

## ICA 기반 상관 그래프-시계열 융합을 통한 멀티모달 리튬이온 배터리 SOH 예측

이 동 호<sup>1</sup> · 박 경 욱<sup>1</sup> · Muhammad Ihza Febriyan Pagri<sup>2</sup> · 서 동 준<sup>3\*</sup>

<sup>1</sup>경북대학교 융복합시스템공학과 석사과정

<sup>2</sup>경북대학교 융복합시스템공학과 박사과정

<sup>3</sup>경북대학교 융복합시스템공학과 부교수

## Multimodal SOH Prediction for Lithium-Ion Batteries Using ICA-Based Correlation Graph and Time-Series Fusion

Dongho Lee<sup>1</sup> · Gyeonguk Park<sup>1</sup> · Muhammad Ihza Febriyan Pagri<sup>2</sup> · Dongjun Suh<sup>3\*</sup>

<sup>1</sup>Master's Course, Department of Convergence and Fusion System Engineering, Kyungpook National University, Daegu 41566, Korea

<sup>2</sup>Ph.D. Course, Department of Convergence and Fusion System Engineering, Kyungpook National University, Daegu 41566, Korea

<sup>3</sup>Associate Professor, Department of Convergence and Fusion System Engineering, Kyungpook National University, Daegu 41566, Korea

### [요 약]

본 연구는 리튬이온 배터리의 건강 상태를 예측하기 위해, 사이클 단위 시계열 정보와 증분 용량 분석법 특징 추출 기반 정보를 결합한 멀티모달 프레임워크를 제안한다. BiLSTM 인코더와 GAT 인코더를 활용하여 방전 구간의 시간적 및 관계적 열화 패턴을 인코딩하고, 결합된 임베딩을 기반으로 SOH를 회귀 방식으로 추정하였다. 열화 데이터셋 실험 결과, 제안 모델은 단일 모달 SOH 예측 모델 대비 정확도와 편향 측면에서 우수한 성능을 보였으며, 멀티모달 결합의 효과를 확인하였다.

### [Abstract]

This study proposes a multimodal model to predict the state of health (SOH) of lithium-ion batteries by combining cycle level discharge time series signals with a correlation graph built from Pearson correlations among Incremental Capacity Analysis (ICA)-derived summary features. ICA-derived descriptors capture cycle-to-cycle electrochemical changes, and their pairwise correlations are encoded into a graph representing inter-cycle similarity. A BiLSTM encoder models temporal degradation dynamics, and a GAT encoder learns relational dependencies across cycles by attending to informative neighbors. The two embeddings are fused and fed into a regression module to predict the SOH for the subsequent cycle. Experiments on public degradation datasets showed that the BiLSTM + GAT combination achieved the best accuracy and bias among the compared models; however, multimodal integration was not consistently superior.

**색인어** : 배터리 수명, 리튬이온 배터리, 배터리 열화, 증분용량 분석법, 멀티모달 학습

**Keyword** : State of Health, Lithium-Ion Battery, Battery Degradation, Incremental Capacity Analysis, Multi-Modal Learning

<http://dx.doi.org/10.9728/dcs.2026.27.4.1079>



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** 06 February 2026; **Revised** 05 March 2026

**Accepted** 24 March 2026

**\*Corresponding Author; Dongjun Suh**

**Tel:** +82-54-530-1482

**E-mail:** dongjunsuh@knu.ac.kr

## I. 서 론

전기차 시장이 확대됨에 따라 리튬이온 배터리는 차량의 성능과 안전을 좌우하는 핵심 부품으로 자리매김하고 있다 [1]. 리튬이온 배터리는 높은 에너지 밀도와 우수한 출력 특성으로 인해 전기차에 널리 적용되지만, 운용 환경과 사용 시간이 누적되면서 전극-전해질 계면 열화, 내부저항 증가, 가용 용량 감소와 같은 다양한 열화 현상이 진행된다[2]. 이러한 성능 저하는 주행거리 감소로 직결될 뿐 아니라 과열 및 이상 반응에 대한 취약성을 높여 안전 측면에서 잠재적 위험 요인으로 작용할 수 있다[3]. 배터리 관리 시스템(BMS; Battery Management System)은 배터리의 안전성과 효율을 확보하기 위한 필수 시스템으로, 셀 전압, 전류, 온도 등 계측 데이터를 기반으로 과충전·과방전 보호, 열 관리, 셀 밸런싱, 운용 전략 최적화 기능을 수행한다[4]. 이때 BMS의 핵심 기능 중 하나는 배터리의 충전 상태(SOC; State of Charge), 건강 상태(SOH; State of Health), 내부 저항, 온도 등의 주요 상태 변수를 정밀하게 추정하는 것이다. 그러나 이러한 상태 변수는 센서로 직접 측정하기 어렵거나, 측정 비용 및 적용 제약이 큰 경우가 많다[5]. 이에 따라 등가회로모델(ECM; Equivalent Circuit Model) 및 전기화학 모델 기반 접근법, 또는 데이터 기반 추정 기법을 활용한 간접 추정이 적용된다. 전기차 배터리는 다수의 셀을 직·병렬로 구성한 팩 단위로 운용되며, 제조 편차나 급격한 부하 변동 등의 요인으로 인해 열화가 균일하게 진행되지 않을 수 있다[6]. 또한 충·방전 전류의 크기, 주행 패턴, 주변 온도와 같은 운용 조건은 열화 속도와 메커니즘에 직접적인 영향을 미치므로, 동일한 사용 시간에서도 성능 저하 수준은 크게 달라질 수 있다. 따라서 BMS 관점에서는 단순 모니터링을 넘어, 다양한 운용 조건에서도 일관되게 적용 가능한 상태 추정 방법과 열화 진단 지표를 확보하는 것이 중요하다. 실제 차량 운용 환경에서는 센서 노이즈, 전류 변동, 온도 변화 등의 요인으로 인해 실험실 조건과 동등한 품질의 신호를 확보하기 어렵다[7]. 전압-용량 기반 특징은 전기화학적 의미가 비교적 명확하고 해석 가능성이 높아 진단 및 상태 추정의 입력으로 활용 가치가 크다. 다만 전처리 및 신호 처리 절차에 따라 특징 추출 결과가 달라질 수 있으므로, 특징 추출 과정의 표준화와 안정화가 요구된다. 배터리 열화 진단에는 전압-용량 곡선의 미분 특성을 활용하는 증분 용량 분석(ICA; Incremental Capacity Analysis)이 널리 사용된다. ICA는 충·방전 과정에서 전압 변화에 대한 용량 변화율( $dQ/dV$ )을 분석함으로써 전기화학 반응 특성이 피크 형태로 비교적 뚜렷하게 나타난다는 장점이 있다[8]. 피크 위치의 이동, 피크 높이의 감소, 피크 폭의 증가, 피크의 분리 및 병합은 열화에 따른 반응 특성 변화를 민감하게 반영하는 것으로 알려져 있으며, SOH 추정 및 열화 진단을 위한 유의미한 특징을 제공한다. 그러나 실제 운용 데이터에서는 노이즈와 샘플링 제약으로 인해 IC 곡선의 품질

이 저하될 수 있으므로, 안정적인 특징 추출과 더불어 IC 곡선을 보완할 수 있는 운용 신호 기반 정보의 통합적 활용이 필요하다[9].

## II. 관련 연구

배터리 열화 진단 분야에서는 전압-용량 곡선의 미분 특성을 활용하는 증분 용량 분석은 전통적으로 활용되고 있다. ICA는 충·방전 과정에서 전압 변화에 대한 용량 변화율로부터 IC 곡선을 구성하고, 피크의 위치 및 높이 변화 등을 해석함으로써 활성 물질 손실이나 리튬 손실과 같은 열화 현상을 비교적 민감하게 포착한다. 이러한 특성은 SOH 추정에 유의미한 진단 지표를 제공하는 장점으로 이어진다. 하지만 ICA 기반 접근은 대체로 고해상도의 정전류(CC; Constant Current) 충·방전 데이터를 전제로 하므로, 실험실 조건에서는 우수한 성능을 보이지만 실제 BMS 환경에 그대로 적용하기에는 한계가 있다는 점이 보고되었다[10]. 특히 실사용 조건에서는 센서 노이즈와 불규칙한 충·방전 전류로 인해 피크 형태가 흐려지거나 특징 추출의 일관성이 저하될 수 있으며, 충분한 전처리와 완전 사이클 데이터 확보가 요구된다는 제약이 존재한다[11]. 이러한 제약을 완화하기 위해 최근에는 IC 곡선의 일부 구간 특성만을 활용하거나, IC 기반 지표를 머신러닝과 결합하여 데이터 요구량을 낮추면서도 강건성을 높이려는 연구가 이어지고 있다[12]. 배터리 SOH 추정 분야에서는 딥러닝을 활용한 데이터 기반 접근이 빠르게 확산되고 있다. 박민식 등[13]은 LSTM(Long Short-Term Memory) 및 GRU(Gated Recurrent Unit)와 같은 순환 신경망 계열 모델을 활용하여, 시계열 센서 데이터로부터 열화 패턴을 직접 학습하고 이를 기반으로 배터리의 수명 및 상태를 예측하였다. 권영석 등[14]은 CNN(Convolutional Neural Network)과 LSTM을 결합한 앙상블 기법을 통해 SOH 예측 성능을 더욱 향상시켰다. 이러한 방법들은 조건이 비교적 정형화된 사이클링 데이터에서 높은 예측 정확도를 보였고[13],[15], 일부 연구에서는 초기 수십 사이클 데이터만으로도 배터리 수명을 예측하는 모델을 제시하기도 했다[15]. 하지만 다수의 딥러닝 모델은 학습 데이터와 운용 조건이 유사하다는 가정 하에서 성능이 안정적인 확보되는 경우가 많아, 실험실과 다른 조건이나 가변적인 방전 프로파일에서는 정확도가 저하될 수 있다는 한계가 지적된다. 실제 차량 환경에서는 온도, C-rate, 주행 패턴 등이 시간에 따라 변화할 수 있으며, 도메인 변화에 대한 민감도가 클수록 일반화 성능 저하가 두드러질 수 있다. 이를 완화하기 위해 실험실 데이터로 학습한 모델을 실제 주행 데이터에 적응시키는 전이 학습 방법이나[16], 10분 이내의 부분 사이클 데이터만으로도 추정을 수행하도록 모델을 경량화하는 기법 등이 제안되고 있다. 그럼에도 데이터 기반 모델은 물리적 해석 가능성이

