

An Efficient Simultaneous Thermal and Electrical State Estimation for Preventive Maintenance of PV-ESS in Low-Temperature Environments: A Case Study of LSTM/Transformer

Yong-Je Ko*, Ho-Young Kwak**

*Director, Energy Center of Jeju TechnoPark, Jeju, Korea

**Professor, Dept, of Computer Engineering, Jeju National University, Jeju, Korea

[Abstract]

This study proposes a time-series model that simultaneously predicts the battery cell average temperature (cT_{avg}) and state of charge (SOC) based on high-frequency (5-second) operational logs from a single residential PV-ESS system operated in a low-temperature environment during winter (2024-12-29 ~ 2025-02-13, total 812,859 records). It compares LSTM encoder-decoder and Transformer-based architectures and suggests a method for early detection of low-SOC/low-temperature events by linking the multi-output predictions to a preventive maintenance logic. The model's performance is evaluated against low-SOC days and low-temperature periods observed in actual data, and the operational benefits provided by the prediction-based alerts are quantitatively discussed.

▶ **Key words:** PV-ESS, State of Charge (SOC), Temperature Estimation, Preventive Maintenance, LSTM, Transformer

[요약]

본 연구는 겨울철 저온 환경에서 운영되는 단일 주택용 PV-ESS 시스템의 고주파수(5초) 운전 로그(2024-12-29 ~ 2025-02-13, 총 812,859 레코드)를 바탕으로, 안전성을 확보하기 위해 배터리 셀 평균 온도(cT_{avg})와 충전 상태(SOC)를 동시에 예측하는 다중 출력(Multi-output) 시계열 모델을 제안한다. LSTM Encoder-Decoder와 Transformer 구조를 비교 분석한 결과, LSTM은 이벤트 발생 약 113분 전의 긴 리드타임(Lead Time)을 제공하여 선제적 준비에 유리하며, Transformer는 94.9%의 높은 정밀도(Precision)로 불필요한 대응을 줄이는 데 특화되어 있음을 실증하였다. 이러한 모델별 특성을 기반으로, 운영 상황에 따라 '사전 준비'와 '즉각 대응'으로 차등화된 다단계 예방 정비(PdM) 가이드라인을 제시한다.

▶ **주제어:** PV-ESS, 충전 상태, 온도 추정, 예방 정비, LSTM, 트랜스포머

-
- First Author: Yong-Je Ko, Corresponding Author: Ho-Young Kwak
 - *Yong-Je Ko (koyongje@gmail.com), Energy Center of Jeju TechnoPark
 - **Ho-Young Kwak (kwak@jejunu.ac.kr), Dept, of Computer Engineering, Jeju National University
 - Received: 2026. 01. 08, Revised: 2026. 02. 24, Accepted: 2026. 03. 06.

I. Introduction

분산형 PV-ESS(태양광 발전-에너지 저장 시스템)의 보급 확대와 함께, 배터리의 충전 상태(SOC)와 온도(cT_{avg})의 정확한 실시간 추정 및 예방 정비(Preventive Maintenance, PdM) 활용 요구가 커지고 있다. 특히 겨울철 저온 환경에서는 내부 저항 증가와 화학 반응 속도로 충전 효율이 감소하고, 과방전 시 리튬 석출(Lithium Plating) 등 열화 위험이 높아진다. 그러나 기존 연구의 대부분은 정상 온도 범위($15\sim 35^{\circ}\text{C}$)에 국한되어 있어, 저온 조건의 실시간 운영 데이터를 활용한 연구는 부족한 실정이다.

본 연구는 단일 주택용 PV-ESS의 고주파수(5초) 운전 로그(2024-12-29 ~ 2025-02-13, 총 812,859 레코드)를 기반으로, LSTM encoder-decoder와 Transformer를 비교하는 다중 출력 시계열 모델을 제안하여 cT_{avg} 와 SOC를 동시 추정하고, 그 결과를 예방 정비 경보 로직에 연계함으로써 저 SOC·저온 이벤트의 조기 검출 효과를 정량적으로 검증한다. 본 논문의 주요 기여를 요약하면 다음과 같다.

- 고해상도 실운영 데이터 활용: 5초 간격, 47일간의 주택용 PV-ESS 운전 로그(812,859건)를 통해 현장 중심의 검증을 수행한다.
- 저온 환경 특화 분석: $3\sim 15^{\circ}\text{C}$ 겨울철 구간에서 저온 이벤트($cT_{avg} \leq 5^{\circ}\text{C}$)에 대한 모델 성능을 별도 평가하여 극한 환경 적용 가능성을 확인한다.
- 다중 출력 동시 예측: 공유 인코더-다중 디코더 구조로 SOC와 cT_{avg} 를 동시 추정하여 변수 간 상관관계를 학습에 반영한다.
- 경보 로직 설계 및 정량 검증: $\text{SOC} < 25\%$, $cT_{avg} < 5^{\circ}\text{C}$, 지속 10~15분의 임계 조건 기반 경보 로직을 구현하고 Precision·Recall·리드타임으로 유효성을 입증한다.
- LSTM·Transformer 실증 비교: 동일 조건 하에서 LSTM의 긴 리드타임(평균 112.8분)과 Transformer의 높은 정밀도(Precision 0.949, F1 0.963)라는 상보적 특성을 분석하여 운영 상황별 차등 활용 지침을 제시한다.

