

# 뉴럴 네트워크를 이용한 배터리 셀 SOC 추정

## Battery Cell SOC Estimation Using Neural Network

유 경 상\*, 김 호 찬\*\*★

Kyung-Sang Ryu\*, Ho-Chan Kim\*\*★

### Abstract

This paper proposes a method of estimating the SOC(State of Charge) of a battery cell using a neural network algorithm. To this, we implement a battery SOC estimation simulator and derive input and output data for neural network learning through charge and discharge experiments at various temperatures. Finally, the performance of the battery SOC estimation is analyzed by comparing with the experimental value by Ah-counting using Matlab/Simulink program and confirmed that the error rate can be reduced to less than 3%.

### 요 약

본 논문은 역전파 뉴럴 네트워크(Back Propagation Neural Network; BPNN) 알고리즘을 이용한 배터리 셀의 잔존용량(State Of Charge; SOC) 추정 방법을 제안한다. 이를 위해 배터리 성능평가 시뮬레이터를 구현하고 다양한 온도에서의 충전 전 실험을 통해 뉴럴 네트워크 학습에 필요한 입출력 데이터를 도출한다. 최종적으로 배터리의 SOC 추정 성능은 Matlab/Simulink 프로그램을 이용하여 Ah-counting에 의한 실험치와 비교를 통해 분석하고 오차율을 3% 미만으로 줄일 수 있음을 시뮬레이션을 통해 확인한다.

*Key words* : Lithium-ion battery, SOC estimation, Ah-counting, Neural network, Test station

### 1. 서론

리튬이온 전지를 이용한 ESS(Energy Storage System)는 에너지 밀도가 높는데 비해 무게가 가벼운 특성을 가지고 있어 대용량화에 유리하고, 긴 수명 및 낮은 자연방전율로 휴대용 기기뿐만 아니라 가정용, 빌딩용, 전기 자동차, 주파수 조정용 등의 산업에 다양하게 활용되고 있다[1]. 이러한 ESS 확대는 화석 연료의 사용을 감소시킬 수 있을 뿐만

아니라 사용에 따른 공해 물질이 발생하는 않는다는 점에서 친환경 및 에너지 효율성 제고를 위한 새로운 대체 전원으로 주목받고 있다. 그러나 발열에 의한 배터리의 비가역적인 화학적 변성 및 최근에 이슈화된 화재로 인한 ESS의 소실을 방지하기 위해서는 배터리의 충전 및 방전 과정을 적절하게 제어하는 고도화된 배터리관리시스템(Battery Management System; BMS)이 필요하며, 그 중에서도 배터리의 SOC를 정확하게 파악하는 것이 특히 중요하다. 그

\* Electric Power System Research Team, Korea Institute of Energy Research (KIER)

\*\* Dept. of Electrical Engineering, Jeju National University

★ Corresponding author

E-mail : hckim@jejunu.ac.kr, Tel : +82-64-754-3676

※ Acknowledgment

This research was partly supported by 2019 scientific promotion program funded by Jeju National University and partly by the Korea Institute of Energy Technology Evaluation and Planning (KETEP) (No. 20182410105070).

Manuscript received Mar. 12, 2020; revised Mar. 13, 2020; accepted Mar. 20, 2020.

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.

러나 전기화학적으로 구성된 배터리의 SOC를 측정하는 것은 매우 어렵기 때문에 BMS 내에서 전압, 전류, 온도, 임피던스를 측정함으로써 배터리의 SOC를 추정하는 방법들이 연구되고 있다[1, 2].

기존의 BMS에서 배터리의 SOC를 추정하는 방법으로는 배터리에 흐르는 충전 전류를 적산하여 배터리의 SOC를 추정하는 적산전류법(Ampere hour Counting; Ah-counting)과 충전 중 단계마다 배터리가 안정된 상태에서 개방회로 전압(Open Circuit Voltage; OCV)을 측정하고 전압 별 SOC 테이블을 만들어 추정하는 OCV 방법, 칼만필터(Kalman Filter)로 대표되어지는 모델 기반 추정방법 등이 있다. 그러나 적산전류법의 경우, 초기치 문제와 전류 센서를 통해 측정하는 과정에서 발생하는 오차가 지속적으로 누적되는 문제가 있다[3]. OCV 방법은 배터리가 안정된 상태에서만 유효한 값을 나타내기 때문에 실시간으로 상태추정이 필요한 응용분야에는 적합하지 않다. 또한 모델 기반 추정 방법에서 실험을 통해 도출된 파라미터는 재실험을 실시하지 않는 한 변하지 않고 사용되는 값이기 때문에 초기에는 SOC의 정확도가 높을지 모르나, 시간이 지남에 따른 노후화로 인해 SOC의 정확도가 떨어지고, 뿐만 아니라 SOC를 추정하는데 고사양의 프로세서가 필요하다는 문제점을 가지고 있다[4].

