

리튬이온 배터리 전기적 및 전기화학적 특성 반영을 위한 가중치 기반 융합 모델 설계 및 융합 모델 기반 SOC 추정에 따른 안전성 진단

김민혁*, 이미영*, 안종찬*, 양가람*, 김종훈*
충남대학교 에너지저장변환연구실*

Designing a weight-based fusion model to reflect the electrical and electrochemical characteristics of lithium-ion batteries and diagnosing safety based on the fusion model-based SOC estimation

Minhyeok Kim*, Miyeong Lee*, Jongchan An*, Garam Yang*, Jonghoon Kim*
Energy Storage Conversion Lab., Chungnam National University*

ABSTRACT

본 논문은 가중치 기반 융합 모델을 통해 전기적 및 전기화학적 특성을 반영한 최적 전압 모델 설계를 설계하고 이를 기반으로 무향 확장 칼만필터 UKF(Unscented Kalman Filter; UKF)를 통한 배터리 안전성 진단 방법을 제안한다. 제안하는 알고리즘은 NMC(Nickel-manganese-cobalt) 배터리 스웰링 현상이 발생한 열화 데이터를 사용하였다. 또한 DC(Direct Current), AC(Alternating Current), OCV(Open circuit voltage) 모델을 융합하여 최적의 단자전압 도출 값을 선정하기 위한 가중치 기반 융합 모델을 설계하였다. 이를 기반으로 SOC 추정 오차(잔차)에 따른 배터리 안전성 진단을 하기 위해 UKF 모델을 추가하여 스웰링 현상이 발생한 열화 프로파일 기반 충전 상태 추정을 진행하였다. 제안한 방법의 검증 결과로써 배터리 스웰링 현상 시점 이후부터 지정한 고장 판단 기준인 임계값을 초과하는 것을 확인하였다.

1. 서 론

배터리 관리 시스템(Battery Management System; BMS)은 핵심 구성 요소로, 전기 자동차의 종합 성능에 상당한 영향을 미치는 안전성과 신뢰성을 직접적으로 영향을 준다. 현재 리튬이온 배터리는 높은 전력 밀도, 고에너지 밀도, 낮은 자체 방전률 등 우수한 성능으로 인해 전기 자동차의 전원 공급 장치로서 최우선 선택지이다. 그러나 최근 몇 년간 국내외적으로 전기자동차(Electric vehicle; EV)의 화재사고가 보고되고 있다. 전기자동차의 화재의 원인은 충전, 외부 충돌, 고온과 같은 환경에 장기간 노출 등을 지목하고 있다. 이로 인해 화재 및 폭발 사고가 발생하기 전 배터리의 특성을 반영하고 화재를 대비하기 위해 안전성 진단 방안이 필요하다. 배터리의 특성을 진단하는 방안에는 DC(Direct Current) 기반의 전기적 등가회로 모델과 AC(Alternating Current) 기반의 전기 화학적 등가회로 모델이 있다. 전기적 등가회로 모델은 전압, 전류, 온도 등 전기적 요소를 사용하여 배터리의 출력 특성과 용량을 모델링한다. 이 모델은 배터리 관리 시스템에 널리 사용되지만, 내부 화학적 변화를 반영하지 못해 배터리 화재의 위험성 예측에는 한계가 있다. 이에 비해, AC 기반의 전기화학적 등가회로 모델은 전해질과 전극 간 화학 반응을 포함하여 배터리의 전기화학적 특성을 더 정밀하게 파악한다. 이 모델은 배터리 성능과 안전성 평가에 필수적이며,

