

신경회로망 기반 리튬 배터리 멀티 셀의 SOC 추정

이종현*, 이인수**

SOC Estimation of Lithium Battery Multi-cells using Neural Networks

JongHyun Lee*, InSoo Lee**

요약

현재 다양한 시스템에서 배터리팩이 동력원으로 사용되고 있다. 배터리팩의 구성 시 내부 셀 간 전압 편차가 심할 경우 과방전이 발생하며 이는 폭발사고와 같은 안전상의 문제가 발생한다. 이러한 문제를 방지하기 위해서는 배터리의 SOC가 중요한 지표로 사용되며, SOC는 배터리의 내부 파라미터를 통해 간접적으로 추정된다. 따라서 본 연구에서는 배터리의 내부 파라미터와 SOC의 관계를 모델링 할 수 있는 신경회로망 기반 배터리 멀티 셀의 SOC 추정 모델을 제안한다. 본 연구는 제작한 주행 시뮬레이터를 통해 배터리의 충방전 실험을 진행하였고 실험 데이터로부터 MNN, LSTM 그리고 GRU의 총 3가지 신경회로망 모델을 사용하여 멀티 셀의 SOC 추정 모델의 성능을 비교하였다. 비교 결과 추정오차가 LSTM 모델이 1.45, MNN 모델은 1.57 그리고 GRU 모델이 1.63으로 세 가지 모델 중 LSTM 모델이 가장 성능이 우수함을 확인하였다.

Abstract

Currently, battery packs are used as power sources in various systems. When configuring a battery pack, if the voltage deviation between internal cells is severe, over-discharge occurs, which causes safety problems such as explosion accidents. In order to prevent these problems, the SOC is used as important indicator, SOC is indirectly estimated through internal parameters of the battery. Therefore, this research proposes an SOC estimation model of a battery multi-cell based on a neural network, which can model the relationship between the internal parameters of the battery and the SOC. This research conducted a battery charge/discharge test using the manufactured driving simulator and compared the performance of the SOC estimation model of multi-cell using three neural network models, MNN, LSTM, and GRU from the experimental data. As a result of comparison, the estimation error is 1.45 for the LSTM model, 1.57 for the MNN model, and 1.63 for the GRU model. Among the three models, it was confirmed that the LSTM model had the well performance.

Keywords

lithium battery, battery management system, state of charge, MNN, LSTM, GRU

* 경북대학교 전자전기공학부 박사과정
- ORCID: <http://orcid.org/0000-0002-9943-4698>
** 경북대학교 전자전기공학부 교수(교신저자)
- ORCID: <http://orcid.org/0000-0001-9773-4710>

· Received: Mar. 20, 2023, Revised: Apr. 06, 2023, Accepted: Apr. 09, 2023
· Corresponding Author: InSoo Lee
School of Electronic and Electrical Engineering, Kyungpook National University,
80 Daehakro, Bukgu, Daegu, 702-701, Korea
Tel.: +82-53-950-7843, Email: insoolee@knu.ac.kr

1. 서 론

4차 산업혁명 시대를 구현할 가장 중요한 요소 중 하나로 배터리가 주목받고 있다. 미래 산업에 있어 배터리는 IoT 제품을 비롯한 에너지 저장장치 그리고 친환경 운송 수단까지 사용되는 중요한 동력원이다[1]-[3]. 이때, 고전압이 필요한 시스템에서는 배터리 셀의 직렬 연결을 통해 배터리팩을 구성한다. 하지만 이러한 배터리팩의 구성 시 배터리팩 내부 셀 간 전압 편차가 심할 경우 과방전이 발생하며 이는 배터리 내부 단락과 같은 손상이 발생하며 이를 방지하면 배터리팩의 고장 또는 화재와 같은 안전상의 문제가 발생한다[4]. 이러한 배터리의 고장을 미리 방지하기 위해 배터리팩의 내부 셀의 전압 불균형 감지 및 제어할 수 있는 배터리 관리 시스템(BMS, Battery Management System)를 통한 지속적인 배터리 셀의 모니터링이 필요하다.

배터리 셀 간의 전압 불균형을 감지하기 위해 배터리 잔존량(SOC, State of Charge)이 중요한 지표로 사용된다. SOC는 운용 중인 배터리에서 직접 측정이 불가능하므로 배터리의 전압, 전류 등 내부의 정보를 이용하여 간접적으로 추정한다. 하지만 배터리는 외부 환경 조건에 따라 배터리의 특성이 변화함으로 이러한 비선형적인 특성을 학습하는 방법의 연구가 필요하다.

