

多模式之駕駛瞌睡腦波偵測研究

徐祥鳴
國立屏東科技大學
資訊管理系
研究生
one02piece@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

在疲勞駕駛之交通事故中，約有高達 40% 以上之駕駛員為職業駕駛，因此本研究應用腦波訊號(Electroencephalogram, EEG)，並進行訊號處理，作為評估人體精神狀態的特徵值。針對人體產生的腦波數據進行分析，將腦波數據分為瞌睡與非瞌睡兩類。研究中提出多模式方法 (Multi-modal method)，即整合 Artificial Neural Network(ANN)、Support Vector Machine(SVM)與 k Nearest Neighbor(k NN)等方法，並納入基因演算法 (Genetic Algorithm)定義出瞌睡指標的數值計算公式。此外，於後續實驗中比較各方法的分類成效後，多模式方法分類成效較佳。而混合腦波數據分類模型和個人數據的分類模型比較後，混合數據模型的分類成效優於個人數據分類模型。

關鍵詞：類神經網路，支持向量機， k -近鄰演算法，基因演算法，腦電波(EEG)

Abstract

In this study, we analyzed the driver's EEG data and adopted Artificial Neural Networks (ANN), Support Vector Machine (SVM) and k Nearest Neighbor (k NN) classification methods to classify brain data into two categories with drowsy and non-drowsy. Furthermore, to increase the accuracy of prediction we integrated the results of the above methods through a Multi-modal method. The parameters in the fusion function of multi-modal method were estimated through a genetic algorithm. To sum up, the classification of brain data was the primary topic in this study. In the experiments of this study, the brain data was collected through a brainwave instrument. The prediction results of the classification methods were compared to each others. We also analyzed the rates of true/negative and false/negative of these methods. According to the experimental results, we found that the classification accuracy rates of three

methods are between 70% and 80%. The multi-modal method we proposed can get the highest accuracy rate of classification. Moreover, the experimental results also show that the methods using multiple subjects' dataset outperform the ones using the personal dataset.

Keywords: Artificial Neural Networks, Support Vector Machine, k Nearest Neighbor, Genetic Algorithm, Electroencephalogram

1. 前言

近來已有許多自動化的車載系統，應用於加強行車安全之中，像是行人偵測、車距巡航、車道偏離警示等系統，而上述是針對車體本身的車載系統，於本研究中將對於駕駛者來建立與人體有關之車載系統。伴隨著科技的進步與發展，已可透過儀器收集人體的生理資訊，而腦波訊號(Electroencephalogram, EEG)則是人體所產生的一種生理訊號。藉由探討EEG變化，並分析人的生理與心理狀態，已經被應用於多種範疇之中。疲勞駕駛是一種駕駛專注力降低的人為疏失，也是交通事故的起因之一，因此透過人體的生理訊號來評估駕駛者的精神狀態，可避免非接觸式偵測可能產生誤判之情形，本研究著重於應用行車時偵測到的腦波數據，對其進行分類，以知曉人體目前行車時的精神狀態。

本研究將設計出一個利用腦波數據進行分析之瞌睡偵測系統。

2. 相關研究

本章節將介紹腦波訊號方面的相關應用研究，包含腦波波型分類、生理資訊與疲勞狀態之探討、人工智慧方法與腦波訊號的應用研究。

2.1 腦波波型分類

根據設備提供的技術文件[1]與臨床生理學會國際聯盟(International Federation of Societies for Electroencephalography and Clinical Neurophysiology)[15]等資料，將大腦所發出的生理訊號，依據頻率範圍被定義為五類

* 通訊作者

波，分別介紹如下：

- Alpha activity(α 波)：頻率落於8-13Hz間，振幅約為30~50 μ V之電波。一般正常人清醒並處在安靜、休息的狀態下，會在大腦頂葉部(parietal region)及枕葉部(occipital region)出現此類的週期波。當人有思考、睜眼或其它刺激時， α 波就會消失，此一現象稱為 α 波的阻斷(alpha-block)，只需重新放鬆、閉目， α 波才會重新出現。
- Beta activity(β 波)：頻率落於14-30 Hz間，振幅則莫約為5~20 μ V之電波。人在清醒而警覺的狀態下，較常在頂葉部(frontal region)出現此類腦波。尤其當大腦思考或接受感官刺激時，此波段更為明顯。
- Theta activity(θ 波)：頻率波段落於4-7Hz間，一般而言其振幅大約是低於30 μ V。主要出現在小孩的頂葉部及顳葉部(temporal region)，但成人情緒受到壓力、意識中斷或身體深度放鬆時也會出現此類腦波。另外許多腦疾病患者，亦可以找到 θ 波。
- Delta activity(δ 波)：腦波頻率波段處於0.5-3Hz間，振幅約100-200 μ V。在意識清醒的狀態下，正常成人幾乎沒有 δ 波，通常發生在深度熟睡、無意識，或深度麻醉、缺氧以及器質性腦病變(organic brain disease, OBD)患者身上，所謂的OBD是指大腦因形狀、組織或細胞產生變化，導致腦功能出現缺陷的症狀。
- Gamma activity(γ 波)：指的是頻率在31-50Hz之間的腦波，其振幅約在5-10 μ V之間。近年有研究發現此波與選擇性的注意力(selective attention)有關，並且更有研究指出此波與人的認知、知覺活動也有其關連。

2.2 生理資訊與疲勞狀態的探討

PERCLOS[25][24][27]為一種利用偵測眼睛閃爍頻率，判斷駕駛者行車時疲勞程度之系統。由於PERCLOS依賴影像處理技術，因此對偵測環境有較嚴謹之要求。例如：外在強烈光線會使駕駛眼睛不自然閃爍，導致偵測結果錯誤。

近來透過生理參數進行人體疲勞評估之研究，已為新的趨勢。於神經中樞系統的相關研究領域中，EEG已被廣泛運用在評估人體之疲勞程度[29][12][28]。例如[14]是應用主成份分析(principal component analysis)配合互相關函

數(cross-correlation function)，計算出各時間點的總平均波型(the grand-averaged waveform)之振幅的變化，進行精神疲勞(mental fatigue)之分析研究。其研究發現當精神疲勞程度增加，腦波振幅則會降低。[9]用腦波訊號的功率頻譜(power spectrum)進行人體意識的程度分析，而功率頻譜可映射出腦波警覺狀態的波動。

