

# 차량 시뮬레이터 및 인공신경망을 이용한 배터리의 SOC 추정

김시진\*<sup>1</sup>, 이종현\*<sup>2</sup>, 왕동훈\*<sup>3</sup>, 이인수\*\*

## Vehicle Simulator and SOC Estimation of Battery using Artificial Neural Networks

Si-Jin Kim\*<sup>1</sup>, Jong-Hyun Lee\*<sup>2</sup>, Dong-Hun Wang\*<sup>3</sup>, and In-Soo Lee\*\*

---

이 논문은 2020년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임  
(No. 2020R111A3A04036615).

---

### 요약

최근 들어 리튬 이온 배터리는 높은 전압 밀도와 오랫동안 출력을 유지할 수 있다는 장점이 있어 다양한 분야에서 중요한 에너지원으로 사용되고 있다. 그러나 잦은 충전 및 방전을 하는 배터리의 특성상 과충전 및 과방전은 불가피하며 이로 인한 안전사고 및 재산 손해가 발생할 수 있다. 그러므로 사용자 하여 배터리의 잔존용량(State Of Charge, SOC)를 정확하게 예측하는 연구가 필요하다. 본 논문에서는 차량 주행 시뮬레이터를 사용하여 SOC를 추정하는 방법을 제안한다. 시뮬레이터를 제작하여 배터리의 방전실험을 진행한 후에 전압 및 전류, 방전소요시간 데이터를 획득하였다. 인공신경망 중 하나인 다층신경망(Multi-layer Neural Network, MNN)과 획득한 데이터를 사용하여 배터리의 SOC를 추정하였으며, 성능이 우수함을 확인하였다.

### Abstract

Recently, lithium-ion batteries have been used as an important source of energy in various fields due to their high voltage density and the advantage of being able to maintain power for a long time. However, due to the characteristics of batteries that charge and discharge frequently, overcharging and overdischarging are inevitable, which can result in safety accidents and property damage. Therefore, research is needed to accurately predict the residual capacity (SOC) of a battery by the user. In this paper, we propose a method for estimating SOC using vehicle driving simulator. Simulator was built to conduct discharge experiments on batteries, and voltage and current, and discharge-time data were obtained. Using one of the artificial neural networks, the Multi-layer Neural Network (MNN), and acquired data, we estimated the SOC of the battery and found its performance to be excellent.

### Keywords

lithium-ion battery, state of charge, multi-layer neural network, vehicle driving simulator

---

\* 경북대학교 전자전기공학부

- ORCID<sup>1</sup>: <http://orcid.org/0000-0002-5064-6120>

- ORCID<sup>2</sup>: <http://orcid.org/0000-0002-9943-4698>

- ORCID<sup>3</sup>: <http://orcid.org/0000-0002-5180-5373>

\*\* 경북대학교 전자전기공학부 교수(교신저자)

- ORCID: <http://orcid.org/0000-0001-9773-4710>

· Received: Apr. 16, 2021, Revised: May 11, 2021, Accepted: May 14, 2021

· Corresponding Author: In-Soo 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](mailto:insoolee@knu.ac.kr)

## I. 서 론

현재 리튬 이온 배터리는 전압 밀도가 높고 출력을 오랫동안 유지할 수 있으며 중량이 가벼운 특성이 있어 전기자동차(Electronic Vehicle, EV), 휴대폰, 노트북, 대용량 에너지저장장치(Energy Storage System, ESS) 등의 다양한 분야의 핵심 동력으로 사용되고 있다[1][2]. 그러나 잦은 충전 및 방전을 하는 배터리의 특성상 과충전 및 과방전이 발생할 수가 있으며, 이런 경우 시스템이 다운되거나 배터리가 폭발할 위험이 있다. 이와 같은 문제점을 해결하기 위해서 배터리의 상태를 정확하게 파악하여 배터리의 효율적이고 안정적인 운용을 할 수 있도록 보조해주는 배터리 관리 시스템(Battery Management System, BMS)의 연구가 진행 중이다. BMS에서 사용할 수 있는 파라미터 중 하나인 잔존용량(State Of Charge, SOC)은 배터리의 남은 용량을 표시할 수 있는 중요한 척도이며 100%일 때 배터리가 가득 찬 상태를, 0%일 때 모두 소모된 상태를 나타낸다. 따라서 사용자로 하여 더욱 안정적이고 효율적인 배터리 운용을 위해 SOC를 정확하게 예측할 수 있어야 한다.

기존의 SOC 추정방법으로 전류적산법, 개방회로 전압(Open Circuit Voltage, OCV), 칼만필터추정법이 있다. 전류적산법은 임의의 초기 SOC를 지정한 후 충전 및 방전 전류의 변화량을 더해주는 방식으로 구현하기 용이한 장점이 있다. 하지만 초기 SOC 설정에 이상이 있는 경우 오차가 지속적으로 누적되어 정확한 SOC 추정이 어렵다[3]. OCV는 배터리에 전류가 흐르지 않는 안정된 상태에서 전압을 측정하여 SOC 추정을 할 수 있으나 측정을 위해서 평형상태가 되기까지 긴 시간을 대기해야 하므로 실시간으로 추정이 어렵다[4]. 확장 칼만 필터 방법은 비선형적 모델의 상태를 추정하기 유리하지만, 선형화할 시 초기 상태 설정이 잘못되면 오차가 심각하게 커지는 문제가 있어 아직 관련 연구가 계속 진행되고 있다[5].

