

LFP 배터리 충전 상태 추정을 위한 MAFF-RLS 기반 동적 파라미터 최적화

이승현*, 강은진*, 송민우*, 김종훈*
충남대학교 에너지저장변환연구실*

Dynamic Parameter Optimization Based on MAFF-RLS for Estimating the State of Charge LFP Batteries

Seunghyun Lee*, Eunjin Kang*, Minwoo Song*, Jonghoon Kim*
Energy Storage Conversion Lab., Chungnam National University*

ABSTRACT

본 논문은 MAFF-RLS(Multiple adaptive forgetting factor-recursive least squares) 기반 최적 전압 모델 설계를 통해 충전 상태 추정 방법(State of Charge; SOC)을 제안한다. 제안하는 알고리즘은 LFP(Lithium-iron-phosphate) 배터리 데이터를 사용하였다. 테브난 전기적 등가회로 모델을 설계하기 위해 재귀 최소 자승법 기반 배터리 충전 상태에 따른 파라미터를 도출하였다. 동적 프로파일을 기반으로 배터리 충전 상태 추정을 진행하였다. 제안한 방법의 검증결과로써 배터리 충전 상태 오차를 2.04% 미만을 확인하였다.

1. 서론

현대사회에서는 환경 보호와 에너지 절약에 대한 중요성이 증대되면서, 전기자동차 및 이동식 전력 저장장치와 같은 어플리케이션 사용이 점차 증가하고 있는 추세이다. 리튬이온 배터리는 높은 에너지 밀도, 낮은 자가 방전율, 긴 수명 등의 특성을 가지고 있어 전기자동차, 에너지 저장 시스템(Energy storage system; ESS)과 같은 다양한 분야에서 사용되고 있다^[1].

배터리를 안전하고 효율적으로 운영하기 위해서는 배터리 충전 상태(State of Charge; SOC)를 정확하게 파악하는 것이 중요하다. EECM(Electric equivalent circuit model; EECM)을 통해 도출된 파라미터는 온도와 노화에 따른 비선형적인 변화로 인해 SOC 추정에 한계가 있다. 이를 극복하기 위해 입력 신호(전압, 전류)를 기반으로 파라미터 변화를 실시간 추정하는 RLS(Recursive least squares)를 사용한다. 그러나 RLS는 모든 파라미터에 동일한 망각 계수를 적용하여 각 파라미터에 적합한 가중치를 제공하지 못한다. 이러한 문제를 해결하기 위해 MAFF-RLS(Multiple adaptive forgetting factor-recursive least squares)를 사용하여 여러 개의 망각 계수를 도입해 각 파라미터에 실시간 동적으로 변화하는 가중치를 적용한다. 여러 망각 계수를 활용하여 파라미터에 다른 가중치를 할당함으로써, 시스템의 동적 변화에 민감하게 적응하여 정확한 상태 추정을 가능하게 한다. 따라서 본 논문에서는 MAFF-RLS를 활용한 LFP 배터리 충전 상태 추정 방법을 제안한다.

2. 배터리 충전 상태 추정

2.1 배터리 전기적 특성 실험

SOC 추정 고도화를 위해서 기준이 되는 OCV(Open circuit voltage)의 정확한 추출을 위해 미소 전류(Low current OCV; LO)를 사용하였다. 정격 용량 116.5Ah의 LFP 배터리 셀을

사용하였으며 전류 인가에 따른 내부 저항을 최소화하기 위해 0.05C-rate로 실험을 진행하였다. 초기 SOC별 파라미터 추출을 위해 1/3C-rate로 IO(Incremental OCV) 실험을 진행하였다. 그림 1은 LO 실험 프로파일과 SOC별 OCV 값을 나타내었다.

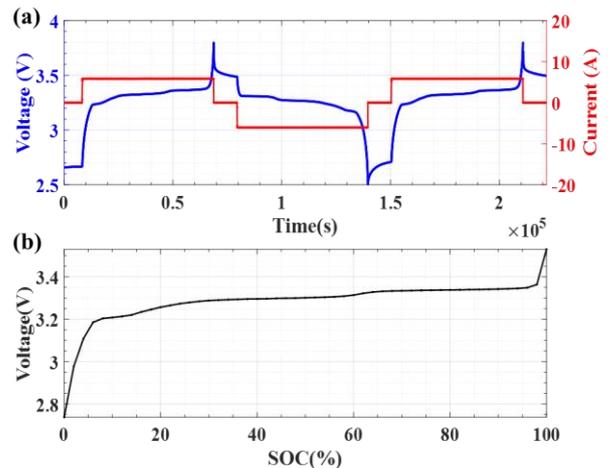


그림 1 (a) LO 실험 프로파일, (b) SOC-OCV 실험 결과
Fig. 1 (a) LO experiment profile, (b) SOC-OCV experiment result

