

전기 자동차 리튬-이온 배터리 SOH 측정 및 추정 방법에 대한 조사연구

오국환^{1,*}, 조현창¹

A Survey on Measurement and Estimation Methods for State of Health of EV Lithium-ion Batteries

Koog-Hwan Oh^{1,*} and Hyun-Chang Cho¹

Abstract

Electric vehicles (EVs) have recently been in the spotlight and have been rapidly developed to reduce the carbon emission with respect to the transport sector. Most EVs currently employ lithium-ion batteries (LIBs) as power sources because they have a higher energy density and a lower self-discharge than other batteries. However, the LIBs cannot respond to high power demands when the state of health (SOH) falls below 80%. Therefore, the SOH of the LIBs must be accurately measured or estimated. To date, many methods have been studied and proposed for measuring or estimating the SOH. In this paper, representative methods among them are reclassified and introduced.

Keywords: Electric vehicle, Li-ion battery, State of health, Estimation

1. 서 론

2015년 유엔 기후 변화 회의에서 파리협정(Paris agreement)이 채택됨에 따라 195개 국가는 온실가스 감축 목표를 정하고 이를 실천 중이다. 2018년 기준 전 세계 온실가스 배출량의 약 17%, 이산화탄소 배출량의 약 25%를 수송 부문이 차지하였으며, 그중 도로 부분 배출량이 매년 약 95% 이상으로 가장 큰 비중을 차지하고 있다[1]. 이에 따라 수송 부문에서의 온실가스 배출량을 줄이기 위한 방안으로 주요국은 전기 자동차 시장 활성화 정책들을 꾸준히 펼쳐왔다. 전기 자동차는 내연기관과 모터를 동시에 활용하는 하이브리드 전기 자동차(Hybrid Electric Vehicle, HEV), 내연기관과 모터를 동시에 활용하며 외부 충전기를 사용하여 배터리 충전이 가능한 플러그인 하이브리드 전기 자동차(Plug-in Hybrid Electric Vehicle, PHEV), 전기만을 사용하여 구동하는 배터리 전기 자동차(Battery Electric Vehicle, BEV), 수소 연료전지를 활용하는 연료전지 전기 자동차(Fuel

Cell Electric Vehicle, FCEV)의 네 가지 주요 유형이 있으며, 이 중 BEV와 PHEV가 2022년 글로벌 자동차 시장 판매량이 14%로 큰 비중을 차지하고 있다[2].

BEV와 PHEV 모두 비교적 높은 가격에도 불구하고 에너지 밀도가 높고 자가 방전이 적은 리튬-이온 배터리(Lithium-ion Battery, LIB)를 주로 사용한다. LIB는 과충전 및 과방전 시 과열되며, 이에 따라 배터리 SOH(State of Health)가 감소할 수 있으며 나아가서는 화재 및 폭발 또한 발생할 수 있다[3]. 또한, 전기 자동차 배터리의 경우 고온 환경에 노출될 수밖에 없으며, 고온 환경 노출 시 시스템 열화가 가속화된다. 순간적으로 고출력을 내야 하는 전기 자동차의 특성상, 배터리 SOH가 일정 수준 이하로 떨어지면 순간적인 고출력 대응이 불가하므로 운행상 위험을 초래할 수 있다. 따라서, 대다수 국가는 안전마진(Safety margin)을 고려하여 전기 자동차 배터리 SOH가 80% 수준 이하로 떨어지면 운행을 금지하고 있으며 LIB의 재사용 및 재활용이 권고 및 의무화되고 있다[4]. 또한, 유럽연합은 2023년 새로운 배터리 규정(Battery regulation)을 채택하면서 SOH가 감소하여 사용이 불가한 전기 자동차 배터리의 리튬, 코발트, 납, 니켈 등 핵심 원자재의 재활용을 의무화하였고, 원자재 재활용 의무화 비율을 단계적으로 높이는 데 합의하였다[5]. 따라서, 전기 자동차의 안전하고 효율적인 운영 및 자원 재활용을 위해서는 전기 자동차 LIB의 SOH 측정 및 추정은 필수적이다.

본 논문은 기존의 리튬-이온 배터리 SOH 측정 및 추정 관련 조사연구 논문들[6-10]과 “Lithium-ion battery”, “State of health”, “Electric vehicle” 등의 검색 키워드를 통해 발표된 논문들을 추

¹한국전자기술연구원 스마트전장연구센터(Smart Electrics Research Center, Korea Electronics Technology Institute)

226, Cheomdangwagi-ro, Buk-gu, Gwangju 61011, Korea

*Corresponding author: ohkhwan@keti.re.kr

(Received: Nov. 13, 2023, Revised: Nov. 20, 2023, Accepted: Nov. 23, 2023)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<https://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.

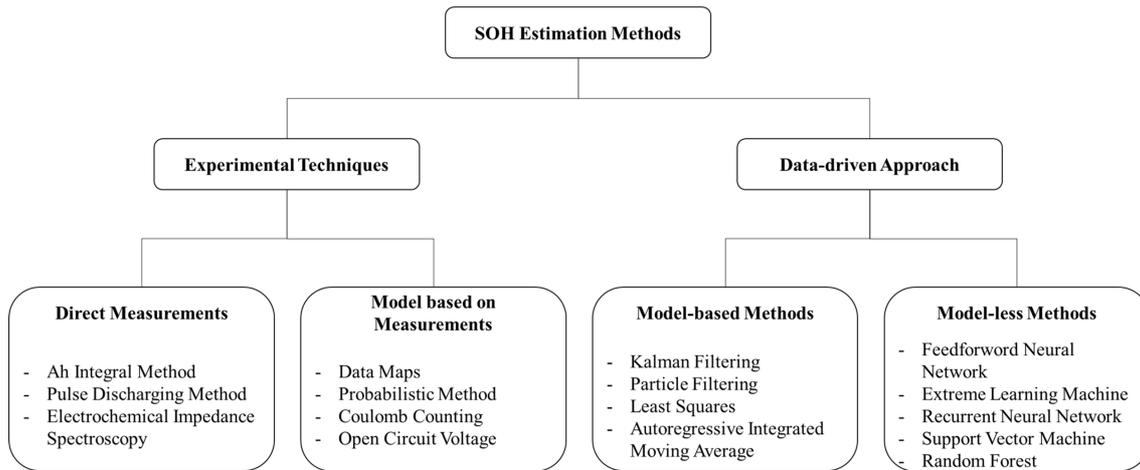


Fig. 1. Classification of SOH measurement and estimation methods

가로 조사하여 전기자동차 리튬-이온 배터리의 SOH 측정 및 추정 방법 중 대표적인 것들을 재분류하고 이를 소개한다.

