

통신 구조물 AI 안전 감시에 관한 연구

김나연, 서민성*, 한진우*, 강왕규*

에이치포테크, *kt

nykim@h4tech.co.kr, *shilla@kt.com

A Study on AI Approach to FBG Sensors for Telecommunication Infrastructure Safety Surveillance

Kim Na Yeon, Seo Min Sung*, Han Jin Woo*, Kang Wang Gyu*

h4tech, *KT


요약

본 논문은 통신구조물 안전 감시를 위해 전원이 필요없는 FBG(Fiber Bragg Grating) 광센서들을 적용했으며, FBG 센서들로부터 수집된 온도 데이터는 LSTM 신경망으로 학습하여 실시간 화재 예측 및 이상 탐지 가능한 모델을 제안했으며, 가속도, 기울기, 변형율, 균열 등의 데이터로는 잔존 수명 및 유지보수 시기를 예측할 수 있는 머신러닝 모델을 제안하였다.

I. 서론

본 논문에서는 전진 배치된 통신장비와 통신구조물의 안전 감시를 위해 FBG(Fiber Bragg Grating) 광센싱을 적용하고, 그 데이터를 인공지능으로 분석하여, 화재 예측, 통신구조물의 노후화 정도를 예측하여 잔존 수명과 유지보수 예상 시기를 예측하는 연구를 했다.

통신 장비의 소형화로 전화국에서 고객 가까이로 통신 장비들이 전진 배치되면서, 통신 장비와 구조물에 대한 안전 감시가 필요해졌다. 대부분의 센서들은 전기 또는 배터리를 공급해야 하지만, 이는 화재 발생으로 이어질 수 있기 때문에, 전원을 사용하지 않으면서 통신구조물의 안전진단을 할 수 있는 대표적인 센서인 FBG 센서를 통신구조물 안전 감시에 적용했다. 대표적인 광센싱 기술로는 FBG, DAS(Distributed Acoustic Sensing), DTS(Distributed Temperature Sensing)가 있다. FBG는 구조물 안전과 온도 측정에 많이 사용되며, DAS는 침입감지와 통신선로, 송유관, 송수관 감지와 지진 모니터링에 많이 사용되며, DTS는 넓은 지역의 온도 측정에 사용되고 있다.



(그림 1) FBG 원리

FBG 기술의 기본 원리는 (그림 1)에서와 같이 프레넬 반사이다. FBG는 광대역 적외선 (IR) 광원 (일반적으로 약 1510-1590nm)으로 조명되며 코어에서 이동하는 빛이 서로 다른 굴절률, 즉 브래그 격자에 도달하면 빛은 반사되고 굴절된다. 반사된 파장을 브래그 파장 (λ_B) 이라고 하며, 브래그 격자 Λ 가 열 또는 Strain에 의해 브래그 파장 (λ_B)이 변화하며 이것은 방정식으로 정의되어, 온도나 변형율 등을 계산할 수 있다.[1]

광센싱 데이터는 일반적으로 IoT 센서의 데이터들보다는 많은 양의 데이터를 생성하는 것이 특징이며, 국내에서는 아직 광센싱 데이터의 분석에 인공지능 알고리즘의 적용 사례가 드물지만, 해외에서는 광센싱 데이터를 Machine Learning으로 분석하는 사례가 빈번하다.[2, 3, 4]

II. 본론

전진 배치된 통신구조물에 온도, 가속도, 변형율, 균열 등의 FBG 센서로부터 센싱된 데이터들을 <표1>과 같은 방법으로 실시간 모니터링과 인공지능 분석을 하고 있다. 각 센서에서 발생된 데이터에 대해 임계값 기준으로 실시간 감시하고 있으며, 화재는 발생하면 통신장비와 구조물에 치명적인 영향을 주므로 LSTM(Long Short-Term Memory) 신경망을 통해 실시간 예측 및 이상감지를 하고 있으며, 가속도, 기울기, 변형율 데이터는 Machine Learning으로 수명예측, 즉 잔존예측을 할 수 있게 알고리즘을 적용하고 있으며, 균열 데이터로는 보수보강 시기를 예측할 수 있도록 알고리즘을 적용하고 있다.

