AI와 IoT 센서를 이용한 클라우드 기반 건축물 실시간 상태감시 및 예측시스템 개발

Development of a Cloud-Based Real-Time Building Health Monitoring and Prediction System Using AI and IoT Sensors

하창완* · 안병태** · 신영식*** · 박진성**** · 이재경***** · 김정집*****

Ha, Chang-Wan*, Ahn, Byungtae**, Shin, Young-Sik***, Park, Jinseong****, Lee, Jai-Kyung*****,
and Kim, Jungjip*****

Abstract

In this study, a cloud-based real-time building health monitoring and prediction system using AI and IoT sensors was developed. To predict the building condition, which constitutes time-series data, statistical-based ARIMA and AI-based LSTM prediction models were designed, and the effectiveness of the proposed prediction models was experimentally verified using a 1/8-scaled miniaturized structure. The prediction accuracy in terms of MAPE (less than 1%) was experimentally confirmed to be satisfactory. Moreover, a method for analyzing dimensional structure deformation was developed by combining multiple sensor measurements, and its effectiveness was verified through the case study of a real earthquake-damaged building.

Key words : Artificial Intelligence, LSTM, ARIMA, Health Monitoring, Sensor Network

요 지

본 연구에서는 AI와 IoT 센서를 활용한 클라우드 기반 실시간 건축물 상태 모니터링 및 예측시스템을 개발하였다. 건축물에 부착된 IoT 센서로부터 취득한 시계열 데이터들을 기반으로 가까운 미래의 건축물 상태(특히 기울기)를 예측하기 위해 통계적 기반의 ARIMA와 인공지능 기반의 LSTM 예측 모델들을 설계하였고 제안한 예측 모델들의 유효성을 검증하기 위해 1/8 스케일 축소 건축물을 제작하여 지반침하에 의한 건축물 기울어짐을 모사한 실험을 진행하였다. 실험결과 제안한 예측 모델들이 가까운 미래의 건축물 기울어짐을 매우 높은 정확도(MAPE 1% 이하)로 예측하는 것을 입증하였다. 또한 건축물에서 부착된 다중 IoT 센서 신호들을 조합하여 건축물의 3차원 변형을 가시화하고 이를 기반으로 분석하는 방법과 포항 지진피해 건축물을 대상으로 실제 적용한 사례를 소개하였다.

핵심용어 : 인공지능, LSTM, ARIMA, 건축물 상태 감시, 센서 네트워크

*정회원, 한국기계연구원 인공지능기계연구실 선임연구원(Tel: +82-42-868-7203, Fax: +82-42-868-7440, E-mail: hawan@kimm.re.kr)

Member, Senior Researcher, Department of AI Machinery, Korea Institute of Machinery & Materials

**한국기계연구원 인공지능기계연구실 선임연구원

Senior Researcher, Department of AI Machinery, Korea Institute of Machinery & Materials

***한국기계연구원 인공지능기계연구실 선임연구원

Senior Researcher, Department of AI Machinery, Korea Institute of Machinery & Materials

****한국기계연구원 인공지능기계연구실 선임연구원

Senior Researcher, Department of AI Machinery, Korea Institute of Machinery & Materials

*****한국기계연구원 스마트산업기계연구실 책임연구원

Principal Researcher, Department of Smart Industrial Machine Technologies, Korea Institute of Machinery & Materials

*****교신저자, 정회원, 텔코코리아아이에스 대표(Tel: +82-42-867-0766, Fax: +82-42-867-0767, E-mail: telco@telcokorea.co.kr)

Corresponding Author, Member, CEO, TelcoKoreaIS

1. 서 론

초고층 재난관리법에 따라 50층 이상 또는 높이 200 m 이상의 초고층 건축물 및 지하연계 복합 건축물들은 건축물의 상태감시를 위해 재난 안전관리 시스템을 구축하여 정부 지침 하에 안전하게 관리되고 있다.

반면, 초고층 재난관리법 대상은 아니지만 주의와 관심이 필요하고 현재 사회적 이슈가 되고 있는 노후 건축물, 지진피해 건축물, 연약지반 및 인근 공사로 인한 지반침하 관심대상 건축물들은 현실적인 제약으로 인해 건축물의 안전점검이 시설물 안전법에 근거하여 연 2회(정기검사) 혹은 3년(정밀검사)/5년(안전진단) 주기로 이루어지고 있지만 거주민들을 충분히 안심시키기에는 부족한 것이 현실이다. 특히, Kim (2020)에 따르면 전국적으로 30년 이상 되는 노후 건축물 비율이 40%에 육박하며 2016년 경주지진을 포함하여 매우 강한 지진이 한반도에 최근 빈번히 발생하고 있어 주의와 관심이 필요한 건축물들의 수가 급격히 증가하고 있다.

