

第二章

基於 EMG 之機器臂定位系統

文獻中探討提及許多使用 EMG 訊號來操控復健裝置或多功能義肢的研究，一般而言其系統架構可分為四個部分：訊號量測、訊號處理、分類器設計以及裝置控制，我們的系統也是基於這種架構基礎而建立，本論文的分類器是利用類神經網路達到期望效果，而系統方塊圖如圖 2.1 所示。在訊號量測部分會透過 EMG 訊號量測系統來擷取原始的 EMG 訊號，將之傳送到電腦端進行下一步的訊號處理，此處理步驟主要為了濾除雜訊，並透過特徵擷取來分析 EMG 訊號的特性，接著以特徵處理後的 EMG 訊號與手臂彎曲的角度做為類神經網路的輸入，經過訓練完成的類神經網路，我們可以得到控制機器臂的角度，使機器臂跟隨著操控者做出相對應的運動，操控者可利用視覺回饋來評估機器臂的活動狀況，進而決定下一步動作，透過這樣的系統便能夠根據操控者的意圖靈活操控機器臂。

為了建構出完整的系統，我們必須先了解每個環節背後的原理與方法，首先訊號量測時要了解運動時所使用的肌肉或肌群，以期將電極安置在正確的位置，此部份將於 2.1 節詳細討論，而手臂角度的測量將在 2.2 節討論，藉由電極收集的 EMG 訊號含有許多雜訊，因而必須知道量測時伴隨發生的雜訊，以期做出正確的 EMG 訊號判讀，並針對不同雜訊設計適合的濾波器設計，濾波後的 EMG 訊號將經由特徵擷取來分析 EMG，觀察其隨著不同運動所伴隨發生的變化狀況，此部分將在 2.3 節討論，最後根據不同運動所表現出來的特徵變化輸入到類神經網路來決定機器手臂的運動，此部份將在 2.4 節予以討論，而機器臂的控制部分我們將在第三章介紹。




圖 2.1 基於肌電圖機器臂控制系統示意圖

2.1 肌電訊號量測

使用電極量測 EMG 訊號時有些人以方便性為考量，因而使用環狀式的主動電極，將多通道的電極擺放在固定肌群上來量測 EMG 訊號[31]，再利用 ICA 來找出通道中訊號較為獨立的部分，然而此多通道的方式卻同時增加分析處理時的計算量，基於減少電極數的目的，肌肉訊號量測前最重要的工作不外乎就是認識手臂肌肉的構造、功能以及分佈，如此才能依照工作的目標來確定電極所必須安置的位置。在大部分的病患當中通常是屬於上肢受損或截肢，因此第一章提及的文獻大部分的目的在於辨識手、腕及肘關節的移動，像是手肘彎曲／伸直，手腕旋前／反掌，手腕外展／內收，手部打開／關閉等動作，本論文主要是針對肘關節的運動，因此我們將針對移動前臂的肌肉來討論 [32]。移動前臂的肌肉分為四類，分別是負責前臂屈曲、伸展、旋前及旋後（各動作的定義如圖 2.2）的屈肌、伸肌、旋前肌及旋後肌，屈肌的部分計有肱二頭肌（*Biceps brachii*）、肱肌（*Brachialis*）及肱橈肌（*Brachioradialis*），其肌肉的位置如圖 2.3；伸肌的部分有肱三頭肌（*Triceps*）及肘肌（*Anconeus*），其肌肉的位置如圖 2.4；旋前肌的部分有旋前方肌（*Pronator quadratus*）及旋前圓肌（*Pronator*），而旋前方肌屬於深肌，其肌肉的位置如圖 2.5；旋後肌的部分有肱二頭肌（*Biceps brachii*）及旋後肌（*Supinator*），而旋後肌是屬於深肌，其肌肉的位置如圖 2.6 所示。探討肌肉