초기 경고 시스템 개발에도 중요한 역할을 한다. 전기화학적 모델은 미세한 배터리 변화까지 감지할 수 있어, 위험 감지 및 안전 조치를 증진시킬 수 있다. 따라서 본 논문에서는 전기적 및 전기화학적 특성을 모두 고려하기 위해 이 두가지 모델을 융합하여 전기적 및 전기화학적 특성을 고려한 배터리 모델을 설계한다. 이에 대한 모델의 성능은 실제 측정 전압을 비교 지표로 하여 기존 DC 및 AC 모델과 융합 모델을 통해 도출된 단자전압 값의 오차로 비교 검증한다. 또한, 융합 모델을 기반으로 도출된 단자전압을 통해 SOC(State-of-charge; SOC) 추정 알고리즘에 적용시켜 배터리 안전성 진단을 한다. 안전성 진단의 경우 모델 기반으로 진행된다. 모델 기반 안전성 방법은 배터리의 수학적 모델링을 사용하여 결함에 대한 매개 변수를 얻는다. 일반적으로 이는 오차(잔차) 신호로 나타나며, 이는 고장 임계값과 비교되어 시스템의 고장 여부를 결정한다. 모델 기반 방법은 오차(잔차) 생성 및 오차(잔차) 평가라는 두 단계로 구성되며, 오차(잔차) 생성에는 상태 추정 방법, 매개 변수 추정 방법 및 패리티 공간 방법 등 세 가지 방법이 있다^[1]. 본 논문에서는 상태 추정 방법을 채택하여 오차(잔차)를 생성한다. 이에 따라 배터리 내부 상태 중 SOC 추정 알고리즘인 UKF(Unscented Kalman Filter)를 통해 결함 특정 매개변수인 SOC 오차(잔차)를 추출한다. 이를 측정 값과 비교하여 오차(잔차)를 생성하여 시스템이 고장인지 여부를 판단한다. 안전 여부를 판단하는 기준인 임계 값은 경험적으로 판단하였다. 임계값을 통한 안전 여부를 검증은 열화로 인해 스웰링 현상이 발생한 배터리 데이터를 통해 검증하였다. 스웰링 현상이란 배터리 셀이 내부에서 부피가 커지는 현상을 나타내며, 이는 배터리 과열이나 과충전과 같은 부적절한 사용 조건으로 인해 배터리 내부 화학 반응의 불안정으로 인해 발생한다. 이에 따라 배터리의 성능과 안전에 부정적인 영향을 미칠 수 있으며, 심각한 경우 배터리의 손상 또는 고장을 유발한다. 따라서 스웰링 현상이 발생한 배터리를 고장 셀로 판단하여 이 데이터를 통해 고장 여부를 검증하였다^[2].

2. 융합 모델 기반 배터리 안전성 진단

2.1 배터리 전기적 및 전기화학적 특성 실험

본 논문에서 사용한 배터리는 Nickel-manganese-cobalt(NMC) 계열이며 용량이 56Ah인 파우치 배터리로 상온(25℃)에서 진행하였다. 정전압-정전류(Constant Current-Constant Voltage; CC-CV) 충전과 정전류(Constant Current; CC) 방전이 반복되는 열화 실험을 진행하였으며, 전류 크기의

경우 정격 용량 56Ah 셀 기준 0.3C-rate로 진행하였다. 또한, Nyquist plot으로부터 전기 화학적 등가회로 모델의 파라미터로 적용될 값들을 도출하기 위해 SOC 5% 구간별 휴지시간에 따른 EIS(Electrochemical Impedance Spectroscopy)를 측정하였다. EIS의 경우 10kHz~10mHz 주파수 범위에서 측정하였다.

2.2 가중치 기반 융합 모델 알고리즘

OCV, Randles, Thevenin 모델을 융합하여 배터리 안정성 진단에 적용될 단자전압을 추정하였다. 이 융합 모델은 각 모델에 가중치를 할당하는 확률론적 수식을 사용하여 최종적으로 추정된 단자 전압을 도출한다. 이러한 확률 기반 가중치 알고리즘은 비정상적인 오차(센서 측정 오류, 배터리 모델 오류 등)나 BMS의 전압 센서 노이즈를 효과적으로 줄이는 데 사용된다. 식 (1)은 각 모델의 오차를 나타낸다. 여기서 $V_t(k)$ 는 k 시간에 측정된 전압, $\hat{V}_{t,n}(k)$ 는 k 시간에 추정된 n 번째 모델의 전압, $res_n(k)$ 는 k 시간에 n 번째 모델의 오차를 의미한다. 이때 n 번째 모델은 OCV, Randles, Thevenin 모델을 의미한다.

$$res_n(k) = V_t(k) - \hat{V}_{t,n}(k) \quad (1)$$

$$f(V_t(k)|P_n) = \frac{1}{(2\pi)^{q/2} Var_n^{1/2}} \times \exp(-res_n^T(k) Var_n^{-1}(k) res_n(k) / 2) \quad (2)$$

