

인공신경망 기반 건물 구조물 식별을 통한 모니터링센서 설치 개수 및 위치 선정

김법렬¹·최세운^{2†}

¹경일대학교 건축공학과 조교수, ²대구가톨릭대학교 건축공학과 부교수

Selection of the Number and Location of Monitoring Sensors using Artificial Neural Network based on Building Structure–System Identification

Bub-Ryur Kim¹ and Se-Woon Choi^{2†}

¹Assistant Professor, Department of Architectural Engineering, Kyungil University, Gyeongsan, 38428, Korea

²Associate Professor, Department of Architectural Engineering, Daegu Catholic University, Gyeongsan, 38430, Korea

Abstract

In this study, a method for selection of the location and number of monitoring sensors in a building structure using artificial neural networks is proposed. The acceleration-history values obtained from the installed accelerometers are defined as the input values, and the mass and stiffness values of each story in a building structure are defined as the output values. To select the installation location and number of accelerometers, several installation scenarios are assumed, artificial neural networks are obtained, and the prediction performance is compared. The installation location and number of sensors are selected based on the prediction accuracy obtained in this study. The proposed method is verified by applying it to 6- and 10-story structure examples.

Keywords : artificial neural network, system identification, installation location, number of sensors

1. 서론

지진·화산재해대책법에 따라 중앙 행정기관 및 지방자치단체의 청사, 국립대학교 등은 지진가속도계측기를 의무적으로 설치하도록 되어 있다(Korea Ministry of Government Legislation, 2020). 이에 따라 교량뿐 아니라 건물 구조물 유지관리 시장에도 가속도계와 같은 센서를 설치하여 구조물의 구조 응답을 실시간으로 수집 및 분석하여 구조안전도를 관리하는 구조모니터링 기술개발과 활용이 활발해질 것으로 전망된다.

2018년에 국토교통부는 스마트 건설기술 활용기반을 구축하기 위한 ‘스마트 건설기술 로드맵’을 수립하였다. 이는 기존 경험 의존적 산업에서 IoT, 빅데이터, 인공지능 등과 같은 첨단기술의 융합을 통해 지식·첨단산업으로 패러다임 전환을 하고자 하는 배경에서 발표되었다. 스마트 건설시장은 2016년 100억달러 규

모 수준으로 나타났으며, 연 12% 성장할 것으로 전망되고 있다.

스마트 건설기술의 핵심요소 중 하나는 센서와 인공지능 기술을 통해 구조물의 안전을 선제적으로 관리하여 안전사고 피해를 줄이는 기술이다. 따라서, IoT 기반의 센서, 빅데이터 분석, 인공지능을 이용한 건물의 유지관리 기술개발은 다양하고 활발하게 진행될 것이다.

삼풍백화점과 성수대교의 붕괴사고로 인해 구조물의 안전 관리 및 진단에 관한 필요성이 증대되었다. 기존 안전진단 기술은 인력 중심으로 운영되어 한계가 있었으나, 최근에는 센서를 설치하고 유·무선 네트워크를 통해 구조물의 응답을 실시간으로 수집 및 분석하여 신속한 대처를 할 수 있게 하는 구조 건전도 모니터링(Structural Health Monitoring, SHM)에 관한 연구 및 적용이 활발히 이루어지게 되었다. Kim 등(2018)은 저전력 장거리통신(Low Power Wide Area Network, LPWAN)

[†]Corresponding author:

Tel: +82-53-850-2736; E-mail: watercloud@cu.ac.kr

Received June 2 2020; Revised June 11 2020;

Accepted June 12 2020

© 2020 by Computational Structural Engineering Institute of Korea

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

센서네트워크 시스템의 시설물 적용가능성을 검토하고, 채널간의 간섭을 최소화하고 대역폭을 효율적으로 활용할 수 있는 네트워크 제어방법을 제안하였다. Lim 등(2016)은 국민안전처의 지진가속도계측자료 통합관리시스템과 연계 가능하며, 지진 가속도 실시간 계측 및 분석 기능, 시설물 건전도 평가 기능을 포함한 시스템을 개발하였다. Kim 등(2016)은 무선 센서 네트워크에서 센서 노드가 일시적 또는 영구적으로 유실될 경우를 대처하기 위해 칼만 필터 기반의 데이터 복구 알고리즘을 제안하였다. Chung 등(2014)은 계측관리기준의 타당성을 실 모니터링 계측 데이터를 활용하여 검증하고, 이를 보정 및 재설정하는 방법론을 제시하였다. Lee 등(2016)은 고층건물의 동적 풍응답 모니터링을 위해 추정 모드형상의 정확도에 관한 모니터링 목표 수준을 달성하기 위한 최소의 센서 수 및 위치를 결정하는 방법을 제시하였다.

본 연구에서는 인공신경망을 이용해 건물 구조물의 가속도계 설치 위치 및 개수를 선정하는 방법을 제안한다. 지진·화산재해대책법(지진가속도계측기 설치 및 운영기준 5장)에서는 10층 이하의 건물의 경우 바닥층과 최상층에 가속도 계측기를 설치하도록 되어 있지만, 구조물의 정확한 거동 및 상태를 평가하기 위해서는 더 많은 센서의 설치가 필요하다. 이를 위해 인공신경망에서는 센서가 설치되었다고 가정된 층의 가속도응답 값이 입력되도록 하고, 구조물의 질량과 강성이 출력하도록 하였다.

