



國立臺北科技大學

自動化科技研究所

碩士學位論文

應用腦電波之眼動訊號於疲勞狀態  
的識別

Identification of drowsiness by detecting eye  
movement based on mindwave EEG signal

研究生：陳崢昊

指導教授：林志哲 博士

中華民國 103 年 12 月

# 中文摘要

論文名稱：應用腦電波之眼動訊號於疲勞狀態的識別

頁數：69

校所別：國立臺北科技大學 自動化科技研究所

畢業時間：一百零三學年度第一學期

學位：碩士

研究生：陳崢昊

指導教授：林志哲 博士

關鍵詞：腦電波圖、小波轉換、支持向量機、類神經網路、模糊邏輯

本研究的目的是發展應用腦電波量測來分析受測者的眼動訊號，透過時域訊號的特徵來辨識眼動狀態，進而了解受測者的疲勞程度。本研究使用由神念科技(NeuroSky)所研發的非侵入式腦電波量測儀，進行腦電波原始資料的擷取，使用 Matlab 程式對於腦電波進行小波轉換(Wavelet transform, WT)將訊號分解，再將數據轉化為特徵值之後，使用支持向量機(Support vector machine, SVM)與倒傳遞類神經網路(Back propagation neural network, BPNN)進行辨識開閉眼的狀態；透過模糊邏輯，根據閉開眼頻率與閉眼時間來推論受測者之疲勞狀態，進而用於駕駛之警示。

# ABSTRACT

Title : Identification of drowsiness by detecting eye movement based on mindwave EEG signal.

Pages : 69

School : National Taipei University of Technology

Department : Graduate Institute of Automation Technology

Time : December, 2014

Degree : Master

Researcher : Ching-Hao Chen

Advisor : Chih-Jer Lin

Keywords : Electroencephalogram, Wavelet transform, Support vector machine, Back propagation neural network, Fuzzy logic

In this study, a drowsiness identification system using mindwave EEG signal is proposed. With the noninvasive mindwave headset developed by NeuroSky, the time domain signal of the mindwave is used to recognize eye movement and the user's fatigue level. First, the EEG raw signal is transformed by the wavelet transformation. Second, the eigenvalues are computed based on the Daubechies wavelet. Third, the support vector machine and the back propagation neural network are studied to identify the status of eye movement using the eigenvalues. Finally, the fuzzy logic is used to obtain the fatigue level, according to the frequency of the eye movement and the time of closing eyes.

## 誌 謝

本論文能夠順利的完成，首先要感謝的人無非是指導教授林志哲老師，在崢昊研究所學涯上受到老師諸多幫助與耐心地指導。每當我遇見學業問題時，都能不厭其煩地與我討論研究，並時時督促著我求取進步，讓我知道在研究所的學習方式，並不是不論是非的填鴨式教育，而是要訓練一個人能獨立思考與尋求真理過程的方式。在這裡小小篇幅中，也再次謝謝老師您給予學生諸多地協助與幫忙。另外要感謝口試委員們，陳俊達教授、吳建達教授在論文上的建議與修正，崢昊在此致上最高的謝意與敬意。

在研究所的生活中，要感謝電腦整合製造與控制實驗室裏的同學們朝文、明家、廷宇、彙翔與學弟致皓、忠奇、永勝、宥楝、建鴻、沛哲、學妹欣儀、敏馥，給予我許多的建議與幫助；實驗過程中少不了會遇到瓶頸，而大家總是能與我一起探索答案與解決問題突破瓶頸，在空閒的假日中也有時會相約一起出去玩，一同釋放平時累積的沉悶與壓力，實在是難得的緣份。也謝謝自動化科技研究所各位老師與同學在我學業與研究上的各種協助；另外我也想感謝大寶科技的吳宗衡先生，一直提供我關於腦電波部分的協助與建議，讓我可以順利的進行實驗。

最後我想感謝的是一直支持著我的家人與朋友們，在我的家族中第一個念研究所的小孩，什麼事情都是全家族一起第一次體驗，多少有些措手不及，而父母的支持以及在我有狀況的時候都給予我多方面的協助與建議，使我可以專心致力在研究上；也謝謝弟弟在研究之餘，跟我一同共度休閒時光，不論是看電視或是玩遊戲，都能夠讓我可以好好的放鬆與休息。

# 目 錄

中文摘要 .....	i
英文摘要 .....	ii
誌 謝 .....	iii
目 錄 .....	iv
表目錄 .....	vi
圖目錄 .....	vii
第一章 緒論 .....	1
1.1 前言 .....	1
1.2 文獻回顧 .....	2
1.2.1 腦電波圖 .....	2
1.2.2 腦機介面 .....	3
1.2.3 小波轉換 .....	5
1.2.4 支持向量機 .....	5
1.2.5 倒傳遞類神經 .....	6
1.3 研究動機與目的 .....	7
1.4 實驗設備與軟體 .....	8
1.5 論文架構 .....	9
第二章 訊號分析與特徵值計算 .....	10
2.1 訊號分析 .....	10
2.2 小波轉換 .....	14
2.3 離散小波轉換 .....	18
2.4 特徵值計算 .....	23
2.5 模糊邏輯 .....	24
第三章 分類器介紹 .....	26
3.1 支持向量機 .....	26
3.2 倒傳遞類神經網路 .....	30
第四章 實驗結果 .....	35
4.1 權重訓練 .....	35
4.2 特徵值選取 .....	41
4.2.1 不同分組方式的分類正確率 .....	41
4.2.2 輸入兩個特徵值分類正確率比較 .....	43
4.2.3 輸入三個特徵值分類正確率比較 .....	45
4.2.4 輸入四個特徵值分類正確率比較 .....	48
4.4 線上分類 .....	50
4.5 疲勞程度計算 .....	53
4.5.1 糊邏輯輸入與輸出變數的歸屬度建立 .....	53
4.5.2 模糊化規則建立 .....	55
4.5.3 解模糊化 .....	56

第五章 結論與未來展望 .....	66
5.1 結論 .....	66
5.2 未來展望 .....	67
參考文獻 .....	68



## 表目錄

表 1.1 電腦硬體與軟體配備 .....	8
表 2.1 小波轉換後 db4 所對應的腦電波類型 .....	20
表 2.2 年齡與程度對照 .....	25
表 4.1 開眼與閉眼瞬間的特徵值 .....	40
表 4.2 三種分組方式的正確率 .....	43
表 4.3 兩個輸入特徵排列組合的分類正確率 .....	45
表 4.4 三個輸入特徵排列組合的分類正確率 .....	47
表 4.5 輸入四個特徵排列組合的分類正確率 .....	49
表 4.6 線上分類正確率計算 .....	52
表 4.7 模糊控制規則表 .....	56
表 4.8 受測者 1 閉開眼頻率 1.5~2.5Hz、閉眼時間 0~0.4 秒 .....	61
表 4.9 受測者 1 閉開眼頻率 0.5~1.5Hz、閉眼時間 0.4~0.7 秒 .....	62
表 4.10 受測者 1 閉開眼頻率 0~0.6Hz、閉眼時間 0.7~1 秒 .....	62
表 4.11 受測者 2 閉開眼頻率 1.5~2.5Hz、閉眼時間 0~0.4 秒 .....	63
表 4.12 受測者 2 閉開眼頻率 0.5~1.5Hz、閉眼時間 0.4~0.7 秒 .....	63
表 4.13 受測者 2 閉開眼頻率 0~0.6Hz、閉眼時間 0.7~1 秒 .....	64
表 4.14 受測者 3 閉開眼頻率 1.5~2.5Hz、閉眼時間 0~0.4 秒 .....	64
表 4.15 受測者 3 閉開眼頻率 0.5~1.5Hz、閉眼時間 0.4~0.7 秒 .....	65
表 4.16 受測者 3 閉開眼頻率 0~0.6Hz、閉眼時間 0.7~1 秒 .....	65

# 圖目錄

圖 1.1 潘斐德幻想小人 .....	1
圖 1.2 各腦電波的波形 .....	3
圖 1.3 腦電波量測儀 (a)傳統(b)新式 .....	4
圖 1.4 國際 10-20 制腦電波電極位置 .....	4
圖 1.5 支持向量機二維分類 .....	6
圖 1.6 系統架構圖 .....	8
圖 2.1 快速傅立葉轉換的結果圖 (a)原始訊號 (b)轉換後訊號 .....	11
圖 2.2 短時距傅立葉轉換的結果圖 (a)原始訊號 (b)窄窗格 (c)寬窗格 .....	13
圖 2.3 窗格比較圖 (a)短時距傅立葉轉換 (b)小波轉換 .....	14
圖 2.4 小波轉換的結果圖 (a)原始訊號 (b)轉換後訊號 .....	16
圖 2.5 不同參數對母小波的影響 (a) $\psi(t)$ (b) $\psi\left(\frac{t}{a}\right)$ (c) $\psi(t-\tau)$ (d) $\psi\left(\frac{t-\tau}{a}\right)$ .....	17
圖 2.6 原始訊號通過降階採樣濾波器的結果 .....	18
圖 2.7 離散小波轉換的分解架構圖 .....	19
圖 2.8 db4 小波函數 (a)小波函數波形圖 (b)調整函數波形圖 .....	19
圖 2.9 開閉眼狀態波形圖 (a)閉眼瞬間 (b)開眼瞬間 .....	21
圖 2.10 開閉眼狀態各階層的結果 (a)閉眼瞬間 (b)開眼瞬間 .....	22
圖 2.11 模糊推論過程 .....	25
圖 3.1 超平面示意圖 .....	29
圖 3.2 最大化區分邊界圖 .....	29
圖 3.3 人工神經元模型 .....	30
圖 3.5 雙曲線正切函數 .....	32
圖 4.1 離線特徵抓取 .....	36
圖 4.2 非眼動狀態時域響應圖 .....	37
圖 4.3 閉眼瞬間時域響應圖 .....	37
圖 4.4 開眼瞬間時域響應圖 .....	38

圖 4.5 開眼瞬間小波轉換結果 .....	39
圖 4.6 開眼瞬間小波轉換結果 .....	39
圖 4.7 不同分組方式的分類正確率實驗流程圖 .....	42
圖 4.8 輸入兩個特徵的區分超平面 .....	44
圖 4.9 輸入兩個特徵的 BPNN 架構圖 .....	44
圖 4.10 輸入三個特徵的區分超平面 .....	46
圖 4.11 輸入三個特徵的 BPNN 架構圖 .....	46
圖 4.12 輸入四個特徵的 BPNN 架構圖 .....	48
圖 4.13 線上分類流程圖 .....	50
圖 4.14 分類結果顯示介面	
(a)閉眼瞬間的狀態 (b)非眼動狀態 (c)開眼瞬間的狀態 .....	51
圖 4.15 閉眼時間的歸屬度 .....	54
圖 4.16 閉開眼頻率的歸屬度 .....	54
圖 4.17 疲勞程度的歸屬度 .....	55
圖 4.18 模糊控制曲面圖 .....	57
圖 4.19 疲勞程度為安全的輸出圖 .....	58
圖 4.20 疲勞程度為注意的輸出圖 .....	58
圖 4.21 疲勞程度為危險的輸出圖 .....	59
圖 4.22 案例 1 測試結果 .....	59
圖 4.23 案例 2 測試結果 .....	60
圖 4.24 案例 3 測試結果 .....	60

# 第一章 緒論

## 1.1 前言

人們日常生活中的大小事如吃飯、走路等都是透過大腦發出腦電波訊號，經由神經細胞傳達到身體各部位，下達控制命令使肌肉做出相對應的動作；而大腦對應控制身體的部位如圖 1.1；而這一連串包括接收訊息、資訊處理、下達命令、神經傳遞到肌肉動作，這段過程大約只需要 150 毫秒，可見人腦在資訊處理上的能力相當優異。

而近幾年來，人們對於大腦這個神秘又複雜的部位所抱持的好奇心越來越強，相關研究與發明也層出不窮；隨著這個領域逐漸熱門，許多相關的領域如醫療輔具、移動裝置、甚至教育和娛樂上都開始出現應用腦電波的相關商品；但腦電波訊號是一個微弱的電波訊號而且非常容易受到外在環境的影響，使得訊號的穩定性降低，因此在腦電波訊號的鑑別與分析上都有著相當的困難度。

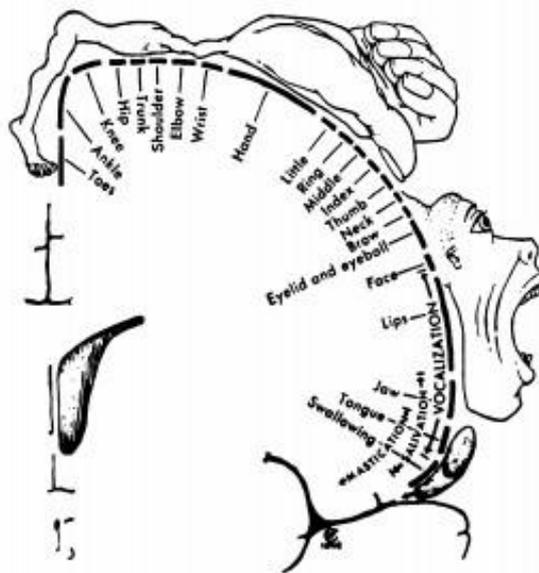


圖 1.1 潘斐德幻想小人[1]

## 1.2 文獻回顧

### 1.2.1 腦電波圖

西元 1875 年時，英國利物浦的生理學教授 Richard Caton 在英國醫學協會(British Medical Association)中提出透過電流計(Galvanometer)在動物的大腦皮質表面觀察到一種電波，此訊號與心跳、呼吸無關，且會因麻醉與缺氧造成訊號變化，並在動物死亡後消失。

直到 1924 年，一位德國精神科醫師 Hans Berger 在人類的頭蓋骨上完整地紀錄到相同的電波活動，並命名為腦電波圖(Electroencephalogram, EEG)。

根據洪偉哲的研究成果[2]可將大腦所發出的腦電波訊號分類成下列五種，各腦電波的波形如圖 1.2：

$\delta$  (Delta)波：頻率約在 0~4Hz 之間，波形與無意識狀態有較大的關連性；

正常人在意識清醒的狀況下  $\delta$  波數值不活躍，通常活躍在深層睡眠、無意識、深度麻醉等狀況。

$\theta$  (Theta)波：頻率約在 4~7Hz 之間，波形與潛意識狀態有較大的關連性；

當  $\theta$  波處於活躍狀態時，人們是處在意識中斷、身體深沉放鬆的狀態；而  $\theta$  波對於深層記憶的觸發與長期記憶的強化等有極大的幫助。

$\alpha$  (Alpha)波：頻率約在 8~16Hz 之間，波形與放鬆狀態有較大的關連性；

$\alpha$  波是意識與潛意識之間溝通的橋梁，會在人們處在放鬆狀態但不感到疲倦時較為活躍，當人產生思考或受到外在環境聲音或其他刺激時， $\alpha$  波就會降低。

$\beta$  (Beta)波：頻率約在 16~32Hz 之間， $\beta$  波波與專注狀態有較大的關連性；

當人清醒、思考及高度警覺狀態時， $\beta$  波會較為活躍；大腦處於思考狀態或接受到感官刺激時，此波段的活躍程度會更明顯。

$\gamma$  (Gamma)波：頻率約在 32~64Hz 之間， $\gamma$  波與高層次的心理活動有關；

是掌管專注、知覺、記憶等的代表腦電波，這些能力都會

隨著  $\gamma$  波的活躍而增強，而  $\gamma$  波最容易在打禪靜坐者身上觀察到。

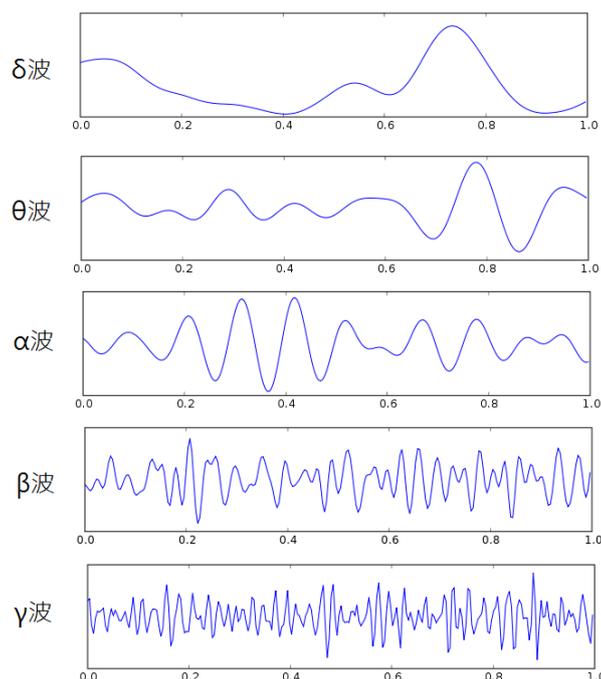


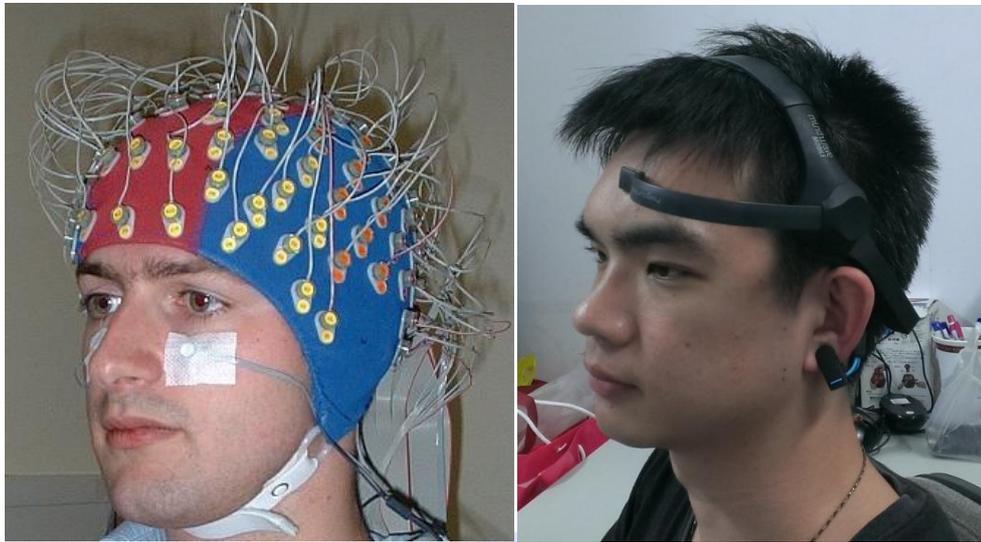
圖1.2 各腦電波的波形

## 1.2.2 腦機介面

腦機介面(Brain computer interface, BCI)是指在人類或動物的大腦與外部裝置之間所建立起來的直接傳遞連線通路，而腦機介面已經從 1978 年 William Dobbie 在一位男性盲人視覺皮層植入用於重建視覺的侵入式腦機介面，漸漸發展至現今的眾多研究中經常使用的非侵入式腦機介面；早期的非侵入式腦電波儀在量測時，受測者必須戴上專屬的頭套如圖 1.3a，以利訊號的蒐集。而該頭套內部含有多個電極片與頭皮接觸，並且須在受測者的頭皮上塗上濕黏的導電膠增進訊號蒐集的效果；此種裝置容易造成受測者的不適感且不方便配戴，此外，測試地點也必須在特定、無干擾的環境下進行。

近年來，神念科技已開發出新的腦電波測量儀器，這項新的儀器使用乾式電極(Dry electrode)取代了傳統測量時須塗導電膠的濕式電極片(Wet electrode)以及需要在特殊環境下才能測量的限制；人們只要戴上一款造型

如同耳機的腦電波儀(圖 1.3b)，透過左前額 FP-1 處輸出並以耳垂 A1 處為參考點，詳細電極位置如圖 1.4；如此一來，便能透過此裝置測量到人們的腦電波狀態，而能偵測到的大腦活動主要是專注力、放鬆度等狀態以及  $\theta$ 、 $\delta$ 、 $\alpha$ 、 $\beta$ 、 $\gamma$  波等五個波形。



(a)

(b)

圖1.3 腦電波量測儀 (a)傳統(b)新式

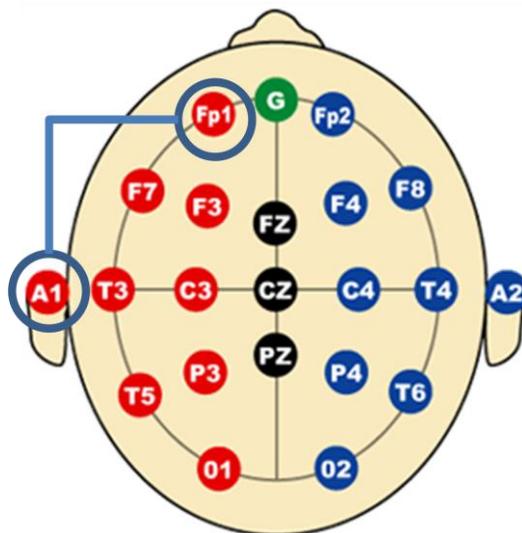


圖1.4 國際10-20制腦電波電極位置

### 1.2.3 小波轉換

小波轉換(Wavelet transform, WT)是指用有限長或快速衰減的振盪波形來表示訊號,該波型被稱為母小波(Mother Wavelet),藉由拉伸母小波函數,並逐段平移,展開被分析的訊號。

小波轉換是來自於小波分析(Wavelet Analysis)的結果,而小波分析方法是 1910 年由 Harr 所提出的小波規範正交基底;而法國地球物理學家 J. Morlet 在 1984 年想分析地震波的局部特性時,發現傳統的傅立葉轉換(Fourier transform)不足以達到他想要的結果,因此他便將小波的概念引進訊號分析中對該訊號進行分解。

1987 年, S.G. Mallat 使用多解析度分析(Multiresolution Analysis)去表現小波轉換函數結構,並提出小波轉換的方法,使得訊號可以被分解與重建。1988 年, I. Daubechies 提出了一個包含正交性(Orthonormal)以及緊支集(Compact Support)兩種特性,並且是在一個有限的區域當中為非零的小波。相關細節將在第二章進行解說。