현재 배터리의 SOC를 추정하는데 사용되는 방법은 모델 기반 방법(Model-based method), 데이터 기반 방법(Data-driven method), 그리고 쿨롱 계수(Coulomb counter) 방법이 대표적이다[5]-[7]. 모델 기반 방법은 시스템에 대한 높은 이해를 바탕으로 수학적 또는 물리적 모델을 설정하고 측정된 데이터를 사용하여 모델의 매개변수를 업데이트하고 이를 통해 미래 예측하는 방법으로, 적은 데이터로도 높은 정확도를 결과를 얻을 수 있는 장점이 있지만, 정확한 동작 환경 또는 동일한 배터리 모델과 같은 엄격한 조건에서만 정확한 성능을 보인다[8][9]. 쿨롱 계수 방법은 배터리의 충방전 전류를 측정하고 이를 통합하여 배터리의 용량을 구하는 방법이다. 간단하게 구현할 수 있다는 장점이 있지만, 장기간 사용 시 추정 오차가 누적되어 정확도가 낮아지는

단점이 있다[10][11]. 이에 반해 데이터 기반 방법은 방대한 수집 데이터를 통해 배터리 SOC와 측정 변수 간의 비선형 관계를 직접 모델링한다. 하지만 추정 성능이 훈련 데이터의 품질과 양에 의해 크게 좌우된다는 단점이 있다[12][13].

기존의 SOC 추정 연구들은 배터리 단일 셀만 이용하거나 시뮬레이션을 통해 배터리를 모델링하여 SOC를 추정하는 연구들이 진행되었다. 따라서 배터리팩 내부의 배터리 셀 간의 전압 편차 및 에너지 불균형으로 인해 SOC 오차를 추정하기 힘들다는 단점이 있다. 따라서 실제 배터리팩을 구성하고 각 셀에 대한 SOC 추정 방법에 관한 연구가 필요하다.

본 논문에서는 배터리팩 내부의 멀티 셀의 모니터링을 위해 신경회로망 기반 리튬 배터리 SOC 추정을 위해 배터리 관리 시스템과 차량 주행 시뮬레이터를 제작하였다. 배터리 관리 시스템은 직렬 연결된 멀티 셀의 정보를 획득하기 위해 전자식 스위치를 사용하여 각 셀과 배터리팩의 전압 및 부하에 흐르는 전류 데이터를 획득하였다. 또한 실제 환경에서의 배터리 운용에 따른 SOC 변화를 확인하기 위해 차량 주행 시뮬레이터를 제작하였고 미국 환경 보호국에서 공인된 차량 주행 사이클인 FTP-75를 기반으로 하여 배터리 방전 실험을 진행하였다. 시뮬레이터의 주행 사이클에 따라 변화하는 배터리의 전압 및 전류 그리고 운용시간을 실시간으로 확인 및 데이터 획득 후 신경회로망 학습을 통해 SOC를 추정하였고 오차를 비교하였다.

본 논문의 구성은 다음과 같다. 2장은 배터리팩의 SOC 추정 실험에 사용된 배터리 관리 시스템의 회로 구성 및 차량 주행 시뮬레이터의 제작과정에 관해 기술하였다. 3장에서는 멀티 셀의 SOC 추정 알고리즘과 사용한 신경회로망인 다층신경회로망(MNN, Multilayer Neural Network)과 LSTM(Long Short-term Memory), GRU(Gated Recurrent Unit)을 소개한다. 4장에서는 실험 과정과 세 개의 신경회로망 모델의 SOC 추정 결과 비교를 기술하였다. 마지막으로 5장에서는 본 연구의 결론과 추후 연구 계획을 기술하였다.

11. 배터리 관리 시스템 및 차량 시뮬레이터 제작

2.2 차량 주행 시뮬레이터 제작

2.1 배터리 관리 시스템의 구성

그림 1은 본 논문에서 실험에 사용한 배터리 관리 시스템의 회로의 구성도를 나타낸다. 배터리 관리 시스템 회로는 배터리팩의 내부의 각 배터리 셀의 정보를 획득하기 위해 전자식 스위치인 릴레이(Relay)와 배터리의 각 셀의 전압 그리고 배터리팩과 부하 사이에 흐르는 전류를 측정하기 위한 아날로그-디지털 변환기(ADC, Analog-to-Digital Converter) 그리고 시스템을 구동하는 마이크로컨트롤러(MCU, Microcontroller Unit)와 배터리팩에서 MCU에 전력을 공급하기 위한 DC-DC 컨버터로 구성된다.

배터리 관리 시스템의 동작 방식은 배터리팩이 부하에 연결되었을 때 각 배터리 셀의 +극과 -극에 각각 연결된 릴레이들이 순서대로 여닫으면서 순차대로 배터리 셀의 정보를 읽어온다. 읽어온 배터리 데이터는 ADC를 통하여 디지털 신호로 MCU에 입력되고 MCU는 수집한 각 배터리 셀의 전압과 배터리팩의 전압 및 전류를 PC로 전송한다. PC는 전송받은 데이터를 리튬 배터리의 SOC 추정 모델에 입력하고 각 셀의 SOC를 추정한다.

본 논문에는 실제 환경에서 운용으로 인한 배터리팩의 특성 변화와 배터리팩의 각 셀의 SOC의 변화를 확인하기 위하여 차량 주행 시뮬레이터를 제작하였다[14]. 시뮬레이터의 구성은 24V, 7400rpm의 DC 모터 2개, 프레임 및 타이어, 아두이노 pro-mini, 그리고 모터 드라이버(L298N)로 구성되어 있다. 그림 2은 제작한 차량 주행 시뮬레이터의 구성도를 나타낸다.