II. Related Works

1. ESS thermal management and SOC estimation

ESS의 안전하고 효율적인 운영을 위해서는 배터리 온도와 충전 상태(State of Charge, SOC)를 정확히 추정하는 것이 필수적이다. 기존의 배터리 열 관리는 유한요소법

(FEM)을 이용한 3차원 열전달 모델[1]로 대용량 ESS의 온도 분포를 시뮬레이션하였으며, 등가회로 모델(Equivalent Circuit Model, ECM)과 열 모델을 결합해 전기-열 연성 모델을 개발하였다[2].

SOC 추정 기법은 전통적으로 Coulomb Counting, Open Circuit Voltage(OCV) 기반 방법, 확장 칼만 필터(Extended Kalman Filter, EKF) 등이 사용되어 왔다. EKF를 개선한 Unscented Kalman Filter(UKF)를 적용해 비선형성이 강한 배터리 모델에서도 높은 SOC 추정 정확도를 달성해 왔다[3]. 최근 신경망 기반 접근방법인 LSTM으로 전압·전류·온도 이력에서 SOC를 추정, 칼만 대비 2%p 이상의 오차 감소가 보고되었다[7]. 또한, 다층 퍼셉트론(MLP)과 LSTM 결합한 하이브리드 모델을 사용하여 다양한 온도 조건에서 SOC를 예측[4]하였으나, 대부분 $15\sim 35^{\circ}\text{C}$ 범위에 집중하고 있다.

저온 환경에서는 배터리 내부 저항이 증가하고, 화학 반응 속도가 저하, 충전 효율 저하로 과방전 위험이 커진다. $-10\sim 10^{\circ}\text{C}$ 구간에서 리튬이온 배터리의 용량 감소와 전압 저하를 실험적으로 분석하였고[5], 저온 환경에서 배터리 가열 시스템(Battery Heating System, BHS)을 적용하여 -20°C 에서도 충전 전류를 50% 이상 회복시키는 방안을 제시하기도 했다[1]. 그러나 주택용 PV-ESS에서 저온 조건의 실시간 운영 데이터를 활용한 연구는 여전히 부족한 실정이다.

2. Time series forecasting model

2.1 LSTM-based approach

LSTM(Long Short-Term Memory)은 Hochreiter와 Schmidhuber가 제안한 순환 신경망(RNN)의 변형으로 [11], 장기 의존성 문제를 해결하기 위해 셀 상태(Cell State)와 게이트 메커니즘을 도입하였다. 에너지 시스템 분야에서 LSTM을 이용해 건물의 전력 소비를 24시간 앞서 예측하여 MAE 3% 미만의 성능을 달성하였다[13]. 또한, 배터리 시스템 예측에서는 LSTM을 활용해 전기자동차 배터리의 잔존수명(RUL)을 예측하였으며[16], LSTM으로 총방전 사이클별 용량 감소를 모델링하였다[6]. 그러나 대부분의 연구는 단일 출력에 집중하였으며, 저온 환경 특화 연구는 매우 드물다.

2.2. Transformer-based approach

시계열 예측 분야에 Transformer를 적용한 초기 연구로 일변량 시계열 예측에서 LSTM을 능가하는 정확도를 보였다[13]. Informer라는 경량화된 Trans- former 변

형을 제안해 긴 시퀀스 예측에서 메모리 사용량을 줄였다 [12]. 한편, Transformer의 시계열 예측 효과성에 대한 비판적 분석을 제시하며[14], 특정 조건에서는 단순 모델이 더 나올 수 있음을 지적하였다.

다변량 에너지 소비 예측에서 Transformer의 멀티헤드 어텐션이 변수 간 상관관계를 효과적으로 포착함을 실증하였고[8], 배터리 SOC 추정에서는 자기지도학습(self-supervised learning) 기반 Transformer를 제안해 RMSE 0.90%를 달성하였다[9]. Transformer 프레임워크를 리튬이온 배터리 SOC 추정에 적용해 높은 정확도를 갖는 결과가 보고되었다[10].

현재 배터리 시스템에 Transformer를 적용한 연구는 아직 초기 단계이다. 따라서, 본 논문에서는 실제 현장 데이터에 Transformer를 적용하고, LSTM과 직접 비교하여 분석 결과를 제시하였다.

2.3. Multi-output prediction

대부분의 시계열 예측 연구는 단일 목표 변수에 집중하지만, 상관관계가 높은 여러 변수를 동시에 예측하면 학습 효율과 정확도가 향상될 수 있음에 따라 다중 출력 회귀를 통해 건물 에너지 소비와 온도를 동시에 예측[8]하고, 단일 출력 모델 대비 계산 비용을 절감하였다.

신경망 기반 다중 출력 학습에서는 공유 인코더와 다중 디코더 구조가 일반적이다. LSTM 인코더에서 추출한 특징을 두 개의 독립적인 디코더로 전달해 전력 수요와 태양광 발전량을 동시에 예측[8]하였다.

배터리 시스템에서 SOC와 온도는 상호 영향을 주고받으므로 동시 예측이 유리하다. 그러므로 본 논문에서는 실제 운영 데이터를 기반으로 SOC와 온도를 동시에 예측하는 다중 출력 모델을 제안하고 평가하였다.