최근 SOC 추정방법 중 하나로 빅 데이터 기반 방법이 있다. 대표적으로 기계학습 기법 중 인공지능망(Artificial Neural Network, ANN) 학습을 통한

SOC 추정방법이 있다[6]. 인공지능망은 생물학적 모델의 뇌 구조를 모방하여 설계된 학습 방법으로 패턴 인식, 식별 및 분류와 같은 다양한 분야에서 사용되고 있으며 입력 및 출력 관계를 효율적으로 학습할 수 있다[7]. 인공지능망을 사용한 추정방법은 배터리의 내부의 전기적, 화학적 변화를 고려하지 않아도 되며, 비선형 모델 추정에 유리하고 저사양의 프로세서에서도 동작이 가능하다는 장점이 있다[8][9].

본 논문에서는 실제 차량의 출력에 따른 배터리의 SOC 변화를 확인하기 위해 차량 주행 시뮬레이터를 제작하였다. 시뮬레이터를 제작 후 미국에서 차량의 연비를 측정하기 위해 사용하는 공인된 주행 사이클인 FTP-75(Federal Test Procedure-75)를 기반으로 하여 주행 상황을 구현 후 배터리의 방전실험을 진행하였다. 시뮬레이터의 모터 속도에 따라 변화하는 배터리의 전압 및 전류, 방전소요시간(T)을 실시간으로 확인 및 데이터 획득 후 인공지능망 학습을 통해 SOC 추정을 하였고 오차를 비교하였다.

본 논문의 구성은 다음과 같다. 2장은 배터리의 방전실험에 사용된 차량 주행 시뮬레이터의 내부 구성과 제작과정에 관해 기술하였다. 3장에서는 제안한 SOC 추정 알고리즘과 본 논문에서 사용한 인공지능망의 종류 중 하나인 다층신경망(Multi-layer Neural Network, MNN)을 소개하고 SOC 추정을 위한 다층신경망의 학습 방법을 설명하였다. 4장에서는 제안한 알고리즘의 실험 과정과 입력 파라미터의 개수 및 방전소요시간 사용·유무 따른 SOC 추정결과를 기술하였다. 마지막으로 5장에서는 본 연구의 결론과 추후 연구의 계획을 기술하였다.

## II. 차량 주행 시뮬레이터 제작

본 논문에서는 실제 차량의 출력에 따른 배터리의 SOC 변화를 확인하기 위해 차량 주행 시뮬레이터를 제작하였고 이는 그림 1과 같다. 시뮬레이터 제작에 사용된 장비는 RC Car(Radio Control Car) 프레임 및 타이어, 정격전압 12V 및 6000RPM DC 모터 2개, 모터 드라이버(MDD3A), 아두이노 pro-mini 모듈, DC컨버터로 구성되어 있으며 2WD 차량을 모델로 하여 제작하였다.




그림 1. 차량 주행 시뮬레이터의 구성도  
Fig. 1. Configuration of vehicle driving simulator

사용된 모터의 정격전압이 12V이므로 완전충전 4.2V 배터리 4개를 직렬연결 시킨 후에 DC컨버터를 사용하여 DC모터의 정격전압으로 설정하였다. 모터 드라이버와 아두이노 pro-mini 모듈을 통해 2개의 DC모터의 RPM을 조절하여 실험에 사용되는 시뮬레이션의 주행주기를 도심 및 시가지 주행주기로 사용되는 FTP-75와 흡사하게 설정하였다. 미국 환경 보호국에서 정의한 FTP-75는 CVS-75(Constant Volume Sampler-75)라고 부르기도 하며 차량의 연비 측정 테스트를 위해 설계된 공인된 주행주기로 한국에서도 사용하고 있다. FTP-75는 그림 2와 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[10].

본 논문의 주행 시뮬레이터는 실제 거리를 주행

할 수 없도록 제작하였기 때문에 모터의 RPM과 실제 차량의 3단 기어비 및 종감속비, 타이어 규격(단면폭, 편평비, 휠 사이즈)을 사용하여 FTP-75의 주행주기에 맞게 실제 차량의 속도로 시뮬레이션 하였다. 차량의 속도를 구하는 계산식은 다음과 같다.

$$Velocity = [60 * 3.14 * (w * 0.02 * f)] + (25.4 * s) RPM / (g * c * 1,000,000) \quad (1)$$

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 종감속비(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 종감속비는 각각 1.294와 4.467이다.

그림 3은 제작된 차량 주행 시뮬레이터의 실제 사진이다. 시뮬레이터를 사용한 방전실험 진행 시 모터의 진동으로 인해 시뮬레이터가 움직이거나 균형을 잃는 것을 방지하고자 철제 프레임과 MC나일론 판재를 사용하여 고정하였다.




