

배터리 팩 내부 셀 불균형 특성 파라미터 분석 및 자기 회귀 모델 기반 과방전 사전 예측 알고리즘 연구

박진형*, 김건우*, 이미영*, 김민오**, 김종훈*
 충남대학교 에너지저장변환실험실*, 현대로템**

Battery pack internal cell imbalance characteristic parameter analysis and auto-regression model for prognosis of over discharging

Jinhyeong Park*, Gunwoo Kim*, Lee Miyoung*, Min-O Kim**, Jonghoon Kim*
 Chungnam National University*, Hyundai-rotem**

ABSTRACT

본 논문은 배터리 팩 내부 셀 파라미터의 불균일도에 대한 분석을 실시하고 이를 기반으로 과방전을 사전에 진단할 수 있는 방법을 제안한다. 이를 위해서 배터리 팩 내부 셀간 편차가 발생하는 셀을 선정하여 두 셀간 특성 분석을 실시하였으며, 이를 기준으로 예측 모델을 구성하였다. 예측 성능을 통해 배터리 전압 예측 성능에 영향을 미치는 인자를 분석하였으며, 배터리 전기적 등가회로 모델을 기반으로 예측 모델을 제안한다. 예측 모델은 실제 과방전이 발생한 셀을 기준으로 실험데이터와 비교하여 예측 성능을 검증하였다.

1. 서 론

최근 일방적인 전력을 소비하는 수동적인 입장에서 전력을 소비한다면, 신재생 에너지와 에너지 저장 장치 (energy storage system: ESS)와 연계하여 능동적으로 전력을 자체적으로 생산하여 Net zero를 실현시키는 방향으로 나아가고 있다^[1]. 하지만 최근 ESS의 화재와 같이 안전상에 문제가 발생하면서 배터리 시스템의 운영 환경 개선에 대한 수요가 증가하고 이를 위한 방지 및 진단 시스템이 요구된다. 하지만 종래의 대책의 경우 배터리의 충전량 (state of charge: SOC)을 옥내 설비의 경우 80%, 옥외설비의 경우 90%로 SOC를 제한하는 조치를 취하였다. 하지만 최근 ESS 화재 사고에서 방전 후 저전압 구간에서 큰 전압 편차를 보인 배터리 등에서 화재가 발생하는 현상이 발생하였다^[2]. 따라서 ESS의 화재 및 고장을 사전에 진단하기 위해서 배터리 팩 내부 셀의 전압 편차를 진단하는 방법론이 요구된다.

배터리 팩 내부 셀의 전압의 편차는 노화가 진행됨에 따라 편차가 증가하고 이는 배터리 팩의 충분한 에너지를 활용 못하는 현상이 발생하거나 안전 문제가 발생할 수 있다. 이러한 현상이 발생하는 원인으로는 배터리 팩 제작 초기 셀간 특성이 조금씩 다른 셀이 조합되어 초기에 편차가 발생할 수 있으며, 이러한 특성에 따라 배터리의 전압 변동률이 차이가 발생한다. 이러한 차이를 방지하기 위해서 기존의 기술은 현재 측정되는 전압을 기준으로 일정 차이가 나거나 상한/하한 전압을 넘지 못하도록 제어하였다. 하지만 배터리가 노화되거나 편차가 심화될수록 고장 셀의 전압의 변동률을 급격하게 커져 제어하는 것에 어려움이 있다. 따라서 본 논문에서는 과방전을 사전에 방지하기 위해서 다변수 자기 회귀 모델을 사용하여 배터리의 전압을 예측하는 방법은 제안한다. 이를 위해서 배터리 내부




그림1 배터리 전기적 특성 신호 기반 등가 회로 모델

Fig.1 Battery equivalent circuit model based on electrical signal

파라미터의 경향성 및 수치를 확인하기 위해서 실시간 파라미터 추정기를 통해 내부 특성을 분석하였다.

