

화성공정 데이터 기반 리튬이온전지의 SOC별 내부저항 예측

기용하^{1,2} · 정아현^{1,2} · 김종현² · 윤명근^{1,2*}

¹고려대학교 바이오의공학과
²주필드큐어

(2025년 7월 28일 접수 : 2025년 8월 7일 수정 : 2025년 8월 11일 채택)

SOC-wise Internal Resistance Prediction for Lithium-Ion Batteries Using Formation Data

Yongha Gi^{1,2}, A Hyun Jung^{1,2}, Jong Hyun Kim², and Myonggeun Yoon^{1,2*}

¹Department of Biomedical Engineering, Korea University, Seoul, Republic of Korea
²FieldCure Co., Ltd., Seoul, Republic of Korea

(Received July 28, 2025 : Revised August 7, 2025 : Accepted August 11, 2025)

초 록

본 연구에서는 리튬이온 배터리 제조 공정 중 화성공정에서 수집된 시계열 데이터를 기반으로, 에이징 이후 Hybrid Pulse Power Characterization(HPPC) 시험을 통해 측정되는 State of Charge(SOC)별 내부저항을 예측하는 다중출력 회귀 모델을 제안한다. 입력 데이터는 화성공정에서 측정된 전압, 전류, 충·방전 용량의 시계열이며, 출력은 SOC 5%부터 100%까지의 내부저항 값으로 구성된다. 제안된 XGBoost와 Random Forest 기반 회귀 모델은 별도의 펄스 진단 없이도 전 SOC 구간에서 1 mΩ이하의 낮은 평균 오차와 0.99이상의 높은 결정계수를 달성하였다. 특히 수명과 상관성이 높은 SOC 5%지점의 내부저항에 대해서도 평균 상대오차 3%내외의 정밀도로 예측함으로써, 화성공정 단계의 충·방전 데이터만으로도 조기 수명 관련 정보를 확보할 수 있는 가능성을 실증하였다. 본 연구는 HPPC 시험을 가상화 할 수 있는 데이터 기반 진단 접근법을 제시함으로써, 배터리 내부저항 특성을 비침습적으로 추정하고 수명 예측, 품질 선별, 제조 공정 최적화 등 다양한 응용에 활용될 수 있는 기술적 가능성을 제공한다.

Abstract : This study proposes a multi-output regression model for predicting the internal resistance of lithium-ion batteries across various states of charge(SOC), based on time-series data collected during the formation stage of the manufacturing process. The target resistance values were measured after aging using the Hybrid Pulse Power Characterization(HPPC) test. The input data consist of time-series measurements of voltage, current, and charge/discharge capacity recorded during formation, while the outputs correspond to internal resistance values at 24 SOC points ranging from 5% to 100%. The proposed regression models, based on XGBoost and Random Forest, achieved low mean errors of less than 1 mΩ and high coefficients of determination($R^2 \approx 0.99$) across the entire SOC range without the need for additional pulse diagnostics. In particular, the model precisely predicted the internal resistance at 5% SOC—strongly correlated with battery lifespan—with a mean absolute percentage error of around 3%, demonstrating the feasibility of extracting early-life indicators using only charge/discharge data from the formation stage. By presenting a data-driven diagnostic approach that virtualizes the HPPC

*E-mail: radiyoon@korea.ac.kr

test, this work enables non-invasive estimation of internal resistance characteristics and offers practical applicability for battery lifespan prediction, quality screening, and process optimization.

Keywords : Lithium-ion battery, Formation data, Internal resistance across State of Charge, Hybrid Pulse Power Characterization

1. 서 론

리튬이온 전지의 성능 열화 및 수명 예측은 전기자동차(Electric Vehicle)와 에너지저장장치(Energy Storage System)의 안전성과 경제성 확보를 위해 핵심적인 과제이다.¹⁻³⁾ 그러나 배터리 수명을 정확히 추정하기 위해서는 일반적으로 장시간의 사이클 시험이나 정밀 진단이 요구되며, 이로 인한 시간 및 비용 부담이 크다.⁴⁻⁶⁾ 이러한 맥락에서 내부저항은 온도, 충·방전 상태(State of Charge, SOC), 열화 상태(State of Health, SOH) 등에 민감하게 반응하며, 배터리의 상태를 나타내는 중요한 지표로 널리 활용된다.⁷⁾ 실제로 리튬이온 전지의 내부저항 증가는 노화 진행의 대표적 징후로 간주되며, SOH 추정이나 수명 모델링에 필수적으로 사용된다.⁷⁻⁹⁾

내부저항 측정을 위한 대표적인 기법인 하이브리드 펄스 전력 특성화(Hybrid Pulse Power Characterization, HPPC)는 수 초간 전류 펄스를 인가하여 전압 응답을 측정하고, 이를 통해 다양한 SOC에서의 직류 내부저항을 계산하는 방식이다.^{10,11)} 이 방식은 주기적 참조 성능 시험(Reference Performance Test) 중 하나로 배터리의 가용 출력 및 열화 수준 평가에 사용되지만, 모든 셀에 대해 HPPC 테스트를 수행하는 것은 제조 공정에서 큰 부담이 될 수 있다. 이에 따라 화성(Formation) 공정단계에서 수집되는 데이터를 활용하여 수명을 예측하려는 접근이 주목받고 있다.¹²⁾

이와 관련하여 최근 Weng 등¹³⁾은 화성공정 단계 완료 직후 낮은 SOC(약 5%)에서 측정한 10초 펄스 내부저항(Resistance at Low State-of-Charge, RLS)이 향후 사이클 수명(초기 용량 대비 70% 용량 도달까지의 사이클 수)과 높은 음의 상관관계(correlation coefficient = -0.84)를 보인다는 점을 밝혔다. RLS는 기존 화성공정 단계 지표들(예: 최초 손실용량 Q_d , 화성 효율 CE_f 등)에 비해 사이클 수명과의 상관성이 뚜렷하게 높았으며, 고SOC 저항이나 용량 기반 지표들보다 예측력이 우수하였다. 특히 RLS는 전기화학 임피던스 분광법(Electrochemical Impedance Spectroscopy)와 같은 고가의 장비 없이 수 초 내에 제조 라인에서 측정 가능하다는 점에서 실용성이 높으며, 단일 RLS 지표만으로 테스트셋에서 약 8% 수준의 평균 절대 백분율 오차(Mean Absolute Percentage

Error, MAPE)를 기록하는 사이클 수명 예측 모델을 구성할 수 있었다. 이는 “화성 공정 직후의 간단한 저항 측정만으로도 수명 예측이 가능하다”는 가능성을 제시한다.