선행 연구 사례를 살펴보면 음파센서, 이미지센서, 온도센서 등 다양한 복합센서를 이용하여 관심대상 건축물(특히 교량)의 상태를 실시간 감시하는 안전관리 시스템 개발과 관련된 연구가 있었고(Sim, 2012; Sim et al., 2010; Moon, 2018; Moon et al., 2019; Yeon et al., 2019), 취득한 다수의 계측치를 활용하여 인공지능(CNN) 및 통계/확률적 방식을 이용하여 교량의 상태를 스스로 진단하는 연구가 수행되었다(Kim and Park, 2016; Jung et al., 2019). 또한 교량뿐만 아니라 초고층 건축물의 건전성을 진단하기 위해 변형률 기반 모니터링에 대한 연구가 수행되었고(Eom and Kim, 2009; Erol, 2010; Poluzzi et al., 2019), 최근에는 건축물 외부에서 촬영된 영상 정보를 바탕으로 건축물의 변형을 추출하는 연구가 수행되었다(Castagnetti et al., 2016). 특히 영상 정보를 이용할 때에는 진동에 의한 촬영영상 왜곡을 최소화하는 것이 중요한데 이와 관련된 진동저감 마운트 설계에 대한 연구도 수행되었다(Xin et al., 2020).

본 논문에서는 사람이 직접 육안으로 점검하던 관심대상 건축물들의 상태를 IoT 복합센서를 이용하여 건축물의 상태를 정량화하고 실시간 심층 모니터링 할 수 있는 시스템 개발과 관련된 연구를 수행하였다. 또한 다수의 계측 정보를 조합하여 건축물의 상태를 입체적으로 분석하는 기술과 통계 및 인공지능 기법을 활용하여 가까운 미래의 건축물 상태(특히 기울기)를 예측하고 이를 기반으로 사고에 사전 대응하는 재난안전 관리시스템 구축과 관련된 연구를 수행하였다.

본 연구가 기존 연구와 구별되는 점은 다음과 같다. 첫째, IoT 기술을 활용하여 클라우드 기반으로 시스템을 구축함으로써 인터넷 연결이 되는 어느 곳에서나 건축물의 상태를 원격으로 실시간 모니터링 할 수 있도록 시스템을 구축하였다. 둘째, 계측된 시계열 센서 데이터를 인공지능(LSTM)과

통계적(ARIMA) 방법을 이용하여 가까운 미래의 건축물 상태(특히 기울기)를 예측하는 모델을 제시하였고 제안한 예측 모델의 실효성을 건축물 축소모형을 이용하여 실험적으로 검증하였다. 셋째, 취득한 다수의 센서 데이터를 융합하여 건축물의 구조적 변형을 시각화함으로써 보다 입체적으로 건축물 상태를 분석하는 방법에 대해 제안하고 실제 지진피해 건축물 사례를 통해 제안한 방법의 효용성을 입증하였다.

본 논문의 구성은 다음과 같다. 2장에서는 제안한 건축물 안전관리 시스템 구성에 대해 소개하고, 3장에서는 인공지능과 통계적인 방법을 이용하여 시계열 데이터 예측 알고리즘과 제안한 방법의 예측정확도를 실증하기 위한 실험에 대해 다루며, 4장에서는 다수의 센서를 융합하여 건축물의 변형을 입체적으로 분석하는 방법과 사례를 통한 제안한 방법의 효용성을 입증한다. 마지막 5장에서 향후 연구방향과 결론을 기술한다.

2. 시스템 구성

기존 육안점검을 통해 주기적으로 이루어지던 건축물의 상태를 정량화하고 실시간으로 모니터링하기 위해 각도, 가속도, 지진파, 방위, 온습도, 기압을 측정할 수 있는 IoT 복합센서 모듈을 Fig. 1과 같이 개발하였다. 개발한 IoT 복합센서 모듈은 Fig. 2와 같이 관심대상 건축물 벽면 혹은 천장에 부착되고 건축물의 상태와 환경 정보를 계측한 후 신호 보정과정을 거쳐 LTE 망을 통해 클라우드 서버로 전송된다. 신호 보정과정이란 온습도, 기압 등 환경 변화에 의한 센서 보정 및 신호에 포함된 오프셋/노이즈 제거를 의미한다. Fig. 2에서는 개발한 IoT 복합센서 모듈 성능 중 본 연구에서 관심이 있는 예측모델의 주요 입력인자(각도와 가속도)에 대한 성능지표를 보여주고 있다. 해당 성능을 공인인증기관을 통해 성능검증을 받았다.

