國立勤益科技大學工業工程與管理系

___114___學年度實務專題競賽

結合增量容量分析與 LSTM / BiLSTM 模型之鋰離子電池 SOH 預測

摘要

隨著鋰離子電池廣泛應用於電動車與儲能系統，如何準確評估電池健康狀態（State of Health, SOH）已成為電池管理系統中的關鍵議題。SOH 能有效反映電池老化程度與剩餘可用性能，對於提升系統安全性、可靠性與使用壽命具有重要意義。然而，傳統以等效電路或經驗模型為基礎的方法，在實際操作條件與長期老化行為下，往往難以準確描述電池退化特性。因此本研究欲提出一套結合特徵工程與時間序列深度學習模型之資料驅動式 SOH 預測架構，使用美國國家航空暨太空總署（National Aeronautics and Space Administration, NASA）公開之 Battery Data Set（鋰離子電池老化數據集）。首先針對原始充放電資料進行前處理與循環配對，以確保時間序列之連續性與特徵—標籤對應之正確性。接續，於充電階段導入增量容量分析（Incremental Capacity Analysis, ICA），萃取具物理意涵之健康指標，包括 IC 峰值高度、峰值電壓位置、曲線面積、谷值特徵及充電時間，並結合 Savitzky–Golay 濾波以提升 IC 曲線特徵之穩定性與可辨識性。模型建構則採用長短期記憶網路（Long Short-Term Memory, LSTM）與雙向長短期記憶網路（Bidirectional LSTM, BiLSTM），以學習經特徵工程轉換後之健康指標序列隨循環次數變化之退化趨勢。模型效能以均方根誤差（Root Mean Square Error, RMSE）作為評估指標。實驗結果顯示，透過系統化特徵工程與模型訓練流程，所建構之 SOH 預測模型可有效描述電池容量衰退行為，並使預測誤差維持在 RMSE 小於 0.01 的水準。整體而言，本研究驗證曲線型特徵結合時間序列深度學習模型於鋰離子電池健康狀態評估上的可行性，並提出一套具一致性與可重現性的研究架構，作為後續電池管理系統與相關研究之參考。

關鍵詞：鋰離子電池、健康狀態（SOH）、增量容量分析（ICA）、長短期記憶網路（LSTM/BiLSTM）、資料驅動預測

1.緒論

1.1 研究背景與動機

從電動車到手機，再到需要長時間穩定運作的行動工具，電池已成為各類智慧與行動設備不可或缺的核心元件。然而，電池性能會隨環境溫度、負載變動、部分充電與不規則使用行為等因素產生波動，進而出現容量衰退、溫升或充放電異常等現象。由於鋰電池具備高能量密度特性，一旦健康狀態評估不準確，可能提高過充、過放或熱失控等風險。為降低上述不確定性對安全與可靠度的影響，工程領域發展出電池管理系統（Battery Management System, BMS）[1][13]，透過監測電壓、電流與溫度等參數，估算剩餘電量（State of Charge, SOC）、健康狀態（State of Health, SOH）與剩餘壽命（Remaining Useful Life, RUL），以避免危險狀況並支援充電策略、功率限制與能源調度等決策。然而，傳統 BMS 多依賴固定模型與參數假設，當面對真實複雜且不確定的操作條件時，往往難以準確反映電池實際老化程度，進而造成續航估算失真或設備效能與可靠度難以兼顧。

因此，近年資料驅動方法逐漸興起，研究者開始從鋰電池充放電曲線中萃取可反映電池老化行為的健康指標（Health Indicators, HIs）[4][6][8][12][15][16]。相較於僅以容量衰退序列作為輸入，曲線型特徵能描述充電過程中不同階段的動態變化，有助於在早期老化尚不明顯時放大細微退化訊號並提升可辨識度。相關研究亦指出，由充放電曲線萃取之特徵可對應鋰耗損（Loss of Lithium Inventory, LLI）、活性材料衰退（Loss of Active Material, LAM）、SEI 膜增厚及電化學動力

學劣化等物理退化機制[1][5][9]，因此在 SOH 與 RUL 預測研究中展現良好潛力。然而，現有文獻在曲線型特徵的使用與處理流程上仍存在限制，部分研究雖已證實此類特徵與電池老化之關聯性，但對量測雜訊、差分運算及操作條件變動所造成的特徵不穩定問題，往往缺乏系統性整合與一致化設計，使特徵品質高度依賴原始資料狀態與前處理方式。因此，如何在資料驅動架構下建立具一致性與可重現性的曲線型特徵處理流程，已成為相關方法能否可靠應用的關鍵課題。

基於上述研究趨勢與挑戰，本研究著眼於整合既有文獻中已被證實具有效性的特徵處理與時序建模技術，以建立一套能穩定描述鋰電池容量衰退行為的 SOH 預測流程。本研究並非僅將資料輸入模型進行預測，而是從原始充放電資料整理開始，依序完成循環配對、增量容量分析（Incremental Capacity Analysis, ICA）特徵萃取[4][6][8][12][15][16]、Savitzky–Golay（S–G）濾波處理[6][8]與充電時間特徵建立，再將健康指標輸入長短期記憶網路（Long Short-Term Memory, LSTM）與雙向長短期記憶網路（BiLSTM）進行 SOH 預測。特徵選用方面，依據相關文獻中反覆被驗證且具物理意義之健康指標，選取 IC 峰值高度、峰值電壓、谷值特徵、曲線面積以及 CC/CV 充電時間等特徵，以描述充電曲線隨老化產生之變化。透過此整合式流程，本研究期望辨識兼具物理意涵與穩定性的關鍵健康指標，建立具一致性與可重現性的 SOH 特徵工程與預測架構，並為後續電池管理系統與相關研究提供參考。

2.文獻探討

本節將介紹健康狀態（State of Health, SOH）、常見 SOH 預測方法、特徵工程的方法與技術，以及預計採用的學習模型（LSTM、BiLSTM）。

2.1 健康狀態（State of Health, SOH）

健康狀態（State of Health, SOH）用以描述電池儲存電能能力之衰退情形，並可視為反映電池整體健康狀態的綜合指標。[1][8]一般而言，SOH 常透過評估電池實際可用容量相對於初始容量之變化加以量化，其定義如下所示：

$$SOH(k) = \frac{C(k)}{C_0} \times 100\% \qquad (1)$$

其中，C（k）表示第 k 次充放電循環所量測之可用容量，C_0 為電池初始容量。雖然 SOH 可量化電池容量衰退程度，但僅以容量作為指標，仍難以完整反映實際老化行為。相關研究指出，鋰離子電池 SOH 受活性材料損失（Loss of Active Material, LAM）、導電能力損失（Loss of Conductivity, CL）及鋰庫存損失（Loss of Lithium Inventory, LLI）等老化機制影響[1][5][9]。這些機制會隨循環次數累積，造成可量測特徵變化，並反映於 SOH 下降趨勢。

2.2 SOH 預測方法

目前鋰離子電池健康狀態（SOH）預測方法大致可分為物理模型、經驗模型、基於微分分析之方法（DVA/ICA-based methods）與資料驅動方法四類[1][7][9][10][14]。物理模型具明確物理意義，但計算負擔大且參數取得困難；經驗模型結構簡單、易於實作，但泛化能力與預測精度有限；DVA/ICA 方法可萃取老化相關特徵，但對量測品質與雜訊較敏感。相較之下，資料驅動方法可結合歷史資料與機器學習或深度學習模型，處理非線性與時間相依性問題，已成為近年 SOH 預測的重要方向。

