37	64.24	60.36	65.57	71.63

在表 4-4 我們發現當時間軸長度設定為 4 的時候，所有輸入的特徵值比起 n=1 時上升了 3% ~ 5%，單一特徵值的分類正確率比起 n=1 的值大約提升了 3%，而且特徵值 $\alpha + \beta + R$ 的分類正確率也突破了 70%，但因還尚未達到我們所設定的停止條件，所以我們將時間軸長度再增加 1 秒進行實驗。

表 4-5 時間軸長度為 5 之分類正確率

	α	β	R	$\alpha + \beta$	$\alpha + R$	$\beta + R$	$\alpha + \beta + R$
平均 Training	51.86	52.01	51.97	62.47	58.37	64.11	69.22
平均 k-fold	51.62	51.89	51.73	62.15	58.06	63.89	68.57
最高 Training	52.33	52.77	52.45	62.90	58.86	64.58	69.88
最高 k-fold	51.99	52.38	52.08	62.63	58.51	64.47	69.40

當 n=5 時，各項特徵值的分類正確率比起 n=4 所辨識出來的正確率反而下降，因此我們將往後持續分析到 n+3 的分類特徵值變化，判斷是否達到我們所設定的實驗停止條件。

表 4-6 時間軸長度為 6 之分類正確率

	α	β	R	$\alpha + \beta$	$\alpha + R$	$\beta + R$	$\alpha + \beta + R$
平均 Training	51.62	51.84	51.72	62.21	58.16	63.87	68.99
平均 k-fold	51.33	51.63	51.58	61.93	57.83	63.61	68.36
最高 Training	51.98	52.58	52.22	62.69	58.61	64.35	69.64
最高 k-fold	51.73	52.17	51.86	62.44	58.25	64.22	69.17

當 n=6 的時候我們觀察各項特徵值的分類正確率皆比 n=5 時略低，所以我們將繼續觀察 n=7 的分類正確率是否逐漸趨近於平緩。

表 4-7 時間軸長度為 7 之分類正確率

	α	β	R	$\alpha + \beta$	$\alpha + R$	$\beta + R$	$\alpha + \beta + R$
平均 Training	51.71	51.93	51.81	62.33	58.27	64.01	69.11
平均 k-fold	51.42	51.77	51.66	62.12	57.96	63.72	68.47
最高 Training	52.03	52.70	52.34	62.81	58.73	64.47	69.73
最高 k-fold	51.88	52.25	51.99	62.56	58.40	64.32	69.28

我們觀察到當 n=7 時的分類正確率與 n=6 的分類正確率相比變化並不大，已經漸漸趨近平緩，因此我們將觀察到 n=8 為止。

表 4-7 時間軸長度為 7 之分類正確率

	α	β	R	$\alpha + \beta$	$\alpha + R$	$\beta + R$	$\alpha + \beta + R$
平均 Training	51.66	51.88	51.76	62.27	58.21	63.96	69.06
平均 k-fold	51.37	51.72	51.61	62.08	57.90	63.67	68.43
最高 Training	51.98	52.65	52.28	62.74	58.68	64.41	69.67
最高 k-fold	51.83	52.19	51.93	62.50	58.34	64.27	69.22

表 4-7 中，n=8 的分類正確率與 n=6、n=7 的分類正確率相比已經趨近於平緩，也因此達到我們所設定的實驗停止條件，故我們將 n=2~8 中，皆為最高分類正確率的特徵值 $\alpha +$

$\beta + R$ 取出進行比較，如下所示

表 4-8 各時間軸長度 $\alpha + \beta + R$ 之分類正確率

	n=1	n=2	n=3	n=4	n=5	n=6	n=7	n=8
平均 Training	66.15	66.86	68.28	70.91	69.22	68.99	69.11	69.06
平均 k-fold	65.87	66.54	68.06	70.59	68.57	68.36	68.47	68.43
最高 Training	66.83	67.43	68.94	71.72	69.88	69.64	69.73	69.67

我們觀察時間軸長度 n 往上遞增，為的就是找出設定的時間軸長度為何，能夠觀察到最佳的分類正確率，以及最容易辨識出受測者產生想要從正常運動變換為和緩運動的腦波狀態。經過實驗證實後，我們將觀察的長度遞增，分析出時間軸長度設定為 5-8 秒的分類正確率並未高於時間軸長度設定為 4 秒的時候，並且當時間軸 n=5 之後的分類正確率變化已趨近於平緩，因此我們將所得到的最高分類正確率結果的時間軸長度 4 秒判定為最佳觀察慢跑運動腦波變化的時間軸長度。

在最高分類正確率中，可以觀察到 n=4 的最高分類正確率趨近於 72%，而特徵值 $\alpha + \beta + R$ 與 α 、 β 、 R 三項單一特徵值的最高正確率相比，平均提升了 17%；與 $\alpha + R$ 、 $\beta + R$ 、 $\alpha + \beta$ 三項兩兩特徵值的最高正確率相比，約提升了 5% ~ 10% 左右；且與其他的時間軸 (n=1,2,3,5) 相比，平均與最高分類正確率差距為 2~5%，遂認定時間軸長度為 4 的時候，所能辨識的腦波數據資料為最佳的時間軸長度。

