

인공신경망을 이용한 철골모멘트골조 접합부의 회전강성 손상예측

최세운^{1*}

Estimation of Rotational Stiffness of Connections in Steel Moment Frames by using Artificial Neural Network

Se-Woon Choi^{1*}

Abstract: In this study, the damage detection method is proposed for the rotational stiffness of connections in steel moment frames by using artificial neural network(ANN). The flexural moment of columns, natural frequencies, modeshapes are used for the input layer in ANN while the damage index, that signify the damage level, is used for the output layer in ANN. The 5-story steel moment frame as an example structure is used to generate the train and test data. Total number of damage scenarios considered is 829. From the results of application, it is shown that the proposed method can accurately estimate the location and level of damages.

Keywords: Artificial neural network, Damage detection, Rotational stiffness, Steel moment frame

1. 서 론

건축물을 구성하는 구조 부재 및 요소는 중력, 지진, 바람 등과 같은 외부 하중에 저항하여 건축물의 형태 및 공간을 유지하는 역할을 수행한다. 이를 통해 건물의 고유 기능이 제공된다. 이들의 성능은 구조물의 안전과 밀접한 관련이 있기 때문에 ‘초고층 및 지하연계 복합건축물 재난관리에 관한 특별법’, ‘지진·화산재해대책법’에서는 건물의 계층 관리를 강제화하고 있다. 이는 가속도와 같은 구조물의 구조응답을 계층하여 구조물의 안전 및 위험을 판단하고 신속한 대처를 통해 피해를 최소화하는데 목적을 둔다.

구조물의 반응은 작용하는 하중의 시간적, 공간적 특성에 따라 달라지기 때문에 구조물의 반응 계층 데이터의 분석 없이 반응 크기만으로 구조물의 안전 및 손상을 평가하기에는 한계가 있다. 그래서 구조물의 손상 여부를 예측하는데 구조물의 고유진동수, 모드형상과 같은 동적 특성이 주로 활용된다(Yoo and Lee, 2013; Yoo, 2014; Kim et al., 2003; Peeters et al., 2001; Doebling et al., 1998; Fan and Qiao, 2011). 이러한 동적 특성은 외부 하중의 시간적, 공간적 특성과는 상관없이

구조물의 강성과 질량 등에 의해 결정되는 고유 특성이기 때문에 손상이 없으면 구조물의 동적 특성은 변화가 없는 반면에, 손상이 발생하면 동적 특성은 변하게 된다.

일반적으로 건축물에 손상이 발생하는 경우는 지진, 태풍과 같이 건축물에 과도한 하중이 작용하거나, 시간 경과에 따른 노후화가 진행된 경우가 있다. 구조적 손상은 외부 힘에 대한 저항 성능이 저하된 것을 의미하며, 이는 구조 요소의 강성 저하로 정의될 수 있다. 강성 저하가 발생하면 구조물의 변형량 및 고유진동수 등이 증가하게 된다. 따라서 가속도 응답을 이용해 구조물의 동특성을 분석하면 구조물의 손상 여부를 판단할 수 있다.

가속도계는 구조물의 가속도 응답을 편리하고 신뢰성 있게 얻을 수 있는 계층기 중에 하나이다. 구조물 내 여러 층에 이를 설치하여 구조물의 가속도 응답을 수집하여 구조물의 고유진동수, 모드형상, 감쇠비 등을 얻을 수 있다. 그러나 이들은 구조물 레벨의 특성치를 나타내는데 유용하지만, 국부적인 손상을 탐지하기에는 한계가 있다. 즉, 접합부와 같은 국부적인 손상은 구조물의 동특성에 대한 영향이 적기 때문에 접합부 손상에 따른 구조물의 동특성 변화만으로 손상의 위치와 정도를 예측하기에는 한계가 있다(Wang and Deng, 1999; Kim and Melhem, 2004). 이러한 한계점을 해결하기 위해 Curvature Mode Shapes, Flexibility, Modal Strain Energy (MSE) 등과 같은 다양한 지표의 변화를 분석하여 손상의 위치 및 크기를 예측하는 기술이 제시되었다(Pandey et al., 1991; Shi et al., 2000;

¹정회원, 대구가톨릭대학교 건축학부 조교수, 교신저자

*Corresponding author: watercloud@cu.ac.kr

Dept. of Architecture, Daegu Catholic University, Gyeongsan, Gyeongbuk, 38430, Korea

•본 논문에 대한 토의를 2018년 2월 1일까지 학회로 보내주시면 2018년 3월호에 토론결과를 게재하겠습니다.

Pandey and Biswas, 1994; Yan et al., 2010).

구조물에 센서를 많이 설치할수록 많은 정보를 얻을 수 있기 때문에 보다 더 정확한 분석이 가능하여 손상평가의 신뢰도를 높일 수 있다. 그러나 센서를 많이 설치할수록 비용이 증가하고 유지관리가 어려운 단점이 있다. 따라서 현실에서는 한정된 센서만 설치할 수 밖에서 없으며, 이는 손상평가의 신뢰성을 저하시키는 원인이 된다(Li et al., 2008; Law et al., 1998; Shi et al., 2000; Park and Park, 2003).

