

東海大學資訊工程學系

專題報告書

基於源感知(EEG)的體療環境和介質溫控

EEG-based therapeutic environment and medium
temperature control

專題學生：

S10350110 李家蓁

S10350114 胡少騏

指導教授：謝宗濤教授

中華民國 113 年 12 月 14 日

誌謝

本研究的完成離不開多方的支持和幫助。首先，我要衷心感謝我的指導教授，感謝您在研究過程中提供的寶貴指導和啟發，無論在研究方向、數據分析、實驗設計還是論文撰寫上，您的專業見解和耐心支持都讓我獲益匪淺。其次，感謝實驗參與者的無私配合，讓研究能夠順利進行，也要感謝我的隊友，與你的交流和合作，使這段學術旅程更加豐富且充實。最後，我要感謝物理治療師和中醫師的配合，補足醫療相關的專業知識，使本研究更為完善，。

摘要

現代社會中，長時間久坐辦公或打字容易引發手腕、腰椎等部位的疲勞，影響血液循環，甚至導致腰椎間盤突出。為緩解這些症狀，許多患者會選擇紅外線照射治療或熱敷療程，治療過程中，患者通常只能依賴主觀口述來表達感受，這種方式因個體對不適或舒適感的認知差異而影響療效，甚至增加燙傷等風險。

透過收集腦波（EEG）等生理訊號，能夠記錄大腦的電位變化，提供一種客觀的指標，將訊號分析應用於治療中，可協助醫護人員即時了解患者是否感到不適，特別是針對老人或兒童，能解決表達延遲或表達不清的問題，使治療方式得以即時且精準調整。

本研究旨在通過監測腦波頻帶對溫度變化的反應，設計一套自適應控制系統。該系統可自動調節治療強度，並在偵測到危險徵兆時及時暫停紅外線照射，確保治療安全，根據文獻， θ (theta)、 α (alpha) 和 γ (gamma) 頻段與疼痛及舒適感受密切相關，為了驗證該文獻的特徵，透過設計前導實驗，以確保熱刺激所產生的疼痛與舒適狀態能夠誘發特定頻段的腦波。收集的資料經過濾波和短時傅立葉轉換進行處理，特徵擷取和分析後，最終選出六段 γ 頻段特徵和 Cz、Fz 電極位作為最佳特徵進行模型訓練，隨機森林、SVM、一維 CNN 和 LSTM 等模型在訓練中均表現優異，進一步驗證顯示，LSTM 模型在預測疼痛狀態發生方面更為精確。最終，本研究將模型與 Arduino 和繼電器結合，構建出一套 AIoT 自動溫控系統，以提升治療師對多位患者的照護效率，減少過熱風險，並提高熱敷療程的品質。

未來，本系統將通過與物理治療師合作來擴充數據庫，增加不同群體的資料，並根據治療師與受試者的回饋調整系統架構，提供針對不同部位、年齡層及敏感肌膚群體的可選擇性設定。

關鍵詞: EEG、刺激、疼痛、放鬆、(非)監督式學習應用、AIoT

目錄

| | |
|--|-----|
| 誌謝 | i |
| 摘要 | ii |
| 圖目錄 | v |
| 表目錄 | vii |
| 第一章 緒論 | 1 |
| 1.1 研究背景 | 1 |
| 1.2 研究動機 | 1 |
| 1.3 研究目的 | 2 |
| 第二章 研究方法 | 3 |
| 2.1 腦電圖(Electroencephalography, EEG) | 3 |
| 2.2 疼痛 | 4 |
| 2.2.1 不同刺激對腦波的影響 | 4 |
| 2.2.2 基於腦波訊號不同模型之疼痛偵測 | 5 |
| 2.2.3 舒服 | 8 |
| 2.3 研究架構 | 9 |
| 第三章 研究設計 | 11 |
| 3.1 研究工具 | 11 |
| 3.1.1 腦波訊號測量儀器 | 11 |
| 3.2 資料前處理流程 | 12 |
| 3.2.1 特徵計算 | 13 |
| 3.2.2 處理體動資料(移除干擾資料) | 14 |
| 3.2.3 使用 IQR 移除離群值(移除干擾資料) | 15 |
| 3.3 實驗設計 | 16 |
| 3.3.1 前導實驗(目標) | 16 |
| 3.3.2 臨床模擬實驗 | 22 |
| 3.4 根據不同部位分析 | 29 |
| 第四章 模型訓練結果與分析 | 31 |
| 4.1 機器學習模型 | 31 |
| 4.1.1 多模型訓練單一特徵與多特徵訓練差異 | 33 |
| 4.1.2 多模型訓練不同時間段訓練差異 | 35 |
| 4.1.3 多模型訓練不同電極位差異 | 36 |
| 4.2 深度學習模型 | 37 |

| | | |
|-------|-----------------------------|----|
| 4.2.1 | 兩者模型訓練於單一特徵和多特徵差異..... | 38 |
| 4.2.2 | 兩種模型訓練於不同時間段訓練差異..... | 39 |
| 4.2.3 | 兩種模型訓練於不同電極位差異..... | 40 |
| 4.2.4 | 時頻圖於二維 CNN 模型訓練..... | 41 |
| 4.2.5 | 以 11 種不同部位使用 LSTM 進行訓練..... | 42 |
| 4.3 | 臨床模擬實驗模型驗證成果..... | 43 |
| 第五章 | 系統架構..... | 46 |
| 5.1 | Platform Development..... | 46 |
| 5.2 | 加熱與否的 Swith..... | 48 |
| 5.3 | 系統評估..... | 49 |
| 第六章 | 討論..... | 52 |
| 6.1 | 四種模型驗證討論..... | 52 |
| 6.2 | 頻譜特徵分析..... | 52 |
| 第七章 | 結論..... | 55 |
| 7.1 | 研究限制..... | 55 |
| 7.2 | 未來展望..... | 55 |
| 參考文獻 | | 56 |
| 附錄 | | 60 |

圖目錄

| | |
|---|----|
| 圖 1.1 熱敷潛在的風險[6] | 2 |
| 圖 2.1 腦波基本波段[7] | 3 |
| 圖 2.1 腦波基本波段[7] | 3 |
| 圖 2.2 研究架構圖 | 10 |
| 圖 3.1 四通道腦波儀器 | 11 |
| 圖 3.2 資料處理流程圖 | 12 |
| 圖 3.3 放鬆情況下畫出的短時傅立葉轉換時頻圖 | 13 |
| 圖 3.4 移除體動前後數據 | 15 |
| 圖 3.5 三個特徵於兩種不同狀態畫出盒方圖(電極位 Cz)..... | 15 |
| 圖 3.6 前導實驗流程圖 | 16 |
| 圖 3.7 國際 10-20 電極位置[34] | 17 |
| 圖 3.8 其中一位受試者感受熱水袋溫度變化示意圖..... | 17 |
| 圖 3.9 三個特徵分別在兩個狀態下位於 Cz 電極位的圖 | 18 |
| 圖 3.10 三個特徵分別在兩個狀態下位於 Fz 電極位的圖..... | 18 |
| 圖 3.11 三個特徵分別在兩個狀態下位於 Cz 電極位的盒方圖 | 19 |
| 圖 3.12 三個特徵分別在兩個狀態下位於 Cz 電極位的散布圖 | 19 |
| 圖 3.13 三個特徵分別在兩個狀態下位於 Fz 電極位的盒方圖..... | 20 |
| 圖 3.14 三個特徵分別在兩個狀態下位於 Fz 電極位的散布圖..... | 20 |
| 圖 3.15 六段 γ 特徵分別在兩個狀態下位於 Cz 電極位的盒方圖 | 21 |
| 圖 3.16 六段 γ 特徵分別在兩個狀態下位於 Fz 電極位的盒方圖..... | 21 |
| 圖 3.17 臨床模擬實驗流程圖 | 23 |
| 圖 3.18 其中一位受試者感受不同紅外線燈光照射 | 23 |
| 圖 3.19 三個特徵分別在兩個狀態下位於 Cz 電極位的盒方圖..... | 24 |
| 圖 3.20 三個特徵分別在兩個狀態下位於 Cz 電極位的散布圖..... | 25 |
| 圖 3.21 三個特徵分別在兩個狀態下位於 Fz 電極位的盒方圖..... | 25 |
| 圖 3.22 三個特徵分別在兩個狀態下位於 Fz 電極位的散布圖..... | 26 |
| 圖 3.23 六段 γ 特徵分別在兩個狀態下位於 Cz 電極位的盒方圖 | 26 |
| 圖 3.24 前三段 γ 特徵分別在兩個狀態下位於 Cz 電極位的盒方圖 | 27 |
| 圖 3.25 後三段 γ 特徵分別在兩個狀態下位於 Cz 電極位的盒方圖 | 27 |
| 圖 3.26 六段 γ 特徵分別在兩個狀態下位於 Fz 電極位的盒方圖..... | 27 |
| 圖 3.27 前三段 γ 特徵分別在兩個狀態下位於 Fz 電極位的盒方圖 | 28 |
| 圖 3.28 後三段 γ 特徵分別在兩個狀態下位於 Fz 電極位的盒方圖 | 28 |
| 圖 3.29 以舒服狀下 θ 、 α 、 γ 特徵的 11 種部位差異在 Cz 電極位下 | 30 |
| 圖 4.1 使用隨機森林訓練 6 段 γ 特徵於 Cz&Fz 點位的分類報告 | 33 |
| 圖 4.2 不同模型訓練 8 種組合特徵於 Cz 點位的準確率..... | 34 |
| 圖 4.3 不同模型預測 8 種組合特徵於 Cz 點位的不舒服狀態準確率 | 34 |