2.3 特徵工程

綜合相關研究可知，特徵工程在鋰離子電池 SOH 預測中扮演關鍵角色[4]。部分研究透過具物理意義的人工特徵有效描述老化行為[4][6][12]，並指出特徵融合與特徵選擇可進一步提升模型穩定性；即使在深度學習方法中，特徵工程仍以顯性或隱性形式存在[13]，對模型效能具有決定性影響。

在特徵輸入型態上，既有研究可依原始量測曲線來源區分為單通道（Single channel）與多通道（Multiple channel）方法。多通道方法通常係指同時將多種原始充電曲線或量測訊號作為模型輸入，例如電壓（Voltage）、電流（Current）與溫度（Temperature）等不同充電曲線（Charging profiles）。Choi,et al.[19]將電壓、電流與溫度三種充電曲線

組合為多通道輸入，並與僅使用電壓曲線之單通道方法進行比較；Khan,et al.[20]亦明確區分單通道充電曲線（Single Channel Charging Profile, SCCP）與多通道充電曲線（Multiple Channel Charging Profiles, MCCPs），並以 V、I、T 之組合作為多通道資料來源。

相較於上述多通道方法，本研究並未直接將電壓、電流與溫度三組原始量測曲線同時輸入模型，而是以充電階段之電壓曲線作為主要特徵來源，並在恆電流充電（Constant Current, CC）條件下，利用固定電流值 1.5A 進行容量近似換算。因此，本研究定位為以充電電壓曲線為核心之單通道特徵工程架構。需特別說明的是，本研究雖然後續模型輸入包含多個健康指標（Health Indicators, HIs），但這些指標皆由同一充電曲線來源經特徵轉換而得，故本文所稱單通道係指原始曲線來源之通道數，而非特徵數量。

鋰離子電池 SOH 預測中所使用的健康指標多來自充電曲線與其衍生之曲線型特徵，其中以增量容量分析（Incremental Capacity Analysis, ICA）相關特徵最為常見。相較於單一容量序列，ICA 類特徵能放大電壓平台區域的細微變化，使早期老化行為更易於辨識，因此被廣泛應用於資料驅動式 SOH 預測研究中。多篇文獻一致指出，IC 曲線之峰值高度、峰值對應之電壓位置，以及 IC 曲線面積，為 ICA 類特徵中最具代表性且反覆被驗證之核心健康指標。相關研究顯示，這些特徵會隨著循環老化呈現穩定變化趨勢，並且能在不同模型架構與資料集條件下有效反映電池容量的衰退行為。因此，多數研究會將上述三項 IC 曲線指標作為預測模型特徵，以提升 SOH 預測的穩定性與一致性[4][6][8][12][15][16]。除了上述主流 IC 峰值相關特徵外，亦有研究進一步納入 IC 曲線中的谷值相關指標，將 IC 谷值大小作為特徵輸入時，於 SOH 預測中可獲得相對穩定之預測表現，並有助於改善部分資料集下的模型效果[15]。雖然 IC 曲線谷值並非所有研究皆採用為模型特徵，但在部分研究中亦展現良好實用性，因此被視為可補充 IC 峰值特徵之健康指標。此外，亦有研究提出充電時間相關特徵作為另一類健康指標，文獻指出隨著電池老化，恆電流（CC）與恆電壓（CV）階段之充電時間比例會產生系統性變化，並與容量衰退呈現一定關聯性[8]。基於此，將 CC 充電時間與 CV 充電時間納入特徵集合，並透過實驗結果顯示，該類時間型特徵可作為曲線型特徵之外的補充資訊，有助於提升模型對不同老化階段的辨識能力。

綜合上述文獻探討，本研究依循既有研究中對各類健康指標之實證結果，選擇以 IC 峰值高度、IC 峰值電壓位置與 IC 曲線面積作為主要曲線型健康指標，並搭配 IC 谷值相關特徵以及 CC 與 CV 充電時間等時間型特徵，共同構成本研究預測模型之特徵集合。上述特徵皆源自充電階段資料，且分別對應電壓平台變化、充電接受能力改變與容量衰退趨勢，因此具有明確之物理意義與老化表徵能力。

2.3.1 增量產能分析（Incremental Capacity Analysis， ICA）

增量容量分析（Incremental Capacity Analysis，ICA）係透過分析鋰離子電池於充放電過程中電壓與容量之關係，以萃取與電池健康狀態相關之特徵[4][6][8]。於恆電流充電條件下，鋰離子電池之端電壓隨充電進行呈現階段性變化，其中部分區段電壓變化趨於平緩，形成所謂之電壓平台（voltage plateau）[4]。此現象主要源於電池內部電化學反應於特定狀態下達到相對平衡。隨著充放電循環次數增加，電池內部老化機制逐漸累積，電壓平台之位置與形狀亦會產生緩慢變化。然而，由於電壓平台本身變化幅度有限，僅由原始電壓－容量曲線進行觀察時，相關變化不易量化分析。透過對容量與電壓關係進行微分運算，ICA 能將原本不易辨識之平台變化轉換為增量容量（Incremental Capacity， IC）曲線上的峰值特徵，使老化行為得以更直觀地呈現，並有助於建立電池外部可量測行為與內部老化狀態之關聯。基於上述概念，增量容量分析可由數學形式加以描述。ICA 係透過計算容量相對於電壓之變化率，以量化充放電過程中電壓平台之變化，其定義如下：

$$IC（V）= \frac{dQ}{dV} = \frac{Q_t - Q_{t-1}}{V_t - V_{t-1}} \quad (2)$$

其中，Q表示電池於充放電過程中之容量，V為對應之端電壓。

容量Q可視為電流對時間之積分，其表示式如下：

$$Q_t = \int_0^t I dt \quad (3)$$

此外，由於 NASA 未提供即時容量量測值之資料集，在恆電流充電條件下，因為充電電流近似為常數，可利用時間差結合固定電流近似容量變化，進而建立 ICA 特徵[8]，其關係式可簡化表示為：

$$\Delta Q \approx I \times （t_t - t_{t-1}） \quad (4)$$

其中，I 是恆定電流模式的電流常數 1.5A。t_t為第 t 個取樣時間點之時間。

因此，在離散量測資料下，增量容量分析可進一步表示為：

$$\frac{dQ}{dV} = \frac{（t_t - t_{t-1}）}{V_t - V_{t-1}} \times I \quad (5)$$

2.3.2 特徵穩定化

如前節所述，增量容量分析（ICA）可有效放大充電曲線中與老化行為相關之細微變化，使其轉換為具辨識度的特徵結構。然而，相關文獻亦指出，由於 ICA 涉及對量測資料進行差分運算，其結果對雜訊與資料解析度相當敏感，若未經適當處理，易導致 IC 曲線中產生不穩定之峰值或谷值，進而影響後續特徵萃取與模型預測效能。因此，如何提升曲線型特徵於實務資料下的穩定性，成為後續研究中重要的探討方向。

針對上述問題，部分研究首先從特徵穩定化的角度提出改善方法。相關文獻指出，透過對原始電壓容量或 IC 曲線進行平滑處理，可有效抑制量測雜訊在差分運算後所造成的放大效應。其中，Savitzky–Golay（S-G）濾波器因能在平滑曲線的同時保留局部形狀特性，而被廣泛應用於 ICA 相關研究中[6][8][17]。文獻結果顯示，經 S-G 濾波器處理後之 IC 曲線，其峰值位置與幅度變化趨勢較為穩定，有助於提升特徵在不同循環間的可重現性，並改善後續 SOH 預測模型之表現。

