

數據驅動主從式充放電策略之低碳車對網交易研製

黃俊瑋^{1*}、林星妤²、徐士賢¹、李秉昕²

摘要

隨著低碳運輸轉型，運具電力化成為了不可忽略的趨勢。在減碳方面，主要有電動車(EV)、插電式混合動力車(PHEV)、氫燃料電池車(FCV)和油電混合車(Hybrid V)等四種低碳運輸工具，而這四種減碳效益差異較大，主要取決於其動力系統、能源來源、能源效率和使用環境等因素，其中以純電動車與氫燃料電動車的減碳效益最大，但因為氫燃料之成本過於高昂，因此目前純電動車為世界之浪潮。但純電動車極度依賴清潔電力，因此，電池管理系統(Battery Management System, BMS)於電動車充放電管理上扮演起至關重要之角色，負責監控碳排放流、負載潮流與電力資訊的關鍵訊息。因此，本研究旨在建構電動車的充放電策略，調度電池充電狀態監控模式，並通過控制主從式電池組實現充放電狀態排程與市電併網調度。同時還設計低碳車對網交易模型，持續監控電力碳足跡、碳費計算與剩餘容量估計，俾利在充放電策略中執行最佳決策。本研究開發電動車充放電策略指引，並通過研究結果篩選ANFIS、GRU、LSTM、GRU-LSTM、LSTM-GRU等5種剩餘容量估測模型分析比較，以優化其估測性能。研究中建立不同環境溫度與充放電速率情境，並於同一電池容量(200 Ah)下進行驗證。研究成果顯示主電池平均消耗為62.75 Ah、副電池平均消耗為71 Ah時，單電池的平均消耗為173 Ah。實驗數據驗證了電池管理系統的優化效果，其中LSTM-GRU模型的估測性能評價指標(MAE)為3.56%，展現了卓越的追蹤能力。此外，在碳排放量的分析中，透過計算碳排放量與碳費，展示碳排之控制成效。與單電池相比，主從式充放電策略的主副電池碳排放量平均少了0.06 kgCO_{2e}。最後，實驗結果表明該策略在實際硬體環境中的可行性，並有望在實際應用中為里程焦慮提供有效的解決方案。

關鍵詞：主從式充放電策略排程，電池電量狀態，碳排監測

1. 前言

隨著全球暖化的議題成為國際社會關注的焦點，各國開始期盼達成淨零排碳的目標，聯合國環境規劃署(United Nations Environment Programme, UNEP)在2022年排放差距報告

(Emissions Gap Report)中提及，交通運輸占能源相關二氧化碳排放總量的25%，是全球第二大的排放來源(UNEP, 2022)。因此，將傳統內燃機驅動的車輛轉換為電動汽車被視為減少碳排放的重要途徑。儘管電動車能帶來節省燃料、降低噪音等諸多正面影響，但在美國國家

¹逢甲大學，電機系教授

²逢甲大學，電機系研究生

*通訊作者，電話：04-24517250#3822，電郵：chunwhuang@fcu.edu.tw

收到日期: 2024年08月26日


修正日期: 2024年12月11日

接受日期: 2025年02月11日

環境保護局(Environmental Protection Agency, EPA)整理了汽油車與純電車的續航里程比較中，電動車只有汽油車的58% (INSIDEEVs, 2022)，如圖1所示由於電動車完全充電所需的大量等待時間，比傳統車輛加滿油箱所需的時間要長得多，電動車電池的所儲存的電力也無法為駕駛人提供足夠的續航力抵達目的地，即里程焦慮(Range Anxiety)之產生。

為了解決續航力不足之問題，許多專家學者紛紛提出解決方案，其中以動態無線充電方面(Dynamic Wireless Charging, DWC)，是透過電磁感應的原理，允許電動車邊行駛邊充電(Charge While Driving, CWD)為低碳車對網之重要解方。這項技術消除了電動車因電池容量有限而導致的里程焦慮問題，使駕駛者無需停留在原地等待充電或擔心再次充電。此外，DWC技術還能減少對笨重電池的依賴，從而提高駕駛人消費電動車的可行性(Duarte *et al.*, 2021；Razu *et al.*, 2021)。目前，DWC 技術的可行

性已在一些國家進行測試，像是由韓國科學技術院(Korea Advanced Institute of Science and Technology, KAIST)發起的在線電動車(On-Line Electric Vehicle, OLEV)項目，在義大利建造了一個應用在電動公車模擬駕駛的無線電力傳輸(Dimitriadou *et al.*, 2023)道路試驗場。此外，以色列的新創公司Electreon也在多個地方製造無線充電公路，測試動態電動車充電的可行性。這些案例展現了運具將不再依賴靜態充電站的可能性，從而讓車輛調度更加靈活，不再需要自備大型電池，車輛的製作成本也有望降低。為降低電動車里程焦慮，本研究透過混和式路況資訊，亦即一般道路加入無線公路之設定，控制其充放電時機，模擬了即時充放電環境下的電動車運行，並採取數據驅動(Data-driven)法擷取電池運行特徵，同時執行充放電策略調整、碳排放量計算與流量監控，並從中估測電池主從式充放電量狀態，為後續低碳足跡監控，奠定低碳車對網之交易模式。



資料來源：INSIDEEVs, 2022.

圖1 EPA對汽油車與電動車的續行比較圖

主從模式(Master-Slave Configuration)是一種在資訊科技領域中常見的架構模式，通常用於描述兩個或多個系統之間的關係，由一個主要的系統(Master)和一個或多個次要的系統(Slave)所組成。這些系統間有著明確的控制和指揮關係，主要系統作為核心架構，通常具有較高的權限和控制能力，負責進行系統的狀態監測、任務分配或下達命令給次要系統的行為，而次要系統則負責在同一時刻根據主系統的指示進行具體的操作任務，進而達到控制策略目標。這種方法用於許多不同的領域，截至目前為止，在電力系統和能源管理領域中經常被用來改善單電池電流大小分配或提升系統穩定性，例如國際間有特斯拉Powerwall 2是利用多個電池模塊來實現長時間的穩定電力供應，在高效能無人機(如商用送貨無人機或長時間飛行的監測無人機)中，也多使用多顆電池協同工作來延長飛行時間和增強穩定性。例DJI Matrice 600無人機，而為避免系統過熱等(Hu and Lai, 2017；Lee and Cho, 2016；Zhang *et al.*, 2022)。因此，本研究提出了一種基於主從模式的雙電池組充放電，設計主從式架構，令主系統有更高的權限和控制能力，而次要系統根據主系統的指示來執行工作。這種架構模式有助於提高系統的效率 and 協調性，同時也能夠更容易地擴展系統的規模，因為可以輕鬆地新增次要系統來擴展系統的功能或容量。主從模式的優勢在於其分工明確、穩定性高以及容錯能力強，能有助於提高系統效能，同時具有良好的通用性和靈活性，並通過明確的角色和通訊方式來管理系統的運作。

其中，電池管理系統(BMS)做為儲能的監控系統，是確保整個系統運作順暢、高效的重要關鍵。BMS透過對電池資料(電壓、電流、溫度等)進行即時監測，隨時掌握電池的狀態，進而調整充放電策略，最大程度地提高能源的利


用效率。在BMS的管理範疇中，包含了一系列資訊，如電池充電狀態(State of Charge, SOC)、健康狀態(State of Health, SOH)和剩餘使用壽命(Remaining Useful Life, RUL)等。其中SOC直接反映了電池的電量，是駕駛人評估電動車續航里程、確保電動車在行駛過程中能夠提供穩定且可靠動力的重要參數。因此，SOC的準確監測不僅有助於延長電池壽命，還能夠減少能耗損失，促使系統整體達成環境永續。本研究提出了一種應用於電動車電池的主從式充放電策略，以剩餘容量狀態作為調控標準，旨在提升電池管理系統的性能並減少電動車行駛過程中的里程焦慮。

電池剩餘容量狀態在電動車的能源管理中，不僅直接影響著設備的供電效能，更關聯到電池的壽命和性能。將電池的剩餘容量控制在一定的工作範圍內，能防止過度充放電，同時還能減緩電池老化過程，避免性能衰退，從而提高電池的長期穩定性與延長壽命。在文獻Kostopoulos *et al.* (2020)與Zhang *et al.* (2020)中提到，鋰離子電池容量運行在80%–100%與運行範圍的20%–80%相比較，其損耗幾乎是兩倍，經老化研究證實在20%到80%之間具有較好的電池使用性能，如圖2所示。因此，綜合電動車電池的性能和壽命的考量，本研究將選用20%到80%作為SOC的充放電運行標準，為提供電動車更高效、經濟的運行參考。

2. 相關文獻探討

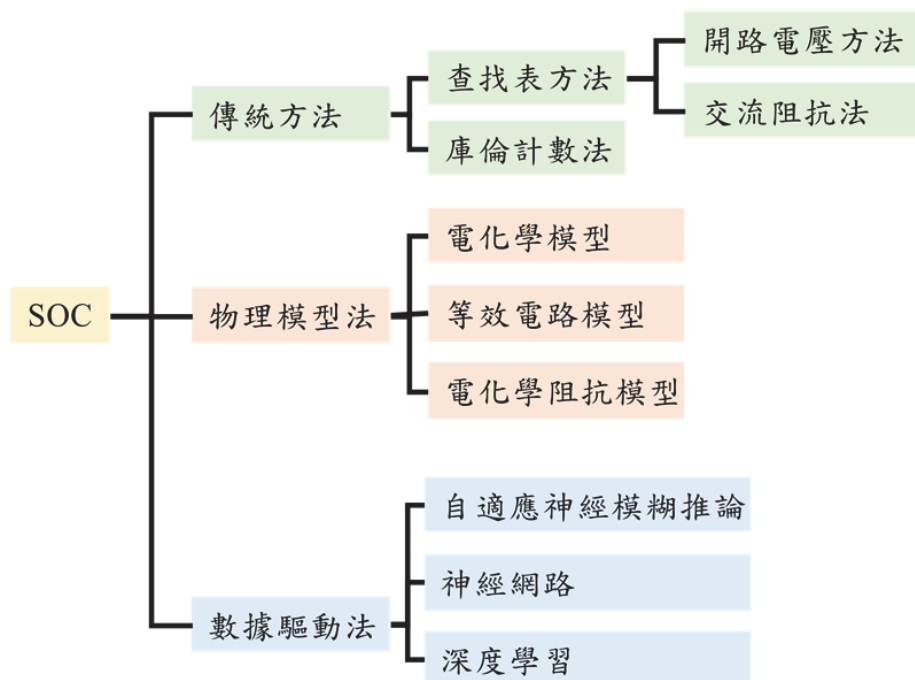
2.1 預測模型探討

本研究探討(Ahmed *et al.*, 2021；Baccouche *et al.*, 2018；Dai *et al.*, 2021；Yang *et al.*, 2021；Basia *et al.*, 2021；Singh *et al.*, 2020)文獻研究中不同剩餘容量狀態的估測方法，將不同SOC的



資料來源：Kostopoulos *et al.*, 2020.

圖2 不同SOC範圍的平均能量損失圖



資料來源：本研究彙製。

圖3 SoC估測方法統整圖

估測方法，大致分為三大類：傳統方法、物理模型法和數據驅動法，如圖3所示。

第一類為傳統方法，基於傳統電化學理論和電池特性，透過測量電池的基本參數進行SOC估測，如電壓、電流和電池外部溫度等，包括開路電壓法(Open Circuit Voltage, OCV) (Ahmed *et al.*, 2021)、交流阻抗法(AC

Impedance)和庫倫計數法(Coulomb Counting, CC)等，如表1所示。

這些方法的共同特點是基於傳統電化學理論和電池特性，透過測量電池的基本參數，如電壓和電流，進行SOC估測。雖然這些方法在一定程度上能夠實現SOC的估測，但由於它們對電池特性變化較為敏感，對溫度和放電率

表1 SOC估測在傳統方法的優劣比較表

方法	優點	缺點
開路電壓法	方法簡單	需長時間靜置受電池特性影響
交流阻抗法	適應性強對SOC變化敏感	穩定範圍有限
放電測試法	準確、可靠	需中斷、時間長
安時積分法	計算簡單	不夠準確
內阻法	與SOC關係密切	測量困難
庫侖計數法	簡單、直觀	長時間積分誤差受電池性能影響
負載電壓法	簡單實用	無法在線使用

資料來源：本研究彙整。

等因素的影響較大，使得精準度和適用性受到了限制，因此在實際應用中存在著一定的局限性。

第二類為物理模型法(Baccouche *et al.*, 2018; Dai *et al.*, 2021)，透過建立電池的物理數學模型，模擬電池的內部反應機制，從而實現對剩餘容量狀態的準確估測，包含了電化學模型(Electrochemical Model, EM)、等效電路模型(Equivalent Circuit Model, ECM)和電化學阻抗模型(Electrochemical Impedance Model, EIM)等，其優點與缺點的分析如表2所示，這些方法透過建立電池的物理數學模型，模擬電池的內部反應機制，從而實現對SOC的準確估測。EM基於電池的電化學反應過程，透過求解相對應的方程組，模擬電池在不同環境下的SOC。ECM則將電池視為一個等效電路，透過建立電

阻、電容和電感等元件的連接，模擬電池的動態特性。EIM則透過分析電池在不同頻率下的阻抗，以獲得SOC的資料。這些物理模型法的優點在於其可靠性以及準確性較高，尤其在理論基礎和模型參數確定方面表現優越。然而，其缺點在於需要豐富的領域知識和相對較長的開發時間，對於這些模型的構建和校準需要深入了解電池的內部結構和化學過程，這也限制了物理模型法在實際應用中的靈活性。

第三類為數據驅動法，利用大量的目標特徵資料建立模型的方法，優點是不需要具備特定領域上的專業知識背景和數學建模，因此被廣泛使用(Yang *et al.*, 2021; Basia *et al.*, 2021)，其常見的方法有：自適應神經模糊推論系統(Adaptive Neuro Fuzzy Inference System, ANFIS)(Singh *et al.*, 2020)、神經網路(Neural Network,

表2 SOC估測在物理模型法的優劣比較表

方法	優點	缺點
電化學模型	高精準度動態適應性高	計算複雜對參數敏感
等效電路模型	相對簡單	對充放電特性依賴性高
電化學阻抗模型	頻域資料豐富動態適應性高	模型複雜

資料來源：本研究彙整

表3 鋰離子電池SoC估測優劣分析表

分類	優點	缺點
傳統方法	方法簡單易實現	精確性不足對環境條件敏感
物理模型法	高精確度高動態適應性	模型需要時間長模型建立資料難以取得
數據驅動方法	開發時間短訓練資料易取得	資料與訓練需求大

資料來源：本研究彙整

NN)和深度學習(Deep Learning, DL)等。數據驅動法是近年來崛起的一種SOC估測方法，通常被視為黑盒模型，基於大量實測資料的學習和訓練，透過演算法、機器學習等方法實現對SOC的估測。

