

## 基於慣性感測與近紅外光之智慧穿戴阻力訓練成效建議系統

專題組員:楊啓宏、許君愷、崔燕宗、李季暉

專題編號:PRJ-NTPUCSIE-003

執行期間:2025 年 09 月至 2026 年 06 月

### 1. 摘要

本研究提出一套智慧穿戴阻力訓練成效建議系統,以手腕穿戴式裝置整合九軸慣性感測元件(IMU)與近紅外光(NIRS)模組,即時監測阻力訓練過程中的動作表現與生理負荷。系統透過向心、離心階段分析以及利用 PPG 訊號估計  $VO_2$ ,作為生理負荷評估依據。分析結果透過行動應用程式即時回饋使用者,並於訓練後提供摘要與建議。預期本系統可應用於一般健身、居家訓練、臨床復健,協助使用者在安全狀況下提升阻力訓練效果。

### 2. 簡介

近年來,隨著健康意識提升與穿戴式裝置普及,智慧健身與數據化訓練系統逐漸受到重視。美國運動醫學會(American College of Sports Medicine, ACSM) 2026 全球健身趨勢調查指出,穿戴式科技(wearable technology)為 2026 年第一大健身趨勢,行動運動應用程式(mobile exercise Apps)亦位居第四,顯示使用者對即時監測與個人化訓練輔助工具的需求持續增加 [1]。然而,穿戴式裝置與 App 的普及並不代表現有系統已能完整解決阻力訓練(resistance training)中的訓練品質評估問題。過去研究指出,多數商用阻力訓練追蹤應用程式仍偏重於重量與重複次數等紀錄,較難進一步分析每一動作的執行品質[2]。

阻力訓練成效並非僅由重量、重複次數與組數決定,而是受到訓練量、休息時間、動作速度、動作節奏與接近力竭程度等多種訓練變項影響。ACSM 阻力訓練指引指出,不同訓練目標需採用不同訓練處方,例如肌肥大、爆發力與局部肌耐力訓練皆對負荷、速度、反覆次數與休息時間有不同要求 [3]。因此,若系統僅記錄完成了幾下,仍難以判斷使用者是否真正以符合訓練目標且安全的方式完成動作。

此外,疲勞累積不僅會影響訓練表現,也可能造成動作品質下降。過去研究指出,肌肉疲勞會降低肌肉產生力量或功率的能力,並影響肌肉功能與運動表現 [4];在阻力訓練情境中,動作速度下降也被視為反映神經肌肉疲勞的重要指標之一 [5]。Hooper 等人的研究進一步指出,短休息、高疲勞的阻力訓練會改變深蹲相關關節生物力學與動作技術,若未適當監測,可能增加傷害風險 [6]。因此,若能在訓練過程中即時偵測疲勞造成的動作節奏改變與動作品質下降,便有機會及早提醒使用者調整負荷、延長休息或修正動作,而不是在訓練結束後才回顧紀錄。

基於上述背景,本研究建立一套能將動作品質、主觀疲勞與生理負荷轉換為個人化建議的智慧阻力

訓練回饋系統。

### 3. 相關研究

#### A. 肌肉受張力時間與動作節奏

在阻力訓練中,肌肉受張力時間(time under tension, TUT)向心收縮時間、離心收縮時間與單次動作持續時間,可用來描述動作節奏(movement tempo)與每一動作的執行特徵。Wilk 等人的回顧性研究指出,動作節奏,也就是向心階段、離心階段與停頓/等長收縮階段的時間安排,會影響訓練刺激與肌力、肌肥大相關適應 [7]。然而,TUT 並不是越長越好。Schoenfeld 等人的統合分析指出,當單次動作持續時間介於 0.5–8 秒時,肌肥大結果可能相近,而過慢的單次動作持續時間不一定更有利 [8]。因此,TUT 更適合作為描述動作節奏、動作控制與訓練品質的過程指標,而非單一訓練成效指標。

#### B. 阻力訓練與疲勞監測

阻力訓練也需要適當的主觀疲勞管理。若訓練負荷或努力程度過低,可能無法提供足夠訓練刺激;但若每組長期過度接近力竭,則不一定帶來額外效益,反而可能造成過度疲勞、恢復不足與動作品質下降。近年的系統性回顧與網絡統合分析指出,在訓練至自主力竭(volitional failure)的條件下,不同負荷對肌肥大效果可能相近,但較高負荷對最大肌力提升較有利,顯示不同訓練目標需要不同負荷與疲勞管理策略 [9]。此外,RPE 已被應用於阻力訓練強度監測,可作為使用者主觀努力程度與訓練負荷調整的重要依據 [10]。

#### C. PPG and $VO_2$ 評估

氧氣攝取量(oxygen uptake,  $VO_2$ )代表人體在運動過程中利用氧氣的能力,是評估運動強度的重要指標。隨著運動強度提升,人體對氧氣的需求也會增加,因此  $VO_2$  能有效反映能量消耗、身體代謝狀態及疲勞累積程度,廣泛應用於運動表現分析與訓練監控。在生理負荷估測方面,光體積變化描記法(photoplethysmography, PPG)是一種低成本、非侵入式光學感測技術,可用於量測組織血容量變化,並已廣泛整合於腕戴式穿戴裝置中 [11]。過去研究已探討使用穿戴式感測器估測氧氣攝取量的可行性,顯示以穿戴式特徵建立  $VO_2$  或代謝負荷替代模型具有研究基礎 [12]。近年也有研究使用穿戴式多波長 PPG 裝置結合機器學習模型進行  $VO_2$  估測,進一步支持 PPG 訊號用於推估運動生理負荷的可行性 [13]。

