

# 배터리 팩 내부 과방전 사전 진단을 위한 모델기반 셀 간 불균형 특성 파라미터 분석 연구

박진형<sup>1</sup>, 김재원<sup>1</sup>, 이미영<sup>1</sup>, 김병철<sup>2</sup>, 정성철<sup>2</sup>, 김종훈<sup>†</sup>

## Model-based Analysis of Cell-to-Cell Imbalance Characteristic Parameters in the Battery Pack for Fault Diagnosis and Over-discharge Prognosis

Jinhyeong Park<sup>1</sup>, Jaewon Kim<sup>1</sup>, Miyoung Lee<sup>1</sup>, Byoung-Choul Kim<sup>2</sup>,  
Sung-Chul Jung<sup>2</sup>, and Jonghoon Kim<sup>†</sup>

### Abstract

Most diagnosis approaches rely on historical failure data that might not be feasible in real operating conditions because the battery voltage and internal parameters are nonlinear according to various operating conditions, such as cell-to-cell configuration and initial condition. To overcome this issue, the estimator and the predictor require integrated approaches that consider comprehensive data, with the degradation process and measured data taken into account. In this paper, vector autoregressive models (VAR) with various parameters that affect overdischarge to the cell in the battery pack were constructed, and the cell-to-cell parameters were identified using an adaptive model to analyze the influence of failure prognosis. The theoretical analysis is validated using experimental results in terms of the feasibility and advantages of fault prognosis.

**Key words:** Adaptive control algorithm, BMS (Battery Management System), EECM (Electrical Equivalent Circuit Model), Fault prognosis

### 1. 서 론

최근 온난화와 같은 전 세계적인 환경문제로 인해 현재의 에너지시스템은 신재생 에너지를 사용하여 탈탄소화를 빠르게 전환 추세이다<sup>[1]</sup>. 탈탄소화를 실현하기 위해서 신재생 에너지의 비중을 증가시켜야 한다. 하지만, 청정에너지인 풍력 및 태양광 발전의 경우 발전량이 환경 조건에 의해 불규칙적이기 때문에 안정적으로 전

력을 공급하도록 하는 에너지저장장치(Energy Storage System, ESS)의 중요성이 부각되고 있다<sup>[2-4]</sup>. 특히, 전력 시스템의 신뢰성 및 발전·부하의 탄력성을 제공하기 위해서, 전 세계 ESS의 설치량은 2018년 9GW/17GWh에서 2040년 1,095GW/2,850GWh로 기하급수적인 증가를 예상하였다<sup>[5]</sup>. 하지만, 최근 국내에 ESS의 화재가 2017년부터 3년여 동안 29건의 화재가 발생하는 등 안전상에 문제가 발생하면서 국내 ESS 시장이 침체기를 겪고 있다<sup>[6]</sup>. 특히, 국내 ESS 시장 규모는 2018년 5.6GWh에서 2019년 3.7GWh로 감소하였다. 같은 시기 글로벌 ESS 시장은 11GWh에서 16GWh로 성장한 것과 대조적이다. 따라서 미래 신성장 동력원인 ESS 산업의 반등을 위해서는 화재의 원인이 명확하게 규명 및 주요 화재 지점인 배터리에 관한 다각적인 연구가 요구된다.

1차 ESS 화재 조사위에서 발표한 내용에 따르면, 20건이 충전 후 휴지 중에서 화재가 발생하였으며, 3건이 충전 중에 발생하였다<sup>[7]</sup>. 또한, 2차 조사위에 조사한 5건의 화재 발생 사고에서는 저전압 및 전압 편차가 발생 하는 것이 확인되었으며, 이상 고온이 발생하는 공통적

Paper number: TKPE-2021-26-6-1

Print ISSN: 1229-2214 Online ISSN: 2288-6281

<sup>†</sup> Corresponding author: whdgn0422@cnu.ac.kr, Dept. of Electrical Engineering, Chungnam National University, Korea

Tel: +82-42-821-5657 Fax: +82-42-821-7606

<sup>1</sup> Dept. of Electrical Engineering, Chungnam National University, Korea

<sup>2</sup> Power Grid Integration Team Power & Industrial System R&D Center, Hyosung Corporation, Korea

Manuscript received Dec. 2, 2020; revised Dec. 30, 2020; accepted Jun. 18, 2021

— 본 논문은 2020년 전력전자학술대회 우수논문상 수상논문임

인 현상이 발생하였다<sup>[8]</sup>. 특히, 2차 조사위에서는 배터리 단락으로 추정되는 저 전압 현상을 주요 화재 원인으로 보았다. 이러한 현상이 발생하는 원인 중 하나로 과충전, 과방전과 같은 배터리 오용이 발생하기 때문이다. 배터리 오용은 배터리 팩 내부 셀 간 저항과 같은 편차로 인해 발생할 수 있다. 배터리 편차로 인한 과방전이 지속해서 발생하면 배터리 내부 리튬 플레이팅(Lithium plating)이 발생한다. 이 현상으로 인해 배터리 내부 단락과 같은 손상이 발생하고, 이에 따라 온도가 증가하면서 화재와 같은 안전상의 문제가 발생할 수 있다<sup>[9]</sup>. 따라서, 지속적인 배터리의 손상을 차단 및 진단하기 위한 배터리 모듈 내부 셀 간 전압 불균형 감지 및 이를 제어하기 위한 배터리 관리시스템(Battery Management System, BMS)를 통한 고장 진단 연구가 필요하다.

