



리튬이온배터리와 슈퍼커패시터를 하이브리드한 에너지 팩을 위한 LSTM 기반 SOC 예측 연구

박진석¹⁾ · 임완수^{*2)}

금오공과대학교 전자공학부¹⁾ · 성균관대학교 전자전기공학부²⁾

LSTM-Based SOC Estimation for Hybrid Energy Pack Combining Li-ion Battery and Supercapacitor

Jinseok Park¹⁾ · Wansu Lim^{*2)}

¹⁾School of Electronic Engineering, Kumoh National Institute of Technology, Gyeongbuk 39177, Korea

²⁾School of Electronic and Electrical Engineering Sungkyunkwan University, Gyeonggi 16419, Korea

(Received 31 January 2024 / Revised 12 June 2024 / Accepted 15 June 2024)

Abstract : A hybrid energy pack combines lithium-ion batteries and supercapacitors to meet high-energy and high-power demands simultaneously, providing various benefits such as improved energy efficiency and extended battery life, which is crucial in the field of energy storage and management. This study proposed a Long Short-Term Memory(LSTM)-based algorithm for State of Charge(SOC) estimation in hybrid energy packs. Data generated from FTP72, FTP75, UDSS, WLTP Class 1, WLTP Class 2, and WLTP Class 3 drive cycles, each discharged 100 times, were used to train and test the model. Compared to a GRU-based model that uses the Root Mean Square Error(RMSE) metric, our proposed model demonstrated a 50 % improvement in performance, showing superior SOC estimation accuracy.

Key words : Lithium-ion battery(리튬이온배터리), Electric vehicle(전기자동차), State of charge(충전상태), Supercapacitor(슈퍼커패시터), Hybrid energy pack(하이브리드 에너지 팩), LSTM(장단기 기억 신경망)

1. 서론

이차 전지 기반 전기자동차는 화석연료로 인해 발생하는 심각한 환경문제를 해결하는 방안으로 제시되고 있다. 납축전지, 니켈-카드뮴 배터리 등 다양한 이차 전지 중 리튬이온배터리는 고 에너지 밀도와 낮은 자가 방전율을 가지며 긴 수명으로 인해 전기 자동차 경제성 및 안전에 큰 영향을 미치는 주요 부품으로써 전기자동차 주력 에너지 저장장치로 사용한다.¹⁻³⁾

슈퍼커패시터는 에너지를 빠르게 저장하고 방출할 수 있어서 가속 및 제동 등의 상황에서 효율적으로 에너지 관리가 가능하다. 또한, 화학반응이 없고 저온에서 안정적인 방전 특성을 가지며 수명이 50만 사이클 이상이라는 장점이 있다.^{4,6)}

전기자동차의 에너지저장 장치는 고에너지 밀도와 높

은 출력밀도를 충족해야 하므로 슈퍼커패시터를 리튬이온배터리 보조 에너지원으로 활용하는 하이브리드 방식에 관한 연구가 활발히 진행되고 있다.⁷⁾ Armenta 등⁸⁾은 전기자동차의 주행거리를 향상하기 위해 차량의 운동 에너지에 따라 슈퍼커패시터의 방전을 제어하여 에너지를 효율적으로 사용하고 배터리의 과부하를 방지한다. 또한 재생 제동을 통해 에너지 소비를 줄이고 가속, 일정 속도, 제동 등 세 가지 주행 상태에 따라 배터리와 슈퍼커패시터 간의 에너지 분배를 최적화한다. Kim 등⁹⁾은 배터리와 슈퍼커패시터를 하이브리드화한 에너지 저장 시스템의 실시간 최적 전력 분배를 위해 심층 강화 학습 기반의 제어 기법을 적용했다. SAC(Soft Actor-Critic) 알고리즘을 사용하여 배터리 SOC(State of Charge), 커패시터의 SOC, 차량 속도, 가속도 등의 파라미터에 따라 전력

^{*}A part of this paper was presented at the KSAE 2023 Fall Conference and Exhibition

^{*}Corresponding author, E-mail: wansu.lim@skku.edu

^{*}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.

을 분배한다. 이를 통해 다양한 주행 조건에서 최적의 에너지 관리를 통해 차량의 성능을 높인다.

