

멀티 채널 충전 프로파일과 방전 용량을 사용한 딥러닝 기반 리튬 이온 배터리 건강 상태 추정

전지훈*, 천호진*, 추용주**, 김홍석^o

Deep-Learning Based Lithium-ion Battery SOH Estimation Using Multi-Channel Charging Profile and Discharge Capacity

Ji-hun Jeon*, Ho-jin Cheon*, Yong-ju Chu**, Hong-seok Kim^o

요약

리튬 이온 배터리팩의 안전하고 효율적인 사용을 위해서는 배터리의 상태를 모니터링하는 것이 중요하다. 다양한 배터리의 상태지표 중에서도 배터리의 성능과 수명을 대표하는 SOH(State-of-Health)를 추정할 필요가 있다. 본 논문에서는 다양한 구조의 인공신경망을 사용하여 SOH를 추정하였다. SOH 추정을 위한 입력으로 배터리의 충전중 전압, 전류, 온도의 측정치를 사용하였다. 또한 방전 중에 전류적산법을 통해 추정된 배터리의 용량을 충전 중에 기록된 측정치와 함께 입력으로 사용하여 성능을 개선한 모델을 제안한다. 순방향 신경망, 합성곱 신경망, 장단기 메모리 모델의 SOH 추정 성능을 평가하였고, 방전 용량을 모델의 입력으로 사용하면 모델의 성능이 크게 향상됨을 확인하였다.

Key Words : Artificial Neural Network, BMS(Battery Management System), Deep Learning, Lithium-ion Battery, SOH(State-of-Health)

ABSTRACT

For safe and efficient use of lithium ion battery pack, it is important to monitor the states of battery. Among various states of battery, it is required to estimate SOH (State-of-Health), which represents the performance and life of battery. In this paper, we estimate SOH using various structures of artificial neural network (ANN). We use the measured voltage, current, and temperature of battery cell during charging process as a feature to estimate SOH. We also use the discharged capacity, measured by the coulomb counting method, of battery cell as the feature. We evaluate the performance of various structures of ANN such as feedforward neural network (FNN), convolutional neural network (CNN) and long short-term memory (LSTM) and confirm that the use of discharged capacity significantly improves the SOH estimation performance.

* 본 연구는 첨단연구개발처-2780(2021.11.10.) “Lab-Test용 전기자동차 배터리 수명 예측 알고리즘 개발”의 결과로 수행되었습니다.

• First Author : Sogang University Department of Electronic Engineering, jihunpower@sogang.ac.kr, 학생회원

^o Corresponding Author : Sogang University Department of Electronic Engineering, hongseok@sogang.ac.kr, 중신회원

* Sogang University Department of Electronic Engineering, kirin0608@sogang.ac.kr, 학생회원

** Shinhan University Department of Cyberdronebot, yongju.chu@o.shinhan.ac.kr

논문번호 : 202201-010-C-RU, Received March 4, 2022; Revised March 31, 2022; Accepted March 31, 2022

I. 서 론

리튬 이온 배터리는 높은 에너지 밀도, 낮은 자기방전을, 긴 수명 등의 장점이 있어 많은 분야에서 에너지 저장수단으로 사용되고 있다. 그러나 리튬 이온 배터리는 사용함에 따라 성능이 감소하며 화재 또는 폭발의 위험성을 가지고 있으므로 배터리 관리 시스템(BMS: Battery Management System)을 통해 배터리의 상태를 모니터링하는 것이 중요하다.

SOH(State-of-Health)는 리튬 이온 배터리의 성능과 수명을 반영하는 상태지표이다. SOH의 정의는 다양하나, 주로 완전히 충전된 배터리가 방전할 수 있는 방전량을 초기의 배터리가 방전할 수 있는 방전량으로 나눈 값의 백분율로 정의한다.^[1] SOH 추정을 바탕으로 배터리의 용량 뿐만 아니라 잔존 수명과 정비, 교체시기를 판단할 수 있으므로 배터리 시스템의 안전하고 효율적인 운용을 위해서는 정확한 SOH 추정 모델이 필수적이다.

