

Transformer 모델을 적용한 전기차량 리튬 이온 배터리의 노화도 예측 및 시각화를 위한 연구

우태걸, 이세훈, 조인호, 박강문
한국교통대학교

Research on Aging Prediction and Visualization of Electric Vehicle Lithium-Ion Batteries using the Transformer Model

TaeGeol-Woo, Sehun-Lee, Inho-Jo, KangMoon-Park
Korea University Of Transportation

ABSTRACT

최근 전기차량에 사용되는 리튬 이온 배터리의 상태와 성능 예측에 대한 연구는 지속 가능한 교통수단의 발전을 위해 중요한 주제로 화두되고 있다. 이러한 연구들은 배터리 성능과 안전성에 대한 기대가 증가함에 따라, 배터리의 효율적인 관리와 장기적인 성능 유지를 중점으로 진행되고 있다. 본 연구에서는 기존의 딥러닝 모델인 LSTM-AutoEncoder 기반 시계열 예측 모델을 넘어서 Self-Attention 메커니즘과 Transformer 모델을 통해 배터리 상태 예측의 정확도를 개선하는 새로운 접근 방식을 연구한다. 실험은 반복적인 철도차량에 사용된 리튬 이온 배터리의 충/방전 데이터를 사용하여 수행되었으며, 모델의 성능은 정확도, 손실률, 그리고 예측 속도 측면에서 평가되었다. 결과적으로, 본 연구에서 Transformer 기반 모델은 기존 LSTM-AutoEncoder 모델 및 Self-Attention 기반 모델에 비해 상당한 성능 향상을 보였으며, 특히 복잡한 시간적 패턴을 가진 리튬 이온 배터리 데이터에서의 예측 정확도 면에서 뛰어난 결과를 제시했다. 본 연구는 리튬 이온 배터리 관리와 장기적 성능 예측 및 시각화에 있어서 Transformer 모델의 응용 가능성을 보여주며, 이러한 기술의 실제 적용이 운전자에게 보다 정확한 배터리 성능 정보를 제공하여 배터리의 안전하고 효율적인 사용을 가능하게 할 것으로 기대된다. 이는 향후 지속 가능한 전기차량 개발을 위한 기술적 발전으로 기여할 전망이다.

1. 서론

전기차량의 에너지원으로서 리튬 이온 배터리의 중요성은 날로 증가하고 있다. 이러한 배터리들은 고에너지 밀도와 높은 수명으로 인해 선호되지만, 사용 중 성능 저하가 불가피하게 발생한다. 이러한 성능 저하를 관리하고, 전기차량의 안정성 및 경제성을 향상시키기 위해 배터리의 상태를 정확하게 추정하고 예측하는 것은 필수적이다. 배터리의 상태 추정은 배터리의 잔여 수명, 성능, 그리고 안정성을 평가하여 사용자에게 최적의 사용 지점을 안내하고, 필요한 유지보수를 예측할 수 있는 기능을 제공한다.

전기자동차 배터리의 배터리 성능 상태 지표(SOH)가 일반적으로 초기 대비 일정 수치에 도달하면, 전기자동차(EV) 배터리의 수명이 거의 다한 것으로 간주되어 초기 상태의 배터리로 교체하는 것이 권장된다. 이러한 결정을 돕기 위해 리튬 이온

배터리 상태 추정과 관련된 다양한 연구들이 수행되어 왔다. 특히, 리튬 이온 배터리의 노화 상태와 건강 지표를 활용한 상태 추정 및 잔존 수명 예측에 관한 연구들이 여러 딥러닝 알고리즘 모델을 통해 진행된 바 있다.

본 논문에서는 철도차량 리튬 이온 배터리의 전압과 전류, 온도의 지표를 기반으로 배터리의 건전성을 시각화 할 수 있는 알고리즘 개발을 목표로 한다. 이를 위하여 딥러닝 모델 중 LSTM-Autoencoder 모델, Self-Attention 모델, Transformer 모델로 배터리의 성능 상태를 학습시키고 이를 RGB 값으로 표현할 수 있도록 하여 시각적으로 관측이 가능하도록 한다.

본 연구에서는 LSTM-AutoEncoder 모델의 한계를 극복하고자, Attention 메커니즘과 Transformer 모델을 도입한다. Attention 메커니즘은 모델이 중요한 정보에 더 많은 가중치를 기울이도록 하여, 데이터 간의 중요한 관계를 더 잘 포착할 수 있도록 한다. 한편, Transformer 모델은 복잡한 시퀀스 데이터를 처리하는 데 탁월한 성능을 보이는데, 이는 주로 자연어 처리 분야에서 뿐만 아니라 최근 시계열 데이터에서도 그 효과가 입증되었다. 본 연구에서는 이러한 기술을 리튬 이온 배터리의 상태 추정 문제에 적용하여, 기존 모델 대비 향상된 예측 정확도를 달성하고자 한다. 이 접근 방식은 복잡한 시간적 패턴과 데이터 간의 장기 의존성을 모델링하는 데 중점을 둔다.