相較之下,近紅外光譜(near-infrared spectroscopy,

NIRS)可量測局部肌肉氧合狀態,例如肌肉氧飽和度 (muscle oxygen saturation,  $SmO_2$ ) 因此更接近局部肌肉代謝與疲勞反應的監測需求;系統性回顧指出,阻力訓練後  $SmO_2$  具有下降趨勢,顯示 NIRS 可用於觀察肌肉氧合變化 [14]。然而,NIRS 通常需配置於特定肌群,硬體成本與佩戴位置限制較高。因此,本研究以較易整合於穿戴式裝置的 PPG 作為主要生理感測來源,並使用  $VO_2$  Master 可攜式呼氣代謝分析儀作為實驗階段之代謝反應參考工具。已有研究指出, $VO_2$  Master 在多數運動強度下具有可接受的  $VO_2$  與通氣量 (ventilation) 量測效率與再測信度 [15]。透過  $VO_2$  Master 校正 PPG-derived metabolic load,本研究可進一步將生理負荷資訊應用於阻力訓練疲勞與恢復狀態判斷。

#### 4. 研究方法

##### 4.1 系統架構

本系統以手腕穿戴式裝置為核心感測平台,整合 PPG 訊號與 IMU 訊號以達成阻力訓練過程中動作品質與肌肉疲勞之同步監測,並以行動裝置應用程式呈現反饋,形成一套完整之即時感測與回饋架構。

在光學感測方面,系統採用多波段近紅外光源 (670 nm、770 nm、810 nm、850 nm 與 950 nm),透過不同波長對血紅素 (hemoglobin, Hb) 與氧合血紅素 (oxyhemoglobin,  $HbO_2$ ) 之吸收特性差異,在手腕進行反射式光學量測。由於不同波長對組織穿透深度與吸收係數不同,可提升對血氧動態變化之敏感度,使量測訊號更能反映局部組織之氧合狀態變化。反射回之光學訊號由光電二極體 (photodiode, PD) 接收,並經由專為生理訊號量測設計之類比前端 (analog front-end, AFE) 進行低雜訊放大與濾波處理,以提升訊號品質並抑制環境光干擾,隨後透過類比數位轉換器 (ADC) 轉換為數位訊號。

在動作監測方面,系統整合九軸慣性感測元件,即三軸加速度計、三軸陀螺儀與三軸磁力計,以取得使用者於阻力訓練過程中的運動軌跡、姿態變化與動作節奏資訊。IMU 與 PPG 之資料同步輸入至 Luckfox Pico Zero 邊緣運算平台,於裝置端即時進行資料前處理與特徵萃取,包括訊號去噪、校正、動作分段 (segmentation) 與階段辨識 (concentric/eccentric phase detection)。

在邊緣運算層,系統進一步整合動作特徵與光學訊號特徵,耗氧量估算 ( $VO_2$  estimation),以反映訓練過程中的內在生理負荷,估測疲勞程度。經分析後之結果透過藍牙傳輸至行動裝置,並由應用程式進行即時視覺化呈現與訓練建議生成,使使用者能於訓練過程中即時掌握動作品質與疲勞狀態,整體系統如圖 1 所示。




圖 1. 系統架構

##### B. 硬體設計

本系統以手腕穿戴式裝置來收集資料,裝置由自製腕帶以及自製 3D 列印外殼所組成,如圖 2 所示。



圖 2. 智慧穿戴式裝置

本研究開發之腕帶穿戴式裝置,包含電源穩壓模組、近紅外光 (NIRS) 模組、慣性感測 (IMU) 模組 (分別對應圖 3 中(1)~(3)區塊) 以及 Luckfox Pico Zero 嵌入式邊緣計算實驗板、鋰電池。電源穩壓模組負責將電池或系統供電電壓轉換成各子模組所需之穩定工作電壓,以確保光學量測與感測電路運行。NIRS 模組透過近紅外光發光二極管 (LED) 對腕部進行照射,所獲得之反射光強度值透過光電感測與類比前端電路轉換為對應之電壓訊號,並進一步透過類比數位轉換,轉為數位資料,並將數據傳到電腦中進行機器學習模型訓練。整體的電路設計如圖 3 所示。本研究選用 Marktech MTMD6788594SMT6 這一顆 LED 發射光源,將五個近紅外波長整合於單一封裝,使光路穩定、波段一致性高且適合穿戴式空間。這五個波長的組合可提供足夠光譜特徵,使 MBLL 能有效拆解  $HbO_2$  與 Hb 的變化,進而反映  $VO_2$  趨勢。在 PCB 板的設計上,採雙面配置方式,於正面放上 IMU,背面放上 PPG 相關元件,如圖 4 所示。

