

## LSTM 모델 기반 리튬이온 배터리의 SOH 예측

고하나<sup>1</sup> · 이솔비<sup>2</sup> · 김의직<sup>3\*</sup>

<sup>1</sup>한림대학교 소프트웨어융합대학 학사과정

<sup>2</sup>한림대학교 융합소프트웨어학과 석박사통합과정

<sup>3\*</sup>한림대학교 소프트웨어융합대학 부교수

## LSTM Model-Based SOH Prediction for Lithium-Ion Battery

Ha-Na Go<sup>1</sup> · Sol-Bee Lee<sup>2</sup> · Eui-Jik Kim<sup>3\*</sup>

<sup>1</sup>B.S. Course, School of Software, Hallym University, Chuncheon, Korea

<sup>2</sup>Integrated M.S. and Ph.D. Course, Department of Convergence Software, Hallym University, Chuncheon, Korea

<sup>3\*</sup>Associate Professor, School of Software, Hallym University, Chuncheon, Korea

### [요 약]

리튬이온 배터리는 높은 에너지 밀도, 높은 출력 밀도, 긴 수명 등의 장점으로 인해 다양한 분야에서 사용되고 있다. 그러나, 리튬이온 배터리는 안전성 문제 및 빈번한 충·방전으로 인한 배터리 성능 저하 문제를 가지고 있다. 이에 따라, 배터리의 수명 예측이 필수적으로 요구된다. 따라서, 본 논문에서는 장단기 기억 신경망 (Long Short-Term Memory, LSTM) 모델 기반의 리튬이온 배터리의 수명상태 (State of Health, SOH) 예측 모델을 제안한다. 제안하는 모델은 Feature Selection, Data Extraction, Normalization, LSTM Prediction의 네 가지 단계를 통해, 리튬이온 배터리의 SOH 예측을 수행한다. 제안하는 모델의 우수성을 입증하기 위해 SOH 예측 실험을 수행하고, 제안하는 모델의 성능을 Recurrent Neural Network (RNN) 기반 모델의 성능과 비교하였다. 그 결과, 제안하는 모델이 RNN 기반 모델보다 평균적으로 28.07% 더 높은 SOH 예측 정확도를 보였다.

### [Abstract]

Lithium-ion batteries are used in various fields due to their advantages such as high energy density, high power density, and long lifetime. However, lithium-ion batteries have safety issues and battery degradation problems due to frequent charging and discharging. Accordingly, it is essential to predict the battery lifetime. Therefore, in this paper, we present a Long Short-Term Memory (LSTM) model-based State of Health (SOH) prediction model for lithium-ion battery. The proposed model performs the SOH prediction for lithium-ion batteries through four steps: Feature Selection, Data Extraction, Normalization, and LSTM Prediction. To verify the superiority of the proposed model, we conducted the SOH prediction experiments and compared the performance of the proposed model with that of the Recurrent Neural Network (RNN)-based model. The results showed that the proposed model was 28.07% higher on average than the RNN-based model in terms of SOH prediction accuracy.

**색인어** : 인공신경망, 리튬이온 배터리, 장단기 기억 신경망, 예측 모델, 수명 상태

**Key word** : Artificial neural network, Lithium-ion battery, Long short-term memory, Prediction model, State of health

<http://dx.doi.org/10.9728/dcs.2021.22.4.697>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 04 March 2021; Revised 24 March 2021

Accepted 24 March 2021

\*Corresponding Author; Eui-Jik Kim

Tel: +82-33-248-2333

E-mail: ejkim32@hallym.ac.kr

## I. 서론

리튬이온 배터리는 물리화학적 특성으로 인해 배터리의 수명을 최대화할 수 있는 충·방전이 가능한 배터리로, 사물인터넷 (Internet of Things, IoT) 기기 및 스마트폰과 같은 소형 시스템에서 자동차 및 에너지 저장 시스템과 같은 대용량 시스템에 이르기까지 다양한 분야에서 사용되고 있다 [1]. 이러한 리튬이온 배터리는 높은 에너지 밀도, 높은 출력 밀도, 긴 수명 등의 장점을 제공한다. 그러나, 폭발과 같은 안전성 문제와 외부 환경의 온도 및 충·방전의 반복을 통한 열화 현상으로 인한 배터리 수명 단축 등의 문제가 있다 [2]. 이로 인해, 배터리 상태 추정 지표로 활용한 정확한 배터리 수명 예측이 필수적으로 요구된다. 이를 위해, 현재 배터리의 충전 상태를 나타내는 State of Charge (SOC)와 배터리의 수명을 나타내는 State of Health (SOH)가 대표적인 배터리 상태 추정 지표로 사용된다.