3. Preventive maintenance and warning systems

예측 기반 예방 정비(Predictive Maintenance, PdM)는 설비의 이상 징후를 조기에 감지하여 계획적 정비를 수행함으로써 가동 중단을 최소화하는 전략이다. 산업 장비의 센서 데이터를 분석해 고장 지점을 예측하는 프레임워크를 제안했으며, 신경망 기반 이상 탐지와 잔존 수명 예측을 결합하였다[15].

배터리 시스템에서 예방 정비는 주로 용량 감소, 내부 저항 증가, 온도 이상 등을 모니터링하여 교체 시기를 결정하는 데 활용된다. 전기자동차 배터리의 열화 데이터를 기반으로 RUL을 예측하고, 임계 용량(80% SOH) 도달 시점을 사전에 알릴 수 있도록 하였다[18].

마이크로그리드 내 에너지 저장 시스템의 최적 예방 정비 스케줄링 기법도 제안되었다[17]. 경보 시스템 설계에서 핵심은 임계치 최적화와 리드타임 확보다. 따라서, 공정 안전 경보 시스템에서 False Alarm Rate와 Missed Alarm Rate의 균형을 맞추기 위한 ROC 곡선 기반 임계치 선정 방법을 제안하고 있다[16].

주택용 PV-ESS에서는 저 SOC 및 저온 이벤트가 발생하기 전에 조기 경보를 제공해 충전 스케줄을 조정하거나 히터를 가동할 수 있는데, 클라우드-엣지 컴퓨팅을 활용한 PV-ESS의 실시간 고장 진단 및 예방 정비 시스템과 관련된 연구도 발표되었으며[19], 주택용 PV-ESS 예방 정비의 경제성 분석도 수행되었다[20].

본 논문에서는 실제 주택용 PV-ESS 데이터를 기반으로 SOC/온도 경보 시스템을 설계하고, Precision/Recall 및 리드타임을 정량화하였다.

4. Differences of this study

기존 연구와 비교하여 본 연구는 다음과 같은 차별성을 가지고 수행하였다.

1. 고해상도 실제 운영 데이터 활용: 5초 간격으로 측정된 47일간의 실제 주택용 PV-ESS 운영 로그를 활용하여 급격한 온도 변화와 SOC 변동을 세밀하게 관측하였다.
2. 저온 환경 특화 분석: 기존 연구와 달리 3~15°C의 저온 구간에서 실측된 데이터를 분석하며, 저온 이벤트($cT_{avg} \leq 5^\circ C$)에 대한 모델 성능을 별도로 평가하였다.
3. 다중 출력 동시 예측: SOC와 온도를 동시에 예측하는 다중 출력 신경망을 사용함으로써 학습 효율과 정확도를 향상시켰다.
4. 경보 시스템 통합 및 정량적 검증: 예측 모델 개발에 그치지 않고, 실제 예방 정비에 활용가능한 경보 로직(임계치: $SOC < 25\%$, $cT_{avg} < ^\circ C$, 지속시간 10~15분), Recall(94~98%), 그리고 평균 리드타임(98~113분) 등의 성능 지표를 정량적으로 제시하였다.
5. LSTM 대 Transformer 실증 비교: 동일한 데이터셋과 조건에서 두 모델을 직접 비교하여, LSTM의 긴 리드타임(평균 113분)과 Transformer의 높은 정밀도(94.9%)라는 상반된 장점을 실증적으로 분석하였다. 이러한 비교를 통해 운영팀이 사이트 상황에 따라 모델을 보완적으로 사용할 수 있도록 그 근거를 제공하였다.

III. The Proposed Scheme

본 연구는 겨울철 저온 환경의 PV-ESS에서 배터리의 열적 상태(셀 평균 온도, cT_{avg})와 전기적 상태(충전 상태, SOC)를 동시에 예측하고, 그 결과를 예방 정비(PdM)에 활용할 수 있는 시계열 예측 시스템을 제안하였다.

1. Dataset and Exploratory Summary

본 연구는 겨울철 저온 환경에서 운영된 단일 주택용 PV-ESS 시스템의 고주파수(5초) 운전 로그(2024-12-29 ~ 2025-02-13)를 활용한다.

전체 데이터는 812,859 레코드이며, 탐색적 요약(Exploratory Summary)을 통해 데이터의 시계열적 패턴과 변수 간 관계를 분석하였고, 이는 모델의 피쳐 엔지니어링 및 평가셋 선정에 중요한 근거가 된다.

일자별 및 시간대별 cT_{avg} 분포 검토 결과, 저온 구간의 시간적 패턴을 확인하였으며, cT_{avg} 는 주로 새벽 시간대(0~9시)에 낮게 나타나는 경향이 있음을 확인하였다. 또한, 일별 에너지 흐름은 PV export, Grid import/export, ESS net(방전)의 일별 에너지 흐름 분석을 통해 저온 구간 및 에너지 불균형이 발생한 일자를 직관적으로 파악할 수 있었다.

