

ICA 피크 특징과 가우시안 프로세스 회귀를 활용한 부분 충전 조건에서의 리튬이온 배터리 SOH 추정

State of Health Estimation of LIB Under Partial Charging Conditions Using ICA Peak Features and Gaussian Process Regression

천 기 범¹, 김 해 준¹, 신 종 호^{1,*}

(Ki-Bum Cheon¹, Hae-Jun Kim¹, and Jongho Shin^{1,*})

¹Department of Mechanical Engineering, Chungbuk National University

Abstract: Lithium-ion batteries (LIBs) are indispensable energy-storage devices due to their high energy density and long cycle life. The rapid growth of the electric-vehicle sector and the pursuit of greater energy efficiency have intensified the need for reliable techniques that continuously assess battery performance. Because cycling progressively raises internal resistance and induces capacity fade, precise estimation of a cell's State of Health (SOH), which captures its degradation level and remaining useful life, is essential for safe and durable operation. This study proposes a Gaussian Process Regression (GPR) framework for SOH estimation using partial-charge data. To improve estimation accuracy, feature vectors consist of (i) the mean and standard deviation of incremental capacity obtained from partial-charging segments during each CC-CV charging process and (ii) peak magnitudes with corresponding voltages extracted via Incremental Capacity Analysis (ICA), which elucidates degradation patterns. The approach was validated using five SAMSUNG INR 18650-25R cells, four for model training and one for independent testing. Predictive accuracy was quantified using mean absolute error (MAE) and root-mean-square error (RMSE), and the proposed model's estimation uncertainty was quantified and presented as 95% confidence intervals.. The results demonstrate that the proposed GPR model yields accurate and reliable SOH estimates, underscoring its suitability for implementation in on-board battery-management systems.

Keywords: Lithium-Ion battery, state estimation, machine learning, incremental capacity analysis, battery management systems

I. 서론

전기자동차 산업이 급격하게 성장하고 그에 따라 에너지 효율에 관한 관심이 높아지면서 리튬 이온 배터리(Lithium-Ion Battery, LIB)에 대한 수요가 급증하고 있다[1]. LIB는 높은 에너지 밀도, 긴 수명, 높은 출력 특성이라는 장점으로 전기자동차(Electric Vehicle, EV), 에너지 저장 장치(Energy Storage System, ESS), 항공우주 및 군사용 장비 등 다양한 분야에서 필수적인 에너지원으로 활용되고 있다[2,3]. LIB는 충전과 방전을 거듭할수록 최대 충전 용량이 감소하는 열화가 발생하게 된다. 열화가 발생하면 LIB의 내부 저항이 증가하고, 출력 전압이 불안정해지며, 에너지 효율이 저하된다. 이러한 성능 저하는 운용 효율과 시스템 신뢰성에 부정적인 영향을 미친다[4]. 이러한 이유로 LIB를 안전하고 경제적으로 사용하기 위해서는 배터리의 상태를 모니터링하고 관리하는 기술인 배터리 관리 시스템(battery management system, BMS)가 필

수적으로 요구된다.

국내·외로 배터리의 상태를 추정하고 예측하기 위해 다양한 접근을 통해 연구가 수행되고 있으며, 이 중에서도 SOH(State Of Health)가 배터리 수명의 핵심 지표로 활용된다. SOH란 초기 공칭 용량 대비 현재 최대 충전 용량의 비율로 산출되며, 반복된 충·방전으로 인한 열화를 수치화한 지표로서, 다음과 같이 표현된다.

$$SOH(\%) = \frac{Q_{current}}{Q_{nominal}} \times 100 \quad (1)$$

여기서, $Q_{nominal}$ 은 제조사 사양에 명시된 출고 시점의 공칭 용량, $Q_{current}$ 은 실험을 통해 얻은 현재 사이클의 최대 충전 용량이다.

현재까지 SOH를 추정하기 위해 수행된 연구들은 크게 회로 모델 기반 접근법과 대규모 데이터를 활용한 기계학습 기

*Corresponding Author

Manuscript received August 1, 2025; revised September 10, 2025; accepted November 3, 2025

천기범: 충북대학교 기계공학부 대학원생(cjsrlqja99@chungbuk.ac.kr, ORCID[®] 0009-0001-7043-8599)

김해준: 충북대학교 기계공학부 대학원생(skhl1111@chungbuk.ac.kr, ORCID[®] 0009-0004-6561-2953)

신종호: 충북대학교 기계공학부 교수(jshin@cbnu.ac.kr, ORCID[®] 0000-0001-9817-3556)

※ 본 연구는 과학기술정보통신부의 재원으로 한국연구재단, 무인이동체원천기술개발사업단의 지원을 받아 무인이동체원천기술개발사업을 통해 수행되었음(2020M3C1C1A01083162) 및 2025년도 교육부 및 충청북도의 재원으로 충북RISE센터의 지원을 받아 수행된 지역혁신중심 대학지원체계(RISE)의 결과임(2025-RISE-11-014-03).




그림 1. LIB CC-CV 충전 곡선 및 부분 충전 데이터.

Fig. 1. CC-CV charge curve and partial charging segment of LIB.

반 접근법으로 분류된다. 회로 모델 기반 LIB SOH 추정 분야에서는 Thevenin's model, 1차 RC model, 2차 RC model 등, 등가 회로 모델(equivalent circuit model, ECM)을 기반으로 한 기본적인 회로 모델을 기반으로 한 방법이 널리 활용되어왔다[5]. 해당 모델은 칼만 필터(Kalman filter, KF) [6,7], 입자 필터(particle filter) [8,9] 등을 활용하여 LIB의 내부 임피던스 변화, 용량 감소 파라미터 등을 추정하여 SOH를 추정한다. 해당 기법들은 물리적인 해석이 가능하고, 완전 충-방전 데이터 확보가 어려운 실제 차량 환경에서도 쉽게 적용할 수 있다는 장점이 있으나, 파라미터 식별 과정에서 온도, C-rate, 노이즈 등 외란에 매우 민감하다는 한계를 지닌다.