그림 3. 차량 주행 시뮬레이터  
Fig. 3. Vehicle driving simulator

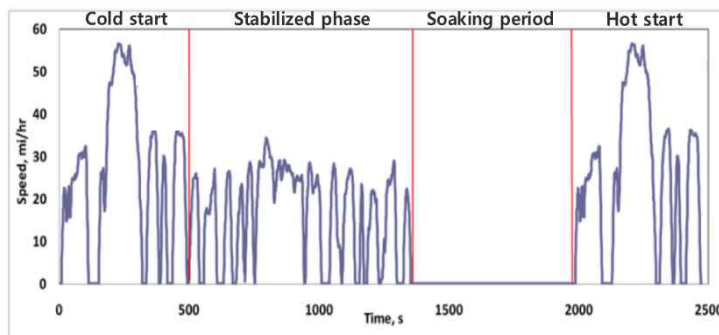


그림 2. FTP-75의 주행주기 그래프  
Fig. 2. Driving cycle graph of FTP-75

### III. 제안한 신경망을 사용한 배터리의 잔존용량(SOC) 추정 알고리즘

#### 3.1 배터리 SOC 추정 방법

본 논문에서는 인공지능망과 차량 주행 시뮬레이터를 사용하여 배터리의 SOC를 추정하는 방법을 제안한다. 실험에 사용된 장비는 직렬로 연결된 4개의 정격용량 1300mAh의 리튬 이온 배터리, 파워 서플라이, 배터리 챔버, 차량 주행 시뮬레이션, 셀 밸런싱 모듈, 전압 센서 및 전류 센서 아두이노 우노로 구성되어 있다. 파워 서플라이는 배터리를 4.2V로 완전충전 시키는 용도로 사용되며 배터리 챔버는 충전 및 방전 시 안전사고를 최소화하기 위한 용도로 사용된다.

그림 4로 본 논문에서 제안한 배터리의 SOC 추정 알고리즘을 표현하였다. 우선 직렬로 연결된 4개의 완전충전 상태의 배터리를 제작한 차량 주행 시뮬레이터를 사용하여 방전시킨다. 방전실험 후 전압, 전류, 방전소요시간(T) 데이터를 PC에 전송한다. 그 후 획득한 데이터들을 인공지능망에 다른 개수의 파라미터로 사용하여 총 4개의 인공지능망 모델로 각 배터리의 SOC를 추정하고 결과를 비교한다.

#### 3.2 다층신경망

배터리의 방전실험을 통해 획득한 데이터를 여러 신경망 중 다층신경망에 학습시켰다. 다층신경망은 그림 5와 같이 단층 퍼셉트론에서 입력층과 출력층 사이에 1개 이상의 은닉층을 추가함으로써 선형함수만으로 구성된다는 제약으로 인해 제한적인 학습밖에 할 수 없는 퍼셉트론의 단점을 보완한 신경망이다.

단층 퍼셉트론에서는 순전파 방식만으로 가중치를 업데이트한다. 순전파 방식은 입력층에서 출력층까지 순서대로 파라미터들을 계산하고 가중치를 업데이트하여 결과값을 가져오는 것을 의미한다.




그림 5. 다층신경망의 구조  
Fig. 5. Structure of MNN

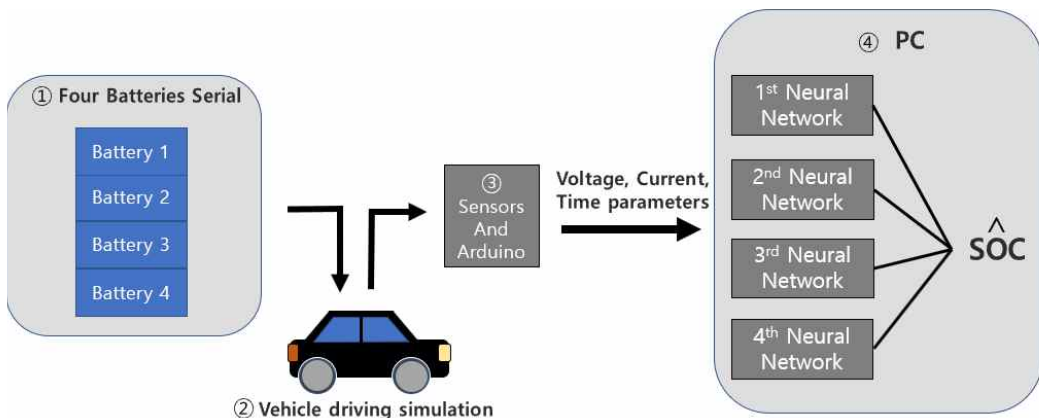


그림 4. 인공지능망과 차량 주행 시뮬레이터를 사용한 배터리의 SOC 추정 다이어그램  
Fig. 4. SOC estimation diagram of batteries using artificial neural networks and vehicle driving simulator

단층 퍼셉트론과 달리 다층신경망은 순전파 및 역전파 방식을 사용하는데 역전파 방식은 순전파 방식과 반대로 출력층에서 입력층의 방향으로 파라미터들에 대한 가중치를 업데이트하면서 오차를 점차 줄여나가는 방법이다. 역전파 방식의 단계는 크게 4단계로 분류된다. 1단계는 기존의 가중치를 사용하여 출력값을 계산한다. 2단계는 오차를 각 가중치로 편미분한 값을 기존의 가중치에서 빼준다. 3단계는 모든 가중치에 대해 2단계가 이루어진다. 마지막으로 4단계는 주어진 학습횟수만큼 1~3단계를 반복한다.