2. SOH 측정 및 추정 방법

LIB의 생애주기에서 SOH는 배터리의 건강 상태 또는 잔존가치 수명율을 의미하며, 배터리의 초기 상태와 비교하여 현재 배터리 성능의 건강 상태 수준을 평가하는 지표이다. 즉, 현재 배터리가 초기 상태와 비교하였을 때 얼마만큼 손상되었는지를 나타낸다. LIB는 충/방전 사이클링의 증가에 따라 필연적으로 기계적 및 화학적 열화를 피할 수 없으며, 이러한 열화 과정은 최대 용량(Capacity)의 감소, 내부 저항(Internal resistance)의 증가 등을 초래한다. LIB의 SOH는 전통적으로 용량과 내부 저항에 기반하여 다음 수식 (1), (2)와 같이 2가지 방식으로 정의할 수 있다[8].

$$SOH = \frac{C_i}{C_0} \times 100 \% \quad (1)$$

$$SOH = \frac{R_{EOL} - R_i}{R_{EOL} - R_0} \times 100 \% \quad (2)$$

여기서 C_0 는 특정 충/방전율(C-rate)에서 초기 상태 배터리의 정격 용량(Rated capacity), C_i 는 동일한 충/방전율에서 현재 최대 가용 용량, R_0 는 초기 상태에서의 내부 저항, R_i 는 현시점에서의 내부 저항, R_{EOL} 은 수명 임계점(End of Life, EOL)에서의 내부 저항을 각각 의미한다. LIB의 전기 자동차 활용에 있어서는 20%의 용량 감소 또는 100%의 내부 저항 증가는 배터리의 EOL로 간주한다[11]. 전기 자동차 LIB가 EOL에 도달하게 되면 순간적인 고출력 대응이 어려우므로 전기 자동차의 안전한 운영을 위해서는 SOH 측정 및 추정은 필수적이다. 따라

서, 많은 문헌에서 다양한 SOH 측정 및 추정 방법이 연구개발되어왔다. LIB의 SOH 측정 및 추정과 관련된 조사연구 논문들 [6-10]은 저자마다 각기 다른 방식으로 이를 분류하였다. 본 논문은 상기 논문들에 기반하여 LIB의 SOH 측정 및 추정 방법들의 대표적인 것들을 Fig. 1과 같이 재분류하였다. 본 논문은 크게 실험적 방법들(Experimental techniques)과 데이터 기반 접근법(Data-driven approach)으로 분류하고, 이것들을 다시 실험적 방법들은 직접 측정(Direct measurements) 방법과 측정값에 기반한 모델(Model based on measurements)을 활용한 방법으로 분류하였으며, 데이터 기반 접근법들은 모델 기반(Model-based) 방법과 모델 리스(Model-less) 방법으로 분류하였다.

2.1 Experimental techniques

실험적 방법들을 통해 LIB의 SOH 측정 및 추정을 할 수 있다. 실험적 방법에는 배터리 셀 또는 모듈의 해체를 통한 방법들이 있지만, 전기 자동차 LIB의 재사용을 위해서는 이러한 방법들을 직접 적용하기에는 어려움이 있다. 따라서, 본 섹션에서는 LIB의 실험적 SOH 추정 방법 중 대표적인 비 파괴적인(Non-destructive) 기술들을 소개한다.

2.1.1 Direct measurements

LIB의 SOH를 추정하는 방법으로는 배터리 용량 또는 내부 저항을 직접 측정하고 이로부터 SOH를 산출하는 방식이 있다. 배터리 용량은 배터리 완전 충전 후 완전 방전을 통해 측정할 수 있으며, 대표적인 방법으로는 암페어시 적산 방법(Ampere-hour integral method)이 있다. 이 경우 정전류-정전압(Constant Current-Constant Voltage, CC-CV) 프로토콜로 배터리를 완전 충전 후 암페어시 적산 방법을 사용하여 방전 용량을 측정하고, 수식 (1)을 이용해 SOH를 산출한다[12].

배터리 내부 저항은 펄스 방전 방법(Pulse discharging method)

을 통해 측정할 수 있다. 이 방법은 배터리에 고속 펄스 전류를 인가하고 수식 (3)의 Ohm의 법칙에 따라 내부 저항을 계산한다.

$$R_i = \frac{\Delta V}{\Delta I} \quad (3)$$

여기서 ΔV 는 전압 강하, ΔI 는 전류 변화를 의미한다. 이처럼 SOC(State of Charge)와 온도에 따라 전류 및 전압 변화를 평가하고 LIB의 내부 저항을 계산[13-15]하고, 수식 (2)를 이용해 SOH를 산출할 수 있다. 또한, 배터리 내부 저항은 Joule 효과 및 열량계를 사용하여 측정할 수 있다[16].

배터리 SOH 추정에는 임피던스값 추정을 통해서도 가능하다. 이 경우 주파수 영역에서 EIS(Electrochemical Impedance Spectroscopy)를 활용하여 임피던스를 측정할 수 있다[17-19]. 서로 다른 주파수 정현파 전류를 인가하고 해당 전압을 측정하여, 임피던스 스펙트럼을 계산한다. 이러한 방법은 간단하고 구현하기 쉽고 비교적 낮은 연산량이 필요하지만, 시험 조건이 엄격하여 실제 적용에는 어렵다는 단점이 있다.

