

改良式對角化主要成份分析法應用於想像動作 腦電波的辨識

Modified Diagonal Principal Component Analysis Applied to Motor Imagery EEG Classification

張苑珍 陳致仰 蔡俊明 葉榮木

Wan-Jen Chang Chih-Yang Chen Chun-Ming Tsai Zong-Mu Yeh

摘要

腦電波辨識是否成功的關鍵，在於特徵擷取與分類兩個議題。過去文獻將重點放在分類演算法的改良上，然而找出更簡單而重要的特徵，也可以獲得高辨識率。對角化主要成份分析法(DiaPCA)可以從腦電波高維度的時-頻-空域資料矩陣中找出主要的成份。被挑選出來的主要成份可構成一個較低維度的特徵矩陣，但仍保有兩種想像動作的腦電波之間主要的特徵差異。因此，藉由計算特徵矩陣間的歐氏距離就可分類腦電波。本論文提出利用「改良式對角化主成份分析法」對腦電波擷取特徵並辨識，結果顯示，腦電波辨識的準確率大幅提升了10.07%。

關鍵詞：大腦人機介面、對角化主要成份分析法、腦電波、時-頻-空域分析。

ABSTRACT

Feature detecting and classifying algorithm are the two keys to Electroencephalogram (EEG) classifying. Past articles focused on the improvement of classifiers, but selecting simpler and more important features is an alternative way to get a high accuracy. Diagonal Principal Component Analysis (DiaPCA) can find out the principal components of the high-dimension Time-Frequency-Spatial matrix of EEG signals. The principal components construct a lower-dimension matrix, which carry the major difference between the two classes of EEG signals. Thus, we can easily classify the EEG signals by calculating the Euclidean distance between feature matrices. A modified Diagonal Principal Component Analysis method is proposed in this paper to select feature vector and classify EEG. The result shows that the accuracy of EEG classifying is improved and up to 10.07%.

Key Words : Brain-Computer Interface, Diagonal Principal Component Analysis, Electroencephalography, Time-Frequency-Spatial analysis.

一、緒論

大腦人機介面，是用來聯絡人腦與外在裝置的介面。舉例來說，當我們感到口渴而想要拿起眼前的水杯，大腦皮質中與手部動作相關區域的神經元就會發出電訊號，經由神經系統的傳導，刺激手部的肌肉產生動作來完成動作。在這個過程中，如果由大腦人機介面量測到神經元所產生的電訊號，並從中擷取出關鍵的特徵，再進

而辨識出使用者的意圖，就可以將此辨識的結果轉換成指令，讓機器手臂來達成同樣的目的，而不需要使用者實際去動作。

對一般人而言，大腦人機介面的發展，的確可以讓生活更加方便省力，但是，以目前所發展的成果來說，最重要的貢獻則是對於身體有重度傷殘的病人(例如：漸凍症、嚴重腦中風、腦幹受損、肢殘…)有很大的幫助(Kübler, Mushahwar, Hochberg, and Donoghue, 2006)。他們的大腦可能完全正常，或是仍保有部份功能，但因肌肉的萎縮、居中聯繫的神經受損、脊髓硬化等等的因素，而

張苑珍 中正大學成人及繼續教育學系助理教授
陳致仰 臺灣師範大學機電科技研究所研究生
蔡俊明 臺北市立教育大學數學資訊教育學系
助理教授
葉榮木 臺灣師範大學機電科技學系教授

無法自由控制他的身體去做動作，甚至完全無法動彈。若是藉由大腦人機介面，他們就可以跟外界溝通，依照他們的意念來操作周遭的裝置，這也是為什麼要研究大腦人機介面的主要動機。大腦人機介面主要的工作是從大腦量測及分析腦電波，並進行特徵擷取與分類。

本文組織架構如下：第二節是先介紹研究大腦人機介面必須了解的一些腦電波背景知識，再介紹如何對腦電波特徵擷取與分類之相關文獻，最後從文獻探討中引出本文研究的目的。第三節是介紹兩個腦電波資料集的取得和處理。特徵擷取與分類的方法在第四節是介紹。實驗結果與討論在第五節是介紹，最後是結論與建議。

二、腦電波、文獻探討及研究目的

腦電波訊號的量測，依電極放置的深度來劃分，可以分為侵入式與非侵入式兩種。非侵入式的量測方式為，將電極固定於頭皮上方，隔著腦殼量測大腦皮質神經元發出的電訊號，此方式收集到的訊號稱為腦電波圖(Electroencephalogram, EEG)；侵入式的量測方式，則是透過手術將電極放置於腦殼下方，貼近在大腦皮質區上，直接量測神經元的電訊號，稱為腦皮層圖(Electrocorticographic, ECoG)。

EEG的量測不用深入到腦殼裡面，量測起來比較方便，也較不具危險性，所以一般的人都可以進行這樣的腦電波量測；ECoG的量測雖然較危

險，也不適合一般人，但因為ECoG是在腦殼內量測的訊號，所以阻礙EEG訊號傳送的腦殼，對ECoG來說反而是隔絕外界雜訊的一個天然屏障，因此，相較於EEG，ECoG有較大的振幅(50~100微伏特)、較寬的頻寬(0~200赫茲)，以及較高的空間解析度(數毫米)，所以往往會有較EEG高的辨識率(Leuthardt, Schalk, Wolpaw, Ojemann, and Moran, 2004)。在量測到腦電波訊號之後，我們可以從三個域(Domain)去作分析，分別是空間域、時間域，與頻率域。我們也從這三個域的觀點，來介紹有關於腦電波的基本知識：

(1) 腦電波的空間域分布

腦波量測的位置，必須要有一個國際通用的標準，才能讓不同的研究團隊能夠容易地溝通，因此在西元1958年，Jasper提出「國際10-20腦電波系統」(Jasper, 1958)，現在已成為一個通用的腦波量測標準系統，其電極分布的位置如圖1所示。

(2) 腦電波的時間域分析

腦電波是一種時間訊號，所以從時間域去分析腦電波，往往也可以獲得重要的特徵。例如受到感官刺激而產生的事件相關電位腦電波(Event-Related Potential, ERP)，通常都是發生在受到刺激後的數百毫秒，腦波的振幅會產生可預期的上升或下降，如圖2中的P50、N100與P200(Hu, Jansen, and Boutros, 2005)。