손상평가기법의 예측 정확도를 높이기 위해 최적화 알고리즘을 활용한 연구가 수행되었다. Cha and Buyukozturk (2015)는 최적화 알고리즘으로 Implicit Redundant Representation Genetic Algorithm (IRR GA)을 사용한 손상평가기법을 제시하고 이를 철골 구조물 예제에 적용하여 해석적으로 검증하였다. 제시된 기법은 한정된 데이터만으로도 다수의 경미한 손상 위치 및 정도를 탐지할 수 있었다. 손상을 평가하기 위해 MSE가 주요 지표로 이용되었다. Kang et al. (2012)는 Particle Swarm Optimization (PSO)와 Artificial Immune System을 접목하여 향상된 PSO를 활용한 손상평가기법을 제시하였다. 고유진동수와 모드형상 데이터가 손상평가를 위한 목적함수 평가에 활용되었다. 보, 트러스 구조물 예제에 이를 적용하여 기존 최적화기법(PSO)에 의한 결과와 비교 검증하였다. 손상 위치 및 크기를 효과적으로 탐지하는 것으로 나타났다. Seyedpoor (2012)는 두 단계로 이루어진 손상평가기법을 제시하고, 보 및 트러스 구조물 예제를 통해 해석적으로 검증하였다. 이는 먼저 MSE의 변화를 통해 구조물의 손상 위치를 탐지하고, 그 결과에 PSO기법에 적용하여 손상 수준을 예측하도록 하였다. Perera et al. (2007)은 Modal Flexibility과 Modal Parameter를 동시에 고려한 다목적 최적화기법을 제시하였으며, 보 구조물 예제에 적용하여 해석적으로 검증하였다. 다수의 지표를 고려함으로써 각 지표가 가지는 단점을 보완하도록 하였다.

본 연구는 인공신경망(Artificial Neural Network, ANN)을 이용해 철골모멘트골조의 접합부 손상을 예측하는 기법을 제안한다. 저자는 선행 연구(Kim and Choi, 2016)를 통해 기동열에 설치된 변형률센서로부터의 응답값을 이용해 구조물의 횡응답(횡변위, 횡가속도)을 예측하는 기법을 제시하였다. 선행 연구 결과를 이용해 구조물레벨의 데이터(고유진동수, 모드형상 등)와 부재레벨의 데이터(휨모멘트)를 조합한 손상평가기법을 제안한다. 구조물의 동특성(고유진동수, 모드형상)과 모멘트 응답이 입력값으로 사용되며, 지점 및 보-기동 접합부의 회전강성의 손상지표가 출력값으로 설정된다. 손상지표는 손상수준을 나타낸다. 5층 철골모멘트골조 예제의 수치해석을 통해 훈련 및 검증용 데이터를 생성한다. 예제 검증을 통해 제시하는 기법의 손상 위치 및 수준 예측 정확성을 분석한다.

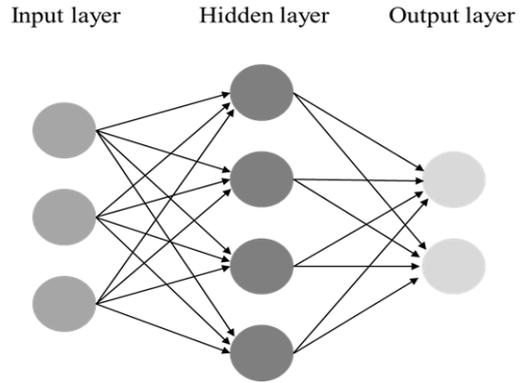


Fig. 1 Organization of Artificial Neural Network(ANN)

2. 인공신경망

인공신경망의 구조는 Fig. 1과 같이 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer)로 구성된다. 입력층에서는 입력층을 이루는 노드의 개수만큼의 값이 입력된다. 참고로 Fig. 1에 표시된 입력층을 이루는 노드는 3개이다. 각 입력값은 가중치를 통한 선형조합을 통해 값이 변환되어 은닉층을 이루는 각 노드에 전달된다. 이러한 값은 은닉층에 위치한 활성화함수의 입력값이 된다. 활성화함수에는 step 함수, sigmoid 함수, ReLU 함수 등 다양한 종류가 있다. 활성화함수의 출력값은 각각 다시 가중치가 곱해지고 은닉층 내의 다른 노드의 출력값과 합쳐져 출력층의 노드에 전달된다. 출력층 내의 각 노드의 값은 출력값을 의미하게 된다.

사전에 수집된(입력, 출력) 데이터는 인공신경망 내의 가중치값을 결정하는데 학습데이터로 활용된다. 사전에 수집된(입력, 출력) 데이터는 일종의(입력, 정답) 관계를 의미하며, 인공신경망에 동일한 입력 데이터를 입력하였을 때 정답과 오차가 적은 출력값을 생성하도록 반복계산을 통해 가중치값을 결정한다. 이러한 학습과정을 통해 생성된 신경망은 입력값을 알고 있으나 정답값은 모르는 상황에서 입력값을 신경망에 전달하여 정답값을 예측하는데 활용할 수 있다. 인공신경망은 건축, 토목 등 다양한 공학분야에서 설계, 시스템 식별, 손상평가, 비용 예측, 구조최적화, 지진 예측 등의 목적으로 널리 사용되고 있다(Rafiq et al., 2001; Flood and Kartam, 1994; Wu et al., 1992; Adeli, 2001).