RLS가 이처럼 사이클 수명과 밀접한 연관을 보이는 이유는, 단순한 내부저항 측정 이상의 정보를 함축하고 있기 때문이다. 낮은 SOC(약 5%) 구간에서 측정된 저항은, 주로 초기 화성 이후 전극의 리튬 분포 상태, 전도성 네트워크의 형성 정도, 전해질과의 계면 품질, 미세구조 손상 여부 등 전극의 균일성과 안정성을 반영한다. 이러한 요인들은 장기 사이클링 동안 성능 열화에 직접적인 영향을 미치며, 조기 열화(cell degradation)의 가능성을 간접적으로 드러낸다. 즉, RLS는 제조 공정 품질의 편차 또는 초기 결함의 존재 여부를 민감하게 반영하는 지표로 작동하며, 이로 인해 향후 용량 저하 속도와 밀접한 상관관계를 갖는 것이다. 따라서 RLS는 단순한 물리량 측정을 넘어, 장기 신뢰성과 내구성을 조기에 평가할 수 있는 유효한 예측 변수로 주목받고 있다.¹³⁾

그러나 RLS를 활용하기 위해서는 여전히 화성공정 이후 별도의 펄스 측정 절차가 필요하다는 한계가 존재한다. 이에 본 연구에서는 화성 과정에서 수집된 시계열 데이터만을 활용하여 HPPC 기반의 내부저항 지표, 특히 다양한 SOC에서의 저항 곡선을 예측하는 모델을 구축하였다. 추가적인 펄스 테스트 없이 화성공정의 충·방전 데이터로부터 RLS 등 내부저항 특성을 추정할 수 있는지를 검토하고, 이를 수명 예측 변수로 활용할 가능성을 탐색하였다. 본 논문은 이러한 화성공정 데이터 기반 저항 예측 모델의 구조와 성능을 제시함으로써, 제조 과정의 데이터만으로 배터리 수명 지표를 확보할 수 있는 대안적 접근을 제안한다.

2. 실 험

2.1 데이터셋

본 연구에서는 Weng et al.¹³⁾에서 수집한 Nickel-Manganese-Cobalt/흑연 기반 리튬이온 파우치 셀 40개에 대한 화성공정단계 데이터셋을 활용하였다. 각 셀의 정격 용량은 약 2.36 Ah이며, 20개씩 두 그룹으로 나누어 상이한 화성 프로토콜이 적용되었다. 한 그룹(기본 포메이션)은 C/10 속도로 2회의 충·방전 사이

클을 수행하였고, 다른 그룹(고속 포메이션)은 C/5 속도로 5회의 사이클을 진행하였다.化成공정 완료 후, 모든 셀은 25 °C(상온) 또는 45 °C(고온) 환경에서 반복 충·방전을 통해 에이징되었으며, 이는 각각 완만한 열화 및 가속 열화 조건을 모사한다.

化成공정 동안 각 셀에 대해 전류(A), 전압(V), 충전 용량(Ah), 방전 용량(Ah) 등 총 4개의 시계열 채널 데이터를 수집하였으며, 본 연구에서는 이를 기반으로 후속 분석을 수행하였다.

전체 시계열은 셀마다 약 2170~2260포인트로 구성되어 있으며, 이는化成공정 단계에서 수행된 두 번의 충·방전 사이클에 해당한다. 본 연구에서는 이 중 첫 번째 충전 사이클 구간인 앞부분에서 순차적으로 1000개의 시점 데이터를 추출하여 입력 벡터로 활용하였다. 이에 따라 전류, 전압, 충전/방전 용량의 4개 채널 각각에 대해 1000포인트씩 구성되었으며, 모든 채널은 원시값 그대로 사용되었다.

에이징 온도 정보는 실험 조건(25 °C 또는 45 °C)에 따라 0 또는 1로 인코딩되어 입력 벡터의 마지막에 추가되었다. 즉, 최종 입력 벡터는 1000포인트 × 4채널 + 1로 구성되며, 총 4001차원의 입력 벡터가 모델 학습에 사용되었다.

2.2 출력 정의 및 분석 구조 비교

본 연구는化成 과정 중 수집된 시계열 데이터만을 입력으로 사용하여, 별도의 진단 없이도 SOC별 내부 저항, 특히 RLS를 정밀하게 예측하는 접근 방식을 제안한다. 이와 같이 데이터 기반으로 내부저항을 예측하는 본 연구의 분석 구조는 기존 연구(Weng 등¹³)와 방법론적으로 근본적인 차이를 갖는다. Fig. 1은 두 방법의 흐름을 비교한 도식으로, Weng은化成공정 이후 실제 HPPC 테스트를 통해 SOC별 저항을 측정하고, 이 중 RLS를 수명 예측에 활용한 반면, 본 연구는化成공정 데이터만으로 SOC별 내부 저항을 예측함으로써 진단 과정을 생략하는 가상 HPPC 접근을 구현하였다.

예측 모델 학습을 위한 정답 레이블은化成공정 완료 후 수행된 HPPC 테스트를 기반으로 산출하였다. 각 셀에 대해 약 5%부터 100%까지의 SOC 구간에 대해 10초간의 충·방전 전류 펄스를 인가하고 전압 강하를 측정하였다.¹³ 약 4% 간격으로 총 24개 지점의 SOC에서 내부저항을 산출하였으며, 이 값들을 예측 모델의 목표 출력으로 사용하였다. 특히 SOC 5% 부근의 저항값은 수명과의 높은 상관성을 고려해 RLS로 정의하고 별도로 관리하였다.

2.3 모델 구성 및 평가

化成공정 데이터로부터 5-100% SOC 구간의 전체 내부저항 곡선을 예측하기 위해, 여러 머신러닝 회귀 모델들을 비교하였다. 트리 기반 앙상블 방법으로 XGBoost (XG)¹⁴, CatBoost (Cat)¹⁵, Random Forest (RF)¹⁶ 모델을 구현하였고, 딥러닝 모델로는 다층 퍼셉트론(MLP)¹⁷과 Long Short Term Memory (LSTM)¹⁸ 사용하였다. 또한 비교를 위해 선형 회귀 모델(Linear Regression, LR)도 포함하였다.

각 모델은 평균제곱오차(Mean Squared Error)를 손실 함수로 사용하여 학습되었으며, 하이퍼파라미터는 기본값을 바탕으로 간단한 교차검증이나 사전 실험을 통해 설정하였다. 트리 기반 모델의 경우 과적합을 방지하기 위해 생성할 트리의 개수(number of estimators)와 깊이(maximum depth), 학습률(learning rate) 등을 조정하였으며, XG는 트리 개수를 300, 최대 깊이를 6, 학습률을 0.1로 설정하였다. Cat과 RF도 유사한 수준에서 구성하였다. MLP는 입력 차원이 약 4001으로 높은 반면 학습 데이터 수가 적은 점을 고려하여 은닉층을 1024, 512로 구성하고, 드롭아웃과 배치 정규화를 적용하여 과적합을 완화하였다. 옵티마이저로는 Adam optimizer를 사용하였으며, 학습률은 1×10^{-3} 로 설정하였다. LSTM은 두 개의 은닉층을 사용하고 시계열 데이터를 (1000, 4) 구조로 재구성하여 입력하였으며, 마지막 시점 출력을 기반으로 회귀를

