

第二章 文獻探討

大腦人機介面自從1990年代以來，發展出各式各樣，包含1.3節中介绍的各種應用，尤其在最近五年左右，研究成果迅速累積，大腦人機介面的研究越來越受到重視，也有一些相關的產品被研發出來。本章介紹數篇近期的文獻，以了解大腦人機介面研究的近況，並歸納出發展的趨勢，最後介紹兩篇在本論文中主要比較的文獻。

2.1 μ 波大腦人機介面的文獻

(一) Wadsworth實驗室

J. R. Wolpaw博士的研究團隊以 μ 波為控制源，設計一個讓使用者用想像的方式來控制游標的電腦選單[17]。他們找來四位受測者，其中兩位是脊髓損傷導致行動不便的傷患，另兩位是身體正常的受測者，除了其中一位正常受測者之外，其他三位受測者都有長時間參與大腦人機介面實驗的經驗。




圖2.1 選單畫面[17]

實驗一開始，受測者注視著電腦銀幕上的選單，如圖2.1最左邊的小圖所示[17]，總共有八個目標區塊。接下來的流程如編號第1~5的小圖所示；一開始，選單上只留下其中一個目標區塊，一秒鐘後游標出現在選單中間，此時受測者開始想像游標往該區塊移動，這個時候系統每50毫秒，會根據量測的腦波，去推算出受測者希望游標在垂直與水平方向的移動方向，依此控制

游標。如果游標在10秒鐘以內到達目標區塊，則目標區塊閃爍一次，表示任務達成；接著銀幕會有一秒鐘的空白，再顯示下一個目標區塊，八個目標區塊依照隨機的次序輪流出現。每次實驗依照上述的流程進行三分鐘，休息一分鐘後再進行下一次實驗，一天做八次實驗。四位受測者分別進行了68, 22, 40, 25天的實驗，各取最後三天的實驗拿來測試辨識率。

他們用自迴歸頻譜分析(Autoregressive)去計算腦波的頻譜值，再將 β 波與 μ 波的頻譜值做線性組合，分別換算出垂直方向的位移(正值代表向上移動，負值代表向下移動)，與水平方向的位移(正值代表向右移動，負值代表向左移動)。利用此特徵擷取與分類演算法來辨識腦電波，在經過數個月不等的訓練後，四位受測者平均的任務達成率，可以達到82.25%。

(二) Graz實驗室

G. Pfurtscheller博士的研究團隊同樣以 μ 波為控制源，再結合虛擬實境的技術，讓三位受測者分別在虛擬實境的街道中，以想像右手動或想像腳動的方式，來決定要向前走、倒退走或是站著不動，使用的特徵同樣是 μ 波能量的變化[18]。



圖2.2 虛擬實境[18]

受測者從頭戴式的銀幕中看見如圖2.2的虛擬街道景像[18]，系統同時給受測者視覺與聽覺的刺激。當銀幕顯示向右的箭頭符號，且聽到「嗶」聲，

則代表系統要求受測者想像右手動，此時系統辨識結果如果是右手動，則受測者在虛擬實境中站著不動；當銀幕顯示向下的箭頭符號，且聽到「嗶嗶」聲，代表系統要求受測者想像腳動，此時系統辨識結果如果是腳動，則受測者在虛擬實境中向前走；反之，如果系統要求受測者想像右手動，受測者誤想成腳動，則受測者在虛擬實境中將會倒退走，以當作處罰，藉此回授給受測者，讓他知道想像錯誤，而如果是將腳動的命令想像成右手動，則不予處罰，受測者在虛擬實境中將站著不動。一直走到街道的盡頭，就完成一次的實驗。每位受測者各完成六次的實驗，平均分開在兩天進行。

其腦電波分類的演算法，是先對原始腦電波取頻譜值當作特徵，再以線性鑑別分析法(Linear Discriminant Analysis, LDA)做兩個類別的分類。辨識的效果，是以受測者在虛擬的街道中總共走多少路程才到終點來評估，三個受測者平均行走的路程分別為12.8、9.4，及9.1單位長度(最差情形為20單位長度)。