서로 다른 특성을 가진 두 에너지원을 하이브리드한 에너지 팩은 두 에너지원의 특성을 제어하여 성능을 극대화할 수 있는 에너지 관리 전략이 필요하다. 리튬이온배터리의 전압은 충전 및 방전 시 비선형적으로 변한다. 또한 에너지 밀도가 높아서 장시간 사용이 가능하며 자가 방전율이 낮다. 슈퍼커패시터의 충전 속도는 리튬이온배터리에 비해 상대적으로 매우 빠르고, 전압도 선형적으로 변한다. 그러나 슈퍼커패시터의 에너지 밀도는 리튬이온배터리에 비해 낮아서 오랜 시간 사용할 수 없다. 따라서 두 에너지원의 이러한 상이한 특성으로 인해 하이브리드 에너지 팩의 성능 유지, 수명 예측, 에너지 효율성 향상은 전기자동차에서 매우 중요한 과제이다.¹⁰⁾

이를 위해, 에너지 팩 SOC 예측기술을 중요하게 활용하며 이는 전기자동차 성능향상과 운전자 및 차량 안전을 보장하므로 사용자에게 나은 운전 경험과 경제성을 제공한다. 또한, 에너지 팩 충·방전 횟수가 증가함에 따라 충전 가능 용량이 감소하므로 정확한 SOC 예측은 안정적인 전기자동차 운용을 위해 중요하다. 현재 SOC 예측에 관한 연구는 활발하게 진행 중이며, 에너지 팩의 SOC를 정확하게 예측하는 기술이 계속 발전하고 있다.

한동호 등¹¹⁾은 ANN(Artificial Neural Network)으로 SOC를 예측한다. ANN을 구성하는 뉴런들은 입력으로 들어오는 여러 신호를 하나로 합산하여 Activation function을 통해 출력을 내보내며 만들어낸 출력은 다시 다른 뉴런의 입력으로 들어간다. Activation function으로 Sigmoid 함수를 사용하며 각 뉴런에 해당하는 가중치와 바이어스 값이 더해진 출력이 Sigmoid 함수를 거쳐 뉴런의 출력으로 결정하는 방식으로 SOC를 예측한다. 김시진 등¹²⁾은 RNN(Recurrent Neural Network)으로 SOC를 예측한다. RNN은 시계열 데이터 분석을 통해 예측할 수 있는 인공신경망이다. 은닉 층 노드에서 Activation function을 통해 얻은 결과는 RNN 구조 내에서 출력 층으로 전달하고 다시 입력으로 사용하는 방식으로 순차적인 데이터나 시계열 데이터를 처리하는 방식으로 SOC를 예측한다. 김시진 등¹³⁾은 MNN(Multi-layer Neural Network)으로 SOC를 예측한다. MNN은 입력 레이어와 출력 레이어 사이에 하나 이상 숨겨진 레이어를 추가한 신경망이다. MNN은 피드포워드와 역전파를 사용하여 출력 레이어에서 입력 레이어로 가중치를 업데이트하여 오류를 줄인다. 단일 레이어 퍼셉트론보다 복잡한 계산을 할 수 있으며 분류 및 수치 예측을 쉽게 한다. 권상욱 등¹⁴⁾은 CNN(Convolutional Neural Networks)으로 SOC를 예측한다. CNN은 Convolution layer를 통해 입력받은 이미지 특징

을 추출하고, 추출한 특징을 기반으로 다층 퍼셉트론 구조의 인공신경망을 이용하여 분류한다. 리튬이온배터리 내부의 화상 데이터와 같이 시각적 데이터를 분석하고 SOC를 예측한다. 임제영 등¹⁵⁾은 EMD-CNN-LSTM을 통해 SOC를 예측한다. EMD(Empirical Mode Decomposition)를 적용한 데이터 전처리와 딥러닝 기반 하이브리드 방식인 CNN-LSTM(Long Short-Term Memory) 결합을 통해 리튬이온배터리 SOC를 예측한다. EMD에서 혼련데이터를 생성하고 CNN-LSTM은 CNN과 LSTM 결합을 통해 높은 정확도로 잔여 수명을 예측할 수 있다. CNN 계층은 입력 데이터의 특징 및 경향성을 추출하여 Feature map을 생성하고, LSTM은 추출한 특징 데이터의 과거와 미래 상관관계를 학습하여 미래 전류용량을 예측하는 방식이다.

기존 논문을 분석한 결과 대부분 연구는 배터리 중심 SOC 예측기술을 제안하여 본 논문에서 사용한 하이브리드 에너지 팩에 적용하기에는 한계가 있다. 이에, 본 논문은 리튬이온배터리와 슈퍼커패시터를 하이브리드한 에너지 팩에 최적화된 SOC 예측기법을 제안한다. SOC 예측에는 시계열 데이터 분석에 효율적인 LSTM을 사용하였다. LSTM은 RNN의 한 종류로 시계열 데이터의 장기 의존성을 학습하며 복잡한 패턴을 안정적으로 파악할 수 있고 긴 시계열 입력 데이터의 불규칙성을 효과적으로 학습한다. 따라서 배터리 충전 및 방전 패턴과 주변 환경의 변화 등 다양한 요인을 종합적으로 고려하여 정확하고 신뢰할 수 있는 SOC 예측이 가능하다. 하이브리드 에너지 팩은 시뮬링크를 통하여 실제 사양과 같게 구성하고 시뮬레이션 하여 학습 데이터와 테스트 데이터를 생성하였다.

