

신호 변환 기반의 지진 오보 탐지 기술에 관한 연구

윤정은, 문애경, 유은상*, 송윤정

한국전자통신연구원, *라성에너지(주)

yje3058@etri.re.kr, akmoon@etri.re.kr, ecopole@naver.com., yjsong@etri.re.kr,

A Study on Signal Transformation-Based Earthquake False Alarm Detection Technology

Yoon Jung Eun, Moon Ae Kyeong, Yu Eun Sang *, Song Yun Jeong

ETRI., *RaSung Energy Corp.

요약

지진 경보 시스템의 주요 문제점은 실제 지진이 아닌 경우에도 오보 알람이 발생한다는 점으로, 이에 대한 개선이 필요하다. 본 논문은 신호 변환 기반의 특징 추출 방법을 적용한 머신러닝 모델을 제안하여 지진 경보 시스템의 오보를 최소화하는 방법을 제안한다. 실험 결과, 신호 변환 기반 특징을 적용한 데이터셋이 오보 판별과 지진 감지에서 정밀도는 2.58%, 정확도는 1.79% 더 높은 성능을 보여, 이를 통해 모델의 성능을 향상할 수 있음을 확인할 수 있었다.

I. 서론

대한민국은 지진 발생 빈도가 낮지만, 경주와 포항 지진 이후 지진의 위험성이 부각되고 있다. 인구 밀집 지역에서의 지진은 큰 피해를 초래할 수 있어, 이에 대한 철저한 대비와 연구가 필요하다. 특히 지진 경보 알람 시스템의 주요 문제점 중 하나는 공사 소음이나 차량 소음과 같은 외부 요인으로 인해 오보 알람이 발생하는 경우가 많다는 점이다. 이러한 오보 알람은 사용자들에게 혼란을 주고, 실제 지진 발생 시 긴급한 대응을 방해할 수 있다. 따라서 기존 지진 알람 시스템의 오보 알람의 발생을 최소화하고, 실제 지진이 발생했을 때만 정확하고 신속하게 알람을 할 수 있는 기능을 갖추는 것이 중요하여 인공지능을 활용한 다양한 연구가 진행되고 있다[1, 2].

Khan et al.은 실제 지진 데이터와 인간의 움직임이나 센서의 인위적 흔들림으로 생성된 오경보 데이터를 사용해 인공 신경망 모델을 학습하고 평가하여, 72.22%의 정확도를 달성하였다[3]. Perol et al.은 실제 지진 신호와 차량 이동 및 인간 활동으로 인해 발생하는 비지진성 신호를 포함한 데이터를 활용해 CNN 모델을 학습시켰으며, 이를 통해 해당 신호가 실제 지진인지 잡음인지를 분류하는 작업을 수행하여 94.8%의 정밀도를 보였다[4]. 인공 신경망과 CNN은 딥러닝 기반 모델로 모델의 복잡도에 따라 학습 및 예측에 많은 시간이 소요될 수 있다. 따라서 신속한 오보 판별을 위해 본 논문에서는 머신러닝 기반 모델을 활용하며, 성능 향상을 위해 센서의 원본 데이터를 사용하는 것이 아닌 데이터의 특성을 반영할 수 있는 특징을 추출하여 실제 지진 감지 및 오보 판별 모델의 실험 연구를 진행한다.

II. 본론

1. 데이터셋

본 논문에서는 라성에너지(주)의 MEMS 정전 용량형 3축 가속도계를 사용하여 실내 건물의 주요 기둥에 설치된 센서로부터 획득한 x, y, z 축의 가속도 값과 PGA, MMI 값을 데이터로 활용한다. 데이터는 흔들림이 발생하고 전후 30초 동안 수집되며, 샘플링 레이트는 100 SPS(Samples Per

Second)이다. 학습에 사용된 모델의 데이터는 한국 SGS에 설치된 지진 실험 장비를 통해 수집된 실제 지진 데이터와 비지진 데이터로 구분된다. 지진이 아닌 데이터는 센서 설치과정에서 발생한 소음이나 흔들림으로 인한 오보 데이터가 포함되어 있다.

2. 지진 감지를 위한 특징 추출

본 논문에서는 지진 발생 시 신속한 알람을 위해 1초 동안 수집한 데이터로 지진을 판별한다. 그림 2에서는 오보와 실제 지진 발생 시의 가속도 데이터를 비교하였으며 이 두 경우 가속도 값이 $-1000 \sim 1000$ 으로 비슷한 분포를 보이기 때문에, 1초 동안 수집한 가속도 데이터로는 실제 지진과 오보를 구별하기 쉽지 않으므로 데이터의 변환이 필요하다.




그림 1. 실제 지진과 오보인 경우의 가속도 데이터

본 논문에서는 실제 지진을 감지하기 위해 DCT(Discrete Cosine Transform) 변환을 사용하여 데이터의 패턴을 압축하고, 데이터의 주요

특징을 추출하는 방법을 제안한다. DCT는 신호를 시간 영역에서 주파수 영역으로 변환하며, 저주파 성분에 에너지를 집중시켜 고주파 성분을 제거하더라도 중요한 특징을 잘 유지할 수 있다[5]. 그림 2는 DCT 변환된 가속도 데이터를 보여주며 저주파에 큰 값이 분포되어 있음을 알 수 있으며, 그림 1과 달리 지진 발생 여부에 따라 데이터의 값 범위와 패턴이 다름을 확인할 수 있다. 그림 2-(a)의 Frequency Index가 40까지일 때, 그림 2-(b)는 20일 때 각각 전체 데이터 대부분에 해당하는 패턴을 포함하고 있음을 알 수 있다. 따라서 DCT 변환을 통해 데이터의 특징을 압축하는 최적의 범위를 찾아 이를 특징으로 활용할 수 있으며, 관련 식은 (1)에 제시된다.




