

가속도 응답 신호와 다층인공신경망을 통한 단순보의 손상추정

Damage Assessment of Simple Beam using Acceleration Response Signal and Multilayer Neural Network

이 용 환* 박 재 형** 김 정 태*** 류 연 선*** 나 원 배***
Lee, Yong-Hwan Park, Jae-Hyung Kim, Jeong-Tae Ryu, Yeon-Sun Na, Won-Bae

ABSTRACT

The use of system identification approaches for damage detection has been expanded in recent years. Soft computing techniques such as neural networks have been utilized increasingly. Damage assessment using neural networks is presented in this study. Data set for training neural networks are acceleration response of simple beam under the various damage states, which are the inputs. The outputs are the damage locations and extents. Not only the trained damages but also untrained damages are detected accurately in the assessment stage.

1. 서 론

교량이나 고층건물 같은 사회기반시설물의 안전성 확보는 여러 분야에서 중요한 문제로 인식되어 왔다. 대형 구조물의 붕괴는 곧바로 엄청난 인적, 물적 피해를 야기하게 되므로 구조설계 기술의 향상과 함께 필수적으로 요구되는 것이 구조물에 대한 적절한 안전도 평가 및 유지관리기법이다. 안전도 평가는 구조물에서 얻을 수 있는 각종 자료의 분석을 통하여 구조물의 현재 상태를 파악 및 평가하는 것이다.⁹⁾ 구조물의 손상 정도나 구조적 결함을 보다 정확히 추정하기 위해 재료적인 비파괴검사 방법과 구조계의 특성을 추정하고 확인하는 시스템식별(System Identification)기법이 활발히 연구되고 있다. 비파괴검사 방법은 육안검사와 초음파, 방사능 등을 이용하는 검사, 그리고 반발경도 등의 역학적 특성을 이용하는 감사 등 그 종류가 다양하다. 비파괴검사 방법은 국부검사에는 효과가 있지만 대형구조물의 전역적인 손상을 검색하는 데에는 많은 비용이 들 뿐만 아니라 시간적인 손실을 야기하며 신뢰성 확보의 미약함으로 인해 실제 현장에서는 경험에 의존하는 경우가 많다.⁷⁾

구조물의 응답을 이용하여 구조물의 전역적인 손상을 추정하는 SI기법 중 인간의 신경과 뇌 판단을 모사한 인공신경망을 이용하는 방법은 1943년 Warren McCulloch와 Walter Pitts에 의하여 수학적 모델이 제시된 이후 여러 연구자들에 의해 단층퍼셉트론, 다층퍼셉트론, 홉필드 네트워크, 코호넨 네트워크 등 다양한 신경망 모델이 개발되었다. 신경망의 기본 특성은 학습의 가능성이다. 학습을 한 신경망은 새로운 자료가 입력되

* 부경대학교 해양공학과 석사과정

** 부경대학교 해양공학과 박사과정

*** 정회원 · 부경대학교 해양공학과 교수

있을 때 적절한 결과를 제시하고 자료가 불충분할 경우에도 학습을 시킬 수 있다. 이 뿐만 아니라 각 연산요소의 병렬처리로 빠른 연산 및 정보의 분산표현이 가능하다. 신경망 모델 중 공학 분야에서 가장 많이 사용되는 모델은 역전파 알고리즘(Back-Propagation Algorithm:BP)이다. 네트워크의 학습이 다른 모델에 비해 용이하다는 장점으로 역전파 알고리즘은 패턴인식, 제어 및 설계, 지식정보처리 등과 같은 다양한 분야에 널리 보급되고 있다.⁷⁾

본 연구에서는 단순보 구조물을 대상으로 신경망 알고리즘 중 역전파 알고리즘을 사용하여 구조물의 손상을 추정하였다. 손상시나리오는 구조물의 부재 휨 강성 감소를 손상으로 가정하여 작성하였다. 구조물의 단계적인 손상 심화에 따른 가속도 응답을 입력 자료로, 손상 위치 및 정도를 출력 자료로 하여 신경망 모델을 학습시킨 뒤 학습되지 않은 시험자료를 이용하여 신경망 알고리즘의 정확도를 검증하였다.