그림 6은 역전파 알고리즘의 개념을 도식적으로 표현한 것이다[11]. 이러한 다층신경망의 학습 방식으로 인해 단층 퍼셉트론과 달리 비선형의 형태로 더욱 복잡하게 표현할 수 있고 분류 및 수치예측에도 유리한 장점이 있다.

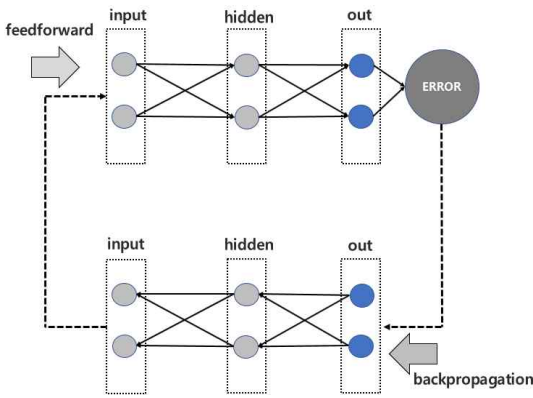


그림 6. 역전파 알고리즘의 개념  
Fig. 6. Schematic of the backpropagation algorithm

역전파 알고리즘의 가중치 업데이트를 하는 과정을 식 (2)부터 식 (6)으로 나타내었다. 우선 순전파 계산에 사용되는 입력값과 출력값은 아래의 식을 통해 구할 수 있다.

$$\neq t_j = \sum_i w_{ij} X_i \quad (2)$$

$$X_j = f(\neq t_j + \theta_j) \quad (3)$$

여기서  $\neq t_j$  는 노드  $j$ 의 입력값,  $w_{ij}$ 는  $j$ 번째 노드에 들어오는  $i$  번째 노드의 가중치,  $f(\neq t_j + \theta_j)$ 는

활성화 함수이다.  $X_i, X_j$ 는  $i$ 와  $j$ 에 들어오는 이전 노드의 출력값이며  $\theta$ 는 입력 바이어스 값이다. 오차에 따라 가중치를 업데이트 할 때 필요한  $\delta$ 의 값은 다음 식으로 구할 수 있다.

$$\delta_i = \lambda(l_i - X_i)f'(X_i) \quad (4)$$

$$\delta_j = \lambda \sum_i \delta_i w_{ji} f'(X_j) \quad (5)$$

여기서  $l$ 는 라벨 값,  $X$ 는 출력값이다. 위 식으로 구한  $\delta$ 를 사용하여 가중치를 업데이트 할 수 있다.

$$w_{ji}(t+1) = w_{ji}(t) + \eta \delta_j y_i \quad (6)$$

여기서  $t$ 는 시간 인덱스,  $\eta$ 는 학습률이다.

#### IV. 실험 과정 및 실험결과

##### 4.1 실험 과정

그림 7은 본 논문의 실제 실험 환경을 나타낸다. 본 실험에서는 차량 주행 시뮬레이터의 동력원으로 직렬로 연결된 4개의 정격용량 1300mAh의 배터리를 사용하였다. 직렬로 연결된 모든 배터리에는 같은 양의 전류가 흐르긴 하지만 여러 번의 충전 및 방전을 하면서 배터리의 충전 상태는 각 배터리의 내부적 화학 특성과 운용 환경에 따라 달라지며 전하 불균형 현상이 발생하게 된다[12].




그림 7. SOC 추정을 위한 실제 실험 환경  
Fig. 7. Actual experimental environment for SOC estimation

따라서 본 실험에서는 충전 및 방전 시 발생하는 전하 불균형 현상을 방지하기 위해 직렬 연결된 배터리들의 전압을 균일하게 만들어 주는 셀 밸런싱 모듈을 사용하였다. 차량 주행 시뮬레이터를 동작하기 전에 4개의 리튬 이온 배터리를 파워 서플라이를 사용하여 각각 4.2V의 정전압으로 완전충전하는 것을 SOC 100%라고 정의하고, 충전 완료 후 평형 상태를 만들기 위해 1시간의 안정화 시간을 가진다. 그 후 차량 주행 시뮬레이터를 사용하여 직렬 연결된 배터리들을 방전시킨다.


