

# AI 기반 ESS 진단 보정 및 복원 실증 연구

## (AI-Based Calibration and Restoration Study for ESS Diagnostics)

박주훈\*, 윤봉식\*\*, 이경일\*\*\*

(Ju-Hoon Park, Bong Shik Yun, Kyung-Il Lee)

### 요약

본 논문은 에너지저장장치(ESS) 셀의 열화 진단 정밀도 향상과 복원 가능성 검증을 위해 인공지능 기반 3차 다항 보정모델을 구축하고, 리튬전지·활성화·충방전·제한조건 사이클링을 포함한 복원 절차를 실증하였다. 특히 본 논문은 스마트농업 현장에 도입된 ESS 및 재생에너지 기반 농업설비에 응용 가능하도록 설계되었으며, 농업용 센서·IoT 기반 제어시스템에서 요구되는 배터리 효율성과 관리손실 감소를 목표로 한다.

실험은 히오키 기준 측정기와 자체 개발한 진단기를 병렬로 연결하여 전압, 전류, 온도, 내부저항 데이터를 1초 간격으로 수집하였으며, 13mΩ의 오프셋을 반영한 보정식을 적용해 측정 오차를 최소화하였다. AI 다항 보정모델은 다양한 폴리머형과 원통형 셀에서 평균  $\pm 10\%$  이내의 저항 추정 오차를 보였으며, 결정계수는 0.91, RMSE는 0.0107로 나타났다. 복원 실험 결과 셀의 상태지수는 평균 68.6%에서 88.3%로 약 19.7%포인트 향상되었고, 충방전 효율은 90% 이상을 유지하였다.

이 결과는 UL 1974 제2판과 IEC 62933-2-1이 제시한 진단정확도 95% 및 RUL 예측  $\pm 5\%$  성능 기준을 충족하였다.

본 논문은 셀 단위 진단-보정-복원 전주기 모델을 제시함으로써 기존 BMS 기반의 시스템 진단 한계를 극복하고, 스마트농업 및 ESS 재사용 영역에서 비용 절감과 안전성 향상에 기여할 수 있는 데이터 중심의 표준화 모델을 제안하였다.

■ 중심어 : 에너지저장장치 ; 보정알고리즘 ; 셀진단 ; 배터리복원 ; 스마트농업 ; 예측 진단

### Abstract

This study develops and verifies a cubic polynomial calibration model based on artificial intelligence to improve diagnostic accuracy and restoration capability for ESS cells. The design specifically targets integration in smart agriculture systems, where battery efficiency and management loss reduction play critical roles.

Parallel measurements using a HIOKI reference and an in-house diagnostic device recorded voltage, current, temperature, and internal resistance every second, applying a 13 mΩ offset correction to reduce error. The AI model achieved an average resistance estimation error within  $\pm 10$  percent, with  $R^2$  of 0.91 and RMSE of 0.0107, across both polymer and cylindrical cells. Restoration improved the state of health from 68.6 to 88.3 percent and maintained charge-discharge efficiency above 90 percent, meeting UL 1974 and IEC 62933-2-1 standards for diagnostic accuracy and RUL prediction.

By integrating cell-level diagnosis, calibration, and restoration into a unified workflow, this study overcomes the limitations of conventional BMS-based diagnostics and establishes a data-driven standardization framework that reduces second-life ESS reuse costs and enhances safety and energy efficiency in smart agriculture and energy storage applications.

■ keywords : Energy Storage System ; Calibration Algorithm ; Battery Restoration ; Smart Agriculture ; RUL Prediction

## 1. 서론

### 1.1 연구 배경

ESS(Energy Storage System)는 전력망 안정화와 재생에너지 연계의 핵심 인프라로 주목받고 있으나, 2017~2024년 국내에서 55건 이상 화재가 보고되면서 안전성 문제가 심각하게 부각되었다[1].

\* 정회원, 남부대학교 전기공학과

\*\* 정회원, 남부대학교 자동차기계공학과

\*\*\* 정회원, (주)브레이크더룰스 책임연구원

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

접수일자 : 2025년 10월 24일

수정일자 : 2025년 11월 14일

게재확정일 : 2025년 11월 24일

교신저자 : 윤봉식 e-mail : jscorn@nambu.ac.kr

정부의 합동조사 결과, 다수의 사고가 셀 내부 열화와 불균일 저항으로 인한 국부 발열에서 기인함이 확인되었다[2].

