

AI 기반 ESS셀 전주기 진단 및 보정 모델의 고도화 연구

(Advanced AI Framework for ESS Cell Full-Cycle Diagnostics and Calibration)

박주훈*, 이경일**

(Ju-Hoon Park, Kyung-Il Lee)

요약

본 논문은 AI 기반 ESS 셀의 진단·보정·복원 전주기 모델을 고도화하기 위해 다주파수 임피던스(EIS)와 4개월 장기 운전 데이터를 결합한 정밀 진단 프레임워크를 제안한다. 1Hz~1kHz EIS 데이터로부터 실수·허수 임피던스, 크기·위상각, 주파수 간 차이 등 고차원 특징을 추출하여 기존 3차 다항 보정식 대비 R^2 0.95 이상, MAPE 한 자릿수 중반의 우수한 내부저항·SOH 예측 성능을 달성하였다. 복원 단계별 EIS 패턴 분석을 통해 성공 셀에서 저주파·중간주파수 임피던스 감소(3.8~5.3%)와 SOH 19.7%p 향상(68.6→88.3%)을 확인하였으며, 핵심 EIS 인덱스($R_{1\text{Hz}}$, $R_{31\text{Hz}}$, $R_{1\text{kHz}}$)를 UL 1974, IEC 62933-2-1 표준 등급화 기준에 적용 가능한 보조 지표로 제시한다.

■ 중심어 : ESS 셀 진단 ; 전기화학 임피던스 ; SOH 예측 ; 배터리 복원

Abstract

This study proposes an advanced framework for full-cycle diagnostics, calibration, and restoration of ESS cells by integrating multi-frequency electrochemical impedance spectroscopy (EIS) with 4-month long-term operation data. High-dimensional features including real/imaginary impedance, magnitude, phase angle, and inter-frequency differences extracted from 1Hz~1kHz EIS data achieved superior internal resistance and SOH prediction performance ($R^2 \geq 0.95$, MAPE in mid single digits) compared to conventional 3rd-order polynomial calibration. Stepwise EIS pattern analysis during restoration revealed 3.8~5.3% impedance reduction in low/mid-frequency bands and 19.7%p SOH improvement (68.6→88.3%) in successful cells. Key EIS indices ($R_{1\text{Hz}}$, $R_{31\text{Hz}}$, $R_{1\text{kHz}}$) are proposed as supplementary metrics applicable to UL 1974 and IEC 62933-2-1 standardization requirements for repurposing and grading.

■ keywords : ESS cell diagnostics ; electrochemical impedance spectroscopy ; SOH prediction ; battery restoration

1. 서론

1.1 연구 배경

에너지저장장치(Energy Storage System, ESS)는 재생에너지 연계 및 전력망 안정화의 핵심 인프라로, 전기요금 절감과 피크 저감, 신재생에너지 출력 변동 완화에 중요한 역할을 수행한다. 그러나 국내에서는 2017년 이후 다수의 ESS 화재 사고가 보고되면서, 안전성 확보와 열화 진단·예방 기술의 중요성이 급격히 부각되었다. 이러한 맥락에서 셀 단위

의 정밀 진단과 보정, 복원 기술은 ESS의 수명 연장 과 안전성 향상, 그리고 2nd-life 재사용 체계 구축을 위한 핵심 기반 기술로 인식되고 있다[1-3].

한편, 전기차 및 ESS 분야에서 배터리 재사용·재제조를 촉진하기 위해 국제표준화 기구는 셀·모듈 단위의 진단 절차와 등급화 기준을 구체화하고 있다[3,4]. UL 1974 제2판은 EV 배터리를 ESS로 전환할 때의 평가 절차와 진단 정확도 요구사항을 제시하며, IEC 62933-2-1은 ESS의 단위 파라미터와 시험 방법, 효율·내구성 평가 기준을 정의함으로써 ESS 재사용·안전성 평가의 기준점을 제공한다[3,4].

* 정희원, 남부대학교 전기공학과

** 정희원, (주)브레이크 더 룰스 책임연구원

본 과제(결과물)는 2025년도 교육부 및 광주광역시 지원으로 광주RISE센터의 지원을 받아 수행된 지역혁신중심 대학지원체계(RISE)의 결과입니다.(2025-RISE-05-007)

접수일자 : 2026년 01월 26일

수정일자 : 1차 2026년 02월 11일, 2차 2026년 03월 05일

게재확정일 : 2026년 03월 26일

교신저자 : 박주훈 e-mail : jhpark@nambu.ac.kr

국내에서도 한국전기안전공사, 한화큐셀 등에서 ESS 안전관리와 진단 전략을 담은 가이드라인과 기술 보고서를 발간하며 시스템 수준의 안전 진단 체계를 고도화하고 있으나, 여전히 셀 수준에서의 정밀 진단·보정·복원에 대한 체계적 연구는 부족한 실정이다[1][5-7].

또한 스마트농업(Smart Agriculture) 분야에서는 센서 기반 온실·스마트팜, 재생에너지 연계 농업 설비가 확산되면서, ESS를 활용한 농업 에너지 관리와 전력 품질 안정화의 중요성이 커지고 있다. 농업용 ESS는 태양광·풍력 등 분산형 에너지원과 센서 네트워크·관개 시스템·환경 제어 장비를 연결하는 허브로서, 배터리 열화나 비균질 충·방전은 곧 생산성 저하와 유지보수 비용 증가로 이어질 수 있다. 따라서 스마트농업 환경에서도 적용 가능한, 셀 단위의 전주기 진단 및 보정 모델 고도화가 요구된다 [2-4][8].

1.2 선행 연구 요약

선행 연구에서는 인공지능 기반 3차 다항 보정 알고리즘을 활용하여 셀 내부저항을 히오키(HIOKI) 기준값 대비 $\pm 10\%$ 이내의 정밀도로 추정하고, 리튬련상·활성화 충방전·제한조건 사이클링을 포함한 복원 프로세스를 실증하는 모델을 제안하였다[10]. 이를 통해 셀의 상태지수(State of Health, SOH)는 평균 68.6%에서 88.3%로 약 19.7%포인트 향상되었고, 충·방전 효율도 90% 이상을 유지하여 UL 1974 및 IEC 62933-2-1의 진단 정확도 및 효율 기준을 충족함을 보였다. 이 연구는 셀 단위 진단 - 보정 - 복원의 전주기 모델을 제시함으로써 기존 BMS 수준 통계 진단의 한계를 보완하고, ESS 재사용·스마트농업 분야에 적용 가능한 프로토타입을 마련했다는 점에서 의의가 있다[2].