SOH를 추정하기 위한 다양한 방법들이 연구되었다. 참고문헌^[2]에 따르면, SOH 추정 방법은 크게 실험적 방법, 모델 기반 방법, 데이터 기반 방법으로 나눌 수 있다. 참고문헌^[3-5]에서는 실험적 방법의 한 종류인 증분용량분석법(ICA: Incremental Capacity Analysis)을 활용해 SOH를 추정할 수 있음을 보였다. 이와 같은 실험적 방법은 계산복잡도는 낮다는 장점이 있다. 그러나 실험을 통해 데이터를 확보해야 하며, 배터리팩을 특정 조건으로 동작시켜 SOH 추정을 위한 데이터를 얻어야 한다는 불편함이 있다. 참고문헌^[6]에서는 Reduced-Order Electrochemical Model을 사용하여 리튬 이온 배터리의 용량 감소를 추정하였다. 또는 등가회로 모델(ECM: Equivalent Circuit Model)을 사용하여 SOH를 추정하기도 한다. 이러한 모델 기반의 SOH 추정 방법은 실험적 방법과 달리 온라인 추정이 가능하다는 장점을 가지지만, 계산복잡도가 높고 정확한 모델을 설계해야 한다는 어려움이 따른다.

이러한 단점들에 의해 최근에는 데이터 기반, 특히 기계학습을 활용한 SOH 추정 방법들이 연구되고 있다. 참고문헌^[7]에서는 가우시안 과정 회귀(Gaussian Process Regression) 모델을 사용해 리튬 이온 배터리의 SOH를 추정하였고, 참고문헌^[8]에서는 RVM(Relevance Vector Machine)을 사용하여 배터리의 SOH를 추정하였다. 이 방법들은 SOH를 비교적 정확하게 추정할 수는 있으나, 계산복잡도가 높아 데이터의 양이 늘어날수록 학습이 어려워진다는 단점이 있

다. 이 연구에서는 인공신경망을 활용하여 리튬 이온 배터리의 SOH를 추정하는 방법을 제안한다. 일반적인 BMS가 측정할 수 있는 수치인 전압, 전류, 온도를 인공신경망의 입력으로 사용하여 SOH를 추정하였다. 또한 전압, 전류, 온도만을 인공신경망의 입력으로 사용하였을 때의 추정 성능과 이전 사이클에서의 방전 용량을 함께 인공신경망의 입력으로 사용하였을 때의 SOH 추정 성능을 비교하였다.

II. 머신러닝 기반 접근

리튬 이온 배터리는 사용함에 따라 의도하지 않은 부반응에 의해 열화가 진행되며, 용량이 감소하고 임피던스가 증가하는 등의 변화가 나타난다. Fig. 1은 사용한 4개의 배터리에 대해서 배터리를 사용함에 따라 열화가 진행되어 용량이 감소하는 모습을 보인다. 이러한 변화는 배터리가 충전되는 동안의 배터리의 전압, 전류, 온도에도 영향을 미친다. Fig. 2는 배터리가 사용됨에 따라 충전 중 전압, 전류, 온도가 변화하는 모습을 보여준다. 참고문헌^[1]에서는 인공신경망을 사용해 충전 중 측정된 전압, 전류, 온도 데이터로부터 리튬 이온 배터리의 SOH를 추정하였다. 한편, 배터리의 SOH는 빠르고 동적으로 변화하기 보다는 배터리를 사용함에 따라 서서히 감소한다. 따라서 이전 사이클에서의 배터리의 SOH는 현재 배터리의 SOH를 추정하기에 좋은 지표이다. 이 논문에서는 배터리가 충전되는 동안 측정된 배터리의 전압, 전류, 온도

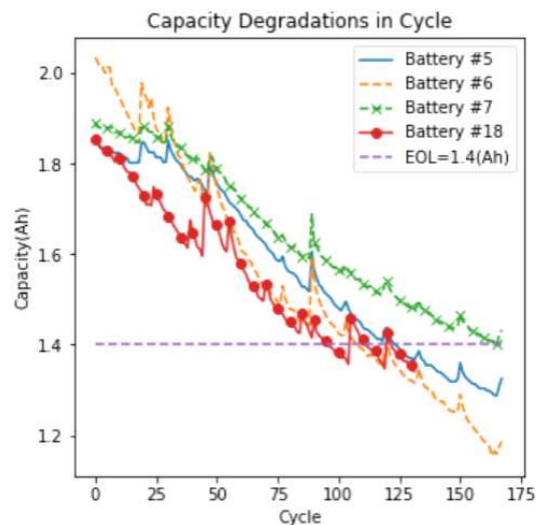


그림 1. 충전 사이클에 따른 배터리의 용량 감소
Fig. 1. Battery capacity degradations in cycle.