| | |
|--|----|
| 圖 4.4 不同模型於不同時序下 8 種組合特徵於 Cz 的準確率 | 35 |
| 圖 4.5 不同模型於不同時序下 8 種組合特徵於 Cz 的不舒服準確率 | 35 |
| 圖 4.6 不同模型於不同電極位下每秒 8 種組合特徵的準確率 | 36 |
| 圖 4.7 不同模型於不同電極位下每秒 8 種組合特徵的準確率 | 36 |
| 圖 4.8 一維 CNN 模型整體架構 | 38 |
| 圖 4.9 LSTM 模型整體架構 | 38 |
| 圖 4.10 不同模型訓練 8 種組合特徵於 Cz 點位的準確率 | 39 |
| 圖 4.11 不同模型訓練 8 種組合特徵於 Cz 點位的不舒服準確率 | 39 |
| 圖 4.12 不同模型於不同時間下每秒 8 種組合特徵的準確率 | 40 |
| 圖 4.13 不同模型於不同時間下每秒 8 種組合特徵的準確率 | 40 |
| 圖 4.14 使用使用二維 CNN 訓練全通道於 Cz&Fz 點位的混淆矩陣 | 41 |
| 圖 4.15 二維 CNN 模型整體架構 | 42 |
| 圖 4.16 十一種部位模型以及全部位模型進行預測的準確率 | 43 |
| 圖 4.17 發生 False Alarm 情況 | 44 |
| 圖 5.1 AIOT 平台架構圖 | 47 |
| 圖 5.2 兩盞紅外線電燈與 Arduino、繼電器串接電路圖 | 47 |
| 圖 5.3 後端預測去影響繼電器切換燈泡-1 | 47 |
| 圖 5.4 後端預測去影響繼電器切換燈泡-2 | 48 |
| 圖 5.5 兩路繼電器內部電路圖 | 48 |
| 圖 5.6 繼電器常閉與常開與共點接法 | 49 |
| 圖 5.7 12V 兩路繼電器 | 49 |
| 圖 5.8 系統網頁介面 | 50 |
| 圖 5.9 預測出不舒服情況時候 | 50 |
| 圖 5.10 將資料儲存置資料庫 | 51 |
| 圖 5.11 常態時以黃燈照射 | 51 |
| 圖 5.12 繼電器開啟時以紅燈照射 | 51 |
| 圖 6.1 不同模型下偵測疼痛反應 | 52 |

表目錄

| | |
|---|----|
| 表 2.1 不同刺激在腦波頻帶、電極位上影響 | 4 |
| 表 2.2 透過不同刺激使用不同特徵進行不同的模型訓練..... | 6 |
| 表 2.3 透過不同刺激使用深度學習模型訓練 | 8 |
| 表 2.4 透過不同實驗方式誘發 α 波 | 9 |
| 表 3.1 腦波量測儀設備資料 | 11 |
| 表 3.2 五位受試者資料處理前後的數據資料 | 18 |
| 表 3.3 七位受試者資料處理前後的數據資料 | 24 |
| 表 3.4 十一種部位於不同狀態下資料數量 | 29 |
| 表 4.1 使用使用隨機森林訓練 6 段 γ 特徵於 Cz&Fz 點位的分類報告 | 33 |
| 表 4.2 使用二維 CNN 訓練全通道於 Cz&Fz 點位的分類報告..... | 41 |
| 表 4.3 四種模型進行預測統計出四種預測結果的數量..... | 44 |
| 表 4.4 統計四種模型在預測正確情況下的實際不適狀態..... | 45 |
| 表 6.1 不舒服在 θ 與 α 兩個特徵下差異 | 53 |
| 表 6.2 不同電極位下誘發特徵的差異 | 53 |
| 表 6.3 六段 γ 頻段在不舒服狀態下數值低與高的頻段..... | 54 |

第一章 緒論

1.1 研究背景

物理治療中，熱敷 (hot compress therapy) 是一種簡單且有效的非藥物治療方式，透過熱力穿透作用，促進血液循環[1]，加速新陳代謝、緩解疼痛和減少炎症。此方法常用於治療各種慢性疼痛，包含肌肉痙攣、關節炎及神經痛，常見的熱敷方式包括紅外線照射、熱介質（如水袋、毛巾）的傳熱作用、熱浴等。

目前，紅外線療法已廣泛應用於臨床，涵蓋中醫診所、術後復健治療到醫院手術等不同領域。憑藉其非侵入性與非接觸性，能夠深達皮下組織，廣泛應用於促進傷口癒合、減輕疼痛及活化細胞，除此之外，臨床應用包括其在運動後減少肌肉損傷和酸痛方面效果顯著[2]；針對關節障礙的紅外線療法，每日使用有助於減輕疼痛並促進功能恢復[3]；糖尿病治療中近幾年有新發現，持續的紅外線照射可改善糖尿病潰瘍[4]，甚至可能影響體內葡萄糖生成[5]，儘管紅外線療法應用廣泛，其對皮膚溫度變化、敏感性及長期疼痛的影響仍需進一步研究。

1.2 研究動機

現今社會中，久坐辦公、長期打字等工作形式易引發手腕、腰椎、肩膀等部位的疲勞與不適，進一步影響血液循環；長時間的久坐或站導致肌肉長期缺乏運動會導致血液循環不良，最終引發僵硬、疼痛甚至腰椎間盤突出；此外，職業運動員在高強度訓練與比賽中，常會面臨肌肉疲勞、拉傷及其他運動相關損傷，這些損傷雖無明顯外傷，實則內部肌肉、韌帶或神經可能已經發炎，除即時緩解疼痛外，後續的持續性治療與康復對於這些人群至關重要。

現行熱敷療法面臨多重挑戰（詳見圖 1.1），例如：物理治療師經常需要同時照顧多位患者，且患者的受傷程度各不相同，對熱敷時間與溫度的需求也不盡相同，這無形中降低治療效率。此外，過長的熱敷時間可能引發皮膚灼傷或過敏，臨床上，物理治療師通常根據經驗為患者制定熱敷參數（如溫度、療程時間和患部），需監控多位患者的療程時間以避免風險。

目前已有研究透過生理資訊（如腦波、心電圖與皮膚電阻抗等）量化患者對溫度變化和痛覺的評估，引發思考：能否結合生理數據與 AIoT 技術，開發輔助工具來幫助物理治療師，從而提高熱敷療程的醫療品質，並更有效照顧多位患者？



圖 1.1 熱敷潛在的風險[6]

1.3 研究目的

本研究旨在透過生理數據來探討不同溫度變化對皮膚的影響。腦電圖 (Electroencephalography, EEG) 是一項重要的生理資訊，人體對溫度的主觀感受會伴隨不同的生理反應，例如痛覺反應，或由溫差引起的舒適度變化（從低溫到高溫的過程），此反應可以在大腦的特定頻段和區域中觀察到，目前對於長時間熱敷狀態的研究較少。本研究將通過調查測試者對溫度變化臨界點的反應來收集數據，進一步了解他們對溫度上升、下降和舒適區間的感受。

本研究旨在探討熱敷過程中可能引發的不適問題，此不適感由神經系統傳遞至大腦，會導致腦電圖的變化，透過機器學習技術，本研究建立一種偵測痛覺的模型，能根據當前數據預測下一秒的不適反應，從而提前預警，避免紅腫或發炎等不適情況的發生，本研究的成果為 AIoT 自動溫控平台提供了智能支持，減少熱敷過程中的風險，並降低物理治療師的監護負擔，此平台能根據使用者的感受與生理反應，自動調節療程溫度，實時維持在最合適的範圍內，從而提升舒適度與健康保障，同時有效降低熱敷的潛在風險。

第二章 研究方法

2.1 腦電圖(Electroencephalography, EEG)

腦電波基於大腦內神經纖維及神經細胞在傳遞神經脈衝時，所產生的微弱電訊號。腦波訊號因其安全性與便捷性，臨床上得到了廣泛應用，用於檢查患者是否患有癲癇、腦部病變、睡眠障礙、腦外傷、腦膜炎等。一般所稱的腦波是指當腦部運作時神經活動所產生的電磁訊號，於大腦層頭皮表層所記錄到的電磁訊號，即為俗稱的腦電波(EEG)。

EEG 量測有一定難度，因其信號微弱，稍微移動或頭皮清洗不乾淨可能導致接觸不良，實驗操作時，飲用咖啡因飲料也可能干擾信號接收，外界雜訊也容易影響結果。腦波的量測方式分為侵入式與非侵入式兩種，侵入式量測方式，需要通過手術開顱，將電極裝置放置於大腦皮質層，直接透過頭皮組織進行量測，可以測量到較為精確的腦波訊號，由於手術過程較為危險，一般不採用此方式；另一種方法為非侵入式量測是將電極貼在頭皮上，便可用於信號分析，此方法較為簡單與安全方法。根據頻率不同，腦波可分為 δ 波、 θ 波、 α 波、 β 波與 γ 波五個主要波段(見圖 2.1)：