綜合上述文獻可知，S-G 濾波器可從特徵穩定化層面改善曲線型特徵之品質。相較於直接將原始長序列資料輸入深度學習模型，本研究先將充電曲線轉換為具物理意義之健康指標，使模型輸入資料由高維原始訊號轉為低維且具代表性的特徵。此作法可降低量測雜訊與冗餘資訊對模型訓練之影響，並提升後續 LSTM／BiLSTM 對 SOH 退化趨勢之學習效率。

2.4 機器學習模型 LSTM/BiLSTM

長短期記憶網路（Long Short-Term Memory，LSTM）屬於遞迴式神經網路（Recurrent Neural Network， RNN）之一，能有效克服傳統 RNN 在長序列訓練過程中所面臨之梯度消失問題，適合用於處理具有長期依賴關係的時間序列資料。基於上述特性，LSTM 已廣泛應用於電池 SOH 預測研究中，並展現良好之預測效能。[1][13]

2.4.1 長短期記憶神經網路 LSTM

長短期記憶神經網路（Long Short-Term Memory， LSTM）[6][8][9][11]主要用途是處理時間序列資料。LSTM 則透過“記憶單元”（cellstate）讓模型可以長時間保存重要資訊 LSTM 內含三個閘門：

1.ForgetGate（遺忘門）：決定要忘記多少舊記憶

2.InputGate（輸入門）：決定要加入多少新的資訊

3.OutputGate（輸出門）：決定要輸出多少記憶

LSTM 能解決 RNN 隱藏層資訊被覆蓋、長期記憶消失的問題，它會將原本記憶乘上一個權重，再加入新的輸入，使得過往資訊可長時間保留。LSTM 方程式及架構圖（如圖 1）如下所示：

$$f_t = \sigma_g\left(W_{fx_t} + Uh_{t-1} + b_f\right) \quad (6)$$

$$i_t = \sigma_g\left(W_{ix_t} + Uh_{t-1} + b_i\right) \quad (7)$$

$$o_t = \sigma_g\left(W_{ox_t} + Uh_{t-1} + b_o\right) \quad (8)$$

$$C_t = f_t \times C_{t-1} + i_t \times \sigma_c\left(W_{cx_t} + Uh_{t-1} + b_c\right) \quad (9)$$

$$h_t = o_t \times \sigma\left(C_t\right) \quad (10)$$

其中，W 為權重與 X、h 之間的運算為矩陣乘法。

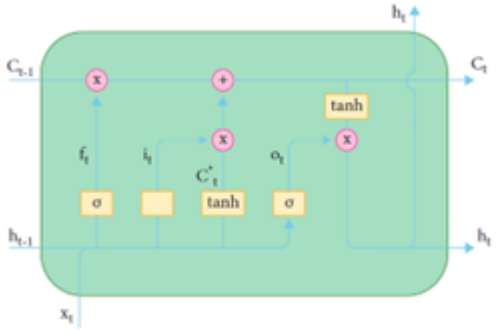


圖 1 單元架構圖[8]

2.4.2 雙向長短期記憶神經網路 BiLSTM

雙向長短期記憶神經網路（Bidirectional Long Short-Term Memory， BiLSTM）為長短期記憶神經網路（LSTM）的延伸架構，主要用於處理時間序列資料。[8][16][18][20]與單向 LSTM 僅沿時間正向進行序列學習不同，BiLSTM 同時考慮時間序列中正向與反向的資訊流動，使模型在同一時間步能同時利用過去與未來的序列資訊進行特徵學習。BiLSTM 由兩個彼此獨立的 LSTM 網路所組成，其中一個沿時間正向（由前至後）處理輸入序列，另一個則沿時間反向(由後至前)進行處理[8][18][20]。對於時間步 t，正向 LSTM 與反向 LSTM 分別輸出其隱藏狀態向量。此雙向結構使模型能同時捕捉序列中前後時間底關係，進而更完整地描述時間序列中特徵的變化行為[18]。在輸出層中，BiLSTM 將正向與反向 LSTM 的隱藏狀態進行線性組合，以產生最終輸出，其數學表示如下：

$$y_t = W_{\overrightarrow{h_y}} \times \overrightarrow{h_t} + W_{\overleftarrow{h_y}} \times \overleftarrow{h_t} + b_y \quad (11)$$

其中，$\overrightarrow{h_y}$與$\overleftarrow{h_y}$分別表示時間正向與反向 LSTM 在時間步 t 的隱藏層輸出，$W_{\overrightarrow{h_y}}$與$W_{\overleftarrow{h_y}}$分別為正向與反向 LSTM 隱藏層至輸出層之權重矩陣，b_y為輸出層之偏置項[18]。

透過上述輸出機制，BiLSTM 能同時整合來自正向與反向時間序列的特徵資訊，生成對應時間步之輸出結果。由於電池充放電循環資料具有明顯的時間連續性與長期退化特性，BiLSTM 能透過雙向時間資訊的整合，有效學習電池健康狀態隨循環次數變化的整體趨勢。BiLSTM 在處理循環數較長或退化行為較為緩慢的時間序列資料時，能提供完整的時間特徵表示，因此適合應用於鋰離子電池 SOH 預測問題[8][16][20]。

2.4.3 小節

近年來，隨著資料驅動方法於電池健康管理領域的發展，以長短期記憶神經網路（LSTM）及其延伸架構為核心的時序模型，已成為鋰離子電池健康狀態（SOH）與剩餘使用壽命（RUL）預測中廣泛採用的方法之一。相較於傳統回歸或淺層機器學習模型，LSTM 類模型能有效處理電池循環資料中的時間相依性與長期退化特徵，並常作為相關研究中評估模型效能的基準架構。

綜合上述文獻可知，LSTM 與 BiLSTM 皆能處理具時間相依性之序列資料，並已廣泛應用於鋰離子電池 SOH 與 RUL 預測研究中。LSTM 可學習容量衰退過程中的長期趨勢，而 BiLSTM 則進一步透過正向與反向序列資訊補充時間特徵表示。因此，本研究選擇 LSTM 與 BiLSTM 作為主要預測模型，以驗證所建構之 ICA 特徵工程流程於 SOH 預測任務中的有效性。

3.研究方法及步驟

本研究旨在使用美國國家航空暨太空總署（National Aeronautics and Space Administration, NASA）公開之 Battery Data Set（鋰離子電池老化數據集）[2][3]，透過資料驅動方法結合特徵工程與序列型深度學習模型，建立鋰離子電池健康狀態（State of Health, SOH）之預測架構。整體研究流程可分為資料理解、資料前處理與特徵挑選、模型建構與參數設定、模型訓練，以及 SOH 預測與成效驗證等階段，其整體研究架構如圖 2 所示：

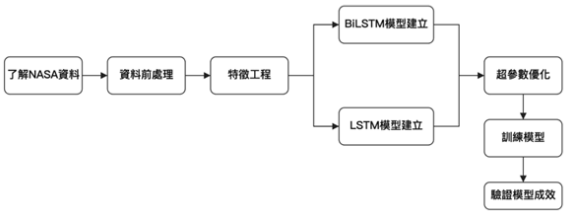


圖 2 研究架構流程圖

研究流程首先對 NASA 電池資料進行理解與整理，以掌握資料結構與量測內容；接著進行資料前處理與特徵工程，包含循環資料整併、異常資料排除，以及關鍵老化特徵之萃取。完成特徵工程後，進入模型建構階段，將經由充電段資料轉換而得之健康指標序列作為 LSTM／BiLSTM 模型輸入，以學習 SOH 隨循環次數變化之退化趨勢。隨後進行模型訓練，並透過驗證資料評估模型預測效能。在模型訓練與驗證過程中，同步執行超參數最佳化流程，反覆調整模型相關參數設定，以提升整體預測表現。最終，依據模型驗證結果分析其 SOH 預測成效，並與既有文獻之方法與結果進行比較，作為本研究模型效能與特徵工程有效性之評估依據。

