

# State of Power(SOP)를 이용한 CNN-Transformer 기반 리튬 이온 배터리 State of Health(SOH) 추정 및 영향 분석

최우주, 원도연, 김선혁  
국립공주대학교

woozoo1007@smail.kongju.ac.kr, onehdus@gmail.com, seonh@kongju.ac.kr

## State of Health (SOH) Estimation and Impact Analysis of Lithium-ion Batteries Based on CNN-Transformer Using State of Power (SOP)

Woo Ju Choi, Do Yeon Won, Seon Hyeog Kim  
Kongju National University

### 요약

본 논문은 리튬 이온 배터리의 State of Health(SOH) 추정을 위해 State of Power(SOP) 지표를 활용한 CNN-Transformer 하이브리드 모델을 제안한다. 기존의 전압강하( $V_{drop}$ ), 방전 종료 시점( $V_{end}$ ), 충분 용량(IC) 지표와 SOP의 추정 성능을 비교 분석하였으며 10 회의 실험을 통한 평균값으로 비교 분석하였다. 실험 결과 SOP 기반 모델이 모든 배터리 유닛에서 가장 우수한 성능을 기록하였으며 평균 RMSE(Root Mean Square Error)는 1.0365로 타 지표 대비 낮은 오차율을 보였다.

### I. 서론

전기자동차(EV) 및 에너지 저장 시스템(ESS) 시장의 확대로 배터리 관리 시스템(BMS) 내 State of Health(SOH) 추정 기술의 중요성이 증가되고 있다. 기존 연구들은 전압 강하( $V_{drop}$ ), 방전 종료 전압( $V_{end}$ ), 혹은 충분 용량(IC) 분석을 특정 인자로 활용해 왔다. 이러한 지표들은 배터리 내부 저항 증가나 열화 상태 파악에 유용한 정보를 제공하지만 내부의 복잡한 화학적 퇴화와 출력 성능 저하를 동시에 반영하기 어렵다는 한계가 있다. 따라서 본 연구에서는 배터리의 출력을 보여주는 State of Power(SOP) 지표를 제안하며 배터리 데이터의 미세한 변화 패턴 포착에 강한 CNN과 시간적 노화 흐름을 학습하는 Transformer를 결합한 모델을 설계한다. 또한 SOP를 포함한 4 가지 인자를 사용해서 SOH를 예측하여 정확도를 향상하고자 한다[1].

### II. 본론

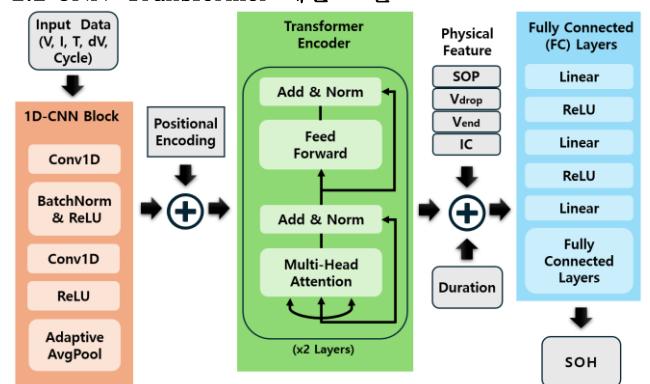
#### 2.1 SOH 추정 정밀도를 위한 여러 특징 인자 분석

본 연구에서는 NASA Ames 연구소의 B0005, B0006, B0007, B0018 배터리 데이터셋을 활용하였다[2]. 방전 사이클 데이터( $V$ ,  $I$ ,  $T$ )를 100 개 포인트로 선형 보간하여 균일화하였으며,  $dV$ 와 Cycle을 포함한 5 채널 시퀀스로 구성하였다. 또한 방전 지속 시간(Duration)을 공통 입력 이자 물리적 특성으로 사용하였다. 핵심 지표인 SOP는 배터리 노화에 따른 내부 저항 증가와 가용 출력 감소를 모델 학습에 투영하기 위해 평균 전력을 식 (1)과 같이 산출하여 별도의 물리적 인자로 활용하였다. 여기서  $V_k$ 와  $I_k$ 는 각 샘플링 시점의 값이며  $N$ 은 전체 샘플 수이다.