1. Delta(δ)波:於 0.1~3Hz，是無意識的波，影響深層睡眠。
2. Theta(θ)波:於 4~7Hz，是潛意識的波，影響專注、記憶、知覺、情緒、創造、靈感、夢境或冥想。
3. Alpha(α)波:於 8~14Hz，是意識與潛意識的橋樑，影響臨睡前頭腦茫然、靈感、直覺、高度警覺、無暇他顧狀態。
4. Beta(β)波:於 12~30Hz，是意識層面的波，影響思考、處理接受外界的訊息、激動、焦慮、興奮。
5. Gamma(γ)波:於 31~100Hz，影響高階的認知功能與專注。

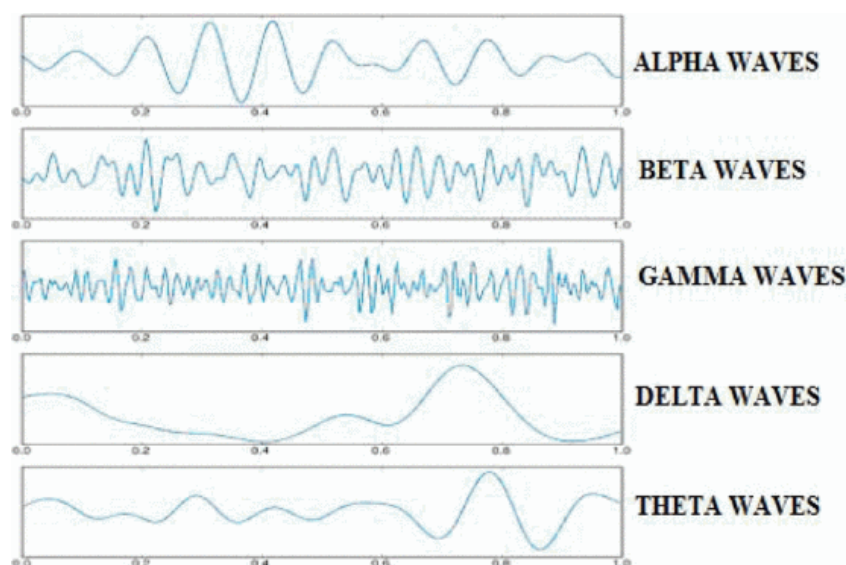


圖 2.1 腦波基本波段[7]

2.2 疼痛

2.2.1 不同刺激對腦波的影響

每個人對於疼痛的反應與自身神經與主觀意識息息相關，同時會反映至腦部活動。當任一患部遇到疼痛狀況時，分布在皮膚的受器會立即覺察到，並把冷、熱及觸感等轉換成「電信號」，透過神經系統傳送，這些訊號透過小纖維感覺神經傳入脊髓，再由脊髓視丘路徑向上傳遞到腦部各個區域，經一系列「感覺傳導路徑」的複雜作用，讓身體感受到疼痛，隨即做出反應，如：喊叫或者移除導致疼痛的熱源。

當前研究中，刺激方式通常採用「刺激至疼痛即停止」的策略，然而，針對長時間、熱刺激所引發的不適反應的研究相對稀少。目前研究的不適刺激方式主要分為冷刺激與熱刺激兩大類，其中以冷刺激為主，相比之下，熱刺激的研究因技術挑戰較高，需要依靠儀器測量熱能堆積與溫度變化，才能推算是否產生客觀的不適反應。表 2.1 彙整不同刺激方式引發疼痛的文獻特徵，研究指出與溫度變化相關的感官反應與大腦的中央皮質區及額葉密切相關，冷刺激經常誘發 δ 和 α ；熱刺激則與 γ 和 θ 相關，疼痛的感受屬於複雜且多層次的過程，涉及大腦中多個區域的協同作用，其中中央皮質區與額葉在疼痛處理中扮演著至關重要的角色，中央皮質區主要負責整合來自身體各部位的感覺信息，當身體遭受疼痛刺激時，信號會迅速傳遞到中央皮質區，進行分類、分析與解釋，此區域可視為疼痛感知的核心，負責區分冷熱刺激等不同類型的疼痛，並透過不同的腦波頻率進行表達。

額葉於疼痛感知中尤為重要，與情緒、感知和行為調節密切相關，即時反映疼痛強度、調節情感反應，如焦慮、恐懼等，額葉的活動也會影響對疼痛的理解，並對應對疼痛的行為產生影響，特別是在情緒波動或壓力增加的情況下，額葉對疼痛的調節作用會更為明顯。因此，中央皮質區負責疼痛信號的接收與初步處理；額葉則在情感和認知層面對疼痛作出即時反應，兩者協同工作，使疼痛的感知伴隨生理、情感及認知的多層次變化。

表 2.1 不同刺激在腦波頻帶、電極位上影響

| 作者 | 刺激方式 | 特徵 |
|----------------------------|------|---|
| Chang, et al. [8] | 冷刺激 | δ 、 α 、 β of frontal lobe |
| Chen and Rappelsberger [9] | 冷刺激 | α 、 β of motor area |
| Chen, et al. [10] | 冷刺激 | α of frontal lobe ; θ of motor area、frontal lobe |
| Lancaster, et al. [11] | 冷刺激 | Invoke γ components of CZ、FZ、O1、FC1 |
| Lv, et al. [12] | 冷刺激 | δ 、 β of C3、F3、F4 |
| | 熱刺激 | δ 、 θ 、 β of frontal lobe、right temporal lobe |
| Gram, et al. [13] | 熱刺激 | α of motor area (C2、C4、CP2、CP4); γ of motor area、frontal lobe (Fz、FC1、FC2、Cz、C1、C3、CP1、CP3) |
| Peng, et al. [14] | 熱刺激 | Invoke high γ components at motor area |

2.2.2 基於腦波訊號不同模型之疼痛偵測

根據不同的刺激方式，表 2.2 表明透過 1-100Hz 頻率一起使用不同的機器學習模型能夠找到有效腦波特徵並透過分類方式做出不舒服情況偵測。冷刺激實驗對大腦活動的影響，透過稀疏正則邏輯回歸 (Sparse Logistic Regression, SLR) 進行特徵選擇，將訊號轉換為 1-100 Hz 的時間-頻率特徵，最終達到 70% 的分類準確率，特徵分析顯示，疼痛感知時 α 波活性減少， θ 則與記憶和注意力負荷有關，疼痛強度上升時， θ 的活躍度會增加。

冷壓疼痛測試中，應用隨機森林模型進行分類，準確率達 72.7%，研究結果指出，無痛層級的準確率較高，而低痛和中痛層級因特徵相似性而區分難度較大，在高痛和不可忍受層級中，準確率則顯著提高，此外，SVM 模型在三層疼痛分類中的準確率為 83%、五層分類中為 62%，顯示出在低層級分類中的優越性能，相較之下，KNN 模型在三層級和五層級分類的準確率分別 80% 和 60%。總體而言，模型通過分析不同腦波特徵 (α 、 β 、 δ 、 γ) 在疼痛分類中的表現出色，展現顯著應用潛力，提供未來進一步探索生理指標與疼痛感知之間的關係提供依據。

使用熱刺激儀施加持續性疼痛，探討疼痛感知的生理特徵及其分類方法，使用隨機森林模型進行受試者的疼痛分類，並採用獨立成分分析 (ICA) 提取多變量成分，特別針對 γ (30-100 Hz) 的頻譜密度進行分析，篩選最具貢獻的頻率特徵，研究結果顯示，隨機森林模型的準確率高達 89.45%，其中 γ 對高強度疼痛的敏感性貢獻最大，表明其在分類中具有顯著影響力，雖然 α 在低層級疼痛的分類中也有一定貢獻，但隨著疼痛強度的提升，其區分能力逐漸減弱，顯示 γ 與 α 之間的互補作用。

使用 Naive Bayes 分類器進行二元分類，將痛感分為“低痛感”和“高痛感”，在單一個體層面的準確率達 $86.3 \pm 8.4\%$ ，跨個體層面則為 $80.3 \pm 8.5\%$ 。同時，運用多重線性回歸 (MLR) 模型進行連續痛感強度的預測，使用 0 到 10 的評估尺度捕捉受試者的痛感反應，此研究不僅揭示不同腦波特徵於疼痛感知中重要性，證明運用機器學習模型進行有效疼痛分類的潛力，為未來的疼痛管理和生理指標應用提供重要基礎。

總結來說，不同文獻展示多種機器學習模型在疼痛分類中的應用潛力，不同模型結合不同腦波頻段特徵 (γ 、 α 、 θ 等) 進行學習與分類，以 γ 特徵為主導，顯著提高疼痛分類的準確度， α 與 γ 特徵達到互補效果，更能精準分出疼痛狀態，模型以隨機森林模型的準確率最高，且在多項研究廣泛使用，結合腦電圖 (EEG) 與生理數據，有助於提升疼痛解碼和干預系統的精確性，從線性 SVM 模型到非線性模型 (如決策樹、KNN、多層感知器等) 均展現了出色的表現，證明與溫差和痛覺相關的腦波特徵足夠強健，應用於未來的醫療輔助系統中。