리튬이온 배터리의 안전성 확보 및 성능 향상을 위한 연구를 통해 다양한 배터리 수명 예측 모델이 제안되었다 [3]-[8]. 이러한 배터리 수명 예측 모델은 배터리의 물리화학적 원리를 분석하고 수학적 및 물리적 모델링을 통해 리튬이온 배터리의 열화 과정을 특성화하는 모델 기반 방법과 배터리 열화 관련 데이터 분석을 통해 배터리의 수명을 예측하는 데이터 기반 방법으로 분류되어 연구되고 있다. 그러나, 기존에 제안된 모델들은 배터리 수명에 영향을 미치는 배터리 충·방전 시 내부 온도를 고려하지 않았다.

본 논문에서는 인공신경망 (Artificial Neural Network, ANN) 기법 중 하나인 장단기 기억 신경망 (Long Short-Term Memory, LSTM) 기반의 리튬이온 배터리의 SOH 예측 모델을 제안한다. 이를 위해, 리튬이온 배터리의 충전 프로파일 데이터로부터 충전 시 전압, 전류, 온도와 방전 시 전압, 전류, 온도, 용량 데이터와 같은 열화 관련 파라미터 추출을 통해 구성된 데이터셋과 오픈소스 라이브러리인 텐서플로우 (Tensorflow)와 케라스 (Keras)로 구현한 LSTM을 사용하여 SOH 예측 모델을 구현한다. 제안하는 모델의 성능을 검증하기 위해 순환신경망 (Recurrent Neural Network, RNN) 기반 리튬이온 배터리 SOH 예측 모델의 성능과 비교하였다.

본 논문은 다음과 같이 구성된다. 2장에서는 리튬이온 배터리의 수명 예측에 대한 관련 연구를 설명한다. 3장에서는 제안하는 LSTM 기반 리튬이온 배터리 수명 예측 모델에 대해 설명한다. 4장에서는 실험을 통해 제안하는 LSTM 기반 리튬이온 배터리 SOH 예측 모델 및 RNN 기반 리튬이온 배터리 SOH 예측 모델의 성능 평가를 수행한다. 마지막으로, 5장에서 결론을 맺는다.

## II. 관련 연구

### 2-1 모델 기반 방법

리튬이온 배터리의 물리화학적 원리 분석 및 모델 설정을 통해 배터리 수명 예측을 위한 다양한 모델 기반 방법이 연구되었다. 논문 [3]에서, 저자는 Kalman Filter를 이용하여 리튬이온 배터리의 SOC와 SOH를 동시에 예측하는 프레임워크를 제안하였다. 논문 [4]에서, 저자는 Particle Filter를 이용하여 리튬이온 배터리의 SOC와 방전 시간을 예측하는 프레임워크를 제안하였다. 논문 [5]에서, 저자는 리튬이온 배터리의 남은 수명을 예측하기 위해 Kalman Filter와 Particle Swarm Optimization (PSO) 알고리즘을 결합한 새로운 Particle Filtering 기반 방법을 제안하였다. 위와 같이, Kalman Filter 및 Particle Filter를 사용한 리튬이온 배터리의 수명 예측은 온도 및 습도와 같은 외부 환경에 의한 노이즈에 취약하기 때문에 정확하게 예측하는데 한계가 있다. 또한, 모델 기반 방법은 배터리의 물리화학적 특성을 고려한 모델의 구현을 반드시 필요로 한다는 단점이 있다. 이러한 단점을 극복하기 위해, 기계학습을 활용한 데이터 기반 방법이 주목받고 있다.

### 2-2 데이터 기반 방법

기계학습 기반의 리튬이온 배터리 열화 관련 데이터 분석을 통해 배터리 수명을 예측하는 다양한 데이터 기반 방법이 연구되었다. 논문 [6]에서, 저자는 Auto-Regressive Integrated Moving Average (ARIMA) 기반의 차량용 리튬이온 배터리의 SOH 예측 모델을 제안하였다. 이러한 ARIMA 기반 예측 모델의 경우, 예측 범위가 길어질수록 동일한 패턴을 반복한다는 단점이 있다. 논문 [7]에서, 저자는 RNN을 사용하여 리튬이온 배터리의 SOC와 SOH를 예측하는 프레임워크를 제안하였다. 그러나 RNN을 사용하는 모델의 경우, 입력 데이터의 범위가 증가하면 과거의 데이터가 소실되는 문제를 피할 수 없다. 논문 [8]에서, 저자는 LSTM 모델을 사용하여 배터리의 전기적 특성을 고려한 리튬이온 배터리의 수명 예측 모델을 제안하였다. 하지만, 배터리 수명 예측에 있어 배터리의 내부 온도가 미치는 영향을 고려하지 않았다.

