

Long-Short Term Memory기반 구조물의 손상 데이터 예측

Damage data prediction for structures based on

Long-Short Term Memory

정도영¹

Do-Young Jung¹

요 약

콘크리트 구조물과 건축물의 상태를 실시간으로 관측하고 미래의 상태를 예측하는 것은 구조물의 이용자의 안전과 직관되어 있으며, 이를 위한 모니터링 및 예측 기술의 접목이 필요한 시점이다. 본 연구에서는 딥러닝을 활용한 Anomaly detection을 제안하고 LSTM(Long-Short Term Memory) 기반의 구조물 손상데이터 예측방법을 연구하였다. 3개의 IoT 디바이스를 제작하여 Office 건물 지하 공용공간 및 휴게공간에 설치하였다. 한달 이상 데이터를 수집하였고 학습결과 다음의 세가지를 확인하였다. Input feature와 동일 디바이스의 동일 속성 값을 예측한 case에서는 매우 높은 정확도를 보였으며, 동일 디바이스에서 얻은 Input feature 중 예측 속성 이외의 속성을 학습하였을 경우에도 제한적이지만 패턴을 유추할 수 있었다. Multi device의 Input feature로 학습한 경우에도 매우 높은 정확도로 예측하였다. 온도, 습도, 밝기 데이터 학습을 통해 만들어진 모델을 활용하고 예측에 대한 오차 기준에 threshold 값을 설정하여 Anomaly analysis가 가능 할 것이다.

핵심어 : 구조물, 손상, IoT, LSTM, Anomaly analysis

Abstract

Observing the condition of concrete structures and buildings in real time and predicting their future condition is directly related to the safety of the users of the structure, and it is time to incorporate monitoring and prediction technology for this purpose. In this study, we proposed anomaly detection using deep learning and studied a structural damage data prediction method based on LSTM (Long-Short Term Memory). Three IoT devices were manufactured and installed in the underground common space and lounge area of the office building. Data was collected for more than a month, and the following three learning results were confirmed. In the case where the input feature and the same attribute value of the same device were predicted, very high accuracy was shown, and even when attributes other than the predicted attribute were learned among the input features obtained from the same device, patterns could be inferred, although limited. Even when learning with input features of multi devices, predictions were made with very high accuracy. Anomaly analysis will be possible by using a model created through learning temperature, humidity, and brightness data and setting a threshold value for the error standard for prediction.

Keyword : Structural, Damage, IoT, LSTM, Anomaly analysis

¹ Department of Highway and Transportation Research, KICT, Gyeonggi-do, Korea [Principal Researcher]
e-mail: bkkim@kict.re.kr

Received(November 16, 2023), Review Result(1st: November 30, 2023), Accepted(December 8, 2023), Published(December 31, 2023)

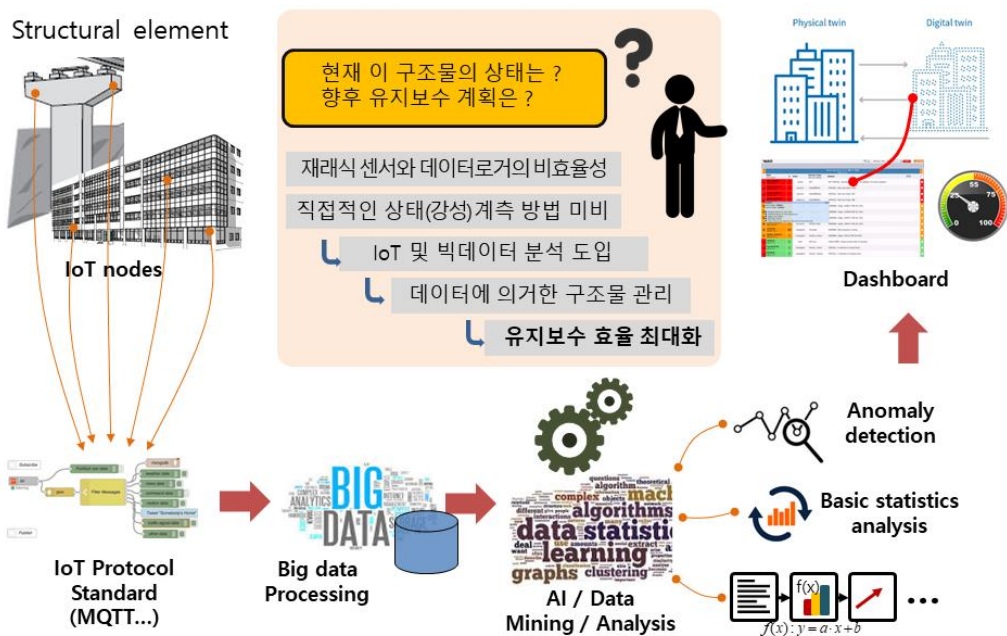


© 2023 The Authors. Published by NCISS.
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