표 1. 배터리 열화 데이터셋 구성 및 시험 조건 요약

Table 1. Summary of battery degradation datasets and test conditions

Data Name	Cell	Degree	Discharge Profile	Cut-off Voltage	Material
Oxford Battery Degradation Dataset	1 ~ 8	40	Drive-cycle based on Urban Artemis	2.7V	LiCoO2
MIT Fast-Charging Dataset	1 ~ 40	30	4C	2.0V	LFP/graphite
NASA PCoE Li-ion Battery Aging Dataset	B0005 ~ B0008, B0018	24	CC 2A	2.7/ 2.5/ 2.2/ 2.5V	NCA or LCO

제한적이며, 경량화하는 기법 등이 제안되고 있다. 그럼에도 순수 데이터 기반 모델은 물리적 해석가능성이 제한적이며, 노이즈나 샘플링 불균일에 대한 문제를 해결하지는 못하였다. 이러한 배경에서 그래프 신경망(GNN; Graph Neural Network) 기반 접근이 유망한 대안으로 주목받고 있다. GNN 기반 모델은 배터리 셀 간 상호 관계나 사이클 간 연관성을 그래프 구조로 표현함으로써, 개별 셀 또는 사이클을 노드로 모형화하고 열화 패턴의 관계적 특성까지 함께 학습할 수 있다는 장점이 있다[17]. 예를 들어 Kim 등[17]은 GraphSAGE(SAmple and aggreGatE) 아키텍처에 스킵 커넥션과 적응형 손실 함수를 결합한 GNN 모델을 제안하여, 불규칙한 주행 패턴에서도 충전 구간의 전압·전류 데이터만으로 비교적 안정적인 SOH 추정을 구현하였다. 최근에는 복수의 센서 출력을 통합하거나, 전압-용량 곡선 기반 특징과 시계열 신호를 함께 활용하려는 시도도 보고되고 있다. Luan 등[18]은 ICA로부터 추출한 특징 조각을 그래프로 구성한 뒤, GAT(graph attention network)와 양방향 GRU를 결합한 프레임워크를 제안하였으며, 임베디드 시스템에서의 실시간 추정 가능성까지 제시하였다. 종합하면, 그래프 기반 방법은 복잡한 열화 양상을 관계 구조 관점에서 함께 학습할 수 있어 기존 딥러닝 접근 대비 정확도와 강건성이 향상되었다는 결과가 보고되고 있다. 다만 상당수 연구가 여전히 도메인 지식에 기반한 특징 추출 절차에 의존하거나, 비교적 이상적인 조건에서 성능을 검증한 사례가 많다는 한계는 남아 있다. 결국 기존 연구는 정형화된 랩 사이클 데이터에 대한 의존도가 높고, 노이즈와 샘플링 불확실성이 큰 실사용 데이터에서는 성능이 흔들릴 수 있다. 따라서 실제 BMS 환경에서 신뢰성 있게 적용하기 위해서는 시계열 패턴을 학습하는 능력과, 운용 조건 변화에 따라 형성되는 구조적 관계를 분석하는 능력을 결합한 접근이 요구된다. 이에 본 연구에서는 BMS 운용 환경을 고려하여 시간적 의존성을 갖는 시계열 정보와 운용 조건 변화에 따른 상관 구조를 동시에 반영할 수 있는 멀티모달 SOH 예측 모델을 제안한다. LSTM 기반 인코더를 통해 방전 구간의 시계열 특성을 학습하고, 특징 간 상관관계로 구성된 그래프를 GNN 기반 인코더로 학습 후, 두 표현을 결합하여 SOH를 추정한다.

### III. 데이터셋

본 연구에서는 공개 배터리 열화 데이터셋인 Oxford,

MIT, NASA 데이터셋을 활용하였다. 서로 다른 화학계와 운용(충·방전) 프로파일을 포함하는 다중 데이터 기반 검증을 통해, 제안 모델이 특정 조건에 국한되지 않고 다양한 환경에서 동작할 수 있는 데서 제안 모델의 적용 가능성을 점검하고자 하였다. 세 데이터셋 모두에서 방전 구간의 전압·전류·온도 시계열을 사용하였으며, 데이터를 사이클 단위로 분할한 뒤 동일한 전처리 절차를 적용하고 입력 특징을 구성하였다. 표 1에는 각 데이터셋의 구성과 시험 조건을 요약하였고, 그림 1에는 방전 구간에서 관측되는 전압, 전류, 온도 시계열의 예시를 제시하였다.




그림 1. NASA B0005 셀의 방전 전압·전류·온도 시계열 예시

Fig. 1. Discharge voltage, current, and temperature profiles (NASA B0005)

#### 3-1 Oxford Battery Degradation Dataset

Oxford 배터리 열화 데이터셋은 리튬이온 LCO 파우치셀 8개를 대상으로 40 °C 항온 조건에서 장기 사이클링을 수행하며 열화 거동을 기록한 데이터이다[19]. 운용 프로토콜은 CC-CV(Constant Current-Constant Voltage) 충전 이후 Urban Artemis 기반 구동 부하 방전을 반복하도록 설계되었으며, 열화 진행을 정량적으로 추적하기 위해 드라이브 사이클 100회마다 진단 사이클을 삽입하였다. 진단 사이클은 1C 충·방전과 저전류 기반 pseudo-OCV(Open Circuit Voltage) 측정으로 구성되며, 시간, 전압, 전류, 온도 등의 변수가 연속적으로 제공된다. 특히 본 데이터셋은 가변 전류 구동 부하 방전을 포함하므로, 정전류 방전 중심의 데이터에 비해 실사용 조건에 보다 근접한 환경에서 열화 특성을 분석하는 데 적합하다.

### 3-2 MIT Fast-Charging Cycle-Life Dataset

MIT Fast-Charging Cycle-Life 데이터셋은 상용 LFP/graphite 18650 셀 124개를 30 °C 조건에서 수명 종료까지 반복 사이클링하여 구축되었다[20]. 본 데이터셋의 핵심은 0-80% SOC 구간의 고속 충전 프로파일이며, one-step 또는 two-step CC 기반의 다양한 충전 프로파일을 적용하여 충전 조건 변화가 수명에 미치는 영향을 체계적으로 비교할 수 있도록 설계되었다. 0-80% SOC 충전 이후에는 내부저항 측정이 수행되며, 80-100% SOC 구간은 모든 셀에 대해 동일한 CC-CV 충전을 적용한 뒤 cut-off current 조건에서 종료한다. 반면 방전 조건은 모든 셀에서 동일하게 유지하여, 관측되는 수명 분산이 주로 충전 정책의 차이에서 기인하도록 실험 변인을 통제하였다.

### 3-3 NASA Li-ion Battery Aging Dataset

NASA PCoE(Prognostics Center of Excellence)에서 제공하는 Li-ion Battery Aging 데이터셋은 리튬이온 18650 셀의 열화 과정을 관찰하기 위해 충전, 방전, 임피던스(EIS; Electrochemical Impedance Spectroscopy) 측정을 포함하는 운용 프로파일을 반복 수행한 자료이다[21]. 널리 활용되는 셀(B0005, B0006, B0007, B0018)은 CC-CV 충전 조건에서 운용되며, 방전은 정전류 조건에서 셀별 cut-off voltage까지 수행된다. 또한 일정 주기로 EIS 측정이 포함되어 열화 진행에 따른 내부 상태 변화를 전기화학적으로 해석할 수 있다. 해당 데이터는 LCO 혹은 NCA 화학계를 대상으로 한다는 점에서 NMC 및 LFP 계열 데이터와 구분되는 열화 특성 비교에도 활용 가능하다[22].

## IV. 데이터 전처리

본 연구에서는 사이클 단위의 특성을 도출하기 위해 ICA를 수행하였으며, 전압에 대한 용량 미분을 계산한 후 이를 기반으로 스칼라 요약 특징을 추출하였다. 전체 절차는 전압 영역 재표본화, 수치 미분 및 스무딩, 특징 추출의 세 단계로 구성된다. 그림 2는 IC 곡선의 예시이다. 또한 각 사이클의 SOH를 용량 기반으로 산출하였다. 사이클  $c$ 의 방전 용량을  $Q_c$ 라 할 때, SOH는 기준 용량  $Q_{ref}$  대비 상대 용량으로 정의한다. 본 연구에서는 데이터셋 별로 기준 용량을 초기 사이클의 방전 용량을 사용하였다. 식 (1)은 SOH 계산식을 나타낸다.

$$SOH_c = \frac{Q_c}{Q_{ref}} \times 100\% \quad (1)$$




그림 2. NASA B0005 데이터셋의 IC 곡선 예시  
Fig. 2. IC curve of NASA B0005 dataset

### 4-1 전압 영역 재표본화

원시 측정 데이터는 시간축 기준으로 샘플링되기 때문에, 방전 과정에서 동일한 전압 값이 여러 번 관측될 수 있다. 이를 수치 미분하면,  $\Delta V$ 가 0에 가깝거나 중복된 구간이 존재할 수 있으며,  $dQ/dV$  계산이 수치적으로 불안정해질 수 있다[23]. 이를 완화하기 위해  $(V, Q)$  쌍에서 동일 전압에 대응하는 용량  $Q$ 를 평균하여 전압 값이 유일한 시퀀스를 구성하였다. 이후 전압 오름차순으로 정렬하고, 관측 전압 범위  $V \in [V_{min}, V_{max}]$ 에서 균일한 전압 그리드  $V_g$ 를 생성하였다. 마지막으로 선형 보간을 적용하여 연속 함수 형태의  $Q(V)$ 를 전압 그리드  $V_g$  상으로 재표현함으로써, 균일 그리드에서의 용량 곡선  $Q_g(V_g)$ 를 얻었다. 이 과정을 통해 비균일 샘플링 및 중복 전압으로 인한 영향을 줄이고, 후속 단계의 수치 미분과 특징 추출을 안정적으로 수행할 수 있도록 하였다.