배터리 수명 예측을 위해 시계열 형태의 배터리 열화 관련 데이터를 사용함에 따라, 많은 데이터 기반 모델 연구에서 순환 구조를 사용하여 반복적이고 순차적인 데이터 학습에 특화된 RNN 및 LSTM이 사용되었다. RNN은 Hidden Layer를 사용하여 과거의 데이터를 기억해 미래의 결과에 영향을 주는 순환 구조로, 과거의 출력 값과 현재의 입력 값을 합한 값을 단일 Tanh Layer에 전달하여 Cell State를 업데이트함으로써 얻어진 결과 값을 출력한다. RNN은 입력된 데이터 시퀀스의 길이에 따라 다른 결과를 출력한다. 이러한 이유로, Input Layer를 통해 입력된 데이터 시퀀스의 길이가 길어지면 과거의 데이터가 소실되는 Vanishing Gradient Problem이 발생한다. LSTM은 RNN의 Vanishing Gradient Problem을 개선한 모델로, 기존 RNN의 Hidden State 내 메모리 셀에 Input Gate, Output Gate, Forget Gate를 추가한 모델이다. 구체적으로, Forget Gate의 Sigmoid Layer는 과거의 출력 값과 현재의 입력 값을 지우거나 보존할

지 결정한다. 이후, Input Gate에서는 Sigmoid 함수와 Tanh 함수를 통해 얻은 결과 값을 합하여 Cell State를 업데이트할 값을 생성한다. 마지막으로, Forget Gate와 Input Gate에서 얻은 값을 사용하여 Cell State를 업데이트하고, Output Gate에서 Sigmoid 함수의 결과 값과 Cell State의 Tanh 함수의 결과 값을 곱하여 Output Layer를 통해 출력한다. 위의 과정을 통해, LSTM은 과거의 정보를 더 오래 기억할 수 있기 때문에 RNN보다 우수한 성능을 보인다.

### III. 리튬이온 배터리 SOH 예측 모델

본 논문에서는 LSTM 기반의 리튬이온 배터리 SOH 예측 모델을 제안한다. 그림 1은 LSTM 기반 리튬이온 배터리 SOH 예측 모델의 파이프라인을 보여준다. 제안하는 모델의 파이프라인은 Feature Selection, Data Extraction, Normalization, LSTM Prediction의 네 가지 단계로 구성된다. Feature Selection에서는 데이터셋으로부터 SOH 예측을 위해 필요한 세 가지 Feature인 전압, 전류, 온도를 선택한다. 이후, Feature Selection을 통해 선택된 Feature에 대한 Data Extraction을 수행한다. 이를 위해, 선택된 각 Feature에 대해 동일한 시간 범위에 해당하는 20개의 샘플 데이터를 사용하여 60차원의 벡터를 구성한다. Normalization에서는 Data Extraction으로부터 생성된 벡터의 값을 정규화하는 과정을 수행한다. 이는 모델의 학습 과정에서 입력 값으로 사용되는 벡터 값 간의 큰 차이나 단위의 차이로 인한 모델의 성능 저하를 방지하기 위함이다. 벡터의 모든 값을 0~1 사이의 값으로 정규화하기 위해 식 (1)의 MinMaxScaler를 사용한다.

$$x = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

$x$ 는 벡터의 데이터를 나타내고,  $x_{\min}$  및  $x_{\max}$ 는  $x$ 에 해당하는 Feature의 최소값과 최대값을 나타낸다. LSTM Prediction에서는 앞의 전처리 과정을 통해 구성된 벡터를 입력 값으로 사용하여 SOH 예측을 수행한다. 그림 2는 LSTM 모델 구조를 보여준다. 그림에서  $X_t$ 는 Input Layer,  $h_t$ 는 Output Layer, LSTM Hidden Layer는 0~1 사이의 값을 반환하는 sigmoid ( $\sigma$ ) 및 -1~1 사이의 값을 반환하는 Tanh 함수를 포함하는 Input Gate, Output Gate, Forget Gate를 사용하여 결과 값을 도출하는 Layer를 의미한다. 이러한 LSTM 모델은 입력 값을 Hidden Layer로 전달하여 Hidden State를 업데이트 하고 SOH 예측 결과 값을 출력한다. 이후, 순차적으로 들어오는 입력 값을 통해 지속적으로 업데이트된 LSTM 모델은 높은 정확도의 SOH 예측 결과 값을 출력한다.

