

基於腦波基準線校正之過動症亞型分類

黃鈺嶽¹ 劉益宏² 李春穎³

¹ 國立臺北科技大學 機電整合所

E-mail: j72435231@gmail.com

² 國立臺灣科技大學 機械工程系

E-mail: lyh@mail.ntust.edu.tw

³ 國立臺北科技大學 機械工程系

E-mail: leech@mail.ntut.edu.tw

摘要

本論文明機器學習演算法對注意力不足過動症(Attention-Deficit/Hyperactivity Disorder, ADHD)的腦波訊號進行分類，ADHD 為一種兒童神經發育障礙，目前全世界約有 5-8% 的兒童被診斷出患有 ADHD。本論文提出使用複雜度特徵的多尺度熵(Multiscale entropy, MSE)以及頻域特徵的頻譜功率(Spectral Power, SP)這兩種特徵方法搭配基準線校正(Baseline Correction)後利用機器學習技術分析 ADHD 亞型(ADHD-I 和 ADHD-C)與 HC 的腦電圖(Electroencephalography, EEG)。

本論文記錄下四種實驗流程(EO-Resting、EC-Resting、MA Task、MOT Task)的腦波資料，並使用 MSE 以及 SP 作為特徵，經過基準線校正之後再利用費雪準則(Fisher's Criterion)做特徵篩選，最後進行基準線校正前後的分類結果比較，結果顯示，基準線校正組合 MA-EC 的分類效果較其他組合好，且經過基準線校正之後，其分類率有所提升，對於 ADHD-I 與 ADHD-C 的分類率可以達到 86.49%，使用 8 個特徵。

關鍵詞：過動症、腦波、腦機介面、多尺度熵、頻譜功率

Abstract

This study uses machine learning algorithms to classify the brainwave signals of attention-deficit/hyperactivity disorder (ADHD), ADHD is a neurodevelopmental disorder of childhood. About 5–8% of children are diagnosis of ADHD worldwide. This study proposes a method to using the multiscale entropy (MSE) of the complexity feature and the spectral power (SP) of the frequency domain feature, these two feature methods are combined with baseline correction (BC) and using machine learning technology to analyze the ADHD subtypes (ADHD-I and ADHD-C) and healthy control (HC) by

Electroencephalography (EEG).

This study records the EEG data of four experimental procedures (EO-Resting, EC-Resting, MA Task, MOT Task), and uses MSE and SP as features. After baseline correction, fisher's criterion is used for feature selection, and finally used LDA for classification. This study compares the classification results with/without baseline correction. The results show that the classification effect of the baseline correction combination MA-EC is better than other combinations, and after the baseline correction, its classification rate has increased, and the classification rate for ADHD-I and ADHD-C can reach 86.49 % (8 features).

Keywords : ADHD, EEG, Brain Computer Interface, Multiscale Entropy, Spectral Power

1. 前言

注意力不足過動症 (Attention-Deficit/Hyperactivity Disorder, ADHD) 為一種神經發育障礙，目前全世界約有 5-8% 的兒童被診斷出患有 ADHD[1]，並且男孩的確診人數是女孩的 2.3 倍。目前 ADHD 的診斷標準依據精神疾病診斷與統計手冊第 5 版(Diagnostic and Statistical Manual of Mental Disorders, DSM-5)[2]，ADHD 又分為三種類型：

1. 注意力不足型(Inattentive type, ADHD-I)
2. 過動 / 衝動型 (Hyperactive/Impulsive type, ADHD-H)
3. 混合型(Combined type, ADHD-C)

依據 DSM-5 的標準，ADHD-C 的症狀包含 ADHD-I 以及 ADHD-H，這使得在臨床上做明確且有效的區分時較不容易，雖然對於 ADHD 腦波研究的論文相當多，但針對 ADHD 亞型做分類的腦波研究非常少，本論文希望藉由使用腦電圖來區分 ADHD 的亞型，並期盼能夠建立一套評估系統以提供醫師做為輔助診斷使用，由於 ADHD-H 的受試者較少，因此本論文僅針對 ADHD-I 與 ADHD-C。