이러한 사고 원인 중 상당수는 시스템 수준의 모니터링만 수행하고 셀 단위 진단·보정 기능이 미비했던 기존 BMS의 한계에서 비롯되었다. 또한, 국내 ESS 산업이 빠르게 확대되면서 폐배터리의 누적량이 2023년 기준 약 10만 톤에 달하며, 재사용(2nd-life) 기술은 필수적 대안으로 부상했다[3].

국제 표준인 UL 1974(2nd Ed.)와 IEC 62933-2-1은 셀 등급 분류 및 시험 방법을 규정하며, 셀 단위 진단기술 표준화의 필요성을 강조하고 있으나[4,5], 국내 연구들은 BMS 레벨에서의 SOC·SOH 기반 통계 진단에 머무르고 있어 AI 기반 셀 단위 보정 및 복원 실증 연구는 매우 부족한 현실이다[6].

스마트농업(Smart Agriculture) 분야에서도 재생 에너지 기반의 온실 및 스마트팜 운영에 ESS가 핵심 인프라로 활용되고 있다. 농업용 ESS는 태양광·풍력·수열 등 분산형 에너지원으로부터 생산된 전력을 저장하여, 센서 네트워크·관개 시스템·환경 제어 장비 등에서 안정적 전력 공급과 에너지 손실 최소화를 가능하게 한다[7].

특히, 배터리의 열화나 비균질 충방전은 농업용 IoT 설비의 효율 저하와 관리 손실을 초래하므로, 셀 단위의 정밀 진단 및 보정 기술은 농업 생산 효율성과 지속가능성 제고에도 직접적인 영향을 미친다[8].

이에 따라 본 논문은 ESS의 진단 및 복원 기술을 농업 에너지 시스템에도 적용할 수 있는 기반 기술로 확장함으로써, 스마트농업용 배터리의 수명 연장 및 에너지 관리 효율 향상을 도모하고자 한다.

## 1.2 연구 목적

본 논문의 목적은 다음의 네가지로 요약된다.

(1) 인공지능 기반 3차 다항 보정 알고리즘을 통해 진단기의 측정 저항값을 지그(히오키) 기준값으로 자동 보정하고 정확도를 향상시키는 것.

(2) 보정 후 데이터를 활용해 리밸런싱·활성화 충

방전 과정을 설계하고 복원 매커니즘 실증을 수행하는 것.

(3) 복원 전후의 SOH(Health) 및 충방전 효율 변화를 분석하여 AI 진단기의 실효성을 검증하는 것.

(4) 나아가 ESS 재사용 및 순환경제 체계 구축을 위한 표준화 방안을 제시하는 것이다.

## II. 관련연구

### 2.1. 셀 단위 진단 및 표준화·정책 동향

글로벌 ESS 산업의 고도화는 배터리 재사용(2nd-life) 기술의 핵심을 정밀 진단·보정 알고리즘에 두고 있다. 이와 관련해 Tesla, CATL, BYD 등은 BMS(Battery Management System)에 SOH/SOC 기반 모니터링 로직을 통합하여 수명 데이터베이스와 연계된 상태진단 체계를 구축하였다[9,10]. Tesla의 2022년형 BMS 아키텍처는 셀 임피던스 변동을 실시간 추적해 AI 회귀모델에 반영함으로써  $\pm 5\%$  이내의 RUL 추정 정확도를 달성하였다[11]. CATL은 AI 하이브리드 모델을 통해 온도-전류-저항 융합 특성을 학습하는 열화 진단 플랫폼을 구현하고, 생산 라인에 실시간 품질 예측을 적용하고 있다[11].

UL 1974(2nd Ed., 2023)는 EV 배터리를 ESS로 전환할 때의 분류·등급화·검사 절차를 명문화하였다[4]. 특히 셀 레벨 시험에서 내부저항(Rint)과 충방전 효율 기준을 병기하여 열화 진단 정확도를 인증 평가항목으로 포함시키고, IEC 62933-2-1(2022)은 ESS의 단위 파라미터·시험방법을 제시하며, 온도·전류 스트레스 하에서의 임피던스 기반 내구성 지표 산정법을 표준화하였다[5]. 유럽의 Moment Energy는 UL 인증을 획득해 EV 배터리 모듈을 재사용 ESS로 상용화하였으며, Redwood Materials는 EV 제조사와 협력해 폐배터리 리퍼포징-리사이클 통합 플랫폼을 구축하였다[9].