2. 신경망 이론

신경망(Neural Network)은 사고, 학습 인식 등 인간과 유사한 지능을 실현하기 위해 인간의 뇌의 신경조직을 모형화 하여, 신호처리, 제어, 패턴인식, 손상추정 등의 분야에 적용되고 있다. 신경망은 연결가중치의 단계적 조정으로 수행된 학습을 통하여 신경망의 성능을 향상시키며, 학습되지 않은 경우에 대해서도 일반화된 기능을 이용하여 합리적인 해를 제공한다는 특징을 가지고 있다. 그림 1은 인간의 뇌신경 세포를 가장 간단하게 표현한 것이다.⁸⁾




그림 1 인공신경망의 뉴런

외부에서 들어오는 신호 x_1, x_2, x_3 를 받아 들여 해당신호에 연결가중치를 곱하여 바이어스를 더한 값을 활성화함수를 거쳐 다른 뉴런으로 전달된다. 식 (1), (2)는 이 과정을 수식화하여 나타낸 것이다.

$$y = f(\text{net}) \quad (1)$$

$$\text{net} = \sum_i W_i x_i + b \quad (2)$$

여기서 b 는 바이어스 값이다. 활성화함수는 가우시안 함수, 구간선형함수, 시그모이드(sigmoid)함수 등 여러 가지 종류가 있으나 주로 시그모이드(sigmoid)함수가 사용되고 있고 그것은 식 (3)으로 표현하였다.

$$f(v) = \frac{1}{1 + \exp(-\lambda v)} \quad (3)$$

본 연구에서는 단순보 구조물의 손상정도와 위치를 추정하기 위해 가장 일반적으로 쓰이고 있는 신경망 학습 알고리즘인 역전파 알고리즘(Back-Propagation Algorithm:BP)을 적용한 모델을 사용하였다. 네트워크는 입력층과 은닉층, 출력층으로 구성된 다층 퍼셉트론이며 그것은 그림 2로 나타내었다.




그림 2 다층 인공 신경망

외부에서 주어진 입력신호에 대해 은닉층의 뉴런에서 식(4)와 같은 연산을 수행한다.

$$y_j = f\left(\sum_i W_{ji} x_i + b_j\right) \quad (4)$$

여기서 x_i 는 외부 입력값, y_j 는 은닉층의 출력값을 나타낸다. W_{ji} 는 입력층과 은닉층 사이의 가중치를 나타내고, b_j 는 바이어스 값을 나타낸다. 은닉층의 출력값을 이용하여 수행된 출력층의 연산은 식(5)로 나타내었다.

$$z_k = f\left(\sum_j W_{kj} y_j + b_k\right) \quad (5)$$

o_k 는 신경망의 출력값이고 W_{kj} , b_k 는 각각 은닉층과 출력층 사이의 가중치와 바이어스값을 나타낸다.

역전파 알고리즘은 신경망을 통한 출력값과 목표출력값 사이의 오차를 감소시켜 신경망을 학습시키는 것으로, 전방향과 역방향 연산을 통하여 주어진 입력에 대해 미리 정해진 출력 값을 만들어 내도록 뉴런 사이의 연결가중치를 적절히 조절한다. 신경망 학습을 위한 오차함수는 평균제곱오차이고 식(6)에 나타내었다.

$$E = \frac{1}{2} \sum_k (t_k - o_k)^2 \quad (6)$$

3. 단순보의 손상추정

3.1 유한요소 모델

본 연구에서는 역전파 학습 알고리즘이 적용된 다층인공신경망을 이용하여 단순보 구조물을 대상으로 손상 평가를 수행하였다. 구조물은 등 간격으로 16개의 요소로 구성되어 있고 단면의 형상은 I형, 재료는 Steel을 사용하였다. 그림 3은 단순보의 치수와 단면형상을 나타내는 그림이다. 구조물의 3L/4위치에 0.01초 동안 가진 하역 L/4위치에서 Damage case별로 0.0007초의 sampling rate로 0.035초 동안 50개의 가속도 응답을 취

특하였다.




그림 3 단순보의 유한요소 모델

3.2 신경망 학습을 위한 손상시나리오

손상평가를 위한 신경망의 학습 자료를 얻기 위해 8개의 요소에 5%, 10%, 15%, 20%의 휨강성을 감소시키는 것으로 손상시나리오를 작성하였다. 학습된 신경망의 테스트 자료를 위한 손상시나리오는 요소 9와 요소 13의 휨 강성을 각각 17%, 7%를 저하시키는 것으로 모사하였다. 표 1은 본 연구에서 작성된 학습을 위한 손상시나리오를 나타내고 그림 4는 손상에 따른 요소 9의 가속도 응답을 나타낸다.

