

리튬 이온 배터리의 충전 상태 추정을 위한 LSTM 네트워크 학습 방법 비교

Comparison of Learning Techniques of LSTM Network for State of Charge Estimation in Lithium-Ion Batteries

홍 선 리*, 강 모 세**, 김 건 우*, 정 학 근**, 백 종 복**★, 김 종 훈*★

Seon-Ri Hong*, Moses Kang**, Gun-Woo Kim*, Hak-Geun Jeong**, Jong-Bok Beak**★,
Jong-Hoon Kim**★

Abstract

To maintain the safe and optimal performance of batteries, accurate estimation of state of charge (SOC) is critical. In this paper, Long short-term memory network (LSTM) based on the artificial intelligence algorithm is applied to address the problem of the conventional coulomb-counting method. Different discharge cycles are concatenated to form the dataset for training and verification. In order to improve the quality of input data for learning, preprocessing was performed. In addition, we compared learning ability and SOC estimation performance according to the structure of LSTM model and hyperparameter setup. The trained model was verified with a UDDS profile and achieved estimated accuracy of RMSE 0.82% and MAX 2.54%.

요 약

안전하고 최적의 배터리 성능을 유지하기 위해 정확한 충전상태(SOC) 추정 기술이 필수적이다. 본 논문에서는 기존의 전류적산 방법이 가지고 있는 문제를 해결하기 위해 시간 종속성을 가지는 인공지능 기반의 LSTM을 이용한 SOC 추정 방법을 적용하였다. 훈련과 검증에 필요한 데이터는 전기적 실험을 통해 일정 크기로 방전된 전류, 전압, 온도를 수집하였고 학습을 위한 입력데이터의 질을 향상시키기 위해 데이터 전처리를 수행하였다. 또한, LSTM 모델의 구조 및 하이퍼파라미터 설정에 따른 학습 능력과 SOC 추정 성능을 비교하였다. 학습한 모델은 UDDS 프로파일을 통해 검증하였으며, RMSE 0.82%, MAX 2.54%의 추정 정확도를 달성하였다.

Key words : State of charge estimation, battery management system, long short-term memory, recurrent neural network, lithium ion battery

* Dept. of Electrical Engineering, Chungnam National University

** Dept. of Electrical Engineering, Korea Institute of Energy Research

★ Corresponding author

E-mail : whdgns0422@cnu.ac.kr, Tel : jongbok.beak@kier.re.kr

※ Acknowledgment

This work was supported by the Korea Institute of Energy Technology Evaluation and Planning (KETEP) and the Ministry of Trade, Industry & Energy (MOTIE) of the Republic of Korea. (No. 20182410105280).

Manuscript received Dec. 10, 2019; revised Dec. 21, 2019; accepted Dec. 27, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

2020년 전후로 미국, 유럽 등 주요 국가에서 온실가스 배출량 20-30% 감소를 위한 환경규제가 도입되므로 재생에너지 사용 증가와 더불어 배터리 시장도 급격히 성장할 것으로 예상 된다[1]. 특히, 스마트 그리드(Smartgrid) 및 전기 자동차(Electric Vehicle) 주요산업에서는 배터리는 주동력원이 되어 가고 있으며, 그 중 리튬 이온 배터리는 높은 에너지 밀도와 긴 수명으로 납축전지(PbAB)를 대체하여 널리 사용되고 있다[2]. 전기 자동차용 배터리의 경우 고용량과 복잡한 운영환경을 가지고 있으므로 리튬 이온 배터리가 안전하고 신뢰성 있게 작동하기 위해서는 배터리 관리 시스템이 필요하다[3]. 배터리 관리 시스템은 배터리 상태를 모니터링하고 안정적인 운영 영역에서만 작동하도록 제어하며, 충전상태(SOC)는 배터리 상태 판단에 중요한 요소이다. 충전상태는 작동중인 배터리의 정격용량 대비 잔류 전하 비율로 정의되는데[4] 이는 배터리의 비선형성 또는 전기화학적 반응으로 인해 직접 측정할 수 없기 때문에 다양한 방법들이 연구되었다.

기존 SOC 추정 방법은 전류적산법을 사용하거나 적응형 필터 기반인 칼만 필터(Kalman Filter, KF)를 사용한다. 전류적산법은 쉽고 강력하여 널리 사용되지만 곱셈에 의존한 방법으로[5] 곱셈의 초기값, 전류 센서 또는 열화에 대한 오차 등에 영향을 받는다는 문제점이 있다. KF의 개선된 기법인 확장 칼만 필터(Extended Kalman Filter, EKF)는 선형 시간 변화(Linear Time Varying, LTV)시스템으로 근사화하여 비선형 시스템 추정을 한다[6]. 이는 역동적인 시스템이나 배터리 종류가 다른 시스템에서도 적합한 성능을 낸다. 또한 잘못 초기화된 상황에도 빠르게 올바른 결과로 수렴된다. 하지만 매우 복잡하여 구현하기 어렵고[7, 8] 배터리 모델링에 고려해야할 매개변수와 조건이 많다. 이는 모델링에 따라 정확도가 달라질 수 있음을 말한다.

