

이상 전력 탐지를 위한 TCN-USAD

(TCN-USAD for Anomaly Power Detection)

진현석*, 김경백**

(Hyeonseok Jin, Kyungbaek Kim)

요약

에너지 사용량의 증가와 친환경 정책으로 인해 건물 에너지를 효율적으로 소비할 필요가 있으며, 이를 위해 딥러닝 기반 이상 전력 탐지가 수행되고 있다. 수집이 어려운 이상치 데이터의 특징으로 인해 Recurrent Neural Network(RNN) 기반 오토인코더를 활용한 복원 에러 기반으로 이상 탐지가 수행되고 있으나, 시계열 특징을 온전히 학습하는데 시간이 오래 걸리고 학습 데이터의 노이즈에 민감하다는 단점이 있다. 본 논문에서는 이러한 한계를 극복하기 위해 Temporal Convolutional Network(TCN)과 UnSupervised Anomaly Detection for multivariate time series(USAD)를 결합한 TCN-USAD를 제안한다. 제안된 모델은 TCN 기반 오토인코더와 두 개의 디코더와 적대적 학습을 사용하는 USAD 구조를 활용하여 빠르게 시계열 특징을 온전히 학습할 수 있고 강건한 이상 탐지가 가능하다. TCN-USAD의 성능을 입증하기 위해 2개의 건물 전력 사용량 데이터 세트를 사용하여 비교 실험을 수행한 결과, TCN 기반 오토인코더는 RNN 기반 오토인코더 대비 빠르고 복원 성능이 우수하였으며, 이를 활용한 TCN-USAD는 다른 이상 탐지 모델 대비 약 20% 개선된 F1-Score를 달성하여 뛰어난 이상 탐지 성능을 보였다.

■ 중심어 : 자기 지도 학습 ; 이상 탐지 ; 시계열 데이터

Abstract

Due to the increase in energy consumption, and eco-friendly policies, there is a need for efficient energy consumption in buildings. Anomaly power detection based on deep learning are being used. Because of the difficulty in collecting anomaly data, anomaly detection is performed using reconstruction error with a Recurrent Neural Network(RNN) based autoencoder. However, there are some limitations such as the long time required to fully learn temporal features and its sensitivity to noise in the train data. To overcome these limitations, this paper proposes the TCN-USAD, combined with Temporal Convolution Network(TCN) and UnSupervised Anomaly Detection for multivariate data(USAD). The proposed model using TCN-based autoencoder and the USAD structure, which uses two decoders and adversarial training, to quickly learn temporal features and enable robust anomaly detection. To validate the performance of TCN-USAD, comparative experiments were performed using two building energy datasets. The results showed that the TCN-based autoencoder can perform faster and better reconstruction than RNN-based autoencoder. Furthermore, TCN-USAD achieved 20% improved F1-Score over other anomaly detection models, demonstrating excellent anomaly detection performance.

■ keywords : Self-supervised Learning ; Anomaly detection ; Time-Series Data

I. 서 론

최근 에너지 사용량의 지속적인 증가로 인한 비용 상승과 정부 및 지자체의 제로 에너지 건축

물 인증 등 친환경 정책으로 인해 전 세계 에너지 소비량의 약 20%를 차지하는 건물 에너지[1]를 효율적으로 소비할 필요가 있다[2-3]. 이로 인해 많은 금전적 손실을 유발하는 정전, 과소모 등 이상 전력 탐지를 수행할 수 있는 스마트 에

* 정회원, 전남대학교 인공지능융합학과 대학원생

** 정회원, 정회원, 전남대학교 인공지능융합학과 교수

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 지역지능화혁신인재양성사업(IIITP-2024-00156287, 50%)
본 연구는 과학기술정보통신부 및 정보통신기획평가원의 인공지능융합혁신인재양성사업 연구 결과로 수행되었음(IIITP-2023-PS-2023-00256629, 50%)

접수일자 : 2024년 06월 15일

수정일자 : 2024년 07월 09일

제재 확정일 : 2024년 07월 15일

교신저자 : 김경백 e-mail : kyungbaekkim@jnu.ac.kr

너지 관리 시스템의 중요성이 나날이 증가하고 있으며[4], 이를 위해 딥러닝을 기반으로 이상 전력 탐지를 수행하는 여러 연구들이 수행되고 있다[5-9]. 그러나 이상치 데이터는 정상 데이터 대비 극소수의 비율을 지닌다는 한계가 존재한다.

이러한 한계를 극복하기 위해 Recurrent Neural Network(RNN) 기반 오토인코더를 활용한 복원 에러 기반 이상 탐지가 수행되고 있다. 그러나 기존 방법들은 시계열 특징을 온전히 학습하는데 시간이 많이 필요하거나[9, 10], 학습 데이터의 노이즈에 민감하다[11]는 단점이 있다.

