

딥러닝과 특징 추출 기반 배터리 노화 상태 추정 방법

장문석¹, 이강석¹, 배성우[†]

Battery State-of-Health Estimation Method based on Deep-learning and Feature Engineering

Moon-Seok Chang¹, Gang-Seok Lee¹, and Sungwoo Bae[†]

Abstract

This study proposes a battery state-of-health estimation method by applying a feature extraction technique. The technique that can improve estimation performance is the process of identifying and extracting meaningful data. To apply a data-driven-based aging state estimation method to batteries, health indicators are used as training data. However, limitations occur in extracting health indicators from charge/discharge cycles. This study proposes a deep-learning-based battery state-of-health estimation method that applies feature extraction techniques to compensate for this problem. According to the performance evaluation result of the proposed method, it has a low estimation error of 0.3887% based on an absolute error evaluation method.

Key words: Health indicator, State-of-health, Feature engineering, Li-ion battery, Deep neural network

1. 서 론

최근 리튬 이온 배터리는 높은 에너지 밀도와 긴 수명의 장점으로 전기 자동차를 포함한 여러 산업에서 사용되고 있다^[1]. 리튬 이온 배터리 사용 증가에 따라 리튬 이온 배터리의 안전하고 효율적인 관리의 중요성이 증대되고 있다. 배터리 노화 상태(State-of-Health, SOH)는 리튬 이온 배터리의 수명의 정보를 가지고 있는 지표이다. 배터리 노화 상태는 내부 저항의 불일치 증가, 내부 배터리 열의 불균형 등의 다양한 원인으로 비선형적으로 감소한다^[2]. 배터리 수명의 정보를 가지고 있는 SOH를 파악하면 배터리 내구성을 개선할 수 있으며, 배터리를 적시에 교체하여 배터리 관리 시스템의 신뢰성을 향상할 수 있다.

데이터 기반 SOH 추정 방법은 SOH 추정 시 배터리

모델링이 필요하지 않아 최근 많이 사용되고 있다. 배터리 모델 기반 SOH 추정 방법은 배터리 화학 반응식 기반 배터리 모델링으로 SOH를 추정한다^[3]. 하지만 이러한 배터리 모델링 과정은 계산이 복잡하여 사용이 어렵다. 반면에 데이터 기반 SOH 추정 방법은 배터리에 대한 사전 지식과 복잡한 계산 없이 배터리 데이터와 목표 데이터의 관계를 도출해 SOH를 추정할 수 있다. 이러한 데이터 기반 SOH 추정 방법에는 Support Vector Machine(SVM)^[4], Long Short Term Memory(LSTM)^[5], Gaussian Process Regression(GPR)^[6]가 있다.

데이터 기반 SOH 추정 방법은 입력 데이터의 개수 그리고 입력 데이터와 목표 데이터의 상관성 정도에 따라 SOH 추정 성능이 좌우된다. 따라서 목표 데이터와 상관성이 높은 데이터를 많이 확보하는 것이 중요하다. 이러한 특성을 가진 데이터 기반 SOH 추정 방법은 배터리 SOH 추정 훈련 데이터로 Health Indicator를 사용한다. 데이터 기반 SOH 추정 방법은 배터리 방전 사이클에서 추출한 배터리의 내부 저항값과 용량, 방전 시간 같은 Health Indicator를 데이터로 사용한다. 하지만 배터리의 내부 저항과 용량은 방전 시간보다 측정하기 어려워 정밀한 측정 장비가 필요하며, 비용이 많이 든다^[7].