2. 인공지능망 모델

2.1 모델 선정 및 비교 연구

본 연구에서는 리튬 이온 배터리의 성능 추정 및 시각화를 정확하게 진행하기 위해 LSTM-AutoEncoder, Self-Attention, 및 Transformer 모델을 선정하여 이 세 모델의 예측 성능을 비교분석하였다. 위 모델들은 기존의 배터리 성능 추정 연구에서 사용되어 온 바가 있으며, 본 연구는 이 모델들이 철도 차량에 사용된 리튬 이온 배터리 데이터셋에 어떤 예측 성능을 보이는지 평가하고자 연구를 진행 하였다.

2.1.1 LSTM-AutoEncoder 모델

LSTM-AutoEncoder 모델은 시퀀스 데이터의 특성을 이해하고 장기 의존성을 모델링하는 데 탁월한 능력을 보여준다^[1]. 본 모델의 인코더 부분은 여러 LSTM 계층을 통해 점차적으로 입력 데이터를 압축하며, 가장 낮은 차원에서는 Dense 계층을 통해 데이터를 RGB 색상 값으로 변환한다. 디코더는 이 과정을 역으로 수행하여 원래 데이터의 구조를 복원한다. 이 모델

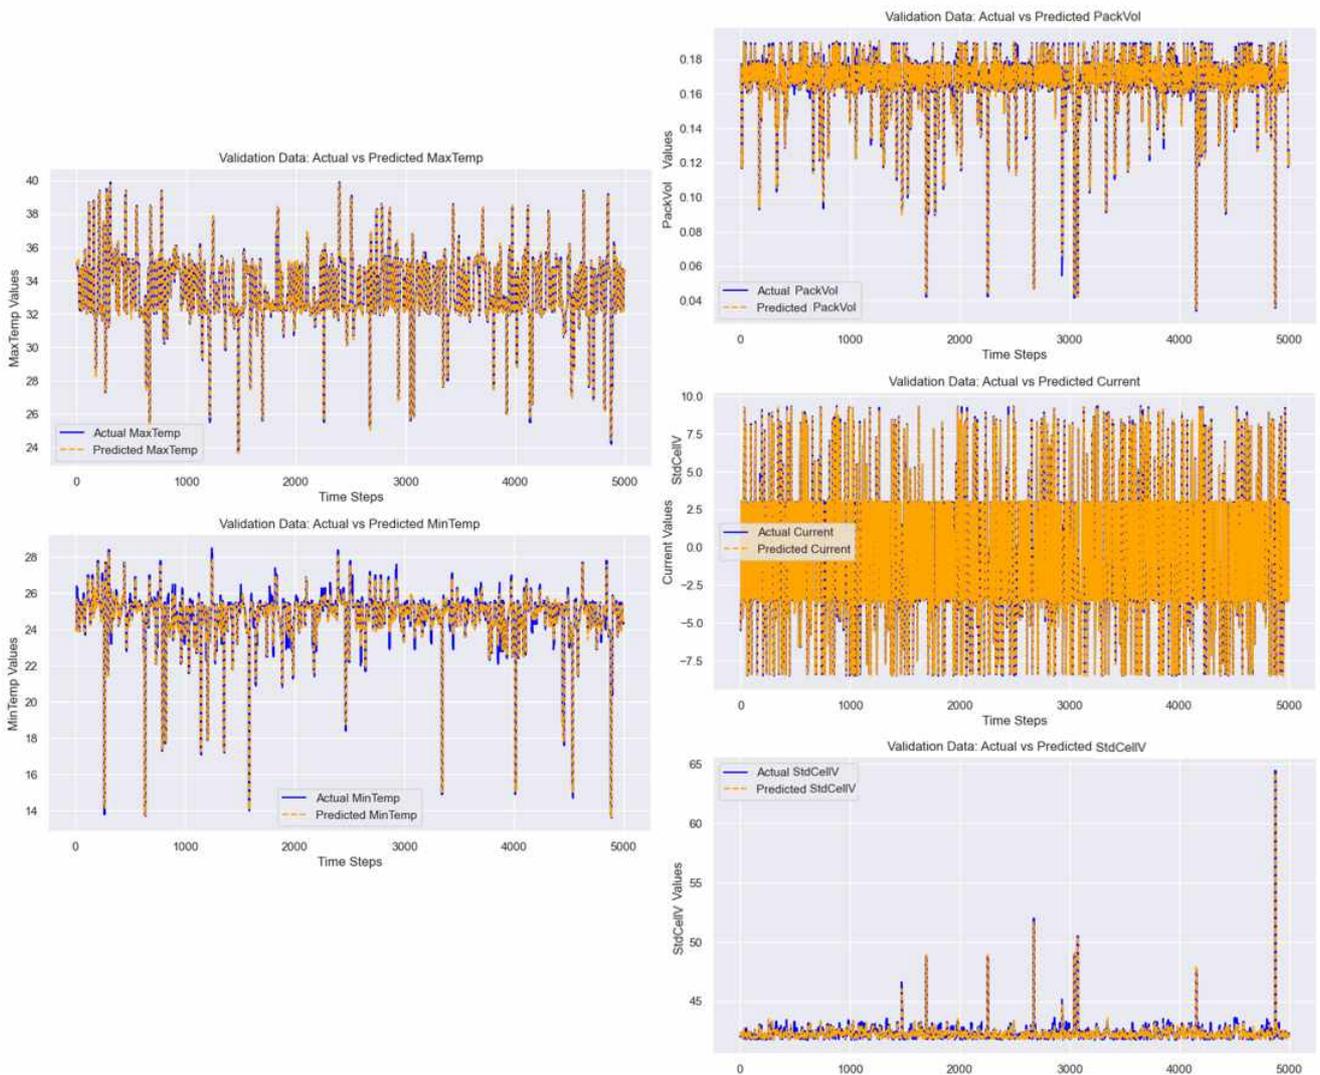


그림 1 Transformer 모델 특징별 원본 및 예측결과 그래프
 Fig. 1 Original and predicted result graph by Transformer model characteristics

은 학습된 인코더를 사용하여 배터리의 현재 상태 RGB 값으로 압축하여 직관적인 색상으로 시각화함으로써 배터리의 건전성을 평가하여 다른 모델과 성능 비교를 진행하였다.

2.1.2 Self-Attention 모델

Self-Attention 모델은 입력 데이터 사이의 상호 작용을 분석하여 각 데이터 포인트의 중요도를 계산하는 방식을 기반으로 한다^[2]. 본 연구에서는 이 모델을 독립적으로 구현하여 리튬이온 배터리의 노화도 예측에 활용하였다. Self-Attention 모델은 중요한 정보를 강조하고 불필요한 정보를 배제함으로써 데이터의 핵심적인 패턴을 더욱 명확하게 포착한다. 특히, 복잡한 시계열 데이터에서의 의존성과 시간적 특성을 분석하는 데 강점을 보인다^[3]. 본 연구에서는 Self-Attention 모델에 LSTM 계층을 추가한 모델을 이용하여 배터리의 충전 및 방전 과정 중 발생하는 주요 변화를 효과적으로 예측하였으며, LSTM-AutoEncoder 모델 및 Transformer 모델과의 성능 비교를 통해 그 유효성을 검증하고자 하였다.

