

# 구조물 손상평가를 위한 접합부 손상모델 및 신경망기법에 관한 연구

## A Study on Joint Damage Model and Neural Networks-Based Approach for Damage Assessment of Structure

윤정방\*      이진학\*\*      방은영\*\*\*  
Yun, Chung Bang      Yi, Jin Hak      Bahng, Eun Young

### 국문요약

프레임 구조물의 접합부 손상을 평가하기 위하여, 접합부 손상모델과 신경망기법을 이용한 손상평가기법을 제안하였다. 구조물의 보-기둥 접합부를 접합부의 회전강성을 갖는 등가의 스프링요소로 표현하였으며, 접합부의 손상도는 손상 전, 후의 고정도계수의 감소비율로 정의하였다. 손상평가를 위하여 다층퍼셉트론즈 신경망기법을 제안하였으며, 손상평가성능을 향상시키기 위하여 부분구조 추정법, 노이즈첨가학습, 자료교란법 등의 기법을 적용하였다. 10층 프레임 구조물에 대한 수치 예제해석과 2층 프레임 구조물에 대한 실험 예제해석을 통하여 제안기법의 유용성을 평가하였다. 계측지점이 일부분으로 제한되어 있고, 계측자료에 심한 계측오차가 포함되어 있는 경우에도 손상평가가 합리적으로 이루어질 수 있음을 알 수 있었다.

**주요어** : 접합부 손상평가, 고정도계수, 신경망기법, 부분구조추정법, 노이즈첨가학습, 자료교란법

### ABSTRACT

A method is proposed to estimate the joint damages of a steel structure from modal data using the neural networks technique. The beam-to-column connection in a steel frame structure is represented by a zero-length rotational spring at the end of the beam element, and the connection fixity factor is defined based on the rotational stiffness so that the factor may be in the range of 0-1.0. Then, the severity of joint damage is defined as the reduction ratio of the connection fixity factor. Several advanced techniques are employed to develop the robust damage identification technique using neural networks. The concept of the substructural identification is used for the localized damage assessment in the large structure. The noise-injection learning algorithm is used to reduce the effects of the noise in the modal data. The data perturbation scheme is also employed to assess the confidence in the estimated damages based on a few sets of actual measurement data. The feasibility of the proposed method is examined through a numerical simulation study on a 2-bay 10-story structure and an experimental study on a 2-story structure. It has been found that the joint damages can be reasonably estimated even for the case where the measured modal vectors are limited to a localized substructure and the data are severely corrupted with noise.

**Key words** : joint damage assessment, connection fixity factor, neural networks, substructural identification, noise injection learning, data perturbation scheme

## 1. 서 론

구조물의 손상평가를 위하여 부재단위의 손

상모델(element-level damage model)이 주로 이용되어져 왔으나, 이러한 손상모델을 이용하여 구조물에서의 취약부인 보-기둥 접합부의 손상을 평가하는 경우, 손상위치는 탐색할 수 있더라도, 손상정도를 정량적으로 평가하는 데에는 부적절하다. 따라서, 접합부 손상정도가

\* 정회원 · 한국과학기술원 토목공학과 교수

\*\* 한국과학기술원 토목공학과 박사과정

\*\*\* 동양대학교 토목공학과 전임강사

본 논문에 대한 토의를 12월 31일까지 학회로 보내 주시면 그 결과를 게재하겠습니다.

지 정량적으로 평가할 수 있는 손상모델의 개발과 적절한 손상평가기법의 개발이 필요하다고 할 수 있다. 본 연구에서는 이를 위하여 반강접합부(semi-rigid connection)를 갖는 보요소를 도입하여 구조물을 모형화하고, 이를 확장시켜 접합부 손상모델을 제안하였으며, 제안된 손상모델을 이용하여 신경망기법으로부터 접합부 손상을 평가하고자 하였다.

보-기둥 접합부를 접합부의 회전강성을 갖는 스프링요소를 사용하여 모형화하였으며, 접합부의 고정도계수를 사용하여 회전강성의 크기를 0~1의 값으로 정규화하였다. 그리고, 접합부의 손상도를 손상 전, 후의 고정도계수의 감소비율로 정의하였다. 기존의 연구(윤정방 등<sup>(1)</sup>)에서는 접합부 강성의 감소비율을 손상도로 정의하였는데, 참고문헌 [1]에서 제안된 손상모델과 본 연구에서 제안한 손상모델을 비교함으로써 본 연구에서 제안한 손상모델의 타당성을 입증하였다.