이러한 기존 문제점 방식을 개선하고자 인공지능 알고리즘을 접목한 기법을 포함하여 여러 기법들이 제안되었다. 일찍이 인공지능 알고리즘이 등장하였으나 최근 컴퓨터 장비의 고급화와 데이터 폭증, 새로운 기법의 등장으로 인해 인공지능에 대한 관심이 커지며 많은 분야에서 활용하고 있다.

현재 인공지능은 학습된 지능에 기반을 두어 인지된 환경에 대한 추론 및 예측이 가능한 수준에 이르렀다[9]. 배터리 분야에서도 마찬가지로 데이터 증가와 복잡한 배터리 모델을 반영하지 않아도 되는 편이성으로 인해 인공지능을 적용한 연구가 많이 진행되었다[10, 11]. 인공지능 기반의 SOC 추정으로는 일반적으로 인공신경망(Artificial Neural Network, ANN), 서포트 벡터 머신(Support Vector Machine, SVM), 퍼지 알고리즘(Fuzzy Logic), 순환신경망(Recurrent Neural Network, RNN)과 같은 방법이 소개되고 있다[12]. SVM과 같은 머신러닝 방식으로 작동 가능한 모든 전류 범위에서 높은 SOC 추정 정확도를 얻을 수 있다[13]. 하지만 이는 현재 입력에 의해 계산되는 값이다. 배터리의 SOC는 전류의 누적량으로 계산되기 때문에 추정 네트워크에 시퀀스 정보를 포함해야할 필요가 있다. 인공지능 알고리즘을 사용한 RNN은 상태 변수를 통해 시퀀스에 따라 변화하는 데이터를 학습할 수 있다. 또한 LSTM, Gate Recurrent Unit(GRU)와 같은 메모리셀의 등장하여 장기간의 큰 데이터에서도 훈련을 수행하여 네트워크의 정확도를 향상시킬 수 있다. 최근에는 Convolutional Neural Network(CNN) 방식과 결합하여 SOC를 추정하기도 한다[14].

본 논문에서는 LSTM 메모리 셀을 사용한 RNN 네트워크로 SOC를 추정하는 방법을 제안한다. 2절에서 LSTM의 구조와 동작과 훈련 데이터를 얻기 위한 전기적 방전 용량 실험과 Urban Dynamometer Driving Schedule(UDDS) 실험을 수행한다. 실험을 통해 수집한 데이터는 총 4개의 프로파일로 최대 방전 크기가 모두 다르다. 3 절에서는 훈련 데이터의 질을 높이기 위한 데이터 전처리 방법을 소개하고 제안한 LSTM 모델 훈련을 위한 실험 매개변수를 설정한다. 총·방전 크기가 다르고 빈번한 프로파일에서 적합성을 가지는지 판단하기 위해 특정 방전 크기 프로파일로 훈련된 모델과 다양한 방전 크기로 훈련된 모델의 정확도를 비교한다. 그 후 UDDS 프로파일을 검증 데이터로 사용하여 모델 파라미터에 대한 정확도를 비교한다. LSTM 모델의 구조와 학습 방법에 대한 영향은 평균 절대 오차(MAE), 평균 제곱근 오차(RMSE), 최대 오차(MAX)를 평가지표로 비교하고 최적의 모델 파라미터를 제시한다.

II. 본론

1. Long-short term memory network

순환신경망은 가변적인 언어, 음성, 주가 등 시간이나 순서 데이터 모델링을 위해 등장하였다[15]. 히든 상태(Hidden State)를 통해 순환신경망에서 시퀀스 상태를 요약하여 네트워크에 가지고 있지만, 고질적인 기울기 소실, 장기간 의존성 소실 등의 문제를 가지고 있다. 순환신경망의 단점을 극복하기 위한 방안으로 1990년대 중반 LSTM 네트워크가 제안되었으며 은닉 상태에 셀 상태(Cell State)를 추가한 구조이다[16]. 이는 장시간에도 학습할 수 있는 바탕이 되어 시계열 데이터 유형의 어플리케이션에 널리 사용되고 있다.