본 논문에서는 딥러닝과 특징 추출 기법을 통해 이러한 한계점을 보완하고 추출하기 쉬운 방전 시간과 사이

Paper number: TKPE-2022-27-4-8

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

[†] Corresponding author: swbae@hanyang.ac.kr, Dept. of Electrical Engineering, Hanyang University, Korea
Tel: +82-2-2220-2309 Fax: +82-2-2220-3119

¹ Dept. of Electrical Engineering, Hanyang University, Korea
Manuscript received Oct. 10, 2021; revised Nov. 4, 2021;
accepted Dec. 27, 2021

— 본 논문은 2021년 전력전자학술대회 우수추천 논문임

클 수를 조합한 새로운 특징을 소개한다. 데이터 기반 모델에서 SOH 추정 과정에서는 데이터 확보 비용을 최소화하며 특징을 확보하는 과정이 필수적이다. 본 논문에서는 특징 추출 기법을 통해 SOH와 연관된 특징들을 생성한다. 이러한 특징을 입력 데이터로 사용하기 위해 딥러닝 알고리즘인 Deep Neural Network(DNN)를 사용하였다[8]. 본 연구에서는 DNN을 통해 특징 추출 기법 사용 전과 후의 배터리 SOH 추정 성능을 비교하였다. 제안한 딥러닝과 특징 추출 기법은 Health Indicator 사용을 최소화하면서 여러 개의 특징과 SOH와 관계를 도출할 수 있었다. 제안하는 방법은 특징 추출을 사용하지 않을 때보다 배터리 SOH 추정 성능을 개선하였으며, 각 기법의 SOH 추정 오차를 Mean Absolute Error(MAE), MIN, MAX 기준으로 비교하였다. 제안된 방법은 해당 오차 기준에서 기존의 성능보다 개선할 수 있었다.

2. SOH 정의 및 배터리 충·방전 과정

2.1 SOH 정의

SOH는 리튬 이온 배터리 노화 정도를 나타내며 배터리 교체 시점 파악에 이용된다. 일반적으로 Data driven 방법에서 SOH는 현재 용량과 초기 용량의 비율로 정의한다. 이에 따른 SOH는 식 (1)과 같이 계산된다.

$$SOH = \frac{C_c}{C_i} \quad (1)$$

해당 수식에서 C_i 는 초기 배터리 용량이며 C_c 는 현재 배터리 용량이다. 현재 용량은 방전 사이클이 증가함에 따라 초기 배터리 대비 현재 배터리의 노화된 정도인 Capacity fade 정도를 반영한다. 이러한 수식에 따라 만들 수 있는 SOH 곡선을 통해 지속적인 충전 및 방전으로 인한 배터리 노화에 따른 전반적인 배터리 수명을 확인할 수 있다.

2.2 배터리 실험 데이터

본 논문에서는 공개 데이터인 CALCE의 CS2 배터리 데이터를 사용하여 실험 데이터를 구축하였다. 해당 배터리는 LiCoO2 타입을 가진다. CS2 배터리의 구체적인 데이터 사양은 표 1과 같다. 정격 용량은 1,100mAh이며 Cut-off 전압은 4.2V에서 2.7V이다. 충전 과정은 정전류-정전압(CC-CV) 충전으로 진행되었으며 정전류 충전 시에는 CS2 배터리는 충전전압 4.2V까지 일정한 0.55A가 유지되었다. 그리고 정전압 충전 시에는 충전전류가 0.05A 미만일 때까지 4.2V의 충전전압이 유지되었다. 방전 과정은 정전류로 진행되며 방전율 0.55C으로 방전되었다.

TABLE I
INVESTIGATED BATTERY DATA SPECIFICATIONS

| Dataset | Type | Capacity | Cut-off Voltage | Data Source |
|---------|--------|----------|-----------------|-------------|
| CS2 | LiCoO2 | 1.1Ah | 4.2V / 2.7V | CALCE |

해당 사양을 가진 CS2 배터리 데이터로부터 사이클 변화에 따라 SOH 값을 추출하였다. 먼저 충전, 방전 사이클이 종료되었을 때 배터리 용량 변화를 측정하였다. 그다음 식 (1) SOH의 정의에 따라 SOH 지표를 계산하였다. 해당 수식에 따라 Capacity fade 정도가 반영된 SOH 값은 딥러닝 추정 시 훈련에 사용되는 훈련 데이터와 추정 평가를 위한 검증 데이터로 사용되었다[4][5][6].