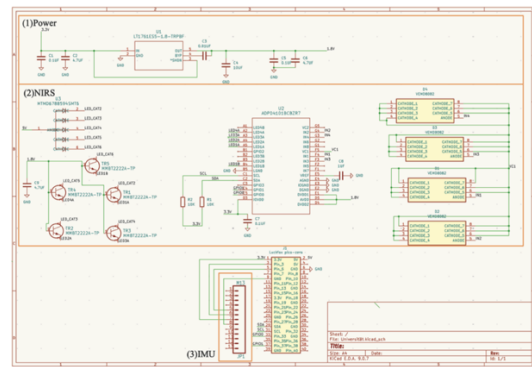


圖 3. 系統電路設計圖




圖 4. PCB 板

## C. 軟體設計

### 1) 軟體架構

本研究之模型設計採用多模態架構，分別以慣性感測元件 (IMU) 資料與 (PPG) 訊號為核心，建立動作分析模型、生理負荷估測模型與疲勞評估模型。整體模型流程可分為三個階段：第一階段利用 IMU 進行阻力訓練動作辨識與動作品質分析；第二階段利用多波段 PPG 訊號估測訓練過程中的相對代謝負荷；第三階段則整合動作特徵、生理特徵與個人化參數，推估使用者之疲勞程度與訓練狀態，整體模型架構如圖 5 所示。

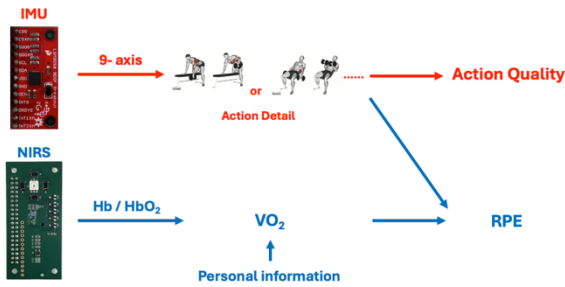


圖 5. 阻力訓練動作示意圖

### 2) 向心、離心切割模型

本研究的 IMU 動作監測模組以單一 6 軸 IMU 作為輸入，包含三軸加速度與三軸角速度訊號。穿戴式慣性感測器已被廣泛應用於運動辨識與次數計算等任務 [16],[17]。本研究在此基礎上，進一步將 IMU 訊號用於阻力訓練中的每一下動作的時間結構分析。系統首先接收原始 6 軸 IMU 訊號，並以約 3 秒的時間視窗作為模型輸入。相較於只靠人工設計特徵或訊號峰值來數次數的方法，本研究採用 Causal CNN 學習 IMU 訊號中的短時間動作變化，例如動作方向、速度節奏與週期轉換，如圖 6 所示。




圖 6. 向心、離心切割模型

選擇 Causal CNN 作為主要模型，是因為向心、離心階段切割屬於精細的時間序列切割任務。系統不只是要判斷某一段訊號是哪個動作，而是要在連續 IMU 訊號中判斷每個時間點屬於向心、離心或其他狀態，並找出階段之間的轉換位置。這類任務需要模型理解前後時間點之間的連續變化，例如動作方向改變、速度節奏變化與週期轉換。相較於 RF 等傳統模型較依賴單一視窗內的統計特徵，CNN 能直接在時間軸上學習局部動作模式，因此更適合用於向心、離心這類細部階段切割。既有時間序列切割研究也顯示，序列模型可用於逐時間點的動作切割，並能捕捉不同時間尺度的動作片段 [18]。此外，單一 6 軸 IMU 搭

配 CNN 已被應用於即時步態階段切割，代表 CNN 不只適合做整段分類，在單一下 repetition 也能提供更精細的逐時間點階段判斷 [19]。

本模型的設計是先切割階段，再建構每一下 repetition。阻力訓練中的 movement tempo 常以離心、停頓、向心等階段時間描述，表示各階段持續時間與肌肉張力持續時間本身就是重要的訓練資訊 [7]。因此，先估計每個時間點的向心離心狀態，再根據向心與離心的轉換建構每一下 repetition，使次數計算不只是單純找訊號峰值，而是由動作階段結構推導而來。此設計受到 DS-MS-TCN 小標籤概念的啟發。該方法並非直接辨識一整段完整動作，而是先辨識較小的動作片段，再依據這些動作片段的時間順序推估完整動作 [18]。本研究延伸此概念，將一次阻力訓練 repetition 視為由向心與離心階段所構成，先判斷每個時間點所屬的動作階段，再由這些階段組合成每一下 repetition。透過這種由小階段組合成完整動作的方式，比直接切割下 repetition 再細分向心離心階段，更能保留動作內部結構和提高辨識穩定性。系統最終輸出包含動作類別、次數、TUT、向心/離心階段時間與向心/離心比例等等。

### 3) 疲勞預估模型

系統首先接收來自穿戴裝置的多模態感測資料，包括 10 通道 PPG 訊號、6 軸 IMU 訊號，以及由動作辨識模組所提供的訓練結構資訊，例如動作類型、組數與次數。此外，使用者的基本資料，如身高、體重、年齡與性別，也會一併納入模型輸入。所有資料經時間同步與 causal trailing window 處理後，轉換為即時可用的特徵表示。整體架構可分為 VO<sub>2</sub> 估算模型與 RPE/Fatigue Estimation 兩個階段。