대규모 데이터를 활용한 기계학습 기반 LIB SOH 추정 분야에서는 수집한 전압, 전류, 온도 데이터를 입력으로 삼아 SVM (Support Vector Machine), CNN (Convolutional Neural Network) 등 기계학습 모델을 통해 SOH를 추정하는 연구를 수행해 왔다[11,12]. 해당 기법들은 비선형 열화 패턴을 자동으로 학습하여 물리적인 모델 없이도 다양한 충-방전 데이터에 걸쳐 높은 예측 정확도를 달성할 수 있다는 장점이 있다. CNN이나 LSTM 같은 딥러닝 모델은 시계열 데이터의 시점 간 상관관계를 추정에 반영할 수 있어 더욱 높은 정확도를 갖는다[13,14]. 그러나 이러한 기법들은 보통 전 구간의 데이터 세트를 필요로 한다는 점과 신경망 기반 모델은 내부 학습 과정을 직접 해석하기 어렵고 추정에 대한 인과관계를 파악하기 힘들다는 블랙박스 문제가 존재한다는 점이 있다[15,16].

앞서 언급된 추정 방식들은 다양한 조건 하에서 검증되었다. 그러나 여전히 상태 추정을 위해 개선되어야 할 부분들이 존재한다. 첫 번째로, 회로 모델 기반의 접근법의 경우 외란에 민감하여 실제 환경에서 신뢰도 높은 SOH 추정이 어렵다. 두 번째로, 기계학습 기반 접근법은 전 구간 데이터 획득이 전제되고, 딥러닝 모델의 경우 블랙박스 특성으로 인과관계 해석이 불투명하다는 한계가 있다. 이는 예측 오류가 발생했을 때, 원인을 추적하거나 모델을 교정할 근거를 확보할 수 없다는 문제를 초래한다.

이에 본 연구에서는 무작위 부분 충전 데이터와 ICA 피크 특징을 활용한 가우시안 프로세스 회귀(Gaussian Process Regression, GPR) 기반 LIB SOH 추정 시스템을 제안한다. 해당 시스템은 데이터 부담 경감과 높은 해석 가능성을 갖도록 무작위로 추출한 부분 충전 데이터에서 얻은 충전 용량 변화

량의 평균, 표준편차와 ICA 피크의 값, 위치 총 네 가지 특징을 입력으로 사용한다. 제안된 기법은 전체 충-방전 데이터 확보를 전제로 한 기존 연구와 달리, 임의의 부분 충전 데이터만으로도 SOH 추정이 가능하다[17]. 더 나아가 본 연구는 충-방전 데이터의 통계적 특징과 ICA 피크 특징을 결합하여 입력 벡터를 설계한다. ICA를 통해 추출한 피크는 SOH 변화에 따라 전압-전류 곡선상에서 물리적으로 유의미한 위치 이동을 보이며, 이를 통해 SOH 추정의 정확도와 안정성을 개선하고자 하였다. 한편, GPR의 경우 기계학습 모델과 같이 블랙박스 문제가 존재하나, 불확실성을 함께 제공함으로써 추정 결과에 대한 신뢰성을 판단할 수 있다. 이를 통해 시스템의 안전성과 신뢰성 확보에 기존 기계학습/딥러닝 모델 대비 이점을 갖는다.

본 논문의 구성은 다음과 같다. 2장에서는 실험환경과 연구에 활용된 데이터 정보 및 학습 데이터 생성을 위한 수 있다. 이를 통해 시스템의 안전성과 신뢰성 확보에 기존 기계학습/딥러닝 모델 대비 이점을 갖는다. 데이터 전처리 과정을 상세히 기술한다. 3장에서는 GPR 기반 SOH 추정 모델의 구조를 소개한다. 4장에서는 모델 학습 및 검증 결과를 분석한다. 5장에서는 본 연구에 결론과 향후 연구 및 기대효과에 관해 기술한다.

II. LIB SOH 추정 데이터

본 장에서는 실험을 통해 얻은 데이터로부터 LIB SOH 추정을 위한 충전 데이터를 추출하고 모델 학습을 위한 입력 및 출력 데이터를 전처리하는 과정을 다룬다.

1. LIB 데이터 분석

본 연구는 SAMSUNG INR 18650-25R 8개 셀을 25°C, 습도 60%가 유지되는 항온-항습 챔버에서 0.5C-rate CC-CV 충전 및 임의의 전류로 방전을 900회 이상 반복 수행하며 각 사이클의 전압-전류 시계열 데이터를 수집한다[18]. 모델 학습에 앞서 실험을 통해 수집한 충-방전 시계열 데이터로부터 SOH 추정에 유의미한 입력 변수를 추출하기 위해 다음과 같은 전처리 과정을 수행한다. 우선 전체 CC-CV 충전 구간 중 CC로 충전되는 구간만을 대상으로, 각 사이클에서 전압을 기준으로 삼아 부분 구간으로 나눈 임의의 충전 세그먼트를 정의한다. 본 논문에서는 충전 세그먼트를 부분 충전 데이터라 칭한다. 그림 2는 LIB의 CC-CV 충전 과정과 부분 충전 데이터 정의 과정을 나타내고 있다. 분할 할 전체 전압 구간의 최저 전압은 3.60V, 최고 전압은 4.19V이며, 각 전압의 해상도는 0.01V, 각 부분 충전 데이터의 폭은 0.4V로 설정하였다. 이후 하나의 충전 사이클 데이터를 20개의 부분 충전 데이터로 변환하는 과정을 수행한다[19]. 이렇게 생성된 부분 충전 데이터는 차후 설명할 모델 학습의 입력 데이터를 추출하는 데 활용된다.

2. LIB SOH 추정 데이터 구성

본 절에서는 LIB의 SOH를 추정하기 위해 입-출력 데이터의 전체적인 구성 과정을 소개하고 그 상관관계를 분석한다.

2.1 입력 데이터

입력 데이터는 LIB의 SOH를 추정하기 위해 시스템에 입력되는 데이터로 본 연구에서는 각 부분 충전 데이터로부터 네 가지 핵심 피치를 추출하여 모델 입력 벡터를 구성하였다.




그림 2. LIB 증분 용량 분석 그래프.

Fig. 2. LIB Incremental Capacity Analysis graph.




그림 3. 부분 충전 데이터-피어슨 상관계수 선도.

Fig. 3. Partial charging data Pearson correlation coefficient plot.

2.1.1 용량 변화량 통계

입력 데이터의 특징을 크게 두 가지로 구분할 수 있다. 첫 번째는 충전 용량 변화량(ΔQ)의 통계적 특성을 이용한 특징이다. 여기서 ΔQ 는 각 부분 충전 데이터에서 전류 $I(t)$ 를 시간에 대해 적분하여 산출한 값이다. 이 용량 변화량의 통계적 특성을 나타내는 평균(ΔQ_{mean})과 표준편차(ΔQ_{std})를 입력 데이터로 사용한다.