배터리 시스템의 운영 환경 개선에 대한 필요성이 대두되고 있음에 따라, BMS에서는 셀 간 전압 편차와 같은 위험 방지 및 진단 기능이 요구된다. ESS에서 배터리의 안전성을 향상하고 관리하기 위해서 BMS를 통해 추정되는 배터리의 정보를 기반으로 시스템의 운용영역을 설정하는 것이 중요하다<sup>[10],[11]</sup>. 특히, 배터리 관리시스템은 배터리의 안전 영역 및 최적 운용 구간 설정과 열관리를 위해서 배터리 충전량을 나타내는 SOC(State-of-charge)와 수명을 나타내는 SOH(State-of-health)와 같은 기준 지표가 사용된다<sup>[12],[13]</sup>. SOC와 SOH는 배터리를 운용하면서 외부 환경 조건에 따라 가변적인 지표이며, 배터리 전압은 두 개의 상태 변수에 종속적 관계성을 가지고 있다. 따라서, SOC와 SOH에 따라 전압 변동률이 가변적이어서 현재와 같이 단순 상·하한 전압만 제한하는 방법은 시간이 지남에 따라 실시간으로 배터리의 고장 진단하는 어려움이 있다. 또한, BMS에서 수많은 고장 조건을 사전에 설정하는 것은 메모리 데이터 저장 용량에 한계가 있다. 기존 방식의 경우 특정 전기적 특성 실험을 통해 자료를 수집하지만, 많은 시간과 개발 비용이 소요하고 고장 상황을 특정 지을 수 없으므로 어려움이 있다. 따라서, 최근 배터리의 고장 진단을 하는 데 있어 실시간으로 배터리의 센서 데이터를 기반으로 내부 정보를 추정 및 예측 방법에 관한 연구가 활발히 진행되고 있다.

대표적으로 배터리의 고장을 진단하는 방법은 사전 지식 기반(Knowledge-based), 모델 기반(Model-based) 및 데이터 기반(Data-driven) 방식들로 분류할 수 있다<sup>[14]</sup>. Knowledge-based 방식은 실험 및 실제 고장 데이터를 기반으로 사전에 배터리의 고장 진단을 하는 방법이다<sup>[15]-[17]</sup>. 운용 조건을 설정하기 쉽고 구현이 쉽다는 장점이 있지만, 데이터 확보에 많은 시간과 비용이 소모되고 명확한 기준을 정하기 어려운 단점이 있다. 두 번째로, 모델기반 방법인 관측기(Observer) 및 필터 계열의 방법이 있다<sup>[18],[19]</sup>. 이 방법의 경우에는 다른 방식에 비해 적은 실험 데이터를 요구하며, 제어가 이득값을 조절하

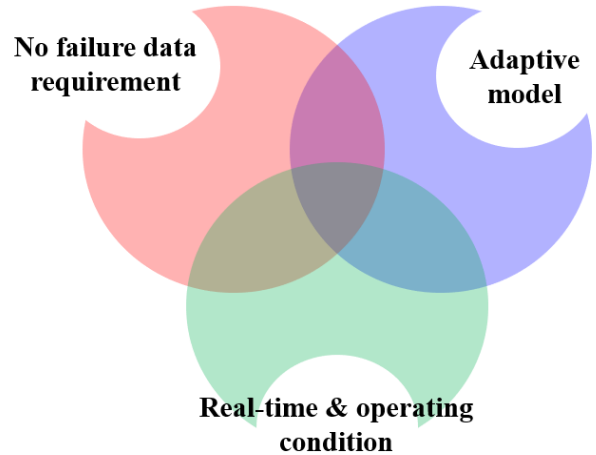


Fig. 1. Intersection requirement of prediction model.

여 실시간으로 배터리의 고장을 진단할 수 있는 장점이 있다<sup>[20]</sup>. 특히 기존 BMS의 상태 추정 알고리즘의 정보를 연계할 수 있으며, 고장 시점을 판단하기 쉬운 장점이 있다<sup>[21]</sup>. 하지만 고장 상황을 설명할 수 있는 모델이 요구되며, 이는 비선형적인 배터리 특성상 정확한 모델을 정립하는 것 또한 많은 양의 데이터가 필요하다는 단점이 있다. 마지막 방법으로 Data-driven 방식이 있으며 다른 방식에 비해 예측 성능이 가장 우수하며, 모델 정보의 불확실성이 존재하더라도 이를 데이터 간의 상관관계를 통해 극복할 수 있다는 장점이 있다<sup>[22]</sup>. 하지만 많은 양의 학습 데이터가 필요하다는 단점이 존재한다. 또한, 인공지능의 모델 학습에는 높은 계산량이 요구되어 병렬 처리가 가능한 Graphics processing unit(GPU)가 필요하여 BMS에 적용하는 것은 비용적으로 문제가 있다. 이를 보완하기 위한 대표적인 방법으로 통계 모델이 있다. 통계 모델의 경우 사전에 실험 데이터를 통해 예측 모델을 정립하지 않고, 시계열 데이터 형태로 측정되는 과거의 데이터 값의 경향성을 통해 예측한다. 또한, 고장 인자 간 상관 분석을 통해 변수 간의 관계성을 하나의 정량적 수치로 표현하여 모델을 구성한다. 따라서, 모델 정립 시 기존 방법과는 다르게 특정 데이터베이스가 필요하지 않은 장점이 있다. 그러나 통계 모델은 시스템의 모델에 의존하지 않지만, 상관성 분석을 할 수 있는 인자 선정 및 추정할 수 있는 방법론이 요구된다.