圖 1 國際 10-20 腦電波系統電極位置分布圖




圖 2 受到聽覺刺激的平均腦電波圖

由於每個人的反應時間不一樣，每次動作的反應時間也會有微小差異，因此時間上的特徵需要經過多次相同動作的腦電波平均之後，才會有顯著的時間域特徵顯示出來。圖2是將受測者受到總共756次聽覺刺激時，刺激前、後各0.5秒鐘的腦電波波段的平均波形，其中聽覺刺激發生在標示為0 sec的時間點，可以看見大約在聽覺刺激後50、100、200毫秒的時候，腦電波振幅有明顯的上升或下降，其中上升與下降分別以英文字母P與N註明。

(3) 腦電波的基本頻帶

除了空間域與時間域的特徵以外，腦電波的頻譜值，也蘊含了重要的特徵。研究腦電波的學者們，將腦電波依照頻率的不同，分為 δ 波、 θ 波、 α 波、 β 波，與 γ 波等基本波段(曾坤章，2006)。 δ 波的頻率範圍在0~3Hz，當人處於深層睡眠狀態下，會產生較高的 δ 波； θ 波是指4~7Hz的腦波，正常人在淺層睡眠時會產生此頻帶的腦波； α 波是指頻率範圍在8~12Hz的腦波，一般人在清醒且身心感到舒服、輕鬆的情況，特別是在閉眼時， α 波會較明顯； β 波是指13~24Hz的腦波，相對於 α 波， β 波是發生在情緒較不安，或是腦中作思考，張開眼時的腦波；另外，25~50Hz的腦波，是近幾年才受到注意的腦波波段，研究發現此頻帶的能量在聽不同類型音樂的時候會有不同的變化(Bhattacharya and Petsche, 2005)，稱之為 γ 波。其中，當四肢做動作時，在感覺運動區會有 α 波能量抑制的情形發生，稱為 μ 波(Kozelka and Pedley, 1990)。

2、文獻探討

大腦人機介面的辨識率高低，主要決定於「特徵擷取」與「分類」兩個關鍵的步驟。如果能夠找出不同想像動作所產生的腦電波之間差異最大的特徵，則不需要很複雜的分類演算法，就可以得到高辨識率；相對地，如果特徵差異不大，就需要效能良好的分類演算法來解決問題。

在大腦人機介面發展的初期，大多數的文獻都是直接對 μ 波取頻譜值，以當作辨識的特徵矩陣(Feature Matrix)，再藉由分類演算法的創新與改進，來提升辨識率(Wolpaw and McFarland, 2004)、(Leeb and Pfurtscheller, 2004)。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(Wolpaw and McFarland)。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。

Wolpaw用自迴歸頻譜分析(Autoregressive, AR)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%。

像這樣很直覺地只使用單純頻率域的特徵來組成特徵矩陣，再把研究的重點放在分類演算法的改良，雖然能夠使得辨識率有所提升，但是演算法往往越改進越趨於複雜，因此，有越來越多的文獻都將研究的重點轉移到腦電波特徵的擷取。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(McFarland, Anderson, Müller, Schlögl, and Krusienski, 2006)，近幾年以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(Hao, Zhang, and Yu, 2006)、(Yamawaki, Wilke, Liu, and He, 2006)，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，並以主要成份分析法(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，再配合適當的分類演算法來辨識腦電波。

舉例來說，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(Zhang, Guan, and Li, 2006)，以79.26%的辨識率得到第一名。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特徵。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。

混合式的特徵擷取方式之所以會有較佳的辨識率，是因為腦電波包含有時間域、頻率域，以及空間域的特徵，也就是說，一次想像試驗(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。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，所以資料矩陣也不是越大越好，太大的資料矩陣，也可能包含了導致誤判的資料。因此，如何從高維度的腦電波資料矩陣中，找出重要的特徵，將是本文研究的重點。

為了與其他文獻的方法做客觀的比較，我們把本文所提出的方法應用於辨識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，Hill的團隊所做的辨識(Hill, et al., 2006)是將腦電波用3階的自迴歸模型(Autoregressive Model)所求得的係數當作特徵，再以支持向量機(Support Vector Machine, SVM)將腦電波分類，依照上述的特徵擷取與分類方法，得到73.2%±0.7%的辨識率。

另一個由Yang的團隊提出的方法(Yang and Shahabi, 2005)是加入主要成份分析法，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。

為了從混合的高維度時間域、頻率域以及空間域特徵中擷取出最有利於辨識，而且低維度的特徵，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，Zhang在人臉影像辨識的領域中，提出了對角化主要成份分析法(Diagonal Principal Component Analysis, DiaPCA)來解決這個問題(Zhang, Zhou, and Chen, 2006)。本文提出「改良式對角化主要成份分析法」，來提升腦電波的辨識率，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。

3、研究目的

我們研究大腦人機介面的主要動機，是希望能研究發展出性能良好的大腦人機介面，以期有朝一日讓無法動作的病患，能夠藉由腦電波，來完成想做的動作。對於這樣的病患來說，他們最需要的，往往不是一套可以代替他們做任何動作的複雜系統，而是能夠讓他們做一些較簡單的動作，例如二選一的決策的系統，這樣他們才有能力靠自己的意念來操作。這樣的系統，首重的就是系統的高準確率，次之則是系統的速度，因此本文期望能藉由不斷地提升腦電波的辨識率，並使用簡單的演算法，有朝一日能夠讓重度傷殘的患者能夠依照自己的主動意志來做一個二選一的決策，簡易而準確地操控外在環境的裝置。

我們首先引用一個在人臉辨識中有良好辨識率的對角化主要成份分析法(Zhang, et al., 2006)，測試它應用於腦電波辨識的效果，並經由使用不同參數值的辨識以後，找出最佳的參數組合。在研究過程中我們發現其可供改進的地方，並定義一個評估特徵矩陣(Feature Matrix)中各個分量貢獻度的參數，定名為「絕對貢獻度」，依此參數找出有助於分類正確的分量，在最近鄰居分類法(Nearest Neighbor Classifier, NNC)計算歐氏距離(Euclidean distance)時，只採用最有助於辨識的前幾個分量。藉由這樣的改良，來提升應用在想像吐舌頭與想像左手小指頭抬起，兩種腦電波的辨識率，對大腦人機介面的發展有所貢獻。

為了客觀地證實我們提出的改良方法，能夠有效提升對腦電波的辨識率，在本文中，我們將提出的方法用來辨識一個在國際上公開為學術使用的ECoG腦電波資料集，再與其他團隊使用相同資料集所提出的方法，互比較辨識的結果。另外，也針對實驗所量測的EEG腦電波資料集做辨識，比較非侵入式的腦電波EEG與侵入式的腦電波

