

國立台北大學資訊工程學系專題報告

透過人工智慧結合近紅外光譜量化肌肉疲勞的可攜式即時感測系統

A Portable Real-Time Sensing System for Quantifying Muscle Fatigue Using Artificial Intelligence Combined with Near-Infrared Spectroscopy

專題組員：柯亭妤、張裴凱、陳映瑋、曾子倫

專題編號：PRJ-NTPUCSIE-113-006

執行期間：113 年 9 月至 114 年 6 月

1. 摘要


肌肉疲勞是指在劇烈和反復的肌肉收縮後發生的生理現象。本篇研究將開發一套智能的穿戴式系統，利用穿戴式裝置上的近紅外光譜(near-infrared spectroscopy, NIRS)感測器擷取使用者血液中肌肉血氧數據，包含氧合血紅素以及脫氧血紅素。將資料傳入 Luckfox Pico Mini 嵌入式邊緣計算板子，再經由板子中訓練過的人工智慧 (artificial intelligence, AI) 模型將資料轉為使用者肌肉疲勞的分級資訊，並透過 LED 或蜂鳴器告知使用者肌肉疲勞程度，讓使用者可以避免過度運動造成肌肉傷害。為了可以在 Luckfox Pico Mini 中進行即時的人工智慧模型計算，我們預計使用長短期記憶網路 (LSTM) 結合一維卷積神經網路 (CNN) 進行模型的訓練，再將訓練完成的模型移植到 Luckfox Pico Mini 中執行，並根據偵測到的數據對應到我們從研究中統整量化出來的疲勞分級，達到及時提醒即將到來的肌肉疲勞。

2. 簡介

隨著健身風氣盛行，人們對運動效能與健康的重視日益提高。無論是專業運動員或一般愛好者，提升表現與避免傷害皆是共同目標。然而，高強度運動常導致肌肉疲勞，進而影響表現與增加受傷風險，甚至危害長期健康。而目前多數肌肉疲勞評估工具成本高、操作複雜，且無法即時提供數據，限制了普及與應用。為解決此問題，本研究將開發一套便捷、準確、經濟的智能穿戴式系統，運用近紅外光譜 (NIRS) 監測肌肉氧合與脫氧血紅素變化，藉由嵌入式邊緣計算裝置 (Luckfox Pico Mini) 與 AI 模型進行即時分析與反饋，旨在實現肌肉疲勞的量化、即時監測與評估，並兼顧系統的便攜性與普及性，為運動訓練、康復與研究提供可靠數據支持。

3. 專題進行方式

我們預計開發出一套智能可量化肌肉疲勞的穿戴式裝置，整體架構如圖一所示。




圖一、系統架構圖

3.1. 硬體架構

穿戴式裝置包含一自製 NIRS 模組、一嵌入式邊緣計算控制板 Luckfox Pico Mini、一鋰電池、一 OLED 顯示模組、一蜂鳴器、一充電模組以及一升壓模組。我們使用 NIRS 模組中的近紅外光發光二極管 (LED) 所測出來的光強度值透過 OPT101 感測器接收，再傳到 ADS1114 類比數位轉換器 (ADC) 將類比訊號轉成數位訊號，並將數據傳到電腦中進行深度學習。本研究採用自製的近紅外光譜 (NIRS) 感測模組。模組搭載三顆由 Ushio 公司製造的近紅外 LED (SMT750-23、SMT810N-23、SMT870N-23)，分別對應波長 750nm、810nm 與 870nm。每顆 LED 透過 MOSFET (AOSS32334C) 控制驅動，並藉由限流電阻 (約 70 Ω) 穩定控制工作電流於 50 mA，以確保光源強度穩定一致。

發射出的近紅外光 (Near-Infrared Light, NIR) 可穿透皮膚與底層生物組織，並被血液中的血紅素 (包括氧合血紅素與脫氧血紅素) 部分吸收。其餘未被吸收的光則在組織中產生散射與反射，最終回到皮膚表層，並被接收元件—OPT101 整合式光電二極體所偵測。

