

오토인코더 기반 신호 패턴 변화 감지 기법

주승세, 신학중, 최원규, 조성균, 배지훈*

한국전자통신연구원, *한국교원대학교

wntmdtp01@etri.re.kr, hakjong@etri.re.kr, wkchoi@etri.re.kr, skjo@etri.re.kr, *baejh@knue.ac.kr

Detection of signal pattern changes using Autoencoders

SeungSae Joo, Hakjong Shin, WonKyu Choi, Seng-Kyoun Jo, Ji-Hoon Bae*

Electronics and Telecommunications Research Institute, *Korea National University of Education.

요 약

교량은 사용 수명 동안 지속적인 동적 하중을 받아 피로 파괴에 취약하다. 최근 IoT 기술의 발전으로 센서를 활용한 교량 상태 모니터링이 시도되고 있다. 하지만, 정확한 모니터링은 다수의 센서를 필요로 하며, 이는 설치 및 유지보수 비용을 증가시킨다. 이러한 문제를 해결하기 위해 일부 실물센서를 가상센서로 대체하기 위한 연구가 활발히 진행되고 있다. 가상센서 모델의 성능 및 신뢰성은 환경 및 구조물 상태 변화에 따라 저하될 수 있다. 따라서, 본 논문에서는 데이터 패턴 변화를 통한 가상센서 모델 신뢰성 모니터링 접근법을 제안한다. 제안된 접근법은 실제 교량에서 수집된 가속도 데이터를 활용하여 성능을 검증하였다. 실험 결과, Fully Connected 오토인코더 모델이 약 98.06%의 우수한 정확도 성능을 달성하며, 데이터 패턴 변화를 효과적으로 감지할 수 있음을 보였다.

I. 서 론

교량은 지속적으로 동적 하중을 받기 때문에 피로 파괴에 취약하다[1]. 최근, IoT 기술이 발전함에 따라, 센서를 통한 교량 상태 모니터링이 시도되고 있으며, 가속도 센서는 구조물에서 발생하는 진동을 측정하는 센서로, 교량의 안정성을 평가하는 데 중요한 수단 중 하나로 활용된다[2]. 하지만, 교량의 안정성을 정확하게 모니터링하기 위해서는 다수의 센서를 필요로 하며, 이는, 설치 및 유지보수 비용을 증가시킨다.

가상센서는 물리적 센서 데이터를 입력 받아 측정이 어려운 변수나 위치의 값을 추정하는 기술로, 주로 데이터 기반 학습 모델을 통해 개발된다. 최근에는, 일부 실물센서를 가상센서로 대체하여 설비 비용 절감과 경제성 향상을 위한 연구가 활발히 진행되고 있다[3].

데이터의 발생 패턴은 환경 변화, 구조물 상태 변화 등의 이유로 달라질 수 있다. 데이터의 패턴이 가상센서 모델 훈련 시기와 달라질 경우, 가상센서 모델의 성능 및 신뢰성이 저하된다[4]. 본 논문에서는 데이터 패턴 변화를 감지하여 가상센서의 신뢰성을 평가하기 위한 오토인코더 기반 신호 패턴 변화 감지 기법을 제안하고자 한다.

II. 본론

2.1 데이터 수집 및 전처리


가속도 데이터는 구조물의 상태에 영향을 많이 받는 데이터로, 그 발생 패턴은 오랜 시간에 걸쳐 서서히 변화한다. 이러한 특성을 고려하여, 본 연구에서는 1년 이상의 간격을 두고 2023년 7월 20일과 2024년 8월 21일에 각각 데이터를 수집하였다. 여기서, 2023년 7월의 데이터를 가상센서 모델의 학습 시점 데이터로, 2024년 8월의 데이터를 데이터 패턴이 변화한 시점의 데이터로 간주하였다.

실제 교량에 3축 가속도 센서를 부착하여 100Hz의 샘플링 주파수로 1시


간 동안 약 360,000개의 시계열 데이터를 수집하였다. 수집된 데이터는 분포를 -1과 1 사이의 값을 가지도록 정규화하였으며, 이는 식 (1)과 같다.

$$x_n = \frac{X - \mu(X)}{\max|X - \mu(X)|} \quad (1)$$

여기서, X 는 원본 데이터, $\mu(X)$ 는 X 의 평균, $\max|X - \mu(X)|$ 는 X 의 편차 최댓값, x_n 은 상기 기술된 값들로 정규화된 특성값을 각각 의미한다. 그림 1은 정규화된 데이터를 보여준다.



(a) 10초 구간의 시계열 데이터




(b) 1시간 구간의 시계열 데이터


데이터의 진폭은 교량에 발생한 진동의 크기를 의미하며, 차량 통행 등의 외부 자극이 발생한 경우에 크게 나타난다. 진폭이 작은 구간은 고유 진동

등에 의해 발생하는 노이즈로 해석된다. 본 연구에서는 진폭이 크게 발생하는 구간을 선별하여 Slicing Window 기법을 적용하였으며, 이때 Window 크기를 100, Step을 1로 설정하였다.