SOC 추정을 위한 LSTM 네트워크 구조는 그림 1과 같이 표현할 수 있다. 훈련 데이터 세트는 입력 데이터와 측정 SOC로 구성되었다. 입력 데이터는 전압, 전류, 온도이며 각각 V, I, T로 표현한다. 타임 스텝인 t로 네트워크에 입력을 표현하면 (V1, I1, T1), (V2, I2, T2), ... (Vt-1, It-1, Tt-1), (Vt, It, Tt) (t = 1, 2, 3 ...)이다. 네트워크의 출력인 SOCt는 추정 SOC이다. 그림 2는 전방향(forward)로 흐르는 순전과 LSTM 셀 내부를 도식화한 것이다. 순전과 LSTM 셀의 입력은 현재의 데이터와 이전 시간의 상태이며, 각 게이트를 거쳐 상태벡터를 얻는다. 삭제 게이트는 과거 정보를 유지할 지 삭제할 지 결정하며 시그모이드 함수의 범위인 0~1 사이의 값을 가진다. 1에 가까울수록 과거 정보를 보존하게 된다. 입력 게이트는 현재 스텝의 기억해야 할 정보를 결정하며 삭제 게이트와 마찬가지로 1이면 현재 입력으로 들어온 정보를 모두 기억한다. LSTM 셀을 거치고 난 후 출력층에 도달하면 상태




Fig. 1. Architecture of Recurrent Neural Network.
그림 1. 순환 신경망의 구조

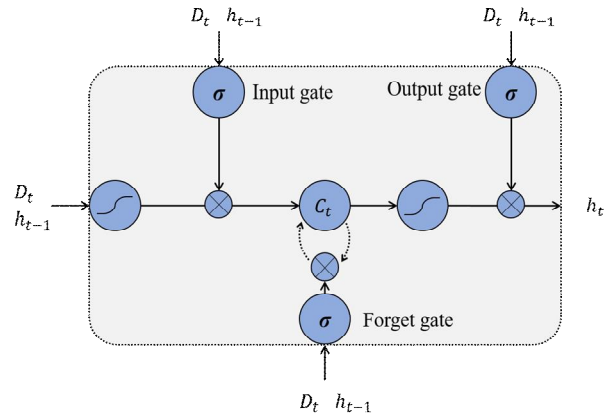


Fig. 2. Long-Short Term Memory cell.
그림 2. 장단기 메모리 셀

벡터와 편향을 이용해 추정 SOC를 구한다.

식 1~5는 LSTM 셀의 계산과정을 나타낸다.

$$i_t = \sigma(W_{D_i}D_t + W_{h_i}h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_{D_f}D_t + W_{h_f}h_{t-1} + b_f) \quad (2)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{D_c}D_t + W_{h_c}h_{t-1} + b_c) \quad (3)$$

$$o_t = \sigma(W_{D_o}D_t + W_{h_o}h_{t-1} + b_o) \quad (4)$$

$$h_t = o_t \circ \tanh(c_t) \quad (5)$$

i, f, o는 각각 입력, 삭제, 출력 게이트를 표현하며 c는 상태를 저장하는 메모리 셀을 나타낸다. h는 셀 상태로 필터링된 상태 벡터를 의미하며, 식 5의 \circ 는 요소별 곱셈을 나타낸다. σ 는 활성화 함수이며 시그모이드 함수로 설정된다. 시그모이드 함수는 식 6번과 같다. W는 게이트 사이의 가중치 행렬을 뜻한다. b는 각 게이트에서의 편향으로 모델의 유연성을 결정하여 일반화에 영향을 준다.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

각 순전과의 마지막 단계에서 추정값과 측정값의 오차를 최소화하기 위한 손실함수가 계산되며 이는 평균제곱오차(Mean Square Error, MSE)를 사용된다. 손실함수는 다음 식 7번과 같다.

$$L = \frac{1}{n} \sum_{t=1}^n (SOC_t - SOC_t^*)^2 \quad (7)$$

SOCt는 스텝 t의 측정값이고, SOCt* 네트워크에 의해 추정된 값이다. n은 데이터의 총 길이이다.

측정값과 추정 값의 차이를 역전과 기법을 통해 네트워크 가중치를 업데이트한다. 이는 최적화 기법인 Adam을 통해 수행된다. Adam은 AdaGrad (duchi et al., 2011)와 RMSProp(Tieleman & Hinton, 2012)의 장점을 결합한 방법이며 구현이 간단하고 계산 효율성이 높은 것이 특징이며 최적화 식은 8과 같다[17].

$$\begin{aligned}
 m_t &= \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \\
 n_t &= \beta_2 \cdot n_{t-1} + (1 - \beta_2) \cdot g_t \\
 \hat{m}_t &= \frac{m_t}{(1 - \beta_1^t)} \\
 \hat{n}_t &= \frac{n_t}{(1 - \beta_2^t)} \\
 W_t &= W_{t-1} - \alpha \cdot \frac{\hat{m}_t}{\sqrt{\hat{n}_t + \epsilon}}
 \end{aligned}
 \tag{8}$$