在硬體架構上，本系統採用反射式設計，LED 發射器與 OPT101 接收器並排配置，兩者之間的物理間距設計為 30 毫米 (mm)。由於光需穿透皮膚、進入組織再反射回接收器，因此實際的光程長度約為發射與接收間距的一半，即約 15 毫米，光學感測裝置設計示意圖如圖二所示。此距離設計可涵蓋淺層與中層肌肉組織，確保能夠取得具生理意義的血氧變化訊號，有助於後續進行即時肌肉疲勞評估。



圖二、光學感測裝置設計示意圖

處理後的模擬訊號再由 16 位元 ADC 晶片 (ADS1114-Q1) 以 860 SPS 採樣率轉換為數位訊號。本模組實際架構如圖三，採用口香糖式鋰電池 (Gumstick Li-ion Battery) 作為主要電源。電池先透過充電模組穩定輸出至升壓模組，再升壓至 5 V 電壓供給整體系統 (包含 IR 發光源與主控單元)，以滿足元件對穩壓供電的需求。此設計實現了無線、低功耗與可穿戴應用的可能性。




圖三、自製 NIRS 模組

本實驗採用 LuckFox Pico Mini 作為穿戴式裝置的核心控制器，內建神經網路處理單元 (neural processing unit, NPU)，適用於低功耗邊緣運算，使裝置可在本地執行機器學習模型，實現肌肉疲勞程度預測，提升系統的即時性與預測準確度。

本研究裝置之外殼採用 3D 列印方式製作，並結合柔性佩戴結構，以提升配戴時的舒適性與固定穩定性，適用於不同肌群與長時間量測情境。為增強即時互動性與使用者回饋，裝置亦整合一塊 OLED 顯示模組，用以即時顯示模型預測之肌肉疲勞等級，使用者可直接於裝置上觀察目前生理狀態之判定結

果，無需額外連接終端設備。完整裝置如圖四所示，具備輕巧、模組化與即時顯示等特性，具備實際應用於可穿戴式生理監測的可行性。




圖四、裝置完成圖

3.2. 軟體架構

本研究主要的設計是將近紅外光譜 (NIRS) 感測器所收集的氧合血紅素 (HbO_2)、脫氧血紅素 (HHb) 以及總血紅素 (tHb) 等數據，結合參與者根據運動過程中的主觀疲勞感受所給予 Borg Scale 分數[7]進行疲勞程度的分析，即 Borg Scale 分數為 AI 模型訓練時的 ground truth。我們將收集的數據餵入深度學習模型進行 AI 學習分析，判斷數據與肌肉疲勞之間的關係，並且評估不同模型之間對肌肉疲勞偵測的準確度。

3.2.1. 參考數值選擇


在近紅外波段中，不同波長對血紅素的吸收特性具有明顯差異如圖五。750 nm 波長對脫氧血紅素 (Hb) 具有較高的吸收率，適用於估算其濃度變化；810 nm 波長則為血紅素的等吸收點，此波長下氧合血紅素 (HbO_2) 與脫氧血紅素的吸收相近，常作為血紅素總量的指標；而 860 nm 波長對氧合血紅素的吸收更為敏感，可用於反映 HbO_2 的濃度變化。因此，透過選擇具代表性的三個波長，可有效解析血液中氧合與脫氧狀態的變化，作為後續生理參數推估與疲勞判斷之依據。




圖五、 HbO_2 、Hb 在運動時變化[1]

在多項研究中[5],[6]，氧合血紅蛋白 (HbO_2) 與脫氧血紅蛋白 (Hb) 被公認為與運動過程及肌肉疲勞程度密切相關。本研究圖六與圖七即展示了在 50% 最大自主收縮力 (MVC) 條件下進行等長收縮時，肌肉疲勞進展期間各項血液動力學參數的變化趨勢，反映肌肉氧氣供需與代謝負荷之間的平衡。在肌肉收縮初期 HbO_2 濃度快速下降時，代表氧氣供應