2.1.2 Model based on measurements

위에서 기술했듯이, LIB의 SOH를 추정하기 위해 저항 측정은 매우 중요하다. 모든 SOC 및 온도에서 내부 저항을 피팅하기 위한 특성 맵(Characteristic map)을 통해 SOH 추정이 가능하다. 이러한 데이터 맵(Data map)은 LIB 상태의 장시간 예측을 위해서 필수적이며, 신뢰할 수 있는 내부 저항값 계산에 드는 시간을 줄여줄 수 있다[6]. 또한, 데이터 맵에 기반하여 배터리 사이클 수를 추정하여 SOH를 산출[20, 21]할 수 있으며, 이러한 방법은 전기 자동차의 배터리 수명을 온라인으로 추정하는 데 적합하다는 장점이 있다. 다만, 데이터 맵을 작성하는데 실험 시간이 길고 방대한 데이터가 필요하다는 점이 주된 단점이다.

저항 측정과 마찬가지로 SOH 추정을 위해 배터리 용량을 추정하는 것은 중요하며, 확률론적 방법(Probabilistic method)을 이용하여 이를 추정할 수 있다[6]. 이러한 확률론적 방법은 배터리의 충/방전 데이터를 분석하여, 새 배터리와 SOH 추정을 원하는 배터리의 동일 전압 측정 횟수의 확률[22], 등가 회로 모델(Equivalent circuit model) 및 상태 전이 모델(State transition model)에 기반한 확률론적 방법[23] 등을 통해서 SOH를 추정한다. 이러한 확률론적 SOH 추정 알고리즘들은 부분적인 충/방전 테스트만을 필요로 하기에 시간이 절약되고, BMS(Battery Management System)에서 알고리즘을 구현하기에 연산량이 적다는 장점을 지닌다.

암페어시 적산 방법을 기반으로 하는 전류 적산법(Coulomb counting)은 SOH를 추정하는 대표적인 방법의 하나이다. 전류 적산법은 완전 충/방전을 통해 충전 또는 방전되는 전류의 양과 배터리의 현재 최대 가용 용량을 계산하여 수식(1)을 통해 SOH를 추정한다[7]. 논문 [24]에서는 배터리의 정적 용량에서 방출

되는 전하량으로 정의된 DOD(Depth of Discharge)를 이용하여 SOH를 분석한다. 전류 적산법은 시험에 많은 시간이 소요되며, 적산으로 인한 누적 오차가 발생할 수 있으므로 높은 정확성이 요구된다. 그럼에도 불구하고, 이 기법은 전력 소모가 적으며, 계산이 간단하고, 충/방전율, 온도 등 다른 매개 변수와의 상관 관계가 적기 때문에 가장 많이 사용되는 방법 중에 하나이다. 또한, 배터리 SOH의 추정 외에도 SOC 추정[25, 26]에도 많이 사용된다.

개방 회로 전압(Open Circuit Voltage, OCV)에 기반하여 배터리 SOH 추정이 가능하다. OCV 기반 추정 방법은 실험실 환경에서의 테스트를 통해 SOH와 OCV 사이의 관계를 얻는다[7]. 배터리의 다양한 SOH에서 CC-CV 프로토콜을 이용하여 충전 곡선 데이터를 수집하고 전기화학 모델(Electrochemical model)에 기반하여 변환 함수와 비선형 최소 제곱법을 이용하여 SOH를 산출한다[27]. 또한, 증분 용량 분석법(Incremental Capacity Analysis, ICA)를 이용하여 다양한 동작 온도에서 배터리 SOH 특성을 예측하기도 한다[28]. 이러한 OCV 기반 SOH 추정 방법은 방대한 실험 데이터가 필요하다는 단점이 있지만, SOH의 온/오프라인 추정이 가능하다는 장점이 지니고 있다.

2.2 Data-driven approach

데이터 기반 접근법은 최근 다양한 분야에서 적용되고 있으며, 활발히 연구되고 있다. 이 접근법은 다양한 방식으로 정의할 수 있지만, 본 논문에서는 이를 논문 [9]와 같이 많은 데이터를 통해 시스템 모델을 데이터에 일치시키는 방법으로 정의하였다. 또한, 본 논문에서는 이러한 데이터 기반 접근법을 SOH 추정을 위한 초기 모델이 기존 배터리 모델인 경우 모델 기반 방법, 그렇지 않은 경우 모델 리스 방법으로 분류하였다.

2.2.1 Model-based methods

배터리 SOC 및 SOH 추정에 있어 모델 기반 방법은 주로 등가 회로 모델 또는 전기화학 모델에 기반한다[9,10]. 일반적으로 위 두 모델을 활용하여 LIB의 동적 및 정적 특성을 모델링 한 후, 데이터들에 기반하여 필터링 기법들을 통해 SOH를 추정한다. 등가 회로 모델은 LIB의 SOC 추정에 주로 사용되나, 잔여 용량을 직접적으로 추정하는 데는 어려움이 있다. 따라서, 배터리 SOH 추정에 있어 전기화학 모델을 활용하는 것이 유리하다[9].

칼만 필터(Kalman Filter, KF)는 가장 널리 사용되는 상태 추정 방법으로써 다양한 분야에서 활용되고 있다. KF는 예측(Prediction)과 보정(Update)의 두 단계로 이루어지며, 이 두 단계는 재귀적으로 동작한다. 예측 단계에서는 현재 상태 변수를 추정하고, 보정 단계에서는 추정된 상태 변수 기반으로 예측한 측정값과 실제 측정 데이터의 차이를 반영하여 현재 상태 변수를 보정한다[29]. 일반적인 KF는 비선형 추정 모델에 없고 LIB의 전기화학 모델이 비선형 모델이기 때문에, 기존 연구 결과들

은 주로 비선형 모델에 적용할 수 있도록 개선된 확장 칼만 필터(Extended Kalman Filter, EKF)[30,31] 또는 무향 칼만 필터(Unscented Kalman Filter, UKF)[32,33]를 이용하여 SOH를 추정한다. KF 기반의 SOH 추정 방법들은 정확도가 높으며 온/오프라인 추정이 가능하다는 장점이 있으나, 행렬 연산을 위해서는 대량의 데이터가 필요하다는 단점을 지니고 있다.