$$SOP = \frac{1}{N} \sum_{k=1}^N (V_k \times I_k) \quad (1)$$

또한 비교 분석을 위해 세 가지 지표를 활용하였다. 내부 저항 증가에 따른 출력 성능 저하를 반영하는 전압강하, 방전 종료 전압에 도달할 때 까지의 사이클 특성으로 용량 변화에 대한 추세를 나타내는 방전 종료시점 전압, 전압 변화에 따른 용량 변화량으로 배터리의 화학적 노화를 보여주는 충분 용량 지표를 대조군으로 선정하였다. 이는 물리 특징(Physical Feature)으로 입력된다.

#### 2.2 CNN-Transformer 제안 모델

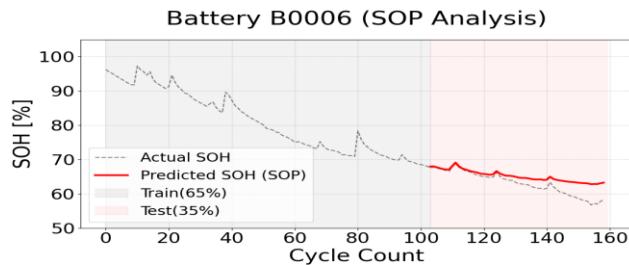


[그림 1] CNN-Transformer 모델 구조

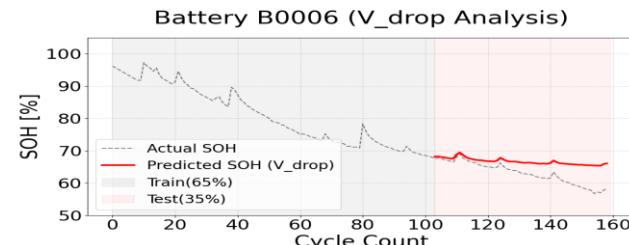
[그림 1]은 CNN-Transformer 하이브리드 모델 구조를 나타낸다. 1D-CNN Block은 입력된 5 채널 시퀀스로부터 사이클 내 특징을 추출하여 데이터를 특징 벡터로 압축한다[3]. Transformer Encoder는 추출된 특징 벡터에 위치 정보를 더한 후 멀티-헤드 어텐션(Multi-Head Attention)을 통해 사이클 간 상관관계를 학습하여 배터리 열화 추세를 파악한다[4]. Feature Fusion과 FC(Fully Connected) Layers는 학습된 시계열 특징에 물리적 인자와 방전 시간을 결합하여 정보의 밀도를 높인다. 마지막으로 3 층의 FC 레이어를 거쳐 SOH 값을 산출한다.

### 2.3 실험 환경 및 결과 분석

데이터셋을 65:35 비율로 분할하여 학습과 테스트를 진행하였으며 10 회 예측한 결과를 평균값으로 나타냈다. 특징 인자별 SOH 추정 결과는 <표 1>과 같다.

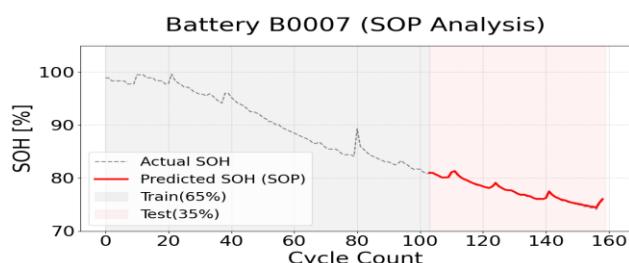


[그림 2] SOP를 이용한 SOH 예측(B0006)

