

# 배터리 DOD 조건에 따른 전이학습 기반 배터리 SOH추정 모델 설계

하태빈\*, 이상력\*, 한동호\*, 김종훈\*  
 충남대학교 에너지저장변환연구실\*

## A transfer learning based Estimating the battery SOH in battery DOD condition

Taebin Ha\*, Sangryuk Lee\*, Dongho Han\*, Jonghoon Kim\*  
 Energy Storage and Conversion Lab, Chungnam National University\*

### ABSTRACT

현재 에너지 저장 장치(Energy Storage System; ESS)의 국·내외 시장이 성장하고 있다. 이에 따라 주 전원인 리튬이온 배터리(Lithium-ion battery; LIB)에 대한 건강 상태(State-of-health; SOH)추정은 필수 요소이다. 그러나 운용 조건이 다양한 ESS에 대한 SOH 추정을 위한 데이터수집 및 처리 과정은 시간과 비용 측면에서 비효율적이다. 따라서 본 논문에서는 리튬이온 배터리의 DOD(Depth of Discharge)조건에 따른 열화 데이터를 통해 건전성 지표 추출 후 SOH 추정 모델을 설계한다. 다른 조건에서는 데이터 일부만 학습데이터로 이용해 전이학습을 통한 SOH를 추정하였다.

### 1. 서론

리튬이온 배터리의 사용량이 급증하게 되면서 배터리 SOH 추정을 통해 적절한 관리가 요구된다. ESS는 운용 목적에 따라 주파수 조정용 ESS, 신재생 에너지 연계용 ESS, 가정용 소형 ESS로 나뉜다. 계통 안정화에 이용되는 주파수 조정(Frequency Regulation; FR) ESS 경우에는 30%의 작은 DOD에서 운용되고 태양광 연계용 ESS의 경우 DOD를 최대 95%까지 활용한다. 또한 ESS를 이용하는 목적에 따라 DOD, C-rate, SOC 등 운용조건이 달라 각각에 맞는 SOH 추정 모델이 필요하다. 그러나 새로운 운용조건에서 SOH 추정을 위한 데이터 수집은 시간 및 비용 측면에서 비효율적이다. 따라서 본 논문은 리튬이온 배터리의 DOD에 대한 세 가지 운용 조건인 DOD Low(20%), DOD Middle(50%), DOD High(80%)를 수립 후 열화 실험을 진행한다. DOD 조건 별 열화 데이터에서 전압 정보를 활용하여 배터리의 건강 상태를 대변할 수 있는 건전성 지표(Health indicator; HI)를 추출 후 DOD High 조건에서 장단기 메모리(Long Short-Term Memory; LSTM)를 활용해 SOH추정 모델을 설계한다. DOD Low, DOD Middle 조건은 열화 데이터 초기 5%만 이용하여 전이학습(Transfer Learning; TL)기반 SOH 추정 모델을 설계하고 같은 열화 데이터의 초기 5%의 학습데이터로 학습된 LSTM 모델을 설계 후 비교 분석하여 전이학습 모델의 우수성을 검증한다.

### 2. 전이학습 모델 설계

#### 2.1절 배터리 셀 열화 시험

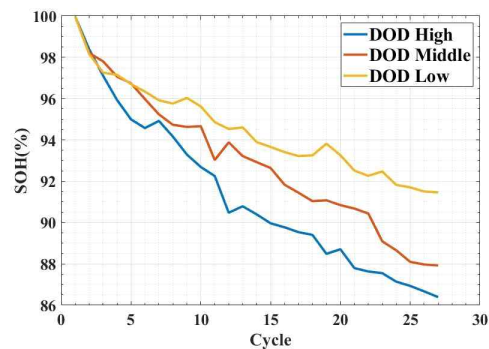


그림 1 DOD 조건별 용량 변화 그래프  
 Fig. 1 Capacity graph to DOD conditions

배터리 셀의 열화 실험은 INR21700-33J 배터리를 사용하여 항온 챔버를 통해 상온(25°C)에서 진행하였다. 실험 진행 순서는 Cap test (1회)-Aging test(50회)를 총 27회 반복하였다. Aging test에서의 SOC Range는 Low(80~100%), DOD M(50~100%), DOD H(20~100%)이며 C-rate는 1C로 고정하여 진행하였다. Reference 데이터 확보를 위한 Cap test에서는 정전류-정전압(Constant current-Constant voltage; CC-CV) 충전 및 정전류(Constant current; CC) 방전, 충전과 방전 사이에 휴지 1시간을 적용하였다. DOD 조건별 용량 변화는 그림1에 나타내었다.

