

# 배터리 용량 예측을 위한 실시간 SOC 보정 모델 및 아레니우스 방정식 기반 열화 모델을 결합한 최적 열화 모델 설계

이재형\*, 공태현\*, 김병철\*\*, 진보건\*\*, 김종훈\*  
 충남대학교 에너지저장변환연구실\*, (주)효성중공업 연구소\*\*

## Developing an optimal deterioration model combining real-time SOC estimation model and Arrhenius deterioration model for battery capacity prediction

Jaehyeong Lee\*, Taehyeon Gong\*, Byoungchoul Kim\*\*, Bogun Jin\*\*, Jonghoon Kim\*  
 Energy Storage Conversion Lab., Chungnam National University\*, Hyosung Co., R&D Center\*\*

### ABSTRACT

본 논문은 배터리 시계열 데이터를 기반으로 실시간 SOC 보정 모델을 통해 확보된 SOC 정보를 아레니우스 방정식 기반으로 설계한 열화 모델에 업데이트하고, 도출된 용량 정보를 SOC 보정 모델에 피드백을 수행하여 용량 예측을 위한 최적 열화 모델을 구현하였다. 해당 데이터를 통해 최적 열화 모델을 구현하고, 최대 오차 약 1.2%를 달성하여 모델의 검증을 수행하였다.

### 1. 서 론

탄소중립화 정책에 따라 온실가스, 오염물질 등을 배출하는 내연기관 자동차의 환경적 문제에 대한 대안으로 전기 자동차(Electric vehicles; EV) 및 에너지 저장 시스템(Energy storage system; ESS)과 같은 배터리를 동력원으로 사용하는 시스템이 점차 증가하고 있다. 지속적으로 배터리 어플리케이션 사용에 따라 내부 화학적 부반응에 의한 비가역적인 용량 감소 및 내부 저항 증가 등 성능 감소가 발생하게 된다. 따라서 배터리 어플리케이션 환경 및 운용 조건에 따라 배터리의 상태 추정 필요성이 대두되고 있다<sup>[1]</sup>. 특히, 배터리의 현재 충전 상태(State-of-Charge; SOC) 및 건강 상태(State-of-health; SOH)를 정확하게 추정하는 것이 필수적이다<sup>[2]</sup>. 이는 SOC에 따라 어플리케이션의 과도 충전 또는 방전 상태를 예방할 수 있어 오래 사용할 수 있으며 배터리 잔여 용량에 따라 어플리케이션 유지 보수 및 교체 시기를 판단할 수 있어 비용 측면에서도 이점이 존재하게 된다. 하지만 기존 열화 예측 모델의 경우 용량을 예측하는 SOC 부분이 전류적산법을 통해 업데이트되며, 이때 전류적산법 수식의 용량은 초기 용량으로 계산되어 열화에 따른 SOC 변화 반영에 한계가 존재한다. 따라서 본 연구에서는 배터리의 실시간 상태 추정 및 성능 개선을 위해 배터리 전기적 모델링 및 상태 추정 알고리즘을 결합한 기법을 제안한다. 배터리의 실시간 상태 추정을 위해 재귀최소자승법(Recursive least square; RLS) 및 확장 칼만 필터(Extended Kalman filter; EKF) 알고리즘을 활용하여 배터리의 단자 전압 및 SOC를 추정한다. RLS 알고리즘은 시간에 따라 변화하는 배터리의 특성을 고려하여 단자 전압을 추정하고, EKF 알고리즘은 비선형적인 배터리 특성을 고려하여 SOC를 추정하여 열화에 따른 SOC를 업데이트 할 수 있다. 배터리의 열화 예측을 수행하기 위해 아레니우스 방정식을 기

반으로 열화 모델을 설계하였다. 앞서 설계한 RLS 및 EKF 알고리즘을 열화 모델에 적용하여 용량 예측에 대한 정확도를 확보하고자 본 연구를 진행하였다. SOC 및 용량을 실시간 업데이트함으로써 기존 열화 모델에 비해 열화를 정확하게 예측할 수 있으며, 실제 학습 데이터에 따른 열화 예측 결과 최대 오차 1.5%의 높은 예측 성능을 보임을 확인하였다.