그림 2. 배터리 열화에 따른 충전 프로파일 변화
 Fig. 2. Changes in charging profile due to the degradation of the battery.

와 배터리가 방전되는 동안 전류적산법을 통해 구해진 배터리의 용량을 인공신경망의 입력으로 사용한다. 이렇게 학습된 모델의 SOH 추정 성능을 참고문헌^[1]의 모델과 비교하였다. 인공신경망 모델은 FNN, CNN, LSTM 구조를 사용해 설계되었다. 실험의 전반

적인 과정을 Fig. 3에 나타냈다.

2.1 배터리 데이터셋

모델 학습에 사용할 데이터로 NASA Ames PCoE의 Battery Dataset을 사용하였다.^[9] 데이터셋에서 #5, #6, #7, #18 배터리의 데이터를 사용하였다. NASA Ames PCoE의 Battery Dataset에서 배터리는 다음과 같은 조건으로 테스트되었다. 모든 배터리는 정전류-정전압 방식으로 충전되었고, 정전류 방식으로 방전되었다. 배터리의 전압이 4.2V에 도달할 때까지 1.5A의 정전류로 충전되었고 이후 충전 전류가 충전종지전류인 20mA에 도달할 때까지 4.2V의 정전압으로 충전되었다. 방전은 배터리의 전압이 방전종지전압에 도달할 때까지 2A의 정전류로 방전되었다. 모든 테스트는 24도의 상온에서 진행되었다. 배터리의 방전종지전압, 초기 용량, 실험환경 등 데이터 셋에 대한 정보를 표 1에 기록하였고 충방전 사이클에 따른 각 배터리의 용량을 그림1에 나타내었다.

2.2 데이터 전처리

배터리가 충전되는 동안 샘플링 빈도에 따라서 수십~수천 개의 전압, 전류, 온도 샘플이 기록된다. 입력 데이터가 커질수록 모델의 정확도는 높아지지만, 모델