3.1 資料集說明

本研究採用美國國家航空暨太空總署（National Aeronautics and Space Administration, NASA）公開之 Battery Data Set（鋰離子電池老化數據集）[2]。選用電池編號 B0005、B0006、B0007、B0018 作為實驗對象，該資料集包含多顆 18650 型鋰離子電池於固定環境溫度條件下進行之充放電循環測試數據，記錄了電壓、電流、溫度與時間量測資訊。研究主要使用參數為充電電壓、充電電流、充電時間。此次充電過程包括兩個階段：以 1.5A 進行恆電流（CC）充電，直到電池電壓達到 4.2V。之後改為恆電壓（CV）充電，並持續充電直到充電電流下降至 20mA。本研究於特徵萃取階段僅採用充電過程之量測資料，主要考量增量容量分析（Incremental Capacity Analysis, ICA）之數學定義係建立於容量與電壓之關係，而於恆電流充電（Constant Current, CC）條件下，電流近似為常數，使容量變化可合理以時間與電流進行近似。相較之下，放電過程中電流與操作條件較為複雜，不易直接滿足 ICA 相關假設[8]。因此本研究選擇以充電段資料作為 ICA 特徵計算之基礎。

3.2 資料前處理

由於每個充放電循環僅提供一個對應之最大容量值，因此本研究之特徵萃取以「完整充放電循環」作為基本單位進行。為確保資料具備一致性與時間序列特性，首先針對原始資料進行量測類型篩選，刪除資料集中量測類（Type）為阻抗（impedance）之循環，僅保留充放電相關之量測資料。其原因在於阻抗量測通常以獨立實驗形式進行，量測頻率與充放電循環並非一一對應，若直接納入將破壞時間序列的連續性，並可能導致特徵與 SOH 標籤之對應關係不一致，進而影響模型學習效果。

此外，雖然電池溫度被廣泛認為是影響電池性能與老化行為的重要因素之一，但在 Battery Data Set 中，所提供之溫度資訊主要為外部量測值，且無法準確反映電池內部實際溫度狀態。在缺乏嚴謹內部溫度量測條件下，直接將該溫度資料作為特徵可能引入額外不確定性，因此本研究未將溫度特徵納入分析。同樣地，電池內阻變化雖被視為反映 SOH 的重要指標之一，但其量測通常需仰賴專用設備，且在實際應用情境中不易即時取得，考量其實務適用性與資料一致性，本研究亦未將內阻相關特徵納入模型輸入。[8]

在實際資料檢視過程中發現，原始資料集中充電與放電量測紀錄係分別儲存，且其時間序列並未直接以單一循環單位呈現，部分循環中充電與放電資料數量亦存在不一致之情形。為確保特徵萃取與 SOH 標籤之對應一致性，本研究以放電過程作為循環定義之基準，並向前配對對應之最近一次充電過程，將其合併視為一個完整之充放電循環（cycle）。此作法可確保每一循環均對應唯一之 SOH 標籤，同時保留充電段資料用於特徵萃取，並避免因充放電資料筆數不一致而造成時間序列錯置或標籤對應錯誤之問題。

經上述前處理後，原始資料集中共包含 2167 筆循環資料，其中刪除量測類型為阻抗（impedance）之循環資料共 887 筆，另有因無法與對應充放電資料完成配對而被排除之資料共 8 筆。經充放電循環配對與整併後，最終可用之完整循環數量為 633

筆。

3.3 特徵選用

本研究之 SOH 預測模型係建立於電池充電行為所衍生之特徵資訊之上。依據資料可得性、理論假設與相關文獻，提取六個特徵。本研究所使用之特徵可概略分為下列幾類：

1.增量容量分析（Incremental Capacity Analysis, ICA）相關特徵：由充電過程中
電壓與時間訊號轉換而得之 ICA 曲線特徵，用以反映電池內部老化行為隨循環次數之變化，包括:IC 峰值高度、峰值電壓、第一個谷值大小、CA 曲線面積。

2.充電時間相關特徵：由充電歷程所衍生之時間特徵，用以描述電池充電行為之演變趨勢，包括:CC 充電時間、CV 充電時間。

上述特徵與識別資訊皆源自充電階段之原始量測資料，並作為後續特徵前處理、特徵篩選、加權機制與時間序列模型之輸入。本研究後續將分別說明特徵之資料前處理方式、特徵選擇策略與模型建構方法。

3.3.1 處理異常值及提取特徵（Voltage_measured 和 time）

本研究模型輸入之健康指標皆由充電階段量測資料轉換而得，因此原始電壓、電流與時間序列的完整性會直接影響 ICA 曲線與充電時間特徵之計算結果。為避免缺失值或明顯異常點在後續差分運算中被放大，本研究於特徵萃取前先針對 Voltage_measured、與 Time 等欄位進行資料檢查，並進一步完成異常值處理。

本研究進一步針對與特徵萃取直接相關之原始量測變數進行異常值檢測與處理。異常值判定採用四分位距（Inter quartile Range, IQR）方法，此方法不需假設資料分佈型態，適合應用於實際量測資料中可能存在之非對稱分佈情形[8]。首先計算資料之第一四分位數Q_1與第三四分位數Q_3，並定義四分位距（IQR）為：

$$IQR = Q_3 - Q_1 \tag{12}$$

異常值之判定範圍定義如下：

$$(D_{low}, D_{high}) = (Q_1 - 1.5IQR, Q_3 + 1.5IQR) \tag{13}$$

其中D_{low}和D_{high}分別為異常資料之下界與上界。凡落於上述範圍之外之量測資料點，皆視為異常值並予以排除。

在資料檢查與異常值處理後發現，原始資料中雖有部分缺失值或無效量測點，但多集中於循環後段資料較不穩定之區間；經異常值排除與有效資料範圍篩選後，後續用於 ICA 特徵計算與充電時間特徵萃取之資料已無缺失值。因此，本研究未額外採用其他方法進行補值。

經上述處理後，本研究再依據整理後之 Voltage_measured 與 Time 資料計算 ICA 曲線，並進一步萃取 IC 峰值、峰值電壓、谷值、曲線面積，以及 CC/CV 充電時間等健康指標。

3.3.2 用 Savitzky-Golay（S-G）濾波器去除 IC 曲線噪聲

由於增量容量分析（Incremental Capacity Analysis, ICA）係透過容量對電壓之數值微分運算取得，其結果對原始量測資料中的高頻雜訊相當敏感。在實際計算過程中，即使原始電壓與時間量測資料僅存在微小波動，經微分轉換後仍可能被放大為明顯震盪，使所得增量容量（IC）曲線呈現高度雜訊化，進而影響後續特徵辨識與模型學習效果。因此，本研究先依據前述方法計算增量容量（dQ/dV）曲線，進一步對所得 IC 曲線進行 S-G 平滑處理，以降低微分運算所引入之高頻雜訊。Savitzky–Golay（S-G）濾波器是一種以局部多項式擬合進行平滑的方法，可在降低噪聲的同時保留峰值與斜率等電化學特徵，因此常被應用於電池增量容量（IC）曲線之後處理，以提升特徵可辨識性與穩定性[1][11][15]。