本研究對於不同的剩餘容量狀態估測方法進行了簡單的優劣比較，如表3所示。電量狀態估測於電動車領域是一個極具挑戰性的課題，需要綜合考慮電池的特性、工作條件和應用場景，在實際應用中，如何平衡這些優勢和缺點，使得估測結果既精準又可解釋，是一個仍待解決的難題，本研究將利用多種剩餘容量狀態不同的估測方法，盼能達到準確且可靠的電量狀態估測，減少不必要的用電浪費，有效降低駕駛人的里程焦慮。

2.2 碳排放管理探討

在全球氣候變化議題日益受到關注的情況下，各國紛紛提出不同的電動車碳排放管理策略，其中包括碳排標準、鼓勵政策、補助措施以及碳價制定等。在碳排管理中，碳價市場被視為應對氣候變化的重要機制之一，其主要功能是透過碳價設定來引導企業減少碳排放。

國際上常用的碳定價工具有2種，即總量管制與碳交易(Cap and Trade, C&T)以及碳稅(Carbon Tax, CT)。其中，C&T 又稱為碳排交易系統(Emissions Trading Scheme, ETS)，通常是由政府透過法規控制二氧化碳及各類溫室氣

體的總排放量，並設定相應的上限，同時授權企業額外的排放許可，當企業在排放超過額度時，需透過市場交易向其他企業購買許可，相反，如果企業的排放低於其分配額度，則可以將未使用的許可轉售給其他公司，這種制度旨在減少排放，同時促使企業尋找到最具成本效益的減碳方法。

另一方面，CT則是一種由政府訂定的碳價機制，對排放出的碳排量徵收碳稅，透過增加溫室氣體排放的成本，鼓勵企業減少碳排放，不同於C&T透過市場機制去靈活的塑造碳價，CT的特點在於碳價是固定的，而付款金額與實際排放成正比。因此，企業可以根據其排放量來預測碳成本，並相應地調整其行為。選擇何種碳價機制，通常取決於當地政策目標和實際環境。

2.3 本研究之貢獻

本研究提出了一種應用於電動車電池的主從式充放電策略，旨在提升電池管理系統的性能並減少電動車行駛過程中的里程焦慮。此策略篩選出多種不同的方法準確估測電池的剩餘容量，確保在最佳的時間點進行充放電切換，避免產生額外的碳排放量，實現低碳永續電力生活，詳細分為三大方面：

第一部分：運用AI精準訓練充放電策略，進行電力資源分配

透過主從式電池充放電策略對能源進行

電力資源管理，在相同時間與電池總容量(200 Ah)下，主副電池剩餘的容量大於單電池。這證實主從式充放電策略能夠更高效地管理電池充放電過程，提高電動車的行駛距離並有效緩解駕駛人的里程焦慮。為了進一步驗證主從式策略的有效性，本研究建立一個電動車充放電策略指引，並由於資料集為時序性的資料，因此篩選出了5種較佳的SOC估測方法，包括ANFIS、GRU、LSTM、GRU-LSTM和LSTM-GRU。經模型評估指標之限制下，選擇SOC估測能力最準確的模型，透過此方法精準反映電池的實際狀態，從而保障充放電策略的有效實施。而主從式策略通過精準的SOC估測方法，提高能源管理的精度和效率，實現了更高效的電池充放電管理。這不僅減少了電池的過度放電和過度充電情況，還延長電池的壽命，從而減少頻繁更換電池所帶來的成本和環境負擔。

第二部分：低碳電力運行監控與碳費成本分析

本研究對不同充放電策略下的碳排放量和碳費通過主從式充放電策略監控系統，實時監測電池的充放電狀態，並利用碳排放數據進行分析比較。以證實主從式策略在減少碳排放與能源消耗方面，不僅有助於優化電池充放電策略，能為未來的碳費訂定提供有效依據，從而實現經濟和環境效益可行性的雙贏。

第三部分：應用硬體在環實現虛實整合驗證

本研究所建立的模型應用於功率調節系統(Power Conditioning System, PCS)，通過硬體在環實現(Hardware-in-the-Loop, HIL)技術，進行220 V市電併網測試，以驗證市電碳排放量與本研究充放電策略的虛實整合可靠性。模擬結果顯示，主從式策略具備在實際環境中應用的潛力，這不僅提高了研究結果的準確性，還為未來的實際應用提供了寶貴的經驗和數據支援。

章節概要說明如下：第二章對本研究所選用之電池充電狀態估測方法進行介紹與分析；

第三章為碳排放量與碳費介紹；第四章為本研究之研究架構，說明了本研究選用的環境參數設置、電動車運行架構、SOC估測方法以及模型訓練情境之設定；第五章為研究結果，呈現主從式架構的應用、比較5種估測模型的準確度、碳排放量的多寡以及硬體在環實現的可行性；第六章為結論，將本研究之研究結果進行統整，並闡述基於本研究的框架下，說明未來可以改善與發展的方向。

3. 電池充電狀態估測方法

SOC反映了電池能提供的供電狀態，也作為駕駛人判斷電池電量的標準(Shrivastava *et al.*, 2023)，如式(1)，其中，當前的SOC值單位為%。

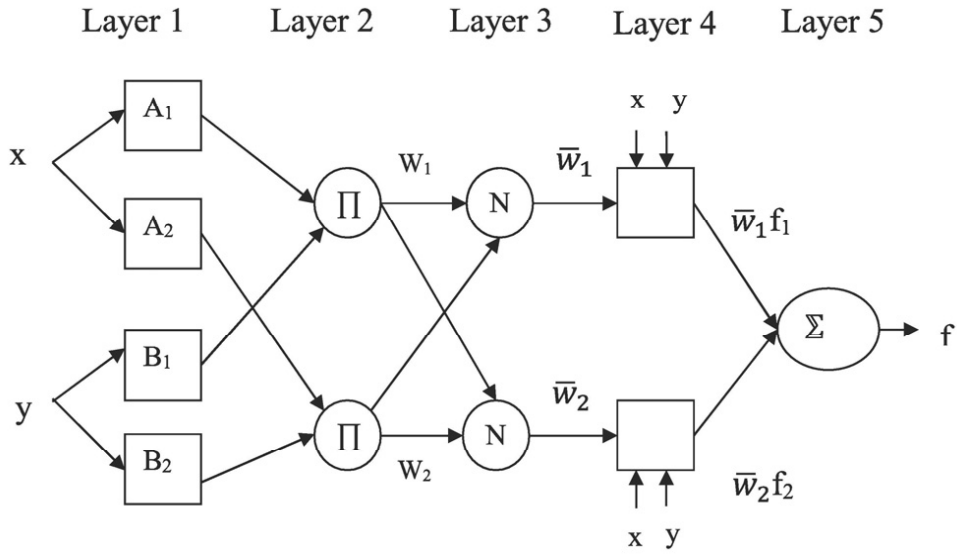
$$SOC(t) = SOC(t-1) - \frac{1}{Q_n} \int_0^t I(t)dt \quad (1)$$

由於充電狀態不能直接測量，所以需要透過其他參數來協助估測，本研究採用自適應性模糊推論法、長短期記憶、門控循環單元以及混合方法作為SOC估測方法，下文將詳細說明。

3.1 自適應性模糊推論法

自適應神經模糊系統(Adaptive Network-based Fuzzy Inference System, ANFIS)作為一種基於Takagi-Sugeno模糊推理系統的人工神經網路(J.-S.R. Jang, 1993)，是具有監督式學習能力的前饋神經網路(Feedforward Neural Network, FNN)，被廣泛應用於電力系統和儲能系統等領域。

ANFIS的結構包括五個層次，由節點與有向邊所構成，部分甚至是全部節點皆具有自適應能力，可以讓節點自行學習規則並從中修正，使得誤差最小化，詳細如圖4所示，分別是



資料來源：Valencia *et al.*, 2023.

圖4 ANFIS基本架構示意圖

輸入層、規則層、正規化層、結論推論層和輸出層，每一層透過權重連接，方形節點代表參數可調整；圓形節點代表沒有參數或參數不可調整。

將輸入變數映射到模糊集合中，每個輸入變數的模糊集合被劃分為多個子集合，形成一個模糊化的輸入空間，各輸入變數的模糊集合進行先決條件的配對後，生成模糊的IF-THEN規則，這些模糊規則的組合進行模糊邏輯運算，接著將所得的結果正規化，確保每條規則的輸出值介於0到1之間，以避免對後續層次的影響，最後與Sugeno模糊公式相乘，形成最終的推論結果，公式如式(2)-(6)所示。

$$O_i^1 = \begin{cases} \mu_{A_i}(x_1) \\ \mu_{B_i}(x_2) \\ \mu_{C_i}(x_3) \end{cases} \quad (2)$$

$$\mu_i(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}}$$

for $i = 1, 2, \dots, n$

$$O_i^2 = w_i = \mu_{A_i}(x_1) \cdot \mu_{B_i}(x_2) \cdot \mu_{C_i}(x_3) \quad (3)$$

for $i = 1, 2, \dots, n$

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2 + w_3} \quad (4)$$

$$O_i^4 = \bar{w}_i f_i = w_i (p_i x + q_i y + r_i) \quad (5)$$

$$O_i^5 = \sum_{i=1}^n \bar{w}_i f_i = \frac{\sum_{i=1}^n w_i f_i}{\sum_{i=1}^n w_i} \quad (6)$$

其中，

O_i^1 為ANFIS輸入層的第 i 個節點；

$\mu_i(x_j)$ 為第 i 個隸屬度與第 j 個輸入變數的對應隸屬度值(Salleh *et al.*, 2017)；

$\{a_i, b_i \text{ 和 } c_i\}$ 為ANFIS的參數集合；

O_i^2 為ANFIS規則層的第 i 個節點；

w_i 為第 i 個節點的啟動函數；

O_i^3 為ANFIS正規化層的第 i 個節點；

\bar{w}_i 為正規化後的啟動強度；

O_i^4 為ANFIS結論推論層的第 i 個節點；

f_i 為ANFIS的第 i 個模糊規則；

$\{p_i, q_i \text{ 和 } r_i\}$ 為結論部分的參數集合；

O_i^5 為輸出層的第 i 個節點。

3.2 神經網路模型

卷機型神經網路模型共分為兩種，分別為

長短期記憶(Long Short-Term Memory, LSTM)與門控循環單元(Gated Recurrent Unit, GRU)，其中LSTM是一種深度學習的神經網路架構，旨在克服傳統遞歸神經網路(Recurrent Neural Network, RNN)在處理長序列資料時的局限性。

(Hannan *et al.*, 2020)通過引入特定的觸發機制，LSTM可以有效控制資料的積累和遺忘。LSTM的單元如圖5(a)所示。每個單元包含三個主要的門：輸入門、遺忘門和輸出門。

輸入門控制進入記憶單元的資料量，決定

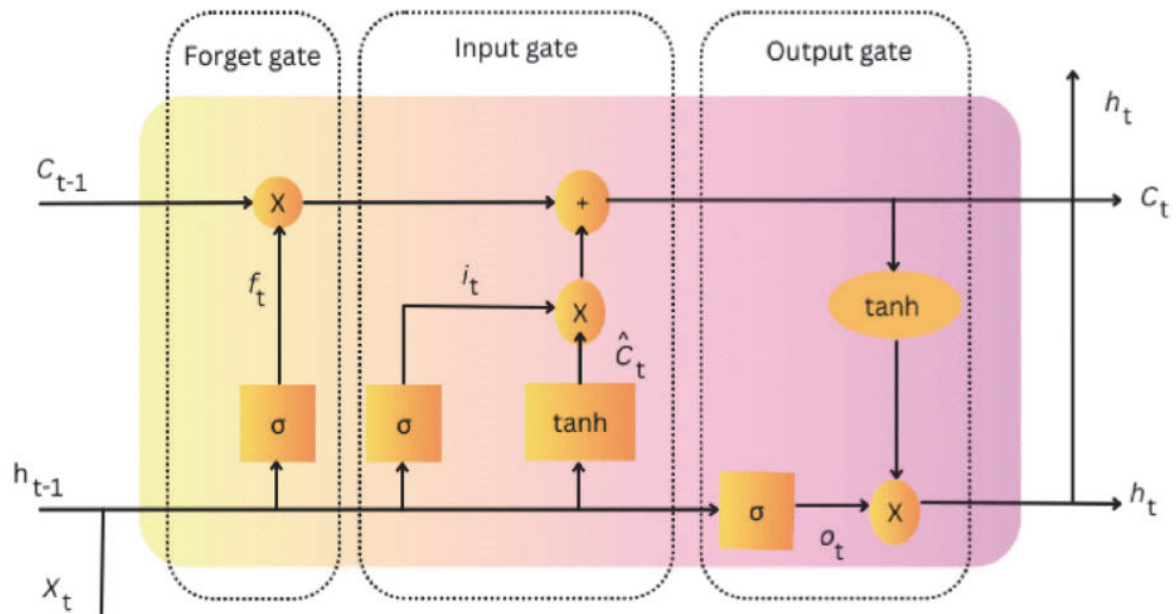



圖5(a) LSTM神經網路的單元示意圖



資料來源：Gole *et al.*, 2023.