### 1.2.4 支持向量機

支持向量機(Support Vector Machine, SVM)是一種監督式學習的方法,可廣泛地應用於統計分類(Classification)或迴歸(Regression)的方法;給定一群已經分類完成的數據後,SVM 便能夠經由訓練(Training)獲得一組模型,再將未被分類的資料投入當中,SVM 將會依據先前數據所訓練出的模型進行預測該資料的所屬分類。此方法屬於一般化線性分類器,此分類器的特點是他們能夠同時最小化經驗誤差與最大化幾何邊緣區,因此 SVM 同時也被稱為最大邊緣區分類器。

以二維問題為例(圖 1.5),若想在黑點與白點間畫出一條分界線,且距離兩個集合的邊界(Margin)越大越好,如此才能明確分辨新的點屬於哪個集合,否則可能會因為計算的精度問題而造成誤差。

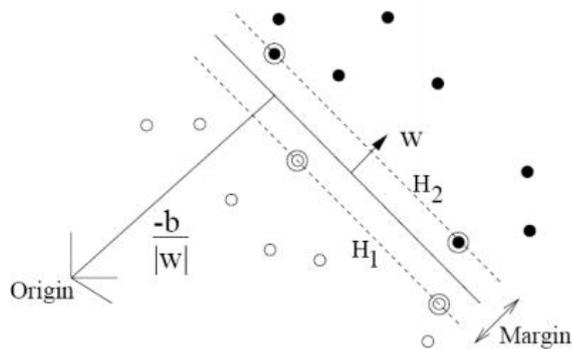


圖1.5 支持向量機二維分類

以數學的角度來看，假設有一堆點集合  $\{x_i, y_i\}, i=1, \dots, n$  且  $x_i \in \mathbb{R}^d, y_i \in \{+1, -1\}$ ，希望可以找到一條直線  $f(x) = w^T x - b$  使所有  $y_i = -1$  的點都落在  $f(x) < 0$  的區間，且所有  $y_i = +1$  落在  $f(x) > 0$  的另一個區間，如此就能透過  $f(x)$  的正與負來區分新的點是屬於兩個集合之中的哪一個。

而將區間劃分出來的這個超平面 (Hyperplane) 被稱為分離超平面 (Separating hyperplane)，而距離邊界最大的超平面為最佳分離超平面 (Optimal separating hyperplane)。

### 1.2.5 倒傳遞類神經

西元 1969 年時 Marvin Minsky 指出缺乏隱藏層的感知機模型無法解決互斥或 (XOR) 問題，而 David Rumelhart 等人在 1986 年時發表了倒傳遞網路的文章，才使其廣為人知。倒傳遞類神經網路是由前向傳遞與反向傳遞所組成的，利用誤差函數計算誤差後，藉由最陡坡降法 (The gradient steepest descent method)，逐層回推。

BPNN 分為兩個模式，學習與回想；學習是將已知的輸入值與已知的輸出值輸入到 BPNN 之中，目的是訓練權重值，過程是由前項傳遞和反向傳遞所組成：輸入資料由前向網路輸入隱藏層運算，再將結果往下一層輸入；在輸出層計算輸出的結果並計算與期望值之間誤差，進入反向傳遞網路，利用誤差從輸出層開始推回，並修正各神經元之間的權重值，使誤差逐漸收斂。

回想是僅將輸入值輸入到 BPNN 之中，透過已經訓練完成的權重值，

計算輸入值所對應到的輸出值。

### 1.3 研究動機與目的

對於腦電波訊號的解析已是近年來相當熱門的研究之一，其中對於大腦人機介面(Brain computer interface, BCI)的研究占了絕大多數，現在使用腦電波訊號做為控制命令的儀器也層出不窮，會使用腦機介面做控制的大多數都是醫療輔具，大多數是提供給因為車禍、中風造成部分癱瘓而需要進行復健的患者，或是因重大傷殘導致身體上有缺陷而需要使用到的義肢的病患，而除了先天性的疾病外，許多重大傷殘的主因都是源自於疲勞而產生的一時疏忽，在國道高速公路局的統計中[3]，雖然疲勞駕駛在所有事故比例中僅占 3.2%，但有許多過失如未保持安全車距、駕駛不當等都含有疲勞駕駛的成分在；本研究希望可以透過腦機介面做即時性的眼動狀態偵測，希望依據開閉眼的狀態，對使用者發出提醒；整個實驗的系統架構圖如圖 1.6，實驗的流程是從 MindWave Mobile 即時擷取使用者的腦電波並去除無效的雜訊，再透過 Matlab 撰寫的程式進行腦電波的分析以及結果的呈現。

由於腦電波訊號本身是一個包含高頻與低頻的訊號，如果使用無法調整窗格大小的快速傅立葉轉換(Fast Fourier transform, FFT)的話，成果不太能符合本研究所希望的結果；而由於小波轉換(Wavelet transform, WT)可提供在高頻帶時較佳的時間解析度，同時也可以在低頻帶時給出較佳的頻率解析度，因此本研究選用小波轉換做為分析腦電波訊號的工具，將訊號分析並分別使用支持向量機與倒傳遞類神經進行眼動狀態分類。

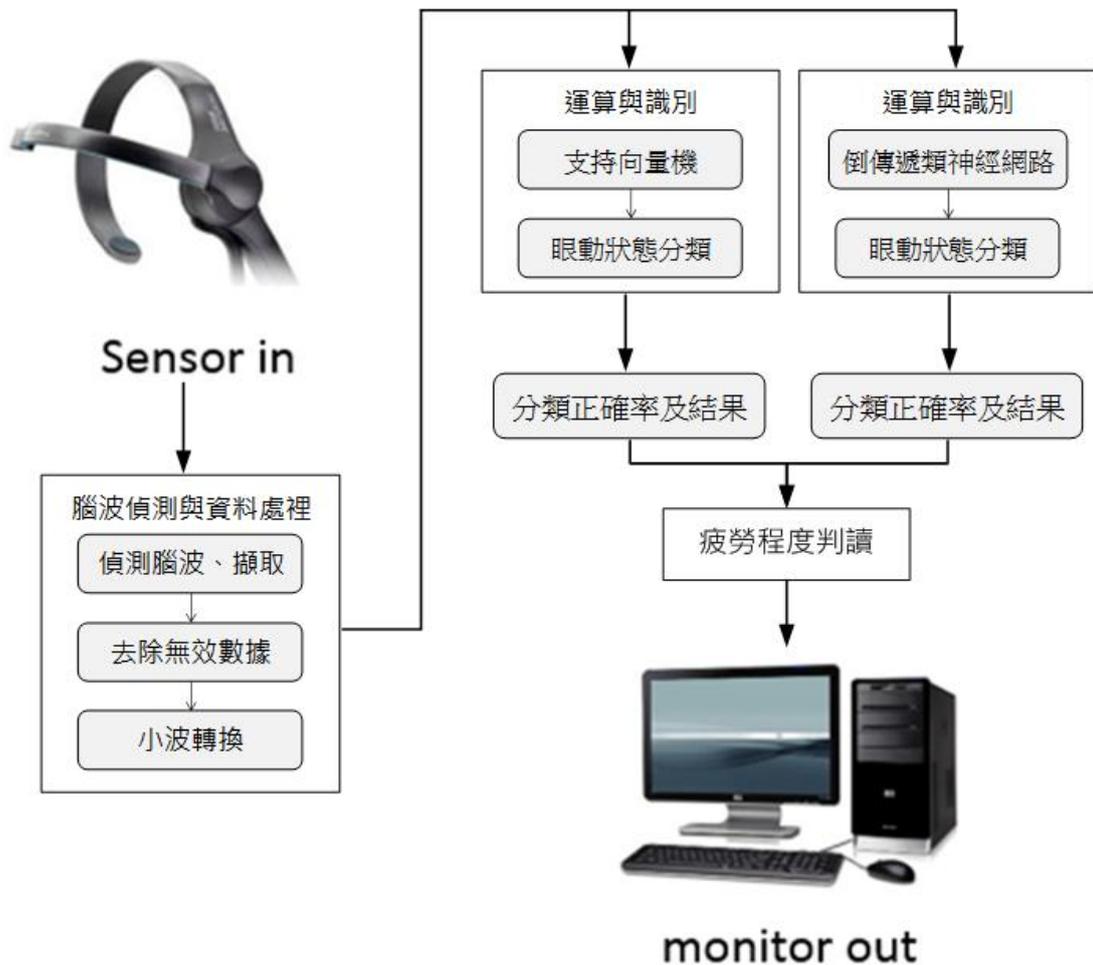


圖 1.6 系統架構圖

## 1.4 實驗設備與軟體

本研究所使用之電腦硬體設備與軟體配備如表 1.1 所示：

表 1.1 電腦硬體與軟體配備

中央處理器	Intel(R) Core(TM) i5-3210M
記憶體	DDR3 1600 16GB
顯示卡	NVIDIA GeForce GT 555M DDR3 3G
作業系統	Windows 7 64-bit
分析軟體	Matlab 2010

## 1.5 論文架構

本研究是利用 MATLAB 執行離散小波轉換(Discrete wavelet transform, DWT)將 Mindwave mobile 所擷取到的腦電波資料加以分解，再使用支持向量機(Support vector machine, SVM)與倒傳遞類神經(Back propagation neural network, BPNN)兩種分類器分類，辨別出受測者當下的開閉眼情形，計算閉眼持續時間以及開閉眼頻率。本論文共分為五章，以下將對每一章節做簡單介紹：

第一章 對過往學者所作之相關研究簡單回顧，確立研究的方向並說明研究動機與研究目的，同時敘述論文架構。

第二章 說明本研究的系統架構，將對於訊號分析、特徵值的取得方式以及模糊邏輯進行探討。

第三章 分類器的說明，包含支持向量機以及倒傳遞類神經網路。

第四章 分類與分析的結果，分為離線與線上。

第五章 結論與未來展望。



## 第二章 訊號分析與特徵值計算

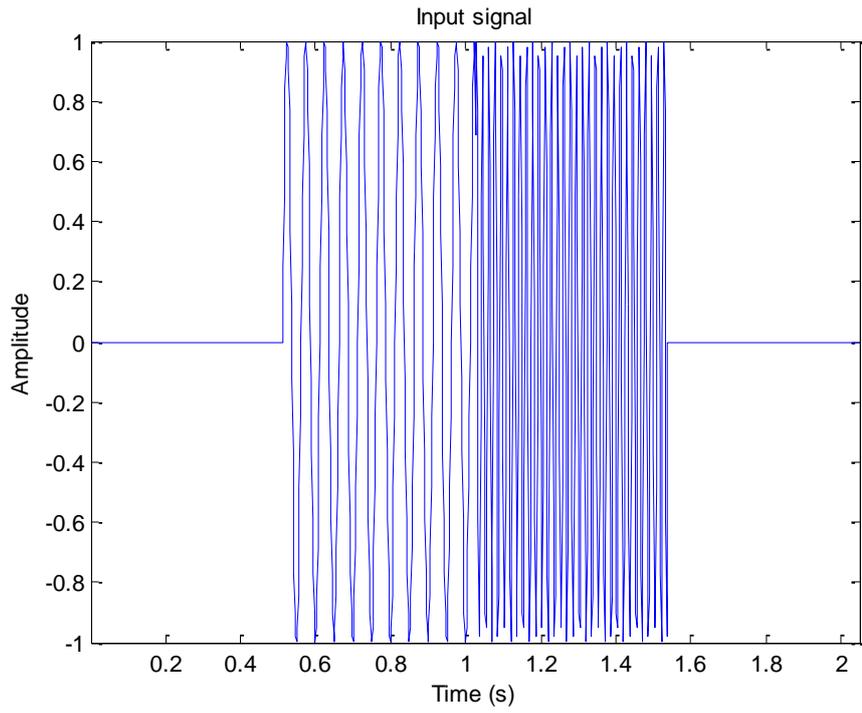
### 2.1 訊號分析

從腦電波耳機所傳送出來的原始的腦電波訊號是一個時域的訊號，包含著不同頻率的成分以及些許的雜訊，以至於在時域的訊號中比較不容易計算出鑑別眼動狀態時所需要的特徵值，因此，在計算特徵值之前，需要先對原始的訊號進行分析，才能將原始訊號當中能產生為特徵值的部分分解出來；傳統的頻譜分析是由傅立葉變換(Fourier transform, FT)構成，FT能把時域的訊號透過不同頻率的正弦與餘弦波將訊號分解，而 FT 的基本公式如下：

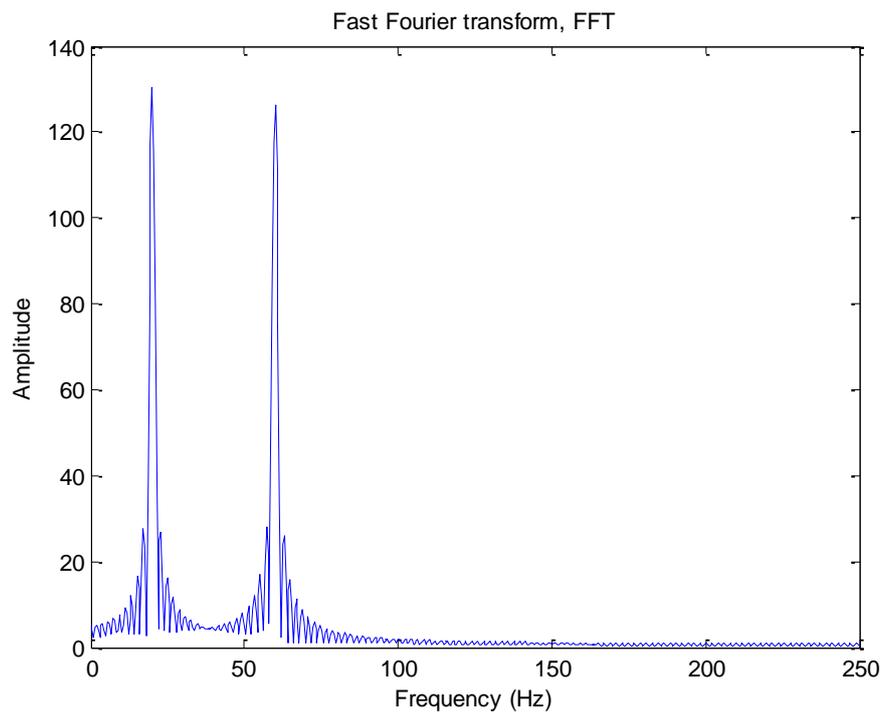
$$F(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-i\omega t} dt \quad (2.1)$$

式中  $f(t)$  代表輸入訊號， $\omega$  為角頻率， $t$  則為時間[4]；快速傅立葉轉換(Fast Fourier transform, FFT)是離散傅立葉轉換(Discrete Fourier Transform, DFT)的快速演算法，在一般訊號處理中，常使用 FFT 來求得訊號所對應的頻譜，與 DFT 相比，FFT 在計算量上節省了許多；圖 2.1 為一訊號經過 FFT 轉換所得到的結果。

雖然 FFT 早在西元 1805 年時就由 Carl Friedrich Gauss 所提出，但在當時並沒有被廣泛的認可，直到 1965 年時 James Cooley 與 John Tukey 所發表的文章[5]，才讓 FFT 開始盛行。但 FFT 仍存在著一些不足，被分析的訊號如果是一個穩態訊號(Stationary signal)，則可直接透過 FFT 取得頻域上的特徵，但訊號若是一個隨時間變化的非穩態訊號(Non-stationary signal)，經過轉換後僅剩頻域的部份，無法同時分析訊號的時變性。[6]



(a)



(b)

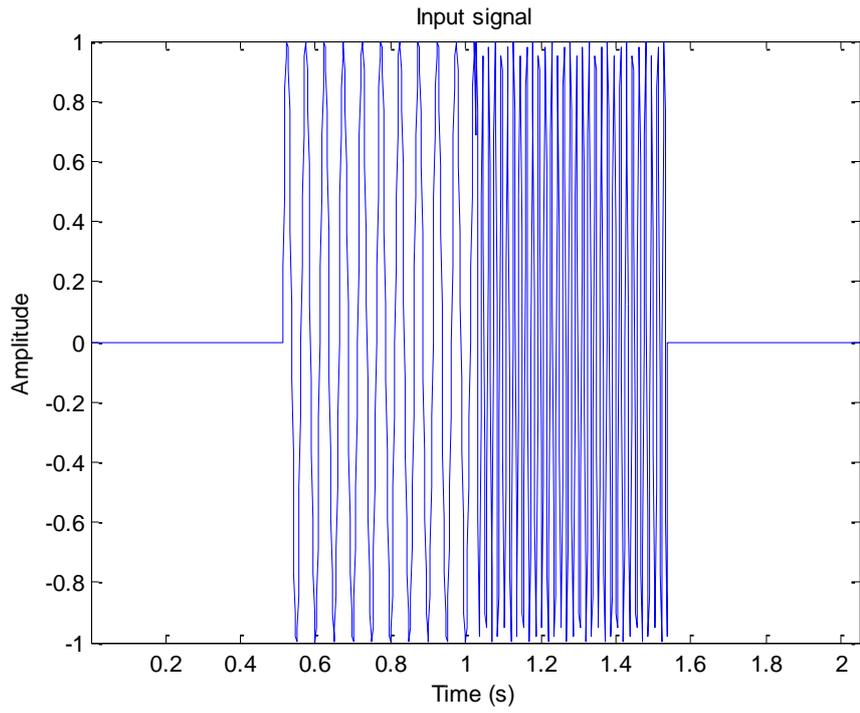
圖 2.1 快速傅立葉轉換的結果圖 (a)原始訊號 (b)轉換後訊號

西元 1946 年，Dennis Gabor 提出了短時距傅立葉轉換(Short-time Fourier Transform, STFT)，使用了窗型函數(Window function)解決傅立葉轉換在分析非穩態訊號時所產生的問題，將訊號分析從頻域轉換到了時頻域。STFT 的公式如下：

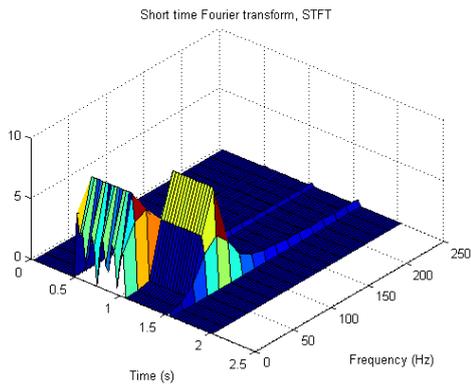
$$STFT(\tau, \omega) = \int_{-\infty}^{+\infty} f(t)g(t - \tau)e^{-i\omega t} dt \quad (2.2)$$

式中  $g(t)$  為窗型函數， $\tau$  為位移參數(Translation parameter)，STFT 透過窗型函數將訊號分割成許多小時間間隔，並假設該段訊號為穩態訊號，然後對局部訊號(Local information)進行傅立葉轉換，再透過位移參數改變窗格位置，依序對不同段的訊號進行傅立葉轉換，圖 2.2 為一訊號經過 STFT 轉換所得到的結果。

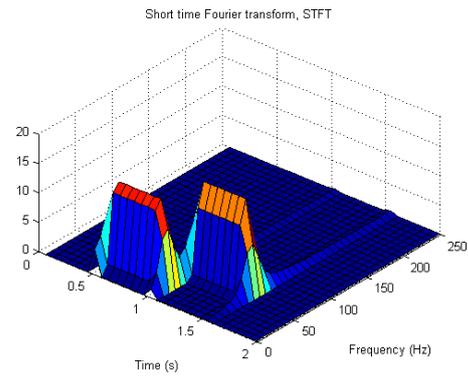
透過窗型函數的平移，將頻域分析轉換到時頻域分析的短時距傅立葉轉換，補足了傅立葉轉換以及快速傅立葉轉換不具有局部分析能力的缺點，但是快速傅立葉轉換的窗型函數是固定的，若使用較窄的窗格，就會有較佳的頻率解析度，但會犧牲掉時間的解析度；反之，選擇較寬的窗格，就能獲得較佳的時間解析度，但頻率解析度則會下降。[7]



(a)



(b)



(c)

圖2.2 短時距傅立葉轉換的結果圖 (a)原始訊號 (b)窄窗格 (c)寬窗格

## 2.2 小波轉換

在訊號的時頻分析中，都會希望在高頻的部分能夠有較佳的時間解析度，因此需要較窄的窗格；而在低頻部分則希望能夠擁有較好的頻率解析度，所以要選擇比較寬的窗格。在上一章節中所提到的短時距傅立葉轉換因為窗格是固定的，所以沒有辦法同時達到這個目標，所以法國的地球物理學家 J. Morlet 在西元 1984 年時開始將小波轉換(Wavelet transform, WT) 的概念引入了訊號分析之中，補足傅立葉轉換所無法提供的局部分析效果；短時距傅立葉轉換與小波轉換的窗格比較圖如圖 2.3。

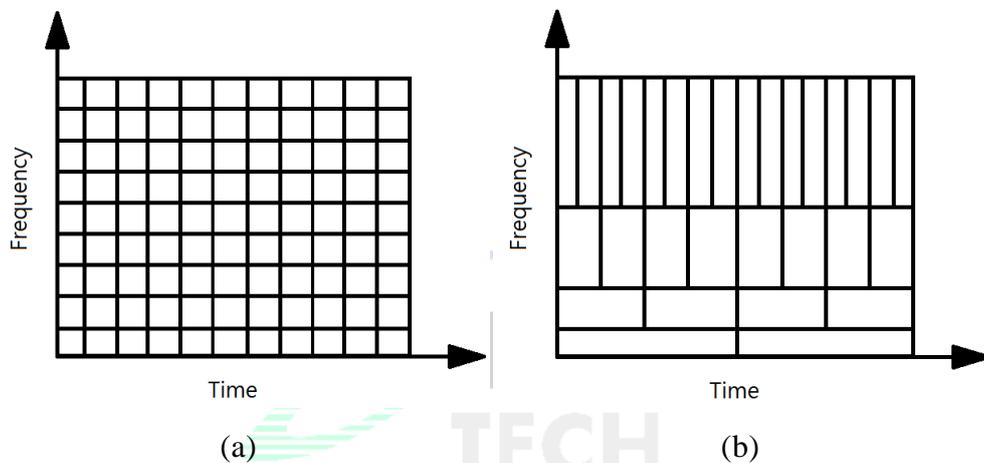


圖2.3 窗格比較圖 (a)短時距傅立葉轉換 (b)小波轉換

傅立葉轉換的缺點就是，其構造是無始無終的周期性正弦波與餘弦波，所以該方法對於濾除或壓縮那些具有周期性的訊號有比較好的效果，而對於一些具有明顯局部特性的訊號，傅立葉轉換的效果就不是如此顯著，而小波轉換正好適合解析這類訊號，因為小波轉換中的母小波擁有在有限長度中快速衰減的特性，能夠透過調整係數達到伸展與平移，展開被分析的訊號，也由於這個特性，使得小波轉換得以良好的分析局部的時域與頻域訊號，彌補傅立葉轉換中的缺失，更有數學顯微鏡的美名，圖 2.4 為一訊號經過小波轉換後的結果。小波轉換的基本公式如式 2.3：

$$\psi_{a,\tau}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-\tau}{a}\right), \quad a > 0 \quad (2.3)$$

