

SOH Estimation of Batteries using Lithium-Ion Internal Parameters with Convolution Neural Network and Gated Recurrent

리튬 이온 배터리 내부 파라미터 및 CNN-GRU를 활용한 배터리 수명 추정

Hyun-Yong Park · Hee-Sung Lim · Kyo-Beum Lee

박현룡* · 임희성** · 이교범†

Abstract

This paper proposes an estimation method for Lithium-Ion Batteries SOH by learning the batteries' internal parameters using the Convolution Neural Network and the Gated Recurrent Unit. Various equivalent circuit models exist to represent the batteries' internal parameters. Among these equivalent circuit models, the most representative model is the Randles model, and the data measured based on the Randles model is used as learning input data. The internal parameters of batteries change non-linearly depending on the operation condition and use time. So, nonlinear features are extracted using the CNN input as the batteries' parameters. The extracted features are used as an input of the GRU to learn the characteristics of change over time, and SOH is predicted through this. The learning dataset utilizes 17IND10 LibForSecUse of EMPIR, which validates the performance of the proposed model.

Key Words

Lithium-Ion Battery, SOH, Internal Resistance, CNN, GRU

1. 서론

전기차 시장의 확대와 신재생 에너지를 활용한 발전시스템의 관심이 증가함에 따라, 배터리 기술에 대한 관심도가 높아지고 있다. 충전을 통해 재사용이 가능한 2차 전지 중 리튬이온 배터리는 높은 에너지 밀도와 긴 수명을 가지는 장점이 있다. 이로 인해, 한정된 공간에 탑재된 배터리로 주행거리 향상이 요구되는 전기자동차 분야 및 배터리 수명에 의해 수익이 좌우되는 에너지 저장 장치에서 널리 활용되고 있다[1][2].

리튬 이온 배터리는 장시간 충전 및 방전이 지속됨에 따라, 노후화가 발생한다. 이러한 노후화는 다양한 환경 조건 및 부하 조건에 따라 차이가 발생한다. 노후화에 따른 상태 변화를 모니터링하여 진단 및 고장 시점을 예측하여 폭발, 화재와 같은 사고를 미연에 방지할 수 있다. 노후화 정도를 판단하는 대표적인 지표는 내부 저항 (IR: Internal Resistance)과 SOH (State of Health)가 있다. IR 기준으로 초기 상태의 1.33배~2배까지 증가하거나, SOH가 80% 도달한 경우 배터리의 수명 임

계점 (EOL: End of Life)에 도달하였다고 한다[3].

배터리 IR을 측정하기 위한 방법은 DCIR (Direct Current Internal Resistance)과 ACIR (Alternating Current Internal Resistance)이 존재한다. DCIR은 일정 전류로 방전하면서, 방전 전류값과 특정 타이밍에서의 전압 강하를 측정하여 내부 저항을 산출하는 방식이다. ACIR은 미세한 교류 신호를 인가하여 내부 저항을 산출하는 방식이다. DCIR은 배터리가 충전되어 있어야 하며, 개방 회로 전압 (OCV : Open Circuit Voltage)의 안정화를 위해 일정 시간 이상의 휴지 기간이 필요하다. ACIR은 측정하기 위한 장비가 고가이며, 자동차와 같이 시스템에 장착되어 운용되는 배터리의 경우 측정하기 어렵다[4].

SOH를 추정하기 위한 방법으로 파괴 방식과 비파괴 방식으로 나눌 수 있다. 파괴 방식의 경우 배터리를 분해하여 주사 전자 현미경 (SEM 및 TEM), 광전자 분광법 기법 (XPS) 등의 기법을 통해 노후화를 분석하는 방식이 있다. 비파괴 방법은 직접 측정, 전기화학 모델 등가회로(ECM)의 데이터 기반으로 노후화를 추정한다. 파괴 방식의 한계점은 배터리가 비가역적인 상태로 변환 후에 측정할 수 있으며, 측정하기 위한 장비

† Corresponding Author: Dept. of Electrical and Computer Engineering, Ajou University, Korea.
E-mail: kyl@ajou.ac.kr
<https://orcid.org/0000-0002-2125-9500>

* Dept. of IT Convergence Engineering, Ajou University, Korea.
SK Signet Inc, Korea.
E-mail : hyunyoung1125@gmail.ac.kr
<https://orcid.org/0009-0002-4429-0727>

** Dept. of Electrical and Computer Engineering, Ajou University, Korea.
E-mail : heesunglim@ajou.ac.kr
<https://orcid.org/0000-0003-1320-6465>

Received: Dec. 15, 2022 Revised: Feb. 08, 2023 Accepted: Feb. 25, 2023

Copyright © The Korean Institute of Electrical Engineers

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

가 매우 고가이다. 비파괴 방식의 한계점은 배터리의 비선형적인 특징을 반영해야 하는 어려움이 존재한다[4]-[6].