그림 2. 차량 주행 시뮬레이터의 구성도
Fig. 2. Configuration of vehicle driving simulator

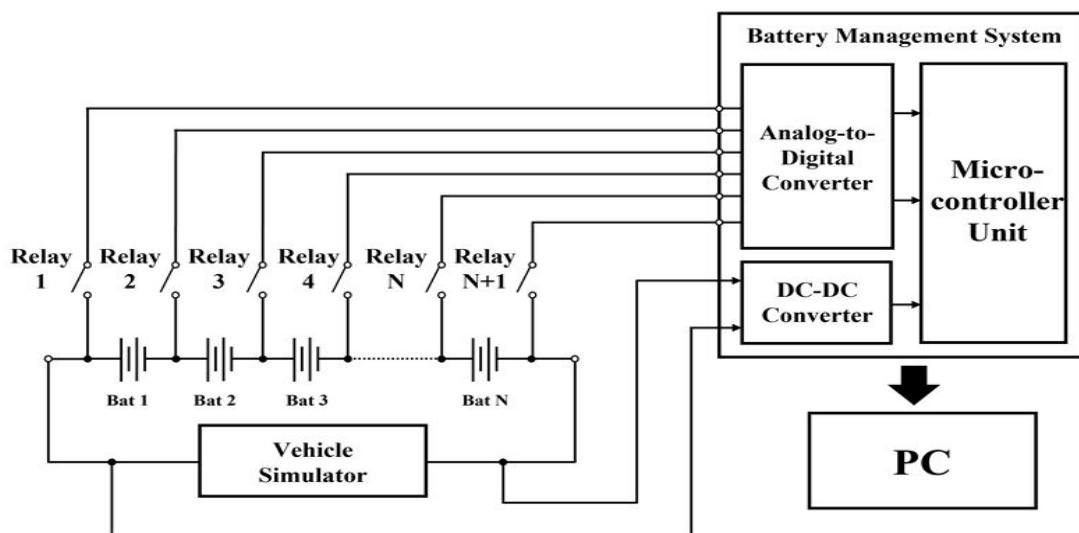


그림 1. 배터리 관리 시스템의 구성도
Fig. 1. Configuration of the battery management system

본 논문의 주행 시뮬레이터의 속도를 실제 차량의 속도와 근사하게 설정하기 위해 모터의 RPM과 실제 차량의 3단 기어비 및 종합속비, 타이어 규격을 활용하여 설계하였다. 차량의 속도를 구하는 계산식은 식 (1)과 같다[15].

$$Velocity = [60 \times 3.14 \times \left\{ \frac{(w \times 0.02 \times f) +}{(25.4 \times s)} \right\} \times RPM] / (g \times c \times 1,000,000) \quad (1)$$

여기서 w 는 타이어의 단면폭(Section width), f 는 타이어의 편평비(Flat ratio), s 는 타이어의 크기(Size), g 는 차량의 기어비(Gear ratio), c 는 차량의 종합속비(Comprehensive reduction cost)이다. 시뮬레이터의 모델로 사용한 차량은 현대자동차의 아반떼 스포츠(AD) 16년식이며, 타이어의 규격은 225/40/18을 사용하였다. 아반떼 스포츠(AD)의 3단 기어비와 종합속비는 각각 1.294와 4.467이다.

차량의 주행 사이클은 미국 환경 보호국에서 정의한 도심 및 시가지 주행 주기로 사용되는 FTP-75을 사용하였다. FTP-75는 그림 3와 같이 저온 시동 단계(Cold start), 안정화 단계(Stabilized phase), 고온 시동 단계(Hot start)와 같이 3개의 주행 단계와 1개의 휴지기간(Soaking period)으로 이루어져 있다[16].

III. 제안한 신경회로망 기반 배터리 멀티 셀 SOC 추정 알고리즘

3.1 배터리의 SOC 추정 방법

본 논문에서는 배터리팩 내부의 멀티 셀의 모니

터링을 위한 신경회로망 기반 SOC 알고리즘을 제안한다. 실제 환경에서의 SOC 추정성능을 확인하기 위해 정전류 방전이 아닌 실제 차량의 주행 사이클을 사용한 차량 주행 시뮬레이터를 사용하였다.

실험에 사용된 배터리팩은 정격용량이 2000mAh의 리튬 이온 배터리 8개를 직렬 연결하여 구성하였으며, 배터리팩의 데이터는 배터리 관리 시스템을 통해 각 셀의 전압, 배터리팩의 전압 및 전류 그리고 운용 시간 데이터를 획득하고 이를 PC로 전송한다. 그 후 획득한 데이터들을 신경회로망 모델의 입력 파라미터로 사용하여 배터리팩 내부의 멀티 셀의 SOC를 추정하고 성능을 검증하였다. 입력 파라미터로는 각 배터리 셀의 전압, 배터리팩의 전압 및 전류 그리고 배터리의 운용 시간 총 11개의 매개변수를 사용하였고 이는 그림 4에 나타낸다.

3.2 다층신경회로망(Multilayer neural network)

본 논문에서는 리튬 배터리의 비선형 특성을 학습한 SOC 추정 모델을 구현하기 위하여 신경회로망 모델 중 MNN과 순환신경회로망의 일종인 LSTM 과 GRU 모델을 사용하였다. MNN은 일반적으로 사용되는 모델 중 하나이며 입력층과 출력층 사이에 하나 이상의 은닉층이 존재하는 구조이며 그림 5와 같다.

