

TKAN을 활용한 배터리 SoC 예측 연구

차은재, 임완수*

성균관대학교

ckdmswo17@skku.edu, *wansu.lim@skku.edu

A Study on Battery State-of-Charge Estimation Using Temporal Kolmogorov-Arnold Networks

Cha Eunjae, Lim Wansu*

Sungkyunkwan Univ.

요약

본 논문에서는 배터리의 전압, 전류, 온도를 이용해서 SoC를 예측하는 모델 구조를 제안한다. 제안하는 모델은 Kolmogorov-Arnold 정리를 활용한 KAN을 시계열 데이터 처리 모델로 변형한 TKAN을 이용한다. KAN은 기존 MLP와 같이 같은 충에선 동일한 활성화 함수를 가지지만 학습을 거듭하면서 각 노드의 활성화 함수가 변경된다는 특징이 있다. 하지만 KAN은 입력을 2차원으로 받기 때문에, 시계열 데이터에 적합하지 않다. 이러한 단점을 TKAN은 LSTM의 구조의 출력 계이트에 KAN을 삽입해 해결한다. TKAN은 현재 시점의 상태가 이전 시점의 상태의 영향을 받음과 동시에 데이터가 길어질수록 기울기가 사라지는 장기 의존성 문제도 해결한다. 모델 학습에 미국 위스콘신 대학교 매디슨 연구진의 Panasonic 배터리 실험 데이터를 활용하였다. 실험 결과, 제안한 네트워크는 배터리 데이터셋의 비선형성을 잘 반영해 기존의 방법 대비 MAE, RMSE 지표에서 우수한 성능을 보였다.

I. 서론

배터리 SoC(State of Charge)는 현재 배터리에 저장된 잔여 에너지의 비율을 나타내는 지표로, 배터리 관리 시스템의 가장 기본적이면서도 중요한 상태 변수 중 하나이다. 정확한 SoC 예측은 배터리의 안전성, 성능, 수명 관리에 직접적인 영향을 미치므로, 실시간 응용 환경에서 필수적인 기술이다.

배터리 SoC 예측에 딥러닝 모델을 활용하는 추세이다. 기존에는 RNN(Recurrent Neural Network), LSTM(Long Short-Term Memory Network) 등 순환 신경망 기반 네트워크가 사용되었으며[1][2], 최근에는 장기 의존성 문제에 강인한 Transformer 기반 네트워크가 사용되고 있다.[3] 하지만 순환 신경망 기반 네트워크는 장기 의존성 문제가 여전히 존재하고, Transformer 기반 네트워크는 한 층의 각 노드에서 모든 활성화 함수가 동일하기 때문에 완벽한 비선형성을 표현하지 못한다는 단점이 존재한다.

II. 본론

2.1 데이터셋

본 논문에서는 미국 위스콘신 대학교 매디슨의 연구진이 Panasonic 18650PF 전기차 배터리 셀을 다양한 온도에서 여러 사이클로 수행한 공개 데이터셋을 이용한다.[4] 온도는 -20°C부터 25°C까지 5°C 단위로 학습과 검증, 테스트 데이터셋에서 모두 활용했다. 학습 데이터셋의 Cycle은 기본적인 충·방전 사이클인 Cycle_1 ~ Cycle_4와 급가속과 급감속 사이클인 US06, 불규칙한 전류 사이클인 NN 등 총 10개의 Cycle를 이용한다. 검증, 테스트 데이터셋의 Cycle은 고속도로 정속 주행 사이클인 HWFET 등 총 3개의 Cycle을 이용한다.

Object	Cycle
Train	Cycle_1, Cycle_2, Cycle_3, Cycle_4, NN, US06, US06_HWFET_UDDS_LA92, HWFET_UDDS_LA92_NN, US06_HWFET_UDDS_LA92_NN
Validation, Test	HWFET, UDDS, LA92

표 1. 실험에 사용한 데이터셋 Cycle 종류

전력, 전류, 온도 데이터를 입력 특성으로 사용한다. 또한 한번의 모델 입력으로 들어가는 시퀀스 길이는 128로 고정한다.

