

## 확장칼만필터를 활용한 배터리 시스템에서의 State of Charge와 용량 동시 추정

문예진 · 김남훈 · 유지훈 · 이경민 · 이종혁 · 조원희 · 김연수<sup>†</sup>

광운대학교 화학공학과  
01897 서울시 노원구 광운로 20  
(2021년 12월 15일 접수, 2022년 1월 18일 수정본 접수, 2022년 1월 24일 채택)

## Simultaneous Estimation of State of Charge and Capacity using Extended Kalman Filter in Battery Systems

Yejin Mun, Namhoon Kim, Jihoon Ryu, Kyungmin Lee, Jonghyeok Lee, Wonhee Cho and Yeonsoo Kim<sup>†</sup>

Department of Chemical Engineering, Kwangwoon University, 20 Kwangwoon-ro, Nowon-gu, Seoul, 01897, Korea  
(Received 15 December 2021; Received in revised form 18 January 2022; Accepted 24 January 2022)

### 요 약

본 논문에서는 전기자동차용 배터리 충/방전 상태 추정의 정확도를 개선하기 위해 칼만 필터(Kalman Filter, KF) 알고리즘과 등가회로모델(Equivalent Circuit Model)을 활용한 State Of Charge (SOC) 추정 방법을 적용하였다. 특히 노화된 배터리 용량을 함께 추정 가능한 관측기(observer)를 설계하였다. 우선 노화가 없는 경우, 칼만 필터를 이용하여 SOC를 단일 추정하면, 관측기 없이 모델로 계산된 경우와 비교하여 평균 절대 오차율이 1.43%(관측기 미사용)에서 0.27%(관측기 사용)로 감소하였다. 차량 주행상태에서는 전류가 고정되지 않아 SOC와 배터리 용량을 모두 추정하는 것에 일반적인 KF 혹은 Extended KF 알고리즘을 이용할 수 없다. 배터리 노화에 의한 용량 변화는 단시간에 일어나지는 않다는 점에 착안하여, 충전 시 배터리 용량 추정을 주기적으로 실시하는 전략을 제시하였다. 충전 모드에서는 일정 구간마다 전류가 고정되기에, 해당 상황에서 배터리 노화 용량을 SOC와 함께 추정 전략을 제시하였다. 전류가 고정된 상태에서 SOC 추정의 평균 절대 오차율은 0.54%였으며, 용량 추정의 평균 절대 오차율은 2.24%로 나타났다. 충전상태에서 전류가 고정됨으로 일반적인 EKF를 활용하여 배터리 용량과 SOC 동시 추정이 가능하도록 하였다. 이를 통하여 배터리 충전 시 주기적인 배터리 용량 보정을 수행할 수 있다. 그리고, 방전 시에는 해당 용량으로 고정된 채 SOC를 추정하는, 배터리 관리 시스템에서 활용 가능한 추정 알고리즘을 제안하였다.

**Abstract** – In this paper, an estimation algorithm for state of charge (SOC) was applied using an equivalent circuit model (ECM) and an Extended Kalman Filter (EKF) to improve the estimation accuracy of the battery system states. In particular, an observer was designed to estimate SOC along with the aged capacity. In the case of the fresh battery, when SOC was estimated by Kalman Filter (KF), the mean absolute percentage error (MAPE) was 0.27% which was smaller than MAPE of 1.43% when the SOC was calculated by the model without the observer. In the driving mode of the vehicle, the general KF or EKF algorithm cannot be used to estimate both SOC and capacity. Considering that the battery aging does not occur in a short period of time, a strategy of periodically estimating the battery capacity during charging was proposed. In the charging mode, since the current is fixed at some intervals, a strategy for estimating the capacity along with the SOC in this situation was suggested. When the current was fixed, MAPE of SOC estimation was 0.54%, and the MAPE of capacity estimation was 2.24%. Since the current is fixed when charging, it is feasible to estimate the battery capacity and SOC simultaneously using the general EKF. This method can be used to periodically perform battery capacity correction when charging the battery. When driving, the SOC can be estimated using EKF with the corrected capacity.

Key words: State of charge, Equivalent circuit model, Extended kalman filter, Observability

<sup>†</sup>To whom correspondence should be addressed.

E-mail: kimy3@kw.ac.kr

§이 논문은 광운대학교 교재교육 교수님의 정년을 기념하여 투고되었습니다.

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.

## 1. 서 론

최근 전기 자동차 사고 사례 중 그 비중이 증가하고 있는 배터리 폭발 사고를 예방하기 위해 완충하지 않고 State of Charge (SOC) 80%~90%까지만 충전하여 과 충전을 방지하는 방법이 대안으로 제시되고 있다. 배터리 사용을 관리하는 배터리 관리 시스템에 정확한 SOC 정보가 주어지면 더욱 효율적이고 안전하게 배터리를 관리할 수 있다[1-4]. SOC를 정확하게 측정할 수 있다면 자동차의 주행거리가 향상되고 연비가 증가하는 등 안전 및 제어 측면에서 더 좋은 효율이 기대된다[5]. 또한, 배터리를 사용함에 따라 점차 완충 용량이 줄어드는 현상이 나타나게 된다. 노화 현상에 의하여 감소된 용량을 정확히 추정하는 것도 전기차 주행 성능 및 안전에 중요하다. SOC 역시 총 용량에 영향을 받는 값이므로 노화된 용량을 추정할 필요가 있다.