문헌 조사를 통해 현재 고장 진단 모델은 공통으로 대용량의 실험 데이터가 요구되는 것을 확인할 수 있다. 또한, 많은 고장 진단 모델의 경우 배터리 모듈 내부의 고장 시점을 판단하는 것에 있어 한계성을 가지고 있다. 따라서 본 논문에서는 과방전을 사전에 방지하기 위해서 다변수 자기 회귀모델을 사용하여 배터리의 전압을 예측하는 방법은 제안한다. 그림 1과 같이 사전 고장 데이터 없이 배터리의 고장 진단을 하는 방법을 제안한다. 이를 위해서 적응형 배터리 모델을 통해 고장 셀의 내부 파라미터를 분석하고 실시간으로 운용하기 위해서

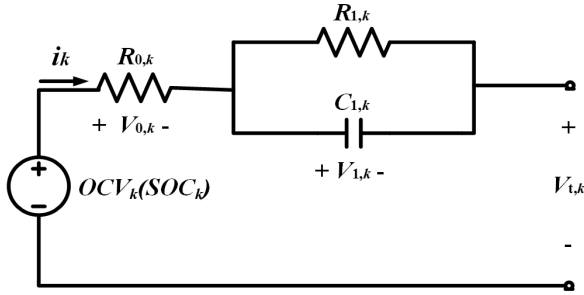


Fig. 2. Electrical equivalent circuit model.

모델기반 적응제어 기법과 통계 모델을 연계하는 방법에 관한 연구를 하였다. 본 논문에서 제안한 방법론은 실제 셀 간 내부 전압 편차에 의해 과방전이 발생한 데이터를 통해 검증하였으며, 선정된 인자 및 통계 모델 간 비교를 통해 예측 성능을 비교 검증하였다.

## 2. 배터리 동적 특성 해석을 위한 등가회로 모델링

### 2.1 고장 예측을 위한 모델기반 인자 선정

BMS에서 셀 단위 편차를 관리하기 위해서 배터리의 전압 거동을 기반으로 추출되는 내부 파라미터의 특성을 파악하는 것이 중요하다. 배터리 전압은 저항, SOC, 용량과 같은 다양한 요인의 영향을 받는다<sup>[23]-[25]</sup>. 또한, 어플리케이션의 요구 출력과 에너지를 충족시켜야 하므로 직·병렬 조합에 따라 최적 고장 인자 선정도 요구된다. 따라서, 본 논문에서는 배터리팩 구성에 따른 전압에 영향을 미치는 인자를 분석하고, 이를 기반으로 모델기반의 해석을 통해 배터리 고장의 사전 진단을 분석한다.

병렬연결 시 셀 간 Self-balancing 효과가 발생하여 각 셀 간 SOC가 맞춰지는 현상이 발생하여 직렬연결보다 불균형이 심화 되지 않는다. 하지만, 병렬연결 시 셀 간 저항 불균형은 전류 분배가 고르지 않게 하여 과전류와 같은 안전 문제가 발생할 수 있다. 특히 병렬연결 시 한 개의 셀이 고장이 발생하면 병렬 모듈 전체로 문제가 발생하는 현상이 발생할 수 있다. 하지만 병렬연결이 증가하면 증가할수록 내부 저항에 대한 영향성이 감소하게 되고 병렬연결 특성상 셀 간 전압이 동일한 특성이 있다. 이러한 특성으로 인해 내부 저항을 진단하기에 고정밀 알고리즘이 요구된다. 또한, 병렬연결의 경우 모듈마다 전류의 불균형을 측정하기 위해 홀 센서와 같은 전류 센서를 연결하는 것은 시스템 구성 시 비용을 증가시킨다. 따라서, 전류를 기반으로 배터리의 내부 상태를 추정하는 것은 효율적인 방법이다.

직렬연결의 경우 한 가지 주요 문제는 배터리가 노화에 따라 전압 및 전류 불균형과 관련된 저항 불일치가 심화하는 것이다<sup>[26],[27]</sup>. 직렬연결의 경우 병렬연결 특성과 달리 셀 간 편차를 바로잡을 수 있는 능력이 없으므로 셀 간 불균형이 발생한다. 이러한 셀 간 편차는 배

터리를 구동하면 할수록 증가하여 과충전 또는 과방전의 문제가 발생할 수 있다. 특히, 많은 배터리 시스템에서 병렬연결 후 직렬연결을 하고 있음에 따라 본 논문에서도 직렬연결 시 발생할 수 있는 전압 불균형 문제를 위주로 진행한다.

### 2.2 배터리 전기적 등가회로 모델링

본 논문에서는 배터리의 고장 데이터를 분석하기 위해서 전기적 입력 및 출력 신호(전압 및 전류)를 기반으로 해석하였다. 측정 데이터를 기반으로 배터리 전기적 등가회로 모델을 설계하였다. 배터리 등가회로 모델은 그림 2와 같이 개방 회로 전압(Open-circuit Voltage,  $OCV_k$ ), 직렬 저항( $R_0$ ), 확산 저항( $R_1$ ) 및 커패시턴스( $C_1$ )으로 구성된다. 일반적인 등가회로 모델의 경우 그림 2처럼 OCV와 같은 배터리 파라미터들이 SOC에 따라 변화하는 특성을 가진다. 하지만, SOC에 종속된 모델 사용 시 SOC 추정을 위한 추가 알고리즘 설계가 요구된다. 하지만, 본 논문에서는 다른 외부 변수에 대한 영향성을 줄이는 동시에 배터리 단자 전압 예측하기 위해 전류와 전압 간의 전달 함수만을 사용한 모델을 사용한다.

