

第三章

肌電訊號分析

肌電訊號的分析與特徵值的選取是本論文研究之手臂運動分析架構與分類器成功與否的重要關鍵；在許多參考的研究與分析肌電訊號的過程中，我們可以發現分析肌電訊號時，不但要考慮到肌肉的移動以及電極與導線錯動時所造成的雜訊，還要注意到肌電訊號的不一致性，即每個人在做相同的肢體動作時，都會因為每個人的生理情況而造成所量得的訊號有所不同；甚至即使是同一個受測者在做同一種動作時也會量得到不盡相同相同的肌電訊號，所以整體來說，由於肌電訊號的不穩定而使得特徵值上產生不穩定的變化。而一般對於複雜且不穩定的生理訊號通常會藉由找出更多的特徵來彼此彌補，然而由於特徵值的不穩定以及採用過多的特徵值或是所選擇的 EMG 訊號特徵無法有效明顯地表現其訊號之間的差異，那麼則會導致系統的負擔或是辨識率下降；另外參考國外的相關研究，可以發現用類神經網路來做為肌電訊號的分類工具容易因為特徵值的不穩定與不確定性而影響了神經網路學習的時間以及增加了系統的運算量[6, 16]，因此在本論文研究中不直接利用大家常使用的類神經網路，而是先藉由獨立成分分析法分析找出 EMG 訊號的獨立特徵成分，並分析手臂在不同速度彎曲的情況下其肌電訊號的特性，藉此找出更有效的 EMG 訊號特徵值以幫助做手臂運動在速度上的分類；而由於目前所分類的項目並不會過於複雜，假使經由分析後找出的特徵值能夠直接表示手臂運動的快慢，那麼我們即可直接以特徵值的類型來做手臂運動速度上的分類；若是找出的特徵很難直接表現出肌電訊號的特性，則還可以再結合模糊類神經網路等其它分類方式來實現。

在研究分析生理訊號方法的過程中，我們發現獨立成分分析法是非常實用的分析工具；在腦波分析的研究裡，可以用來去除眼皮跳動所造成的影響，在肌電訊號的分析裡，可以用以去除雜訊以及分離出其獨立訊號等。而為了解決生理訊號這種 Blind Source Separation 問題，我們不使用主成分分析法 (Principle Component Analysis, 簡稱 PCA) 的原因在於經過 PCA 轉化後所得到的特徵參數容易受到許多並不是真正因為動作所造成的訊號差異所影響，如導線晃動的干擾或是電極貼片錯動等因素，而這些因素有時可能會造成差異的存在；此外，我們也希望將來能夠結合腦波方面的研究，使用相同的分析方法以建立起一套從人類大腦至手臂運動以及機械手臂或義肢控制的完整分析流程，所以我們決定選擇獨立成分分析法做為我們分析肌電訊號的工具。

在本論文研究中，我們利用獨立成分分析法的主要目的在於找出肌電訊號裡得獨立特徵成分，並觀察經過獨立成分分析法運算處理後的訊號在頻域分佈的相關性，用以篩選掉誤差較大的肌電訊號數據，我們發現用此方法做為篩選資料工具，可以更有效率地刪除差異性大的資料以增加數據的一致性，如此整個肌電訊號的分析才不易受到差異性較大的數據所影響，所以在本研究中獨立成分分析法是相當重要的分析工具，以下則介紹本論文中所使用到的獨立成分分析法。

3.1 獨立成分分析法簡介

Independent Component Analysis(以下簡稱 ICA)是種使用統計和計算的方法,可用來找出在隨機變數、量測資料或是訊號裡的獨立成分；ICA 的發展起初是為了解決未知訊號分離(Blind Source Separation, BSS) 這種將訊號的問題，此又被稱為雞尾酒宴會 (Cocktail-Party) 問題[1]，所謂雞尾酒宴會問題即是在一個空間中，同時有許多聲音一起出現，也許有很多人再說話，甚至背景夾雜

著音樂，即使在這個吵雜的環境下，我們仍能專心的聽到想聽的聲音，甚至與人交談。這個機制牽涉到人腦的結構與神經的傳導，但在解決訊號處理的問題時也是一個有趣的問題。而 ICA 對於這樣的問題，在訊號源是獨立的前提下提供了一個解決的方式。此方法最早是由 Ans、Herault 與 Jutten 在 1983 年提出，一開始是用來處理神經生理學方面的問題[14]，而在研究訊號處理方面較早的是 blind signal deconvolution 之相關問題，然而一直到九〇年代中期，ICA 的研究成果依然受到侷限，當時所發展的演算法通常只能在一些限制下使用。而在 1997 年 Hyvarinen 提出 FastICA 後[11]，由於計算效率較高，ICA 才開始普遍的被應用在各個領域[24]。

3.2 問題描述

ICA 所處理的主要為 Blind Source Separation 的問題，為便於描述，假設有 N 個未知的訊號源經過混合過程之後，我們得到了一組混合訊號，而 ICA 的目的即在於藉由此混合訊號來還原出原本的未知訊號，其示意圖如圖 3.1 所示。

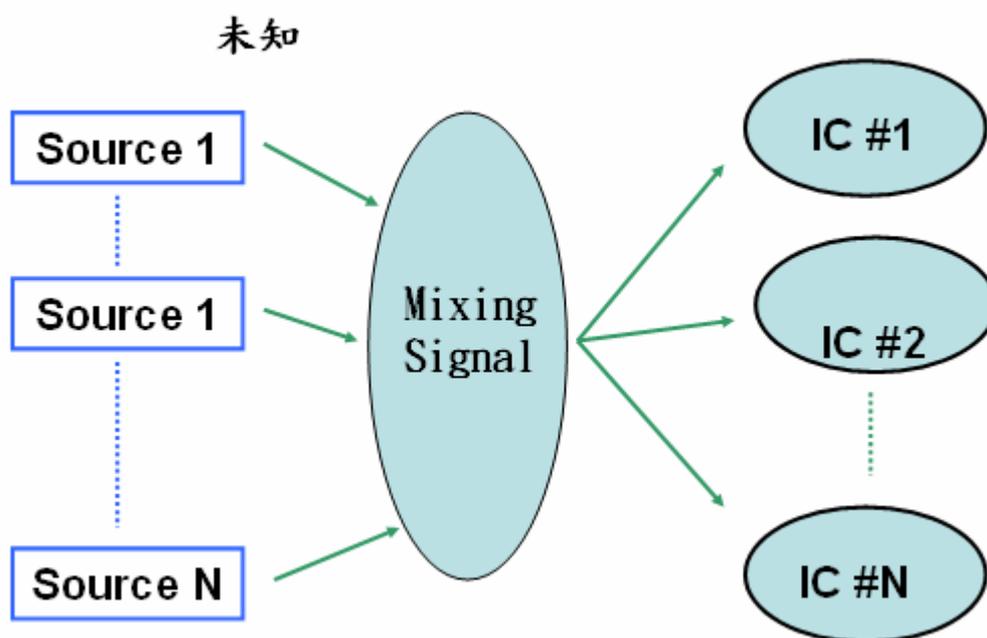


圖 3.1 Blind Source Separation 示意圖

在這些我們所測量到的混和訊號中，一定包含了一些來自訊號源的資訊，而所測量到的訊號個數和訊號源的個數也可能會有很多個。假設我們有 m 組測量到的訊號，而訊號源共有 n 個，那麼將測量到的訊號可以用 $x_j(t)$ 表示，其中 $j=1, 2, 3, \dots, m$ ；而訊號源可用 $s_i(t)$ 來表示，其中 $i=1, 2, 3, \dots, n$ ；而在一般情況下為了將問題簡單化，我們會只考慮所測量到的訊號和訊號源之間存在的是線性組合，如下數學式表示：

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_n \end{bmatrix} = AS \quad (3-1)$$

其中 a_{ij} 代表第 j 個訊號源到第 i 個感測器的放大倍率；其中混和矩陣 A 與訊號源矩陣 S 都為未知，因此處理 Blind Signal Separation 就像是去找出一個矩陣 W ，來讓所測量到的訊號能夠透過矩陣 W 的反運算還原成原來的訊號，如下式所示：

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1m} \\ w_{21} & w_{22} & \cdots & w_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \cdots & w_{nm} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{bmatrix} \approx S \quad (3-2)$$

至於該如何決定上式 W 的值則可以用訊號源彼此間獨立的關係。

$$\begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_n \end{bmatrix} = \begin{bmatrix} \tilde{s}_1 \\ \tilde{s}_2 \\ \vdots \\ \tilde{s}_n \end{bmatrix} = W \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

$$S \approx \tilde{S} = WX$$

$$\Rightarrow W \approx A^{-1} \quad (3-3)$$

因為訊號源之間是獨立的，所以所量測到的訊號經過 W 的轉換，如果有把混和的

因素消除，則運算出來的 Y 應該也是彼此獨立，即原本彼此相關性獨立的訊號源如(3-3)式所示。

3.3 ICA 演算法

在開始進行 ICA 演算時，我們都會先去訂定目標函數，目標函數的本意義是為了讓我們能夠藉此經過運算而找到獨立元素出來，而 ICA 演算法除了需要找到目標函數之外，可靠的演算法亦左右 ICA 演算法的成效與找尋獨立元素的收斂速度，而這些考慮的因素則會在之後做討論；圖 3.2 為 ICA 演算法之整體架構圖。