EECoG的辨識率有何差異。

三、腦電波資料集

本節將介紹兩個腦電波資料集的實驗設計與量測步驟，包含在網路上開放下載的EECoG腦電波資料集I，與實驗量測的EEG腦電波資料集II。

1、資料集 I

在本研究中，為了能夠客觀地把本文提出的演算法與別的方法做比較，我們將演算法用來辨識一個網路上開放下載的腦電波資料集I，此資料集是使用Birbaumer與Schökopf等人量測的腦電波資料(Lal, et al., 2005)。我們選擇這個腦電波資料集，因為它是國際上知名的一個資料集，比較具有公信力。

Birbaumer與Schökopf團隊使用侵入式的電極，在一位要動腦部手術的癲癇症病患的同意下，將一片含有8x8個電極的電極板放在病患右側的主要運動皮質區上的頭骨與腦膜下面。頭骨與腦膜相當於是一個低通的濾波器，隔絕了大部分的市電、肢體電訊號等非腦電波的雜訊，放在這個位置所量測到的EECoG腦電波，受到的雜訊干擾較少。




圖3 N. Birbaumer的實驗流程圖



圖4 視覺刺激採用的圖像

病患總共紀錄了數天的腦電波，其中只有兩天參與實驗。實驗流程如圖3所示，首先受測者必須注視著銀幕，實驗開始的時候，銀幕上出現一個長度為一秒鐘的視覺刺激，如圖4所示(Lal, et al., 2005)，然後受測者依照視覺刺激的暗示，做對應的想像動作，左手小指與愛因斯坦吐舌頭的圖片分別指示受測者做想像左手小指抬起與想像吐舌頭。想像持續四秒鐘後，休息兩秒鐘，再進行

下一次的想像試驗。

每次視覺刺激之後0.5秒到3.5秒的腦電波被取出來儲存為一筆想像動作的腦電波資料，也就是拿來辨識的基本單位。至於為何要從刺激後0.5秒開始，是因為刺激後0.5秒內的腦電波包含了受到視覺刺激產生的電訊號，相對於想像動作的腦電波，此時間內測量到的腦電波被當作雜訊，所以不予取用。上述的實驗流程總共量測了278筆想像動作的腦電波資料，其中左手動與吐舌頭各佔139筆。

2、資料集 II

為了要實際測試我們所提出的方法對非侵入式腦電波EEG的辨識效果，我們設計了一套實驗的流程，來蒐集非侵入式腦電波資料。實驗總共有四位受測者，皆為年齡在23~27歲之間，大腦未受過創傷，且四肢健全的男性，以下列的設備與流程，來量測並紀錄其腦電波。

(1) 硬體設備

腦電波的量測需要許多硬體設備與耗材，實驗時，是使用NeuroScan公司的電極帽與40通道腦電波數位放大器(取樣頻率1000 Hz)。

(2) 軟體設備

使用NeuroScan公司的軟體NeuroScan 4.3，此軟體可以在電腦銀幕上顯示量測到的腦電波，以及進行去眼動雜訊、濾波等訊號前處理動作，至於腦電波特徵擷取與分類等訊號後處理，則是以Matlab 7.0程式語言來實現。

(3) 實驗流程

首先讓受測者坐在椅子上並戴上電極帽，將Cz電極調整至向前對齊眉心中央、左右對齊兩耳耳尖的標準位置後，把電極帽調整到適當的鬆緊度，接著將每個量測電極都注滿導電膠，使得頭皮與電極之間的電阻值降低至5k(10³)歐姆以下，以完成實驗的準備工作。

為了量測到有意義的腦電波訊號，我們必須讓每位受測者充份了解實驗的流程與要求，並讓他們在正式紀錄腦電波前，先經過足夠的訓練(大約20分鐘)以降低正式量測時犯錯的機會，訓練階段受測者的想像任務與流程，皆仿照真正紀錄腦電波的實驗設計。

在經過20分鐘的訓練以後，我們先讓受測者休息3分鐘，並讓心情平靜、大腦保持清醒與專注，準備依照下面敘述的流程進行腦電波的量測。實驗流程如圖5所示：

開始的前0~2秒，受測者預備並休息，在第2秒的時候，我們給予受測者聽覺的命令提示聲，實驗中命令的內容皆為隨機產生，以兩種指令(左手或是舌頭)出現的機會相同為原則；當命令為左手時，受測者想像意圖左手小指抬起，若命令為舌頭，則受測者想像意圖伸長舌頭的動作。想像動作持續三秒之後，會有兩秒鐘的休息間隔，再繼續下一個想像的任務。每個包含休息與想像動作兩階段共五秒鐘的一次想像試驗，稱為一個「Trial」。

我們依照上述的流程進行一連串的想像試驗，考慮到受測者可能因為實驗內容較乏味且冗長，而產生疲勞的狀態，影響到腦電波的品質，所以在連續進行50次的想像動作之後，我們暫時停止紀錄腦電波，讓受測者休息三分鐘的時間，再重覆進行同樣的實驗流程，每位受測者各進行八次的實驗，包含有400次想像動作試驗，其中左手與舌頭的命令各200次。參與實驗的四位受測者，我們分別在不同日期量測腦波，因此我們的腦電波資料集包含有不同天氣、不同受測者的腦電波。

(4) 資料前處理

收集到腦電波資料集II之後，還需要經過幾個資料前處理的步驟，來濾除掉可能的雜訊，以提升辨識的準確率。做法如下：1. 去除眼動所造成的雜訊，是腦電波量測中很重要的一個前處理步

驟。腦電波是微伏特等級的電訊號，因此眼球轉動，或是張眼、閉眼等等的動作所產生的電位差，往往是頭皮上的腦電波的數十或是數百倍，即使電極與眼球有些距離，我們所量測的訊號還是會受到眼動訊號很大的干擾。2. 腦電波的量測與紀錄是連續的，因此包含了想像動作與休息時的腦電波訊號，然而我們在後處理的特徵擷取與辨識階段，只針對想像動作的腦電波，所以我們在去除眼動雜訊後，接著就是切出腦電波，一般是從0.5到2秒或從0.5到3.5秒切出(Lal, ect., 2005)。本研究腦電波資料集I是將每個刺激之後的0.5到3.5秒分別切取出來；獨立成一段長度為3秒鐘的腦電波資料。另外腦電波資料集II是將每個刺激之後的0.5到2.5秒分別切取出來，獨立成一段長度為兩秒鐘(2048個取樣點)的腦電波資料。接下來我們將每一段資料輸出儲存成文件檔，就得到我們所需要的資料矩陣。