파티클 필터(Particle Filter, PF)는 상태 변수가 가우시안 분포를 따르지 않는 비선형 시스템에도 적용이 가능하기 때문에 KF 만큼 다양한 분야에서 활용되고 있다. PF는 몬테카를로(Monte Carlo) 시뮬레이션에 기반하여 베이지안(Bayesian) 필터를 재귀적으로 구현하는 방법이다. PF는 비선형 모델의 확률 분포를 모사하는 입자(Particle)들을 생성하고 비선형 시스템 모델, 측정 모델, 상태 변수 확률 밀도 함수(Probability density function)의 선형적 추정에 의해서 이를 업데이트하고 재생성하여 재귀적으로 상태 변수를 추정한다[29]. PF는 배터리 SOH 추정을 위한 저항, 용량 등의 전기적 매개 변수 추정이 가능하다[34,35]. PF는 입자가 충분히 많다면 KF에 비해 더욱 정확한 추정이 가능하지만, 입자의 수가 충분하지 않다면 정확도에 문제가 생길 수 있다. 따라서, 이러한 경우 PF와 KF를 복합하여 사용할 수 있으며, PF와 UKF를 복합적으로 사용하여 SOH 추정 또한 가능하다[33]. PF는 SOH 추정에 높은 정확도를 지니지만, 높은 정확도를 위한 충분히 많은 수의 입자, 베이지안 처리를 위한 많은 연산이 필요하므로 BMS에서 구현하기에는 어려움이 있다.

최소제곱법(Least Squares, LS)은 통계적 해석 기법인 회귀 분석에서 가장 기본적인 방법으로 배터리 SOH 추정에 사용될 수 있다. LS는 각 점이 알려지지 않은 종속 변수와 이미 알고 있는 종속 변수 사이의 관계를 나타내는 데이터 집합에서 가장 적합한 모델의 매개 변수를 구하는 데 사용된다 [7]. LS를 이용한 SOH 추정 방법들은 주로 전기화학 모델에 기반한다. LS는 SOH의 오프라인 추정[36] 및 온라인 추정[37]에 직접적으로 활용할 수 있으며, 더욱 정확한 SOH 추정을 위해 충/방전 전압 곡선 피팅[38] 등에도 간접적으로 활용할 수 있다.

SOH 측정값 및 SOH 추정을 위한 데이터들은 일정 시간 간격으로 표현이 가능한 시계열(Time series)로써 시계열 분석 기법을 이용하여 SOH 추정이 가능하다. 마찬가지로 가장 널리 사용되는 시계열 예측 방법의 하나인 자동회귀 누적 이동 평균(Autoregressive integrated moving average, ARIMA) 모델을 통해 LIB의 SOH 추정이 가능하다. ARIMA 모델은 과거의 시계열 데이터만 이용하여 미래 시점의 시계열을 예측한다. 따라서, ARIMA 모델은 장기 SOH 예측보다 단일 단계의 SOH 예측에 더 적합하다[9]. 따라서 장기 예측 과정에서의 정확도 향상을 위해 논문 [39]는 영향 인자를 도입하고 이를 ARIMA 모델에서의 자동회귀(Autoregressive) 모델에 결합하여 SOH를 추정하였다. 또한, ARIMA 모델의 예측 정확도를 더 향상시키기 위해서는 PF와 결합하여 SOH 추정[40]이 가능하다.

2.2.2 Model-less methods

위에서 언급했듯이 모델 리스 배터리 SOH 추정 방법들은 모델 기반 방법들과 달리 등가 회로 모델 또는 전기화학 모델 등의 배터리 모델이 필요하지 않으며, 비선형 배터리 시스템을 하나의 블랙박스(Black box)로 간주하여 특징을 추출하여 직접 배터리 SOH 또는 수명을 추정한다[9]. 이러한 모델리스 방법들은 대부분 기계 학습(Machine Learning, ML)에 기반하며 본 섹션에서는 ML에 기반한 대표적인 SOH 추정 방법들을 소개한다.

인공신경망(Artificial Neural Network, ANN)은 비선형 모델링을 위한 가장 대표적인 ML 기법 중 하나이다. ANN은 생물학의 신경망에서 영감을 받아 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer)에 각각 인공 뉴런을 배치하여 뇌의 행동을 모방한다. 입력층은 사전 처리된 정보를 수집하고 이를 은닉층으로 보내는 전달자 역할을 한다. 각각의 뉴런은 은닉층에서의 출력을 결정하기 위한 수학적 모델을 포함한 가중 선형 조합(Weighted linear combination)으로 표현할 수 있다[9]. ANN은 인공 뉴런의 배치와 연결 구조에 따라 다양한 종류의 네트워크를 가진다.

순방향 신경망(Feedforward Neural Network, FFNN)은 노드 간 연결이 순환을 형성하지 않아 데이터가 한 방향으로 전달되는 순방향 연결만을 갖는 ANN의 가장 기본적인 모델이며, 일반적으로 출력층에서 입력층 방향으로 오차를 전파시키는 역전파(Back-propagation) 알고리즘에 의해 학습된다. 논문 [41]은 FFNN을 기반의 LIB SOH 및 잔여 수명 온라인 추정 방법을 제안했으며, 논문 [42]는 FFNN의 iteration 횟수를 줄이기 위해 차분 진화(Differential evolution) 알고리즘에 기반한 LIB 현재 생애주기 추정 방법을 제안하였다. 그리고 논문 [43]은 빅데이터 플랫폼을 통해 수집된 실제 EV 데이터에 기반하여 FFNN을 이용하여 SOH 추정을 구현하였다. 이러한 SOH 추정 방법들은 간단한 모델 구조에 비해 높은 정확도를 가지는 장점이 있지만, FFNN의 일반적으로 느린 훈련 속도와 높은 연산량으로 인해 온보드에서 구현하기에는 어려움이 있다. 이러한 단점을 해결하기 위해서 극한 학습 기계(Extreme Learning Machine, ELM)이 이용되기도 한다. ELM은 FFNN의 추정 정확도를 보장하면서 기존 역전파 알고리즘에 비해 빠른 훈련 속도를 제공한다[10]. ELM은 다른 ANN과 다르게 입력층과 은닉층 사이의 연결 가중치와 은닉층의 임계 값을 임의로 설정할 수 있고 업데이트가 필요하지 않다. 그리고 은닉층과 출력층 사이의 연결 가중치는 일반화된 역행렬을 통해서 결정된다[9]. 논문 [44,45]는 높은 정확도를 유지하며 기존 FFNN 대비 학습 시간이 짧은 ELM에 기반한 SOH 추정 방법을 제안하였다.