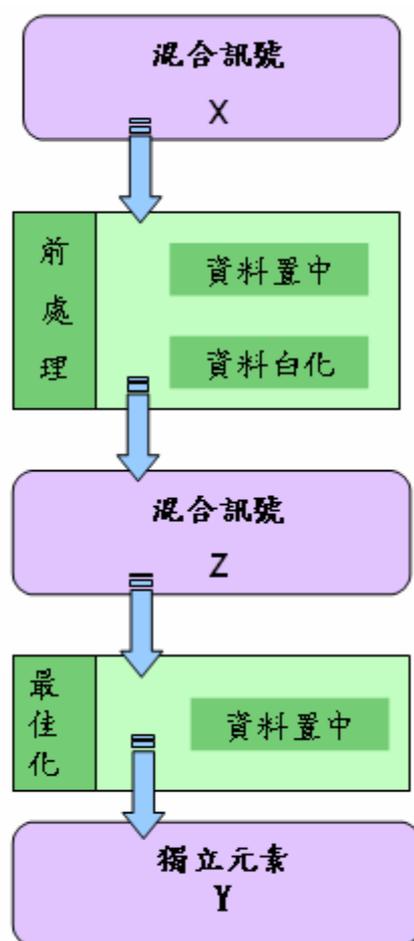


圖 3.2 ICA 演算法架構圖

3.4 ICA 之前置處理方法

在一般情況下，在開始使用 ICA 演算法之前，為了能夠更有效率簡化問題，通常會先進行前處理的動作，而好的前處理動作能夠讓 Blind Source Separation 的問題變的較容易解決，同時亦能有助於之後將 correlated 的訊號轉變成 uncorrelated 的訊號以及後端的 FastICA 運算；以下就以 ICA 的前處理，包括資料置中(Centering)和白化(Whitening)，進行說明[20]。

3.4.1 資料置中

假使獨立訊號源和我們所收集到的混合訊號的平均值不為零，那麼在演算法的推導過程會變的比較複雜，會增加許多計算量，所以在這種情況下我們可以將所收集到的訊號減去它們的平均值，使其平均值為零，如(3-3)式所示：

$$x_{center} = x - E\{x\} \quad (3-4)$$

此外，經過資料置中處理後的混合訊號 X ，矩陣 A 依然不會改變；雖然只有對接收到的訊號作資料置中的運算，但事實上也對訊號源做了資料置中的計算：

$$E[X] = E[AS] \quad (3-5)$$

$$\Rightarrow E[X] = A \cdot E[S] \quad (3-6)$$

$$\Rightarrow E[S] = A^{-1} E[X] \quad (3-7)$$

$$= A^{-1} 0 = 0 \quad (3-8)$$

由(3.7)式可以得知雖然只有對混合訊號作置中動作，但其實也對原始訊號做了置中的動作。

3.4.2 白化

在統計學裡，非相關的條件比相互獨立稍微寬鬆一些，表 3-1 即為 correlation, uncorrelation, whiteness 以及 independent 的條件關係表：

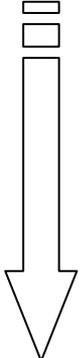
類型	條件	強度
Correlation	$E[(X_1 - U_{x1})(X_2 - U_{x2})^T] = E[X_1 X_x^T] - U_{x1} U_{x2}^T \neq 0$	
Uncorrelation	$E[(X_1 - U_{x1})(X_2 - U_{x2})^T] = E[X_1 * X_x^T] - U_{x1} U_{x2}^T = 0$	
Whiteness	$E[(X_1 - U_{x1})(X_2 - U_{x2})^T] = E[X_1 X_x^T] - U_{x1} U_{x2}^T = 0$ $E[(X - U_x)(X - U_x)^T] = I$	
Independent	$P[X1, X2] = P[X1] \cdot P[X2]$	

表 3-1 correlation、uncorrelation、whiteness 及 independent 的條件關係表

所以在做 ICA 之前，假使如果能夠透過前處理的方式將取得的訊號轉變為非相關，那麼則可以讓運算的訊號能夠更為接近相互獨立；至於白化則是介於非相關與相互獨立之間的另一種關係，除了訊號為非相關，而且變異數的值為”1”，假使 Z 為 white（平均值為 0 的隨機向量），那麼它的 covariance matrix 的數值為單位矩陣。

$$E[ZZ^T] = I \quad (3-9)$$

資料白化的目的主要是去找到一個矩陣 V (whitening matrix) 用來將混合訊號做轉換：

$$Z = VX \quad (3-10)$$

而較一般常使用的方法就是對混合訊號的 covariance matrix 做的分解 (Eigenvalue Decomposition, 即 EVD)

$$E[XX^T] = EDE^T \quad (3-11)$$

上式的矩陣 E 是 Eigenvector 所組成的正交矩陣，同時 $E^T = E^{-1}$ ；而矩陣 D 則是其相對應的特徵值所形成的對角線矩陣，那麼矩陣 V 可改寫為

$$V = ED^{-1/2}E^T \quad (3-12)$$

$$\text{其中 } D^{-1/2} = \begin{bmatrix} d_1^{-1/2} & 0 & \cdots & 0 \\ 0 & d_2^{-1/2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & d_n^{-1/2} \end{bmatrix} \quad (3-13)$$

如式(3-13)，可由(3-12)式代入 covariance matrix 判斷是否為單位矩陣，並檢查經由 whitening matrix 運算後的矩陣 Z 是否已變為 white。

$$\begin{aligned} E[ZZ^T] &= E[VXX^TV^T] \\ &= E[ED^{-1/2}E^TXX^TED^{-1/2}E^T] \\ &= ED^{-1/2}DD^{-1/2}E^T \\ &= EE^T \\ &= I \end{aligned} \quad (3-14)$$

資料白化的運算，可當作是將混合矩陣 A 做線性轉換，可將(3-13)式改寫為

$$\begin{aligned} Z &= VX \\ &= VAS \\ &= \tilde{A}S \end{aligned} \quad (3-15)$$

其中 \tilde{A} 可視為經過轉換後的混合矩陣；此外當訊號經過白化後，其 covariance matrix 以(3-9)式代換可得到下式結果：

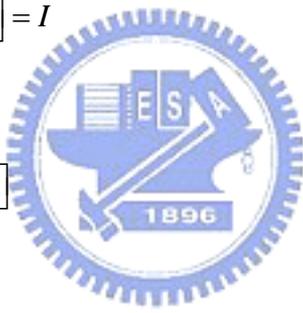
$$\begin{aligned} E[ZZ^T] &= E[\tilde{A}SS^T\tilde{A}^T] \\ &= \tilde{A} * E[SS^T] \tilde{A}^T \end{aligned} \quad (3-16)$$

$$\text{又 } E[s_i^2] = I \quad (3-17)$$

那麼可以知道訊號源的平均值等於” 0 ”，而且變異數等於” 1 ”；此外，訊號源之間又相互為獨立關係，所以

$$E[SS^T] = I \quad (3-18)$$

那麼

$$\begin{aligned} E[ZZ^T] &= \tilde{A}\tilde{A}^T \\ &= I \end{aligned} \quad (3-19)$$


由以上推導可知經過白化運算後的混合矩陣為一個正交矩陣，這代表我們只要找到相互正交的向量，即可找到 demixing matrix，這可以方便我們簡化整個演算法。

3.5 FastICA

基於統計學中的中央極限定理，如果我們想分出獨立元素出來，可以先找到一個使運算結果最不接近 Gaussian 分佈的矩陣 W ，所以對於矩陣 W 的 Gaussian

分佈程度則需一個量化的測量，通常最典型的測量方法就是利用峰態(Kurtosis)和負熵值 (Neg-Entropy) 這兩個方法[19]。

FastICA 是 Hyvarinen 所提出的，此演算法是利用負熵值當作目標函數來計算非高斯訊號的函數值，設所估測的 $x = w^T z$ ，則可得

$$J(W) \approx \left\{ E \left[G(W^T Z) - E[G(v)] \right] \right\}^2 \quad (3-20)$$

而尋找 $E[G(W^T z)]$ 的極值可以藉由負熵值找到；在 $E[G(w^T z)] = \|w\|^2 = 1$ 的限制下， $E[G(W^T z)]$ 發生極值的 w 得滿足

$$E \left[z G(W^T z) \right] + \beta W = 0 \quad (3-21)$$



上式的 g 為 G 的微分，可以用牛頓法找到滿足 $E[zg(w^T z)] + \beta w = 0$ 的解。令

$E[zg(w^T z)] + \beta w = 0$ 左式等於 F ，那麼其梯度為

$$\frac{dF}{dw} = E \left[ZZ^T G'(W^T Z) \right] + \beta I \quad (3-22)$$

對於經過資料白化後的訊號，則可以近似為：

$$E \left[ZZ^T G'(W^T Z) \right] \quad (3-23)$$

$$\approx E \left[ZZ^T \right] E \left[G'(W^T Z) \right] \quad (3-24)$$

$$= E[G'(W^T Z)]I \quad (3-25)$$

根據牛頓法可以推得下式：

$$w_{new} = w_{old} - \left\{ E[zG(W_{old}^T Z)] + \beta w_{old} \right\} / \left\{ E[G'(W_{old}^T Z)] + \beta \right\} \quad (3-26)$$

$$W_{new} = W_{old} / \|W_{old}\|$$

之後再乘上

$$E[G'(W^T Z)] + \beta$$

可得

$$W_{new} = E[ZG(W_{old}^T Z)] - E[G'(W_{old}^T Z)]W_{old} \quad (3-27)$$

$$W_{new} = W_{old} / \|W_{old}\|$$

其收斂條件為 w 與更新之前方向相同，當超過一個獨立元素時，經過前處理後，在計算 demixing matrix 時，只需找出相互正交的向量，因此在找第 p 個 w 時，須把之前 (p-1) 個找出的 w 方向減去，讓每次計算出來的獨立成分部相同。

$$W_{p_new} = W_{p_old} - \sum_{j=1}^{p-1} (W_{p_old}^T W_j) W_j \quad (3-28)$$

綜合上述討論，將 FastICA 演算法步驟整理於下：

步驟一：將所要處理的資料作置中的運算

步驟二：將置中後的資料白化

步驟三：設定 m 為獨立元素之個數，並設定 counter $p=1$

步驟四：隨機選擇一初始化矩陣 w_p

步驟五： $W_p \leftarrow E[zG(W_p^T Z)] - E[G'(W_p^T Z)]W_p$

$$W_p \leftarrow W_p / \|W_p\|$$

步驟六：資料正交化

$$W_p \leftarrow W_p - \sum_{j=1}^{p-1} (W_p^T W_j) W_j$$

步驟七：設定 $W_p \leftarrow W_p / \|W_p\|$

步驟八：假使 w_p 還沒收斂，則跳回步驟五。

步驟九：設 $p \leftarrow p+1$ ，若 $p < m$ ，則跳回步驟四。



此外，在使用獨立成分分析法時我們需要注意到的是我們無法判斷經過 ICA 運算後結果的順序性，在經過 ICA 演算法後的資料時常因為分離後的不確定性造成後續處理上的一些困擾，但在本論文研究中因為是將經過 FastICA 演算法後所得到的 4 個 component 一同計算其頻率分佈變異數的平均值，所以不會受到 4 個 component 順序的影響，此部分則在下一章節再進一步討論。