(5) 資料後處理

在本研究中，我們嘗試以不同的特徵擷取與分類演算法，分別對前述的腦電波資料做辨識，希望能找出最有效的方法。

A. 時、頻、空間域特徵的組成

得到的資料矩陣，只包含時間域與空間域的特徵，而我們希望用於辨識的特徵矩陣能夠同時包含有時、頻、空間域上的特徵，因此以快速傅立葉轉換求出每一段訊號的頻譜值，再將其中L個頻譜值當作頻域特徵，串接在時域特徵後面，當作初始資料矩陣的後L行。此資料矩陣是主要成份分析法所用如圖6所示。




圖5 本研究的實驗流程圖




圖6資料矩陣

其中M為電極的數量，N為每一段的腦電波資料的取樣點數，L是頻域特徵的數量。在資料集I中，M=64, N=3000，而資料集II則是M=9, N=2048，至於L，可以供使用者自行調整，我們也將找出較有助於辨識的L值。

B. 特徵擷取

得到包含時、頻、空間域的特徵矩陣A以後，必須從中找出利於辨識的成份，並把其他不重要的成份捨去，以降低計算的負擔，並提高辨識的準確率。在評估辨識率的時候，以資料集I為例，得出278筆腦電波資料分為兩部分；一部分用來求出公式 (5)的 C_k ，稱為訓練資料，而剩下的用來測試辨識率，稱為測試資料。在本文中我們使用「Leave-one-out」的辨識率評估方式[Fukunaga, 1989]，也就是一次只留下一筆腦電波做為測試，另外277筆腦電波則當作訓練資料，利用此方法把278筆腦電波輪流當作測試資料以後，再把得到的278個辨識率平均，就是整個分類法最後的辨識率。

為了求得 C_k ，我們把277筆用來訓練的腦電波按照想像左手動與想像吐舌頭分為兩類(簡稱0類與1類)，再把兩類的資料分別對角化、平均，就得到 B_0 與 B_1 ，接下來依照公式(1)~(4)式，也就是主要成份分析法與對角化主要成份分析法的共同步驟，求出特徵向量的主要成份 C_{test} 以及 C_k ，完成特徵擷取的步驟。

在特徵擷取部分，本研究探討主要成份分析法與對角化主要成份分析法，將這兩個不同特徵擷取方法搭配相同的分類法(最近鄰居分類法)，並對同樣資料集來做辨識，比較其辨識效果。

四、方法

本文提出一套特徵擷取與分類的方法，對前述的兩個腦電波資料集做分類。先以對角化主要

成份分析法，從包含了時間、頻率，與空間域資料的高維度矩陣中擷取出維度較小的主要特徵矩陣，再以定義的絕對貢獻度當做選取分量的標準，在以改良式最近鄰居分類法將特徵矩陣分類時，只用絕對貢獻度較高的分量來計算歐氏距離。接下來將依照資料分析流程，介紹我們所使用與提出的演算法。

1、混合時空、頻域特徵的初始資料矩陣

開始分析腦電波之前，要先把量測到的腦電波資料集轉換成數位訊號，並以矩陣的形式來表示。以資料集I為例，實驗一共有64個電極，每個Trial長度為3秒鐘，類比訊號轉數位訊號的取樣頻率為1000 Hz，所以原始資料的每一個Trial都被儲存為維度64x3000的矩陣。但是這樣的矩陣只包含時間與空間域的特徵，為了不遺失頻率域的資訊，我們將此矩陣的64個列向量分別作快速傅立葉轉換(Fast Fourier Transform, FFT)，得到腦電波訊號的頻譜值，再把頻譜值(假設取L個)接在時域資料的後面，形成一個64x(3000+L)的矩陣，其中加入的頻率域資料的數量，可以由使用者自行決定，若加入0~50 Hz的頻譜值當作頻率域資料，則L=50，所形成的矩陣示意圖如圖7所示。

2、以對角化主要成份分析法(DiaPCA)擷取主要特徵

在得到腦電波空間、時間與頻率域的初始矩陣以後，許多團隊採用主要成份分析法來降低這三個域的資料所組合成的高維度矩陣之維度，只保留其中主要的特徵成份。

主要成份分析法的目的，在於從初始矩陣中選出前d個對應的特徵值(Eigenvalue)較大的特徵向量(Eigenvector)，將原始資料投影在該特徵向量上，雖然新維度比原始資料維度低，但仍可保留住原始資料中較重要的訊息。如圖8中(劉勇均，

2004)，有一群二維的資料點，其中 w_1 、 w_2 是其兩個正交的特徵向量。如果要以其中一個特徵向量的投影量，來取代原本二維的資料，則可以看到在 w_1 上的投影量，要比在 w_2 上的投影量，保留了更多原來資料點分布的特徵，因此 w_1 是較佳的特

徵向量。而主要成份分析法，就是將 n 個特徵向量依照其保留的資訊量，由高到低排列，讓使用者可以視情況，保留 d 個($d < n$)較佳的特徵向量，以達到降低矩陣維度的效果，同時仍保留了原始資料的重要特徵。




圖7 資料集I的初始資料矩陣組成示意圖(L=50)




圖8 主要成份分析法示意圖




圖9 原始矩陣對角化示意圖

主要成份分析法看似能夠降低矩陣的維度，並且保留重要的特徵，但是在其計算的過程中，卻隱含一個計算上的盲點，使得矩陣列向量所帶有的特徵，在運算過程中遺失了。有許多學者針對主要成份分析法的這個缺點提出改善的方法，對角化主要成份分析法就是其中之一，而且在人臉辨識的應用中，辨識率有明顯的提升(Zhang, et al., 2006)，因此我們將它應用在腦電波的辨識。

為了解決主要成份分析法遺失矩陣列向量中特徵的缺點，對角化主要成份分析法將初始矩陣的元素以對角化的方式重新排列。假設腦電波的初始矩陣 A 為一個 $m \times n$ 的矩陣，對角化的示意圖如圖9所示(以 $m=4, n=5$ 為例)：

