

거대언어모델 기반 SHAP 분석을 이용한 리튬 이온 배터리 잔존 수명 예측 기법 해석

(Large Language Model-based SHAP Analysis for Interpretation of Remaining Useful Life Prediction of Lithium-ion Battery)

이재승¹⁾, 유제혁^{2)*}
(Jaeseung Lee and Jehyeok Rew)

요약 이동성을 갖춘 전자 장비에 에너지를 공급하는 리튬 이온 배터리를 안전하게 운영하기 위해서는 배터리의 잔존 수명을 정확히 예측하는 것이 중요하다. 최근, 기계학습 기술의 발달로, 인공지능 기반의 배터리 잔존 수명 예측 모델이 활발히 연구되고 있다. 하지만, 기존 모델들은 모델 내부에서 일어나는 추론 과정을 알 수 없어 기계학습을 통해 예측된 값을 완전히 신뢰하고 사용하는 데 제약이 있었다. 이를 해결하기 위해 여러 설명가능한 인공지능 기법이 제안되었지만, 이러한 기법들은 단순히 결과를 그래프 형태로 시각화하였기에 사용자가 직접 그래프를 분석해야 했다. 이에 본 논문에서는 거대언어모델에 기반한 SHAP 분석을 이용하여 예측 모델의 추론 과정을 텍스트 형태로 해석하는 설명가능한 리튬 이온 배터리 잔존 수명 예측 기법을 제안한다. 공개 리튬 이온 배터리 데이터셋을 이용한 실험 결과, 거대언어모델 기반 SHAP 분석을 통해 모델의 예측 근거를 텍스트 형태로 구체화하여 이해할 수 있었다.

핵심주제어: 거대언어모델, 배터리, 잔존 수명, 설명가능한 인공지능

Abstract To safely operate lithium-ion batteries that power mobile electronic devices, it is crucial to accurately predict the remaining useful life (RUL) of the battery. Recently, with the advancement of machine learning technologies, artificial intelligence (AI)-based RUL prediction models for batteries have been actively researched. However, existing models have limitations as the reasoning process within the models is not transparent, making it difficult to fully trust and utilize the predicted values derived from machine learning. To address this issue, various explainable AI techniques have been proposed, but these techniques typically visualize results in the form of graphs, requiring users to manually analyze the graphs. In this paper, we propose an explainable RUL prediction method for lithium-ion batteries that interprets the reasoning process of the prediction model in textual form using SHAP analysis based on large language models (LLMs). Experimental results using publicly available lithium-ion battery datasets demonstrated that the LLM-based SHAP analysis enabled us to concretely understand the model's prediction rationale in textual form.

Keywords: Large Language Model, Battery, Remaining Useful Life, Explainable Artificial Intelligence

* Corresponding Author: jhrew@duksung.ac.kr
Manuscript received July 15, 2024 / revised August 05, 2024 /
accepted September 12, 2024

1) 고려대학교 전기전자공학과, 제1저자
2) 덕성여자대학교 데이터사이언스학과, 교신저자

1. 서론

최근 이동성을 갖춘 전자 장비에 에너지원을 공급하는 핵심 요소로서 이차 전지의 일종인 리튬 이온 배터리(Lithium-ion battery)가 주목받고 있다. 리튬 이온 배터리란, 리튬 코발트 산화물 등의 양극과 탄소 등의 음극 사이에 유기 전해질을 넣어 충전과 방전을 반복하게 하는 원리로 작동하는 전지를 말한다(Nitta et al., 2015). 이는 이차 전지 중 에너지 용량 대비 무게가 가장 가볍고, 높은 에너지 밀도와 낮은 자기방전을, 그리고 수명이 길다는 장점으로 인해 빠르게 대중화되고 있다. 이때, 배터리 폭발, 과열, 발화 등 배터리의 안전사고를 사전에 방지하기 위해서는 배터리의 상태를 정확히 진단하는 것이 중요하다(Luca et al., 2024). 예를 들어, 배터리의 온도를 모니터링한다면 과열이 발생할 경우 즉시 경고를 발행하고 필요시 시스템을 차단함으로써 화재를 예방할 수 있다. 또한, 배터리 셀의 전압과 충전 전류를 지속적으로 측정한다면 과충전, 과방전 상태를 감지함으로써 이를 방지하기 위한 조치를 취할 수 있다. 따라서 배터리의 상태를 정확하게 진단하기 위한 다양한 연구들이 진행되고 있다(Zhou et al., 2023; Dhabe et al., 2023; Gopalakrishman et al., 2023; Park and Yi, 2013).

이중, 대표적인 배터리 상태 진단 기법으로 배터리의 잔존 수명(Remaining useful life)을 사전에 예측하는 기술이 있다(Zhao et al., 2022). 잔존 수명이란, 배터리가 현재 상태에서 더 이상 사용할 수 없을 때까지의 남은 기간 또는 사용 가능한 충전 및 방전 사이클 수를 의미한다. 일반적으로 배터리의 수명은 배터리 잔량이 초기값 대비 80% 미만에 도달하면 종료되는 경향이 있다(Jiang et al., 2013). 잔존 수명은 배터리의 성능이나 특정 임계값 아래로 떨어지기 전까지 사용할 수 있는 시간이나 사이클 수를 추정하는 데 사용되기 때문에, 배터리 시스템을 운영하는 데 있어서의 안전성 확보를 위해서는 잔존 수명을 정확하게 예측하는 것이 중요하다(Shi et al., 2020).

과거에는 배터리의 잔존 수명을 예측하는 방

법으로 전기화학 모델링에 기반한 기법들이 많이 활용되었다(Kim et al., 2020; Stroe and Schaltz, 2018). 예를 들어, Kim et al.(2020)은 MapleSim을 활용한 전기화학 모델링과 전기적 특성 실험 기반의 내부 저항을 이용한 잔존 수명 추정 기법을 제안하였다. Stroe and Schaltz (2018)은 전기화학 모델링의 한 종류인 증분용량 분석법을 이용하여 잔존 수명을 추정하는 기법을 제시하였다. 이러한 접근법은 계산복잡도가 낮다는 장점이 있지만, 배터리팩을 특정 조건으로 동작시키는 실험을 통해 직접 배터리 데이터를 확보해야 한다는 불편함이 있다.

이를 해결하기 위해, 최근에는 기계학습에 기반한 예측 모델에 관한 연구가 활발히 이루어지고 있다(Andrioiaia et al., 2024; Liu, 2022). Andrioiaia et al.(2024)은 Support vector regression 을 이용하여 무인 항공기에서의 리튬 이온 배터리의 잔존 수명을 예측하는 기법을 제안하였다. Liu (2022)는 여러 개의 커널 함수(Kernel function)를 결합한 Multiple kernel extreme learning machine을 이용하여 리튬 이온 배터리의 잔존 수명을 예측하는 기법을 제시하였다. 이러한 기계학습 모델들은 주로 배터리에서의 전압, 전류, 온도를 입력으로 이용하여 잔존 수명을 추정하며, 전기화학 모델링에 기반한 기법들보다 우수한 예측 성능을 보였다. 하지만, 뛰어난 성능을 보여주는 기계학습 모델들은 복잡한 연산으로 인해 모델 내부에서 발생하는 의사결정 과정을 설명하기 어려워 흔히 ‘블랙박스’로 여겨진다. 이 때문에 모델이 입력 데이터의 어떤 특성을 기반으로 배터리의 잔존 수명을 추정하였는지에 대해 사용자가 파악할 수 없으며, 예측 모델이 오판하더라도 그 원인을 알 수 없어 모델의 개선이 어렵게 만든다. 그러므로, 모델이 추론한 결과에 대한 분석은 모델의 신뢰성과 정확도를 향상시키는 데 있어 필수적이다.