在第一階段的 VO<sub>2</sub> Estimation 中，系統將 PPG、IMU 與運動狀態特徵輸入至 Multiscale Blend 模組。此模組同時利用不同時間尺度的視窗建構多組模型，以兼顧短期動作變化與較長時間的生理反應。其中較長視窗可捕捉氧氣攝取與恢復過程的慢速變化，而較短視窗則保留局部動作造成的即時波動。本研究分別建立 XGBoost (120 s、45 s smoothing)、XGBoost (90 s、30 s smoothing) 以及 CatBoost (120 s、45 s smoothing) 三組模型。其中 XGBoost 在非線性回歸問題上具有優異表現，而 CatBoost 則能提供不同樹模型的補充資訊。最後透過加權融合整合各模型輸出，產生最終的 VO<sub>2</sub> Estimate，使系統能在即時條件下穩定估測使用者的氧氣攝取量，如圖 7 所示。

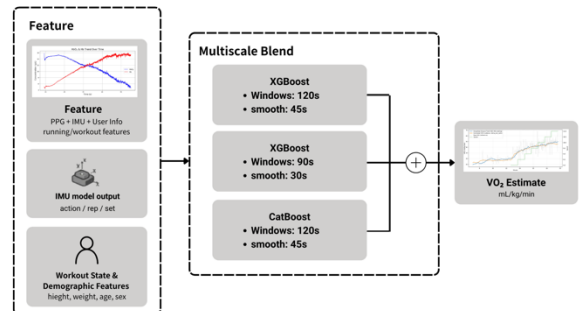


圖 7. VO<sub>2</sub> 估算模型圖

得到  $VO_2$  Estimate 後，系統進入第二階段的 RPE/Fatigue Estimation。此階段除使用估測之  $VO_2$  外，亦整合 IMU 所反映的動作品質、訓練節奏、TUT 以及訓練資訊，建立疲勞相關特徵。透過這些特徵，模型不僅能觀察當前動作狀態，也能反映訓練過程中的疲勞累積現象。RPE Estimator 採用雙分支架構。Tabular Branch 使用 ExtraTrees 樹模型直接學習單一 Rep 特徵與 RPE 之間的非線性關係。由於樹模型對結構化特徵具有良好的建模能力，且不易受到特徵尺度影響，因此適合作為穩定的基準模型。另一方面，Sequence Branch 將同一受試者於相同動作下的多個 Rep 視為連續序列，利用深度學習模型學習疲勞隨訓練進行而逐漸累積的時間依賴性。本研究比較 LSTM、GRU、CNN-LSTM 與 TCN 等序列模型，最終以表現較佳的 CNN-LSTM 與 GRU 作為主要深度模型。最後，兩個分支的預測結果透過 Nested Ensemble 機制進行融合，並利用驗證資料選擇最佳模型組合與權重，以降低過度擬合與資料洩漏風險，提升模型在未知受試者上的泛化能力，如圖 8 所示。

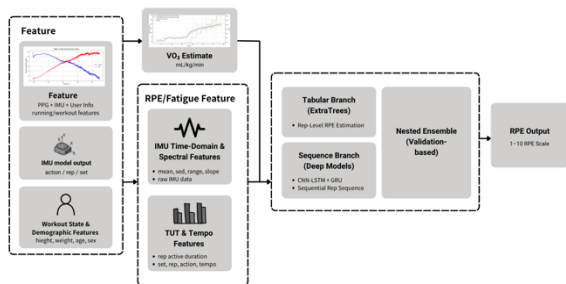


圖 8. 疲勞估算模型圖

疲勞模型最終輸出包含兩項指標。第一項為連續型  $VO_2$  數值，可作為即時生理負荷監測與後續分析依據；第二項為連續型 RPE 預測結果，並可進一步映射至 1 至 10 級主觀疲勞量表，提供使用者對當前訓練負荷與疲勞程度的即時評估。透過此兩階段架構，系統得以同時整合心肺代謝資訊與動作表現資訊，從不同時間尺度描述使用者的訓練負荷與疲勞狀態。

## 5. 實驗設計

本實驗在新北市恩主公醫院申請人體研究倫理審查 (IRB No.: ECKIRB1150203)，招募 30 位年齡介於 20 至 55 歲之健康男女受試者，所有受測者均了解受測流程並簽署受測者同意書。整體實驗流程分為兩日進行，分別為阻力訓練資料收集與最大攝氧量 ( $VO_{2max}$ ) 測試，以同時取得動作訊號、生理負荷與代謝指標之對應關係。

於實驗過程中，受試者需同步配戴  $VO_2$  Master 可攜式呼氣代謝分析儀 (如圖 9 所示) 以量測即時攝氧量 ( $VO_2$ )，並同時穿戴本研究所設計之智慧穿戴裝置 (如圖 10 所示) 進行動作與光學訊號之量測。透過多模態資料之同步蒐集，可建立動作特徵、心血管反應與代謝負荷之關聯性，作為後續模型訓練與驗證之依據。