3.6 EMG 訊號量測與分析

整個系統建立的主要目的在於分析當人體手臂在不同速度彎曲時，經過 ICA 演算法分析後 EMG 訊號的特徵狀況，分析的方法介紹如下，而圖 3.3 為肌電訊號的分析架構的示意圖，基本上是將透過儀器讀取後的 EMG 訊號，再經過濾波器來做前處理，之後再利用 ICA 演算法做資料的篩選，最後在 frequency domain 做更進一步的分析。

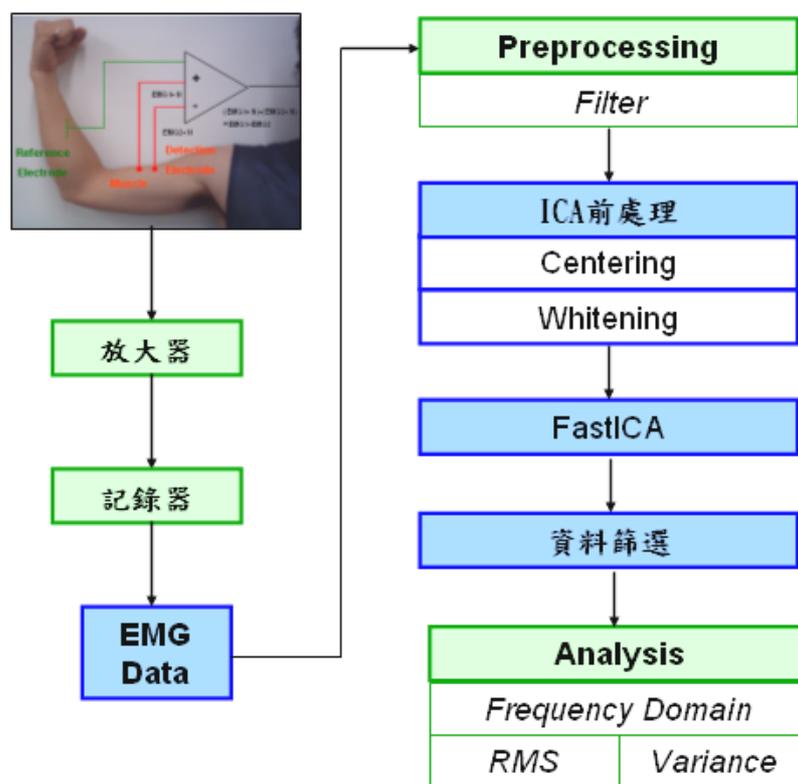


圖 3.3 肌電訊號分析示意圖

3.7 資料量測

我們實驗的內容是以手臂彎曲速度的快慢分類為重點，速度的等級分為快、中、慢三類，分別以約一秒鐘、兩秒鐘，及四秒鐘的速度來完成手肘彎曲的運動，

為增加實驗數據的準確性，在量測訊號前，一些須先準備的前置作業如下：

1. 讓受測者先做適度的休息，以緩和肌肉的緊繃度；
2. 利用磨砂膏去除欲貼置電極處皮膚上的角質；
3. 在手臂上貼置量測電極；
4. 將作為參考點的電極(接地點)黏貼至小腿上；
5. 開啟量測設備及應用軟體；
6. 開始 EMG 訊號的記錄。

3.8 濾波器

實驗中所使用的濾波器部分是採用 iWoks 的分析軟體 LabScribe 內的濾波器工具；由於要避免電線的干擾，所以須先濾掉頻率約 60 Hz 的訊號，帶拒濾波器設定如圖 3.4，低通濾波器的截止頻率設在 59.5Hz，高通濾波器的截止頻率則設為設在 61Hz，以過濾電線的干擾雜訊。

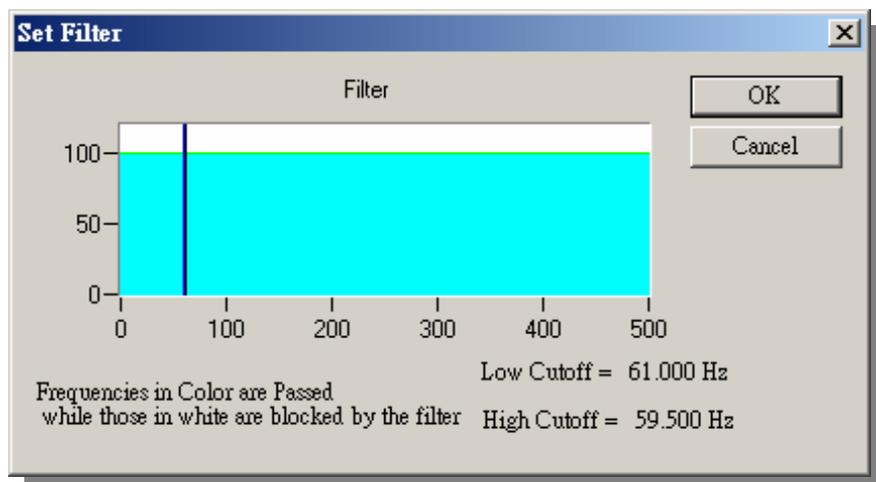


圖 3.4 帶拒濾波器的設定

濾掉約 60 Hz 的電源雜訊干擾訊號後，我們再設定濾波器設定如圖 3.5 所示，利用一帶通濾波器將頻寬限制在約 20Hz~400Hz 之間。

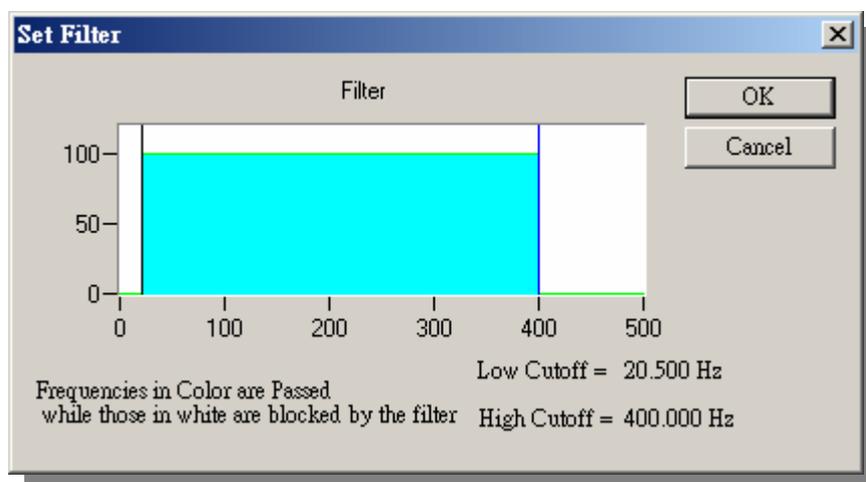
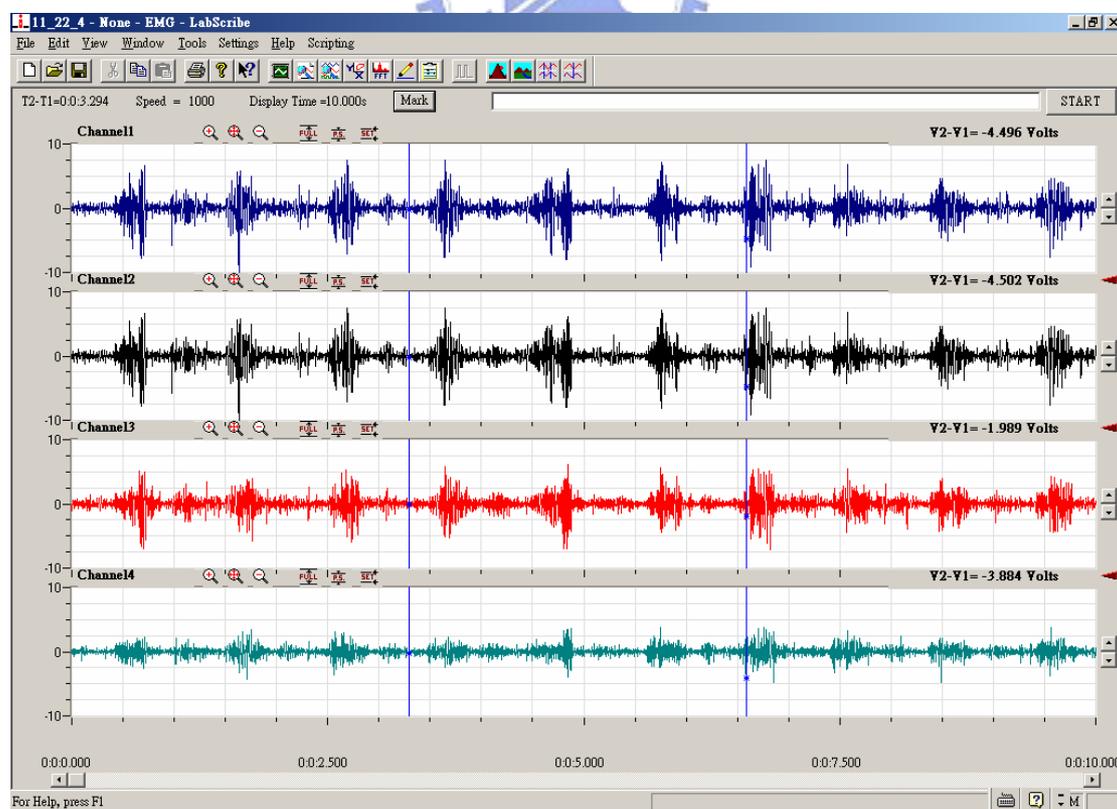
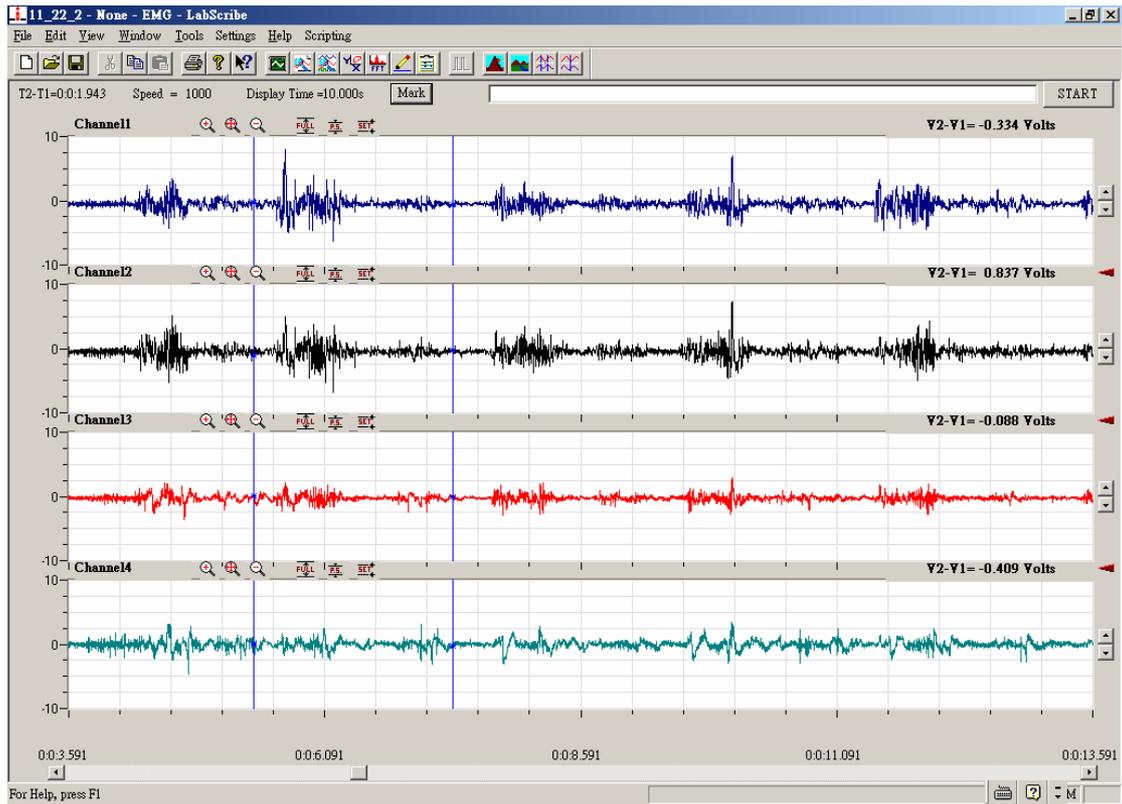