與運動的關係之後，接下來將討論實際量測肌肉訊號時的考量，包括肌肉的選取以及電極位置的考量。

雖然每一個動作的完成可能都是由數條肌肉共同完成，但是在實際的 EMG 訊號量測時並不是將所有相關的肌肉都當成量測的對象，必須考慮到肌肉面積的大小以及位置等因素，因為這些因素都可能影響 EMG 訊號的量測，甚至可能會造成訊號量測時不必要的困擾，比如說考量手肘的屈曲跟伸展，根據前述資料，手肘的屈曲應該是由屈肌來負責，也就是肱二頭肌（Biceps brachii）、肱肌（Brachialis）及肱橈肌（Brachioradialis），而伸展的部分應該是由伸肌負責，也就是肱三頭肌（Triceps）及肘肌（Anconeus），但是由於下列三個原因：

- (1) 肱肌的肌肉面積太小，剛好又位於主要肌肉（肱二頭肌）的旁邊，除了有位置不易找尋之虞，所量測到的訊號易受肱二頭肌 EMG 的影響，即所謂的 crosstalk；
- (2) 肱橈肌和肱肌比起來，雖然肌肉面積較為廣大，但根據實驗的結果，由肱二頭肌已經足夠判斷前臂的屈曲動作；
- (3) 肘肌的肌肉面積太小，有位置不易找尋之虞，且根據實驗，肱三頭肌已經足夠判斷前臂的伸展動作，

綜合上述原因，最後只選擇對肱二頭肌（Biceps brachii）進行量測，除了肌取量測的肌肉之外，我們仍需考慮電極在肌肉上的位置，因為在同一條肌肉上，不同的電極位置，所收集到的 EMG 訊號仍存在著相當的差異性[2]，為了收集到正確且有意義的 EMG 訊號，肌肉中點為最恰當的電極位置[33]，因此我們必須將電極安置在肌肉的中點。




圖 2.2 前臂四種動作的定義[33]




圖 2.3 屈肌位置圖[33]




圖 2.4 伸肌位置圖[33]




圖 2.5 旋前肌位置圖[33]





圖 2.6 旋後肌位置圖[33]

2.2 手臂角度量測

爲了正確測量出手臂在空間中的角度變化，我們分別再手臂上三個地方(手腕 S3、手肘彎曲處 S2 以及肱二頭肌 S1)放置感測器如圖 2.7 所示，在每次取樣時同時紀錄三點在空間的絕對座標，如此即可計算出此時手臂的彎曲角度，計算過程詳細說明如下。



(a)手臂運動前

(b)手臂運動後

圖 2.7 手臂運動與角度關係圖: (a)手臂運動前(b)手臂運動後

在取樣之前：

$$\vec{V}_1 = S_1 - S_2 \quad (2.1)$$

$$\vec{V}_2 = S_3 - S_2 \quad (2.2)$$

由餘弦定理可得：

$$\cos \theta = \frac{\vec{v}_1 * \vec{v}_2}{|\vec{v}_1| * |\vec{v}_2|} \quad (2.3)$$

推得 (2.4)

$$\theta = \cos^{-1} \left(\frac{\vec{v}_1 * \vec{v}_2}{|\vec{v}_1| * |\vec{v}_2|} \right)$$