여기서 β_1 과 β_2 는 지수감소평균이며 각각 모멘텀(Momentum)과 스케일(Scale) 감쇠 하이퍼 파라미터이다. m , n 은 각각 기울기에 대한 1차, 2차 모멘트 벡터이다. 이는 g 는 목적함수로 손실함수 L 을 뜻한다. α 는 훈련 스텝 사이즈이며 W 는 네트워크 매개변수를 나타낸다. LSTM 네트워크는 앞선 내용을 반복하여 업데이트 되고 각 스텝마다 추정 SOC를 계산한다.

2. 훈련과 검증 데이터를 위한 전기적 실험

2.1 충전상태(SOC)

SOC는 배터리에 저장되어 있는 전하량을 나타내며, 배터리 관리 시스템에 의해 계산된다. 이는 퍼센트 또는 0에서 1 사이의 범위로 표현된다. 전류적산법을 통한 SOC를 계산하는 식은 다음 9와 같다[18].

$$SOC_t(\%) = SOC_0 - \frac{\int_0^t idt}{C_n} \times 100
 \tag{9}$$

SOC_t는 타임 스텝 t 의 측정 SOC이며, SOC₀은 초기 SOC값이다. SOC₀은 SOC 5% 펄스로 실험한 OCV 실험 결과를 록업 테이블을 기반으로 추정하였으며, 관련 SOC-OCV 곡선 그래프는 그림 3에 나타내었다. C_n은 정격 용량이며 i 는 각 타임 스텝의 전류이다. C_n은 실제 배터리 노화 정도에 따라

가변 값이지만 본 논문에서는 짧은 주기의 데이터를 사용하므로 일정한 용량으로 가정하고 계산한다.




Fig. 3. SOC-OCV curve in 5% of SOC.
그림 3. SOC 5% 간격의 SOC-OCV 곡선

2.2 배터리 특성 실험

훈련 데이터 수집 위해 사용한 테스트 장비는 그림 4번과 같다. 실험에 사용한 삼성 INR21700-50E 셀은 리튬 망간 니켈(LiNiMnCoO2) 충전 화학 물질의 배터리이며 공칭 용량은 5000mA, 최대 전압은 4.2V이다. 자세한 사양은 표 1에서 확인할 수 있다. 배터리 테스트 장비는 MACCOR Model 4300이며 전류범위는 최대 15A까지다. 훈련 데이터 수집을 위해 표 2와 같이 두 가지의 실험을 수행한다. 첫 번째로 방전 용량 실험을 수행한다. 이 실험은 배터리의 용량을 확인하는 실험으로 2,450mA (0.5C)의 크기로 정전류 충전을 하였고 최대 전압 4.2V에서 완전 충전을 하였다. 그 후 1시간 동안 휴지 시간을 거쳐 배터리 내부를 안정시키고 샘플 타임 1초로 각 0.5C, 1C(4,900mA), 2C(9,800mA)로 방전 하한 전압 2.5V까지 방전을 진행하였다. 그림 5는 방전 실험 결과이며 각 방전 크기의 전압과 전류를 나타낸다. 하한전압에 도달하는 시간을 기준으로 각 방전 크기의 용량을 계산하여 전류적산법으로 SOC를 구할 때 반영한다. 다음으로 전류의 급격한 변화에 대한 SOC 추정 성능을 검증하기 위해 전기차 주행 시험에 사용되는 프로파일인 UDDS 실험을 진행하였다. 그림 6은 UDDS 프로파일의 전류, 전압을 나타내며, 최대 2C로 단시간 내에 충·방전을 수행한 프로파일이다. UDDS 사이클 구간 동안 인가된 총 전하량은 0이다.

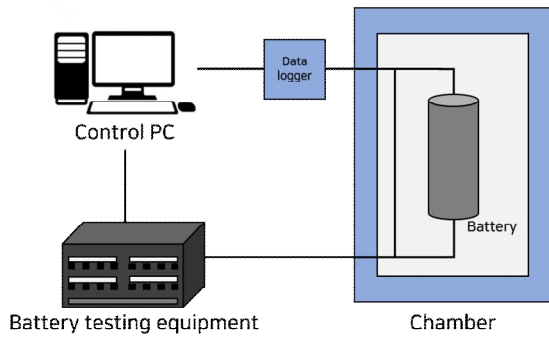


Fig. 4. Schematic of experimental equipment for battery test.
그림 4. 배터리 테스트를 위한 실험 장비 개요