표 1 신경망 학습을 위한 손상시나리오

Damage case	Damaged Elements	$\Delta EI/EI$ (%)
Reference	-	0
1	1,3,5,7,9,11,13,15	5
2	1,3,5,7,9,11,13,15	10
3	1,3,5,7,9,11,13,15	15
4	1,3,5,7,9,11,13,15	20




그림 4 요소 9의 가속도 응답

3.3 신경망학습 검증 및 손상추정

단순보의 손상추정을 위한 신경망 학습 자료로 손상을 입지 않은 경우의 가속도 신호 (1set)와 요소 8개가 각각 5%, 10%, 15%, 20%의 손상을 입은 경우의 가속도 신호(32set)를 사용하였다. 신경망은 50개 뉴런의 입력층과 50개 뉴런의 은닉층, 16개 뉴런의 출력층으로 구성하였다. 신경망의 입력은 가속도 응답이고 출력은 각 요소에 해당하는 손상 추정 결과를 나타내도록 하였다. 요소의 손상이 없는 경우의 출력값은 1이 되고,

10%의 손상이 발생한 요소의 출력값은 0.9가 된다. 은닉층의 활성화함수는 sigmoid함수를 사용하였고, 출력층은 선형함수를 사용하였다. 신경망은 역전파 알고리즘을 이용하여 학습되었다.

학습이 끝난 신경망의 정확도를 검증하기 위해 학습에 사용된 자료를 재입력하여 출력을 얻었다. 표 2와 표 3은 학습에 사용된 자료 중 요소 1,5,9,13의 출력값을 나타낸 것이다. 학습이 이루어진 신경망의 손상 추정 자료인 표 2와 3의 출력값과 목표값을 비교하기 위해 식 (7)을 이용하여 손상 추정 오차를 구하였다.

$$\text{손상추정오차 } (\%) = \frac{|t - o|}{t} \times 100 \quad (7)$$

표 4는 학습된 자료의 손상 추정 오차를 나타내고 있다. 각 요소에서 발생한 손상의 추정 오차가 3번 요소의 5% 손상에 대한 추정오차 2.58%, 10% 손상에 대한 2.832%의 오차를 제외하고는 대부분 1% 이하의 좋은 결과를 보여주고 있다. 실제 구조물에 발생하는 손상은 매우 다양하기 때문에 모든 경우에 대한 손상을 학습하는 것은 사실상 불가능하다. 따라서 구조물의 손상을 대표할 수 있는 몇몇의 손상을 대상으로 신경망을 학습시키고, 학습이 끝난 신경망을 이용하여 다른 손상들을 추정해야 한다. 본 연구에서는 학습에 사용하지 않은 손상자료로 9번 요소에 17%, 13번 요소에 7%의 손상이 발생한 모델의 가속도 응답을 이용하였고 그에 대한 손상 추정 결과는 표 5에 나타내었다. 학습에 사용되지 않은 자료임에도 불구하고 학습 데이터의 결과와 거의 비슷한 1%이하의 오차를 가지는 우수한 예측결과를 보여주고 있다. 그림 5는 학습에 사용된 자료의 신경망 출력을 나타내고 그림 6은 9번 요소와 13번 요소가 각각 17%와 7%의 손상이 발생했을 때의 결과를 나타낸다. 이 결과로부터 신경망이 모든 경우의 손상을 학습하지 않더라도 대표적인 몇 가지의 손상의 학습만으로도 학습하지 않은 손상을 찾을 수 있다고 판단된다. 손상 추정 시 나타나는 오차를 줄이기 위해서는 손상 경우의 수를 증가시켜 신경망을 학습시켜야 한다고 생각되고 이 과정에서 학습에 소요되는 시간은 증가하지만 오차는 크게 줄일 수 있을 것이라 사료된다.

표 2 학습된 손상에 대한 신경망 출력 (요소 1-8)

