

폐배터리 SOH 추정을 위한 ICA 기반 AdaBoost-GRU 앙상블 모델 설계

이상력*, 신승화*, 한동호*, 정영호*, 김종훈*

충남대학교 에너지저장변환연구실*

An ICA-based Adaboost GRU ensemble model for estimating SOH of secondlife-battery

Sangryuk Lee*, Seunghwa Shin*, Dongho Han*, Youngho Jeong*, Jonghoon Kim*

Energy Storage and Conversion Lab., Chungnam National University*

ABSTRACT

폐배터리의 효율적인 관리와 안전한 재사용을 위해서는 EOL (End of life; EOL) 이후의 배터리의 노화에 따른 배터리 모니터링이 중요해지고 있다. 따라서 본 논문에서는 증분용량분석(Incremental capacity analysis; ICA) 기법을 적용하여 EOL 이전 데이터를 통해 EOL 이후의 SOH (State-of-health; SOH) 추정이 가능한 모델을 소개한다. IC curve에서 나오는 Feature들을 분석하여 Pearson 상관 계수가 높은 2개의 Feature들을 학습데이터로 사용한다. SOH 추정 모델은 AdaBoost-GRU 앙상블 모델을 구성하고, 다른 모델과 비교하여 성능이 우수함을 검증했다.

1. 서 론

최근 지구 온난화와 환경오염의 문제를 해결하기 위한 방안으로 내연 자동차를 대체하여 전기자동차의 수가 크게 증가하고 있다. 전기자동차의 주 전원인 리튬이온 배터리는 SOH(State-of-health; SOH)가 80% 이하로 떨어지면, 에너지 및 전력요구량을 충족 못함에 따라 폐기되며 이때를 EOL(End of life; EOL)라 정의한다. 그러나 폐기된 배터리는 여전히 ESS 어플리케이션과 같이 에너지 및 전력 수요가 낮은 곳에서 재사용이 가능하다. 이에 따라 안전하게 폐배터리를 재사용하기 위해 EOL 이후의 SOH 추정 기술이 필요한 상황이다. 재사용 배터리와 신품 배터리를 사용하는 것의 중요한 차이점 중 하나는 배터리의 열화 경향성이다. 배터리가 동일한 상태에서 작동하더라도 EOL 이전과 이후의 배터리 노화 패턴이 다르다. 그에 따라 배터리의 노화와 잔존 수명에 관련되는 SOH 추정기법에 대한 연구가 필요하다. SOH 추정을 위한 다양한 건강지표(Health-indicator; HI) 중 증분용량분석(Incremental capacity analysis; ICA)는 정전류의 충전 또는 방전 시험 데이터를 통해 전도성 손실, 활물질 감소, 리튬 저장소 감소의 전기 화학적 특성을 분석할 수 있다는 장점이 있다. IC curve에서 나오는 peak 값들을 분석하여 상관 계수가 높은 상위 2개의 값을 Feature로 사용했다. 앙상블 기법 중 AdaBoost는 이전 모델의 학습결과를 토대로 다음 모델의 학습 데이터의 샘플 가중치를 조정해 학습을 진행하는 방법이다. GRU 모델을 AdaBoost 앙상블 모델의 하위 모델로 구성하고, EOL 이전 데이터를 학습시킴으로써 EOL 이후의 SOH를 예측하였다. 설계된 모델의 평가는 다른 시계열 모델과 비교하여 진행하였다.

2. ICA기반 AdaBoost-GRU 앙상블 모델 설계

2.1 절 INR21700-33J 배터리 셀 열화 시험




그림 1 INR21700-33J 배터리 열화 시험을 위한 실험 환경

Fig. 1 Physical configuration of INR21700-33J battery degradation test




그림 2 INR21700-33J 용량 그래프

Fig. 2 Capacity graph of INR21700-33J

배터리 셀의 열화 시험 구성은 그림 1에 명시하였다. 열화 시험은 항온챔버를 사용하여 상온 (25°C) 조건에서 1C-rate 충전 및 방전을 진행하였다. 충전은 정전류-정전압(Constant current-Constant voltage; CC-CV), 방전은 정전류(Constant current; CC)로 진행하였으며, 충전과 방전 사이에 휴지 1시간을 적용하였다. 그림 2는 상기 열화 시험 구성에 따라 SOH 100%에서 60%까지 노화된 용량 그래프이다.

2.1 절 ICA Peak 분석 및 학습데이터 구성

ICA는 IC 곡선의 Peak 위치, 크기, 폭 및 면적 등을 모니터링하여 노화 메커니즘을 분석하는 기법이다. IC 곡선의 분석을 통해 배터리 내부의 화학적 상태를 전류와 전압 데이터로 진단할 수 있다는 장점이 있으며 식(1)에 의해 일정 전압 구간별로 도출할 수 있다.

$$IC(Ah/V) = \frac{dQ}{dV} = \frac{d(I \cdot t)}{dV} = \frac{dI}{dV/dt} \quad (1)$$

(Q 는 용량(Ah), V 는 전압(V)을 의미하며, t 는 일정 전압 간격에 도달하는 시간을 나타낸다. IC 곡선은 1mV 간격으로 추출하였다.