不足；Hb 濃度則隨著缺氧狀態而上升，顯示組織耗氧增加。總血紅蛋白（tHb）的變化則有助揭示局部血流灌注與微循環調節的角色。根據文獻[1]，HbO₂ 與 Hb 濃度變化在不同疲勞階段間呈顯著關聯。此外，肌肉氧飽和度（SmO₂）作為即時反映肌肉氧合狀態的指標，定義為 HbO₂ 在 tHb 中的比例。研究顯示，隨著運動強度上升，SmO₂ 往往下降，顯示局部肌肉氧氣供需失衡，對肌肉疲勞程度具有良好的指標性。



圖六、肌肉氧合（濃度變化 HbO₂、Hb）從 50% MVC 下的等長收縮記錄



圖七、肌肉氧飽和度（SmO₂）從 50% MVC 下的等長收縮記錄

為了探討肌肉疲勞的關聯特徵，本研究採用線性混合效應模型（Linear Mixed-Effects Model, LMM）進行統計分析，以識別能夠在多數受試者中穩定預測疲勞等級的生理變數。如表一所示，多數特徵的 p 值均遠小於 0.05，顯示這些變數與疲勞程度之間具有高度統計顯著性。其中，HHb_min、ΔHb_max、smO₂_mean 與 OI_mean 等特徵在不同受試者間皆呈現一致性的解釋力，顯示脫氧血紅素（HHb）、總血量變化（ΔHb）、氧合指數（OI）等參數具備成為通用肌肉疲勞指標的潛力。此結果也支持我們在特徵選擇上的依據，進一步強化模型的分類準確性與跨受試者的泛化能力。

表一、線性混合模型分析結果

LMM Results		
feature	Coef	p-value
HHb_min	0.407268	2.29E-135
HHb_mean	0.40948	1.59E-134
HHb_from_first	0.40951	4.61E-134
HHb_max	0.404279	7.62E-127
ΔHb_from_first	-0.2048	4.14E-75
ΔHb_mean	-0.20479	6.42E-75
ΔHb_max	-0.20501	1.37E-74
ΔHb_min	-0.20231	2.26E-73
OI_from_first	-0.0451	2.48E-68
smO ₂ _from_first	-0.09021	2.65E-68
smO ₂ _mean	-0.09021	2.87E-68
OI_mean	-0.04511	3.19E-68

3.2.2. 訊號處理

為確保使用 OPT101 光電探測器與 ADS1114 類比數位轉換器轉換的 NIRS 訊號的準確性與可靠性，需進行數位預處理，以消除雜訊、修正基線漂移，並提取氧合血紅蛋白與去氧血紅蛋白的變化。此外，為了使取樣率與前述 NIRS 研究[4], [5]一致，應用取平均法來降低取樣率，使訊號更符合生理變化範圍，減少不必要的數據冗餘。同時，應用移動平均法進行平滑處理，以減少短時間內的訊號波動並增強穩定性。這些訊號處理步驟確保了 NIRS 訊號的品質，使其適用於後續的生理分析與肌肉疲勞評估。

3.2.3. 特徵提取

在本研究中，肌肉的血氧變化資訊是透過近紅外光譜（Near-Infrared Spectroscopy, NIRS）量測取得，主要依據修正的 Lambert - Beer 定律

（Modified Beer's Law, MBLL）來計算特定血液色素的濃度變化。由於人體組織對近紅外光（650 - 1000 nm）的穿透性良好，因此可以使用固定波長的光源穿透皮膚，透過接收器接收穿透光後的強度變化，進一步推算出組織中光吸收物質（如氧合血紅素與脫氧血紅素）的濃度改變。

修正後的 Lambert - Beer 定律[14]考慮了組織內光的散射效應，因此其數學表示式：

$$A = \ln \left(\frac{I_0}{I} \right) = B \cdot L \cdot \beta \cdot C \cdot G \quad (1)$$

其中，A 為光密度（也稱吸光度），代表入射與出射光強度的比值； I_0 與 I 分別是入射與出射光強度；B 是差異性光程因子（differential pathlength factor, DPF），表示光在組織中實際傳播路徑長度與幾何長度之間的比例；L 為光源與接收器之間的距離；β 是摩爾吸收係數，取決於特定波長下某色素的光吸收能力；C 為色素濃度；而 G 是散射衰減因子，通常視為常數。

