

공학석사 학위논문

가속도-모드현상 기반 신경망을 이용한  
손상검색기법에 관한 연구

이 논문을 공학석사 학위논문으로 제출함.



2006년 2월

부경대학교 대학원

해양공학과

이 용 환

# 이용환의 공학석사 학위논문을 인준함

2005년 12월 22일

주 심 공학박사 류 연 선



위 원 공학박사 나 원 배



위 원 공학박사 김 정 태



# 목 차

List of Figures .....	iii
List of Tables .....	v
List of Symbols .....	vi
ABSTRACT .....	vii
1. 서론 .....	1
1.1 연구배경 및 필요성 .....	1
1.2 연구목적 및 내용 .....	2
2. 인공신경망 이론 .....	4
2.1 인공신경망 모델 .....	4
2.2 오차 역전파 학습 알고리즘 .....	5
3. 신경망을 이용한 손상검색 기법 .....	12
3.1 가속도 기반 인공신경망 알고리즘 .....	12
3.2 모드형상 기반 인공신경망 알고리즘 .....	14
3.3 가속도-모드형상 기반 신경망 알고리즘을 이용한 손상검색기법 .....	15
4. 손상검색 기법의 수치 검증 .....	16
4.1 대상 모델 .....	16
4.2 신경망 학습 .....	16
4.2.1 신경망 학습을 위한 손상시나리오 .....	16
4.2.2 가속도 기반 신경망 학습 .....	18
4.2.3 모드형상 기반 신경망 학습 .....	21

4.3 신경망을 이용한 손상검색 .....	22
4.3.1 가속도 기반 신경망을 이용한 손상검색 .....	23
4.3.2 모드형상 기반 신경망을 이용한 손상검색 .....	30
5. 손상검색 기법의 실험 검증 .....	33
5.1 실험구조물 .....	33
5.2 신경망 학습 .....	35
5.2.1 신경망 학습을 위한 손상 시나리오 .....	35
5.2.2 가속도 기반 신경망 학습 .....	36
5.2.3 모드형상 기반 신경망 학습 .....	39
5.3 신경망을 이용한 손상 검색 .....	41
5.3.1 가속도 신호기반 신경망을 이용한 손상검색 .....	41
5.3.2 모드형상 기반 신경망을 이용한 손상검색 .....	47
5.3.3 손상검색 정확도 .....	49
6. 요약 및 결론 .....	52
참고문헌 .....	54

## List of Figures

- Fig. 2.1 Unit of Neural Networks
- Fig. 2.2 Back-Propagation Multi Layer Perceptron
- Fig. 2.3 Activation function
- Fig. 3.1 Acceleration based Neural Network Algorithm
- Fig. 3.2 Mode Shape based Neural Network Algorithm
- Fig. 3.3 Damage Detection Method using Acceleration-Mode Shape based Neural Networks
- Fig. 4.1 Geometry of Numerical Model
- Fig. 4.2 Finite Element Model for Target Structure
- Fig. 4.3 Excitation System and Sensor System
- Fig. 4.4 Impulse Excitation Configuration
- Fig. 4.5 Acceleration-0.125L
- Fig. 4.6 Acceleration-0.25L
- Fig. 4.7 Cross Correlation Result of Two Signal
- Fig. 4.8 Acceleration based Neural Networks
- Fig. 4.9 Finite Element Model for Acquisition Eigen Vector
- Fig. 4.10 Eigen Vector of Undamage Finite Model
- Fig. 4.11 Mode Shape based Neural Networks
- Fig. 4.12 Pulse Loading Scenario for Damage Detection
- Fig. 4.13 Damage Detection Result from Test Pattern using Triangular Pulse
- Fig. 4.14 Damage Detection Result from Test Pattern using Right Triangular Pulse
- Fig. 4.15 Damage Detection Result from Test Pattern using Rectangular Pulse Case- I
- Fig. 4.16 Damage Detection Result from Test Pattern using Rectangular Pulse Case- II
- Fig. 4.17 Damage Detection Result from Test Pattern using Triangular Pulse
- Fig. 4.18 Damage Index of Single Damage using Result of Four Pulse Shape Excitations
- Fig. 4.19 Damage Index of Single Damage using Result of Four Triangular Excitations
- Fig. 4.20 Triangular Pulse for Damage Detection of Multi Damage Scenario

Fig. 4.21 Damage Detection Result from Test Pattern using Triangular Pulse  
Fig. 4.22 Damage Index of Multi Damage using Result of Four Triangular  
Excitations  
Fig. 4.23 Damage Detection Result of Single Damage  
Fig. 4.24 Damage Detection Result of Multi Damage  
Fig. 5.1 Free-Free Beam Structure  
Fig. 5.2 Experiment set up and Damage  
Fig. 5.3 Experiment equipment and acceleration signal  
Fig. 5.4 Finite Element Model of Free-Free Beam  
Fig. 5.5 Excitation System and Sensor System  
Fig. 5.6 Excitation Scenario  
Fig. 5.7 Acceleration-0.3214L  
Fig. 5.8 Acceleration-0.5L  
Fig. 5.9 Cross Correlation Result of Two Signals  
Fig. 5.10 A Process of Acceleration based Neural Networks Training  
Fig. 5.11 Finite Element Model for Acquisition Eigen Vector  
Fig. 5.12 Eigen Vector for Neural Networks Training  
Fig. 5.13 A Process of Mode Shape based Neural Networks Training  
Fig. 5.14 Damage Detection Result of Damage Case - I  
Fig. 5.15 Damage Index of Damage Case - I  
Fig. 5.16 Damage Detection Result of Damage Case - II  
Fig. 5.17 Damage Index of Damage Case - II  
Fig. 5.18 Damage Detection Result of Damage Case - III  
Fig. 5.19 Damage Index of Damage Case - III  
Fig. 5.20 Damage Detection Result of Damage Case - IV  
Fig. 5.21 Damage Index of Damage Case - IV  
Fig. 5.22 Damage Detection Result of Damage Case-I  
Fig. 5.23 Damage Detection Result of Damage Case-II  
Fig. 5.24 Damage Detection Result of Damage Case-III  
Fig. 5.25 Damage Detection Result of Damage Case-IV

## List of Tables

- Table 4.1 Single Damage Scenario for Training Neural Networks
- Table 4.2 Multi Damage Scenario for Training Neural Networks
- Table 4.3 Impulse Excitation Conditions for Acceleration based Neural Networks  
Training
- Table 4.4 Damage Scenario
- Table 4.5 Damage Detection Result of Single Damage
- Table 4.6 Damage Detection Result of Multi Damage
- Table 5.1 Property of free-free beam
- Table 5.2 Damage Scenario
- Table 5.3 Single Damage Scenario for Training Neural Networks
- Table 5.4 Multi Damage Scenario for Training Neural Networks
- Table 5.5 Impulse Excitation Conditions for Acceleration based Neural Networks  
Training
- Table 5.6 Accuracy of Damage Detection using Acceleration based Neural Networks
- Table 5.7 Accuracy of Damage Location Detection using Mode Shape based Neural  
Networks
- Table 5.8 Result of Damage Extent Assessment using Mode Shape based Neural  
Networks

## List of Symbols

$f$	transformation function
$i,j,k$	coefficient of layers of neural networks
$net_j$	input of $j$ layers
$net_k$	input of $k$ layers
$o_i$	output from $i$ layer
$o_j$	output from $j$ layer
$o_k$	output from $k$ layer
$t_k$	target
$w_{ij}$	weight $i$ layer from $j$ layer
$\alpha$	momentum
$Z_i$	damage index
$P$	ratio of cross-correlation between before and after damage
$R_{xy}$	cross correlation values of two functions
$R_{xy}^d$	cross correlation values of two accelerations in damage state
$R_{xy}^u$	cross correlation values of in two accelerations undamage state

# A Study on Damage Detection Method using Acceleration-Mode Shape based Neural Networks

Yong-Hwan Lee

*Department of Ocean Engineering, Graduate School.  
Pukyong National University*

## ABSTRACT

Structure health monitoring (SHM) has become an important research topic in order to secure the safety of infra-structures. Recently, artificial neural network (ANN) have been increasingly utilized for SHM due to the advantage that it needs only a few training data to detect damage in structures. The purpose of this study is to develop a ANN-based damage detection algorithm using acceleration and mode shape as the inputs. The following approaches are used to achieve the research goal. Firstly, an ANN algorithm using acceleration data is newly designed to detect the occurrence of damage in real time. The cross-correlation values of acceleration responses are acquired as the features representing the state of the structure. Also, it is trained for several loading patterns, loading durations, and damage locations in the structure for which its loading levels are not measured. Secondly, another ANN algorithm using mode shape data are designed to locate and estimate severity of damage. It is trained for several damage locations and severities using eigenvalue analyses.

The feasibility and the practicality of the proposed damage detection method are evaluated from both numerical tests on simply supported beams and laboratory experiments on free-free beams for which a series of acceleration responses were measured and a few mode shapes were identified. It is shown that the proposed method could alarm the occurrence, the location, and the severity of damage in the test structures.

# 1. 서론

## 1.1 연구 배경 및 필요성

교량이나 고층건물 같은 대형 구조물들은 그 생애주기 동안에 지진, 바람, 교통하중, 풍하중 등의 다양한 외부하중에 노출되어 있다. 시간이 경과함에 따라 이런 구조물들은 초기 설계 시 고려되지 않았던 각종 요인들에 의해 구조물의 손상이 발생하게 되고, 발견되지 못한 손상은 지속적인 손상의 진전에 의하여 결국 구조물의 붕괴로 이어지게 된다. 90년대에 발생한 삼풍백화점 붕괴사고, 성수대교 붕괴사고 등에서 볼 수 있는 바와 같이 대형구조물의 붕괴는 곧바로 막대한 인적 피해와 경제적 손실을 초래하게 된다. 따라서 구조물의 상태를 정확히 진단하고 구조물에 발생한 손상을 초기에 파악하여 그에 적절한 보수·보강 등을 수행함으로써 구조 상태를 안전하게 유지하기 위한 필요성이 대두되었다. 이에 따라 신뢰성 있는 구조건전성 모니터링 체계의 구축에 대한 연구가 현재까지 활발히 이루어지고 있다.

구조건전성 모니터링 체계는 크게 두 가지 기법으로 분류할 수 있다. 첫 번째는 구조물의 응답 자료만 이용하는 신호기반 모니터링 기법이고 두 번째는 대상 구조물 해석 모델의 개선을 통한 모델기반 모니터링 기법이다. 이 모니터링 기법들은 주로 통계적 특징을 분석하거나 민감도법을 이용하여 구조물의 건전성을 평가하였다[윤정방 등, 2004]. 그러나 최근 들어 인공지능망, 유전자 알고리즘 같은 소프트 컴퓨팅 기법이 많이 적용되고 있다[이종재 등, 2002]. 특히 인공지능망 기법은 뛰어난 패턴인식 성능과 다양한 입력 자료를 사용할 수 있는 장점 등으로 인해 손상 추정 문제에 있어 활발히 연구되고 있다. 인공지능망은 구조물의 여러 손상 상태에 대한 구조물의 응답을 여러 패턴으로 구성한 후 이 패턴집합을 사용하여 미리 손상에 대한 학습을 하게 된다. 신경망 학습 시 손상의 위치와 정도에 관한 학습 자료에 대해 몇 개의 특정 자료만을 학습에 이용하더라도 학습되지 않은 손상에 대해서도 뛰어난 평가기능을 발휘한다. 이 뿐만 아니라 학습된 신경망을 이용할 경우 아주 짧은 시각에 손상 추정이 이루어질 수 있으므로 구조물의 실시간 모니터링에 큰 장점을 가지게 된다.

신경망을 이용한 구조 건전성 모니터링에 관한 연구는 Adeli와 Yeh (1989)에 의해 처음으로 토목공학에 인공지능망이 적용된 이후 활발히 이루어졌다. Maity와 Saha는 변위 자료를 신경망 학습 자료로 하여 캔틸레버 보의 손상을 추정하였다.[Maity and Saha, 1994]. Pandey와 Barai 또한 변위차료를 이용한 신경망으로부터 트러스교의 손상평가를 수행하였으며, 역전파 알고리즘을 학습알고리즘을

하는 다층퍼셉트론이 공학분야에서 가장 적용성이 높다고 제시하였다[Pandey and Barai, 1995]. 기존의 연구에서 사용된 변위자료는 교량을 통제하고 이동하중을 재하하거나 정적 재하시험 등을 통해서 추출되어야 한다. 하지만 실시간 구조 건전성 모니터링을 위해서 실시간 구조응답 신호를 입력으로 한 신경망 기법을 이용한 손상평가 체계의 개발이 필요하다. 이를 위해 상시진동 데이터로부터 추출된 구조물의 모드형상을 신경망 입력으로 이용하고자 하는 연구가 이종재 등에 의해 수행되었다[이종재 등, 2002]. 이들은 모델링 오차를 줄이기 위하여 모드형상 보다는 손상 전후의 모드형상 비를 신경망 입력 자료로 활용할 것을 제안하였다. 또 실시간 가속도 데이터를 신경망 입력으로 이용하는 시도가 이인원 등에 의해서 수행된 바 있다.[이인원 등, 1999] 이들의 연구는 구조물의 한 점에서 이동하중에 의해 발생하는 가속도 신호를 신경망 입력으로 이용하는 방법을 제시하였으며 이를 수치 시뮬레이션을 통해 적용성을 검증하였다.

이상과 같은 기존의 연구가 실시간 구조건전성 모니터링에 적용되기 위해서는 다음과 같은 문제점이 있을 수 있다. 첫째, 모드형상을 신경망 입력으로 이용하는 경우, 구조물의 손상 추정에는 좋은 결과를 보이고 있으나 모드형상 추출을 위해 모드해석과정이 필수적으로 수반되어야 한다. 하지만 모드형상을 추출하기 위해서는 많은 수의 센서를 필요로 하고, 실제 구조물의 모드형상 추출을 위해서는 전문가의 식별이 필요하다. 따라서 이와 같은 경우 실시간 구조건전성 모니터링에는 적합하지 못하다. 둘째, 가속도 신호를 이용할 경우 특별한 신호처리 과정이 없기 때문에 실시간 건전성 모니터링에 유리하나 절대적인 가속도 값을 이용할 경우 가속도의 레벨이 하중에 따라 크게 변동되기 때문에 특정 하중 하에서 학습된 신경망으로 건전성을 평가하는 것은 어렵다. 뿐만 아니라 계측 신호의 노이즈, 수치모델과 실제 구조물간의 모델링오차 등의 문제가 존재할 수 있다.

따라서 실시간 구조건전성 모니터링을 위하여 절대적인 신호응답이 아닌 상대적인 응답치를 신경망에 학습시켜 외력에 대한 구조응답의 레벨차이를 극복하게 할 필요가 있으며, 모델링 오차와 노이즈 등으로 인하여 정확한 손상도 평가가 힘들기 때문에 모드형상을 이용한 상세한 손상평가가 수행되는 건전성 모니터링 기법의 도입 또한 고려되어야 한다.

## 1.2 연구 목적 및 내용

본 연구의 목적은 실시간 구조건전성 모니터링 구현을 위한 가속도-모드형상 기반 신경망을 이용한 손상검색 기법을 개발하는 것이다. 즉 실시간 손상 검색을 위해 가속도 기반 신경망을 이용한 손상검색을 수행하고, 보다 정확한 손상 위치와 정도를 평가하기 위하여 모드형상 기반 신경망을 이용한 손상검색을 수행하

는 기법을 제안하였다.

위와 같은 연구 목적을 달성하기 위해 다음과 같은 연구가 수행되었다. 첫째, 손상평가 체계의 기반이 되는 인공신경망의 이론과 본 연구에서 적용된 오차역전파 학습알고리즘에 관하여 정리되었다. 둘째, 가속도-모드형상 기반 신경망 알고리즘을 이용한 손상검색기법이 정리되었다. 이 체계는 크게 두 단계로 구성되었다. 첫 번째 단계는 가속도 기반 신경망 알고리즘을 이용한 실시간 손상경보 단계이고, 두 번째 단계는 모드형상 기반 신경망 알고리즘을 이용한 정확한 손상 위치 및 손상 정도의 식별 단계이다. 특히, 가속도 기반 신경망 알고리즘을 이용한 손상검색 단계에서는 가진력의 불확실성을 고려하여 상호상관함수와 통계적 가설검증 기법을 이용하였다. 마지막으로, 제안된 가속도-모드형상 기반 손상검색 기법의 적합성과 실제 적용성이 검증되었다. 단순보 수치모델을 사용하여 적합성을 검증하였으며, 양단 자유보 축소모형에 대한 실험을 통해 실제 적용성을 검토하였다.

## 2. 인공신경망 이론

### 2.1 인공신경망 모델

인간의 뇌는 대량의 복잡한 정보를 효율적으로 병렬 처리할 수 있을 뿐만 아니라 학습능력을 가지고 있다. 인공신경망은 인간의 대뇌 신경세포의 구조특성을 모방하여 인간의 두뇌특성을 갖도록 만든 수학적 모델로서 음성식별, 문자식별, 목표인식, 화상식별, 지능제어 등 여러 영역에서 성공적으로 응용되고 있다. 생물학적 신경조직의 기본요소는 신경세포(Neuron) 이고 이것은 세포체로 이루어진 중심부와 축색돌기, 수상돌기로 이루어진 신경섬유로 되어 있다. 신경세포는 수상돌기가 인접세포로부터 신호를 받아들이고 축색돌기가 신호를 내보내는 작용을 함으로써 신호를 한 방향으로 전달하는데, 이들의 연결 부위를 시냅스(Synapse)라고 한다. 각 신경세포는 이렇게 보내진 신호를 입력으로 하여 신호들의 합이 적당한 수준의 임계값을 초과할 때만 출력을 생성하는 임계치치리로 볼 수 있다. 이와 같은 신경세포의 생물학적인 특성을 기반으로 하여 신경망 모델을 구현할 수 있다.

인공신경망 모델은 1943년 McCulloch와 Pitts가 최초의 수학적 모델을 제시한 이후, 퍼셉트론(Perceptron), 다층퍼셉트론(Multi-Layer Perceptron), 홉필드 네트워크, 코호넨 네트워크, ART 네트워크 등 다양한 신경망 모델이 개발되었으며 현재에는 오차 역전파 알고리즘을 학습알고리즘으로 채택하는 인공신경망이 여러 분야에서 가장 많이 이용되고 있고 본 연구에서도 오차 역전파 신경망 알고리즘을 이용하였다. 인공신경망에서는 Fig. 2.1과 같이 신경세포의 역할을 하나의 유닛이 수행하며, 시냅스는 각 단위처리기를 연결하여 주는 가중치(Weight)로 표현한다. 인공신경망은 정보가 들어오는 입력층(Input-Layer), 입력과 가중치를 결합하여 활성화함수에 의해 새로운 output이 생성되는 은닉층(Hidden-Layer), 은닉층으로부터 나온 결과를 출력 값으로 결정하게 하는 출력층(Output-Layer)으로 구성된다. 이러한 인공신경망은 학습단계와 사용단계의 두 가지 단계로 동작한다. 학습단계에서는 입력패턴과 목적패턴이 다수의 입·출력 쌍으로 주어지고, 이 입·출력 쌍의 관계를 잘 표현해 주도록 가중치의 크기를 수정한다. 이러한 작업은 각 입력패턴에 대해 출력을 먼저 계산한 후, 기대되는 출력과 실제 출력의 차이를 줄이는 방향으로 가중치를 조절함으로써 수행된다. 조절과정이 끝나면 새로운 입·출력 쌍이 주어지고 같은 과정으로 학습이 반복된다. 사용단계에서는 학습단계에서 형성된 입·출력 쌍의 상관관계에 의해 새로운 입력에 대해 적절한 결과를 출력하게 된다.