방전 및 충전이 진행되지 않는, 정상상태에서는 Open circuit voltage (OCV)를 활용하여 SOC를 역 추정하거나, Coulomb Counting으로 SOC를 계산하는 방법이 잘 작동한다. 해당 방법들은 비교적 단순한 방법으로 실험실 조건이나 정상 상태에서는 활용이 가능하다. 그러나, 주행하거나 충전 상황에서는 전류가 흐르고 있기에 OCV-SOC map을 통하여 SOC를 실시간으로 추정하는 방법은 적합하지 않다. OCV 방법은 셀이 충분히 안정된 상태의 전압을 이용하기 때문이다. 또한, Coulomb Counting방법은 초기 SOC 값을 정확히 알지 못하고 전류 측정의 노이즈가 존재할 경우 그 오차가 누적되는 단점이 있다 [6-8]. 실험실 조건에서는 가한 전류 값과 초기 SOC를 정확히 알 수 있다. 그로부터 SOC를 Coulomb counting 방법으로 계산을 할 수 있기에 데이터로 확보 가능하다. 전류, 전압, 온도 등을 뉴랄넷의 입력, 계산된 데이터 SOC를 뉴랄넷의 출력으로 하여 뉴랄넷 모델을 구축하여 SOC 추정에 활용하는 방법들도 존재한다[9,10]. 그러나 모델 없이 데이터로만 구축된 뉴랄넷을 활용할 경우 추정되는 SOC에서 peak가 발생하는 현상이 나타나, 이를 모델과 Unscented Kalman Filter (UKF)를 활용하여 해결하는 방법도 존재한다[11].

시간이 지남에 따라 배터리 용량이 감소하며 SOC에 영향을 미치므로 감소된 배터리 용량도 추정할 필요가 있다. Coulomb counting 방법을 통해 현재 사이클에서의 최대 용량 값을 계산[12]하거나 뉴랄넷 모델로 학습[13]하거나, 모델 기반 관측기를 통해 SOC와 함께 추정하는 방법[14] 등이 있다. 특히 P. Shen et al. [14]에서 SOC는 모델 기반 관측기를 통해 추정되었으나, 노화도인 State of Health (SOH) 추정에는 관측기를 사용한 것이 아니라, OCV-SOC map을 활용하여 역추산하였다.

본 논문에서는 모델과 실시간 측정값을 통해 측정 불가능한 상태 변수를 추정할 수 있는 칼만 필터(Kalman Filter, KF) 알고리즘을 활용하여 SOC를 추정하였다. 특히, 점차 노화되는 배터리 용량을 함께 고려해 SOC를 추정할 필요가 있으므로, 해당 부분을 반영할 수 있는 전략을 제시하였다. 칼만 필터는 출력 값의 모델 예측 값과 현재 측정 데이터를 함께 활용하여 추정 정확도가 높으며 계산 로드가 moving horizon estimation과 같은 기법보다 높지 않다는 장점이 있다. 또한 데이터들에 대한 가중치를 임의로 주는 것이 아니라 계산을 통해 주어질 실시간으로 사용되므로 더 정확한 추정이 가능하다. 칼만 필터 적용을 위하여 적정 수준의 정확도와 낮은 계산 로드를 보이는 Equivalent Circuit Model (ECM)을 활용하였다.

전기화학적 이론 기반 모델들의 경우 셀 내부의 복잡한 화학적 반응 및 확산들을 고려하나 많은 계산 시간이 요구되기 때문에 실시간 응용에는 부적절하다[15].

본 연구에서는 배터리 용량까지 상태 변수로 포함시켜 확장된 동역학을 활용하여 SOC와 노화도를 함께 추정하는 전략을 제시하였다. 특히 충전 상황에서는 전류가 구간별로 일정하다는 점에 착안하여, 충전 상황에서 SOC 과 함께 노화된 용량을 추정하여 주기적으로 보완하는 방법을 제안하였다. 전류가 제한됨으로써 일반적인 Extended KF (EKF)가 적용 가능함을 확인하였다. 또한 Observability 분석을 통하여 관측 가능한 상황이었음을 확인하였다. 추가적으로 방전 상황에서는 보정된 용량을 고정된 뒤, EKF를 사용하여 SOC만 추정하였으며 해당 상황에서의 추정 정확도 분석을 수행하였다.

Section 2에서는 ECM에 대해 설명하고 이를 기반으로 계산되는 SOC 그래프를 그려보았다. Section 3에서는 KF에 대해 소개하고 이를 적용하여 SOC 추정을 수행하였다. Section 4에서는 배터리의 노화를 함께 추정하기 위해 상태 변수에 배터리 용량을 추가하였다. 이에 따라 비선형 시스템이 되어, EKF를 적용하였다.

## 2. Equivalent Circuit Model (ECM)

본 연구에서 사용된 notation의 명명 법을 Table 1에 나타내었다. Fig. 1과 같은 RC-ladder 1개의 등가회로모델을 사용하여 리튬 이온 배터리의 동 특성을 모사한 J. Zhang et al. [1]의 ECM 식과 패러미터 값을 활용하였다. 해당 지배방정식은 (1)-(3)과 같다.

$$SOC(k+1) = SOC(k) - \frac{n_0 \Delta T}{C_{b,s}} I_B(k) \quad (1)$$

$$V_A(k+1) = e^{\frac{-\Delta T}{R_s C_s}} V_A(k) + \left(1 - e^{\frac{-\Delta T}{R_s C_s}}\right) R_s I_B(k) \\ = \theta_1 V_A(k) + (1 - \theta_1) \theta_2 I_B(k) \quad (2)$$

$$V_B(k) = OCV(SOC(k)) - R_0 I_B(k) - V_A(k) \\ = OCV(SOC(k)) - \theta_3 I_B(k) - V_A(k) \quad (3)$$

여기서 OCV는 두 단자 사이에 외부적으로는 아무것도 연결되지 않은 상태에서의 전압을 의미하며, 배터리 종류에 따라 달라지는 부분이다. J. Zhang et al. [1]에서 실험데이터로부터 다음과 같이 구축되었다.

$$OCV(SOC) = \theta_4 SOC + \theta_5 \\ = \begin{cases} 3.58 \times SOC + 2.805 & (0\% \leq SOC \leq 10\%) \\ 0.213 \times SOC + 3.142 & (10\% \leq SOC \leq 95\%) \\ 4.682 \times SOC - 1.103 & (95\% \leq SOC \leq 100\%) \end{cases} \quad (4)$$