上式中  $\psi(t)$  為母小波(Mother wavelet)， $\frac{1}{\sqrt{a}}$  為維持小波正交基底的正規

化因子(Normalization factor)， $\frac{1}{\sqrt{a}}\psi\left(\frac{t}{a}\right)$ 即為母小波的拉伸(Dilation)，平移則是透過 $(t - \tau)$ 來實現， $\tau$ 為位移參數(Translation parameter)。不同的  $a$  值與 $\tau$ ，會對母小波產生不同的效果，如圖 2.5 所示。

而母小波函數 $\psi(t)$ ，需要滿足以下的條件[4]：

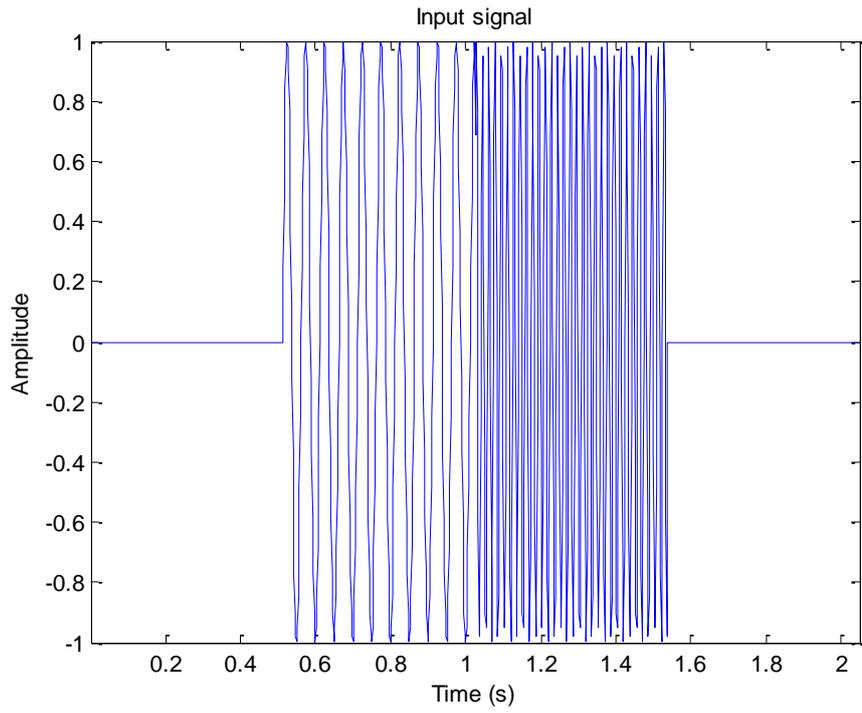
$$\int_{-\infty}^{+\infty} \psi(t)dt = 0 \quad (2.4)$$

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt = 1 \quad (2.5)$$

$$\int_{-\infty}^{+\infty} |\psi(t)| dt < \infty \quad (2.6)$$

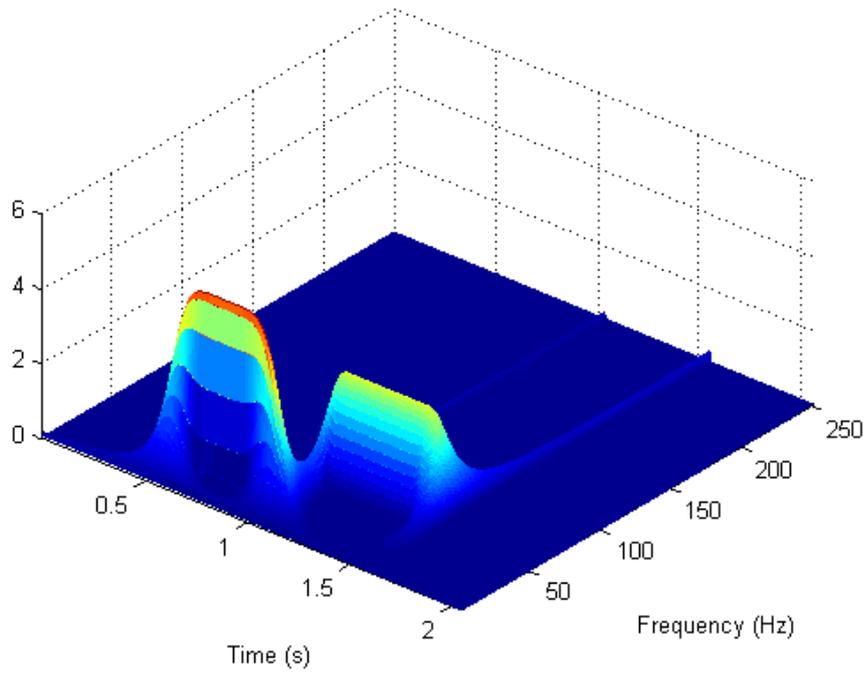
式 2.4 所代表的意思為母小波是一個上下起伏的振盪波(Oscillation wave)且積分和為零的函數，式 2.5 與 2.6 則表示該函數大部分是被限制在有限的時間之中，振幅在正負兩個方向往零衰減。





(a)

Wavelet transform, WT



(b)

圖 2.4 小波轉換的結果圖 (a)原始訊號 (b)轉換後訊號

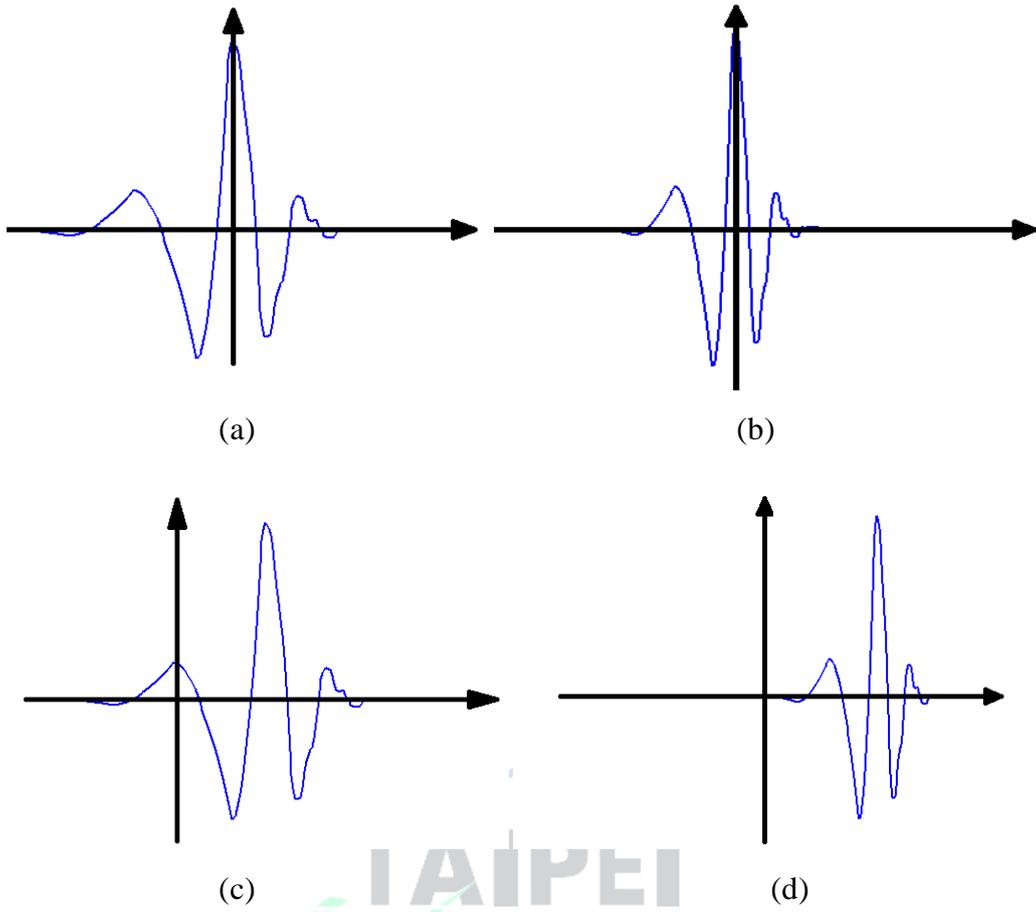


圖 2.5 不同參數對母小波的影響

(a)  $\psi(t)$  (b)  $\psi\left(\frac{t}{a}\right)$  (c)  $\psi(t - \tau)$  (d)  $\psi\left(\frac{t - \tau}{a}\right)$

## 2.3 離散小波轉換

離散小波轉換(Discrete wavelet transform, DWT)是從連續小波轉換(Continuous wavelet transform, CWT)簡化而來的，由於 CWT 是在不同時間與不同尺度的母小波計算內積，因此在計算時會增加餘冗性，而 DWT 是將原始訊號經過高通濾波器(High-pass filter)與低通濾波器(Low-pass filter)，分別被稱為小波函數(Wavelet function)與調整函數(Scaling function)，當腦電波訊號通過高通與低通濾波器之後，會被分為近似訊號(Approximated signal)與細節訊號(Detailed signal)，相關公式如下[8]：

$$\varphi_{j,k}[t] = 2^{\frac{j}{2}} \sum_k d_{j,k} \varphi[2^j t - k] \quad (2.7)$$

$$\psi_{j,k}[t] = 2^{\frac{j}{2}} \sum_k c_{j,k} \psi[2^j t - k] \quad (2.8)$$

式 2.7 中的  $\varphi(t)$  為小波函數，式 2.8 的  $\psi(t)$  則為調整函數，而  $d_j$  與  $c_j$  分別為第  $j$  層的小波參數(Wavelet coefficient)與調整參數(Scaling coefficient)，圖 2.6 為原始訊號通過降階採樣濾波器(Down sampling filter)後的結果，圖 2.7 為離散小波轉換的分解架構圖。

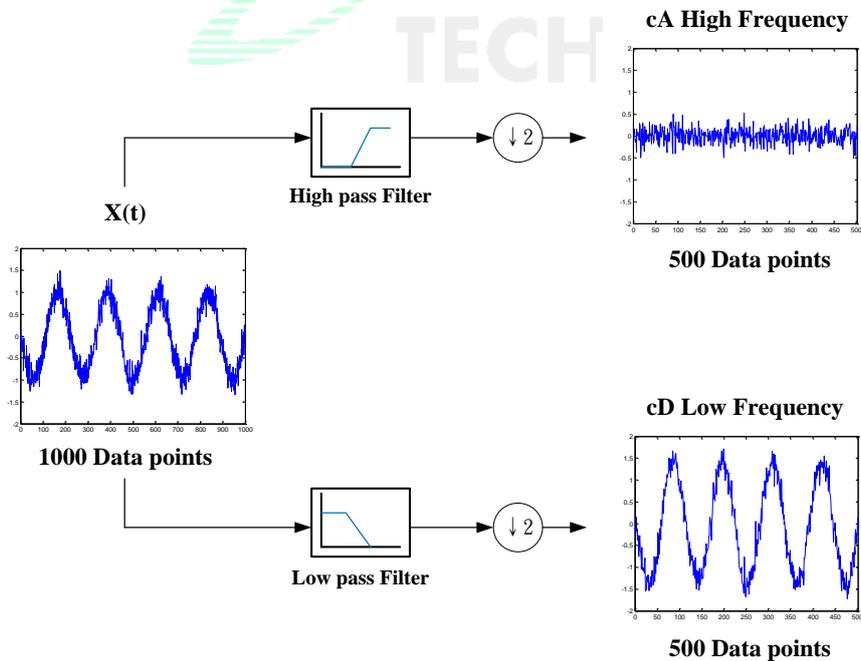


圖2.6 原始訊號通過降階採樣濾波器的結果

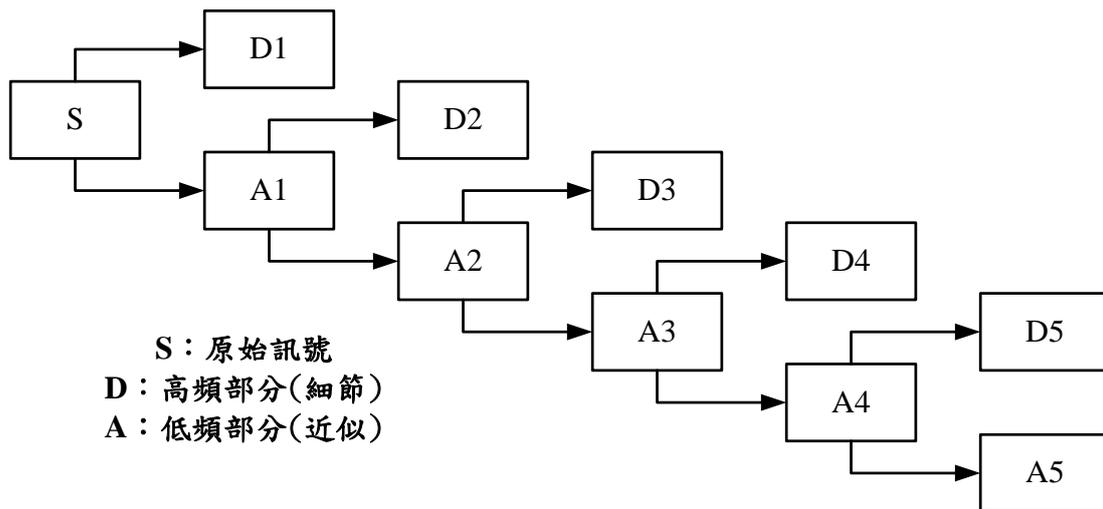


圖2.7 離散小波轉換的分解架構圖[4]

本研究將使用以 Ingrid Daubechies 命名的小波函數，也就是多貝西小波(Daubechies wavelet)來進行訊號的分解[9]，在 Matlab 中是以 dbA 的型式來表式，A 所代表的則是多貝西小波的消失動量(Vanishing moment)，而本文使用的是多貝西小波家族中的 db4，其小波函數與調整函數波形圖如圖 2.8，圖中橫軸為時間，縱軸為振幅；多貝西小波主要應用於離散型的小波轉換，最常使用在數位訊號分析的部分。[10]

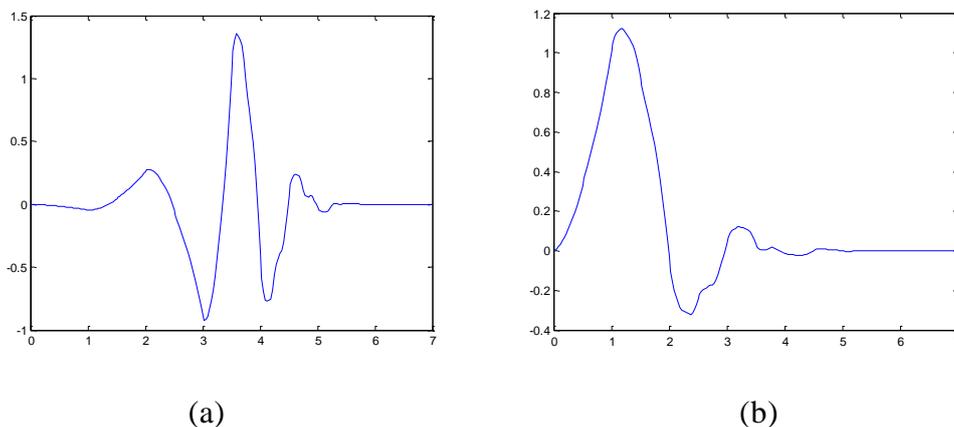


圖 2.8 db4 小波函數 (a)小波函數波形圖 (b)調整函數波形圖

原始腦電波經過 db4 的小波轉換之後，所對應到的頻段將透過下列公式計算[11]：

$$f = 2^j \left( \frac{Fs}{N_p} \right) \quad (2.9)$$

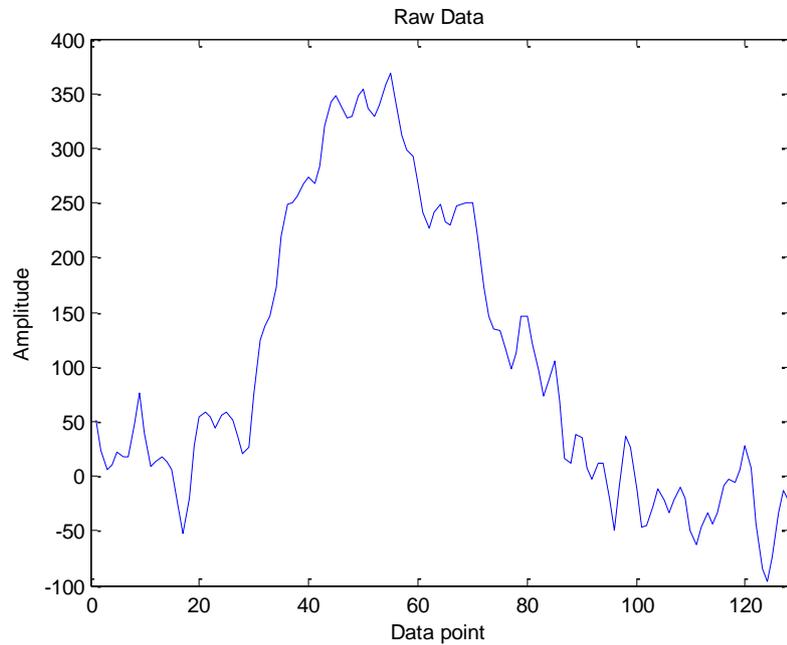
在式 2.9 中  $f$  為在第  $j$  階層時，最高的頻率上限， $Fs$  所代表的是取樣頻率(Sampling frequency)， $N_p$  為輸入的資料點數。

腦電波耳機的取樣頻率為 512 Hz，即每 1 秒鐘會輸出 512 筆原始腦電波的資料，而開眼與閉眼瞬間的速度不到  $\frac{1}{4}$  秒，為了取得開眼與閉眼瞬間的波形，並且避免輸入過多非開閉眼狀態的波形，因此本研究將輸入的資料點數設定為 128 點，如圖 2.9 所示，而重疊(Overlap)設為 78%，即每次只更新 28 筆腦電波數據，此行為是為了不使擷取腦電波的窗格平移距離過多，導致記錄不到完整的眼動狀態波形。而通過式 2.9 所計算出每階小波所對應的頻寬以及該與頻寬符合的腦電波頻段如表 2.1 所示：

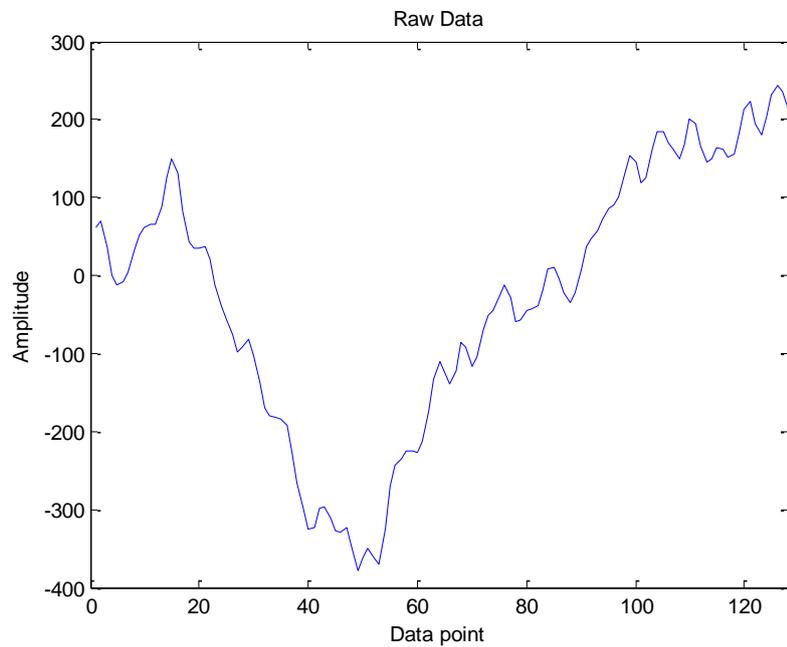
表 2.1 小波轉換後 db4 所對應的腦電波類型

Resolution (Wavelet level)	Frequency bandwidth (Hz)	對應的腦電波
0 (A5)	0-4	Delta
1 (D5)	4-8	Theta
2 (D4)	8-16	Alpha
3 (D3)	16-32	Beta
4 (D2)	32-64	Gamma
5 (D1)	64-128	Noise

從表 2.1 可以得知，將原始腦電波進行 5 階層的小波轉換，就可以取得各類型的腦電波，因此本文將依循此方法進行原始腦電波的分解，並從中尋找能夠做為分類依據的腦電波波形，其結果如圖 2.10 所示。