입력 전류와 배터리 단자 전압 간의 전달 함수는 연속 시간 기준으로 식 (1)로 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  $\theta_k$ 는 입력 파라미터 벡터 및  $\phi_k$  배터리 내부 파라미터 벡터를 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.

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

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

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

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

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

$$R_0 = b_0, R_1 = \frac{b_1 - a_1 \cdot b_0}{1 + a_1}, C_1 = \frac{\Delta t}{b_1 - a_1 \cdot b_0} \quad (5)$$

### 2.3 실시간 배터리 등가회로 모델 추정 기법

배터리의 내부 파라미터는 노화 정도, 배터리 내부 직·병렬 조합에 따라 가변적이다. 따라서, 입력 신호(전압 및 전류)에 따라 배터리 내부 파라미터의 변화를 추정할 수 있는 방법론 중 모델 기반 방법론이 많이 사용되고 있다. 대표적인 방법으로 Recursive least square(RLS)는 배터리 파라미터 및 상태 추정 시 널리 쓰이는 방법 중 하나이다<sup>[28]-[30]</sup>. 일반적인 RLS 기법의 경우 SOC-

OCV를 사용하고 이를 기준으로 나머지 파라미터들을 추정한다. 하지만 고장 상황에서 배터리는 SOC 영역이 일반 셀들에 비해 축소가 되어 동일한 SOC-OCV 정보를 사용할 경우 추정 성능이 하락하는 문제점이 발생한다. 따라서, 본 논문에서는 기존 RLS와 달리 배터리 OCV를 추정하는 동시에 배터리 파라미터( $R_0$ ,  $R_1$ ,  $C_1$ )를 추정할 수 있는 방법이 요구된다.

본 논문에서는 배터리 등가회로 모델의 4가지 파라미터를 모두 추정하기 위해서 Multiple adaptive forgetting factor(MAFF)-RLS 알고리즘을 활용하였다<sup>[29]</sup>. MAFF-RLS는 기존 RLS 방법론과는 다르게 SOC 정보 없이 배터리의 4가지 파라미터( $OCV_k$ ,  $R_0$ ,  $R_1$  및  $C_1$ )를 추정하는 알고리즘이다. 배터리 등가 모델의 파라미터들은 서로 다른 특성(수렴 속도, 변화량 등)을 가지기 때문에 각 파라미터의 forgetting factor( $\lambda_{i,k}$ )를 식 (6)과 같이 각각 정의하고 계산한다. 이 식에서  $\zeta$ 는 감쇠 계수를 뜻하며 각 파라미터마다 다른 상수값으로 정의한다. 이를 기반으로 계인 값( $L_{i,k}$ )을 식 (7)과 같이 계산하며  $P_{i,k}$ 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 줄여나가는 방식으로 알고리즘이 구동되게 한다.

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

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

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

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

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

### 3. 통계 모델기반 배터리 전압 예측 모델

#### 3.1 배터리 전압 예측을 위한 벡터자기회기 모델

자기 회귀(Auto-regressive, AR) 모델은 과거 시점의 시계열이 현재 시점의 시계열에 영향을 줄 때 유용한 시계열 모델이다<sup>[31]</sup>. 일반적으로 AR 모델은 식 (11)과 같이 이전 시계열 정보와 노이즈 성분을 추가하여 정의한다.

$$y(t) = a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + \epsilon_t \quad (11)$$

여기서  $a$ 는 모델 계수값을 뜻한다.

일반적인 AR 모델에서는 변수의 값이 급격하게 변하거나 시계열 데이터가 비선형성이 강한 경우 예측 성능이 하락하는 문제점이 있다. 특히, 배터리의 경우 사용 부하 및 환경 조건에 따라 전압이 급격하게 변동할 수 있다. 또한, 등가회로 모델에서 추정되는 파라미터를 활용하기 위해서는 일반 AR 모델 사용이 적절하지 않다. 따라서, 본 논문에서는 일반량의 데이터만의 상관관계를 반영하는 AR 모델 대신 다변량의 데이터들의 인과 관계를 사용하는 벡터자기회귀모델(Vector Auto-regressive Model, VAR)을 활용하였다<sup>[33]</sup>. 하나의 변수만을 통해 예측하는 일반적인 AR 모델과 달리 VAR 모델은 식 (12)와 같이 다변수를 활용하는 모델이다. 배터리와 같이 다양한 파라미터 변화에 의해 동작하는 시스템에 적합한 모델이라고 할 수 있다. 특히, 배터리 전압은 내부 저항으로 인해 급격하게 변하는 특성이 있고 전압은 다양한 변수에 의해 결정되기 때문에 이러한 현상을 잘 반영할 수 있는 VAR 모델을 사용하였다. VAR 모델은 식 (12)와 같이 정의할 수 있다.

$$y(t) = a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + b_1 u_1 + \dots + b_q u_q \quad (12)$$

여기서  $u_q$ 는 기존 AR 모델에서 다변량 파라미터를 추가한 변수이다.