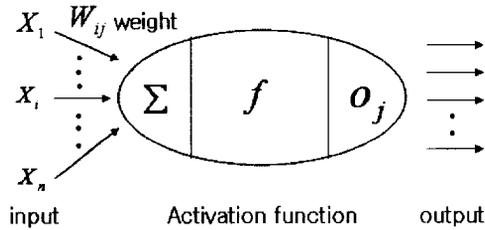


Fig. 2.1 Unit of Neural Networks

## 2.2 오차 역전파 학습 알고리즘

오차 역전파 학습 알고리즘 (Back Propagation Learning Algorithm)은 목표 값과 출력 값의 차이(Delta  $\Delta$ )를 이용하여 학습을 하는 델타법칙에 역전파 방법이 추가된 일반화된 델타법칙이라고 한다. Fig. 2.2는 오차 역전파 학습 알고리즘의 모식도이다. 이 학습 알고리즘은 진행방향에 따라 전방향 연산과 역방향 연산으로 구분할 수 있다.

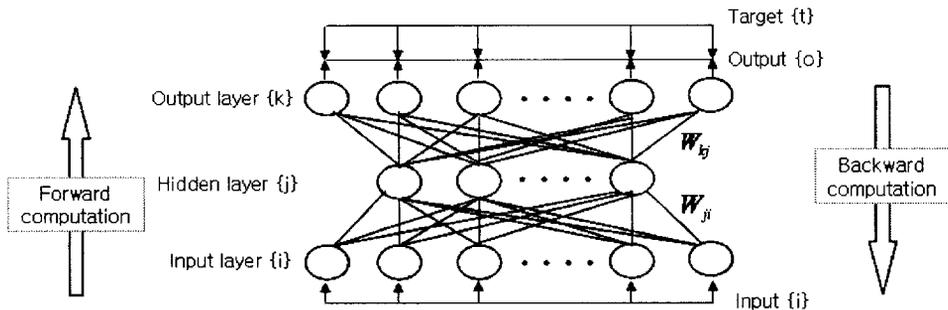


Fig. 2.2 Back-Propagation Multi Layer Perceptron

오차 역전파 학습 알고리즘에서는 가중치공간에서 오차를 점진적으로 탐색해 나가는 점진적인 기울기 감소 (Gradient Descending Search) 방법을 사용한다. 즉 델타규칙에 의해 가중치의 변화는 가중치 공간상에 주어지는 오차의 제곱의 높이에 대한 곡면에 대하여 기울기가 감소하게 되며, 이 오차의 제곱을 최소화하는 방향으로 변화하게 되는 것이다. 이는 입력층에서 출력층으로의 전방향으로 진행하며 주어진 입력 데이터에 대한 실제 출력 값을 계산하고, 이에 대응하는 목표 출력 값과의 오차를 하위 층에 역방향으로 전달하면서 일률적으로 가중치를 조정해 나가는 과정을 적용함으로써 신경망 전체를 학습시키는 알고리즘이다. 가중치 조정 후 다시 입력하여 계산하면 처음 시도 때보다 오차가 작아지고 모

든 오차의 합이 정해진 오차한계에 도달할 때까지 계속 반복 수행하게 된다.

Fig. 2.3에 나타내어진 바와 같이 신경망의 맨 아래층을 입력층, 맨 위층을 출력층 그리고 가운데에 위치한 중간층을 은닉층이라 하고 각 층들은 유니트들로 구성되어 있다. 입력층의 한 유니트는 입력벡터의 각 원소와 대응하고 출력층으로부터의 출력 값은 활성화함수의 출력과 같다. 즉, 오차 역전파 알고리즘에서의 각 유니트는 자신의 바로 위층의 모든 유니트와 연결되어 있고, 각 연결은 그것과 관계된 무한의 양 또는 음의 가중치를 갖고 있기 때문에 신경망의 출력 값은 입력과 가중치의 함수라 할 수 있다.

신경망 학습은 일반적으로 다음과 같은 과정을 거치게 된다. Fig. 2.3의 전방향 진행에서는 먼저 입력층(i)에 하나의 입력 패턴이 주어지면, 은닉층(j)에 있는 유니트로 들어가는 입력값  $net_j$ 는 입력층의 모든 유니트의 입력값들의 가중합으로 식 2.1과 같이 계산된다.

$$net_j = \sum_{i=0}^m w_{ji} o_i \quad (2.1)$$

여기서  $w_{ji}$ 는 j층과 i층을 연결하는 가중치이다.

$o_i$ 는 i층에 있는 단위처리기에서 나오는 출력을 나타내며,  $net_j$ 는 전달함수를 거친 후 식 2.2 와 같이 계산되어 j층 유니트의 출력  $o_j$ 가 된다.

$$o_j = f(net_j) = \frac{1}{1 + e^{-(net_j)}} \quad (2.2)$$

전달함수는 계단함수(step function), 임계논리함수(threshold logic function), 시그모이드함수(sigmoid function), hyperbolic tangent 함수 등이 있으며 Fig. 2.4에 나타내었다. 본 연구에서는 시그모이드 함수를 사용하였다. 그 이유는 시그모이드함수가 역치함수와 선형함수의 특징을 모두 가지고 있는 비선형함수이며, 가중치를 구하는데 필요한 미분이 간단하여 은닉층을 학습할 수 있는 역전파 학습알고리즘을 수행하는 데 용이하다.

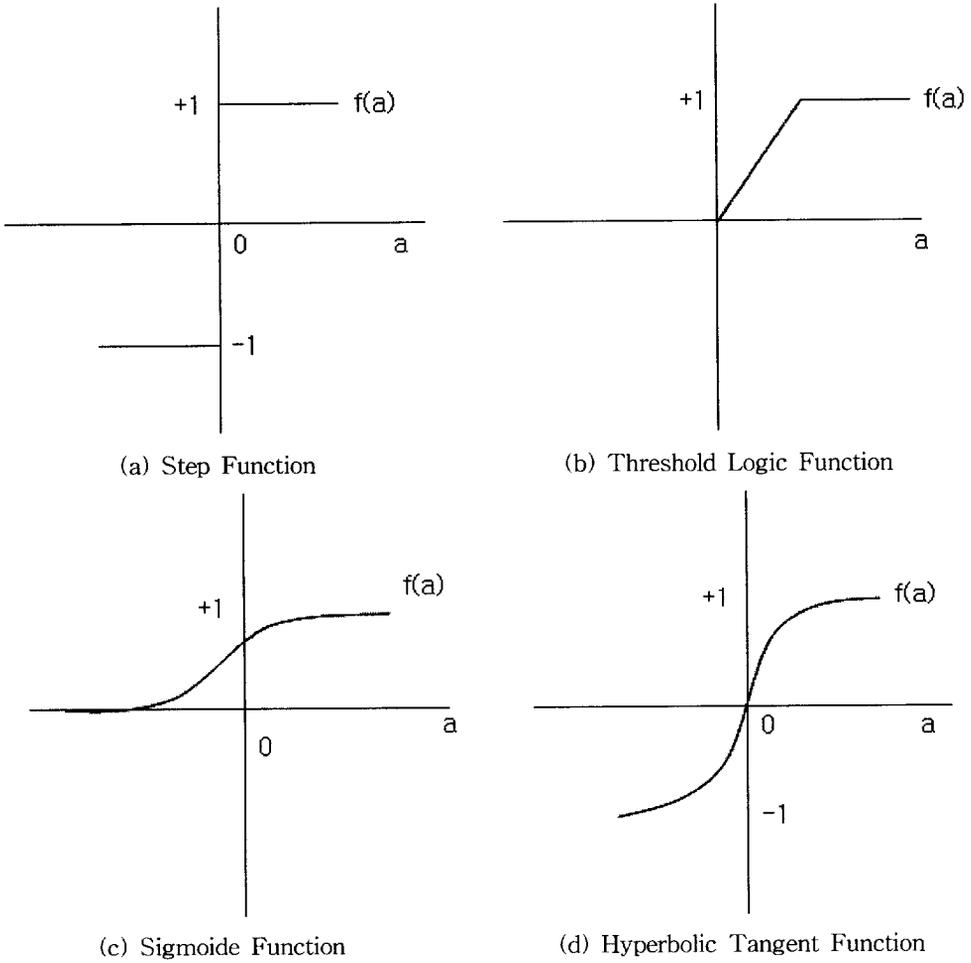


Fig. 2.3 Activation Function

$o_j$ 는 다시 식 2.3 과 같이 출력층(k)으로 입력되고, 전달 함수 f에 의해 식 2.4 와 같이 계산되어 k층 유니트의 출력  $o_k$ 가 된다.

$$net_k = \sum_j w_{kj} o_j \quad (2.3)$$

$$o_k = f(net_k) = \frac{1}{1 + e^{-net_k}} \quad (2.4)$$

일반적으로 신경망의 출력패턴  $o_k$ 는 초기에 입력패턴과 쌍으로 주어지는 목적패턴  $t_k$ 와 일치하지 않으므로 하나의 패턴에 대한 패턴 오차 (Pattern Error)  $\epsilon_p$ 를

식 2.5 와 같이 정의하고  $\varepsilon_p$ 가 정해지면  $\varepsilon_p$ 를 최소화 하는 방향으로 가중치와 임계값을 조정한다. 이러한 가중치의 조정과정이 끝나면 또 다른 입-출력쌍이 주어지며 같은 방법으로 가중치를 재조정한다. 이때 전체 패턴에 대한 오차  $\varepsilon_t$ 는  $\varepsilon_p$ 를 모두 합하여 구하며 학습에 사용된 패턴수를 P라 할 때 식 2.6 과 같이 구해진다.

$$\varepsilon_p = \frac{1}{2} \sum_k (t_k - o_k)^2 \quad (2.5)$$

$$\varepsilon_p = \sum_p \varepsilon_p = \frac{1}{2} \sum_p \sum_k (t_k - o_k)^2 \quad (2.6)$$

역방향 연산은 최종 출력층에서 계산된 패턴 오차를 역방향으로 입력층까지 전파하여 가중치를 수정함으로써 오차를 최소화 하는 과정을 의미한다.

가중치의 변화량을  $\Delta w_{kj}$ 라고 하면, 가중치의 변화는 다음 식 2.7 과 같이 가중치에 대한 오차의 변화율에 비례하는 증가 변위를 취함으로써 얻을 수 있다.

$$\Delta w_{kj} \propto - \frac{\partial \varepsilon}{\partial w_{kj}} \quad (2.7)$$

여기서, 가중치 항의 지수 k는 출력층을, j는 은닉층을 나타낸다. 식 2.7 의 우변 항은 미분의 반복법칙에 의해 다음과 같이 나타낼 수 있다.

$$- \frac{\partial \varepsilon}{\partial w_{kj}} = - \frac{\partial \varepsilon}{\partial net_k} \frac{\partial net_k}{\partial w_{kj}} \quad (2.8)$$

여기에서,  $-\frac{\partial \varepsilon}{\partial net_k}$ 를 오차지표  $\delta_k$ 로 정의하면, 식 2.8 의 우변 항들은 각각 식 2.9, 2.10 으로 나타내어진다.

$$\begin{aligned} \delta_k &= - \frac{\partial \varepsilon}{\partial net_k} = - \frac{\partial \varepsilon}{\partial o_k} \frac{\partial o_k}{\partial net_k} \\ &= - \frac{\partial}{\partial o_k} \left[ \frac{1}{2} \sum_k (t_k - o_k)^2 \right] \frac{\partial o_k}{\partial net_k} \\ &= (t_k - o_k) \frac{\partial o_k}{\partial net_k} \end{aligned} \quad (2.9)$$

$$= (t_k - o_k) f'(net_k)$$

$$\frac{\partial net_k}{\partial w_{kj}} = \frac{\partial}{\partial w_{kj}} \left( \sum_j w_{kj} o_j \right) \quad (2.10)$$

식 2.8, 2.9, 2.10 으로부터 출력층에서의 가중치 변화량  $\Delta w_{kj}$ 는 다음 식 2.11 과 같이 나타낼 수 있다. 출력층에서  $\varepsilon$ 를 줄이는 방향으로 학습을 하기 위해서 식 2.11 을 이용하여 가중치를 변하시키게 된다.

$$\begin{aligned} \Delta w_{kj} &= \eta \frac{\partial \varepsilon_p}{\partial w_{kj}} = \eta \delta_k o_j \\ &= \eta (t_k - o_k) f'(net_k) o_j \end{aligned} \quad (2.11)$$

여기서  $\eta$ 는 학습율(Learning Rate)이다. 학습율  $\eta$ 는 신경망의 학습능력을 결정하는 상수로 학습의 빠르기에 관계된다. 학습율이 작을수록 학습이 성공적으로 이루어질 확률은 높아지지만 이 경우 학습이 수렴하기까지 상당한 시간이 소요되며, 반면에 값이 클수록 학습은 빨라지지만 정확한 신경망 학습이 어려울 가능성이 크다. 학습율은 대부분 네트워크의 복잡도에 따라 시행착오를 거쳐 결정하며 일반적으로 0과 1사이의 값을 갖는다.

은닉층 가중치의 미소변화량도 출력층의 가중치의 조정과 같은 과정으로 전개된다. 은닉층에서의 가중치 미소변화량은  $j$ 를 은닉층의 지수,  $i$ 를 입력층의 지수라고 하면 다음 식 2.12 와 같이 표현된다.

$$-\frac{\partial \varepsilon_k}{\partial w_{ji}} = -\frac{\partial \varepsilon}{\partial net_j} \frac{\partial net_j}{\partial w_{ji}} \quad (2.12)$$

여기서,  $-\frac{\partial \varepsilon}{\partial net_j}$ 를 오차지표  $\delta_j$ 로 정의하면 식 2.12 의 우변 항들은 각각 식 2.13, 2.14로 나타내어진다.

$$\begin{aligned}\delta_j &= -\frac{\partial \varepsilon}{\partial net_j} = -\frac{\partial \varepsilon}{\partial o_i} \frac{\partial o_i}{\partial net_j} \\ &= \frac{\partial \varepsilon}{\partial o_j} f'(net_j)\end{aligned}\tag{2.13}$$

$$\frac{\partial net_j}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \left( \sum_i w_{ji} o_i \right) = o_i\tag{2.14}$$

식 2.13의  $\varepsilon$ 은 식 2.5에서 나타난 바와 같이  $\varepsilon_p = \frac{1}{2} \sum_k (t_k - o_k)^2$  로 주어져

$-\frac{\partial \varepsilon}{\partial o_j}$  를 쉽게 구할 수 없으므로 다음과 같이 나타낸다.

$$\begin{aligned}-\frac{\partial \varepsilon}{\partial o_j} &= -\sum_k \frac{\partial \varepsilon}{\partial net_k} \frac{\partial net_j}{\partial o_j} \\ &= -\sum_k \frac{\partial \varepsilon}{\partial net_k} \frac{\partial (\sum_j w_{kj} o_j)}{\partial o_j} \\ &= -\sum_k \frac{\partial \varepsilon}{\partial net_k} w_{kj} \\ &= \sum_k \delta_k w_{kj}\end{aligned}\tag{2.15}$$

식 2.15로부터 식 2.13 은 다음과 같이 나타낼 수 있다.

$$\delta_j = \sum_k \delta_k w_{kj} \cdot f'(net_j)\tag{2.16}$$

위 식들로부터 가중치의 변화량  $\Delta w_{ji}$ 는 다음과 같이 나타낼 수 있다.

$$\Delta w_{ji} = \eta \delta_j o_i\tag{2.17}$$

$$= \eta \cdot \left[ f'(net_j) \sum_k \delta_k w_{kj} \right] \cdot o_i$$

결국 학습과정에서 필요한 가중치의 변화량은 입-출력 쌍의 미소변화량을 모두 합하여 식 2.18 과 식 2.19 로 계산하며, 위와 같은 학습과정은 반복적으로 수행함으로써 가중치를 다음 식 2.20 과 같이 조정한다.

$$\Delta w_{kj} = \sum_p \Delta_p w_{kj} \quad (2.18)$$

$$\Delta w_{ji} = \sum_p \Delta_p w_{ji} \quad (2.19)$$

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n+1) \quad (2.20)$$

최종적으로 학습의 진행속도를 빠르게 하기 위해 모멘텀 항  $\alpha$ 를 고려한다. 모멘텀 항은 이전의 연결가중치를 저장하고 있어 신경망의 연결가중치 변화에 관심을 줌으로써 학습시간을 단축하고 신경망의 학습 성능을 향상시키는 역할을 한다.  $(n+1)$ 단계에서 출력층과 은닉층의 최종적인 가중치의 수정량은 다음 식 2.21과 식 2.22 와 같이 정의된다.

$$\Delta w_{kj}(n+1) = \eta \delta_k o_j + \alpha \Delta w_{kj}(n) \quad (2.21)$$

$$\Delta w_{ji}(n+1) = \eta \delta_j o_i + \alpha \Delta w_{ji}(n) \quad (2.22)$$

이러한 과정을 반복하면서 학습이 진행되며, 어떤 입력패턴이 주어질 때 전방향 연산에서 역방향 연산까지의 과정을 하나의 학습주기라 하고 정해진 반복 횟수에 도달하거나 오차가 정해진 범위로 줄어들면 학습이 모두 끝나게 된다.

### 3. 신경망을 이용한 손상검색 기법

#### 3.1 가속도 기반 인공신경망 알고리즘

구조건전성 모니터링에 구조물에서 계측되는 실시간 가속도 데이터를 이용하게 되면 소수의 센서만으로도 모니터링 시스템을 운용할 수 있을 뿐만 아니라 현장에서 계측된 데이터를 그대로 이용하게 되므로 실시간 건전성 모니터링이 가능하다. 이에 이인원 등은 손상평가를 위하여 한 점에서의 가속도 신호 변화 패턴을 이용한 인공신경망 알고리즘을 제안하였고, 수치 시뮬레이션을 통해 적용성을 검증하였다[이인원 등, 1999]. 그러나 이들은 불확실한 하중 조건에 따른 가속도 응답 패턴의 변화를 고려하지 못하였다. 절대적인 가속도 값을 이용할 경우 가속도의 레벨이 하중에 따라 크게 변동되므로 이러한 경우 손상 추정 결과가 크게 달라질 수 있다. 즉, 기존의 연구는 외력에 따라 변화하는 가속도 응답의 패턴 차이를 극복하지 못하는 문제가 있다. 따라서 본 연구에서는 현장에서 계측되는 실시간 가속도 응답 자료를 모니터링 시스템에 이용하기 위하여, 구조물의 두 점에서 취득한 가속도 응답의 상호상관함수를 이용한 패턴을 신경망 입력 자료로 이용하는 것을 제안하였다. 또한 하중의 형태, 지속시간 등을 고려하기 위하여 여러 가지 하중 조건에 따른 학습 신경망을 생성하고 각각에 대한 결과들을 통계적 가설검증 기법을 통해 분석하는 기법을 제안하였다. 이렇게 제안된 가속도 기반 신경망 알고리즘의 손상 검색 과정을 Fig. 3.1에 제시하였다.