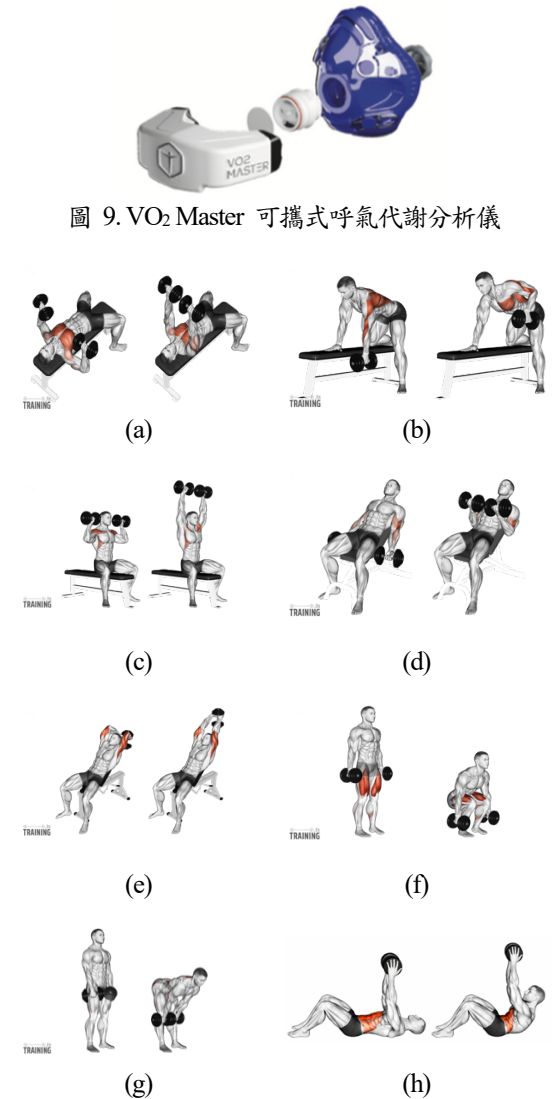


圖 9.  $VO_2$  Master 可攜式呼氣代謝分析儀

圖 10. 阻力訓練動作示意圖。(a) 啞鈴臥推，(b) 單手啞鈴划船，(c) 啞鈴肩推，(d) 啞鈴二頭彎舉，(e) 啞鈴三頭彎舉，(f) 啞鈴深蹲，(g) 啞鈴羅馬尼亞硬舉，(h) 啞鈴負重卷腹

受試者將進行下列八組阻力訓練動作 (如圖 13 所示) 為了在不造成過度疲勞的情況下設定合理訓練重量，本研究採用次最大測試 (submaximal test) 估算各啞鈴動作的 1RM，並取其 60-70% 作為實驗用訓練負荷。針對每一個啞鈴動作，先以極輕重量進行 8-10 下動作練習，以確認動作型態與安全性。逐步增加重量，請受試者在可接受的負荷下完成 3-10 次，並記錄某一重量下可完成之最大次數 (例如 20kg 可完成 8 次)。透過標準 1RM 估算法 (如 Epley 或 Brzycki 公式) 估算該動作之 1RM，再取 60-70% 1RM 作為之後正式阻力訓練階段的實驗重量。此階段不配戴  $VO_2$  面罩，只配戴 IMU 以同步檢查各動作波形品質，避免過早累積全身疲勞。阻力訓練測試前需完成前置暖身與次最大負荷測試估算各動作之一回最大肌力 (one-repetition maximum, 1RM) 以作為正式訓練負荷之依據。

為建立個別化之代謝基準，本研究安排受試者進行標準化之  $VO_2$  max 漸進負荷測試。測試過程中，透

過逐步增加運動強度（如跑步機速度或坡度），使受試者持續運動直至達到生理極限或符合終止條件。於測試過程中即時量測  $VO_2$  與心率變化，取得每位受試者之最大攝氧量。此  $VO_2$  max 數據將作為後續  $VO_2$  proxy 模型校正之基準，並用於計算相對運動強度（ $\%VO_2$  max），進一步建立動作特徵與代謝負荷之對應關係。透過此個別化校正流程，可提升系統在不同使用者間之泛化能力，使疲勞評估與訓練建議更具個人化與準確性。

## 6. 結果

### A. 向心、離心切割模型

本研究將所提出向心、離心切割模型與 Peak、RF、Causal TCN-lite 及 BiLSTM 進行比較。Peak 代表常見的 rule-based count baseline；RF 代表輕量化傳統機器學習方法；Causal TCN-lite 代表可用於 temporal segmentation 的 causal convolution baseline；BiLSTM 則作為能利用雙向時間資訊的 sequence modeling baseline。TCN 類模型常用於 temporal action segmentation，而 BiLSTM 可同時利用過去與未來資訊進行序列建模，因此適合作為本研究的比較基準。

本研究方法在 structured repetition-level output 上表現最佳，Rep IoU-F1@50 達 87.40%，Phase IoU-F1@50 達 71.60%，TUTMAE 為 0.601。Peak 雖然具有較低的 Count MAE，但僅能提供 count-level output，無法估計 C/E phase segmentation 或 phase duration。相較於 RF、Causal TCN-Lite 與 BiLSTM，本研究方法在 rep boundary、phase segmentation 與 TUT estimation 上取得較佳平衡，因此被選為最終 IMU segmentation model，如表 1 所示。

表 1. 本研究所提切割模型與其它研究之比較

Model	Count MAE	Rep IoU-F1@50	Phase IoU-F1@50	C/E Ratio MAE
Ours	0.973	<b>87.40%</b>	<b>71.60%</b>	<b>0.601</b>
Peak	<b>0.927</b>	74.80%	N/A	N/A
RF	1.427	82.40%	63.60%	1.675
Causal TCN-Lite	3.214	77.80%	67.10%	1.238
BiLSTM	2.077	78.00%	62.70%	1.331

