

데이터 기반 인공지능 알고리즘을 사용하는 배터리 충전상태 추정 기법 조사 분석

정대웅, 배성우*
한양대학교 전기공학과

Survey on Battery SOC Estimation Methods using Data-driven AI Algorithms

Dae-Ung Jeong, Sungwoo Bae*

Dept. of Electrical Engineering, Hanyang University, Seoul, Korea

ABSTRACT

본 논문은 최근 주목 받고 있는 데이터 기반 인공지능 알고리즘을 사용하는 배터리 충전 상태 추정 기법에 대하여 조사 분석한다. 기존의 배터리 모델링 기법의 단점을 회피할 수 있는 데이터 기반 인공지능 알고리즘의 구조적 특징을 확인하고, 배터리 충전 상태 추정에 데이터 기반 인공지능 알고리즘을 적용했을 때, 충전 상태 추정 정확도에 영향을 끼치는 요소인 데이터 구성에 대한 분석을 실시하여, 데이터 구성 시 필수적으로 고려해야하는 설계조건을 조사 분석한다.

1. 서론

전기자동차의 보급이 확대됨에 따라 전기자동차의 고질적인 문제였던 주행거리 향상에 대한 연구가 활발히 이루어지고 있다. 전기자동차는 주로 리튬이온 배터리를 에너지 저장 장치로 사용하고 있으며 안정적인 동작 및 주행거리 향상을 위해서는 배터리의 관리가 필수적이다[1].

배터리 관리 시스템(BMS)은 배터리의 안정적인 동작과 효율적인 사용을 위해 전기자동차 뿐만 아니라 배터리 시스템에 필수적으로 구성된다. 배터리 관리 시스템은 배터리 전압, 전류, 온도 등을 측정하여 배터리의 과충전, 과방전, 과열 등의 위험을 방지한다. 특히 배터리의 상태정보를 나타내는 State of charge(SOC), State of health(SOH)는 배터리 상태를 나타내는 핵심 지표로, BMS 시스템의 신뢰성과 정확성은 SOC, SOH 추정 정확도에 달려있다[1].

최근 배터리 SOC를 정확히 추정하기 위해 데이터 기반 인공지능(AI) 알고리즘을 적용한 SOC 추정 방법이 제안되고 있다. 기존 등가회로모델(ECM)을 통한 SOC 추정방법은 배터리 모델링의 한계와 계산 집약적인 알고리즘이 단점으로 지적되었다. 인공지능 알고리즘을 통한 SOC 추정 방법은 대체로 기존 ECM 방법의 단점인 배터리 모델링 설계가 필요 없어 배터리 모델링에 대한 사전 지식이 필요 없다는 점과, 계산 집약적인 알고리즘에서 벗어날 수 있다는 장점이 있다[2].

본 논문에서는 최근 데이터 기반 인공지능 알고리즘을 적용한 SOC 추정 기법들을 소개하고, SOC 추정 정확도를 높일 수 있는 훈련 데이터의 설계조건을 설명한다.

2. 본론

2.1 데이터 기반 인공지능 알고리즘

최근 많은 양의 데이터를 기반으로 인공지능 알고리즘을 통해 데이터를 분석하고 처리하는 기술이 각광 받고 있다. 배터리 사양과 종류가 다양해짐에 따라, 데이터 기반 인공지능 알고리즘은 배터리 전압, 전류, 온도 등의 배터리 상태 정보 데이터를 SOC와 맵핑하여 결과를 출력한다. 따라서 배터리 모델링 기법과 같이 모델링 매개변수가 가져야하는 높은 정확성과 계산 집약적 필터의 한계에서 자유로워질 수 있다. 대표적인 데이터 기반 인공지능 알고리즘으로 Extreme learning machine (ELM), Feedforward artificial neural network(FNN), Recurrent neural network(RNN) 등이 배터리 SOC 추정에 사용된다.