1. 서론

콘크리트 구조물과 건축물의 상태를 실시간으로 관측하고 미래의 상태를 예측하는 것은 구조물의 이용자의 안전과 직관되어 있으며, 이를 위한 모니터링 및 예측 기술의 접목이 필요한 시점이다. 실제 교량, 포장 등의 콘크리트 도로 시설물의 모니터링 수요가 있으나 광범위한 구조물에 대한 모니터링을 수행하기에 알맞은 기술이 제공되지 않고 있다. 이러한 요구에 맞게 건축물의 모니터링 시장도 확대될 것으로 전망되고 있는 상황으로 이에 상응하는 IoT 활용 기술의 개발이 필요하다 [1]. 또한 2023년 5월 ‘시설물의 안전 및 유지관리에 관한 특별법 시행령’이 개정되어 토목분야 3종 시설물의 경우 안전진단 및 모니터링이 의무화되었다. 그 규모는 건축물 5,879건, 공동주택 1,914건, 그 외 3,965건으로 매우 크다.

다음 [그림 1]과 같이 구조물에서 수집한 데이터를 활용한 손상 진단과 예방이 가능하며 이 중 수집 데이터를 이용한 분석과정이 필요하다. 본 연구에서는 딥러닝을 활용한 Anomaly detection을 제안하고 LSTM(Long-Short Term Memory) 기반의 구조물 손상데이터 예측방법을 연구하였다.



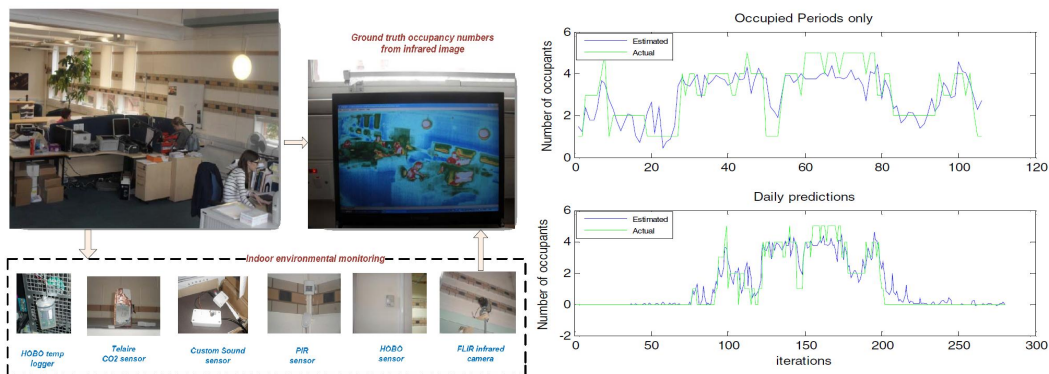
[그림 1] IoT 기반 구조물의 예방적 손상 진단 개요도

[Fig. 1] Schematic diagram of preventive damage diagnosis of IoT-based structures

2. 구조물 손상 진단 문헌 고찰

IoT로 수집한 데이터와 Anomaly analysis 관련해서 활발한 선행연구가 진행되고 있다. Anomaly detection은 outlier detection 이라고 할 수 있으며, 데이터베이스에서 일반적이지 않은 데이터를 찾아내는 것이다 [2]. Anomaly analysis 방법들은 (1)통계적인 분류방법, (2)Kernel based 기계학습, (3)probabilistic graphical modeling, (4) Neural Networks, (5) Data mining and Clustering 이고, 그 중에 서도 Deep neural network 방법들이 매우 강력하다 [3].

실제 연구에 적용한 다양한 사례들이 있다. 온도, CO2농도, 움직임을 수집하여 Neural network 방법으로 점유정보를 예측한 결과는 적외선카메라로 촬영한 ground-truth 데이터와 비교하여 75% 정확도를 다음 [그림 2]와 같이 달성하였다 [4].



