

생존 분석 기반 리튬이온 배터리 잔존수명 예측 및 입력 특성 영향 분석

(Survival Analysis Based Prediction of Remaining Useful Life of Lithium-ion Batteries
with an Analysis of Input Feature Effects)

김예진*, 최민준*, 김태림**, 최대한**, 홍소현**, 김건민***, 김경백****

(Yejin Kim, Minjun Choi, Taerim Kim, Daehan Choi,
Soheyon Hong, Geonmin Kim, Kyungbaek Kim)

요약

리튬이온 배터리의 잔존수명(Remaining Useful Life, RUL) 예측은 에너지 저장 시스템(Energy Storage System, ESS)과 전기차 등 다양한 응용 분야에서 시스템의 안정성과 신뢰성을 확보하기 위한 핵심 과제로 인식되고 있다. 기존의 배터리 수명 예측 연구는 주로 회귀 기반 접근법을 통해 잔존 수명을 추정해 왔으나, 이러한 방식은 배터리 수명 특성을 시간에 따른 사건 발생 문제로 해석하는 데 한계를 가진다. 본 연구에서는 리튬이온 배터리의 잔존수명 예측 문제를 생존 분석 관점에서 재정의하고, 배터리 열화 과정에서 관측되는 상태 정보를 기반으로 수명 특성을 확률적으로 모델링하는 접근법을 제안한다. 생존 분석은 시간에 따른 위험도 변화를 분석할 수 있는 방법론으로, 배터리 수명을 절대적인 수명 값이 아닌 상대적인 위험도 관점에서 해석할 수 있는 장점을 가진다. 이를 통해 배터리 열화 양상의 차이를 보다 유연하게 반영할 수 있다. 또한, 입력 구성 특성에 따른 예측 성능의 변화를 분석함으로써, 생존 분석 기반 배터리 잔존수명 예측에서 입력 정보의 역할을 고찰한다. 본 연구에서 제안한 접근법은 배터리 수명 예측 문제에 대한 새로운 관점을 제시하며, 향후 배터리 상태 진단 및 예방적 유지보수 전략 수립에 활용될 수 있을 것이다.

■ 중심어 : 리튬이온 배터리 ; 잔존수명 예측 ; 생존 분석 ; 입력 특성 영향 분석

Abstract

Predicting the Remaining Useful Life (RUL) of lithium-ion batteries is crucial for the reliability of applications like energy storage systems (ESS) and electric vehicles. Conventional studies predominantly rely on regression but often limit the interpretation of degradation as a time-to-event process. This study reformulates RUL prediction using survival analysis, proposing a probabilistic model based on observed degradation states. This approach characterizes time-dependent risk, interpreting lifetime as relative hazard rather than absolute lifespan, which offers greater flexibility in capturing heterogeneous degradation patterns. Furthermore, we systematically analyze the impact of input feature configurations on prediction performance. The proposed approach introduces a new perspective on RUL prediction, applicable to battery health monitoring and preventive maintenance.

■ keywords : Lithium-ion Battery ; RUL Prediction ; Survival Analysis ; Input Feature Impact Analysis

I. 서 론

리튬이온 배터리[1-3]는 에너지 저장 시스템
(Energy Storage System, ESS) [4,5], 전기차
(Electric Vehicle) 및 다양한 전자기기에서 핵심적

* 준회원, 전남대학교 소프트웨어공학과

** 준회원, 전남대학교 인공지능학부

*** 준회원, 전남대학교 인공지능융합학과

**** 정회원, 전남대학교 인공지능융합학과

본 과제(결과물)는 2025년도 교육부 및 광주광역시의 재원으로 광주RISE센터의 지원을 받아 수행된 지역혁신중심 대학지원체계(RISE) 사업의 결과입니다.(2025-RISE-05-011)(34%)이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-지역지능화혁신 인재 양성사업의 지원을 받아 수행된 연구임(IITP-2025-RS-2022-00156287)(33%)본 연구는 과학기술정보통신부 및 정보통신기획평가원의 인공지능융합혁신인재 양성사업 연구 결과로 수행되었음(IITP-2025-RS-2023-00256629)(33%)

접수일자 : 2025년 12월 20일

게재 확정일 : 2026년 01월 23일

교신저자 : 김경백 e-mail : kyungbaekkim@jnu.ac.kr

인 에너지원으로 활용되고 있다. 특히 최근 친환경 에너지 정책과 전기차 보급 확대에 따라 대규모 배터리 시스템의 활용이 증가하면서, 배터리 시스템의 안전성과 신뢰성을 확보하는 것이 중요한 기술적 과제로 부각되고 있다. 이러한 배경에서 배터리의 상태를 정확히 진단하고, 향후 사용 가능 기간을 예측하는 기술은 시스템의 안정적인 운용과 유지보수 비용 절감을 위해 필수적인 요소로 인식되고 있다. 배터리 잔존수명 예측은 배터리 열화 상태를 정량적으로 평가하고 향후 성능 저하를 예측하는 것을 목적으로 한다. 기존의 배터리 수명 (Remiaing Useful Life, RUL) 예측 연구는 주로 배터리의 용량 열화 특성이나 운용 데이터를 기반으로 잔존수명을 직접 추정하는 회귀 기반 접근법을 중심으로 이루어져 왔다[6-10]. 이러한 접근법은 구현이 비교적 용이하고 직관적인 결과를 제공한다는 장점이 있으나, 배터리 열화 과정에서 나타나는 시간적 변화 양상과 개별 배터리 간의 열화 특성 차이를 충분히 반영하는 데에는 한계를 가진다. 특히 회귀 기반 예측은 배터리 수명을 하나의 고정된 수치로 표현하는데 초점을 두고 있어, 시간 경과에 따른 열화 위험도의 변화나 수명 종료 시점에 대한 불확실성을 해석하는 데 제약이 있다. 이로 인해 실제 운용 환경에서 요구되는 위험도 기반 관리나 예방적 유지보수 전략을 수립하기에는 제한적인 정보를 제공하는 경우가 많다[11]. 따라서 배터리 잔존수명 예측 문제를 단순한 수치 예측 문제가 아닌, 시간에 따른 열화 특성 변화라는 관점에서 재해석할 필요성이 제기된다.

이러한 문제의식 하에, 배터리 수명 예측을 시간과 사건의 관계로 해석할 수 있는 분석 관점이 주목 받고 있다. 해당 관점에서는 배터리의 열화 과정을 특정 시점에서의 상태 변화로만 판단하는 것이 아니라, 시간에 따라 변화하는 수명 특성을 종합적으로 분석하는 것이 가능하다. 이를 통해 배터리 간 열화 양상의 차이를 보다 유연하게 반영하고, 수명 예측 결과를 위험도 변화의 관점에서 해석할 수 있는 기반을 제공할 수 있다.