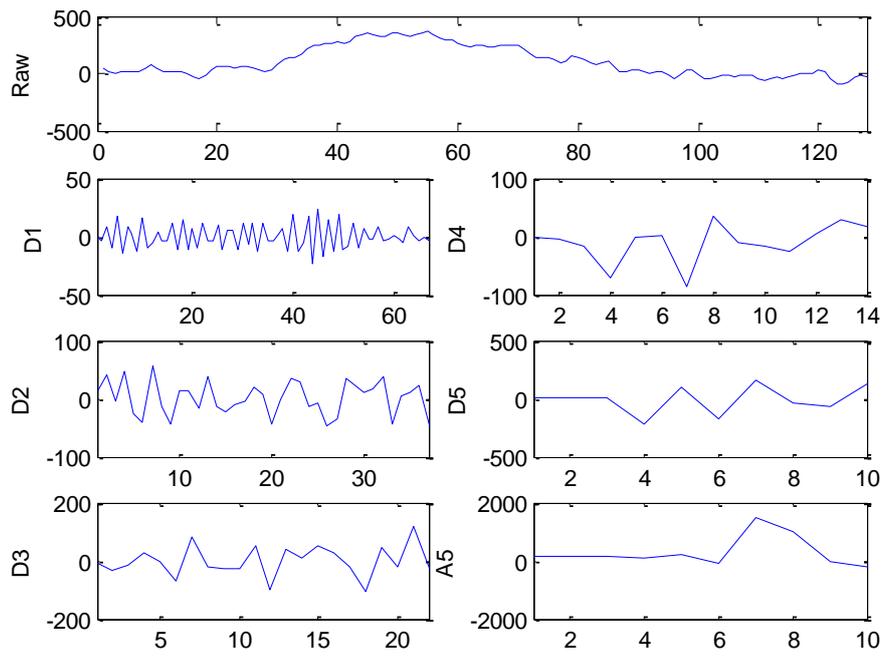


(a)

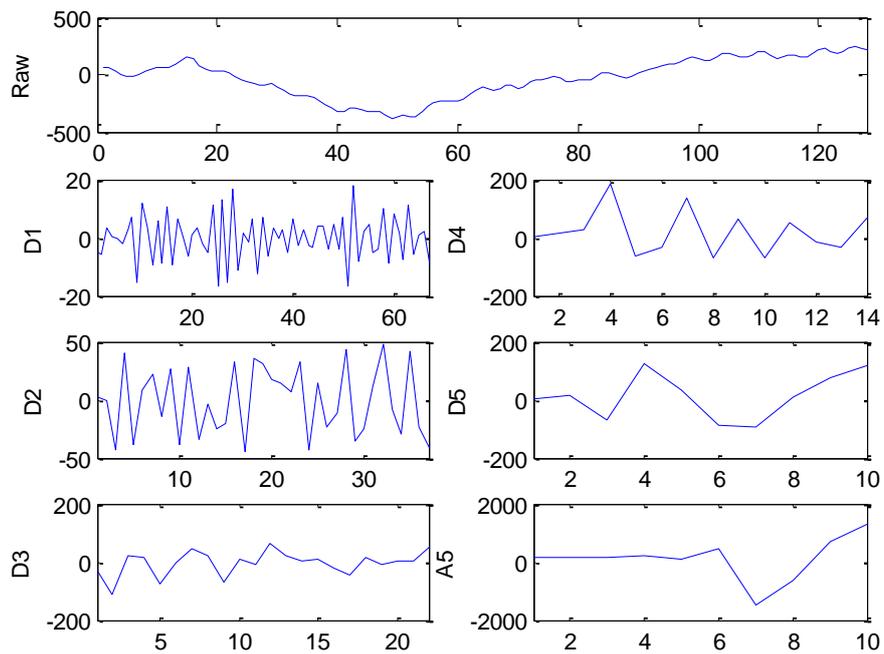


(b)

圖2.9 開閉眼狀態波形圖 (a)閉眼瞬間 (b)開眼瞬間



(a)



(b)

圖2.10 開閉眼狀態各階層的結果 (a)閉眼瞬間 (b)開眼瞬間

從圖 2.10 中可以看出，在 A5 的頻段下可以明顯分辨出開眼狀態與閉眼狀態，因此本研究將透過小波轉換後的 A5 頻段進行眼動狀態的分類，相關的特徵值選定以及計算方式會在下節說明。

## 2.4 特徵值計算

本節中將把經過小波轉換後的原始腦電波進行特徵值的計算，而計算所選取的頻段為轉換後的 A5 頻段，所使用的計算方式包含最大值(Maximum)、最小值(Minimum)、總合(Summation)、全距(Range)、標準差(Standard deviation)以及絕對中位差(Median absolute deviation)，相關的計算公式如下，假設讀取到的腦電波訊號為  $X_N(n)$ ， $N$  為第  $N$  筆 A5 頻段的資料， $N=1,2,3,\dots,N$ ， $n$  為該筆資料中的資料點數， $n=1,2,3,\dots,\tilde{N}$ 。

最大值：

$$X_{N,Max} = \max_{0 \leq n \leq N}(X_N(n)) \quad (2.10)$$

最小值：

$$X_{N,min} = \min_{0 \leq n \leq N}(X_N(n)) \quad (2.11)$$

總和：

$$X_{N,Sum} = \sum_{n=1}^{\tilde{N}} X_N(n) \quad (2.12)$$

全距：

$$X_{N,Range} = X_{N,Max} - X_{N,min} \quad (2.13)$$

標準差：

$$X_{N,\sigma} = \sqrt{\frac{1}{\tilde{N}} \sum_{n=1}^{\tilde{N}} (X_N(n) - X_{N,\mu})^2} \quad (2.14)$$

其中：

$$X_{N,\mu} = \frac{1}{\tilde{N}} \sum_{n=1}^{\tilde{N}} X_N(n) \quad (2.15)$$

絕對中位差：

$$X_{N,MAD} = \text{median}(|X_N(n) - \text{median}(X_N(n))|) \quad (2.16)$$

最大值與從第 N 筆 A5 數據中找尋最大值做為分類的特徵，同理，最小值是取第 N 筆數據的最小值，總和是指將第 N 筆 A5 頻段中的數據加總做為其中一種特徵值，全距為最大值與最小值的差距，所以較容易受到極端值影響，而標準差定義為變異數的算術平方根，計算結果與組內個體間的離散程度有關，絕對中位差是考慮資料中百分之五十的位置，故結果受到極端值的影響性比較小。經過本章節的轉換與計算之後，就可以得到用來判斷眼動狀態的特徵值，因為線上分類的時間要求，將挑選數個特徵值作為分類器分類的依據，而特徵值的選取是透過該特徵值對於分類正確率的比較，將在第四章進行說明。

## 2.5 模糊邏輯

「疲勞」一詞並不像今天是幾年幾月幾日一樣具有確定性，過了午夜 12 點的一瞬間就是另一天的開始，但疲勞是無法用一個很明確的分界線去定義的；為了解決這些具有不完整、不精確、曖昧性、隨機性、模糊性的狀況，美國加州柏克萊大學的 Zadeh 教授在 1965 年的資訊與控制 (Information and Control) 學術雜誌上，發表了「Fuzzy 集合」的論文，這個新的集合概念突破了以往的集合理論框架，如此一來，機器能夠模擬出人類的決策模式，不再透過數學模式的推導，解決了許多無法量化建立模型的現象。[12,13]

以下將以「年輕的」作為語意的模糊進行數學描述的例子說明模糊性 (fuzziness) 的數學表現，假設有一群從 20 歲到 70 歲的一般人，則「年輕的」實際上就是指「年輕的人」，如 20 歲的人、21 歲的人、...、30 歲的人等等，通常的分類方式是規定出一個界限劃分「年輕的」與「不年輕的」，例如以 30 歲為界限，超過 30 歲即為「不年輕的」，而這種二值的規定性是不合理的，因為年輕與否並不是一個是非題，而是一個程度問題。在 fuzzy 理論中是使用介於 0 和 1 之間的數來表示這些程度，20 歲的人是 20 歲到 70 歲的人中最年輕的，因此給予 1，25 歲的人比起 20 歲要老了一些，但也能稱為年輕，為 0.9，30 歲為 0.7，35 歲為 0.5，40 歲為 0.3，以此類推；70 歲的人就絕對不能稱為年輕的了，所以為 0，而 60 歲也是不能被稱為年

輕，但比起 70 年輕了一些，規定為 0.001；將上述的年齡與程度(grade)建立成表來對照，如表 2.2 所示。

表 2.2 年齡與程度對照

年輕									
年齡	20	25	30	35	40	45	...	60	70
grade	1	0.9	0.7	0.5	0.3	0.1	...	0.001	0

需要注意的是，在規定 grade 時，是有著相當大的主觀性，有人認為 45 歲還能勉強稱為「年輕的」，因此給 0.1，也有人認為 45 歲是步入中年的標準，因此，45 歲以上的 grade 均給 0 也無妨。[14]

本研究所用來偵測疲勞的系統是由閉眼的持續時間以及閉開眼的頻率作為模糊的輸入，經過模糊推論以及解模糊化來決定疲勞的程度是否達到需要提出警告。而本系統主要的結構為模糊化(Fuzzification)、模糊規則表(Rule-Table)、解模糊化(Defuzzification)，系統架構圖如圖 2.11。而相關的參數設定將在第四章進行說明。

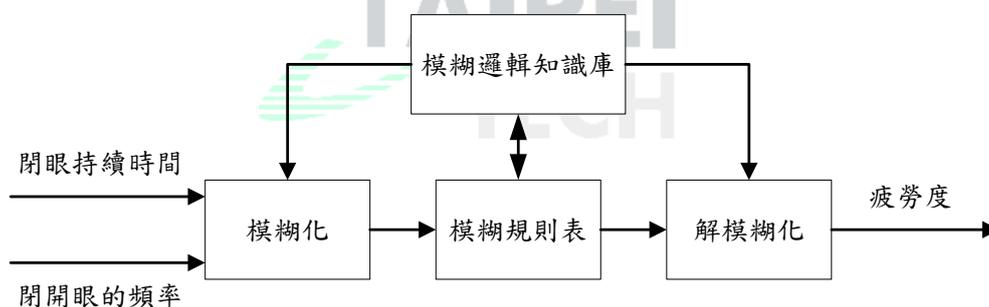


圖2.11 模糊推論過程

## 第三章 分類器介紹

### 3.1 支持向量機

本章將介紹在實驗中所使用的兩項分類器，分別是支持向量機(Support vector machine, SVM)與倒傳遞類神經網路(Back propagation neural network, BPNN)；而本節先對支持向量機的部分進行說明。

支持向量機(Support vector machine, SVM)是由 Vladimir Naumovich Vapnik 和他所屬的 AT&T 實驗室在西元 1995 年時所提出的新方法，解決了許多分類上的問題，是機器學習領域(Machine learning)中極為熱門的一種方法；SVM 屬於一種監督式學習網路(Supervised Learning Network)，所指的是一種機器學習中的方法，透過程式在訓練資料(Training Data)中建立一個輸入與輸出之間的平面，稱之為超平面(Hyperplane)，並透過建立出的超平面來推測新的輸入資料所對應的輸出結果。在典型的分類問題中，SVM 的表示法定義如下[15]：

$x_i$ ：向量(Vector)，用來表示  $N$  維資料個樣式(Pattern)， $x_i \in R^N$ ， $i = 1, 2, 3, \dots, m$ 。

$y_i$ ：稱為標籤(Label)或目標(Target)，在假設目標為兩類時通常以  $\{\pm 1\}$  來表示， $+1$  與  $-1$  分別為不同的類別(Class)， $y_i \in \{\pm 1\}$ ， $i = 1, 2, 3, \dots, m$ 。

當 SVM 在處理不同的問題時又可以細分為線性 SVM 與非線性 SVM 兩種，線性的支持向量機分類將從輸入訓練的資料中，找出一個區分超平面(Separating hyperplane)使兩種資料的邊界(Margin)可以最大化，如圖 3.1，圖中  $d_+$  與  $d_-$  分別為標籤  $+1$  與  $-1$  的資料距離區分超平面的最短距離，而在此之前要先定義每個向量所對應的標籤：

$$(x_1, y_1), \dots, (x_i, y_i), x_i \in R^N, y_i \in \{-1, +1\}$$

而區分超平面可定義為  $f: x \cdot w + b$ ，若  $f$  值大於 0，則將該筆資料歸類到  $+1$ ，反之若  $f$  小於 0，則將資料歸類到  $-1$ 。但是依照這樣的分類方式， $w$

與  $b$  將有無限多種組合，而此問題可以藉由找尋最大區域的區分超平面來將資料最大限度的分開，透過這個方法將可以有效的降低測試錯誤。此時支持向量機必須滿足以下條件：

$$x_i \cdot w + b \geq +1 \text{ for } y_i = +1 \quad (3.1)$$

$$x_i \cdot w + b \leq -1 \text{ for } y_i = -1 \quad (3.2)$$

可將式 3.1 與式 3.2 結合成以下不等式：

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall i \quad (3.3)$$

從式 3.1 與式 3.2 分別到  $x \cdot w + b = 0$  的距離為  $\frac{1}{\|w\|}$ ，所以邊界為  $\frac{2}{\|w\|}$ 。

如果要尋找區分超平面的最大邊界，就是在符合式 3.3 的條件下，求出  $\|w\|^2$  的最小值，若存在任何一個  $x_i$  可以使等號成立，則稱  $x_i$  為支持向量 (Support vector)。如圖 3.2，圖中圈起來的資料就是支持向量。

為了求出  $\|w\|^2$  的最小值，可以使用拉格朗日 (Lagrange) 最佳化問題來處理，拉格朗日函數 (Lagrange function) 表示如下：

$$L_p(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i [y_i(w \cdot x_i + b) - 1] \quad (3.4)$$

其中， $\alpha_i$  為拉格朗日係數且  $\alpha_i > 0$ ，通過對式 3.4 中的  $w$  和  $b$  進行偏微分並令其等於 0，可以得到以下兩個關係式：

$$w = \sum_{i=1}^l y_i \alpha_i x_i \quad (3.5)$$

$$0 = \sum_{i=1}^l y_i \alpha_i \quad (3.6)$$

將式 3.5 代回式 3.4 中，就能得到其對偶型式 (Dual form)，並將問題從最小化轉變成最大化的問題：

$$\text{maximize} \quad L_D(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (x_i \cdot x_j)$$

$$\text{subject to} \quad \alpha_i \geq 0, \quad \forall i = 1, \dots, l \quad \text{以及} \quad \sum_{i=1}^l \alpha_i y_i = 0$$

再來根據 Karush Kuhn-Tucker (KKT) 理論，代入最佳化解 ( $w^* \cdot b^*$ ) 即可得到式 (3.7)，且  $\alpha_i^*$  的值一定大於或等於零，此結果會使  $y_i(w_i^* \cdot x_i + b^*) - 1$  必定為零。

$$\sum_{i=1}^m \alpha_i^* [y_i^*(w^* \cdot x_i + b^*) - 1] = 0 \quad (3.7)$$

從上述的結果中可以得知，如果存在著  $x_i$  可以滿足上式，這些  $x_i$  就是最接近最佳化區分超平面的向量，亦即若有一個  $x_i$  的  $\alpha_i^* \geq 0$ ，就可以稱為支

持向量。在找到支持向量之後，也等於找到最大邊界。最後可以歸納出一個分類處理問題的函數：

$$f(x) = \text{sgn}(\sum_{i=1}^m y_i \alpha_i \cdot (x_i \cdot x_i) + b) \quad (3.8)$$

當 $f(x) > 0$ 時，表示該筆資料的分類與標籤為+1 的資料為同一類，反之則屬於另外一類。

SVM 當中另一項重要的關鍵則是核函數(Kernel function)，透過核函數，SVM 能將輸入的資料集映射到特徵空間(Feature space)之中，而不同的核函數都有著不同的分類結果，常見的核函數有線性函數、多項式函數、放射型函數、S 型函數，以下為各個核函數的定義：

線性核函數 (Linear)：

$$K(x_i, x_j) = (x_i, x_j) \quad (3.9)$$

多項式核函數 (Polynomial)：

$$K(x_i, x_j) = (x_i^T x_j + 1)^d \quad (3.10)$$

放射型核函數 (Radial basis function, RBF)：

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (3.11)$$

S 型核函數 (Sigmoid)：

$$K(x_i, x_j) = \tanh(kx_i x_j - \delta) \quad (3.12)$$

而在王麟璋[16]以及韓歆儀[17]的研究成果中指出，使用多項式核函數的分類準確率較佳，因此本研究將選用多項式核函數。

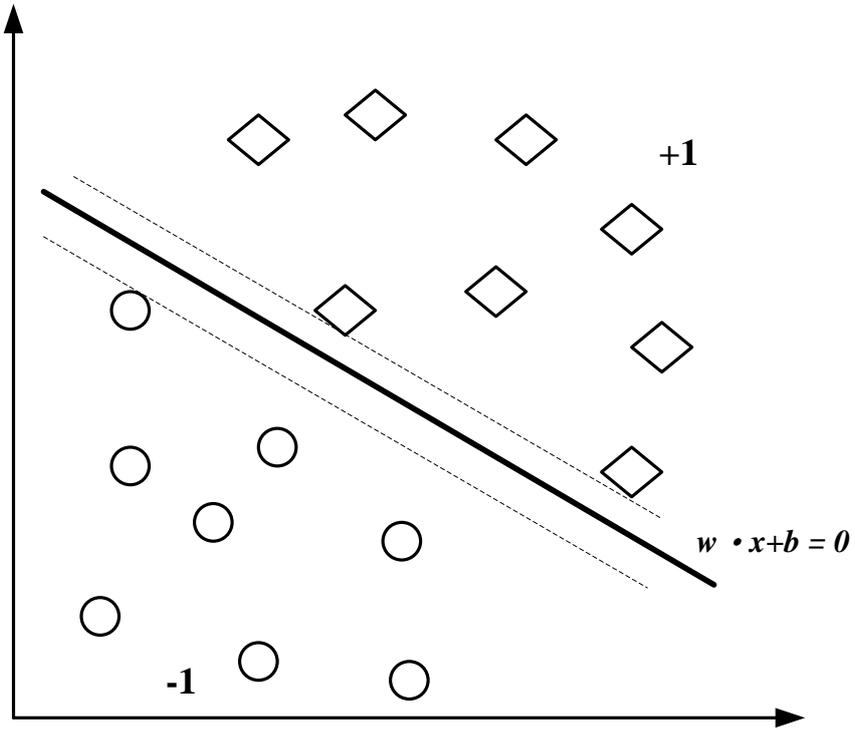


圖3.1 超平面示意圖

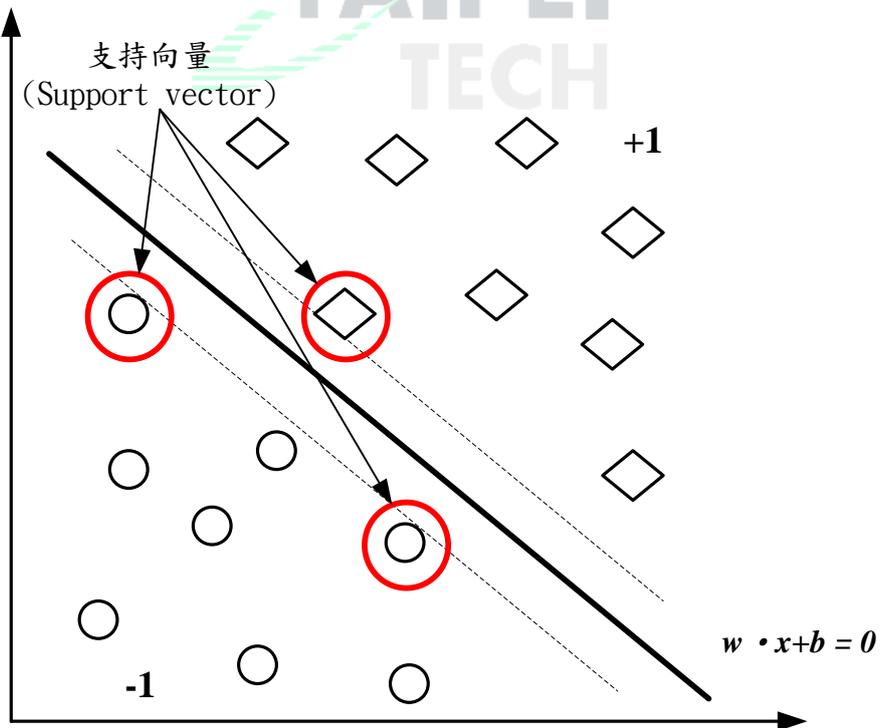


圖3.2 最大化區分邊界圖

## 3.2 倒傳遞類神經網路

類神經網路(Artificial neural network, ANN)是由許多人工神經細胞所組成，這些細胞又稱處理單元、人工神經元；其輸入值與輸出值之間的關係式，一般可用輸入值的加權乘積和之函數來表示，神經元的模型如圖 3.3 所示。

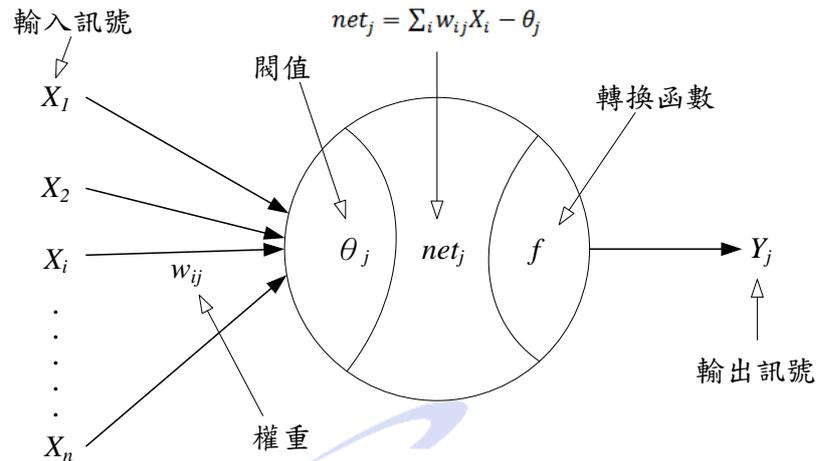


圖 3.3 人工神經元模型

從圖 3.3 可以得知，在第  $n$  層的第  $j$  個單元的輸出值，是由第  $n-1$  層單元輸出值的非線性函數，如式 3.13：

$$Y_j^n = f\left(\text{net}_j^n \sum_{i=1}^n W_{ij} Y_i^{n-1} - \theta_j\right) = f(\text{net}_j^n) \quad (3.13)$$

上式中  $\text{net}_j^n$  為集成函數， $f$  則是轉換函數。

倒傳遞類神經網路(Back propagation neural network, BPNN)是目前類神經網路學習模式中最具代表性且應用最普遍的模式，基本的 BPNN 架構圖如圖 3.4。