그림 3 Cycle 별 IC 곡선

Fig. 3 IC curve per cycle

IC 곡선에서 peak 1은 배터리 노화가 진행됨에 따라 소멸하였기 때문에 peak1의 높이와 이동거리, peak1 area와 peak2 area는 기준을 정할 수 없어 제외하였다. 따라서 peak2, peak3의 높이와 이동거리 그리고 peak3 area를 초기 Feature로 선정하였다. 표 1은 용량과 초기 HI간의 Pearson 상관분석을 통해 나온 상관 계수를 나타내고 있으며, 이를 바탕으로 peak2, peak3의 높이를 최종적으로 학습데이터의 Feature로 선정하여 SOH 추정에 접목하였다.

표 1 ICA peak 상관분석

Table 1 Analysis of ICA peak

Feature	peak2 height	peak2 distance	peak3 height	peak3 distance	peak3 Area
상관계수	0.9885	0.4078	0.9683	0.754	0.8341





그림 4 AdaBoost-GRU ensemble 모델 개략도

Fig. 4 Schematic of AdaBoost-GRU ensemble model


2.2 절 AdaBoost-GRU 앙상블 모델 설계

AdaBoost 알고리즘은 예측력이 약한 분류기들을 순차적으로 결합하여 강한 분류기를 만드는 것이다. AdaBoost 알고리즘은 학습 초기에 모든 데이터가 추출될 확률은 동일하지만 분류가 잘못된 데이터는 가중치를 증가시키고 분류가 잘 된 데이터는 가중치를 감소시킨다. 데이터가 추출될 확률을 재조정하면서 반복 학습이 진행되며 최종적으로 가중치 값을 곱하여 강한 분류기를 도출한다^[1]. 그림 4에서는 AdaBoost 알고리즘과 시계열 예측에 사용되는 GRU 신경망 아키텍처를 결합하여 앙상블 모델을 구성하였다. 학습에는 EOL 이전 데이터가 사용되었으며 과적합을 방지하기 위해 조기 종료 기법을 적용하여 검증되었다. GRU 레이어의 하이퍼 파라미터와 드롭아웃 비율은 GridsearchCV 함수를 통해 최적화되었다.

제안된 AdaBoost-GRU 앙상블 모델의 성능평가를 위해 다른 시계열 예측 모델과 비교하였다. LSTM 모델은 널리 사용되는 순환 신경망 아키텍처로 선택되었으며, 다중선형회귀 모델은 전통적인 선형 회귀 기준 모델로 활용되었다. 또한, AdaBoost 부스팅 기법이 성능에 미치는 영향을 평가하기 위해 Single GRU 모델을 포함하였다.



(a)



(b)

그림 5 예측모델 별 (a) 에러, (b) SOH

Fig. 5 Predictive model (a) error, (b) SOH

평가는 MSE값으로 진행하였으며, 결과는 그림 5와 표2를 통해 나타내었다. Single GRU 같은 경우에는 MSE값이 136.15로 발산하는 모습을 보여줬으며, MLR이 20.219, LSTM 약 2.1363 순으로 MSE 값이 낮게 나왔다. AdaBoost-GRU 앙상블 모델의 경우 1.1245로 같이 비교한 다른 모델보다 높은 성능이 나온 것을 확인하였다.

표 2 예측 모델 별 MSE 값

Table 2 MSE by Predictive model

예측모델	Adaboost GRU	Single GRU	LSTM	MLR
MSE	1.1245	136.15	2.1363	20.219

3. 결 론

본 논문은 폐배터리의 EOL 이전의 노화 특성에 따른 EOL 이후의 용량 추정 방법으로 ICA 기반 AdaBoost-GRU 앙상블 모델을 설계하였다. 결론적으로, 모델의 용량 추정 성능은 AdaBoost 알고리즘과 GRU를 결합하여 가중치를 업데이트함으로써 비교군으로 사용된 다른 모델들보다 성능이 우수한 것을 확인하였다. 이후 연구에서는 학습데이터의 사용 Feature를 추가하여 성능 향상을 목적으로 연구를 진행할 예정이다.

본 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원(Nb. 2022-1711152629, 대규모 분산 에너지 저장장치 인프라의 안전한 자율운영 및 성능 평가를 위한 지능형 SW 프레임 워크 개발)과 한국에너지기술연구원(C3-2426, 배터리 건강 상태 추정을 위한 특성 분석 및 알고리즘 연구)의 지원을 받아 수행되었음.

참 고 문 헌

- [1] Nae Won Kwak, Dong Hoon Lim.(2021).Financial time series forecasting using AdaBoost-GRU ensemble model,Journal of the Korean Data And Information Science Society,32(2),267-281..
- [2] Bao, E, San Martín, I, Sánchez, P, Usta, A, & Stroe, D I. (2022). Health indicator selection for state of health estimation of second-life lithium batteries under extended aging. Journal of Energy Storage, 55, 105365