### 4-2 IC 곡선 계산 및 스무딩

전압 영역으로 재표본화된 균일 전압 그리드  $V_g$  상에서 유한 차분 기반 수치 미분을 수행하여 IC 곡선을 계산하였다. 보간된 용량 곡선  $Q_g(V_g)$ 에 대해 전압에 대한 미분을 계산함으로써  $(dQ/dV)_g$ 를 얻었으며, 이는 식 (2)와 같이 정의한다. 여기서  $\nabla$ 는  $V_g$ 에 대한 수치 미분 연산자를 의미한다. 이산화 및 센서 노이즈 성분은 미분 과정에서 고주파 성분으로 증폭되어 IC 곡선의 피크 형상을 왜곡하거나 불필요한 진동을 유발할 수 있으므로, 후속 특징 추출의 안정성을 위해 스무딩이 권장된다[24]. 이에 본 연구에서는 계산된  $(dQ/dV)_g$ 에 대해 윈도우 크기 21의 이동 평균 필터를 적용하여 고주파 잡음을 완화하고, 피크 기반 특징이 일관되게 추출되도록 하였다[25].

$$\left(\frac{dQ}{dV}\right)_g = \nabla v_g Q_g \quad (2)$$

### 4-3 특징 추출

스무딩된 IC 곡선  $V_g(dQ/dV)_g$ 로부터 사이클 별로 IC 면적, 피크 크기, 피크 전압 위치, 무게 중심 전압 네 가지 특징 추출하였다. 또한 방전 구간의 운용 정보를 요약하기 위해 평균 방전 전류  $I_{avg}$ , 사이클의 방전 시간  $t_{last}$ , 최대 온도  $T_{max}$  그리고 최대 온도 도달 시점  $t_{T_{max}}$  을 추가로 산출하였다.

#### 1) IC 면적

IC 면적은 주어진 전압 구간 내에서의 누적 용량 변화를 정량화한 지표로, 열화에 따른 반응 활성도 감소를 직접적으로 반영한다[26]. IC 곡선은 특정 전압 범위에서 피크를 형성한다. 이는 해당 구간에서 활발한 전기화학 반응이 이루어지고 있음을 의미한다. 따라서 피크가 형성되는 전압 영역의 면적을 정량화하면, 사이클의 진행에 따라 반응이 약화되거나 분산되는 현상을 확인 할 수 있다. 본 연구에서는 사이클 간 비교의 일관성 확보를 위해 적분 구간  $[V_{min}, V_{max}]$ 를 각 실험 조건 별로 고정하였다. 이를 통해 동일 전압 범위에서 관측되는 면적 변화가 열화 추세에 따라 반영되도록 설계하였다. 식 (3)은 균일 전압  $V_g$  상에서 IC 면적  $IC_{area}$ 를 계산하는 수식을 나타낸다.

$$IC_{area} = \int_{V_{min}}^{V_{max}} \left(\frac{dQ}{dV}\right)_g \cdot dV \quad (3)$$

#### 2) IC 피크 크기

피크 크기는 IC 곡선에서 가장 높은 반응 강도를 나타내는 최대  $dQ/dV$ 값을 의미한다. 이는 특정 전압 구간에서 전기화학반응이 얼마나 뚜렷하게 나타나는지를 요약하는 지표로 해석할 수 있다. 열화가 진행되면 반응이 분산되거나 분극 증가로 인해 평탄 구간이 완만해지면서 피크 높이가 감소하는 경향이 보고된다. 따라서 피크 크기는 사이클 진행에 따른 특성 변화를 민감하게 반영할 수 있어, SOH 추정에서 유의미한 특징으로 자주 채택된다[26]. 식 (4)는 균일 전압 그리드  $V_g$ 에서 IC 피크 크기 특징  $IC_{peak}$ 를 정의한다.

$$IC_{peak} = \max_{V_g} \left(\frac{dQ}{dV}\right)_g \quad (4)$$

#### 3) IC 피크 전압 위치

IC 피크 전압 위치는 IC 곡선에서 주요 반응이 가장 활발히 일어나는 특성 전압을 나타내며, 전기 화학적 반응의 중심이 전압 축 상에서 어디에 위치하는지를 정량화한 지표이다. 피크 위치의 이동은 리튬 손실, 활성 물질 손실, 저항 증가에 따른 분극 변화 등으로 인해 나타날 수 있으며, 서로 다른 조건, 온도, C-rate에서도 비교적 일정한 특징으로 평가되어 SOH 추정에 사용된다[27]. 식 (5)는 ICA가 최대가 되는 지점의 전압 위치 특징  $IC_{peak\ v}$ 를 의미한다.

$$IC_{peak\ v} = \arg \max_{V_g} \left(\frac{dQ}{dV}\right)_g \quad (5)$$

#### 4) IC 무게중심 전압

무게중심 전압은 IC 응답이 전압축에서 어느 방향으로 더 치우쳐 있는지를 나타내는 전역 요약치이다. 피크 하나만을 이용하는 방식은 노이즈, 피크 분열, 형상 변화에 민감할 수 있으나, 무게중심 전압은 곡선 전체 분포를 평균적으로 반영하므로 피크 형상이 변하더라도 전반적인 전압 이동을 비교적 안정적으로 감지할 수 있다[25]. 식 (6)은 전압의 가중 평균으로 정의한 무게중심 전압  $IC_{centroid}$ 를 의미한다. 여기서 절댓값 가중  $w$ 는 부호 규약에 대한 민감도를 줄이고, 전압축에서 IC 응답의 질량 중심을 보다 안정적으로 추정하기 위한 것이다. 모든 적분은 균일 그리드 상에서 사다리꼴 적분으로 계산한다. 결과적으로 각 사이클의 특징 벡터 IC는 IC 곡선의 주요 특성을 함축적으로 표현하며, 이후 열화 분석 및 모델링 단계에서 입력 특징으로 활용된다.

$$IC_{centroid} = \frac{\int_{V_{min}}^{V_{max}} Vw(V)dV}{\int_{V_{min}}^{V_{max}} w(V)dV}, w(V) = \left|\frac{dQ}{dV}\right| \quad (6)$$

## V. 입력 데이터 구성

### 5-1 그래프 생성

본 연구에서는 운용 조건 변화에 따른 관계 정보를 학습하기 위해 그래프 형태의 입력을 구성하였다. 그래프는 배터리 셀별로 독립적으로 생성하였으며, 각 실험 셀  $k$ 에 대해 하나의 셀 단위 그래프  $G^{(k)} = (V^{(k)}, E^{(k)})$ 를 구성하였다. 각 그래프는 해당 셀의 사이클 데이터에서 추출한 특징을 기반으로 구성하였고, 사용된 특징의 구체적인 내용은 표 2에 제시하였다. 즉, 각 배터리 셀에 대해 독립적으로 특징을 추출하고, 이를 이용해 셀 단위 그래프를 생성하였다. 그래프 구성에는 입력 특성만 활용하였으며, 평가 구간의 SOH 정답값은 그래프 생성 및 모델 학습에 사용하지 않았다. 각 노드  $v^{(k)} \in V^{(k)}$ 의 특성은 Min-Max 정규화를 거친 수치형 입력 벡터로 표현하였다. 이는 사이클, 전압, 전류, 시간, 온도, ICA 기반 특징 등 노드 특성을 이루는 변수들이 서로 다른 단위와 수치 범위를 가지므로, 특정 변수의 크기 차이가 노드 간 관계 계산에 과도한 영향을 미치는 것을 방지하고 모든 특성이 비교 가능한 범위에서 반영되도록 하기 위함이다. 이에 따라 실험 셀  $k$ 의 노드 특성 행렬은 식 (7)과 같이 표현된다.

$$X_g^{(k)} \in \mathbb{R}^{N_k \times F_g} \quad (7)$$

여기서  $N$ 는 실험  $k$ 에서의 노드 수,  $F_g$ 는 그래프 입력 특성 차원이다. 또한 실험 셀  $k$ 의 각 사이클  $c$ 에 대응하는 11개의 노드 특성 벡터로 구성하였으며, 표 2에 나타내었다.

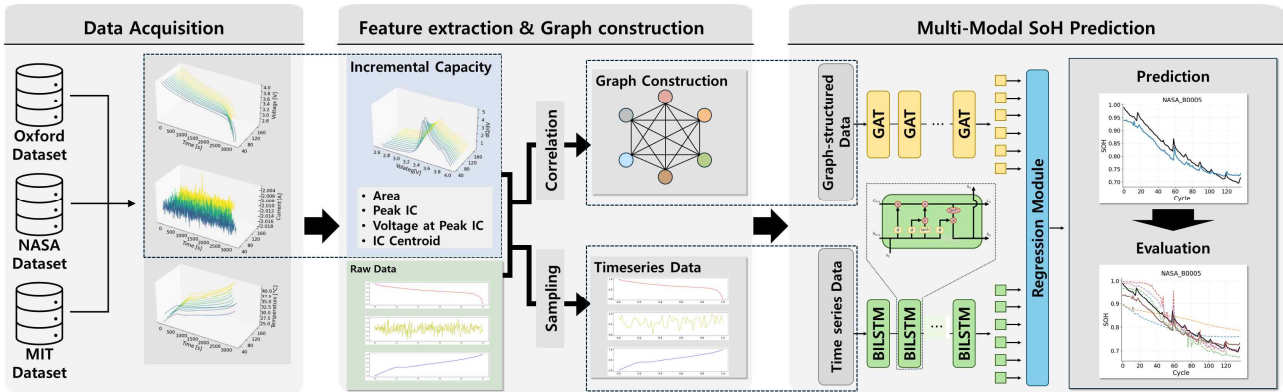


그림 3. 제안 멀티모달 SOH 예측 모델 프레임워크 구조  
 Fig. 3. Architecture of the proposed multimodal SOH prediction framework

그래프의 연결 구조는 노드 간의 특성 유사도를 반영하기 위해 피어슨 상관계수를 기반으로 정의하였다[28]. 식 (8)은 실험  $k$ 의 노드 특성 행렬  $X_g^{(k)}$ 에 대해, 노드  $i$ 와  $j$ 의 특성 벡터 간 피어슨 상관계수  $\rho_{i,j}^{(k)}$ 를 계산하여 구성된 노드-노드 상관 행렬  $C^{(k)}$ 를 나타낸다.

$$C^{(k)} = [C_{i,j}^{(k)}] \in \mathbb{R}^{N_k \times N_k}, C_{i,j}^{(k)} = \rho(X_g^{(k)}[i,:], X_g^{(k)}[j,:]) \quad (8)$$

여기서  $X_g^{(k)}[i,:] \in \mathbb{R}^{F_g}$ 는 실험  $k$ 에서의 노드  $i$ 의 특성 벡터를 의미하며, 피어슨 상관계수  $\rho(\cdot)$ 는 식 (9)와 같이 정의된다.

