

다수의 건강성 지표를 입력 가능한 리튬 이온 배터리의 열화 상태 추정 딥러닝 모델 연구

박종욱¹, 정대웅¹, 장규진¹, 김동락², 이훈², 오승엽², 배성우^{1*}
¹한양대학교, ²현대모비스

Research of a Deep Learning Model for State of Health Estimation of Lithium-Ion Batteries Capable of Inputting Multiple Health Indicators

Jongwook Park¹, Daeung Jeong¹, Kyujin Jang¹, Dongrak Kim², Hoon Lee², Seungyeob Oh², Sungwoo Bae^{1*}

¹Dept. of Electrical Engineering, Hanyang University, Seoul, Korea
²Hyundai MOBIS

ABSTRACT

본 논문은 다수의 건강성 지표(Health Indicator, HI)를 입력으로 받아 배터리의 열화 상태(State of Health, SOH)를 추정하는 딥러닝 모델을 제안한다. 딥러닝을 적용하여 SOH를 추정하기 위해서는 리튬 이온 배터리의 전압, 전류, 온도 등의 측정 데이터로부터 추출한 건강성 지표가 필요하다. 이때, 배터리는 다양한 운영 조건과 환경에 따라 SOH 감소 경향성이 달라진다. 따라서 정확한 SOH 추정을 위해서는, 적절한 건강성 지표를 조합하여 SOH를 추정하는 것이 필요하다. 따라서, 본 논문에서는 여러 종류의 건강성 지표를 동시에 활용할 수 있는 다중 입력 기반 딥러닝 모델을 설계하였다. 제안된 모델은 리튬 이온 배터리의 운영 조건에 따른 다중 입력된 건강성 지표를 활용하여 SOH 추정 성능을 비교 분석한다.

1. 서 론

최근 전기자동차(Electric Vehicle, EV) 혹은 에너지저장장치(Energy Storage System, ESS)의 증가로 인하여, 리튬 이온 배터리의 수요가 증가하고 있다. 리튬 이온 배터리는 높은 출력을 낼 수 있고, 고밀도의 에너지를 저장할 수 있다. 하지만, 리튬 이온 배터리는 지속적인 충·방전 사용에 따라서 사용할 수 있는 용량이 감소한다. 이러한 용량 감소를 지표로 나타내는 것을 배터리의 SOH라고 한다^[1].

SOH 추정을 위해서는 전압, 전류, 온도, 내부 저항 등 다양한 HI를 사용한다. 이러한 지표들은 각각 배터리의 상태를 반영하는 중요한 정보이지만, 지표들간의 관계는 매우 복잡하고 비선형적이기 때문에 단순한 통계적 방법으로는 정확한 SOH 추정이 어렵다. 딥러닝 기반의 SOH 추정 방법은 이러한 복잡한 비선형 관계를 효과적으로 모델링할 수 있는 장점을 제공하며, 특히 여러 HI의 상호관계를 학습하여 높은 정확도의 SOH 추정을 가능하게 한다. 따라서 본 논문에서는 다수의 HI를 입력 가능한 딥러닝 모델을 활용하여, 배터리의 SOH를 추정하는 방법을 제안한다.

2. 본 론

2.1 리튬 이온 배터리의 열화 상태

표 1 추출된 건강성 지표 목록

Table 1 Extracted health indicators list

Index	Description & Equation
1	정전류 충전 시간 동안의 전압 값의 평균 값 $HI_1 = (V[0] + V[1] + \dots + V[n])/n,$ $n = \text{charge endtime}, V[n] = \text{Voltage}$
2	충전 후 특정 시간 동안의 평균 전압 상승량 $HI_2 = (V[0] + V[1] + \dots + V[k])/k,$ $k = \text{sampling time}, V[k] = \text{Voltage}$
3	정전압 충전 시간 동안 전류 변화의 평균 값 $HI_3 = (I[0] + I[1] + \dots + I[k])/k,$ $k = \text{time}, I[k] = \text{Current}$
4	정전류 충전 시간 $HI_4 = \text{Capacity} \times (SOC_{\text{target}} - SOC_{\text{initial}}) / I_{cc}$ $I_{cc} = \text{Constant Current}$
5	정전압 충전 시간 $HI_5 = t, \text{ if } i[t] < I_{cc} \text{ and } i[t] > 0.067$ $t = \text{time}, I_{cc} = \text{Constant Current}$
6	특정 전압 도달까지의 시간 $HI_6 = t - k, \text{ if } V_1 = V[k], V_2 = V[t]$ $t, k = \text{time}$