Node Element		Node							
		1	2	3	4	5	6	7	8
1	0.95	0.9497	1.0000	0.9998	1.0000	0.9975	1.0000	0.9977	1.0000
	0.9	0.8988	1.0000	0.9994	1.0000	0.9967	1.0000	0.9970	1.0000
	0.85	0.8479	1.0000	0.9990	1.0000	0.9963	1.0000	0.9960	1.0000
	0.8	0.7973	1.0000	0.9990	1.0000	0.9980	1.0000	0.9967	1.0000
5	0.95	1.0002	1.0000	1.0002	1.0000	0.9479	1.0000	0.9979	1.0000
	0.9	0.9998	1.0000	1.0002	1.0000	0.8981	1.0000	0.9982	1.0000
	0.85	0.9997	1.0000	1.0004	1.0000	0.8482	1.0000	0.9984	1.0000
	0.8	0.9995	1.0000	1.0007	1.0000	0.7982	1.0000	0.9985	1.0000
9	0.95	0.9998	1.0000	1.0007	1.0000	1.0002	1.0000	0.9985	1.0000
	0.9	0.9986	1.0000	1.0001	1.0000	0.9999	1.0000	0.9979	1.0000
	0.85	0.9977	1.0000	0.9999	1.0000	0.9996	1.0000	0.9974	1.0000
	0.8	0.9972	1.0000	1.0002	1.0000	1.0001	1.0000	0.9972	1.0000
13	0.95	1.0001	1.0000	1.0003	1.0000	0.9987	1.0000	0.9980	1.0000
	0.9	0.9996	1.0000	1.0002	1.0000	0.9991	1.0000	0.9983	1.0000
	0.85	0.9993	1.0000	1.0001	1.0000	0.9995	1.0000	0.9988	1.0000
	0.8	0.9991	1.0000	1.0000	1.0000	1.0001	1.0000	0.9990	1.0000

표 3 학습된 손상에 대한 신경망 출력 (요소 9-16)



Element \ Node		Node								
		9	10	11	12	13	14	15	16	
1	0.95	1.0016	1.0000	1.0016	1.0000	1.0017	1.0000	0.9996	1.0000	
	0.9	1.0006	1.0000	1.0024	1.0000	1.0022	1.0000	0.9996	1.0000	
	0.85	0.9996	1.0000	1.0026	1.0000	1.0029	1.0000	1.0001	1.0000	
	0.8	0.9977	1.0000	1.0003	1.0000	1.0030	1.0000	1.0006	1.0000	
5	0.95	1.0025	1.0000	1.0011	1.0000	1.0016	1.0000	0.9991	1.0000	
	0.9	1.0015	1.0000	1.0017	1.0000	1.0014	1.0000	0.9990	1.0000	
	0.85	1.0010	1.0000	1.0023	1.0000	1.0012	1.0000	0.9991	1.0000	
	0.8	1.0010	1.0000	1.0029	1.0000	1.0012	1.0000	0.9994	1.0000	
9	0.95	0.9512	1.0000	0.9994	1.0000	0.9996	1.0000	0.9992	1.0000	
	0.9	0.8994	1.0000	1.0001	1.0000	0.9997	1.0000	0.9998	1.0000	
	0.85	0.8481	1.0000	1.0005	1.0000	0.9997	1.0000	1.0001	1.0000	
	0.8	0.7972	1.0000	1.0002	1.0000	0.9994	1.0000	1.0000	1.0000	
13	0.95	1.0023	1.0000	1.0007	1.0000	0.9508	1.0000	0.9993	1.0000	
	0.9	1.0012	1.0000	1.0009	1.0000	0.9002	1.0000	0.9997	1.0000	
	0.85	1.0005	1.0000	1.0007	1.0000	0.8499	1.0000	1.0001	1.0000	
	0.8	1.0004	1.0000	1.0005	1.0000	0.7993	1.0000	1.0005	1.0000	

표 4 손상 시나리오별 손상 추정 오차

Element \ Damage		Damage								
		1	3	5	7	9	11	13	15	
5%	출력값	0.949	0.925	0.948	0.949	0.951	0.952	0.951	0.949	
	오차 (%)	0.032	2.58	0.224	0.156	0.128	0.164	0.081	0.047	
10%	출력값	0.899	0.925	0.898	0.898	0.899	0.902	0.900	0.899	
	오차 (%)	0.13	2.832	0.210	0.138	0.064	0.265	0.024	0.023	
15%	출력값	0.848	0.850	0.848	0.848	0.848	0.853	0.850	0.850	
	오차 (%)	0.242	0.039	0.211	0.179	0.225	0.389	0.017	0.018	
20%	출력값	0.797	0.800	0.798	0.798	0.797	0.804	0.799	0.800	
	오차 (%)	0.337	0.017	0.230	0.253	0.351	0.522	0.086	0.026	

