

확률신경망에 기초한 교량구조물의 손상평가

Probabilistic Neural Network-Based Damage Assessment for Bridge Structures

조 호 남* 강 경 구** 이 성 칠** 허 춘 근***

Cho, Hyo-Nam Kang, Kyoung-Koo Lee, Sung-Chil Hur, Choon-Kun

Abstract

This paper presents an efficient algorithm for the estimation of damage location and severity in structure using Probabilistic Neural Network (PNN). Artificial neural network has been being used for damage assessment by many researchers, but there are still some barriers that must be overcome to improve its accuracy and efficiency. The major problems with the conventional neural network are the necessity of many training data for neural network learning and ambiguity in the relation of neural network architecture with convergence of solution. In this paper, PNN is used as a pattern classifier to overcome those problems in the conventional neural network. The basic idea of damage assessment algorithm proposed in this paper is that modal characteristics from a damaged structure are compared with the training patterns which represent the damage in specific element to determine how close it is to training patterns in terms of the probability from PNN. The training pattern that gives a maximum probability implies that the element used in producing the training pattern is considered as a damaged one. The proposed damage assessment algorithm using PNN is applied to a 2-span continuous beam model structure to verify the algorithm.

keywords : Probabilistic Neural Network, Damage Assessment, Mode Shape

* 정회원, 한양대학교 토목·환경공학과 교수

** 학생회원, 한양대학교 토목·환경공학과 박사수료

*** 학생회원, 한양대학교 토목·환경공학과 석사과정

E-mail : twin7@chol.com 031-406-5660

• 본 논문에 대한 토의를 2002년 12월 31일까지 학회로 보내 주시면 2003년 4월호에 토론결과를 게재하겠습니다.

1. 서 론

구조물의 손상평가는 주로 손상 전·후의 구조물 동적응답의 변화를 이용한다. 이러한 손상평가 기법은 손상평가에 이용되는 자료의 형태에 따라 크게 시간영역 방법과 주파수 영역 방법으로 구별된다. 그러나, 이러한 기법들은 구조물의 손상평가를 위해 많은 추가적인 해석과정을 필요로 하거나, 최적 알고리즘을 통한 반복수행을 해야 하는 등 많은 어려움이 따른다.

인공신경망(이하 신경망)⁽¹¹⁾⁽¹²⁾은 뇌신경의 학습과 기억방식을 컴퓨터를 통해 모사한 모형으로, 이를 이용한 구조물의 손상평가에 관한 많은 연구가 진행되었다. 대표적으로 Wu et al.⁽⁸⁾은 3층 구조물의 손상을 평가하기 위해 하나의 은닉층을 갖는 BPNN (Backpropagation Neural Network)을 사용하였으며, 신경망을 훈련시키기 위해 입력자료로 푸리에 스펙트럼(Fourier Spectra)의 진폭을 사용하였다. 신경망의 구조는 시행 착오법을 통하여 200개의 입력노드, 3개의 출력노드, 그리고 10개의 노드를 가진 1개의 은닉층으로 구성하였다. 훈련자료의 생성을 위해 손상위치와 손상정도를 달리한 43가지 손상 경우에 대해 구조물의 맨 윗 층에서 얻은 가속도 자료를 이용하였다. Szweczyk와 Hajela⁽⁴⁾는 9개의 휨요소를 가진 프레임 구조물에 대해 신경망을 이용한 손상평가를 하였는데, 신경망을 훈련시키기 위해 3600가지의 손상 경우에 대한 구조물의 정적응답을 이용하였다. Pandey와 Barai⁽⁵⁾는 21개의 부재를 가진 트러스 구조물에 대해 40가지의 손상유형에 따른 훈련자료를 사용하여 신경망을 훈련시켰다. Bahng⁽⁶⁾은 55개의 부재를 가진 트러스 구조물의 손상을 평가하기 위해 BPNN을 사용하였는데, 신경망 훈련을 위하여 1200가지의 손상유형에 따른 훈련자료를 이용하였다.