2.1.2 ICA 피크 특징

용량 변화량의 통계적 특성 외에도, 본 연구에서는 증분 용량 분석 기법(incremental capacity analysis, ICA)를 이용해서 얻어낸 피크에 대한 특징을 입력 데이터로 활용하였다. ICA란 배터리 내부 상태와 열화 정도를 평가하는 분석 기법으로 해당 기법은 배터리 충전 곡선의 변화를 분석하여 배터리 내부 반응에 따른 열화 메커니즘을 해석할 수 있는 특징이 있다. ICA 그래프는 x축이 전압, y축이 용량의 변화율(dQ/dV)로 정의되고 정전류 충전 시 배터리의 단자전압은 같이 표현된다.

$$V(Q) = E_{eq}(Q) + I \times R(Q) + \eta(Q, I, T) \quad (2)$$

여기서, $E_{eq}(Q)$ 는 전극의 평형 전압 함수, $R(Q)$ 는 내부 저항 항, η 는 과전압 항이다. LIB 충전 시 특정 전압 구간에서 리튬이온 삽입·탈리가 급격하게 일어나면 평형 전압 항이 크

게 변동하며 해당 구간에서 피크가 생성되게 된다. 그림 3은 LIB의 열화가 진행됨에 따라 ICA 곡선 형상이 변화하는 양상을 나타내고 있다. 여기서 ICA 피크의 값과 위치는 다음과 같이 정의하였다. 이때, j 는 부분 충전 데이터의 인덱스를 의미하며 본 논문에서는 하나의 충전 사이클을 20개의 부분 충전 데이터로 분할하였으므로 $j = 1, 2, \dots, 20$ 이다. i 는 각 부분 충전 데이터 내부에 있는 이산 데이터 샘플의 인덱스이다.

$$P_j = \max_i \frac{\Delta Q_{ji}}{\Delta V_{ji}}, \quad V_j = \arg \max_i \frac{\Delta Q_{ji}}{\Delta V_{ji}} \quad (3)$$

그림 3에서와 같이 배터리 충전 사이클이 증가함에 따라 피크의 값은 감소하고 위치는 고전압으로 이동하는 경향을 보인다. 피크 값 감소는 배터리 열화 시 내부 저항 증가와 SEI (Solid Electrolyte Interface) 성장에 따른 반응성 저하로 설명된다. 내부 저항 증가 시 CC 충전 구간에서 전압 강하가 커지며 동일 전압 구간에서 전기화학적 반응 효율을 저하시킨다. 또한 SEI 층 성장과 음극 활성물질 소실에 의해 삽입 가능한 리튬의 양이 감소되어 반응성이 감소하여 피크 크기가 감소한다. 다음으로, 피크의 위치 이동은 내부 저항 증가와 유효용량 감소로 인한 상대적 C-rate 상승에서 기인한다. 배터리를 사용할수록 내부 저항이 증가하게 되는데, 내부 저항이 증가하면 충전 시 기존보다 더 높은 전압 구간에 도달하게 된다.

$$V(Q) = E_{eq}(Q) + I \times R(Q) \quad (4)$$

열화가 진행되면 유효용량(Q_{total})이 감소한다. 이때 동일한 충전 전류 조건에서 유효용량이 줄어들면 배터리 입장에서는 상대적으로 더 높은 C-rate에 해당하게 된다. 예를 들어 2500mAh 배터리를 1C-rate(1.25A)로 충전한다고 가정하였을 시 열화로 인해 용량이 2000mAh로 감소한 경우 동일한 1.25A의 전류는 해당 셀에서 1.25C-rate에 해당한다. 이 경우 충전 과정에서 과전압이 증가하여, ICA 곡선 상 피크가 기존보다 더 높은 전압구간에서 형성된다[20,21]. 그러나 고 SOC (State of Charge) 구간에서는 셀 특성에 따라 피크의 위치가 왼쪽으로 되돌아가는 현상이 나타나기도 한다. 대표적인 원인으로서는 평형 전압($E_{eq}(Q)$, OCV) 항과 내부 저항($I \times R(Q)$) 항의 상대적인 기여도 차이가 있다. 고 SOC 구간에서는 OCV-SOC 그래프의 기울기가 급격히 증가하여 ICA 곡선이 평형 전압 변화에 더욱 민감하게 반응한다[22]. 이 구간에서 배터리 노화로 삽입가능한 리튬이 감소하면 평형 전압 항이 크게 저하되고, 이 효과는 내부저항 증가에 따른 피크 이동보다 지배적으로 작용한다. 이때 피크가 왼쪽으로 되돌아가는 현상으로 나타나게 된다. 이 외에도 충전 조건, 온도 조건에 따라 ICA 피크의 위치가 반대로 이동하거나 비정상적으로 거동하는 경향을 보인다[23,24]. 이렇게 ICA를 통해 얻어낸 곡선에서 나타나는 피크의 값과 위치를 입력 데이터 특징으로 사용한다. 부분 충전 데이터 안에 두 개 이상의 피크가 포함된다면 그중 값이 큰 피크를 입력 데이터로 택하도록 하였다.

충전 용량 변화량의 평균(ΔQ_{mean}) 및 표준편차(ΔQ_{std}), ICA 피크 값(P_j) 및 위치(V_j)로 이루어진 입력 데이터는 4차원 벡터를 구성하며, 부분 충전 데이터마다 하나의 벡터씩 추출된다. 본 연구에서는 1, 2, 4, 7번 배터리 데이터에서 부분 충

전 데이터를 무작위로 샘플링하여 입력 데이터로 사용하였다.

2.2 출력 데이터

출력 데이터는 LIB의 상태를 의미하는 데이터로 시스템의 출력에 해당한다. 본 연구에서는 배터리의 SOH를 출력으로 사용하였다. SOH는 배터리의 잔존 사용 가능 용량과 남은 수명을 직관적으로 제시하므로 BMS에서 가장 중요한 출력 값 중 하나이다. 통상적으로 70~80% 수준으로 떨어지면 수명 종료 시점(End Of Life, EOL)으로 간주하며 이 시점 이후에는 배터리 교체를 권고한다[25]. 본 BMS는 SOH값을 사용자에게 제공하여 배터리 교체 시기 판단 및 안전 관리 등의 의사결정을 판단할 수 있도록 지원한다.