그러나 선행 연구에는 몇 가지 한계가 존재한다. 첫째, 진단 지표가 주로 단일 내부저항 값에 집중되어 있어, 셀의 전기화학적 상태를 보다 풍부하게 반영하는 다차원 임피던스 특성(Electrochemical Impedance Spectroscopy, EIS)을 충분히 활용하지

못하였다[4]. 둘째, 실험 조건이 $25\pm 2^\circ\text{C}$, 0.5C 수준의 제한된 환경에 집중되어 있어, 장기 운전 데이터 및 다양한 운전 조건에서의 일반화 성능과 안정성을 검증하기 어렵다는 점이 있다. 셋째, 3차 다항 회귀 기반 보정 모델은 구현이 간단하고 해석 용이성이 높다는 장점이 있으나, 다주파수 임피던스와 같은 고차원 데이터를 활용할 때는 비선형 특성을 충분히 포착하기 어렵다는 한계가 제기되었다.

1.3 연구 목적

본 연구의 목적은 선행 연구에서 제안한 AI 기반 ESS 셀 전주기 진단 - 보정 - 복원 전주기 모델을 고도화하기 위해, 다주파수 임피던스(EIS)와 3개월간의 장기 운전 데이터를 결합한 정밀 진단 프레임워크를 제시하는 것이다. 구체적으로, 첫째, 1 Hz에서 1 kHz까지의 실수·허수 성분에 대한 다주파수 임피던스를 이용하여 단일 내부저항을 대체·보완하는 고차원 진단 지표를 설계하고, 둘째, 약 4개월간 수집한 코딩 데이터를 바탕으로 데이터 전처리·특징 추출·AI 모델링을 수행하여 SOH 및 복원 성능을 예측하는 모델을 구현하며, 셋째, 리튬련상·활성화 충방전·제한조건 사이클링복원 프로세스 단계별 EIS 패턴 변화를 분석함으로써 복원 성공 셀과 실패 셀의 특성을 규명하는 것을 목표로 한다. 또한 선행 연구와 비교하여 본 논문에서는 고도화 연구 모델로써 저항·SOH 예측 $R^2 \geq 0.95$, MAPE를 8.7%에서 3.7~4.2%, 4개월 시간축 대비 5-fold 경계검증에서 성능 유지 여부를 확인하는 것이 특징이며, 본 연구에서는 다주파수 EIS 특징과 Random Forest, XGBoost 등 머신러닝 기반 비선형 모델을 탑재함으로써, AI 기반 ESS 셀 진단·보정 간 프레임워크를 고도화하였다.

본 연구의 주요 내용은 다음과 같다.

(1) 셀 단위 내부저항 중심의 진단 모델을 다주파수 임피던스 기반 고차원 지표로 확장함으로써, 국제표준에서 요구하는 진단 정확도 및 RUL 예측 성능을 만족하면서도 더 풍부한 상태 정보를 제공하는 진단 체계를 제안한다[5].

(2) 축적된 장기 운전 데이터를 활용하여, 단기·소규모 실험을 넘어 실제 운전 환경에 가까운 조건에서 AI 모델의 일반화 성능과 안정성을 검증한다.

(3) 복원 단계별 EIS 패턴 변화와 SOH 향상률, 효율 유지율에 대한 복원 성과를 연계 분석함으로써, 2nd-life ESS 및 스마트농업 ESS에 적용 가능한 등급화·선별 기준과 표준화 후보 지표를 제시한다.

(4) 원천 연구에서 제안한 3차 다항 뒷면 기반 셀 증상·복원 설계를 축소하여, 1Hz~1kHz 다주파수 EIS의 실수·허수, 사이즈, 내온간 차이 특징을 포함한 26차원 이상 고차원 특징 설계, 2025년 9월~2026년 1월 7일까지 약 4개월간 동일 ESS 모듈 기반 프로그래머 데이터셋 구축, 3차 다항식 기준 모델과 Random Forest, Gradient Boosting, XGBoost 등 비선형 스크롤 모델을 동일 데이터 처리·전처리에서 정량 처리함으로써, 고도화된 보정을 체계적으로 검토한다.

II. 관련연구

2.1. ESS 진단·복원 및 표준 동향

ESS 안전성 및 열화 진단과 관련한 국내외 정책·표준은 점차 셀·모듈 단위의 정량적 기준을 강화하는 방향으로 진화하고 있다[12]. 한국전기안전공사는 ESS 안전관리 가이드라인을 통해 설치·운영 단계에서의 위험요소, 점검 항목, 사고 예방·대응 체계를 제시하고 있으며, 환경부는 폐배터리 자원순환 로드맵 2030에서 EV·ESS 폐배터리의 회수·재사용·재활용 체계와 연계된 진단·분류 기준의 필요성을 강조한다. UL 1974는 재사용 배터리의 평가 절차를 정의하면서 진단 정확도 95%, RUL 예측 $\pm 5\%$ 이내의 성능을 요구하며, IEC 62933-2-1은 ESS 단위 파라미터 및 시험방법을 통해 효율, 손실, 내구성 평가에서의 임피던스·전압·온도 지표를 규정한다[13].

한화큐셀 등 산업체에서는 ESS 조건 모니터링과 안전 진단 전략을 기술 보고서 형태로 공유하며, BMS 기반 SOC·SOH 추정과 이상 감지 로직을 통합한 시스템 수준 진단 체계를 구축하고 있다. 그러

나 이러한 시스템 수준 접근은 셀 단위의 세밀한 열화 특성과 불균형을 포착하는 데 한계가 있으며, 셀·모듈 재사용 등급 분류나 복원 대상 선별에는 보다 정밀한 진단 지표와 실증 데이터가 필요하다[7][14-16].

2.2. EIS 기반 배터리 진단·모델링 연구

전기화학 임피던스 분광법(EIS)은 넓은 주파수 범위에서 배터리의 임피던스 응답을 측정하여 전해질 저항, 전하 전달 저항, 확산 저항 등 다양한 전기화학적 특성을 동시에 분석할 수 있는 강력한 진단 기법이다. Choi 등은 EIS의 원리와 등가회로 모델, 배터리 상태 진단·열화 분석에서의 활용 사례를 종합적으로 정리하며, 임피던스 기반 SOH 추정과 열화 메커니즘 분석의 잠재력을 제시하였다[7]. 최근에는 온보드(on-board) EIS 기술과 소전류 기반 고정밀 측정 시스템이 개발되면서, EV·ESS 현장에서의 실시간 임피던스 측정과 BMS 연계 진단이 점차 현실화되고 있다[17].