在 2020 年的研究結果顯示[12]，結合使用兒童

行為檢查表(Child Behavior Checklist, CBCL)分數、綜合視覺聽覺測試(Integrated Visual and Auditory test, IVA)分數和腦電圖的頻域特徵這三種方法後可以用來區分 ADHD 亞型，偵測率分別為，健康受試者(Healthy Control, HC): 100%、ADHD-C: 80.41%、ADHD-I: 84.17%、ADHD-H: 71.46%。另外，有多項研究表明非線性特徵可以區分 ADHD 孩童與健康孩童，在2016年的一項研究中[11]，該研究使用碎形維度(Fractal Dimension)、近似熵(Approximate Entropy)、李亞普諾夫指數(Lyapunov Exponent)，並且分類率可以達到93.65%，其分析的 ADHD 孩童包含三種類型；2020的研究中[6]，該研究使用多種類的特徵進行分析，而最後使用非線性特徵的分類率最高(86.4%)，其次是頻域特徵(80.44%)，因此本論文將使用的特徵鎖定在非線性特徵以及頻域特徵。

即使在先前的研究中已經證明非線性特徵對於 ADHD 的分類是有效的，但非線性特徵有許多種，在2020年的研究顯示[10]熵對於分析 ADHD(包含三種亞型)與 HC 是可靠的一項生物標記，其結果可達到99.58%的分類率，但是該研究在特徵使用上包含多種熵(Shannon entropy、Sample entropy、Dispersion entropy、Multiscale entropy)。另外，在2016年的研究[7]指出，多尺度熵(Multiscale entropy, MSE)可能是辨識 ADHD 的新指標。

由於過往文獻皆使用在單一放鬆狀態或是任務下的腦波進行分析，而本論文認為 ADHD 孩童的注意力較差，因此在任務與休息狀態間的能量轉換可能與健康孩童有所差異，因此本論文在進行特徵抽取之後加入基準線校正(Baseline Correction, BC)，希望藉此觀察到 ADHD 亞型在任務與休息狀態間的能量轉換差異，最後本論文選用 MSE 與頻譜功率(Spectral Power, SP)這兩種特徵作為特徵抽取方法，本論文認為可以藉由結合這兩種在複雜度(MSE)以及頻域(SP)上的特徵所提供之訊息來分類 ADHD-I vs. HC、ADHD-C vs. HC 以及 ADHD-I vs. ADHD-C，並且期望在搭配基準線校正之後能夠得到更好的分類結果。

2. 實驗對象

本論文共收集57位男性孩童受試者的腦波資料，年齡層為8-15歲，其中22位為 ADHD-I，15位為 ADHD-C，20位為 HC。

受試者皆經由臺北馬偕紀念醫院兒童神經科主治醫師陳慧如醫師和臺北馬偕紀念醫院精神醫學部主治醫師黃郁心醫師兩位醫師各自評估後轉介，並於臺北馬偕紀念醫院完成實驗流程。

表 1. 受試者資料統計

年齡層 (8~15 歲)		人數	年齡	p-value
			平均±標準差	
ADHD-I vs. HC	ADHD-I	22	10.82 ± 1.87	0.501
	HC	20	11.2 ± 1.66	
ADHD-C vs. HC	ADHD-C	15	10.4 ± 1.74	0.1894
	HC	20	11.2 ± 1.66	
ADHD-I vs. ADHD-C	ADHD-I	22	10.82 ± 1.87	0.5094
	ADHD-C	15	10.4 ± 1.74	

2.1. 實驗設計

本實驗流程共有四個階段，分別為張眼放鬆(Eye-open Resting)、閉眼放鬆(Eye-close Resting)、心算任務(Mental Arithmetic Task)、多物件追蹤任務(Multiple Object Tracking Task)，在每一階段完成後皆有15秒的休息時間讓受試者進行準備。

A. 張眼放鬆 (EO-Resting)

第一個階段為張眼放鬆，實驗開始時會請受試者靜坐在椅子上，螢幕正中央會出現一個黑色十字架的圖片，此時受試者需要保持放鬆狀態並看著螢幕上的黑色十字架，持續時間為150秒。

B. 閉眼放鬆 (EC-Resting)

第二個階段為閉眼放鬆，實驗開始時會請受試者靜坐在椅子上，螢幕上會出現「請閉眼」三個字提示受試者，此時受試者需要保持放鬆狀態並閉著眼睛，持續時間為150秒，在結束時會有提示音提醒受試者。