Table 1. Samsung INR 21700-50E Cell Parameter.
표 1. 삼성 INR 21700-50E 배터리 사양

Item	Specification
Nominal Voltage	3.6 [V]
Nominal Capacity	5,000 [mAh]
Charging Current	2,450 [mA]
Charging Voltage	4.2 [V]
Discharging Cut-off Voltage	2.5[V]
Storage Temperature	-20~+60 [°C]

3. LSTM 네트워크의 SOC 추정 결과

이 장에서는 LSTM 네트워크 모델을 위한 데이터 전처리 방법과 구현 방법을 다룬다. 먼저, 모델 입력의 모양에 따른 영향을 비교하고, 다음으로 LSTM의 구조와 모델 파라미터 설정에 따른 학습 능력 및 성능을 비교·분석한다.

Table 2. Experimental data for verification and training.
표 2. 검증과 훈련을 위한 실험 데이터

Index	Method	Maximum discharge current[A]
profile 1	discharge	2.45
profile 2	discharge	4.9
profile 3	discharge	9.8
profile 4	UDDS	13.41

3.1 실험 매개변수 설정

실험 환경은 CPU Intel i7 9700K 12Mb, GPU NVIDIA GeForce RTX 2060 6GB와 RAM 64GB로 구성된 데스크탑이다. 모델 구현은 Python과 Tensorflow Backend를 사용한다. 모델은 입력층과

2개의 은닉층을 사용한다. 입력층의 입력 형태는 데이터의 깊이를 반영할 수 있도록 배열 모양을 결정하였다. 입력 데이터의 깊이는 100개로 1분 40초간의 데이터를 고려한다. 각 은닉층은 128개의 계산 유닛을 가지고 있다. 출력층은 은닉층의 유닛과 연결되어 하나의 추정 SOC를 산출한다. 모델의 과적합(Overfitting) 방지를 위한 드롭아웃 층은 25%로 설정한다. 훈련 과정에서 사용되는 최적화 알고리즘은 adam으로 수행한다.

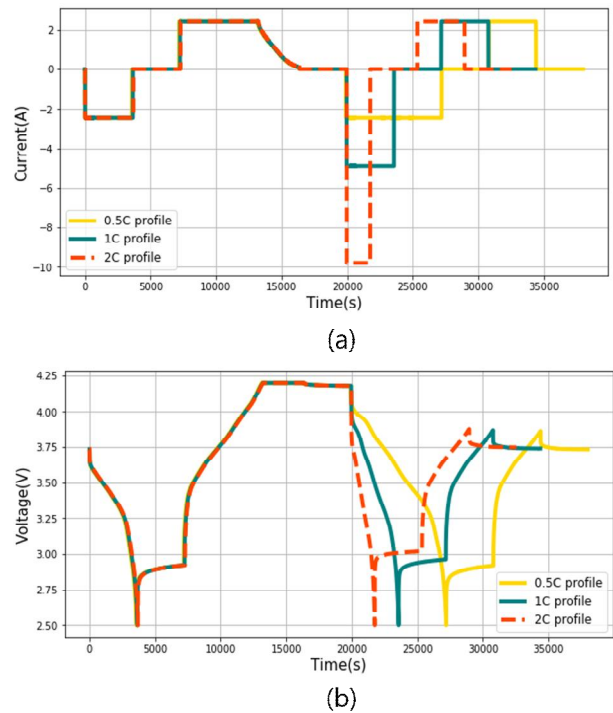


Fig. 5. Discharge capacity test profile. (a) Current (b) Voltage.
그림 5. 방전 용량 실험 프로파일 (a) 전류 (b) 전압




Fig. 6. UDDS profile.
그림 6. UDDS 프로파일

모델 성능의 검증 지표는 MAE, RMSE, MAX를 사용한다. 각 지표의 계산식은 아래 식 10, 11과 같다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |SOC_i - SOC_i^*| \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (SOC_i - SOC_i^*)^2} \quad (11)$$

3.2 훈련 데이터의 전처리

인공지능 알고리즘 기반의 훈련에서 입력 데이터의 전처리는 중요한 영향을 미친다. 사용하려는 입력 데이터의 전압은 2.5V에서 4.2V, 온도는 25°C에서 52°C와 같이 다른 범위를 가지고 있다. 이는 신경망 모델뿐 아니라 선형 회귀 모델에서도 특성 간의 단위 차이가 크다면 추정 과정에서 오버플로우(Overflow)나 언더플로우(Underflow)를 발생시킬 수 있다. 데이터 스케일링은 표준화를 이용해 이와 같은 문제점을 방지하고 최적화 과정에서 수렴 속도를 향상시킬 수 있다. 1C 프로파일을 훈련데이터로 입력 벡터가 0에서 1사이에 있도록 식 12를 통해 표준화를 한다. 입력 데이터 벡터는 표 3에서 확인할 수 있다.

$$x_{scaled} = \frac{x_{raw} - x_{min}}{x_{max} - x_{min}} \quad (12)$$

표준화를 한 데이터와 기존 데이터를 각각 훈련하여 평가를 진행하였고 전류적산법 기반의 SOC와 결과를 비교하였다. 실험 결과는 표 4에 나타났다. 일반 데이터로 훈련한 모델보다 표준화가 된 데이터가 최적결과로 수렴하는데 더 적은 시간이 걸린다는 것을 확인하였다.

