

知識物件上傳表

計畫名稱：113年度「淨零排放-MW 等級儲能電池健康檢測及評估技術優化」(2/2)

上傳主題：電池健康檢測技術

提報機構：工業技術研究院綠能所

提報時間：113 年 6 月 5 日

與計畫相關	☒ 1.是 ☐ 2. 否
國別	☒ 1.國內 ☐ 2. 國外：美國
能源業務	☐ 1.能源政策(包含政策工具及碳交易、碳稅等) ☐ 2.石油及瓦斯 ☒ 3.電力及煤碳(包含電力供應、輸配、煤炭、核能) ☐ 4.新及再生能源 ☐ 5.節約能源(包含工業、住商、運輸等部門) ☐ 6.其他
能源領域	☐ 1.能源總體政策與法規 ☐ 2.能源安全 ☐ 3.能源供需 ☐ 4.能源環境 ☐ 5.能源價格 ☐ 6.能源經濟 ☒ 7.能源科技 ☐ 8.能源產業 ☐ 9.能源措施 ☐ 10.能源推廣 ☐ 11.能源統計 ☐ 12.國際合作
決策知識類別	☐ 1.建言(策略、政策、措施、法規) ☒ 2.評析(先進技術或方法、策略、政策、措施、法規) ☐ 3.標竿及統計數據：技術或方法、產業、市場等趨勢分析 ☐ 4.其他：
重點摘述	電池技術在當今現代社會中扮演著至關重要的角色，然而電池性能和壽命的持久性和穩定性一直是一個關鍵問題，因此電池健康檢測技術變得至關重要。而電池健康度(State of Health, SOH)的預測方法有分為三種方式：直接量測法(Direct Measurement)，模型基礎法(Model-Based Method)與數據驅動法(Data-Driven Method)。Direct Measurement 係指透過實際量測電池性能來確定期 SOH，其中包括量測電池的放電容量、充電電壓、內部電阻等物理參數。Model-Based Method 是建立物理和化學的模型，並基於數學算法來模擬電池的工作情況，然後使用數學算法與實際量測的結果進行比較，從而估計電池的 SOH。Data-Driven Method 係指透過實驗數據搭配機器學習方法，讓模型自己從這些數據中學習特性，藉此預估 SOH。
詳細說明	因應國內再生能源及電網需求，政府積極推動電網端及發電端儲能設備布建，2025年儲能併網目標達1,500MW 以上，成長快速。國內 MW 等級儲能系統以鋰電池為主，尚缺乏深度健康檢測及評估技術，為有效監控儲能系統運轉即時狀況，需投入儲能電池健康檢測技術，掌握系統維運週期及排程，提升儲能系統可靠度與運轉效益。 電池健康度(State of Health, SOH)的預測方法有分為三種方式：直接量測法(Direct Measurement)，模型基礎法(Model-Based Method)與數據驅動法(Data-Driven Method)。近年來，人工智慧的興起，除了傳統的評估方式外，使用機器學習來訓練模型的方式，來預測電池健康狀態(State of Health, SOH)的方式也越來越多。最近機器學習技術快速發展為電池評估技術帶來全新的可能性。不僅可以提供更多訊息，也可以幫助我們更好地了解電池性能趨勢和需求變化。因此機器學習方法被視為一個具有潛力的方法，可以為電池評估技術的發展提供新的洞察。

本文主要介紹機器學習、深度學習方法，並以實際案例說明在電池健康度預測上的應用。

一、機器學習與深度學習理論分析

介紹機器學習與深度學習之前，必須先提到人工智慧，它是一種高科技時代的產物，顧名思義就是人類所製造的智慧，可以這樣將其定義，通常是指電腦模擬人類的思考方式或是行為能力來達成目標。但早期礙於電腦效能限制，只能用來解決一些比較簡單的問題，雖然人工智慧的技術仍然有持續往前，但此技術並沒有獲得廣大的青睞。直到 AlphaGo 在圍棋上擊敗人類，人工智慧的技術才得以被大家所看見。由圖1可以得知，機器學習是人工智慧的子集合，而深度學習是機器學習的子集合。




圖 1、人工智慧、機器學習與深度學習[1]

1. 機器學習:

如圖2所示，機器學習方法主要分成四類：監督式學習（Supervised learning），非監督式學習（Unsupervised learning），半監督式學習（Semi-supervised learning），強化學習（Reinforcement learning），將針對每個類別做敘述及列舉幾個演算法。