2. 하이브리드 에너지 팩의 SOC 예측

Fig. 1은 본 논문이 제안하는 LSTM SOC 예측 알고리즘 흐름도이다. Data generation은 FTP72, FTP75, UDDS, WLTP Class 1, WLTP Class 2, and WLTP Class 3 등 6가지 Drive-cycle에 따라 데이터를 생성하고, 생성한 데이터는 훈련 데이터와 테스트 데이터로 분리하였다. LSTM




Fig. 1 Flowchart of LSTM based SOC estimation

training은 LSTM 모델을 훈련하고 SOC를 예측한다. Error comparison은 LSTM 기반 SOC 예측 값과 벤치마크 모델인 GRU(Gated Recurrent Unit)를 이용한 SOC 예측 값에 대한 오차를 비교한다.

$$V = V_0 \left(\frac{SOC}{1 - \beta(1 - SOC)} \right) \quad (1)$$

2.1 데이터 생성(Data Generation)

Table 1은 하이브리드 팩을 구성할 때 사용한 리튬이온배터리와 슈퍼커패시터 사양이다. 리튬이온배터리 전압은 340 V이고 용량은 176.47 Ah로 설정하였다. 슈퍼커패시터의 각 셀 전압은 2.7 V이고 셀 용량은 3000 F으로

Table 1 Specifications for Lithium-ion batteries and supercapacitors

Item	Specification
Battery nominal voltage	340 V
Battery capacity	176.47 Ah
Capacitor cell voltage	2.7 V
Capacitor cell capacitance	3000 F
Capacitor voltage	599.4 V
Capacitor capacitance	13.51 F
Capacitor capacity	2.25 Ah

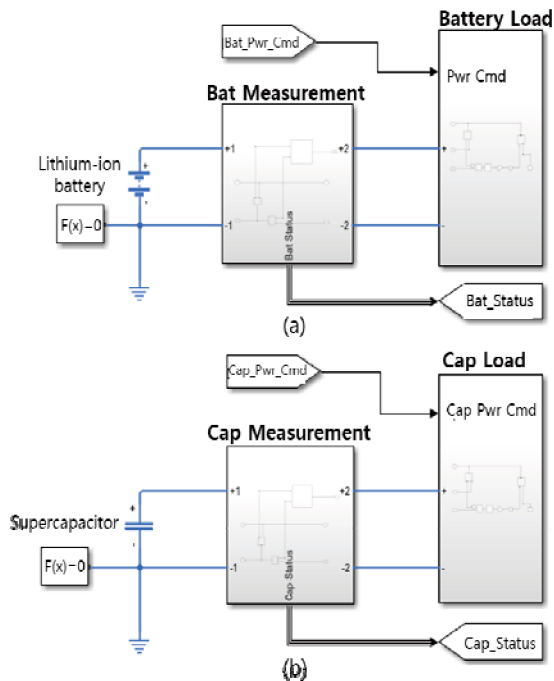


Fig. 2 Hybrid energy pack model: (a) Lithium-ion battery, (b) Supercapacitor

설정하였다. 슈퍼커패시터의 총 전압은 599.4 V로 222개의 셀이 직렬로 연결했을 때 합이다. 슈퍼커패시터의 전체 배열이 저장할 수 있는 총 전하량은 13.51 F이고 저장할 수 있는 총 에너지량은 2.25 Ah로 리튬이온배터리와 슈퍼커패시터 사양을 구성하였다.

Fig. 2는 리튬이온배터리와 슈퍼커패시터를 결합한 하이브리드 에너지 팩을 나타내는 시뮬링크 모델이다. (a)와 (b)는 각각 리튬이온배터리와 슈퍼커패시터 모델이다. Bat measurement와 Cap measurement는 각각 리튬이온배터리와 슈퍼커패시터의 전압과 전류를 측정하여 Actual SOC를 계산하는 모듈이다. 측정된 전압과 전류, Actual SOC 등은 Bat_Status와 Cap_Status 모듈로 전송한다. Battery load와 Cap load는 각각 리튬이온배터리와 슈퍼커패시터의 전압을 모니터링하고 전력 명령 신호 Bat_Pwr_Cmd와 Cap_Pwr_Cmd를 받아 부하에 필요한 전류를 조절한다.

$$I = C \frac{dV}{dt} \quad (2)$$

식 (1)은 시뮬링크에서 제공하는 식이고 전압과 SOC 관계를 나타낸다. β 는 리튬이온배터리 모델에서 SOC와 전압 사이에 비선형 관계를 설명하는 데 사용하는 상수이다. β 는 배터리의 유형에 따라 결정되며 본 논문에서 사용한 LG INR18650HG2 배터리의 β 는 0.937이다.

