

확률신경망을 이용한 철도 판형교의 손상평가

Damage Assessment of Plate Gider Railway Bridge Based on the Probabilistic Neural Network

조 호 남† 이 성 칠* 강 경 구** 오 달 수*
Cho, Hyo Nam Lee, Sungchil Kang, Kyoung-Koo Oh, Dal-Soo

(논문접수일 : 2002년 11월 25일 ; 심사종료일 : 2003년 9월 8일)

요 지

손상평가를 위해 많은 연구자들에 의해 인공신경망이 이용되어 왔다. 그러나, 인공신경망을 이용한 손상평가에 있어 정확성과 능률성을 제고하기 위해서는 몇가지 문제점들이 있다. 기존의 인공신경망 특히 역전파신경망(BPNN)의 경우 신경망 학습을 위해 많은 수의 학습패턴을 필요로 하며, 또한 신경망의 구조와 해의 수렴간에 어떤 확정적인 관계가 존재하지 않는다. 따라서 신경망의 은닉층의 수와 한 은닉층에서의 노드수는 시행착오적으로 결정되게 된다. 이러한 많은 훈련패턴의 준비와 최적의 신경망 구조 결정을 위해서는 많은 시간이 필요하다. 본 논문에서는 이러한 단점들을 극복하기 위해 확률신경망을 패턴분류기로 사용하였다. 이를 판형철도교의 손상평가에 수치해석적으로 검증하였다. 또한 확률신경망을 이용한 철도판형교 손상평가지 적절한 훈련패턴 선택을 위해 모드형상과 고유진동수를 사용한 경우의 적용성에 대해 검토하였다.

핵심용어 : 확률신경망, 손상 평가, 철도판형교

Abstract

Artificial neural network has been 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 associated with the conventional artificial neural network, especially the Back Propagation Neural Network (BPNN), are on the need of many training patterns and on the ambiguous relationship between neural network architecture and the convergence of solution. Therefore, the number of hidden layers and nodes in one hidden layer would be determined by trial and error. Also, it takes a lot of time to prepare many training patterns and to determine the optimum architecture of neural network. To overcome these drawbacks, the PNN can be used as a pattern classifier. In this paper, the PNN is used numerically to detect damage in a plate girder railway bridge. Also, the comparison between mode shapes and natural frequencies of the structure is investigated to select the appropriate training pattern for the damage detection in the railway bridge.

Keywords : probabilistic neural network, damage assessment, plate-girder railway bridge

1. 서 론

구조물 손상평가는 손상 전·후에 구조물의 물리적 성질, 즉 질량행렬, 강성행렬, 감쇠행렬 등이 변화하면 이에 따라 구조물의 동적 응답이 변화하는 것을 이용한다. 이러한 손상평가 기법은 크게 시간영역 방법과 주파수 영역 방법으로 대별할 수 있다. 그러나, 이러한 기법들은 구조물의

손상평가를 위해 많은 추가적인 해석과정을 필요로 하거나, 최적 알고리즘을 통한 반복수행을 해야 하는 등 많은 어려움이 따른다.

이러한 문제들을 극복하기 위해 많은 연구자들에 의해 인공신경망(ANN:Artificial Neural Network)을 이용한 손상평가에 대한 연구가 이루어졌다. 신경망은 인간신경의 학습과 기억방식을 컴퓨터를 통해 모사한 모형으로,

† 책임저자, 정회원 · 한양대학교 공과대학교 학장
전화: 031-400-4027; Fax: 031-406-5660
E-mail: RYFID@chollian.net

* 한양대학교 토목·환경공학과

** 승화 E&C 건설IT사업부 부장

· 이 논문에 대한 토론을 2003년 12월 31일까지 본 학회에 보내주시면 2004년 3월호에 그 결과를 게재하겠습니다.