<표 1> FBG 센서의 실시간 감시기준과 인공지능 적용

| FBG 센서 | 관리 지표 | 실시간 판단 기준 (임계값) | 인공지능 적용 |
|--------|------------|----------------------------------|------------------------------------|
| 온도 | 온도 상승 | 섭씨35도 이상 경계, 섭씨40도 이상 심각 | 실시간 화재 예측 (LSTM) |
| | 화재 | 섭씨70도이상 또는 1분에 7도이상 상승 | |
| 가속도 | 진동발생 | 100gal 이상, 지진전후 감시 | 손상(잔존가치)예측 (Fbprophet(sklearn) ML) |
| | 철가변형발생 | 0.15도 이상 경계, 0.2도 이상 심각, 지진전후 감시 | |
| 기울기 | 수명예측 | | 손상(잔존가치)예측 (Fbprophet(sklearn) ML) |
| | 변형정도 | 100μm 경계, 200μm 심각, 지진전후 감시 | 손상(잔존가치)예측 (Fbprophet(sklearn) ML) |
| 변형율 | 수명예측(잔존예측) | | |
| | 균열발생 | 1mm 경계, 1.2 mm심각, 지진전후 감시 | 보수보강시기 예측 (Fbprophet(sklearn) ML) |
| | 보수보강시기예측 | | |
| 점수 | 일시적 | on / off | |

LSTM 신경망의 기본 적인 구조는 순환 신경망과 동일하나 은닉 상태 (Hidden State)와 셀 상태(Cell State) 두 가지를 가지고 있다. 새로운 Cell State(c_t)는 식(1)과 같으며, 여기서 f_t 는 Forget Gate(f_t), i_t 는 nput Gate를 의미하며, p 는 이전 셀의 은닉 상태 (h_{t-1})와 현재 입력 값(x_t)에 가중치를 곱한 선형 계산의 결과이다.

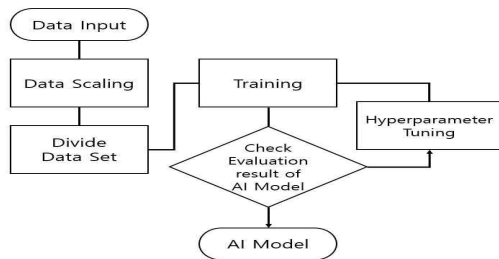
p의 첨자가 다른 이유는 각기 다른 가중치 행렬이 적용되기 때문이다.

$$\begin{aligned} c_t &= f_t + i_t \\ f_t &= c_{t-1} \times \text{sigmoid}(p_f) \\ i_t &= \text{sigmoid}(p_i) \times \tanh(p_i) \end{aligned} \quad (1)$$

새 Hidden State(h_t)의 계산은 식(1)에서 나온 현재 Cell State(c_t)에 하이퍼볼릭 탄젠트 활성화 함수를 적용하며 p에 시그모이드 활성화 함수를 적용한 것을 곱해서 구한다.


$$h_t = \tanh(c_t) * \text{sigmoid}(p_o) \quad (2)$$

온도 시계열 데이터 학습 과정에 사용한 샘플 데이터는 약 1주일(2021년 4월 22일 ~ 2021년 4월 29일)간의 10분 통계 데이터로 약 1,000개의 데이터를 가지고 (그림 2)와 같은 절차로 학습을 하여 모델을 만들었다.



(그림 2) LSTM 학습과정

Data Scaling은 MinMaxScaler를 사용하여 데이터의 최대값을 1.0, 최소값은 0.0을 기준으로 하여 각 데이터들을 0과 1사이 값으로 변환시켰다. 총 데이터 수의 70%는 학습 데이터, 나머지 30%에서 검증 데이터와 테스트 데이터에 각 15%씩 나누어 사용했다. 학습 초기 Batch size로는 LSTM 모델 특성상 1로 설정하며 TimeStamp로는 6으로 설정한다. 손실 함수로는 평균 제곱 오차 (MSE : Mean Squared Error)로 설정 하며 최적화 함수로는 Adam으로 설정했으며, 모델의 과적합을 막기 위해 Drop Out 값을 0.3으로 설정한다. 모델의 평가 지표는 MAPE(Mean Absolute Percentage Error) 값을 사용했다. 학습을 진행한 결과 (그림 3)의 MSE 값의 변화 그래프와 같이 epoch는 69번째에서 종료되었으며 손실 함수에 적용한 MSE값은 큰 변화 없이 일정하게 나오는 것을 확인할 수 있다. 학습된 모델의 신뢰도 평가지표인 MAPE의 10%가 넘지 않는 것을 확인할 수 있었다.