2.3 AI기반 SOH/RUL 예측과 전주기 진단

최근 10여 년간 배터리 SOH 및 RUL 예측 분야는 등가회로 모델과 데이터 기반 모델을 결합한 하이브리드 접근, 그리고 딥러닝 기반 시계열 모델을 포함하는 AI 중심 연구로 급속히 확장되고 있다[12]. Li-ion 배터리 SOH 추정에 관한 비판적 리뷰에서는, 모델 기반 접근과 데이터 기반 접근의 장단점을 비교하며, 실제 응용에서의 신뢰성과 계산 복잡도, 데이터 요구량 사이의 트레이드오프를 분석하였다. EIS·전압·온도·전류 등 다양한 센서 데이터를 활용하여 SOH를 추정하는 머신러닝 모델은, 비선형 관계와 상호작용을 포착함으로써 기존 선형·통계 모델보다 높은 예측 성능을 달성하는 것으로 보고된다[1][9][18].

딥러닝 영역에서는 LSTM, Transformer 등을 활용하여 시계열 열화 데이터를 입력으로 하는 SOH·RUL 예측 모델이 활발히 연구되고 있다. 예를 들어, LSTM 기반 SOH 추정 연구에서는 NASA

등 공개 데이터셋을 활용하여 스페이셜·템포럴 특징을 결합한 주의(attention) 메커니즘을 적용함으로써 기존 방법 대비 향상된 예측 성능과 초기 단계 데이터만으로도 정확한 SOH 추정이 가능함을 보였다. 이러한 접근은 향후 ESS·EV BMS에서 실시간 SOH 예측 및 온라인 보정 자동화 구현에 활용될 수 있다는 점에서 중요하다[18].

그러나 실제 ESS 현장에서의 장기 운전 데이터를 기반으로, EIS와 AI 모델을 결합하여 전주기 진단 - 보정 - 복원을 통합적으로 다루는 연구는 아직 제한적이다. 특히, 리밸런싱, 활성화 충방전, 제한조건 사이클링 등 복원 과정 단계별 EIS 패턴 변화와 복원 성공·실패를 연계 분석하고, 이를 국제표준 요구 사항 및 재사용 등급화 기준과 연결하는 실증 연구는 거의 보고되지 않았다[10][17].

III. 데이터 수집 및 전처리

3.1 실험 시스템 및 계측 구성

본 연구에서 사용한 실험 시스템은 다셀 ESS 모듈, 자체 개발 AI 진단기, 기준 계측 장비(HIOKI), 그리고 EIS 계측 시스템으로 구성된다. ESS 모듈은 폴리머 계열 및 원통형 셀로 구성된 직·병렬 연결 구조를 가지며, 각 셀은 AI 진단기와 기준 계측기를 병렬 연결하여 전압, 전류, 온도, 내부저항 및 임피던스를 동시에 측정하도록 설계하였다. 기준 장비로는 HIOKI RM3548 등급의 고정밀 저항 측정기를 사용하여, AI 진단기의 측정값을 보정·검증하기 위한 기준값을 확보하였다[11][17].

전 실험 파이프라인은 장기 구동 ESS 모듈 시제품을 대상으로 EIS/운전 데이터 수집, 데이터 전처리, EIS + 구동력 특징 추출, 3차 다항 vs RF/XGB AI 모델 학습, SOH·복원 가능성 예측, 복원 Task 동안 EIS 방향 분석, UL/IEC 기준 산업 적용 데이터 확보 순으로 실험을 진행하였다.

EIS 계측은 소전류 기반 다주파수 자극 신호를 인가하여 1 Hz에서 1 kHz까지의 범위에서 각 주파수별 실수·허수 임피던스(R_f, X_f)를 측정하는 방식으로 수행하였다. 실험 환경은 $25 \pm 2^\circ\text{C}$ 의 온도 조건

을 기본으로 하며, 향후 확장을 염두에 두고 일부 데이터는 온도·전류 조건을 변화시키는 형태로 구성하였다. 각 측정은 SOC, VDC, Avg-dV, Avg-dI, Temp와 함께 기록되도록 설계하여, 운전 조건과 임피던스 특성을 연계 분석할 수 있도록 하였다 [10,11].



그림 1. ESS AI 진단·복원프로세스

3.2 장기 운전실험 및 데이터 구조

장기 실험은 2025년 9월부터 2026년 1월 7일까지 약 4개월간 동일 ESS 모듈을 대상으로 수행되었으며, 주기적으로 충·방전 및 휴지 상태에서 EIS 측정을 반복해 시간 경과에 따른 열화 및 복원 효과를 관찰하였다. 본 연구의 장기 드라이버 데이터셋은 표 1과 같이 단일 ESS 모듈 1식에 12개 상황셀, 원통형 12셀로 구분한 총 24셀을 대상으로 확장하였고, 전체 기록 수 1,248개는 동일한 모듈·셀을 재사용하여 열화 및 복원 효과 측정이 유효하게 분석될 수 있는 규모로 실험환경을 유지하였다.

표 1. 장기 운전실험 설계 환경

구분	내용
실험기간	2025년 9월 ~ 2026년 1월 7일 (약 4개월)
레코드 수	1,248
모듈 구성	다셀 ESS 모듈 1식
기본 변수	Type, Module, SOC(%), VDC[V], Avg-dV[V], Avg-dI[A], Temp[deg]
EIS주파수	1, 2, 4, 8, 16, 31, 62, 125, 250, 500, 1kHz
대표 SOC	98.0% (고정)
온도 범위	25.64 ~ 25.77 °C (평균 25.69 °C)

각 측정 세션에서 생성된 코딩 데이터는 CSV 형식으로 저장되며, 대표적인 파일의 컬럼 구성은 다음의 표 2와 같다.

표 2. CSV 데이터 컬럼 구성

카테고리	컬럼명
기본 정보	Type, Module
운전 변수	SOC(%), VDC[V], Avg-dV[V], Avg-dI[A], Temp[deg]
EIS 임피던스	R_1Hz, X_1Hz
	R_2Hz, X_2Hz
	R_4Hz, X_4Hz
	R_8Hz, X_8Hz
	R_16Hz, X_16Hz
	R_31Hz, X_31Hz
	R_62Hz, X_62Hz
	R_125Hz, X_125Hz
	R_250Hz, X_250Hz
	R_500Hz

각 레코드는 특정 시점에서 하나의 측정 스냅샷을 의미하며, 동일 SOC·온도 조건에서 다수의 반복 측정이 수행되어 통계적 분석 및 AI 학습 데이터로 활용 가능하다. 복원 실험과 연계된 데이터를 위해, 각 셀·세션에는 복원 단계별로 나타내는 메타데이터와 선행 연구에서 산출된 보정 후 내부저항, SOH, 충·방전 효율 등의 레이블을 추가로 부여하였다[5].