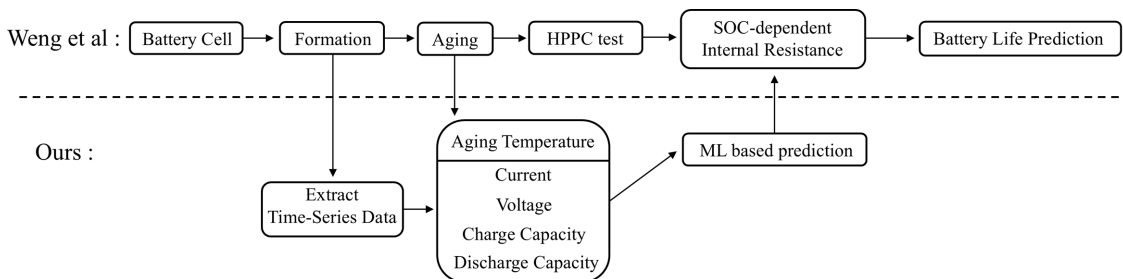


Fig. 1. Comparison between the SOC-resolved internal resistance measurement approach of the previous study (Weng et al.) and the formation data-based prediction pipeline proposed in this study.

수행하도록 설계하였다. 이 모델 역시 Adam optimizer를 사용하였으며, 학습률은 1×10^{-5} 로 설정하였다. 학습은 최대 2000회까지 반복 수행하였다.

모델 성능 평가는 결정계수(R^2)¹⁹⁾, 평균절대오차(MAE), 평균절대백분율오차(MAPE) 등의 지표로 수행하였다. 모든 모델은 5-Fold 교차검증을²⁰⁾ 기반으로 전체 40개 셀에 대해 훈련 및 평가되었으며, 각 Fold 별 성능은 평균값(Mean)과 Hodges-Lehmann 추정량(HL estimator)²¹⁾으로 종합하였다. 아울러, 전체 SOC 구간 예측과는 별도로 RLS 예측 성능을 별도로 평가하여 모델 간 비교에 활용하였다.

3. 결과 및 고찰

3.1 전체 SOC별 내부저항 예측 비교 결과

결정계수(R^2), 평균절대오차(MAE), 평균절대백분율오차(MAPE)는 각각 회귀 모델의 설명력, 절대 오차 크기, 상대 오차 비율을 나타내는 대표적인 평가 지표이다. Table 1은 이 세 가지 지표를 종합적으로 비교하여 전체 SOC 구간에서의 내부저항 예측 성능을 모델별로 요약한 결과를 보여준다.

트리 기반 앙상블 모델 중 XG는 모든 지표에서 가장 뛰어난 예측 성능을 보였다. 모든 폴드에서

$R^2 \geq 0.991$ 을 유지하였으며, 평균 R^2 은 0.996, HL estimator 기준으로는 0.997로 관측값을 거의 완벽하게 설명하였다. MAE 또한 평균 0.646 m Ω , HL estimator 기준 0.647 m Ω 으로 매우 낮았으며, 이는 실제 HPPC 장비 수준의 정밀도를 달성한 수치이다. 상대 오차 측면에서도 평균 MAPE는 2.59%, HL estimator 기준 2.51%로 매우 양호하였다.

RF 역시 평균 R^2 0.996, MAE 0.617 m Ω , MAPE 2.40%를 기록하며 XG와 동등한 수준의 예측력을 보였다. 특히 MAPE 기준으로는 가장 낮은 평균값을 기록하였고, 전반적인 모델 안정성에서도 가장 작은 분산을 보였다.

Cat은 평균 R^2 0.983, MAE 1.48 m Ω , MAPE 5.46%로 앞선 두 모델보다는 다소 낮은 수치를 보였지만, 여전히 수 m Ω 단위의 오차와 5% 수준의 상대오차로 실용적인 예측력을 유지하였다. 다만 저SOC 구간에서 일부 오차 증가 현상이 관찰되었으며, 이는 이후 Fig 분석에서 보다 구체적으로 논의된다.

반면, LSTM과 MLP는 전반적으로 성능이 낮고 불안정하였다. 평균 R^2 은 각각 0.633, 0.674에 불과하였고, MAE는 각각 8.52 m Ω , 7.45 m Ω 으로 수 m Ω 이상의 오차를 기록하였다. 특히 MAPE는 31.4%, 29.9%로 모든 모델 중 가장 높았으며, 이는 전 SOC

Table 1. Performance of regression models for predicting internal resistance across all SOC levels

Evaluation Metric		Model					
		LR	MLP	LSTM	XG	Cat	RF
R^2	Outer fold 1	0.992	0.638	0.542	0.998	0.988	0.997
	Outer fold 2	0.752	0.554	0.692	0.991	0.981	0.992
	Outer fold 3	0.826	0.642	0.564	0.997	0.966	0.997
	Outer fold 4	0.986	0.774	0.730	0.998	0.993	0.996
	Outer fold 5	0.986	0.764	0.639	0.997	0.988	0.998
	Mean	0.908	0.674	0.633	0.996	0.983	0.996
	HL estimator	0.906	0.664	0.636	0.997	0.984	0.996
MAE (m Ω)	Outer fold 1	1.19	7.08	8.77	0.569	1.37	0.556
	Outer fold 2	5.08	9.22	7.99	0.562	1.50	0.562
	Outer fold 3	4.82	7.38	8.81	0.731	1.92	0.619
	Outer fold 4	1.37	6.81	8.35	0.642	1.14	0.848
	Outer fold 5	1.23	6.77	8.69	0.726	1.45	0.499
	Mean	2.74	7.45	8.52	0.646	1.48	0.617
	HL estimator	3.03	7.10	8.56	0.647	1.45	0.588
MAPE (%)	Outer fold 1	4.91	29.3	34.3	2.45	5.10	2.22
	Outer fold 2	20.5	39.4	29.3	1.88	5.14	1.96
	Outer fold 3	17.1	29.4	36.3	3.62	7.51	2.82
	Outer fold 4	4.49	24.8	25.7	2.11	3.94	2.89
	Outer fold 5	3.89	26.6	31.7	2.91	5.59	2.09
	Mean	10.2	29.9	31.4	2.59	5.46	2.40
	HL estimator	10.8	29.3	31.7	2.51	5.35	2.43