Table 3. An example of preprocessed input data vector.

표 3. 전처리된 입력 데이터 예시

Element	I	V	T
Unscaled	-4.751	3.857	25.33
Scaled	0.404	0.773	0.042

Table 4. Error rate and training time between scaled and unscaled data set.

표 4. 표준화된 데이터와 일반 데이터 간의 오차와 훈련 시간

Element	MSE	MAE	Time(s)
Unscaled	0.224	0.054	4230
Scaled	0.210	0.033	460

3.3 SOC 추정에서 훈련 데이터의 영향

특정 방전 크기 데이터로 훈련된 모델이 다른 방전 크기 데이터를 추정할 수 있는지 확인하기 위해 표 5와 같이 훈련 데이터를 다르게 설정하여 실험을 수행한다. Case 1로 특정 방전 크기로 데이터를 훈련 데이터로 사용하며 Case 2로 다양한 방전 크기 데이터로 훈련한다.

Case 1은 1C 프로파일로 훈련한 모델로 0.5C, 2C 프로파일로 검증을 수행한다. 그림 7은 1C 프로파일로 훈련한 모델의 추정 SOC와 오차율이다. 0.5C 프로파일은 RMSE 8%, MAX 14%를 보였고, 2C 프로파일은 RMSE 12%, MAX 17%의 결과를 보였다. 이는 특정 방전 크기의 데이터가 다양한 방전 크기의 데이터에서 추정 성능이 떨어질 수 있음을 확인할 수 있다.

Table 5. Performance of LSTM model between Case 1 and Case 2.

표 5. Case 1과 Case 2 간의 LSTM 모델 성능

Case	MAE	RMSE	MAX
1	0.021	0.036	0.174
2	0.019	0.032	0.061




Fig. 7. Training data set is 1C discharge profile and test with 0.5C · 2C discharge profile. (a) estimated SOC, (b) error rate.

그림 7. 훈련 데이터는 1C 방전 프로파일, 검증 데이터는 0.5C · 2C 방전 프로파일. (a) 추정 SOC, (b) 오차율




Fig. 8. Training data sets are all discharge profile and test with 0.5C · 1C · 2C discharge profile. (a) estimated SOC, (b) error rate.

그림 8. 훈련 데이터는 모든 방전 데이터, 검증 데이터는 0.5C, 1C, 2C 각각의 프로파일. (a) 추정 SOC, (b) 오차율

다음으로 Case 2는 앞서 실험한 0.5C, 1C, 2C 프로파일을 한 스텝의 입력으로 단일 모델을 훈련한다. 이 모델 네트워크의 결과는 그림 8번과 같다. 평균 RMSE 3%, MAX 6%로 특정 방전 데이터로 훈련한 것보다 RMSE 5% 낮은 결과를 보였다. 이를 통해 다양한 방전 크기의 프로파일로 훈련한 모델이 다양한 C-rate에서 추정 성능이 향상된 결과를 확인하였다.

3.4 SOC 추정에서 모델 파라미터의 영향

모델 파라미터는 모델의 구성이나 훈련 과정에 필요한 파라미터로 레이어, 유닛, 배치 사이즈, 에포크 등이 해당된다. 이 장에서는 동적인 프로파일에서 적합한 추정 정확도를 얻기 위해 레이어, 유닛 두 가지의 파라미터를 선정하고 실험을 통해 정확도를 비교한다. 선정된 파라미터를 제외한 모델 파라미터는 모두 동일하게 설정한다. 실험에 사용한 훈련 데이터는 3.3절에서 얻은 다양한 방전 크기 데이터와 UDSS 프로파일이다. 검증 데이터는 SOC 50%의 UDSS 프로파일로 모델의 적합성을 판단한다. 우선 그림 9와 표 6은 각각 계산 유닛 수 차이에 따른 추정 SOC와 모델의 성능 지표를 나타낸다. 하나의 레이어에 각각 64, 128, 256, 512개의 유닛을 가진 모델로 실험을 수행하였다. 실험 결과 유닛의 수가 많을수록 추정 정확도는 높아지는 경향을 보였으나 유닛수가 512개일 때는 오히려 추정 정확도가 떨어졌다. 이는 과적합이 발생하였으며 동일 배치사이즈와 에포크라면 유닛의 수 차이에 따라 과적합이 발생하여 정확도가 떨어질 수 있다.