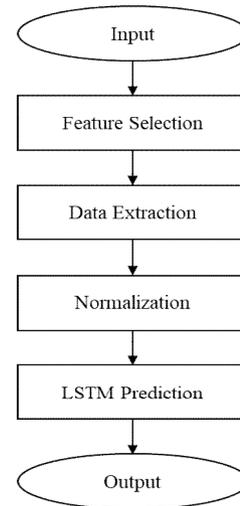


그림 1. LSTM 기반 리튬이온 배터리 SOH 예측 모델  
Fig. 1. LSTM Model-based SOH Prediction Model for Lithium-ion Battery

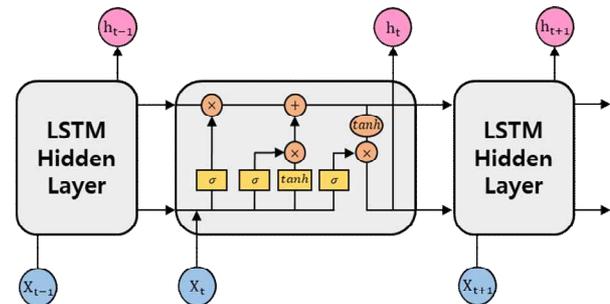


그림 2. LSTM 모델 구조  
Fig. 2. Structure of LSTM Model

### IV. 실험 및 결과

본 장에서는 LSTM 기반의 리튬이온 배터리 SOH 예측 모델을 구현하고, 실험에 사용한 데이터셋, 실험 환경, 실험 결과에 대해 설명한다.

#### 4-1 NASA의 리튬이온 배터리 데이터셋

본 논문에서는 리튬이온 배터리의 SOH 예측 실험을 위해 NASA에서 제공하는 총 6개의 리튬이온 배터리 데이터셋 중에서 첫 번째 데이터셋을 사용한다 [9]. 해당 데이터셋은 총 4개의 리튬이온 배터리 (5, 6, 7, 18번 리튬이온 배터리) 각각을 충·방전시킴으로써 얻어진 데이터로 구성된다. 구체적으로, 각 리튬이온 배터리에 대해 전압이 4.2V에 도달할 때까지 전압을 변화시켜 1.5A의 전류를 유지하도록 하는 정전류 (Constant Current, CC) 모드로 충전을 수행하고, 충전 전류가 20mA로 떨어질 때까지 전류를 변화시켜 전압을 유지하는 정전압 (Constant Voltage, CV) 모드로 충전을 지속한다. 이후, 2A의 정전류를 사

용하여 각 리튬이온 배터리에 대해 전압이 각각 2V, 2.2V, 2.5V, 2.7V에 도달할 때까지 방전시킴으로써 얻어진 데이터를 사용한다. 해당 데이터셋은 충전 시 전압 (V), 전류 (A), 온도 (°C)와 방전 시 전압, 전류, 온도, 용량 (Ah) 데이터로 구성된다. 데이터셋은 168 사이클로 구성된다. 우리는 리튬이온 배터리의 SOH 예측 실험을 위해 4개의 리튬이온 배터리 데이터셋 중에서 5번 리튬이온 배터리 데이터셋의 충전 시 전압, 전류, 온도 데이터를 사용한다. 표 1은 5번 리튬이온 배터리의 사양을 나타낸다. 제안하는 모델의 학습을 위해 방전 시 용량 데이터를 사용하여 SOH를 계산하였다. SOH는 식 (2)로 정의된다 [10].  $C_0$ 와  $C_n$ 은 리튬이온 배터리의 초기 방전 용량 및 n 번째 사이클에서의 방전 용량을 나타낸다. 일반적으로, 방전 용량이 초기 값 대비 70% 이하로 낮아지면 더 이상 해당 배터리를 사용할 수 없다고 판단한다 [11]. 이에 따라, 배터리의 수명 임계 용량 (End-off-Life, EOL)을 의미하는  $C_{EOL}$ 은 식 (3)으로 정의된다.

$$SOH(\%) = \frac{C_n - C_{EOL}}{C_0 - C_{EOL}} \times 100(\%) \quad (2)$$

$$C_{EOL} = C_n \times 0.7 \quad (3)$$

그림 3은 사이클 변화에 따른 CC-CV 충전 전압 곡선을 보여준다. 리튬이온 배터리의 사이클이 증가함에 따라, CC 충전 시간은 감소하고, CV 충전 시간은 증가하는 경향을 보였다. CC 충전 시간은 리튬이온 배터리의 전압이 4.2V에 도달할 때까지 충전에 소요된 시간을 의미하고, CV 충전 시간은 리튬이온 배터리의 전압이 4.2V에 도달한 이후부터 배터리의 전류가 0에 도달하는 데까지 소요된 시간을 의미한다. 그림 4는 사이클 변화에 따른 CC-CV 충전 전류 곡선을 보여준다. 사이클의 변화와 관계없이 시간이 증가함에 따라 리튬이온 배터리의 초기 전류 값은 그대로 유지되다가 감소하는 경향을 보였다. 이는 CC 충전 모드에서 리튬이온 배터리의 전압이 상한전압에 도달한 이후, CV 충전 모드로 전환되어 일정한 전압 유지를 통해 전류를 0에 가까운 값으로 떨어뜨리며 충전을 수행하기 때문이다.