3.4 資料正規化

使用之電池健康特徵在數值尺度與量級上存在差異，若直接將原始特徵輸入深度學習模型，可能導致模型訓練過程中計算量增加，並使梯度更新出現不穩定情形，進而影響模型收斂速度與學習效

果。因此，在模型訓練前，有必要對特徵資料進行適當之正規化處理。透過資料正規化，各特徵可被轉換至相近之數值範圍，使模型在訓練過程中能更穩定地進行參數更新，降低梯度不穩定對模型學習所造成之影響，並有助於提升模型收斂速度與預測準確度。經正規化後之特徵資料，將作為後續 LSTM／BiLSTM 模型之輸入，以確保模型訓練過程之穩定性與泛化表現。

3.5 訓練資料集、驗證資料集與測試資料集建構

完成前述資料前處理、特徵萃取與資料正規化後，本研究最終取得 633 筆完整循環資料，並將其建構為模型訓練所需之訓練資料集、驗證資料集與測試資料集。參考既有鋰離子電池 SOH 預測相關文獻之資料配置方式，本研究設計兩種資料集形成方法，以觀察不同資料組成方式對 LSTM／BiLSTM 模型預測效果與穩定性之影響，其資料切分流程如圖 3 所示。

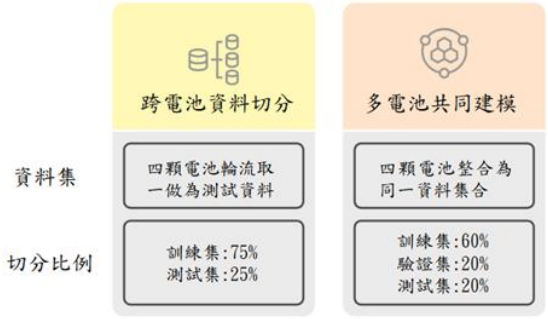


圖 3 資料切分示意圖

第一種方式為跨電池資料切分方式，亦即將 B0005、B0006、B0007 與 B0018 四顆電池輪流作為測試資料，其餘三顆電池則作為訓練資料；其中訓練資料再依比例切分出 25%作為驗證資料，其餘 75%作為訓練資料。此方式可用於檢驗模型面對未參與訓練之電池時的預測能力，進而評估模型是否能從其他電池之容量衰退趨勢與健康指標變化中，學習到較具泛化能力的 SOH 預測規律。

第二種方式為多電池共同建模方式，將四顆電池經前處理與特徵工程後之資料整合為同一資料集合，再依訓練集 60%、驗證集 20%、測試集 20%之比例進行切分。透過此方式，模型可同時學習多顆電池之退化軌跡與健康指標變化，降低單一電池資料量不足或個別老化差異對模型訓練造成的影響。

本研究比較上述兩種資料集形成方式，主要是考量即使不同電池來自相同 NASA 資料集，且具有相近規格與測試條件，其實際容量衰退過程仍可能存在個體差異。因此，透過跨電池資料切分與多電池共同建模之比較，可進一步評估資料組成方式對模型預測效果與穩定性的影響，並作為後續模型訓練與結果分析之依據。

3.6 建立模型

本研究擬採用長短期記憶網路（Long Short-Term Memory, LSTM）與雙向長短期記憶網路（Bidirectional LSTM, BiLSTM）作為鋰離子電池健康狀態（State of Health, SOH）之時間序列預測模型。與直接輸入原始電壓、電流或溫度長序列資料之方法不同，本研究模型輸入為經前述特徵工程流程所萃取之健康指標序列，包括:IC 峰值高度、IC 峰值電壓位置、第一個谷值大小、CA 曲線面積、CC 充電時間與 CV 充電時間。上述特徵皆由充電階段資料轉換而得，具有明確物理意義，能反映電池於不同循環中之充電行為與容量衰退趨勢

在資料輸入方式上，本研究透過滑動視窗（Sliding Window）方式，將連續多個循環之健康指標組合為時間序列輸入，使模型能學習 SOH 隨循環次數變化之時間動態行為。初始實驗中以較短序列作為基準，後續經超參數最佳化後，最終採用 sequence length=40 作為模型輸入長度。此設定可使模型在保留足夠退化趨勢資訊的同時，避免輸入序列過長而增加模型訓練負擔。

在模型結構設定上，LSTM 模型由三層 LSTM 所組成，各層隱藏層神經元數依序設定為 128、64 與 32；BiLSTM 模型則採用三層雙向 LSTM 架構，每一方向之隱藏層神經元數設定為 128、64 與 32。兩種模型之輸出皆連接至全連接回歸層（Dense layer），以產生對應循環之 SOH 預測值，模型架構如圖 4 所示：

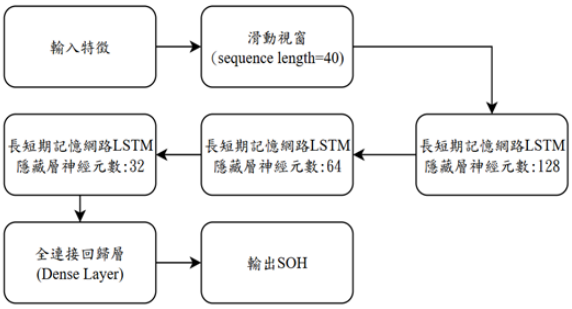


圖 4 模型架構圖

為避免模型於訓練過程中產生過擬合現象，本研究於各隱藏層後引入 Dropout 機制，經超參數最佳化後，最終採用比例設定為 0.3。

在模型訓練階段，採用均方根誤差（Root Mean Square Error, RMSE）與平均絕對誤差（Mean Absolute Error, MAE）作為損失函數，用以量化模型預測 SOH 與實際 SOH 之差異，並作為模型參數更新之依據。模型之初始訓練參數包含批次大小（batch size）設定為 32、訓練回合數（epochs）為 300，以及最佳化方法（optimizer）為 Adam，學習率（Learning rate, LR）設定為 0.001。上述模型結構與參數設定係依據相關文獻建議並結合初步實驗結果進行調整。

3.7 超參數最佳化與測試結果

為提升模型於鋰離子電池健康狀態（State of Health, SOH）預測任務中的穩定性與準確度，本研究針對模型訓練過程之參數設定進行調整，並以 RMSE 與 MAE 作為主要評估指標。調整項目包含 sequence length、dropout 比例與 epochs 等參數。為降低單次模型訓練中隨機初始化與資料切分差異對結果造成的影響，本研究針對每一組參數組合皆進行 15 次重複實驗，並以 15 次實驗之平均 RMSE 與平均 MAE 作為該組參數之模型表現，表 1 所列數值即為平均後之結果，其中以星號標記者為本研究於該階段取得之最佳參數組合，結果如表 1 所示。

表 1 參數組合比較

模型	sequence length	hidden units	LR	batch size	drop out	epoch	AVG_RMSE	AVG_MAE
LSTM	5	32	0.001	32	0.1	300	0.01371	0.01001
LSTM	30	32	0.001	32	0.15	100	0.00895	0.00643
LSTM	30	32	0.001	32	0.2	300	0.00755	0.00509
LSTM	**40**	**32**	**0.001**	**32**	**0.3**	**500**	**0.005412***	**0.004044***