C. 心算任務 (MA Task)

第三個階段為心算任務，螢幕畫面在一開始時會出現一道加法之數學題目請受試者心算，心算完後會請受試者按下空白鍵，之後畫面會切換成一個數字請受試者將此數字與剛剛心算的答案比大小，若心算完的數字大於畫面上的數字就按下方向鍵的右鍵，相等則按方向鍵的下鍵，小於按下方向鍵的左鍵，完成後便繼續進行下一題心算，持續時間為150秒，如圖1所示。

D. 多物件追蹤任務 (MOT Task)

第四個階段為多物件追蹤，螢幕畫面在一開始時會出現3顆綠色的球以及5顆黑色的球，共八顆靜止的球且彼此不重疊，0.5秒後3顆綠球會變成黑色，此時畫面中會有8顆黑球隨機移動且不重疊持續8秒，時間到之後8顆黑球會停下，此時會請受試者用滑鼠點選出一開始的3顆綠球，選完後便開始進行下一題，總共有15題，如圖2所示。




圖1 心算任務




圖2 多物件追蹤任務

2.2. 資料紀錄

腦波訊號資料收集儀器使用 Neuroscan 公司所開發的 32-channel 電極帽與 40-channel 放大器，並且施打 19 顆電極(Fp1、Fp2、F3、F4、F7、F8、T3、T4、C3、C4、T5、T6、P3、P4、Fz、Cz、Pz、O1、O2)，如圖 3 所示。參考電極為 GND，並與(A1+A2)/2 進行 re-reference 以避免市電干擾，以 500Hz 之取樣頻率來收錄受試者之腦波，並且每顆電極的阻抗在 10kΩ 以下後便會開始進行實驗，電極帽之電極位置是依照國際 10-20 系統所配置。

實驗環境需保持在安靜無干擾的空間，並依照受試者體型微調螢幕或椅子位置，螢幕使用 20 吋液晶螢幕，受試者眼睛與螢幕需保持水平高度，讓受試者可以平視螢幕畫面，同時距離保持約在 60 公分左右，確保實驗過程中不會對眼睛造成太大負擔，產生疲倦感。

收錄下來的腦波資料會依序進行以下處理：

1. 使用帶通濾波器，頻率範圍：0.5~50Hz
2. 使用陷波濾波器，過濾臺灣市電頻率，頻率範圍：60Hz
3. 使用 Scan4.5 去除眼動訊號

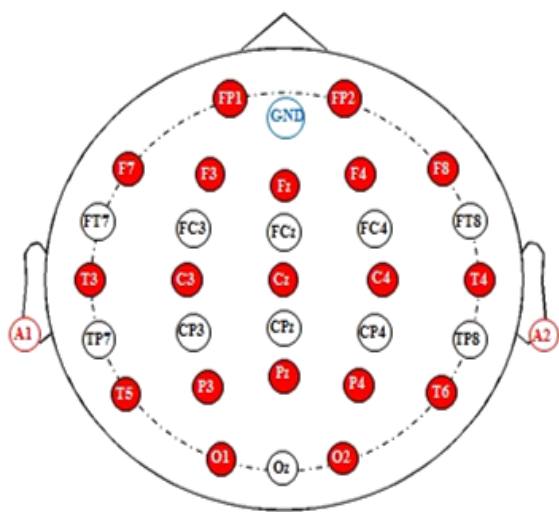


圖 2 國際 10-20 系統之電極分布

2.3. 資料分析

本論文所使用的特徵為 MSE 以及 SP，並在經過基準線校正後，使用費雪準則進行特徵篩選以及排序，並且將排序後的特徵依照特徵遞增準則(Add-one-feature-in strategy, AOFI)加入資料中進行分類，最後分類器使用線性鑑別分析，並搭配使用留一個體驗證(Leave-One-subject-Out Cross Validation, LOSOCV)來驗證分類器。

1. 多尺度熵(Multiscale Entropy, MSE)