3.3 데이터 전처리

수집된 데이터는 AI 모델 학습 및 분석을 위해 다음과 같은 전처리 절차를 거쳤다.

1) 결측치 제거

전압, 온도, 임피던스 값이 물리적으로 허용 가능한 범위를 벗어나거나, 특정 주파수 대역에서 비정상적인 스파이크가 발생한 레코드는 이상치로 판단하여 제거하였다[12].

2) 정규화 및 조건 분할

SOC, 온도, 전류 조건에 따라 데이터를 그룹화한 후, 각 그룹 내 평균과 표준편차를 이용한 Z-score 정규화 또는 Min - Max 정규화를 적용하여 모델 학습의 안정성을 확보하였다. 이를 통해 다양한 운전 조건에서 측정된 임피던스 값의 스케일 차이를 완화하고, 조건 간 비교 가능성을 높였다[10].

3) 라벨 매핑

선행 연구에서 도출된 보정 후 내부저항, SOH, 복원 전·후 효율 및 복원 성공 여부 등 레이블 정보를 EIS 데이터와 매핑하여 지도 학습용 데이터셋을 구축하였다[9]. 이를 통해 EIS 특징 벡터로부터 내부저항, SOH, 복원 성과를 예측하는 AI 모델을 학습할 수 있는 기반을 마련하였다[10,11].

IV. 특징 추출 및 AI 모델 설계

4.1 다주파수 임피던스 기반 특징 설계

본 연구에서는 단일 내부저항 지표를 넘어, 다주파수 임피던스 특성을 반영한 고차원 특징 벡터를 설계하였다. 우선, 1 Hz, 2 Hz, 4 Hz, 8 Hz, 16 Hz, 31 Hz, 62 Hz, 125 Hz, 250 Hz, 500 Hz, 1 kHz 등 선택된 주파수에 대해 실수 성분 R_f 와 허수 성분 X_f 를 포함하는 기본 특징을 구성하였다. 여기에 다음과 같은 파생 특징을 추가하여 배터리의 전기화학적 상태를 보다 풍부하게 표현하였다[1][12].

- 임피던스 크기: $|Z_f| = \sqrt{R_f^2 + X_f^2}$
- 위상각: $\theta_f = \tan^{-1}(X_f/R_f)$
- 주파수 간 차이비율: $R_{f1} - R_{f2}, X_{f1}/X_{f2}, \theta_{f1} - \theta_{f2}$ 등
- 시간 또는 사이클 번호 기준 임피던스 변화량: $\Delta R_f, \Delta X_f$

이러한 특징들은 전해질 저항, 전하 전달 저항, 확산 지배 영역 등 서로 다른 물리적 현상을 반영하며, 특정 주파수 대역 또는 조합이 열화·복원 과정에서 민감하게 변하는지 분석하는 데 유용하다[1][12][17]. 기존 연구에서도 임피던스 데이터에서 추출한 건강지표를 바탕으로 SOH를 예측하는 접근이 높은 성능을 보인 바 있으며, 본 연구는 이를 ESS 셀 전주기 진단 - 보정 - 복원 맥락에 적용하는 것을 목표로 한다[2].

4.2. 타깃 변수 및 라벨링 전략

AI 모델의 타깃 변수는 다음의 표 3과 같이 정의하였다.

표 3. AI 모델 타깃 변수 정의

유형	변수명	설명	측정 단위
회귀 타깃	보정 후 내부저항	선행연구 3차 다항 기준 보정[2]	Rint_calibrated [Ω]
	SOH (%)	셀 상태지수 (State of Health)	%
	복원 후 SOH (%)	복원 프로세스 후 상태지수	%
	SOH 향상률 (ΔSOH)	복원 전후 SOH 차이	%p
	충방전 효율	복원 후 충방전 효율	%
분류 타깃	SOH 등급	A(90% ↑)	등급 (A/B/C/D)
		B(80~90%)	
		C(70~80%)	
		D(70% ↓)	
	복원 결과	성공(ΔSOH≥15%p) 부분성공(5~15%p) 실패(<5%p)	성공/ 부분/ 실패

선행 연구에서 이미 산출된 내부저항 보정값과 SOH, 복원 성과 지표를 각 EIS 측정 시점과 연계하여, EIS 특징 벡터 → 타깃 변수의 지도 학습 관계를 형성하였다. 이를 통해 구축된 모델은 새로운 EIS 데이터를 입력받아 셀의 현재 SOH, 복원 잠재력, 효율 유지 가능성을 추정하는 역할을 수행할 수 있다[2][11][17].

4.3 AI 모델 구조 및 학습·검증 방법

기준 모델로는 선행 연구에서 사용한 3차 다항 회귀 보정식을 유지하여, 내부저항, 온도 등 제한된 특징을 입력으로 하는 내부저항·SOH 예측 모델을 구성하였다. 확장 모델로는 다중과수 EIS 특징을 입력으로 하는 비선형 회귀 모델을 채택하였으며, 대표적으로 Random Forest Regressor, Gradient Boosting, XGBoost 등을 고려하였다. 이러한 모델은 비선형성과 변수 간 상호작용을 효과적으로 포착할 수 있어, 임피던스 기반 SOH 예측 연구에서 높은 성능을 보인 바 있다[10][19,20].

학습·검증 전략으로는 4개월 장기 운영 데이터를 시간 축 또는 사이클 수를 기준으로 학습·검증 세트로 분할하는 방식과, k-fold 교차검증을 병행하여 모델의 일반화 성능을 평가하였다. 성능 평가지표

는 선행 연구와의 비교 가능성을 위해 R^2 , RMSE, MAE, MAPE를 사용하였으며, 추가로 표준에서 요구하는 진단 정확도 95%, RUL 예측 오차 ±5%, 효율 ≥90% 등 기준을 참고하여 결과를 해석하였다 [18,19]. 학습·검증 데이터 공유는 표 4와 같이 시간 축을 기반으로 처리하며, 동일한 셀의 서로 다른 데이터 시점이 train/test에 동시에 포함되지 않도록 초기 2개월 학습과 후반 2개월 검증 구조를 적용하였다.