圖 3.5 帶通濾波器的設定

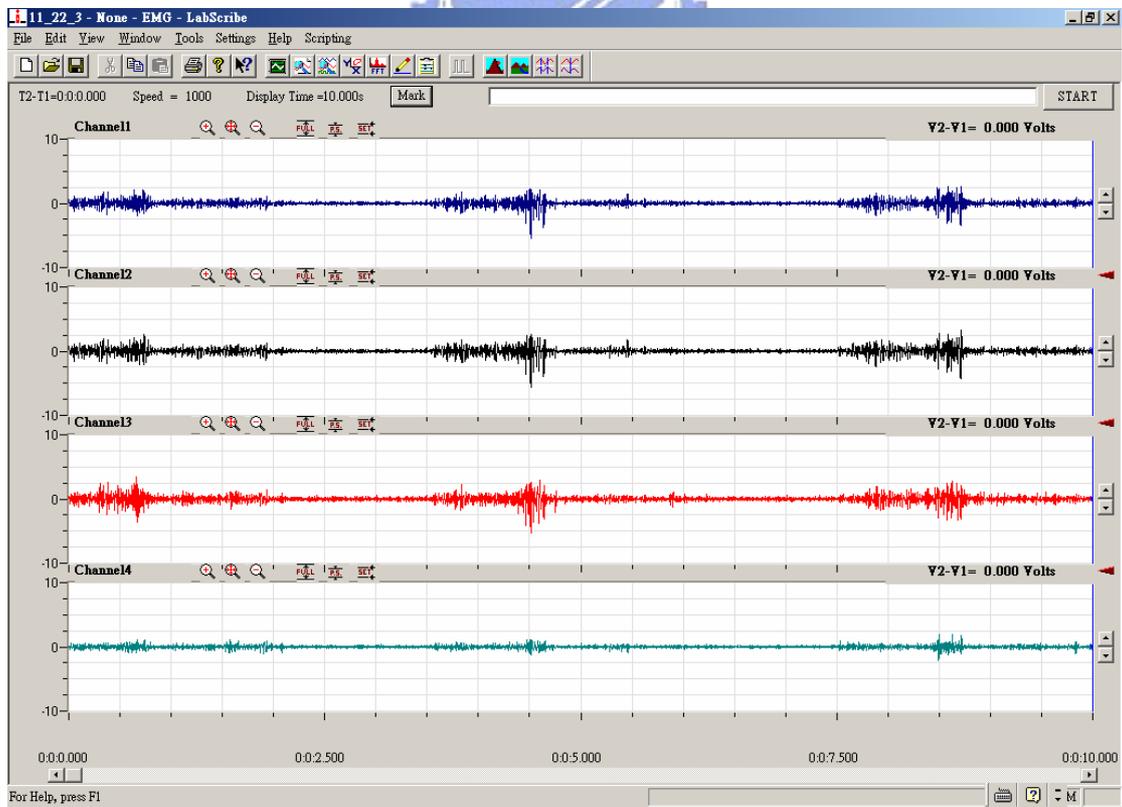
將所存取的 EMG 訊號經過濾波器處理後的資料如圖 3.6，其為三種速度情況下四個通道的連續肌電訊號資料。



(a)手臂運動約 1s



(b) 手臂運動約 2s

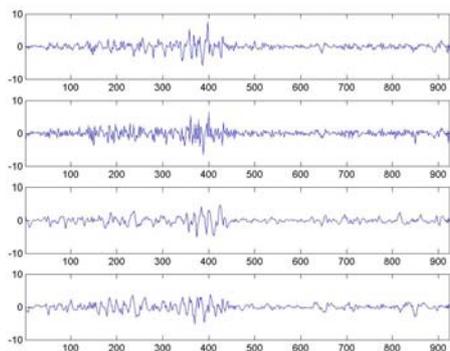


(c) 手臂運動約 4s

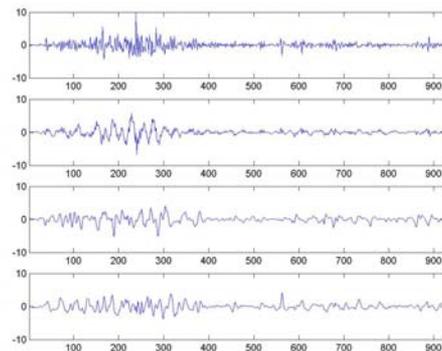
圖 3.6 手臂運動 EMG 訊號：(a) 約 1s (b) 約 2s (c) 約 4s

3.9 FastICA 演算法處理

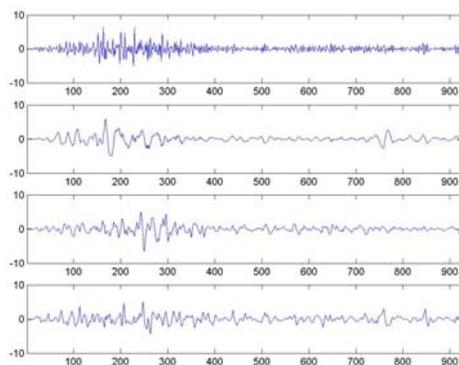
經由前面的分析步驟後得到的資料，我們再將快中慢三種速度下得到的 EMG 訊號作分割，每種速度的資料為 10 筆。以下為 10 筆經過 FastICA 演算法處理以及切割後的手臂快速彎曲運動的訊號：