본 논문에서는 이러한 한계를 극복하기 위해 Temporal Convolutional Network(TCN)[10]과 UnSupervised Anomaly Detection for multivariate time series(USAD)[9]의 장점을 결합하여 시계열 특징을 빠르게 학습하면서도 강건한 이상 탐지가 가능한 TCN-USAD를 제안한다. 제안된 모델은 빠르게 시계열 특징을 학습할 수 있으며, 두 개의 디코더와 적대적 학습을 사용하여 강건한 이상 탐지를 수행할 수 있다.

본 논문의 주요 기여는 다음과 같다. TCN과 USAD를 결합하여 효율적이고 강건한 이상 탐지 모델을 제안하였으며, 실제 건물 전력 사용량 데이터 세트를 사용하여 제안한 모델의 성능을 검증하여 효율적인 건물 에너지 소비를 위한 이상 전력 탐지 수행 가능성을 보였다.

서론 이후의 구성은 다음과 같다. 2장에서는 시계열 특징 학습 및 복원 에러 기반 이상 탐지 관련 연구, 3장에서는 제안한 TCN-USAD에 대해서 설명한다. 4장에서는 실험에 대해서 설명 및 평가를 수행하고 마지막 5장에서는 결론 및 향후 연구에 대해 설명한다.

II. 관련 연구

1. 시계열 특징 학습

가. LSTM

Long Short-Term Memory(LSTM)[12]은 입력 데이터의 길이가 길어지면 기울기 소멸이 발생하는 기존 RNN의 장기 의존성 문제를 극복하기 위해 개발되었다. 이전 시점의 정보인 c_{t-1} , h_{t-1} 과 현재 시점의 입력 데이터 x_t 를 사용하며, 정보를 전달하는 경로 및 이를 업데이트 하는 역할을 수행하는 Cell State, 새로운 정보를 저장할지 결정하는 Input Gate, 중요하지 않은 정보를 제거하는 Forget Gate와 출력할 정보를 결정하는 Output Gate로 구성되어 있다.

해당 구조를 통해 기존 RNN의 한계를 극복하고 높은 성능을 보여 시계열 예측, 자연어 처리 등 다양한 분야에서 활용[13-15]되고 있지만, 복잡한 구조로 인해 계산 비용이 높다는 단점이 있다.

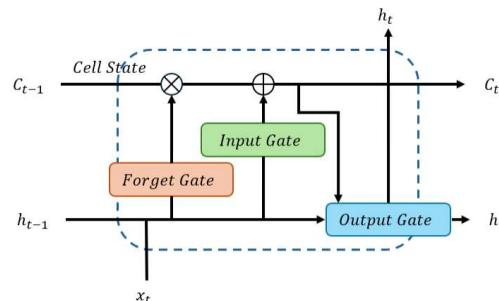


그림 1. LSTM 구조

나. GRU

Gated Recurrent Unit(GRU)[16]은 복잡도가 높고 많은 계산 비용이 필요한 LSTM의 한계를 극복하기 위해 개발되었으며, 보다 간단한 구조를 가지고 있다. 이전 시점의 정보인 h_{t-1} 와 현재 시점의 입력 데이터 x_t 를 사용하여 이를 이용하여 이전 시점의 정보를 얼마나 반영할지 결정하는 Reset Gate, 이전 시점의 정보와 현재 시점의 입력 데이터의 비율을 결정하여 현재 시점의 정보 h_t 를 계산하는 Update Gate로 구성되어 있으며, LSTM과 다르게 1개의 상태 정보만을 활용

한다.

기존 RNN의 장기 의존성 한계를 극복하면서도 단순화된 구조를 통해 LSTM 보다 낮은 계산 비용이 필요하다는 장점이 있지만, LSTM과의 성능 차이가 명확하지 않아 항상 뛰어난 성능을 보장하지 않는다는 단점이 있다.

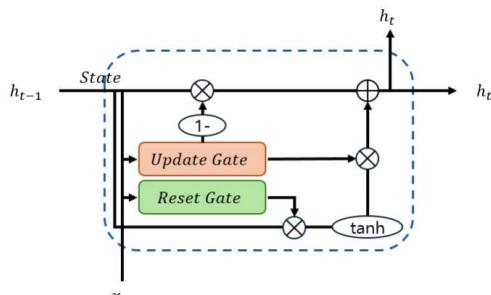


그림 2. GRU 구조

다. TCN

LSTM, GRU와 같이 시계열 특징 학습에 주로 사용되는 RNN 기반 신경망은 다음 시점의 추론을 수행하려면 이전 시점의 추론이 완료될 때까지 대기해야 하는 순차적인 특성으로 인해 시계열 특징을 온전히 학습하는데 시간이 많이 필요하여 비용이 많이 발생한다는 한계 [9, 10]가 있다.