본 논문에서는 전기적, 전기화학적 방법으로 측정된 리튬이온 배터리의 내부 파라미터를 학습하여 배터리의 SOH 추정한다. 학습 모델은 CNN-GRU 모델을 제안한다. 제안한 학습 모델은 배터리 내부 파라미터와 SOH 간의 비선형적인 특징과 시간에 따라 변화되는 특징을 학습하여, 배터리의 잔여 수명을 예측한다. 데이터 세트로는 실제 충·방전 데이터를 기반으로 작성된 EMPIR의 17IND10 LibForSecUse를 활용하여, 제안된 모델의 성능 검증을 수행한다.

2. 배터리 내부 파라미터와 SOH 관계

본 장에서는 리튬이온 배터리의 내부 파라미터의 특징 및 측정 기법에 대해 정리한다. 또한, 배터리 내부 파라미터와 SOH의 관계를 분석한다.

2.1 내부 파라미터 측정 기법

리튬이온 배터리의 내부 파라미터는 전기적 방법 및 전기화학적 방법으로 측정한다. 전기적 방법은 직류 전류를 인가하여, 전압의 변화를 통해 저항과 커패시턴스 성분을 추출한다. 전기화학적 방법에는 고주파 영역에서 저주파 영역까지 미소한 정현파 전류 및 전압 신호를 인가하여, 배터리가 전기적, 열적 평형 상태를 벗어나지 않는 범위에서의 응답을 활용하여 AC 임피던스 파라미터를 추출하는 전기화학 분광법 (EIS : Electrochemical Impedance Spectroscopy)가 있다[6].

2.2 내부 파라미터 종류

배터리 내부의 전기화학적 상태를 표현하기 위해, 전기적 등가회로 모델을 사용한다. 대표적으로 사용되는 등가회로는 모델은 랜들스 모델이며 그림 1과 같다. 랜들스 등가회로 모델로 표현된 리튬 이온 배터리의 응답 임피던스를 나이키스트 선도로 표현하면 그림 2와 같다. 등가회로로 표현되는 배터리 내부 파라미터 종류에는 전해질 이온 전도 특성을 나타내는 전해질 저항 (R_{ohm}), 고체 전해질 필름에 의한 저항 (R_{SEI}), 전극 계면에서 전하가 이동할 때 나타나는 전달저항 (R_{ct}), 리튬 배터리 내 이온 확산 현상을 나타내는 와버그 임피던스 (Z_W)로 구성된다[6]. 그림 2의 나이키스트 플롯 기준으로 R_{ohm} 은 임피던스 축의 X 절편에 위치하며, 가장 첫 번째 반원이 R_{SEI} , 두 번째 반원이 R_{ct} 이며, 45도 직선은 와버그 임피던스이다[6].

본 논문에서는 그림 3과 같이 표현되는 변형 랜들스 등가회로 모델을 활용한다. 랜들스 등가회로 모델과 변형 랜들스 등가회로 모델의 차이점은 R_{SEI} 에 대한 특성을 고려하지 않는 점이다. 일반적으로 고체 전해질 필름 (SEI : Solid Electrolyte

Interphase)에 의한 영향이 약한 경우, R_{SEI} 및 커패시턴스 성분이 뚜렷하게 측정되지 않으며 이를 고려하지 않을 수 있다[6].