2.3 상관관계 분석

일반적으로 데이터 기반 모델의 입·출력 간 상관관계가 높을수록 모델의 예측 정확도가 향상된다. 따라서 본 연구에서는 피어슨 상관계수(Pearson correlation coefficient)를 통해 각 입력 변수와 배터리 SOH 간의 선형 상관관계를 정량적으로 평가하였다. 피어슨 상관계수는 -1과 +1 이내의 값을 가지며, 절댓값이 클수록 변수 간의 선형 연관성이 강함을 의미한다. 피어슨 상관계수는 다음과 같이 계산된다.

$$\rho_x = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (5)$$

여기서 x_i 는 입력 데이터, y_i 는 출력 데이터이며 $\bar{x}$ 와 $\bar{y}$ 는 각각의 평균값이다. 분자의 $\sum(x_i - \bar{x})(y_i - \bar{y})$ 는 입력값 편차와 출력값 편차의 곱을 전체 샘플에 대해 합산한 것이며, 분모의 $\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}$ 는 각각 입력과 출력의 편차 제곱을 전체 샘플에 대해 합산한 것을 의미한다. 본 연구에서는 배터리 전압에 의해 결정되는 부분 충전 구간 데이터에서 추출한 입력 데이터 4가지와 출력 데이터인 SOH 간의 상관관계를 계산

한다. 상관관계 결과를 그림 (3)에 제시하였다. 초·중반 부분 충전 구간에서 ΔQ_{mean} 과 ΔQ_{std} 는 SOH와 높은 상관관계를 보이나 후반 구간에서는 상관계수가 서서히 감소하는 특성을 보인다. P_f 와 V_f 는 초반과 극 후반 구간에서는 높은 상관관계를 보이지만, 중반 구간에서 하락하는 특성을 보인다. 이는 중반 구간에 해당하는 P_f 와 V_f 의 변화폭이 크지 않아, 선형 상관관계 분석만으로는 유의미한 패턴을 포착하기 어려웠기 때문으로 판단된다(그림 (3) 참조).

한편 피어슨 상관계수는 입·출력 데이터 간의 선형적인 관계만을 정량화하는 지표이므로, GPR 모델이 사용하는 커널 함수의 비선형 특성을 반영하지 못한다[26]. 커널 함수와 같이 비선형 관계가 강한 경우에는 상관계수가 0에 가까워도 실제로는 강한 비선형 의존성이 있을 수 있다는 기존 연구 결과가 존재한다[27]. 따라서 특정 구간에 상관계수가 낮아 선형성을 보장하지 못하더라도, 비선형 커널을 통해 해당 구간의 피크 특징을 모델이 학습함으로써 최종 추정 정확도에는 유의미한 영향을 미칠 수 있을 것으로 기대된다.

III. GPR 기반 LIB SOH 추정 학습 모델

본 장에서는 LIB SOH 추정을 위한 학습 모델을 구성하고, 모델 평가를 위한 지표를 정의한다.

1. GPR 기반 학습 모델

GPR (Gaussian Process Regression)이란 관측 데이터로부터 함수의 분포를 추정하는 비모수 기법의 기계학습 모델이다. 입력 데이터와 출력 데이터 간의 관계를 함수의 분포로 모델링 한다. GPR은 다음과 같은 특징이 있다. 첫 번째로, 예측 불확실성을 제공한다. 예측의 신뢰도를 정량화할 수 있다는 점에서 안전이 중요한 분야에서 의사결정에 유용한 정보를 제공한다. 두 번째로, 복잡한 비선형 관계를 모델링 할 수 있는 비모수 기법이다. 세 번째로, 입력 간 유사도와 관계를 간접적으로 계산함으로써 반영할 수 있는 커널 함수 기반의 모델이라는 특징이 있다.

그림 4는 GPR의 전체 동작 과정을 네 단계로 요약하여 보여준다. 먼저 사전분포 단계(prior)에서는 추정하고자 하는 함수 $f(x)$ 를 평균이 0이고 커널 함수 $k(x, x')$ 를 공분산으로 사용하는 가우시안 프로세스(gaussian process)로 가정한다. 이때, 다음과 같이 함수 $f(x)$ 를 정의할 수 있다.

$$f(x) \sim gp(0, k(x, x')) \quad (6)$$

여기서, 임의의 유한개의 입력 점 $\{x_1, \dots, x_n\}$ 에 대한 함수값 벡터 $[f(x_1), \dots, f(x_n)]^T$ 는 평균이 모두 0이고 공분산 행렬 K 의 원소가 $K_{i,j} = k(x_i, x_j)$ 인 다변량 정규분포를 따른다. 이 가우시안 프로세스 가정에 따라 추정하고자 하는 함수 $f(x)$ 를 확률 과정으로 모델링할 수 있다. 다음으로 데이터 관측 단계(data observation)에서는 학습 데이터 $\{(x_i, y_i)\}_{i=1}^N$ 를 확보하여 입력 행렬 $X = [x_1, \dots, x_N]^T$, 대응 출력 벡터 $y = [y_1, \dots, y_N]^T$ 를 구성한다. 관측된 출력 값(빨간 점)을 통해 사전분포와 입·출력 벡터 간 데이터가 얼마나 일치하는지 파악하고 이후 하이퍼파라미터 최적화를 위한 초기 추정 근거로 활




그림 4. 가우시안 프로세스 회귀 과정. (1) 사전분포 단계. (2) 데이터 관측 단계. (3) 사후분포 단계. (4) 예측 단계.

Fig. 4. Gaussian Process Regression Workflow. (1) Prior Distribution. (2) Data Observation. (3) Posterior Distribution. (4) Prediction.