多尺度熵是藉由計算不同時間尺度下的樣本熵(Sample Entropy)來量化訊號的複雜度，在 2005 年時提出，而樣本熵是近似熵的修改。

給定一時間序列 $X = \{x_1, x_2, \dots, x_N\}$ 和尺度因子 (Scale Factor) τ ，接下來經由公式(1.1)將原本的時間序列重新計算為連續不重疊的時間序列 $\{y^{(\tau)}\}$ ，此過程稱為粗粒化(Coarse-Grained)，當尺度 $\tau=1$ 時即為原始的時間序列，進行完粗粒化之後便可以對每一個尺度因子下的時間序列計算樣本熵， $MSE(\tau = 1)$ 表示，在 $\tau = 1$ 時的 MSE 值。

$$y_j^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} x_i, 1 \leq j \leq \frac{N}{\tau} \quad (1.1)$$

2. 頻譜功率(Spectral Power, SP)

頻譜功率為利用離散傅立葉轉換(Discrete Fourier Transform, DFT)將腦波資料由時間域資料轉換到頻率域資料，假設腦波訊號 $x(t)$ 為一連續時間 t 的函式，公式(2.1)所示。

$$X(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (2.1)$$

但由於腦波訊號的擷取是屬於離散資料，因此，需將公式(2.1)修改為離散傅立葉轉換，公式(2.2)所示。

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-\frac{j2\pi kn}{N}} \quad (2.2)$$

$x[n]$ 為離散腦波訊號的第 n 個資料點， N 為輸入訊號的資料長度， X 為 x 所計算的頻譜(Spectrum)，而 $X[k]$ 的 k 為第 k 個頻率點的頻譜，而 $k = 0, 1, 2, \dots, N-1$ 。得到 $X[k]$ 後即可計算功率頻譜密度(Power Spectral Density, PSD)，公式(2.3)所示。

$$PSD_k = |X[k]|^2 \quad (2.3)$$

PSD_k 即為我們在第 k 個頻率點下的功率值，而頻率點間的時間距可利用頻率解析度(Frequency resolution)得知，公式(2.4)所示。

$$F_r = \frac{f_s}{N} \quad (2.4)$$

公式(2.4)中，等號左邊的 F_r 為頻率解析度， f_s 為取樣頻率， N 為輸入訊號的資料長度。接著將感興趣的頻帶加總，則可得到頻譜功率，如公式(2.5)所示。

$$SP_{\omega^*} = \sum_{\omega^*} PSD_k \quad (2.5)$$

上列公式中， ω^* 為感興趣的頻帶，而 BP_{ω^*} 即為 ω^* 頻帶下的頻譜功率，本論文所感興趣的頻帶如表 2 所示。

表 2 感興趣頻帶範圍

頻帶	範圍
delta band	1~4 Hz
theta band	4~8 Hz
alpha band	8~13 Hz
beta band	13~30 Hz
gamma band	30~45 Hz

計算完每顆電極在不同頻帶下的帶功率後，本論文再將該頻譜功率值除以分析頻帶範圍之頻譜功率總值，即為相對功率(Relative Power, RP)，如公式(2.6 所示)。

$$RP_{\omega^*} = \frac{BP_{\omega^*}}{BP_{1\sim 45\text{ Hz}}} \quad (2.6)$$

SP(delta)表示 delta 頻帶的頻譜功率，RP(delta)表示 delta 頻帶的相對功率。

3. 基準線校正(Baseline Correction)

由於每位受測者的基準線不同，因此這種方法的目的在於使用休息的狀態作為基準，並對每位受測者的心算任務或多物件追蹤任務進行校正，從而得到每位受測者在放鬆狀態到心算或是多物件追蹤狀態下的腦波能量轉換差異，其公式如公式(3.1)所示。

$$\text{Baseline Correction} = \frac{\text{Task-Rest}}{\text{Rest}} \quad (3.1)$$

其中 Task 為特徵抽取之後的任務狀態之腦波資料，可以是 MA Task 或是 MOT Task，Rest 為特徵抽取之後的放鬆狀態之腦波資料，可以是 EO-Resting 或是 EC-Resting。因此在本論文中，進行基準線校正之後可以組合出四種組合，分別是 EO-MA、EC-MA、EO-MOT、EC-MOT。

4. 費雪準則(Fisher Criterion)