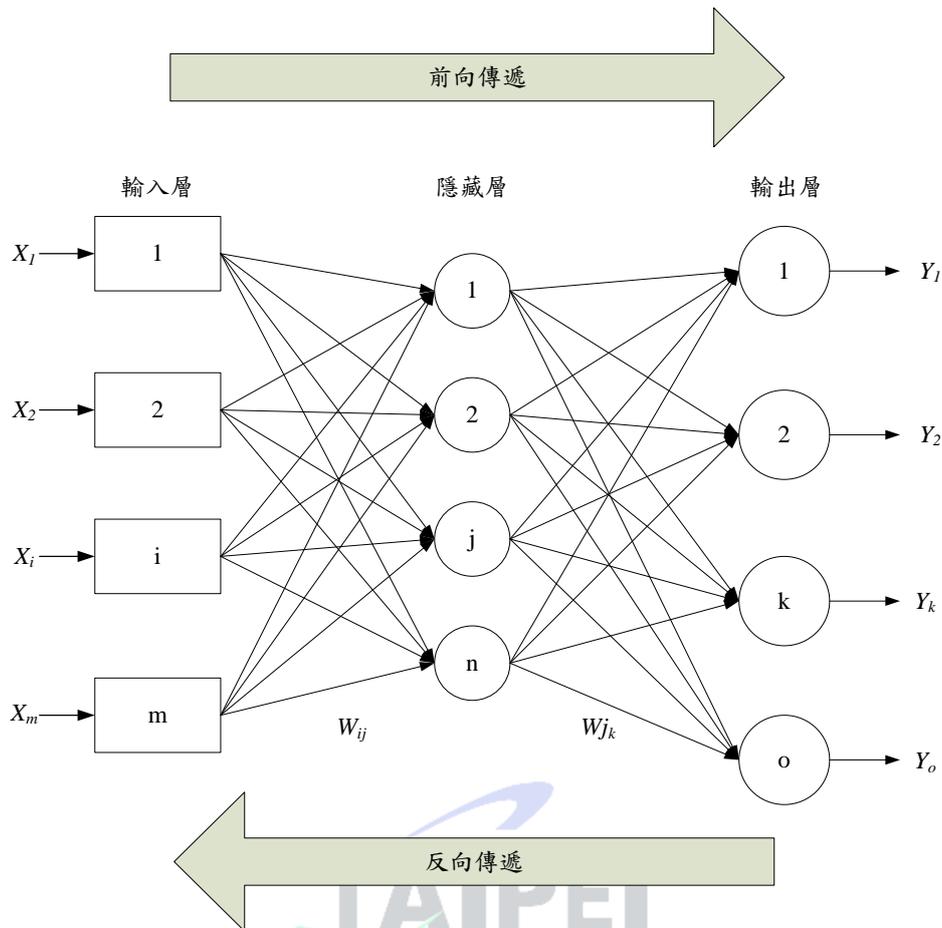


圖 3.4 倒傳遞類神經網路架構圖

在前向傳遞中，從輸入層(Input layer)輸入特徵值，藉著初始設定的權重值，將輸入層的數據傳遞到隱藏層。再來經過轉換函數(Transfer function)將輸入的總和轉換為隱藏層的變數，轉換函數是負責將輸入的訊號總合，轉換並傳到下一層；而人類的神經在處理外部刺激時，輸出的訊號是有極限的，所以在轉換函數的選取時，不能選擇傳統的線性函數，通常會改用兼具正向收斂與負向收斂的 S 型函數，本研究所選擇的 S 型轉換函數為雙曲線正切函數(Hyperbolic Tangent function)。圖 3.4 即為雙曲線正切函數，而公式如式 3.14：

$$f(\text{net}_j) = \frac{e^{\text{net}_j} - e^{-\text{net}_j}}{e^{\text{net}_j} + e^{-\text{net}_j}} \quad (3.14)$$

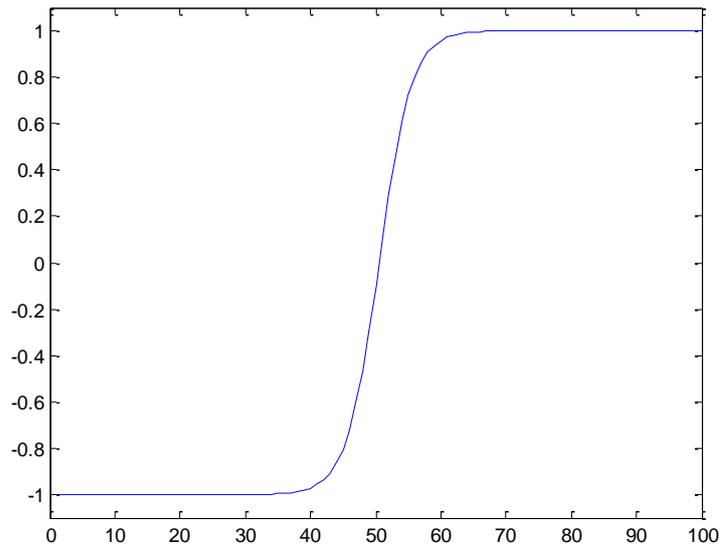


圖3.5 雙曲線正切函數

隱藏層(Hidden layer)的功能主要是增加類神經網路的複雜性，以模擬許多複雜的非線性關係，但如果隱藏層過多，容易使整個類神經網路記憶了訓練組的資料結構，產生過度學習(Over fitting)的狀況；從隱藏層到輸出層會再經過另一次的權重計算與加總，使隱藏層的資訊轉換為輸出資料，再透過誤差函數計算理想的輸出值與類神經網路計算的輸出值之間的差距，本文選用的誤差函數為均方誤差(Mean squared error, MSE)，公式如式 3.15，式中  $T_k$  為輸出層目標值， $Y_k$  則為類神經計算的輸出層推論值。完成前向傳遞後，進入反向傳遞。

$$E = \frac{1}{2} \sum_{k=1}^n (T_k - Y_k)^2 \quad (3.15)$$

反向傳遞則是從輸出層開始往回推並更新權重，使誤差函數最小化。因此，整個倒傳遞類神經網路的學習過程就變成了將誤差函數最小化的過程，通常以最陡坡降法(The gradient steepest descent method)來最小化誤差函數，每當輸入一個訓練樣本時，網路就會小幅度調整權重的大小，而誤差函數對加權值的敏感度跟調整的幅度有著正比關係，也就是跟誤差函數對加權值的偏微分成正比：

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E}{\partial W_{ij}} \quad (3.16)$$

式 3.16 中  $W_{ij}$  為第  $n-1$  層中的第  $i$  個處理單元，與第  $n$  層中的第  $j$  個處

理單元之間的權重； $\eta$ 為學習速率(Learning rate)，控制著每次使用最陡坡降法最小化誤差函數的步幅。使用連鎖率將 $\frac{\partial E}{\partial W_{ij}}$ 展開後可得

$$\frac{\partial E}{\partial W_{ij}} = \left( \frac{\partial E}{\partial \text{net}_j^n} \right) \left( \frac{\partial \text{net}_j^n}{\partial W_{ij}} \right) \quad (3.17a)$$

$$\frac{\partial E}{\partial W_{ij}} = \left( \frac{\partial E}{\partial A_j^n} \right) \left( \frac{\partial A_j^n}{\partial \text{net}_j^n} \right) \left( \frac{\partial \text{net}_j^n}{\partial W_{ij}} \right) \quad (3.17b)$$

把集成函數代入式 3.17b 中第三項中就能得到

$$\frac{\partial \text{net}_j^n}{\partial W_{ij}} = \frac{\partial}{\partial W_{ij}} \left( \sum_{k=1}^n W_{kj} A_k^{n-1} - \theta_j \right) = A_i^{n-1} \quad (3.18)$$

而將式 3.13 代入式 3.17b 第二項，可得

$$\frac{\partial A_j^n}{\partial \text{net}_j^n} = \frac{\partial}{\partial \text{net}_j^n} f(\text{net}_j^n) = f'(\text{net}_j^n) \quad (3.19)$$

如果第  $n$  層就是最終層，則將 3.15 式帶入

$$\frac{\partial E}{\partial \text{net}_j^n} = \frac{\partial}{\partial \text{net}_j^n} \left[ \frac{1}{2} \sum_{k=1}^n (T_k - A_k)^2 \right] = -(T_j - A_j^n) \quad (3.20)$$

而如果  $n$  並不是最終層，而是網路的隱藏層之一，則可以推導出

$$\frac{\partial E}{\partial A_j^n} = - \sum_{k=1}^n \delta_k^{n+1} \cdot W_{jk} \quad (3.21)$$

最後可將 $\frac{\partial E}{\partial W_{ij}}$ 寫成通式：

$$\frac{\partial E}{\partial W_{ij}} = - \delta_j^n \cdot A_i^{n-1} \quad (3.22)$$

其中 $A_i^{n-1}$ 為 $W_{ij}$ 所連接之較低層的處理單元輸出值； $\delta_j^n$ 為 $W_{ij}$ 所連接之較上層的處理單元之差距量，如果 $W_{ij}$ 所連接的較上層處理單元為輸出層，則 $\delta_j^n = (T_j - Y_j) \cdot f'(\text{net}_j^n)$ ，否則 $\delta_j^n = \left[ \sum_{k=1}^n \delta_k^{n+1} \cdot W_{jk} \right] \cdot f'(\text{net}_j^n)$

將式 3.22 代入式 3.16 之中可得

$$\Delta W_{ij} = \eta \cdot \delta_j^n \cdot A_i^{n-1} \quad (3.23)$$

本研究中所使用的非線性轉換函數為雙曲線正切函數，若依照式 3.19 對式 3.14 的 $\text{net}_j$ 進行微分就可以得到

$$f'(\text{net}_j) = [1 + f(\text{net}_j)] \cdot [1 - f(\text{net}_j)] \quad (3.24)$$

而透過最陡坡降法可以導出輸出層的差距量 $\delta$ 為

$$\delta_j = (T_j - Y_j) \cdot f'(\text{net}_j) = (T_j - Y_j) \cdot (1 + Y_j) \cdot (1 - Y_j) \quad (3.25)$$

同理可證閾值  $\theta$  的變化量公式如下

$$\Delta \theta = -\eta \cdot \delta_j^n \quad (3.26)$$

透過上述推導的結果，每次的反向傳遞時都可以得知權重與閾值的差距量，藉由逐步更新權重以及閾值，將能夠使誤差函數漸漸收斂。[18,19]

由於在類神經網路中，許多參數都是根據問題類型決定，如輸入層的神經元個數、隱藏層的層數以及轉換函數的選擇等，而本研究將使用兩個隱藏層，而輸入的特徵值數量將在第四章說明。



## 第四章 實驗結果

### 4.1 權重訓練

使用 SVM 以及 BPNN 進行眼動狀態的分類之前，要先給定一些標準特徵進行權重的訓練，而標準特徵是透過離線特徵抓取的實驗取得，流程圖如圖 4.1，實驗進行的方式是請九位受測者在電腦的鏡頭前分別進行 15 次的開眼與閉眼，透過程式將每次開眼與閉眼的間隔時間控制為 1 秒，再由協助者協助實驗影片拍攝與程式控制；待實驗結束後再從影片中尋找開眼與閉眼的時間點，並以資料點數為 128 的窗格擷取開眼或閉眼的原始腦電波，計算該窗格內的特徵值，之後就可以輸入到 SVM 及 BPNN 之中進行最佳區分超平面以及神經元之間的各項參數的訓練；權重訓練所輸入的樣本為九位受測者中隨機挑選五位，另外四位的腦電波資料則是當作測試資料輸入給 SVM 與 BPNN，計算分類正確率。

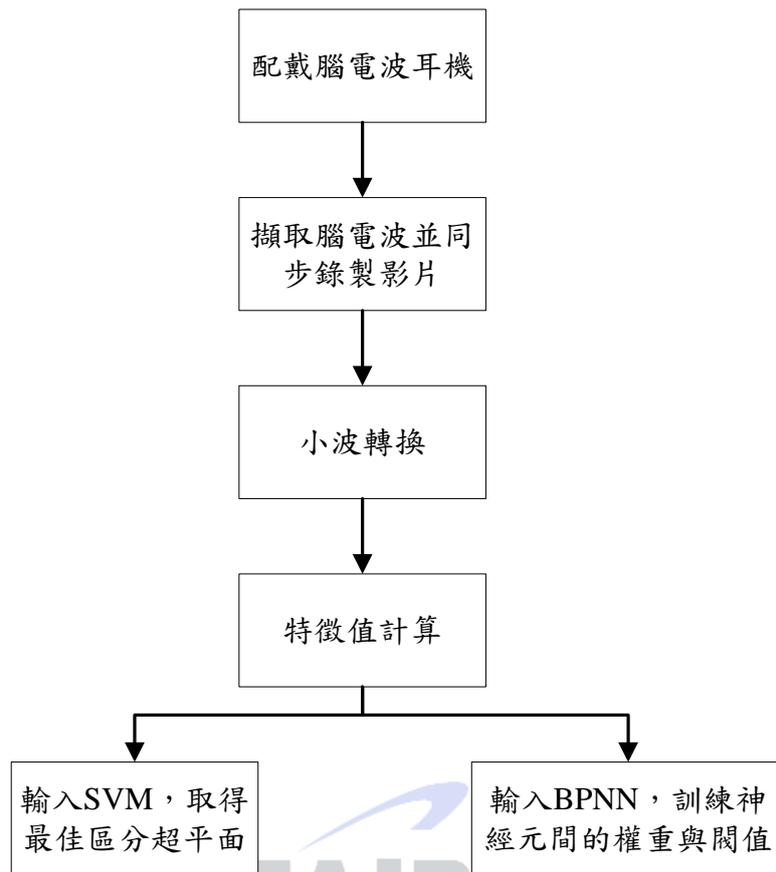


圖4.1 離線特徵抓取

從腦電波耳機傳送出的腦電波原始資料中，可以取得開眼、閉眼以及非眼動狀態的原始腦電波，而透過程式將腦電波繪製成波形圖，結果如下。

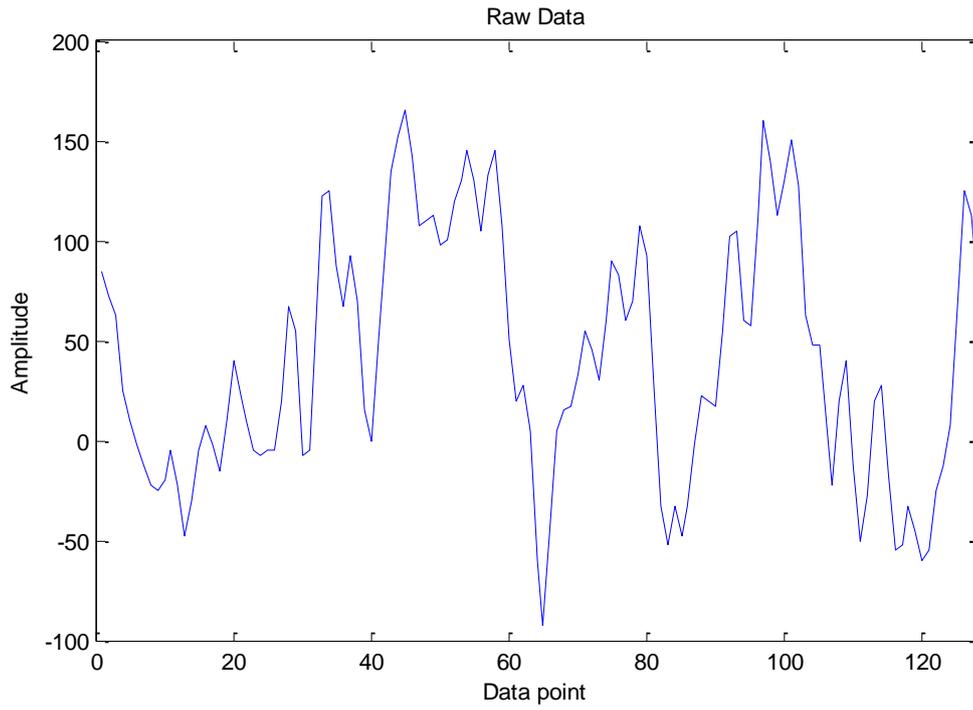


圖4.2 非眼動狀態時域響應圖

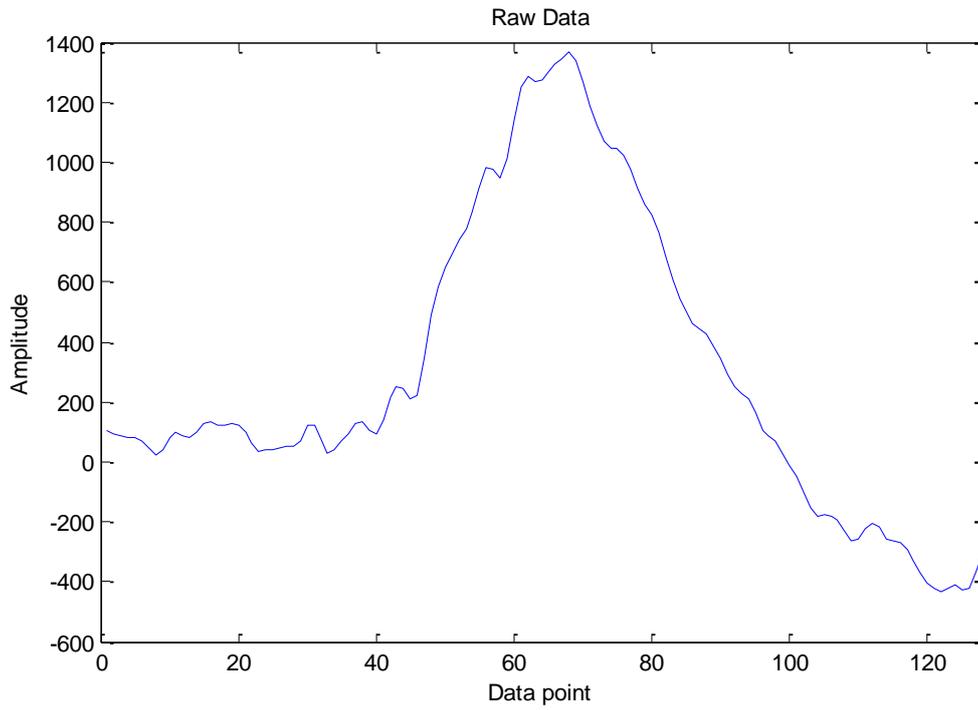


圖4.3 閉眼瞬間時域響應圖

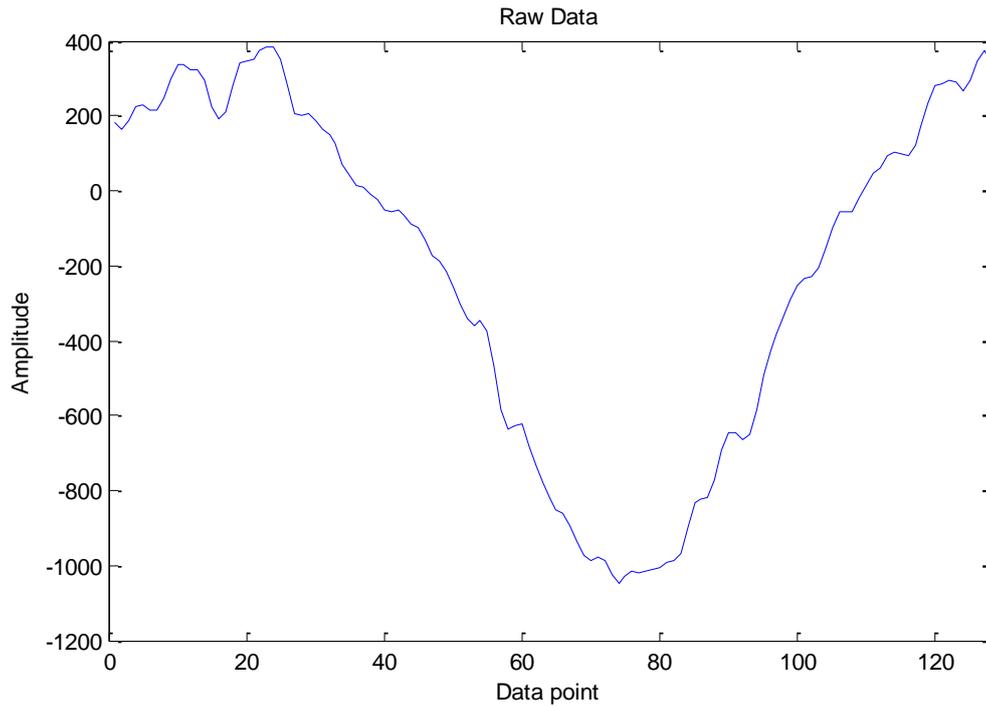


圖4.4 開眼瞬間時域響應圖

由圖 4.2-4.4 中可以明顯看出閉眼與開眼瞬間的時域響應圖和非眼動狀態的時域響應圖有著相當大的差別性，再對眼動狀態的訊號進行小波轉換，提取 A5 的部分進行特徵值的計算；圖 4.5-4.6 為小波轉換的結果，表 4.1 則為使用 A5 頻段計算出的特徵值，相關的公式已在第二章時介紹；4.2 節將使用部分特徵值進行分類正確率的比較並選擇線上測試時所使用的特徵值。