본 연구에서는 리튬이온 배터리 잔존수명 예측 문제를 시간에 따른 열화 특성 변화라는 관점에서 재정의하고, 배터리 열화 과정에서 관측되는 상태 정보를 기반으로 수명 특성을 분석하는 접근법을 제안한다. 또한 입력 특성 구성에 따른 예측 성능의 변화를 분석함으로써, 배터리 수명 예측에서 입력 정보의 역할을 고찰하고자 한다. 본 연구는 배터리 잔존수명 예측 문제에 대한 새로운 해석 관점을 제시함과 동시에, 향후 배터리 상태 진단 및 유지보수 전략 수립을 위한 기초적인 연구 방향을 제시하는데 목적이 있다.

II. 관련 연구

1. 배터리 잔존수명 예측 연구

배터리 잔존수명 RUL 예측에 관한 연구는 배터리 시스템의 안정적인 운용과 유지보수 효율 향상을 목적으로 다양한 접근법을 통해 수행되어 왔다. 초기 연구에서는 배터리 내부의 전기화학적 반응과 열화 메커니즘을 수식적으로 모델링하는 물리 기반 접근법이 주로 활용되었다[12,13]. 이러한 방법은 배터리 열화 현상을 이론적으로 설명할 수 있다는 장점을 가지나, 모델 구축 과정의 복잡성과 실제 운용 환경에 대한 적용성 측면에서 한계를 가진다.

이후 센서 데이터와 운용 데이터의 축적에 따라 데이터 기반 접근법이 본격적으로 연구되기 시작하였다. 특히 배터리의 용량 열화 곡선, 전압 및 전류 특성 등을 입력으로 하여 잔존수명을 직접 추정하는 회귀 기반 모델이 널리 활용되었다. 최근에는 기계학습 및 딥러닝 기법을 적용하여 비선형적인 열화 패턴을 학습하고 예측 성능을 향상시키려는 연구가 다수 보고되고 있다[14-20]. 이러한 연구들은 기존의 단순 통계 모델에 비해 향상된 예측 성능을 보였으나, 대부분 배터리 수명을 단일한 수치로 예측하는 데 초점을 두고 있다.

그러나 회귀 기반 RUL 예측은 배터리 열화 과정을 시간에 따라 점진적으로 변화하는 현상으로만

해석하는 경향이 있으며[11], 시간 경과에 따른 열화 위험도의 변화나 수명 종료 시점에 대한 불확실성을 정량적으로 표현하는 데에는 한계를 가진다. 또한 예측 결과를 기반으로 위험도 수준을 비교하거나, 배터리 간 열화 양상의 상대적인 차이를 분석하는 데에는 제한적인 정보를 제공하는 경우가 많다. 이러한 한계로 인해 배터리 수명 예측 결과를 실제 운용 환경에서의 의사결정에 직접적으로 활용하는 데에는 어려움이 존재한다.

2. 생존분석 기반 배터리 잔존수명 예측

생존 분석은 특정 사건이 발생하기까지의 시간을 분석하는 통계적 방법론으로, 의료 분야에서 환자의 생존 시간 분석이나 신뢰성 공학 분야에서 시스템의 고장 시간 분석 등에 널리 활용되어 왔다[21-25]. 생존 분석의 핵심적인 특징은 시간과 사건 간의 관계를 확률적으로 모델링할 수 있으며, 수명 종료 시점에 대한 불확실성을 포함하여 시간에 따른 위험도 변화를 분석할 수 있다는 점이다.

최근 일부 연구에서는 이러한 생존 분석의 개념을 배터리 수명 예측 문제에 적용하려는 시도[25]가 이루어지고 있다. 해당 접근은 배터리 수명을 절대적인 잔존수명 값이 아닌, 시간에 따른 위험도 변화의 관점에서 해석할 수 있도록 하며, 배터리 간 열화 특성의 상대적인 차이를 비교하는 데 유용한 정보를 제공한다. 이를 통해 배터리 열화 양상을 보다 유연하게 반영하고, 수명 예측 결과의 해석 가능성을 향상시킬 수 있다. 다만 생존 분석을 배터리 잔존수명 예측에 적용한 기존 연구는 아직 제한적인 수준에 머물러 있으며, 적용 대상 데이터나 입력 특성 구성에 대한 체계적인 분석은 충분히 이루어지지 않았다. 특히 배터리 열화 과정에서 관측되는 다양한 상태 정보 중 어떤 특성이 생존 분석 기반 수명 예측에 중요한 역할을 수행하는지에 대한 분석은 상대적으로 부족한 실정이다. 또한 일부 연구는 생존 분석 기법을 단순 비교 대상으로 활용하거나, 기존 예측 모델의 보조적인 수단으로 적용하는 데

그치는 경우도 존재한다. 즉, 기존의 배터리 잔존수명 예측 연구는 주로 회귀 기반 모델을 통해 수명을 직접 추정하는 데 초점을 맞추어 왔으며[26], 생존 분석을 적용한 연구 역시 제한적인 범위에서 이루어져 왔다. 이에 반해 본 연구는 배터리 잔존수명 예측 문제를 시간에 따른 열화 특성 변화라는 관점에서 재정의하고, 생존 분석을 주요 분석 틀로 활용한다는 점에서 기존 연구와 차별성을 가진다. 특히, 리튬이온 배터리의 열화 과정은 일반적으로 비선형적이며 비정상적인 특성을 가진다. 본 연구에서 제안하는 생존 분석 기반 접근은 배터리 수명 예측 문제를 사건 발생 문제로 재정의한다. 즉, 배터리 수명 종료를 하나의 사건으로 정의하고, 잔존수명을 절대적인 값이 아닌 위험도의 시간적인 변화로 모델링 한다. 또한 본 연구는 입력 특성 구성에 따른 예측 성능 변화를 분석함으로써, 생존 분석 기반 배터리 수명 예측에서 어떤 입력 정보가 중요한 역할을 수행하는지를 체계적으로 고찰한다. 이를 통해 배터리 수명 예측 문제에 대한 해석 가능성을 높이고, 생존 분석 기반 접근의 실용적 적용 가능성을 확장하고자 한다.

III. 생존분석 기반 잔존수명 예측 모델 설계

1. 데이터셋 개요 및 특징

본 연구에서는 리튬이온 배터리의 열화 특성과 잔존수명 RUL을 분석하기 위해 NASA Ames Research Center 산하 Prognostics Center of Excellence(PCoE)에서 공개한 리튬이온 배터리 수명 데이터셋을 활용하였다. 해당 데이터셋은 동일한 화학 조성을 가진 배터리 셀을 대상으로 통제된 실험 환경에서 반복적인 충·방전 사이클을 수행하며, 수명 종료에 이르기까지 장기간 관측한 실험 데이터로 구성되어 있다.

원본 데이터셋은 총 7,565개의 기록과 34개의 배터리 셀을 포함하고 있으나, 모든 배터리가 동일한

길이의 실험 구간을 갖는 것은 아니다. 일부 배터리는 실험 도중 중단되거나 관측 기간 내에 수명 종료에 도달하지 않은 상태로 기록이 종료되어, 열화 전과정이 관측되지 않은 경우도 포함되어 있다.