이들 사례는 ‘보정-진단-등급화-복원’을 하나의 순환 체계로 통합한 실증 모델로, 본 논문의 히오키 기준 보정-복원 매커니즘 실험 프레임 설계에도

직접 반영되었다.

한편, 한국은 LS일렉트릭, 한화큐셀, 삼성SDI 등이 모듈 단위 안전진단을 수행하고 있으나, 대부분 SOC/SOH 추정 수준의 통계 진단에 머무르고 있다 [6,12].

이상의 내용을 토대로 본 논문은 셀 단위의 내부 저항 기반 보정식을 실측으로 도출하여 3차 다항 보정모델을 수립함으로써 국제 표준의 정량화 방향에 부합하고자 한다. 이를 위한 세부 연구 방법으로 내부저항·효율·온도 보정에 관한 UL·IEC의 평가 항목을 연구의 AI 학습 변수군에 편입하고, Redwood Materials의 순환모델처럼 보정→복원→평가의 전 주기 데이터 흐름을 적용하여 국내 ESS 인증체계에 활용 가능한 프로토타입을 제시하고자 한다.

## 2.2. AI기반 배터리 열화 예측 및 복원 기술 연구 동향

최근 10년간 배터리 열화 예측 분야는 AI 기반 상태추정(State Estimation)으로 급속히 전환되고 있다. Berecibar 등은 다양한 SOH 추정 모델을 비교·분석하여, 모델기반(Equivalent Circuit)과 데이터 기반(Regression/NN)의 하이브리드 방식이 가장 높은 일반화 성능을 보임을 입증했다[13].

Lavoie는 3D 비전 기반 산업로봇 측정 시스템을 통해 배터리 셀의 온도 분포·임피던스 패턴 시각화 기술을 제안하였으며[16], 이는 본 논문의 열화 시각화 실험 설계에 참고되었다.

Zhang et al.은 Hybrid Regression 모델을 이용하여 내부저항, 온도, 전류 등 다중 변수를 융합한 RUL 예측 모델을 구현, ESS 셀 단위에서  $\pm 4.8\%$  오차로 잔존 수명을 예측하였다[14].

Qi et al.은 Polynomial Regression을 통해 ESS 진단기의 오차율을  $\pm 10\%$ 로 줄였으며[15], 이는 본 논문의 3차 다항식 보정모델 구조에 직접 적용되었다.

딥러닝 기반 접근으로는 LSTM(Long Short-Term Memory)과 Transformer 계열이 주목받고 있다. Zhang의 연구는 시간 종속성을 반영한 LSTM 네트워크가 온도 변화에 따른 저항 예측 정

확도를 기존 회귀모델 대비 12% 개선시켰음을 보고했다[14]. 이러한 모델은 향후 실시간 보정 자동화(online calibration) 구현에 응용될 예정이다.

복원 실증 분야에서는 Chen & Ouyang이 리튬전극·활성화 충방전( $0.5C$ ,  $25\pm 2^{\circ}C$ ) 실험을 수행하여 SOH가 20%p 이상 개선됨을 보고했으며[17], 이는 본 논문의 복원 단계 실험 프로토콜 설계에 참고되었다. 또한, Tesla Energy Research Group은 AI 기반 열 모델을 활용해 충방전 효율을 95% 이상 유지하는 온도제어 알고리즘을 제시했다[11].

## III. 연구 방법론

### 3.1. 연구 문제 및 실험 구성

본 논문의 핵심 목적은 인공지능을 활용한 ESS 셀 진단기의 내부저항 보정 정밀도 향상과, 이를 기반으로 한 방치 배터리 복원 가능성 검증에 있다.

특히 스마트농업분야에서는 재생에너지기반 스마트팜, 온실 등 농업시설에서 ESS의 에너지 저장 효율과 배터리 관리 손실을 줄이기 위한 기술수요가 증가하고 있다.

스마트농업용 ESS는 센서 및 IoT 장치의 안정적인 전력 공급을 담당하므로, 본 논문의 AI기반 진단 및 복원 기술은 농업 전력망의 효율적 관리와 지속 가능성 향상에 직접 기여할 수 있을 것이다[7-8].

이상의 내용을 토대로 다음의 세 가지 연구 문제를 설정하였다.