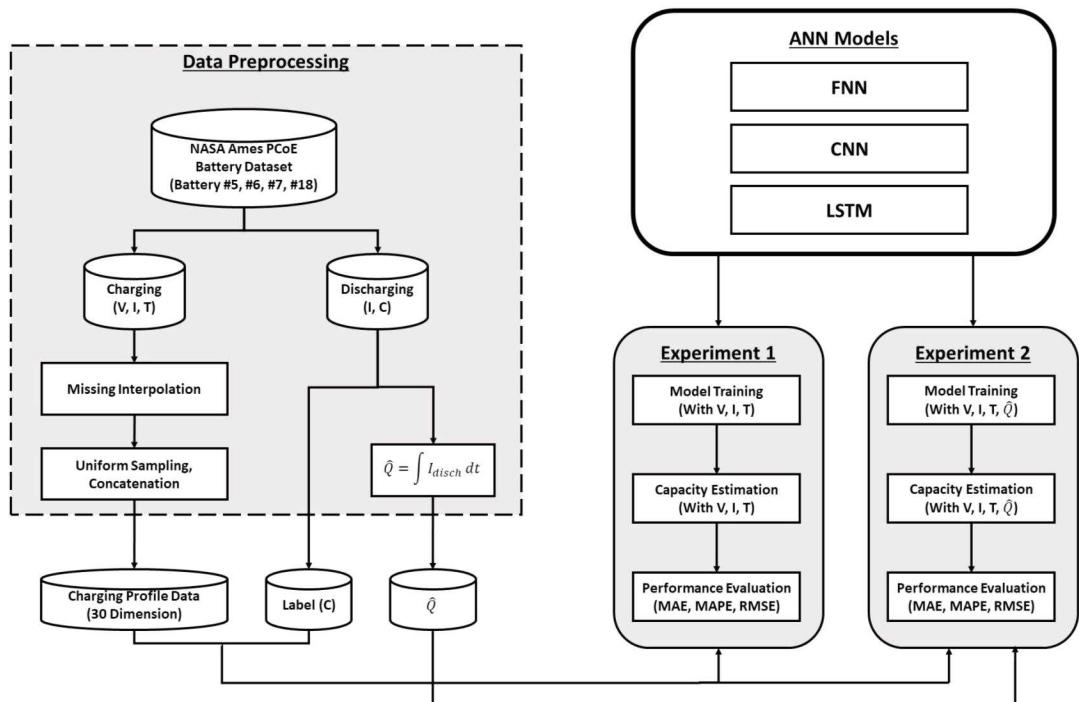


그림 3. SOH 추정 실험의 전체 과정
 Fig. 3. Entire step of SOH estimation experiment.

표 1. 각 배터리의 운용조건
Table 1. Operation conditions of each battery.

Battery no.	Charging			Discharging		Operating conditions	
	Constant current (A)	Upper voltage limit (V)	Cut-off current (mA)	Constant current (A)	Cut-off voltage (V)	Operating temperature	Initial capacity (Ah)
Battery #5	1.5	4.2	20	2	2.7	24℃	1.86
Battery #6	1.5	4.2	20	2	2.5	24℃	2.04
Battery #7	1.5	4.2	20	2	2.2	24℃	1.89
Battery #18	1.5	4.2	20	2	2.5	24℃	1.86

의 파라미터 수가 커지기 때문에 모델 학습에 소요되는 시간이 증가한다. 따라서 작은 차원의 입력 데이터를 사용할 필요가 있다. 본 논문에서는 충전중인 배터리의 전압, 전류, 온도를 균일 샘플링하여 작은 차원의 벡터로 변환하였다.

본 논문에서는 SOH 추정을 위해 두 가지의 실험을 수행하였다. <실험1>에서는 충전중의 측정치만 사용하여 SOH를 추정한다. 매 충전 사이클마다 전압, 전류, 온도로부터 각각 10개씩의 샘플을 추출하여 총 30차원의 데이터를 인공신경망 모델의 입력으로 사용하였다. 30개의 샘플은 충전중인 배터리의 전압, 전류, 온도를 시간 축에서 동일한 간격의 10개의 구간으로 분할하고, 각 구간에서 측정치의 평균을 계산하여 얻었다.^[1]

<실험2>에서는 충전중의 측정치와 방전중의 전류를 사용하여 SOH를 추정한다. 실험 1에서 사용한 30차원의 데이터에 방전 용량의 추정치를 더한 31차원의 데이터를 인공신경망 모델의 입력으로 사용하였다. 방전 용량의 추정값은 방전중 측정된 전류를 시간에 대해 적분하여 얻었다. (1) <실험2>에서는 위 방법을 통해 충전중, 방전중의 측정치를 모두 고려하여 SOH 추정의 정확도를 <실험1>에서보다 향상시키고자 한다.

2.3 모델 구조

2.3.1 순방향 신경망 (FNN)

FNN은 가장 단순한 인공신경망 구조로 입력층, 은닉층, 출력층을 갖는다. 데이터는 입력층에서 은닉층을 거쳐 출력층으로 한 방향으로만 전달되며 순환 구조는 갖지 않는다. 본 논문에서는 40개 노드를 포함하는 하나의 은닉층을 가진 순방향 신경망을 사용하였다.

2.3.2 합성곱 신경망 (CNN)

CNN은 컨볼루션층을 갖는 인공신경망으로, 패턴을 잘 찾아낸다는 특징이 있어 영상, 음성 등 다양한

분야에서 사용된다. 컨볼루션층은 입력된 데이터와 커널(가중치)의 컨볼루션을 출력한다. 본 논문에서는 두 개의 1차원 컨볼루션층과 한 개의 완전 연결 층을 사용하여 CNN을 구성하였다.

