

DTW 군집화 기반 롤링 IQR 규칙 강화학습을 통한 이상치 탐지 모델에 관한 연구

권우현¹, 정민성¹, 이정섭¹, 이충호², 허태욱², *이상금¹

*국립한밭대학교¹, 한국전자통신연구원²

{mfiron0520, jmss1101}@gmail.com, rornfl4512@naver.com, {leech, htw398}@etri.re.kr,

*sangkeum@hanbat.ac.kr

A Study on the Anomaly Detection Model Based on DTW Clustering and Reinforcement Learning for IQR Rules

Woohyeon Kwon¹, Minsung Jung¹, Jungseop Lee¹, Chungho Lee², Taewook Heo², and

*Sangkeum Lee¹

*Hanbat National University¹, Electronics and Telecommunications Research Institute

요약

본 논문은 시계열 데이터의 이상치 탐지 성능 향상을 위해 DTW(Dynamic Time Warping)기반 K-means 클러스터링, 롤링 IQR(Interquartile Range) 규칙, 그리고 강화학습(Reinforcement Learning)을 결합한 새로운 프레임워크를 제안한다. 산업에서 사용되는 전력은 변동성과 이상성이 커서, 일반적인 통계 방법으로 정밀한 패턴의 분석이 어렵다. 따라서 기존 이상치 탐지 방법론들이 데이터의 동적인 변화나 시간적 패턴을 효과적으로 반영하지 못하는 한계를 극복하기 위해 이상치 탐지 시 강화학습을 적용하여 동적으로 모델의 파라미터를 조정하며 효율적인 학습을 이끌어낸다. 이는 시계열 특성을 유연하게 분석함으로써 더 높은 탐지율을 보인다.

I. 서 론

현대 사회에서 시계열 데이터는 다양한 산업 분야에서 핵심적인 역할을 하지만, 시스템 오류나 센서 결함 등으로 발생하는 이상치로 인해 분석의 정확성이 떨어지고 치명적인 결과를 초래할 수 있다. 이를 위해, 본 연구는 DTW(Dynamic Time Warping)기반 K-means 클러스터링, 롤링 IQR(Interquartile Range) 규칙, 그리고 강화학습(Reinforcement Learning)을 결합하여 새로운 시계열 데이터 이상치 탐지 프레임워크를 제안한다. 이 프레임워크는 DTW K-means 클러스터링을 통해 유사한 패턴의 데이터를 그룹화하고, 롤링 IQR로 동적인 이상치 경계를 설정하며, 강화학습으로 탐지 민감도를 최적화하여 오탐지와 미탐지를 줄이고, 모델의 성능을 향상시킨다.

II. 본론

2.1 데이터 전처리 및 환경 구성

본 연구의 입력 데이터는 연속적인 전력 소모량 시계열 데이터이며, 결측치가 다수 존재한다. 이 결측값을 없애기 위해서 K-NN(Nearest Neighbor) Imputer 알고리즘을 이용하여 데이터의 전반적인 패턴과 특성을 유지하면서, 결측치를 보간한다.

2.2 DTW 기반 K-means 클러스터링

그림 1에서 제안 모델의 두 번째 단계는 DTW 거리를 활용한 K-means 클러스터링을 통해 시계열 데이터의 패턴을 기반으로 유사한 군집을 형성하는 것이다. DTW는 두 시계열 간의 유사도를 측정하는 알고리즘으로 시계열 길이가 달라도 비교가 가능하다. 이는 단순한 거리(Euclidean distance)로 시계열 데이터를 비교했을 시 발생하는 시간 간격의 모순에 의한 왜곡을 줄일 수 있다는 큰 특징이 있다.

따라서 DTW 기반 군집화는 단순히 값의 크기가 아닌, 시간적 패턴의 유사성을 기반으로 데이터를 분류함으로

써, 이상치 탐지 모델의 정확도를 높이는 데 중요한 역할을 한다.

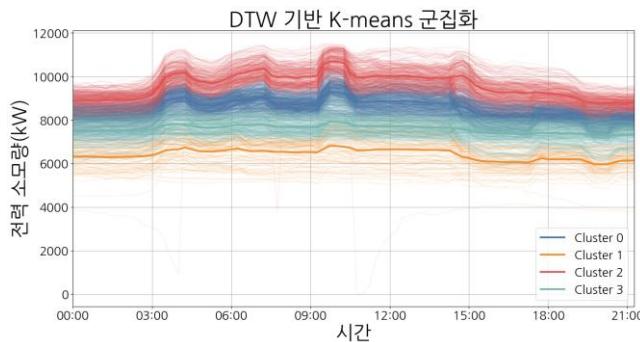


그림 1. DTW 기반 K-means 군집화

2.3 강화학습 기반 롤링 IQR 규칙

DTW K-means로 군집화 된 각 클러스터는 다음 규칙에 따라 모델에 학습된다.