如此即可得到目前手臂的角度，再搭配先前所測量的 EMG 訊號，就可得到 EMG 與角度在時間上的關係。

2.3 訊號處理

透過上一節所介紹的電極安置考量，我們得以將電極安置在正確的位置，並透過 EMG 量測設備擷取出 EMG 訊號，然而擷取出的訊號摻雜了許多雜訊，因此常造成判讀上的困難，爲了能夠針對量測結果作正確的判讀，我們有必要了解原始的 EMG 訊號以及受雜訊干擾的 EMG 訊號圖形，並提出適當的解決方案，圖 2.8 所示爲乾淨的 EMG 訊號以及幾種常出現的錯誤訊號與雜訊干擾，如 ECG 的 crosstalk、電源線輻射干擾（60Hz）、直流偏移、運動造成的雜訊、放大器的電壓飽和。ECG 即所謂的心電圖，當量測的肌肉位置接近心臟時，ECG 的 crosstalk 則相對明顯，只要選擇離心臟較遠或是身體右半邊的肌肉來量測（如右手的肌肉），即可降低 ECG crosstalk 的影響，另外計算平均值也能達到降低 ECG crosstalk 影響的效果。導線輻射干擾的頻率約爲 60Hz，理論上可透過帶拒濾波器的設計來濾除雜訊，[29,30]便是使用這種方式，然而有其他的研究者[2]考慮 EMG 訊號的頻率分布特性，其最強的訊號頻率約在 50~150Hz，帶拒濾波器的使用也相對的引起 EMG 訊號失真，因此不建議使用帶拒濾波器來解決這方面的問題。針對直流偏移與電壓飽和的問題，可靠著實驗前調整直流準位以及增益來避免錯誤的訊號發生。運動造成的雜訊主要有兩個來源，一個是手臂運動時造成的電極的滑動甚至脫落，另一個則是電極的導線晃動，這兩種雜訊的頻率分布範圍約在 0~20Hz，不包含 EMG 的重要資訊，因此可設計一高通濾波來解決這部分的問題。確定訊號擷取的正確性之後，我們將進一步完成訊號處理的步驟，此步驟包括濾波器設計以及特徵擷取，在濾波器設計部份，將針對雜訊以及 EMG 訊號的頻寬來設計適合的濾波器，然後擷取經過濾波處理後 EMG 訊號特徵，藉由特徵來分析 EMG 的特性。




圖 2.8 乾淨之 EMG 訊號以及常出現的錯誤與雜訊干擾 [8]

濾波器的設計上，針對 EMG 訊號的頻帶分布 (0-500Hz)，其中主要的頻寬為 50-150Hz，因而必須設計一帶通濾波器，而針對移動時所造成電極滑動極導線晃動 (0-20Hz)，則必須設計高通濾波器，特別注意的是，我們沒有針對電磁波干擾而使用帶拒濾波器，綜合以上討論，我們設計了一六階的 Butterworth 帶通濾波器，其通過頻率與截止頻率分別為 20Hz 與 400Hz。

在特徵的擷取上，我們使用了傳統上經常使用的四種特徵，MAV [1,3,15,26]、VAR[9,14,20,25]、ZC[1,9,14,20]、以及 WAMP[14,20]，對於每個特徵，我們選取適當數量的取樣點來計算其特徵值，並說明每個特徵所代表的意義，在之後的系統分析我們將進一步評估每種特徵在起始點偵測時的性能，特徵值計算公式及如表 2.1。其中 X_k 代表第 k 個取樣點的 EMG 值， N 代表取樣點數目。每個特徵值都有其特殊的意義，藉由對特徵值得觀察，我們便可大致看出特定時間曲段內的 EMG 訊號的收縮程度，以及在時域以及頻域上的特性，特徵值的意義說明如下。

表 2.1 特徵值計算公式

<p>1. MAV (Mean Absolute Value)</p> $MAV = \frac{1}{N} \sum_{k=1}^N X_k $	<p>3. BZC (Bias Zero-Crossing)</p> $BZC = \sum_{k=1}^N \text{sgn}[(X_k - 0.4) \times (X_{k-1} - 0.4)]$ $\text{sgn}(x) = \begin{cases} 1, & \text{if } x > 0 \\ 0, & \text{others} \end{cases}$
<p>2. VAR (Variance)</p> $VAR = \frac{1}{N-1} \sum_{k=1}^N X_k^2$	<p>4. WAMP (Willison Amplitude)</p> $WAMP = \sum_{k=1}^N f(X_k - X_{k-1});$ $f(x) = \begin{cases} 1, & \text{if } x > \text{threshold} \\ 0, & \text{if otherwise} \end{cases}$