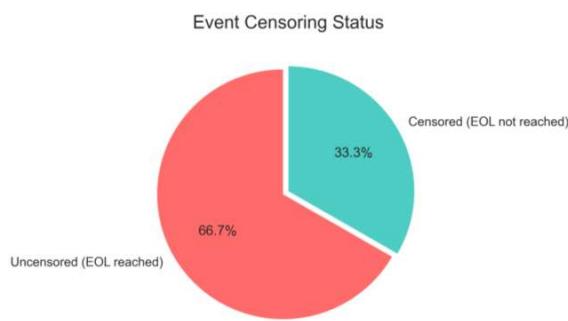


그림 1. 배터리 데이터셋 사건 검열 상태 분포

본 연구에서는 입력 특성 구성에 따른 예측 성능 차이를 명확히 분석하기 위해, 관측 기간 내에 수명 종료(End of Life, EOL)에 도달한 배터리만을 의도적으로 선별하여 분석에 사용하였다. 그 결과 총 10개의 배터리가 최종 분석 대상으로 선정되었으며, 이들 배터리는 열화 초기부터 후기까지의 사이클 데이터가 연속적으로 확보된 경우에 해당한다. 선정된 배터리들은 사이클 단위로 분해되어 분석 샘플로 재구성되었으며, 이를 통해 총 723개의 분석용 데이터 샘플이 생성되었다.

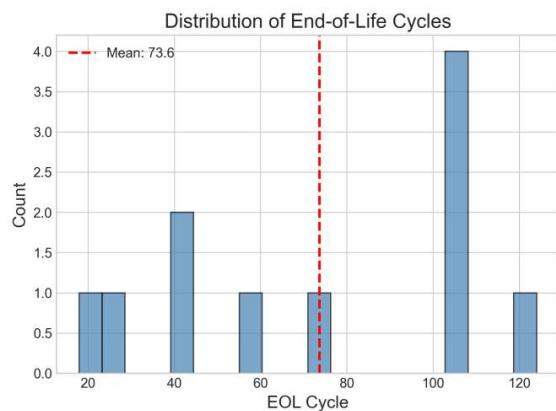


그림 2. 배터리 종료 수명(EOL) 사이클 분포

배터리 수명 종료 시점 EOL은 잔존수명 예측 문제를 정의하는 핵심 요소이다. 본 연구에서는 배터리의 상태지표 SoH가 초기 용량 대비 80% 미만으

로 감소하는 최초 시점을 수명 종료 시점으로 정의하였다. 분석 대상 배터리들의 EOL 도달 사이클 분포를 분석한 결과, 배터리별 수명 종료 시점에는 상당한 편차가 존재함을 확인하였다. 이러한 결과는 동일한 실험 조건 하에서도 배터리 열화 경로가 크게 달라질 수 있음을 시사한다. EOL 사이클 분포가 단일 평균값을 중심으로 밀집되지 않고 비대칭적인 분포를 형성한다는 점은, 배터리 수명을 단순한 회귀 문제로 접근하는 방식의 한계를 보여준다.

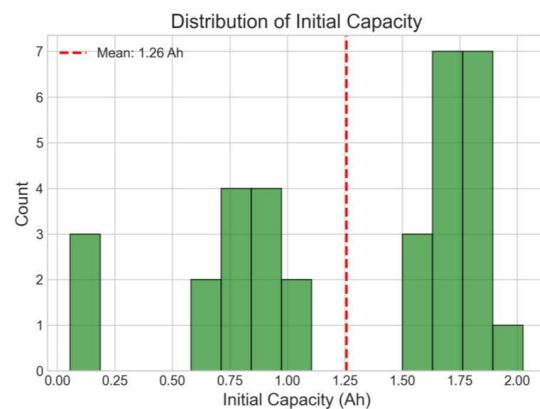


그림 3. 배터리 초기 용량 분포

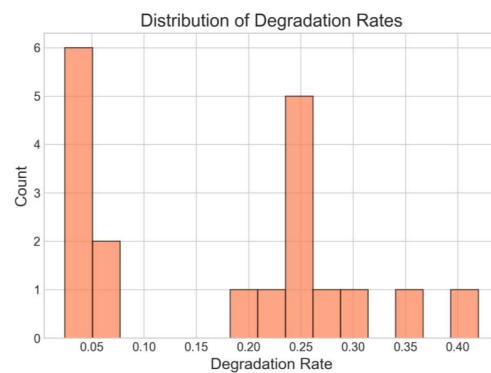


그림 4. 배터리 열화 속도 분포

배터리들의 초기 방전 용량 분포를 분석한 결과, 초기 용량은 약 0.1 Ah에서 2.0 Ah에 이르는 넓은 범위에 분포하며 평균값은 약 1.26 Ah로 나타났다. 이러한 초기 용량의 분산은 배터리 제조 편차, 실험 시작 시점의 상태 차이, 실험 조건 차이 등이 복합적으로 반영된 결과로 해석할 수 있다.

또한 배터리별 열화 속도 역시 배터리마다 큰 차이를 보였다. 일부 배터리는 완만한 열화 속도를 유지한 반면, 다른 배터리들은 비교적 초기 단계부터

Before/After Preprocessing Overview

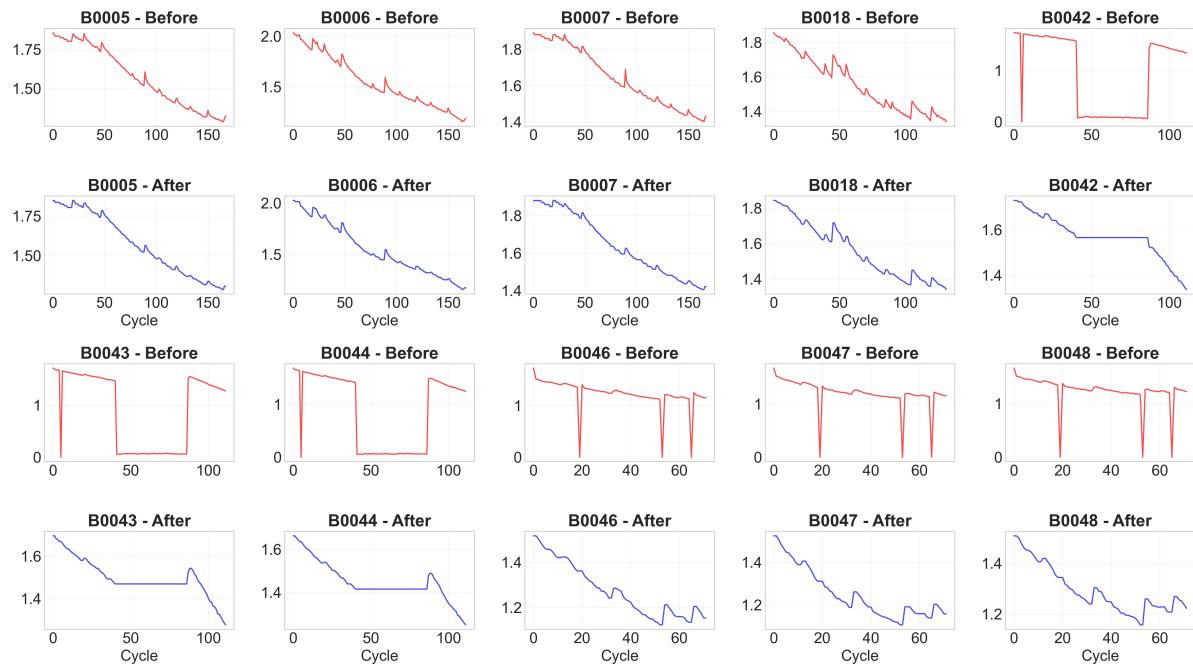


그림 5. 전처리 전후 용량 곡선 비교

All Battery Degradation Curves - Overview (Train vs Test)