首先，將原始矩陣 A (Original Matrix)複製且橫向並排，其中 a_{ij} ($i=1 \sim 4, j=1 \sim 5$)為矩陣中的元素，然後只保留圖中深色部分的元素而白色部分去除

掉，也就是只保留5條對角線的元素，接著再將深色部分的像素重新排列整齊，得到對角化的矩陣 B (Diagonal Matrix)。經過這樣的步驟以後，對角化後矩陣 B 相對於原始矩陣 A ，並沒有增加或減少元素，只是重新排列，而且是依照原始矩陣的對角線順序排列，因此 B 稱為對角化矩陣。而 B 矩陣每一行向量的元素，其實就包含了原始矩陣 A 在行向量與列向量上的資料，因此，將主要成份分析法使用在對角化矩陣的時候，雖然只運用到 B 矩陣行向量上的資料，但是等於同時運用了原始矩陣 A 在行向量與列向量的資料。

Zhang的實驗的結果顯示，在人臉辨識的應用中，使用對角化主要成份分析法比原來沒有對角化步驟增加了5%的辨識率。因此，我們將對角化主要成份分析法應用在腦電波的辨識上，希望同時保留時間域、頻率域特徵與空間特徵，並測試

它使用在腦電波辨識的效果。接下來介紹對角化主要成份分析法擷取主要腦電波特徵的後續步驟，也是跟主要成份分析法相同的部分。

假設我們要將腦電波分為 M 類，則先將已知類別的訓練資料，依照類別的不同分開來求對角化的矩陣的平均值，得到 M 個類別的平均矩陣，分別記為 $B_1, B_2, \dots, B_M$ ，再求對角化的類別間的總體平均矩陣 $\bar{B}$ ($m \times n$)：

$$\bar{B} = \frac{1}{M} \sum_{k=1}^M B_k \quad (1)$$

接著求其共變異數矩陣 G ($n \times n$)，定義如下：

$$G = \frac{1}{M} \sum_{k=1}^M (B_k - \bar{B})^T (B_k - \bar{B}) \quad (2)$$

式(2)將對角化的類別平均矩陣 B_k 減總體平均矩陣 $\bar{B}$ 得到的矩陣先轉置再相乘，在這個運算過程中，只有 $(B_k - \bar{B})$ 的行向量在運算，列向量在運算過程中被忽略了，這也就是主要成份分析法計算上的盲點。求得 G 之後，計算它的特徵向量 X ，與特徵值 λ ：

$$GX = \lambda X \quad (3)$$

再將這 n 個特徵向量依照其對應的特徵值的大小來排序，對應的特徵值越大，則該特徵向量就越有利於辨識。假設 $X_d = [x_1, \dots, x_d]$ 為 $X = [x_1, \dots, x_n]$ 中，前 d 個最佳的特徵向量 ($d < n$) 所組成的矩陣，則把待分類的測試資料的初始矩陣 A_{test} 乘上 X_d ，就得到測試資料的特徵矩陣 C_{test} ($m \times d$)：

$$C_{test} = A_{test} X_d \quad (4)$$

此時， C_{test} 矩陣所包含的，就是經過對角化主要成份分析法降低維度後的主要成份，將此特徵矩陣，再經由後續的分類演算法，就可以辨識出腦電波所屬的類別。

三、以改良式最近鄰居分類法分類腦電波

從共變異數矩陣 G 求出特徵向量 X ，並保留其中對應到較大特徵值的 d 個特徵向量，記為 X_d 。接下來我們將各類別未經對角化的平均矩陣 A_k 分別乘上 X_d ，以得到各類別腦電波的標準特徵矩陣 C_k ，如式(5)所示。

$$C_k = A_k X_d \quad (5)$$

接下來就可以用最近鄰居分類法，將測試資料 A_{test} 的特徵矩陣 C_{test} 分類。最近鄰居分類法藉由計算 C_{test} 與各個類別的標準特徵矩陣 C_k ($k=1 \sim M$) 的歐氏距離，找出與 C_{test} 距離最近的標準特徵矩陣之後，就把測試資料歸類到該類別，完成對角化主要成份分析法最後的分類步驟，歐氏距離的數學式如式(6)所示：

$$d(C_{test}, C_k) = \sqrt{\sum_{i=1}^m \sum_{j=1}^d (C_{test}^{(i,j)} - C_k^{(i,j)})^2} \quad (6)$$

歐氏距離的計算，可以視為是把兩個向量在各個分量上垂直投影後的距離平方，相加，再開平方。然而，我們發現這樣的計算方式，因為把特徵矩陣在每個分量的距離都計算進去，容易被少數幾個不利於辨識的分量所影響，造成辨識錯誤的機會增加，如果以二維的向量來當作例子，可以圖10來說明：圖中 C_1 與 C_2 分別是1類與2類資料的標準特徵矩陣， x 與 y 則是代表二維向量的兩個互相正交的座標軸。我們要求測試資料的特徵矩陣 C_T 與 C_1 、 C_2 的距離，從圖中可以很明顯的看出 C_T 與 C_1 的距離比較近，所以 C_T 應該要被分類為1類。但是仔細觀察可以發現，把這三個向量分別投影到 x 與 y 來計算距離，結果兩個座標軸的結果不一樣。在 x 軸上，距離 $|C_{TX} - C_{1X}| < |C_{TX} - C_{2X}|$ ，因此 x 可以說是對於分類有正向的貢獻；在 y 軸上，距離 $|C_{TY} - C_{1Y}| > |C_{TY} - C_{2Y}|$ ，因此 y 對於分類是呈現負向的貢獻。




圖 10 二維向量座標軸的絕對正向貢獻度說明

由於腦電波的特徵矩陣維度很高，如果提供負向貢獻的分量太多，會導致辨識的錯誤。因此，我們先去評估各個分量的正向貢獻度，並由高到低排列，在使用最近鄰居分類法分類的時候，我

們只用正向貢獻度較高的幾個分量來計算歐氏距離，這就是我們提出的改良式最近鄰居分類法的精神。

至於如何評估每個分量的正向貢獻度，我們定義了一個參數，稱它為「絕對貢獻度」。絕對貢獻度是以該分量在單獨被用來辨識時造成的正確率，來評估其對分類的貢獻度。以本論文所使用的腦電波資料集I為例，該資料集總共有278筆想像動作的腦電波資料(分為抬起左手小指與吐舌頭兩類)，我們所定義的單一分量的絕對貢獻度，其計算步驟如下：