3. 변형률 기반 횡응답 예측

손상평가에서 주로 사용되는 구조물레벨의 가속도응답은 국부적인 손상을 파악하는데 한계가 있는 것으로 알려져 있기 때문에(Wang and Deng, 1999; Kim and Melhem, 2004), 본

연구에서는 부재레벨의 모멘트 응답을 함께 사용하는 손상평가기법을 제시하고자 한다. 이를 위해 본 저자의 선행 연구 결과(Kim and Choi, 2016)에서 제시된 변형률 응답을 이용한 건축물의 횡응답 기법을 사용한다. 본 절에서는 이에 대한 내용을 요약 정리하였으며, 자세한 사항은 Kim and Choi(2016)을 참고하기 바란다

3.1 기둥 부재의 휨모멘트 분포 예측

기둥부재의 휨모멘트 분포를 추정하기 위해 변형률 센서는 Fig. 2와 같이 기둥의 양 단부에 총 4개씩 설치된다고 가정한다. 기둥의 양단부에 2개씩 변형률 센서를 설치하기 때문에 단부면에서의 변형률 분포를 얻을 수 있다. 식 (1)과 같이 단면의 변형률 ε 에 탄성계수 E 와 부재 단면계수 Z 를 곱하면 해당 위치에서의 모멘트 M 를 얻을 수 있다.

$$M = \varepsilon EZ \quad (1)$$

한편, 일반적으로 기둥 부재 내에서는 분포하중 또는 횡하중이 작용하지 않는다고 가정하기 때문에 기둥 부재의 휨모멘트 분포는 양 단부의 모멘트를 선형으로 이어주면 얻을 수 있다. 따라서 부재 치수 및 탄성계수 값을 알고 있고, 기둥 양 단부에 2개씩 변형률 센서를 설치하면 해당 부재의 휨모멘트

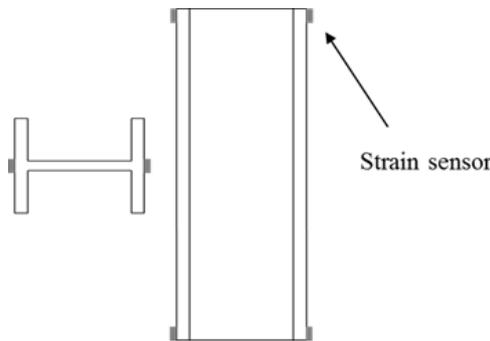


Fig. 2 Installment of strain sensors

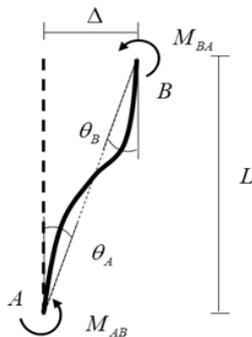


Fig. 3 Slope deflection method

분포를 예측할 수 있다.

3.2 기둥열의 횡변위 및 횡가속도 예측

건물 내 특정 기둥열을 이루는 모든 기둥에 동일한 방법으로 변형률 센서가 설치된다고 가정하면, 해당 기둥열의 휨모멘트 분포를 예측할 수 있다. 일반적인 골조의 횡변위는 휨변형에 의해 지배되기 때문에 축력 및 전단력에 의한 횡변위 기여도는 작으며, 휨모멘트에 의한 횡변위 기여도만 고려해도 신뢰할 만한 결과값을 얻을 수 있다(Hibbeler, 2011). 따라서 기둥열의 휨모멘트 분포를 예측할 수 있다는 것은 해당 구조물의 횡변위 응답을 얻을 수 있음을 의미하며, 이는 선행 연구를 통해 검증되었다(Kim and Choi, 2016). 선행 연구(Kim and Choi, 2016)에서는 처짐각법(Slope Deflection Method)을 이용하여 Fig. 3과 같이 기둥의 횡처짐 Δ 과 처짐각 θ 을 구하고, 이를 누적하여 기둥열의 횡변위를 구하였다.

한편, 처짐각법에 의해 예측된 각 층의 횡변위 응답 $y(t)$ 은 식 (2)와 같이 이중미분을 하면 각 층의 횡방향 가속도 응답 $a(t)$ 을 예측할 수 있다.

$$a(t) = \frac{-y(t-3) + 4y(t-2) - 5y(t-1) + 2y(t)}{(\Delta t)^2} \quad (2)$$

예측된 횡변위 혹은 횡가속도 응답 이력값은 구조물의 고유진동수, 모드형상, 감쇠비 등과 같은 동특성을 파악하는데 활용될 수 있다. Brincker et al.(2001)은 응답데이터만으로 모달 파라미터를 식별할 수 있는 Frequency Domain Decomposition (FDD)을 제시하였으며, 이는 교량 및 건물의 상시 진동 데이터로부터 동특성을 추출하는데 활용되고 있고 있다(Weng et al., 2008; Michel et al., 2010). 본 연구에서는 식 (2)로부터 얻은 횡가속도 이력 데이터를 FDD기법에 적용하여 구조물의 고유진동수, 모드형상 값을 추출한다.