본 논문에서는 배터리 전압을 예측하기 위해서 이전 20초의 데이터를 바탕으로 다음 20초의 데이터를 예측하기 위해 활용하였다. 자기회귀모델에 부하와 연관성을 것으로 예상되는 OCV와 확산 전압 데이터를 결합한 다중회귀모델을 사용하였다. 이를 통해 부하를 예측하는 식은 (13)과 같다. 확산 전압은 그림 3의 RC 병렬 회로의 전압을 나타내는 값으로써 식 (14)와 같이 정의한다.

$$V_{i,\tau} = \sum_{\tau=1}^p a_\tau V_{i,k-\tau} + b OCV_k + c V_{1,k} + R_0 i_k \quad (13)$$

$$V_{1,k+1} = \exp(-\frac{\Delta t}{\tau}) \cdot V_{1,k} + (1 - \exp(-\frac{\Delta t}{\tau})) \cdot R_{i,k} i_k \quad (14)$$

여기서  $t$ 는 예측 시간을 나타내고  $\tau$ 는 예측 시간으로부터 이전 20초 데이터의 Index 값이며,  $p$ 는 사용된 이전 전압 데이터의 개수를 나타낸다.

#### 3.2 전압 예측 성능 향상을 위한 통상최소자승법

예측 모델을 실시간 알고리즘에 적용하고 추정 성능을 보장하기 위해서는 식 (12)의 계수를 지속적으로 업데이트하는 방안이 필요하다. 최소제곱법의 풀이 중 하나로 통상최소자승법(Ordinary Least Square, OLS)는 선형 회귀모델의 계수 값을 계산하는 방법이다. VAR 모델은 다변량 식으로 시작하여 문제를 해결하기 때문에 선형 회귀모델을 행렬 형태를 통해 나타낸다.

예측 모델의 수식을  $y = X\theta$ 와 같은 선형식으로 정의

한다. 이식의 잔차 제곱합의 미분식이 0이 되도록 하는  $w$ 를 직접 계산하여 VAR 모델의 계수를 구한다. 따라서 본 논문에서는 식 (12)의 계수를 계산하기 위해서 식 (15)와 같이 계산한다<sup>[34]</sup>.

$$\hat{\alpha}_t = (\Phi_t' \Phi_t)^{-1} \Phi_t' y_t \quad (15)$$

여기서  $\Phi_t$ 는 식별되는 값,  $y_t$ 는 측정값,  $\hat{\alpha}_t$ 는 VAR 모델의 추정된 계수값을 나타낸다. 정의된 파라미터들을 식 (16), (17)와 같이 정의한다.

$$\Phi_t = \begin{bmatrix} y_{k-1} & \cdots & y_{k-p} & u_{1,k} & \cdots & u_{s,k} \\ y_{k-2} & \cdots & y_{k-p-1} & u_{1,k-1} & \cdots & u_{s,k-1} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ y_{p-1} & \cdots & y_2 & u_{1,p} & \cdots & u_{s,p} \\ y_p & \cdots & y_1 & u_{1,p+1} & \cdots & u_{s,p+1} \end{bmatrix} \quad (16)$$

$$y_k = \begin{bmatrix} y_k \\ y_{k-1} \\ \vdots \\ y_p \\ y_{p+1} \end{bmatrix}, \hat{a}_k = \begin{bmatrix} \hat{a}_0 \\ \hat{a}_0 \\ \vdots \\ \hat{a}_p \\ \hat{b}_1 \\ \vdots \\ \hat{b}_s \end{bmatrix} \quad (17)$$

#### 4. 배터리 과방전 전압 예측 및 검증

##### 4.1 셀 간 불균형 파라미터 추정 결과

본 논문에서는 배터리 팩 내부 셀 간 파라미터 불균형을 검증하기 위해서 배터리 충·방전 실험을 진행하였다. 실험은 11S2P(S: 직렬, P: 병렬)로 구성된 배터리 팩을 사용하였으며, 셀마다 전압을 측정하였다. 그중에서 과·방전 현상을 나타내는 셀과 일반적인 셀을 선정하여 그림 3과 같이 구성하였다. 배터리 충·방전 실험상에서 배터리의 하한 전압은 셀 기준으로 3V로 설정하였으며, 셀 사양서 상에서 하한 전압은 2.5V이다. 각 셀에 2.2장에서 소개한 MAFF-RLS 알고리즘을 적용하여 배터리의 내부 파라미터 간 차이를 분석하였다.

그림 4는 배터리의 OCV를 고장 셀과 일반 셀을 비교한 그래프이다. OCV는 단자 전압과 마찬가지로 두 셀 간 차이가 저전압 구간에서만 편차가 발생하였으며 충전 영역에서는 큰 차이가 나타나지 않는 것을 확인할 수 있다. 그림 5와 6은 배터리의 내부 저항과 확산 저항을 나타낸 그래프이다. 일반적으로 배터리 내부 저항은 배터리 전압 변동에 큰 영향을 미치는 요소이다. 특히, 고장 셀의 경우 일반 셀보다 더 큰 값을 나타내고 있다. 그림 7은 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 하한 전압에 빠르게 도달