- (1) 使用「Leave-one-out」的辨識率評估方式一次只留下一筆腦電波做為測試，另外277筆腦電波則當作訓練資料，利用此方法把278筆腦電波輪流當作測試資料以後，再把得到的278個辨識率平均。以對角化主要成份分析法從277筆訓練資料中，求出兩個類別的標準特徵矩陣 C_1, C_2 (假設特徵維度是 64×1)。
- (2) 對剩下的一筆已知類別的測試資料 A_{test} 計算其主要特徵矩陣 C_{test} 。
- (3) 一次只使用特徵矩陣裡的一個分量來計算 C_{test} 與 C_1, C_2 的歐氏距離，並將 C_{test} 分類，64個特徵分量各分類一次。
- (4) 比較使用64個特徵分量分類的結果與該測試資料的已知類別是否相同，若相同(辨識結果為正確)，則將該分量的絕對正向貢獻度+1；反之，辨識結果與已知類別不同，則該分量的絕對負向貢獻度-1。
- (5) 全部278筆資料輪流當作測試資料，並重覆(1)~(4)的步驟之後，各個分量的絕對(正、負向)貢獻度就被評估出來了。

我們所提出的方法與原本的最近鄰居分類法的差別，主要在於針對計算特徵矩陣之間的歐氏距離的公式，定義了「絕對貢獻度」這個參數，來評估各分量對於分類正確的貢獻度，依此來決定分類腦電波訊號的時候，要使用哪幾個分量來計算特徵矩陣的歐氏距離。

本節所介紹的這一新方法，命名為「改良式對角化主要成份分析法」，此方法包括特徵擷取和分類，在特徵擷取部分，其特點是使用了對角

化主要成份分析法，使得特徵矩陣的維度降低，並且保留了有利於辨識的特徵；在分類方法部分，定義一種選取計算距離所採用的分量標準，稱它為「絕對貢獻度」，這讓最近鄰居分類法在計算特徵矩陣之間的歐氏距離時，可以排除可能導致辨識錯誤的分量。

五、結果與討論

本文實驗的內容分為資料集II與資料集I的辨識兩部分。在腦電波資料集I的實驗，首先將主要成份分析法與對角化主要成份分析法分別用來辨識資料集I，以測試對角化主要成份分析法在腦電波辨識的效果，接著藉由改變「初始矩陣的頻率域資料數量L」與「保留的特徵向量數d」兩個參數，找出對角化主要成份分析法應用在腦電波辨識的最佳參數組合，最後以本文所提出的改良式對角化主要成份分析法辨識資料集I，並將辨識率與其他方法相比較。

在資料集II的實驗部分，我們把對角化主要成份分析法與改良式對角化主要成份分析法的辨識結果相比較，以驗證本文所提出的方法應用於不同人的腦電波，是否都能夠提升對角化主要成份分析法的辨識率，並將結果與資料集I的辨識率作比較，以觀察非侵入式的EEG與侵入式的ECoG的辨識效果有何差異。

1、資料集 I 的實驗結果

(1) PCA與DiaPCA的比較

在PCA與DiaPCA的比較中，我們分別測試了三種特徵混合方式的辨識率，一種是採用「頻域與空域特徵」混合，一種是「時域與空域特徵」混合，第三種是「時域、頻域與空域特徵」的混合，實驗結果如表1所示。從表中可以發現，在三種特混合方式中，只有採用頻率域與空間域混合特徵的時候辨識率很明顯地較低，而混合時間域、頻率域與空間域的方式有較高的辨識率，以DiaPCA來說，在無頻域特徵下，其辨識率比在有頻域特徵下低，所以，在此驗證了有無頻域特徵的結果。DiaPCA的辨識率僅比PCA高了約1.8%，沒有顯著差異，不像使用在人臉辨識中，其辨識率提升5%，在本研究中，第一個將DiaPCA應用於腦電波EEG的特徵抽取與降低資料的維度，研究和比較與PCA的差異，利用分量的絕對正負向貢

獻度來解決了傳統最近鄰居分類法中，計算歐氏距離的缺點，所以，確實也有研究的價值。

表 1 以 PCA 與 DiaPCA 辨識資料集 I 的辨識率比較表

特徵混合方式	PCA辨識率 (%)	DiaPCA辨識 率(%)
頻域+空域	55.04	54.32
時域+空域	71.23	72.66
時域+頻域+空域	71.23	73.02

(2) DiaPCA最佳的參數值組合

接下來針對辨識率比較高的DiaPCA來分析。在DiaPCA辨識腦電波的過程中，有兩個參數是可以讓使用者自行決定的，第一個是初始矩陣A的頻率域資料數L，若L的值太小，有可能遺漏重要的頻率域資料，但L並不是越大越好，因為加入的頻率域資料越多，計算所需的時間就越久。我們嘗試了使用 μ 波頻率範圍8~12Hz的頻譜值(L=5)、一般腦電波頻率範圍1~50Hz的頻譜值(L=50)，與更大範圍的頻譜值(L=200、1000)，並比較其間辨識率的變化。




圖 11 DiaPCA 在不同參數下的辨識率(%)

另一個使用者可以選擇的參數，就是在第(4)式裡，保留最有利於辨識的特徵向量數量 d 。保留的特徵向量越少，代表越精要的特徵，不但有助於辨識，計算量也較小，但是保留太少特徵，也可能會遺失重要的特徵。所以在實驗中我們分別測試了保留1、3、6個特徵向量的辨識率，來找出最適當的 d 值。

各種參數值組合所得到的辨識率以圖11中的長條圖表示，其中橫軸標示為1是指使用 μ 波的頻率範圍「8~12Hz的頻譜值」；標示為2是指使用「1~50Hz的頻譜值」；標示為3是指使用快速傅立葉轉換所得到的前200個頻譜值；標示為4則是指使用快速傅立葉轉換所得到的前1000個頻譜值當作初始矩陣A的頻率域資料，所得到的辨識率。藉此研究「初始頻率域資料數」與「保留的特徵向量數」的改變，對辨識率有何影響。

結果顯示，初始頻率域資料的數目L對辨識率的影響很小。不論在保留幾個特徵向量的條件下，只要初始頻譜資料增加為1~50Hz，就達到最高的辨識率，再增加資料點也不會使辨識率增加。以保留的特徵向量數量而言，留下3個特徵向量的辨識率最高，最高達73.02%，留下更多或更少的特徵向量都會降低辨識率。