[그림 2] IoT 기반의 데이터 예측 사례

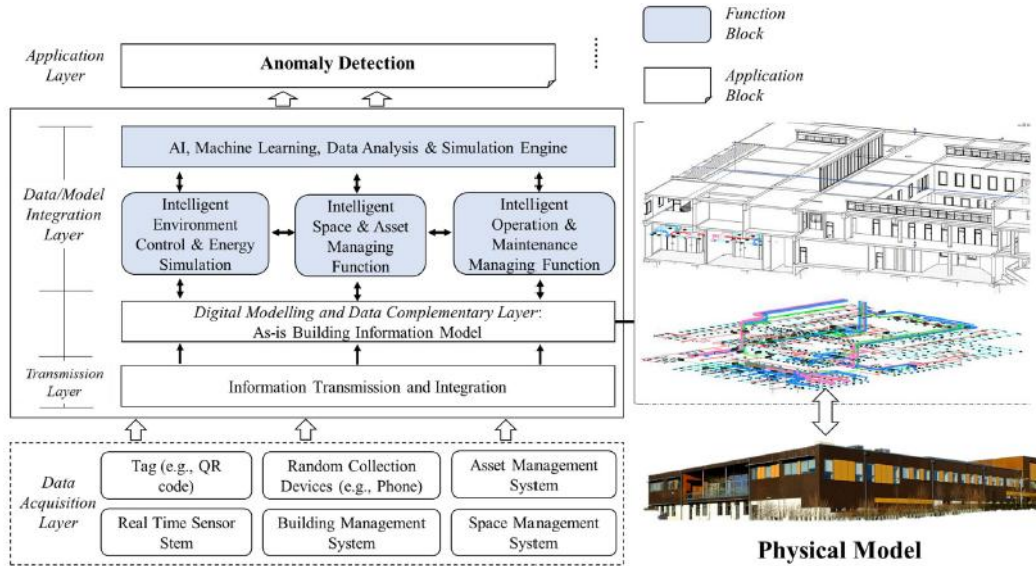
[Fig. 2] IoT-based data prediction case

조도, 온도, 습도, CO2 데이터를 통계적-분류모델을 활용하여 점유여부를 분석하였는데 온도데이터만 활용한 모델의 경우가 85%, 83%로 점유 예측 정확도가 가장 높다 [5].

polynomial regression and Gaussian distribution을 적용하여 학교의 전력 사용에 대해 Anomaly detection을 한 사례가 있다 [6]. 건물의 에너지 소비에 대해 Anomaly detection framework를 하고 ANN을 이용해서 에너지 소비를 예측한 연구가 수행되었다 [7]. ‘Energy-use per person (K)’이라는 parameter를 제안하고, Deep neural network 알고리즘으로 occupancy를 통해 K를 예측한 연구처럼 건축물의 에너지 분야에서 에너지 사용을 예측하기 위해서 Anomaly detection이 활발하게 연구되고 있다 [8].

Facility management를 위해 Bayesian change point detection을 적용하는 Anomaly detection process를 제안하고 AMI(Advanced Metering Infrastructure) 데이터로 딥러닝하여 building occupancy detection

framework를 제안한 연구가 수행되었다. 실내의 온도 조절을 위해 CO2 와 온도 정보에 machine learning 방법으로 Anomaly detection 한 연구는 다음 [그림 3]과 같이 Anomaly detection, 프라이버시에 영향이 적은 데이터를 기반으로한 occupancy detection을 한 대표적인 선행연구이다 [9].