若將某一時間點的光密度變化（例如肌肉收縮前後的變化）表示為 ΔA，則可簡化上述公式為：

$$\Delta A = \ln \left(\frac{I_0}{I_t} \right) = B \cdot L \cdot \beta \cdot \Delta C \quad (2)$$

此處 I_0 為初始狀態的光強度，而 I_t 是在肌肉狀態改變後的光強度。這個關係說明，只要能測得光強度的變化，搭配已知的吸收係數與路徑長，就可以計算出濃度變化 ΔC。

β 值根據[16]Scott Prahl 使用來自 W.B.Gratzer, Med.Res.Council Labs, Holly Hill, London 與 N.Kollias, Wellman Laboratories, Harvard Medical School, Boston 的摩爾消光係數 e；吸光度在修正的

Lamber-Beer 公式下再除以 64500 作為血紅蛋白的克分子量。

$$A = \frac{e \cdot \left(\frac{1}{\text{cm} \cdot \text{mol/L}} \right) \cdot x [\text{g/L}] \cdot 1 [\text{cm}]}{64500 [\text{g/mol}]} \quad (3)$$

在實際操作中，[15]若同時使用三種不同波長的近紅外光源，便可以針對三種主要的吸收色素（Hb、HbO₂）建立如下的矩陣方程式：

$$\begin{pmatrix} \Delta OD_{\lambda_1} \\ \Delta OD_{\lambda_2} \\ \Delta OD_{\lambda_3} \end{pmatrix} = \begin{pmatrix} \epsilon_{Hb}^{\lambda_1} & \epsilon_{HbO_2}^{\lambda_1} \\ \epsilon_{Hb}^{\lambda_2} & \epsilon_{HbO_2}^{\lambda_2} \\ \epsilon_{Hb}^{\lambda_3} & \epsilon_{HbO_2}^{\lambda_3} \end{pmatrix} \begin{pmatrix} \Delta[Hb] \\ \Delta[HbO_2] \end{pmatrix} \cdot DPF \cdot d \quad (4)$$

公式(4)中， $\Delta OD(\lambda_i)$ 表示在第 i 個波長下量測到的光密度變化，而矩陣中的 ϵ 值則代表 HbO₂ 和 Hb 在波長 λ_1 、 λ_2 和 λ_3 處的消光係數；DPF 是差異性光程因子； $\Delta[Hb]$ 、 $\Delta[HbO_2]$ 則為 Hb 與 HbO₂ 的濃度變化； d 是光源與接收器之間的距離。由於各波長 ϵ 值與 DPF 可從文獻查得，因此只要測得 ΔOD 值便可利用反矩陣運算求得三個色素的濃度變化。

此外，在實務中光強度會受到儀器的背景光與環境影響，因此常透過下列公式(5)來校正實際吸收變化[4]。

$$\Delta A_t = -\ln \left(\frac{V_t - V_{baseline}}{V_0 - V_{baseline}} \right) \quad (5)$$

此式中， V_0 為初始光強度， V_t 是當前時刻的光強度， $V_{baseline}$ 則是光源未開啟時的背景電壓。這樣可以消除光源不穩定與環境光對吸光度計算造成的誤差。

透過以上方法，便可以即時獲取氧合血紅素（HbO₂）與脫氧血紅素（HHb）的濃度變化值，進而推導總血紅素（tHb = HbO₂ + HHb）與氧合飽和度（smO₂ = HbO₂ / tHb）。


3.2.4. 學習與邊緣運算

本研究基於近紅外光譜（NIRS）所擷取的生理特徵（如 HbO₂、HHb、SmO₂、 ΔHb 與氧合指數），設計一套可部署於邊緣設備的肌肉疲勞分級模型。為了準確建模血氧訊號的時間動態與統計特性，我們採用融合式深度學習架構——LSTM-CNN+MLP Fusion Model，整合時序與靜態特徵進行多模態分類學習。

如圖八所示，模型包含雙分支結構：上側分支處理原始 NIRS 時間序列資料（長度 100、維度 8），先經一維卷積層（32 filters，kernel size=3）擷取局部時

序特徵，再通過最大池化降維與雜訊抑制，接續以 LSTM（32 單元）捕捉長期依賴與非線性變化，最後使用 GlobalAveragePooling1D 壓縮為固定維度向量。