2.1.1 ELM 기반 배터리 SOC 추정 기법

ELM은 리튬이온 배터리와 같은 비선형시스템에서 결과를 예측하는데 적합한 알고리즘이다. ELM은 그림 1과 같이 FNN과 비슷한 구조를 가지고 있으나 역전파 과정을 거치지 않는 차이점을 가지고 있다. ELM은 역전파 과정 대신 일반화 역행렬 또는 유사 역행렬을 통해 알고리즘의 가중치(Weight) 값을 계산하여 훈련 속도가 빠르다는 특징을 가진다.

2.1.2 FNN 기반 배터리 SOC 추정 기법

FNN 기반 배터리 SOC 추정 기법은 그림 2와 같이 입력 데이터로 배터리 전압 $V(t)$, 전류 $I(t)$, 온도 $T(t)$ 등의 배터리 상태 정보 데이터를 통해 SOC(t)를 추정하며 Input, hidden layers, output으로 구성된다. 입력 데이터를 통해 정확도 높은 SOC 값을 출력하기 위해서 알고리즘은 훈련데이터를 통해 훈련된다. 이 과정에서 훈련데이터의 질과 양에 따른 SOC 추정 정확도 차이가 발생한다.




그림 1 배터리 SOC 추정을 위한 ELM 구조




그림 2 배터리 SOC 추정을 위한 FNN 구조

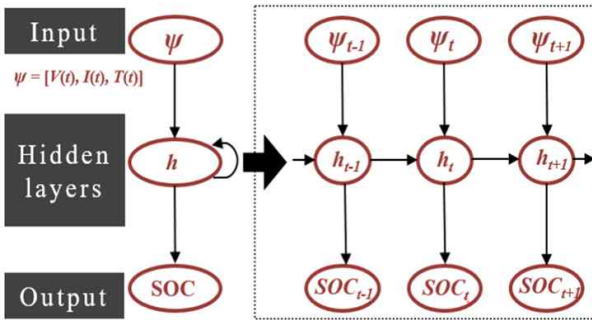


그림 3 배터리 SOC 추정을 위한 RNN 구조

2.1.3 RNN 기반 배터리 SOC 추정 기법

RNN 기반 배터리 SOC 추정기법은 입력 데이터로 FNN과 같이 배터리의 전압 $V(t)$, 전류 $I(t)$, 온도 $T(t)$ 의 정보를 사용한다. SOC 추정 구조에서 FNN과 다른 부분은 그림 3과 같이 hidden layers에서 출력된 데이터가 다음 시간 t 에 입력으로 들어가는 재귀적 동작 구조를 가지고 있으며, 이로 인해 RNN은 시간 t 에서의 입력 데이터의 패턴과 이전 시간 $t-1$ 에 데이터 경향성도 판단할 수 있게 된다. 즉 배터리 동적전류, 온도 등 환경 변화를 고려할 수 있게 된다.

2.2 데이터 기반 SOC 추정 기법의 데이터 분석

2.2.1 데이터 셋 구성요소

최근 전기자동차를 대상으로 연구된 데이터 기반 인공지능 알고리즘의 경우 표 1과 같이 배터리의 환경역학을 고려한 데이터 셋을 사용한다. 전기자동차의 배터리의 동작온도, 사용자 패턴을 반영한 배터리 주행 프로파일과 같은 조건을 고려하며, 앞서 설명한 ELM[2], FNN[3], RNN[1]과 같은 데이터 기반 인공지능 알고리즘 연구에 적용된 데이터는 배터리 실제 동작 온도 영역인 0°C , 25°C , 45°C 로 구성되었다. 알고리즘에 입력 값으로 사용하는 전압, 전류, 온도의 정의는 알고리즘 설계자에 따라 평균전류, 평균전압과 같은 입력 값을 추가로 설정할 수 있으며, 입력 값의 정의에 따라 알고리즘 추정 속도 및 정확도에 영향을 준다. 그리고 훈련 데이터에 전기자동차의 실제 도로 주행 시나리오가 구성된다. 실제 도로 주행 상황을 반영한 데이터로 고속도로 주행환경을 반영하는 HWFET, US06 사이클 테스트와 도심 주행환경을 반영하는 UDSS, 고속도로와 도심 주행환경이 복합적으로 구성된 NEDC, BJDST가 있다. 또한, 공격적인 운전 패턴과 배터리의 급격한 동적전류 변화를 반영하기 위해 LA92, DST같은 주행 사이클을 인공지능 알고리즘의 훈련데이터로 구성할 수 있다.