另外，研究[11]應用ICA(Independent Component Analysis)與腦電功率頻譜分析，提出一個判斷精神疲勞程度的方法。其使用FFT(Fast Fourier Transform)計算人體的腦波頻譜，並將取得的頻譜計算疲勞程度。在研究[10]中，作者設計一個睡意偵斷系統。此系統運用ICA分析多來源之EEG訊號並運用統計方法來評斷駕駛者行車時的意識(認知狀態,cognitive state)。透過研究實驗證明，利用腦電頻譜診斷人體睡意是可行的。此外，研究[6]則是利用車道偏離的反應時間和次數來評估駕駛是否在打瞌睡。其設計的原理是當駕駛打瞌睡時，其車道偏離的現象會在短時間內密集重覆數次。此外在此研究中指出當駕駛處理車道偏移的反應時間增加時，大腦皮質的枕部(occipital lobe)、後頂葉部(posterior parietal lobe)、顳葉皮質部(middle temporal cortex)有較明顯的腦電活動。且 α 、 δ 、 θ 等頻帶的功率也有增加的趨勢，尤其是 α 波的功率增加最為劇烈。上述的研究當中，所採用的偵測設備與記錄系統通常需要繁瑣的配戴程序與安裝。對於駕駛而言，容易造成使用上的負擔。因此本研究改採較輕便的設備進行腦波數據之收集與判斷。

2.3 ANN的腦波研究與應用

在[23][17]研究之中，擷取EEG訊號的特徵值作為ANN之輸入以進行腦波之分類。而[18][19]則是採用離散小波轉換(Discrete Wavelet Transform)解析腦波訊號，並透過DB4濾波器(Daubechies 4 wavelet filter)將訊號分解成5個等級。之後分別從此5等級之訊號中擷取特徵值，並將特徵值做為ANN分類器之輸入值。另外研究[5]則擷取腦波中相對的小波能量(Relative wavelet energy, RWE)作為ANN分類器之輸入值。文獻[20]則是先利用FastICA(Fast Independent Component)分析EEG訊號後再進行ANN分類

2.4 SVM的腦波研究與應用

腦波是一種複雜的人體生理訊號，可藉由SVM進行腦波訊號的分類及處理。目前已有研究將SVM方法應用於腦圖像之分析。例如研究[3]中應用拉普拉斯算子(Laplacian)結合SVM分

類方法，使腦圖像的成影結果更易解析。在研究[4]中，則提出一個具有糾錯輸出碼(error-correcting output codes, ecoc)的Multiclass SVM方法對EEG訊號進行分類。在文獻[2]中，作者則使用SVM進行腦電訊號分類，藉此設計BCI系統。此系統能辨識人腦的腦電訊號，如：移動右手、左手或是簡單的數學運算。另外，在許多BCI系統中需要使用佈建於腦部各處之感測器所偵測到的資料。但由於感測器分佈的位置不同，使得各感測器偵測的資料對分類結果之影響也有所不同。依此特性，在研究[8]中則提出一個加入權重概念的SVM分類框架，稱之為sw-SVM(sensor weighting SVM)。

2.5 kNN 的腦波研究與應用

研究[26]主要是基於Dempster-Shafer理論的kNN腦電訊號分類法，將此分法用於分類一個包含五個不同精神事件的腦電訊號資料集。實驗結果顯示DS(Dempster-Shafer)的kNN分類演算法比起傳統的kNN有更好的分類正確率。此外，也有研究針對人體應激(Human Stress)的反應進行與腦電訊號的相關研究。所謂應激狀態是指人體因受到環境因素(噪音、氣溫、氣壓)或身體因素(創傷、精神壓力、飢餓、劇痛、疾病)等原因，而使人面臨一種壓力(死亡壓力)，此時人體則會有超乎平常的反應或是抵抗。研究[21]則是透過當人體產生Human Stress時擷取其EEG訊號，並採用kNN進行應激檢測與分類。實驗結果顯示出人體應激時的EEG分類準確率為88.89%。而為了能使EEG訊號能獲得最佳的辨識成果，有些研究則採取集成學習(Ensemble Learning)的方式。研究[22]則是整合kNN、Decision Tree、SVM三種方法，達到BCI系統集成上述三種方法並學習更準確分類腦電訊號之目的。將偵測到的 EEG訊號進行即時記錄，系統經由測試所得到的結論顯示，集成多種方法對於EEG訊號的分類是具有一定成效的。至於研究[13]，則是主要藉由收集人體的EEG訊號，並配合kNN classifier與樸素貝葉斯分類器(Naïve Bayes classifier)等分類器，分類出人體在學習時的EEG訊號之特徵值。配合原本用來分類情緒的 Self-Assessment Manikin(SAM)模型來分類和分析學習時的專注力。

3. 研究方法

研究主題為瞌睡腦波偵測系統，透過收集人體的腦波，並將其應用於人體精神指標的計算之中，其指標則可作為精神狀態的判定。瞌睡腦波偵測的部分是透過配戴於頭上的腦波

設備配合偵測系統，來擷取當人體有瞌睡情形時，才會產生的特定腦波變化，並將其進行記錄，以作為分類模型建立之用。研究方法之主軸，則會包含 EEG 訊號的轉換，以及腦波數據的正規化處理，並藉由三種人工智慧的分類方法判斷此數據是否為瞌睡狀態，最後則針對三種方法所產生的瞌睡程度判斷預測結果進行 Multi-modal method 的運算。

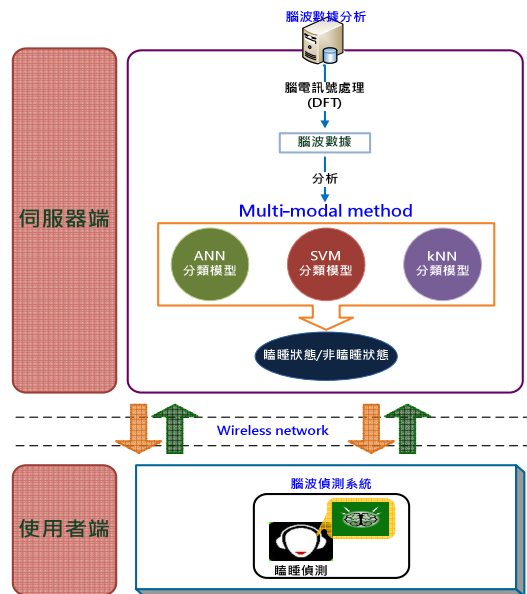


圖 3-1 瞌睡腦波偵測系統架構圖

3.1 腦波訊號擷取方式

利用腦波儀器，來偵測駕駛者的腦波，接著透過腦波記錄系統將腦波數據存成電子檔，以供後續實驗分析用。研究中的腦波數據是將接收到的腦電訊號做 DFT 處理，最後經由計算功率頻譜密度，應用於判斷人體的精神狀態之特徵值。