그림 8의 (a)부터 (d)는 각 배터리의 1주기 방전 실험 전압 변화의 그래프를 나타낸 것이다. 그림 8의 (d)와 같이 방전실험 시작점부터 직렬로 연결된 4개의 배터리 중 일부가 방전되어 차량 주행 시뮬레이터의 동작이 멈출 때까지를 1주기로 정의한다. 그 후 실험 과정을 반복하여 1주기부터 10주기까지의 전압 및 전류 센서, 아두이노 모듈을 사용하여 다층신경망의 입력 파라미터로 사용할 전압, 전류, 방전소요시간(T) 데이터를 획득 후 PC에 전송한다. 방전소요시간(T)는 방전실험 동안 흘러가는 시간의 누적정보로 그림 9와 같이 정의할 수 있다.

다층신경망의 학습 라벨값으로 사용할 SOC를 계산하기 위해 완전방전 상태의 4개의 배터리를 개별 충전시킨 후에 각 배터리의 임의의 초기 SOC를 지정하고 방전실험으로 획득한 전류 데이터를 전류 적산법을 통해 계산하였다. 전류 적산법의 식은 다음과 같다.


$$SOC(t) = SOC(0) - \int_0^t \frac{I(t)}{C_n} dt \quad (7)$$

여기서 SOC(t)는 시간 t에서의 SOC, I(t)는 시간 t에서의 전류를 뜻하며 SOC(0)는 초기 SOC, C는 배터리의 정격용량을 의미한다.


본 논문에서 사용한 다층신경망 모델의 구조는 그림 10과 같다. 다층신경망 모델에 전압 및 전류 데이터를 각각 2개, 3개, 4개, 5개로 구성된 4개의 다층신경망 모델을 사용하였고, 4개의 모델에 방전 소요시간 파라미터(T)를 사용한 것과 사용하지 않은 것으로 분류하여 학습을 진행하였다.




(a) 배터리 1의 방전 그래프  
(a) Discharge graph of battery 1



(b) 배터리 2의 방전 그래프  
(b) Discharge graph of battery 2



(c) 배터리 3의 방전 그래프  
(c) Discharge graph of battery 3



(d) 배터리 4의 방전 그래프  
(d) Discharge graph of battery 4

그림 8. 각 배터리의 1주기 방전실험 전압 그래프  
Fig. 8. 1 cycle discharge experiment voltage graph of each battery




그림 9. 방전소요시간 파라미터(T)의 정의 그래프  
Fig. 9. Definition graph of discharge time parameter(T)



각 다층신경망 모델의 은닉층은 총 2층으로 첫 번째 은닉층의 노드 수는 128개, 두 번째 은닉층의 노드 수는 64개를 사용하였고 은닉층의 활성화 함수로 ReLU(Rectified Linear Unit)함수를 사용하였다. ReLU는 최근 가장 많이 사용되는 활성화 함수로 시그모이드와 하이퍼볼릭 탄젠트의 기울기 소실 문제를 개선하기 위해 제안되었다[13].




그림 10. 사용한 다층신경망 모델의 학습 구조  
Fig. 10. Learning structure of used MNN models




그림 11. ReLU의 정의 그래프  
Fig. 11. Definition graph of ReLU

그림 11은 ReLU로써, 양의 값일 때 선형으로 표현할 수 있고 음의 값을 0으로 수렴하여 계산이 매우 간단하고 학습의 속도가 매우 빠르다. 각 모델의 출력층의 노드는 1개를 사용하였고 15000번의 횟수로 학습을 반복하였다.

## 4.2 실험 결과

본 논문에서는 다층신경망에 전압 및 전류 입력 파라미터의 개수를 다르게 구성한 4개의 모델로 SOC 추정을 하였고, 그 후에 방전소요시간 파라미터(T)를 추가로 사용하여 SOC 추정을 하였다. 표 1과 그림 12는 방전소요시간 파라미터(T)를 추가하지 않고 학습을 진행한 각 모델의 SOC 오차를 나타낸 것이다. 전압 및 전류 파라미터를 각각 2개씩 사용한 모델을 Model 1, 3개씩 사용한 모델을 Model 2, 4개씩 사용한 모델을 Model 3, 마지막으로 5개씩 사용한 모델을 Model 4로 표기하였다.

표 1. 방전소요시간(T)을 추가하지 않은 모델의 전압 및 전류 입력 파라미터 개수에 따른 SOC 오차  
Table 1. SOC error by number of voltage and current input parameters for the model without adding discharge time(T)

Cell numbers / Input models	Cell 1	Cell 2	Cell 3	Cell 4
Model 1	3.86%	3.94%	5.26%	3.88%
Model 2	3.65%	3.55%	5.1%	2.92%
Model 3	3.86%	3.66%	5.19%	3.58%
Model 4	2.88%	2.71%	3.9%	2.52%




그림 12. 방전소요시간(T)을 추가하지 않은 모델의 전압 및 전류 입력 파라미터 개수에 따른 SOC 오차 그래프  
Fig. 12. SOC error graph by number of voltage and current input parameters for the model without adding discharge time(T)

각 배터리의 오차는 MAE(Mean Absolute Error)로 계산하였다. MAE의 식은 다음과 같다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}| \quad (8)$$

여기서  $n$ 은 계산할 데이터의 양을 의미하며  $y$ 는 전류 적산법을 사용하여 계산된 SOC,  $\hat{y}$ 은 다층신경망 모델에 의해 추정된 SOC를 의미한다.