在實驗第一部份的結果中顯示，在慢跑運動中， β 波對於分類的正確率影響較高，而在特徵值的應用上，我們使用了七項特徵值，並且逐一比較分類正確率，得出最高的分類正確率是在 α 、 β 、 R 三種特徵同時使用時最佳，如果缺少其中一項特徵則正確率會略微下降；而我們的研究中沒有使用到 δ 與 θ 兩種腦波的原因，是因為此兩種腦波是與睡眠較為相關，對於運動狀況來說，此兩種腦波並不會影響運動者的狀態。

4.4 激勵性音樂推薦結果

在此階段的實驗中，將會測試所設計的激勵性音樂推薦機制是否能有效的激勵慢跑運動者。此部分實驗的受測者為 4 人 (3 男 1 女)。在實驗的第一階段，我們會收集四位受測者平時聆聽音樂的記錄資料，並將記錄資料輸入到使用者喜好決策樹中，用於分類出使用者喜好的音樂，音樂資料庫中的歌曲共有 100 首，由於一首歌曲的演奏時間約為 3~5 分鐘，因此我們將由音樂資料庫中篩選出 15 首歌曲進行推

薦，並詢問使用者推薦的喜好歌曲正確數量，使用者喜好歌曲辨識精確率的公式如下。使用者喜好歌曲辨識率如表 4-9 所示：

$$\text{使用者喜好辨識率} = \frac{\text{使用者喜好音樂數量}}{\text{喜好決策樹推薦音樂總數量}} \times 100\% \quad (4-2)$$

表 4-9 使用者喜好歌曲辨識精確率

受測者 天數	A	B	C	D
Day1	40	33	40	33
Day2	53	40	53	40
Day3	67	53	67	53
Day4	67	67	73	53
Day5	73	73	80	67
Day6	80	73	86	73

實驗是在模擬器上進行，系統會記錄歌曲播放的過程中，受測者的腦波變化情況，當受測者的腦波產生和緩運動狀態變化時，系統將會由所挑選出來的使用者喜好歌曲中挑選具有激勵性的音樂並推薦給慢跑者聆聽，受測者聆聽所推薦的歌曲後如果能再持續運動一段時間，則我們將此次稱為成功的推薦。所有受測者皆擁有自己的決策樹，決策樹一段時間會更新一次，評估激勵性音樂推薦機制的效能定義如下：

$$\text{推薦精確率} = \frac{\text{成功推薦激勵性歌曲數量}}{\text{推薦使用者之喜好歌曲數量}} \times 100\% \quad (4-3)$$




圖 4-3 激勵性音樂推薦精準率

我們請 4 位受測者各進行了六天的實驗，實驗的結果如圖 4-3 所示，由於剛開始的實驗只有受測者的以往聆聽音樂的記錄資料能使用，因此所播放的歌曲大多是隨機推薦與受測者喜好相似的歌曲。從第二次實驗開始，由於決策樹的資料已經建立完成，因此所推薦的歌曲基本上都已經具有激勵性的效果，實驗進行了六天後推薦精確率已經趨於穩定的狀況，從實驗數據可以看出，決策樹的樹高到達一定高度後，對於推薦的精確率並沒有大大的差異。

5. 結論與未來展望

本研究是將腦波運用在觀察慢跑運動上，主要目的是希望能夠藉由腦波的觀測找出在慢跑運動時，慢跑者因為主觀認定無法繼續正常運動，從而轉變為走路時的腦波變化；並且觀察在產生和緩運動腦波變化時，聆聽何種類型的音樂清單對於慢跑者有最佳的幫助，能夠藉此提升運動的時效。在實驗中我們透過量化腦波數據的方式，對特徵值進行排列組合，將各項特徵值進行搭配並透過一連串的實驗與計算，每個特徵值對於分類的正確率有不同的影響；在慢跑運動的狀態下，影響腦波辨識正確率最佳的特徵值為 β 波，而能觀察到最佳分類正確率的特徵值則是 α 、 β 及特徵值 R 三項特徵同時進行辨識的時候；經由實驗結果得知，時間軸長度設定為 4 秒，對於腦波觀測能夠得到較為顯著的分類正確率。

而我們除了偵測與分析慢跑運動狀態的腦波數據之外，另外還設計了一套能判斷使用者喜好音樂的激勵性音樂推薦機制，此推薦機制是依據慢跑者聆聽音樂的歷史紀錄，從音樂資料庫中挑選出使用者所喜好的音樂，再透過腦波變化學習所挑選出來的喜好音樂中，哪些音樂對於慢跑運動者擁有激勵性的效果，讓其能夠延長運動的時間。經由實驗證明，我們所設計的音樂推薦機制對於慢跑者的運動狀態具有激勵的作用。在過去許多腦波與運動的相關研究中，有學者運用腦波偵測觀察職業運動員在賽前的熱身時，聆聽音樂能夠使得運動員於競賽時有較好的成績，也有研究指出，在專注於運動時大腦的腦波變化情況；但是，對於某項運動進行較為深入的觀察腦波變化，這一類型的相關研究較為不普遍，所以本研究對於慢跑運動進行觀察的結果，希望能夠幫助往後進行此方面研究的學者或研究人員。