식 (2)는 확률 밀도 함수를 정의한다. 여기서 Var_n 은 각 모델의 분산을 의미하며, 이는 식 (1)의 오차로부터 파생된 것이다. 이러한 분산은 오차 공분산 행렬의 대각 성분에서 추출된다. q 는 사전 확률을 나타내며, 모든 모델의 사전 확률이 동등하다는 가정하에 모델의 수에 따라 결정된다. 식 (3)은 각 모델의 오차, 확률 밀도 함수, 사전 확률 및 오차 공분산을 고려하여 사후 확률을 계산하는 과정이다. 식 (4)는 식 (3)에서 계산된 사후 확률을 이전 시간으로 지연시키는 과정이다. 마지막으로, 식 (5)를 통해 각 모델의 가중치를 계산한다. 식 (6)은 OCV, Randles, Thevenin 모델 각각의 전압 추정 정보를 이용하여 새로운 단자 전압 추정 값을 도출하는데 사용된다. 이 식에서 가중치 (w)의 합은 1이다. 각 모델의 가중치를 선택하여, 3가지 모델 중 가중치가 가장 큰 모델이 나머지 두 모델의 가중치의 합보다 크면 가장 큰 가중치를 가지는 모델의 추정 전압을 사용하게 된다. 그렇지 않다면 각 3가지 모델에서 도출된 가중치를 각 모델을 통해 도출된 단자전압에 각각 곱한 후 이 3가지 모델의 단자전압 값을 합한 전압을 사용하게 되어 최종적으로 융합모델을 통해 추정된 단자전압이 도출된다.

$$P_r(P_n | V_t(k)) = \frac{f(V_t(k)|P_n)P_r(P_n)}{\sum_{n=1}^N f(V_t(k)|P_n)P_r(P_n)} \quad (3)$$

$$P_r(P_n | V_t(k-1)) = \frac{P_r(P_n | V_t(k))P_r(P_n)}{P_r(P_n | V_t(k-1))} \quad (4)$$

$$\omega_i = P_r(P_n | V_t(k)) = \frac{f(V_t(k)|P_n)P_r(P_n | V_t(k-1))}{\sum_{n=1}^N f(V_t(k)|P_n)P_r(P_n | V_t(k-1))} \quad (5)$$

$$V_{fused} = \omega_{Randles} z_{Randles} + \omega_{Thevenin} z_{Thevenin} + \omega_{OCV} z_{OCV} \quad (6)$$

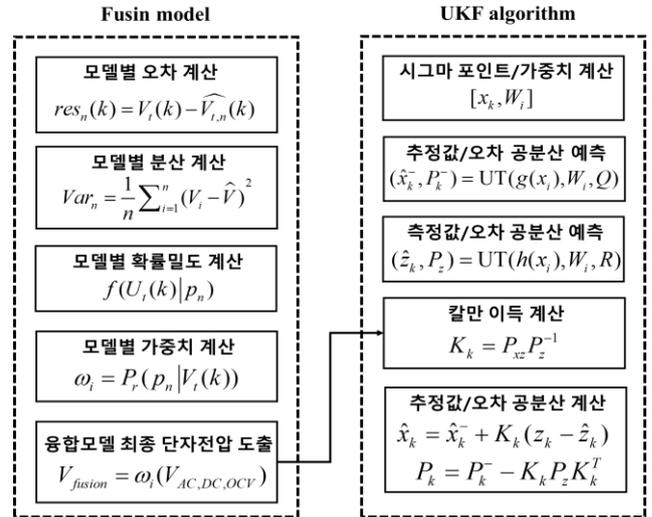


그림 1 가중치 기반 융합 모델+UKF 알고리즘 흐름도

Fig. 1 Flowchart of Weight-Based Fusion Model + UKF Algorithm

최종적으로 식 (6)에서 도출되는 가중치 기반 융합 모델의 단자전압은 배터리 안전성 진단을 위한 UKF 알고리즘의 칼만이득 K_k 를 구하는데 사용된다. 이에 따른 가중치 기반 융합 모델+UKF 알고리즘 흐름은 그림 1에 나타내었다.