그림 1 랜들스 등가 회로 모델로 표현한 리튬이온 배터리
Fig. 1 Lithium-ion batteries represented by Randles Model




그림 2 랜들스 등가회로 모델의 나이키스트 플롯
Fig. 2 Nyquist plot of Randles equivalent circuit model




그림 3 변형 랜들스 등가회로 모델로 표현한 리튬이온 배터리
Fig. 3 Lithium-ion batteries represented by modified Randles equivalent circuit model

2.3 SOH (State of Health)

배터리의 SOH는 초기 용량 대비 감소된 용량을 백분율로 표현하며, 노화로 인한 성능 감소 지표로 활용한다. 배터리는 충·방전 사이클이 반복됨에 따라 분극 현상으로 인해 저항이 증가한다. 즉, 내부 저항의 증가로 전하가 완전히 전극으로 이동하는 것을 방해하여 사용 가능 용량이 감소한다. 일반적인 경우 배터리의 용량이 초기 용량의 80%에 도달하면, 수명이 다한 것으로 판단하며 교체가 요구된다. SOH는 식 (1)과 식 (2)와 같이 산출한다[8].

$$SOH(\%) = \frac{Q_{max}}{Q_{rated}} \times 100 \quad (1)$$

$$Q_{EOL} = Q_{rated} \times 0.8 \quad (2)$$

2.4 내부 파라미터 특성과 SOH 관계 분석

변형 랜들스 등가회로 모델로 표현된 리튬이온 배터리의 응답 임피던스를 나이키스트 선도로 표현하면 그림 4와 같다. 변형

랜들스 등가회로 모델의 내부 파라미터에는 전해질 저항 (R_{ohm}), 전하 전달 저항(R_{ct}), 전기 이중층 커패시턴스 (CPE_{ct}), 와버그 임피던스 (Z_w)가 있다. R_{ohm} 은 전해질, 집전체 등에서 발생하는 모든 저항을 포함한다. 해당 파라미터는 커패시턴스 성분과 인덕턴스가 존재하지 않기 때문에 그림 4에서 수평축 교차 지점에 표현된다. R_{ct} 의 경우 전해질 용액과 전극 계면에서 에너지 교환을 통해 리튬 이온이 이동하는 전기화학 반응 현상에 따른 저항값이다. 그림 4에서 반원 형태로 표현된다. R_{ct} 는 커패시턴스가 최대가 될 때의 저항값에서 R_{ohm} 을 빼고, 이에 2배를 하여 계산한다. 이는 식 (3)과 같이 표현한다. CPE_{ct} 는 y 축의 가장 높은 지점의 주파수와 R_{ct} 를 식 (4)에 적용하여 계산한다[6].




그림 4 변형 랜들스 등가회로 모델의 나이퀴스트 플롯

Fig. 4 Nyquist plot of modified Randles equivalent circuit model

Z_w 는 리튬 이온의 확산 현상을 나타내는 인자이다. 확산 현상은 충전과 방전이 진행됨에 따라 리튬 이온이 이동하며 발생한다. 즉, 내부의 화학 농도차에 의해 기전력이 형성되어 과전압이 생성된다. Z_w 는 커패시턴스와 저항으로 표현되며, 식 (5) - (6)을 활용하여 계산한다. R_w 는 확산 저항으로 허수부가 최소값을 갖는 지점의 저항이며, w 는 상이 -45° 로 포화되었을 때의 주파수를 나타낸다[6].

$$2(x_{f_{z_{imp,max}}} - R_{\omega}) = R_{ct} \quad (3)$$

$$CPE_{ct} = \frac{1}{\omega R_{ct}} \quad (4)$$

$$Z_w = R_w \frac{1}{\sqrt{j\omega}} \tanh(\sqrt{j\omega}) \quad (5)$$

$$R_w = f_{z_{imp,min}} \quad (6)$$

그림 5는 배터리 충·방전 횟수에 따른, 내부 파라미터의 변화를 나타내고 있다. 배터리 충·방전 횟수가 증가함에 따라, 그래프의 실수 축이 증가하는 방향으로 오른쪽으로 이동하는 특성을 확인할 수 있다. 즉, 배터리 내부 파라미터가 증가함에 따라, 에너지 손실이 발생하게 되며 이로 인해 배터리의 SOH 감소에 영향을 주게 된다.




그림 5 충·방전 사이클에 따른 내부 파라미터 변화

Fig. 5 Changes internal parameters according to charge discharge cycle

3. 제안하는 신경망 학습 모델 구조

본 장에서는 합성곱 신경망 (CNN : Convolution neural Network)와 게이트 순환 유닛 (GRU : Gated Recurrent Units)의 특징에 대해 정리하며, 배터리 SOH 추정을 위한 CNN-GRU 구조에 관해 설명한다.