由表 1 可觀察到，隨著參數組合逐步調整，模型之 RMSE 與 MAE 皆呈現下降趨勢，顯示超參數調整對 SOH 預測表現具有明顯影響。初始設定中，sequence length 僅為 5，模型主要依據較短循環區間內的健康指標變化進行預測，較容易受到單一循環波動或局部異常影響。當 sequence length 增加至 30 與 40 後，模型能參考較長區間內的健康指標變化，使 LSTM 能學習較完整的容量衰退趨勢，因此預測誤差明顯降低。

此外，dropout 比例由 0.1 逐步提高至 0.3 後，模型預測結果亦有所改善。由於本研究輸入特徵已經過 ICA 特徵萃取與充電時間轉換，特徵本身已具有一定代表性；然而，在資料量有限的情況下，模型仍可能過度依賴部分特徵或特定循環區段，造成過擬合現象。因此，適度提高 dropout 比例可降低模型對局部特徵的依賴，使模型更傾向學習整體退化趨勢，進而提升測試資料上的預測穩定性。

綜合表 1 結果可知，最佳參數組合為 sequence length=40、hidden units=32、learning rate=0.001、batch size=32、dropout=0.3、epochs=500。於此設定下，LSTM 模型取得 RMSE=0.005412、MAE=0.004044 之最佳結果。此結果顯示，對於本研究之 SOH 預測任務而言，較長的時間視窗能提供更完整的退化資訊，而適當的 dropout 與訓練回合數則有助於提升模型收斂穩定性與泛化能力

在最佳參數設定下，LSTM 與 BiLSTM 模型之

SOH 預測曲線分別如圖 5 與圖 6 所示。由圖 5 可觀察到，LSTM 預測曲線能大致貼合實際 SOH 衰退趨勢，顯示模型可有效學習健康指標序列與容量衰退之間的關係。圖 6 則呈現 BiLSTM 於相同資料條件下之預測結果，雖然整體趨勢亦能反映 SOH 下降變化，但其誤差略高於 LSTM，表示在本研究之資料切分與輸入特徵設定下，BiLSTM 未明顯優於單向 LSTM。

本研究進一步比較最佳參數下 LSTM 與 BiLSTM 模型之預測結果，如表 2 所示。結果顯示，LSTM 於多電池共同建模條件下取得 RMSE=0.005412、MAE=0.004044；BiLSTM 則取得 RMSE=0.006210、MAE=0.004586，兩者皆優於單一電池測試結果。其中，LSTM 整體表現略優於 BiLSTM，顯示在本研究以過去循環健康指標預測後續 SOH 之任務設定下，單向 LSTM 已能有效捕捉主要容量衰退趨勢。

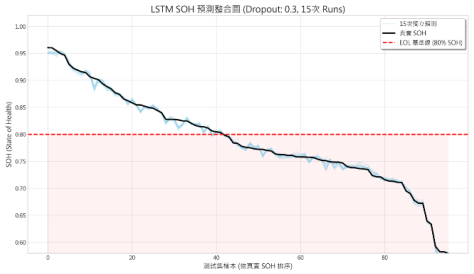


圖 5、LSTM 最佳組合結果

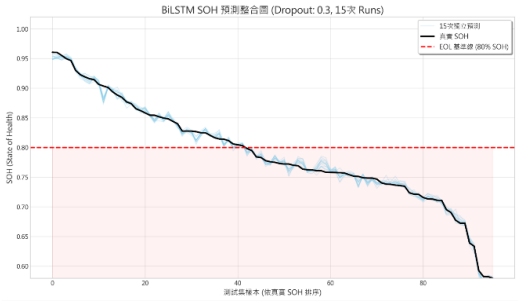


圖 6、BiLSTM 最佳組合結果

表 2 本研究模型預測結果比較

模型	電池	MAE	RMSE
LSTM	多電池	**0.004044***	**0.005412***
BiLSTM	多電池	0.004586	0.006210
LSTM	B0005	0.013430	0.0174
LSTM	B0006	0.054839	0.0642
LSTM	B0007	0.016794	0.0207
LSTM	B0018	0.022118	0.0273

由表 2 可知，LSTM 於多電池共同建模條件下取得最佳結果，且整體表現略優於 BiLSTM。此結果可能與本研究之資料切分方式及輸入特徵型態有關。本研究採用 sequence length=40 之滑動視窗作為模型輸入，模型僅使用預測點之前 40 個循環之健康指標序列，而不使用預測點之後的資料，以避免未來資訊洩漏。因此，BiLSTM 雖具有正向與反向學習能力，但其反向資訊僅來自同一段歷史視窗內的反向讀取，並非真正取得未來循環資訊，故額外效益有限。

另一方面，多電池共同建模之整體誤差低於單一電池測試結果，顯示將 B0005、B0006、B0007 與 B0018 等多顆電池資料共同納入訓練，可使模型學習不同電池之容量衰退型態與健康指標變化，降低單一電池退化差異對預測穩定性的影響。其中 B0006 之 RMSE 明顯高於其他電池，也說明不同電池即使來自相同資料集，其退化軌跡仍可能存在差異。因此，本研究後續分析以多電池共同建模結果作為主要成果，並將單一電池測試作為補充說明。

3.8 與既有文獻之預測結果比較

為進一步評估本研究方法之有效性，本研究將 LSTM／BiLSTM 模型結果與既有 NASA 鋰離子電池資料集相關研究進行比較。由於不同文獻在資料切分方式、輸入型態、特徵定義、模型架構與評估方式上可能存在差異，因此本節並非僅以單一

RMSE 數值判定優劣，而是從多電池共同建模、單通道與多通道輸入，以及單一電池測試三個面向進行討論，以說明本研究方法之特性與應用價值。

3.8.1 基於多電池之數據採集建模分析

表 3 整理本研究多電池共同建模結果與相關文獻之模型表現。Choi et al.[19]採用充電曲線作為模型輸入，並利用 LSTM 進行容量估測；Panagiotis et al.[6]則導入 ICA 相關特徵，比較不同機器學習模型於 SOH 估測中的表現；Sun et al.[8]進一步結合 ICA 特徵與 BiLSTM 模型進行 SOH 預測。上述研究皆與本研究同樣關注充電資料或 ICA 特徵於電池健康狀態預測中的應用，因此可作為本研究模型表現之比較基準。

表 3 與既有文獻之預測結果比較（多電池之數據採集建模分析）

作者/年份	模型	輸入訊號	MAE	RMSE
本文	LSTM	電壓	0.004044*	0.005412*
	BiLSTM		0.004586	0.00621
Choi,Yohwan,et al.（2019）[19]	LSTM	電壓	0.021	0.0288
Panagiotis,et al.（2024）[6]	LSTM	電壓	0.577	0.741
Sun,et al.（2022）[8]	LSTM	電壓	-	0.0897
	ICA-BiLSTM		-	0.0539

由表 3 可觀察到，本研究多電池共同建模下之 LSTM 模型取得 RMSE=0.005412、MAE=0.004044，整體預測誤差低於表中所列相關文獻結果。本研究與 Choi et al.[19]相同，皆以充電階段資料作為主要資訊來源；不同之處在於，Choi et al.[19]主要由原始充電曲線學習容量變化趨勢，而本研究進一步將充電電壓與時間資料轉換為 IC 峰值高度、峰值電壓、谷值、曲線面積與充電時間等健康指標，使模型能更集中學習與 SOH 衰退相關之特徵。

相較於 Panagiotis et al.[6]與 Sun et al.[8]，本研究同樣重視 ICA 特徵於 SOH 估測中的應用，但進一步結合循環配對、S-G 濾波、資料正規化與多電池共同建模流程。整體而言，表 3 結果顯示，本研究之優勢在於將單一充電電壓來源轉換為多個具物理意義之健康指標，並使模型同時學習不同電池之容量衰退型態，在保持模型流程相對簡潔的情況下，仍能取得具競爭力之 SOH 預測結果。

