

딥 러닝을 활용한 단기간 배터리 전압 특성 기반의 배터리 노화 상태 추정

박종욱, 정대웅, 권상협, 배성우^{*}
한양대학교 전기공학과

Battery State of Health Estimation using Deep Learning Based on Short-term Battery Voltage Characteristic

Jongwook Park, Daeung Jeong, Sanghyup Kwon, Sungwoo Bae^{*}
Dept. of Electrical Engineering, Hanyang University, Seoul, Korea

ABSTRACT

본 논문에서는 단기간의 배터리 전압 특성 데이터를 딥 러닝 모델로 학습하는 배터리 노화 상태 추정 방법을 제안한다. 기존의 딥 러닝을 활용한 배터리 노화 상태 추정 방법은 충·방전 전체 이력 데이터를 학습한다. 이러한 추정 방법은 전체 충·방전 데이터가 확보하기 어려운 실제 배터리 운영 상황에서는 적용하기 어렵다는 단점이 있다. 따라서 본 논문에서는 충·방전 전체 이력 데이터가 아닌 일부 데이터를 사용하는 배터리 노화 상태 추정 방법을 제안한다. 배터리 노화 상태 추정을 위해 전압 구간을 0.1V 단위로 구분하여 건전성 지표를 추출한다. 이후 추출된 단기간의 배터리 사용 데이터를 딥 러닝 모델로 학습하여 배터리 노화 상태를 추정한다.

1. 서론

최근 탄소중립을 위한 노력으로 전기자동차(Electric Vehicle, EV)와 에너지저장장치(Energy Storage System, ESS)의 시장 규모가 지속해서 증가하고 있다. EV와 ESS의 경우 에너지 공급원으로 리튬 이온 배터리를 주로 사용한다. 이러한 리튬이온 배터리는 지속적으로 사용함에 따라 사용 가능한 최대 용량이 감소하는 노화가 발생한다^[1]. 배터리 노화 상태(State of Health, SOH)에 따라 효율과 안전성이 감소하기 때문에 정확한 노화 상태를 추정하는 것이 중요하다.

기존의 배터리 노화 상태 추정을 위해서는 정전류-정전압(Constant current-constant voltage) 충·방전 전체 이력 데이터에서 건전성 지표(Health Indicator)를 추출하여 추정한다. 이러한 추정 방법은 배터리 전주기의 충·방전 이력 데이터를 확보하기 어려워, 실제 배터리 운영에서는 적용하기 어려운 한계점이 존재한다.

따라서 본 논문에서는 단기간의 배터리 데이터를 전처리하고 특성을 반영하기 위해서, 딥 러닝 모델을 적용하여 배터리 노화 상태를 추정하는 방법을 제안한다. 제안된 방법을 사용할 경우 단기간의 배터리 전압 구간 데이터만으로도 배터리 노화 상태를 추정할 수 있어, 배터리 전 주기의 충·방전 이력 데이터가 요구되지 않는다. 또한, 딥 러닝 모델을 적용하기 때문에 기존 모델 기반의 방법에서 요구되는 배터리의 내부 저항과 같은 데이터 없이 노화 상태 추정이 가능하다는 장점이 있다.

본 논문에서는 배터리 노화 상태 추정 성능을 검증하기 위해 NASA Ames Prognostic Center에서 제공하는 배터리




그림 1 LSTM 모델 내부 구조

Fig. 1 Structure of long short-term memory model

충·방전 데이터를 사용한다. 제안된 방법은 LSTM(Long Short-Term Memory)을 사용하여 배터리 전압 구간 별로 배터리 노화 상태를 추정하였으며, 실제 값과 Mean Absolute Error(MAE)와 Mean Square Error(MSE)를 비교하여 모델의 성능을 검증한다.

2. 이론

2.1 배터리 노화 상태

배터리 노화는 시간이 지남에 따라 최대 사용 가능한 배터리의 용량이 감소하는 것을 의미한다. 따라서, 배터리 노화 상태는 초기 용량에 비해 감소한 현재 용량을 의미하며, 식 (1)과 같이 정의할 수 있다.

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

식 (1)에서 $Capacity_{Initial}$ 와 $Capacity_{Current}$ 는 각각 배터리의 초기 용량과 현재 사용 가능한 최대 용량을 의미한다. 배터리 노화는 사용 주기, 온도와 같은 주변 환경에 영향을 받기 때문에, 불규칙적으로 감소하는 특성이 있다. 이러한 특성으로 노화 상태를 정확하게 추정하기 위해서는 전체 충·방전 이력 데이터가 요구된다.