주로 패턴인식분야에서 많이 사용되어왔다. 구조물의 손상 평가 분야에서는 구조물의 손상 전·후의 동적 응답에 의해 손상을 평가하는 과정이 패턴인식 과정과 유사하므로 구조물의 손상평가에 응용되었다. 이러한 신경망을 이용한 손상평가의 대표적 연구로 Wu et al.¹⁾은 3층 구조물의 손상을 평가하기 위해 하나의 은닉층(Hidden Layer)을 갖는 역전파 신경망 BPNN(Back Propagation 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. Sze-wczyk & Hajela²⁾는 9개의 힘요소를 가진 프레임 구조물에 대해 신경망을 이용한 손상평가를 하였는데, 신경망을 훈련시키기 위해 3600가지의 손상 경우에 대한 구조물의 정적응답을 이용하였다. Pandey & Barai³⁾는 21개의 부재를 가진 트러스 구조물에 대해 40가지의 손상유형에 따른 훈련패턴을 사용하여 신경망을 훈련시켰다. 또한 Bahng⁴⁾은 55개의 부재를 가진 트러스 구조물의 손상을 평가하기 위해 역전파신경망(BPNN)을 사용하였는데, 신경망 훈련을 위하여 1200가지의 손상유형에 따른 훈련패턴을 이용하였다.

신경망을 이용한 구조물의 손상평가 기법은 비록 시간영역과 주파수영역에서의 손상평가 기법의 복잡함을 해결하는 대안으로 생각될 수 있으나, 신경망 학습을 위해 적절한 수의 훈련패턴을 준비하여야 하며, 이는 훈련패턴을 생성하기 위하여 훈련패턴수와 같은 수의 유한요소 해석을 수행해야 한다는 것을 의미한다. Baum & Haussler⁵⁾는 신경망의 일반적인 수렴성을 보장하기 위한 훈련패턴 수를 다음 식과 같이 제안하였다.

$$N \geq \frac{32W}{\epsilon} \ln \left(\frac{32M}{\epsilon} \right) \quad (1)$$

여기서, N 은 필요한 훈련패턴 수, ϵ 은 허용오차, W 는 신경망의 연결가중치 수, M 은 은닉층의 수를 나타낸다. 식(1)에서 로그항을 무시하면, 식(2)와 같다.

$$N \geq \frac{W}{\epsilon} \quad (2)$$

따라서, 10%의 오차를 허용한다면 필요한 훈련패턴의 수는 연결가중치 수의 10배가 필요하게 된다.

또한 문제에 따라서는 신경망을 구성하는 은닉층의 수, 은닉층별 노드 수에 따라 수렴성이 보장되지 않는 경우도 있으며, 은닉층 수와 은닉층별 노드 수에 따른 신경망의 학습 결과 사이의 상관성을 파악하기가 어렵다. 따라서 위에 열거한 연구들에서는 최적의 신경망 구조를 결정하기 위해 시행착오적으로 은닉층 수와 은닉층 별 노드 수를 결정해야만 했다. 이러한 많은 훈련패턴의 준비와 최적의 신경망 구조 결정은 상당한 시간을 필요로 한다.

그러나 확률신경망(PNN : Probability Neural Network)⁵⁾은 하나의 은닉층을 갖는 구조로 되어있으며, 훈련패턴의 수만 결정되면 은닉층의 노드수가 결정된다. 따라서 역전파신경망에서와 같은 최적 신경망구조 결정을 위한 시간 소모적인 단계를 생략할 수 있으며, 항상 수렴성이 보장되는 장점이 있다. 또한 확률신경망을 이용할 경우 역전파신경망과는 달리 신경망을 훈련시키는 과정이 필요치 않으므로 훈련과정에서 파생될 수 있는 신경망의 일반성 상실, 발산 등을 방지할 수 있다.

Rytter⁶⁾는 구조물의 손상평가 기법을 손상평가 수준에 따라 4단계로 구분하였다. 대부분의 구조물손상평가 기법의 목표는 3단계 즉, 구조물의 손상위치 및 손상정도 파악에 두고 있다. 그러나, 본 논문에서는 전체 구조물을 몇 개의 부구조 부분으로 분류한 후, 손상이 발생한 부구조 부분을 파악할 수 있다면, 그 부분에 대한 점검을 집중적으로 실시할 수 있으므로, 이러한 부구조 부분에 대한 손상발생 여부 파악을 위한 기법으로서 확률신경망을 이용하였다.