$\bar{x}_i$ 와  $\bar{x}_j$ 는 각각 노드  $i$ 와  $j$ 의 특성 벡터에 대해, 특성 차원  $F_g$  전반에 걸쳐 계산한 평균을 의미하며, 식 (10)에 나타내었다. 식 (11)은 상관계수의 절댓값이 임계값  $\tau$  이상인 노

드 쌍을 연결하여 구성된 엣지 집합을 나타낸다. 노드 간 상관 구조만 반영하기 위해  $i \neq j$ 인 경우에 한해 엣지를 정의하였다. 또한 그래프 신경망 입력 단계에서는 각 노드가 이웃 정보와 함께 자기 자신의 특성도 반영할 수 있도록 self-loop를 추가하였다. 본 연구에서는 그래프가 지나치게 조밀해지거나 과도하게 희소해지는 상황을 모두 방지하기 위해  $\tau$ 를 0.3, 0.5, 0.7의 세 수준으로 설정하였고, 최적 범위는 실험적으로 비교하였다[29].

$$\rho(x_i, x_j) = \frac{\sum_{f=1}^{F_g} (x_{i,f} - \bar{x}_i)(x_{j,f} - \bar{x}_j)}{\sqrt{\sum_{f=1}^{F_g} (x_{i,f} - \bar{x}_i)^2} \sqrt{\sum_{f=1}^{F_g} (x_{j,f} - \bar{x}_j)^2}} \quad (9)$$

$$\bar{x}_i = \frac{1}{F_g} \sum_{f=1}^{F_g} x_{i,f}, \bar{x}_j = \frac{1}{F_g} \sum_{f=1}^{F_g} x_{j,f} \quad (10)$$

$$\epsilon^{(k)} = \{(i, j) | i \neq j, |C_{i,j}^{(k)}| \geq \tau\} \quad (11)$$

표 2. 그래프 노드 설명  
 Table 2. Description of graph node features

Node	Description
$c$	Cycle index within a given cell, used to encode progression over time.
$V_{min}$	Minimum voltage observed during the discharge segment.
$V_{max}$	Maximum voltage observed during the discharge segment.
$I_{avg}$	Average discharge current over the discharge segment.
$t_{last}$	Total duration of the discharge segment.
$T_{max}$	Maximum temperature observed during the discharge segment.
$t_{T_{max}}$	Time instant when $T_{max}$ is reached.
$IC_{peak}$	Maximum value of the IC curve.
$IC_{peak\ v}$	Voltage at which $IC_{peak}$ occurs.
$IC_{area}$	Integral of the IC curve over $[V_{min}, V_{max}]$ , summarizing cumulative response.
$IC_{centroid}$	Voltage centroid of the IC curve

### 5-2 시퀀스 생성

본 연구에서는 방전 구간 시계열 데이터를 BiLSTM 인코더에 입력하기 위해, 시간축으로 측정된 데이터를 사이클 단위 시퀀스로 재구성하였다. 각 사이클  $c$ 에 대해 입력 시퀀스는 시간( $t$ ), 전압( $V$ ), 전류( $I$ ), 온도( $T$ )와 IC 과정에서 계산된  $dQ/dV$  및 이에 대응하는  $V_g$ 를 포함한다. 또한 각 시퀀스에 사이클 식별을 위한  $c$ 를 추가하여, 모델이 사이클 진행 정보를 함께 활용할 수 있도록 하였다. 데이터셋마다 방전 구간 길이가 달라 입력 길이를 통일할 필요가 있다. 본 연구에서는 전체 데이터에서 가장 짧은 시퀀스  $L$ 을 가진 셀을 기준으로 시계열 입력을 동일 길이로 샘플링하였다. 식 (12)는 실험  $k$ 의 사이클  $c$ 에 대한 LSTM 입력 시퀀스 행렬이다. 여기서  $F_g$ 는 입력 차원이며, 본 연구에서는 7개의 입력을 가진다.

$$X_s^{(k,c)} \in \mathbb{R}^{L \times F_s} \quad (12)$$

## VI. 방법론

본 연구에서는 시간적 연속성과 사이클 간 구조적 관계를 동시에 반영하여 SOH를 정밀하게 예측하기 위해, BiLSTM 기반 시계열 인코더와 GAT 기반 그래프 인코더를 결합한 멀티모달 SOH 추정 모델을 제안한다. 제안 모델은 두 모달리티에서 정보를 각각 인코딩한 뒤 이를 통합하여 회귀 예측을 수행하는 구조이다. 전체 프레임워크는 그림 3에 제시하였다. 모델의 전체 처리 절차는 다음과 같다.

1. 시계열 입력  $X_s$ 를 BiLSTM 인코더에 입력하여 방전 구간의 동적 패턴을 요약한 시계열 임베딩  $z_s$ 를 생성한다.
2. 그래프 입력  $X_g$ 를 GAT 인코더에 입력하여 사이클 간 관계 구조를 반영한 그래프 임베딩  $z_g$ 를 생성한다.
3. 생성된 두 임베딩  $z_s, z_g$ 를 결합하여 시계열 정보와 구조 정보를 통합한 표현을 구성한다.
4. 통합 표현을 회귀 모듈에 입력하여 SOH를 예측한다.

### 6-1 GAT

그래프 인코더로는 GAT를 사용하였다. GAT는 사이클 간 관계를 그래프로 표현한 입력  $G^{(k)} = (\nu^{(k)}, e^{(k)})$ 를 기반으로 노드 표현을 학습하며, 각 노드  $\nu^{(k)} \in \nu^{(k)}$ 는 노드 특성  $x_\nu \in \mathbb{R}^{F_s}$ 를 가진다. 전체 노드 특성은  $X_g$ 로 구성되며, 초기 노드 표현은 입력 특성으로부터  $h_\nu^{(0)}$ 은  $x_\nu$ 로 초기화한다. 이후 GAT는 이웃 노드로부터 정보를 집계할 때 이웃별 중요도를 attention 계수로 학습하여, 가중합 형태로 노드 표현을 갱신한다. 레이어  $\ell$ 에서 노드  $\nu$ 의 표현은 식 (13)과 같이 업데이트된다.

$$h_\nu^{(\ell)} = \sigma \left( \sum_{u \in N(\nu) \cup \{\nu\}} \alpha_{\nu u}^{(\ell)} W^{(\ell)} h_u^{(\ell-1)} \right) \quad (13)$$

$h_\nu^{(\ell)}$ 는 레이어  $\ell$ 에서의 노드 표현,  $W^{(\ell)}$ 은 선형 변환 가중치 행렬,  $\sigma(\cdot)$ 는 비선형 활성화 함수이다.  $\alpha_{\nu u}^{(k)}$ 는 노드  $\nu$ 가 이웃 노드  $u$ 로부터 정보를 집계할 때의 attention 계수로, 비정규화 점수  $e_{\nu u}^{(\ell)}$ 를 계산한 뒤 softmax 함수를 활용해 정규화한다. 식 (14)는 노드  $\nu$ 와 이웃 노드  $u$ 의 변환된 표현을 연결한 뒤, 학습 가능한 벡터  $\alpha$ 로 점수를 계산하는 식이다. 이후 노드  $\nu$ 의 이웃 집합  $N(\nu) \cup \{\nu\}$ 에 대해 softmax를 적용하여 attention 계수  $\alpha_{\nu u}^{(\ell)}$ 를 계산하며, 식 (15)를 통해 나타내었다.

본 연구에서는 그래프 입력을 각 실험 단위로 구성하고, 노드 특성  $X_g$ 로부터 노드 간 피어슨 상관관계수 기반 엣지 집합  $e$ 를 생성하였다. 상관관계수 기반 연결은 노드 간 통계적 유사성을 반영하는 구조적 사전 정보를 제공하며, GAT는 해당 구조 위에서 이웃별 정보 전달 비중  $\alpha$ 를 학습함으로써 집계 과정의 유연성을 확보한다. 결과적으로 GAT 인코더는 주변 노드의 정보를 attention 가중치로 반영하도록 학습되어 관계적·구조적 패턴을 포함한 노드 임베딩  $z_g$ 를 얻는다.

$$e_{\nu u}^{(\ell)} = \text{LeakyReLU} \left( a^\top [W^{(\ell)} h_\nu^{(\ell-1)} \| W^{(\ell)} h_u^{(\ell-1)}] \right) \quad (14)$$

$$\alpha_{\nu u}^{(\ell)} = \text{softmax}_u(e_{\nu u}^{(\ell)}) = \frac{\exp(e_{\nu u}^{(\ell)})}{\sum_{m \in N(\nu) \cup \{\nu\}} \{\exp(e_{\nu m}^{(\ell)})\}} \quad (15)$$

### 6-2 BiLSTM

시계열 입력  $X_s$ 를 BiLSTM 인코더에 입력하여, 시간 축의 동적 특성을 반영한 시계열 임베딩을 생성한다. BiLSTM은 시점  $t$ 에서 정방향과 역방향이 은닉 상태를 각각 계산한 뒤 이를 결합하여 출력한다. 식 (16)은 시점  $t$ 에서 입력  $x_t \in X_s$

에 대해 정방향·역방향 LSTM이 각각 은닉 상태  $\vec{h}_t, \overleftarrow{h}_t$ 를 계산하는 BiLSTM의 업데이트 식이다. 식 (17)은 시점  $t$ 의 출력 표현  $h_t$ 를 구성하는 식이다.

$$\vec{h}_t = \text{LSTM}_f(x_t, \vec{h}_{t-1}), \overleftarrow{h}_t = \text{LSTM}_b(x_t, \overleftarrow{h}_{t+1}) \quad (16)$$

$$h_t = [\vec{h}_t \| \overleftarrow{h}_t] \quad (17)$$

$$z_s = \frac{1}{T} \sum_{t=1}^T h_t \quad (18)$$

여기서  $x_t \in \mathbb{R}^F$ 는  $X_s^{(k,c)}$ 의  $t$ 번째 시점 입력,  $h_t$ 는 벡터 연결을 의미한다. BiLSTM 출력  $\{h_t\}_{t=1}^T$ 로부터 시퀀스 전체를 대표하는 시계열 임베딩  $z_s$ 를 구성하여 회귀 헤드의 입력으로 사용하였다. 식 (18)은 시점별 BiLSTM 출력  $h_t$ 를 시간축 평균 풀링으로 요약하여 시퀀스 임베딩  $z_s$ 를 생성하는 식이다. BiLSTM 인코더 출력은 MLP를 통해 예측에 적합한 차원으로 변환되어 시계열 기반 예측 표현으로 사용되며, 그래프 인코더에서 얻은 그래프 임베딩  $z_g$ 과 결합되어 최종 SOH를 추정한다.