역섭동법, 민감도법, 최소자승법 등의 구조계 추정기법은 복잡한 수식화 과정을 필요로 하거나, 혹은 계측오차의 존재와 계측자료의 부족 등으로 인한 약조건(ill-condition)이 발생할 수 있다. 그러나, 신경망기법의 경우 미리 작성된 모드특성치-접합부 손상도의 관계를 이용하여 신경망을 구성한 후, 손상평가를 수행할 때는 단순한 행렬연산을 수행하기 때문에 약조건이 완화되며, 또한 노이즈첨가학습을 사용함으로써 계측오차로 인한 약조건을 상당히 해결할 수 있는 장점이 있어 구조손상평가를 위한 대안으로 제시되고 있다. Wu 등<sup>(2)</sup>은 3층 프레임 구조물의 손상위치와 정도를 평가하기 위하여 다층퍼셉트론즈 신경망기법을 적용하였으며, Szewczyk와 Hajela<sup>(3)</sup>는 정적변위로부터 구조강성을 추정하기 위하여 counterpropagation 신경망기법을 사용하였다. Yun과 Bahng<sup>(4)</sup>은 다층퍼셉트론즈 신경망에 부분구조추정법의 개념을 도입하여 추정결과를 향상시켰다. 본 연구에서는 계측오차의 영향을 줄이기 위하여 노이즈첨가학습(Matsuoka<sup>(5)</sup>, Hölmstrom<sup>(6)</sup>)

을 사용하였으며, 실제 계측된 자료를 이용한 추정에서의 신뢰성을 평가하기 위하여 자료교란법(Shin<sup>(7)</sup>, Hjelmstad and Shin<sup>(8)</sup>)을 도입하였다. 대형구조물에서의 일부 부재에 대한 손상평가를 위하여 부분구조추정법의 개념을 도입하였다.

## 2. 접합부 손상모델

### 2.1 반강접합부 및 접합부 손상도의 모형화

구조물의 접합부는 일반적으로 강접합(rigid connection) 또는 핀접합(pin connection)으로 가정되어 해석 또는 설계되지만, 실제 접합부의 거동은 이러한 양극단의 사이, 즉 반강접합(semi-rigid connection)의 거동을 한다. 이러한 반강접합부의 거동은 접합부의 회전강성을 갖는 스프링요소를 보의 양쪽에 배치하여 표현할 수 있으며, 접합부의 손상은 스프링요소에서의 회전강성의 감소로 나타낼 수 있다.

반강접합부를 고려한 보요소를 그림 1과 같이 나타낼 수 있다. 스프링요소의 회전강성( $k_r$ )은 작용모멘트( $M_1$ )와 스프링의 회전변위량( $\phi_1$ )으로 나타낼 수 있으며, 이때,  $\theta_1^*$ 은 보의 변형축(deformed axis)에 대한 스프링의 외측 회전변위량이고,  $\bar{\theta}_1$ 는 보의 변형축에 대한 내측 회전변위량이다.




그림 1 반강접합부를 고려한 보요소

반강접합부를 고려한 보요소의 강성행렬은 요소자유도  $\{u\} = \langle v_1, \theta_1, v_2, \theta_2 \rangle^T$ 에 대하여 식 (1)과 같이 구할 수 있다.<sup>(1)</sup>



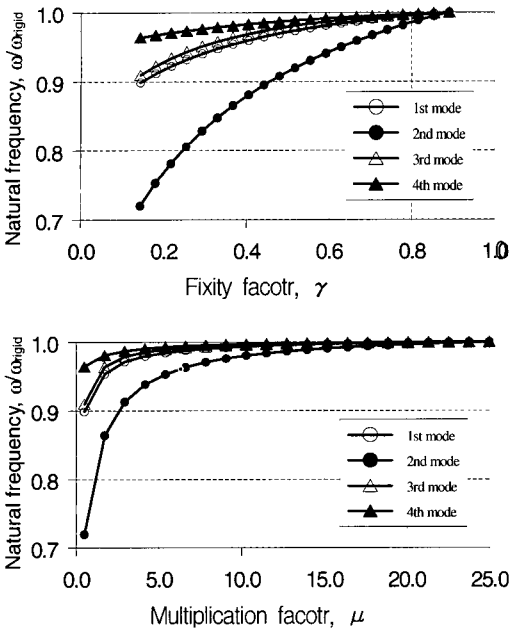


그림 3 고유주파수와 고정도계수 및 강성계수의 비교

### 3. 신경망기법에 의한 접합부의 손상평가

#### 3.1 다층퍼셉트론즈 신경망기법

본 연구에서는 구조물의 접합부 손상도를 평가하기 위하여 다층퍼셉트론즈 신경망을 사용하였다. 다층퍼셉트론즈 신경망은 그림 4와 같이 하나의 입력층, 여러 개의 은닉층, 그리고 하나의 출력층으로 구성되어 있다. 입력층을 통하여 구조물의 모드특성치가 입력되고, 출력층에서는 구조물의 접합부 손상도가 출력되는 구조로 되어있다. 주어진 모드특성치, 즉 입력값에 대하여 원하는 접합부 손상도, 즉 출력값이 나오도록 신경망을 구성하는 과정을 훈련과정이라고 하며, 본 연구에서는 이를 위하여 역전파학습 알고리즘(back-propagation learning algorithm)을 사용하였다.