2. 확률신경망(PNN : Probability Neural Network)

2.1 확률신경망의 기초

확률신경망은 확률밀도함수(Probability Density Function)에 대한 비모수 추정과 베이즈의 의사결정전략을 결합하여 베이즈안 유형분류(Bayesian Classification)를 한다. $\theta_1, \theta_2, \dots, \theta_q, \dots, \theta_s$ 의 여러 범주에 대한 다중 범주분류 문제의 경우, 측정된 k -차원의 벡터 $X = \{x_1, x_2, \dots, x_i, \dots, x_p\}^T$ 를 기초로 하여 θ 가 θ_q 로 유형분류 되기 위한 Bayes 결정법칙은 아래 식(3)과 같이 기술된다.

$$d(X) \in \theta_q \quad \text{if } h_q l_q f_q(X) > h_k l_k f_k \quad \text{for all } k \neq q \quad (3)$$

여기서 $d(X)$ 는 시험벡터 X 에 대한 범주결정, h_q 와 h_k 는 각각 범주 θ_q 와 θ_k 에 대한 사전확률, l_q 는 $\theta \in \theta_q$ 일 때 $d(X) \neq \theta_q$ 라고 분류한 경우의 손실, l_k 는 $\theta \in \theta_k$

일 때 $d(X) \neq \theta_k$ 로 분류한 경우의 손실, $f_q(X)$ 와 $f_k(X)$ 는 각각 범주 θ_q 와 θ_k 에 대한 확률밀도함수이다.

손상 추정 문제에 있어 기대되는 사전확률 h 와 손실 l 은 모든 범주에 대해 같다고 가정하고, 확률밀도함수를 알면 식(1)을 사용하여 범주 분류를 할 수 있다. 그러나 각 범주에 대한 확률밀도함수는 주어진 정보가 훈련패턴 뿐이므로 훈련패턴에 기초하여 확률밀도함수를 추정해야만 한다. 범주의 확률밀도함수 추정은 다음 식(4)와 같은 Parzen's windows 방법을 이용하여 추정할 수 있다(Wasserman).⁷⁾

$$f_q(X) = \frac{1}{n_q(2\pi)^{p/2} \sigma^p} \sum_{i=1}^{n_q} \exp\left[-\frac{(X - X_{qi})^T (X - X_{qi})}{2\sigma^2}\right] \quad (4)$$

여기서 X 는 분류되어야 할 시험패턴, $f_q(X)$ 는 X 점에서 범주 q 의 확률밀도함수, n_q 는 범주 q 에 속한 훈련패턴의 수, p 는 훈련패턴의 차원, X_{qi} 는 범주 q 에서 i 번째 훈련패턴, σ 는 평활화 변수(smoothing parameter)이다.

2.2 확률신경망의 구조

확률신경망은 그림 1과 같은 3개의 층으로 구성된다. 확률신경망의 첫 번째 층(입력층)은 분류되어야 할 시험패턴을 단순히 받아들이며 입력층의 노드 수는 훈련패턴의 차원과 동일하다. 패턴층의 각 노드에는 훈련패턴을 저장하고 있으며, 시험패턴 X 와 훈련패턴별 가중치벡터 W_j 를 곱한다($z_j = X \cdot W_j$). 여기서 가중치벡터 W_j 는 훈련패턴과 동일하다. 그리고 마지막 합계층으로 이동하기 전에 비선형 활성화 함수(activation function)에 의해 z_j 를 변환한다. 여기서 활성화 함수는 통상적인 역전파신경망의 시그모이드 활성화함수를 이용하지 않고 $g(z_j) = \exp[(z_j - 1)/\sigma^2]$ 을 이용한다. 합계층의 각 뉴런은 패턴층으로




그림 1 확률신경망 구조

로부터 각각의 범주별로 결과를 받게 된다. 따라서 범주 q 에 상응하는 합계층의 결과는 식(5)과 같다.

$$f_q(X) = \sum_{i=1}^{n_q} z_{qi} = \sum_{i=1}^{n_q} \exp[(X \cdot W_{qi} - 1)/\sigma^2] \quad (5)$$

식(4)에서 가중치벡터 W_{qi} 를 훈련벡터 X_{qi} 로 선정하고 $X^T \cdot X = X_{qi}^T \cdot X_{qi} = 1$ 이 되도록 정규화하면 합계층의 결과인 식(4)는 식(5)와 같게 된다.

본 논문에서 확률신경망의 손상추정 부문에 대한 적용은 다음과 같다. 먼저 구조물을 몇 개의 부분으로 분류한 후, 각 부분에 대한 몇 가지 손상을 가정하여 손상구조물로부터 훈련패턴을 생성하고 컴퓨터에 저장한다. 다음으로 미지의 어느 부분이 손상된 상태 하에서 얻어진 시험패턴이 주어지면 이것을 확률신경망에 입력하여 식(5)에 의하여 손상부분을 탐지하는 것이다.