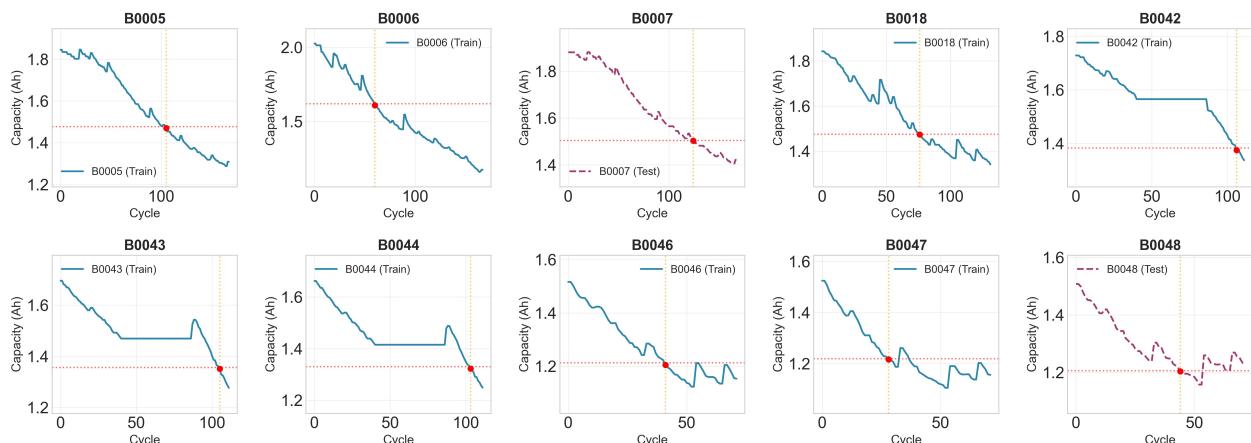


그림 6. 학습 및 테스트 데이터셋의 배터리별 열화 곡선 개요

급격한 열화 경향을 나타냈다. 이러한 관측 결과는 배터리 RUL 예측 문제에서 단일 시점의 상태 정보 뿐 아니라, 상태 변화율과 같은 동적 정보가 중요한 역할을 할 수 있음을 시사한다. 이는 본 연구에서 입력 특성 구성을 단계적으로 확장하여 분석한 제거 연구 설계의 근거가 된다.

4. 데이터 전처리 및 생존 데이터 구성

본 연구에서는 원시 방전 용량 데이터에 포함된

측정 오류, 센서 노이즈, 실험 환경 변화로 인한 이상치를 제거하고, 신뢰성 있는 생존 분석 데이터를 구성하기 위해 단계적인 전처리 과정을 적용하였다. 인접 사이클 간 용량 변화가 비현실적으로 큰 구간과 극단적인 이상값은 제거하거나 인접 값 기반 보간으로 보정하였으며, 이후 중앙값 필터와 이동 평균 기반 평활화를 적용하여 전반적인 열화 추세를 유지하면서 단기 변동성을 완화하였다. 전처리 결과, 비현실적인 급격한 감소 구간이 제거되고 물리

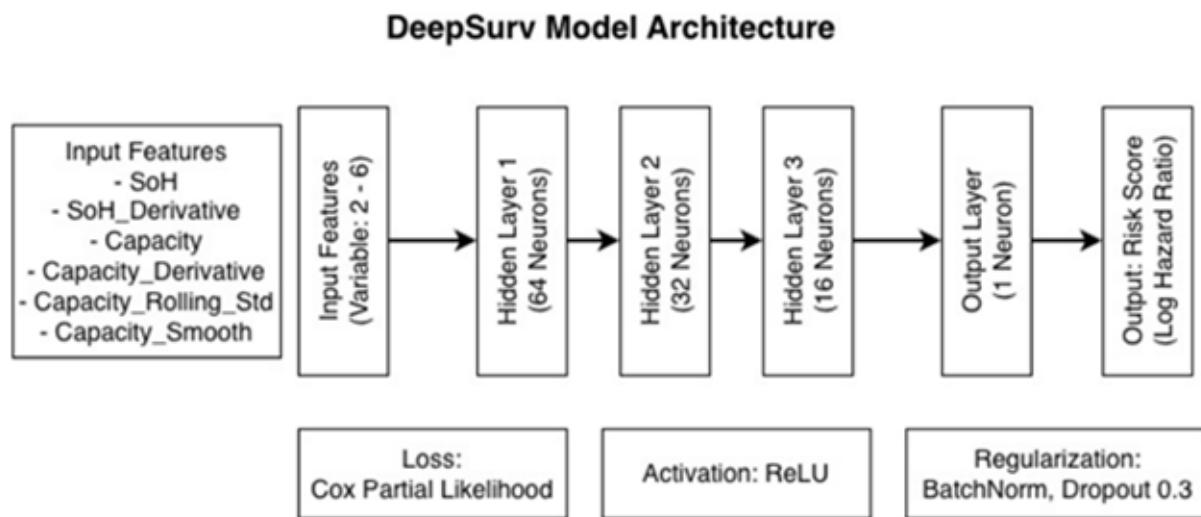


그림 7. DeepSurv 기반 배터리 수명 예측 아키텍처

적으로 타당한 열화 곡선이 형성됨을 확인하였다.

전처리된 데이터로부터 각 사이클 시점의 잔존수명(RUL)을 수명 종료(EOL)까지 남은 사이클 수로 정의하여 생존 시간으로 구성하였으며, EOL에 도달한 배터리만을 사용하여 비검열(un-censored) 생존 데이터셋을 구축하였다. 모델의 일반화 성능 평가를 위해 전체 10개 배터리 중 8개는 학습용, 2개는 시험용으로 배터리 단위 분할을 수행하여, 동일 배터리가 학습과 시험에 동시에 포함되지 않도록 하였다. 이를 통해 관측되지 않은 새로운 배터리에 대한 예측 성능을 평가할 수 있도록 설계하였다.