다층신경회로망은 역전파 알고리즘을 통해 출력층에서 발생한 오차를 입력층으로 역전파 하여 가중치를 업데이트하고 오차를 최소화한다. 가중치를 업데이트하기 위한 다양한 방법이 있으며 본 논문에서는 Adam 알고리즘을 사용하였다.




그림 3. FTP-75의 주행주기 그래프

Fig. 3. Graph of driving cycle FTP-75

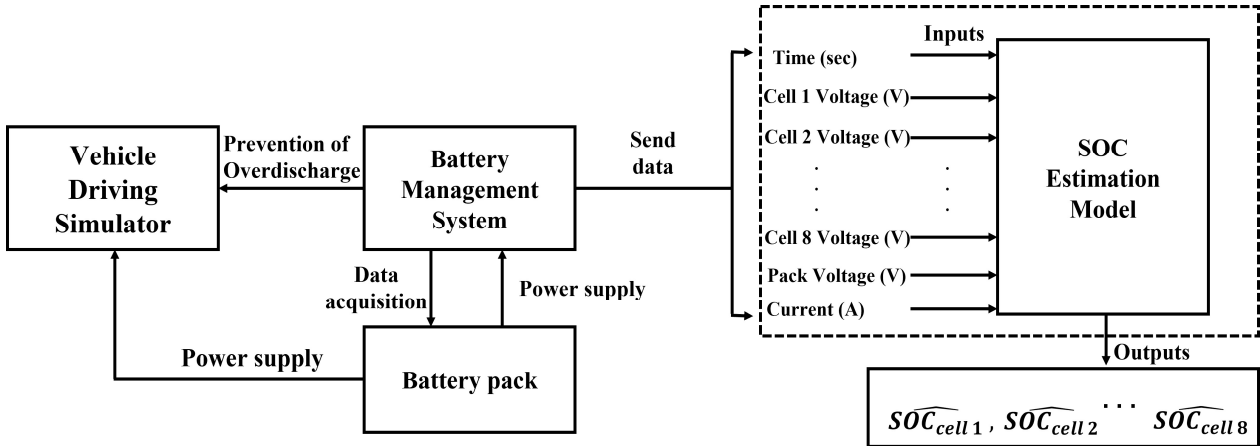


그림 4. 신경회로망 기반 배터리 멀티 셀 SOC 추정 알고리즘 구성도
 Fig. 4. SOC estimation algorithm of battery multi-cell based on neural networks




그림 5. MNN의 구조
 Fig. 5. Structure of a MNN

Adam 알고리즘은 모멘텀과 지수 가중 이동 평균을 사용하여 가중치 업데이트 시 관성과 적응적 학습률을 갖는 알고리즘이다. 아담 알고리즘은 구현이 간단하고, 계산 효율이 높으며, 복잡한 데이터를 사용하는 문제에 적합하다는 장점이 있다. Adam 알고리즘은 식 (2)-(6)에 나타낸다.

$$m_t = \beta_1 m_t + (1 - \beta_1) \nabla_{\theta} f(\theta) \quad (2)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) (\nabla_{\theta} f(\theta))^2 \quad (3)$$

m 과 v 의 초기값이 0일 때, 학습 초기에 가중치들이 0으로 편향되는 경향이 있다. 편향을 잡아주기 위해 식 (4)(5)에 의해 편향 보정(Bias correction)을 계산하고 최종적으로 식 (6)이 최종 가중치 업데이트 계산식이 된다.

$$\hat{m}_t = \frac{m_t}{1 - \beta_1} \quad (4)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2} \quad (5)$$

$$\theta = \theta - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t \quad (6)$$

여기서 m_t 는 가중치의 1차 모멘텀 추정치, v_t 는 2차 모멘텀 추정치이다. β_1 과 β_2 는 모멘텀 추정치에 대한 지수적 감쇠율이다. 본 논문에서는 $\beta_1 = 0.9$, $\beta_2 = 0.999$ 로 설정하였다. t 는 시간 간격(Time step), θ 는 가중치를 의미하며, $\nabla_{\theta} f()$ 는 활성화 함수이다. ϵ 는 10^{-8} 의 상수이다.

3.3 LSTM(Long Short-term Memory)

LSTM은 기존의 순환신경회로망의 은닉층의 과거의 정보가 마지막까지 전달되지 못하는 장기 의존성 문제를 해결한 개선된 모델이다. LSTM은 기존의 순환신경회로망 모델에 셀 상태(Cell state)와 게이트(Gate)를 추가하여 장단기의 과거의 정보 저장이 가능하다. LSTM은 셀 상태와 망각, 입력 그리고 출력 게이트로 구성된다. LSTM의 구성은 그림 6과 같으며 동작 알고리즘은 식 (7)-(12)에 나타낸다.