### 2. 배터리 실시간 SOC 추정 알고리즘 구현

#### 2.1 배터리 열화 및 전기적 특성 실험

본 장에서는 최적 열화 모델 설계를 위한 배터리 열화 및 전기적 특성 분석을 위한 데이터 확보를 위해 그림 1-(b)와 같이 CC-CV 기반의 완전 충전, CC 기반의 완전 방전을 반복하여 배터리 열화 시험을 수행한다. 또한 그림 1-(c)와 같이 100사이클 간격으로 내부 저항 등의 전기적 특성 측, 무부하 전압(Open circuit voltage; OCV) 및 전기적 등가회로 모델(Electrical circuit model; ECM) 파라미터를 추출하기 위해 SOC 5% 간격으로 방전 및 휴지 구간에 따른 전압 응답 특성을 통한 특성 파라미터를 확보한다. 실험에 사용된 셀은 LFP 기반의 각형 셀이며, 정격 용량은 100Ah이다. 실험 수행 중 온도 안정화를 위해 항온항습챔버를 통해서 일정한 상온 조건 25℃를 유지하였고, 692사이클 열화 시험을 수행하였다.

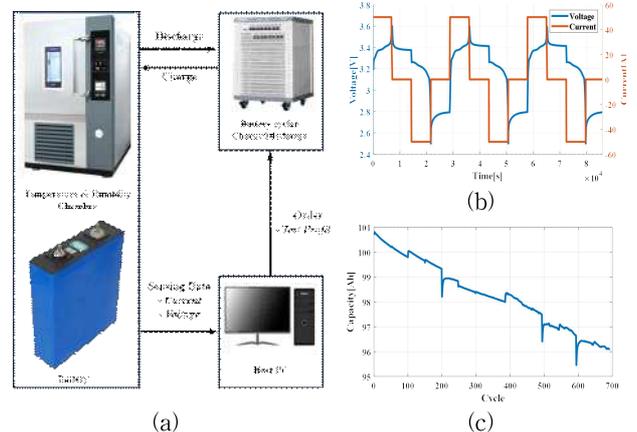


그림 1 (a) 배터리 열화 및 특성 실험 구성도, (b) 열화 시험 프로파일, (c) 사이클별 측정 용량

Fig. 1 (a) Experiment setup for electrical characteristics test, (b) Aging test profile (c) Discharge capacity

## 2.2 RLS 알고리즘 기반 배터리 단자 전압 추정

본 논문에서는 최적 열화모델 설계를 위해 내부 로직에 적용되는 SOC 정보를 실시간으로 추정하기 위해 재귀최소자승법(Recursive least square; RLS) 및 확장칼만필터(Extended Kalman filter; EKF) 알고리즘을 활용하여 추정 성능을 확보하였다.

$$\epsilon_k = V_{q,k} - \phi_k \theta_{k-1}^T \quad (1)$$

$$K_k = \frac{P_{k-1} \phi_k}{\lambda + \phi_k^T P_{k-1} \phi_k} \quad (2)$$

$$P_k = \frac{(1 - K_k \phi_k^T) P_{k-1}}{\lambda} \quad (3)$$

$$\theta_k^T = \theta_{k-1}^T + K_k \epsilon_k \quad (4)$$

RLS 알고리즘 기반 모델 파라미터를 업데이트 하기 위해 가중치 및 오차공분산을 계산하는 과정을 식 (1)-(4)에 나타내었다. 식 (1)에서 실제 전압과 추정 전압의 오차를 계산하게 되고, 해당 오차값을 기반으로 식 (2)와 식 (3)을 통해 게인값  $K$ 와 오차공분산인  $P$  값을 계산하여 최종적으로 실시간으로 도출된 가중치를 식 (4)을 통해서 파라미터 상태 업데이트를 수행하게 된다. 해당 알고리즘을 통해 본 논문에서는 1RC 기반의 전기적 등가회로 모델 파라미터 정보를 RLS 알고리즘을 통해 실시간으로 업데이트하여 SOC 추정 시 EKF 알고리즘 내부 로직에 반영하였다.