표 1. 5번 리튬이온 배터리 사양

Table 1. Lithium-ion Battery #5 Specification

Profile	Item	Specification
Charge Profile	Constant Current	1.5A
	Voltage Limit	4.2V
	Cut-off Current	20mA
Discharge Profile	Constant Current	2A
	Cut-off Voltage	2.7V
Operating Condition	Initial Capacity	1.86Ah
	Temperature	Room Temperature
	EOL	1.4Ah

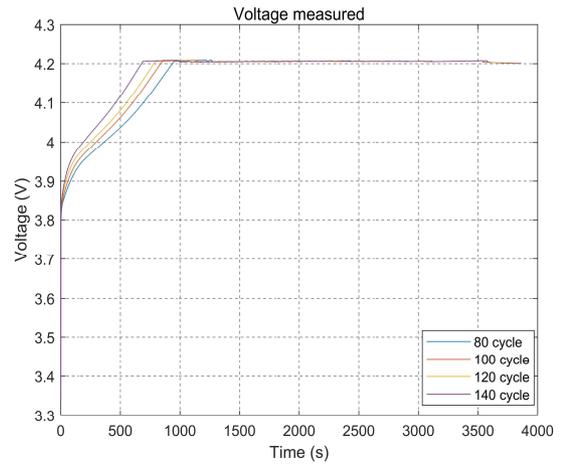


그림 3. 사이클 변화에 따른 CC-CV 충전 전압 곡선  
Fig. 3. CC-CV Charging Voltage Curve for Various Cycle

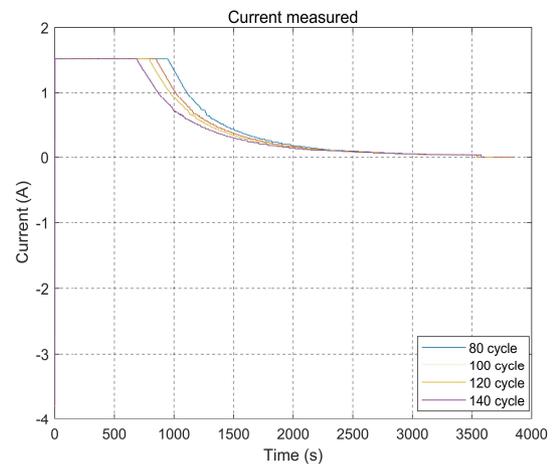


그림 4. 사이클 변화에 따른 CC-CV 충전 전류 곡선  
Fig. 4. CC-CV Charging Current Curve for Various Cycle

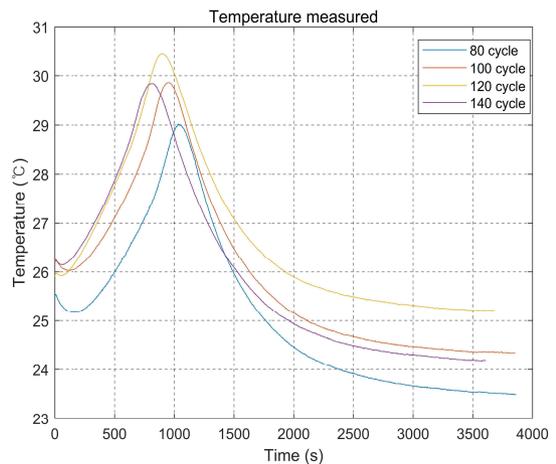


그림 5. 사이클 변화에 따른 CC-CV 충전 온도 곡선  
Fig. 5. CC-CV Charging Temperature Curve of Various Cycle

그림 5는 사이클 변화에 따른 CC-CV 충전 온도 곡선을 보여 준다. 리튬이온 배터리의 온도는 사이클과 관계없이 시간이 지남에 따라 감소하다가 특정 시점 이후 급격하게 증가하는 경향을 보였다. 이는 충전으로 인해 발생하는 열화 현상으로 리튬이온 배터리의 온도가 증가하기 때문이다. 이후, 리튬이온 배터리의 온도가 다시 감소하는 현상을 보였다. 이는 CC 충전이 완료되고 나서 CV 충전이 시작되는 시점부터는 전압의 변화가 발생되지 않음으로써 온도가 감소하기 때문이다.