설치되는 가속도 센서의 위치와 개수를 선정하기 위해 입력되는 값은 가정하는 센서 위치와 개수에 기반하여 해당 층에서의 가속도 이력 응답이 입력되도록 하였다. 출력층은 가정하는 센서 위치와 개수에 상관없이 동일하게 구조물 각 층의 질량과 강성 값을 출력하도록 하였다. 이를 통해 예측되는 출력값의 오차를 기준으로 센서의 설치 위치와 개수를 선정할 수 있다. 가속도 센서를 통해 얻는 응답값은 구조물의 특성 및 건전도를 평가하는데 활용된다(Brincker *et al.*, 2001; Cross *et al.*, 2013; Sirca and Adeli, 2012).

본 연구에서는 6층, 10층 건물 구조물 예제를 선정하고, 이에 대한 400개의 설계안을 만들어 제안하는 기법을 적용하였다. 지진·화산재해대책법에서 10층을 기준으로 설치 개수를 구분하고 있기 때문에 본 연구에서는 이에 대한 기초연구로 6층과 10층 건물을 대상 예제로 선정하였다. 설치하는 센서의 개수는 1개, 2개, 3개로 구분하였으며, 각 경우에서 발생하는 설치층 조합에 대해 인공신경망을 생성하고 예측 오차를 비교하였다. 지진·화산재해대책법에서는 최상층에는 의무적으로 센서를 설치하도록 되어있기 때문에 센서 1개가 설치되는 경우에는 최상층에만 설치되는 경우만 고려하였다.

2. 인공신경망을 이용한 구조물 시스템 식별

인공신경망(Artificial Neural Network, ANN)은 건설분야에

서 다양한 방법으로 활용되어 온 기술이다. Kwag과 Hahm(2019)은 ANN을 이용하여 사면의 확률론적 내진 성능을 예측하는 모델을 제시하였다. Park 등(2007)은 보 구조물의 손상발생 및 손상위치를 실시간으로 예측하는 가속도 신호를 이용한 ANN 기반 손상검색기법을 제안하였다. Choi(2018)은 ANN을 이용하여 철골모멘트골조의 접합부 회전강성을 예측하는 기법을 제시하였다. Kim 등(2005)은 ANN을 이용한 전단보강근이 없는 철근콘크리트 보의 전단강도 예측기법을 제안하였다. Lee 등(2019)은 영상기반 딥러닝 및 이미지 프로세싱 기법을 이용한 볼트풀림 손상검출 기법을 제안하였다. 이와 같이 ANN은 입력변수와 출력 값 사이의 관계를 훈련데이터를 이용하여 모사하고 이를 통해 구조물의 내진성능, 강도, 강성, 손상 등을 예측하는데 활용되어 왔다.

본 연구에서는 구조모니터링을 위한 센서의 설치 및 위치를 선정하는 기준으로 구조물의 질량과 강성에 대한 예측 오차를 고려한다. 이를 위해 Fig. 1과 같이 센서가 설치되었다고 가정한 곳에서의 가속도 이력 응답이 인공신경망의 입력값으로 사용되며, 구조물의 질량과 강성은 출력값으로 설정된다.

인공신경망을 생성하고 검증하기 위해 사용되는 각 센서의 가속도 이력 데이터의 개수가 100개이고 설치된 센서의 수가 3개라면, 총 300개의 데이터가 입력값으로 사용된다. 즉, 입력층의 노드 수는 가정된 센서의 수에 따라 달라지며, 사용되는 각 시점에서의 가속도 응답값이 입력된다.

반면, 출력값은 대상 구조물 각 층의 질량과 강성 값이기 때문에 대상 구조물이 동일하다면 출력층의 노드 수는 동일하다. 대상 구조물이 6층이라 한다면 6개의 층질량 값과 6개의 층강성 값이 출력층 노드 값을 의미하게 된다.

시뮬레이션의 경우 구조물의 층질량과 층강성에 대한 정해를 알 수 있기 때문에 인공신경망을 통해 제시되는 예측값에 대한 오차를 계산할 수 있다. 활용되는 데이터가 제한된 센서

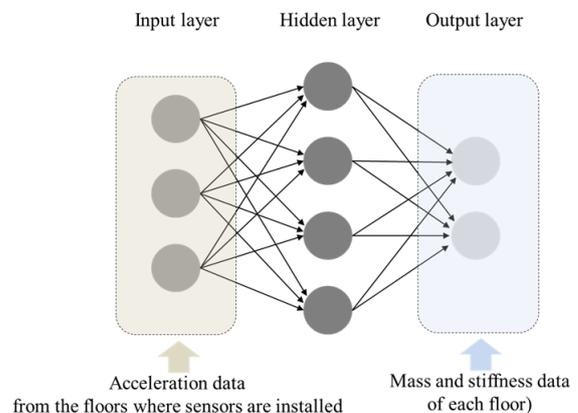


Fig. 1 Organization of artificial neural network(ANN) proposed to predict the structural data from the acceleration data

로부터 얻은 가속도 이력 응답이기 때문에 예측되는 질량과 강성 값을 의미있는 값으로 여기거나 활용하기에는 한계가 있을 수 있지만, 예측 오차가 크지 않다면 오차 값이 센서 위치 및 개수를 선정하는데 판별 기준으로 활용할 수 있다고 판단한다.