식 (2)는 슈퍼커패시터의 전류를 계산하는 식으로 슈퍼커패시터의 전기용량 (C)과 전압 변화율 ($\frac{dV}{dt}$)에 비례한다. 따라서 전류는 전압 변화율에 따라 결정되므로 전류를 통해 충전 시 전압이 증가하고 방전 시 전압이 감소하는 과정을 확인할 수 있다.

리튬이온배터리와 슈퍼커패시터로 이루어진 하이브리드 에너지 팩에서 현재 충전상태를 구하기 위해 식 (3)을 사용한다.

$$H_c = \frac{B_c + C_c}{B_{ct} + C_{ct}} \quad (3)$$

식 (3)에서 H_c 는 하이브리드 에너지 팩의 총용량이다. B_c 와 C_c 는 각각 리튬이온배터리와 슈퍼커패시터의 현재 용량이며 B_{ct} 와 C_{ct} 는 각각 리튬이온배터리와 슈퍼커패시터의 총용량이다. $H_c, B_c, C_c, B_{ct}, C_{ct}$ 의 단위는 Ah이다. 하이브리드 에너지 팩을 구성한 후 다양한 Drive-cycle을 적용하여 각각 100회씩 에너지 팩 방전 실험을 수행하였다. 6개 Drive-cycle 중 5개는 훈련 데이터로 사용하고 나

머지 1개는 테스트 데이터로 사용하였다. 이를 통해 리튬이온배터리와 슈퍼커패시터 전류 및 전압 데이터를 추출하고 시간에 따른 SOC 변화를 예측한다. 최종적으로 이 하이브리드 에너지 팩 모델을 통해 얻은 리튬이온 배터리와 슈퍼커패시터의 전류, 전압 및 SOC 데이터를 LSTM 모델 입력 데이터로 사용한다.

2.2 모델 훈련(Model Training)

본 논문은 하이브리드 에너지 팩 SOC 예측을 위해 LSTM 기법을 사용한다. LSTM은 RNN의 한 종류로 시계열 데이터의 장기 및 단기적인 시간 의존성을 모델링하기 위해 설계한 네트워크이다. RNN의 일반적인 문제인 기울기 소실과 같은 문제를 완화하면서 장기적인 의존성을 학습할 수 있는 능력을 갖추고 있다. 이 모델은 하이브리드 에너지 팩의 전류, 전압 및 SOC로 구성된 시계열 데이터를 입력으로 활용하고 이전 시간 단계의 은닉 상태와 함께 현재의 상태를 고려하여 SOC를 예측한다.

Fig. 3은 본 논문에서 사용한 LSTM 모델 구조이다. LSTM은 Forget gate, Input gate, Output gate 등 3종류 게이트 유닛과 기억 소자로 이루어져 있다. x_t 는 Input vector, h_{t-1} 은 Previous hidden state, C_{t-1} 은 Previous cell state, σ 는 Sigmoid layer, h_t 는 Current hidden state 그리고 C_t 는 Current cell state를 의미한다. Forget gate는 h_{t-1} 과 x_t 를 σ 함수를 통과시켜 C_{t-1} 의 어떤 정보를 잊을지 결정한다. Input gate는 h_{t-1} 과 x_t 에 대해 2가지 연산을 수행한다. 하나는 σ 를 통과해 새로운 정보가 셀 상태에 저장될지를 결정하고, 다른 하나는 \tanh 를 통과해 새로운 후보 값들을 생성한다. 이 값들은 서로 곱셈을 통해 결합하여 셀 상태를 업데이트한다. 마지막으로 Output gate는 h_{t-1} 과 x_t 를 사용하여 σ 함수를 통과시킨 후 Tanh를 통과한 새로운 셀 상태와 요소별로 곱하여 숨겨진 상태 h_t 를 결정한다.

Fig. 4는 LSTM 모델을 기반으로 SOC 예측 과정을 구현한 의사 코드이다. 의사 코드는 Load data, Configure model architecture, Set training parameter, Train model evaluate performance 등 5단계로 구성한다. Load data는 앞서 생성한 5개 Drive-cycle로부터 얻은 전압, 전류 및 SOC 데이터를 불러온다. Configure model architecture는 LSTM 모델 구조를 설정한다. 정확한 SOC 예측을 위해 여러 LSTM layer를 쌓고 Output layer를 모델에 추가한다. Set training parameter는 모델 훈련을 위한 파라미터를 설정하기 위해 Adam optimization algorithm(Adam)을 적용하여 적절한 배치 크기와 에포크 수 등의 하이퍼파라미터를 설정한다. Train model은 이러한 설정들을 바탕으로 모델을 학습시킨다. 과적합을 방지하고 일반화 성능