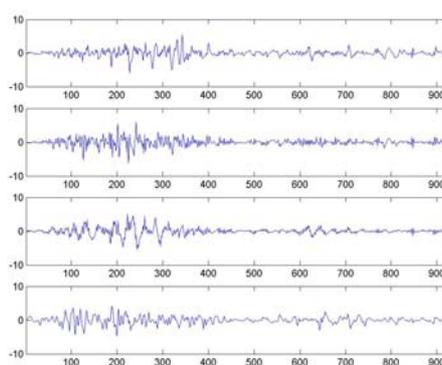
(a) 第 1 筆



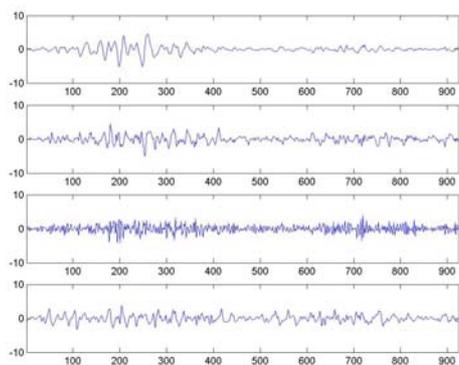
(b) 第 2 筆



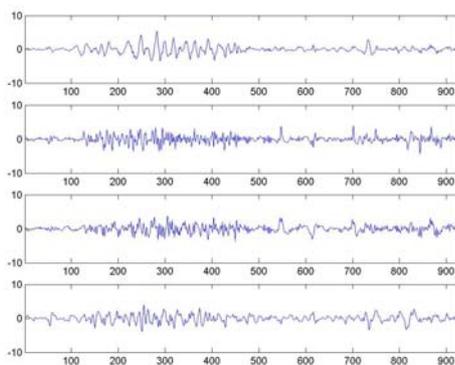
(c) 第 3 筆



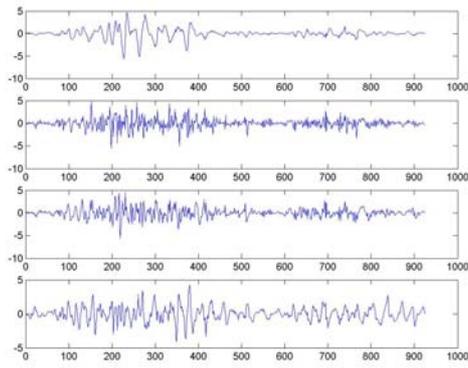
(d) 第 4 筆



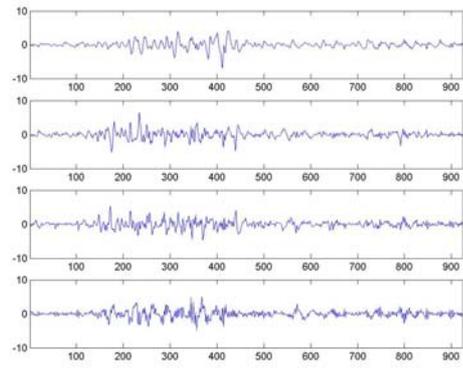
(e) 第 5 筆



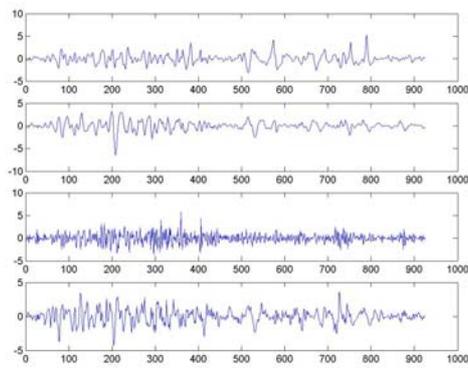
(f) 第 6 筆



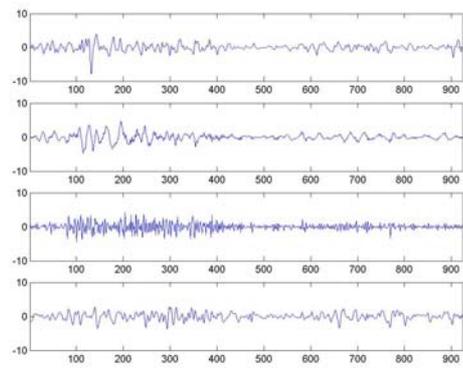
(g) 第 7 筆



(h) 第 8 筆



(i) 第 9 筆

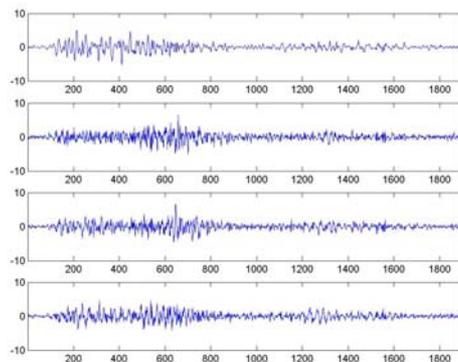


(j) 第 10 筆

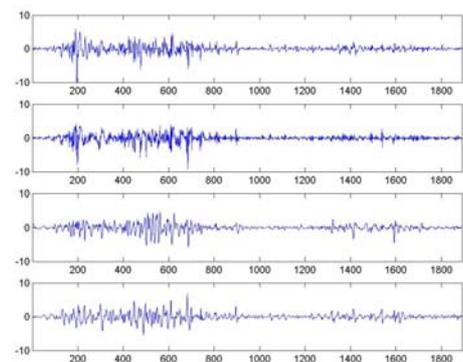


圖 3.7 經過 FastICA 後之快速運動 EMG 訊號：(a)第 1 筆(b)第 2 筆(c)第 3 筆
(d)第 4 筆(e)第 5 筆(g)第 6 筆(g)第 7 筆(h)第 8 筆(i)第 9 筆(j)第 10 筆

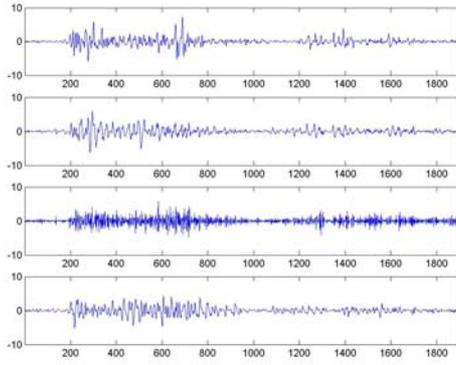
以下為 10 筆經過 FastICA 演算法處理以及切割後的手臂中速彎曲運動的訊號：



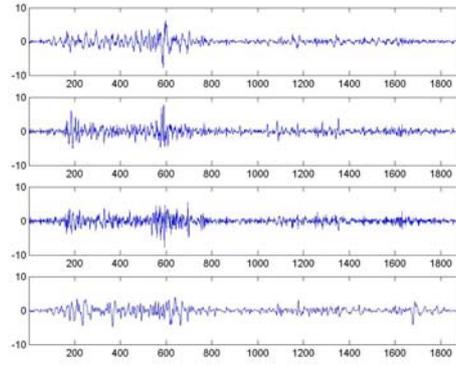
(a) 第 1 筆



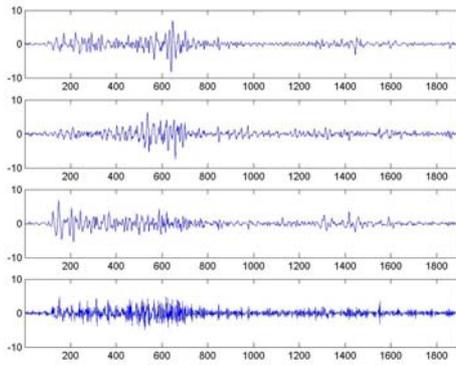
(b) 第 2 筆



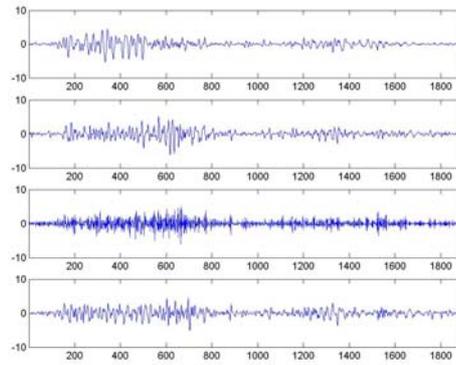
(c) 第3筆



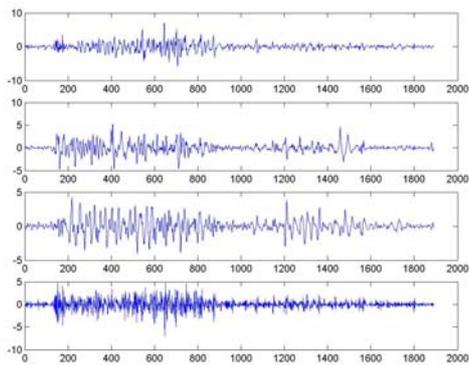
(d) 第4筆



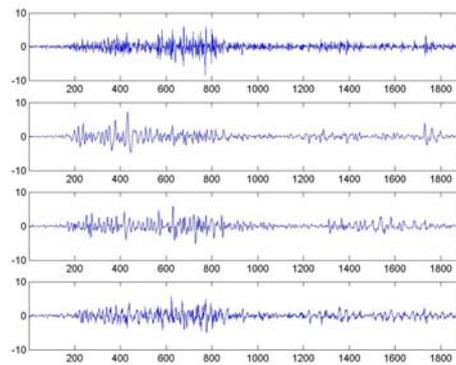
(e) 第5筆



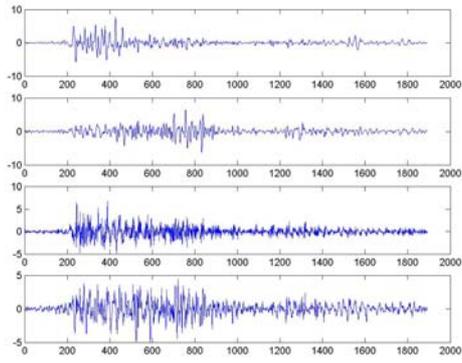
(f) 第6筆



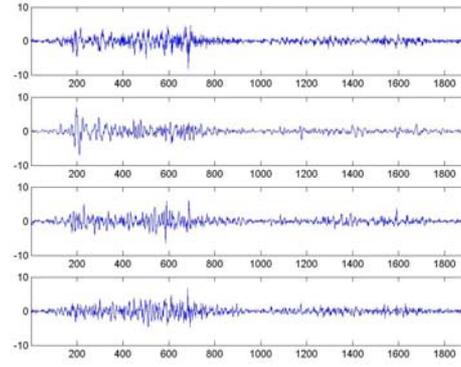
(g) 第7筆



(h) 第8筆



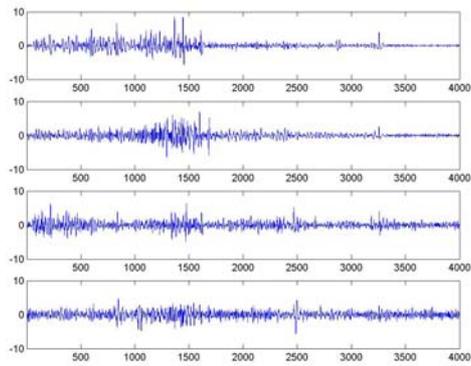
(i) 第 9 筆



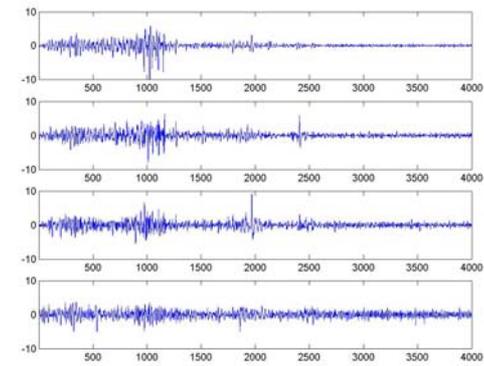
(j) 第 10 筆

圖 3.8 經過 FastICA 後之中速運動 EMG 訊號：(a)第 1 筆(b)第 2 筆(c)第 3 筆
(d)第 4 筆(e)第 5 筆(g)第 6 筆(g)第 7 筆(h)第 8 筆(i)第 9 筆(j)第 10 筆