용한다. 사후분포 단계(posterior)에서는 앞서 설정한 사전분포와 관측된 학습 데이터(X, y)를 반영하여 새로운 입력 X^* 에 대한 함숫값 f^* 의 조건부 분포를 다음과 같이 유도한다.

$$p(f^*|X, y, X^*) = N(\mu^*, \Sigma^*) \quad (7)$$

$$\mu^* = K(K^*, X)[K(X, X) + \sigma_n^2 I]^{-1} y \quad (8)$$

$$\Sigma^* = K(X^*, X^*) - K(X^*, X)[K(X, X) + \sigma_n^2 I]^{-1} K(X, X^*) \quad (9)$$

이 분포의 예측 평균(μ^*)과 예측 공분산(Σ^*)은 각각 식 (8)과 식 (9)과 같이 계산된다. 여기서, $K(X, X)$ 는 학습된 입력 벡터 간 공분산 행렬, $K(X^*, X)$ 는 새 입력과 학습된 입력 벡터 간 공분산 행렬, σ_n^2 은 노이즈 분산이다. 이 과정을 통해 관측된 데이터를 반영하여 사전분포의 평균과 공분산을 사후분포의 예측 평균과 예측 공분산으로 업데이트한다. 마지막으로 예측 단계(prediction)에서는 학습이 완료된 사후분포를 이용해 실제 예측값 $\hat{y}^* = \mu^*$ 와 95% 신뢰구간 $\mu^* \pm 1.96\sqrt{\text{diag}(\Sigma^*)}$ 을 계산하여 새로운 입력이 들어왔을 때 해당 지점의 예측값과 신뢰구간을 제시하게 된다.

본 연구에서는 전체 충전 데이터가 아닌 부분 충전 데이터를 무작위로 샘플링하여 모델 학습을 진행하였다. 커널 함수로는 국부적 비선형성을 보다 효과적으로 반영하는 Matérn 5/2 커널 함수를 사용하였다. 해당 커널 함수는 다음과 같이 표현된다.

$$k(x_i, x_j) = \sigma_f^2 \left(1 + \frac{\sqrt{5}r}{\sigma_l} + \frac{5r^2}{3\sigma_l^2}\right) \exp(-\sqrt{5} \frac{r}{\sigma_l}) \quad (10)$$

$$r = \|x_i - x_j\|_2 \quad (11)$$

식 (12)는 입력 벡터 간 거리로 본 연구에서는 부분 충전 데이터의 특징 벡터 간 거리이다. 여기서 σ_l 는 특성 길이, σ_f 는 신호 분산으로 커널 함수의 하이퍼파라미터이다. 특성 길이란 커널의 굴곡을 반영하는 파라미터로, 이 값을 조정함에 따라 커널의 형상이 그림 4(2)과 같이 정해진다. 신호분산이란 노이즈 편차를 의미한다. 이는 데이터가 갖는 노이즈의 크기 기준을 정하고, 신뢰구간의 폭과 불확실성 평가에 영향을 준다. 본 연구에서는 특성 길이를 입력 변수 표준편차의 평균으로 설정하고, 신호 분산을 최적화하여 회귀를 진행하였다.

2. 모델 성능 지표

본 연구에서는 회귀모델 평가지표로 MAE, RMSE를 사용하였다. 우선 평균 절대 오차(mean absolute error, MAE)는 다음과 같이 표현된다.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (12)$$

여기서, y_i 는 실제 관측값, $\hat{y}_i$ 는 모델 예측값이며 N 은 샘플 수이다. MAE는 예측 오차의 절대값 평균으로 단위가 원래 출력값의 단위와 동일해 직관적 해석에 용이하다. 평균 제곱근 편차(root mean squared error, RMSE)는 다음과 같이 표현된다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (13)$$

RMSE는 오차 제곱의 평균을 다시 제곱근 취한 것으로 큰 오차에 더욱 큰 패널티를 부과한다. 따라서 모델이 일부 샘플에서 큰 오차를 발생시킬 때 MAE보다 민감하게 반영되며, 오차 분포의 분산 정도를 강조하고자 할 때 유용하다. 측정 단위는 MAE와 마찬가지로 원 단위를 따른다. 두 가지 지표를 종합적으로 고려함으로써, 본 연구에서는 제안한 GPR 기반 SOH 추정 모델의 성능을 다각도로 분석하였다.

IV. 학습 및 검증 결과

본 장에서는 LIB SOH 추정 모델을 학습하고, 획득한 모델의 결과를 분석한다.

1. 환경 구성

GPR 기반 배터리 SOH 추정 모델 개발을 위해 MATLAB의 Statistics and Machine Learning Toolbox를 사용하였다. 모델 학습은 Window 11 환경에서 진행되었으며, 학습에 사용된 PC는 AMD Ryzen 7 5800X8-Core Processor (CPU), NVIDIA GeForce RTX 3070 (GPU), 64GB (RAM)으로 구성된다. 본 연구에서 사용된 LIB는 실험을 통해 수집한 Samsung INR 18650-25R 셀로 총 6개로 구성되며, 4개의 LIB는 학습으로, 1개의 LIB는 검증 데이터로 사용하였다.

2. 모델 학습

본 연구에서는 모델 학습을 위해 입력 변수로 부분 충전 데이터를, 출력 변수로 SOH를 각각 설정하였다. 이때, 사용된 SOH(%) 참값은 각 사이클에서 측정된 최대 충전용량을 배터리 공칭 용량으로 나눈 값으로 정의된다. 실험에 사용된 배터리 Samsung INR 18650-25R의 공칭 용량은 2500mAh이다. 학습용 데이터로 부분 충전 데이터를 확보하였으며 이 중 2,000개를 실제 입력 데이터 샘플로 사용하였다. 검증용 데이터의 개수는 LIB의 전체 충·방전 사이클 수와 동일하게 957개로 구성하였다. 하이퍼파라미터 탐색에는 베이지안 최적화를 활용하였으며, 획득 함수의 값을 최소화하는 방향으로 최적점을 탐색하도록 하였다. 하이퍼파라미터 최적화 Statistics and Machine Learning Toolbox의 내부 함수를 이용한 자동 최적화 기능을 사용하였다. 이를 통해 Standardize 함수와 신호 분산을 최적화하도록 설정하였다. Standardize 파라미터는 입력

표 1. 입력 데이터 및 파라미터 최적화별 모델 분류.

Table 1. Model classification by input data and parameter optimization.

Parameter Optimization	Input Data	
	$\Delta Q_{mean}, \Delta Q_{std}, P_j, V_j$	$\Delta Q_{mean}, \Delta Q_{std}$
standardize, σ_f	Model 1	Model 2

표 2. 델 학습 데이터 및 학습 파라미터 정의.

Table 2. Define model learning data and parameters.