2.2 KAN

KAN(Kolmogorov-Arnold Network)은 식 (1)의 Kolmogorov-Arnold 정리를 딥러닝 모델에 적용한 모델이다.[5] Kolmogorov-Arnold 정리의 핵심은 다변수 함수의 근사에는 다변수 비선형성이 필요 없다는 것이다. 즉, 딥러닝 모델 구현시 비선형성은 1D 함수에만 존재하고 변수 간 상호작용은 선형 결합으로 처리한다는 것이다.

KAN은 일반적인 MLP(Multi Layer Perceptron)와 달리 노드가 아닌 엣지에 활성화 함수가 존재한다. 그래서 MLP는 각 활성화 함수가 여러 엣지를 받는 Fully-Connected 구조인 반면, KAN은 각 활성화 함수가 하나의 엣지만 처리하는 구조이다. 또한 KAN은 활성화 함수를 학습 중에 업데이트해서, 초기에는 활성화 함수가 총 별로 동일하지만 학습 데이터셋에 맞춰서 활성화 함수의 개성이 변한다.

$$f(x) = f(x_1, \dots, x_n) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_{p=1}^n \phi_{q,p}(x_p) \right) \quad (1)$$

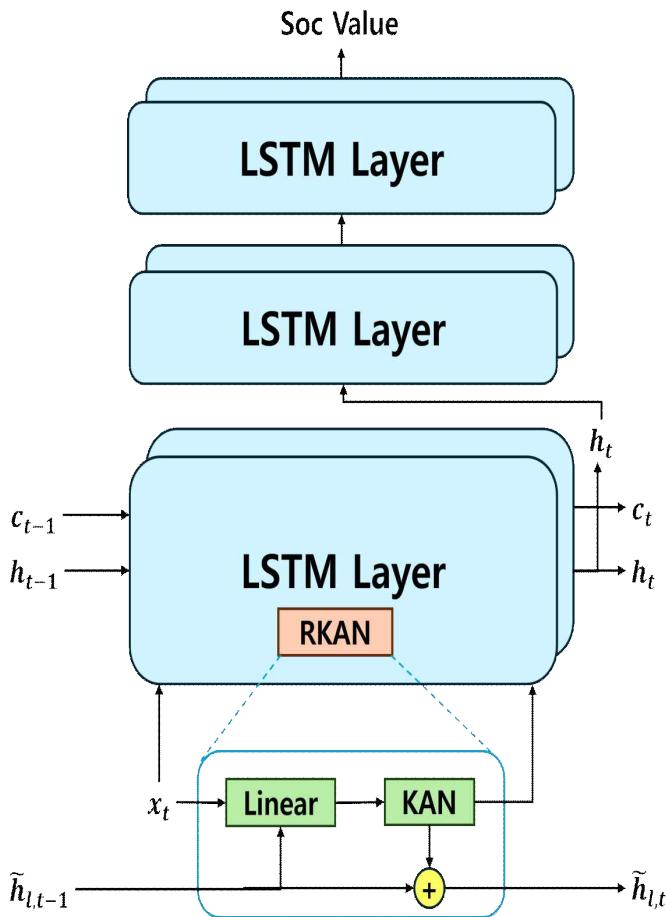


그림 1. 제안한 네트워크 구조

2.3 네트워크 구조

TKAN(Temporal KAN)은 KAN을 시계열 데이터 처리 모델로 변형한 모델이다. TKAN은 LSTM의 게이팅 매커니즘을 일부 변형해 사용한다.[6] 차이점은 LSTM 내부에 RKAN(Recurring KAN)이라는 네트워크를 추가적으로 거친다는 점이다.

전체적인 네트워크 구조는 그림 1과 같다. 네트워크는 크게 RKAN을 포함한 3개의 LSTM Layer로 구성된다. 입력 데이터는 PyTorch 환경에서 (batch, features, time) 차원으로 입력을 받으므로, (128, 3, 128) 차원의 데이터를 한 번에 사용한다. LSTM Layer는 여러 개의 LSTM Block으로 구성되며, 각 층의 LSTM Layer는 아래부터 순서대로 128, 64, 32개의 LSTM Block을 가진다.

각 LSTM Block은 이전 Block의 입력 x_{t-1} , 은닉값 h_{t-1} , 셀 상태 c_{t-1} 를 사용한다. forget, input 게이트에선 이 값들을 이용해 연산을 하고 추가적으로 셀 상태를 계산해 다음 LSTM Block에 볼록에 전달한다. output 게이트에서는 입력되기 이전에 RKAN 네트워크를 거친다.