순환 신경망(Recurrent Neural Network, RNN)은 ANN의 한 종류로 노드 간 연결이 순환적 구조를 갖는 특징을 가지고 있다. 이러한 구조는 시간에 따른 동적 특징의 모델링이 가능하도록 신경망 내부에 상태를 저장할 수 있게 해준다. FFNN의 경

우 입력 및 출력 차원은 일반적으로 고정되어 있으며 임의로 변경할 수 없다. 따라서, 전통적인 FFNN은 시퀀스 형태의 입력을 처리에 어려움이 있다. 반면에 RNN은 자기 피드백이 있는 뉴런을 사용하여 다양한 길이의 시퀀스 데이터 처리가 가능하다 [10]. 논문 [46]은 LIB 용량이 연속적으로 감소한다는 가정하에 RNN 기반의 SOH 추정 방법을 제안하였다. 그러나 전통적인 RNN은 일정 기간 이상의 정보를 저장하면 네트워크가 더 이상 업데이트되지 않는 기울기 소멸 문제(Vanishing gradient problem)를 가지고 있고, 이에 따라 RNN은 데이터의 장기 의존성을 학습하는 데는 적합하지 않다[9]. 장단기 메모리(Long Short-Term Memory, LSTM)와 게이트 순환 뉴트(Gated Recurrent Unit, GRU)은 이러한 기울기 소멸 문제를 해결함으로써 시퀀스 구성 요소 간의 장기 의존성을 유지할 수 있다.

LSTM RNN(Long Short-Term Memory Recurrent Neural Network)은 기존 RNN에 셀(Cell), 입력 게이트(Input gate), 출력 게이트(Output gate), 망각 게이트(Forget gate)를 추가한 모델이다. 입력 게이트는 내부 상태에 저장할 핵심 정보를 선택할 수 있고, 출력 게이트는 출력 정보를 결정할 수 있으며, 망각 게이트는 중복 정보를 폐기할 수 있다. LSTM RNN은 이러한 게이트들을 통해 오랜 시간 동안 정보를 기억할 수 있어 장기 의존성을 유지할 수 있다[47]. 이러한 LSTM RNN에 기반하여 적은 양의 온라인 데이터만으로도 LIB의 잔여 수명 추정[47] 및 정확한 SOH 추정[48]이 가능하다. GRU 신경망은 게이트 메커니즘이 적용된 RNN으로써, LSTM의 입력 게이트 및 망각 게이트를 업데이트 게이트(Update gate)로 통합하여 LSTM RNN에 비해 단순한 구조로 되어 있으며 훈련 및 예측 효율이 높다. GRU 신경망은 LSTM RNN에 비해 매개 변수의 수가 적고 많은 양의 데이터를 처리하는 경우 더 빠른 훈련 속도를 가진다 [10]. 논문 [49]는 GRU에 기반한 LIB SOH 추정을 제안하였으며, 실험 결과를 통해 LSTM에 비해 추정 성능이 비슷하지만 약 25% 적은 매개 변수를 필요로 하므로 온보드 구현에 적합하다는 것을 보였다.

서포트 벡터 머신(Support Vector Machine, SVM)은 ANN과 함께 비선형 모델링을 위한 가장 대표적인 ML 기법의 하나이며, 주로 분류와 회귀 분석을 위해 사용된다. SVM은 비선형 분류를 하기 위해서 커널 함수(Kernel function)를 이용하여 서포트 벡터를 더 높은 차원의 공간에 매핑하고, 두 개의 초평면을 결정하여 초평면 양쪽으로 데이터를 분리하고, 두 개의 초평면 사이의 거리를 최대화한다[10]. 이러한 SVM 분류기의 몇몇 개념들을 차용하여 SVM을 비선형 회귀 문제에도 적용할 수 있다. 연속적인 수치 변수에 대해 SVM을 두 개의 초평면 사이에 최대한 많은 변수가 포함되도록 초평면 사이의 거리를 최소화하도록 적합함으로써 비선형 회귀 문제에 적용할 수 있으며, 이를 서포트 벡터 회귀(Support Vector Regression, SVR)라고 한다. 논문 [50]은 15분가량의 충전 데이터만 있어도 가능한 SVR

기반 온라인 LIB SOH 추정 방법을 개발하였으며, 논문 [51]은 SVR을 이용하여 추정 오차 2% 이내의 LIB의 SOH 추정 방법을 제안하였다. 이러한 SVM 기반 방법들은 이론적으로 전역적 최적성이 존재하고 지역적 극단의 결함을 피할 수 있다는 장점이 있으나, 실제 구현 시 비선형 모델링을 위한 커널 함수 최적화 및 초 매개 변수(Hyper parameter) 결정에 어려움이 있을 수 있으며 신뢰 구간을 출력하는 능력이 부족하다는 단점이 있다[9]. 이와 같은 SVM 문제점들을 해결하기 위한 기법으로 렐러런스 벡터 머신(Relevance Vector Machine, RVM)이 있다. RVM은 SVM과 동일한 기능적 형태를 갖지만, 베이시안 추론에 기반하여 확률적 분류를 제공한다. RVM은 자기상관 결정(Auto-correlation decision)을 통해 사전 매개 변수의 구조를 통합하고 연관 없는 데이터의 점들을 제거하여 희박 확률 모델(Sparse probability model)을 얻을 수 있다. 즉, RVM은 SVM의 단점을 보완하고 최적 해에 대한 확률 설명을 제공할 수 있다[10]. 또한, SVM은 매개 변수를 수동으로 초기화해야 하지만, RVM은 자동으로 운영이 가능하다. 논문 [52]는 SVM과 RVM의 성능 검증을 위해 두 방법 모두를 통해 SOH를 추정하였으며, RVM이 정확도 측면에서 SVM보다 높다는 것을 보였다. 논문 [53]은 샘플 엔트로피(Sample entropy)와 RVM을 통합한 LIB의 잔여 수명 추정 방법을 제안하였다.