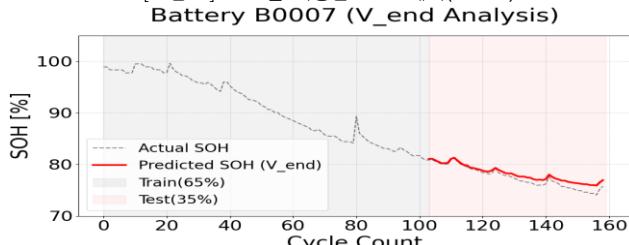


[그림 3] V<sub>drop</sub>를 이용한 SOH 예측(B0006)

B0006 배터리는 특성이 불규칙하여 모든 물리 특징에서 상대적으로 높은 오차가 발생했다. 전체적으로 실제 값보다 높게 예측하거나 용량 회복 구간의 변동성을 충분히 반영하지 못하는 한계를 보였다.



[그림 4] SOP를 이용한 SOH 예측(B0007)



[그림 5] V<sub>end</sub>를 이용한 SOH 예측(B0007)

[그림 4]는 SOP 지표를 이용했을 때 실제 SOH 와 예측 값이 거의 일치하는 모습을 보이며 특히 RMSE 0.1374라는 낮은 오차를 기록하였다. [그림 5]는 V<sub>end</sub> 지표를 이용했을 때 테스트 후반부에서 실제 용량의 하락 속도를 정확히 따라가지 못해 예측 정밀도가 0.8540에 머물렀지만 SOP를 지표로 이용했을 때 V<sub>end</sub> 대비 RMSE가 약 6 배 향상된 성능을 기록하였으며 SOP가 배터리 내부 저항의 변화를 실시간 출력 데이터로 환산하여 모델에 전달함으로써 비선형적인 노화 특성을 더 예민하게 포착했기 때문으로 분석된다.

<표 1> 배터리 별 특성에 따른 SOH 예측 결과 - RMSE(%)

배터리 특성	B0005	B0006	B0007	B0018	평균 RMSE
Vend	2.4021	4.5630	0.8540	1.2535	2.2682
Vdrop	2.3391	4.3734	0.3138	0.5568	1.8958
IC Peak	2.0087	4.7547	0.7064	1.0341	2.1260
SOP	0.9701	2.7407	0.1374	0.2976	1.0365

<표 1> 분석 결과 제안된 SOP 기반 모델이 모든 배터리 유닛에서 가장 우수한 성능을 기록하였으며, 평균 RMSE 1.0365로 타 지표 대비 낮은 오차율을 보였다.

### III. 결론

본 논문에서는 여러 물리 특징과 CNN-Transformer 하이브리드 모델로 리튬 이온 배터리의 SOH 추정 성능을 분석하였다. 실험 결과 제안한 SOP 지표가 타 지표 대비 낮은 오차를 기록함으로써 예측 정밀도를 확보하여 모델의 강건성을 입증하였다. SOP는 기존 전압 기반 지표들보다 배터리의 화학적 퇴화와 동적 출력 특성을 대변하는 인자이며 특히 용량이 불규칙하게 상승하는 비선형적 구간에서 향상된 예측 결과를 보여주며 추정 오차를 낮췄다. 다만 배터리 노화가 급격히 진행되는 구간에서의 오차가 발생한다는 점을 통해 오차 제어를 보완한다면 본 연구 결과는 향후 에너지 저장 장치의 SOH 진단에 기여를 할 수 있을 것으로 기대된다.

### ACKNOWLEDGMENT

본 연구는 산업통상자원부 및 한국산업기술진흥원의 사업지원(KIAT) (No. RS-2025-04752996), 그리고 국립공주대학교 학술연구지원사업의 의하여 연구되었음.

### 참 고 문 헌

- [1] 신지수. (2021). “리튬 이온 배터리의 State of Health(SOH) 추정을 위한 State of Power(SOP) 기반의 딥러닝 모델”, 석사학위논문. 한양대학교.
- [2] Saha, B., and Goebel, K., "Battery Data Set," NASA Ames Prognostics Data Repository, 2007.
- [3] LeCun, Y., et al., "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [4] Vaswani, A., et al., "Attention is all you need," *Advances in Neural Information Processing Systems*, pp. 5998–6008, 2017.