3.1.1 腦電取樣率與取樣方式

研究中每秒的取樣率 F_s 為 500Hz，而取樣點 N 的數量則為 1000，藉由離散傅立葉轉換(Discrete-time Fourier Transform, DFT)計算每個取樣片段的頻譜功率。




圖 3-2 取樣片段示意圖

3.1.2 離散傅立葉轉換

腦電訊號中存在五種不同的腦波型態，分別為 α 波、 β 波、 δ 波、 θ 波、 γ 波。根據研究[11]之中所提到與人體精神較有關的腦波波型為 α 波、 β 波、 δ 波、 θ 波等四種波。

研究中我們應用 DFT 來處理擷取到的腦電訊號，並將腦電訊號由時域轉到頻域。而四種腦波之頻譜則應用於後續功率計算之中。

3.1.3 腦波功率頻譜密度計算

將各 EEG 訊號的取樣片段經由 DFT 轉換後，即可描繪出取樣片段的 α 、 β 、 δ 、 θ 的頻譜狀態，接著取各腦波振幅的平方，即為該腦波之功率值，又稱作功率頻譜密度 (Power spectral density, PSD) [11]。則 PSD 公式定義如下：

$$X(\omega) = |FFT(x(n))|^2 \quad (3-1)$$

假設 $x(n)$ 為取樣片段， $n=0, 1, 2, \dots, 999$ 。

3.1.4 加總各腦波的 PSD

我們將每秒全部的取樣片段進行 PSD 的加總，下列則為 α 波、 β 波、 δ 波、 θ 波的頻率範圍，以及計算出每秒四種腦波的 Energy 數值，其計算公式如下：

$$\begin{cases} E_{\delta} = \sum X(\omega), 0.5 \leq f(i) \leq 3 \\ E_{\theta} = \sum X(\omega), 4 \leq f(i) \leq 7 \\ E_{\alpha} = \sum X(\omega), 8 \leq f(i) \leq 13 \\ E_{\beta} = \sum X(\omega), 14 \leq f(i) \leq 30 \end{cases} \quad (3-2)$$

$$f(i) = \frac{f_s \times i}{N} \quad (3-3)$$

而 $i = 1, 2, 3 \dots \frac{N}{2}$ ， $N=1000$

3.1.5 E_{δ} 、 E_{θ} 、 E_{α} 、 E_{β} 正規化處理

將資料以二十秒為一個時間區段進行正規化的處理。每類腦波數據會有二十個數值，並著找出每類腦波數據，該時段當中的最大值，並將此數值作為除數，去除本身類別且該時間區段中的各腦波數據，再將計算出來之數值，無條件捨去至小數點第一位後，即為該腦波數據所計算出來之分數 $S_{activity}$ ， $activity \in \{\delta, \theta, \alpha, \beta\}$ 。例如：第一個 E_{δ_1} 腦波數值為 230306，而 $E_{\delta_{max}}$ 腦波最大數值為 369831，經過計算後無條件捨去到小數點第一位為 0.6，此數值則是 S_{δ_1} ，即為該腦波數據之分數，公式定義如下：

$$S_{activity\ n} = \left(\frac{E_{activity\ n}}{E_{activity\ max}} \right) \times 10, n = 1, 2, \dots, 20 \quad (3-4)$$

每筆腦波數據會藉由影片的觀察，給予其一個觀測結果值，假使為瞌睡腦波數據則給予 1，反之，非瞌睡腦波數據則定義為 0。

3.2 基於類神經網路的腦波數據分類機制

將每秒的計算出來的腦波數據 S_{δ} 、 S_{θ} 、 S_{α} 、 S_{β} 作為神經元的輸入參數，而 ANN 之中的隱藏層則為一層，包含五個神經元，由於只

需分成兩類，因此設定一個輸出，之後進行訓練完成分類模型，並將資料集分類成瞌睡腦波與非瞌睡腦波。每代 ANN 的訓練有 600 個腦波數據作為類神經網路的輸入，並建立成一個分類模型。




圖 3-3 類神經網路模型架構

3.2.1 樣本收集

本研究先將初步收集到的 600 筆腦波數據作為訓練樣本，並經過人工分類的方式，盡量將其分為各 300 筆瞌睡腦波與 300 筆非瞌睡腦波，此為觀測結果，並依此資料集訓練出分類模型。

3.2.2 腦波分數的類神經網路訓練機制

將每秒計算出來且依時間排序的 600 筆腦波數據作為類神經網路之輸入，並在經由訓練後，判斷腦波數據是屬於瞌睡腦波或是非瞌睡腦波，以達到分類之目的。由於每個訓練樣本皆是 S_{δ} 、 S_{θ} 、 S_{α} 、 S_{β} 所組成的，因此將從範圍 -0.5~0.5 之中採隨機挑選的方式，給予各 w_i 初始數值，另外學習率則是 0.4， θ 為 0.2。已事先定義觀測結果為 0 或 1，將此作為期望輸出，因此激勵函數定義為：

$$X = \sum_{i=1}^n S_{activity} w_i \quad (3-5)$$

$$Y^{step} = \begin{cases} 1, X \geq \theta \\ 0, X < \theta \end{cases}$$

3.2.3 ANN 的 probability 計算

ANN 對於每個腦波數據的 probability 的數值計算，即每筆腦波數據 (S_{δ} 、 S_{θ} 、 S_{α} 、 S_{β}) 的實際輸出，公式如下：

$$ANN_probability = step \left[\sum_{i=1}^n S_{activity} w_i - \theta \right] \quad (3-6)$$

3.3 基於 SVM 的腦波數據分類機制

SVM 的概念為將高維度的資料，藉由一個超平面 (hyperplane)，使資料區分為兩個集合，達到資料集分類之目的。而區分資料的超平面之兩面為平行的平面，且皆分別最靠近其分類的資料點，而假定相互平行的距離越大，分類之誤差則越小，下圖為二維的 SVM 分類示意

圖：




圖 3-4 SVM 分類示意圖

將多維的腦波數據(S_δ 、 S_θ 、 S_α 、 S_β)投映到 SVM 的向量空間之中，進行瞌睡與非瞌睡的分類，並且給予每筆腦波數據一個 SVM 分類的 probability 之預測值。

3.3.1 樣本收集

應用與 ANN 相同之資料集，進行 SVM 的分類模型建立。

3.3.2 挑選核心函數

SVM 透過核心函數，可將輸入的資料集映射到特徵空間(feature space)之中，不同的核心函數都有其不同的分類結果，所以 SVM 對於核心函數的挑選是重要的一個步驟，下表為核心函數的定義：