(그림 3)MSE 값의 변화(좌)와 예측 결과(우)

최종적으로 테스트 데이터셋을 사용하여 예측한 결과, (그림 3)에서와 같이 실제 데이터와 예측 결과의 변화 패턴이 같았으며, 예측 값과 실제 데이터의 소수점 이하 자리에서 차이가 나는 것을 확인할 수 있었다. 가속도, 기울기, 변형률 데이터로 잔존예측하고 균열 데이터로 보수보강 시기를 예측하기 위해 FBprophet을 머신러닝 알고리즘을 적용했다. FBprophet 알고리즘은 시계열 예측을 위해 알고리즘으로 식(3)과 같다.[5]

$$y(t) = g(t) + s(t) + h(t) \quad (3)$$

함수 $g(t)$ 는 Growth 즉, 시계열에서 비주기적 변화를 모델링하는 추세 함수, $s(t)$ 는 Seasonality, 즉 주기적 변화, $h(t)$ 는 Holidays, 즉 주기성은 없지만 전체 추이에 큰 영향을 주는 이벤트를 나타내는 함수이다. FBprophet은 일변량 데이터만 적용 가능하며, 알고리즘 Model fitting은 MAP(Maximum a Posterior)와 MCMC(Markov Chain Monte Carlo) 방식 중에 선택하여 fitting하고, 미래 Dataframe 생성하고 예측하여 결과를 확인한다.



(그림 4) 변형률 예측결과(좌)와 기울기예측(우)

(그림 4)의 변형률과 기울기 예측결과와 MAP 방식으로 모델링한 결과이다. 변형률과 기울기의 경우 예측된 결과 값이 상승하면, 통신 구조물의 손상을 뜻한다. 균열의 경우도 예측 결과가 상승하면 유지보수를 필요로 하며, 가속도의 경우 예측 결과 값들이 하향하면 구조물의 손상을 뜻한다. FBprophet의 경우 대량의 데이터로 장기간 예측이 가능하므로 향후 3개월 또는 6개월 이상의 기간을 예측을 할 수 있도록 모델의 정확성을 높일 계획이다.

III. 결론

본 논문에서는 통신구조물 안전 진단과 온도 측정에 FBG 센서를 적용했으며, FBG 센서 데이터 분석에 인공지능 모델을 적용하여 센서 데이터를 예측하는 모델을 제시했다. FBG 센서 데이터 중, 온도 데이터는 LSTM 신경망으로 화재 예측 및 온도 이상을 찾을 수 있는 모델을 제안했으며, FBprophet를 활용하여 가속도, 기울기, 변형률, 균열 등의 데이터로 통신 구조물의 잔존 수명예측과 유지보수시기 예측 모델을 제시했다. 향후, FBprophet의 MAP모델과 MCMC모델로 각각 결과 예측을 해보고, 정확도를 평가해볼 계획이며, LSTM 신경망의 경우 3개월 정도의 온도 데이터를 확보하여 지속적인 학습을 통해 MAPE 2% 이내로 정확도를 높일 계획이다.

ACKNOWLEDGMENT

.이 성과는 kt 재원으로 kt 인프라연구소와 공동으로 수행된 연구 결과입니다.

참 고 문 헌

- [1] Eric Pinet, "Temperature fiber-optic point sensors: Commercial technologies and industrial applications," MIDEM Conference 2010.
- [2] Payam Kavousi Ghahfarokhi, "A Fiber-optic Assisted Multilayer Perceptron Reservoir Production Modeling: A Machine Learning Approach in Prediction of Gas Production from the Marcellus Shale," Unconventional Resources Technology Conference 2018.
- [3] Javier Tejedor, "Machine Learning Methods for Pipeline Surveillance Systems Based on Distributed Acoustic Sensing: A Review," Applied sciences Vol. 7 Issue 8, 2017.
- [4] Emre Sahinoglu, "Machine Learning Approach to Distributed Acoustic Sensors(DAS) for Securing Pipelines In Urban Areas," ptj pp. 38-42, 2020.
- [5] Benjamin Letham, "Forecasting at Scale," Peerj Sep. 2017.