2.2 데이터 발생 패턴 변화



(a) 2023년 7월 데이터 FFT 수행 결과



(b) 2024년 8월 데이터 FFT 수행 결과

그림 2. 가속도 시계열 데이터 FFT 분석 결과

오토인코더 모델 학습에 사용한 2023년 7월 데이터를 FFT한 경우, 약 5Hz 미만의 주파수 영역에 주요 성분이 집중되는 반면, 2024년 8월 데이터에서는 15Hz 이상의 주파수 성분이 추가로 관측되었다. 이는 2024년 8월에 수집된 데이터의 발생 패턴이 변화하였음을 의미한다.

2.3 오토인코더 모델 설계

오토인코더는 비지도학습 기반 딥러닝 모델로, 데이터를 압축 및 복원하도록 학습을 수행한다[6]. 본 연구에서는 2023년 7월 데이터로 오토인코더 모델을 학습하고, 재구성 오차를 기반으로 임계치를 설정하여 데이터 패턴 변화를 감지하였다. 임계치는 학습 데이터에 대한 평균 절대 오차의 평균과 표준편차의 합으로 정의된다.

본 논문에서는 Fully Connected, Deep, 1D CNN, LSTM의 네 가지 구조의 오토인코더를 구현하고, 그 성능을 상호 비교 분석한다.

본 연구에서는 오토인코더 모델 학습을 위해 동일한 하이퍼파라미터(에포크 50, 배치사이즈 512)를 사용하였다. 옵티마이저는 Adam을 선택하였으며, 학습률은 Step-dacay 기법을 적용하여 5×10^{-4} 에서 점진적으로 감소시켰다.

2.4 실험 결과

본 논문에서는 오토인코더 모델 학습을 위해 2023년 7월에 수집된 118,608개의 데이터를 사용하였다. 시험 데이터는 데이터 패턴 변화 시점 (2024년 8월)의 데이터 72,977개를 활용하였다.

| Method | Fully Connected | Deep | 1D CNN | LSTM |
|--------------|--------------------|-------|-----------|-------|
| Accuracy (%) | 98.06 | 88.29 | 70.16 | 66.63 |
| F1 Score (%) | 99.02 | 90.09 | 82.46 | 79.97 |

표 1. 오토인코더 모델 구조에 따른 분류 정확도 비교

표 1의 결과에 따르면 Fully Connected 오토인코더 모델이 다른 구조 기반 모델에 비해 뛰어난 성능을 보이는 것을 실험을 통해 확인할 수 있다.




그림 3. Fully Connected 오토인코더 모델

III. 결론

본 논문에서는 오토인코더 기반 신호 패턴 변화 감지 기법을 제안하였다. 제안된 방법은 1년 이상의 시간 간격이 있는 데이터에서 검증되었으며, 오토인코더 모델의 재구성 오차를 기반으로 데이터 패턴 변화를 감지하도록 구성된다.

실험 결과, 네 가지 오토인코더 모델 중 Fully Connected 오토인코더가 약 98.06% 분류 정확도를 달성하며 가장 우수한 성능을 보였다. 이는 본 연구에서 제안한 접근법이 데이터 발생 패턴 변화 감지에 효과적으로 활용될 수 있음을 시사한다.

ACKNOWLEDGMENT

이 논문은 2022년도 정부 과학기술정보통신부 의 재원으로 정보통신기획
평가원의 지원을 받아 수행된 연구임 (No. 2022-0-00591, 디지털트윈 환
경에서 센서 음영구역을 해소하기 위한 가상센서 프레임워크 기술 개발)

참 고 문 헌

- [1] Soheila S. E. et al., "AI-enabled Indirect Bridge Strain Sensing using Field Acceleration Data," *Computers & Structures*, Vol. 305, pp. 1-14, Dec. 2024. doi: 10.1016/j.compstruc.2024.107531.
- [2] Anqi Y. et al., "Bridge Dynamic Displacement Monitoring Using Adaptive Data Fusion of GNSS and Accelerometer Measurements," *IEEE Sensors Journal*, Vol. 21, No. 21, pp. 24359-24370, Nov. 2021. doi: 10.1109/JSEN.2021.3112177.
- [3] Maira A. et al., "Cost Effective Soft Sensing for Wastewater Treatment Facilities," *IEEE Access*, Vol. 10, pp. 55694-55708, May. 2022. doi: 10.1109/ACCESS.2022.3177201.
- [4] Li Y., and Abdallah S., "A Lightweight Concept Drift Detection and Adaptation Framework for IoT Data Streams," *IEEE Internet of Things Magazine*, Vol. 4, No. 2, pp. 96-101, June 2021. doi: 10.1109/IOTM.0001.2100012.
- [5] Dor B. et al., "Autoencoders," arXiv:2003.05991v2, pp. 1-22, Mar. 2020. doi: 10.48550/arXiv.2003.05991.