#### 3.2 손상평가성능의 개선

신경망의 손상평가성능을 개선하기 위하여 부분구조추정법, 노이즈첨가학습, 자료교란법 등이 사용되었다. 부재의 수가 많은 대형구조물

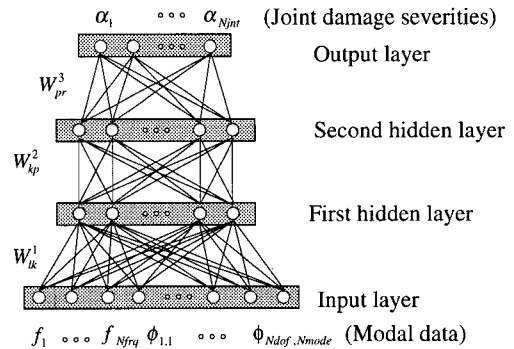


그림 4 다층퍼셉트론즈 신경망의 구조

에 신경망기법을 적용하기 위하여 부분구조추정법을 도입하였다. 이러한 부분구조추정법에서는 사전에 육안검사나 다른 평가기법에 의하여 손상의 가능성이 큰 부분, 즉 관심 영역을 내부부분구조로 분할하여, 분할된 내부부분구조에 대한 손상을 평가하는 기법으로, 만약 사전정보가 전혀 없다면, 전체 구조물을 부분으로 나누어서 손상을 평가할 수 있다.(Yun and Bahng<sup>(4)</sup>)

계측자료에 포함된 계측오차로 인한 악조건을 완화할 수 있는 방안으로 노이즈첨가학습을 적용하였다. 이는 훈련과정에서 입력패턴에 무작위의 노이즈를 첨가하여 학습시키는 것으로, 이때 첨가되는 노이즈의 수준은 다음과 같이 입력패턴을 구성하는 요소의 특성을 고려하여 결정할 수 있다.

$$\tilde{f}_i = f_i(1 + v_i^f), \quad \tilde{\phi}_{ij} = \phi_{ij}(1 + v_{ij}^{\phi}) \quad (5)$$

여기서,  $f_i$ 와  $\tilde{f}_i$ 는 각각 정확한 고유주파수와 노이즈를 첨가한 고유주파수이며,  $\phi_{ij}$ 와  $\tilde{\phi}_{ij}$ 는 각각 정확한 모드형상과 노이즈를 첨가한 모드형상이다.  $v_i^f$ 와  $v_{ij}^{\phi}$ 는 각각 고유주파수와 모드형상에 대한 Gaussian random noise로,  $v_i^f$ 에 대한 RMS(root mean square)값을  $v_{ij}^{\phi}$ 에 대한 RMS값보다 작게 결정하였다.

실제 계측자료를 사용하여 접합부 손상평가를

수행하는 경우, 결과의 신뢰성을 평가할 수 있을 만큼의 계측자료 세트를 구하기 어렵다. 이러한 문제를 해결하기 위하여 식 (6)과 같이 계측자료에 임의의 교란을 주어 많은 수의 계측자료 세트를 작성하고, 이러한 많은 세트에 대하여 손상을 평가하여, 그 결과를 통계처리 함으로써 신뢰성을 평가할 수 있게 된다. 이러한 과정을 자료교란법(data perturbation scheme)이라고 한다.

$$f_j^* = \hat{f}_j(1 + \zeta_j^f), \quad \phi_{ij}^* = \hat{\phi}_{ij}(1 + \zeta_{ij}^{\phi}) \quad (6)$$

여기서,  $\hat{f}_j$ 와  $\hat{\phi}_{ij}$ 는 각각 계측된 고유주파수와 교란된 고유주파수이며,  $\zeta_j^f$ 와  $\zeta_{ij}^{\phi}$ 는 각각 계측된 모드형상과 교란된 모드형상이다.  $\zeta_j^f$ 와  $\zeta_{ij}^{\phi}$ 는 각각 고유주파수와 모드형상에 대한 교란정도를 나타내는 값이다.

