

運用腦波識別專注狀態

朱璿瑾
國立屏東科技大學資訊管理系
研究生
sassnd@gmail.com

江政祐
國立屏東科技大學資訊管理系
研究生
djmb3567@gmail.com

劉寧漢*
國立屏東科技大學資訊管理系
副教授
gregliu@mail.npust.edu.tw

摘要

人們透過多元的方式獲取知識與經驗，但大部分的人在成長過程中，是經由就學吸收新知，而學習的過程中，專心(Attention)的意識對於學習的成效有一定程度的影響，因此，學生能不能專心於課堂學習之上，為其學習成功與否的依據，倘若老師能即時知道學生是否專心，將可以適時地提醒學生、改善學習情況。本研究以觀測腦波的方式，辨識出學生在課堂上的專心與非專心(Inattention)狀態。首先，運用科學儀器進行腦波偵測並予以紀錄，接著將收集到腦波數據值，利用人工的方式過濾無效數據，再結合 Support Vector Machine(支援向量機，SVM)分類器進行運算、分析，便能辨識出二類型腦波數據值(專心 v.s. 非專心)。在研究中正確的辨識率最高可達 71.17%。

關鍵詞：腦波、專注狀態、腦波辨識、腦波分類、支援向量機

Abstract

Human got the knowledge in various ways, but mostly from school. In the process of learning, attention affects the learning result. In the other words, attention is a basis of learning well. If a teacher can find immediately that a student is not concentrative, then the teacher can alert the student to improve the learning attitude at the right moment. This research is expected to recognize the EEG signal as attention or inattention through EEG measure. First, we used the wireless apparatus to measure and record EEG signal. And all the useless data were filtered manually. Finally, we used Support Vector Machine (SVM) classifier to calculate and analyze the data. The classifier can recognize EEG data as two classes (attention or inattention). According to our experiment results, the attention recognition rate in this research is 71.17%.

Keywords: Electroencephalogram, Attention Status, EEG Recognition, EEG Classification,

Support Vector Machine.

1.前言

人們不論是在運動、放鬆、思考，甚至是在睡眠時，大腦的神經細胞依然會不停活動、互相傳遞訊息，而在傳送訊息的同時會發出各式各樣不同頻率的微量電磁波，這些電磁波即是大家所謂的腦波(Electroencephalogram, EEG)。腦波就和心跳、血壓、呼吸一樣，是自然的生理現象、資訊，普遍來說，平常人在無特別訓練的情況下，是無法隨意控制腦波的變化。而且各式生理行為、心理狀態會形成不同的腦波表現，利用人類身體本能產生出來的生理資訊，作為觀察的對象是最直接且不易捏造的。所以利用腦波識別出學習者是否處於專注(Attention)的學習狀態為此研究之主軸。

現在學生的上課方式，除了正統的師生面對面授課方式以外，還因科技帶來的便利性，讓人們可以何時、何地都能進行學習，例如：數位式教材學習、遠距教學(Distance Learning)等。也因為學習管道、方式變多了，要確實掌握學生專注的狀態變得困難。學習過程中，除了教材的幫助外，更重要的因素則是學生的學習態度與熱情。根據本研究的主軸，將在學習的過程中，擷取腦波之數據，觀測是否屬於專注狀態，希望研究成果可幫助人們有更佳的學習成效。

在過去文獻中，幾乎沒有人利用課堂學習作為研究環境。因此，本研究以此作為出發點，透用腦波當作媒介來觀察人們在學習時的有無專心，並藉由觀測到的腦波數據、結合分類器，識別出人類專心時的腦波為何，希望能利用簡易的腦波偵測及分類方法，來觀測、判斷學習者是否專心，這樣子授課的老師或聽課的學生便能了解學習時的專心情況，藉此雙方皆能做適度的調整。

2.相關研究

本章節主要所探討的文獻包含腦波生理資訊、腦波與專心度、腦波與學習之相關研究方法。

2.1 腦波生理資訊

*通訊作者

最早在 1875 年，位於英國利物浦的生理學教授李查克通(Richard Carton)[2]，首次在兔子大腦皮質表面上發現電波，其屬於一種腦部生理變化，並與身體變化有關。直至 1924 年，一位德國精神科醫師漢斯伯格(Hans Berger)，在人類的頭蓋骨上紀錄到相同的電波活動，並藉由圖表來捕捉、描繪腦波[9]，此為首次發表人類的腦波記錄，並且命名為腦電波圖(Electroencephalogram)，簡稱為 EEG。

由於腦波和人的各種意識及活動都有某些程度的對應關係，因而引發許多研究者之興趣，爾後腦波便開始被應用在各醫學領域，直到現在腦波已被廣泛運用在各種研究領域，例如：醫療方面，可用來篩檢病患以及腦疾病人的追蹤檢查，像是過動、中風、腦炎、癲癇、昏迷、和其他腦疾等；在學術、遊戲、生活應用和腦機介面(Brain Computer Interface, BCI)方面，近幾年腦波更是熱門的議題；

早在 1970 年時，由 Vidal 等學者提出腦機介面(Brain Computer Interface, BCI)的概念[13][14]，其主要是利用 BCI 系統作為人類和外界溝通的工具，將測量到的腦波資訊轉成命令，再運用硬體設備去實現動作。Reinhold S. 等人曾發表 Neuroscience Letters 系統[21]，將腦波利用費雪線性鑑別分析(Fisher's linear discriminant analysis, FLDA)作分類，使這套系統能利用想像下、左、右三個方向的腦波，發展成虛擬鍵盤(Virtual Keyboard)系統進行拼字。