下側分支處理統計摘要特徵（約 40 維），涵蓋各指標的平均、標準差、極值與中位數等，視需要可納入背景變項（如受試者 ID、肌群位置）。此分支經一層全連接層進行特徵轉換與正則化處理。兩分支的高階特徵向量在 Concatenate 層融合，通過一層 Dense 層進一步整合，最終經由 softmax 層輸出五類肌肉疲勞等級。訓練過程採用 sparse categorical crossentropy 損失函數、Adam 優化器（學習率 0.001），並結合 EarlyStopping 與 ReduceLROnPlateau 根據驗證結果動態調整學習率，以增強穩定性與泛化能力。該模型結構融合序列與統計資訊，具備強大的多層次特徵表徵能力，且結構輕量，具備部署於邊緣裝置的實用性，適合即時肌肉疲勞監測應用。



圖八、LSTM-CNN 加上 MLP

3.3. 實驗流程

實驗流程包括硬體製作、設備測試、資料收集與模型訓練四大部分。首先，使用自製的 NIRS 模組製作血氧傳感器裝置。其次，將自製裝置與醫院專業監測儀進行比對測試，驗證其準確性與可靠性。接著，招募 50 名健康受試者進行上肢和下肢實驗，透過啞鈴彎舉和深蹲運動誘發肌肉疲勞，結合 Borg Scale 疲勞評分[7]系統記錄主觀疲勞感受，同時採集血氧參數和運動數據。最後，將收集的數據輸入 LSTM 深度學習模型進行訓練，以預測不同運動階段的肌肉疲勞程度，進一步評估裝置的應用潛力和模型的預測準確性。

3.3.1. 資料收集

本研究預計會在新北市恩主公醫院申請 IRB。對 50 名 20 多歲健康男性與女性進行兩類型實驗，分成上肢實驗與下肢實驗。在上肢實驗開始前參與者保持直立坐姿，手肘處於放鬆狀態，將前臂垂直於上臂放置，手持啞鈴進行 45 度肘關節彎曲維持動作，在能完成 45 度運動時的啞鈴最大重量視為 100% MVC；下肢實驗我們進行的是深蹲動作。在實驗開始前讓參與者保持雙腳保持放鬆站姿，以此收集肌肉基礎數據。

3.3.1.1. 上肢實驗與資料收集

在上肢實驗中，受試者進行維持 45 度肘關節彎舉動作，並記錄其主觀肌肉疲勞程度。因此，我們設計上肢實驗感測裝置，固定於受試者左右手肱二頭肌的中間位置，結合近紅外光技術進行血氧參數監測。受試者以 50% MVC（最大自主收縮力）的重量作為啞鈴負重，執行單手啞鈴彎舉動作維持以誘發肌肉疲勞。

實驗開始時，參與者保持直立坐姿，手肘放鬆，前臂垂直於上臂，在空載條件下收集基礎數據 20 秒。隨後，受試者手持啞鈴並維持肘關節屈曲 45 度，保持該姿勢 90 秒。若過程中無法繼續維持 45 度角度，即視為肌肉疲勞極限，並記錄此時的數據作為肌肉耐力與疲勞評估參考。完成單側測試後，受試者休息 30 秒，再進行另一側手臂測試。上肢實驗流程及動作如圖九、圖十所示。在測試過程中，受試者需持續回報自身的疲勞程度，並根據「肌肉疲勞評分」（Borg scale）系統在 0 至 10 分範圍內進行即時評估。感測裝置會持續記錄上肢血液狀況及相關參數。




圖九、上肢實驗流程示意圖



圖十、上肢實驗動作示範圖

3.3.1.2. 下肢實驗與資料收集

在下肢實驗中，感測裝置固定於受試者左右腿股外側肌的前側位置，結合近紅外光譜技術監測血氧參數。實驗開始時，參與者保持放鬆狀態 20 秒以收集基礎數據。隨後，受試者開始執行深蹲姿勢持續 90 秒。完成單次測試後，會休息 30 秒。下肢實驗流程及動作示範圖如圖十一、圖十二所示。在測試過程中，持續回報自身的疲勞程度，並根據「肌肉疲勞評分」（Borg scale）系統在 0 至 10 分範圍內進行即時評估。感測裝置會持續記錄上肢血液狀況及相關參數。