환경(Environment, $\varepsilon = \{C_1, C_2, \dots, C_N\}$)은 C_k 은 K개로 환경을 설정한다. 상태(State, $S_t = [v_t, Q1_t, Q3_t, IQR_t]$)이고 행동(Action, $A = \{a_{normal}, a_{anomaly}\}$)에 반영한다: 보상(Reward)은 이상치 탐지를 위한 최적의 임계값을 위해 사용된다.

$$R(s_t, a_t) = +1 \cdot \mathbb{I}(a_t = a_{anomaly} \wedge \text{IQR Rule holds}) - 1 \cdot \mathbb{I}(a_t \neq a_{anomaly} \wedge \text{IQR Rule fails})$$

이상치 탐지에서 현재 데이터 포인트의 값이 상한 경계를 초과하거나 하한 경계 미만일 경우 이상치로 판단한다.

2.3.1 모델 학습 및 이상치 탐지

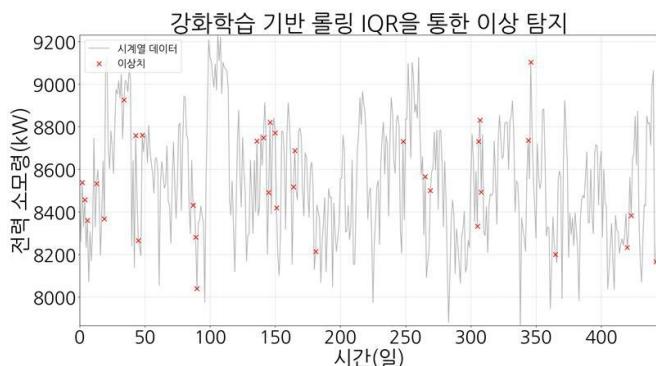


그림 2. 강화학습 기반 롤링 IQR 이상 탐지 그래프

그림 2에서 빨간색 점은 각 시간 (일)에서 발생한 이상치를 보여준다. 강화학습의 에피소드가 진행될수록 에이전트는 데이터의 변동에 따라 누적 보상을 꾸준히 증가시키며, 파라미터 k 값의 동적인 조정으로 지속적인 학습을 진행한다. 각 이상 시점은 데이터의 변동성이 큰 곳에서 눈에 띄게 관찰된다.

2.4 모델 성능 평가

제안 모델의 성능을 평가하기 위해, Isolation Forest, Autoencoder, 그리고 k 매개변수가 1.5로 고정된 기본 롤링 IQR 모델과 성능을 비교했다.

| Model | F1-Score | Precision | Recall |
|------------------|----------|-----------|--------|
| Rolling IQR – RL | 0.85 | 0.83 | 0.87 |
| Rolling IQR | 0.78 | 0.75 | 0.82 |
| Isolation Forest | 0.72 | 0.69 | 0.76 |
| Autoencoder | 0.76 | 0.78 | 0.74 |

표 1. 모델 성능 비교

III. 결론

본 연구는 시계열 데이터의 탐지 성능을 향상시키기 위해 DTW 기반 클러스터링, 롤링 IQR 규칙, 그리고 강화학습을 결합한 새로운 프레임워크를 제안했다. 가장 중요한 기여는 강화학습을 통해 롤링 IQR의 핵심 매개변수인 k 값을 동적으로 최적화했다는 점이다. 향후 딥러닝 기반 강화학습(DQN)을 도입하여 더 복잡한 데이터 패턴을 분석하는 방안을 모색하는 것에 중점을 둘 예정이다.

ACKNOWLEDGMENT

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술 평가원 (KETEP)의 지원을 받아 수행한 연구 과제입니다.
(No. RS2023-00237018)

이 (성과)는 교육부와 대전광역시의 재원으로 2025년

대전 RISE 사업의 지원을 받아 수행된 연구임

참 고 문 헌

- [1] Z. Gao, T. Huang, G. Cao, G. Ma, and W. Wang, "Reinforcement learning for time series anomaly detection," in *Proc. of the IEEE Int. Conf. on Data Mining Workshops*, 2021, pp. 248–255.
- [2] Tang, C., Abbate, B., Hu, J., Chandra, R., Martín-Martín, R., & Stone, P. (2024). *Deep Reinforcement Learning for Robotics: A Survey of Real-World Successes*. Annual Review of Control, Robotics, and Autonomous Systems.
- [3] Sangkeum Lee, Sarvar Hussain Nengroo, Hojun Jin, Yoonmee Doh, Chungho Lee, Taewook Heo and Dongsoo Har. (2023). *Anomaly detection of smart metering system for power management with battery storage system/electric vehicle*. ETRI Journal, 45(4), 650–665.