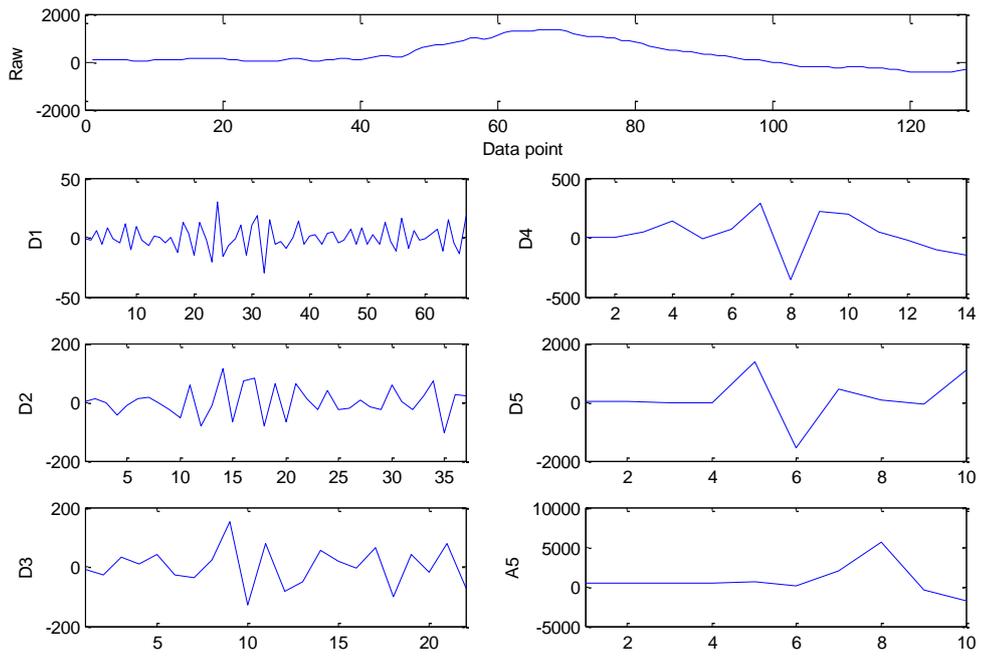


圖4.5 開眼瞬間小波轉換結果

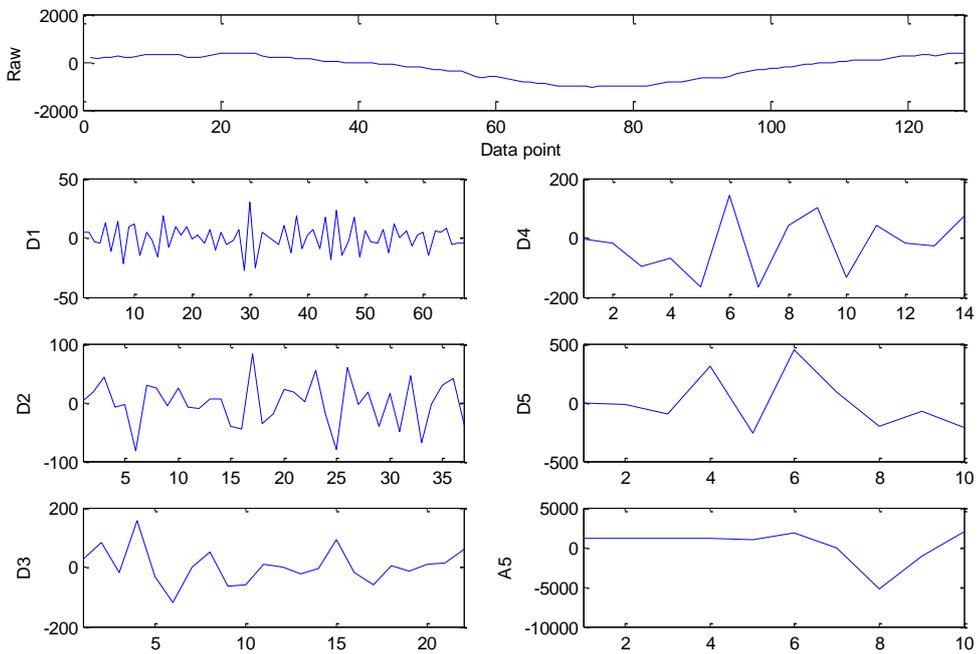


圖4.6 開眼瞬間小波轉換結果

表 4.1 開眼與閉眼瞬間的特徵值

特徵	閉眼瞬間	開眼瞬間
最大值	5676.19	2061.02
最小值	-1849.35	-5326.20
總和	8054.66	2795.14
全距	7525.55	7387.22
標準差	1865.36	2053.97
絕對中位差	255.42	388.58



## 4.2 特徵值選取

在第二章中所提到的各項特徵值計算公式，在本節中將對其進行分類正確率的實驗，以及挑選能夠做為主要分類依據的特徵值，而本研究所使用的分類正確率公式如下：

$$\text{分類正確率}(\%) = \frac{\text{分類正確}}{\text{分類資料總數}} \times 100\% \quad (4.1)$$

$$\text{平均分類正確率}(\%) = \frac{\text{分類正確率}}{\text{實驗執行次數}} \times 100\% \quad (4.2)$$

由於本研究中使用 SVM 以及 BPNN 兩種分類器，所以在特徵值選取的部分將分開進行實驗，並選擇能同時提供良好正確率的特徵值，做為後續實驗的特徵值。

### 4.2.1 不同分組方式的分類正確率

在測試分類正確率的實驗中，將把數據以全內部、半內部以及全外部的的方式分組，一部分做為訓練樣本(Training)輸入到 SVM 與 BPNN 中，另一部分則做為測試樣本(Testing)進行分類正確率的實驗，再比較結果[20]。三種樣本的分組方式如下：

全內部：使用全部的數據進行訓練，再使用相同的數據進行測試，觀察分類正確率。此行為的目的是希望透過正確率來判斷本實驗所選用的分類器是否符合需求。

半內部：只使用一半的數據進行訓練，而使用全部的數據測試。目的是希望藉由沒有被訓練到的數據，觀察兩種分類器是否有過度學習的情況產生。

全外部：僅使用一半的數據進行訓練，而由完全沒有被包含的另一半數據執行測試。此目的是為了模擬未來進行線上分類時，分類器是否還能維持良好的分類正確率。而分類的流程圖如圖 4.7。

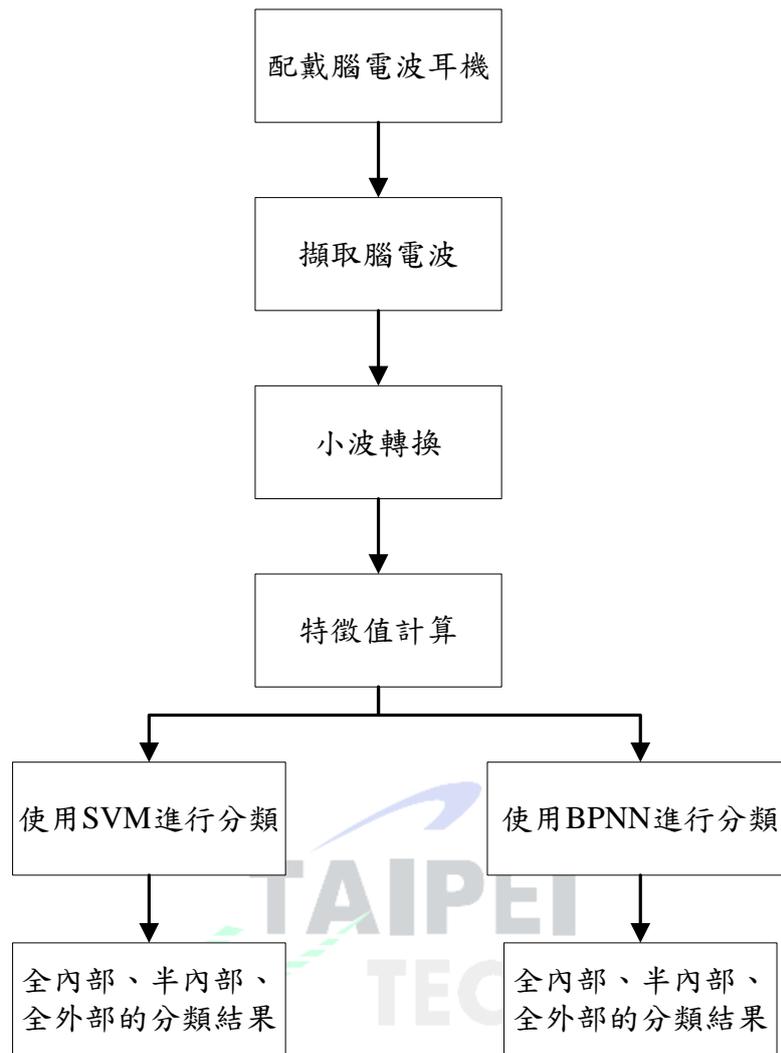


圖4.7 不同分組方式的分類正確率實驗流程圖

在此選擇的特徵值為腦電波經由 128 筆資料點數進行擷取，再透過小波轉換取得 A5 頻段並計算出最大值、最小值、總和、全距、標準差以及絕對中位差等六種特徵值，以全部特徵值輸入 SVM 及 BPNN 之中，表 4.1 為三種分組方式分別對應的 SVM 及 BPNN 的分類結果；而主要的特徵值選用將在後續章節中提出；分類正確率如表 4.2 所示。

表 4.2 三種分組方式的正確率

	全內部	半內部	全外部
訓練與測試 資料數	訓練資料：180 筆 測試資料：180 筆	訓練資料：90 筆 測試資料：180 筆	訓練資料：90 筆 測試資料：90 筆
SVM	分類正確率 97.22%	分類正確率 88.89%	分類正確率 82.22%
BPNN	分類正確率 93.33%	分類正確率 91.67%	分類正確率 88.89%

從上表所顯示的結果中可以看出，不管在全內部、半內部或是全外部，SVM 與 BPNN 都保有一定的穩健性以及良好的分類正確率，兩個分類器的結果都顯示適合應用在腦電波波形的分類。而在後續的章節中將經由特徵值選擇實驗，希望可以透過特定的特徵值達到以上的成果。

#### 4.2.2 輸入兩個特徵值分類正確率比較

本節中把六個特徵值每兩個分為一組進行分類正確率比較，全部實驗都是使用全外部的分組方式進行，圖4.8為SVM使用最大值與最小值做為分類標準所繪製的區分超平面，圖4.9為輸入兩個特徵的BPNN架構圖，在隱藏層的部分是選擇使用兩層隱藏層，而每層的神經元個數則是選擇與輸入的特徵值數量相同。

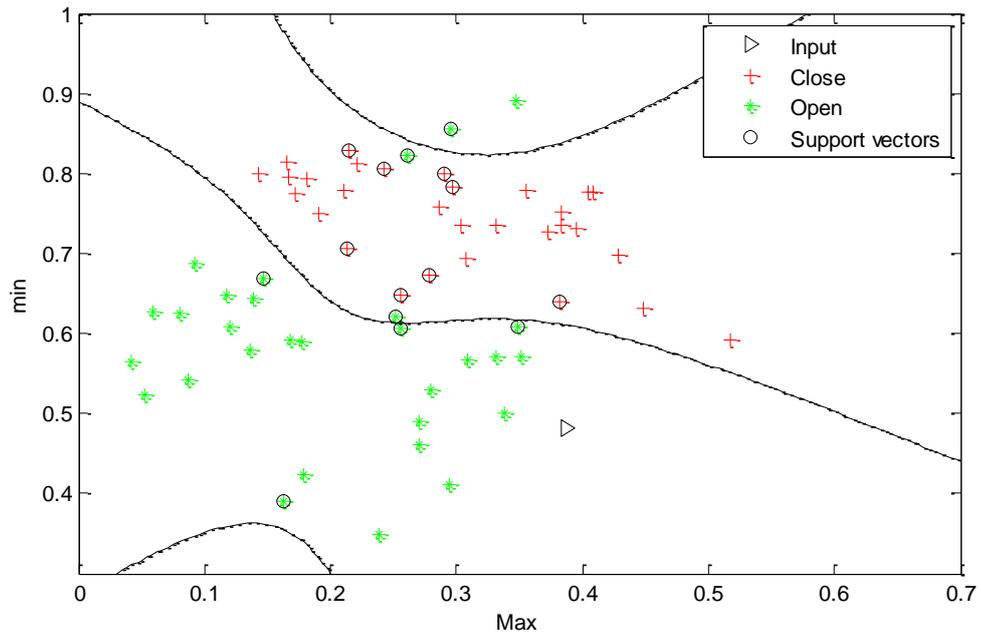


圖4.8 輸入兩個特徵的區分超平面

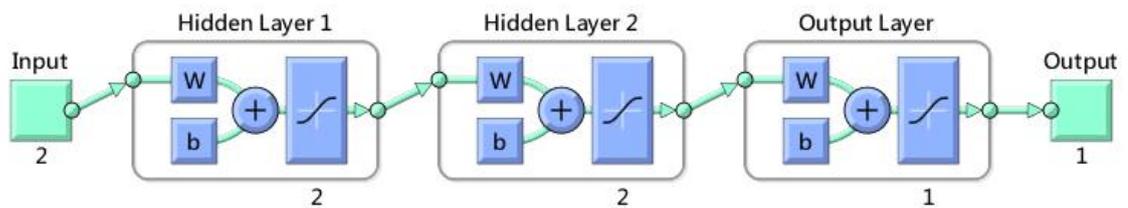


圖4.9 輸入兩個特徵的BPNN架構圖

表4.3中依序為最大值與最小值、最大值與總和、最大值與全距等15種組合的SVM與BPNN分類結果比較。

表 4.3 兩個輸入特徵排列組合的分類正確率

組合	SVM	BPNN
最大值、最小值	95.83%	95.00%
最大值、總和	83.33%	84.17%
最大值、全距	95.00%	97.50%
最大值、標準差	96.67%	94.17%
最大值、絕對中位差	77.50%	80.83%
最小值、總和	81.67%	86.67%
最小值、全距	93.33%	95.83%
最小值、標準差	92.50%	95.00%
最小值、絕對中位差	74.17%	75.00%
總和、全距	78.33%	83.30%
總和、標準差	82.50%	84.17%
總和、絕對中位差	80.83%	81.67%
全距、標準差	40.00%	50.83%
全距、絕對中位差	49.17%	43.33%
標準差、絕對中位差	53.33%	50.00%

從表4.3中可以發現，含有最大值與最小值作為輸入特徵時的分類正確率相當的高，因為在閉眼與開眼的特徵中最大值與最小值的差異性最大，使得在這個部分的分類正確率達到90%以上；同理，總和、全距也達到80%左右的分類正確率，其他的正確率都不太理想，但由於離線測試可以調整特徵出現的位置，所以能輸入最佳特徵，因此，為了能在線上測試時提供穩定的分類，希望能將分類正確率再提高；接下來將輸入的特徵值增加到三個，並以同樣的方式測試分類正確率。

### 4.2.3 輸入三個特徵值分類正確率比較

在4.2.2節的實驗中得知，輸入兩個特徵值所得到的分類正確率不夠理想，因此本節將輸入調整為三個特徵值，進行SVM與BPNN的分類正確率實驗；由於輸入的特徵變為三個，SVM的區分超平面也轉變為三維空間，如圖4.10所示，其中x軸為最大值，y軸為最小值，z軸為總和；而圖4.11則為三個特徵的BPNN架構圖，在輸入三個特徵值的實驗中，一樣選擇兩層隱藏層的BPNN架構，而隱藏層中的神經元個數也隨著輸入的特徵值增加而增加至三個。

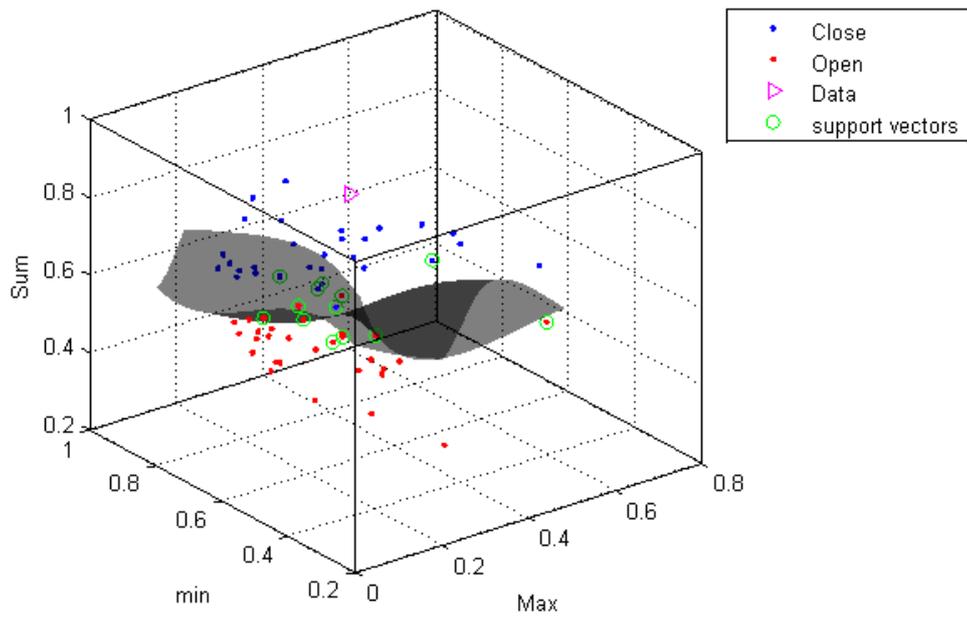


圖4.10 輸入三個特徵的區分超平面

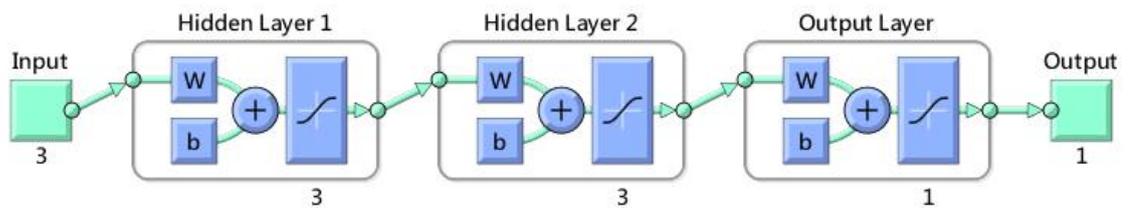


圖4.11 輸入三個特徵的BPNN架構圖

表4.4為輸入三個特徵值進行排列組合後取得20種組合，再使用SVM以及BPNN進行開閉眼分類實驗的平均分類正確率。

表 4.4 三個輸入特徵排列組合的分類正確率

組合	SVM	BPNN
最大值、最小值、總和	95.83%	96.67%
最大值、最小值、全距	94.17%	95.83%
最大值、最小值、標準差	94.17%	97.50%
最大值、最小值、絕對中位差	96.67%	95.83%
最大值、總和、全距	96.67%	96.67%
最大值、總和、標準差	91.67%	95.83%
最大值、總和、絕對中位差	85.00%	88.33%
最大值、全距、標準差	95.83%	96.67%
最大值、全距、絕對中位差	95.83%	96.67%
最大值、標準差、絕對中位差	95.83%	97.50%
最小值、總和、全距	96.67%	96.67%
最小值、總和、標準差	93.33%	93.33%
最小值、總和、絕對中位差	82.50%	84.17%
最小值、全距、標準差	92.50%	97.50%
最小值、全距、絕對中位差	96.67%	96.67%
最小值、標準差、絕對中位差	90.00%	95.83%
總和、全距、標準差	78.33%	82.50%
總和、全距、絕對中位差	75.00%	80.83%
總和、標準差、絕對中位差	78.33%	81.67%
全距、標準差、絕對中位差	48.33%	45.00%

從表4.3-4.4的結果當中，可以發現，分類正確率跟最大值與最小值兩項特徵值有著很大的關係，同時也跟總和、全距有關連性，另一方面也可以得知標準差及絕對中位差都會使分類正確率下降，因此在下一章節的四特徵分類中將以最大值、最小值兩項特徵為主，與其他特徵值進行排列組合，找出能提供最高的分類正確率的四個特徵。

#### 4.2.4 輸入四個特徵值分類正確率比較

從前兩節的結果中，可以看出雖然輸入三個特徵值分類的正確率得到了提升，但因為離線的眼動狀態分類可以透過手動調整窗格，將輸入的波形完整呈現，線上分類時將無法進行波形的調整，所以本研究希望的離線分類正確率能夠趨近於99%，因此在本節中再將輸入的特徵值數量增加，使用四個特徵值做為輸入，再使用SVM以及BPNN進行分類正確率的實驗，而由於輸入四個特徵值，SVM的維度提升到四維，無法直接將區分超平面畫出；使用四個特徵輸入的BPNN架構圖則如圖4.12所示，使用兩層隱藏層，每層的神經元的個數變更為四個。

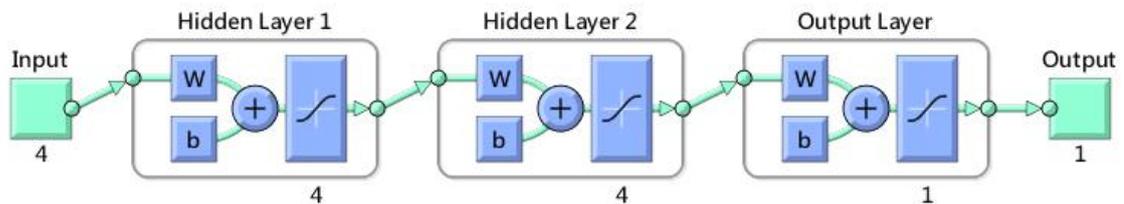


圖4.12 輸入四個特徵的BPNN架構圖

使用四個特徵值排列組合進行SVM與BPNN分類的分類正確率結果比較表，如表4.5所示，經排列組合後，共有15種組合分別進行實驗。

表 4.5 輸入四個特徵排列組合的分類正確率

組合	SVM	BPNN
最大值、最小值、總和、全距	95.83%	98.33%
最大值、最小值、總和、標準差	95.00%	97.50%
最大值、最小值、總和、絕對中位差	95.83%	94.17%
最大值、最小值、全距、標準差	93.33%	98.33%
最大值、最小值、全距、絕對中位差	92.50%	95.83%
最大值、最小值、標準差、絕對中位差	93.33%	97.50%
最大值、總和、全距、標準差	95.00%	95.00%
最大值、總和、全距、絕對中位差	92.50%	97.50%
最大值、總和、標準差、絕對中位差	90.83%	95.83%
最大值、全距、標準差、絕對中位差	95.83%	95.83%
最小值、總和、全距、標準差	95.83%	96.67%
最小值、總和、全距、絕對中位差	90.83%	94.17%
最小值、總和、標準差、絕對中位差	89.17%	96.67%
最小值、全距、標準差、絕對中位差	94.17%	90.83%
總和、全距、標準差、絕對中位差	79.17%	72.50%

從本節實驗數據中可以發現，將最大值、最小值、總和、全距定為輸入特徵時，雖然SVM的分類正確率依然維持在95%左右，沒有繼續往上提升，但BPNN的分類正確率可以提升到98.33%，很接近本研究對於離線分類的期望正確率，所以在接下來的線上分類實驗中，將使用最大值、最小值、總和、全距四項特徵值搭配BPNN進行線上的分類正確率實驗。