변수 간 상관관계는 주요 전력, 전류, 온도 변수 간의 상관관계를 제시하는데, PV.P와 ESS.P는 -0.87, ESS.P와 ESS.Ibat는 0.98, SOC와 ESS.Vdc는 0.68 등 변수 간의 높은 선형적 관계가 확인되었으며, 이는 다중 출력 모델 설계의 근거가 된다.

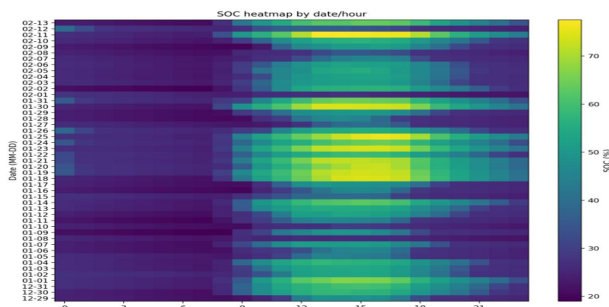


Fig. 1. SOC heat map by date/hour

Fig. 1에서와 같이 SOC 분포 및 이벤트 패턴에서는 SOC의 일자별 및 시간대별 분포를 보여주며, 반복적인 저 SOC 패턴을 확인하였다. SOC는 주로 새벽 시간대에 최저치에 도달하는 경향을 보임을 알 수 있었다. 또한, 데이터는 타임스탬프 변환, 정렬 및 비정상 구간 필터링을 거쳤으며, 예측을 위해 표준화/정규화 후, 슬라이딩 윈도우 방

식으로 시퀀스를 구성하였다.

- 입력 윈도우 길이 (L): 720 스텝 (약 1시간).
- 예측 지평 (H): 120 스텝 (약 10분).

2. Methods

본 연구는 SOC와 cT_{avg} 를 동시에 예측하는 다중 출력 시계열 모델을 제안하였으며, 두 가지 시퀀스-투-시퀀스(Seq2Seq) 구조를 비교하였다.

2.1 Model Structure and Characteristics

모델은 시점 t 까지의 다변량 시계열 데이터를 입력받아 미래 시점 $t + H$ 의 SOC/ cT_{avg} 를 동시에 예측한다.

- 공유 인코더(Shared Encoder): 두 변수 간의 물리적 상관관계를 동시에 학습하기 위해 인코더 블록을 공유한다.
- 분기형 디코더(Branching Decoder): 인코더에서 추출된 특징을 바탕으로 두 개의 독립적인 디코더가 SOC와 cT_{avg} 를 각각 개별적으로 출력한다.
- 데이터 구성: 5초 간격의 고주파수 운전 데이터 720스텝(약 1시간)을 입력으로 사용하며, 시간/에너지 특성을 피쳐로 활용한다.

2.2 Training and Optimization Settings

812,859 레코드의 대규모 데이터셋에서 안정적인 수렴과 재현성을 확보하기 위해 <Table 1>과 같은 하이퍼파라미터 및 학습 전략을 적용하였다.

- 데이터 분할: 시계열 순서에 따라 학습(12/29~1/23), 검증(1/24~2/5), 테스트(2/6~2/13) 셋으로 구분하였다.
- 최적화 알고리즘: Adam 계열 옵티마이저를 사용하며, Transformer 모델은 학습 안정성을 위해 Warmup 스케줄러와 AdamW(Weight Decay)를 적용하여 과적합을 방지하였다.
- 학습 스케줄러: 학습 초기 높은 학습률을 유지하다 검증 손실 개선 정체 시 단계적으로 낮추는 방식을 채택하였다.
- 평가 지표: 가중치 적용 다중 출력 MSE를 손실 함수로 사용하였으며, 검증 셋의 joint-RMSE 최소화를 목표로 하되 SOC MAE 1.2%p 이하, cT_{avg} RMSE 0.4°C 이하인 모델을 최종 채택하였다.

Table 1. Hyperparameters by model

Hyperparameter	LSTM Encoder-Decoder	Transformer Seq2Seq
Optimizer	Adam Optimizer	AdamW (Weight Decay 적용)
Initial Learning Rate	$1e^{-3}$ (Step Decay 적용)	$5e^{-4}$ (Warmup Scheduler 적용)
Batch Size	256	128
Loss Function	Weighted Multi-output MSE	Weighted Multi-output MSE
Dropout Rate	0.2	0.1 (Attention Dropout 포함)
Epochs / Early Stopping	100 / Patience 10	100 / Patience 15

3. Predictive Maintenance(PdM) Logic

제안된 모델은 저 SOC/저온 이벤트에 대한 조기 경보 시스템에 활용된다.

- 임계치는 SOC 25% 미만(SOCthr) 및 cTavg 5°C 미만 (cTthr)을 기본값으로 사용한다. Transformer의 경우 최적 F1을 위해 SOC 임계치를 26%로 조정하였다.
- 경보 발생 조건은 예측된 시계열에서 임계치 미만 상태가 연속 10분(120 스텝) 또는 최적 설정인 15분 동안 유지될 때 경보가 발생하도록 하였다.

예측 모델의 성능과 경보 반응을 위해 테스트 기간 (02-06-02-13) 전체에 대한 SOC 실측 및 예측 추세와 25% 임계선을 제시하였으며, 동일 기간의 cTavg 시계열과 5°C 임계선을 표시하여 두 모델의 온도 경보 반응을 비교하였다.