3. Health Indicator 및 시계열 특징

3.1 Health Indicator

일반적으로 Health Indicator는 배터리 노화 상태를 나타내는 지표로 데이터 기반 방법에서 리튬 이온 배터리의 SOH를 추정할 때 입력 데이터로 사용된다. 데이터 기반 SOH 추정 모델은 Health Indicator 데이터를 통해 학습하며 SOH와의 관계 도출이 가능하다. Health Indicator를 추출하는 방법은 다양한 방법이 존재한다. Health Indicator 추출 방법으로는 증분 용량 곡선, 내부 저항, 동일 전압 차이의 방전 용량, 동일 전압 차이의 방전 시간, 정전류 충전 시간, 정전압 충전 시간 등이 있다[9][10][11]. 각각의 Health Indicator는 추출 방법마다 계산 정도 및 비용이 다르므로 적용 환경에 따라 Health Indicator 추출 방법을 다르게 적용한다.

3.2 Health Indicator 추출

본 논문에서는 배터리 방전 과정에서 동일 전압 구간 방전 시간의 차이를 Health Indicator로 사용하였다. 해당 방법은 다른 Health Indicator인 용량 및 내부 저항보다 복잡한 계산이 필요하지 않으며 온라인으로 측정할 수 있다는 장점이 있다[12]. 그림 1은 CS2 배터리의 방전 시간별 전압의 변화 그래프이다. Health Indicator인 동일 전압 차이의 방전 시간을 계산하기 위해서는 전압 구간(V1-V2)을 정하는 것이 필요하다. 단자 전압이 V1일 때 시간을 T1, 단자 전압이 V2일 때 시간을 T2로 지정한다. 이때 동일 전압 차이의 방전 시간은 T1-T2가 된다. 이러한 방법으로 방전 사이클마다 동일 전압 차이의 방전 시간의 Health Indicator를 추출하였다.

본 논문에서 사용한 전압 구간(V1-V2)은 참고문헌 [1]에서 같은 배터리 사양으로 V1, V2 값 변화 시




Fig. 1. Extracting a health indicator from a discharge curve.




Fig. 2. Discharge time in the 3.9~3.5V range in each discharge cycle.

SOH와 가장 높은 상관관계를 가진 3.9-3.5V 구간으로 선정하였다. 그림 2는 본 논문에서 사용한 Health Indicator로 3.9-3.5V 구간의 방전 시간 차이를 방전 사이클마다 계산하여 그래프로 구현한 것이다. 그래프를 통해 방전 사이클이 1 Cycle일 때 3.9-3.5V 구간의 방전 시간 차이 값이 최대이며, 방전 사이클이 증가하면서 용량 저하 현상이 일어나 방전 시간 차이 값이 점차 줄어드는 것을 확인할 수 있다.

3.3 시계열 특징 추출

시계열 특징 추출은 시계열 데이터를 주요 성분으로 분리하는 과정이다. 이러한 시계열 특징 추출 모델에는 가법 모델(Additive Model)과 승법 모델(Multiplicative model)이 있다. 승법 모델은 주요 성분의 곱으로 시계열 데이터가 구성되어 서로 영향을 주는 값으로 분리가 된다. 반면에 가법 모델은 주요 성분의 합으로 분리가 되어 독립적인 성분으로 추출하는 것이 가능하다. 본 논문에서는 각 특징과 SOH와 상관관계를 독립적으로 파악하기 위해 가법 모델을 사용하였다. 가법 모델로 추출할 수 있는 시계열 주요 성분에는 추세(Trend), 계절성(Seasonal), 잔차(Residual)가 존재한다. 추세는 데이터가 장기적으로 증가하거나 감소하는 값을 나타내며 계절성은 특정 시간의 주기로 나타나는 패턴

을 의미한다. 그리고 잔차는 예측 불가능한 임의의 변동을 나타낸다.

$$Y_t = T_t + S_t + R_t \quad (2)$$

가법 모델에서 시계열 데이터는 식 (2)와 같이 표현될 수 있다. 해당 수식에서 Y_t 는 특정 시간 t 에서의 시계열 데이터, T_t 는 특정 시간 t 에서의 추세, S_t 는 특정 시간 t 에서의 계절성, R_t 는 특정 시간 t 에서의 잔차 데이터를 의미한다.