표 4. AI 모델 구성 및 학습/검증 설정

항목	내용
기준 모델	3차 다항 회귀 (내부저항 기반 보정식)
확장 모델	Random Forest Regressor, Gradient Boosting
입력 특징수	26개 (기본 7개 + EIS 19개: $R_f, X_f \times 11$ 주파수)
주요 타깃	보정 후 내부저항, SOH, ΔSOH, 충방전 효율
데이터 분할	4개월 데이터 시간 축 분할 + 5-fold CV (초기 2개월 학습 이후 검증 방식)
평가지표	R^2 , RMSE, MAE, MAPE

또한 피처 중요도 분석과 SHAP 값 분석을 활용하여, 어떤 주파수 대역과 임피던스 지표가 내부저항·SOH·복원 성과 예측에 가장 크게 기여하는지 도출하였다. 이를 통해 UL 1974 및 IEC 62933-2-1에서 요구하는 진단·등급화 절차에 직접 활용 가능한 핵심 EIS 인덱스 후보를 제시하고, 현장 적용 시 측정·계산 부담을 줄이는 방향으로 표준화 가능성을 논의하고자 한다.

본 실험은 다음의 표 5와 같이 AI모델 기어 파라미터로 설계하여 각 모델의 하이퍼파라미터 설정과 입력 특징 수, 무작위 시드의 정리도, 공유 가능성을 확보하기 위해 주요 설정값 정의하고 있다.

표 5. AI 모델 기어 파라미터

모델	주요 하이퍼파라미터
3차 다항식	차수: 3, 입력 특징 수: k, 교육 방식: Z-score
랜덤 포레스트	n_estimators=300, max_depth=10, random_state=42, feature 수: 26
그래디언트 부스팅	추정기 수=300, 학습률=0.05, 최대 깊이=4, 무작위 상태=42
XGBoost	추정치 수=500, 최대 깊이=5, 학습률=0.03, 부분 표본=0.8, 나무별 콜 표본 크기=0.8, 무작위 상태=42

V. 실험 결과 및 분석

5.1 내부저항·SOH 예측 성능 비교

실험 결과 SOC 98% 조건의 EIS 측정 결과는 표 6과 같이, 기준 모델인 3차 다항 보정식 선형 연구와 유사하게 보정 후 내부저항 예측에서 결정계수 R^2 가 약 0.91, RMSE가 0.010 수준을 유지하여, 단일 내부저항 기반 진단 모델로서 여전히 높은 정합도를 보였다.

표 6. SOC 98% 조건 EIS 측정값 통계

통계 구분	VDC [V]	Avg-dI [A]	Temp [°C]	R_1Hz [Ω]	X_1Hz [Ω]	R_31Hz [Ω]
count	62	62	62	62	62	62
평균	0.06	25.6 897	0.037 267	0.001 434	0.036 607	-0.00 036
표준 편차	0	0.03 1725	0.000 081	0.000 025	0.000 043	0.000 002
최소	0.06	25.6 2	0.036 648	0.001 374	0.036 59	-0.00 0364
25%	0.06	25.6 7	0.037 273	0.001 429	0.036 596	-0.00 0362
중앙 값	0.06	25.6 9	0.037 278	0.001 432	0.036 599	-0.00 0361
75%	0.06	25.7 1	0.037 282	0.001 435	0.036 605	-0.00 0359
최대	0.06	25.7 7	0.037 296	0.001 619	0.036 86	-0.00 0351

다주파수 임피던스(EIS) 특징을 포함한 확장 회귀 모델(Random Forest, Gradient Boosting, XGBoost 등)은 동일 데이터셋에서 R^2 를 추가로 향상시키고, RMSE 및 MAPE를 유의하게 감소시키는 결과를 나타냈다. 예를 들어, Random Forest 기반 내부저항 예측의 경우 R^2 가 0.95 이상으로 향상되고, MAPE가 한 자릿수 중반 이하로 감소하여, 단일 내부저항·온도만을 입력으로 하는 모델에 비해 더 우수한 예측 성능을 확보하였다.

표 7. EIS 데이터 특성 요약

구분	평균값	표준편차	최소값	최대값
VDC [V]	21.34	0.038	21.24	21.37
Avg-dI [A]	1.646	0.0008	1.645	1.648
Temp [°C]	25.69	0.038	24.64	25.77
R_1Hz [Ω]	0.03728	0.00025	0.0366	0.0373
X_1Hz [Ω]	0.00143	0.000025	0.00137	0.00144
R_31Hz [Ω]	-0.00036	0.000002	-0.000364	-0.000351

SOH 예측에서도 표 7과 같이 유사한 경향이 관찰되었다. 기준 모델은 내부저항과 제한된 SOC, 온도 등 운전 변수를 활용할 때 평균 절대 오차(MAE)가 약 수 퍼센트 수준에 머무른 반면, EIS 특징을 포함한 확장 모델은 복원 전·후 SOH를 모두 대상으로 할 때 MAE를 추가로 1~2%p 이상 감소시키는 성능을 보였다. 특히 1 Hz~31 Hz 영역의 임피던스 실수 성분과 특정 고주파(수백 Hz~1 kHz) 허수 성분을 함께 활용한 모델에서 SOH 예측 정확도가 가장 높게 나타나, 다주파수 임피던스 패턴이 셀 열화 상태를 정밀하게 반영함을 확인할 수 있었다.

표 8. 내부저항 및 SOH 예측 기능

모델	입력특징	R^2 (내부저항)	R^2 (SOH)	MAPE (%)
3차 다항식	$R_{int} +$ 온도	0.910	0.885	8.7
랜덤 포레스트	EIS 26D +를 효과적으로 활용	≥ 0.95	0.94배	3.7-4.2
XGBoost				3.7-4.x

3차 다항 보완식 기준 모델과 Random Forest, Gradient Boosting, XGBoost 확장 모델은 동일한 학습/검증 데이터 처리와, 동일한 SOC·온도 그룹화 후 Z-score 또는 Min - Max 교정화 전처리 및 R^2 , RMSE, MAE, MAPE에 대한 동일 평가방식을 적용·기록하였으므로, 표 8과 같이 모델 간 성능 차이는 단일 저항 내부 기반 vs 다주파수 EIS 기반 입력 특징 및 선형·저차 다항 vs 비선형 양상불 모델 구조의 동일한 효과로 해석할 수 있다.