4. 예제 적용

4.1 예제 개요

본 연구에서는 Fig. 4와 같은 5층 1경간 철골모멘트골조 예제를 사용한다. 층높이와 경간 길이는 각각 3.96 m, 9.14 m이다. 3장에서 설명한 변형률 데이터를 이용해 구조물의 횡응답을 계산하기 위해 왼쪽 기둥열에 각 층의 기둥당 4개씩 변형률계가 설치되어 총 20개의 센서가 사용된다고 가정한다.

그리고 본 예제의 붕괴모드는 지점과 보에서 힌지가 발생하는 보-힌지 붕괴모드(Beam-hinge collapse mechanism)를

가진다고 가정하고, 이를 통해 지점과 보 접합부를 회전 스프링을 이용해 모델링하도록 한다.

손상 전후의 회전스프링 거동은 선형 거동을 한다고 가정한다. 그리고 만약 지진에 의한 손상은 회전 스프링이 위치한 곳에서만 발생하며, 이는 해당 스프링의 강성 저하로 고려될 수 있다고 가정한다.

구조물의 진동을 발생시키기 위해 가진기가 최상부층에 위치한다고 가정한다. 가진기를 통해 백색잡음(White noise) 및 조화하중을 발생시키고, 기둥 단부(변형률이 설치되었다고 가정된 곳)에서 변형률 값을 얻고 이를 통해 휨모멘트, 횡가속도 응답, 고유진동수, 모드형상 등을 얻는다.

구조해석은 OpenSees를 사용한다. 기둥, 보 등의 부재는 탄성부재를 사용하며, 패널존의 강성 및 강도 효과는 고려하지 않는다. 회전스프링의 강성은 $6EI/L(E$ 탄성계수, I 단면이차모멘트, L 부재길이)을 통해 설정한다. 다이어프램 및 P-delta 효과는 고려되며, gravity-frame에 의한 기여는 고려하지 않는다.

본 연구에서는 Backpropagation Algorithm(BP)을 사용하여 신경망 내의 가중치를 결정하도록 한다. Fig. 1에서 신경망의 입력층에는 고유진동수, 모드형상, 기둥 단부의 모멘트 값을 입력한다. 예제 구조물의 경우 1차와 2차 모드의 질량참여율을 합하면 90% 이상 값을 나타내기 때문에, 고유진동수와 모드형상은 1차와 2차만 고려한다. 따라서 고유진동수를 입력하기 위해서는 2개의 노드가 필요하며, 모드형상을 입력하기 위해서는 10개(5층*2개 모드)의 노드가 필요하다. 한편, 기둥 단부의 휨모멘트값을 입력하기 위해서는 10개(2개/기둥*5기둥)의 노드가 필요하다. 이를 종합하면, 총 22개의 입력노드가 사용된다. 은닉층의 노드는 20개로 설정한다. 은닉층의 활성화함수는 sigmoid함수가 사용된다.

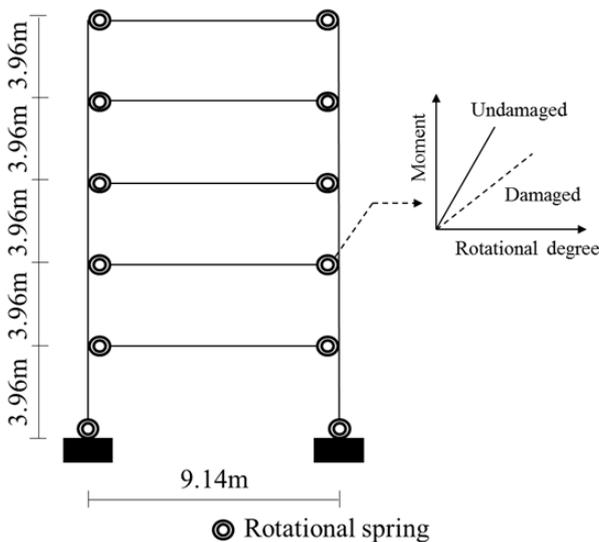


Fig. 4 Example structure

출력층의 노드에는 회전스프링의 손상지표(DF)이 연결된다. DF는 식 (3)과 같이 활용된다. DF가 1.0이면 손상이 없다는 것을 의미하며, DF가 0.8이면 해당 회전스프링이 위치한 곳에 손상이 발생하여 회전스프링의 강성값이 20% 저감하였음을 의미한다. 본 연구에서는 층별로 독립적인 손상이 발생할 수 있는 반면에, 동일 층 내에서는 동일한 손상이 발생한다고 가정한다. 따라서 Fig. 4에서 동일 층에 위치한 회전스프링의 DF는 동일한 변수가 연결되어 총 6개의 DF 변수가 사용된다. 출력층에는 총 6개의 노드가 설정되어 각 DF 값을 출력하게 된다.

$$\text{손상 후 회전강성} = DF \times \text{손상 전 회전강성} \quad (3)$$

본 연구에서는 인공신경망을 훈련하고 손상 예측의 정확성을 평가하기 위해 총 729가지의 손상시나리오를 고려하였다. 각 회전스프링의 DF는 1.00, 0.75, 0.50와 같이 총 3가지의 값을 가질 수 있도록 하여 $729(=3^6)$ 가지의 손상시나리오에 대한 구조해석을 수행하고 이들의 결과로부터 입력층과 출력층에 필요한 변수들의 값을 정리하였다.