본 연구에서는 Amazon에서 제공하는 클라우드 Amazon Web Service (AWS)를 이용하였다. 개별 서버를 직접 운영하는 온프레미스(On-Premise) 방식에 비해 클라우드 방식은 보안, 운영의 확장성 및 유연성 측면에서 유리한 면이 있다. 개별 IoT 복합센서와 클라우드 서버 간에는 저전력/소규모 디바이스 특히 IoT 기기 등에서 많이 활용되는 Message Queuing

Major specification	
MCU	Raspberry Pi
Communication	LTE module
Angle range	$\pm 10^\circ$
Angle accuracy	$\pm 0.01^\circ$
Acceleration bandwidth	1kHz
Acceleration accuracy	$\pm 0.01g$
Size and Weight	94x60x60mm ³ /0.2kg

Fig. 1. Developed IoT Sensor and Its Major Specifications

Fig. 2. Configuration of Cloud-Based Real-Time Building Health Monitoring and Prediction System Using AI and IoT Sensors

Telemetry Transport (MQTT) 규격에 맞춰 통신이 이루어지며, 여러 건축물에 설치된 다수의 IoT 복합센서가 동시에 안정적으로 계측될 수 있도록 시스템을 설계하였다. 수집된 계측 데이터들은 누락신호 보간, 좌표변환, 리샘플링 등과 같은 전처리 과정을 거친 후 인공지능 예측 모델과 통계적 예측 모델의 입력 값으로 전달된다.

클라우드 상에서 수집된 건축물의 상태는 인터넷 연결이 되는 어느 곳에서나 원격 접근이 가능하며 이를 통해 실시간 모니터링이 가능하다. 또한 인공지능과 통계적 방법을 통해 예측된 값은 건축물에 거주하는 주민과 시공사에 알려 사고를 사전에 대응하는데 활용된다. 향후에는 건축물의 상태와 위치 및 지리정보를 접목하여 스마트시티 통합 안전관리시스템 구축에 활용할 계획이다.

3. 건축물 상태 예측모델

IoT 복합센서를 통해 취득한 건축물 상태 정보는 시간의 경과에 따라 변하는 시계열 데이터(Time Series Data)이다. 과거와 현재 데이터를 기반으로 가까운 미래를 예측하기 위해 통계적인 방법과 인공지능 방법을 이용하였다. 본 연구에서 사용하는 통계적인 방법인 ARIMA는 인공지능 방법에 비해 계산이 비교적 단순하여 사용이 용이하지만 다양한 변수간의 상호작용이 고려되지 않는 단점이 있다. 인공지능 방법인 LSTM은 입력 데이터의 특징 패턴을 그대로 학습하기 때문에 충분한 학습 데이터만 주어진다면 건축물의 상태를 보다 더 정교하게 표현할 수 있고, 건축물의 특성변화(지진과 같은 이벤트 혹은 IoT 복합센서 고장 등에 따른 이상증후를 감지하는 데에도 활용할 수 있다.

3.1 ARIMA를 이용한 건축물 기울어짐 예측모델

Auto Regressive Integrated Moving Average (ARIMA) 모델은 AR 모델과 MA 모델을 동시에 포함하여 시간의 흐름에 따른 관측 값들의 확률 구조를 고려하는 모델이다. 시계열 데이터의 종속변수가 과거 값에 직접적으로 의존하는 AR 모델과 과거 값에 무작위로 발생한 교란 요인에 영향을 받는 MA 모델을 조합하여 시계열 데이터의 경향에 대한 설명력을 높이는 통계적 방법론이다(Box et al., 1976; Kim et al., 2014, Kang 2019). 시계열 데이터 y 가 $ARIMA(p, d, q)$ 를 만족하면 아래와 같이 표현된다.

$$\phi_p(B)(1-B)^d y_t = \theta_q(B)\epsilon_t \quad (1)$$

$$\text{where } \phi_p(B) = 1 - \sum_{k=1}^p \phi_k B^k$$

$$\theta_q(B) = 1 + \sum_{k=1}^q \theta_k B^k$$

여기서 $\phi(B)$, $\theta(B)$ 는 각각 자기회귀, 이동평균에 관한 다항식을 나타낸다. p 는 자기회귀의 차수를 나타내며 t 시점(현재)의 값에 $t-1, \dots, t-p$ 시점(과거) 값이 영향을 준다는 것을 의미한다. 그리고 d 는 시계열 데이터의 차분을 나타내며, t 시점의 값에서 $t-d$ 시점의 값의 차이를 통하여 비정상성(Non-stationary) 시계열 데이터를 정상성(Stationary) 시계열데이터로 만들어 주는 것을 의미한다. q 는 이동평균의 차수로서, t 시점의 값이 $t-1, \dots, t-q$ 시점까지 연속적으로 각 항의 영향을 받는 것을 의미한다.