$$T_t = \frac{Y_{t-1} + Y_{t-2} + \dots + Y_{t-p}}{p} \quad (3)$$

$$D_t = Y_t - T_t \quad (4)$$

$$S_t = \frac{(D_t + D_{t+p} + \dots + D_{t+p*(n-1)})}{n} \quad (5)$$

$$R_t = Y_t - T_t - S_t \quad (6)$$

시계열 특징 추출과정은 세 데이터 추출과정, 추세 제거 데이터 추출과정, 시계열 데이터 추출과정, 잔차 데이터 추출과정 4단계로 구성된다. 첫 번째로 추세 데이터 추출과정은 식 (3)과 같이 주기가 p 일 때마다 평균을 취하는 이동 평균을 이용하여 추출된다. 해당 수식은 주기가 p 일 때의 p 크기의 구간을 이동시켜 해당 구간의 평균을 구하는 과정이다. 두 번째로 추세 제거 데이터 추출과정은 식 (4)와 같이 시계열 특징 원본 데이터에서 추세 데이터를 뺀 추세 제거 데이터(Detrended Series)인 D_t 를 계산한다. 세 번째로 계절성 데이터 추출과정은 식 (5)처럼 주기가 p 이고 이러한 주기가 n 번 지속될 때 각주기마다 추세 제거 데이터의 t 번째 값들의 평균을 취해 구할 수 있다. 마지막으로 잔차 데이터 추출과정은 식 (6)과 같이 잔차 데이터는 시계열 데이터 원본에서 추세와 계절성을 뺀 나머지 값으로 표현될 수 있다. 위와 같은 계산 방법으로 방전 시간 데이터에서 추출한 시계열 특징들의 그래프는 그림 3과 같다. 각 그래프는 상단부터 시계열 추출 적용 전의 방전 시간 그리고 시계열 특징 추출로 만든 추세, 계절, 잔차 데이터의 그래프이다.

3.4 다항 차수 변환

추출한 시계열 특징들을 바탕으로 SOH와 상관관계가

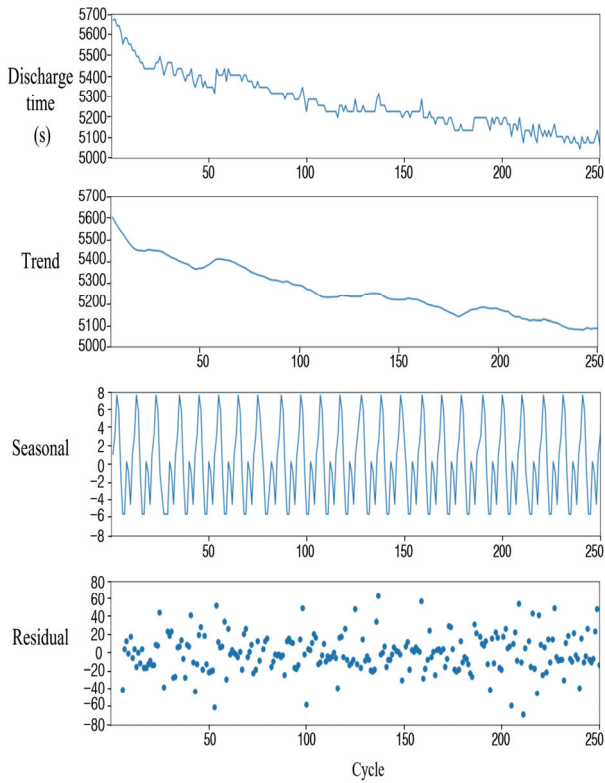


Fig. 3. Time series features (Discharge Time, Trend, Seasonal, and Residual) graphs.