다음으로 레이어 수 차이에 따른 모델 성능을 비교한다. 각 1, 2, 4개의 레이어를 포함하는 모델 3개를 각각 학습하고 성능을 비교한다. 다수의 레이어를 사용하기 때문에 각 모델은 드롭 아웃층을 포함한다. 그림 10은 레이어 수에 따른 추정 SOC이다. 표 7은 레이어 수 증가에 따라 모델 성능이 낮아지는 것을 나타낸다. 이는 데이터의 양이 풍부하지 않은 상황에서 레이어 수의 증가는 모델 성능이 저하될 수 있음을 보여준다. 두 가지 모델 파라미터를 선정하여 실험한 결과 유닛의 수가 128개인 레이어 1개와 드롭아웃을 포함한 모델의 성능이 MAE 0.62%, RMSE 0.82%, MAX 2.54%로 가장 좋은 것으로 나타난다.




Fig. 9. SOC estimation on the different number of units. 그림 9. 유닛 수 차이에 따른 SOC 추정

Table 6. Performance of LSTM model on the different number of units.

표 6. 유닛 수 차이에 따른 LSTM 모델 성능

Number of units	MAE	RMSE	MAX
64	0.66	0.86	2.85
128	0.62	0.85	2.62
256	0.67	0.86	2.58
512	8.71	9.31	23.9




Fig. 10. SOC estimation on the different number of layers. 그림 10. 레이어 수 차이에 따른 SOC 추정

Table 7. Performance of LSTM model on the different number of layers.

표 7. 유닛 수 차이에 따른 LSTM 모델 성능

Number of layers	MAE	RMSE	MAX
1	0.62	0.82	2.54
2	0.66	0.90	3.78
4	0.99	1.45	5.80

III. 결론

본 논문에서는 직접 측정이 불가능한 리튬 이온 배터리 SOC를 추정하기 위해 시간 종속성을 학습할 수 있는 LSTM 네트워크를 사용하였다. 훈련과 검증에 필요한 데이터는 전기적 실험을 통해 일정 크기로 방전된 전류, 전압, 온도를 수집하였다. 인공지능 알고리즘에서 데이터의 양과 질이 추정 정확도에 큰 영향을 주는 만큼 데이터 전처리를 수행하였다. 방전 실험 데이터를 통해 동적인 프로파일 추정을 위해서는 다양한 방전 크기의 데이터가 필요하다는 것을 확인하고, 정확도 향상에 영향을 미

치는 모델 파라미터를 선정하여 실험을 수행하였다. 그 결과 과적합이 발생하는 모델 파라미터의 조건을 확인하고 드롭 아웃과 파라미터 조절을 통해 LSTM 모델을 구현하였다. 추가적으로 다양한 종류의 주행 프로파일로 훈련을 한다면 정확도 향상에 도움을 줄 것이라고 생각한다.