일반적으로 ARIMA 모형의 적용단계는 다음과 같다. 첫

Fig. 3. Sliding Window Based ARIMA Model

제, 시계열 데이터에 대한 정상성을 검증한다(Box et al., 1976). 여기서 정상성이란 시계열을 일정한 주기로 나누었을 때, 각 주기에 해당하는 평균과 분산이 일정하다는 것을 의미한다. 만일 비정상성 시계열 데이터인 경우 차분을 적용하여 정상성을 만족하는 시계열 데이터로 변환하는 작업이 필요하다. 차분을 적용하기 위해서는 자기상관함수(Autocorrelation Function, ACF)와 부분자기상관함수(Partial Autocorrelation Function, PACF)를 활용한다. 둘째, 모형의 구성요소인 $AR(p)$, $I(d)$, $MA(q)$ 를 조합하여 모형을 추정한 후 Akaike's Information Criterion (AIC) 또는 Normalized Bayesian Information Criterion (BIC) 통계량 등을 산출하여 가장 적합한 모형을 결정한다(Box et al., 1976; Kang 2019). 마지막으로, 산출된 모형을 통해서 미래값을 예측한다.

ARIMA 모형의 경우 Box et al. (1976)에 의해서 정형화되었으며 적절한 모형을 설정하기 위해서는 50개 이상의 관측치가 필요하며, 단기 예측의 경우 60개 이상의 관측치로도 충분한 시계열 분석이 가능한 것으로 알려져 있다.

ARIMA 모형과 같은 시계열 데이터 분석 및 예측과 관련한 방법론들은 일반적으로 데이터에서 특별한 모형의 특성이 지속할 것이라는 가정으로 출발하여 모형을 설정, 분석 및 예측한다. 그러나 실제 시계열로 나타나는 현상들은 일시적으로는 특별한 구조를 유지하지만, 시간이 지남에 따라 데이터의 모형이 변화할 수 있으므로 고정된 모형을 활용하는 경우 정확한 분석과 예측이 곤란한 경우가 빈번히 발생하게 된다. 건축물의 경우 지형의 침식, 지진과 같은 외란에 의해 모형이 변화되는 경우가 발생할 수 있으므로 제안하는 시스템에서는 Sliding Window에 기반을 둔 ARIMA 모형을 적용하여 활용한다. Fig. 3은 본 시스템에 적용된 Sliding Window 기반 ARIMA 모델이다. 새로운 관측치가 입력될 때마다 k 개의 최신 입력데이터를 바탕으로 ARIMA 모형을 업데이트하고 예측을 수행한다.

3.2 LSTM을 이용한 건축물 기울어짐 예측모델

연속적인 시퀀스 형태의 신호를 다루는 음성인식, 언어번역, 날씨 및 주가 예측 분야 등에 널리 쓰이는 Long Short Term Memory Networks (LSTM)은 순환신경망(Recurrent Neural Network, RNN) 계열의 인공지능 모델이다(Hochreiter

Fig. 4. Structure of LSTM Unit

and Schmidhuber, 1997).

특히, 시계열 데이터 예측의 경우, 현 단계의 입력뿐만 아니라 이전단계의 출력에 의해서도 영향을 받는다. 이를 반영하기 위하여 LSTM 모델은 뉴런 간의 연결 사이의 상태를 저장하는 내부 메모리를 추가하여 시변적 동적 특징을 모델링할 수 있도록 하였다. 그 결과 입력 시퀀스에 장기 의존성을 담을 수 있게 되어 예측 정확도를 높이는 장점을 갖는다. LSTM의 구성단위인 unit의 구조는 Fig. 4와 같다.

LSTM에서 상태(State)는 셀의 상태(C)와 은닉층의 상태(h)로 구성된다. 이 셀 상태를 보호하고 제어하기 위한 세 가지 문(Gate)을 통해 다층신경망 학습의 경사 소실(Vanishing Gradient) 문제를 방지하고 경사 정보가 효과적으로 흐를 수 있게 한다. f_t 는 과거 정보를 얼마나 잊어버릴지를 결정하는 게이트(Forget Gate)이고, i_t 는 현재 정보를 얼마나 포함시킬 것인지를 결정하는 게이트(Input Gate), 그리고 계산된 최종 셀 상태를 얼마나 은닉층의 상태에 포함할 것인지를 결정하는 출력 게이트(Output Gate)이다.