2.1.3 Transformer 모델

Transformer 모델은 자연어 처리 분야뿐만 아니라 복잡한 시계열 데이터를 처리하는 데 높은 성능을 보여준 바^[4]가 있으며 이를 적용하여 리튬 이온 배터리의 성능 추정 및 시각화의 정확성을 향상시키고자 하였다. 이 모델의 핵심 구성 요소는 Self-Attention 메커니즘이다. 이 메커니즘은 입력 데이터의 모든 부분을 서로 비교 분석하여 중요한 정보에 더 큰 가중치를 부여한다. Transformer 모델은 이러한 Self-Attention 레이어를 여러 개 쌓아서 구성하며, 각 레이어는 입력 시퀀스의 각 요소를 동시에 처리하여 전체 데이터의 맥락을 파악한다^[2]. 이렇게 여러 Self-Attention 레이어를 적층해서 만들어진 Transformer 모델을 통해서 리튬 이온 배터리의 시간에 따른 성능 변화 패턴을 보다 정밀하게 예측하고자 하였다. 따라서, 본 연구에서는 Transformer 모델이 LSTM-AutoEncoder 및 Self-Attention 모델과의 비교 분석에서 리튬 이온 배터리의 시간에 따른 성능 변화 패턴을 보다 정밀하게 예측이 가능한지 검증하고자 하였다.

표 1 알고리즘 모델 실험 정확도 및 손실값
TABLE 1 Algorithm model experiment accuracy and loss value

	Loss	Accuracy
LSTM-AutoEncoder	0.017	94.9%
Self-Attention	8.79e-05	97.8%
Transformer	1.52e-05	98.7%

2.2 데이터 셋

본 연구에서 사용된 데이터 셋은 철도 차량의 리튬 이온 배터리의 데이터로 2,000번의 주기를 구간을 나누어 7번 반복하여 총 14,000번의 주기(Cycle)동안 충/방전을 반복하여 리튬 이온 배터리의 성능 상태 변화를 기록한 데이터 셋이다.