圖 12 DiaPCA 在 16 種條件下的辨識率(%)

(3) 改良式DiaPCA的分析

分析了DiaPCA在各個參數條件下的辨識率之後，我們發現在分類的過程中有一個可能導致辨識率無法提升的主要原因，而我們也針對這點提出

了改良式最近鄰居分類法，本節統計出各分量的絕對貢獻度，來選取計算歐氏距離的分量，找出其中最有效的選取原則。

我們分別選取特徵矩陣中絕對貢獻度排名在

前3、5、7、9名的分量來計算歐氏距離，測試在選取幾個分量的時候會有最高的辨識率。而辨識率的計算方式是在四種不同參數條件組合下的平均辨識率。

結果如圖12所示，其中橫軸兩種座標，標示1、2、3、4，分別代表「保留1個特徵向量，8~12Hz頻域資料」、「保留1個特徵向量，1~50Hz頻域資料」、「保留3個特徵向量，8~12Hz頻域資料」、「保留3個特徵向量，1~50Hz頻域資料」參數條件下的辨識率，在這些標示1、2、3、4的下方，分別標示絕對貢獻度排名在前3、5、7、9名的分量。從結果可以發現，當我們只選擇貢獻度較佳的分量來算距離，不論是保留幾個分量，DiaPCA的辨識率都有很明顯的提升，其中以保留7個分量的平均辨識率82.46%最高，比原來的DiaPCA計算距離的方法平均提升了10.79 %；而各種參數條件組合中最高的辨識率為83.09%，在其中三個組合下產生。保留的特徵向量數量裡，仍然以3個特徵向量的辨識率要比1個特徵向量略為高了1.44%；至於頻率域特徵範圍的改變，則是幾乎沒有影響，用1~50Hz的頻譜值當作頻率域特徵平均起來只比8~12Hz高了大約0.1%。

(4) 改良式 DiaPCA 與其他方法的比較

表2是包含本篇文章與兩篇同樣針對腦電波資料集I做辨識的國外文獻所提出的方法以及其最高的辨識率的比較表：

從表中可以看到，以辨識率而言，在腦電波分類一向有不錯效果的SVM，用在資料集I的時候，也有73.9%的辨識率(Hill, et al., 2006)，Yang等人將資料矩陣擴大到時間、頻率，與空間域，並以PCA保留其中主要的成份，再以SVM將腦電波分類，使得辨識率提升至81%(Yang and Shahabi, 2005)。本研究使用Zhang等人所提出的對角化主要成份分析法來改善PCA的缺點(Zhang, et al., 2006)，不但降低初始資料矩陣的維度，同時保留了腦電波在時間、頻率，與空間域上的重要特徵矩陣，再以本研究所提出的改良式最近鄰居分類法將特徵矩陣分類，得到的辨識率提升至83.09%。

以計算速度而言，本研究所採用的DiaPCA雖然較PCA多了一個將矩陣重新對角化排列的步驟，但是對角化實際花費的時間其實很短。再考慮

分類方法的速度，雖然改良式最近鄰居分類法在計算各分量的貢獻度的時候，花費了不少時間，但SVM在超平面最佳化的過程中所花的計算成本也是很龐大，然而兩個分類器雖然在訓練階段花費較多時間，但是訓練完成後的分類步驟分別只需要將特徵矩陣計算歐氏距離與代入超平面方程式，花費的時間都很短暫。

綜合來看，兩套方法在計算的時間上差距很小，且將來實際使用系統的肢障患者往往對準確率的需求高於反應速度，因此我們認為本研究所提出的特徵擷取與分類演算法相較於前人提出的方法，不但有助於提升辨識率，也無損系統的速度，對腦電波的辨識有所貢獻。

2、資料集II 的實驗結果

資料集II與資料集I最大的不同之處，在於資料集II是非侵入式的腦電波EEG，而且包含了有四位受測者的腦電波。本研究將提出的「改良式對角化主要成份分析法」實際用在資料集II的辨識，並與對角化主要成份分析法的辨識率比較，以驗證本研究所提出的方法在辨識不同受測者的腦電波時，是否都能提升辨識率，同時也藉此觀察ECoG與EEG的辨識率有何差異，辨識的結果如表3所示。

從表中可以發現，本研究提出的改良式對角化主要成份分析法用在四位受測者腦電波的辨識率，都比對角化主要成份分析法的辨識率要來得高，以平均辨識率而言，提升了大約6%的辨識率，不過四位受測者的辨識率平均只有65.93%，相較於腦電波資料集I(ECoG)的辨識率可高到83.09%，非侵入式EEG腦電波的辨識率平均比侵入式的ECoG腦電波大約低了10%以上。

表2 本研究提出的方法與相關文獻比較表

文獻	特徵擷取	分類方法	最高辨
Hill, et al.,	AR	SVM	73.90
Yang and	AR+PCA	SVM	81.00
本研究	FFT+DiaPCA	Modified Nearest	83.09

表 3 以 DiaPCA 與 Modified DiaPCA 辨識資料集 II 的辨識率比較表

	DiaPCA辨識率(%)	Modified DiaPCA辨識率(%)
甲	61.11	64.81
乙	62.92	70.79
丙	55.13	61.54
丁	59.18	65.31
平均	59.63	65.93

六、結論與建議

本研究把在人臉辨識中有良好效果的特徵擷取方法「對角化主要成份分析法」應用在腦電波辨識想像左手動與想像吐舌頭的研究，企圖藉由這個方法擷取出時間域、頻率域以及空間域中最有利於辨識的特徵，以減低腦電波辨識中龐大的運算量，同時也提升辨識率。而此方法也如預期地改善了主要成份分析法的辨識率，將腦電波辨識率提升了約2%。

在評估其辨識率的時候，藉由改變「初始矩陣頻率資料數」與「保留的特徵向量數」這兩個參數，我們在12種不同的條件組合中，找出對角化主要成份分析法在保留3個特徵向量，且頻率域特徵範圍1~50Hz的參數條件下，即可獲得最佳的辨識率(73.02%)。

除了探討DiaPCA在各個參數條件下的辨識率以外，我們進一步提出改良式對角化主要成份分析法，在計算待辨識腦電波的特徵矩陣，與兩類腦電波的標準特徵矩陣之距離時，只採用絕對貢獻度較高的分量。實驗結果發現，當我們選取絕對正向貢獻度前7名的分量來計算歐氏距離，使得辨識率較原本的DiaPCA平均提升了超過10個百分比，最高辨識率達到83.09%，比起其他兩篇同樣使用腦電波資料集I做辨識的文獻有更高的辨識率。