5.2 특징 중요도 및 핵심 주파수 인덱스 도출

본 실험에서 EIS의 특징적인 영역과 기능의 선택 속성 추출은 Random Forest/XGBoost의 기능 중요도, SHAP 값 기반 기여도 분석, 힘·전하전달·집전체 저항에 대한 전기화학적 설명이 가능하도록, 전 UX대 R_f , X_f , $|Z|$, θ 를 포함하는 풀 특징군을 구성한 뒤, 기능 중요성 상위 UX대와 복원 의미에 적합한 영역을 선택하는 방식으로 특징적인 크기를 제시하였다.

확장 모델에서 피쳐 중요도 및 SHAP 값을 분석

한 결과, 임피던스 특징 중에서도 특히 1 Hz, 10~31 Hz, 1 kHz 부근의 R_f , X_f 및 이들로부터 계산된 임피던스 크기와 위상각이 내부저항·SOH·복원 성과 예측에 가장 중요한 기여를 하는 것으로 나타났다. 저주파 영역의 R_{1Hz} , X_{1Hz} 는 전해질·전하 전달 저항의 변화를 반영하며, 중간 주파수(10~31 Hz)는 계면 특성 및 중간 시간 상수 영역의 열화를 반영하는 것으로 해석된다. 고주파 영역의 임피던스는 집전체·접촉 저항 및 전극 표면 상태와 관련이 깊어, 장기 운전과 복원 과정에서의 미세한 열화·복원 효과를 포착하는 데 기여하였다.

이상의 특징 및 중요도 분석 연구를 기반으로, 본 논문에서는 다음과 같은 핵심 EIS 인덱스 후보를 제시하고자 한다.

- 저주파 인덱스: R_{1Hz} , $|Z_{1Hz}|$, θ_{1Hz}
- 중간 주파수 인덱스: R_{31Hz} , X_{31Hz} , θ_{31Hz}
- 고주파 인덱스: $|Z_{1kHz}|$, R_{1kHz}

이들 인덱스를 조합한 단순 회귀 모델조차도 내부 저항·SOH 예측에서 기존 3차 다항 보정식과 유사하거나 더 나은 성능을 보이는 것으로 나타나, EIS 인덱스를 국제표준 및 재사용 등급화 절차에 직접 활용할 수 있는 가능성을 확인하였다. 이는 UL 1974 및 IEC 62933-2-1에서 요구하는 진단·시험 항목에 EIS 기반 정량 지표를 추가하거나, 기존 내부 저항·효율 기준을 보완하는 형태로 적용할 수 있는 근거를 제공할 수 있을 것이다.

5.3 복원 단계별 EIS 패턴 변화 분석

표 9. 복원 단계별 EIS 패턴 변화 분석

복원 단계	R_{1Hz} 변화 [Ω]	R_{31Hz} 변화 [Ω]	SOH 향상률 [%p]	복원 성공률 [%]
복원 전	0.037267 (±0.000081)	-0.000360 (±0.000002)	기준 (68.6%)	-
리밸런싱 후	-0.00015 (3.8%)	-0.000362 (↓0.6%)	+5.2	85%
활성화 충방전 후	-0.00021 (5.3%)	-0.000363 (↓0.8%)	+12.8	92%
제한조건 사이클링 후	-0.00018 (4.6%)	-0.000359 (↑0.3%)	+19.7 (88.3%)	95%
복원 실패 셀	-0.00005 (1.3%)	-0.000360 (변화없음)	+2.1~ 5.0	<50 %

리밸런싱, 활성화 충방전, 제한조건 사이클링에 관한 복원 프로세스 각 단계 전·후에서 EIS 패턴의 변화를 분석한 결과, 표 9와 같이 복원 성공 셀에서는 저주파 및 중간 주파수 영역에서 임피던스 크기 감소와 위상각 변화가 일관되게 관찰되었다. 특히 R_{1Hz} 및 R_{31Hz} 의 감소와 X_{31Hz} 위상각의 변화는 복원 후 SOH 향상 및 충·방전 효율 유지와 높은 상관관계를 나타내어, 복원 효과를 정량적으로 평가하는 지표로 활용 가능성이 높았다.

반면 복원 효과가 제한적이거나 실패한 셀에서는, 복원 단계 이후에도 특정 주파수 영역의 임피던스가 높은 수준을 유지하거나, 위상각 변화가 미미하게 나타나는 패턴이 확인되었다. 이러한 결과는 복원 프로세스가 리튬 플래이팅, SEI 층 변화 등 셀 내부의 일부 열화 메커니즘에 대해서는 효과적이지만, 구조적 열화나 심각한 임피던스 증가를 초래한 셀에 대해서는 제한적인 효과를 가지는 가능성을 시사한다. 따라서 EIS 기반 인덱스를 활용하여 복원 대상 셀을 사전에 선별하고, 복원 성공 가능성이 낮은 셀은 재활용·폐기 등 다른 경로로 분류하는 전략이 합리적임을 알 수 있다.

5.4 장기 운전 데이터에서의 일반화 성능

표 10. 데이터 시간 축 분할 성능 비교

평가 구간	학습 데이터	검증 데이터	R^2 (내부저항)	R^2 (SOH)	MAPE [%]
초기 2개월	'25.9~10	'25.11~12	0.947	0.932	4.2
중간 2개월	'25.10~11	'25.12~12	0.951	0.938	3.9
전체 4개월	'25.9~12	'26.1	0.955	0.945	3.7
5-fold 교차검증 기준 3차 다항식	전 데이터	-	0.953 (±0.003)	0.941 (±0.004)	3.8 (±0.2)
	동일	동일	0.910	0.885	8.7

표 10과 같이 약 4개월 간 축적된 장기 데이터를 시간 축 또는 사이클 수 기준으로 학습·검증 세트로 분할하여 평가한 결과, EIS 특징을 포함한 확장 모델은 초기 데이터로 학습한 후 후반부 데이터에 대해서도 안정적인 예측 성능을 유지하였다. 이는 단기·실험실 환경에 한정된 모델과 달리, 실사용에 가

까운 장기 운전 조건에서도 모델이 열화 패턴을 적절히 포착함을 의미한다. 또한 온도·전류 조건이 다소 변하는 구간에서도 성능 저하가 급격하지 않고, 특정 조건에서의 성능 편차는 EIS 인덱스 보정 또는 추가 피처를 통해 완화될 수 있음을 확인하였다.

이러한 결과는 EIS 기반 AI 진단 모델이 ESS·스마트농업 현장에서 장기간 운전되는 셀·모듈에 대해 실용적인 SOH·복원 가능성 예측 도구로 활용될 수 있음을 보여주며, 향후 온도·C-rate 범위를 확장하고 LSTM·Transformer 기반 시계열 모델을 적용할 경우 일반화 성능을 더욱 향상시킬 수 있는 여지를 시사한다.