최근 설명 가능한 인공지능(Explainable artificial intelligence)에 대한 연구가 활발히 이루어지고 있다. 설명 가능한 인공지능이란, 인공지능 모델이 출력값을 도출하는 과정을 해석함으로써 모델의 결정 과정이나 결과를 사용자가 이해할 수 있는 형태로 설명하는 기술을 말한다(Gohel et

al., 2021). 이러한 기술은 모델의 작동 방식을 명확하게 이해할 수 있도록 하기 때문에 사용자로 하여금 모델의 예측 결과를 더욱 잘 이해하고 신뢰할 수 있도록 한다. 지금까지 인공지능 모델에서의 설명 가능성을 확보하기 위해 다양한 연구들이 진행되었으며, 대표적인 설명 가능한 인공지능 기법으로는 Shapley additive explanations (SHAP), Local interpretable modal-agnostic explanation(LIME) 분석, Partial dependency plot(PDP), Individual conditional expectation (ICE) plot 등이 있다(Lundberg and Lee, 2017; Saeed and Omlin, 2023). LIME 분석은 모델에 구애받지 않고 예측값에 대한 지역적인 설명을 제공한다는 장점이 있지만, 설명의 일관성이 떨어질 수 있고 임의적인 샘플링에 의존한다는 단점이 있다. PDP는 특정 입력변수와 출력변수 사이의 관계를 시각화하는 데 유용하지만, 변수들 간의 상호작용 효과를 고려하지 않는다. ICE plot은 개별 예측값에 대한 민감도 분석을 제공하지만, 해석 과정이 복잡하고 변수 간의 상호작용을 충분히 고려하지 않는다는 단점이 있다. 반면, SHAP 분석은 Shapley 값에 기반한 각 입력변수의 기여도 평가를 통해 예측값에 대한 공정한 해석을 제공하며, 전역적인 특성과 지역적인 특성을 통합하여 전체 모델과 개별 예측에 대하여 일관적인 설명이 가능하다는 특징이 있다. 또한, 예측 모델의 유형과 상관없이 적용 가능하며 해석 용이성이 높다는 장점 덕분에 대표적인 설명가능한 인공지능 기법으로 각광받고 있다.

하지만, 기존의 설명 가능한 인공지능 기법들은 단순히 그래프 형태로 결과를 시각화하였기에 사용자가 직접 해당 그래프를 분석하며 예측 모델을 해석해야 했다. 사용자가 예측 모델 내부에서의 추론 과정과 설명 가능한 인공지능 기법의 작동 과정을 함께 고려하지 않은 채, 결과에 대해서만 분석을 수행한다면 잘못된 해석 결과를 도출할 수 있다. 주어진 수치 데이터와 그래프를 확인하며 예측 모델이 추론한 값을 분석하고 이를 텍스트 형태로 정리하는 사용자의 특성을 고려하였을 때, 텍스트 형태로 설명 가능한 인공지능 기술이 도출한 결과를 구체화하고

이를 사용자에게 함께 제공한다면 사용자가 예측 모델을 해석하는 데 큰 도움을 줄 수 있을 것이다.

최근 자연어 처리의 발전에 따라 거대언어모델(Large language models)이 많은 주목을 받고 있다. 거대언어모델은 방대한 양의 텍스트 데이터를 사전 학습한 모델로서 텍스트 데이터 뿐만 아니라, 정형 데이터, 이미지나 비디오를 비롯한 비정형 데이터 등 다양한 분야에서 뛰어난 활용처를 보이고 있다(Minaee et al., 2024; Kim and Yu, 2023). 특히, 거대언어모델은 정형 데이터의 특성을 이해하고 이를 기반으로 예측, 생성, 분류 등 새로운 과업을 수행하는 데 효과적이라는 특징이 있다(Fang et al., 2024). 이에, 본 논문에서는 거대언어모델 기반 SHAP 분석을 이용한 설명가능한 리튬 이온 배터리 잔존 수명 예측 기법을 제안한다. 먼저, Random forest 등 기계학습 모델을 이용하여 예측 성능이 높은 배터리 잔존 수명 예측 모델을 구성한다. 이후, 학습된 모델이 예측 결과를 도출하는 과정을 거대언어모델 기반 SHAP 분석을 통해 해석한다. 제안하는 기법의 효과를 입증하기 위해 공개 리튬 이온 배터리 데이터셋을 활용하였으며, 다양한 프롬프트(Prompt)를 이용한 실험을 통해 거대언어모델 기반 SHAP 분석 결과에서의 설명가능성을 확보하였다.

본 논문의 구성은 다음과 같다. 2장에서는 배터리의 잔존 수명을 예측하는 것과 관련된 연구를 기술하고, 3장에서는 제안하는 기법에 대하여 설명한다. 4장에서는 본 논문에서 활용한 데이터셋을 설명하고, 제안 기법의 실험 결과를 보이며 그 결과를 분석한다. 마지막으로 5장에서는 결론 및 향후 연구에 대해 밝히며 본 논문의 끝을 맺는다.

2. 관련 연구

2.1 전기화학 모델링 기반의 배터리 잔존 수명 예측

리튬 이온 배터리 내부에서 발생하는 전기화

학적 작용을 이용하여 모델을 구축하는 것은 배터리 잔존 수명 예측의 대표적인 접근 방법이다 (Lee and Yoon, 2012; Lee et al., 2021; Kim et al., 2022). 예를 들어, Lee and Yoon(2012)은 배터리의 전기화학적 상태에 대해 Butler-Volmer 식을 지배방정식으로 하여 유사 2차원 모델링을 적용하고, 편미분 연산자인 FEMLAB을 활용하여 전산모사를 수행하는 기법을 제안하였다. Lee et al.(2021)은 전기화학적 임피던스 분광법(Electrochemical impedance spectroscopy)을 이용하여 배터리의 전기화학적 특성을 나타내는 임피던스 파라미터를 계산함으로써 배터리의 특성을 모델링하는 기법을 제시하였다. Kim et al.(2022)은 배터리에서의 전류, 전압, 온도 데이터를 고려한 최적의 열화 모델을 설계하였다. 구체적으로, 배터리 잔여 용량의 정확한 예측과 모델의 계수를 보정하기 위하여 무어-펜로즈 유사 역행렬(Moore-penrose pseudo inverse matrix)을 이용하였으며, 배터리 관리 시스템에서의 저장 공간에 대한 한계성을 해결하기 위해 적은 사이클(Cycle)의 데이터에 기반한 잔존 수명 예측 기법을 제안하였다. 하지만 전기화학 모델을 정확하게 구축하고 검증하기 위해서는 고가의 장비와 많은 시간, 전문 지식을 필요로 하는 실험 데이터를 수집해야 한다. 실험 데이터가 부족할 경우, 모델의 신뢰성과 일반화 가능성을 제한하게 될 수 있다. 또한, 전기화학 모델링은 일반적으로 특정 배터리 셀이나 모듈에 대해 수행되므로, 이를 대규모 배터리 시스템이나 다양한 배터리 유형에 적용하기 위해서는 추가적인 조정과 검증이 필요하다. 이는 모델의 활용성을 제한하게 된다는 한계가 있다.

2.2 통계적 기법 기반의 배터리 잔존 수명 예측

기존의 전기화학적 모델링을 넘어, 최근 배터리에서의 전류, 전압, 온도 등의 데이터에 대하여 통계적 특성을 고려한 모델링을 통해 배터리의 잔존 수명을 예측하는 기법들이 제안되었다 (Zhou and Huang, 2016; Jiao et al., 2022). Zhou and Huang (2016)은 비선형적이고 비정

칙적인 배터리 시계열 데이터를 내재 모드 함수(Intrinsic mode function)으로 분해하는 기법인 경험적 모드 분해법(Empirical mode decomposition)과 통계적 기법 기반의 시계열 예측 모델인 자기회귀 누적 이동평균 모델(Autoregressive integrated moving average)를 결합한 리튬 이온 배터리 잔존 수명 예측 기법을 제시하였다. Jiao et al.(2022)은 장기적인 배터리의 잔존 수명 예측 성능을 향상시키기 위해 자기회귀 이동평균 모델(Autoregressive moving average)와 지수 저하 모델(Exponential degradation model)을 결합한 기법을 제안하였다. 하지만 이러한 기법들은 주로 평균값 추정 등 선형 관계를 모델링하는데 초점을 두기 때문에, 배터리 데이터의 전반적인 분포를 파악하는 데 한계를 보여 예측 성능이 하락하는 모습을 보였다.