확률신경망의 주된 이점은 학습 속도이다. 역전파신경망은 신경망의 학습을 위하여 훈련패턴과 목표값에 의한 반복적인 학습과정을 통해 가중치들이 결정되지만, 확률신경망의 가중치들은 반복적인 학습과정을 통해 훈련되지 않으며, 보통의 학습과정 중에 패턴층의 각 노드에 기억된다. 확률신경망은 모든 훈련패턴을 기억해야하기 때문에 많은 기억 장소를 필요로 하며, 적절한 연산을 위해 어느 정도의 훈련패턴을 필요로 한다.

3. 수치해석 대상구조물

3.1 대상 구조물

많은 철도교 중 대부분은 단순보 형식의 판형교이다. 이러한 판형철도교량은 경부선, 호남선 등 주요 철도간선(幹線)에 설치되어 중요한 역할을 담당하고 있으며, 만일 파괴되는 경우 다른 우회 방법 없이 선로가 통제되므로 이에 따른 경제적 피해는 실로 막대하다. 따라서 이러한 판형철도교의 안전성 확보는 사회적 경제적인 면에서 매우 중요한 요소라고 할 수 있다.

본 논문에서 제안한 손상평가기법의 적용을 위해 경부선 상에 있는 판형철도교를 선정하여 상용프로그램 MIDAS Civil Ver 5.2⁹⁾를 이용한 유한요소 모델링을 수행하고 요소에 손상을 강성저하로 가정하여 손상을 가한 후 손상을 추정하였다. 적용구조물에 대한 유한요소 모델은 그림 2와 같다. 표 1은 적용교량에 대한 구조제원을 나타낸다. 유한요소 모델링은 원래 구조물의 형태를 최대한 반영하기 위해 거더 부분은 상용프로그램의 플레이트요소를 사용하

표 1 구조 형식

구분	제원표	실측
형식	판형교 (리벳:경부형)	
호칭경간(m)	9	
지간(m)	9.7	9.44
보전장(m)	10.14	10.8
보높이(m)	1.16	1.05
주형 중심간격	1.6	1.5
상부플랜지두께(cm)	1.6/3.0	1.8/3.4
하부플랜지두께(cm)	1.6/3.0	1.8/3.4
플랜지폭(cm)	25	30
웹두께(cm)	1	1
플랜지 재질	SWS41	

표 2 각 요소의 Class 분류 및 위치

Class 분류	요소 번호	요소 위치
1번 Class	E 1 E 2 ⋮ E 12	우측 거더
2번 Class	E 13 E 14 ⋮ E 23	우측 거더
3번 Class	E 24 E 25 ⋮ E 35	좌측 거더
4번 Class	E 36 E 37 ⋮ E 46	좌측 거더

였으며, 브레이싱과 침목은 프레임요소를 사용하여 모델링하였다.

3.2 손상평가를 위한 Class 구분

철도판형교의 손상 평가를 위해 시험교량에 대한 부구조

를 그림 3과 같이 4개의 Class로 구분하였다. 각 Class 구분은 왼쪽 플레이트 거더와 오른쪽 플레이트 거더에 대해 표 2에 나타내었다. 표 2에서 1번 Class는 거더 요소 1번부터 12번까지이며, 2번 Class는 거더 요소 13번부터 23번까지, 3번 Class는 거더 요소 24번부터 35번까지 그리고 4번 Class는 거더 요소 36번부터 46번까지이다. 따라서 손상평가시 확률신경망을 통해 산출되는 값은 예상 손상 Class를 산출하게 된다.

4. 입력패턴 및 손상시나리오

4.1 입력패턴의 생성

구조물 손상평가를 위해 사용되는 구조물 동적 응답의 종류는 다양하다. 이러한 구조물 응답의 종류는 시간영역과 주파수 영역에서의 응답으로 구분할 수 있는데 주파수 영역에서는 모드형상과 고유진동수가 가장 많이 사용되어져 왔다. 신경망을 이용한 손상평가에 있어서 신경망을 훈련시키기 위한 적절한 입력패턴의 결정은 매우 중요한 역할을 한다.