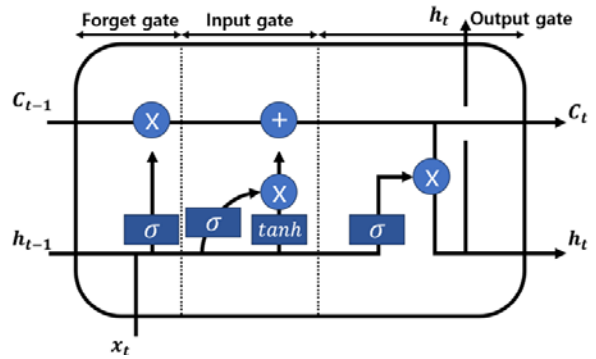


Fig. 3 LSTM model used for SOC estimation

Train model	
Input :	voltage, current, SOC of five drive cycle
Output :	LSTM_model
Load data	
1	Load the preprocessed data for training and testing
Configure model architecture	
2	Configure the model layers
3	Define suitable input and output dimensions
Set training parameter	
4	Choose an optimizer for training the model
5	Set batch size and epochs
Train model	
6	Split the loaded data into training and test data
7	Train the model with the training data
8	Use early stopping based on test data loss
Evaluate performance	
9	Evaluate the trained model on the test data
10	Calculate evaluation metrics
11	Save the LSTM model

Fig. 4 Pseudocode of model training

을 향상하기 위해 조기 종료 메커니즘을 적용한다. Evaluate performance는 훈련한 모델을 테스트 데이터셋을 사용하여 평가하였다. 평가 과정에서 평가 지표들을 통해 모델 성능을 측정 후 모델을 저장한다.

2.3 오류 비교(Error Comparison)

데이터 모델 평가를 위한 주요 지표로 RMSE(Root Mean Square Error), MAE(Maximum Absolute Error), PCC (Pearson Correlation Coefficient)를 모델 예측 정확도와 오차를 측정하는 데 사용한다. RMSE는 식 (5)로 정의한다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

RMSE는 평균 제곱근 오차로 n은 관측 값 총 개수를 나타내고 y_i 는 실제 관측 값, \hat{y}_i 는 모델로 예측한 값을 의미한다. RMSE는 예측 오차를 제곱하여 계산하고 이를 모두 합산한 후 평균을 취한 뒤 제곱근을 구한 값이다. MAE(Mean Absolute Error)는 예측 값과 실제 값 간의 차이를 절댓값으로 측정하고 평균화한 값이다. MAE는 식 (6)으로 정의한다.

$$MAE = \frac{1}{n} \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)} \quad (6)$$

MAE는 평균 제곱 오차로 n은 관측 값 총 개수를 나타내고, y_i 는 실제 관측 값, \hat{y}_i 는 모델로 예측한 값을 의미한다. MAE는 예측 값이 실제 값에 얼마나 가까운지를 나타내며 MAE 값이 낮을수록 모델이 실제 데이터를 더 정확하게 예측 할 수 있음을 나타낸다.

PCC는 변수 간 선형 관계의 강도와 방향을 나타내어 모델의 예측 정확도를 측정한다. PCC는 식 (7)으로 정의한다.

$$PCC = \sum_{i=1}^n \frac{(x_i - \mu_x) \times (y_i - \mu_y)}{\sqrt{(x_i - \mu_x)^2} \sqrt{(y_i - \mu_y)^2}} \quad (7)$$

PCC는 피어슨 상관 계수로 n은 관측 값 총 개수를 나타내고 x_i, y_i 는 각각 i번째 x, y 값이고, μ_x, μ_y 는 x, y의 평균을 나타낸다. $\sqrt{(x_i - \mu_x)^2} \sqrt{(y_i - \mu_y)^2}$ 는 각 변수 편차에 제곱 합을 한 후의 제곱근인데 이는 표준편차를 계산할 때에 사용한다. PCC는 -1과 1 사이 값을 가지며 1은 양의 선형 관계, -1은 음의 선형 관계, 0은 어떤 선형 관계가 없다는 것을 의미한다. 위 지표들을 통해 데이터를 분석하고 모델을 평가하였다.