在 1997 年時，有研究者運用腦波的功率頻譜(Power Spectrum)進行研究分析，發現 EEG 的功率頻譜可映射出人類腦波靈敏狀態(Level of Alertness)的波動[25]。另外，還有學者用 EEG 來評估人的精神疲勞[18][27]，或者是做音樂感受的辨識[17]、人類情緒辨識[15][31]、各類運動表現的觀察[24]，還有利用腦波控制小型機械車移動的方向、完成變換病床高低等。

依據臨床生理學會國際聯盟(International Federation of Societies for Electroencephalography and Clinical Neurophysiology)[20]提供的資料，腦波以頻率來區分，常見的大致可分為四大類：alpha 波、beta 波、delta 波及 theta 波，各腦波所代表頻率如表 2-1 所呈現，各腦波的波形如圖 2-1 所示。而且每個人的內在與外在行為及學習上的表現，會產生不同腦波的組合。

表 2-1 各腦波代表的頻率

腦波名稱	頻率
α 腦波(Alpha waves)	8~13 Hz
β 腦波(Beta waves)	14~30 Hz
δ 腦波(Delta wave)	0.5~3 Hz
θ 腦波(Theta waves)	4~7 Hz




圖 2-1 腦波種類與波形(資料來源：文獻[10])

2.2 腦波生理資訊

目前在腦波與專注、學習方面的相關研究尚未完全成熟，在近期學者、研究者漸漸投入此研究領域，而有些部分的研究是為了輔助遠距教學[28][29]。因為遠距學習的關係，師生之間並無法實際面對面的接觸，所以比起一般師生面對面授課教學方式，更無法得知學生當前的學習狀態，因此才讓學者、研究者興起研究腦波與學習、專心之間的關係。

在 2001 年時，由 Ivan 等人[12]觀測 alpha 腦波研究新手(Novices)及專家級(Experts)老師授課，以及利用文字、多媒體(Multimedia)教學課程之腦波的變化情況，結果顯示學生在專家級老師的教學下，學習力可以比較控制，而多媒體的教材也比文字性教材更容易刺激腦部活動。

在 Xiao-Wei Li 等人的研究[29]中，其開發一套情感學習(Affective learning)系統，並結合 kNN (k-nearest neighbor, k-最近鄰居法) 和 Naïve Bayes (簡單貝氏法) 二種分類法作為研究方法，藉由 alpha、theta 共 13 處的腦波電位資料之收集，利用上述二種分類法對學生的情感和態度進行檢測，以求識別出學生的專注程度，其實驗結果數據中，最佳辨識率可達為 66.7%，但平均為 44.4%。

Yong-Chang Li 等人[30]是以 EEG 為觀察目標，讓受測者做有關腦力任務(Mental Tasks)的實驗，並要求受測者要回答其專注程度，再用 kNN 分類法作為研究方法，設計一套即時系統來測量受測者的專注力水平，其系統平均的分類準確率達 57.3%。

Ashwin 等人[5]利用 EEG 和 ECG (心電圖, Electrocardiograph) 做專注力的分類準確度比較, 以觀看有趣、無趣的影片各 20 分鐘作為實驗方式, 再用 Regression (回歸)、C4.5 (決策樹法)、Random Forest (隨機樹林法) 作分類計算。在二種檢測生理資訊方法的結果中, 顯示 EEG 的分類準確度比 ECG 多 8.74%, 由此可見, 用 EEG 來做為觀測的對象是較為妥當的, 而且 EEG 含有許多不同的資訊, 更值得學者們繼續研究並將其做更多的應用。

在 Sheng-Fu 研究[23]中, 利用 EEG 測量的方式, 針對放鬆、上網、慢跑、靜坐四項活動專注力表現的觀察, 實驗結果指出, 四項活動專注度的優先順序為: 慢跑 > 靜坐 > 放鬆 > 上網, 因為該研究作者表示, 休息時可做簡易的運動來幫助專注力的提升, 而不是盲目的放鬆。

2.3 Support Vector Machine(支援向量機)

Support Vector Machine (SVM)是由 Vapnik 於 1995 年所提出的[26], 為一種監督式的學習方法, 用來解決二元分類的問題, 一般多用於統計分類和迴歸的問題上[16]。

Remi 等人[22]研究結合 SVM 與拉普拉斯算子(Laplacian)二種分類方法, 使得腦部圖像的成影結果能更容易解析, 連 3D 腦圖像與二層大腦皮質之間也能利用該技術成像, 最後經由年長者與阿茲海默症患者各 30 受測者的腦圖像作對照並分類, 實驗比較後證實, 大腦的剖學圖像和其腦圖像的成影之結果是相同的。

Giovanni 等人[8]是將腦波訊號進行 SVM 分類而設計出一套 BCI 系統, 能辨別簡單的數學運算或是移動左、右手等腦波訊號。

而 Jrad N. 等人[19]的研究提出權重式 (Weighting)概念的 SVM, 設計出分類腦波訊號的框架, 研究結果顯示 sw-SVM(Sensor Weighting SVM)對資料集和錯誤相關電位資料集(Error-related Potential, ErrP)之分類是有效的, 而此種分類方式對少量訓練樣本之事件相關電位(Event-Related Potential, ERP)的分類也有用。