## 2.2 EKF 알고리즘 기반 배터리 SOC 추정

열화 모델 구현을 위해 실시간 SOC 정보를 EKF 알고리즘을 통해 확보하였다. 확장 칼만 필터는 기존 칼만 필터와 비슷하지만, 비선형 시스템의 선형화를 위해 편미분 기법을 사용한다. 이는 비선형 시스템의 상태를 근사하여 추정하기 위함이다. 따라서 본 연구에서는 배터리의 비선형적인 특성을 선형화하여 실시간으로 변화하는 SOC를 추정한다.

$$\hat{x}_k^- = A \hat{x}_{k-1} \quad (5)$$

$$P_k^- = A P_{k-1} A^T + Q \quad (6)$$

$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + R_k)^{-1} \quad (7)$$

$$\hat{x}_k^+ = \hat{x}_k^- + K(y_k - \hat{y}_k) \quad (8)$$

$$P_k = (I - K C_k) P_k^- \quad (9)$$

위의 식 (5)와 (6)을 통해 추정값과 오차공분산을 예측하고, 예측된 오차공분산과 측정 방정식, 측정 노이즈를 반영하여 식 (7)에서 칼만 이득이 계산된다. 해당 값을 기반으로 식 (8)을 통해 시스템 상태가 보정되어 최종적인 SOC 상태를 추정한다. 다음 상태에 대한 업데이트를 위해 식 (9)에서 오차공분산을 계산한다. 앞서 설계한 RLS 알고리즘에서 확보된 실시간 파라미터 정보를 기반으로 EKF 알고리즘을 통해 실시간 SOC 추정 정확도를 검증하였다. 정확도 판단의 경우 전류적산법 기반의 SOC 값과의 오차 정도를 통해 판단하였으며, 시뮬레이션 결과 최대 약 1.2% 이내의 높은 정확도를 검증하였다.

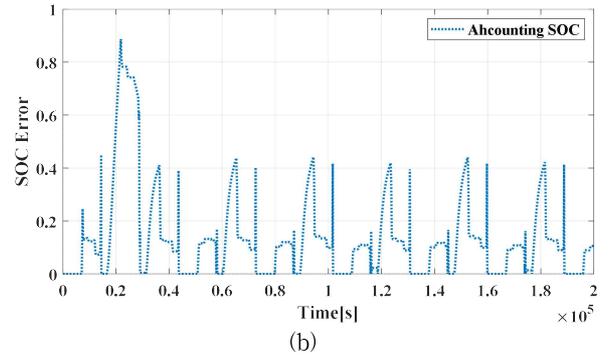
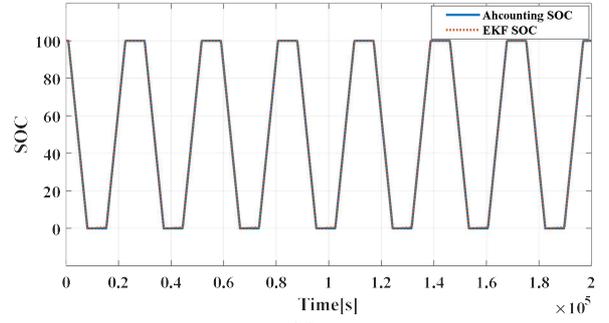


그림 2 (a) RLS 및 EKF 기반 SOC 추정 결과, (b) SOC 추정 오차  
Fig. 2 (a) SOC estimation result based on RLS and EKF algorithm, (b) SOC estimation error