표 1 배터리 데이터 충·방전 실험 조건

Table 1 Battery data charge/discharge test conditions

Battery Specification	Battery No.			
	B0005	B0006	B0007	B0018
Discharge Current (A)	2.0	2.0	2.0	2.0
Discharge Cut-off Voltage (V)	2.7	2.5	2.2	2.5
Fresh Capacity (Ah)	1.857	2.035	1.891	1.855
Final Capacity (Ah)	1.325	1.186	1.433	1.341




그림 2 NASA 데이터 셋 배터리 노화 그래프

Fig. 2 NASA dataset battery aging graph

2.2 LSTM (Long Short-Term Memory) 모델

LSTM 모델은 시계열 데이터 처리에 유리한 특성을 가지고 있다. 이러한 특성은 충/방전 사이클 횟수와 시간에 따라 노화 상태가 변화하는 배터리 데이터를 학습하는데 유리하다. 그림 1은 LSTM 모델의 내부 구조에 대한 그림이다. LSTM 모델은 입력 게이트(I_t), 망각 게이트(F_t), 출력 게이트(O_t)로 3개의 게이트로 구성되어 있다. 또한, 시간이 지남에 따라 정보를 기억하거나 잊을 수 있는 셀 상태(C_t)에 대한 정보가 있다. 망각 게이트를 통해 셀 상태의 반영 정도를 결정하여 기술기 소멸 문제를 해결할 수 있어 시계열 데이터 처리에 유리한 특성이 있다.

식 (2), (3), (4)를 통해 현재 시점의 입력(x_t)과 이전 시점의 출력(h_{t-1})을 입력받아 Sigmoid 함수로 연산을 수행한다. 이후 과거 장기 기억(C_{t-1})의 반영 정도를 망각 게이트를 통해 조절한다.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (4)$$

식 (5)에서 입력 게이트로부터 기억 일부($\tilde{C}_t$)의 곱을 통해 현재 장기 기억(C_t)을 업데이트한다. 같은 과정으로 C_t 는 타임스텝마다 기억 일부가 삭제 및 추가되는 과정을 수행한다.

식 (6)에서는 sigmoid 함수로 연산 후 복사된 C_t 는 출력 게이트에 hyperbolic tangent 함수로 전달되고, 이를 통해 현재 시점의 상태(h_t)에 대한 값을 도출한다^[2].

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (5)$$

$$h_t = o_t \odot \tanh(C_t) \quad (6)$$




그림 3 딥 러닝 모델 학습 알고리즘

Fig. 3 Deep learning model training algorithm

3. 배터리 노화 상태 추정 실험

3.1 배터리 충·방전 데이터 셋

리튬 이온 배터리의 데이터는 NASA Ames Prognostic Center에서 제공하는 배터리 충·방전 데이터를 사용하였다. 구체적인 배터리 조건은 표 1과 같다. 실험에 사용된 배터리는 리튬 이온 18650 셀이며, 공칭 용량이 2Ah이다. 실험 데이터 셋 B0005, B0006, B0007, B0018의 방전 중지 전압 임계 값은 각각 상이하게 설정하였으며, 정격 용량의 30% 감소까지 진행하였다. 그림 2는 데이터 셋의 용량 감소를 나타낸 그래프이다.

3.2 실험 방법 설계

제안된 방법에 사용된 딥 러닝 모델은 시계열 데이터 처리에 유리한 LSTM 모델을 2개 층으로 사용하였다. 딥 러닝 모델의 하이퍼파라미터는 표 2와 같다.

배터리 노화 상태 추정을 위해 배터리 전압 동작 범위는 3.0 ~ 3.9 V로 구분하였고, 단기간의 전압 데이터 구간으로 각 구간을 0.1V 기준으로 구분하였다. 또한 학습 데이터로 사용할 건전성 지표로 특정 구간의 전압, 온도, IC(Incremental Capacity), 그리고 DTV(Differential Thermal Voltammety) 값을 사용하였다^[3]. 딥러닝 모델 학습에는 네 종류의 데이터가 입력층을 거치고, LSTM 모델이 2개 층으로 구성된 은닉층을 통

표 2 딥러닝 모델 하이퍼파라미터

Table 2 Hyper-parameters of deep learning model

Hyperparameters	Selection Options
Number of neurons (LSTM_1)	150
Number of neurons (LSTM_2)	100
Number of hidden layers	2
Optimization algorithm	Adam
Batch size	5
Loss Function	Mean Square Error
Activation	ReLU




그림 4 전압 구간별 딥 러닝 모델의 노화 상태 추정 비교
Fig. 4 Comparison of aging estimation of deep learning models based on voltage intervals

해 SOH를 학습하는 구조로 이루어져 있다.