입력 파라미터의 개수가 각각 2개인 모델의 오차는 배터리 1은 3.86%, 배터리 2는 3.94%, 배터리 3은 5.26%, 배터리 4는 3.88%, 두 번째로 입력 파라미터의 개수가 각각 3개인 모델의 오차는 배터리 1은 3.65%, 배터리 2는 3.55%, 배터리 3은 5.1%, 배터리 4는 2.92%, 세 번째로 입력 파라미터의 개수가 각각 4개인 모델의 오차는 배터리 1은 3.86%, 배터리 2는 3.66%, 배터리 3은 5.19%, 배터리 4는 3.58%, 마지막으로 입력 파라미터의 개수가 각각 5개인 모델의 오차는 배터리 1은 2.88%, 배터리 2는 2.71%, 배터리 3은 3.9%, 배터리 4는 2.52%로 추정되었다. 표 1의 Model 4는 전압 및 전류 파라미터를 각각 5개로 사용한 모델이며 네 모델 중 오차가 전반적으로 작은 것을 확인할 수 있다. 방전소요시간을 사용하지 않은 다층신경망 모델의 최저 오차는 2.52%이며 최대 오차는 5.26%이다.

표 2와 그림 13은 그림 9와 같은 방전소요시간(T) 파라미터를 입력으로 추가하여 학습을 진행한 각 모델의 SOC 오차를 나타낸 것이다. 표 1 및 그림 12와 마찬가지로 MAE를 통해 오차를 계산하였으며 전압 및 전류 파라미터를 각각 2개씩 사용한 모델을 Model 1, 3개씩 사용한 모델을 Model 2, 4개씩 사용한 모델을 Model 3, 마지막으로 5개씩 사용한 모델을 Model 4로 표기하였다.

표 2. 방전소요시간을 입력 파라미터로 추가 후 전압 및 전류 입력 파라미터 개수에 따른 SOC 오차

Table 2. SOC error according to the number of voltage and current input parameter after adding discharge time as input parameters

Cell numbers Input models	Cell 1	Cell 2	Cell 3	Cell 4
Model 1	1.97%	1.83%	1.83%	1.99%
Model 2	1.61%	2.06%	1.65%	2.15%
Model 3	1.72%	1.79%	1.62%	1.76%
Model 4	2.05%	1.84%	2.23%	1.82%

표 1과 표 2를 비교하였을 때 방전소요시간(T)을 입력 파라미터로 추가한 모델이 추가하지 않고 학습을 진행한 모델보다 전체적으로 오차가 줄어들었으므로 방전소요시간(T)을 추가한 다층신경망 모델이 비교적 우수한 추정 성능을 가지는 것으로 판단할 수 있다.





그림 13. 방전소요시간을 입력 파라미터로 추가 후 전압 및 전류 입력 파라미터 개수에 따른 SOC 오차 그래프  
Fig. 13. SOC error graph according to the number of voltage and current input parameter after adding discharge time as input parameters




전압 및 전류의 입력 파라미터 개수가 각각 4개인 모델의 오차는 배터리 1은 1.72%, 배터리 2는 1.79%, 배터리 3은 1.62%, 배터리 4는 1.76%로 배터리의 내부적 화학 특성과 데이터의 정확도에 따라 오차가 차이를 보였지만 다른 개수의 모델에 비해 오차가 전반적으로 작은 것으로 확인할 수 있었다. 입력 파라미터 개수가 각각 5개인 모델의 경우 파

라미터의 개수가 다른 모델에 비해 비교적 많아 데이터 간의 거리가 멀어져 오히려 학습 효율이 떨어지는 것으로 판단된다. 방전소요시간(T) 파라미터를 사용한 모델의 최저 오차는 1.61%, 최대 오차는 2.15%이다. 그림 14부터 그림 17은 방전소요시간(T)을 입력 파라미터로 사용한 모델과 사용하지 않은 모델의 배터리 1의 SOC 오차 그래프를 나타낸 것이다.




(a) 방전소요시간 파라미터(T) 사용  
(a) Discharge Time parameter(T) used




(b) 방전소요시간 파라미터(T) 미사용  
(b) Discharge time parameter(T) not used

그림 14. 전압 및 전류 파라미터가 각각 2인 MNN 모델의 SOC 추정 결과 그래프  
Fig. 14. SOC estimation results graph for MNN models with two voltage and one current parameter respectively




(a) 방전소요시간 파라미터(T) 사용  
(a) Discharge Time parameter(T) used




(b) 방전소요시간 파라미터(T) 미사용  
(b) Discharge time parameter(T) not used

그림 15. 전압 및 전류 파라미터가 각각 3개인 MNN 모델의 SOC 추정 결과 그래프  
Fig. 15. SOC estimation results graph for MNN models with three voltage and one current parameter respectively