본 연구에서는 Fig. 5와 같은 하이퍼 파라미터를 사용하여 LSTM 예측 모델을 생성하였다. 예측에 앞서 Fig. 6(a)에서 볼 수 있듯이 오프라인에서 다양한 지반침하 모사파형을 이용하여 LSTM 예측모형을 학습하고 검증한다. 본 연구에서는 100개와 20개의 지반침하 모사파형을 만들어 오프라인에서 LSTM 예측모형을 학습하고 검증하였다. 학습이 완료된 후에는 Fig. 6(b)에서 볼 수 있듯이 실시간으로 계속되는 시계열 데이터를 LSTM 예측모형의 입력으로 전달하면 한 샘플시간 뒤의 예측 값이 출력으로 나오게 된다. 제안한 예측 모델의 정확도는 평균절대백분율오차(Mean Absolute Percentage Error, MAPE)로 평가된다.

$$M = \frac{100}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (2)$$

여기에서 F_t 는 현재 시점에서 한 샘플시간 후 예측한 값이며, A_t 는 한 샘플시간이 경과한 후 측정한 참값이다.

Fig. 5. Hyper-Parameters for LSTM

Fig. 6. Architecture of LSTM Prediction Model

3.3 건축물 축소모형을 이용한 예측모델 실증

제한한 통계 기반의 ARIMA와 인공지능 기반의 LSTM 예측모델의 실효성을 검증하기 위해 Fig. 7(a)과 같이 1/8 스케일 건축물 축소모형을 제작하여 6자유도 진동대에 올려놓고 지반침하를 모사한 거동으로 6자유도 진동대를 기울였다.

1/8 스케일 건축물 축소모형은 단면 2차 모멘트가 길이의 네제곱에 비례한다는 상사성(Similarity)을 이용하여 단면 2차 모멘트를 기준으로 Table 1과 같이 기둥과 보를 설계하여 제작하였다. 제작한 건축물 축소모형 구조는 포항지진 피해 건축물(크리스탈 빌라)과 비슷한 구조를 갖는다. 시뮬레이션 결과 층사가 낮아 건축물 전체가 강체(Rigid Body)처럼 거동하는 것을 확인하였다. 실제 지반침하 혹은 지진피해 건축물의 경우, 층간 상대변형이 발생하는 경우가 많은데 본 실험에서는 이러한 층간 상대변형은 모사하지 못하였다.

지반침하를 모사한 진동대 기울기 파형은 기존 연구(Nam

et al., 2017; Kim and Jung, 2018; Hong, 2020)와 2017년 발생한 진도 5.8의 포항지진 피해건물에서 1년간 취득한 건축물의 기울기 정보를 바탕으로 한국지진안전기술원의 자문을 받아 특성이 다른 지반침하 모사파형을 만들었다. 지반침하 모사파형은 크게 3 종류로 구성된다. LSTM 학습을 위한 100개의 모사파형, 검증을 위한 20개 모사파형, 진동대 실험을 위한 100개의 모사파형이 있으며 각각의 파형들은 단조증가하는 패턴과 진동하는 패턴(주파수와 진폭)이 조금씩 다르게 설계되었다.

Fig. 7(b)은 건축물 축소모형에 IoT 복합센서를 부착한 후 건축물 축소모형이 기울어질 때 ARIMA와 LSTM 모델을 이용하여 현재와 과거 정보를 바탕으로 한 샘플시간 후의 건축물 상태를 예측한 결과와 이에 대한 평균절대백분율오차(MAPE)를 나타낸 것이다. 모사파형 66 (진동이 적고 단조증가하는 형태)에서의 ARIMA와 LSTM의 예측오차는 MAPE

(a) Test environment by using 1/8 scaled miniaturized structure and 6 DOF vibrator

(b) Experimental results of ARIMA and LSTM prediction (black solid line: measured data from tilt sensor, red dot line: prediction from ARIMA model, green dot line: prediction from LSTM model)

Fig. 7. Experimental Verification of Proposed LSTM and ARIMA Prediction Models by Using 1/8 Scaled Miniaturized Structure and 6 DOF Vibrator

Table 1. Geometrical Moment of Inertia of a Miniaturized Structure Model

	Column			Beam		
	Shape & Size	Geometrical moment of inertia		Shape & Size	Geometrical moment of inertia	
		Major axis	Minor axis		Major axis	Minor axis
Regular model	H beam (300 mm × 300 mm × 10 mm × 15 mm)	$2.04 \times 1e8$ mm ²	$6.75 \times 1e7$ mm ²	H beam (500 mm × 200 mm × 10 mm × 16 mm)	$4.78 \times 1e8$ mm ²	$2.14 \times 1e7$ mm ²
1/8 scaled miniaturized model	□ beam (40 mm × 20 mm × 1.6 t)	$3.43 \times 1e4$ mm ²	$1.15 \times 1e4$ mm ²	□ beam (60 mm × 30 mm × 1.6 t)	$1.25 \times 1e5$ mm ²	$4.25 \times 1e4$ mm ²

관점에서 각각 0.26%, 0.55%이며, 모사파형 93 (단조 증가하면서 진폭이 크고 진동수가 높은 형태)에서의 ARIMA와 LSTM의 예측오차는 MAPE 관점에서 각각 0.52%, 0.62%였다. 두 종류의 기반침하 모사실험에서 제안한 ARIMA와 LSTM 예측모델 모두 예측오차 측면에서 만족스러운 결과가 나왔다.