2.2 特徵擷取的趨勢

從大腦人機介面發展以來，大多數的文獻都如上一節所介紹的文獻一樣，直接將 μ 波的頻譜值，當作辨識的特徵。像這樣很直覺地使用單純頻率域，或是單純時間域的特徵來做辨識，雖然都有不錯的效果，但是仍然有改進的空間。一般依照實驗設計所量測到的腦電波，通常都含有時間域、頻率域，以及空間域的特徵。也就是說，一次想像動作試驗(Trial)的過程中，量測到的待分類腦電波，可能在某個時間點、某個頻率的能量，或是在其中幾個電極的訊號，會出現有助於辨識的特徵，但是這些特徵卻不一定很穩定的出現，所以，如果我們只採用其中一種特徵，則很可能會漏掉其他真正利於辨識的特徵，辨識率也可能因此而無法提升；但是，顧慮到系統計算所花費的時間不能太長，所以特徵向量也不是越大越好，太大的特徵矩陣，也可能包含了導致誤判的特徵。因此，如何保留住重要的特徵，就是一個新的課題。

在2005年舉辦的一個國際的大腦人機介面會議的報告中也提到[19]，近幾年來有一個值得注意的現象，那就是有越來越多的團隊，開始嘗試使用混合式的特徵來做腦電波辨識[20][21]，而且在針對同樣腦電波資料集做辨識的大腦人機介面競賽中，成績較為突出的團隊，大多採用的是混合式的特徵，甚至把腦電波量測的範圍從感覺運動區擴大到整個大腦皮質，以增加空間特徵，再以主要成份分析法(Principal Component Analysis, PCA)或獨立成份分析法(Independent Component Analysis, ICA)...等方法降低資料的維度、找出這些特徵中最有利於辨識的成份[22]，再配合適當的分類演算法來辨識腦電波。

舉例來說，C. Guan博士的研究團隊在2005年第三次大腦人機介面競賽中，對編號IIIa的腦電波資料集做四個方向的辨識[23]，以79.26%的辨識率得到第一名。此腦電波資料集是由著名的Graz實驗室所量測的，總共有三名受測者，依照銀幕的視覺刺激提示，想像左手動、右手動、吐舌頭，以及腳動等動作，提供參賽者做辨識。

C. Guan博士等人是利用小波包分解(Wavelet Packet Decomposition)對腦電波的時間-頻率做分析，再以稀疏成份分析法(Sparse Component Analysis, SCA)分解成各個腦電波源頭成份(Source Component)的時間-頻譜值，然後將屬於雜訊的部分去除，只留下源頭在感覺運動區的成份的時間-頻譜值當作辨識特徵。保留下來的特徵矩陣不但維度降低，也包含了時間域、頻率域以及空間域中較重要的資料。經過這個完善的特徵擷取步驟以後，接著再用兩個支持向量機分類器辨識出腦電波的類別，最後得到的辨識率在參賽隊伍中為最佳。

在混合時間域、頻率域與空間域特徵的文獻之中，通常都會先降低特徵矩陣的維度，再進行分類，以改善計算的速度。在降維度的方法中，常被使用的有PCA、ICA，以及SCA。其中ICA與SCA相當類似，其優點是可以將腦電波分解成數個互相獨立的源頭成份，因此，我們可以了解每一個成份的意義，例如它是來自於眼動雜訊，或是來自於感覺運動區，然後我們就可以

挑選要分析的腦電波源頭成份。它們共同的缺點是需要人工挑選。

PCA是把腦電波分解為數個互相正交的投影軸的投影量，並依照他們保留的訊息量，由多到少做排序，因此可以自動選擇保留訊息較多的腦電波成份來分析，缺點則是每個成份沒有特殊的物理意義。三者當中，PCA因為能夠將成份依重要程度排序，因此最廣為被使用。有關PCA與其他相關的特徵擷取與分類演算法，在後續章節將詳細地介紹。

2.3 針對同一腦電波資料集做辨識的文獻

本文提出一個方法來提升腦電波的辨識率，稱為「改良式對角化主要成份分析法」，為了能夠與其他人提出的方法做客觀的比較，我們辨識的腦電波，是選用一個公開的腦電波資料集。同時，我們介紹另外兩團隊使用相同腦電波資料集所使用的方法。

首先，是N. Birbaumer與B. Schölkopf的團隊所做的辨識[24]，他們用3階的自迴歸模型(Autoregressive model, AR model)求取腦電波訊號的頻譜值當作辨識的特徵。自迴歸模型在訊號處理中，經常被用來做線性預測(Linear Prediction)，它是以第n個取樣點的訊號值與其前p個取樣點訊號值之間的關係，來表示一段訊號的特性。