Parameter	LIB SOH Estimation Model	
	Model 1	Model 2
Learning/Total	2000	2000
σ_l	[1e-3,1]	[1e-3,1]
Iteration	30	30

데이터의 정규화 여부를 결정하는 파라미터로 입력 변수들을 평균 0, 표준편차 1로의 변환 여부를 결정한다. 이는 스케일이 다른 변수들이 있을 때 모델 성능을 높이기 위해 사용된다. 학습 과정은 iteration 단위로 반복수행되며, 진행된 모든 실험에서 iteration 수를 30으로 통일하였다. 본 연구에서는 표 1과 같이 입력 데이터에 따라 2개의 모델을 학습하여 결과를 분석한다. 학습 과정에서 사용된 데이터 및 파라미터에 대한 정보는 표 2에 정리하였다.

3. 모델 검증

본 절에서는 학습에 사용되지 않은 데이터를 활용하여 앞 절에서 학습된 총 4개의 LIB SOH 추정 모델의 성능을 검증하고 상기한 MAE, RMSE, 신뢰구간 포함 비율을 평가지표로 제시한다. 신뢰구간은 95%로 설정하였으며 다음과 같이 정의된다.

$$\mu^* \pm 1.96\sqrt{\text{diag}(\Sigma^*)} \quad (14)$$


95% 신뢰구간은 추정의 불확실성을 정량화하여 추정한 값이 95% 확률로 해당 범위 내에 포함됨을 보장하는 구간이다. 이를 통해 서로 다른 모델의 추정 불확실성을 비교 및 평가하고, 배터리 SOH 추정 시 안전 여유를 설정하거나 모델 간 과신 여부를 진단하는 데 활용할 수 있다. 그림 5는 Model 1, 2로 검증 데이터의 SOH를 추정하고 그 오차율을 계산한 결과이다.

4. 결과 분석


그림 5는 검증용 배터리에 대한 Model 1, 2의 SOH를 추정한 결과이다. 5(a)와 5(b)는 검증 데이터에 대한 SOH 참값, 각 모델이 추정한 SOH 값과 95퍼센트 신뢰구간을 나타낸다. 5(c)와 5(d)는 각 사이클에서의 오차율을 나타낸다.

여기서 SOH_{pred} 는 모델이 추정한 SOH, SOH_{true} 는 SOH 참값이다. 그림 5와 표 3을 기반으로 Model 1과 Model 2의 SOH 추정 성능을 비교하면, 우선 Model 1은 MAE와 RMSE 측면에서 Model 2보다 우수한 추정 성능을 보인다. 구체적으로, ICA 피크 특징을 입력 데이터로 사용한 Model 1의 평균 절대오차(MAE)는 0.9103%인 반면 ICA 피크 특징을 사용하지 않은 Model 2는 1.0234%로 사용한 모델의 MAE가 약 0.11% 개선되었고, 평균 제곱근 오차(RMSE) 역시 Model 1이 1.2981%로 Model 2의 1.4954%와 비교해 0.20% 개선되었다.


본 연구에서 ICA 피크 특징을 추가함에 따라 발생한 성능 개선이 SOH 추정 분야의 일반적인 맥락에서도 유의미한 수준임을 보이기 위해, 입력 데이터 선택에 따른 성능을 비교한 선행연구와 비교하였다. 선행연구 Xin et al.(2025)의 결과(Table 4, 6)에 따르면, Pearson 상관계수와 Spearman 상관계수를 기반으로 입력데이터를 다르게 구성했을 때, 동일한 예측 모델에서의 성능 차이가 비교적 작게 보고되었다[28]. 예를 들어 PSO-BP 모델에서는 절대적 MAE 차이가 0.002%, RMSE 차이는 0.0025%로 나타났으며, 타 모델에서도 MAE 차이가 입력 데이터 구성에 따라 우수한 모델이 약 10% 내외의 상대적 성능 차이를 보였다. 본 연구에서 보고된 Model 1과 Model 2의 차이는 각각 MAE, RMSE에서 0.11, 0.20으로 절대적 개선 폭은 크지 않지만, 입력 구성 차이에 따른 상대적 추정 결과가 선행연구와 유사하거나 이를 상회하는 개선 폭을 보였다.




(a) Model 1, SOH (%).



(b) Model 2, SOH (%).



(c) Model 1, SOH Error (%).



(d) Model 2, SOH Error (%).

그림 5. Model 1, 2 SOH 추정 및 상대 오차율 결과(신뢰구간 95%).

Fig. 5. Model 1, 2 SOH Estimation and Relative Error Rate (CI Coverage 95%).

표 3. SOH 추정 모델 성능 평가 결과.

Table 3. Performance evaluation results of SOH estimation models.

Criterion	Classification	
	Model 1	Model 2
MAE	0.9103%	1.0234%
RMSE	1.2981%	1.4954%
Nominal CI Coverage	95%	95%
Empirical Coverage	90.71%	89.66%

$$\frac{SOH_{pred} - SOH_{true}}{SOH_{true}} \times 100(\%) \quad [15]$$

이는 유의미한 성능 향상으로 해석할 수 있으며, 동일한 배터리 조건에서 반복 검증된 결과라는 점에서 의미가 있다. 또한 신뢰구간 측면에서는 표 3과 그림 5(c), 5(d)에서 확인할 수 있듯 Model 1은 실제 SOH 값이 95% 신뢰구간에 대해 과도하게 신뢰하는 90.71%의 신뢰구간을 형성하였다. Model 2는 실제 포함 비율이 89.66%로 Model 1과 비슷한 수준의 신뢰구간을 형성하였다. 그림 5(c)에 제시된 SOH 오차율을 살펴보면, Model 1은 전체 샘플에 걸쳐 안정적인 오차 분포를 보이는 예측 특성을 확인할 수 있다. 반면 Model 2의 경우 초중반 사이클에서 비교적 큰 오차가 관측된다. 이러한 예측 성능 차이는 피크 특징의 활용 여부에서 기인하는 것으로 판단된다. 피크 특징을 입력 데이터로 사용함으로써 dQ/dV 곡선이 평탄해지는 중 전압 구간에서도 미세한 비선형 패턴 변화를 포착할 수 있었던 것으로 보인다. 반면 ΔQ_{mean} , ΔQ_{std} 만을 사용한 Model 2는 국부적 열화 징후에 대한 정보가 반영되지 않아 데이터가 부족한 부분에서 예측 불확실성이 급격히 확대된 결과로 해석된다. 표 3의 Nominal CI Coverage는 모델이 산출한 명목상 신뢰구간(95%)을 의미한다. 반면, Empirical CI Coverage는 검증 데이터의 실제 관측값이 모델이 산출한 신뢰구간 안에 포함된 비율을 나타낸다. 두 모델 모두 95% 신뢰구간 대비 실제 포함 비율이 90% 내외로 형성되는 경향을 보였다. 이러한 결과는 모델이 불확실성을 과소평가하고 있음을 의미하며 과소평가된 불확실성은 평균 오차 기반의 성능 최적화 측면에서는 효과적으로 작용하며 추정 정확도가 중요한 분야에서는 유리하게 해석될 수 있다. 한편 안전 중요도가 높은 분야에서는 보다 보수적인 불확실성 표현이 요구될 수 있다.