$V_A$ 는 RC회로에 걸리는 전압을 의미하며, 해당 부분의 저항 및 capacitance는 각각  $R_s$ ,  $C_s$ 로 표시하였다.  $V_B$ 는 단자 전압을,  $R_0$ 는 내부 저항을 의미한다.  $C_b$ 는 배터리용량으로 J. Zhang et al. [1]에서 사용한 배터리는 36Ah용량을 가진다.  $C_{b,s}$ 는 As단위로 나타낸 값으로 129600As이다.  $n_0$ 는 배터리 셀의 쿨롱효율계수로 이상적인 값 1을 사용한다.  $\Delta T$ 는 샘플링 시간으로 1초로 설정되었다.  $\theta_1$ ,  $\theta_2$ ,  $\theta_3$ 로 치환한 부분의 값은 다음과 같으며, J. Zhang et al. [1]에서 구축된 패러미터 값을 활용하였다.

Table 1. Nomenclature

	Parameter	Name
$A$	System matrix ( $n \times n$ ) matrix	-
$B$	Input matrix ( $n \times 1$ ) column vector	-
$C_{b,s}$	Nominal capacity in unit A·s	A·s
$C_b$	Nominal capacity in unit A·h	A·h
$C_t$	Capacitance of RC circuit	A·s
$H$	Output matrix ( $m \times n$ ) matrix	-
$I_B$	Applied current of battery	A
$K_k$	Kalman gain Matrix	-
$M_0$	Observability matrix	-
$P_0$	Initial error covariance matrix	-
$P_k^-$	Error covariance matrix before current measurements are used	-
$Q$	System disturbance covariance matrix	-
$R$	Measurement noise covariance matrix	-
$R_0$	Internal resistance	$\Omega$
$R_t$	Resistance of RC circuit	$\Omega$
$\Delta T$	Sampling time	s
$u_k$	System input	-
$v_k$	Measurement noise	-
$w_k$	Process disturbance	-
$x_k$	State variable	-
$\hat{x}_0$	Initial estimation of state variable ( $n \times 1$ )	-
$\hat{x}_k^-$	The predicted value of $x_k$ before current measurements are considered	-
$\hat{x}_k$	Present estimated value	-
$z_k$	Measurements ( $m \times 1$ )	-




Fig. 1. Equivalent Circuit Model.

$$\theta_1 = e^{-\frac{\Delta T}{R_t C_t}} = 0.9838, \theta_2 = R_t = 0.00631, \theta_3 = R_0 = 0.0224 \quad (5)$$

지배 방정식 (1)-(3)과 패러미터 정보 (4), (5)를 활용하여 관측기 없이 시뮬레이션 한 결과는 Fig. 2와 같다. 초기 SOC는 0.8로 설정하였고, RC회로의 초기 전압은 0.1V로 설정하였다.

관측기를 설계하는 이유는 초기 상태 값의 불확실성 뿐만 아니라 모델과 실제 플랜트와의 차이가 있기 때문이다. 이로 인해, 모델과 측정값 모두를 활용하여 시스템의 상태를 추정할 필요가 있다. 초기값에 대한 불확실성은 관측기 설계의 다음 섹션들에 명시하였으며 여기에서는 모델과 실제 시스템과의 불확실성 구현에 대해 명시하였다. (1)의 SOC dynamics에는 평균 0, 분산  $10^{-4}$ 인 정규분포를 따르는 외란을 더하였고, (2)의 RC ladder dynamics에는 평균 0, 분산  $10^{-4}$ 인 정규분포를 따르는 외란을 더하였다. 분산의 크기  $10^{-4}$ 는 SOC와 RC ladder 전압 크기를 고려하여 설정되었다. SOC의 경우




Fig. 2. SOC calculated by ECM with disturbances (Black line) and without disturbances (Red line). SOC calculated by ECM when aging factor 0.9 is multiplied to  $C_b$ .




Fig. 3. Current scenario used for simulation, dynamic stress test.

0-1 사이의 값을 가지기에, 표준편차가 0.01인 외란을 더하였다. 68.2% 확률로  $\pm 0.01$ 범위 내의 모델 오차가 발생함을 의미한다. RC ladder의 전압의 경우 절대값이 0-0.25 사이의 값을 가지며 약 최대치의  $\pm 4\%$ 에 해당하는 오차 범위 내의 외란이 68.2% 확률 발생하도록 설정하였다. 발생할 수 있는 노이즈의 크기는 시스템마다 다르며, 본 논문에서는 위와 같은 설정 하에서 구축된 관측기를 테스트할 것이다. 전류  $I_B$ 는 Fig. 3과 같이 Dynamic Stress Test (DST) 시나리오를 반복적으로 활용하여 시뮬레이션을 수행하였다. 전류는 방전 시 양의 값을 가지고, 충전 시에서는 음의 값을 갖는다.

Fig. 2에서 SOC (Model)은 모델을 통하여 계산된 값이고, SOC (Real)는 확률적 외란이 더해진 실제 값으로 간주되는 값이다. SOC (Aging)은 배터리의 노화가 발생한 경우를 구현한 것으로 식 (2)의  $C_b$ 에 aging factor인 0.9를 곱한 것으로 시뮬레이션한 결과이다.

Fig. 2에서 알 수 있듯이, model값과 real값의 차이가 존재하고 더 나아가 배터리의 노화를 고려했을 때는 그 차이가 더 심하다는 것을 볼 수 있다. 이러한 차이를 줄이기 위해 측정값을 활용하여 상

태 추정 값을 보정하는 칼만 필터를 적용할 것이다.