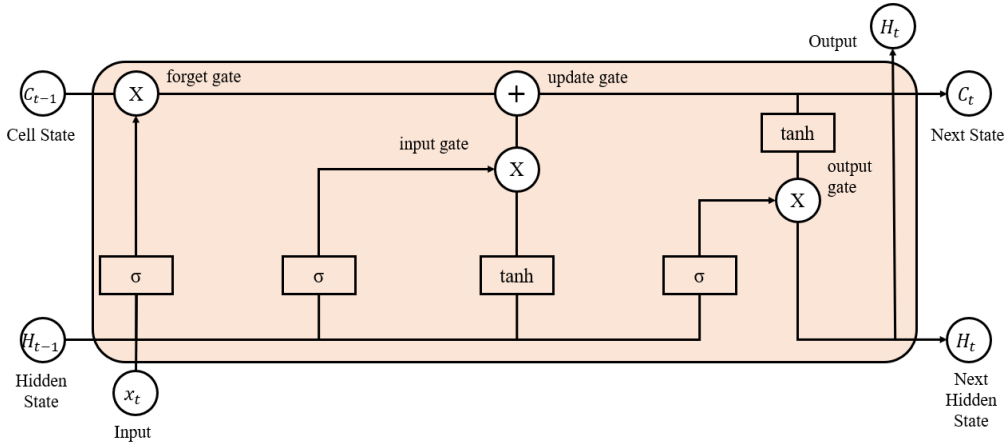


그림 6. LSTM의 구조
Fig. 6. Structure of a LSTM

Step 1. 망각 게이트

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (7)$$

Step 2. 입력 게이트

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (8)$$

$$\tilde{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \quad (9)$$

Step 3. 셀 상태 업데이트

$$C_t = f_t \circ C_{t-1} + i_t \circ \tilde{C}_t \quad (10)$$

Step 4. 출력 게이트

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (11)$$

$$h_t = o_t \circ \tanh(C_t) \quad (12)$$

여기서 h_{t-1} 는 과거의 매개변수이고, x_t 는 현재의 입력 매개변수이다. \circ 는 아다마르 곱(Hadamard product)을 의미한다. W 는 가중치이며 b 는 편향이다. f_t, i_t, o_t 는 각각 망각, 입력, 출력 게이트의 출력값이며 이 3개의 게이트에는 공통으로 시그모이드 함수가 사용되었다. 시그모이드 함수를 지나면 0과 1 사이의 값이 나오게 되는데 이 값을 통해 게이트를 조절한다. C_t 는 셀 상태에서 업데이트된 값이다.

3.4 GRU(Gated Recurrent Unit)

GRU는 기존의 LSTM 구조를 간단하게 개선한

모델이다. LSTM의 경우 망각, 입력, 출력의 총 3개의 게이트로 구성되어 있다면 GRU는 리셋과 업데이트 게이트 총 2개의 게이트로 구성되어 있다. 그리고 LSTM의 셀 상태는 GRU에서 은닉상태(Hidden state)와 합쳐져 하나의 은닉상태로 나타낸다. LSTM에 비해 구조가 단순하여 학습할 매개변수가 적은 것이 장점이다. GRU의 구성은 그림 7과 같으며 동작 알고리즘 식은 식 (13)-(16)에 나타낸다.

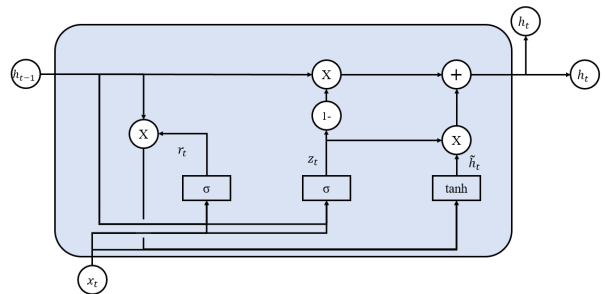


그림 7. GRU의 구조
Fig. 7. Structure of a GRU

Step 1. 리셋 게이트

$$r_t = \sigma(W_r \times [h_{t-1}, x_t]) \quad (13)$$

Step 2. 업데이트 게이트

$$z_t = \sigma(W_z \times [h_{t-1}, x_t]) \quad (14)$$

Step 3. 은닉상태 업데이트

$$\tilde{h}_t = \tanh(W[r_t \circ h_{t-1}, x_t]) \quad (15)$$

$$h_t = (1 - z_t) \circ h_{t-1} + z_t \circ \tilde{h}_t \quad (16)$$

여기서 h_{t-1} 는 과거의 매개변수이고, x_t 는 현재의 입력 매개변수이다. \odot 는 아다마르 곱을 의미한다. W 는 가중치이며 r_t, z_t 는 각각 리셋과 업데이트 게이트의 출력값이다. 리셋과 업데이트 게이트는 시그모이드 함수를 사용하여 0과 1 사이의 값을 통해 게이트를 조절한다. \tilde{h}_t 는 은닉상태 업데이트 값이다.