2.3.3 장단기 메모리 (LSTM)

LSTM은 순환 신경망의 한 종류이다. 기본적인 순환신경망인 RNN은 긴 시퀀스를 학습할 때 기울기 소실 문제를 겪는다는 문제점이 있다. LSTM은 RNN의 기울기 소실 문제를 해결하기 위해 forget gate, input gate, output gate를 도입한 순환신경망이다.^[10] 본 논문에서는 하나의 LSTM 레이어와 하나의 완전연결층을 사용하여 LSTM 모델을 구성하였다.

각 모델의 구조와 하이퍼파라미터는 표 2에 정리된 것과 같다.

표 2. 인공신경망 모델의 하이퍼파라미터
Table 2. Hyper parameters of ANN models.

Model	Structure	Optimizer
FNN	Input-Hidden(40)-Output	Adam (lr=0.001), Batch size=1, Epoch=15
CNN	Input-Conv1-Conv2-Fc(435)-Output Conv1(1x2@30), Conv2(1x2@15), padding=0, stride=1	
LSTM	Input-LSTM-Fc(20)-Output LSTM(hidden_size=20, dropout=0.5)	

III. SOH 추정 실험

본 논문에서는 리튬 이온 배터리의 SOH 추정 실험을 위해 FNN, CNN, 그리고 LSTM의 구조로 이루어진 모델을 사용하였다.

손실함수로 평균 제곱 오차(MSE)를 사용하였으며, 안정성이 높고 빠른 학습속도를 가지는 Adam

optimizer를 학습률 0.001로 하여 학습을 진행하였다. 은닉층의 활성화함수는 ReLU를 사용하였고, 출력층에는 선형 활성화함수를 사용하였다. 과적합을 방지하기 위해 batch size는 1로 하였고 15 Epoch 학습시켰다. FNN, CNN, LSTM과 같은 딥러닝 모델의 정확성을 평가하는 지표로 평균절대비오차(MAPE) (2), 평균 절대 오차(MAE) (3), 평균 제곱근 오차(RMSE) (4)를 사용하였다.

$$MAPE(\%) = \frac{100}{K} \sum_{k=1}^K \frac{|C(k) - \hat{C}(k)|}{C(k)} \quad (2)$$

$$MAE = \frac{1}{K} \sum_{k=1}^K |C(k) - \hat{C}(k)| \quad (3)$$

$$SE = \sqrt{\frac{1}{K} \sum_{k=1}^K |C(k) - \hat{C}(k)|^2} \quad (4)$$

여기서 $C(k)$ 와 $\hat{C}(k)$ 는 k번째 사이클에서 배터리의 실제 용량과 모델이 추정한 용량을 의미한다.

네 개 배터리의 데이터 중 한 개 배터리의 데이터를 테스트용으로 사용하고 나머지 세 개 배터리의 데이터를 학습용으로 사용하였다. 각 배터리의 데이터를 한 번씩 테스트용 데이터로 사용하여 실험을 총 네 번 수행하였고, 네 번의 실험에서 얻어진 오차의 평균을 표 3과 표 4에 기록하였다.

표 3. 배터리 용량 추정 오차 (실험 1)
Table 3. Battery capacity estimation error. (Experiment 1)

Model	MAPE(%)	MAE	RMSE
FNN	3.1511	0.0502	0.0811
CNN	4.3017	0.0675	0.0851
LSTM	3.5787	0.0557	0.0667

표 4. 배터리 용량 추정 오차 (실험 2)
Table 4. Battery capacity estimation error. (Experiment 2)

Model	MAPE(%)	MAE	RMSE
FNN	2.0322	0.0306	0.0412
CNN	4.2659	0.0651	0.0739
LSTM	0.9517	0.0148	0.0220

IV. 실험 결과

4.1 실험 1

Fig. 4에서 <실험1>의 배터리의 충전 사이클에 따른 추정된 SOH 및 실제 SOH를 보여준다. 성능 분석을 위해 표3에 모델별 SOH 추정 오차를 나타내었다. 학습된 모델은 SOH 감소의 전반적인 추세를 포착하였다. 하지만 추정값이 진동하거나 편향된 추정을 하는 모습을 보였다. FNN, CNN, LSTM 모델의 추정 오차는 MAPE 기준 각각 3.15%, 4.30%, 3.58%로, FNN, LSTM, CNN 순으로 성능이 좋았다.