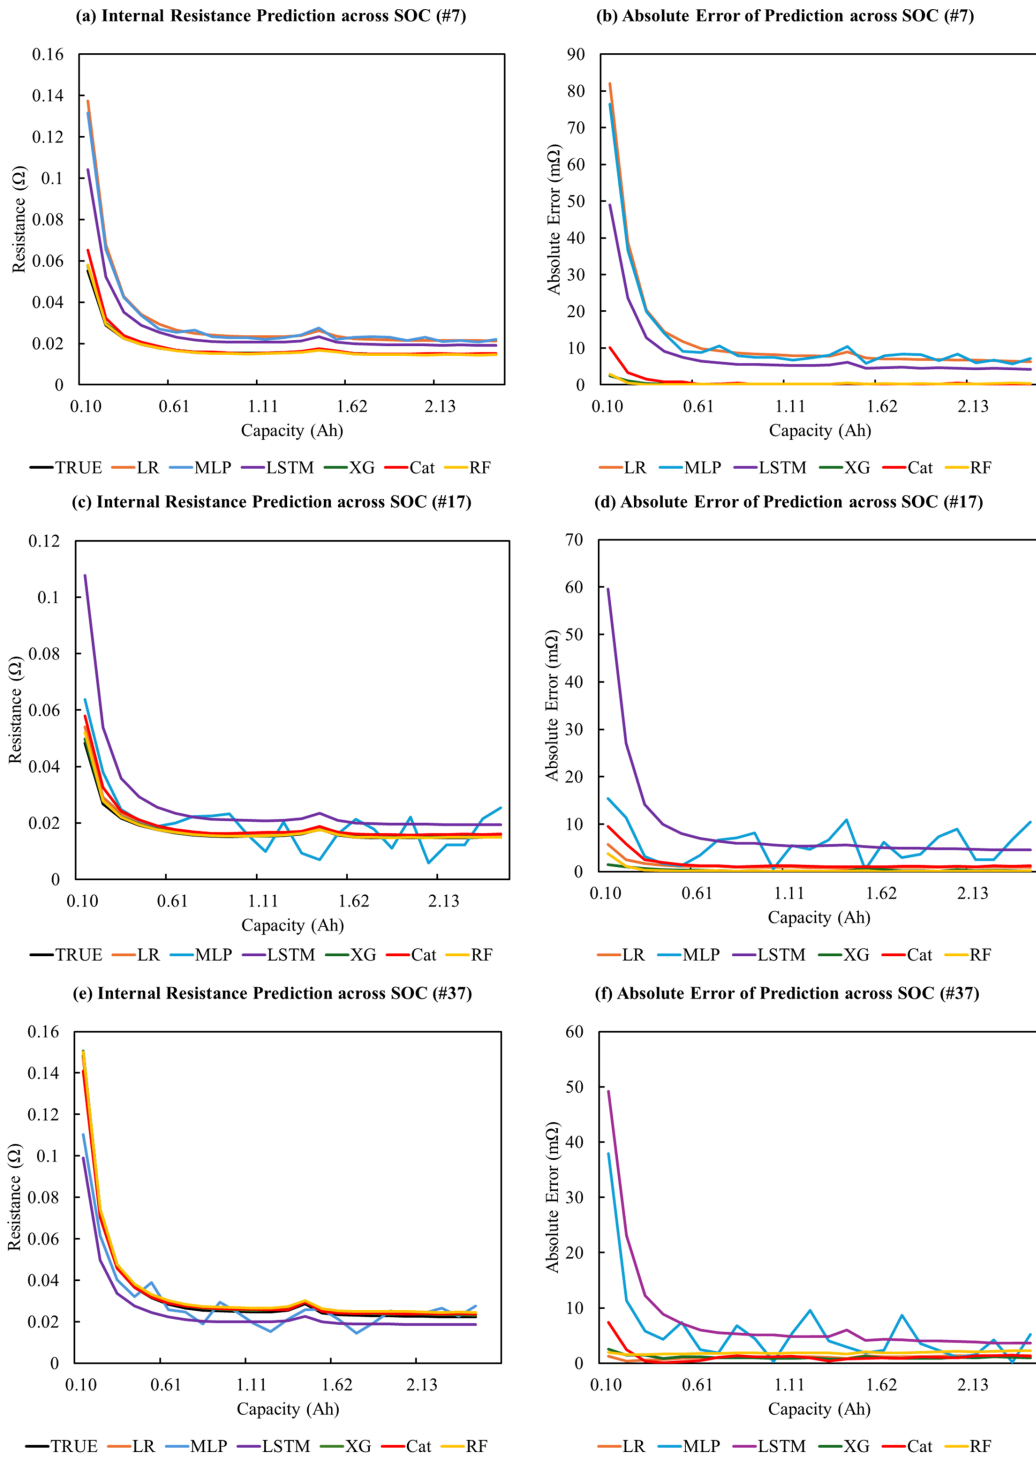


Fig. 2. Internal resistance prediction results for three representative cells(#7, #17, #37). (a), (c), (e): Predicted resistance profiles from six regression models(LR, MLP, LSTM, XG, Cat, and RF) versus HPPC-measured values across the entire SOC range(5-100%). (b), (d), (f): Absolute prediction errors (|predicted - measured|) as a function of SOC for the corresponding cells.

구간에서 상대적으로 큰 예측 오류가 발생했음을 의미한다. 이는 본 연구의 시계열 데이터 특성(정규화된 고정 길이, 소규모 샘플 수)이 순환신경망 기반 모델의 일반화 능력에 불리하게 작용했기 때문으로 해석된다.

LR은 단순한 모델 구조에도 불구하고 일부 Fold(예: Fold 1, 4, 5)에서는 $R^2 = 0.986\text{--}0.992$ 의 준수한 성능을 기록하였다. 그러나 Fold 2와 3에서는 각각 0.752, 0.826에 머물러 전체 평균 R^2 은 0.908, HL estimator 기준으로는 0.906에 그쳤다. MAE는 평균 2.74 m Ω , MAPE는 10.2%로, 딥러닝 계열 모델인 LSTM이나 MLP보다는 상대적으로 안정적이었지만, 트리 기반 모델에 비해서는 오차 폭이 크게 나타났다. 특히 Fold 2와 3에서는 MAE가 약 5 m Ω 에 달했고, MAPE 역시 각각 20.5%, 17.1% 수준으로 상승하는 등 데이터 분할에 따라 민감하게 성능이 변동하는 모습을 보였다. 이는 단순 선형 모델이 데이터의 복잡한 비선형 구조를 충분히 포착하지 못하는 구조적 한계에서 기인한 것으로 해석된다.

요약하면, XG와 RF는 모든 성능 지표에서 뛰어난 정밀도와 안정성을 보이며, 전체 SOC 구간에서의 내부저항 예측 곡선에 가장 적합한 모델로 확인되었다. Cat도 충분히 실용적인 정확도를 확보하였으며, LR은 간단한 모델임에도 일부 상황에서는 예외적으로 양호한 성능을 나타냈다. 반면, LSTM과 MLP는 전체적으로 높은 오차와 낮은 설명력을 보여주었으며, 현 데이터 조건에서는 적합성이 떨어지는 것으로 판단된다.

Fig. 2는 예측오차 분포가 서로 다른 대표 셀(#7, #17, #37)에 대해, 전 SOC 구간에 걸친 내부저항 예측 곡선과 절대 오차 곡선을 시각화한 결과이다. 좌측 열(a, c, e)은 실제 측정값과 각 모델의 예측값을 비교한 저항 곡선이며, 우측 열(b, d, f)은 예측값과 실측값 간의 절대 오차를 나타낸다.