圖5(b) GRU神經網路的單元示意圖

當前輸入資料是否需要被保存到單元；遺忘門通過sigmoid函數對前一時刻的資料進行篩選，決定單元中有哪些資料需要被遺忘，從而確定是否丟棄來自前一時刻的資料；輸出門首先通過sigmoid函數對輸出進行篩選，然後使用tanh函數對經過篩選的輸出進行縮放，最終將調適後的資料作為當前LSTM單元的輸出。這些門通過特定的激活函數來調節資料的流動和更新單元狀態，使得LSTM能夠在長期和短期記憶之間找到平衡，從而在處理長序列資料時表現出色。LSTM的架構公式如式(7)-(12)。

$$i_t = \sigma(W_{x_i}x_t + W_{h_i}h_{t-1} + W_{c_i}c_{t-1} + b_i) \quad (7)$$

$$f_t = \sigma(W_{x_f}x_t + W_{h_f}h_{t-1} + W_{c_f}c_{t-1} + b_f) \quad (8)$$

$$\tilde{c}_t = \tanh(W_{x_c}x_t + W_{h_c}h_{t-1} + b_c) \quad (9)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (10)$$

$$o_t = \sigma(W_{x_o}x_t + W_{h_o}h_{t-1} + W_{c_o}c_t + b_o) \quad (11)$$

$$h_t = o_t \odot \tanh(c_t) \quad (12)$$

其中，

i_t 為LSTM的輸入門；

o_t 為LSTM的輸出門；

f_t 為LSTM的遺忘門；

x_t 為時間 t 時的輸入；

h_t 為LSTM的隱藏狀態；

c_t 為LSTM的記憶單元；

\tilde{c}_t 為LSTM的備選狀態；

W 和 b 分別表示權重和偏差量；

σ 為S型函數；

門控循環單元(Gated Recurrent Unit, GRU)專門用於處理序列資料，尤其是時間序列資料。GRU以其獨特的架構和卓越的性能在神經網路領域中引起了廣泛關注，圖5(b)顯示了GRU的單元架構。

GRU中兩個關鍵的單元：重置門(Reset Gate)和更新門(Update Gate)，控制著資料的流動，以及何時和如何更新模型的內部狀態。重置門確定了先前狀態對當前狀態的影響，而更新門則確定了是否引入新的資料以及如何將其融入當前狀態中。

$$z_t = \sigma(W_zx_t + U_zh_{t-1} + b_z) \quad (13)$$

$$f_t = \sigma(W_fx_t + U_fh_{t-1} + b_f) \quad (14)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tanh(W_hx_t + U_h(r_t \odot h_{t-1}) + b_h) \quad (15)$$

其中，

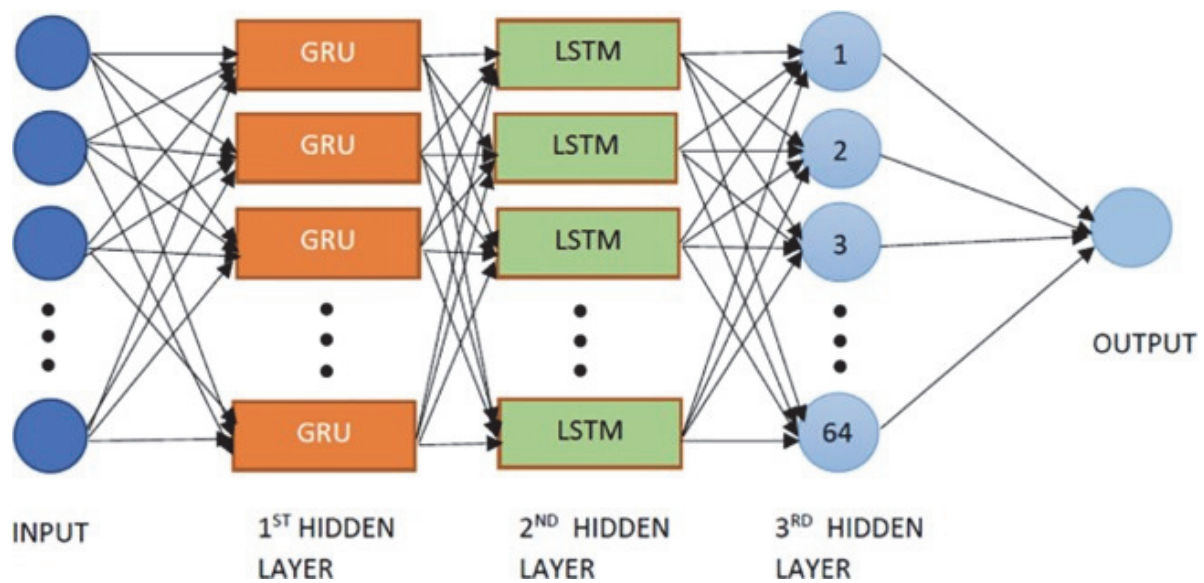
z_t 為GRU的更新門；

r_t 為GRU的重置門。

3.3 混合方法


混和方法共有兩種，分別為GRU-LSTM與LSTM-GRU，GRU-LSTM是一種結合了GRU和LSTM的深度學習模型，其神經網路架構如圖6(a)所示。與LSTM-GRU相比，GRU-LSTM在於隱藏層的連接順序不同，資料由第一個GRU的隱藏層通過並傳遞到LSTM層，由於GRU與LSTM的遺忘資料方式不同，本研究將建立LSTM-GRU的深度學習模型，觀察是否有所區別。

LSTM-GRU是一種結合了LSTM和GRU的深度學習模型，其神經網路架構如圖6(b)所示。LSTM以其專門設計的記憶單元和門結構在捕捉長期依賴關係方面表現出色。相對而言，GRU以其簡化的結構和高效的計算特性而聞名。這種結合的目的在於希望充分發揮兩種模型的優勢，提升計算速度的同時降低模型複雜度，從而提高對序列資料的處理性能和準確性(Hong *et al.*, 2024)。透過更改連接層數順序的不同，觀察GRU-LSTM與LSTM-GRU兩者間



資料來源：Islam and Hossain, 2021.

圖6(a) GRU-LSTM神經網路的架構示意圖



資料來源：Hong *et al.*, 2024.

圖6(b) LSTM-GRU神經網路的架構示意圖

之模型，對於GRU與LSTM資料的遺忘多寡是否會影響最終訓練結果進行優劣評判。

4. 碳排放量與碳費

碳排放量意旨在一定時間內所排放的二氧化碳(CO₂)及其他溫室氣體的總量。這些排放主要來自燃燒化石燃料(如煤、石油和天然氣)、工業過程、農業活動、森林砍伐等。碳排放量以二氧化碳當量(CO_{2e})來衡量，這個單位同時考慮了其他溫室氣體(如甲烷、氧化亞氮)的對全球暖化的影響，使得它們可以與二氧化碳的

影響直接比較。

排碳係數是指單位能源產生的二氧化碳排放量，作為評估電力產生對環境影響的重要指標。根據不同國家的能源結構、技術水平及政策等，使得排碳係數受到影響。臺灣在111年所公布的電力排碳係數為0.495 kgCO_{2e}/度(經濟部能源署，2023)，表示每1度電伴隨著0.495公斤的二氧化碳當量；美國國家可再生能源實驗室(National Renewable Energy Laboratory, NREL)(Nicholson and Heath, 2021)所提供的鋰離子電池排碳係數為0.033 kgCO_{2e}/度。當電動車連接儲能充電樁進行充電時，在儲能微電網系統中，

碳排放總量包含市電端、負載端、電池端以及傳輸路徑加總所產生的碳排，對於不同設備所產生的功率，乘以其相對應的排放係數並相加，即為系統的總碳排放量，公式如(16)所示：

$$T_{CE} = \sum_{i=1}^n \gamma_i \times P_i \quad (16)$$

其中，

T_{CE} 是系統所產生的總碳排放量(kgCO_{2e})；

γ_i 是設備 i 所對應的排碳係數(kgCO_{2e}/kWh)；

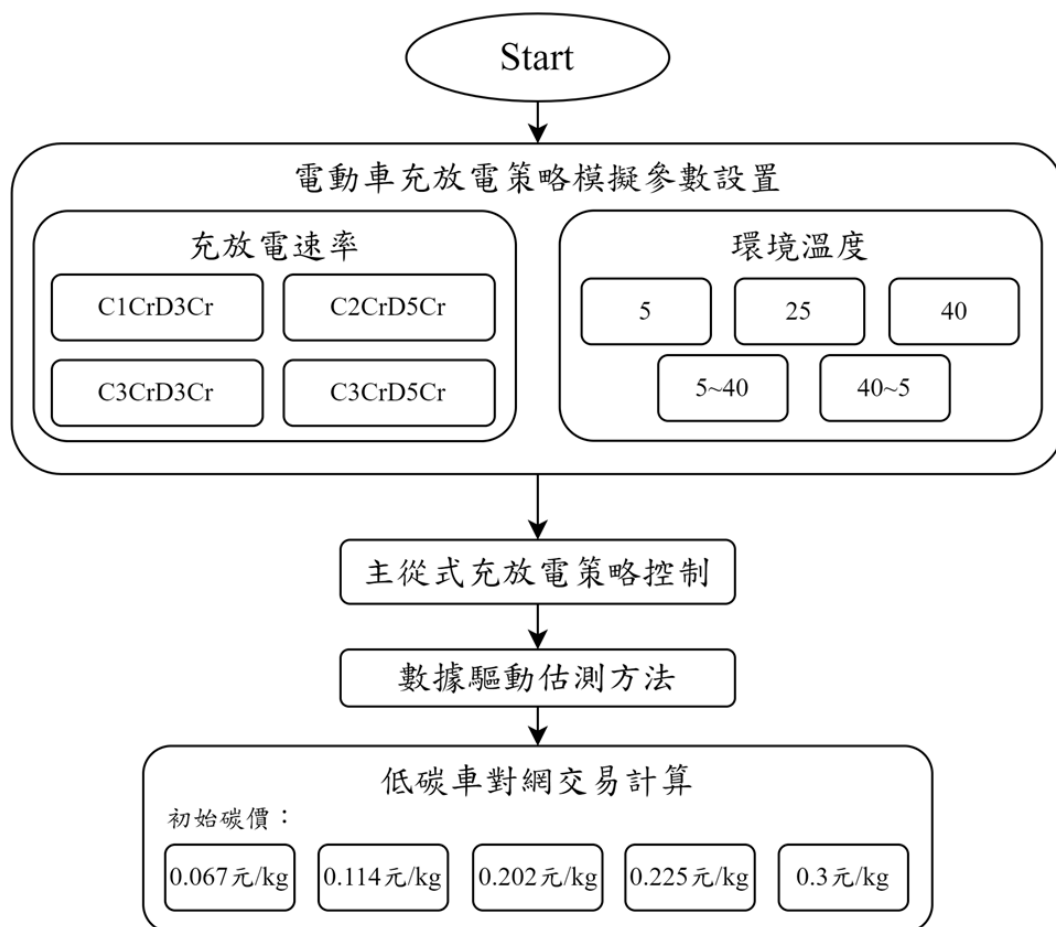
P_i 是設備 i 所產生的功率(kWh)。

5. 研究架構

本研究基於所提出的方法進行整合，連接市電與電動車，利用 MATLAB/Simulink 建立分

散式微電網作為研究模型。為了模擬電動車不同的使用情境，本研究建立了四種不同充放電速率，並在每種速率下採用五種不同的環境溫度(T_{amb})做為電動車的變數。首先，利用兩組電池組設立主從模式的充放電架構，內含之參數設置包含充放電速率共4種模式及環境溫度，並採取本研究所設計之數據驅動估測方法，執行電壓(V_b)與電池電量(SOC)的估測輸出，最後呈現其低碳車對網交易模組，碳排放量與初始碳價計算，研究架構如圖7所示。

本研究對於分散式微電網的建立分為市電與電動車兩個部分。其中，市電併網再生能源的提供來源，相對相電壓設定為220 V；電動車內建構主要與從屬兩個電池組，透過交/直流轉換器與升降壓電路連接市電，模擬電動車路上



資料來源：本研究彙製。

圖7 本研究微電網模擬系統示意圖

表4 本研究電池模擬參數設置表

系統設備	額定電壓(V)	額定容量(Ah)	初始 SOC (%)
主從式(MS)鋰離子電池	48	100	75
單顆(Single)鋰離子電池	48	200	75

資料來源：本研究彙整。

充電時，與充電公路的電力交換情境。鋰離子電池選用MATLAB/Simulink中的電池特性，如表4所示，由於電池主從式的交互充放電，使電池的電力即時的達到補充，而不需要太多的電池容量，同時電池設計容量的減少也可以為電動車減少重量。因此，本研究在設計時將主從式的電池組額定容量設定為預設單顆電池的一半，電池電壓為48 V，容量以方罐電池100 Ah做為額定容量，並將主要電池與從屬電池的初始電壓設為75%，模擬電動車剛啟動運行時的情境。另外，單顆電池作為對照組將額定電壓設定為48 V，容量則為200 Ah。

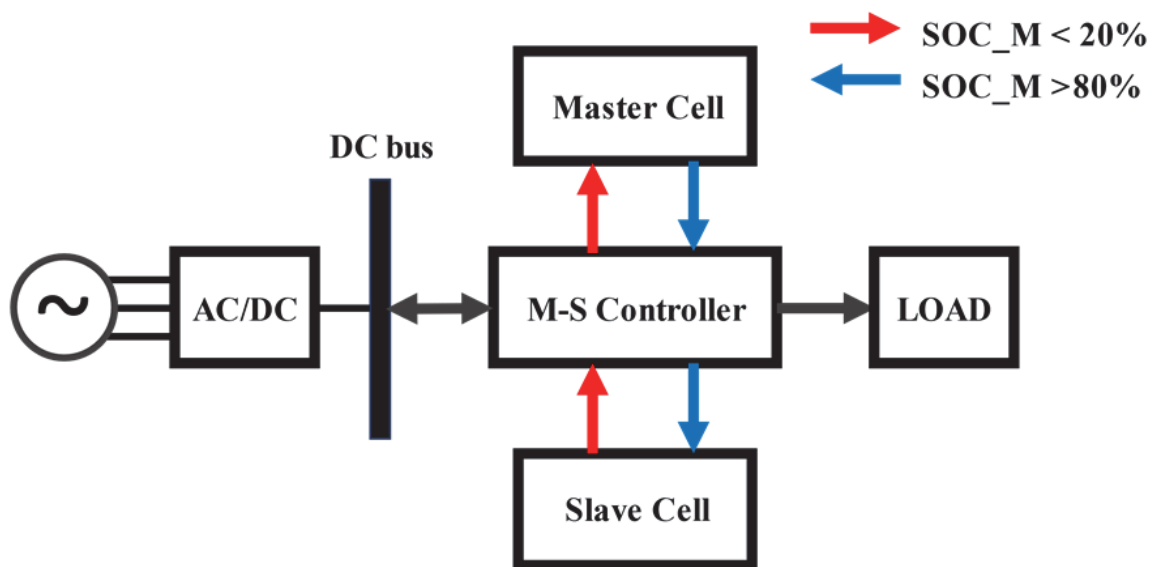
5.1 主從式電池充放電策略

本研究透過建立主要與附屬兩組電池組進

行電動車充放電循環，其主從式的切換控制開關是基於電池的SOC，利用主要電池組的SOC作為主要控制，對整體系統進行開關轉換，並根據圖2的最佳運轉範圍設計控制策略，其架構說明如圖8所示。

當系統啟動時，預設對主電池組進行充電，而後監測SOC值，當主要電池組的SOC充電至高於80%時，則主要電池對負載進行放電，從屬電池在同一時間充電；相反，當主要電池組的SOC放電至低於20%時，則主要電池重新充電，並由從屬電池對負載進行放電，詳細的主從式控制器切換流程如表5所示，其中，M代表主電池，S代表副電池，C代表電池充電，D代表電池放電，T代表停止充放電。