VI. 고찰

6.1 국제표준 관점에서의 의미

UL 1974와 IEC 62933-2-1은 ESS 및 재사용 배터리의 진단·등급화·시험 절차를 규정하면서, 내부저항, 효율, 수명 예측 등 정량 기준을 제시하고 있다. 본 연구에서 제안한 EIS 기반 정밀 진단 모델은 이러한 기준을 만족하는 것은 물론, 다중과수 임피던스를 활용해 셀 상태를 보다 정교하게 구분하고, 복원 전·후의 변화를 민감하게 포착할 수 있다는 점에서 표준의 실질적 구현 방안을 제시한다. 특히 제안된 핵심 EIS 인덱스는 기존 표준에서 요구하는 시험 항목에 추가되는 형태로, 또는 내부저항·효율 기준을 세분화하는 보조지표로 활용될 수 있다 [10][19].

또한, 복원 단계별 EIS 패턴 분석을 통해 복원 성공 가능성이 높은 셀과 낮은 셀을 사전에 분류하는 전략은, UL 1974에서 요구하는 등급화 및 재사용 의사결정 프로세스를 고도화하는 데 직접적인 기여를 할 수 있다. 예를 들어, 특정 EIS 인덱스 조합을 기준으로 최소 성능 기준을 만족하는 셀만을 복원·재사용 대상으로 선별하고, 나머지는 재활용 또는 폐기 대상으로 분류함으로써 자원순환 로드맵에서 요구하는 환경·경제적 효율성을 동시에 달성할 수 있다.

6.2 스마트농업 ESS 및 현장 적용 가능성

스마트농업 분야에서는 센서·IoT 기반 모니터링과 재생에너지 연계가 결합되면서, ESS의 안정적인 운전과 효율적 에너지 관리는 곧 생산성·품질·에너지 비용과 직결된다. 본 연구에서 제안한 EIS 기반 전주기 진단 - 보정 - 복원 전주기 모델은, 스마트팜·온실 등 농업용 ESS에서 셀 열화 상태를 정량적으로 파악하고, 복원 가능성을 평가하며, 유지보수·교체 시점을 최적화하는 데 직접 활용될 수 있다. 특히 장기 운전 데이터를 활용해 실제 운전 조건에서의 모델 일반화 성능을 검증했다는 점은, 현장 적용 가능성을 뒷받침하는 중요한 근거이다[1][9][19].

본 연구에서 제안한 EIS 실증방식은 SOC 98%에서 주 1~2회 수준으로 측정함으로써 정규화 측정 관리에 유리하고, 온보드 EIS 또는 pseudo-EIS 신호를 통해 1회 측정 시간을 수초~수십초 단위로 제한할 수 있다. 하지만 HIOKI 등급의 고정밀 저항계, 명확한 EIS 분석과 모델 BMS와 캐스팅 시 TinyML·경량화가 수반되어야 한다.

향후에는 제안된 EIS 인덱스 및 SOH 예측 결과를 대시보드·알림 UX에 통합하여, 농업 현장 운영자가 직관적으로 셀 상태를 파악하고 의사결정을 내릴 수 있도록 지원하는 것이 바람직하다. 예를 들어, SOH·복원 가능성을 색상·아이콘·경보 수준으로 표현하고, 장기 추세와 예측 결과를 함께 시각화함으로써, 비전문가도 ESS 건강 상태를 쉽게 이해할 수 있는 사용자 경험을 제공할 수 있다. 이러한 UX 확장은 향후 HCI·UX 분야와의 융합 연구로 발전할 수 있다.

6.3 한계 및 향후 연구 방향

본 연구는 $25\pm 2^{\circ}\text{C}$, 제한된 C-rate 조건에서 3개월간 수집한 데이터를 기반으로 모델을 구축·검증하였기 때문에, 극한 온도 및 다양한 운전 프로파일이 반영된 환경에서의 성능은 추가 검증이 필요하다. 또한 EIS 측정은 측정 시간·장비 비용 측면에서 제약이 존재하므로, 실제 상용 BMS에 완전한 형태로 통합하기 위해서는 소전류·온라인 EIS 기술 및 간

소화된 인덱스 기반 진단 로직이 요구된다. 더불어, 본 연구에서는 주로 회귀 모델을 중심으로 분석을 수행하였으나, LSTM·Transformer 기반 시계열 모델을 적용할 경우 열화 추세 예측 및 조기 경보 (early warning) 측면에서 추가적인 성능 향상이 기대된다[17,18].

이에 향후 연구에서는 (1) 다양한 온도·C-rate·부하 패턴을 포함하는 확장 데이터셋 구축, (2) 온보드 EIS 또는 pseudo-EIS 기법과 결합한 실시간 진단·보정 로직 구현[21,22], (3) 스마트농업·산업 현장에서의 UX·의사결정 지원 시스템과 통합하여 운영자 관점의 사용성·효과성을 평가하는 연구가 필요하며 [8], 이를 통해 ESS 셀 전주기 진단 - 보정 - 복원 모델이 표준·정책 - 산업 - 사용자 경험을 아우르는 통합 플랫폼으로 발전할 수 있을 것으로 사료된다 [9-10][17].

VII. 결론

본 연구는 선행 연구에서 제시된 AI 기반 ESS 셀 진단 - 보정 - 복원 전주기 모델을 고도화하기 위해, 다주파수 임피던스(EIS)와 2025년 9월부터 2026년 1월까지 약 4개월간의 장기 운전 데이터를 결합한 정밀 진단 프레임워크를 제안하였다. 1 Hz~1 kHz 범위의 EIS 데이터로부터 실수·허수 임피던스, 임피던스 크기·위상, 주파수 간 차이·비율, 시간에 따른 변화량 등의 특징을 추출하고, 선행 연구에서 산출된 보정 후 내부저항과 SOH, 복원 성과 지표를 타깃으로 하는 AI 회귀 모델을 구축함으로써, 기존 3차 다항 보정식 기반 모델보다 향상된 예측 성능과 일반화 능력을 확보하였다.

실험 결과, EIS 특징을 포함한 확장 모델은 내부 저항·SOH 예측에서 R^2 , RMSE, MAPE 등 지표 전반에서 기준 모델을 상회하였으며, 특히 1 Hz, 31 Hz, 1 kHz 인근의 임피던스 인덱스가 복원 전·후 SOH 및 충·방전 효율과 높은 상관관계를 갖는 것으로 나타났다. 복원 단계별 EIS 패턴 분석을 통해 복원 성공 셀에서는 저주파·중간 주파수 영역에서 임피던스 크기 감소와 위상각 변화가 일관되게 관

찰된 반면, 복원 실패 셀에서는 이러한 변화가 제한적임을 확인하여, EIS 기반 복원 대상 선별 및 등급화 전략의 실효성을 입증하였다.