2.3 기계학습 기반의 배터리 잔존 수명 예측

최근 컴퓨팅 기술의 발전으로 인해 기계학습에 기반한 배터리 잔존 수명 예측 모델에 대한 연구가 활발히 수행되고 있다. 이러한 모델들은 통계적인 기법에 기반한 배터리 잔존 수명 예측 모델보다 더욱 우수한 성능을 보여주었다(Park, 2022; Son, 2023; Gao et al., 2022). Park(2022)은 점진적 기계학습 기법을 도입하여 시간의 흐름에 따라 변화하는 배터리의 사용패턴을 고려하며 도출한 배터리 잔존 수명 예측 결과를 자동차 계기판에 나타내는 연구를 수행하였다. Son(2023)은 기계학습 기반 리튬 이온 배터리 잔존 수명 예측 모델의 추론 시간 단축을 목표로 배터리 노화에 따라 부분 정전류 방전을 시간별로 진행하여 데이터를 취득한 이후 시계열 알고리즘을 구축하는 기법을 제안하였다. Gao et al.(2022)은 Particle filter와 이산 웨이블릿 변환(Discrete wavelet transform)을 결합하여 배터리 데이터를 전처리한 후 Support vector regression을 이용하여 리튬 이온 배터리의 잔존 수명을 예측하는 기법을 제시하였다.

하지만, 기존의 기계학습 모델들은 예측 결과를 도출하는 데 있어서의 의사결정 과정을 명확히 설명하기 어려웠다는 한계점이 있다. 이는

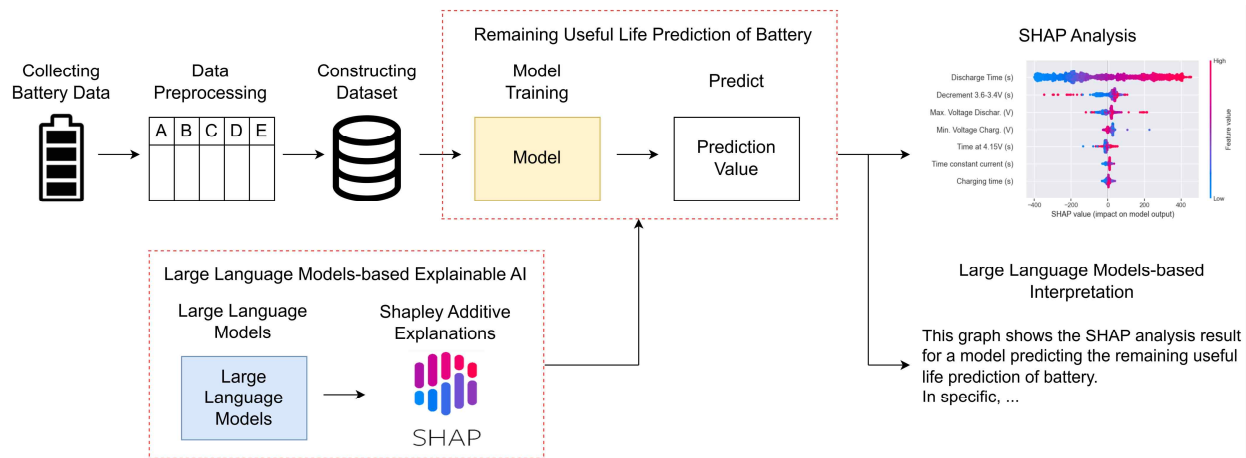


Fig. 1 Overview of the proposed scheme

예측 결과에 대한 신뢰도를 저하시킬 수 있기 때문에 실제 배터리 산업 현장에서 예측값을 직접적으로 활용하기 어려울 수 있다. 이에, 본 논문에서는 거대언어모델 기반의 SHAP 분석을 이용하여 기계학습 모델이 도출한 배터리 잔존 수명 예측 결과에 대하여 설명 가능성을 확보하는 기법을 제안한다.

3. 제안하는 기법

본 장에서는 연구에서 제안하는 기법의 전체 구조를 서술한다. Fig. 1은 본 논문에서 제안하는 기법의 전체적인 구조도를 나타낸다.

3.1 배터리 데이터 수집 및 전처리

배터리는 전류, 전압, 온도 등 다양한 요소들이 상호작용하며 작동한다는 특성이 있다(Chen et al., 2021). 특히, 배터리는 충방전 과정을 거치는 동안 샘플링의 빈도에 따라서 수집되는 데이터의 양이 달라진다. 이에, 본 논문에서는 한번의 완전 충전 및 완전 방전을 의미하는 매 사이클마다 수집한 전류, 전압, 온도 데이터가 포함되어 있는 공개 배터리 데이터셋을 이용한다.

본 논문에서 다루는 리튬 이온 배터리는 CC/CV 방식(Constant current/Constant voltage)을 통해 충전이 이루어지고, CC 방식(Constant current)을 통해 방전이 이루어진다(Zhou et al.,

2023). 먼저, 충전의 경우 배터리의 전압이 목표치에 도달할 때까지 일정한 전류를 공급하여 빠르게 충전하는 CC 단계를 거친다. 이후, 전압이 목표치에 도달하면 CV 단계로 전환되어 전압을 일정하게 유지하면서 전류를 점차 줄여 배터리가 완전히 충전될 때까지 조절한다. 반대로, 방전의 경우 배터리에서 일정한 전류를 방출하여 전자 기기를 지속적으로 작동시키는 방식인 CC 단계를 수행한다. 이러한 방식은 배터리의 일정한 출력을 유지해야 하는 상황에서 매우 중요하며, 효율적인 에너지 사용과 기기의 안정적인 운영을 보장한다는 특징이 있다. 이러한 점을 고려하여, 배터리가 충방전의 절차를 거치는 데 있어 시간의 흐름에 따라 나타내는 전류, 전압, 온도 데이터를 수집하고 이를 전처리하여 주어진 배터리의 특성을 나타내는 변수들을 추출한다. 이를테면, 충전과 방전을 수행할 시 소요된 시간, 특정 기준 전압에 도달할 때까지 소요된 시간, 전압의 최솟값 및 최댓값, 그리고 전류가 최댓값에서 일정하게 유지되는 데 소요된 시간 등이 대표적인 변수가 될 수 있다(Zhao et al., 2022). 이러한 과정을 통해 향후 리튬 이온 배터리의 잔존 수명 예측 모델을 개발하는 데 있어 필요한 데이터셋을 구축한다.

3.2 기계학습 모델을 통한 배터리 잔존 수명 예측

3.1절에서 구축한 배터리 데이터셋을 입력으로 받은 기계학습 모델을 학습하여 배터리 잔존 수명 예측을 수행한다. 제안하는 기법에서는 널리 활용되며 우수한 예측 성능을 보여주는 모델인 Random Forest를 이용한다(Louppe, 2014). Random Forest는 다수의 결정 트리를 각기 다른 데이터 샘플과 특성의 일부만을 사용하여 독립적으로 학습시키고, 이 트리들의 예측 결과를 평균 내어 최종 예측값을 도출하는 모델이다. 이러한 과정은 모델의 과적합을 방지하고 일반화 성능을 향상시키기 때문에 주어진 데이터에서의 복잡한 비선형 관계를 모델링하는 데 효과적이라는 특성이 있다.

3.3 SHAP 분석을 이용한 예측 모델에서의 설명가능성 확보

기계학습에 기반한 배터리 잔존 수명 예측 모델에서 설명가능성을 확보하기 위해, SHAP 분석을 이용한다(Lundberg and Lee, 2017). SHAP은 기계학습 모델에서의 예측값을 설명하기 위한 기법 중 하나로서, 게임 이론의 Shapley 값에 기반을 두고 있다. Shapley 값은 여러 플레이어가 게임에서 협력하여 얻는 이익을 공정하게 분배하는 방법을 제공한다. SHAP은 Shapley 값에서의 플레이어를 입력변수에, 게임을 예측 모델에 적용한 개념이다. 즉, 각 플레이어의 기여도에 따라 이익을 분배하는 원리를 예측 모델의 각 특성에 적용하여, 특성이 결과에 미치는 기여도를 계산한다. SHAP은 기계학습 모델의 각 입력변수가 최종 예측 결과에 미치는 기여도를 정량화하고 해석할 수 있도록 하기 때문에, 각각의 입력변수의 값이 변할 때 모델의 예측이 어떻게 이루어지는지 투명하게 드러낼 수 있다. 이를 통해, 기계학습 모델이 주어진 데이터에 대하여 예측 결과를 도출하는 과정에 있어 설명가능성을 확보할 수 있다.

3.4 거대언어모델 기반 SHAP 분석을 이용한 설명가능성 구체화

3.3절에서 도출한 SHAP 분석 결과에 대하여,

설명가능성을 구체화하기 위해 거대언어모델을 활용한다. 거대언어모델은 사전에 많은 양의 텍스트 데이터를 사전 학습한 모델이기에 주어진 정보의 의미를 파악하고 이를 해석할 수 있다는 특징이 있다(Fang et al., 2024). 이러한 특성을 고려하여, 리튬 이온 배터리의 잔존 수명 예측 모델에서 SHAP 분석을 통해 설명가능성을 확보하는 데 있어, 거대언어모델을 함께 활용하여 주어진 데이터에 관해 예측 모델이 도출한 결과값에 대한 해석을 구체화한다.