3. 시뮬레이션 결과

3.1 실험 환경

하이브리드 에너지 팩 데이터는 시뮬링크를 이용하여 생성하였고 SOC 예측 시뮬레이션은 파이썬을 이용하였다. Table 2는 LSTM 기반 모델을 훈련하기 위해 설정한 파라미터 값들이다. 먼저 Adam을 사용하고 Learning rate를 0.001로 설정하여 손실을 최소화하였다. 모델의 효율적인 학습을 위해 Batch size는 128로 설정하였고 총 350 Epoch 동안 모델이 반복 학습하도록 설정하였다. LSTM layer는 128개 유닛을 사용하며 Scaled Exponential

Table 2 Proposed LSTM parameters

Optimizer	Adam	Learning rate	0.001
Batch size	128	Epoch	350
LSTM units	128	Dropout	0.2
Activation (Recurrent layer)	SELU	numNueronsFCL1	128
Activation (Output layer)	Linear	numNueronsFCL2	64




Fig. 5 Voltage of Lithium-ion batteries




Fig. 6 Current of Lithium-ion batteries




Fig. 7 Voltage of supercapacitors




Fig. 8 Current of supercapacitors




Fig. 9 SOC of hybrid energy pack

Linear Unit (SELU) 활성화 함수를 적용하였다. 과적합을 방지하기 위해 Dropout 비율을 0.2로 적용하였고 완전연결 Layer인 numNueronsFCL1과 numNueronsFCL2는 각각 128과 64개 뉴런을 사용하였다. Output layer는 linear 활성화 함수로 선형 변환을 수행하여 회귀 문제를 해결하였다.

Figs. 5~9는 각각 하이브리드 에너지 팩을 방전시킬 때 시간에 따른 리튬이온배터리의 전압, 리튬이온배터리의 전류, 슈퍼커패시터의 전압, 슈퍼커패시터의 전류, 하이브리드 에너지 팩 SOC 이다. Drive-cycle은 FTP75, FTP72, UDDS, WLTP Class 1, WLTP Class 2, WLTP Class 3 등 6가지를 이용했다. 각 Drive-cycle은 100회씩 실행하였고 실험 결과 획득한 데이터 총량은 600개이다. 이중 FTP75, FTP72, UDDS, WLTP Class 1, WLTP Class 2 등 5개 Drive-cycle에서 얻은 데이터는 모델을 훈련하는 데 사용했고, WLTP Class 3 Drive-cycle은 테스트용으로 사용했다.

3.2 실험 결과

Fig. 10은 훈련 데이터 5개 사이클에 대한 SOC 예측 그래프이다. 5개 Drive-cycle로 에너지 팩을 방전시켰으며 파란색 선은 실제 데이터를 의미하고 붉은색 선은

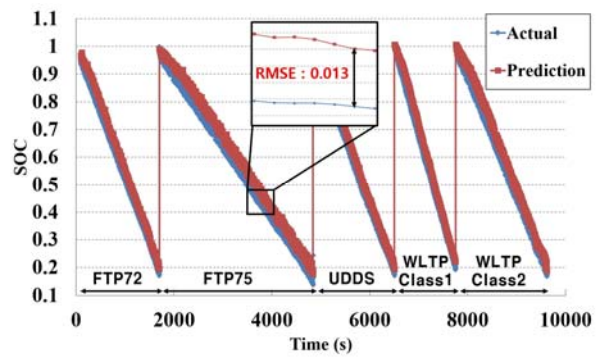


Fig. 10 Data training results




Fig. 11 LSTM model based SOC estimation results

LSTM 기반 모델을 사용하여 예측한 값을 나타낸다.

Fig. 11은 LSTM 모델을 기반으로 SOC를 예측한 그래프이다. WLTP Class3의 Drive-cycle에 대한 테스트 데이터를 사용하였으며 입력 데이터로 Fig. 10의 훈련 데이터를 사용하였다. 파란색 선은 실제 데이터를 의미하고 붉은색 선은 LSTM 모델을 기반으로 한 예측 값을 의미한다. 확대한 부분을 보면 RMSE 값이 0.013으로 비교적 SOC 예측 성능이 뛰어난 것을 알 수 있다.

Fig. 12는 벤치마크 모델로 GRU 모델을 사용하여 SOC 예측 결과 그래프이다. WLTP Class3의 Drive-cycle에 대한 테스트 데이터를 기반으로 시뮬레이션 하였으며 입력 데이터는 LSTM과 같이 Fig. 10의 훈련 데이터를 사용하였다. 확대한 부분을 보면 RMSE 값이 0.026으로 높은 SOC 예측 정확도를 가지고 있지만, LSTM보다 예측 정확도가 떨어짐을 알 수 있다.