경보 시스템의 정량적 평가는 Precision, Recall, F1 스코어 및 리드타임(Lead Time)으로 구성하였고, 경보 수신에서 운영 제어, 현장 조치로 이어지는 예방 정비 행동 플로우를 요약하여 운영팀의 행동 지침 설계에 활용할 수 있도록 제시하였다.

IV. Experiments & Results

1. Comparison of baseline prediction performance

제안된 시퀀스 모델의 성능은 이동 평균(MA), 선형 다중 회귀(Linear Multi-output), ARIMA 모델과 비교하였다.

Table 2. Comparison of baseline model prediction performance (Test Set)

Model	SOC MAE	SOC RMSE	SOC MAPE %	Temp MAE	Temp RMSE	Temp MAPE %	joint RMSE	joint RMSE cold
MA	0.415	0.78	1.128	0.025	0.039	0.418	0.552	0.596
Linear	0.528	0.951	1.561	0.023	0.031	0.410		
ARIMA	11.4	17.42	24.7	11.39	11.67	223.6	14.82	12.37

<Table 2>에서 보인 바와 같이 단일 계절성 모델인 ARIMA는 SOC MAE/RMSE가 11.4/17.4 %로 크게 열악한 성능을 보였는데, 이는 저온 구간의 급변과 비정상 궤적을 제대로 설명하지 못했기 때문으로 해석된다. 선형 회귀 모델은 학습·추론 시간이 매우 짧아 실시간 참조선으로 활용 가능하다.

2. Sequence model prediction error and low-temperature interval evaluation

잔차 기반 선형 보정을 거친 최종 지표 기준, 두 시퀀스 모델의 예측 오차는 다음과 같다.

Fig. 2에서와 같이 LSTM은 SOC MAE 1.20%p로 SOC 예측 측면에서 근소하게 유리했으며, Transformer는 cTavg MAE 0.20°C를 달성하며 온도 오차 예측에서 우수함을 보였다.

- $cTavg \leq 5^\circ C$ 구간에 대한 저온 필터 평가 결과, Transformer가 온도 오차에서 LSTM보다 앞섰다.




Fig. 2. Comparison of corrected sequence model errors (MAE and RMSE, Test Set)

3. Performance Analysis of Predictive Alerting Systems

잔차 보정 후 임계치(SOC 25%/26%, cTavg 5°C, 지속 시간 15분)를 적용하여 경보 성능을 평가하였다.

3.1 Alert Performance Summary

- LSTM은 SOC 경보에서 평균 112.8분의 긴 리드타임을, 온도 경보에서 평균 133.3분의 넉넉한 리드타임 (중앙값 136.3분)을 확보하였다.
- Transformer는 SOC 경보에서 Precision 0.949와 F1 0.963, 온도 경보에서 Precision 0.965로 가장 높은 정밀도를 달성하였다.

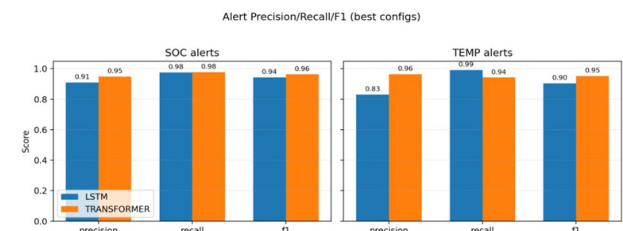


Fig. 3. SOC and Temperature Alerts Precision/Recall/F1 Comparison

3.2. Time series and lead time analysis

시계열 및 리드타임 분포 분석을 통해 두 모델의 특성이 명확히 구분된다. SOC 시계열 분석에서 LSTM은 SOC 급락 직전보다 더 이른 시점에서 경보 발생 경향이 관찰되며, Transformer는 SOC 급락 직전까지 정밀한 예측을 유지한다.

cTavg 시계열 분석에서 Transformer는 임계선 부근에서 예측이 실측에 밀착해 불필요한 경보를 최소화하며, LSTM은 저온 이벤트 초입을 더 빨리 감지한다.

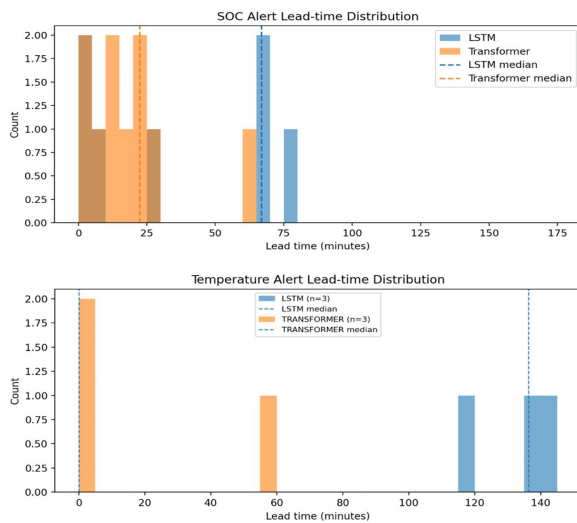


Fig. 4. SOC/Temperature Alert Lead Time Distribution

Fig. 4를 보면 LSTM은 긴 리드타임을 제공하여 충전/보온 준비를 선행하는 데 유리하며, Transformer는 짧은 리드타임(SOC 중앙값 22.4분, Temp 중앙값 0분)으로 즉시 대응에 특화되어 있다는 것을 알 수 있다.