圖 2、機器學習方法種類[2]

i. 監督式學習:

監督式學習問題可以進一步分為分類（Classification）和回歸（Regression），這兩個任之間的區別在於分類是對資料做選擇

分類，而回歸是對資料做出計算值預測。分類的經典算法有貝葉斯分類器[3]，K-近鄰演算法(K-Nearest Neighbor)[4]、決策樹(Random Forest)[5]、支持向量機（SVM）[6]等。通常應用在分類問題，房價預測，股票預測。

ii. 非監督式學習:

與監督式學習剛好相反，非監督式學習不需要對資料進行標記，在沒有任何標記的情況下讓機器自行學習資料的關聯性。常見的經典算法有 K-Means，Apriori 與 PCA，這三種演算法分別對應分群，關聯與降維。

iii. 強化學習:

強化學習主要是讓智能體在環境當中，模擬人在錯誤中，透過與環境的互動，不斷修正自己的行為（action），已獲得最大的獎勵。如圖3所示，智能體與環境互動，環境給予相對應的獎勵，智能體接下就可以藉由此獎勵與接下來的環境狀況判斷接下來的動作。所以為了找出獲得最大獎勵的方式，智能體必須沙盤推演於採取不同行動策略下，所獲得不同的獎勵值，並揀選能於環境所具有的狀態（state）中獲得最大獎勵的行動策略來訓練（training）出神經網路中的權重（weight）。而上述提到的 AlphaGo 就是一個著名的強化學習案例。

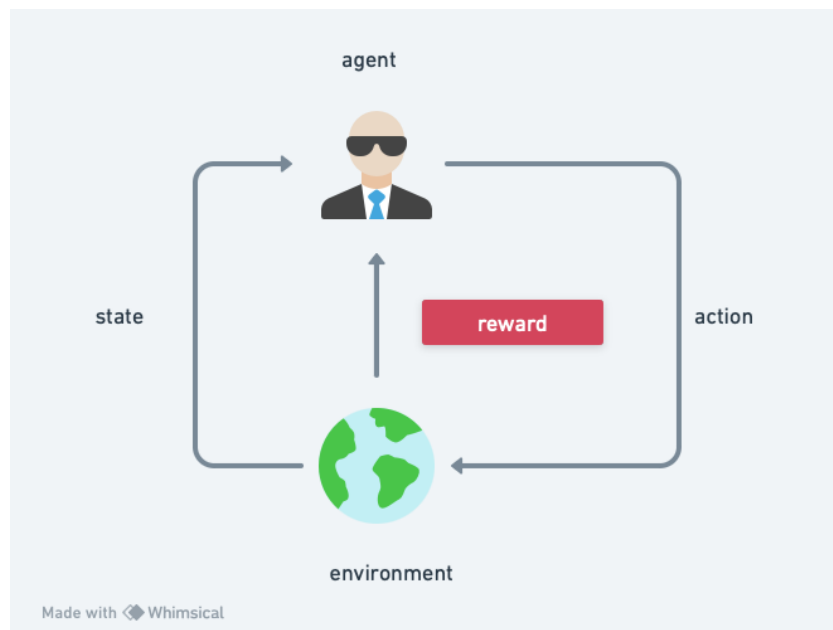


圖 3、強化學習示意圖

2. 深度學習

通常深度學習也常與神經網路一起被提到，因為深度學習就是以神經網路為架構，並且以多層不斷疊加所形成的架構[7]。由 Yann LeCun 等人在2015年發表，提出了 Deep learning 的方法，它的應用幾乎涵蓋目前 AI 的各個領域：影像辨識、影像生成、自然語言處理、文字生成機、語意理解、推薦系統等，就連現在的 ChatGPT 也是以深度學習為基礎的一種架構。由圖4可以發現，深度學習是由多層神經網路所組成，可以將它想像是人的腦神經，從一端輸入訊號，由另一端輸出訊號。我們可以

看到每一層 layer 都是由數個 neuron 組成。神經網路大致上可以分成三層：輸入層、隱藏層及輸出層。由圖6可知，輸入層做為輸入資料的接收點，接下來隱藏層的每一個神經元會對其前一層神經元乘以權重 (w)，然後通過激活函數(activation function)的計算後，再將輸出的結果輸入到下一層。輸出層則是輸出最終結果 y 。如圖7所示，這些權重就是模型訓練過程中，透過反向傳播(back propagation)來修正這些權重來找到最佳的權重值。