在表 2.1 中，MAV 將 N 個取樣點取絕對值後相加再做平均，此參數類似於對能量的估測，VAR 則是取平方相加後再平均，此參數可看出 EMG 訊號的能量密度，MAV 與 VAR 同樣經常被用來估測肌肉收縮的程度，並依據特徵值大小作為不同速度的義肢控制。BZC 參考[14]針對 ZC 所做的修正，主要用來計算與零值交越的次數多寡，可大致看出在頻率的特性，當特徵值越大則代表此時間區段的頻率越高，其中引入一個 0.4 的偏移量，主要是針對肌肉未收縮時，背景雜訊使得 EMG 值在零值附近跳動，零值交越次數因而累積，以致無法區分出放鬆狀態與運動狀態，利用此偏移植修正可避免因雜訊干擾所造成的錯誤，此偏移量可視情況不同而彈性的調整，WAMP 用來計算出超越某一臨界值的次數，類似於 ZC 值的變形，可藉此了解肌肉收縮的程度。

由於 MAV 在對於肌肉的收縮上有顯著的表現，因此在以上這麼多特徵值中我們選擇了 MAV 來當處理 EMG 訊號的特徵值，其 window 寬度為 200，EMG 經過了特徵處理後，再輸入到類神經網路。

2.4 類神經網路設計

在傳統的類神經網路上，大致上可以分為兩種，一種是監督式神經網路 (supervised learning)，此種神經網路包括 MLP (Multilayer Perceptron) 和 RBF (Radial Basis Function) 等，其特色為網路的訓練演算法是由屬於錯誤更正學習法則的倒傳遞演算法 (backpropagation algorithm) 來訓練網路的鍵結值，使得神經網路輸出會趨於期望輸出值。而另一種是非監督式神經網路 (unsupervised learning)，像是 SOM (Self-Organizing Map)、適應共振理論 (Adaptive Resonance Theory) 以及學習向量量化類神經網路 (learning vector quantization) 等，屬於非監督式神經網路，其特色為能自行發掘出資料中哪些特徵是重要的或是可忽略的以便將資料作群聚 (clustering) 的處理。因此非監督式神經網路常被用來作為前處理單元，以便萃取

出資料的特徵，再配合監督式學習法，可完成複雜的圖樣辨別。

考慮到 EMG 訊號的特性，以及希望可以利用類神經網路自行發掘出資料中哪些特徵是重要的或是可忽略，以利將資料作群聚的處理，因此我們需要非監督式類神經網路來處理 EMG 達到分類以及學習的效果。在 SOM 以及其他的非監督式類神經網路在處理映射(Mapping)時，它們必須要有短暫記憶(short-term memory)的機制，才能短暫的儲存之前的輸入以及輸出向量的資訊，Barreto 提出了以 Self-Organizing Map (SOM)當作主體的 Vector-Quantized Temporal Associative Memory (VQTAM) 網路結構[10]，其中將神經元當中的鍵結值分成兩個部份 W^{in} 與 W^{out} ，而 W^{in} 與 W^{out} 也代表著在網路學習的過程中，在同一個神經元內負責儲存先前的輸入以及輸出向量，利用此種方法的好處是由於網路是利用 SOM 為主要的架構，因此在訓練過程中不像傳統的 MLP 或 RBF 網路需要那麼多的訓練時間，同時所訓練出來的結果可以像 MLP 或 RBF 般的準確。圖 2.9 為此神經網路神經元裡面鍵結值的關係圖，在圖 2.9 中我們可以清楚的看到在一個神經元中，會有兩個向量分別對輸入以及輸出向量去做運算，在本篇論文中輸入向量 $X^{in}(n)$ 為經過取 MAV 特徵值的 EMG 訊號，而輸出向量 $X^{out}(n)$ 手臂的角度。