3.研究方法

雖然每個人對於同一學習內容的專心程度不同、腦波的變化也不盡相同, 在此研究中希望能以便利、簡單的方式, 找出普遍情況下, 人們在專心學習時的腦波變化, 因此我們利用模擬的方式, 先針對實驗對學習者的影響(專心與否)及相關腦波資料進行收集、分析, 再運用 SVM 分類器分類對已處理過的資料作

運算, 進而達成此研究的目的。圖 3-1 為本研究之架構圖。

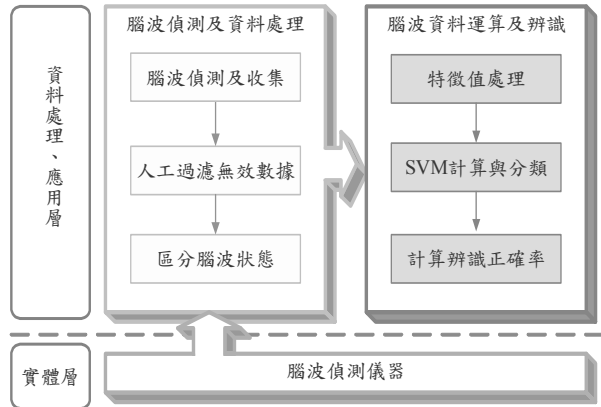


圖 3-1 研究架構圖

首先會先利用腦波偵測儀器, 對受測者進行學習時的腦波收集, 並經由腦波偵測及資料處理模組對資料進行篩選及前置處理, 最後利用腦波資料運算及辨識模組對資料作計算及分類, 進而求得專心與非專心之分類結果。

3.1 腦波偵測及資料處理模組

3.1.1 腦波偵測儀器

為了模擬課堂環境, 此研究採用可攜性高的無線式腦波偵測儀器, 如圖 3-2 所示。此腦波偵測儀器可從大腦中檢測出微弱腦波訊號予以數據化, 並以無線傳輸的方式回傳於硬體設備中。



圖 3-2 腦波偵測儀器與佩戴方式

經過一個世紀的實驗, 神經系統科學領域的專家們已經定義了大腦中控制具體活動的部位, 例如: 控制四肢的區域位於大腦的頂部, 而負責視力的區域位於大腦的後部。從進化論的角度看, 大多數動物的大腦也具備這些功能。隨著人演化為較高級的物種, 大腦前額處的皮質產生了更高級的思維, 人的情緒、精神狀態及專注狀態都受這個區域的控制。因此本研究所使用的腦波偵測儀器, 其電極位置於前額的 Fp1 處(參考圖 3-3 的國際 10-20 制腦波電極位置)。




圖 3-3 國際 10-20 制腦波電極位置

3.1.2 腦波數據收集

研究中使用的腦波偵測儀器採樣率為 512Hz，每次 1000 個取樣點，一秒為一個單位，將收集到的腦部原始訊號利用快速傅立葉轉換(Fast Fourier Transform, FFT)從時域(Time Domain)轉成頻域(Frequency Domain)，接著將各腦波波段對應的頻率區段之振幅(Amplitude)平方後並加總，即為研究用之數據。圖 3-4 為腦波收集程式的操作畫面，由 C#語言撰寫而成，在紀錄腦波的同時亦可紀錄受測者的影像和周遭聲音。



圖 3-4 腦波收集程式畫面

3.1.3 人工過濾無效數據

收集到的腦波數據中，有可能會因為以下情況造成腦波數據資料無法正確測量及收集，而導致不正確的數值產生：

- 一、有物品完全遮蔽腦波偵測儀器的接收器，造成腦波偵測儀器和接收器之間無法正常傳遞及接收資料。
- 二、受測過程中，腦波偵測儀器電力不足，造成腦波資料無法偵測及傳輸。
- 三、在實驗過程中，腦波偵測儀器移位，或者是測量電極無法和受測者肌膚接觸。

本研究中，以人工操作的方式予以檢視，以及排除這些會影響研究結果的數據，例如：腦波數據前後重複、數值過高、數值過低或為零。

3.1.4 區分腦波狀態

在此研究中以人工的方式，區分出哪一些受測者的腦波數據為專心或者是不專心，並在分類器計算、分類完後，作為判讀辨識正確率之用。

本研究是透過實驗收集受測者的腦波，而進行的方式是讓受測者聆聽英文句子，並於聆聽後要求作答(詳情於第四章節中描述)。此處

區別腦波狀態的作法，是在完成腦波相關資料收集後，批改受測者的英文作答是否正確，並以腦波收集程式所錄製的影片、聲音以及作答結果作為區分腦波狀態的依據。

如果影片中受測者神態、動作是專心，加上作答答案是正確的，我們就判定其對應的腦波資料為專心；反之，不專心的腦波狀態判斷亦是如此。倘若從影像裡無法清楚辨識狀態的話，我們會與受測者一起檢視影片片段、並訪問受測者當時的狀態為何，藉由以上作法便能以較客觀的方式，區分出哪些腦波數據為受測者專心和不專心的腦波。

3.2 腦波資料運算及辨識模組

3.2.1 特徵值處理

在研究中收集的四種腦波之數據資料作為研究用特徵值：alpha (8 ~ 13 Hz)、beta (14 ~ 30 Hz)、delta (0.5 ~ 3 Hz)、theta (4 ~ 7 Hz)。