본 논문에서는 크게 2가지의 기법을 취한다. 먼저, 예측 모델에서 SHAP 분석을 수행하는 데 있어 거대언어모델을 직접적으로 연계한다. 이는 거대언어모델로 하여금 예측 모델에서 SHAP 분석이 수행되는 전체적인 과정을 파악하도록 한 후, 텍스트 형태로 설명가능성에 대한 해석을 수행한다. SHAP 분석이 기반을 두고 있는 Shapley 값은, 예측 모델에 입력변수가 추가되는 순서에 따라 모델 예측의 변화를 계산하여 각 입력변수의 기여도를 공정하게 분배함으로써 도출된다는 특성이 있다. 이를 위해 가능한 모든 입력변수 순열을 생성하고, 이에 대한 마스킹(Masking) 기법을 통해 특정 입력변수를 제외한 상태에서 모델 예측을 수행하여 기여도를 계산한다. 이러한 마스킹의 과정과 최종적으로 계산되는 Shapley 값을 거대언어모델이 파악하도록 함으로써 예측 모델에서의 설명가능성을 텍스트 형태로 구체화한다. 이러한 기법은 단순히 예측 모델에서의 SHAP 분석 결과를 도출하는 것을 넘어, 거대언어모델을 통해 텍스트 형태로 설명을 생성하기 때문에 예측 모델이 도출한 결과값에 대한 근거를 사용자가 더욱 명확히 이해할 수 있도록 한다는 장점이 있다.

두 번째 기법으로는 이미지 형태로 표현된 그래프 형식의 SHAP 분석 결과에 대해 멀티모달(Multimodal) 거대언어모델을 이용하여 설명가능성에 대한 해석 결과를 도출한다. 멀티모달 거대언어모델이란 입력 데이터로 텍스트 데이터 뿐만 아니라, 이미지, 오디오 등 다양한 유형의 데이터를 처리할 수 있는 모델을 말한다(Zheng et al., 2024). 각 모달(Modal)의 특성을 이해하고 관련 데이터 사이의 상관관계를 파악할 수

Table 1 Template for prompt in analyzing the graph visualization result of SHAP analysis

	Template	Example
Description of SHAP	SHAP (Shapley Additive Explanations) is a method used to interpret the output of machine learning models by quantifying the contribution of each feature to the prediction. It is based on Shapley values from game theory, ensuring a fair distribution of contribution values among features. SHAP values help in understanding the importance and impact of each feature on the model's predictions, enhancing model transparency and interpretability.	
Case (1) - Summary plot of SHAP	This image shows the result of SHAP values using a prediction model to estimate the remaining useful life of a lithium-ion battery. It is the summary plot of all the input variables. Please interpret the given image in text format.	
Case (2) - Dependence plot of SHAP	This image shows the result of SHAP values using a prediction model to estimate the remaining useful life of a lithium-ion battery. It is the dependence plot for the variable ' $X_{input\ variable}$ '. Please interpret the given image in text format.	This image shows the result of SHAP values using a prediction model to estimate the remaining useful life of a lithium-ion battery. It is the dependence plot for the variable 'Time at 4.15V (s)'. Please interpret the given image in text format.

있으며, 단순한 텍스트 분석이나 이미지 인식을 넘어 이미지에 대한 설명 작성, 오디오와 관련된 텍스트 생성 등 복잡한 작업을 수행할 수 있다는 장점이 있다. 본 기법에서는 텍스트 형태로 표현된 프롬프트와 이미지 형태로 표현된 그래프 형식의 SHAP 분석 결과를 함께 멀티모달 거대언어모델의 입력으로 활용하여, 주어진 그래프 형식의 SHAP 분석 결과에 대하여 텍스트 형태로 설명가능성에 대해 해석한다. 이러한 기법은 이미지 형식의 SHAP 분석 결과와 그 결과에 대한 개괄적인 설명을 거대언어모델에게 함께 제공하기 때문에, 거대언어모델이 SHAP 분석 결과에 대한 맥락을 파악하며 예측 모델을 해석하기 때문에 설명가능성을 더욱 구체화할 수 있다는 장점이 있다.

이때, 거대언어모델에서는 프롬프트의 제시 방법이 출력 결과에 큰 영향을 미칠 수 있다 (Minaee et al., 2024). 즉, 사전 학습된 지식을 바탕으로 입력된 프롬프트를 해석하고 관련된 출력을 생성하는 거대언어모델의 특성상, 프롬프트의 구성, 표현 방식, 그리고 제공된 맥락에 따라 모델이 생성하는 답변이나 콘텐츠의 질과

정확도가 크게 달라질 수 있다. 이에, 이미지 형태로 표현된 그래프 형식의 SHAP 분석 결과에 대하여 명확한 설명가능성을 도출할 수 있는 프롬프트를 구성해야 한다. Table 1은 거대언어모델을 이용하여 이미지 형태로 표현된 그래프 형식의 SHAP 분석 결과를 해석하기 위해 활용한 프롬프트의 형식을 나타낸다. 프롬프트는 크게 SHAP 분석의 개념에 대한 설명과 주어진 과제에 대한 설명으로 이루어진다. 먼저, SHAP 분석의 개념에 대한 설명을 통해 거대언어모델로 하여금 SHAP 분석의 정의를 상기시킨다. 이후, 주어진 과제에 대한 설명을 통해 거대언어모델이 수행해야 하는 과업을 지시한다. 본 기법에서는 SHAP 분석 결과에서 크게 Summary plot과 Dependence plot을 다루기에, 각각의 경우에 대한 프롬프트를 개발하였다. Summary plot이란, 예측 모델에서 활용된 모든 입력변수의 Shapley 값 분포를 한눈에 보여주는 그래프를 말하며, 이를 통해 입력변수들의 중요도를 비교할 수 있게 한다. Dependence plot이란, 특정 입력변수의 값과 그 입력변수의 Shapley 값 사이의 관계를 시각화한 그래프를 말한다. 이 그래

Table 2 Input variables of Hawaii Natural Energy Institute Battery dataset

No.	Input variables	Description	Variable type
F1	Discharge Time (s)	Time to reach the minimum voltage	Continuous
F2	Time at 4.15V (s)	Time that the voltage reaches 4.15V	Continuous
F3	Time Constant Current (s)	Time when the current remains constant at its maximum value	Continuous
F4	Decrement 3.6-3.4V (s)	Time required for the voltage to decrease from 3.6V to 3.4V	Continuous
F5	Max. Voltage Discharge (V)	Initial and maximum value of voltage	Continuous
F6	Min. Voltage Discharge (V)	Initial and minimum value of voltage	Continuous
F7	Charging Time (s)	Total charging time	Continuous

Table 3 Output variable of Hawaii Natural Energy Institute Battery dataset

Output variable	Description	Variable type
RUL	Remaining useful life of Lithium-ion battery	Continuous

프는 개별 입력변수가 모델 예측에 어떻게 기여하는지를 더욱 자세히 분석할 수 있게 해주며, 이를 통해 특정 입력변수가 다른 입력변수와 어떻게 상호작용하며 모델 예측에 영향을 미치는지 파악할 수 있다. SHAP 분석 결과로 다루는 각각의 Plot에 대한 명사와 함께, 리튬 이온 배터리의 잔존 수명을 예측하는 기계학습 모델에서 설명가능성을 텍스트 형태로 구체화하기 위한 과업이라는 점을 기술함으로써 거대언어모델이 주어진 과업을 명확히 이해하고 수행할 수 있도록 한다. 최종적으로, SHAP 분석의 개념에 대한 설명과 주어진 과업에 대한 설명을 합친 것이 본 기법에서 다루는 프롬프트의 형식이 된다.

이러한 과정을 거쳐 도출된 설명가능성은 단순히 그래프 형식으로 표현된 SHAP 분석을 넘어, 거대언어모델을 통해 해당 그래프에 대하여 구체화된 텍스트 형태로 표현되기 때문에 사용자로 하여금 예측 모델에 대한 신뢰도와 설명가능성에 대한 이해도를 더욱 향상시킬 수 있다.