圖 4強化學習示意圖神經網路示意圖[8]

二、 電池老化評估分析架構與方法

使用 NASA 鋰電池壽命衰退數據集，實驗數據為18650可充電電池的實驗數據，分別拿5號, 6號, 7號, 18號電池數據進行分析。充電過程為，用固定電流1.5A 對電池進行充電，直到電池電壓達到4.2V，然後以固定電壓充電，直到充電電流降到20mA。放電過程為，以2A 固定電流放電，直到電壓分別降到2.7V, 2.5V, 2.2V 與2.5V。重複此充放電過程，直到電池容量下降30%，也就是從2Ah 下降到1.4Ah。


1. 分析架構:

- I. 電池資料：NASA 鋰電池壽命衰退數據集
- II. 資料處理：在訓練模型之前，必須檢查資料有無異常值，對資料做正則化，有助於模型的訓練
- III. 建構模型：選擇適合的模型進行訓練
- IV. 模型是否適合：將訓練好的模型，用新的資料進行預測，檢查模型的效度，若不夠準確，必須重新訓練模型或對資料面重新調整

2. 模型架構

I. LSTM(long short-term memory)

在 LSTML 提出之前，RNN(recurrent neural networks)模型就被用來分析時間序列資料，相較於 RNN，LSTM 可以記憶長時間的數據，可以將它當成是一個暫存記憶體，也就是說它可以記住之前的訊息。如圖5所示，其架構主要由三個 gate 所組成分別為：



The repeating module in an LSTM contains four interacting layers.

圖 5、LSTM 示意圖[9]

- Input gate: 控制多少比例的值可以輸入
- Forget gate: 控制有多少比例的值從 memory cell 取出
- Output gate: 控制多少比例的值可以輸出

II. Transformer

上述有提到 LSTM 可以用來處理序列化的資料，但是當這些序列化資料太長時，很容易丟失訊息，因此 Google 在2017[10]提出 Attention is All You Need，介紹一種新的網路架構，Transformer。Transformer 透過一種自注意力機制（self-attention）方式，學習資料上下文之間的關係，這是在 CNN 之後，近幾年的重大突破。其基本架構是由 Encoder 及 Decoder 所組成，Encoder 對序列化資料進行特徵擷取，並且輸出向量，Decoder 則將使用向量輸出結果。

在開始介紹 Transformer 之前，必須要先介紹自注意力機制（self-attention），它能夠使模型計算輸入序列彼此之間的關聯性，可以關注不同位置的訊息，這樣能夠讓模型清楚知道序列資料前後的依賴關係。要計算關聯性，必須透過以下三個參數：

- q(query): 當前的數據，用於對每個的 key 做內積，計算出關聯性的分數
- k(key): 序列中的所有輸入
- v(value): 實際的序列資料

如圖6，q1會對每一個 k 做內積得到關聯性 α ，又叫作 attention score，然後將這個值在經過 softmax 作轉換後得到權重 α' ，接下來再將 α' 與 v 內積來抽取重要資訊。




圖 6、self attention 示意圖[10]

如圖 7 所示，transformer 架構由 Encoder 與 Decoder 所組成，其中這兩個 block 由 Positional Encoding、Multi-head Attention、Add&Norm、Feed Forward、Masked Multi-head Attention 所組成，接下來將一一介紹：

- Position Encoding：目的使 Transformer 考慮序列輸入值的位置關係
- Multi-head Attention：上面提到的 self attention，只有一組 q, k, v，而多組 q, k, v，目的為讓各個 head 可以關注不同的訊息
- Add&Norm：Add 指的是 residual connection，它可以解決前面有提過的梯度消失問題；Norm 指的是 layer normalization，通常深度學習會使用 batch normalization，但不適合用於序列化資料，原因為
 1. batch 太小，訓練效果不好
 2. 序列化資料長度通常不一致

因此在序列化資料中較常使用 layer normalization，概念與 batch normalization 類似，在於 layer normalization 是對每一筆資料的不同特徵進行 normalize。




圖 7、Transformer 架構示意圖[10]

三、 實作與分析結果

將根據電池數據分析結果與不同參數之間進行比較，分別使用 Transformer、LSTM 進行訓練後，將模型預測的電池容量與實際的電池容量會製成圖，探討所使用的分析方法與實際結果差異。