높은 특징을 만들기 위해 다항 차수 변환 방법을 사용하였다. 다항 차수 변환은 지정된 차수 이하의 모든 다항식 조합으로 특징을 만드는 것이다. 예를 들어 식 (7)은 특징이 X_1, X_2 이고 차수가 N 이라고 가정했을 때 다항 차수 변환을 나타낸 것이다. 해당 방법을 통해 데이터 기반 모델의 성능을 개선할 수 있는 새로운 특징을 만들 수 있다. 본 논문에서는 사이클 수, 방전 시간, 그리고 시계열 특징들을 다항 차수 변환하여 새로운 특징을 만들었다.

$$Poly(X_1, X_2, N) = X_1^N, X_1^{N-1} * X_2, \dots, X_2^N \quad (7)$$

3.5 피어슨 상관관계

본 논문에서 다항 차수 변환으로 만든 특징들은 SOH와의 피어슨 상관관계(Pearson Correlation Coefficients)를 통해 상관관계를 파악하였다. 피어슨 상관관계는 두 변수의 선형 상관관계를 계량화한 수치다.

$$Pearson = \frac{\sum_{i=1}^n (x_i - \bar{x}) * (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} * \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (8)$$

피어슨 상관관계의 수식은 식 (8)과 같다. 해당 수식에서 x 는 SOH, y 는 다항 차수로 조합한 특징을 의미한다. n 은 표본의 크기, 즉 배터리 사이클의 수이다. x_i, y_i 는 i 번째 표본의 각각의 값이며 \bar{x}, \bar{y} 는 각 표본의 평균값을 나타낸다. 이러한 수식을 통해 두 변수 x 와 y 의 상관관계 수치를 파악할 수 있다. 피어슨 상관관계가 1인 경우 완벽한 양의 선형 상관관계이고 -1인 경우 완벽한 음의 선형 상관관계를 의미한다. Pearson Correlation Coefficients를 통해 두 특징 간의 관계를 파악하는 것이 가능하다.

4. 제안한 SOH 추정 방법

4.1 특징 추출 기반 SOH 추정 방법

본 논문에서 제안한 특징 추출 기반 SOH 추정 방법 과정은 그림 4와 같다. 먼저 배터리 방전 데이터에서 전압, 전류, 방전 시간, 사이클 수 데이터를 수집한다. 다음으로 수집한 데이터를 바탕으로 이전에 언급한 3.9-3.5V 구간에서의 Health Indicator인 방전 시간 데이터를 추출한다. 추출된 Health Indicator에서 시계열 특징 추출 방법을 이용해 추세, 계절성, 잔차 데이터를 추출한다. 이후 시계열 특징들과 사이클 수, 방전 시간을 다항 차수로 변환하여 새로운 특징들을 만든다. 마지막으로 새로운 특징들은 피어슨 상관관계 파악 및 딤러닝 모델을 통해 성능 평가가 진행된다. 사이클 수, 방전 시간, 계절성, 추세의 다항 차수 변형을 통하여 새로운 특징들을 만들었으며, 만든 특징들은 피어슨 상관관계를 적용하여 SOH와의 상관관계를 파악하였다. 상관관계가 높은 순으로 차수가 3 이하의 값의 특징들의 딤러닝 성능 평가를 진행하였다. 이러한 성능 평가를 통해 특징 F1, F2가 선택되었다. F1과 F2를 포함한 주요 특징들과 SOH와의 피어슨 상관관계는 표 2와 같다. F1, F2의 수식은 식 (9), 식 (10)과 같다. F1은 사이클 수와 방전 시간을 조합한 특징으로 피어슨 상관관계 수치가 0.732521로 SOH와 높은 상관관계가 있는 특징임을 보여준다.