[그림 3] Facility management 분야에 Anomaly detection을 활용한 사례

[Fig. 3] Case study using Anomaly detection in the field of facility management

3. 데이터 수집을 통한 LSTM(Long-Short Term Memory) 학습

3.1 데이터 수집


데이터 수집을 위하여 ESP8266기반의 NodeMCU에 각종 센서와 디스플레이를 연결하여 IoT디바이스를 제작하였다. ESP8266 칩셋은 TCP/IP 스택을 지원하는 Wi-Fi 기능을 포함하는 마이크로컨트롤러이다. Wifi 게이트웨이가 잘 구성되어 있는 실내에서 활용하는 IoT 디바이스 용도로 적당하다. IoT 디바이스를 구성하는 센서 모듈은 [표 1]과 같다. 온습도 센서로는 DHT22 모듈을 사용하였다. 온도의 경우 $-40\sim 80^{\circ}\text{C}$ 범위를 0.1°C 단위로 측정할 수 있고 $\pm 0.5^{\circ}\text{C}$ 의 정밀도를 갖는다. 상대습도는 $0\sim 100\%$ 의 범위를 0.1% 단위로 측정하고 $\pm 2\%$ 의 정밀도를 갖는다. 밝기는 CdS(황화카드뮴) 센서모듈을 이용해서 측정하였다. 밝기를 1024단계로 나타낼 수 있으며, 제사한 사양은 [표 1]과 같다.

[표 1] 데이터 수집용 IoT의 센서 구성

[Table 1] IoT sensor configuration for data collection

Module	Part	Feature
NodeMCU	Micro Controller	ESP8266 (WiFi) Memory : 128kBytes Storage : 4MByte
OLED	Display	128 x 64, I2C
DHT22	Temperature, Humidity Sensor	-40~80℃ ($\pm 0.5^{\circ}\text{C}$) 0~100%RH ($\pm 2\%\text{RH}$)
CdS	Illuminance sensor	10 bits resolution

다음 [그림 4]와 같이 프로토타입 디바이스를 제작하였다. 앞서 설명한 각 모듈을 연결하고, 3D 프린터로 케이스를 제작하였다. 케이스는 가로 x 세로가 6.5cm x 6.5 cm의 정사각형이고 높이가 2.5cm이다. 전원은 1000mAh 용량의 배터리를 사용했을 때 약 6시간 동안 작동하였다.




[그림 4] IoT 디바이스 제작

[Fig. 4] IoT device production


3개의 디바이스가 지하 1층에 위치한 공용공간에 설치되었다. 설치 위치는 [그림 5]와 같다. 지하 1층이지만 외부와 통하는 유리문이 있어서 제한적이지만 햇빛이 들어온다. 디바이스 1과 3은 같은 공간에 위치하고 있고 디바이스2는 유리벽으로 나뉘어져 있어서 온도와 습도는 서로 차단되어 있지만 밝기는 서로 영향을 준다. 디바이스는 약 1m 높이에 설치될 수 있도록 식수대위, 책꽂이 선반, 조형물 틈에 설치하였다.

2023년 8월 10일부터 9월 12일까지 약 한달간 1 sample per min의 sample rate로 각 디바이스의 속성별로 53,900 record를 수집하였다. [그림 6]은 Device 1 에서 온도와 RH를 수집한 결과이다. 여름철 에어컨 작동에 따라 주중 업무시간에 온도가 낮아지는 weekly pattern을 확인 할 수 있다. Device 2와 3에서 수집한 온도 습도의 경우 센서 문제로 censored 된 부분이 있어서 딥러닝 학습 데이터로 활용하지 않았다.



[그림 5] 디바이스 설치 위치

[Fig. 5] Device installation location




[그림 6] 온도와 습도 수집 결과

[Fig. 6] Temperature and humidity collection results

[그림 7]은 3개의 디바이스에서 수집한 밝기 값이다. 밝기는 가장 밝은 값인 0 에서부터 1024 단계로 나타낸 값으로, 우선 상대 밝기 값이 256 이하로 내려간 부분은 공간의 조명이 켜져 있는 상

태이다. 사용자들이 공간을 이용하고 있는 상태이다. 768 이하의 밝기는 복도의 빛이 유리를 통해서 들어온 정도의 밝기이다. 주중에는 복도가 밝았으나 주말에는 복도불도 꺼졌고, 외부와 연결된 유리문의 채광에 따라 밝기가 미세하게 바뀌었다. 밝기는 매우 정밀하고, 공간의 상태를 높은 신뢰도로 나타낼 수 있다. 딥러닝 시에 데이터는 scaling 과정을 거치므로, Lux 와 같은 단위로 변환하지 않은 제한사항이 있다. 하지만, 각 데이터에서는 공간의 밝기변화와, 직접적인 조명과 간접적인 조명의 차이를 모두 확인 할 수 있다.