### 6-3 예측 회귀 모듈

본 연구에서는 5-1절과 5-2절에서 각각 도출된 그래프 임베딩  $z_g$ 와 시계열 임베딩  $z_s$ 를 결합한 후, 이를 입력으로 하는 다층 퍼셉트론 기반의 회귀 모듈을 통해 최종 SOH 예측을 수행한다. 예측 회귀 모듈을 입력 임베딩을 통합한 벡터에 대해 선형 변환 및 비선형 활성화를 연속적으로 적용하여 최종 출력값을 생성하는 구조로, 식 (19)와 같이 정의된다. 여기서  $o$ 는 모델의 최종 출력인 예측된 SOH 값이며  $[z_g, z_s]$ 는 시계열 인코더와 그래프 인코더에서 각각 얻어진 임베딩 벡터의 연결을 의미한다.  $W$ 와  $b$ 는 회귀 계층의 가중치 행렬과 편향 벡터이며,  $\sigma(\cdot)$ 는 비선형 활성화 함수로서 본 연구에서는 출력값이 정규화 되어야 하는 SOH의 특성을 반영하여 sigmoid 함수를 채택하였다.

$$o = \sigma(W \cdot [z_g, z_s] + b) \tag{19}$$

## Ⅶ. 실험

### 7-1 학습 설정

Oxford, MIT, NASA 데이터셋의 방전 구간 시계열로부터 사이클별 입력을 구성하였다. 각 데이터셋은 셀 단위로 학습, 검증, 평가 집합으로 분할하였으며, 구체적인 분할 구성은 표 3에 제시하였다. 모델 학습 과정에서는 검증 성능을 기준으로 early stopping을 적용하였다. 그래프는 각 셀의 내부 사이클만을 이용하여 구성하였고, 검증 및 평가 셀은 학습 단계에서 사용되지 않도록 분리하였다[30]. 평가 데이터는 최종 성능 산출에만 활용하였다. 또한 통합 데이터셋을 활용함으로써 특정 실험이나 단일 운용 조건에 대한 과도한 의존을 줄이고, 서로 다른 화학계와 운용 프로토콜을 포함하는 환경에서 제안 방법의 적용 가능성을 평가하고자 하였다. 본 설정에서는  $c$ 번째 사이클 입력 ( $X_g^{(k,c)}, X_s^{(k,c)}$ )을 이용하여  $c+1$ 번째 사이클의 SOH를 예측하였으며, 이는 식 (20)으로 정의하였다.

$$\widehat{SOH}_{c+1} = f(X_g^{(k,c)}, X_s^{(k,c)}) \tag{20}$$

표 3. 훈련 및 실험 분할 구성

Table 3. Training and testing data splits across datasets

	Train	Test	Validation
Oxford Battery Degradation Dataset	Cell 5 ~ 8	Cell 1, 2	Cell 3, 4
MIT Fast-Charging Dataset	Cell 20 ~39	Cell 1 ~ 10	Cell 11 ~19
NASA PCoE Li-ion Battery Aging Dataset	B0007, B0018	B0005	B0006

### 7-2 손실 함수 및 최적화

모델 학습은 예측값  $\widehat{SOH}$ 와 정답 SOH 간의 오차를 최소화하는 방식으로 수행되었다. 학습 손실 함수로는 RMSE (root mean squared error)를 사용하였으며, 평가 샘플 수를  $N$ 이라 할 때 RMSE는 식 (21)과 같다. 최적화 알고리즘은 Adam(Adaptive Moment Estimation)을 사용하였다.

$$L_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\widehat{SOH}_i - SOH_i)^2} \tag{21}$$

### 7-3 평가 지표

모델 성능 평가는 MAPE(Mean Absolute Percentage Error)와 MBE(Mean Bias Error)를 사용하여 예측 정확도와 예측 편향을 함께 분석하였다. MAPE는 상대 오차 기반 지표로서 예측의 백분율 오차 수준을 정량화하며, 식 (22)와 같이 정의된다. 또한 MBE는 예측 평균 편향을 나타내는 지표로, 모델이 전반적으로 과대·과소 추정하는 경향을 확인하기 위해 사용한다. MBE는 식 (23)과 같이 정의된다. MBE가 양수이면 평균적으로 과대 추정, 음수이면 평균적으로 과소 추정 경향을 의미한다.

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{\widehat{SOH}_i - SOH_i}{SOH_i} \right| \tag{22}$$

$$MBE = \frac{1}{N} \sum_{i=1}^N (\widehat{SOH}_i - SOH_i) \tag{23}$$

### 7-4 비교 모델

제안 모델의 성능을 정량적으로 검증하기 위해 본 연구에서는 그래프 단일 모달 모델, 시계열 단일 모달 모델, 그리고 시계열-그래프 결합 멀티모달 모델을 비교군으로 설정하였다. 비교군 구성의 목적은 두 가지이다. 첫째, 단일 모달 baseline을 통해 각 입력 표현이 SOH 예측에 기여하는 정도를 분리하여 확인하고자 하였다. 둘째, 멀티모달 결합 모델을 통해 두 정보의 결합이 추가적인 성능 향상으로 이어지는지를 평가하고자 하였다. 공정한 비교를 위해 모든 모델에 동일한 데이터 분할, 특징 추출 및 전처리 절차, 그리고 동일한 평가 지표를 적용하여 예측 정확도와 편향 특성을 함께 비교하였다. 다만 그래프 기반 모델의 경우에는 각 모델의 정보 집계 방식 차이를 반영하여 그래프 입력 구성을 일부 달리하였다. GAT와 GCN 모델에는 각 노드가 자기 자신의 특성까지 함께 반영할 수 있도록 self-loop를 포함하였으며, GraphSAGE에는 self-loop를 별도로 추가하지 않았다. 이는 비교 조건의 일관성을 유지하면서도 각 그래프 신경망 구조의 특성에 부합하도록 입력 그래프를 구성하기 위함이다.

표 4. 그래프 단일 모달 SOH 예측 모델 성능 비교

Table 4. Performance comparison of single-modality graph models for SOH prediction

$\tau$	GCN			GAT			GraphSAGE		
	RMSE (%)	MAPE (%)	MBE (%)	RMSE (%)	MAPE (%)	MBE (%)	RMSE (%)	MAPE (%)	MBE (%)
0.3	0.0229 ± 0.0008	1.9289 ± 0.1448	0.0016 ± 0.0048	0.0180 ± 0.0014	1.5587 ± 0.1458	0.0014 ± 0.0016	0.0269 ± 0.0009	2.3158 ± 0.0825	0.0042 ± 0.0029
0.5	0.0238 ± 0.0004	2.0271 ± 0.1510	0.0005 ± 0.0054	0.0197 ± 0.0016	1.7749 ± 0.1513	-0.0009 ± 0.0025	0.0269 ± 0.0021	2.4500 ± 0.2787	-0.0030 ± 0.0057
0.7	0.0222 ± 0.0005	1.9091 ± 0.0766	-0.0019 ± 0.0050	0.0190 ± 0.0021	1.7035 ± 0.2505	-0.0025 ± 0.0041	0.0222 ± 0.0017	2.0069 ± 0.1682	-0.0018 ± 0.0049

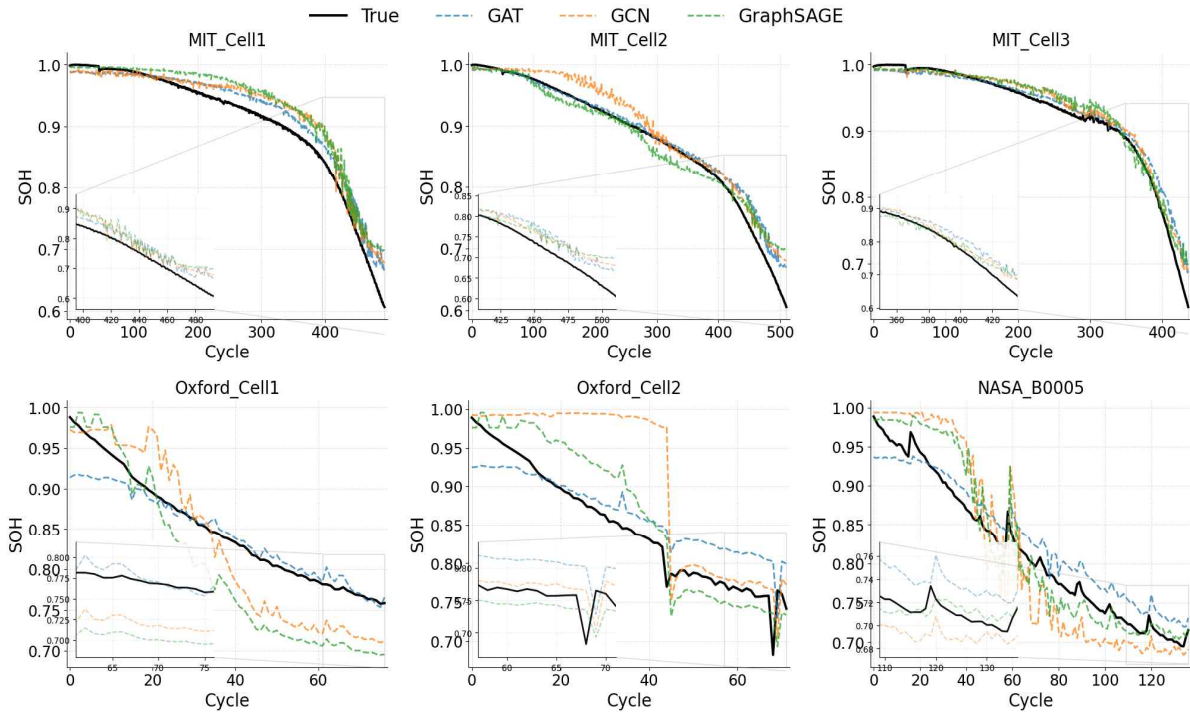


그림 4. 그래프 단일 모달 모델의 예측 SOH와 실제 SOH 비교

Fig. 4. Predicted vs. true SOH for single-modality graph models

## VIII. 실험 결과

### 8-1 그래프 단일 모달 비교군 및 실험 결과

그래프 기반 단일 모달 baseline으로 GCN, GAT, GraphSAGE를 사용하였다. 세 모델은 모두 그래프 상에서 이웃 노드의 정보를 집계해 노드 표현을 갱신하지만, 정보 집계 방식에는 차이가 있다. GAT는 attention 메커니즘을 통해 이웃 노드의 중요도를 학습하여 가중 집계를 수행하고, GCN은 정규화된 인접 행렬에 기반한 선형 집계를 적용한다. GraphSAGE는 이웃 샘플링과 집계 함수를 통해 노드 표현을 구성한다. 따라서 동일한 그래프 입력 조건에서 집계 메커니즘의 차이와 임계값  $\tau$  변화가 SOH 예측 성능에 미치는 영향을 비교할 수 있다. 그래프 연결은 노드 특성 간 유사도를 반영하도록 피어슨 상관계수 기반으로 정의하였으며, 상관계수 임계값  $\tau$ 를 0.3, 0.5, 0.7로 변경하여 연결 강도에 따른 성능 변화