본 논문에서는 판형교에서 측정할 수 있는 동적응답 중 고유진동수와 모드형상을 이용하여 입력패턴을 형성하고 각각의 입력패턴에 대해 손상평가 적용성에 대해 검토하여 보았다.

모드형상을 이용한 손상평가를 위해, 시험교량의 수직 1차 모드형상을 이용하였으며, 확률신경망을 위한 입력패턴은 다음 식(6)과 같이 결정하였다.

$$P_j = \frac{\phi_j^U - \phi_j^D}{\text{Max}[|\phi_i^U| - |\phi_i^D|]} \quad (6)$$

여기서 P_j 는 입력층 j 번째 노드의 입력치, ϕ_j^D 는 손상구조물의 j 번째 절점에서의 모드형상값, ϕ_j^U 는 무손상구조물의 j 번째 절점에서의 모드형상값, $\text{Max}[|\phi_i^U| - |\phi_i^D|]$




그림 2 대상구조물의 유한요소 모델




그림 3 손상위치 추정을 위한 Class 구분

는 손상구조물과 무손상구조물의 각 절점에서의 모드형상 차 중 가장 큰 값이다.

고유진동수를 이용한 손상평가를 위해서 유한요소해석을 통해 얻은 고유진동수에 대해 다음 식(7)와 같은 방식으로 결정하였다.

$$P_j = \frac{f_j^U - f_j^D}{\text{Max}[|f_i^U - f_i^D|]} \quad (7)$$

여기서 P_j 는 입력층 j 번째 노드의 입력치, f_j^D 는 손상구조물의 j 번째 진동차수의 고유진동수, f_j^U 는 무손상구조물의 j 번째 차수의 고유진동수, $\text{Max}[|f_i^U - f_i^D|]$ 는 손상구조물과 무손상구조물의 각 진동차수의 고유진동수 차 중 가장 큰 값이다. 본 논문에서 고유진동수를 이용한 손상평가를 위해 20차까지의 고유진동수를 이용하였다.

4.2 훈련패턴 생성 및 손상 시나리오

구조물의 손상을 도입하는 기법은 부재 단면을 감소하는 방법, 부재두께를 감소하는 방법, 직접 균열을 모사하는 방법 등 여러 가지가 있지만, 본 논문에서는 재료의 탄성계수를 감소함으로써 손상을 묘사하였다. 훈련패턴생성을 위해 각 Class 별로 표 3에 나타난 요소에 대해 탄성계수를 70% 감소시킨 후 이러한 손상상태에 대한 유한요소해석을 통해 얻은 모드형상과 고유진동수를 이용하여 훈련패턴을 생성하였다. 또한 모드형상과 고유진동수를 사용한 경우에 대한 손상추정을 평가하기 위해 표 4와 같이 시험패턴구성을 위한 손상시나리오를 가정하였다. 손상추정기법은 구조물의 파괴를 미리 예방할 수 있어야 하므로 초기 손상을 탐지할 수 있어야 한다. 그러나, 표 4에서 손상시나리오의 손상정도가 70%, 50%인 것은 확률신경망의 손상추정 적용성을 평가하기 위해 선택된 것이다.

표 3 Class 별 손상요소

Class 1	Class 2	Class 3	Class 4
2, 7	14, 19	25, 30	37, 42
3, 8	15, 20	26, 31	38, 43
4, 9	16, 21	27, 32	39, 44
5, 10	17, 22	28, 33	40, 45
6, 11	18, 23	29, 34	41, 46

표 4 손상시나리오

손상요소		소 속 Class	손 상 정도(%)
모드형상	고 유 진동수		
9	3	1	70(50)*
18	15	2	70(50)
29	31	3	70(50)
41	41	4	70(50)

* ()는 모드형상에 대한 경우에만 적용

5. 손상추정 결과

5.1 모드 형상을 이용한 손상 추정 결과

확률신경망을 이용한 손상 평가 시 입력패턴으로 모드형상을 이용한 경우에 대한 결과는 표 5 및 표 6과 같다. 표 5 와 6에서 각 요소의 손상정도는 각각 50%, 70%이다. 그림 4~11은 표 5와 6에 대한 결과를 나타낸 것이다. 이들 그림에서 수치는 각 Class별 손상확률을 나타내며, 손상확률이 가장 큰 Class 내에 손상요소가 존재함을 의미한다. 그림 4, 5는 Class 1에 속하는 요소번호 9번에 손상을 각각 50%, 70% 도입하였을 때 손상추정결과를 나타낸다. 그림 6, 7은 Class 2에 속하는 18번 요소에 손상을 50%, 70% 도입한 경우 손상추정결과이다. 그리고 그림 8, 9는 Class 3에 속하는 29번 요소, 그림 10, 11은 Class 4에 속하는 41번 요소에 손상을 50%, 70% 도입