本研究所使用的兩個腦電波資料集，分別是非侵入式與侵入式的腦電波，辨識的結果印證了侵入

式的腦電波ECoG由於受到的雜訊較少，空間解析度也較高，所以辨識率比非侵入式的腦電波EEG來得高；另外，兩個資料集一共五位受測者，在使用本研究提出的改良式對角化主要成份分析法做辨識的準確率，都比使用對角化主要成份分析法辨識有更高的辨識率，這顯示我們提出以「絕對貢獻度」來選取辨識所用的分量，確實可以改善對角化主要成份分析法的辨識效果。在我們的未來研究中，將繼續嘗試使用目前文獻中的Tensor factorization和非線性的方法來做特徵擷取和辨識，並跟目前的線性的方法做比較。並且將研究不同刺激呈現時，腦波ERSP的差異(Welling and Weber, 2001) 及線上分類 (Lehtonen, 2008)。

參考文獻

中文期刊

劉勇均(2004)。應用於指動偵測之腦波訊號分析系統。未出版之碩士論文，國立成功大學資訊工程研究所，台南市。

曾坤章(2006)。你開悟了嗎？遠離豬頭擁抱佛陀。台北市：小海豚意識科技。

英文期刊

1. Bhattacharya, J. and Petsche, H. (2005). Phase Synchrony analysis of EEG during music perception reveals changes in functional connectivity due to musical expertise. *Signal Processing*. 85, pp.2161-2177.
2. Fukunaga, K and Hummels, D. M. Leave-One-Out Procedures for Nonparametric Error Estimates, *IEEE Trans. Pattern Anal. Machine Intell.*, Vol. 11, no. 4, pp. 421-423, April, 1989.
3. Hao, D., Zhang, H., and Yu, N.(2006). High Resolution Time-Frequency Analysis for Event-Related Electroencephalogram. In X. Wu (Ed.), *Proc. of 6st World Congress on Intelligent Control and Automation Conference of the IEEE EMBS* (pp. 9473-9476). Dalian: Springer.
4. Hill, N. J., Lal, T. N., Schröder, M., Hinterberger, T., Wilhelm, B., Nijboer, F., Mochty, U., Widman, G., Elger, C., Schököpf, B., Kübler, A. ,and

- Birbaumer, N. (2006). Classifying EEG and ECoG Signals without Subject Training for Fast BCI Implementation: Comparison of Non-Paralysed and Completely Paralysed Subjects. *IEEE Trans. Rehabil. Eng.*, 14(2), pp. 183-186.
5. Hu, L., Jansen, B. H., and Boutros, N. N. (2005). Is P50 an Epiphenomenon? In W. Q. Wang (Ed.), *Proc. of 27st Annual International Conference of the IEEE EMBS* (pp. 1166-1169). Shanghai.
6. Jasper, H. (1958). Report of Committee on Methods of Clinical Exam in EEG. *Electroencephalogr. Clin. Neurophysiol.* 10, pp. 370-375.
7. Kozelka, J. W. and Pedley, T. A. (1990). Beta and Mu Rhythms. *J. Clin. Neurophysiol.* 7(2), pp. 191-207.
8. Kübler, A., Mushahwar, V. K., Hochberg, L. R., and Donoghue, J. P. (2006). BCI Meeting 2005—Workshop on Clinical Issues and Applications. *IEEE Trans. Rehabil. Eng.*, 14(2), pp. 131-134.
9. Lal, T. N., Hinterberger, T., Widman, G., Schröder, M., Hill, J., Rosenstiel, W., Elger, C. E., Schölkopf, B., Birbaumer, N., Saul, L. K., Weiss, Y., and Bortou, L. (2005). Methods Towards Invasive Human Brain Computer Interfaces. In L. K. Saul (Ed.), *Advances in Neural Information Processing Systems (NIPS) 17* (pp. 737-744). Cambridge: MIT Press.
10. Leeb, R. and Pfurtscheller, G. (2004). Walking through a Virtual City by Thought. In G. Dumont (Ed.), *Proc. of 26st Annual International Conference of the IEEE EMBS* (pp. 4503-4506). San Francisco.
11. Lehtonen J, Jylänki P, Kauhanen L, Sams M. (2008). Online Classification of Single EEG Trials During Finger Movements. *IEEE Trans Biomed Eng.* 2008 Feb;55(2), pp.713-720
12. Leuthardt, E. C., Schalk, G., Wolpaw, J. R., Ojemann, J. G., and Moran, D. W. (2004). A Brain-Computer Interface Using Electrocorticographic Signals in Humans. *Journal of Neural Eng.* 1(2), pp. 63-71.
13. McFarland, D. J., Anderson, C. W., Müller, K. R., Schlögl, A., and Krusienski, D. J. (2006). BCI Meeting 2005—Workshop on BCI Signal Processing: Feature Extraction and Translation. *IEEE Trans. Rehabil. Eng.*, 14(2), pp. 135-138.
14. Welling, Max and Weber, Markus, Positive tensor factorization. *Pattern Recognition Letters*, Volume 22, Issue 12, October 2001, pp. 1255-1261
15. Wolpaw, J. R. and McFarland, D. J. (2004). Control of a Two-Dimensional Movement Signal by a Non-Invasive Brain-Computer Interface in Humans. *Proc. Natl. Acad. Sci. USA*, 101, pp. 17849-17854.
16. Yamawaki, N., Wilke, C., Liu, Z., and He, B. (2006). An Enhanced Time-Frequency-Spatial Approach for Motor Imagery Classification. *IEEE Trans. Rehabil. Eng.*, 14(2), pp. 250-254.
17. Yang, K. and Shahabi, C. (2005). On the Stationarity of Multivariate Time Series for Correlation-Based Data Analysis. In W. Q. Wang (Ed.), *Proc. of 5th IEEE International Conference on Data Mining*. Houston: Springer.
18. Zhang, D., Zhou, Z. H., and Chen, S. (2006). Diagonal Principal Component Analysis for Face Recognition. *Pattern Recognition*. 39, pp. 140-142.
19. Zhang, H., Guan, C., and Li, Y. (2006). Signal Processing for Brain-Computer Interface: Enhance Feature Extraction and Classification. In E. Dermatas (Ed.), *Proc. ISCAS*. (pp. 1615-1618). Patras.