가속도 기반 신경망 알고리즘은 손상 모니터링 대상 구조물이 정해지면 먼저 신경망 학습을 위한 유한요소 모델을 작성한다. 다음으로 유한요소 모델에 적용되는 N개의 가진 조건을 선정한다. 가진 조건은 실제 구조물에서 발생할 수 있는 다수의 가진 조건을 고려해야 할 필요가 있다. 가진 조건이 선정되면 각각의 가진 조건에 대하여 M개의 손상 경우를 가지는 손상 시나리오를 작성한다. 선정된 가진 조건으로 손상 시나리오에 따라 구조물의 두 점에서 가속도 신호  $x(t)$ 와  $y(x)$ 를 취득한다. 취득된 두 가속도 신호를 식 3.1에 나타난 상호상관함수를 통하여 두 신호의 상관성을 나타내는 함수로 표현할 수 있다.

$$R_{xy}(\tau) = E[x(t)y(t+\tau)] \quad (3.1)$$

여기서  $E$ 는 시간  $t$ 에 대한 평균 계산하는 함수이고,  $\tau$ 는 시간 증분을 뜻한다. 상호상관함수를 이용하게 되면 노이즈를 감소시킬 뿐만 아니라 외력에 대한 구조 응답의 레벨차이를 효과적으로 고려할 수 있다. 다음으로 유한요소 모델의 모델

링 오차를 고려하기 위하여 손상 전·후의  $R_{xy}(\tau)$ 값의 비를 구하고, 이를 학습 패턴으로 이용한다. 손상 시나리오에 따라 구해진 학습 패턴을 이용하여 신경망 학습을 수행한다. 이러한 일련의 과정을 M개의 가진 조건에 대해서 수행함으로써 M개의 학습된 신경망을 구성하게 된다. 학습된 M개의 신경망 구성되면 Fig. 3.1의 우측과 같이 실시간 손상 모니터링 체계를 운영하게 된다. 이는 먼저 구조물의 손상 전·후에 두 점에서 실시간 가속도 신호를 계측하고, 계측된 신호를 상호상관함수와 손상 전·후의 비를 이용하여 패턴을 만들게 된다. 구해진 패턴은 가진 조건에 따라 미리 학습된 각각의 신경망에 입력하여 손상검색 결과를 추출한다. 추출된 M개의 손상검색 결과를 통계적 가설 검증 기법을 이용하여 손상지수를 구하고, 이에 따라 손상 발생 여부를 판단한다. 여기서 통계적 가설 검증 기법은 구조계의 정상상태의 특징정보에 대한 표준정규분포곡선을 구하고 특정 특징정보가 기각영역에 속하는지를 식별하여 구조계의 이상상태를 판정하는 것이다. 이상상태를 판정하는 손상지수는 식 3.2와 같이 계산할 수 있다.

$$Z_i = \frac{(X_i - \mu)}{\sigma} \quad (3.2)$$

여기서  $X_i$ 는 각 요소별로 나타난 손상검색 결과들의 평균에 역수를 취한 값이고,  $\mu$ 는  $X_i$ 의 평균을 의미하며,  $\sigma$ 는  $X_i$ 의 분산을 나타낸다. 아래 첨자  $i$ 는 각 요소를 나타낸다.

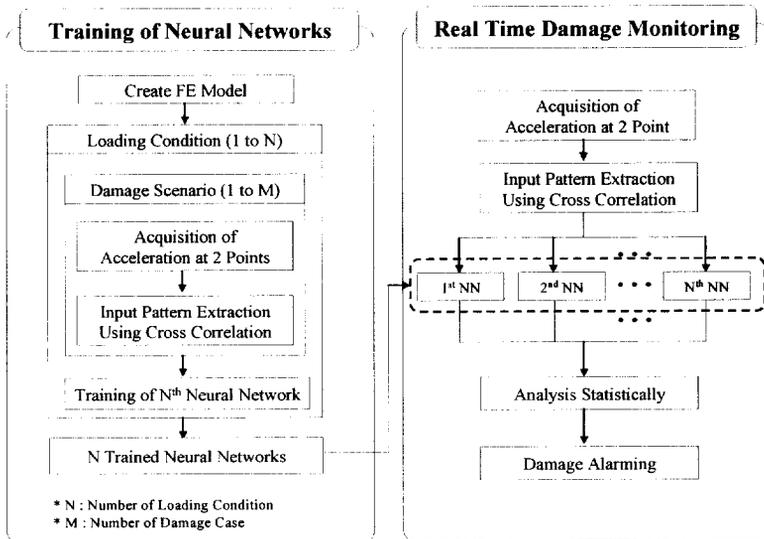


Fig. 3.1 Acceleration based Neural Network Algorithm

### 3.2 모드형상 기반 인공신경망 알고리즘

모드형상 기반 신경망을 이용한 손상검색 알고리즘은 신경망 입력으로 사용되는 모드형상을 비교적 복잡한 모드해석과정이 수반되어야 한다. 하지만, 모드형상은 구조물의 전역적인 위치에서 계측된 신호에 의해 추출될 뿐만 아니라 온도, 바람 등의 외부환경에 의한 영향에 상대적으로 영향을 적게 받으므로 보다 신뢰성 있는 손상 평가가 수행될 수 있는 장점이 있다.[이종재 등 2002]

모드형상 기반 신경망 손상검색 알고리즘은 Fig. 3.2에 나타내었다. 첫 번째 과정은 신경망 학습단계이다. 손상 검색 대상구조물의 유한요소 모델을 작성하고 신경망 학습을 위한 손상시나리오를 선정한다. 다음으로 유한요소 모델의 고유치 해석을 통해서 고유벡터를 추출하고 손상 전·후의 고유벡터 비를 구하여 신경망 학습 자료로 사용한다. 신경망 학습을 위한 유한요소 모델과 실제 대상 구조물의 모델링 오차는 손상 전·후의 비를 이용함으로써 효과적으로 고려될 수 있다.[이종재 등 2002] 학습이 끝난 신경망은 구조물의 손상 위치와 정도를 추정할 알고리즘으로 사용된다. 두 번째 과정은 학습된 신경망을 이용하여 구조물의 손상추정을 수행하는 단계이다. 이 단계에서는 모드형상이 신경망 입력자료로 사용된다. 모드형상을 추출하기 위해 구조물의 전역적 위치에서 가속도 신호를 계측한다. 다음으로 모드해석을 통해 모드형상을 추출하고 손상 전·후의 모드형상 비를 구한다. 최종적으로 모드형상 비를 미리 학습된 신경망의 입력으로 사용하여 구조물의 손상 위치와 정도를 식별하게 된다.

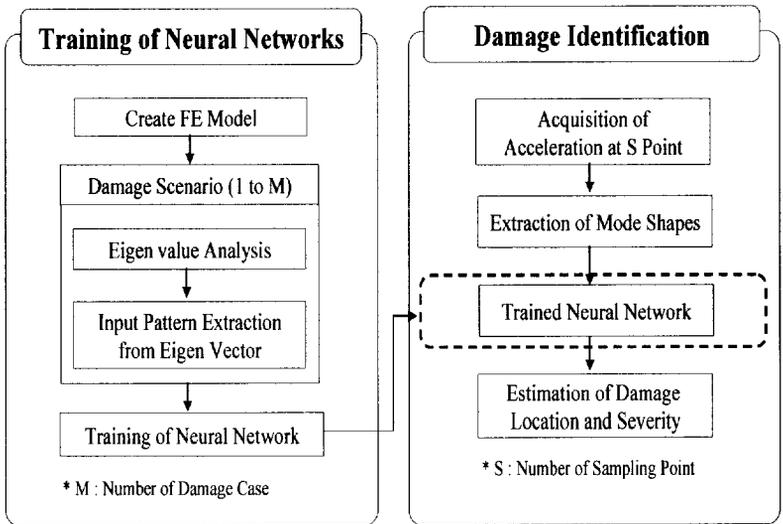


Fig. 3.2 Mode Shape based Neural Network Algorithm

### 3.3 가속도-모드형상 기반 신경망 알고리즘을 이용한 손상검색기법

3.1절에서 제안된 가속도 기반 신경망을 이용한 손상검색 체계는 통계적 기법을 이용하였기 때문에 손상의 정량적인 표현이 어렵고, 실제 구조물에서의 가속도 신호는 계측 환경의 영향을 크게 받기 때문에 손상 위치의 판별 또한 쉽지 않다. 따라서 이러한 경우 모드형상 기반 신경망 알고리즘을 이용할 필요가 있다. 따라서 본 연구에서는 가속도-모드형상 기반 신경망을 이용한 손상검색 기법을 제안하였다. 이는 Fig. 3.3과 같이 가속도 기반 신경망 알고리즘으로 실시간 구조 건전성 모니터링을 수행하여 구조물의 손상경보 단계와 모드형상 기반 신경망 알고리즘으로 구조물 손상에 대한 상세한 위치 및 손상을 식별하는 단계로 구성되었다. 손상 경보 단계는 가속도 기반 신경망 알고리즘과 동일한 과정으로 손상을 경보하게 되며, 손상 발생이 식별되면 모드형상 기반 신경망 알고리즘을 이용한 손상검색 단계로 넘어가게 되고 손상이 발견되지 않았다면 계속적인 모니터링을 수행하게 된다.

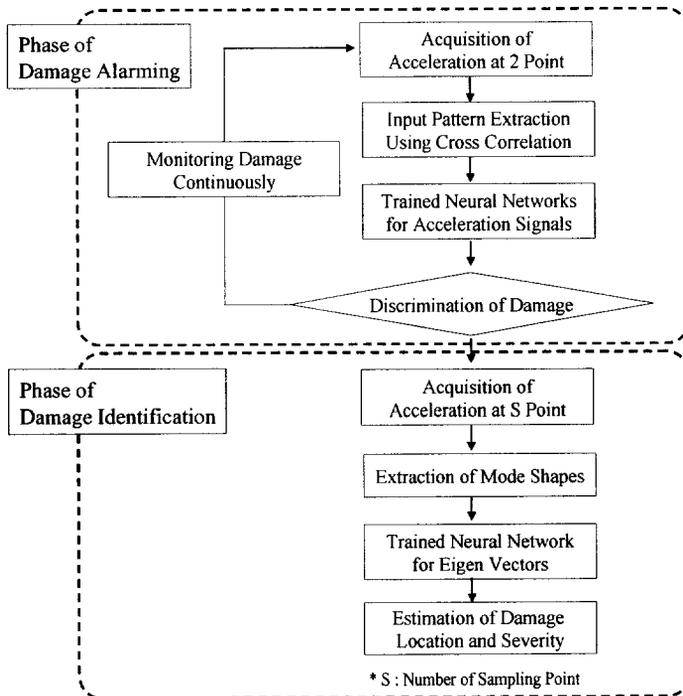


Fig. 3.3 Damage Detection Method using Acceleration-Mode Shape based Neural Networks

## 4. 손상검색 기법의 수치 검증

### 4.1 대상 모델

신경망을 이용한 가속도-모드형상 기반 손상검색 기법을 검증하기 위하여 수치 모델을 대상으로 손상 평가를 수행하였다. 대상 모델은 Fig. 4.1과 같이 지간 2.24m의 단순보를 선정하였다. 단면 형상은 I형이며, 재료는 SS400 강재를 사용하였다. 대상 모델의 수치해석을 위하여 MIDAS/Civil을 이용한 유한요소 해석이 수행되었다. 유한요소 모델은 Fig. 4.2와 같이 절점 17개, 요소 16개를 1차원 보 요소를 이용하여 작성되었다.

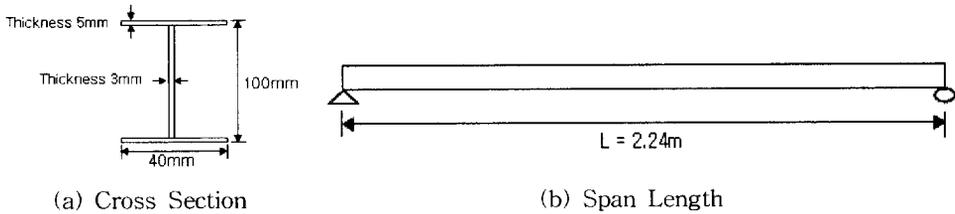


Fig. 4.1 Geometry of Numerical Model

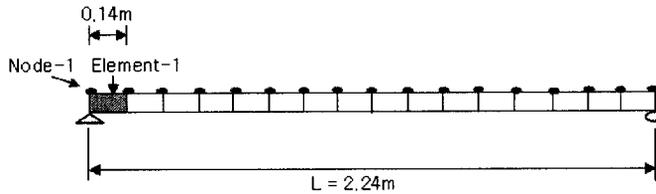


Fig. 4.2 Finite Element Model for Target Structure

### 4.2 신경망 학습

#### 4.2.1 신경망 학습을 위한 손상시나리오

신경망 학습을 위하여 다음과 같이 손상시나리오를 선정하였다. 먼저, 단일 손상 학습패턴 구성을 위한 손상시나리오는 홀수번 8개의 요소에 각각 5%, 10%, 15%, 20%의 휨 강성을 감소시키는 것으로 작성하였다. 따라서, 학습 패턴은 Table 4.1과 같이 비손상 상태 1 경우를 포함하여 총 33개가 작성되었다. 복수 손상에 대한 학습패턴은 손상이 두 개의 요소에서 동시에 발생하는 것으로 한정

하였다. 손상 시나리오는 2개의 요소에 대하여 각각 5%, 10%, 15%, 20%의 손상을 무작위로 적용하였다. 이와 같은 방법으로 복수 손상 학습 패턴은 Table 4.2와 같이 총 28개가 작성되었다. 예를 들어, Table 4.2에서 Pattern 1은 1번 요소와 3번 요소에 각각 5%, 20%의 손상이 발생한 것을 의미한다.

Table 4.1 Single Damage Scenario for Training Neural Networks

Pattern	Damaged Element	$\Delta EI/EI$ (%)	Pattern	Damaged Element	$\Delta EI/EI$ (%)
1	-	-	18	1	15
2	1	5	19	3	15
3	3	5	20	5	15
4	5	5	21	7	15
5	7	5	22	9	15
6	9	5	23	11	15
7	11	5	24	13	15
8	13	5	25	15	15
9	15	5	26	1	20
10	1	10	27	3	20
11	3	10	28	5	20
12	5	10	29	7	20
13	7	10	30	9	20
14	9	10	31	11	20
15	11	10	32	13	20
16	13	10	33	15	20
17	15	10			

Table 4.2 Multi Damage Scenario for Training Neural Networks

Pattern	Damaged Elements	$\Delta EI/EI$ (%)	Pattern	Damaged Elements	$\Delta EI/EI$ (%)
1	1, 3	5, 20	15	5, 9	15, 15
2	1, 5	10, 5	16	5, 11	20, 15
3	1, 7	15, 10	17	5, 13	10, 15
4	1, 9	20, 15	18	5, 15	15, 10
5	1, 11	20, 5	19	7, 9	15, 15
6	1, 13	5, 10	20	7, 11	5, 20
7	1, 15	10, 10	21	7, 13	10, 10
8	3, 5	5, 20	22	7, 15	20, 15
9	3, 7	10, 5	23	9, 11	5, 5
10	3, 9	15, 10	24	9, 13	10, 5
11	3, 11	20, 10	25	9, 15	20, 20
12	3, 13	5, 5	26	11, 13	10, 20
13	3, 15	15, 5	27	11, 15	15, 5
14	5, 7	10, 10	28	13, 15	20, 15

## 4.2.2 가속도 기반 신경망 학습

가속도 기반 신경망 학습을 위한 가속도 신호계측 시스템을 Fig. 4.3에 나타내었다. 그림에 나타난 바와 같이, 유한요소 모델의 0.75L위치(13번 절점)에 충격하중을 주었고, 구조물의 0.125L(3번 절점), 0.25L위치(5번 절점)에 가속도 신호를 취득하였다. 샘플링 주파수는 10kHz로 하였고, 총 16,384개의 가속도 신호를 취득하였다.

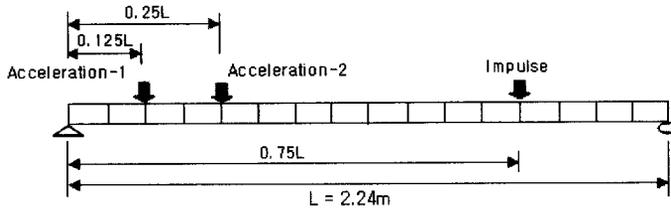
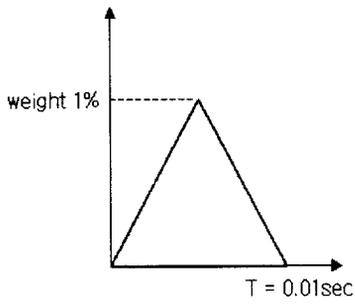


Fig. 4.3 Excitation System and Sensor System

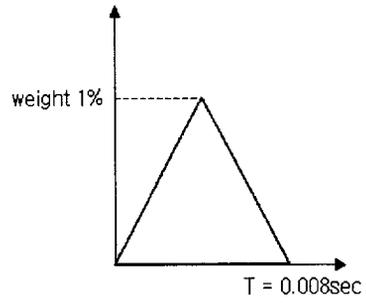
하중조건에 따른 신경망 입력 패턴을 추출하기 위하여 Table 4.3과 Fig. 4.4와 같이 총 7개의 가진 경우를 고려하였다. 가진 경우 1부터 4까지는 모두 삼각형 가진 형태로 고려하였다. 가진 시간은 각각 0.01초, 0.008초, 0.012초, 0.015초로 하였다. 가진 경우 5는 직각삼각형 형태의 충격하중을 고려하였고, 가진 시간은 0.01초로 하였다. 가진 경우 6은 사각형 형태의 충격하중이며, 가진 시간은 0.01초로 하였다. 가진 경우 7의 충격하중은 가진 경우 6의 충격하중과 동일한 사각형 형태이지만 가진을 0.005초 지연하여 주는 것으로 하였다. 모든 가진 경우의 가진력의 크기는 유한요소 모델 자중의 1%로 하였다.

Table 4.3 Impulse Excitation Conditions for Acceleration based Neural Networks Training

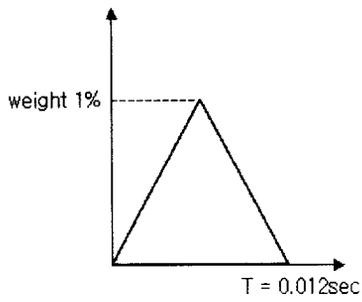
Case	Pulse Shape	Pulse Intensity (percent per self-wight)	Pulse Duration (sec)
1	Triangular Pulse- I	1%	0 - 0.01
2	Triangular Pulse- II	1%	0 - 0.008
3	Triangular Pulse- III	1%	0 - 0.012
4	Triangular Pulse- IV	1%	0 - 0.015
5	Right Triangular Pulse	1%	0 - 0.01
6	Rectangular Pulse- I	1%	0 - 0.01
7	Rectangular Pulse- II	1%	0.005 - 0.015



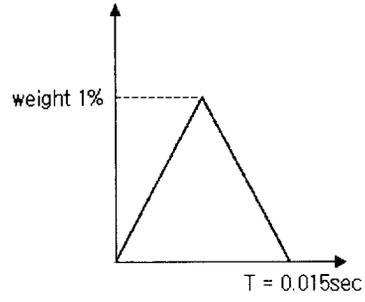
(a) Triangular Pulse-I



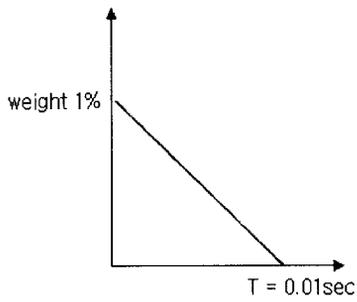
(b) Triangular Pulse-II



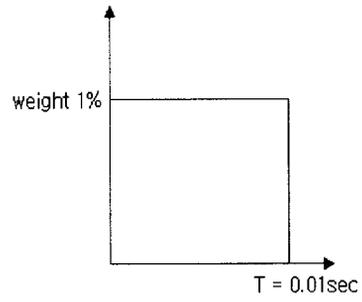
(c) Triangular Pulse-III



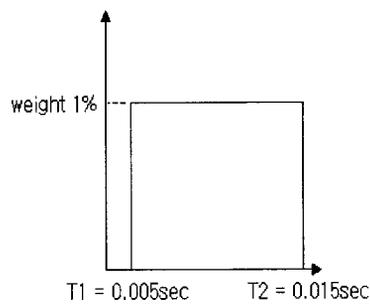
(d) Triangular Pulse-IV



(e) Right Triangular Pulse



(f) Rectangular Pulse-I



(g) Rectangular Pulse-II

Fig. 4.4 Impulse Excitation Configuration

이상과 같은 7개의 가진 조건을 각각의 손상 시나리오별에 따라 적용하여 가속도를 추출하였다. Fig. 4.5와 4.6은 손상이 없는 상태의 유한요소 모델에 가진 경우 1을 적용하여 0.125L(3번 절점), 0.25L 위치(5번 절점)에서 각각 취득된 가속도 신호이다.