3. 예제 적용

3.1 개요

본 연구에서는 Fig. 2와 같은 6층과 10층 구조물에 제안하는 기법을 적용하였다. 센서가 설치되는 층 수와 위치에 따른 인공신경망 기반의 시스템식별 방법의 예측 오차를 분석하는 것

이 주 목적이기 때문에 본 연구에서는 구조물의 비선형 거동은 고려하지 않는다. PEER Gound Motion Database(2020)로부터 다운로드 받은 지진파를 이용해 선형시간이력해석을 수행한다.

인공신경망을 훈련시키기 위해 사용되는 입력데이터는 100개의 시점에서의 데이터가 사용된다. 따라서 사용되는 센서의 수가 1개, 2개, 3개인 경우에 대한 입력층에서의 입력 데이터 수는 각각 100개, 200개, 300개가 된다. 6층과 10층 예제의 출력층 노드는 각각 12개, 20개로 구성된다.

계측값을 입력시켜 구조물 각 층의 질량과 강성을 출력하는 인공신경망을 생성하고 시험하기 위해 총 400개의 사례가 사용된다. 구조해석은 OpenSees(2020)을 사용한다. 이는 각 층의 질량과 강성 값을 난수발생기를 이용해 배정하였다. 6층 예제의 1차 고유주기 범위는 0.41s~0.60s이며, 10층 예제의 1차 고유주기 범위는 0.70s~0.93s이다.

난수발생기를 이용해 각 층의 질량과 강성 값을 얻고, 이를 구조모델링에 적용한다. 이렇게 가정된 구조물에 대하여 지진 해석을 수행하여 각 층의 가속도응답을 얻는다. 이러한 과정을 통해 얻게 되는 가속도응답은 인공신경망 훈련 및 검증 시 입력값으로 사용된다. 각 층의 질량과 강성 값은 출력값으로 활용된다. 인공신경망을 통해 얻게 되는 각 층의 질량과 강성 값은 예측값이며, 난수발생기를 통해 얻은 각 층의 값은 정해로 활용된다. 이와 관련한 흐름도를 Fig. 3에 나타내었다.

본 연구에서는 설치되는 센서 수는 총 3가지(1개, 2개, 3개인 경우)로 구분하였다. 지진·화산재해대책법에 따라 최상층에는 의무적으로 센서를 설치하도록 되어 있기 때문에, 모든 경우에 대해 최상층에는 센서가 설치된다고 가정하였다. 6층 예제에서 설치 센서가 1개, 2개, 3개인 경우의 수는 각각 1가지, 5가지, 10가지이다. 10층 예제에서 설치 센서가 1개, 2개, 3개인 경우의 수는 각각 1가지, 9가지, 36가지이다.