表 2.2 透過不同刺激使用不同特徵進行不同的模型訓練

| 作者 | 刺激方式 | 生理資訊 | 特徵 | 分析器 |
|----------------------------|--------------------------------|------|---|--------------------|
| Lancaster, et al. [11] | 熱刺激 | EEG | δ (0-4 Hz) 、 θ (4-8 Hz) 、 α (8-13Hz)) 、 β (13-30 Hz) 、 γ (>30Hz) | SF |
| Vijayakumar, et al. [15] | 冷刺激 | EEG | δ (0-4 Hz) 、 θ (4-8 Hz) 、 α (8-13Hz)) 、 β (13-30 Hz) 、 γ (>30Hz) | SLR |
| Bonotis, et al. [16] | 冷刺激 | EEG | δ (0-4 Hz) 、 θ (4-8 Hz) 、 α (8-13Hz)) 、 β (13-30 Hz) 、 γ (>30Hz) | SF、C4.5、 RF、MLP |
| Veerasarn and Stohler [17] | 高滲透壓 鹽水誘發 持續疼痛 | EEG | α 、 β and γ bands increase & δ and θ bands decrease | SVM |
| Chen and Rappelsberger [9] | 冷刺激 | EEG | Power in α band decreases | SVM |
| Cleeland, et al. [18] | 冷刺激 | EEG | Power in α and β bands increase | SVM |
| Chen, et al. [10] | 冷刺激 | EEG | Power of α and β and γ bands increase in the motor area | SVM |
| Huang, et al. [19] | laser- evoked potentials | EEG | Single-trial feature extraction & MLR coefficients | NB |
| Gram, et al. [13] | 冷刺激 | EEG | α , β and γ bands increase & δ and θ bands decrease | SVM |
| Nezam, et al. [20] | 冷刺激 | EEG | α, δ, β and γ bands , Shannon entropy, fractal dimensions and AR | SVM、 KNN |

SF : Stochastic Forest

SLR : Sparse Logistic Regression

RF : Random Forest

MLP : Multilayer Perceptron

NB : Naive Bayes Classifier

KNN : K Nearest Neighbor

除了傳統的機器學習分類器外，本研究也採用多種深度學習技術進行疼痛情況的預測。透過對 2D 圖像與一維數據的神經網路訓練，以及基於多種生理數據和全通道分析，實現疼痛狀態的準確預測，如表 2.3 顯示了不同深度學習模型在疼痛情況預測中的表現。

功能性近紅外光譜 (fNIRS) 與雙向長短期記憶網路 (Bi-LSTM RNNs) 的疼痛評估方法，該方法通過直接處理 fNIRS 數據，提高疼痛分類的準確性。研究利用冷熱刺激獲取疼痛閾值和耐受性數據，將 fNIRS 的原始信號作為模型輸入，聚焦於與疼痛處理相關的氧合血紅蛋白 (Oxy-Hb) 信號，特別是感覺運動皮層區域的 Oxy-Hb 濃度變化。為提取時間序列特徵，使用滑動窗口法將 fNIRS 數據分為約 30 秒的片段 (300 個樣本)，並保持 50% 的重疊率，確保時間連續性。將這些片段輸入 Bi-LSTM 模型，以學習長期依賴與時間關係。此外，動態血流變化被用作關鍵特徵，用以記錄冷熱疼痛刺激下的大腦血流動力學模式變化，這些模式被證明是區分不同疼痛狀態的重要指標。Bi-LSTM 結合前向與反向的信息流處理時間序列特徵，並與多層感知器 (MLP) 和單向 LSTM 進行性能比較。研究結果顯示，Bi-LSTM 模型的準確率達到 90.6%，顯著優於基準模型 (71.7%) 和其他深度學習模型，展現出在疼痛分類任務中的優越性能，同時減少了特徵設計的主觀性，為未來的多模態疼痛評估提供了可能性。

基於 EEG 和卷積神經網路 (CNN) 的疼痛檢測方法，此方法旨在區分慢性背痛患者的疼痛與非疼痛狀態。研究招募了 10 名慢性背痛患者，通過運動刺激 (如跑步機行走) 及觀看與疼痛相關的視頻收集 EEG 數據，並使用 32 通道 EEG 設備記錄大腦活動，提取時間序列特徵。模型核心為 CNN，包含多層卷積層與池化層，用於自動學習 EEG 信號的空間特徵，並進行疼痛與無痛的二分類。特徵包括 EEG 頻帶振盪 (如 α 波和 γ 波) 的變化，這些信號與疼痛相關的大腦區域 (如感覺運動皮層) 的活動密切相關。結果顯示，在運動刺激和視頻刺激條件下，模型的 AUC 分別為 0.83 和 0.81，展現出對疼痛狀態準確分類的潛力，為基於 EEG 的客觀疼痛評估提供了實驗依據。

透過結合面部表情、語言分析、身體動作、EEG、肌電圖 (EMG)、皮膚電活動 (EDA) 等特徵，採用深度學習模型 (如 CNN、RNN、CNN+LSTM、GANs) 進行特徵提取與分類，提升疼痛與非疼痛分類的準確性 (AUC 達 0.83 至 0.90)。結果顯示，多模態融合策略的性能顯著優於單一模態，適用於急性與慢性疼痛的不同情境。然而，需關注數據質量與倫理問題，並聚焦於模型的臨床適應性與泛化能力。疼痛評估結合了行為特徵、神經生理特徵與多模態特徵三大層面。例如，行為特徵包括面部動作編碼系統 (FACS) 捕捉表情變化，分析語調、詞彙和情感特徵，以及肢體語言 (如姿態與運動) 變化。神經生理學特徵則包括腦波振盪變化 (如 α 波與 γ 波)、肌電圖微表情檢測、皮膚電活動 (EDA) 及心率變異性 (HRV)。多模態融合顯著提升了疼痛評估的準確性與穩定性。

設計一種用於 TMJ 治療的疼痛評估系統，通過整合實驗性熱刺激與臨床治療數據實現。收集的電皮膚活動 (EDA) 信號被提取出 36 個統計特徵 (如中值、

標準差及其導數)，以捕捉疼痛與非疼痛狀態間的差異。初始模型採用 LSTM，使用實驗數據進行訓練，並生成臨床數據的偽標籤；最終模型結合偽標籤與主觀標籤，採用新穎的多變量損失函數進行優化。在平均每 3 秒的數據片段上，模型達到 0.89 的準確率與 0.85 的 F1 score，首次實現了實驗模式向臨床應用的知識轉移，展示了其在疼痛評估中的可行性與優越性能。

利用面部表情特徵進行模型訓練和疼痛狀態分類，透過 RGB 視訊中的靜態 2D 影像，提取與疼痛相關的面部特徵，以卷積神經網絡 (CNN)，用於自動學習面部影像的空間特徵，不依賴手工提取的特徵，提取面部區域 (如眼睛、鼻子、嘴巴) 相關的特徵，同時引入注意力機制，對疼痛表情更為明顯的區域賦予更高的權重，以提高模型的敏感度。以分類任務 (如疼痛與非疼痛二分類或多級疼痛強度分類) 進行模型訓練，為解決數據稀少問題，採用數據增強技術 (如翻轉、旋轉、裁剪) 生成更多樣本，並通過交叉驗證確保模型的穩健性。靜態疼痛表情的分類中表現優異，準確率超過 90%，該方法簡化了硬體需求，僅需普通 RGB 攝影機即可實現，為臨床疼痛評估提供可行且高效的技術支持。

表 2.3 透過不同刺激使用深度學習模型訓練

| 作者 | 刺激方式 | 生理資訊 | 模型 |
|---------------------------|----------------------|---|-----------------------|
| Rojas, et al. [21] | 熱電探針進行冷熱刺激 | EEG | MLP、LSTM、Bi-LSTM |
| Chen, et al. [22] | 運動刺激 (MS) 和視頻刺激 (VS) | EEG | CNN |
| Cascella, et al. [23] | 熱刺激 | EEG、面部表情、語音信號、身體動作、心率變異 (HRV)、膚電活動 (EDA) | CNN、RNN、CNN+LSTM、GANs |
| Badura, et al. [24] | 熱刺激 | 膚電活動 (EDA) | LSTM |
| Gkikas and Tsiknakis [25] | 運動刺激、熱刺激、視覺刺激 | 面部表情、語音信號、身體動作、ECG、EMG、EDA、血氧飽和度 (SpO2)、近紅光譜 (NIRS) | CNN(3D)、LSTM、RCNN |

2.2.3 舒服

目前關於 EEG 與舒服相關的研究主要集中在外在環境溫度對舒服狀態的影響 [26]，尚無明確研究於不同刺激下舒服會有甚麼特徵誘發出來，同時無實體研究支持在舒服狀態下一定會出現特定的腦波，需要透過其他試驗方式來確認人體在放鬆狀態下能誘發出特定腦波頻段。

通過表 2.3 不同刺激方法，如 α 音樂、放鬆音樂、虛擬實境 (VR) 場景設計和環境溫度的調整，誘發和調節大腦中的 α 活動，研究其對放鬆狀態和情緒的影響，實驗結果顯示，使用此放鬆方法後，受試者的 α 顯著增加，表明大腦進入更