5. 입력 특성 구성에 따른 비교 실험 설계

본 연구에서는 리튬이온 배터리 잔존수명(RUL) 예측 문제를 생존 분석 관점에서 접근함에 있어, 배터리 열화 상태를 어떠한 수준의 입력 특성으로 표현하는 것이 예측 성능에 효과적인지를 체계적으로 분석하고자 한다.

이를 위해 DeepSurv 기반 생존 분석 모델의 네트워크 구조, 손실 함수(Cox partial likelihood), 활성화 함수, 정규화 기법 및 학습·데이터 분할 전략은 모두 동일하게 고정한 상태에서, 입력 특성 집합만을 단계적으로 변화시키는 통제된 비교 실험을 설계하였다. 이러한 설계는 모델 구조나 학습 조건의

차이에 따른 영향을 배제하고, 입력 특성 구성 수준이 예측 결과에 미치는 효과만을 명확히 분리하여 분석하기 위한 것이다.

입력 특성은 각 사이클 시점에서 관측되는 연속형 수치 변수로 구성되며, 별도의 임베딩 층을 사용하지 않고 표준화된 실수 벡터 형태로 신경망에 직접 입력된다. 이는 텍스트 및 범주형 데이터에서 주로 활용되는 임베딩 기반 표현과 달리, 배터리 열화 지표가 물리적 의미를 갖는 연속형 값이라는 점을 고려한 설계이다. 입력 차원은 비교 실험 조건에 따라 2 - 6으로 변하며, 각 조건에서 동일한 네트워크 구조를 유지한 채 입력 벡터만 변경하였다.

Deepsurv 네트워크는 3개의 완전 연결층(64 - 32 - 16)으로 구성된 점진적 축소 구조를 사용한다. 이는 (i) 초기 층에서 다차원 입력 간 비선형 상호작용을 학습하고, (ii) 중간 층에서 위험 관련 표현을 점진적으로 압축하며, (iii) 최종적으로 안정적인 단일 위험 점수로 수렴시키기 위한 구조이다. 또한 각 은닉층에 ReLU 활성화 함수와 Batch Normalization 기법을 적용하여 학습 안정성을 확보하고, 드롭아웃 설정을 통해 제한된 배터리 수 환경에서의 과적합 가능성을 완화하였다.

표 1. DeepSurv 모델 입력 특성 구성

Case	Feature
Basic	○ SoH

	<ul style="list-style-type: none"> ◦ Capacity ◦ SoH ◦ Capacity ◦ SoH_Derivative ◦ Capacity_Derivative
Dynamic	<ul style="list-style-type: none"> ◦ SoH ◦ Capacity ◦ SoH_Derivative ◦ Capacity_Derivative
Full	<ul style="list-style-type: none"> ◦ SoH ◦ Capacity ◦ SoH_Derivative ◦ Capacity_Derivative ◦ Capacity_Smooth ◦ Capacity_Rolling_Std

입력 특성은 배터리 열화 정보의 해석 수준에 따라 세 단계로 구성하였다. 첫 번째는 특정 시점의 상태만을 반영하는 정적 상태 기반(Basic) 구성으로, 방전 용량과 SoH (State of Health)를 포함한다. 두 번째는 여기에 열화 진행 속도를 반영하는 동적 특성(Dynamic)을 추가한 구성으로, 용량 및 SoH의 변화율을 포함한다. 마지막으로, 이동 평균 기반 평활 용량과 변동성 지표를 포함하는 통계적 특성(Full)을 추가하여, 열화 과정의 불규칙성과 변동성을 반영한 입력 구성을 정의하였다. 이러한 단계적 확장은 배터리 열화를 단일 시점의 상태가 아닌, 시간에 따른 위험도 진화 과정으로 해석하고자 하는 본 연구의 관점을 데이터 차원에서 구현한 것이다.

입력 특성 구성에 따른 예측 성능 평가는 생존 분석 문제의 특성을 고려하여 다각적인 지표를 통해 수행한다. 우선, 위험도 기반 예측 성능의 핵심 지표로 C-index(Concordance Index)를 사용하여, 예측된 위험도 순위와 실제 생존 시간 순서 간의 정합성을 평가한다. 또한 생존 확률로부터 환산된 잔존수명 값에 대해 평균 절대 오차(Mean Absolute Error, MAE)와 평균 제곱근 오차(Root Mean Squared Error, RMSE)를 함께 분석함으로써, 실제 RUL 추정 관점에서의 정량적 오차 특성을 평가한다.

특히, 본 연구에서 배터리 열화 위험도는 배터리 수명 종료(EOL)를 사건(event)로 정의할 때, 주어진 열화 상태 및 상태 변화 특성 x 하에 단위 시간(사이클) 내 사건이 발생할 조건부 경향을 의미한다. 이를 생존 분석 이론 위험 함수로 작성하면 수

식 (1)과 같다.

$$h(t | x) = \lim_{\Delta t \rightarrow 0} \frac{P(t \leq T < t + \Delta t | T \geq t, x)}{\Delta t}$$

(1)

여기서 T 는 EOL 도달 시점(사이클)이며, x 는 해당 시점에서 배터리 열화 상태 및 상태 변화도를 포함한다. 또한, Cox 비례위험 모형을 기반으로 위험 함수는 수식 (2)와 같다.

$$h(t | x) = h_0(t) \exp(f_\theta(x)) \quad (2)$$

$h_0(t)$ 는 기준 위험함수이며, $f_\theta(X)$ 는 DeepSurv 신경망이 학습하는 로그 위험비(log hazard ratio)로서, 본 논문에서의 위험 점수에 해당한다. 결과적으로 본 연구는 잔존수명을 직접 회귀하는 대신, 열화 상태와 변화 정보를 기반으로 사건 발생 위험의 상대적 크기를 학습함으로써 배터리간 열화 서열 구조를 추정한다.

IV. 입력 특성 구성에 따른 잔존수명 예측 분석

그림 8, 9, 10은 입력 특성 구성에 따라 DeepSurv 모델의 예측 성능이 어떻게 변화하는지를 각각 C-index, MAE, 그리고 RMSE 관점에서 비교한 결과를 나타낸다.