### 3. 칼만 필터(Kalman Filter) 활용한 SOC 추정

칼만 필터는 정보가 확실하지 않은 일부 동적 시스템에서 사용할 수 있으며 시스템이 다음에 수행할 작업에 대해 정확한 추측을 하는 데 도움을 주는 재귀 필터이다[16-20]. 미사일의 궤적 추정, 레이다, 인공위성의 항법 등에 많이 이용되어 왔고 최근에는 고속의 고성능 마이크로 프로세서의 발달로 인해 칼만 필터는 매우 복잡한 실시간 처리 시스템 분야에서도 이용이 되고 있다. 칼만 필터 적용에 대한 설명을 위하여 일반적인 선형 시스템의 상태 공간 방정식을 다음과 같이 적었다[21].

$$x_{k+1} = Ax_k + Bu_k + w_k \quad (6)$$

$$z_k = Hx_k + v_k \quad (7)$$

Notation 단순화를 위하여 time step을 의미하는  $k$ 는 아래 첨자에 적었다. 제어 입력  $u_k$ 는 우리가 결정해주는 것이기에 들어가는 값을 정확히 알 수 있다는 가정 하에 일반적인 칼만 필터가 설계된다.  $w_k$ 와  $v_k$ 는 각각 상태 변수 동역학에 미치는 외란과 측정 노이즈를 나타내며, 정규분포를 따른다고 가정한다. 행렬  $A$ 는 시간에 따른 시스템의 거동을 나타내주는 시스템 행렬이고 행렬  $H$ 는 측정값과 상태 변수의 관계를 나타내는 출력 행렬이다.

이러한 변수들을 배터리 모델 식과 비교해보면 상태 변수인  $x_k$ 는 SOC와  $V_f$  값을 나타내고,  $u_k$ 는 전류,  $z_k$ 는  $V_B$  값을 나타낸다.

$$\begin{aligned} x(k) &= \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} = \begin{bmatrix} SOC(k) \\ V_f(k) \end{bmatrix} \\ u(k) &= I_B(k) \\ z(k) &= V_B(k) \\ w(k) &\sim N(0, Q_R) \\ v(k) &\sim N(0, Q_R) \end{aligned} \quad (8)$$

이번 시뮬레이션에서는 다음과 같은  $Q_R$ 과  $R_R$  값을 사용하였다.

$$Q_R = \begin{bmatrix} 10^{-4} & 0 \\ 0 & 10^{-4} \end{bmatrix}, \quad R_R = 10^{-4}$$

칼만 필터 알고리즘은 크게 예측 과정과 추정 과정을 통해 다음과 같은 과정으로 실행된다[17,20].

1. 칼만 필터 알고리즘을 시작하기 위해 초기 상태 변수 추정 값과 오차공분산의 초기값( $\hat{x}_0$  및  $P_0$ )을 설정한다.

2. 예측 과정에서는 모델, 이전에 계산된 추정 값과 오차 공분산 값을 이용해 현재 상태 변수 값  $\hat{x}_k$ 와 오차 공분산  $\hat{P}_k$ 의 값을 예측한다.

3. 추정 과정에서는 예측 과정에서 구한 예측 값과 측정값의 차이를 보정해 최종 추정 값을 계산한다.

식 (9)-(10)은 예측 과정을 나타내고, 식 (11)-(13)는 추정 과정을 나타낸다.

$$\hat{x}_k^- = A\hat{x}_{k-1}^- + Bu_{k-1} \quad (9)$$

$$P_k^- = AP_{k-1}A^T + Q \quad (10)$$

$$K_k = P_k^- H^T (HP_k^- H^T + R)^{-1} \quad (11)$$

$$\hat{x}_k = \hat{x}_k^- + K_k(z_k - H\hat{x}_k^-) \quad (12)$$

$$P_k = P_k^- - K_k H P_k^- \quad (13)$$

지배 방정식 (1)-(3)를 정리하여, 최종적으로 칼만 필터 적용하기 위한 시스템의 상태 공간 방정식 및 출력방정식으로 나타내면, 각각 식 (14)와 (15)와 같다. 행렬  $A$ ,  $B$ ,  $H$ 는 식 (16)과 같이 나타낼 수 있다. 특히, 본 섹션에서는 (15)와 같이, 실제 측정값인  $V_D(k)$ , 측정되는 입력 전류와 모델 상수로 이루어진 항,  $V_B(k) + \theta_3 I_B - \theta_5$ 를 가상의 출력으로 간주하여, KF 적용 가능한 선형 시스템 형태로 정리하였다.

$$\begin{bmatrix} SOC(k+1) \\ V_f(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & \theta_1 \end{bmatrix} \begin{bmatrix} SOC(k) \\ V_f(k) \end{bmatrix} + \begin{bmatrix} -\frac{\eta_0 \Delta T}{C_{b,s}} \\ (1-\theta_1)\theta_2 \end{bmatrix} I_B(k) \quad (14)$$

$$z_{virtual} = V_B(k) + \theta_3 I_B - \theta_5 = [\theta_4 \quad -1] \begin{bmatrix} SOC(k) \\ V_f(k) \end{bmatrix} \quad (15)$$

$$A = \begin{bmatrix} 1 & 0 \\ 0 & \theta_1 \end{bmatrix}, \quad B = \begin{bmatrix} -\frac{\eta_0 \Delta T}{C_{b,s}} \\ (1-\theta_1)\theta_2 \end{bmatrix}, \quad H = [\theta_4 \quad -1] \quad (16)$$

앞서 설명한 칼만 필터를 적용한 SOC 추정 그래프는 Fig. 4와 같다. 초기 SOC와  $V_f$  추정 값은 실제 값과 1% 오차를 갖도록 설정

하였으며, 그에 따라  $P_0 = \begin{bmatrix} 10^{-4} & 0 \\ 0 & 10^{-4} \end{bmatrix}$ 로 설정되었다.  $Q_R = \begin{bmatrix} 10^{-4} & 0 \\ 0 & 10^{-4} \end{bmatrix}$ ,

$R_R = 10^{-4}$  설정하였다.