총 729가지 손상시나리오 중 656가지 시나리오(약 90%)의 결과는 인공신경망을 훈련 및 검증하는데 사용하며, 나머지 73가지 시나리오(약 10%)의 손상 예측의 정확성을 평가하는데 활용한다. 73가지의 시나리오 데이터에는 각 시나리오의 입력값을 신경망에 입력할 경우 출력되어야 할 정확한 출력값을 가지고 있다. 따라서 656가지 시나리오 데이터를 통해 생성한 신경망에 새로운 73가지 시나리오의 입력값을 넣게 되면 신경망에 의한 예측값을 얻을 수 있으며, 이를 참값과 비교할 수 있다. 이러한 신경망의 손상 예측값의 오차를 평가하는 설명도를 Fig. 5에 나타내었다.

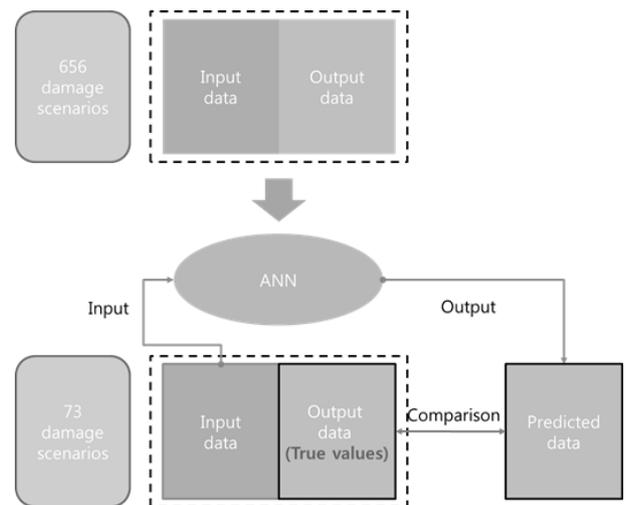
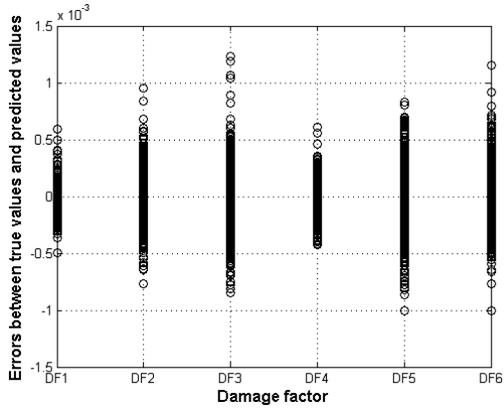


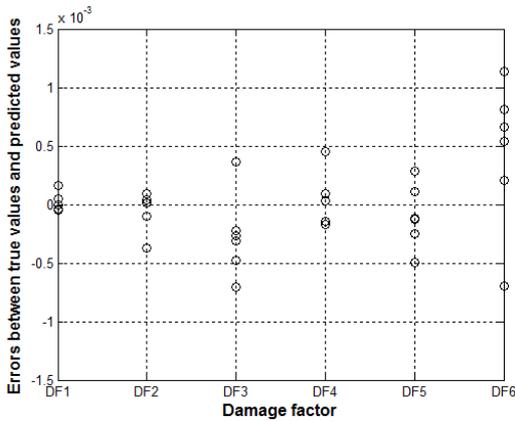
Fig. 5 Illustration of damage prediction by using ANN

4.2 적용 결과

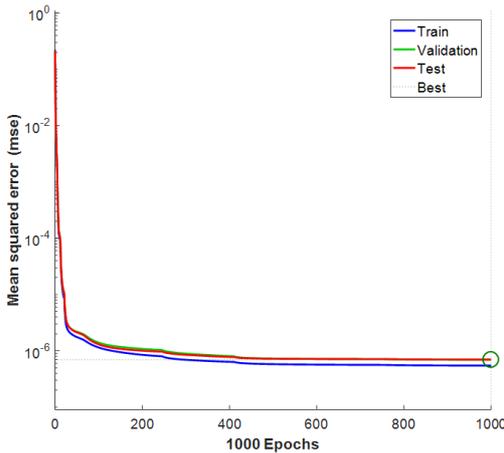
Fig. 4와 같은 예제 구조물의 시뮬레이션 데이터를 이용하여 인공신경망을 훈련하고 이를 통해 접합부 손상을 예측한 결과는 Fig. 6과 같다. Fig. 6(a)는 인공신경망을 훈련시키는 과정에서 발생한 오차이며, Fig. 6(b)는 훈련을 통해 생성된 인공신경망에 새로운 시뮬레이션 데이터를 적용하여 회전강성