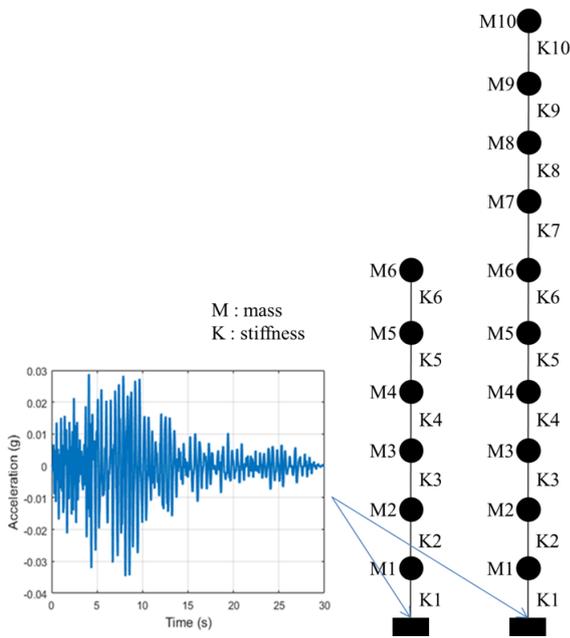


Fig. 2 Example structures

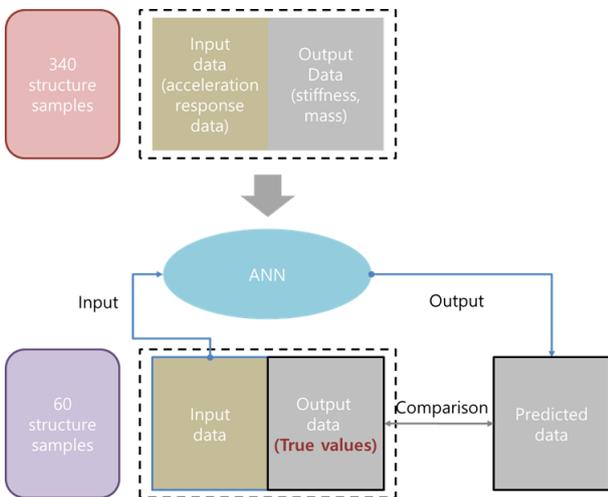


Fig. 3 Flowchart of system identification by using ANN

3.2 예제 결과 분석

400개의 예제 중 훈련에 사용되지 않은 예제 60개를 선택하여 센서 개수 및 위치에 따른 예측 성능을 비교하였다. 성능 지표로는 정해와 예측값 간의 상관계수(Correlation coefficient, R)과 평균 제곱근 편차(Root Mean Square Error, RMSE)를 이용하였다. 상관계수는 높을수록 예측 정확도가 높은 것을 의미하며, 평균 제곱근 편차는 낮을수록 예측 정확도가 높은 것을 의미한다.

6층 예제 결과를 Table 1에 나타내었으며, 센서 수에 따른 평균치를 Fig. 4에 표현하였다. 2개의 센서를 설치할 경우 2층과 최상층 바닥에 설치하는 것이 예측정확도가 가장 높았으며, 3개의 센서를 설치할 경우에는 2층, 4층과 최상층 바닥에

Table 1 Comparison of prediction results with respect to the number of sensors(6-story structure)

No. of sensors	Installation placements	Correlation coefficient(R)	RMSE
1	6	0.7386	0.0165
2	1,6	0.9139	0.0055
2	2,6	0.8601	0.0075
2	2,6	0.8359	0.0112
2	4,6	0.8079	0.0101
2	5,6	0.7723	0.0147
3	1,2,6	0.8830	0.0059
3	1,3,6	0.9293	0.0036
3	1,4,6	0.9162	0.0046
3	1,5,6	0.9105	0.0041
3	2,3,6	0.9283	0.0037
3	2,4,6	0.9011	0.0057
3	2,5,6	0.8916	0.0054
3	3,4,6	0.8691	0.0056
3	3,5,6	0.8763	0.0066
3	4,5,6	0.8515	0.0083

Table 2 Prediction investigation of solutions from ANN (6-story structure)

No. of Sensors	Mass ratios					
	M1	M2	M3	M4	M5	M6
1	0.92	0.93	0.93	0.93	1.09	1.09
2	1.00	1.06	0.98	0.98	1.12	1.09
3	0.98	0.98	0.95	1.01	0.97	1.02
No. of Sensors	Stiffness ratios					
	K1	K2	K3	K4	K5	K6
1	1.01	1.12	0.95	0.96	1.02	0.90
2	1.01	0.97	1.07	1.18	1.05	1.08
3	0.97	1.06	0.91	1.01	1.08	1.01
No. of Sensors	Natural frequency ratios					
	1st	2nd	3rd	4th	5th	6th
1	1.00	1.01	1.00	1.02	1.02	0.98
2	0.99	1.01	1.01	1.00	1.00	1.05
3	1.00	1.02	0.99	1.01	1.01	1.02
No. of Sensors	Modal Assurance Criteria(MAC)					
	1st	2nd	3rd	4th	5th	6th
1	1.00	0.99	0.98	0.91	0.76	0.79
2	1.00	1.00	1.00	0.99	0.86	0.85
3	1.00	1.00	1.00	1.00	0.99	1.00

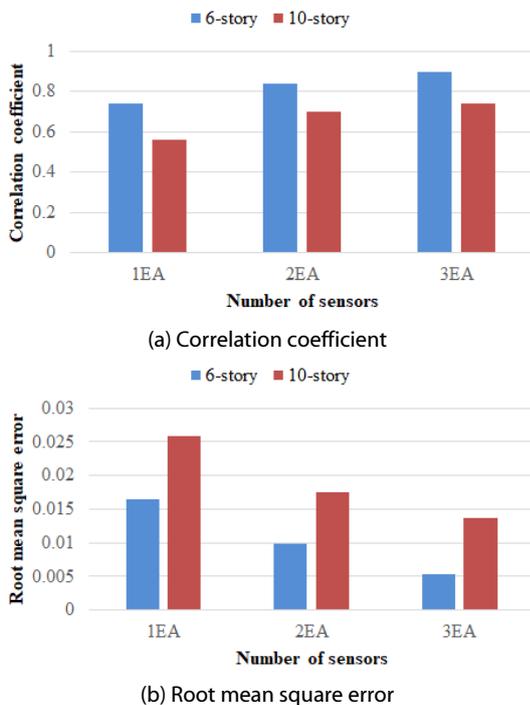


Fig. 4 Result comparison with respect to the number of sensors

센서를 설치하는 것이 예측정확도가 가장 높았다.

설치되는 센서의 수가 증가할수록 구조물의 특성을 예측하는 성능은 증가한 것으로 나타났다. 이는 고려한 센서 개수 범위 내에서는 개수가 증가함에 따라 입력되는 데이터 수가 증가하여 구조물의 특성을 보다 더 정확하게 예측하도록 작용한 것으로 판단된다.

센서의 수가 동일한 경우에는 중저층에 센서를 설치하는 것이 상대적으로 더 좋은 예측 성능을 가지는 것으로 나타났다.