리튬 이온 배터리의 열화 현상은 지속적인 충·방전 사용으로 인하여 사용할 수 있는 최대 용량이 감소하는 것을 의미한다. 이를 수식으로 나타내면 식 (1)과 같이 정의할 수 있다.

$$SOH[\%] = \frac{Capacity_{Current}}{Capacity_{Initial}} \times 100 \quad (1)$$

식 (1)에서 $Capacity_{Current}$ 와 $Capacity_{Initial}$ 는 각각 배터리의 초기 용량과 현재 사용 가능한 최대 용량을 의미한다. 따라서, SOH는 초기 상태 대비하여 감소된 용량 상태를 비율로 나타낸 것을 의미한다.

2.2 건강성 지표

리튬 이온 배터리의 HI는 SOH 추정을 위해 사용하는 요소이다. 해당 지표들은 배터리의 측정 가능한 데이터인 전압, 전류, 온도, 시간 등을 통해서 추출하는 값이다. 이때, 효과적으로 사용할 수 있는 HI는 배터리의 SOH가 감소함에 따라서, 비례하여 감소하거나 증가하는 경향성을 가지고 있다. 본 논문에서 사용하는 HI의 정의와 수식은 표 1과 같다.

2.3 리튬 이온 배터리 열화 상태 추정 실험

리튬 이온 배터리 열화 실험에 사용한 배터리는

표 2 리튬 이온 배터리 충·방전 실험 조건
Table 2 Li-Ion batteries charge·discharge experiment conditions

State	Spec	Test No.					
		1	2	3	4	5	6
Chg	Current(A)	1.02	1.7	1.02	1.7	1.02	1.7
	Cutoff Voltage(V)	4.2	4.2	4.2	4.2	4.2	4.2
	Cutoff Current(mA)	67	67	67	67	67	67
Dchg	Current(A)	1.75	8	1.75	8	1.75	8
	Cutoff Voltage(V)	2.65	2.65	2.65	2.65	2.65	2.65
Temperature(°C)		25	25	-10	-10	45	45

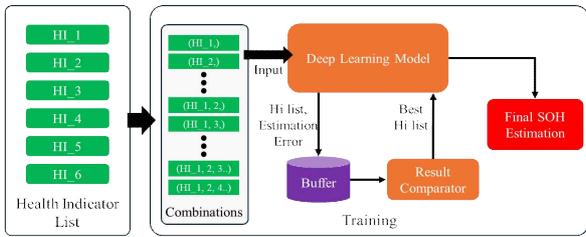


그림 1 다수의 건강성 지표 입력이 가능한 딥러닝 모델 구조
Fig. 1 Deep learning model structure that allows input of multi health indicators

Samsung SDI의 INR18650-35E 셀을 사용하였다. 배터리 셀의 실험 조건은 표 2와 같이 설정하였다. 그림 1은 본 논문에서 제안하는 딥러닝 모델의 학습 구조이다. 우선, 표 1의 HI 항목을 토대로, 다수의 HI 입력할 수 있도록 순열/조합을 통해 입력 데이터를 설정하였다. 딥러닝 모델의 경우 시계열 데이터 학습에 유리한 장단기 기억(Long Short-Term Memory, LSTM) 모델을 사용하였다. LSTM 모델은 시간에 따라 감소하는 경향성을 가진 SOH 학습에 유리하다는 특징이 있다^[2]. 이때, 딥러닝 모델은 조합된 HI 값들을 순차적으로 학습하여, SOH를 추정하고 버퍼에 HI 항목과 추정 결과에 대한 정보를 저장한다. 학습 성능을 비교하기 위하여 추정한 SOH와 실제 SOH 값을 평균 절대 오차(Mean Absolute Error, MAE)로 비교한다. 버퍼에 저장된 값을 토대로 결과를 분석하여, 실험 조건에 따른 최적의 HI 항목들을 결정한다.