표 1 SOC 추정 기법에 적용된 배터리 데이터

| AI method | Data profile | Input | Temperature |
|-----------|----------------------|--------------------------------------|---|
| ELM[2] | BJDST, US06 | $V(t), I(t), T(t)$ | $25^{\circ}\text{C}, 45^{\circ}\text{C}$ |
| FNN[3] | FUDS, NEDC US06, DST | $V(t), T(t), I_{avg}(t), V_{avg}(t)$ | $0^{\circ}\text{C}, 25^{\circ}\text{C}, 45^{\circ}\text{C}$ |
| RNN[1] | HWFET, UDSS, LA92 | $V(t), I(t), T(t)$ | $0^{\circ}\text{C}, 10^{\circ}\text{C}, 25^{\circ}\text{C}$ |

2.2.2 데이터 기반 인공지능 알고리즘의 데이터 셋 설계 조건

데이터 기반 인공지능 알고리즘은 배터리 SOC를 추정하기 위해 데이터 훈련 과정을 거치게 된다. 배터리 SOC 추정 시 배터리의 환경조건에 따라 큰 SOC 추정 오차가 발생할 수 있는데, 데이터 기반 인공지능 알고리즘은 배터리 모델링 기법과 달리 급변하는 배터리 환경 조건에 대한 훈련을 통해 SOC 추정 성능을 향상시킬 수 있다. 따라서, 데이터 기반 인공지능 알고리즘의 SOC 추정 향상을 위해 다음과 같은 데이터 셋 설계 조건을 적용할 수 있다: 1) 배터리 환경상태를 정확히 반영할 수 있는 입력 값 정의 2) 실제 배터리의 급격한 환경 변화를 훈련할 수 있는 다양한 배터리 주행 데이터 구성 3) 훈련데이터로 훈련되지 않은 영역에 대한 SOC 추정 성능 검증을 위해, 훈련되지 않은 영역 데이터를 구성하여 SOC 추정 신뢰성을 확보하는 검증 단계를 구성할 수 있다.

3. 결론

본 논문은 최근 주목 받고 있는 데이터 기반 인공지능 알고리즘을 사용하는 배터리 충전 상태 추정 기법인 ELM, FNN, RNN의 구조와 데이터 적용에 대하여 분석하였다. 데이터 기반 인공지능 알고리즘 연구에 사용되는 데이터는 2.2절의 분석에서와 같이 실제 배터리 사용 환경을 반영할 수 있으며, 배터리 주행 사이클의 성격을 분석하여 데이터를 구성하여야 한다. 또한 훈련 데이터에서 훈련하지 못한 영역에 대 추정 성능을 검증하여, 데이터 기반 인공지능 알고리즘의 신뢰성을 향상시키는 과정이 수반되어야 한다.

이 연구는 2020년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원에 의한 연구임(20011626)

참고 문헌

- [1] Ephrem Chemali, et al, "Long Short-Term Memory Networks for Accurate State-of-Charge Estimation of Li-ion Batteries," *IEEE Trans. Industrial Electronics*, Vol. 65, no. 8, August 2018
- [2] Molla S. Hossain Lipu, et al, "Extreme Learning Machine Model for State-of-Charge Estimation of Lithium-Ion Battery Using Gravitational Search Algorithm," *IEEE Trans. Industry Applications*, Vol. 55, no.4, July/August 2019
- [3] J. Du, Z. Liu, and Y. Wang, "State of charge estimation for li-ion battery based on model from extreme learning machine," *Control Eng. Pract.*, vol. 26, no. 1, pp. 11 - 19, May 2014.