이는 최상층에 센서 하나가 고정되기 때문에 정확한 예측을 위해서는 이것과 거리가 떨어진 위치에 센서를 설치하는 것이 예측을 하는데 유리한 것으로 분석된다.

Table 1은 60개의 설계안에 대한 예측 오차에 대한 통계분석 결과이다. 다양한 분석을 위해 특정 설계안에 대한 예측 결과를 추가적으로 비교하였고, 이를 Table 2에 나타내었다. Table 2에서 모드형상의 유사성(Modal Assurance Criteria, MAC)은 식 (1)을 이용하여 구한다.

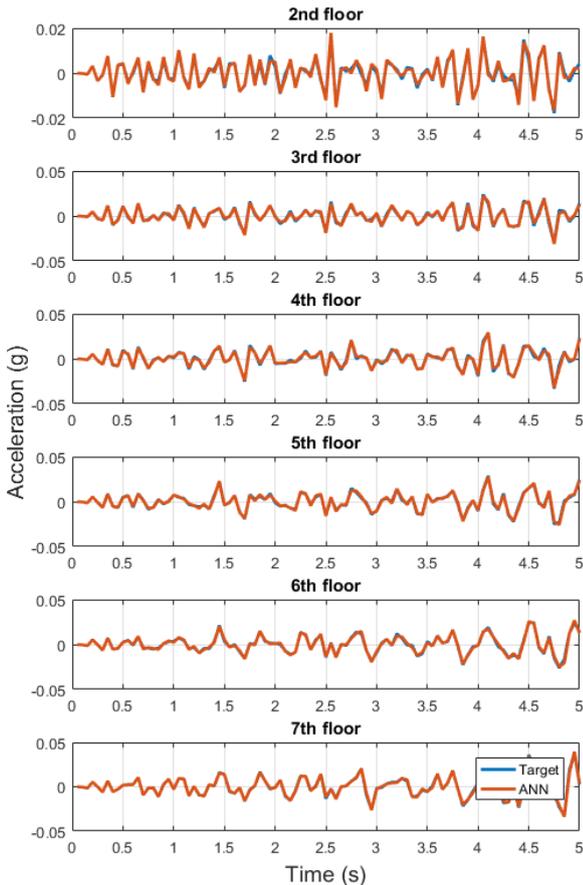
$$MAC_{ij} = \frac{[\{x_i\}^T \{\phi_j\}]^2}{[\{x_i\}^T \{x_j\}][\{\phi_j\}^T \{\phi_j\}]} \quad (1)$$

여기서, x_i 는 i 번째 기준모드형상을 의미하며, ϕ_j 는 j 번째 비교모드형상을 의미한다. MAC값은 0과 1사이의 값을 가지며, 1에 가까울수록 높은 상관관계를 의미한다.

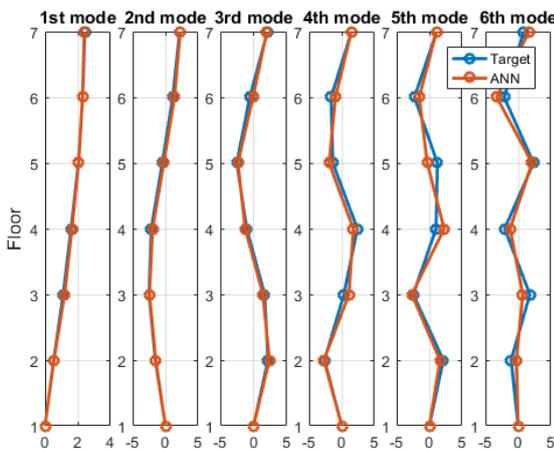
인공신경망에 의해 예측된 질량, 강성, 고유진동수, MAC은 대체로 정해와 유사한 것으로 나타났다. 설치되는 센서 수가 증가함에 따라 정해의 값과 유사해지는 경향을 나타내었다. 센서가 적을 경우 고차모드에서 오차가 상대적으로 커지는 것으로 나타났다. Fig. 5는 Table 2에서 센서가 1개 사용되었을 경우에 대한 층별 이력과 모드형상을 정해와 비교한 것이다. ‘Target’은 정해를 의미하며, ‘ANN’은 인공신경망에 의해 예측된 값을 의미한다. 예측값이 정해와 유사한 것을 확인할 수 있다.

10층 예제 결과를 Fig. 6에 나타내었으며, 센서 수에 따른 평

가지표 평균치는 Fig. 4에 표현하였다. Fig. 6에서 센서 설치의 위치 조합에 따른 편차가 있지만, 설치 수가 증가함에 따라 예측 정확도는 향상되는 것을 확인할 수 있다. 2개의 센서를 설치할 경우 2층과 최상층 바닥에 설치하는 것이 예측정확도가 가장 높았으며, 3개의 센서를 설치할 경우에는 2층, 7층과 최상층 바닥에 센서를 설치하는 것이 예측정확도가 가장 높았다.