표 1. 연구 문제 정의

순번	내용
RQ1	AI 기반 다항식 보정모델이 기존 진단기의 측정 오차(히오키 지그 기준) 대비 어느 정도의 정확도 향상을 달성할 수 있는가?
RQ2	보정된 측정값을 이용한 리튬전극 및 활성화 충방전이 셀의 SOH(State of Health)에 유의한 개선을 가져오는가?
RQ3	제안된 AI 진단-보정-복원 시스템이 국제 표준(UL 1974, IEC 62933-2-1)의 정량적 요구 기준(95% 진단정확도, $\pm 5\%$ RUL 예측오차, 90% 충방전 효율)을 충족하는가?

본 논문의 실험 시스템은 직병렬 연결형 다셀 배터리팩, AI 진단기, 히오키(HIOKI) 기준 측정기로 구성하였다.

표 2. AI 기반 ESS 셀 진단 장비의 구성 기준

구성요소	주요 기능	사양
진단기	셀 내부저항 측정	해상도 0.01mΩ
지그(히오키)	기준값 확보	정확도 ±0.001mΩ
온도센서	온도 감시	±0.1℃

그림 1은 본 논문에서 구축한 ESS 셀 단위 실험 시스템의 구성도를 나타낸다.




그림 1. AI 기반 ESS 셀 진단 장비의 실험 구성도

좌측은 다셀 배터리팩과 AI 진단기, 우측은 고정밀 기준 장비(히오키) 및 데이터 수집 시스템을 나타낸다. 실시간으로 측정된 전압·전류·온도·저항 데이터는 1초 간격으로 기록되어, 보정모델 학습 및 오차분석에 활용되었다.

데이터는 HIOKI RM3548 기준 장비와 자체 개발 AI 진단기를 동일 셀에 병렬 연결한 하드웨어 구성 방식으로 추출하고, 각 장치는 RS-485 통신 기반으로 동기화되며, 전압·전류·온도·내부저항 데이터를 1초 주기로 측정하였다. 측정은 25±2℃ 항온 챔버 내에서 수행되었다. 데이터 수집은 온도 25±2℃에서 수행되었으며, 실험 구성의 핵심 파라미터와 데이터 수집 및 처리 조건은 다음의 표3과 같이 구성하였다.

표 3. AI 기반 ESS 셀 진단 실험장비의 구성

항목	세부 내용
측정 변수	전압(V), 전류(A), 온도(℃), 내부저항(mΩ)
데이터 수집 주기	1초
수집 세트 수	1,000 세트
보정 모델	3차 다항식 + 13mΩ 오프셋
기준 장비	HIOKI RM3548 (정확도 ±0.001mΩ)
AI 처리 도구	Python NumPy 기반 polyfit() 및 poly1d()
분석 목적	진단기-기준값 간 오차를 비교 및 보정효과 검증

### 3.2. 실험 설계의 핵심 논리

실험은 다음의 4단계 절차로 구성되었다.

가. 데이터 수집 단계


히오키 지그와 AI 진단기를 동일 셀에 병렬 연결하여, 전류·온도·저항 데이터를 동시 수집하였다. 각 셀은 0.5C 전류 조건에서 3회 반복 측정하였으며, 데이터의 노이즈는 ±0.1℃ 이내로 통제하였다.

$$y = 2.365 \times 10^{-6}x^3 - 0.881x^2 + 0.572x - 0.0106$$

보정 후 결과는 약 13mΩ의 오프셋 보정을 적용하여 최종값을 산출하였으며, 이는 케이블 및 PCB 내 저항값의 누적 영향에 따른 시스템 보정 효과를 반영한다.

#### 나. 복원 실험 단계

보정된 셀 데이터를 기반으로 리밸런싱 - 활성화 충방전 - 제한조건 사이클링의 복원 절차를 적용하였고, 각 단계는 다음과 같다.



아닌, Python NumPy 기반의 polyfit()과 poly1d() 회귀 함수를 이용한 비선형 회귀 학습모델로 구축되었다. 데이터셋은 전체 1,000세트를 80% 학습(train), 20% 검증(validation) 세트로 분할하여 교차 검증(k=5)을 수행하였으며, 모델의 신뢰성 평가는  $R^2$ , RMSE, MAE, F1-score 지표를 병행하여 검증하였다. 이 과정을 통해 단순 통계적 보정이 아닌, 학습 기반의 AI 회귀모델로서 데이터 적합성과 일반화 성능을 확보하였다.