### 3.3 추정결과의 평가

손상평가성능을 비교하기 위하여 MSE(mean sizing error), DME(damage missing error), FAE(false alarm error)를 기준으로 사용하였다.(Kim and Stubbs<sup>(10)</sup>) MSE는 식 (7)과 같이 추정된 손상도와 실제 손상도의 차이에 대한 평균값이며, DME는 식 (8)과 같이 실제 손상 접합부를 탐색하지 못하는 정도를 나타내는 평균값이며, FAE 값은 식 (9)와 같이 예측한 손상부재가 실제로 건전한 경우가 어느 정도인지를 나타내는 값이다.

$$MSE = \frac{1}{NE} \sum_{i=1}^{NE} |\alpha_{est, i} - \alpha_{exact, i}| \quad (7)$$

$$DME = \frac{1}{NT} \sum_{i=1}^N \epsilon_i^I; 0 \leq DME \leq 1 \quad (8)$$

$$FAE = \frac{1}{NF} \sum_{i=1}^N \epsilon_i^{II}; 0 \leq FAE \leq 1 \quad (9)$$

식 (7)에서  $\alpha_{est, i}$ 와  $\alpha_{exact, i}$ 는 각각  $i$ 번째 접합부에 대하여 추정된 손상도와 실제 손상도를 의미하며,  $NE$ 는 추정하고 있는 접합부의 수이다. 식 (8)

에서  $\epsilon_i^I$ 는  $i$ 번째 손상 접합부를 탐색하는 데 실패할 경우  $\epsilon_i^I = 1$ 을 갖고, 탐색하는 데 성공한 경우  $\epsilon_i^I = 0$ 를 가진다.  $NT$ 는 전체 손상 접합부의 수이다. 한편 FAE값을 구하는 식 (9)에서  $\epsilon_i^{II}$ 는  $i$ 번째 예측 손상 접합부가 실제 건전한 경우  $\epsilon_i^{II} = 1$ 이고, 실제 손상 접합부인 경우  $\epsilon_i^{II} = 0$ 이 된다.  $NF$ 는 예측한 총 접합부의 수이다.

## 4. 수치 예제해석

### 4.1 예제 구조물

그림 5와 같은 프레임 구조물에 대한 수치 예제해석을 수행하였다. 보와 기둥의 부재로는 각각 W24×55와 W14×145의 강재를 가정하였고, 강재의 밀도와 탄성계수는 각각 7850kg/m<sup>3</sup> 210GPa로 가정하였다. 건전상태에서의 접합부 강성은 3.0×10<sup>8</sup>N·m/rad로 가정하였으며, 손상평가는 그림 5에서와 같이 6개의 보부재와 기둥부재로 이루어진 내부부분구조로 제한하였다. 그림 6과 같이 내부부분구조의 15개의 자유도(Ⅰ, Ⅵ, Ⅲ번 지점의 경우 수평변위, 나머지 지점에서는 수직변위)에 대한 모드형상을 구할 수 있다고 가정하였다. 그림 7은 첫 번째 모드와 두 번째 모드에 대한 모드형상을 보여




그림 5 수치 예제해석을 위한 대상 구조물

주고 있다. 접합부에서의 거동은 두 번째 모드에서 잘 나타나고 있음을 알 수 있다.




그림 6 계측위치 및 접합부 정의




그림 7 저차 2개 모드의 모드형상

#### 4.2 신경망 구조

입력층은 저차 4개 모드의 고유주파수와 보의 거동을 잘 나타나고 있는 두 번째 모드에 대한 15개 모드형상자료로 총 19개의 입력뉴런으로 구성하였다. 두 개의 은닉층을 사용하였으며, 각각의 은닉층은 15개의 뉴런으로 구성하였다. 출력층은 12개 접합부의 손상도로 구성되어 있다. 1500개의 훈련패턴을 Latin hypercube sampling 기법을 이용하여 그림 8과 같은 확률분포를 갖도록 하였다.(Press et al<sup>(11)</sup>, 방은영<sup>(12)</sup>)




그림 8 Latin hypercube sampling을 위한 확률밀도함수

#### 4.3 접합부 손상추정

500개의 시험패턴으로부터 신경망의 손상평가 성능을 검토하였다. 계측오차의 수준에 따른 추정결과를 비교하기 위하여 표 1과 같이 5단계의 계측오차를 고려하였으며, 노이즈첨가학습의 성능을 비교하기 위하여 표 2와 같이 3단계의 노이즈의 수준을 고려하였다. 그림 9는 시험패턴에 대한 MSE값을 보여주는 것으로 중간 수준의 계측오차(noise level III)를 가진 계측자료에 대하여, 노이즈첨가학습(NIL-B, NIL-C)을 수행할 때 0.06정도의 MSE값을 가지는 것을 보여주고 있다. 이것은 0.06보다 큰 손상의 경우 신경망기법을 사용하여 추정이 가능함을 의미하며, 또한 0.06보다 작은 손상으로 추정된 경우, 신뢰성이 떨어진다고 할 수 있다.