ARIMA와 LSTM 예측모델은 각각의 장단점이 있다. LSTM 예측모델의 경우, ARIMA 예측모델에 비해 방대한 학습 데이터가 필요하다. 본 연구에서는 예측오차 1% 이하 수준의 예측모델을 위해 LSTM은 300개 이상의 샘플 데이터가 필요한 반면, ARIMA는 50개 이상의 샘플 데이터가 필요했다. 이로 인해 건축물에 IoT 복합센서를 설치한 후 예측모델이 학습하는데 필요한 데이터가 쌓이기까지 LSTM은 상대적으로 더 많은 시간이 필요하다. 예로 들면, 12시간 간격 예측 모델을 학습하기 위해서는 LSTM은 최소 150일, ARIMA는 최소 25일의 데이터가 확보되어야 함을 의미한다. 반면, LSTM 예측모델은 ARIMA 예측모델에 비해 건축물의 상해한 거동을 예측하는데 유리하다.

본 연구에서는 ARIMA 예측모델을 전통적인 방법이 아닌 Sliding Window 기반의 ARIMA 모델을 이용하였다. 이는 ARIMA 모델은 매 샘플시간마다 50개의 최신 입력데이터를 기반으로 재학습하고 재학습된 모델을 기반으로 예측한다는 것을 의미한다. 반면 LSTM 예측모델의 경우 IoT 복합센서를 설치하는 시점부터 취득한 초기 300개 샘플 데이터를 기반으로 학습을 하고 매 샘플시간마다는 이전에 학습된 모델을 바탕으로 예측이 이루어진다. 이는 ARIMA 모델이 LSTM 모델에 비해 학습을 위해 계산량이 상대적으로 적게 요구되기 때문에 매 샘플시간마다 재학습을 해도 서버에 큰 무리가 없기 때문이다. 또한 이런 두 종류의 예측모델을 이용할 경우, LSTM 모델은 센서 설치 시점의 데이터를 기반으로 학습을 하였기 때문에 센서를 설치한 시점의 건축

물 동특성 정보를 포함한 반면 ARIMA 모델은 매 샘플시간마다 학습이 이루어지기 때문에 현재의 건축물 동특성 정보를 포함하고 있다. 따라서 LSTM과 ARIMA 예측오차가 크게 차이가 날 경우, 건축물의 동특성에 변화가 발생했다는 것을 간접적으로 유추할 수 있다. 이와 관련한 내용은 추후 연구에서 상세히 다룰 예정이다.

4. 건축물 3차원 변형 시각화와 실증사례

건축물의 안전 관점에서 앞 절에서 설명한 특정위치의 기울기 변화를 지속적으로 관찰하고 예측하는 것도 중요하지만 층간 변형 혹은 뒤틀림과 같은 건축물의 입체적인 변화를 관찰하는 것 또한 매우 중요하다.

개발한 IoT 복합센서의 경우, 무선으로 데이터 취득이 가능할 수 있기 때문에 규모가 큰 건축물의 다양한 위치에 추가적인 배선작업 없이 손쉽게 다수의 센서 설치가 가능하다는 장점이 있다.

본 논문에서는 IoT 복합센서에서 측정된 기울기 정보들을 조합하여 건축물의 3차원 변형을 분석하는 방법과 실제 적용사례에 대해 소개하고자 한다.

기울기 정보를 바탕으로 건축물의 3차원 구조를 가시화하기 위해서는 계층 지점 간의 상대 길이는 변하지 않는다는 가정이 필요하다. 이는 기울기 정보만으로는 건축물 높이의 상대 변화(ex., 지진 등으로 인한 지반의 부분 침하, 철근의 휘어짐, 콘크리트 파손 등)를 알 수 없기 때문이다. 이런 가정으로 개별센서 결과만으로는 보기 힘든 층간 혹은 위치간 상대변형을 가시화함으로써 간접적으로 건축물의 구조적 변형을 분석할 수 있다.

Fig. 8은 2017년에 발생한 포항지진으로 피해를 입은 필로티 구조의 빌딩이다. 횡파에 취약한 필로티 구조로 인해 1층 기둥들이 Fig. 8과 같이 심각한 피해를 입게 되었다.