#### 2.2절 건전성 지표 추출 및 데이터 보간

건전성 지표는 방전 전압에 따른 시간변화를 나타내는 TIEDVD(Time interval of equal discharge voltage difference)는 3.6V~4.0V 구간에서 추출하였다. 일정 방전 시간에 따른 전압 변화를 나타내는 VIEDTD(Voltage interval of equal discharge time difference)는 3.6V에서 60초 간격으로 추출하였다. 완전 충전 전압과 방전 시 전압 차의 평균값인 MVF(Mean voltage falloff)는 3.6V에서 200초에서 추출하였다. 추출한 건전성 지표와 SOH의 상관계수는 표 1에 나타내었다. 또한 학습데이터 확보를 통한 성능 향상을 위해 용량 데이터 및 건전성 지표의 데이터의 중간 지점마다 선형 보간법(linear interpolation)을 이용하여 데이터를 추가한다.

표 1 건전성 지표 상관분석  
 Table 1 Analysis of HI

	TIEDVD	VIEDTD	MVF
DOD H	0.9942	-0.9874	0.9714
DOD M	0.8675	-0.8837	0.9881
DOD L	0.9746	-0.9598	0.9718

### 2.3절 전이학습 모델 설계

보유 데이터의 크기가 작을 때, 모델은 과적합 및 성능 저하의 위험이 있다. 전이학습은 보유 데이터의 크기가 제한적인 상황에서 문제를 해결할 수 있는 효과적인 방법이다. 사전에 학습된 Pretrain-model의 가중치를 활용함으로써 데이터수집의 시간 및 비용을 절약함과 동시에 높은 성능을 도출할 수 있다.

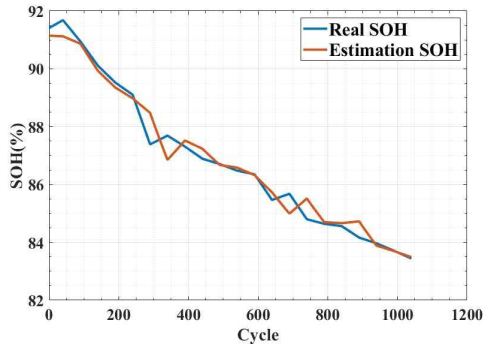


그림 2 Pretrain-model - SOH 추정 그래프  
Fig. 2 Pretrain-model - SOH Estimation graph

표 2 SOH추정모델 성능평가지표  
Table 2 SOH Estimation Performance

MAE	MSE	RMSE	R2
0.2092	0.0807	0.2843	0.9857

Pretrain-model은 DOD High 조건의 열화 데이터로 장기의존성 학습이 가능한 장단기 메모리(Long Short - Term Memory; LSTM)을 이용하여 Pretrain-model의 성능을 확보하였다. 이는 표 2에 나타내었다.

Pretrain-model은 두 개의 LSTM Layer와 두 개의 드롭아웃(Dropout) Layer, 한 개의 완전 연결층(Dense Layer)로 구성되어 있다. 하이퍼파라미터는 베이지안 최적화를 이용하여 unit 81, dropout 0.39, learning rate 0.0056로 구성하였다. 과적합 방지를 위해 Early stopping 이용하여 Epoch 10, Batch size 1로 학습하였다. 미세조정(fine tuning) 과정에서 추가로 완전 연결층을 추가하였고 동결시키지 않은 완전 연결층의 가중치를 크게 손상 시키지 않기 위해 Epoch는 1로 하였다.<sup>[1][2]</sup> 이는 그림 3에 나타내었다.