#### 4-2 실험 환경

LSTM 기반 리튬이온 배터리의 SOH 예측 모델을 구현하기 Python과 오픈소스 라이브러리인 Tensorflow와 Keras를 사용하여 LSTM 모델을 구현하였다. 제안하는 모델을 위해 사용된 하이퍼 파라미터는 표 2와 같다. 실험을 위해 사용되는 LSTM 은 100개의 Hidden State로 구성되며, 설정된 Epoch 및 Batch Size 값에 따라 200회 반복 학습을 수행하고, 한 번의 Batch 마다 5개의 데이터를 전달한다. 또한, Patience를 10으로 설정하여 성능이 더 이상 증가하지 않는 Epoch가 10을 넘으면 학습을 중단하도록 설정하였다. 실험은 전체 데이터셋의 80~140 사이클 범위 내에서 사이클을 20 씩 증가시켜가며 수행되었다. 제안하는 모델의 성능 평가를 위해 RNN 기반 모델과 SOH 예측 성능을 비교하였다. 모델의 예측 성능을 평가하기 위해 Root Mean Square Error (RMSE)를 사용하였다. RMSE는 실제 데이터와 예측 데이터 간의 오차를 의미하며, 값이 0에 가까울수록 예측 성능이 우수함을 나타낸다. 따라서, RMSE를 모델의 예측 성능을 평가하는 지표로 사용하였으며, RMSE는 식 (4)로 정의된다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

여기에서  $n$ 은 데이터 차원의 수를 나타내고,  $i$ 는 데이터 차원 내 데이터의 인덱스 번호를 나타낸다.  $y_i$ 는 실제 SOH를 나타내며,  $\hat{y}_i$ 는 모델을 통해 예측된 SOH를 나타낸다.

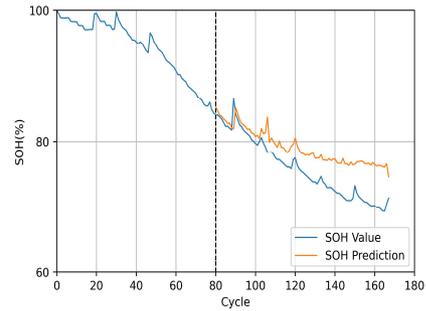
표 2. LSTM 모델의 하이퍼 파라미터

Table 2. Hyperparameters for LSTM Model

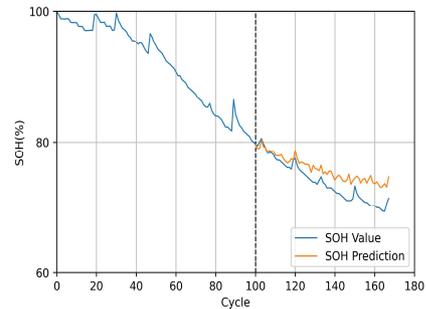
Hidden State	Epoch	Batch Size	Patience
100	200	5	10

#### 4-3 실험 결과

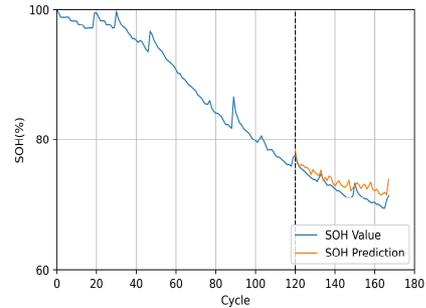
그림 6과 그림 7 각각은 학습 데이터셋 크기 변화에 따른 LSTM 기반 모델 및 RNN 기반 모델의 SOH 예측 값 및 실제 값을 보여준다. LSTM 기반 모델 및 RNN 기반 모델은 학습 데이터셋의 크기가 증가함에 따라 실제 SOH 값에 대한 예측 SOH 값의 오차가 감소하는 경향을 보였다. 두 모델의 SOH 예측 오차를 비교한 결과, LSTM 기반 모델이 RNN 기반 모델보다 더 작은 SOH 예측 오차를 보였다.



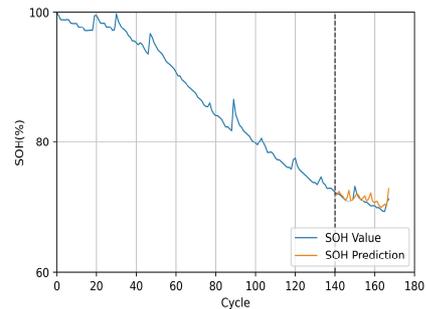
(a)



(b)



(c)



(d)

그림 6. 학습 데이터셋 크기 변화에 따른 LSTM 기반 모델의 SOH 예측 결과: (a) 80 사이클; (b) 100 사이클; (c) 120 사이클; (d) 140 사이클

Fig. 6. SOH Prediction Results of LSTM-based Model for Various Size of Training Dataset: (a) 80 Cycles; (b) 100 Cycles; (c) 120 Cycles; (d) 140 Cycles