(a) Acceleration response



(b) Mode-shape

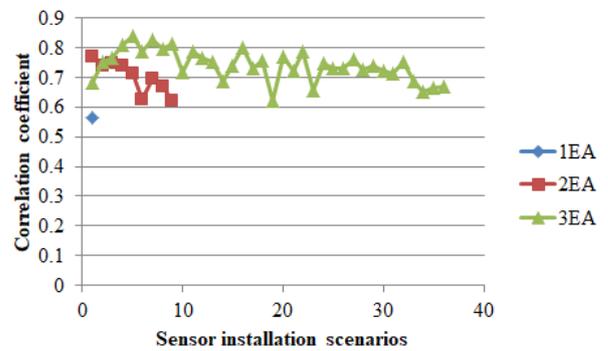
Fig. 5 Comparison of exact and predicted solutions (6-story structure)

특정 설계안에 대한 각 센서 수에 따른 예측정확도를 Table 3에 정리하였다. 정해와 유사한 설계안을 예측하는 것을 확인할 수 있다. Fig. 7은 Table 3에서 센서가 1개(최상층 바닥 설치)가 사용되었을 경우에 대한 층별 이력과 모드형상을 정해와 비교한 것이다. 층별 가속도이력 및 모드형상을 정해와 유사하게 예측하는 것으로 나타났다.

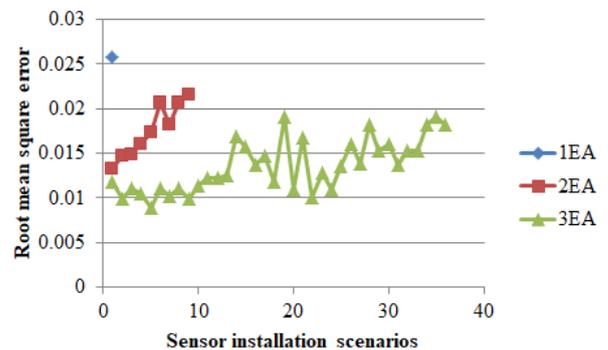
4. 결론

본 연구에서는 인공지능망을 이용해 건물 구조물의 가속도계 설치 위치 및 개수를 선정하는 방법을 제안한다. 인공지능망의 입력층에는 층에 설치되는 가속도계로부터 얻는 가속도 이력데이터가 입력되며, 출력층에는 구조물을 정의하는 각 층의 질량과 강성 값을 출력하도록 신경망을 구성한다. 가속도계의 설치 위치 및 개수를 선정하기 위해 여러 설치 시나리오를 가정하고 각 경우에 대한 인공지능망을 구하고 예측 성능을 비교하였다.

예제 적용 결과, 설치 위치 및 개수에 따라 예측 정확도가 달라지는 것으로 나타났으며, 이에 근거하여 센서의 위치 및 개수를 선정할 수 있었다. 설치되는 센서의 수가 증가할수록 구조물의 특성을 예측하는 성능은 증가한 것으로 나타났다.



(a) Correlation coefficient



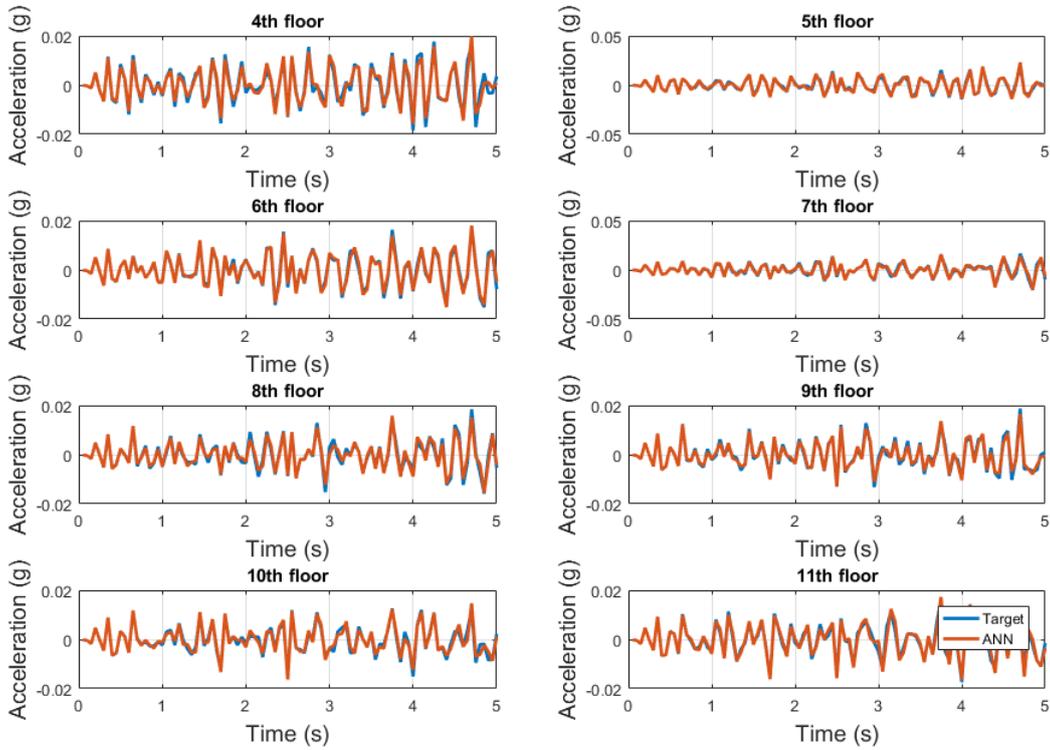
(b) Root mean square error

Fig. 6 Comparison of prediction results with respect to the number of sensors(10-story structure)