그림 3은 실험에 적용한 딥 러닝 모델 학습 방법 알고리즘을 나타낸 그림이다. 딥 러닝 모델 학습의 경우 B0005, B0006, B0007 데이터를 사용하고, 학습 데이터의 10%를 검증 데이터로 사용한다. 시험 데이터로 이전에 학습된 적 없는 B0018 데이터 셋의 노화 상태를 추정한다. 제안된 방법의 적합성은 시험 데이터에 대한 추정 결과를 실제 값과의 MSE와 MAE 비교를 통해 검증한다.

3.3 실험 결과 및 검증

본 논문에서 제안한 방법의 결과는 그림 4와 같다. 그림 4(a)는 실제 값과 추정 값 비교 그래프이며, 그림 4(b)는 MAE를 비교한 그래프이다. 또한, 각 구간에 대한 MAE와 MSE 결과는 표 3과 같다.

전체 충·방전 이력 데이터를 학습하였을 경우, MAE는 1.52%, MSE는 0.06%의 오차율을 보여주었다. 특정 전압 구간의 데이터만을 사용하여 노화 상태를 추정했을 때는, 최저 오차는 3.1 - 3.2V 구간의 경우 2.29%의 MAE와 0.10%의 MSE 값을 나타냈다. 이처럼 전체 충·방전 이력 데이터를 학습

표 3 전압 구간에 따른 노화 상태 추정 오차

Table 3 Estimation error of State of Health by voltage range

전압 구간	오차 지표	MAE (%)	MSE (%)
3.0 - 3.9[V] (전 구간)		1.52	0.06
3.0 - 3.1[V]		9.50	1.15
3.1 - 3.2[V]		2.29	0.10
3.2 - 3.3[V]		3.80	0.25
3.3 - 3.4[V]		10.97	1.36
3.4 - 3.5[V]		12.68	1.68
3.5 - 3.6[V]		12.42	1.63
3.6 - 3.7[V]		5.88	0.74
3.7 - 3.8[V]		7.94	0.79
3.8 - 3.9[V]		7.48	0.70

하지 않고도, 단기간 배터리 전압 특성 데이터를 사용하여 유의미한 배터리 노화 상태 추정이 가능함을 검증하였다.

4. 결론

본 논문에서는 단기간의 배터리 데이터를 활용한 배터리 노화 상태 추정 방법을 제안하였다. 배터리의 단기간의 전압 데이터 기반으로 건전성 지표를 추출한 후, LSTM 2층 모델을 사용하여 노화 상태를 추정하였다. 제안된 방법을 적용하였을 때, 전체 이력 데이터가 없더라도 특정 전압 구간의 배터리 데이터만으로 노화 상태 추정 가능하다. 추정 정확도를 비교하였을 때, MAE 범위는 2.29 ~ 12.68%로 나타났고, MSE 범위는 0.10 ~ 1.68%로 나타났다.

추후 제안된 방법을 적용하여 다양한 배터리의 노화 상태 추정에도 단기간 배터리 전압 특성 기반의 배터리 노화 추정 방법의 실효성을 검증할 계획이다. 또한 실제 운영데이터와 가속노화와 같은 특정 조건에서도 제안하는 방법을 검증하는 후속 연구를 진행할 계획이다.

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20225500000060)

참 고 문 헌

- [1] H. Rauf, M. Khalid, N. Arshad, "Machine learning in state of health and remaining useful life estimation: Theoretical and technological development in battery degradation modelling", Renewable and Sustainable Energy Reviews, vol 156, p 111903, 3 2022
- [2] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," in Neural Computation, vol. 9, no. 8, pp. 1735-1780, 15 Nov. 1997
- [3] Z. Wang, C. Yuan, X. Li, "Lithium Battery State-of-Health Estimation via Differential Thermal Voltammetry With Gaussian Process Regression", IEEE Trans. Transp. Electric., vol 7, pp 16 - 25, 3 2021