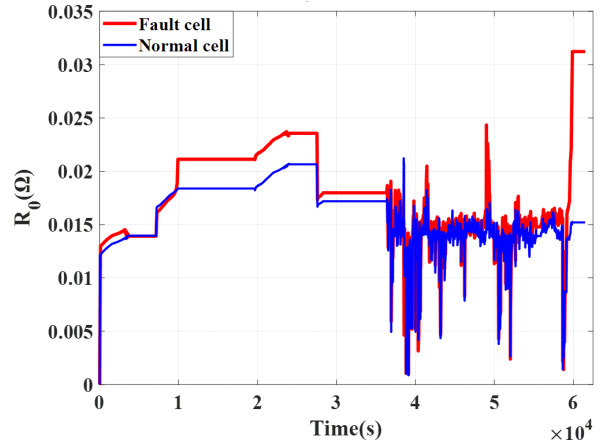


Fig. 3. Estimation result of series resistance using MAFF-RLS comparing with fault and normal cell.




Fig. 4. Estimation result of open circuit voltage using MAFF-RLS comparing with fault and normal cell.




Fig. 5. Estimation result of diffusion resistance using MAFF-RLS comparing with fault and normal cell.

하는 것을 확인할 수 있다. 이러한 현상의 발생 원인으로서는 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.




Fig. 6. Experimental result of terminal voltage using MAFF-RLS comparing with fault and normal cell.




Fig. 7. Parameter tendency in the over-discharge region comparing with fault and normal cell.

#### 4.2 과방전 예측 결과 및 예측 모델 비교 분석

일반 AR 모델을 통해 예측된 전압은 그림 8에 나타내었다. 빨간색 선은 식 회귀모델의 계수값을 도출하기 위해 학습한 구간을 나타내며 파란색 선은 식 (13)에서 내부 저항 요소를 제거한 예측 결과를 나타내고 보라색 선은 식 (13)를 통해 예측된 결과이다. 초록색 선은 실험 데이터에서 측정된 전압을 사용이며 기준값으로 활용하였다. 일반 AR 모델의 경우 전압 데이터만을 통해 전압을 예측하였기 때문에, 초기 계수값에 의해 결과값이 의존한다. 따라서, 전압이 변동하는 부분에서 계수를 피팅하여 예측 결과도 전압값이 흔들리는 것을 확인할




Fig. 8. Prediction result of the conventional AR model.

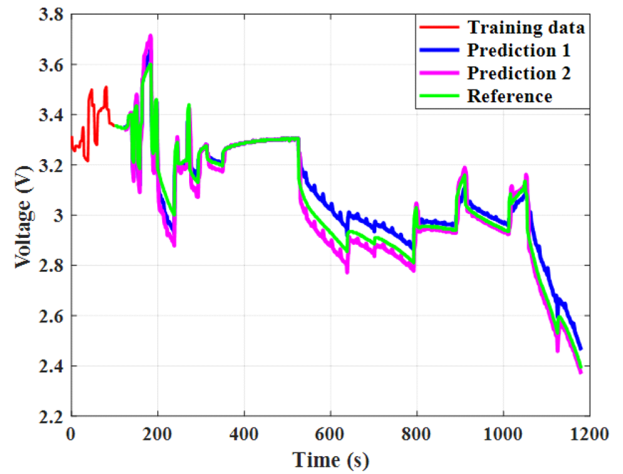


Fig. 9. Comparison of the various VAR model in over-discharge region.

TABLE I  
MEAN ABSOLUTE PERCENTAGE ERROR RESULTS OF AR AND VAR

Prediction Model	MAPE (%)
AR model	1.85
Prediction 1 (VAR)	1.44
Prediction 2 (VAR)	1.04

수 있다. MAFF-RLS기반 VAR 모델을 통한 배터리 단자 전압 예측 결과는 그림 9에 도시하였다. 식 (18)를 통해서 평균 절대 에러 백분율(Mean absolute percentage error, MAPE)를 통해 예측 성능을 평가하였으며, 표 1에 명시하였다. 여기서  $n$ 은 샘플 개수를 나타내며  $A_n$ 는 실제값  $F_n$ 는 예측값을 나타낸다. 파란색 선을 나타내는 첫 번째 예측 결과의 MAPE는 1.445%이며, 보라색 선의 두 번째 예측 결과의 MAPE는 1.044%로 내부 저항 영향에 따라 전압의 강하를 반영하면 예측 결과의 성능이 약 0.4% 향상하는 것을 확인할 수 있다.



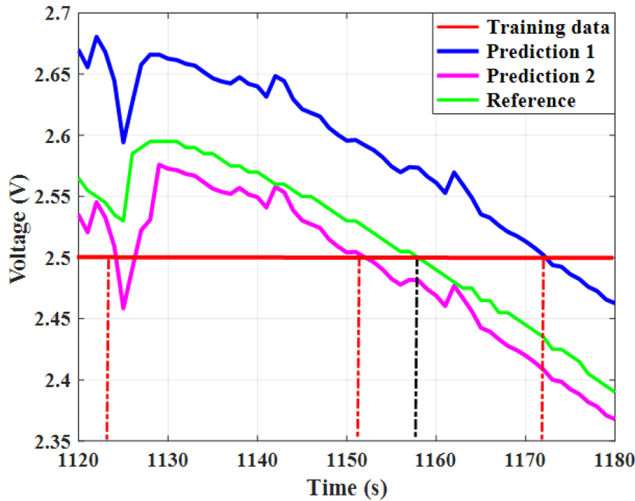


Fig. 10. Enlarged result of the voltage prediction in over-discharge region.

$$MAPE = \frac{100}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{A_t} (\%) \quad (18)$$

그림 10은 하한 전압(2.5V) 지점을 예측하는 지점을 나타낸 그래프이다. 내부저항을 무시한 모델의 예측 결과의 경우 실제 값보다 하한 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 하한 전압을 예측하는 것을 확인할 수 있다. 하지만 1123초 구간에서 순간적인 전압 강하로 인해 2.5V에 도달하는 것을 확인할 수 있으며, 추후에 이러한 현상을 방지하기 위한 과방전에 대한 기준점을 새로 정립할 필요가 있다.