XG와 RF 모델은 모든 셀에서 실제 곡선과 유사한 패턴을 안정적으로 재현하였으며, SOC 하단(5%)에서 급격히 증가하는 저항 특성까지 정밀하게 포착하였다. 특히 (a), (c), (e)에서 확인할 수 있듯이, 두 모델은 고SOC 구간에서는 2 m Ω , 저SOC 구간에서도 4 m Ω 이내의 절대 오차를 유지하며 매우 정밀한 예측을 보여주었다. 반면, Cat은 고SOC 구간에서는 비교적 안정된 예측 성능을 보였으나, 저SOC 영역에서는 오차가 순간적으로 급증하는 경향을 보였다. 특히 셀 #7(b)에서는 0.10 Ah 지점(SOC 5%)에서 약 10 m Ω 의 급격한 오차가 발생하였으며, 이는 초기 급변 영역의 특성 학습이 다소 불안정했음을 나타낸다.

전기화학적으로 저SOC 구간은 리튬 이온의 비균일한 분포, 계면 저항 증가, 전해질 반응 편차 등으로

인해 내부저항이 급격히 변동하는 영역이며, 실측값 자체도 비선형적이고 불안정한 특성을 보인다. Cat은 ordered boosting을 통해 과적합을 방지하는 장점이 있으나, 이 과정에서 학습 데이터의 순차적 일부만을 사용하여 잔차를 계산하므로, 저SOC처럼 데이터 포인트가 적고 급변하는 구간에서는 불안정한 예측으로 이어질 수 있다. 또한 Cat이 채택한 symmetric tree 구조는 모든 리프 노드에 동일한 분할 기준을 적용하므로, 국소적인 비선형 패턴을 세밀하게 포착하는 데 제약이 있을 수 있다. 반면, XG는 2차 미분(Hessian)까지 활용한 Taylor 근사를 통해 더 정밀한 분할점을 찾을 수 있으며, 비대칭적 tree 구조로 복잡한 패턴을 유연하게 학습할 수 있다. RF는 다수의 독립적인 트리로 구성되어 앙상블 효과를 통해 개별 트리의 예측 불안정성을 완화할 수 있으므로, 저SOC와 같은 급변 영역에서도 상대적으로 안정적인 예측 성능을 유지할 수 있었던 것으로 해석된다.

딥러닝 모델인 LSTM과 MLP 모델은 전반적으로 낮은 성능을 보였다. 두 모델 모두 예측 곡선이 실제 저항 패턴을 제대로 반영하지 못했으며, 특히 MLP는 모든 셀에서 불규칙한 진동 형태(oscillating pattern)를 나타내며 예측 안정성이 현저히 떨어졌다. 이는 시계열 길이에 비해 부족한 학습 샘플 수, 그리고 적절한 정규화 및 하이퍼파라미터 조정 부족에 기인한 과적합 또는 학습 불안정 현상으로 해석된다.

LR은 셀 #37(e, f)에서는 다른 모델에 근접한 예측 곡선을 보여주었으며, 절대 오차도 2 m Ω 내외로 양호하였다. 그러나 셀 #7(a, b)에서는 SOC 전반에서 구조적으로 과대 예측하는 경향을 보여 성능이 크게 저하되었으며, 이는 단순한 선형 모델이 셀 간 이질성과 다양한 곡선 형태를 포괄하기에는 한계가 있음을 시사한다. 따라서 LR은 일부 데이터셋에서는 좋은 근사 결과를 보일 수 있으나, 전체 셀을 대상으로 한 robust한 적용에는 적합하지 않은 것으로 평가된다.

3.2 RLS 예측 비교 결과

Table 2는 SOC 5% 조건에서의 내부저항(RLS) 예측 성능을 R^2 , MAE, MAPE 세 가지 지표 기준으로 종합 비교한 결과이다. 이 구간은 배터리 수명과 높은 상관성을 가지는 영역으로, 예측 정확도 뿐 아니라 모델의 일반화 성능을 확인하는 데 중요한 기준이 된다. 전체적으로 모델 간 성능 차이가 뚜렷하게 나타났으며, 이는 낮은 SOC 구간에서의 데이터 특성과 예측 난이도가 성능에 크게 영향을 미친다는 점을 시사한다.

XG와 RF는 모든 평가 지표에서 가장 뛰어난 성능을 보였다. 두 모델 모두 평균 R^2 0.988, HL estimator 기준으로도 0.992를 기록하며 모든 Fold에서 안정적

Table 2. Regression Performance Comparison for Predicting RLS: R², MAE, and MAPE

Evaluation Metric		Model					
		LR	MLP	LSTM	XG	Cat	RF
R ²	Outer fold 1	0.986	0.217	-0.0995	0.999	0.977	0.997
	Outer fold 2	0.139	-0.170	-0.00233	0.962	0.929	0.963
	Outer fold 3	0.561	0.142	-0.0731	0.995	0.907	0.995
	Outer fold 4	0.922	-0.0598	-0.467	0.990	0.969	0.987
	Outer fold 5	0.962	0.462	0.000	0.996	0.969	0.998
	Mean	0.714	0.118	-0.128	0.988	0.950	0.988
	HL estimator	0.762	0.130	-0.0731	0.992	0.950	0.992
MAE (mΩ)	Outer fold 1	5.16	39.8	53.2	1.09	7.12	1.97
	Outer fold 2	33.4	42.7	46.1	4.89	11.7	4.79
	Outer fold 3	28.5	42.3	52.6	2.79	14.1	2.62
	Outer fold 4	8.63	34.0	48.9	3.28	5.62	3.61
	Outer fold 5	7.06	32.5	52.3	2.69	8.00	1.81
	Mean	16.6	38.3	50.6	2.95	9.31	2.96
	HL estimator	17.8	38.2	50.8	2.99	9.41	2.79
MAPE (%)	Outer fold 1	7.46	60.5	78.6	1.57	9.29	2.46
	Outer fold 2	50.5	63.5	55.1	5.90	15.0	5.94
	Outer fold 3	30.0	55.2	73.8	3.82	18.6	3.53
	Outer fold 4	9.11	37.9	43.9	2.47	6.00	2.83
	Outer fold 5	5.56	38.5	67.6	3.18	10.5	2.63
	Mean	20.5	51.1	63.8	3.39	11.9	3.48
	HL estimator	18.7	50.7	64.5	3.18	12.1	3.08

인 설명력을 유지했다. MAE는 각각 평균 2.95 mΩ, 2.96 mΩ 수준으로 매우 낮았고, MAPE는 3.39%, 3.48%로 상대오차 기준에서도 모든 모델 중 가장 우수한 결과를 나타냈다. 특히 모든 Fold에서 MAPE가 6% 미만으로 유지되었고, XG는 Fold 1에서 R² = 0.999를 기록하는 등 예외적으로 높은 적합도를 보였다.