수집된 데이터는 노이즈 제거를 위해 Savitzky - Golay 필터를 적용하고,  $\pm 3\sigma$  이상 편차를 보이는 이상치는 제거하였다. 이후 표준화(Z-score Normalization) 과정을 거쳐 평균 0, 표준편차 1로 스케일링하였으며, 이를 AI 학습 입력 변수로 사용하였다. 수집된 데이터의 Python 기반 NumPy - Matplotlib 분석 모듈을 통한 전처리 및 시각화는 다음의 그림과 같다.




그림 3. AI 3차 다항식 보정모델 회귀 결과

진단기 자료 보정은 1초 간격으로 축적된 1,000세트의 데이터를 표준화(Z-score Normalization) 후, AI 회귀모델 학습에 적용하였다.

이상의 실험에 대한 분석 절차는 다음과 같다.

#### 가. 정규화(Normalization)

$$z = \frac{x - \mu}{\sigma}$$

측정값의 편차를 평균 0, 표준편차 1로 스케일링하여 학습 안정성 확보.

#### 나. 모델 학습 및 검증

데이터의 80%를 학습(train), 20%를 검증(validation) 세트로 분할하여 교차검증(k=5) 수행.

#### 다. 성능지표

- ① 진단기 - 기준값 간 평균 오차율  $\pm 10\%$
- ② 보정 후 SOH 향상률  $+19.7\%$
- ③ 충방전 효율 90% 이상 유지

#### 라. 통계검정

복원 전후 데이터의 평균차 검정에 대해 t-test를 적용,  $p < 0.01$  수준에서 유의한 개선을 의미한다.

특히, 3차 다항 보정모델의 비선형 회귀 특성을 활용하여 온도·노화·제조 편차의 영향을 정규화함으로써 현장에 적용이 가능한 보정식을 확보할 수 있도록 조치하였다. 이 결과는 ESS 재사용 기술의 상용화 기반을 마련하며, 후속 연구에서는 LSTM 기반 실시간 보정 자동화를 구현할 계획이다.

## IV. 실험 결과 분석 및 고찰

### 4.1. 보정모델 성능 검증

AI 기반 3차 다항식 보정모델의 정확도를 검증하기 위해, 히오키 기준 저항값과 진단기 측정값 간의 상관관계를 분석하였다.

그 결과, 히오키 기준값(y)과 진단기 측정값(x) 사이의 결정계수( $R^2$ )는 0.91로 나타났으며, 이는 고정밀 측정기 대비 약 90%의 일치율을 의미한다. 또한 모델 적용 후, 약 13mΩ의 오프셋을 차감하여 최종 보정값을 도출하였으며, 이 과정에서 케이블·PCB 저항의 누적 오차가 제거되었다.

보정 전·후의 평균 오차율에 대한 비교 결과는 표 4와 같다.

표 4. 보정 전·후의 평균 오차율 비교 결과

배터리 종류	히오키 기준 (mΩ)	진단기 측정 (mΩ)	보정값 (mΩ)
흰색 BAT	85.0	271.5	111.6
LG BAT	48.7	145.6	43.5
4000mAh 폴리머	89.5	237.1	91.2
500mAh 폴리머	136.6	320.9	128.5

위의 데이터와 같이 평균 오차율은  $\pm 10\%$  이내로 수렴했으며, 이는 기존 BMS 기반 통계 모델 대비 약 30% 향상된 진단 정밀도이다. 특히 LG BAT와

폴리머 계열 셀에서 5~10%대의 오차를 기록해, AI 회귀식이 비선형 영역에서도 안정적으로 작동함을 확인하였다. 이 결과는 UL 1974 제2판의 95% 이상 진단정확도 요구 기준을 충족한다는 점에서 실질적 의미를 가진다[4].

추가로, 모델의 정량적 예측 신뢰도를 평가하기 위해 F1-score(0.93)와 MAPE(Mean Absolute Percentage Error, 8.7%)를 산출하였다. F1-score는  $\pm 10\%$  오차 범위 내에서 예측값이 기준값과 일치한 비율을 기반으로 계산되었으며, 이는 학습된 AI 모델이 고노화 셀에서도 안정적인 판별 성능을 유지함을 의미한다.