신경망을 이용한 구조물의 손상평가 기법은 비록 시간영역과 주파수영역에서의 손상평가 기법의 복잡함을 해결하는 대안으로 생각될 수 있으나, 신경망 학습을 위해 많은 훈련자료가 필요하며, 이는 훈련자료를 생성하기 위한 구조물의 많은 수의 유한요소 해석을 의미한다. 또한 신경망을 구성하는 층의 수, 노드의 수에 따라 수렴성이 보장되지 않는 경우도 있

으며, 층의 수와 노드 수에 따른 신경망의 학습 결과 사이의 상관성을 파악하기가 어려우므로 기존의 많은 연구들에서 신경망의 구조를 결정하기 위해 시행착오적으로 은닉층의 수와 노드 수를 결정해야 하는 제약이 가진다.

본 논문에서는 주로 유형인식(Pattern Recognition)에 활용되어 온 신경망의 일종인 확률신경망(PNN: Probability Neural Network)⁽⁷⁾을 사용함으로써, 기존의 신경망을 이용한 구조물 손상평가와는 다른 접근방식으로 구조물의 손상을 추정하였다. 확률신경망을 사용함으로써 기존의 신경망 구조를 결정하는데 소요되는 시간과, 신경망 학습을 위해 필요한 훈련자료를 생성하는데 소요되는 시간과 노력을 경감하였다. 본 논문에서 제안한 손상평가 기법을 2경간 교량구조 모델에 적용함으로써 검증하였다.

2. 확률신경망

확률신경망은 확률밀도함수(Probability Density Function)에 대한 비모수 추정과 Bayes Strategy를 결합하여 베이지안 유형분류(Bayesian Classification)를 수행한다.⁽⁷⁾

$\theta_1, \theta_2, \dots, \theta_q, \dots, \theta_s$ 의 여러 범주에 대한 다중범주분류문제의 경우, 측정된 p -차원의 벡터 $X = \{x_1 x_2 \dots x_i \dots x_p\}^T$ 를 기초로 하여 θ_q 로 유형분류 되기 위한 Bayes결정법칙은 아래 식 (1)과 같이 기술된다.

$$d(X) \in \theta_q \text{ if } h_q l_{qf_q}(X) > h_k l_{kf_k} \text{ for all } k \neq q \quad (1)$$

여기서

$d(X)$: 시험벡터 X 에 대한 범주결정,

h_q, h_k : 범주 θ_q 와 θ_k 각각에 대한 사전확률,

l_q : $\theta \in \theta_q$ 일 때 $d(X) \neq \theta_q$ 라고 분류한 경우 손실,

l_k : $\theta \in \theta_k$ 일 때 $d(X) \neq \theta_k$ 로 분류한 경우 손실,

$f_q(X), f_k(X)$: 범주 θ_q 와 θ_k 각각에 대한 확률 밀도함수이다.

손상 추정 문제에 있어 기대되는 h (사전확률)와 l (손실)은 모든 범주에 대해 보통 같다고 가정하므로, 식(1)에 의한 분류를 행하는 경우 확률밀도함수를 알아야 하며 확률밀도함수는 주어진 정보가 훈련 유형뿐이므로 훈련유형에 기초하여 확률밀도함수를 추정해야만 한다. 범주의 확률밀도함수 추정은 다음 식(2)와 같은 Parzen windows 방법을 이용하여 추정할 수 있다.

$$f_q(X) = \frac{1}{n_q (2\pi)^{p/2} \sigma^p} \sum_{i=1}^{n_q} \exp \left[-\frac{(X - X_{qi})^T (X - X_{qi})}{2\sigma^2} \right] \quad (2)$$

- 여기서 X : 분류되어야 할 시험벡터,
- $f_q(X)$: X 점에서 범주 q 의 확률밀도함수,
- n_q : 범주 q 에 속한 훈련 벡터의 수,
- p : 훈련 벡터의 차원,
- X_{qi} : 범주 q 에서 i 번째 훈련벡터,
- σ : 평활화 변수(smoothing parameter)이다.