4.2 실험 2

Fig. 5에서 <실험2>의 배터리의 충전 사이클에 따른 추정된 SOH 및 실제 SOH를 보여준다. 성능 분석을 위해 표4에 모델별 추정 오차를 나타내었다. <실험2>의 모든 모델은 <실험1>에서보다 더 낮은 SOH 추정 오차를 보였고, 방전 용량의 추정치를 입력에 사용함으로써 SOH 추정 성능이 개선됨을 확인하였다. 배터리의 SOH는 연속적으로 변화하는 값이기 때문에, 직전 사이클의 배터리의 용량이 배터리의 현재 SOH를 추정하기에 좋은 지표가 되었기 때문이다. 그림[6]에서 이전 사이클의 SOH와 현재 사이클의 SOH에 높은 상관관계가 있음을 알 수 있다.

특히 LSTM 기반 모델의 경우 MAPE(%) 기준 0.95%의 오차율로 SOH 추정 성능이 가장 크게 개선되었고, 실험에 사용한 모든 배터리의 열화를 정확하게 포착하였다. LSTM 모델의 성능이 다른 모델에 비해서 성능 향상이 큰 이유는 LSTM 기반 모델이 시계열 데이터 분석에 큰 강점이 있어 이전 사이클 데이터의 시간적 변화를 더욱 잘 포착해 냈기 때문이다.

4.3 배터리 충전 프로파일의 변화

Fig. 4, Fig. 5에서 #18 배터리의 44번째 사이클에서 FNN, CNN 기반 모델의 추정 결과가 기존의 추세에서 이탈하는 큰 오차를 보였다. 이는 44사이클을 기준으로 배터리의 충전 프로파일에 변화, 즉 전환점이 발생했기 때문이다. Fig. 6은 매 사이클마다 추출한 10개 샘플의 전압 데이터를 나타내는 그림이다. Fig. 6를 살펴보면 44사이클 이후 충전 프로파일 전압이 샘플마다 순간적으로 강하한 모습을 보인다. 44사이클 이후 다시 변경된 충전 프로파일로 작동하는 모습을 확인 할 수 있다. 이러한 충전 프로파일 변화에도 불구하고 LSTM 기반의 모델은 전환점에 의한 전압 강하도 포착하여 정확하게 추정하는 모습을 보인다.

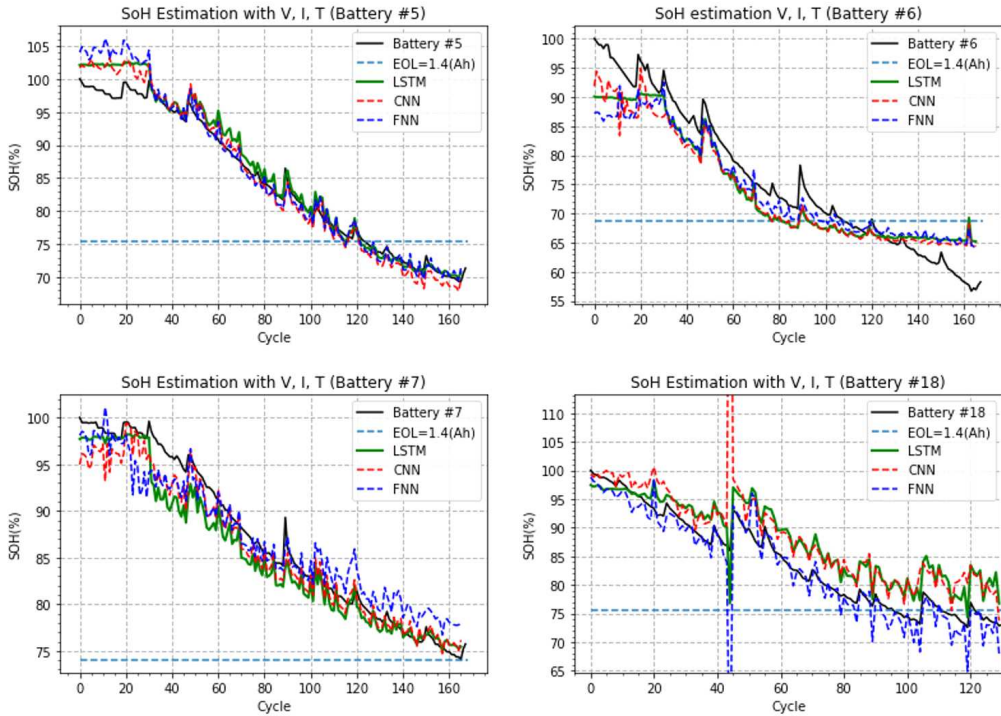


그림 4. 실험 1의 SOH 추정 결과
Fig. 4. SOH estimation results of experiment 1.