在辨識 8 種阻力訓練動作中模型在多數情況下能正確辨識動作類別，而錯誤主要發生於動作特徵不明顯或訊號較接近非標準動作區段時。

此外，模型在動作之間的直接混淆相對少見。較明顯的例子為 Shoulder 有 12.5% 被判為 Crunch，Row 有 7.1% 被判為 RDL；其餘多數類別之間的誤判比例接近 0%。此結果顯示，action recognition branch 能提供可靠的動作脈絡，支援後續 action-conditioned repetition refinement，使系統能根據不同訓練動作調整 repetition segmentation 與 phase interpretation。整體而言，模型在各主要動作上的辨識結果穩定，正確分類比例多集中於對角線，顯示模型能有效區分不同訓練動作，如圖 11 所示。




圖 11.8 種阻力訓練動作混淆矩陣

### B. $VO_2$ 預測與疲勞預測

不同  $VO_2$  預測模型於嚴格留一受試者交叉驗證（leave-one-subject-out, LOSO）評估下之結果。所提出的 Multiscale Blend 模型達到最佳表現，獲得  $R^2 = 0.7070$ 、 $MAE = 1.49$  mL/kg/min 及  $RMSE = 1.89$  mL/kg/min，優於所有單一模型。其中，XGBoost(120 s、smooth 45 s) 為表現最佳的單一模型，而透過多時間尺度與多模型融合後，預測準確度進一步提升，顯示不同時間尺度的生理資訊具有互補效果，有助於提高模型的泛化能力與穩定性。如表 2 所示。

表 2. 健身即時  $VO_2$  預測模型

Model	$R^2$	MAE	RMSE	rMAE
Ours	<b>0.7070</b>	<b>1.4901</b>	<b>1.8865</b>	<b>0.1576</b>
XGBoost (120s, smooth45)	0.6862	1.5412	1.9526	0.1630
CalBoost (120s, smooth45)	0.5887	1.7925	2.2352	0.1896
ExtraTrees (120s, absolute)	0.5320	1.9214	2.3843	0.2032

在疲勞預測結果主要集中於對角線附近，代表模型能有效估計受試者的主觀疲勞程度。大部分錯誤發生於相鄰 RPE 等級之間，例如 RPE 5、6、7 容易被預測為前後一級，顯示模型已能掌握疲勞變化趨勢。整體而言，模型達到  $MAE = 0.724$ 、 $Within \pm 1 Accuracy = 88.6\%$ ，表示大多數預測結果均落在真實 RPE 的  $\pm 1$  範圍內，具備良好的實際應用價值，如圖 12 所示。




圖 12. RPE 預測混淆矩陣

表 3. 不同疲勞模型比較表

Criteria	Baek et al. [20]	Thomas and Wahlström [21]	King et al. [22]	Smiley et al. [23]	Ours
Exercise Types	Bench press	Bicep curl	Preacher curl	Cycling	8 exercises
Exercise Classification	No	No	No	No	8-class
Fatigue Quantification	Continuous RPE	Multi-level RPE	Binary RIR ≤ 2	High/low exertion	Continuous RPE
Real-Time Capability	Partial	No	Yes	Partial	Yes
Performance	±1 RPE > 93%	±1 Acc. = 85.9%	Acc. = 92.7%	Acc. = 78.3%	±1 Acc. = 88.6%
Edge computing	No	No	Yes	No	Yes
Feedback	No	No	Yes	No	Yes

### C. 疲勞模型比較

過去的研究大多只解決疲勞預測中的某一部分。例如 Baek et al. [20] 的 RPE 預測表現很好，但它使用的是機台力量資料，因此不適合一般手腕穿戴式使用。Thomas and Wahlström [21] 使用 IMU 和 EMG 預測 RPE，並證明 rep-level 特徵與離心時間很重要，但它主要針對單一 bicep curl 動作。King et al. [22] 則證明單一手腕 IMU 可以即時偵測接近力竭狀態，但它只做二分類，無法輸出連續型 RPE。

我們的系統有以下四個創新。第一，我們不是只針對單一動作，而是支援 8 種阻力訓練動作分類，並將 action、set、rep、phase 等動作結構資訊提供給疲勞模型。第二，我們不是只判斷累或不累，也不是只判斷是否接近力竭，而是輸出連續型 RPE，並可轉成 1-10 級顯示。第三，我們不只使用 IMU 動作特徵，也加入 PPG-based VO<sub>2</sub> 作為生理與代謝負荷特徵，因此模型可以同時考慮身體內部負荷與外部動作退化。第四，我們的特徵建構只使用當下與過去資料，較符合即時訓練回饋的使用情境。

既有研究可能在單一任務上表現很好，但常受限於機台、單一動作、離線分析、二分類輸出或缺乏生理特徵；本研究則嘗試把手腕 PPG/IMU、8-class action recognition、VO<sub>2</sub> estimation、rep-level 動作退化特徵與連續型 RPE 預測整合成一個更接近實際阻力訓練場景的疲勞預測框架。

### D. 手機應用程式



圖 13. 智慧肌力訓練效能回饋系統

在行動端系統開發方面，本研究採用 Flutter 跨平台框架建構 iOS 與 Android 應用程式，以提升系統普及性、裝置相容性與後續維護便利性。透過單一程式碼基底，可同時支援雙平台，降低重複開發成本。

使用者介面設計上，系統提供圖文化操作引導，協助使用者快速完成裝置配對與基本設定。首次使用時，使用者需輸入年齡、性別與體重等個人資料，作為模型推論與指標正規化之參考，以提升分析結果的個人化程度。