## 5. 결 론

본 논문은 배터리 시스템의 안전성을 높이기 위한 배터리 팩 내부 셀의 과방전을 예측 알고리즘을 제안하였다. 이를 위해 배터리 모델 기반 알고리즘을 통해 실시간으로 파라미터를 추정하여 데이터를 취득하였다. 확보된 시계열 형태의 배터리 파라미터 정보를 기반으로 백터 자기 회귀모델을 사용하여 전압을 예측하여 과방전을 사전에 진단할 수 있도록 구성하였다. 시뮬레이션 예측 결과를 기준으로 단순 배터리 전압 데이터만 활용하는 것보다 내부 저항 요소를 충분히 반영할수록 성능이 향상됨을 확인하였다. 이를 기반으로 추후 연구에서는 배터리 고장에 기인하는 특성 파라미터에 대한 추가적인 연구가 수행할 예정이며, 배터리의 과방전에 대한 정확한 기준을 정립하기 위한 연구가 필요하다. 또한, 저전압 구간이 아닌 고전압 구간에서도 예측 모델에 대한 검증이 요구된다.

본 연구는 (주)효성 중공업연구소의 지원을 받아 수행한 연구 결과입니다.

## References

- [1] IRENA, "Electricity storage and renewables: costs and VARkets to 2030," *International Renewable Energy Agency*, Abu Dhabi, 2017.
- [2] IEA, "Understanding the world energy outlook scenarios," 2019.
- [3] IRENA, "Global energy transformation: A roadmap to 2050," 2019 ed., Apr. 2019.
- [4] Bloomberg New Energy Finance, "Energy storage outlook 2019," *BloombergNEF*, Paris, France, 2019.
- [5] B. Dunn, H. Kamath, and J. M. Tarascon, "Electrical energy storage for the grid: A battery of choices," *Science*, Vol. 334, No. 6058, pp. 928 - 935, Nov. 2011.
- [6] W. Jang, "Crisis in the domestic ESS industry environment - causes and action," *VIP Report*, Vol. 734, pp. 1 - 19, 2020.
- [7] Ministry of Trade, Industry and Energy, "ESS fire accident investigation result, public-private partnership ESS fire accident investigation result," Jun. 2019.
- [8] KESCO & KTI, "ESS fire accident investigation result report, ESS fire accident investigation team," Feb. 2020.
- [9] R. Xiong, W. Sun, Q. Yu, and F. Sun, "Research progress, challenges and prospects of fault diagnosis on battery system of electric vehicles," *Applied Energy*, Vol. 279, 115855, Dec. 2020.
- [10] M. F. Samadi and M. Saif, "Integrated battery, management system," *Integrated Systems: Innovations and Applications*, Springer, Cham, pp. 173 - 193, 2015.
- [11] Y. Xing, E. W. Ma, K. L. Tsui, and M. Pecht, "Battery management systems in electric and hybrid vehicles," *Energies*, Vol. 4, No. 11, pp. 1840 - 1857, Oct. 2011.
- [12] M. A. Hannan, M. H. Lipu, A. Hussain, and A. Mohamed, "A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations," *Renewable and Sustainable Energy Reviews*, Vol. 78, pp. 834 - 854, Oct. 2017.
- [13] R. Xiong, J. Cao, Q. Yu, H. He, and F. Sun, "Critical review on the battery state of charge estimation methods for electric vehicles," *IEEE Access*, Vol. 6, pp. 1832 - 1843, Dec. 2017.
- [14] X. Hu et al., "Advanced fault diagnosis for lithium-ion battery systems," *IEEE Industrial Electronics Magazine*, Vol. 14, No. 3, pp. 65 - 91, Sep. 2020.
- [15] J. Xiong et al., "Failure detection for over-discharged Li-ion batteries," in *Proceedings of 2012 IEEE*