랜덤 포레스트(Random Forest, RF)는 결정 트리(Decision Tree, DT)에 기반한 앙상블(Ensemble) 학습 방법의 일종으로 SVM과 마찬가지로 주로 분류, 회귀 분석 등에 사용된다. RF는 다수의 DT 모델들을 생성하고, 각각의 모델들은 대안적으로 학습하여 독립적으로 예측을 수행한다. 각 회귀 트리의 구성에 있어, 각각의 부분 표본 데이터는 배깅(Bagging) 알고리즘에 의해 임의 중복 추출되어 훈련에 사용되며 나머지 표본 데이터들은 OOB(Out-of-Bag) 표본으로 간주하여 회귀 트리의 성능을 평가한다. 이를 통해 RF는 단일 예측보다 우수한 성능을 발휘하며, 과적합 문제를 획기적으로 완화할 수 있고 일반화 능력을 향상시킬 수 있다[10]. 논문 [54,55]는 RF 기반의 각각 SOH 추정기를 제안하고 개발된 추정기의 최대오차가 2% 미만으로 정확하게 SOH를 추정할 수 있음을 보였다. 또한, RF는 위에 기술한 장점들로 인해 일반화 회귀 신경망(General regression neural network)[56], 합성곱 신경망 [57] 등과 결합하여 SOH 추정에 사용되기도 한다.

위에서 소개한 데이터 기반 방법들은 사용한 데이터 세트에 따라 추정 성능 면에서 다른 결과를 낼 수 있다. 특히, 모델 리스 기반의 SOH 추정 방법들은 배터리 시스템에 대한 모델링을 전적으로 데이터 세트에 의존하기 때문에 이러한 경향이 더 강하며, 동일한 데이터 세트를 사용하여도 일부 논문에서 추정 정확도가 과도하게 높게 표현되는 경우가 있을 수 있다. 따라서, 관련 문헌들에서 제안하는 모델 리스 기반의 SOH 추정 시스템의 적용에 앞서 추정 기술에 대한 명확한 검증과 성능 평가가 필요하다.

3. 결 론

본 논문은 리튬-이온 배터리 SOH 추정과 관련된 몇 가지 조사연구 논문들과 추가로 검색한 논문들에 기반하여 전기 자동차 리튬-이온 배터리의 SOH를 측정하고 추정할 수 있는 대표적인 기술들을 조사하였고, 이것들을 재분류하고 소개하였다. 본 논문에서는 대표적인 SOH 추정 방법들을 크게 실험적 방법과 데이터 기반 접근법으로 분류하였으며, 실험적 방법들은 직접 측정 방법들과 측정값에 기반한 모델들을 활용한 방법들로, 그리고 데이터 기반 방법들은 SOH 추정을 위한 초기 모델이 기존 배터리 모델인 경우 모델 기반 방법들로 그렇지 않은 경우 모델 리스 방법들로 각각 분류하여 이를 소개하였다. 본 연구팀은 향후 본 논문을 통해 조사된 다양한 리튬-이온 배터리의 SOH 추정 방법 중 성능이 우수하고 BMS에서 온보드 구현이 가능할 것으로 예상되는 몇몇 기술들을 선별하여 이들을 BMS에 직접 구현하고 이것들의 성능 검증 및 비교를 수행할 예정이다.

감사의 글

이 논문은 2023년 정부(산업통상자원부)의 재원으로 한국산업기술진흥원의 지원을 받아 수행된 연구임(P0021883, 2022년 전기차용 폐배터리 재사용 산업화 기술개발 사업).

REFERENCES

- [1] E. M. Kim, Greenhouse Gas Reduction in the Global Transportation Sector and Implications: Focusing on the Shipping Sector, The Korea Institute for International Economic Policy (KIEP), Sejong, 2022.
- [2] <https://www.iea.org/reports/global-ev-outlook-2023> (retrieved on Nov. 26, 2023).
- [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", *J. Power Sources*, Vol. 226, pp. 272-288, 2013.
- [4] A. Fotouhi, K. Propp, D. J. Auger, and S. Longo, "State of charge and state of health estimation over the battery lifespan," in *Behaviour of Lithium-Ion Batteries in Electric Vehicles*, G. P. B. Liaw, Eds. Green Energy and Technology, Springer, Cham, pp. 267-288, 2018.
- [5] <https://www.consilium.europa.eu/en/press/press-releases/2023/07/10/council-adopts-new-regulation-on-batteries-and-waste-batteries/> (retrieved on Sep. 25, 2023).
- [6] M. Berecibar, I. Gandiaga, I. Villarreal, N. Omar, J. Van Mierlo, and P. Van den Bossche, "Critical review of state of health estimation methods of Li-ion batteries for real applications", *Renew. Sustain. Energy Rev.*, Vol. 56, pp. 572-587, 2016.
- [7] M. H. Lipu, M. A. Hannan, A. Hussain, M. M. Hoque, P. J. Ker, M. H. M. Saad, and A. Ayob, "A review of state of health and remaining useful life estimation methods for lithium-ion battery in electric vehicles: Challenges and recommendations", *J. Clean. Prod.*, Vol. 205, pp. 115-133, 2018.
- [8] Z. Wang, G. Feng, D. Zhen, F. Gu, and A. Ball, "A review on online state of charge and state of health estimation for lithium-ion batteries in electric vehicles", *Energy Reports*, Vol. 7, pp. 5141-5161, 2021.
- [9] T. Oji, Y. Zhou, S. Ci, F. Kang, X. Chen, and X. Liu, "Data-driven methods for battery soh estimation: Survey and a critical analysis", *IEEE Access*, Vol. 9, pp. 126903-126916, 2021.
- [10] X. Shu, S. Shen, J. Shen, Y. Zhang, G. Li, Z. Chen, and Y. Liu, "State of health prediction of lithium-ion batteries based on machine learning: Advances and perspectives", *IScience*, Vol. 24, No. 11, p. 103265(1)-103265(31), 2021.
- [11] X. Hu, F. Feng, K. Liu, L. Zhang, J. Xie, and B. Liu, "State estimation for advanced battery management: Key challenges and future trends", *Renew. Sustain. Energy Rev.*, Vol. 114, p. 109334, 2019.
- [12] D. Xiao, G. Fang, S. Liu, S. Yuan, R. Ahmed, S. Habibi, and A. Emadi, "Reduced-coupling coestimation of SOC and SOH for lithium-ion batteries based on convex optimization", *IEEE Trans. Power Electron.*, Vol. 35, No.11, pp. 12332-12346, 2020.
- [13] X. Wei, B. Zhu, and W. Xu, "Internal resistance identification in vehicle power lithium-ion battery and application in lifetime evaluation", *Proc. of 2009 International Conference on Measuring Technology and Mechatronics Automation*, pp. 388-392, Zhangjiajie, China, 2009.
- [14] J. Remmlinger, M. Buchholz, M. Meiler, P. Bernreuter, and K. Dietmayer, "State-of-health monitoring of lithium-ion batteries in electric vehicles by on-board internal resistance estimation", *J. Power Sources*, Vol. 196, No. 12, pp. 5357-5363, 2011.
- [15] W. Waag, C. Fleischer, C. Schäper, J. Berger, and D. Sauer, "Self-adapting on-board diagnostic algorithms for lithium-ion batteries", *Proc. of Advanced Battery Development for Automotive and Utility Applications and their Electric Power Grid Integration*, pp. 1-17, Aachen, Germany, 2011.
- [16] U.S. Department of Energy Office of Scientific and Technical Information, "PNGV battery test manual", DOE/ID-10597, 01 Feb., 2001.
- [17] U. Tröltzsch, O. Kanoun, and H. R. Tränkler, "Characterizing aging effects of lithium ion batteries by impedance spectroscopy", *Electrochim. Acta*, Vol. 51, No. 8-9, pp. 1664-1672, 2006.
- [18] P. Bueschel, U. Troeltzsch, and O. Kanoun, "Use of stochastic methods for robust parameter extraction from impedance spectra", *Electrochim. Acta*, Vol. 56, No. 23, pp. 8069-8077, 2011.
- [19] S. R. Islam, and S. Y. Park, "Precise online electrochemical impedance spectroscopy strategies for Li-ion batteries", *IEEE Trans. Ind. Appl.*, Vol. 56, No. 2, pp. 1661-1669, 2019.
- [20] T. Sarikurt, M. Ceylan, and A. Balikçi, "An analytical battery state of health estimation method", *Proc. of 2014 IEEE*