손상 접합부에 대한 탐색능력을 DME 값과 FAE 값을 이용하여 검토하였다.(그림 10, 그림 11) 앞서 살펴보았듯이 0.06보다 작게 추정된 결과에 대한 신뢰도가 떨어지기 때문에 적절한 기준을 두어, 손상부재와 건전부재를 나눌 수 있도록 하여야 한다. 일반적으로 이러한 기준값을 높게 설정하면, FAE값은 줄일 수 있지만, DME값은 커지게 되고, 이와 반대로 기준값을 낮게 설정하면 DME값은 줄일 수 있지만, FAE값은 커지게 되어, 결론적으로 DME값의 중요도와 FAE값의 중요도를 고려하여 적절한 수준의 값을 설정하여야 한다. 본 연구에서는 노이즈첨가학습을 수행하는 경우의 MSE 값인 0.06보다 큰 값인 0.1을 기준값으로 설정하였는데, 기준값을 일관적으로 정하기 위해서는 추후 연구가 필요할 것으로 판단된다. 그림 10으로부터 노이즈첨가학습을 수행한 경우 DME 값을 상당히 줄일 수 있음을 알 수 있었다. 계측오차가 심하게 포함되어 있는 경우에 있어서도, 손상도가 0.2보다 큰 접합부의 경우  $DME \leq 0.1$ 의 결과를 얻을 수 있는데, 이는 0.2보다 큰 손상 접합부의 90% 이상을 정확하게 탐색할 수 있음을 의미한다. FAE값의 경우도 DME와 마찬가지로 시험패턴에 포함된 계측오차의 수준이

표 1 시험패턴에서 고려한 계측오차 (% in RMS level)

Mode No.	I		II		III		IV		V	
	$f_j$	$\phi_{ij}$	$f_j$	$\phi_{ij}$	$f_j$	$\phi_{ij}$	$f_j$	$\phi_{ij}$	$f_j$	$\phi_{ij}$
1	0.0	-	0.2	-	0.3	-	0.5	-	1.0	-
2	0.0	0.0	0.3	5.0	0.5	10.0	1.0	15.0	1.5	20.0
3	0.0	-	0.5	-	1.0	-	1.5	-	2.0	-
4	0.0	-	1.0	-	1.5	-	2.0	-	3.0	-

표 2 노이즈첨가학습을 위한 노이즈의 수준 (% in RMS level)

NIL-A		NIL-B		NIL-C	
$f_j$	$\phi_{ij}$	$f_j$	$\phi_{ij}$	$f_j$	$\phi_{ij}$
0.0	0.0	1.0	10.0	2.0	20.0

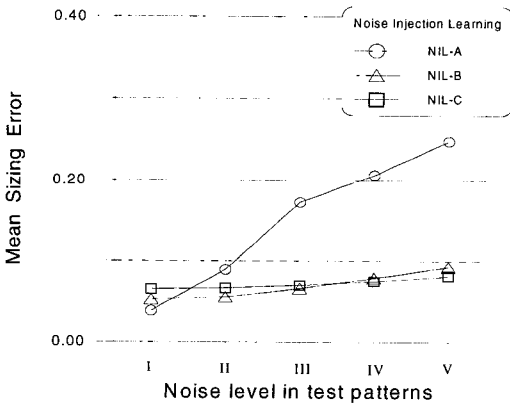


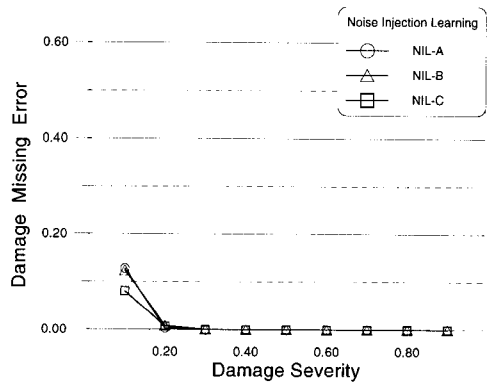
그림 9 계측오차에 따른 MSE값의 비교

높아질수록 FAE값도 증가하지만 노이즈첨가학습을 수행함으로써 그 값을 상당히 줄일 수 있음을 알 수 있다. 한편 접합부의 손상도가 0.3보다 큰 것으로 추정되었을 경우, FAE가 거의 0에 가까움을 알 수 있는데, 이는 손상도가 0.3보다 큰 것으로 예측한 부재는 거의 모두 실제 손상 접합부임을 의미한다.

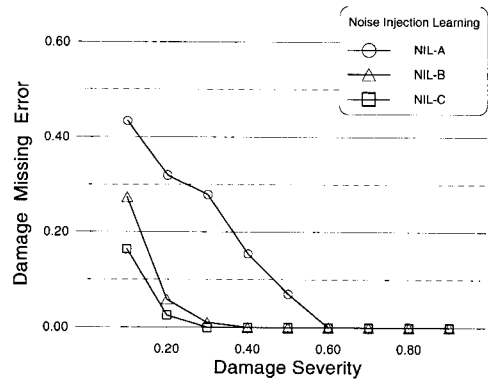
## 5 실험 예제해석

### 5.1 대상 구조물


그림 12에서와 같은 2층 프레임 구조물을 대상으로 실험 예제해석을 수행하였다. 보와 기둥은 강재를 사용하여 제작하였으며, 각각의 I값은  $5.48 \times 10^{-9} \text{m}^4$ ,  $6.62 \times 10^{-10} \text{m}^4$ 과 같다. 인위적