Fig. 4를 통해 칼만 필터를 적용하여 보정된 SOC가 실제 SOC를 잘 추정하고 있는 것을 확인 하였다. Fig. 4(a)에는 칼만 필터를 활용하였을 때 추정된 SOC와 실제 SOC, 칼만 필터가 적용되지 않았을 때의 SOC값이 나타나 있다. Fig. 4(b)에는 칼만 필터로 보정된 SOC와 적용되지 않았을 때 SOC 값의 실제 SOC 값에 대한 오차율을 나타내었다. 전체 시뮬레이션 시간 동안의 Mean absolute percentage error (MAPE), Maximum absolute percentage error는 Table 2에 나타내었다. MAPE는 칼만 필터를 사용하지 않았을 때와 비교하여 1.43%에서 0.27%로 감소하였다. 최대 절대 오차 값 역시 2.06%에서 1.21%로 감소하였다. 이로써 칼만 필터를 적용함으로써 SOC 추정의 정확도가 향상된 것을 확인할 수 있다.

### 4. 배터리 노화 정도 및 SOC 동시 추정

배터리를 지속적 사용하면 aging으로 인하여 fresh 상태보다  $C_b$ 가 줄어들게 된다. 해당 값은 SOC 계산식에 포함되어 있으며 SOC 추정 정확도에 상당한 영향을 미치게 되므로 노화 되었을 때 줄어든  $C_b$ 를 추정하여 주기적으로 업데이트할 필요가 있다. 이를 위해 배터리 용량인  $C_b$ 를 상태 변수로 간주하여 확장된 모델을 활용하여 관측기를 설계하였다. 방전상태에서는 전류가 일정하지 않으므로 상태 변수  $C_b$ 와 입력 변수  $I_B$ 가 서로 곱해진 Bilinear System이 되는 문제점이 발생되어 일반적인 KF를 활용할 수 없다. 하지만 충전 상태에서는 일반적으로 전류가 구간별로 일정한 값을 가지므로  $C_b$ 를 충전 조건에서 추정하는 전략을 제시하고자 한다.

$C_b$ 를 새로운 상태 변수로 정의할 경우 식 (1)에서  $C_b$ 가 분모에




Fig. 4. (a) Real SOC, SOC estimated using Kalman Filter, and SOC calculated without Kalman Filter. (b) Percent error with respect to real SOC values.

Table 2. Mean and maximum of absolute percentage error in SOC estimated by KF and calculated without KF

	SOC estimated using KF	SOC calculated without KF
Mean absolute percentage error [%]	0.27	1.43
Maximum absolute percentage error [%]	1.21	2.06

존재하여 시스템 모델이 비선형이 되기 때문에 선형 시스템 모델에만 사용할 수 있는 칼만 필터를 적용할 수 없다. 이를 해결하기 위해서 비선형 시스템을 선형 화한 정보를 활용하는 EKF를 사용한다 [17,20]. 일반적인 비선형 시스템 모델을 다음과 같이 적을 수 있다.

$$\hat{x}_k = f(\hat{x}_{k-1}, u_{k-1}) \quad (17)$$

$$\hat{z}_k = h(\hat{x}_k, u_k) \quad (18)$$

이러한 시스템을 위한 EKF의 알고리즘은 (19)-(23)과 같다. Gain을 계산하는 (20)-(21)은 선형 칼만 필터와 동일하게 계산되며 이때, A와 H 행렬은 비선형 시스템의 함수 f와 h의 1차 Taylor 항을 사용하게 된다. 즉,  $A = \left. \frac{\partial f(x, u)}{\partial x} \right|_{\hat{x}_{k-1}, u_{k-1}}$ ,  $H = \left. \frac{\partial h(x, u)}{\partial x} \right|_{\hat{x}_k, u_k}$  을 의미한다.

$$\hat{x}_k^- = f(\hat{x}_{k-1}, u_{k-1}) \quad (19)$$

$$P_k^- = AP_{k-1}A^T + Q \quad (20)$$

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1} \quad (21)$$

$$\hat{x}_k = \hat{x}_k^- + K_k(z_k - \hat{z}_k^-) \quad (22)$$

$$P_k = P_k^- - K_k H P_k^- \quad (23)$$

$C_b$ 를 추가적 상태 변수로 간주하는 ECM에 대하여 A, H를 계산하기 위하여 식 (1)을 현 시점에서의  $C_b$  추정 값,  $C_{b,e}$ 을 기준으로 테일러 전개하면 식 (24)과 같다.

$$SOC(k+1) = SOC(k) - \frac{\eta_0 \Delta T}{3600} I_B \left( \frac{1}{C_{b,e}} - \frac{1}{C_b^2} (C_b(k) - b_{b,e}) \right) \quad (24)$$

여기서, 3600은 A·h를 A·s로 변환해주는 conversion factor이다. 기존 상태 변수인 SOC는 0-1 범위의 값,  $V_i$ 는 nominal voltage 3.2V 근방의 값들을 가진다. 따라서 새롭게 추가되는 상태 변수를

A·s단위로 할 경우  $C_{b,s}$ 는 nominal capacity 값인 129600 A·s 근방의 값을 갖게 되므로 다른 상태변수들과 scale 차이가 크게 된다. 기존 상태변수들과 scale이 지나치게 차이 나지 않도록 A·h인  $C_b$ 를 사용하였으며 이로 인하여 수식에 conversion factor 3600이 적히게 된다. 식 (24)를 추가적으로 정리하면 식 (25)과 같다.

$$\begin{aligned} SOC(k+1) &= SOC(k) - \frac{\eta_0 \Delta T}{3600} I_B \left( \frac{1}{C_{b,e}} - \frac{1}{C_b^2} (C_b(k) - b_{b,e}) \right) \\ &= SOC(k) + \frac{\eta_0 \Delta T}{3600} \frac{I_B}{C_{b,e}^2} C_b(k) - \frac{\eta_0 \Delta T 2 I_B}{3600 C_{b,e}} \end{aligned} \quad (25)$$