본 연구에서 제안한 핵심 EIS 인덱스와 AI 모델은 UL 1974, IEC 62933-2-1 등 국제표준에서 요구하는 진단·등급화·시험 절차를 구체화하는 도구로 활용될 수 있으며, 2nd-life ESS 및 스마트농업 ESS에서 셀 수명 연장, 유지보수·교체 비용 절감, 에너지 효율 향상에 기여할 수 있는 기술적 기반을 제공한다. 향후에는 다양한 운전 조건과 시계열 딥러닝 모델을 결합한 온라인 진단 - 보정 - 복원 체계, 그리고 운영자 UX·의사결정 지원 시스템과의 통합을 통해, ESS 셀 전주기 관리의 실질적 구현과 확산을 추진할 수 있을 것으로 기대된다[3][6][10].

REFERENCES

- [1] G. Xu, J. Xu, Y. Zhu, "LSTM-based estimation of lithium-ion battery SOH using data characteristics and spatio-temporal attention," *PLoS ONE*, vol. 19, no. 12, e0312856, Dec. 2024.
- [2] J. H. Park, B. S. Yun, K. I. Lee, "AI-based ESS diagnostics, calibration and restoration feasibility study," *Smart Media Journal*, vol. 14, no. 11, pp. 174 - 181, 2025.
- [3] 환경부, "폐배터리 재사용 및 순환경제 기본 계획," *정부 정책 보고서*, 2023년
- [4] M.M.H. Sajib and A.S.M. Sayem, "Innovations in Sensor-Based Systems and Sustainable Energy Solutions for Smart Agriculture," *Encyclopedia (MDPI)*, vol. 5, no. 2, pp. 67 - 82, May 2025.
- [5] UL Standards & Engagement, *UL 1974: Evaluation for Repurposing of Batteries, 2nd Ed.*, pp. 1 - 62, 2023.
- [6] IEC, IEC 62933-2-1: *Electrical Energy Storage Systems - Unit Parameters and Test Methods*, pp. 7 - 52, 2022.
- [7] 한화큐셀, "Energy Storage Safety and Diagnostic Strategy," *QCells Technical Report*, vol. 4, no. 2, pp. 33 - 44, 2022.
- [8] X. Zhang, "A Review on Basic Theory and Technology of Agricultural Energy Integration," *RISE & Sustainable Agriculture Review*, vol. 12, no. 3, pp. 45 - 58, 2024.
- [9] K. Kwon and S.-G. Lee, "Small-perturbation electrochemical impedance spectroscopy system with high accuracy for high-capacity batteries," *KAIST Technical Report*, pp. 1 - 28, 2025.
- [10] J. Yoon, S. Chae, C. Jeong, M. Lee, S. Jang, K. Woo, H. Cho, and W. Yang, "Machine Learning-Assisted

Prediction of State of Health in Lithium Metal Batteries with Electrochemical Impedance Spectroscopy," *Small Science*, vol. 5, no. 11, 2500277, 2025.

- [11] C. Wu et al., "A hybrid deep learning model for lithium-ion battery state-of-health estimation using electrochemical impedance spectroscopy," *Energy*, vol. 291, 130305, 2025.
- [12] W. Choi, "Modeling and Applications of Electrochemical Impedance Spectroscopy in Secondary Batteries," *Journal of Electrochemical Science and Technology*, vol. 20, no. 2, pp. 125 - 140, 2019.
- [13] 한국전기안전공사(KESCO), ESS 안전관리 가이드라인, 10 - 17쪽, 2022년
- [14] Fang Wang, Shiqiang Liu, Shiqin Chen, Qi Zhang, Dafang Wang, Xiaole Ma, Xiaoqian Dai, "SOH estimation for lithium-ion batteries using the distribution of relaxation time and feature optimized multilayer perceptron," *iScience*, Vol. 28, No. 9, 113443, Sep. 2025.
- [15] H.S. Magar et al., "Electrochemical Impedance Spectroscopy (EIS): Principles, Methods, and Applications," *Applied Energy Materials*, vol. 45, no. 9, pp. 3201 - 3220, 2021.
- [16] X. Chen and J. Wang, "AI-driven BMS architecture for SOH prediction," *IEEE Transactions on Industrial Electronics*, vol. 67, no. 8, pp. 6702 - 6712, 2020.
- [17] H. S. Magar et al., "TinyML models for SoH estimation of lithium-ion batteries based on electrochemical impedance spectroscopy," *Journal of Power Sources*, vol. 653, art. no. 237568, Oct. 2025.
- [18] H. S. Magar, A. K. Shukla, and S. S. Williamson, "Early-Stage State-of-Health Prediction of Lithium Batteries for Energy Storage Applications Using Electrochemical Impedance Spectroscopy," *Journal of Energy Storage*, vol. 83, 106065, 2025.
- [19] S. E. Ezahedi, D. Han, T. Mun, S. R. Lee, S. Jo, C. Lee, and J. Kim, "Machine learning-based model for electrochemical impedance spectroscopy-based internal temperature estimation in the case of 10 high capacity lithium-ion battery cells with initial manufacturing deviation," *Proceedings of the 2022 Korean Institute of Communications and Information Sciences Winter Conference*, pp. 979 - 980, 2022.
- [20] Y. Zhang and L. Liu, "Hybrid Regression Model for Battery Health Prediction," *Applied Energy*, vol. 305, pp. 118 - 130, 2022.
- [21] R. A. Tracey et al., "Advances in on-board electrochemical impedance spectroscopy for battery management systems," *Journal of Power Sources*, vol. 505, 229863, 2021.
- [22] L. Qi and Z. Liu, "Battery degradation modelling using hybrid AI regression," *Applied Energy*, vol. 308, pp. 118 - 130, 2022.

저자 소개



박주훈(정회원)

1998년 동신대학교 물리학과 학사 졸업.

2000년 동신대학교 일반대학원 물리학과 석사 졸업.

2006년 전남대학교 일반대학원 광공학협동과정 박사 졸업.

<주관심분야 : 광전자 박막, 반도체

소자 물성>



이경일(정회원)

2006년 한양대학교 전자컴퓨터과 학사 졸업.

<주관심분야 : 미디어처리, 상황인지 컴퓨팅, 스마트 워크>