Table 3은 LSTM 모델과 GRU 모델 테스트 데이터를 RMSE, MAE, PCC와 같은 지표들로 데이터를 비교한 수치이다. 제안한 LSTM 모델은 RMSE가 0.013, MAE가 0.009으로 뛰어난 정확도를 보여주며 PCC 수치가 0.999로 매우 높은 상관관계를 나타낸다. 반면 GRU 모델은 RMSE가 0.026, MAE가 0.024의 수치를 보여주며 PCC는 0.998로 상대적으로 낮지만, 여전히 높은 상관관계를 보

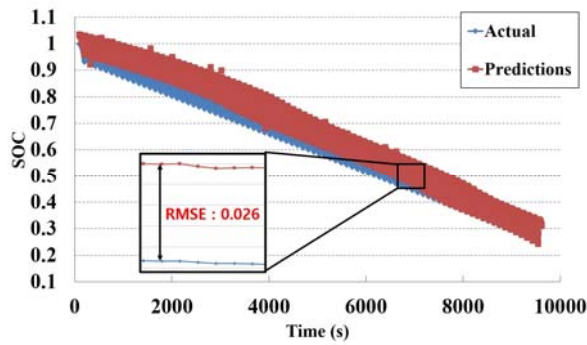


Fig. 12 GRU model based SOC estimation results

Table 3 Performance comparison between LSTM and GRU

	RMSE	MAE	PCC
LSTM	0.013	0.009	0.999
GRU	0.026	0.024	0.998

여준다. 이 데이터를 보았을 때 RMSE와 MAE 수치가 0에 가까운 LSTM 모델이 GRU 모델보다 예측 정확도와 데이터 상관성 면에서 더 우수하다는 것을 보여준다. GRU는 LSTM과 같이 RNN의 한 종류이지만 LSTM에 비해 간단한 구조로 이루어져 있어서 학습에 필요한 매개변수가 적다. 따라서 GRU는 LSTM보다 계산량이 적으므로 효율적이고 빠르게 학습할 수 있다. 그러나 이러한 GRU 특성은 입력 데이터의 패턴이 간단한 데이터에는 효과적이지만 본 논문에서 사용한 복잡한 입력 데이터에서 특징을 추출할 때는 한계가 있다. 시뮬레이션 결과 LSTM을 사용 시 RMSE는 평균 0.013이었으나 GRU는 0.026이었다.

Table 4는 LSTM 모델과 GRU 모델 RMSE 수치를 다양한 에포크 수에 따라 비교한 결과이다. 에포크 수 이외에 모든 파라미터는 같게 시뮬레이션 하였고 250, 300, 350, 400의 에포크 수를 설정하였으며 LSTM 모델은 350 에포크 수에서 RMSE 값이 가장 낮았고 GRU 모델은 300 에포크 수에서 RMSE 값이 가장 낮았다. 하지만 LSTM 모델이 300, 350의 에포크 수일 때 모두 GRU 모델보다 낮은 RMSE 수치를 가지기 때문에 LSTM 모델의 성능이 더 우수함을 보여준다.

Table 5는 LSTM과 GRU 모델의 RMSE 수치를 LSTM 레이어 수에 따라 비교한 결과이다. LSTM 모델에서는 레이어 수가 128일 때 RMSE가 최소인 0.013이고 GRU 모델은 레이어 수가 증가함에 따라 RMSE가 증가하는 경향을 보이는데 64 레이어 수를 가질 때 가장 낮은

Table 4 RMSE comparison between LSTM and GRU over different epochs

Epoch	LSTM	GRU
250	0.014	0.066
300	0.018	0.024
350	0.013	0.026
400	0.032	0.045

Table 5 RMSE comparison between LSTM and GRU over different layers

Number of layer	LSTM	GRU
64	0.017	0.023
128	0.013	0.024
256	0.019	0.046
512	0.032	0.050

RMSE 값인 0.023이다. LSTM RMSE 수치가 가장 낮은 레이어 수인 128일 때와 GRU RMSE 수치가 가장 낮은 레이어 수 64일 때 모두 LSTM RMSE 수치가 낮음을 보여줌으로써 LSTM 모델 성능이 GRU 모델보다 더 우수함을 알 수 있다.

4. 결론

본 논문은 LSTM 모델을 이용하여 리튬이온배터리와 슈퍼커패시터를 하이브리드한 에너지 팩의 SOC 예측 알고리즘을 제안했다. LSTM은 시계열 데이터의 장기 의존성을 학습하고 복잡한 패턴을 안정적으로 파악할 수 있다. 따라서 LSTM을 이용함으로써 배터리 충전과 방전 패턴 그리고 주변 환경 변화 등 다양한 요인을 종합적으로 고려하여 신뢰성 높은 SOC를 예측했다. 이를 증명하기 위해 GRU 모델을 벤치마크로 이용하여 RMSE, MAE, PCC 등 3가지 파라미터로 비교했다. 에포크와 레이어 수에 차별화를 두어 시뮬레이션 하였으며 시뮬레이션 결과 에포크를 다르게 했을 때 LSTM의 RMSE는 GRU의 RMSE보다 각각 78.79%, 25%, 50%, 28.89% 향상됐다. 또한 레이어 수를 다르게 했을 때 LSTM의 RMSE는 GRU의 RMSE보다 26.09%, 45.83%, 58.7%, 36% 향상됐다. 시계열 데이터 처리 모델인 LSTM의 성능이 확인됐으므로 향후 RNN을 변형한 BiRNN (Bi-directional RNN), VRNN (Variational RNN), DeepAR (Deep Autoregressive) 모델을 활용하여 하이브리드 에너지 팩의 SOC 예측 연구를 진행할 예정이다.