1. Transformer 模型預測

表 1 列出，在固定的變數之下，不同電池在相同模型下，RMSE、MAE、MSE 的比較。圖 8 為 5 號電池的模型預測值與實際值，循環次數與電容量關係圖，由圖中可以得知，雖然模型預測電容量隨著循環次數增加有下降趨勢，但是在 window size 為 32，dropout 為 0 的情況下，Transformer 模型預測的電容量，並沒有擬和實際的數據。

表 1、Transformer 模型，dropout = 0，對應於不同電池的比較

window size = 32，dropout = 0				
	B0005	B0006	B0007	B0018
RMSE	0.047	0.12	0.064	0.045
MAE	0.042	0.1	0.053	0.036
MSE	0.0022	0.016	0.004	0.02




圖 8、於 Transformer 模型，電池 B0005模型預測值與實際值，循環次數與電容量關係圖

2. LSTM 模型預測

表 2 列出，在固定的變數之下，不同電池在相同模型下，RMSE、MAE、MSE 的比較。圖 9 為 5 號電池的模型預測值與實際值，循環次數與電容量關係圖，由圖中可以得知，雖然模型預測電容量隨著循環次數增加有下降趨勢，但是在 window size 為 32，dropout 為 0 的情況下，LSTM 模型預測的電容量，並沒有擬和實際的數據。

表 2、LSTM 模型，dropout = 0，對應於不同電池的比較

window size = 32，dropout = 0				
	B0005	B0006	B0007	B0018
RMSE	0.024	0.12	0.12	0.037
MAE	0.019	0.10	0.11	0.029
MSE	0.0006	0.015	0.015	0.0014




圖 9、於 LSTM 模型，電池 B0005模型預測值與實際值，循環次數與電容量關係圖

結論

使用機器學習方法，可以來預測電池電容量，並比較不同模型的結果。本文使用實驗量測的已知電容量，並且可以成功預測出電池的未來的電容量，但是結果準確度有待提升。

本方法的優缺點分析如下：

1.優點

- 靈活性高：不需要對電池的物理過程進行深入理解，可以適應不同類型的電池和應用場景。
- 能夠即時：通常可以提供即時的老化狀態預測。

2.缺點

- 1.可解釋性較差：相對於基於模型的方法，數據驅動方法可能難以提供對老化機制的深入理解。
- 2.需要大量數據：數據驅動方法通常需要大量的標記數據進行訓練，而這些數據的獲取和標記可能成本較高。

參考文獻

	[1] What's the Difference Between Artificial Intelligence, Machine Learning and Deep Learning, https://blogs.nvidia.com/blog/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/ [2] Types of Machine Learning Algorithms You Should Know, https://towardsdatascience.com/types-of-machine-learning-algorithms-you-should-know-953a08248861 [3] G. E. Box and G. C. Tiao, Bayesian Inference in Statistical Analysis, vol. 40. New York, NY, USA: Wiley, 2011. [4] K. S. Beyer, J. Goldstein, R. Ramakrishnan, and U. Shaft, "When is 'nearest neighbor' meaningful?" in Proc. Int. Conf. Database Theory, Jan. 1999, pp. 217–235. [5] S. R. Safavian and D. Landgrebe, "A survey of decision tree classification methodology," IEEE Trans. Syst., Man, Cybern., vol. 21, no. 3, pp. 660–674, May/Jun. 1991. [6] C. Cortes and V. Vapnik, "Support-vector networks," Mach. Learn., vol. 20, no. 3, pp. 273–297, Sep. 1995 [7] Yann LeCun, Yoshua Bengio, Geoffrey Hinton, "Deep learning" [8] Michael A. Nielsen, Neural Networks and Deep Learning, Determination. Press, (2015) [9] Understanding LSTM Networks, https://colah.github.io/posts/2015-08-Understanding-LSTMs/ [10] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, Illia Polosukhin: Attention Is All You Need

資料提供者／機構：吳重億、黃建中/工業技術研究院綠能與環境研究所

連絡電話：06-3636776

Email: itrib20639@itri.org.tw

註：1.請計畫執行單位上傳提供較具策略性的知識物件，不限計畫執行有關內容。

2.請計畫執行單位每季更新與上傳一次，另有新增政策建議可隨時上傳。

3.文字精要具體，量化數據盡量輔以圖表說明。