(a) Training errors



(b) Prediction errors

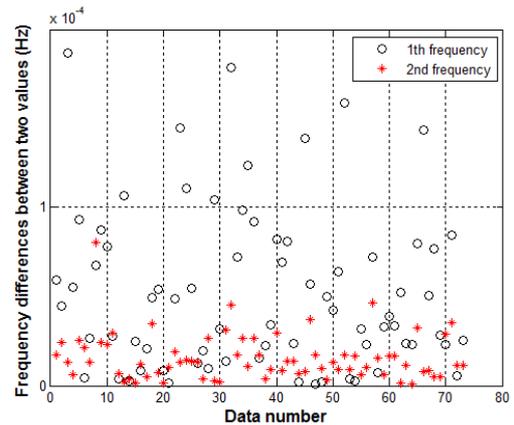


(c) Mean squared errors

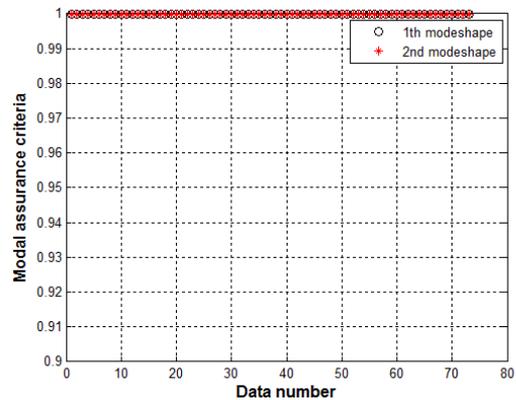
Fig. 6 Errors from ANN(Method 1)

값을 예측한 결과이다. Fig. 5에서 나타난 것처럼 본 연구에서 사용된 시뮬레이션 데이터는 인공신경망을 생성하기 위해 사용되는 훈련용 데이터와 이를 검증하기 위해 사용되는 데이터를 구분된다. 그림에 나타난 것처럼 모든 손상지표(DF1~DF6)에 대한 오차가 0.002 이하의 수준인 것을 확인할 수 있다. 이는 손상위치 및 정도를 높은 정확도를 가지고 예측할 수 있음을 의미한다. Fig. 6에서 사용된 데이터는 각 손상지표(DF)의 값을 0.50, 0.75, 1.00으로 한정시키고 검증한 결과이다(Method 1). 즉, 인공신경망을 훈련시키는데 동일한 조건에서 발생하는 손상 및 회전강성값에 대해서 정확히 예측할 수 있음을 확인할 수 있다.

예측된 회전강성값을 이용해 구조 모델링 및 해석을 수행하여 고유특성값을 얻고, 이를 참된 회전강성값으로 정의된 구조물의 고유특성값과 비교하였다. 그 결과는 Fig. 7과 같다. Fig. 7(a)는 1차, 2차 고유진동수의 오차를 나타내며, Fig. 7(b)는 1차, 2차 모드형상의 유사도를 의미한다. 모드형상의 유사도는 식 (4)와 같이 Modal Assurance Criteria(MAC)를 사용한다(Chang and Kim, 2008). MAC값은 0과 1사이의 값을 가지며, 1에 근접할수록 두 모드형상의 상관관계가 높다.



(a) Frequency



(b) Modal assurance criteria

Fig. 7 Comparison of dynamic properties(Method 1)

$$MAC_{ij} = \frac{[\{\phi_i\}^T \{\phi_j\}]^2}{[\{\phi_i\}^T \{\phi_i\}][\{\phi_j\}^T \{\phi_j\}]} \quad (4)$$

여기서, ϕ_i 와 ϕ_j 는 비교하는 두 모드형상을 의미한다. 고유진동수와 모드형상이 모두 유사하게 나타나는 것을 Fig. 7(a)과 7(b)를 통해 확인할 수 있다.

Fig. 6과 7은 훈련용 데이터와 동일한 조건(DF값이 0.50,

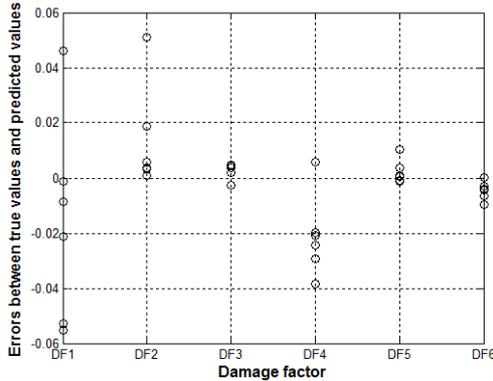
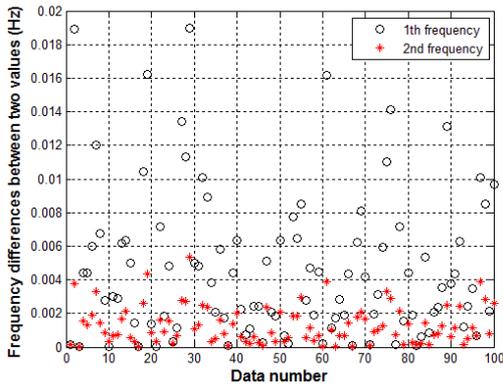
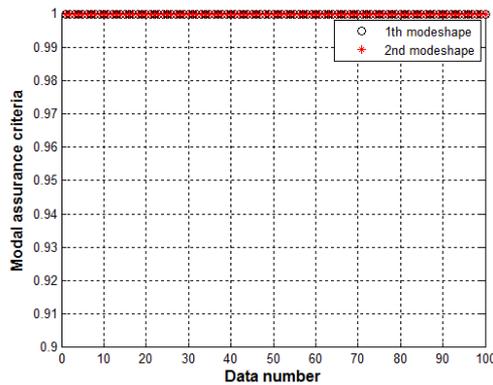