2.2 배터리 전기적 등가회로 모델

배터리의 전압은 비선형적인 특성을 가지고 있으며, 이를 고려하여 SOC를 추정하는 것은 상당히 복잡하다. 따라서 비선형적인 전압 거동을 묘사하기 위해 EECM을 사용한다. EECM은 배터리의 단자 전압을 추정하는데 매우 중요하며, 주로 개방 회로 전압(OCV), 내부 저항, 테브난 모델로 구성된다. 본 논문에서는 그림 2와 같이 뛰어난 정확성을 가지고 있고 계산이 보다 간편한 1RC EECM 모델을 채택했다. 배터리의 단자 전압을 모델링하기 위해 식 (1), (2)와 같은 상태 방정식과 측정 방정식을 사용한다. 배터리 SOC 추정 성능을 보장하기 위해서는 보다 정확한 OCV값을 얻어야 하며^[2], LO 실험을 통해 취득한 결과를 이용해 LUT(Look-up table)을 구성했다.

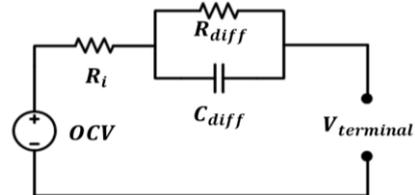


그림 2 테브난 전기적 등가회로 모델
Fig. 2 Thevenin electrical equivalent circuit model

$$\begin{bmatrix} SOC_k \\ V_{diff_k} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 - e^{-\frac{\Delta t}{R_{diff}C_{diff}}} \end{bmatrix} \begin{bmatrix} SOC_{k-1} \\ V_{diff_{k-1}} \end{bmatrix} + \begin{bmatrix} \frac{\Delta t}{Q_n} \\ \frac{\Delta t}{(1 - e^{-\frac{\Delta t}{R_{diff}C_{diff}}})R_1} \end{bmatrix} i_{k-1} \quad (1)$$

$$V_t = OCV(SOC_k) + i_k R_0 + V_{diff_k} \quad (2)$$

2.3 MAFF-RLS 기반 SOC 추정

각 파라미터의 망각 계수는 식 (3)과 같이 계산된다. ζ_i 는 감쇠 계수를 나타내며, 이는 표 1에 제시되어 있다. 이를 바탕으로 이득 값 $L_{i,k}$ 이 계산되고, $P_{i,k-1}$ 은 오차 공분산을 나타낸다. 각 파라미터의 이득 값은 식 (5)를 통해 행렬로 결합되며, 식 (6)을 통해 배터리 파라미터가 수정된다. 수정된 파라미터에 따라 오차 공분산은 식 (7)과 같이 조정되어 알고리즘이 오차를 줄이는 방향으로 작동한다.

$$\lambda_{i,k} = 1 - \left[1 + \zeta_i (\phi_{i,k}^T \cdot P_{i,k-1} \cdot \phi_{i,k})^{-1} \right]^{-1} \quad (3)$$

$$L_{i,k} = P_{i,k-1} \cdot \phi_{i,k} [\lambda_{i,k} + \phi_{i,k}^T \cdot P_{i,k-1} \cdot \phi_{i,k}]^{-1} \quad (4)$$

$$L_k = \begin{bmatrix} \lambda_{1,k}^{-1} & P_{1,k-1} & \phi_{1,k} \\ \lambda_{2,k}^{-1} & P_{2,k-1} & \phi_{2,k} \\ \lambda_{3,k}^{-1} & P_{3,k-1} & \phi_{3,k} \end{bmatrix} \left[1 + \sum_{i=1}^3 \lambda_{i,k}^{-1} \cdot P_{i,k-1} \cdot \phi_{i,k}^2 \right] \quad (5)$$

$$\theta_k = \theta_{k-1} + L_k (y_k - \phi_k^T \cdot \theta_{k-1}) \quad (6)$$

$$P_{i,k} = \lambda_{i,k}^{-1} (1 - L_{i,k} \cdot \phi_{i,k}^T) P_{i,k-1} \quad (7)$$

표 1 파라미터 추정에 사용되는 감쇠 계수

ζ_1	ζ_2	ζ_3
0.11	0.345	0.65

2.4 배터리 전압 및 SOC 추정 결과

모델 검증을 위해 도심주행시험(Urban dynamometer driving schedule; UDSS) 프로파일을 전체 전압 범위에서 시험을 진행한 데이터를 이용하였다. 그림 3은 RLS, MAFF-RLS 모델에 대해 전압 및 SOC 추정 결과 그래프를 나타내었고, 그림 4는 각 모델의 전압, SOC 오차를 나타내었다. 추정 성능을 비교한 결과로 MAFF-RLS를 적용한 모델의 SOC 추정의 최대 오차는 2.04%, 평균 오차는 0.41%로 가장 우수한 결과를 나타내었다. MAFF-RLS 모델은 RLS 대비 SOC 추정의 최대 오차는 5.49%, 평균 오차는 2.25% 감소하는 것을 확인하였다.