후 기

이 성과는 정부의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(과제번호: 2021R111A3056900, RS-2024-00349885).

References

- 1) A. M. Pascual, T. Ahn, I. Jeon, M. Kim and W. Lim, "Enhancing State-of-Health Estimation Through Deep Architecture Modification of LSTM Networks," Transactions of KSAE, Vol.32, No.2, pp.193-201, 2024.
- 2) C. Zheng, Y. Park, W. Lim and S. Cha, "A Study on Battery SOC Estimation by Regenerative Braking in Electric Vehicles," Transactions of KSAE, Vol.20, No.1, pp.119-123, 2012.
- 3) J. Gim, W. Choi and C. Ahn, "Design of Unscented Kalman Filter with Gated Recurrent Units-Based Battery Model for SOC Estimation," Transactions of KSAE, Vol.30, No.1, pp.61-68, 2022.
- 4) Y. Kim, S. Jung, J. Kim, G. Park, T. Kang, J. Kim and D. Kim, "Implementation of Super-Capacitors Based a Battery Pack for E-Mobility," Journal of KIIT, Vol.20, No.3, pp.57-65, 2022.
- 5) J. Han, Y. Park and S. Ryu, "Analysis of Virtual Fuel Economy Evaluation Method Considering Final SoC of Battery in Fuel Cell Hybrid Electric Vehicle," Transactions of KSAE, Vol.20, No.5, pp.1627-1630, 2012.
- 6) S. Kim, B. Gil, G. Hwang and C. Ryu, "Electrochemical Characteristics of Hybrid Cell Consisting of Li Secondary Battery and Supercapacitor," Korean Hydrogen and New Energy Society, Vol.30, No.1, pp.43-48, 2019.
- 7) J. Park and W. Lim, "Study on State of Charge (SOC) Estimation for Hybrid Energy Packs in Electric Vehicles," KSAE Fall Conference Proceedings, pp.1640-1641, 2023.
- 8) J. Armenta, C. Nunez, N. Visairo and I. Lazaro, "An Advanced Energy Management System for Controlling the Ultracapacitor Discharge and Improving the Electric Vehicle Range," Journal of Power Sources, Vol.284, pp.452-458, 2015.
- 9) D. Kim, S. Hong, S. Cui and I. Joe, "Deep Reinforcement Learning-Based Real-Time Joint Optimal Power Split for Battery-Ultracapacitor-Fuel Cell Hybrid Electric Vehicles," Electronics, Vol.11, No.12, Paper No.1850, 2022.
- 10) I. Kim, Y. Kim, W. Cho, I. Jeong, D. Chung and J. Jeon, "A Study on Transformer Deep Learning Algorithm for a State of Charge (SOC) Prediction of Vanadium Redox Flow Battery," The Institute of Electronics and Information Engineers, Vol.58, No.6, pp.2060-2064, 2021.
- 11) D. Han, S. Kwon, S. Kim, J. Kim and S. Lee, "SOC Estimation of Li-Ion Battery Using ANN Based on Electric Vehicle Running Profile," Proceedings of the KIPE Conference, pp.129-130, 2018.
- 12) S. Kim, J. Lee, D. Wang and I. Lee, "LSTM-Based Real-Time SOC Estimation of Lithium-Ion Batteries Using a Vehicle Driving Simulator," International Conference on Control, Automation and Systems, Kyungpook National University, Daegu, 2021.
- 13) S. Kim, J. Lee, D. Wang and I. Lee, "Vehicle Simulator and SOC Estimation of Battery Using Artificial Neural Networks," The Journal of Korean Institute of Information Technology, Vol.19, No.5, pp.51-62, 2021.
- 14) S. Kwon, J. Kim, J. Ahn, E. Choi, J. Park and J. Kim, "CNN Based Battery SOC Estimation Using Thermal Distribution Image," The Korean Institute of Power Electronics, Vol.23, No.7, pp.453-454, 2019.
- 15) J. Lim, D. Kim, T. Noh and B. Lee, "Remaining Useful Life Prediction for Lithium-Ion Batteries Using EMD-CNN-LSTM Hybrid Method," The Transactions of the Korean Institute of Power Electronics, Vol.27, No.1, pp.48-55, 2022.