## 4.4 線上分類

本節將進行即時的眼動狀態分類，與離線的分類相比，線上的去除了關閉腦電波耳機的選項，直接對程式紀錄到的腦電波進行轉換與分類，而線上分類的流程圖如下圖 4.13。

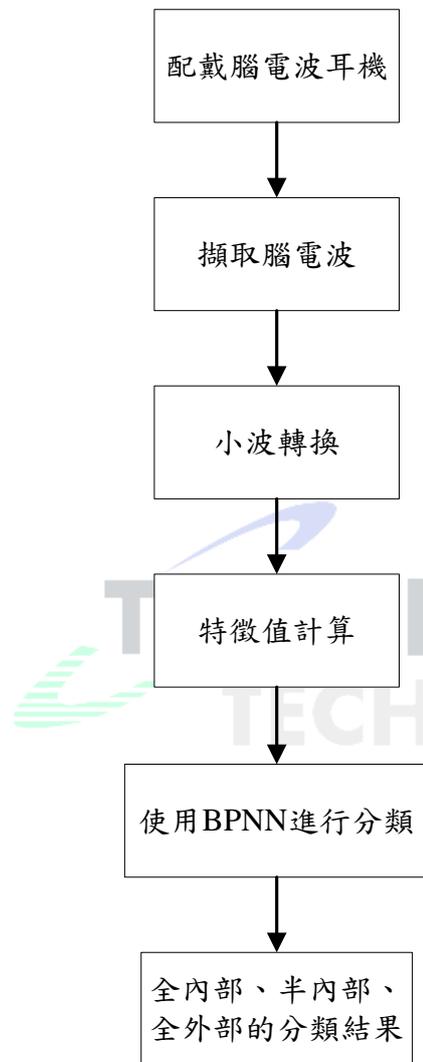


圖4.13 線上分類流程圖

在線上分類眼動狀態的實驗中，受測者在戴上腦電波耳機之後，啟動程式擷取腦電波，直接對小波轉換持續輸入 128 點資料進行轉換，並以特徵值的計算公式將轉換後 A5 頻段的特徵值計算出來，再輸入到 SVM 與 BPNN 兩個分類器中，進行眼動狀態的分類再由不同的燈號顯示分類的結果。與離線的分類正確率實驗最大的不同是，線上的眼動狀態分類，是沒有時間計算 SVM 的區分超平面以及 BPNN 的各項權重，因此將離線所建

立起的權重數據，直接使用在線上分類的實驗當中。

透過全內部、半內部以及全外部分組方式的結果可以知道，SVM 以及 BPNN 是適合用在分類眼動狀態的分類器，而用來分類的特徵值則有最大值、最小值、總和、全距、標準差以及絕對中位差等六種，根據前面各小節中的分析將選用最大值、最小值、總和以及全距做為線上分類的特徵值。

由於線上分類不像離線時可以透過影片的重播進行進行數據的收集以及特徵的眼動訊號進行窗格的移動，且在即時分類時容易遇到許多未知的突發狀況。為了不讓資料產生不齊全的狀態導致分類錯誤，將對訊號進行重疊(Overlap)的處理，而重疊的量要控制在不能重疊太多使程式延遲，但如果重疊的量太少將導致程式所能判斷的特徵資料不齊全，所以本研究將重疊的量設定為 78%，也就是在一個資料點數為 128 的資料當中，會有 100 個資料點是屬於上一個窗格的，每次僅更新 28 筆數據。

為了將線上分類的結果做即時的呈現，本研究透過 MATLAB 程式製作出一個顯示結果用的介面，其介面圖如下：

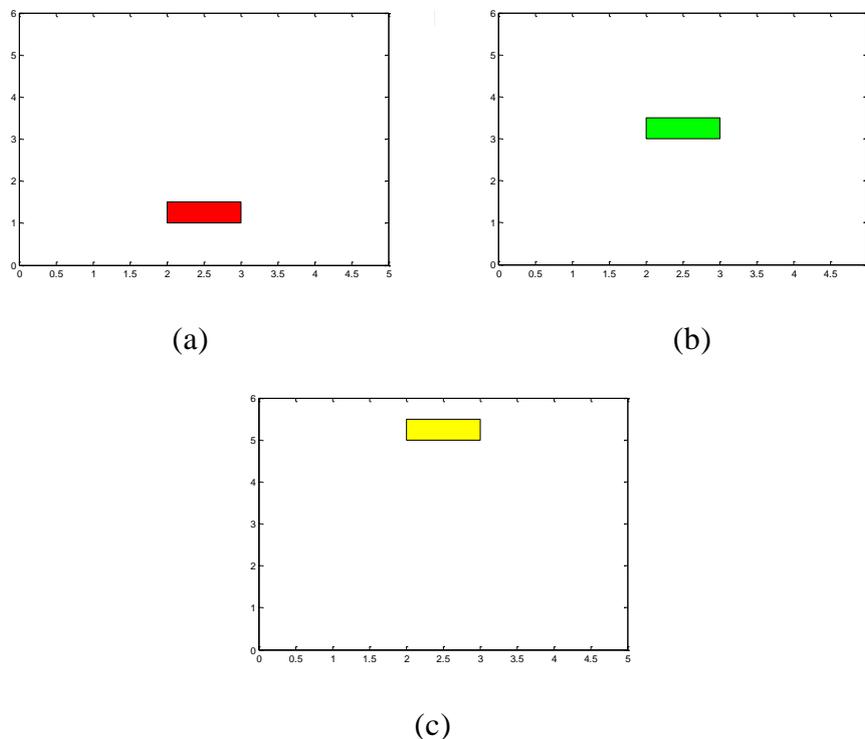


圖4.14 分類結果顯示介面

(a)閉眼瞬間的狀態 (b)非眼動狀態 (c)開眼瞬間的狀態

圖 4.14 中，分別以紅、黃、綠三種顯示來代表閉眼瞬間、開眼瞬間以及非眼動等三種眼動狀態，在偵測到不同眼動狀態時，將透過不同的燈號顯示狀態，以利計算分類正確率。

本次實驗受測者共五人，使用計時器給予開閉眼的指示並由第三者的協助記錄實驗，將分別進行 20 次閉眼與開眼，而線上分類的結果如下表：

表 4.6 線上分類正確率計算

	資料總數	分類正確數	分類正確率
受測者 1	40	37	92.50%
受測者 2	40	36	90.00%
受測者 3	40	30	75.00%
受測者 4	40	34	85.00%
受測者 5	40	33	82.50%
		平均正確率	85.00%

線上的分類正確率實驗結果可以從表 4.6 中得知，分類正確率最高的是受測者 1 的 92.5%，錯誤數只有 3 個；而分類正確率最低的則是受測者 3，分類錯誤數為 10 個，分類正確率為 75%。線上的分類正確率無法達到離線實驗時的 98.33%，是因為在離線的實驗中，閉眼瞬間狀態與開眼瞬間狀態的出現位置是可以透過程式來進行手動調整，而為了的到 SVM 的分類超平面以及 BPNN 的權重與閾值，會盡可能地將眼動狀態的波形控制在窗格的正中間；但在線上實驗時，無法對眼動狀態的波形進行調整，因此可能會發生僅一半的波形進入判斷的窗格中，使得程式產生誤判。

雖然受測者 3 在四名受測者中的分類正確率最低，但是仍保有七成以上的分類正確率，且五位受測者的平均分類正確率有 85%，這證明了從離線實驗所訓練出來的權重是相當有效的，希望未來可以使線上分類的正確率更為準確。

## 4.5 疲勞程度計算

### 4.5.1 糊邏輯輸入與輸出變數的歸屬度建立

根據第二章所提到的模糊邏輯推論，本節中將建立模糊邏輯輸入與輸出變數的歸屬度，所使用的架構為雙輸入單輸出，以受測者閉眼的持續時間與閉開眼的頻率作為系統的輸入，系統的輸出則是受測者的疲勞度，因此將定義三種不同的模糊集合，再針對每個變數選擇適當的歸屬函數 (Membership function)，相關參數的設定與說明如下：

閉眼持續時間={短、中、長}

閉開眼的頻率={慢、中、快}

疲勞程度={安全、注意、危險}

常見的歸屬函數有三角型歸屬函數(Triangular MF)、梯型歸屬函數 (Trapezoidal MF)、鐘型歸屬函數(Bell MF)、高斯歸屬函數(Gaussian MF) 等，由於輸入變數與輸出變數的模糊變數與歸屬函數都可以由設計者自行決定，因此環境及變數的設定相當重要，本文所設定的環境為時速 100 公里以上的高速公路，而在歸屬函數的選擇上，是使用三角型歸屬函數；輸入以及輸出的歸屬度定義則如下：

輸入變數中的閉眼時間定義如下，橫軸單位為秒，最大值為 1 秒。

閉眼時間短=Triangular(0,0,0.4)

閉眼時間中=Triangular(0.3,0.5,0.8)

閉眼時間長=Triangular(0.7,1,1)

透過 Matlab 所繪製出來的閉眼時間歸屬度圖如圖 4.15 所示。

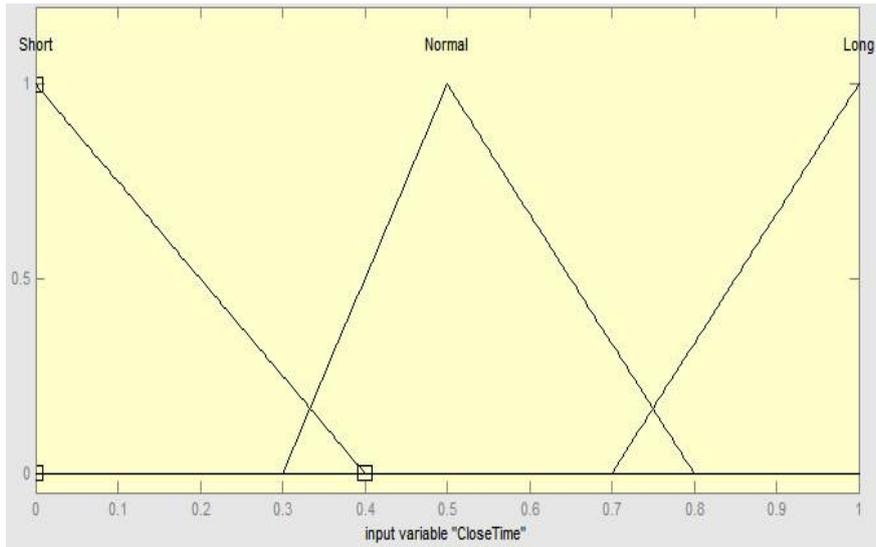


圖4.15 閉眼時間的歸屬度

輸入變數中的閉開眼頻率定義如下，橫軸為 10 秒內閉開眼的頻率，最大值為 2.5。

閉開眼頻率慢 =  $\text{Triangular}(0,0,0.7)$

閉開眼頻率中 =  $\text{Triangular}(0.5,1,1.8)$

閉開眼頻率快 =  $\text{Triangular}(1.2,2.5,2.5)$

透過 Matlab 所繪製出來的閉眼時間歸屬度圖如圖 4.16 所示。

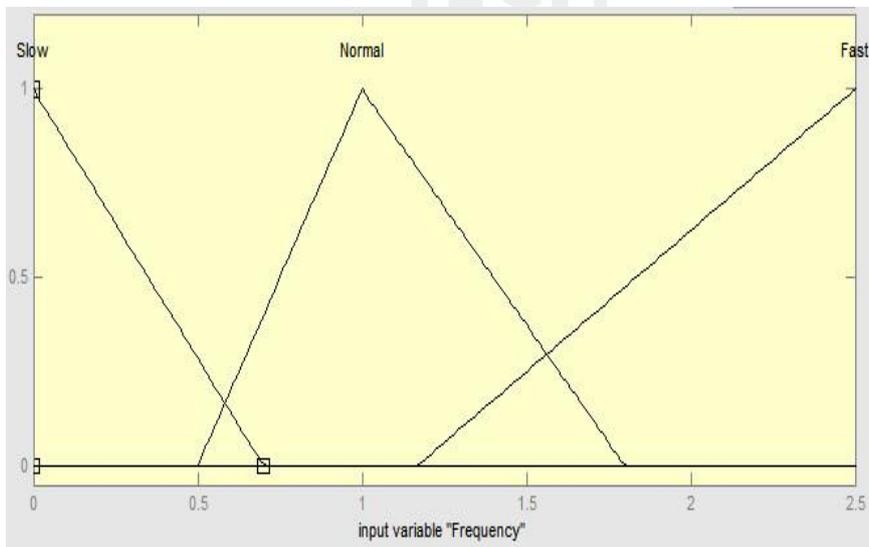


圖4.16 閉開眼頻率的歸屬度

輸出變數為疲勞程度，數據為 1 到 10 分，共分為三種等級。

安全= Triangular(0,0,4)

注意= Triangular(3,5,9)

危險= Triangular(8,10,10)

透過 Matlab 所繪製出來的閉眼時間歸屬度圖如圖 4.17 所示。

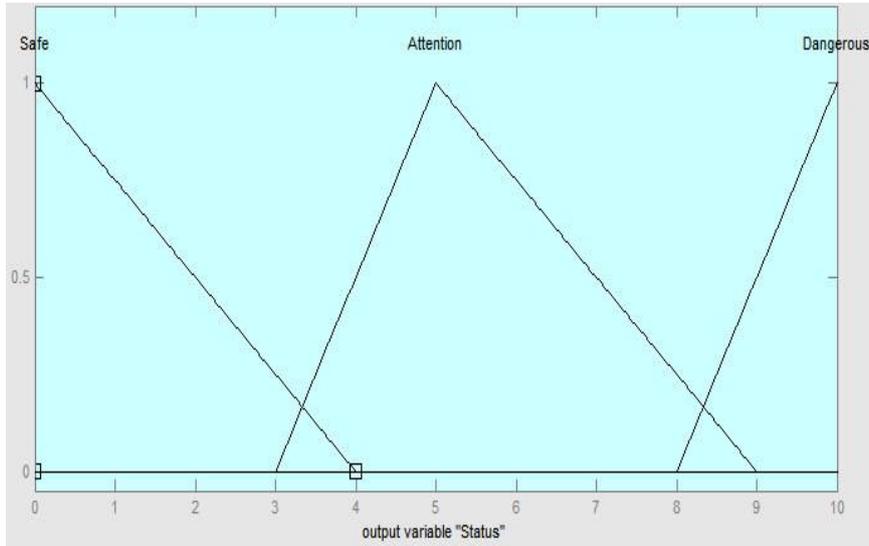


圖4.17 疲勞程度的歸屬度

## 4.5.2 模糊化規則建立

模糊規則是由專家寫成的控制規則，而這些規則大多是利用口語項的方式編寫而成的，一般可經由操作員的控制行為、專家的經驗以及控制系統的特性來產生規則，並透過許多 IF-THEN 建立起模糊規則庫；IF 為模糊規則中前提的部分，THEN 的部分則是經過模糊規則庫所得到的結論。

在陳拓榮的研究結果中提到，眼科醫生解釋，一般正常且經過充分休息的眼睛會以每 3~4 秒眨一次眼的頻率活動，而眨眼的時間約為 0.25~0.3 秒。但是這個時間間隔會受到駕駛者當下的生理狀態產生不同的變化。若駕駛者從清醒狀態漸漸進入疲勞狀態時，基於保護作用，眼睛將會產生不自主的增加眨眼速度，藉此保護視覺，如果進入了更深層的疲勞狀態時，眼睛便會直接延長閉眼的時間。[12]

根據實驗結果，一般人在身體機能接正常的狀態下眨眼的次數大約每分鐘 15 下(頻率約為 0.25 秒)，而在清醒狀態開車時，眨眼的頻率則會變得

較為頻繁，每分鐘眨眼次數將超過 15 次且眨眼的間隔會變短，也就是閉眼持續時間較短；而當駕駛者開始進入疲勞狀態時，眨眼的頻率則會變少，每分鐘的眨眼次數會是正常狀態下的一半，且閉眼的持續時間變長。所以本研究利用閉眼的持續時間與閉開眼的頻率建立起三種程度的模糊集合，在雙輸入的交互關係之下可以獲得九條控制規則，九條規則所建立出的模糊控制規則表如表 4.7 所示。

表 4.7 模糊控制規則表

閉眼持續時間 閉開眼頻率	短	中	長
慢	安全	危險	危險
中	安全	注意	危險
快	安全	注意	危險

### 4.5.3 解模糊化

解模糊化如字面意思，是轉換經過推論所得到的模糊化結果，也就是將模糊集合轉換成明確值。一般常見的解模糊化方法有中心平均法(Center average)、重心法(Center gravity)、最大值法(Maximum)、總和中心法(Center of sum)等。本研究將使用重心法來進行解模糊，重心法是計算重疊後，區塊面積的中心點，公式如下。

$$y(x) = \frac{\sum_{i=1}^N y_i \mu(y_i)}{\sum_{i=1}^N \mu(y_i)} \quad (4.3)$$

式 4.3 中  $y(x)$  為模糊控制器的輸出， $\mu(y_i)$  為第  $i$  個規則輸出集合的歸屬度， $y_i$  為第  $i$  個規則的輸出值， $N$  則為規則的總數。

最後依照兩個輸入變數，閉眼的持續時間的歸屬度、閉開眼的頻率的歸屬度，輸出變數疲勞程度的歸屬度，和式 4.3 的解模糊化，求出模糊邏輯的推論值  $y(x)$ ，並由此推算出駕駛者的疲勞程度，求得模糊邏輯控制曲面圖，如圖 4.18 所示。

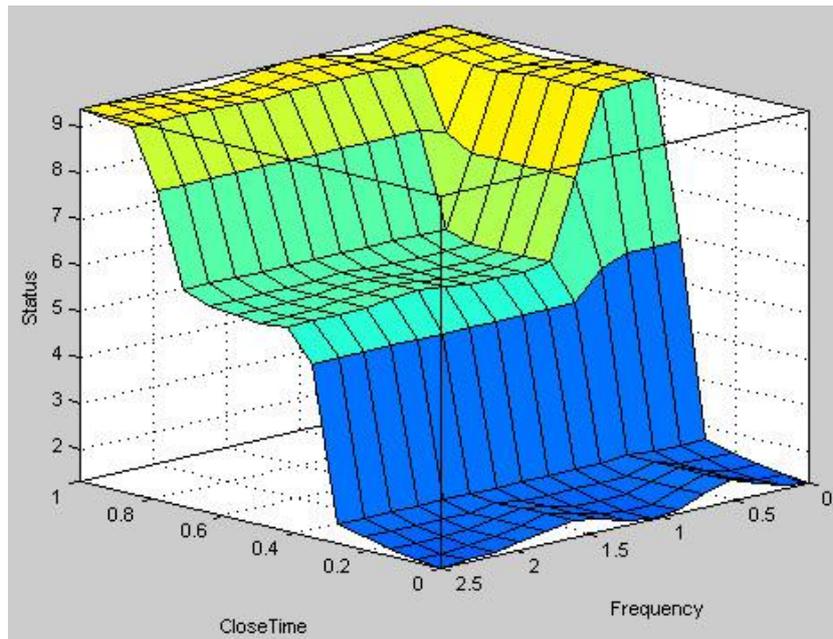


圖4.18 模糊控制曲面圖

在圖 4.18 中，疲勞程度數值越高的地方代表駕駛者的狀態越危險，而由圖中可得知，本研究所使用的系統是以閉眼的持續時間為主，閉開眼的間隔時間為輔，當閉眼的持續時間越長，系統則判定為危險，但閉開眼的頻率減少時，系統仍然判定為危險。因為不管駕駛者的是否疲勞，閉眼時間過長就代表危險性倍增，所以在此系統中閉眼的持續時間優先於閉開眼的頻率。最後將系統放入線上分類的程式中，實現眼動狀態分類與疲勞程度推論。

在程式判斷完疲勞程度之後，將透過 Matlab 輸出三種顏色來代表安全、注意以及危險三個狀態，如圖 4.19~21。當系統判斷駕駛者的疲勞程度為安全時，程式將在視窗右端顯示綠色的燈號，如圖 4.19。