본 논문에서는 SOC 추정을 신뢰할 수 있을 정도로 얻음과 동시에 저사양의 프로세서에도 동작이 가능한 BPNN(Back Propagation Neural Network)에 의한 배터리 셀 SOC 추정 방법을 제안한다. 이를 위해 배터리 성능평가 시뮬레이터를 구현하고 다양한 온도에서 충전 실험을 통해 뉴럴 네트워크 학습에 필요한 입출력 데이터를 도출한다. 최종적으로 배터리의 SOC 추정 성능은 Matlab/Simulink를 이용하여 Ah-counting에 의한 실험치와 비교를 통해 분석하고, -15~45도의 온도범위에서 추정 오차율을 3% 미만으로 줄일 수 있음을 확인한다.

## II. 본론

### 1. 뉴럴 네트워크를 이용한 SOC 추정

뉴럴 네트워크는 인간의 신경계를 모방하여 개발된 학습모델로, 반복적인 학습과정을 거쳐 최적의 결과치를 예측하는 기능을 가진다[5]. 본 논문은 배

터리 셀 SOC를 추정하기 위해 순전파에 의한 출력값이 가지는 오차를 역방향으로 다시 보내면서 가중치를 조정하는 BPNN 알고리즘을 제안한다.

그림 1은 제안한 BPNN 알고리즘을 이용한 SOC 추정 모델로 숨겨진 계층의 모든 활성화 함수는 tanh ( $f_j$ 로 표시)이고 출력은 1 개의 tanh ( $f_0$ 로 표시)로 표시된다.




Fig. 1. BPNN model for SOC estimation.

그림 1. SOC 추정을 위한 BPNN 모델

SOC의 정확도를 높이고 모델을 단순화하기 위해 배터리 셀에서 측정된 전압, 전류, 온도는 식 (1)과 같이 전처리 과정을 거쳐 시간당 전력량을 입력으로 하고 범위는 SOC와 동등하게 0~1의 값을 갖도록 한다.

$$Q_{j,hat}^{T_i}(k) = (P_j^{T_i}(k) - v_j^{T_i}(k) i_j^{T_i}(k)) / P_j^{T_i}(k) \quad (1)$$

여기서  $P$ 는 사용가능한 셀의 총 전력량(3.5\*3.8\*3600)을 나타내며  $v$  및  $i$ 는 시간에 따라 측정된 전압 및 전류를 나타낸다.

전처리된  $Q_{hat}$ 는 모델에서 1개의 뉴런을 사용한 입력층에 입력되고, 은닉층에서는 trial-and-error를 통해 2개의 뉴런을 사용하며, 최종적으로 출력층에서 식 (2)와 같이 SOC를 추정하게 된다.

$$SOC(k+1) = \sum_{j=1}^2 w_j \tanh \left[ \sum_{l=1}^2 w_{jl} Q_{hat}(k) + w_{j0} \right] + w_0 \quad (2)$$

### 2. 배터리 셀 SOC 추정을 위한 시험장치 구현

#### 가. 배터리 충전 시험장치

뉴럴 네트워크를 이용한 SOC 추정방안을 도출하기 위해 구성된 시험장치는 그림 2와 같다. 우선 온도 챔버에서는 배터리 시료에 대해 외부환경을 최대한 제한하고 다양한 온도에서 실험할 수 있도록 하며, 직류 전원공급기(DC Power Supply), 전자부하, 보호장치로 구성된 충전기는 펄스(Pulse) 단

위로 충방전을 모사할 수 있기 때문에, 전기자동차의 다양한 운전 프로파일(Profile) 이용이 가능하다. 마지막으로 PC에서는 충방전 시나리오를 작성하고 각 측정장치로부터 전압 및 전류 데이터를 저장하고 처리하는 기능을 갖는다.

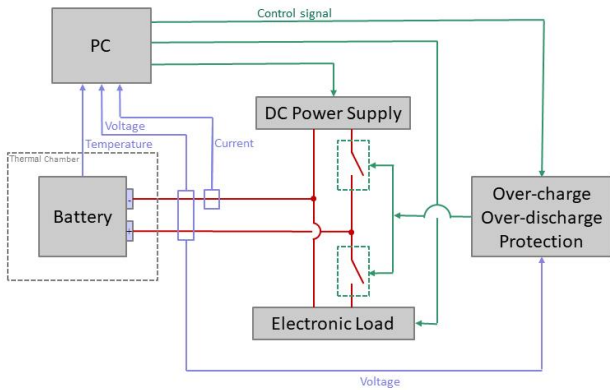


Fig. 2. Schematic of battery test station.  
그림 2. 배터리 시험장치 구성도

그림 3은 배터리 시험장치의 각 요소별 기능을 보여준다. 우선 DAQ 시스템에서는 배터리 충방전 실험을 위한 시험 절차를 작성하고 실험 중 배터리에 이상신호가 감지될 경우 충방전기의 보호장치를 작동시켜 배터리를 보호한다. 배터리 실험 중 취득한 전압, 전류, 온도 데이터는 SOC를 산정하기 위한 계산 알고리즘에 사용된다. 최종적으로 각종 취득 데이터는 저장매체에 저장에 저장되고 계산된 SOC 추정값은 실제값과의 분석을 통해 정확도를 검증한다.