Cat은 평균 R² 0.950, MAE 9.31 mΩ, MAPE 11.9%로 앞선 두 모델보다는 다소 낮았으나, 여전히 비교적 안정적인 예측 성능을 보였다. Fold 3에서 MAE 14.1 mΩ, MAPE 18.6% 수준의 오차 증가가 관찰되었으나, Fold 4에서는 MAE가 5.62 mΩ로 줄어드는 등 Fold 간 편차를 일정 수준 내로 유지하였다.

LR은 구조가 단순함에도 불구하고 일부 Fold에서는 준수한 성능을 보였다. Fold 1, 4, 5에서 R²이 0.92 이상으로 나타났으며, 평균 R²은 0.714, HL estimator 기준으로는 0.762였다. 그러나 Fold 2와 3에서는 R²이 각각 0.139, 0.561에 그쳤고, MAE는 평균 16.6 mΩ, MAPE는 20.5%로 트리 기반 모델에 비해 예측 오차가 크게 나타났다. 특히 Fold 2와 3에서는 MAE가 28 mΩ 이상, MAPE는 30% 이상에 달하는 등 분할 방식에 따라 예측 성능이 민감하게 변동하였다. 이는

선형 회귀 모델이 SOC 5% 구간에서 나타나는 비선형적 패턴을 포착하기 어렵다는 구조적 한계를 반영한다.

MLP와 LSTM은 모든 지표에서 가장 낮은 성능을 기록하였다. MLP는 평균 R² 0.118, MAE 38.3 mΩ, MAPE 51.1%를 나타냈고, LSTM은 R² -0.128, MAE 50.6 mΩ, MAPE 63.8%로 예측 실패 수준의 결과를 보였다. Fold 간 편차도 매우 컸으며, 일부 Fold에서는 음의 R² 값이 나타나 회귀 모델로서의 설명력조차 확보하지 못하였다. 이는 입력 특성의 복잡도에 비해 학습 샘플 수가 부족하고, 모델 구조가 화성공정 데이터의 패턴을 효과적으로 학습하지 못했기 때문으로 해석된다.

요약하면, SOC 5% 조건에서의 예측 성능은 트리 기반 앙상블 모델이 가장 우수하며, 특히 XG와 RF는 낮은 오차와 높은 결정계수를 동시에 만족시키는 견고한 성능을 보여주었다. 반면, 신경망 기반 모델은 현재의 데이터 조건과 구조 하에서 예측 안정성을 확보하지 못하였으며, 성능 향상을 위해서는 모델 구조 개선이나 데이터 확장이 필요할 것으로 판단된다.

Fig. 3은 총 40개의 셀에 대해, RLS를 예측한 각 모델의 절대 오차 분포(단위: mΩ)를 박스플롯 형태로

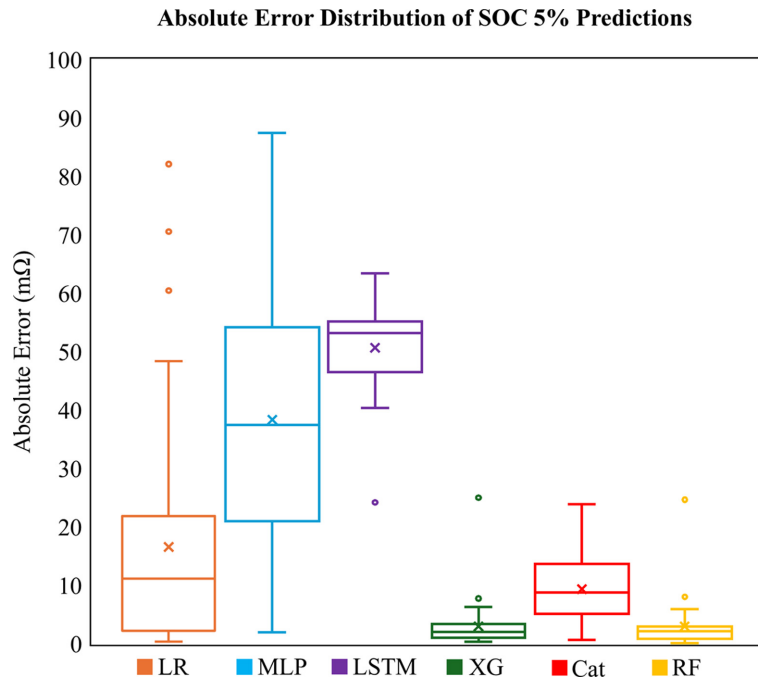


Fig. 3. Absolute error distribution of RLS predictions by model. Box plots show the prediction errors across all 40 cells, with outliers indicated as individual points.

시각화한 결과이다. 모든 셀을 개별적으로 평가한 예측 오차가 포함되어 있으며, 모델별 예측 안정성과 이상치(outlier) 발생 정도를 직관적으로 비교할 수 있도록 구성되었다.

XG와 RF는 40개 셀 전반에서 가장 낮고 안정적인 오차 분포를 보였다. 이들 모델은 대부분의 셀에서 절대 오차가 5 mΩ 미만에 수렴하며, 이상치가 거의 관찰되지 않았다. 특히 RF는 중앙값과 사분위 범위가 가장 작게 나타나, 전체 셀에 대해 일관된 성능을 유지하는 경향을 보였다.

Cat은 XG 및 RF에 비해 다소 높은 오차를 기록하였으나, 대부분의 셀에서 예측 오차가 20 mΩ 이내로 유지되었으며 전반적으로 안정적인 예측 품질을 나타냈다.

반면, MLP와 LSTM은 40개 셀 전체에 걸쳐 예측 오차의 분산이 매우 크게 나타났다. 특히 LSTM은 중앙값과 오차 범위가 모두 넓었고, 70 mΩ을 초과하는 이상치도 다수 포함되어 예측 성능이 불안정함을 보여주었다. MLP 역시 유사한 경향을 보였으며, 일부 셀에서는 80–90 mΩ에 달하는 큰 오차가 관찰되었다.

LR은 특정 셀에서는 낮은 오차를 기록했으나, 전체적으로 오차 편차가 크고 이상치 발생도 잦아 예측의 일관성과 신뢰도가 떨어지는 것으로 평가되었다.

이와 같이, Fig. 3은 트리 기반 모델들이 SOC 5%와 같은 초기 조건에서도 전 셀에 걸쳐 높은 예측 정확도와 일관성을 유지한 반면, 신경망 기반 모델은 셀 간 편차가 크고 예측 안정성이 낮은 경향을 보였음을 시각적으로 잘 보여준다.

Fig. 4는 RLS 예측 오차에 대해 모델 간 성능 차이를 비교한 Nemenyi 사후검정 결과를 히트맵 형태로 시각화한 것이다. 히트맵의 색상은 각 모델 쌍 간의 p-value 크기에 따라 농도 차로 표현되며, 짙은 파란색일수록 통계적으로 유의한 성능 차이($p < 0.05$)가 존재함을 나타낸다. 이를 통해 수치적 결과 뿐 아니라 시각적으로도 모델 간 차이를 직관적으로 확인할 수 있다.