(a) 방전소요시간 파라미터(T) 사용  
(a) Discharge Time parameter(T) used




(b) 방전소요시간 파라미터(T) 미사용  
(b) Discharge time parameter(T) not used

그림 16. 전압 및 전류 파라미터가 각각 4개인 MNN 모델의 SOC 추정 결과 그래프  
Fig. 16. SOC estimation results graph for MNN models with four voltage and one current parameter respectively



(a) 방전소요시간 파라미터(T) 사용  
(a) Discharge Time parameter(T) used



(b) 방전소요시간 파라미터(T) 미사용  
(b) Discharge time parameter(T) not used

그림 17. 전압 및 전류 파라미터가 각각 5개인 MNN 모델의 SOC 추정 결과 그래프

Fig. 17. SOC estimation results graph for MNN models with five voltage and one current parameter respectively

다층신경망 모델에 방전소요시간(T)을 입력 파라미터로 추가하여 학습을 진행한 결과 최저 SOC 오차는 전압, 전류 파라미터를 각각 3개씩 사용한 모델의 1.61%로 Jiechao Lv[14]의 무향 칼만 필터를 사용한 SOC 추정 방법의 오차 2.9%보다 1.29% 낮은 것으로 확인할 수 있었다. J. H. Park[15]의 다층신경망에 전압 데이터를 8개의 입력 파라미터로 사용한 모델의 SOC 오차는 고온(40도)일 때 배터리 1은 2.8%, 배터리 2는 3.1%, 배터리 3은 3.4%, 배터리 4는 1.1%이고, 본 논문의 표 2에서 Model 3의 SOC 오차는 배터리 1은 1.72%, 배터리 2는 1.79%, 배터리 3은 1.62%, 배터리 4는 1.76%이다.

본 논문의 표 2에서 Model 3의 SOC 오차는 4개의 배터리 모두 2% 미만으로 J. H. Park[15]의 다층신경망에 전압 데이터를 8개의 입력 파라미터로 사용한 모델과 비교하였을 때 전반적으로 오차가 작으므로 실제 SOC 추정을 더욱 정확하게 할 수 있었다. 최종적으로 방전소요시간(T) 파라미터를 사용한 다층신경망 중 전압 및 전류 파라미터를 각각 3개, 4개씩 사용한 것의 추정 성능이 비교적 우수한 것으로 판단된다.

## V. 결 론

본 논문에서는 실제 차량의 출력에 따른 SOC 변화를 추정하기 위해 차량 주행 시뮬레이터를 제작하였고, 도심에서의 주행주기 테스트 모드로 사용되는 FTP-75를 시뮬레이터의 주행주기로 하여 방전실

험을 진행하였다. 그 후 획득한 전압 및 전류 데이터를 통해 다층신경망 신경망의 입력 파라미터 개수를 각각 2개, 3개, 4개, 5개로 구성된 4개의 모델에 방전소요시간(T) 파라미터를 추가한 것과 추가하지 않은 것으로 분류하여 학습을 진행한 뒤 SOC를 추정하는 방법을 제안하였다. 먼저 방전소요시간(T)을 추가하지 않은 모델의 최저 오차는 2.52%로 확인할 수 있었다. 방전소요시간(T)을 입력 파라미터로 사용한 다층신경망 모델과 그렇지 않은 모델의 최저 오차는 각각 1.61%, 2.52%로 0.91%의 차이가 발생하는 것을 확인하였고, 또한 표 1과 표 2를 비교하였을 때 모든 모델에서 모든 배터리의 SOC 추정 오차가 줄어들었으므로 방전소요시간(T)을 입력으로 사용한 경우가 SOC 추정 성능이 더 우수하였다.

마지막으로 본 논문에서는 타 논문에서의 방전실험 시 일정한 정전류로 방전하는 방식이 아닌 시뮬레이터의 RPM 출력에 따라 변화하는 전류와 그에 따른 배터리 전압의 변화를 확인 및 획득하였고, 다층신경망을 통해 SOC를 추정하였으므로 실제 차량 주행 상황에 접목 가능할 것으로 예상된다.

추후 연구에서는 체인 형식의 구조로 이전 정보가 다음 학습에 영향을 주는 RNN(Recurrent Neural Network)기반의 LSTM(Long Short Term Memory)을 사용하여 SOC를 추정할 예정이다. 그리고 방전실험을 진행할 때 주변 온도를 포함한 다른 파라미터의 SOC 추정 시 영향을 분석하여, 이를 고려할 예정이다.