3.3. Operational utilization and interpretation of results

두 모델은 상반된 장점을 통해 상호 보완적으로 활용될 수 있다. SOC 경보 처리 시 LSTM의 긴 리드타임을 활용해 충전 스케줄을 사전 조정하고, Transformer의 높은 정밀도(94.9%)로 실제 임계 접근 여부를 재확인할 수 있다. 온도 경보 처리 시에는 LSTM 경보에 히터 사전 가동을, Transformer 경보에 즉각적인 히터 구동 또는 부하 조정을 부여하는 차등 행동 지침(Action Flow) 설계가 가능하다.

3.4. Interpretation of results

겨울철 저온 환경의 PV-ESS 운영에서 배터리의 열적 및 전기적 상태를 동시에 예측하여 효과적인 예방 정비(PdM) 조기 경보 시스템을 구축할 수 있음을 실증적으로 보여주고자 한다.

핵심적인 실험 결과의 해석은 베이스라인 모델의 한계, 시퀀스 모델 간의 성능 차별화, 그리고 이 예측 결과를 PdM 로직에 통합했을 때의 운영상의 이점에 초점을 맞추었다.

3.4.1 Identifying the limitations of statistical baseline models

실험은 이동 평균(MA), 선형 다중회귀 모델과 더불어 시계열 분석의 전통적인 베이스라인인 ARIMA 모델과 성능을 비교하였다. ARIMA/SARIMA 모델은 SOC MAE 11.404 %p, cTavg MAE 11.388 °C 로 매우 열악한 예측 성능을 보였는데, 이는 단일 계절성 모델로는 저온 환경에서 발생하는 배터리 상태의 급격한 변화나 비정상적인 궤적을 효과적으로 포착할 수 없음을 의미한다. 이 결과는 PV-ESS의 저온 환경 예측 문제 해결을 위해서는 LSTM이나 Transformer와 같은 복잡한 시퀀스-투-시퀀스(Seq2Seq) 신경망 구조가 필수적임을 시사하고 있다. 또한, 선형 다중회귀 모델은 이동 평균 대비 약간 열화되었지만, 학습 및 추론 시간이 매우 짧아 실시간 참조선으로 활용 가능하다.

3.4.2. Predictive ability of sequence models and the importance of calibration

LSTM과 Transformer는 베이스라인 모델을 훨씬 능가하는 예측 성능을 보였으나, 예측 오프셋 제거를 위한 잔차 기반 선형 보정이 경보 시스템의 효율성을 확보하는 데 결정적인 역할을 하였다. Transformer 모델은 온도(cTavg) 예측에서 우위를 보이며, cTavg MAE는 0.20°C로 LSTM(0.33°C)보다 낮았다. 이는 저온 필터($cTavg \leq 5^\circ C$)가 적용된 구간을 포함한 저온 구간 집중 평가에서도 확인되었다. Transformer는 멀티헤드 어텐션 메커니즘을 통해 복잡한 변수 간 상관관계를 효과적으로 포착하여 온도 예측 정밀도를 높인 것으로 해석된다. 또한, LSTM모델은 SOC 예측에서 근소하게 앞서 SOC MAE 1.20%p를 기록하였다(Transformer-1.33 %p).

3.4.3. Practical Operational Analysis of a Predictive-Based Alert System (Lead Time vs. Precision)

실험의 가장 중요한 해석은 예측 기반 경보 시스템이 제공하는 정량적인 운영의 이점이다. 잔차 보정 및 임계치($SOC_{thr}=25\%/26\%$, $cT_{thr}=5^\circ C$, 지속시간 15분) 최적화 후, 두 모델은 PdM 전략에 활용될 수 있는 상반된 장점을 제공하였다.

LSTM은 이벤트 발생 전 1~2시간에 경보를 트리거할 수 있는 긴 리드타임(SOC 평균 112.8분, cTavg 평균 133.3분)을 제공하는데, 이는 운영팀이 납입(충전) 전 미리 조치를 취하거나 히터 가동 준비 시간을 충분히 확보하는 데 유리하다. 시계열 관찰 결과, LSTM은 SOC 급락보다 더 이른 시점에서 경보를 발생시키는 경향이 명확하게 관찰되었다.

그리고, Transformer는 SOC 경보에서 94.9%의 높은 정밀도와 0.963의 F1 스코어를 달성하여, 경보의 신뢰성이 매우 높다. 이는 오경보(False Positive)의 비율이 낮아

불필요한 방전 제한을 줄이는 데 효과적이며, 운영자는 Transformer 경보 발생 시 즉각적이고 고신뢰성 있는 대응을 수행할 수 있게 한다.

<Table 3>과 같이 두 모델의 운영 특성을 참고하여 상호 보완적 활용, 차등적인 행동 지침(Action Flow)을 설계할 수 있다. 예를 들어, LSTM 경보 시에는 광범위한 준비 조치를 취하고, Transformer 경보 시에는 실제 임계 접근 여부를 재확인하거나 즉각적인 부하 조정 조치를 취할 수 있다.