Fig. 8 Comparison of damage factor values(Method 2)



(a) Frequency



(b) Modal assurance criteria

Fig. 9 Comparison of dynamic properties(Method 2)

0.75, 1.00 중 한 값을 가짐)에서 예측된 결과이다. 훈련 데이터와 다른 상황에 대한 예측 정확도를 파악하기 위해서 각 DF는 0.5에서 1.0사이 중 임의 값을 랜덤하게 가지도록 설정한 후, 총 100개의 새로운 데이터를 생성하여 오차를 분석하였다(Method 2). 예를 들면, 한 경우의 회전강성값(DF1~DF6)은 (0.6673, 0.9531, 0.6470, 0.7349, 0.8268, 0.6951)이다. 회전강성의 예측 정확도는 Fig. 6의 결과보다는 오차가 크지만, Fig. 8에 나타난 것처럼 오차 수준은 0.06 이하로 나타났다. 이러한 오차는 Fig. 9(a)와 9(b)에 표시된 것처럼 참값에 근접한 고유진동수와 모드형상을 예측할 수 있는 수준이다.

5. 결론

본 연구는 인공지능망을 이용해 철골모멘트골조의 접합부 손상을 예측하는 기법을 제안한다. 인공지능망을 훈련하고 손상 예측의 정확성을 평가하기 위해 총 829가지의 손상시나리오(DF값이 0.50, 0.75, 1.00 중 한 값을 가지는 경우 729가지, DF값이 0.5에서 1.0 사이 중 임의의 값을 가지는 100가지)를 고려하였다. 인공지능망의 입력층에는 기둥 부재의 휨모멘트, 고유진동수, 모드형상 정보가 사용되며, 출력층에는 구조물 접합부의 회전강성 손상지표가 사용한다.

5층 1경간 철골모멘트골조 예제 검증 결과, 다수의 위치에서 발생하는 손상에 대해 위치별 손상정도를 신뢰할 수 있는 수준으로 예측할 수 있는 것으로 확인된다. 그러나 인공지능망 기반 예측성을 파악하기 위해 훈련용 데이터와 동일한 방법(Method 1)으로 생성된 데이터 결과(Figs. 6과 7)보다 데이터 범위는 동일하지만 생성방법을 다르게 할 경우(Method 2)의 결과(Figs. 8과 9)는 다소 오차가 크게 발생하는 것으로 나타났다.

감사의 글

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

References

Yoo, S. H., and Lee, H. K. (2013), Damage Location Detection of Shear Building Structures Using Mode Shape, *Journal of the Korea Institute for Structural Maintenance and Inspection*, 17(1), 124-132.