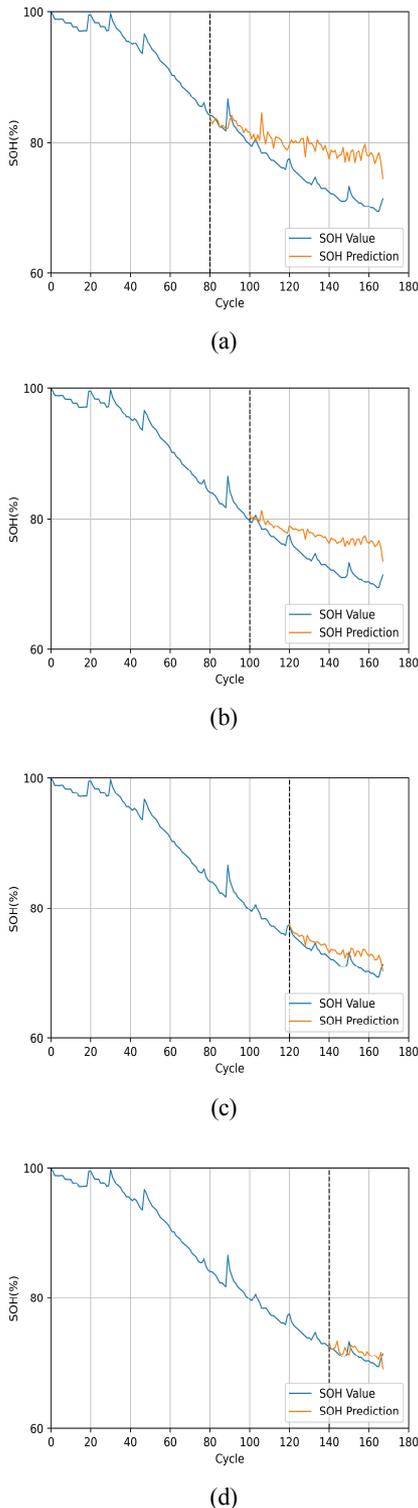


그림 7. 학습 데이터셋 크기 변화에 따른 RNN 기반 모델의 SOH 예측 결과: (a) 80 사이클; (b) 100 사이클; (c) 120 사이클; (d) 140 사이클

Fig. 7. SOH Prediction Results of RNN-based Model for Various Size of Training Dataset: (a) 80 Cycles; (b) 100 Cycles; (c) 120 Cycles; (d) 140 Cycles

표 3. 학습 데이터셋 크기 변화에 따른 LSTM 기반 모델 및 RNN 기반 모델의 SOH 예측 정확도 (RMSE)

Table 3. SOH Prediction Accuracy of LSTM and RNN-based Model for Various Size of Training Dataset

	80 Cycles	100 Cycles	120 Cycles	140 Cycles
LSTM	0.1251	0.0752	0.0491	0.0270
RNN	0.1653	0.1334	0.0598	0.0367

구체적으로, 표 3은 LSTM 기반 모델과 RNN 기반 모델의 SOH 예측 오차를 보여준다. 이 때, SOH 예측 오차는 RMSE를 통해 도출되었다. 사용 모델과 관계없이 학습 데이터셋의 크기가 증가함에 따라 예측 오차가 0에 가까워지는 경향을 보였다. 결과적으로, LSTM 기반 모델이 RNN 기반 모델보다 더 낮은 예측 오차를 보였다.

### V. 결론

본 논문에서는 리튬이온 배터리의 수명을 예측하기 위해 LSTM 기반 리튬이온 배터리의 SOH 예측 모델을 제안하였다. 리튬이온 배터리의 SOH 예측은 Feature Selection, Data Extraction, Normalization, LSTM Prediction의 네 가지 단계를 따라 수행된다. 제안하는 모델은 Python과 오픈소스 라이브러리인 Tensorflow와 Keras를 사용하여 구현되었다. 제안하는 모델의 성능 평가를 위해 NASA의 리튬이온 배터리 데이터셋의 충전 프로파일 데이터인 전압, 전류, 온도 데이터를 사용하였다. 구성된 데이터셋에서 학습 데이터셋의 크기를 20 사이클씩 증가시켜가며 학습 데이터셋의 크기 변화에 따른 LSTM 기반 모델의 예측 성능을 측정하고, RNN 기반 모델의 예측 오차 측정 결과와 비교하였다. 학습 데이터셋의 크기 변화에 따른 SOH 예측 오차의 비교를 통해 LSTM 기반 모델의 SOH 예측 성능이 RNN 기반 모델보다 평균적으로 28.07% 더 우수함을 검증하였다.

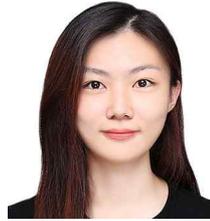
### 감사의 글

이 논문은 2020년도 정부 (교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (NRF-2020R111A3052733).

### 참고문헌

[1] S. W. Yang, N. Y. Kim, E. S. Kim, M. H. Lim, J. N. Park, J. H. Song, S. H. Park, W. A. Appiah, M. H. Ryou, and Y. M. Lee, "A Review on Electrochemical Model for Predicting the Performance of Lithium Secondary Battery," Journal of the Korean Electrochemical Society, Vol. 22, No. 1, pp. 43-52, Feb. 2019.