2. 실시간 파라미터 추정용 배터리 등가회로 모델

2.1 배터리 전기적 등가회로 모델

본 논문에서는 배터리의 고장 원인 분석을 전기적 입력 신호 (전압 및 전류)를 기반으로 해석하기 위해서 배터리 전기적 등가회로 모델을 사용하였다. 배터리 등가회로 모델은 그림 1과 같이 개방 회로 전압 (open circuit voltage: OCV), 직렬 저항 (R_0), 확산 저항 (R_1) 및 커패시턴스 (C_1)으로 구성된다. 입력 전류와 배터리 단자 전압 간의 전달 함수는 연속 시간 기준으로 식 (1)으로 정의할 수 있으며, Z 변환을 통해서 이산 시간 형태인 식 (2)와 같이 정의할 수 있다. 이를 기반으로 식 (3)과 같이 상태 방정식을 정의할 수 있으며, 식 (4)와 같이 θ_k 는 입력 파라미터 ϕ_k 배터리 내부 파라미터를 뜻한다. 내부 파라미터의 계수 값 (b_0, b_1 및 a_1)은 식 (5)를 통해 직렬 저항, 확산 저항 및 커패시턴스를 계산할 수 있다.

$$G(s) = \frac{U_{RRC}(s)}{I(s)} = R_0 + \frac{R_1}{1 + s \cdot R_1 \cdot C_1} \quad (1)$$

$$G(z) = \frac{b_0 + b_1 \cdot z^{-1}}{1 + a_1 \cdot z^{-1}} \quad (2)$$

$$y_k = I_k \cdot b_0 + I_{k-1} \cdot b_1 + a_1(OCV_{k-1} - y_{k-1}) + OCV_k = \theta_k^T \cdot \phi_k \quad (3)$$

$$\phi_k = [I_k; I_{k-1}; (OCV_{k-1} - y_{k-1}); 1;] \quad (4)$$

$$\theta_k = [b_{0,k}; b_{1,k}; a_{1,k}; OCV_k;] \quad (5)$$

$$R_0 = b_0, R_1 = \frac{b_1 - a_1 \cdot b_0}{1 + a_1}, C_1 = \frac{\Delta t}{b_1 - a_1 \cdot b_0}$$




그림2 일반 셀과 고장 셀간 단자 전압 편차 비교

Fig.2 Comparison of voltage deviation with normal and fault cell




그림3 실시간 파라미터 관측기 기반 일반 셀과 고장 셀의 OCV 특성 분석

Fig.3 Analysis of the OCV characteristics with normal and fault cells based on real-time parameter observer

2.2 실시간 배터리 내부 파라미터 추정 알고리즘

배터리의 내부 파라미터는 노화 정도, 배터리 내부 직/병렬 조합에 따라 가변적이며 이를 위해 입력 신호 (전압 및 전류)에 따라 변동성을 반영할 수 있는 방법론이 요구된다. 이를 위해 본 논문에서는 Multiple adaptive forgetting factor - recursive least square (MAFF-RLS) 알고리즘을 활용하였다^[3]. MAFF-RLS는 배터리의 4가지 파라미터 (OCV_k , R_0 , R_1 및 C)을 추정하는 알고리즘으로써 서로 다른 특성을 가지는 파라미터의 변동성을 반영하기 위해서 각 파라미터의 forgetting factor (λ_{ik})를 식 (6)과 같이 계산한다. 이 식에서 ζ 는 감쇠 계수를 뜻하며 각 파라미터 마다 상수값으로 정의한다. 이를 기반으로 계인 값 (L_{ik})을 식 (7)과 같이 계산하며 P_{ik} 는 오차 공분산을 뜻한다. 계산된 각 파라미터의 계인 값들은 식 (8)을 통해 하나의 행렬로 조합되고 식 (9)를 통해서 배터리의 파라미터들을 보정하게 된다. 보정된 파라미터에 따라 각 오차 공분산이 식 (10)과 같이 보정되어 오차를 줄여 나가는 방식으로 알고리즘이 구동되게 한다.

$$\lambda_{i,k} = 1 - [1 + \zeta_i (\phi_{i,k}^T \cdot P_{i,k-1} \cdot \phi_{i,k})]^{-1} \quad (6)$$

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

$$L_k = \begin{bmatrix} \lambda_{1,k}^{-1} \cdot P_{1,k-1} \cdot \phi_{1,k} \\ \lambda_{2,k}^{-1} \cdot P_{2,k-1} \cdot \phi_{2,k} \\ \lambda_{3,k}^{-1} \cdot P_{3,k-1} \cdot \phi_{3,k} \\ \lambda_{4,k}^{-1} \cdot P_{4,k-1} \cdot \phi_{4,k} \end{bmatrix} [1 + \sum_{i=1}^4 \lambda_{i,k}^{-1} \cdot P_{i,k-1} \cdot \phi_{i,k}^2] \quad (8)$$

$$\theta_k = \theta_{k-1} + L_k (y_k - \phi_k^T \cdot \theta_{k-1}) \quad (9)$$

$$P_{i,k} = \lambda_{i,k}^{-1} (1 - L_{i,k} \cdot \phi_{i,k}^T) P_{i,k-1} \quad (10)$$