深的放鬆狀態； β 和 θ 的減少則意味著焦慮感、壓力和注意力的降低，研究表明 α 波的增強可有效減輕壓力，促進情緒穩定，並有助於改善失眠、高血壓等與壓力相關的健康問題。此外，長期聆聽放鬆音樂或參與 α 波神經反饋訓練，顯示持續提升放鬆感和穩定情緒的效果，對自閉症、抑鬱症和注意力缺失症 (ADD/ADHD) 的輔助治療具有潛力。

根據實驗數據顯示，此類刺激實驗可顯著增加前額葉區域的 α 波，尤其在適宜環境條件（如 26°C）下，進一步促進放鬆和舒適感，當環境溫度超出舒適範圍時， β 波的增加暗示不適感的出現。

表 2.4 透過不同實驗方式誘發 α 波

| 作者 | 試驗方式 | 生理資訊 | 特徵 |
|----------------------------|-----------------------------|---------|------------------------------------|
| Vijayalakshmi, et al. [27] | 聽 α 音樂 | EEG | α 、 β |
| Phneah and Nisar [28] | 聽喜愛的音樂和 A binaural beats | EEG | α |
| Zhu, et al. [29] | 觀看 VR 影片 | EEG | α 、 θ at FP1、FPZ、FP2 |
| Yao, et al. [30] | 放鬆(不進行思 考)、智力測驗 | EEG、ECG | α |

2.3 研究架構

根據文獻統整，熱刺激實驗引發疼痛的特徵為 γ 和 θ 頻帶；放鬆實驗與放鬆相關的特徵為 α 頻帶，誘發此特徵的電極位置主要位於中央皮質和額葉區域，多數研究使用隨機森林模型來辨識疼痛指標，並找出相關的特徵。

本研究假設在舒適溫度下會誘發 α 頻帶，不適溫度下會誘發 γ 和 θ 頻帶，透過測量 Cz 和 Fz 點位的特徵，分析熱刺激對受試者皮膚感受的影響。本研究設計階段性實驗以模擬舒服和不舒服狀態的發生，根據以上特徵和實驗方法，制定圖 2.2 的研究架構。

(略)

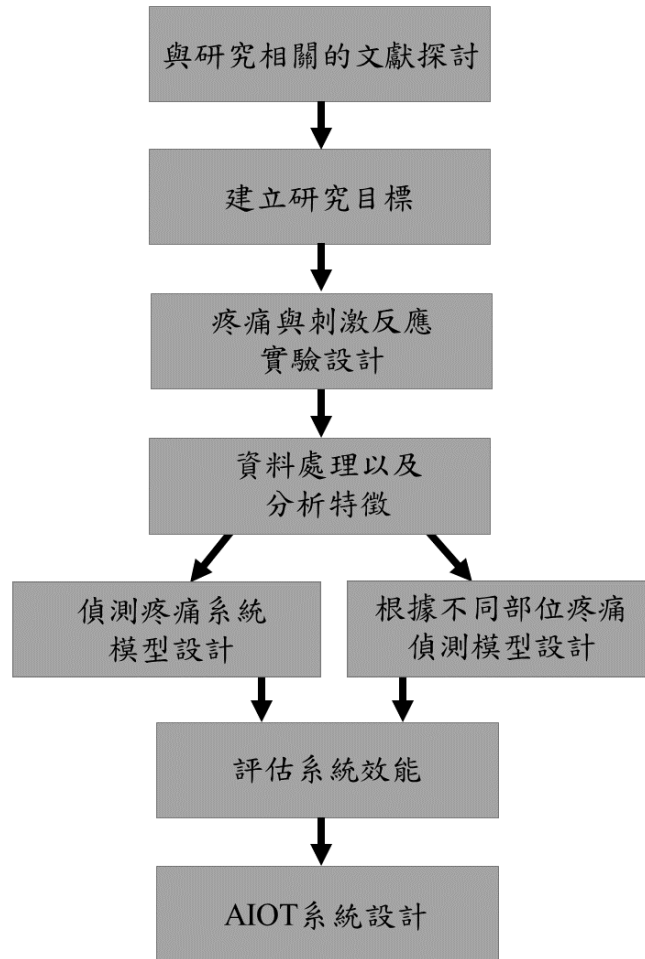


圖 2.2 研究架構圖

第三章 研究設計

3.1 研究工具

3.1.1 腦波訊號測量儀器

(略)

3.2 資料前處理流程

收集腦波訊號時，經常遇到來自環境的噪訊干擾，包括 110V 電壓中 60Hz 干擾、周圍環境的電磁波干擾以及受試者的體動干擾，為了確保數據的準確性，必須有效去除這些噪訊，原始腦波信號無法直接進行分析，需先轉換為實際電壓值，並經過短時傅立葉轉換處理後，才能進一步分析。

干擾移除分為四個步驟。第一步，使用濾波器進行濾波；第二步，採用平均頻帶方法移除環境干擾；第三步，通過演算法移除體動影響；最後一步，使用四分位距 (IQR) 方法去除離群值，詳見圖 3.2 可以看到完整資料前處理流程。

透過三種濾波器進行濾波，由帶阻濾波器(notch filter)濾除 59~61Hz，並進行 100Hz 低通濾波和 1Hz 高通濾波，濾波後的資料會進行短時傅立葉轉換並繪成時頻圖，以檢查是否存在環境電磁波干擾。實驗中常發現持續性的 70Hz 室電波干擾，對於受到干擾的頻帶，本研究使用 69Hz 和 71Hz 的能量值取平均來替換 70Hz 頻帶的數據。

接著使用體動移除演算法檢查 **Baseline** (放鬆狀態) 期間是否發生體動。每秒檢測一次體動，若某秒鐘內所有頻帶的能量值中有超過 300(能量值)的異常頻帶數量佔比超過七成 (0~125Hz)，則判定該秒為體動，並移除該秒資料，移除體動後，更新 **Baseline** 資料中時間與能量並重新儲存。

由於每位受試者的腦波可能存在個體差異，為減少這些生物差異的影響，將兩種狀態的資料除 **Baseline** 資料，得到相對比率資料，根據文獻中特徵頻帶，提取 θ (4~7Hz)、 α (8~14 Hz) 與 γ (71~90Hz) 的能量特徵，並計算每秒的平均頻帶值。

特徵提取後，需要再次移除有體動的資料，通過檢查每秒特徵資料與前一秒的差值 (取絕對值)，若任一特徵的差值超過 2，則移除該秒的所有特徵資料；若 Cz 電極位的資料被移除，則 Fz 電極位的資料也需同步移除。最後，通過四分位距法繪出盒方圖，並使用 IQR 方法去除離群值，並提取 Q1~Q3 區間的資料，以強化舒服與不舒服狀態間的特徵差異。

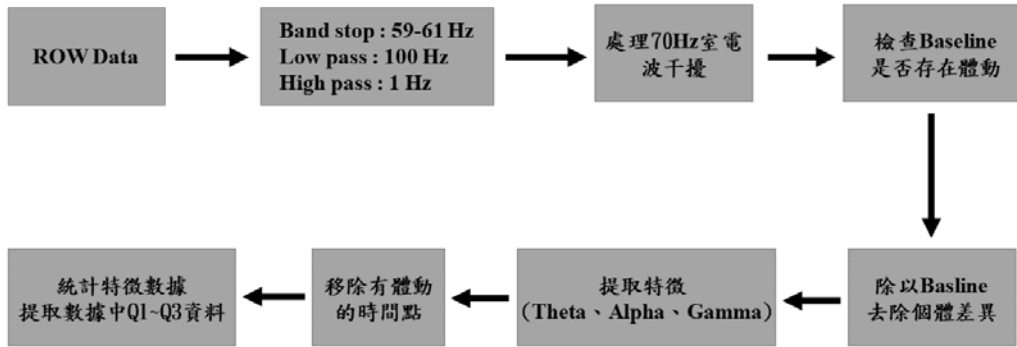


圖 3.1 資料處理流程圖

3.2.1 特徵計算

短時傅立葉變換（Short-time Fourier Transform, STFT）是傅立葉變換的一種變形，也稱作加窗傅立葉轉換（Windowed Fourier Transform）或時間依賴傅立葉轉換（Time-dependent Fourier Transform），用於決定隨時間變化的訊號局部分的正弦頻率和相位。其基本原理是將長時間訊號分割成多個較短且等長的訊號片段，對每個片段分別進行傅立葉轉換，從而在頻域和時域中獲得訊號的變化特徵（詳見圖 3.3），此方法是時頻分析中的一個重要工具[31] [32]。

研究過程中，使用 200 毫秒的 Hanning 窗進行 STFT，將單次試驗的 EEG 數據轉換為時間-頻率域，以精確量化不同頻段（如 α 波和 γ 波）與主觀痛感強度的關聯性。透過 STFT 分析，研究者在多變量線性回歸（MVLRL）和部分最小平方方法（PLSR）的框架下，成功識別出與痛感強度顯著相關的時間-頻率區域。這種方法無需事先設定特定的頻帶和時間範圍，可以自動從全頻域中篩選出與痛感相關的 EEG 活動，顯著提高了預測模型的準確性和有效性[31]。