3.1 합성곱 신경망 (CNN)

CNN은 이미지 분류에 널리 사용되었지만, 최근에는 데이터 간의 관계를 분석하는 데이터 마이닝 분야에도 적극적으로 활용되고 있다. CNN의 경우 학습을 통해 데이터의 특징 추출을 자동으로 수행하게 되며, 높은 정확도를 가진 인식 결과를 얻을 수 있는 장점이 존재한다. CNN의 구조는 그림 6과 같이 표현되며, 데이터의 특징을 추출하는 Feature Learning Layer와 추출된 특징으로 클래스에 따라 분류하는 Classification Layer로 구성이 된다. Feature Learning Layer는 합성곱 (Convolution), ReLU (Rectified Linear Unit), Pooling 처리를 반복하여 입력된 데이터의 특징을 추출한다. Classification Layer는 Flatten, Fully Connected Layer, Softmax 함수를 통해 확률을 포함한 형태로 클래스에 대한 분류를 수행한다. CNN은 일반적인 신경망과 동일하게 입력층 (Input Layer), 출력층 (Output Layer), 은닉층 (Hidden Layer)로 구성된다. 이러한 구조적 특징으로 입력 데이터가 단계별 레이어를 거치며 예측값으로 변환된 후에는 현재 입력된 데이터에 대한 정보는 완전히 사라진다. 즉, 입력 데이터들의 정보가 저장되지 않기 때문에 입력 순서에 따라 데이터 간 종속성이 존재하는 시계열 데이터를 처리하는 데 한계가 존재한다. 이러한 부분을 보완하기 위해 순환신경망 (RNN)을 활용한다[7]-[9].

3.2 게이트 순환 유닛 (GRU)

GRU의 구조는 그림 7과 같다. 장단기 메모리 (LSTM : Long Short-Term Memory)와 매우 유사한 구조로 되어 있다. GRU




그림 6 합성곱 신경망 (CNN) 구조

Fig. 6 Structure of Convolutional Neural Network

및 LSTM은 RNN 계열의 신경망으로서 RNN에서 해결하지 못한 장기 의존성 문제를 해결할 수 있는 구조로 되어 있다. GRU는 LSTM에 대비하여 간략한 구조로 되어 있어, 높은 학습 속도와 유사한 수준의 추론 성능을 보여준다. 특히, 학습 데이터양이 적은 상황에서는 매개 변수량이 적은 GRU가 더 좋은 성능을 보여주는 것으로 알려져 있다. GRU는 리셋 게이트 (Reset Gate)와 업데이트 게이트 (Update Gate)로 구성되어 있다. 입출력 관계는 식 (7) - (10) 와 같이 표현 한다. 식 (7) 은 Reset Gate를 표현하는 수식으로 무시해야 할 과거의 정보량을 결정 하는데 활용한다. 식 (8)은 Update Gate를 나타내며, 출력에 반영하고자 하는 과거의 정보와 현재 정보의 양을 결정한다. 이는 LSTM의 Forget Gate와 Input Gate를 결합한 것과 유사한 형태를 가지고 있다. Update Gate는 반영하고자 하는 과거의 정보와 현재의 정보의 양을 결정한다. 식 (9)은 과거 데이터와 Reset Gate의 결과를 곱해 후보 활성화 벡터 (Candidate Activation Vector)를 계산하며, 최종적인 출력은 식 (10)를 통해 계산한다[9].

$$r_t = \sigma(W_r \cdot [h_{t-1} \ x_t]) \quad (7)$$

$$z_t = \sigma(W_z \cdot [h_{t-1} \ x_t]) \quad (8)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \cdot h_{t-1} \ x_t]) \quad (9)$$

$$h_t = \tanh(W_h \cdot [z_t \cdot h_{t-1} \ \tilde{h}_t]) \quad (10)$$




그림 7 게이트 순환 유닛 (GRU) 구조

Fig. 7 Structure of Gated Recurrent Unit

3.2 제안하는 CNN-GRU 구조

그림 8은 배터리 충·방전 사이클에 따른 용량 감소를 나타

내고 있는 그래프이다. 동일한 충·방전 프로 파일임에도 배터리 마다 용량 감소의 정도와 내부 저항 변화율의 차이가 존재하는 것을 확인할 수 있다. 이러한 비선형적인 특징을 추출하고 장기적인 시계열 데이터를 학습할 수 있는 모델이 요구된다.