Fig. 8. Earthquake-Damaged Building (Crystal Building, Pohang, Korea) and Location of Sensor Installation at 2nd Floor

Fig. 9. Coordinate of Target Building and 3D Visualization Results Based on Multi Sensor Measurements

이로 인해 해당 빌딩은 지진발생 후 서서히 기울어지기 시작하였고 현재는 보강기둥 설치 등의 대응으로 건물이 기울어지는 속도를 늦추었지만 여전히 위험한 상황이며 지속적인 주의가 필요하다. 본 연구에서는 개발한 IoT 복합 센서를 해당 건물의 네 모서리에 층별로 설치하고 개별 위치에서 측정한 기울기와 변화량, 그리고 3차원 구조 변형을 가시화하는 연구를 수행하였다. 예로 지진피해가 가장 심각한 1~2층간의 3차원 변형은 아래 식과 같이 표현할 수 있다.

$$\begin{aligned} P_{201} &= \begin{bmatrix} +h\sin(\theta_{201x}) & -h\sin(\theta_{201y}) & h\cos(\theta_{201x})\cos(\theta_{201y}) \\ D+h\sin(\theta_{202x}) & -h\sin(\theta_{202y}) & h\cos(\theta_{202x})\cos(\theta_{202y}) \\ +h\sin(\theta_{203x}) & L-h\sin(\theta_{203y}) & h\cos(\theta_{203x})\cos(\theta_{203y}) \\ D+h\sin(\theta_{204x}) & L-h\sin(\theta_{204y}) & h\cos(\theta_{204x})\cos(\theta_{204y}) \end{bmatrix} \quad (3) \end{aligned}$$

h 는 층간 높이이며, L 과 D 는 센서 간의 가로/세로 간격이다. θ 는 센서를 통해 취득한 기울기 값이며 이를 통해 건축물의 3차원 변형을 가시화 할 수 있다.

Fig. 9는 2020년 4월부터 6월까지 포항 크리스탈 빌라에서 취득한 기울기 정보들을 이용하여 건축물의 3차원 변형을 가시화한 것이다. 202 센서 위치의 기울기가 가장 크게 발생하며, 시간이 지남에 따라 점진적으로 증가하는 것을 확인할 수 있다. 또한, 다른 위치의 기울기 역시 같은 방향으로 기울어지고 있다는 것을 시각적으로 확인할 수 있다. 실제로 202 센서가 설치된 위치 아래의 1층 필로티 기둥이 Fig. 8과 같이 지진으로 인해 가장 큰 피해를 입었고 그 영향으로 건축물 전체가 202 센서 방향으로 기울고 있다. 현재 보강대를 세워 건축물이 안정화된 상태이나 측정된 데이터를 기반으로 해석하자면 202 센서 아래 필로티 기둥 쪽에 반드시 추가적인 보강공사가 이루어져야 한다는 것을 유추할 수 있다. 이와 같이 다중센서를 이용한 건축물 3차원 변형 가시화는 건축물의 상태를 직관적으로 해석하는데 도움을 줄

뿐만 아니라 개별 위치간의 특성 상관관계를 파악하는 데에도 도움이 된다.

5. 결 론

본 연구에서는 AI와 IoT 센서를 이용한 클라우드 기반 건축물 실시간 상태감시 및 예측시스템을 개발하였다. 건축물의 상태를 예측하기 위해 통계 기반의 ARIMA와 인공지능 기반의 LSTM 예측모델을 설계하였고, 제한한 예측모델의 유효성을 검증하기 위해 1/8 스케일 축소 건축물을 이용하여 실험적으로 제안한 방법의 예측정확도가 99% 이상 되는 것을 확인하였다. 또한 다중 센서를 통해 취득한 기울기 정보를 이용하여 건축물의 3차원 변형을 간접적으로 분석하는 방법을 제안하고 실제 지진피해 건축물 사례를 기반으로 제안한 방법의 효용성을 입증하였다.

현재는 IoT 복합센서 내부의 기울기 정보를 활용하여 건축물의 상태를 분석하여 예측하는데 그쳤지만 향후에는 기울기 정보와 가속도, 지진강도, 기상청 데이터들을 조합하여 건축물의 상태와 상태를 변화시킨 원인간의 상관관계를 분석하는 영역에도 인공지능 방법을 이용하여 추가연구를 진행할 예정이다. 현재 개발 중인 시스템은 인공지능과 통계적 방법을 통해 예측된 값을 활용하여 건축물에 거주하는 주민들에게 대피를 알리거나 시공사에 긴급보수를 요청하는 등 다양한 방식으로 활용될 수 있다. 현재 개발 중인 시스템은 향후 건축물의 상태와 위치 및 지리정보를 접목하여 스마트 시티 통합 안전관리시스템 구축에 활용할 계획이다.