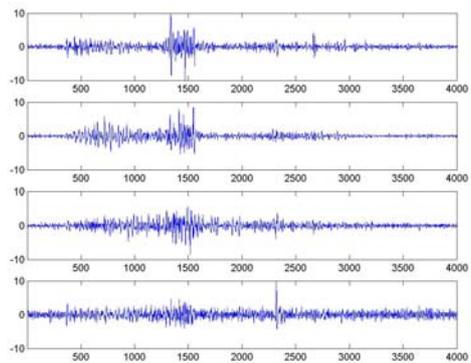
以下為 10 筆經過 FastICA 演算法處理以及切割後的手臂慢速彎曲運動的訊號：



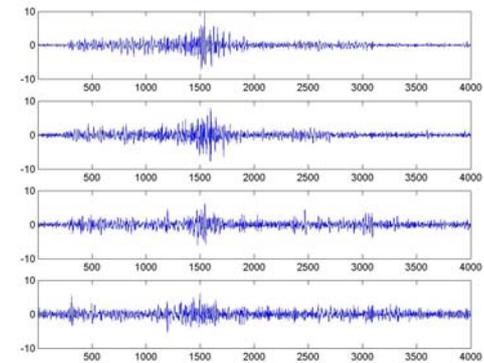
(a) 第 1 筆



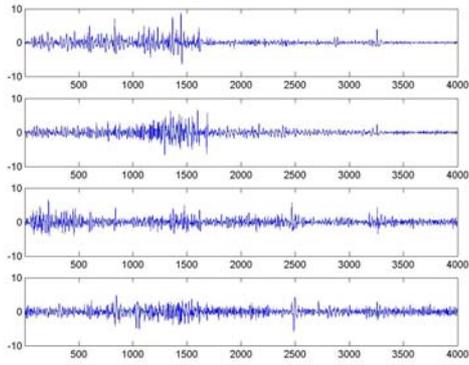
(b) 第 2 筆



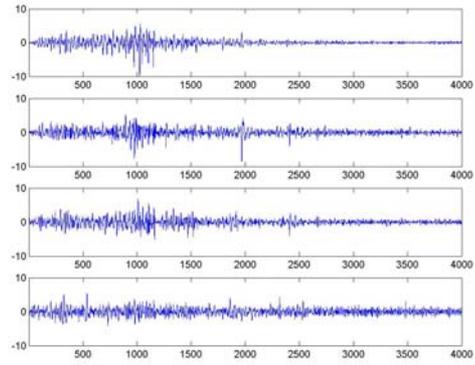
(c) 第 3 筆



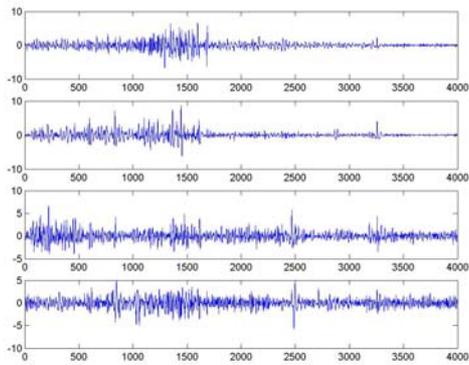
(d) 第 4 筆



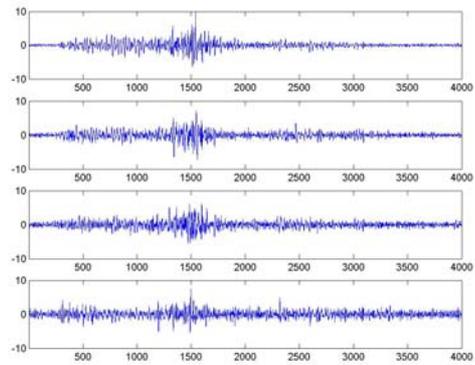
(e) 第 5 筆



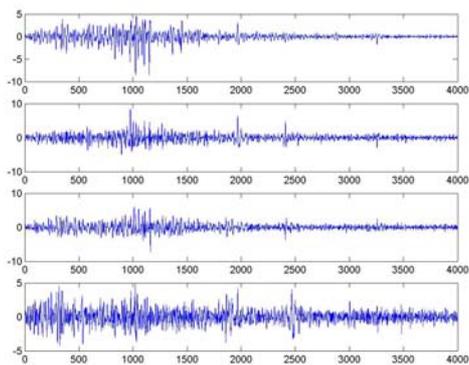
(f) 第 6 筆



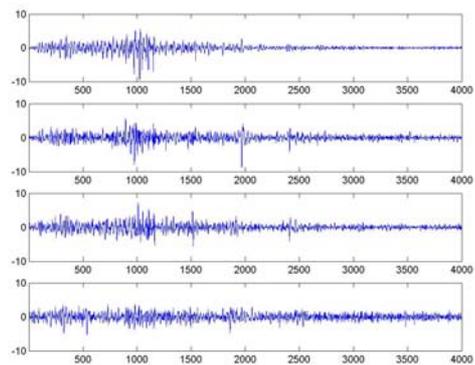
(g) 第 7 筆



(h) 第 8 筆



(i) 第 9 筆



(j) 第 10 筆

圖 3.9 經過 FastICA 後之慢速運動 EMG 訊號：(a)第 1 筆(b)第 2 筆(c)第 3 筆
(d)第 4 筆(e)第 5 筆(g)第 6 筆(g)第 7 筆(h)第 8 筆(i)第 9 筆(j)第 10 筆

3.10 資料篩選

在我們收集到的資料中，一定會存在一些受到外在因素影響到的資料，此時應該盡量刪除這些資料，以利之後的分析，而選擇淘汰資料的作法一般都是去比較資料彼此間的相關性。經過 FastICA 處理過後的 EMG 訊號，由於考慮到可能因為訊號在時域上有相位差的關係，使得在比較彼此間的相關係數時容易造成影響，所以我們將訊號轉到頻域來比較其相關性。首先我們將在三種速度運動情況下的訊號分別在頻域彼此相互比對，以圖 3.10(a) 為例，縱座標與橫座標代表 10 筆經過 FastICA 處理後 40 筆獨立成分的編號，其所對應的顏色區塊則代表的是其兩筆資料之間的相關性，若相關性較低的資料則可以予以淘汰並更換一筆新的資料，如第 5 筆獨立成分其其它資料相較下相關性皆趨近於 0，故可以予以更換；而圖 3.10 為比較後的結果；其中圖 3.10(a) 為快速運動情況下的相關係數圖；圖 3.10(b) 為中速運動情況下的相關係數圖；圖 3.10(c) 為慢速運動情況下的相關係數圖：

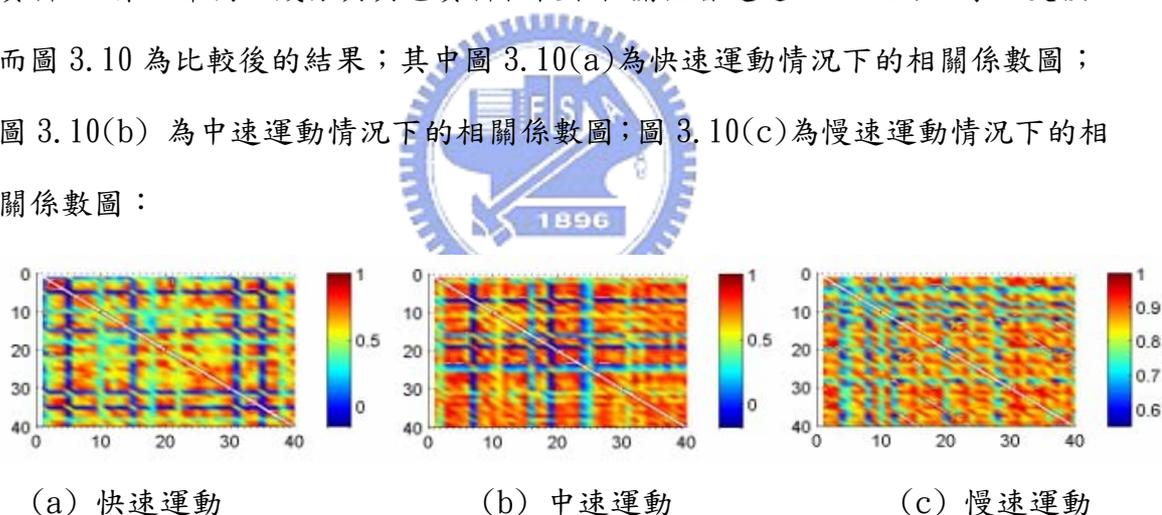


圖 3.10 將經過 FastICA 後的資料在 frequency domain 比較其相關性：
(a) 快速運動(b) 中速運動(c) 慢速運動

從圖 3.10 可以很明顯看出有些資料在互相比較後，其顏色分佈偏向藍色，代表其相關係數都很低，所以我們可以予以淘汰，並補進新的資料。更新後資料頻域的分析如圖 3.11 所示，其顏色分佈多偏向紅色，可以確定每筆資料都有一定的相關性。