IV. 실험 및 고찰

본 실험에서는 3.7V, 2000mAh 사양의 리튬이온 배터리 8개를 직렬로 연결한 배터리팩을 대상으로 SOC 추정 실험을 진행하였다. 배터리팩은 차량 주행 시뮬레이터 장착하여 공인된 도심 및 시가지 주행 주기인 FTP-75을 사용하여 배터리의 방전 실험을 진행하였다. 배터리팩의 충전은 배터리 관리 시스템의 스위칭 회로를 통해 셀별로 충전을 진행하였다. 이는 방전 실험 시 전압 불균형 현상을 방지함과 각 셀에 대한 충전 데이터를 획득하기 위함이다. 배터리는 전원 공급기를 사용하여 4.2V와 1A로 셀의 전압이 4.2V에 도달할 때까지 충전을 진행하고 이를 SOC가 100%라고 정의한다. 배터리팩 내부 셀들의 충전이 완료되면 차량 주행 시뮬레이터를 동작하여 배터리팩의 방전을 시작한다. 그림 8은 차량 주행 시뮬레이터의 방전 1주기에 대한 전류 그래프이며, 그림 9는 전류 그래프에 대한 배터리팩 내부의 각 셀의 방전 전압 그래프이다. 학습에 사용한 배터리의 SOC는 각 셀별로 충전하였을 때 획득한 전류 데이터를 적류 적산법을 사용하여 계산하였다. 적류 적산법의 식은 식 (17)과 같다.




그림 8. 차량 주행 시뮬레이터의 방전 전류 그래프
Fig. 8. Discharge current of the vehicle driving simulator




그림 9. 배터리팩 내부의 멀티 셀의 방전 전압 그래프
Fig. 9. Discharge voltage of multi-cells inside the battery pack

$$SOC(t) = SOC(0) - \int_0^t \frac{I(t)}{C_n} dt \quad (17)$$

여기서 $SOC(t)$ 는 시간 t 일때의 SOC 값, $I(t)$ 는 시간 t 일때의 전류 값이다. C_n 는 배터리의 총 용량이며, $SOC(0)$ 는 초기 SOC 값이다.

본 실험에서는 MNN, LSTM, GRU 총 세 개의 신경회로망을 사용하여 SOC 추정 모델을 제작하였다. MNN은 입력층과 출력층 사이에 3개의 은닉층으로 구성하였으며 학습 횟수는 5000으로 설정하였고, 학습 알고리즘은 Adam을 사용하였다. 활성화 함수는 경사함수(ReLU, Rectified Linear Unit)를 사용하였으며 식 (18)과 같이 나타낸다. 실험에 사용된 MNN 모델의 구성은 표 1에 나타낸다.

LSTM은 입력층과 출력층 사이에 3개의 LSTM 레이어를 구성하였으며 학습 횟수는 3000으로 설정하였고, 학습 알고리즘은 Adam을 사용하였다.

$$f = \begin{cases} (x < 0) & f(x) = 0 \\ (x \geq 0) & f(x) = x \end{cases} \quad (18)$$

표 1. 실험에 사용된 MNN 모델의 구성
Table 1. Configuration of the MNN model

Layer	Node	Active function
Input	11	None
Hidden 1	128	ReLU
Hidden 2	64	ReLU
Hidden 3	32	ReLU
Output	8	None

활성화 함수는 tanh를 사용하였으며 식 (19)와 같이 나타낸다. 실험에 사용된 LSTM 모델의 구성은 표 2에 나타낸다.

$$\tanh(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (19)$$

표 2. 실험에 사용된 LSTM 모델의 구성
Table 2. Configuration of the LSTM model

Layer	Node	Active function
Input	11	None
LSTM 1	128	tanh
LSTM 2	64	tanh
LSTM 3	32	tanh
Output	8	None

GRU은 입력층과 출력층 사이에 3개의 GRU 레이어를 구성하였으며 학습 횟수는 3000으로 설정하였고, 학습 알고리즘은 Adam을 사용하였다. 실험에 사용된 GRU 모델의 구성은 표 3에 나타낸다.

각 신경회로망 모델의 SOC 추정 성능을 나타내기 위하여 SOC 추정 오차를 MAE(Mean Absolute Error)로 계산하였다. MAE은 식 (20)과 같다.

표 3. 실험에 사용된 GRU 모델의 구성
Table 3. Configuration of the GRU model

Layer	Node	Active function
Input	11	None
GRU 1	128	tanh
GRU 2	64	tanh
GRU 3	32	tanh
Output	8	None

표 4. 차량 주행 시뮬레이터의 데이터를 사용한 각 신경회로망 모델의 배터리팩 내부의 멀티 셀의 SOC 추정 결과
Table 4. SOC estimation error for each neural network model using the vehicle driving simulator data

Models \ Cell number	Cell 1	Cell 2	Cell 3	Cell 4	Cell 5	Cell 6	Cell 7	Cell 8	Average
	LSTM	1.22	1.21	0.72	2.40	1.70	0.97	1.68	1.70
MNN	1.36	1.32	0.92	2.42	1.82	1.12	1.79	1.83	1.57
GRU	1.43	1.41	0.80	2.52	1.90	1.17	1.87	1.90	1.63

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (20)$$

여기서 n은 테스트 데이터의 개수를 의미하며 \hat{y}_i 는 신경회로망 모델에서 추정된 SOC 값, y_i 는 전류 적산법으로 계산한 SOC 값이다.