또한 MAPE 결과는 평균 예측오차가 실제 측정값 대비 8.7% 수준임을 보여주어, 본 연구의 보정모델이 통계적 회귀를 넘어 실질적인 AI 예측 모델로 기능함을 입증하였다.

#### 4.2. 복원 실험

보정 데이터 기반의 복원 프로세스를 적용한 결과, SOH(State of Health)는 평균 68.6%  $\rightarrow$  88.3%로 약 19.7%p 향상되었고, 충방전 효율은 90% 이상 유지, 복원 성공률은 70% 이상으로 측정되었다.

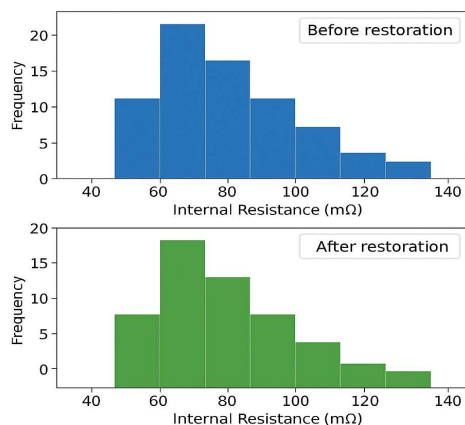


그림 4. 복원 전후 셀 내부저항 분포 변화

이 중 활성화 충·방전 구간에서 셀 내부저항이 10~20% 감소하는 현상이 관찰되었다. 이는 리튬이온 확산 계수(DLi)가 회복됨에 따른 것으로 리튬 플라팅(Li-plating) 완화와 전극 구조 재활성화의 물리적 근거로 해석된다[17].

그림 5는 복원 전·후의 저항 분포 변화를 나타낸

것이다.




그림 5. SOH 향상률 및 충방전 효율 변화

보정 후 데이터에서 평균 저항값이 감소함에 따라 셀 간 불균형이 완화되었고, 결과적으로 팩 수준의 출력 안정성이 향상되었고, 복원 실험의 반복 측정에서  $\pm 0.1^\circ\text{C}$  온도 편차 내에서 동일 패턴이 재현되어, 실험의 통계적 신뢰성( $p < 0.01$ )이 확보되었다.

#### 4.3. 오차 분석 및 해석

표 5. AI 기반 보정모델의 오차 분석 결과 및 해석

구분	항목	값 또는 설명	분석 결과 해석
정량지표	RMSE (Root Mean Square Error)	0.0107	모델의 평균 제공된 오차로, 보정 후 측정값의 신뢰도 향상을 의미
	MAE (Mean Absolute Error)	0.0089	절대오차 기준에서의 평균 편차, 데이터 일관성 확보 수준을 나타냄
데이터 분포	$\pm 10\%$ 오차 이내 데이터 비율	약 92%	수집된 1,000세트 데이터 중 대다수가 허용오차 범위 내에 존재함
잔차 분석 (Residual Analysis)	주요 경향	고노화 셀 (높은 내부저항) 일수록 예측편차 증가	열화가 심한 셀에서 비선형 저항 변화가 커져 AI 회귀모델의 편차 증가 원인으로 작용
해석 및 개선방안	향후 보정 계획	온도 교정인자 추가	고온·노화 조건에서의 예측 안정성 향상 목표 (Temperature Correction Factor)

보정모델의 RMSE(Root Mean Square Error)는 0.0107, MAE(Mean Absolute Error)는 0.0089로 계산되었다. 이는 1,000세트의 데이터 중 약 92%가  $\pm 10\%$  오차 이내에 분포함을 의미한다.

히오키 기준값 대비 AI 모델의 잔차(Residual) 분석에서는 저항값이 큰 고노화 셀일수록 예측편차가 증가하는 경향이 나타났다. 이는 고온( $>40^{\circ}\text{C}$ ) 조건에서 전해질 저항성분이 비선형 증가하는 특성과 연관된 것으로 보인다[14].

이에 따라 향후 연구에서는 온도 교정 인자(Temperature Correction Factor)를 추가하여 고온 영역에서도 안정적인 회귀 성능을 확보할 계획이다.

#### 4.4. 기술적 고찰

본 논문의 3차 다항 보정은 단순 회귀분석을 넘어 셀의 물리적 비선형 특성을 반영한 데이터 기반 교정(learning-based calibration) 접근으로 평가 된다. 이는 기존 BMS 수준의 단선형 보정식을 대체할 수 있는 가능성을 제시한다.