PNN은 Fig. 1과 같은 3개의 층으로 구성된다. PNN의 첫 번째 층(입력층)은 분류되어야 할 시험벡터를 단순히 받아 들이며 입력층의 노드수는 훈련벡터의 차원과 동일하다. 유형층의 각 뉴런에서는 시험 벡터 X 와 훈련유형별 가중치벡터 W_j 를 곱한다($z_j = X \cdot W_j$). 그리고 마지막 합계층으로 이동하기 전에 비선형 활성화 함수(activation function)에 의해 z_j 를 변환한다. 여기서 활성화 함수는 통상적인 BPNN의 시그모이드 활성화 함수를 이용하지 않고 $g(z_j) = \exp[(z_j - 1)/\sigma^2]$ 을 이용한다. 합계층의 각 뉴런은 유형층으로부터 각각의 범주별로 결과를 받게 된다. 따라서 범주 q 에 상응하는 합계층의 결과는 식(3)과 같다.

$$f_q(X) = \sum_{i=1}^{n_q} z_{qi} = \sum_{i=1}^{n_q} \exp [(X \cdot W_{qi} - 1)/\sigma^2] \quad (3)$$

식(3)은 가중치벡터 W_{qi} 를 훈련벡터 X_{qi} 로 선정하고 $X \cdot X = X_{qi} \cdot X_{qi} = 1$ 이 되도록 정규화하면 합계층의 결과인 식(3)은 식(2)와 같게 된다.

본 논문에서 사용한 PNN의 주된 이점은 학습 속도이다. 다른 신경망은 신경망의 학습을 위하여 여러 번




Fig. 1 PNN 구조

련자료에 의한 반복적인 학습과정을 통해 가중치들이 결정되지만, PNN의 가중치들은 반복적인 학습과정을 통해 훈련되지 않으며, 보통의 학습과정 중에 기억된다. 그러나 PNN은 모든 훈련유형을 기억해야하기 때문에 많은 기억 장소를 필요로 하며, 적절한 연산을 위해 어느 정도의 훈련유형을 필요로 한다.

3. PNN을 이용한 손상추정

3.1 손상평가 알고리즘

본 논문에서 사용한 손상추정 알고리즘은 먼저 1차 모드형상 정보를 이용하여 손상위치를 판별한 후, 구조물에서 얻은 고유진동수를 사용하여 손상정도를 추정한다. Fig. 2는 구조물의 손상추정 알고리즘 순서도이다. 손상추정 알고리즘은 크게 두 개의 PNN으로 구성되어 있다. 먼저 PNN(1)을 통하여 손상위치를 구하고, 이를 근거로 PNN(2)에 의하여 손상정도를 추정하게 된다. 구조물의 손상위치 평가단계에서는 PNN을 유형분류기로 활용하여 구조물의 손상을 평가하므로, 먼저 구조물의 각 요소의 손상을 대표할 수

있는 훈련유형을 결정해야한다. 요소 손상을 대표할 훈련유형은 각 요소에 임의의 손상을 도입한 후, 손상 전·후의 1차 모드형상 의 차이를 수치해석적으로 구한 다음 가장 큰 값에 대해 정규화 함으로써 얻는다.

입력유형은 실제 손상에 의한 구조물 1차 모드형상과 손상전의 1차 모드형상 의 차이를 정규화 함으로써 얻을 수 있다. 이렇게 구한 훈련유형과 입력유형을 PNN(1)에 입력하면 PNN(1)의 첫 번째 층에서는 입력유형과 각 훈련유형을 비교하여 입력유형과 훈련유형사이의 유사정도를 확률값으로 나타낸다. 두 번째 층에서는 첫 번째 층에서 나온 확률값 중 가장 큰 확률값을 가지는 훈련유형에 "1"을 부여하고 나머지 훈련유형에 대해서는 "0"을 부여함으로써 손상위치를 추정하게 된다.