그림 3 전이학습 모델 개략도  
Fig. 3 Schematic of Transfer Learning model

### 2.4절 결과 분석 및 비교

전이학습 모델의 성능을 검증하기 위해 열화데이터 초기 5%의 데이터로 학습한 LSTM-SOH 추정모델을 설계하여 비교 분석하였다. 이는 그림 4, 5를 통해 나타내었다. 성능 평가를 위해 오차값을 기반으로하여 0에 가까울수록 높은 성능을 나타내는 MAE, MSE, RMSE와 1에 가까울수록 높은 성능을 나타내는 결정계수  $R^2$ 를 사용하였다. 결과는 표 3을 통해 나타내었다.

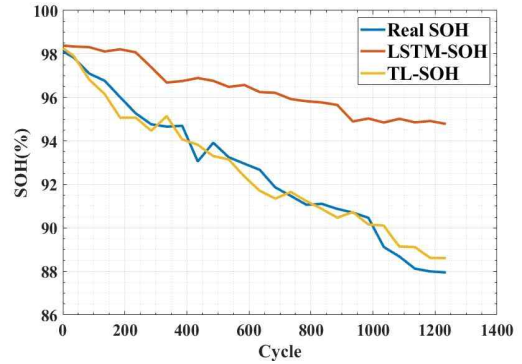


그림 4 SOH 추정모델 결과비교 - DOD Middle  
Fig. 4 Comparison of SOH Estimation - DOD Middle

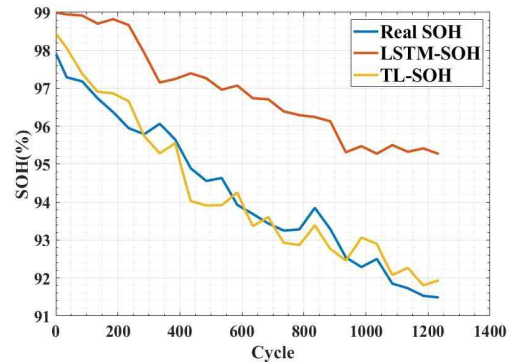


그림 5 SOH 추정모델 결과비교 - DOD Low  
Fig. 5 Comparison of SOH Estimation - DOD Low

표 3 SOH추정 성능평가 비교  
Table 3 Comparison of SOH Estimation Performance

	MAE	MSE	RMSE	$R^2$
TL- M	0.3973	0.2332	0.4829	0.9713
LSTM -M	4.2164	20.6127	4.5401	-1.5286
TL- L	0.3805	0.1993	0.4464	0.9380
LSTM -L	1.6808	3.1237	1.7674	0.0285

### 3. 결론

본 논문은 운용조건의 다양화로 인해 보유 데이터가 제한적인 상황에서 전이학습을 기반한 SOH추정 모델을 설계하였다. Pretrain-model의 가중치를 동결하고 완전 연결층을 추가하여 미세조정 함으로써 비교군인 LSTM-SOH모델 보다 성능이 우수한 것을 확인하였다. 향후 연구에는 SOC, C-rate 등 운용조건을 추가하여 연구를 진행 할 예정이다.

본 논문은 현대자동차(모델 융합형 기술 기반 배터리 상태 진단 기술 고도화 개발)와 2021년도 정부(산업통상자원부)의 재원으로 한국에너지기술연구원(No. 20210501010020, MMC타입 ESS 및 재생에너지 연계 고압형 허브스테이션 핵심기기 개발)의 지원을 받아 수행되었음.

### 참고 문헌

- [1] Tan, Y., & Zhao, G. (2019). Transfer learning with long short-term memory network for state-of-health prediction of lithium-ion batteries. *IEEE Transactions on Industrial Electronics*, 67(10), 8723-8731.
- [2] Shen, S., Sadoughi, M., & Hu, C. (2019, June). Online estimation of lithium-ion battery capacity using transfer learning. In *2019 IEEE Transportation Electrification Conference and Expo (ITEC)* (pp. 1-4). IEEE.