時域訊號會被切割成小片段，並對每個片段進行傅立葉轉換以獲得時頻訊息。然而，短時傅立葉轉換也有其局限性，即視窗寬度的選擇會影響時間和頻率的解析度。分析低頻訊號時，需加大視窗函數的寬度；而分析高頻訊號時，則需縮小視窗寬度[32]。如果無法事先確定訊號主要集中在高頻還是低頻，選擇適當的視窗函數寬度就會變得困難。

STFT 數學公式如下所示：

$$X(t, f) = \int_{-\infty}^{+\infty} \omega(t - \tau)x(\tau)e^{-j2\pi f\tau} d\tau \quad (3.1)$$

其中 $\omega(t)$ 是窗函數，窗函數種類有很多種，會在稍後再做仔細討論。 $x(t)$ 是待變換的訊號。 $X(t, \omega)$ 是對加窗後的訊號； $\omega(t - \tau)x(\tau)$ 進行傅立葉變換得到的結果。隨著 t 的改變，窗函數在時間軸上會有位移。經 $\omega(t - \tau)x(\tau)$ 加窗處理後，訊號只保留窗函數選定的區域，然後進行傅立葉轉換，所得到的結果為一複數函數，代表著訊號隨時間與頻率變化的大小與相位。




圖 3.2 放鬆情況下畫出的短時傅立葉轉換時頻圖

隨機選取一段放鬆情況下的數據，繪出短時傅立葉轉換 (STFT) 圖，訊號採樣頻率(fs)設定為 250 Hz；窗口(window)大小設定為 1250 個樣本，表示每次短時傅立葉變換時使用 1250 個樣本，把窗口大小除採樣頻率等於 5，代表短時傅立葉轉換中每次會分析 5 秒的訊號；窗口重疊 (nover lap)大小設定為 1000 個樣本，表示相鄰窗口之間的重疊部分是 1000 個樣本，把窗口大小與窗口重疊大小相減，再除採樣頻率等於 1，代表時間軸上每次採樣會間隔 1 秒；快速傅立葉變換的點數(nfft)設定為 256，決定每個時間窗口頻率的解析度，解析度越高時頻圖越精細。

連續小波轉換(Continuous Wavelet Transform,CWT)則是與 STFT 相似但在解析度上有所改良的方法，CWT 僅作用於影像的局部區域，因此可以了解局部空間域的頻率域，而非整張影像的頻率域。母小波函數是小波轉換的關鍵元素，它決定了小波轉換的特性，不同的母小波函數具有不同的時間和頻率特性，適用於不同的訊號分析。

將小波分析(Wavelet Analysis)應用於量化嗎啡和安慰劑對 CHEPs 頻譜特徵的影響，結果顯示嗎啡可顯著降低低頻段 (delta 與 theta) 的功率，並增強高頻段 (beta 與 gamma) 的功率，反映其對腦部痛覺處理的調控作用，同時透過可靠性測試 (包括變異係數和組內相關係數)，證實 CWT 對頻譜指標的穩定性與準確性，充分利用 CWT 在時頻分解中的優勢，不僅增強了對腦電信號的處理能力，還為分析藥物 (如嗎啡) 對中樞神經系統的影響提供了強有力的工具，展示了其在藥理學和神經科學研究中的廣泛應用潛力[33]。

CWT 的通式如：

$$X(a,b) = \frac{1}{\sqrt{b}} \int_{-\infty}^{+\infty} x(t) \varphi\left(\frac{t-a}{b}\right) dt \quad (3.2)$$

本研究最終選擇 STFT 作為分析工具，其具體參數設置進一步體現方法的適用性與效率：訊號採樣頻率 (fs) 設定為 250 Hz，窗口大小為 1250 個樣本 (即 5 秒)，重疊部分為 1000 個樣本 (即每次時間軸間隔 1 秒)，快速傅立葉變換點數 (nfft) 為 256，確保時頻圖的精細程度，此參數設置不僅能保證時間軸上的解析度，還能有效捕捉頻率域中的細節變化。

相較於連續小波轉換 (CWT)，STFT 此設置下顯示出顯著的運算效率，特別是需要分析大範圍特徵時，其固定窗口與重疊設計能高效地平衡計算量與特徵提取的完整性。此外，STFT 的穩定結構使其更適合後續模型在預測中的實時運算需求，尤其在需要快速處理與即時應用的情境下，具有無可替代的優勢。

3.2.2 處理體動資料(移除干擾資料)

根據 STFT 後的資料，首先處理 70Hz 室電波干擾後，檢查 **Baseline** 是否存在體動，儲存為新的 **Baseline** 資料後，根據不同受試者之間腦波訊號對於疼痛產生的差異性，因此需要藉由不同受試者的 **Baseline** 分別除以不同狀態(舒服、不舒服)，儲存為新的不同狀態(舒服、不舒服)，再提取特徵後，檢測體動發生的時

間點，無論哪個特徵發生體動，該時間的數據應刪除，並將後續數據往前移，同時不採用第一秒與最後一秒的數據，檢測有體動的時間點方法為從第二秒開始檢測，通過檢測當前秒數據與前後秒數據的差異，若其絕對值大於 2，則判定為體動，根據不同電極位的情況，若任一電極位檢測到體動，則該秒兩個電極位的數據均應刪除，體動移除前後的差異見圖 3.4。

(略)

3.2.3 使用 IQR 移除離群值(移除干擾資料)

移除體動資料後，對三個特徵 (θ 、 α 、 γ) 的資料分別使用四分位距方法，計算兩種狀態(舒服、不舒服)下最小值、Q1、中位數、Q3 和最大值後，會有離群值資料呈現在圖上，根據 IQR 方法，計算 Q1 與 Q3 的數值來確定離群值的上下限，檢查數據是否在這些範圍之外，透過迴圈方法不斷進行此方法直到沒有離群值(見圖 3.5 左圖)，進一步去取 Q1 到 Q3 數值，可以為特徵精準分出兩個狀態。

(略)

3.3 實驗設計

3.3.1 前導實驗(目標)

(略)

透過前導實驗結果得知，當腦部處於放空狀態時會誘發出低頻的 α 波，而在模擬的舒服狀態實驗中也達到類似效果。為了觀察 α 活性的增長率，將 **Baseline** 與模擬的舒服和不舒服狀態數據進行比值計算，結果顯示 γ 頻段出現顯著變化，能夠清楚區分兩種狀態，驗證文獻所述，即 γ 頻段常被用作疼痛的指標。

不同頻帶的 γ 頻段能處理不同事件，比如處理認知功能相關、跨感官整合或與短期記憶相關、創造力與情緒調控有關，因此進一步將 γ 頻段分為六個頻段，發現 51~60Hz 與 81~60 Hz 中 γ 頻段值明顯高於其他頻段； θ 特徵在不舒服狀態下並未出現顯著誘發，不過在不舒服情況下的確稍微上升，僅在 Fz 電極位上顯示出差異，Cz 電極位則無顯著變化； α 特徵方面，根據文獻，疼痛狀態下應該誘發 γ 並抑制 α ，根據前導實驗結果顯示，不舒服情況下， α 數值反而略高於舒服情況，且僅在 Fz 電極位顯示出差異，Cz 電極位未見顯著變化，目前未觀察到明顯的 α 抑制效果，且與舒服情況的數值差異不大。

此外，前導實驗顯示 Fz 電極位與受試者的主觀感受高度相關，較 Cz 電極位更能反映受試者的即時感受。推測這可能是由於熱敷實驗無法精準調控溫度。因此，計劃進一步使用紅外線燈照射來模擬臨床應用，以期在兩個狀態下的 α 差異更加明顯。

3.3.2 臨床模擬實驗

(略)

從臨床模擬實驗得知，分析結果與前導實驗一致，發現 γ 頻段上有顯著變化，能清楚區分兩種狀態，結果驗證文獻所述，即 γ 頻段常被用作疼痛指標，進一步將 γ 頻段分成六段進行分析，每個頻帶的 Q1~Q3 區間數值相似，與前導實驗的最大差異，同時 Fz 電極位下， γ 數值明顯高於 Cz，進一步驗證 Fz 電極位與人體感受的高度相關性。

相對而言， θ 特徵在不舒服狀態下並未顯著誘發，但在不舒服情況下略有上升，且僅在 Fz 電極位顯示出差異，Cz 無顯著變化。根據文獻，不舒服情況應誘發 γ 並抑制 α ，根據前導實驗結果，不舒服狀態下 α 數值反而略高於舒服狀態，僅在 Fz 電極位顯示出差異，Cz 無顯著變化。此外，前導實驗顯示 Fz 電極位與感受高度相關，比 Cz 更能反映直觀感受。在多特徵情況下，將嘗試使用不同特徵進行模型訓練。

3.4 根據不同部位分析

(略)