3. 실험 결과

3.1 딥러닝 모델 추정 결과

제안된 SOH 추정 모델의 결과 비교 그래프는 그림 2와 같다. 그림 2의 (a)는 HI의 인덱스에 따른 추정 성능을 비교한 그래프이며, 그림 2의 (b)는 HI의 개수에 따른 추정 성능을 비교한 그래프이다. 해당 그래프에서는 HI 중 1, 2, 6번이 포함됨에 따라, 그리고 HI 개수가 증가함에 따라 추정 성능이 증가함을 보였다. 그림 3은 해당 실험을 통해서 표 2의 실험군 1번의 SOH를 추정 성능을 비교한 그래프이다. 제안된 방법으로 학습하였을 때, 해당 실험군에서는 HI₁, HI₃, HI₄, HI₅, HI₆를 포함하였을 때, MAE가 1.01%로 가장 높은 추정 성능을 보였다. 추정 성능이 제일 낮은 경우는 HI₂만 포함했을 경우로 MAE가 2.82%가 나타났다. 제안된 모델로 최적의 HI

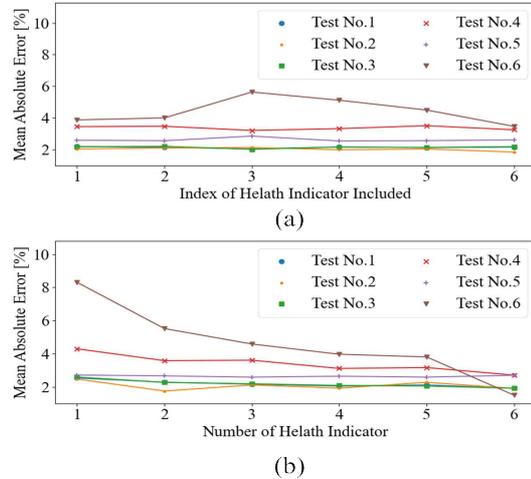


그림 2 특정 건강성 지표 포함과 개수에 따른 추정 오차 비교
Fig. 2 Comparison of estimation errors based on inclusion and number of specific health indicators

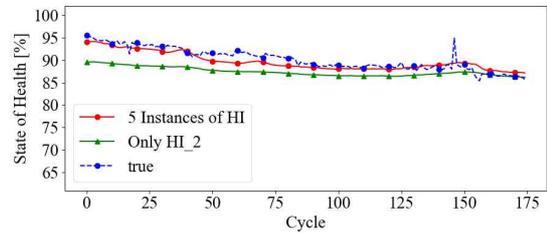


그림 3 실험군 1번의 열화 상태 추정 비교 그래프
Fig. 3 SOH estimation comparison graph for Test No.1
의 조합을 통해 SOH의 추정 성능을 향상시킬 수 있었다.

4. 결론

본 논문에서는 다수의 HI를 입력으로 받아 배터리 SOH를 추정하는 딥러닝 모델 연구를 진행하였다. 추정 성능을 비교하였을 때, HI 개수가 증가함에 따라, 높은 추정 정확도를 나타내는 경향성을 가졌다. 또한, 실험 조건에 따라 추정 정확도에 영향을 주는 HI가 다른 것을 확인하였다. 차후에는 HI와 실시간 운영데이터를 병렬적으로 학습하여, SOH의 추정 정확도를 높일 수 있는 딥러닝 모델을 연구할 계획이다.

본 연구는 2024년도 정부(산업통상자원부)의 재원으로 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다.(No.RS-2024-00422103, EV 스마트 충전 플랫폼 혁신연구센터)

참고 문헌

- [1] "Algorithms for Advanced Battery-Management Systems," IEEE Control Syst., vol. 30, no. 3, pp. 49 - 68, Jun. 2010, doi: 10.1109/MCS.2010.936293.
- [2] Y. Zhang, R. Xiong, H. He, and M. G. Pecht, "Longshort-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries,"IEEE Trans. Veh. Technol., Vol. 67, No. 7, pp.5695-5705, Jul. 2018.