F2는 방전 시간과 사이클 그리고 계절성 데이터를 조합한 특징으로 사이클 수보다 피어슨 상관관계 수치가 높았으며, F2 특징을 선택해 F1과 함께 적용하였을 때 딤러닝 추정 성능을 개선하기 위해 선택되었다.

$$F1 = \frac{(Discharge\ time)^2}{\sqrt{Cycle}} \quad (9)$$

$$F2 = \frac{Discharge\ time * Seasonal}{\sqrt{Cycle}} \quad (10)$$

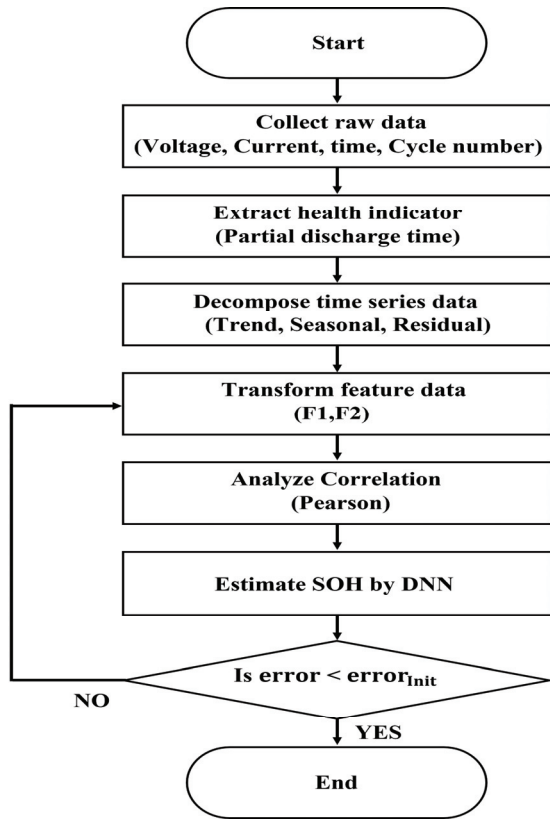


Fig. 4. Flowchart of the proposed SOH estimation process.

TABLE II
CORRELATION ANALYSIS

| Feature | Pearson Correlation |
|----------------|---------------------|
| Cycle number | -0.966700 |
| Discharge time | 0.960149 |
| F1 | 0.732521 |
| F2 | 0.097432 |




Fig. 5. Architecture of a DNN.

4.2 DNN을 통한 SOH 추정


본 논문에서 SOH 추정 모델로 DNN을 사용하였다. DNN은 여러 층의 은닉층을 갖고 있어 학습 과정에서 파라미터의 최적값을 찾을 수 있으며 일반 신경망에서 나타나는 과대 적합의 문제를 보완한 방법이다. 그림 5와 같이 DNN은 입력층(Input layer)과 출력층(Output layer) 사이에 2개 이상의 은닉층을 가진 신경망 모델이다. DNN은 여러 개의 입력을 출력에 매핑하여 학습할 수 있다. 이러한 구조의 DNN은 충분한 연산 층을 가지고 있어 비선형성 함수를 추정하는 데 유용하며, 비선형 데이터인 SOH를 추정하기에 적합하다^[13]. 이러한 장점을 활용하여 본 논문에서는 DNN 모델의 입력 데이터로 Health Indicator인 부분 방전 시간, 특징 추출 기법을 사용하여 만든 특징 F1, F2를 사용하였으며, 해당 특징들을 통해 SOH를 추정하였다. 이를 통해 방전 시간 데이터에 대한 의존성을 줄일 수 있었다. SOH 추정 실험에 이용한 DNN 모델은 64개 뉴런의 Hidden layer 5층으로 구성하였고 활성화 함수는 Rectified Linear Unit(ReLU) 함수로 선정하였다. ReLU는 층이 여러 개로 구성된 딥러닝에서 빠르게 학습될 수 있게 하며 기존의 활성화 함수에서 기울기가 0에 가까워져 없어지는 현상인 기울기 소실 문제가 발생하지 않는다는 장점이 있다^[14].