를 분석하였다. 표 4는 각  $\tau$  값에 대해 5회 반복 실험을 수행한 뒤, 성능 지표를 평균과 표준편차로 정리한 결과이다. 실험 결과, 전반적으로 GAT가 가장 우수한 성능을 보였다. 특히  $\tau = 0.3$ 에서 RMSE 0.018±0.0014, MAPE 1.5587±0.1458, MBE 0.0014±0.0016을 기록하여 전체 조건 중 가장 낮은 RMSE와 MAPE를 나타냈다. GCN은  $\tau = 0.7$ 에서 RMSE 0.0222±0.0005, MAPE 1.9091±0.0766으로 비교적 준수한 성능을 보였으나, 전반적으로 GAT보다 높은 오차를 보였다. GraphSAGE는  $\tau = 0.7$ 에서 RMSE 0.0222±0.0017, MAPE 2.0069±0.1682, MBE -0.0018±0.0049를 기록하여  $\tau = 0.3, 0.5$ 보다 개선된 성능을 보였지만, 세 모델 중 가장 큰 오차를 나타냈다. 이러한 결과는 attention 기반 이웃 집계 방식을 사용하는 GAT가 상관 그래프로 표현된 구조적 관계 정보를 보다 효과적으로 반영할 수 있음을 시사한다. 그림 4는 최소 MAPE를 기록한 그래프 단일 모달 SOH 예측 모델의 결과와 실제값을 비교한 것이다.

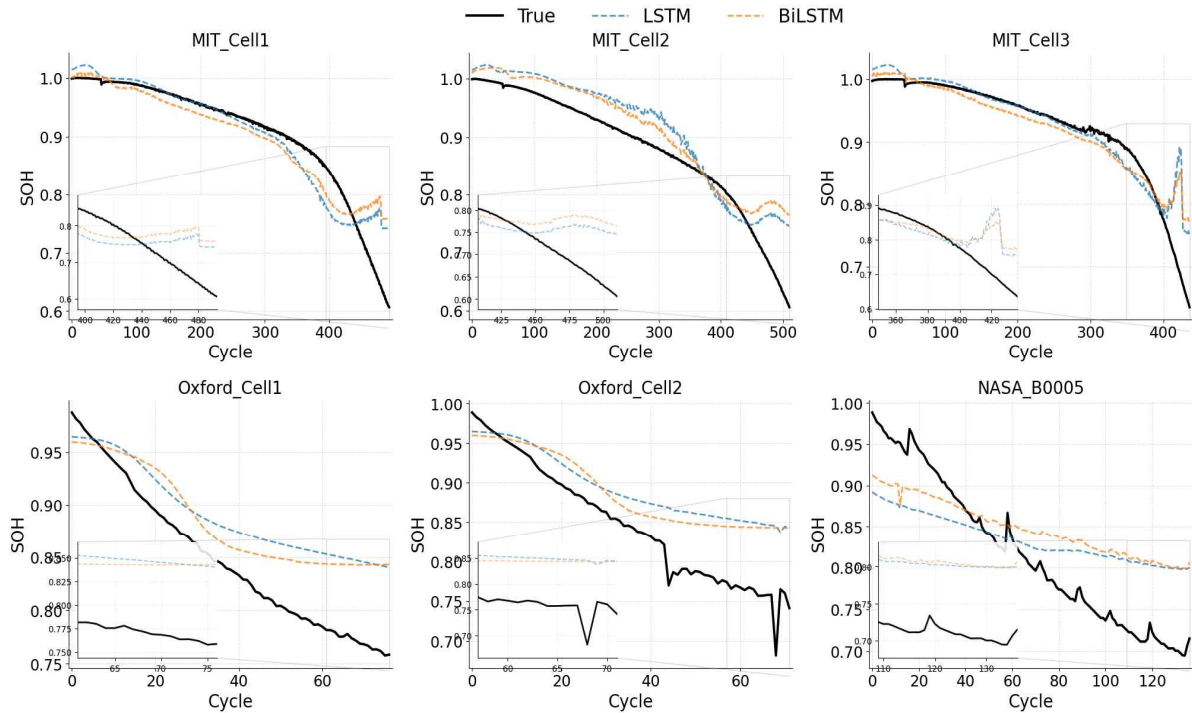


그림 5. 시계열 단일 모달 모델의 예측 SOH와 실제 SOH 비교  
**Fig. 5.** Predicted vs. true SOH for single-modality time-series models

8-2 시계열 단일 모달 비교군 및 실험 결과

시계열 기반 단일 모달 baseline으로 LSTM과 BiLSTM을 사용하였다. 두 모델은 방전 구간의 시계열 신호를 입력으로 받아 사이클 단위 SOH를 직접 예측하는 대표적인 구조로, 제안 모델에서 시계열 인코더가 시간적 패턴을 얼마나 효과적으로 요약하는지를 평가하기 위한 기준선으로 활용하였다. 표 5는 두 시계열 단일 모달 모델을 5회 반복 실험한 결과를 정량적으로 성능 비교한 것이다. BiLSTM은 순방향과 역방향 은닉 상태를 함께 사용하므로, 단방향 LSTM 대비 시계열의 전후 문맥 정보를 추가로 반영했을 때의 성능 변화를 확인할 수 있다. 실험 결과, BiLSTM은 LSTM 대비 RMSE와 MAPE에서 소폭 개선된 성능을 보였다. LSTM은 RMSE  $0.0554 \pm 0.0010$ , MAPE  $4.5099 \pm 0.1823$ , MBE  $0.0080 \pm 0.0038$ 를 기록하였으며, BiLSTM은 RMSE  $0.0549 \pm 0.0011$ , MAPE  $4.4644 \pm 0.0964$ , MBE  $0.0099 \pm 0.0035$ 를 기록하였다. BiLSTM은 LSTM보다 RMSE와 MAPE가 더 낮아 예측 정확도 측면에서 우수한 성능을 보였으나, MBE는 소폭 증가하여 평균 예측 편향은 큰 것으로 나타났다. 이는 BiLSTM이 양방향 문맥 정보를 활용함으로써 시계열 내 열화 패턴을 보다 효과적으로 반영할 수 있음을 시사한다. 그림 5는 단일 시계열 모델 가운데 가장 낮은 RMSE와 MAPE를 기록한 BiLSTM의 예측 SOH와 실제 SOH를 비교한 결과를 제시한다.

표 5. 시계열 단일 모달 SOH 예측 모델 성능 비교  
**Table 5.** Performance comparison of single-modality time-series models for SOH prediction

Model	LSTM	BiLSTM
RMSE (%)	$0.0554 \pm 0.0010$	<b><math>0.0549 \pm 0.0011</math></b>
MAPE (%)	$4.5099 \pm 0.1823$	<b><math>4.4644 \pm 0.0964</math></b>
MBE (%)	$0.0080 \pm 0.0038$	$0.0099 \pm 0.0035$

8-3 멀티 모달 비교군 및 실험 결과

멀티모달 비교군은 시계열 인코더와 그래프 인코더의 조합으로 구성하였다. 각 멀티모달 모델은 (i) 시계열 인코더가 방전 구간의 동적 패턴을 요약하여 생성한 시계열 임베딩과, (ii) 그래프 인코더가 사이클 간 관계 구조를 반영하여 생성한 그래프 임베딩을 결합한 뒤 SOH를 예측하도록 설계하였다. 이를 통해 시계열 기반 정보와 관계 기반 정보를 동시에 활용하는 결합 전략의 효과를 정량적으로 비교하고자 하였다. 조합별 성능은 각  $\tau$  설정에 대해 5회 반복 실험한 뒤 평균과 표준편차로 정리하였으며, LSTM 기반 결합 모델의 결과는 표 6, BiLSTM 기반 결합 모델의 결과는 표 7에 제시하였다. 또한 최소 MAPE를 기록한 설정의 예측값과 실제값 비교 결과는 그림 6에 제시하였다. 실험 결과, 전체 멀티모달 비교군 가운데 가장 우수한 성능은 BiLSTM+ GAT의  $\tau = 0.5$  조건에서 확인되었다. 해당 조합은 RMSE  $0.0167 \pm 0.0007$ , MAPE  $1.4710 \pm 0.0786$ , MBE  $0.0014 \pm 0.0015$ 를 기록하여 정

표 6. LSTM 기반 멀티모달 SOH 예측 모델 성능 비교

Table 6. Performance comparison of LSTM-based multimodal models for SOH prediction

$\tau$	LSTM+GCN			LSTM+GAT			LSTM+GRAPHSAGE		
	RMSE (%)	MAPE (%)	MBE (%)	RMSE (%)	MAPE (%)	MBE (%)	RMSE (%)	MAPE (%)	MBE (%)
0.3	0.0269 ± 0.0021	2.4246 ± 0.1619	-0.0099 ± 0.0065	0.0188 ± 0.0017	1.6742 ± 0.2099	-0.0040 ± 0.0049	0.0272 ± 0.0022	2.5310 ± 0.3362	-0.0028 ± 0.0108
0.5	0.0269 ± 0.0026	2.3957 ± 0.3944	-0.0054 ± 0.0115	0.0198 ± 0.0029	1.7833 ± 0.2560	-0.0069 ± 0.0043	0.0239 ± 0.0020	2.2274 ± 0.2927	-0.0070 ± 0.0038
0.7	0.0230 ± 0.0027	2.0834 ± 0.2957	-0.0018 ± 0.0079	0.0190 ± 0.0009	1.7089 ± 0.1101	-0.0067 ± 0.0023	0.0239 ± 0.0029	2.2144 ± 0.4027	-0.0093 ± 0.0050

