

Trend-Seasonal 분해를 적용한 Transformer 기반 전기차 배터리 SoH 예측

천유림, 윤유정, 변예린, 임완수*

성균관대학교 전자전기컴퓨터공학과

*wansu.lim@skku.edu

State of Health Prediction for EV Batteries Using a Trend-Seasonal Decomposed Transformer

Yurim Cheon, Youjeong Yoon, Yerin Byeon, Wansu Lim

Sungkyunkwan University

요약

본 논문은 전기차 배터리의 상태지수(State of Health, SoH) 예측 정확도를 향상시키기 위해 시계열 분해 기반 Transformer 모델을 제안하였다. 제안 모델은 Autoformer의 이동평균 기반 시계열 분해 기법을 적용하여 배터리 열화 신호를 추세(Trend) 성분과 주기적(Seasonal) 성분으로 분리한 후, 각 성분을 Transformer 인코더를 통해 독립적으로 학습하고, 이를 재조합하여 최종 SoH를 예측하도록 설계하였다. 모델 학습에는 미국 메릴랜드 대학교 CALCE 센터의 CS2 계열 배터리 실험 데이터를 활용하였으며, 내부저항과 CCCT(Constant Current Charging Time) 측정 데이터를 입력 피처로 사용하였다. 실험 결과, 제안 모델은 배터리 열화 특성을 효과적으로 반영하여 기존 방법 대비 RMSE와 MAE 지표에서 우수한 성능을 나타내었다.

I. 서론

전기차 배터리의 SoH 예측은 배터리의 안정성과 수명 관리를 위해 중요한 기술이다[1]. 기존에는 RNN, LSTM 등 순환 신경망 기반의 모델이 주로 사용되었으며, 최근에는 transformer 계열의 모델이 시계열 데이터의 장기 의존성을 효과적으로 학습할 수 있어 활용이 확대되고 있다. 특히 Autoformer는 시계열 데이터를 추세 성분과 주기적 성분으로 분해한 후 각각을 독립적으로 학습함으로써 예측 정확도를 향상시키는 구조로 주목받고 있다[2-3].

본 연구는 시계열 분해 기반 예측 구조를 전기차 배터리 SoH 문제에 적용하고, 추세 성분과 주기적 성분의 특성을 분리 학습하는 transformer 모델을 제안한다. 시계열 데이터를 입력으로 받아 추세 성분과 주기적 성분을 분리하고 각각을 transformer로 학습한 후 재조합하여 최종 SoH를 예측한다. 제안하는 모델은 배터리 열화 특성에 적합한 학습 구조를 갖추고 있으며, 실험을 통해 예측 성능의 우수성을 확인한다.

II. 본론

2.1 데이터셋

본 연구에서는 전기차 배터리 SoH 예측 모델의 성능을 검증하기 위해 미국 메릴랜드 대학교의 CALCE(Computer-Aided Life Cycle Engineering) 센터에서 공개한 배터리 열화 실험 데이터를 활용하였다. 사용된 데이터셋은 CS2 실험군 중 CS2_35, CS2_36, CS2_37, CS2_38의 총 네 개 시리즈로 구성되며, 각각 동일한 초기 상태에서 반복적인 충·방전 조건 하에서 측정된 시계열 데이터를 포함한다. 이 데이터셋은 다양한 열화 조건에서 배터리의 전압, 전류, 온도, 내부저항 등의 특성을 측정된 결과를 제공하며, 실험정에 가까운 배터리 열화 양상을 반영하고 있어

SoH 예측 모델의 학습 및 검증에 적합하다.

특히 본 연구에서는 데이터셋 내 CCCT 측정값을 기반으로 하였으며, 입력 피처로는 배터리의 내부저항과 CCCT 구간에서 수집된 주요 변수를 활용하였다. SoH는 초기 용량 대비 현재 용량의 비로 정의하고, 각 사이클마다 계산된 SoH를 회귀 모델의 학습 타겟으로 설정하였다. 또한 다양한 환경 조건에서 전압, 전류, 온도, 내부저항 등을 종합적으로 반영하여 기초 데이터를 구축함으로써 모델의 일반화 성능을 강화하였다.

2.2 전처리

CALCE 데이터는 실험 환경에서 얻어진 raw 데이터이기 때문에, 시계열 분석 모델에 직접 적용하기에는 시간축 간격이 불균일하고 일부 데이터가 누락되어 있는 문제가 존재한다. 이를 해결하기 위해 본 연구에서는 큐빅 스플라인 보간법(Cubic Spline Interpolation)을 활용하여 시간축 기준으로 데이터를 균등하게 보간하였다. 큐빅 스플라인 보간법은 각 데이터 구간을 3차 다항식으로 근사하여 전체 시계열을 부드럽게 이어주는 방식으로, 급격한 값의 변화를 방지하면서 연속성을 유지할 수 있는 장점을 가진다.