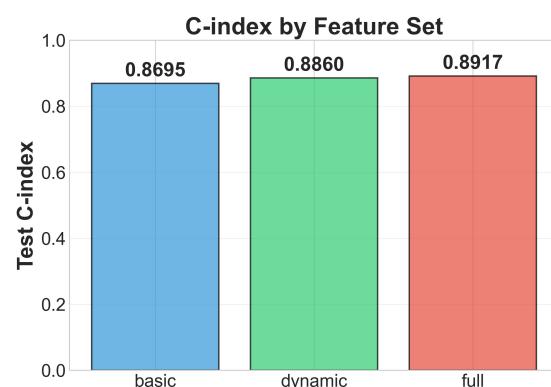


그림 8. 입력 특성에 따른 Concordance Index 비교

그림 8에서 확인할 수 있듯이, 기본 특성(capacity, SOH)만을 사용한 경우에도 C-index 0.8695로, 배터리 용량 및 SoH 정보만으로도 배터리 수명 사건의

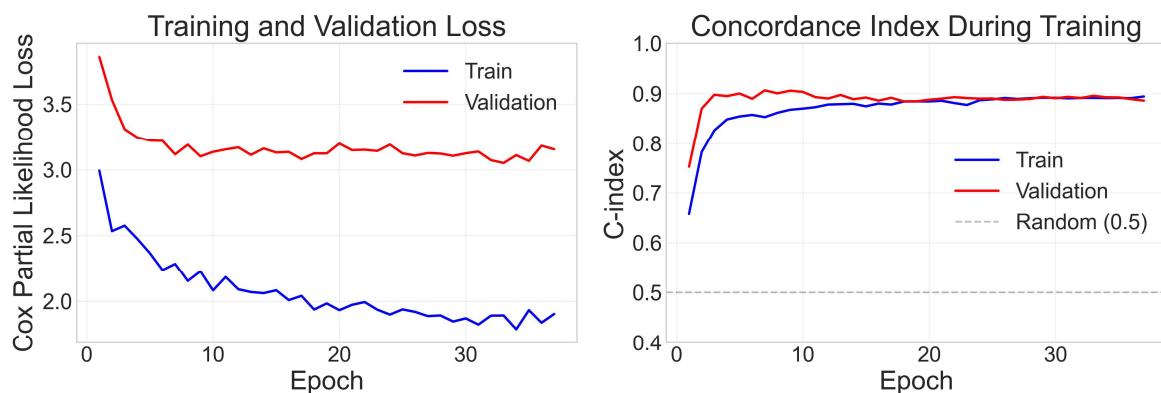


그림 11. DeepSurv 모델 학습 과정에서의 손실 함수 및 C-Index 변화

상대적 위험 순서를 상당 수준까지 설명할 수 있음을 보여준다. 이는 배터리 열화가 일정 수준 이상 진행되었을 경우, 단일 시점의 상태 정보만으로도 수명 위험도를 구분할 수 있음을 시사한다.

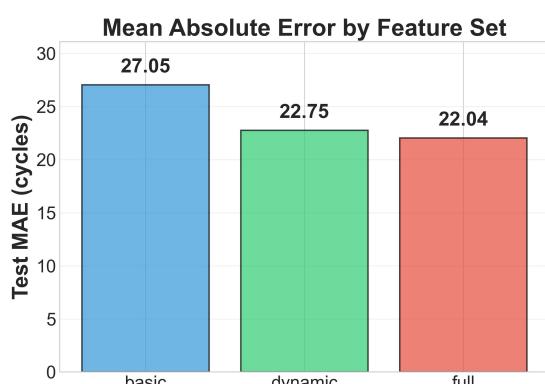


그림 9. 입력 특성에 따른 MAE 비교

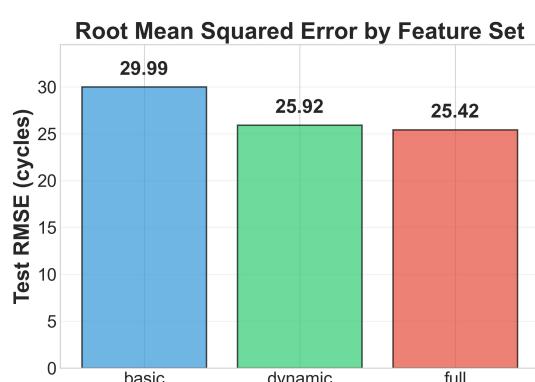


그림 10. 입력 특성 구성에 따른 RMSE 비교

열화 속도 정보를 포함한 동적 특성 구성에서는 C-index가 0.8860으로 약 1.9% 상승하였으며, 이는

단순한 상태 값뿐 아니라 시간에 따른 변화율 정보가 사건 발생 순서를 보다 정밀하게 구분하는 데 기여함을 의미한다. 이러한 경향은 그림 10의 MAE 결과에서도 일관되게 관찰된다. 기본 특성 구성 대비 동적 특성 구성에서는 MAE가 약 27.05에서 22.75로 약 15.9% 감소하여, 예측된 잔존수명의 절대 오차가 유의미하게 개선되었음을 확인할 수 있다. 이는 열화가 진행되는 속도 정보가 배터리 수명 감소 시점을 보다 직접적으로 반영하기 때문으로 해석할 수 있다. 변동성 정보를 포함한 전체 특성 구성에서는 C-index가 0.8917로 가장 높은 값을 기록하였으며, MAE 또한 22.04 cycles로 추가적인 감소를 보였다. RMSE 결과(그림 10) 역시 동일한 경향을 보이며, 기본 특성 구성 대비 전체 특성 구성에서 RMSE가 약 29.99에서 25.42로 감소하여, 큰 오차에 대한 민감도까지 완화되었음을 확인할 수 있다. 종합하면, 입력 특성을 단순한 상태 정보에서 열화 속도, 나아가 변동성 정보까지 단계적으로 확장할수록 DeepSurv 모델은 배터리 수명 사건의 상대적 위험 순서를 보다 정확히 학습하고, 잔존수명 예측 오차 또한 점진적으로 감소하는 경향을 보였다. 이는 배터리 열화 과정을 정적 상태가 아닌 시간에 따른 동적·화률적 과정으로 표현하는 것이 생존 분석 기반 RUL 예측에 효과적임을 실험적으로 입증하는 결과라 할 수 있다. 그림 11은 모델 학습 과정에서의 손실 함수 및 C-index 변화 양상을 나타낸다. 훈련 손실은 초기 학습 단계에서 급격히 감

소한 이후 점진적으로 수렴하는 양상을 보이며, 검증 손실 역시 큰 진동 없이 안정적으로 유지된다. 이는 제안된 모델이 제한된 배터리 수 환경에서도 과도한 과적합 없이 학습되었음을 시사한다. 또한, C-index 변화 결과를 보면, 학습 초반에 0.8 이상의 값을 빠르게 회복한 이후 비교적 좁은 범위 내에서 유지되는 것을 확인할 수 있다. 이러한 결과는 모델이 개별 샘플의 절대 수명 값을 정밀하게 회귀하기보다는, 생존 분석의 목적에 부합하도록 사건 발생 순서에 대한 상대적 위험도를 안정적으로 학습했음을 의미한다.

그림 12은 비검열 사건에 대해 추정된 위험 점수 분포를 나타낸다. 위험 점수는 Cox 비례위험 모형 기반의 log hazard ratio로 정의되며, 값이 클수록 단기 내 사건 발생 가능성이 높음을 의미한다. 그림에서 확인할 수 있듯이, 위험 점수는 음수에서 양수 까지 넓은 범위에 걸쳐 분포하고 있으며, 이는 모델이 배터리 상태를 단일 위험군이 아닌 연속적인 위험 스펙트럼으로 구분하고 있음을 보여준다.