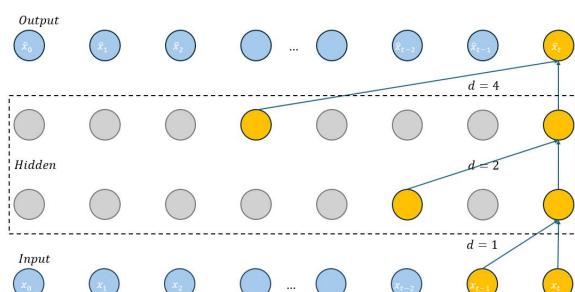


그림 3. TCN 구조

TCN[10]은 그림 3과 같이 필터의 간격을 점차 늘려가고 각 레이어가 현재 시점까지의 데이터만을 사용하는 Dilated Causal Convolution 구조를 사용하여 Convolutional Neural Network (CNN) 만으로 시계열 특징 학습이 가능하다. 이

로 인해 병렬 처리가 용이하고 입력 데이터의 길이가 길수록 다수의 게이트가 필요한 RNN 대비 메모리 요구량이 적으며, 필터 크기나 간격을 늘리는 방식으로 유연한 확장이 가능하다.

최근 연구 결과에 따르면 이러한 장점으로 인해 시계열 데이터 이상 탐지 분야에서 TCN은 LSTM 대비 뛰어난 성능을 보였으며[17], 기존 RNN을 대체하거나 오토인코더 혹은 이를 응용한 새로운 구조를 기반으로 한 복원 에러 기반 이상 탐지 연구가 수행[18-21]되고 있다.

2. 복원 에러 기반 이상 탐지

이상 탐지는 정상 데이터와 다른 패턴을 보이거나 과거에 극히 드물게 나타나는 이상 데이터[4]를 탐지하는 것으로, 대부분의 경우 정상 데이터 대비 극소수의 비율을 보이고, 특히 시계열 데이터의 경우 라벨링된 데이터를 얻는 것은 시간이 많이 발생하여 수집이 어렵다. 이와 더불어 클래스 불균형으로 인해 모델의 성능을 향상시키기 어렵다는 문제로 인해 자기 지도 학습의 필요성이 높아지고 있다 [22, 23].

가. 오토인코더

오토인코더[24]는 입력 데이터의 특징을 잠재 공간의 벡터로 압축하는 인코더와 압축된 특징을 다시 복원하는 디코더의 대칭 구조로 이루어져 있다. 오토인코더는 정상 데이터만을 사용하여 정상 데이터의 특징을 학습하고, 복원 시 발생하는 복원 에러를 기준으로 이상 탐지를 수행할 수 있다.

인코더는 정상 데이터를 입력받아 잠재 공간의 벡터로 압축하며, 디코더는 압축된 특징을 복원한다. 입력 데이터와 출력 데이터의 차이를 최소화하여 정상 데이터를 잘 복원하도록 학습되고, 학습 과정에서 발생한 에러를 기준으로 임계값을 설정한다.

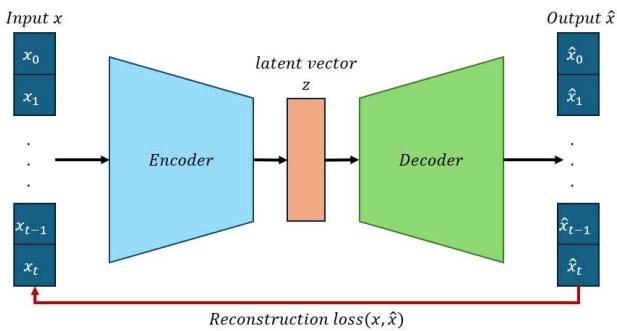


그림 4. 오토인코더의 복원 에러 기반 이상 탐지

추론 과정에서는 이상 데이터는 정상 데이터와 다른 패턴을 보이기 때문에 복원 에러가 높을 것으로 가정하여 테스트 데이터에 대한 복원 에러가 임계값보다 높을 시, 이상 데이터로 판단하여 이상 탐지를 수행한다.

오토인코더를 활용한 복원 에러 기반 이상 탐지는 정상 데이터만을 활용하여 임계값을 기준으로 이상 데이터를 판단하기에 수집이 어려운 이상 데이터의 한계를 극복할 수 있지만, 임계값 설정 방법이 명확하지 않고, 노이즈에 민감하다는 단점이 존재한다.