3.8.2 單通道與多通道比較

為進一步分析輸入訊號通道數對 SOH 預測結果之影響，本節將本研究之單通道特徵工程方法與既有文獻中採用多通道輸入之方法進行比較。一般而言，多通道方法係指同時使用兩種以上原始量測訊號作為模型輸入，例如電壓、電流與溫度等，使模型能從不同量測來源中學習電池老化過程中的變化特性。相較之下，本研究雖然模型輸入包含 IC 峰值高度、峰值電壓、谷值、曲線面積、CC 充電時間與 CV 充電時間等多個健康指標，但這些特徵皆由充電階段之電壓與時間資料轉換而得，並未直接將電壓、電流與溫度等多組原始曲線同時輸入模型。因此，本研究仍定位為以充電電壓為核心之單通道特徵工程方法。

表 4 整理本研究與多通道相關文獻之預測結果。Choi et al.[19]採用電壓、電流與溫度三種充電曲線建立多通道 LSTM 模型；Qi et al.[21]使用電壓與電流作為輸入，並結合 SLATrans 模型進行 SOH 估測；Chen et al.[22]則採用電壓、電流與溫度作為多通道輸入，

並結合GWO-CNN-BiLSTM-Attention模型提升預測能力。透過上述文獻比較，可觀察本研究在未使用多通道原始訊號輸入的情況下，是否仍能取得具競爭力之預測表現。

表 4 與既有文獻之預測結果比較（通道）

作者/年份	模型	輸入訊號	MAE	RMSE
本文	LSTM	電壓	0.004044*	0.005412*
	BiLSTM		0.004586	0.00621
Choi,Yohwan,et al.（2019）[19]	MC-LSTM	電壓、電流、溫度	0.0159	0.0246
Qi et al（2025）[21]	SLATrans	電壓、電流	0.0097	0.0137
Chen et al.（2025）[22]	GWO-CNN-BiLSTM-Attention	電壓、電流、溫度	0.015	0.018

由表 4 可觀察到，本研究以單一充電電壓來源為核心，經特徵工程轉換後輸入 LSTM 模型，取得 RMSE=0.005412、MAE=0.004044 之結果，整體誤差低於表中所列多通道文獻結果。此結果顯示，SOH 預測表現並不單純取決於輸入通道數量，而與輸入資料是否能有效反映電池老化行為密切相關。

Choi et al.[19]採用電壓、電流與溫度三種充電曲線作為多通道輸入，Qi et al.[21]使用電壓與電流並結合 SLATrans 模型，Chen et al.[22]則進一步結合 GWO、CNN、BiLSTM 與 Attention 架構。上述方法皆透過增加輸入訊號或模型複雜度提升特徵學習能力；相較之下，本研究未直接使用多通道原始資料，而是透過 ICA 與充電時間特徵將單一電壓來源轉換為具物理意義之健康指標，再以較簡潔的 LSTM 模型學習其時間變化趨勢。

綜合表 4 結果可知，多通道輸入雖可提供更豐富的量測資訊，但也可能增加模型訓練複雜度，並使結果更依賴不同通道資料的品質與同步性。以 NASA 資料集而言，溫度多屬外部量測值，電流在恆電流充電階段變化有限，因此本研究選擇以充電電壓為核心進行特徵工程。此結果說明，本研究方法的主要優勢並非來自輸入通道數量的增加，而是來自對充電電壓曲線中老化資訊的有效轉換與利用。

3-8-3 單一電池測驗比較

除多電池共同建模外，本研究亦進行單一電池測試，以觀察模型在不同電池個體下之預測能力。單一電池測試可用於檢視模型對特定電池容量衰退軌跡的擬合程度，但其結果較容易受到該顆電池本身退化特性的影響。換言之，即使模型在某一顆電池上取得良好結果，也不一定代表相同模型能直接應用於其他電池。因此，本節將本研究之單一電池測試結果與 Khan et al.[20]及 Qu et al.[11]之研究進行比較，以進一步說明本研究方法在不同電池條件下之表現。

表 5 整理本研究與既有文獻之單一電池預測結果。Khan et al.[20]主要比較單通道充電曲線與多通道充電曲線於不同模型下之預測效果，其中單通道電壓結果與本研究以充電電壓為核心之方法具有較高對照意義。Qu et al.[11]則提出 PA-LSTM 方法，該方法以 LSTM 為基礎，結合 PSO、Attention、CEEMDAN 去噪與增量學習，並以容量或

SOH 序列作為主要輸入，可作為較高模型複雜度下之參考基準。

表 5 與既有文獻之預測結果比較（單一電池）

作者/年份	模型	輸入訊號		B0005	B0006	B0007	B0018
本文	LSTM	電壓	RMSE	0.0174	0.0642	0.0207	0.0273
			MAE	0.01343	0.054839	0.016794	0.022118
Khan,et al.（2020）[20]	LSTM	電壓	RMSE	0.0289	0.0291	0.0294	0.0299
			MAE	0.0211	0.0215	0.0219	0.0224
	BiLSTM	電壓	RMSE	0.0241	0.0244	0.0248	0.0252
			MAE	0.0188	0.0189	0.0191	0.0195
QU,et al.（2019）[11]	Simple LSTM	容量	RMSE	**0.0061***	0.0161	-	0.0142
			MAE	-	-	-	-
	PA-LSTM		RMSE	**0.0060***	0.0079	-	0.0124
			MAE	-	-	-	-

由表 5 可觀察到，本研究在不同單一電池上的預測結果並不完全一致。其中，B0005、B0007 與 B0018 之 RMSE 分別為 0.0174、0.0207 與 0.0273，整體仍維持在可接受範圍內；然而，B0006 之 RMSE 為 0.0642，明顯高於其他電池。此結果顯示，即使電池來自相同 NASA 資料集，且具有相近測試條件，不同電池之退化軌跡仍可能存在差異，因此單一電池測試較容易受到個別電池老化行為影響。

與 Khan et al.[20]之單通道電壓 LSTM 結果相比，本研究於 B0005、B0007 與 B0018 之 RMSE 皆較低，顯示透過 ICA 與充電時間特徵所建立之健康指標，能較直接輸入原始電壓曲線更有效地描述容量衰退趨勢；但 B0006 結果高於該文獻，也說明本研究目前特徵處理流程對部分電池退化型態仍有改善空間。

相較於 Qu et al.[11]，其 PA-LSTM 於多數單顆電池上取得較低 RMSE，主要原因在於該方法結合 PSO 參數最佳化、Attention 機制、CEEMDAN 去噪與增量學習，並以容量或 SOH 序列作為主要輸入。整體而言，單一電池測試可作為模型對個別電池預測能力的補充說明；若考量實務應用中不同電池個體之退化差異，多電池共同建模仍較能反映模型整體穩定性與應用價值。

4.實驗結果與分析

本研究透過資料前處理、循環配對、ICA 特徵萃取、S-G 濾波與資料正規化，將原始充電資料轉換為具物理意義且較穩定之健康指標序列，包括 IC 峰值高度、峰值電壓、谷值、曲線面積，以及 CC/CV 充電時間等特徵。此處理流程可降低原始量測雜訊與資料冗餘對模型訓練之影響，使 LSTM 與 BiLSTM 能更集中學習容量衰退相關資訊。