RKAN은 x_{t-1} 과 이전 Block의 KAN에서 서로 다른 개형의 활성화 함수를 거친 은닉값 $\tilde{h}_{l,t-1}$ 를 이용한다. 내부적으로 Linear 층과 KAN을 거쳐 비선형성과 잔차 입력을 추가해 output 게이트와 다음 LSTM Block로 정보를 전달한다. output 게이트에서는 이 정보를 이용해 은닉값을 계산하고 다음 LSTM Block과 상단의 Layer에 전달한다.

모델 학습의 손실 함수로는 평균 제곱 오차(Mean Squared Error, MSE)를 사용했고, 학습률 0.005의 Adam 옵티마이저를 사용해 파라미터를 최적화했다. 추가적으로 불필요한 과적합을 막기 위해, 검증 손실이 10 에포

크동안 감소하지 않으면 학습을 조기에 종료하는 EarlyStopping을 적용했다. 모델 테스트의 손실 함수로는 평균 절대 오차(Mean Absolute Error, MAE)와 평균 제곱근 오차(Root Mean Squared Error, RMSE)를 사용했다.

III. 결론

본 논문은 배터리 SoC 예측 성능 향상을 위해 TKAN 모델을 제안하였다. 제안한 모델은 시간 순서대로 측정된 데이터를 각 LSTM Block에 대응시켜 전압, 전력, 온도의 시간 순서에 따른 관계를 학습한다. 또한 KAN을 이용해 데이터에 더 최적화된 엣지별 활성화 함수를 이용해 높은 성능을 달성할 수 있다. 제안한 모델은 RMSE와 MAE 지표에서 기존 방법보다 더욱 향상된 성능을 보였다. 추후 연구에서는 실제 주행 배터리 데이터 세트을 포함한 다양한 배터리 데이터셋 환경에서 학습을 진행하고, 실시간 추론을 위한 모델 경량화 및 최적화를 수행할 예정이다.

ACKNOWLEDGMENT

이 논문은 과학기술정보통신부가 지원한 ‘2025년도 주문연구기업 성장사다리 구축(글로벌 기업 도약)사업’으로 지원을 받아 수행된 연구 결과입니다. [RS-2025-25459504]

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

참 고 문 헌

- [1] H. Chaoui and C. C. Ibe-Ekeocha, "State of Charge and State of Health Estimation for Lithium Batteries Using Recurrent Neural Networks," in IEEE Transactions on Vehicular Technology, vol. 66, no. 10, pp. 8773–8783, Oct. 2017
- [2] Chemali, Ephrem and Kollmeyer, Phillip J. and Preindl, Matthias and Ahmed, Ryan and Emadi, Ali. "Long Short-Term Memory Networks for Accurate State-of-Charge Estimation of Li-ion Batteries," in IEEE Transactions on Industrial Electronics, vol. 65, no.8, pp. 6730–6739, August 2018
- [3] A. Almarzooqi, M. Alhusin, I. P. Nikolakakos, M. Salih, A. Husnain and H. Albeshr, "Improved NaS Battery State of Charge and State of Health Estimation: A Novel Integration of Temporal Fusion Transformer, Isolation Forest, and Support Vector Regression," in IEEE Transactions on Industry Applications, vol. 60, no. 6, pp. 8020–8030, Nov.–Dec. 2024
- [4] A. B. de Lima, M. B. C. Salles and J. R. Cardoso, "Data-driven state-of-charge estimation of the Panasonic 18650PF Li-ion cell using deep forward neural networks," 2021 14th IEEE International Conference on Industry Applications (INDUSCON), São Paulo, Brazil, 2021, pp. 1546–1550
- [5] Ziming Liu and Yixuan Wang and Sachin Vaidya and Fabian Ruehle and James Halverson and Marin Soljačić and Thomas Y. Hou and Max Tegmark. "KAN: Kolmogorov–Arnold Networks," arXiv:2404.19756, 2025
- [6] Remi Genet and Hugo Inzirillo. "TKAN: Temporal Kolmogorov–Arnold Networks," arXiv:2405.07344, 2025