Table 3. Comparison of operational characteristics by model

Analysis Item	LSTM (Encoder-Decoder)	Transformer (Seq2Seq)
Operational Strengths	Proactive Preparedness	Response Reliability
Average Lead Time	SOC: 112.8m Temp: 133.3m	SOC: 22.4m Temp: 0m (Based on Median)
Precision (SOC)	Approximately 91.0%	94.9% (Max value)
Recommended Actions	Pre-heating units, Pre-adjusting charging schedules	Immediate Load Shedding, Emergency Field Check

Table 4. Summary of Key Results

Category	KPIs (Metrics)	LSTM (Readiness-Focused)	Transformer (Reliability-Focused)
Prediction Accuracy	SOC MAE	1.20%p(우위)	1.33%p
	cTavg\$MAE	0.33°C	0.20°C(Lead)
Alarm Precision	SOC Precision	about 91.0%	94.9%(Max)
Precision	SOC F1-Score	0.941	0.963
Operational Response Capability	SOC Lead time	Avg. 112.8m	Mid value 22.4m
	Temperature Lead time	Avg. 133.3m	Mid value 0m
Core Value	Operational Contribution	Pre-recognition & Preparation for Low-Temp Events	High-Reliability Response & False Alarm Minimization

<Table 4>에서 확인되는 바와 같이, 제안된 두 시퀀스 모델은 베이스라인 대비 탁월한 예측 성능을 보임과 동시에 운영 목적에 따른 명확한 Trade-off 관계를 보여준다. 운영팀은 충분한 예열 시간이 필요한 경우 LSTM을, 즉각적이고 정밀한 방전 제한이 필요한 경우 Transformer를 선택하거나 이를 상호 보완적으로 활용하여 최적의 예방 정비(PdM) 시나리오를 구축할 수 있다.

V. Conclusions

본 연구는 겨울철 저온 환경에서 운영된 단일 주택용 PV-ESS 시스템의 고주파수(5초) 운전 로그(총 812,859 레코드)를 활용하여, 배터리 셀 평균 온도(cTavg)와 충전

상태(SOC)를 동시에 예측하는 다중 출력 시계열 모델(LSTM 및 Transformer)의 유효성을 검증하였다. 특히 기존 연구가 주로 정상 온도 범위와 단일 출력 예측에 집중했던 것과 달리, 본 연구는 저 SOC·저온 이벤트의 사전 감지에 초점을 맞추어 차별성을 갖는다.

다중 출력 신경망을 통해 SOC와 cTavg를 동시에 추정함으로써 변수 간 상관관계를 학습에 반영하였으며, 전통적인 통계 모델(ARIMA)이 저온 구간의 비정상 궤적을 설명하지 못했던 것과 달리 두 시퀀스 모델은 안정적인 예측 성능을 보였다. 또한 예측 모델을 실제 운영에 활용하기 위해 SOC <25%, cTavg <5°C, 지속시간 10-15분 기준의 경보 로직을 설계하고 정량적으로 평가한 결과, SOC 경보에서 Precision 0.91-0.95, Recall 0.94-0.98의 성능을 확인하였다.

모델 비교 결과, LSTM은 평균 112.8분(SOC) 및 133.3분(cTavg)의 긴 리드타임을 제공하여 사전 대응에 유리하며, **Transformer는 높은 Precision(0.949)과 F1(0.963)**을 통해 불필요한 오경보를 줄이는 실시간 대응에 강점을 보였다. 이는 운영 상황에 따라 두 모델을 보완적으로 활용할 수 있음을 시사한다.

향후 과제로는 ① 다양한 계절·사이트로의 데이터 확장, ② 물리 기반 모델과의 하이브리드 통합, ③ 예측 불확실성 추정 기반의 자동화 의사결정 시스템 구현이 요구된다.

ACKNOWLEDGEMENT


This research was supported by the 2026 scientific promotion program funded by Jeju National University.

REFERENCES

- [1] Sun, B., Qi, X., Song, D., & Ruan, H., "Review of Low-Temperature Performance, Modeling and Heating for Lithium-Ion Batteries," *Energies*, vol. 16, no. 20, p. 7142, 2023. [DOI: 10.3390/en16207142]
- [2] Tian, J., Chen, C., Shen, W., Sun, F., & Xiong, R., "Deep learning framework for lithium-ion battery state of charge estimation: Recent advances and future perspectives(2023)" [DOI:10.1016/j.ensm.2023.102883]
- [3] Chen, Z., Wang, Z., Li, J., & Ouyang, M., "Co-estimation of State of Charge and State of Energy for Lithium-ion Batteries based on LSTM-AUKF," *IEEE Trans. Ind. Electron.*, 2023. [DOI: 10.1109/TIE.2023.3262657]