訓練過程中，行動端會即時顯示穿戴裝置回傳之分析結果，包含當前訓練動作、累計次數、動作品質指標與疲勞指數，讓使用者能即時調整動作節奏與姿態。訓練結束後，系統自動產生訓練摘要，內容包含訓練總時長、各動作次數與時間分布，並以人體前後視圖呈現主要活動肌群與負荷程度，進一步提供訓練評估與後續建議，如圖 13 所示。

### 7. 結論

本研究證明了以穿戴式 IMU 和 PPG 建立阻力訓練即時回饋系統的可行性。相較於傳統健身 App 主要記錄重量、組數與次數，本系統能同時考慮動作品質、生理負荷與疲勞狀態，並將其轉換為可供使用者理解的訓練回饋。未來若能進一步擴大受試者數量，增加不同訓練強度與動作種類，並導入個人化校正與長期追蹤機制，系統將有機會應用於智慧健身、運動表現監控與居家訓練安全輔助等場域。

### 8. 參考文獻

- [1] C. R. McAvoy et al., "2026 ACSM Worldwide Fitness Trends: Future Directions of the Health and Fitness Industry," *ACSM's Health & Fitness Journal*, vol. 29, no. 6, pp. 16–33, 2025.
- [2] W. Coates and J. Wahlström, "LEAN: Real-Time Analysis of Resistance Training Using Wearable Computing," *Sensors*, vol. 23, no. 10, 2023, Art. no. 4602.
- [3] American College of Sports Medicine, "Progression Models in Resistance Training for Healthy Adults," *Medicine & Science in Sports & Exercise*, vol. 41, no. 3, pp. 687–708, 2009.
- [4] R. M. Enoka and J. Duchateau, "Muscle fatigue: What, why and how it influences muscle function," *The Journal of Physiology*, vol. 586, no. 1, pp. 11–23, 2008.
- [5] L. Sánchez-Medina and J. J. González-Badillo, "Velocity loss as an indicator of neuromuscular fatigue during resistance training," *Medicine & Science in Sports & Exercise*, vol. 43, no. 9, pp. 1725–1734, 2011.
- [6] D. R. Hooper, T. K. Szivak, L. J. DiStefano, B. A. Comstock, C. Dunn-Lewis, J. M. Apicella, N. A. Kelly, B. C. Creighton, J. S. Volek, C. M. Maresh, and W. J. Kraemer, "Effects of resistance training fatigue on joint biomechanics," *Journal of Strength and Conditioning Research*, vol. 27, no. 1, pp. 146–153, 2013.
- [7] M. Wilk, A. Zajac, and J. J. Tufano, "The Influence of Movement Tempo During Resistance Training on Muscular Strength and