4. 실험 및 결과

4.1 데이터셋

본 논문에서 제안하는 기법의 효과성을 검증

하기 위해, 공개적으로 사용 가능한 Hawaii Natural Energy Institute(HNEI) 배터리 데이터셋을 이용하였다(Devie et al., 2018). HNEI의 연구진이 51개의 리튬 이온 배터리 셀에서의 사이클링을 통해 셀 분해의 가변성을 조사하며 수집한 데이터 중 대외적으로 공개한 15개의 배터리 셀에 대한 데이터를 본 논문에서의 데이터셋으로 활용한다. 이 15개의 배터리 셀은 LG화학이 개발한 모델 ICR18650 C2 에서의 상용 2.8 Ah NMC-LCO/graphite 18650 셀이며, 본 데이터셋은 해당 셀들이 기온 25도에서 1.5C 방전 및 C/2 충전 프로토콜을 이용하여 최대 1000번 사이클링하며 수집된 데이터이다.

Table 2는 예측 모델에서 활용한 입력변수들을 나타낸다. 배터리의 방전 시간, 전압 4.15V에 도달하기까지 소요된 시간, 전류가 최댓값에서 일정하게 유지되는 시간, 전압이 3.6V에서 3.4V로 감소하는 데 필요한 시간, 최소 및 최대 전압, 충전 시간 등 7가지의 입력변수를 활용하였다. 모든 입력변수들은 연속형 데이터로 표현되었다. Table 3은 예측 모델에서 활용한 출력변수인 배터리의 잔존 수명으로, 배터리에서의 1회 충방전 주기를 나타낸다(Devie et al., 2018; Wu et al., 2022). Table 4와 5는 각각 데이터셋에서의 입력변수와 출력변수에 대한 요약 통계이다.

Table 4 Summary statistics for input variables of Hawaii Natural Energy Institute Battery dataset

Variable Statistics	Discharge Time (s)	Time at 4.15V (s)	Time Constant Current (s)	Decrement 3.6-3.4V (s)	Max. Voltage Discharge (V)	Min. Voltage Discharge (V)	Charging Time (s)
Mean	4581.27	3768.33	5461.26	1239.78	3.90	3.57	10066.49
Standard deviation	33144.01	9129.55	25155.84	15039.58	0.09	0.12	26415.35
Min. value	8.69	-113.58	5.98	-397645.90	3.04	3.02	5.98
25%	1169.31	1828.88	2564.31	319.60	3.84	3.48	7841.92
50%	1557.25	2930.20	3824.26	439.23	3.90	3.57	8320.41
75%	1908.00	4088.32	5012.35	600.00	3.97	3.66	8763.28
Max. value	958320.37	245101.11	880728.10	406703.76	4.36	4.37	880728.10

Table 5 Summary statistics for output variable of Hawaii Natural Energy Institute Battery dataset

Variable Statistics	RUL (Cycle)
Mean	554.19
Standard deviation	322.43
Min. value	0.00
25%	277.00
50%	551.00
75%	839.00
Max. value	1133.00

4.2 실험 환경

제안하는 기법의 성능을 평가하기 위해, 다양한 통계적 기법 기반 예측 모델과 기계학습 기반 예측 모델들과 비교하는 실험을 수행하였다. 모든 데이터는 최소-최대 정규화를 이용하여 0 과 1 사이의 값으로 표현되었으며, 훈련, 검증, 평가 데이터셋은 7:1:2의 비율로 설정하였다. 실험에 사용한 통계적 기법 및 기계학습 모델은 Linear Regression, SGD Regression, Extra Tree Regression, Multi-Layer Perceptron, Gradient Boosting, AdaBoost, XGBoost, LightGBM, CatBoost, Decision Tree, K-Nearest Neighbor, Bagging Regression, Random Forest로 총 13 가지의 모델을 활용하였다(Maulud and Abdulazeez, 2020; Bentejac et al., 2020).

평가 지표로는 예측 모델에서 주로 사용되는 지표인 Root mean squared error(RMSE), Mean absolute error(MAE), R-squared value (R2

Score)를 사용하였다(Lee and Rew, 2024). RMSE는 예측값과 실제값 간 차이의 차이를 제곱한 후, 그 평균을 구하고 마지막으로 제곱근을 취한 값이다. 값이 낮을수록 모델의 예측 성능이 더 좋다는 것을 의미하는 RMSE는 큰 오차에 더 큰 가중치를 부여함으로써 큰 예측 오류를 민감하게 반영한다는 특성이 있다. MAE는 예측값과 실제값 간의 차이의 절댓값을 평균으로 나타낸 지표로서 값이 낮을수록 더 정확한 예측을 나타낸다. MAE는 모든 오차를 동등하게 취급하기 때문에 RMSE에 비해 이상치의 영향을 덜 받는다는 특성이 있다. R2 Score는 결정 계수라고도 불리며, 예측 모델이 데이터의 변동성을 얼마나 잘 설명하는지를 나타내는 지표이다. 이는 0에서 1 사이의 값을 가지며, 값이 1에 가까울수록 예측 모델의 성능이 우수하다고 볼 수 있다. 식 (1)-(3)은 각각 RMSE, MAE, R2 Score의 공식을 나타낸다. n 은 전체 데이터의 개수를, y_i 는 실제 배터리 잔존 수명 데이터를 의미하고, \bar{y} 는 실제 배터리 잔존 수명 데이터의 평균값을, \hat{y}_i 는 예측값을 의미한다.

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

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

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Table 6 Comparison of the performance of prediction model

Model	RMSE	MAE	R2 Score
Linear Regression	138.738	94.547	0.8126
SGD Regression	138.819	95.793	0.8124
Extra Tree Regression	30.923	11.640	0.9906
Multi-Layer Perceptron	75.542	57.092	0.9444
Gradient Boosting	45.150	31.876	0.9801
AdaBoost	67.491	54.790	0.9556
XGBoost	24.728	13.986	0.9940
LightGBM	31.133	20.368	0.9905
CatBoost	27.793	17.301	0.9924
Decision Tree	29.665	11.115	0.9914
K-Nearest Neighbor	35.875	14.676	0.9874
Bagging Regression	23.009	11.019	0.9948
Random Forest	22.348	10.304	0.9951




Fig. 2 Comparison of the predicted value in proposed scheme and actual value

3.4절에서의 거대언어모델과 멀티모달 거대언어모델로는 각각 OpenAI의 GPT-4 Turbo와 GPT-4o를 이용하였다(OpenAI, 2023). GPT-4 Turbo는 OpenAI가 개발한 거대언어모델인 GPT-4에 대하여 성능 최적화와 비용 절감을 목표로 경량화된 버전으로서, GPT-4와 동일한 기본 구조를 공유하면서도 더 빠르고 비용 효율적으로 작동할 수 있도록 설계되었다. GPT-4o는 텍스트, 이미지, 음성 등 다양한 유형의 데이터를 처리할 수 있는 능력을 갖춘 멀티모달 거대언어모델을 말한다. 이는 사용자가 입력 데이터를 다

양한 형식으로 제공할 수 있게 하며, 모델이 이를 종합적으로 이해하여 더 정확한 예측과 응답을 생성할 수 있게 한다는 특징이 있다.

4.3 배터리 잔존 수명 예측 성능 평가

4.2절에서 기술한 실험 환경을 바탕으로 배터리 잔존 수명 예측 모델의 성능을 평가하였다. Table 6은 RMSE, MAE, R2 Score를 기준으로 배터리 잔존 수명 예측 모델의 성능을 비교한 결과이다. 각 평가 지표에 대하여 가장 좋은 성능을 보인 모델은 진한 색을, 2번째로 좋은 성능을 보인 모델은 밑줄을 표기하였다. 모든 평가 지표에서 Random Forest를 이용한 예측 모델이 가장 우수한 성능을 보이며, Bagging Regression이 2번째로 우수한 성능을 보이고 있다. 전통적인 통계적 기법인 Linear Regression과 SGD Regression은 타 기계학습 모델들에 비해 좋지 않은 성능을 보였으며, XGBoost와 CatBoost 등 Gradient Boosting에 기반한 Ensemble Learning 모델들이 대체로 우수한 성능을 보이고 있다는 점을 파악할 수 있다.