손상위치가 결정되면 손상정도의 추정은 손상구조물에 대해 얻은 실제 고유진동수를 이용하여 손상정도 추정을 위한 새로운 PNN(2)를 사용하여 구할 수 있다. PNN(2)에서의 훈련유형(실체는 벡터)은 구조물의 한 요소에 대해 여러 손상정도에 따라 유한요소해석을 수행하여 구한 고유진동수로 구성되며, 실제 손상구조물로부터 얻은 고유진동수와 훈련유형을 PNN에 입력하여 손상위치 추정을 위한 PNN(1)과 유사한 과정을 통해 손상정도를 추정하게 된다.

3.2 PNN의 훈련유형

기존의 신경망을 이용한 손상평가 연구에서는 신경망을 학습시키기 위해 여러 손상경우에 대하여 구조물로부터 얻은 1차 모드형상 과 고유진동수등을 이용하여 훈련자료를 구성한다. 본 논문에서도 구조물의 손상에 따른 1차 모드형상 과 진동수를 이용하지만 기존의 신경망을 이용한 기법과는 달리 유형분류를 위하여 PNN을 사용하므로 구조물의 손상을 대표할 수 있는 훈련유형을 1차 모드형상 차이로부터 도출하여야 한다.

본 논문에서 수치예제로 사용한 2경간 연속보 구조물모형에 대한 훈련유형을 생성함으로써 훈련유형을 구하는 과정을 설명하고자 한다.

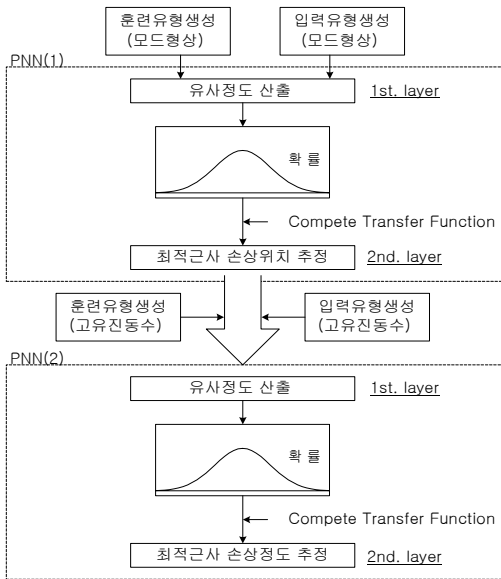


Fig. 2 손상평가 알고리즘

Fig. 3은 Fig. 9의 2번 요소에 30% 손상을 도입한 경우와 5번 요소에 30%손상을 도입한 경우 각각의 1차 모드형상에 대해 손상전·후 1차 모드형상 차이를 가장 큰 값에 대해 정규화한 그림이다.

Fig. 4에서 2번 요소에 손상이 존재하는 경우 손상 전·후에 대한 1차 모드형상의 차이는 3번 절점에서 가장 크게 나타난다. 2번 요소 손상시 2번 절점보다 3번 절점에서 1차 모드형상의 차이가 더 크게 되는데 이는 2번 절점에서 1차 모드형상의 진폭 자체가 작고 또 지점에 근접한 영향 때문인 것으로 사료된다.




Fig. 3 2번, 5번 요소 손상전·후 1차 모드형상 차이의 정규화 값




Fig. 4 2번 요소 손상에 대한 훈련유형

그리고 5번 요소에 손상이 존재할 때는 5번과 6번 절점에서 1차 모드형상의 차이가 가장 크게 되는데 이는 5번 요소위치가 경간의 중앙이므로 예상대로 5번 요소의 양쪽 절점에 거의 같은 영향을 미치기 때문이라고 판단된다. Fig. 3과 유사하게 수치해석을 통해 다른 요소에 대해서 살펴본 바 정모멘트 발생구간에서는 대체로 손상을 도입한 위치에서 정규화한 값이 크게 나타났으며, 두 번째 구간에서는 1차 모드형상의 차이가 미소하였다.

따라서 2번 요소와 같이 정모멘트 구간에 있는 요소의 손상을 대표할 수 있는 훈련유형은 Fig. 3의 2번 요소 손상시 1차 모드형상의 차이를 근사적으로 표현한 삼각형 모양(Fig. 4)을 이용하고, 5번 요소와 같이 경간 중앙에 위치한 요소에 대해서는 유형은 Fig. 3의 5번 요소 손상시 1차 모드형상의 차이를 근사적으로 표현한 사다리꼴 모양(Fig. 5)을 훈련유형으로 사용한다.