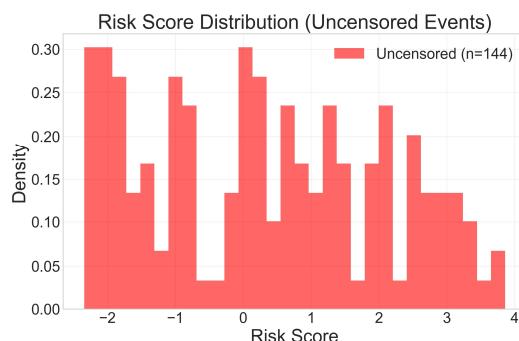


그림 12. 비검열 사건에 대한 위험 점수 분포

그림 13은 DeepSurv 모델이 추정한 위험 점수(risk score)를 기준으로 사분위수별로 분류된 배터리 그룹의 예측 생존 곡선을 나타낸다. 여기서 위험 점수는 Cox 비례위험모형의 log hazard ratio에 해당하며, 값이 클수록 동일한 시점에서 사건(EOL)에 도달할 조건부 위험이 높음을 의미한다. 본 연구에서는 평가 대상 배터리 샘플의 위험 점수를 오름차순으로 정렬한 후 이를 네 개의 동일한 크기의 분위수 그룹(Q1 - Q4)으로 분할하였으며, Q1은 가장 낮은 위험 점수를 갖는 저위험 그룹, Q4는 가장 높은

위험 점수를 갖는 고위험 그룹을 의미한다.

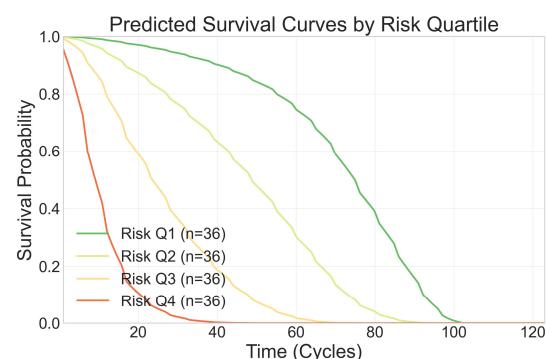


그림 13. 위험 점수 분위수 기반 생존 곡선 비교

고위험 분위수(Q4)에 해당하는 그룹일수록 생존 확률이 초기 단계부터 급격히 감소하는 반면, 저위험 분위수(Q1) 그룹에서는 생존 확률이 비교적 완만하게 감소하는 경향이 유지된다. 중간 위험 구간(Q2, Q3)은 이 두 극단 사이에서 단계적인 생존 확률 감소 양상을 보이며, 모든 분위수 그룹 간 생존 곡선이 시간 전반에 걸쳐 명확히 분리되어 나타난다. 특히, 생존 곡선 간의 교차가 거의 발생하지 않는다는 점은 위험 점수 기반 순위가 시간에 따라 일관되게 유지됨을 시사하며, 따라서 본 결과는 DeepSurv 모델이 잔존수명을 단일 값으로 회귀하는 기준 접근법과 달리, 생존 확률 관점에서 해석 가능한 출력을 제공함으로써 배터리 상태 진단 및 위험 기반 유지보수 의사결정에 활용될 수 있는 가능성을 제시한다.

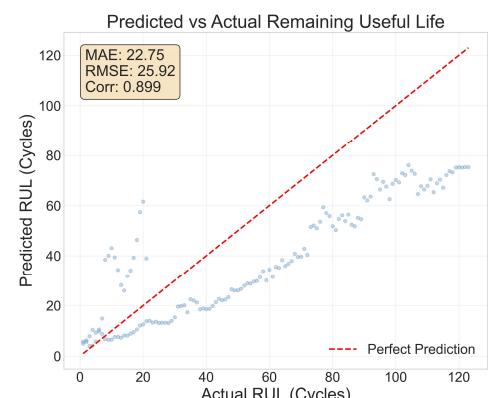


그림 14. 실제 잔존 수명과 예측 잔존 수명 비교

그림 14는 예측된 잔존수명과 실제 잔존수명 간의 관계를 나타낸 산점도이다. 예측값은 전반적으로

실제 RUL의 증가 추세를 잘 따라가며, 비교적 높은 상관성을 유지하는 것으로 나타났다. 그러나 실제 RUL이 큰 구간이나 EOL에 근접한 구간에서는 오차 분산이 증가하는 경향이 관찰되는데, 이는 생존 확률 곡선의 평坦 구간과 데이터 분포의 불균형에서 기인한 것으로 해석할 수 있다. 그럼에도 불구하고 평균 절대 오차 및 제곱근 평균 오차 기준에서 실용적인 수준의 예측 정확도를 확보하였다는 점에서, 제안된 접근법의 적용 가능성을 확인할 수 있다.

V. 결 론

본 연구에서는 리튬이온 배터리 잔존수명(RUL) 예측 문제를 생존 분석 관점에서 재정의하고, DeepSurv 모델을 활용하여 배터리 열화 과정의 사건 발생 위험도를 확률적으로 추정하는 접근법을 제안하였다. 수명 종료(EOL)를 사건으로 정의하고 상대적 위험도를 학습함으로써, 절대적 수명 값 예측이 갖는 불확실성을 완화하고 배터리 간 수명 서로 관계를 보다 안정적으로 모델링하고자 하였다.

실험 결과, 제안한 방법은 제한된 데이터 환경에서도 안정적인 학습 수렴과 함께 높은 C-index 성능을 보였으며, 이는 모델이 배터리 간 수명 순서를 효과적으로 학습할 수 있음을 의미한다. 또한 입력 특성 구성 비교를 통해 열화 속도 및 변동성 정보를 포함할수록 예측 오차가 감소하고 성능이 향상됨을 확인하였다. 한편, 본 연구는 비검열 데이터만을 대상으로 분석을 수행하였으므로, 향후 연구에서는 부분 검열 데이터가 포함된 실제 운용 환경으로 확장하여 일반화 성능을 추가적으로 검증할 필요가 있다. 종합적으로, 본 연구는 생존 분석 기반 DeepSurv 모델이 배터리 열화의 위험도를 해석 가능하게 추정하면서 구조적으로 일관된 RUL 예측을 가능하게 함을 실험적으로 입증하였으며, 이는 배터리 상태 진단 및 위험 기반 유지보수 전략 수립을 위한 유의미한 기반을 제공한다.