표 5 50% 손상시 손상추정 결과

Class	손상 확률			
	요소 #9 손상시	요소 #18 손상시	요소 #29 손상시	요소 #41 손상시
1	86.84	26.56	35.08	19.14
2	35.44	95.54	19.18	34.60
3	29.76	19.64	95.20	29.06
4	19.72	36.86	29.92	96.64

표 6 70% 손상시 손상추정 결과

Class	손상 확률			
	요소 #9 손상시	요소 #18 손상시	요소 #29 손상시	요소 #41 손상시
1	87.04	26.40	35.40	19.20
2	34.86	95.42	19.24	34.74
3	30.16	19.72	95.12	28.88
4	19.78	37.02	29.60	96.62




그림 4 손상요소:9(Class 1), 손상정도:50%




그림 7 손상요소:18(Class 2), 손상정도:70%




그림 5 손상요소:9(Class 1), 손상정도:70%

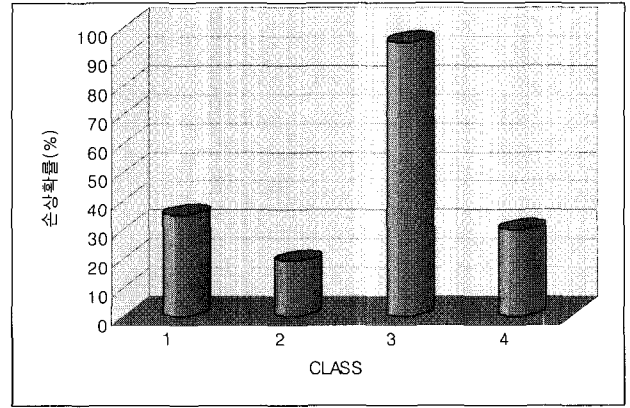


그림 8 손상요소:29(Class 3), 손상정도:50%




그림 6 손상요소:18(Class 2), 손상정도:50%




그림 9 손상요소:29(Class 3), 손상정도:70%




그림 10. 손상요소:41(Class4), 손상정도:50%

하였을 때 손상추정 결과를 나타낸다.

위의 그림에서 모든 경우에 손상을 잘 추정함을 알 수 있다. 동일한 요소에 대해 손상정도만 50%와 70%로 달린 경우에도 손상확률이 거의 비슷하게 추정됨을 알 수 있는데 이는 입력패턴을 구성할 때 손상 전·후의 각 절점에서의 모드형상의 차이를 가장 큰 차이 값으로 나눔으로써 정규화 하였기 때문에 요소의 손상정도에 관계없이 비슷한 입력패턴이 생성되기 때문이다.

5.2 고유진동수를 이용한 손상 추정 결과

입력패턴 생성시 고유진동수를 이용한 경우에 대한 손상평가 결과는 표 7과 같으며, 그림 12~15는 각 손상시나리오에 대한 결과를 도시화 한 것이다. 그림 12는 Class 1에 속하는 3번 요소에 70% 손상을 가한 후 손상평가를 수행한 결과이다. 표 7에서 3번 요소에 대한 손상평가 외에는 손상 Class 추정이 잘 안됨을 알 수 있으며, 3번 요소 손상 경우에도 각 Class에 대한 손상확률이 거의 유사함을 알 수 있다. 이러한 결과는 15번 요소(Class 2 : 그림 13), 32번 요소(Class 3 : 그림 14), 41번 요소(Class 4 : 그림 15)에 대해서도 비슷하다.