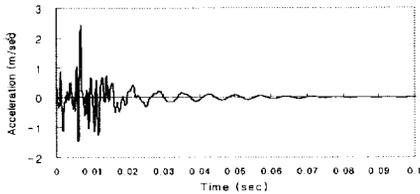


Fig. 4.5 Acceleration Result-0.125L

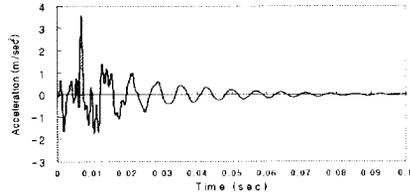


Fig. 4.6 Acceleration Result-0.25L

학습 패턴은 식 4.1과 같이 먼저 손상 시나리오별로 두 점에서 취득한 가속도 신호의 상호상관신호를 구하고, 초기 50개의 데이터에 대한 손상 전후의 비 값을 이용하여 추출하였다.

$$P = R_{xy}^d / R_{xy}^u \quad (4.1)$$

여기서,  $R_{xy}^d$  는 손상상태에서 x, y점에서 취득한 가속도 신호의 상호상관함수 출력결과이고  $R_{xy}^u$  는 비 손상상태에서 x, y점에서 취득한 가속도 신호의 상호상관함수 출력결과이다. Fig. 4.7은 Fig. 4.5와 4.6에 나타난 신호에 대한 상호상관신호를 보여준다.

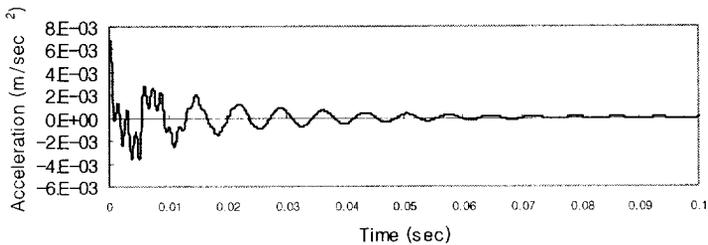


Fig. 4.7 Cross Correlation signal of Two Signals

가속도 기반 신경망의 구성은 Fig. 4.8에 나타내었다. 신경망은 50개 유니트의 입력층, 50개 유니트의 은닉층, 16개 유니트의 출력층으로 구성하였다. 출력층의

16개 유니트는 각각 대상 구조물의 16 요소에 해당한다. 학습에 이용된 패턴은 단일 손상에 대한 손상 검색에는 비 손상상태 1set과 홀수번 요소 8개가 각각 5%, 10%, 15%, 20%의 손상을 입은 경우의 32set을 이용하였고, 복수 손상에 대한 손상 검색에는 단일 손상에 대한 학습 패턴 33set에 앞서 작성된 복수 손상에 대한 학습시나리오 28set을 추가한 61set의 패턴을 이용하였다.

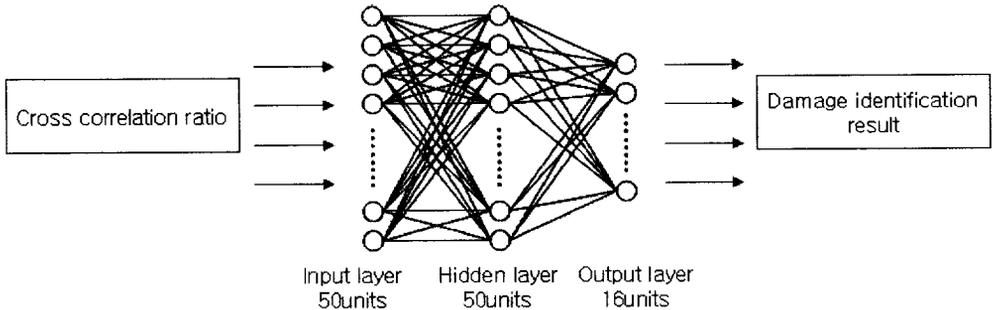


Fig. 4.8 Acceleration based Neural Networks

### 4.2.3 모드형상 기반 신경망 학습

모드형상 기반 신경망 학습을 위하여 고유벡터를 추출하기 위한 유한요소 모델을 Fig. 4.9에 나타내었다. 등 간격의 16개의 요소로 구성된 모델의 17개의 점에서 고유모드형상을 취득하였고, 비손상 상태에서 추출된 고유모드형상은 Fig. 4.10과 같다.

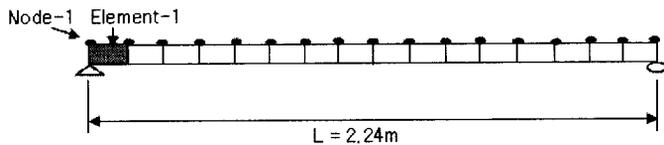


Fig. 4.9 Finite Element Model for Acquisition Eigen Vector

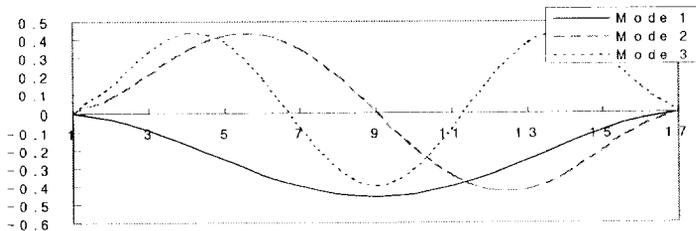


Fig. 4.10 Eigen Vector of Undamage Finite Model

모드형상 기반 신경망에 대한 학습 자료는 Table 4.1과 4.2의 신경망 학습 시나리오에 따라 추출된 구조물의 고유모드형상으로부터 식 4.1을 이용하여 손상 전·후에 대한 고유모드형상 비를 구하여 사용되었다. 지점부의 고유벡터 값은 0이 되므로 손상 전·후에 대한 비를 구할 수 없다. 따라서 신경망 학습 자료에 지점부의 고유벡터는 제외하였다. 모드형상 기반 신경망은 Fig. 4.11에 나타내었다. 신경망은 45개 유닛의 입력층, 45개 유닛의 은닉층, 16개 유닛의 출력층으로 구성하였다. 출력층의 16개 유닛은 각각 대상 구조물의 16 요소에 해당한다. 신경망 입력에 사용된 하나의 패턴은 초기 3개의 저차모드를 이용하였고 지점부의 자료를 제외 한 45개의 데이터로 구성하였다. 단일 손상에 대한 손상 검색에는 비 손상상태 1set과 홀수번 요소 8개가 각각 5%, 10%, 15%, 20%의 손상을 입은 경우의 32set을 이용하였고, 복수 손상에 대한 손상 검색에는 단일 손상에 대한 학습 패턴 33set에 앞서 작성된 복수 손상에 대한 학습시나리오 28set을 추가한 61set의 패턴을 이용하였다.

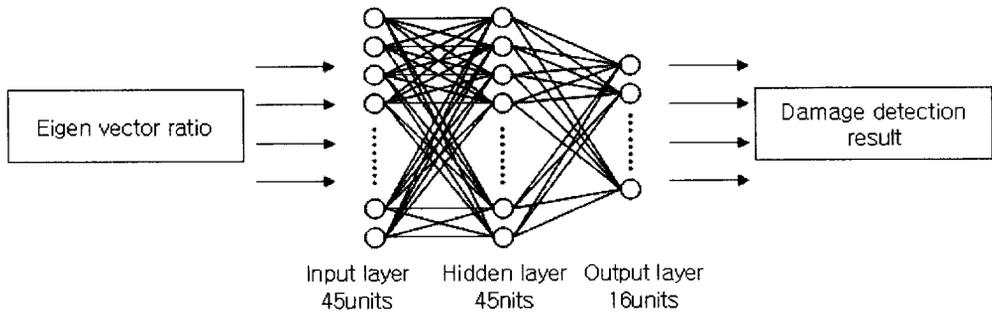


Fig. 4.11 Mode Shape based Neural Networks

### 4.3 신경망을 이용한 손상검색

신경망을 이용한 손상검색을 위해 작성된 손상시나리오는 Table 4.4에 나타내었다. 손상 경우 1은 9번 요소에 10%의 강성을 감소시켜 단일 손상을 모사하였고, 손상 경우 2는 3번 요소에 5%의 강성 감소, 9번 요소에 15%의 강성 감소를 적용하여 복수 손상을 모사하였다.

Table 4.4 Damage Scenario

Damage case	Damaged Elements	$\Delta EI/EI$ (%)
Damage 1	9	10
Damage 2	3, 9	5, 15

### 4.3.1 가속도 기반 신경망을 이용한 손상검색

#### (1) 단일 손상에 대한 손상검색 결과

학습에 이용된 가속도 신호의 가진력과 동일하지 않은 가진력에 의해 추출된 가속도를 이용하여 신경망을 통한 손상 검색을 수행하였다. Fig. 4.12는 신호취득을 위해 적용된 가진 조건을 나타낸다. Fig. 4.12(a)는 삼각형 형태의 충격하중으로 가진력의 크기는 유한요소 모델 자중의 0.8%로 하였고, 가진시간은 0.01초로 하였다. Fig. 4.12(b)는 크기가 유한요소 모델 자중의 0.8%, 가진시간은 0.01초인 직각삼각형 충격하중을 나타낸다. Fig. 4.12(c)는 사각형 형태의 충격하중으로 가진력의 크기는 유한요소 모델 자중의 0.8%, 가진 시간은 0.01초로 하였다. Fig. 4.12(d)는 Fig. 4.12(c)의 충격하중과 동일한 사각형 형태이지만 가진을 0.005초 지연하여 주는 것으로 하였다.

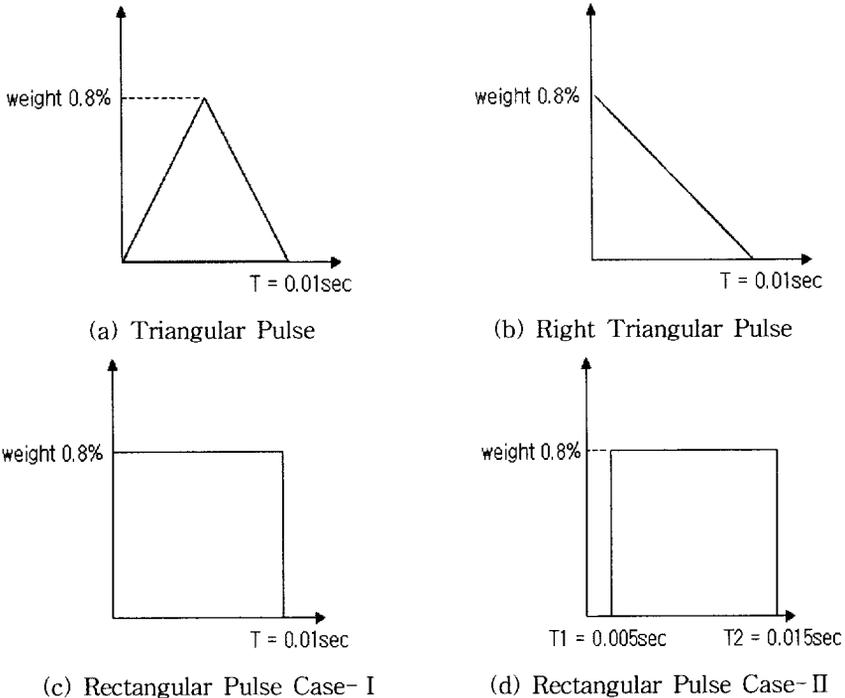
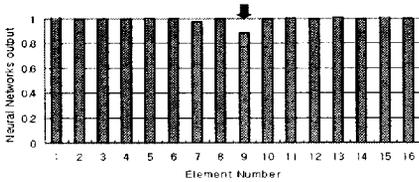


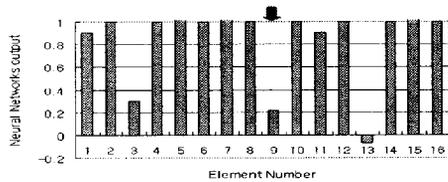
Fig. 4.12 Pulse Loading Scenario for Damage Detection

Fig. 4.13은 Table 4.3의 신경망 학습을 위한 가진조건 중 경우 1의 삼각형가진, 경우 5의 직각삼각형가진, 경우 6의 사각형가진, 경우 7의 가진시간 지연이 있는

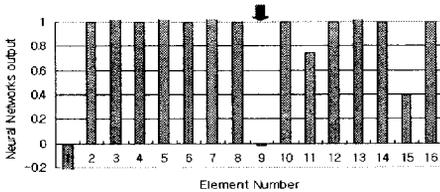
삼각형가진에 대한 신호로 각각 학습된 신경망으로 Fig. 4.12(a)의 삼각형 가진에 따른 신호를 이용하여 단일손상에 대한 손상검색을 수행한 결과이다. Fig. 4.13(a)는 손상검색에 사용된 신호의 가진력(삼각형 가진)과 신경망 학습에 사용된 신호의 가진력이 같은 형태일 때의 결과를 나타낸다. 그림에 나타난 바와 같이 손상이 발생한 요소는 9번 요소인 것으로 정확히 예측하고 있다. Fig. 4.13(b), 4.13(c), 4.13(d)의 결과는 손상검색에 사용된 신호의 가진력인 삼각형 가진과 신경망 학습에 사용된 신호의 가진력이 각각 다른 형태일 때의 손상검색 결과이다. 그림에서 보는바와 같이 각각의 신경망은 손상검색에 모두 다른 결과를 나타내고 있으나 실제 손상이 존재하는 9번 요소의 손상은 모두 공통적으로 예측하고 있음을 확인할 수 있다.



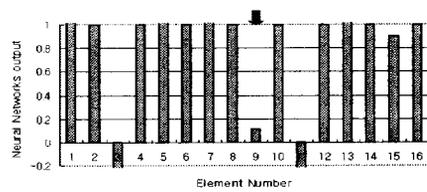
(a) Result via Excitation Case - 1



(b) Result via Excitation Case - 5



(c) Result via Excitation Case - 6



(d) Result via Excitation Case - 7

Fig. 4.13 Damage Detection Result from Test Pattern using Triangular Pulse

Fig. 4.14는 가진 경우1, 가진 경우5, 가진 경우6, 가진 경우7에 따른 신호를 입력으로 각각 학습된 신경망을 통해 Fig. 4.12(b)의 직각삼각형 가진에 따른 신호를 이용하여 단일손상에 대한 손상검색을 수행한 결과이다. Fig. 4.14(a)와 4.14(c), 4.14(d)는 손상검색에 사용된 신호의 가진력(직각삼각형 가진)과 신경망 학습에 사용된 신호의 가진력이 다른 형태일 때의 손상검색 결과를 나타낸다. 그림에 나타난 바와 같이 실제 손상이 존재하는 9번 요소뿐만 아니라 다른 요소들에서도 손상이 있음을 예측하고 있다. 그러나 9번 요소의 손상은 모두 공통적으로 감지하고 있다. Fig. 4.14(b)는 손상검색에 사용된 신호의 가진력과 신경망 학습에 사용된 신호의 가진력이 같은 형태일 때의 결과를 나타내는 것으로 13번 요소에서

도 손상이 발생하는 것으로 감지되었으나 9번 요소 손상에 대한 손상검색에 가장 좋은 결과를 나타내었다.

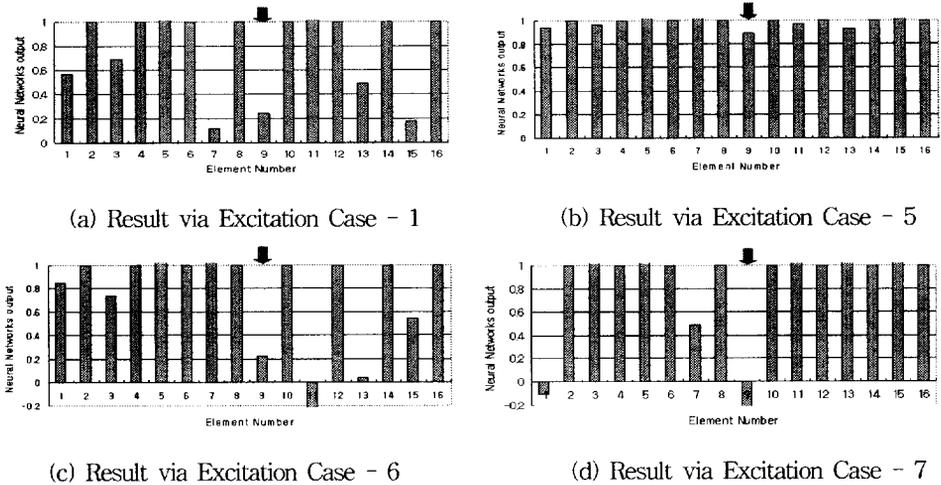
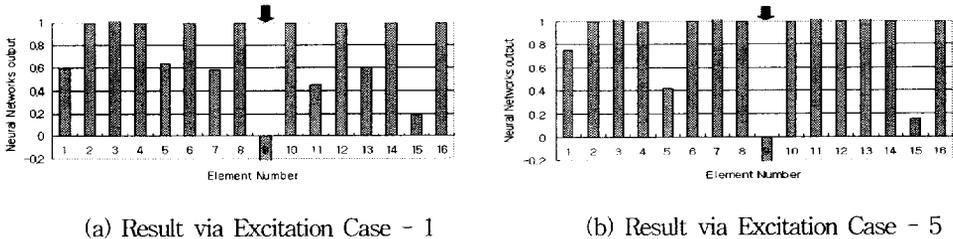
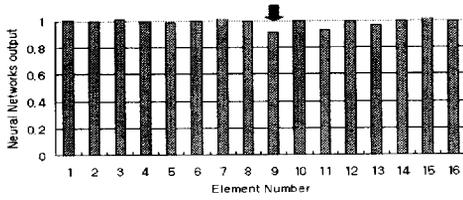


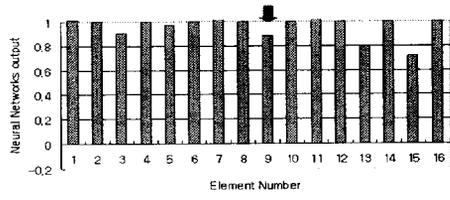
Fig. 4.14 Damage Detection Result from Test Pattern using Right Triangular Pulse

Fig. 4.15는 가진 경우1, 가진 경우5, 가진 경우6, 가진 경우7의 가진에 의한 신호로 학습한 신경망으로 Fig. 4.12(c)의 사각형가진에 따른 신호를 이용하여 단일손상에 대한 손상검색을 수행한 결과이다. Fig. 4.15(c)는 손상검색에 사용된 신호의 가진력(사각형가진)과 신경망 학습에 사용된 신호의 가진력이 같은 형태일 때의 결과를 나타낸다. 그림에 나타난 바와 같이 손상이 발생한 요소는 9번과 11번 요소로 나타났으나 다른 가진 형태의 결과보다 더 좋은 손상 검색 결과를 나타내었다. Fig. 4.15(a), 4.15(b), 4.15(d)의 결과는 손상검색에 사용된 신호의 가진력인 사각형 가진과 신경망 학습에 사용된 신호의 가진력이 각각 다른 형태일 때의 손상검색 결과이다. 실제 손상이 발생한 9번 요소의 손상뿐만 아니라 다른 요소들에서도 손상이 감지되는 결과를 나타내고 있다. 4가지 결과를 모두 보았을 때, 각각의 신경망이 수행한 손상검색 결과는 모두 달랐으나 9번 요소의 손상은 모두 공통적으로 예측하고 있음을 확인할 수 있다.