舉例而言，當主副電池SOC都大於80%



資料來源：本研究彙製。

圖8 本研究主從式充放電策略示意圖

表5 本研究主從式充放電控制策略表

主電池副電池	> 80%	80-20%	< 20%
> 80%	MD、ST	MD、ST	MC、SD
80-20%	MD、SC	MD、SC	MC、SD
< 20%	MD、SC	MD、SC	MT、ST

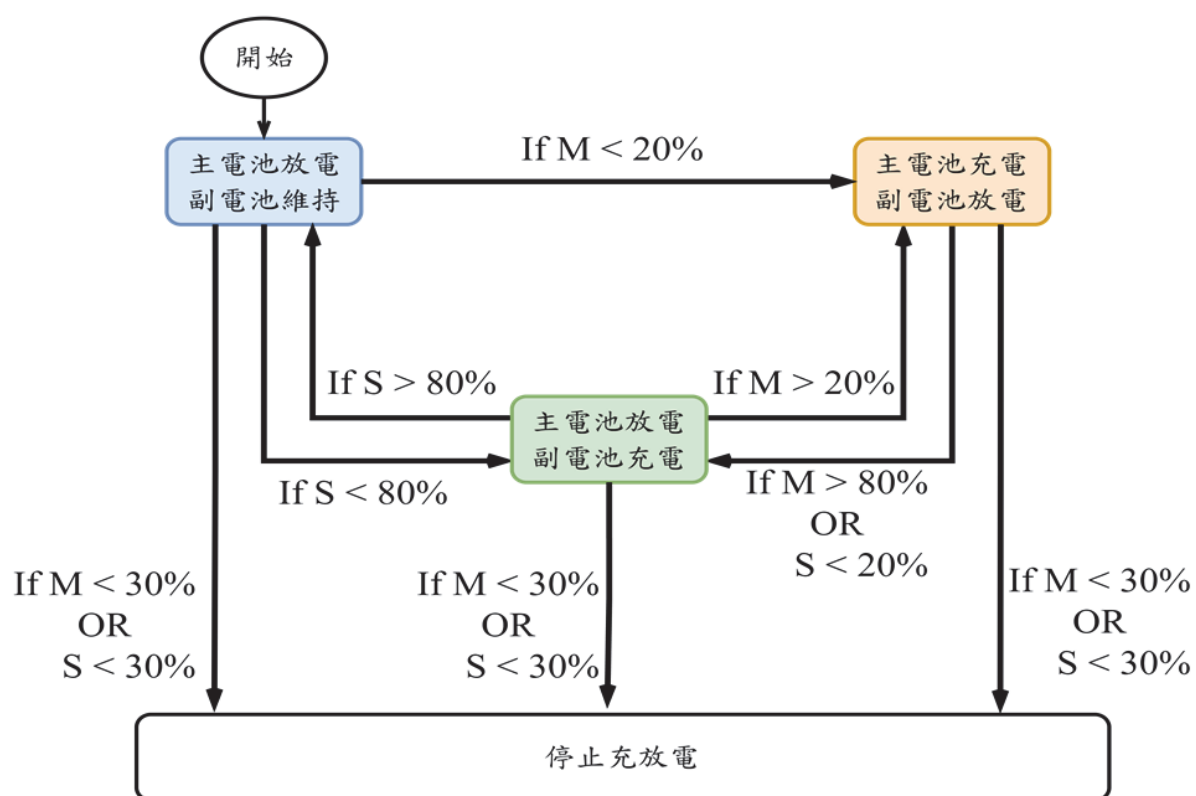
資料來源：本研究彙製。

時，對應的情形為MD、ST，代表主電池SOC放電而副電池維持當前電量。另外，由於電動車放電的速率(C-rate)大於充電的速率，因此主從式充放電策略在執行時，主副電池的電量都會逐漸減少，為避免電動車沒有足夠的電量可以為電動車進行後續充電，故本研究額外將主從式的充放電控制提前截止在SOC為30%時，整體的流程圖如圖9所示。透過兩組電池組交互充放電為電動車提供穩定電力，使得車輛能維

持在一定的可行駛電量，電動車的續航能力能夠達到提升，改善需要定點充電造成的里程焦慮問題。

5.2 電池充電狀態估測

本研究透過MATLAB / Simulink模擬蒐集電動車電池的特徵資料，輸入和輸出的向量定義為：



資料來源：本研究彙製。

圖9 本研究主從式充放電策略狀態圖


$$\begin{cases} X_k = [V_{b,k}, I_{b,k}, T_{cell,k}] \\ Y_{1,k} = [SOC_k] \\ Y_{2,k} = [V_{b,k}] \end{cases} \quad (17)$$

試集(test)，詳如圖11所示，擷取數據特徵為驅動模型之訓練基礎。

5.2.1 自適應模糊邏輯模型


估測模型採用數據驅動模型估測電池的 V_b 與SOC，如圖10所示。同時，將所收集之資料切分成訓練集(training)、驗證集(validation)和測

本研究利用鐘型函數設計出帶有五個域度的歸屬函數，架構如圖12所示。為了訓練這些歸屬函數，從系統中擷取80%的資料作為訓練



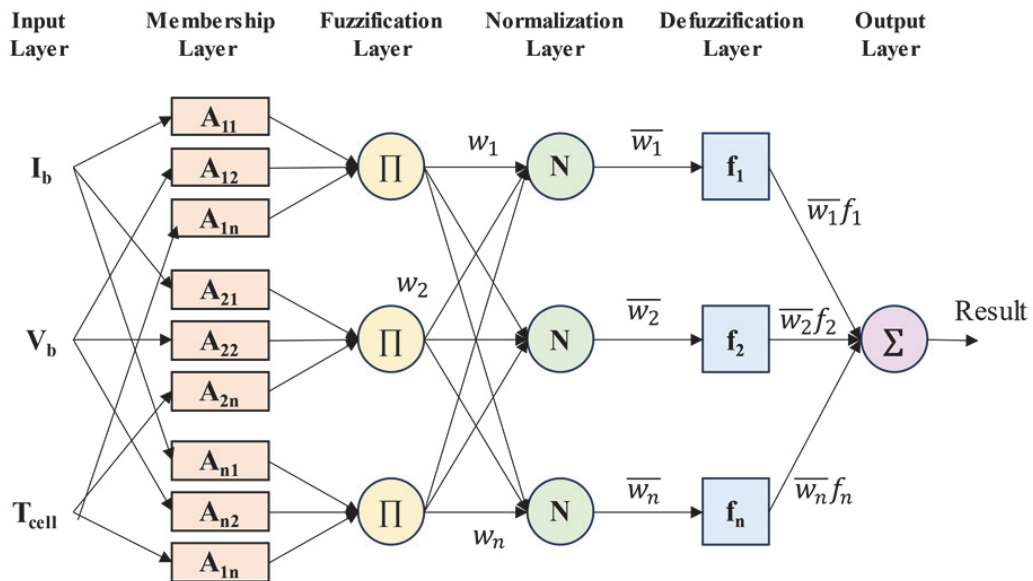
資料來源：本研究彙製。

圖10 本研究之估測方法示意圖



資料來源：本研究彙製。

圖11 本研究之切分資料示意圖



資料來源：本研究彙製。

圖12 本研究ANFIS架構圖

表6 本研究ANFIS模型訓練參數設定表

項目	參數	說明	設定參數
模糊邏輯系統	genfis Options	生成歸屬函數與模糊規則	Grid Partition
	Initial FIS	輸入變數的歸屬函數個數	5
	Input MF Type	輸入變數的歸屬函數類型	gaussmf
	Output MF Type	輸出變數的歸屬函數類型	constant
人工神經網路	Epoch Number	迭代次數	350
	Optimization Method	訓練最佳化方式	hybrid
	Error Tolerance	訓練誤差容忍值	0.5

資料來源：本研究彙整。

資料，同時保留一部分作為測試資料以避免過擬合。在模型訓練以前，需要先設定模糊推論系統之參數，包含歸屬函數、訓練次數與誤差等相關參數，詳細設定如表6所示。透過設定的相關參數對控制器的前提參數與結論參數進行學習，最終得到其估測與實際值。這種方法有效地綜合了模糊邏輯與神經網路的優勢，提高了電池容量百分比的估測精度。

5.2.2 長短期記憶模型

在文獻(Vidal *et al.*, 2022)提到，隱藏層層數越多，訓練過程越困難，且準確率並不會顯著提高。因此，本研究決定採用單層LSTM隱藏層架構來簡化模型，同時提高訓練效率。本研究參考文獻(Hong *et al.*, 2024)中對LSTM隱藏層單元數量的設置，利用隨機搜尋法對LSTM隱藏層進行了32、64、128三種不同單元數量的訓練測試，並挑選準確度最高的模型，其訓練

結果如表7所示。

經比較發現當隱藏層的單元數量設置為64時，模型的準確度達到最佳。因此，本研究構建了一層長短期記憶層和三層全連接層的神經網路架構，其中LSTM單元如圖13所示。此外，模型的相關訓練參數設置如表8所示：學習率為0.001，批次大小為64，最大迭代次數為350並選用Adam優化器進行訓練。

5.2.3 門控循環單元模型

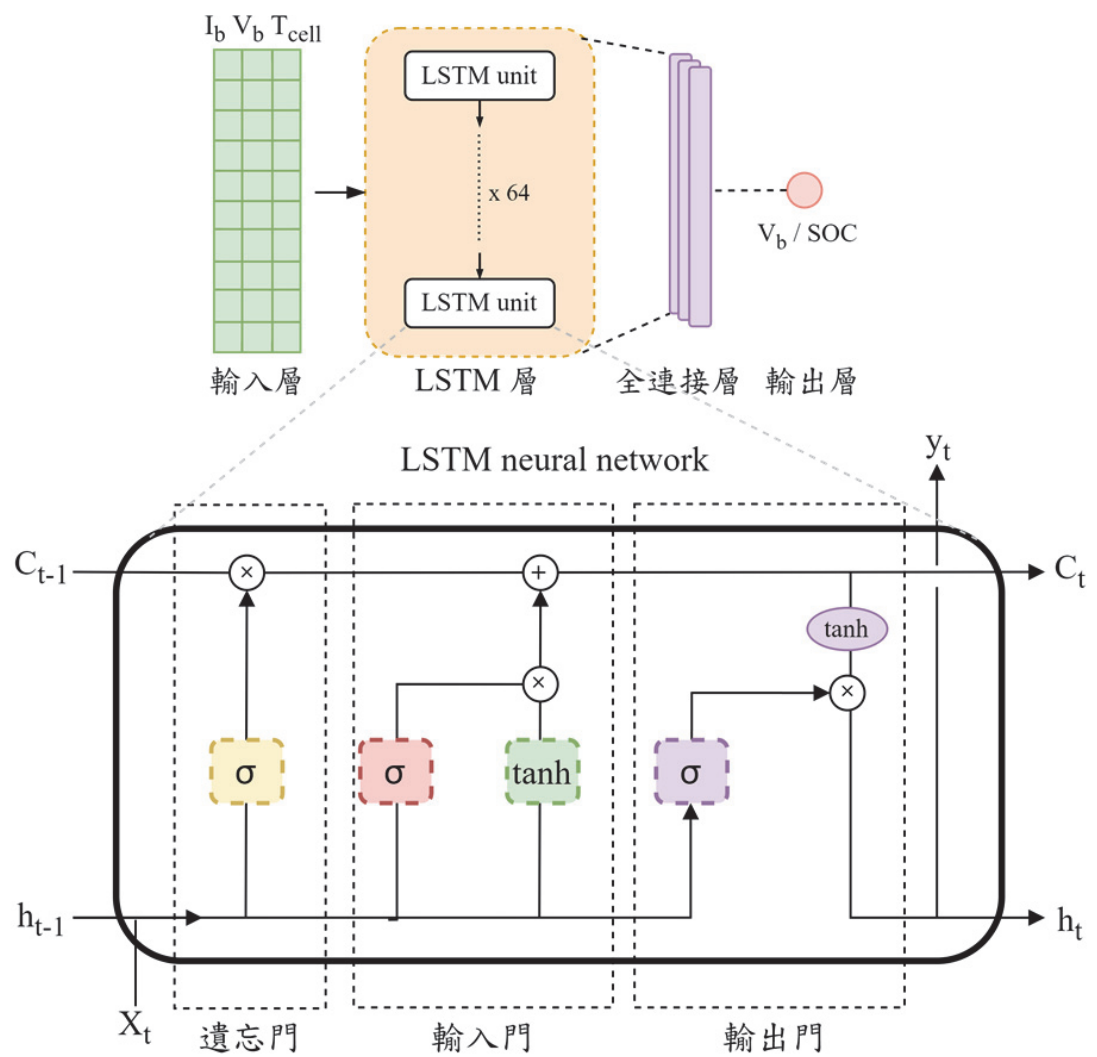
本研究構建了一層GRU層和三層全連接層的神經網路架構，如圖14所示。為了比較該模型與5.2.2模型之優劣，因此，模型的相關參數設置與LSTM一致，如表9所示：學習率為0.001，批次大小為64，最大迭代次數為350並選用了Adam優化器進行訓練。

5.2.4 混合模型(GRU-LSTM)

表7 本研究LSTM隱藏層比較表

LSTM隱藏層	32	64	128
驗證RMSE(%)	8.6451	2.447	3.2408
訓練時間	68分5秒	135分42秒	139分35秒

資料來源：本研究彙整。



資料來源：本研究彙製。
圖13 本研究LSTM架構示意圖

表8 本研究LSTM的參數選擇表

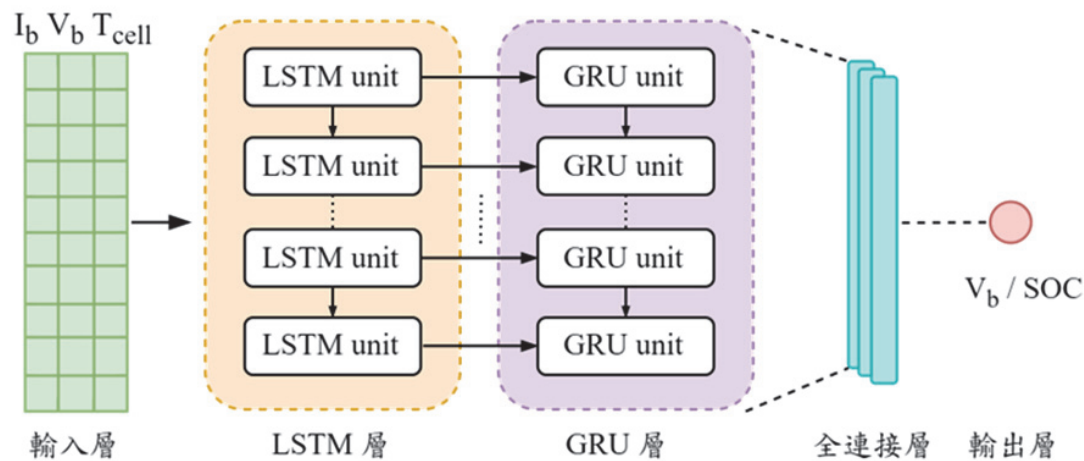
模型參數	參數設置
LSTM隱藏單元	64
全連接層第一層	64
全連接層第二層	32
全連接層第三層	16
學習率	0.001
批次大小	64
最大迭代次數	350
優化器	Adam