表 3-1 核心函數表

線性函數(linear)：
$K(x_i, x_j) = (x_i, x_j)$
多項式函數(polynomial)：
$K(x_i, x_j) = (x_i^T x_j + 1)^d$
放射型函數(radial basis function, RBF)：
$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
S 型函數(sigmoid)：
$K(x_i, x_j) = \tanh(kx_i x_j - \delta)$

研究中的後續實驗則選擇多項式函數 (polynomial) 作為 SVM 的核心函數。

3.3.3 SVM 的 probability 計算

將參考[16]當中提出的方式來計算 SVM 的 probability 之數值，公式如下：

$$p_i = \frac{1}{1 + \exp(Af_i + B)} \quad (3-7)$$

3.4 基於 kNN 的腦波數據分類機制

kNN 是一種監督式學習 (supervised learning) 演算法。本研究將取得的腦波數據 S_δ 、 S_θ 、 S_α 、 S_β 進行訓練，以建立一個 kNN

classifier。腦波數據樣本在特徵空間中的距離計算，則應用歐幾里德距離公式，公式如下：

$$\text{dist}(x, y) = \sqrt{\sum_{i=1}^n (f_i(x) - f_i(y))^2} \quad (3-8)$$

3.4.1 樣本收集

依照前面所述之資料集，進行 kNN 的分類模型建立。

3.4.2 腦波數據樣本的特徵值

每筆腦波樣本的特徵值與上述處理方式一樣，將其正規化，並計算出腦波分數，下表為腦波樣本特徵值範例。

表 3-2 腦波樣本特徵範例

	T_1	T_2	T_3	...	T_{600}
S_α	0.7	0.3	0.6	...	0.6
S_β	0.6	0.4	0.9	...	0.2
S_δ	0.7	0.9	0.8	...	0.5
S_θ	0.3	0.2	0.2	...	0.3

T_1 為第一個時間單位，以此類推，並於後續 kNN 的實驗中進行 k 個數之分類正確率的比較。

3.4.3 kNN 的 probability 計算

每筆腦波數據的 probability 的計算方式為，假如設定 $k=5$ ，並藉由距離公式找出最相近的五筆資料，其中一筆觀測結果為瞌睡腦波 (drowsy_count)，四筆為非瞌睡腦波，則將此樣本歸類為非瞌睡腦波，而 probability 的值則為 0.2，公式定義如下：

$$\text{kNN_probability} = \frac{\text{drowsy_count}}{k} \quad (3-9)$$

drowsy_count 為觀測結果為瞌睡腦波的總數，k 為 kNN 的個數。

3.5 Multi-modal method 應用於瞌睡狀態之判斷

每筆腦波數據一個觀測結果，假使判斷為瞌睡狀態則為 1，反之，非瞌睡狀態則是 0。且三種人工智慧方法，分別針對取得的腦波數據進行腦波數據之分類時，皆會計算出一個 probability 的數值，即為 P_n ，例如：ANN 對於某筆腦波數據的 P_n 為 0.8912，即表示此數據較可能是一個瞌睡腦波。但每個方法的 probability 數值與觀測結果都有其差距。因此研究中則定義一個疲勞程度函式，並計算出一個精確數值用於判斷人體的精神狀態。此函式給予三個 probability 結果各乘上一個權重值 w_n 。權重值 w_n 則是藉由 Genetic Algorithm 的調整來取得最佳之權值。最後進行三個數值的加總，此數值則為人體精神狀態判斷的一個指標。疲勞程度 (fatigue degree, fd) 公式定義如下：

$$fd = \sum_{n=1}^3 (w_n \times P_n), 0 \leq fd \leq 1 \quad (3-10)$$

3.5.1 基因編碼(Encoding)與解碼(Decoding)

因為 Multi-modal method 採用三種分類方法，因此三個 w_n 的定義如下：

$$\sum_{n=1}^3 w_n = 1, 0 \leq w_n \leq 1 \quad (3-11)$$

將三個 w_n 變數連接成一個染色體 W ，並且每個 w_n 用 16bits 來表示，如下圖所示：




圖 3-5 染色體之範例

此外，解碼函式(decoding function)定義如下，而 D_n 為 w_n 的十進位數值：

$$w_n = (D_n)_{10} \times \frac{1}{2^{16}} \quad (3-12)$$

3.5.2 Genetic Algorithm 之問題定義

先隨機產生 16 對染色體 W 作為初始種群，並且從腦波數據的訓練集中，隨機挑選 300 筆資料，進行 fd 函式運算。其集合定義為 $D=\{fd_x, x=1, 2, \dots, 300\}$ ，下一步為計算每筆腦波數據的觀測結果和 fd_x 之差異。假設：腦波數據的觀察結果之集合為 $V=\{V_x, x=1, 2, \dots, 300\}$ ，某筆腦波數據的觀測結果 V_x 為 1，而計算出來的 fd_x 數值為 0.7564，因此其差異則為 0.2436。差異定義如下：

$$Dif(D | W, V) = |V_x - fd_x| \quad (3-13)$$

此外，我們可計算出每組差異之總值，並找出其差異最小的一對染色體，作為最佳之 W ，因此問題定義如下：

$$W' = \arg \min_W \sum_{fd_x \in D} Dif(D | W, V) \quad (3-14)$$

3.5.3 適應性函數(fitness function)之評估標準

經由 fitness function 評估染色體 W ，期望能找出最佳之 W ，因此定義的 fitness function 如下：

$$f(W) = \frac{1}{\left(\sum_{fd_x \in D} Dif(D | W, V) \right) + 1} \quad (3-15)$$

3.5.4 Genetic Algorithm 之流程與步驟

先隨機產生 16 對染色體作為初始種群，並經由 $f(W)$ 計算出 16 個染色體的適應性數值，接著採用輪盤式選擇(roulette wheel selection)去選取 8 雙染色體，作為產生下一代染色體的雙親，而挑選機率之公式定義如下：

$$P_x = \frac{f(W)_x}{\sum_{i=1}^{16} f(W)_i} \quad (3-16)$$

並且我們指定交配機率(probability crossover)為 0.7，此外，交配點則採取兩點隨機之方式，舉例如下圖：

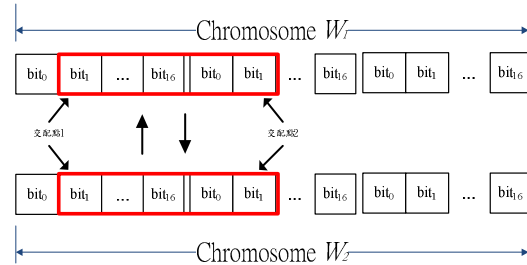


圖 3-6 染色體交配示意圖

反之假使兩個染色體沒交配的話，則採用複製的方式，使之成為下一代的染色體，而突變機率(probability mutation)設定為 0.001，即每隔 1000 個 bits 則進行突變，將子代染色體的某 bit 由 0 變 1 或 1 變 0，而疊代次數初始設定為 500 代。假設基因演算法在執行完 500 代後，則會產生許多染色體 W ，如下表所示：