(a) Case I without Noise

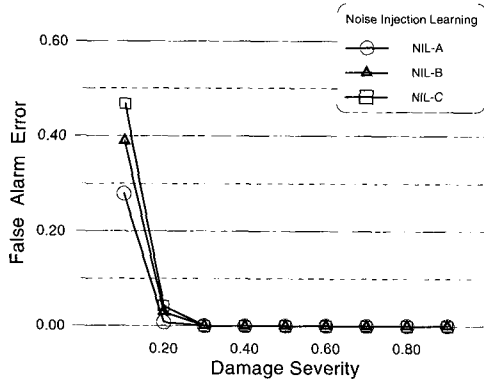


(b) Case III with moderate noise

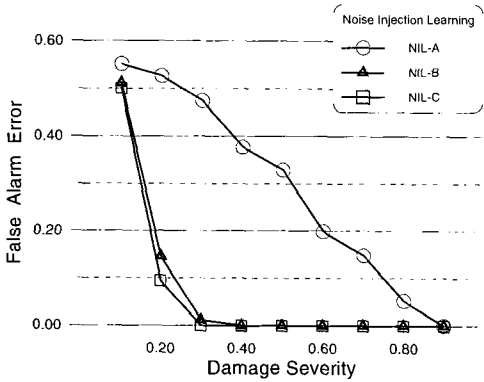


(c) Case V with severe noise


그림 10 계측오차에 따른 DME 값의 비교



(a) Case I without noise



(b) Case III with moderate noise



(c) Case V with severe noise

그림 11 계측오차에 따른 FAE 값의 비교

인 손상을 그림 13과 같이 볼트 탈락의 경우, 접합격자 탈락의 경우, 그리고 접합부의 두께 감소로 표현하였다. 저차 4개 모드의 고유주파수와 8개 계측지점에서의 병진자유도에 대한 모드형상을 충격시험을 통하여 구하였으며, 그 결과를 이용하여 접합부의 고정도 계수를 추정하였다.




그림 12 실험 대상 구조물




그림 13 인위적인 손상

## 5.2 자료교란법과 신경망기법의 적용

4층 신경망구조를 사용하였으며, 입력층은 저차 4개 모드의 고유주파수와 4개 주파수의 조합(e.g.  $f_1, f_2, f_3, \dots, f_3, f_4$ ), 그리고 두 번째와 네 번째 모드에 대한 8개 병진자유도의 모드벡터요소로 총 26개의 입력뉴런으로 구성하였다. 첫 번째 모드와 세 번째 모드의 경우 보의 거동이 크게 나타나지 않으므로 입력패턴에서 제외하였다. 출력층은 4개 접합부의 고정도계수에 해당하는 4개의 출력뉴런으로 구성하였다. 1000개의 훈련패턴을 Latin hypercube sampling 기법을 사용하여 작성하였으며, 이 때 가정된 확률분포함수는 균일분포함수를 사용하였다.



표 2에서 사용된 노이즈 수준을 사용하여 노이즈첨가학습을 수행하였으며, 자료교란법으로부터 100개의 인위적인 입력패턴을 작성하여, 평가결과의 평균과 표준편차를 구하여 신뢰성을 정성적으로 분석하였다. 이때 교란 정도인  $\zeta_1$ 과  $\zeta_2$ 의 RMS값은 실험결과에 대한 분석결과를 바탕으로 각각 0.01과 0.10으로 결정하였다.

### 5.3 접합부 손상추정

건전상태 및 세 가지 손상상태에 대하여 고 정도계수 및 접합부 손상도추정 결과를 표 3에 정리하였다. 각각의 결과는 100개의 교란된 입력패턴에 대한 추정결과의 평균 및 표준편차를 나타낸 값이다. 일층 보의 양쪽 접합부가 탈락된 손상경우 I에 대하여, 노이즈첨가학습을 수행한 경우 접합부 손상도는 0.43-0.49로 추정되었다. 그러나, 노이즈첨가학습을 하지 않은 경우, 양쪽 추정 손상도가 0.63과 0.25로 상당히 많은 차이를 보이고 있고, 표준편차 역시 다른 경우와 비교하여 크다는 점을 알 수 있는데, 이는 추정결과의 신뢰성이 낮음을 의미한다. 3번 접합부에서의 접합부 탈락과 2번 접합부에서의 볼트가 탈락한 손상경우 II에 대

하여, 볼트 탈락의 경우 손상도는 0.15로 추정되었다(노이즈첨가학습을 수행한 경우). 1번 접합부의 두께가 감소한 경우에 해당하는 손상경우 되었으며, 이는 상당히 심각한 수준의 손상으로 간주할 수 있다. 추정결과를 이용하여 재해석을 수행하였으며, 그 결과를 표 4와 그림 14에 제시하였다. 고유주파수의 경우 오차의 범위가 0%~3% 수준으로 만족할 만하며, 모드형상 또한 계측값과 잘 일치함을 알 수 있다.

