

LSTM Autoencoder 기반 수요관리용 ESS 운전 패턴 분석 및 이상 운전 탐지

강지수¹, 권우현¹, 정민성¹, 진호준², *이상금¹

*국립한밭대학교¹, 한국에너지기술원²

{k4ngj15u, mfireon0520, jmss1101} @gmail.com, hojunjin@kier.re.kr,

*sangkeum@hanbat.ac.kr

LSTM Autoencoder-based Analysis of Operation Patterns and Anomaly Detection for Demand Management ESS

Jisu Kang¹, Woohyeon Kwon¹, Minsung Jung¹, Hojun Jin², and *Sangkeum Lee¹

*Hanbat National University¹, Korea Institute of Energy Research²

요약

본 논문에서는 수요관리용 에너지저장시스템(Energy Storage System, ESS)의 정상 운전 데이터 기반으로 정상 운전 패턴을 학습하고, 이상 운전 구간을 탐지하는 비지도 학습 방법론을 제안한다. 수요관리용 ESS는 BMS(Battery Management System)에 따라 평일 피크 시간대 방전과 비피크 시간대 충전을 수행하며 주기적인 운전 스케줄을 형성한다. 기존 임계값 기반 기법은 이러한 패턴 변화를 충분히 반영하지 못하는 한계를 가진다. 이에 본 연구는 정상 운전 데이터를 학습한 LSTM(Long Short-Term Memory)기반 Autoencoder모델을 구축하고 재구성 오차를 이상 운전 지표로 사용한다. 실제 운영 데이터에 적용한 결과, 전압 불균형과 비정상 패턴 구간에서 재구성 오차가 증가하며 이상 운전 탐지 가능성을 확인한다.

I. 서 론

최근 산업단지 내 전력 피크 저감 및 부하 평준화를 위한 수요관리용 에너지저장시스템(Energy Storage System, ESS)의 보급이 가속화되고 있다. 수요관리용 ESS는 전력 피크 시간대에 방전하고 비피크 시간대에 충전하는 운전 방식이 반복되면서 일정한 주기의 시계열 패턴을 형성한다. 실제 운영 환경에서는 전압 불균형, 제어 시스템 오류 등의 요인으로 운전 패턴이 변화하고, 이는 ESS 성능 저하 및 안전 문제로 직결될 수 있다. 기존의 지도 학습 방식은 모든 이상 징후에 대한 사전 라벨링이 필요하다는 한계가 있어, 본 연구에서는 정상 운전 패턴을 학습하여 재구성 오차를 기반으로 이상을 감지하는 비지도 학습 기반의 LSTM(Long Short-Term Memory)기반 Autoencoder 방법론을 제안한다 [1].

II. 본론

2.1 데이터 구성

약 5분 간격으로 수집된 ESS 운영 데이터를 활용하며 랙 전압, 전류, 충전 상태, 셀의 최저·최고 전압 등을 포함한다. 셀 간 전압 불균형 정도를 정량적으로 분석하기 위해 셀 최고 전압과 최저 전압의 차이인 셀 전압 편차를 산출하여 분석 지표로 활용한다.

2.2 입력 변수 선정 및 정상 운전 구간 정의

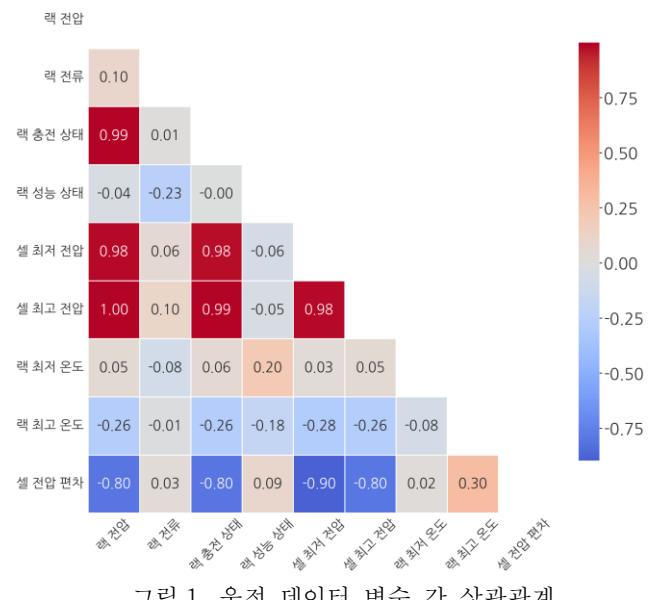


그림 1. 운전 데이터 변수 간 상관관계

그림 1의 상관관계 분석을 통해 모델의 입력 변수를 최적화한다. 랙 충전상태는 전압과 0.99의 높은 상관관계로 운전 과정에서 선형적으로 유사한 패턴을 보이므로 전압 대신 시스템의 운전 상태 대표 변수로 채택한다. 셀 전압 편차는 전압 및 충전상태와 -0.80의 강한 음의 상관관계로 충전 상태와 전압이 낮아질수록 셀 전압 편차가 커지는 배터리 특성을 반영하므로 입력 변수에 포함한다. 랙 전류는 타 변수와의 상관계수가

대체로 0.1 이하로 낮아 부하 및 제어 명령의 독립적인 특성을 반영하므로 주요 입력 변수로 선정한다.