表 3-3 染色體範例如下

W_1		
w_1	w_2	w_3
0.66665649	0.99804687	0.11109924
⋮		
W_n		
w_1	w_2	w_3
0.00389099	0.19999694	0.33332824

3.5.5 疲勞指標的定義

由於觀測結果 1 表示為瞌睡腦波，因此三種分類方法的 probability 數值，經由 fd 函式計算之後其結果值，如果越接近 1 表示現在可能出現瞌睡腦波，因此依 0.6 為一個門檻值，超過則判斷為瞌睡腦波。

4. 實驗分析

瞌睡腦波偵測系統的設計與研究之中，主要功能是人體的瞌睡腦波偵測，透過腦波設備與偵測系統之配合，進行人體腦波數據的收集，並進行實驗。主要實驗有 ANN、SVM、kNN 等方法的偵測正確率之比較。並探討調整分類方法之參數，對於腦波數據的分類之成效。以及藉由分類錯誤之數據來分析 True Negative、False Negative 的結果，最後則是 Multi-modal method 的成效驗證。

4.1 系統測試環境

實際於行車時進行瞌睡腦波偵測時，要讓駕駛者真的產生瞌睡情形，需要花費相當多的時間進行數據之收集，並且有安全性上的考量，故選擇了兩種模擬環境，以利腦波數據的收集。環境(1)早晨課堂以及夜晚撰寫文件或工作時進行人體的瞌睡偵測、環境(2)藉由搭乘長途路程之客運時進行腦波數據的收集。上述模擬環境都會要求測試者要保持正常之活動行為，如：早晨上課時則是照常專心聽課，並同時進行腦波偵測與受測者影像記錄，以便事後將記錄畫面與腦波數據進行比對，給予每筆腦波數據一個觀測結果。而搭乘環境下收集腦波數據時，則會要求受測者在長途旅程之中保持目前是自己開車之想像，避免出現一搭車就準備休息或補眠的情況產生。環境(1)測試時間每次約為 50 分鐘，受測人數共 7 人，並且為了有完整且連續性的腦波數據，所以只取中間 40 分鐘的資料作為可用的實驗數據，而環境(2)因為是一段長時間的偵測，並以 40 分鐘為一個單位，受測者 1 人。

4.2 各分類方法之分類正確率

一筆腦波數據的結構為四個(S_δ 、 S_θ 、 S_α 、 S_β)正規化的數值，而每秒記錄一個腦波數據，所以四十分鐘則會有 2400 筆連續性的腦波數據。下列實驗將應用收集到的實驗樣本建立每個分類模型，並計算其分類正確率。每個分類模型的建立方式為，藉由影像分辨人的精神狀況，然後依照影片時間，給每筆數據一個觀測結果。假設影片中受測者在 3:56 秒開始出現瞌睡情形(眼皮緩慢的開闔、點頭)，且於 5:24 秒有短暫回復的跡像(透過眼睛、臉部表情判斷)，此時這段期間記錄的腦波數據則會標記為瞌睡腦波，反之則為非瞌睡腦波。下面為觀測的影像圖片：



圖 4-1 精神狀態影像

下列實驗中會分為依個人數據建立的瞌睡

腦波判斷模型，以及混合多人資料來建立各方法的分類模型。

4.2.1 ANN 分類模型正確率計算

首先整理出每個人 600 筆(300 筆瞌睡腦波、300 筆非瞌睡腦波)的腦波數據來進行 ANN 模型的訓練。於此實驗中系統判斷的結果值越趨近於 0 表示非瞌睡腦波，而越靠近 1 則是瞌睡腦波。當系統將訓練樣本分類完成後，則會經由統計的方式，來計算其系統分類結果與人為觀測結果的分類正確率。舉例如下：假設 600 筆訓練資料之中，系統分類結果與觀測結果一致的是 427 筆(分類正確)、反之相異 173 筆(分類錯誤)，則正確率約為 71.1%。下表為各受測者的分類正確率之結果：

表 4-1 ANN 分類正確率結果

受測者	分類正確率(%)
1	76.7
2	76.2
3	80.1
4	75.8
5	79.3
6	75.2
7	74.3
8	76.5
AVG	76.8

4.2.2 SVM 分類模型正確率計算

SVM 的實驗之中，我們將用 NomolizePolyKernel、PolyKernel 作為 kernel function，來進行腦波數據的分類。並配合懲罰參數的調整，來計算各受測者的分類正確率。懲罰參數存在的意義主要是處理當分類資料無法區隔的情況(Non-Separable case)。由於某些資料橫跨兩類，使得 optimal separating hyperplane 無法明確的將資料區隔，此時則給予這些資料一定程度的懲罰。參數越小則代表有較寬的邊界，反之，較窄之邊界，即是求取訓練誤差最小化。下列為核心函數之公式[7]：PolyKernel(多項式)：

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

NomolizePolyKernel(正規化多項式)：

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

下表為 SVM 的分類正確率結果：

表 4-2 NomolizePolyKernel 分類正確率結果

NomolizePolyKernel									
受測者 懲罰 參數	1	2	3	4	5	6	7	8	AVG
1	79.2	77.1	80.9	75.2	78.6	76.2	75.0	76.2	77.3
10	80.1	78.6	81.9	77.8	79.4	78.1	77.3	78.3	78.9
100	79.7	77.4	80.6	75.4	78.9	76.4	75.6	76.9	77.6

表 4-3 PolyKernel 分類正確率結果

PolyKernel									
受測者 懲罰 參數	1	2	3	4	5	6	7	8	AVG
1	74.3	72.6	77.4	70.2	73.6	70.9	71.1	72.1	72.7
10	74.8	72.9	77.9	70.7	73.9	71.1	71.8	72.6	73.2
100	75.1	73.1	78.5	72.8	74.4	72.9	73.3	73.0	74.1

4.2.3 kNN 分類模型正確率計算

將每位受測者 600 筆的訓練樣本，應用於不同的 k 個數之實驗中。分類之定義如下：假設 k=3，然後應用歐幾里德距離公式去計算出與該實驗數據最相近的三個訓練樣本點，接著依照三個訓練樣本的腦波類別(觀測結果)，判斷此實驗數據是屬於何種類別。例如：三個訓練樣本之中兩個是屬於瞌睡類，一個是屬於非瞌睡類，則實驗數據即被歸類為瞌睡腦波。並經由平均的分類正確率找出較適當的 k 之值。而正確率的計算方式與上述兩種方法皆相同，實驗結果如下表所示：