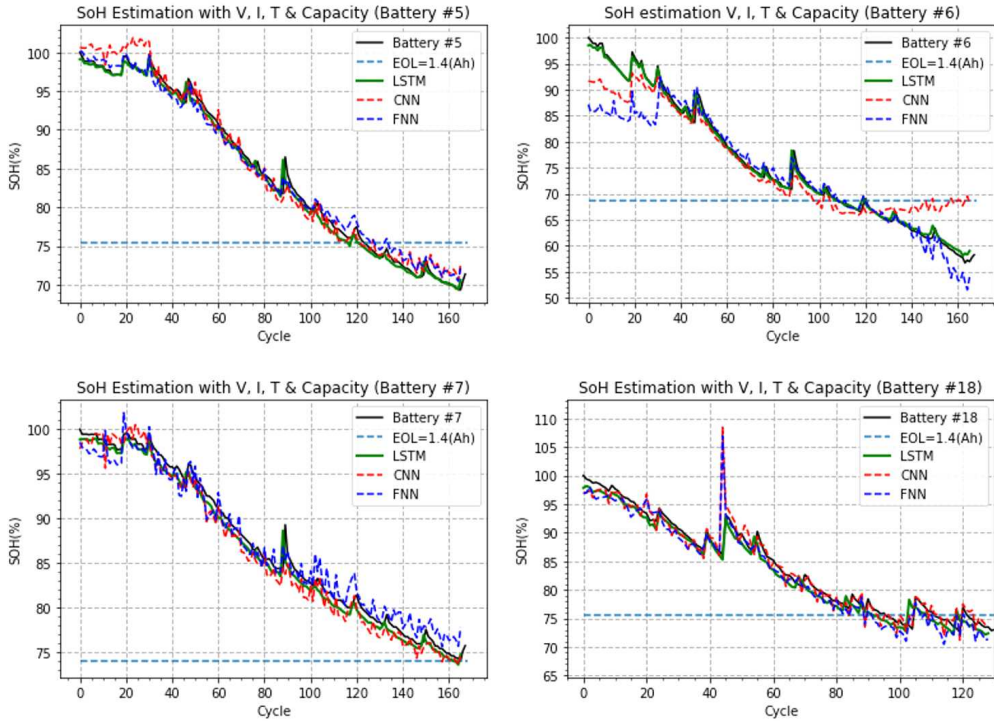


그림 5. 실험 2의 SOH 추정 결과
Fig. 5. SOH estimation results of experiment 2.




그림 6. 직전 사이클의 SOH와 현재 사이클의 SOH의 산점도
Fig. 6. Scatter plot of SOH of previous cycle and current SOH.




그림 7. 배터리 #18의 충전 프로파일 변화
Fig. 7. Transition of charging profile of Battery #18.

V. 결론

본 논문에서는 리튬 이온 배터리의 SOH를 추정하기 위한 두 가지 실험을 수행하고 결과를 비교하였다. <실험1>에서는 충전중의 전압, 전류, 온도 측정치를

균일 샘플링하여 얻은 30차원의 데이터로 배터리의 SOH를 추정하였고, <실험2>에서는 <실험1>에서 사용한 30차원의 데이터에 방전 전류를 시간에 대해 적분하여 얻은 방전 용량의 추정치를 추가하여 배터리의 SOH를 추정하였다.

SOH 추정에 사용한 세 가지 모델 모두 <실험1>에 서보다 <실험2>에서 개선된 성능을 보였다. 이를 통해 이전 사이클의 배터리의 용량이 배터리의 SOH 추정에 도움이 됨을 보였다. SOH 추정 오차가 감소하였으며, 추정값이 진동하는 현상도 크게 줄어들었다. 특히 LSTM 모델의 성능 향상폭이 가장 컸고, LSTM 모델을 사용해 MAPE 0.95%로 SOH를 정확하게 추정하였다.