그림 8 사이클에 따른 배터리 용량 감소

Fig. 8 Reduced battery capacity with cycles

본 논문에서는 비선형적인 변화에 따른 특징을 추출하기 위해 CNN을 사용한다. CNN을 통해 예측된 정보는 단시간 정보의 특징을 추출할 수 있지만, 시간에 따른 변화 특성을 추출하기는 어렵다. 이러한 한계를 보완하기 위해 CNN의 추출 정보를 GRU의 입력으로 활용하여, 배터리의 SOH를 추정한다. 그림 9는 본 논문에서 제안하는 CNN-GRU의 구조를 나타내고 있다. 입력 데이터는 배터리 SOC, 내부 파라미터, 내부 파라미터 측정 주파수로 구성되며, 모든 데이터는 정규화 되어 고정된 2차원 배열로 구성한다.




그림 9 제안하는 CNN-GRU 구조

Fig. 9 Proposed structure of CNN-GRU

4. 학습 데이터 처리 및 구조

4.1 학습 데이터

제안한 학습 모델을 학습시키기 위한 데이터는 EMPIR

(European Metrology Programme for Innovation and Research)의 17IND10 LiBforSecUse의 LCT(Life Cycle Tests) 데이터를 활용한다. 해당 데이터는 총 34개의 18650 NMC 811 계열의 배터리를 동일한 CC-CV 조건으로 충·방전 사이클 별 배터리의 내부 파라미터를 측정하였다. 해당 데이터는 13개의 그룹으로 구분되어 있으며, 그룹에 따라 DoD Cycle, SOC 최대 충전기준과 충·방전 중 주변 온도 차이가 존재한다. 각 그룹에 따른 상세 조건은 표 1과 같다.

표 1 시험 그룹에 따른 충방전 조건

Table 1 Charging and discharging conditions according to test group

시험 그룹	주변 온도 (°C)	최대 충전 SOC (%)	DoD Cycle (회)
1_01	45	100	100
1_02	45	100	100
1_03	45	100	100
1_04	45	100	100
1_05	45	100	100
1_06	45	100	100
1_10	35	100	100
1_11	45	75	50
1_13	23	100	100
1_14	45	100	50
1_15	45	100	70
1_16	45	100	30
1_17	5	100	100

4.2 데이터 전처리

17IND10 LiBforSecUse의 LCT (Life Cycle Tests) 데이터 세트에는 내부 파라미터 측정 시점의 충·방전 사이클, SOC, 측정 주파수, 내부 파라미터의 실수부, 허수부 등으로 구성되어 있다. 해당 데이터 항목 중 SOC, 측정 주파수, 내부 파라미터를 학습 데이터로 활용한다. 해당 데이터를 학습 모델의 입력으로 활용하기 위해서 서브 샘플링과 정규화와 같은 전처리가 요구된다.

서브 샘플링의 경우 충·방전 사이클에 따라 내부 파라미터 측정 횟수의 차이가 존재하여, 동일한 조건의 데이터 세트 구성을 위해서 수행되어야 한다. 충·방전 사이클 별 SOC 기준 최대 6 포인트, 최소 2 포인트에서 내부 파라미터가 측정되어 있다. 이에 따라 서브 샘플링 조건은 SOC 기준 최소 5 포인트 이상 측정된 사이클의 데이터를 추출한다. 또한, 사이클 횟수가 10 이상인데, SOH의 값이 1인 경우 이상 데이터라고 판단하여 샘플링에서 제외한다. 이에 따라, 총 966개 중 633개의 데이터 세트를 사용한다. 이후, SOC 측정이 6포인트 이상인 경우, 랜덤으로 5포인트를 추출한다. 구성된 데이터 세트 구조는 그림 10과 같다.




그림 10 학습 데이터 세트 구조

Fig. 10 Structure of learning dataset structure

앞서 추출된 데이터는 종류에 따라 측정 단위의 차이가 존재하며, 이에 따른 가중치가 발생하게 된다. 또한, 동일 조건의 충·방전 프로파일에서도 개별 배터리마다 용량이 감퇴되는 정도의 차이가 존재한다. 이러한 차이는 과적합 (Over-fitting)의 원인이 된다. 이러한 문제를 회피하기 위해 식 (11)을 활용하여 0과 1 사이의 값을 갖도록 정규화를 수행한다.

$$z_k = \frac{x_k - \min(x)}{\max(x) - \min(x)} \quad k \in 1, \dots, n \quad (11)$$

이렇게 전처리가 완료된 633개의 데이터 세트를 활용하며, 이 중 80%는 학습을 위해 데이터 세트, 10%는 검증 데이터 세트, 10%는 테스트 데이터 세트로 나누어 활용한다.