### 6. 결 론

신경망기법을 이용한 프레임 구조물의 접합부 손상평가기법을 제안하였다. 접합부 손상을 평가할 수 있는 접합부 손상모델을 제시하였으며, 이러한 접합부 손상모델을 이용하여 접합부 손상을 평가할 수 있는 기법으로 신경망기법을 제안하였다.

접합부 손상모델의 개발과 관련하여, 반강 접합부를 고려한 보요소의 개념을 도입하였으며, 접합부의 손상은 등가의 스프링요소에서 회전강성의 감소로 표현하였다. 회전강성은 편접합 상태에서 0에 가까운 값을 가지고,

표 3 추정된 접합부 손상도

손상경우		접합부 번호		1	2	3	4
		$\gamma_{0j}$	$\alpha_{0j}$				
건전		$\gamma_{0j}$		0.70	0.63	1.00	0.94
			$\alpha_{0j}$	0.00	0.00	0.00	0.00
I	손상형태			-	-	접합부탈락	접합부탈락
	$\alpha_i$	NIL-A		0.00(0.05)	0.00(0.20)	0.63(0.32)	0.25(0.32)
		NIL-B		0.00(0.02)	0.00(0.02)	0.43(0.03)	0.49(0.04)
		NIL-C		0.00(0.01)	0.00(0.01)	0.48(0.06)	0.45(0.04)
II	손상형태			-	볼트탈락	접합부탈락	-
	$\alpha_i$	NIL-A		0.14(0.18)	0.21(0.33)	0.33(0.22)	0.08(0.02)
		NIL-B		0.00(0.03)	0.16(0.03)	0.39(0.07)	0.05(0.05)
		NIL-C		0.00(0.02)	0.15(0.01)	0.34(0.06)	0.06(0.04)
III	손상형태			접합부두께감소	-	-	-
	$\alpha_i$	NIL-A		0.98(0.24)	0.19(0.32)	0.05(0.11)	0.05(0.17)
		NIL-B		0.88(0.09)	0.05(0.06)	0.07(0.05)	0.09(0.04)
		NIL-C		0.86(0.09)	0.06(0.04)	0.06(0.03)	0.06(0.03)

표 4 고유주파수의 예측값과 재해석값의 비교

Mode No.		1			2			3			4		
Cases		$f_{mea}$ (Hz)	$f_{recal}$ (Hz)	Error (%)	$f_{mea}$ (Hz)	$f_{recal}$ (Hz)	Error (%)	$f_{mea}$ (Hz)	$f_{recal}$ (Hz)	Error (%)	$f_{mea}$ (Hz)	$f_{recal}$ (Hz)	Error (%)
Intact		4.59	4.58	0.04	18.96	18.73	1.21	22.26	21.57	3.09	25.83	25.22	2.74
I	NIL-A	4.22	4.25	0.71	18.83	18.91	0.42	22.27	21.37	4.04	17.32	17.59	1.55
	NIL-B		4.17	1.18		18.52	1.64		21.41	3.86		16.88	2.54
	NIL-C		4.22	0.00		18.74	0.48		21.57	3.10		17.00	1.85
II	NIL-A	4.34	4.34	0.00	18.81	17.11	9.04	22.30	21.61	3.09	20.83	21.04	1.01
	NIL-B		4.28	1.38		18.24	3.03		21.77	2.37		20.41	2.01
	NIL-C		4.41	1.61		18.29	2.76		21.26	4.66		21.52	3.31
III	NIL-A	4.24	4.17	1.65	14.71	14.50	1.43	21.85	20.87	4.48	24.31	24.17	0.57
	NIL-B		4.26	0.47		15.25	3.67		21.43	1.92		23.50	3.30
	NIL-C		4.28	0.94		15.36	4.41		21.51	1.55		23.92	1.60