나. USAD

Generative Adversarial Network(GAN)[25]에

서 영감을 받아서 제안된 모델로, 그림 5. (a)와 같이 두 개의 디코더를 사용하여 적대적 학습을 적용한다. USAD[9]는 두 개의 디코더와 두 단계의 적대적 학습을 적용하여 단일 디코더만을 사용하는 기존 복원 에러 기반 이상 탐지 대비 강건한 이상 탐지가 가능하다.

두 개의 디코더는 각각 생성자와 판별자 역할을 수행하며, 1차적으로 정상 데이터의 특징을 인코더가 압축하고 두 개의 디코더가 복원하며, 2차적으로 생성자 역할을 수행하는 디코더의 출력을 판별자 역할을 하는 디코더가 재복원을 수행한다. 손실함수를 이용하여 판별자 디코더는 재복원 결과와 정상 데이터의 차이를 키우는 방향으로, 생성자 디코더는 재복원 결과와 정상 데이터의 차이를 줄이는 방향으로 적대적 학습을 수행한다.

추론을 수행할 때는 판별자 디코더의 복원 및 재복원 오차에 가중치를 부여하여 점수를 측정하고 이상 탐지를 수행하며 가중치를 조절하여 노이즈에 대한 민감도를 조정할 수 있다. USAD [9]는 강건한 이상 탐지를 수행할 수 있지만, Fully-Connected(FC) Layer 기반 오토인코더를 사용하여 복잡한 시계열 특징을 온전히 학습하기 어려울 수 있고, 소규모 데이터 세트의 경우 과

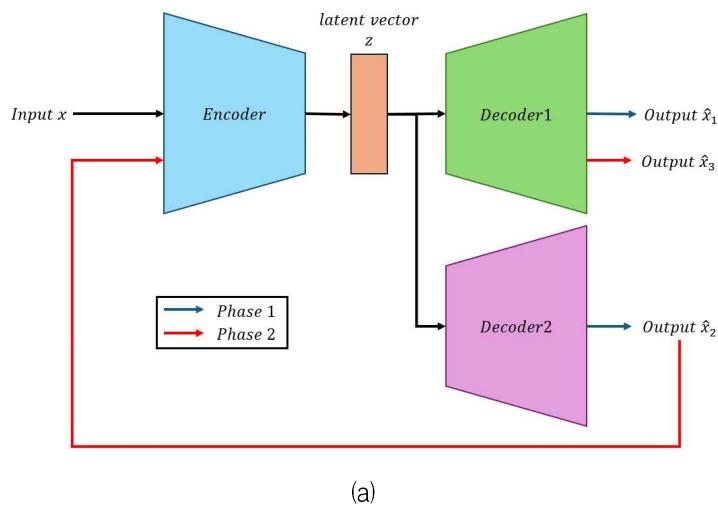
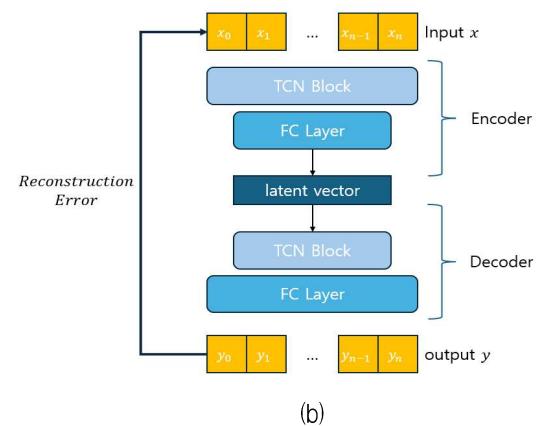


그림 5. TCN-USAD 모델, (a) USAD 구조 (b) TCN 오토인코더 구조



적합되어 일반화 성능이 떨어질 수 있다는 단점이 있다.

III. TCN-USAD

본 논문에서 제안한 TCN-USAD의 전체 구조는 그림 5와 같다. 기존 시계열 특징 학습에 시간이 오래 걸리는 한계와 FC Layer의 한계를 극복하기 위해 그림 5. (b)와 같은 TCN 오토인코더를 사용하였다.

t 의 길이를 갖는 입력 데이터 x , 활성화 함수 σ , 크기 K , 간격 d 의 필터 w 를 사용하는 TCN은 수식 1로 정의되며, 수식 2와 같이 TCN 인코더 E_{tcn} 은 정상 데이터 x 를 입력받아 시계열 특징을 추출하고, FC Layer를 사용하여 잠재 공간의 벡터 z 로 압축한다.