[그림 7] 밝기 데이터 수집 결과

[Fig. 7] Brightness data collection results

3.2 데이터 학습

Input features 와 labels 들은 [표 2]에 나타냈다. 3가지 case를 학습하였다. 모든 case는 시간과 관련된 feature인 Month, Day, Weekday, Hour, Min를 포함한다. 월은 1월부터 12월을 1 to 12로 그대로 나타내었고 Monday to Sunday를 1 to 7로 매핑하였다.

첫번째 케이스는 밝기, 온도, 상대습도를 각각 학습한 것이다. 두번째 유형은 온도와 상대습도를 학습하여 밝기를 예측한 것이다. 온도와 상대습도 또한 Label이 되는 feature를 제외하고 학습하여 예측하였다. 세번째 유형은 밝기를 예측하기 위해 인접한 디바이스의 밝기를 학습하였다. 전체 53,900개의 시계열 중 구간으로 나누어 뒤쪽 5900개를 test set 으로 설정하였다. Train set 중에서는 20%를 validation set로 활용하도록 설정하였다.

딥러닝 모델은 [표 2]와 같이 설계되었다. 두개의 LSTM 층을 설치하였고 Activation 은 Relu, Loss function은 ‘Mean Squared Error’를 설정하였다. Batch Normalization 및 Dropout/Regularization 은 고려하지 않은 단순한 네트워크를 구성하였고, Sequence length는 many-to-one 으로 10개의 time series 데이터로 11번째 값을 예측하도록 하였다. 또한 데이터별로 scale이 다른 것을 보완하기 위하여 정규화 하여 학습하였다.


[표 2] LSTM 층으로 구성된 딥러닝 네트워크

[Table 2] Deep learning network composed of LSTM layers

No.	Layer type	Units
1	LSTM	512
2	LSTM	512
3	Dense	512
4	Dense	1


3.3 학습 결과

[그림 8]은 case1의 예측결과를 나타낸 그래프이다. 1번 디바이스에서 수집한 brightness, temperature, relative humidity를 학습하고, $t+1$ 를 예측한 결과이다. Input feature에 직접적으로 반영이 되기 때문인지 모든 속성에서 매우 높은 accuracy를 확인 하였다. brightness, temperature, relative humidity의 예측값의 MAPE는 각각 1.04%, 1.30%, 2.06% 이다.



[그림 8] Case 1 예측결과

[Fig. 8] Result of Case 1 prediction




[그림 9] Case 2 예측결과

[Fig. 9] Result of Case 2 prediction

[그림 9]는 case2의 예측결과를 나타낸 그래프이다. 1번 디바이스에서 수집한 데이터 중 다른 속성을 학습하여 예측한 경우이다. 예를 들어 case 2-1은 온도와 상대습도를 학습하여 $t+1$ 의 밝기값

을 예측하였다. brightness, temperature, relative humidity의 예측값의 MAPE는 각각 17.92%, 9.28%, 32.06% 이다. 밝기와 습도는 예측의 정확도가 낮다. 예측의 정확도와는 별개로 몇 시사점이 있다. 첫번째는, 온도와 습도 데이터 만으로 밝아지는 것을 미리 예측할 수 있었던 부분이다. [그림 9]의 그래프에서 보면 실제 측정데이터는 Test set의 3,000번째와 약 4,700번째 에서 밝아지는 부분을 미리 예측한 것을 확인 할 수 있다. 두번째는 그래프 에서처럼 온도 의 변화 추세를 상당히 유사하게 예측한 것과 습도 값이 오차 와는 별도로 그래프의 형태는 유사하게 맞춘 것이다. 하였다. 온도의 변화는 4°C 내외로 매우 작은 변화였으나, 습도와는 다르게, 높은 정확도로 예측된 것이 의미 있다. 아마 온도 변화와 밝기 변화가 매우 유사하기 때문이다. 데이터 수집 시기가 여름인 계절적인 HAV 운영 특성인지 공간 관리 측면에서 추적 조사를 해보아야 한다.

[그림 10]은 case3의 예측결과를 나타낸 그래프이다. 인근에 설치된 두개의 디바이스에서 수집된 밝기 값으로 t+1 시점의 밝기를 예측하였다. MAPE는 8.58%로 정확도가 매우 높다. 공간이 연결되어 있거나, 유리로 되어있기 때문에 예상할 수 있었던 결과이다. 그러나 공간을 관리하면서, 디바이스간 연계를 통해서 이상상황을 detection 할 수 있는 가능성을 확인하였다.