V. 결론

본 연구에서는 LIB의 SOH 추정을 위해 GPR 기반의 기계 학습 모델을 이용하여 SOH를 추정하는 시스템을 제안하였다. 성능 향상을 위해 ICA 기법을 통한 피크 특징을 입력에 추가하고, 커널 함수의 하이퍼파라미터로 신호 분산과 특성 길이를 베이지안 최적화 기법을 활용해 최적의 값을 계산하였다. 본 연구에 사용된 데이터는 연구진이 직접 수집한 실험 데이터로, 출력 전류와 부하 변화에 따른 불안정성이 큰 방전 구간 대신 상대적으로 안정적인 충전 구간 데이터를 활용하였다. 여기서, 전체 충전 사이클 중 CC 구간의 부분 충전 데이터를 학습 및 검증에 사용하였다.

결론적으로, 본 연구에서 제안한 ICA 피크 기반 특징을 도입함으로써 기존 통계적 특징만을 사용한 모델 대비 MAE와

RMSE가 감소하여 LIB SOH 추정 정확도가 개선되었음을 확인하였다. 더 나아가, ICA 피크 특징의 도입은 추정 불확실성 측면에서 성능이 개선되어 신뢰도를 비교적 합리적으로 표현하도록 돕는 역할을 수행하였다. 이는 예측 결과의 신뢰성이 중요한 실제 BMS 적용 관점에서 중요한 의미를 가지며, ICA 피크 특징이 SOH 추정 모델의 정확도와 신뢰도를 동시에 최적화하는 핵심 요소임을 시사한다.

한편, 학습 및 평가 과정에서 전체 충전 사이클 데이터가 아닌 부분 충전 데이터를 무작위로 샘플링하여 모델을 학습하였음에도, 실제 운용 환경에서 임의의 부분 충전 데이터를 입력으로 사용했을 때, LIB SOH 추정의 안정성과 신뢰도가 보장됨을 실험적으로 확인하였다. 이는 전체 충전 데이터 이력을 확인하기 어려운 조건에서도 데이터 수집 및 적용에 용이함을 의미하며, BMS 적용 시 실용적 강점으로 작용한다. 따라서 제안된 ICA 기반 특징 추출 SOH 추정 정확도를 높이는 동시에 예측 불확실성을 안정적으로 보장할 수 있음을 확인하였다.

본 연구에서는 단일 종류의 LIB를 일정한 온-습도 및 부하 조건에서 수집된 부분 충전 데이터만 사용하였다. 향후 연구에서 LFP, NCA 등 다양한 리튬이온 배터리에 적용 여부를 연구하고, 단일 셀에서 모듈 단위로 적용 범위를 확장하여 실제 BMS 시스템에서의 실용성을 검증할 필요가 있다. 또한 본 연구에서는 피크 특징의 절댓값만을 고려하였으나, 변화를 정보나 데이터 분포 특성을 반영한 지표를 추가적으로 활용하여 제안 프레임워크의 추정 안정성을 강화할 수 있을 것으로 기대된다.

REFERENCES

- [1] B. Nykvist and M. Nilsson, "Rapidly falling costs of battery packs for electric vehicles," *Nature Climate Change*, vol. 5, pp. 329–332, 2015. doi: 10.1038/nclimate2564
- [2] R. Bugga, M. Smart, J. Whitacre, and W. West, "Lithium ion batteries for space applications," *Proceedings of the IEEE Aerospace Conference*, pp. 1–7, 2007. doi: 10.1109/AERO.2007.352728
- [3] A. Masias, J. Marcicki, and W. Paxton, "Opportunities and challenges of lithium ion batteries in automotive applications," *ACS Energy Letters*, vol. 6, pp. 621–630, 2021. doi: 10.1021/acsenenergylt.0c02584
- [4] Y. Li, W. Guo, D.-I. Stroe, H. Zhao, P. Kristensen, L. Jensen, K. Pedersen, and L. Gurevich, "Evolution of aging mechanisms and performance degradation of lithium-ion battery from moderate to severe capacity loss scenarios," *Chemical Engineering Journal*, vol. 498, Art. no. 155588, 2024. doi: 10.1016/j.ccej.2024.155588.
- [5] A. Barré, B. Deguilhem, S. Grolleau, M. Gerard, F. Suard, and D. Riu, "A review on lithium-ion battery ageing mechanisms and estimations for automotive applications," *Journal of Power Sources*, vol. 241, pp. 680–689, 2013. doi: 10.1016/j.jpowsour.2013.05.040.
- [6] N. A. Azis, E. Joelianto, and A. Widhyatriatmo, "State of charge (SoC) and state of health (SoH) estimation of lithium-ion battery using dual extended Kalman filter based