그림4 실시간 파라미터 관측기 기반 일반 셀과 고장 셀의 내부 저항 분석

Fig.4 Analysis of the ohmic resistance characteristics with normal and fault cells based on real-time parameter observer




그림5 실시간 파라미터 관측기 기반 일반 셀과 고장 셀의 확산 저항 분석

Fig.5 Analysis of the diffusion resistance characteristics with normal and fault cells based on real-time parameter observer




그림6 일반 셀과 고장 셀의 배터리 전압-저항간 특성 분석 (저전압 구간)

Fig.6 Analysis of the ohmic resistance characteristics with normal and fault cells based on real-time parameter observer (low voltage region)

2.3 배터리 내부 파라미터 추정 결과

본 논문에서는 배터리 팩 내부 셀 간 파라미터 불균형을 검증하기 위해서 그림 2와 같은 충/방전 실험을 진행하였다. 실험은 11S2P (S: 직렬, P: 병렬)로 구성된 배터리 팩을 사용하였으며, 그 중에서 과/방전 현상을 나타내는 셀과 일반적인 셀은 선정하여 그림 2와 같이 구성하였다. 배터리 충/방전 실험상에서 배터리의 중지 전압은 셀 기준으로 3V로 설정하였으며, 셀 사양서 상에서 중지 전압은 2.5 V이다. 각




그림7 예측 모델에 따른 배터리 단자 전압 예측 결과

Fig.7 Prediction result of terminal voltage according to the prediction model

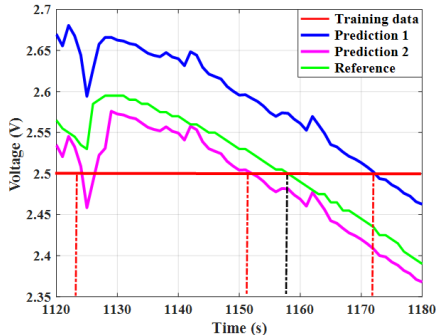


그림8 예측 모델에 따른 배터리 단자 전압 예측 결과 (저전압 구간)

Fig.8 Prediction result of terminal voltage according to the prediction model (low voltage region)

셀에 2.2장에서 소개한 MAFF-RLS 알고리즘을 적용하여 배터리의 내부 파라미터간 차이를 분석하였다.

그림 3은 배터리의 OCV를 고장 셀과 일반 셀을 비교한 그래프이다. OCV는 단자 전압과 마찬가지로 두 셀간 차이가 저전압 구간에서만 편차가 발생하였으며 충전 영역에서는 큰 차이가 나타나지 않는 것을 확인할 수 있다. 그림 4, 5는 배터리의 내부 저항과 확산 저항을 나타낸 그래프이다. 저항 값들은 배터리 전압 변동에 큰 영향을 미치는 요소이다. 특히 고장 셀의 경우 일반 셀보다 더 높은 값을 나타내고 있다. 그림 6은 프로파일의 종료 시점에 셀의 단자 전압, 내부 저항, 확산 저항을 확대하여 비교한 그래프이다. 두 셀의 단자 전압 차이의 경우 프로파일이 진행됨에 따라 증가하는 것을 확인할 수 있으며, 고장 셀의 경우 전압의 변화율이 더 커짐에 따라 종지 전압에 빠르게 도달하는 것을 확인할 수 있다. 이러한 현상의 발생 원인으로는 내부 저항과 확산 저항의 급격한 증가로 확인할 수 있다. 따라서 본 논문에서는 내부 파라미터의 증가하는 경향성을 통해 배터리의 전압을 예측 모델을 사용하여 사전에 진단하는 방법을 제안한다.

3. 배터리 팩 내부 셀 과방전 사전 예측 모델

3.1 배터리 등가 모델 기반 다변수 자기 회귀 모델

자기회귀모형은 과거 시점의 시계열이 현재 시점의 시계열에 영향을 주는 경우에 유용한 시계열 모형이다[4]. 이전 20초의 데이터를 바탕으로 다음 20초의 데이터를 예측하기 위해 이용하였다. 자기회귀모형에 부하와 연관성이 클 것으로 예상되는 OCV와 확산 전압 데이터를 결합한 다중회귀모형을 사용하였다. 이를 통해 부하를 예측하는 식은 (12)와 같다. 여기서 t 는 예측시간을 나타내고 t_n 는 예측 시간으로부터 이전