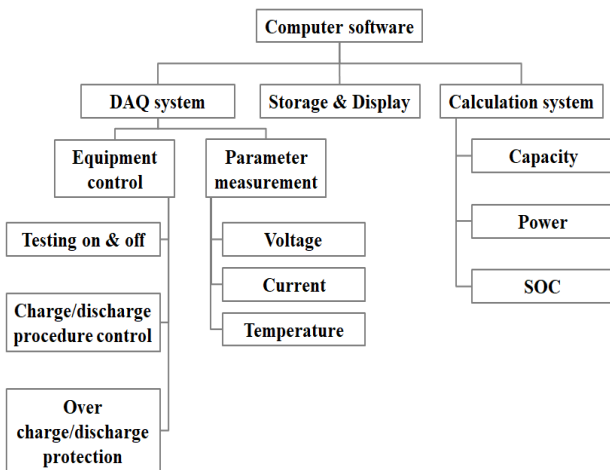


Fig. 3. Function block diagram of battery test station.  
그림 3. 배터리 테스트 스테이션 요소별 기능

나. 배터리 시료 사양

뉴럴 네트워크 알고리즘 검증을 위해 사용된 배터리 셀은 표 1과 같이 18650 타입으로 공칭전압 3.8V, 완전 충전전압 4.5V, 용량 3500mAh의 사양을 갖는다. 실험에 적용된 온도 조건은 -15~45도로 10도 간격으로 다양한 온도 조건하에서 충방전을 실행한다. 이를 통해 제안한 배터리의 상태 추정 알고리즘의 유용성을 검증하기 위하여 충/방전 실험을 통해 기준값으로 사용될 Ah-counting에 의한 SOC 값과 BPNN에 의한 SOC 값을 비교 분석한다.

Table 1. The battery cell specification.

표 1. 배터리 셀 사양

Classification	Condition	Classification	Condition
Battery Type	18650 NCM	Final discharging voltage	2.5V
Operation Voltage	3.8V	Full charging voltage	4.5V
Nominal Capacity	3.5Ah	Temp.	-15~45°C

### 3. Case Study

의한 SOC 추정값을 산정하기 위해 -15~45도까지 10도 단위로 UDSS(Urban Dynamometer Driving Schedule) 프로파일을 실행하여 전압, 전류, 온도 데이터를 측정한다. 또한 알고리즘의 입력 데이터는 1초 단위로 계측된 전압, 전류, 온도 값을 이용하여 식 (1)에 의해 도출된 값을 이용한다. 이때 배터리는 내부의 리튬이온이 안정화 되도록 해당 온도에서 2시간 동안 휴지기간을 거친다. 이후 UDSS 프로파일을 실행하기 전에 1C로 0.55Ah(SOC 15.7%) 만큼 방전시킨다. 이는 순간 펄스전류에 의한 셀의 과충전을 방지하기 위함이다. UDSS 프로파일은 그림 4에서 누적 방전용량이 2.8Ah가 될 때까지 이 실행된다. 이때 셀의 SOC가 0%인 2.5V까지 방전시키지 않는 이유는 펄스 전류에 의한 과방전을 방지하기 위함이다. 개별 온도당 실행 시간은 약 11시간으로 19번의 UDSS 프로파일이 반복 실행된다.

그림 4를 통해 -15~45도까지 얻은 전압 및 전류 데이터는 식 (1)을 통해 전처리 한 후, 식 (2)를 통해 SOC를 도출하게 된다. 본 논문에 제안한 방법으로 도출된 SOC는 일반적으로 SOC의 비교검증을 위해 이용되는 Ah-counting에 의한 SOC와 비교를 통해 정확도를 산정한다.