표 7. BiLSTM 기반 멀티모달 SOH 예측 모델 성능 비교

Table 7. Performance comparison of BiLSTM-based multimodal models for SOH prediction

$\tau$	BiLSTM+GCN			BiLSTM+GAT			BiLSTM+GRAPHSAGE		
	RMSE (%)	MAPE (%)	MBE (%)	RMSE (%)	MAPE (%)	MBE (%)	RMSE (%)	MAPE (%)	MBE (%)
0.3	0.0269 ± 0.0050	2.4788 ± 0.5871	-0.0148 ± 0.0053	0.0176 ± 0.0005	1.6007 ± 0.0805	-0.0056 ± 0.0034	0.0270 ± 0.0029	2.6567 ± 0.3247	-0.0115 ± 0.0047
0.5	0.0269 ± 0.0047	2.5129 ± 0.5306	-0.0105 ± 0.0070	0.0167 ± 0.0007	1.4710 ± 0.0786	0.0014 ± 0.0015	0.0239 ± 0.0025	2.2432 ± 0.1594	-0.0036 ± 0.0054
0.7	0.0239 ± 0.0023	2.2189 ± 0.2476	-0.0049 ± 0.0087	0.0170 ± 0.0014	1.5277 ± 0.1453	-0.0047 ± 0.0026	0.0223 ± 0.0007	2.0170 ± 0.1019	-0.0033 ± 0.0058

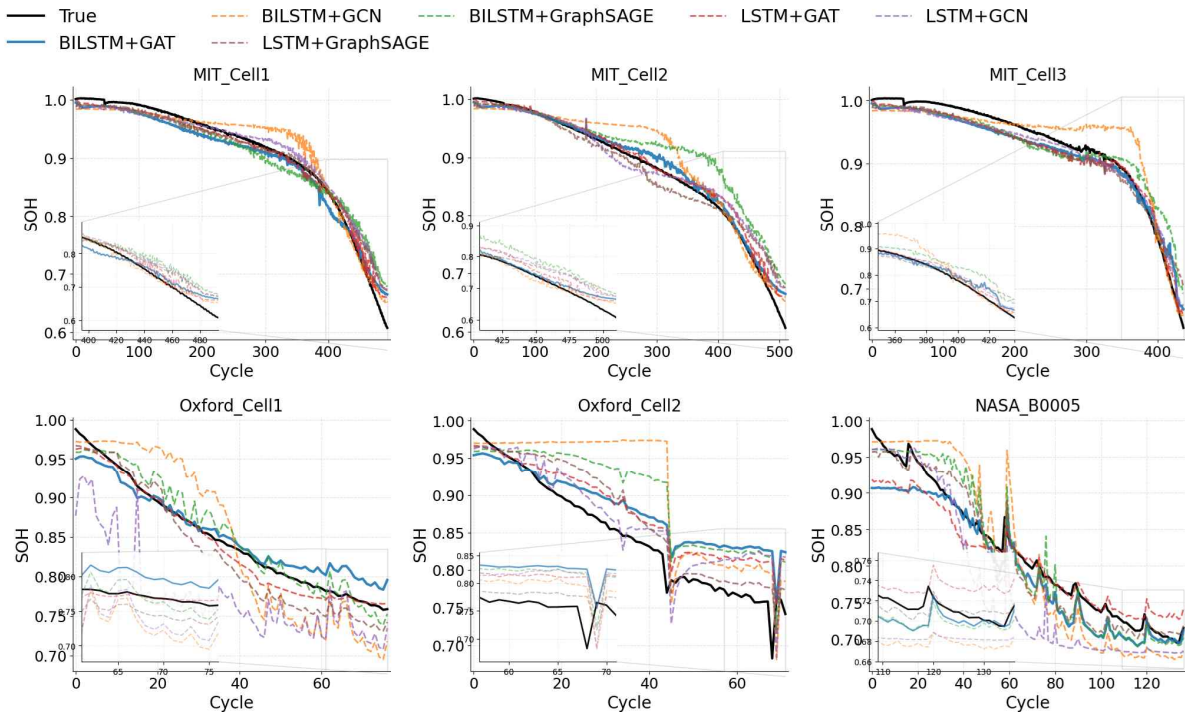


그림 6. 멀티모달 모델의 예측 SOH와 실제 SOH 비교

Fig. 6. Predicted vs. true SOH for multimodal models

확도와 편향 측면에서 모두 가장 우수한 결과를 나타냈다. 이는 BiLSTM이 시계열의 전후 문맥 정보를 함께 반영하여 열화 패턴을 보다 풍부하게 요약하고, GAT가 attention 기반 이웃 집계를 통해 중요한 관계 정보를 효과적으로 반영한 결과로 해석할 수 있다. LSTM 기반 결합 모델에서도 LSTM+GAT가 가장 우수한 경향을 보였다. 특히  $\tau=0.3$ 에

서 RMSE  $0.0188 \pm 0.0017$ , MAPE  $1.6742 \pm 0.2099$ , MBE  $-0.0040 \pm 0.0049$ 를 기록하여 LSTM 기반 멀티모달 조합 중 가장 낮은 RMSE와 MAPE를 보였다.  $\tau=0.7$ 에서도 RMSE  $0.0190 \pm 0.0009$ , MAPE  $1.7089 \pm 0.1101$ 로 유사하게 우수한 성능을 유지하였다. 반면 LSTM+GCN은  $\tau=0.7$ 에서 RMSE  $0.0230 \pm 0.0027$ , MAPE  $2.0834 \pm$

0.2957로 가장 나은 성능을 보였으나, GAT 결합보다 오차가 컸다. LSTM+ GraphSAGE 역시  $\tau = 0.7$ 에서 RMSE  $0.0239 \pm 0.0029$ , MAPE  $2.2144 \pm 0.4027$ 을 기록하여 일부 개선된 성능을 보였지만, 전반적으로는 GAT 결합보다 낮은 성능을 나타냈다. BiLSTM 기반 결합 모델에서는 GAT 결합의 우수성이 더욱 뚜렷하게 나타났다. BiLSTM+ GAT는  $\tau = 0.3$ 에서 RMSE  $0.0170 \pm 0.0014$ , MAPE  $1.5277 \pm 0.1453$ 을 기록하였고,  $\tau = 0.5$ 에서는 RMSE  $0.0167 \pm 0.0007$ , MAPE  $1.4710 \pm 0.0786$ 을 기록하여 모든 BiLSTM 기반 조합 중 가장 낮은 오차를 보였다. 반면 BiLSTM+ GCN은  $\tau = 0.3, 0.5$ 에서 RMSE가 모두 0.0269 수준으로 높게 나타났으며, BiLSTM+ GraphSAGE도  $\tau = 0.5$ 에서 RMSE  $0.0239 \pm 0.0025$ , MAPE  $2.2432 \pm 0.1594$ 를 기록하여 GAT 대비 큰 오차를 보였다. 종합하면, 멀티모달 결합이 항상 성능 향상으로 이어지는 것은 아니며, 시계열 표현과 그래프 표현 사이의 정합성, 그리고 그래프 인코더의 관계 반영 방식이 성능에 중요한 영향을 미치는 것으로 해석된다. 임계값  $\tau$ 의 영향 역시 조합에 따라 다르게 나타났다. BiLSTM+ GAT는  $\tau = 0.5$ 에서 가장 우수한 성능을 보인 반면, LSTM+ GAT는  $\tau = 0.3$ 에서 가장 낮은 RMSE와 MAPE를 기록하였다. 이는 그래프 연결 강도의 최적 수준이 시계열 인코더의 구조에 따라 달라질 수 있음을 시사한다. 전반적으로 attention 기반 집계 방식을 사용하는 GAT가 GCN이나 GraphSAGE보다 관계 정보를 더 효과적으로 활용하여 안정적인 성능을 제공하는 것으로 나타났다.

## IX. 결 론

본 연구에서는 방전 구간 시계열 정보와 ICA 기반 상관 그래프 정보를 결합한 멀티모달 SOH 예측 프레임워크를 제안하였다. 실험 결과, 멀티모달 결합이 항상 단일 모달보다 우수한 성능으로 이어지는 않았으나, BiLSTM+ GAT 조합은  $\tau = 0.5$ 에서 RMSE  $0.0167 \pm 0.0007$ , MAPE  $1.4710 \pm 0.0786$ , MBE  $0.0014 \pm 0.0015$ 를 기록하며 전체 비교군 중 가장 우수한 성능을 나타냈다. 이는 BiLSTM이 방전 시계열의 장단기 문맥 정보를 효과적으로 반영하고, GAT가 셀 내부 사이클 간 관계에서 중요한 이웃 정보를 선택적으로 집계함으로써 SOH 추정 정확도 향상에 기여할 수 있음을 보여준다. 또한 본 연구는 셀 단위로 분리된 학습, 검증, 평가 집합을 기반으로 수행되었으며, 학습에 사용되지 않은 셀에 대해서도 제안 모델이 유의미한 예측 성능을 보일 수 있음을 확인하였다. 제한된 실험 셀 수와 공개 데이터셋 기반 검증이라는 제약으로 인해 실제 운용 환경 전반에 대한 일반화 가능성을 충분히 논하기에는 한계가 있다. 향후에는 다양한 셀군과 운용 조건을 포함한 대규모 환경에서 셀 단위 일반화 성능을 추가로 검증하고, 그래프 구성 방식과  $\tau$  설정의 영향에 대한 체계

적 분석, BMS 적용을 위한 모델 경량화 및 도메인 적응 기법을 함께 검토할 예정이다.

## 감사의 글

이 논문은 2023학년도 경북대학교 연구년 교수 연구비에 의하여 연구되었음.