먼저 Friedman test 결과, χ^2 통계량은 123.79($p < 1 \times 10^{-24}$)로, 여섯 개 모델 간의 성능 차이가 통계적으로 유의함을 확인하였다. 이어 수행된 Nemenyi 사후검정에서는 XG와 RF가 딥러닝 기반 모델인 MLP 및 LSTM과 매우 유의한 차이를 보였으며($p < 0.001$), 선형 회귀 모델인 LR과도 통계적으로 유의한 차이를 나타냈다($p = 0.016, 0.019$). 같은 트리 기반 회귀 모델인 Cat과의 비교에서도 XG와 RF는 각각 $p = 0.028, 0.033$ 으로, 일반적인 유의수준($p < 0.05$)을 만족하였다. 반면, XG와 RF 간에는 $p = 0.900$ 으로

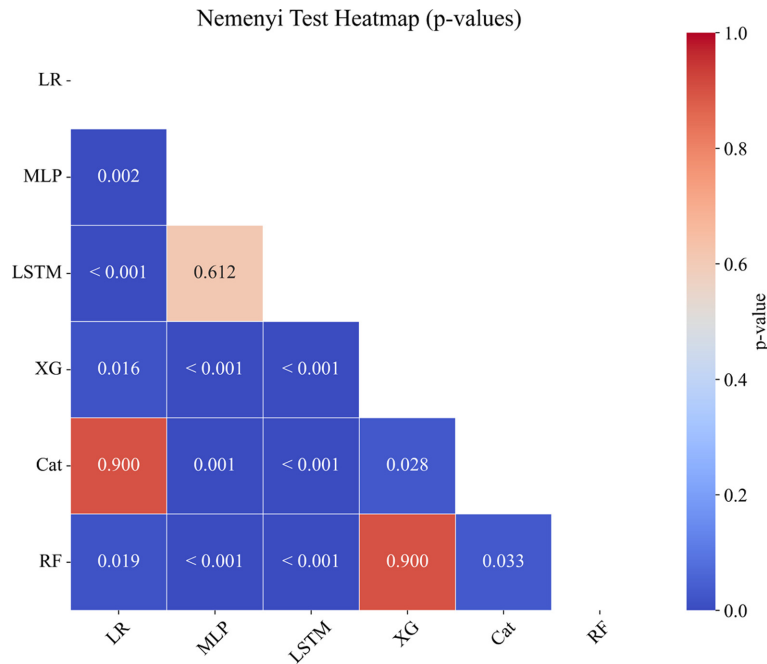


Fig. 4. Nemenyi post-hoc test results for pairwise model comparisons in RLS prediction. Darker blue indicates statistically significant differences ($p < 0.05$) between models.

유의한 차이가 없는 것으로 나타났다. 이러한 결과는 XG와 RF가 SOC 5% 구간의 예측 성능에서 다른 모델들에 비해 통계적으로 유의하게 우수함을 시사하며, 두 모델 간에는 성능 차이가 없다는 점도 함께 보여준다.

위와 같은 결과는 화성공정의 총·방전 데이터만으로도 HPPC 테스트를 대체할 수 있는 “가상 HPPC” 모델이 가능함을 보여준다. 기존 연구(Weng 등¹³)는 화성공정 완료 후 실제 HPPC 조건에서 측정한 RLS 값을 바탕으로, 해당 지표가 배터리의 수명과 강한 음의 상관관계를 가진다는 점을 보고한 바 있다. 본 연구는 이를 확장하여 HPPC 테스트 자체 없이 화성공정 데이터만으로 RLS를 3% 내외의 정밀도로 예측함으로써, 진단 없이도 수명 관련 지표를 조기에 확보할 수 있는 가능성을 입증하였다.

이러한 접근은 실제 제조 공정에 매우 실용적이다. 예를 들어, 화성공정 직후에 해당 모델을 적용함으로써 셀 품질을 비침습적으로 진단하고, RLS 기반 조기 선별을 통해 초기 불량 셀을 제거하거나 팩 구성 전략에 반영할 수 있다. 또한 예측된 내부저항 값을 초기 Battery Management System (BMS) 파라미터 설정에 활용하거나, 셀 그룹핑(grouping) 기준에 사용할 수 있는 가능성도 제시된다.^{22,23} 제조 라인에서의

실시간 적용을 염두에 둔다면, 별도의 진단 장비 없이도 주요 물리 지표를 확보할 수 있다는 점에서 생산성 향상과 비용 절감 효과도 크다.

다만 본 연구는 약 40개의 셀 데이터를 기반으로 하였으며, 특히 딥러닝 모델인 MLP와 LSTM에서 과적합 문제가 뚜렷하게 나타난 점은 데이터 규모의 한계를 보여준다. 또한 일부 구간(특히 저SOC 영역)에서는 예측 성능의 편차가 비교적 크게 나타났으며, Fig. 2에서 확인된 바와 같이 특정 모델에서는 SOC 5% 부근에서 일시적으로 오차가 급증하는 현상도 관찰되었다. 이러한 예측 불안정성은 제조 현장에서 RLS 기반 조기 진단 및 셀 분류의 신뢰도를 저하시킬 수 있으며, 특히 초기 불량 셀 선별이나 팩 구성 전략에 직접적인 영향을 미칠 수 있다.

향후 연구에서는 다양한 화성공정 조건과 셀 화학계에 대한 적용 가능성을 검토하여 모델의 범용성을 보다 정밀하게 평가할 필요가 있다. 더불어 저SOC와 같이 내부저항의 급격한 변화가 발생하는 구간에 대한 국소적 데이터 보강, 변화율($dR/dSOC$) 등 물리적 의미를 갖는 feature의 도입²⁴, residual learning²⁵ 또는 attention²⁶ 기반의 구조적 개선을 통해 예측 민감도를 향상시킬 수 있을 것이다. 아울러, 외부 검증셋 확보, transfer learning²⁷ 및 데이터 증강 기법²⁸

활용한 학습 일반화 전략도 병행함으로써, 제한된 샘플 환경에서도 안정적인 성능을 확보할 수 있는 예측 프레임워크 구축이 요구된다.

4. 결 론

본 연구에서는 리튬이온 배터리化成 공정 시점에서 수집된 시계열 데이터를 기반으로, HPPC 방식으로 측정되는 SOC별 내부저항 곡선을 정밀하게 예측하는 회귀 모델을 제안하고, 그 가능성을 실증하였다. 제안된 XG와 RF 기반 다중출력 회귀 모델은 전압·전류·용량 데이터만을 입력으로 사용하여, 별도의 펄스 진단 없이도 전 SOC 구간의 정적 저항 특성을 $m\Omega$ 수준의 오차로 재현할 수 있었다. 특히 수명 지표와 밀접하게 연관된 RLS도 평균 3% 내외의 상대 오차로 예측되었다. 이는化成 공정 데이터만으로 초기 수명 예측에 필요한 정보를 확보할 수 있음을 보여준다.