제안하는 기법의 우수성을 더욱 자세히 검증하기 위해, 실제 배터리 잔존 수명 데이터와 제안하는 기법의 예측 결과를 서로 비교하였다. Fig. 2는 Random Forest를 이용한 배터리 잔존

Table 7 Interpretation of SHAP analysis using large language model

Result
<p>According to the SHAP analysis, the most important feature for predicting the remaining useful life (RUL) of the lithium-ion battery is "Discharge Time = -0.083" with a feature importance score of +132.69. This means that a shorter discharge time is strongly associated with a higher predicted RUL. The predicted value of RUL is 761.55.</p> <p>Additionally, features like "Decrement 3.6-3.4V (s)" with a score of +34.45, "Min. Voltage Charge. (V)" with a score of +24.18, and "Max. Voltage Dischar. (V)" with a score of +22.2 have positive impacts on predicting RUL. This indicates that higher values for these features are associated with a higher predicted RUL.</p> <p>On the other hand, features like "Charging time (s)" with a score of -15.89, "Time constant current (s)" with a score of +10.15, and "Time at 4.15V (s)" with a score of -3.74 have smaller impacts but still influence the predicted RUL. Specifically, longer charging times and longer times at 4.15V are associated with a decrease in the predicted RUL.</p> <p>To adjust the predicted RUL from 761.55, changing the values of these key features is necessary. Increasing the value of "Discharge Time" or decreasing values of "Decrement 3.6-3.4V (s)", "Min. Voltage Charge. (V)", and "Max. Voltage Dischar. (V)" can negatively influence the RUL prediction. Conversely, reducing the times for "Charging time (s)" and "Time at 4.15V (s)" may help in adjusting the predicted RUL favorably.</p>

수명 예측 기법이 도출한 예측값과 실제 데이터 간의 관계를 그래프 형태로 시각화한 모습이다. Fig. 2의 가로축은 실제값을 나타내며, 세로축은 예측값을 나타낸다. 전반적으로, 제안하는 기법인 Random Forest를 이용한 기계학습 기반 예측 모델이 배터리의 잔존 수명을 명확히 예측하고 있다는 점을 확인할 수 있다.

4.4 거대언어모델 기반 SHAP 분석

거대언어모델을 직접적으로 연계하여 SHAP 분석을 수행한 결과를 Table 7에 나타내었다. 주어진 입력 데이터에 대하여 모델이 예측값을 도출하는 데 있어 어떠한 입력변수들이 주요하게 작용하였는지를 텍스트 형태로 설명하고 있다. 해당 입력 데이터에서는 배터리의 방전 시간을 나타내는 변수인 Discharge Time (s)가 가장 중요한 입력변수이며, 짧은 방전 시간이 높은 배터리의 잔존 수명을 예측하는 데 크게 관련이 있다고 해석하고 있다. 또한, Decrement 3.6-3.4V (s), Min. Voltage Charge (V), Max. Voltage Discharge (V) 변수들은 모두 해당 입

력변수의 값이 높을수록 배터리의 잔존 수명 역시 높은 수치로 예측한다고 설명하고 있다. Charging Time (s)와 Time constant current (s), 그리고 Time at 4.15V (s) 변수는 배터리의 잔존 수명을 예측하는 데 미약한 영향을 주는 입력변수라는 점 역시 서술하고 있다. 이를 통해, 주어진 입력 데이터에 대하여 모델이 예측값을 도출하는 데 있어서 어떠한 입력변수가 주요하게 작용하였고 각각의 입력변수가 예측 모델에 기여한 사항을 텍스트 형태로 파악함으로써 배터리 잔존 수명 예측 모델에서의 설명가능성을 구체화할 수 있었다.

Fig. 3, 4와 Table 8, 9는 이미지 형태로 표현된 그래프 형식의 SHAP 분석 결과에 대하여 멀티모달 거대언어모델을 이용하여 설명가능성을 해석한 결과들을 나타낸다. 먼저, Fig. 3과 Table 8은 각각 SHAP 분석의 Summary plot에 대하여 그래프로 시각화한 결과와 거대언어모델을 통해 텍스트 형태로 해석한 결과이다. Fig. 3의 경우, 파란색에서 빨간색으로 변할수록 입력변수의 값이 증가함을 나타낸다. 또한, 중앙선의 왼쪽에 위치한 점들은 예측값을 낮추는데, 오른쪽

Table 8 Interpretation of summary plot of SHAP analysis using large language model

Result

SHAP (SHapley Additive exPlanations) values indicate the impact of each feature on the model output. This graph shows the SHAP analysis result for a model predicting the remaining usage life of a battery. The graph displays how different features influence the battery life prediction. The y-axis lists the features, and the x-axis represents SHAP values, indicating the degree of impact on the model output. Higher feature values are shown in red, and lower feature values are shown in blue.

Key Feature Interpretations:

1. Discharge Time (s):

- This feature has a significant impact on the model, with a wide distribution of SHAP values. Longer discharge times (red) positively influence battery life, while shorter times (blue) negatively impact it.

2. Decrement 3.6-3.4V (s):

- Although this feature has a relatively smaller impact, it still plays an important role. Higher feature values (red) positively affect battery life.

3. Max. Voltage Dischar. (V):

- The maximum voltage during discharge shows that higher values (red) slightly positively influence battery life, while lower values (blue) have a negative impact.

4. Min. Voltage Charg. (V):

- This feature has a minimal impact on battery life, but higher values (red) have a slightly positive effect.

5. Time at 4.15V (s):

- The time at 4.15V tends to negatively influence battery life when feature values are higher (red).

6. Time constant current (s):

- Time at constant current positively affects battery life, with higher feature values (red) being beneficial.

7. Charging time (s):

- Charging time has a positive influence on battery life when feature values are higher (red) and a negative impact when values are lower (blue).

Overall Interpretation:

The most important features for predicting battery life are Discharge Time and Charging Time. These two features have the widest distribution of SHAP values, indicating that the model heavily relies on them. Other features also influence the prediction but to a lesser extent. This SHAP analysis helps to understand which features are crucial for the model's battery life predictions, aiding in battery management and optimization strategies.

Table 9 Interpretation of dependency plot of SHAP analysis for Discharge Time (s) variable using large language models

Result
<p>This SHAP dependence plot illustrates the relationship between the variable "Discharge Time (s)" and its SHAP value for predicting the remaining useful life (RUL) of the lithium-ion battery. The color gradient represents the "Min. Voltage Charg. (V)" feature.</p> <p>Interpretation:</p> <ol style="list-style-type: none"> 1. Discharge Time Influence: <ul style="list-style-type: none"> - Low Discharge Time (0-5s): When the discharge time is very low (close to 0 seconds), the SHAP values are widely spread, ranging from -400 to +400. This indicates that a very short discharge time can have a highly variable impact on the RUL prediction, possibly due to interaction with other features. - Moderate Discharge Time (5-10s): As the discharge time increases to between 5 and 10 seconds, the SHAP values generally become positive and cluster around +200. This suggests that a moderate discharge time is associated with an increase in RUL. - High Discharge Time (>10s): For discharge times above 10 seconds, the SHAP values are mostly positive but less frequent and spread out, indicating that higher discharge times generally contribute positively to RUL but are less common. 2. Interaction with Min. Voltage Charg. (V): <ul style="list-style-type: none"> - The color gradient shows the impact of "Min. Voltage Charg. (V)" on the SHAP value of "Discharge Time (s)". Points in red indicate higher values of "Min. Voltage Charg. (V)", while points in blue indicate lower values. - It can be observed that most points with high SHAP values (positive influence on RUL) correspond to lower "Min. Voltage Charg. (V)" (blue points). Conversely, some points with very high SHAP values correspond to higher "Min. Voltage Charg. (V)" (red points). <p>Summary:</p> <ul style="list-style-type: none"> - Short discharge times have a highly variable impact on RUL, influenced by other factors such as "Min. Voltage Charg. (V)". - Moderate discharge times are generally associated with a positive impact on RUL. - Long discharge times also contribute positively to RUL but are less frequent. - The interaction between "Discharge Time" and "Min. Voltage Charg. (V)" shows that lower values of "Min. Voltage Charg. (V)" tend to correspond with higher positive SHAP values for "Discharge Time".