References

- [1] Alicia K. Birky, "Modeling for Light and Heavy Vehicle Market Analysis," *Energetics, 2015 Department of Energy*, 2015.
- [2] M. A. Hannan, M. S. H. Lihu, A. Hussain, A. Mohamed, "A review of lithium-ion battery state of charge estimation and management system in electric vehicle application: Challenges and recommendations," *Renewable and Sustainable Energy Reviews*, vol.78, pp.834-854, 2017.
- [3] L. Lu, X. Han, J. Li, J. Hua, and M. Ouyang, "A review on the key issues for lithium-ion battery management in electric vehicles," *Journal of Power Sources*, vol.226, pp.272-288, 2013. DOI: 10.1016/j.jpowsour.2012.10.060
- [4] C. Huang, Z. Wang, Z. Zhao, L. Wang, C. S. Lai, and D. Wang, "Robustness evaluation of extended and unscented Kalman filter for battery state of charge estimation," *IEEE*, vol.6, pp.27617-27628, 2018. DOI: 10.1109/ACCESS.2018.2833858
- [5] Kong Soon Ng, Chin-Sien Moo, Yi-Ping Chen, Yao-Ching Hsieh, "Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries," *Applied Energy*, vol.86, No.9, pp.1506-1511, 2009. DOI: 10.1016/j.apenergy.2008.11.021
- [6] Saeed Sepasi, Reza Ghorbani, Bor Yann Liaw, "A novel on-board state-of-charge estimation method for aged Li-ion batteries based on model adaptive extended kalman filter," *Journal of Power Sources*, vol.245, pp.337-344, 2014. DOI: /10.1016/j.jpowsour.2013.06.108
- [7] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 2. Modeling and identification," *Journal of Power Sources*, vol.134, pp.262-276, 2004. DOI: 10.1016/j.jpowsour.2004.02.032
- [8] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 3. Modeling and identification," *Journal of power Sources*, vol.134, no.2, pp.277-292, 2004. DOI: 10.1016/j.jpowsour.2004.02.032
- [9] Bo Dai, Yuqi Zhang, Dahua Lin. "Detecting Visual Relationships with Deep Relational Networks," *The IEEE Conference on Computer Vision and Pattern Recognition*, pp.3076-3086, 2017.
- [10] Xiaosong Hu, Shengbo Eben Li, Yalian Yang. "Advanced Machine Learning Approach for Lithium-Ion Battery State Estimation in Electric Vehicles," *IEEE Transaction on Transportation Electrification*, Vol.2, No.2, pp.140-149, 2016. DOI: 10.1109/TTE.2015.2512237
- [11] Yongzhi Zhang, Rui Ziong, HongWen He, Zhiru Liu. "A LSTM-RNN method for the lithium-ion battery remaining useful life prediction," *Prognostics and System Health Management Conference(PHM-Harbin)*, 2017. DOI: 10.3390/en12040660
- [12] Juan Pablo Rivera-Barrera, Nicolas Munoz-Galeano and Henry Omar Samiento-Maldonado "SOC Estimation for Lithium-ion Batteries: Review and Future Challenges," *Journals of Electronics*, Vol.6, No.4, pp.102, 2017. DOI: 10.3390/electronics6040102
- [13] Juan Carlos Álvarez Antón, Paulino José García Nieto, Cecilio Blanco Viejo, José Antonio Vilán Vilán, "Support Vector Machines Used to Estimate the Battery State of Charge," *IEEE Transactions on Power Electronics*, vol.28, pp. 5919-5926, 2013. DOI: 10.1109/TPEL.2013.2243918
- [14] Xiangbao Song, Fangfang Yang, Dong Wang, and Kwok-Leung Tsui, "Combined CNN-LSTM Network for State-of-Charge Estimation of Lithium-Ion Batteries," *IEEE Access*, vol.7, pp.88894-88902, 2019. DOI: 10.1109/ACCESS.2019.2926517
- [15] Sutskever I. Training recurrent neural networks. Doctoral; 2013.

[16] Hochreiter S, Schmidhuber J. "Long short-term memory," *Neural Computation*, vol.9(8), pp. 1735-80, 1997.

[17] Kingma DP, Ba J. "Adam: a method for stochastic optimization," *CoRR*, vol.abs/1412.6980, 2014.

[18] Zhe Li, Jun Huang, Bor Yann Liaw, Jianbo Zhang, "On state-of-charge determination for lithium-ion batteries," *Journal of Power Sources*, vol.348, pp.281-301, 2017.

DOI: 10.1016/j.jpowsour.2017.03.001

BIOGRAPHY

Seon-Ri Hong (Member)



2013 : BS degree in Computer Science, Hanbat National University.
2019~current : MS degree in Electrical Engineering, Chungnam National University.

Seon-Ri Hong (Member)



2015 : B.S degree in Electrical Engineering, Jeonbuk National University.
2017 : M.S degree in Electrical Engineering, Jeonbuk National University.

2018~Current : Researcher, Korea Institute of Energy Research (KIER)

Gun-Woo Kim (Member)



2019 : BS degree in Electrical Engineering, Chungnam National University.
2019~current : MS degree in Electrical Engineering, Chungnam National University.

Hak-Geun Jeong (Member)



1996 : BS degree in Electrical Engineering, Chonnam National University.
1998 : MS degree in Mechatronics Engineering, Gwangju Institute of Science and Technology.

2013 : Ph.D degree in Mechanical and Aerospace Engineering, Seoul National University.

1998~Current : Principal Researcher, Korea Institute of Energy Research

Jong-Bok Beak (Member)



2007 : BS degree in Electrical Engineering, Kyungpook National University.

2014 : Ph.D degree in Electrical Engineering, Seoul National University.

2014~2015 : Senior Research, Samsung Electronics.
2015~current : Senior Research, Korea Institute of Energy Research.

Jong-Hoon Kim (Member)



2005 : BS degree in Electrical Engineering, Chungnam National University.

2012 : Ph.D degree in Electrical engineering and Computer Science, Seoul National University.

2012~2013 : Senior Researcher, ESS Development Group, Samsung SDI.

2013~2016 : Assistant professor, Chosun University.

2016~current : Assistant professor, Chungnam National University.