감사의 글

본 연구는 과학기술정보통신부 ICT R&D 혁신바우처 지원(중기지원형) 사업의 연구비지원(AI와 IoT센서를 이용

한 재난안전 관리시스템 개발, 2020-0-01142)에 의해 수행되었습니다.

References

- Box, G.E., Jenkins, G.M., Reinsel, G.C., and Ljung, G.M. (1976). *Time series analysis: Forecasting and control*. John Wiley & Sons, pp. 19-32.
- Castagnetti, C., Bertacchini, E., and Capra, A. (2016). Monitoring learning towers by geodetic approaches: Effects of subsidence and earthquake to the ghirlandina tower. *Structure Control and Health Monitoring*, Vol. 23, pp. 580-593.
- Eom, T.-S., and Kim, J.-Y. (2009). An application of construction sequence analysis for checking structural stability of high-rise building under construction. *Computational Structural Engineering*, Vol. 22, No. 3, pp. 211-221.
- Erol, B. (2010). Evaluation of high-precision sensors in structural monitoring. *Sensors*, Vol. 10, pp. 10803-10827.
- Hochreiter, S., and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735-1780.
- Hong, G. (2020). Experimental study on soft ground with DCM column. *Journal of Korean Geosynthetic Society*, Vol. 19, No. 3, pp. 35-44.
- Jung, W., Jeong, D., Kim, Y., Kim, C., Lee, H., Yu, H., et al. (2019). Deep generative models to overcome an insufficient data problem in structural health diagnosis. *Transactions of the Korean Society of Mechanical Engineers A*, Vol. 43, No. 3, pp. 169-176.
- Kang, S. (2019). A comparative study on the prediction of the final settlement using preexistence method and ARIMA method. *Journal of the Korean Geo-Environmental Society*, Vol. 20, No. 10, pp. 29-38.
- Kim, S.J., and Jung, G.S. (2018). Influence of groundwater level variation on the adjacent ground through laboratory model test. *Conference of Korean Society of Civil Engineers*, pp. 123-124.
- Kim, S.-Y., Jung, H.-W., Park, J.-D., Baek, S.-M., Kim, W.-S., Chon, K.-H., and Song, K.-B. (2014). Weekly maximum electric load forecasting for 104 weeks by seasonal ARIMA model. *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, Vol. 28, No. 1, pp. 50-56.
- Kim, T.-H., and Park, K.-T. (2016). Development of statistical / probabilistic based adaptive thresholding algorithm for monitoring the safety of the structure. *Journal of the Korea Institute for Structural Maintenance and Inspection*, Vol. 20, No. 4, pp. 1-8.
- Kim, Y. (2020). Current status of old building and future tasks. *National Assembly Research Service*, Vol. 133.
- Moon, K.-H. (2018). Application and case study of structure health monitoring systems for building. *Review of Architecture and Building Science*, Vol. 62, No. 11, pp. 31-34.
- Moon, K.-H., Kim, J.-Y., and Sin, S.-H. (2019). Construction of structure health monitoring systems for action after disaster. *Magazine of the Korea Concrete Institute*, Vol. 31, No. 6, pp. 62-65.
- Nam, K.M., Kim, J.J., and Yoo, H.K. (2017). A case study on the indoor model experiments for the effect of subsidence due to tunnel excavation. *Conference of Korean Society of Civil Engineers*, pp. 1098-1099.
- Poluzzi, L., Barbarella, M., Tavasci, L., Gandolfi, S., and Cenni, N. (2019). Monitoring of the garisenda tower through GNSS using advanced approaches toward the frame of reference stations. *Journal of Cultural Heritage*, Vol. 38, pp. 231-241.
- Sim, B.-G., Lee, S.-B., and Chae, M.-S. (2010). Development of a wireless vibration monitoring system for structural health evaluation. *Transactions of the Korean Society for Noise and Vibration Engineering*, Vol. 20, No. 2, pp. 166-171.
- Sim, S.-H. (2012). Structural health monitoring of bridges using wireless smart sensor Networks. *Magazine of the Korea Concrete Institute*, Vol. 24, No. 3, pp. 34-36.
- Yeon, S.-H., Kim, J.-S., and Yeon, C.-H. (2019). A study on the safety monitoring of bridge facilities based on smart sensors. *Journal of the Korean Association of Geographic Information Studies*, Vol. 22, No. 2, pp. 97-106.
- Xin, R., Le, V.Y., Jin, T., Ko, Y., Seo, S.H., and Goo, N.S. (2020). Building health monitoring using digital image. *Conference of The Korean Society of Mechanical Engineers*, pp. 281-282.

Received	October 25, 2021
Revised	October 26, 2021
Accepted	November 3, 2021