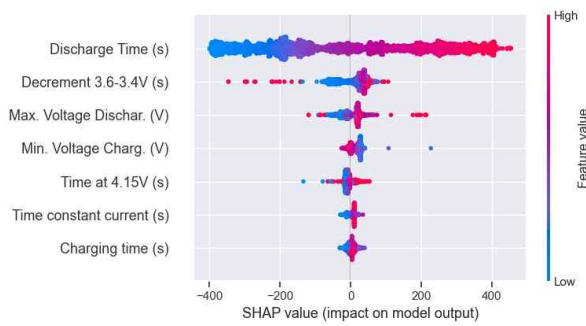


Fig. 3 Summary plot of proposed scheme




Fig. 4 Dependence plot of Discharge Time (s) variable of proposed scheme

쪽에 위치한 점들은 예측값을 높이는 데 기여함을 의미한다. 모델이 전반적으로 예측값을 도출하는 데 있어 Discharge Time (s) 변수가 가장 큰 영향을 미쳤음을 파악할 수 있으며, 배터리의 전압과 관련된 변수들이 예측에 있어서 중요하다 하는 것을 확인하였다. Table 8의 경우, 먼저 그래프의 가로축이 각 입력변수가 모델의 출력에 미치는 영향의 정도를 나타내는 Shapley 값을, 세로축은 각 입력변수를 나타낸다는 점을 상단에 기술하고 있다. 이후, 각 입력변수에 대하여 도출된 Shapley 값을 텍스트 형태로 설명하고 있다. 마지막으로, 배터리의 잔존 수명을 예측하는 데 있어 방전 시간과 충전 시간이 가장 중요한 입력변수라는 점을 서술하며 SHAP 분석의 결과를 전체적으로 정리하고 있음을 확인할 수 있다.

Fig. 4와 Table 9는 각각 예측 모델에서 가장 중요한 입력변수로 해석된 Discharge Time (s)

변수에서의 SHAP 분석의 Dependency plot에 대하여 그래프로 시각화한 결과와 거대언어모델을 통해 텍스트 형태로 구체화하여 해석한 결과이다. Fig. 4의 경우, Fig. 3과 마찬가지로 파란색에서 빨간색으로 변할수록 주어진 입력변수의 값이 증가한다는 것을 나타낸다. Shapley 값이 대체로 낮은 Discharge Time (s)에 분포하고 있는 것으로 보아, 방전 시간이 낮을수록 배터리의 잔존 수명 예측값이 높게 도출된다는 결론을 도출할 수 있다. Table 9의 경우, 방전 시간을 구간별로 분할한 이후 각 구간에서의 Shapley 값에 대하여 텍스트 형태로 설명하고 있다. 또한, 본 Dependency plot에서 다른 변수인 Discharge Time (s)와 타 변수인 Min. Voltage Charge (V)와의 상호 작용에 대해 다루고 있고, 마지막 단락에서는 본 SHAP 분석 결과를 해석한 것을 요약하여 제시하고 있음을 확인할 수 있다. 이를 통해, 배터리 잔존 수명 예측 모델에서 예측값을 도출하는 과정에 있어 각 입력변수의 영향력에 대해 텍스트 형태로 구체화하여 제시함으로써 사용자가 예측 모델을 해석하는 데 있어 도움을 줄 수 있음을 보였다.

5. 결론

본 논문에서는 거대언어모델에 기반한 SHAP 분석을 통해 리튬 이온 배터리 예측 모델에서의 설명가능성을 확보하는 기법을 제안하였다. 여러 예측 모델들과의 비교를 통해 주어진 배터리 데이터에서 가장 우수한 예측 성능을 보이는 기계학습 모델을 택하였으며, 해당 예측 모델에 대하여 거대언어모델에 기반한 SHAP 분석을 통해 설명가능성을 구체화하였다. 다양한 통계적 기법 및 기계학습 모델들과의 비교 실험 결과, Random Forest 기반의 예측 모델이 가장 우수한 성능을 보였다. 또한, 거대언어모델 기반 SHAP 분석을 통해 배터리 잔존 수명 예측 모델의 예측값 도출 과정을 분석한 결과, 방전 시간과 전압과 관련된 변수가 배터리의 잔존 수명 예측에 큰 영향을 미친다는 점을 확인할 수 있었다. 이러한 SHAP 분석 과정을 거대언어모델

을 통해 텍스트 형태로 서술함으로써 예측 모델에서의 설명가능성을 더욱 구체화할 수 있었다.

이러한 연구 결과는 향후 거대언어모델을 이용하여 예측 모델에서의 설명가능성을 확보하는 방안에 대한 연구를 촉진시킬 수 있을 것으로 기대된다. 특히, 리튬 이온 배터리는 실제 산업 현장에서 전기 자동차, 휴대전화, 노트북 등 다양한 기기에서 활용되고 있으며, 이러한 기기들에 탑재된 배터리들은 배터리 폭발 등 안전사고가 발생할 수 있다는 위험이 있다. 따라서, 실무적인 관점에서는 거대언어모델을 통해 배터리의 잔존 수명을 예측하는 모델에서의 설명가능성을 구체화함으로써 안전사고를 사전에 방지할 수 있는 조치들을 취할 수 있을 것으로 기대된다.

제안하는 기법에서는 설명가능한 인공지능 기법으로 SHAP 분석을 이용하였지만, 지금까지 설명가능한 인공지능 기법으로 SHAP 분석뿐만 아니라 LIME 분석, PDP, ICE plot 등 다양한 기법들이 개발되었다(Saeed and Omlin, 2023). 따라서 향후 연구로 SHAP 분석뿐만 아니라 다양한 설명가능한 인공지능 기법들을 거대언어모델과 연계하여 예측 모델에서의 설명가능성을 구체화하는 방안에 대한 연구를 수행할 예정이다. 또한, 비록 본 논문에서 실제 배터리 데이터셋을 이용하여 제안하는 기법의 우수성을 확인하였지만, 해당 실험 데이터셋이 단일 출처에 한정된다는 한계가 있다. 이에, 향후 연구로 다양한 유형의 배터리 데이터셋을 활용하여 제안하는 기법의 우수성을 검증해볼 계획이다. 이에 더해, 거대언어모델에서는 어떠한 형식으로 프롬프트를 제시하느냐에 따라 해당 모델의 출력 결과가 크게 달라질 수 있다(Minaee et al., 2024). 이를 반영하여, 향후 연구에서는 각각의 입력 데이터와 SHAP 분석 결과에 적합한 맞춤형 프롬프트를 구축함으로써 예측 모델에서 설명가능성을 확보하는 데 있어서의 정확도를 향상시키는 방안을 연구할 계획이다.

References

- Andrioaia, D., Gaitan, V., Cuela, G. and Banu, I. (2024). Predicting the RUL of Li-Ion Batteries in UAVs Using Machine Learning Techniques, *Computers*, 13(64). <https://doi.org/10.3390/computers13030064>
- Bentejac, C., Csorgo, A. and Martinez-Munoz, G. (2020). A Comparative Analysis of Gradient Boosting Algorithms, *Artificial Intelligence Review*, 54, 1937-1967. <https://doi.org/10.1007/s10462-020-09896-5>
- Chen, Y., Kang, Y., Zhao, Y., Wang, Li, Liu, J., Li, Y., Liang, Z., He, X., Li, X., Tavajohi, N. and Li, B. (2021). A Review of Lithium-ion Battery Safety Concerns: The Issues, Strategies, and Testing Standards, *Journal of Energy Chemistry*, 59, 83-99. <https://doi.org/10.1016/j.jechem.2020.10.017>
- Devie, A., Baure, G. and Dubarry, M. (2018). Intrinsic Variability in the Degradation of a Batch of Commercial 18650 Lithium-ion Cells, *Energies*, 11(5), 1031. <https://doi.org/10.3390/en11051031>
- Dhabe, P. R., Paraskar, S. R. and Jadhao, S. S. (2023). Battery State of Charge Estimation Methods - A Critical Review, *International Journal of Innovative Research in Electrical, Electronics, Instrumentation and Control Engineering*, 11(12). <https://doi.org/10.17148/IJIREICE.2023.111201>
- Fang, X., Xu, W., Tan, F., Zhang, J., Hu, Z., Qi, Y., Nickleach, S., Scolinsky, D., Sengamedu, S. and Faloutsos, C. (2024). Large Language Models(LLMs) on Tabular Data: Prediction, Generation, and Understanding - A Survey, *arXiv preprint*, arXiv:2402.17644
- Gao, K., Xu, J., Li, Z., Cai, Z., Jiang, D. and Zeng, A. (2022). A Novel Remaining Useful Life Prediction Method for Capacity Diving Lithium-ion Batteries, *ACS Omega*, 7(30), 26701-26714. <https://doi.org/10.1021/acsomega.2c03043>
- Gohel, P., Singh, P. and Mohanty, M. (2021). Explainable AI: Current Status and Future