5. 학습 및 SOH 추정 결과

본 장에서는 제안하는 신경망 모델의 학습 파라미터에 대해 정리하며, 성능을 검증하기 위해 LSTM, GRU 모델과의 성능을 비교한다.

5.1 학습 파라미터

모델의 하이퍼 파라미터는 표 2와 같이 구성하였다. 표 3은 제안하는 CNN-GRU 모델의 세부 구조이다. 성능 비교를 위해 LSTM, GRU 모두 동일한 구조와 학습 파라미터로 설정하였다. 입력 데이터는 그림 10과 같이 배터리 충·방전 사이클에 따라 전처리된 2차원 데이터이다. 최적화 방법은 Adam을 사용하였으며, 초기 학습률은 0.01로 설정하여 학습 과정 중 조정한다. 손실 함수는 평균 제곱 오차 (RMSE)를 사용한다.

5.2 추정 모델 성능

모델 간의 성능 비교는 평균 절대 오차 (Mean Absolute

표 2 하이퍼 파라미터

Table 2 Hyper Parameter

Item	Value
Learning rate	0.01
Epochs	400
Loss function	RMSE

표 3 CNN-GRU 모델의 세부 구조

Table 3 Detailed Structure of CNN-GRU Model

Item	Value		
	Filter Size	Stride Size	Units
Conv.1	58 x 2	(1, 1)	20
Conv.2	20 x 2	(1, 1)	20
GRU (LSTM)	-	-	128
Fully Connected	-	-	1

Error), 평균 제곱 오차 (Root Mean Square Error)를 사용하였다. 동일 단위 내에서 비교 수행하였으며, 결과는 표 4와 같다. 추정 모델별 MAE는 0.0126으로 CNN-GRU의 성능이 가장 우수하다.

표 4 학습 모델별 성능 비교

Table 4 Performance comparison by learning model

학습 모델	MAE	RMSE
CNN-GRU	0.0126	0.0161
LSTM	0.0239	0.0352
GRU	0.0239	0.0350

그림 11은 테스트 데이터 세트를 학습된 모델의 입력으로 활용하여 예측된 배터리의 SOH를 나타내고 있다. 테스트 데이터 세트는 전처리 과정 중 획득한, 633개의 데이터 중 10%를 랜덤으로 추출하였다.

표 5 학습 모델별 최대 오차를 가지는 테스트 데이터

Table 5 Test data with maximum error per learning model

학습 모델	테스트 데이터 번호	시험 그룹	Cell ID	Error(%)
CNN-GRU	39	I-10	Inst1-11	4.8
LSTM	42	I-10	Inst1-11	12.3%
GRU	42	I-10	Inst1-11	12.2%

본 논문에서 제안하는 CNN-GRU 모델의 경우 63개의 데이터 세트 중 58개의 데이터 세트에서 3% 이내의 SOH를 예측하였다. 동일 기준으로 LSTM은 51개를 예측하였으며 GRU의 경우 47개를 예측하여, 제안한 CNN-GRU 모델의 예측 성능이 가장 우수함을 확인하였다. CNN-GRU의 성능이 LSTM, GRU 대비 우수한 이유는 2차원 구조를 가지는 데이터 세트에 의한 영향이 가장 큰 것으로 보인다. CNN-GRU의 경우 2차원 구조의 데이터를 CNN의 입력 데이터로 직접 활용할 수 있다. 이




그림 11 학습 모델에 따른 SOH 추정 성능 비교

Fig. 11 Comparisons of SOH estimation performance between learning models

를 통해 실제 측정 데이터의 비선형적인 특징을 추출하고 이를 GRU의 입력으로 활용한다. LSTM과 GRU의 경우에는 학습을 위해 2차원 데이터를 1차원 데이터 변환하는 과정이 요구되며, 이로 인해 데이터 세트의 특성이 제대로 반영하지 못하여 성능 저하가 발생한 것으로 판단된다.