資料來源：本研究彙整。

表9 本研究GRU的超參數選擇表

模型參數	參數設置
GRU 隱藏單元	64
全連接層第一層	64
全連接層第二層	32
全連接層第三層	16
學習率	0.001
批次大小	64
最大迭代次數	350
優化器	Adam

資料來源：本研究彙整。



資料來源：本研究彙製。

圖15 本研究GRU-LSTM架構示意圖

表11 本研究GRU-LSTM的超參數選擇表

模型參數	參數設置
GRU 隱藏單元	64
LSTM 隱藏單元	64
全連接層第一層	64
全連接層第二層	32
全連接層第三層	16
學習率	0.001
批次大小	64
最大迭代次數	350
優化器	Adam

資料來源：本研究彙整。

表12 本研究LSTM-GRU的超參數選擇表

模型參數	參數設置
LSTM 隱藏單元	64
GRU 隱藏單元	64
全連接層第一層	64
全連接層第二層	32
全連接層第三層	16
學習率	0.001
批次大小	64
最大迭代次數	350
優化器	Adam

資料來源：本研究彙整。

用了Adam優化器進行訓練，如表11所示。

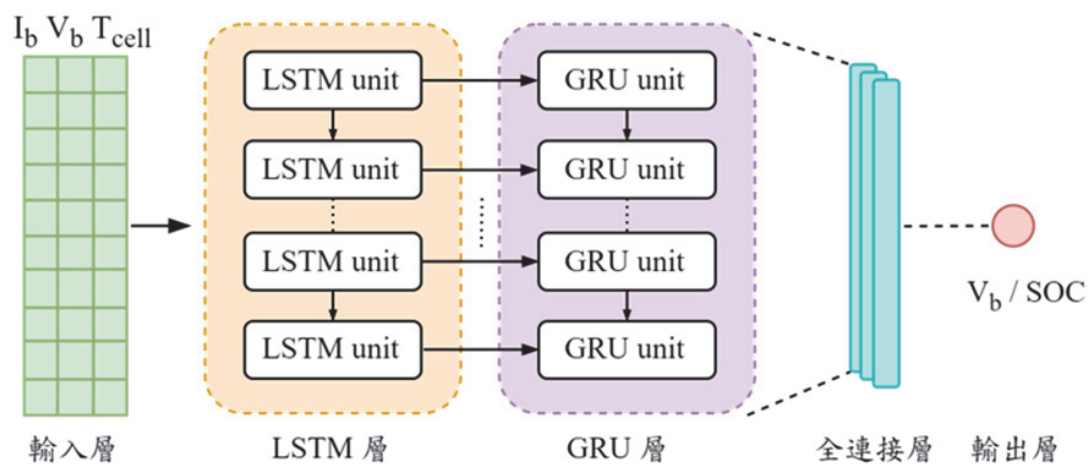
5.2.5 混合模型(LSTM-GRU)

本研究構建了LSTM與GRU兩層隱藏層和三層全連接層的神經網路架構，如圖16所示，為了與5.2.4模型進行比較，因此相關參數設置與此模型相同，如表12所示。

5.3 碳排放量與碳費計算

首先，本研究將針對主從式電池組和單顆電池的運行機制進行碳排放量與碳費的計算，將鋰離子電池的碳排係數以0.033 kgCO_{2e}/度作為標準，計算其碳排放量。其次，將針對數據驅動估測模型比較彼此的碳排損失量與碳費。本研究將以The World Bank初估每公噸大約臺幣300元之碳價代為計算(World Bank Group, 2023)計算碳費標準，其相關計算式如下：

$$F^C = \sum_{i=1}^n C_{M_i} T_{CE}$$
 (18)



資料來源：本研究彙製。

圖16 本研究LSTM-GRU架構示意圖

其中，
 F^C 是系統的總碳費
 T_{CE} 是系統所產生的總碳排量
 C_{M_i} 為不同國家之碳定價
同時參考周邊亞洲國家的初始碳價共同探討(InfoLink Consulting, 2024)，如圖17所示。

6. 研究結果

本研究成果考慮電動車在低碳車對網充放電情境中的應用，經實驗成果開發電動車充放電策略指引，如圖18所示。通過詳細的實驗分析與模型訓練，本文係以逐步式(step-by-step)提出最適合的電動車運行狀態參數選擇方法，並通過模型評價函數(MAE)作為指標，逐步篩

選出最適合的狀態估測模型，以最大限度地減少碳排放，並提升電動車的能源利用效率。

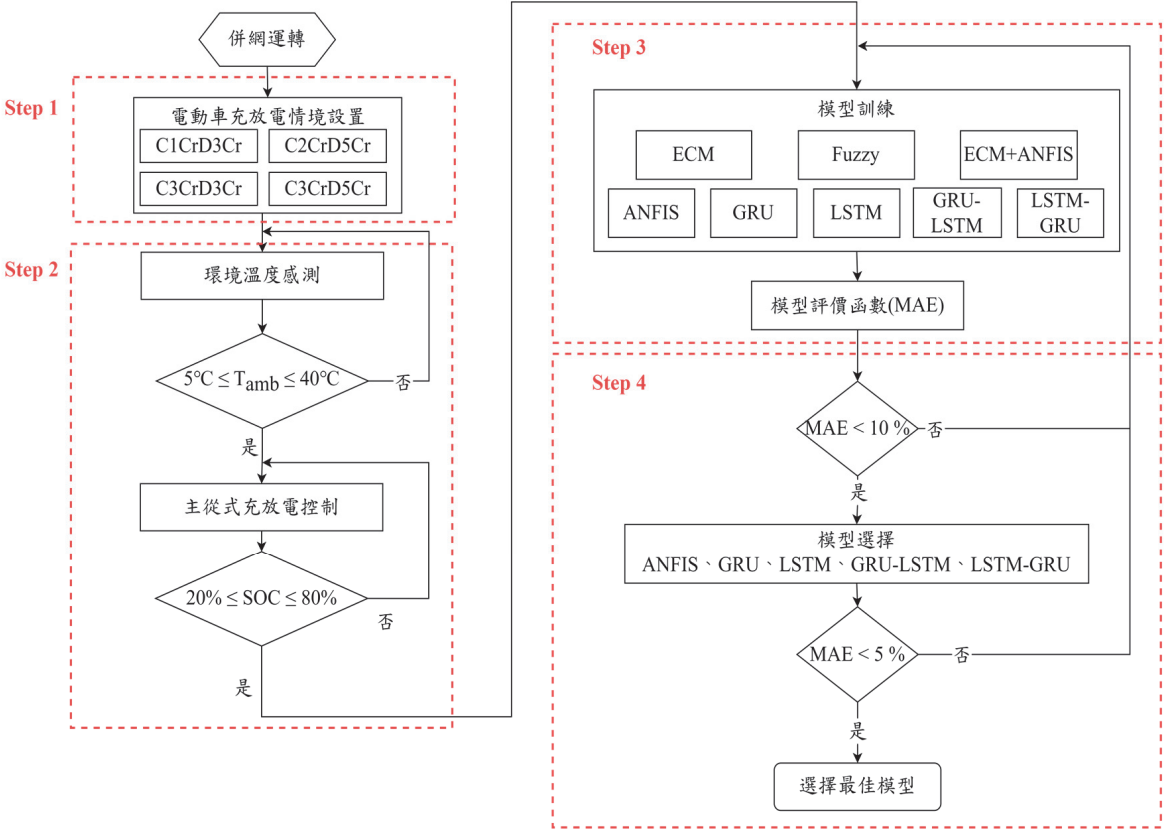
6.1 逐步式模型訓練

- Step 1. 選定初始電動車的模擬環境
- 首先設置電動車的模擬環境，充電速率設定為1 C到3 C之間，放電速率則為3 C和5 C (Yang *et al.*, 2019)，如表13所示。考慮到環境溫度對電池性能的影響，我們將環境溫度是否設置在5°C至40°C之間，並模擬不同的環境溫度狀態。
- Step 2. 環境溫度感測與充電範圍界定
- 表14所示，以全面評估電池在不同環境溫度條件下的工作狀態，並確保實驗環境皆坐落在環境溫度5°C至40°C，階段保護電池不受外在

	中國	日本	南韓	新加坡
	碳交易	地球暖化對策稅	碳交易	碳稅
初始價格	NT\$ 225	NT\$ 67	NT\$ 202	NT\$ 114
現價	NT\$ 247	NT\$ 67	NT\$ 319	NT\$ 114

資料來源：InfoLink Consulting, 2024.

圖17 亞洲國家碳定價介紹圖



資料來源：本研究彙製。

圖18 電動車充放電策略指引流程圖

表13 充放電速率與代號對照表

充放電速率	代號
充電 1 C 放電 3 C	C1Cr-D3Cr
充電 2 C 放電 5 C	C2Cr-D5Cr
充電 3 C 放電 3 C	C3Cr-D3Cr
充電 3 C 放電 5 C	C3Cr-D5Cr

資料來源：本研究彙整。

表14 溫度與代號對照表

溫度	代號
5°C	T5
25°C	T25
40°C	T40
5°C到40°C	T540
40°C到5°C	T405

資料來源：本研究彙整。

環境溫度影響其儲能之性能。

接著，採用主從式控制策略對電網進行充放電控制，當SOC運作範圍介於20%~80%之間時，進行模型訓練，以確保電池在最佳性能範圍內運作。在模型驗證的評價指標平均絕對誤差(MAE)小於10%，初步篩選出ANFIS、GRU、LSTM、GRU-LSTM、LSTM-GRU五種模型；倘若MAE小於5%，本研究開發的LSTM-GRU模型呈現出最佳的預測準確性和可靠性。

Step 3. 估測模型訓練與評價指標分析

依絕對誤差<10%之標準，採用ANFIS、GRU、LSTM、GRU-LSTM和LSTM-GRU 5種估測方法。將同一溫度下，4種不同的電池充放電速率中的特徵，包含電池充電狀態(SOC)、電池電流(I_b)、電池電壓(V_b)以及電池內部溫度(T_{cell})，作為模型估測的輸入或輸出訓練資料，

表15 在不同溫度下模型 V_b 估測MAE性能表

溫度	ANFIS	GRU	LSTM	GRU-LSTM	LSTM-GRU
T5	1.39%	0.19%	0.28%	0.68%	0.41%
T25	0.55%	0.20%	0.43%	0.16%	0.68%
T40	1.59%	0.18%	0.11%	0.21%	0.18%
T540	0.51%	0.54%	0.68%	0.44%	0.34%
T405	2.80%	2.68%	0.28%	1.03%	0.38%
平均	1.37%	0.76%	0.36%	0.50%	0.40%

資料來源：本研究彙整。

最終在不同的估測方法下，各自得到環境溫度狀態的預訓練模型，並觀察不同充放電速率在不同的估測方法下 V_b 的估測結果，詳如表15所示。

表16統整了5種不同環境溫度(T5、T25、T40、T540、T405)下，5種不同模型(ANFIS、GRU、LSTM、GRU-LSTM、LSTM-GRU)所得到的MAE值，於不同環境溫度狀態下，執行剩餘容量之估測性能。

Step 4. 模型選擇與最佳化決策模型

在綜合比較各模型於不同溫度條件下的表現後，可得以下結論：ANFIS模型的MAE小於8.3%，顯示其在電力數據估測中具有中等的準確性，但較深度學習模型稍遜。GRU模型的MAE小於9.6%，表現不如其他模型，且

由於其在處理長期依賴性資料時丟棄較多前一時刻資料，影響了性能。LSTM模型的MAE小於6.5%，顯示出最佳的長期依賴性資料處理能力，在估測準確性上優於ANFIS和GRU。另外，GRU-LSTM模型的MAE小於8.2%，結合兩者並未顯著提升性能。

依 $MAE < 5\%$ 之標準，LSTM-GRU模型的MAE小於4.7%，在所有模型中表現最佳，能更準確地估算SOC與 V_b ，從而提升主從式充放電策略的精準度。此外，GRU模型因在處理長期依賴性資料方面的能力不如LSTM，導致其在剩餘容量估算上的表現相對差強人意。進一步證實了在剩餘容量估算上，LSTM模型的優越性。

綜上所述，本研究在不同環境溫度下對

表16 不同模型SOC估測MAE性能表

溫度	ANFIS	GRU	LSTM	GRU-LSTM	LSTM-GRU
T5	5.03%	4.93%	2.65%	8.18%	2.84%
T25	2.01%	3.32%	3.83%	6.56%	2.42%
T40	4.64%	9.53%	5.55%	9.12%	4.31%
T540	4.41%	6.07%	4.29%	5.07%	3.52%
T405	8.23%	8.42%	6.43%	6.97%	4.68%
平均	4.86%	6.45%	4.55%	6.98%	3.56%

資料來源：本研究彙整。

剩餘容量估算模型進行了全面比較，結果顯示 LSTM-GRU 模型在環境溫度 25°C 下的追蹤結果最佳。該模型能夠有效減少儲存容量的損耗，為主從式系統以及後續的碳排放估算，提供更好的切換時機與碳排放量消耗的預測。這些結果為提升電動車的能效管理和續航里程提供了重要的理論依據碳排放量結果。

6.2 充放電策略調度與故障分析

當電動車與市電正常連接行駛時，架構如圖19所示。依據電動車的模擬環境，考慮環境溫度對電池性能的影響與放電速率監控，於正常行駛時，評估最適合的電動車運行狀態參數，正常情境下的運行結果如圖20所示。

除了主從式在正常充放電行為外，為了模擬電動車的故障行駛情形，其中，以灰色區塊代表故障行駛的架構，如圖21所示。

本研究也針對主從式電池組建立主電池在充電或放電故障的兩種情形。第一種為主電池充電時故障，將充電故障時機設置在時間 900 至 1,100 秒之間，改由副電池對負載提供電力直至副電池 SOC 小於 30%，如圖22。第二種為主電池放電時故障，放電故障時機設置在時間 500 至 700 秒之間，副電池從充電狀態切換至放電直至副電池 SOC 小於 30%，如圖23所示。