表 4-4 kNN 分類正確率結果

受測者	kNN				
	k=3	k=5	k=7	k=9	k=11
1	78.1	75.7	71.7	73.7	70.2
2	79.2	77.5	75.6	74.9	72.1
3	75.8	74.6	70.3	68.6	66.8
4	77.1	73.9	74.7	72.1	70.8
5	73.7	70.2	69.9	67.9	65.3
6	73.5	70.1	68.8	66.2	64.8
7	75.2	73.7	70.1	67.8	66.1
8	72.1	69.2	66.2	64.7	61.8
AVG	75.5	73.1	70.9	69.4	67.2

4.2.4 混合數據之分類正確率

將八個人的腦波數據各取一部份，作為混

合的腦波數據，取的方式為每個人 300 筆資料 (150 瞌睡腦波、150 非瞌睡腦波)，所以訓練樣本總筆數為 2400 筆。

ANN 經由混合數據所訓練出來之模型的分類正確率為 79.8%。

下列為 SVM 與 kNN 的各自的混合數據之訓練結果：

表 4-5 NomolizePolyKernel 混合數據正確率結果

NomolizePolyKernel	
懲罰 參數	正確率(%)
1	73.6
10	76.0
100	76.6

表 4-6 PolyKernel 混合數據正確率結果

PolyKernel	
懲罰 參數	正確率(%)
1	75.0
10	75.2
100	75.6

表 4-7 kNN 混合數據正確率

	k 的個數				
	k=3	k=5	k=7	k=9	k=11
正確率	81.9	77.6	77.1	76.0	75.8

實驗結果顯示，kNN 在 k=3 時的正確率最高，但是隨著 k 的個數增加，正確率普遍會遞減，且正確率變化是較大且不穩定的。而 ANN 與 SVM 結果相近且隨著訓練資料集的不同，其正確率的變化是較穩定。SVM 的 Kernel function 的比較雖然差異不大，但是經由個人數據與混合數據的實驗數據顯示，NomolizePolyKernel 的正確率是較優於 PolyKernel 的正確率。此外，將多人的腦波數據混合應用於分類模型之建立，可得到較佳的分類正確率，因此後續的實驗將以混合數據作為輸入樣本，進行分類成效的驗證。

4.3 k-fold cross validation 之分類正確率

鑑於前項實驗之成果，本實驗直接以混合的腦波數據進行測試，共 2400 筆資料(瞌睡與

非瞌睡各一半)。依照 k-fold 的方法將實驗數據分成十組，然後每份資料集輪替為測試樣本，因此每次實驗時都會有 2160 筆訓練樣本、240 筆測試樣本。

4.3.1 ANN 的分類正確率計算

十組測試樣本的分類率計算結果如下表：

表 4-8 ANN 的 k-fold 結果

k-fold(組)	分類正確率(%)
1	74.3
2	75.2
3	75.6
4	76.8
5	74.9
6	76.4
7	74.8
8	78.1
9	74.2
10	76.1
AVG	75.6

4.3.2 SVM 的分類正確率計算

SVM 則針對兩種 kernel function 進行分類正確率的比較，其分類正確率如下表：

表 4-9 NomolizePolyKernel 的 k-fold cross validation 結果

NomolizePolyKernel											
k-fold	1	2	3	4	5	6	7	8	9	10	AVG
懲罰參數											
1	74.2	73.4	74.7	72.3	75.1	72.1	74.7	72.4	72.7	74.9	73.6
10	75.3	74.7	75.8	73.6	76.7	73.4	75.7	73.5	73.9	76.1	74.8
100	76.6	75.2	76.3	74.3	77.2	74.2	76.1	74.7	74.6	76.8	75.6

表 4-10 PolyKernel 的 k-fold cross validation 結果

PolyKernel											
k-fold	1	2	3	4	5	6	7	8	9	10	AVG
懲罰參數											
1	71.6	73.8	70.1	71.2	70.8	70.7	70.8	70.2	72.3	72.9	71.4
10	72.5	74.2	71.8	72.4	71.6	71.8	71.9	71.7	73.6	73.9	72.5
100	73.7	75.6	72.3	73.2	72.5	72.6	72.4	72.2	74.8	74.7	73.4

4.3.3 kNN 的分類正確率計算

實驗中分別進行 $k=3$ 、 5 、 7 、 9 、 11 的分類正確率計算，下表為 kNN 的實驗結果：

表 4-11 kNN 分類正確率結果

kNN k -fold	$k=3$	$k=5$	$k=7$	$k=9$	$k=11$
1	75.1	76.4	79.8	78.7	77.1
2	73.9	75.2	76.5	75.9	74.3
3	72.8	74.1	75.7	74.6	73.7
4	74.3	75.5	76.7	75.2	74.2
5	75.7	76.3	77.9	76.6	75.1
6	73.1	76.4	76.8	75.4	74.2
7	76.4	78.2	79.6	78.3	77.6
8	73.1	74.5	75.6	74.5	73.2
9	77.8	78.6	79.8	78.3	77.5
10	74.5	76.9	77.5	76.4	75.2
AVG	74.6	76.2	77.5	76.3	75.2

由實驗結果發現將混合數據，藉由 k -fold 驗證後，ANN 與 SVM 的分類正確率雖然有些微的下降，但皆仍有七成五以上的正確率。此外，鑑於 SVM 的分類成果，因此 SVM 於 Multi-modal method 的設定為懲罰參數 100，Kernel function 為 NomolizePolyKernel。而 kNN 的設定則是選擇 $k=7$ ，因為會有較高且穩定的分類正確率。

4.4 各分類方法誤判率之解析

採用混合腦波數據集(3000 筆)進行誤判結果之實驗。實驗作法為於 3000 筆的腦波數據之中，隨機挑選 500 筆腦波數據作為測試樣本，剩餘的 2500 筆數據用來當作訓練樣本。藉由系統所錄製的影片，可觀察每位受測者的精神狀況，並透過影像來判別受測者是否有瞌睡的情形。假設影片當中受測者出現瞌睡的情形，則表示精神狀態不佳以 False(觀測結果)標記，反之精神狀態佳則為 True。而系統判斷受測者當下的腦波數據為瞌睡腦波時，用 Positive(系統判斷結果)表示系統判斷正確，反之為非瞌睡腦波則為 Negative。由於在精神狀態不佳時，系統判斷錯誤是一個嚴重的問題，因此將特別計算 False/Negative 的情況，而我們定義 *False Negative*, FN 公式如下：

$$FN = \frac{False_Negative_Count}{False_Positive_Count + False_Negative_Count} \quad (4-3)$$