$$TCN = \sigma \left(\sum_{k=0}^{K-1} w_k * x_{t-d^*k} \right) \quad (1)$$

$$E_{tcn}(x) = FC(TCN(x_{0:t})) = z \quad (2)$$

TCN 디코더 D_{tcn} 는 수식 3과 같이 잠재 공간의 벡터 z 로 압축된 시계열 입력받아 복원하고, FC Layer를 사용하여 x 와 동일한 길이를 갖는 \hat{x} 를 생성한다. TCN 오토인코더의 전체 수식은 수식 4와 같다.

$$D_{tcn}(z) = FC(TCN(z)) = \hat{x} \quad (3)$$

$$AE_{tcn}(x) = D_{tcn}(E_{tcn}(x_{0:t})) = \hat{x} \quad (4)$$

또한 노이즈 데이터에 민감한 기존 방법의 한계를 극복하기 위해 TCN 오토인코더와 더불어 그림 5. (a)와 같이 USAD[9]에서 제안된 두 개의 디코더와 두 단계의 적대적 학습 구조를 사용하였다.

첫 번째 단계에서 판별자 역할을 하는 D_{tcn}^1 와

생성자 역할을 하는 D_{tcn}^2 은 수식 5와 같이 인코더 E_{tcn} 를 통해 압축된 잠재 공간의 벡터 z 를 입력받아 복원하여 두 개의 출력 \hat{x}_1, \hat{x}_2 를 생성한다. 두 번째 단계에서는 수식 6과 같이 D_{tcn}^2 의 출력 \hat{x}_2 를 D_{tcn}^1 이 복원을 수행하며, 수식 7과 같은 손실함수를 사용하여 적대적 학습을 수행한다.

$$\begin{aligned} AE_{tcn}^1(x) &= D_{tcn}^1(E_{tcn}(x)) = \hat{x}_1 \\ AE_{tcn}^2(x) &= D_{tcn}^2(E_{tcn}(x)) = \hat{x}_2 \end{aligned} \quad (5)$$

$$AE_{tcn}^1(\hat{x}_2) = \hat{x}_3 \quad (6)$$

$$\begin{aligned} l_1 &= \frac{1}{2}(x - \hat{x}_1)^2 - \frac{1}{2}(x - \hat{x}_3)^2 \\ l_2 &= \frac{1}{2}(x - \hat{x}_2)^2 + \frac{1}{2}(x - \hat{x}_3)^2 \end{aligned} \quad (7)$$

제안한 TCN-USAD는 수식 4와 같은 TCN 오토인코더를 사용하여 상태 정보와 여러 게이트의 연산을 순차적으로 적용하는 RNN 기반 오토인코더 대비 빠르게 시계열 특징을 학습할 수 있으며, FC Layer만을 사용한 USAD[9] 대비 복잡한 시계열 특징을 온전히 학습할 수 있음과 더불어 USAD의 구조를 기반으로 두 개의 디코더와 두 단계의 적대적 학습을 사용함으로서 기존 이상 탐지 모델 대비 강건한 이상 탐지 수행이 가능하다.

IV. 실험

1. 환경 설정

실험은 Intel(R) Core(TM) i7-10700 CPU @ 2.90 GHz, RTX 3070, Python 3.9.13, TensorFlow 2.10.0, Keras 2.10.0 환경에서 Adam optimizer, 학습률 0.001, Mean Squared Error(MSE) 손실 함수, USAD 및 TCN-USAD는 수식 7의 손실함수를 사용하여 50회 학습을 진행 및 비교를 수행하였다.

2. 측정 지표

가. 복원 성능 평가

TCN-USAD에 사용된 TCN 오토인코더의 복원 성능을 비교하기 위해 LSTM 오토인코더[7]와 GRU 오토인코더를 대상으로, 특정 시간대의 복원 능력이 많이 떨어지는 것을 확인하기 위해 수식 8과 같이 오차에 제곱을 취하여 평균을 구하는 MSE와 직관적인 복원 능력 확인을 위해 수식 9와 같이 오차에 절댓값을 취하여 평균을 구하는 Mean Absolute Error(MAE)를 측정하여 비교 실험을 수행하였다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2 \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - \hat{y}| \quad (9)$$

나. 이상 탐지 성능 평가

본 논문에서 제안한 TCN-USAD의 이상 탐지 성능을 비교하기 위해 LSTM 오토인코더[7], GRU 오토인코더, TCN 오토인코더 및 USAD[9]를 대상으로 수식 10과 같이 모델이 True라고 분류한 것 중 실제 True인 것의 비율을 나타내는 Precision, 실제 True인 것 중 모델이 True라고 분류한 비율을 나타내는 Recall, 이들의 조화 평균인 F1-Score를 각 클래스 별로 측정 및 평균을 구하여 비교 실험을 수행하였다.