Fig. 7은 Fig. 6의 부모멘트 발생구간 중 9번, 10번 요소의 손상시 손상전·후의 1차 모드형상의 차이에 대한 정규화 값을 나타내는 그림이다.




Fig. 5 5번 요소 손상에 대한 훈련유형




Fig. 6 2경간 해석모형의 모멘트선도

Fig. 7에서 알 수 있듯이 부모멘트 구간에 위치하는 요소 손상시 1차 모드형상 차이의 정규화값은 해당 손상요소 위치에서 피크를 이루며 손상이 존재하는 구간에서는 9번,10번 요소에 대한 차이가 크게 나타나지 않는다. 반면에 손상이 존재하지 않는 2경간에서는 1차 모드형상 의 차이가 크다. 따라서 부모멘트 구간에 위치하는 요소의 훈련유형은 Fig. 8과 같이 손상요소에서 피크를 이루며, 손상 이웃 경간에서 삼각형 형상을 갖는 두 개의 삼각형으로 구성한다.




Fig. 7 9번,10번 요소손상시 손상전·후의 1차 모드형상의 차이 정규화 값




Fig. 8 9번 요소 손상에 대한 훈련유형

4.1 대상 구조물

본 논문에서 제안한 손상평가 알고리즘을 검증하기 위해 Fig. 9와 같은 모형에 적용하였다. 모형 구조물은 2경간 연속보를 고려하였으며, 해석에 사용한 물성치는 단면적 $0.4631m^2$, 단위중량 $7.8334t/m^3$, 단면 2차모멘트 $0.337m^4$ 이다. 유한요소해석을 위해 요소 수 20개, 절점 수 21개, 요소길이 2m로 하였다.

4.2 PNN 훈련유형

Fig. 9에 보인 모형 구조물의 각 요소가 손상을 입었을 때 각 요소의 손상을 대표할 수 있는 훈련 유형은 다음과 같이 구할 수 있다. 먼저 각 요소에 손상을 30%씩 도입하였을 때 각 요소에 대해 손상전·후의 1차 모드형상 차이를 구한 후 가장 큰 값으로 정규화하면 Fig. 10과 같이 정규화된 그래프를 얻을 수 있다.




Fig. 10 손상전후의 1차 모드형상 차이의 정규화 값




Fig. 9 수치 해석 모형 (2경간 40m)

4. 수치 해석 예

Table 1 손상전 · 후 1차 모드형상의 차를 정규화한 값 (손상 30%)

손상요소 절 점	1	2	3	4	5	6	7	8	9	10
1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
2	1.00	0.55	0.38	0.27	0.18	0.08	-0.04	-0.24	-0.32	-0.31
3	0.78	1.00	0.80	0.57	0.39	0.19	-0.05	-0.42	-0.59	-0.57
4	0.60	0.74	1.00	0.92	0.65	0.36	0.02	-0.50	-0.77	-0.76
5	0.43	0.52	0.70	1.00	0.99	0.62	0.20	-0.43	-0.83	-0.82
6	0.28	0.35	0.47	0.67	1.00	1.00	0.51	-0.18	-0.72	-0.75
7	0.17	0.21	0.29	0.42	0.63	0.96	1.00	0.29	-0.45	-0.53
8	0.08	0.11	0.16	0.24	0.37	0.57	0.91	1.00	0.00	-0.16
9	0.02	0.04	0.07	0.11	0.18	0.29	0.49	0.83	0.63	0.35
10	-0.01	0.01	0.02	0.04	0.07	0.11	0.20	0.35	0.35	1.00
11	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
12	-0.05	-0.02	-0.01	0.01	0.04	0.09	0.17	0.33	0.34	0.29
13	-0.11	-0.05	-0.03	0.00	0.05	0.14	0.30	0.59	0.63	0.52
14	-0.17	-0.09	-0.05	-0.02	0.05	0.17	0.38	0.78	0.84	0.69
15	-0.22	-0.12	-0.08	-0.04	0.04	0.17	0.42	0.88	0.97	0.78
16	-0.25	-0.14	-0.10	-0.05	0.02	0.16	0.42	0.90	1.00	0.80
17	-0.25	-0.15	-0.10	-0.06	0.01	0.14	0.38	0.84	0.94	0.74
18	-0.22	-0.13	-0.09	-0.06	0.00	0.11	0.32	0.70	0.79	0.62
19	-0.17	-0.10	-0.07	-0.05	0.00	0.08	0.22	0.50	0.57	0.44
20	-0.09	-0.05	-0.04	-0.02	0.00	0.04	0.12	0.26	0.30	0.23
21	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00