표 4는 차량 주행 시뮬레이터의 데이터를 사용한 각 신경회로망 모델의 배터리팩 내부의 멀티 셀의 SOC 추정 결과를 나타낸다. MNN, LSTM 그리고 GRU 총 세 개의 모델 사용하여 SOC 추정 결과를 비교 분석한다. 먼저 LSTM을 사용한 모델은 다른 모델보다 모든 셀에서 추정 오차가 낮아 세 모델 중 가장 우수한 성능을 보여주었다. MNN을 사용한 모델은 셀 3을 제외한 나머지 셀들의 추정성능이 GRU를 사용한 모델보다 높음을 확인하였다. 최종적으로 LSTM을 사용한 SOC 추정 모델의 평균오차가 1.45, MNN과 GRU 모델은 각각 1.57과 1.63으로 LSTM, MNN 그리고 GRU 순으로 추정성능이 우수함을 확인할 수 있다. 그림 10은 각 신경회로망 모델의 SOC 추정오차를 그래프를 나타낸다.




그림 10. 각 신경회로망 모델의 SOC 추정오차 그래프
Fig. 10. SOC estimation error of each neural network model

SOC 추정 추이를 나타내기 위해 Cell 3의 각 신경회로망에서의 추정 그래프를 그림 11에서 그림13에 나타낸다.

그림 11은 LSTM 모델에서의 배터리 cell 3에 대한 추정 그래프이다. SOC 60% 부근의 오차를 제외하고는 거의 정확하게 추정하였음을 확인할 수 있다.

그림 12은 GRU 모델에서의 배터리 cell 3에 대한 추정 그래프이다. SOC 60% 부근의 오차는 LSTM 모델과 큰 차이가 없지만 SOC 40% 아래에서는 LSTM 모델보다 오차가 높은 것을 확인할 수 있다.

그림 13은 MNN 모델에서의 배터리 cell 3에 대한 추정 그래프이다. 전체적으로 LSTM 모델보다 오차가 높은 것을 확인할 수 있으며 SOC 10% 아래는 정확한 추정이 되지 않았음을 확인할 수 있다. 따라서, LSTM을 사용한 SOC 추정 모델이 MNN과 GRU를 사용한 모델보다 리튬 배터리의 SOC를 추정하는데 더 효과적임을 확인할 수 있다.




그림 11. LSTM을 사용한 cell 3의 SOC 추정 결과
Fig. 11. SOC estimation result of cell 3 using LSTM




그림 12. GRU를 사용한 cell 3의 SOC 추정 결과
Fig. 12. SOC estimation result of cell 3 using GRU




그림 13. MNN을 사용한 cell 3의 SOC 추정 결과
Fig. 13. SOC estimation result of cell 3 using MNN

V. 결 론

본 논문에서는 배터리팩 내부의 멀티 셀의 모니터링을 위해 배터리 관리 시스템을 제작하고 실제 환경에서의 성능을 검증하기 위해 실제 차량을 모사한 차량 시뮬레이터를 제작하여 실험을 진행하였다. 그 후 획득한 배터리팩의 전압, 전류 그리고 각 셀의 전압과 배터리 운용 시간의 파라미터를 획득하여 신경회로망 모델의 SOC 추정 파라미터로 사용하였다. 실험에는 LSTM, GRU, MNN의 세 개의 신경회로망 모델을 사용하였다. 본 실험에서 LSTM 모델이 MNN 및 GRU 모델보다 모든 셀에서 SOC 추정 오차가 작았으며 평균오차도 LSTM 모델의 경우 1.45, MNN 모델은 1.57 그리고 GRU 모델은 1.63으로 LSTM을 사용한 멀티 셀의 SOC 추정이 세 모델 중 가장 우수한 성능을 보여주었다. 실험 결과는 정전류가 아닌 부하가 있는 실제 차량 주행을 모사한 시뮬레이터의 데이터를 통해 추정된 결과로써 2% 미만의 오차를 보여 실제 환경에서도 추정성능이 우수할 것으로 예상된다.

추후 연구에서는 배터리팩의 열화를 고려한 SOC 추정 및 SOH를 추정하고 이를 기반으로 배터리 셀 밸런싱 및 고장 난 배터리 셀의 진단 및 교체를 진행하는 배터리 관리 시스템의 알고리즘을 적용할 예정이다.

References

[1] Z. Gao, C. S. Chin, J. H. K. Chiew, J. Jia, and C. Zhang, "Design and implementation of a smart