$False_Positive_Count$ 為精神狀態不佳時，判斷正確的資料筆數，加上判斷錯誤的資料筆數 $False_Negative_Count$ 作為分母，而分子為 $False_Negative_Count$ 。

4.4.1 ANN 誤判結果之數據計算

ANN 實驗結果統計如下表所示：

表 4-12 ANN 誤判結果統計表

Drowsy state Drowsy detection	True (精神狀態佳)	False (精神狀態不佳)
Positive (判斷正確)	178	191
Negative (判斷錯誤)	62	69

透過上表的實驗結果顯示， FN 約為 26.53%，而精神狀態不佳的偵測正確率約為 73.46%(191/260)，精神狀態佳的正確率則是 74.16%(178/240)。測試樣本的分類正確率則為 73.8%((178+191)/500)。

4.4.2 SVM 誤判結果之數據計算

下表 SVM 為統計出來的實驗結果：

表 4-13 SVM 誤判結果統計表

Drowsy state Drowsy detection	True (精神狀態佳)	False (精神狀態不佳)
Positive (判斷正確)	182	186
Negative (判斷錯誤)	78	54

SVM 的分類模型之 FN 約為 22.5%。另外，精神狀態不佳的偵測正確率約為 77.5%(186/240)，精神狀態佳的正確率則是 70%(182/260)。此外，分類正確率則為 73.6%((182+186)/500)。

4.4.3 kNN 誤判結果之數據計算

kNN 實驗結果統計如下表所示：

表 4-14 kNN 誤判結果統計表

Drowsy state Drowsy detection	True (精神狀態佳)	False (精神狀態不佳)
Positive (判斷正確)	192	188
Negative (判斷錯誤)	61	59

kNN 的分類模型之 FN 誤判率約為 23.88%。精神狀態不佳的偵測正確率約為 76.11%(188/247)，精神狀態佳的正確率則是 75.88%(192/253)。而分類正確率則為 76%((192+188)/500)。

考量三種方法在分類精神狀態佳與精神狀態不佳上，都各有其優、缺點，因此將三種方法之分類結果，納入 Multi-modal method 的計算之中，是為了能夠更精準的評估人體是否產

生瞌睡之情形，並依此數值作為一個評定精神佳或不佳的指標。

4.5 Multi-modal method 成效驗證

本實驗則是為了驗證 Multi-modal method 成效。因此將三種分類模型與 Multi-modal method 進行正確率的比較。Multi-modal method 計算出的數值只要在 0.6 以上則斷定為瞌睡腦波。且四種方式判定之結果，皆會與人工觀測結果比較，假使結果一樣即為判斷正確，反之，則為判斷錯誤。

4.5.1 驗證資料集

受測者八個人隨機各取 100 筆的腦波數據，並將每個人的腦波數據套用上述四種方法來分析。將統計各方法精神判定結果之正確率。

4.5.2 方法結果比較

下表為四種方法分類統計之比較結果：

4-2 四種方法之判定結果比較表

	Multi-modal	ANN	SVM	kNN
AVG	77.50%	74.50%	73.63%	73.50%

由於多模式之分類模型，經由參考三種方法的 probability 之數值，來進行腦波的類別判斷，因此當某一方法出現誤判後，即可透過另兩種方法的 probability 之數值，進行判斷結果的調整，使之能得到更準確的腦波分類正確率。像是受測者 1 與受測者 2 的資料集當中有較多是屬於誤判的樣本，因此各單一方法與 Multi-modal method 的判斷結果會有較明顯的差異。但假使驗證資料集當中有較多是屬於三種方法判定結果皆正確之樣本，則多模式的正確率結果仍會以些微的差距優於其它三種單一分類模型。此外，依平均值來看多模式的判斷結果，透過調整權值以較彈性的方式判定人體之精神狀態，降低三種方法各出現誤判時，對於精神判定的影響程度是有其效果存在的。

5. 結論與未來研究方向

透過實驗結果的分析，三種分類方法各應用於腦波偵測的分類準確率皆約有七成五以上的成果。考量為了改善錯誤判斷(True Negative、False Negative)的結果，因此研究中提出的 Multi-modal method，對於精神狀態的判斷是優於其它三種分類方法。但未來系統，如欲實際應用到真正的客運駕駛員身上，駕駛可配戴頭帶式的腦波偵測器，由於是鬆緊帶的材質，並不影響駕駛者的視線且長時間配戴不易造成頭部不適。為了使系統更適合建置於駕駛環境之中，已經將腦波偵測系統移植至較小

型的手持通訊設備，並透過手持通訊設備的攝影功能，達到拍攝駕駛臉部表情之目的，以便可藉由影像圖檔觀察駕駛的精神狀況。但在車載環境之下，進行實測與數據收集，須透過 3G 網路傳輸資料，易出現網路不穩定(例如：經過高樓大廈、隧道等)，易造成資料傳輸速率較慢、資料遺漏等情形。因此為了能讓目前的研究成果更易於實測環境下使用，往後則需設計資訊續傳的相關機制。圖為實際於客運公司提供的公車環境之中，人員針對環境架設瞌睡腦波偵測系統的評估與模擬實況。



圖 5-1 客運公司勘察圖

此外，瞌睡警示應可採用音樂提醒的方式。假設系統判定客運駕駛者是瞌睡狀態時，可將音樂推薦的概念納入系統功能之中。例如：採用資料探堪的方法，將駕駛者過往聆聽之歌曲記錄與腦波數據做比對，找出能讓駕駛者精神較亢奮的歌曲，藉由不同曲風的變化，達到提振精神之目的。

人體的腦波其實已經有相當可觀的研究與應用。像是醫療、教育學習、遊戲等，因此實驗室未來也預計進行人體腦波與運動的相關研究。此外，人體生理狀態偵測仍有許多應用層面可作發揮。除了瞌睡偵測之外，人體心率也能提供多種訊息，因此或許藉由心率偵測，給予有心臟疾病的駕駛者警示或是其它幫助。以及為了提高人體精神狀態的辨識準確度，除了透過腦波判斷外，也可將腦波與影像辨識做結合，藉由多元的方式達到更精準的判斷。

誌謝

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

參考文獻

[1] NeuroSky, Inc., "Brain Wave Singnal (EEG)," <http://www.neurosky.com/Documents/Docum>