在過去的研究[10]中，顯示 alpha 和 beta 存在著一定的相互關係，例如：alpha 代表大腦放鬆的狀態，beta 代表大腦活躍的狀態。而在該研究中，為了觀察受測者的連續性的精神狀態變化(具有時間序列性的研究)，利用 alpha、beta 二個腦波值做簡易平均值除法運算(如公式 3-1、3-2)，並用算出來的 R 值(如公式 3-3)作為觀測受測者精神專注狀態之用，其公式如下：

$$\alpha_{avg.} = \frac{1}{N} \sum_{k=1}^N \alpha_k \quad (3-1)$$

$$\beta_{avg.} = \frac{1}{N} \sum_{k=1}^N \beta_k \quad (3-2)$$

$$R = \frac{\alpha_{avg.}}{\beta_{avg.}} \quad (3-3)$$

通常人類專心都是一個持續性的表現，並且可以保持一段時間，但考量[10]採用從頭到尾累加的作法，若觀測時間越長，R 值便會平均越多數值，會造成平均值會被某一極大值、極小值所影響，或者是極大值、極小者會因為平均之後，而無法明確觀測到，造成受測者的精神狀態越不易判讀。

為了避免上述盲點，所以在此研究中改為每三筆資料作為一個觀察的單位。此二個特徵值是每一位受測者分別計算後，才將所以特徵值資料作合併，並在第四章的部分進行實驗比較和結果的呈現、說明。此二項特徵值介紹如下：

- 一、為單一筆資料中，新增一個該筆資料的 α / β 值，用來觀察該筆數據的腦波狀態，算

法如下方公式 3-4 所示。

$$\frac{\alpha}{\beta} = \frac{\alpha_n}{\beta_n} \quad (3-4)$$

n 為該筆資料筆數

二、則是以每三筆資料為一個觀察單位，並且作平均值計算，觀察片段性的腦波狀態，例如：第三筆資料 $\alpha_{avg.}/\beta_{avg.}$ 值，其計算的方法就是公式 3-5 的 n 代入 3 即可，後續其他值的計算以此類推，算法如下方公式 3-5 所示，但第一、二筆資料因無法構成每三筆為一單位的要素，遂於計算後剔除之。

$$\frac{\alpha_{avg.}}{\beta_{avg.}} = \frac{\sum_{i=n-2}^n \alpha_i}{\sum_{i=n-2}^n \beta_i} \quad (3-5)$$

n 為該筆資料筆數

3.2.2 SVM 計算與分類

本研究希望透過 SVM 分類器的規則，在腦波特徵值的高維度空間裡，找出一個能分割專心與不專心腦波數據的超平面(Hyperplane)。




圖 3-5 SVM 示意圖

SVM 的基本觀念如下：在給定一群訓練樣本之下，每個樣本會分別對應至兩個不同的類別(如圖 3-5 的 Old Space)，接著將樣本經由核心函數 (Kernel Function)[4]映射到一個高維度的空間裡(如圖 3-5 的 New Space)，SVM 會嘗試從中建構一個模型，並利用此模型將每一個樣本分配到一個類別上，而這個模型就是要在高維度空間裡建立有一個分隔超平面 (Separating Hyperplane, 如圖 3-5 的紅色實線所示)。而在分開樣本的超平面的兩邊會有兩個互相平行的超平面(如圖 3-5 的黑色虛線所示)，分隔超平面使兩個平行超平面的距離最大化。而且平行超平面間的距離或差距越大，分類器的總誤差越小。

舉例來說：在一個二維的空間裡，有資料點的集合(圖 3-5 中○和△)如下所示。 x_i 為輸入資料； y_i 表示類別目標值；n 為樣本量；d 為輸入維度。

$$\{x_i, y_i\}, i = 1, \dots, n \text{ and } x_i \in R^d, y_i \in \{+1, -1\}$$

希望藉由 SVM 找出一個能劃分這二組資料的直線 $f(x)=w \cdot x - b$ (如圖 3-6 紅線實線所示)能夠使全部 $y_i = -1$ 的點落在 $f(x) < 0$ 這一側，並使全部 $y_i = +1$ 的點落在 $f(x) > 0$ 那一側，這樣便能根據 $f(x)$ 的正號、負號來劃分該資料點是屬於兩個集合中的哪一個，其中 w 是超平面的垂直向量 (Normal Vector)， b 是偏移量 (Bias)。另外也希望能找到分割此二組資料的最大邊界(如圖 3-6 黑色虛線所示)，這樣子在新的資料點加入後，才更明確地知道新的資料是屬於哪組。

3.2.3 核心函數(Kernel)

不同的核心函數處理不同的資料，也因函數使用的不同，而使得分類正確率有所差異。SVM 常見核心函數類有三種：多項式 (Polynomial)、放射型函數 (Radial Basis Function)、S 型(Sigmoid)。

而在王麒瑋[1]和 Hsinyi H.[11]的研究中指出，使用多項式核心函數的分類準確率會較佳，所以在本研究中使用多項式核心函數將特徵值資料映射到高維度空間中，再進行 SVM 的計算與分類，結果將於第四章節呈現、解說。

另外，不採用 RBF 是因為其限定輸入資料需[0,1]之間，以利資料範圍縮小，才可減少運算之複雜度與時間，而本研究腦波數據都是大於 1 的值；不採用 S 型是因為該核心函數需要設定三個相關參數才能完成分類。