第四章 模型訓練結果與分析

基於數據的非線性特性、不同模型的優勢各異，以及本研究僅使用兩個電極位進行分析，藉由選用多種模型進行前期訓練，EEG 數據通常具有高度的非線性和時變性，單一模型可能無法充分捕捉數據的複雜模式；多模型訓練有助於本研究找到最適合特徵組合最佳方法。例如，邏輯迴歸提供簡單的迴歸方法，隨機森林和決策樹適合處理高維非線性數據，SVM 對少量高維數據的分類效果較好，而 CNN 和 LSTM 等深度學習模型擅長捕捉時序數據中的長期依賴性。通過比較不同模型的特色，不僅可以提高結果的準確性和穩定性，亦能降低模型選擇風險，並揭示數據中的重要特徵，從而選擇出最適合的模型來支持 AIoT 自動溫控系統的發展，此外多模型訓練還可以驗證文獻中提到的模型於本研究場景中的適用性，進一步提升結果的可靠性。

4.1 機器學習模型

文獻中隨機森林和 SVM[16, 17]模型常用於疼痛預測的模型訓練，本研究在此基礎上，額外加入羅吉斯迴歸和決策樹模型進行比較。羅吉斯迴歸適合二元分類以及分類計算實速度快、運算資源少，同時便利觀察資料機率數值；隨機森林由多棵決策樹組成，能夠同時處理數據型和常規型屬性，經過決策樹模型變是否能做到與隨機森林模型同等效果。

羅吉斯迴歸利用迴歸運算方式進行分類實作，計算各特徵的權重及偏置，以迴歸演算的結果作為 sigmoid 函式的輸入值來計算機率，sigmoid 函數將輸入變量映射到 0 和 1 之間的概率，並將結果分類為兩個類別，做為判斷類別的機率值稱為閾值。多變數羅吉斯迴歸（Multivariable Logistic Regression）是一種分析多個自變數與二元或多元因變數之間關係的統計方法，特別適合二分類問題，具備強大的模型解釋力，可為每個自變數提供其對目標變數的影響方向和程度。為提高穩定性，多變數羅吉斯迴歸假設自變數間共線性較低，因此通常需事先篩選變數；它也適合非正態分布資料。

邏輯函數形式為：

$$p(x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}} \quad (4.1)$$

$\beta_0 = -\mu/s$ 稱為截距，是直線 $y = \beta_0 + \beta_1 x$ 的 y 截距。 $\beta_1 = 1/s$ 是反比例參數或速率參數，是作為"x"函數的對數發生率的"y"截距和斜率。反之， $\mu = -\beta_0/\beta_1$ ，並且 $s = 1/\beta_1$ 。

決策樹包含根節點、多個子節點和葉節點，根節點是決策樹的起點，包含全體樣本；每個子節點對應於一個特徵測試，測試結果決定樣本的分支方向，最終到達葉節點以得到分類結果。

決策樹公式為:

$$I_E(i) = - \sum_{j=1}^m f(i,j) \log_2 f(i,j) \quad (4.2)$$

隨機森林是決策樹的進階版本，森林旨由多棵決策樹組成，使用 Bagging 加上隨機特徵採樣的方法所產生出來的整體學習演算法，與決策樹不同地方在於，當模型的樹最大深度設定太大的話決策樹模型容易讓模型過擬合，隨機森林由多棵不同樹所組成，讓結果比較不容易過度擬合，並使得預測能力更提升。

隨機森林訓練演算法把 bagging 的一般技術應用到樹學習中。給定訓練集 $X = x_1, \dots, x_n$ 和目標 $Y = y_1, \dots, y_n$ ，bagging 方法重複 (B 次) 從訓練集中有放回地採樣，然後在這些樣本上訓練樹模型：

For $b = 1, \dots, B$:

1. Sample, with replacement, n training examples from X, Y ; call these X_b, Y_b .
2. Train a classification or regression tree f_b on X_b, Y_b .

在訓練結束之後，對未知樣本 x 的預測可以通過對 x 上所有單個回歸樹的預測求平均來實現：

$$\hat{f} = \sum_{b=1}^B f_b(x') \quad (4.3)$$

SVM 在分類和回歸任務中應用廣泛，其核心是尋找最大化類間間隔的決策邊界，以提升泛化能力，SVM 模型支持非線性分類，透過核函數（如 linear、poly 和 rbf）將低維數據映射到高維空間，即使是複雜非線性數據也能有效分類。

SVM 公式為:

$$\left[\frac{1}{n} \sum_{i=1}^n \max(0, 1 - y_i(\omega \cdot x_i + b)) \right] + \lambda \|\omega\|^2 \quad (4.4)$$

四種模型的訓練和測試集比例為 7:3，並從訓練集中選取 20% 作為內部驗證集，另外還有額外輸入資料的驗證方式。羅吉斯迴歸模型的迭代次數(max_iter)設定為 1000，每次迭代，模型都會更新參數並檢查是否已經接近最佳解，如果設置的迭代次數太少，模型可能無法找到最佳解（未收斂），結果就不夠精確；隨機森林模型中，n_estimators 設定為 100 表示使用 100 棵樹來建構隨機森林模型，樹的數量越多，模型的穩定性和精度通常會提升，但計算成本也會增加，把 random_state 設定 42，每次運行時的結果是一致(可重現)；決策樹把 random_state 設定 42 以確保分割資料結果一致，便於每次運行都能得到相同的決策樹結構，主要影響的是分割點選擇及模型的隨機性部分；SVM 設定核函數(kernel function) 為 RBF (Radial Basis Function)，能夠處理非線性數據，可以在高維空間中劃分非線性數據，將 random_state 設定為 42 使結果具有可重現。

根據模擬床實驗提取的特徵包含 θ (4~7Hz)、 α (8~14Hz)、 γ (30~90Hz)、六段 γ (30~90Hz)，在 Cz 和 Fz 電極位上均誘發出此四種特徵，同時對於每次使用幾秒資料進行訓練沒有固定的數值，本研究進一步探討單一特徵與多特徵、不同時序和不同電極位的訓練效果，以找到最佳特徵組合，四種基礎特徵可以組合成以下八種特徵組合 θ 、 α 、 γ 、 θ & α 、 α & γ 、 θ & γ 、 θ & α & γ 、六段 γ 特徵，電極位的組合方式包括 Cz、Fz 以及 Cz&Fz。

4.1.1 多模型訓練單一特徵與多特徵訓練差異

(略)

4.1.2 多模型訓練不同時間段訓練差異

(略)

4.1.3 多模型訓練不同電極位差異

(略)

4.2 深度學習模型

(略)

4.2.1 兩者模型訓練於單一特徵和多特徵差異

(略)

4.2.2 兩種模型訓練於不同時間段訓練差異

(略)

4.2.3 兩種模型訓練於不同電極位差異

(略)

4.2.4 時頻圖於二維 CNN 模型訓練

(略)

4.2.5 以 11 種不同部位使用 LSTM 進行訓練

(略)

4.3 臨床模擬實驗模型驗證成果

(略)

第五章 系統架構

5.1 Platform Development

(略)

5.2 加熱與否的 Swith

(略)

5.3 系統評估

(略)

第六章 討論

6.1 四種模型驗證討論

(略)

6.2 頻譜特徵分析

(略)

第七章 結論

本研究通過前導實驗與臨床模擬實驗發現， γ 頻帶特徵在不舒服情況下可作為疼痛偵測的有效指標，分析與訓練六段 γ 頻帶數據能清晰區分舒服與不舒服狀態，並在 Cz 與 Fz 電極位下達到更高的準確率。基於隨機森林、SVM、CNN 和 LSTM 四種模型的訓練結果，LSTM 模型在預測不舒服發生方面表現最佳，在無不舒服情況下誤判的情形相對較少，但仍需進一步收集更多驗證資料，以評估該模型結合 AIoT 系統架構的實際效能，並探討其未來在臨床應用及物理治療中的潛力。

實驗結果顯示，不舒服狀態下 γ 頻帶有顯著變化，符合文獻所述， γ 頻帶可作為疼痛辨識的重要指標，揭示受試者在不舒服情況下的主要表現為疼痛症狀。此外，Fz 電極位的數據與受試者的實際感受更為接近，驗證情緒反應通常反映在 Fz 電極位的研究結論，LSTM 模型的優越表現可能與其對時序數據的處理能力有關，將本研究結果與既有文獻進行比較，表明持續收集不舒服狀態後的數據並進行深入分析，有助於提升模型的實用性與準確性，這些發現為 AIoT 系統的實際應用提供了重要參考，並為其在臨床及物理治療領域的應用奠定了基礎。

7.1 研究限制

目前實驗對象的年齡層為 19 至 23 歲，未來將擴展至青少年(12-17 歲)、青壯年(25-34 歲)、壯年(35-64 歲)及銀髮族(65 歲以上)，以適應不同年齡層對熱感受的差異，開發更精確的疼痛偵測模型。尤其對於銀髮族，由於其皮膚較脆弱、神經較不敏感，疼痛偵測的準確性需提高，以避免潛在的傷害。對於神經敏感度較低的受試者，應設計專門的實驗，並結合腦電波(EEG)和心電圖(ECG)等生醫訊號，以獲得更客觀的數據測量和分析結果。

目前資料收集的時間以十分鐘為單位，但在臨床應用中，可能需要持續照射整晚或全天。為了更好地應用於臨床環境，未來將與醫院合作收集更長時間的數據，以比較短時間預測長時間的模型和長時間預測長時間的模型，評估哪種方法效果更佳。