REFERENCES

- [1] Li, Matthew, et al. "30 years of lithium ion batteries." *Advanced materials*, 30.33 (2018): 1800561.
- [2] Blomgren, George E. "The development and future of lithium ion batteries." *Journal of The Electrochemical Society*, 164.1 (2016): A5019.
- [3] Kim, Taehoon, et al. "Lithium-ion batteries: outlook on present, future, and hybridized technologies." *Journal of materials chemistry A*, 7.7 (2019): 2942–2964.
- [4] Mitali, J., S. Dhinakaran, and A. A. Mohamad. "Energy storage systems: A review." *Energy Storage and Saving*, 1.3 (2022): 166–216.
- [5] Ibrahim, Hussein, Adrian Ilinca, and Jean Perron. "Energy storage systems—Characteristics and comparisons." *Renewable and sustainable energy reviews*, 12.5 (2008): 1221–1250.
- [6] L.T.Van, L.T.Ha, D.Chi, "Data-Driven Approach for Lithium-Ion Battery Remaining Useful Life Prediction: A Literature Review", *Smart Media Journal*, vol. 11, No. 11, pp. 63–74, 2022.
- [7] H.Ryoo, S.H.Lee, D.J.Chi, H.R.Park, "Improved SOH Prediction Model for Lithium-ion Battery Using Charging Characteristics and Attention-Based LSTM", *Smart Media Journal*, Vol. 12, No. 11, pp. 103–112, 2023.
- [8] Severson, Kristen A., et al. "Data-driven prediction of battery cycle life before capacity degradation." *Nature Energy*, 4.5 (2019): 383–391.
- [9] Q. Zhai, J. Sun and H. Wang, "Remaining useful life prediction of lithium-ion batteries based on indirect feature and bidirectional long and short-term memory network optimized by beluga whale optimization," *2024 4th International Conference on Neural Networks, Information and Communication Engineering (NNICE)*, Guangzhou, China, pp. 1418–1421, 2024.
- [10] Wu, Chao & Zhu, Chunbo & Ge, Yunwang & Zhao, Yongping. (2015). "A Review on Fault Mechanism and Diagnosis Approach for Li-Ion Batteries." *Journal of Nanomaterials*, pp. 1–9, 2015.
- [11] R. R. Richardson, C. R. Birk, M. A. Osborne and D. A. Howey, "Gaussian Process Regression for In Situ Capacity Estimation of Lithium-Ion Batteries," in *IEEE Transactions on Industrial Informatics*, vol. 15, no. 1, pp. 127–138, Jan. 2019.
- [12] Birk, Christoph R., et al. "Degradation diagnostics for lithium ion cells." *Journal of*

- Power Sources*, 341 (2017): 373–386.
- [13] Wu, Billy, et al. "Coupled thermal-electrochemical modelling of uneven heat generation in lithium-ion battery packs." *Journal of Power Sources*, 243 (2013): 544–554.
- [14] Li, Ruihe, et al. "The importance of degradation mode analysis in parameterising lifetime prediction models of lithium-ion battery degradation." *Nature Communications*, 16.1 (2025): 2776.
- [15] Meng, Jianwen, Toufik Azib, and Meiling Yue. "Early-Stage end-of-Life prediction of lithium-Ion battery using empirical mode decomposition and particle filter." *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, 237.5 (2023): 1090–1099.
- [16] Wang, Jianguo, et al. "A data-driven method with mode decomposition mechanism for remaining useful life prediction of lithium-ion batteries." *IEEE Transactions on Power Electronics*, 37.11 (2022): 13684–13695.
- [17] Wang, Dong, et al. "Prognostics of Lithium-ion batteries based on state space modeling with heterogeneous noise variances." *Microelectronics Reliability*, 75 (2017): 1–8.
- [18] Wang, Dong, Qiang Miao, and Michael Pecht. "Prognostics of lithium-ion batteries based on relevance vectors and a conditional three-parameter capacity degradation model." *Journal of Power Sources*, 239 (2013): 253–264.
- [19] Kouhestani, Hamed Sadegh, et al. "Data-driven prognosis of failure detection and prediction of lithium-ion batteries." *Journal of Energy Storage*, 70 (2023): 108045.
- [20] Madani, Seyed Saeed, et al. "A comprehensive review on lithium-ion battery lifetime prediction and aging mechanism analysis." *Batteries*, 11.4 (2025): 127.
- [21] Xue, Jingyuan, et al. "Survival Analysis with Machine Learning for Predicting Li-ion Battery Remaining Useful Life." arXiv preprint arXiv:2503.13558 (2025).
- [22] Kolekar, Shivani Sanjay, et al. "Web based microservice framework for survival analysis of lung cancer patient using digital twin." Annual Conference of KIPS. Korea Information Processing Society, 2021.
- [23] 최철웅 and 김경백. "폐암환자 생존분석에 대한 TNM 병기 군집분석 평가" 스마트미디어저널, vol. 9, no. 4, pp. 126–133, Jan. 2020.
- [24] Bappi, Ilias, et al. "HCLmNet: A Unified Hybrid Continual Learning Strategy Multimodal Network for Lung Cancer Survival Prediction." medRxiv (2024): 2024-12.
- [25] Santhira Sekeran, Maya, Milan Živadinović, and Myra Spiliopoulou. "Transferability of a battery cell end-of-life prediction model using survival analysis." *Energies*, 15.8 (2022): 2930.
- [26] Cox, D. R. "Regression Models and Life-Tables." *Journal of the Royal Statistical Society. Series B (Methodological)*, vol. 34, no. 2, 1972, pp. 187 – 220.
- [27] Y. Zhang, R. Xiong, H. He and M. G. Pecht, "Lithium-Ion Battery Remaining Useful Life Prediction With Box - Cox Transformation and Monte Carlo Simulation," in *IEEE Transactions on Industrial Electronics*, vol. 66, no. 2, pp. 1585–1597, Feb. 2019.

저자소개



김예진(준회원)
2022년~ 전남대학교 소프트웨어공학과
학사과정



김건민(준회원)
2025년 전남대학교 소프트웨어공학과
학사 졸업
2025년~ 전남대학교 인공지능융합학과
硕사과정

<주관심분야 : 마케팅 데이터 분석, 피쳐 엔지니어링,
데이터 모델링>



최민준(준회원)
2020년~ 전남대학교 소프트웨어공학과
학사과정

<주관심분야 : 인공지능, 강화학습, 빅데이터 응용>



김태림(준회원)
2023년~ 전남대학교 인공지능학부
소프트웨어전공 학사과정

<주관심분야 : 클라우드 컴퓨팅, 인공지능, 컴퓨터 네
트워크, 분산 시스템>



최대한(준회원)
2021년~ 전남대학교 인공지능학부
인공지능전공 학사과정

<주관심분야 : 데이터 분석, 강화학습, AI 엔지니어링>



홍소현(준회원)
2023년~ 전남대학교 인공지능학부
인공지능전공 학사과정

<주관심분야 : 컴퓨터 비전, 지능형 로봇 응용, 데이터
분석, IoT 시스템, 엣지 컴퓨팅>

<주관심분야 : 데이터 분석, 엣지 컴퓨팅, 클라우드 컴퓨팅, 클라우드 보안, 인공지능>



김경백(정회원)
1999년 한국과학기술원 전기및전자공
학과 학사 졸업
2001년 한국과학기술원 전기및전자공
학과 석사 졸업
2007년 한국과학기술원 전기및전자공
학과 박사 졸업
2012년~ 전남대학교 인공지능융합학과
교수

<주관심분야 : 지능형 분산시스템, 빅데이터 플랫폼,
인공지능, SDN/NFV>