- [2] P. Lee, S. Kwon, D. Kang, S. Han, and J. Kim, "SOH Estimation and Feature Extraction using Principal Component Analysis based on Health Indicator for High Energy Battery Pack," The Korean Institute of Power Electronics (KIPE), Vol. 25, No. 5, pp. 376-384, Oct. 2020.
- [3] P. A. Topan, M. N. Ramadan, G. Fathoni, A. I. Cahyadi, and O. Wahyunggoro, "State of Charge (SOC) and State of Health (SOH) estimation on lithium polymer battery via Kalman filter," 2016 2nd International Conference on Science and Technology-Computer (ICST), Yogyakarta, pp. 93-96, 2016.
- [4] D. A. Pola, H. F. Navarrete, M. E. Orchard, R. S. Rabié, M. A. Cerda, B. E. Olivares, J. F. Silva, P. A. Espinoza, and A. Pérez, "Particle-Filtering-Based Discharge Time Prognosis for Lithium-Ion Batteries With a Statistical Characterization of Use Profiles," IEEE Transactions on Reliability, Vol.64, No.2, pp.710-720, Jun. 2015.
- [5] B. Mo, J. Yu, D. Tang, H. Liu, and J. Yu, "A remaining useful life prediction approach for lithium-ion batteries using Kalman filter and an improved particle filter," 2016 IEEE International Conference on Prognostics and Health Management (ICPHM), Ottawa, ON, pp. 1-5, Jun. 2016.
- [6] S. Shen, S. Ci, K. Zhang, and X. Liang, "Lifecycle Prediction of Second Use Electric Vehicle Batteries Based on ARIMA Model," 2019 IEEE Globecom Workshops (GC Wkshps), Waikoloa, HI, USA, pp. 1-6, Dec. 2019.
- [7] H. Chaoui and C. C. Ibe-Ekeocha, "State of Charge and State of Health Estimation for Lithium Batteries Using Recurrent Neural Networks," IEEE Transactions on Vehicular Technology, Vol. 66, No. 10, pp. 8773-8783, Oct. 2017.
- [8] S. U. Kwon, D. H. Han, S. Y Park, and J. H. Kim, "Long Short Term Memory-Based State-of-Health Prediction Algorithm of a Rechargeable Lithium-Ion Battery for Electric Vehicle," The Transactions of The Korean Institute of Electrical Engineers, Vol. 68, No. 10, pp. 1214-1221, Oct. 2019.
- [9] NASA Ames Research Center. Battery Data Set. Available: <http://ti.arc.nasa.gov/project/prognostic-data-repository>.
- [10] A. Nuhic, T. Terzimehic, T. Soczka-Guth, M. Buchholz, and K. Dietmayer, "Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods," Journal of Power Sources, Vol. 239, pp. 680-688, Oct. 2013.
- [11] C. Kupper, B. Weißhar, S. Reißmann, and W. G. Bessler, "End-of-Life Prediction of a Lithium-Ion Battery Cell Based on Mechanistic Aging Models of the Graphite Electrode," Journal of The Electrochemical Society, Vol. 165, No. 14, Nov. 2018.

**고하나(Ha-Na Go)**

2017년~현 재: 한림대학교 소프트웨어  
융합대학 학사과정

2017년~현 재: 한림대학교 소프트웨어융합대학 학사과정  
※ 관심분야 : 사물인터넷(IoT), 기계학습(Machine Learning),  
임베디드 시스템(Embedded System) 등

**이솔비(Sol-Bee Lee)**

2018년: 한림대학교 융합소프트웨어  
학과(공학사)

2018년~현 재: 한림대학교 융합소프트  
웨어학과 석박사통합  
과정

2018년: 한림대학교 융합소프트웨어학과(공학사)

2018년~현 재: 한림대학교 융합소프트웨어학과  
석박사통합과정

※ 관심분야 : 사물인터넷(IoT), 기계학습(Machine Learning),  
임베디드 시스템(Embedded System) 등

**김의직(Eui-Jik Kim)**

2004년: 고려대학교 전기전자전파공학부  
(공학사)

2006년: 고려대학교 전자컴퓨터공학과  
(공학석사)

2013년: 고려대학교 전기전자전파공학과  
(공학박사)

2005년: 인텔 코리아 R&D센터

2006년~2009년: 삼성전자 DMC연구소

2009년~2013년: KT 융합기술원

2013년~현 재: 한림대학교 소프트웨어융합대학 부교수

※ 관심분야 : 사물인터넷(IoT), 기계학습(Machine Learning),  
임베디드 시스템(Embedded System) 등