圖十一、下肢實驗流程示意圖



圖十二、下肢實驗動作示範圖


3.3.2. 模型訓練

本研究提出一套結合離線訓練與即時預測的肌肉疲勞辨識系統，整體流程如圖十三所示。涵蓋資料蒐集、深度學習模型訓練與邊緣部署三大階段，最終實現可即時運行於穿戴裝置的高準確率疲勞預測解決方案。



圖十三、系統流程架構

為驗證此架構之效能，我們採用 5 折交叉驗證(5-fold cross-validation)進行訓練與評估。每一折中，訓練集依據標籤分布進行分層抽樣，確保模型在多類別不平衡情況下仍能維持穩定性。整體模型訓練結果如下圖十四所示，五折驗證平均準確率達 88.28%，顯示模型在不同資料分割下皆能穩定預測肌肉疲勞程度。



圖十四、五折驗證平均混淆矩陣

4. 主要成果與評估

表二、模型訓練結果

Model Comparison		
Model	Accuracy	F1 Score
Our Model	0.8828	0.8835
LSTM	0.8506	0.8519
CNN	0.7707	0.7727
Transformer	0.8050	0.8073
Random Forest	0.3141	0.3062
Bagged Trees	0.3057	0.2981
Boosted Trees	0.3585	0.3406
RBF-SVM	0.3491	0.3144
Cubic SVM (deg = 3)	0.3553	0.3174
Quad SVM (deg = 2)	0.3565	0.3159

為驗證本研究提出模型相較於傳統機器學習方法之優勢，我們亦實作多種分類器進行比較，包括 Random Forest、Bagged Tree、Boosted Tree、RBF-SVM、Cubic SVM 與 Quadratic SVM。實驗結果如表二顯示，傳統模型在處理具高變異與非線性特性的多源資料時，整體準確率與泛化能力均不如本研究之深度融合模型，進一步突顯我們所設計架構於疲勞辨識任務中的適用性與優勢。

5. 結語與展望

表三、與其他研究比較表

Study	Signal Types	Portable	Real-Time	Quantified Fatigue	Accuracy
Ours	NIRS	Yes	Yes	Yes (3-level)	88.35%
Zhang et al. (2025)	sEMG	No	No	Yes (3-level)	84.11%
Chua et al. (2025)	Strain sensor	No	Yes	Yes (2-level)	N/A
Li et al. (2025)	sEMG	No	No	No	N/A
Fernandez Schroeder et al. (2024)	sEMG, RTM	No	Yes	No	N/A
Kimono et al. (2023)	EMG, MMG, NIRS	No	No	No	N/A
Gut et al. (2022)	sEMG, MMG, NIRS	No	No	No	N/A
Muramatsu et al. (2013)	NIRS	No	No	No	N/A

表三中與其他論文相比本研究是第一個成功開發出一套可攜式、即時、且具備量化能力的肌肉疲勞檢測裝置，此裝置在我們的訓練及測試下，其達到了接近 90% 的高準確率，可以有效的幫助使用者在訓練或是活動過程中即時的追蹤身體當前狀態，不僅僅可以提升運動表現，更可以降低運動造成傷害的風險；我們的裝置同時也很適合應用在復健過程中，可以幫助醫療人員更加客觀掌握病患的肌肉負荷狀況，達到更科學且良好的復健成效。另外，我們也已經提出專利申請，確保這項創新成果的技術受到應有的保護。最後，我們相信，我們研發的這套系統在運動科學與智慧醫療領域都將會有很大發展潛力。

6. 銘謝

感謝指導教授提供我們大量的資源和豐富的研究經驗分享，以及讓我們能無限的嘗試及發揮的空間；另外也感謝實驗室學長姊的協助及經驗分享，讓我們快速的熟悉實驗室的各項器材且少走了許多彎路，使我們在進行專題的過程中更加順利；也感謝系上的同學朋友自願擔任我們研究中的受試者，提供我們資料訓練模型，使研究獲得一大進展；最後感謝專題組員們近一年來的互相扶持與合作，一同完成了這項看似艱鉅的任務，使專題如期完成。