3.2.4 驗證方法

採用 k -fold 交叉驗證法 (k -fold Cross-validation)作 SVM 分類器辨識正確率的驗證，將收集到的腦波資料隨機切割成不重複的 k 組，再以 $k-1$ 組作為訓練資料，1 組做為測試資料，共循環作 k 次，以求算最佳的辨識正確率。

在研究過程中，會比較不同的驗證組數之間有無差異，所以會將收集到的樣本數依序分成 2~10 組的方式，進行 SVM 的分類驗證。

4. 實驗分析

4.1 實驗相關資訊

為了確實紀錄受測者的腦波資料和辨識專心情況，實驗過程中除了紀錄腦波數據資料外，還會錄下受測者的實驗時的臉部影像和周遭聲音，以便後續分析資料時能做更有效的判別。

考量課堂上每個人所擁有的座位空間有限，因此在實驗中採用筆記型電腦作為主要的腦波紀錄工具，而且腦波偵測方面，採用便利

性高的腦波偵測儀器，進行腦波訊號的偵測及收集。

4.1.1 實驗環境

在實驗中每位受測者均佩戴同款的腦波偵測儀器，並個別搭配一台筆記型電腦及一組喇叭，使每一次實驗的環境品質能一致，也讓受測者能在最恰當的音量下進行實驗。實際的實驗現場佈置如圖 4-1 所示。



圖 4-1 實驗實境照

4.1.2 硬體設備

在硬體筆記型電腦方面，我們採用的配備規格如下：

- 處理器(CPU)：Genuine Intel® CPU U7300 1.3GHz
- 記憶體(RAM)：2.0 GB
- 硬碟(Hard Disk)：300 GB
- 作業系統(Operating System)：Windows 7

4.1.3 受測者

- 總受測者人數：14 位 (12 男 2 女)
- 受測者平均年齡：24 歲(受測者年齡介於 22~27 歲)
- 所有受測者聽力、精神狀態及健康狀況皆正常，而且無受過腦波相關訓練。

4.1.4 實驗流程

為求能清楚辨識出學習者在學習時的專心腦波情況，所以在此研究的實驗，使用正規課堂的英文教材作為此研究之實驗題材，讓受測者以聆聽英文句子，並要求聽完句子後作答(題目類型：看圖填順序、看圖勾選答案或單選題)的方式，讓受測者在實驗中能確實專心。




圖 4-2 實驗流程圖

此實驗流程如圖 4-2 所示。實驗開始後，會先請受測者戴上腦波偵測儀器 2 分鐘，藉此

先讓受測者熟悉腦波偵測儀器的存在，避免受測者因為佩戴時的不適，而影響實驗結果之正確性，同時測試喇叭音量，使受測者能在最適當的音量下作實驗。

接下來，每位受測者都需要接受二部分(每一部分各為 22 題)，共 44 題的測驗：

Part 1. 模擬專心的狀態：無任何干擾的情況下，聆聽英文對話後作答。

Part 2. 模擬非專心的狀態：旁邊有 2 人對話的干擾情況下，聆聽英文對話後作答並寫下 2 人對話內容。

4.1.5 腦波數據筆數

- 總數據筆數：4,644 筆
- 有效數據筆數：4,291 筆
- 無效數據筆數：353 筆

4.2 實驗說明

此次實驗使用SVM作為主要運算方法，並利用多項式核心函數下的二種核心函數(公式如下公式4-1、4-2所示)[7]，以及調整懲罰權重值(Cost，在研究中以C作為代表符號)的方式，加上各種不同腦波特徵值的組合進行實驗計算，最後以 k -fold 交叉驗證法 (k -fold Cross-validation)作辨識正確率的驗證。

實驗中所使用的二種多項式核心函數如下所示：

PolyKernel(多項式)：

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

NormalizedPolyKernel(正規化多項式)：

$$K(x_i, x_j) = (x_i^T \cdot x_j + 1)^d / \sqrt{x_i^{T+1} + x_j^{T+1}} \quad (4-2)$$

此研究實驗分成三個部分進行：

一、比較 alpha、beta、delta、theta 腦波值對於分類正確率的影響，並與全部特徵值之分類正確率進行比較。

二、比較 α/β 、 α_{avg}/β_{avg} 對於分類正確率的影響，並與全部特徵值之分類正確率進行比較。

三、依照專心、非專心的平均分類正確比率作分析。

4.3 實驗結果

4.3.1 實驗一

在此實驗當中，使用六個特徵值，分別是四個原始的腦波值—alpha、beta、delta、theta，以及由 alpha、beta 值做簡易的除法運算的 α/β 、 α_{avg}/β_{avg} 值(計算方法請參考公式 3-4、

3-5)，並用 PolyKernel、NormalizedPolyKernel 懲罰權重值的方式作分類和比較各項分類結果。二種核心函數(參考公式 4-1、4-2)，以及調整

表 4-1 實驗一之刪除單一特徵值的分類正確率

比較項目		刪除特徵值				
		Non	alpha	beta	delta	theta
Training 平均 分類正確率	PolyKernel	71.53	71.19	71.58	66.45	71.56
	NormalizedPolyKernel	68.98	66.92	66.82	65.85	68.46
k-fold 平均 分類正確率	PolyKernel	71.17	70.88	71.12	66.11	71.16
	NormalizedPolyKernel	67.96	66.12	66.07	65.14	67.8
Training 最高 分類正確率	PolyKernel	71.68	71.38	71.75	66.6	71.82
	NormalizedPolyKernel	70.38	67.63	67.7	67.21	69.47
k-fold 最高 分類正確率	PolyKernel	71.38	71.11	71.37	66.28	71.37
	NormalizedPolyKernel	69.14	66.64	66.56	65.82	68.75