최종적으로 상태 변수  $C_b$ 를 추가함에 따라 확장된 상태 변수 동역학은 다음과 같다.

$$SOC(k+1) = SOC(k) + \frac{\eta_0 \Delta T}{3600} \frac{I_B}{C_{b,e}^2} C_b(k) - \frac{\eta_0 \Delta T 2 I_B}{3600 C_{b,e}} = \quad (26)$$

$$V_i(k+1) = \theta_1 V_i(k) + (1 - \theta_1) \theta_2 I_B \quad (27)$$

$$C_b(k+1) = C_b(k) \quad (28)$$

$$\begin{aligned} z(k) &= V_B(k) = OCV(SOC(k)) - \theta_3 I_B(k) - V_i(k) \\ &= \theta_4 \times SOC(k) + \theta_5 - \theta_3 I_B(k) - V_i(k) \end{aligned} \quad (29)$$

A, H 행렬을 식 (30), (31)에 정리되어 있으며, 유의할 점은  $C_{b,e}^2$  값이 매 스텝 변하므로 A역시 매 스텝 업데이트 되어야 한다는 점이다.

$$A(k) = \begin{bmatrix} 1 & 0 & \frac{\eta_0 \Delta T}{3600} \frac{I_B}{C_{b,e}^2} \\ 0 & \theta_1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, B(k) = \begin{bmatrix} -\frac{\eta_0 \Delta T 2}{3600 C_{b,e}} \\ (1 - \theta_1) \theta_2 \\ 0 \end{bmatrix} \quad (30)$$

$$H = [\theta_4 \quad -1 \quad 0] \quad (31)$$

#### 4-1. Simulation Results

10% aging 되어 nominal capacity의 90%가 된 경우를 시뮬레이션 하였다. 충전 속도는 1C-rate (36A)인 상황을 설정하였다. 초기 SOC와  $V_t$  추정 값은 실제 값과 1% 오차를 갖는 것으로 설정하였으며, 초기  $C_b$  추정 값은 5% 과 추정된 값으로 설정하였다. 그에 따라

$$P_0 = \begin{bmatrix} 10^{-4} & 0 & 0 \\ 0 & 10^{-4} & 0 \\ 0 & 0 & 25 \times 10^{-4} \end{bmatrix} \text{로 설정되었다. EKF gain 계산을 위한 } Q \text{와}$$

$R$ 값은 다음을 사용하였다.

$$Q = \begin{bmatrix} 10^{-4} & 0 & 0 \\ 0 & 10^{-4} & 0 \\ 0 & 0 & 3 \end{bmatrix}, R = 10^{-4}$$

EKF를 적용하여 SOC추정 오차 그래프는 Fig. 5(a)와 같으며 용량 추정 오차율은 Fig. 5(b)에 나타내었다. 평균 절대 오차율, 최대 절대 오차율은 Table 3에 나타내었다. Fig. 5(a)에서 빨간색 선은 확장된 상태 변수 동역학과 EKF를 사용하여 capacity와 SOC가 동시 추정될 때, 추정 SOC가 갖는 오차율이다. 파란색 선은 초기 capacity 추정 값인, 즉 실제 노화된 capacity ( $0.9 C_b$ )를 5%과 추정한 값으로 고정하고, 섹션 3의 KF를 활용해 SOC를 추정할 때의 오차율이다. Table 3에서 확인할 수 있듯이, capacity를 함께 추정할 경우, SOC의 평균 절대 오차율은 0.54%로, 과-추정된 용량으로 고정된 상황에서 SOC만 추정되었을 때의 평균 절대 오차율 0.97% 보다 개선됨을 확인할 수 있다. 특히 추정된 capacity의 평균 절대 오차율은 2.24%로 초기 5% 과 추정된 용량을 개선시킴을 확인하였다. 이는 Fig. 5(b)에서 확인 가능하다. 추가적으로 Fig. 5(c)에는 추정되고 있는 capacity의 actual값을 그렸다. 90% 노화된 실제 capacity 값은 32.4Ah이며, Fig. 5(c)에서 확인되듯이 5% 과 추정된 초기값에서 시작하여 점차 실제 노화된 capacity에 가깝게 추정되는 것을 확인할 수 있다.

#### 4-2. Observability 분석

배터리 용량  $C_b$ 를 새로운 상태 변수  $x_3$ 로 추가하여 배터리 용량을 추정하는 것이 가능한 사항이었던 지 확인하기 위해 observability를 체크해 보았다. 제어 시스템을 상태 변수 방정식으로 나타낼 때, 상태변수들은 시스템의 내부 변수들이므로 외부에서 측정하기 어려운 경우가 많다. 제어기를 설계하거나 제어 시스템의 상태를 관찰하기 위해서 모든 상태의 변수들을 측정할 필요성이 있다. 이번 논문에서 SOC와 용량 동시 추정 observer를 구성하였고 이와 같은 observer가 상태 변수 값을 알아내기 위해서는 시스템이 관측 가능(적어도 detectable)해야 하며, 이러한 특징을 관측 가능성(observability)이라고 부른다[21].

$$x_{k+1} = Ax_k + Bu_k \quad (32)$$




Fig. 5. (a) Percent error in SOC when estimated along with capacity (Red line) and estimated with the initial estimated capacity (Blue line). (b) Percent error in capacity when estimated along with capacity. (c) Estimated capacity (Red line) and the actual aged capacity (Black line).

$$z_k = Hx_k \quad (33)$$

식 (32)와 (33) 같은 형태의 상태 공간 방정식이 있을 때

Table 3. Mean and maximum of absolute percentage errors in SOC and  $C_b$  estimates when they are estimated simultaneously by EKF. Those percentage errors in SOC when only SOC is estimated by KF with the overestimated capacity

	Simultaneous estimation of SOC and capacity		Estimation of SOC with the overestimated capacity
	$C_b$	SOC	SOC
Mean absolute percentage error [%]	2.24	0.54	0.97
Maximum absolute percentage error [%]	5.00	1.96	2.34