7.2 未來展望

目前尚未獲得專業物理治療師的認證此系統具有效療效，未來計劃與物理治療師或醫院合作，進行長期照射實驗，以確認系統能否在偵測到患者疼痛時即時調整照射參數，並提升療效，此外，將結合物聯網技術即時讀取 EEG 資料，通過不同受試者的數據來不斷更新模型訓練，系統也將建立不同部位的模型，方便切換以適配各部位的疼痛偵測需求。

參考文獻

- [1] L. Yan, W. Chenni, and L. Fang, "Medical Data Analysis of Lumbar Disc Herniation Patients after Traditional Chinese Medicine Rehabilitation Intervention Lumbar Function Recovery," *Applied Bionics and Biomechanics*, vol. 2022, 2022.
- [2] L. S. Borges *et al.*, "Light-emitting diode phototherapy improves muscle recovery after a damaging exercise," *Lasers in Medical Science*, vol. 29, pp. 1139-1144, 2014.
- [3] V. H. Panhoca *et al.*, "Comparative clinical study of light analgesic effect on temporomandibular disorder (TMD) using red and infrared led therapy," *Lasers in medical science*, vol. 30, pp. 815-822, 2015.
- [4] N. C. d. S. Borges *et al.*, "Photobiomodulation using red and infrared spectrum light emitting-diode (LED) for the healing of diabetic foot ulcers: a controlled randomized clinical trial," *Lasers in Medical Science*, vol. 39, no. 1, p. 253, 2024.
- [5] J. Yan, C. Li, and J. Liu, "Remotely ameliorating blood glucose levels in type 2 diabetes via a near-infrared laser," *Advanced Functional Materials*, vol. 31, no. 8, p. 2007215, 2021.
- [6] 黃毓倫、黃鴻宇. "到診所復健熱敷遭燙傷 退休醫師控診所冷處理." 民視新聞.
<https://tw.news.yahoo.com/%E5%88%B0%E8%A8%BA%E6%89%80%E5%BE%A9%E5%81%A5%E7%86%B1%E6%95%B7%E9%81%AD%E7%87%99%E5%82%B7-%E9%80%80%E4%BC%91%E9%86%AB%E5%B8%AB%E6%8E%A7%E8%A8%BA%E6%89%80%E5%86%B7%E8%99%95%E7%90%86-103102959.html> (accessed).
- [7] S. Vaid, P. Singh, and C. Kaur, "EEG signal analysis for BCI interface: A review," in *2015 fifth international conference on advanced computing & communication technologies*, 2015: IEEE, pp. 143-147.
- [8] P. F. Chang, L. Arendt-Nielsen, and A. C. Chen, "Comparative cerebral responses to non-painful warm vs. cold stimuli in man: EEG power spectra and coherence," *International Journal of Psychophysiology*, vol. 55, no. 1, pp. 73-83, 2005.
- [9] A. C. Chen and P. Rappelsberger, "Brain and human pain: topographic EEG amplitude and coherence mapping," *Brain topography*, vol. 7, no. 2, pp. 129-140, 1994.
- [10] A. C. Chen, P. Rappelsberger, and O. Filz, "Topology of EEG coherence


- changes may reflect differential neural network activation in cold and pain perception," *Brain topography*, vol. 11, pp. 125-132, 1998.
- [11] J. Lancaster, H. Mano, D. Callan, M. Kawato, and B. Seymour, "Decoding acute pain with combined EEG and physiological data," in *2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)*, 2017: IEEE, pp. 521-524.
- [12] B. Lv, C. Su, L. Yang, and T. Wu, "Effects of stimulus mode and ambient temperature on cerebral responses to local thermal stimulation: An EEG study," *International Journal of Psychophysiology*, vol. 113, pp. 17-22, 2017.
- [13] M. Gram, C. Graversen, S. Olesen, and A. Drewes, "Dynamic spectral indices of the electroencephalogram provide new insights into tonic pain," *Clinical Neurophysiology*, vol. 126, no. 4, pp. 763-771, 2015.
- [14] W. Peng, L. Hu, Z. Zhang, and Y. Hu, "Changes of spontaneous oscillatory activity to tonic heat pain," *PloS one*, vol. 9, no. 3, p. e91052, 2014.
- [15] V. Vijayakumar, M. Case, S. Shirinpour, and B. He, "Quantifying and characterizing tonic thermal pain across subjects from EEG data using random forest models," *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 12, pp. 2988-2996, 2017.
- [16] P. A. Bonotis *et al.*, "Automated assessment of pain intensity based on EEG signal analysis," in *2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE)*, 2019: IEEE, pp. 583-588.
- [17] P. Veerasarn and C. S. Stohler, "The effect of experimental muscle pain on the background electrical brain activity," *Pain*, vol. 49, no. 3, pp. 349-360, 1992.
- [18] C. S. Cleeland, Y. Nakamura, E. W. Howland, N. R. Morgan, K. R. Edwards, and M. Backonja, "Effects of oral morphine on cold pressor tolerance time and neuropsychological performance," *Neuropsychopharmacology*, vol. 15, no. 3, pp. 252-262, 1996.
- [19] G. Huang, P. Xiao, Y. Hung, G. D. Iannetti, Z. Zhang, and L. Hu, "A novel approach to predict subjective pain perception from single-trial laser-evoked potentials," *Neuroimage*, vol. 81, pp. 283-293, 2013.
- [20] T. Nezam, R. Boostani, V. Abootalebi, and K. Rastegar, "A novel classification strategy to distinguish five levels of pain using the EEG signal features," *IEEE Transactions on Affective Computing*, vol. 12, no. 1, pp. 131-140, 2018.
- [21] R. F. Rojas, J. Romero, J. Lopez-Aparicio, and K.-L. Ou, "Pain assessment based on fnirs using bi-lstm rnns," in *2021 10th International IEEE/EMBS Conference on Neural Engineering (NER)*, 2021: IEEE, pp. 399-402.
- [22] D. Chen *et al.*, "Scalp EEG-based pain detection using convolutional neural network," *IEEE Transactions on Neural Systems and Rehabilitation*

- Engineering*, vol. 30, pp. 274-285, 2022.
- [23] M. Cascella *et al.*, "Artificial intelligence for automatic pain assessment: research methods and perspectives," *Pain Research and Management*, vol. 2023, no. 1, p. 6018736, 2023.
- [24] A. Badura, M. Bienkowska, A. Mysliwiec, and E. Pietka, "Continuous short-term pain assessment in temporomandibular joint therapy using LSTM models supported by heat-induced pain data patterns," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024.
- [25] S. Gkikas and M. Tsiknakis, "Automatic assessment of pain based on deep learning methods: A systematic review," *Computer methods and programs in biomedicine*, vol. 231, p. 107365, 2023.
- [26] X. Lang, Z. Wang, X. Tian, Y. Wu, S. Zhu, and W. Liu, "The effects of extreme high indoor temperature on EEG during a low intensity activity," *Building and Environment*, vol. 219, p. 109225, 2022.
- [27] K. Vijayalakshmi, S. Sridhar, and P. Khanwani, "Estimation of effects of alpha music on EEG components by time and frequency domain analysis," in *International Conference on Computer and Communication Engineering (ICCCCE'10)*, 2010: IEEE, pp. 1-5.
- [28] S. W. Phneah and H. Nisar, "EEG-based alpha neurofeedback training for mood enhancement," *Australasian physical & engineering sciences in medicine*, vol. 40, pp. 325-336, 2017.
- [29] L. Zhu, X. Tian, X. Xu, and L. Shu, "Design and evaluation of the mental relaxation VR scenes using forehead EEG features," in *2019 IEEE MTT-S International Microwave Biomedical Conference (IMBioC)*, 2019, vol. 1: IEEE, pp. 1-4.
- [30] Y. Yao, Z. Lian, W. Liu, and Q. Shen, "Experimental study on physiological responses and thermal comfort under various ambient temperatures," *Physiology & Behavior*, vol. 93, no. 1-2, pp. 310-321, 2008.
- [31] Y. Tu, Y. S. Hung, Z. Zhang, and L. Hu, "Prediction of pain perception using multivariate pattern analysis of laser-evoked EEG oscillations," in *2014 13th International Conference on Control Automation Robotics & Vision (ICARCV)*, 2014: IEEE, pp. 13-16.
- [32] J. Teo, L. H. Chew, J. T. Chia, and J. Mountstephens, "Classification of affective states via EEG and deep learning," *International Journal of Advanced Computer Science and Applications*, vol. 9, no. 5, 2018.
- [33] T. M. Hansen, C. Graversen, J. B. Frøkjær, A. E. Olesen, M. Valeriani, and A. M. Drewes, "Single-sweep spectral analysis of contact heat evoked potentials: a novel approach to identify altered cortical processing after morphine


treatment," *British Journal of Clinical Pharmacology*, vol. 79, no. 6, pp. 926-936, 2015.

- [34] M. Aslan, M. Baykara, and T. Alakuş, "Analysis of brain areas in emotion recognition from EEG signals with deep learning methods," *Multimedia Tools and Applications*, vol. 83, pp. 1-30, 09/21 2023, doi: 10.1007/s11042-023-16696-w.


附錄



附圖 1 第一位受試者於臨床模擬實驗三個特徵



附圖 2 第二位受試者於臨床模擬實驗三個特徵



附圖 3 十一種部位於 Cz 電極位兩種狀態下三個特徵差異