저자는 <실험1>과 <실험2>의 비교를 통해 충전중의 데이터 뿐만 아니라 방전중의 데이터를 함께 사용하여 SOH 추정 성능을 향상시킬 수 있음을 보였다. 또한 제안된 방법으로 모델을 학습시켰을 때 LSTM 모델이 다른 모델에 비해 높은 성능을 보인다는 것을 검증하였다.

References

- [1] Y. Choi, S. Ryu, K. Park, and H. Kim, "Machine learning-based lithium-ion battery capacity estimation exploiting multi-channel charging profiles," *IEEE Access*, vol. 7, pp. 75143-75152, Jun. 2019.
- [2] S. Park, et al., "Review of state-of-the-art battery state estimation technologies for battery management systems of stationary energy storage systems," *J. Power Electron.*, vol. 20, pp. 1526-1540, Aug. 2020.
- [3] C. Weng, et al., "On-board state of health monitoring of lithium-ion batteries using incremental capacity analysis with support vector regression," *J. Power Source*, vol. 235, pp. 36-44, Aug. 2013.
- [4] D.-I. Stroe and E. Schaltz. "SOH estimation of LMO/NMC-based electric vehicle lithium-ion batteries using the incremental capacity analysis technique," *2018 IEEE ECCE*, pp. 2720-2725, Sep. 2018.
- [5] X. Li, C. Yuan, and Z. Wang, "State of health estimation for Li-ion battery via partial incremental capacity analysis based on support

vector regression,” *Energy*, vol. 203, Jul. 2020.

- [6] J. Marcicki, et al., “Nonlinear parameter estimation for capacity fade in Lithium-ion cells based on a reduced-order electrochemical model,” *2012 ACC*, pp. 572-577, Montreal, Canada, Jun. 2012.
- [7] D. Yang, et al., “A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve,” *J. Power Sources*, vol. 384, pp. 387-395, Apr. 2018.
- [8] Y. Chang and H. Fang, “A hybrid prognostic method for system degradation based on particle filter and relevance vector machine,” *Reliability Eng. & Syst. Safety*, vol. 186, pp. 51-63, Jun. 2019.
- [9] B. Saha and K. Goebel, “Battery data set,” *NASA Ames. Prognostics Data Repository*, (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), NASA Ames. Research Center, Moffett Field, CA, 2007.
- [10] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735-1780, 1997.

전 지 훈 (Ji-hun Jeon)



2021년 8월 : 서강대학교 전자공학과 졸업
 2021년 8월~현재 : 서강대학교 전자공학과 석사과정
 <관심분야> 에너지 공학, 배터리 AI, 인공지능
 [ORCID:0000-0003-4886-7239]

천 호 진 (Ho-jin Cheon)



2022년 2월 : 서강대학교 전자공학과 졸업
 2022년 2월~현재 : 서강대학교 전자공학과 석사과정
 <관심분야> 에너지 공학, 배터리 AI, 인공지능
 [ORCID:0000-0002-5285-349X]

추 용 주 (Yong-ju Chu)



2007년 2월 : 고려대학교 기계공학과 석사
 2019년 2월 : 서강대학교 기계공학과 박사
 2010년 2월~2019년 9월 : 한국자동차연구원 선임연구원
 2020년 7월~2022년 3월 : 한국교통안전공단 첨단기술연구센터 과장
 2022년 3월~현재 : 신한대학교 사이버드론봇 교수
 <관심분야> 실차 주행 성능 검증, 인공지능, 이미지 프로세싱,
 [ORCID:0000-0001-5511-8629]

김 흥 석 (Hong-seok Kim)



2000년 2월 : 서울대학교 전기공학부 석사
 2009년 12월 : 서울대학교 전기공학부 박사
 2011년 9월~현재 : 서강대학교 전자공학과 교수
 <관심분야> 전자공학, 에너지 공학, 인공지능
 [ORCID:0000-0002-5744-2358]