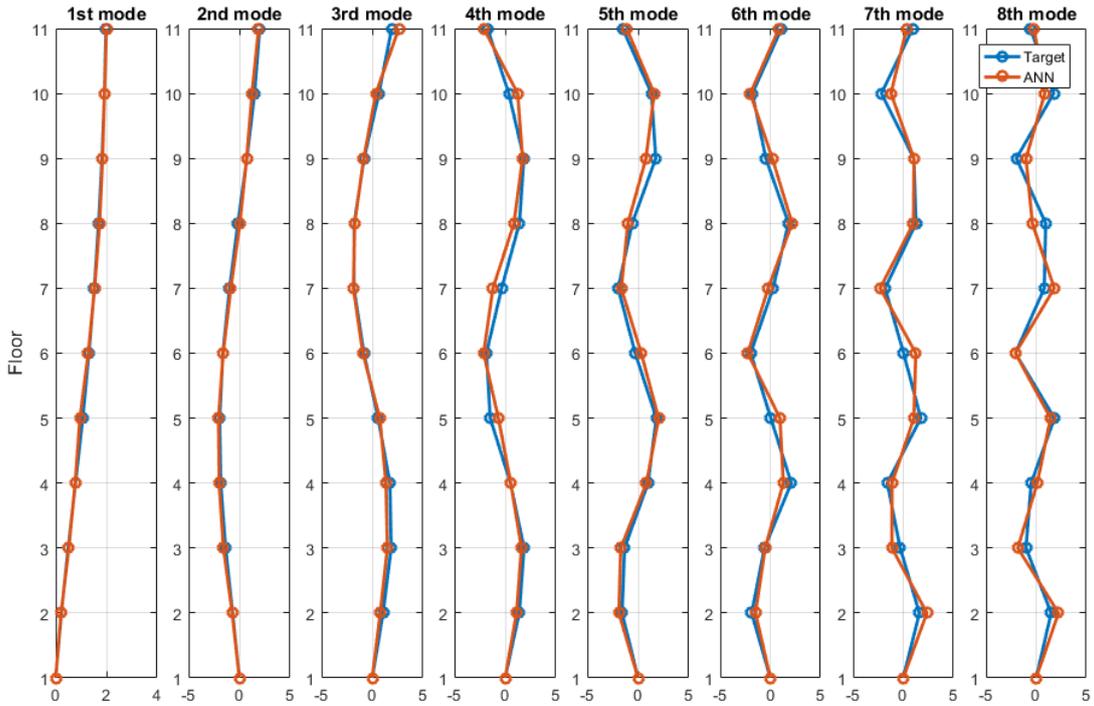
센서의 수가 동일한 경우에는 중저층에 센서를 설치하는 게 상대적으로 더 좋은 예측 성능을 가지는 것으로 나타났다. 지진·화산재해대책법에 따라 최상층에 의무로 설치한 상태에

서 추가적인 설치를 검토할 경우 최상층과 거리가 먼 중저층에 센서를 설치하는 것이 유리한 것으로 분석된다.

본 연구에서 고려된 구조물과 같이 고차모드의 영향이 적은



(a) Acceleration response



(b) Mode-shape

Fig. 7 Comparison of exact and predicted solutions(10-story structure)

Table 3 Prediction investigation of solutions from ANN(10-story structure)

No. of Sensors	Mass ratios									
	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
1	0.95	0.91	1.04	1.02	1.08	1.07	0.94	1.03	0.88	1.09
2	0.92	1.09	1.06	1.11	1.02	1.12	0.93	1.08	1.09	1.04
3	1.02	1.09	0.98	1.06	1.11	0.96	1.06	1.01	0.95	1.03
No. of Sensors	Stiffness ratios									
	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10
1	0.99	1.16	0.90	0.68	1.39	1.17	1.17	0.86	0.79	1.53
2	1.05	1.10	0.78	1.29	1.06	1.39	1.24	1.33	0.82	0.97
3	1.05	1.04	1.12	0.91	0.96	1.51	1.15	1.08	1.19	1.07
No. of Sensors	Natural frequency ratios									
	1st	2nd	3rd	4th	5th	6th	7th	8th	9th	10th
1	1.01	1.01	1.03	1.04	1.04	1.05	1.00	1.04	0.98	0.96
2	1.03	1.04	1.03	1.05	1.00	1.06	1.05	1.06	0.94	0.94
3	1.04	1.05	1.05	1.01	1.06	1.03	1.08	0.99	1.05	1.00
No. of Sensors	Modal Assurance Criteria(MAC)									
	1st	2nd	3rd	4th	5th	6th	7th	8th	9th	10th
1	1.00	0.99	0.95	0.86	0.90	0.87	0.76	0.71	0.57	0.66
2	1.00	1.00	0.99	0.94	0.93	0.91	0.78	0.64	0.79	0.90
3	1.00	1.00	0.98	0.99	0.96	0.95	0.87	0.76	0.80	0.98

구조물의 경우 최상층에 센서를 설치한 것으로도 충분한 예측이 가능한 것으로 판단된다. 다만 이를 위해서는 센서로부터 얻은 응답값을 가지고 구조물의 질량과 강성 정보를 예측하는 기법이 요구되며, 예측기법에 따라 예측 정확도는 달라질 것이다.