Fig. 11 정모멘트 구간의 혼련유형




Fig. 12 중앙부의 혼련유형




Fig. 13 부모멘트 구간의 혼련유형

Table 1은 각 요소의 손상전 · 후 1차 모드형상 차이의 정규화값을 1경간에 대해서만 나타낸 것이다. Table 1을 보면 1번 요소에 손상을 도입한 경우 1차 모드형상 의 차이가 2번 절점에서 가장 크게되며, 2번 요소에 손상을 도입한 경우에는 3번 절점에서 가장 큰 차이가 발생한다. 그리고 1경간의 중앙에 해당하는 5번 요소에 손상을 도입한 경우에는 5번과 6번 절점에서 1차 모드형상 의 차이가 가장 크게 됨을 알 수 있으며, 부모멘트구간 9번과 10번에서와 다음 경간 중앙부에서 1차 모드형상 차가 큼을 알수 있다.

따라서 3.2절에서 본 바와 같이 정모멘트 구간의 1번 요소부터 4번 요소, 그리고 7번 요소의 혼련유형은 Fig. 11의 삼각형 모양으로 사용한다. 또한 경간 중앙에 위치한 5번, 6번 요소의 혼련유형은 Fig. 12와 같은 사다리꼴 모양을 혼련유형으로 하며, 부모멘트 구간 8번에서 10번 요소의 혼련유형은 Fig. 13과 같은 두 개의 삼각형 모양을 혼련유형으로 사용한다. 모형 구조물은 좌우 대칭이므로 11번 요소부터 20번 요소에 대한 혼련유형은 구조물의 대칭성을 이용하여 1번 요소에서 10번 요소에 대해 얻은 혼련유형을 사용하였다.

Table 2 각 요소별 훈련유형

손상요소 절점	1	2	3	4	5	6	7	8	9	10
1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
2	1.00	0.50	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
3	0.50	1.00	0.50	0.00	0.00	0.00	0.00	0.00	0.00	0.00
4	0.00	0.50	1.00	0.50	0.50	0.00	0.00	0.00	0.00	0.00
5	0.00	0.00	0.50	1.00	1.00	0.50	0.00	0.00	0.00	0.00
6	0.00	0.00	0.00	0.50	1.00	1.00	0.50	0.00	0.00	0.00
7	0.00	0.00	0.00	0.00	0.50	1.00	1.00	0.00	0.00	0.00
8	0.00	0.00	0.00	0.00	0.00	0.50	0.50	1.00	0.00	0.00
9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.50	1.00	0.50
10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00

4.3 손상위치 추정

모형 구조물의 2번, 5번, 9번 요소에 각각 40% 손상을 도입한 경우 손상전후의 1차 모드형상 차이를 정규화하여 입력유형을 만든 후 훈련유형과 함께 PNN에 입력하여 손상위치를 추정하였다. Fig. 14~ Fig. 16은 1개소에 손상이 존재하는 경우에 대한 손상위치 추정결과를 나타낸다. Fig. 14는 2번 요소에 손상이

있는 경우 실제 입력유형과 2번 훈련유형사이에 58%의 유사성이 있다는 것을 의미하며 이는 2번 요소의 손상을 의미한다. Fig. 15은 5번 요소에 손상이 존재할 때의 결과이며 Fig. 16은 9번 요소 손상시 손상위치 추정 결과이다. 그림에서 손상이 일어난 주변부재에 어느 정도의 손상확률이 나타나는 이유는 손상부재의 강성저하로 인한 1차 모드형상의 변화가 손상주변 절점에서의 1차 모드형상에 영향을 미치기 때문이다.