實驗一中，單獨刪除各腦波特徵值後，再進行分類計算，結果如表 4-1 所示，分別呈現平均分類正確率和最高分類正確率；並且以使用全部特徵值(「Non」欄)的欄位作為比較基準值。

由表 4-1 可以得知 PolyKernel 的分類正確率都比 NormalizedPolyKernel 來得好一些，這表示研究中的實驗數據較不適合正規化處理，因為經由正規化的步驟後，可能會使某些數據失去其代表的分類意義，而造成專心與非專心辨識上錯誤。

從實驗一得到另一項結果是，六個特徵值對於分類而言，都具有一定存在的意義，因為在刪除某一特徵值後，不管是在最高分類正確率或者是平均分類正確率，都比使用全部特徵值時下降一些，如表 4-1 所示，這就證明每一個特徵值都存在著影響分類正確率的價值，只是每個特徵值影響分類正確率的多寡不一而已。

4.3.2 實驗二

在此實驗中比較 α/β 、 α_{avg}/β_{avg} 影響整體分類正確率的結果，還會加上 alpha、beta、delta、theta 一同觀察。此處使用 PolyKernel、NormalizedPolyKernel 二種核心函數，以及調整懲罰權重值的方式作分類和比較結果。

實驗二中，分別計算「只用 α/β 、 α_{avg}/β_{avg} 」、「不用 α/β 、 α_{avg}/β_{avg} 」、單獨刪除 α/β 或 α_{avg}/β_{avg} 的分類正確率，結果如表 4-2 所示，表格中呈現平均分類正確率和最高分類正確率；並以使用全部特徵值(「Non」欄)的欄位作為比較基準值。

表 4-2 實驗二—各式特徵值組合之分類正確率

比較項目		刪除特徵值				
		Non	$\frac{\alpha}{\beta}$ 、 $\frac{\alpha_{avg.}}{\beta_{avg.}}$	Alpha, beta, delta, theta	$\frac{\alpha_{avg.}}{\beta_{avg.}}$	$\frac{\alpha}{\beta}$
Training 平均 分類正確率	PolyKernel	71.17	68.99	65.84	69.48	71.37
	NormalizedPolyKernel	68.98	65.12	62.02	68.10	67.42
k-fold 平均 分類正確率	PolyKernel	71.53	68.67	65.73	69.13	70.95
	NormalizedPolyKernel	67.96	64.56	61.95	67.4	66.93
Training 最高 分類正確率	PolyKernel	71.38	69.14	65.98	69.61	71.55
	NormalizedPolyKernel	70.38	65.16	62.15	68.89	68.35
k-fold 最高 分類正確率	PolyKernel	71.68	68.73	65.87	69.19	71.15
	NormalizedPolyKernel	69.14	64.60	62.06	67.85	66.96

單位：%

由實驗二可以得知， α/β 、 α_{avg}/β_{avg} 二個特徵值對於分類而言，占了頗重要的地位(參考表 4-2)，因為在刪除 α/β 或 α_{avg}/β_{avg} 特徵值後，不管是在最高分類正確率或者是平均分類正確率，都比使用全部特徵值時下降 2.5%、3.4%，這就證明 α/β 、 α_{avg}/β_{avg} 這二個特徵值都存在著影響分類正確率的意義，只是其特徵值影響分類正確率的高低不一而已。

而在整體分類正確率方面其結果，不論是 PolyKernel 或者是用 NormalizedPolyKernel 核心函數下，其順序皆相同(參考表 4-2)：

6 項特徵值 > 4 項原始腦波特徵值 > 2 項 α/β 、 α_{avg}/β_{avg} 特徵值

由上述分類正確率排序可知，在分類專心與非專心腦波時，用 6 項特徵值的效果會最好，也代表每一項特徵值對於分類來說，都具有其重要的辨識意義。

4.3.3 實驗三

由上面二個實驗可以得知，使用六個特徵值的分類正確率最好—71.17%，因此在實驗三中，利用此分類正確率下的分類正確筆數之比率作分析，觀察專心或非專心之腦波判別，何者較為容易、正確比率較高。

實驗三的實驗結果部分，是使用分類正確筆數平均值的比率，其計算公式如下：

假設專心的分類正確比率稱為 Attention Rate(AR)，全部專心的筆數稱為 Total Attention(TA)，腦波資料正確被分類成專心的情況稱為 Correct of Attention(CA)

$$AR = \left(\frac{CA}{TA} \times 100 \right) \% \quad (4-3)$$

假設非專心的分類正確比率稱為 Inattention Rate(IR)，全部非專心的筆數稱為 Total Inattention(TI)，腦波資料正確被分為非專心的情況稱為 Correct of Inattention(CI)。

$$IR = \left(\frac{CI}{TI} \times 100 \right) \% \quad (4-4)$$

表 4-3 PolyKernel 分類正確比率

懲罰 權重值	學習狀態	Training	k-fold
c=1	專心(AR)	87.21%	87.18%
	非專心(IR)	45.59%	44.18%
c=10	專心(AR)	86.57%	86.69%
	非專心(IR)	47.00%	46.26%
c=50	專心(AR)	86.65%	86.57%
	非專心(IR)	47.30%	46.63%