## 3. 실시간 SOC 추정 모델 및 열화 모델을 결합한 최적 열화 모델 설계

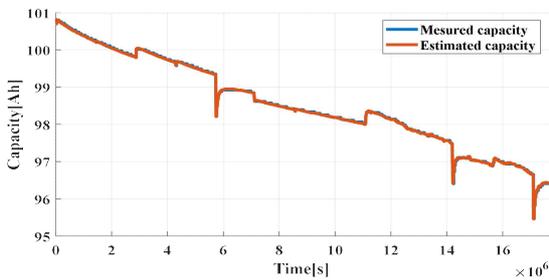
### 3.1 아레니우스 방정식 기반 열화 모델 설계

리튬이온 배터리의 열화 메커니즘은 다양한 요인들이 존재하게 된다. 배터리 운용 중 발생하는 산화/환원 반응에 의해 Solid electrolyte interface (SEI)층이 형성되며, 이에 따라 리튬이온 및 활물질 손실이 발생하여 용량이 감소하게 된다. 또한 SOC, C-rate뿐만 아니라 온도에 따라 발생하는 내부 화학적 부반응 및 SEI 층 형성에 의해서도 용량 감소에 대한 영향성이 존재하게 된다. 따라서 본 논문에서는 Arrhenius 방정식을 기반으로 온도 및 SOC, C-rate에 의한 영향성을 반영하여 열화 모델을 설계한다.

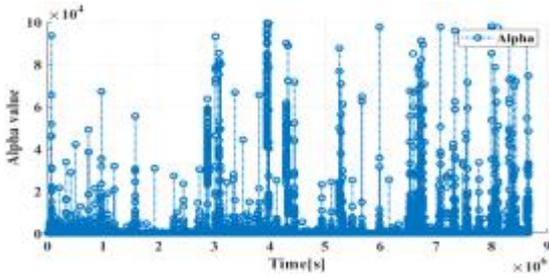
$$Q_{cyc} = (\alpha SOC + \beta) \exp\left(\frac{-E_a + \eta C_{rate}}{R_{gas} T_k}\right) A h_k^z \quad (10)$$

$$Q_{cyc,k+1} - Q_{cyc,k} = \Delta A h^* z (\alpha SOC + \beta) \exp\left(\frac{-E_a + \eta C_{rate}}{R_{gas} T_k}\right) A h_k^{z-1} \quad (11)$$

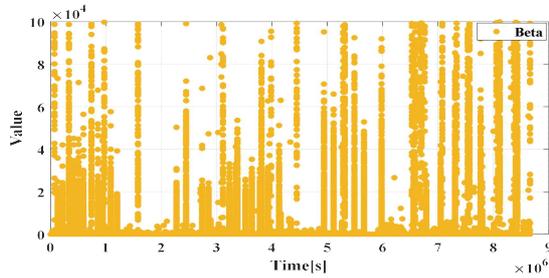
위의 식에서  $Q_{cyc}$ 의 경우 사이클별 용량값에 해당하며,  $E_a$ 는 활성화 기체 에너지,  $\eta$ 는 C-rate에 의한 보상 계수,  $R_{gas}$ 는 기체 상수 8.314[J/mol]를 나타내고,  $T_k$ 는 절대 온도이다. 설정된 계수값을 기반으로 식 (13)에서 실시간으로 업데이트되는 SOC 정보를 통해 용량값이 산출되며, 식 (14)는 이산식으로 변환한 수식이다. 따라서  $k+1$  시점에서의 용량값과  $k$  시점에서의 용량값의 차이를 바탕으로 열화 모델 내부 하이퍼 파라미터인  $\alpha$ ,  $\beta$  값을 선정한다.



(a)



(b)



(c)

그림 3 (a) 열화 모델 기반 용량 예측 결과, (b) 파라미터  $\alpha$  값 도출 결과, (c) 파라미터  $\beta$  값 도출 결과  
 Fig. 3 (a) Capacity prediction result based on deterioration model, (b) Extraction result of alpha parameter (c) Extraction result of beta parameter

### 3.2 SOC 및 용량 보정을 통한 최적 열화 모델 설계

사전 설계한 SOC 추정 모델과 열화 모델을 융합하여 최적 열화 모델을 설계하였다. RLS와 EKF 알고리즘을 결합해 실시간 SOC 정보를 도출하여 기존 열화 모델의 SOC 추정부에 업데이트하는 방식으로 모델을 설계하였다. 또한 열화 모델에서 추출된 용량 정보는 ECM 내부 로직에 업데이트되어 열화에 따른 용량 변화를 반영해 SOC 추정 정확도를 개선한다.