費雪準則是一種維度縮減方法，經由計算組間散佈(Between-class scatter)與組內散佈(Within-class scatter)之比值得到費雪值(Fisher Score, F-score)，可藉由此值判斷該特徵是否具有鑑別力，費雪值的公式如下所示， S_B ：組間散佈， S_W ：組內散佈，F-score(f)：第 f 個維度的費雪值。

$$\text{F-score}(f) = \frac{S_B(f)}{S_W(f)}, f = 1, 2, 3, \dots, d \quad (4)$$

通常希望特徵的組內散佈越小越好，組間散佈越大越好，也就是費雪值越大越好，表示該特徵是具有鑑別力的特徵。為避免小樣本問題，我們會對費雪值進行排序(由高到低排列)，並選出前 d 個特徵， d 為兩類別人數總和-1

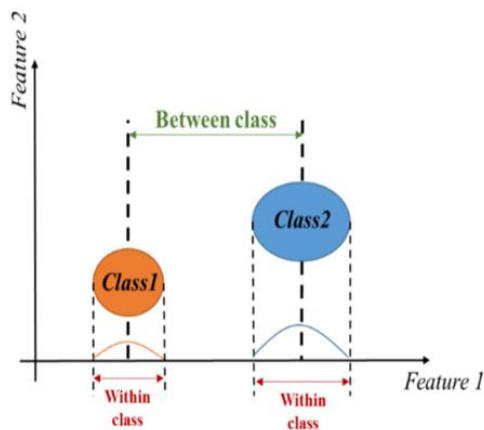


圖 3 組間散佈與組內散佈示意圖

5. 線性鑑別分析(Linear Discriminant Analysis, LDA)

線性鑑別分析有以下兩種假設：1.假設兩類別的資料屬於常態分佈(Normal Distribution)。2.假設兩類別的資料有共同之共變異矩陣(Covariance Matrix)。

對於二類別的分類，線性鑑別分析之決策函數如公式(5.1)所示：

$$D_{LDA}(x) = (\mu_1 - \mu_2)^T \Sigma^{-1} x - \frac{1}{2} (\mu_1 - \mu_2)^T \Sigma^{-1} (\mu_1 + \mu_2) - \ln \left(\frac{C_{12}\pi_2}{C_{21}\pi_1} \right) \quad (5.1)$$

公式(5.1)中， x 為測試資料， μ_1 與 μ_2 分別為第一類別與第二類別訓練資料的平均向量， Σ 為兩類別的共變異矩陣(Common Covariance Matrix)，且 $\Sigma = \pi_1 \Sigma_1 + \pi_2 \Sigma_2$ ，其中 Σ_1 和 Σ_2 分別為第一類別與第二類別之共變異矩陣，而 π_1 與 π_2 分別為第一類別與第二類別之事前機率(Prior probability)，即 $\pi_1 = \frac{n_1}{n_1+n_2}$ 、 $\pi_2 = \frac{n_2}{n_1+n_2}$ ， n_1 與 n_2 分別為第一類別與第二類別的訓練資料個數。

C_{12} 為將第一類別資料判為第二類別的錯誤權重， C_{21} 為將第二類別資料判為第一類別的錯誤權重。將一筆測試資料 x 帶入決策函數公式(5.1)時，若得到之決策值大於零，則該筆測試資料就會被判為第一類別，反之當得到的決策值小於零時，則該筆測試資料就會被判為第二類別。




圖 4 C_{12} 與 C_{21} 關係示意圖

由圖 4 可知，圖中的紅線為線性鑑別分析的決策平面，綠線為 $C_{12} > C_{21}$ 的決策平面，當 C_{12} 越大，則代表越重視第一類別，橘線為 $C_{12} < C_{21}$ 的決策平面，當 C_{21} 越大，則代表越重視第二類別。

3. 結果與討論

本論文目的在於利用腦波訊號並透過機器學習演算法區分出 ADHD-I vs. HC、ADHD-C vs. HC 及 ADHD-I vs. ADHD-C。

在未經過基準線校正的情況下，三種類別之中最高分類率為 ADHD-I vs. ADHD-C 在 EO 的狀態下達到 75.68%，使用 1 個特徵。

如表 3 所示，分類率後面的括弧內的數字表示達到最高分類率所需要使用的特徵數量，ADHD-I vs. HC 的最高分類率為多物件追蹤任務的 69.05%，並且使用 2 個特徵，ADHD-C vs. HC 的最高分類率為閉眼放鬆的 74.29%，使用 1 個特徵，ADHD-I vs. ADHD-C 的最高分類率為張眼放鬆的 75.68%，使用 1 個特徵。表 4 為每種類別達到最高分類率所使用的特徵。