표 5 요소 9와 요소 13의 손상 추정 결과



Element \ Node		Node							
		1	2	3	4	5	6	7	8
요소 9 17% 손상	Node	1	2	3	4	5	6	7	8
	출력값	1.002	1.000	1.002	1.000	0.993	1.000	1.014	1.000
	오차 (%)	0.232	0.001	0.1999	0.001	0.707	0.001	1.3796	0.001
	Node	9	10	11	12	13	14	15	16
출력값	0.8277	1.000	0.9958	1.000	1.011	1.000	0.999	1.000	
오차 (%)	0.277	0.001	0.4185	0.001	1.121	0.001	0.082	0.001	
요소 13 7% 손상	Node	1	2	3	4	5	6	7	8
	출력값	1.001	1.000	1.002	1.000	1.002	1.000	1.001	1.000
	오차 (%)	0.064	0.001	0.158	0.001	0.197	0.001	0.097	0.001
	Node	9	10	11	12	13	14	15	16
출력값	0.999	1.000	0.999	1.000	0.9301	1.000	1.000	1.000	
오차 (%)	0.0788	0.001	0.044	0.001	0.0093	0.001	0.008	0.001	



(a) 요소 1의 5% 손상

(b) 요소 5의 15% 손상

그림 5 학습된 손상의 신경망 출력



(a) 요소 9의 17% 손상

(b) 요소 13의 7% 손상

그림 6 신경망을 이용한 손상 추정 결과

4. 결론

본 연구에서는 역전파 알고리즘을 적용한 다층 인공신경망을 이용하여 단순보 구조물의 손상 추정에 대한 수치실험을 수행하였다. 손상 시나리오에 의한 모의실험을 통해 얻은 가속도 응답 신호를 이용하여 신경망을 학습시킨 후 학습에 사용한 자료와 사용되지 않은 자료를 이용하여 적용된 알고리즘의 정확도를 검증하였다.

학습에 사용된 자료를 이용하여 신경망을 테스트 하였을 때 3번 요소의 5%와 10%의 손상의 경우를 제외하고는 오차 1% 이하의 우수한 결과를 얻었고, 학습하지 않은 자료를 이용한 손상 추정도 학습된 자료를 이용했을 때와 거의 비슷한 결과를 얻을 수 있었다.

신경망을 이용한 구조물의 손상 추정의 정확도를 높이려면 구조물의 모델링을 정확히 해야 하고 구조물의 거동에 민감하게 반응하는 동적응답을 신경망의 학습 자료로 이용해야 한다고 생각된다. 구조물 손상 경우의 수를 증가시켜 신경망을 학습하게 되면 학습과정에 소요되는 시간은 증가할

것이지만 목표값과 신경망의 출력값 사이의 오차를 줄일 수 있어 신경망이 가지는 정확도를 높이는 데 크게 기여할 것이라 사료된다.

감사의 글

이 연구는 2005년도 한국과학재단 지정 스마트사회기반연구센터의 지원에 의해 수행되었습니다.

참고 문헌

1. Lee, J.J. Lee, J.W. Yi, J.H. Yun, C.B. Jung, H.Y. "Neural networks-based damage detection for bridges considering errors in baseline finite element models", Journal of sound and vibration, Vol. 280 No. 3, pp.555-578, 2005
2. J.T. Kim, Y.S. Ryu, H.M. Cho, Norris Stubbs(2003), "Damage identification in beam-type structures: frequency-based method vs mode-shape-based method", Engineering Structure 25, pp. 57-67
3. P.C Pandey, S. V. Brai. "Multilayer Perceptron in Damage Detection of Bridge Structures", Computers & Structures, Vol. 54, No 4, pp. 597-608. 1995
4. X. Wu, J. Ghanoussi, J. H. Garret, "Use of Neural Networks in Detection of Structural Damage". Computers & Structures, Vol. 42, No. 4, pp. 649-659, 1992
5. Masri. S. F, M. Nakamura, A. G. Chassiako, and T. K. Caughey, "Neural Network Approach to Detection of Change in Structural Parameters", Journal of Engineering Mechanics, Vol. 122, No. 4, pp. 350-360, 1996
6. P. Tsou, M. H. Herman Shen, "Structural Damage Detection and Identification Using Neural Networks", AIAA Journal, Vol. 32, No. 1, pp. 176-183, 1994
7. 정환진, 김주태, 오주원, 이인원, "신경망을 이용한 구조물의 손상평가", 대한토목학회논문집, Vol. 17, No. 0, pp. 617-626
8. 배상현, 정현철, "Neural Networks와 유전자 알고리즘". 조선대학교 출판부, 2004
9. 박재형, 김정태, 류연선, "고유진동수 시간이력을 이용한 보 구조물 손상 모니터링 기법", 한국전산구조공학회 춘계 학술대회, pp.41-56, 2004