20초 데이터의 Index 값이며, p 는 사용된 이전 전압 값의 개수를 나타낸다.

$$V_{1,k+1} = \exp\left(-\frac{\Delta t}{\tau}\right) \cdot V_{1,k} + (1 - \exp\left(-\frac{\Delta t}{\tau}\right)) \cdot R_{1,k} i_k \quad (11)$$

$$V_{t,\tau} = \sum_{\tau=1}^p a_{\tau} V_{t,k-\tau} + bOCV_k + cV_{1,k} + R_0 i_k \quad (12)$$

3.2 실험 데이터 기반 시뮬레이션 및 검증

제안한 방법의 예측 결과는 그림 7에 도시하였다. 빨간색 선은 식 (12)의 계수값을 도출하기 위해 학습한 구간을 나타내며 파란색 선은 식 (12)에서 내부 저항의 요소를 제거한 예측 결과를 나타내고 보라색 선은 식 (12)를 통해 예측된 결과이다. 초록색 선은 실험데이터에서 측정된 전압을 사용하며 기준 값으로 활용하였다. 식 (13)을 통해서 평균 절대 에러 백분율 (mean absolute percentage error: MAPE)를 통해 예측 성능을 평가하였다. 여기서 n 은 샘플 개수를 나타내며 A_t 는 실제값 F_t 는 예측값을 나타낸다. 파란색 선을 나타내는 첫번째 예측 결과의 MAPE는 1.445%이며, 보라색 선의 두번째 예측 결과의 MAPE는 1.044%로 내부 저항으로 기인하는 전압의 강하를 반영하면 예측 결과의 성능이 약 0.4% 향상한다.

그림 8은 종지 전압 (2.5V) 지점을 예측하는 지점을 나타낸 그래프이다. 내부 저항을 무시한 모델의 예측 결과의 경우 실제 값보다 종지 전압을 약 10초 늦게 예측하여 사전 경보를 알리는 목적에 부합하지 않는 것을 확인할 수 있다. 하지만 내부 저항을 고려한 모델의 경우 실제 값보다 약 8초 이전에 종지 전압을 예측하는 것을 확인할 수 있다. 하지만 1123초 구간에서 순간 적인 전압 강하로 인해 2.5V에 도달하는 것을 확인할 수 있으며, 추후에 이러한 현상을 방지하기 위한 과방전에 대한 기준점을 새로 정립할 필요가 있다.

$$MAPE = \frac{100}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{A_t} (\%) \quad (13)$$

4. 결론

본 논문은 배터리 팩 내부 셀의 과방전을 방지하기 위해 사전에 전압을 예측하여 배터리 시스템의 안정성을 높이기 위한 배터리 내부 파라미터 추정 기반 다변수 자기 회귀 모델을 사용하여 전압을 예측하는 모델은 제안하였다. 시뮬레이션 예측 결과를 기준으로 배터리 과방전을 예측하기 위해서는 내부 저항 요소를 충분히 반영할수록 성능이 향상되었다. 이를 기반으로 추후 연구에서는 배터리 고장에 기인하는 특성 파라미터에 대한 추가적인 연구가 요구되며, 이를 기반으로 배터리의 과방전에 대한 정확한 기준을 정립할 필요가 있다. 또한, 저전압 구간이 아닌 고전압구간에서도 예측 모델에 대한 검증이 요구된다.

본 연구는 산업통상자원부(MOTIE)와 산업기술평가관리원(KEIT)의 지원을 받아 수행한 연구과제(No. 20011626) 및 현대 로템의 지원을 받아 수행한 연구 결과입니다.

참고 문헌

- [1] IEA. (2019). Understanding the world energy outlook scenarios.
- [2] 한국산업기술시험원, 2020. 02. 06, "ESS 화재사고 조사단, 5곳의 화재사고 조사 결과 발표"
- [3] V. H. Duong, H. A. Bastawrous, K. Lim, K. W. See, P. Zhang, and S. X. Dou, "Online state of charge and model parameters estimation of the LiFePO4 battery in electric vehicles using multiple adaptive forgetting factors recursive least-squares," J. Power Sources, 296, pp. 215-224, Nov. 2015.
- [4] Park, J, Lee, M, Kim, G, Park, S, and Kim, J. (2020). Integrated Approach Based on Dual Extended Kalman Filter and Multivariate Autoregressive Model for Predicting Battery Capacity Using Health Indicator and SOC/SOH. Energies, 13(9), 2138.