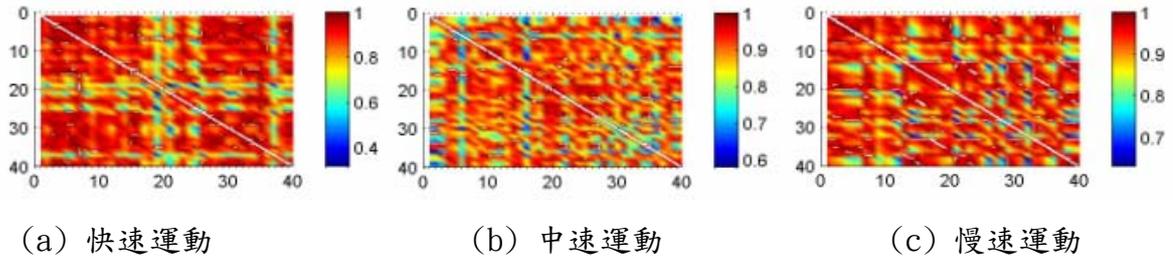


圖 3.11 經過更新後的資料在頻域的相關係數圖：(a) 快速運動(b) 中速運動(c) 慢速運動

另外，圖 3.12 為訊號未經過 FastICA 演算法在頻域的相關係數比較圖，可以發現沒有經過 FastICA 演算法的資料比較難去辨別那些是比較重要的資料。

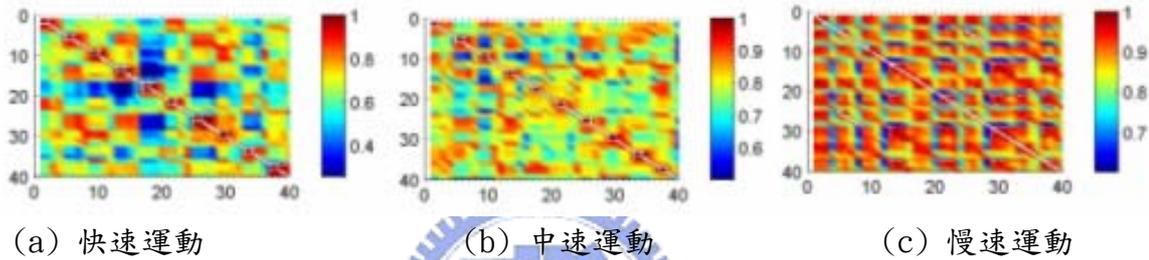


圖 3.12 未經過 FastICA 後的資料在頻域比較其相關性：(a) 快速運動(b) 中速運動(c) 慢速運動

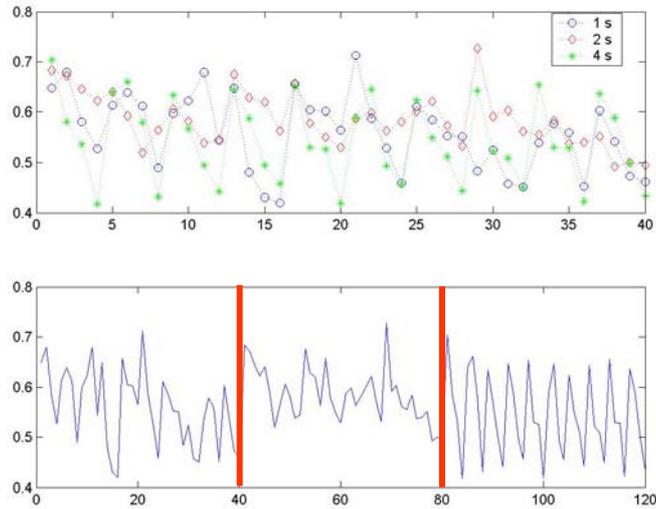
3.11 資料分析

經過篩選後的資料，我們再做更進一步的分析。我們對經過 FastICA 演算法的訊號分別比較其四種情況下的差異，圖 13~圖 16 為分析結果，縱座標為分析數值，而橫座標為 30 筆肌電訊號經過 FastICA 處理後的 120 個獨立成分編號。

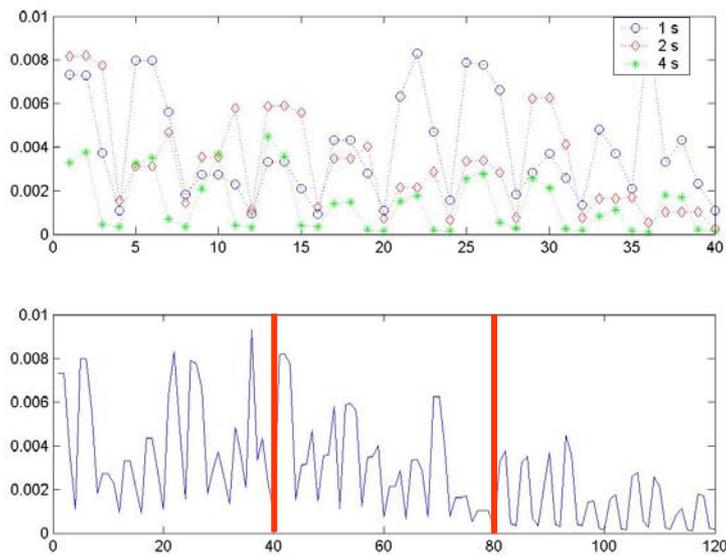
1. 在時域上取 IEMG，再比較其變異數：

圖 3.13(a) 為 EMG 訊號在經過 FastICA 處理後，再做 IEMG 處理後其變異數的分佈圖，上圖為將三種狀況的分佈圖疊合起來一同比較，而下圖則是將三種情況的分佈圖攤開相互分別比較。我們可以明顯發現手臂在快、中、慢三種速度狀況下，其變異數有很大不同的分佈趨勢；而在圖 3.13(b) 中，可以發現未經過

FastICA 階段處理的訊號只有在快速運動的狀態有明顯的不同，至於在中速度與慢速度彎曲的情況下，比較難發現有特別的不同。



(a) EMG 訊號做 IEMG 處理後其變異數的分佈圖

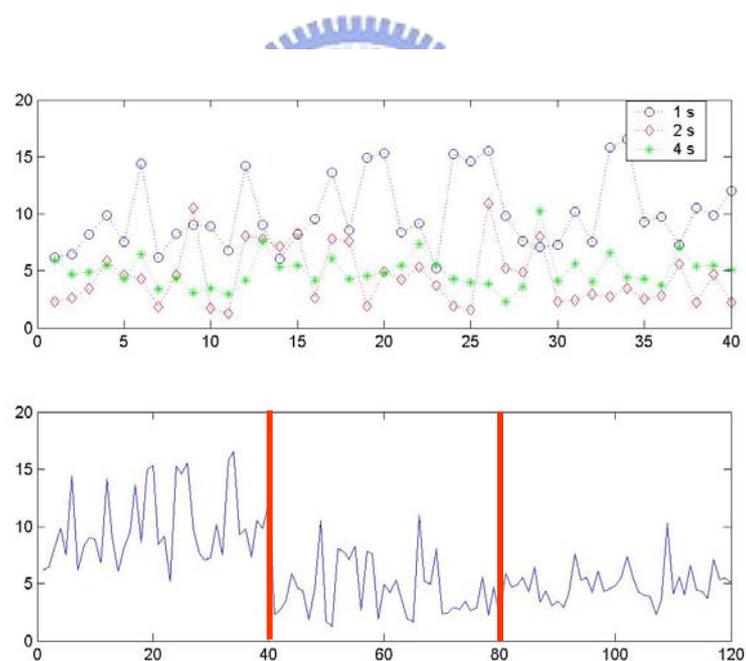


(b) 未經過 FastICA 的 EMG 訊號做 IEMG 處理後其變異數的分佈圖

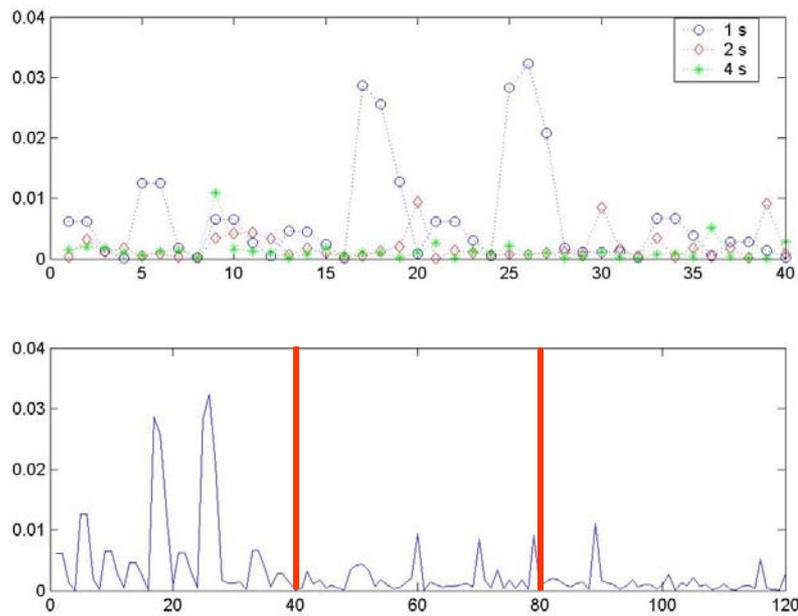
圖 3.13 (a) EMG 訊號做 IEMG 處理後其變異數的分佈圖(b) 未經過 FastICA 的 EMG 訊號做 IEMG 處理後其變異數的分佈圖

2. 經過 FastICA 處理後，在頻域比較其變異數分佈：

圖 3.14(a) 為 EMG 訊號經過 FastICA 處理後，比較其在頻域上的頻譜分佈圖，上圖為將三種狀況的分佈圖疊合起來一同比較，而下圖則是將三種情況的分佈圖攤開相互分別比較。可以發現隨著手臂運動速度的減緩，其頻譜變異數的變化量逐漸變小；至於在圖 3.14(b) 中，可以確定未經過 FastICA 階段處理的訊號只有在快速運動的狀態有明顯的變化，而在中速度與慢速兩種情況情況下，數值幾乎接近於零。



