

전리층 총 전자량 데이터에 적용한 LSTM 기반의 지진 이상현상 탐지

조건우, 박동건, 김홍국
광주과학기술원

joungju257@gist.ac.kr, dongkeon@gist.ac.kr, hongkook@gist.ac.kr

LSTM-based Earthquake Anomaly Detection Applied to Total Electron Current Data

Geon Woo Cho, Dong Keon Park, Hong Kook Kim
Gwangju Institute of Science and Technology

요약

본 논문에서는 전리층 총 전자량(TEC, Total Electron Current) 데이터에서의 이상현상을 long short-term memory (LSTM) 기반 모델로 탐지하는 기법을 제안한다. 또한 제안된 방식은 Gaussian mixture model, K-means clustering, 그리고 support vector machine의 기계학습 기반의 기법과 비교한다. 실제 지진 데이터와 비교하여 이상현상 탐지 성능을 비교한 결과, LSTM 기반의 이상현상 탐지 성능이 기존의 기계학습 기반의 성능과 비교하여 F1-score로 약 20% 향상됨을 확인하였다.

I. 서론

전리층 총 전자량(TEC, Total Electron Current) 데이터는 지구 전리층에 있는 전자의 밀도를 나타내는 지표로, 지진과의 상관 관계는 꾸준히 논의되어 왔다[1]. 하지만, 규모 6.0 이상의 지진 중 특정한 사례에 대해서만 분석된 것이 대부분이었다[2, 3]. 본 논문에서는 시계열 데이터 학습에 사용되는 지도 학습 모델 중 하나인 long short-term memory (LSTM)[4] 기반의 모델을 이용한 TEC 데이터에서의 이상현상을 탐지하는 기법을 제안한다. 제안된 기법의 성능은 2016년 1년간 미국에서 지진이 가장 많이 발생한 경도 $-117^{\circ} \sim -120^{\circ}$, 위도 $35^{\circ} \sim 40^{\circ}$ 사이의 TEC 데이터를 이용하여 실제 지진 데이터와 비교하여 평가된다. 또한, 머신러닝 기법 중에 Gaussian mixture model (GMM), K-means clustering, 그리고 support vector machine (SVM) 기반의 기법과도 성능을 비교한다.

II. 본론

2.1 TEC 데이터

TEC 데이터는 NOAA에서 2016년 1월 1일 0시부터 12월 31일 24시까지 15분 간격 (총 35040개), 위도와 경도를 1도 간격으로 관측한 것을 사용하였으며[5], 위도, 경도 별로 관측된 TEC 데이터들에 평균을 취한 후 이용하였다. 단위는 $10 \text{ TECU} = 10^{17} \text{ electrons/m}^2$ 이다. TEC 데이터는 태양 활동에 영향을 크게 받아 계절별 분포 차이가 크기 때문에, 학습 정확도 향상을 위해 1~3월, 4~6월, 7~9월, 10~12월 4분기로 나누어 사용하였고, 전체 데이터를 학습시킨 결과와 비교하였다.

전체 TEC 데이터의 70%를 학습 데이터, 나머지 30%를 평가 데이터로 분리하였다. [3]의 연구에서는 지진 발생 이전 3일 안에 TEC 데이터에서 두드러지는 변화가 나타남을 보인 반면, 본 연구에서는 규모 4.5

이상의 지진에 대한 정보를 이용하였기에 본진이 끝난 후에도 여진이 있을 것을 감안하여 지진 전후로 3일을 이상현상으로 레이블링하였다.

2.2 방법론

2.2.1 K-means Clustering

전체 데이터에 대해 군집의 수를 1개부터 늘려가며 elbow point로 군집의 개수를 6개로 정하였다. K-means clustering 기법을 통해 6개의 군집을 형성한 후, 군집들의 중심으로부터 가장 먼 거리에 위치한 군집에 속한 데이터들을 이상현상으로 분류하였다.

2.2.2 One-class Support Vector Machine

One-class SVM에 기반한 학습 기법을 적용해 정상 학습 데이터에 대한 경계를 학습한 후, 전체 데이터를 넣어 학습된 경계 밖에 있는 데이터들을 이상현상으로 판별하였다.

2.2.3 Gaussian Mixture Model

전체 혼합 개수를 3개로 설정한 후, expectation-maximization (EM) 알고리즘을 이용하여 정상 데이터에 대한 확률 분포를 추정하였고, 문턱치보다 높은 확률 값을 가지는 데이터들을 이상현상이라고 탐지하였다.

2.2.4 Long Short-Term Memory Model

70%의 학습 데이터 중 정상 데이터만 선택하여 LSTM이 정상일 때의 분포를 예측할 수 있도록 학습시켰다. 학습된 파라미터를 이용해 10단계 예측값을 도출하였고, 예측된 결과를 바탕으로 다음과 같은 Mahalanobis distance 기반의 anomaly score를 정의하였다.

$$\text{Anomaly Score} = (e^{(i)} - \mu)\Sigma^{-1}(e^{(i)} - \mu)^T \quad (1)$$

여기서, μ 와 Σ 는 평균 및 공분산을, e^i 는 i (범위: 0~35039)번째 index 에서의 오차를 의미한다. 식 (1)의 anomaly score 가 문턱치 값보다 높은 값을 가지고 있으면 이상현상이라고 판별하였다.

2.3 실험 및 성능 평가

데이터들을 학습시킬 때, 잡음이 약간 섞인 데이터에 대해서도 비슷한 결과를 얻을 수 있도록 아래와 같은 데이터 증강 기법을 적용하였다.