학습 모델별 가장 큰 오차와 이에 따른 테스트 데이터 정보, Cell ID 정보는 표 5를 통해 확인할 수 있다. 가장 큰 오차를 보이는 데이터 번호는 학습 모델에 따라 차이가 있으나, 동일 Cell ID인 Inst-11에서 추출된 데이터 활용 시 가장 큰 오차가 발생하였다. 이러한 오차 발생 원인으로 대부분의 데이터 구성이 충·방전 사이클 2,000회 또는 SOH 80% 대역으로 구성되어 SOH 60% 대역의 데이터가 부족하여 발생한 것으로 판단된다. 그러나, 제안하는 CNN-GRU의 구조의 경우 학습 데이터가 적은 상황에서도 LSTM, GRU 대비 높은 성능을 보여준다.

표 4에 따르면, LSTM과 GRU의 추론 성능은 유사한 수준의 성능을 보인다. 학습 매개변수의 개수가 LSTM은 약 77 만개, GRU는 약 58 만개이다. GRU는 적은 매개변수로 LSTM과 유사한 수준의 성능을 보인다. 즉, 학습 데이터가 충분하지 않은 상황에서는 LSTM 대비 GRU 활용이 더 적합함을 확인하였다.

배터리 SOH의 변화는 충·방전 사이클 이외에도 충·방전 중 주변 환경 및 온도에 의한 영향이 크다. 표 1에서 확인할 수 있듯, 각 그룹은 다른 온도 조건과 DoD 조건을 가지고 있다. 본 논문에서 제안하는 학습 데이터 구조의 경우 이러한 주변 온도 및 DoD 조건을 포함하지 않음에도, 내부 파라미터의 변화 특성으로 SOH 추정이 가능함을 확인하였다.

5. 결론

본 논문에서는 랜들스 모델을 기반으로 측정된 배터리 내부 파라미터를 CNN-GRU로 학습하여, 배터리의 SOH를 추정하는 기법을 제안하였다. 배터리 내부 파라미터와 SOH는 비선형적인 관계를 가지고 있으며, 배터리 사용 시간 및 운용 특성에 따라 변화하는 시계열 특성도 가지고 있다. 이에 따라 제안한

신경망 학습 모델은 배터리의 운용 특성과 운용 시간에 따라 비선형적으로 변화하는 내부 파라미터 특성을 추출하고, 장기적인 시계열 데이터를 학습할 수 있는 구조를 가지고 있다. 제안한 신경망 모델의 타당성을 검증하기 위해, 18650 NMC 811 배터리의 실제 측정 데이터 세트를 학습, 검증, 시험데이터로 나누어 적용하였다. 또한, 제안한 신경망 학습 모델의 성능 비교를 위해 LSTM과 GRU도 동일한 학습 데이터, 하이퍼 파라미터 및 세부 구조로 학습을 수행하여 성능을 비교하였다. CNN-GRU와 LSTM, GRU 간 추론 성능은 큰 차이를 보였으며, 학습 데이터 구조를 비롯하여 비선형적인 변화 특징에 대한 학습 가능 여부에 따른 성능 차이가 발생하였다. CNN-GRU 모델의 경우 배터리 수명 임계점인 SOH 80% 이상에서는 3.5% 이내의 추정 결과를 보였다. 또한, 배터리 셀에 따라 주변 온도 및 DoD와 같은 충·방전 조건 차이가 존재하였으나 내부 파라미터의 변화만으로도 높은 수준의 정확도를 가진 SOH를 추정할 수 있음을 입증하였다. 이를 통해 제안된 모델의 타당성 성능을 입증하였다.


Acknowledgements

This work was supported by the Korea Institute of Energy Technology Evaluation and Planning(KETEP) and the Ministry of Trade, Industry & Energy(MOTIE) of the Republic of Korea (No. 20206910100160, No. 20225500000110)