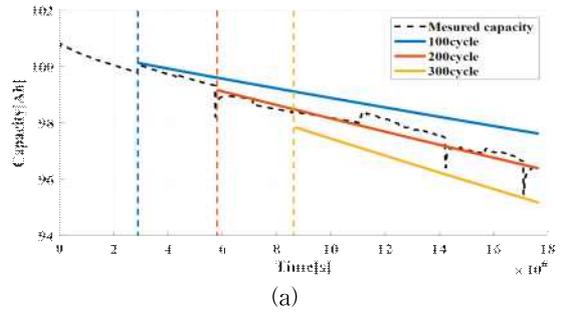
표 1 설정한 학습 데이터별 도출된  $\alpha, \beta$  값  
 Table 1 Pearson correlation coefficient for each specific discharge section according to the cycle

Item	100cycle	200cycle	300cycle
Mean $\alpha$	3.8003	6.6571	6.9375
Mean $\beta$	14.2473	19.2909	25.5493

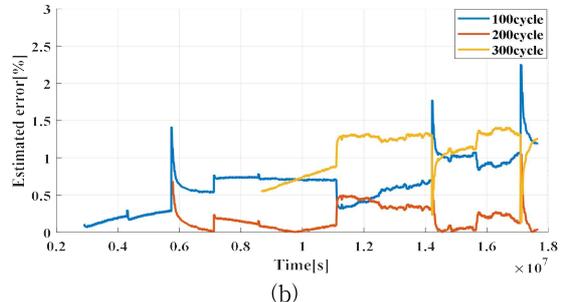
열화 모델 파라미터를 도출하기 위해 학습 데이터를 100, 200, 300 cycle로 구성하여, 열화 모델 식 (10)을 기반으로 용량 추정을 진행하였다. 추정 용량과 실제 용량 사이의 오차를 최소화하는 파라미터가 산출되었으며 이를 그림 3에 나타내었다. 최적 열화 모델 설계 시 산출된 파라미터의 평균값을 사용하였으며, 표 1에 나타내었다.

### 3.3 최적 열화 모델 기반 열화 예측 성능 검증

학습 데이터별 산출된 파라미터값을 열화 모델에 적용하여 그림 4-(a)와 같이 시뮬레이션을 통해 용량 예측 성능을 확인하였다. 100/200/300 cycle 학습 데이터별 모두 높은 예측 성능을 보였으며, 그 중 200 cycle 학습 시 최대 오차 약 1.2%로 높은 예측 성능이 나타남을 확인하였다. 결론적으로, 최적의 학습 데이터가 있을 경우 높은 예측 성능이 나타났으며, 본 연구에서 제안한 최적 열화 모델 성능을 검증하였다.



(a)



(b)

그림 4 (a) 최적 열화 모델 기반 학습 데이터별 용량 예측 결과, (b) 학습 데이터별 용량 예측 오차  
 Fig. 4 (a) Capacity prediction result of training data based on optimal deterioration model, (b) Capacity prediction error of training data

## 4. 결 론

본 연구에서는 기존 열화 모델에 실시간 SOC 및 용량 보정 알고리즘을 추가하여 최적 열화 예측 모델을 설계하였다. 최적 열화 모델을 기반으로 학습 데이터별 용량 예측을 진행하였으며, 이에 대한 결과로 최대 용량 예측 오차 약 2.5% 이내에 도달하여 최적 열화 모델 성능을 확보하였다. 향후 연구로는, 수명 임계점까지의 데이터를 확보하여 잔여 수명 예측에 대한 연구를 진행할 예정이다.

본 논문은 한국전력연구원(P23X005-03, ESS향 물리모델-AI 결합 클라우드 기반 BMS 요소기술 개발)과 효성중공업의 지원((2023-1331-01) 시스템 단위 LFP 배터리 수명 예측 알고리즘 개발)을 받아 수행되었음.

### 참 고 문 헌

- [1] Zou, Yuan, et al. "Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan for electric vehicles." *Journal of Power Sources* 273 (2015): 793-803.
- [2] Hossain, Monowar, M. E. Haque, and Mohammad Taufiqul Arif. "Kalman filtering techniques for the online model parameters and state of charge estimation of the Li-ion batteries: A comparative analysis." *Journal of Energy Storage* 51 (2022): 104174.