2.3 UKF 알고리즘

UKF는 비선형 시스템의 제어를 위한 필터로, Kalman filter (KF)의 한 종류이다. 비선형 시스템에서도 효과적으로 작동하며, 특히 EKF의 단점을 보완하기 위해 개발되었다. EKF는 비선형 시스템을 선형화하여 제어하는데, 이 과정에서 Jacobian matrix를 사용한다. 하지만 이러한 선형화는 어플리케이션에 따라 자명하지 않고, 구현이 어렵다는 단점이 있다. 또한, EKF는 시스템을 작은 간격으로 선형화하여 동작하기 때문에 실제 비선형 시스템의 특성을 잘 반영하지 못한다. UKF는 이러한 선형화 오차를 줄이기 위해 개발되었다. 가우시안 분포를 사용하여 확률 분포를 근사하며, 이를 통해 비선형 시스템에서도 효과적으로 작동한다. 따라서 UKF는 보다 정확한 추정을 제공하며, 비선형 시스템의 실제 동작을 더 잘 반영할 수 있다. 이에 따른 UKF 알고리즘 흐름은 다음과 같다.

UKF 알고리즘 흐름도

1단계: 시그마 포인트 및 가중치 계산 (x_k, W_i).

2단계: 추정값/오차 공분산 예측

$$(\hat{x}_k^-, P_k^-) = UT(g(x_i), W_i, Q)$$

Q 는 시스템 모델의 불확실성을 나타내는 노이즈 공분산이다. 추정된 값은 시스템 방정식인 $g(x)$ 와 UT 를 통해 예측한다.

3단계: 측정값/오차 공분산 예측

$$(\hat{z}_k, P_z) = UT(h(x_i), W_i, R)$$

R 은 불확실성을 나타내는 노이즈 공분산이다. 측정값은 측정 방정식인 $h(x)$ 와 UT 를 통해 예측한다.

4단계: 칼만 이득 계산

$$P_{xz} = \sum_{i=0}^{2n} W_i \{g(x_i) - \hat{x}_k^-\} \{h(x_i) - \hat{z}_k\}^T$$

$$K_k = P_{xz} P_z^{-1}$$

5단계: 추정값 계산

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

6단계: 오차 공분산 계산.

$$P_k = P_k^- - K_k P_z K_k^T$$

표 1 가중치 기반 융합모델을 통한 단자전압 추정 결과

Table. 1 Results of terminal voltage estimation based on weight-based fusion model.

Model	전압 평균 오차(V)	평균 오차율 (%)
AC	0.0315	0.8613
DC	0.0118	0.3314
OCV	0.0373	1.0190
Fusion	0.0114	0.3178

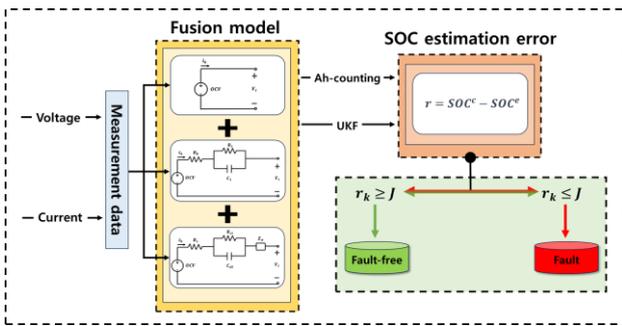


그림 2 배터리 안전성 진단 알고리즘 흐름도

Fig. 2 Battery Safety Diagnostic Algorithm Flowchart

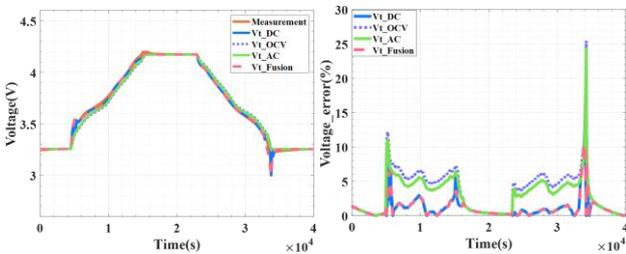


그림 3 가중치 기반 융합모델을 통한 단자전압 추정 결과

Fig. 3 Results of terminal voltage estimation based on weight-based fusion model.