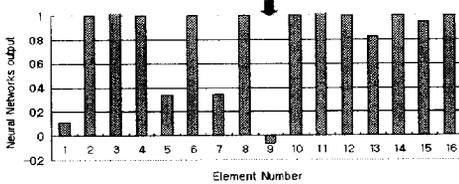
(c) Result via Excitation Case - 6



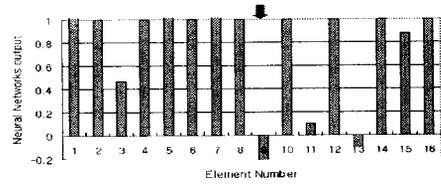
(d) Result via Excitation Case - 7

Fig. 4.15 Damage Detection Result from Test Pattern using Rectangular Pulse Case- I

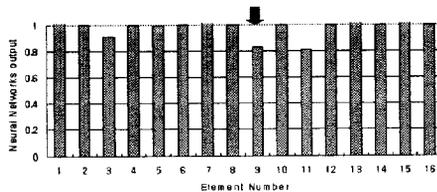
Fig. 4.16은 가진 경우1, 가진 경우5, 가진 경우6, 가진 경우7의 가진에 의한 신호로 학습한 신경망으로 Fig. 4.12(d)의 가진 시간의 지연이 있는 사각형 가진에 의한 신호를 이용하여 단일손상에 대한 손상검색을 수행한 결과이다. Fig. 4.16(d)는 손상검색에 사용된 신호의 가진력과 신경망 학습에 사용된 신호의 가진력이 같은 형태일 때의 결과를 나타낸다. 그림에 나타난 바와 같이 손상이 발생한 요소는 9번 요소와 5번 요소로 예측되었으나 다른 가진 형태보다 더 좋은 손상 검색 결과를 얻을 수 있었다. Fig. 4.16(a), 4.16(b), 4.16(c)의 결과는 손상검색에 사용된 신호의 가진력인 사각형 가진과 신경망 학습에 사용된 신호의 가진력이 각각 다른 형태일 때의 손상검색 결과이다. 실제 손상이 발생한 9번 요소의 손상뿐만 아니라 다른 요소들에서도 손상이 감지되는 결과를 나타내고 있다. 그림에서 보는바와 같이 각각의 신경망은 손상검색에 모두 다른 결과를 나타내고 있으나 실제 손상이 존재하는 9번 요소의 손상은 모두 공통적으로 예측하고 있음을 확인할 수 있다.



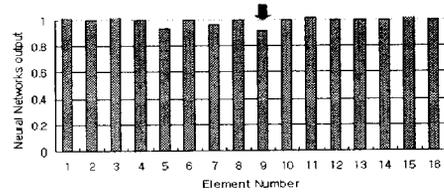
(a) Result via Excitation Case - 1



(b) Result via Excitation Case - 5



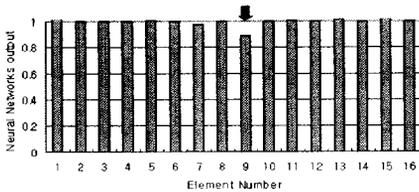
(c) Result via Excitation Case - 6



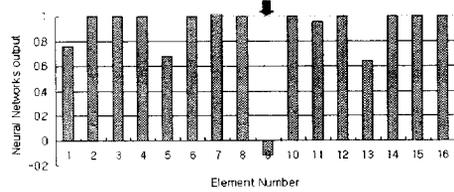
(d) Result via Excitation Case - 7

Fig. 4.16 Damage Detection Result from Test Pattern using Rectangular Pulse Case-II

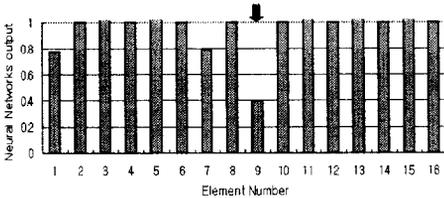
Fig. 4.17은 Table 4.3의 신경망 학습을 위한 가진 조건 중 경우1, 경우2, 경우3, 경우4의 가진에 따른 신호로 각각 학습된 신경망의 손상검색 결과이다. 손상검색에 사용된 신호의 가진력은 Fig. 4.12(a)의 삼각형 가진이다. Fig. 4.17(a)는 신경망 학습에 사용된 신호의 가진시간과 손상검색에 사용된 신호의 가진 시간이 같을 때의 결과를 나타낸다. 그림에서 보는바와 같이 9번 요소의 손상이 정확히 예측되고 있다. Fig. 4.17(b), 4.17(c), 4.17(d)는 손상검색에 사용된 신호의 가진 시간과 신경망 학습에 사용된 신호의 가진 시간이 다른 형태일 때의 결과를 나타낸다. 그림에서 보는바와 같이 실제 손상이 발생한 9번 요소의 손상뿐만 아니라 다른 요소들에서도 손상이 감지되는 결과를 나타내고 있다. 이상의 4가지 결과들을 보았을 때, 각각의 신경망은 모두 다른 손상예측 결과를 보이고 있으나 실제 손상이 존재하는 9번 요소의 손상은 모두 공통적으로 예측하고 있음을 확인할 수 있다.



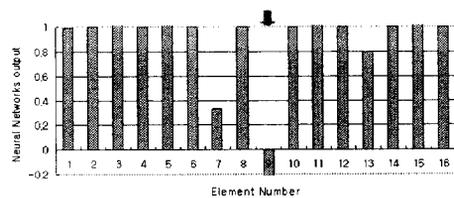
(a) Result via Excitation Case - 1



(b) Result via Excitation Case - 2



(c) Result via Excitation Case - 3

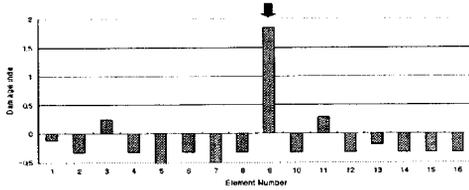


(d) Result via Excitation Case - 4

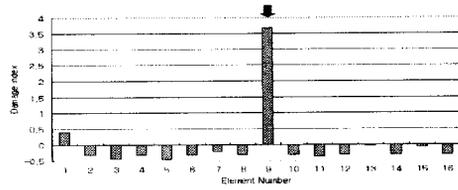
Fig. 4.17 Damage Detection Result from Test Pattern using Triangular Pulse

Fig. 4.18은 Table 4.3의 가진 조건 중 경우1, 경우5, 경우6, 경우7의 가진에 따른 신호로 학습된 각각의 신경망의 손상검색 결과들을 3장에서 기술된 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. Fig. 4.18(a)는 가진 경우1을 통한 결과를 나타내고 Fig. 4.18(b)는 가진 경우2를 통한 결과, 4.18(c)는 가진 경우3을 통한 결과, 4.18(d)는 가진 경우4를 통한 결과이다. 그림에서 나타난 바와 같이, 손상지수(Damage Index)가 1.5이상인 (정규 분포 상 기각영역 93.3%) 실제 손상이 있는 요소인 9번 요소로 나타났고,

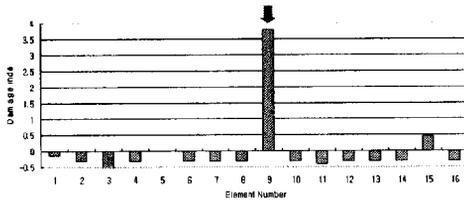
손상이 정확히 예측되었다.



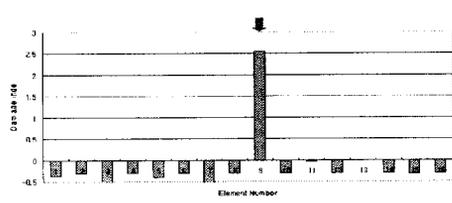
(a) Damage Index of Excitation Case - 1



(b) Damage Index of Excitation Case - 5



(c) Damage Index of Excitation Case - 6



(d) Damage Index of Excitation Case - 7

Fig. 4.18 Damage Index of Single Damage using Result of Four Pulse Shape Excitations

Fig. 4.19는 Table 4.3의 가진 조건 중 경우1, 경우2, 경우3, 경우4의 삼각형 가진에 따른 신경망의 손상검색 결과를 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이 손상지수가 1.5 이상으로 손상발생 가능성이 가장 높은 요소는 9번 요소로 나타났으며, 이것으로 보아 9번 요소에서 발생한 손상을 정확히 예측하고 있다고 판단되어 진다.

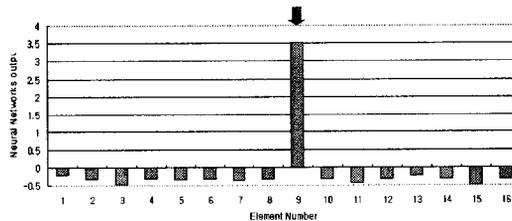


Fig. 4.19 Damage Index of Single Damage using Result of Four Triangular Excitations

## (2) 복수 손상에 대한 손상검색 결과

신호기반 신경망을 이용하여 복수 손상을 검색한 결과는 Fig. 4.21에 나타내었다. Fig. 4.21은 Table 4.3의 신경망 학습 가진 조건 중 경우1, 경우2, 경우3, 경우4의 삼각형 가진에 따른 가속도로 학습한 신경망으로 9번 요소와 3번 요소의 복수 손상에 대한 손상검색을 수행하였다. Fig. 4.20는 손상 검색을 위해 사용된 신호의 가진력이다.

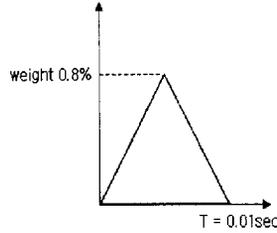
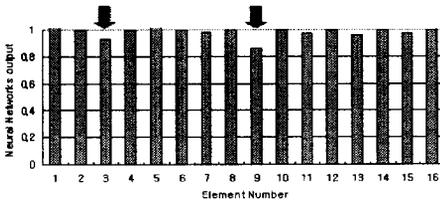
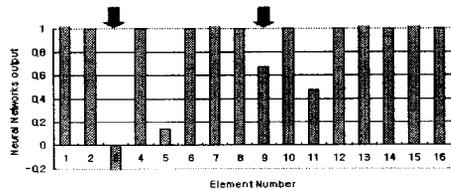


Fig. 4.20 Triangular Pulse for Damage Detection of Multi Damage Scenario

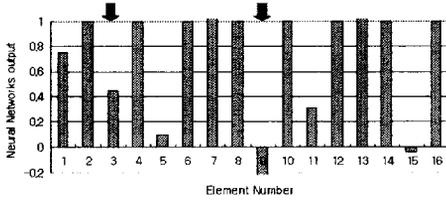
Fig. 4.21(a)은 손상검색용 신호의 가진과 가진 시간이 같은 Table 4.3의 경우1의 가진에 의한 신호로 학습된 신경망으로 손상검색을 수행한 결과이다. 그림에서 나타난 바와 같이 3번 요소와 9번 요소의 손상을 정확히 예측하고 있다. Fig. 4.21(b), 4.21(c), 4.21(d)는 손상검색용 신호의 가진과 가진 시간이 다른 가진에 의한 신호로 학습된 신경망으로 손상검색을 수행한 결과이다. Fig. 4.21(b)의 직각삼각형 가진에 의한 결과와 Fig. 4.21(c)의 사각형 가진에 의한 결과를 보았을 때, 3번 요소와 9번 요소에서의 손상이 예측되고 있으나 손상이 없는 다른 요소들에서도 손상이 감지되는 결과를 얻을 수 있었다. Fig. 4.21(d)의 결과는 시간지연이 있는 사각형 가진에 의한 결과이다. 그림에서 나타난 바와 같이, 9번 요소의 손상 뿐만 아니라 손상이 없는 다른 요소들에서도 손상이 감지되고 있다. 그러나 실제 손상이 있는 3번 요소에서 발생한 손상은 감지되지 못하였다.



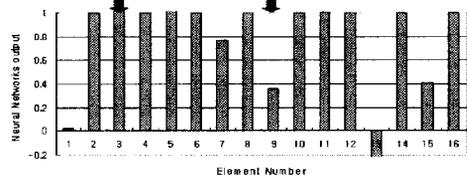
(a) Result via Excitation Case - 1



(b) Result via Excitation Case - 2



(c) Result via Excitation Case - 3



(d) Result via Excitation Case - 4

Fig. 4.21 Damage Detection Result from Test Pattern using Triangular Pulse

Fig. 4.22는 Fig. 4.21의 가진 경우1, 가진 경우2, 가진 경우3, 가진 경우4의 삼각형 가진에 따른 신경망의 손상검색 결과를 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이 손상지수가 1.5 이상으로 손상발생 가능성이 가장 높은 요소는 9번 요소로 나타났으며, 이것으로 보아 9번 요소에서 발생한 손상을 정확히 예측하고 있다고 판단되어 진다. 그러나 3번 요소의 손상지수 값은 거의 0에 가까운 값으로 나타났으며, 손상은 예측되지 않았다.

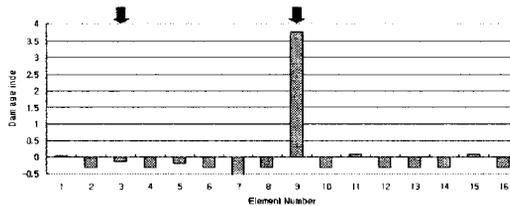


Fig. 4.22 Damage Index of Multi Damage using Result of Four Triangular Excitations

## 4.3.2 모드형상 기반 신경망을 이용한 손상검색

### (1) 단일 손상에 대한 손상검색 결과

모드형상 기반 신경망 알고리즘으로 단일 손상에 대한 손상 검색을 수행하였고 그 결과를 Fig. 4.23에 나타내었다. 그림에서 보는바와 같이 9번 요소에서 발생한 10%의 손상에 대하여 그 위치를 정확히 추정하고 있는 결과를 얻을 수 있었다. Table 4.5는 신경망을 통한 손상검색의 출력값을 나타낸 것이다. Table 4.5에서 나타난 바와 같이 손상이 발생하지 않은 요소에서는 비손상 상태의 목표값인 1에 거의 가까운 값을 나타내고 있었고, 9번 요소의 손상검색 출력값은 10% 손상에 대한 목표 값인 0.9에 거의 가까운 값을 나타내고 있었다. 이것으로 보아

모드형상 기반 신경망으로 단일 손상에 대한 손상위치와 정도를 정확히 추정할 수 있다.

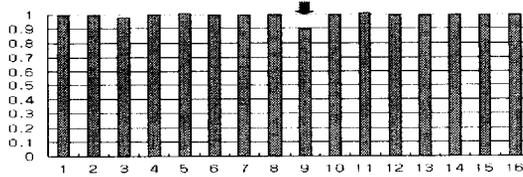


Fig. 4.23 Damage Detection Result of Single Damage

Table 4.5 Damage Detection Result of Single Damage

element	1	2	3	4
output	1.0011	1.0000	0.9781	1.0000
element	5	6	7	8
output	1.0099	1.0000	0.9964	1.0000
element	9	10	11	12
output	0.8949	1.0000	1.0110	1.0000
element	13	14	15	16
output	0.9935	1.0000	0.9961	1.0000

## (2) 복수 손상에 대한 손상검색 결과

모드형상 기반 신경망 알고리즘으로 3번 요소와 9번 요소에 각각 5%, 15%의 손상을 추정하였다. Fig. 4.24는 손상 추정 결과를 나타낸 것이다. Fig. 4.24에 나타난 바와 같이, 3번 요소와 9번 요소의 손상에 대해 그 위치가 정확히 추정되었다. Table 4.6은 신경망의 손상추정 출력값을 나타낸 것이다. 손상이 없는 요소들의 출력값은 그 목표값인 1에 거의 가까운 값이 출력되었다. 3번 요소의 5% 손상에 대한 신경망 출력값은 0.96으로 목표값인 0.95에 거의 가까운 값을 나타내고 있고, 9번 요소의 15% 손상에 대한 출력값은 0.85에 거의 가까운 0.8464의 출력값을 나타내고 있다. 이것으로 보아 모드형상 기반 신경망으로 복수손상에 대해서도 손상 위치와 손상 정도의 정확히 추정하였다.

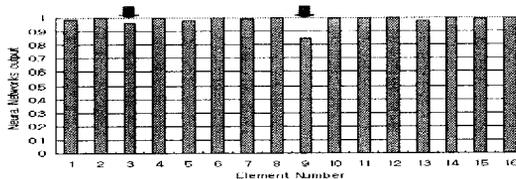


Fig. 4.24 Damage Detection Result of Multi Damage

Table 4.6 Damage Detection Result of Multi Damage

element	1	2	3	4
output	0.9838	1.0000	0.9601	1.0000
element	5	6	7	8
output	1.0100	1.0000	0.9964	1.0000
element	9	10	11	12
output	0.8464	1.0000	0.9992	1.0000
element	13	14	15	16
output	0.9935	1.0000	0.9961	1.0000

## 5. 손상검색 기법의 실험 검증

### 5.1 실험구조물

신경망을 이용한 가속도-모드형상 기반 손상검색 기법을 검증하기 위하여 양단 자유보의 실험을 수행하였다. 대상 구조물은 길이 56cm, 폭 4cm, 두께 1cm의 알루미늄 양단 자유보이고 그것은 Fig. 5.1에 나타내었다. 구조물의 재료 물성치는 Table 5.1에 나타내었다. Fig. 5.2는 실험 세팅과 구조물의 손상형태를 나타내는 그림이다. Fig. 5.2(a)에서 보는 바와 같이, 가속도 센서는 9.2cm의 동일한 간격으로 7개를 부착하였다. 가속도 신호취득을 위해서 구조물 좌측단에서 6cm위치에 충격하중을 가하였다.

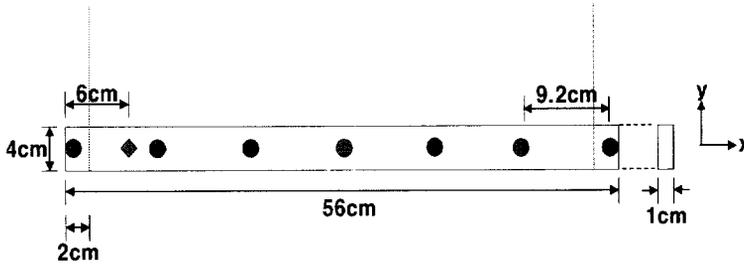


Fig. 5.1 Free-Free Beam Structure

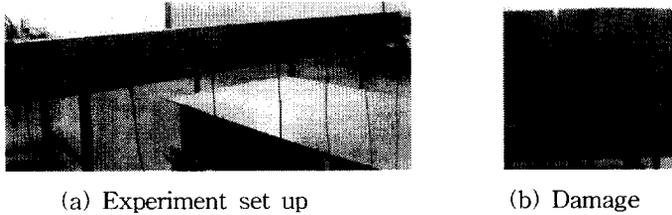


Fig. 5.2 Experiment set up and Damage

Table 5.1 Property of free-free beam

Elastic Modulus	Mass Density	Poisson's ratio
$70 \times 10^9 \text{ kgf/m}^2$	$2700 \text{ kgf/m}^3$	0.33

본 실험의 손상시나리오는 Table 5.2에 나타내었다. 손상 시나리오는 4가지의 경우로 작성되었다. 손상 경우-I은 구조물 정 중앙에서 좌측으로 2cm위치에 폭 1mm, 깊이 2.5mm의 균열이다. 손상 경우-II는 손상 경우-I과 동일한 위치에서

손상 깊이가 5mm로 증가된 경우이다. 손상 경우-Ⅲ은 구조물 중앙에서 좌측으로 2cm위치에 폭 1mm, 깊이 5mm의 균열과 구조물 우측단에서 좌측으로 3.4cm 위치에 폭 1mm, 깊이 2.5mm의 균열로 선정되었다. 손상 경우-Ⅳ는 손상 경우-Ⅲ과 동일한 위치에 우측단에서 좌측으로 3.4cm위치의 균열 깊이가 5mm로 증가된 경우로 선정되었다.