## 참고문헌

- [1] A. O. Ali, O. Abdelrehim, M. M. Saafan, M. R. Elmarghany, and A. M. Hamed, "Comprehensive Review of Battery Management Systems for Electric Vehicles: Thermal Management, Charging Strategies, and Emerging Technologies," *Journal of Power Sources*, Vol. 658, 238269, December 2025. <https://doi.org/10.1016/j.jpowsour.2025.238269>
- [2] D. H. Jeon, S. Kim, and R. Hempelmann, "Degradation Factors of Commercial Lithium-Ion Batteries," *Applied Physics Reviews*, Vol. 12, No. 3, 031320, September 2025. <https://doi.org/10.1063/5.0255290>
- [3] P. A. Zavareh, A. N. Matam, and K. Shah, "Heterogeneous Aging in a Multi-Cell Lithium-Ion Battery System Driven by Manufacturing-Induced Variability in Electrode Microstructure: A Physics-Based Simulation Study," *Energy Advances*, Vol. 5, No. 2, pp. 202-223, November 2025. <https://doi.org/10.1039/D5YA00182J>
- [4] S. V. Kulkarni, G. Arjun, S. Gupta, R. Sinha, and A. Shukla, "Advanced Battery Diagnostics for Electric Vehicles Using CAN Based BMS Data with EKF and Data Driven Predictive Models," *Scientific Reports*, Vol. 15, 32848, September 2025. <https://doi.org/10.1038/s41598-025-18042-6>
- [5] F. Mohammadi, "Lithium-Ion Battery State-of-Charge Estimation Based on an Improved Coulomb-Counting Algorithm and Uncertainty Evaluation," *Journal of Energy Storage*, Vol. 48, 104061, April 2022. <https://doi.org/10.1016/j.est.2022.104061>
- [6] G. Luo, Y. Zhang, and A. Tang, "Capacity Degradation and Aging Mechanisms Evolution of Lithium-Ion Batteries Under Different Operation Conditions," *Energies*, Vol. 16, No. 10, 4232, May 2023. <https://doi.org/10.3390/en16104232>
- [7] W. Wu, Z. Chen, W. Liu, and E. Pan, "Correlation Based-Graph Neural Network for Health Prognosis of Non-Fully Charged and Discharged Lithium-Ion Batteries," *Journal of Power Sources*, Vol. 629, 235984, February 2025. <https://doi.org/10.1016/j.jpowsour.2024.235984>

- [8] Y. Zhang, A. Wang, C. Zhang, P. He, K. Shao, K. Cheng, and Y. Zhou, "State-of-Health Estimation for Lithium-Ion Batteries via Incremental Energy Analysis and Hybrid Deep Learning Model," *Batteries*, Vol. 11, No. 6, 217, June 2025. <https://doi.org/10.3390/batteries11060217>
- [9] C. Zhu, L. Sun, C. Chen, J. Tian, W. Shen, and R. Xiong, "Lithium-Ion Battery Degradation Diagnosis and State-of-Health Estimation with Half Cell Electrode Potential," *Electrochimica Acta*, Vol. 459, 142588, August 2023. <https://doi.org/10.1016/j.electacta.2023.142588>
- [10] S. Ansari, M. A. Hannan, A. Ayob, M. G. M. Abdolrasol, and M. A. Dar, "Co-Estimation of State of Health and Remaining Useful Life for Lithium-Ion Batteries Using a Hybrid Optimized Framework," *Journal of Energy Storage*, Vol. 105, 114711, January 2025. <https://doi.org/10.1016/j.est.2024.114711>
- [11] A. Krupp, E. Ferg, F. Schuldt, K. Derendorf, and C. Agert, "Incremental Capacity Analysis as a State of Health Estimation Method for Lithium-Ion Battery Modules with Series-Connected Cells," *Batteries*, Vol. 7, No. 1, 2, December 2020. <https://doi.org/10.3390/batteries7010002>
- [12] Z. Xu, J. Wang, P. D. Lund, and Y. Zhang, "Estimation and Prediction of State of Health of Electric Vehicle Batteries Using Discrete Incremental Capacity Analysis Based on Real Driving Data," *Energy*, Vol. 225, 120160, June 2021. <https://doi.org/10.1016/j.energy.2021.120160>
- [13] M.-S. Park, J. S. Kim, and B. W. Kim, "Study on Lithium-Ion Battery SOH Estimation Based on Incremental Capacity Analysis and Deep Learning," *The Transactions of the Korean Institute of Electrical Engineers*, Vol. 73, No. 2, pp. 349-357, 2024 <https://doi.org/10.5370/KIEE.2024.73.2.349>
- [14] Y. Kwon, G. Kwon, D. Lee, and D. Lee, "SOH Prediction of Lithium-Ion Batteries Using Optimized Deep Learning Ensemble Models," *Journal of Society of Korea Industrial and Systems Engineering*, Vol. 48, No. 2, pp. 132-143, 2025. <https://doi.org/10.11627/jksie.2025.48.2.132>
- [15] L. Ren, J. Dong, X. Wang, Z. Meng, L. Zhao, and M. J. Deen, "A Data-Driven Auto-CNN-LSTM Prediction Model for Lithium-Ion Battery Remaining Useful Life," *IEEE Transactions on Industrial Informatics*, Vol. 17, No. 5, pp. 3478-3487, May 2021. <https://doi.org/10.1109/TII.2020.3008223>
- [16] Q. Wang, X. Cai, M. Ye, D. U. Sauer, and W. Li, "Transferable Data-Driven Capacity Estimation for Lithium-Ion Batteries with Deep Learning: A Case Study from Laboratory to Field Applications," *Applied Energy*, Vol. 350, 121747, November 2023. <https://doi.org/10.1016/j.apenergy.2023.121747>
- [17] W. H. Kim, Y. M. Chung, and B. Stinner, "State of Health Prediction of Lithium-Ion Batteries with Adaptive Loss-Based Graph Neural Network," *Journal of Energy Storage*, Vol. 124, 116637, July 2025. <https://doi.org/10.1016/j.est.2025.116637>
- [18] W. Luan, H. Cai, X. Wang, and B. Zhao, "State of Health for Lithium-Ion Batteries Based on Explainable Feature Fragments via Graph Attention Network and Bi-Directional Gated Recurrent Unit," *Sensors*, Vol. 25, No. 19, 5953, September 2025. <https://doi.org/10.3390/s25195953>
- [19] D. Howey and C. Birkl, Oxford Battery Degradation Dataset 1, University of Oxford, 2017. <https://doi.org/10.5287/bodleian:KO2kdmYgG>
- [20] K. A. Severson, P. M. Attia, N. Jin, N. Perkins, B. Jiang, Z. Yang, ... and R. D. Braatz, "Data-Driven Prediction of Battery Cycle Life Before Capacity Degradation," *Nature Energy*, Vol. 4, pp. 383-391, March 2019. <https://doi.org/10.1038/s41560-019-0356-8>
- [21] B. Saha and K. Goebel, Battery Data Set, NASA Prognostics Data Repository, NASA Ames Research Center, Moffett Field: CA, 2007. <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>
- [22] S. Evro, A. Ajumobi, D. Mayon, and O. S. Tomomewo, "Navigating Battery Choices: A Comparative Study of Lithium Iron Phosphate and Nickel Manganese Cobalt Battery Technologies," *Future Batteries*, Vol. 4, 100007, December 2024. <https://doi.org/10.1016/j.fub.2024.100007>
- [23] M. Dubarry and D. Anseán, "Best Practices for Incremental Capacity Analysis," *Frontiers in Energy Research*, Vol. 10, 1023555, October 2022. <https://doi.org/10.3389/fenrg.2022.1023555>
- [24] L. Su, S. Tao, Y. Chen, C. Zou, and X. Zhang, "Incremental Capacity Feature Selection for Lithium-Ion Battery State of Health Estimation Considering Estimation Capability and Efficiency," *Cell Reports Physical Science*, Vol. 7, No. 2, 103083, February 2026. <https://doi.org/10.1016/j.xcrp.2025.103083>
- [25] Y. Fan, J. Qiu, S. Wang, X. Yang, D. Liu, and C. Fernandez, "Incremental Capacity Curve Health-Indicator Extraction Based on Gaussian Filter and Improved Relevance Vector Machine for Lithium-Ion Battery Remaining Useful Life Estimation," *Metals*, Vol. 12, No. 8, 1331, August 2022. <https://doi.org/10.3390/met12081331>
- [26] X. Feng, C. Weng, X. He, L. Wang, D. Ren, L. Lu, ... and M. Ouyang, "Incremental Capacity Analysis on Commercial Lithium-Ion Batteries Using Support Vector Regression: A Parametric Study," *Energies*, Vol. 11, No. 9,

2323, September 2018. <https://doi.org/10.3390/en11092323>

[27] D.-I. Stroe and E. Schaltz, "Lithium-Ion Battery State-of-Health Estimation Using the Incremental Capacity Analysis Technique," *IEEE Transactions on Industry Applications*, Vol. 56, No. 1, pp. 678-685, February 2020. <https://doi.org/10.1109/TIA.2019.2955396>

[28] X.-Y. Yao, G. Chen, M. Pecht, and B. Chen, "A Novel Graph-Based Framework for State of Health Prediction of Lithium-Ion Battery," *Journal of Energy Storage*, Vol. 58, 106437, February 2023. <https://doi.org/10.1016/j.est.2022.106437>

[29] W. Wu, Z. Chen, W. Liu, and E. Pan, "Correlation Based-Graph Neural Network for Health Prognosis of Non-Fully Charged and Discharged Lithium-Ion Batteries," *Journal of Power Sources*, Vol. 629, 235984, February 2025. <https://doi.org/10.1016/j.jpowsour.2024.235984>

[30] M. Flores, M. Soliz, and R. A. Mollineda, "Graph neural networks for Soil Organic Carbon Estimation: Data-Efficient Modeling of multimodal Spatial dependencies," *Machine Learning with Applications*, Vol. 24, pp. 100878, June 2026. <https://doi.org/10.1016/j.mlwa.2026.100878>



**이동호(Dongho Lee)**

2025년 : 경북대학교 융복합시스템공학부 공학사

2025년~현 재: 경북대학교 융복합시스템공학과 석사과정  
※ 관심분야 : 임베디드 시스템, 시계열 데이터 분석, 이차전지 등



**박경욱(Gyeonguk Park)**

2023년 : 경북대학교 융복합시스템공학부 공학사

2023년~현 재: 경북대학교 융복합시스템공학과 석사과정  
※ 관심분야 : AI응용 최적화, 이차전지, AI기반 이상탐지 등



**Muhammad Ihza Febriyan Pagri**

2024년: 경북대학교 융복합시스템공학과 공학석사

2024년~현 재: 경북대학교 융복합시스템공학과 박사과정  
※ 관심분야 : 강화학습, 지능형 에너지관리시스템, 이차전지 등



**서동준(Dongjun Suh)**

2007년 : KAIST 공학석사  
2014년 : KAIST 공학박사

2014년~2015년: KAIST IT융합연구소 연구조교수  
2015년~2018년: KISTI 선임연구원  
2018년~현 재: 경북대학교 융복합시스템공학과 부교수  
※ 관심분야 : 산업AI응용, 에너지AI응용, AI기반 이상탐지 및 최적화분석 등