그림 2. DCT 변환한 가속도 데이터

y_d 는 주파수 영역으로 변환한 데이터, e 는 에너지를 나타낸다. 이때 에너지는 90%로 설정되며, 이를 통해 90%의 특성을 압축하는 변수 k 를 추출하여 모델 학습 시 특징으로 사용한다. 또한, 2-(a)와 2-(b)에서 나타난 DCT 계수 범위의 차이를 반영하여, DCT로 변환된 데이터의 분산 값도 학습에 활용한다.

$$k = \min \left\{ k \in N \mid \frac{\sum_{i=0}^k |y_d[i]|^2}{\sum |y_d|^2} \geq e \right\} \quad (1)$$

DCT로 변환된 데이터뿐만 아니라, 원본 데이터의 특성을 반영하기 위해 1초 동안 수집된 데이터의 최대값, 최소값, 분산을 추출하여 모델 학습에 함께 활용한다. 이때 데이터셋은 2가지로 나누어 실험하며 A는 DCT를 통해 추출된 특징을 포함한 데이터셋이고, 데이터셋 B는 이를 제외한 데이터셋으로, 두 데이터셋의 학습 성능을 비교 분석한다.

3. 지진 판별 모델

2-2에서 추출한 특징을 바탕으로 모델을 학습하기 위해, 지진이 발생하지 않은 데이터를 라벨 0으로, 지진이 발생한 데이터를 라벨 1로 지정하여 학습한다. 각 클래스의 데이터 개수는 동일하게 설정하여 총 34,638개의 데이터를 학습에 사용하며, 데이터는 8:2 비율로 훈련 세트와 테스트 세트로 분할한다. 모델은 머신러닝 기반의 분류 알고리즘인 랜덤 포레스트를 사용하며, 성능 평가와 분석에는 정밀도와 정확도를 지표로 활용한다. 또

한, 처리 시간 성능을 고려하여, 1초 동안 수집된 데이터의 특징 추출 및 예측 처리 시간을 추가적인 지표로 사용한다.

표 1은 학습에 사용되지 않은 데이터를 기반으로 한 모델 성능 평가 결과를 나타낸다. 실험에 사용된 데이터는 클래스 0과 1의 데이터 개수를 각각 4,841개로 동일하게 맞추어, 총 9,682개의 데이터를 사용하였다. 데이터셋 A는 정밀도 97.45%, 정확도 89.73%로, 각각 94.87%와 87.94%를 기록한 B보다 정밀도는 2.58%, 정확도는 1.79% 더 높은 성능을 보였다. 이는 DCT로 추출된 특징을 포함한 데이터셋 A가 모델의 성능을 개선했음을 알 수 있다. 처리 시간 측면에서는 데이터셋 A가 0.017초, B가 0.015초로, 차이는 있지만 두 데이터셋 간 처리 시간은 거의 동일한 수준으로 빠른 처리시간을 보였다.

표 1. 지진 판별 모델 성능 결과

Data	Precision	Accuracy	Time
데이터셋A	97.45%	89.73%	0.017s
데이터셋B	94.87%	87.94%	0.015s

III. 결론

본 논문에서는 지진 경보 시스템의 오보 문제를 개선하기 위해, 머신러닝 기반 모델을 활용하여 지진을 신속하고 정확하게 감지하는 방법을 제안하였다. 연구는 DCT를 사용하여 가속도 데이터의 주요 특징을 추출하고, 이를 바탕으로 랜덤 포레스트 모델을 학습시켜 성능을 평가하였다. 실험 결과, DCT를 적용한 데이터셋 A가 정밀도 97.45%, 정확도 89.73%로, 이를 적용하지 않은 데이터셋 B에 비해 높은 성능을 보였다. 이는 DCT 기반 특징 추출 방법이 오보 판별 및 지진 감지 모델의 성능을 향상할 수 있음을 보여준다. 향후, 모델의 신뢰성을 위해 다양한 상황에서 발생할 수 있는 오보 데이터를 수집하고 모델의 학습과 검증을 진행하고자 한다.

ACKNOWLEDGMENT

본 논문은 안동 중소기업 ICT융합기술경쟁력강화사업(24AD1100)의 연구결과로 수행되었음. 한국전자통신연구원 연구운영지원사업의 일환으로 수행되었음. [24ZD1110, 대경권 지역산업 기반 ICT 융합 기술 고도화 지원사업]

참 고 문 헌

- [1] Chiang, Y. J., Chin, T. L., and Chen, D. Y. "Neural network-based strong motion prediction for on-site earthquake early warning." *Sensors*, 2022.
- [2] Bilal, M. A., Ji, Y., Wang, Y., Akhter, M. P., and Yaqub, M. "An early warning system for earthquake prediction from seismic data using batch normalized graph convolutional neural network with attention mechanism (BNGCNNATT)." *Sensors*, 2022.
- [3] Khan, I., Kim, S. J., and Kwon, Y. W. "Earthquake Detection Using Artificial Neural Networks." *Proceedings of the Korean Institute of Communication Sciences Conference*, pp. 1,575-1,577, Jan. 2019.
- [4] Perol, T., Gharbi, M., and Denolle, M. "Convolutional neural network for earthquake detection and location." *Science Advances*, 4(2), 2018.
- [5] Ahmed, N., Natarajan, T., & Rao, K. R. "Discrete cosine transform." *IEEE transactions on Computers*, 100(1), pp. 90-93. Jan. 1974.