(a) FastICA 處理後，在頻域變異數的分佈圖



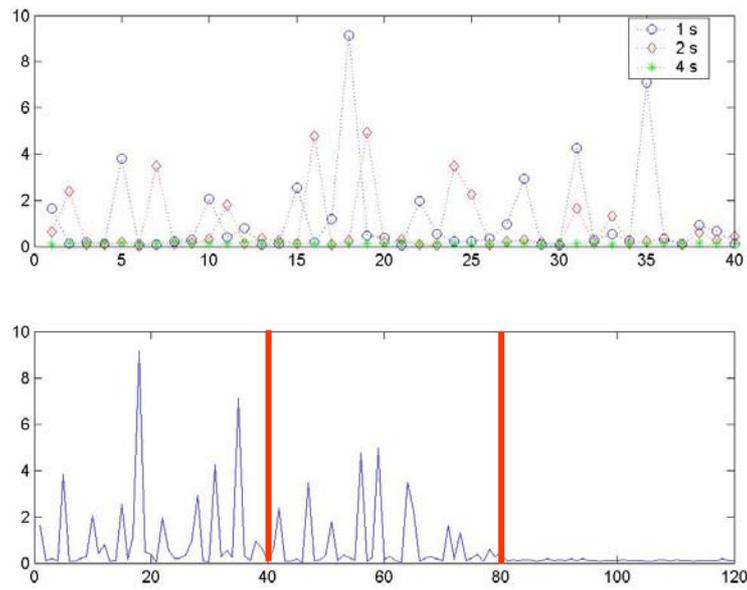
(b) 未經過FastICA處理，在頻域變異數的分佈圖

圖 3.14(a) FastICA 處理後，在頻域變異數的分佈圖(b) 未經過 FastICA 處理，在頻域變異數的分佈圖

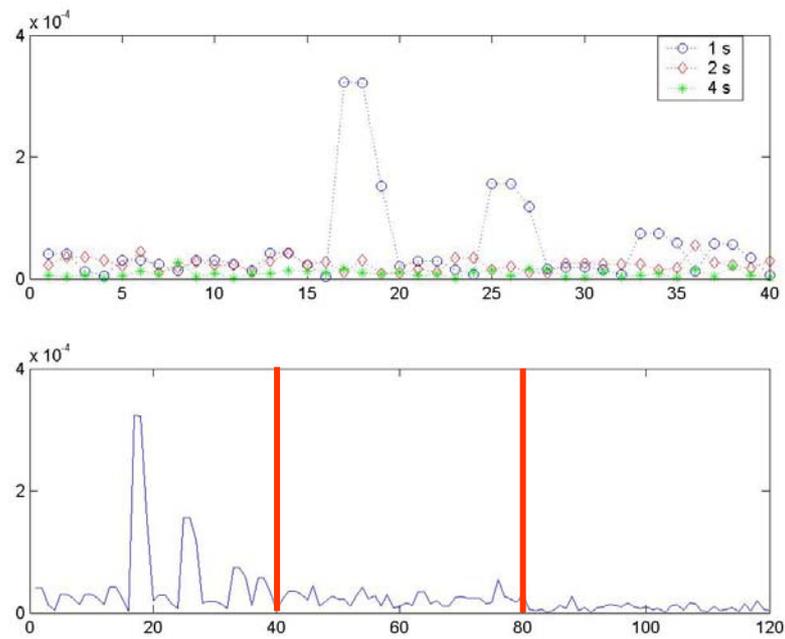


3. 經過 FastICA 處理以及訊號微分後在頻域比較其變異數分佈：

圖 3.15(a) 為 EMG 訊號經過 FastICA 處理以及訊號微分後，比較其在頻域上的頻譜分佈圖，上圖為將三種狀況的分佈圖疊合起來一同比較，而下圖則是將三種情況的分佈圖攤開相互分別比較。在圖中可以發現手臂在隨著手臂運動速度的減緩，其頻譜變異數的變化量以及分別在三種情況下其變異數的平均值逐漸變小；而在圖 3.15(b) 中，可以發現未經過 FastICA 階段處理的訊號在中速度與慢速度運動的狀態之下，數值幾乎接近於零，只有在快速度運動時有較明顯的變化。



(a) 經過 FastICA 及訊號微分，在頻域的變異數分佈圖

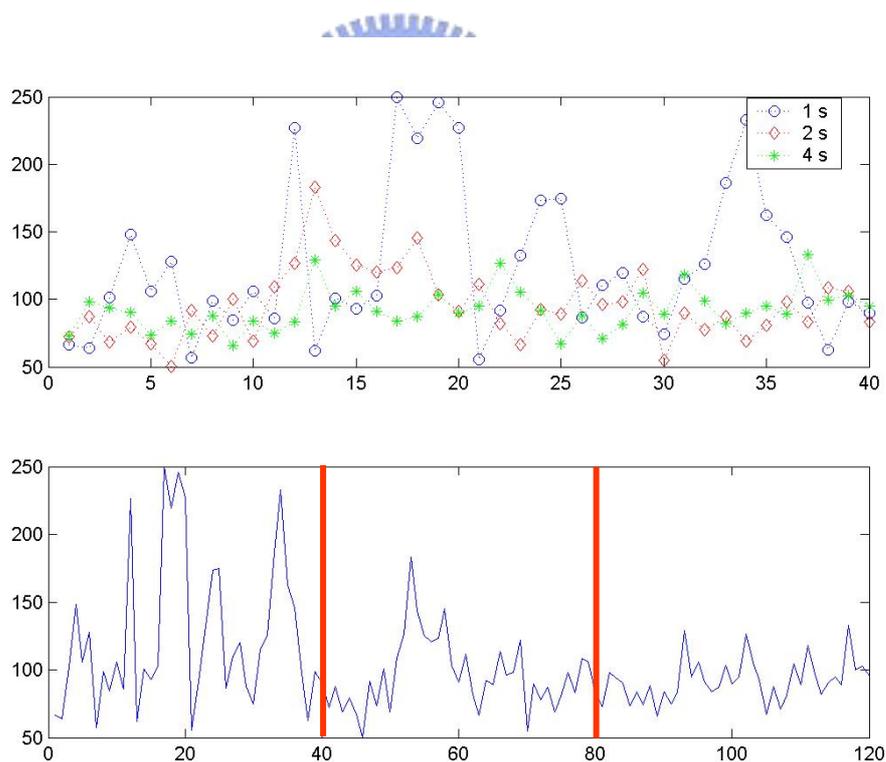


(b) 未經過 FastICA 在頻域的變異數分佈圖

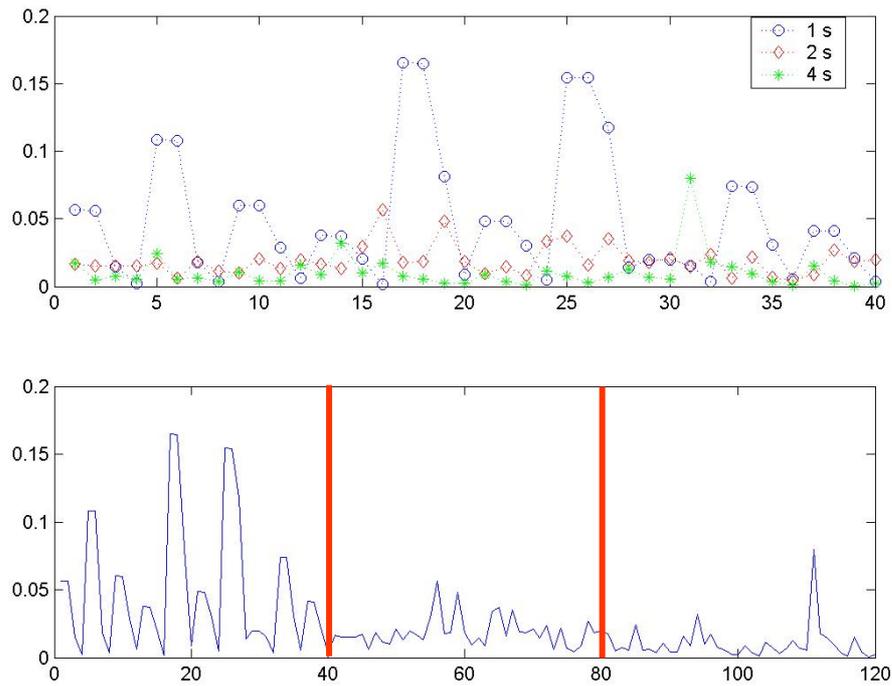
圖 3.15 (a)經過 FastICA 及訊號微分在頻域的變異數分佈圖(b)未經過 FastICA 在頻域的變異數分佈圖

4. 經過 FastICA 以及取 IEMG 後在頻域比較其變異數分佈：

圖 3.16(a) 為 EMG 訊號經過 FastICA 以及 IEMG 處理後，比較其在頻域上的頻譜分佈圖，上圖為將三種狀況的分佈圖疊合起來一同比較，而下圖則是將三種情況的分佈圖攤開相互分別比較。在圖中可以發現其分佈類似於圖 3.16(a)，隨著手臂運動速度的減緩，頻譜變異數的變化範圍逐漸變小；而在圖 3.16(b) 中，可以發現只有在快速度運動時有較明顯的變化，在中速度與慢速度運動的狀態之下，數值一樣幾乎接近於零。



(a) 經 FastICA 及取 IEMG 後在頻域的變異數分佈圖



(b) 未經過FastICA 在頻域的變異數分佈圖

圖 3.16(a) 經 FastICA 及取 IEMG 後在頻域的變異數分佈圖 (b) 未經過 FastICA 在頻域的變異數分佈圖

從上述四種分析，可以發現經由 FastICA 處理後的訊號可以明顯的分辨出手臂在快中慢三種速度情況下彎曲運動時 EMG 訊號有其明顯的特徵；基於此分析，可以完成一以 FastICA 為基礎，且可以分辨出手臂在快、中、慢三種速度情況下彎曲運動的分類器，分類器的完成則於下一個章節討論。