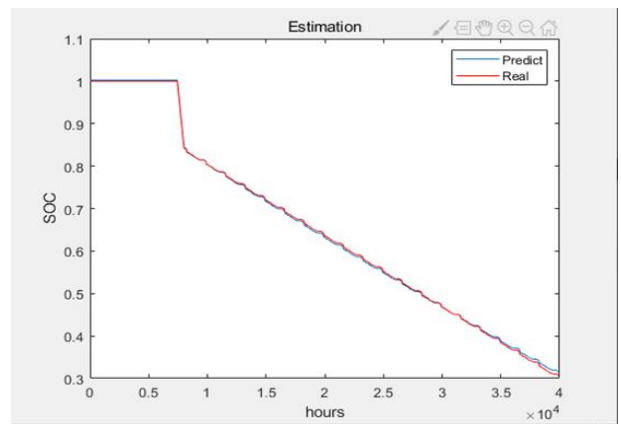
Fig. 4. Current and Voltage values by UDDS profile, (a) current, (b) voltage.

그림 4. UDDS 프로파일에 의한 전류 및 전압파형, (a) 전류, (b) 전압


그림 5의 (a)~(g)는 -15~45도까지 각 온도에서의 Ah-counting 및 BPNN에 의한 셀의 SOC 비교 결과 값을 보여준다. 여기서 붉은색 실선은 Ah-counting에 의한 SOC 값을 나타내며, 파란색 실선은 뉴럴 네트워크로 추정된 SOC 값을 나타낸다.




(b)




(c)




(d)




(e)



(a)



(f)



(g)

Fig. 5. Comparison of SOC, (a) -15 degree, (b) -5 degree, (c) 5 degree, (d) 15 degree, (e) 25 degree, (f) 35 degree, (f) 45 degree.

그림 5. SOC 비교검증, (a) -15도, (b) -5도, (c) 5도, (d) 15도, (e) 25도, (f) 35도, (f) 45도

Ah-counting과 제안한 BPNN의 오차는 RMSE (Root Mean Square Error)에 의해 도출되며 그 결과는 표 2와 같다. 여기서 오차는 0.0035~0.0252의 범위에 있으며 온도가 5~25도 범위에서 BPNN에 알고리즘에 의한 SOC 추정 성능이 매우 효과적임을 보여준다.

Table 2. RMSE of SOC according to temperature.

표 2 온도별 SOC 추정오차

Temp.	RMSE	Temp.	RMSE
-15	0.0252	25	0.0082
-5	0.0093	35	0.0104
5	0.0035	45	0.0112
15	0.0064	-	-

### III. 결론

본 논문은 BPNN 알고리즘을 이용한 SOC 추정 방법을 제안하였다. 이를 위해 배터리 시험장치를 구현하고 다양한 온도에서의 충방전 실험을 통해 UDSS를 이용하여 뉴럴 네트워크 학습에 필요한 입력 데이터를 도출하였다. 최종적으로 배터리 셀의 SOC 추정 성능은 Matlab/Simulink를 이용하여 Ah-counting에 의한 실험치와 비교를 통해 분석하였다. 비교 결과 모든 온도에서 RMSE에 의한 오차가 3% 미만으로 나타남을 시뮬레이션을 통해 확인하여 본 논문에서 제안한 BPNN 알고리즘에 의한 SOC 추정 성능의 효과성을 입증하였다.

### References

[1] M. A. Hannan, M. S. H. Lipu, A. Hussain and A. Mohamed, "A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations," *Renewable and Sustainable Energy Reviews*, Vol.78, pp.834-854, 2017. DOI: 10.1016/j.rser.2017.05.001

[2] 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, pp.1506-1511, 2009. DOI: 10.1016/j.apenergy.2008.11.021

[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, 2014. DOI: 10.1109/ECCE.2014.6953989

[4] M. U. Ali, A. Zafar, S. H. Nengroo, S. Hussain, M. J. Alvi and H. J. Kim, "Towards a smarter battery management system for electric vehicle applications: A critical review of lithium-Ion battery state of charge estimation," *Energies*, Vol.12, No.3, 2019. DOI: 10.3390/en12030446

[5] B. Enache and E. Diaconescu, "Estimating a

betterly state of charge using neural networks,”  
*International Symposium on Fundamentals of  
 Electrical Engineering*, pp.1-6, 2014.

DOI: 10.1109/ISFEE.2014.7050636

---

**BIOGRAPHY**

---

**Kyung-Sang Ryu** (Member)



2008 : BS degree in Electrical Eng.,  
 Korea University of Technology and  
 Education

2013 : MS degree in Electrical Eng.,  
 Korea University of Technology and  
 Education.

2013~Current : Senior Researcher, Dept. of Electric  
 Power System Research Team, Korea Institute of  
 Energy Research

**Ho-Chan Kim** (Member)



1987 : BS degree in Control &  
 Instrument Eng., Seoul National  
 University.

1989 : MS degree in Control &  
 Instrument Eng., Seoul National  
 University.

1994 : PhD degree in Control &  
 Instrument Eng., Seoul National  
 University

1995~Current : Professor, Dept. of Electrical Eng., Jeju  
 National University