- 23rd International Symposium on Industrial Electronics (ISIE), pp. 1605-1609, Istanbul, Turkey, 2014.
- [21] K. Goebel, B. Saha, A. Saxena, J. R. Celaya, and J. P. Christophersen, "Prognostics in battery health management", *IEEE Instrum. Meas. Mag.*, Vol. 11, No. 4, pp. 33-40, 2008.
- [22] X. Feng, J. Li, M. Ouyang, L. Lu, J. Li, and X. He, "Using probability density function to evaluate the state of health of lithium-ion batteries", *J. Power Sources*, Vol. 232, pp. 209-218, 2013.
- [23] B. Saha, S. Poll, K. Goebel, and J. Christophersen, "An integrated approach to battery health monitoring using Bayesian regression and state estimation", *Proc. of 2007 IEEE Autotestcon*, pp. 646-653, Baltimore, USA, 2007.
- [24] 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", *Appl. Energy*, Vol. 86, No. 9, pp. 1506-1511, 2009.
- [25] A. Nugroho, E. Rijanto, F. D. Wijaya, and P. Nugroho, "Battery state of charge estimation by using a combination of Coulomb Counting and dynamic model with adjusted gain", *Proc. of 2015 International Conference on Sustainable Energy Engineering and Application (ICSEEA)*, pp. 54-58, Bandung, Indonesia, 2015.
- [26] M. B. Lazreg, I. Baccouche, S. Jemmali, B. Manai, and M. Hamouda, "SoC estimation of li-ion battery pack for light electric vehicles using enhanced coulomb counting algorithm", *Proc. of 2019 10th International Renewable Energy Congress (IREC)*, pp. 1-6, Sousse, Tunisia, 2019.
- [27] Z. Guo, X. Qiu, G. Hou, B. Y. Liaw, and C. Zhang, "State of health estimation for lithium ion batteries based on charging curves", *J. Power Sources*, Vol. 249, pp. 457-462, 2014.
- [28] C. Weng, J. Sun, and H. Peng, "A unified open-circuit-voltage model of lithium-ion batteries for state-of-charge estimation and state-of-health monitoring", *J. Power Sources*, Vol. 258, pp. 228-237, 2014.
- [29] K. György, A. Kelemen, and L. Dávid, "Unscented Kalman filters and particle filter methods for nonlinear state estimation", *Procedia Technology*, Vol. 12, pp. 65-74, 2014.
- [30] G. L. Plett, "Dual and joint EKF for simultaneous SOC and SOH estimation", *Proc. of 21st Electric Vehicle Symposium (EVS21)*, pp. 1-12, Monaco, 2005.
- [31] J. Kim, and B. H. Cho, "State-of-charge estimation and state-of-health prediction of a Li-ion degraded battery based on an EKF combined with a per-unit system", *IEEE Trans. Veh. Technol.*, Vol. 60, No. 9, pp. 4249-4260, 2011.
- [32] W. Qiuting, J. Yinzhui, and L. Yunhao, "State of health estimation for lithium-ion battery based on D-UKF", *Int. J. Hybrid Inf. Technol.*, Vol. 8, No. 7, pp. 55-70, 2015.
- [33] F. Zhu, and J. Fu, "A novel state-of-health estimation for lithium-ion battery via unscented Kalman filter and improved unscented particle filter", *IEEE Sens. J.*, Vol. 21, No. 22, pp. 25449-25456, 2021.
- [34] R. Xiong, Y. Zhang, H. He, X. Zhou, and M. G. Pecht, "A double-scale, particle-filtering, energy state prediction algorithm for lithium-ion batteries", *IEEE Trans. Industr. Inform.*, Vol. 65, No. 2, pp. 1526-1538, 2017.
- [35] H. Zhang, Q. Miao, X. Zhang, and Z. Liu, "An improved unscented particle filter approach for lithium-ion battery remaining useful life prediction", *Microelectron. Reliab.*, Vol. 81, pp. 288-298, 2018.
- [36] G. K. Prasad, and C. D. Rahn, "Model based identification of aging parameters in lithium ion batteries", *J. Power Sources*, Vol. 232, pp. 79-85, 2013.
- [37] A. Eddahech, O. Briat, and J. M. Vinassa, "Real-time SOC and SOH estimation for EV Li-ion cell using online parameters identification", *Proc. of 2012 IEEE Energy Conversion Congress and Exposition (ECCE)*, pp. 4501-4505, Raleigh, USA, 2012.
- [38] H. W. Liu, W. J. Xu, and C. Guo, "Study on state of health estimation algorithm for lithium power battery used on pure electric vehicle", *Adv. Mat. Res.*, Vol. 608, pp. 1577-1581, 2013.
- [39] D. Liu, Y. Luo, Y. Peng, X. Peng, and M. Pecht, "Lithium-ion battery remaining useful life estimation based on nonlinear AR model combined with degradation feature", *Annu. Conf. PHM Soc.*, Vol. 4, No. 1, pp. 1-7, 2012.
- [40] D. Liu, Y. Luo, J. Liu, Y. Peng, L. Guo, and M. Pecht, "Lithium-ion battery remaining useful life estimation based on fusion nonlinear degradation AR model and RPF algorithm", *Neural Comput. Appl.*, Vol. 25, pp. 557-572, 2014.
- [41] S. Zhang, B. Zhai, X. Guo, K. Wang, N. Peng, and X. Zhang, "Synchronous estimation of state of health and remaining useful lifetime for lithium-ion battery using the incremental capacity and artificial neural networks", *J. Energy Storage*, Vol. 26, p. 100951, 2019.
- [42] Z. Yao, S. Lu, Y. Li, and X. Yi, "Cycle life prediction of lithium ion battery based on DE-BP neural network", *Proc. of 2019 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*, pp. 137-141, Beijing, China, 2019.
- [43] L. Song, K. Zhang, T. Liang, X. Han, and Y. Zhang, "Intelligent state of health estimation for lithium-ion battery pack based on big data analysis", *J. Energy Storage*, Vol. 32, p. 101836, 2020.
- [44] W. Liu, Y. Xu, and X. Feng, "A hierarchical and flexible data-driven method for online state-of-health estimation of Li-ion battery", *IEEE Trans. Veh. Technol.*, Vol. 69, No. 12, pp. 14739-14748, 2020.
- [45] L. Chen, H. Wang, B. Liu, Y. Wang, Y. Ding, and H. Pan, "Battery state-of-health estimation based on a metabolic extreme learning machine combining degradation state model and error compensation", *Energy*, Vol. 215, p. 119078, 2021.
- [46] A. Eddahech, O. Briat, N. Bertrand, J. Y. Delétage, and J. M. Vinassa, "Behavior and state-of-health monitoring of Li-ion batteries using impedance spectroscopy and recurrent neural networks", *Int. J. Electr. Power Eng. Syst.*, Vol. 42, No. 1, pp. 487-494, 2012.
- [47] Y. Zhang, R. Xiong, H. He, and M. G. Pecht, "Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries", *IEEE Trans. Veh. Technol.*, Vol. 67, No. 7, pp. 5695-5705, 2018.
- [48] P. Li, Z. Zhang, Q. Xiong, B. Ding, J. Hou, D. Luo, Y. Rong, and S. Li, "State-of-health estimation and remaining useful life prediction for the lithium-ion battery based on a