표 1. 잡음 인가 기반의 데이터 증강 기법

데이터 증강 기법	
1:	Total data = {Original data}
2:	Noise $\sim N(0,1)$, $i = 0$
3:	While $i < 0.05$
4:	Total data $\leftarrow$ Original data + $\sigma \times \text{Noise} \times i$ (σ 는 Original data 의 표준 편차)
5:	$i = i + 0.0005$

LSTM 의 학습 결과에 대한 예시는 그림 1 과 같다. 초록색 그래프는 1 단계 예측에 대한 결과이고, 파란색 그래프는 이전 단계에 대한 값을 주지 않고 재귀적으로 예측한 결과로, 정상 데이터에 대한 모델의 학습 정도를 확인할 수 있다.




그림 1. LSTM 기반의 TEC 데이터 예측 (target0: 본 데이터, 전체 데이터 번호의 범위: 0~35039)

LSTM, K-means clustering, SVM, GMM 을 이용해 이상 현상을 탐지한 결과에 대한 예시는 그림 2 와 같다.




그림 2. LSTM, K-means clustering, SVM, GMM 기반의 이상현상 탐지 성능 비교

전체 데이터 35,040 개 중 이상현상이라고 표기된 값은 총 5,159 개로, 이상현상의 개수에 비해 정상일 때의 개수가 많은 불균형 데이터이기에, 정확하게는 예측 결과에 대한 분석을 정확하게 할 수 없었다. 따라서 precision 과 recall 의 조화 평균에 해당하는 F1-score 를 이용해 예측 결과를 분석하였다. LSTM 에서의 F1-score 는 anomaly score 에 대해 임의의 문턱치 값을 잡았을 때 얻어지는 F1-score 중 가장 큰 값으로 하였다. 예측 결과는 표 2 와 같다.

표에서 보는 바와 같이, F1-score 측정 결과, LSTM 기반의 기법의 F1-score 가 기존의 기계학습 기반의 기법보다 높고, 계절별 학습에 대해서는 LSTM 기반 기법이 이상현상을 F1-score 로 약 20%만큼 잘 예측하고, 전체 데이터에 대한 학습에서는 이상현상을 약

10%만큼 잘 예측함을 확인할 수 있었다. 또한, LSTM 을 이용해 학습시킬 시, 전체 데이터를 모두 학습시킨 기법에 비해 데이터를 계절별로 따로 학습시킨 기법이 이상현상을 약 15%만큼 잘 예측함을 확인할 수 있었다.

표 2. 각 기법별 단일모델과 계절별 모델의 F1-score 비교

Method	단일 모델	계절별 모델			
		spring	summer	autumn	winter
K-means	0.000	0.016	0.005	0.017	0.011
GMM	0.033	0.031	0.001	0.011	0.013
SVM	0.031	0.009	0.000	0.004	0.032
LSTM	0.121	0.197	0.218	0.223	0.378

III. 결론

본 논문에서는 TEC 데이터에서의 이상현상 탐지를 위해 제안된 LSTM 기반의 기법의 F1-score 가 GMM, K-means clustering, 그리고 SVM 에 비해 좋음을 확인하였다. 또한, TEC 데이터의 계절별 분포 차이가 있음을 각 계절별 F1-score 를 통해 간접적으로 확인할 수 있었다. 하지만, LSTM 기반 기법의 F1-score 가 상대적으로는 높지만 절대적인 수치를 봤을 때 이상현상 탐지를 효율적으로 하지는 못함을 확인할 수 있었다. 이는 disturbance storm time (Dst) 지수, K(George) 지수에 의해 발생하는 잡음이 지진에 의해 발생하는 TEC 데이터의 변화보다 더 크거나 불규칙하게 발생할 때가 많아 학습이 제대로 이루어지지 않아 그런 것으로 판단된다. 추후 규모가 큰 지진이라는 제약을 두어 잡음의 영향을 상대적으로 줄이고, Dst, K 지수 등을 활용한 잡음제거 기법을 도입하는 등의 학습 방법을 도입해 LSTM 기반의 이상현상 탐지 기법의 성능을 높이려 한다.

ACKNOWLEDGMENT

본 연구는 광주과학기술원 전기전자컴퓨터공학부 오디오지능연구실 인턴십의 결과이며, 2020 년도 광주과학기술원 GRI(GIST 연구원)의 지원을 받아 수행된 연구임.

참 고 문 헌

- [1] M. Hayakawa, "Earthquake prediction with electromagnetic phenomena," in *Proc. AIP Conference*, vol. 1709, no. 1, p. 020002, 2016.
- [2] W. Liu and L. Xu, "Statistical analysis of ionospheric TEC anomalies before global $M_w \geq 7.0$ earthquakes using data of CODE GIM," *Journal of Seismology*, vol. 21, no. 4, pp. 759-775, 2016.
- [3] J. Y. Liu, Y. I. Chen, Y. J. Chuo, and H. F. Tsai, "Variations of ionospheric total electron content during the Chi-Chi earthquake," *Geophysical Research Letters*, vol. 28, no. 7, pp. 1383-1386, 2001.
- [4] P. Malhotra, A. Ramakrishnan, G. Anand, L. Vig, P. Agarwal, and G. Shroff, "LSTM-based encoder-decoder for multi-sensor anomaly detection," arXiv:1607.00148, 2016.
- [5] N. G. D. Center, "Real-time US-Total Electron Content: Vertical and Slant" *NOAA National Centers for Environmental Information* (NCEI), 11-Jul-2006. (<https://www.ngdc.noaa.gov/stp/iono/ustec/products/>)