고유진동수를 입력패턴으로 한 경우 손상평가가 잘 수행되지 않은 이유는 비록 입력패턴 구성을 위해 20차까지의 고차 진동수를 고려하였지만 구조물의 손상에 따른 고유진

표 7 70% 손상시 손상추정 결과

Class	손상 확률			
	요소 #3 손상시	요소 #18 손상시	요소 #29 손상시	요소 #41 손상시
1	90.18	87.90	87.52	94.66
2	89.48	88.88	88.24	94.74
3	90.34	87.86	87.46	94.64
4	89.68	88.80	88.16	94.66

동수의 변화가 민감하지 않으므로, 손상을 70% 도입하더라도, 고유진동수는 크게 변하지 않기 때문이다. 또한 고유진동수는 손상의 공간정보를 나타내기가 어려운 것도 영향을 미친 것으로 판단된다. 즉, 유사한 고유진동수 변화를 산출하는 손상요소 조합은 여러 가지가 가능하므로, 고유진동수를 이용한 경우의 입력패턴들은 모드형상을 이용한 경우와는 달리 손상 Class 별로 크게 다른 형태를 보이지 않는다.




그림 11 손상요소:41(Class4), 손상정도:70%




그림 12 손상요소:3(Class1), 손상정도:70%

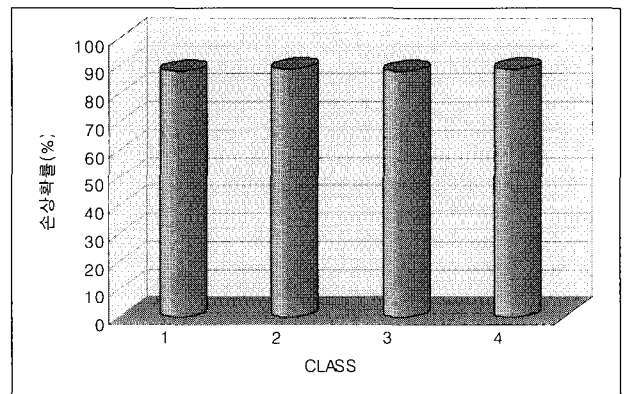


그림 13 손상요소:15(Class2), 손상정도:70%




그림 14 손상요소:32(Class3), 손상정도:70%




그림 15 손상요소:41(Class4), 손상정도:70%

6. 결 론

본 논문에서는 기존의 신경망 대신 확률신경망을 이용하여, 철도 관형교에 대한 손상평가를 실시하였다. 본 연구를 통해 확률신경망을 이용하여 철도 관형교의 손상 부분에 대한 손상추정이 가능함을 알았다. 또한, 확률신경망의 입력패턴으로 모드형상과 고유진동수를 사용한 경우에 손상평가를 실시한 결과, 모드형상을 이용한 경우에는 손상 Class 추정이 잘 되었으나, 고유진동수를 사용한 경우에는 손상 Class 추정이 잘 되지 않았다. 특히, 고유진동수의 경우는 실제 실험에서 20차 까지의 고유진동수는 계측 신호작동 오류에 의해 그 획득 가능성이 불분명하다. 이러한 결과를 통해 확률신경망을 이용한 관형교의 손상평가를 수행하는 경우 입력패턴 구성을 위해서는 모드형상을 사용하

는 것이 더 바람직하다고 판단된다.

감사의 글

본 연구는 BK21 사업 연구비 지원에 의하여 수행되었으며, 이에 감사를 드립니다.

참 고 문 헌

1. Wu, X., Ghaboussi, J., and Garrett J.H. Jr, "Use of neural networks in detection of structural damage", *Computer & Structures*, Vol.42, No.4, 1992, pp.649-659
2. Szewczyk Z.P., Hajela P., "Damage detection in structures based on feature-sensitive neural networks", *J Comput Civil Eng. ASCE*, Vol.8, No.2, 1994, pp.163~78
3. Pandey, P. C., and Barai, S. V., "Multilayer perceptron in damage detection of bridge structures", *Computer & Structures*, Vol.54, No.4, 1995, pp.597~608
4. Bahng, E. Y., "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
5. Specht, D. F., "Probabilistic Neural Networks" *Neural Networks*, 3, 1990, pp.109~118
6. Rhytter, A., "Vibration Based Inspection of Civil Engineering Structures", Ph. D. Dissertation, Dept. of Building Technology and Structural Engineering, Aalborg University, Denmark, 1993
7. Wasserman, P.D., *Advanced Methods in Neural Networks*, Van Nostrand Reinhold, New York, (Chapter 3), 1993, pp.35~55
8. Baum, E. B. and Haussler, D., "What size net gives valid generalization?", *Neural Computation* 1, 1989, pp.151~160
9. MIDASIT, *Midas Civil Ver 5.2 Manual*, 2002