그 중 리튬 이온 배터리의 성능 상태를 추정하기 위해 배터리 최고 온도(MaxTemp), 배터리 최저 온도(MinTemp), 전압 편차(StdCellV), 전류(Current), 그리고 충전 전압(PackVol)의 다섯 개의 특징만 추출하고 배터리의 상태를 추정하고 시각화하기 위한 데이터로 실험에 사용했다.

모델 학습에 사용되는 데이터의 편차를 줄이기 위해서 추출한 5개의 특징값들을 모든 데이터 값이 0과 1 사이의 범위로 변환하여, 데이터 간의 상대적인 크기 차이를 유지하면서도 전체적인 데이터의 편차를 줄여 학습에 사용하기 위해 데이터 정규화를 Min-Max 스케일러를 사용하여 수행한 뒤 데이터를 학습에 사용하였다.

3. 실험

3.1 정확도 분석

본 연구에서는 기존에 리튬 이온 배터리의 노화도 추정 및 시각화에 사용되었던 LSTM-AutoEncoder 모델의 성능을 더욱 향상시키기 위해 Self-Attention 모델과 Transformer 모델을 비교 분석하였다. 각 모델의 성능을 정확하게 평가하기 위해 정확도(Accuracy)와 손실(Loss) 값을 사용하였다. 이를 통해 각 모델의 성능 차이를 명확히 파악하고, 배터리 상태 추정에 가장 적합한 모델을 도출하고자 하였다.

3.2 실험 결과

표 1은 LSTM-AutoEncoder, Self-Attention, Transformer 모델의 성능 비교 결과를 나타낸다. Transformer 모델은 기존 LSTM-AutoEncoder 모델에 비해 정확도가 4.00% 향상되고 손실 값이 99.91% 감소했으며, Self-Attention 모델에 비해 정확도가 0.92% 향상되고 손실 값이 82.70% 감소하여 세 모델 중 가장 우수한 성능을 보였다. 이러한 Transformer 모델의 성능을 판단하기 위한 그림 1은 Transformer 모델의 특징값들의 원본데이터와 예측데이터간의 비교 그래프를 시각화하여 표현한 그래프로 전체적으로 예측데이터가 원본데이터와 유사함을 볼 수 있다.

4. 결론

본 연구에서는 LSTM-AutoEncode 모델, Self-Attention 모델, Transformer 모델들을 이용한 철도 차량의 리튬 이온 배터리의 건전성을 추정하고 시각화할 수 있는 알고리즘을 비교하였다.

연구에 사용된 알고리즘들은 반복되는 리튬 이온 배터리의 충/방전 Cycle 데이터를 학습하여 이를 클러스터링 하고 RGB 값을 통해 특정 시점의 배터리의 건전성 상태를 추정하고 색으로 시각화하여 표현하기 위한 모델들을 구성 및 성능을 비교하였으며 이때 Transformer 모델의 경우 RGB 시각화에 중요한 영향을 끼치는 손실 값이 다른 두 모델인 LSTM-AutoEncoder 모델, Self-Attention 모델보다 각각 약 99.1%, 82.7% 이상의 성능을 보였다.

위의 모델들로 인한 결과로 리튬 이온 배터리의 건전성 상태를 RGB 값으로 표현할 수 있으며 이를 통해 사용자에게 가시성 높은 알람을 주기에 유용하기 때문에 배터리 교체 주기를 파악하는 데 도움을 줄 수 있을 것으로 기대된다.

본 연구에서 복잡한 시계열 데이터인 리튬 이온 배터리 데이터를 사용한 연구 결과에서 Transformer 모델의 성능이 뛰어나다는 것을 확인할 수 있으며 이를 통해 추후 RGB 값을 통해 특정 시점의 배터리의 건전성 상태를 색으로 시각화를 진행할 때 더욱 높은 정확성을 가진 학습 결과를 얻을 수 있을 것으로 기대된다.

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2022R1G1A10070561230382068210102)

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2022R1G1A10070561230382068210102)

참고 문헌

- [1] J. -Y. Wu, M. Wu, Z. Chen, X. -L. Li and R. Yan, "Degradation-Aware Remaining Useful Life Prediction With LSTM Autoencoder," in IEEE Transactions on Instrumentation and Measurement, vol. 70, pp. 1-10, 2021, Art no. 3511810, doi: 10.1109/TIM.2021.3055788.
- [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, pp. 5998-6008, 2017.
- [3] Y. Jiang, Y. Chen, F. Yang, and W. Peng, "State of health estimation of lithium-ion battery with automatic feature extraction and self-attention learning mechanism," Journal of Power Sources, vol. 556, p. 232466, 2023.
- [4] D. Chen, W. Hong and X. Zhou, "Transformer Network for Remaining Useful Life Prediction of Lithium-Ion Batteries," in IEEE Access, vol. 10, pp. 19621-19628, 2022, doi: 10.1109/ACCESS.2022.3151975.