- [ent.pdf?DocumentID=77eee738-c25c-4d63-b278-1035cfa1de92](#), pp.1-22, 2009.
- [2] Costantini, G. Casali, D. and Todisco, M., "An SVM based Classification Method for EEG Signals" *WSEAS International Conference on CIRCUITS*, 14thed., pp. 107-109, 2010.
- [3] 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.
- [4] Guler, I. and Ubeyli, E.D., "Multiclass Support Vector Machines for EEG-Signals Classification," *IEEE Transactions on Information Technology in Biomedicine*, Vol. 11, Issue. 2, pp. 117-126, 2007.
- [5] Guo, L., Rivero, D., Seoane, J.A. and Pazos, A., "Classification of EEG signals using relative wavelet energy and artificial neural networks," *First ACM/SIGEVO Summit on Genetic and Evolutionary Computation*, pp. 177-184, 2009.
- [6] Huang, R.S., Jung, T.P. and Makeig, S. "Tonic Changes in EEG Power Spectra during Simulated Driving," *Lecture Notes in Computer Science*, Vol. 5638, pp. 394-403, 2009.
- [7] Isa, D., Blanchfield, P. and Chen, Z.Y., "Intellectual Property Management System for The Super-Capacitor Pilot Plant," *Workshop on Advances in Intelligent Computing*, pp. 37-42, 2009.
- [8] Jrad, N., Congedo, M., Phlypo, R., Rousseau, S., Flamary, R., Yger, F. and Rakotomamonjy, A., "sw-SVM : sensor weighting support vector machines for EEG-based brain-computer interfaces," *Journal of Neural Engineering*, Vol. 8, No. 5. 2011.
- [9] Jung, T.P., Makeig, S., Stensmo, M. and Sejnowski, T.J., "Estimating alertness from the EEG power spectrum," *IEEE Transactions on Biomedical Engineering*, Vol. 44, pp. 60-69, 1997.
- [10] Lin, C.T., W, R.C., Liang, S.F., Chao, W.H., Chen, Y.J. and Jung, T.P., "EEG-Based Drowsiness Estimation for Safety Driving Using Independent Component Analysis," *IEEE Transactions on Circuits and Systems I: Regular Papers*, Vol. 52, No. 12, pp.2726-2738, 2005.
- [11] Li, M.A., Zhang, C. and Yang, J.F., "An EEG-based Method for Detecting Drowsy Driving State," *Seventh International Conference on Fuzzy Systems and Knowledge Discovery*, Vol. 5, pp. 2164-2167, 2010.
- [12] Li, W., Tao Y. and Wen, B.C. "Assessment based on nonlinear parameters of EEG α waves for human-body fatigues," *Journal of Northeastern University*, Vol. 26. p.p. 1174-1177, 2005.
- [13] Li, X.W., Zhao, Q.G., Liu, L., P, H., Qi, Y.B., Mao, C.S., Fang, Z. & Liu, Q.Y., "Improve Affective Learning with EEG Approach," *Computing and Informatics*, pp. 557-570, 2010.
- [14] Murata, A. and Takasawa, Y., "Evaluation of mental fatigue using feature parameter extracted from event-related potential," *International Journal of Industrial Ergonomics*, Vol. 35, Issue. 8, pp. 761-770, 2005.
- [15] 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, Published by Elsevier Science B.V.*, Chapter 1.5, pp. 21-40, 1999.
- [16] Platt, J.C., "Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods," *Advances in Large Margin Classifiers*, A.J. Smola, P. Bartlett, B. Schölkopf & D. Schuurmans, Eds. MIT Press, Cambridge, MA., 1999.
- [17] Rivero, D., Dorado, J., Rabuñal, J. and Pazos, A., "Evolving simple feedforward and recurrent ANNs for signal classification: A comparison," *International Joint Conference on Neural Networks*, pp. 2685-2692, 2009.
- [18] Subasi, A., "Epileptic seizure detection using dynamic wavelet network," *Expert Systems with Applications*, Vol. 29, Issue. 2, pp. 343-355, 2005.
- [19] Subasi, A., "EEG signal classification using wavelet feature extraction and a mixture of expert model," *Expert Systems with Applications*, Vol. 32, Issue. 4, No. 4, pp. 1084-1093, 2007.
- [20] Sivasankari, N. and Thanushkodi, K., "Automated Epileptic Seizure Detection in EEG Signals Using FastICA and Neural

- Network,” *International Journal of Advances Soft Computing and Its Applications*, Vol. 1, Issue. 2, pp. 91-104, 2009.
- [21] Sulaiman, N., Taib, M.N., Lias, S., Murat, Z.H., Aris, S.A.M. and Hamid, N.H.A., “EEG-based Stress Features Using Spectral Centroids Technique and k-Nearest Neighbor Classifier,” *International Conference on Computer Modelling and Simulation*, 13thed., pp. 69-74, 2011.
- [22] Sun, S.L., Zhang, C.S., and Zhang, D., “An experimental evaluation of ensemble methods for EEG signal classification,” *Pattern Recognition Letters*, Vol. 28, No. 15, pp.2157-2163, 2007.
- [23] Srinivasan, V., Eswaran, C. and Sriraam, A.N., “Artificial neural network based epileptic detection using time-domain and frequency-domain features,” *Journal of Medical System*, Vol. 29, No. 6, pp. 647-660, 2005.
- [24] Wang, L., Wu, X.J., Ba, B.D. and Ddong, W.H. , “A visionbased method to detect PERCLOS features,” *J. Computer Engineering and Science*, Vol. 28, pp. 52-54, 2006.
- [25] Xia, Q., Song, Y.W. and Zhu, X.F., “The research development on driving fatigue based on PERCLOS,” *Techniques of Automation and Applications*, Vol. 27, pp. 43-46, 2008.
- [26] Yazdani, A., Ebrahimi, T., and Hoffmann, U., “Classification of EEG Signals Using Dempster Shafer Theory and a K-Nearest Neighbor Classifier,” *Int. IEEE/EMBS Conference Neural Eng.*, 4thed., Antalya, pp.327-330, 2009.
- [27] Yang, B. and Huang, Y.Z., “A study on drowsy driver monitor system using PERCLOS,” *Control and Automation*, Vol. 21, pp. 119-121, 2005.
- [28] Yan, S., Wei, J.Q. and Wu, Y.H., “Study of EEG features extraction for doze car driver,” *Chinese Journal of Biomedical Engineerin*, Vol. 24, pp. 110-113, 2005.
- [29] Zhang, L.Y., Zheng, C.X., Li X.P. and Shen, K.Q., “Measuring kolmogorov entropy of EEG for studying the state of mental fatigue,” *Chinese Journal of Biomedical Engineering*, Vol. 26, pp. 170-176, 2007.