- Directions, *arXiv preprint*, arXiv:2107.07045
- Gopalakrishnan, R., Vidhya, D. S., Bharath, P., Kaviyan, P. and Sivaselvam, P. (2023). Battery State Estimation and Control System for Mobile Charging Station for Electric Vehicles, *International Conference on Sustainable Computing and Data Communication Systems*, Mar. 23-25, Erode, India, pp. 985-989. <https://doi.org/10.1109/ICSCDS56580>. 2023.10104624
- Jiang, J., Shi, W., Zheng, J., Zuo, P., Xiao, J. A., Chen, X., Xu, W. and Zhang, J. (2013). Optimized Operating Range for Large-Format LiFePO₄/Graphite Batteries, *Journal of the Electrochemical Society*, 161(3), 336-341. <https://doi.org/10.1149/2.052403jes>
- Jiao, R. H., Ma, X., Li, L. and Xiao, J. P. (2022). Battery Remaining Useful Life Prediction Based on a Combination of ARMA and Degradation Model, 13th *International Conference on Reliability, Maintainability, and Safety*, Aug. 21-24, Hong Kong, China, pp. 115-119.
- Kim, H. and Yu, Y. (2023). Development of a Regulatory Q&A System for KAERI Utilizing Document Search Algorithms and Large Language Model, *Journal of Korea Society of Industrial Information Systems*, 28(5), 31-39. <http://doi.org/10.9723/jksiiis.2023.28.5.031>
- Kim, J., Park, J., Jin, B., Park, S., Jung, S. and Kim, J. (2022). Optimal Battery Aging Model based on Moore-Penrose Pseudo Inverse Matrix for Early Prediction of Remaining-useful-life on Lithium-ion Battery, *Power Electronics Annual Conference*, Jul. 5-7, Gyeongju, Korea, pp. 168-170.
- Kim, S., Park, S. and Kim, J. (2020). State of Health estimation based on Secondary Li-ion battery Electrochemical Modeling and Electrical Experiment, *Journal of IKEEE*, 24(4), 1098-1103. <https://doi.org/10.7471/ikeee.2020.24.4.1098>
- Lee, D. and Yoon, D. (2012). Evaluating Modeling Heat Generation Behavior for Lithium-ion Battery using FEMLAB, *Clean Technology*, 18(3), 320-324. <https://doi.org/10.7464/ksct.2012.18.3.320>
- Lee, J. and Rew, J. (2024). Large Language Models-based Feature Extraction for Short-Term Load Forecasting, *Journal of Korea Society of Industrial Information Systems*, 29(3), 51-65. <http://doi.org/10.9723/jksiiis.2024.29.3.051>
- Lee, M., Park, J. and Kim, J. (2021). Prediction of Maximum Available Current of High Power Lithium-ion Battery based on Electrochemical Impedance Spectroscopy, *Power Electronics Annual Conference*, Jul. 6-8, Buan, Korea, pp. 348-350.
- Liu, R. (2022). Remaining Useful Life Prediction of Lithium-ion Batteries Using Multiple Kernel Extreme Learning Machine, *Recent Advances in Computer Science and Communications*, 15, 715-721. <https://doi.org/10.2174/2666255813999201002152742>
- Louppe, G. (2014). *Understanding Random Forests: From Theory to Practice*, Dissertation, Graduate School of Liege University, Liege, Belgium.
- Luca, G. D., Blasio, G. D., Gimelli, A. and Misul, D. A. (2024). Review on Battery State Estimation and Management Solutions for Next-Generation Connected Vehicles, *Energies*, 17(1), 202. <https://doi.org/10.3390/en17010202>
- Lundberg, S. and Lee, S. (2017). A Unified Approach to Interpreting Model Predictions, *Proceedings of the Neural Information Processing Systems*, Dec. 4-9, California, CA, USA, pp. 4768-4777.
- Maulud, D. H. and Abdulazeez, A. M. (2020). A Review on Linear Regression Comprehensive in Machine Learning, *Journal of Applied Science and Technology Trends*, 1(4), 140-147. <https://doi.org/10.38094/jastt1457>

- Minaee, S., Mikolov, T., Nikzad, N., Chenaghlu, M., Socher, R., Amatrain, X. and Gao, J. (2024). Large Language Models: A Survey, *arXiv preprint*, arXiv:2402.06196
- Nitta, N., Wu, F., Lee, J. and Yushin, G. (2015). Li-ion Battery Materials: Present and Future, *Materials Today*, 18(5), 252-264. <https://doi.org/10.1016/j.mattod.2014.10.040>
- OpenAI. (2023). GPT-4 Technical Report, *arXiv preprint*, arXiv:2303.08774
- Park, J. (2022). *A Study on Battery Remaining Useful Life Prediction based on Incremental Machine Learning with Battery Usage Patterns*, Dissertation, Graduate School of Seoul National University of Science and Technology, Seoul, Korea.
- Park, K. and Yi, K. (2013). Voltage Balancing Circuit for Li-ion Battery System, *Journal of Korea Society of Industrial Information Systems*, 18(5), 73-80. <http://doi.org/10.9723/jksis.2013.18.5.073>
- Saeed, W. and Omlin, C. (2023). Explainable AI (XAI): A Systematic Meta-survey of Current Challenges and Future Opportunities, *Knowledge-based Systems*, 263, 110273. <https://doi.org/10.1016/j.knosys.2023.110273>
- Shi, Y., Yang, Y., Wen, J., Cui, F. and Wang, J. (2020). Remaining Useful Life Prediction for Lithium-ion Battery based on CEEMDAN and SVR, *IEEE 18th International Conference on Industrial Informatics*, Jul. 20-23, Warwick, United Kingdom, pp. 888-893.
- Son, Y. (2023). *A Study on Accelerating Battery Aging Estimation through Machine Learning for Reduced Estimation Time*, Thesis, Graduate School of Kookmin University, Seoul, Korea.
- Stroe, D. and Schaltz, E. (2018). SOH Estimation of LMO/NMC-based Electric Vehicle Lithium-ion Batteries Using the Incremental Capacity Analysis Technique. *IEEE Energy Conversion Congress and Exposition*, Sep. 23-27, Portland, OR, USA, pp. 2720-2725. <https://doi.org/10.1109/ECCE.2018.8557998>
- Wu, J., Kong, L., Cheng, Z., Yang, Y., and Zuo, H. (2022). RUL Prediction for Lithium Batteries Using a Novel Ensemble Learning Method, *International Conference on the Energy Internet and Energy Interactive Technology*, Mar. 25-27, Wuhan, China, pp. 313-326. <https://doi.org/10.1016/j.egy.2022.10.298>
- Zhao, J., Tian, L., Cheng, L., Zhang, Y. and Zhu, C. (2022). Review on RUL Prediction Methods for Lithium-ion Battery, *IEEE/IAS Industrial and Commercial Power System Asia*, Jul. 8-11, Shanghai, China, pp. 1501-1505. <https://doi.org/10.1109/ICPSAsia55496.2022.9949753>
- Zheng, Z., Wei, J., Hu, X., Zhu, H. and Nevatia, R. (2024). Large Language Models are Good Prompt Learners for Low-Shot Image Classification, *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Jun, 17-21, Seattle, WA, USA, pp. 28453-28462.
- Zhou, L., Lai, X., Li, B., Yao, Y., Yuan, M., Weng, J. and Zheng, Y. (2023). State Estimation Models of Lithium-Ion Batteries for Battery Management System: Status, Challenges, and Future Trends, *Batteries*, 9(2), 131. <https://doi.org/10.3390/batteries9020131>
- Zhou, Y. and Huang, M. (2016). Lithium-ion Batteries Remaining Useful Life Prediction based on a Mixture of Empirical Mode Decomposition and ARIMA Model, *Microelectronics Reliability*, 65, 265-273. <https://doi.org/10.1016/j.microrel.2016.07.151>



이 재 승 (Jaeseung Lee)

- 고려대학교 통계학과 학사
- (현재) 고려대학교 전기전자 공학과 석사과정
- 관심분야: 통계적 머신러닝, 빅데이터, 거대언어모델



유 제 혁 (Jehyeok Rew)

- 정회원
 - 경희대학교 전자전파공학과 학사
 - 고려대학교 전기전자컴퓨터 공학과 박사
 - 덕성여자대학교 데이터사이언스학과 조교수
- 관심분야: GIS, 정보검색, 빅데이터, 인공지능