表 3 未做基準線校正之最高分類率

實驗 流程	類別	ADHD-I	ADHD-C	ADHD-I
		vs. HC	vs. HC	vs. ADHD-C
EO		64.29% (1)	68.57% (1)	75.68% (1)
EC		66.67% (5)	74.29% (1)	64.86% (1)
MA		64.29% (2)	68.57% (2)	64.86% (2)
MOT		69.05% (2)	71.43% (1)	72.97% (1)

表 4 每種類別達到最高分類率所使用的特徵

類別	ADHD-I	ADHD-C	ADHD-I
	vs. HC	vs. HC	vs. ADHD-C
實驗 流程	MOT	EC	EO

使用 特徵	RP(delta)-O1	RP(gamma)-O1	RP(gamma)-Pz
	SP(beta)-T4	-	-

經過基準線校正之後，三種類別之中最高分類率為 ADHD-I vs. ADHD-C 在 MA-EC 下達到 86.49%，使用 8 個特徵。如表 5 所示。ADHD-I vs. HC 的最高分類率為 MA-EC 的 71.43%，使用 8 個特徵，ADHD-C vs. HC 的最高分類率為 MA-EO 的 77.14%，使用 5 個特徵，ADHD-I vs. ADHD-C 的最高分類率為 MA-EC 的 86.49%，使用 8 個特徵，表 6 為每種類別所使用的特徵。

表 5 經過基準線校正之最高分類率

組合	類別	ADHD-I	ADHD-C	ADHD-I
		vs. HC	vs. HC	vs. ADHD-C
MA-EO		69.05% (1)	77.14% (5)	72.97% (1)
MA-EC		71.43% (8)	68.57% (3)	86.49% (8)
MOT-EO		66.67% (1)	68.57% (1)	70.27% (1)
MOT-EC		69.05% (2)	74.29% (4)	78.38% (7)

表 6 每種類別達到最高分類率所使用的特徵

類別	ADHD-I	ADHD-C	ADHD-I
	vs. HC	vs. HC	vs. ADHD-C
組合	MA-EC	MA-EO	MA-EC
使用 特徵	MSE($\tau=18$)-O1	SP(alpha)-O2	SP(delta)-T5
	MSE($\tau=19$)-O1	RP(alpha)-O2	SP(delta)-Pz
	RP(alpha)-O2	SP(alpha)-O1	SP(delta)-P4
	MSE($\tau=20$)-O1	RP(alpha)-O1	SP(delta)-O1
	MSE($\tau=17$)-O1	SP(theta)-O2	SP(beta)-C3
	SP(delta)-F3	-	SP(delta)-O2
	RP(alpha)-O1	-	SP(delta)-P3
	SP(delta)-T3	-	RP(delta)-T4

由表 3 及表 5 的結果得知，基準線校正方法是有效的，可以提高分類率，從最高分類率的層面來看，ADHD-I vs. HC 提升 2.38%，ADHD-C vs. HC 提升 2.85%，ADHD-I vs. ADHD-C 提升 10.81%，為三種類別之中提升最多的，雖然使用的特徵數量也有增加，但還在可以接受的範圍。

原本還未經過基準線校正的情況下，心算任務的分類效果在四個實驗流程中並不好，甚至在

ADHD-C vs. HC 和 ADHD-I vs. ADHD-C 的效果是最差的，但經過基準線校正之後，能夠達到最高分類率的組合皆與心算相關。

4. 結論與未來展望

結果顯示，在基準線校正前，三種類別的最高分類率為 ADHD-I vs. ADHD-C 在 EO 的狀態下達到 75.68%，且三種類別能到達到最高分類率的實驗流程分別為 ADHD-I vs. HC 的 MOT、ADHD-C vs. HC 的 EC 以及 ADHD-I vs. ADHD-C 的 EO，其中有兩種的實驗流程是屬於放鬆狀態，而基準線校正後，三種類別的最高分類率為 ADHD-I vs. ADHD-C 在 MA-EC 下達到 86.49%，且三種類別能到達到最高分類率的基準線校正組合分別為 ADHD-I vs. HC 的 MA-EC、ADHD-C vs. HC 的 MA-EO 以及 ADHD-I vs. ADHD-C 的 MA-EC，其中有兩種類別的組合是屬於 MA-EC，表示放鬆狀態對於區分 ADHD 亞型具有不錯的效果，其中又以閉眼放鬆搭配心算任務做基準線校正之後的效果是最好的。