- Yoo, S. H. (2014), Damage Detection of Shear Building Structures Using Dynamic Response, *Journal of the Korea Institute for Structural Maintenance and Inspection*, 18(3), 101-107.
- Kim, J. T., Ryu, Y. S., Cho, H. M., and Stubbs, N. (2003), Damage Identification in Beam-Type Structures: Frequency-Based Method vs Mode-Shape-Based Method, *Engineering Structures*, 25(1), 57-67.
- Peeters, B., Maeck, J., and De Roeck, G. (2001), Vibration-Based Damage Detection in Civil Engineering: Excitation Sources and Temperature Effects, *Smart Materials and Structures*, 10(3), <https://doi.org/10.1088/0964-1726/10/3/314>.
- Doebling, S. W., Farrar, C. R., and Prime, M. B. (1998), A Summary Review of Vibration-Based Damage Identification Methods, *Shock and Vibration Digest*, 30(2), 91-105.
- Fan, W., and Qiao, P. (2011), Vibration-Based Damage Identification Methods: A Review and Comparative Study, *Structural Health Monitoring*, 10(1), 83-111.
- Wang, Q., and Deng, X. (1999), Damage Detection with Spatial Wavelets, *International Journal of Solids and Structures*, 36(23), 3433-3468.
- Kim, H., and Melhem, H. (2004), Damage Detection of Structures by Wavelet Analysis, *Engineering Structures*, 26(3), 347-362.
- Pandey, A. K., Biswas, M., and Samman, M. M. (1991), Damage Detection from Changes in Curvature Mode Shapes, *Journal of Sound and Vibration*, 145(2), 321-332.
- Shi, Z., Law, S. S., and Zhang, L. (2000), Structural Damage Detection from Modal Strain Energy Change, *Journal of Engineering Mechanics*, 126(12), 1216-1223.
- Pandey, A. K., and Biswas, M. (1994), Damage Detection in Structures using Changes in Flexibility, *Journal of Sound and Vibration*, 169(1), 3-17.
- Yan, W. J., Huang, T. L., and Ren, W. X. (2010), Damage Detection Method based on Element Modal Strain Energy Sensitivity, *Advances in Structural Engineering*, 13(6), 1075-1088.
- Li, H., Wang, J. and Hu, S. L. J. (2008), Using Incomplete Modal Data for Damage Detection in Offshore Structures, *Ocean Engineering*, 35(17), 1793-1799.
- Law, S. S., Shi, Z. Y., and Zhang, L. M. (1998), Structural Damage Detection From Incomplete and Noisy Modal Test Data, *Journal of Engineering Mechanics*, 124(11), 1280-1288.
- Shi, Z. Y., Law, S. S., and Zhang, L. M. (2000), Damage Localization by Directly Using Incomplete Mode Shapes, *Journal of Engineering Mechanics*, 126(6), 656-660.
- Park, N. G., and Park, Y. S. (2003), Damage Detection Using Spatially Incomplete Frequency Response Functions, *Mechanical Systems and Signal Processing*, 17(3), 519-532.
- Cha, Y. J., and Buyukozturk, O. (2015), Structural Damage Detection Using Modal Strain Energy and Hybrid Multiobjective Optimization, *Computer-Aided Civil and Infrastructure Engineering*, 30, 347-358.
- Kang, F., Li, J. J., and Xu, Q. (2012), Damage Detection based on Improved Particle Swarm Optimization using Vibration Data, *Applied Soft Computing*, 12, 2329-2335.
- Seyedpoor, S. M. (2012), A Two Stage Method for Structural Damage Detection Using A Modal Strain Energy Based Index and Particle Swarm Optimization, *International Journal of Non-Linear Mechanics*, 47, 1-8.
- Perera, R., Ruiz, A., and Manzano, C. (2007), An Evolutionary Multiobjective Framework for Structural Damage Localization and Quantification, *Engineering Structures*, 29, 2540-2550.
- Kim, S. J., and Choi, S. W. (2016), A Numerical Study to Estimate the Lateral Responses of Steel Moment Frames Using Strain Data, *Journal of the Korea Institute for Structural Maintenance and Inspection*, 20(6), 113-119.
- Rafiq, M. Y., Bugmann, G., and Easterbrook, D. J. (2001), Neural Network Design for Engineering Applications, *Computers & Structures*, 79(17), 1541-1552.
- Flood, I., and Kartam, N. (1994), Neural Networks in Civil Engineering I: Principles and Understanding, *Journal of Computing in Civil Engineering*, 8(2), 131-148.
- Wu, X., Ghaboussi, J., and Garrett, J. H. (1992), Use of Neural Networks in Detection of Structural Damage, *Computers & Structures*, 42(4), 649-659.
- Adeli, H. (2001), Neural Networks in Civil Engineering: 1989-2000, *Computer-Aided Civil and Infrastructure Engineering*, 16(2), 126-142.
- Hibbeler, R. C. (2011), *Structural Analysis*, Prentice Hall, 451-486.
- Brincker, R., Zhang, L. and Andersen, P. (2001), Modal Identification of Output-only Systems Using Frequency Domain Decomposition, *Smart Materials and Structures*, 10, 441-445.
- Weng, J. H., Loh, C. H., Lynch, J. P., Lu, K. C., Lin, P. Y., and Wang, Y. (2008), Output-only Modal Identification of a Cable-Stayed Bridge Using Wireless Monitoring Systems, *Engineering Structures*, 30, 1820-1830.
- Michel, C., Guéguen, P., El Arem, S., Mazars, J., and Kotronis, P. (2010), Full-scale Dynamic Response of an RC Building Under Weak Seismic Motions Using Earthquake Recordings, Ambient Vibrations and Modelling, *Earthquake Engineering & Structural Dynamics*, 39, 419-441.
- Chang, S. J., and Kim, N. S. (2008), Estimation of Displacement Response from the Measured Dynamic Strain Signals Using Mode Decomposition Technique, *KSCE Journal of Civil Engineering*, 28, 507-515.

Received : 08/22/2017

Revised : 12/12/2017

Accepted : 12/13/2017

요 지 : 본 연구는 인공지능망을 이용해 철골모멘트골조의 접합부 손상을 예측하는 기법을 제안한다. 인공지능망의 입력층에는 기둥 부재의 휨모멘트, 고유진동수, 모드형상 정보가 사용되며, 출력층에는 구조물 접합부의 회전강성 손상지표가 사용한다. 손상지표는 각 접합부의 손상정도를 의미한다. 5층 철골모멘트골조 예제의 수치해석을 통해 훈련 및 검증용 데이터를 생성한다. 총 829가지의 손상 시나리오가 고려된다. 시뮬레이션은 OpenSees를 이용해 반복 실행하여 데이터를 얻도록 하였으며, 훈련용 데이터를 생성할 때 회전 강성의 손상은 1.0, 0.75, 0.5 등 세 가지 중 하나의 값을 가지도록 하였다. 예제 검증을 통해 제시하는 기법은 손상 위치 및 수준을 정확하게 예측하는 것으로 나타났다. 제시하는 기법은 손상지표, 1차, 2차 고유진동수 및 모드형상 등에 대해 매우 유사한 결과를 제시하는 것으로 확인되었다.

핵심용어 : 인공지능망, 손상평가, 회전강성, 철골모멘트