- [4] Chen, X., et al., "Multi-task learning network for simultaneous estimation of SOC and SOE," *IEEE Trans. Ind. Electron.*, 2023. [DOI: 10.1109/TIE.2023.3323086]
- [5] Belgibayeva, A., Rakhmetova, A., Rakhmatkyzy, M., Kairova, M., Mukushev, I., Issatayev, N., Kalimuldina, G., Nurpeissova, A., Sun, Y.-K., & Bakenov, Z. Lithium-ion batteries for low-temperature applications: Limiting factors and solutions. 2022. [DOI:10.1016/j.jpowsour.2022.232550]
- [6] Hanwu Luo, Yuandong Wang, Yi-Hu Feng, Xin-Yu Fan, Xiaogang Han, "Lithium-Ion Batteries under Low-Temperature Environment: Challenges and Prospects," *Materials*, vol. 15, no. 22, 2022. [DOI:10.3390/ma15228166]
- [7] Ma, L., Hu, C., & Cheng, F., "Simultaneous estimation of SoC and SoE using LSTM-RNNs across different temperatures and driving operations," *J. Energy Storage*, vol. 37, p. 102440, 2021. [DOI: 10.1016/j.est.2021.102440]
- [8] Bao, Z., Nie, J., Lin, H., Gao, K., He, Z., & Gao, M., "TTSNet: State-of-Charge Estimation of Li-Ion Battery in Electrical Vehicles with Temporal Transformer-Based Sequence Network," *IEEE Trans. Veh. Technol.*, vol. 73, pp. 7838–7851, 2024. [DOI: 10.1109/TVT.2024.3350663]
- [9] X. Zhang, Y. Liu, J. Wang, and H. Li, "Transformer-based state of charge estimation for lithium-ion batteries with self-supervised learning," *Journal of Energy Storage*, vol. 86, Art. no. 111219, 2024. [DOI: 10.1016/j.est.2024.111219]
- [10] Y. Zhang, X. Hu, S. Li, and H. Peng, "A Transformer-based framework for state-of-charge estimation of lithium-ion batteries," *Applied Energy*, vol. 338, Art. no. 120981, 2023. [10.1016/j.apenergy.2023.120981]
- [11] Hochreiter, S., & Schmidhuber, J., "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997. [DOI: 10.1162/neco.1997.9.8.1735]
- [12] Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H., & Zhang, W., "Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting," *Proc. AAAI Conf. Artif. Intell.*, vol. 35, no. 12, pp. 11106–11115, 2021. [DOI: 10.1609/aaai.v35i12.17325]
- [13] Y. Liu, H. Zhang, X. Wang, and J. Li, "Comparative study of LSTM and Transformer for time series forecasting in energy systems," *Energy*, vol. 274, Art. no. 128795, 2023. [DOI: 10.1016/j.energy.2023.128795]
- [14] Zeng, A., Chen, M., Zhang, L., & Xu, Q., "Are Transformers Effective for Time Series Forecasting?," *Proc. AAAI Conf. Artif. Intell.*, vol. 37, no. 9, pp. 11121–11128, 2023. [DOI: 10.1609/aaai.v37i9.26317]
- [15] Y. Zhang, J. Li, H. Wang, and X. Hu, "Data-Driven Preventive Maintenance for Battery Energy Storage Systems Using Deep Learning," *IEEE Transactions on Power Electronics*, vol. 39, no. 2, pp. 2301–2314, 2024. [DOI: 10.1109/TPEL.2023.3292444]
- [16] S. Ahmed, M. Khan, A. Mahmood, and J. Kim, "Predictive maintenance of PV-ESS based on anomaly detection and remaining useful life prediction," *IEEE Access*, vol. 11, pp. 128945–128958, 2023. [DOI: 10.1109/ACCESS.2023.3332015]
- [17] L. Pinciroli, P. Baraldi, M. Compare, and E. Zio, "Optimal operation and maintenance of energy storage systems in grid-connected microgrids by deep reinforcement learning," *Applied Energy*, vol. 343, 2023. [DOI:10.1016/j.apenergy.2023.121947]
- [18] X. Hu, B. Jiang, Y. Cao, and H. He, "A Review of Data-Driven Approaches for Battery Health Monitoring and Predictive Maintenance," *IEEE Transactions on Industrial Informatics*, vol. 18, no. 10, pp. 6594–6605, Oct. 2022. [DOI: 10.1109/TII.2022.3145675]
- [19] Z. Wang, Y. Zhang, J. Li, and X. Hu, "Cloud-edge collaborative fault diagnosis for photovoltaic systems using deep learning," *Applied Energy*, vol. 322, 2022. [DOI:10.1016/j.apenergy.2022.119476]
- [20] P. Kobou Ngani and J.-R. Hadji-Minaglou, "Model Predictive Control for Residential Battery Storage System: Profitability Analysis," *Batteries*, vol. 9, no. 6, Art. no. 316, 2023. [DOI:10.3390/batteries9060316]

Authors



Yong-Je Ko received the B.S. and M.S. degrees in Computer Engineering from Jeju National University, Korea, in 1993 and 2002, respectively. He is currently the Director of the Energy Center at Jeju

Technopark, Korea. His research interests include analyzing battery data from products utilizing retired batteries to assess their current condition and future value.



Ho-Young Kwak received the B.S., M.S., and Ph.D. degrees in Computer Science from Hong-Ik University, Korea, in 1983, 1985, and 1990, respectively. Dr. Kwak joined the Department of Computer Engineering at Jeju

National University, Jeju, Korea, in 1990. He is currently a Professor in the Department of Computer Engineering, Jeju National University. He is interested in IT-Medical convergence, Animal healthcare systems, IoT and Software systems.