例如一段數位訊號 $x(n)$ ，假設我們將它在時間軸上向右平移1、2、3個取樣時間所得到的延遲訊號，分別表示成 $x(n-1)$ 、 $x(n-2)$ 、 $x(n-3)$ ；則3階的自迴歸模型，就是要找出這三個延遲訊號分別對應的權重值 α_k ($k=1,2,3$)，使得這三個延遲訊號與其對應權重值相乘的加總，再加上一個高斯白雜訊(White Gaussian Noise) $e(n)$ ，能夠等於原來的訊號 $x(n)$ ，(2.1)式為p階自迴歸模型的數學表示式[25]：

$$x(n) = -\sum_{k=1}^p \alpha_k x(n-k) + e(n) \quad (2.1)$$

其中 α_k 也稱為AR參數，而 $e(n)$ 的變異數為 σ^2 。藉由自迴歸模型的參數化，

我們可以用一組AR參數來表示一段訊號的特性。

自迴歸模型也常被用來求得訊號的頻譜，在求出AR參數 α_k 與 σ 之後，我們可以利用(2.2)式來算原訊號 $x(n)$ 的頻譜 $S(f)$ ：

$$S(f) = \left| \frac{\sigma}{1 + \sum_{k=1}^p \alpha_k e^{-i2\pi kT}} \right| \quad (2.2)$$

其中， T 為訊號的取樣週期。

自迴歸頻譜分析的關鍵步驟，在於找出AR參數的方法，較著名的有Yule-Walker Method[26], Burg Method, 和Covariance Method等方法。

N. Birbaumer等人利用AR參數求出頻譜值建構出特徵向量以後，再以支持向量機(Support Vector Machine, SVM)將腦電波分類。支持向量機的概念雖然很容易理解，但是其最佳化的過程，則是相對複雜許多。然而其計算過程雖然複雜，因為有良好的辨識率，因此在很多領域都廣為被採用，例如本文主要比較的兩篇文獻[24][29]，都是採用支持向量機做腦電波的分類。

支持向量機屬於線性的分類器，其目的是在空間中找出一個最佳的超平面，將兩群不同類別的資料劃分開來，而且距離越遠越好，其示意圖如圖2.3所示[27]，圓形與方形分別代表 $y=+1$ 與 $y=-1$ 兩種不同類別的資料。




圖2.3 支持向量機分類示意圖[27]

兩群資料中距離超平面最近且與超平面距離相等的點，稱為支持向量（在圖中為 x_1 與 x_2 ），若一超平面與其支持向量的距離為最大，則稱此超平面為最佳超平面。

首先，假設 $x_i (i=1,2,\dots,n)$ 為 n 筆腦電波資料的特徵向量，其對應的類別 y_i 為+1或-1，而分割兩個類別的最佳超平面我們假設其平面方程式為[28]：

$$w^T x + b = 0 \quad (2.3)$$

其中 w 為超平面的法線向量， b 為常數項。此外，假設通過 x_1 與 x_2 ，且與最佳超平面平行的另外兩個超平面（在圖2.3中以虛線表示）分別以(2.4)式與(2.5)式表示：

$$w^T x + b = 1 \quad (2.4)$$

$$w^T x + b = -1 \quad (2.5)$$

接下來我們希望把兩個支持向量到超平面的距離和最大化，以得到最佳超平面。我們先將超平面與兩邊支持向量的距離和，也就是邊限 M (Margin)，以(2.6)式表示：

$$M = D_1 - D_2 \quad (2.6)$$

其中 D_1 與 D_2 分別是 x_1 與 x_2 在超平面的法線向量 w 上的投影長度。假設 x_1 與 x_2 與 w 的夾角分別是 α 與 β ，由三角函數關係我們可以得到：

$$D_1 = \|x_1\| \cos(\alpha) \quad (2.7)$$

$$D_2 = \|x_2\| \cos(\beta) \quad (2.8)$$

再由向量的內積定理，可以得到下面兩式：

$$\cos(\alpha) = \frac{x_1^T w}{\|x_1\| \|w\|} \quad (2.9)$$

$$\cos(\beta) = \frac{x_2^T w}{\|x_2\| \|w\|} \quad (2.10)$$

將(2.9)與(2.10)式分別代入(2.7)與(2.8)式，又因為 x_1 與 x_2 分別屬於(2.4)

與(2.5)式所表示的超平面，所以我們可以將(2.6)式代換成為如(2.11)式所示：

$$M = \frac{2}{\|w\|} \quad (2.11)$$

由(2.11)式可知，要將邊限 M 最大化，等同於將 $\|w\|$ 最小化。而在將 $\|w\|$ 最小化的同時，我們加入限制的條件，就是 x_i 與 y_i 要符合條件式：

$$y_i(w^T x_i + b) \geq 1 \quad (2.12)$$

因此，我們在最小化的過程加入 Langrange 條件項，如第(2.13)式所示，其中 λ_i 是 Langrange 係數：

$$L(w, b, \lambda) = \frac{1}{2} w^T w + \sum_{i=1}^N \lambda_i \{y_i(w^T x_i + b) - 1\} \quad (2.13)$$