7. 參考文獻

- [1] Y. Muramatsu and H. Kobayashi, "Assessment of local muscle fatigue by NIRS," *7th Int. Conf. Sens. Technol. (ICST)*, Wellington, New Zealand, 2013, pp. 623-626.
- [2] Feldmann, Andri, Roger Schmitz, and Daniel Erlacher, "Near-infrared spectroscopy-derived muscle oxygen saturation on a 0% to 100% scale: reliability and validity of the Moxy Monitor," *J. Biomed. Opt.*, vol. 24, no.11, Nov. 2019, Art. no. 115001
- [3] W. Guo, X. Sheng, and X. Zhu, "Assessment of muscle fatigue by simultaneous sEMG and NIRS: From the perspective of electrophysiology and hemodynamics," *Proc.*

- 8th Int. IEEE/EMBS Conf. Neural Eng. (NER)*, Shanghai, China, May 25-28, 2017, pp. 33-36.
- [4] W. Guo, X. Sheng, and X. Zhu, "Assessment of Muscle Fatigue Based on Motor Unit Firing, Muscular Vibration and Oxygenation via Hybrid Mini-Grid sEMG, MMG, and NIRS Sensing," *IEEE Trans. Instrum. Meas.*, vol. 71, pp. 1-10, 2022.
- [5] 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.
- [6] Kimoto, H. Fujiyama, and M. Machida, "A Wireless Multi-Layered EMG/MMG/NIRS Sensor for Muscular Activity Evaluation," *Sensors*, vol. 23, no. 23, Jan. 2023, Art. no.1539.
- [7] Nerys Williams, "The Borg Rating of Perceived Exertion (RPE) scale," *Occup. Med.*, Vol. 67, no. 5, pp. 404-405, Jul. 2017.
- [8] 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.
- [9] 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. 15, 2024.
- [10] J. Montes, A. M. Goodwin, M. P. McDermott, D. Uher, F. M. Hernandez, K. Coutts, J. Cocchi, M. Hauschildt, K. M. Cornett, A. K. Rao, U. R. Monani, C. E. Garber, and D. C. De Vivo, "Diminished muscle oxygen uptake and fatigue in spinal muscular atrophy," *Ann. Clin. Transl. Neurol.*, vol. 8, no. 5, pp. 1086-1095, May 2021.
- [11] F. Michaud, S. Beron, U. Lugris, and J. Cuadrado, "Four-compartment muscle fatigue model to predict metabolic inhibition and long-lasting nonmetabolic components," *Front. Physiol.*, vol. 15, Mar. 2024, Art. no. 1366172.
- [12] M. Li, J. Han, L. Gao, Z. Yang, Y. Chen, and L. Huang, "Research on Fatigue Assessment Algorithm based on ECG and Multi-source Physiological Signals," *Proc. Int. Conf. Artif. Intell. Inf. Process. Cloud Comput. (AIIPCC)*, Kunming, China, Dec. 10-12, 2022, pp. 350-355.
- [13] T. J. Barstow, "Understanding near infrared spectroscopy and its application to skeletal muscle research," *J. Appl. Physiol.*, vol. 126, no. 5, pp. 1360-1376, May 2019.
- [14] R. V. Maikala, "Modified Beer's Law - historical perspectives and relevance in near-infrared monitoring of optical properties of human tissue," *Int. J. Ind. Ergon.*, vol. 40, no. 2, pp. 125-134, 2010.
- [15] M. Ferrari and V. Quaresima, "A brief review on the history
- [16] Y. Zhao, L. Qiu, Y. Sun, C. Huang, and T. Li, "Optimal hemoglobin extinction coefficient data set for near-infrared spectroscopy," *Biomed. Opt. Express*, vol. 8, no. 11, pp. 5151-5159, Nov. 2017.
- [17] S. Nath. "Why is BiLSTM better than LSTM? Know the underlying functionality." *Medium*.<https://medium.com/@souro400.nath/why-is-bilstm-better-than-lstm-a7eb0090c1e4> (accessed May 6, 2025).