在我們的研究中，進行實驗的環境大多是在天氣晴朗且氣候宜人的情況下偵測腦波數據資料，並沒有在差異性極高的天氣狀況下進行腦波數據資料的收集，因此希望往後的研究者能夠藉由我們所分析出的結果，於後續實驗中在不同的環境下進行分析。我們在本論文中用於腦波分類的方法為 SVM，核心函數則是使用 PolyKernel 函數，選擇使用 SVM 主要是因為我們是將腦波分為兩類，正好符合 SVM 的分類方法，且使用 PolyKernel 函數比起其他核心函數能夠得到更佳的分類正確率。用於音樂推薦的方法為決策樹，選擇決策樹的原因是因為音樂具有多項特徵，而為了能夠更為準確的

辨識出使用者喜好的歌曲，因此我們選擇此方法。但是，在分類方法中還有許多種，如：k最近鄰居演算法 (k-Nearest Neighbor, 簡稱kNN)、類神經網路演算法(Artificial Neural Network, 簡稱ANN)等，也希望之後的學者可以嘗試使用其他種方法，並以本實驗的結果為基礎，嘗試能否提升腦波分類辨識的正確率，除了偵測腦波資訊之外，也可以搭配心率帶或其他類型的生理資訊偵測儀器進行實驗，再者，也可以搭配影像辨識進行更多元化的辨識。

誌謝

本文由國科會"以3G網路傳輸為基礎之智慧型車載音響系統整合設計與實作"(NSC-102-2218-E-020-002-)經費支援，特此誌謝。

參考文獻

- [1] 韓歆儀，“應用兩階段分類法提昇 SVM 法之分類準確率”，*成功大學工業與資訊管理學系碩士論文*，2004。
- [2] 許示佐，“不同音樂節奏對踏步機運動者影響成效之研究”，*大葉大學休閒事業管理學系碩士論文*，2009。
- [3] 朱璿瑾，“運用腦波識別專注狀態”，*屏東科技大學資訊管理研究所碩士論文*，2013。
- [4] Chen, H. C. and Chen, Arbee L. P., “A music recommendation system based on music data grouping and user interests”, *Proceedings of the tenth ACM international conference on Information and knowledge management*, pp. 231-238, 2001.
- [5] Costantini, G., Casali, D. and Todisco, M., “An SVM based Classification Method for EEG Signals”, *Proceedings of the 14th WSEAS international conference on Circuits*, pp. 107-109, 2010.
- [6] Hasegawa, C. and Oguri, K., “The effects of specific musical stimuli on driver’s drowsiness”, *Intelligent Transportation Systems Conference, ITSC’06*, pp. 817-822, 2006.
- [7] Heitmann, B. and Hayes, C., “Using linked data to build open, collaborative recommender systems”, *Association for the Advancement of Artificial Intelligence*, pp. 76-81, 2010.
- [8] Huang, Y.C. and Jenor S.K., “An audio recommendation system based on audio signature description scheme in MPEG-7 Audio”, *IEEE International Conference on Multimedia & Expo*, pp. 639-642, 2004.
- [9] Li, J. and Wang, W., “Extracting impact characteristics of sports training on EEG by genetic algorithm”, *Proceedings of the IEEE First International Workshop on Complexity and Data Mining*, pp. 76-79, 2011.
- [10] Liu, N. H., Lai, S. W., Chen, C. Y. and Hsieh, S. J., “Adaptive music recommendation based on user behavior in time slot”, *International Journal of Computer Science and Network Security*, Volume 9, pp. 219-227, 2009.
- [11] Liu, N. H., “Comparison of content-based music recommendation using different distance estimation methods”, *Applied Intelligence*, Volume 38, pp. 160-174, 2013.
- [12] Logan B., “Music recommendation from song sets”, *International Conference on Music Information Retrieval*, pp. 425-428, 2004.
- [13] Noachtar, S., Binnie, C., Ebersole, J., Mauguière, F., Sakamoto, A. and Westmoreland, B., “A glossary of terms most commonly used by clinical electroencephalographers and proposal for the report form for the EEG findings”, *International Federation of Clinical Neurophysiology*, pp. 21-41, 1999.
- [14] Steffen, P. and Sander, V. W., “User evaluation of a new interactive playlist generation concept”, *International Conference on Music Information Retrieval*, pp. 638-643, 2005.
- [15] Tso-Sutter, K. H. L., Marinho, L. B. and Schmidt-Thieme L., “Tag-aware recommender systems by fusion of collaborative filtering algorithms”, *Proceedings of the 2008 ACM symposium on Applied computing*, pp. 1995-1999, 2008.
- [16] Vapnik, V.N., “*Statistical Learning Theory*”, 1995.
- [17] Yeo, Mervyn V. M., Li, X., Shen, K. and Wilder-Smith, Einar P.V., “Can SVM be used for automatic EEG detection of drowsiness during car driving?”, *Journal of Safety Science*, Volume 47, Issue 1, pp. 115-124, 2009.