可以看到在基準線之後的分類率有所提升，比基準線校正前的分類率要更高，表示 ADHD 孩童的在任務與休息狀態間的能量轉換可能與健康孩童有所差異，此結果符合本論文的假設，但是找出的最佳特徵卻不符合本論文的推測，根據表 4 的結果顯示，未做基準線校正之前，每種類別達到最高分類率所使用的特徵裡面並沒有包含多尺度熵，這項結果雖與先前的推測不同，但是與 2021 年的一項研究結果相同[3]，該研究指出，高頻段(β_1, β_2, γ)與後側電極對於分類 HC、ADHD-I、ADHD-C 具有高度貢獻。

從本論文的結果來看，之後也許可以考慮僅使用心算任務以及閉眼放鬆進行後續分析，或是針對本論文的實驗流程與分析方法進行優化，未來將有機會建立一套 EEG 評估系統並提供醫師輔助診斷使用。

5. 參考文獻

- [1] 台灣兒童青少年精神醫學會. (2011). 衛教專欄. http://www.tscap.org.tw/TW/NewsColumn/ugC_News_Detail.asp?hidNewsCatID=6&hidNewsID=78
- [2] American Psychiatric Association, American Psychiatric Association. DSM-5 Task Force., Diagnostic and statistical manual of mental disorders: DSM-5. 5th ed. American Psychiatric Association: Washington, D.C., 2013.
- [3] Ahmadi, A., Kashefi, M., Shahrokhi, H., & Nazari, M. A. "Computer aided diagnosis system using deep convolutional neural networks for

ADHD subtypes," Biomedical Signal Processing and Control, vol. 63, pp. 1-10, 2021.

- [4] Richman, J. S., & Moorman, J. R., "Physiological time-series analysis using approximate entropy and sample entropy," American Journal of Physiology-Heart and Circulatory Physiology, vol. 43, pp. H2039-H2049, 2000.
- [5] Richman, J. S., Lake, D. E., & Moorman, J. R., "Sample entropy," Methods in enzymology, vol. 384, pp. 172-184, 2004.
- [6] Khaleghi, A., Birgani, P.M., Fooladi, M.F. et al. "Applicable features of electroencephalogram for ADHD diagnosis," Research on Biomedical Engineering, vol. 36, pp. 1-11, 2020.
- [7] Li Chenxi, Yanni Chen, Youjun Li, Jue Wang, and Tian Liu, "Complexity analysis of brain activity in attention-deficit/hyperactivity disorder: A multiscale entropy analysis," Brain Research Bulletin, vol. 124, pp. 12-20, 2016.
- [8] Costa, M., Goldberger, A. L., & Peng, C. K., "Multiscale entropy analysis of complex physiologic time series," Physical review letters, vol. 89, pp. 068102, 2002.
- [9] Costa, M., Goldberger, A. L., & Peng, C. K., "Multiscale entropy analysis of biological signals," Physical review E, vol. 71, pp. 021906, 2005.
- [10] Maryam Rezaeezadeh, Sina Shamekhi, and Mousa Shamsi. "Attention Deficit Hyperactivity Disorder Diagnosis using non-linear univariate and multivariate EEG measurements: a preliminary study," Physical and Engineering Sciences in Medicine, vol. 43, pp. 577-592, 2020.
- [11] Mohammadi, M.R., Khaleghi, A., Nasrabadi, A.M. et al. "EEG classification of ADHD and normal children using non-linear features and neural network," Biomedical Engineering Letters, vol. 6, pp. 66-73, 2016.
- [12] Rostami M, Farashi S, Khosrowabadi R, Pouretmad H. "Discrimination of ADHD Subtypes Using Decision Tree on Behavioral, Neuropsychological, and Neural Markers," Basic and clinical neuroscience, vol. 11, pp. 359-367, 2020.

6. 致謝

本論文得以順利完成需要感謝許多人的幫助，首先感謝指導教授劉益宏教授在期間對學生的悉心指導，提供許多寶貴的建議，以及感謝陳慧如醫師和黃郁心醫師積極轉介受試者，得以讓我們能夠順利取得腦波資料。