表 4-4 NormalizedPolyKernel 分類正確比率

懲罰 權重值	學習狀態	Training	k-fold
c=1	專心(AR)	88.30%	88.04%
	非專心(IR)	32.90%	31.25%
c=10	專心(AR)	86.95%	86.35%
	非專心(IR)	40.63%	38.85%
c=50	專心(AR)	86.20%	85.45%
	非專心(IR)	44.61%	42.59%

上方表 4-3、4-4 是腦波資料分類後的對錯比率，並依 PolyKernel、NormalizedPolyKernel 核心函數分別表示。

由上方二個表格可以得知，不論是訓練資料或 k-fold 驗證，二者的分類正確比率很接近(專心的分類正確比率差距是 0.24%~0.75%，非專心的分類正確比率差距是 1.65%~2.02%)。

在實驗中發現，不論是使用 PolyKernel 或 NormalizedPolyKernel 核心函數，其專心的分類正確筆數比率都比非專心的分類正確筆數比率來得高，因此可知人們在專心時的腦波數據是較具有相同或類似的特徵，並且比較容易被判別出來的。

在實驗設計中，模擬出專心與非專心的二種學習環境，由實驗三的比較可以知道，專心的分類正確率都比非專心的分類正確率高出許多。表示收集到的專心腦波數據是較具相似的特徵，因此也較容易被識別出來的，但這不表示非專心的腦波數據就不易辨識，而是因為造成非專心的原因有很多，所以在非專心的腦波數據內，藏有更不同的狀態類別，需更進一步的解析才能判別出來，例如：受測者需要一心二用，一邊要聆聽英文句子內容，一邊還要聆聽旁人的對話、思考旁人對話內容…等。

5. 結論與未來研究方向

相較於過去學習相關研究的正確辨識率 66.7%[29]，本研究的分類正確率為 71.17%。

本研究在實驗中試著將各個特徵值逐一作刪除，得知最好的分類正確率是 6 項特徵值同時使用時，但每個特徵值對於分類正確率的影響程度不一，其中屬 delta 值帶來的變化最大，可影響分類正確率達到 5.06%，這是過往研究中少見的。根據 Barbara 等人的研究結果[6]顯示，delta 的變化與語言學習有相關，因此，若是學習方式是屬於語音教學類型的話，delta 特徵值將是個分類的重點依據。

經研究結果證實專心狀態是持續性存在的現象，而且觀察小區段性的資料比觀察單筆資料的分類正確率來得好一些。且專心的腦波

比非專心的腦波容易被辨識；非專心腦波中因蘊含許多資訊，造成辨識上較困難，但其可挖掘出更多的未知的資訊或狀態類別。

研究結果也發現使用 PolyKernel 核心函數比使用 NormalizedPolyKernel 核心函數的分類正確率來得高，表示正規化時會使某些具分類價值的數據給隱藏掉，導致分類結果表現較遜色。

本研究中尚屬於事後分析、辨識作業，將來希望收集更多受測者的腦波數據，並且發展成即時的辨識系統，這樣才能確實應用在學生學習環境裡。並希望能用其他方法作為研究基礎，嘗試別的分類方法能否再提升專心腦波的分類正確率，例如：kNN (k-th Nearest Neighbor, 第 k 位最近鄰居分類法)、ANN(Artificial Neural Network, 類神經網路演算法)、C4.5(決策樹 C4.5 演算法)、Random Forest(隨機森林法)。