- Hypertrophy Responses: A Review,” *Sports Medicine*, vol. 51, pp. 1629–1650, 2021.
- [8] B. J. Schoenfeld, D. I. Ogborn, and J. W. Krieger, “Effect of Repetition Duration During Resistance Training on Muscle Hypertrophy: A Systematic Review and Meta-Analysis,” *Sports Medicine*, vol. 45, no. 4, pp. 577–585, 2015.
- [9] P. Lopez *et al.*, “Resistance Training Load Effects on Muscle Hypertrophy and Strength Gain: Systematic Review and Network Meta-analysis,” *Medicine & Science in Sports & Exercise*, vol. 53, no. 6, pp. 1206–1216, 2021.
- [10] E. R. Helms, M. R. Cronin, A. Storey, and M. C. Zourdos, “Application of the Repetitions in Reserve-Based Rating of Perceived Exertion Scale for Resistance Training,” *Strength and Conditioning Journal*, vol. 38, no. 4, pp. 42–49, 2016.
- [11] K. B. Kim, J. Baek, and S. H. Lee, “Photoplethysmography in Wearable Devices: A Comprehensive Review of Technological Advances, Current Challenges, and Future Directions,” *Electronics*, vol. 12, no. 13, 2023, Art. no. 2923.
- [12] M. M. H. Shandhi, W. H. Bartlett, J. A. Heller, M. Etemadi, A. Young, T. Ploetz, and O. T. Inan, “Estimation of Instantaneous Oxygen Uptake During Exercise and Daily Activities Using a Wearable Cardio-Electromechanical and Environmental Sensor,” *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 3, pp. 634–646, 2021.
- [13] C.-T. Hsiao, C. Tong, and G. L. Coté, “Machine Learning-Based VO<sub>2</sub> Estimation Using a Wearable Multiwavelength Photoplethysmography Device,” *Biosensors*, vol. 15, no. 4, 2025, Art. no. 208.
- [14] C. Miranda-Fuentes, L. J. Chiroso-Ríos, I. M. Guisado-Requena, P. Delgado-Floody, and D. Jerez-Mayorga, “Changes in Muscle Oxygen Saturation Measured Using Wireless Near-Infrared Spectroscopy in Resistance Training: A Systematic Review,” *International Journal of Environmental Research and Public Health*, vol. 18, no. 8, 2021, Art. no. 4293.
- [15] A. H. K. Montoye, M. T. Vondrasek, J. P. Hancock, A. E. Wirth, J. M. Pfeiffer, and R. C. Laurson, “Validity and Reliability of the VO<sub>2</sub> Master Pro for Oxygen Consumption and Ventilation Assessment,” *International Journal of Exercise Science*, vol. 13, no. 4, pp. 1382–1401, 2020.
- [16] D. Strömbäck, S. Huang, and V. Radu, “MM-Fit: Multimodal Deep Learning for Automatic Exercise Logging across Sensing Devices,” *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, vol. 4, no. 4, 2020, Art. no. 168.
- [17] D. Soro *et al.*, “Recognition and Repetition Counting for Complex Physical Exercises with Deep Learning,” *Sensors*, vol. 19, no. 3, 2019, Art. no. 714.
- [18] M. Shang *et al.*, “DS-MS-TCN: Otago Exercises Recognition With a Dual-Scale Multi-Stage Temporal Convolutional Network,” *IEEE J. Biomed. Health Inform.*, vol. 28, no. 12, pp. 7138–7150, Dec. 2024.
- [19] J.-D. Sui, W.-H. Chen, T.-Y. Shing, and T.-S. Chang, “Real-Time Wearable Gait Phase Segmentation for Running and Walking,” in *Proc. IEEE Int. Symp. Circuits Syst. (ISCAS)*, Seville, Spain, 2020, pp. 1–5.
- [20] J.-Y. Baek, J.-H. Kwon, H. Khan, and M.-C. Lee, “Machine Learning-Driven Muscle Fatigue Estimation in Resistance Training with Assistive Robotics,” *Sensors*, vol. 25, no. 21, 2025, Art. no. 6588.
- [21] J. Thomas and J. Wahlström, “Estimation of Resistance Training RPE using Inertial Sensors and Electromyography,” arXiv preprint arXiv:2510.03197, 2025.
- [22] G. King, M. Azeem, S. Noblitt, R. Zand, and H. Valafar, “Rep Smarter, Not Harder: AI Hypertrophy Coaching with Wearable Sensors and Edge Neural Networks,” arXiv preprint arXiv:2512.11854, 2025.
- [23] A. Smiley *et al.*, “Exercise Exertion Levels Prediction Based on Real-Time Wearable Physiological Signal Monitoring,” in *Healthcare Transformation with Informatics and Artificial Intelligence*, ser. *Studies in Health Technology and Informatics*, vol. 305, pp. 172–175, 2023.
- [24] L. Greig, C. Stephens Hemingway, R. Aspe, J. A. Cooper, D. Cornfort, and L. A. Swinton, “Autoregulation in Resistance Training: Addressing the Inconsistencies,” *Sports Medicine*, vol. 50, pp. 1873–1887, 2020.
- [25] T. T. de Beukelaar and D. Mantini, “Monitoring Resistance Training in Real Time with Wearable Technology: Current Applications and Future Directions,” *Bioengineering*, vol. 10, no. 9, 2023, Art. no. 1085.
- [26] T. A. Swain, M. A. McNary, A. W. H. Runacres, and K. A. Mackintosh, “The Role of Multi-Sensor Measurement in the Assessment of Movement Quality,” *Sports Med.*, vol. 53, no. 12, pp. 2477–2504, 2023.
- [27] M. A. O’Reilly, P. Slevin, T. Ward, and B. Caulfield, “A Wearable Sensor-Based Exercise Biofeedback System,” *JMIR mHealth and uHealth*, vol. 6, no. 1, 2018, Art. no. e33.
- [28] T. J. Hamaoka, K. K. McCully, V. L. Quaresima, K. Yamamoto, and B. Chance, “Near-infrared spectroscopy/imaging for monitoring muscle oxygenation and oxidative metabolism in healthy and diseased humans,” *J. Biomed. Opt.*, vol. 12, no. 6, 2007, Art. no. 062105.
- [29] B. Grassi and M. Quaresima, “Near-infrared spectroscopy and skeletal muscle oxidative function in vivo in health and disease,” *J. Biomed. Opt.*, vol. 21, no. 9, 2016, Art. no. 091313.
- [30] J. Liu, Q. Tao, and B. Wu, “Dynamic Muscle Fatigue State Recognition Based on Deep Learning Fusion Model,” *IEEE Access*, vol. 11, pp. 95079–95091, 2023.
- [31] R. D. Giminiiani *et al.*, “A wearable integrated textile EMG and muscle oximetry system for monitoring exercise-induced effects: A feasibility study,” in *Proc. IEEE Int. Symp. Med. Meas. Appl. (MeMeA)*, Rome, Italy, Jun. 11–13, 2018, pp. 1–5.
- [32] A. Kimoto, Y. Oishi, and M. Machida, “A Wireless 2-Channel Layered EMG/NIRS Sensor System for Local Muscular Activity Evaluation,” *Sensors*, vol. 23, no. 20, Oct. 2023, Art. no. 8394.
- [33] Y. Liu, J. Zhou, D. Zhou, and L. Peng, “Quantitative Assessment of Muscle Fatigue Based on Improved Gramian Angular Difference Field,” *IEEE Sens. J.*, vol. 24, no. 20, pp. 32966–32980, Oct. 2024.
- [34] C. Pham, Y. Huang, M. Hoai, and L. T. Nguyen, “Class-Agnostic Repetitive Action Counting Using Wearable Devices,” *IEEE Trans. Hum. Mach. Syst.*, vol. 55, no. 3, pp. 1–15, 2025.
- [35] J. Lim, Y. Oh, and Y. Choi, “uLift: Adaptive Workout Tracker Using a Single Wrist-Worn Accelerometer,” *IEEE Access*, vol. 12, pp. 21710–21722, 2024.