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1-Score = \frac{(Precision * Recall)}{(Precision + Recall)}$$

3. 데이터 세트

실험에는 실제 건물 전력 사용량 데이터가 포함된 2개의 데이터 세트를 사용하였다. TCN 오토인코더의 복원 성능 비교에는 크롤링을 통해 수집한 2017년부터 2021년 5월 까지 측정된 전남대학교 공과대학 3호관 월별 전력 데이터[26]와 공공 데이터 포털의 광주시 일별 시간대별 전력거래량 데이터[27]를 사용하여 획득한 시간 단위 전력 계수를 적용한 시간 단위 데이터 세트를 사용하였다. 모든 데이터는 정상이라고 가정하였으며, 약 38000건의 데이터 중 2017년부터 2019년까지 2년 동안의 데이터를 학습, 2020년까지 1년 동안의 데이터를 검증, 나머지를 테스트용으로 분할하여 사용하였다.

복원 성능 비교에는 2016년 동안 200개 건물에 대해서 시간 단위로 수집된 전력 사용량 데이터인 LEAD 1.0 데이터 세트[28]를 활용하였다. LEAD 1.0 데이터 세트에는 각 건물별로 8784건의 데이터가 존재하며, 전체 데이터 세트 중 index가 1인 건물의 데이터를 사용하여 측정하였다. 실험의 무결성을 유지하기 위해 결측치 데이터는 모두 제거하였으며, 제거 이후 55건의 이상 데이터가 포함된 5318건의 데이터를 학습, 검증, 테스트 각각 6:2:2의 비율로 분할하였다.

각 데이터 세트는 공통적으로 하루 단위로 시계열 특징을 추출할 수 있도록 24시간 단위로 슬라이딩 윈도우 및 값의 범위를 0에서 1사이로 조정하는 Min-Max 정규화가 적용되었다.

3. 실험 결과

가. 복원 결과

실험 결과는 표 1과 같으며, TCN 오토인코더는 낮은 계산 비용이 필요한 GRU 기반의 오토인코더보다 빠른 학습 시간을 보이면서도 시계열 특징을 온전히 학습하여 그림 6과 같이 수렴 속도 또한 가장 빠른 모습을 보였으며, 테스트 데이터를 대상으로 가장 낮은 MSE와 MAE를 획득하여

복원 성능이 가장 뛰어남을 확인하였다.

표 1. 오토인코더(AE) 모델별 복원 성능 비교 결과

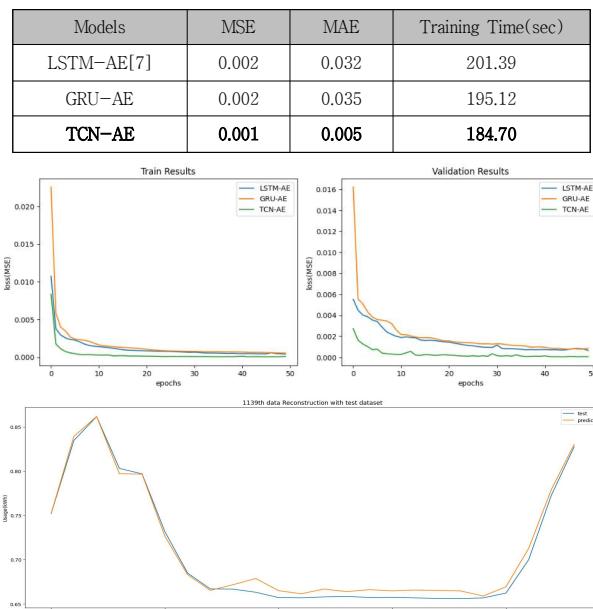


그림 6. 오토인코더 모델별 학습 및 복원 테스트

나. 이상 탐지 결과

테스트 데이터에 대한 이상 탐지 성능 비교 결과는 표 2와 같으며, 검증 데이터를 기반으로 최적의 임계값 및 USAD 계열 모델의 추론에 필요한 가중치를 선택하였다.

표 2 모델별 이상 탐지 성능 비교 결과

Models	Threshold	Precision	Recall	F1-Score
LSTM-AE[5]	0.13	0.52	0.82	0.50
GRU-AE	0.27	0.52	0.81	0.55
TCN-AE	0.07	0.51	0.83	0.44
USAD[9]	0.07	0.50	0.56	0.21
TCN-USAD	0.17	0.58	0.78	0.62

실험 결과 본 논문에서 제안한 TCN-USAD는 오토인코더 기반 모델 대비 높은 Precision, 특히 다른 이상 탐지 모델 대비 20% 개선된 F1-Score를 달성하여 그림 7과 같이 강건한 이상 탐지를 수행할 수 있음을 확인할 수 있었으며, TCN 오토인코더를 활용하여 USAD[9] 대비 시계열 특징을 보다 잘 학습함을 확인하였다.