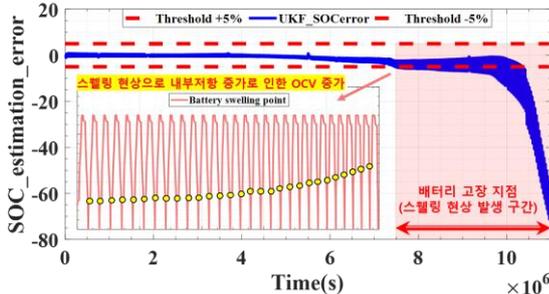


그림 4 융합 모델 + UKF 알고리즘 기반 배터리 안전성 진단 결과

Fig. 4 fusion model + UKF algorithm-based battery safety diagnosis result.

2.4 배터리 안전성 진단

위 UKF 알고리즘을 통해 결합 특성화 매개변수를 추출한다. 그런 다음 측정된 값과 비교하여 오차(잔차)를 생성하여 시스템에 결함이 있는지 확인한다. 이에 따른 안전성진단 알고리즘 흐름은 그림 2에 표시되어 있으며, 여기서 r 은 결합 특성화 매개변수로써 전류적산을 통해 도출한 SOC와 UKF 알고리즘을 통해 추정된 SOC의 차이이다. 또한, J 는 임계값으로 고장여부를 판단할 범위이다. 따라서 r 이 J 의 범위 외로 벗어날 경우 배터리를 고장으로 판단한다. 본 논문에서는 J 를 경험적으로 판단하여 $\pm 5\%$ 로 지정하였다^[3].

2.5 가중치 기반 융합 모델 및 안전성 진단 결과

모델 검증을 위해 정전압-정전류(CC-CV) 충전과 정전류(CC) 방전이 반복되는 열화 실험을 통해 200Cycle 이후부터 배터리 스웰링 현상이 발생한 데이터를 사용하였다. 그림 3은 가중치 기반 융합모델을 통한 단자전압 추정 결과를 나타낸 것이다. 그림 4는 UKF를 통해 추정된 고장 매개변수인 SOC 추정값과 전류적산기반 SOC값과의 오차(잔차)를 통해 지정한 임계값 범위 내에서의 배터리 안전성 진단 결과이다. 가중치 기반 융합모델을 통한 단자전압 추정 결과 AC 및 DC 모델을 통한 단자전압 추정결과 보다 우수한 것을 확인하였다. 이는 표 1에 각 모델의 오차 값을 정리하였다. 이에 따라 가중치 기반 융합모델의 단자전압값을 UKF 알고리즘에 적용시켜 배터리 안전성 진단을 한 결과 스웰링 시점 이후부터 SOC 추정 오차(잔차)가 급격히 증가하여 지정한 임계값($\pm 5\%$) 범위를 초과하는 것을 확인하였다.

3. 결론

본 논문에서는 전기적 및 전기화학적 특성을 모두 반영하기 위한 가중치 기반 융합 모델을 설계하였다. 또한, 안전성 진단을 위해 UKF 알고리즘을 통해 결합 특성 매개변수를 추출하였다. 결과적으로 가중치 기반 융합 모델을 통해 도출된 단자전압이 기존 DC 및 AC 모델 기반 단자전압 추정 결과보다 우수하였다. 또한, 안전성 진단의 경우 스웰링 현상이 발생한 데이터로 검증하였다. 그 결과 스웰링 시점 이후부터 결합 특성 매개변수인 SOC 오차(잔차)가 크게 발생하는 것을 확인하였다. 향후, 전기차 주행 데이터 및 서로 다른 온도 조건에 따른 배터리 안전성 진단을 검증한다.

본 논문은 현대자동차의 지원(LFP 배터리의 SOC 추정 BMS 알고리즘 개발)과 한국전력연구원(R23X005-03, ESS향 물리모델-AI 결합 클라우드 기반 BMS 요소기술 개발)의 지원을 받아 수행되었음.

참고 문헌

- [1] Xiong, Rui, et al. "Research progress, challenges and prospects of fault diagnosis on battery system of electric vehicles." Applied Energy 279 (2020): 115855.
- [2] Palacín, M. Rosa, and Anne de Guibert. "Why do batteries fail?." Science 351.6273 (2016): 1253292.
- [3] Xiong, Rui, et al. "A sensor fault diagnosis method for a lithium-ion battery pack in electric vehicles." IEEE Transactions on Power Electronics 34.10 (2019): 9709-9718.