4.3 DNN을 통한 특징 추출 기법 성능 평가


DNN 모델의 입력으로 방전 시간만 사용하여 SOH 추정했을 경우와 방전 시간과 특징 추출 기법을 통해 만든 F1, F2를 함께 사용하여 추정했을 경우를 함께 비교 실험하여 제안하는 방법의 효과를 확인하였다. 이는 그림 6의 SOH 추정 그래프와 표 3의 SOH 추정 오차를 통해 입증될 수 있다. 그림 6 (a) SOH 추정 그래프는 5 Cycles 주기로 260 Cycles까지 SOH 추정 결과를 나타낸 그래프이다. 그림 6 (a)에서 부분 구간 60 Cycles에서 110 Cycles 추정 결과인 그림 6 (b)를 확인하면, Health Indicator와 F1, F2를 함께 적용했을 때 결과의 그래프가 Health Indicator만 적용한 결과의 그래프보다 더 실제 SOH 값에 가까운 것을 확인할 수 있다. 실험에서는 평가지표로 MAE, MIN, MAX 세 가지 지표를 사용하였다. MAE는 평균 절대오차로 SOH 추정값과 SOH 실제값 차이의 평균값이다. 그리고 MIN, MAX는 각각 전체 추정 결과에서 최소, 최대 오차를 나타낸다. 이러한 평가지표들을 통해 평가된 결과는 표 3에 나타나 있다. MAE 지표는 오차율이 0.6352%에서 0.3887%로 절반 가까이 감소하였으며, MAX 지표에서는 1.605%에서 1.151%로 감소하였다 마지막으로 MIN 지표에서는 0.0186%에서 0.0159%로 감소하였다. 실험 결과를 통해 제안하는 방법을 사용했을 때 SOH 추정 성능이 향상될 수 있음을 입증하였다.

TABLE III
SOH ESTIMATION ERROR RATE

| Used feature | MAE (%) | MAE (%) | MAX (%) |
|--------------------------|---------|---------|---------|
| Health Indicator | 0.6352 | 0.0186 | 1.605 |
| Health Indicator, F1, F2 | 0.3887 | 0.0159 | 1.151 |



(a)



(b)

Fig. 6. SOH estimation results before and after using the proposed method (a) estimated results of 1~260 cycles. (b) estimated results of 60~110 cycles.

5. 결 론

본 논문에서는 특징 추출 기법을 적용한 리튬이온 배터리 SOH 추정 방법을 제안하였다. SOH는 리튬 이온 배터리의 수명의 정보를 가지고 있는 지표로 배터리 관리 시스템에서 배터리 교체 시점을 파악하는데 필수적인 지표이다. 일반적으로 데이터 기반 SOH 추정 기법은 Health Indicator 데이터로 배터리 방전 사이클에서 추출한 내부 저항값과 용량, 방전 시간 등을 사용한다. 하지만 방전 시간 대비 저항과 용량 측정을 위해서는 정밀한 측정 장비를 사용하는 실험이 필요하므로 데이터 취득 비용과 시간이 많이 든다. 본 논문에서는 방전 시간 데이터에서 시계열 특징 추출 및 다항 차수 변환을 이용하여 데이터 기반 모델에서 SOH 추정 시 성능 개선할 수 있는 새로운 특징을 생성하였으며, 해당 데이터에서 SOH 추정과 연관성이 높은 특징을 선택하였다.

해당 방법의 적용을 통해 추가 Health Indicator 데이터 확보 과정 없이 SOH 추정 성능을 개선할 수 있음을 DNN 모델을 활용하여 확인하였다. 실험 결과로 MAE, MAX, MIN 지표에서 성능 향상을 보였으며, 특히 MAE에서는 오차율이 0.6352%에서 0.3887%로 크게 감소하였다. 이를 통해 제안하는 딥러닝과 특징 추출 기반 배터리 SOH 추정 방법의 우수성을 입증하였다. 추가로 방전 전류가 변하는 환경에서도 본 논문에서 제안하는 방법을 적용할 수 있다. 해당 환경에서는 정전류(CC) 충전 구간에서 특정 전압 구간의 충전 시간을 Health Indicator로 사용한다면 제안하는 딥러닝과 특징 추출 기반 배터리 노화 상태 추정 방법을 적용할 수 있다. 이러한 과정을 통해 충전 과정 중에도 추가 데이터 확보 과정 없이도 SOH 추정 성능을 개선할 수 있을 것이다.