References

- [1] H. S. Lim, J. S. Yun, and K. B. Lee, "State estimation of LiFePO4 battery using a Linear Regression Analysis," The Korean Institute of Power Electronics, The Transactions of Korean Institute of Power Electronics, vol. 71, no. 2, pp. 366-374, Feb. 2022.
- [2] S. H. Lee, J. Y. Cha, S. Cho, S. S. Cho, and K. B. Lee, "Smart Inverter," Munundang, 2021, ISBN 979-11-5692-584-2.
- [3] P. Y. Lee, S. U. Kwon, D. H. Kang, S. Y. Han, and J. H. Kim, "SOH Estimation and Feature Extraction using Principal Component Analysis based on Health Indicator for High Energy Battery Pack," The Korean Institute of Power Electronics, The Transactions of Korean Institute of Power Electronics, vol. 25, no. 5, pp. 376-384, Oct. 2020.
- [4] P. Y. Lee, S. U. Kwon, D. H. Kang, S. Y. Han, and J. H. Kim, "SOH Estimation and Feature Extraction using Principal Component Analysis based on Health Indicator for High Energy Battery Pack," The Korean Institute of Power Electronics, The Transactions of Korean Institute of Power Electronics, vol. 25, no. 5, pp. 376-384, Oct. 2020.
- [5] N.A. Z R-Smith, M. Ragulskis, M. Kasper, S. Wagner, J. Pumsleitner, B. Zollo, A. Groebmeyer, and F. Kienberger "Multiplexed 16 × 16 Li-Ion Cell Measurements Including Internal Resistance for Quality Inspection and Classification," IEEE Transactions on Instrumentation and Measurement, vol. 70, pp. 1-9, Aug. 2021.
- [6] W. S. Choi, H. C. Shin, J. M. Kim, J. Y. Choi, and W. S. Yoon, "Modeling and Applications of Electrochemical Impedance Spectroscopy (EIS) for Lithium-ion Batteries," The Korean Electrochemical Society, Journal of electrochemical science and technology, vol. 11, no. 1, pp. 1-13, Jan. 2020.
- [7] Y. H. Choi, S. H. Ryu, K. N. Park, and H. S. Kim, "Machine Learning-Based Lithium-Ion Battery Capacity Estimation Exploiting Multi-Channel Charging Profiles," IEEE Access, vol 7, pp. 75143-75152, Jun. 2019.
- [8] S. R. Hong, M. Kang, H. G. Jeong, J. B. Baek, J. H. Kim, "State of Health Estimation for Lithium-Ion Batteries Using Long-term Recurrent Convolutional Network," The Korean Institute of Power Electronics, The Transactions of Korean Institute of Power Electronics, vol. 26, no. 3, pp. 183-191, Mar. 2021.
- [9] L. Ungurean, M. V. Micea, and G. Carstoiu, "Online state of health prediction method for lithium-ion batteries, based on gated recurrent unit neural networks," International journal of energy research, Vol 44(8), pp 6767-6777.
- [10] C. H. Seng, "LiBforSecUse Data Release - Impedance spectra of life cycle tests of commercial 18650 cells," Zenodo, Mar. 22, 2022. doi: 10.5281/zenodo.6418665.

저자소개



박현룡 (Hyun-Yong Park)

He received the B.S. degree in Electronics engineering from the Chungbuk National University, Cheongju, Korea, in 2014. He has been working as a research engineer in SK Signet since 2022. He received the M.S. degree in IT convergence engineering from Ajou University, Suwon, Korea, in 2023. His research interests include EV charger, ISO 15118, IEC 61851, and battery management system for electric vehicles.

E-mail : hyunyoung1125@gmail.com



임희성 (Hee-Sung Lim)

He received the B.S. degree in Computer engineering from the Hanyang Cyber University, Seoul, Korea, in 2020. He received the M.S. degree in IT convergence engineering from Ajou University, Suwon, Korea, in 2022. He is currently working toward the Ph.D. degree in Electrical and Computer engineering from Ajou University, Suwon, Korea. His research interests include A.I. Algorithm, and Battery management systems for electric vehicle.

E-mail: bamtolwow@gmail.com



이교범 (Kyo-Beum Lee)

He received the B.S. and M.S. degrees in electrical and electronic engineering from the Ajou University, Suwon, Korea, in 1997 and 1999, respectively. He received the Ph.D. degree in electrical engineering from the Korea University, Seoul, Korea, in 2003. From 2003 to 2006, he was with the Institute of Energy Technology, Aalborg University, Aalborg, Denmark. From 2006 to 2007, he was with the Division of Electronics and Information Engineering, Jeonbuk National University, Jeonju, Korea. In 2007, he joined the Department of Electrical and Computer Engineering, Ajou University, Suwon, Korea. He is an associated editor of the IEEE Transactions on Industrial Electronics, the IEEE Transactions on Power Electronics, and the Journal of Power Electronics. His research interests include electric machine drives, renewable power generations, and electric vehicle applications.

E-mail: kyl@ajou.ac.kr