실험 결과, 트리 기반 회귀 모델이化成 공정 데이터를 이용한 내부저항 예측에 가장 효과적인 구조임을 확인하였으며, 이는 소규모 제조 데이터 환경에서도 고정밀 예측이 가능함을 시사한다. 이러한 접근은 실제 HPPC 테스트를 대체할 수 있는 가상 진단 기법으로 확장될 수 있으며, 제조 공정 중 실시간으로 셀 품질을 평가하고, BMS 입력 개선이나 셀 선별 기준 설정 등 다양한 응용으로 활용될 수 있다.

향후 연구로는 예측된 내부저항(RLS 포함)을 활용한 수명 예측 모델의 구축, 다양한 셀 화학계 및化成 공정 조건에 대한 확장 검증 등을 통해 본 기법의 범용성과 산업적 실효성을 더욱 강화할 수 있을 것이다.

Acknowledgments

이 연구는 2024년도 산업통상자원부 및 한국산업기술기획평가원(KEIT) 연구비 지원에 의한 연구임(RS-2024-00466528).

References

1. N. Collath, B. Tepe, S. Englberger, A. Jossen, and H. Hesse, Aging aware operation of lithium-ion battery energy storage systems: A review, *J. Energy Storage*, **55**, 105384 (2022).
2. S. R. Arsal, N. M. Nayan, M. A. Baharudin, M. S. Mohamed Ali, and M. F. M. Elias, Longevity of lithium-ion batteries in EV applications: Techno-economic and environmental impact considerations toward sustainability, *J. Energy Storage*, **131**, 117551 (2025).
3. I. T. Adebajo, M. A. Olutoye, S. M. Al-Salem, A. H. Al-Muhtaseb, and A. S. Al-Fatesh, A comprehensive review of lithium-ion battery components degradation and operational considerations: a safety perspective, *Energy Adv.*, **4**, 820-877 (2025).
4. K. A. Severson, P. M. Attia, N. Jin, N. Perkins, B. Jiang, Z. Yang, et al., Data-driven prediction of battery cycle life before capacity degradation, *Nat. Energy*, **4**(5), 383-391 (2019).
5. Almutairi, Z., Bheyan, H. A., Al-Ansary, H., & Eltamaly, A. M., Reducing Lithium-Ion Battery Testing Costs Through Strategic Sample Optimization, *Processes*, **13**(7), 2030 (2025).
6. Y. Preger, B. T. Glunz, A. Case, C. P. Gunning, A. M. Bloom, and E. J. Dufek, Degradation of commercial lithium-ion cells as a function of chemistry and cycling conditions, *J. Electrochem. Soc.*, **167**(12), 120532 (2020).
7. Hemavathi, S., Lithium-ion battery state of health estimation using intelligent methods, *Franklin Open*, **10**, 100237 (2025).
8. Chi Nguyen Van and Duy Ta Quang, Estimation of SoH and internal resistances of lithium-ion battery based on LSTM network, *Int. J. Electrochem. Sci.*, **18**(6), 100166 (2023).
9. Y. Liu, C. Liu, Y. Liu, and F. Sun, Review on degradation mechanism and health state estimation methods of lithium-ion batteries, *J. Traffic Transp. Eng.*, **11**(6), 1420-1446 (2024).
10. P. Ramadass, B. S. Haran, R. E. White, and B. N. Popov, Capacity fade of Sony 18650 cells cycled at elevated temperatures, *J. Power Sources*, **112**(2), 606-613 (2002).
11. T. T. Lou, W. G. Zhang, H. Y. Guo, and J. S. Wang, The internal resistance characteristics of lithium-ion battery based on HPPC method, *Adv. Mater. Res.*, **455**, 246-251 (2012).
12. J. Rhyu, J. Schaeffer, M. L. Li, X. Cui, W. C. Chueh, M. Z. Bazant, and R. D. Braatz, Systematic feature design for cycle life prediction of lithium-ion batteries during formation, *Joule*, **9**(1), 64-76 (2025).
13. A. Weng, P. Mohtat, P. M. Attia, V. Sulzer, S. Lee, G. L. Less, and A. G. Stefanopoulou, Predicting the impact of formation protocols on battery lifetime immediately after manufacturing, *Joule*, **5**(11), 2971-2992 (2021).
14. T. Chen and C. Guestrin, XGBoost: A scalable tree boosting system, Proc. 22nd ACM SIGKDD Int. Conf. Knowl. Discov. Data Min., pp. 785-794 (2016).
15. L. Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush, and A. Gulin, CatBoost: Unbiased boosting with categorical features, *Adv. Neural Inf. Process. Syst.*, **31**, 6638-6648 (2018).
16. L. Breiman, Random forests, *Mach. Learn.*, **45**(1), 5-32 (2001).
17. D. E. Rumelhart, G. E. Hinton, and R. J. Williams, Learning representations by back-propagating errors, *Nature*, **323**, 533-536 (1986).
18. S. Hochreiter and J. Schmidhuber, Long short-term memory, *Neural Comput.*, **9**(8), 1735 (1997).
19. T. O. Kvalseth, Cautionary note about R^2 , *Am. Stat.*,

- 39(4)**, 279–285 (1985).
20. R. Kohavi, A study of cross-validation and bootstrap for accuracy estimation and model selection, Proc. 14th Int. Joint Conf. Artif. Intell., pp. 1137–1143 (1995).
 21. J. L. Hodges Jr. and E. L. Lehmann, Estimation of location based on ranks, *Ann. Math. Statist.*, **34**, 598 (1963).
 22. Y. Preger, B. T. Glunz, A. Case, C. P. Gunning, A. M. Bloom, and E. J. Dufek, Degradation of commercial lithium-ion cells as a function of chemistry and cycling conditions, *J. Electrochem. Soc.*, **167(12)**, 120532 (2020).
 23. Pillai, P., Desai, S., Pattipati, K. R., & Balasingam, B. An Improved Approach to Estimate the Internal Resistance of a Battery, arXiv preprint arXiv:2505.06410 (2025).
 24. C. L. Wu, Z. G. Tang, H. Y. Wang, Z. Q. Tan, and C. F. Pan, “A discharging internal resistance dynamic model of lithium-ion batteries based on multiple influencing factors,” *J. Cent. South Univ.*, **31(2)**, 670–678 (2024).
 25. He, K., Zhang, X., Ren, S., and Sun, J. Deep residual learning for image recognition. Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), pp. 770–778 (2016).
 26. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. Attention is all you need. *Adv. Neural Inf. Process. Syst.*, **30**, 5998–6008 (2017).
 27. Weiss, K., Khoshgoftaar, T. M., and Wang, D. A survey of transfer learning. *J. Big Data*, **3(1)**, 9 (2016).
 28. Iwana, B. K. and Uchida, S. An empirical survey of data augmentation for time series classification with neural networks. *PLoS One*, **16(7)**, e0254841 (2021).