Table 5.2 Damage Scenario

Damage Case	Damage location (x/L)	Damage size (a/H)	Damage width (mm)
I	0.464	0.25	1
Ⅱ	0.464	0.5	1
Ⅲ	0.464, 0.939	0.5, 0.25	1
Ⅳ	0.464, 0.939	0.5, 0.5	1

Fig. 5.3은 실험에 사용된 장비와 가속도 신호의 일례를 나타낸 그림이다. 실험은 압전형 가속도계(Dytran 3101BG)와 DAQ 보드(NI PXI-4472)를 이용하여 sampling frequency 8000Hz로 총 8450개의 가속도 신호를 계측하였다.

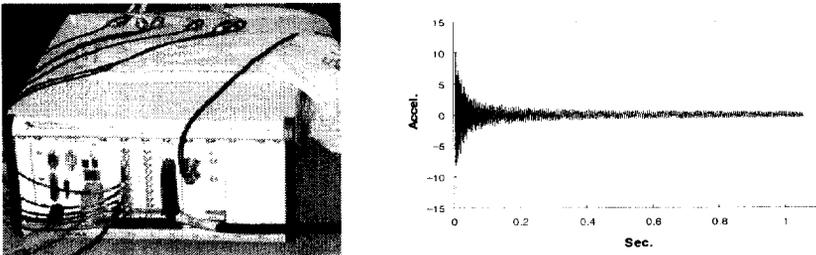


Fig. 5.3 Experiment equipment and acceleration signal

양단 자유보의 유한요소 해석모델은 Fig. 5.4와 같다. 유한요소 모델의 재료 물성치는 Table 5.1에 나타난 실험 대상 구조의 물성치와 동일하게 적용되었다. 구조물의 길이는 양 끝단에 부착된 센서의 반경(4mm)을 제외한 55.2cm로 하였고, 구조물은 4.6cm의 등 간격으로 12개의 요소로 구성되었다. Table 5.2에 나타난 손상시나리오에서 x/L이 0.464인 위치에 해당하는 요소는 6번 요소이고, x/L이 0.939인 위치에 해당하는 요소는 12번 요소이다.

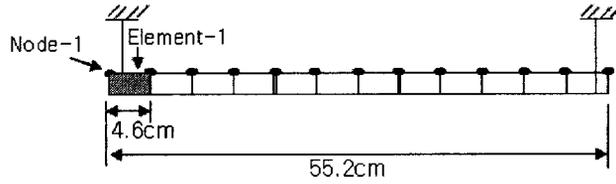


Fig. 5.4 Finite Element Model of Free-Free Beam

## 5.2 신경망 학습

### 5.2.1 신경망 학습을 위한 손상시나리오

신경망 학습을 위하여 다음과 같이 손상시나리오를 선정하였다. 단일 손상에 대한 손상 시나리오는 Table 5.3, 복수손상에 대한 손상시나리오는 Table 5.4에 나타내었다. 먼저, 단일 손상 학습패턴 구성을 위한 손상시나리오는 12개의 요소에 각각 10%, 20%, 30%, 40%, 50%의 휨 강성을 감소시키는 것으로 작성하였다. 따라서, 학습 패턴은 Table 5.3과 같이 비손상 상태 1 경우를 포함하여 총 61개가 작성되었다. 복수 손상 학습패턴 구성에 있어 손상은 두 개의 요소에서 동시에 발생하는 것으로 한정하였다. 손상 시나리오는 2개의 요소에 대하여 각각 10%, 20%, 30%, 40%, 50%의 손상을 무작위로 적용하였다. 이와 같은 방법으로 복수 손상 학습패턴은 Table 5.4와 같이 총 66개가 작성되었다. 예를 들어, Table 5.4에서 Pattern 1은 1번 요소와 2번 요소에 각각 10%, 10%의 손상이 발생한 것을 의미한다.

Table 5.3 Single Damage Scenario for Training Neural Networks

Pattern	Damaged Element	$\Delta EI/EI$ (%)	Pattern	Damaged Element	$\Delta EI/EI$ (%)	Pattern	Damaged Element	$\Delta EI/EI$ (%)	Pattern	Damaged Element	$\Delta EI/EI$ (%)
1	-	-	17	4	20	33	8	30	49	12	40
2	1	10	18	5	20	34	9	30	50	1	50
3	2	10	19	6	20	35	10	30	51	2	50
4	3	10	20	7	20	36	11	30	52	3	50
5	4	10	21	8	20	37	12	30	53	4	50
6	5	10	22	9	20	38	1	40	54	5	50
7	6	10	23	10	20	39	2	40	55	6	50
8	7	10	24	11	20	40	3	40	56	7	50
9	8	10	25	12	20	41	4	40	57	8	50
10	9	10	26	1	30	42	5	40	58	9	50
11	10	10	27	2	30	43	6	40	59	10	50
12	11	10	28	3	30	44	7	40	60	11	50
13	12	10	29	4	30	45	8	40	61	12	50
14	1	20	30	5	30	46	9	40			
15	2	20	31	6	30	47	10	40			
16	3	20	32	7	30	48	11	40			

Table 5.4 Multi Damage Scenario for Training Neural Networks

Pattern	Damaged Elements	$\Delta EI/EI$ (%)	Pattern	Damaged Elements	$\Delta EI/EI$ (%)
1	1, 2	10, 10	34	4, 8	50, 10
2	1, 3	20, 20	35	4, 9	10, 40
3	1, 4	30, 10	36	4, 10	20, 40
4	1, 5	40, 10	37	4, 11	30, 30
5	1, 6	50, 50	38	4, 12	40, 40
6	1, 7	10, 30	39	5, 6	50, 40
7	1, 8	20, 40	40	5, 7	10, 50
8	1, 9	30, 10	41	5, 8	20, 50
9	1, 10	40, 20	42	5, 9	30, 50
10	1, 11	50, 50	43	5, 10	40, 50
11	1, 12	10, 20	44	5, 11	50, 20
12	2, 3	20, 30	45	5, 12	10, 50
13	2, 4	30, 50	46	6, 7	30, 10
14	2, 5	40, 20	47	6, 8	10, 10
15	2, 6	50, 20	48	6, 9	20, 20
16	2, 7	10, 20	49	6, 10	30, 10
17	2, 8	20, 30	50	6, 11	50, 10
18	2, 9	30, 20	51	6, 12	50, 50
19	2, 10	40, 10	52	7, 8	20, 20
20	2, 11	50, 10	53	7, 9	30, 10
21	2, 12	20, 50	54	7, 10	40, 20
22	3, 4	10, 20	55	7, 11	50, 50
23	3, 5	30, 30	56	7, 12	10, 30
24	3, 6	40, 40	57	8, 9	30, 30
25	3, 7	50, 10	58	8, 10	40, 30
26	3, 8	10, 20	59	8, 11	50, 40
27	3, 9	20, 30	60	8, 12	30, 10
28	3, 10	30, 30	61	9, 10	40, 40
29	3, 11	40, 40	62	9, 11	50, 30
30	3, 12	50, 30	63	9, 12	10, 20
31	4, 5	20, 40	64	10, 11	50, 20
32	4, 6	30, 10	65	10, 12	40, 30
33	4, 7	40, 40	66	11, 12	10, 50

## 5.2.2 가속도 기반 신경망 학습

가속도 기반 신경망 학습을 위한 유한요소 모델의 가속도 신호계측 시스템을 Fig. 5.5에 나타내었다. 그림에서 나타난 바와 같이 구조물의 0.1L위치에 충격하중을 주었고, 구조물의 0.3214L(5번 절점), 0.5L(7번 절점)의 위치에서 가속도 신호를 취득하였다. 샘플링 주파수는 8000Hz로 하였고, 총 8450개의 가속도 데이터를 취득하였다.

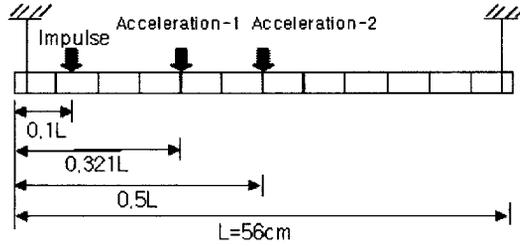
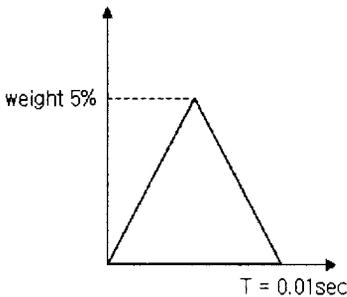


Fig. 5.5 Excitation System and Sensor System

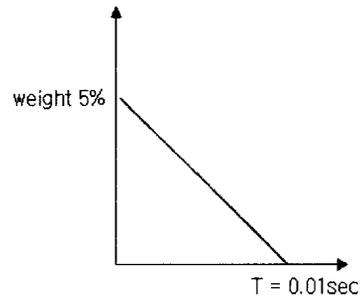
하중조건에 따른 신경망 입력 패턴을 추출하기 위하여 Table 5.5와 Fig. 5.6과 같이 총 4개의 가진 경우를 고려하였다. 모든 충격하중의 크기는 유한요소 모델 자중의 5%로 하였고, 가진 시간은 0.01초로 하였다. 가진 경우 1은 삼각형 형태의 충격하중이고, 가진 경우 2는 직각삼각형 형태의 충격하중이다. 가진 경우 3은 사각형 형태의 충격하중이고, 가진 경우 4의 충격하중은 가진 경우 3의 충격하중과 동일한 사각형 형태이지만 가진을 0.005초 지연하여 주는 것으로 하였다.

Table 5.5 Impulse Excitation Conditions for Acceleration based Neural Networks Training

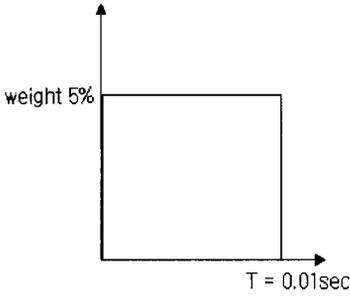
Case	Pulse Shape	Pulse Intensity (percent per self-wight)	Pulse Duration (sec)
1	Triangular Pulse	5%	0 - 0.01
2	Right Triangular Pulse	5%	0 - 0.01
3	Rectangular Pulse- I	5%	0 - 0.01
4	Rectangular Pulse- II	5%	0.005 - 0.015



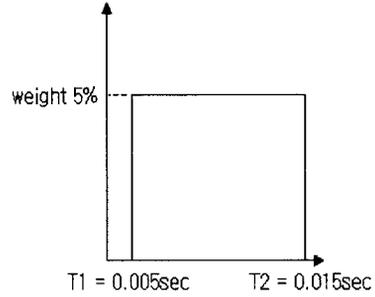
(a) Triangular Pulse



(b) Right Triangular Pulse



(c) Rectangular Pulse- I



(d) Rectangular Pulse- II

Fig. 5.6 Excitation Scenario

이상과 같은 4개의 가진 조건에 따라 각각의 손상 시나리오별로 적용하여 가속도를 추출하였다. Fig. 5.7과 5.8은 손상이 없는 상태의 유한요소 모델에 가진 경우 1을 적용하여 0.3214L(5번 절점)과 0.5L(7번 절점)에서 각각 취득된 가속도 신호의 예를 나타낸 그림이다.

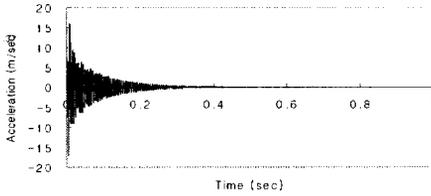


Fig. 5.7 Acceleration-0.3214L

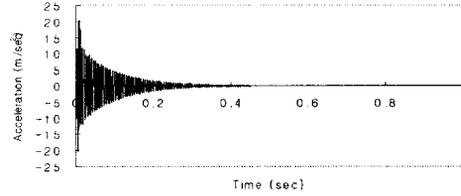


Fig. 5.8 Acceleration-0.5L

학습 패턴은 손상 시나리오에 따라 두 점에서 취득한 가속도 신호의 상호상관 함수를 통하여 추출되었다. 다음으로 식 4.1을 이용하여 비손상 상태에 대한 각 손상시나리오별 상관함수 패턴의 비를 구하고, 구해진 각 손상시나리오별 패턴 비의 값 중에서 초기 50개의 패턴 비를 신경망의 입력 자료로 이용하였다. Fig. 5.9는 Fig. 5.7, 5.8에 나타난 신호가 상호상관함수를 통하여 출력된 패턴이다.

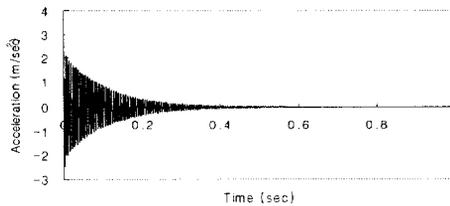


Fig. 5.9 Cross Correlation Result of Two Signals

가속도 기반 신경망의 구성은 Fig. 5.10에 나타내었다. 신경망은 50개 유니트의 입력층, 50개 유니트의 은닉층, 12개 유니트의 출력층으로 구성하였다. 출력층의 12개 유니트는 각각 대상 구조물의 12요소에 해당한다. 학습에 이용된 패턴은 Table 5.2의 손상시나리오 중 손상 경우-I 과 손상 경우-II의 단일 손상을 검색하는 Undamage 1set과 12개의 요소가 각각 10%, 20%, 30%, 40%, 50%의 손상을 입은 경우의 61set을 이용하였다. 손상 경우-III과 손상 경우-IV의 복수 손상을 검색하는 단일 손상 학습패턴 61set과 복수손상 학습패턴 66set을 추가한 127set의 패턴을 이용하였다.

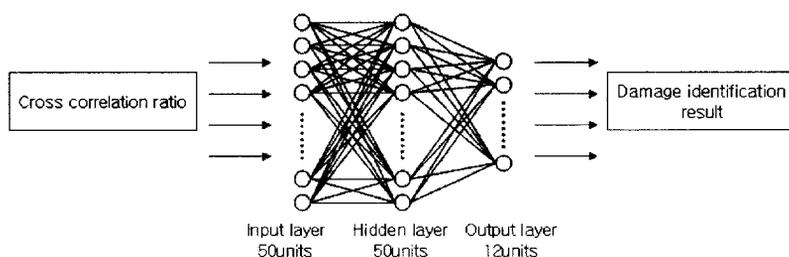


Fig. 5.10 A Process of Acceleration based Neural Networks Training

### 5.2.3 모드형상 기반 신경망 학습

모드형상 기반 신경망 학습을 위하여 고유모드형상을 추출하기 위한 유한요소 모델을 Fig. 5.11에 나타내었다. 고유모드형상은 구조물의 센서가 부착된 지점과 동일한 위치에서 고유벡터를 취득하여 추출하였으며, 비손상 상태에 대한 모드형상은 Fig. 5.12와 같다.

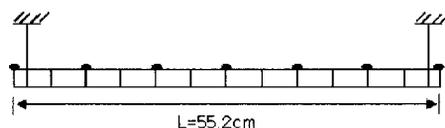


Fig. 5.11 Finite Element Model for Acquisition Eigen Vector

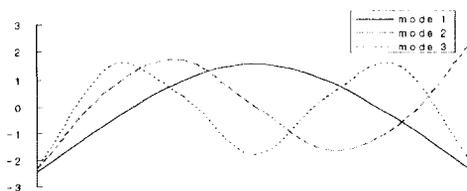


Fig. 5.12 Eigen Vector for Neural Networks Training

Table 5.3과 5.4의 신경망 학습 시나리오에 따라 추출된 구조물의 고유벡터로 식 4.1을 이용하여 손상 전·후의 고유벡터비를 구하였다. 모드형상 기반 신경망의 학습은 고유벡터비가 학습 자료로 사용된다. 모드형상 기반 신경망은 Fig. 5.13에 나타내었다. 신경망은 21개 유닛의 입력층, 21개 유닛의 은닉층, 12개 유닛의 출력층으로 구성하였다. 출력층의 12개 유닛은 각각 대상 구조물의 12요소에 해당한다. 신경망 입력에 사용된 하나의 패턴은 초기 3개의 저차모드를 이용하였고, 21개의 데이터로 구성하였다. 학습에 이용된 패턴은 가속도기반 신경망의 학습패턴과 같이 손상 경우-I 과 손상 경우-II의 단일 손상 검색에는 Undamage 1set과 12개의 요소가 각각 10%, 20%, 30%, 40%, 50%의 손상을 입은 경우의 61set을 이용하였다. 손상 경우-III과 손상 경우-IV의 복수 손상 검색에는 단일 손상 학습패턴 61set과 복수손상 학습패턴 66set을 추가한 127set의 패턴을 이용하였다.

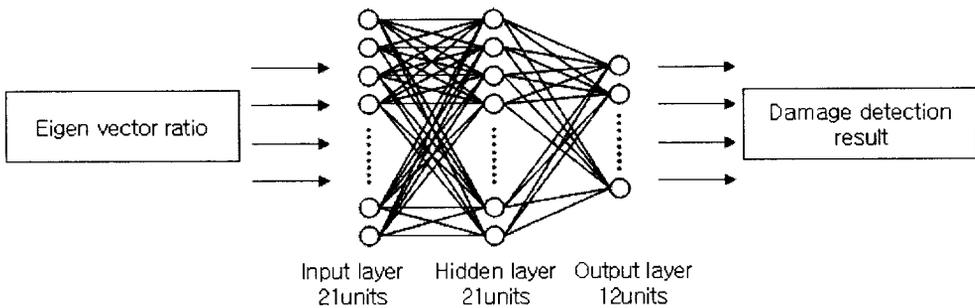


Fig. 5.13 A Process of Mode Shape based Neural Networks Training

### 5.3 신경망을 이용한 손상 검색

#### 5.3.1 가속도 신호기반 신경망을 이용한 손상검색

##### (1) 손상검색 : Damage Case-I

Fig. 5.14는 Table 5.5의 신경망 학습을 위한 가진조건 중 경우1의 삼각형가진, 경우2의 직각삼각형가진, 경우3의 사각형가진, 경우4의 가진시간 지연이 있는 사각형가진에 대한 신호로 각각 학습된 신경망으로 손상 경우-I에 대한 손상검색을 손상검색을 수행한 결과이다. Fig. 5.14(a)는 삼각형 가진에 의해 추출된 신호로 학습한 신경망의 결과이고, Fig. 5.14(b)는 직각삼각형 가진에 의해 추출된 신호로 학습한 신경망의 결과이다. Fig. 5.14(c)는 사각형 가진에 의한 신호로 학습한 신경망의 결과

이고, Fig. 5.14(d)는 0.005초간의 가진시간 지연이 있는 사각형 가진에 따른 신호로 학습한 신경망의 결과이다. 각각의 그림에서 확인할 수 있는 바와 같이 실제 손상이 있는 6번 요소의 손상뿐만 아니라 다른 요소들에서도 손상이 감지되는 결과를 나타내고 있다. 4가지 결과를 모두 보았을 때, 각각의 신경망이 수행한 손상추정은 모두 다른 결과를 나타내고 있으나 6번 요소의 손상은 모두 공통적으로 예측하고 있음을 확인할 수 있다.