由實驗結果可知，當 sequence length 設定為 40、dropout 設定為 0.3、epochs 設定為 500 時，模型可取得較佳預測效果。其中，LSTM 於多電池共同建模條件下取得 RMSE=0.005412、MAE=0.004044 之最佳結果，整體表現略優於 BiLSTM 與各單一電池測試結果。此結果顯示，多電池共同建模可使模型同時學習不同電池之退化軌跡，降低單一電池資料差異對預測穩定性的影響。

綜合文獻比較結果可知，本研究雖未直接使用多通道原始資料，也未採用 Transformer、CNN-BiLSTM-Attention 或最佳化演算法等複雜架構，但透過單一充電電壓來源之特徵工程，仍能取得具競爭力之預測表現。此結果說明，SOH 預測效能並非單純取決於輸入通道數量或模型複雜度，而與特徵

是否能有效反映電池老化行為密切相關。

5.結論

本研究以 NASA 鋰離子電池資料集為基礎，建立一套結合增量容量分析（ICA）、S-G 濾波、充電時間特徵與 LSTM／BiLSTM 模型之 SOH 預測流程。透過充放電循環配對、異常資料處理與資料正規化，本研究將原始充電資料轉換為具物理意義且較穩定之健康指標，作為後續時間序列模型之輸入。實驗結果顯示，LSTM 於多電池共同建模條件下取得最佳表現，RMSE 為 0.005412、MAE 為 0.004044，優於 BiLSTM 及各單一電池測試結果。此結果說明，將 B0005、B0006、B0007 與 B0018 等多顆電池資料共同納入訓練，有助於模型學習不同電池之退化軌跡，並提升整體預測穩定性。

此外，本研究雖未直接使用多通道原始資料或高度複雜之混合模型架構，但透過單一充電電壓來源之特徵工程，仍能取得具競爭力之預測結果。此結果顯示，SOH 預測效能並非單純取決於輸入通道數量或模型複雜度，而與特徵是否能有效反映電池老化行為密切相關。

未來研究可針對 B0006 等誤差較高之樣本進一步分析其 IC 曲線與充電時間特徵變化，並可加入交叉驗證或多通道輸入版本，以更完整評估不同資料組成與模型架構對 SOH 預測結果之影響。

參考文獻

[1] Hasib, S. A., Islam, S., Chakrabortty, R. K., Ryan, M. J., Saha, D. K., Ahamed, M. H., ... & Badal, F. R. (2021). A comprehensive review of available battery datasets, RUL prediction approaches, and advanced battery management. Ieee Access, 9, 86166-86193.

[2] B. Saha and K. Goebel (2007). “Battery Data Set”, NASA Prognostics Data Repository, NASA Ames Research Center, Moffett Field, CA

[3] Dos Reis, G., Strange, C., Yadav, M., & Li, S. (2021). Lithium-ion battery data and where to find it. Energy and AI, 5, 100081.

[4] Hu, X., Che, Y., Lin, X., & Onori, S. (2020). Battery health prediction using fusion-based feature selection and machine learning. IEEE Transactions on Transportation Electrification, 7(2), 382-398.

[5] Devie, A., Baure, G., & Dubarry, M. (2018). Intrinsic variability in the degradation of a batch of commercial 18650 lithium-ion cells. Energies, 11(5), 1031.

[6] Eleftheriadis, P., Gangi, M., Leva, S., Rey, A. V., Groppo, E., & Grande, L. (2024). Comparative study of machine learning techniques for the state of health estimation of Li-Ion batteries. Electric Power Systems Research, 235, 110889.

[7] Lipu, M. H., Hannan, M. A., Hussain, A., Hoque, M. M., Ker, P. J., Saad, M. H. M., & Ayob, A. (2018). A review of state of health and remaining useful life estimation methods for lithium-ion battery in electric vehicles: Challenges and recommendations. Journal of cleaner production, 205, 115-133.

[8] Sun, H., Sun, J., Zhao, K., Wang, L., & Wang, K. (2022). Data-driven ICA-Bi-LSTM-combined lithium battery SOH estimation. Mathematical Problems in Engineering, 2022(1), 9645892.

[9] Elmahallawy, M., Elfouly, T., Alouani, A., & Massoud, A. M. (2022). A comprehensive review of lithium-ion batteries modeling, and state of health and remaining useful lifetime prediction. Ieee Access, 10, 119040-119070.

[10] Meng, H., & Li, Y. F. (2019). A review on prognostics and health management (PHM) methods of lithium-ion batteries. Renewable and Sustainable Energy Reviews, 116, 109405.

[11] Qu, J., Liu, F., Ma, Y., & Fan, J. (2019). A neural-network-based method for RUL prediction and SOH monitoring of lithium-ion battery. IEEE access, 7, 87178-87191.

[12] Lu, Z., Fei, Z., Wang, B., & Yang, F. (2024). A feature fusion-based convolutional neural network for battery state-of-health estimation with mining of partial voltage curve. Energy, 288, 129690.

[13] Ding, T., Xiang, D., Sun, T., Qi, Y., & Zhao, Z. (2025, June). AI-driven prognostics for state of health

prediction in Li-ion batteries: A comprehensive analysis with validation. In 2025 6th International Conference on Electrical Technology and Automatic Control (ICETAC) (pp. 22-28). IEEE.
[14] Rai, A., & Liu, J. (2025). A novel feature adaptive meta-model for efficient remaining useful life prediction of lithium-ion batteries. Journal of Energy Storage, 114, 115715.
[15] Paulson, N. H., Kubal, J., Ward, L., Saxena, S., Lu, W., & Babinec, S. J. (2022). Feature engineering for machine learning enabled early prediction of battery lifetime. Journal of Power Sources, 527, 231127.
[16] Bian, J., Liu, G., Chen, J., Cao, Y., Chen, R., & Qian, Y. (2025). PSO-MLSt-LSTM: Multi-layer stacked ensemble model for lithium-ion battery SOH prediction via multi-feature fusion. Journal of Energy Storage, 125, 116825.
[17] Zhao, B., Zhang, W., Zhang, Y., Zhang, C., Zhang, C., & Zhang, J. (2024). Research on the remaining useful life prediction method for lithium-ion batteries by fusion of feature engineering and deep learning. Applied Energy, 358, 122325.
[18] Zhang, Z., Zhang, W., Yang, K., & Zhang, S. (2022). Remaining useful life prediction of lithium-ion batteries based on attention mechanism and bidirectional long short-term memory network. Measurement, 204, 112093.
[19] Choi, Y., Ryu, S., Park, K., & Kim, H. (2019). Machine learning-based lithium-ion battery capacity estimation exploiting multi-channel charging profiles. Ieee Access, 7, 75143-75152.
[20] Khan, N., Ullah, F. U. M., Ullah, A., Lee, M. Y., & Baik, S. W. (2020). Batteries state of health estimation via efficient neural networks with multiple channel charging profiles. Ieee Access, 9, 7797-7813.
[21] Qi, J., Zhu, Y., He, X., Wang, J., Chen, Z., Li, J., & Li, H. (2025). State of Health Estimation for Lithium-Ion Batteries Based on Gray Wolf-Optimized CNN-BiLSTM-Attention Hybrid Model. Energy & Fuels, 39(42), 20682-20698.
[22] Chen, T., Zhang, C., Jing, W., Foo, E. Y., Lai, X., & Zeng, N. (2025). State of health estimation for lithium-ion batteries using separable LogSparse self-attention transformer. IEEE Transactions on Instrumentation and Measurement..

附錄

程式碼:

https://github.com/luyuu0215/Battery-SOH-Prediction-LSTM/tree/main