V. 결 론

본 논문에서는 기존 RNN 기반 오토인코더 및

복원 에러 기반 이상 탐지의 한계를 극복하기 위해 TCN 오토인코더와 USAD 구조를 결합한 TCN-USAD를 제안하였다.

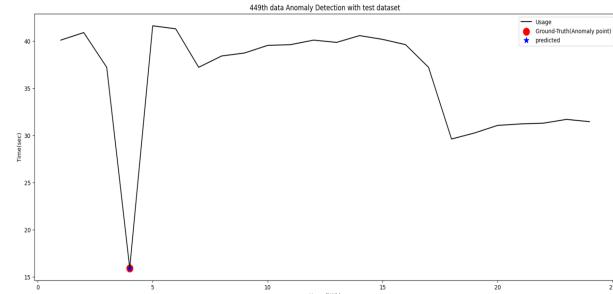


그림 7. TCN-USAD 이상 탐지 테스트

건물 전력 사용량 데이터 세트를 활용한 실험 결과, TCN 오토인코더는 RNN 계열 대비 시계열 특징을 빠르게 학습할 수 있어 효율적으로 학습 및 추론이 가능하며, 두 개의 디코더와 적대적 학습을 적용한 USAD 구조를 결합한 TCN-USAD는 LEAD 1.0 데이터 세트[28] 전체적으로 높은 성능을 달성하였으며, 기존 이상 탐지 모델 대비 약 20% 개선된 F1-Score를 달성하여 시계열 특징을 잘 학습하면서 보다 강건한 이상 탐지가 가능함을 확인할 수 있었고 건물의 전력 이상 탐지를 잘 수행할 수 있는 가능성은 보였다.

향후 연구에서는 모델 구조 고도화 및 다양한 시나리오가 포함된 건물 전력 사용량 데이터 세트를 활용하여 TCN-USAD의 일반화 성능을 검증하고 유효성을 평가할 계획이며, 본 논문에서 제안한 TCN-USAD가 다양한 시스템 보안 관련 연구[29, 30]와의 결합을 통해 전력 이상치 탐지에 유용하게 활용될 수 있을 것으로 기대한다.

REFERENCES

- [1] Global energy consumption driven by more electricity in residential, commercial buildings (2019), <https://www.eia.gov/todayinenergy/detail.php?id=41753> (accessed Jun., 1, 2024).
- [2] Shaikh, Pervez Hameed, et al. "A review on optimized control systems for building energy and comfort management of smart sustainable building