- International Electric Vehicle Conference*, Greenville, SC, pp. 1 - 5, Mar. 2012.
- [16] V. K. Muddappa and S. Anwar, "Electrochemical model based fault diagnosis of Li-ion battery using fuzzy logic," in *ASME 2014 International Mechanical Engineering Congress and Exposition*, pp. 9, Mar. 2015.
- [17] J. Huber et al., "Method for classification of battery separator defects using optical inspection," *Procedia CIRP*, Vol. 57, pp. 585 - 590, Nov. 2016.
- [18] X. Feng, C. Weng, M. Ouyang, and J. Sun, "Online internal short circuit detection for a large format lithium ion battery," *Applied Energy*, Vol. 161, pp. 168 - 180, Jan. 2016.
- [19] A. Singh, A. Izadian, and S. Anwar, "Fault diagnosis of Li-ion batteries using multiple-model adaptive estimation," in *IECON 2013 - 39th Annual Conference of the IEEE Industrial Electronics Society*, Vienna, Austria, pp. 3524 - 3529, Nov. 2013.
- [20] M. Ouyang et al., "Internal short circuit detection for battery pack using equivalent parameter and consistency method," *Journal of Power Sources*, Vol. 294, pp. 272 - 283, 2015.
- [21] X. Feng et al., "Online internal short circuit detection for a large format lithium ion battery," *Applied Energy*, Vol. 161, pp. 168 - 180, Jan. 2016.
- [22] Y. Zhao, P. Liu, Z. Wang, L. Zhang, and J. Hong, "Fault and defect diagnosis of battery for electric vehicles based on big data analysis methods," *Applied Energy*, Vol. 207, pp. 354 - 362, Dec. 2017.
- [23] E. Meissner and G. Richter, "Battery monitoring and electrical energy management: precondition for future vehicle electric power systems," *Journal of Power Sources*, Vol. 116, pp. 79 - 98, 2003.
- [24] L. Zhou et al., "A study on parameter variation effects on battery packs for electric vehicles," *Journal of Power Sources*, Vol. 364, pp. 242 - 252, 2017.
- [25] B. Wu, V. Yufit, M. Marinescu, G. J. Offer, R. F. Martinez-Botas, and N. P. Brandon, "Coupled thermal-electrochemical modelling of uneven heat generation in lithium-ion battery packs," *Journal of Power Sources*, Vol. 243, pp. 544 - 554, 2013.
- [26] C. Fleischer, W. Waag, Z. Bai, and D. Sauer, "On-line self-learning time forward voltage prognosis for lithium-ion batteries using adaptive neuro-fuzzy inference system," *Journal of Power Sources*, Vol. 243, pp. 728e49, 2013.
- [27] X. Zhang, Y. Wang, J. Wu, and Z. Chen, "A novel method for lithium-ion battery state of energy and state of power estimation based on multi-time-scale filter," *Applied Energy*, Vol. 216, pp. 442 - 451, Apr. 2018.
- [28] H. F. Dai, X. Z. Wei, and Z. C. Sun, "Recursive parameter identification of lithium-ion battery for EVs based on equivalent circuit model," *Journal of Computational and Theoretical Nanoscience*, Vol. 10, pp. 2813 - 2818, 2013.
- [29] A. Vahidi, A. Stefanopoulou, and H. Peng, "Recursive least squares with forgetting for online estimation of vehicle mass and road grade: theory and experiments," *Vehicle System Dynamics*, Vol. 43, No. 1, pp. 31 - 55, 2005.
- [30] B. D. Ketelaere, H. Saelens, L. Wulterputte, and J. Anthonis, "Nozzle fault detection using recursive least-squares," in *20th Annual Conference on Liquid Atomization and Spray Systems*, Chicago, USA, 2007.
- [31] 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 LiFePO<sub>4</sub> battery in electric vehicles using multiple adaptive forgetting factors recursive least-squares," *Journal of Power Sources*, Vol. 296, pp. 215 - 224, 2015.
- [32] J. Park, M. Lee, G. Kim, S. Park, and J. Kim, "Integrated approach based on dual extended kalman filter and multivariate autoregressive model for predicting battery capacity using health indicator and SOC/SOH," *Energies*, Vol. 13, No. 9, pp. 2138, 2020.
- [33] K. Moon, "Vector autoregressive model," *KOSTAT*, Vol. 2.1, pp. 23 - 56, 1997.
- [34] G. E. P. Box, G. M. Jenkins, and G. C. Reinsel, *Time series analysis: Forecasting and control*, John Wiley & Sons, 2008.



#### **박진형 (朴珍亨)**

1993년 1월 4일생. 2018년 충남대 전기공학과 졸업. 2018년~2020년 동 대학원 전기공학과 졸업(석사). 2020년~현재 동 대학원 전기공학과 박사과정



#### **김재원 (金載源)**

1996년 3월 21일생. 2021년 충남대 전기공학과 졸업. 2021년~현재 동 대학원 전기공학과 석사과정.



#### **이미영 (李美英)**

1994년 3월 7일생. 2018년 한밭대 화학생명공학과 졸업. 2021년~현재 충남대 전기공학과 석사과정.





**김병철(金丙哲)**

1979년 2월 22일생. 2020년 건국대 전기기계 및 전력전자 전공 졸업. 2008년~현재 (주)효성 중공업연구소 ESS연구팀 차장.



**정성철(鄭成哲)**

1983년 2월 7일생. 2010년 한양대 전자전기 전공 졸업. 2020년~현재 (주)효성 중공업연구소 ESS연구팀 과장.



**김종훈(金鍾勳)**

1979년 4월 22일생. 2005년 충남대 정보통신공학부 전기전자전파전공 졸업. 2012년 서울대 전기컴퓨터공학부 졸업(공학; 석박 통합과정). 2012년~2013년 삼성SDI ES사업부 책임연구원. 2013년~2016년 조선대 전기공학과 조교수. 2016년~현재 충남대 전기공학과 부교수. 2018년~2020년 한국과학기술원 친환경센터 스마트자동차연구센터 겸직 교수. 2015년~현재 JPE Associate Editor. 2016년~2020년 당 학회 편집위원. 2017년 당 학회 학술위원. 2020년~현재 당 학회 연구사업이사. 2019년~현재 IEEE Senior Member.