Fig. 14 2번 요소 손상시




Fig. 16 9번 요소 손상시




Fig. 15 5번 요소 손상시




Fig. 17 2번, 3번 요소 동시 손상시




Fig. 18 3번, 8번 요소 동시 손상시




Fig. 20 손상 정도에 따른 고유진동수 변화(5번요소)




Fig. 19 4번, 17번 요소 동시 손상시




Fig. 21 손상 정도 추정(5번요소, 17% 손상)

손상이 2개소에 존재할 경우에 대한 결과는 Fig. 17~Fig. 19에 나타내었다. Fig. 17은 이웃한 2번, 3번에 요소에 손상을 도입한 경우이다. 그림에서 이웃한 두 요소에 동시에 손상이 존재하는 경우 손상 위치 평가는 한 요소에 손상이 존재할 때와 유사하여 명확한 평가가 어렵다. Fig. 18은 1경간에 대해 3번 요소와 8번 요소가 손상을 받은 경우 최대확률에 대해 정규화한 결과이며, Fig. 19는 1경간의 4번 요소와 2경간의 19번 요소에 손상을 동시에 도입하였을 때 최대확률에 대해 정규화한 결과이다. 손상이 서로 떨어진 요소에 존재하는 경우 각 훈련 유형에 대한 유사정도 확률중 큰 값에 대해 정규화하면 Fig. 18과 Fig. 19와 같이 손상위치를 잘 추정함을 알 수 있다.

4.4 손상정도 추정

구조물의 손상정도 추정은 손상위치가 추정된 후 손상 구조물로부터 얻은 고유진동수를 사용하여 추정할

수 있다. 손상정도를 추정하기 위해 PNN에 입력되는 훈련집합은 각 요소별로 손상정도에 따라 유한요소 해석을 통해 얻은 고유진동수로 구성한다. 손상위치가 결정된 후 손상정도의 추정은 손상이 발생한 요소의 고유진동수 훈련집합과 손상구조물로부터 얻은 고유진동수를 PNN에 입력하여 손상정도를 추정하게 된다.

예를 들어 손상위치 추정에서 5번 요소에 손상이 있다고 평가되면 훈련집합은 유한요소 해석을 통해 5번 요소에 손상을 5%~40%까지 5%단위로 도입한 후 각 손상정도에 대한 고유진동수를 구하여 구성한다. 수치해석 예에서는 5번 요소에 손상을 17% 도입한 경우와 2번 요소에 7% 손상을 도입한 후 손상정도 추정에 대해 검증하였다. Fig. 20과 Fig. 22는 각각 5번 요소와 2번 요소의 손상정도에 따른 고유진동수의 변화를 나타내는 그림이며, 이것을 훈련유형으로 하여 실제로 구한 고유진동수와 함께 PNN에 입력한 결과 Fig. 21과 Fig. 23과 같은 각각의 경우에 대한 손상정도 추정결과를 얻었다.




Fig. 22 손상 정도에 따른 고유진동수 변화(2변요소)




Fig. 23 손상 정도 추정(2변요소, 7% 손상)

5. 결론

본 논문에서는 기존의 신경망을 통한 구조물 손상평가 시 단점으로 지적되는 신경망학습에 대한 많은 훈련자료의 생성, 신경망의 구조에 따른 수렴성 불확실성을 극복하고자 PNN을 유형분류기로 사용하는 개선된 손상추정 기법을 제안하였다. 구조물 각 요소의 손상을 대표할 수 있는 기하학적 모형(삼각형 또는 사다리꼴)을 훈련유형으로 모델링하여 손상위치를 추정하고, 추정된 손상위치를 근거로 손상구조물의 고유진동수를 사용하여 손상정도를 추정하였다. 본 연구결과 다음과 같은 결론을 얻을 수 있었다.