본 연구는 2022년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원에 의한 연구임. (20011626)

References

- [1] X. Han, M. Ouyang, L. Lu, J. Li, Y. Zheng, and Z. Li, "A comparative study of commercial lithium ion battery cycle life in electrical vehicle: Aging mechanism identification," *J. Power Sources*, Vol. 251, pp. 38-54, Apr. 2014.
- [2] Wei Liu, Yan Xu "Data-driven online health estimation of li-ion batteries using a novel energy-based health indicator," *IEEE Trans. Energy Convers.*, Vol. 35, No. 3, pp. 1715-1718, Sep. 2020.
- [3] Z. Guo, X. Qiu, G. Hou, B. Liaw, and C. Zhang, "State of health estimation for lithium ion batteries based on charging curves," *J. Power Sources*, Vol. 249, pp. 457-462, Mar. 2014.
- [4] Z. Chen, M. Sun, X. Shu, R. Xiao, and J. Shen, "Online state of health estimation for lithium-ion batteries based on support vector machine," *Appl. Sci.*, Vol. 8, No. 6, pp. 925, Jun. 2018.
- [5] Y. Wu, Q. Xue, J. Shen, Z. Lei, Z. Chen, and Y. Liu, "State of health estimation for lithium-ion batteries based on healthy features and long short-term memory," *IEEE Access*, Vol. 8, pp. 28533-28547, 2020.
- [6] D. Yang, X. Zhang, R. Pan, Y. Wang, and Z. Chen, "A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve," *J. Power Sources*, Vol. 384, pp. 387-395, Apr. 2018.
- [7] S. Cui and I. Joe, "A dynamic spatial-temporal attention-based GRU model with healthy features for state-of-health estimation of lithium-ion batteries," *IEEE Access*, Vol. 9, pp. 27374-27388, 2021.
- [8] P. Khumprom and N. Yodo, "A data-driven predictive pro


gnostic model for lithium-ion batteries based on a deep learning algorithm,” *Energies*, Vol. 12, No. 4, pp. 660, Feb. 2019.

- [9] Y. Deng, H. Ying, J. E. H. Zhu, K. Wei, J. Chen, F. Zhang, and G. Liao, “Feature parameter extraction and intelligent estimation of the state-of-health of lithium-ion batteries,” *Energy*, Vol. 176, pp. 91-102, Jun. 2019.
- [10] X. Li, Z. Wang, and J. Yan, “Prognostic health condition for lithium battery using the partial incremental capacity and gaussian process regression,” *J. Power Sources*, Vol. 421, pp. 56-67, May 2019.
- [11] W. Liu, Y. Xu, and X. Feng, “A hierarchical and flexible data driven method for online state-of-health estimation of li-ion battery,” *IEEE Trans. Veh. Technol.*, Vol. 69, No. 12, pp. 14739-14748, 2020.
- [12] D. Liu, H. Wang, Y. Peng, W. Xie, and H. Liao, “Satellite lithium-ion battery remaining cycle life prediction with novel indirect health indicator extraction,” *Energies*, Vol. 6, No. 8, pp. 3654-3668, Jul. 2013.
- [13] D.N.T. How, M.A. Hannan, M.S.H. Lipu, K.S.M. Sahari, P.J. Ker, K.M. Muttaqi, “State-of-charge estimation of li-ion battery in electric vehicles: A deep neural network approach,” *IEEE Trans. Ind. Appl.*, Vol. 56, No. 5, pp. 5565-5574, Sep. 2020.
- [14] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Proc. NIPS*, pp. 1097-1105, 2012.



장문석(張文碩)

2018년 홍익대 전자전기공학부 졸업. 2022년 한양대 전기공학과 졸업(석사).



이강석(李康碩)

2013년 한양대 전기제어 공학과 졸업. 2013년~현재 동 대학원 전기공학과 석박사통합 과정.



배성우(裵晟佑)

2006년 한양대 전자전기컴퓨터공학부 졸업. 2009년 미국 Univ. of Texas at Austin 전기공학과 졸업(석사). 2011년 동 대학원 전기공학과 졸업(공박). 2012년~2013년 삼성전자 종합기술원 책임연구원. 2017년~현재 한양대 전기공학과 부교수. 당 학회 학술위원.