그림 2와 같이, 정상 운전 구간은 충·방전 패턴이 규칙적이며, 입력 변수의 변동이 안정적으로 유지되는 구간으로 정의한다. 시계열 분석을 통해 패턴의 반복성과 변수 변동의 안정성이 확인된 구간을 정상 후보로 선정한 후, 평균으로부터 $\pm 2\sigma$ 및 $\pm 3\sigma$ 범위를 정상 범위로 설정하여 통계적 이상치를 검토한다. 평균 $\pm 2\sigma$ 기준에서 검출된 데이터는 물리적 관점에서 뚜렷한 이상 징후가 관찰되지 않아 정상 변동 범위로 판단하며, 과도한 데이터 제거를 방지하기 위해 최종적으로 평균 $\pm 3\sigma$ 를 정상 범위로 채택한다.

2.3 LSTM Autoencoder 기반 모델 학습

본 연구는 시계열 데이터의 시간적 종속성과 복잡한 운전 패턴을 효과적으로 학습하기 위해 LSTM Autoencoder 구조를 채택한다. 이 모델은 입력 시퀀스를 고정된 차원의 벡터로 압축하는 인코더와 이를 다시 원래 시퀀스로 복원하는 디코더로 구성된다 [2].

모델은 정상 운전 데이터만을 학습하며, 학습 시 입력과 복원값 사이의 MSE(Mean Squared Error)를 최소화하며, 5분 간격 데이터 12개를 하나의 시퀀스로 구성하여 1시간 단위의 패턴을 학습한다. 정상 패턴은 낮은 오차로 복원하지만, 미학습된 비정상 패턴에는 높은 재구성 오차를 발생시킨다. 이를 이상 점수로 산출하여 ESS의 이상 운전 여부를 판단하는 지표로 활용한다.

2.4 이상 운전 탐지 및 결과 분석

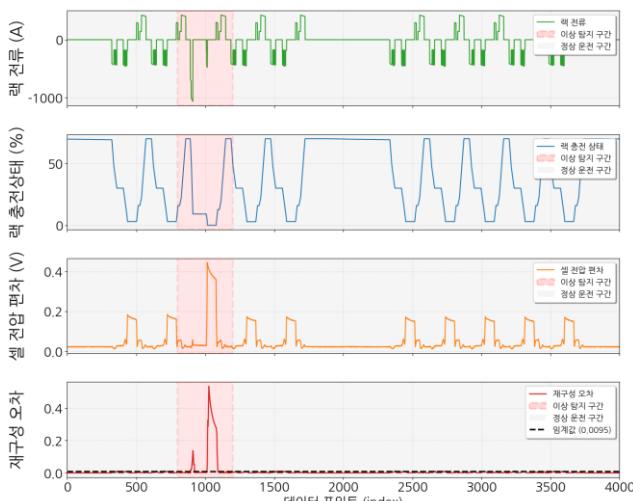


그림 2. 정상 및 이상 구간 이상 운전 탐지 결과

정상 학습 데이터의 재구성 오차 분포 중 상위 99% 지점인 0.0095를 이상 탐지 임계값으로 설정한다. 이는 정상 범위 내 변동성을 허용하면서도 비정상적인 패턴 변화를 효과적으로 검출하기 위한 지표로 활용된다.

그림 2는 미학습 데이터를 적용한 결과로, 붉은색 점선 박스 구간에서 셀 전압 편차의 급격한 증가와 함께 재구성 오차가 임계값을 상회하는 구간이 관찰된다. 이는 전압 불균형이 모델의 오차 상승으로 직결됨을 증명한다. 반면 정상 운전 구간은 규칙적인 충·방전 패턴을 유지하며 오차가 임계값 미만에서 안정적으로 형성된다.

	평균	표준편차
정상 운전 구간	0.0022	0.0029
이상 운전 구간	0.0120	0.0606

표 1. 재구성 오차 분포 비교

표 1은 두 구간의 재구성 오차를 정량적으로 비교한 결과이다. 이상 구간의 평균 오차는 정상 구간 대비 약 5.5배 증가하며, 특히 표준 편차는 20배 이상 급증한다. 이상 운전 발생 시 재구성 오차가 극심한 현상을 정량적으로 증명하며 별도의 이상 데이터 라벨링 없이 정상 운전 패턴 학습만으로 실제 ESS 현장에서 발생하는 복합적인 이상 징후를 식별할 수 있다.

III. 결론

본 연구는 수요관리용 ESS의 정상 운전 데이터를 기반으로 LSTM Autoencoder를 활용한 이상 운전 탐지 방법을 제안한다. 이상 데이터에 대한 라벨 없이도 정상 패턴 학습을 통해 비정상 패턴을 탐지하고 충전 상태 및 셀 전압 편차와 같은 물리적 지표를 결합하여 이상 운전 구간에 대한 해석 가능성을 보인다. 향후 연구에서는 탐지된 이상 구간의 재구성 오차 특성을 분석하여 전압 불균형, 통신 오류, 제어 이상 등 이상 운전의 원인을 자동으로 분류하는 진단 모델로 고도화하는 방안을 모색하는 것에 중점을 둘 예정이다.

ACKNOWLEDGMENTS

This work was conducted under framework of the research and development program of the Korea Institute of Energy Research (C6-2410-36).

참고 문헌

- [1] Lee, S., Nengroo, S. H., Jin, H., Doh, Y., Lee, C., Heo, T., & Har, D. (2023). Anomaly detection of smart metering system for power management with battery storage system/electric vehicle. *ETRI Journal*, 45(4), 650–665.
- [2] Malhotra, P. (2016). LSTM-based Encoder–Decoder for Multi–sensor Anomaly Detection. *arXiv preprint arXiv:1607.00148*.