誌謝

本研究承國科會專題研究計畫(編號：NSC100-2218-E-020-003 及 NSC101-2221-E-020-025) 補助經費，謹此誌謝。

參考文獻

- [1] 王麒璋, "支向機核心函數適用指標之建立", *國立成功大學工業管理科學研究所碩士論文*, 台灣台南市, 2003。
- [2] 吳進安, *神經診斷學*, 台北: 揚智文化, 1998。
- [3] 黃承龍、陳穆臻、王界人, "支援向量機於信用評等之應用", *計量管理期刊*, Vol. 1, No. 2, pp. 155~172, 2004
- [4] Aizerman, M. A., Braverman, E. M., and Rozonoer, L. I., "Theoretical Foundations of the Potential Function Method in Pattern Recognition Learning, Autom.," *Remote Control*, Vol. No. 25, 1964
- [5] Belle, A., Hargraves R. H. and Najarian, K. "An Automated Optimal Engagement and Attention Detection System Using Electrocardiogram," *Computational and Mathematical Methods in Medicine*, Vol.2012, pp. 1-12., 2012
- [6] Penolazzi, B, Spironelli C and Angrilli A. , "Delta EEG activity as a marker of dysfunctional linguistic processing in developmental dyslexia," *2008 Society for Psychophysiological Research*, Vol.45, Issue 6, pp. 1025-1033, 2008
- [7] Isa D., Blanchfield P. and Chen Z, "Intellectual Property Management System for the Super-Capacitor Pilot Plant," *IC-AI*, page 708-714. CSREA Press, 2009
- [8] Costantini, G., Casali, D. and Todisco, M. , "An SVM based Classification Method for EEG Signals," *14th WSEAS International Conference on CIRCUITS*, pp. 107-109, 2010
- [9] Berger H. (1929). "Über das Elektrenkephalogramm des Menschen (On the EEG in humans)," *Journal of European Archives of Psychiatry and Clinical Neuroscience* , Vol. 87, No. 1, pp. 527-570, 1929
- [10] Hasegawa, C. and Oguri, K., "The Effects of Specific Musical Stimuli on Driver's Drowsiness," *2006 IEEE Intelligent Transportation Systems Conference*, Toronto, Canada, pp.817-822, 2006
- [11] Han, H. Y. , "Applying the Two-Stage Classification to Improve the SVM Classification Accuracy," *Unpublished doctoral dissertation*, National Cheng Kung University, Tainan, Taiwan(R.O.C), 2004
- [12] Gerlic, I. and Jausovec, N. , "Differences in EEG Power and Coherence Measures Related to the Type of Presentation: Text versus Multimedia," *Journal of Educational Computing Research*, Vol. 25, pp. 177-195, 2001
- [13] Vidal, J. J., "Toward direct brain-computer communication. Annu. Rev. Biophys.," *Bioeng*, Vol. 2, pp. 157-180, 1973
- [14] Vidal, J. J., "Real-Time Detection of Brain Events in EEG," *PROCEEDINGS OF THE IEEE*, Vol. 65, Issue. 5, pp. 633-641, 1997
- [15] Zhang, S., Gao, J. and Chen, Z., "Analysis of Emotion EEG Classification Based on GA-Fisher Classifier," *Complexity and Data Mining (IWCDM), 2011 First International Workshop*, pp. 24-27, 2011
- [16] Platt, J. C., "Fast training of support vector machines using sequential minimal optimization," *Advances in kernel methods*, MA, USA: MIT Press Cambridge, pp. 185-208, 2000
- [17] Kabuto, M., Kageyama, T. and Nitta H. (1993), "EEG power spectrum changes due to listening to pleasant music and their relation to relaxation effects," *Journal of Nippon Eiseigaku Zasshi*, Vol. 48(4), pp.807-818, 1993
- [18] Zhang, L., Zheng, C., Li, X. and Shen, K., "Measuring kolmogorov entropy of EEG

- for studying the state of mental fatigue,” *Chinese Journal of Biomedical Engineering*. Vol. 26, pp. 170–176, 2007
- [19] Jrad N., Congedo M., Phlypo R., Rousseau S., Flamary R., Yger F., Rakotomamonjy A., “sw-SVM: sensor weighting Support Vector Machines for EEG-based Brain-Computer Interfaces,” *Journal of Neural Engineering*, Vol. 8, No. 5, pp. 1-19, 2011
- [20] 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,” *1999 International Federation of Clinical Neurophysiology, Published by Elsevier Science B.V.*, Vol. 52, pp. 21-41, 1999
- [21] Reinhold, S., Gernot, R. M., Christa, N. and Gert, P., “An Asynchronously Controlled EEG-Based Virtual Keyboard: Improvement of the Spelling Rate,” *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, Vol. 51, No. 6, pp.979-984, 2004
- [22] Cuingnet, R., Chupin, M., Benali, H. and Colliot, O., “Spatial and anatomical regularization of SVM for brain image analysis,” *Neural Information Processing Systems*, pp. 1-9, 2010
- [23] Huang, S., “The correlation between attention and EEG signals, Unpublished doctoral dissertation,” *Chien Hsin University of Science and Technology*, Taoyouan, Taiwan(R.O.C), 2012
- [24] Hsu, S., “A Music Player System for Cycling with Modulating Rider’s Status,” *2012 International Conference on Advanced Information Technologies and The Second National Conference on Web Intelligence and Applications (AIT / NCWIA 2012)*. ISBN: 978-986-7043-58-0, 2012
- [25] Jung, T. P., Makeig, S., Stensmo, M. and Sejnowski, T. J. “Estimating alertness from the EEG power spectrum,” *Journal of IEEE Trans on Biomedical Engineering*. Vol. 44, Issue. 1, pp. 60–69, 1997
- [26] Vapnik, V. N. (1995), “The Nature of Statistical Learning Theory,” *Springer-Verlag*, ISBN: 0-387-98780-0
- [27] Wang, L., Yu, T. and Wen, B., “Assessment based on nonlinear parameters of EEG α waves for human-body fatigues,” *Journal of Northeastern University*. Vol. 26, pp. 1174–1177, 2005
- [28] Li, X., Hu, B., Zhu, T., Yan, J., Zheng, F., “Towards affective learning with an EEG feedback approach,” *MTDL '09 Proceedings of the first ACM international workshop on Multimedia technologies for distance learning*, pp. 33-38, 2009
- [29] Li, X., Zhao, Q., Li, L., Peng, H., Qi, Y., Mao, C., Fang, Z., Liu, Q. and Hu, B., “Improve Affective Learning with EEG Approach,” *Journal of Computing and Informatics, formerly: Computers and Artificial Intelligence.*, Vol. 29, pp.557–570, 2010
- [30] Li, Y., Li, X., Ratcliffe, M., Liu, L., Qi, Y. and Liu, Q., “A real-time EEG-based BCI System for Attention Recognition in Ubiquitous Environment.,” *UAAII '11 Proceedings of 2011 international workshop on Ubiquitous affective awareness and intelligent interaction*, pp.33-40, 2011
- [31] Lin, Y. P., “Exploring EEG Spectral Dynamics of Emotional Responses in Music Appreciation,” *Unpublished doctoral dissertation*, National Taiwan University, Taipei, Taiwan(R.O.C), 2011