[그림 10] Case 3 예측결과

[Fig. 10] Result of Case 3 prediction

4. 결론

온도, 습도, 밝기 정보를 IoT 디바이스로 수집한 데이터를 대상으로 anomaly analysis를 수행하였다. 3개의 IoT 디바이스를 제작하여 Office 건물 지하 공용공간 및 휴게공간에 설치하였다. 한달 이상 데이터를 수집하였고 딥러닝 방법 중 대표적인 RNN(Recurrent Neural Network)방법인 LSTM(Long-Short Term Memory) 으로 학습하였다. 학습결과 다음의 세가지를 확인하였다.

Input feature와 동일 디바이스의 동일 속성 값을 예측한 case 에서는 매우 높은 정확도를 보였는데, 데이터 자체의 변동성이 작기 때문에 어렵지 않은 문제일 수 있다. 동일 디바이스에서 얻은

Input feature 중 예측 속성 이외의 속성을 학습하였을 경우에도 제한적이지만 패턴을 유추할 수 있었다. 온도와 습도 데이터를 학습하여 밝기가 밝아지는 것을 예측하는 결과를 볼 수 있었다.

Multi device의 input feature로 학습한 경우에도 매우 높은 정확도로 예측하였다. 데이터를 예측 가능성을 통해 IoT 디바이스로 데이터를 수집하고 anomaly analysis 하는 framework를 검토 할 수 있었다. 제한적인 기간과 디바이스, 환경에서 수집한 데이터 이지만 multi device를 활용하는 모델과, 온도, 습도와 밝기와의 pattern을 기준으로 하는 모델의 활용 가능성도 확인하였다. 온도, 습도, 밝기 데이터 학습을 통해 만들어진 모델을 활용하고 예측에 대한 오차 기준에 threshold 값을 설정하여 anomaly analysis가 가능 할 것이다.

References

- [1] H. N. Li, D. S. Li, L. Ren, T. H. Yi, Z. G. Jia, K. P. Li, “Structural health monitoring of innovative civil engineering structures in Mainland China”, *Structural Monitoring and Maintenance*, vol. 3, no. 1, March 2016, pp. 1-32, doi: 10.12989/smm.2016.3.1.001.
- [2] A. Zimek, E. Schubert, “Outlier Detection”, *Encyclopedia of Database Systems*, September 2017, pp. 1-5, doi: 10.1007/978-1-4899-7993-3_80719-1.
- [3] H. Saha, A. R. Florita, G. P. Henze, S. Sarkar, “Occupancy sensing in buildings: A review of data analytics approaches”, *Energy and Buildings*, vol. 188-189, April 2019, pp. 278-285. doi: 10.1016/j.enbuild.2019.02.030.
- [4] Y. Liu, Z. Pang, M. Karlsson, S. Gong, “Anomaly detection based on machine learning in IoT-based vertical plant wall for indoor climate control”, *Building and Environment*, vol 183, October 2020, pp. 107212. doi: 10.1016/j.buildenv.2020.107212.
- [5] L. M. Candanedo, V. Feldheim, “Accurate occupancy detection of an office room from light, temperature, humidity and CO2 measurements using statistical learning models”, *Energy and Buildings*, vol. 112, January 2016, pp. 28-39, doi: 10.1016/j.enbuild.2015.11.071.
- [6] W. Cui, H. Wang, “A New Anomaly detection System for School Electricity Consumption Data”, *Information*, vol. 8 no. 4, November 2017, pp. 151, doi: 10.3390/info8040151.
- [7] A. Shabani, O. Zavalani, “Hourly Prediction of Building Energy Consumption: An Incremental ANN Approach”, *European Journal of Engineering Research and Science*, vol. 2, May 2017, pp. 27-32. doi: 10.24018/ejers.2017.2.7.397.
- [8] P. Anand, D. Cheong, C. Sekhar, M. Santamouris, S. Kondepudi, “Energy saving estimation for plug and lighting load using occupancy analysis”, *Renewable Energy*, vol. 143, November 2019, pp. 1143-1161, doi: 10.1016/j.renene.2019.05.089.
- [9] Y. Liu, Z. Pang, M. Karlsson, S. Gong, “Anomaly detection based on machine learning in IoT-based vertical plant wall for indoor climate control”, *Building and Environment*, vol. 183, April 2020, pp. 107212, doi: 10.1016/j.buildenv.2020.107212.