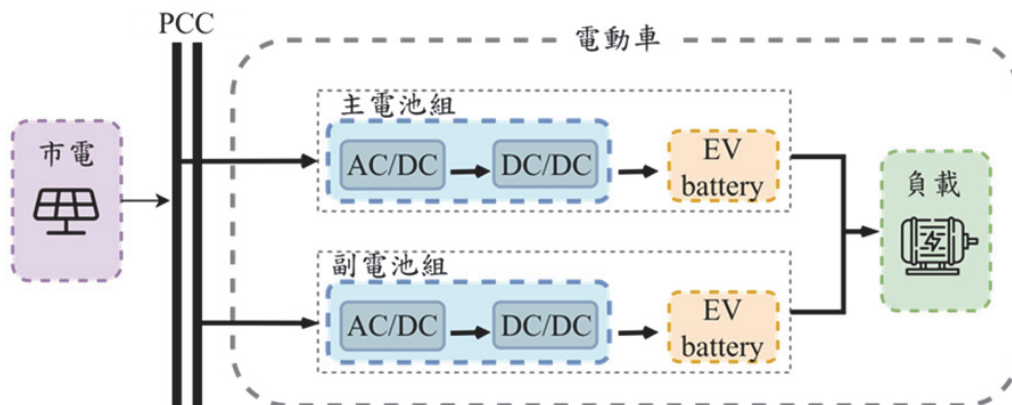
表17為主從式電池組與單電池在標準電動車電池運行溫度(25°C)正常運行情境下的實驗結果，在正常運行模式下，研究結果顯示主電池平均消耗為 62.75 Ah、副電池平均消耗為 71 Ah 時，單電池的平均消耗為 173 Ah。兩者比較後之平均電量消耗量 E 計算如下：

$$E = 173 - 62.75 - 71 = 39.25 \text{ Ah} \quad (19)$$

由此可知，主從式電池架構在優化電池使用性能方面比單電池多了 39.3 Ah 調度優勢。

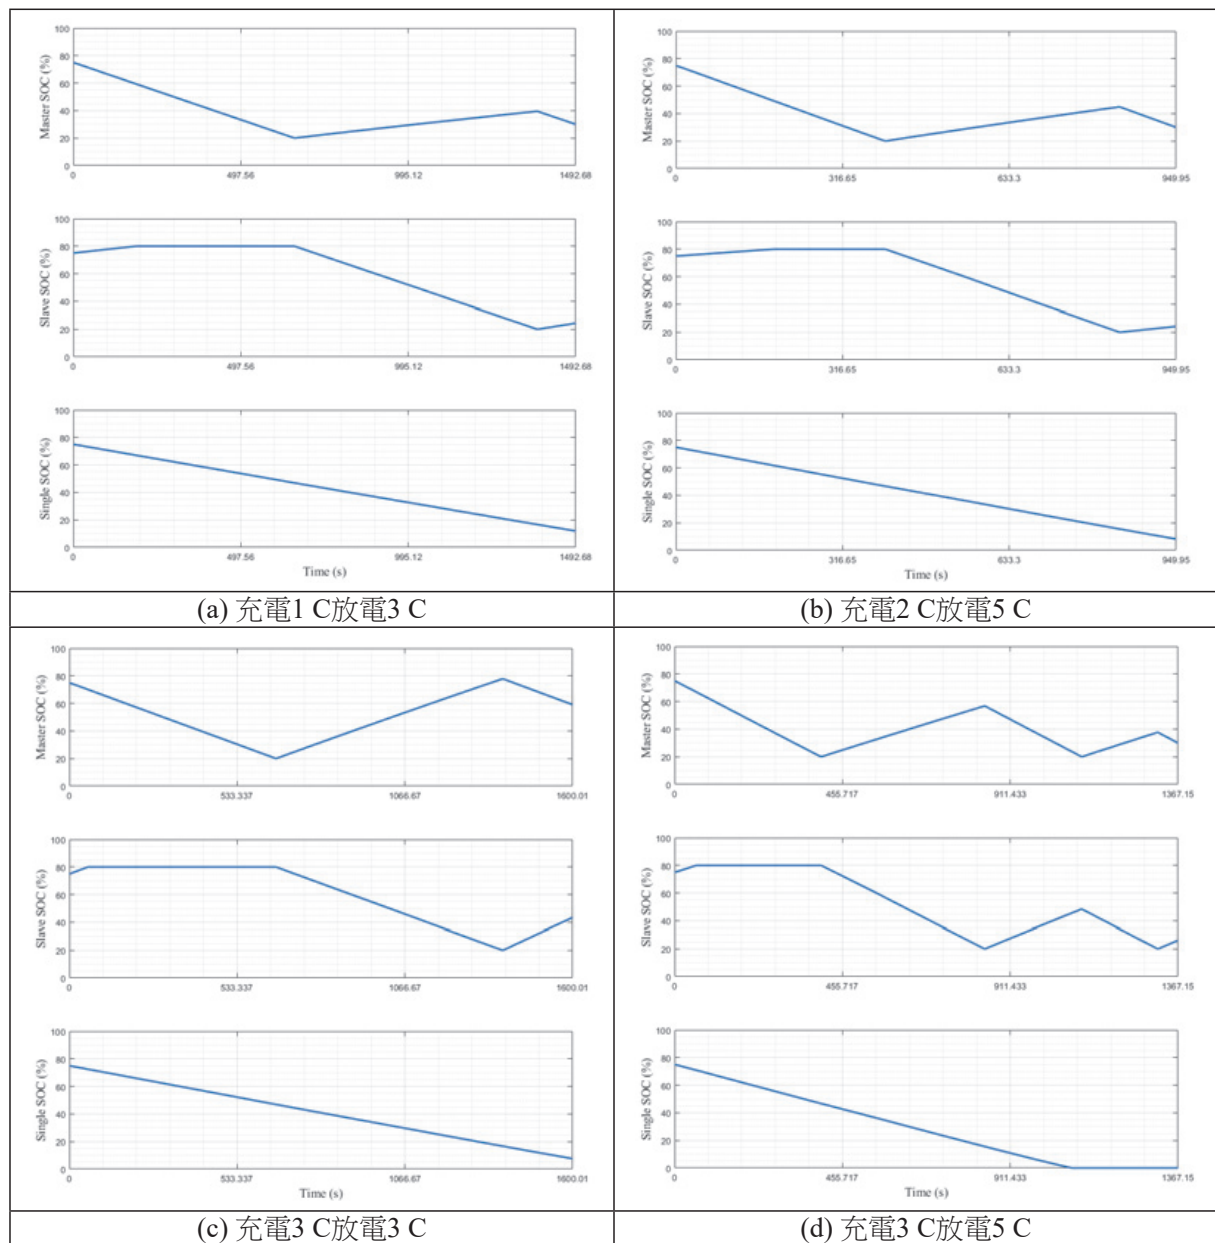
透過主從式電池系統的電量調配，有效延長電池組的總使用壽命，進一步提高了電動車的續航里程。此系統確保電池能夠最大化利用，使車輛的行駛里程延長。在主從式電池架構中，當其中一組電池發生故障時，另一組電池能夠接管並提供足夠的電力支持，保證電動車的正常運行，符合電力系統調度(N-1)原則。相比之下，單電池系統在故障時則直接癱瘓車輛無法繼續行駛。因此本研究之主從式電池充放電設計，大幅提高了電動車系統的可靠性和安全性，降低了因電池故障而導致電動車停運的風險。

綜上所述，主從式電池組架構不僅在正常運行階段提升了電動車的續航里程，而且在故障情境下也顯示出更高的穩定性和可靠性。這



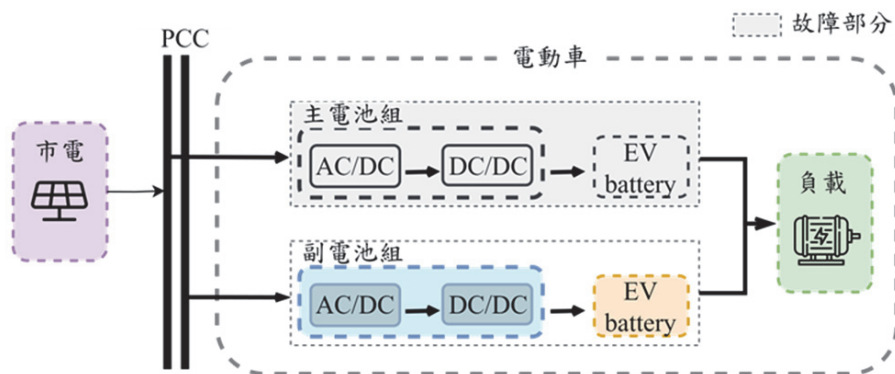
資料來源：本研究彙製。

圖19 本研究電動車正常行駛時架構圖



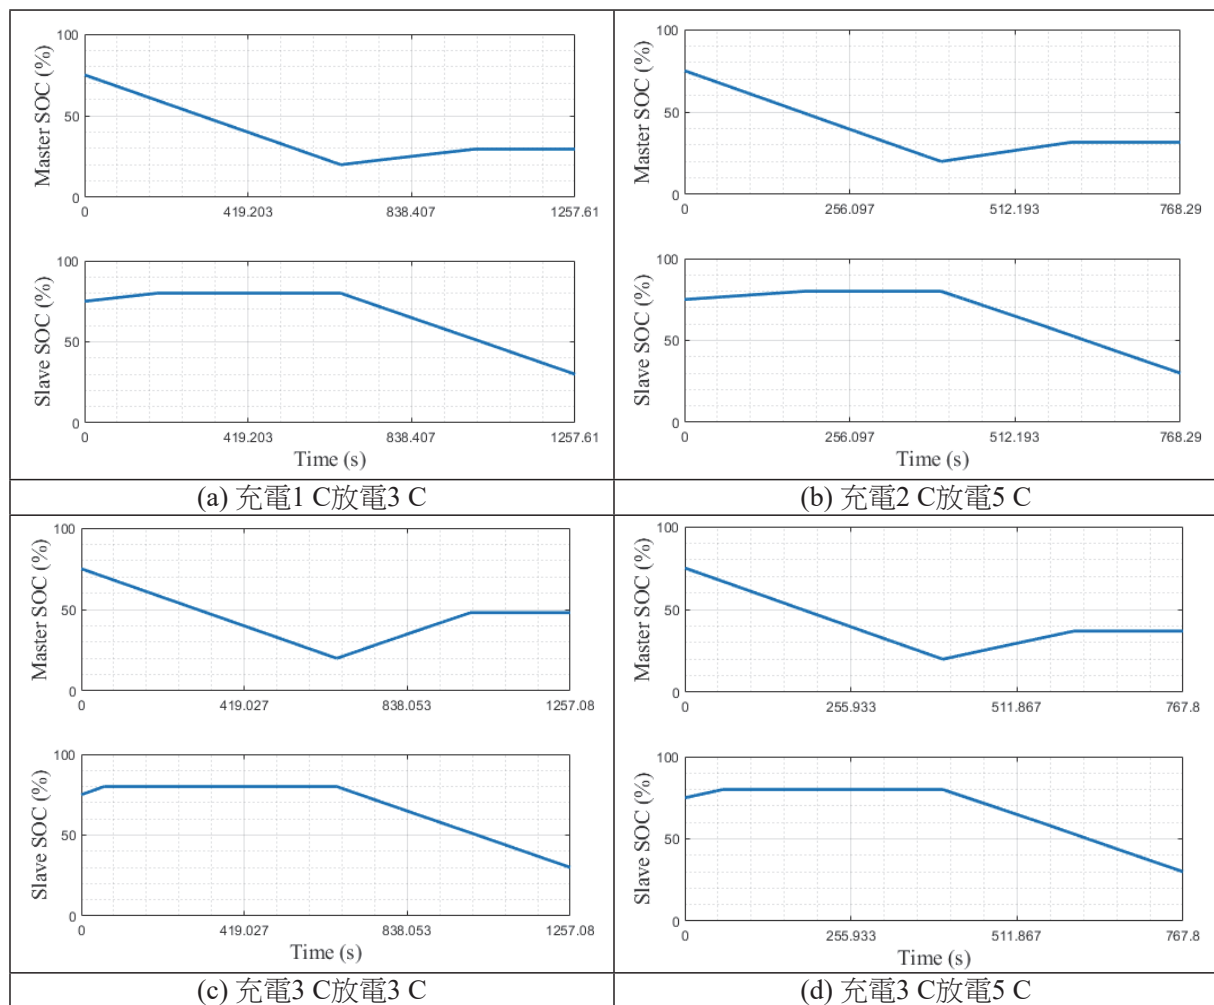
資料來源：本研究彙製。

圖20 正常情境下的充放電曲線圖



資料來源：本研究彙製。

圖21 本研究電動車主電池組故障架構示意圖



資料來源：本研究彙製。

圖22 主電池充電時故障下的充放電曲線圖

些優勢使得主從式充放電策略成為電動車未來發展的一個重要方向，具有廣泛的應用前景和研究價值。

6.3 硬體在環實現

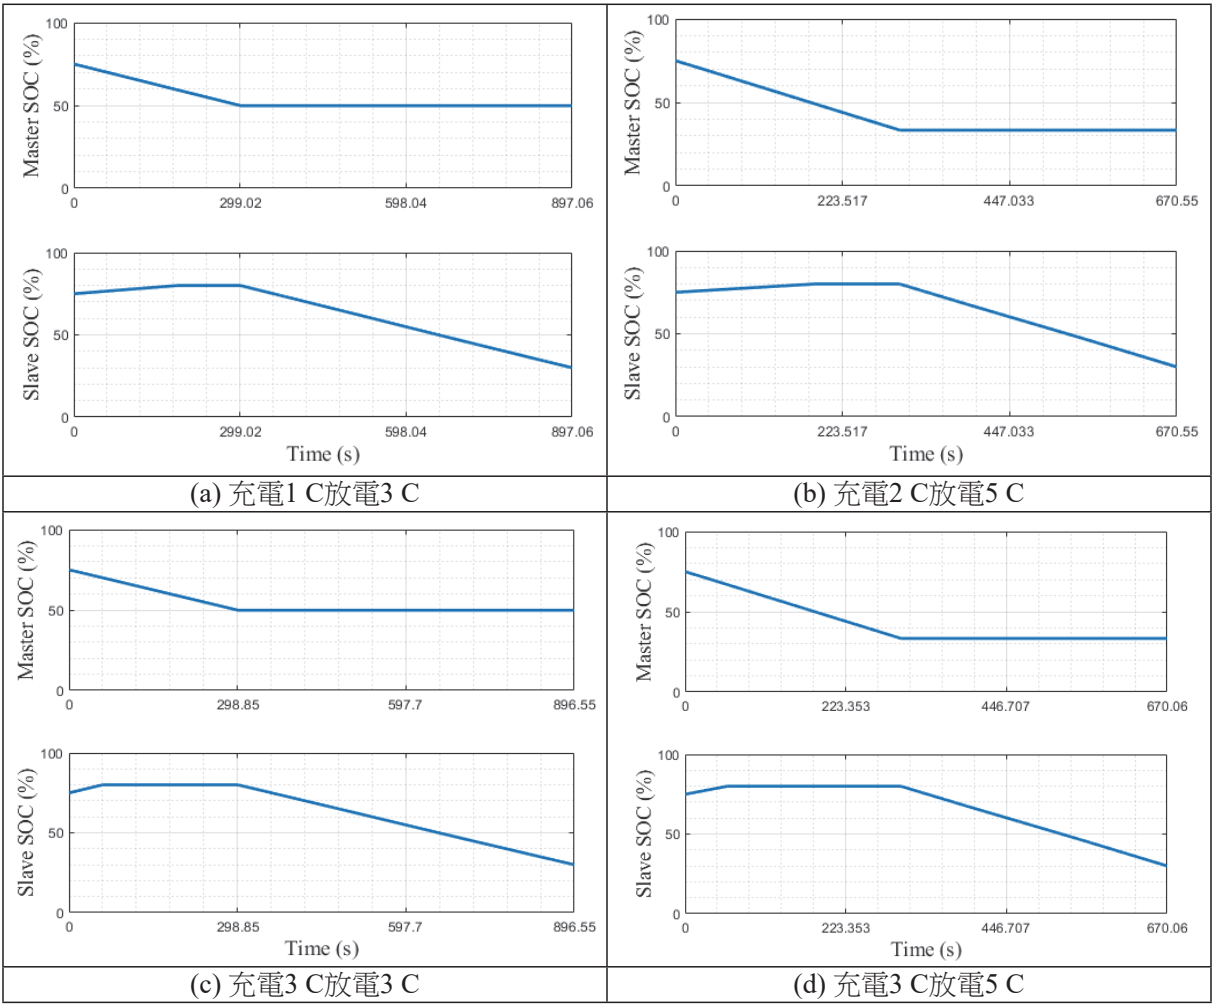
硬體在環實現(Hardware-in-the-Loop, HIL)用於模擬和驗證控制系統與硬體設備在實際運行環境下的表現，提供一個安全、經濟且高效的方式，確保實際應用中的可靠性和穩定性。其架構圖如圖24所示，本研究導入實際市電(AC 220 V)取代MATLAB/Simulink中的市電訊號進行環境測試，透過PSIM軟體監控，將運算後的資料傳輸至公共耦合點(Point of Common