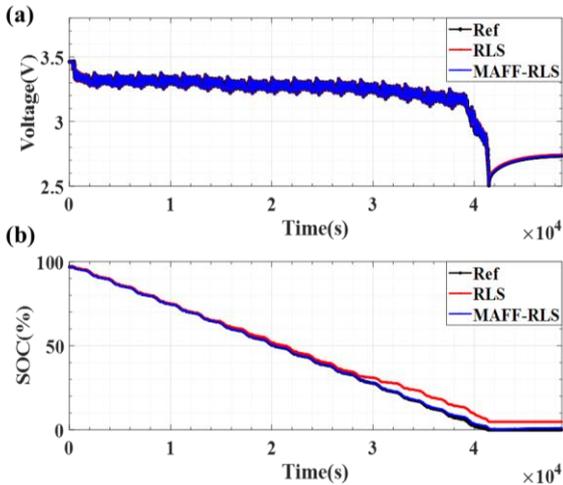


그림 3 (a) RLS, MAFF-RLS 모델의 전압 추정 결과, (b) SOC 추정 결과
Fig. 3 (a) Voltage estimation result, (b) SOC estimation result for RLS and MAFF-RLS models

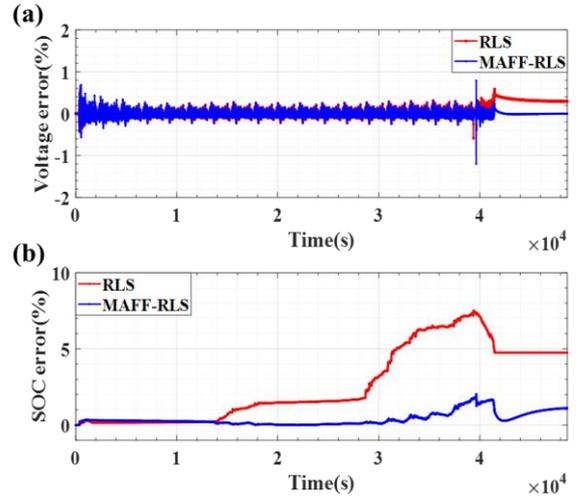


그림 4 (a) RLS, MAFF-RLS 모델의 전압 추정 오차, (b) SOC 추정 오차
Fig. 4 (a) Voltage estimation error, (b) SOC estimation error for RLS and MAFF-RLS Models

표 2 RLS, MAFF-RLS 모델의 전압 및 SOC 최대, 평균 오차 비교
Table. 2 Comparison of maximum and average errors in voltage and SOC for RLS and MAFF-RLS models

구분	최대(%)	평균(%)
RLS voltage error	0.59	0.08
RLS SOC error	7.53	2.66
MAFF-RLS voltage error	1.20	0.03
MAFF-RLS SOC error	2.04	0.41

3. 결론

본 논문에서 LFP 배터리의 충전 상태 추정을 위해 MAFF-RLS 기반 최적 전압 추정 모델 설계를 진행하였다. 동적 프로파일 기반 전체 전압 영역에서 검증을 진행하였을 때 MAFF-RLS 모델이 RLS 모델에 비해 배터리 충전 상태 추정 성능이 우수하였으며, 최대, 평균 오차는 2.04%, 0.41%이었다. 향후, 다양한 충전 상태 추정 모델과 제한한 모델의 추정 성능에 대한 비교를 진행한다.

본 논문은 한국에너지기술평가원(MMC타입 ESS 및 재생에너지 연계 고압형 허브스테이션 핵심기기 개발)과 정보통신기획평가원(대규모 분산 에너지 저장장치 인프라의 안전한 자율운영 및 성능 평가를 위한 지능형 SW 프레임 워크 개발)의 지원을 받아 수행되었음.

참고 문헌

- [1] Wen, Jianping, Dan Zhao, and Chuanwei Zhang. "An overview of electricity powered vehicles: Lithium-ion battery energy storage density and energy conversion efficiency." *Renewable Energy* 162 (2020): 1629-1648.
- [2] Tong, Shijie, Matthew P. Klein, and Jae Wan Park. "On-line optimization of battery open circuit voltage for improved state-of-charge and state-of-health estimation." *Journal of Power Sources* 293 (2015): 416-428.