圖 2.9 神經元當中鍵結值的關係圖

神經元數目上我們設定為 101 個，在訓練的過程中，必須計算以 $X^{in}(n)$ 為基準以最小歐基里德距離所計算得勝的神經元 j^*

$$j^* = \arg \min \|x^{in}(n) - W_j^{in}(n)\| \quad , \quad j = 1, 2, \dots, n \quad (2.5)$$

並用輸入向量 $X^{in}(n)$ 以及輸出向量 $X^{out}(n)$ 調整鍵結值向量

$$W_j^{in}(n+1) = W_j^{in}(n) + \eta(n)\pi_{j,j^*}(n)(x^{in}(n) - W_j^{in}(n)) \quad (2.6)$$

$$W_j^{out}(n+1) = W_j^{out}(n) + \eta(n)\pi_{j,j^*}(n)(x^{out}(n) - W_j^{out}(n)) \quad (2.7)$$

其中學習率 $\eta(n)$ 我們設為:

$$\eta(n) = 0.7 * \exp(-time/40) \quad , \quad \text{其中 time 為訓練次數} \quad (2.8)$$

而 π_{j,j^*} 為鄰近區域函數，用來調整得勝神經元周遭的神經元被影響的程度

$$\pi_{j,j^*}(n) = \exp\left(-\frac{d_{j,j^*}^2}{2\sigma^2}\right) \quad (2.9)$$

其中鄰近區域有效寬度 $\sigma = ((N/2) * \exp(-time/35))^2$ ，其中 N 為神經元個數

$$d_{j,j^*} = (r_j(n) - r_{j^*}(n)) \quad (2.10)$$

而 $r_j(n)$ 為第 j 個神經元在 output array 上的位置， $r_{j^*}(n)$ 為得勝神經元在 output array 上的位置，而類神經網路的輸出為經由 EMG 所算出的手臂角度 y 為:

$$y = W_{j^*}^{out} \quad (2.11)$$

由以上的式子，可知道 VQTAM 是先找出得勝的神經元，再利用期望輸出值去調整 W_j^{out} ，就可以得到一組完整的鍵結值實現一個即時的控制系統。在訓練神經網路時，利用 EMG 來找出得勝神經元並調整 W_j^{in} ，而空間中手臂彎曲的角度為輸出期望值是用來調整 W_j^{out} ，有了這些資訊，即可利用這些資訊來訓練類神經網路的參數。一開始我們同步測量 EMG 與空間中手臂位置的資訊，手臂角度停留在 30，90 與 150 度以及其對應的 EMG 如圖 2.10，在測量資訊時，手臂動作不能太迅速，因為在手臂上升時，若是太迅速，反而 EMG 所測量到的值會太少，對於訓練類神經網路的效果並不好，因為我們需要在手臂上升時 EMG 的資訊，才能有更多的資料來訓練神經網路，而同時我們也必須多測量一些在固定角度時

的資料，使得神經網路知道在固定位置時的 EMG，如此才能讓類神經網路有訓練出能讓 EMG 訊號控制機械臂定位。




圖 2.10 手臂在空間中運動的角度與 EMG 在同一時間所對應的關係

在訓練時，取連續 20 點 EMG 的值對應一個輸出，由於 EMG 的非線性與時變的特性，因此我們必須用連續好幾個點來對應一個輸出，也可以說是當 EMG 產生出這樣的趨勢，此時對應的角度應該是多少來讓神經網路學習。圖 2.11 為一真實手臂角度與訓練角度的比較例子，由此圖我們可以觀察到 EMG 經由神經網路的訓練後，所得到的角度與實際的角度相差不大，因此 EMG 可以做為定位機械手臂的訊號。




圖 2.11 真實手臂角度與訓練角度的比較結果
(紅色為實際手臂動作的角度，藍色為神經網路訓練的結果)