Coupling, PCC)，並比較與 MATLAB/Simulink 模擬之SOC估測誤差，如圖25所示。模擬所結果顯示，在4種不同充放電速率的MAE值皆小於1%，證實本研究所提出策略的可使用性。

6.4 碳排放量與碳費結果

在標準電動車電池運行溫度(25°C)下的碳排放量如圖26所示，單顆電池的放電碳排量平均比主從式電池多了 0.06 kgCO_{2e}。

根據圖18所描述，不同國家的每公斤初始碳價如表18所整理。經公式(18)計算得電動車電池放電的碳費如表19所示，從資料可以看出，單顆電池的碳費範圍與主從式電池相比較



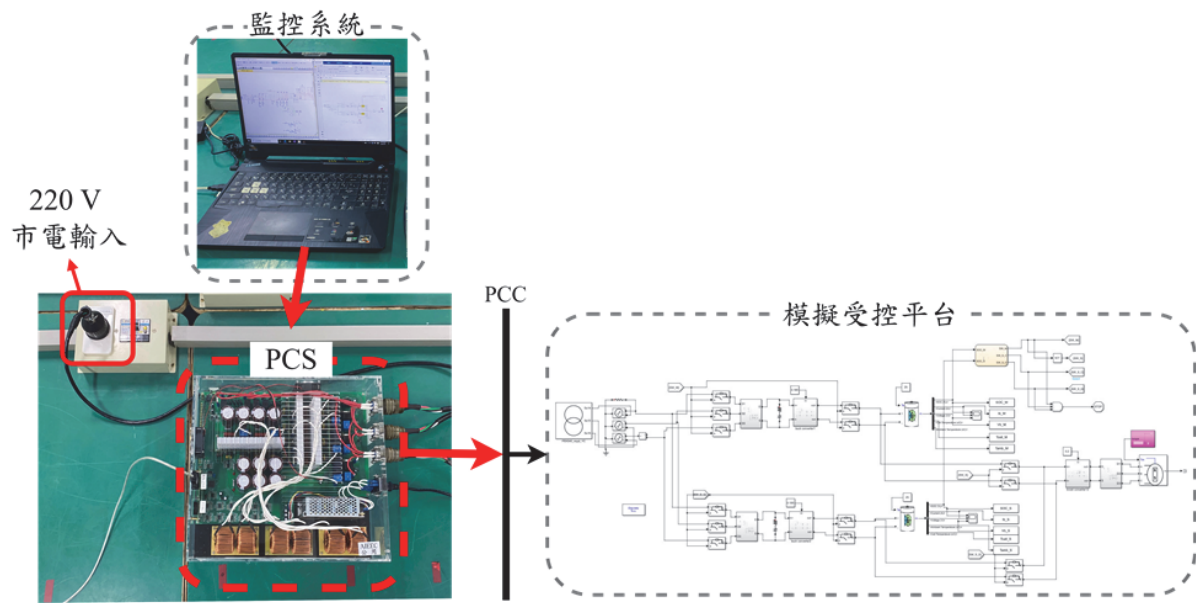
資料來源：本研究彙製。

圖23 主電池放電時故障下的充放電曲線圖

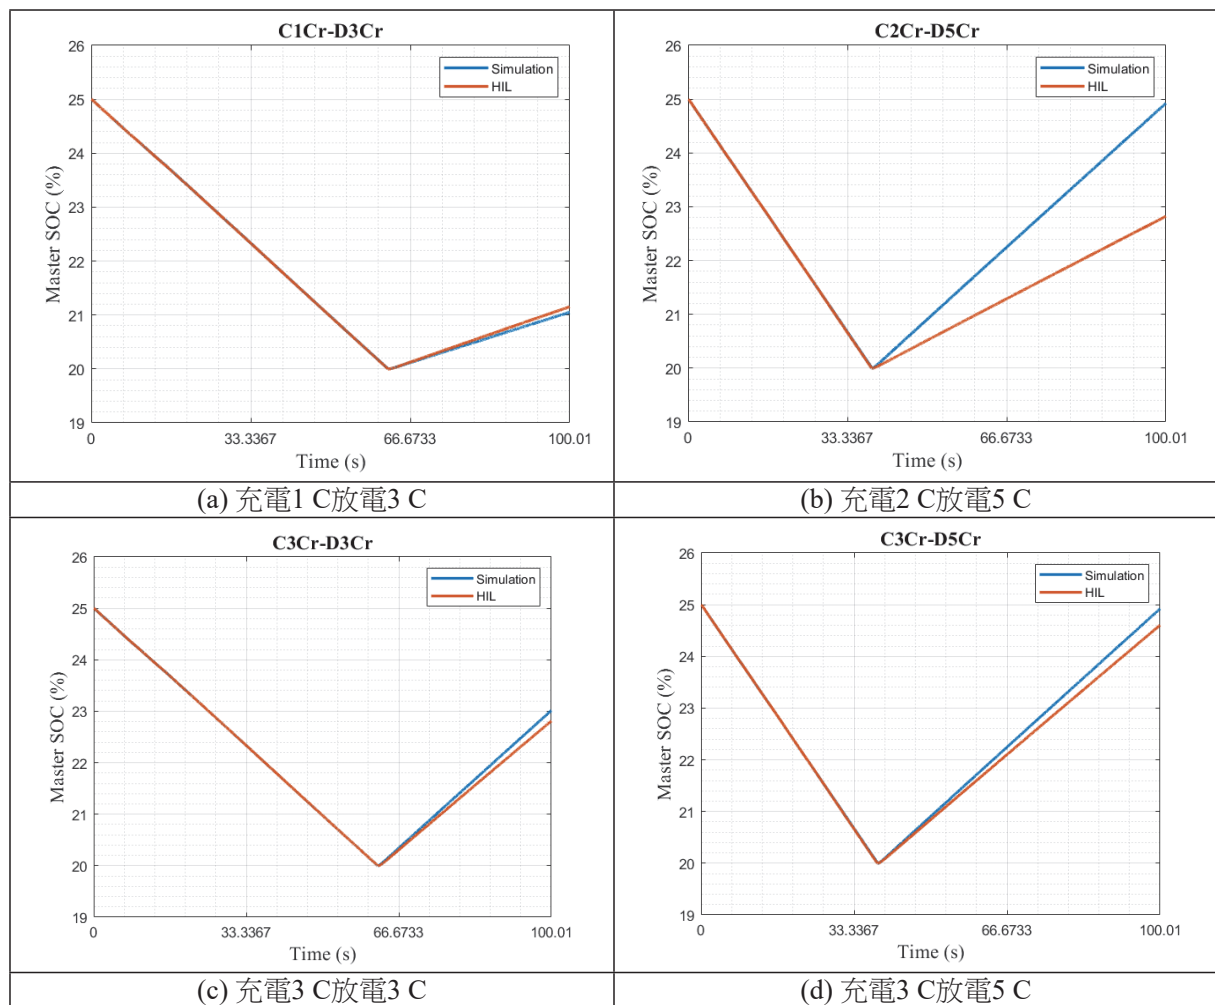
表17 在正常情境下剩餘容量比較表

情境	電池	電池充放電速率			
		C1Cr D3Cr	C2Cr D5Cr	C3Cr D3Cr	C3Cr D5Cr
正常情境		剩餘容量(%)			
	主電池	30%	30%	59%	30%
	副電池	24%	24%	43%	25%
	單電池	24%	16%	14%	0%
剩餘容量計算		6 Ah	22 Ah	74Ah	55 Ah
平均		39.3 Ah			

資料來源：本研究彙整。

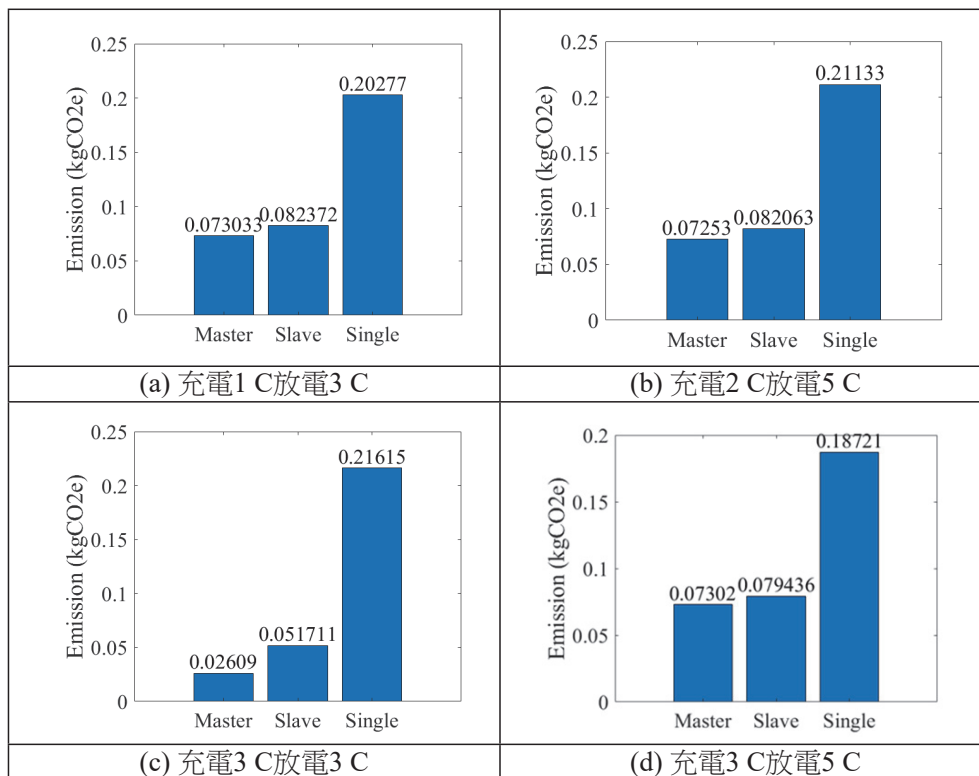


資料來源：本研究彙製。



資料來源：本研究彙製。

圖25 HIL在T25不同充放電速率的SOC結果圖



資料來源：本研究彙製。

圖26 主從式與單電池在T25碳排放量比較圖

表18 亞洲國家每公斤初始碳價統整表

國家	初始碳價(NT/kg)
日本	0.067
新加坡	0.114
南韓	0.202
中國	0.225
臺灣	0.3

資料來源：本研究彙整。

大。

圖27到圖31呈現不同SOC估測方法與實際碳排放量誤差的比較結果。其中，ANFIS的平均誤差碳排放量皆為最大，而在環境溫度40°C時，GRU-LSTM的平均誤差碳排放量與LSTM-GRU相近，其餘環境溫度下，LSTM-GRU的平均誤差碳排放量最小。而表20統整了不同環境溫度下、不同的估測模型，在不同充放電速率中平均的充放電碳排放量誤差，可以看出LSTM-

GRU在這5種模型中具有最佳的表現。

7. 結 論


本研究探討了電動車主從式充放電策略在不同情境與剩餘儲存容量估測模型的開發，並分析了碳排放對電力調度與碳價交易的影響，同時透過功率轉換系統建立硬體在環實現。主從式充放電策略也建立了不同的充放電速率與故障情境。研究結果顯示，在正常充放電情境下，當主從式的主電池平均剩餘容量為37.25%、副電池平均剩餘容量為29%時，單電池的平均容量僅剩13.5%，證實主從式策略能夠有效的管理電池的充放電過程，通過合理的分配電力資源，有效減緩電動車里程焦慮。

本研究設計電動車充放電策略指引，並據此篩選ANFIS、GRU、LSTM、GRU-LSTM、LSTM-GRU 五種不同的模型，來估測電動車電

表19 T25主從式與單電池組碳費比較表

充放電速率		C1Cr D3Cr	C2Cr D5Cr	C3Cr D3Cr	C3Cr D5Cr
臺幣	電池	碳費(元)			
67/噸	主從式	0.0104	0.0104	0.0052	0.0102
	單電池	0.0136	0.0142	0.0145	0.0125
114/噸	主從式	0.0177	0.0176	0.0089	0.0174
	單電池	0.0231	0.0241	0.0246	0.0213
202/噸	主從式	0.0314	0.0312	0.0157	0.0308
	單電池	0.0410	0.0427	0.0437	0.0378
225/噸	主從式	0.0350	0.0348	0.0175	0.0343
	單電池	0.0456	0.0475	0.0486	0.0421
300/噸	主從式	0.0466	0.0464	0.0233	0.0457
	單電池	0.0608	0.0634	0.0648	0.0562