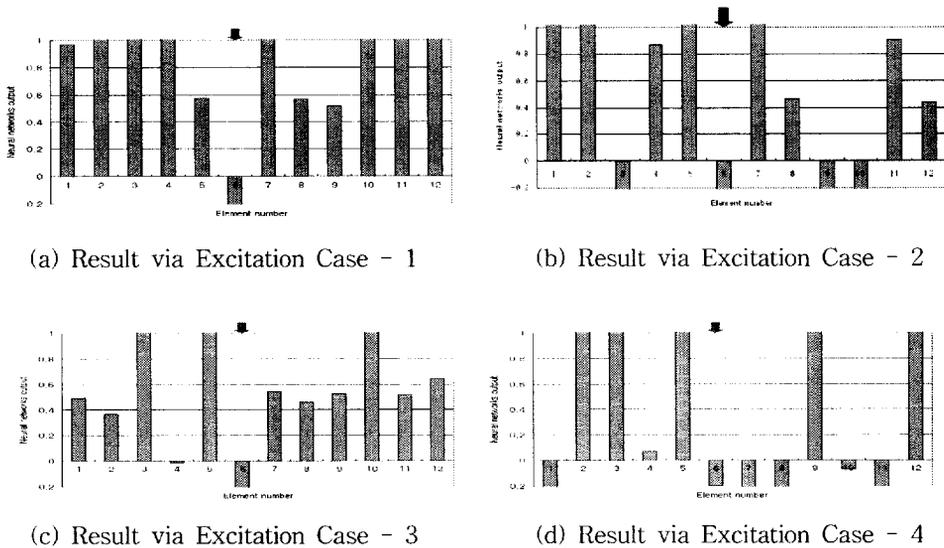
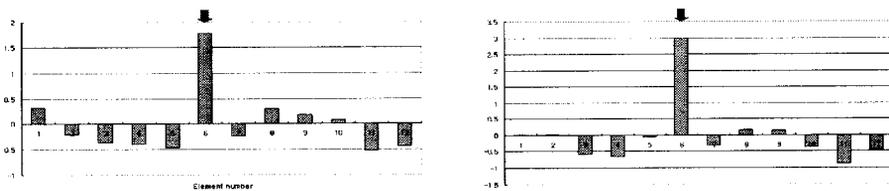


Fig. 5.14 Damage Detection Result of Damage Case - 1

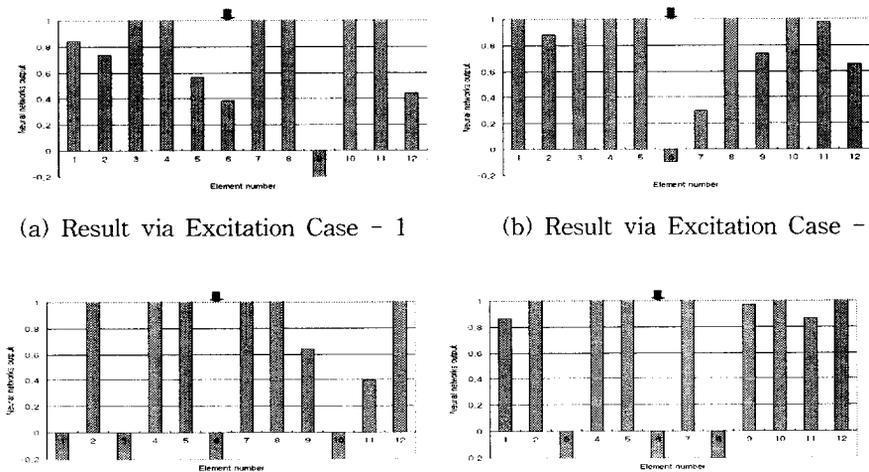
Fig. 5.15(a)는 Table 5.5의 가진조건 중 경우1, 경우2, 경우3, 경우4의 가진에 따른 신호로 학습된 각각의 신경망의 손상검색 결과들을 3장에서 기술된 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이, 손상지수(Damage Index)가 1.5이상(정규 분포 상 기각영역 93.3%) 실제 손상이 있는 요소인 6번 요소로 나타났고, 이를 보아 6번 요소의 손상이 정확히 예측되었다고 판단된다. Fig. 5.15(b)는 실제 실험의 충격하중의 형태와 비슷한, 경우 1의 삼각형 가진, 경우 3의 사각형 가진에 따른 신호로 학습된 신경망의 손상검색 결과들을 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이 6번 요소의 손상지수가 1.5 이상의 값을 가지는 것으로 나타나 6번 요소의 손상 발생가능성이 가장 높은 것으로 예측되었다.



(a) Damage Index using Four Excitations (b) Damage Index using Tri. and Rect. Pulse  
 Fig. 5.15 Damage Index of Damage Case - I

(2) 손상검색 : Damage Case-II

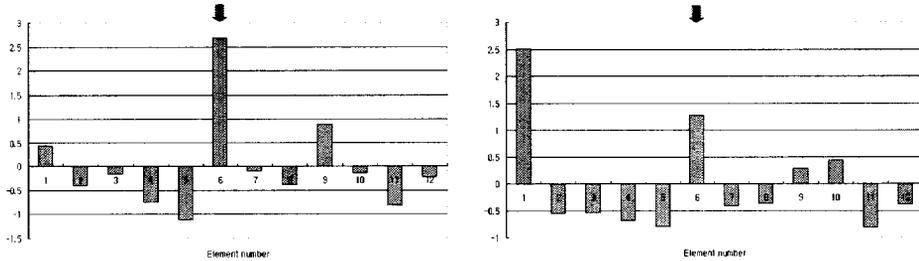
Fig. 5.16은 Table 5.5의 가진조건 중 경우1, 경우2, 경우3, 경우4의 가진에 대한 신호로 각각 학습된 신경망으로 손상 경우-II에 대한 손상검색을 수행한 결과이다. Fig. 5.16(a)는 삼각형 가진에 의해 추출된 신호로 학습한 신경망의 결과이고, Fig. 5.16(b)는 직각삼각형 가진에 의해 추출된 신호로 학습한 신경망의 결과이다. Fig. 5.16(c)는 사각형 가진에 의한 신호로 학습한 신경망의 결과이고, Fig. 5.16(d)는 0.005초간의 가진시간 지연이 있는 사각형 가진에 따른 신호로 학습한 신경망의 결과이다. 각각의 그림에서 확인할 수 있는 바와 같이 실제 손상이 있는 6번 요소의 손상뿐만 아니라 다른 요소들에서도 손상이 감지되는 결과를 나타내고 있다. 4가지 결과를 모두 보았을 때 손상 경우-I의 결과와 같이, 각각의 신경망이 수행한 손상검색 결과는 모두 달랐으나 6번 요소의 손상은 모두 공통적으로 예측하고 있음을 확인할 수 있다.



(a) Result via Excitation Case - 1 (b) Result via Excitation Case - 2  
 (c) Result via Excitation Case - 3 (d) Result via Excitation Case - 4

Fig. 5.16 Damage Detection Result of Damage Case - II

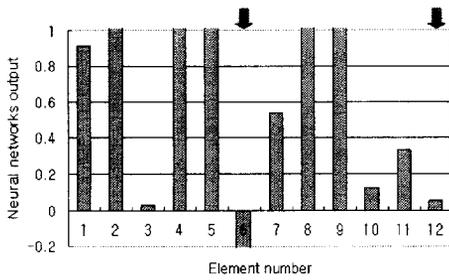
Fig. 5.17(a)는 Table 5.5의 가진조건 중 경우1, 경우2, 경우3, 경우4의 가진에 따른 신호로 학습된 각각의 신경망의 손상검색 결과들을 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이, 손상지수가 1.5이상은 실제 손상이 있는 요소인 6번 요소로 나타났으며, 손상이 정확히 예측되었다. Fig. 5.17(b)는 실제 실험의 충격하중의 형태와 비슷한, 경우 1의 삼각형 가진, 경우 3의 사각형 가진에 따른 신호로 학습된 신경망의 손상검색 결과들을 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이 1번 요소와 6번 요소에서 손상발생 가능성이 높은 것으로 나타났으나, 1번 요소에 대해서는 손상위치 예측 오류를 나타내었다.



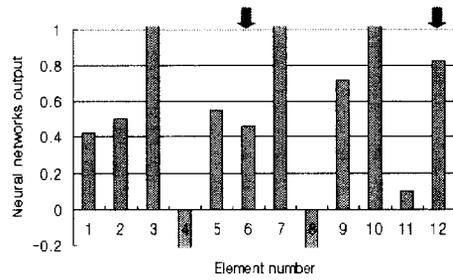
(a) Damage Index using Four Excitations (b) Damage Index using Tri. and Rect. Pulse  
Fig. 5.17 Damage Index of Damage Case - II

### (3) 손상검색 : Damage Case-III

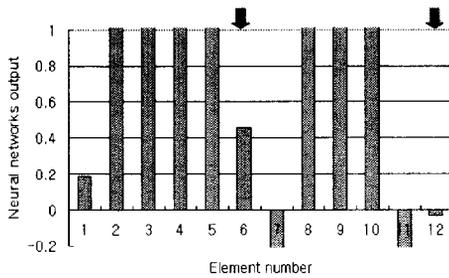
Fig. 5.18은 Table 5.5의 가진조건 중 경우1, 경우2, 경우3, 경우4의 가진에 대한 신호로 각각 학습된 신경망으로 손상 경우-III의 6번 요소와 12번 요소에서 동시에 발생한 손상을 추정한 결과이다. Fig. 5.18(a)는 삼각형 가진에 의해 추출된 신호로 학습한 신경망의 결과이고, Fig. 5.18(b)는 직각삼각형 가진에 의해 추출된 신호로 학습한 신경망의 결과이다. Fig. 5.18(c)는 사각형 가진에 의한 신호로 학습한 신경망의 결과이고, Fig. 5.18(d)는 0.005초간의 가진시간 지연이 있는 사각형 가진에 따른 신호로 학습한 신경망의 결과이다. 각각의 그림에서 나타난 바와 같이 실제 손상이 있는 6번 요소와 12번 요소의 손상뿐만 아니라 다른 요소들에서도 손상이 예측되는 결과를 나타내고 있다. 이것으로 보아 각각의 신경망이 수행한 손상추정은 모두 다른 결과를 나타내었으나, 6번 요소와 12번 요소의 손상은 모두 공통적으로 예측하고 있음을 확인할 수 있다.



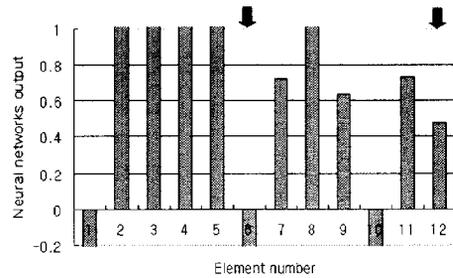
(a) Result via Excitation Case-1



(b) Result via Excitation Case-2



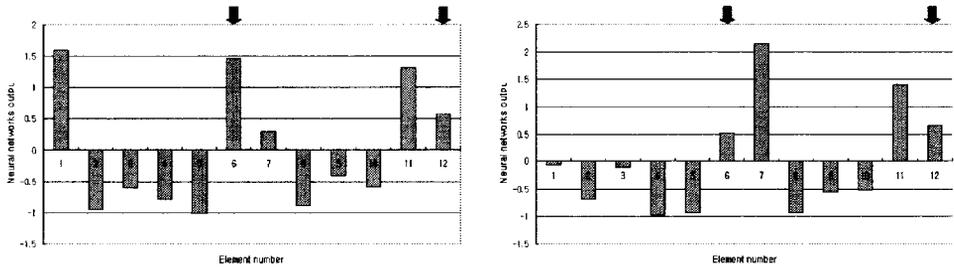
(c) Result via Excitation Case-3



(d) Result via Excitation Case-4

Fig. 5.18 Damage Detection Result of Damage Case - III

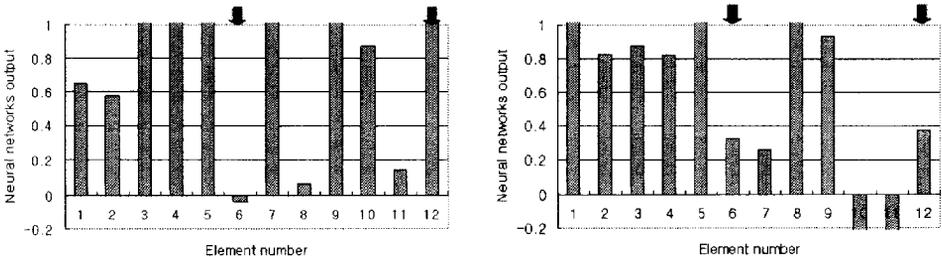
Fig. 5.19(a)는 경우1, 경우2, 경우3, 경우4의 충격하중에 따른 신호로 학습된 각각의 신경망의 손상검색 결과들을 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이, 손상 발생 가능성이 높은 요소는 1번 요소와 6번 요소, 11번 요소 등으로 나타났다. 이것으로 보아 실제 손상이 있는 6번 요소는 손상 위치가 예측되었으나 12번 요소의 손상위치는 11번 요소로 예측한 것으로 판단된다. 손상지수가 1.5이상인 것은 1번 요소로 나타나 1번 요소의 손상 발생 가능성이 가장 높은 결과를 얻을 수 있어 손상위치 예측오류를 나타내었다. Fig. 5.19(b)는 경우 1의 삼각형 가진, 경우 3의 사각형 가진에 따른 신호로 학습된 신경망의 손상검색 결과들을 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이, 손상 발생 가능성이 높은 요소는 7번과 11번 요소로 나타났고 이 중 손상지수가 1.5를 넘은 요소는 7번 요소로 나타났다. 이것으로 보아 6번 요소의 손상위치는 7번 요소로 예측되었고, 12번 요소의 손상은 11번 요소로 예측된 것으로 판단되어진다.



(a) Damage Index using Four Excitations (b) Damage Index using Tri. and Rect. Pulse  
 Fig. 5.19 Damage Index of Damage Case - III

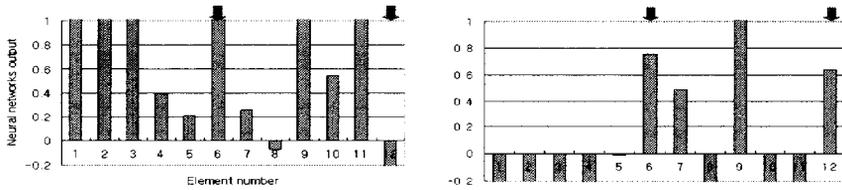
(4) 손상검색 : Damage Case-IV

Fig. 5.20은 경우1, 경우2, 경우3, 경우4의 가진에 대한 신호로 각각 학습된 신경망으로 손상 경우-IV의 6번 요소와 12번 요소에서 동시에 발생한 손상을 추정한 결과이다. Fig. 5.20(a)는 삼각형 가진에 의해 추출된 신호로 학습한 신경망의 결과이고, Fig. 5.20(b)는 직각삼각형 가진에 의해 추출된 신호로 학습한 신경망의 결과이다. Fig. 5.20(c)는 사각형 가진에 의한 신호로 학습한 신경망의 결과이고, Fig. 5.20(d)는 0.005초 간의 가진시간 지연이 있는 사각형 가진에 따른 신호로 학습한 신경망의 결과이다. Fig. 5.20(a), 5.20(b), 5.20(d)의 결과에서는 6번 요소와 12번 요소의 손상뿐만 아니라 다른 요소들에서도 손상이 예측되는 결과를 나타내고 있다. 그러나 Fig. 5.20(c)에 나타난 손상검색 결과에서는 12번 요소의 손상을 비롯하여 다른 요소들에서도 손상이 발생하고 있다고 예측하고 있으나 6번 요소의 손상은 예측되지 못하는 결과를 나타내고 있다. 비록 Fig. 5.20(c)의 사각형 가진에 대한 결과에서는 6번 요소의 손상은 예측되지 못하였으나, 4가지 결과를 종합하여 보았을 때, 실제 손상이 있는 6번 요소와 12번 요소의 손상은 전반적으로 예측되고 있음을 확인할 수 있다.



(a) Result via Excitation Case-1

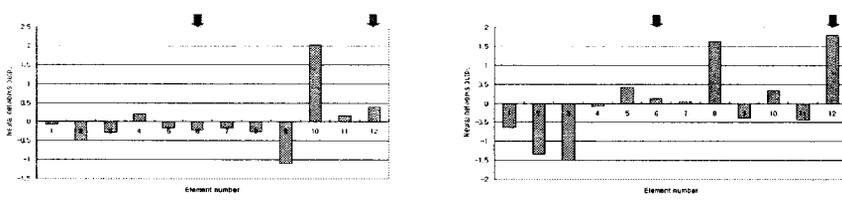
(b) Result via Excitation Case-2



(c) Result via Excitation Case-3                      (d) Result via Excitation Case-4

Fig. 5.20 Damage Detection Result of Damage Case - IV

Fig. 5.21(a)는 경우1, 경우2, 경우3, 경우4의 충격하중에 따른 신호로 학습된 각각의 신경망의 손상검색 결과들을 통계적 가설 검증 기법을 이용하여 구조물 각 요소별로 손상발생 가능성을 예측한 결과이다. 그림에서 나타난 바와 같이, 손상 발생 가능성이 높은 요소는 10번 요소로 나타났고, 실제 손상이 있는 6번 요소와 12번 요소에서는 손상이 발생할 가능성이 낮은 것으로 나타났다. Fig. 5.21(b)는 가진 경우 1과 가진 경우 2의 사각형 가진에 대한 결과를 통계적 가설 검증 기법을 통하여 손상발생 가능성을 예측한 결과이다. 손상 지수가 1.5 이상을 나타내는 요소는 8번 요소와 12번 요소로 나타났다. 따라서, 6번 요소의 손상은 8번 요소로 오차를 나타냈으며, 12번 요소는 정확하게 예측하였다.



(a) Damage Index using Four Excitations                      (b) Damage Index using Tri. and Rect. Pulse

Fig. 5.21 Damage Index of Damage Case - IV

### 5.3.2 모드형상 기반 신경망을 이용한 손상검색

#### (1) 손상검색 : Damage Case- I

모드형상 기반 신경망을 이용하여 6번 요소에서 발생한 2.5mm의 균열에 대한 손상 검색을 수행한 결과는 Fig. 5.22와 같다. 그림에서 보는바와 같이 6번 요소에서 발생한 손상에 대해 그 위치가 정확히 추정된 결과를 나타내고 있다. 손상 정도의 추정에 있어서 2.5mm의 균열에 대하여 10%의 강성이 저하된 것으로 추정되었다.

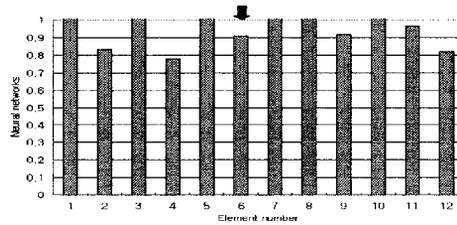


Fig. 5.22 Damage Detection Result of Damage Case- I

**(2) 손상검색 : Damage Case-II**

6번 요소에서의 균열의 깊이가 5mm 증가된 것에 대한 손상 검색을 수행한 결과는 Fig. 5.23과 같다. 그림에서 보는바와 같이 손상이 6번 요소에서 발생한 것으로 나타나 정확한 위치추정이 이루어졌다. 그리고 5mm의 균열깊이에 대해 25%의 강성이 저하된 것으로 추정되었다. 손상 경우-I의 결과와 비교해보았을 때 2.5mm에서 5mm로 균열이 2배가 증가하는 것에 대해 10%의 강성저하에서 25%로 2.5배로 증가되는 것으로 나타났다. 이것으로 보아 모드형상 기반 신경망을 통하여 구조물의 손상 증가에 대한 정량적 평가가 어느 정도 가능하다고 판단된다.