Fig. 6.  $\text{Det}(M_O)$  graph.

observability 행렬은 식 (34)과 같이 나타낼 수 있다.

$$M_O = \begin{bmatrix} H \\ HA \\ HA^2 \\ \vdots \\ HA^{n-1} \end{bmatrix} \quad (34)$$

만약  $\text{det}(M_O)$ 의 값이 0이 아닐 때, 즉 역 행렬이 존재할 때 이 시스템은 관측 가능하고, 0일 때는 관측 불가능하다.  $\text{det}(M_O)$ 을 구하는 과정에서 행렬 A와 H는 매 스텝 상태 값과 SOC 범위에 따라 바뀌는 행렬이므로 행렬식 값은 일정하지 않다. 전체 시뮬레이션 동안 매 스텝 상태에서의 선형 화를 진행하고 그 선형 시스템의  $\text{det}(M_O)$  값의 그래프를 그려보면 Fig. 6과 같다. 따라서  $\text{det}(M_O)$ 의 값이 0이 아니므로 매 스텝 선형화 된 시스템은 관측 가능하다는 observability를 얻어 낼 수 있다. 시뮬레이션 동안 eigenvalue 값 각각의 평균은 -0.76, -0.004, -3.64E-8이었다.

Observability matrix  $M_O$ 에  $t=0$  시점의 상태변수 값  $x_0$ 을 곱하면 아래와 같다.

$$M_O x_0 = \begin{bmatrix} H \\ HA \\ HA^2 \end{bmatrix} x_0 = \begin{bmatrix} z_0 \\ z_1 \\ z_2 \end{bmatrix} \quad (35)$$

시스템 상태변수 차원인 3 스텝 동안의 측정값  $[z_0 \ z_1 \ z_2]$ 으로부터  $x_0$ 을 unique 하게 결정할 수 있기 위해서는  $M_O$ 가 full rank여야 함을 다시 한번 확인할 수 있다. 또한,  $M_O$ 의 eigenvalue 크기는 대응되는 eigenvector의 영향이 측정값  $[z_0 \ z_1 \ z_2]$ 에 얼마나 나타날 것인가에 대한 정보를 가지고 있다. 따라서, 해당 eigenvalue의 비율이 너무 크게 차이 나지 않을 경우가 더 추정이 용이한 시스템이라 할 수 있다.

본 논문에서는 local observability를 분석하였다. Determinant 값이 0이 아닌 것으로부터 관측 가능함을 확인하였다. 그러나 eigenvalue 값 각각의 평균들을 살펴보았을 때, 최대 eigenvalue와 최소 eigenvalue가 상당히 크게 차이 남을 볼 수 있다. 이는  $M_O$ 의 condition number가 평균적으로 상당히 컸을 것임을 의미한다.

Condition number가 클수록 상태 변수의 추정이 어렵다는 것[22]을 고려할 때, future work로써 low-observability를 추가적으로 해결할 수 있는 방안에 대한 연구가 필요할 것이다. 기존 이를 해결하기 위한 방법론으로는 pseudo-measurement 존재하는 센서로부터 정의 [23,24]하거나 과거 데이터를 추가적으로 더 활용하는 방안[25], 센서 추가를 제안하는 방안[26-28] 등이 있다.

## 5. 결 론

본 논문에서는 실시간 구현 및 모델의 오차 보정을 해주고 노이즈에 강인한 특성을 가지고 있는 EKF를 사용하여 노화된 배터리의 SOC 및 배터리 용량을 실시간으로 동시 추정하는 알고리즘을 제안하였다. 배터리 용량을 상태 변수로 추가한 확장된 ECM을 활용하며 충전 모드인 정 전류(constant current) 상황에서 EKF를 적용하는 전략을 제시하였다. 가상 실제 값과 SOC의 평균 절대 오차율은 0.54%로 용량을 함께 추정하지 않은 경우의 오차율 0.97%보다 감소한 결과를 보였다. 용량 추정 값의 평균 절대 오차율은 초기 과 추정 오차율 5%보다 감소한 2.24%를 보였다. 또한 observability를 분석함으로써 확장된 시스템 모델에서의 용량 관측 가능성을 판단하였다. 이 관측 가능성을 함께 제시함으로써 terminal voltage만 측정되는 상황에서 확장된 상태 변수 값들이 추정될 수 있는 구조임을 확인하였다.

향후에는 관측 가능성 행렬의 condition number가 큰 것을 추가적으로 해소할 필요가 있으며 이를 통하여 상태 변수 추정을 보다 용이하고 노이즈에 강건하게 만들 필요가 있다.

## References

- Ouyang, Q., Chen, J. and Zheng, J., "State-of-charge Observer Design for Batteries with Online Model Parameter Identification: A Robust Approach," *IEEE Transactions on Power Electronics*, **35**(6), 5820-5831(2019).
- Ryu, K., Kim, B., Kim, D., Jang, M., Ko, H. and Kim, H., "A State-of-Charge Estimation Using Extended Kalman Filter for Battery of Electric Vehicle," *Journal of the Korea Academia-Industrial Cooperation Society*, **18**(10), 15-23(2017).
- Xiong Rui, et al. "Critical Review on the Battery State of Charge Estimation Methods for Electric Vehicles," *IEEE Access*, **6**, 1832-1843(2017).
- Ouyang, Q., Chen, J. and You, K., "State of Charge Estimation of Lithium-ion Batteries with Unknown Model Parameters, 2016 American Control Conference (ACC), IEEE, 2016.
- Kai, Wang, et al. "State of Charge (SOC) Estimation of Lithium-ion Battery Based on Adaptive Square Root Unscented Kalman Filter," *International Journal of Electrochemical Science*, **15**(9), 9499-9516 (2020).
- Bae, K.-C., et al. "OCV Prediction Method for SOC Estimation of Li-ion Battery. In: Proceedings of the KPIE Conference," *The Korean Institute of Power Electronics*, 528-529(2014).
- Koo, J., Study on SoC Accuracy Improvement of Lithium-Ion Battery System, Graduate School of Chonnam National University (2019).
- Jang, K. and Jeong, K., "A SOC Estimation using Kalman Filter for Lithium-Polymer Battery," *Transactions of the Korean Insti-*