- variant long short term memory neural network”, *J. Power Sources*, Vol. 459, p. 228069, 2020.
- [49] L. Ungurean, M. V. Micea, and G. Cârstoiu, “Online state of health prediction method for lithium-ion batteries, based on gated recurrent unit neural networks”, *Int. J. Energy Res.*, Vol. 44, No. 8, pp. 6767-6777, 2020.
- [50] X. Feng, C. Weng, X. He, X. Han, L. Lu, D. Ren, and M. Ouyang, “Online state-of-health estimation for Li-ion battery using partial charging segment based on support vector machine”, *IEEE Trans. Veh. Technol.*, Vol. 68, No. 9, pp. 8583-8592, 2019.
- [51] X. Shu, G. Li, J. Shen, Z. Lei, Z. Chen, and Y. Liu, “A uniform estimation framework for state of health of lithium-ion batteries considering feature extraction and parameters optimization”, *Energy*, Vol. 204, p. 117957, 2020.
- [52] A. Widodo, M. C. Shim, W. Caesarendra, and B. S. Yang, “Intelligent prognostics for battery health monitoring based on sample entropy”, *Expert Syst. Appl.*, Vol. 38, No. 9, pp. 11763-11769, 2011.
- [53] S. Jia, B. Ma, W. Guo, and Z. S. Li, “A sample entropy based prognostics method for lithium-ion batteries using relevance vector machine”, *J. Manuf. Syst.*, Vol. 61, pp. 773-781, 2021.
- [54] A. Lamprecht, M. Riesterer, and S. Steinhorst, “Random forest regression of charge balancing data: A state of health estimation method for electric vehicle batteries”, *Proc. of 2020 International Conference on Omni-layer Intelligent Systems (COINS)*, pp. 1-6, Barcelona, Spain, 2020.
- [55] K. S. Mawonou, A. Eddahech, D. Dumur, D. Beauvois, and E. Godoy, “State-of-health estimators coupled to a random forest approach for lithium-ion battery aging factor ranking”, *J. Power Sources*, Vol. 484, p. 229154, 2021.
- [56] Y. Zhang, Z. Peng, Y. Guan, and L. Wu, “Prognostics of battery cycle life in the early-cycle stage based on hybrid model”, *Energy*, Vol. 221, p. 119901, 2021.
- [57] N. Yang, Z. Song, H. Hofmann, and J. Sun, “Robust State of Health estimation of lithium-ion batteries using convolutional neural network and random forest”, *J. Energy Storage*, Vol. 48, p. 103857, 2022.