- on polynomial battery model,” *Proceedings of the 6th International Conference on Instrumentation, Control, and Automation (ICA)*, Bandung, Indonesia, pp. 88–93, 2019. doi: 10.1109/ICA.2019.8916734.
- [7] L. Ling and Y. Wei, “State-of-charge and state-of-health estimation for lithium-ion batteries based on dual fractional-order extended Kalman filter and online parameter identification,” *IEEE Access*, vol. 9, pp. 1–11, 2021. doi: 10.1109/ACCESS.2021.3068813
- [8] T. Wu, S. Liu, Z. Wang, and Y. Huang, “SOC and SOH joint estimation of lithium-ion battery based on improved particle filter algorithm,” *Journal of Electrical Engineering & Technology*, vol. 17, no. 1, pp. 307–317, 2022
- [9] H. Pan, C. Chen, and M. Gu, “A state of health estimation method for lithium-ion batteries based on improved particle filter considering capacity regeneration,” *Energies*, vol. 14, no. 16, Art. no. 5000, 2021. doi: <https://doi.org/10.3390/en14165000>
- [10] M. U. Ali, A. Zafar, S. H. Nengroo, S. Hussain, and H.-J. Kim, “Effect of sensors sensitivity on lithium-ion battery modeled parameters and state of charge: a comparative study,” *Electronics*, vol. 8, no. 6, Art. no. 709, 2019. doi: <https://doi.org/10.3390/electronics8060709>
- [11] E. Petkovski, I. Marri, L. Cristaldi, and M. Faifer, “State of health estimation procedure for lithium-ion batteries using partial discharge data and support vector regression,” *Energies*, vol. 17, no. 1, Art. no. 206, 2024. <https://doi.org/10.3390/en17010206>
- [12] E. Chemali, P. J. Kollmeyer, M. Preindl, Y. Fahmy, and A. Emadi, “A convolutional neural network approach for estimation of li-ion battery state of health from charge profiles,” *Energies*, vol. 15, no. 3, Art. no. 1185, 2022. <https://doi.org/10.3390/en15031185>
- [13] C. Van and D. Quang, “Estimation of SoH and internal resistances of lithium-ion battery based on LSTM network,” *International Journal of Electrochemical Science*, vol. 18, Art. no. 100166, 2023. doi: 10.1016/j.ijoes.2023.100166
- [14] M. Chae, M. Ha, and T. Park, “LSTM-based forecasting and evaluation of sensor signals containing anomaly data,” *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 29, no. 12, pp. 1060–1066, 2023
- [15] K. A. Severson, P. M. Attia, N. Jin, et al., “Data-driven prediction of battery cycle life before capacity degradation,” *Nature Energy*, vol. 4, pp. 383–391, 2019. doi: <https://doi.org/10.1038/s41560-019-0356-8>
- [16] Y. Zhang, P. Tino, A. Leonardis, and K. Tang, “A survey on neural network interpretability,” *IEEE Transactions on Emerging Topics in Computational Intelligence*, pp. 1–17, 2021. doi: 10.1109/TETCI.2021.3100641
- [17] R. Richardson, M. Osborne, and D. Howey, “Gaussian process regression for forecasting battery state of health,” *Journal of Power Sources*, vol. 357, 2017. doi: 10.1016/j.jpowsour.2017.05.004
- [18] D. Seo and J. Shin, “Development of DNN-based LIB state diagnosis system using statistical feature extraction,” *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 30, no. 7, pp. 755–762, 2024.
- [19] Z. Deng, X. Hu, P. Li, X. Lin, and X. Bian, “Data-driven battery state of health estimation based on random partial charging data,” *IEEE Transactions on Power Electronics*, pp. 1–11, 2021. doi: 10.1109/TPEL.2021.3134701
- [20] S. Duan, Z. Yu, J. Li, Z. Zhao, and H. Liu, “Rapid screening for retired batteries based on lithium-ion battery IC curve prediction,” *World Electric Vehicle Journal*, vol. 15, no. 10, Art. no. 451, 2024. doi: <https://doi.org/10.3390/wevj15100451>
- [21] Z. Wang, J. Ma, and L. Zhang, “State-of-health estimation for lithium-ion batteries based on the multi-island genetic algorithm and the Gaussian process regression,” *IEEE Access*, vol. 5, pp. 1–11, 2017. 10.1109/ACCESS. 2017.2759094.
- [22] J. Lin and E. Khoo, “Identifiability study of lithium-ion battery capacity fade using degradation mode sensitivity for a minimally and intuitively parametrized electrode-specific cell open-circuit voltage model,” *Journal of Power Sources*, vol. 605, Art. no. 234446, 2024. <https://doi.org/10.1016/j.jpowsour.2024.234446>. (<https://www.sciencedirect.com/science/article/pii/S0378775324003975>)
- [23] A. Fly and R. Chen, “Rate dependency of incremental capacity analysis (dQ/dV) as a diagnostic tool for lithium-ion batteries,” *Journal of Energy Storage*, vol. 29, Art. no. 101329, 2020. <https://doi.org/10.1016/j.est.2020.101329>. (<https://www.sciencedirect.com/science/article/pii/S2352152X19308175>)
- [24] A. Fly and R. Chen, “Rate dependency of incremental capacity analysis (dQ/dV) as a diagnostic tool for lithium-ion batteries,” *Journal of Energy Storage*, vol. 29, Art. no. 101329, 2020. <https://doi.org/10.1016/j.est.2020.101329>. (<https://www.sciencedirect.com/science/article/pii/S2352152X19308175>)
- [25] M. H. S. M. Haram, J. W. Lee, G. Ramasamy, E. E. Ngu, S. P. Thiagarajah, and Y. H. Lee, “Feasibility of utilising second life EV batteries: applications, lifespan, economics, environmental impact, assessment, and challenges,” *Alexandria Engineering Journal*, vol. 60, no. 5, pp. 4517–4536, 2021. <https://doi.org/10.1016/j.aej.2021.03.021> (<https://www.sciencedirect.com/science/article/pii/S1110016821001757>)
- [26] C. E. Rasmussen and C. K. I. Williams, *Gaussian Processes for Machine Learning*, MIT Press, Cambridge, MA, 2006.
- [27] J. Cohen, P. Cohen, S. G. West, and L. S. Aiken, *Applied Multiple Regression/Correlation Analysis For The Behavioral Sciences*, 3rd ed., Lawrence Erlbaum Associates, Mahwah, NJ, 2003.
- [28] K. Xin, F. Jia, B. Choi, and G. Lee, “A study on the differences in optimized inputs of various data-driven methods for battery capacity prediction,” *Batteries*, vol. 11, no. 1, Art. no. 26, 2025. <https://doi.org/10.3390/batteries11010026>

**천 기 범**

2025년 충북대학교 기계공학부 졸업.
2025년~현재 동 대학원 석사 과정 재학
중. 관심분야는 딥러닝, 학습 기반 상태
추정.

**김 해 준**

2024년 충북대학교 기계공학부 졸업.
2024년~현재 동 대학원 석·박사 통합 과
정. 관심분야는 학습 기반 제어, 최적화
기반 경로계획.

**신 종 호**

2005년 숭실대학교 기계공학과 졸업.
2011년 서울대학교 기계항공공학부 박
사. 2012년~2019년 국방과학연구소 선임
연구원. 2019년~현재 충북대학교 기계공
학부 교수. 관심분야는 학습기반 제어,
최적화.