為了將 L 最小化，我們分別令 L 對 w 與 b 偏微分為零：

$$\frac{\partial}{\partial w} L(w, b, \lambda) = 0 \quad (2.14)$$

$$\frac{\partial}{\partial b} L(w, b, \lambda) = 0 \quad (2.15)$$

從(2.13)~(2.15)式，我們得到使 L 最小化的解需滿足下列兩式：

$$w = \sum_{i=1}^N \lambda_i y_i x_i \quad (2.16)$$

$$\sum_{i=1}^N \lambda_i y_i = 0 \quad (2.17)$$

將(2.16)、(2.17)式代入(2.13)式，並利用對偶問題(Dual Problem)的觀念，將(2.13)式最小化的問題，轉換成(2.18)式的最大化：

$$W(\lambda) = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j x_i^T x_j \quad (2.18)$$

在(2.18)式最大化時所加入的限制條件為：

$$\sum_{i=1}^N \lambda_i y_i = 0 \quad (2.19)$$

$$\lambda \geq 0 \quad (2.20)$$

求出使(2.18)式最大化的 λ 之後，再帶回到(2.13)、(2.16)與(2.17)式，即可得到使 L 最小化的 w 值與 b 值(w_o 與 b_o)，相當於是得到有最大 M 值的超平面方程式。之後辨識未知分類的腦電波，我們只需要將其特徵向量 x 代入第(2.21)式，就可以辨識出其類別屬於+1類或-1類。

$$y(x) = \text{sign}(w_o^T x + b_o) \quad (2.21)$$

N. Birbaumer等人依照上述的特徵擷取與分類方法，得到73.2%±0.7%的辨識率。

另一個是K. Yang與C. Shahabi團隊提出的方法[29]，與N. Birbaumer等人提出的方法最大的不同，在於他們在AR model求出腦電波的頻率域資料之後，加入了主要成份分析法(PCA)，用來擷取腦電波頻譜值中最利於辨識的特徵，接著同樣以支持向量機將腦電波分類，得到了較佳的81%的辨識率。主要成份分析法的計算與我們使用的方法很類似，所以留待第三章再詳細介紹。

為了從混合的高維度時間域、頻率域以及空間域資料矩陣中擷取出最有利於辨識，而且低維度的特徵矩陣，許多文獻將PCA應用在腦電波辨識的特徵擷取上。然而，這樣的良好特性中，卻隱藏著一個計算上的盲點，使得PCA其實並沒有同時保留時間域、頻率域以及空間域混合的特徵，因此，D. Zhang在人臉影像辨識的領域中[16]，提出了對角化主要成份分析法來解決這個問題。本文研究的目的，就是將對角化主要成份分析法，實際應用在腦電波的辨識上，並找出辨識率最高的參數條件，再進一步以本文所提出的「改良式對角化主要成份分析法」，來提升辨識率，並與前述兩團隊使用同樣腦電波資料集所得辨識率做比較。

2.4 文獻回顧整理

前面幾節介紹了幾篇過去的文獻，我們將其中五篇文獻所使用的特徵擷取與分類演算法，以及最後的辨識率，列在表2.1中比較並討論。

由表中的內容，我們可以看出在特徵擷取方法的部分，在最近幾年開始有比較多的文獻是採用先混合頻率域、時間域與空間域的特徵，再從中篩選出重要特徵的方式，尤其最後兩篇的比較更可以看出以此方式擷取特徵，的確使得辨識率提升了。在分類器的部分，SVM 仍是最受歡迎的分類演算法，但是我們希望以更簡單的分類法，能有相同，甚至更佳의 辨識效果。

表2.1 過去做法比較表

作者	特徵擷取演算法	分類演算法	辨識率 (%)
J. R. Wolpaw et al., 2004 [17]	Autoregressive	Linear Combination	
G. Pfurtscheller et al., 2004 [18]	logarithmic band power	LDA	
H. Zhang et al., 2005 [23]	Wavelet + SCA	SVMs	79.26
N. Birbaumer et al., 2006 [24]	Autoregressive	SVM	73.20
K. Yang et al., 2005 [29]	Autoregressive +PCA	SVM	81.00