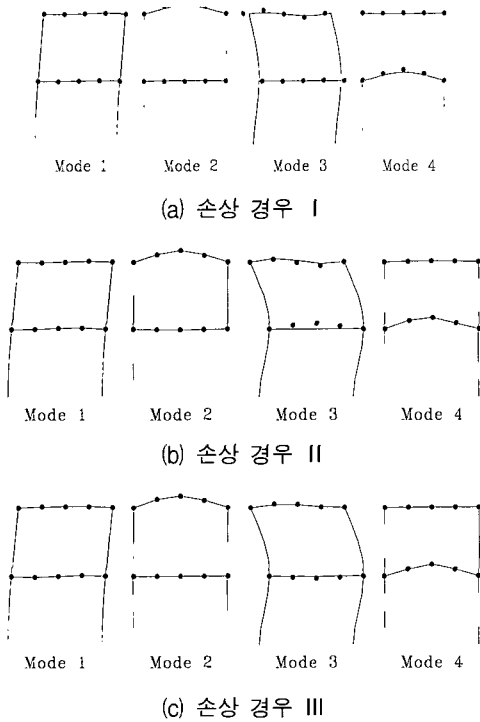


그림 14 모드형상의 예측값과 재해석값의 비교

강접합 상태인 경우 무한대에 가까운 값을 가질 수 있기 때문에 역해석이나 구조물의 손상을 정의하는데 적절하지 못하여, 본 연구에서는 고정도계수를 사용하여 접합부의 손상도를 정의하였다. 제안된 접합부 손상모델의 타당성을 간단한 구조물을 대상으로 검토하였다.

접합부 손상평가기법으로 다층퍼셉트론즈 신경망기법을 적용하였으며, 평가성능을 향상시키기 위하여 부분구조추정법, 노이즈첨가학습, 자료교란법 등의 기법을 적용시켰다. 제안된 손상평가기법의 적용성을 10층 프레임 구조물에 대하여 수치 예제해석과 2층 프레임 구조물에 대하여 실험 예제해석을 수행함으로써 검토하였다. 수치 예제해석에서는 부분구조추정법의 효용성을 검증할 수 있었으며, 또한 MSE, DME, FAE 등의 값을 사용하여 전체적인 성능을 평가할 수 있었다. 수치 예제해석의 결과로 신경망기법의 경우, 예측지점이 구조물의 일부영역으로 제한되어 있고, 예측오차가 상당히 많이 포함되어 있는 경우에도 상당히 신뢰성 있는 결과를 얻을 수 있음을 알 수 있었다. 신경망기법의 경우, 훈련과정을 통하여 손상을 적절하게 평가할 수 있는 신경망을 구성하게 되는데, 이러한 훈련과정에는 비교적 많은 계산시간이 소모되지만, 훈련과정이 끝난 후 임의의 입력자료에 대한 결과는 신속하게 얻을 수 있다. 실험 예제해석의 경우 자료교란법을 적용함으로써 예측된 소수의 자료에 대한 통계적인 결론을 얻을 수 있도록 하였는데, 이러한 자료교란법을 적용하는 경우 신경망기법의 이러한 특징을 이용할 수 있어 더욱 효과적임을 알 수 있었다.

## 감사의 글

본 연구는 서울대학교 지진공학연구센터를 통한 한국과학재단 우수연구센터 지원금에 의한 것으로, 연구비를 지원해 준 한국과학재단에 감사드립니다.

## 참고 문헌

1. 윤정방, 방은영, 이진학, "신경망을 이용한 구조물 접합부의 손상도 추정", 한국지진공학회 논문집, 1998.
2. Wu, X., Ghaboussi, J., and Garret, J. H. Jr., "Use of neural networks in detection of structural damage," *Computers and Structures*, 42(4), 1992, pp. 649-659.
3. Szweczyk, Z. P. and Hajela, P., "Damage detection in structures based on feature-sensitive neural networks," *Journal of Computing in Civil Engineering*, ASCE, 8(2), 1994, pp. 163-178.
4. Yun, C. B. and Bahng, E. Y., "Substructural identification of structures using neural networks," *Proceedings of NSF Workshop on Structural Reliability in Bridge Engineering*, (Boulder, 1996), 1996, pp. 322-327.
5. Matsuoka, K., "Noise injection into inputs in back-propagation learning," *IEEE Transaction of Systems, Man, and Cybernetics*, 22(3), 1992, pp. 436-440.
6. Hölmstrom, L. and Koistinen, P., "Using additive noise in back-propagation training," *IEEE Transaction of Neural Networks*, 3(1), 1992, pp. 24-38.
7. Shin, S. B., "Damage Detection and Assessment of Structural Systems from Measured Response," Ph.D. Dissertation, University of Illinois at Urbana-Champaign, Illinois, 1994.
8. Hjelmstad, K. D. and Shin, S., "Damage detection and assessment of structures from static response," *Journal of Engineering Mechanics*, ASCE 123(6), 1997, pp. 568-576.
9. Eurocode 3, "Design of steel structures," *Draft for Development*, 1993-1-1, 1992.
10. Kim, J. T. and Stubb, N., "Model uncertainty impact and damage-detection accuracy in plate girder," *Journal of Structural Engineering*, ASCE, 121(10), 1996, pp. 1409-1417.
11. Press, W., Teukolsky, S. A., Vetterling, W. T., and Flannery, B. P., *Numerical recipes in C-the art of scientific computing*, Cambridge University Press, New York, 1992.
12. 방은영, "신경망 기법을 사용한 구조계의 손상도 추정법", 박사학위논문, 한국과학기술원, 1997.