감사의 글

이 논문은 2017년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. NRF-2017R1D1A1B03034978).

References

- Brincker, R., Zhang, L., Andersen, P.** (2001) Modal Identification of Output-only Systems Using Frequency Domain Decomposition, *Smart Mater. & Struct.*, 10, pp.441~445.
- Choi, S.W.** (2018) Estimation of Rotational Stiffness of Connection in Steel Moment Frames by using Artificial Neural Network, *J. Korea Inst. Struct. Maint. & Insp.*, 22(1), pp.107~114.
- Chung, C.H., An, H.H., Shin, S.B., Kim, Y.H.** (2014) Reset of Measurement Control Criteria for Monitoring Data through the Analysis of Measured Data, *J. Korea Inst. Struct. Maint. & Insp.*, 18(6), pp.105~113.
- Cross, E.J., Koo, K.Y., Brownjohn, J.M.W., Worden, K.** (2013) Long-term Monitoring and Data Analysis of the Tamar Bridge, *Mech. Syst. & Signal Proc.*, 35(1-2), pp.16~34.
- Kim, K.S., Jung, S.M., Han, S.E.** (2005) Prediction of Shear Strength Using Artificial Neural Network for Reinforced Concrete Members without Shear Reinforcement, *J. Comput. Struct. Eng. Inst. Korea*, 18(2), pp.201~211.
- Kim, E.J., Park, J.W., Sim, S.H.** (2016) Kalman Filter-based Data Recovery in Wireless Smart Sensor Network for Infrastructure Monitoring, *J. Korea Inst. Struct. Maint. & Insp.*, 20(3), pp.42~48.
- Kim, J.H., Park, W.J., Park, J.O., Park, S.H.** (2018) LoRa LPWAN Sensor Network for Real-Time Monitoring and It's Control Method, *J. Comput. Struct. Eng. Inst. Korea*, 31(6), pp.359~366.
- Korea Ministry of Government Legislation**, <http://www.law.go.kr/> (accessed May, 30, 2020).
- Kwag, S., Hahm, D.** (2019) A Propose on Seismic Performance Evaluation Model of Slope using Artificial Neural Network Technique, *J. Comput. Struct. Eng. Inst. Korea*, 32(2), pp.93~101.
- Lee, Y.H., Kim, J.H., Lee, S.H.** (2016) The Optimal Placements and Number of Sensors for Dynamic Monitoring of Tall Buildings, *J. Wind Eng. Inst. Korea*, 20(2), pp.99~105.
- Lee, S.Y., Huynh, T.C., Park, J.H., Kim, J.T.** (2019) Bolt-Loosening Detection using Vision-Based Deep Learning Algorithm and Image Processing Method, *J. Comput. Struct. Eng. Inst. Korea*, 32(4), pp.265~272.
- Lim, J.H., Jung, J.W., Moon, D.J., Choi, D.H.** (2016) A Development of Real-time Vibration Monitoring and Analysis System Linked to the Integrated Management System of Ministry of Public Safety and Security, *J. Korea Inst. Struct. Maint. & Insp.*, 20(3), pp.130~139.

OpenSees, <http://opensees.berkeley.edu/> (accessed May 30, 2020)

Park, J.H., Kim, J.T., Lee, Y.H. (2007) ANN-Based Real-Time Damage Detection Technique Using Acceleration Signals in Beam-Type Structures, *J. Comput. Struct. Eng. Inst. Korea*, 20(3), pp.229~237.

PEER Ground Motion Database, <http://ngawest2.berkeley.edu/> (accessed May 30, 2020)

Sirca Jr, G.F., Adeli, H. (2012) System Identification in Structural Engineering, *Sci. Iran.*, 19(6), pp.1355~1364.

요 지

본 연구에서는 인공신경망을 이용해 건물 구조물의 가속도계 설치 위치 및 개수를 선정하는 방법을 제안한다. 인공신경망의 입력층에는 층에 설치되는 가속도계로부터 얻는 가속도이력데이터가 입력되며, 출력층에는 구조물을 정의하는 각 층의 질량과 강성 값을 출력하도록 신경망을 구성한다. 가속도계의 설치 위치 및 개수를 선정하기 위해 여러 설치 시나리오를 가정하고 훈련을 통해 인공신경망을 구한다. 훈련에 사용되지 않은 예제를 이용해 예측 성능을 비교하였다. 센서 개수 및 위치에 따른 예측 성능을 비교하여 설치 위치 및 개수를 선정한다. 6층과 10층 예제 적용을 통해 제안하는 방법을 검증하였다.

핵심용어 : 인공신경망, 시스템 식별, 설치 위치, 센서 개수