- tute of Power Electronics*, 17(3), (2012).
9. Hannan, M. A., Lipu, M. S. H., Hussain, A., Saad, M. H. and Ayob, A., "Neural Network Approach for Estimating State of Charge of Lithium-Ion Battery Using Backtracking Search Algorithm," *IEEE Access*, **6**, 10069-10079 (2018).
  10. Tong, S., Lacap, J. H., Park, J. W., "Battery State of Charge Estimation Using a Load-classifying Neural Network," *Journal of Energy Storage*, **7**, 236-243(2016).
  11. He, W., Williard, N., Chen, C. and Pecht, M., "State of Charge Estimation for Li-ion Batteries Using Neural Network Modeling and Unscented Kalman Filter-based Error Cancellation," *International Journal of Electrical Power & Energy Systems*, **62**, 783-791(2014).
  12. Berecibar, M., Gandiaga, I., Villarreal, I., Omar, N., Van Mierlo, J. and Van den Bossche, P., "Critical Review of State of Health Estimation Methods of Li-ion Batteries for Real Applications," *Renewable and Sustainable Energy Reviews*, **56**, 572-587(2016).
  13. Duo Yang, Yujie Wang, Rui Pan, Ruiyang Chen, Zonghai Chen, "A Neural Network Based State-of-Health Estimation of Lithium-ion Battery in Electric Vehicles," *Energy Procedia*, **105**, 2059-2064(2017).
  14. Shen, P., Ouyang, M., Lu, L., Li, J. and Feng, X., "The Co-estimation of State of Charge, State of Health, and State of Function for Lithium-Ion Batteries in Electric Vehicles," *IEEE Transactions on Vehicular Technology*, **67**(1), 92-103(2018).
  15. Jo, S., Jung, S. and Kim, H., "Development of Battery Monitoring System Using the Extended Kalman Filter," *Journal of the Korea Convergence Society*, **11**(6), 7-14(2020).
  16. How, D. N., Hannan, M. A., Lipu, M. S. and Ker, P. J., "State of Charge Estimation for Lithium-ion Batteries Using Model-based and Data-driven Methods: A Review," *IEEE Access*, **7**, 136116-136136(2019).
  17. Simon, D., Optimal state estimation: Kalman, H infinity, and nonlinear approaches, 2006: John Wiley & Sons.
  18. Sin, S., Park, J., Baek, J., Kang, M. and Kim, J., "Improving Accuracy of Battery Modeling by Estimating the Diffusion Voltage of Li-ion Batteries Based on EKF," *Power Electronics Conference*, **11**, 230-231(2020).
  19. Lee, S. and Park, M., "Battery State of Charge Estimation Considering the Battery Aging," *Journal of IKEEE*, **18**(3), 298-304(2014).
  20. Steven M. Kay, Fundamentals of Statistical Signal Processing, 2013: Pearson Education.
  21. Chen, C.-T., Linear System Theory and Design, 4ed, 2013: Oxford University Press.
  22. Krener, A. J. and Ide, K., "Measures of Unobservability," *Proceedings of the 48th IEEE Conference on Decision and Control (CDC)*, 6401-6406(2009).
  23. Manitsas, E., Singh, R., Pal, B. C. and Strbac, G., "Distribution System State Estimation Using An Artificial Neural Network Approach for Pseudo Measurement Modeling," *IEEE Transactions on Power Systems*, **27**(4), 1888-1896(2012).
  24. Wu, J., He, Y. and Jenkins, N., "A Robust State Estimator for Medium Voltage Distribution Networks," *IEEE Transactions on Power Systems*, **28**(2), 1008-1016(2013).
  25. Rey, D., Chaos, observability and symplectic structure in optimal estimation. UC San Diego Ph.D. Thesis, 2017.
  26. Singh, R., Pal, B. C. and Vinter, R. B., "Measurement Placement in Distribution System State Estimation," *IEEE Transactions on Power Systems*, **24**(2), 668-675(2009).
  27. Bhela, S., Kekatos, V. and Veeramachaneni, S., "Enhancing Observability in Distribution Grids Using Smart Meter Data," *IEEE Transactions on Smart Grid*, **9**(6), 5953-5961(2018).
  28. Jiang, H. and Zhang, Y., "Short-term Distribution System State Forecast Based on Optimal Synchrophasor Sensor Placement and Extreme Learning Machine," *IEEE Power and Energy Society General Meeting (PESGM)*, 1-5(2016).

#### Authors

**Yejin Mun:** Undergraduate student, Department of Chemical Engineering, Kwangwoon University, Seoul 01897, Korea; ginniemoon@naver.com

**Namhoon Kim:** Undergraduate student, Department of Chemical Engineering, Kwangwoon University, Seoul 01897, Korea; npk2315@naver.com

**Jihoon Ryu:** Undergraduate student, Department of Chemical Engineering, Kwangwoon University, Seoul 01897, Korea; ryuwlgn2@naver.com

**Kyungmin Lee:** Undergraduate student, Department of Chemical Engineering, Kwangwoon University, Seoul 01897, Korea; zxc12323@kw.ac.kr

**Jonghyeok Lee:** Undergraduate student, Department of Chemical Engineering, Kwangwoon University, Seoul 01897, Korea; jhldlwhdgur7@naver.com

**Wonhee Cho:** Undergraduate student, Department of Chemical Engineering, Kwangwoon University, Seoul 01897, Korea; dnjsgmlwh98@naver.com

**Yeonsoo Kim:** Assistant Professor, Department of Chemical Engineering, Kwangwoon University, Seoul 01897, Korea; kimy3@kw.ac.kr