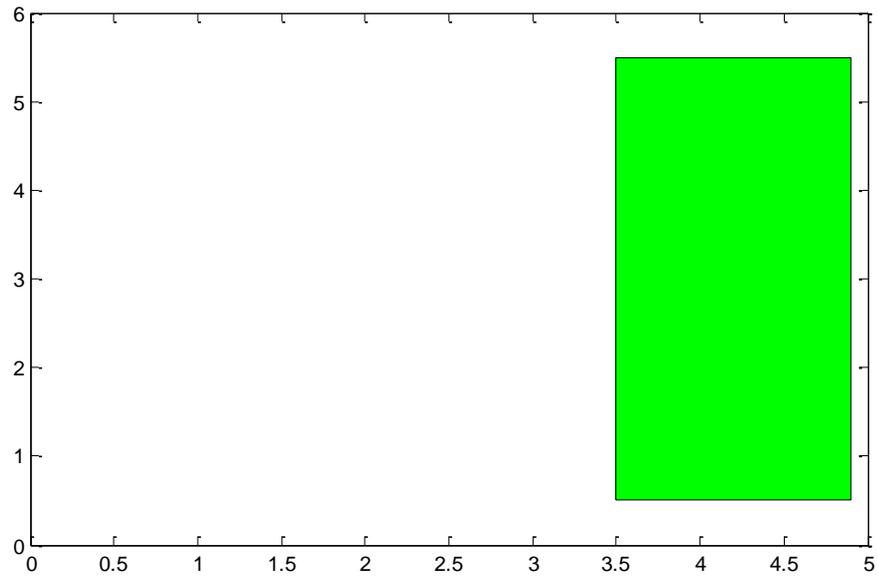


圖4.19 疲勞程度為安全的輸出圖

在系統判斷駕駛者的疲勞狀態為注意時，會在視窗右端顯示黃色的燈號，如圖 4.20。

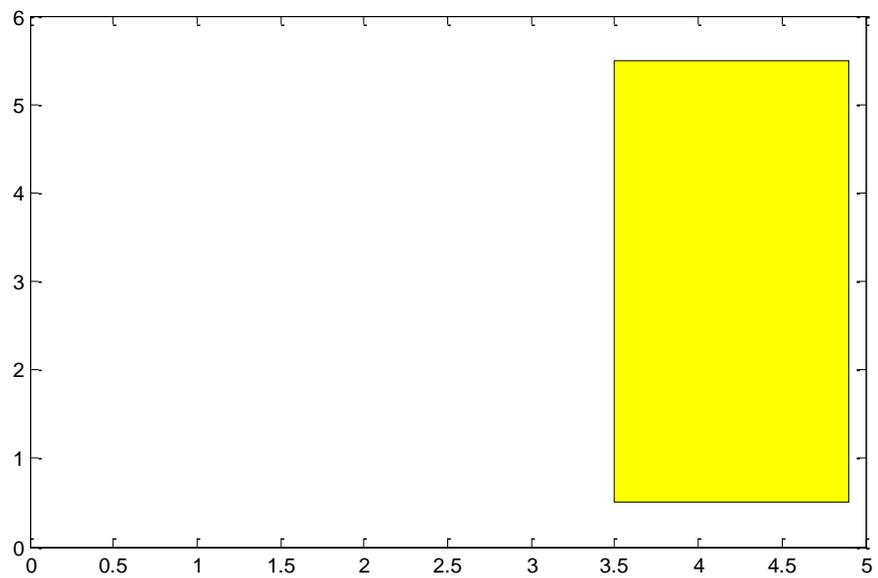


圖4.20 疲勞程度為注意的輸出圖

而在程式判斷出駕駛者的疲勞狀態為危險的時候，程式將在右端以紅色的燈號提醒駕駛者，如圖 4.21 所示。

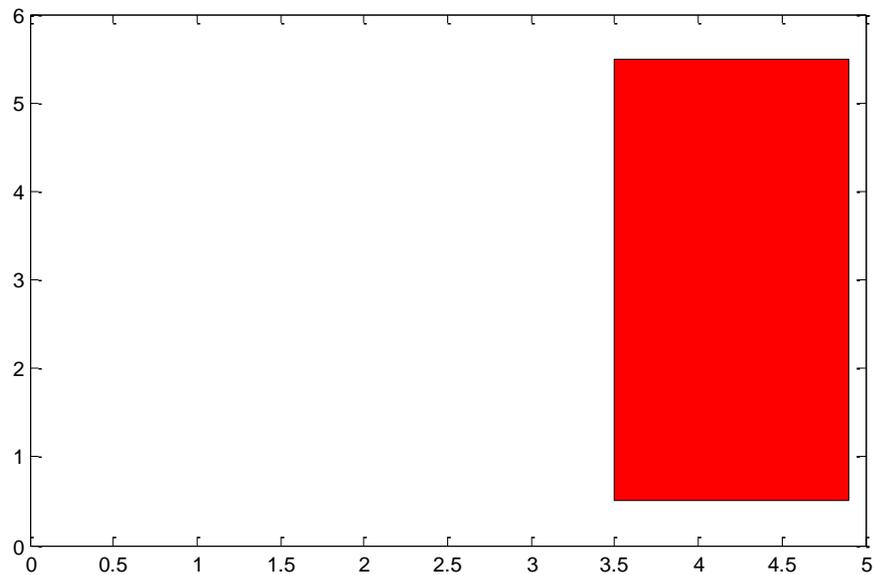


圖4.21 疲勞程度為危險的輸出圖

以下將實際使用三種案例模擬駕駛者的疲勞程度，測試本研究所使用的系統是否能正確判斷疲勞程度：

1. 模擬清醒時：閉開眼頻率快、閉眼時間短，程式顯示的疲勞程度如圖 4.21。

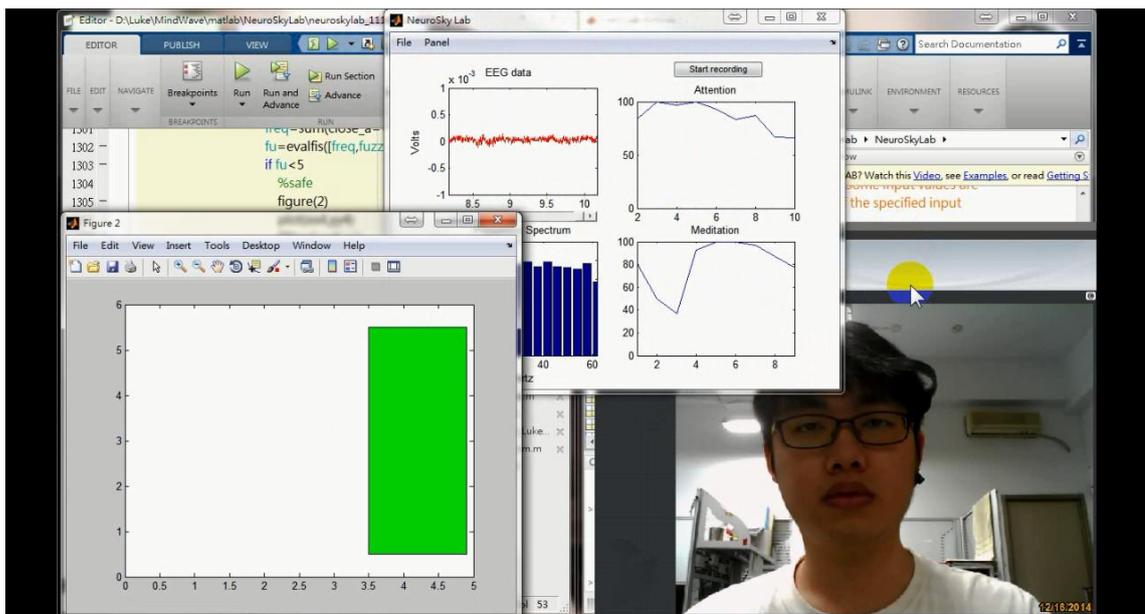


圖4.22 案例 1 測試結果

2. 模擬從清醒進入疲勞狀態時：閉開眼頻率中、閉眼時間中，程式顯示的疲勞狀態如圖 4.22。

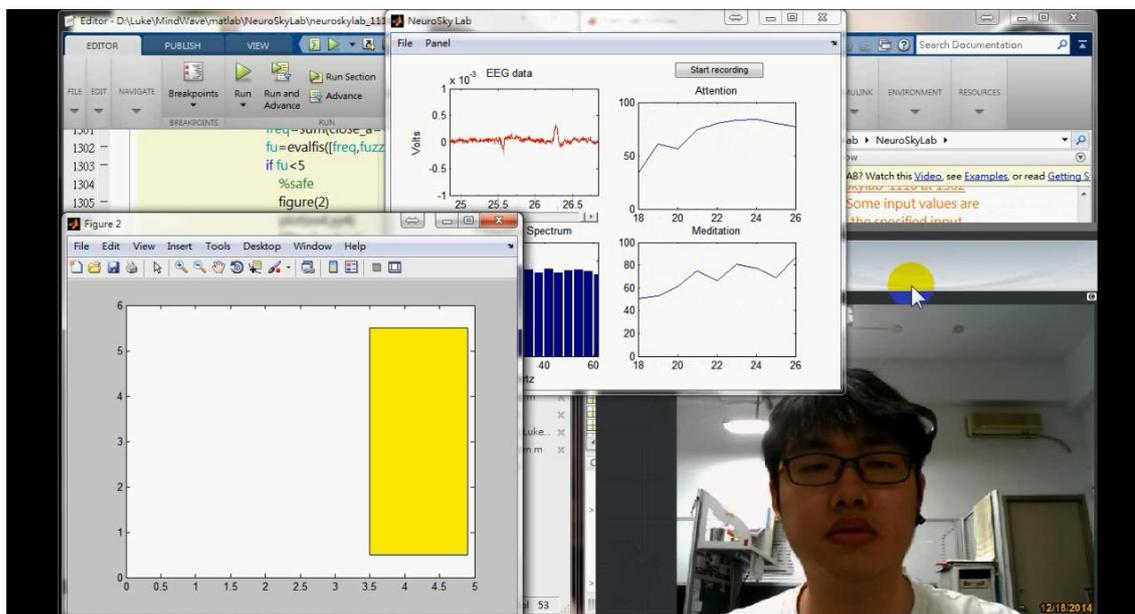


圖4.23 案例 2 測試結果

3. 模擬疲勞時：閉開眼頻率慢、閉眼時間長，圖 4.23 為程式判斷疲勞程度後的輸出圖。

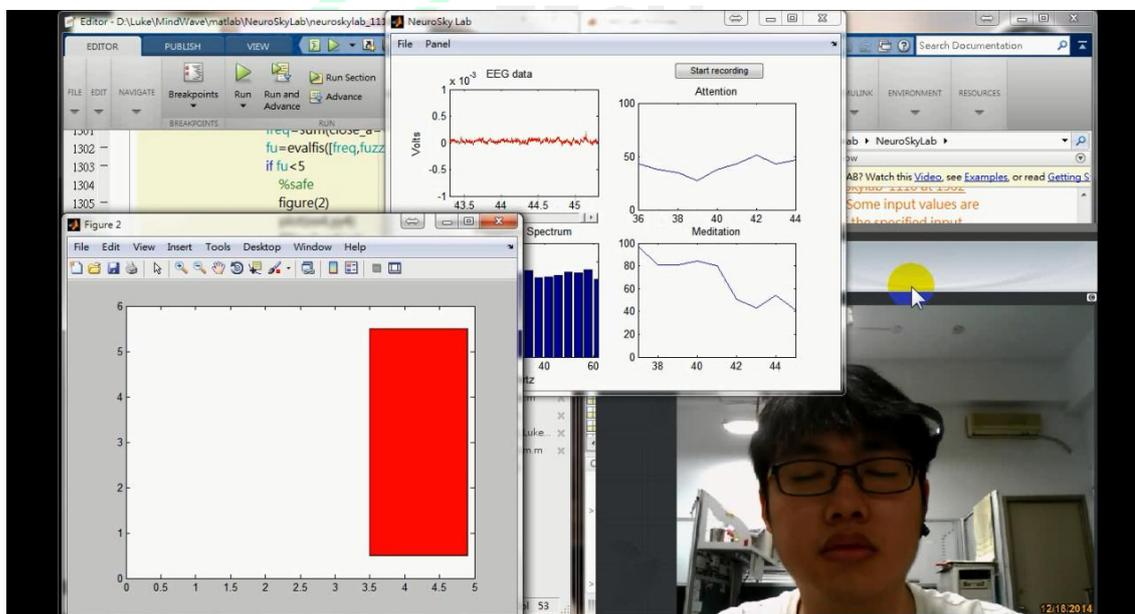


圖4.24 案例 3 測試結果

再來將閉開眼頻率與閉眼持續時間數據化，閉開眼頻率數據化如下：

閉開眼頻率快=閉開眼頻率 1.5~2.5Hz

閉開眼頻率中=閉開眼頻率 0.5~1.5Hz

閉開眼頻率慢=閉開眼頻率 0~0.6Hz

閉眼持續時間數據化如下：

閉眼持續時間短=閉眼持續時間 0~0.4 秒

閉眼持續時間中=閉眼持續時間 0.4~0.7 秒

閉眼持續時間長=閉眼持續時間 0.7~1 秒

透過上述的數據，將狀況 1 到 3 數據化後如下：

案例 1=閉開眼頻率 1.5~2.5Hz、閉眼時間 0~0.4 秒

案例 2=閉開眼頻率 0.5~1.5Hz、閉眼時間 0.4~0.7 秒

案例 3=閉開眼頻率 0~0.6Hz、閉眼時間 0.7~1 秒。

再請三位受測者協助實驗進行，先讓受測者習慣上述數據化後的閉開眼方式，再開始執行實驗，每個狀況執行五次，每次一分鐘，並錄製影片及記錄結果，再透過影片計算判讀正確率，由於每 0.25 秒就會有數據輸入到模糊進行疲勞程度判讀，所以一分鐘的實驗會 240 次疲勞判讀的結果，從影片中尋找判讀錯誤的部分即可得到判讀正確率，受測者 1 的實驗結果如表 4.8 至 4.10。

表 4.8 受測者 1 閉開眼頻率 1.5~2.5Hz、閉眼時間 0~0.4 秒

實驗次數 \ 實驗結果	判讀正確數/總資料數	判讀正確率
1	206/240	85.83%
2	174/240	72.50%
3	169/240	70.42%
4	156/240	65.00%
5	162/240	67.50%
	平均判讀正確率	72.25%

表 4.9 受測者 1 閉開眼頻率 0.5~1.5Hz、閉眼時間 0.4~0.7 秒

實驗次數 \ 實驗結果	判讀正確數/總資料數	判讀正確率
1	219/240	91.25%
2	207/240	86.25%
3	200/240	83.33%
4	201/240	83.75%
5	194/240	80.83%
	平均判讀正確率	85.08%

表 4.10 受測者 1 閉開眼頻率 0~0.6Hz、閉眼時間 0.7~1 秒

實驗次數 \ 實驗結果	判讀正確數/總資料數	判讀正確率
1	183/240	76.25%
2	187/240	77.92%
3	166/240	69.17%
4	179/240	74.58%
5	194/240	80.83%
	平均判讀正確率	75.75%

受測者 2 的實驗結果如表 4.11 至 4.13。

表 4.11 受測者 2 閉開眼頻率 1.5~2.5Hz、閉眼時間 0~0.4 秒

實驗次數 \ 實驗結果	判讀正確數/總資料數	判讀正確率
1	185/240	77.08%
2	198/240	82.50%
3	213/240	88.75%
4	178/240	74.17%
5	182/240	75.83%
	平均判讀正確率	79.67%

表 4.12 受測者 2 閉開眼頻率 0.5~1.5Hz、閉眼時間 0.4~0.7 秒

實驗次數 \ 實驗結果	判讀正確數/總資料數	判讀正確率
1	191/240	79.58%
2	183/240	76.25%
3	166/240	69.17%
4	182/240	75.83%
5	205/240	85.42%
	平均判讀正確率	77.25%

表 4.13 受測者 2 閉開眼頻率 0~0.6Hz、閉眼時間 0.7~1 秒

實驗次數	實驗結果 判讀正確數/總資料數	判讀正確率
1	174/240	72.50%
2	192/240	80.00%
3	148/240	61.67%
4	188/240	78.33%
5	161/240	67.08%
	平均判讀正確率	71.92%

受測者 3 的實驗結果如表 4.14 至 4.16。

表 4.14 受測者 3 閉開眼頻率 1.5~2.5Hz、閉眼時間 0~0.4 秒

實驗次數	實驗結果 判讀正確數/總資料數	判讀正確率
1	205/240	85.42%
2	189/240	78.75%
3	182/240	75.83%
4	194/240	80.83%
5	189/240	78.75%
	平均判讀正確率	79.92%

表 4.15 受測者 3 閉開眼頻率 0.5~1.5Hz、閉眼時間 0.4~0.7 秒

實驗次數 \ 實驗結果	判讀正確數/總資料數	判讀正確率
1	149/240	62.08%
2	183/240	76.25%
3	178/240	74.17%
4	178/240	74.17%
5	177/240	73.75%
	平均判讀正確率	72.08%

表 4.16 受測者 3 閉開眼頻率 0~0.6Hz、閉眼時間 0.7~1 秒

實驗次數 \ 實驗結果	判讀正確數/總資料數	判讀正確率
1	214/240	89.17%
2	160/240	66.67%
3	160/240	66.67%
4	137/240	57.08%
5	154/240	64.17%
	平均判讀正確率	68.75%

從以上三位受測者的實驗結果中可以看出，本研究中所使用的兩個輸入變數，閉眼的持續時間與閉開眼的頻率，搭配表 4.7 的控制規則表，進行的疲勞程度推論，最高的判讀正確率為 85.08%，最低的判讀正確率則為 68.75%，可見增強系統的強健性會是未來需要改進的因素之一。

## 第五章 結論與未來展望

### 5.1 結論

本論文成功的藉由神念科技所開發的腦電波耳機，將人們的腦電波擷取並儲存起來，從時域的訊號中就可以發現開眼與閉眼都存在著明顯且特別的波形，但原始的腦電波訊號是不同的腦電波所構成的，因此不能直接進行眼動狀態的分類，所以透過多貝西小波中的 db4 執行五階層的小波轉換，將原始的腦電波分解成 D1、D2、D3、D4、D5 以及 A5 等五個頻段。

從轉換的結果中，發現對應到  $\delta$  波的 A5 頻段有著跟原始腦電波相似的波形，因此決定使用 A5 頻段來進行開閉眼狀態的分類，在此之前須將 A5 頻段的訊號轉換為分類用的特徵值，文中使用的特徵值計算公式包含最大值、最小值、總和、全距、標準差及絕對中位差等六種再使用分類器進行分類。

用來分類眼動狀態的分類器為支持向量機與倒傳遞類神經網路，兩者都屬於監督式的學習網路且發展完整；將轉換後的特徵值輸入到兩個分類器中，透過支持向量機所建構出的超平面以及倒傳遞類神經迭代算出的權重，進行眼動狀態的分類，在離線的實驗中發現最大值、最小值、總和與全距的分類正確率最高，因此決定使用這四種做為計算特徵值的方式計算出特徵值，並記錄支持向量機與倒傳遞類神經所算出的權重，以利線上分類的執行。

線上分類是不透過影片紀錄開閉眼時間點取得腦電波訊號，直接透過擷取腦電波窗格的平移來進行原始腦電波的擷取並計算特徵值，再使用已經訓練好的支持向量機與倒傳遞類神經進行眼動狀態的分類，線上的平均分類正確率約為 85%。

在疲勞程度判斷的部分，由於無法取得真實的駕駛者疲勞狀況，因此使用假設案例來進行實驗，效果也符合預期，只是在眼動狀態的分類上如果產生了失誤，就容易影響疲勞程度判斷，所以要再將眼動狀態分類的正

確率繼續提升。

## 5.2 未來展望

從實驗結果中可以看出線上的眼動狀態分類正確率雖有忽高忽低的狀態，希望在未來可以提升整個系統的精準度；而平均分類正確率是不錯的，所以可以將本文所使用的方法應用到實際生活中，如駕駛人行車時腦電波的記錄與分析、上課前、課中及課後學生的腦電波分析等；而小波轉換出其他頻段的波形，也會包含專注、放鬆等許多其他狀態的特徵，希望在未來可以使用其他部分的腦電波資訊來做更細微的處理如控制機械手臂、控制復建機構的運作等。

而由於神念科技所開發出的腦電波耳機是藉由乾式電極與人腦的左前額進行接觸讀取腦電波，所以比較容易受到使用者頭部的移動、儀器未正確配戴、外在環境的震動等狀況影響擷取出來的腦電波訊號，而這些訊號不見得都會被程式判斷為雜訊而濾除，因此在訊號處理方面希望能夠更精細的將這些雜訊去除，僅留下所需要的腦電波資訊，以利進行更精細的腦電波分析。

由於閉眼與開眼的腦電波訊號會受到閉、開眼的速度影響，閉開眼速度越快，所產生的腦電波形起伏也相對較明顯；反之，慢速的閉眼與開眼訊號，在腦電波的波形起伏會變得不明顯，很有可能會造成程式判讀不到閉、開眼的狀態；如果與其他頻段的波形互相搭配，或是加上鏡頭進行眼睛的影像辨識，將會有比較多的判斷基準，進而能夠較容易判斷出慢速的閉開眼狀態。

## 參考文獻

- [1] G.D Schott, " Penfield's homunculus: a note on cerebral cartography," *Journal of Neurology, Neurosurgery and Psychiatry*, 56, 1993, pp. 329-333.
- [2] 洪偉哲，以小波轉換鑑別人類情緒腦波，碩士論文，國立臺灣師範大學機電科技學系，臺北，2011。
- [3] 中華民國交通部台灣區國道高速公路局，交通事故分析  
<http://www.freeway.gov.tw/Publish.aspx?cnid=516&p=128>
- [4] 黃清福，應用小波轉換及類神經網路技術於機油狀態監測系統，碩士論文，國立彰化師範大學車輛科技研究所，彰化，2014。
- [5] James W. Cooley and John W. Tukey, " An algorithm for the machine calculation of complex Fourier series," *Mathematics of Computation*, vol. 19, no. 90, 1965, pp. 297-301.
- [6] 林怡秀，調適性網路模糊推論於水下聲源訊號辨識系統之研究，碩士論文，私立中原大學資訊工程學系，桃園，2001。
- [7] 王意如，小波轉換應用於光纖感測之研究，碩士論文，國立中山大學電機工程學系，高雄，2006。
- [8] 劉秋宏，發展以離散小波與小波包技術之車輛故障診斷系統，碩士論文，國立彰化師範大學車輛科技研究所，彰化，2007。
- [9] I. Daubechies, " Orthonormal bases of compactly supported wavelets," *Communications on Pure and Applied Mathematics*, vol. 41, 1988, pp. 909-996.
- [10] 芮國勝,康健譯,小波與傅立葉分析基礎,北京:電子工業出版社,2004,第 210-223 頁。
- [11] C.Parameswariah, M. Cox, " Frequency characteristics of wavelets," *IEEE Transactions on Power Delivery*, vol. 17, 2002, pp. 800-804.
- [12] 陳拓榮，模糊邏輯應用於疲勞辨識系統，碩士論文，國立彰化師範大學車輛工程學系，彰化，2003。
- [13] 王文俊，認識 **Fuzzy**，台北：全華科技圖書股份有限公司，1997，第二章 2-14。
- [14] 張詩言，**Fuzzy 入門**，台北：全欣資訊圖書股份有限公司，1995，2-21。

- [15] 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. 2，2004，pp.155-172。
- [16] 王麟璋，**支向機核心函數適用指標之建立**，碩士論文，國立成功大學工業管理研究所，台南，2003。
- [17] 韓歆儀，**應用兩階段分類法提升 SVM 法之分類準確率**，碩士論文，國立成功大學工業管理研究所，台南，2004。
- [18] 葉怡成，**類神經網路模式應用與實作**，台北：儒林圖書有限公司，1993，69-96。
- [19] 王進德，蕭大全，**類神經網路與模糊控制理論入門**，台北：全華科技圖書股份有限公司，2003，199-219。
- [20] 劉邦亦，**應用語音音高特性於車輛駕駛者辨識系統**，碩士論文，國立彰化師範大學車輛科技研究所，彰化，2014。