## References

- [1] A. Barré, B. Deguilhem, S. Grolleau, M. Gérard, F.Suard, and D. Riu, "A review on lithium-ion battery ageing mechanisms and estimations for automotive applications", *Journal of Power Sources*, Vol. 241, pp. 680-689, Nov. 2013. <https://doi.org/10.1016/j.jpowsour.2013.05.040>.
- [2] T. Kodama and H. Sakaebe, "Present status and future prospect for national project on lithium batteries", *Journal of Power Sources*, Vol. 81-82, pp. 144-149, Sep. 1999. [https://doi.org/10.1016/S0378-7753\(98\)00207-9](https://doi.org/10.1016/S0378-7753(98)00207-9).
- [3] Y. Jeong, Y. Cho, J. Ahn, S. Ryu, and B. Lee, "Enhanced coulomb counting method with adaptive SOC reset time for estimating OCV", 2014 IEEE Energy Conversion Congress and Exposition (ECCE), Pittsburgh, PA, pp. 1313-1318, Sep. 2014. <https://doi.org/10.1109/ECCE.2014.6953989>.
- [4] Cho, Y. K., Jeong, Y. M., Ahn, J. H., and Lee. B. K., "Algorithm for Reduction Error using Statistical Error Analysis of the Coulomb Counting Method", *Proc. of The Korean Institute of Power Electronics*, pp. 1043-1044, 2014.
- [5] Jang, K. W., and Chung, G. B., "A SOC Estimation using Kalman Filter for Lithium-Polymer Battery", *Proc. of The Korean Institute of power electronics, The Transactions of the Korean Institute of Power Electronics*, Vol. 17, No. 3, pp. 222-229, Jun. 2012. <http://doi.org/10.6113/TKPE.2012.17.3.222>.
- [6] I. Anand and B. L. Mathur, "State of charge estimation of lead acid batteries using neural networks", *International Conference on Circuits IEEE, Nagercoil, India*, pp. 596-599, Mar. 2013. <https://doi.org/10.1109/ICCPCCT.2013.6528901>.
- [7] T. H. Cho, H. R. Hwang, J. H. Lee, and I. S. Lee, "Comparison of Intelligent Methods of SOC Estimation for Battery of Photovoltaic System", *IJACSA*, Vol. 9, No. 9, pp. 48-56, 2018. <https://dx.doi.org/10.14569/IJACSA.2018.090907>.
- [8] H. Chaoui and C. C. Ibe-Ekeocha, "State of charge and state of health estimation for lithium batteries using recurrent neural networks", *IEEE Transactions on Vehicular Technology*, Vol. 66, No. 10, pp. 8773-8783, Jun. 2017. <https://doi.org/10.1109/TVT.2017.2715333>.
- [9] K. S. Ryu, and H. C. Kim, "Battery Cell SOC Estimation Using Neural Network", *Institute of Korean Electrical and Electronics Engineers*, Vol. 24, No. 1, pp. 333-338, Mar. 2020. <https://doi.org/10.7471/ikeee.2020.24.1.333>
- [10] 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, Oct 2016. <https://doi.org/10.7842/kigas.2016.20.6.9>.
- [11] C. H. Li, D. R. Byun, and S. C. Park, "BPNN Algorithm with SVD Technique for Korean Document Categorization", *Korea Society of Industrial Informantion Systems*, Vol. 15, No. 2, pp. 49-57, Jun. 2010
- [12] S. J. Lee, M. H. Kim, J. W. Baek, and J. H. Jung, "Enhanced Switching Pattern to Improve Energy Transfer Efficiency of Active Cell Balancing Circuits Using Multi-winding Transformer", *The Transactions of the Korean Institute of Power Electronics*, Vol. 24, No. 4, pp. 279-285, Aug. 2019. <https://doi.org/10.6113/TKPE.2019.24.4.279>.
- [13] Vinod Nair and Geoffrey E. Hinton, "Rectified linear units improve restricted boltzmann machines", *Proceedings of the 27th international conference on machine learning (ICML-10)*, Haifa, Israel, Jun. 2010.
- [14] Jiechao Lv, Baochen Jiang, Xiaoli Wang, Yirong Liu, and Yucheng Fu, "Estimation of the State of Charge of Lithium Batteries Based on

Adaptive Unscented Kalman Filter Algorithm", Electronics, Vol. 9, No. 9, 1425, Sep. 2020. <https://doi.org/10.3390/electronics9091425>.

- [15] 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, 8644, 8644, Dec. 2020. <https://doi.org/10.3390/app10238644>.

저자소개

김 시 진 (Si-Jin Kim)



2020년 2월 : 영진전문대학교  
전자정보통신공학과(공학사)  
2020년 3월 ~ 현재 : 경북대학교  
전자전기공학부(공학석사과정)  
관심분야 : 리튬 이온 배터리 SOC  
추정

이 종 현 (Jong-Hyun 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

왕 동 훈 (Dong-Hun Wang)



2021년 2월 : 경북대학교  
전자공학부(공학사)  
2021년 3월 ~ 현재 : 경북대학교  
전자전기공학부(공학석사과정)  
관심분야 : 리튬 이온 배터리 SOC  
추정

이 인 수 (In-Soo 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 : 샌디아고 주립대학 연구원

2008년 3월 ~ 2014년 10월 : 경북대학교 전자공학부 교수

2014년 11월 ~ 현재 : 경북대학교 전자공학과 교수

관심분야 : 배터리 SOC와 SOH, 추정, 시스템 고장진단  
및 고장허용제어, 신경회로망 기반 지능제어, 지능형  
센서 시스템