보간된 시계열 데이터는 고정된 입력 시퀀스 길이를 갖도록 윈도우 슬라이딩을 적용하였으며, 학습 데이터와 테스트 데이터는 시계열 순서를 유지한 채 비율로 분할하였다. 데이터 전처리 과정에서는 단순한 노이즈 제거에 그치지 않고, 시계열의 장기적 경향과 단기 변동성을 보존하기 위한 특수 필터링 기법을 적용하였다. 이 과정은 후속 Transformer 모델이 학습 시 불필요한 잡음을 줄이고, 실제 배터리의 열화 패턴을 더욱 정밀하게 학습할 수 있도록 돕는다. 나아가, 기존의 평균화 방식이 갖는 한계를 극복하여 세밀한 SoH 변화 추이를 반영하는 데 더욱 유리하도록 설계하였다.




그림 1. 제안한 모델 구조

2.3 모델 구조

제안하는 모델은 Transformer 기반의 시계열 예측 프레임워크이다. 입력 시계열 데이터를 추세 성분과 주기적 성분으로 분해한 후, 각 성분을 Transformer 인코더를 통해 독립적으로 학습하고 결과를 통합하여 최종 SoH를 예측한다.

우선, 입력 시계열 X 에 대해 Autoformer에서 제안된 이동평균(Moving Average) 기반 시계열 분해 기법을 적용하였다. 이를 통해 전체 신호는 장기적인 추세 성분과 단기적 주기 성분으로 구분되며, 수식적으로는 다음과 같이 표현된다.

$$X_t = \text{AvgPool}(\text{Padding}(X)) \quad (1)$$

$$X_s = X - X_t \quad (2)$$

이러한 분해 과정을 통해 모델은 배터리 열화의 추세 성분과 주기적 성분을 분리하여 학습할 수 있다. 분리된 각 성분은 Transformer 인코더 내의 멀티헤드 Self-Attention 모듈을 통해 시점 간의 장기 의존성을 학습하며, 이를 통해 비선형적 열화 패턴과 반복적 충·방전 변동성을 동시에 반영할 수 있다.

특히 추세 성분 학습은 배터리의 장기 열화 경향을 안정적으로 포착하는 데 기여하고, 주기 성분 학습은 충·방전 과정에서 나타나는 단기 변동성을

효과적으로 반영한다. 또한 Positional Encoding은 시계열 특성을 보존하여 시간 축 정보를 유지하고, Self-Attention은 두 성분 간 상관관계를 정밀하게 학습하도록 돕는다. 이러한 과정은 기존 RNN/LSTM 기반 모델이 가지는 장기 의존성 학습의 한계를 극복하고, Autoformer 기반 구조의 장점을 그대로 살려 잡음 억제와 예측 안정성 향상에 기여한다.

모델 학습에는 평균제곱오차(Mean Squared Error, MSE)를 손실 함수로 사용하였으며, Adam optimizer를 통해 파라미터를 최적화하였다. 또한 학습의 안정성을 확보하기 위해 학습률 조정(Learning Rate Scheduler)과 Early Stopping 기법을 병행하여 과적합을 방지하였다. 모델의 성능 평가는 RMSE(Root Mean Squared Error)와 MAE(Mean Absolute Error) 지표를 활용하여 정량적으로 분석하였다.

III. 결론

본 논문은 전기차 배터리 SoH 예측의 정확도 향상을 위해 시계열 분해 기반 transformer 모델을 제안하였다. 제안 모델은 Autoformer의 이동평균 기반 시계열 분해 기법을 적용하여 배터리 열화 신호를 장기 경향과 주기적 변동 성분으로 분리하고, 각 성분을 transformer 인코더를 통해 독립적으로 학습한 후 재조합하여 최종 SoH를 예측하였다. 미국 메릴랜드 대학교 CALCE 센터의 CS2 계열 데이터를 활용한 실험 결과, 제안 모델은 RMSE와 MAE 지표에서 기존 방법 대비 더욱 향상된 성능을 보였으며, 이는 배터리 열화 특성을 효과적으로 반영한 학습 구조의 타당성을 충분히 입증한다. 향후 연구에서는 다양한 배터리 화학 조성 및 운용 환경에 대한 확장 실험과, 경량화 및 실시간 추론을 위한 모델 최적화를 지속적으로 진행할 예정이다.

ACKNOWLEDGMENT

▷ 본 연구는 2023년도 산업통상자원부의 재원으로 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (RS-2023-00266248)

▷ 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2024-00349885)

참 고 문 헌

- [1] M. Kannan, K. Sundareswaran, P. S. R. Nayak, and S. P. Simon, "A Combined DNN-NBEATS Architecture for State of Charge Estimation of Lithium-Ion Batteries in Electric Vehicles," *IEEE Transactions on Vehicular Technology*, vol. 72, no. 6, pp. 7328 - 7338, Jun. 2023.
- [2] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, "Attention is all you need," in *Advances in Neural Information Processing Systems*, vol. 30, 2017.
- [3] H. Wu, J. Xu, J. Wang, and M. Long, "Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting," *Advances in Neural Information Processing Systems*, vol. 34, pp. 22419 - 22430, 2021.
- [4] S. Wang, H. Wu, X. Shi, T. Hu, H. Luo, L. Ma, J. Y. Zhang, and J. Zhou, "TimeMixer: Decomposable Multiscale Mixing for Time Series Forecasting," in *International Conference on Learning Representations (ICLR)*, 2024.