- 1) 무감독 신경망인 PNN에 의한 손상평가는 기존 감독 신경망에서 필요로 하는 신경망 훈련방식을 사용하지 않고, 훈련유형에 대한 실제 입력유형의 유사정도를 확률값으로 산출하므로 신경망의 구조가 단순하고 기존의 신경망에서 필요한 많은 훈련자료의 생성과 신경망 구조를 결정하는데 소요되는 노력을 경감할 수 있다.
- 2) 기존 신경망의 훈련자료에 해당하는 훈련유형은 구조물의 각 요소의 손상유형을 대표할 수 있는 형태로서 유한요소를 통해 손상전후의 1차 모드형상 차이에 대한 정규값으로부터 정모멘트 발생 구간에서는 삼각형 형태, 경간의 중앙부에 대해서는 사다리꼴 형태, 부모멘트 발생구간에서는 2개의 삼각형 형태를 훈련유형으로 사용할 수 있다.
- 3) 구조물의 손상위치 추정에 있어 손상위치가 1개소인 경우에는 손상위치를 나타내는 확률정도가 높

지만 2개소인 경우에는 손상요소의 배치형태에 따라 손상위치 추정의 정도가 낮게 나타난다. 따라서 손상이 2개소 이상인 경우에 대해서는 훈련유형을 재구성함으로써 추정정확도를 향상 시킬수 있으리라 판단된다.

감사의 글

본 연구는 한국과학재단 목적연구과제(1999-2-311-002-5) 지원으로 수행되었으며, 지원에 감사 드립니다.

참고문헌

1. 정환진, 김주태, 오주원, 이인원, “신경망을 이용한 구조물의 손상평가.” 토목학회 논문집, 제17권, 제1-4호, 1997, pp. 617-626.
2. 김동현, 정형조, 이인원, “교량의 손상평가를 위한 다층 신경망,” 방제연구논문집, 제2권 제1호, 2000, pp. 127-134.
3. 전덕빈, 신호덕, 이정진, “예측치 결함을 위한 PNN 접근 방법,” Journal of the Korean institute of Industrial Eng, 26(3), 2000, pp. 193-199.
4. Szweczyk ZP, Hajela P., “Damage detection in structures based on feature-sensitive neural networks,” J Comput Civil Eng, ASCE, 8(2), 1994, 163-78.
5. Pandey, P.C., and Barai, S. V., “Multilayer perceptron in damage detection of bridge structures,” Computer & Structures, 54(4), 1995, 597-608.
6. Eun Young Bahng. “Substructural identification for Damage Assessment Using Neural Networks,” Ph.

-
- D Dissertation, Dept. of Civil Engrg, Korea Advanced Institute of Science and Technology, Taejon, Korea, 1997.
7. Specht, D. F. "Probabilistic Neural Networks" Neural Networks. 3, 1990, pp. 109-118.
 8. Wu, X., Ghaboussi, J., and Garrett J.H. Jr,(1992). "Use of neural networks in detection of structural damage," Computer & Structures, 42(4), pp. 649-659.
 9. Swamidas, A.S.J., and Chen, Y., "Damage detection in a tripod tower platform using modal analysis," Proceeding of the 11th International Conference on Offshore Mechanics and Arctic Engineering, Vol.1,Pt.B,june 7-12, 1992, pp. 577-583.
 10. Y.Q. Ni, X.T. Zhou, J.M. Ko and B.S. Wang., "Vibration-Based Damage Localization in Ting Kau Bridge Using Probabilistic Neural Network." Advances in Structural Dynamics, Elsevier Science Ltd., Oxford, UK, Vol. 2, pp. 1069-1076.
 11. Tsou, P., and Shen, M-H. H., "Structural damage detection and identification using neural networks," AIAA J. 32(1), 1994, 176-183.
 12. Manning, R. A., "Structural damage detection using active members and neural networks," AIAA J,32(6), 1994, pp. 1331-1333.

(접수일자 : 2001년 8월 24일)