資料來源：本研究彙整。




資料來源：本研究彙製。

圖27 在T5不同速率的碳排估測誤差量結果比較圖


池的儲存電量，並觀察在電能傳輸速率(C-rate)與溫度下的估測結果。研究結果顯示，GRU-LSTM的估測誤差較大，平均MAE為6.98%；

LSTM-GRU的MAE為3.56%，為本研究最小的估測誤差，能準確的反應電池的實際儲存電量，從而有效實施充放電策略。此外，本研究



資料來源：本研究彙製。

圖28 在T25不同速率的碳排估測誤差量結果比較圖




資料來源：本研究彙製。

圖29 在T40不同速率的碳排估測誤差量結果比較圖


對電動車在不同充放電策略下的碳排量與碳費進行計算，並比較不同估測模型結果的誤差。實驗結果顯示，主從式充放電策略的主副電池

相比單電池相比平均少了0.06 kgCO_{2e}的碳排放量，且從主從式電池的最終剩餘容量也比單電池多了39.3 Ah，證實了此策略在減少碳排放量



資料來源：本研究彙製。

圖30 在T540不同速率的碳排估測誤差量結果比較圖



資料來源：本研究彙製。

圖31 在T405不同速率的碳排估測誤差量結果比較圖

與碳費方面具備一定的可行性與有效性。硬體在環模擬實現的部分，證實了本研究所建立之模型，可應用於實際分散式電網與異質性能源

碳排分析，其模擬成果可昭公信，亦可作為後續碳費設計之參考基準值。

基於本研究所提出架構，未來可以針對

表20 估測模型在不同環境溫度下的碳排誤差量比較表

環境溫度	ANFIS	GRU	LSTM	GRU-LSTM	LSTM-GRU
T5	13.75	8.25	5.14	2.73	4.46
T25	45.13	21.51	16.30	7.19	0.91
T40	20.60	9.37	5.86	1.47	1.59
T540	27.31	10.65	9.64	4.25	0.62
T405	10.78	28.51	8.57	5.39	1.47
平均	25.95	17.51	10.09	4.57	1.15

資料來源：本研究彙整。

將主從式充放電策略擴展到更多應用層面，如不同類型的電動車或是使用場景，包括電動巴士或市商用車隊等。此外，在分散式微電網中加入供需兩端異質性設備，像是充電樁或虛擬電廠等，增加電力調度之彈性。未來的研究方向，包括深入探討隱藏層數設定(如：貝葉斯優化，Bayesian Optimization)、固定步長的局限性，改善搜索效率低與計算成本高的問題，進一步提升數據驅動法的可解釋性、並結合應用不同方法以獲得更好的估測效果。同時將剩餘儲存容量的估測結果，用於調控主從式切換時機點，使其可以根據電網或電動車的狀態實現即時動態調整充放電策略。此外，碳排可以更进一步考慮整體環境因素與市場變數，提供更全面的評估指標做為參考，這將為電動車領域的發展帶來更多的創新和突破。

參考文獻

- 經濟部能源署，2023。“111年度電力排碳係數。”經濟部能源署(Energy Administration, Ministry of Economic Affairs, R.O.C.)全球資訊網. June 21, 2023. https://www.moeaea.gov.tw/ecw/populace/content/ContentDesc.aspx?menu_id=23142.
- Ahmed, M. S., B. Balasingam and K. R. Pattipati, 2021. “Experimental Data on Open Circuit Voltage Characterization for Li-Ion Batteries.” *Data in Brief* 36 (June): 107071. <https://doi.org/10.1016/j.dib.2021.107071>.
- Baccouche, I., S. Jemmali, A. Mlayah, B. Manai, and N. E. B. Amara, 2018. “Implementation of an Improved Coulomb-Counting Algorithm Based on a Piecewise SOC-OCV Relationship for SOC Estimation of Li-Ion Battery.” arXiv. <https://doi.org/10.48550/arXiv.1803.10654>.
- Basia, A., Z. Simeu-Abazi, E. Gascard and P. Zwolinski, 2021. “Review on State of Health Estimation Methodologies for Lithium-Ion Batteries in the Context of Circular Economy.” *CIRP Journal of Manufacturing Science and Technology* 32 (January): 517-28. <https://doi.org/10.1016/j.cirpj.2021.02.004>.
- Dai, H., B. Jiang, X. Hu, X. Lin, X. Wei and M. Pecht, 2021. “Advanced Battery Management Strategies for A Sustainable Energy Future: Multilayer Design Concepts and Research Trends.” *Renewable and Sustainable Energy Reviews* 138 (March): 110480. <https://doi.org/10.1016/j.rser.2020.110480>.

- Dimitriadou, K., N. Rigogiannis, S. Fountoukidis, F. Kotarela, A. Kyritsis and N. Papanikolaou, 2023. "Current Trends in Electric Vehicle Charging Infrastructure; Opportunities and Challenges in Wireless Charging Integration." *Energies* 16(4): 2057. <https://doi.org/10.3390/en16042057>.
- Duarte, G., A. Silva and P. Baptista, 2021. "Assessment of Wireless Charging Impacts Based on Real-World Driving Patterns: Case Study in Lisbon, Portugal." *Sustainable Cities and Society* 71 (August): 102952. <https://doi.org/10.1016/j.scs.2021.102952>.
- Gole, A. C., P. K. Aher and S. L. Patil, 2023. "SOC Estimation of a Li-Ion Battery Using Deep Learning Method: A Comparative Study of LSTM and GRU Architecture." In *2023 11th National Power Electronics Conference (NPEC)*, 1-6. <https://doi.org/10.1109/NPEC57805.2023.10384964>.
- Hannan, M. A., D. N. T. How, M. Mansor, M. S. H. Lipu, P. J. Ker and K. M. Muttaqi, 2020. "State-of-Charge Estimation of Li-Ion Battery at Variable Ambient Temperature with Gated Recurrent Unit Network." In *2020 IEEE Industry Applications Society Annual Meeting*, 1-8. <https://doi.org/10.1109/IAS44978.2020.9334824>.
- Hong, J., F. Liang, H. Yang, C. Zhang, X. Zhang, H. Zhang, W. Wang, K. Li and J. Yang, 2024. "Multi- Forward-Step State of Charge Prediction for Real-World Electric Vehicles Battery Systems Using a Novel LSTM-GRU Hybrid Neural Network." *eTransportation* 20 (May): 100322. <https://doi.org/10.1016/j.etran.2024.100322>.
- Hu, J., and Suming Lai, 2017. "Master-Slave Battery Charging System Using Parallel DC-DC Converters for Thermal Safety." In *2017 IEEE International Symposium on Circuits and Systems (ISCAS)*, 1-4. <https://doi.org/10.1109/ISCAS.2017.8050651>.
- InfoLink Consulting, 2024. "2024年台灣碳費應該收多少才合理?" Accessed June 13, 2024. <https://www.infolink-group.com/energy-article/tw/topic-how-much-taiwan-should-price-carbon-credits-for-2024>.
- INSIDEEVs, 2022. "US: Median Range of 2021 Gasoline Vehicles Is 72% Higher than BEVs." InsideEVs. June 18, 2022. <https://insideevs.com/news/561634/us-median-range-gasoline-bevs/>.
- Islam, M. S. and E. Hossain, 2021. "Foreign Exchange Currency Rate Prediction Using a GRU-LSTM Hybrid Network." *Soft Computing Letters* 3 (December): 100009. <https://doi.org/10.1016/j.socl.2020.100009>.
- J.-S.R. Jang, 1993. "ANFIS: Adaptive-Network-Based Fuzzy Inference System." *IEEE Transactions on Systems, Man, and Cybernetics* 23(3): 665-85. <https://doi.org/10.1109/21.256541>.
- Jansen, M. G., K. Smith and L. Brown, 2011. "Effect of state-of-charge on the cycle life of lithium-ion batteries." *Journal of The Electrochemical Society*.
- Kostopoulos, E. D., G. C. Spyropoulos and J. K. Kaldellis, 2020. "Real-World Study for the Optimal Charging of Electric Vehicles." *Energy Reports* 6 (November): 418-26. <https://doi.org/10.1016/j.egyr.2019.12.008>.
- Lee, S.-W. and B.-H. Cho, 2016. "Master-Slave

- Based Hierarchical Control for a Small Power DC-Distributed Microgrid System with a Storage Device.” *Energies* 9(11): 880. <https://doi.org/10.3390/en9110880>.
- Nicholson, S., and G. Heath, 2021. “Life Cycle Emissions Factors for Electricity Generation Technologies.” National Renewable Energy Laboratory - Data (NREL-DATA), Golden, CO (United States); National Renewable Energy Laboratory (NREL), Golden, CO (United States). <https://doi.org/10.7799/1819907>.
- Razu, M. R. R., S. Mahmud, M. J. Uddin, S. S. Islam, B. Bais, N. Misran and M. T. Islam, 2021. “Wireless Charging of Electric Vehicle While Driving.” *IEEE Access* 9: 157973-83. <https://doi.org/10.1109/ACCESS.2021.3130099>.
- Salleh, M., N. Talpur and K. Hussain, 2017. “Adaptive Neuro-Fuzzy Inference System: Overview, Strengths, Limitations, and Solutions.” In, 527-35. https://doi.org/10.1007/978-3-319-61845-6_52.
- Shrivastava, P., P. A. Naidu, S. S., B. K. Panigrahi and A. Garg, 2023. “Review on Technological Advancement of Lithium-Ion Battery States Estimation Methods for Electric Vehicle Applications.” *Journal of Energy Storage* 64 (August): 107159. <https://doi.org/10.1016/j.est.2023.107159>.
- Singh, K. V., H. O. Bansal and D. Singh, 2020. “Hardware-in-the-Loop Implementation of ANFIS Based Adaptive SoC Estimation of Lithium-Ion Battery for Hybrid Vehicle Applications.” *Journal of Energy Storage* 27 (February): 101124. <https://doi.org/10.1016/j.est.2019.101124>.
- UNEP, 2022. “Emissions Gap Report 2022.” UN Environment Programme. October 21, 2022. <http://www.unep.org/resources/emissions-gap-report-2022>.
- Valencia, N., A. Fotouhi, N. Shateri and D. Auger, 2023. “Development of a Hybrid Adaptive Neuro-Fuzzy Inference System with Coulomb-Counting State-of-Charge Estimator for Lithium-Sulphur Battery.” *International Journal of Fuzzy Systems* 25(2): 407-22. <https://doi.org/10.1007/s40815-022-01403-y>.
- Vidal, C., P. Malysz, M. Naguib, A. Emadi and P. J. Kollmeyer, 2022. “Estimating Battery State of Charge Using Recurrent and Non-Recurrent Neural Networks.” *Journal of Energy Storage* 47(March): 103660. <https://doi.org/10.1016/j.est.2021.103660>.
- World Bank Group, 2023. “State and Trends of Carbon Pricing Dashboard.” Carbon Pricing Dashboard. November 1, 2023. <https://dev-rad-carbon-pricing.pantheonsite.io/compliance/factsheets>.
- Yang, A., Y. Wang, F. Yang, D. Wang, Y. Zi, K. L. Tsui and B. Zhang, 2019. A comprehensive investigation of lithium-ion battery degradation performance at different discharge rates. *Journal of Power Sources*, 443, 227108, ISSN 0378-7753.
- Yang, B., J. Wang, P. Cao, T. Zhu, H. Shu, J. Chen, J. Zhang and J. Zhu, 2021. “Classification, Summarization and Perspectives on State-of-Charge Estimation of Lithium-Ion Batteries Used in Electric Vehicles: A Critical Comprehensive Survey.” *Journal of Energy Storage* 39 (July): 102572. <https://doi.org/10.1016/j.est.2019.101124>.

org/10.1016/j.est.2021.102572.

Zhang, F., J. Zhang, M. Cheng and B. Xu, 2022.
“A Flow-Limited Rate Control Scheme for
the Master–Slave Hydraulic Manipulator.”
IEEE Transactions on Industrial Electronics
69(5): 4988-98. <https://doi.org/10.1109/>

TIE.2021.3084175.

Zhang, J. T., Y. Wang, W. Li and B. Chen, 2020.
“Impact of charging/discharging cycles on the
life cycle of lithium-ion batteries.” *Energy*
Reports.

Development of a Data-Driven Master-Slave Charging and Discharging Strategy for Low-Carbon Grid-to-Vehicle (G2V) Trading Applications

Chun-Wei Huang^{1*} Hsing-Yu Lin² Shih-Hsien Hsu¹ Ping-Hsin Lee²

ABSTRACT

With the transformation of low-carbon transportation, the electrification of transportation vehicles has become a trend that cannot be ignored. In terms of carbon reduction, there are mainly four low-carbon transportation vehicles such as electric vehicles (EV), plug-in hybrid vehicles (PHEV), hydrogen fuel cell vehicles (FCV) and hybrid vehicles (Hybrid V), and these four carbon reduction benefits are quite different, mainly depending on their power system, energy source, energy efficiency and use environment and other factors, among which pure electric vehicles and hydrogen fuel electric vehicles have the greatest carbon reduction benefits, but because the cost of hydrogen fuel is too high, pure electric vehicles are currently the wave of the world. However, BEVs are extremely dependent on clean electricity, so the battery management system (BMS) plays a crucial role in EV charging and discharging management. Within this context, the Battery Management System (BMS) plays a pivotal role in managing the charging and discharging of electric vehicles, specifically by monitoring key information such as carbon emissions flow, load flow, and power data. Consequently, this study aims to develop charging and discharging strategies for electric vehicles, facilitating the master-slave battery packs for charge/discharge scheduling and grid connection. Additionally, a low-carbon grid-to-vehicle (G2V) trading model was designed, with continuous monitoring of the energy-related carbon footprints, carbon cost calculations, and state-of-charge estimation to enable optimal decision-making in the charging and discharging strategy.

This study develops a state of charge (SOC) estimation guideline for low-carbon electric vehicle charging and discharging strategies. Based on the research results, five state-of-charge estimation models, ANFIS, GRU, LSTM, GRU-LSTM, and LSTM-GRU, were selected for analysis and comparison to optimize their estimation performance. Different ambient temperature and (dis)charge rate scenarios were established to optimize the Battery Management System (BMS). Under verification with the same battery capacity (200 Ah), the results showed that the average consumption was 62.75 Ah for the primary battery and 71 Ah for the secondary battery, compared to 173 Ah for the single battery. Experimental data validated the optimization of the Battery Management System, with the LSTM-GRU model demonstrating superior estimation performance, achieving a Mean Absolute Error (MAE) of 3.56%, indicative of excellent tracking capability. Furthermore, the analysis of carbon emissions, including the calculation of carbon emissions and carbon costs, demonstrated effective carbon control. Compared to single-battery operation, the master-slave charging/discharging strategy reduced the average carbon emissions by 0.06 kgCO_{2e}. Finally, the experimental results confirm the feasibility of this strategy in actual hardware environments, offering a promising solution for mitigating range anxiety in practical applications.

Keywords: Master-Slave Charging and Discharging Strategy, Battery State of Charge, Carbon Emission Monitoring.

¹ Assistant professor, Department of Electrical Engineering, Feng Chia University.

² Postgraduate, Department of Electrical Engineering, Feng Chia University.

*Corresponding Author, Phone: +886-04-24517250#3822, E-mail: chunwhuang@fcu.edu

Received Date: August 26, 2024

Revised Date: December 11, 2024

Accepted Date: February 11, 2025