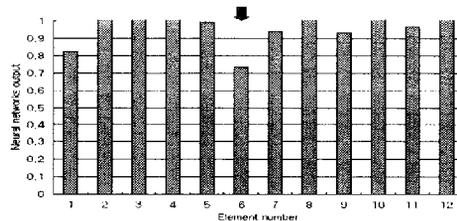


Fig. 5.23 Damage Detection Result of Damage Case-II

**(3) 손상검색 : Damage Case-III**

손상 경우-III의 6번 요소의 5mm균열, 12번 요소에서의 2.5mm균열에 대한 손상검색 결과는 Fig 5.24와 같다. 그림에서 보는바와 같이 6번 요소의 5mm 균열에 대해 그 위치는 정확히 추정되었고, 강성은 약 30%가 저하된 것으로 추정되었다. 12번 요소의 손상은 11번 요소에서 손상이 발생한 것으로 추정되어 손상 위치예측 오류가 나타났다. 2.5mm의 균열에 대한 손상도의 추정은 25%의 강성이 저하된 것으로 추정되었다.

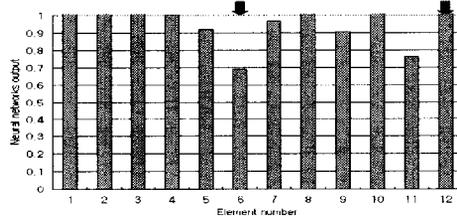


Fig. 5.24 Damage Detection Result of Damage Case-III

#### (4) 손상검색 : Damage Case-IV

손상 경우-IV의 6번 요소의 5mm균열, 12번 요소의 5mm균열에 대한 손상검색 결과는 Fig. 5.25와 같다. 그림에서 보는바와 같이 6번 요소에서 발생한 5mm균열에 대해서는 6번 요소의 약 30%의 강성저하로 추정하고 있어 손상 경우-II의 25%의 강성저하, 손상 경우-III의 30%의 강성저하로 추정한 것과 거의 비슷한 결과를 얻을 수 있었다. 12번 요소의 5mm 균열에 대해서는 약 50%의 강성저하로 추정된 결과를 보여주고 있다. 손상 경우-III의 결과와 비교해보았을 때, 2.5mm에서 5mm로 균열이 2배가 증가하는 것에 대해 강성저하가 23.9%에서 약 50.5%로 약 2.1배로 증가되는 것으로 나타났다. 이것으로 보아 모드형상 기반 신경망을 통해 손상 증가에 대한 정량적 평가가 어느 정도 가능하다고 판단된다.

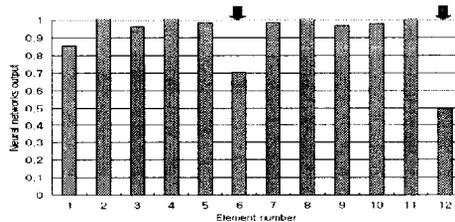


Fig. 5.25 Damage Detection Result of Damage Case-IV

### 5.3.3 손상검색 정확도

#### (1) 가속도 기반 신경망의 손상검색 정확도

가속도 기반 신경망 알고리즘에 대한 양단 자유보의 손상 검색 정확도는 Table 5.6과 같이 산정되었다. 손상 경우-I에서는 Table 5.5에 나타난 4가지 충격하중 형태에 따른 가속도 신호로 학습된 각각의 신경망을 이용하였을 때 6번 요소에서의 손상을 정확히 예측하였다. 가진 경우1의 삼각형 가진과 가진 경우3

의 사각형 가진에 따른 가속도 신호로 학습된 신경망의 손상검색 결과에서도 6번 요소의 손상을 정확히 예측하였다. 손상 경우-II에서는 4가지 가진에 따른 가속도로 학습된 신경망의 손상검색 결과는 6번 요소의 손상을 정확히 예측하고 있다. 그러나 삼각형 가진과 사각형 가진의 결과는 6번 요소의 손상에 대해 1번 요소에서 손상이 발생한 것으로 예측되어 41.67%의 위치오차를 나타내었다. 손상 경우-III의 6번 요소와 12번 요소의 손상에 대해서는 4가지 가진을 이용하였을 때 6번 요소의 손상은 정확히 예측되었으나 12번 요소의 손상은 1번 요소에서 손상이 발생된 것으로 예측되어 91.67%의 오차가 나타나 12번 요소의 손상은 감지되지 않았다고 판단된다. 삼각형 가진과 사각형 가진을 이용한 결과는 6번 요소에서의 손상은 7번 요소에서 손상이 발생한 것으로 예측되어 8.33%의 위치예측 오차를 나타내었고, 12번 요소에서 발생한 손상은 예측되지 않았다. 손상 경우-IV의 6번 요소와 12번 요소의 손상에 대해, 4가지 가진을 사용한 손상검색 결과는 6번 요소의 손상은 감지되지 않았고 12번 요소의 손상은 10번 요소에서 손상이 발생한 것으로 예측되어 16.67%의 오차를 나타내고 있다. 삼각형 가진과 사각형 가진을 사용한 손상검색 결과는 6번 요소에서의 손상은 8번 요소에서 손상이 나타난 것으로 예측되어 16.67%의 위치예측 오차를 나타내었고, 12번 요소에서의 손상은 예측되지 않았다. 이상의 결과에서 보았을 때, 가속도 신호기반 신경망으로 구조물에 발생한 단일 손상에 대해서는 거의 정확한 예측을 할 수 있다고 판단되었다. 복수 손상에 대해서는 단일 손상에 대한 손상검색에 비해 정확한 위치추정은 이루어 지지 않았으나 어느 정도의 위치추정이 가능하다고 판단되었다. 따라서 가속도 신호기반 신경망을 이용한 손상검색 기법을 통하여 상세한 구조물의 손상 식별은 힘들지만 손상 발생 유무에 대한 경보는 가능하다고 생각된다. 또 실시간 가속도 데이터를 이용하게 되므로 실시간 구조건전성 모니터링에 적용하여 실시간으로 구조물의 손상경보가 가능할 것이라고 판단된다.

Table 5.6 Accuracy of Damage Detection using Acceleration based Neural Networks

Damage Case	Inflicted Damage		Predicted Damage		Prediction Accuracy	
	Location (Element No.)	Severity (a/H)	Location (Element No.)		Location Error (%)	
			Using 4 Pulses	Tri. and Rect. Pulse	Using 4 Pulses	Tri. and Rect. Pulse
1	6	0.25	6	6	0	0
2	6	0.5	6	1	0	41.67
3	6, 12	0.5, 0.25	6, 1	7, -	8.3, 91.67	0, 100
4	6, 12	0.5, 0.5	-, 10	8, 12	100, 16.67	16.67, 0

(2) 모드 형상기반 신경망의 손상검색 정확도

모드형상 기반 신경망을 이용한 손상검색 결과는 Table 5.8과 Table 5.9에 요약하였다. Table 5.8은 손상위치 검색 결과를 요약한 것이다. 손상 경우-I의 6번 요소의 손상검색 결과를 보았을 때 그 위치를 정확히 추정하였다. 손상 경우-II의 결과에서도 손상이 발생한 6번 요소의 손상 위치가 정확히 추정되었다. 손상 경우-III의 6번 요소와 12번 요소에서 발생한 손상 추정에서는 6번 요소에 발생한 손상 위치를 정확히 추정하고 있었으나 12번 요소에서의 손상은 11번 요소에서 손상이 발생한 것으로 예측되어 8.33%의 손상위치 예측오차를 나타내고 있었다. 손상 경우-IV의 6번 요소와 12번 요소의 손상추정은 각각 그 위치를 정확히 추정하였다. Table 5.9는 구조물의 손상 정도를 예측한 결과이다. 손상 경우-I과 손상 경우-II를 비교해보았을 때, 요소 6의 균열이 2배가 증가된 것에 관하여 신경망의 출력은 약 2.9배가 증가한 것으로 나타났다. 손상 경우-III과 손상 경우-IV를 비교해보았을 때, 6번 요소 5mm균열에 대한 신경망 출력값은 각각 31.2%와 29.9%의 강성저하 나타났고 12번 요소의 균열이 2.5mm에서 5mm로 2배가 증가하였을 때 신경망 출력 결과는 23.9%에서 50.5%로 약 2.1배 증가한 것으로 나타났다. 이것으로 보아 모드형상 기반 신경망은 구조물의 손상에 대해 더 상세한 손상 위치 추정이 가능할 뿐만 아니라 발생한 손상의 증가에 대한 정량적 평가가 어느 정도 가능하다고 판단된다.

Table 5.7 Accuracy of Damage Location Detection using Mode Shape based Neural Networks

Damage Case	Inflicted Damage		Predicted Damage	Prediction Accuracy
	Location (Element No.)	Size (a/H)	Location (Element No.)	Location Error (%)
1	6	0.25	6	0
2	6	0.5	6	0
3	6, 12	0.5, 0.25	6, 11	0, 8.33
4	6, 12	0.5, 0.5	6, 12	0, 0

Table 5.8 Result of Damage Extent Assessment using Mode Shape based Neural Networks

Damage Case	Damage size of Element-6 (a/H)	Damage Extent Result of Element-6 (%)	Damage size of Element-12 (a/H)	Damage Extent Result of Element-12 (%)
1	0.25	9	-	-
2	0.5	26.5	-	-
3	0.5	31.2	0.25	23.9
4	0.5	29.9	0.5	50.5

## 6. 요약 및 결론

본 연구에서는 실시간 구조건전성 모니터링 구현을 위한 가속도-모드형상 기반 신경망을 이용한 손상검색체계를 제안하였다. 이 체계는 크게 2단계로 구성되었다. 첫 번째 단계에서는 실시간 가속도 응답을 이용하여 학습된 신경망으로 구조물의 실시간 손상 모니터링을 수행하여 손상을 경보하는 단계이다. 두 번째 단계는 감지된 손상에 대해 모드형상을 입력으로 한 신경망 기법으로 상세한 손상 평가를 수행하는 단계이다. 특히 손상 경보 단계의 경우, 기존 연구에서는 일정한 외력 조건으로부터 절대적인 가속도 값을 신경망 학습에 이용하였기 때문에 실제 구조물에서와 같은 불확실한 외력 조건하에서는 적용하기 곤란하다. 따라서, 본 연구에서는 이러한 불확실성을 고려하기 위하여 두 가지 방법을 이용하였다. 먼저, 외력의 크기에 따른 가속도 레벨의 변화를 해결하기 위해서 두 점에서 취득한 가속도의 상호상관함수를 이용하였다. 다음으로, 외력의 형상이나 지속시간에 의한 가속도 신호 패턴의 변화에 대해서는 몇 개의 가진 시나리오에 따라 각각의 신경망을 학습하고, 손상 검색 결과들을 통계적으로 분석하였다.

제안된 손상검색 기법의 적합성을 검증하기 위하여 먼저 수치모형실험을 실시하였고, 실제 적용성을 평가하기 위하여 양단 자유보의 축소모형 실험을 실시하였다. 그 결과 제안된 손상 평가 기법에 대한 검증 결과를 통해 다음과 같은 결론을 도출할 수 있었다.

- (1) 두 점에서 취득된 가속도 신호의 상호상관신호를 입력패턴으로 이용할 경우, 외력 크기에 대한 가속도 레벨 변화를 고려할 수 있다. 하지만 가진 형상 및 가진 시간 또한 가속도 신호의 변화에 영향을 미치므로 고려되어야 한다.
- (2) 제안된 가속도 기반 신경망을 이용한 손상검색체계의 경우, 단일 손상에 대해서는 손상예측이 수치적 검증과 실험적 검증에서 정확하게 예측되었으나, 복수 손상에 대해서는 다소 예측 오차가 나타났다. 또한, 신경망 학습 단계에서 고려되는 하중의 종류와 손상 평가에 사용되는 신경망의 수량이 많을수록 더 신뢰할 만한 예측 결과를 산출할 수 있었다.
- (3) 모드형상 기반 신경망을 이용하여 손상 평가를 수행하였을 때, 수치적 검증과 실험적 검증을 통해 손상 위치뿐만 아니라 손상 정도까지 비교적 정확하게 예측할 수 있음을 확인하였다.

- (4) 구조물에 작용하는 다양한 외력 조건에 대한 분석이 이루어지고, 대상 구조물의 구조식별을 통해 구조 특성이 명확히 파악된다면, 제안된 실시간 손상 검색 체계는 실제 구조물에 대해서도 적용 가능할 것으로 기대된다.

## 참고문헌

- 구자홍, 김진경, 박진호, 박현진, 이재준, 전홍석, 황진수,(2000), 통계학, 자유아카데미
- 박재형, 김정태, 류연선(2004), 고유진동수 시간이력을 이용한 보 구조물 손상 모니터링 기법, 한국전산구조공학회 춘계 학술대회, pp.41-56
- 박재형, 김정태, 류연선, 이진학,(2005), 보 구조물의 진동기반 구조손상검색을 위한 마이크로 유전 알고리즘의 적용, 한국강구조학회 학술발표회
- 배상현, 정현철,(2004), Neural Networks와 유전자 알고리즘. 조선대학교 출판부
- 백종훈,(2002) 손상지수법과 구조식별 기법을 통한 균열된 모형 강관형교의 손상 검색, 석사학위논문, 부경대학교
- 이용환, 박재형, 김정태, 류연선, 나원배,(2005), 가속도 응답 신호와 다층인공신경망을 통한 단순보의 손상추정, 한국전산구조공학회 학술발표회, pp.367-374
- 이인원, 오주원, 박선규, 김주태,(1999), 신경망을 이용한 강박스 거더교의 손상평가, 한국강구조학회논문집, Vol. 11, No. 1, pp. 79-88,
- 이종재, “신경망 기법을 이용한 교량의 건전도 모니터링”, 한국과학기술원, 박사학위논문
- 임중수,(2002), Matlab’s power, 도서출판 아진
- 정환진, 김주태, 오주원, 이인원, “신경망을 이용한 구조물의 손상평가”, 대한토목학회논문집, Vol. 17, No. 0, pp. 617-626
- Adeli, H., and Yeh,C.(1989), Perceptron learning in engineering design, Microcomputers in Civil Engineering, Vol.4, pp.247-256
- 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
- Julius. B, Allan. P, Random Data - Analysis and Measurement Procedures, John Wiley and Sons INC
- Lee, J.J. Lee, J.W. Yi, J.H. Yun, C.B. Jung, H.Y,(2005) 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
- Lee, J. W., Kim, J. D., Yun, C. B., Yi, J. H. and Shim, J. M.(2002), Health-Monitoring Method for Bridges under Ordinary Traffic Loadings, Journal of Sound and Vibration, 257(2), pp. 247-264
- Maity. D, Saha. A,(2004) Damage assessment in structure from changes in static parameter using neural networks, Academy proceedings in

- engineering science, v.29 no.3, pp.315-328
- Masri. S. F, M. Nakamura, A. G. Chassiako, and T. K. Caughey,(1996), Neural Network Approach to Detection of Change in Structural Parameters, Journal of Engineering Mechanics, Vol. 122, No. 4, pp. 350-360
- Ni. Y. Q., Wang, B. S and Ko, J. M.(2002), Constructing input vectors to neural networks for structural damage identification, Smart Materials and Structures, Vol.11, pp.825-833
- P.C Pandey, S. V. Brai.(1995), Multilayer Perceptron in Damage Detection of Bridge Structures, Computers & Structures, Vol. 54, No 4, pp. 597-608
- P. Tsou, M. H. Herman Shen,(1994), Structural Damage Detection and Identification Using Neural Networks, AIAA Journal, Vol. 32, No. 1, pp. 176-183,
- S. F. Masri, M. Nakamura, A. G. Chassiakos, T.K. Caughey,(1996), Neural Network Approach to Detection of Changes in Structural Parameters, Journal of Engineering Mechanics, Vol. 122, No. 4, pp. 350-360,
- Szewezyk, Z.P. and Hajela, P.(1994), Damage detection in strucruess based on feature-sensitive neural networks, Journal of Computing in Civil Engineering, ASCE, Vol.8, No.2, pp.163-178
- X. Wu, J. Ghanoussi, J. H. Garret,(1992), Use of Neural Networks in Detection of Structural Damage. Computers & Structures, Vol. 42, No. 4, pp. 649-659
- Yun, C. B., Yi, J. H. and Bahng, E. Y.(2001), Joint Damage Assessment of Framed Structures Using Neural Networks Technique, Engineering Structures, Vol.23, No.5, pp.425-435
- Zhao. Jun, Ivan, John N,(1998), Structural damage detection using artificial neural networks, Journal of infrastructure systems, Vol.4 No.3, pp.93-101

## 감사의 글

5년이라는 시간동안 부족한 저를 항상 바른길로 인도해주시고 제 논문에 대해 깊은 관심을 가지시며 지도 편달 해주신 지도교수 김정태 교수님께 감사의 말씀을 올립니다. 아버님과 같은 인자하심과 엄한 꾸짖음으로 저를 지도해주신 류연선 교수님, 큰 형과 같은 따뜻함으로 저에게 애정 어린 조언을 해주신 대선배님이자 교수님이신 나원배 교수님께 진심으로 감사드립니다. 학부와 대학원 과정동안 평소 끊임없는 관심으로 지도해주신 윤길수 교수님, 류청로 교수님, 김헌태 교수님, 이인철 교수님, 김윤태 교수님께도 깊이 감사드립니다.

연구 과정동안 어려움에 봉착했을 때, 먼 이국땅에서 늦은 새벽에도 불구하고 많은 조언을 아끼지 않으신 University of California Irvine에서 박사 후 연구원으로 계시는 이종재 박사님, 2년의 대학원 과정동안 함께 수많은 밤을 새하얗게 지새우며 용기를 북돋워 주시고 논문 연구동안 실의에 빠져있을 때 항상 함께 해주셨던 스마트구조공학 연구실 박사과정 박재형 선배님께 감사의 말씀드립니다. 바쁜 업무 중에도 항상 연구실과 후배들을 챙겨주신 이영규 선배님께 감사드립니다. 연구실생활 동안 동고동락한 동기 이병준, 대학원 졸업동기 김주영에게도 고마운 마음 표합니다. 성실이라는 것을 알게 해준 후배 홍동수, 이 부족한 형의 일이라면 언제든지 OK 사인을 날리며 달려와 줬던 박민효, 어느덧 가장 믿음직한 후배로 거듭난 우리 스마트 구조공학 연구실의 두 기동 도한성, 이정미, 실험 및 컴퓨터 프로그램 작업과정동안 같이 밤을 새며 고생해준 조국래, 딱딱한 일상에서도 푸근함을 느끼게 해준 이소영, 친동생처럼 따라준 정찬일, 감자탕의 추억을 함께 나눈 신송기, 그리고 먼 이국에서 수학중인 천재용 후배님들께 고마운 마음 전합니다.

언제나 든든한 지원군이 되어준 10년 지기 친구 모대영, 정진영, 박성한, 김형철 군에게도 감사드립니다. 타향에서 보내는 외로운 시간동안 따뜻함으로 저를 안아주고 걱정해줬던 박여정, 강일선 양에게도 고마운 마음 표합니다. 학부 및 대학원 과정동안 소중한 추억을 가지게 해준 배민지 양, 안춘식, 정욱재 군을 비롯한 빛촌(영상예술연구회) 후배님들께도 감사드립니다. 나태해지려할 때 따끔한 충고로 저를 다잡아주신 정교현 형님, 늘 한결같은 관심으로 저를 살피주시고 아껴주신 이완재 형님, 김소영 누님께 진심으로 감사드립니다.

크신 사랑으로 저를 안아주신 할머니님, 외할머니님. 부족한 큰 조카를 열렬하게 지지해주시고 아껴주신 이모님, 이모부님 내외분께 큰 감사의 말씀 올립니다. 모든 면에서 열심히 하며 형을 잘 따라주는 착하고 든든한 동생 이용민군에게도 감사드립니다.

마지막으로, 오늘의 저를 있게 해 주시고 항상 걱정과 뜨거운 사랑으로 이 못난 아들을 믿어주시며 지지해주신 존경하는 아버님, 사랑하는 어머님. 두 분께 고개 숙여 두 손으로 이 줄고를 바치고자 합니다. 아버님, 어머님 감사합니다.