- s," *Renewable and Sustainable Energy Reviews*, vol. 34, pp. 409–429, 2014.
- [3] Pipattanasomporn, Manisa, et al. "CU-BEMS, smart building electricity consumption and indoor environmental sensor datasets," *Scientific Data*, 7.1 (2020): 241.
- [4] Choi, Kukjin, et al. "Deep learning for anomaly detection in time-series data: Review, analysis, and guidelines," *IEEE access*, vol. 9, pp. 120043–120065.
- [5] Zhang, Chuxu, et al. "A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data," *Proceedings of the AAAI conference on artificial intelligence*, Vol. 33. no. 01. 2019.
- [6] Basumallik, Sagnik, Rui Ma, and Sara Eftekharnjad. "Packet-data anomaly detection in PMU-based state estimator using convolutional neural network," *International Journal of Electrical Power & Energy Systems*, vol. 107, pp. 690–702, 2019.
- [7] Hsieh, Ruei-Jie, Jerry Chou, and Chih-Hsiang Ho. "Unsupervised online anomaly detection on multivariate sensing time series data for smart manufacturing," *2019 IEEE 12th conference on service-oriented computing and applications (SOCA)*. IEEE, 2019.
- [8] Choi, Yeji, et al. "Gan-based anomaly detection and localization of multivariate time series data for power plant," *2020 IEEE international conference on big data and smart computing (BigComp)*. IEEE, 2020.
- [9] Audibert, Julien, et al. "Usad: Unsupervised anomaly detection on multivariate time series," *Proceedings of the 26th ACM SIGKDD international conference on knowledge discovery & data mining*, 2020.
- [10] Bai, Shaojie, J. Zico Kolter, and Vladlen Koltun. "An empirical evaluation of generic convolutional and recurrent networks for sequence modeling." arXiv preprint arXiv:1803.01271 (2018).
- [11] Zhang, Chuxu, et al. "A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data," *Proceedings of the AAAI conference on artificial intelligence*, Vol. 33. No. 01. 2019.
- [12] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [13] Yeom, Sungwoong, Chulwoong Choi, and Kyungbaek Kim. "LSTM-based collaborative source-side DDoS attack detection," *IEEE Access*, vol. 10, pp. 44033–44045, 2022.
- [14] 류한일, et al. "충전 특성과 어텐션 기반 LSTM 을 활용한 개선된 리튬이온 배터리 SOH 예측 모델," 스마트미디어저널, 제12권, 제11호, 103–112쪽, 2023년
- [15] 김휘수, 정송현, and 김경백, "어텐션 기반 협업형 소스측 분산 서비스 거부 공격 탐지," *정보처리학회 논문지 (KTSDE)*, 제13권, 제4호, 157–165쪽, 2024년
- [16] Chung, Junyoung, et al. "Empirical evaluation of gated recurrent neural networks on sequence modeling," arXiv preprint arXiv:1412.3555 (2014).
- [17] Gopali, Saroj, et al. "A comparison of TCN and LSTM models in detecting anomalies in time series data," *2021 IEEE International Conference on Big Data (Big Data)*. IEEE, 2021.
- [18] He, Yangdong, and Jiabao Zhao. "Temporal convolutional networks for anomaly detection in time series," *Journal of Physics: Conference Series*, Vol. 1213. No. 4. IOP Publishing, 2019.
- [19] Thill, Markus, et al. "Temporal convolutional autoencoder for unsupervised anomaly detection in time series," *Applied Soft Computing*, vol. 112, 107751, 2021.
- [20] Mo, Ronghong, et al. "Unsupervised TCN-AE-based outlier detection for time series with seasonality and trend for cellular networks," *IEEE Transactions on Wireless Communications*, vol. 2, no. 5, pp. 3114–3127, 2022.
- [21] Yu, Ling-rui, Qiu-hong Lu, and Yang Xue. "DT AAD: Dual TCN-attention networks for anomaly detection in multivariate time series data," *Knowledge-Based Systems*, vol. 295, 111849, 2014.
- [22] Lin, Shuyu, et al. "Anomaly detection for time series using vae-lstm hybrid model," *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Ieee, 2020.
- [23] Zhang, Kexin, et al. "Self-supervised learning for time series analysis: Taxonomy, progress, and prospects," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024.
- [24] Baldi, Pierre. "Autoencoders, unsupervised learning, and deep architectures," *Proceedings of ICML workshop on unsupervised and transfer learning. JMLR Workshop and Conference Proceedings*, 2012.
- [25] Goodfellow, Ian, et al. "Generative adversarial nets," *Advances in neural information processing systems* 27, 2014.
- [26] 전남대학교 건물별 전기사용량 (2021), <https://sisul.jnu.ac.kr/sisul/13422/subview.do> (accessed June, 11, 2024).
- [27] 공공데이터포털 광주시 일별 시간대별 전력거래량 (2023), <https://www.data.go.kr/data/15104326/file>

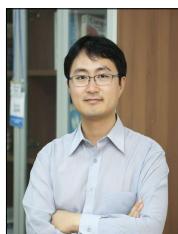
- Data.do (accessed Jun., 11, 2024).
- [28] Gulati, Manoj, and Pandarasamy Arjunan. "LEA D1. 0: a large-scale annotated dataset for energy anomaly detection in commercial buildings," *Proceedings of the thirteenth ACM international conference on future energy systems*, 2022.
- [29] 이윤기, et al. "SDN 을 위한 샘플링 기반 네트워크 플러딩 공격 탐지/방어 시스템," 스마트미디어저널, 제4권, 제4호, 24~32쪽, 2015년
- [30] 김구민, 정송현, and 김경백, "개방형 정책 에이전트 기반 다자간 마이크로서비스 접근체어 정책," 스마트미디어저널, 제12권, 제9호, 60~71쪽, 2023년

저자 소개

**진현석(정회원)**

2023년 전남대학교 전자컴퓨터공학부 학사 졸업.
2023년~현재 전남대학교 인공지능융합학과 석사과정.

<주관심분야 : 인공지능, 모델 최적화, 데이터 분석>

**김경백(정회원)**

1999년 한국과학기술원 전기공학 및 컴퓨터공학 학사 졸업.
2001년 한국과학기술원 전기공학 및 컴퓨터공학 석사 졸업.
2007년 한국과학기술원 전기공학 및 컴퓨터공학 박사 졸업.

2007년~2008년 Network and Distributed Systems Group, Computer Science, University of California Irvine.
2008년~2012년 Information Systems Group, Computer Science, University of California Irvine.
2012년~2016년 전남대학교 전자컴퓨터공학부 조교수
2016년~2021년 전남대학교 전자컴퓨터공학부 부교수
2021년~현 재 전남대학교 소프트웨어공학과/인공지능학부 교수

<주관심분야 : 지능형 분산시스템, SDN/NFV, 빅데이터 플랫폼, 인공지능, 블록체인, 소셜네트워크>