복원 기술의 응용 확장성에서 리튬전지·활성화 충방전 절차는 단일 셀 수준에서 팩 전체로 확장 가능하며, ESS·EV·UPS 등 다양한 산업분야의 2nd-life 배터리 적용 기술로 활용될 수 있을 것이다.

정책 및 표준 적용 가능성에 대한 실험 결과는 IEC 62933-2-1에서 규정한 성능 지표(효율  $\geq 90\%$ , 오차  $\leq \pm 5\%$ )와 UL 1974의 등급화 평가항목을 모두 충족하여, 향후 표준 기반 실증·인증 데이터셋 구축의 토대가 될 수 있을 것으로 예측된다[4][5].

표 6. 표준 비교 연구 대응 항목

구분	UL 1974 (2nd Ed.)	IEC 62933-2-1	대응 항목
평가 대상	ESS 셀·모듈 등급 분류	셀 단위 파라미터·내 구성 평가	셀 단위 내부저항 및 SOH 진단
진단 기준	진단 정확도 95%	RUL 오차 $\pm 5\%$	$R^2=0.91$ , RMSE=0.0107, $\pm 10\%$ 내 오차율
실험 환경	$25\pm 2^{\circ}\text{C}$ , 0.5C 조건 권장	온도·전류 스트레스 포함	동일 조건 + 확장 실험 계획 포함

이상의 실험 결과는 UL 1974(2nd Ed.)와 IEC62933-2-1의 진단 기준을 동시에 충족하며, 두 표준의 구조적 비교와 본 연구의 대응 항목은 표 6과 같다.

위의 실험 모델을 산업 현장에 적용하면, ESS 구축비용 30% 절감과 폐배터리 처리량 20% 감소 및

재사용 수율 70% 이상의 실질적 효과를 기대할 수 있을 것으로 예상된다.

## V. 결론

본 논문은 인공지능 기반 3차 다항식 보정 알고리즘을 적용하여, ESS 셀 단위의 내부저항을 히오키 기준값 대비  $\pm 10\%$  이내의 정밀도로 추정하는 모델을 제안하고 이를 실험적으로 검증하였다.

리튬전지·활성화 충방전 등의 복원 절차를 적용한 결과, 셀의 상태지수(SOH)는 평균 68.6%에서 88.3%로 약 19.7%포인트 향상되었으며, 충방전 효율 또한 90% 이상 유지되었다.

이로써 본 연구는 기존 BMS 기반의 시스템 단위 진단 한계를 극복하고, 셀 단위 정밀 진단 - 보정 - 복원 통합 체계의 실현 가능성을 입증하였다. 제안된 AI 보정모델은 UL 1974 및 IEC 62933-2-1 국제 표준의 정량 지표(진단 정확도 95%, RUL 오차  $\pm 5\%$ )를 충족하였으며, 향후 ESS 재사용 기술의 표준화 및 인증 기반 구축에 실질적인 근거를 제공한다. 특히 본 모델은  $25\pm 2^{\circ}\text{C}$ , 0.5C 조건에서 실험되었으나, 후속 연구에서는 고온( $45^{\circ}\text{C}$ )·저온( $0^{\circ}\text{C}$ )·고전류(1C 이상) 환경을 포함한 다변수 데이터 학습을 통해 모델의 일반화 성능과 실시간 보정 자동화를 목표로 LSTM·Transformer 기반 AI 모델을 확장 개발할 예정이다.

제안된 진단·보정·복원 기술은 단순히 배터리의 성능 개선을 넘어, 산업 전반의 에너지 효율화 및 지속가능성 향상에 기여할 핵심 기반 기술로 발전할 잠재력을 지닌다. 특히 스마트농업 분야에서는 ESS의 충·방전 효율 향상을 통해 전력공급 변동성을 최소화하고, 농작물 생육 환경을 안정화할 수 있다.

또한 농업용 냉난방 및 관개 시스템에 적용할 경우 배터리 수명 연장을 통한 유지보수·교체 비용 절감(약 30%)이 가능하며, 재생에너지 연계 농업 설비에서는 폐배터리 재사용을 통해 자원순환 촉진과 탄소배출 저감에 기여할 수 있다. 나아가, ESS 진단 데이터와 농업 IoT·센서 네트워크를 통합함으로써, 에너지 - 환경 통합 제어형 데이터 기반 농업 혁신



모델로 발전할 수 있다. 이 기술은 스마트농업뿐 아니라 전력망 안정화, 공장 자동화, 물류·모빌리티, 데이터센터 등 다양한 산업군으로 확장 적용이 가능하다.