- lithium-ion battery system with real-time fault diagnosis capability for electric vehicles", *Energies*, Vol. 10, No. 10, Sep. 2017. <https://doi.org/10.3390/en10101503>.
- [2] Z. W. Seh, Y. Sun, Q. Zhang, and Y. Cui, "Designing high-energy lithium-sulfur batteries", *Chemical society reviews*, Vol. 45, No. 20, pp. 5605-5634, Jul. 2016. <https://doi.org/10.1039/C5CS00410A>.
- [3] J. H. Park, J. H. Lee, S. J. Kim, and I. S. Lee, "Real-Time State of Charge Estimation for Each Cell of Lithium Battery Pack Using Neural Networks", *Applied sciences*, Vol. 10, No. 23, Dec. 2020. <https://doi.org/10.3390/app10238644>.
- [4] J. Park, J. Kim, M. Lee, B. C. Kim, S. C. Jung, and J. Kim, "Model-based Analysis of Cell-to-Cell Imbalance Characteristic Parameters in the Battery Pack for Fault Diagnosis and Over-discharge Prognosi", *The Transactions of the Korean Institute of Power Electronic*, Vol. 26, No. 6, pp. 381-389, Dec. 2021. <https://doi.org/10.6113/TKPE.2021.26.6.381>.
- [5] S. Wang, P. Takyi-Aninakwa, S. Jin, C. Yu, C. Fernandez, and D. I. Stroe, "An improved feedforward-long short-term memory modeling method for the whole-life-cycle state of charge prediction of lithium-ion batteries considering current-voltage-temperature variation", *Energy*, Vol. 254, Sep. 2022. <https://doi.org/10.1016/j.energy.2022.124224>.
- [6] C. Jiang, S. Wang, B. Wu, C. Fernandez, X. Xiong, and J. Coffie-Ken, "A state-of-charge estimation method of the power lithium-ion battery in complex conditions based on adaptive square root extended Kalman filter", *Energy*, Vol. 219, Mar. 2021. <https://doi.org/10.1016/j.energy.2020.119603>.
- [7] D. N. T. How, M. A. Hannan, M. S. H. Lipu, and P. J. Ker, "State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review", *IEEE Access*, Vol. 7, pp. 136116-136136, Sep. 2019. <https://doi.org/10.1109/ACCESS.2019.2942213>.
- [8] M. Corno, N. Bhatt, S. M. Savaresi, and M. Verhaegen, "Electrochemical model-based state of charge estimation for Li-ion cells", *IEEE Transactions on Control Systems Technology*, Vol. 23, No. 1, pp. 117-127, Apr. 2014. <https://doi.org/10.1109/TCST.2014.2314333>.
- [9] H. He, R. Xiong, and J. Fan, "Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach", *Energies*, Vol. 4, No. 4, pp. 582-598, Mar. 2011. <https://doi.org/10.3390/en4040582>.
- [10] K. S. Ng, C. S. Moo, Y. P. Chen, and Y. C. 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, Sep. 2009. <https://doi.org/10.1016/j.apenergy.2008.11.021>.
- [11] C. Truchot, M. Dubarry, and B. Y. Liaw, "State-of-charge estimation and uncertainty for lithium-ion battery string", *Applied energy*, Vol. 119, pp. 218-227, Apr. 2014. <https://doi.org/10.1016/j.apenergy.2013.12.046>.
- [12] M. F. Ng, J. Zhao, Q. Yan, G. J. Conduit, and Z. W. Seh, "Predicting the state of charge and health of batteries using data-driven machine learning", *Nature Machine Intelligence*, Vol. 2, pp. 161-170, Mar. 2020. <https://doi.org/10.1038/s42256-020-0156-7>.
- [13] P. M. Attia, et al., "Closed-loop optimization of fast-charging protocols for batteries with machine learning", *Nature*, Vol. 578, pp. 397-402, Feb. 2020. <https://doi.org/10.1038/s41586-020-1994-5>.
- [14] S. J. Kim, J. H. Lee, D. H. Wang, and I. S. Lee, "Vehicle Simulator and SOC Estimation of Battery using Artificial Neural Networks", *Journal of KIIT*, Vol. 19, No. 5, pp. 51-62, May 2021. <http://dx.doi.org/10.14801/jkiit.2021.19.5.51>.

- [15] Engineers Edge, https://www.engineersedge.com/mechanics_machines/transmission-gear-ratio-calculator.htm [accessed: Apr. 05, 2023]
- [16] J. Y. Chang, Y. J. Lee, O. S. Kwon, and J. H. Kim, "Comparing Exhaust Gas Emission and PN in LPG and CNG Vehicle under FTP-75 and WLTC Test Mode", Journal of the Korean Institute of Gas, Vol. 20, No 6, pp. 9-15, Dec. 2016. <https://doi.org/10.7842/kigas.2016.20.6.9>.

저자소개

이 종 현 (JongHyun Lee)



2018년 2월 : 경북대학교
전자공학부(공학사)
2020년 2월 : 경북대학교
전자전기공학부(공학석사)
2020년 3월 ~ 현재 : 경북대학교
전자전기공학부 공학박사과정
관심분야 : 리튬 이온 배터리 SOC
및 SOH 추정

이 인 수 (InSoo Lee)



1986년 : 경북대학교
전자공학부(공학사)
1989년 : 경북대학교
전자공학부(공학석사)
1997년 : 경북대학교
전자공학부(공학박사)
1997년 3월 ~ 2008년 2월 :
상주대학교 전자 및 전기 공학 교수
2005년 8월 ~ 2007년 1월 : 미국 샌디에고 주립대학교
방문학자
2008년 3월 ~ 2014년 10월 : 경북대학교 전자전기공학부
교수
2014년 11월 ~ 현재 : 경북대학교 전자공학과 교수
관심분야 : 배터리 SOC 및 SOH 추정, 시스템 고장진단
및 고장허용제어, 신경회로망 기반 지능제어, 지능형
센서 시스템