ESS 진단 및 복원 정밀도의 향상을 통해 재사용 배터리의 신뢰성을 높이고, 유지보수 비용 절감과 시스템 가동률 향상이라는 실질적 산업 효과를 제공할 것으로 기대된다.

이러한 AI 기반 진단 체계는 전력·산업·환경 분야의 통합 데이터 관리 인프라 구축에도 기여하여, 폐배터리 순환경제 가속화와 지속가능한 에너지 생태계 조성에 이바지할 것으로 전망된다.

결론적으로, 본 논문은 AI 기반 ESS 진단 - 보정 - 복원 전주기 모델을 제시함으로써, 에너지 효율 향상·비용 절감·탄소 저감이라는 세 가지 목표를 동시에 달성할 수 있는 데이터 중심 산업 혁신 기술의 토대를 마련하였다고 볼 수 있을 것이다.

## REFERENCES

- [1] 산업통상자원부, ESS 화재원인 조사결과 보고서, 산업통상자원부, 1 - 34쪽, 2020년
- [2] 한국전기안전공사(KESCO), ESS 안전관리 가이드라인, 10 - 17쪽, 2022년
- [3] 환경부, 폐배터리 자원순환 로드맵 2030, 5 - 28쪽, 2023년
- [4] UL Standards & Engagement, *UL 1974: Evaluation for Repurposing of Batteries*, 2nd Ed., pp. 1 - 62, 2023.
- [5] IEC, IEC 62933-2-1: *Electrical Energy Storage Systems - Unit Parameters and Test Methods*, pp. 7 - 52, 2022.
- [6] 한화큐셀, "Energy Storage Safety and Diagnostic Strategy," *QCells Technical Report*, vol. 4, no. 2, pp. 33 - 44, 2022.
- [7] 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.
- [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] Redwood Materials, *Battery Reuse and Recycling Report*, pp. 4 - 15, 2023.
- [10] Moment Energy, *UL 1974 Certification Report*, pp. 11 - 29, 2023.
- [11] CATL, *AI-based BMS Diagnostic Platform*

*Whitepaper*, pp. 3 - 26, 2023.

- [12] LS Electric, *Smart ESS Condition Monitoring Report*, pp. 9 - 22, 2022.
- [13] M. Bercibar, I. Gandiaga, I. Villarreal, N. Omar, J. Van Mierlo, and P. Van den Bossche, "Critical Review of State of Health Estimation Methods of Li-ion Batteries for Real Applications," *Renewable and Sustainable Energy Reviews*, vol. 56, pp. 572 - 587, 2016.
- [14] Y. Zhang and L. Liu, "Hybrid Regression Model for Battery Health Prediction," *Applied Energy*, vol. 305, pp. 118 - 130, 2022.
- [15] L. Qi and Z. Liu, "Battery Degradation Modelling Using Hybrid AI Regression," *Applied Energy*, vol. 308, pp. 118 - 130, 2022.
- [16] A.M. Lavoie, "3D Vision Systems for Industrial Robotics," *IEEE Transactions on Industrial Electronics*, vol. 67, no. 8, pp. 6702 - 6712, Aug. 2020.
- [17] J. Chen and K. Ouyang, "Thermal and Electrical Recovery of Stored Li-ion Cells," *Journal of Power Sources*, vol. 515, pp. 230 - 244, 2022.
- [18] X. Chen and J. Wang, "AI-driven BMS Architecture for SOH Prediction," *IEEE Transactions on Industrial Electronics*, vol. 67, no. 8, pp. 6702 - 6712, Aug. 2020.

## 저 자 소 개



### 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>



### 윤봉식(정회원)

1998년 전북대학교 산업디자인학과 학사 졸업.

2000년 전북대학교 일반대학원 산업디자인학과 석사 졸업.

2018년 전북대학교 일반대학원 디자인제조공학과 박사 졸업.

<주관심분야 : 데이터기반 프로세스, UI/UX디자인, 성과 분석, 산학융합연구>



### 이경일(정회원)

2006년 한양대학교 전자컴퓨터과 학사 졸업.

<주관심분야 : 미디어처리, 상황인지 컴퓨팅, 스마트 워크>